



**TUGAS AKHIR - SS141501**

**MODEL HIBRIDA ARIMAX DAN *DEEP LEARNING*  
NEURAL NETWORK UNTUK PERAMALAN BEBAN  
LISTRIK JANGKA PENDEK DI PT. INDONESIA  
POWER UP BALI**

**KADEK AYU KRISNAWATI  
NRP 062114 4000 0052**

**Dosen Pembimbing  
Dr. Suhartono**

**PROGRAM STUDI SARJANA  
DEPARTEMEN STATISTIKA  
FAKULTAS MATEMATIKA, KOMPUTASI, DAN SAINS DATA  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA 2018**





**TUGAS AKHIR - SS141501**

**MODEL HIBRIDA ARIMAX DAN *DEEP LEARNING*  
*NEURAL NETWORK* UNTUK PERAMALAN  
BEBAN LISTRIK JANGKA PENDEK DI PT.  
INDONESIA POWER UP BALI**

**KADEK AYU KRISNAWATI  
NRP 062114 4000 0052**

**Dosen Pembimbing  
Dr. Suhartono**

**PROGRAM STUDI SARJANA  
DEPARTEMEN STATISTIKA  
FAKULTAS MATEMATIKA, KOMPUTASI, DAN SAINS DATA  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA 2018**





**FINAL PROJECT - SS141501**

**HYBRID ARIMAX AND DEEP LEARNING  
NEURAL NETWORK FOR SHORT TERM LOAD  
FORECASTING IN PT. INDONESIA POWER UP  
BALI**

**KADEK AYU KRISNAWATI  
SN 062114 4000 0052**

**Supervisor  
Dr. Suhartono**

**UNDERGRADUATE PROGRAMME  
DEPARTMENT OF STATISTICS  
FACULTY OF MATHEMATICS, COMPUTING, AND DATA SCIENCE  
INSTITUT TEKNOLOGI SEPULUH NOPEMBER  
SURABAYA 2018**



**LEMBAR PENGESAHAN**

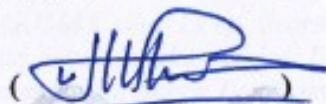
**MODEL HIBRIDA ARIMAX DAN *DEEP LEARNING*  
NEURAL NETWORK UNTUK PERAMALAN BEBAN  
LISTRIK JANGKA PENDEK DI PT. INDONESIA  
POWER UP BALI**

**TUGAS AKHIR**

Diajukan Untuk Memenuhi Salah Satu Syarat  
Memperoleh Gelar Sarjana Sains  
pada  
Program Studi Sarjana Departemen Statistika  
Fakultas Matematika, Komputasi, dan Sains Data  
Institut Teknologi Sepuluh Nopember

Oleh :  
**Kadek Ayu Krisnawati**  
NRP. 062114 4000 0052

Disetujui oleh Pembimbing:  
**Dr. Suhartono**  
NIP : 19710929 199512 1 001



Mengetahui,  
**Kepala Departemen**



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

**SURABAYA, JULI 2018**

*(Halaman ini sengaja dikosongkan)*



**MODEL HIBRIDA ARIMAX DAN DEEP LEARNING  
NEURAL NETWORK UNTUK PERAMALAN BEBAN  
LISTRIK JANGKA PENDEK DI PT. INDONESIA POWER  
UP BALI**

**Nama : Kadek Ayu Krisnawati**

**NRP : 062114 4000 0052**

**Departemen : Statistika**

**Pembimbing : Dr. Suhartono**

**Abstrak**

*Energi listrik tidak dapat langsung disimpan dalam skala besar dan hanya dapat digunakan saat dibutuhkan saja. Oleh karena itu energi listrik yang dibangkitkan di pembangkit harus sama dengan energi listrik yang digunakan oleh konsumen. Prediksi listrik yang tepat pada suatu daerah sangat diperlukan untuk mengoptimalkan persediaan kebutuhan listrik. Penelitian ini dilakukan bertujuan untuk menerapkan metode Hibrida ARIMAX dan Deep Learning Neural Network untuk peramalan beban listrik jangka pendek. Data yang digunakan pada penelitian ini adalah data beban listrik mulai Januari 2014 hingga Desember 2017 sebanyak 1461 observasi. Kajian yang digunakan dibagi menjadi dua kajian yaitu kajian simulasi dan kajian terapan. Hasil kajian simulasi menunjukkan bahwa metode Hibrida ARIMAX dan Deep Learning Neural Network menghasilkan hasil peramalan yang lebih baik untuk horizon medium dan long, sementara hasil lebih beragam diperoleh pada horizon short. Untuk kajian terapan, menunjukkan bahwa hasil peramalan menggunakan metode Deep Learning Neural Network menghasilkan hasil ramalan yang lebih baik untuk horizon medium dan long, sementara Hibrida ARIMAX dan Deep Learning Neural Network mendominasi pada horizon short. Pada kedua kajian model Hibrida ARIMAX-DLNN tidak selalu lebih unggul dibanding metode lainnya. Hal ini membuktikan bahwa metode yang lebih kompleks tidak selalu memberikan nilai akurasi ramalan yang lebih baik. Peramalan beban listrik*

*dilakukan berdasarkan metode terbaik yang diperoleh pada horizon short dikarenakan pada umumnya semakin pendek periode peramalan maka akurasi yang dihasilkan semakin baik.*

***Kata Kunci : ARIMAX, Beban Listrik, Deep Learning Neural Network, Hibrida***

# **HYBRID ARIMAX AND DEEP LEARNING NEURAL NETWORK FOR SHORT TERM LOAD FORECASTING IN PT. INDONESIA POWER UP BALI**

**Name** : Kadek Ayu Krisnawati  
**Student Number** : 062114 4000 0052  
**Department** : Statistics  
**Supervisor** : Dr. Suhartono

## **Abstract**

*Electrical energy can not be directly stored on a large scale and can only be used when needed only. Therefore, the electrical energy generated in the power plant must be equal to the electrical energy used by the consumer. Precise electrical prediction in a region is needed to optimize the supply of electricity needs. The aim of this research is to apply Hybrid ARIMAX and Deep Learning Neural Network method to forecast short-term electrical load. Data used in this research is electric load data from January 2014 to December 2017 as many as 1461 observations. The study used is divided into two studies namely simulation studies and applied studies. The results of the simulation study show that the Hybrid ARIMAX and Deep Learning Neural Network method produce better forecasting results for medium and long horizons, while more diverse results are obtained on the short horizon. For applied studies, indicating that forecasting results using the Deep Learning Neural Network method resulted in better outcomes for medium and long horizons, while Hybrid ARIMAX and Deep Learning Neural Network method dominated on the short horizon. In both studies the Hybrid ARIMAX-DLNN model is not always superior to other methods. This proves that more complex methods do not always provide better prediction accuracy values. Power load forecasting is based on the best method obtained on the short*

*horizon because in general the shorter the forecast period the better the accuracy.*

***Keywords: ARIMAX, Deep Learning Neural Network, Hybrid, Load***

## KATA PENGANTAR

Puja dan puji syukur penulis panjatkan kehadirat Tuhan Yang Maha Esa atas segala berkah-Nya, sehingga penulis dapat menyelesaikan Tugas Akhir dengan judul **“Model Hibrida ARIMAX dan *Deep Learning Neural Network* untuk Peramalan Beban Listrik Jangka Pendek di PT. Indonesia Power UP Bali”** dengan tepat waktu.

Penulis menyadari bahwa dalam penyusunan Tugas Akhir ini tidak terlepas dari bantuan maupun dukungan dari berbagai pihak. Pada kesempatan ini penulis menyampaikan terima kasih kepada:

1. Dr. Suhartono selaku dosen pembimbing Tugas Akhir dan Kepala Departemen Statistika, telah meluangkan waktu, mengarahkan, dan memberikan bimbingan bagi penulis.
2. Dr. rer. Pol. Heri Kuswanto, S.Si, M.Si dan Muhammad Sjahid Akbar, S.Si, M.Si selaku dosen penguji yang telah meluangkan waktu dan banyak memberi masukan kepada penulis.
3. Dr. Sutikno, M.Si. selaku Ketua Program Studi Sarjana yang telah memfasilitasi dan membantu secara administrasi dalam proses penyusunan Tugas Akhir.
4. Bapak I Ketut Gunada selaku SPS Rendal Operasi dan Niaga yang telah meluangkan waktu dan memberikan bimbingan kepada penulis selama melakukan pengambilan data di PT. Indonesia Power UP Bali.
5. Seluruh karyawan pada bagian PON (Pengendali Operasi dan Niaga) PT. Indonesia Power UP Bali atas bimbingan, kemudahan, bantuan serta keramahan yang telah diberikan kepada penulis.
6. Teman-teman Statistika ITS angkatan 2014, Respect, yang selalu memberikan dukungan kepada penulis selama ini.
7. Kedua orang tua penulis serta keluarga besar yang telah memberikan doa dan dukungan kepada penulis dalam menyelesaikan Tugas Akhir.

8. Semua pihak yang telah memberikan bantuan maupun dukungan yang tidak dapat disebutkan satu per satu dalam penyusunan Tugas Akhir ini.

Tugas Akhir yang disusun oleh penulis masih memiliki banyak kekurangan. Kritik dan saran yang membangun selalu diharapkan penulis sehingga Tugas Akhir ini dapat memberikan manfaat bagi semua pihak yang terkait.

Surabaya, Juni 2018

Penulis

## DAFTAR ISI

	Halaman
<b>HALAMAN JUDUL</b> .....	i
<b>COVER PAGE</b> .....	iii
<b>LEMBAR PENGESAHAN</b> .....	v
<b>Abstrak</b> .....	vii
<b>Abstract</b> .....	ix
<b>KATA PENGANTAR</b> .....	xi
<b>DAFTAR ISI</b> .....	xiii
<b>DAFTAR GAMBAR</b> .....	xv
<b>DAFTAR TABEL</b> .....	xix
<b>DAFTAR LAMPIRAN</b> .....	xxi
<b>DAFTAR NOTASI</b> .....	xxiii
<b>BAB I PENDAHULUAN</b> .....	1
1.1 Latar Belakang .....	1
1.2 Rumusan Masalah .....	10
1.3 Tujuan .....	11
1.4 Manfaat .....	11
1.5 Batasan Masalah .....	11
<b>BAB II TINJAUAN PUSTAKA</b> .....	13
2.1 <i>Autoregressive Integrated Moving Average</i> (ARIMA) .....	13
2.2 Estimasi Parameter .....	14
2.3 Uji Diagnostik .....	16
2.4 <i>Autoregressive Integrated Moving Average with</i> <i>Exogenous Variable (ARIMAX)</i> .....	18
2.5 Pengujian Linieritas .....	19
2.6 <i>Neural Network</i> .....	20
2.7 <i>Algoritma Backpropagation</i> .....	24
2.8 <i>Deep Learning Neural Network</i> .....	27
2.9 Hibrida ARIMAX dan <i>Deep Learning Neural</i> <i>Network</i> .....	31
2.10 Pemilihan Model Terbaik .....	32
2.11 Listrik .....	33
2.12 Penelitian Sebelumnya .....	36

<b>BAB III METODOLOGI PENELITIAN</b> .....	41
3.1 Sumber Data dan Variabel Penelitian.....	41
3.2 Langkah Analisis .....	42
3.2.1 Kajian Simulasi.....	43
3.2.2 Kajian Terapan .....	48
<b>BAB IV ANALISIS DAN PEMBAHASAN</b> .....	57
4.1 Studi Simulasi.....	57
4.1.1 Simulasi Data Bangkitan .....	57
4.1.2 Hasil Simulasi .....	84
4.2 Karakteristik Data Beban Listrik .....	89
4.3 Pemodelan Data Beban Listrik dengan ARIMAX .....	93
4.4 Pemodelan Data Beban Listrik dengan <i>Deep Learning Neural Network</i> .....	99
4.5 Pemodelan Data Beban Listrik dengan Hibrida ARIMAX dan <i>Deep Learning Neural Network</i> .....	103
4.6 Perbandingan Model ARIMAX, DLNN serta Hibrida ARIMAX dan DNN .....	106
4.7 Peramalan .....	111
<b>BAB V KESIMPULAN DAN SARAN</b> .....	115
5.1 Kesimpulan.....	115
5.2 Saran .....	116
<b>DAFTAR PUSTAKA</b> .....	117
<b>LAMPIRAN</b> .....	123
<b>BIODATA PENULIS</b> .....	239



## DAFTAR GAMBAR

	Halaman
<b>Gambar 1.1</b>	Penelitian Forecasting, Nowcasting dan STLF dari Tahun 1994 sampai 2018 ..... 5
<b>Gambar 2.1</b>	Arsitektur Neural Network ..... 21
<b>Gambar 2.2</b>	Arsitektur <i>Deep Learning</i> Neural Network ..... 28
<b>Gambar 2.3</b>	Sistem Tenaga Listrik ..... 34
<b>Gambar 3.1</b>	Diagram Alir Metode ARIMAX ..... 51
<b>Gambar 3.2</b>	Diagram Alir Metode <i>Deep Learning</i> Neural Network ..... 52
<b>Gambar 3.3</b>	Diagram Alir Kajian Terapan ..... 53
<b>Gambar 3.4</b>	Proses ARIMAX ..... 54
<b>Gambar 3.5</b>	Proses <i>Deep Learning Neural Network</i> ..... 55
<b>Gambar 3.6</b>	Proses Hibrida ARIMAX dan <i>Deep Learning</i> Neural Network ..... 56
<b>Gambar 4.1</b>	<i>Time Series Plot</i> Komponen (a) Tren ..... 57
<b>Gambar 4.2</b>	Plot <i>Noise</i> pada Waktu ke $t$ dengan <i>Noise</i> pada Waktu ke $t-1$ pada (a) pola linier dan (b) pola nonlinier ..... 59
<b>Gambar 4.3</b>	Data Simulasi Jam (a) 04:00, (b) 08:00, (c) 12:00, (d) 16:00, (e) 20:00 dan (f) 24:00 pada Skenario 1 ..... 59
<b>Gambar 4.4</b>	Perbandingan Data Aktual dan Hasil Ramalan Beban Listrik Menggunakan Metode ARIMAX pada Skenario 1 ..... 63
<b>Gambar 4.5</b>	Plot PACF pada Jam 20:00 ..... 64
<b>Gambar 4.6</b>	Arsitektur DLNN Jam 20:00 pada Skenario 1 ..... 65
<b>Gambar 4.7</b>	Perbandingan Data Aktual dan Hasil Ramalan Beban Listrik Menggunakan Metode DLNN pada Skenario 1 ..... 67
<b>Gambar 4.8</b>	Arsitektur Hibrida ARIMAX & DLNN Jam 20:00 pada Skenario 1 ..... 69
<b>Gambar 4.9</b>	Perbandingan Data Aktual dan Hasil Ramalan Beban Listrik Menggunakan

	Metode Hibrida ARIMAX dan DLNN pada Skenario 1.....	70
<b>Gambar 4.10</b>	Data Simulasi Pukul (a) 04.00, (b) 08.00, (c) 12.00, (d) 16.00, (e) 20.00 dan (f) 24.00 pada Skenario 2.....	71
<b>Gambar 4.11</b>	Perbandingan Data Aktual dan Hasil Ramalan Beban Listrik Menggunakan Metode ARIMAX pada Skenario 2 .....	76
<b>Gambar 4.12</b>	Plot PACF pada Jam 20:00.....	77
<b>Gambar 4.13</b>	Arsitektur DLNN Jam 20:00 pada Skenario 2 .....	78
<b>Gambar 4.14</b>	Perbandingan Data Aktual dan Hasil Ramalan Beban Listrik Menggunakan Metode DLNN pada Skenario 2 .....	79
<b>Gambar 4.15</b>	Arsitektur Hibrida ARIMAX & DLNN Jam 20:00 pada Skenario 2 .....	81
<b>Gambar 4.16</b>	Perbandingan Data Aktual dan Hasil Ramalan Beban Listrik Menggunakan Metode Hibrida ARIMAX dan DLNN pada Skenario 2.....	82
<b>Gambar 4.17</b>	<i>Time Series Plot</i> Data Beban Listrik.....	89
<b>Gambar 4.18</b>	Plot Rata-rata Pemakaian Beban Listrik Per Jam dan Per Setengah Jam.....	91
<b>Gambar 4.19</b>	Plot Rata-rata Pemakaian Beban Listrik Per Hari .....	92
<b>Gambar 4.20</b>	Perbandingan Data Aktual dan Hasil Ramalan Beban Listrik pada Jam 20:00 Menggunakan Metode ARIMAX.....	96
<b>Gambar 4.21</b>	Plot PACF pada Jam 20:00.....	99
<b>Gambar 4.22</b>	Arsitektur DLNN Jam 20:00.....	100
<b>Gambar 4.23</b>	Perbandingan Data Aktual dan Hasil Ramalan Beban Listrik pada Jam 20:00 Menggunakan Metode DLNN .....	101
<b>Gambar 4.24</b>	Arsitektur Hibrida ARIMAX dan DLNN Jam 20:00.....	104

<b>Gambar 4.25</b>	Perbandingan Data Aktual dan Hasil Ramalan Beban Listrik pada Jam 20:00 Menggunakan Metode Hibrida ARIMAX dan DLNN .....	105
<b>Gambar 4.26</b>	Perbandingan Nilai RMSE dan sMAPE Ketiga Metode pada Data Aktual .....	107
<b>Gambar 4.27</b>	Metode Terbaik pada Ketiga Horizon .....	110
<b>Gambar 4.28</b>	Plot Ramalan Beban Listrik.....	113

*(Halaman ini sengaja dikosongkan)*

## DAFTAR TABEL

	Halaman
<b>Tabel 2.1</b>	Penelitian sebelumnya ..... 36
<b>Tabel 3.1</b>	Struktur Data..... 41
<b>Tabel 3.2</b>	Pembobotan untuk Komponen Musiman (Hari)..... 44
<b>Tabel 3.3</b>	Hari Libur selain Hari Minggu Tahun 2014 hingga 2017 ..... 46
<b>Tabel 4.1</b>	Estimasi Paramater Regresi <i>Time Series</i> untuk Jam 20:00..... 60
<b>Tabel 4.2</b>	Pengujian Asumsi Residual ARIMAX pada Jam 20:00..... 62
<b>Tabel 4.3</b>	Model ARIMAX untuk Jam 04:00, 08:00, 12:00, 16:00, 20:00 dan 24:00 ..... 63
<b>Tabel 4.4</b>	Arsitektur DLLN Optimum pada Skenario 1..... 66
<b>Tabel 4.5</b>	Arsitektur Hibrida ARIMAX dan DLLN Optimum pada Skenario 1 ..... 70
<b>Tabel 4.6</b>	Estimasi Paramater Regresi <i>Time Series</i> untuk Pukul 20:00..... 73
<b>Tabel 4.7</b>	Pengujian Asumsi Residual ARIMAX pada Pukul 20:00..... 74
<b>Tabel 4.8</b>	Model ARIMAX untuk Pukul 04:00, 08:00, 12:00, 16:00, 20:00 dan 24:00 ..... 75
<b>Tabel 4.9</b>	Arsitektur DLLN Optimum pada Skenario 2..... 79
<b>Tabel 4.10</b>	Arsitektur Hibrida ARIMAX dan DLLN Optimum pada Skenario 2 ..... 82
<b>Tabel 4.11</b>	Nilai RMSE dan sMAPE Metode ARIMAX pada Dua Skenario ..... 84
<b>Tabel 4.12</b>	Nilai RMSE pada Ketiga Metode ..... 85
<b>Tabel 4.13</b>	Nilai sMAPE pada Ketiga Metode ..... 85
<b>Tabel 4.14</b>	Nilai RMSEP pada Ketiga Horizon untuk Skenario 1 ..... 87
<b>Tabel 4.15</b>	Metode Terbaik pada Ketiga Horizon untuk Skenario 1 ..... 87

<b>Tabel 4.16</b>	Nilai RMSEP pada Ketiga Horizon untuk Skenario 2 .....	88
<b>Tabel 4.17</b>	Metode Terbaik pada Ketiga Horizon untuk Skenario 2 .....	88
<b>Tabel 4.18</b>	Statistika Deskriptif Data Beban Listrik .....	89
<b>Tabel 4.19</b>	Estimasi Paramater Regresi <i>Time Series</i> untuk Pukul 20:00 .....	93
<b>Tabel 4.20</b>	Pengujian Asumsi Residual ARIMAX pada Jam 20:00 .....	95
<b>Tabel 4.21</b>	Model ARIMAX untuk Data Beban Listrik Per Setengah Jam .....	97
<b>Tabel 4.22</b>	Nilai RMSE dan sMAPE Beban Listrik Per Setengah Jam .....	98
<b>Tabel 4.23</b>	Arsitektur DLLN Optimum pada Data Aktual.....	101
<b>Tabel 4.24</b>	Arsitektur Hibrida ARIMAX dan DLLN Optimum pada Data Aktual.....	105
<b>Tabel 4.25</b>	Perbandingan RMSE Data <i>Testing</i> Ketiga Metode pada Data Aktual Menggunakan Tiga Horizon .....	108

## DAFTAR LAMPIRAN

	Halaman
Lampiran 1. Data Beban Listrik .....	123
Lampiran 2. <i>Output</i> ARIMAX Skenario 1 & 2 .....	124
Lampiran 3. <i>Output</i> ARIMAX Data Aktual .....	141
Lampiran 4. Uji <i>White</i> .....	177
Lampiran 5. Arsitektur DLNN Simulasi Skenario 1 .....	188
Lampiran 6. Arsitektur DLNN Simulasi Skenario 2 .....	191
Lampiran 7. Arsitektur DLNN Data Aktual .....	194
Lampiran 8. Arsitektur Hibrida ARIMAX & DLNN Simulasi Skenario 1.....	207
Lampiran 9. Arsitektur Hibrida ARIMAX & DLNN Simulasi Skenario 2.....	210
Lampiran 10. Arsitektur Hibrida ARIMAX & DLNN Data Aktual.....	213
Lampiran 11. Perbandingan Nilai RMSE dan sMAPE Data <i>Training</i> Ketiga Metode pada Data Aktual .....	226
Lampiran 12. Perbandingan Nilai RMSE dan sMAPE Data <i>Testing</i> Ketiga Metode pada Data Aktual .....	227
Lampiran 13. <i>Syntax</i> Program SAS untuk Metode ARIMAX.....	228
Lampiran 14. <i>Syntax</i> Program R untuk Metode DLNN .....	230
Lampiran 15. <i>Syntax</i> Program R untuk Metode Hibrida ARIMAX-DLNN .....	233
Lampiran 16. <i>Syntax</i> Program R untuk Uji <i>White</i> .....	236
Lampiran 17. Surat Keterangan Pengambilan Data.....	237

*(Halaman ini sengaja dikosongkan)*



## DAFTAR NOTASI

### ARIMAX

$a_t$	Residual pada waktu ke- $t$ dari proses ARIMAX
$B$	<i>Backshift</i> operator
$Y_t$	Data time series dengan indeks $t$
$\phi_p(B)$	Koefisien komponen AR non musiman dengan orde $p$
$\theta_q(B)$	Koefisien komponen MA non musiman dengan orde $q$
$\Phi_P(B^s)$	Koefisien komponen AR musiman $s$ dengan orde $P$
$\Theta_Q(B^s)$	Koefisien komponen MA musiman $s$ dengan orde $Q$
$t$	Variabel <i>dummy</i> tren
$H_i$	Variabel <i>dummy</i> hari
$I_k$	Variabel <i>dummy</i> untuk variasi kalender

### Neural Network

$\hat{Y}_{(t)}$	Nilai dugaan dari variabel output
$f^0$	Fungsi aktivasi pada neuron di lapisan output
$b_0^0$	Bias pada neuron di lapisan output
$w_i^0$	Bobot dari neuron ke- $i$ pada <i>hidden layer</i> yang menuju neuron pada <i>output layer</i>
$f_i^h$	Fungsi aktivasi di neuron ke- $i$ pada <i>hidden layer</i>
$b_i^1$	Bias pada neuron ke- $i$ pada <i>hidden layer</i>
$w_{ji}^1$	Bobot dari input ke- $j$ menuju neuron ke- $i$ pada <i>hidden layer</i>

$Z_{j(t)}$  Variabel input sebanyak  $q$

**Deep Learning Neural Network**

$\hat{Y}_{(t)}$  Nilai dugaan dari variabel output

$f^0$  Fungsi aktivasi pada neuron di lapisan output

$b_0^0$  Bias pada neuron di lapisan output

$w_i^0$  Bobot dari neuron ke- $i$  pada *hidden layer* yang menuju neuron pada *output layer*

$f_i^{h_2}$  Fungsi aktivasi di neuron ke- $i$  pada *hidden layer*

$f_j^{h_1}$  Fungsi aktivasi di neuron ke- $j$  pada *hidden layer*

$b_i^2$  Bias pada neuron ke- $i$  pada *hidden layer*

$b_j^1$  Bias pada neuron ke- $j$  pada *hidden layer* (

$w_{ji}^2$  Bobot dari *input* ke- $j$  menuju neuron ke- $i$  pada *hidden layer*

$w_{kj}^1$  Bobot dari *input* ke- $k$  menuju neuron ke- $j$  pada *hidden layer*

$Z_{k(t)}$  Variabel *input* sebanyak  $r$

# **BAB I**

## **PENDAHULUAN**

### **1.1 Latar Belakang**

Energi listrik tidak dapat langsung disimpan dalam skala besar, energi listrik hanya dapat digunakan saat dibutuhkan saja serta energi listrik yang dibangkitkan harus sama dengan energi listrik yang digunakan oleh konsumen. Jika energi listrik yang dibangkitkan tidak sesuai atau lebih dari yang digunakan maka hal tersebut akan mempengaruhi banyak faktor terutama dalam hal biaya bahan bakar serta tidak efisiennya penggunaan mesin pembangkit listrik (PLTG dan PLTDG) sebaliknya jika energi listrik yang dibangkitkan kurang dari yang digunakan maka akan terjadi pemadaman listrik yang akan mengganggu kenyamanan konsumen. Hal tersebut menyebabkan sangat penting untuk terus melakukan monitoring terhadap beban pembangkit listrik terutama beban pembangkit listrik jangka pendek atau per setengah jam. Di Provinsi Bali listrik berasal dari 3 pembangkit yaitu PT. Indonesia Power, Celukan Bawang serta Kabel Laut. PT. Indonesia Power atau IP adalah sebuah anak perusahaan PLN yang menjalankan usaha komersial pada bidang pembangkitan tenaga listrik. PT. Indonesia Power UP Bali mengoperasikan PLTD (Pembangkit Listrik Tenaga Diesel) Pesanggaran Denpasar, PLTG Pesanggaran, PLTG Gilimanuk dan PLTG Pamaron. PT. Indonesia Power UP Bali sendiri memiliki 12 unit PLTDG dan 4 unit PLTG. Untuk 12 unit PLTDG terbagi menjadi 4 blok dengan daya mampu masing-masing sebesar 50 MW, sementara untuk 4 unit PLTG memiliki daya mampu yang berbeda-beda berkisar antara 17 MW hingga 36 MW. Kemampuan unit untuk mampu memikul beban juga berbeda-beda, dimana PLTG membutuhkan waktu sekitar 18 menit dan PLTDG hanya memerlukan waktu 3 menit. Terdapat 3 alur ketenagalistrikan sebelum sampai pada konsumen yaitu pembangkit, transmisi dan distribusi. PT. Indonesia Power UP Bali berada di hulu ketenagalistrikan yaitu pembangkit dimana

menjalani bisnis untuk operasi dan pemeliharaan pembangkit serta pengembangan pembangkit. Berdasarkan statistik ketenagalistrikan jenis pelanggan listrik di Provinsi Bali terdiri atas rumah tangga, industri, sosial, gedung kantor pemerintah dan penerangan jalan umum. Pada tahun 2016, persentase pelanggan pengguna listrik tertinggi di Provinsi Bali adalah rumah tangga sebesar 81,28% diikuti oleh usaha sebesar 15,39%, sosial sebesar 2,54%, penerangan jalan umum sebesar 0,38%, gedung kantor pemerintah sebesar 0,30% serta industri sebesar 0,07%.

Berdasarkan hasil wawancara dengan Ahli Muda pada bagian Pengendalian Operasi dan Niaga, persiapan beban pembangkit listrik setiap harinya dilakukan berdasarkan permintaan PLN dimana aplikasi yang digunakan PLN untuk melakukan peramalan beban bernama J Ros. Setelah itu beban listrik yang harus dipersiapkan PT. Indonesia Power UP Bali dilakukan secara manual via telepon. PT. Indonesia Power harus menghubungi celukan bawang serta kabel laut terlebih dahulu untuk mengetahui berapa besar beban yang dapat dibangkitkan oleh Celukan Bawang serta Kabel Laut sehingga dapat langsung diketahui berapa beban yang harus disiapkan oleh PT. Indonesia Power. Kebutuhan listrik yang sangat tinggi di Provinsi Bali menuntut PT. Indonesia Power UP Bali untuk tetap mampu dalam memenuhi kebutuhan akan listrik di Bali. Kebutuhan listrik selalu mengalami perubahan dari waktu ke waktu sehingga perusahaan penyedia listrik serta perusahaan pembangkit listrik seperti PT. Indonesia Power UP Bali harus dapat melakukan prediksi yang tepat akan kebutuhan listrik. PT. Indonesia Power mengalami kendala karena persiapan beban yang dilakukan hanya sekedar perkiraan saja dimana aplikasi J Ros melakukan peramalan beban listrik dengan menggunakan data beban listrik tahun sebelumnya yang di *breakdown* menjadi data per bulan dan dibandingkan dengan data beban harian pada minggu sebelumnya, sehingga terkadang beban riil yang dibutuhkan tidak sesuai dengan beban pembangkit yang disiapkan. PT. Indonesia Power menginginkan error peramalan yang kecil dengan menggunakan data *real time*

dimana hal tersebut akan mempengaruhi penggunaan unit pembangkit. Kecilnya error peramalan akan lebih meningkatkan efisiensi penggunaan mesin, mengurangi biaya bahan bakar serta mempengaruhi waktu perawatan unit. Peramalan beban listrik menjadi instrumen kunci dalam operasi sistem tenaga, karena akan mempengaruhi keputusan operasi berdasarkan perkiraan beban, penjadwalan pembangkit kapasitas, analisis keandalan serta rencana perawatan generator selain itu keakuratan perkiraan beban menjadi kunci untuk perkiraan harga listrik (Fan & Chen, 2006). Dengan melakukan peramalan pada beban pembangkit listrik per setengah jamnya akan sangat membantu PT. Indonesia Power UP Bali dalam hal ketersediaan energi listrik serta permintaan energi listrik agar menjadi lebih seimbang.


Peramalan merupakan salah satu solusi yang dianggap tepat dalam menyelesaikan permasalahan yang dimiliki PT. Indonesia Power UP Bali. Banyak penelitian yang menggunakan peramalan atau *forecasting* dalam menyelesaikan permasalahan di berbagai bidang seperti listrik, bahan bakar, cuaca, jumlah wisatawan dan lain-lain. Sejak tahun 1994 hingga awal tahun 2018, jumlah penelitian mengenai peramalan atau *forecasting* terus mengalami peningkatan dimana hingga tanggal 6 Februari 2018 jumlah jurnal *forecasting* pada laman sciendirect.com telah mencapai 200.789 jurnal. Peningkatan paling signifikan dirasakan 5 tahun terakhir terutama sejak tahun 2016 dimana terdapat 16.797 penelitian hingga tahun 2017 terdapat 21.965 penelitian sehingga peningkatan terjadi sebesar 30,76%.

Salah satu jenis peramalan yang akhir-akhir ini sering digunakan adalah *nowcasting*. *Nowcasting* sendiri sering digunakan dalam melakukan peramalan jangka pendek seperti peramalan cuaca untuk 0 sampai 6 jam kedepan sehingga peramalan yang dihasilkan cukup akurat (WMO, 2017). Dengan hasil peramalan yang akurat, *nowcasting* dianggap cukup tepat juga untuk digunakan pada data listrik per setengah jamnya. Sama halnya dengan *forecasting*, penelitian tentang *nowcasting* sudah makin dikenal dan terus mengalami peningkatan sejak tahun 1994


sampai saat ini, hingga tanggal 6 Februari 2018 jumlah jurnal *nowcasting* pada laman sciendirect.com telah mencapai 1.562 jurnal. Dimana peningkatan paling signifikan terjadi dalam 4 tahun terakhir terutama sejak tahun 2015 hingga tahun 2016 sebesar 29,85%. Pada tahun 2015 terdapat 134 penelitian mengenai *nowcasting* dan tahun 2016 sudah terdapat 174 penelitian mengenai *nowcasting*. Untuk tahun 2017 penelitian mengenai *nowcasting* mencapai 172 penelitian.

Selain penggunaan *nowcasting*, *short term load forecasting* (STLF) juga cukup dikenal. STLF tidak jauh berbeda dengan *nowcasting* dimana merupakan peramalan jangka pendek. Namun STLF memiliki interval peramalan lebih jauh dari *nowcasting* dimana bisa melakukan peramalan hingga tujuh hari kedepan (Barman, Choudhury, & Sutradhar, 2018). Penelitian mengenai STLF juga cukup banyak dilakukan sejak tahun 1994 dan mengalami peningkatan sangat signifikan dalam 5 tahun terakhir, hingga tanggal 6 Februari 2018 jumlah jurnal STLF pada laman sciendirect.com telah mencapai 27.810 jurnal. Dimana peningkatan paling signifikan terjadi pada tahun 2016 hingga tahun 2017 sebesar 32,32% dengan masing-masing tahun terdapat 2.787 dan 3.688 penelitian mengenai STLF. STLF juga sangat cocok digunakan pada data beban listrik dimana biasanya data beban listrik per setengah jam khususnya memiliki pola tren, musiman, variasi kalender, bersifat nonlinier dan terdapat *outlier*.


## Forecasting



## Nowcasting



## STLF



**Gambar 1.1** Penelitian Forecasting, Nowcasting dan STLF dari Tahun 1994 sampai 2018

Peramalan beban listrik sudah beberapa kali dilakukan baik di dalam negeri maupun di luar negeri. Penelitian *Short Term Electricity Load Forecasting of Kurdistan-Erbil Power System Using Artificial Neural Network* dilakukan oleh Muhammed (2011). Dua model ANN yaitu dengan 4 fitur input dan 2 fitur input digunakan untuk memperkirakan sebuah beban aktif sistem tenaga listrik Erbil. Aplikasi peramalan direalisasikan dengan menggunakan tiga kesalahan ukuran kinerja, yaitu *Mean Absolute Persentase Error* (MAPE), *Maximum Error* (MAX) dan *Mean square error* (MSE). Hasil menunjukkan struktur kedua lebih akurat dalam peramalan dan menghasilkan *error* yang kecil dan peramalan menggunakan ANN memberikan solusi yang lebih

cepat dan akurat dibanding metode konvensional. Nie, Liu, Liu & Wang (2012) melakukan penelitian *Hybrid of ARIMA and SVMs for Short Term Load Forecasting*. Dilakukan pengujian menggunakan metode ARIMA, SVM serta hibrida ARIMA-SVM. Berdasarkan nilai MAPE dan RMSE terkecil didapatkan bahwa model Hibrida ARIMA-SVM adalah yang paling baik. Penelitian *Short Term Load Forecasting using a Hybrid Model with a Refined Exponentially Weighted Fuzzy Time Series (REWFTS) and an Improved Harmony Search (IHS)* dilakukan oleh Sadaei, Enayatifar, Abdullah & Gani (2014). Menggunakan delapan studi kasus data beban listrik di Paris dan Inggris dari tahun 2005. Studi ini menunjukkan bahwa algoritma REWFTS yang disempurnakan, sangat sesuai untuk keadaan STLF dimana informasi iklim tidak dapat diakses. Didapatkan hasil hibrida REWFTS-IHS berhasil mengatasi hubungan yang kompleks pada data beban listrik. Ryu, Noh & Kim (2016) melakukan penelitian mengenai *Deep Neural Network (DNN) Based Demand Side Short Term Load Forecasting*. Untuk memverifikasi kinerja DNN hasil peramalan dibandingkan dengan model *Shallow Neural Network (SNN)*, dan model *Double Seasonal Holt-Winters (DSHW)*. Berdasarkan nilai *Mean Absolute Percentage Error (MAPE)* dan nilai *Relative Root Mean Square Error (RRMSE)* didapatkan bahwa DNN memiliki perkiraan peramalan yang paling akurat dibanding dengan model peramalan lainnya. Dimana nilai MAPE dan RRMSE kurang dari 17% dan 22% jika dibandingkan dengan SNN, dan kurang dari 9% dan 29% jika dibandingkan dengan DSHW. Dudek (2016) melakukan penelitian mengenai *Neural networks for pattern based short term load forecasting: A comparative study*. Hasil peramalan menunjukkan bahwa model Neural Networks menghasilkan pola yang sangat baik. Model berbasis Generalized regression neural network (GRNN) ternyata menjadi yang paling akurat dalam STLF dibandingkan model neural networks lainnya. GRNN adalah yang paling sederhana di antara metode yang diuji.



Dimana hanya memiliki satu parameter untuk diestimasi sehingga mudah dioptimalkan.

Din & Marnerides (2017) melakukan penelitian mengenai *Short term power load forecasting using Deep Neural Networks*. Penelitian ini dilakukan untuk membandingkan kinerja *Feed-Forward Deep Neural Network* (FF-DNN) dan *Recurrent Deep Neural Network* (R-DNN) pada peramalan beban listrik jangka pendek. Dilakukan peramalan untuk beberapa hari dan beberapa minggu ke depan menggunakan data selama 4 tahun. Didapatkan R-DNN lebih akurat dalam peramalan berdasarkan nilai MAPE, RMSE dan MAE terkecil. Penelitian *Short Term Load Forecasting using Deep Neural Networks* (DNN) juga dilakukan oleh Hoseen, Plathottam, Angamuthu, Ranganathan & Salehfar (2017). Penelitian ini bertujuan untuk menginvestigasi penggunaan DNN pada peramalan pasar listrik Iberian, dimana menggunakan banyak kombinasi fungsi aktivasi untuk mendapatkan nilai MAPE terkecil. Fungsi aktivasi yang digunakan adalah *Sigmoid*, *Rectifier Linear Unit* (ReLU), dan *Exponential Linear Unit* (ELU). Didapatkan penggunaan fungsi aktivasi ELU menghasilkan nilai MAPE terkecil. Margaret, Balaraman & Karthika (2017) melakukan penelitian mengenai *Hybrid Short Term Load Forecasting using ARIMA-SVM*. Data diambil dari tahun 2014 sampai tahun 2015 yang merupakan data beban listrik pada wilayah selatan. ARIMA digunakan untuk memprediksi beban berdasarkan data beban historis dan SVM digunakan untuk meningkatkan akurasi peramalan dengan mengekstrak komponen sensitif dari beban seperti suhu, hari dan minggu untuk menjadi pertimbangan. Metode *hybrid* yang digunakan dapat mereduksi MAPE menjadi 4,15% dan model hibrida menghasilkan akurasi yang lebih baik daripada dua model yang dipisah. Khwaja, Zhang, Anpalagan & Venkatesh (2017) melakukan penelitian mengenai *Boosted Neural Networks (BooNN) for Improved Short Term Electric Load Forecasting*. Didapatkan hasil bahwa peramalan beban listrik menggunakan model BooNN lebih baik dalam memperkecil *error* dibandingkan

model *single ANN*, *bagged ANN*, *ARMA*, *hybrid unsupervised-supervised ANN* dan *bagged regression trees*. Barman, Choudhury & Sutradhar (2018) melakukan penelitian mengenai *A Regional Hybrid GOA-SVM Model Based on Similar Day Approach for Short Term Load Forecasting in Assam, India*. Penelitian dilakukan di Assam, Negara bagian India menggunakan model GOA-SVM untuk meramalkan beban listrik pada kondisi iklim setempat. Hasil peramalan menggunakan model GOA-SVM menghasilkan hasil yang lebih baik dibanding menggunakan model STLF klasik.

Puspitasari (2011) melakukan peramalan beban listrik jangka pendek di Jawa Bali menggunakan model *Dua Level Seasonal Autoregressive* Hibrida ARIMA-ANFIS. Data yang digunakan adalah data beban listrik Jawa-Bali dari tanggal 1 Januari 2009 sampai dengan 31 Desember 2010. Hasil penelitian menunjukkan bahwa model peramalan yang paling sesuai untuk 2 hari kedepan adalah model dua level *seasonal autoregressive* Hibrida ARIMA-ANFIS dengan fungsi *Gaussian* dan jumlah fungsi keanggotaan 2 yang menghasilkan MAPE 1,18%. Pada peramalan 7 hari kedepan, model peramalan yang paling sesuai adalah model peramalan dengan metode ANFIS yang menggunakan fungsi keanggotaan *Gaussian* dan jumlah keanggotaan 3 dimana MAPE yang dihasilkan adalah 1,78%. Utomo, Kuswanto & Suhartono (2012) melakukan penelitian mengenai Penerapan Model DSARFIMA untuk Peramalan Beban Konsumsi Listrik Jangka Pendek di Jawa Timur dan Bali. Pada penelitian ini dilakukan perbandingan antara model DSARIMA dan model DSARFIMA untuk meramalkan beban konsumsi listrik pada periode satu minggu, dua minggu, tiga minggu, dan empat minggu kedepan. Perhitungan criteria *out-sample* untuk kebaikan model menunjukkan bahwa model DSARFIMA dapat menghasilkan ramalan yang lebih akurat daripada model DSARIMA. Noveri & Syafii (2013) melakukan penelitian mengenai Studi Peramalan (*Forecasting*) Kurva Beban Harian Listrik Jangka Pendek Menggunakan Metode ARIMA. Data yang digunakan dalam

penelitian ini adalah data time series beban harian listrik per jam (24 jam), hasil penelitian memperlihatkan model terbaik yang diperoleh adalah  $(0,1,0)(0,1,1)^{24}$  dengan MAPE terkecil yaitu 2,975% untuk pengujian pertama dan MAPE kedua sebesar 3,08%.

Kristiana, Wilandari & Prahutama (2015) melakukan penelitian mengenai Peramalan Beban Puncak Pemakaian Listrik di Area Semarang dengan Metode *Hybrid* ARIMA (*Autoregressive Integrated Moving Average*) - ANFIS (*Adaptive Neuro Fuzzy Inference System*) untuk studi kasus di PT PLN (Persero) distribusi Jawa Tengah dan DIY. Diperoleh model terbaik yang digunakan untuk memprediksi beban puncak harian listrik di area Semarang selama periode Desember 2014 sampai Januari 2015 adalah model *hybrid* ARIMA-ANFIS. Penelitian Peramalan Beban Pemakaian Listrik Jawa Tengah dan Daerah Istimewa Yogyakarta dengan menggunakan *Hybrid* ARIMA-NN dilakukan oleh Fitriani, Ispriyanti & Prahutama (2015). Dilakukan peramalan beban pemakaian listrik di Jawa Tengah dan Daerah Istimewa Yogyakarta untuk 30 hari kedepan, data yang digunakan mulai Januari 2014 sampai November 2014. Hasil yang didapatkan adalah peramalan menggunakan model Neural Network untuk 30 hari kedepan lebih baik dari menggunakan *Hybrid* ARIMA-NN. Khusna & Suhartono (2015) melakukan penelitian mengenai Pendekatan *Percentile Error Bootstrap* pada Model *Double Seasonal Holt-Winters*, *Double Seasonal* ARIMA, dan *Naive* untuk peramalan beban listrik jangka pendek di Jawa Timur dan Bali. Penelitian ini bertujuan untuk meramalkan beban listrik area Jawa Timur dan Bali menggunakan pendekatan *percentile error bootstrap* (PEB) pada model DSHW, DSARIMA, dan *Naive*. Data yang digunakan adalah beban listrik per setengah jam dalam satuan Mega Watt (MW) dari periode 1 Januari 2013 hingga 30 September 2014. Hasil penelitian menunjukkan bahwa model DSARIMA merupakan model terbaik berdasarkan kriteria *out-sample* sMAPE, kriteria *in-sample* AIC-SBC, serta kriteria *out-sample*

rata-rata lebar interval prediksi. Dengan demikian, dapat disimpulkan bahwa model terbaik untuk peramalan beban listrik jangka pendek area Jawa Timur-Bali adalah model DSARIMA dengan interval prediksi yang dikonstruksi menggunakan pendekatan *percentile error bootstrap*.

Pada penelitian kali ini metode yang digunakan adalah Hibrida ARIMAX dan *Deep Learning Neural Network* untuk peramalan jangka pendek beban listrik. ARIMAX digunakan untuk memodelkan data yang linier dengan mempertimbangkan variasi kalender seperti hari raya keagamaan, hari libur nasional dan lain-lain. Neural Network sangat bagus dalam memodelkan data nonlinier dari berbagai bidang dengan fungsi yang kompleks sehingga sangat baik digunakan untuk data beban listrik yang cenderung berpola nonlinier (He, 2017). *Deep Learning* merupakan pengembangan dari *Neural Network* dimana memiliki lebih banyak lapisan (layer), dengan lapisan yang lebih banyak diharapkan mampu mengenali proses yang lebih kompleks (Schmidhuber, 2015). Kombinasi dua atau lebih sistem dalam suatu fungsi disarankan karena jarang ditemukan data yang memiliki pola linier atau pola nonlinier saja, sering ditemukan data dengan pola gabungan linier dan nonlinier (Zhang, 2003). Model hibrida merupakan model gabungan yang digunakan pada data yang memiliki pola gabungan dimana diharapkan dapat menghasilkan akurasi yang lebih tinggi.

## **1.2 Rumusan Masalah**

Secara umum rumusan masalah yang akan dibahas pada penelitian ini berdasarkan latar belakang yang telah diuraikan adalah mengenai peramalan jangka pendek pada beban listrik di PT. Indonesia Power UP Bali. Pemodelan yang akan digunakan untuk melakukan peramalan jangka pendek pada beban listrik adalah model ARIMAX, *Deep Learning Neural Network* serta Hibrida ARIMAX dan *Deep Learning Neural Network*. Selanjutnya akan dilakukan perbandingan akurasi dari ketiga model tersebut untuk mendapatkan model terbaik yang akan

digunakan untuk peramalan jangka pendek pada beban listrik di PT. Indonesia Power UP Bali.

### **1.3 Tujuan**

Tujuan yang akan dibahas pada penelitian ini berdasarkan rumusan masalah yang telah diuraikan sebagai berikut:

1. Memperoleh model ARIMAX, *Deep Learning* Neural Network serta Hibrida ARIMAX dan *Deep Learning* Neural Network untuk peramalan jangka pendek beban listrik di PT. Indonesia Power UP Bali.
2. Memperoleh akurasi model ARIMAX, *Deep Learning* Neural Network serta Hibrida ARIMAX dan *Deep Learning* Neural Network untuk peramalan jangka pendek beban listrik di PT. Indonesia Power UP Bali.

### **1.4 Manfaat**

Penelitian ini diharapkan dapat memberikan beberapa manfaat dari berbagai pihak, diantaranya sebagai berikut:

1. Memberikan informasi kepada PT. Indonesia Power UP Bali yang dapat digunakan sebagai pertimbangan dalam melakukan pembangkitan energi listrik.
2. Memberikan tambahan keilmuan statistika terkait model ARIMAX, *Deep Learning* Neural Network serta Hibrida ARIMAX dan *Deep Learning* Neural Network.

### **1.5 Batasan Masalah**

Batasan yang digunakan dalam penelitian ini adalah data beban listrik per setengah jam PT. Indonesia Power UP Bali yaitu pada periode Januari 2014 hingga Desember 2017. Pemodelan yang digunakan untuk peramalan jangka pendek beban listrik adalah model ARIMAX, *Deep Learning* Neural Network serta Hibrida ARIMAX dan *Deep Learning* Neural Network.

*(Halaman ini sengaja dikosongkan)*

## BAB II

### TINJAUAN PUSTAKA

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

Model ARIMA adalah gabungan model AR dan MA dengan *differencing* orde  $d$ . Model ARIMA dapat digunakan pada data yang berpola musiman dan non musiman. Model ARIMA harus memenuhi syarat yaitu stasioner dalam *mean* dan varians (Wei, 2006). Bentuk umum dari model ARIMA  $(p,d,q)$  adalah

$$\phi_p(B)(1-B)^d Y_t = \theta_0 + \theta_q(B)a_t \quad (2.1)$$

dengan

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

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

$d$  = order *differencing*.

Sedangkan model ARIMA musiman sebagai berikut:

$$\Phi_P(B^s)(1-B^s)^D Y_t = \Theta_Q(B^s)a_t \quad (2.2)$$

dengan  $(P,D,Q)$  merupakan orde AR ( $P$ ), orde *differencing* ( $D$ ) dan orde MA ( $Q$ ) untuk pola musiman. AR dengan musiman  $s$  derajat ( $P$ ) dinotasikan sebagai berikut  $\Phi_P(B^s) = 1 - \Phi_1 B^s - \Phi_2 B^{2s} - \dots - \Phi_P B^{Ps}$ , dan MA dengan musiman  $s$  derajat ( $Q$ ) dinotasikan  $\Theta_Q(B^s) = 1 - \Theta_1 B^s - \Theta_2 B^{2s} - \dots - \Theta_Q B^{Qs}$  serta  $a_t$  merupakan nilai residual pada waktu ke- $t$  yang sudah memenuhi asumsi *white noise*. Jika terdapat efek musiman dan non musiman, model yang terbentuk model multiplikatif ARIMA  $(p,d,q)(P,D,Q)^s$  dengan bentuk umumnya sebagai berikut:

$$\Phi_p(B^s)\phi_p(B)(1-B)^d(1-B^s)^D Y_t = \theta_q(B)\Theta_Q(B^s)a_t. \quad (2.3)$$

Langkah analisis deret waktu dengan menggunakan metode ARIMA pada data beban pembangkit listrik per setengah jam adalah dengan identifikasi model ARIMA, estimasi parameter, uji diagnostik, pemilihan model terbaik serta dilakukan peramalan dengan menggunakan model ARIMA.

## 2.2 Estimasi Parameter

Estimasi parameter dilakukan untuk memperoleh nilai dari setiap parameter pada model ARIMA. Salah satu metode estimasi parameter yang dapat digunakan adalah *Conditional Least Square*. Metode *Conditional Least Square* bekerja dengan membuat *error* yang tidak diketahui sama dengan nol dan meminimumkan jumlah kuadrat *error* (SSE). Berikut merupakan metode *Conditional Least Square* untuk model *Autoregressive* (AR):

$$\begin{aligned} Y_t - \mu &= \phi(Y_{t-1} - \mu) + a_t \\ a_t &= (Y_t - \mu) - \phi(Y_{t-1} - \mu) \end{aligned} \quad (2.4)$$

Dengan  $Y_1, Y_2, \dots, Y_n$  observasi, dapat dijumlahkan dari  $t = 2$  hingga  $t = n$  sehingga fungsi *Conditional Least Square* sebagai berikut:

$$S_c(\phi, \mu) = \sum_{t=2}^n \left[ (Y_t - \mu) - \phi(Y_{t-1} - \mu) \right]^2 \quad (2.5)$$

Dilakukan estimasi  $\phi$  dan  $\mu$  dari masing-masing nilai yang meminimumkan  $S_c(\phi, \mu)$  dari nilai observasi  $Y_1, Y_2, \dots, Y_n$ .

Didapatkan

$$\frac{\partial S_c}{\partial \mu} = \sum_{t=2}^n 2 \left[ (Y_t - \mu) - \phi(Y_{t-1} - \mu) \right] (-1 + \phi) = 0 \quad (2.6)$$

Sehingga solusi untuk  $\mu$  sebagai berikut:

$$\mu = \frac{1}{(n-1)(1-\phi)} \left[ \sum_{t=2}^n Y_t - \phi \sum_{t=2}^n Y_{t-1} \right] \quad (2.7)$$

Untuk  $n$  besar sebagai berikut:

$$\frac{1}{(n-1)} \sum_{t=2}^n Y_t \approx \frac{1}{(n-1)} \sum_{t=2}^n Y_{t-1} \approx \bar{Y} \quad (2.8)$$

Tanpa memperhatikan nilai  $\phi$ , persamaan sebelumnya tereduksi



menjadi

$$\mu \approx \frac{1}{1-\phi} (\bar{Y} - \phi \bar{Y}) = \bar{Y} \quad (2.9)$$

Hasil dari meminimumkan  $S_c(\phi, \mu)$  berdasarkan  $\phi$  sebagai berikut:

$$\frac{\partial S_c(\phi, \bar{Y})}{\partial \phi} = \sum_{t=2}^n 2 \left[ (Y_t - \bar{Y}) - \phi (Y_{t-1} - \bar{Y}) \right] (Y_{t-1} - \bar{Y}) \quad (2.10)$$

Sehingga solusi untuk  $\phi$  sebagai berikut:

$$\hat{\phi} = \frac{\sum_{t=2}^n (Y_t - \bar{Y})(Y_{t-1} - \bar{Y})}{\sum_{t=2}^n (Y_{t-1} - \bar{Y})^2} \quad (2.11)$$

Selanjutnya merupakan metode *Conditional Least Square* untuk model *Moving Average* (MA) dimana

$$Y_t = a_t - \theta a_{t-1} \quad (2.12)$$

Model MA(1) dapat dituliskan sebagai berikut:

$$Y_t = -\theta Y_{t-1} - \theta^2 Y_{t-2} - \theta^3 Y_{t-3} - \dots + a_t \quad (2.13)$$

*Conditional Least Square* dapat diaplikasikan dengan pemilihan nilai  $\theta$  yang meminimumkan

$$S_c(\theta) = \sum (a_t)^2 = \sum \left[ Y_t + \theta Y_{t-1} + \theta^2 Y_{t-2} + \theta^3 Y_{t-3} + \dots \right]^2 \quad (2.14)$$

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

Setelah melakukan perhitungan estimasi parameter dilakukan uji signifikansi parameter. Uji ini digunakan untuk mengetahui apakah parameter AR ( $p$ ) dan MA ( $q$ ) signifikan atau tidak. Jika parameter-parameter tersebut signifikan maka model

layak digunakan.

Uji Signifikansi parameter  $\phi$

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

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

Statistik uji yang digunakan adalah

$$t_{hitung} = \frac{\hat{\phi}_p}{SE(\hat{\phi}_p)} \quad (2.15)$$

Daerah penolakan : Tolak  $H_0$  jika  $|t_{hitung}| > t_{\alpha/2-n-1}$  atau  $P\text{-value} < \alpha$  Dimana  $n$  menunjukkan banyaknya data.

Uji Signifikansi parameter  $\theta$

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

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

Statistik uji yang digunakan adalah

$$t_{hitung} = \frac{\hat{\theta}_q}{SE(\hat{\theta}_q)} \quad (2.16)$$

Daerah penolakan : Tolak  $H_0$  jika  $|t_{hitung}| > t_{\alpha/2-n-1}$  atau  $P\text{-value} < \alpha$ . Dimana  $n$  menunjukkan banyaknya data.

### 2.3 Uji Diagnostik

Dalam menentukan model ARIMA yang terbaik, harus dipilih model yang seluruh parameternya signifikan, kemudian memenuhi 2 asumsi residual yaitu berdistribusi normal dan *white noise*.

#### 1. Uji Asumsi Residual Berdistribusi Normal

Salah satu asumsi yang harus dipenuhi adalah residual berdistribusi normal. Pengujian distribusi normal dapat dilakukan dengan menggunakan uji *Kolmogorov-Smirnov* (Daniel, 2000).

Hipotesis :

$H_0 : F(x) = F_0(x)$  Residual berdistribusi normal

$H_1 : F(x) \neq F_0(x)$  Residual tidak berdistribusi normal

Statistik uji :

$$D_{hit} = \sup_x |F(x) - F_0(x)| \quad (2.17)$$

Kriteria pengujian :

Jika  $D_{hit} > D_{(1-\alpha),n}$  atau  $P\text{-value} < \alpha$  maka  $H_0$  ditolak.

Dengan :

$F_0(x)$  = Fungsi yang dihipotesiskan yaitu berdistribusi normal

$F(x)$  = Fungsi distribusi kumulatif dari data asal

$n$  = Banyaknya residual

$D_{(1-\alpha),n}$  didapatkan dari Tabel *Kolmogorov-Smirnov*

## 2. Uji Asumsi Residual *White Noise*

Suatu model bersifat *white noise* artinya residual dari model tersebut telah memenuhi asumsi identik (variasi residual homogen) serta independen (antar residual tidak berkorelasi). Pengujian asumsi *white noise* dilakukan dengan menggunakan uji *Ljung-Box* dengan hipotesis sebagai berikut (Wei, 2006).

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

$H_1$  : Minimal ada satu  $\rho_k$  yang tidak sama dengan nol,  $k = 1, 2, \dots, K$

Statistik Uji :

$$Q = n(n+2) \sum_{k=1}^K (n-k)^{-1} \hat{\rho}_k^2 \quad (2.18)$$

Daerah penolakan :  $Q > X^2_{(\alpha; K-p-q)}$  atau  $P\text{-value} < \alpha$

Dengan :

$K$  = lag maksimum

$n$  = jumlah data (observasi)

$k$  = lag ke- $k$

p dan q = order dari ARMA(p,q)

$\rho_k$  = autokorelasi residual untuk lag ke-k

#### 2.4 *Autoregressive Integrated Moving Average with Exogeneous Variable (ARIMAX)*

Model ARIMAX merupakan modifikasi dari model ARIMA dengan penambahan variabel. Terdapat dua jenis penambahan variabel yaitu penambahan variabel *dummy* hanya untuk efek dari variasi kalender dan variabel *dummy* untuk efek variasi kalender dan tren deterministik. Model pertama merupakan model ARIMAX dengan tren stokastik dengan mengimplementasikan *difference non seasonal* atau *seasonal* dan model kedua merupakan model ARIMAX dengan tren deterministik yaitu tanpa order *differencing*. Model ARIMAX dengan tren stokastik sebagai berikut (Lee, Suhartono, & Hamzah, 2010).

$$Y_t = \beta_1 V_{1,t} + \beta_2 V_{2,t} + \dots + \beta_p V_{p,t} + \frac{\theta_q(B)\Theta_Q(B^S)}{\phi_p(B)\Phi_P(B^S)(1-B)^d(1-B^S)^D} a_t \quad (2.19)$$

Model ARIMAX dengan tren deterministik sebagai berikut.

$$Y_t = \gamma t + \beta_1 V_{1,t} + \beta_2 V_{2,t} + \dots + \beta_p V_{p,t} + \frac{\theta_q(B)\Theta_Q(B^S)}{\phi_p(B)\Phi_P(B^S)^D} a_t \quad (2.20)$$

dengan

$V_{p,t}$  = Variabel *dummy* ke p

$\beta$  = Koefisien parameter variabel *dummy*

$a_t$  = Residual pada waktu ke-t dari proses ARIMAX

Variabel prediktor yang digunakan pemodelan ARIMAX adalah variabel *dummy* tren, musiman serta variasi kalender. Untuk variabel *dummy* tren digunakan kenaikan penggunaan daya listrik. Variabel *dummy* musiman adalah beban listrik harian dan per setengah jam serta variabel *dummy* untuk variasi kalender adalah hari raya Idul Fitri dan hari raya Nyepi. Berikut merupakan rumus umum dari model ARIMAX untuk beban listrik per setengah jam.

$$Y_t = \alpha t + \sum_{i=1}^7 \beta_i H_{i,t} + \sum_{k=1}^r \gamma_k I_{k,t} + N_t \quad (2.21)$$

dengan 
$$N_t = \frac{\theta_q(B)\Theta_Q(B^S)}{\phi_p(B)\Phi_P(B^S)(1-B)^d(1-B^S)^D} a_t$$

dan

$t$  = Variabel *dummy* tren

$H_{1,t}, H_{2,t}, \dots, H_{7,t}$  = Variabel *dummy* hari

$I_{1,t}, I_{2,t}, \dots, I_{r,t}$  = Variabel *dummy* untuk variasi kalender

## 2.5 Pengujian Linieritas

Salah satu cara untuk menguji linear atau tidaknya suatu data dapat digunakan dengan uji White. Uji White adalah uji deteksi non-linearitas yang dikembangkan dari model neural network yang ditemukan oleh White pada tahun 1989. Uji White memiliki persamaan sebagai berikut:

$$Y_t = \beta_0 + \beta_1 Y_{t-1} + \dots + \beta_p Y_{t-p} + a_t \quad (\text{komponen linier}) \quad (2.22)$$

$$Y_t = \beta_0 + \beta_1 Y_{t-1} + \dots + \beta_p Y_{t-p} + \theta_1 f(Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}) + \theta_2 f(Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}) + a_t$$

(komponen nonlinier) (2.23)

$$Y_t = \beta_0 + \beta_1 Y_{t-1} + \dots + \beta_p Y_{t-p} + \theta_1 x_{1t}^* + \theta_2 x_{2t}^* + a_t \quad (2.24)$$

dengan  $x_{1t}^*$  dan  $x_{2t}^*$  adalah komponen nonlinier pada uji white yang diturunkan dari model *Neural Network*.

Hipotesis:

$$H_0 : \theta_1 = \theta_2 = 0 \quad (\text{Hubungan linear})$$

$H_1$  : minimal terdapat satu  $\theta_i \neq 0$ ,  $i = 1, 2$  ( Hubungan tidak linear)

Berikut merupakan langkah-langkah dari pengujian White:

1. Meregresikan  $Y_t$  pada  $Y_{t-1}, Y_{t-2}, \dots$  dan menghitung

$$\text{residual } \hat{u}_t \text{ dan menghitung } \text{sum square residual } SSR_0 = \sum_{t=1}^n \hat{u}_t^2$$

2. Meregresikan  $\hat{u}_t$  pada  $Y_{t-1}, Y_{t-2}, \dots$  dan 2 prediktor tambahan dan menghitung *residual*  $\hat{v}_t$  dan *sum square residual*

$$SSR_1 = \sum_{t=1}^n \hat{v}_t^2$$


3. Menghitung  $F_{hitung} = \frac{(SSR_0 - SSR_1) / 2}{SSR_1 / (n - p - 1 - 2)}$ ,

dengan  $n$  adalah jumlah pengamatan yang digunakan.

Tolak  $H_0$  apabila  $F > F_{(\alpha; 2, (n-p-1-2))}$  atau  $P\text{-value} < \alpha$ .

## 2.6 Neural Network

Neural Network terdiri atas neuron-neuron yang saling berhubungan, dimana input dari setiap neuron terdiri atas bobot output dari neuron-neuron lainnya. Hubungan ini menyebabkan terjadinya pertukaran data atau informasi diantara neuron-neuron. Pada *Feedforward* Neural Network neuron-neuron saling berhubungan dalam suatu *layer*, sehingga data berjalan hanya pada satu jalur. *Layer* pertama pada Neural Network disebut *input layer*, dan *layer* terakhir disebut *output layer*. *Layer-layer* yang berada diantara *input layer* dan *output layer* dinamakan *hidden layer*. Setiap neuron akan menerima informasi hanya dari neuron pada *layer* sebelumnya dimana input dari neuron tersebut berasal dari bobot output neuron pada *layer* sebelumnya. Berikut merupakan arsitektur dari Neural Network (Chong & Zak, 2001):



**Gambar 2.1** Arsitektur Neural Network

Dalam arsitektur ini, nilai respon atau output  $Y_{(t)}$  dihitung dengan rumus sebagai berikut:

$$\hat{Y}_{(t)} = f^0 \left( b_0^0 + \sum_{i=1}^p w_i^0 f_i^h \left( b_i^1 + \sum_{j=1}^q w_{ji}^1 Z_{j(t)} \right) \right) \quad (2.25)$$

dengan

$\hat{Y}_{(t)}$  = Nilai dugaan dari variabel output

$f^0$  = Fungsi aktivasi pada neuron di lapisan output

$b_0^0$  = Bias pada neuron di lapisan output

$w_i^0$  = Bobot dari neuron ke- $i$  pada *hidden layer* yang menuju neuron pada *output layer*

$f_i^h$  = Fungsi aktivasi di neuron ke- $i$  pada *hidden layer*

$b_i^1$  = Bias pada neuron ke- $i$  pada *hidden layer* ( $i = 1, 2, \dots, p$ )

$w_{ji}^1$  = Bobot dari input ke- $j$  menuju neuron ke- $i$  pada *hidden layer* ( $i = 1, 2, \dots, p$ )

$Z_{j(t)}$  = Variabel input sebanyak  $q$  ( $j = 1, 2, \dots, q$ )

$t$  = Indeks pasangan data input-target ( $Z_{j(t)}, \hat{Y}_{(t)}$ ),  $t = 1, 2, \dots, n$

$v_{i(t)}$  digunakan untuk menyatakan suatu vektor nilai-nilai setelah proses penjumlahan *input* dan bobot pada *hidden layer* di neuron ke- $i$  untuk data ke  $t$ ,

$$v_{i(t)} = b_i^1 + \sum_{j=1}^q w_{ji}^1 Z_{j(t)} \quad (2.26)$$

dan  $a_{i(t)}$  digunakan untuk output pada *hidden layer* di neuron ke- $i$ ,

$$a_{i(t)} = f_i^h \left( b_i^1 + \sum_{j=1}^q w_{ji}^1 Z_{j(t)} \right). \quad (2.27)$$

Menggunakan cara yang sama, notasi dari penjumlahan input dan bobot-bobot pada *output layer* sebagai berikut:

$$v_{0(t)} = b_0^0 + \sum_{i=1}^p w_i^0 a_{i(t)} \quad (2.28)$$

$$Y_{(t)} = f^0 \left( v_{0(t)} \right) \quad (2.29)$$

Sehingga hubungan antara input  $Z_{j(t)}$ ,  $j = 1, 2, \dots, q$  dengan output  $\hat{Y}_{(t)}$  sebagai berikut:

$$\begin{aligned} \hat{Y}_{(t)} &= f^0 \left( b_0^0 + \sum_{i=1}^p w_i^0 f_i^h \left( v_{i(t)} \right) \right) \\ &= f^0 \left( b_0^0 + \sum_{i=1}^p w_i^0 f_i^h \left( b_i^1 + \sum_{j=1}^q w_{ji}^1 Z_{j(t)} \right) \right) \\ &= \mathbf{F} \left( Z_{1(t)}, Z_{2(t)}, \dots, Z_{q(t)} \right). \end{aligned} \quad (2.30)$$

Keseluruhan pemetaan pada Neural Network sebagai berikut:



$$\begin{bmatrix} \hat{Y}_{(1)} \\ \hat{Y}_{(2)} \\ \vdots \\ \hat{Y}_{(n)} \end{bmatrix} = \begin{bmatrix} F_1(Z_{1(1)}, Z_{2(1)}, \dots) \\ F_2(Z_{1(2)}, Z_{2(2)}, \dots) \\ \vdots \\ F_n(Z_{1(n)}, Z_{2(n)}, \dots) \end{bmatrix}. \quad (2.31)$$

Fungsi sigmoid digunakan sebagai salah satu fungsi aktivasi yang didefinisikan melalui suatu fungsi logistik. Fungsi aktivasi harus memiliki beberapa syarat yaitu kontinu, dapat diturunkan atau *differentiable* dan merupakan fungsi yang tidak turun (Kajitani, 1999). Fungsi sigmoid juga merupakan fungsi yang mudah dalam melakukan *training* Neural Network dengan nilai fungsi terletak pada 0 sampai 1. Persamaan fungsi sigmoid sebagai berikut:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2.32)$$

Selain fungsi sigmoid terdapat pula fungsi bipolar sigmoid, *Hyperbolic Tangent Function*, *Radial Basis Function* (RBF) serta *Conic Section Function*. Namun, untuk fungsi aktivasi pada Neural Network biasanya RBF serta *Conic Section* memiliki akurasi yang cukup rendah. Jadi fungsi aktivasi yang lebih cocok digunakan pada Neural Network adalah fungsi sigmoid, fungsi bipolar sigmoid serta *Hyperbolic Tangent Function*. Berikut merupakan persamaan dari fungsi bipolar sigmoid:

$$f(x) = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (2.33)$$

Fungsi bipolar sigmoid hampir sama dengan fungsi sigmoid, namun nilai fungsi terletak pada -1 sampai 1. Sedangkan persamaan untuk *Hyperbolic Tangent Function* sebagai berikut:

$$f(x) = \frac{\sinh(x)}{\cosh(x)} = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.34)$$

Dari kelima fungsi aktivasi yang ada, *Hyperbolic Tangent Function* memiliki sifat yang mirip dengan fungsi sigmoid dan

nilai fungsi terletak pada -1 sampai 1. Namun, *Hyperbolic Tangent Function* memiliki akurasi yang paling tinggi saat digunakan untuk melakukan *training* pada Neural Network (Karlik & Olgac, 2011). Selain fungsi nonlinier terdapat fungsi aktivasi pada Neural Network yang bersifat linier dimana nilai output sama dengan nilai inputnya (Puspitorini, 2009). Berikut merupakan persamaan fungsi aktivasi linier:

$$f(x) = x \quad (2.35)$$

## 2.7 Algoritma *Backpropagation*

Algoritma yang paling sering digunakan dalam melakukan *training* Neural Network adalah algoritma *Backpropagation*, khususnya *perceptron* untuk mengubah bobot-bobot yang terhubung dengan neuron-neuron pada *hidden layer* yang memiliki banyak lapisan (Chong & Zak, 2001). Dalam melakukan *training* Neural Network dengan penentuan bobot

misal diberikan  $Z_d = [Z_{d_1}, \dots]$ . Untuk memperoleh bobot digunakan formula dengan meminimumkan:

$$\frac{1}{2} \sum_{t=1}^n (Z_{d(t)} - \hat{Y}_{(t)})^2 \quad (2.36)$$

Dimana  $\hat{Y}_{(t)}$  merupakan output dari Neural Network pada respon dengan input  $Z_{d_1}, \dots$  sebagai berikut:

$$\hat{Y}_{(t)} = f^0 \left( b_0^0 + \sum_{i=1}^p w_i^0 f_i^h \left( b_i^1 + \sum_{j=1}^q w_{ji}^1 Z_{j(t)} \right) \right) \quad (2.37)$$

Persamaan (2.16) digunakan untuk mendapatkan nilai  $w_{ji}^1$  dan  $w_i^0$ . Untuk memudahkan notasi digunakan simbol  $\mathbf{w}$  untuk vektor, yaitu:

$$\mathbf{w} = \{w_{ji}^1, w_i^0 : i = 1, 2, \dots, p, j = 1, 2, \dots, q, t = 1, 2, \dots, n\} \quad (2.38)$$

Simbol  $E$  digunakan sebagai fungsi objektif untuk meminimumkan

$$\begin{aligned}
E(\mathbf{w}) &= \frac{1}{2} \sum_{t=1}^n (Z_{d(t)} - \hat{Y}_{(t)})^2 \\
&= \frac{1}{2} \sum_{t=1}^n \left( Z_{d(t)} - f^0 \left( b_0^0 + \sum_{i=1}^p w_i^0 f_i^h \left( b_i^1 + \sum_{j=1}^q w_{ji}^1 Z_{j(t)} \right) \right) \right)^2 \quad (2.39)
\end{aligned}$$

Untuk menyelesaikan masalah optimasi diatas, digunakan algoritma *gradient* dengan ukuran langkah yang tetap. Untuk memformulasikan algoritma, perlu dilakukan perhitungan *partial derivatives* dari  $E$  dengan melibatkan setiap komponen pada  $\mathbf{w}$ . Pertama, dilakukan perhitungan *partial derivatives* dari  $E$  dengan melibatkan  $w_i^0$ . Persamaannya dituliskan sebagai berikut:

$$E(\mathbf{w}) = \frac{1}{2} \sum_{t=1}^n \left( Z_{d(t)} - f^0 \left( b_0^0 + \sum_{i=1}^p w_i^0 a_{i(t)} \right) \right)^2 \quad (2.40)$$

dengan  $i = 1, 2, \dots, p$ , dan

$$a_{i(t)} = f_i^h \left( b_i^1 + \sum_{j=1}^q w_{ji}^1 Z_{j(t)} \right) \quad (2.41)$$

Dengan menggunakan aturan rantai pada perhitungan turunan parsial, diperoleh

$$\frac{\partial E(\mathbf{w})}{\partial w_i^0} = \frac{\partial E(\mathbf{w})}{\partial \hat{Y}_{(t)}} \frac{\partial \hat{Y}_{(t)}}{\partial v_{0(t)}} \frac{\partial v_{0(t)}}{\partial w_i^0} \quad (2.42)$$

Menggunakan aturan rantai, didapatkan

$$\frac{\partial E}{\partial w_i^0}(\mathbf{w}) = - \sum_{t=1}^n (Z_{d(t)} - \hat{Y}_{(t)}) f^0 \left( b_0^0 + \sum_{i=1}^p w_i^0 a_{i(t)} \right) a_{i(t)}, \quad (2.43)$$

dengan  $f^0$  merupakan derivatif dari  $f^0$ . Untuk menyederhanakan notasi, ditulis sebagai berikut:

$$\delta_i = - \left( Z_{d(t)} - \hat{Y}_{(t)} \right) f^0 \left( b_0^0 + \sum_{i=1}^p w_i^0 a_{i(t)} \right). \quad (2.44)$$

Setiap  $\delta_t$  dianggap sebagai skala pada *output error*, karena merupakan perbedaan diantara output sebenarnya  $\hat{Y}_{(t)}$  pada Neural Network dan output yang diinginkan  $Z_{d(t)}$ , skala yang digunakan  $f^{0'} \left( b_0^0 + \sum_{i=1}^p w_i^0 a_{i(t)} \right)$ . Dengan menggunakan notasi  $\delta_{(t)}$  didapatkan

$$\frac{\partial E}{\partial \phi_i^0}(\mathbf{w}) = -\sum_{t=1}^n \delta_{(t)} a_{i(t)}. \quad (2.45)$$

Selanjutnya dilakukan perhitungan *partial derivatives* dari  $E$  dengan melibatkan  $w_{ji}^1$ . Persamaannya dituliskan sebagai berikut:

$$E(\mathbf{w}) = \frac{1}{2} \sum_{t=1}^n \left( Z_{d(t)} - f^0 \left( b_0^0 + \sum_{i=1}^p w_i^0 f_i^h \left( b_i^1 + \sum_{j=1}^q w_{ji}^1 Z_{j(t)} \right) \right) \right)^2. \quad (2.46)$$

Dengan menggunakan aturan rantai pada perhitungan turunan parsial, diperoleh

$$\frac{\partial E(\mathbf{w})}{\partial w_{ji}^1} = \frac{\partial E(\mathbf{w})}{\partial \hat{Y}_{(t)}} \frac{\partial \hat{Y}_{(t)}}{\partial v_{0(t)}} \frac{\partial v_{0(t)}}{\partial a_{i(t)}} \frac{\partial a_{i(t)}}{\partial v_{i(t)}} \frac{\partial v_{i(t)}}{\partial w_{ji}^1}. \quad (2.47)$$

Menggunakan aturan rantai, didapatkan

$$\frac{\partial E}{\partial w_{ji}^1}(\mathbf{w}) = -\sum_{t=1}^n (Z_{d(t)} - \hat{Y}_{(t)}) f^{0'} \left( b_0^0 + \sum_{i=1}^p w_i^0 a_{i(t)} \right) w_i^0 f_i^{h'} \left( b_i^1 + \sum_{j=1}^q w_{ji}^1 Z_{j(t)} \right) Z_{j(t)} \quad (2.48)$$

dengan  $f_{hi}^1$  merupakan derivatif dari  $f_{hi}^1$ . Untuk menyederhanakan notasi, ditulis sebagai berikut:

$$\frac{\partial E}{\partial w_{ji}^1}(\mathbf{w}) = -\left( \sum_{t=1}^n \delta_{(t)} w_i^0 \right) f_i^{h'}(v_{i(t)}) Z_{j(t)}$$

$$\text{dimana } \delta_t^{[1]} = -\left( \delta_{(t)} w_i^0 \right) f_i^{h'}(v_{i(t)}) \quad (2.49)$$

$$\frac{\partial E}{\partial w_{ji}^1}(\mathbf{w}) = -\sum_{t=1}^n \delta_{(t)}^{[1]} Z_{j(t)} \quad (2.50)$$

Selanjutnya bisa memformulasikan algoritma *gradient* untuk memperbarui bobot pada Neural Network. Berikut dituliskan *equations* dari dua bobot  $w_i^0$ ,  $b_0^0$ ,  $w_{ji}^1$  dan  $b_i^1$  secara terpisah, yaitu:

$$w_i^{0(s+1)} = w_i^{0(s)} + \eta \sum_{t=1}^n \delta_{(t)}^{(s)} a_{i(t)}^{(s)} \quad (2.51)$$

$$b_0^{0(s+1)} = b_0^{0(s)} + \eta \sum_{t=1}^n \delta_{(t)}^{(s)} \quad (2.52)$$


$$w_{ji}^{1(s+1)} = w_{ji}^{1(s)} + \eta \left( \sum_{t=1}^n \delta_{(t)}^{(s)} w_i^{0(s)} \right) f_i^h \left( v_{i(t)}^{(s)} \right) Z_{j(t)} \quad (2.53)$$

$$w_{ji}^{1(s+1)} = w_{ji}^{1(s)} + \eta \sum_{t=1}^n \delta_{(t)}^{[1](s)} Z_{j(t)} \quad (2.54)$$

$$b_i^{1(s+1)} = b_i^{1(s)} + \eta \sum_{t=1}^n \delta_{(t)}^{[1](s)}. \quad (2.55)$$

## 2.8 Deep Learning Neural Network

Neural Network mencoba mereplikasi fungsi otak manusia dan memiliki kemampuan untuk mempelajari data nonlinier dengan struktur data yang kompleks (Din & Marnerides, 2017). Sampai saat ini Neural Network sebagian besar hanya terbatas pada satu *hidden layer* saja, *Deep Neural Network* (DNN) memiliki lebih dari satu *hidden layer* pada suatu fungsi. Dengan menggunakan banyak lapisan layer pada fungsi nonlinier dapat memodelkan fungsi yang rumit dengan lebih efisien (Dalto, Matusko, & Vasak, 2015). Berikut merupakan arsitektur dari *Deep Learning Neural Network*:



**Gambar 2.2** Arsitektur *Deep Learning* Neural Network

Dalam arsitektur ini, nilai respon atau output  $Y_{(t)}$  dihitung dengan rumus sebagai berikut:

$$\hat{Y}_{(t)} = f^0 \left( b_0^0 + \sum_{i=1}^p w_i^0 f_i^{h_2} \left( b_i^2 + \sum_{j=1}^q w_{ji}^2 f_j^{h_1} \left( b_j^1 + \sum_{k=1}^r w_{kj}^1 Z_{k(t)} \right) \right) \right) \quad (2.56)$$

dengan

$\hat{Y}_{(t)}$  = Nilai dugaan dari variabel output

$f^0$  = Fungsi aktivasi pada neuron di lapisan output

$b_0^0$  = Bias pada neuron di lapisan output

$w_i^0$  = Bobot dari neuron ke- $i$  pada *hidden layer* yang menuju neuron pada *output layer*

$f_i^{h_2}$  = Fungsi aktivasi di neuron ke- $i$  pada *hidden layer*

$f_j^{h_1}$  = Fungsi aktivasi di neuron ke- $j$  pada *hidden layer*

$b_i^2$  = Bias pada neuron ke- $i$  pada *hidden layer* ( $i = 1, 2, \dots, p$ )

$b_j^1$  = Bias pada neuron ke- $j$  pada *hidden layer* ( $j = 1, 2, \dots, q$ )

$w_{ji}^2$  = Bobot dari *input* ke- $j$  menuju neuron ke- $i$  pada *hidden layer* ( $i = 1, 2, \dots, p$ )

$w_{kj}^1$  = Bobot dari *input* ke- $k$  menuju neuron ke- $j$  pada *hidden layer* ( $j = 1, 2, \dots, q$ )

$Z_{k(t)}$  = Variabel *input* sebanyak  $r$  ( $k = 1, 2, \dots, r$ )

$t$  = Indeks pasangan data input-target ( $Z_{k(t)}, \hat{Y}_{(t)}$ ),  $t = 1, 2, \dots, n$

$v_{j(t)}$  digunakan untuk menyatakan suatu vektor nilai-nilai setelah proses penjumlahan input dan bobot pada *hidden layer* di neuron ke- $j$  untuk data ke  $t$ ,

$$v_{j(t)} = b_j^1 + \sum_{k=1}^r w_{kj}^1 Z_{k(t)} \quad (2.57)$$

dan  $a_{j(t)}$  digunakan untuk output pada *hidden layer* di neuron ke- $j$ ,

$$a_{j(t)} = f_j^{h_1} \left( b_j^1 + \sum_{k=1}^r w_{kj}^1 Z_{k(t)} \right). \quad (2.58)$$

$v_{i(t)}$  digunakan untuk menyatakan suatu vektor nilai-nilai setelah proses penjumlahan input dan bobot pada *hidden layer* di neuron ke- $i$  untuk data ke  $t$ ,

$$v_{i(t)} = b_i^2 + \sum_{j=1}^q w_{ji}^2 a_{j(t)} \quad (2.59)$$

dan  $a_i$  digunakan untuk output pada *hidden layer* di neuron ke- $i$ ,

$$a_{i(t)} = f_i^{h_2} \left( v_{i(t)} \right). \quad (2.60)$$

Menggunakan cara yang sama, notasi dari penjumlahan input dan bobot-bobot pada *output layer* sebagai berikut:

$$v_{0(t)} = b_0^0 + \sum_{i=1}^p w_i^0 a_{i(t)} \quad (2.61)$$

$$\hat{Y}_{(t)} = f^0(v_{0(t)}). \quad (2.62)$$

Sehingga hubungan antara input  $Z_k$ ,  $k = 1, 2, \dots, r$  dengan output  $\hat{Y}_{(t)}$  sebagai berikut:

$$\begin{aligned} \hat{Y}_{(t)} &= f^0 \left( b_0^0 + \sum_{i=1}^p w_i^0 f_i^{h_2}(v_{i(t)}) \right) \\ &= f^0 \left( b_0^0 + \sum_{i=1}^p w_i^0 f_i^{h_2} \left( b_i^2 + \sum_{j=1}^q w_{ji}^2 f_j^{h_1} \left( b_j^1 + \sum_{k=1}^r w_{kj}^1 Z_{k(t)} \right) \right) \right) \\ &= \mathbf{F} \left( Z_{1(t)}, Z_{2(t)}, \dots, Z_{r(t)} \right) \end{aligned} \quad (2.63)$$

Keseluruhan pemetaan pada Neural Network sebagai berikut:

$$\begin{bmatrix} \hat{Y}_{(1)} \\ \hat{Y}_{(2)} \\ \vdots \\ \hat{Y}_{(n)} \end{bmatrix} = \begin{bmatrix} F_1(Z_{1(1)}, Z_{2(1)}, \dots) \\ F_2(Z_{1(2)}, Z_{2(2)}, \dots) \\ \vdots \\ F_n(Z_{1(n)}, Z_{2(n)}, \dots) \end{bmatrix} \quad (2.64)$$

Dengan cara yang sama dengan algoritma *Backpropagation* pada Neural Network berikut merupakan formula dari algoritma *gradient* untuk memperbarui bobot pada *Deep Learning* Neural Network. Tiga persamaan perbaruan untuk bobot  $b_0^0$ ,  $w_i^0$ ,  $b_i^2$ ,  $w_{ji}^2$ ,  $b_j^1$  dan  $w_{kj}^1$  akan diberikan secara terpisah, yaitu

a. Untuk perbaruan bobot dan bias pada lapisan output :

$$w_i^{0(s+1)} = w_i^{0(s)} + \eta \sum_{t=1}^n \delta_{(t)}^{(s)} a_{i(t)}^{(s)} \quad (2.65)$$

$$b_0^{0(s+1)} = b_0^{0(s)} + \eta \sum_{t=1}^n \delta_{(t)}^{(s)} \quad (2.66)$$

dengan



$$\delta_{(t)} = \left( Z_{d(t)} - \hat{Y}_{(t)} \right) f^{0'} \left( b_0^0 + \sum_{i=1}^p w_i^0 a_{i(t)} \right) \quad (2.67)$$

b. Untuk perbaruan bobot dan bias pada *hidden layer* 2 :

$$w_{ji}^{2(s+1)} = w_{ji}^{2(s)} + \eta \sum_{t=1}^n \delta_{(t)}^{[2](s)} a_{j(t)}^{(s)} \quad (2.68)$$

$$b_i^{2(s+1)} = b_i^{2(s)} + \eta \sum_{t=1}^n \delta_{(t)}^{[2](s)} \quad (2.69)$$

dengan

$$\delta_{(t)}^{[2]} = \delta_{(t)} w_i^0 f_i^{h_2'} \left( b_i^2 + \sum_{j=1}^q w_{ji}^2 a_{j(t)} \right) \quad (2.70)$$

c. Untuk perbaruan bobot dan bias pada *hidden layer* 1 :

$$w_{kj}^{1(s+1)} = w_{kj}^{1(s)} + \eta \sum_{t=1}^n \delta_{(t)}^{[1](s)} Z_{k(t)} \quad (2.71)$$

$$b_j^{1(s+1)} = b_j^{1(s)} + \eta \sum_{t=1}^n \delta_{(t)}^{[1](s)} \quad (2.72)$$

dengan

$$\delta_{(t)}^{[1]} = \delta_{(t)} \delta_{(t)}^{[2]} w_{ji}^2 f_j^{h_1'} \left( b_j^1 + \sum_{k=1}^r w_{kj}^1 Z_{k(t)} \right). \quad (2.73)$$

## 2.9 Hibrida ARIMAX dan *Deep Learning Neural Network*

Hibrida adalah kombinasi dua atau lebih sistem dalam satu fungsi, dalam hal ini adalah kombinasi *Deep Learning Neural Network* dan ARIMAX. Model ARIMAX dapat menghasilkan peramalan yang baik pada kondisi yang linier, tetapi akan buruk jika bertemu dengan kondisi yang nonlinier untuk itu dilakukan kombinasi dengan *Deep Learning Neural Network* yang menunjukkan performa yang baik jika data bersifat nonlinier dengan menggunakan jumlah layer yang lebih banyak. Jadi model hibrida dapat membantu mengatasi struktur yang kompleks dari

suatu data (Zheng & Zhong, 2011). Secara umum kombinasi dari model *time series* dapat dituliskan sebagai berikut:

$$Y_t = L_t + N_t + \varepsilon_t \quad (2.74)$$

dengan  $L_t$  menunjukkan komponen linier yang diwakili oleh metode ARIMAX dan  $N_t$  menunjukkan komponen nonlinier yang diwakili oleh metode *Deep Learning Neural Network*, dimana residual dari model yang linier masih mengandung informasi hubungan nonlinier. Secara matematis untuk level 1 dapat dituliskan sebagai berikut:

$$a_t = Y_t - \hat{L}_t \quad (2.75)$$

$\hat{L}_t$  merupakan nilai peramalan dari model linier pada waktu ke- $t$ . Selanjutnya untuk level 2 dilakukan pemodelan  $a_t$  dengan Neural Network. Residual model linier sebagai berikut:

$$\begin{aligned} a_t &= f(a_{t-1}, a_{t-2}, \dots, a_{t-k}) + \varepsilon_t \\ &= \hat{N}_t + \varepsilon_t \end{aligned} \quad (2.76)$$

dengan  $f$  merupakan fungsi non-linier yang didapatkan dari Neural Network dan  $\hat{N}_t$  dan merupakan hasil peramalan dari Neural Network pada waktu ke- $t$ . Sehingga didapatkan model hibrida ARIMAX dan *Deep Learning Neural Network* sebagai berikut (Zhang, 2003):

$$\hat{Y}_{(t)} = \hat{L}_t + \hat{N}_t \quad (2.77)$$

## 2.10 Pemilihan Model Terbaik

Penelitian ini menggunakan kriteria kesalahan peramalan untuk *out sample* yaitu *Symmetric Mean Absolute Percentage Error* (sMAPE) dan *Root Mean Square Error* (RMSE) sebagai pemilihan model terbaik (Hyndman & Koehler, 2006). Rumus sMAPE sebagai berikut:

$$sMAPE = \frac{1}{L} \sum_{l=1}^L \frac{|Y_{n+l} - \hat{Y}_n(l)|}{\left(\frac{|Y_{n+l}| + |\hat{Y}_n(l)|}{2}\right)} \times 100\% \quad (2.78)$$

Rumus RMSE sebagai berikut:

$$RMSE = \sqrt{\frac{1}{L} \sum_{l=1}^L (Y_{n+l} - \hat{Y}_n(l))^2} \quad (2.79)$$

dengan

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


$Y_n(l)$  : nilai ramalan

$L$  : jumlah data *out sample*

## 2.11 Listrik

Listrik merupakan bentuk energi yang mengalir melalui jaringan kabel dan merupakan bentuk energi yang paling penting bagi manusia saat ini. Semakin bertambahnya konsumsi listrik perkapita di seluruh dunia mengindikasikan adanya kenaikan standar kehidupan manusia (Hadi & Pabla, 1999).

Energi listrik merupakan energi yang sangat bermanfaat. Tidak dapat dipungkiri lagi bahwa manusia dewasa ini sudah demikian besar tingkat ketergantungannya terhadap energi listrik. Sehingga energi listrik bagi kebutuhan hidup manusia dewasa ini sudah hampir setara dengan oksigen. Bahkan ukuran kemajuan suatu Negara dapat diukur dari tingkat konsumsi energi listriknya. Amerika Serikat yang merupakan Negara maju pada tahun 2000 mempunyai kapasitas terpasang pembangkit listrik total sekitar 1200 GW atau  $1,2 \times 10^{12}$  Watt. Sementara untuk Indonesia yang merupakan Negara berkembang pada akhir tahun 2004 untuk sistem Jawa-Bali mempunyai kapasitas terpasang pembangkit listrik sebesar 20 GW. Konsumsi listrik di Indonesia sebagian besar berada di Jawa-Bali sehingga sebagian besar pembangkit listriknya terpusat di pulau Jawa dan Bali.



**Gambar 2.3** Sistem Tenaga Listrik

Secara umum, definisi sistem tenaga listrik meliputi sistem pembangkitan, sistem transmisi dan sistem distribusi. Pada pusat pembangkit, sumber daya energi primer seperti bahan bakar fosil (minyak, gas alam, dan batubara), hidro, panas bumi, dan nuklir diubah menjadi energi listrik. Generator mengubah energi mekanis yang dihasilkan pada poros turbin menjadi energi listrik tiga fasa. Melalui transformator *step-up*, energi listrik ini kemudian dikirimkan melalui saluran transmisi bertegangan tinggi menuju pusat-pusat beban. Energi listrik dibangkitkan pada pusat-pusat pembangkit tenaga listrik seperti pembangkit listrik tenaga air (PLTA), pembangkit listrik tenaga uap (PLTU), pembangkit listrik tenaga gas (PLTG), pembangkit listrik tenaga nuklir (PLTN) dan lain-lain. Pusat-pusat pembangkit listrik tersebut umumnya jauh dari daerah-daerah dimana energi listrik itu digunakan, yang disebut sebagai pusat-pusat beban (*load centres*). Oleh karena itu energi listrik yang dibangkitkan harus disalurkan melalui suatu saluran transmisi. Karena tegangan yang dihasilkan generator umumnya relatif rendah (berkisar 6 kV hingga 24 kV), maka tegangan ini biasanya dinaikkan dengan bantuan transformator daya ke tingkat tegangan yang lebih tinggi

antara 30 kV sampai 500 kV. Peningkatan tegangan dimaksudkan untuk mengurangi jumlah arus yang mengalir pada saluran transmisi. Dengan demikian saluran transmisi bertegangan tinggi akan membawa aliran arus yang rendah dan berarti mengurangi rugi panas (*heat loss*) yang menyertainya. Ketika saluran transmisi mencapai pusat beban, tegangan tersebut kembali diturunkan menjadi tegangan menengah melalui transformator *step-down*. Di pusat-pusat beban yang terhubung dengan saluran distribusi, energi listrik ini diubah menjadi bentuk-bentuk energi terpakai lainnya seperti energi mekanis (motor), penerangan, pemanas, pendingin, dan sebagainya. Dari saluran distribusi inilah listrik akan disalurkan kepada konsumen baik rumah tangga, industri, perkantoran, usaha dan lain-lain (Syahputra, 2016).

## 2.12 Penelitian Sebelumnya

Tabel 2.1 Penelitian sebelumnya

Peneliti (Penulis)	Tahun	Judul	Metode	Tempat	Hasil Metode Terbaik
Muhammed	2011	<i>Short Term Electricity Load Forecasting of Kurdistan-Erbil Power System Using Artificial Neural Network</i>	ANN & Metode Konvensional	Kurdistan-Erbil	ANN
Nie, Liu, Liu & Wang	2012	<i>Hybrid of ARIMA and SVMs for Short Term Load Forecasting</i>	ARIMA, SVM, Hibrida ARIMA-SVM	Heilongjiang, China	Hibrida ARIMA-SVM
Sadaei, Enayatifar, Abdullah & Gani	2014	<i>Short Term Load Forecasting using a Hybrid Model with a Refined Exponentially Weighted Fuzzy Time Series (REWFTS) and an Improved Harmony Search (IHS)</i>	REWFTS, HIS, Hibrida REWFTS-IHS	Paris dan Inggris	Hibrida REWFTS-IHS

Ryu, Noh & Kim	2016	<i>Deep Neural Network (DNN) Based Demand Side Short Term Load Forecasting</i>	DNN, <i>Shallow Neural Network (SNN)</i> , <i>Double Seasonal Holt-Winters (DSHW)</i>	Korea	DNN
Dudek	2016	<i>Neural networks for pattern based short term load forecasting: A comparative study</i>	Generalized regression neural network (GRNN) dibandingkan model neural networks lainnya	-	GRNN
Din & Marnerides	2017	<i>Short term power load forecasting using Deep Neural Networks.</i>	<i>Feed-Forward Deep Neural Network (FF-DNN) &amp; Recurrent Deep Neural Network (R-DNN)</i>	New England, USA	R-DNN
Hoseen, Plathottam,	2017	<i>Short Term Load Forecasting using</i>	DNN dengan fungsi aktivasi	Pasar listrik	DNN dengan fungsi aktivasi

Angamuthu, Ranganathan & Salehfar		<i>Deep Neural Networks (DNN)</i>	<i>Sigmoid, Rectifier Linear Unit (ReLU), dan Exponential Linear Unit (ELU)</i>	Iberian	<i>Exponential Linear Unit (ELU)</i>
Balaraman & Karthika	2017	<i>Hybrid Short Term Load Forecasting using ARIMA-SVM</i>	ARIMA, SVM, Hibrida ARIMA-SVM	Data diambil dari tahun 2014 sampai tahun 2015 yang merupakan data beban listrik pada wilayah selatan	Hibrida ARIMA-SVM
Khwaja, Zhang, Anpalagan & Venkastesh	2017	<i>Boosted Neural Networks (BooNN) for Improved Short Term Electric Load Forecasting</i>	Boosted Neural Networks (BooNN), <i>single ANN, bagged ANN, ARMA, hybrid unsupervised-supervised</i>	-	Boosted Neural Networks (BooNN)



			ANN dan <i>bagged</i> <i>regression trees</i>		
Barman, Choudhury & Sutradhar	2018	<i>A Regional Hybrid GOA-SVM Model Based on Similar Day Approach for Short Term Load Forecasting in Assam, India.</i>	GOA, SVM, Hibrida GOA- SVM	Assam, India	Hibrida GOA- SVM

*(Halaman ini sengaja dikosongkan)*

## BAB III

### METODOLOGI PENELITIAN

#### 3.1 Sumber Data dan Variabel Penelitian

Data yang digunakan dalam penelitian ini merupakan data sekunder yang diperoleh dari PT. Indonesia Power UP Bali yang merupakan data beban listrik jangka pendek yaitu per setengah jam. Data beban listrik per setengah jam sekaligus digunakan sebagai variabel penelitian, dimana data dibagi menjadi data training dan data testing. Data training yang digunakan adalah periode Januari 2014 hingga Desember 2016. Sementara data testing yang digunakan adalah Januari 2017 hingga Desember 2017. Variabel respon yang digunakan terdiri dari 27 variabel, dimana variabel 00:30, 01:30, 02:30 sampai dengan 17:30 tidak digunakan karena perusahaan mengasumsikan pada jam tersebut listrik memiliki beban yang sama pada jam sebelumnya. Namun variabel 18:30, 19:30 dan 20:30 digunakan karena terkait dengan beban puncak. Variabel 21:30, 22:30 dan 23:30 kembali tidak digunakan karena diasumsikan memiliki beban yang sama dengan jam sebelumnya. Variabel respon yang digunakan dalam penelitian ini sebagai berikut.

**Tabel 3.1** Struktur Data

Tahun	Bulan	Tanggal	Waktu			
			01:00	02:00	...	24:00
2014	Januari	1	$Z_{1,1}$	$Z_{1,2}$	...	$Z_{1,27}$
2014	Januari	2	$Z_{2,1}$	$Z_{2,2}$	...	$Z_{2,27}$
⋮	⋮	⋮	⋮	⋮	⋮	⋮
2014	Januari	30	$Z_{30,1}$	$Z_{30,2}$	...	$Z_{30,27}$
2014	Januari	31	$Z_{31,1}$	$Z_{31,2}$	...	$Z_{31,27}$
2014	Februari	1	$Z_{32,1}$	$Z_{32,2}$	...	$Z_{32,27}$
2014	Februari	2	$Z_{33,1}$	$Z_{33,2}$	...	$Z_{33,27}$
⋮	⋮	⋮	⋮	⋮	⋮	⋮
2014	Februari	27	$Z_{58,1}$	$Z_{58,2}$	...	$Z_{58,27}$
2014	Februari	28	$Z_{59,1}$	$Z_{59,2}$	...	$Z_{59,27}$
...	...	...	...	...	⋮	⋮

Tabel 3.1 Struktur Data (Lanjutan)

Tahun	Bulan	Tanggal	Waktu			
			01:00	02:00	...	24:00
2016	Desember	1	$Z_{n-30,1}$	$Z_{n-30,2}$	...	$Z_{n-30,27}$
2016	Desember	2	$Z_{n-29,1}$	$Z_{n-29,2}$	...	$Z_{n-29,27}$
⋮	⋮	⋮	⋮	⋮	⋮	⋮
2016	Desember	30	$Z_{n-1,1}$	$Z_{n-1,2}$	...	$Z_{n-1,27}$
2016	Desember	31	$Z_{n,1}$	$Z_{n,2}$	...	$Z_{n,27}$

Variabel prediktor yang digunakan dalam pemodelan sebagai berikut.

1. Variabel untuk *dummy* tren sebagai berikut:

$$t = 1, 2, \dots, n$$

2. Variabel untuk *dummy* pola musiman (hari)

$$H_{1,t} = \begin{cases} 1, & \text{Hari Senin} \\ 0, & \text{Hari lainnya} \end{cases}$$

$$H_{2,t} = \begin{cases} 1, & \text{Hari Selasa} \\ 0, & \text{Hari lainnya} \end{cases}$$

⋮

$$H_{7,t} = \begin{cases} 1, & \text{Hari Minggu} \\ 0, & \text{Hari lainnya} \end{cases}$$

3. Variabel *dummy* untuk variasi kalender

Variasi kalender yang dimaksud bisa berupa hari raya keagamaan, hari libur biasa serta hari libur nasional.

$$I_{r,t} = \begin{cases} 1, & \text{Waktu terjadinya variasi kalender ke-}r \\ 0, & \text{Waktu tidak terjadinya variasi kalender} \end{cases}$$

dengan  $r$  banyak variasi kalender.

### 3.2 Langkah Analisis

Langkah analisis yang disusun dalam penelitian ini disesuaikan dengan tujuan penelitian yang ingin dicapai. Terdapat dua kajian analisis yang dilakukan yaitu kajian simulasi dan kajian terapan.

### 3.2.1 Kajian Simulasi

Membangkitkan data simulasi berupa komponen *trend*, musiman, variasi kalender serta *noise*. Simulasi data bangkitan dilakukan berdasarkan jurnal Soares & Medeiros (2008). Dilakukan 27 simulasi, dimana mengikuti data beban listrik per setengah jam. Simulasi data bangkitan mengikuti persamaan beban total dimana beban total merupakan jumlahan dari beban potensial dan beban irregular. Untuk beban potensial mengandung komponen untuk pola tren, pola musiman (hari) serta efek variasi kalender. Persamaan untuk simulasi data bangkitan berdasarkan persamaan beban potensial sebagai berikut:

$$Y_{J,t}^P = T_t + H_t + I_t \quad (3.1)$$

dengan :

$T_t$  : komponen untuk pola tren

$H_t$  : komponen untuk pola musiman (Hari)

$I_t$  : komponen untuk variasi kalender

Untuk beban irregular dibangkitkan data yang berpola linier dan nonlinier. Pada skenario 1 dibangkitkan data berpola linier yang mengikuti pola AR(1) dan pada skenario 2 dibangkitkan data berpola nonlinier yang mengikuti pola ESTAR(1). Persamaan untuk simulasi data bangkitan berdasarkan persamaan beban irregular sebagai berikut:

$$Y_{J,t}^I = \phi_1 y_{J,t} + a_{J,t} \quad (3.2)$$

dengan :

$\phi_1 y_{J,t}$  : komponen AR(1) atau ESTAR (1)

$a_{J,t}$  : komponen *noise*

#### 1. Komponen tren

Persamaan yang digunakan pada komponen tren sebagai berikut:

$$T_t = \rho t \quad (3.3)$$

Komponen tren akan dibangkitkan menggunakan koefisien yang konstan yaitu  $\rho = 0,1$

## 2. Komponen musiman

Dibangkitkan data dengan mengandung komponen musiman (hari) dengan persamaan sebagai berikut:

$$M_t = \beta_1 H_{1,t} + \beta_2 H_{2,t} + \beta_3 H_{3,t} + \dots \quad (3.4)$$

Digunakan pembobotan untuk membangkitkan data dengan komponen musiman (hari). Pembobotan dilakukan dengan mengacu pada data beban listrik per setengah jam. Pembobotan untuk komponen musiman (hari) sebagai berikut :

**Tabel 3.2** Pembobotan untuk Komponen Musiman (Hari)

Jam	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
01:00	515.5	517.3	512.8	515.1	517	514.8	520.9
02:00	495.6	491.4	493.2	496.6	500	493.9	498.6
03:00	478.8	477.6	476.9	483.3	483.4	478.7	485.8
04:00	470.2	468.5	470.1	475.2	473.7	469.7	473.7
05:00	478.9	475.9	478	478.6	481.6	476.9	476.7
06:00	506	505.9	507.8	506.9	511.3	501.6	492.1
07:00	508.4	508.8	511.8	508.6	514.8	501	495
08:00	549.9	547.7	548	546.3	554	529.8	524.2
09:00	610.4	610.3	603.3	607.4	613.3	581.8	567.6
10:00	650.2	646.8	641.6	646.2	651.3	625.2	599.3
11:00	667.2	660.6	655.3	661.6	667.1	640.2	613.9
12:00	659.3	651.7	647.7	650.4	655.7	638.8	610.7
13:00	658.7	656.5	653.7	654.7	653.1	637.2	605.4
14:00	677.4	672.5	671.7	671	670.1	641.8	611.6
15:00	674.6	672	668.3	675.7	667.7	638.1	612.4
16:00	661.5	659.3	655.9	658.5	660.1	630	603.5
17:00	641.5	640.6	638.5	644.7	644.4	619.2	601.7
18:00	653.5	652	652.5	653.3	657	638	625.1
18:30	709.5	709.2	709.3	714.2	710.4	696.8	684.9
19:00	736.6	735.2	737.4	740.1	740.6	725.8	717.9
19:30	739.6	735.8	734.2	740.4	740.6	727.5	717.8
20:00	734.4	730.5	730.2	737.3	736.5	719	718.7
20:30	721.3	721.3	721.8	727.9	725.5	709.3	711.7
21:00	711	707	706.8	714.2	713.6	698	703.7
22:00	658.4	654	657.7	660.5	658.6	654.9	653.7

**Tabel 3.2** Pembobotan untuk Komponen Musiman (Hari) (Lanjutan)

Jam	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
23:00	596.6	594.4	595.6	596.6	602	593.7	592
24:00	546.4	546.7	552.6	548.7	553	551.1	548.2

### 3. Komponen variasi kalender

Data yang dibangkitkan memiliki komponen variasi kalender dimana terdapat pengaruh dari suatu kejadian seperti hari libur selain hari minggu. Berikut merupakan komponen variasi kalender yang merupakan hari libur selain hari minggu dari tahun 2014 hingga 2017:

**Tabel 3.3** Hari Libur selain Hari Minggu Tahun 2014 hingga 2017

Dum my	Keterangan	2014		2015		2016		2017	
		Tanggal	Hari	Tanggal	Hari	Tanggal	Hari	Tanggal	Hari
I1	Tahun Baru	1 Januari	Rabu	1 Januari	Kamis	1 Januari	Jumat	-	-
I2	Maulid Nabi Muhammad SAW	14 Januari	Selasa	3 Januari	Sabtu	-	-	-	-
		-	-	24 Desember	Jumat	12 Desember	Senin	1 Desember	Jumat
I3	Tahun Baru Imlek	31 Januari	Jumat	19 Februari	Kamis	8 Februari	Senin	28 Januari	Sabtu
I4	H-1 Nyepi (Tawur Kesanga)	-	-	20 Maret	Jumat	8 Maret	Selasa	27 Maret	Senin
I5	Hari Raya Nyepi	31 Maret	Senin	21 Maret	Sabtu	9 Maret	Rabu	28 Maret	Selasa
I6	H+1 Nyepi (Ngembak Geni)	1 April	Selasa	-	-	10 Maret	Kamis	29 Maret	Rabu
I7	Wafat Isa Almasih	18 April	Jumat	3 April	Jumat	25 Maret	Jumat	14 April	Jumat
I8	Hari Buruh	1 Mei	Kamis	1 Mei	Jumat	-	-	1 Mei	Senin
I9	Hari Raya Waisak	15 Mei	Kamis	2 Juni	Selasa	-	-	11 Mei	Kamis
I10	Isra Miraj Nabi Muhammad SAW	27 Mei	Selasa	16 Mei	Sabtu	6 Mei	Jumat	24 April	Senin
I11	Kenaikan Isa Al Masih	29 Mei	Kamis	14 Mei	Kamis	5 Mei	Kamis	25 Mei	Kamis
I12	Hari Raya Idul Fitri	28 Juli	Senin	17 Juli	Jumat	6 Juli	Rabu	25 Juni	Rabu
I13	Hari Raya Idul Fitri	29 Juli	Selasa	18 Juli	Sabtu	7 Juli	Kamis	26 Juni	Kamis
I14	Hari Kemerdekaan	-	-	17 Agustus	Senin	17 Agustus	Rabu	17 Agustus	Kamis
I15	Hari Raya Idul Adha	-	-	24 September	Kamis	12 September	Senin	1 September	Jumat
I16	Tahun Baru Islam	25 Oktober	Kamis	14 Oktober	Rabu	-	-	21 September	Kamis



I17	Hari Raya Natal	25 Desember	Kamis	25 Desember	Jumat	-	-	25 Desember	Senin
I18	Hari Raya Siwaratri	30 Januari	Kamis	20 Januari	Selasa	9 Januari	Sabtu	27 Januari	Jumat
I19	Hari Raya Saraswati	8 Maret	Sabtu	2 Mei	Sabtu	-	-	21 Januari	Sabtu
		4 Oktober	Sabtu	28 November	Sabtu	25 Juni	Sabtu	19 Agustus	Sabtu
I20	Hari Raya Pagerwesi	12 Maret	Rabu	6 Mei	Rabu	-	-	25 Januari	Rabu
		8 Oktober	Rabu	2 Desember	Rabu	29 Juni	Rabu	23 Agustus	Rabu
I21	H-1 Galungan	20 Mei	Selasa	14 Juli	Selasa	9 Februari	Selasa	4 April	Selasa
		16 Desember	Selasa	-	-	6 September	Selasa	31 Oktober	Selasa
I22	Hari Raya Galungan	21 Mei	Rabu	15 Juli	Rabu	10 Februari	Rabu	5 April	Rabu
		17 Desember	Rabu	-	-	7 September	Rabu	1 November	Rabu
I23	H+1 Galungan	22 Mei	Kamis	16 Juli	Kamis	11 Februari	Kamis	6 April	Kamis
		18 Desember	Kamis	-	-	8 September	Kamis	2 November	Kamis
I24	H-1 Kuningan	30 Mei	Jumat	24 Juli	Jumat	19 Februari	Jumat	14 April	Jumat
		26 Desember	Jumat	-	-	16 September	Jumat	10 November	Jumat
I25	Hari Raya Kuningan	31 Mei	Sabtu	25 Juli	Sabtu	20 Februari	Sabtu	15 April	Sabtu
		27 Desember	Sabtu	-	-	17 September	Sabtu	11 November	Sabtu

#### 4. Komponen *noise*

Komponen *noise* yang digunakan adalah yang mengandung pola linier AR(1) untuk skenario 1 dan pola nonlinier ESTAR(1) untuk skenario 2 dengan persamaan sebagai berikut:

$$N_{1,t} = 0,7N_{1,t-1} + a_t \text{ dengan } a_t \sim N(0,1)$$

$$N_{2,t} = 6,5N_{2,t-1} \exp(-0,25N_{2,t-1}^2) + a_t \text{ dengan } a_t \sim N(0,1)$$

Skala data yang besar menyebabkan pola linier dan nonlinier tidak begitu terlihat saat dilakukan *time series plot*, sehingga *noise* dengan pola nonlinier dikalikan dengan angka 5. Selanjutnya dilakukan pemodelan dengan menggunakan ARIMAX, *Deep Learning Neural Network* serta Hibrida ARIMAX dan *Deep Learning Neural Network*. Ketiga model tersebut selanjutnya dibandingkan berdasarkan kebaikan model RMSE untuk mendapatkan model terbaik. Langkah terakhir adalah menarik kesimpulan.

### 3.2.2 Kajian Terapan

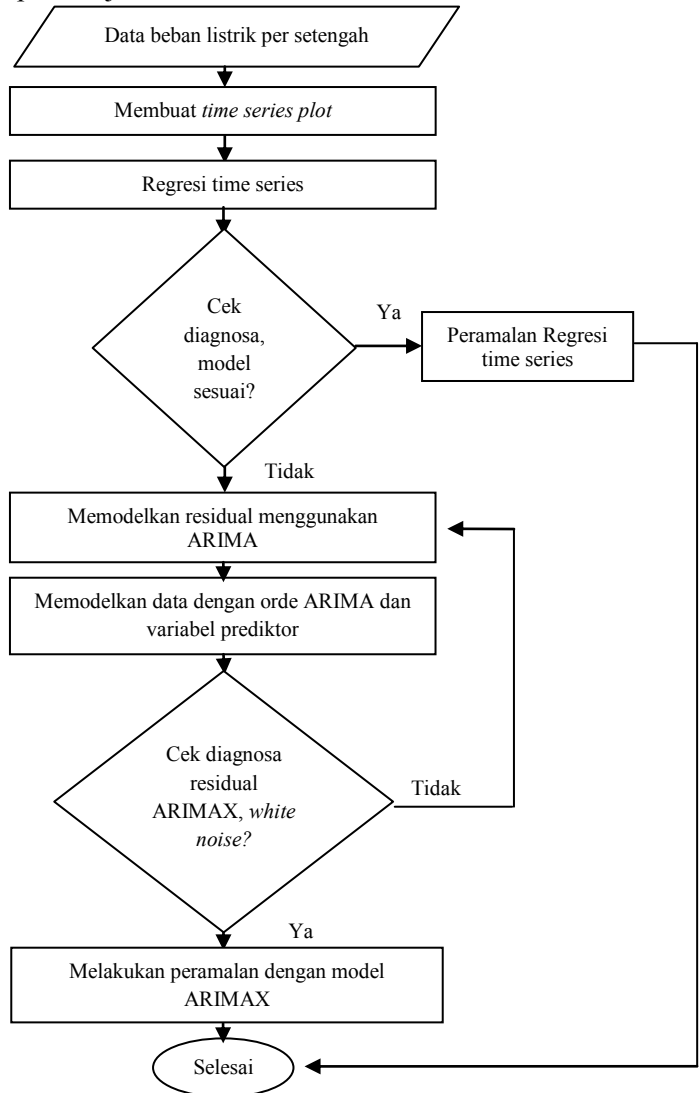
Langkah-langkah analisis yang dilakukan pada kajian terapan sebagai berikut:

1. Melakukan analisis statistika deskriptif pada data beban listrik jangka pendek (per setengah jam) di PT. Indonesia Power UP Bali.
2. Membagi data beban listrik per setengah jam menjadi dua bagian yaitu data *in-sample* (training) pada periode Januari 2014 hingga Desember 2016 dan data *out-sample* (testing) pada periode Januari 2017 hingga Desember 2017.
3. Mengaplikasikan model ARIMAX, *Deep Learning Neural Network* serta Hibrida ARIMAX dan *Deep Learning Neural Network*.
  - (i) Model ARIMAX
    - a. Membuat *time series plot* dimana data diasumsikan mengandung pola tren, musiman, variasi kalender serta residual.
    - b. Meregresikan variabel respon dengan variabel prediktor (*dummy*)

- c. Melakukan cek diagnosa untuk mengetahui apakah residual sudah memenuhi asumsi *white noise* atau belum. Jika sudah memenuhi asumsi *white noise* dilanjutkan dengan regresi time series lalu melakukan peramalan, namun jika belum akan dilanjutkan ke langkah berikutnya.
  - d. Memodelkan residual dari regresi time series menggunakan metode ARIMA berdasarkan prosedur Box-Jenkins.
  - e. Memodelkan data dengan orde ARIMA dan variabel prediktor yang berupa *dummy* secara simultan.
  - f. Melakukan cek diagnosa kembali pada residual ARIMAX.
  - g. Melakukan peramalan dengan model ARIMAX dan menghitung nilai RMSE.
- (ii) Model *Deep Learning Neural Network*
- a. Melakukan *preprocessing* data menggunakan normalisasi dengan persamaan sebagai berikut:
 
$$Y_{(t)}^* = \frac{Y_{(t)} - \min(Y_{(t)})}{\max(Y_{(t)}) - \min(Y_{(t)})} \quad (3.5)$$
  - b. Menentukan variabel input berdasarkan variabel komponen tren, musiman dan kalender variasi pada ARIMAX serta lag variabel respon berdasarkan plot PACF yang signifikan.
  - c. Menentukan arsitektur *Deep Learning Neural Network* yaitu menentukan banyak input, jumlah neuron dalam hidden layer, bobot awal dan fungsi aktivasi.
  - d. Melakukan peramalan dan menghitung nilai RMSE dan sMAPE.
  - e. Melakukan *postprocessing* data dengan persamaan sebagai berikut:
 
$$Y_{(t)} = Y_{(t)}^* \left( \max(Y_{(t)}) - \min(Y_{(t)}) \right) + \min(Y_{(t)}) \quad (3.6)$$
- (iii) Model Hibrida ARIMAX dan *Deep Learning Neural Network*


- a. Mencari model ARIMAX yang sesuai.
  - b. Melakukan pemodelan dan peramalan dengan model ARIMAX.
  - c. Orde AR dari residual pada model ARIMAX serta komponen tren, musiman dan kalender variasi pada ARIMAX digunakan sebagai input lalu dimodelkan kembali dengan model *Deep Learning Neural Network*.
  - d. Menggabungkan model ARIMAX dan model *Deep Learning Neural Network* sehingga didapat model Hibrida ARIMAX dan *Deep Learning Neural Network*.
  - e. Melakukan peramalan dan menghitung nilai RMSE.
  - f. Memilih model terbaik.
4. Membandingkan model ARIMAX, *Deep Learning Neural Network* dan model Hibrida ARIMAX dan *Deep Learning Neural Network* berdasarkan nilai RMSE dan sMAPE.
  5. Mendapatkan hasil peramalan beban listrik per setengah jam dengan model terbaik.
  6. Melakukan peramalan dengan model terbaik.

Langkah-langkah analisis untuk peramalan menggunakan metode ARIMAX dapat disajikan dalam Gambar 3.1.




**Gambar 3.1** Diagram Alir Metode ARIMAX

Langkah-langkah analisis untuk peramalan menggunakan metode *Deep Learning* Neural Network dapat disajikan dalam Gambar 3.2.




**Gambar 3.2** Diagram Alir Metode *Deep Learning* Neural Network

Langkah-langkah analisis untuk kajian terapan dapat disajikan dalam Gambar 3.3.

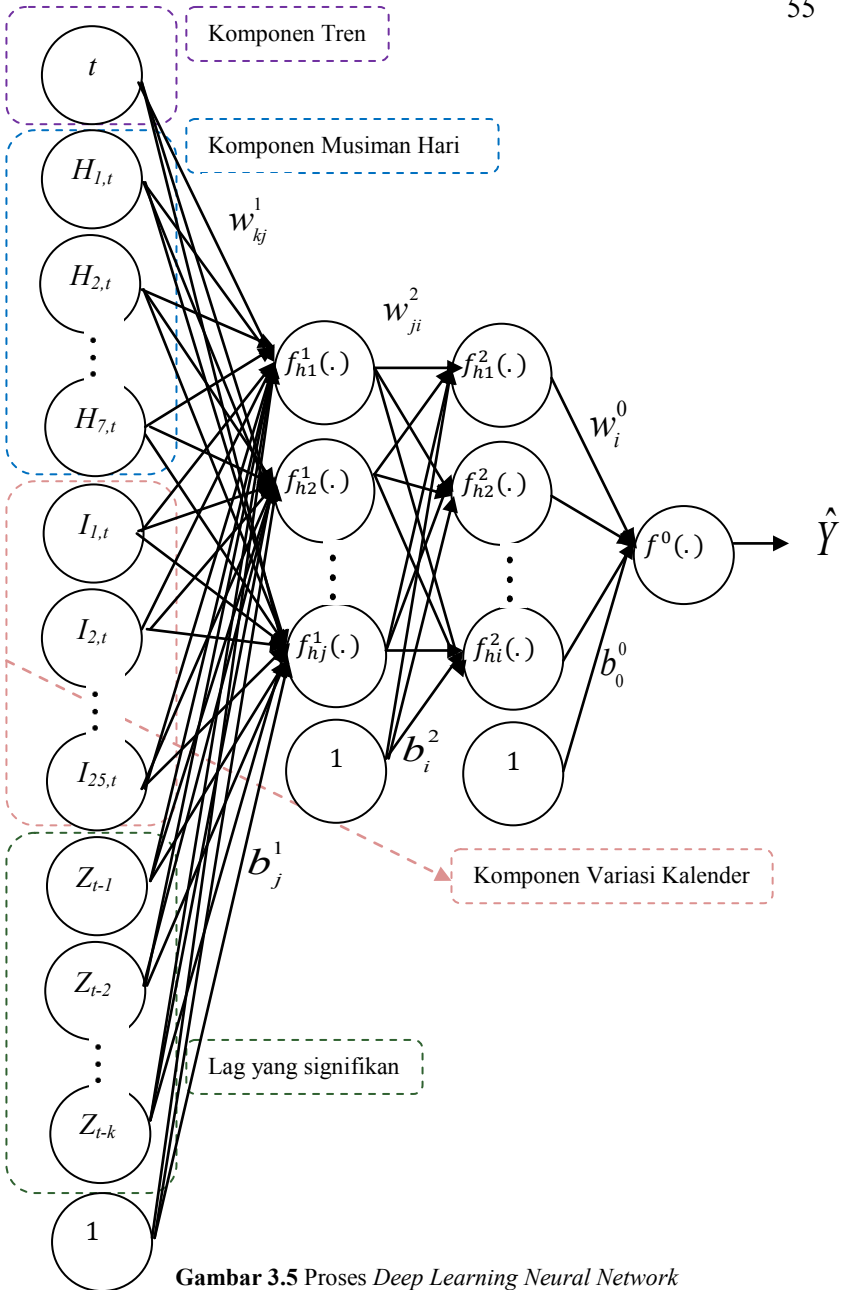


**Gambar 3.3** Diagram Alir Kajian Terapan

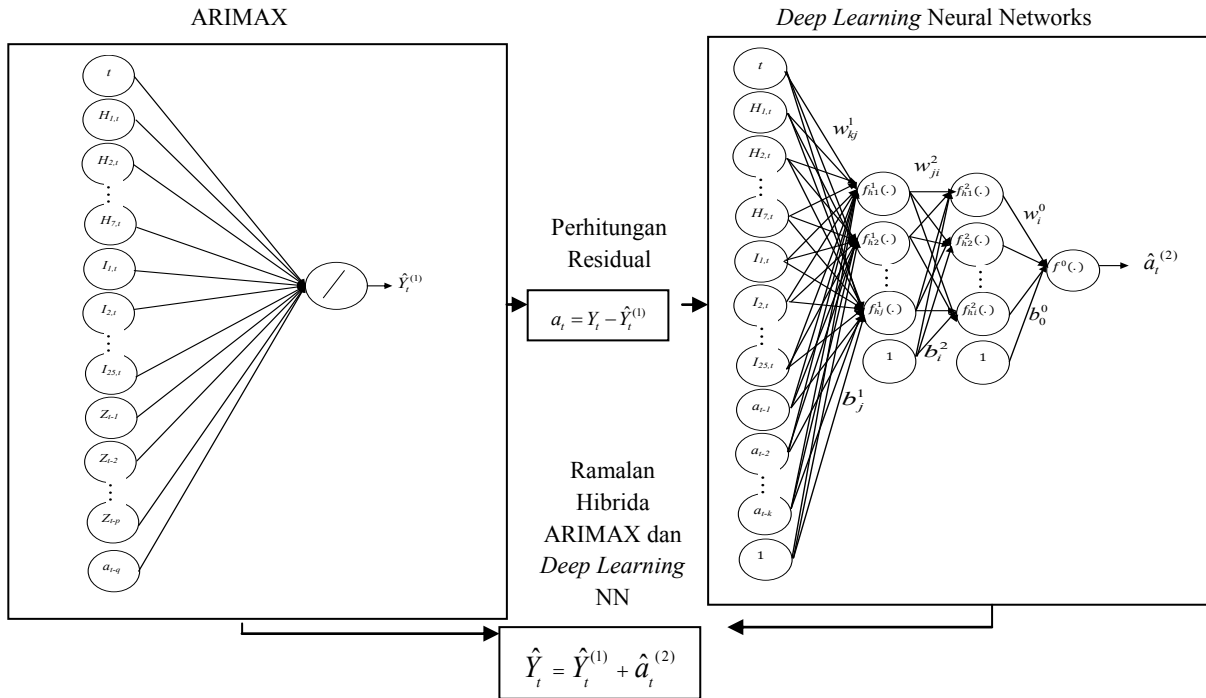


**Gambar 3.4** Proses ARIMAX





**Gambar 3.5** Proses *Deep Learning Neural Network*



**Gambar 3.6** Proses Hibrida ARIMAX dan *Deep Learning Neural Network*

## BAB IV

### ANALISIS DAN PEMBAHASAN


Pada bab ini dilakukan analisis dan pembahasan mengenai pemodelan dengan ARIMAX, *Deep Learning Neural Network* serta Hibrida ARIMAX dan *Deep Learning Neural Network* menggunakan data simulasi serta data beban listrik per setengah jam di PT. Indonesia Power UP Bali. Selain melakukan pemodelan, dilakukan pula analisis performa masing-masing model yang selanjutnya akan dibandingkan untuk mendapatkan model terbaik.

#### 4.1 Studi Simulasi


Tujuan dari studi simulasi adalah untuk membuktikan bahwa suatu metode layak untuk digunakan. Pada penelitian ini, studi simulasi dilakukan untuk mengidentifikasi terjadinya nonlinieritas pada data.

##### 4.1.1 Simulasi Data Bangkitan

Beban total yang akan digunakan memiliki dua skenario dengan perbedaan komponen *noise* yaitu dengan pola linier AR(1) dan pola nonlinier ESTAR(1). *Time series plot* untuk komponen tren, musiman, variasi kalender serta *noise* pada pukul 20:00 yang digunakan sebagai acuan pada kajian simulasi sebagai berikut:




**Gambar 4.1** *Time Series Plot* Komponen (a) Tren  
(b) Musiman (c) Variasi Kalender (d) Noise Linear (e) Noise Nonlinear



**Gambar 4.1** *Time Series Plot* Komponen (a) Tren  
(b) Musiman (c) Variasi Kalender (d) Noise Linear (e) Noise Nonlinear  
(Lanjutan)

Berdasarkan Gambar 4.1, *time series plot* pada komponen tren menunjukkan adanya kenaikan data pengamatan setiap pertambahan waktu. Komponen musiman menunjukkan adanya kenaikan dan penurunan data pada waktu tertentu. *Time series plot* pada komponen variasi kalender menunjukkan adanya efek dari kejadian khusus seperti hari libur nasional, hari raya keagamaan dan lainnya. Sementara untuk pola linier dan nonlinier pada data ditunjukkan oleh komponen *noise* linier dan nonlinier. *Time series plot* pada komponen *noise* linier dan nonlinier tidak memiliki perbedaan yang signifikan, sehingga untuk mengidentifikasi pola *noise* digunakan plot antara *noise* pada waktu ke  $t$  dengan *noise* pada waktu ke  $t-1$ . Berikut merupakan *plot* antara *noise* pada waktu ke  $t$  dengan *noise* pada waktu ke  $t-1$  pada masing-masing komponen linier dan nonlinier:




**Gambar 4.2** Plot *Noise* pada Waktu ke  $t$  dengan *Noise* pada Waktu ke  $t-1$  pada (a) pola linier dan (b) pola nonlinier


Berdasarkan Gambar 4.2, *noise* yang memiliki pola linier menghasilkan plot yang berbentuk linier. Sementara *noise* yang memiliki pola nonlinier menghasilkan plot yang berbentuk nonlinier.

### 1. Skenario 1

Pada skenario 1, menggunakan *noise* yang memiliki pola linier yaitu AR(1). Berikut merupakan *time series plot* untuk data simulasi pada jam 04:00, 08:00, 12:00, 16:00, 20:00 dan 24:00:



**Gambar 4.3** Data Simulasi Jam (a) 04:00, (b) 08:00, (c) 12:00, (d) 16:00, (e) 20:00 dan (f) 24:00 pada Skenario 1



**Gambar 4.3** Data Simulasi Jam (a) 04:00, (b) 08:00, (c) 12:00, (d) 16:00, (e) 20:00 dan (f) 24:00 pada Skenario 1 (Lanjutan)

Berdasarkan *time series plot* pada Gambar 4.3, terlihat bahwa data memiliki pola tren naik, sementara untuk pola musiman tidak terlalu terlihat karena jumlah data yang digunakan sebesar 1096 data dimana merupakan data *training* selama 3 tahun mulai 1 Januari 2014 hingga 31 Desember 2016. Untuk variasi kalender yang terkandung pada skenario 1, terlihat jelas data yang memiliki nilai yang sangat rendah maupun nilai yang sangat tinggi disaat hari terjadinya hari raya.

Pemodelan menggunakan ARIMAX mengandung efek dari komponen tren, musiman, serta variasi kalender dengan menggunakan variabel *dummy*. Dilakukan regresi *time series* dengan prediktor variabel *dummy* dan respon yaitu simulasi data beban listrik per setengah jamnya. Hasil signifikansi parameter simulasi data beban listrik pada jam 20:00 sebagai berikut:

**Tabel 4.1** Estimasi Paramater Regresi *Time Series* untuk Jam 20:00

Variabel	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
$\phi_1$	0,71	0,02	32,87	<,0001
<i>t</i>	0,10	0,002	63,85	<,0001
$H_{1,t}$	734,15	1,06	691,9	<,0001
$H_{2,t}$	730	1,06	686,8	<,0001
$H_{3,t}$	729,62	1,06	687,1	<,0001
$H_{4,t}$	736,95	1,06	692,4	<,0001
$H_{5,t}$	735,99	1,07	690,8	<,0001
$H_{6,t}$	718,69	1,07	674,3	<,0001
$H_{7,t}$	718,26	1,06	677	<,0001
$I_{1,t}$	-32,33	2,30	-14,08	<,0001
$I_{2,t}$	-33,20	2,01	-16,48	<,0001

**Tabel 4.1** Estimasi Paramater Regresi *Time Series* untuk Jam 20:00 (Lanjutan)

Variabel	Estimasi	SE	t-value	p-value
$I_{3,t}$	-1,75	2,34	-0,74	0,4567
$I_{4,t}$	-137,91	3,09	-44,62	<,0001
$I_{5,t}$	-259,03	2,73	-94,75	<,0001
$I_{6,t}$	-4,91	3,09	-1,59	0,1121
$I_{7,t}$	32,13	2,31	13,91	<,0001
$I_{8,t}$	-7,12	2,84	-2,51	0,0122
$I_{9,t}$	-8,63	2,81	-3,07	0,0022
$I_{10,t}$	11,40	2,32	4,91	<,0001
$I_{11,t}$	32,44	2,36	13,75	<,0001
$I_{12,t}$	-80,63	2,63	-30,61	<,0001
$I_{13,t}$	-56,57	2,60	-21,69	<,0001
$I_{14,t}$	-27,71	2,81	-9,87	<,0001
$I_{15,t}$	-26,76	2,81	-9,53	<,0001
$I_{16,t}$	-16,39	2,81	-5,83	<,0001
$I_{17,t}$	-2,10	2,90	-0,73	0,4659
$I_{18,t}$	13,06	2,32	5,62	<,0001
$I_{19,t}$	-7,55	1,82	-4,14	<,0001
$I_{20,t}$	-5,31	1,80	-2,95	0,0033
$I_{21,t}$	-30,77	2,16	-14,27	<,0001
$I_{22,t}$	-40,94	2,43	-16,8	<,0001
$I_{23,t}$	-28,55	2,16	-13,19	<,0001
$I_{24,t}$	40,02	2,10	19,1	<,0001
$I_{25,t}$	3,14	2,05	1,53	0,1261

Pada tabel 4.1 hampir seluruh variabel memiliki *p-value* kurang dari  $\alpha$  (0,05) yang artinya bahwa variabel berpengaruh signifikan. Namun terdapat empat variabel yang memiliki *p-value* lebih dari  $\alpha$  (0,05) yang menandakan variabel tersebut tidak memiliki pengaruh yang signifikan. Setelah dilakukan estimasi parameter pada regresi *time series*, selanjutnya dilakukan pengecekan residual dari regresi *time series* untuk mengetahui apakah pemodelan menggunakan ARIMA diperlukan atau tidak. Jika residual dari regresi *time series* sudah *white noise* dan berdistribusi normal maka tidak diperlukan pemodelan menggunakan ARIMA. Setelah didapatkan hasil estimasi parameter pada jam 20:00, diketahui bahwa residual dari regresi

*time series* memiliki model ARIMA(1,0,0). Berdasarkan model dugaan, dilakukan pengujian untuk mengetahui apakah asumsi *white noise* dan berdistribusi normal terpenuhi atau tidak. Berikut merupakan pengujian asumsi residual model ARIMAX:

**Tabel 4.2** Pengujian Asumsi Residual ARIMAX pada Jam 20:00

Uji <i>White Noise</i>				Uji Normalitas	
Hingga lag ke-	$\chi^2$	df	<i>p-value</i>	<i>p-value</i>	
6	3,49	5	0,6246	>0,1500	
12	11,71	11	0,3861		
18	14,96	17	0,5985		
24	24,89	23	0,3561		
36	37,54	35	0,3535		
48	46,14	47	0,5083		

Berdasarkan hasil pengujian asumsi pada tabel 4.2, asumsi *white noise* telah terpenuhi dimana seluruh lag telah signifikan dan asumsi residual berdistribusi normal juga telah terpenuhi dengan *p-value* 0,1500 dimana *p-value* lebih besar dari  $\alpha$ . Sehingga model persamaan dari data simulasi pada jam 20:00 memiliki fungsi sebagai berikut:

$$\begin{aligned}
 Y_{22,t} = & 0,10I_t + 734,15H_{1,t} + 730,00H_{2,t} + 729,62H_{3,t} + 736,95H_{4,t} + 735,99H_{5,t} \\
 & + 718,69H_{6,t} + 718,26H_{7,t} - 32,33I_{1,t} - 33,20I_{2,t} - 1,75I_{3,t} - 137,91I_{4,t} \\
 & - 259,03I_{5,t} - 4,91I_{6,t} + 32,13I_{7,t} - 7,12I_{8,t} - 8,63I_{9,t} + 11,40I_{10,t} + 32,44I_{11,t} \\
 & - 80,63I_{12,t} - 56,57I_{13,t} - 27,71I_{14,t} - 26,76I_{15,t} - 16,39I_{16,t} - 2,10I_{17,t} \\
 & + 13,06I_{18,t} - 7,55I_{19,t} - 5,31I_{20,t} - 30,77I_{21,t} - 40,94I_{22,t} - 28,55I_{23,t} \\
 & + 40,02I_{24,t} + 3,14I_{25,t} + \frac{1}{(1-0,71B)} a_t
 \end{aligned}$$


Dengan cara yang sama, berikut merupakan pendugaan model untuk data simulasi pada jam 04:00, 08:00, 12:00, 16:00, 20:00 dan 24:00 :




**Tabel 4.3** Model ARIMAX untuk Jam 04:00, 08:00, 12:00, 16:00, 20:00 dan 24:00

Jam	Model	Residual <i>White noise</i>	Berdistribusi normal
04:00	ARMA(1,0,0)	Ya	Ya
08:00	ARMA(1,0,0)	Ya	Ya
12:00	ARMA(1,0,0)	Ya	Ya
16:00	ARMA(1,0,0)	Ya	Ya
20:00	ARMA(1,0,0)	Ya	Ya
24:00	ARMA(1,0,0)	Ya	Ya

Tabel 4.3 menunjukkan model dugaan ARIMA untuk residual regresi *time series* yang telah memenuhi asumsi *white noise* dan berdistribusi normal. Berdasarkan hasil peramalan menggunakan metode ARIMAX diatas, berikut merupakan perbandingan data aktual dan data ramalan pada skenario 1:




**Gambar 4.4** Perbandingan Data Aktual dan Hasil Ramalan Beban Listrik Menggunakan Metode ARIMAX pada Skenario 1




**Gambar 4.4** Perbandingan Data Aktual dan Hasil Ramalan Beban Listrik Menggunakan Metode ARIMAX pada Skenario 1 (Lanjutan)

Selanjutnya dilakukan pemodelan dengan menggunakan *Deep Learning Neural Network* (DLNN) pada data simulasi untuk skenario 1. Arsitektur jaringan yang digunakan adalah dua *hidden layer* dengan jumlah neuron 1 sampai dengan 5. Dilakukan replikasi sebanyak 10 kali untuk mendapatkan nilai pembobot (*weight*) terbaik. Menggunakan algoritma *backpropagation* dengan fungsi aktivasi sigmoid untuk *hidden layer* dan fungsi aktivasi linier/*identity* untuk *output layer*. Penentuan input dilakukan berdasarkan lag yang signifikan pada PACF serta *dummy* tren, hari dan variasi kalender seperti pada metode ARIMAX selumnya. Berikut merupakan plot PACF pada data simulasi untuk jam 20:00:



**Gambar 4.5** Plot PACF pada Jam 20:00

Berdasarkan plot PACF pada jam 20:00, terdapat 15 lag yang signifikan yaitu pada lag 1, lag 2, lag 3, lag 4, lag 5, lag 6, lag 7, lag 10, lag 13, lag 14, lag 17, lag 20, lag 21, lag 27 dan lag 41. Berdasarkan nilai RMSE terkecil, arsitektur DLNN yang optimum didapatkan dengan jumlah neuron pada *hidden layer* 1 sebanyak 1 dan jumlah neuron pada *hidden layer* 2 sebanyak 5. Persamaan model DLNN untuk jam 20:00 pada skenario 1 sebagai berikut:



**Gambar 4.6** Arsitektur DLNN Jam 20:00 pada Skenario 1

$$\hat{Y}_{22,t}^* = 0,81 + 1,00f_1^{h_2}(\cdot) + 1,23f_2^{h_2}(\cdot) - 1,61f_3^{h_2}(\cdot) + 0,14f_4^{h_2}(\cdot) - 1,61f_5^{h_2}(\cdot)$$

dengan

$$f_1^{h_2}(\cdot) = (1 + \exp(-(0,97 + 5,08f_1^h(\cdot))))^{-1}$$

$$f_2^{h_2}(\cdot) = (1 + \exp(-2,87 - 2,27f_1^h(\cdot)))^{-1}$$

$$f_3^{h_2}(\cdot) = (1 + \exp(-0,76 + 29,15f_1^h(\cdot)))^{-1}$$

$$f_4^{h_2}(\cdot) = (1 + \exp(-0,38 - 31,04f_1^h(\cdot)))^{-1}$$

$$f_5^{h_2}(\cdot) = (1 + \exp(-0,93 + 3,40f_1^h(\cdot)))^{-1}$$

dengan


$$f_1^h(\cdot) = (1 + \exp(-(4,22 - 1,11Z_{t-1} - 0,11Z_{t-2} - 0,02Z_{t-3} + \dots + Z_{t-25})))^{-1}$$

Dengan cara yang sama, arsitektur DLNN yang optimum pada jam 04:00, 08:00, 12:00, 16:00, 20:00 dan 24:00 pada skenario 1 sebagai berikut:

**Tabel 4.4** Arsitektur DLLN Optimum pada Skenario 1

Jam	Input (Lag)	Jumlah Neuron di Hidden Layer	
		1	2
04:00	1,2,3,4,5,6,7,12,14,20,41	2	4
08:00	1,2,3,4,6,7,8,10,13,14,15,20,21,22,27,28,29,35,36,41,42,43	1	5
12:00	1,2,3,4,6,7,8,13,14,15,20,21,22,27,28,29,35,36,41,42,43	2	3
16:00	1,3,4,5,6,7,8,9,13,14,15,20,21,22,27,28,29,35,36,41,42,43	5	4
20:00	1,2,3,4,5,6,7,10,13,14,17,20,21,27,41	1	5
24:00	1,2,3,4,5,6,7,11,12,14,19,20,21,28,33,41	1	2

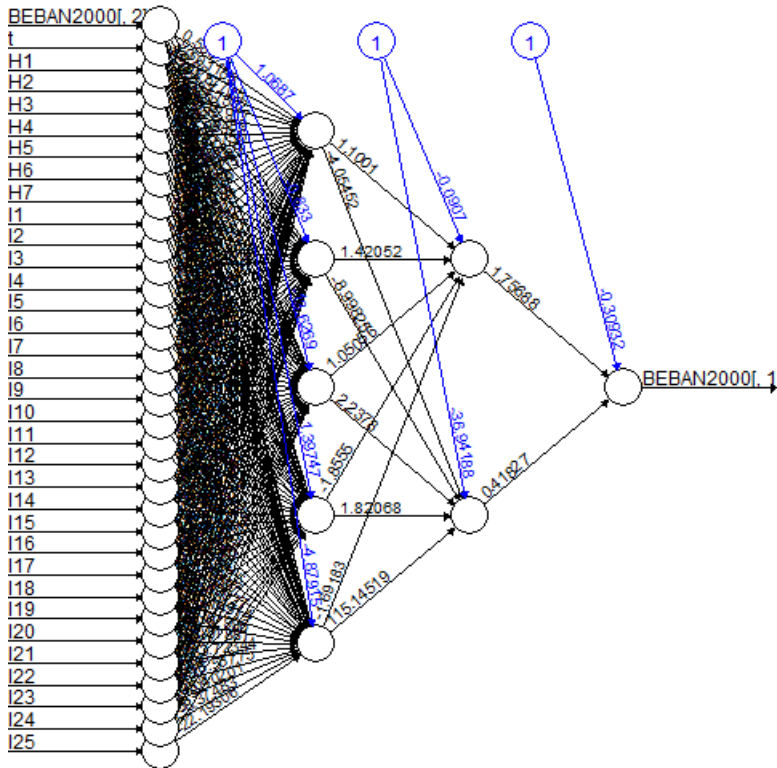
Berikut merupakan perbandingan data simulasi aktual dengan hasil ramalan dengan menggunakan metode *Deep Learning Neural Network* :



**Gambar 4.7** Perbandingan Data Aktual dan Hasil Ramalan Beban Listrik Menggunakan Metode DLNN pada Skenario 1

Pemodelan selanjutnya adalah dengan menggunakan metode Hibrida ARIMAX dan *Deep Learning Neural Network*. Pemodelan dimulai dengan memodelkan data secara linier menggunakan ARIMAX. Dari pemodelan ARIMAX akan didapatkan residual, residual tersebut akan dimodelkan menggunakan DLNN. Input yang akan digunakan dalam memodelkan residual dengan metode DLNN adalah model yang didapatkan dari ARIMAX serta *dummy* tren, hari dan variasi kalender. Model ARIMAX yang diperoleh pada skenario 1 adalah AR (1) sehingga inputnya adalah lag 1 ditambah dengan 1

*dummy* tren, 7 *dummy* hari dan 25 *dummy* variasi kalender, sehingga input DLNN sebanyak 34 input. Sama halnya dengan DLNN, arsitektur Hibrida ARIMAX dan DLNN menggunakan dua *hidden layer* dimana masing-masing *hidden layer* memiliki jumlah neuron 1 sampai dengan 5. Replikasi dilakukan sebanyak 10 kali untuk mendapatkan pembobot (*weight*) terbaik. Menggunakan algoritma *backpropagation* dengan fungsi aktivasi sigmoid untuk *hidden layer* dan fungsi aktivasi linier/*identity* untuk *output layer*. Berdasarkan nilai RMSE terkecil, arsitektur Hibrida ARIMAX dan DLNN yang optimum pada jam 20:00 adalah dengan jumlah neuron pada *hidden layer* 1 sebanyak 5 dan jumlah neuron pada *hidden layer* 2 sebanyak 2. Arsitektur serta persamaan model Hibrida ARIMAX dan DLNN untuk jam 20:00 pada skenario 1 sebagai berikut:



**Gambar 4.8** Arsitektur Hibrida ARIMAX & DLNN Jam 20:00 pada Skenario 1  
 $\hat{Y}_{22,t}^* = \hat{L}_t + \hat{N}_t$  dengan  $\hat{N}_t^*$  = *normalized* dari  $\hat{N}_t$

dimana:

$$\begin{aligned} \hat{L}_t = & 0,10I_t + 734,15H_{1,t} + 730,00H_{2,t} + 729,62H_{3,t} + 736,95H_{4,t} + 735,99H_{5,t} \\ & + 718,69H_{6,t} + 718,26H_{7,t} - 32,33I_{1,t} - 33,20I_{2,t} - 1,75I_{3,t} - 137,91I_{4,t} \\ & - 259,03I_{5,t} - 4,91I_{6,t} + 32,13I_{7,t} - 7,12I_{8,t} - 8,63I_{9,t} + 11,40I_{10,t} + 32,44I_{11,t} \\ & - 80,63I_{12,t} - 56,57I_{13,t} - 27,71I_{14,t} - 26,76I_{15,t} - 16,39I_{16,t} - 2,10I_{17,t} \\ & + 13,06I_{18,t} - 7,55I_{19,t} - 5,31I_{20,t} - 30,77I_{21,t} - 40,94I_{22,t} - 28,55I_{23,t} \\ & + 40,02I_{24,t} + 3,14I_{25,t} + \frac{1}{(1-0,71B)} a_t \end{aligned}$$

$$\hat{N}_t^* = -0,31 + 1,75f_1^{h_2}(\cdot) + 0,42f_2^{h_2}(\cdot)$$

dengan

$$f_1^{h_2}(\cdot) = (1 + \exp(-(-0,09 + 1,10f_1^{h_1}(\cdot) + 1,42f_2^{h_1}(\cdot) + 1,05f_3^{h_1}(\cdot) - 1,86f_4^{h_1}(\cdot) - 1,69f_5^{h_1}(\cdot))))^{-1}$$

$$f_2^{h_2}(\cdot) = (1 + \exp(-(-36,94 - 4,05f_1^{h_1}(\cdot) - 8,99f_2^{h_1}(\cdot) + 2,23f_3^{h_1}(\cdot) + 1,82f_4^{h_1}(\cdot) + 115,15f_5^{h_1}(\cdot))))^{-1}$$

dengan

$$f_1^{h_1}(\cdot) = (1 + \exp(-(-1,07 + 0,59Z_{t-1} + 0,01Z_{t-2} - 1,58Z_{t-3} + \dots \quad 25)))^{-1}$$

$$f_2^{h_1}(\cdot) = (1 + \exp(-(-0,83 + 9,56Z_{t-1} - 0,64Z_{t-2} + 0,10Z_{t-3} + \dots \quad I_{25})))^{-1}$$

$$f_3^{h_1}(\cdot) = (1 + \exp(-(-13,63 + 10,87Z_{t-1} + 1,10Z_{t-2} + 39,08Z_{t-3} + \dots \quad 25)))^{-1}$$

$$f_4^{h_1}(\cdot) = (1 + \exp(-(-1,39 - 0,09Z_{t-1} + 0,0001Z_{t-2} - 0,30Z_{t-3} + \dots \quad 25)))^{-1}$$


$$f_5^{h_1}(\cdot) = (1 + \exp(-(-4,88 + 3,21Z_{t-1} + 0,08Z_{t-2} - 6,59Z_{t-3} + \dots \quad I_{25})))^{-1}$$

Dengan cara yang sama, arsitektur Hibrida ARIMAX dan DLNN yang optimum pada jam 04:00, 08:00, 12:00, 16:00, 20:00 dan 24:00 pada skenario 1 sebagai berikut:

**Tabel 4.5** Arsitektur Hibrida ARIMAX dan DLLN Optimum pada Skenario 1


Jam	Input (Lag)	Jumlah Neuron di Hidden Layer	
		1	2
04:00	1	1	1
08:00	1	3	4
12:00	1	3	2
16:00	1	5	5
20:00	1	5	2
24:00	1	1	1

Berikut merupakan perbandingan data simulasi aktual dengan hasil ramalan dengan menggunakan metode Hibrida ARIMAX dan *Deep Learning Neural Network* :



**Gambar 4.9** Perbandingan Data Aktual dan Hasil Ramalan Beban Listrik Menggunakan Metode Hibrida ARIMAX dan DLNN pada Skenario 1







**Gambar 4.9** Perbandingan Data Aktual dan Hasil Ramalan Beban Listrik Menggunakan Metode Hibrida ARIMAX dan DLNN pada Skenario 1 (Lanjutan)

## 2. Skenario 2

Pada skenario 2, menggunakan *noise* yang memiliki pola nonlinier yaitu ESTAR(1). Berikut merupakan *time series plot* untuk data simulasi pada pukul 04.00, 08.00, 12.00, 16.00, 20.00 dan 24.00:



**Gambar 4.10** Data Simulasi Pukul (a) 04.00, (b) 08.00, (c) 12.00, (d) 16.00, (e) 20.00 dan (f) 24.00 pada Skenario 2



**Gambar 4.10** Data Simulasi Pukul (a) 04.00, (b) 08.00, (c) 12.00, (d) 16.00, (e) 20.00 dan (f) 24.00 pada Skenario 2 (Lanjutan)

Berdasarkan *time series plot* pada Gambar 4.10, sama seperti pada skenario 1 terlihat bahwa data memiliki pola tren naik, sementara untuk pola musiman tidak terlalu terlihat karena jumlah data yang digunakan sebesar 1096 data dimana merupakan data *training* selama 3 tahun mulai 1 Januari 2014 hingga 31 Desember 2016. Untuk variasi kalender yang terkandung pada skenario 2, terlihat jelas data yang memiliki nilai yang sangat rendah maupun nilai yang sangat tinggi disaat terjadinya hari raya.

Pemodelan menggunakan ARIMAX mengandung efek dari komponen tren, musiman, serta variasi kalender dengan menggunakan variabel *dummy*. Dilakukan regresi *time series* dengan prediktor variabel *dummy* dan respon yaitu simulasi data beban listrik per setengah jamnya. Hasil signifikansi parameter simulasi data beban listrik pada pukul 20.00 sebagai berikut:

**Tabel 4.6** Estimasi Paramater Regresi *Time Series* untuk Pukul 20:00

Variabel	Estimasi	SE	t-value	p-value
$\theta_7$	-0,07	0,031	-2,39	0,0172
$\phi_1$	0,25	0,03	8,31	<,0001
$\phi_2$	0,21	0,03	7,02	<,0001
$t$	0,11	0,003	37,56	<,0001
$H_{1,t}$	731,80	2,11	346,8	<,0001
$H_{2,t}$	728,05	2,12	342,6	<,0001
$H_{3,t}$	726,52	2,13	341,5	<,0001
$H_{4,t}$	734,58	2,13	344,3	<,0001
$H_{5,t}$	734,40	2,13	344,6	<,0001
$H_{6,t}$	714,00	2,13	334,6	<,0001
$H_{7,t}$	714,99	2,11	339,4	<,0001
$I_{1,t}$	-23,53	8,22	-2,86	0,0043
$I_{2,t}$	-23,53	7,11	-3,31	0,001
$I_{3,t}$	-8,31	8,23	-1,01	0,3128
$I_{4,t}$	-135,07	10,23	-13,21	<,0001
$I_{5,t}$	-250,84	8,40	-29,89	<,0001
$I_{6,t}$	-8,74	10,21	-0,86	0,3923
$I_{7,t}$	24,81	8,24	3,01	0,0027
$I_{8,t}$	-9,34	10,05	-0,93	0,3525
$I_{9,t}$	-16,00	10,04	-1,59	0,1114
$I_{10,t}$	-3,26	8,35	-0,39	0,6962
$I_{11,t}$	32,88	8,42	3,9	0,0001
$I_{12,t}$	-75,47	8,36	-9,03	<,0001
$I_{13,t}$	-66,23	8,34	-7,94	<,0001
$I_{14,t}$	-19,14	10,05	-1,9	0,0571
$I_{15,t}$	-16,94	10,04	-1,69	0,0919
$I_{16,t}$	-14,27	10,06	-1,42	0,1565
$I_{17,t}$	-6,10	10,14	-0,6	0,5476
$I_{18,t}$	16,22	8,20	1,98	0,0482
$I_{19,t}$	5,80	6,44	0,9	0,3677
$I_{20,t}$	-3,65	6,42	-0,57	0,5697
$I_{21,t}$	-32,14	6,72	-4,78	<,0001
$I_{22,t}$	-46,45	6,72	-6,91	<,0001
$I_{23,t}$	-37,31	6,75	-5,53	<,0001
$I_{24,t}$	32,52	6,56	4,96	<,0001
$I_{25,t}$	20,54	6,56	3,13	0,0018

Pada tabel 4.6 sebagian besar variabel memiliki  $p$ -value kurang dari  $\alpha$  (0,05) yang artinya bahwa variabel berpengaruh signifikan. Namun terdapat sebelas variabel yang memiliki  $p$ -value lebih dari  $\alpha$  (0,05) yang menandakan variabel tersebut tidak memiliki pengaruh yang signifikan.

Setelah dilakukan estimasi parameter pada regresi *time series*, selanjutnya dilakukan pengecekan residual dari regresi *time series* untuk mengetahui apakah pemodelan menggunakan ARIMA diperlukan atau tidak. Jika residual dari regresi *time series* sudah *white noise* dan berdistribusi normal maka tidak diperlukan pemodelan menggunakan ARIMA. Setelah didapatkan hasil estimasi parameter pada pukul 20:00, diketahui bahwa residual dari regresi *time series* memiliki model ARMA(2,0,[7]). Berdasarkan model dugaan, dilakukan pengujian untuk mengetahui apakah asumsi *white noise* dan berdistribusi normal terpenuhi atau tidak. Berikut merupakan pengujian asumsi residual model ARIMAX:

**Tabel 4.7** Pengujian Asumsi Residual ARIMAX pada Pukul 20:00

Uji <i>White Noise</i>				Uji Normalitas	
Hingga lag ke-	$\chi^2$	df	$p$ -value	$p$ -value	
6	4,39	3	0,2222	>0,1500	
12	7,54	9	0,581		
18	9,58	15	0,8455		
24	16,5	21	0,741		
36	26,78	33	0,7692		
48	32,86	45	0,9107		

Berdasarkan hasil pengujian asumsi pada tabel 4.7, asumsi *white noise* telah terpenuhi dimana seluruh lag telah signifikan dan asumsi residual berdistribusi normal juga telah terpenuhi dengan  $p$ -value 0,1500 dimana  $p$ -value lebih besar dari  $\alpha$ . Sehingga model persamaan dari data simulasi pada pukul 20:00 memiliki fungsi sebagai berikut:


$$\begin{aligned}
Y_{22,t} = & 0,11T_t + 731,80H_{1,t} + 728,05H_{2,t} + 726,52H_{3,t} + 734,58H_{4,t} + 734,40H_{5,t} \\
& + 714,00H_{6,t} + 714,99H_{7,t} - 23,53I_{1,t} - 23,53I_{2,t} - 8,31I_{3,t} - 135,07I_{4,t} \\
& - 250,84I_{5,t} - 8,74I_{6,t} - 24,81I_{7,t} - 9,34I_{8,t} - 16,00I_{9,t} - 3,26I_{10,t} \\
& - 32,88I_{11,t} - 75,47I_{12,t} - 66,23I_{13,t} - 19,14I_{14,t} - 16,94I_{15,t} - 14,27I_{16,t} \\
& - 6,10I_{17,t} + 16,22I_{18,t} + 5,80I_{19,t} - 3,65I_{20,t} - 32,14I_{21,t} - 46,45I_{22,t} \\
& - 37,31I_{23,t} + 32,52I_{24,t} + 20,54I_{25,t} + \frac{(1+0,07B^4)}{(1-0,25B)(1-0,21B^2)} a_t
\end{aligned}$$

Dengan cara yang sama, berikut merupakan pendugaan model untuk data simulasi pada pukul 04:00, 08:00, 12:00, 16:00, 20:00 dan 24:00 :

**Tabel 4.8** Model ARIMAX untuk Pukul 04:00, 08:00, 12:00, 16:00, 20:00 dan 24:00

Jam	Model	Residual <i>White noise</i>	Berdistribusi normal
04:00	ARMA([2,30],0,[1,3])	Ya	Ya
08:00	ARMA([2],0,[1,30,70])	Ya	Ya
12:00	ARMA(2,0,[4])	Ya	Ya
16:00	ARMA([2],0,[1,50])	Ya	Ya
20:00	ARMA(2,0,[7])	Ya	Ya
24:00	ARMA(0,0,2)	Ya	Ya


Tabel 4.8 menunjukkan model dugaan ARIMA untuk residual regresi *time series* pada skenario 2 yang telah memenuhi asumsi *white noise* dan berdistribusi normal. Berdasarkan hasil peramalan menggunakan metode ARIMAX diatas, berikut merupakan perbandingan data aktual dan data ramalan pada skenario 2:



**Gambar 4.11** Perbandingan Data Aktual dan Hasil Ramalan Beban Listrik Menggunakan Metode ARIMAX pada Skenario 2


Selanjutnya dilakukan pemodelan dengan menggunakan *Deep Learning Neural Network* (DLNN) pada data simulasi untuk skenario 2. Arsitektur jaringan yang digunakan adalah dua *hidden layer* dengan jumlah neuron 1 sampai dengan 5. Dilakukan replikasi sebanyak 10 kali untuk mendapatkan nilai pembobot (*weight*) terbaik. Menggunakan algoritma *backpropagation* dengan fungsi aktivasi sigmoid untuk *hidden layer* dan fungsi aktivasi linier/*identity* untuk *output layer*. Penentuan input dilakukan berdasarkan lag yang signifikan pada PACF serta *dummy* tren, hari dan variasi kalender seperti pada

metode ARIMAX selumnya. Berikut merupakan plot PACF pada data simulasi untuk jam 20:00:



**Gambar 4.12** Plot PACF pada Jam 20:00

Berdasarkan plot PACF pada jam 20:00, terdapat 14 lag yang signifikan yaitu lag 1, lag 2, lag 3, lag 4, lag 5, lag 6, lag 7, lag 10, lag 13, lag 14, lag 20, lag 21, lag 24 dan lag 28. Berdasarkan nilai RMSE terkecil, arsitektur DLNN yang optimum didapatkan dengan jumlah neuron pada *hidden layer* 1 sebanyak 1 dan jumlah neuron pada *hidden layer* 2 sebanyak 1. Persamaan model DLNN sebagai berikut:



**Gambar 4.13** Arsitektur DLNN Jam 20:00 pada Skenario 2

$$\hat{Y}_{22,t}^* = -0,28 + 1,99 f_1^{hs}(\cdot)$$

dengan

$$f_1^{hs}(\cdot) = (1 + \exp(-(-1,49 + 3,25 f_1^h(\cdot))))^{-1}$$

dengan

$$f_1^h(\cdot) = (1 + \exp(-(-0,34 + 0,52Z_{t-1} + 0,22Z_{t-2} - 0,03Z_{t-3} + \dots + I_{25})))^{-1}$$


Dengan cara yang sama, arsitektur DLNN yang optimum pada jam 04:00, 08:00, 12:00, 16:00, 20:00 dan 24:00 pada skenario 2 sebagai berikut:




**Tabel 4.9** Arsitektur DLLN Optimum pada Skenario 2

Jam	Input (Lag)	Jumlah Neuron di <i>Hidden Layer</i>	
		1	2
04:00	1,2,3,4,5,6,7,8,10,12,20,21	1	5
08:00	1,2,3,4,5,6,7,10,11,13,14, 17,21,28,30,42,43	3	4
12:00	1,2,3,4,6,7,8,10,11,13,14, 15,21,22,27,28,29,35,42	1	3
16:00	1,2,3,4,5,6,7,8,10,13,14,15, 20,21,27,28,29,35,42,44	1	6
20:00	1,2,3,4,5,6,7,10,13,14,20,21, 24,28	1	1
24:00	1,2,3,4,5,6,7,8,11,12,13,14, 20,26,28,36	1	4

Berikut merupakan perbandingan data simulasi aktual dengan hasil ramalan dengan menggunakan metode *Deep Learning Neural Network* :




**Gambar 4.14** Perbandingan Data Aktual dan Hasil Ramalan Beban Listrik Menggunakan Metode DLNN pada Skenario 2



**Gambar 4.14** Perbandingan Data Aktual dan Hasil Ramalan Beban Listrik Menggunakan Metode DLNN pada Skenario 2 (Lanjutan)

Pemodelan selanjutnya adalah dengan menggunakan metode Hibrida ARIMAX dan *Deep Learning Neural Network*. Pemodelan dimulai dengan memodelkan data secara linier menggunakan ARIMAX. Dari pemodelan ARIMAX akan didapatkan residual, residual tersebut akan dimodelkan menggunakan DLNN. Input yang akan digunakan dalam memodelkan residual dengan metode DLNN adalah model yang didapatkan dari ARIMAX serta *dummy* tren, hari dan variasi kalender. Model ARIMAX yang diperoleh pada skenario 2 adalah ESTAR (1) ditambah dengan 1 *dummy* tren, 7 *dummy* hari dan 25 *dummy* variasi kalender. Sama halnya dengan DLNN, arsitektur Hibrida ARIMAX dan DLNN menggunakan dua *hidden layer* dimana masing-masing *hidden layer* memiliki jumlah neuron 1 sampai dengan 5. Replikasi dilakukan sebanyak 10 kali untuk mendapatkan pembobot (*weight*) terbaik. Menggunakan algoritma *backpropagation* dengan fungsi aktivasi sigmoid untuk *hidden layer* dan fungsi aktivasi linier/*identity* untuk *output layer*. Berdasarkan nilai RMSE terkecil, arsitektur Hibrida ARIMAX dan DLNN yang optimum pada jam 20:00 adalah dengan jumlah neuron pada *hidden layer* 1 sebanyak 2 dan jumlah neuron pada *hidden layer* 2 sebanyak 2. Persamaan model Hibrida ARIMAX dan DLNN untuk jam 20:00 pada skenario 2 sebagai berikut:



**Gambar 4.15** Arsitektur Hibrida ARIMAX & DLNN Jam 20:00 pada Skenario 2

$$\hat{Y}_{22,t}^* = \hat{L}_t + \hat{N}_t \quad \text{dengan } \hat{N}_t^* = \text{normalized dari } \hat{N}_t$$

dimana:

$$\begin{aligned} \hat{L}_t = & 0,11I_t + 731,80H_{1,t} + 728,05H_{2,t} + 726,52H_{3,t} + 734,58H_{4,t} + 734,40H_{5,t} \\ & + 714,00H_{6,t} + 714,99H_{7,t} - 23,53I_{1,t} - 23,53I_{2,t} - 8,31I_{3,t} - 135,07I_{4,t} \\ & - 250,84I_{5,t} - 8,74I_{6,t} - 24,81I_{7,t} - 9,34I_{8,t} - 16,00I_{9,t} - 3,26I_{10,t} \\ & - 32,88I_{11,t} - 75,47I_{12,t} - 66,23I_{13,t} - 19,14I_{14,t} - 16,94I_{15,t} - 14,27I_{16,t} \\ & - 6,10I_{17,t} + 16,22I_{18,t} + 5,80I_{19,t} - 3,65I_{20,t} - 32,14I_{21,t} - 46,45I_{22,t} \\ & - 37,31I_{23,t} + 32,52I_{24,t} + 20,54I_{25,t} + \frac{(1+0,07B^4)}{(1-0,25B)(1-0,21B^2)} a_t \end{aligned}$$

$$\hat{N}_t^* = 0,22 - 0,50f_1^{h_2}(\cdot) + 1,51f_2^{h_2}(\cdot)$$

dengan

$$f_1^{h_2}(\cdot) = (1 + \exp(-(1,78 + 13,05f_1^h(\cdot) - 51,79f_2^h(\cdot))))^{-1}$$

$$f_2^{h_2}(\cdot) = (1 + \exp(-(-0,78 + 0,85f_1^h(\cdot) - 1,68f_2^h(\cdot))))^{-1}$$

dengan

$$f_1^h(\cdot) = (1 + \exp(-(3,45 - 12,97Z_{t-1} - 26,50Z_{t-2} + 1,05Z_{t-3} + \dots - I_{25})))^{-1}$$


$$f_2^h(\cdot) = (1 + \exp(-(-9,43 + 8,25Z_{t-1} + 2,88Z_{t-2} + 0,04Z_{t-3} + \dots - I_{25})))^{-1}$$

Dengan cara yang sama, arsitektur Hibrida ARIMAX dan DLNN yang optimum pada jam 04:00, 08:00, 12:00, 16:00, 20:00 dan 24:00 pada skenario 2 sebagai berikut:


**Tabel 4.10** Arsitektur Hibrida ARIMAX dan DLLN Optimum pada Skenario 2

Jam	Input (Lag)	Jumlah Neuron di <i>Hidden Layer</i>	
		1	2
04:00	2,30	4	3
08:00	2	1	4
12:00	1,2	3	2
16:00	2	4	1
20:00	1,2	2	2
24:00	1	3	1

Berikut merupakan perbandingan data simulasi aktual dengan hasil ramalan dengan menggunakan metode Hibrida ARIMAX dan *Deep Learning Neural Network* :



**Gambar 4.16** Perbandingan Data Aktual dan Hasil Ramalan Beban Listrik Menggunakan Metode Hibrida ARIMAX dan DLNN pada Skenario 2



**Gambar 4.16** Perbandingan Data Aktual dan Hasil Ramalan Beban Listrik Menggunakan Metode Hibrida ARIMAX dan DLNN pada Skenario 2 (Lanjutan)

#### 4.1.2 Hasil Simulasi

Setelah dilakukan simulasi data bangkitan dengan menggunakan dua skenario yaitu dengan pola linier AR(1) dan pola nonlinier ESTAR(1), berikut merupakan nilai RMSE *Training* dan *Testing* serta sMAPE *Training* dan *Testing* untuk 365 hari kedepan dari kedua skenario:

**Tabel 4.11** Nilai RMSE dan sMAPE Metode ARIMAX pada Dua Skenario

Jam	Skenario1		Skenario2	
	RMSE	RMSE	RMSE	RMSE
	<i>Training</i>	<i>Testing</i>	<i>Training</i>	<i>Testing</i>
04:00	4,81	8,22	15,00	17,06
08:00	5,05	6,82	15,21	16,24
12:00	4,77	7,42	15,29	17,06
16:00	4,79	6,34	15,19	16,17
20:00	4,78	7,20	14,68	17,94
24:00	4,90	7,72	15,16	17,45
Jam	sMAPE	sMAPE	sMAPE	sMAPE
	<i>Training</i>	<i>Testing</i>	<i>Training</i>	<i>Testing</i>
04:00	0,74	1,13	2,36	2,27
08:00	0,67	0,82	2,09	1,93
12:00	0,55	0,77	1,81	1,78
16:00	0,55	0,65	1,79	1,69
20:00	0,48	0,68	1,53	1,70
24:00	0,65	0,94	2,08	2,02

Berdasarkan tabel 4.7 terlihat bahwa skenario 1 memiliki nilai RMSE dan sMAPE *Training* maupun *Testing* lebih kecil dibandingkan dengan skenario 2, hal ini menunjukkan bahwa metode ARIMAX memiliki hasil yang lebih baik saat diterapkan pada data yang memiliki pola linier. Sehingga untuk mengatasi pola nonlinier akan dilanjutkan dengan menggunakan metode *Deep Learning Neural Network* serta Hibrida ARIMAX dan *Deep Learning Neural Network*.

**Tabel 4.12** Nilai RMSE pada Ketiga Metode

Skenario	Jam	ARIMAX		DLNN		Hibrida ARIMAX & DLNN	
		Train	Test	Train	Test	Train	Test
1	04:00	4,81	8,22	5,98	9,81	4,80	8,19
	08:00	5,05	6,82	6,16	8,24	4,96	6,70
	12:00	4,77	7,42	4,99	7,66	4,72	7,40
	16:00	4,79	6,34	4,81	7,48	4,69	6,18
	20:00	4,78	7,20	5,85	8,15	4,67	7,12
	24:00	4,90	7,72	6,00	8,48	4,89	7,70
2	04:00	15,00	17,06	14,99	17,49	14,45	17,05
	08:00	15,21	16,24	15,10	17,22	15,19	16,24
	12:00	15,29	17,06	15,42	17,27	15,00	17,03
	16:00	15,19	16,17	15,46	16,29	14,93	16,17
	20:00	14,68	17,94	15,14	17,03	14,57	17,58
	24:00	15,16	17,45	15,11	17,98	14,96	17,28

**Tabel 4.13** Nilai sMAPE pada Ketiga Metode

Skenario	Jam	ARIMAX		DLNN		Hibrida ARIMAX & DLNN	
		Train	Test	Train	Test	Train	Test
1	04:00	0,74	1,13	0,90	1,30	0,73	1,12
	08:00	0,67	0,82	0,79	0,96	0,65	0,80
	12:00	0,55	0,77	0,56	0,80	0,53	0,76
	16:00	0,55	0,65	0,54	0,78	0,52	0,63
	20:00	0,48	0,68	0,58	0,76	0,46	0,67
	24:00	0,65	0,94	0,76	1,01	0,64	0,94
2	04:00	2,36	2,27	2,33	2,36	2,21	2,27
	08:00	2,09	1,93	2,00	2,06	2,08	1,93
	12:00	1,81	1,78	1,77	1,78	1,74	1,77
	16:00	1,79	1,69	1,80	1,70	1,72	1,69
	20:00	1,53	1,70	1,54	1,60	1,50	1,66
	24:00	2,08	2,02	2,03	2,10	2,02	2,00

Berdasarkan hasil perbandingan nilai RMSE dan sMAPE untuk 365 hari kedepan, didapatkan bahwa metode yang menghasilkan model terbaik pada kedua skenario adalah metode

Hibrida ARIMAX dan DLNN. Pada skenario 1 setelah metode Hibrida, metode ARIMAX menghasilkan model terbaik diikuti oleh DLNN. Hal tersebut dikarenakan data pada skenario 1 memiliki pola linier yaitu AR(1) sehingga metode ARIMAX lebih baik digunakan daripada metode DLNN. Sementara untuk skenario 2, terdapat 1 data yaitu di jam 20:00 dimana metode DLNN menjadi yang terbaik diikuti oleh hibrida dan selanjutnya oleh ARIMAX. Sedangkan 5 data lainnya Hibrida menjadi metode terbaik diikuti oleh ARIMAX dan selanjutnya oleh DLNN. Skenario 2 memiliki pola nonlinier, namun ARIMAX ternyata lebih mampu menghasilkan model yang lebih baik daripada DLNN. Hasil yang sama juga ditunjukkan pada jurnal berjudul *Statistical and Machine Learning Forecasting Methods: Concern and Ways Forward* yang dilakukan oleh Makridakis, Spiliotis & Assimakopoulos (2018). Dimana 7 metode statistika yang digunakan memiliki akurasi yang lebih baik dibandingkan metode *Machine Learning*. Hal ini dikarenakan metode *Machine Learning* belum diketahui apakah mampu untuk membedakan noise dengan baik dari pola data.

Selanjutnya dilakukan perbandingan akurasi dengan menggunakan tiga horizon yaitu *short* (7 hari kedepan), *medium* (6 bulan kedepan/181 hari kedepan) dan *long* (12 bulan kedepan/365 hari kedepan) untuk ketiga metode pada skenario 1 dan 2 menggunakan RMSE *testing*. Hasil Berikut merupakan hasil akurasi serta metode terbaik yang diperoleh pada ketiga horizon untuk skenario 1 dan 2:



Tabel 4.14 Nilai RMSEP pada Ketiga Horizon untuk Skenario 1

Jam	Metode	Short	Medium	Long	Average
04:00	ARIMAX	5,47	7,20	8,22	6,96
	DLNN	7,14	7,83	9,81	8,26
	Hibrida ARIMAX-DLNN	5,55	7,19	8,19	6,98
08:00	ARIMAX	6,31	7,03	6,82	6,72
	DLNN	5,55	8,38	8,24	7,39
	Hibrida ARIMAX-DLNN	6,40	6,93	6,70	6,68
12:00	ARIMAX	5,05	7,17	7,42	6,55
	DLNN	6,01	7,14	7,66	6,94
	Hibrida ARIMAX-DLNN	5,14	7,13	7,40	6,56
16:00	ARIMAX	5,09	6,50	6,34	5,98
	DLNN	4,64	7,26	7,48	6,46
	Hibrida ARIMAX-DLNN	5,14	6,43	6,18	5,92
20:00	ARIMAX	9,75	8,03	7,20	8,33
	DLNN	12,87	7,99	8,15	9,67
	Hibrida ARIMAX-DLNN	9,61	7,89	7,12	8,21
24:00	ARIMAX	5,63	7,48	7,72	6,94
	DLNN	7,67	8,52	8,48	8,22
	Hibrida ARIMAX-DLNN	5,55	7,45	7,70	6,9

Tabel 4.15 Metode Terbaik pada Ketiga Horizon untuk Skenario 1

Jam	Metode Terbaik		
	Short	Medium	Long
04:00	ARIMAX	Hibrida	Hibrida
08:00	DLNN	Hibrida	Hibrida
12:00	ARIMAX	Hibrida	Hibrida
16:00	DLNN	Hibrida	Hibrida
20:00	Hibrida	Hibrida	Hibrida
24:00	Hibrida	Hibrida	Hibrida

Pada skenario 1, untuk horizon *medium* dan *long* metode terbaik yang didapatkan adalah metode Hibrida ARIMAX-DLNN. Sedangkan untuk horizon *short* hasil yang didapatkan lebih beragam.

Tabel 4.16 Nilai RMSEP pada Ketiga Horizon untuk Skenario 2

Jam	Metode	Short	Medium	Long	Average
04:00	ARIMAX	18,41	17,01	17,06	17,50
	DLNN	20,59	17,88	17,49	18,65
	Hibrida ARIMAX-DLNN	18,64	17,02	17,05	17,57
08:00	ARIMAX	15,98	16,19	16,24	16,14
	DLNN	16,25	16,45	17,22	16,64
	Hibrida ARIMAX-DLNN	16,14	16,20	16,24	16,19
12:00	ARIMAX	13,34	16,97	17,06	15,79
	DLNN	13,84	17,32	17,27	16,14
	Hibrida ARIMAX-DLNN	13,46	16,96	17,03	15,82
16:00	ARIMAX	15,26	16,57	16,17	16
	DLNN	16,92	15,93	16,29	16,38
	Hibrida ARIMAX-DLNN	15,20	16,56	16,17	15,98
20:00	ARIMAX	18,40	18,85	17,94	18,40
	DLNN	21,16	17,67	17,03	18,62
	Hibrida ARIMAX-DLNN	17,63	18,43	17,58	17,88
24:00	ARIMAX	14,08	17,60	17,45	16,38
	DLNN	13,96	18,70	17,98	16,88
	Hibrida ARIMAX-DLNN	13,65	17,42	17,28	16,12

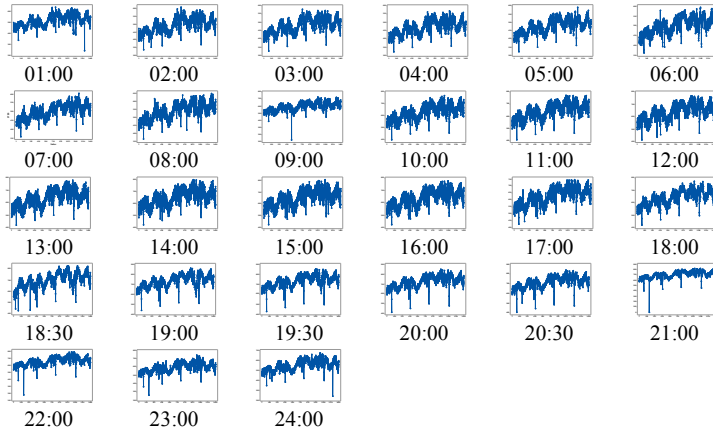
Tabel 4.17 Metode Terbaik pada Ketiga Horizon untuk Skenario 2

Jam	Metode Terbaik		
	Short	Medium	Long
04:00	ARIMAX	ARIMAX	Hibrida
08:00	ARIMAX	ARIMAX	Hibrida
12:00	ARIMAX	Hibrida	Hibrida
16:00	Hibrida	DLNN	Hibrida
20:00	Hibrida	DLNN	DLNN
24:00	Hibrida	Hibrida	Hibrida

Untuk skenario 2, pada horizon *long* metode terbaik yang didapatkan pada 5 dari 6 jam adalah Hibrida. Hasil lebih beragam didapatkan pada horizon *short* dan *medium*, dimana pada horizon *medium* ketiga metode sebanding dan pada horizon *short* didominasi oleh ARIMAX dan Hibrida.

## 4.2 Karakteristik Data Beban Listrik

Digunakan data beban listrik per jam dan per setengah jam di wilayah Provinsi Bali. Berikut merupakan pola data beban listrik per jam dan per setengah jamnya mulai tahun 2014 hingga tahun 2017:



**Gambar 4.17** Time Series Plot Data Beban Listrik

Berdasarkan Gambar 4.17, terlihat data beban listrik memiliki pola tren naik. Efek variasi kalender juga sangat terlihat dari plot data beban listrik, dimana terdapat titik-titik yang terlihat sangat rendah. Untuk seluruh jamnya terlihat pula bahwa data beban listrik memiliki keragaman yang tinggi, hal tersebut menunjukkan adanya keragaman aktivitas penggunaan listrik yang terjadi setiap jamnya. Selanjutnya dilihat rata-rata penggunaan beban listrik per jam dan per setengah jamnya sebagai berikut:


**Tabel 4.18** Statistika Deskriptif Data Beban Listrik


Jam	Mean	Standar Deviasi	Jam	Mean	Standar Deviasi
Beban 01:00	516.58	47.99	Beban 15:00	656.3	64.1
Beban 02:00	495.58	44.31	Beban 16:00	644.52	61.01
Beban 03:00	480.67	42.24	Beban 17:00	629.53	56.47
Beban 04:00	471.84	40.7	Beban 18:00	644.43	54.74
Beban 05:00	477.4	39.92	Beban 18:30	700.02	60.64

**Tabel 4.14** Statistika Deskriptif Data Beban Listrik (Lanjutan)

Jam	Mean	Standar Deviasi	Jam	Mean	Standar Deviasi
Beban 06:00	502.35	37.86	Beban 19:00	731.67	56.44
Beban 07:00	503.31	37.58	Beban 19:30	732.18	53.73
Beban 08:00	539.83	45.49	Beban 20:00	726.31	53.32
Beban 09:00	597.57	54.9	Beban 20:30	716.82	54.02
Beban 10:00	634.94	57.06	Beban 21:00	704.76	56.98
Beban 11:00	648.7	58.49	Beban 22:00	656.82	54.98
Beban 12:00	643.32	59.54	Beban 23:00	596.65	52.69
Beban 13:00	644.43	61.05	Beban 24:00	550.58	49.73
Beban 14:00	658.58	64.1			

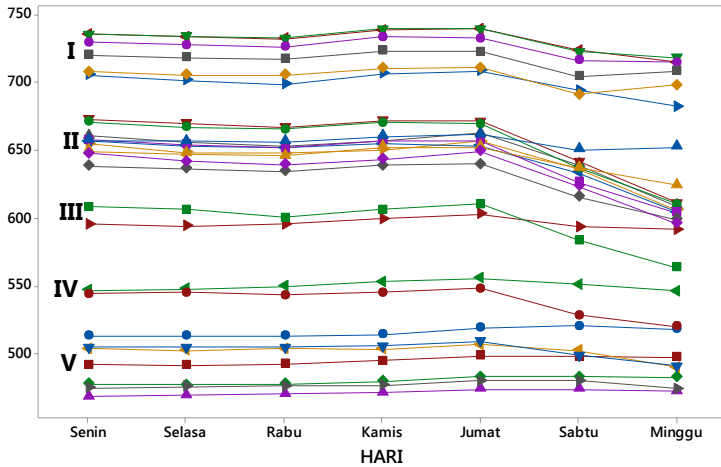

Berdasarkan tabel 4.14, terlihat bahwa penggunaan beban listrik tertinggi terjadi pada jam 19:30 dimana dapat disebut juga sebagai beban puncak. Hal tersebut dikarenakan aktifitas penggunaan listrik paling tinggi terjadi pada jam tersebut. Berikut merupakan plot dari rata-rata pemakaian beban listrik per jam dan per setengah jamnya:





**Gambar 4.18** Plot Rata-rata Pemakaian Beban Listrik Per Jam dan Per Setengah Jam

Berdasarkan gambar 4.18, terlihat beban listrik mulai mengalami kenaikan yang signifikan pada jam 07:00 hingga jam 11:00 dimana menunjukkan aktifitas mulai berjalan pada jam tersebut. Kenaikan aktifitas tersebut sebagian besar disebabkan oleh sekolah, perkantoran, tempat pariwisata dan instansi lainnya. Selanjutnya penggunaan listrik kembali mengalami penurunan pada jam 12:00 dikarenakan jam tersebut merupakan jam istirahat siang sehingga aktifitas mulai terhenti sementara. Penggunaan listrik kembali mengalami kenaikan dari jam 13:00 hingga 16:00 dikarenakan aktifitas kembali berjalan setelah istirahat siang, setelah itu pukul 17:00 kembali turun karena jam tersebut merupakan jam pulang kantor. Beban puncak mulai terjadi dari jam 18:00 hingga 20:30, pada jam tersebut penggunaan listrik paling optimal. Penggunaan listrik mengalami penurunan dari jam 21:00 hingga 06:00 dikarenakan aktifitas mulai terhenti pada jam tersebut. Berikut merupakan plot dari rata-rata pemakaian beban listrik per hari:



**Gambar 4.19** Plot Rata-rata Pemakaian Beban Listrik Per Hari

Keterangan :

I = Jam 18:30 – Jam 21:00

II = Jam 10:00 – Jam 18:00 dan Jam 22:00

III = Jam 09:00 dan Jam 23:00

IV = Jam 08:00 dan Jam 24:00

V = Jam 01:00 – Jam 07:00

Berdasarkan gambar 4.19, rata-rata penggunaan listrik tertinggi terjadi pada hari Kamis dan Jumat serta rata-rata penggunaan listrik terendah terjadi pada hari Minggu. Untuk masing-masing jamnya dibagi menjadi lima kelompok berdasarkan besar penggunaan listriknya. Kelompok I menunjukkan penggunaan listrik tertinggi dimana terjadi pada jam 18:30 hingga jam 21:00. Sementara kelompok V menunjukkan penggunaan listrik paling rendah yang terjadi pada jam 01:00 hingga jam 07:00. Untuk seluruh jamnya penggunaan listrik paling rendah terjadi pada hari Sabtu dan Minggu. Rendahnya rata-rata penggunaan listrik pada hari Minggu dikarenakan liburannya kantor-kantor dan sekolah. Hal ini menunjukkan bahwa hari libur berpengaruh terhadap penggunaan listrik di Provinsi Bali.

### 4.3 Pemodelan Data Beban Listrik dengan ARIMAX

Pemodelan beban listrik dengan metode ARIMAX memiliki langkah yang sama dengan kajian simulasi. Dilakukan regresi *time series* dengan prediktor variabel *dummy* dan respon yaitu data beban listrik per setengah jamnya. Hasil signifikansi parameter data beban listrik pada jam 20:00 sebagai berikut:

**Tabel 4.19** Estimasi Paramater Regresi *Time Series* Pukul 20:00

Variabel	Estimasi	SE	t-value	p-value
$\phi_1$	0,69	0,03	22,49	<,0001
$\phi_2$	0,11	0,03	3,65	0,0003
$\phi_7$	0,11	0,02	5,51	<,0001
$t$	0,13	0,02	7,7	<,0001
$H_{1,t}$	646,19	10,90	59,28	<,0001
$H_{2,t}$	644,23	10,89	59,17	<,0001
$H_{3,t}$	642,99	10,87	59,18	<,0001
$H_{4,t}$	647,49	10,89	59,44	<,0001
$H_{5,t}$	646,31	10,91	59,23	<,0001

**Tabel 4.15** Estimasi Paramater Regresi *Time Series* Pukul 20:00 (Lanjutan)

Variabel	Estimasi	SE	<i>t-value</i>	<i>p-value</i>
$\phi_1$	0,69	0,03	22,49	<,0001
$\phi_2$	0,11	0,03	3,65	0,0003
$\phi_7$	0,11	0,02	5,51	<,0001
$t$	0,13	0,02	7,7	<,0001
$H_{1,t}$	646,19	10,90	59,28	<,0001
$H_{2,t}$	644,23	10,89	59,17	<,0001
$H_{3,t}$	642,99	10,87	59,18	<,0001
$H_{4,t}$	647,49	10,89	59,44	<,0001
$H_{5,t}$	646,31	10,91	59,23	<,0001
$H_{6,t}$	630,51	10,91	57,78	<,0001
$H_{7,t}$	629,02	10,90	57,67	<,0001
$I_{1,t}$	-26,90	8,62	-3,12	0,0019
$I_{2,t}$	-22,73	7,37	-3,09	0,0021
$I_{3,t}$	-5,78	8,56	-0,67	0,5001
$I_{4,t}$	-115,67	11,09	-10,43	<,0001
$I_{5,t}$	-223,30	9,65	-23,13	<,0001
$I_{6,t}$	-28,67	11,09	-2,59	0,0099
$I_{7,t}$	-2,96	8,47	-0,35	0,7264
$I_{8,t}$	-4,83	10,38	-0,46	0,6422
$I_{9,t}$	6,68	10,31	0,65	0,5169
$I_{10,t}$	-10,55	8,56	-1,23	0,2184
$I_{11,t}$	-0,63	8,69	-0,07	0,9418
$I_{12,t}$	-21,61	9,32	-2,32	0,0207
$I_{13,t}$	-13,65	9,24	-1,48	0,14
$I_{14,t}$	-11,23	10,30	-1,09	0,2759
$I_{15,t}$	-19,11	10,31	-1,85	0,064
$I_{16,t}$	-9,37	10,30	-0,91	0,3635
$I_{17,t}$	-19,47	10,57	-1,84	0,0658
$I_{18,t}$	3,53	8,49	0,42	0,6777
$I_{19,t}$	-18,72	6,64	-2,82	0,0049
$I_{20,t}$	-16,42	6,60	-2,48	0,0131
$I_{21,t}$	-9,72	7,63	-1,27	0,2035
$I_{22,t}$	-38,60	8,31	-4,65	<,0001
$I_{23,t}$	-25,60	7,66	-3,34	0,0009
$I_{24,t}$	-1,13	7,38	-0,15	0,8779
$I_{25,t}$	-15,84	7,27	-2,18	0,0296



Pada tabel 4.15 terdapat beberapa variabel memiliki *p-value* kurang dari  $\alpha$  (0,05) yang artinya bahwa variabel berpengaruh signifikan. Namun terdapat banyak variabel yang memiliki *p-value* lebih dari  $\alpha$  (0,05) yang menandakan variabel tersebut tidak memiliki pengaruh yang signifikan. Banyaknya variabel yang tidak memiliki pengaruh yang signifikan dikarenakan efek variasi kalender tidak terlalu berpengaruh pada jam 20:00.

Setelah dilakukan estimasi parameter pada regresi *time series*, selanjutnya dilakukan pengecekan residual dari regresi *time series* untuk mengetahui apakah pemodelan menggunakan ARIMA diperlukan atau tidak. Jika residual dari regresi *time series* sudah *white noise* dan berdistribusi normal maka tidak diperlukan pemodelan menggunakan ARIMA. Setelah didapatkan hasil estimasi parameter pada jam 20:00, diketahui bahwa residual dari regresi *time series* memiliki model ARIMA([1,2,7],0,0). Berdasarkan model dugaan, dilakukan pengujian untuk mengetahui apakah asumsi *white noise* dan berdistribusi normal terpenuhi atau tidak. Berikut merupakan pengujian asumsi residual model ARIMAX:

**Tabel 4.20** Pengujian Asumsi Residual ARIMAX pada Jam 20:00


Uji <i>White Noise</i>				Uji
Hingga lag ke-	$\chi^2$	df	<i>p-value</i>	Normalitas
6	3,2	3	0,36	<0,0100
12	9,79	9	0,36	
18	14,09	15	0,52	
24	22,66	21	0,36	
36	45,46	33	0,07	
48	55,62	45	0,13	

Berdasarkan hasil pengujian asumsi pada tabel 4.16, asumsi *white noise* telah terpenuhi dimana seluruh lag telah signifikan, namun asumsi residual berdistribusi normal tidak terpenuhi dengan *p-value* 0,0100 dimana *p-value* lebih kecil dari  $\alpha$ . Hal ini diduga karena residual memiliki pola nonlinier, sehingga metode ARIMAX tidak cukup baik dalam mengatasi pola data tersebut.

Model persamaan dari data beban listrik pada jam 20:00 memiliki fungsi sebagai berikut:

$$\begin{aligned}
 Y_{22,t} = & 0,13I_t + 646,19H_{1,t} + 644,23H_{2,t} + 642,99H_{3,t} + 647,49H_{4,t} + 646,31H_{5,t} \\
 & + 630,51H_{6,t} + 629,02H_{7,t} - 26,90I_{1,t} - 22,73I_{2,t} - 5,78I_{3,t} - 115,67I_{4,t} \\
 & - 223,30I_{5,t} - 28,67I_{6,t} - 2,96I_{7,t} - 4,83I_{8,t} + 6,68I_{9,t} - 10,55I_{10,t} - 0,63I_{11,t} \\
 & - 21,61I_{12,t} - 13,65I_{13,t} - 11,23I_{14,t} - 19,11I_{15,t} - 9,37I_{16,t} - 19,47I_{17,t} + 3,53I_{18,t} \\
 & - 18,72I_{19,t} - 16,42I_{20,t} - 9,72I_{21,t} - 38,60I_{22,t} - 25,60I_{23,t} - 1,13I_{24,t} - 15,84I_{25,t} \\
 & + \frac{1}{(1-0,69B-0,11B^2-0,11B^7)} a_t
 \end{aligned}$$

Berdasarkan model ARIMAX yang telah didapatkan untuk jam 20:00, terlihat pada *dummy*  $I_5$  yang merupakan *dummy* Hari Raya Nyepi memiliki penurunan beban listrik paling besar. Hal tersebut dikarenakan dalam satu hari seluruh aktifitas serta penggunaan listrik dihentikan. Berikut merupakan perbandingan antara data aktual dan hasil ramalan pada data *training* dan *testing*:



**Gambar 4.20** Perbandingan Data Aktual dan Hasil Ramalan Beban Listrik pada Jam 20:00 Menggunakan Metode ARIMAX

Pada data *training*, hasil ramalan masih dapat mengikuti pola data aktual. Namun, pada *testing* hasil ramalan terlihat sangat jauh berbeda dengan data aktual. Hal ini dapat disebabkan karena efek variasi kalender tidak begitu berpengaruh pada jam 20:00.

Dengan cara yang sama, berikut merupakan pendugaan model ARIMAX untuk data beban listrik per setengah jamnya.

**Tabel 4.21** Model ARIMAX untuk Data Beban Listrik Per Setengah Jam

Jam	Model	Residual White noise	Berdistribusi normal
01:00	ARMA([1,2,3,7,11],0,0)	Ya	Tidak
02:00	ARMA([1,2,9],0,0)	Ya	Tidak
03:00	ARMA([1,2,9],0,0)	Ya	Tidak
04:00	ARMA([1,2,3,4,9],0,0)	Ya	Tidak
05:00	ARMA([1,2,9],0,0)	Ya	Tidak
06:00	ARMA([1,2,9],0,0)	Ya	Tidak
07:00	ARMA([1,2,5,9],0,0)	Ya	Ya
08:00	ARMA([1,2,4,7],0,0)	Ya	Tidak
09:00	ARMA([1,2,3,7,8,13],0,0)	Ya	Tidak
10:00	ARMA([1,2,7,10],0,0)	Ya	Tidak
11:00	ARMA([1,2,5,7,10,11,52],0,0)	Ya	Tidak
12:00	ARMA([1,2,7,10],0,0)	Ya	Tidak
13:00	ARMA([1,2,4,5,9],0,0)	Ya	Tidak
14:00	ARMA([1,2,4,5,7,9],0,0)	Ya	Tidak
15:00	ARMA([1,2,4,5,10],0,0)	Ya	Tidak
16:00	ARMA([1,2,6,10],0,0)	Ya	Tidak
17:00	ARMA([1,2,7],0,0)	Ya	Tidak
18:00	ARMA([1,2,5,7],0,0)	Ya	Tidak
18:30	ARMA([1,2,4,8,10,37],0,0)	Ya	Tidak
19:00	ARMA([1,2,7],0,0)	Ya	Tidak
19:30	ARMA([1,2,7],0,0)	Tidak	Tidak
20:00	ARMA([1,2,7],0,0)	Ya	Tidak
20:30	ARMA([1,2,7,12],0,0)	Ya	Tidak
21:00	ARMA([1,2,3,8,9,12],0,0)	Ya	Tidak
22:00	ARMA([1,2,3,8],0,0)	Ya	Tidak
23:00	ARMA([1,2,3,5,7,13],0,0)	Ya	Tidak
24:00	ARMA([1,2,8],0,0)	Tidak	Tidak

Setelah didapatkan model ARIMAX untuk beban listrik, berikut merupakan nilai RMSE dan sMAPE untuk masing-masing data *Training* dan *Testing*:


**Tabel 4.22** Nilai RMSE dan sMAPE Beban Listrik Per Setengah Jam

Jam	<i>Data Training</i>		<i>Data Testing</i>	
	RMSE	sMAPE	RMSE	sMAPE
01:00	16,80	2,46	68,75	10,09
02:00	16,45	2,49	59,17	9,34
03:00	15,03	2,42	57,00	9,22
04:00	14,79	2,41	55,15	9,16
05:00	13,79	2,29	52,79	8,72
06:00	14,00	2,15	49,84	7,89
07:00	12,49	1,96	43,32	6,64
08:00	15,53	2,16	51,32	7,54
09:00	22,17	2,28	66,89	8,28
10:00	16,43	1,96	63,25	7,88
11:00	16,44	1,94	66,57	8,07
12:00	18,41	2,06	71,70	8,65
13:00	17,55	2,08	77,35	9,34
14:00	19,93	2,22	78,50	9,22
15:00	20,12	2,30	77,17	9,00
16:00	19,48	2,23	71,27	8,52
17:00	17,63	2,10	65,56	8,01
18:00	17,17	2,03	63,37	7,48
18:30	20,99	2,08	82,55	9,46
19:00	16,54	1,68	85,64	9,49
19:30	17,52	1,77	79,61	8,94
20:00	17,54	1,83	73,10	7,98
20:30	18,49	1,90	74,06	8,13
21:00	27,77	2,31	71,92	7,95
22:00	24,57	2,49	69,76	8,32
23:00	21,95	2,59	67,69	8,93
24:00	17,55	2,45	69,80	9,77

Evaluasi kebaikan model dengan menggunakan RMSE dan sMAPE berdasarkan metode ARIMAX menunjukkan hampir seluruh jamnya masih memiliki nilai RMSE yang cukup tinggi, hal tersebut sesuai dengan gambar 4.19 dimana data aktual masih memiliki perbandingan yang cukup jauh dengan data ramalan berdasarkan metode ARIMAX.

#### 4.4 Pemodelan Data Beban Listrik dengan *Deep Learning Neural Network*


Pemodelan data beban listrik selanjutnya dilakukan dengan menggunakan metode *Deep Learning Neural Network*. Arsitektur jaringan yang digunakan adalah dua *hidden layer* dengan jumlah neuron satu sampai lima. Dilakukan replikasi sebanyak 10 kali untuk mendapatkan nilai pembobot (*weight*) terbaik. Menggunakan algoritma *backpropagation* dengan fungsi aktivasi sigmoid pada *hidden layer* dan fungsi aktivasi linier/*identity* pada *output layer*. Penentuan input dilakukan berdasarkan lag yang signifikan pada PACF serta *dummy* tren, hari dan variasi kalender seperti pada metode ARIMAX selumnya. Berikut merupakan plot PACF pada data simulasi untuk jam 20:00:



**Gambar 4.21** Plot PACF pada Jam 20:00

Berdasarkan plot PACF pada jam 20:00, terdapat 16 lag yang signifikan yaitu pada lag 1, lag 3, lag 4, lag 5, lag 6, lag 7, lag 9, lag 10, lag 13, lag 14, lag 15, lag 17, lag 20, lag 29, lag 34, dan lag 43. Setelah menentukan input berdasarkan plot PACF, dilakukan uji White untuk melihat apakah data memiliki hubungan linier atau nonlinier. Berdasarkan hasil uji White yang dilakukan didapatkan data menghasilkan hubungan linier. Berdasarkan nilai RMSE terkecil, arsitektur DLNN yang

optimum didapatkan dengan jumlah neuron pada *hidden layer 1* sebanyak 4 dan jumlah neuron pada *hidden layer 2* sebanyak 2. Persamaan model DLNN untuk jam 20:00 sebagai berikut:



**Gambar 4.22** Arsitektur DLNN Jam 20:00

$$\hat{Y}_{22,t}^* = -0,50 + 1,30 f_1^{h_2}(\cdot) + 0,21 f_2^{h_2}(\cdot)$$

dengan

$$f_1^{h_2}(\cdot) = (1 + \exp(-(0,92 + 1,09 f_1^{h_1}(\cdot) + 3,69 f_2^{h_1}(\cdot) - 1,38 f_3^{h_1}(\cdot) + 1,73 f_4^{h_1}(\cdot))))^{-1}$$

$$f_2^{h_2}(\cdot) = (1 + \exp(-(-4,09 + 2,76 f_1^{h_1}(\cdot) + 5,60 f_2^{h_1}(\cdot) - 2,40 f_3^{h_1}(\cdot) + 1,64 f_4^{h_1}(\cdot))))^{-1}$$

dengan


$$f_1^{h_1}(\cdot) = (1 + \exp(-(-3,62 - 5,76 Z_{t-1} + 8,36 Z_{t-2} + 1,52 Z_{t-3} + \dots \quad ; I_{25})))^{-1}$$

$$f_2^{h_1}(\cdot) = (1 + \exp(-(-1,97 + 6,75 Z_{t-1} - 9,88 Z_{t-2} - 4,25 Z_{t-3} + \dots \quad '_{25})))^{-1}$$

$$f_3^h(.) = (1 + \exp(-(4,43 + 1,34Z_{t-1} - 2,35Z_{t-2} - 1,66Z_{t-3} + \dots \quad 25)))^{-1}$$

$$f_4^h(.) = (1 + \exp(-(1,39 + 0,58Z_{t-1} + 1,50Z_{t-2} - 9,13Z_{t-3} + \dots \quad 9I_{25})))^{-1}$$

Berikut merupakan perbandingan data aktual dengan hasil ramalan dengan menggunakan metode *Deep Learning Neural Network* :



**Gambar 4.23** Perbandingan Data Aktual dan Hasil Ramalan Beban Listrik pada Jam 20:00 Menggunakan Metode DLNN

Penentuan arsitektur DLNN yang optimum untuk jam lainnya dilakukan dengan cara yang sama. Berikut arsitektur DLNN optimum untuk data aktual:

**Tabel 4.23** Arsitektur DLNN Optimum pada Data Aktual

Jam	Input (Lag)	Jumlah Neuron di Hidden Layer	
		1	2
01:00	1,2,3,4,5,6,7,11	5	2
02:00	1,2,3,5,6,8,9,12,20,26	2	4
03:00	1,2,4,5,6,9,11,12,28,30,44	3	4
04:00	1,2,4,5,6,8,9,12,17,20,28	5	1
05:00	1,2,3,4,5,6,8,9,14,17,23	3	1
06:00	1,2,3,5,6,7,9,10,14,15,17,20,22,28,35,37	4	3
07:00	1,2,3,4,5,6,7,8,13,14,15,18,20,21,22,23,36	5	2
08:00	1,2,3,4,5,6,7,8,10,13,14,15,16,17,20,21,22,28,35,36,37,48	5	4


**Tabel 4.19** Arsitektur DLLN Optimum pada Data Aktual (Lanjutan)

Jam	Input (Lag)	Jumlah Neuron di <i>Hidden Layer</i>	
		1	2
09:00	1,2,3,4,6,7,8,10,13,14,15,20,21,22,23,28,35,36,37	2	3
10:00	1,2,3,4,6,7,8,9,10,13,14,15,21,22,28,29,36,42,43	5	2
11:00	1,2,3,4,5,6,7,8,9,10,13,14,15,28,29,36,37,42	5	3
12:00	1,2,3,4,5,6,7,8,9,10,13,14,15,21,22,28,29,35,36,42	4	5
13:00	1,2,3,4,5,6,7,8,9,10,13,14,15,20,21,22,25,28,29,36,42	5	4
14:00	1,2,3,4,5,6,7,8,13,14,15,20,21,22,27,28,29,36,41,43	2	2
15:00	1,2,3,4,5,6,7,8,10,13,14,15,18,20,21,22,28,29,36,41,43	4	5
16:00	1,2,3,4,5,6,7,8,10,13,14,15,20,21,22,27,28,29,41,43	4	5
17:00	1,2,3,4,5,6,7,8,10,13,14,15,17,20,21,22,28,29,31,36,41,42,43	3	3
18:00	1,2,3,4,5,6,7,8,10,13,14,15,17,20,27,28,29,36	5	3
18:30	1,2,3,4,5,6,7,10,14,15,17,22,28,29,36,37	5	5
19:00	1,2,3,4,5,6,7,8,9,10,13,14,15,17,20,22,27,29,43	4	2
19:30	1,3,5,6,7,9,10,13,14,15,17,20,22,29,34,43	4	3
20:00	1,3,4,5,6,7,9,10,13,14,15,17,20,29,34,43	4	2
20:30	1,2,3,4,5,6,7,9,13,14,17,20,34,43	5	4
21:00	1,2,3,4,6,7,8,10,14,42	5	3
22:00	1,2,3,4,6,7,8,14,28,43	2	2
23:00	1,2,3,4,6,7,13,28	5	3
24:00	1,2,3,4,5,6,8,20	4	4



#### **4.5 Pemodelan Data Beban Listrik dengan Hibrida ARIMAX dan *Deep Learning Neural Network***

Sama seperti saat melakukan simulasi pemodelan selanjutnya adalah dengan menggunakan metode Hibrida ARIMAX dan *Deep Learning Neural Network*. Pemodelan dimulai dengan memodelkan data secara linier menggunakan ARIMAX. Dari pemodelan ARIMAX akan didapatkan residual, residual tersebut akan dimodelkan menggunakan DLNN. Input yang akan digunakan dalam memodelkan residual dengan metode DLNN adalah model yang didapatkan dari ARIMAX serta *dummy* tren, hari dan variasi kalender. Model ARIMAX yang diperoleh pada data aktual ditambah dengan 1 *dummy* tren, 7 *dummy* hari dan 25 *dummy* variasi kalender. Sama halnya dengan DLNN, arsitektur Hibrida ARIMAX dan DLNN menggunakan dua *hidden layer* dimana masing-masing *hidden layer* memiliki jumlah neuron 1 sampai dengan 5. Replikasi dilakukan sebanyak 10 kali untuk mendapatkan pembobot (*weight*) terbaik. Menggunakan algoritma *backpropagation* dengan fungsi aktivasi sigmoid untuk *hidden layer* dan fungsi aktivasi linier/*identity* untuk *output layer*. Berdasarkan nilai RMSE terkecil, arsitektur Hibrida ARIMAX dan DLNN yang optimum pada jam 20:00 adalah dengan jumlah neuron pada *hidden layer* 1 sebanyak 3 dan jumlah neuron pada *hidden layer* 2 sebanyak 3. Persamaan model Hibrida ARIMAX dan DLNN untuk jam 20:00 pada data aktual sebagai berikut:



**Gambar 4.24** Arsitektur Hibrida ARIMAX dan DLNN Jam 20:00

$$\hat{Y}_{22,t}^* = \hat{L}_t + \hat{N}_t^* \text{ dengan } \hat{N}_t^* = \text{normalized dari } \hat{N}_t$$

dimana:

$$\begin{aligned} \hat{L}_t = & 0,13T_t + 646,19H_{1,t} + 644,23H_{2,t} + 642,99H_{3,t} + 647,49H_{4,t} + 646,31H_{5,t} \\ & + 630,51H_{6,t} + 629,02H_{7,t} - 26,90I_{1,t} - 22,73I_{2,t} - 5,78I_{3,t} - 115,67I_{4,t} \\ & - 223,30I_{5,t} - 28,67I_{6,t} - 2,96I_{7,t} - 4,83I_{8,t} + 6,68I_{9,t} - 10,55I_{10,t} - 0,63I_{11,t} \\ & - 21,61I_{12,t} - 13,65I_{13,t} - 11,23I_{14,t} - 19,11I_{15,t} - 9,37I_{16,t} - 19,47I_{17,t} + 3,53I_{18,t} \\ & - 18,72I_{19,t} - 16,42I_{20,t} - 9,72I_{21,t} - 38,60I_{22,t} - 25,60I_{23,t} - 1,13I_{24,t} - 15,84I_{25,t} \\ & + \frac{1}{(1 - 0,69B - 0,11B^2 - 0,11B^7)} a_t \end{aligned}$$

$$\hat{N}_t^* = 1,14 - 0,52f_1^{h_2}(\cdot) + 0,18f_2^{h_2}(\cdot) - 1,27f_3^{h_2}(\cdot)$$

dengan

$$f_1^{h_2}(\cdot) = (1 + \exp(-(-1,67 - 4,23f_1^h(\cdot) - 15,63f_2^h(\cdot) + 1,56f_3^h(\cdot))))^{-1}$$

$$f_2^{h_2}(\cdot) = (1 + \exp(-(-0,56 - 1,50f_1^h(\cdot) + 33,55f_2^h(\cdot) + 1,25f_3^h(\cdot))))^{-1}$$

$$f_3^{h_2}(\cdot) = (1 + \exp(-(-0,76 + 0,59f_1^h(\cdot) + 0,63f_2^h(\cdot) - 0,22f_3^h(\cdot))))^{-1}$$


dengan

$$f_1^h(\cdot) = (1 + \exp(-(-6,68 + 7,08Z_{t-1} - 1,95Z_{t-2} - 0,65Z_{t-3} + \dots \quad I_{25})))^{-1}$$

$$f_2^h(\cdot) = (1 + \exp(-(-0,75 + 0,33Z_{t-1} + 3,57Z_{t-2} + 3,53Z_{t-3} + \dots \quad 2I_{25})))^{-1}$$

$$f_3^h(\cdot) = (1 + \exp(-(-2,74 - 0,91Z_{t-1} - 1,13Z_{t-2} - 8,64Z_{t-3} + \dots \quad '25)))^{-1}$$

Berikut merupakan perbandingan data aktual dengan hasil ramalan dengan menggunakan metode Hibrida ARIMAX dan *Deep Learning Neural Network* :



**Gambar 4.25** Perbandingan Data Aktual dan Hasil Ramalan Beban Listrik pada Jam 20:00 Menggunakan Metode Hibrida ARIMAX dan DLNN

Penentuan arsitektur Hibrida ARIMAX dan DLNN yang optimum untuk jam lainnya dilakukan dengan cara yang sama. Berikut arsitektur Hibrida ARIMAX dan DLNN optimum untuk data aktual:

**Tabel 4.24** Arsitektur Hibrida ARIMAX dan DLLN Optimum pada Data Aktual


Jam	Input (Lag)	Jumlah Neuron di Hidden Layer	
		1	2
01:00	1,2,3,7,11	3	4
02:00	1,2,9	3	2
03:00	1,2,9	2	4
04:00	1,2,3,4,9	5	4

**Tabel 4.20** Arsitektur Hibrida ARIMAX dan DLLN Optimum pada Data Aktual  
(Lanjutan)

Jam	Input (Lag)	Jumlah Neuron di <i>Hidden Layer</i>	
		1	2
05:00	1,2,9	5	2
06:00	1,2,9	4	4
07:00	1,2,5,9	4	1
08:00	1,2,4,7	2	3
09:00	1,2,3,7,8,13	2	4
10:00	1,2,7,10	1	4
11:00	1,2,5,7,10,11,52	4	2
12:00	1,2,7,10	4	4
13:00	1,2,4,5,9	4	1
14:00	1,2,4,5,7,9	3	4
15:00	1,2,4,5,10	4	1
16:00	1,2,6,10	1	1
17:00	1,2,7	5	1
18:00	1,2,5,7	5	3
18:30	1,2,4,8,10,37	5	4
19:00	1,2,7	5	4
19:30	1,2,7	3	4
20:00	1,2,7	3	3
20:30	1,2,7,12	5	3
21:00	1,2,3,8,9,12	2	4
22:00	1,2,3,8	3	1
23:00	1,2,3,5,7,13	1	4
24:00	1,2,8	5	2

#### 4.6 Perbandingan Model ARIMAX, DLNN serta Hibrida ARIMAX dan DNN

Setelah dilakukan peramalan menggunakan metode ARIMAX, DLNN serta Hibrida ARIMAX dan DLNN, dilakukan perbandingan nilai RMSE dan sMAPE data testing untuk ketiga model tersebut. Berikut merupakan perbandingan kebaikan model pada ketiga metode:



**Gambar 4.26** Perbandingan Nilai RMSE dan sMAPE Ketiga Metode pada Data Aktual

Setelah dilakukan perbandingan, dari ketiga metode diatas yang menghasilkan model terbaik data aktual adalah metode *Deep Learning Neural Network*. Pada data *training* akurasi ketiga metode tidak jauh berbeda, namun pada data *testing* terlihat DLNN jauh lebih baik dari metode lainnya. Selanjutnya dilakukan perbandingan akurasi dengan menggunakan tiga horizon yaitu *short* (7 hari kedepan), *medium* (6 bulan kedepan/181 hari kedepan) dan *long* (12 bulan kedepan/365 hari kedepan) untuk ketiga metode menggunakan RMSE *testing*. Berikut merupakan hasil akurasi serta metode terbaik yang diperoleh pada ketiga horizon:

**Tabel 4.25** Perbandingan RMSE Data *Testing* Ketiga Metode pada Data Aktual Menggunakan Tiga Horizon

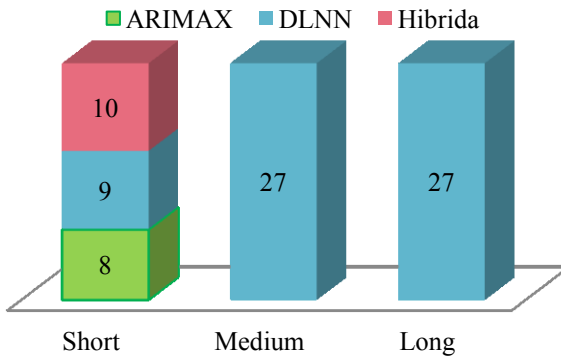
<b>Jam</b>	<b>Metode</b>	<b>Short</b>	<b>Medium</b>	<b>Long</b>	<b>Average</b>
<b>01:00</b>	<b>ARIMAX</b>	19,56	57,37	68,75	48,56
	<b>DLNN</b>	29,11	52,27	49,38	43,58
	<b>Hibrida ARIMAX-DLNN</b>	20,55	56,76	67,97	48,43
<b>02:00</b>	<b>ARIMAX</b>	19,01	41,97	59,17	40,05
	<b>DLNN</b>	19,28	34,05	38,66	30,66
	<b>Hibrida ARIMAX-DLNN</b>	18,99	41,40	58,70	39,70
<b>03:00</b>	<b>ARIMAX</b>	17,08	40,06	57,00	38,05
	<b>DLNN</b>	20,38	29,28	33,21	27,62
	<b>Hibrida ARIMAX-DLNN</b>	17,03	39,86	56,85	37,91
<b>04:00</b>	<b>ARIMAX</b>	20,86	40,27	55,15	38,76
	<b>DLNN</b>	15,29	29,77	31,45	25,50
	<b>Hibrida ARIMAX-DLNN</b>	17,82	38,87	52,88	36,52
<b>05:00</b>	<b>ARIMAX</b>	30,56	42,03	52,79	41,79
	<b>DLNN</b>	32,65	29,07	28,61	30,11
	<b>Hibrida ARIMAX-DLNN</b>	31,67	42,11	51,76	41,85
<b>06:00</b>	<b>ARIMAX</b>	43,16	44,22	49,84	45,74
	<b>DLNN</b>	33,38	37,34	32,93	34,55
	<b>Hibrida ARIMAX-DLNN</b>	41,15	43,46	48,83	44,48
<b>07:00</b>	<b>ARIMAX</b>	22,01	34,63	43,32	33,32
	<b>DLNN</b>	18,53	26,52	26,64	23,90
	<b>Hibrida ARIMAX-DLNN</b>	21,29	34,03	42,49	32,60
<b>08:00</b>	<b>ARIMAX</b>	63,25	47,21	51,32	53,93
	<b>DLNN</b>	65,15	35,67	33,02	44,61
	<b>Hibrida ARIMAX-DLNN</b>	62,66	46,78	50,84	53,43
<b>09:00</b>	<b>ARIMAX</b>	83,62	60,02	62,89	68,84
	<b>DLNN</b>	77,85	52,63	44,05	58,18
	<b>Hibrida ARIMAX-DLNN</b>	80,83	55,31	55,83	63,99
<b>10:00</b>	<b>ARIMAX</b>	51,90	52,80	63,25	55,98
	<b>DLNN</b>	52,37	44,28	40,92	45,86
	<b>Hibrida ARIMAX-DLNN</b>	51,21	50,30	59,36	53,62
<b>11:00</b>	<b>ARIMAX</b>	48,02	52,99	66,57	55,86
	<b>DLNN</b>	57,73	39,82	44,02	47,19
	<b>Hibrida ARIMAX-DLNN</b>	47,40	52,36	65,82	55,19

**Tabel 4.25** Perbandingan RMSE Data *Testing* Ketiga Metode pada Data Aktual Menggunakan Tiga Horizon (lanjutan)

<b>Jam</b>	<b>Metode</b>	<b>Short</b>	<b>Medium</b>	<b>Long</b>	<b>Average</b>
<b>12:00</b>	<b>ARIMAX</b>	28,50	53,03	71,70	51,08
	<b>DLNN</b>	31,05	35,96	39,33	35,45
	<b>Hibrida ARIMAX-DLNN</b>	27,80	52,06	70,47	50,11
<b>13:00</b>	<b>ARIMAX</b>	35,53	59,64	77,35	57,51
	<b>DLNN</b>	46,86	50,10	47,11	48,02
	<b>Hibrida ARIMAX-DLNN</b>	35,24	62,13	63,82	53,73
<b>14:00</b>	<b>ARIMAX</b>	34,05	62,33	78,50	58,29
	<b>DLNN</b>	29,05	49,15	53,04	43,75
	<b>Hibrida ARIMAX-DLNN</b>	30,24	60,74	75,42	55,47
<b>15:00</b>	<b>ARIMAX</b>	30,10	59,56	77,17	55,61
	<b>DLNN</b>	36,80	51,18	49,75	45,91
	<b>Hibrida ARIMAX-DLNN</b>	20,38	57,39	71,81	49,86
<b>16:00</b>	<b>ARIMAX</b>	32,45	53,44	71,27	52,39
	<b>DLNN</b>	33,35	40,97	40,13	38,15
	<b>Hibrida ARIMAX-DLNN</b>	31,77	52,63	69,65	51,35
<b>17:00</b>	<b>ARIMAX</b>	28,11	47,50	65,56	47,06
	<b>DLNN</b>	38,68	37,20	38,45	38,11
	<b>Hibrida ARIMAX-DLNN</b>	28,29	47,17	65,14	46,87
<b>18:00</b>	<b>ARIMAX</b>	25,56	46,91	63,37	45,28
	<b>DLNN</b>	20,30	44,31	40,19	34,93
	<b>Hibrida ARIMAX-DLNN</b>	24,49	45,87	62,20	44,19
<b>18:30</b>	<b>ARIMAX</b>	55,43	72,30	82,55	70,09
	<b>DLNN</b>	44,48	57,75	49,35	50,53
	<b>Hibrida ARIMAX-DLNN</b>	54,07	71,14	80,62	68,61
<b>19:00</b>	<b>ARIMAX</b>	102,77	81,80	85,64	90,07
	<b>DLNN</b>	95,01	65,93	53,54	71,49
	<b>Hibrida ARIMAX-DLNN</b>	102,15	81,93	84,66	89,58
<b>19:30</b>	<b>ARIMAX</b>	78,82	70,49	79,61	76,31
	<b>DLNN</b>	77,00	53,14	48,58	59,57
	<b>Hibrida ARIMAX-DLNN</b>	75,52	68,53	74,69	72,91
<b>20:00</b>	<b>ARIMAX</b>	21,80	52,96	73,10	49,29
	<b>DLNN</b>	19,80	36,04	37,85	31,23
	<b>Hibrida ARIMAX-DLNN</b>	21,22	52,19	72,22	48,54

**Tabel 4.25** Perbandingan RMSE Data *Testing* Ketiga Metode pada Data Aktual Menggunakan Tiga Horizon (lanjutan)

Jam	Metode	Short	Medium	Long	Average
20:30	ARIMAX	22,97	51,31	74,06	49,45
	DLNN	31,74	42,03	39,19	37,65
	Hibrida ARIMAX-DLNN	24,78	48,08	67,85	46,90
21:00	ARIMAX	26,26	49,25	71,92	49,14
	DLNN	36,54	37,15	42,41	38,7
	Hibrida ARIMAX-DLNN	26,67	27,33	66,72	40,24
22:00	ARIMAX	45,42	49,73	69,76	54,97
	DLNN	55,70	42,10	40,54	46,11
	Hibrida ARIMAX-DLNN	48,40	45,20	58,81	50,80
23:00	ARIMAX	53,64	49,79	67,69	57,04
	DLNN	57,80	46,15	41,90	48,62
	Hibrida ARIMAX-DLNN	54,11	49,58	67,32	57,00
24:00	ARIMAX	30,14	46,89	69,80	48,94
	DLNN	37,72	34,90	40,01	37,54
	Hibrida ARIMAX-DLNN	32,52	46,17	68,73	49,14



**Gambar 4.27** Metode Terbaik pada Ketiga Horizon


Pada horizon *short* metode terbaik yang diperoleh lebih beragam namun didominasi oleh Hibrida ARIMAX-DLNN, sementara untuk horizon *medium* dan *long* untuk seluruh waktu metode terbaik yang diperoleh adalah DLNN. Metode Hibrida ARIMAX-DLNN dan DLNN pada data aktual secara umum menghasilkan akurasi yang lebih baik dari ARIMAX. Namun




untuk beberapa waktu yaitu pada jam 01:00, 05:00, 17:00, 20:30, 21:00, 22:00, 23:00 dan 24:00 metode ARIMAX lebih unggul dibanding metode lainnya pada horizon *short*. Secara umum, untuk kajian simulasi dan kajian terapan semakin panjang periode ramalan yang dilakukan maka kesalahan ramalan yang dihasilkan semakin besar. Hasil akurasi yang diperoleh pada kajian simulasi dan kajian terapan berbeda. Hal tersebut dikarenakan perbedaan pola data yang dimiliki data simulasi dan data aktual. Pada kedua kajian model Hibrida ARIMAX-DLNN tidak selalu lebih unggul dibanding metode lainnya. Hal ini membuktikan bahwa metode yang lebih kompleks tidak selalu memberikan nilai akurasi ramalan yang lebih baik, seperti pada penelitian yang dilakukan oleh Makridakis & Hilbon (2000) pada kompetisi M3 serta pada jurnal *Statistical and Machine Learning Forecasting Methods: Concern and Ways Forward* yang dilakukan oleh Makridakis, Spiliotis & Assimakopoulos (2018).

#### 4.7 Peramalan


Dilakukan peramalan beban listrik untuk 7 hari kedepan menggunakan metode yang menghasilkan hasil terbaik untuk masing-masing jam. Peramalan beban listrik dilakukan untuk 7 hari kedepan dikarenakan pada umumnya semakin pendek periode peramalan maka akurasi yang dihasilkan semakin baik. Berikut merupakan plot dari ramalan beban listrik:




01:00




02:00




03:00




04:00




05:00




06:00




07:00




08:00




09:00




10:00




11:00




12:00




13:00




14:00




15:00




16:00




17:00




18:00




18:30




19:00




19:30




20:00




20:30




21:00



22:00



23:00



24:00

Gambar 4.28 Plot Ramalan Beban Listrik

*(Halaman ini sengaja dikosongkan)*

## BAB V KESIMPULAN DAN SARAN

### 5.1 Kesimpulan

Berdasarkan analisis dan pembahasan yang telah dilakukan, maka dapat ditarik kesimpulan sebagai berikut:

1. Karakteristik beban listrik di Provinsi Bali mengalami kenaikan yang signifikan mulai jam 07:00 hingga jam 11:00 dimana menunjukkan aktifitas mulai berjalan pada jam tersebut. Beban puncak mulai terjadi dari jam 18:00 hingga 20:30, pada jam tersebut penggunaan listrik paling optimal. Penggunaan listrik mengalami penurunan dari jam 21:00 hingga 06:00 dikarenakan aktifitas mulai terhenti pada jam tersebut. Sementara rata-rata penggunaan listrik tertinggi terjadi pada hari Kamis, dan rata penggunaan listrik terendah terjadi pada hari Minggu. Rendahnya rata-rata penggunaan listrik pada hari Minggu dikarenakan liburanya kantor-kantor dan sekolah. Hal ini menunjukkan bahwa hari libur berpengaruh terhadap penggunaan listrik di Provinsi Bali.
2. Studi simulasi yang dilakukan pada skenario 1 dan skenario 2 untuk enam waktu yaitu jam 04:00, jam 08:00, jam 12:00, jam 16:00, jam 20:00 dan jam 24:00 menunjukkan bahwa metode yang mampu menghasilkan model terbaik didominasi oleh metode Hibrida ARIMAX dan *Deep Learning Neural Network*. Saat dilakukan perhitungan RMSE *testing* menggunakan tiga horizon didapatkan pada skenario 1, untuk horizon *medium* dan *long* metode terbaik yang didapatkan adalah metode Hibrida ARIMAX-DLNN. Sedangkan untuk horizon *short* hasil yang didapatkan lebih beragam. Untuk skenario 2, pada horizon *long* metode terbaik yang didapatkan pada 5 dari 6 jam adalah Hibrida. Hasil lebih beragam didapatkan pada horizon *short* dan *medium*
3. Pada data aktual menunjukkan bahwa metode yang mampu menghasilkan model terbaik adalah metode *Deep Learning Neural Network*. Saat dilakukan perhitungan RMSE *testing*

menggunakan tiga horizon didapatkan didapatkan pada horizon *short* metode terbaik yang diperoleh lebih beragam namun didominasi oleh Hibrida ARIMAX-DLNN, sementara untuk horizon *medium* dan *long* untuk seluruh waktu metode terbaik yang diperoleh adalah DLNN. Secara umum, untuk kajian simulasi dan kajian terapan semakin panjang periode ramalan yang dilakukan maka kesalahan ramalan yang dihasilkan semakin besar. Hasil akurasi yang diperoleh pada kajian simulasi dan kajian terapan berbeda. Hal tersebut dikarenakan perbedaan pola data yang dimiliki data simulasi dan data aktual. Pada kedua kajian model Hibrida ARIMAX-DLNN tidak selalu lebih unggul dibanding metode lainnya. Hal ini membuktikan bahwa metode yang lebih kompleks tidak selalu memberikan nilai akurasi ramalan yang lebih baik.

## 5.2 Saran

Saran untuk penelitian selanjutnya adalah agar melakukan *preprocessing* data untuk mengoptimalkan metode yang digunakan khususnya jika menggunakan DLNN. Penelitian selanjutnya juga dapat mempertimbangkan penggunaan deteksi *outlier* untuk mengatasi asumsi yang tidak terpenuhi.

## DAFTAR PUSTAKA

- Barman, M., Choudhury, N. D., & Sutradhar, S. (2018). A regional hybrid GOA-SVM model based on similar day approach for short-term load forecasting in Assam, India. *Energy*, *145*, 710-720.
- Chong, E. K., & Zak, S. H. (2001). *An Introduction to Optimization* (2nd ed.). Canada: John Wiley & Sons, Inc.
- Dalto, M., Matusko, J., & Vasak, M. (2015). Deep neural networks for ultra-short-term wind forecasting. *Industrial Technology (ICIT), 2015 IEEE International Conference on* (hal. 1657–1663). IEEE.
- Daniel, W. W. (1989). *Statistik Nonparametrik Terapan*. (A. T. W, Penerj.) Jakarta: PT. Gramedia.
- Din, G. M., & Marnerides, A. K. (2017). Short term power load forecasting using Deep Neural Networks. *Computing, Networking and Communications (ICNC), 2017 International Conference on* (hal. 594–598). IEEE.
- Dudek, G. (2016). Neural networks for pattern-based short-term load forecasting: A comparative study. *Neurocomputing*, *205*, 64-74.
- Fan, S., & Chen, L. (2006). Short-term load forecasting based on an adaptive hybrid method. *21* (1), 392–401.
- Fitriani, B. E., Ispriyanti, D., & Prahutama, A. (2015). Peramalan Beban Pemakaian Listrik Jawa Tengah Dan Daerah Istimewa YOGYAKARTA Dengan Menggunakan Hybrid Autoregresive Integrated Moving Average–Neural Network. *Jurnal Gaussian*, *4* (4), 745-754.
- Gross, G., & Galiana, F. D. (1987). Short-term load forecasting. *Proceedings of the IEEE*, *75* (12), 1558–1573.

- Hadi, A., & Pabla, A. S. (1999). *Distribusi Daya Listrik*. Jakarta: Penerbit Erlangga.
- He, W. (2017). Load Forecasting via Deep Neural Networks. *Procedia Computer Science* , 122, 308-314.
- Hossen, T., Plathottam, S. J., Angamuthu, R. K., Ranganathan, P., & Salehfar, H. (2017). Short-term load forecasting using deep neural networks (DNN). *Power Symposium (NAPS), 2017 North American* (hal. 1–6). IEEE.
- Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting* , 3 (2), 679-688.
- Kajitani, Y. (1999). Forecasting Time Series With Neural Nets. *Tesis* . London: University of Western Ontario.
- Karlik, B., & Olgac, A. (2011). Performance analysis of various activation functions in generalized MLP architectures of neural networks. *International Journal of Artificial Intelligence and Expert Systems* , 1 (4), 111-122.
- Khusna, H., & Suhartono. (2015). Pendekatan Percentile Error Bootstrap pada Model Double Seasonal Holt-Winters, Double Seasonal ARIMA, dan Naive untuk peramalan beban listrik jangka pendek di Jawa Timur dan Bali. *Jurnal Sains dan Seni ITS* , 4 (1), 43-48.
- Khawaja, A., Zhang, X., Anpalagan, A., & Venkatesh, B. (2017). Boosted neural networks for improved short-term electric load forecasting. *Electric Power Systems Research* , 143, 431-437.
- Kristiana, A., Wilandari, Y., & Prahutama, A. (2015). Peramalan Beban Puncak Pemakaian Listrik Di Area Semarang Dengan Metode Hybrid Arima (Autoregressive Integrated Moving Average)-anfis (Adaptive Neuro Fuzzy Inference System)(Studi Kasus Di PT Pln (Persero) Distribusi Jawa Tengah Dan DIY). *Jurnal Gaussian* , 4 (4), 714–723.



- Kusumaningrum, O., Suhartono, & Haryono. (2012). Peramalan Kebutuhan Bahan Bakar Premium di Depot Ampanan dengan Metode Hibrida Arima-Neural Network untuk Optimasi Persediaan. *Jurnal Sains Dan Seni ITS* , 1 (1), D194–D200.
- Lee, M. H., Suhartono, & Hamzah, N. A. (2010). Calendar variation model based on ARIMAX for forecasting sales data with Ramadhan effect. *Proceedings of the Regional Conference on Statistical Sciences*, (hal. 349–361).
- Makridakis, S., & Hibon, M. (2000). The M3-Competition: results, conclusions and implications. *International Journal of Forecasting* , 451-476.
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018). Statistical and Machine Learning Forecasting Methods: Concerns and Ways Forward. *PLoS ONE* , 13 (3).
- Margaret, V., Balaraman, D. K., & Karthika. (2017). Hybrid Short Term Load Forecasting using ARIMA-SVM. *International Conference on Innovations in Power and Advanced Computing Technologies [i-PACT2017]*. IEEE.
- Muhammed, A. A. (2011). Short-Term Electricity Load Forecasting of Kurdistan-Erbil Power System Using Artificial Neural Network. *The 4th International Scientific Conference of Salahaddin University-Erbil* (hal. 276-281). Erbil: Salahaddin University.
- Nie, H., Liu, G., Liu, X., & Wang, Y. (2012). Hybrid of ARIMA and SVMs for short-term load forecasting. *2012 International Conference on Future Energy, Environment, and Materials*. 16, hal. 1455-1460. Energy Procedia.
- Noveri, E., & Syafii. (2013). Studi Peramalan (Forecasting) Kurva Beban Harian Listrik Jangka Pendek Menggunakan Metode Autoregressive Integrated Moving Average (ARIMA). *Jurnal Nasional Teknik Elektro* , 2 (1).

- Puspitasari, I. (2011). Model Dua Level Seasonal Autoregressive Hibrida ARIMA-ANFIS Untuk Peramalan Beban Listrik Jangka Pendek Di Jawa Bali. *Laporan Tugas Akhir Jurusan Statistika* . Surabaya: ITS.
- Puspitorini, S. (2009). Penyelesaian Masalah Traveling Salesman Problem Dengan Jaringan Saraf Self Organizing. *Media Informatika* , 6 (1).
- Ryu, S., Noh, J., & Kim, H. (2016). Deep neural network based demand side short term load forecasting. *10* (1), 3.
- Sadaei, H. J., Enayatifar, R., Abdullah, A. H., & Gani, A. (2014). Short-term load forecasting using a hybrid model with a refined exponentially weighted fuzzy time series and an improved harmony search. *International Journal of Electrical Power & Energy Systems* , 62, 118-129.
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks* , 61, 85–117.
- Syahputra, R. (2016). *Transmisi dan Distribusi Tenaga Listrik*. Yogyakarta: LP3M UMY.
- Terasvirta, T., Lin, C.-F., & Granger, C. W. (1993). Power of the neural network linearity test. *Journal of Time Series Analysis* , 14 (2), 209-220.
- Utomo, P. D., Kuswanto, H., & Suhartono. (2012). Penerapan Model DSARFIMA untuk Peramalan Beban Konsumsi Listrik Jangka Pendek di Jawa Timur dan Bali. *Jurnal Sains dan Seni ITS* , D242-D247.
- Wei, W. W. (2006). *Time Series Analysis Univariate dan Multivariate Methods* (2nd ed.). United States of America: Pearson Education, Inc.
- WMO. (2017). *Public Weather Service*. Diambil kembali dari [www.wmo.int](http://www.wmo.int).

- Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing* , 50, 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, Engineering and Technology* , 75, 1471–1475.

*(Halaman ini sengaja dikosongkan)*

## LAMPIRAN

### Lampiran 1. Data Beban Listrik

Tahun	Bulan	Tanggal	Waktu			
			01:00	02:00	...	24:00
2014	Januari	1	496.9	472.5	...	453.8
2014	Januari	2	425.7	403.9	...	444.8
⋮	⋮	⋮	⋮	⋮	⋮	⋮
2014	Januari	30	480.5	457.8	...	506.2
2014	Januari	31	475.7	455.5	...	503.5
2014	Februari	1	472.3	447.4	...	512.9
2014	Februari	2	489.3	469.1	...	485.8
⋮	⋮	⋮	⋮	⋮	⋮	⋮
2014	Februari	27	440.4	422.9	...	481.5
2014	Februari	28	449.1	429.9	...	489.7
...	...	...	...	...	...	...
2016	Januari	1	632.2	598	...	622.3
2016	Januari	2	581	555.1	...	603.7
⋮	⋮	⋮	⋮	⋮	⋮	⋮
2016	Desember	30	570.8	546.2	...	629.8
2016	Desember	31	593.7	569	...	624.8
2017	Januari	1	624.8	569.4	...	630.5
2017	Januari	2	576.9	569.4	...	630.5
⋮	⋮	⋮	⋮	⋮	⋮	⋮
2017	Desember	30	549	536.6	...	581.8
2017	Desember	31	541.4	521.1	...	557.3

## Lampiran 2. *Output* ARIMAX Skenario 1 & 2

### ARIMAX Skenario 1

Pukul 04:00

## The ARIMA Procedure

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.71231	0.02165	32.9	<.0001	1	y	0
NUM1	0.09867	0.0016035	61.53	<.0001	0	t	0
NUM2	470.24601	1.06891	439.9	<.0001	0	H1	0
NUM3	4.69E+02	1.07062	438.3	<.0001	0	H2	0
NUM4	470.48286	1.06978	439.8	<.0001	0	H3	0
NUM5	475.31779	1.0722	443.3	<.0001	0	H4	0
NUM6	473.56425	1.07329	441.2	<.0001	0	H5	0
NUM7	470.20011	1.07376	437.9	<.0001	0	H6	0
NUM8	473.43025	1.06879	443	<.0001	0	H7	0
NUM9	20.14273	2.31074	8.72	<.0001	0	I1	0
NUM10	-9.61192	2.02709	-4.74	<.0001	0	I2	0
NUM11	6.74962	2.35986	2.86	0.0043	0	I3	0
NUM12	-7.76026	3.11082	-2.49	0.0128	0	I4	0
NUM13	-61.84393	2.75149	-22.48	<.0001	0	I5	0
NUM14	-122.4969	3.11112	-39.37	<.0001	0	I6	0
NUM15	31.47451	2.32497	13.54	<.0001	0	I7	0
NUM16	1.78674	2.85503	0.63	0.5316	0	I8	0
NUM17	-11.75569	2.82893	-4.16	<.0001	0	I9	0
NUM18	47.35418	2.33552	20.28	<.0001	0	I10	0
NUM19	50.8912	2.37461	21.43	<.0001	0	I11	0
NUM20	-36.09892	2.65349	-13.6	<.0001	0	I12	0
NUM21	-28.76656	2.62689	-10.95	<.0001	0	I13	0
NUM22	-28.03597	2.82745	-9.92	<.0001	0	I14	0
NUM23	-12.52005	2.82707	-4.43	<.0001	0	I15	0
NUM24	2.89673	2.82791	1.02	0.3059	0	I16	0
NUM25	21.82363	2.91144	7.5	<.0001	0	I17	0
NUM26	2.55983	2.33882	1.09	0.274	0	I18	0
NUM27	1.20694	1.83325	0.66	0.5105	0	I19	0
NUM28	-9.88376	1.81297	-5.45	<.0001	0	I20	0
NUM29	-12.71163	2.17183	-5.85	<.0001	0	I21	0
NUM30	-2.8008	2.4536	-1.14	0.2539	0	I22	0
NUM31	-12.73778	2.17891	-5.85	<.0001	0	I23	0
NUM32	20.05842	2.111	9.5	<.0001	0	I24	0
NUM33	43.70081	2.06928	21.12	<.0001	0	I25	0
Variance Estimate				23.93192			
Std Error Estimate				4.892026			
AIC				6623.808			
SBC				6793.789			
Number of Residuals				1096			

\* AIC and SBC do not include log determinant.

#### Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.76	5	0.3306	0.01	0.005	0.016	-0.066	-0.003	-0.02
12	8.88	11	0.6332	0.042	0.019	0.009	0.016	-0.018	-0.01
18	17.55	17	0.4176	0.026	-0.018	-0.036	-0.069	-0.007	0.027
24	22.07	23	0.5158	0.022	-0.037	-0.032	-0.025	-0.022	0.003
30	30.46	29	0.3912	0.021	0.012	-0.028	-0.023	0.046	-0.06
36	37.23	35	0.3667	0	0.033	-0.044	0.045	-0.014	-0.03
42	39.53	41	0.5359	-0.021	-0.026	0.002	0.016	0.008	-0.02
48	41.46	47	0.7005	0.015	0.025	-0.007	-0.006	0.019	-0.02

#### Tests for Normality

Test	Statistic	P-value
Shapiro-Wilk	W 0.998055	Pr < W 0.2371
Kolmogorov-Smirnov	D 0.023398	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.077303	Pr > W-Sq 0.2304
Anderson-Darling	A-Sq 0.490633	Pr > A-Sq 0.227

## Pukul 08:00

### The ARIMA Procedure

#### Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.71714	0.02143	33.47	<.0001	1	y	0
NUM1	0.09759	0.0017101	57.07	<.0001	0	t	0
NUM2	550.45159	1.13786	483.8	<.0001	0	H1	0
NUM3	5.48E+02	1.13956	480.8	<.0001	0	H2	0
NUM4	549.10914	1.13862	482.3	<.0001	0	H3	0
NUM5	547.43038	1.14121	479.7	<.0001	0	H4	0
NUM6	554.73675	1.14242	485.6	<.0001	0	H5	0
NUM7	531.11332	1.1429	464.7	<.0001	0	H6	0
NUM8	524.90025	1.13778	461.3	<.0001	0	H7	0
NUM9	-22.82745	2.41818	-9.44	<.0001	0	I1	0
NUM10	-7.37846	2.12163	-3.48	0.0005	0	I2	0
NUM11	-27.72282	2.46986	-11.22	<.0001	0	I3	0
NUM12	-35.03316	3.2575	-10.75	<.0001	0	I4	0
NUM13	-129.77231	2.88204	-45.03	<.0001	0	I5	0
NUM14	-46.19741	3.2575	-14.18	<.0001	0	I6	0
NUM15	-1.9066	2.43251	-0.78	0.4333	0	I7	0
NUM16	-13.73327	2.98642	-4.6	<.0001	0	I8	0
NUM17	-17.59968	2.95884	-5.95	<.0001	0	I9	0
NUM18	16.47026	2.44424	6.74	<.0001	0	I10	0
NUM19	19.09003	2.48526	7.68	<.0001	0	I11	0
NUM20	-59.88858	2.77708	-21.57	<.0001	0	I12	0

NUM21	-59.08882	2.74925	-21.49	<.0001	0	113	0
NUM22	-25.67885	2.95938	-8.68	<.0001	0	114	0
NUM23	-31.80203	2.9584	-10.75	<.0001	0	115	0
NUM24	-16.94194	2.95862	-5.73	<.0001	0	116	0
NUM25	11.72055	3.04766	3.85	0.0001	0	117	0
NUM26	-25.014	2.44796	-10.22	<.0001	0	118	0
NUM27	-23.72563	1.91785	-12.37	<.0001	0	119	0
NUM28	-43.2637	1.89715	-22.8	<.0001	0	120	0
NUM29	-19.78647	2.27511	-8.7	<.0001	0	121	0
NUM30	-45.10521	2.57208	-17.54	<.0001	0	122	0
NUM31	-6.16709	2.28307	-2.7	0.007	0	123	0
NUM32	10.10268	2.20828	4.57	<.0001	0	124	0
NUM33	-16.46106	2.16515	-7.6	<.0001	0	125	0

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	1.65	5	0.8951	-0.016	0.013	-0.004	0.026	0.019	-0.004
12	8.2	11	0.6951	-0.005	-0.032	-0.011	0.013	-0.065	0.021
18	14	17	0.6668	0.046	0.005	-0.032	0.004	-0.038	0.024
24	17.14	23	0.8024	0.012	0.007	0.008	0.012	-0.003	-0.049
30	28.67	29	0.4824	-0.024	-0.027	0.048	0.038	0.019	-0.069
36	34.03	35	0.5148	0.003	0.008	-0.017	0.014	-0.063	-0.016
42	37.15	41	0.6426	0.024	-0.003	0.011	0.005	0.022	0.039
48	40.31	47	0.7442	0.033	0.024	-0.02	-0.007	-0.024	-0.009

Tests for Normality

Test	Statistic	P-value
Shapiro-Wilk	W 0.998972	Pr < W 0.8074
Kolmogorov-Smirnov	D 0.02054	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.062325	Pr > W-Sq >0.2500
Anderson-Darling	A-Sq 0.367812	Pr > A-Sq >0.2500

**Pukul 12:00**

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.70274	0.02193	32.04	<.0001	1	y	0
NUM1	0.10117	0.001541	65.66	<.0001	0	t	0
NUM2	657.92512	1.03091	638.2	<.0001	0	H1	0
NUM3	6.51E+02	1.03278	630.3	<.0001	0	H2	0
NUM4	646.79597	1.03209	626.7	<.0001	0	H3	0
NUM5	649.68675	1.03438	628.1	<.0001	0	H4	0
NUM6	655.08904	1.03535	632.7	<.0001	0	H5	0
NUM7	638.28694	1.03585	616.2	<.0001	0	H6	0
NUM8	609.72203	1.03073	591.5	<.0001	0	H7	0



NUM9	-33.08745	2.30204	-14.37	<.0001	0	I1	0
NUM10	-29.29448	2.02016	-14.5	<.0001	0	I2	0
NUM11	-18.19666	2.35113	-7.74	<.0001	0	I3	0
NUM12	-67.72259	3.09693	-21.87	<.0001	0	I4	0
NUM13	-180.63713	2.73708	-66	<.0001	0	I5	0
NUM14	-33.98646	3.09693	-10.97	<.0001	0	I6	0
NUM15	7.78698	2.3169	3.36	0.0008	0	I7	0
NUM16	-26.63777	2.8435	-9.37	<.0001	0	I8	0
NUM17	-30.31022	2.81775	-10.76	<.0001	0	I9	0
NUM18	3.67993	2.32719	1.58	0.1141	0	I10	0
NUM19	-6.53378	2.36672	-2.76	0.0059	0	I11	0
NUM20	-96.64786	2.63915	-36.62	<.0001	0	I12	0
NUM21	-85.00621	2.61306	-32.53	<.0001	0	I13	0
NUM22	-46.67962	2.8174	-16.57	<.0001	0	I14	0
NUM23	-42.46453	2.81759	-15.07	<.0001	0	I15	0
NUM24	-19.09365	2.81753	-6.78	<.0001	0	I16	0
NUM25	-22.82866	2.89994	-7.87	<.0001	0	I17	0
NUM26	5.17282	2.33048	2.22	0.0267	0	I18	0
NUM27	-19.82909	1.82644	-10.86	<.0001	0	I19	0
NUM28	-36.14657	1.80665	-20.01	<.0001	0	I20	0
NUM29	-20.52764	2.16078	-9.5	<.0001	0	I21	0
NUM30	-67.72674	2.43829	-27.78	<.0001	0	I22	0
NUM31	-48.87763	2.1673	-22.55	<.0001	0	I23	0
NUM32	10.93469	2.09812	5.21	<.0001	0	I24	0
NUM33	-19.27981	2.0576	-9.37	<.0001	0	I25	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.24	5	0.6635	-0.031	0.038	0.019	-0.011	0.006	0.009
12	15.17	11	0.1749	-0.054	0.02	-0.008	0.03	0.045	-0.07
18	19.74	17	0.2876	-0.015	-0.002	-0.042	0.044	0.007	-0.01
24	28.11	23	0.2117	0.042	0.004	-0.032	0.051	-0.017	-0.04
30	32.86	29	0.2833	-0.027	0.022	-0.044	-0.013	0.003	0.029
36	39.5	35	0.2757	0.003	-0.047	0.046	0.019	-0.029	0.018
42	43.2	41	0.3773	0.016	-0.025	-0.02	-0.016	-0.034	0.024
48	48.42	47	0.4152	-0.037	0.012	0.009	0.01	0.041	-0.04

## Tests for Normality

Test	Statistic	P-value
Shapiro-Wilk	W	0.998101
Kolmogorov-Smirnov	D	0.018789
Cramer-von Mises	W-Sq	0.030907
Anderson-Darling	A-Sq	0.215463
	Pr < W	0.2557
	Pr > D	>0.1500
	Pr > W-Sq	>0.2500
	Pr > A-Sq	>0.2500

**Pukul 16:00**

## The ARIMA Procedure

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1_1	0.68362	0.02252	30.36	<.0001	1	y	0
NUM1	0.10247	0.0014557	70.39	<.0001	0	t	0
NUM2	660.85105	0.98098	673.7	<.0001	0	H1	0
NUM3	6.58E+02	0.98312	669.8	<.0001	0	H2	0
NUM4	654.17905	0.98265	665.7	<.0001	0	H3	0
NUM5	657.58488	0.98483	667.7	<.0001	0	H4	0
NUM6	659.26993	0.98567	668.9	<.0001	0	H5	0
NUM7	628.28707	0.98618	637.1	<.0001	0	H6	0
NUM8	602.74033	0.98071	614.6	<.0001	0	H7	0
NUM9	-83.80152	2.32699	-36.01	<.0001	0	I1	0
NUM10	-22.1236	2.04175	-10.84	<.0001	0	I2	0
NUM11	-31.5561	2.37608	-13.28	<.0001	0	I3	0
NUM12	-112.28992	3.12817	-35.9	<.0001	0	I4	0
NUM13	-160.07127	2.76071	-57.98	<.0001	0	I5	0
NUM14	-30.24781	3.12707	-9.67	<.0001	0	I6	0
NUM15	4.7548	2.342	2.03	0.0426	0	I7	0
NUM16	-44.2593	2.87541	-15.39	<.0001	0	I8	0
NUM17	-28.09947	2.84907	-9.86	<.0001	0	I9	0
NUM18	1.64675	2.35231	0.7	0.484	0	I10	0
NUM19	14.26333	2.39113	5.97	<.0001	0	I11	0
NUM20	-91.15641	2.66051	-34.26	<.0001	0	I12	0
NUM21	-80.16445	2.63497	-30.42	<.0001	0	I13	0
NUM22	-43.27915	2.84913	-15.19	<.0001	0	I14	0
NUM23	-44.14011	2.84848	-15.5	<.0001	0	I15	0
NUM24	-13.88822	2.84897	-4.87	<.0001	0	I16	0
NUM25	-43.80726	2.93021	-14.95	<.0001	0	I17	0
NUM26	-4.93775	2.35614	-2.1	0.0363	0	I18	0
NUM27	-23.65721	1.84589	-12.82	<.0001	0	I19	0
NUM28	-25.34116	1.82688	-13.87	<.0001	0	I20	0
NUM29	-42.09878	2.17101	-19.39	<.0001	0	I21	0
NUM30	-72.5967	2.44325	-29.71	<.0001	0	I22	0
NUM31	-55.53764	2.17819	-25.5	<.0001	0	I23	0
NUM32	19.05233	2.11471	9.01	<.0001	0	I24	0
NUM33	-9.92667	2.0746	-4.78	<.0001	0	I25	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.56	5	0.4724	-0.011	0.013	-0.016	-0.009	0.045	0.038
12	8.03	11	0.7108	-0.028	0.006	-0.001	-0.006	0.011	-0.047
18	14.12	17	0.6584	-0.007	-0.016	0.018	0.058	0.035	0.017
24	28.37	23	0.2021	0.011	0.03	-0.04	0.099	-0.012	-0.009

30	30.39	29	0.3946	-0.004	-0.023	-0.006	-0.007	0.017	-0.03
36	38.75	35	0.3042	-0.047	-0.064	-0.009	-0.023	0	-0.022
42	41.74	41	0.4385	0.027	-0.032	-0.014	-0.008	-0.025	-0.005
48	48.69	47	0.4048	-0.006	0.02	-0.03	-0.041	0.037	-0.041

Tests for Normality			
Test	Statistic	P-value	
Shapiro-Wilk	W	0.998919	Pr < W 0.7721
Kolmogorov-Smirnov	D	0.014993	Pr > D >0.1500
Cramer-von Mises	W-Sq	0.024445	Pr > W-Sq >0.2500
Anderson-Darling	A-Sq	0.198418	Pr > A-Sq >0.2500

## Pukul 20:00

### The ARIMA Procedure

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.71197	0.02166	32.87	<.0001	1	y	0
NUM1	0.10163	0.0015917	63.85	<.0001	0	t	0
NUM2	734.14753	1.06108	691.9	<.0001	0	H1	0
NUM3	7.30E+02	1.06278	686.8	<.0001	0	H2	0
NUM4	729.62165	1.06196	687.1	<.0001	0	H3	0
NUM5	736.94814	1.06437	692.4	<.0001	0	H4	0
NUM6	735.99828	1.06544	690.8	<.0001	0	H5	0
NUM7	718.69456	1.06592	674.3	<.0001	0	H6	0
NUM8	718.26324	1.06097	677	<.0001	0	H7	0
NUM9	-32.33218	2.29576	-14.08	<.0001	0	11	0
NUM10	-33.20135	2.01412	-16.48	<.0001	0	12	0
NUM11	-1.74569	2.34444	-0.74	0.4567	0	13	0
NUM12	-137.91395	3.09102	-44.62	<.0001	0	14	0
NUM13	-259.02511	2.73384	-94.75	<.0001	0	15	0
NUM14	-4.91488	3.09125	-1.59	0.1121	0	16	0
NUM15	32.13259	2.30978	13.91	<.0001	0	17	0
NUM16	-7.1188	2.83562	-2.51	0.0122	0	18	0
NUM17	-8.63079	2.80933	-3.07	0.0022	0	19	0
NUM18	11.39573	2.32047	4.91	<.0001	0	I10	0
NUM19	32.43554	2.35935	13.75	<.0001	0	I11	0
NUM20	-80.63398	2.63456	-30.61	<.0001	0	I12	0
NUM21	-56.56774	2.6084	-21.69	<.0001	0	I13	0
NUM22	-27.71375	2.80908	-9.87	<.0001	0	I14	0
NUM23	-26.76276	2.80923	-9.53	<.0001	0	I15	0
NUM24	-16.38854	2.80941	-5.83	<.0001	0	I16	0
NUM25	-2.10971	2.89228	-0.73	0.4659	0	I17	0
NUM26	13.05687	2.32387	5.62	<.0001	0	I18	0
NUM27	-7.54508	1.82108	-4.14	<.0001	0	I19	0
NUM28	-5.31296	1.8013	-2.95	0.0033	0	I20	0
NUM29	-30.77359	2.15702	-14.27	<.0001	0	I21	0

NUM30	-40.93537	2.43695	-16.8	<.0001	0	I22	0
NUM31	-28.54682	2.16459	-13.19	<.0001	0	I23	0
NUM32	40.02281	2.09516	19.1	<.0001	0	I24	0
NUM33	3.14498	2.05437	1.53	0.1261	0	I25	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.49	5	0.6246	0.018	-0.022	-0.015	-0.014	0.021	0.039
12	11.71	11	0.3861	0.014	-0.039	-0.046	-0.023	0.024	0.05
18	14.96	17	0.5985	0.026	0.006	-0.002	0.032	0.024	-0.024
24	24.89	23	0.3561	0.035	0.056	0.004	-0.024	0.048	0.04
30	31.74	29	0.3314	-0.02	0.025	0.036	-0.03	-0.042	0.033
36	37.54	35	0.3535	0.03	-0.037	0.009	0.011	-0.05	0.01
42	39.9	41	0.5196	0.011	-0.014	-0.018	-0.037	0.008	-0.004
48	46.14	47	0.5083	-0.006	0.044	0.011	0.049	-0.031	-0.001

## Tests for Normality

Test	Statistic	P-value
Shapiro-Wilk	W	0.997236
Kolmogorov-Smirnov	D	0.021669
Cramer-von Mises	W-Sq	0.069763
Anderson-Darling	A-Sq	0.449038

Pr < W	0.056
Pr > D	>0.1500
Pr > W-Sq	>0.2500
Pr > A-Sq	>0.2500

**Pukul 24:00**

## The ARIMA Procedure

## Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.72331	0.02127	34	<.0001	1	y	0
NUM1	0.10156	0.0016984	59.8	<.0001	0	t	0
NUM2	545.45426	1.12751	483.8	<.0001	0	H1	0
NUM3	5.46E+02	1.12906	483.2	<.0001	0	H2	0
NUM4	551.27641	1.12805	488.7	<.0001	0	H3	0
NUM5	547.85493	1.13063	484.6	<.0001	0	H4	0
NUM6	552.37733	1.13185	488	<.0001	0	H5	0
NUM7	549.819	1.13232	485.6	<.0001	0	H6	0
NUM8	546.66784	1.12746	484.9	<.0001	0	H7	0
NUM9	-7.15552	2.34315	-3.05	0.0023	0	I1	0
NUM10	-27.70068	2.05553	-13.48	<.0001	0	I2	0
NUM11	7.87911	2.39359	3.29	0.001	0	I3	0
NUM12	-60.27927	3.15845	-19.09	<.0001	0	I4	0
NUM13	-157.38594	2.79748	-56.26	<.0001	0	I5	0
NUM14	4.42521	3.15923	1.4	0.1616	0	I6	0
NUM15	37.43921	2.3567	15.89	<.0001	0	I7	0
NUM16	-1.97366	2.89531	-0.68	0.4956	0	I8	0
NUM17	-1.90253	2.86668	-0.66	0.507	0	I9	0

NUM18	12.86082	2.36864	5.43	<.0001	0	I10	0
NUM19	35.7087	2.40816	14.83	<.0001	0	I11	0
NUM20	-42.05499	2.69284	-15.62	<.0001	0	I12	0
NUM21	-41.57965	2.66571	-15.6	<.0001	0	I13	0
NUM22	-7.27309	2.86639	-2.54	0.0113	0	I14	0
NUM23	-15.52992	2.86628	-5.42	<.0001	0	I15	0
NUM24	3.67772	2.86651	1.28	0.1998	0	I16	0
NUM25	25.81594	2.95233	8.74	<.0001	0	I17	0
NUM26	9.01514	2.37183	3.8	0.0002	0	I18	0
NUM27	-6.2255	1.85854	-3.35	0.0008	0	I19	0
NUM28	1.43051	1.83812	0.78	0.4366	0	I20	0
NUM29	-25.43756	2.20824	-11.52	<.0001	0	I21	0
NUM30	-15.2855	2.4984	-6.12	<.0001	0	I22	0
NUM31	-9.41051	2.21576	-4.25	<.0001	0	I23	0
NUM32	45.86077	2.14177	21.41	<.0001	0	I24	0
NUM33	25.99309	2.09968	12.38	<.0001	0	I25	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr >ChiSq	-----Autocorrelations-----					
6	5.33	5	0.3767	0.027	-0.009	-0.052	-0.011	0.03	0.019
12	13.64	11	0.2537	0.012	-0.048	0.05	-0.025	0.015	0.041
18	18.39	17	0.3645	-0.001	-0.049	-0.014	-0.005	-0.026	-0.031
24	23.88	23	0.4106	-0.03	-0.038	-0.027	0.024	-0.03	-0.02
30	27.08	29	0.5674	0.02	-0.009	0.002	0.021	0.006	-0.043
36	38.39	35	0.3186	-0.029	0.009	0.064	0.07	-0.009	-0.002
42	41.6	41	0.4443	0.003	0.022	0.015	0.025	-0.033	-0.019
48	47.17	47	0.4658	0.043	-0.003	0.016	0.008	0.009	0.051

## Tests for Normality

Test	Statistic	P-value
Shapiro-Wilk	W 0.998887	Pr < W 0.7489
Kolmogorov-Smirnov	D 0.016477	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.040963	Pr > W-Sq >0.2500
Anderson-Darling	A-Sq 0.277081	Pr > A-Sq >0.2500

## ARIMAX Skenario 2

### Pukul 04:00

## The ARIMA Procedure

## Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
MA1,1	-0.2801	0.03092	-9.06	<.0001	1	y	0
MA1,2	-0.06002	0.0301	-1.99	0.0464	3	y	0
AR1,1	0.25215	0.03123	8.08	<.0001	2	y	0
AR1,2	-0.06331	0.03039	-2.08	0.0375	30	y	0
NUM1	0.0994	0.0024189	41.09	<.0001	0	t	0

NUM2	470.75997	1.86447	252.5	<.0001	0	H1	0
NUM3	467.65126	1.88205	248.5	<.0001	0	H2	0
NUM4	472.63587	1.88674	250.5	<.0001	0	H3	0
NUM5	474.15855	1.89214	250.6	<.0001	0	H4	0
NUM6	473.70047	1.88921	250.7	<.0001	0	H5	0
NUM7	468.78069	1.89236	247.7	<.0001	0	H6	0
NUM8	473.25447	1.85978	254.5	<.0001	0	H7	0
NUM9	10.53396	8.39246	1.26	0.2097	0	I1	0
NUM10	-8.57985	7.28458	-1.18	0.2391	0	I2	0
NUM11	8.41893	8.42844	1	0.3181	0	I3	0
NUM12	-6.42361	10.48133	-0.61	0.5401	0	I4	0
NUM13	-49.17476	8.65796	-5.68	<.0001	0	I5	0
NUM14	-119.16163	10.49242	-11.36	<.0001	0	I6	0
NUM15	27.99869	8.47011	3.31	0.001	0	I7	0
NUM16	26.87673	10.31169	2.61	0.0093	0	I8	0
NUM17	-26.44523	10.30361	-2.57	0.0104	0	I9	0
NUM18	42.34609	8.51366	4.97	<.0001	0	I10	0
NUM19	63.89212	8.61456	7.42	<.0001	0	I11	0
NUM20	-32.95402	8.61533	-3.83	0.0001	0	I12	0
NUM21	-40.43397	8.59665	-4.7	<.0001	0	I13	0
NUM22	-19.311	10.28392	-1.88	0.0607	0	I14	0
NUM23	-11.92399	10.26592	-1.16	0.2457	0	I15	0
NUM24	16.8685	10.27647	1.64	0.101	0	I16	0
NUM25	9.81019	10.35233	0.95	0.3435	0	I17	0
NUM26	-6.76543	8.38926	-0.81	0.4202	0	I18	0
NUM27	-3.55091	6.59311	-0.54	0.5903	0	I19	0
NUM28	-4.47612	6.58161	-0.68	0.4966	0	I20	0
NUM29	-6.53354	6.89787	-0.95	0.3438	0	I21	0
NUM30	-11.85508	6.97054	-1.7	0.0893	0	I22	0
NUM31	-5.23508	6.91179	-0.76	0.449	0	I23	0
NUM32	26.29343	6.78451	3.88	0.0001	0	I24	0
NUM33	47.07587	6.75223	6.97	<.0001	0	I25	0

Variance Estimate 232.9844  
 Std Error Estimate 15.26383  
 AIC 9120.939  
 SBC 9305.918  
 Number of Residuals 1096

\* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr >ChiSq	-----Autocorrelations-----					
6	0.51	2	0.7734	0	-0.001	0.005	0.009	0.001	0.019
12	8.22	8	0.4119	0.013	0.028	-0.036	0.029	-0.034	0.052
18	13.59	14	0.4808	-0.002	0	-0.025	0.01	-0.064	-0
24	20.26	20	0.4417	-0.033	0.02	-0.006	0.066	-0.007	0.007
30	31.2	26	0.2209	0.035	0.049	-0.052	0.04	0.043	-0.01
36	39.95	32	0.1577	-0.006	0.045	-0.014	-0.013	-0.036	0.063

42	47.07	38	0.1486	-0.058	0.012	-0.029	-0.01	-0.034	-0.03
48	52.78	44	0.171	-0.035	-0.021	0.018	-0.008	-0.044	0.031
54	56.12	50	0.2563	0.012	0.026	-0.034	0.03	-0.001	0.003
60	72.24	56	0.0709	-0.047	-0.048	0.054	0.032	-0.015	0.072
66	81.73	62	0.0474	-0.037	0.034	-0.055	0.036	0.001	-0.04
72	86.31	68	0.0663	-0.011	0.051	0.008	0.015	0.029	0.008
78	90.7	74	0.0909	-0.016	0.043	0.001	-0.006	-0.04	-0.01
84	92.89	80	0.1537	-0.032	0.015	-0.001	-0.004	0.008	-0.02
90	107.15	86	0.061	0.01	0.02	-0.075	-0.01	0.075	0.013
96	112.37	92	0.0733	0.001	0.016	-0.04	-0.016	-0.031	0.036

Test	Tests for Normality		P-value
	Statistic		
Shapiro-Wilk	W	0.992743	Pr < W < 0.0001
Kolmogorov-Smirnov	D	0.023912	Pr > D 0.1307
Cramer-von Mises	W-Sq	0.194784	Pr > W-Sq 0.0063
Anderson-Darling	A-Sq	1.440209	Pr > A-Sq < 0.0050

## Pukul 08:00

### The ARIMA Procedure

Parameter	Estimate	Conditional Least Squares Estimation					
		Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
MA1,1	-0.2763	0.03045	-9.07	<.0001	1	y	0
MA1,2	0.11173	0.02996	3.73	0.0002	30	y	0
MA1,3	-0.07749	0.03079	-2.52	0.012	70	y	0
AR1,1	0.22943	0.0313	7.33	<.0001	2	y	0
NUM1	0.09764	0.0023681	41.23	<.0001	0	t	0
NUM2	550.74806	1.90667	288.9	<.0001	0	H1	0
NUM3	547.40513	1.92374	284.6	<.0001	0	H2	0
NUM4	549.24619	1.9298	284.6	<.0001	0	H3	0
NUM5	548.44257	1.93308	283.7	<.0001	0	H4	0
NUM6	555.87763	1.93005	288	<.0001	0	H5	0
NUM7	531.87042	1.93399	275	<.0001	0	H6	0
NUM8	527.36829	1.90182	277.3	<.0001	0	H7	0
NUM9	-15.75495	8.46501	-1.86	0.063	0	11	0
NUM10	-10.17375	7.37688	-1.38	0.1681	0	12	0
NUM11	-35.96504	8.50362	-4.23	<.0001	0	13	0
NUM12	-34.94832	10.59285	-3.3	0.001	0	14	0
NUM13	-112.71784	8.78625	-12.83	<.0001	0	15	0
NUM14	-36.4564	10.60685	-3.44	0.0006	0	16	0
NUM15	7.97224	8.52096	0.94	0.3497	0	17	0
NUM16	-4.12519	10.40103	-0.4	0.6917	0	18	0
NUM17	-4.05009	10.35812	-0.39	0.6959	0	19	0
NUM18	13.32047	8.59658	1.55	0.1216	0	110	0
NUM19	6.52511	8.66289	0.75	0.4515	0	111	0
NUM20	-49.62074	8.6971	-5.71	<.0001	0	112	0

NUM21	-67.34658	8.69096	-7.75	<.0001	0	I13	0
NUM22	-36.73367	10.37125	-3.54	0.0004	0	I14	0
NUM23	-33.99512	10.36515	-3.28	0.0011	0	I15	0
NUM24	-15.28277	10.3681	-1.47	0.1408	0	I16	0
NUM25	-7.82554	10.44203	-0.75	0.4538	0	I17	0
NUM26	-13.88267	8.45939	-1.64	0.1011	0	I18	0
NUM27	-28.80986	6.64574	-4.34	<.0001	0	I19	0
NUM28	-43.89967	6.66344	-6.59	<.0001	0	I20	0
NUM29	-18.11368	6.97902	-2.6	0.0096	0	I21	0
NUM30	-35.49036	7.08715	-5.01	<.0001	0	I22	0
NUM31	-14.93522	6.99445	-2.14	0.033	0	I23	0
NUM32	0.71	6.85202	0.1	0.9175	0	I24	0
NUM33	-26.10547	6.83006	-3.82	0.0001	0	I25	0

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr >ChiSq	-----Autocorrelations-----					
6	3.82	2	0.1478	0.005	-0.004	0.024	0.006	0.033	0.042
12	6.17	8	0.6278	-0.015	0.016	-0.025	-0.024	0.015	0.014
18	10.02	14	0.7611	0.021	0.024	-0.012	0.006	0.03	0.037
24	14.77	20	0.7891	-0.037	-0.006	0.001	0.027	0.032	-0.033
30	18.22	26	0.8678	-0.033	-0.019	-0.008	0.031	0.024	-0.004
36	25.47	32	0.7866	-0.037	0.028	0.047	0.044	-0.009	0.005
42	36.5	38	0.5391	0.013	0.083	-0.003	0.037	0.022	0.029
48	41.75	44	0.5685	-0.042	-0.011	-0.015	0.013	-0.046	0.01
54	47.84	50	0.5605	0.009	0.015	0.069	0.004	0.01	-0.008
60	61.55	56	0.2843	0.08	0.033	-0.035	0.03	-0.012	-0.046
66	66.75	62	0.3172	-0.008	0.042	-0.004	0.03	-0.041	-0.001
72	68.71	68	0.4532	-0.004	0.017	0.013	0.006	0.034	-0.001
78	71.53	74	0.5597	0.032	-0.003	0.033	0.014	0.009	-0.007
84	77.06	80	0.5725	0.04	-0.003	-0.016	-0.01	-0.015	0.049
90	79.41	86	0.679	-0.015	0.012	-0.015	-0.004	-0.002	0.037
96	87.17	92	0.623	0.012	-0.049	0.029	-0.043	-0.024	0.026

Tests for Normality

Test	Statistic	P-value
Shapiro-Wilk	W 0.992459	Pr < W <0.0001
Kolmogorov-Smirnov	D 0.025046	Pr > D 0.0931
Cramer-von Mises	W-Sq 0.129454	Pr > W-Sq 0.046
Anderson-Darling	A-Sq 1.320913	Pr > A-Sq <0.0050

**Pukul 12:00**

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
MA1,1	0.08455	0.03176	2.66	0.0079	4	y	0



AR1,1	0.28778	0.0309	9.31	<.0001	1	y	0
AR1,2	0.09109	0.03129	2.91	0.0037	2	y	0
NUM1	0.10421	0.0021898	47.59	<.0001	0	t	0
NUM2	657.39271	1.78618	368	<.0001	0	H1	0
NUM3	649.40451	1.8053	359.7	<.0001	0	H2	0
NUM4	645.06913	1.81127	356.1	<.0001	0	H3	0
NUM5	647.84887	1.81603	356.7	<.0001	0	H4	0
NUM6	652.26003	1.81322	359.7	<.0001	0	H5	0
NUM7	637.07643	1.81688	350.6	<.0001	0	H6	0
NUM8	607.28499	1.78089	341	<.0001	0	H7	0
NUM9	-30.53481	8.59314	-3.55	0.0004	0	I1	0
NUM10	-27.6344	7.47656	-3.7	0.0002	0	I2	0
NUM11	-28.45961	8.67984	-3.28	0.0011	0	I3	0
NUM12	-73.77891	10.79073	-6.84	<.0001	0	I4	0
NUM13	-191.23537	8.97867	-21.3	<.0001	0	I5	0
NUM14	-34.57192	10.80229	-3.2	0.0014	0	I6	0
NUM15	-6.54277	8.65532	-0.76	0.4499	0	I7	0
NUM16	-31.78091	10.55237	-3.01	0.0027	0	I8	0
NUM17	-43.02208	10.53927	-4.08	<.0001	0	I9	0
NUM18	8.25667	8.72706	0.95	0.3443	0	I10	0
NUM19	-13.01652	8.7777	-1.48	0.1384	0	I11	0
NUM20	-96.2141	8.88035	-10.83	<.0001	0	I12	0
NUM21	-72.44763	8.85968	-8.18	<.0001	0	I13	0
NUM22	-55.02523	10.5572	-5.21	<.0001	0	I14	0
NUM23	-49.38391	10.54348	-4.68	<.0001	0	I15	0
NUM24	-27.81997	10.55238	-2.64	0.0085	0	I16	0
NUM25	3.85213	10.63293	0.36	0.7172	0	I17	0
NUM26	0.10733	8.62488	0.01	0.9901	0	I18	0
NUM27	-22.18712	6.80907	-3.26	0.0012	0	I19	0
NUM28	-40.30755	6.77448	-5.95	<.0001	0	I20	0
NUM29	-24.17572	7.06499	-3.42	0.0006	0	I21	0
NUM30	-62.49659	7.24235	-8.63	<.0001	0	I22	0
NUM31	-43.96493	7.07187	-6.22	<.0001	0	I23	0
NUM32	15.7447	7.00291	2.25	0.0248	0	I24	0
NUM33	-22.49329	6.97071	-3.23	0.0013	0	I25	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr >ChiSq	-----Autocorrelations-----					
6	1.24	3	0.7428	0	0	-0.01	0	0.03	0.011
12	3.71	9	0.9296	-0.006	0.001	-0.001	0.003	0.03	0.036
18	13.38	15	0.5734	-0.041	-0.032	-0.045	-0.042	-0.046	-0.005
24	16.92	21	0.7157	-0.016	-0.041	-0.002	-0.005	-0.025	-0.024
30	26.85	27	0.4721	-0.023	-0.029	-0.009	-0.027	-0.06	0.055
36	36.29	33	0.3177	-0.031	-0.043	0.015	-0.024	0.068	0.011
42	39.66	39	0.4405	-0.01	-0.013	0.033	0.011	0.038	-0.009
48	43.06	45	0.5545	-0.014	0.016	0.006	-0.011	-0.021	0.044
54	44.91	51	0.7129	-0.009	0.025	0.017	0.016	0.015	0.011
60	49.61	57	0.7459	-0.001	0.006	-0.036	-0.026	0.022	0.039

66	58.68	63	0.6308	-0.026	0.004	0.019	-0.061	-0.027	0.047
72	62.01	69	0.7119	-0.024	0.01	-0.009	0.005	-0.029	0.036
78	66.93	75	0.7355	-0.014	0.001	-0.026	-0.008	0.003	0.057
84	76.85	81	0.6099	-0.055	-0.031	-0.011	0.008	0.052	-0.039
90	90.77	87	0.3699	0.022	-0.069	-0.04	-0.001	0.068	0.017
96	97.4	93	0.3569	0.004	0.032	0.055	-0.011	0.037	-0.004

Test	Tests for Normality		P-value
	Statistic		
Shapiro-Wilk	W	0.989595	Pr < W < 0.0001
Kolmogorov-Smirnov	D	0.026495	Pr > D 0.0615
Cramer-von Mises	W-Sq	0.205921	Pr > W-Sq < 0.0050
Anderson-Darling	A-Sq	1.776111	Pr > A-Sq < 0.0050

## Pukul 16:00

### The ARIMA Procedure

Parameter	Estimate	Conditional Least Squares Estimation			Lag	Variable	Shift
		Standard Error	t Value	Approx Pr >  t			
MA1,1	-0.282	0.03053	-9.24	<.0001	1	y	0
MA1,2	0.1275	0.03071	4.15	<.0001	50	y	0
AR1,1	0.19392	0.03151	6.15	<.0001	2	y	0
NUM1	0.10024	0.0021429	46.78	<.0001	0	t	0
NUM2	662.16607	1.74088	380.4	<.0001	0	H1	0
NUM3	659.22199	1.76033	374.5	<.0001	0	H2	0
NUM4	656.22807	1.76742	371.3	<.0001	0	H3	0
NUM5	661.10288	1.77117	373.3	<.0001	0	H4	0
NUM6	660.93335	1.76823	373.8	<.0001	0	H5	0
NUM7	632.7594	1.77104	357.3	<.0001	0	H6	0
NUM8	604.39152	1.73566	348.2	<.0001	0	H7	0
NUM9	-95.04506	8.49206	-11.19	<.0001	0	I1	0
NUM10	-25.3064	7.39578	-3.42	0.0006	0	I2	0
NUM11	-33.31188	8.52697	-3.91	<.0001	0	I3	0
NUM12	-113.84051	10.64402	-10.7	<.0001	0	I4	0
NUM13	-151.57058	8.83379	-17.16	<.0001	0	I5	0
NUM14	-26.26695	10.63358	-2.47	0.0137	0	I6	0
NUM15	-4.12156	8.53891	-0.48	0.6294	0	I7	0
NUM16	-29.45777	10.4167	-2.83	0.0048	0	I8	0
NUM17	-36.31585	10.38819	-3.5	0.0005	0	I9	0
NUM18	-11.33385	8.57447	-1.32	0.1865	0	I10	0
NUM19	18.50291	8.67702	2.13	0.0332	0	I11	0
NUM20	-101.94217	8.76078	-11.64	<.0001	0	I12	0
NUM21	-93.19882	8.73467	-10.67	<.0001	0	I13	0
NUM22	-39.63621	10.39339	-3.81	0.0001	0	I14	0
NUM23	-53.27755	10.38582	-5.13	<.0001	0	I15	0
NUM24	-9.35035	10.38171	-0.9	0.368	0	I16	0
NUM25	-37.4071	10.47262	-3.57	0.0004	0	I17	0

NUM26	8.51315	8.50411	1	0.317	0	118	0
NUM27	-27.70916	6.67775	-4.15	<.0001	0	119	0
NUM28	-24.62608	6.65824	-3.7	0.0002	0	120	0
NUM29	-25.6879	6.97835	-3.68	0.0002	0	121	0
NUM30	-84.51907	7.15087	-11.82	<.0001	0	122	0
NUM31	-48.91703	6.98466	-7	<.0001	0	123	0
NUM32	31.77724	6.90222	4.6	<.0001	0	124	0
NUM33	-2.36105	6.87566	-0.34	0.7314	0	125	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr >ChiSq	-----Autocorrelations-----					
6	1.28	3	0.7327	0	-0.002	0.013	0.008	0.025	0.018
12	3.09	9	0.9605	-0.033	0.012	0.018	-0.006	0.008	0.004
18	13.1	15	0.5942	0.031	0.035	-0.033	0.04	-0.021	0.061
24	22.58	21	0.3666	0.038	-0.025	0.01	0.052	0.052	-0.031
30	26.49	27	0.4917	-0.006	-0.024	0.003	-0.022	-0.047	0.012
36	31.95	33	0.5194	-0.04	-0.036	-0.025	-0.026	0.018	0.016
42	37.05	39	0.5592	0.021	-0.007	0.046	-0.008	-0.028	-0.032
48	44.44	45	0.4956	0.034	0.018	-0.006	-0.057	-0.02	-0.035
54	46.52	51	0.652	0.028	-0.006	-0.015	-0.01	-0.014	-0.021
60	57.02	57	0.4744	-0.032	-0.08	0.039	-0.009	-0.001	0.007
66	66.71	63	0.3506	0.028	0	-0.032	0.052	-0.038	0.048
72	76.82	69	0.2425	-0.018	0.003	0.014	0.01	-0.086	0.024
78	81.93	75	0.2732	0.022	-0.047	0.024	-0.032	0.003	-0.005
84	87.52	81	0.2907	0.004	0.057	0.005	-0.028	0.01	0.023
90	93.39	87	0.3004	-0.016	0.004	0.008	0.057	0.007	-0.036
96	96.3	93	0.3867	-0.008	-0.026	-0.004	0.006	-0.038	0.012

## Tests for Normality

Test	Statistic	P-value
Shapiro-Wilk	W 0.991649	Pr < W <0.0001
Kolmogorov-Smirnov	D 0.026436	Pr > D 0.0628
Cramer-von Mises	W-Sq 0.195595	Pr > W-Sq 0.0062
Anderson-Darling	A-Sq 1.585543	Pr > A-Sq <0.0050

**Pukul 20:00**

## The ARIMA Procedure

## Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
MA1,1	-0.07441	0.03118	-2.39	0.0172	7	y	0
AR1,1	0.25233	0.03036	8.31	<.0001	1	y	0
AR1,2	0.21231	0.03024	7.02	<.0001	2	y	0
NUM1	0.10693	0.0028468	37.56	<.0001	0	t	0
NUM2	731.79503	2.11034	346.8	<.0001	0	H1	0
NUM3	728.04666	2.12491	342.6	<.0001	0	H2	0

NUM4	726.52397	2.12775	341.5	<.0001	0	H3	0
NUM5	734.58046	2.13335	344.3	<.0001	0	H4	0
NUM6	734.39402	2.13125	344.6	<.0001	0	H5	0
NUM7	713.9931	2.13391	334.6	<.0001	0	H6	0
NUM8	714.98951	2.10651	339.4	<.0001	0	H7	0
NUM9	-23.53141	8.22012	-2.86	0.0043	0	I1	0
NUM10	-23.53454	7.11188	-3.31	0.001	0	I2	0
NUM11	-8.31017	8.22897	-1.01	0.3128	0	I3	0
NUM12	-135.07013	10.22851	-13.21	<.0001	0	I4	0
NUM13	-250.83875	8.3917	-29.89	<.0001	0	I5	0
NUM14	-8.73743	10.20971	-0.86	0.3923	0	I6	0
NUM15	24.81104	8.24301	3.01	0.0027	0	I7	0
NUM16	-9.34351	10.0457	-0.93	0.3525	0	I8	0
NUM17	-15.99248	10.03683	-1.59	0.1114	0	I9	0
NUM18	-3.26144	8.35085	-0.39	0.6962	0	I10	0
NUM19	32.87999	8.42467	3.9	0.0001	0	I11	0
NUM20	-75.46834	8.35861	-9.03	<.0001	0	I12	0
NUM21	-66.22966	8.33953	-7.94	<.0001	0	I13	0
NUM22	-19.13586	10.04597	-1.9	0.0571	0	I14	0
NUM23	-16.94421	10.04326	-1.69	0.0919	0	I15	0
NUM24	-14.2653	10.06121	-1.42	0.1565	0	I16	0
NUM25	-6.1015	10.1439	-0.6	0.5476	0	I17	0
NUM26	16.22257	8.2012	1.98	0.0482	0	I18	0
NUM27	5.80005	6.43663	0.9	0.3677	0	I19	0
NUM28	-3.65126	6.42124	-0.57	0.5697	0	I20	0
NUM29	-32.1389	6.71888	-4.78	<.0001	0	I21	0
NUM30	-46.44926	6.71935	-6.91	<.0001	0	I22	0
NUM31	-37.30507	6.75148	-5.53	<.0001	0	I23	0
NUM32	32.52267	6.55762	4.96	<.0001	0	I24	0
NUM33	20.54008	6.55702	3.13	0.0018	0	I25	0

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr >ChiSq	-----Autocorrelations-----					
6	4.39	3	0.2222	0.008	0.006	-0.038	0.026	-0.039	0.016
12	7.54	9	0.581	0.001	-0.009	-0.016	0.047	0.001	0.017
18	9.58	15	0.8455	-0.011	0.017	0.024	-0.023	-0.015	-0.007
24	16.5	21	0.741	-0.055	-0.006	0.011	0.036	-0.009	0.041
30	22.51	27	0.7108	0.014	0.027	0.005	0.041	-0.044	-0.028
36	26.78	33	0.7692	0.037	-0.008	0.041	0.012	-0.016	-0.014
42	30.73	39	0.8251	0.002	-0.027	0.03	0.013	0.021	-0.035
48	32.86	45	0.9107	0.032	-0.013	0.018	0	0.011	0.016
54	37.25	51	0.9251	0.006	-0.024	-0.051	-0.022	-0.003	0.01
60	40.44	57	0.9525	0.002	0.03	-0.036	0.01	0.001	0.022
66	43.01	63	0.9746	-0.007	0.041	-0.01	0.012	0.013	0.003
72	50.04	69	0.9584	-0.03	-0.02	-0.037	0.004	-0.055	0.018
78	52.54	75	0.9773	-0.027	-0.032	-0.013	0.009	-0.001	-0.01
84	55.87	81	0.9851	-0.027	-0.006	-0.035	-0.015	0.011	-0.022
90	65.29	87	0.9604	-0.027	-0.016	0.018	0.025	-0.066	-0.04

96 70.49 93 0.9605 0.004 0.028 -0.003 -0.017 -0.009 -0.056

Test	Tests for Normality		P-value	
	Statistic			
Shapiro-Wilk	W	0.995624	Pr < W	0.0032
Kolmogorov-Smirnov	D	0.021531	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.089752	Pr > W-Sq	0.1571
Anderson-Darling	A-Sq	0.744467	Pr > A-Sq	0.0529

## Pukul 24:00

### The ARIMA Procedure

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
MA1,1	-0.29927	0.0306	-9.78	<.0001	1	y	0
MA1,2	-0.14899	0.03065	-4.86	<.0001	2	y	0
NUM1	0.09884	0.0021316	46.37	<.0001	0	t	0
NUM2	545.04225	1.75394	310.8	<.0001	0	H1	0
NUM3	547.34215	1.77345	308.6	<.0001	0	H2	0
NUM4	552.36746	1.77964	310.4	<.0001	0	H3	0
NUM5	549.05891	1.78401	307.8	<.0001	0	H4	0
NUM6	553.9519	1.78109	311	<.0001	0	H5	0
NUM7	549.48706	1.78459	307.9	<.0001	0	H6	0
NUM8	546.76675	1.74858	312.7	<.0001	0	H7	0
NUM9	-6.60571	8.51763	-0.78	0.4382	0	I1	0
NUM10	-25.97846	7.41088	-3.51	0.0005	0	I2	0
NUM11	-4.89476	8.57843	-0.57	0.5684	0	I3	0
NUM12	-63.07994	10.7239	-5.88	<.0001	0	I4	0
NUM13	-156.2825	8.9494	-17.46	<.0001	0	I5	0
NUM14	5.05199	10.72091	0.47	0.6376	0	I6	0
NUM15	31.21522	8.58708	3.64	0.0003	0	I7	0
NUM16	-4.90225	10.48275	-0.47	0.6401	0	I8	0
NUM17	19.75032	10.43675	1.89	0.0587	0	I9	0
NUM18	7.69545	8.59713	0.9	0.3709	0	I10	0
NUM19	43.30282	8.68424	4.99	<.0001	0	I11	0
NUM20	-45.63752	8.85947	-5.15	<.0001	0	I12	0
NUM21	-45.29724	8.83474	-5.13	<.0001	0	I13	0
NUM22	3.36411	10.43611	0.32	0.7472	0	I14	0
NUM23	-27.65302	10.44598	-2.65	0.0082	0	I15	0
NUM24	2.50939	10.443	0.24	0.8101	0	I16	0
NUM25	7.26875	10.54456	0.69	0.4908	0	I17	0
NUM26	14.2003	8.58364	1.65	0.0984	0	I18	0
NUM27	-10.74683	6.71262	-1.6	0.1097	0	I19	0
NUM28	0.5579	6.69819	0.08	0.9336	0	I20	0
NUM29	-23.71391	7.02921	-3.37	0.0008	0	I21	0
NUM30	-10.2533	7.25324	-1.41	0.1578	0	I22	0
NUM31	-8.69363	7.03171	-1.24	0.2166	0	I23	0

NUM32	54.6201	6.98556	7.82	<.0001	0	124	0
NUM33	27.03159	6.94371	3.89	0.0001	0	125	0

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr >ChiSq	-----Autocorrelations-----						
6	1.6	4	0.8086	0.001	0.003	0.005	0.006	-0.01	0.036	
12	2.44	10	0.9918	0.002	-0.01	-0.01	-0.018	-0.011	-0.011	
18	5.97	16	0.9884	0.019	-0.012	-0.012	-0.026	-0.008	-0.043	
24	9.59	22	0.9896	0.009	0.028	-0.023	0.026	-0.01	0.033	
30	15.45	28	0.9733	-0.007	0.038	0.025	0.021	0.05	-0.01	
36	21.39	34	0.9545	-0.03	-0.027	-0.012	0.022	0.046	-0.029	
42	23.83	40	0.9801	0.003	0.002	0.009	0.036	-0.024	-0.013	
48	30.5	46	0.9618	-0.028	0.008	0.027	-0.004	-0.063	0.016	
54	34.16	52	0.9735	0.045	-0.002	0.004	0.013	-0.006	-0.031	
60	39.43	58	0.9706	0.038	0.015	0.02	-0.047	-0.01	-0.013	
66	48.8	64	0.9204	0.027	-0.025	-0.07	-0.009	-0.024	0.034	
72	49.82	70	0.9676	0.005	-0.011	-0.004	0.024	0.001	-0.012	
78	52.73	76	0.9807	-0.021	-0.02	0.031	0.007	-0.013	0.022	
84	65.73	82	0.9053	0.027	0.018	0.033	-0.085	0.002	-0.039	
90	71.93	88	0.8931	0.054	0.004	0.002	-0.024	-0.023	-0.034	
96	75.41	94	0.9204	-0.036	0.014	0.002	0.024	-0.019	0.022	

Tests for Normality

Test	Statistic	P-value
Shapiro-Wilk	W 0.990677	Pr < W <.0001
Kolmogorov-Smirnov	D 0.024905	Pr > D 0.0961
Cramer-von Mises	W-Sq 0.187338	Pr > W-Sq 0.008
Anderson-Darling	A-Sq 1.637138	Pr > A-Sq <.0050

### Lampiran 3. *Output* ARIMAX Data Aktual Pukul 01:00

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.66995	0.03079	21.76	<.0001	1	y	0
AR1,2	0.20624	0.03684	5.6	<.0001	2	y	0
AR1,3	-0.10205	0.0319	-3.2	0.0014	3	y	0
AR1,4	1.06E-01	0.0227	4.69	<.0001	7	y	0
AR1,5	0.0443	0.02143	2.07	0.0389	11	y	0
NUM1	0.10643	0.01762	6.04	<.0001	0	t	0
NUM2	448.13166	10.65618	42.05	<.0001	0	H1	0
NUM3	448.79432	10.64445	42.16	<.0001	0	H2	0
NUM4	449.7528	10.62221	42.34	<.0001	0	H3	0
NUM5	450.08254	10.64867	42.27	<.0001	0	H4	0
NUM6	452.27698	10.67049	42.39	<.0001	0	H5	0
NUM7	454.16041	10.66801	42.57	<.0001	0	H6	0
NUM8	452.05979	10.66424	42.39	<.0001	0	H7	0
NUM9	46.56969	8.29216	5.62	<.0001	0	I1	0
NUM10	4.88094	7.03627	0.69	0.488	0	I2	0
NUM11	-7.11902	8.19016	-0.87	0.3849	0	I3	0
NUM12	75.78307	10.53127	7.2	<.0001	0	I4	0
NUM13	-7.86759	8.96486	-0.88	0.3804	0	I5	0
NUM14	-120.20768	10.60407	-11.34	<.0001	0	I6	0
NUM15	-4.14947	8.10443	-0.51	0.6088	0	I7	0
NUM16	3.28423	9.91718	0.33	0.7406	0	I8	0
NUM17	2.9589	9.86972	0.3	0.7644	0	I9	0
NUM18	10.52454	8.29382	1.27	0.2047	0	I10	0
NUM19	9.42364	8.41904	1.12	0.2633	0	I11	0
NUM20	1.0056	8.75259	0.11	0.9086	0	I12	0
NUM21	-2.03184	8.68421	-0.23	0.8151	0	I13	0
NUM22	7.74944	9.8497	0.79	0.4316	0	I14	0
NUM23	2.22569	9.8662	0.23	0.8216	0	I15	0
NUM24	4.30698	9.8638	0.44	0.6625	0	I16	0
NUM25	6.83372	10.09511	0.68	0.4986	0	I17	0
NUM26	8.8208	8.10878	1.09	0.2769	0	I18	0
NUM27	7.88133	6.35335	1.24	0.2151	0	I19	0
NUM28	-10.48623	6.31264	-1.66	0.097	0	I20	0
NUM29	-7.3791	7.37048	-1	0.317	0	I21	0
NUM30	-0.33085	7.78595	-0.04	0.9661	0	I22	0
NUM31	-9.09718	7.38777	-1.23	0.2185	0	I23	0
NUM32	8.16385	6.90789	1.18	0.2375	0	I24	0
NUM33	9.86254	6.84963	1.44	0.1502	0	I25	0

Variance Estimate	292.5427
Std Error Estimate	17.10388
AIC	9371.396
SBC	9561.374
Number of Residuals	1096

\* AIC and SBC do not include log determinant.

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	1.33	1	0.2486	-0.002	-0.008	-0.02	0.018	-0.011	0.018
12	8.21	7	0.3144	-0.034	0.046	0.017	-0.039	-0.031	-0.013
18	15.23	13	0.2934	0.029	0.035	-0.03	0.035	0.007	0.046
24	20.16	19	0.3849	-0.042	0.006	0.01	0.018	-0.01	-0.046
30	32.4	25	0.1467	-0.051	0.046	-0.043	-0.063	0.013	0.013
36	43.28	31	0.0703	0.006	0.051	-0.004	0.082	0.013	0.011
42	46.96	37	0.1265	-0.026	0.039	0.012	-0.011	-0.022	-0.015
48	51.03	43	0.1873	0.003	0.016	0.03	0.017	0.015	0.043

Tests for Normality

Test	Statistic	P-value
Shapiro-Wilk	W 0.958977	Pr < W < 0.0001
Kolmogorov-Smirnov	D 0.051006	Pr > D < 0.0100
Cramer-von Mises	W-Sq 0.837674	Pr > W-Sq < 0.0050
Anderson-Darling	A-Sq 5.139708	Pr > A-Sq < 0.0050

**Pukul 02:00**

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.65578	0.03062	21.41	<.0001	1	y	0
AR1,2	0.15175	0.03077	4.93	<.0001	2	y	0
AR1,3	0.10888	0.0201	5.42	<.0001	9	y	0
NUM1	1.04E-01	0.01598	6.49	<.0001	0	t	0
NUM2	428.38035	9.76699	43.86	<.0001	0	H1	0
NUM3	428.51176	9.76344	43.89	<.0001	0	H2	0
NUM4	430.2975	9.74396	44.16	<.0001	0	H3	0
NUM5	430.38346	9.76093	44.09	<.0001	0	H4	0
NUM6	432.80209	9.77567	44.27	<.0001	0	H5	0
NUM7	433.17355	9.77322	44.32	<.0001	0	H6	0
NUM8	431.6514	9.76973	44.18	<.0001	0	H7	0
NUM9	39.75282	8.18445	4.86	<.0001	0	I1	0
NUM10	6.32637	7.01776	0.9	0.3675	0	I2	0
NUM11	3.29943	8.1327	0.41	0.685	0	I3	0



NUM12	15.6406	10.45723	1.5	0.135	0	14	0
NUM13	-18.19698	8.95991	-2.03	0.0425	0	15	0
NUM14	-104.75318	10.4554	-10.02	<.0001	0	16	0
NUM15	-7.81856	8.06652	-0.97	0.3326	0	17	0
NUM16	6.51714	9.86607	0.66	0.509	0	18	0
NUM17	-1.85903	9.80971	-0.19	0.8497	0	19	0
NUM18	11.23591	8.16101	1.38	0.1689	0	110	0
NUM19	7.56369	8.28173	0.91	0.3613	0	111	0
NUM20	-1.70999	8.74264	-0.2	0.845	0	112	0
NUM21	-5.95031	8.67831	-0.69	0.4931	0	113	0
NUM22	8.52159	9.80194	0.87	0.3848	0	114	0
NUM23	-3.24609	9.80725	-0.33	0.7407	0	115	0
NUM24	5.91779	9.81292	0.6	0.5466	0	116	0
NUM25	3.74118	10.05234	0.37	0.7098	0	117	0
NUM26	11.51901	8.07351	1.43	0.1539	0	118	0
NUM27	7.29827	6.34008	1.15	0.2499	0	119	0
NUM28	-8.1973	6.29464	-1.3	0.1931	0	120	0
NUM29	1.66222	7.17986	0.23	0.817	0	121	0
NUM30	4.70187	7.74006	0.61	0.5437	0	122	0
NUM31	-6.63504	7.22072	-0.92	0.3584	0	123	0
NUM32	10.26928	6.95308	1.48	0.14	0	124	0
NUM33	8.55174	6.86718	1.25	0.2133	0	125	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr >ChiSq	-----Autocorrelations-----					
6	2.62	3	0.4544	0.004	-0.013	-0.035	-0.01	-0.018	0.024
12	16.03	9	0.0663	0.03	0.057	0.026	-0.069	-0.044	0.025
18	20.44	15	0.1558	0.044	0	-0.018	0.011	0.038	0.011
24	27.1	21	0.1675	-0.053	0.024	-0.006	0.043	-0.026	-0.004
30	30.22	27	0.3045	-0.036	0.001	-0.021	-0.029	0.014	-0.001
36	37.11	33	0.285	0.022	0.061	0.022	0.036	0.009	-0.001
42	45.4	39	0.2227	-0.046	0.026	0.001	0.026	0.027	-0.055
48	49.61	45	0.2947	0.003	0.019	0.027	0.015	0.04	0.026

## Tests for Normality

Test	Statistic	P-value
Shapiro-Wilk	W 0.962657	Pr < W <0.0001
Kolmogorov-Smirnov	D 0.046964	Pr > D <0.0100
Cramer-von Mises	W-Sq 0.894252	Pr > W-Sq <0.0050
Anderson-Darling	A-Sq 5.445457	Pr > A-Sq <0.0050

**Pukul 03:00**

## The ARIMA Procedure

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.66962	0.03062	21.87	<.0001	1	y	0
AR1,2	0.15761	0.0309	5.1	<.0001	2	y	0
AR1,3	0.09957	0.01912	5.21	<.0001	9	y	0
NUM1	0.10102	0.01616	6.25	<.0001	0	t	0
NUM2	415.62618	9.74018	42.67	<.0001	0	H1	0
NUM3	415.74458	9.73599	42.7	<.0001	0	H2	0
NUM4	416.33711	9.71634	42.85	<.0001	0	H3	0
NUM5	416.4118	9.73331	42.78	<.0001	0	H4	0
NUM6	419.55133	9.74807	43.04	<.0001	0	H5	0
NUM7	419.46089	9.74512	43.04	<.0001	0	H6	0
NUM8	417.65955	9.74302	42.87	<.0001	0	H7	0
NUM9	27.86673	7.4746	3.73	0.0002	0	I1	0
NUM10	-2.54852	6.37576	-0.4	0.6894	0	I2	0
NUM11	2.50537	7.39251	0.34	0.7347	0	I3	0
NUM12	3.99213	9.50192	0.42	0.6745	0	I4	0
NUM13	-17.36428	8.1424	-2.13	0.0332	0	I5	0
NUM14	-102.73298	9.49632	-10.82	<.0001	0	I6	0
NUM15	-7.95317	7.32699	-1.09	0.278	0	I7	0
NUM16	9.55509	8.96317	1.07	0.2866	0	I8	0
NUM17	9.42633	8.91756	1.06	0.2907	0	I9	0
NUM18	12.96133	7.41531	1.75	0.0808	0	I10	0
NUM19	9.91358	7.52769	1.32	0.1881	0	I11	0
NUM20	-0.312	7.9438	-0.04	0.9687	0	I12	0
NUM21	-6.77545	7.8863	-0.86	0.3905	0	I13	0
NUM22	7.63948	8.91164	0.86	0.3915	0	I14	0
NUM23	4.25343	8.9069	0.48	0.6331	0	I15	0
NUM24	-0.94139	8.90811	-0.11	0.9159	0	I16	0
NUM25	6.30517	9.13097	0.69	0.49	0	I17	0
NUM26	7.02073	7.33194	0.96	0.3385	0	I18	0
NUM27	5.36438	5.75746	0.93	0.3517	0	I19	0
NUM28	-6.62974	5.71495	-1.16	0.2463	0	I20	0
NUM29	3.8786	6.53123	0.59	0.5527	0	I21	0
NUM30	4.46894	7.03719	0.64	0.5255	0	I22	0
NUM31	0.92903	6.56588	0.14	0.8875	0	I23	0
NUM32	2.86351	6.31365	0.45	0.6503	0	I24	0
NUM33	7.81637	6.23461	1.25	0.2102	0	I25	0

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr >ChiSq	-----Autocorrelations-----					
6	5.56	3	0.135	0.01	0.02	-0.045	-0.026	-0.025	0.036
12	16.08	9	0.0652	0.007	0.025	0.027	-0.079	-0.03	0.032
18	17.08	15	0.3143	0.017	0.008	0.011	0.01	0.015	0.01
24	22.97	21	0.3454	-0.048	0.025	0.011	0.039	-0.027	-0.003
30	28.34	27	0.3939	-0.049	-0.013	-0.039	-0.004	-0.022	0.012
36	39.34	33	0.2072	0.011	0.044	0.041	0.075	-0.014	-0.015
42	42.28	39	0.3311	-0.001	0.023	-0.002	0.016	-0.013	-0.04
48	51.17	45	0.2445	-0.004	-0.023	0.054	0.06	-0.002	0.025

Tests for Normality				
Test	Statistic		P-value	
Shapiro-Wilk	W	0.969413	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.04105	Pr > D	<0.0100
Cramer-von Mises	W-Sq	0.44305	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	3.019278	Pr > A-Sq	<0.0050

## Pukul 04:00

### The ARIMA Procedure

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.67966	0.0309	21.99	<.0001	1	y	0
AR1,2	0.15573	0.03742	4.16	<.0001	2	y	0
AR1,3	-0.08384	0.03771	-2.22	0.0264	3	y	0
AR1,4	0.07471	0.03162	2.36	0.0183	4	y	0
AR1,5	0.096	0.02048	4.69	<.0001	9	y	0
NUM1	0.09653	0.01521	6.35	<.0001	0	t	0
NUM2	409.4688	9.23155	44.36	<.0001	0	H1	0
NUM3	410.90015	9.22695	44.53	<.0001	0	H2	0
NUM4	411.2331	9.20848	44.66	<.0001	0	H3	0
NUM5	411.67397	9.22522	44.62	<.0001	0	H4	0
NUM6	413.16471	9.24109	44.71	<.0001	0	H5	0
NUM7	413.72927	9.23611	44.79	<.0001	0	H6	0
NUM8	411.25241	9.23494	44.53	<.0001	0	H7	0
NUM9	26.7388	7.28978	3.67	0.0003	0	I1	0
NUM10	-0.59078	6.23528	-0.09	0.9245	0	I2	0
NUM11	1.57163	7.23269	0.22	0.828	0	I3	0

NUM12	4.24502	9.37651	0.45	0.6508	0	14	0
NUM13	-19.01965	8.04451	-2.36	0.0182	0	15	0
NUM14	-99.10328	9.35998	-10.59	<.0001	0	16	0
NUM15	-4.59071	7.18113	-0.64	0.5228	0	17	0
NUM16	12.77905	8.76222	1.46	0.145	0	18	0
NUM17	2.85267	8.69605	0.33	0.7429	0	19	0
NUM18	14.75479	7.28293	2.03	0.043	0	110	0
NUM19	7.32197	7.39501	0.99	0.3223	0	111	0
NUM20	-1.78584	7.82972	-0.23	0.8196	0	112	0
NUM21	-4.45356	7.75426	-0.57	0.5659	0	113	0
NUM22	12.82603	8.69623	1.47	0.1405	0	114	0
NUM23	7.08956	8.7059	0.81	0.4156	0	115	0
NUM24	1.2368	8.70344	0.14	0.887	0	116	0
NUM25	10.09289	8.94436	1.13	0.2594	0	117	0
NUM26	11.63275	7.16887	1.62	0.105	0	118	0
NUM27	10.78678	5.63751	1.91	0.056	0	119	0
NUM28	-5.97974	5.60607	-1.07	0.2864	0	120	0
NUM29	1.72008	6.54591	0.26	0.7928	0	121	0
NUM30	12.91342	7.07115	1.83	0.0681	0	122	0
NUM31	-2.72306	6.56803	-0.41	0.6785	0	123	0
NUM32	-0.68285	6.22194	-0.11	0.9126	0	124	0
NUM33	11.08302	6.14685	1.8	0.0717	0	125	0

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr >ChiSq	-----Autocorrelations-----					
6	1.84	1	0.1748	0.003	-0.002	-0.004	-0.014	-0.028	0.026
12	9.2	7	0.2384	-0.005	0.014	0.024	-0.037	-0.066	0.013
18	12.46	13	0.4904	0.026	0.009	0.006	-0.006	0.044	0.011
24	20.07	19	0.3901	-0.036	0.051	-0.025	0.033	-0.029	-0.018
30	26.29	25	0.3922	-0.018	0.01	-0.058	-0.039	0.008	0.011
36	40.33	31	0.1217	0.014	0.067	0.048	0.064	-0.036	0.008
42	42.14	37	0.2583	0.005	0.012	0.023	-0.003	-0.02	-0.022
48	45.96	43	0.3507	-0.012	0.02	0.026	0.041	-0.01	0.018

Tests for Normality

Test	Statistic	P-value
Shapiro-Wilk	W 0.966264	Pr < W <0.0001
Kolmogorov-Smirnov	D 0.048466	Pr > D <0.0100
Cramer-von Mises	W-Sq 0.726523	Pr > W-Sq <0.0050
Anderson-Darling	A-Sq 4.41777	Pr > A-Sq <0.0050

**Pukul 05:00**

## The ARIMA Procedure

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.67839	0.03077	22.05	<.0001	1	y	0
AR1,2	0.14679	0.03088	4.75	<.0001	2	y	0
AR1,3	0.09783	0.01926	5.08	<.0001	9	y	0
NUM1	0.09627	0.01431	6.73	<.0001	0	t	0
NUM2	416.08676	8.67716	47.95	<.0001	0	H1	0
NUM3	417.21438	8.67323	48.1	<.0001	0	H2	0
NUM4	417.344	8.65584	48.22	<.0001	0	H3	0
NUM5	417.13607	8.67108	48.11	<.0001	0	H4	0
NUM6	419.87921	8.6845	48.35	<.0001	0	H5	0
NUM7	419.17309	8.682	48.28	<.0001	0	H6	0
NUM8	413.3238	8.67976	47.62	<.0001	0	H7	0
NUM9	18.88634	6.82306	2.77	0.0057	0	I1	0
NUM10	-5.50848	5.83368	-0.94	0.3453	0	I2	0
NUM11	-1.7409	6.76945	-0.26	0.7971	0	I3	0
NUM12	25.06433	8.71494	2.88	0.0041	0	I4	0
NUM13	-25.12495	7.48252	-3.36	0.0008	0	I5	0
NUM14	-102.83969	8.72859	-11.78	<.0001	0	I6	0
NUM15	-6.04869	6.7055	-0.9	0.3672	0	I7	0
NUM16	3.51886	8.20232	0.43	0.668	0	I8	0
NUM17	-1.39758	8.14551	-0.17	0.8638	0	I9	0
NUM18	10.59948	6.78242	1.56	0.1184	0	I10	0
NUM19	4.64099	6.88311	0.67	0.5003	0	I11	0
NUM20	-1.43582	7.30201	-0.2	0.8442	0	I12	0
NUM21	-5.38931	7.2426	-0.74	0.457	0	I13	0
NUM22	8.5129	8.14544	1.05	0.2962	0	I14	0
NUM23	3.59158	8.15002	0.44	0.6595	0	I15	0
NUM24	-2.81228	8.14971	-0.35	0.7301	0	I16	0
NUM25	-0.41366	8.35746	-0.05	0.9605	0	I17	0
NUM26	9.62363	6.71441	1.43	0.1521	0	I18	0
NUM27	5.17833	5.26867	0.98	0.3259	0	I19	0
NUM28	-2.69468	5.22924	-0.52	0.6064	0	I20	0
NUM29	6.04111	5.99968	1.01	0.3142	0	I21	0
NUM30	24.37782	6.48699	3.76	0.0002	0	I22	0
NUM31	-5.43364	6.02924	-0.9	0.3677	0	I23	0
NUM32	4.83613	5.80088	0.83	0.4046	0	I24	0
NUM33	28.57868	5.72383	4.99	<.0001	0	I25	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.51	3	0.1378	0.007	0.018	-0.044	-0.036	-0.027	0.026
12	15.15	9	0.0868	0.002	0.052	0.008	-0.047	-0.057	0.024
18	19	15	0.2136	0.015	0.009	0.035	0	0.013	0.042
24	25	21	0.2474	-0.03	0.043	-0.018	0.046	-0.007	-0.01
30	33.2	27	0.1904	-0.067	0.019	-0.047	-0.009	-0.001	-0.008
36	37.92	33	0.2548	0.037	0.025	0.031	0.027	0.014	0.017
42	41.91	39	0.3459	0.023	-0.006	0.017	-0.014	0.003	-0.049
48	48.05	45	0.3502	-0.005	0.011	0.054	0.047	0.002	0.007

## Tests for Normality

Test	Statistic	P-value
Shapiro-Wilk	W 0.983696	Pr < W < 0.0001
Kolmogorov-Smirnov	D 0.026669	Pr > D 0.0577
Cramer-von Mises	W-Sq 0.275956	Pr > W-Sq < 0.0050
Anderson-Darling	A-Sq 1.959686	Pr > A-Sq < 0.0050

**Pukul 06:00**

## The ARIMA Procedure

## Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.60436	0.03051	19.81	<.0001	1	y	0
AR1,2	0.19343	0.03056	6.33	<.0001	2	y	0
AR1,3	0.09517	0.02075	4.59	<.0001	9	y	0
NUM1	0.09274	0.01126	8.23	<.0001	0	t	0
NUM2	446.57472	7.03027	63.52	<.0001	0	H1	0
NUM3	445.57439	7.02903	63.39	<.0001	0	H2	0
NUM4	447.21541	7.01627	63.74	<.0001	0	H3	0
NUM5	446.74537	7.02764	63.57	<.0001	0	H4	0
NUM6	449.63327	7.03799	63.89	<.0001	0	H5	0
NUM7	444.85165	7.03612	63.22	<.0001	0	H6	0
NUM8	430.64936	7.03175	61.24	<.0001	0	H7	0
NUM9	-1.00389	7.05244	-0.14	0.8868	0	I1	0
NUM10	-12.09977	6.07972	-1.99	0.0468	0	I2	0
NUM11	-13.13162	7.05037	-1.86	0.0628	0	I3	0
NUM12	19.61328	8.98839	2.18	0.0293	0	I4	0
NUM13	-59.45704	7.61676	-7.81	<.0001	0	I5	0
NUM14	-96.73745	8.99206	-10.76	<.0001	0	I6	0

NUM15	-18.76207	6.99781	-2.68	0.0075	0	17	0
NUM16	-9.79719	8.55094	-1.15	0.2522	0	18	0
NUM17	-11.71971	8.50465	-1.38	0.1685	0	19	0
NUM18	4.02947	7.09692	0.57	0.5703	0	110	0
NUM19	-1.33879	7.19891	-0.19	0.8525	0	111	0
NUM20	-7.73155	7.47115	-1.03	0.301	0	112	0
NUM21	-12.47058	7.42725	-1.68	0.0934	0	113	0
NUM22	-2.07555	8.5134	-0.24	0.8074	0	114	0
NUM23	-2.31519	8.50999	-0.27	0.7856	0	115	0
NUM24	-17.52021	8.50941	-2.06	0.0397	0	116	0
NUM25	-7.67683	8.69475	-0.88	0.3775	0	117	0
NUM26	3.14661	7.00225	0.45	0.6533	0	118	0
NUM27	4.97382	5.48939	0.91	0.3651	0	119	0
NUM28	-15.58073	5.46416	-2.85	0.0044	0	120	0
NUM29	1.29789	6.13494	0.21	0.8325	0	121	0
NUM30	19.69448	6.49192	3.03	0.0025	0	122	0
NUM31	-9.11224	6.16666	-1.48	0.1398	0	123	0
NUM32	-4.74446	5.92564	-0.8	0.4235	0	124	0
NUM33	20.04353	5.86808	3.42	0.0007	0	125	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.05	3	0.5619	-0.008	-0.016	0.006	-0.037	-0.013	0.004
12	7.09	9	0.6274	-0.001	0.042	-0.043	-0.002	-0.03	0.002
18	15.44	15	0.4201	0.048	0.043	-0.019	0.008	0.036	0.039
24	27.12	21	0.167	-0.039	0.077	0.019	0.007	-0.005	-0.05
30	29.48	27	0.3378	-0.036	-0.015	-0.011	-0.02	0.008	-0.007
36	38.01	33	0.2517	0.007	0.054	0.025	0.025	0.012	0.056
42	41.74	39	0.3527	-0.035	0.022	0.007	0.003	-0.028	-0.027
48	53.24	45	0.1867	-0.054	0.047	0.045	0.053	-0.011	-0.002

## Tests for Normality

Test	Statistic	P-value
Shapiro-Wilk	W	0.960458
Kolmogorov-Smirnov	D	0.041687
Cramer-von Mises	W-Sq	0.501447
Anderson-Darling	A-Sq	3.483992
	Pr < W	<0.0001
	Pr > D	<0.0100
	Pr > W-Sq	<0.0050
	Pr > A-Sq	<0.0050

**Pukul 07:00**

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.63306	0.03069	20.63	<.0001	1	y	0
AR1,2	0.12581	0.03235	3.89	0.0001	2	y	0
AR1,3	0.07171	0.02548	2.81	0.005	5	y	0
AR1,4	7.89E-02	0.02265	3.48	0.0005	9	y	0
NUM1	0.09477	0.01143	8.29	<.0001	0	t	0
NUM2	444.40392	7.04629	63.07	<.0001	0	H1	0
NUM3	445.29168	7.04401	63.22	<.0001	0	H2	0
NUM4	445.54971	7.03041	63.37	<.0001	0	H3	0
NUM5	446.01556	7.0436	63.32	<.0001	0	H4	0
NUM6	448.5706	7.05337	63.6	<.0001	0	H5	0
NUM7	438.42281	7.05228	62.17	<.0001	0	H6	0
NUM8	429.4325	7.04765	60.93	<.0001	0	H7	0
NUM9	8.46874	6.263	1.35	0.1766	0	I1	0
NUM10	-6.95419	5.399	-1.29	0.198	0	I2	0
NUM11	-14.29483	6.26985	-2.28	0.0228	0	I3	0
NUM12	-1.5722	8.06139	-0.2	0.8454	0	I4	0
NUM13	-83.1046	6.91546	-12.02	<.0001	0	I5	0
NUM14	-42.56661	8.06173	-5.28	<.0001	0	I6	0
NUM15	-11.00952	6.20564	-1.77	0.0763	0	I7	0
NUM16	-5.46544	7.59082	-0.72	0.4717	0	I8	0
NUM17	-17.05535	7.56163	-2.26	0.0243	0	I9	0
NUM18	-0.08835	6.26815	-0.01	0.9888	0	I10	0
NUM19	-4.62899	6.36434	-0.73	0.4672	0	I11	0
NUM20	-12.33152	6.75119	-1.83	0.068	0	I12	0
NUM21	-4.35922	6.70368	-0.65	0.5157	0	I13	0
NUM22	-8.29949	7.54738	-1.1	0.2717	0	I14	0
NUM23	-11.9984	7.55526	-1.59	0.1126	0	I15	0
NUM24	-16.63146	7.54975	-2.2	0.0278	0	I16	0
NUM25	-11.24983	7.72698	-1.46	0.1457	0	I17	0
NUM26	-2.81255	6.21782	-0.45	0.6511	0	I18	0
NUM27	5.16773	4.87677	1.06	0.2895	0	I19	0
NUM28	-7.95529	4.8432	-1.64	0.1008	0	I20	0
NUM29	-12.48857	5.51817	-2.26	0.0238	0	I21	0
NUM30	-20.76757	5.96437	-3.48	0.0005	0	I22	0
NUM31	-16.1054	5.54367	-2.91	0.0037	0	I23	0
NUM32	-11.84922	5.36349	-2.21	0.0274	0	I24	0
NUM33	-2.50025	5.28999	-0.47	0.6366	0	I25	0

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----
--------	------------	----	------------	----------------------------



6	2.02	2	0.3648	-0.005	-0.024	0.025	-0.011	-0.017	-0.013
12	4.93	8	0.7653	0.012	0.004	-0.016	-0.041	-0.023	0.004
18	10.42	14	0.7307	0.044	0.004	0.026	0.009	-0.023	0.042
24	24.76	20	0.2107	-0.029	0.021	0.081	0.041	-0.048	-0.031
30	29.77	26	0.2772	0	-0.017	-0.025	-0.019	0.031	-0.047
36	35.8	32	0.2946	0.044	0.049	-0.018	-0.002	0.027	0.005
42	37.11	38	0.5104	0	-0.007	0.021	-0.001	-0.017	-0.02
48	46.34	44	0.3761	0.013	0.005	0.027	0.065	-0.021	0.05

Tests for Normality			
Test	Statistic	P-value	
Shapiro-Wilk	W	0.993319	Pr < W < 0.0001
Kolmogorov-Smirnov	D	0.023657	Pr > D 0.1403
Cramer-von Mises	W-Sq	0.14387	Pr > W-Sq 0.0296
Anderson-Darling	A-Sq	0.970426	Pr > A-Sq 0.0159

## Pukul 08:00

### The ARIMA Procedure

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.54984	0.03024	18.18	<.0001	1	y	0
AR1,2	0.15427	0.03278	4.71	<.0001	2	y	0
AR1,3	0.08938	0.02846	3.14	0.0017	4	y	0
AR1,4	1.21E-01	0.02491	4.87	<.0001	7	y	0
NUM1	0.10697	0.01463	7.31	<.0001	0	t	0
NUM2	478.49298	8.93202	53.57	<.0001	0	H1	0
NUM3	480.14869	8.92628	53.79	<.0001	0	H2	0
NUM4	479.62369	8.90909	53.84	<.0001	0	H3	0
NUM5	479.77988	8.9289	53.73	<.0001	0	H4	0
NUM6	482.20122	8.94123	53.93	<.0001	0	H5	0
NUM7	462.4992	8.9365	51.75	<.0001	0	H6	0
NUM8	452.50293	8.93372	50.65	<.0001	0	H7	0
NUM9	-27.60728	8.04116	-3.43	0.0006	0	I1	0
NUM10	-17.26908	6.87852	-2.51	0.0122	0	I2	0
NUM11	-27.68964	7.9924	-3.46	0.0006	0	I3	0
NUM12	-35.44382	10.15728	-3.49	0.0005	0	I4	0
NUM13	-105.20462	8.63001	-12.19	<.0001	0	I5	0
NUM14	-51.35446	10.16657	-5.05	<.0001	0	I6	0
NUM15	-24.27252	7.93103	-3.06	0.0023	0	I7	0
NUM16	-16.8014	9.69804	-1.73	0.0835	0	I8	0
NUM17	-20.77755	9.65118	-2.15	0.0316	0	I9	0
NUM18	-3.8792	8.0236	-0.48	0.6289	0	I10	0
NUM19	-17.06669	8.12026	-2.1	0.0358	0	I11	0
NUM20	-19.23777	8.50744	-2.26	0.0239	0	I12	0

NUM21	-11.86831	8.43576	-1.41	0.1597	0	I13	0
NUM22	-21.80779	9.64827	-2.26	0.024	0	I14	0
NUM23	-11.98193	9.66011	-1.24	0.2151	0	I15	0
NUM24	-27.62959	9.67019	-2.86	0.0044	0	I16	0
NUM25	-12.17171	9.85313	-1.24	0.217	0	I17	0
NUM26	-4.06419	7.93159	-0.51	0.6085	0	I18	0
NUM27	-4.14794	6.21955	-0.67	0.505	0	I19	0
NUM28	-37.78339	6.18788	-6.11	<.0001	0	I20	0
NUM29	-26.86933	6.84882	-3.92	<.0001	0	I21	0
NUM30	-54.59338	7.25817	-7.52	<.0001	0	I22	0
NUM31	-19.73196	6.86701	-2.87	0.0041	0	I23	0
NUM32	-16.1648	6.66994	-2.42	0.0155	0	I24	0
NUM33	-23.6391	6.61026	-3.58	0.0004	0	I25	0

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.91	2	0.2332	-0.005	-0.01	-0.012	-0.032	0.031	-0.021
12	7.31	8	0.5037	-0.028	-0.045	0.005	0.013	0.019	-0.024
18	13.73	14	0.4703	0.052	0.017	-0.012	-0.028	0.027	0.034
24	16.9	20	0.6596	-0.017	0.027	-0.003	0.022	0.005	-0.036
30	19.68	26	0.8063	0.004	0.037	-0.019	-0.016	0.002	-0.022
36	29.68	32	0.5843	0.068	0.046	0.016	0.005	0.035	0.024
42	31.3	38	0.7705	-0.004	0.01	0	-0.003	-0.014	-0.033
48	45.67	44	0.4026	0.018	-0.007	0.011	0.064	-0.052	0.072

Tests for Normality

Test	Statistic	P-value
Shapiro-Wilk	W 0.958987	Pr < W <.0001
Kolmogorov-Smirnov	D 0.046713	Pr > D <.0100
Cramer-von Mises	W-Sq 0.886388	Pr > W-Sq <.0050
Anderson-Darling	A-Sq 5.694886	Pr > A-Sq <.0050

**Pukul 09:00**

The ARIMA Procedure

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.39304	0.03065	12.82	<.0001	1	y	0
AR1,2	0.18194	0.03257	5.59	<.0001	2	y	0
AR1,3	0.10872	0.03131	3.47	0.0005	3	y	0
AR1,4	0.06134	0.03083	1.99	0.0469	7	y	0
AR1,5	0.08387	0.0307	2.73	0.0064	8	y	0
AR1,6	0.0787	0.02632	2.99	0.0029	13	y	0
NUM1	0.12387	0.0186	6.66	<.0001	0	t	0

NUM2	533.76217	11.34274	47.06	<.0001	0	H1	0
NUM3	531.57332	11.34229	46.87	<.0001	0	H2	0
NUM4	527.3423	11.32012	46.58	<.0001	0	H3	0
NUM5	532.89779	11.34071	46.99	<.0001	0	H4	0
NUM6	534.72129	11.35428	47.09	<.0001	0	H5	0
NUM7	508.91668	11.35534	44.82	<.0001	0	H6	0
NUM8	485.86956	11.34527	42.83	<.0001	0	H7	0
NUM9	-52.63309	12.03571	-4.37	<.0001	0	I1	0
NUM10	-29.0309	10.33315	-2.81	0.0051	0	I2	0
NUM11	-25.50817	11.94636	-2.14	0.033	0	I3	0
NUM12	-41.45221	14.89464	-2.78	0.0055	0	I4	0
NUM13	-154.77641	12.38194	-12.5	<.0001	0	I5	0
NUM14	-68.89815	14.91539	-4.62	<.0001	0	I6	0
NUM15	-31.2701	11.95607	-2.62	0.009	0	I7	0
NUM16	-28.29796	14.57618	-1.94	0.0525	0	I8	0
NUM17	-4.26293	14.53621	-0.29	0.7694	0	I9	0
NUM18	-17.38414	12.01442	-1.45	0.1482	0	I10	0
NUM19	-24.64794	12.15092	-2.03	0.0428	0	I11	0
NUM20	-34.70078	12.30736	-2.82	0.0049	0	I12	0
NUM21	-24.11063	12.2586	-1.97	0.0495	0	I13	0
NUM22	-36.97197	14.52456	-2.55	0.0111	0	I14	0
NUM23	-44.76737	14.53137	-3.08	0.0021	0	I15	0
NUM24	-8.45481	14.53643	-0.58	0.5609	0	I16	0
NUM25	-43.73978	14.66833	-2.98	0.0029	0	I17	0
NUM26	-8.17436	11.90804	-0.69	0.4926	0	I18	0
NUM27	-6.0044	9.33941	-0.64	0.5204	0	I19	0
NUM28	-20.99603	9.314	-2.25	0.0244	0	I20	0
NUM29	-42.27951	9.81848	-4.31	<.0001	0	I21	0
NUM30	-81.15545	10.06552	-8.06	<.0001	0	I22	0
NUM31	-53.0422	9.8795	-5.37	<.0001	0	I23	0
NUM32	-24.7934	9.69605	-2.56	0.0107	0	I24	0
NUM33	-53.2301	9.62251	-5.53	<.0001	0	I25	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr >ChiSq	-----Autocorrelations-----					
6	.	0	.	-0.01	-0.019	-0.037	0.011	0.033	0.035
12	12.2	6	0.0576	-0.017	-0.045	0.047	0.01	0.041	0.024
18	13.51	12	0.333	0.001	-0.019	-0.025	0	0.008	0.01
24	23.58	18	0.1692	-0.06	-0.004	0.053	0.045	-0.02	-0.013
30	26.96	24	0.3061	-0.012	0.01	-0.035	-0.035	0.008	0.014
36	31.91	30	0.3716	0.036	0.026	0.041	0.024	0.004	0.009
42	33.5	36	0.5883	0.018	0.02	-0.011	0.021	0.009	-0.002

48 39.09 42 0.5996 0.019 0.024 -0.01 0.045 0.042 0.007

Tests for Normality				
Test	Statistic		P-value	
Shapiro-Wilk	W	0.651037	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.102993	Pr > D	<0.0100
Cramer-von Mises	W-Sq	5.131006	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	33.00548	Pr > A-Sq	<0.0050

### Pukul 10:00

#### The ARIMA Procedure

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.60731	0.03064	19.82	<.0001	1	y	0
AR1,2	0.16083	0.03118	5.16	<.0001	2	y	0
AR1,3	0.10862	0.02471	4.4	<.0001	7	y	0
AR1,4	6.40E-02	0.02401	2.67	0.0078	10	y	0
NUM1	0.13396	0.01972	6.79	<.0001	0	t	0
NUM2	565.36166	11.44567	49.4	<.0001	0	H1	0
NUM3	559.59256	11.43671	48.93	<.0001	0	H2	0
NUM4	559.57397	11.41393	49.03	<.0001	0	H3	0
NUM5	562.82811	11.43898	49.2	<.0001	0	H4	0
NUM6	565.61153	11.45441	49.38	<.0001	0	H5	0
NUM7	542.08775	11.45225	47.33	<.0001	0	H6	0
NUM8	510.68022	11.44908	44.6	<.0001	0	H7	0
NUM9	-55.85268	8.38414	-6.66	<.0001	0	I1	0
NUM10	-37.37206	7.11331	-5.25	<.0001	0	I2	0
NUM11	-41.85308	8.27094	-5.06	<.0001	0	I3	0
NUM12	-41.81524	10.57647	-3.95	<.0001	0	I4	0
NUM13	-172.98993	9.0208	-19.18	<.0001	0	I5	0
NUM14	-76.2421	10.59552	-7.2	<.0001	0	I6	0
NUM15	-34.75411	8.20133	-4.24	<.0001	0	I7	0
NUM16	-37.86731	10.03982	-3.77	0.0002	0	I8	0
NUM17	-45.07953	9.98449	-4.51	<.0001	0	I9	0
NUM18	-28.90025	8.32049	-3.47	0.0005	0	I10	0
NUM19	-24.64711	8.43343	-2.92	0.0035	0	I11	0
NUM20	-44.49206	8.83433	-5.04	<.0001	0	I12	0
NUM21	-29.86054	8.76846	-3.41	0.0007	0	I13	0
NUM22	-41.47857	9.97806	-4.16	<.0001	0	I14	0
NUM23	-37.34373	9.9838	-3.74	0.0002	0	I15	0
NUM24	-23.541	9.97968	-2.36	0.0185	0	I16	0
NUM25	-56.05877	10.18954	-5.5	<.0001	0	I17	0
NUM26	-12.65895	8.20808	-1.54	0.1233	0	I18	0
NUM27	-9.14202	6.42797	-1.42	0.1553	0	I19	0
NUM28	-26.79803	6.39154	-4.19	<.0001	0	I20	0

NUM29	-38.05087	7.21693	-5.27	<.0001	0	I21	0
NUM30	-99.17392	7.68997	-12.9	<.0001	0	I22	0
NUM31	-63.93234	7.23644	-8.83	<.0001	0	I23	0
NUM32	-25.14775	6.98281	-3.6	0.0003	0	I24	0
NUM33	-62.28172	6.90281	-9.02	<.0001	0	I25	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr >ChiSq	-----Autocorrelations-----					
6	3.79	2	0.1505	0.002	0.003	-0.042	0.018	0.036	0.002
12	8.49	8	0.3872	-0.002	0.001	0.02	0.014	0.003	-0.06
18	21.89	14	0.081	0.055	0.029	-0.073	-0.001	-0.03	0.044
24	29.06	20	0.0866	-0.055	-0.013	0.017	0.037	-0.016	-0.036
30	30.55	26	0.2456	-0.008	0.026	-0.013	-0.012	-0.016	-0.005
36	42.14	32	0.1083	0.014	0.054	0.071	0.014	0.034	-0.026
42	45.18	38	0.1971	0.017	-0.017	0.033	0.005	-0.029	0.009
48	56.61	44	0.0962	0.022	0.004	0.042	-0.007	0.037	0.079

## Tests for Normality

Test	Statistic	P-value
Shapiro-Wilk	W 0.959001	Pr < W <.0001
Kolmogorov-Smirnov	D 0.072324	Pr > D <.0100
Cramer-von Mises	W-Sq 1.557366	Pr > W-Sq <.0050
Anderson-Darling	A-Sq 9.111748	Pr > A-Sq <.0050

**Pukul 11:00**

## The ARIMA Procedure

## Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.63066	0.03058	20.63	<.0001	1	y	0
AR1,2	0.13222	0.03188	4.15	<.0001	2	y	0
AR1,3	0.05559	0.02818	1.97	0.0488	5	y	0
AR1,4	7.66E-02	0.02807	2.73	0.0065	7	y	0
AR1,5	0.14244	0.03238	4.4	<.0001	10	y	0
AR1,6	-0.08057	0.0311	-2.59	0.0097	11	y	0
AR1,7	-0.03611	0.01526	-2.37	0.0182	52	y	0
NUM1	0.13865	0.01715	8.08	<.0001	0	t	0
NUM2	575.86453	10.28024	56.02	<.0001	0	H1	0
NUM3	570.73768	10.27361	55.55	<.0001	0	H2	0
NUM4	570.69594	10.25326	55.66	<.0001	0	H3	0
NUM5	572.46999	10.27546	55.71	<.0001	0	H4	0
NUM6	576.2769	10.28896	56.01	<.0001	0	H5	0
NUM7	554.86321	10.29051	53.92	<.0001	0	H6	0

NUM8	520.60256	10.28315	50.63	<.0001	0	H7	0
NUM9	-60.64006	8.24169	-7.36	<.0001	0	I1	0
NUM10	-47.07293	7.02087	-6.7	<.0001	0	I2	0
NUM11	-36.98803	8.20556	-4.51	<.0001	0	I3	0
NUM12	-48.30803	10.51742	-4.59	<.0001	0	I4	0
NUM13	-178.86991	9.04197	-19.78	<.0001	0	I5	0
NUM14	-83.42116	10.54014	-7.91	<.0001	0	I6	0
NUM15	-36.59427	8.10633	-4.51	<.0001	0	I7	0
NUM16	-36.17165	9.93027	-3.64	0.0003	0	I8	0
NUM17	-33.35367	9.86164	-3.38	0.0007	0	I9	0
NUM18	-35.19794	8.19948	-4.29	<.0001	0	I10	0
NUM19	-21.79131	8.31035	-2.62	0.0089	0	I11	0
NUM20	-44.50883	8.84439	-5.03	<.0001	0	I12	0
NUM21	-28.7202	8.75552	-3.28	0.0011	0	I13	0
NUM22	-48.05609	9.86402	-4.87	<.0001	0	I14	0
NUM23	-36.12455	9.86589	-3.66	0.0003	0	I15	0
NUM24	-24.73753	9.85884	-2.51	0.0123	0	I16	0
NUM25	-57.63449	10.10965	-5.7	<.0001	0	I17	0
NUM26	-4.97626	8.11865	-0.61	0.54	0	I18	0
NUM27	-5.71821	6.36108	-0.9	0.3689	0	I19	0
NUM28	-29.00131	6.31992	-4.59	<.0001	0	I20	0
NUM29	-37.46718	7.2817	-5.15	<.0001	0	I21	0
NUM30	-93.75046	7.82723	-11.98	<.0001	0	I22	0
NUM31	-62.06702	7.21133	-8.61	<.0001	0	I23	0
NUM32	-22.69718	7.03629	-3.23	0.0013	0	I24	0
NUM33	-54.82017	6.94136	-7.9	<.0001	0	I25	0

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr >ChiSq	-----Autocorrelations-----					
6	.	0	0.005	0.028	-0.019	-0.041	-0.004	0.008	
12	9.2	5	0.1014	0.013	-0.049	0.025	-0.007	-0.017	-0.043
18	16.3	11	0.1304	0.025	0.015	-0.052	0.013	-0.038	0.035
24	22.45	17	0.168	-0.056	0.004	-0.019	0.021	-0.013	-0.037
30	25.3	23	0.335	0.027	-0.022	-0.006	-0.022	-0.027	-0.004
36	38.37	29	0.1143	0.089	0.031	0.029	0.039	-0.013	-0.009
42	42.25	35	0.1864	-0.004	-0.007	0.019	-0.006	-0.032	-0.044
48	47.79	41	0.2162	-0.005	0.012	0.052	0.02	0.028	0.027

Tests for Normality

Test	Statistic	P-value
Shapiro-Wilk	W 0.967783	Pr < W <.0001
Kolmogorov-Smirnov	D 0.063651	Pr > D <0.0100
Cramer-von Mises	W-Sq 1.287907	Pr > W-Sq <0.0050
Anderson-Darling	A-Sq 7.617374	Pr > A-Sq <0.0050

**Pukul 12:00**

## The ARIMA Procedure

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.6081	0.03042	19.99	<.0001	1	y	0
AR1,2	0.15923	0.03073	5.18	<.0001	2	y	0
AR1,3	0.10026	0.02446	4.1	<.0001	7	y	0
AR1,4	7.69E-02	0.02378	3.23	0.0013	10	y	0
NUM1	0.14919	0.02301	6.48	<.0001	0	t	0
NUM2	560.66717	13.21569	42.42	<.0001	0	H1	0
NUM3	554.46671	13.20582	41.99	<.0001	0	H2	0
NUM4	556.64926	13.17937	42.24	<.0001	0	H3	0
NUM5	558.40946	13.20753	42.28	<.0001	0	H4	0
NUM6	561.88752	13.22477	42.49	<.0001	0	H5	0
NUM7	541.90791	13.22169	40.99	<.0001	0	H6	0
NUM8	509.95154	13.219	38.58	<.0001	0	H7	0
NUM9	-46.50772	9.40893	-4.94	<.0001	0	I1	0
NUM10	-48.89622	7.97077	-6.13	<.0001	0	I2	0
NUM11	-32.03065	9.26126	-3.46	0.0006	0	I3	0
NUM12	-52.0058	11.85371	-4.39	<.0001	0	I4	0
NUM13	-170.59401	10.12489	-16.85	<.0001	0	I5	0
NUM14	-73.51992	11.86708	-6.2	<.0001	0	I6	0
NUM15	-33.89619	9.18541	-3.69	0.0002	0	I7	0
NUM16	-36.51897	11.27222	-3.24	0.0012	0	I8	0
NUM17	-38.09947	11.191	-3.4	0.0007	0	I9	0
NUM18	-32.65326	9.31597	-3.51	0.0005	0	I10	0
NUM19	-19.64885	9.43158	-2.08	0.0375	0	I11	0
NUM20	-36.42292	9.89782	-3.68	0.0002	0	I12	0
NUM21	-31.57945	9.82448	-3.21	0.0013	0	I13	0
NUM22	-45.46007	11.18353	-4.06	<.0001	0	I14	0
NUM23	-37.19263	11.18771	-3.32	0.0009	0	I15	0
NUM24	-14.99019	11.18329	-1.34	0.1804	0	I16	0
NUM25	-63.97408	11.41826	-5.6	<.0001	0	I17	0
NUM26	0.53667	9.27029	0.06	0.9538	0	I18	0
NUM27	-6.87913	7.2057	-0.95	0.34	0	I19	0
NUM28	-29.34433	7.15875	-4.1	<.0001	0	I20	0
NUM29	-30.46981	8.08662	-3.77	0.0002	0	I21	0
NUM30	-82.11184	8.60884	-9.54	<.0001	0	I22	0
NUM31	-59.21455	8.10614	-7.3	<.0001	0	I23	0
NUM32	-16.24033	7.82676	-2.07	0.0382	0	I24	0
NUM33	-44.89602	7.74465	-5.8	<.0001	0	I25	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----						
6	4.45	2	0.1078	0.005	0.013	0.021	-0.04	-0.013	0.04	

12	8.83	8	0.3572	0.01	-0.005	-0.007	0.034	-0.01	-0.05
18	11.99	14	0.6075	-0.023	0.023	-0.016	0.001	-0.003	0.039
24	17.91	20	0.5935	-0.045	0.022	-0.043	0.028	0.008	-0.007
30	21.02	26	0.741	-0.004	0.01	0.002	-0.022	-0.046	0.006
36	31.59	32	0.4871	0.038	0.052	0.064	0.019	-0.024	-0.01
42	36.19	38	0.5534	-0.015	0.039	-0.022	0.011	0.015	-0.038
48	39.49	44	0.665	0.036	0.016	-0.001	0.027	0.024	0.007

Tests for Normality				
Test	Statistic		P-value	
Shapiro-Wilk	W	0.903577	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.082555	Pr > D	<0.0100
Cramer-von Mises	W-Sq	2.390474	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	14.14763	Pr > A-Sq	<0.0050

## Pukul 13:00

### The ARIMA Procedure

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.70618	0.03082	22.91	<.0001	1	y	0
AR1,2	0.09384	0.03426	2.74	0.0063	2	y	0
AR1,3	-0.07505	0.03432	-2.19	0.029	4	y	0
AR1,4	1.17E-01	0.03158	3.7	0.0002	5	y	0
AR1,5	0.10315	0.02127	4.85	<.0001	9	y	0
NUM1	0.1502	0.02258	6.65	<.0001	0	t	0
NUM2	563.85857	13.03653	43.25	<.0001	0	H1	0
NUM3	560.7545	13.02684	43.05	<.0001	0	H2	0
NUM4	561.19123	12.9994	43.17	<.0001	0	H3	0
NUM5	563.5936	13.02559	43.27	<.0001	0	H4	0
NUM6	559.17681	13.04748	42.86	<.0001	0	H5	0
NUM7	539.83995	13.04905	41.37	<.0001	0	H6	0
NUM8	509.28994	13.04162	39.05	<.0001	0	H7	0
NUM9	-63.06216	8.61049	-7.32	<.0001	0	I1	0
NUM10	-44.6878	7.33549	-6.09	<.0001	0	I2	0
NUM11	-46.12196	8.54288	-5.4	<.0001	0	I3	0
NUM12	-66.14685	11.06011	-5.98	<.0001	0	I4	0
NUM13	-166.55608	9.61499	-17.32	<.0001	0	I5	0
NUM14	-74.46074	11.06667	-6.73	<.0001	0	I6	0
NUM15	-32.15077	8.4154	-3.82	0.0001	0	I7	0
NUM16	-32.44671	10.33597	-3.14	0.0017	0	I8	0
NUM17	-36.41409	10.2294	-3.56	0.0004	0	I9	0
NUM18	-33.61034	8.49749	-3.96	<.0001	0	I10	0
NUM19	-38.32445	8.64196	-4.43	<.0001	0	I11	0
NUM20	-46.80023	9.31881	-5.02	<.0001	0	I12	0
NUM21	-35.11384	9.23375	-3.8	0.0002	0	I13	0
NUM22	-50.38652	10.22761	-4.93	<.0001	0	I14	0



NUM23	-43.60066	10.24489	-4.26	<0001	0	I15	0
NUM24	-28.87444	10.23367	-2.82	0.0049	0	I16	0
NUM25	-58.52618	10.535	-5.56	<0001	0	I17	0
NUM26	-9.73007	8.44757	-1.15	0.2497	0	I18	0
NUM27	-6.61519	6.65905	-0.99	0.3207	0	I19	0
NUM28	-33.72919	6.60503	-5.11	<0001	0	I20	0
NUM29	-33.93871	7.69173	-4.41	<0001	0	I21	0
NUM30	-78.27744	8.47418	-9.24	<0001	0	I22	0
NUM31	-61.69193	7.72864	-7.98	<0001	0	I23	0
NUM32	-14.58751	7.43533	-1.96	0.05	0	I24	0
NUM33	-38.01551	7.31586	-5.2	<0001	0	I25	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr >ChiSq	-----Autocorrelations-----						
6	2.16	1	0.1415	-0.005	-0.001	-0.001	-0.007	-0.042	0.012	
12	6.12	7	0.5262	0.036	0.02	-0.005	0.01	-0.008	-0.041	
18	20.09	13	0.0931	0.023	0.075	-0.075	0.003	-0.005	0.026	
24	25.05	19	0.1589	-0.045	0.021	0.041	-0.016	0.001	-0.01	
30	29.39	25	0.2479	-0.008	-0.016	0.029	-0.031	-0.041	0.005	
36	44.34	31	0.057	0.059	0.05	0.01	0.065	0.009	-0.052	
42	51.96	37	0.0522	0.001	-0.002	0.054	-0.016	-0.013	-0.057	
48	58.66	43	0.0561	0.007	0.061	0.006	-0.006	0.036	0.027	

## Tests for Normality

Test	Statistic	P-value
Shapiro-Wilk	W 0.961527	Pr < W <0.0001
Kolmogorov-Smirnov	D 0.069791	Pr > D <0.0100
Cramer-von Mises	W-Sq 1.639348	Pr > W-Sq <0.0050
Anderson-Darling	A-Sq 9.424937	Pr > A-Sq <0.0050

**Pukul 14:00**

## The ARIMA Procedure

## Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.60688	0.03051	19.89	<.0001	1	y	0
AR1,2	0.17157	0.03336	5.14	<.0001	2	y	0
AR1,3	-0.06789	0.03366	-2.02	0.0439	4	y	0
AR1,4	7.18E-02	0.03389	2.12	0.0344	5	y	0
AR1,5	0.06648	0.03076	2.16	0.0309	7	y	0
AR1,6	0.08912	0.02666	3.34	0.0009	9	y	0
NUM1	0.15149	0.02331	6.5	<.0001	0	t	0
NUM2	579.52259	13.67665	42.37	<.0001	0	H1	0
NUM3	577.30945	13.6667	42.24	<.0001	0	H2	0
NUM4	576.00801	13.63892	42.23	<.0001	0	H3	0

NUM5	580.93809	13.66544	42.51	<.0001	0	H4	0
NUM6	576.65526	13.68891	42.13	<.0001	0	H5	0
NUM7	546.77369	13.69027	39.94	<.0001	0	H6	0
NUM8	514.23327	13.68244	37.58	<.0001	0	H7	0
NUM9	-80.61666	10.11723	-7.97	<.0001	0	I1	0
NUM10	-47.0002	8.65134	-5.43	<.0001	0	I2	0
NUM11	-54.78194	10.12954	-5.41	<.0001	0	I3	0
NUM12	-79.21897	12.81869	-6.18	<.0001	0	I4	0
NUM13	-173.45205	10.914	-15.89	<.0001	0	I5	0
NUM14	-82.66042	12.84479	-6.44	<.0001	0	I6	0
NUM15	-40.3672	9.93968	-4.06	<.0001	0	I7	0
NUM16	-46.46002	12.18528	-3.81	0.0001	0	I8	0
NUM17	-40.41832	12.08789	-3.34	0.0009	0	I9	0
NUM18	-37.86103	10.0764	-3.76	0.0002	0	I10	0
NUM19	-37.51082	10.209	-3.67	0.0003	0	I11	0
NUM20	-51.45735	10.7028	-4.81	<.0001	0	I12	0
NUM21	-42.8761	10.60319	-4.04	<.0001	0	I13	0
NUM22	-61.10205	12.0754	-5.06	<.0001	0	I14	0
NUM23	-50.2041	12.09951	-4.15	<.0001	0	I15	0
NUM24	-29.04024	12.09245	-2.4	0.0165	0	I16	0
NUM25	-66.8685	12.39465	-5.39	<.0001	0	I17	0
NUM26	-9.63121	9.94912	-0.97	0.3332	0	I18	0
NUM27	-8.66506	7.82279	-1.11	0.2683	0	I19	0
NUM28	-34.47818	7.77805	-4.43	<.0001	0	I20	0
NUM29	-40.54201	8.76092	-4.63	<.0001	0	I21	0
NUM30	-85.98228	9.32099	-9.22	<.0001	0	I22	0
NUM31	-70.7078	8.79866	-8.04	<.0001	0	I23	0
NUM32	-18.08104	8.46501	-2.14	0.0329	0	I24	0
NUM33	-38.46833	8.37833	-4.59	<.0001	0	I25	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	.	0	.	-0.005	-0.021	0.031	0.004	0.004	-0.01
12	3.98	6	0.6796	-0.013	0.024	0.003	-0.02	-0.006	0.029
18	9	12	0.7026	-0.038	0.039	-0.034	0.009	-0.01	0.015
24	11.61	18	0.8668	-0.021	0.021	-0.009	0.018	0.022	-0.02
30	17.94	24	0.8059	-0.031	-0.001	0.032	-0.019	-0.046	0.034
36	24.52	30	0.7478	0.016	0.042	0.001	0.053	0.012	-0.03
42	34.67	36	0.5319	-0.003	-0.042	0.073	-0.005	0.001	-0.04
48	42.48	42	0.4503	-0.033	0.047	0.052	0.002	0.028	0.007

## Tests for Normality

Test	Statistic	P-value
Shapiro-Wilk	W	0.919376
Kolmogorov-Smirnov	D	0.073759
Cramer-von Mises	W-Sq	2.216373
Anderson-Darling	A-Sq	13.08284

Pr < W <.0001  
Pr > D <.0100  
Pr > W-Sq <.0050  
Pr > A-Sq <.0050

**Pukul 15:00**

## The ARIMA Procedure

## Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.62355	0.03061	20.37	<.0001	1	y	0
AR1,2	0.16189	0.0338	4.79	<.0001	2	y	0
AR1,3	-0.06844	0.03373	-2.03	0.0427	4	y	0
AR1,4	1.13E-01	0.03129	3.61	0.0003	5	y	0
AR1,5	0.10158	0.02212	4.59	<.0001	10	y	0
NUM1	0.151	0.02221	6.8	<.0001	0	t	0
NUM2	577.01724	13.28792	43.42	<.0001	0	H1	0
NUM3	574.59326	13.28371	43.26	<.0001	0	H2	0
NUM4	572.74374	13.25662	43.2	<.0001	0	H3	0
NUM5	577.3166	13.28085	43.47	<.0001	0	H4	0
NUM6	573.67417	13.29623	43.15	<.0001	0	H5	0
NUM7	540.92227	13.29754	40.68	<.0001	0	H6	0
NUM8	513.35831	13.28866	38.63	<.0001	0	H7	0
NUM9	-77.1122	10.12261	-7.62	<.0001	0	I1	0
NUM10	-50.19531	8.60994	-5.83	<.0001	0	I2	0
NUM11	-43.09596	10.06554	-4.28	<.0001	0	I3	0
NUM12	-99.66115	12.86985	-7.74	<.0001	0	I4	0
NUM13	-164.42511	10.99623	-14.95	<.0001	0	I5	0
NUM14	-67.92147	12.8834	-5.27	<.0001	0	I6	0
NUM15	-36.86846	9.94907	-3.71	0.0002	0	I7	0
NUM16	-39.98795	12.18322	-3.28	0.0011	0	I8	0
NUM17	-41.00249	12.09936	-3.39	0.0007	0	I9	0
NUM18	-32.53826	10.0852	-3.23	0.0013	0	I10	0
NUM19	-34.67667	10.23351	-3.39	0.0007	0	I11	0
NUM20	-41.52047	10.73751	-3.87	0.0001	0	I12	0
NUM21	-32.14221	10.65194	-3.02	0.0026	0	I13	0
NUM22	-56.1391	12.09958	-4.64	<.0001	0	I14	0
NUM23	-53.16149	12.10934	-4.39	<.0001	0	I15	0
NUM24	-20.86802	12.11085	-1.72	0.0852	0	I16	0
NUM25	-66.24098	12.32992	-5.37	<.0001	0	I17	0
NUM26	-2.90793	9.95871	-0.29	0.7703	0	I18	0
NUM27	-7.90348	7.85083	-1.01	0.3143	0	I19	0
NUM28	-30.39417	7.80334	-3.9	0.0001	0	I20	0
NUM29	-33.14539	8.84983	-3.75	0.0002	0	I21	0
NUM30	-77.7528	9.4415	-8.24	<.0001	0	I22	0
NUM31	-58.21451	8.85968	-6.57	<.0001	0	I23	0
NUM32	-21.837	8.52746	-2.56	0.0106	0	I24	0
NUM33	-34.04476	8.43759	-4.03	<.0001	0	I25	0

## Autocorrelation Check of Residuals

To	Chi-	Pr	
Lag	Square	>ChiSq	-----Autocorrelations-----

6	3.66	1	0.0558	-0.007	-0.023	0.018	-0.011	-0.042	-0.02
12	11.75	7	0.109	0.037	0.05	0.04	0.012	-0.041	-0.01
18	18.41	13	0.1426	-0.001	0.05	-0.033	0.021	-0.029	0.033
24	22.62	19	0.2543	-0.037	0.04	0.001	0.002	0.014	-0.03
30	24.57	25	0.4867	-0.019	0.003	-0.02	-0.013	0.023	-0.02
36	31.96	31	0.4185	0.007	0.048	0.023	0.057	-0.019	-0.01
42	35.83	37	0.524	-0.005	0.001	0.034	-0.031	0.029	-0.02
48	41.67	43	0.529	-0.024	0.017	0.063	0.009	0.003	0.013

Tests for Normality			
Test	Statistic	P-value	
Shapiro-Wilk	W	0.937354	Pr < W < 0.0001
Kolmogorov-Smirnov	D	0.062568	Pr > D < 0.0100
Cramer-von Mises	W-Sq	1.392043	Pr > W-Sq < 0.0050
Anderson-Darling	A-Sq	8.532881	Pr > A-Sq < 0.0050

## Pukul 16:00

### The ARIMA Procedure

#### Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.56947	0.03027	18.81	<.0001	1	y	0
AR1,2	0.18253	0.03115	5.86	<.0001	2	y	0
AR1,3	0.10213	0.0241	4.24	<.0001	6	y	0
AR1,4	7.95E-02	0.0231	3.44	0.0006	10	y	0
NUM1	0.14474	0.02171	6.67	<.0001	0	t	0
NUM2	566.79495	12.86343	44.06	<.0001	0	H1	0
NUM3	563.99614	12.86091	43.85	<.0001	0	H2	0
NUM4	562.43327	12.83543	43.82	<.0001	0	H3	0
NUM5	567.92156	12.85691	44.17	<.0001	0	H4	0
NUM6	565.66203	12.87505	43.93	<.0001	0	H5	0
NUM7	533.54753	12.87269	41.45	<.0001	0	H6	0
NUM8	511.33548	12.86772	39.74	<.0001	0	H7	0
NUM9	-75.14883	10.03518	-7.49	<.0001	0	I1	0
NUM10	-45.77785	8.53227	-5.37	<.0001	0	I2	0
NUM11	-40.52501	9.91628	-4.09	<.0001	0	I3	0
NUM12	-99.33799	12.63191	-7.86	<.0001	0	I4	0
NUM13	-146.99984	10.71503	-13.72	<.0001	0	I5	0
NUM14	-66.14197	12.66657	-5.22	<.0001	0	I6	0
NUM15	-30.59105	9.86858	-3.1	0.002	0	I7	0
NUM16	-36.25441	12.06123	-3.01	0.0027	0	I8	0
NUM17	-31.2438	12.00151	-2.6	0.0094	0	I9	0
NUM18	-31.70503	10.00695	-3.17	0.0016	0	I10	0
NUM19	-29.45035	10.12756	-2.91	0.0037	0	I11	0
NUM20	-43.44629	10.49858	-4.14	<.0001	0	I12	0
NUM21	-34.70027	10.43687	-3.32	0.0009	0	I13	0
NUM22	-46.17605	12.00357	-3.85	0.0001	0	I14	0

NUM23	-47.80318	12.00357	-3.98	<.0001	0	I15	0
NUM24	-15.38313	11.99862	-1.28	0.2001	0	I16	0
NUM25	-61.9228	12.18757	-5.08	<.0001	0	I17	0
NUM26	-13.74473	9.86208	-1.39	0.1637	0	I18	0
NUM27	-12.21881	7.7412	-1.58	0.1148	0	I19	0
NUM28	-20.94967	7.70044	-2.72	0.0066	0	I20	0
NUM29	-27.11497	8.58693	-3.16	0.0016	0	I21	0
NUM30	-70.78105	9.0432	-7.83	<.0001	0	I22	0
NUM31	-56.37969	8.61229	-6.55	<.0001	0	I23	0
NUM32	-19.87692	8.31592	-2.39	0.017	0	I24	0
NUM33	-25.33009	8.23657	-3.08	0.0022	0	I25	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr >ChiSq	-----Autocorrelations-----						
6	4.25	2	0.1194	-0.001	0.006	0.022	-0.047	-0.013	-0.031	
12	7.21	8	0.514	0.006	0.032	0.026	0.007	-0.029	-0.005	
18	9.95	14	0.7655	0.008	0.031	-0.014	0.025	-0.022	0.012	
24	13.69	20	0.8458	-0.03	0.034	0.019	-0.005	-0.024	-0.016	
30	18.87	26	0.8421	0.015	-0.053	0.009	-0.028	-0.024	-0.009	
36	30.85	32	0.5248	0.003	0.074	0.022	0.048	-0.032	0.036	
42	40.48	38	0.3615	0.012	-0.014	0.052	-0.059	0.03	-0.032	
48	47.14	44	0.3455	-0.019	0.056	0.041	0.017	0.004	0.017	

## Tests for Normality

Test	Statistic	P-value
Shapiro-Wilk	W 0.933647	Pr < W <.0001
Kolmogorov-Smirnov	D 0.068821	Pr > D <.0100
Cramer-von Mises	W-Sq 1.810797	Pr > W-Sq <.0050
Anderson-Darling	A-Sq 10.94966	Pr > A-Sq <.0050

**Pukul 17:00**

## The ARIMA Procedure

## Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.60563	0.03037	19.94	<.0001	1	y	0
AR1,2	0.16189	0.03052	5.3	<.0001	2	y	0
AR1,3	0.153	0.02154	7.1	<.0001	7	y	0
NUM1	1.35E-01	0.01759	7.67	<.0001	0	t	0
NUM2	555.34972	10.69554	51.92	<.0001	0	H1	0
NUM3	554.00462	10.68376	51.85	<.0001	0	H2	0
NUM4	551.41727	10.66258	51.72	<.0001	0	H3	0
NUM5	556.38936	10.68936	52.05	<.0001	0	H4	0
NUM6	554.96729	10.70827	51.83	<.0001	0	H5	0

NUM7	529.78437	10.70778	49.48	<.0001	0	H6	0
NUM8	513.05362	10.70191	47.94	<.0001	0	H7	0
NUM9	-53.58047	8.93268	-6	<.0001	0	I1	0
NUM10	-34.31924	7.6224	-4.5	<.0001	0	I2	0
NUM11	-31.09334	8.842	-3.52	0.0005	0	I3	0
NUM12	-93.89749	11.30613	-8.31	<.0001	0	I4	0
NUM13	-127.36158	9.64418	-13.21	<.0001	0	I5	0
NUM14	-46.82298	11.31039	-4.14	<.0001	0	I6	0
NUM15	-19.41777	8.76932	-2.21	0.027	0	I7	0
NUM16	-29.01409	10.74746	-2.7	0.0071	0	I8	0
NUM17	-22.70454	10.68753	-2.12	0.0339	0	I9	0
NUM18	-19.04335	8.90782	-2.14	0.0328	0	I10	0
NUM19	-20.88744	9.01525	-2.32	0.0207	0	I11	0
NUM20	-34.30685	9.43975	-3.63	0.0003	0	I12	0
NUM21	-22.66962	9.37041	-2.42	0.0157	0	I13	0
NUM22	-32.42909	10.67659	-3.04	0.0024	0	I14	0
NUM23	-36.45678	10.68739	-3.41	0.0007	0	I15	0
NUM24	-17.7872	10.68121	-1.67	0.0962	0	I16	0
NUM25	-43.96329	10.93889	-4.02	<.0001	0	I17	0
NUM26	-1.39091	8.78186	-0.16	0.8742	0	I18	0
NUM27	-5.36069	6.87055	-0.78	0.4354	0	I19	0
NUM28	-14.62842	6.83411	-2.14	0.0325	0	I20	0
NUM29	-27.19361	7.68217	-3.54	0.0004	0	I21	0
NUM30	-57.90504	8.15967	-7.1	<.0001	0	I22	0
NUM31	-45.80344	7.71687	-5.94	<.0001	0	I23	0
NUM32	-17.35209	7.44118	-2.33	0.0199	0	I24	0
NUM33	-25.02945	7.3729	-3.39	0.0007	0	I25	0

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr >ChiSq	-----Autocorrelations-----						
6	5.84	3	0.1197	-0.015	-0.034	0.041	-0.042	-0.014	0.017	
12	9.22	9	0.4174	-0.051	0.005	-0.005	0.005	-0.013	0.014	
18	15.73	15	0.4001	0.022	0.07	0.007	-0.016	0.015	0	
24	19.88	21	0.5287	-0.018	0.034	0.025	-0.008	-0.01	-0.038	
30	24.53	27	0.6007	0.005	-0.004	-0.013	-0.033	0.038	-0.037	
36	35.22	33	0.3636	0.014	0.077	0.009	0.057	0.007	0	
42	38.37	39	0.4985	0.014	0	0.034	-0.029	-0.024	0.004	
48	43.61	45	0.5311	-0.004	0.03	0.039	0.009	0.024	0.039	

Tests for Normality

Test	Statistic	P-value
Shapiro-Wilk	W 0.952945	Pr < W <0.0001
Kolmogorov-Smirnov	D 0.065291	Pr > D <0.0100
Cramer-von Mises	W-Sq 1.301783	Pr > W-Sq <0.0050
Anderson-Darling	A-Sq 8.140493	Pr > A-Sq <0.0050

**Pukul 18:00**

## The ARIMA Procedure

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.54558	0.03035	17.98	<.0001	1	y	0
AR1,2	0.18367	0.03138	5.85	<.0001	2	y	0
AR1,3	0.08931	0.02867	3.12	0.0019	5	y	0
AR1,4	1.05E-01	0.02715	3.85	0.0001	7	y	0
NUM1	0.13633	0.01739	7.84	<.0001	0	t	0
NUM2	563.97139	10.50186	53.7	<.0001	0	H1	0
NUM3	562.23936	10.49464	53.57	<.0001	0	H2	0
NUM4	561.48774	10.47405	53.61	<.0001	0	H3	0
NUM5	566.61904	10.49686	53.98	<.0001	0	H4	0
NUM6	565.35449	10.51242	53.78	<.0001	0	H5	0
NUM7	548.78651	10.5114	52.21	<.0001	0	H6	0
NUM8	536.86648	10.50452	51.11	<.0001	0	H7	0
NUM9	-43.16116	8.89309	-4.85	<.0001	0	I1	0
NUM10	-21.13247	7.59779	-2.78	0.0055	0	I2	0
NUM11	-15.46357	8.85372	-1.75	0.081	0	I3	0
NUM12	-88.75836	11.19293	-7.93	<.0001	0	I4	0
NUM13	-134.82342	9.49681	-14.2	<.0001	0	I5	0
NUM14	-31.20512	11.21689	-2.78	0.0055	0	I6	0
NUM15	-17.88477	8.7606	-2.04	0.0414	0	I7	0
NUM16	-19.76547	10.70666	-1.85	0.0652	0	I8	0
NUM17	-15.59715	10.67936	-1.46	0.1445	0	I9	0
NUM18	-19.31285	8.88794	-2.17	0.03	0	I10	0
NUM19	-7.41285	8.99087	-0.82	0.4098	0	I11	0
NUM20	-30.05647	9.29682	-3.23	0.0013	0	I12	0
NUM21	-24.03632	9.24107	-2.6	0.0094	0	I13	0
NUM22	-18.07002	10.65912	-1.7	0.0903	0	I14	0
NUM23	-26.60449	10.67006	-2.49	0.0128	0	I15	0
NUM24	-0.32855	10.6632	-0.03	0.9754	0	I16	0
NUM25	-34.82837	10.88384	-3.2	0.0014	0	I17	0
NUM26	-4.76683	8.7659	-0.54	0.5867	0	I18	0
NUM27	-4.28427	6.8632	-0.62	0.5326	0	I19	0
NUM28	-13.47041	6.8339	-1.97	0.049	0	I20	0
NUM29	-14.92008	7.5751	-1.97	0.0491	0	I21	0
NUM30	-49.59056	7.92584	-6.26	<.0001	0	I22	0
NUM31	-41.43669	7.57101	-5.47	<.0001	0	I23	0
NUM32	-12.97193	7.3274	-1.77	0.077	0	I24	0
NUM33	-24.00449	7.26559	-3.3	0.001	0	I25	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----
--------	------------	----	------------	----------------------------

6	2.39	2	0.3021	-0.006	-0.009	-0.03	0.017	-0.013	-0.026
12	7.85	8	0.4487	-0.06	0.011	0.02	0.008	-0.025	0.011
18	13.19	14	0.5118	0.057	0.038	0.006	-0.007	0.004	0.001
24	20.86	20	0.4054	0.003	0.068	-0.03	0.019	-0.015	-0.027
30	24.49	26	0.548	-0.002	-0.025	-0.008	0.012	0.047	-0.013
36	35.73	32	0.2974	0.048	0.079	-0.027	0.019	-0.002	-0.015
42	38.39	38	0.4516	0.001	0.006	0.018	0.036	0.013	-0.024
48	43.22	44	0.5049	-0.011	0.058	-0.012	0.012	-0.02	0.006

Tests for Normality			
Test	Statistic	P-value	
Shapiro-Wilk	W	0.967182	Pr < W < 0.0001
Kolmogorov-Smirnov	D	0.043198	Pr > D < 0.0100
Cramer-von Mises	W-Sq	0.72219	Pr > W-Sq < 0.0050
Anderson-Darling	A-Sq	4.752578	Pr > A-Sq < 0.0050

## Pukul 18:30

### The ARIMA Procedure

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.44404	0.03028	14.66	<.0001	1	y	0
AR1,2	0.21558	0.03198	6.74	<.0001	2	y	0
AR1,3	0.09497	0.02918	3.25	0.0012	4	y	0
AR1,4	1.12E-01	0.02915	3.86	0.0001	8	y	0
AR1,5	0.09154	0.02846	3.22	0.0013	10	y	0
AR1,6	-0.04734	0.01852	-2.56	0.0107	37	y	0
NUM1	0.15447	0.01916	8.06	<.0001	0	t	0
NUM2	610.77826	11.60676	52.62	<.0001	0	H1	0
NUM3	607.73021	11.60542	52.37	<.0001	0	H2	0
NUM4	604.3691	11.58085	52.19	<.0001	0	H3	0
NUM5	610.83146	11.60141	52.65	<.0001	0	H4	0
NUM6	612.17124	11.61204	52.72	<.0001	0	H5	0
NUM7	597.6294	11.60812	51.48	<.0001	0	H6	0
NUM8	585.18305	11.60454	50.43	<.0001	0	H7	0
NUM9	-37.00195	11.17652	-3.31	0.001	0	I1	0
NUM10	-21.76975	9.56457	-2.28	0.023	0	I2	0
NUM11	-14.02392	11.06306	-1.27	0.2052	0	I3	0
NUM12	-115.94628	13.90144	-8.34	<.0001	0	I4	0
NUM13	-182.04647	11.61556	-15.67	<.0001	0	I5	0
NUM14	-47.76079	13.93108	-3.43	0.0006	0	I6	0
NUM15	-11.70624	11.05118	-1.06	0.2897	0	I7	0
NUM16	-11.10166	13.47438	-0.82	0.4102	0	I8	0
NUM17	-1.15742	13.44011	-0.09	0.9314	0	I9	0
NUM18	-20.19962	11.17533	-1.81	0.071	0	I10	0
NUM19	-6.58099	11.32845	-0.58	0.5614	0	I11	0



NUM20	-31.29567	11.46312	-2.73	0.0064	0	I12	0
NUM21	-22.56066	11.43201	-1.97	0.0487	0	I13	0
NUM22	-12.94631	13.43744	-0.96	0.3355	0	I14	0
NUM23	-17.46055	13.45182	-1.3	0.1946	0	I15	0
NUM24	1.47692	13.43163	0.11	0.9125	0	I16	0
NUM25	-44.06908	13.60534	-3.24	0.0012	0	I17	0
NUM26	-1.4338	11.01943	-0.13	0.8965	0	I18	0
NUM27	-16.62319	8.67567	-1.92	0.0556	0	I19	0
NUM28	-14.64428	8.64801	-1.69	0.0907	0	I20	0
NUM29	-27.87747	9.32068	-2.99	0.0028	0	I21	0
NUM30	-45.59293	9.56245	-4.77	<.0001	0	I22	0
NUM31	-35.72817	9.32123	-3.83	0.0001	0	I23	0
NUM32	-13.82484	9.10454	-1.52	0.1292	0	I24	0
NUM33	-27.44014	9.03194	-3.04	0.0024	0	I25	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	.	0	.	-0.025	-0.036	0.032	-0.051	0.021	0.012
12	11.08	6	0.086	0.023	-0.027	0.026	-0.033	-0.026	0.014
18	19.52	12	0.0768	-0.03	0.054	0.016	-0.037	0.003	-0.046
24	24.35	18	0.1438	0.043	0.047	-0.008	0.012	0	-0.008
30	29.1	24	0.2165	0.003	-0.018	-0.043	-0.004	0.043	-0.013
36	32.63	30	0.3388	-0.01	0.044	-0.011	0.012	0.029	0.004
42	38.22	36	0.3691	0.051	0.042	0.006	-0.01	0.006	-0.02
48	45.59	42	0.3251	-0.023	0.07	-0.007	0.03	-0.004	-0.003

## Tests for Normality

Test	Statistic	P-value
Shapiro-Wilk	W 0.830052	Pr < W <.0001
Kolmogorov-Smirnov	D 0.074865	Pr > D <.0100
Cramer-von Mises	W-Sq 2.324814	Pr > W-Sq <.0050
Anderson-Darling	A-Sq 15.28887	Pr > A-Sq <.0050

**Pukul 19:00**

## The ARIMA Procedure

## Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.69333	0.0307	22.58	<.0001	1	y	0
AR1,2	0.09554	0.03107	3.08	0.0022	2	y	0
AR1,3	0.14724	0.02012	7.32	<.0001	7	y	0
NUM1	1.47E-01	0.01947	7.53	<.0001	0	t	0
NUM2	647.55096	11.59394	55.85	<.0001	0	H1	0
NUM3	645.69314	11.57668	55.78	<.0001	0	H2	0

NUM4	644.21951	11.55248	55.76	<.0001	0	H3	0
NUM5	648.4202	11.5856	55.97	<.0001	0	H4	0
NUM6	649.38308	11.60724	55.95	<.0001	0	H5	0
NUM7	633.04516	11.60619	54.54	<.0001	0	H6	0
NUM8	623.49483	11.60217	53.74	<.0001	0	H7	0
NUM9	-34.36891	8.16916	-4.21	<.0001	0	I1	0
NUM10	-18.46415	6.9411	-2.66	0.0079	0	I2	0
NUM11	-8.32272	8.0627	-1.03	0.3022	0	I3	0
NUM12	-118.65882	10.45136	-11.35	<.0001	0	I4	0
NUM13	-207.24805	9.12061	-22.72	<.0001	0	I5	0
NUM14	-30.85612	10.4678	-2.95	0.0033	0	I6	0
NUM15	-4.45192	7.96519	-0.56	0.5763	0	I7	0
NUM16	-12.50287	9.78019	-1.28	0.2014	0	I8	0
NUM17	-0.89422	9.71692	-0.09	0.9267	0	I9	0
NUM18	-15.44606	8.05654	-1.92	0.0555	0	I10	0
NUM19	-4.77453	8.17341	-0.58	0.5592	0	I11	0
NUM20	-27.78097	8.81427	-3.15	0.0017	0	I12	0
NUM21	-19.5666	8.73386	-2.24	0.0253	0	I13	0
NUM22	-13.81314	9.70043	-1.42	0.1547	0	I14	0
NUM23	-18.1923	9.70751	-1.87	0.0612	0	I15	0
NUM24	-2.92628	9.70496	-0.3	0.7631	0	I16	0
NUM25	-23.07193	9.97562	-2.31	0.0209	0	I17	0
NUM26	-5.66374	8.0034	-0.71	0.4793	0	I18	0
NUM27	-17.19324	6.25512	-2.75	0.0061	0	I19	0
NUM28	-13.74808	6.21337	-2.21	0.0271	0	I20	0
NUM29	-15.3585	7.20084	-2.13	0.0332	0	I21	0
NUM30	-43.13503	7.85733	-5.49	<.0001	0	I22	0
NUM31	-29.87035	7.21778	-4.14	<.0001	0	I23	0
NUM32	-10.73141	6.96969	-1.54	0.1239	0	I24	0
NUM33	-22.37108	6.86397	-3.26	0.0012	0	I25	0

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr >ChiSq	-----Autocorrelations-----					
6	0.94	3	0.8158	0.004	-0.001	-0.012	-0.026	0.003	0.003
12	10.71	9	0.2963	0.008	-0.054	-0.009	0.025	-0.046	0.055
18	12.66	15	0.6289	0.017	0.024	0.017	0.003	0.015	-0.02
24	22.42	21	0.3758	-0.032	0.051	0.041	0.029	-0.046	0.021
30	32.15	27	0.2265	-0.017	-0.025	0.012	-0.04	0.062	-0.046
36	42.56	33	0.1232	-0.029	0.056	0.021	0.064	0.025	0.014
42	45.33	39	0.225	-0.045	0.008	0.001	-0.001	0.002	-0.019
48	51.82	45	0.2252	-0.026	0.03	0.034	0.033	-0.021	0.038

Tests for Normality

Test	Statistic	P-value
Shapiro-Wilk	W 0.936252	Pr < W <0.0001
Kolmogorov-Smirnov	D 0.062647	Pr > D <0.0100
Cramer-von Mises	W-Sq 1.120336	Pr > W-Sq <0.0050
Anderson-Darling	A-Sq 6.933819	Pr > A-Sq <0.0050

**Pukul 19:30**

## The ARIMA Procedure

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.6808	0.0307	22.17	<.0001	1	y	0
AR1,2	0.11648	0.03115	3.74	0.0002	2	y	0
AR1,3	0.12466	0.02021	6.17	<.0001	7	y	0
NUM1	0.13694	0.01806	7.58	<.0001	0	t	0
NUM2	653.89683	11.02571	59.31	<.0001	0	H1	0
NUM3	652.85192	11.01236	59.28	<.0001	0	H2	0
NUM4	651.03316	10.98967	59.24	<.0001	0	H3	0
NUM5	655.65638	11.01908	59.5	<.0001	0	H4	0
NUM6	655.29779	11.03853	59.36	<.0001	0	H5	0
NUM7	638.82828	11.03804	57.88	<.0001	0	H6	0
NUM8	634.25734	11.03249	57.49	<.0001	0	H7	0
NUM9	-29.81172	8.65093	-3.45	0.0006	0	I1	0
NUM10	-22.96083	7.3925	-3.11	0.0019	0	I2	0
NUM11	-8.85022	8.58779	-1.03	0.303	0	I3	0
NUM12	-119.12735	11.09631	-10.74	<.0001	0	I4	0
NUM13	-220.44742	9.6486	-22.85	<.0001	0	I5	0
NUM14	-29.27394	11.1083	-2.64	0.0085	0	I6	0
NUM15	-0.20345	8.49004	-0.02	0.9809	0	I7	0
NUM16	-4.78176	10.41744	-0.46	0.6463	0	I8	0
NUM17	1.1865	10.35286	0.11	0.9088	0	I9	0
NUM18	-15.6028	8.5954	-1.82	0.0698	0	I10	0
NUM19	-7.66594	8.71884	-0.88	0.3795	0	I11	0
NUM20	-21.59938	9.33489	-2.31	0.0209	0	I12	0
NUM21	-15.98816	9.25308	-1.73	0.0843	0	I13	0
NUM22	-12.90149	10.33674	-1.25	0.2123	0	I14	0
NUM23	-18.55744	10.34224	-1.79	0.073	0	I15	0
NUM24	-15.07572	10.3422	-1.46	0.1452	0	I16	0
NUM25	-23.62498	10.60865	-2.23	0.0262	0	I17	0
NUM26	-2.09828	8.52329	-0.25	0.8056	0	I18	0
NUM27	-16.9031	6.66553	-2.54	0.0114	0	I19	0
NUM28	-13.44193	6.61945	-2.03	0.0425	0	I20	0
NUM29	-12.4415	7.62768	-1.63	0.1032	0	I21	0
NUM30	-37.39392	8.27963	-4.52	<.0001	0	I22	0
NUM31	-28.92025	7.65383	-3.78	0.0002	0	I23	0
NUM32	-2.52548	7.3816	-0.34	0.7323	0	I24	0
NUM33	-13.69844	7.28014	-1.88	0.0602	0	I25	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.49	3	0.2128	0.006	0.019	-0.016	-0.058	0.001	0.008
12	10.51	9	0.3107	0.002	-0.054	-0.001	-0.017	-0.014	0.045
18	13.27	15	0.5818	0.035	0.02	-0.008	0.014	0.01	0.022
24	20.28	21	0.5034	-0.043	0.029	0.038	0.01	-0.045	-0.005
30	28.27	27	0.3971	-0.025	-0.012	0.008	-0.034	0.054	-0.047
36	47.98	33	0.0445	-0.026	0.042	0.023	0.118	-0.006	0.017
42	52.6	39	0.0716	-0.041	0.022	0.01	-0.011	-0.004	-0.041
48	60.05	45	0.066	-0.008	0.018	0.052	0.043	-0.038	0.015

## Tests for Normality

Test	Statistic	P-value
Shapiro-Wilk	W 0.936965	Pr < W < 0.0001
Kolmogorov-Smirnov	D 0.060076	Pr > D < 0.0100
Cramer-von Mises	W-Sq 1.414712	Pr > W-Sq < 0.0050
Anderson-Darling	A-Sq 8.406026	Pr > A-Sq < 0.0050

**Pukul 20:00**

## The ARIMA Procedure

## Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.6942	0.03087	22.49	<.0001	1	y	0
AR1,2	0.11439	0.03135	3.65	0.0003	2	y	0
AR1,3	0.11071	0.02008	5.51	<.0001	7	y	0
NUM1	1.37E-01	0.01776	7.7	<.0001	0	t	0
NUM2	646.19188	10.90039	59.28	<.0001	0	H1	0
NUM3	644.22952	10.88779	59.17	<.0001	0	H2	0
NUM4	642.99091	10.86533	59.18	<.0001	0	H3	0
NUM5	647.49491	10.89382	59.44	<.0001	0	H4	0
NUM6	646.30973	10.91268	59.23	<.0001	0	H5	0
NUM7	630.51017	10.91203	57.78	<.0001	0	H6	0
NUM8	629.01544	10.90664	57.67	<.0001	0	H7	0
NUM9	-26.90653	8.62306	-3.12	0.0019	0	I1	0
NUM10	-22.73145	7.3672	-3.09	0.0021	0	I2	0
NUM11	-5.77587	8.56267	-0.67	0.5001	0	I3	0
NUM12	-115.66725	11.08546	-10.43	<.0001	0	I4	0
NUM13	-223.29503	9.65542	-23.13	<.0001	0	I5	0
NUM14	-28.6682	11.08875	-2.59	0.0099	0	I6	0
NUM15	-2.96245	8.46507	-0.35	0.7264	0	I7	0
NUM16	-4.82578	10.3827	-0.46	0.6422	0	I8	0
NUM17	6.68256	10.30723	0.65	0.5169	0	I9	0
NUM18	-10.54832	8.56603	-1.23	0.2184	0	I10	0

NUM19	-0.63419	8.68974	-0.07	0.9418	0	I11	0
NUM20	-21.60885	9.32395	-2.32	0.0207	0	I12	0
NUM21	-13.65286	9.24338	-1.48	0.14	0	I13	0
NUM22	-11.23014	10.30123	-1.09	0.2759	0	I14	0
NUM23	-19.11248	10.30965	-1.85	0.064	0	I15	0
NUM24	-9.36811	10.30578	-0.91	0.3635	0	I16	0
NUM25	-19.46612	10.57013	-1.84	0.0658	0	I17	0
NUM26	3.53044	8.49175	0.42	0.6777	0	I18	0
NUM27	-18.72197	6.6464	-2.82	0.0049	0	I19	0
NUM28	-16.41702	6.60692	-2.48	0.0131	0	I20	0
NUM29	-9.71721	7.63622	-1.27	0.2035	0	I21	0
NUM30	-38.60705	8.30693	-4.65	<0.0001	0	I22	0
NUM31	-25.6021	7.65757	-3.34	0.0009	0	I23	0
NUM32	-1.13401	7.37988	-0.15	0.8779	0	I24	0
NUM33	-15.84455	7.27429	-2.18	0.0296	0	I25	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr >ChiSq	-----Autocorrelations-----					
6	3.2	3	0.3618	-0.002	0.008	-0.02	-0.046	-0.013	0.013
12	9.79	9	0.3678	-0.045	-0.037	0.031	-0.007	-0.022	0.032
18	14.09	15	0.5184	0.047	0.03	0.008	0.018	-0.002	0.019
24	22.66	21	0.3621	-0.024	0.019	0.063	-0.024	-0.047	0.008
30	31.65	27	0.2451	-0.034	0.018	0.018	-0.068	0.034	-0.02
36	45.46	33	0.0729	-0.023	0.065	0.03	0.076	0.006	0.026
42	50.97	39	0.0949	-0.039	0.044	-0.005	0.002	-0.019	-0.031
48	55.62	45	0.1332	-0.006	0.029	0.035	0.031	-0.024	0.02

## Tests for Normality

Test	Statistic	P-value
Shapiro-Wilk	W	0.95203
Kolmogorov-Smirnov	D	0.047191
Cramer-von Mises	W-Sq	0.81018
Anderson-Darling	A-Sq	5.228546
	Pr < W	<0.0001
	Pr > D	<0.0100
	Pr > W-Sq	<0.0050
	Pr > A-Sq	<0.0050

**Pukul 20:30**

## The ARIMA Procedure

## Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.63558	0.03059	20.77	<.0001	1	y	0
AR1,2	0.15078	0.03145	4.79	<.0001	2	y	0
AR1,3	0.08985	0.02265	3.97	<.0001	7	y	0
AR1,4	5.82E-02	0.02136	2.73	0.0065	12	y	0
NUM1	0.13942	0.02109	6.61	<.0001	0	t	0

NUM2	633.21642	12.60112	50.25	<.0001	0	H1	0
NUM3	631.16791	12.58951	50.13	<.0001	0	H2	0
NUM4	630.10125	12.56345	50.15	<.0001	0	H3	0
NUM5	633.66681	12.59288	50.32	<.0001	0	H4	0
NUM6	633.12606	12.61319	50.2	<.0001	0	H5	0
NUM7	615.68235	12.61079	48.82	<.0001	0	H6	0
NUM8	619.4838	12.6059	49.14	<.0001	0	H7	0
NUM9	-17.37825	9.36425	-1.86	0.0638	0	I1	0
NUM10	-16.44688	7.9386	-2.07	0.0385	0	I2	0
NUM11	-0.92439	9.23665	-0.1	0.9203	0	I3	0
NUM12	-109.73112	11.84334	-9.27	<.0001	0	I4	0
NUM13	-230.10563	10.19357	-22.57	<.0001	0	I5	0
NUM14	-22.337	11.84396	-1.89	0.0596	0	I6	0
NUM15	2.52983	9.15624	0.28	0.7824	0	I7	0
NUM16	-3.21406	11.19278	-0.29	0.774	0	I8	0
NUM17	4.87613	11.12797	0.44	0.6613	0	I9	0
NUM18	-13.58753	9.26331	-1.47	0.1427	0	I10	0
NUM19	4.09688	9.38618	0.44	0.6626	0	I11	0
NUM20	-16.73871	9.90445	-1.69	0.0913	0	I12	0
NUM21	-9.54836	9.83194	-0.97	0.3317	0	I13	0
NUM22	-8.90391	11.11978	-0.8	0.4235	0	I14	0
NUM23	-15.03625	11.132	-1.35	0.1771	0	I15	0
NUM24	-5.04918	11.12892	-0.45	0.6501	0	I16	0
NUM25	-8.65146	11.37422	-0.76	0.4471	0	I17	0
NUM26	3.13716	9.15378	0.34	0.7319	0	I18	0
NUM27	-16.48279	7.16981	-2.3	0.0217	0	I19	0
NUM28	-13.53927	7.13616	-1.9	0.0581	0	I20	0
NUM29	-9.68322	8.09987	-1.2	0.2322	0	I21	0
NUM30	-34.97889	8.66709	-4.04	<.0001	0	I22	0
NUM31	-22.58663	8.12022	-2.78	0.0055	0	I23	0
NUM32	-2.80794	7.83936	-0.36	0.7203	0	I24	0
NUM33	-17.78271	7.74102	-2.3	0.0218	0	I25	0

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr >ChiSq	-----Autocorrelations-----					
6	1.69	2	0.4288	0	0.011	-0.002	-0.037	0.006	0.001
12	7.72	8	0.4611	-0.018	-0.021	0.059	0.017	-0.027	-0.015
18	11.33	14	0.6603	0.009	0.012	0.001	0.038	-0.03	0.025
24	14.08	20	0.8263	-0.024	0.021	0.004	-0.007	-0.032	-0.019
30	28.1	26	0.3534	-0.013	-0.001	0.019	-0.103	0.036	-0.001
36	46.16	32	0.0504	-0.02	0.057	0.009	0.102	-0.035	0.025
42	50.05	38	0.0913	-0.018	0.027	0.013	-0.024	-0.008	-0.04
48	53.38	44	0.1571	0.025	0.024	0.039	0.009	-0.009	0.008

Test		Tests for Normality	
Statistic	P-value	Statistic	P-value
Shapiro-Wilk	W	0.924887	Pr < W < 0.0001

Kolmogorov-Smirnov	D	0.063894	Pr > D	<0.0100
Cramer-von Mises	W-Sq	1.613167	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	9.459613	Pr > A-Sq	<0.0050

## Pukul 21:00

### The ARIMA Procedure

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.36273	0.03058	11.86	<.0001	1	y	0
AR1,2	0.21413	0.03206	6.68	<.0001	2	y	0
AR1,3	0.12062	0.03103	3.89	0.0001	3	y	0
AR1,4	6.68E-02	0.03018	2.21	0.0271	8	y	0
AR1,5	0.06626	0.03095	2.14	0.0325	9	y	0
AR1,6	0.05928	0.02782	2.13	0.0333	12	y	0
NUM1	0.13182	0.02068	6.37	<.0001	0	t	0
NUM2	627.24345	12.85577	48.79	<.0001	0	H1	0
NUM3	624.93532	12.85978	48.6	<.0001	0	H2	0
NUM4	624.87476	12.83619	48.68	<.0001	0	H3	0
NUM5	627.83319	12.85455	48.84	<.0001	0	H4	0
NUM6	627.19418	12.86701	48.74	<.0001	0	H5	0
NUM7	607.08316	12.86683	47.18	<.0001	0	H6	0
NUM8	615.42094	12.85311	47.88	<.0001	0	H7	0
NUM9	-22.11145	15.11203	-1.46	0.1437	0	I1	0
NUM10	-27.55968	12.98171	-2.12	0.034	0	I2	0
NUM11	5.78535	15.07567	0.38	0.7012	0	I3	0
NUM12	-108.58139	18.66435	-5.82	<.0001	0	I4	0
NUM13	-246.2653	15.45305	-15.94	<.0001	0	I5	0
NUM14	-26.74901	18.74178	-1.43	0.1538	0	I6	0
NUM15	9.08657	15.07207	0.6	0.5467	0	I7	0
NUM16	-4.60999	18.32593	-0.25	0.8014	0	I8	0
NUM17	8.87787	18.27826	0.49	0.6273	0	I9	0
NUM18	-0.93866	15.14468	-0.06	0.9506	0	I10	0
NUM19	0.94696	15.29277	0.06	0.9506	0	I11	0
NUM20	-17.04862	15.34583	-1.11	0.2668	0	I12	0
NUM21	-5.79915	15.30436	-0.38	0.7048	0	I13	0
NUM22	-7.22434	18.27641	-0.4	0.6927	0	I14	0
NUM23	-16.29848	18.293	-0.89	0.3731	0	I15	0
NUM24	-2.17537	18.29157	-0.12	0.9054	0	I16	0
NUM25	-12.42614	18.4611	-0.67	0.501	0	I17	0
NUM26	4.97672	14.95658	0.33	0.7394	0	I18	0
NUM27	-10.44114	11.77931	-0.89	0.3756	0	I19	0
NUM28	-13.93608	11.73999	-1.19	0.2355	0	I20	0
NUM29	-7.18649	12.29313	-0.58	0.5589	0	I21	0
NUM30	-37.67762	12.48025	-3.02	0.0026	0	I22	0
NUM31	-25.68672	12.33206	-2.08	0.0375	0	I23	0

NUM32	-2.30051	12.11483	-0.19	0.8494	0	I24	0
NUM33	-12.09559	12.07525	-1	0.3167	0	I25	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	.	0	.	-0.009	-0.013	-0.017	0.026	-0.017	0.002
12	4.5	6	0.6094	0.019	-0.01	-0.013	0.03	-0.018	-0.028
18	6.82	12	0.8694	0.02	0.033	0.018	0.012	-0.001	0.01
24	9.81	18	0.9381	-0.019	0.03	-0.008	0.006	-0.018	-0.031
30	13.34	24	0.9602	-0.032	0.005	0.004	-0.042	0.006	0.016
36	18.97	30	0.9407	-0.008	0.03	0.023	0.052	-0.003	0.029
42	20.78	36	0.98	-0.011	0.022	-0.031	-0.007	-0.001	0
48	23.2	42	0.9918	0.02	0.031	0.012	0.013	-0.017	0.012

## Tests for Normality

Test	Statistic	P-value
Shapiro-Wilk	W 0.592845	Pr < W < 0.0001
Kolmogorov-Smirnov	D 0.124101	Pr > D < 0.0100
Cramer-von Mises	W-Sq 7.574485	Pr > W-Sq < 0.0050
Anderson-Darling	A-Sq 46.97153	Pr > A-Sq < 0.0050

**Pukul 22:00**

## The ARIMA Procedure

## Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.44972	0.03061	14.69	<.0001	1	y	0
AR1,2	0.22839	0.03309	6.9	<.0001	2	y	0
AR1,3	0.0861	0.03113	2.77	0.0058	3	y	0
AR1,4	1.22E-01	0.02394	5.11	<.0001	8	y	0
NUM1	0.12346	0.01852	6.66	<.0001	0	t	0
NUM2	581.41692	11.57639	50.22	<.0001	0	H1	0
NUM3	580.41452	11.57606	50.14	<.0001	0	H2	0
NUM4	579.9308	11.55293	50.2	<.0001	0	H3	0
NUM5	580.7837	11.57451	50.18	<.0001	0	H4	0
NUM6	582.11813	11.58784	50.24	<.0001	0	H5	0
NUM7	571.75549	11.58847	49.34	<.0001	0	H6	0
NUM8	574.02569	11.57668	49.58	<.0001	0	H7	0
NUM9	-15.47302	12.99252	-1.19	0.234	0	I1	0
NUM10	-24.85804	11.16268	-2.23	0.0262	0	I2	0
NUM11	8.27768	12.92599	0.64	0.5221	0	I3	0
NUM12	-72.02869	16.18125	-4.45	<.0001	0	I4	0
NUM13	-216.81953	13.48836	-16.07	<.0001	0	I5	0



NUM14	-26.98153	16.25039	-1.66	0.0971	0	16	0
NUM15	5.91487	12.92195	0.46	0.6472	0	17	0
NUM16	-6.03276	15.75083	-0.38	0.7018	0	18	0
NUM17	5.83311	15.69938	0.37	0.7103	0	19	0
NUM18	-5.09583	13.05006	-0.39	0.6963	0	110	0
NUM19	10.10616	13.19618	0.77	0.4439	0	111	0
NUM20	-9.88037	13.34627	-0.74	0.4593	0	112	0
NUM21	-4.50691	13.29632	-0.34	0.7347	0	113	0
NUM22	-3.6261	15.70085	-0.23	0.8174	0	114	0
NUM23	-21.21617	15.70086	-1.35	0.1769	0	115	0
NUM24	11.22441	15.70236	0.71	0.4749	0	116	0
NUM25	3.12843	15.89496	0.2	0.844	0	117	0
NUM26	-3.29288	12.8762	-0.26	0.7982	0	118	0
NUM27	-11.81545	10.11802	-1.17	0.2432	0	119	0
NUM28	-14.98122	10.09384	-1.48	0.1381	0	120	0
NUM29	-4.4967	10.76629	-0.42	0.6763	0	121	0
NUM30	-27.04414	11.02969	-2.45	0.0144	0	122	0
NUM31	-14.26092	10.84347	-1.32	0.1887	0	123	0
NUM32	6.82193	10.5713	0.65	0.5189	0	124	0
NUM33	-9.89124	10.48389	-0.94	0.3457	0	125	0

## Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	1.83	2	0.4005	-0.009	-0.009	-0.017	0.009	-0.033	0.003
12	6.7	8	0.5693	0.003	-0.038	0.025	-0.015	-0.045	-0.006
18	13.61	14	0.479	0.039	0.043	0.033	0.035	0.022	-0.001
24	17.29	20	0.6339	-0.028	0.034	0.004	0	0.004	-0.036
30	23.81	26	0.5868	-0.055	-0.004	-0.028	-0.021	0	0.039
36	32.7	32	0.4323	0.024	0.02	-0.007	0.06	0.035	0.045
42	35.07	38	0.6056	0.023	0.013	-0.01	0	-0.007	-0.035
48	41.51	44	0.5789	0.021	0.045	0.009	0.019	-0.01	0.051

## Tests for Normality

Test	Statistic	P-value
Shapiro-Wilk	W	0.773782
Kolmogorov-Smirnov	D	0.094424
Cramer-von Mises	W-Sq	3.645094
Anderson-Darling	A-Sq	22.83383
	Pr < W	<0.0001
	Pr > D	<0.0100
	Pr > W-Sq	<0.0050
	Pr > A-Sq	<0.0050

**Pukul 23:00**

## The ARIMA Procedure

## Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.49087	0.03049	16.1	<.0001	1	y	0
AR1,2	0.20061	0.03395	5.91	<.0001	2	y	0
AR1,3	0.09366	0.033	2.84	0.0046	3	y	0
AR1,4	-6.64E-02	0.03122	-2.13	0.0337	5	y	0
AR1,5	0.11101	0.02785	3.99	<.0001	7	y	0
AR1,6	0.08636	0.02301	3.75	0.0002	13	y	0
NUM1	0.12039	0.02042	5.9	<.0001	0	t	0
NUM2	521.47665	12.43355	41.94	<.0001	0	H1	0
NUM3	519.22043	12.43003	41.77	<.0001	0	H2	0
NUM4	520.63673	12.40628	41.97	<.0001	0	H3	0
NUM5	521.27141	12.42897	41.94	<.0001	0	H4	0
NUM6	525.05472	12.44762	42.18	<.0001	0	H5	0
NUM7	516.60469	12.44761	41.5	<.0001	0	H6	0
NUM8	515.10386	12.44054	41.41	<.0001	0	H7	0
NUM9	-16.20498	11.53918	-1.4	0.1605	0	I1	0
NUM10	-26.17622	9.8509	-2.66	0.008	0	I2	0
NUM11	4.12926	11.44571	0.36	0.7183	0	I3	0
NUM12	-49.45188	14.32958	-3.45	0.0006	0	I4	0
NUM13	-184.26438	12.01456	-15.34	<.0001	0	I5	0
NUM14	-23.84887	14.369	-1.66	0.0973	0	I6	0
NUM15	14.68905	11.37909	1.29	0.197	0	I7	0
NUM16	2.05783	13.90171	0.15	0.8823	0	I8	0
NUM17	43.8576	13.8394	3.17	0.0016	0	I9	0
NUM18	-4.62341	11.50392	-0.4	0.6878	0	I10	0
NUM19	3.36344	11.61931	0.29	0.7723	0	I11	0
NUM20	-12.81299	11.87476	-1.08	0.2808	0	I12	0
NUM21	-4.36962	11.8234	-0.37	0.7118	0	I13	0
NUM22	2.28973	13.83075	0.17	0.8685	0	I14	0
NUM23	-9.59018	13.86341	-0.69	0.4892	0	I15	0
NUM24	5.84546	13.8278	0.42	0.6726	0	I16	0
NUM25	0.16056	14.05273	0.01	0.9909	0	I17	0
NUM26	5.95816	11.38291	0.52	0.6008	0	I18	0
NUM27	-10.01379	8.88872	-1.13	0.2602	0	I19	0
NUM28	-9.75961	8.87174	-1.1	0.2715	0	I20	0
NUM29	1.04368	9.62069	0.11	0.9136	0	I21	0
NUM30	-43.97165	9.9033	-4.44	<.0001	0	I22	0
NUM31	-7.06492	9.60068	-0.74	0.462	0	I23	0
NUM32	5.77171	9.3445	0.62	0.5369	0	I24	0
NUM33	-15.4257	9.29247	-1.66	0.0972	0	I25	0

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	.	0	.	-0.002	-0.006	-0.004	0.032	-0.004	-0.007
12	10.05	6	0.1224	-0.009	0.034	0.059	0.001	-0.056	0.007
18	12.44	12	0.4108	0.026	-0.031	-0.001	-0.012	0.011	0.017
24	19.78	18	0.3451	-0.041	-0.004	0.037	-0.02	-0.043	-0.035
30	28.58	24	0.2363	-0.056	-0.042	0.004	-0.031	-0.032	0.03
36	33.86	30	0.2863	-0.007	0.037	0.042	0.02	0.025	0.02
42	36.79	36	0.4322	0.012	0.021	0.01	0.023	-0.016	-0.033
48	46.73	42	0.2842	0.005	0.056	0.018	0.036	-0.044	0.045

Tests for Normality				
Test	Statistic	P-value		
Shapiro-Wilk	W	0.873812	Pr < W	<0.0001
Kolmogorov-Smirnov	D	0.078361	Pr > D	<0.0100
Cramer-von Mises	W-Sq	2.279516	Pr > W-Sq	<0.0050
Anderson-Darling	A-Sq	14.01421	Pr > A-Sq	<0.0050

## Pukul 24:00

### The ARIMA Procedure

Conditional Least Squares Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr >  t	Lag	Variable	Shift
AR1,1	0.66029	0.03047	21.67	<.0001	1	y	0
AR1,2	0.14687	0.03091	4.75	<.0001	2	y	0
AR1,3	0.1115	0.01996	5.59	<.0001	8	y	0
NUM1	0.11822	0.01752	6.75	<.0001	0	t	0
NUM2	474.72392	10.6937	44.39	<.0001	0	H1	0
NUM3	474.5986	10.68588	44.41	<.0001	0	H2	0
NUM4	476.0029	10.66212	44.64	<.0001	0	H3	0
NUM5	478.05497	10.68657	44.73	<.0001	0	H4	0
NUM6	480.23016	10.70244	44.87	<.0001	0	H5	0
NUM7	477.96436	10.70328	44.66	<.0001	0	H6	0
NUM8	472.1658	10.69768	44.14	<.0001	0	H7	0
NUM9	-10.47442	8.71497	-1.2	0.2297	0	I1	0
NUM10	-20.70807	7.4624	-2.77	0.0056	0	I2	0
NUM11	2.15419	8.66528	0.25	0.8037	0	I3	0
NUM12	-50.00941	11.15605	-4.48	<.0001	0	I4	0
NUM13	-148.777	9.57591	-15.54	<.0001	0	I5	0
NUM14	-19.44425	11.14588	-1.74	0.0814	0	I6	0
NUM15	13.46016	8.60264	1.56	0.118	0	I7	0
NUM16	5.52005	10.50986	0.53	0.5995	0	I8	0
NUM17	3.21517	10.45127	0.31	0.7584	0	I9	0
NUM18	-4.07298	8.69485	-0.47	0.6396	0	I10	0
NUM19	2.11774	8.82756	0.24	0.8105	0	I11	0

NUM20	-7.51273	9.33393	-0.8	0.4211	0	I12	0
NUM21	-2.49016	9.26773	-0.27	0.7882	0	I13	0
NUM22	2.7577	10.45262	0.26	0.792	0	I14	0
NUM23	-8.22214	10.45094	-0.79	0.4316	0	I15	0
NUM24	1.9865	10.45262	0.19	0.8493	0	I16	0
NUM25	2.84906	10.67635	0.27	0.7896	0	I17	0
NUM26	-5.08605	8.62419	-0.59	0.5555	0	I18	0
NUM27	-7.84319	6.76956	-1.16	0.2469	0	I19	0
NUM28	-4.68034	6.72234	-0.7	0.4864	0	I20	0
NUM29	-1.90882	7.65518	-0.25	0.8031	0	I21	0
NUM30	-14.19427	8.24029	-1.72	0.0853	0	I22	0
NUM31	-3.09902	7.7047	-0.4	0.6876	0	I23	0
NUM32	9.46553	7.42068	1.28	0.2024	0	I24	0
NUM33	-10.40321	7.31341	-1.42	0.1552	0	I25	0

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr >ChiSq	-----Autocorrelations-----						
6	1.44	3	0.6954	-0.003	-0.008	-0.014	0.014	-0.028	0.007	
12	3.78	9	0.9251	-0.001	-0.03	0	-0.007	-0.033	0.009	
18	12.08	15	0.6728	0.007	0.055	-0.027	0.031	0.034	0.039	
24	25.97	21	0.2077	-0.087	0.05	-0.006	0.041	-0.003	-0.025	
30	36.38	27	0.1072	-0.07	-0.041	0.02	-0.041	0.007	0.024	
36	53.09	33	0.0148	-0.007	0.089	0.008	0.082	0.002	0.01	
42	60.31	39	0.0159	-0.005	0.03	-0.027	0.022	-0.03	-0.057	
48	71.71	45	0.0069	0.028	0.059	0.005	0.052	-0.022	0.05	

Tests for Normality

Test	Statistic	P-value
Shapiro-Wilk	W 0.968513	Pr < W <0.0001
Kolmogorov-Smirnov	D 0.049883	Pr > D <0.0100
Cramer-von Mises	W-Sq 0.986373	Pr > W-Sq <0.0050
Anderson-Darling	A-Sq 6.047977	Pr > A-Sq <0.0050

**Lampiran 4.** Uji *White*

Data Aktual

Jam	<i>F</i>	df1	df2	<i>P-value</i>	Keputusan
01:00	0.326259	2	1042	0.721692	Linier
	1.395155	2	1042	0.248257	
	0.118224	2	1042	0.888509	
	0.440833	2	1042	0.64362	
	1.238106	2	1042	0.290359	
	0.285537	2	1042	0.75167	
	0.587474	2	1042	0.555913	
	0.010167	2	1042	0.989884	
	0.33637	2	1042	0.714436	
	0.056389	2	1042	0.945175	
02:00	0.385233	2	1025	0.68039	Linier
	0.082644	2	1025	0.920685	
	0.110126	2	1025	0.895732	
	0.167958	2	1025	0.845412	
	1.568691	2	1025	0.208817	
	0.076161	2	1025	0.926672	
	5.138215	2	1025	0.00602	
	0.738512	2	1025	0.478079	
	2.713488	2	1025	0.066781	
	0.476545	2	1025	0.621063	
03:00	0.326051	2	1006	0.721845	Linier
	0.278184	2	1006	0.757216	
	0.865677	2	1006	0.42108	
	0.881603	2	1006	0.414438	
	0.38492	2	1006	0.680606	
	3.548687	2	1006	0.029123	
	0.034259	2	1006	0.966323	
	1.057216	2	1006	0.347807	
	0.953901	2	1006	0.385583	
	0.897241	2	1006	0.408019	

**Lampiran 4. Uji *White* (Lanjutan)**

<b>Jam</b>	<b><i>F</i></b>	<b>df1</b>	<b>df2</b>	<b><i>P-value</i></b>	<b>Keputusan</b>
04:00	0.149628	2	1022	0.861047	Linier
	1.371676	2	1022	0.254148	
	0.6331	2	1022	0.531151	
	1.947739	2	1022	0.143125	
	0.834329	2	1022	0.434461	
	0.631305	2	1022	0.532105	
	3.115227	2	1022	0.04479	
	0.45757	2	1022	0.632949	
	0.834577	2	1022	0.434354	
	0.977747	2	1022	0.376509	
05:00	1.264034	2	1027	0.282951	Linier
	1.139601	2	1027	0.320351	
	5.721367	2	1027	0.003381	
	4.03767	2	1027	0.017919	
	0.271266	2	1027	0.762469	
	1.298161	2	1027	0.273481	
	0.113049	2	1027	0.893118	
	0.245185	2	1027	0.782605	
	1.098487	2	1027	0.333767	
0.358432	2	1027	0.698859		
06:00	3.667553	2	1008	0.02588	Linier
	1.382512	2	1008	0.251423	
	0.928324	2	1008	0.395553	
	4.531877	2	1008	0.010981	
	0.647522	2	1008	0.523559	
	0.163906	2	1008	0.848845	
	0.517495	2	1008	0.59617	
	0.53586	2	1008	0.585333	
	0.722577	2	1008	0.485751	
1.516501	2	1008	0.219979		

**Lampiran 4.** Uji *White* (Lanjutan)

<b>Jam</b>	<b><i>F</i></b>	<b>df1</b>	<b>df2</b>	<b><i>P-value</i></b>	<b>Keputusan</b>
07:00	1.53609	2	1008	0.215724	Linier
	0.462338	2	1008	0.629943	
	3.845923	2	1008	0.021681	
	0.805505	2	1008	0.44715	
	0.26576	2	1008	0.766677	
	0.057589	2	1008	0.944041	
	1.164079	2	1008	0.31263	
	2.108442	2	1008	0.121962	
	1.773436	2	1008	0.170278	
	0.055498	2	1008	0.946017	
08:00	3.130187	2	991	0.044142	Linier
	0.005625	2	991	0.994391	
	1.037101	2	991	0.354865	
	0.155996	2	991	0.855583	
	1.996013	2	991	0.136422	
	1.583372	2	991	0.205801	
	0.786201	2	991	0.455856	
	0.667885	2	991	0.513023	
	0.637605	2	991	0.528774	
0.265379	2	991	0.76697		
09:00	0.587	2	1005	0.556183	Linier
	1.889501	2	1005	0.151684	
	0.75374	2	1005	0.470869	
	0.756741	2	1005	0.46946	
	0.301751	2	1005	0.739589	
	1.501031	2	1005	0.2234	
	1.72229	2	1005	0.179183	
	0.434894	2	1005	0.647455	
	1.023387	2	1005	0.35975	
0.914826	2	1005	0.40092		

**Lampiran 4. Uji White (Lanjutan)**

<b>Jam</b>	<b><i>F</i></b>	<b>df1</b>	<b>df2</b>	<b><i>P-value</i></b>	<b>Keputusan</b>
10:00	1.588115	2	999	0.204826	Linier
	0.421656	2	999	0.656076	
	0.733872	2	999	0.480305	
	1.328906	2	999	0.265235	
	1.640352	2	999	0.194434	
	3.980141	2	999	0.01898	
	0.231816	2	999	0.793135	
	0.205288	2	999	0.814447	
	0.057305	2	999	0.944309	
0.415131	2	999	0.660368		
11:00	0.27994	2	1001	0.755888	Linier
	0.401659	2	1001	0.669317	
	0.09262	2	1001	0.911548	
	2.090676	2	1001	0.124143	
	2.161537	2	1001	0.115685	
	0.420837	2	1001	0.656613	
	0.240562	2	1001	0.786231	
	1.030427	2	1001	0.357233	
	1.678142	2	1001	0.187245	
1.18525	2	1001	0.306099		
12:00	0.149862	2	999	0.860846	Linier
	1.231794	2	999	0.292211	
	1.326543	2	999	0.26586	
	4.751259	2	999	0.008837	
	3.629711	2	999	0.026874	
	2.230088	2	999	0.108054	
	0.260401	2	999	0.770795	
	0.25482	2	999	0.775107	
	0.733744	2	999	0.480367	
1.374853	2	999	0.253355		



**Lampiran 4. Uji White (Lanjutan)**

<b>Jam</b>	<b><i>F</i></b>	<b>df1</b>	<b>df2</b>	<b><i>P-value</i></b>	<b>Keputusan</b>
13:00	0.868591	2	998	0.419859	Linier
	0.405448	2	998	0.666788	
	0.631184	2	998	0.532174	
	0.828224	2	998	0.437124	
	0.159895	2	998	0.852255	
	0.324268	2	998	0.723133	
	2.505561	2	998	0.082143	
	2.728801	2	998	0.065785	
	2.546442	2	998	0.078869	
1.342403	2	998	0.261688		
14:00	1.619495	2	998	0.198519	Linier
	0.403907	2	998	0.667815	
	3.061082	2	998	0.047277	
	0.095089	2	998	0.909301	
	2.76449	2	998	0.063491	
	0.117935	2	998	0.888766	
	0.385838	2	998	0.679982	
	1.216717	2	998	0.29664	
	1.972463	2	998	0.139656	
1.487614	2	998	0.226412		
15:00	1.712885	2	997	0.180875	Linier
	1.416188	2	997	0.243125	
	0.945348	2	997	0.388892	
	3.335309	2	997	0.036001	
	1.858007	2	997	0.156523	
	4.33594	2	997	0.013337	
	0.071281	2	997	0.931205	
	0.2908	2	997	0.747729	
	3.877138	2	997	0.021023	
0.840145	2	997	0.431953		

**Lampiran 4. Uji *White* (Lanjutan)**

<b>Jam</b>	<b><i>F</i></b>	<b>df1</b>	<b>df2</b>	<b><i>P-value</i></b>	<b>Keputusan</b>
16:00	0.080872	2	998	0.922318	Linier
	0.075244	2	998	0.927523	
	4.634473	2	998	0.009921	
	2.096395	2	998	0.12344	
	1.531626	2	998	0.216692	
	4.409039	2	998	0.012405	
	0.877683	2	998	0.416066	
	3.747139	2	998	0.023918	
	1.827178	2	998	0.161405	
	0.810533	2	998	0.444913	
17:00	2.453132	2	995	0.086544	Linier
	5.267571	2	995	0.005301	
	1.182074	2	995	0.307072	
	2.513082	2	995	0.081532	
	0.628871	2	995	0.533405	
	0.383642	2	995	0.681476	
	0.322918	2	995	0.724109	
	2.444215	2	995	0.087315	
	2.752496	2	995	0.064254	
1.403958	2	995	0.246109		
18:00	1.366868	2	1007	0.255377	Linier
	4.56073	2	1007	0.010671	
	0.429652	2	1007	0.650855	
	0.407796	2	1007	0.665224	
	2.391809	2	1007	0.091983	
	0.257848	2	1007	0.772763	
	1.645157	2	1007	0.193501	
	0.052537	2	1007	0.948822	
	0.481583	2	1007	0.617947	
0.684231	2	1007	0.504713		

**Lampiran 4.** Uji *White* (Lanjutan)

Jam	<i>F</i>	df1	df2	<i>P-value</i>	Keputusan
18:30	0.429481	2	1008	0.650966	Linier
	0.574234	2	1008	0.56332	
	0.876566	2	1008	0.416527	
	0.127277	2	1008	0.880504	
	0.417643	2	1008	0.658711	
	0.493285	2	1008	0.610765	
	7.067733	2	1008	0.000895	
	1.001951	2	1008	0.367528	
	0.301118	2	1008	0.740057	
0.961214	2	1008	0.382779		
19:00	0.058735	2	999	0.94296	Linier
	0.610389	2	999	0.543342	
	2.988553	2	999	0.050811	
	4.474889	2	999	0.011621	
	0.10568	2	999	0.899723	
	0.357765	2	999	0.699327	
	1.473691	2	999	0.229576	
	0.208906	2	999	0.811507	
	0.700669	2	999	0.496497	
3.936934	2	999	0.019811		
19:30	0.716165	2	1002	0.488873	Linier
	0.384281	2	1002	0.681041	
	5.591859	2	1002	0.003845	
	0.075372	2	1002	0.927403	
	4.391483	2	1002	0.012622	
	0.607634	2	1002	0.544838	
	5.078472	2	1002	0.006391	
	0.08904	2	1002	0.914816	
	1.631679	2	1002	0.19612	
5.87768	2	1002	0.002899		


**Lampiran 4. Uji *White* (Lanjutan)**

<b>Jam</b>	<b><i>F</i></b>	<b>df1</b>	<b>df2</b>	<b><i>P-value</i></b>	<b>Keputusan</b>
20:00	0.861675	2	1002	0.422767	Linier
	1.491188	2	1002	0.225604	
	4.183	2	1002	0.01552	
	0.92379	2	1002	0.39735	
	0.035157	2	1002	0.965455	
	3.125085	2	1002	0.044362	
	2.035255	2	1002	0.131187	
	0.104364	2	1002	0.900908	
	0.262829	2	1002	0.768926	
	0.421027	2	1002	0.656488	
20:30	4.92439	2	1004	0.007444	Linier
	0.036774	2	1004	0.963895	
	0.327846	2	1004	0.720551	
	0.34001	2	1004	0.711845	
	0.225452	2	1004	0.798196	
	2.550324	2	1004	0.078562	
	0.60976	2	1004	0.543682	
	4.577312	2	1004	0.010498	
	0.893185	2	1004	0.409675	
3.074107	2	1004	0.046666		
21:00	6.557664	2	1009	0.00148	Nonlinier
	4.472792	2	1009	0.011643	
	3.727029	2	1009	0.024396	
	4.331212	2	1009	0.013397	
	1.023987	2	1009	0.359533	
	4.148688	2	1009	0.016055	
	0.20211	2	1009	0.817039	
	1.882635	2	1009	0.152723	
	7.607996	2	1009	0.000525	
0.009727	2	1009	0.990321		


**Lampiran 4. Uji White (Lanjutan)**

Jam	<i>F</i>	df1	df2	<i>P-value</i>	Keputusan
22:00	4.45873	2	1008	0.011806	Linier
	0.210631	2	1008	0.810108	
	0.649827	2	1008	0.522355	
	1.095068	2	1008	0.334914	
	0.496881	2	1008	0.608574	
	1.325485	2	1008	0.266137	
	0.369862	2	1008	0.690924	
	3.661123	2	1008	0.026046	
	3.716453	2	1008	0.024654	
	1.26878	2	1008	0.281623	
23:00	0.192842	2	1025	0.824642	Linier
	0.525712	2	1025	0.591293	
	2.707669	2	1025	0.067169	
	0.010387	2	1025	0.989667	
	5.579418	2	1025	0.00389	
	3.638786	2	1025	0.026624	
	0.740243	2	1025	0.477253	
	1.097787	2	1025	0.334001	
	2.995354	2	1025	0.050457	
	0.576564	2	1025	0.562008	
24:00	0.330914	2	1033	0.718343	Linier
	0.886998	2	1033	0.412204	
	3.328462	2	1033	0.036233	
	4.780446	2	1033	0.008579	
	1.11383	2	1033	0.328693	
	0.264411	2	1033	0.76771	
	0.534062	2	1033	0.586381	
	0.332942	2	1033	0.716888	
	3.758234	2	1033	0.023644	
0.568218	2	1033	0.566711		


**Lampiran 5.** Arsitektur DLNN Simulasi Skenario 1  
Beban 04:00




Beban 08:00




Beban 12:00



Beban 16:00




Beban 24:00







### Lampiran 6. Arsitektur DLNN Simulasi Skenario 2 Beban 04:00




### Beban 08:00




Beban 12:00




Beban 16:00




Beban 24:00




**Lampiran 7. Arsitektur DLNN Data Aktual**  
**Beban 01:00**




**Beban 02:00**




Beban 03:00




Beban 04:00




Beban 05:00




Beban 06:00




Beban 07:00




Beban 08:00



Beban 09:00




Beban 10:00







Beban 11:00




Beban 12:00




Beban 13:00




Beban 14:00




Beban 15:00




Beban 16:00




Beban 17:00




Beban 18:00




Beban 18:30




Beban 19:00




Beban 19:30




Beban 20:30




Beban 21:00




Beban 22:00



Beban 23:00




Beban 24:00






Lampiran 8. Arsitektur Hibrida ARIMAX & DLNN Simulasi Skenario 1


Beban 04:00




Beban 08:00




Beban 12:00



Beban 16:00




## Beban 24:00




**Lampiran 9.** Arsitektur Hibrida ARIMAX & DLNN Simulasi  
Skenario 2


Beban 04:00




Beban 08:00




Beban 12:00



Beban 16:00




Beban 24:00




**Lampiran 10.** Arsitektur Hibrida ARIMAX & DLNN Data Aktual

Beban 01:00




Beban 02:00









Beban 05:00




Beban 06:00




Beban 07:00




Beban 08:00




Beban 09:00




Beban 10:00




Beban 11:00




Beban 12:00




Beban 13:00




Beban 14:00




Beban 15:00




Beban 16:00




Beban 17:00




Beban 18:00



Beban 18:30




Beban 19:00







Beban 19:30




Beban 20:30




Beban 21:00




Beban 22:00



Beban 23:00



Beban 24:00



**Lampiran 11.** Perbandingan Nilai RMSE dan sMAPE Data  
*Training* Ketiga Metode pada Data Aktual

JAM	ARIMAX		DLNN		Hibrida ARIMAX & DLNN	
	RMSE	sMAPE	RMSE	sMAPE	RMSE	sMAPE
01:00	16,80	2,46	14,89	2,11	16,40	2,37
02:00	16,45	2,49	16,09	2,44	16,30	2,44
03:00	15,03	2,42	14,66	2,34	14,95	2,38
04:00	14,79	2,41	13,98	2,21	14,49	2,32
05:00	13,79	2,29	13,52	2,22	13,54	2,21
06:00	14,00	2,15	13,28	1,96	13,84	2,10
07:00	12,49	1,96	11,19	1,67	12,18	1,87
08:00	15,53	2,16	13,84	1,88	15,46	2,13
09:00	22,17	2,28	21,84	2,21	22,20	2,26
10:00	16,43	1,96	14,82	1,67	16,36	1,93
11:00	16,44	1,94	14,52	1,69	15,73	1,78
12:00	18,41	2,06	17,09	1,91	18,23	2,01
13:00	17,55	2,08	15,41	1,78	16,88	1,94
14:00	19,93	2,22	19,72	2,17	19,71	2,17
15:00	20,12	2,30	18,25	2,03	19,69	2,20
16:00	19,48	2,23	18,30	2,02	19,40	2,21
17:00	17,63	2,10	16,25	1,90	17,04	1,98
18:00	17,17	2,03	15,67	1,80	16,92	1,97
18:30	20,99	2,08	18,87	1,80	20,29	2,01
19:00	16,54	1,68	15,27	1,54	16,28	1,64
19:30	17,52	1,77	16,23	1,58	17,35	1,73
20:00	17,54	1,83	16,07	1,64	17,38	1,80
20:30	18,49	1,90	15,80	1,55	18,26	1,85
21:00	27,77	2,31	26,07	2,08	27,84	2,30
22:00	24,57	2,49	24,01	2,36	24,55	2,46
23:00	21,95	2,59	21,00	2,41	21,94	2,58
24:00	17,55	2,45	15,89	2,12	17,26	2,37

**Lampiran 12.** Perbandingan Nilai RMSE dan sMAPE Data  
*Testing* Ketiga Metode pada Data Aktual

JAM	ARIMAX		DLNN		Hibrida ARIMAX & DLNN	
	RMSEP	sMAPE	RMSEP	sMAPE	RMSEP	sMAPE
01:00	68,75	10,09	49,38	7,22	67,97	9,96
02:00	59,17	9,34	38,66	6,22	58,70	9,26
03:00	57,00	9,22	33,21	5,44	56,85	9,19
04:00	55,15	9,16	31,45	5,01	52,88	8,74
05:00	52,79	8,72	28,61	4,75	51,76	8,54
06:00	49,84	7,89	32,93	5,02	48,83	7,68
07:00	43,32	6,64	26,64	4,06	42,49	6,49
08:00	51,32	7,54	33,02	4,74	50,84	7,46
09:00	62,89	8,28	44,05	5,68	55,83	7,24
10:00	63,25	7,88	40,92	5,02	59,36	7,25
11:00	66,57	8,07	44,02	5,18	65,82	7,96
12:00	71,70	8,65	39,33	4,54	70,47	8,48
13:00	77,35	9,34	47,11	5,87	63,82	7,33
14:00	78,50	9,22	53,04	5,91	75,42	8,82
15:00	77,17	9,00	49,75	5,79	71,81	8,32
16:00	71,27	8,52	40,13	4,78	69,65	8,30
17:00	65,56	8,01	38,45	4,79	65,14	7,96
18:00	63,37	7,48	40,19	4,86	62,20	7,32
18:30	82,55	9,46	49,35	5,50	80,62	9,22
19:00	85,64	9,49	53,54	5,54	84,66	9,20
19:30	79,61	8,94	48,58	5,20	74,69	8,21
20:00	73,10	7,98	37,85	4,03	72,22	7,86
20:30	74,06	8,13	39,19	4,23	67,85	7,37
21:00	71,92	7,95	42,41	4,68	66,72	7,32
22:00	69,76	8,32	40,54	4,92	58,81	6,90
23:00	67,69	8,93	41,90	5,29	67,32	8,88
24:00	69,80	9,77	40,01	5,29	68,73	9,61

**Lampiran 13.** *Syntax* Program SAS untuk Metode ARIMAX

```

data beban2000;
input y t H1 H2 H3 H4 H5 H6 H7 I1 I2 I3 I4 I5 I6 I7 I8 I9 I10 I11 I12 I13 I14
I15 I16 I17 I18 I19 I20 I21 I22 I23 I24 I25;
datalines;
592.4 1 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
599.0 2 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
644.9 3 0 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
.
.
.
.
.
.
781.7 1094 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
797.9 1095 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
758.8 1096 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
.
.
.
.
.

```

```

.          1458      0      0      0      1      0      0
.          0          0      0      0      0      0      0
.          0          0      0      0      0      0      0
.          0          0      0      0      0      0      0
.          0          0      0      0      0      0      0
.          1459      0      0      0      0      1      0
.          0          0      0      0      0      0      0
.          0          0      0      0      0      0      0
.          0          0      0      0      0      0      0
.          0          0      0      0      0      0      0
.          1460      0      0      0      0      0      1
.          0          0      0      0      0      0      0
.          0          0      0      0      0      0      0
.          0          0      0      0      0      0      0
.          0          0      0      0      0      0      0
.          1461      0      0      0      0      0      0
.          1          0      0      0      0      0      0
.          0          0      0      0      0      0      0
.          0          0      0      0      0      0      0
.          0          0      0      0      0      0      0
;
proc arima data = beban2000;
identify var=y(0) crosscorr=(t H1 H2 H3 H4 H5 H6 H7 I1 I2 I3 I4 I5 I6 I7 I8 I9
I10 I11 I12 I13 I14 I15 I16 I17 I18 I19 I20 I21 I22 I23 I24 I25) nlag=48;
run;

estimate p=(1,2,7) q=(0) input=(t H1 H2 H3 H4 H5 H6 H7 I1 I2 I3 I4 I5 I6 I7 I8
I9 I10 I11 I12 I13 I14 I15 I16 I17 I18 I19 I20 I21 I22 I23 I24 I25) noconstant
method=cls;
forecast out = beban2000 lead=365 printall;
run;

proc univariate data=beban2000 normal;
var residual;
run;

proc export data=work.beban2000
outfile='D:/output SAS/DATAASLIbeban2000.xls'
dbms=excel
replace;
run;

```

**Lampiran 14.** *Syntax* Program R untuk Metode DLNN

```

install.packages("neuralnet")
install.packages("tseries")
install.packages("forecast")

library(neuralnet)
library(tseries)
library(forecast)

x<-read.csv("D://TA/DATA/BEBAN2000.csv",header = TRUE,sep=",")
zt<-as.ts(x)
ztrain<-as.ts(zt[1:1096,])
ztest<-as.ts(zt[1097:1461,])

z1t.std<-(ztrain[,1]-min(ztrain[,1]))/(max(ztrain[,1])-min(ztrain[,1]))

lagz1<-c(1,3,4,5,6,7,9,10,13,14,15,17,20,29,34,43)
maxlag<-max(lagz1)
laginput<-matrix(NA,(length(z1t.std)-maxlag),length(lagz1))

for (j in 1:length(lagz1))
{
  laginput[,j]<-z1t.std[(maxlag-lagz1[j]+1):(length(z1t.std)-lagz1[j])]
}
head(laginput)

BEBAN2000<-
data.frame(cbind(z1t.std[(maxlag+1):length(z1t.std)],laginput,zt[(maxlag+1):length(z1t.std),-1]))
head(BEBAN2000)

h1<-c(1,2,3,4,5)
h2<-c(1,2,3,4,5)
neuron<-cbind(rep(h1,times=length(h2)),rep(h2,each=length(h1)))
n_fore=365
dummy1<-rbind((zt[(maxlag+1):length(z1t.std),-1]),ztest[,-1])

koef=list()
bestmodel=list()
fitsmodel=list()
foremodel=list()
akurasi=list()

for (k in seq_along(neuron[,1]))
{
  set.seed(k)

```



```

best.model<-
neuralnet(BEBAN2000[,1]~BEBAN2000[,2]+BEBAN2000[,3]+BEBAN2000[,4]+
  BEBAN2000[,5]+BEBAN2000[,6]+BEBAN2000[,7]+
  BEBAN2000[,8]+ BEBAN2000[,9]+BEBAN2000[,10]+
  BEBAN2000[,11]+BEBAN2000[,12]+BEBAN2000[,13]+
  BEBAN2000[,14]+BEBAN2000[,15]+BEBAN2000[,16]+
  BEBAN2000[,17])+t+H1+H2+H3+H4+H5+H6+H7+I1+I2+I3+
  I4+I5+I6+I7+I8+I9+I10+I11+I12+I13+I14+I15+I16+I17+I18+
  I19+I20+I21+I22+I23+I24+I25,data=BEBAN2000,hidden=neuron[k,],
  stepmax = 1e+08, rep=10,act.fct="logistic",linear.output =
  TRUE,likelihood=TRUE)

plot(best.model, rep="best")
mypath <- file.path("D://TA/plot",paste("BEBAN2000", (k), ".jpg", sep = ""))
png(file=mypath)
plot(best.model, rep="best")
dev.off()

koef[[k]]<-best.model$weights[which.min(best.model$result.matrix[1,])]

ytest<-c(BEBAN2000[,1],rep(0,n_fore))
for (l in ((length(BEBAN2000[,1])+1):(length(BEBAN2000[,1])+n_fore)))
{
  dummytest<-t(as.matrix(dummy1[l,]))
  lagtest<-matrix(0,1,length(lagz1))
  for (m in 1:length(lagz1))
  {
    lagtest[[m]]<-ytest[(l-lagz1[m])]
  }
  inputTest<-cbind(lagtest,dummytest)
  ytest[l]<-compute(best.model,covariate=inputTest,rep
  which.min(best.model$result.matrix[1,]))$net.result
}

fits.model<-
unlist(best.model$net.result[which.min(best.model$result.matrix[1,])])*(max(ztrain[,
1])-min(ztrain[,1]))+min(ztrain[,1])
NtTrain<-(BEBAN2000[,1]*(max(ztrain[,1])-min(ztrain[,1]))+min(ztrain[,1]))-
(unlist(best.model$net.result[which.min(best.model$result.matrix[1,])])*(max(ztrain[,
1])-min(ztrain[,1]))+min(ztrain[,1])))
avgNtTrain<-((abs(BEBAN2000[,1]*(max(ztrain[,1])-
min(ztrain[,1]))+min(ztrain[,1]))+abs(unlist(best.model$net.result)*(max(ztrain[,1])-
min(ztrain[,1]))+min(ztrain[,1]))))/2
RMSETrain<-((sum(NtTrain^2)/length(NtTrain))^(1/2)

sMAPE1<-c()
for (p1 in 1:length(NtTrain)){
  sMAPE1[p1]<-(1/length(NtTrain))*abs(NtTrain[p1])/avgNtTrain[p1]
}

```

```

}
sMAPETrain<-sum(sMAPE1)*100

fore.model<-
ytest[(length(BEBAN2000[,1])+1):(length(BEBAN2000[,1])+n_fore)]*(max(ztrain[,
1])-min(ztrain[,1]))+min(ztrain[,1])
NtTest<-ztest[,1]-
(ytest[(length(BEBAN2000[,1])+1):(length(BEBAN2000[,1])+n_fore)]*(max(ztrain[
,1])-min(ztrain[,1]))+min(ztrain[,1]))
avgNtTest<-
(abs(ztest[,1])+abs(ytest[(length(BEBAN2000[,1])+1):(length(BEBAN2000[,1])+n_f
ore)]*(max(ztrain[,1])-min(ztrain[,1]))+min(ztrain[,1]))))/2
RMSETest<-((sum(NtTest^2))/length(NtTest))^(1/2)

sMAPE2<-c()
for (p2 in 1:length(NtTest)){
  sMAPE2[p2]<-(1/length(NtTest))*abs(NtTest[p2])/(avgNtTest[p2])
}
sMAPETest<-sum(sMAPE2)*100

fitsmodel[[k]]<-fits.model
foremodel[[k]]<-fore.model
akurasi[[k]]<-rbind(RMSETrain,RMSETest,sMAPETrain,sMAPETest)
}

write.csv(akurasi,"D://TA/OUTPUTNEW/akurasi2000.csv")
write.csv(fitsmodel,"D://TA/OUTPUTNEW/fitsBEBAN2000.csv")
write.csv(foremodel,"D://TA/OUTPUTNEW/fore2000.csv")
saveRDS(koef,file="D://TA/KOEF/koef2000.rds")

```

## Lampiran 15. *Syntax* Program R untuk Metode Hibrida ARIMAX-DLNN

```

install.packages("neuralnet")
install.packages("tseries")
install.packages("forecast")

library(neuralnet)
library(tseries)
library(forecast)

x<-read.csv("D://TA/DATA/HYBRIDBEBAN2000.csv",header = TRUE,sep=',')
zt<-as.ts(x)
ztrain<-as.ts(zt[1:1096,])
ztest<-as.ts(zt[1097:1461,])
at.train<-ztrain[,1]-ztrain[,2]

at.norm<-(at.train-min(at.train))/(max(at.train)-min(at.train))

lagz<-c(1,2,7)
maxlag<-max(lagz)
laginput<-matrix(NA,(length(at.norm)-maxlag),length(lagz))
for (j in 1:length(lagz))
{
  laginput[,j]<-at.norm[(maxlag-lagz[j]+1):(length(at.norm)-lagz[j])]
}
head(laginput)

BEBAN2000<-
data.frame(cbind(at.norm[(maxlag+1):length(at.norm)],laginput,zt[(maxlag+1):length
(at.norm),(3:dim(zt)[2]))))
head(BEBAN2000)

h1<-c(1,2,3,4,5)
h2<-c(1,2,3,4,5)
n_fore=365
neuron<-cbind(rep(h1,times=length(h2)),rep(h2,each=length(h1)))
dummy<-
rbind((zt[(maxlag+1):length(at.norm),(3:dim(zt)[2])]),ztest[(3:dim(ztest)[2])])

koef=list()
bestmodel=list()
fitsmodel=list()
foremodel=list()
akurasi=list()

```

```

for (k in seq_along(neuron[,1]))
{
  set.seed(k)
  best.model<-neuralnet(BEBAN2000[,1]~BEBAN2000[,2]+ BEBAN2000[,3]+
    BEBAN2000[,4]+t+H1+H2+H3+H4+H5+H6+H7+I1+I2+
    I3+I4+I5+I6+I7+I8+I9+I10+I11+I12+I13+I14+I15+I16+
    I17+I18+I19+I20+I21+I22+I23+I24+I25,
    data=BEBAN2000,hidden=neuron[k,],
    stepmax = 1e+08,rep=10,act.fct="logistic",linear.output = TRUE,
    likelihood=TRUE)

  plot(best.model, rep="best")
  koef[[k]]<-best.model$weights[which.min(best.model$result.matrix[1,])]
  plot2000<-file.path("D://TA/plotnew", paste("HYBRID2000",(k),".jpg",sep=""))
  png(file=plot2000)
  plot(best.model, rep="best")
  dev.off()

  ytest<-c(BEBAN2000[,1],rep(0,n_fore))
  for (l in ((length(BEBAN2000[,1])+1):(length(BEBAN2000[,1])+n_fore)))
  {
    dummytest<-t(as.matrix(dummy[1,]))
    lagtest<-matrix(0,1,length(lagz))
    for (m in 1:length(lagz))
    {
      lagtest[[m]]<-ytest[(l-lagz[m])]
    }
    inputTest<-cbind(lagtest,dummytest)
    ytest[l]<-compute(best.model,covariate=inputTest,rep
    which.min(best.model$result.matrix[1,]))$net.result
  }
  fits.model<-
  unlist(best.model$net.result[which.min(best.model$result.matrix[1,])]*(max(at.train)
  -min(at.train))+min(at.train)
  fits.ARIMAX_DNN<-
  ztrain[(maxlag+1):length(ztrain[,1]),2]+unlist(best.model$net.result)*(max(at.train)-
  min(at.train))+min(at.train)
  NtTrain<-(ztrain[(maxlag+1):length(ztrain[,1]),1])-
  (ztrain[(maxlag+1):length(ztrain[,1]),2]+(unlist(best.model$net.result)*(max(at.train)
  -min(at.train))+min(at.train))))
  avgNtTrain<-
  (abs((ztrain[(maxlag+1):length(ztrain[,1]),1]))+abs((ztrain[(maxlag+1):length(ztrain[,
  1]),2]+(unlist(best.model$net.result)*(max(at.train)-
  min(at.train))+min(at.train)))))))/2
  RMSETrain<-((sum(NtTrain^2))/length(NtTrain))^(1/2)

```

```

sMAPE1<-c()

for (p1 in 1:length(NtTrain)){
  sMAPE1[p1]<-(1/length(NtTrain))*abs(NtTrain[p1])/avgNtTrain[p1]
}
sMAPETrain<-sum(sMAPE1)*100

fore.model<-
ytest[(length(BEBAN2000[,1])+1):(length(BEBAN2000[,1])+n_fore)]*(max(at.train)
-min(at.train))+min(at.train)
fore.ARIMAX_DNN<-
ztest[,2]+ytest[(length(BEBAN2000[,1])+1):(length(BEBAN2000[,1])+n_fore)]*(ma
x(at.train)-min(at.train))+min(at.train)
NtTest<-ztest[,1]-
(ztest[,2]+ytest[(length(BEBAN2000[,1])+1):(length(BEBAN2000[,1])+n_fore)]*(ma
x(at.train)-min(at.train))+min(at.train))
avgNtTest<-
(abs(ztest[,1])+abs((ztest[,2]+ytest[(length(BEBAN2000[,1])+1):(length(BEBAN200
0[,1])+n_fore)]*(max(at.train)-min(at.train))+min(at.train))))/2
RMSETest<-((sum(NtTest^2)/length(NtTest))^(1/2)

sMAPE2<-c()
for (p2 in 1:length(NtTest)){
  sMAPE2[p2]<-(1/length(NtTest))*abs(NtTest[p2])/avgNtTest[p2]
}
sMAPETest<-sum(sMAPE2)*100

fitsmodel[[k]]<-fits.ARIMAX_DNN
foremodel[[k]]<-fore.ARIMAX_DNN
akurasi[[k]]<-rbind(RMSETrain,RMSETest,sMAPETrain,sMAPETest)
}

write.csv(akurasi,"D://TA/OUTPUTNEWHYBRID/akurasi2000.csv")
write.csv(fitsmodel,"D://TA/OUTPUTNEWHYBRID/fits2000E.csv")
write.csv(foremodel,"D://TA/OUTPUTNEWHYBRID/fore2000.csv")
koef
saveRDS(koef, file="D://TA/KOEFNEW/koefHYBRID2000.rds")

```

**Lampiran 16.** *Syntax* Program R untuk Uji *White*

```

library(tseries)
x <- read.csv("D://TA/DATA/dataasli.csv",head=TRUE, sep = ",")
dummy<-read.csv("D://TA/DATA/dummyfile.csv",head=TRUE, sep = ",")
#Uji White Pada BEBAN2000#
dm<-as.ts(dummy)
zt<-as.ts(x)
Z2000<-zt[,22]
lagz2000<-c(1,3,4,5,6,7,9,10,13,14,15,17,20,29,34,43)
maxlag<-max(lagz2000)
laginputZ2000<-matrix(NA,(length(Z2000)-maxlag),length(lagz2000))
for (j in 1:length(lagz2000)){
  laginputZ2000[,j]<-Z2000[(maxlag-lagz2000[j]+1):(length(Z2000)-lagz2000[j])]
  head(laginputZ2000)

  BEBAN2000<-
  data.frame(cbind(Z2000[(maxlag+1):length(Z2000)],laginputZ2000,dm[(maxlag+1):l
  ength(Z2000),]))
  head(BEBAN2000)

  ujiZ2000=list()
  statuji.Z2000<-c()
  p.Z2000<-c()

  for (i in 1:10)
  {
    ujiZ2000[[i]]<-white.test(BEBAN2000[,-1],BEBAN2000[,1],type="F")
    statuji.Z2000[i]<-ujiZ2000[[i]]$statistic
    p.Z2000[i]<-ujiZ2000[[i]]$p.value
  }
  hasilZ2000<-cbind(statuji.Z2000,p.Z2000)
  par2000<-ujiZ2000[[i]]$parameter
  par2000

```

## Lampiran 17. Surat Keterangan Pengambilan Data

### SURAT KETERANGAN

Saya yang bertanda tangan di bawah ini menerangkan bahwa :

1. Mahasiswa Statistika FMKSD-ITS dengan identitas berikut :

Nama : Kadek Ayu Krisnawati

NRP : 0621144000052

Telah mengambil data di instansi/perusahaan kami :

Nama Instansi : PT. Indonesia Power UP Bali

Divisi/ bagian : Pengendali Operasi dan Niaga (PON)

sejak tanggal 17 Desember 2017 sampai dengan 18 Maret 2018 untuk keperluan

Tugas Akhir/ ~~Thesis Semester Gasal/Genap~~\* 2017/ 2018.

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.

Denpasar, 8 Januari 2018

Manajer Operasi dan Pemeliharaan



(I Wayan Suda)  
NIP. 6989018JA

\*(coret yang tidak perlu)

*(Halaman ini sengaja dikosongkan)*



## BIODATA PENULIS



Kadek Ayu Krisnawati, lahir di Singaraja, 8 Maret 1996, anak kedua dari pasangan I Wayan Aryana dan Ketut Suastini. Pendidikan formal penulis di TK Negeri Singaraja, SD Negeri 4 Kaliuntu, SMP Negeri 2 Singaraja, SMA Negeri 1 Singaraja hingga diterima S1 Statistika ITS pada tahun 2014 melalui jalur SNMPTN Undangan dengan NRP 06211440000052. Selama duduk di bangku kuliah, penulis aktif di TPKH ITS serta HIMASTA ITS. Pada saat aktif di TPKH ITS, penulis menjabat sebagai Staff Komunikasi dan Informasi pada tahun 2015 dan Sekretaris Departemen Media Kreatif pada tahun 2016. Pada organisasi HIMASTA ITS, penulis menjabat sebagai Staff Kewirausahaan pada tahun 2015. Penulis pernah melakukan kerja praktik di PT. Indonesia Power UP Bali tahun 2017. Apabila ada kritik, saran atau pertanyaan terkait Tugas Akhir ini, bisa menghubungi penulis melalui email [ayukrisnawati88@gmail.com](mailto:ayukrisnawati88@gmail.com).

*(Halaman ini sengaja dikosongkan)*