



## TUGAS AKHIR - KS141501

PERAMALAN JUMLAH PENUMPANG PENERBANGAN DI  
TERMINAL 1 BANDARA INTERNASIONAL JUANDA  
MENGUNAKAN METODE ARIMA BOX-JENKINS DAN HYBRID  
AUTOREGRESSIVE INTEGRATED MOVING AVERAGE-  
ARTIFICIAL NEURAL NETWORK (ARIMA-ANN)

*PASSENGERS OF DOMESTIC AIRLINES FORECASTING IN  
JUANDA INTERNATIONAL AIRPORT USING ARIMA BOX-  
JENKINS AND HYBRID ARIMA-ANN METHOD*

PRAMITA LUCIANNA PUTRI SUPRIYANTO  
NRP 5213 100 186

Dosen Pembimbing  
Wiwik Anggraeni, S.Si., M. Kom.

DEPARTEMEN SISTEM INFORMASI  
Fakultas Teknologi Informasi  
Institut Teknologi Sepuluh Nopember  
Surabaya 2017



**TUGAS AKHIR - KS141501**

**PERAMALAN JUMLAH PENUMPANG PENERBANGAN DI  
TERMINAL 1 BANDARA INTERNASIONAL JUANDA  
MENGUNAKAN METODE ARIMA BOX-JENKINS DAN  
HYBRID AUTOREGRESSIVE INTEGRATED MOVING  
AVERAGE-ARTIFICIAL NEURAL NETWORK (ARIMA-ANN)**

**PRAMITA LUCIANNA PUTRI SUPRIYANTO**

**NRP 5213 100 186**

**Dosen Pembimbing**

**Wiwik Anggraeni, S.Si., M. Kom.**

**DEPARTEMEN SISTEM INFORMASI**

**Fakultas Teknologi Informasi**

**Institut Teknologi Sepuluh Nopember**

**Surabaya 2017**



**LEMBAR PENGESAHAN**

**PERAMALAN JUMLAH PENUMPANG PENERBANGAN DI  
TERMINAL 1 BANDARA INTERNASIONAL JUANDA  
MENGUNAKAN METODE ARIMA BOX-JENKINS DAN  
HYBRID AUTOREGRESSIVE INTEGRATED MOVING  
AVERAGE-ARTIFICIAL NEURAL NETWORK (ARIMA-ANN)  
TUGAS AKHIR**

Disusun Untuk Memenuhi Salah Satu Syarat  
Memperoleh Gelar Sarjana Komputer  
Pada

Departemen Sistem Informasi  
Fakultas Teknologi Informasi  
Institut Teknologi Sepuluh Nopember

Oleh:

**PRAMITA LUCIANNA PUTRI SUPRIYANTO**

NRP. 5213100186

Surabaya, Juli 2017

**KEPALA**

**DEPARTEMEN SISTEM INFORMASI**

**Dr. Ir. Aris Trihyanto, M.Kom.**

**SIS NIP. 19650310199102001**



**LEMBAR PERSETUJUAN**

**PERAMALAN JUMLAH PENUMPANG PENERBANGAN DI  
TERMINAL 1 BANDARA INTERNASIONAL JUANDA  
MENGUNAKAN METODE ARIMA BOX-JENKINS DAN  
HYBRID AUTOREGRESSIVE INTEGRATED MOVING  
AVERAGE-ARTIFICIAL NEURAL NETWORK (ARIMA-ANN)  
TUGAS AKHIR**

Disusun Untuk Memenuhi Salah Satu Syarat  
Memperoleh Gelar Sarjana Komputer

Pada  
Departemen Sistem Informasi  
Fakultas Teknologi Informasi

Institut Teknologi Sepuluh Nopember

Oleh:

**PRAMITA LUCIANNA PUTRI SUPRIYANTO**

NRP. 5213100186


Disetujui Tim Penguji: Tanggal Ujian: Juli 2017

Periode Wisuda: September 2017


**Wiwik Angracni, S.Si., M. Kom.**

  
(Pembimbing I)

**Edwin Riksakomara, S.Kom., M.T.**

  
(Penguji I)

**Ahmad Mukhlason, S.Kom., M.Sc.**

  
(Penguji II)







**PERAMALAN JUMLAH PENUMPANG  
PENERBANGAN DI TERMINAL 1 BANDARA  
INTERNASIONAL JUANDA MENGGUNAKAN  
METODE ARIMA BOX-JENKINS DAN HYBRID  
AUTOREGRESSIVE INTEGRATED MOVING  
AVERAGE-ARTIFICIAL NEURAL NETWORK  
(ARIMA-ANN)**

**Nama Mahasiswa : Pramita Lucianna Putri Supriyanto**

**NRP : 5213 100 186**

**Jurusan : Sistem Informasi FTIF-ITS**

**Dosen Pembimbing : Wiwik Anggraeni, S.Si., M. Kom.**

**ABSTRAK**

*Transportasi udara merupakan sarana transportasi yang dapat digunakan untuk menghubungkan antar wilayah dengan berbagai macam kepentingan di antar pulau bahkan antar negara dengan jarak yang jauh sekalipun dapat ditempuh dengan waktu yang relatif singkat. Bandara Internasional Juanda merupakan salah satu bandara yang tersibuk ke-2 setelah Bandara Internasional Soekarno-Hatta. Bandara Internasional Juanda memiliki jumlah penumpang yang banyak baik yang berangkat maupun yang datang. Oleh karena itu PT Angkasa Pura I Juanda memiliki dinas SIMTAPOR yang bertugas sebagai memprediksikan berapa jumlah penumpang yang akan berangkat dan datang melalui pintu-pintu di Bandara Internasional Juanda. Selain untuk memperlancar proses bisnis di dalam Bandara Internasional Juanda agar tidak mengalami penumpukan penumpang, fasilitas juga*

*menunjang keberhasilan dari kenyamanan yang diberikan oleh pihak Bandara Internasional Juanda*

*Dalam menyelesaikan permasalahan meramalkan jumlah penumpang penerbangan domestic pada terminal 1 untuk yang akan datang, dilakukan menggunakan dua metode, yaitu penyelesaian menggunakan metode ARIMA dan hybrid Autoregressive Integrated Moving Average-Artificial Neural Network (ARIMA-ANN). Dimana hasil peramalan dapat dijadikan acuan untuk mengatur strategi bisnis yang tepat. Pada penelitian ini, digunakan metode ARIMA dan hybrid ARIMA-ANN. Hasil akhir yang telah dibandingkan menunjukkan jika dengan menggunakan metode hybrid ARIMA-ANN, menunjukkan nilai akurasi yang baik. Model yang digunakan untuk meramalkan data penumpang kedatangan dan keberangkatan pada penelitian ini memiliki masing-masing nilai MAPE sebesar 7,33% dan 4,13%. Hal tersebut menunjukkan bahwa model yang dihasilkan memiliki hasil peramalan yang sangat baik. Penelitian tugas akhir ini diharapkan dapat menjadi salah satu elemen pendukung keputusan terkait tentang penjualan oleh perusahaan.*

***Kata Kunci:*** *Penumpang, Pesawat, Peramalan, ARIMA, Hybrid ARIMA-ANN, Backpropagation, MAPE.*

**PERAMALAN JUMLAH PENUMPANG  
PENERBANGAN DI TERMINAL 1 BANDARA  
INTERNASIONAL JUANDA MENGGUNAKAN  
METODE ARIMA BOX-JENKINS DAN HYBRID  
AUTOREGRESSIVE INTEGRATED MOVING  
AVERAGE-ARTIFICIAL NEURAL NETWORK  
(ARIMA-ANN)**

**Nama Mahasiswa : Pramita Lucianna Putri Supriyanto**

**NRP : 5213 100 186**

**Jurusan : Sistem Informasi FTIF-ITS**

**Dosen Pembimbing : Wiwik Anggraeni, S.Si., M. Kom.**

**ABSTRACT**

*Air transport is a means of transport that can be used to connect the region with a wide range of interests in the interisland even between countries with long distances even if it is a relative short time. Juanda international airport is one of the busiest airports in the 2nd after Soekarno-Hatta International Airport. Juanda international airport has a lot of good number of passengers who depart or arrive. Therefore P.T Juanda Angkasa Pura I has a SIMTAPOR Department serving as the number of passengers predicted how leaving and coming through the doors at Juanda international airport. In addition to streamline business processes within the Juanda international airport in order not to experience a buildup of passengers, also support the success of the comfort provided by the Juanda international airport.*

*In resolving the problem of predicting the number of domestic flight passengers at terminal 1 for that will come, done using two methods, namely the completion method using ARIMA and Autoregressive Hybrid Integrated Moving Average - Artificial Neural Network (ARIMA-ANN). Forecasting result referable to set the right business strategy. In this research, used the method of ARIMA and hybrid ARIMA-ANN. The end result has been compared to show if using hybrid ARIMA-ANN, demonstrates the value of a good accuracy. Models used to predict the passenger arrival and departure data on this research have each value of the MAPE of 7.33% and 4.13%. It is shown that the resulting model has very good results of forecasting. Research thesis is expected to be one of the elements of the related decision support on the sale by the company.*

**Keywords:** *Passengers, Airplane, Forecasting, ARIMA, Hybrid ARIMA-ANN, Backpropagation, MAPE.*

## KATA PENGANTAR

Alhamdulillah, puji syukur kehadiran Allah SWT atas limpahan karunia, rahmat, serta barokah yang diberikan-Nya selama ini sehingga penulis dapat menyelesaikan tugas akhir yang berjudul **Peramalan Jumlah Penumpang Penerbangan di Terminal 1 Bandara Internasional Juanda Menggunakan Metode Arima Box-Jenkins dan Hybrid Autoregressive Integrated Moving Average-Artificial Neural Network (Arima-ANN)**. Terima kasih kepada pihak-pihak yang telah mendukung, memberikan saran, motivasi, bantuan baik materi maupun spiritual demi tercapainya tujuan pembuatan tugas akhir ini. Secara khusus, penulis akan menyampaikan terima kasih banyak kepada:

1. Papa (Agus), Mama (Annik), kakak (Prastya) penulis yang tiada henti memberikan dukungan dan semangat.
2. Ibu Hanim Maria Astuti, S.Kom., M.Sc. selaku dosen wali penulis yang senantiasa membimbing saya dari awal perkuliahan hingga akhir kuliah.
3. Ibu Wiwik Anggraeni, S.Si., M.Kom. selaku dosen pembimbing pertama penulis yang senantiasa meluangkan waktu, memberikan ilmu serta petunjuk dan memotivasi untuk kelancaran tugas akhir ini.
4. Bapak Erwin Riksakomara, S.Kom., M.T. dan Bapak Ahmad Muklason, S.Kom., M.Sc., selaku dosen penguji yang telah memberikan saran dan kritik untuk perbaikan tugas akhir.
5. Seluruh dosen Jurusan Sistem Informasi ITS yang telah memberikan ilmu yang bermanfaat kepada penulis.
6. Marina Safitri, Shania Olivia, Delina Rahayu, Provani Winda, Stezar Priansya, Chandra Surya, Ikhwan Aziz, M. Fahmi, Nadya Chandra, Caesar Gilang, Rani Oktavia, Bintang Setyawan yang telah mendukung dan menemani penulis dari masa mahasiswa baru hingga tugas akhir ini dapat diselesaikan.

7. Teman-teman RDIB dan ADDI yang telah memberi naungan pada penulis untuk menyelesaikan tugas akhir ini.
8. Joshua Satriawan selaku orang terdekat penulis yang selalu memberikan dukungan, hiburan dan doa kepada penulis.
9. Rekan-rekan BELTRANIS yang telah memberikan banyak kenangan manis dan pahit semasa kuliah.
10. Berbagai pihak yang tidak bisa disebutkan satu persatu yang telah turut serta menyukseskan penulis dalam menyelesaikan tugas akhir.

Penyusunan laporan ini masih jauh dari kata sempurna sehingga penulis menerima adanya kritik maupun saran yang membangun untuk perbaikan di masa yang akan datang. Semoga buku tugas akhir ini dapat memberikan manfaat bagi pembaca.

Surabaya, 10 April 2017  
Penulis,

Pramita Lucianna Putri  
Supriyanto

## DAFTAR ISI

LEMBAR PENGESAHAN....	<b>Error! Bookmark not defined.</b>
LEMBAR PERSETUJUAN...	<b>Error! Bookmark not defined.</b>
ABSTRAK .....	vi
KATA PENGANTAR .....	x
DAFTAR ISI.....	xii
DAFTAR GAMBAR .....	xvi
DAFTAR TABEL .....	xx
BAB I PENDAHULUAN .....	1
1.1. Latar Belakang .....	1
1.2. Perumusan Masalah.....	6
1.3. Batasan Masalah.....	6
1.4. Tujuan Penelitian.....	7
1.5. Manfaat Penelitian.....	7
1.6. Relevansi.....	8
BAB II TINJAUAN PUSTAKA .....	11
2.1. Penelitian Terdahulu.....	11
2.2. Dasar Teori .....	15
2.2.1. Konsep Peramalan .....	15
2.2.2. Metode ARIMA.....	19
2.2.3. Neural Network .....	24
2.2.6. Uji Performance Model Peramalan.....	31
2.2.7. Hybrid (ARIMA-ANN) .....	32
BAB III METODOLOGI.....	35
3.1 Studi Literatur.....	36
3.2. Persiapan Data.....	36



3.3.	Proses Analisis Model ARIMA.....	37
3.3.1.	Analisa Data .....	37
3.3.2.	Uji Stasioner Data.....	37
3.3.3.	Pemodelan ARIMA .....	37
3.3.4.	Forecasting .....	38
3.4.	Model Penelitian dengan ANN .....	38
3.5.	Metode Hybrid (ARIMA-ANN).....	40
3.6.	Analisa Hasil Peramalan .....	40
3.7.	Penyusunan Tugas Akhir .....	40
BAB IV PERANCANGAN .....		43
4.1.	Persiapan Data.....	43
4.1.1.	Pengumpulan Data.....	43
4.1.2.	Pra-proses Data.....	44
4.1.3.	Menentukan Data Pelatihan dan Pengujian ....	44
4.2.	Metode Penelitian dengan ARIMA .....	44
4.2.1.	Gambaran Data Masukan .....	44
4.2.2.	Uji Stasioner Ragam .....	46
4.2.3.	Transformasi Data.....	46
4.2.4.	Uji Stasioner Rataan.....	46
4.2.5.	Differencing Data .....	47
4.2.6.	Pemodelan ARIMA .....	47
4.2.7.	Peramalan Penumpang Domestik .....	49
4.2.8.	Ketepatan Model Peramalan.....	49
4.3.	Metode Hybrid ARIMA-ANN .....	49
4.3.1.	Pra-Proses Data.....	50

4.3.2.	Perancangan Model ANN .....	50
4.3.3.	Peramalan Penumpang Domestik .....	51
4.3.4.	Ketepatan Model Peramalan .....	51
<b>BAB V IMPLEMENTASI.....</b>		<b>53</b>
5.1.	Implementasi Model ARIMA .....	53
5.1.1.	Pengujian Outlier .....	53
5.1.2.	Menentukan Data Pelatihan dan Data Pengujian 54	
5.1.3.	Uji Stasioneritas Ragam.....	54
5.1.4.	Transformasi Data .....	55
5.1.5.	Uji Stasioneritas Rataan .....	56
5.5.1.	Differencing Data .....	57
5.5.2.	Pemodelan ARIMA .....	59
5.2.	Implementasi Model Hybrid ARIMA-ANN.....	72
5.2.1.	Pemrosesan Data.....	72
5.2.2.	Validation .....	76
5.2.3.	Normalisasi Data .....	76
5.2.4.	Pembentukan Artificial Neural Network.....	77
5.2.5.	Penentuan Parameter Artificial Neural Network 78	
5.2.6.	Penerapan Model Artificial Neural Network..	78
5.2.7.	Denormalisasi Data Pelatihan.....	78
5.2.8.	Pengujian.....	78
5.2.9.	Peramalan Periode Kedepan.....	79
<b>BAB VI HASIL DAN PEMBAHASAN .....</b>		<b>81</b>
6.1.	Hasil Uji Coba Model.....	81

6.2.	Hasil Validasi Model .....	84
6.2.1.	Hasil Validasi Pertama Model .....	84
6.2.2.	Hasil Validasi Kedua Model.....	87
6.3.	Analisis Hasil Peramalan .....	89
6.3.1.	Uji Coba Parameter Model ANN.....	89
6.3.2.	Hasil Pengujian.....	92
6.4.	Analisis Hasil Peramalan .....	95
BAB VII KESIMPULAN DAN SARAN .....		101
7.1.	Kesimpulan .....	101
7.2.	Saran .....	102
DAFTAR PUSTAKA .....		105
BIODATA PENULIS .....		111
LAMPIRAN A DATA MENTAH.....		113
LAMPIRAN B UJI SIGNIFIKANSI PARAMETER.....		117
LAMPIRAN C UJI DIAGNOSTIK PARAMETER.....		131
LAMPIRAN D HASIL PERAMALAN MODEL ARIMA .		143
LAMPIRAN E NILAI RESIDUAL ARIMA (INPUT ANN) .....		151

## DAFTAR GAMBAR

Gambar 2. 1 Diagram klasifikasi teknik peramalan (Mukhyi, 2008).....	16
Gambar 2. 2 Ilustrasi Neuron Tiruan .....	25
Gambar 2. 3 Arsitektur Multilayer Neural Network (Fauset, 1994).....	27
Gambar 5. 1 Hasil Uji Outlier Data Penumpang Kedatangan Menggunakan Grubb's.....	53
Gambar 5. 2 Uji Outlier Jumlah Penumpang Keberangkatan Bandara Juanda Menggunakan Grubb's .....	53
Gambar 5. 3 Uji Stasioneritas Ragam pada Data Penumpang Kedatangan.....	54
Gambar 5. 4 Uji Stasioneritas Ragam pada Data Penumpang Keberangkatan.....	55
Gambar 5. 5 Transformasi Jumlah Penumpang Kedatangan .	56
Gambar 5. 6 Transformasi Jumlah Penumpang Keberangkatan .....	56
Gambar 5. 7 Uji Stasioneritas Rataan Jumlah Penumpang Kedatangan.....	56
Gambar 5. 8 Uji Stasioneritas Rataan Jumlah Penumpang Keberangkatan.....	57
Gambar 5. 9 Uji Stasioner Rataan Differencing 1 Jumlah Penumpang Kedatangan.....	58
Gambar 5. 10 Uji Stasioner Rataan Differencing 2 Jumlah Penumpang Kedatangan.....	58
Gambar 5. 11 Uji Stasioner Rataan Differencing 2 Jumlah Penumpang Keberangkatan.....	59
Gambar 5. 12 Estimasi Parameter ARIMA Data Jumlah Penumpang Kedatangan, $d=1$ .....	60
Gambar 5. 13 Estimasi Parameter ARIMA Data Jumlah Penumpang Kedatangan, $d=2$ .....	61

Gambar 5. 14 Estimasi Parameter ARMA Data Jumlah Penumpang Kedatangan.....	62
Gambar 5. 15 Estimasi Parameter ARIMA Data Jumlah Penumpang Keberangkatan, $d=2$ .....	63
Gambar 5. 16 Uji Signifikansi ARIMA (0,1,1).....	64
Gambar 5. 17 Uji Diagnostik (Keacakan Sisaan) ARIMA (0,1,1).....	68
Gambar 5. 18 Uji Diagnostik (Homogenitas) ARIMA (0,1,1).....	68
Gambar 5. 19 Operator Read Excel.....	75
Gambar 5. 20 Operator Set Role.....	75
Gambar 5. 21 Operator Windowing.....	76
Gambar 5. 22 Operator Validation.....	76
Gambar 5. 23 Operator Neural Net.....	77
Gambar 5. 24 Parameter Normalize.....	77
Gambar 5. 25 Parameter Hidden Layer.....	77
Gambar 5. 26 Parameter Jaringan pada Operator Neural Net	78
Gambar 5. 27 Operator Apply Model.....	78
Gambar 5. 28 Operator Write Excel.....	79
Gambar 6. 1 Hasil Peramalan Data Training Menggunakan Model ARIMA (0,1,1).....	82
Gambar 6. 2 Hasil Peramalan Data Training Menggunakan Model ARIMA (1,1,0).....	82
Gambar 6. 3 Hasil Peramalan Model Data Jumlah Penumpang Keberangkatan.....	83
Gambar 6. 4 Hasil Peramalan Validasi Pertama Menggunakan Model ARIMA (0,1,1).....	85
Gambar 6. 5 Hasil Peramalan Validasi Pertama Menggunakan Model ARIMA (1,1,0).....	85
Gambar 6. 6 Hasil Peramalan Validasi Pertama Menggunakan Model ARMA (1,1).....	86
Gambar 6. 7 Hasil Peramalan Validasi Kedua Menggunakan Model ARIMA (0,1,1).....	87

Gambar 6. 8 Hasil Peramalan Validasi Kedua Menggunakan Model ARIMA (1,1,0) .....	88
Gambar 6. 9 Hasil Peramalan Validasi Kedua Menggunakan Model ARMA (1,1) .....	89
Gambar 6. 10 Uji Coba Parameter Model ANN Data Jumlah Penumpang Kedatangan.....	90
Gambar 6. 11 Uji Coba Parameter Model ANN Data Jumlah Penumpang Keberangkatan.....	92
Gambar 6. 12 Hasil Pengujian Pertama Menggunakan Data Penumpang Kedatangan.....	93
Gambar 6. 13 Hasil Pengujian Kedua Menggunakan Data Penumpang Kedatangan.....	93
Gambar 6. 14 Hasil Pengujian Pertama Menggunakan Data Penumpang Keberangkatan.....	94
Gambar 6. 15 Hasil Pengujian Kedua Menggunakan Data Penumpang Keberangkatan.....	95

*(Halaman ini sengaja dikosongkan)*

## DAFTAR TABEL

Tabel 2. 1 Penelitian Terdahulu.....	11
Tabel 4. 1 Tabel Perancangan Model ANN .....	50
Tabel 5. 1 Estimasi Parameter ARIMA Jumlah Penumpang Kedatangan, $d=1$ .....	60
Tabel 5. 2 Estimasi Parameter ARIMA Jumlah Penumpang Kedatangan, $d=2$ .....	61
Tabel 5. 3 Estimasi Parameter ARMA Jumlah Penumpang Keberangkatan.....	62
Tabel 5. 4 Estimasi Parameter ARIMA Jumlah Penumpang Keberangkatan, $d=2$ .....	63
Tabel 5. 5 Uji Signifikansi ARIMA Menggunakan Data Jumlah Penumpang Kedatangan, $d=1$ .....	65
Tabel 5. 6 Uji Signifikansi ARIMA Menggunakan Data Jumlah Penumpang Kedatangan, $d=2$ .....	65
Tabel 5. 7 Uji Signifikansi ARMA Menggunakan Data Jumlah Penumpang Keberangkatan.....	66
Tabel 5. 8 Uji Signifikansi ARMA Mengguna kan Data Jumlah Penumpang Keberangkatan, $d=2$ .....	66
Tabel 5. 9 Uji Diagnostik Keacakan Sisaan ARIMA Jumlah Penumpang Kedatangan.....	69
Tabel 5. 10 Uji Diagnostik Homogenitas ARIMA Jumlah Penumpang Kedatangan.....	69
Tabel 5. 11 Uji Diagnostik Keacakan Sisaan ARMA Jumlah Penumpang Keberangkatan.....	70
Tabel 5. 12 Uji Diagnostik Homogenitas ARMA Jumlah Penumpang Keberangkatan.....	70
Tabel 5. 13 Pemilihan Model Terbaik ARIMA Sementara Menggunakan Data Jumlah Penumpang Kedatangan.....	71
Tabel 5. 14 Pemilihan Model Terbaik ARMA Menggunakan Data Jumlah Penumpang Keberangkatan.....	71



Tabel 5. 15 Data Training Data Jumlah Penumpang Kedatangan .....	72
Tabel 5. 16 Data Training Data Jumlah Penumpang Keberangkatan.....	73
Tabel 5. 17 Data Testing Menggunakan Data Jumlah Penumpang Kedatangan.....	74
Tabel 5. 18 Data Testing Menggunakan Data Jumlah Penumpang Keberangkatan.....	74
Tabel 6. 1 Hasil Uji Coba Model Data Jumlah Penumpang Kedatangan.....	81
Tabel 6. 2 Hasil Uji Coba Model Data Jumlah Penumpang Keberangkatan.....	83
Tabel 6. 3 Hasil Validasi Pertama Model Jumlah Penumpang Kedatangan.....	84
Tabel 6. 4 Hasil Peramalan Validasi Pertama Menggunakan Model ARMA (1,1) .....	86
Tabel 6. 5 Hasil Validasi Kedua Model Jumlah Penumpang Kedatangan.....	87
Tabel 6. 6 Hasil Peramalan Validasi Kedatangan Menggunakan Model ARMA (1,1) .....	88
Tabel 6. 7 Uji Coba Parameter Model ANN Data Jumlah Penumpang Kedatangan.....	90
Tabel 6. 8 Uji Coba Parameter Model ANN Data Jumlah Penumpang Keberangkatan.....	91
Tabel 6. 9 Perbandingan Jumlah Penumpang Kedatangan Menggunakan Hasil MAPE ARIMA dan Hybrid ARIMA-ANN pada Data Pelatihan.....	96
Tabel 6. 10 Perbandingan Jumlah Penumpang Kedatangan Menggunakan Hasil MAPE ARIMA dan Hybrid ARIMA-ANN pada Data Pengujian Pertama .....	96
Tabel 6. 11 Perbandingan Jumlah Penumpang Kedatangan Menggunakan Hasil MAPE ARIMA dan Hybrid ARIMA-ANN pada Data Pengujian Kedua.....	97

Tabel 6. 12 Perbandingan Jumlah Penumpang Keberangkatan Menggunakan Hasil MAPE ARIMA dan Hybrid ARIMA-ANN pada Data Pelatihan .....	98
Tabel 6. 13 Perbandingan Jumlah Penumpang Keberangkatan Menggunakan Hasil MAPE ARIMA dan Hybrid ARIMA-ANN pada Data Pengujian Pertama .....	99
Tabel 6. 14 Perbandingan Jumlah Penumpang Keberangkatan Menggunakan Hasil MAPE ARIMA dan Hybrid ARIMA-ANN pada Data Pengujian Kedua .....	99

*(Halaman ini sengaja dikosongkan)*



# **BAB I**

## **PENDAHULUAN**

Dalam bab ini dijelaskan gambaran umum mengenai tugas akhir yang diangkat meliputi latar belakang masalah, perumusan masalah, batasan tugas akhir, tujuan tugas akhir dan relevansi atau manfaat kegiatan tugas akhir. Selain itu dijelaskan pula mengenai sistematika penulisan untuk memudahkan dalam membaca buku tugas akhir ini.

### **1.1. Latar Belakang**

Seiring dengan pertambahan waktu, kepadatan penduduk pada suatu negara sangat mempengaruhi tingkat perkembangan ekonominya. Pertumbuhan penduduk di Indonesia semakin meningkat, menurut data Badan Pusat Statistika (BPS), pada tahun 2010 jumlah penduduk Indonesia mencapai 237.641.326 jiwa dengan rincian penduduk yang bertempat tinggal di daerah perkotaan sebanyak 118. 320.256 jiwa (49,79%) dan di daerah pedesaan sebanyak 119.321.070 jiwa (50,21%) [1]. Di daerah Jawa Timur sendiri memiliki jumlah penduduk yang cukup besar yaitu 37.476.757 jiwa, hal ini menyebabkan kepadatan yang cukup tinggi di wilayah ini mengingat 15% dari total penduduk Indonesia berada di Jawa Timur. Meningkatnya jumlah penduduk di Indonesia dapat mempengaruhi segala aspek salah satu diantaranya yaitu bidang transportasi, mobilitas penduduk yang tinggi menyebabkan kebutuhan akan alat transportasi menjadi sarana penting bagi seseorang untuk melakukan aktivitas. Transportasi udara merupakan salah satu sarana alternatif penunjang dalam bepergian dengan kepentingan bisnis atau pariwisata yang sangat diperhitungkan. Transportasi udara merupakan sarana transportasi yang dapat digunakan untuk menghubungkan antar wilayah dengan berbagai macam kepentingan di antar pulau bahkan antar

negara dengan jarak yang jauh sekalipun dapat ditempuh dengan waktu yang relatif singkat. Penataan sistem transportasi udara nasional yang handal, terpadu, terarah, serta perencanaan pengembangannya harus didukung dengan peningkatan kualitas sumber daya manusia serta pemenuhan data statistik transportasi udara yang tepat waktu, dapat dipercaya, dan memiliki tingkat akurasi tinggi. Seiring minat masyarakat yang semakin meningkat dalam menggunakan transportasi udara, membuat berbagai perusahaan penerbangan baru saling bersaing untuk menerapkan tarif yang kompetitif. Hal ini membuktikan bahwa penerbangan tidak selalu membawa penumpang dalam jumlah yang sama tiap bulannya dalam tiap penerbangannya. Penerbangan kadang mengalami lonjakan penumpang atau mengalami penurunan, perubahan-perubahan tersebut dapat diambil sebagai data untuk keperluan dalam mengambil keputusan atau kebijakan, khususnya dibidang penerbangan untuk penyesuaian terhadap peningkatan dan penurunan penumpang di masa yang akan datang [2].

Di Jawa Timur sendiri memiliki empat bandara, diantaranya Bandar Internasional Juanda, Bandara Abdul Rachman Saleh, Bandara Nasional Trunojoyo, dan Bandara Blimbingsari. Bandara Internasional Juanda yang dikelola oleh PT. Angkasa Pura I merupakan bandara ke-6 terbaik se-Indonesia dan terbaik ke-10 di dunia menurut *Airport Service Quaility* (ASQ) [3]. Bandara Internasional Juanda memiliki tingkat jumlah penumpang yang tinggi sehingga diperlukan peramalan tentang jumlah penumpang untuk menunjang perusahaan agar mengetahui prediksi jumlah penumpang di masa yang akan datang. Hal ini juga dapat digunakan sebagai persiapan untuk mempersiapkan meningkatkan fasilitas-fasilitas bandara untuk mengantisipasi kenaikan penumpang yang signifikan, seperti penerbangan ekstra, ruang tunggu yang nyaman, toilet dan

musholla yang bersih, serta tempat parkir yang diperluas untuk menampung kendaraan-kendaraan baik yang dipakai penumpang dan pengantar.

Dalam melakukan peramalan pada data time series, diperlukan pengetahuan terkait pola data yang ada dalam data tersebut sehingga peramalan dapat dilakukan dengan metode yang tepat dan sesuai. Pola data dapat dibedakan menjadi empat bagian yaitu: musiman, siklis, trend, dan irregular [4]. Pola musiman terbentuk akibat beberapa aktivitas dari data dalam suatu periode kecil sehingga grafik yang dihasilkan akan serupa jangka waktu tertentu berulang-ulang, siklis yaitu suatu pola fluktuasi atau siklus dari data runtut waktu akibat perubahan kondisi ekonomi, trend adalah komponen jangka panjang yang mendasari pertumbuhan atau penurunan suatu data runtut waktu, sedangkan pola data irregular yaitu pola acak yang disebabkan oleh peristiwa yang tidak dapat diprediksi atau tidak beraturan karna suatu faktor [5].

Untuk melakukan peramalan jumlah penumpang pesawat pada terminal 1 Bandara Internasional Juanda, dapat dilakukan dengan membandingkan dua metode yaitu menggunakan metode *Autoregressive Integrated Moving Average* (ARIMA) dan *hybrid Autoregressive Integrated Moving Average – Artificial Neural Network* (ARIMA-ANN). Metode ARIMA digunakan untuk menyelesaikan deret berkala untuk menganalisis time series. Metode ARIMA sangat baik digunakan untuk meramalkan data untuk jangka pendek sedangkan untuk peramalan jangka panjang ketepatan terhadap peramalannya kurang baik. Model ARIMA adalah model univariate, sehingga model ini cocok jika observasi dari time series secara statistik tidak berhubungan satu sama lain. Walaupun model ARIMA sangat fleksibel namun model

ARIMA mempunyai beberapa jenis runtun waktu yang berbeda yaitu model *Autoregressive* (AR), *Moving Average* (MA) dan kombinasi AR dan MA (ARMA) yang diasumsikan berbentuk linier [6] dan kekurangan dari ARIMA adalah model ARIMA mengasumsikan model yang linier. Hal ini menyebabkan model ARIMA tidak menangkap pola-pola yang *non-linear* yang umum terdapat pada *time series*. Oleh karena itu, model tersebut memerlukan model yang dapat menangkap pola-pola yang *non-linear*. Model tersebut adalah model ANN (*Artificial Neural Network*) [7]. Karena tidak hanya pola linier yang sering diketahui namun juga pola nonlinier. Keuntungan utama dari ANN ini adalah memiliki kemampuan yang fleksibel dalam memodelkan nonlinier. Dengan menggunakan ANN, tidak membutuhkan bentuk model yang tetap melainkan model dengan adaptif dibentuk berdasarkan model yang ditampilkan dari data [8]. Sehingga kombinasi antara metode ARIMA dan ANN ini akan memaksimalkan hasil peramalan yang berbentuk linier dan nonlinier. Dalam peramalan, tidak ada metode peramalan yang sangat tepat untuk meramalkan keadaan data di masa yang akan datang. Sehingga dalam tiap metode peramalan pasti melakukan kesalahan atau error. Alat yang digunakan untuk menghitung kesalahan pada peramalan menggunakan *Mean Absolute Percentage Error* (MAPE).

Penelitian sebelumnya tentang peramalan jumlah penumpang pesawat pernah dilakukan oleh Sinnyo H.S. Salmon, Nelson Nainggolan, dan Djoni Hatidja, dengan judul penelitian "*Pemodelan ARIMA dalam Prediksi Penumpang Pesawat Terbang pada Bandara Internasional Sam Ratulangi Manado*". Penelitian ini bertujuan untuk menentukan model *time series* yakni model ARIMA dari banyaknya penumpang pesawat



domestik di Bandara Internasional Sam Ratulangi Manado untuk periode 6 bulan. Variable yang digunakan pada penelitian ini adalah data jumlah penumpang domestik di bandara tersebut. Penelitian selanjutnya tentang peramalan penumpang dilakukan oleh Hector Allende, Claudio Moraga, dan Rodrigo Salas dengan judul penelitian “*Artificial Neural Networks in Time Series Forecasting: A Comparative Analysis*”. Pada penelitian ini bertujuan untuk membahas metode ANN dan membandingkannya dengan nonlinier *time series*.

Penelitian tentang *hybrid* ARIMA dan *Artificial Neural Network* dilakukan oleh Ayari Samia, Noura Kaouther, dan Trabelsi Abdelwahed, dengan judul penelitian “*A Hybrid ARIMA and Artificial Neural Networks Model to Forecast Air Quality in Urban Areas: Case of Tunisia*”. Tujuan dari penelitian ini adalah untuk meramalkan kualitas udara di Tunisia dengan pola data linier dan nonlinier sehingga kombinasi dari kedua metode tersebut dapat meningkatkan peramalan dibandingkan dengan menggunakan metode tersebut secara terpisah.

Tujuan penelitian tugas akhir ini yaitu membuat model peramalan dengan mengkombinasi metode *Autoregressive Integrated Moving Average* (ARIMA) dan *Artificial Neural Network* (ANN) yang dapat meramalkan jumlah penumpang penerbangan domestik di Bandara Internasional Juanda. Dengan menggunakan metode ARIMA dapat menemukan hasil peramalan linier dan dengan mengkombinasikan dengan ANN dapat menemukan hubungan linier dan nonlinier. Peramalan dengan menggunakan ARIMA ataupun ANN belum bisa dipastikan model mana yang benar-benar mempunyai keakuratan yang lebih tinggi, sehingga pada pengerjaan tugas

akhir ini akan dilakukan pengujian kombinasi ARIMA dan ANN.

Harapannya dalam penelitian ini dapat membantu perusahaan dalam membuat kebijakan keputusan untuk meningkatkan kinerja dan manajemen perusahaan. Fasilitas penunjang perlu diperhitungkan untuk meningkatkan tingkat kepuasan pelanggan yang merupakan salah satu faktor dari meningkatnya jumlah penumpang di terminal 1 Bandara Internasional Juanda. Dalam hal ini peningkatan jumlah penumpang dapat memperhitungkan profit perusahaan itu sendiri.

### **1.2. Perumusan Masalah**

Berdasarkan latar belakang di atas, maka dapat dirumuskan permasalahan:

1. Bagaimana model peramalan jumlah kedatangan dan keberangkatan penumpang di terminal 1 Bandara Internasional Juanda dengan metode ARIMA dan *hybrid* ARIMA-ANN?
2. Berapa perbandingan hasil peramalan jumlah kedatangan dan keberangkatan penumpang terminal 1 di Bandara Internasional Juanda dengan metode ARIMA dan *hybrid* ARIMA-ANN?
3. Metode peramalan manakah yang menghasilkan model terbaik untuk peramalan jumlah kedatangan dan keberangkatan penumpang terminal 1 di Bandara Internasional Juanda?

### **1.3. Batasan Masalah**

Tugas Akhir ini memiliki batasan agar lebih fokus pada topik yang akan diteliti, yaitu sebagai berikut ini:

1. Bandara yang digunakan adalah Bandara Internasional Juanda.
2. Data yang digunakan adalah data jumlah penumpang domestic periode bulanan mulai Januari 2007 hingga Maret 2017.
3. Data yang diambil dari pintu keberangkatan dan kedatangan penumpang domestik di terminal 1 (terminal 1A dan 1B) di Bandara Internasional Juanda.
4. Membandingkan dua metode yaitu ARIMA dan *hybrid* ARIMA-ANN.
5. Permasalahan yang dibandingkan adalah hasil peramalan dari jumlah penumpang dan hasil error.
6. Menentukan metode peramalan terbaik untuk jumlah keberangkatan dan kedatangan penumpang terminal 1 di Bandara Internasional Juanda.

#### **1.4. Tujuan Penelitian**

1. Menentukan model peramalan jumlah keberangkatan dan kedatangan terminal 1 pada Bandara Internasional Juanda dengan metode ARIMA dan *hybrid* ARIMA-ANN.
2. Mengetahui hasil perbandingan hasil peramalan jumlah keberangkatan dan kedatangan penumpang terminal 1 di Bandara Internasional Juanda dengan metode ARIMA dan *hybrid* ARIMA-ANN.

#### **1.5. Manfaat Penelitian**

Tugas akhir ini diharapkan dapat memberikan manfaat antara lain:

1. Bagi PT. Angkasa Pura I (Persero):
  - Membantu agar dapat meramalkan jumlah keberangkatan dan kedatangan penumpang terminal 1 untuk periode ke depan.

- Membantu mengetahui nilai peramalan jumlah keberangkatan dan kedatangan penumpang domestic.
- Membantu dalam mengambil kebijakan untuk mengatasi peningkatan jumlah penumpang.

2. Bagi peneliti:

- Mampu memahami cara penerapan metode *Autoregressive Integrated Moving Average* (ARIMA) yang dikombinasikan dengan *Artificial Neural Network* (ANN).
- Dapat menilai dan membandingkan hasil terbaik antara metode *Autoregressive Integrated Moving Average* (ARIMA) dan *hybrid* ARIMA-ANN.

### **1.6. Relevansi**

Bandara di Indonesia khususnya bandara Juanda merupakan salah satu bandara yang berada di urutan kedua untuk bandar udara tersibuk di Indonesia setelah bandara Soekarno-Hatta. Bandara Juanda dapat menampung kurang lebih 17.000.000 penumpang per tahun dan akan bertambah setiap tahunnya. Peningkatan tersebut juga mempengaruhi dari kebijakan atau keputusan yang diambil oleh manajemen untuk meningkatkan sarana dan prasarana. Untuk dapat memperkirakan jumlah penumpang yang datang di bandara Juanda maka peramalan jumlah penumpang merupakan hal yang perlu dipertimbangkan dalam pengambilan keputusan di bandara Juanda. Penerapan dengan menggunakan dua metode yaitu *Autoregressive Integrated Moving Average* (ARIMA) dan *hybrid* ARIMA-ANN dapat menyelesaikan permasalahan yang akan dihadapi di bandara. Kedua metode tersebut dibandingkan dengan tingkat error terkecil sehingga didapatkan hasil yang mendekati real. Sehingga dari hasil perbandingan tersebut dipilih

metode dengan hasil yang terbaik atau error terkecil yang kemudian dapat memberikan keputusan dalam peramalan jumlah penumpang di Bandara Juanda.

*(Halaman ini sengaja dikosongkan)*

## BAB II TINJAUAN PUSTAKA

Dalam bab ini dijelaskan mengenai penelitian terdahulu dan landasan teori yang digunakan sebagai acuan peneliti dalam pengerjaan tugas akhir. Penelitian terdahulu merupakan suatu penelitian yang digunakan sebagai acuan dalam pengerjaan tugas akhir. Landasan teori yang digunakan merupakan teori-teori yang berhubungan dengan pengerjaan tugas akhir. Landasan teori yang dibahas meliputi deskripsi studi kasus yang dipakai yaitu konsep peramalan, metode ARIMA Box-Jenkins, metode *hybrid* ANN, dan penumpang pesawat.

### 2.1. Penelitian Terdahulu

Beberapa penelitian sebelumnya yang dijadikan acuan dalam pengerjaan tugas akhir disajikan dalam Tabel berikut:

**Tabel 2. 1 Penelitian Terdahulu**

No	Tahun; Penulis	Pembahasan
	<i>Airline Passenger Forecasting Using Neural Networks and Box-Jenkins</i>	
	2016; S.M.T. Fatemi Ghomi and K. Forghani	Pada penelitian ini dilakukan peramalan yang dilakukan menggunakan data penumpang dari perusahaan maskapai di Turki dan terdiri dari data harian di masa lalu 5 tahun. Data ini digunakan untuk memperkirakan jumlah penumpang yang diharapkan untuk penerbangan di setahun mendatang yang akan dijadikan rekomendasi pada

No	Tahun; Penulis	Pembahasan
		system reservasi. Pada paper ini akan diidentifikasi dengan metode ARIMA dan ANN setelah itu akan dibandingkan hasil MAPE yang telah diterapkan.
	Penerapan Model <i>Hybrid ARIMA Backpropogation</i> untuk Peramalan Harga Gabah Indonesia	
	2014; Sufia Nur Janah, Winita Sulandari, Santoso Budi Wiyono	Penelitian ini dilakukan dengan mengkaji ulang metode <i>hybrid ARIMA backpropagation</i> dan menerapkan untuk peramalan harga Gabah Kering Giling untuk periode Januari 2008-April 2013. Dengan menggunakan tiga metode yaitu ARIMA, <i>Backpropagation</i> , dan <i>hybrid ARIMA Backpropagation</i> maka hasil yang didapatkan hasil terbaik ARIMA (0,1,[12]) BP struktur 5-14-1 dan hasil <i>hybrid ARIMA</i> (0,1,[12]) BP adalah 4.834,91, 4.763,94, dan 4.696,10.
	Peramalan Jumlah Wisatawan Mancanegara yang Masuk Melalui Pintu Kedatangan Bandara Soekarno-Hatta dan Bandara Juanda	



	2009; Indira Rahmi dan Sri Pingit Wulandari	Pada penelitian ini dilakukan peramalan pada jumlah wisatawan mancanegara yang datang pada Bandara Soekarno-Hatta dan Bandara Juanda dengan memperhatikan faktor krisis politik Thailand yang mempengaruhi wisatawan datang ke Indonesia, pada penelitian ini juga akan menggunakan model intervensi yang digunakan karena terdapat faktor eksternal. Namun diakhir penelitian ini menggunakan ARIMA Box-Jenkins karena krisis politik Thailand tidak memberikan pengaruh yang signifikan terhadap jumlah kunjungan wisatawan mancanegara di Bandara Juanda.
	Peramalan Temperatur Udara di Kota Surabaya dengan Menggunakan ARIMA dan <i>Artificial Neural Network</i>	
	2012; Ali Machmudin dan Brodhjol S. S. Ulama	Pada penelitian ini dilakukan peramalan temperature udara di kota Surabaya dengan menggunakan ARIMA dan ANN. Metode ANN yang digunakan adalah <i>backpropogation</i> yang

		<p>umumnya digunakan dalam hal penyelesaian yang berkaitan dengan identifikasi, prediksi, pengenalan pola, dan sebagainya. Kesimpulan diakhir penelitian ini menunjukkan bahwa model ARIMA belum baik dan ANN <i>backpropagation</i> memberikan model yang cukup baik.</p>
	<p>Pemodelan Curah Hujan dengan Pendekatan Model ARIMA, <i>Feed Forward Neural Network</i> dan <i>Hybrid</i> (ARIMA-NN) di Banyuwangi</p>	
	<p>2016; Yudi Santoso dan Brodjol Sutijo Suprih Ulama</p>	<p>Penelitian ini memodelkan curah hujan dengan pendekatan ARIMA, <i>feed forward neural network</i>, dan <i>hybrid</i> (ARIMA-NN) kegunaannya untuk membantu petani dalam produksi padi di Banyuwangi Karena factor alam berpengaruh dalam produksi padi terutama curah hujan. Kesimpulan dari penelitian ini didapatkan pemodelan ARIMA <math>([1,13,17],0,0)(1,0,0)^{12}</math>, FFNN <math>(3,3,1)</math> dengan input <math>Z_{t-1}, Z_{t-12}</math>, dan <math>Z_{t-13}</math>, dan <i>hybrid</i> (ARIMA-NN) gabungan model ARIMA <math>([1,13,17],0,0)(1,0,0)^{12}</math> dan <i>residualnya</i> dimodelkan</p>

		kembali dengan model FFNN (4,5,1) dimana variable <i>inputnya</i> adalah $a_{t-1}$ hingga $a_{t-4}$ .
--	--	---

## 2.2. Dasar Teori

### 2.2.1. Konsep Peramalan

Peramalan adalah kegiatan mengestimasi apa yang akan terjadi pada masa yang akan datang. Sedangkan ramalan adalah situasi atau kondisi yang akan diperkirakan akan terjadi pada masa yang akan datang. Peramalan adalah usaha untuk melihat situasi dan kondisi pada masa yang akan data dengan memperkirakan hasil masa lampau dan pengaruh situasi secara kondisi terhadap perkembangan di masa yang akan datang [9]. Menurut sumber lain menyebutkan bahwa peramalan merupakan salah satu unsur yang sangat penting dalam pengambilan keputusan, karena terkadang faktor-faktor yang berhubungan dengan pengambilan keputusan tidak dapat ditentukan pada saat keputusan tersebut diambil [10]. Karena ramalan tidak sepenuhnya menghilangkan risiko, namun hanya dapat diperkecil seminimal mungkin sehingga faktor ketidakpastian harus diperhatikan secara eksplisit dalam pengambilan keputusan. Metode peramalan adalah suatu cara untuk memperkirakan secara kuantitatif apa yang akan terjadi di masa yang akan datang dengan dasar data yang relevan pada masa lalu, sehingga metode peramalan digunakan untuk peramalan yang bersifat objektif [11].

Metode peramalan dibagi menjadi dua kategori utama, yaitu metode kualitatif dan metode kuantitatif [12].

- a. Peramalan Kualitatif: Peramalan yang didasarkan atas data kualitatif pada masa lalu. Hasil peramalan kualitatif didasarkan pada pengamatan kejadian-kejadian di masa

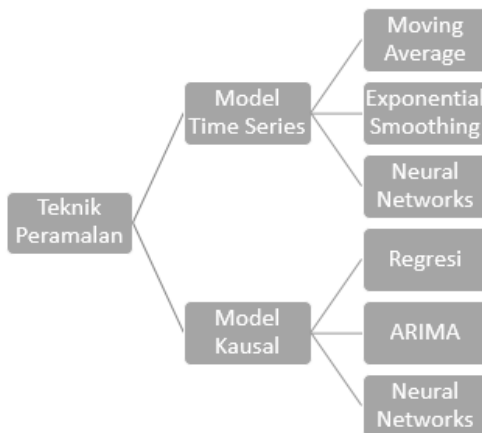
sebelumnya digabung dengan pemikiran dari penyusunannya.

- b. Peramalan Kuantitatif: Peramalan yang didasarkan ata data kuantitatif masa lalu yang diperoleh dari pengamatan nilai-nilai sebelumnya. Hasil peramalan yang dibuat tergantung pada metode yang digunakan, menggunakan metode yang berbeda akan diperoleh hasil peramalan yang berbeda.

Namun, apabila data masa lalu tersedia, maka peramalan dengan menggunakan metode kuantitatif akan lebih efektif digunakan dibandingkan dengan metode kualitatif.

### 2.2.1.1. Konsep Model Time Series

Metode peramalan kuantitatif dapat dibagi menjadi dua bagian, yaitu *time series* dan *causal model*. *Time series model* didasarkan pada data yang dikumpulkan, dicatat, atau diamati berdasarkan urutan waktu dan peramalannya dilakukan berdasarkan pola tertentu dari data [13].



Gambar 2. 1 Diagram klasifikasi teknik peramalan (Mukhyi, 2008)

*Time series* merupakan data yang dikumpulkan, dicatat, atau diobservasi sepanjang waktu secara berurutan yang diperoleh

dari perhitungan dari waktu ke waktu atau periodik, pada umumnya pencatatan dilakukan berdasarkan jangka waktu tertentu misal tiap tahun, tiap semester, tiap tahun, dan sebagainya yang biasanya memiliki interval waktu yang sama. Data deret waktu yang dicatat tidaklah timbul hanya karena pengaruh sebuah faktor saja, melainkan karena berbagai faktor penentu, seperti bencana, manusia, selera konsumen, keadaan musim, kebiasaan, dan lain-lain [14]. Data *time series* dianalisis untuk menemukan pola variasi masa lalu yang dapat dipergunakan untuk memperkirakan nilai untuk masa depan (*forecast*) karena dengan mengamati data runtut waktu akan terlihat komponen yang akan mempengaruhi pola data masa lalu dan sekarang yang cenderung berulang di masa datang [5].

Klasifikasi model *time series* adalah metode peramalan dengan menggunakan Analisa pola hubungan antara variable yang akan diperkirakan dengan variable tertentu atau analisis *time series*, antara lain:

1. *Moving Average*
2. *Exponential Smoothing*
3. ARIMA Box-Jenkins

Terdapat empat komponen yang ditemukan dalam analisis *time series* adalah: [5]

1. Trend: Komponen jangka panjang yang mendasari pertumbuhan atau penurunan suatu data runtut waktu. Trend disebabkan oleh perubahan jangka panjang yang terjadi disekitar factor-faktor yang mempengaruhi data deret waktu. Pola perkembangan data membentuk karakteristik yang mendekati garis linier. Gradien yang

naik atau turun menunjukkan peningkatan atau pengurangan nilai data sesuai dengan waktu.

2. Siklikal: Suatu pola fluktuasi atau siklus dari data runtut waktu kibat perubahan kondisi ekonomi.
3. Seasonal: Fluktuasi musiman yang sering dijumpai pada kuartalan, bulanan, atau mingguan. Pola ini terbentuk akibat beberapa aktivitas dari data dalam suatu periode kecil sehingga grafik yang dihasilkan akan serupa jangka waktu tertentu berulang-ulang.
4. Irregular: Pola acak yang disebabkan oleh peristiwa yang tidak dapat diprediksi atau tidak beraturan karna suatu faktor.

#### **2.2.1.2. Konsep Model Kausal**

Model kausal didasarkan pada hubungan sebab-akibat dan peramalan dilakukan dengan dugaan adanya gubungan antar variable yang satu dengan -yang lainnya. Pada model ini dikembangkan dimana variable dependent dan variable independen akan dibedakan, kemudian dilanjtkan dengan membuat sebuah model dan peramalan dilakukan berdasarkan model tersebut.

Analisis yang dapat dilakukan dalam model kausal diantaranya:

1. Regresi
2. ARIMA
3. Neural Network

Hal penting dalam peramalan yang lainnya adalah dengan memperhatikan pada *error*, hal ini perlu diperhatikan karena hasil *error* akan menentukan apakah model yang dihasilkan menghasilkan *error* yang minimal. Sehingga untuk mendapatkan hasil yang mendekati data aktual diusahakan untuk membuat *error* sekecil mungkin.

### 2.2.2. Metode ARIMA

ARIMA umumnya disebut dengan metode time series Box-Jenkins. ARIMA atau *Autoregressive Integrated Moving Average* ditemukan oleh George Edward Pelham Box dan Gwilym Meirion Jenkins yaitu metode peramalan untuk menyelesaikan deret berkala untuk menganalisis time series. Metode ARIMA sangat baik digunakan untuk meramalkan data untuk jangka pendek sedangkan untuk peramalan jangka panjang ketepatan terhadap peramalannya kurang baik. Model ARIMA adalah model univariate, sehingga model ini cocok jika observasi dari time series secara statistik tidak berhubungan satu sama lain.

Tujuan dari pemodelan ARIMA adalah menentukan hubungan statistik yang baik antar variable yang diramal dengan nilai historis variable tersebut sehingga peramalan dapat dilakukan dengan model tersebut. Pada penggunaan metode ARIMA data yang dibutuhkan adalah data yang sudah stasioner, jika data belum stasioner maka perlu melakukan uji stasioner data. Model ARIMA dapat melakukan peramalan terhadap masa depan dengan hanya menggunakan data masa lalu.

Selanjutnya ARIMA dapat digunakan untuk melakukan peramalan jika model yang dihasilkan telah memadai

Kelebihan dari ARIMA dapat dijabarkan sebagai berikut: [16]

- a. Mudah dalam pembentukan modelnya.
- b. Lebih cepat dalam pembentukan model, tidak perlu melakukan uji pelatihan seperti ANN.

- c. Hasilnya mudah diinterpretasikan, karena koefisien-koefisien model diketahui sehingga dapat dilihat pengaruh masing-masing prediktor terhadap hasil keluaran model.

Kekurangan dari ARIMA adalah: [16]

- a. Secara umum lebih tidak akurat dibandingkan model ANN.
- b. Tidak menangkap hubungan fungsional yang belum diketahui antara variable independen dengan variable dependen / tidak dapat menangkap hubungan antar variable yang belum memiliki teori yang melandasinya

Klasifikasi model ARIMA telah dibagi menjadi tiga kelompok diantaranya yaitu, model *Autoregressive* (AR), model *Moving Average* (MA), dan model campuran yang memiliki karakteristik dari dua model pertama (ARMA). Model ARIMA merupakan gabungan antara model *Autoregressive* (AR) dan model *Moving Average* (MA) dengan data yang telah mengalami *diffrencing* atau perbedaan sebanyak  $d$  kali.

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

Model *Autoregressive* (AR) memiliki nilai data sekarang tergantung dengan nilai data masa lalu, dengan bentuk umum dengan ordo  $p$  (AR(p)) atau model ARIMA ( $p, 0, 0$ ) dinyatakan persamaan sebagai berikut:

$$X_t = \mu' + \phi_1 X_{t-1} + \phi_2 X_{t-2} + \phi_3 X_{t-3} + \dots + \phi_p X_{t-p} + e_t$$

Dimana:

- $X_t$  : Variabel yang diramalkan atau variable tidak bebas
- $X_{t-1}, X_{t-2}, X_{t-3}, \dots, X_{t-p}$  : Variabel bebas yang merupakan lag dari variable tidak bebas.
- $\mu'$  : suatu konstanta
- $\phi_p$  : Parameter *Autoregressive* ke- $p$



- $e_t$  : nilai kesalahan pada saat  $t$

Pada persamaan ordo  $p$  atau AR( $p$ ) adalah jumlah observasi masa lampau yang akan dimasukkan dalam meramalkan periode yang akan datang. Dalam hal ini pula yang menjadi variable bebas adalah dengan variable yang sama (auto variable) tetapi pada periode sebelumnya ( $t-1, t-2, t-3, \dots, t-p$ ).

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

Model *Moving Average* (MA) memiliki nilai data sekarang tergantung dari peramalan *error* pada periode sebelumnya, dengan bentuk umum dengan ordo  $q$  (AR( $q$ )) atau model ARIMA (0, 0,  $q$ ) dinyatakan persamaan sebagai berikut:

$$X_t = \mu' + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-k}$$

Dimana:

- $X_t$  : Variabel yang diramalkan atau variable tidak bebas
- $\mu'$  : Suatu konstanta
- $\theta_1, \theta_2, \dots, \theta_q$  : Parameter *Moving Average* ke- $q$
- $e_{t-k}$  : Nilai kesalahan pada saat  $t - k$

### 2.2.2.3. Model Campuran *Autoregressive Moving Average* (ARMA)

Model umum untuk campuran AR ( $p$ ) dan MA ( $q$ ) atau sering kali disebut dengan model ARMA ( $p, q$ ) atau ARIMA ( $p, 0, q$ ) adalah sebagai berikut:

$$X_t = \mu + \phi_1 X_{t-1} + \dots + \phi_p X_{t-p} - e_t - \phi_1 e_{t-1} - \dots - \phi_q e_{t-p}$$

#### 2.2.2.4. Model *Autoregressive Integrated Moving Average* (ARIMA)

Apabila nonstasioneritas ditambahkan pada campuran proses ARMA, maka model umum ARIMA ( $p, d, q$ ) terpenuhi. Persamaan untuk model umum dari model ini adalah ARIMA (1, 1, 1), dan dirumuskan dengan:

$$W_t = \mu + \phi_1 X_{t-1} + \dots + \phi_p X_{t-p} + e_t - \theta_1 e_{t-1} - \dots - \theta_q X_{t-q}$$

#### 2.2.2.5. Integrated (I)

Bentuk umum model *integrated* dengan ordo  $d$  (I( $d$ )) atau model ARIMA (0, $d$ ,0), model *integrated* menyatakan *difference* dari data. Model ini mengartikan bahwa dalam membuat model ARIMA memiliki syarat stasioner data, apabila data telah stasioner pada level maka ordo memiliki nilai 0. Namun jika data telah stasioner pada *different* pertama maka memiliki ordo 1 atau ARIMA ( $p,1,q$ ).

#### 2.2.2.6. Musiman dan Model ARIMA

Musiman didefinisikan sebagai suatu pola yang berulang-ulang dalam selang waktu yang tetap. Untuk data yang stasioner, faktor musiman dapat ditentukan dengan mengidentifikasi koefisien autokorelasi pada dua atau tiga *time-lag* yang berbeda nyata dari nol. Autokorelasi yang secara signifikan berbedanya dari nol menyatakan adanya suatu pola dalam data. Untuk mengenali adanya faktor musiman, seseorang harus melihat pada autokorelasi yang tinggi. Untuk menangani musiman, rumus umum yang dapat diimplementasikan adalah:

$$ARIMA(p, d, q)(P, D, Q)^s$$

Dimana:

- $(p, d, q)$ : Bagian yang tidak musiman dari model
- $(P, D, Q)$ : Bagian musiman dari model
- $s$ : Jumlah periode per musim

Model ARIMA terdiri dari tiga langkah dasar, yaitu tahap identifikasi model, pendugaan parameter, dan diagnostik model [15]:

a. Identifikasi Model

Pembuatan model ARIMA berawal dengan membuat plot data *time series*, plot tersebut dapat dilihat pola identifikasi model sementara dilakukan dengan cara melihat model AR dan atau MA sehingga diperlukan melihat unsur  $p$  (pada AR) dan  $q$  (pada MA)

**Tabel 2. 2 Identifikasi ACF dan PACF (Suhartono, 2008)**

Model	ACF	PACF
AR( $p$ )	<i>Dies down</i> (turun cepat secara eksponensial/sinusoidal)	<i>Cuts off after lag p</i> (terputusnya setelah lag p)
MA( $q$ )	<i>Cuts off after lag q</i> (terputusnya setelah lag q)	<i>Dies down</i> (turun cepat secara eksponensial/sinusoidal)
ARMA ( $p, q$ )	<i>Dies down after lag (q-p) or (p-q)</i>	<i>Dies down after lag (q-p) or (p-q)</i>
No AR or MA (White Noise)	<i>No spike</i>	<i>No spike</i>

b. Estimasi Parameter

Pada tahap ini setelah menentukan model awal, akan diperoleh estimasi koefisien-koefisien dari model yang diperoleh pada tahap identifikasi. Beberapa model yang

sudah dipilih akan diterima apabila koefisien hasil estimasi signifikan. Sebaliknya, apabila koefisien hasil estimasi tidak signifikan maka model tersebut ditolak.

c. Uji Diagnostik Parameter

Setelah tahap estimasi model, langkah selanjutnya yaitu melakukan diagnostic checking dari model yang telah diestimasi. Pada tahap ini dilakukan verifikasi kesesuaian model dengan sifat-sifat data serta dilakukan pemilihan model terbaik berdasarkan MSE yang diperoleh. Jika modelnya tepat maka data yang dihitung dengan model akan memiliki sifat-sifat yang mirip dengan data asli. Dengan demikian, residual yang dihitung berdasarkan model yang telah diestimasi bersifat white noise.

d. Peramalan berdasarkan model terbaik

Setelah model terbaik diperoleh berdasarkan langkah langkah sebelumnya, model tersebut digunakan untuk meramalkan data di masa yang akan datang. Data hasil peramalan ini akan mendekati data aslinya.

### 2.2.3. Neural Network

Pada sub bab *Neural Network* ini akan dijelaskan tentang dasar-dasar *Neural Network* yang akan digunakan pada pemodelan peramalan ini.


#### 2.2.3.1. *Artificial Neural Network*

Dari model multivariate ARIMA yang cukup fleksibel dalam memodelkan sebagian besar pola time series. Kekurangan dari ARIMA adalah model ARIMA mengasumsikan model yang linier. Hal ini menyebabkan model ARIMA tidak menangkap pola-pola yang non-linear yang umum terdapat pada time series. Oleh karena itu, model tersebut memerlukan model yang dapat menangkap pola-pola yang non-linear. Model tersebut adalah

model ANN (*Artificial Neural Network*) [7]. Menurut struktur neuron pada otak manusia, dan proses kerja yang dijelaskan diatas, maka konsep dasar pembangunan *Artificial Neural Network* terbentuk. Cara kerja ANN dapat disimpulkan mengadopsi dari cara berpikir sebuah system atau aplikasi yang menyerupai otak manusia, mulai dari menerima input yang diterima, toleransi dari kesalahan atau error, dan juga prosesnya. ANN mempresentasikan buatan dari otak manusia yang selalu melakukan proses pembelajaran pada otak manusia tersebut, di dalam ANN terdapat tiga elemen yang berperan penting sebagai berikut:

- a. Arsitektur jaringan beserta hubungan antar neutron
- b. Algoritma pembelajaran yang berfungsi untuk penggunaan penemuan bobot-bobot jaringan
- c. Fungsi dari aktivasi yang digunakan

Cara yang efisien untuk memecahkan problem yang kompleks adalah memecahkan permasalahan tersebut ke dalam elemen-elemen yang lebih kecil (*divide and conquer*). Model ANN dapat melakukan kegiatan semacam ini [18]. Secara prinsip jaringan dibangun menggunakan input yang dikaitkan dengan suatu faktor penimbang tertentu. Dan kemudian dijumlahkan semua masukan tersebut untuk menentukan tingkat aktivasi neuron.



**Gambar 2. 2 Ilustrasi Neuron Tiruan**

Dalam ANN, model neuron terdiri dari 3 bagian, diantaranya:

1. Synapsis (jalur penghubung) antara neuron yang memiliki bobot tiap synapsis memiliki indeks untuk menunjukkan input yang mana yang akan diproses untuk menjadi output.
2. Summing Unit untuk melakukan perhitungan terhadap total output
3. Activation function untuk membatasi output


Seperti jaringan manusia, jaringan saraf tiruan memiliki komponen sebagai berikut [19]:

- a. Neuron Tiruan (*Artificial Neuron*)  
ANN disusun oleh unit dasar yang disebut dengan neuron tiruan yang merupakan elemen pemrosesan dalam jaringan, dimana semua proses perhitungan dilakukan disini.
- b. Lapisan (*Layer*)  
ANN disusun oleh kumpulan neuron yang berhubungan dan dikelompokkan pada layer-layer. Dalam ANN terdapat tiga layer diantaranya: *input layer*, *hidden layer*, dan *output layer*
- c. Masukan (*Input*)  
ANN hanya dapat memproses data yang memiliki masukan berjenis numerik. Sehingga apabila masalah melibatkan data kualitatif seperti grafik, gambar, sinyal suara dan data tersebut akan dirubah ke dalam data numeric yang ekuivalen sebelum dapat diproses oleh ANN.
- d. Keluaran (*Output*)  
Keluaran dari ANN adalah berupa pemecahan terhadap masalah yang berupa data numerik.
- e. Bobot (*Weight*)  
Bobot di dalam ANN menyatakan bahwa suatu system memiliki tingkat kepintaran. Bobot dari sebuah ANN

berupa deretan angka yang sangat penting untuk mengoptimalkan dan akan memungkinkan sebuah system menerjemahkan data masukan secara benar dan menghasilkan sebuah keluaran yang diinginkan.

### 2.2.3.2. Metode Backpropagation

Backpropagation merupakan salah satu pengembangan dari arsitektur *Single Layer Neural Network*. Pada arsitektur ini terdiri dari input layer, hidden layer, dan output layer, setiap layer terdiri dari satu atau lebih artificial neuron. Sebutan umum untuk arsitektur ini adalah multilayer neural network.



**Gambar 2. 3 Arsitektur Multilayer Neural Network (Fauset, 1994)**

Pada metode ini merupakan metode sistematis jaringan saraf tiruan yang menggunakan algoritma *unsupervised learning* dan biasanya digunakan oleh perceptron dengan banyak lapisan untuk mengubah bobot-bobot yang ada pada lapisan tersembunyi (*hidden layer*). Pelatihan yang digunakan pada backpropagation adalah jenis terkontrol dimana menggunakan pola penyesuaian bobot untuk mencapai nilai kesalahan yang

minimum antara keluaran hasil prediksi *dengan* keluaran yang nyata.

Dalam metode *backpropagation* menggunakan tiga langkah untuk melakukan pelatihan, yaitu:

- a. *Feedforward* dari pola input training
- b. *Backpropagation* dari *error* yang terhubung
- c. Penyesuaian bobot-bobot

#### **2.2.3.3. Pelatihan Standar *Backpropagation***

Pada pelatihan *backpropagation* meliputi tiga fase, yaitu sebagai berikut [20]:

- a. Fase I: Propagasi Maju  
Pola inputan dihitung mamu Mukai dari layer masukan hingga layer keluaran menggunakan fungsi aktivasi yang ditentukan.
- b. Fase II: Propagasi Mundur  
Selisih antara keluaran jaringan dengan target yang diinginkan merupakan kesalahan yang terjadi. Kesalahan tersebut dipropagasikan mundur, dimulai dari garis yang berhubungan langsung dengan unit-unit layer keluaran.
- c. Fase III: Perubahan Bobot  
Modifikasi bobot untuk menurunkan kesalahan yang terjadi. Fase ini diiterasi hingga kondisi penghentian terpenuhi.

#### **2.2.3.4. Algoritma Pembelajaran *Backpropagation***

Algoritma pelatihan untuk jaringan dengan satu layer tersembunyi (dengan fungsi aktivasi sigmoid biner) adalah sebagai berikut [21]:

1. Langkah 0: inisialisasi semua bobot dengan bilangan acak kecil.



2. Langkah 1: jika kondisi penghentian belum terpenuhi, lakukan langkah 2-9.
3. Langkah 2: untuk setiap pasang data pelatihan, lakukan langkah 3-8

Fase I: *Feedforward* (propagasi maju)

4. Langkah 3: tiap unit masukan menerima sinyal dan meneruskannya ke unit tersembunyi di atasnya
5. Langkah 4: Hitung semua keluaran di unit tersembunyi  $X_j$  ( $j = 1, 2, \dots, p$ )

$$z_{net_j} = v_{jo} + \sum_{i=1}^n x_i v_{ii}$$

Setelah itu menghitung sinyal output dan unit tersembunyi dengan menggunakan fungsi aktivasi yang ditentukan:

$$X_j = f(X_{in_j})$$

Sinyal output ini selanjutnya dikirim ke seluruh unit pada unit atas (unit output)

6. Langkah ke 5: Hitung semua keluaran jaringan di unit  $y_k$  ( $k=1, 2, \dots, q$ )

$$y_{net_k} = w_{ko} + \sum_{j=1}^p Z_j W_{kj}$$

Selanjutnya menghitung sinyal output dari unit output bersangkutan dengan menggunakan fungsi aktivasi yang telah ditentukan

$$Y_k = f(Y_{in_k})$$

Fase II: *Backpropagation* (propagasi mundur)

7. Langkah 6: hitung faktor  $\delta$  unit keluaran berdasarkan kesalahan di setiap unit keluaran  $y_k$  ( $k=1, 2, \dots, q$ )

$$\delta_k = (t_k - y_k) f'(y_{net_k}) = (t_k - y_k) y_k (1 - y_k)$$

$\delta_k$  merupakan unit kesalahan yang akan dipakai dalam perubahan bobot layer dibawahnya (langkah 7). Hitung suku perubahan bobot  $w_{kj}$  (yang akan dipakai untuk merubah bobot  $w_{kj}$ ) dengan laju percepatan  $\alpha$

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

8. Langkah 7: hitung factor  $\delta$  unit tersembunyi berdasarkan kesalahan di setiap unit tersembunyi  $Z_j$  ( $j=1,2,\dots,p$ )

$$\delta_{net_j} = \sum_{k=1}^m \delta_k w_{kj}$$

Factor  $\delta$  unit tersembunyi:

$$\delta_j = \delta_{net_j} f'(z_{net_j}) = \delta_{net_j} z_j (1 - z_j)$$

Hitung suku perubahan bobot  $v_{ji}$  (yang akan dipakai nanti untuk merubah bobot  $v_{ji}$ )

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

Fase III: Perubahan Bobot

9. Langkah 8: Hitung semua perubahan bobot

Perubahan bobot garis yang menuju ke unit keluaran:

$$w_{kj}(\text{baru}) = w_{kj}(\text{lama}) + \Delta w_{kj}$$

Perubahan bobot garis yang menuju ke unit tersembunyi:

$$v_{ji}(\text{baru}) = v_{ji}(\text{lama}) + \Delta v_{ji}$$

Setelah pelatihan selesai dilakukan, jaringan dapat dipakai untuk pengenalan pola. Dalam hal ini, hanya *feedforward* (langkah 4 dan 5) saja yang dipakai untuk menentukan keluaran

jaringan. Apabila fungsi aktivasi yang dipakai bukan sigmoid biner, maka langkah 4 dan 5 harus disesuaikan. Demikian juga turunannya pada langkah 6 dan 7.

10. Langkah ke-9: tes kondisi berhenti apabila error ditemukan. Jika kondisi STOP telah terpenuhi, maka pelatihan jaringan dapat dihentikan.

### 2.2.6. Uji Performance Model Peramalan

Untuk menguji ukuran keakuratan peramalan dapat menggunakan beberapa metode [22]. Salah satu cara dalam mengukur ketepatan peramalan, biasanya digunakan perhitungan MAPE

#### 2.2.6.1. Mean Absolute Percentage Error (MAPE)

MAPE dihitung menggunakan kesalahan absolut pada tiap periode dibagi dengan nilai observasi yang nyata pada periode itu. Lalu, merata-rata kesalahan persentase absolut tersebut. Pendekatan yang dilakukan ini berfungsi untuk saat ukuran atau besar variable ramalan itu penting dalam mengevaluasi ketepatan ramalan. MAPE juga mengindikasikan seberapa besar kesalahan dalam meramal yang dibandingkan dengan nilai real. Dalam MAPE nilai error dikatakan baik jika bernilai 20% sedangkan semakin kecil dari 20% maka semakin baik. Berikut ini adalah rumus MAPE:

$$MAPE = \sum \frac{|Actual - Forecast|}{Actual} \times 100\%$$

Dimana:

- Aktual: Data actual
- Forecast: Data hasil peramalan
- n: Banyaknya periode ramalan

### 2.2.7. *Hybrid* (ARIMA-ANN)

Model hybrid merupakan suatu metode kombinasi dari satu atau lebih dari dua model dalam fungsi suatu system. Model ARIMA dan ANN merupakan model untuk mengatasi masalah linier atau nonlinier [23]. Karena pada kenyataannya jarang ditemukan kejadian *time series* yang murni linier maupun murni nonlinier maka model *hybrid* yang mempunyai kemampuan memodelkan linier dan nonlinier dapat dijadikan strategi yang praktis. Secara umum, kombinasi dari model *time series* yang memiliki struktur autokorelasi linier dan nonlinier dapat dituliskan:

$$y_t = L_t + N_t$$

Dimana:

- $L_t$ : Komponen linier
- $N_t$ : komponen nonlinier

Dua komponen tersebut digunakan untuk meramalkan data. Pertama, digunakan ARIMA untuk bentuk model linier, kemudian residual dari model linier akan mengandung hubungan nonlinier.  $e_t$  menunjukkan residual saat  $t$  waktu dari model linier

$$e_t = y_t - \hat{L}_t$$

Dimana:

- $\hat{L}_t$ : Nilai peramalan untuk  $t$  waktu dari hubungan penaksiran

Dalam mendiagnosa model-model linier, residual sangat penting sehingga saat memodelkan residual menggunakan ANN, hubungan nonlinier dapat ditemukan. Sehingga model ANN untuk residual dengan  $n$  input akan menjadi:

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

Dimana:

- $f$ : fungsi nonlinier yang ditentukan dengan ANN
- $\varepsilon_t$ : *error*

Kombinasi peramalan akan menjadi:

$$\hat{y}_t = \hat{L}_t + \check{N}_t$$

Singkatnya, tujuan dari metodologi system hibridasi terdiri atas dua langkah. Langkah pertama, model ARIMA digunakan untuk menganalisis masalah bagian linier. Dan langkah kedua, model ANN dibangun untuk memodelkan residual dari model ARIMA. Karena model ARIMA tidak dapat menangkap struktur nonlinier dari data, model residual dari linier akan memiliki informasi tentang nonlinier. Hasil dari ANN dapat digunakan sebagai meramalkan *error* untuk model ARIMA [23].

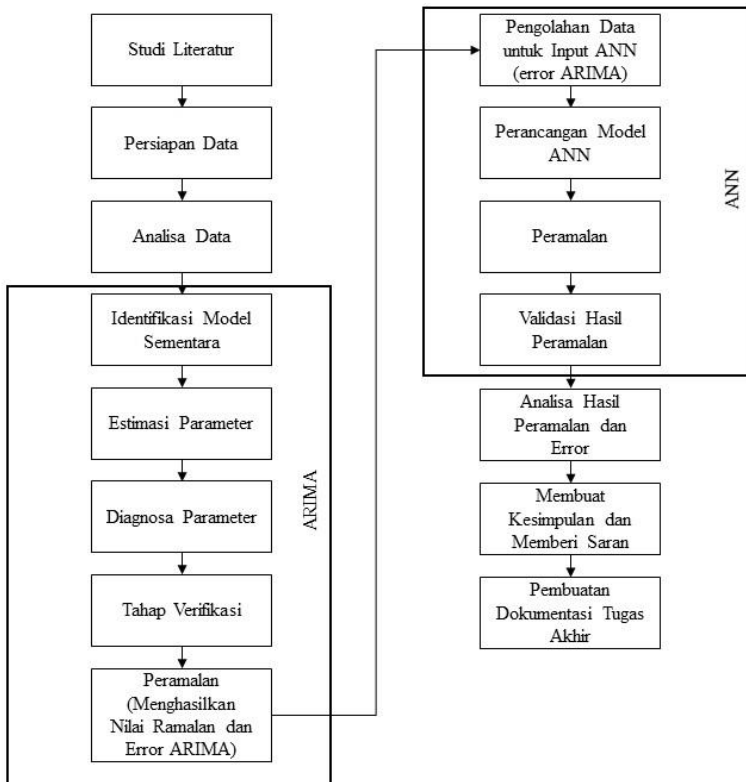
Langkah-langkah peramalan harga saham dengan metode hibrid ARIMA – JST adalah sebagai berikut:

- a. Melakukan pemodelan dan peramalan menggunakan model ARIMA terbaik.
- b. Setelah diperoleh residual dari model ARIMA, langkah selanjutnya adalah melakukan peramalan residual dari model ARIMA tersebut dengan menggunakan metode jaringan syaraf tiruan.
- c. Hasil peramalan diperoleh dari selisih antara nilai data actual dan hasil peramalan residual menggunakan metode jaringan syaraf tiruan.

*(Halaman ini sengaja dikosongkan)*

### BAB III METODOLOGI

Pada bab ini akan dijelaskan mengenai metodologi yang akan digunakan sebagai acuan melaksanakan penyusunan tugas akhir. Metodologi digunakan untuk pedoman agar penyusunan tugas akhir terarah dan sistematis. Berikut merupakan urutan pengerjaan tugas akhir dapat dilihat pada



Gambar 3.1 Metodologi Penelitian

### **3.1 Studi Literatur**

Pada tahap pertama, studi literature merupakan suatu kegiatan penelitian dalam mengumpulkan informasi yang dibutuhkan selama proses pengerjaan tugas akhir. Pengumpulan informasi bisa didapatkan melalui penelitian terdahulu, narasumber, buku, maupun dokumen yang terkait. Tujuannya adalah untuk mengetahui permasalahan serta menjadi dasar teori dalam melakukan studi dan juga menjadi dasar dalam melakukan peramalan penumpang pada Bandara Juanda. Pada tahap ini, akan dilakukan kajian terhadap metode apa yang akan digunakan untuk menyelesaikan permasalahan yang diangkat pada topik tugas akhir

### **3.2. Persiapan Data**

Dalam pengerjaan tugas akhir ini diperlukan data yang mendukung dan dapat digunakan dalam melaksanakan proses penelitian tugas akhir. Maka dalam tahapan ini dilakukan pencarian data yang akan diolah untuk tugas akhir ini. Data yang dibutuhkan oleh penulis adalah data jumlah penumpang pesawat di Bandara Internasional Juanda. Dimana data yang digunakan diperoleh dari data statistika PT Angkasa Pura I Juanda dan [www.hubud.dephub.go.id](http://www.hubud.dephub.go.id). Data yang digunakan oleh penulis adalah data penumpang yang melakukan keberangkatan dan kedatangan di Bandara Internasional Juanda. Rentang waktu yang digunakan adalah mulai dari Januari 2011 hingga Desember 2016. Dan dalam tahap ini dilakukan uji realibilitas dan validitas terhadap data yang akan digunakan apakah data tersebut layak untuk digunakan dalam melakukan peramalan.



### **3.3. Proses Analisis Model ARIMA**

Pembentukan model ARIMA untuk melakukan peramalan data penumpang di Bandara Internasional Juanda yaitu dengan cara:

#### **3.3.1. Analisa Data**

Melakukan analisa data dengan melakukan pengujian kestasioneran data dengan melihat plot data dengan cara melihat grafik yaitu plot ACF dan PACF. Jika data tidak stasioner maka harus dilakukan proses stasioner terlebih dahulu dengan proses differencing atau pembedaan

#### **3.3.2. Uji Stasioner Data**

Pada tahap ini data diharuskan stasioner dalam ragam maupun rata-rata, jika data telah stasioner dalam ragam maupun rata-rata bias dilanjutkan pada pemodelan ARIMA. Namun jika belum stasioner dalam ragam harus dilakukan transformasi data, namun data yang tidak stasioner dalam rata-rata harus dilakukan differencing data.

#### **3.3.3. Pemodelan ARIMA**

Apabila data telah stasioner dalam ragam maupun rata-rata maka tahap selanjutnya adalah pemodelan ARIMA. Dimana tahap pemodelan ARIMA terdapat beberapa tahapan, yaitu:

##### **3.3.3.1. Estimasi Parameter**

Dalam melakukan estimasi parameter memiliki dua cara yang mendasar yaitu menggunakan *trial and error* dan perbaikan secara iterative. *Trial and error* dilakukan dengan cara menguji beberapa nilai yang berbeda dan memilih satu nilai tersebut (atau sekumpulan nilai, apabila terdapat lebih dari satu parameter yang akan diramalkan) yang meminimumkan jumlah kuadrat nilai sisa (*sum of squared residual*). Pada perbaikan secara iterative dilakukan dengan cara memilih taksiran awal

dan kemudian membiarkan program computer memperhalus penaksiran tersebut secara iterative.

### **3.3.3.2. Uji Signifikansi Parameter**

Tahap ini untuk menguji model yang telah ditentukan pada tahap sebelumnya. Pengujian dilakukan untuk menentukan model layak atau tidak untuk dilanjutkan proses selanjutnya. Model dapat dikatakan layak jika memiliki nilai probabilitas  $variable \leq 0,05$

### **3.3.3.3. Uji Signifikansi Model**

Pada tahap ini model akan diuji untuk mengetahui apakah model bersifat acak dan homogen. Ketika model tidak acak dan homogenitas, maka data dikatakan tidak layak.

### **3.3.4. Forecasting**

Setelah semua tahap dilakukan maka dapat dilakukan peramalan dan penarikan kesimpulan. Peramalan ini sebenarnya merupakan penjabaran dari persamaan berdasarkan koefisien-koefisien yang didapat, sehingga dapat menentukan kondisi di masa yang akan datang

## **3.4. Model Penelitian dengan ANN**

Metode peramalan yang menggunakan ANN adalah model yang dibentuk menggunakan algoritma *backpropagation* tersebut dipakai untuk meramalkan data jumlah penumpang penerbangan terminal 1 di Bandara Internasional Juanda. Peramalan ini dilakukan menggunakan *tools* RapidMiner. Tahapan yang dilakukan sebagai berikut [24]:

#### **a. Pelatihan**

Tahap pelatihan ini adalah proses pengenalan dari pola-pola data yang telah dinormalisasi dengan tujuan untuk mendapatkan nilai bobot yang dapat memetakan antara data input dengan data target yang diinginkan. Bobot yang

dihasilkan dalam tiap putaran dapat diubah dan dilakukan secara berulang-ulang sampai mencapai batas pelatihan. Dalam tahap ini, besarnya parameter yang diberikan secara manual sehingga didapatkan jaringan dengan tingkat pengenalan yang optimal. Parameter-parameter tersebut meliputi jumlah maksimum iterasi, besarnya kecepatan pembelajaran, besarnya kinerja tujuan atau *goal*, dan jumlah *neuron* pada *hidden layer*. Pelatihan dilakukan dengan algoritma *backpropagation* yang terdiri dari tiga fase, yaitu umpan maju (*feedforward*), propagasi mundur (*backpropagation*) dan pembaruan bobot dan bias. Hasilnya yang didapatkan berupa pembaruan bobot jaringan yang nantinya akan digunakan dalam tahap *testing* jaringan.

b. Pengujian

Setelah dilakukan pelatihan jaringan menggunakan data *training*, akan diperoleh nilai-nilai bobot dan bias terbaik yang mewakili system jaringan. Nilai bobot dan bias baru diterapkan pada data *testing* untuk menghasilkan ramalan data runtun waktu yang diinginkan. Jika jaringan diberikan *input*, maka jaringan akan dapat menghasilkan *output* seperti yang diharapkan. Dengan cara menerapkan algoritma *backpropagation* kembali namun hanya fase *feedforward*. Tahap *testing* dilakukan untuk mengetahui apakah jaringan dapat bekerja dengan baik dalam meramalkan pola data yang telah dilatihkan dengan tingkat kesalahan yang kecil.

c. Peramalan dengan ANN

Model dengan tingkat pengenalan terbaik dalam proses *testing* dapat digunakan untuk proses meramalkan data pada masa yang akan datang. Tujuan dari peramalan ini adalah memperkirakan jumlah penumpang penerbangan

domestic untuk tiga period eke depan. Hasil dari data historis jumlah penumpang diumpangkan ke dalam ANN yang telah disimpan dan diolah dengan bobot atau bias tertentu, sehingga didapatkan jumlah penumpang menggunakan ANN.

### **3.5. Metode *Hybrid* (ARIMA-ANN)**

Langkah-langkah dalam meramalkan jumlah penumpang dengan metode *hybrid* ARIMA-ANN adalah:

1. Melakukan pemodelan dan peramalan menggunakan model ARIMA terbaik.
2. Setelah diperoleh residual dari model ARIMA, langkah selanjutnya adalah melakukan peramalan residual dari model ARIMA tersebut dengan menggunakan metode jaringan syaraf tiruan.
3. Hasil peramalan diperoleh dari selisih antara nilai data actual dan hasil peramalan residual menggunakan metode jaringan syaraf tiruan.

### **3.6. Analisa Hasil Peramalan**

Pada tahap analisis hasil peramalan, dilakukan analisis terhadap model yang telah dibuat, apakah model tersebut sudah tepat dalam melakukan peramalan data jumlah penumpang pesawat di Bandara Internasional Juanda. Dimana Analisa ini berupa perbandingan hasil peramalan yang dilakukan dengan metode ARIMA dan *hybrid* ARIMA-ANN dengan menggunakan data aktual. Pada analisis ini juga dapat dilihat dari tingkat kesalahan atau error dari ketiga metode tersebut.

### **3.7. Penyusunan Tugas Akhir**

Setelah dilakukan seluruh tahap 1-6 maka tahap akhir yang akan dilakukan oleh penulis adalah melakukan dokumentasi dari

hasil penelitian tugasakhir yang terdiri dari tujuh bab yang terdiri dari:

**a. Bab I Pendahuluan**

Bab ini menjelaskan mengenai latar belakang, rumusan masalah, batasan masalah, tujuan penelitian, manfaat penelitian, dan relevansi dalam pengerjaan tugas akhir ini.

**b. Bab II Tinjauan Pustaka**

Bab ini menjelaskan mengenai penelitian sebelumnya yang berkaitan dengan tugas akhir. Selanjutnya dalam bab ini dibahas tentang teori-teori yang digunakan sebagai dasae dalam pengerjaan tugas akhir ini.

**c. Bab III Metodologi**

Bab ini menjelaskan mengenai tahapan-tahapan yang harus dilakukan dalam pengerjaan tugas akhir ini.

**d. Bab IV Rancangan**

Bab ini menjelaskan tentang rancangan tugas akhir dalam pembuatan model peramalan. Dalam bab ini terdiri dari proses pengumpulan data, gambaran data masukan, dan keluaran, serta pengolahan data yang akan dilakukan.

**e. Bab V Implementasi**

Bab ini menjelaskan bagaimana proses dalam pembuatan model yang akan digunakan dalam peramalan. Dimulai dari pengujian terhadap data yang dimiliki hingga model terbentuk.

**f. Bab VI Hasil dan Pembahasan**

bab ini akan membahas hasil dari implementasi. Hasil yang dijelaskan berupa hasil ujicoba dan hasil peramalan untuk periode mendatang

**g. Bab VII Kesimpulan dan Saran**

Bab ini berisi tentang kesimpulan dan saran yang ditujukan untuk kelengkapan dalam penyempurnaan tugas akhir ini

*(Halaman ini sengaja dikosongkan)*

## **BAB IV**

### **PERANCANGAN**

Tujuan dari pengerjaan tugas akhir ini adalah untuk menghasilkan model dan hasil peramalan untuk peramalan jumlah penumpang domestic pada terminal 1 Bandara Juanda dengan menggunakan ARIMA dan *Hybrid* ARIMA-ANN. Untuk mencapai tujuan dari pengerjaan tugas akhir ini, pada bab perancangan akan dijelaskan tentang Proses Persiapan Data, Analisis Model ARIMA, Model Penelitian dengan ANN, *Hybrid* ARIMA-ANN, dan Analisa Hasil Peramalan.

#### **4.1. Persiapan Data**

Pada tahap ini dilakukan proses pengumpulan data dan pengolahan data awal hingga data dapat digunakan dalam pengerjaan tugas akhir ini. Data yang digunakan pada tugas akhir ini adalah data jumlah penumpang domestic di terminal 1 Bandara Juanda. Dari data jumlah penumpang domestic ini didapatkan dari PT. Angkasa Pura I Juanda, variable yang diambil adalah data jumlah penumpang keberangkatan dan kedatangan domestic di terminal 1. Data jumlah penumpang keberangkatan dapat dilihat pada Lampiran A dan kedatangan dapat dilihat pada Lampiran B.

##### **4.1.1. Pengumpulan Data**

Bahan penelitian dalam tugas akhir ini adalah data jumlah penumpang keberangkatan dan kedatangan domestic di terminal 1 Bandara Juanda dalam kurun waktu Januari 2007 – Maret 2017. Data yang digunakan pada tugas akhir ini berupa data bulanan.

### **4.1.2. Pra-proses Data**

Pada pra-proses data ini digunakan untuk pengolahan data awal yang telah didapatkan. Setelah mendapatkan data yang dibutuhkan dalam penelitian, dilakukan pra-proses data yaitu, menjadikan seluruh data jumlah penumpang keberangkatan dan kedatangan dalam periode bulanan.

Tahap pro-proses data berikutnya adalah melakukan pengujian outlier data. Pengujian outlier dilakukan menggunakan *Grubb's* dengan tingkat signifikansi sebesar 95%. Data dinyatakan tidak terdapat outlier didalamnya apabila nilai probabilitas = 1. Outlier test yang dilakukan pada seluruh data menggunakan program Minitab.

### **4.1.3. Menentukan Data Pelatihan dan Pengujian**


Data jumlah penumpang keberangkatan dan kedatangan yang telah dijadikan dalam periode mingguan, dikelompokkan menjadi tiga kelompok yaitu data pelatihan, data pengujian pertama, dan data pengujian kedua dengan proporsi 70%, 20%, dan 10%. Data yang digunakan untuk data pelatihan adalah 70% dari total data yang dimiliki yaitu sebanyak 88 data, dari Januari 2007 – April 2014. Data pengujian pertama sebanyak 20% atau 25 data, dari Mei 2014 – Mei 2016. Data pengujian sebanyak 10% atau 10 data, dari Juni 2016 – Maret 2017.

## **4.2. Metode Penelitian dengan ARIMA**


### **4.2.1. Gambaran Data Masukan**

Gambaran data masukan adalah gambaran grafik data setelah dilakukan pra-proses dapat dilihat pada Gambar 4.1 dan Gambar 4.2. Data masukan yaitu penumpang domestik pada kedatangan dan data penumpang pada keberangkatan secara lengkap terdapat dalam Lampiran A.





**Gambar 4. 1 Grafik Jumlah Penumpang Kedatangan di Terminal 1 Juanda Januari 2007 - Maret 2017**



**Gambar 4. 2 Grafik Jumlah Penumpang Keberangkatan di Terminal 1 Juanda Januari 2007 - April 2014**

#### 4.2.2. Uji Stasioner Ragam

Pada uji stasioner ragam dilakukan dengan menggunakan uji *Barlett* dengan menggunakan fungsi *Box-Cox Transformation* yang dilakukan menggunakan *software Minitab*. Data dapat dikatakan sudah stasioner dalam ragam jika *rounded value* = 1, uji stasioner ragam dilakukan dengan tingkat signifikansi 95% [25]. Apabila nilai *rounded value* = 1, maka tidak perlu dilakukan transformasi data [26]. Apabila nilai *rounded value*  $\neq$  1, hal itu menunjukkan bahwa data tidak stasioner dalam ragam sehingga data tidak dapat langsung digunakan untuk proses selanjutnya. Untuk membuat data yang tidak stasioner menjadi stasioner dalam ragam, maka perlu dilakukan transformasi data.

#### 4.2.3. Transformasi Data

Transformasi data dilakukan jika dalam tahap uji stasioner ragam, data dinyatakan belum stasioner. Metode transformasi yang digunakan dalam pengerjaan tugas akhir ini menggunakan transformasi *Box-Cox*. Dalam melakukan transformasi data menggunakan fungsi *log* dengan menggunakan *Generate by Equation* yang ada pada *software Eviews*. Dalam transformasi *Box-Cox*, transformasi yang sering dilakukan adalah dengan melakukan transformasi *log* yang dilambangkan dengan lamda 0 [26]. Untuk melakukan transformasi data bisa memasukkan persamaan *data transformasi* =  $\log(\text{data aktual})$ .

#### 4.2.4. Uji Stasioner Rataan

Setelah data yang diolah dipastikan sudah stasioner dalam ragam, maka selanjutnya dilakukan uji stasioner rataaan untuk mengetahui kestasioneritas data dalam rataaan. Untuk melakukan pengujian ini, dilakukan menggunakan fungsi *unit root test* pada program *Eviews*. Data dapat dikatakan sudah stasioner dalam rataaan apabila hasil uji *unit root test*

menunjukkan bahwa nilai probabilitas  $\leq 0,05$  dan juga nilai  $|t - statistic| \geq |test\ critical\ values|$  [27].

#### **4.2.5. Differencing Data**

Differencing data dilakukan apabila data tidak stasioner dalam rataan dalam uji stasioner rataan. Differencing dilakukan menggunakan *unit root test* pada *software Eviews*. Differencing data dapat dilakukan sebanyak dua kali atau lebih hingga data yang diolah dinyatakan sudah stasioner, jika pada differencing pertama data tidak menunjukkan stasioner. Data dikatakan stasioner dalam rataan jika nilai probabilitas  $\leq 0,05$  dan nilai  $|t - statistic| \geq |test\ critical\ values|$  [28]. Apabila pada differencing pertama dan kedua data sudah stasioner dalam rataan, kedua level differencing dapat digunakan dalam pemodelan estimasi parameter dengan tujuan memperbanyak kemungkinan model yang dapat digunakan.

#### **4.2.6. Pemodelan ARIMA**

Pemodelan ARIMA digunakan untuk menentukan model arima yang akan digunakan dalam tugas akhir ini. Data yang akan dimodelkan adalah data yang sudah stasioner dalam ragam dan rataan. Dan juga model ARIMA dilakukan setelah proses transformasi dan dan dimodelkan menggunakan proses *differencing*.

##### **4.2.6.1. Estimasi Parameter ARIMA**

Estimasi parameter dilakukan untuk menentukan model yang digunakan dalam ARIMA yaitu AR, MA, ARMA, atau ARIMA. Untuk menentukan model yang akan diestimasi dapat ditentukan dari ordo masing-masing dengan melihat lag pada grafik *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF). Untuk menentukan

parameter dilihat dari fungsi ACF dan PACF menggunakan fungsi *Correlogram* pada *Eviews*.

#### 4.2.6.2. Uji Signifikansi Parameter ARIMA

Uji signifikansi parameter dilakukan untuk menguji kelayakan model ARIMA yang telah dimodelkan sebelumnya. Model dapat dikatakan layak, apabila nilai probabilitas seluruh variable  $\leq 0,05$  dan  $|t - statistic| \text{ seluruh variabel} > t - \text{tabel}$ . Uji signifikansi parameter dilakukan menggunakan fungsi *Quick Estimation* pada program *Eviews*. Persamaan yang digunakan dalam *Eviews* untuk differencing 1 adalah  $d(\text{Data Transformasi}) ar(p) ma(q)$  dan untuk differencing 2 adalah  $d(\text{Data Transformasi}, 2) ar(p) ma(q)$ . Dimana data transformasi adalah data actual yang telah dilakukan transformasi data pada tahap sebelumnya. Jika model yang telah ditentukan tidak signifikan, maka model tidak layak atau tidak dapat dilanjutkan untuk tahap selanjutnya.

#### 4.2.6.3. Uji Diagnostik Parameter ARIMA

Tahap uji diagnostik dapat dilakukan dengan menggunakan model yang telah signifikan, uji diagnostik dilakukan untuk menentukan kelayakan model ARIMA dari residual model. Uji diagnostik parameter juga digunakan untuk mengetahui bahwa model yang didapatkan bersifat acak dan homogenitas sisaan.

Uji diagnostik parameter dilakukan dengan menggunakan fungsi *Correlogram - Q Statistic* pada program *Eviews*. Model dapat dinyatakan diterima dari uji keacakan sisaan apabila tidak memiliki pola tertentu yaitu apabila rata-rata seluruh nilai probabilitas  $\geq 0,05$ . Sedangkan untuk pengujian homogenitas sisaan dilakukan dengan menggunakan fungsi *Correlogram Squared Residuals* pada program *Eviews*. Model dapat

dinyatakan diterima dari uji homogenitas sisaan apabila rata-rata seluruh nilai probabilitas  $\geq 0,05$ .

#### **4.2.6.4. Pemodelan Model Terbaik**

Pada tahap ini dilakukan ketika model yang didapatkan pada tahap sebelumnya lebih dari satu model. Penentuan model terbaik dilakukan dengan melihat nilai AIC dan SIC yang memiliki nilai terkecil.

#### **4.2.7. Peramalan Penumpang Domestik**

Peramalan pada periode mendatang jumlah penumpang kedatangan dan keberangkatan dilakukan menggunakan model ARIMA terbaik yang sebelumnya telah diuji dan dipilih menjadi yang terbaik. Peramalan dilakukan dengan menggunakan program *Eviews*

#### **4.2.8. Ketepatan Model Peramalan**

Ketepatan model peramalan dilakukan setelah mendapatkan model ARIMA terbaik dan telah melakukan peramalan dengan menggunakan data jumlah penumpang kedatangan dan keberangkatan. Hal tersebut perlu dilakukan untuk mengetahui tingkat keakuratan model yang telah didapatkan dalam melakukan peramalan. Untuk menghitung ketepatan model ARIMA dapat dilakukan dengan mengukur nilai MAPE (*Mean Absolute Percentage Error*) dengan cara menghitung perbandingan antara data actual dan hasil peramalan dengan menggunakan *Microdoft Excel*.

### **4.3. Metode *Hybrid* ARIMA-ANN**

Tahap selanjutnya adalah melakukan metode *hybrid* dengan menggunakan nilai *error* yang dihasilkan dari peramalan ARIMA untuk nilai *input* ANN yang akan diolah menggunakan program *RapidMinner*.

### 4.3.1. Pra-Proses Data

Data yang digunakan dalam pengerjaan tugas akhir ini adalah nilai error yang didapatkan dari hasil peramalan ARIMA baik dari data jumlah penumpang kedatangan keberangkatan di terminal 1 Bandara Juanda Surabaya. Data yang akan digunakan dapat dilihat pada LAMPIRAN D.

### 4.3.2. Perancangan Model ANN

Dalam perancangan model, hal yang dilakukan pertama adalah menyiapkan data untuk pelatihan dan data pengujian. Komposisi data pelatihan sebesar 70% dari keseluruhan data, yaitu sebanyak 88 data, data pengujian satu sebesar 20% dari keseluruhan data, yaitu sebanyak 25 data, dan data pengujian kedua sebanyak 10% dari keseluruhan data, yaitu sebanyak 10 data.

Rancangan arsitektur ANN yang digunakan dalam tugas akhir ini terdiri dari *input layer*, *hidden layer* dan *output layer* beserta parameter yang akan digunakan dalam proses pelatihan. Pada *hidden layer* terdiri dari satu lapisan. Lapisan ini berisi neuron dengan fungsi aktivasi sigmoid. Jumlah neuron pada *hidden layer* ditentukan dengan proses *trial & error*.

**Tabel 4. 1 Tabel Perancangan Model ANN**

Parameter	Jumlah	Deskripsi
Input Layer	8-96 neuron	Berdasarkan asumsi pengaruh periode berikutnya
Hidden Layer	<i>Trial and Error</i>	Hasil percobaan

Parameter	Jumlah	Deskripsi
	<i>dengan 2-9 neuron</i>	
Output Layer	1 neuron	Ramalan jumlah penumpang kedatangan atau keberangkatan
Epoch	<i>Trial and Error</i>	100-500
Learning Rate	<i>Trial and Error</i>	0.1-0.9
Momentum	<i>Trial and Error</i>	0.1-0.9

#### 4.3.3. Peramalan Penumpang Domestik

Pada tahap peramalan yang dilakukan menggunakan *hybrid* ARIMA-ANN adalah dengan menggunakan nilai peramalan dari *error*, lalu *diconvert* menggunakan *Write Excel* yang akan disimpan dalam *file Excel* baru. Selanjutnya dilakukan proses penghitungan untuk menentukan nilai *forecast* yang dihasilkan dengan menggunakan metode *hybrid* ARIMA-ANN

*nilai forecast hybrid ARIMA – ANN*

= *nilai aktual – nilai error hybrid (ARIMA – ANN)*

#### 4.3.4. Ketepatan Model Peramalan

Ketepatan model peramalan dilakukan setelah mendapatkan model *hybrid* ARIMA-ANN terbaik dan telah melakukan peramalan dengan menggunakan data jumlah penumpang kedatangan dan keberangkatan. Hal tersebut perlu dilakukan untuk mengetahui tingkat keakuratan model yang telah didapatkan dalam melakukan peramalan. Untuk menghitung

ketepatan model *hybrid* ARIMA-ANN dapat dilakukan dengan mengukur nilai MAPE (*Mean Absolute Percentage Error*) dengan cara menghitung perbandingan antara data actual dan hasil peramalan dengan menggunakan *Microdoft Excel*.



## BAB V IMPLEMENTASI

### 5.1. Implementasi Model ARIMA

#### 5.1.1. Pengujian Outlier

Di tahap pertama ini dilakukan pra-proses data seperti yang dijelaskan pada bab 4.1.2. Pengujian outlier dilakukan dengan menggunakan metode *Grubb's* pada fungsi *outlier test* pada minitab dengan tingkat signifikansi 95%. Pada Gambar 5.1 menunjukkan hasil pengujian outlier pada jumlah penumpang kedatangan menggunakan *Grubbs Test*.

Null hypothesis	All data values come from the same normal population						
Alternative hypothesis	Smallest or largest data value is an outlier						
Significance level	$\alpha = 0,05$						
Grubbs' Test							
Variable	N	Mean	StDev	Min	Max	G	P
Kedatangan	210	501773	148729	249045	886902	2,59	1,000
* NOTE * No outlier at the 5% level of significance							

**Gambar 5. 1 Hasil Uji Outlier Data Penumpang Kedatangan Menggunakan Grubb's**

Pada tingkat signifikansi 95% tidak ditemukan *outlier* pada jumlah penumpang kedatangan Bandara Juanda. Hal ini ditunjukkan pada Gambar 5.1 dengan nilai probabilitas sebesar 1,000. Pada Gambar 5.2 juga menunjukkan hasil pengujian *outlier* pada jumlah penumpang keberangkatan.

Null hypothesis	All data values come from the same normal population						
Alternative hypothesis	Smallest or largest data value is an outlier						
Significance level	$\alpha = 0,05$						
Grubbs' Test							
Variable	N	Mean	StDev	Min	Max	G	P
C1	123	480602	134605	221823	825715	2,56	1,000
* NOTE * No outlier at the 5% level of significance							

**Gambar 5. 2 Uji Outlier Jumlah Penumpang Keberangkatan Bandara Juanda Menggunakan Grubb's**


Pada tingkat signifikansi 95% tidak ditemukan *outlier* pada jumlah penumpang kedatangan Bandara Juanda. Hal ini ditunjukkan pada Gambar 5.2 dengan nilai probabilitas sebesar 1,000

### 5.1.2. Menentukan Data Pelatihan dan Data Pengujian

Pada tahap ini, data akan dikelompokkan menjadi tiga kelompok yaitu data pelatihan, data pengujian pertama, dan data pengujian kedua dengan proporsi 70:20:10. Total data yang didapatkan sejumlah 123 data (Januari 2007 – Maret 2017), sehingga data yang akan digunakan sebagai data pelatihan sejumlah 88 data (Januari 2007 – April 2014), data yang digunakan untuk pengujian pertama sejumlah 25 data (Mei 2014 – Mei 2016), dan data pengujian kedua sejumlah 10 data (Juni 2016 – Maret 2017).


### 5.1.3. Uji Stasioneritas Ragam

Uji stasioner ragam dilakukan pada data penumpang kedatangan Bandara Juanda. Dalam melakukan uji stasioneritas ragam, memiliki beberapa kriteria yang ditunjukkan pada bab 4.2.2. Gambar 5.3 menunjukkan hasil uji stasioner ragam terhadap data penumpang kedatangan di Juanda



Gambar 5. 3 Uji Stasioneritas Ragam pada Data Penumpang Kedatangan

Hasil uji stasioneritas ragam pada Gambar 5.3 menunjukkan bahwa, data jumlah penumpang kedatangan di Bandara Juanda yang didapat tidak stasioner dalam ragam. Hal ini dapat dilihat dari nilai *rounded value* menunjukkan nilai 0,00 atau  $\neq 1$ .




**Gambar 5. 4 Uji Stasioneritas Ragam pada Data Penumpang Keberangkatan**

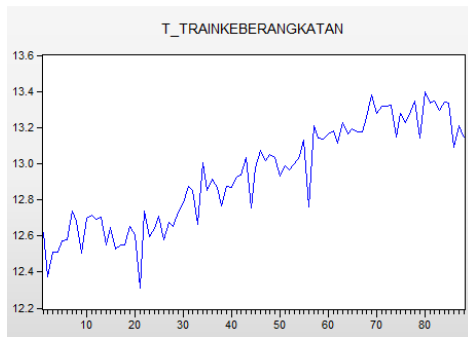
Hasil uji stasioneritas ragam pada Gambar 5.4 menunjukkan bahwa data jumlah penumpang keberangkatan di Bandara Juanda yang didapat tidak stasioner dalam ragam. Hal ini dapat dilihat dari nilai *rounded value* menunjukkan nilai 0,50 atau  $\neq 1$ . Sehingga untuk data jumlah penumpang kedatangan dan keberangkatan di Bandara Juanda harus melakukan proses transformasi data.

#### 5.1.4. Transformasi Data

Transformasi data dilakukan setelah uji stasioneritas ragam, transformasi data menggunakan transformasi *Box-Cox* dengan lambda ( $\lambda$ ) = 0. Transformasi data dilakukan pada data jumlah penumpang kedatangan karena dari hasil stasioneritas ragam menyatakan data tidak stasioner dalam ragam. Sehingga perlu dilakukan transformasi data dengan menggunakan persamaan  $[data\ transformasi] = \log([data\ aktual])$ . Gambar 5.5 dan Gambar 5.6 menunjukkan hasil transformasi data jumlah penumpang kedatangan dan keberangkatan di Bandara Juanda



**Gambar 5. 5 Transformasi Jumlah Penumpang Kedatangan**



**Gambar 5. 6 Transformasi Jumlah Penumpang Keberangkatan**

### 5.1.5. Uji Stasioneritas Rataan

Uji stasioneritas rataan dilakukan pada data jumlah penumpang kedatangan dan keberangkatan terminal 1 di Bandara Juanda. Pada Gambar 5.7 menunjukkan hasil uji stasioner rataan jumlah penumpang kedatangan terminal 1 di Bandara Juanda

Null Hypothesis: TKEDATANGAN has a unit root		
Exogenous: Constant		
Lag Length: 1 (Automatic - based on SIC, maxlag=11)		
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.669269	0.4431
Test critical values:		
1% level	-3.508326	
5% level	-2.895512	
10% level	-2.584952	

\*Mackinnon (1996) one-sided p-values.

**Gambar 5. 7 Uji Stasioneritas Rataan Jumlah Penumpang Kedatangan**

Dari hasil uji stasioneritas rataaan pada Gambar 5.6, menunjukkan bahwa nilai probabilitas 0,4431 atau  $> 0,05$  dan  $|t - statistic| < |test\ critical\ values|$ . Berdasarkan hasil tersebut, maka data jumlah penumpang kedatangan terminal 1 Bandara Juanda tidak stasioner dalam rataaan. Sehingga langkah selanjutnya adalah melakukan proses *differencing* data.

Uji stasioneritas selanjutnya adalah jumlah penumpang keberangkatan terminal 1 Bandara Juanda yang ditunjukkan pada Gambar 5.8.

Null Hypothesis: T_TRAINKEBERANGKATAN has a unit root		
Exogenous: Constant, Linear Trend		
Lag Length: 1 (Automatic - based on SIC, maxlag=11)		
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-3.997036	0.0123
Test critical values:		
1% level	-4.068290	
5% level	-3.462912	
10% level	-3.157836	

\*MacKinnon (1996) one-sided p-values.

### Gambar 5. 8 Uji Stasioneritas Rataan Jumlah Penumpang Keberangkatan

Dari hasil uji stasioneritas rataaan pada Gambar 5.8, menunjukkan bahwa nilai probabilitas 0,0123 atau  $< 0,05$  dan  $|t - statistic| > |test\ critical\ values|$ . Berdasarkan hasil tersebut, maka data jumlah penumpang keberangkatan terminal 1 Bandara Juanda stasioner dalam rataaan. Sehingga langkah selanjutnya adalah melakukan mengestimasi parameter model ARIMA tanpa melakukan *differencing* data.

#### 5.5.1. Differencing Data

Proses *differencing* dilakukan jika data yang diolah tidak stasioner dalam rataaan, sehingga data jumlah penumpang kedatangan melalui proses *differencing*.

Null Hypothesis: D(TKEDATANGAN) has a unit root  
 Exogenous: Constant  
 Lag Length: 0 (Automatic - based on SIC, maxlag=11)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-15.79764	0.0001
Test critical values:		
1% level	-3.508326	
5% level	-2.895512	
10% level	-2.584952	

\*MacKinnon (1996) one-sided p-values.

### Gambar 5. 9 Uji Stasioner Rataan Differencing 1 Jumlah Penumpang Kedatangan

Dari hasil uji stasioneritas rataaan *differencing* 1 pada Gambar 5.9, menunjukkan bahwa nilai probabilitas 0,0001 atau  $< 0,05$  dan  $|t - statistic| > |test critical values|$ . Berdasarkan hasil tersebut, maka data jumlah penumpang kedatangan terminal 1 Bandara Juanda telah stasioner dalam rataaan. Sehingga tidak perlu dilakukan proses *differencing* selanjutnya, namun untuk menambah kemungkinan estimasi parameter ARIMA maka selanjutnya dilakukan proses *differencing* 2 yang dilakukan pada Gambar 5.10.

Null Hypothesis: D(T\_TRANKEDATANGAN,2) has a unit root  
 Exogenous: Constant, Linear Trend  
 Lag Length: 10 (Automatic - based on SIC, maxlag=11)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-4.475569	0.0031
Test critical values:		
1% level	-4.085092	
5% level	-3.470851	
10% level	-3.162458	

\*MacKinnon (1996) one-sided p-values.

### Gambar 5. 10 Uji Stasioner Rataan Differencing 2 Jumlah Penumpang Kedatangan

Dari hasil uji stasioneritas rataaan *differencing* 2 pada Gambar 5.10, menunjukkan bahwa nilai probabilitas 0,0031 atau  $< 0,05$  dan  $|t - statistic| > |test critical values|$ . Berdasarkan hasil tersebut, maka data jumlah penumpang kedatangan terminal 1 Bandara Juanda telah stasioner dalam rataaan. Sehingga data dapat dilanjutkan proses selanjutnya.

Null Hypothesis: D(T\_TRAINKEBERANGKATAN,2) has a unit root  
 Exogenous: Constant, Linear Trend  
 Lag Length: 11 (Automatic - based on SIC, maxlag=11)

		t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic		-5.984367	0.0000
Test critical values:	1% level	-4.086877	
	5% level	-3.471693	
	10% level	-3.162948	

\*Mackinnon (1996) one-sided p-values.

**Gambar 5. 11 Uji Stasioner Rataan Differencing 2 Jumlah Penumpang Keberangkatan**

Pada Gambar 5.11 untuk menambahkan kemungkinan parameter maka dilakukan proses *differencing*. Dari hasil uji stasioneritas rataaan *differencing* 2 pada Gambar 5.11, menunjukkan bahwa nilai probabilitas 0,0000 atau  $< 0,05$  dan  $|t - statistic| > |test\ critical\ values|$ . Berdasarkan hasil tersebut, maka data jumlah penumpang keberangkatan terminal 1 Bandara Juanda telah stasioner dalam rataaan. Sehingga data dapat dilanjutkan proses selanjutnya.

## 5.5.2. Pemodelan ARIMA

### 5.5.2.1. Estimasi Parameter ARIMA

Estimasi parameter dilakukan pada data jumlah penumpang kedatangan dan keberangkatan terminal 1 Bandara Juanda yang telah stasioner dalam ragam dan rataaan. Untuk menentukan parameter dilihat dari fungsi ACF dan PACF dari data yang telah stasioner. Menentukan estimasi parameter ARIMA dilakukan berdasarkan fungsi ACF dan PACF, pada Gambar 5.12 merupakan grafik ACF dan PACF yang dilakukan menggunakan data penumpang kedatangan. Estimasi parameter untuk *differencing* 1 pada data penumpang kedatangan ini berupa  $AR = 0,1,2,3$  dan  $MA = 0,1$  sehingga estimasi parameter *differencing* 1 dapat dilihat pada Tabel 5.1.

Date: 07/08/17 Time: 09:00  
Sample: 1 88  
Included observations: 87

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.476	-0.476	20.425	0.000
		2 0.048	-0.231	20.637	0.000
		3 0.040	-0.057	20.785	0.000
		4 -0.162	-0.208	23.218	0.000
		5 0.240	0.091	28.658	0.000
		6 -0.269	-0.171	35.553	0.000
		7 0.275	0.145	42.879	0.000
		8 -0.105	0.057	43.959	0.000
		9 -0.022	0.055	44.010	0.000
		10 -0.047	-0.166	44.230	0.000
		11 -0.213	-0.348	48.859	0.000
		12 0.456	0.176	70.308	0.000
		13 -0.261	0.099	77.431	0.000
		14 0.050	-0.017	77.694	0.000
		15 -0.007	-0.096	77.699	0.000

**Gambar 5. 12 Estimasi Parameter ARIMA Data Jumlah Penumpang Kedatangan, d=1**

Hasil estimasi parameter ARIMA terdapat pada Tabel 5.1. Pada Tabel 5.1 estimasi parameter ARIMA menggunakan hasil *differencing* 1.


**Tabel 5. 1 Estimasi Parameter ARIMA Jumlah Penumpang Kedatangan, d=1**

Variabel	Estimasi Parameter
Jumlah Penumpang Kedatangan	ARIMA (0,1,1)
	ARIMA (1,1,0)
	ARIMA (1,1,1)
	ARIMA (2,1,0),
	ARIMA (2,1,1),
	ARIMA (3,1,0)
	ARIMA (3,1,1)

Menentukan estimasi parameter ARIMA dilakukan berdasarkan fungsi ACF dan PACF, pada Gambar 5.13 merupakan grafik ACF dan PACF yang dilakukan menggunakan data penumpang kedatangan. Estimasi parameter untuk *differencing* 2 pada data penumpang kedatangan ini



berupa  $AR = 0,1,2$  dan  $MA = 0,1,2,3$  sehingga estimasi parameter *differencing* 2 dapat dilihat pada Tabel 5.2.



**Gambar 5. 13** Estimasi Parameter ARIMA Data Jumlah Penumpang Kedatangan,  $d=2$


Untuk estimasi selanjutnya hasil estimasi parameter ARIMA terdapat pada Tabel 5.2. Pada Tabel 5.2 estimasi parameter ARIMA menggunakan hasil *differencing* 2.

**Tabel 5. 2** Estimasi Parameter ARIMA Jumlah Penumpang Kedatangan,  $d=2$

Variabel	Estimasi Parameter
Jumlah Penumpang Kedatangan	ARIMA (0,2,1)
	ARIMA (0,2,2)
	ARIMA (0,2,3)
	ARIMA (1,2,0)
	ARIMA (1,2,1)
	ARIMA (1,2,2)
	ARIMA (1,2,3)
	ARIMA (2,2,0)
	ARIMA (2,2,1)

Variabel	Estimasi Parameter
	ARIMA (2,2,2)
	ARIMA (2,2,3)

Menentukan estimasi parameter ARIMA dilakukan berdasarkan fungsi ACF dan PACF, pada Gambar 5.14 merupakan grafik ACF dan PACF yang dilakukan menggunakan data penumpang keberangkatan. Estimasi parameter pada data penumpang kedatangan ini berupa AR = 0,1,2,3 dan MA = 0,1 sehingga estimasi parameter dapat dilihat pada Tabel 5.3.



**Gambar 5. 14 Estimasi Parameter ARMA Data Jumlah Penumpang Kedatangan**


Untuk estimasi selanjutnya hasil estimasi parameter ARMA terdapat pada Tabel 5.3. Pada Tabel 5.3 estimasi parameter ARMA tidak menggunakan *differencing*

**Tabel 5. 3 Estimasi Parameter ARMA Jumlah Penumpang Keberangkatan**

Variabel	Estimasi Parameter
	ARMA (0,1)

Variabel	Estimasi Parameter
Jumlah Penumpang Keberangkatan	ARMA (1,0)
	ARMA (1,1)
	ARMA (2,0)
	ARMA (2,1)
	ARIMA (3,0)
	ARIMA (3,1)

Menentukan estimasi parameter ARIMA dilakukan berdasarkan fungsi ACF dan PACF, pada Gambar 5.15 merupakan grafik ACF dan PACF yang dilakukan menggunakan data penumpang keberangkatan. Estimasi parameter pada data penumpang kedatangan ini berupa AR = 0,1,2,3 dan MA = 0,1,2,3 sehingga estimasi parameter dapat dilihat pada Tabel 5.4.



**Gambar 5. 15** Estimasi Parameter ARIMA Data Jumlah Penumpang Keberangkatan,  $d=2$

Untuk estimasi selanjutnya hasil estimasi parameter ARIMA terdapat pada Tabel 5.4. Pada Tabel 5.4 estimasi parameter ARIMA menggunakan hasil *differencing* 2.

**Tabel 5. 4** Estimasi Parameter ARIMA Jumlah Penumpang Keberangkatan,  $d=2$

Variabel	Estimasi Parameter
	ARIMA (0,2,1)

Variabel	Estimasi Parameter
Jumlah Penumpang Keberangkatan	ARIMA (0,2,2)
	ARIMA (0,2,3)
	ARIMA (1,2,1)
	ARIMA (1,2,2)
	ARIMA (1,2,3)
	ARIMA (2,2,1)
	ARIMA (2,2,2)
	ARIMA (2,2,3)
	ARIMA (3,2,1)
	ARIMA (3,2,2)
	ARIMA (3,2,3)

### 5.5.2.2. Uji Signifikansi ARIMA

Uji signifikansi parameter dilakukan untuk menguji kelayakan model ARIMA yang telah dimodelkan sebelumnya. Model dapat dikatakan layak, apabila nilai probabilitas seluruh variable  $\leq 0,05$  dan  $|t - statistic| \text{ seluruh variabel} > t - \text{tabel}$ .

Dependent Variable: D(TKEDATANGAN)  
Method: ARMA Maximum Likelihood (OPG - BHHH)  
Date: 05/29/17 Time: 15:17  
Sample: 2 88  
Included observations: 87  
Convergence achieved after 11 iterations  
Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(1)	-0.538740	0.091981	-5.857079	0.0000
SIGMASQ	0.008952	0.001438	6.226020	0.0000

**Gambar 5. 16 Uji Signifikansi ARIMA (0,1,1)**

Hasil uji signifikansi pada Gambar 5.10 menunjukkan bahwa parameter telah signifikan karena nilai probabilitas seluruh variable  $\leq 0,05$  dan  $|t - statistic| \text{ seluruh variabel} > t - \text{tabel}$ . T-tabel untuk seluruh uji signifikansi parameter adalah 1,98. Seluruh hasil uji signifikansi setiap parameter terdapat dalam LAMPIRAN B dan telah dirangkum dalam Tabel 5.5

**Tabel 5. 5 Uji Signifikansi ARIMA Menggunakan Data Jumlah Penumpang Kedatangan,  $d=1$**

Variabel	Model ARIMA	Keterangan
Jumlah Penumpang Kedatangan	ARIMA (0,1,1)	Lolos
	ARIMA (1,1,0)	Lolos
	ARIMA (1,1,1)	Tidak Lolos
	ARIMA (2,1,0)	Tidak Lolos
	ARIMA (2,1,1)	Tidak Lolos
	ARIMA (3,1,0)	Tidak Lolos
	ARIMA (3,1,1)	Tidak Lolos

Untuk proses uji signifikansi data jumlah penumpang kedatangan dengan proses *differencing* 1, terdapat dua model parameter ARIMA yang diterima yaitu ARIMA (0,1,1) dan ARIMA (1,1,0)

**Tabel 5. 6 Uji Signifikansi ARIMA Menggunakan Data Jumlah Penumpang Kedatangan,  $d=2$**

Variabel	Model ARIMA	Keterangan
Jumlah Penumpang Kedatangan	ARIMA (0,2,1)	Tidak Lolos
	ARIMA (0,2,2)	Tidak Lolos
	ARIMA (0,2,3)	Lolos
	ARIMA (1,2,0)	Lolos
	ARIMA (1,2,1)	Tidak Lolos
	ARIMA (1,2,2)	Tidak Lolos
	ARIMA (1,2,3)	Tidak Lolos
	ARIMA (2,2,0)	Tidak Lolos
	ARIMA (2,2,1)	Tidak Lolos

Variabel	Model ARIMA	Keterangan
	ARIMA (2,2,2)	Tidak Lolos
	ARIMA (2,2,3)	Lolos

Dan untuk proses uji signifikansi data jumlah penumpang kedatangan dengan proses *differencing* 2, terdapat tiga model parameter ARIMA yang diterima yaitu ARIMA (0,2,3), ARIMA (1,2,0) dan ARIMA (2,2,3).

Uji signifikansi parameter pada data jumlah penumpang keberangkatan dilakukan untuk menguji kelayakan model ARIMA yang telah dimodelkan sebelumnya. Model dapat dikatakan layak, apabila nilai probabilitas seluruh variable  $\leq 0,05$  dan  $|t - statistic| \text{ seluruh variabel} > t - \text{tabel}$ .

**Tabel 5. 7 Uji Signifikansi ARMA Menggunakan Data Jumlah Penumpang Keberangkatan**

Variabel	Model ARIMA	Keterangan
Jumlah Penumpang Keberangkatan	ARMA (0,1)	Tidak Lolos
	ARMA (1,0)	Lolos
	ARMA (1,1)	Lolos
	ARMA (2,0)	Lolos
	ARMA (2,1)	Tidak Lolos
	ARMA (3,0)	Lolos
	ARMA (3,1)	Tidak Lolos

Untuk proses uji signifikansi data jumlah penumpang keberangkatan, terdapat empat model parameter ARMA yang diterima yaitu ARMA (1,0), ARMA (1,1), ARMA (2,0), dan ARMA (3,0).

**Tabel 5. 8 Uji Signifikansi ARMA Menggunakan Data Jumlah Penumpang Keberangkatan, d=2**

Variabel	Model ARIMA	Keterangan
	ARIMA (0,2,1)	Tidak Lolos

Variabel	Model ARIMA	Keterangan
Jumlah Penumpang Keberangkatan	ARIMA (0,2,2)	Lolos
	ARIMA (0,2,3)	Tidak Lolos
	ARIMA (1,2,1)	Tidak Lolos
	ARIMA (1,2,2)	Lolos
	ARIMA (1,2,3)	Tidak Lolos
	ARIMA (2,2,1)	Tidak Lolos
	ARIMA (2,2,2)	Tidak Lolos
	ARIMA (2,2,3)	Lolos
	ARIMA (3,2,1)	Tidak Lolos
	ARIMA (3,2,2)	Tidak Lolos
ARIMA (3,2,3)	Tidak Lolos	

Untuk proses uji signifikansi data jumlah penumpang keberangkatan dengan proses *differencing* 1, terdapat tiga model parameter ARIMA yang diterima yaitu ARIMA (0,2,2), ARIMA (1,2,2), dan ARIMA (2,2,3).

### 5.5.2.3. Uji Diagnostik ARIMA

Uji diagnostik ARIMA dilakukan untuk menguji kelayakan model dari model keacakan dan homogenitas sisaan. Parameter. Model ARIMA dikatakan layak keacakan sisaan apabila *Correlogram – Q Statistic* dapat dinyatakan diterima apabila rata-rata seluruh nilai probabilitas  $\geq 0,05$ . Sedangkan untuk pengujian homogenitas sisaan dilakukan *Correlogram Squared Residuals* dapat dinyatakan diterima apabila rata-rata seluruh nilai probabilitas  $\geq 0,05$ .

Date: 05/31/17 Time: 16:01  
 Sample: 188  
 Included observations: 87  
 Q-statistic probabilities adjusted for 1 ARMA term

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.090	-0.090	0.7360	
		2 0.017	0.009	0.7638	0.382
		3 -0.005	-0.003	0.7662	0.682
		4 -0.112	-0.114	1.9401	0.585
		5 0.157	0.139	4.2545	0.373
		6 -0.143	-0.121	6.2213	0.285
		7 0.207	0.193	10.350	0.111
		8 -0.083	-0.078	11.022	0.138
		9 -0.125	-0.107	12.565	0.128
		10 -0.169	-0.252	15.433	0.080
		11 -0.143	-0.102	17.514	0.064
		12 0.375	0.321	32.045	0.001
		13 -0.139	-0.065	34.064	0.001
		14 -0.029	-0.129	34.152	0.001
		15 -0.066	-0.090	34.623	0.002

**Gambar 5. 17 Uji Diagnostik (Keacakan Sisaan) ARIMA (0,1,1)**

Pada Gambar 5.11 rata-rata nilai probabilitas  $> 0,05$ , sehingga model tersebut telah bersifat acak. Sedangkan pada Gambar 5.12 rata-rata nilai probabilitas  $> 0,05$  sehingga sisaan telah bersifat homogen.

Date: 05/31/17 Time: 16:05  
 Sample: 188  
 Included observations: 87

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.011	0.011	0.0102	0.920
		2 -0.150	-0.150	2.0569	0.358
		3 -0.007	-0.004	2.0613	0.560
		4 -0.047	-0.071	2.2674	0.687
		5 0.004	0.004	2.2692	0.811
		6 -0.133	-0.155	3.9495	0.684
		7 0.023	0.029	4.0005	0.780
		8 0.013	-0.040	4.0173	0.856
		9 0.115	0.131	5.3314	0.805
		10 -0.025	-0.058	5.3918	0.864
		11 -0.039	0.013	5.5447	0.902
		12 0.185	0.158	9.0793	0.696
		13 0.078	0.103	9.7220	0.716
		14 0.021	0.071	9.7689	0.779
		15 -0.021	0.045	9.8178	0.831

**Gambar 5. 18 Uji Diagnostik (Homogenitas) ARIMA (0,1,1)**

Karena model telah lolos uji keacakan dan homogenitas sisaan maka model telah lolos uji diagnostik dan layak untuk digunakan dalam peramalan jumlah penumpang kedatangan. Hasil uji diagnostik setiap model ARIMA yang telah lolos uji



signifikansi terdapat pada LAMPIRAN C dan dirangkum pada Tabel 5.9 dan Tabel 5.10.

Pada Tabel 5.9 telah dirangkum dari hasil uji diagnostik keacakan sisaan pada data jumlah penumpang kedatangan.

**Tabel 5. 9 Uji Diagnostik Keacakan Sisaan ARIMA Jumlah Penumpang Kedatangan**

Variabel	Model ARIMA	Keacakan Sisaan	Keterangan
Jumlah Penumpang Kedatangan	ARIMA (0,1,1)	0,188	Lolos
	ARIMA (1,1,0)	0,065	Lolos
	ARIMA (0,2,3)	0	Tidak Lolos
	ARIMA (1,2,0)	0	Tidak Lolos
	ARIMA (2,2,3)	0	Tidak Lolos

Pada Tabel 5.10 telah dirangkum dari hasil uji diagnostik homogenitas pada data jumlah penumpang kedatangan.

**Tabel 5. 10 Uji Diagnostik Homogenitas ARIMA Jumlah Penumpang Kedatangan**

Variabel	Model ARIMA	Homogenitas	Keterangan
Jumlah Penumpang Kedatangan	ARIMA (0,1,1)	0,747	Lolos
	ARIMA (1,1,0)	0,677	Lolos
	ARIMA (0,2,3)	0,008	Tidak Lolos
	ARIMA (1,2,0)	0,436	Lolos
	ARIMA (2,2,3)	0,119	Lolos

Pada Tabel 5.9 dan Tabel 5.10 menggunakan data jumlah penumpang kedatangan, pada data tersebut menggunakan *differencing* 1 dan *differencing* 2. Sehingga menghasilkan dua model ARIMA yang layak untuk diramalkan yaitu, ARIMA (0,1,1) dan ARIMA (1,1,0).

Pada Tabel 5.11 telah dirangkum dari hasil uji diagnostik keacakan sisaan pada data jumlah penumpang keberangkatan.

**Tabel 5. 11 Uji Diagnostik Keacakan Sisaan ARMA Jumlah Penumpang Keberangkatan**

Variabel	Model ARMA	Keacakan Sisaan	Keterangan
Jumlah Penumpang Keberangkatan	ARMA (1,0)	0	Tidak Lolos
	ARMA (1,1)	0,155	Lolos
	ARMA (2,0)	0,002	Tidak Lolos
	ARMA (3,0)	0,015	Tidak Lolos
	ARIMA (0,2,2)	0	Tidak Lolos
	ARIMA (1,2,2)	0,003	Tidak Lolos
	ARIMA (2,2,3)	0,025	Tidak Lolos

Pada Tabel 5.12 telah dirangkum dari hasil uji diagnostik homogenitas pada data jumlah penumpang keberangkatan.

**Tabel 5. 12 Uji Diagnostik Homogenitas ARMA Jumlah Penumpang Keberangkatan**

Variabel	Model ARMA	Homogenitas	Keterangan
Jumlah Penumpang Keberangkatan	ARMA (1,0)	0,004	Tidak Lolos
	ARMA (1,1)	0,06	Lolos
	ARMA (2,0)	0,058	Lolos
	ARMA (3,0)	0,431	Lolos
	ARIMA (0,2,2)	0,005	Tidak Lolos
	ARIMA (1,2,2)	0,003	Tidak Lolos
	ARIMA (2,2,3)	0,025	Tidak Lolos

Pada Tabel 5.11 dan Tabel 5.12 menggunakan data jumlah penumpang keberangkatan, pada data tersebut menggunakan model ARMA dan ARIMA. Sehingga menghasilkan satu model ARMA yang layak untuk diramalkan yaitu, ARMA (1,1).

#### 5.5.2.4. Pemilihan Model Terbaik ARIMA Sementara

Pemilihan model ARIMA dilakukan karena terdapat lebih dari satu model ARIMA yang lulus uji diagnostic dengan menggunakan data jumlah penumpang kedatangan dan keberangkatan. Pemilihan model dilakukan dengan memilih nilai terkecil *Akaike Information Criterion* (AIC) dan *Schwarz Information Criterion* (SIC). Pemilihan model terbaik dilakukan dengan menggunakan program *Eviews*. Tabel 5.13 dan Tabel 5.14 menunjukkan bahwa nilai AIC dan SIC yang terkecil.

Pada Tabel 5.13 menunjukkan bahwa nilai AIC dan SIC terkecil terdapat pada model ARIMA (0,1,1), sehingga untuk peramalan periode 2017-2018 menggunakan model terbaik yaitu ARIMA (0,1,1).

**Tabel 5. 13 Pemilihan Model Terbaik ARIMA Sementara Menggunakan Data Jumlah Penumpang Kedatangan**

Model ARIMA	AIC	SIC
ARIMA (0,1,1)	-1,828	-1,771
ARIMA (1,1,0)	-1.788	-1.731

Pada Tabel 5.14 menunjukkan bahwa nilai AIC dan SIC terkecil terdapat pada model ARMA (1,1), sehingga untuk peramalan periode 2017-2018 menggunakan model terbaik yaitu ARMA (1,1).

**Tabel 5. 14 Pemilihan Model Terbaik ARMA Menggunakan Data Jumlah Penumpang Keberangkatan**

Model ARIMA	AIC	SIC
ARMA (1,1)	-1,443	-1,359

## 5.2. Implementasi Model *Hybrid* ARIMA-ANN

Pada pengerjaan tugas akhir ini, metode yang dilakukan menggunakan dua metode. Proses sebelumnya menggunakan ARIMA dan selanjutnya hasil dari ARIMA dilakukan proses *hybrid* menggunakan ANN.

### 5.2.1. Pemrosesan Data

Dalam proses pengolahan data, pengerjaan tugas akhir ini membagi data seperti metode ARIMA sebelumnya. Pada tahap ini, data akan dikelompokkan menjadi tiga kelompok yaitu data pelatihan, data pengujian pertama, dan data pengujian kedua dengan proporsi 70:20:10. Total data yang didapatkan sejumlah 123 data (Januari 2007 – Maret 2017), sehingga data yang akan digunakan sebagai data pelatihan sejumlah 88 data (Januari 2007 – April 2014), data yang digunakan untuk pengujian pertama sejumlah 25 data (Mei 2014 – Mei 2016), dan data pengujian kedua sejumlah 10 data (Juni 2016 – Maret 2017).

Tabel 5.15 merupakan inputan ANN yang dihasilkan dari proses ARIMA, input ANN akan diproses untuk proses *hybrid* ARIMA-ANN

**Tabel 5. 15 Data Training Data Jumlah Penumpang Kedatangan**

Bulan	Data Residual (Input ANN)
Januari 2007	0
Februari 2007	-53494
Maret 2007	24710
April 2007	12787
Mei 2007	26847
Juni 2007	12342
Juli 2007	58857
Agustus 2007	11353

Bulan	Data Residual (Input ANN)
September 2007	-27691
Oktober 2007	50890
Nopember 2007	23410
Desember 2007	20016
...	...

Tabel 5.16 merupakan data training umlah penumpang keberangkatan yang akan diproses menggunakan ANN.

**Tabel 5. 16 Data Training Data Jumlah Penumpang Keberangkatan**

Bulan	Data Residual (Input ANN)
Januari 2007	0
Februari 2007	0
Maret 2007	0
April 2007	-30457
Mei 2007	34956
Juni 2007	18214
Juli 2007	19225
Agustus 2007	52153
September 2007	31252
Oktober 2007	-71225
Nopember 2007	6971
Desember 2007	63110
...	...

Pada Tabel 5. 15 adalah contoh data testing yang akan digunakan untuk pengujian dari model yang telah dimodelkan dengan menggunakan data training.

**Tabel 5. 17 Data Testing Menggunakan Data Jumlah Penumpang Kedatangan**

Bulan	Data Residual (Input ANN)
Mei 2014	0
Juni 2014	58.292
Juli 2014	-26.848
Agustus 2014	29.411
September 2014	-46.041
Oktober 2014	22.230
Nopember 2014	-16.707
Desember 2014	80.786
Januari 2015	-104.267
Februari 2015	-133.565
Maret 2015	-54.129
April 2015	-10.279
...	...

Tabel 5.18 merupakan data testing jumlah penumpang keberangkatan yang akan diproses menggunakan ANN.

**Tabel 5. 18 Data Testing Menggunakan Data Jumlah Penumpang Keberangkatan**

Bulan	Data Residual (Input ANN)
Mei 2014	0
Juni 2014	58.292
Juli 2014	-26.848
Agustus 2014	29.411
September 2014	-46.041
Oktober 2014	22.230
Nopember 2014	-16.707

Bulan	Data Residual (Input ANN)
Desember 2014	80.786
Januari 2015	-104.267
Februari 2015	-133.565
Maret 2015	-54.129
April 2015	-10.279
...	...

Data residual yang telah masuk dalam file excel baru dimasukkan dalam proses menggunakan operator *Read Excel* pada Gambar 5.19



**Gambar 5. 19 Operator *Read Excel***

Setelah data dimasukkan, maka proses selanjutnya yaitu menggunakan operator *Set Role*. Operator ini digunakan untuk mnegubah peran suatu atribut yaitu attribute bulan dari atribut regular menjadi atribut special yaitu sebagai *id*.



**Gambar 5. 20 Operator *Set Role***

Operator selanjutnya yang digunakan untuk pemrosesan data yaitu operator *Windowing*, operator ini salah satu Teknik dalam mennetukan data *input* dan data *output* dalam prediksi data runtun waktu dengan tipe univariate. Dengan menggunakan


*Windowing*, data yang berupa data residual yang akan dipecah dari data 12 data *input* dan 1 data *output*. Data *input* merupakan data 12 bulan sebelumnya dan data *output* adalah data 1 bulan berikutnya.



Gambar 5. 21 Operator *Windowing*

### 5.2.2. *Validation*

Pada operator *Validation* mempunyai 2 sub-proses, yaitu sub-proses *training* dan sub-proses *testing*. Sub-proses *training* digunakan untuk pelatihan sebuah model. Model yang telah ditraining lalu diterapkan didalam sub-proses *testing*. Kinerja model juga diukur selama fase *testing*.




Gambar 5. 22 Operator *Validation*

### 5.2.3. Normalisasi Data

Sebelum melakukan proses ANN data *training* yang akan diinputkan perlu dinormalisasikan. Normalisasi ini disebut juga dengan penskalaan data. Normalisasi data *input* untuk ANN bertujuan untuk mentransformasikan data agar kestabilan persebaran data dapat dicapai. Menurut Siang normalisasi berguna untuk menyesuaikan nilai dari data dengan range fungsi aktivasi yang digunakan dalam jaringan, selain itu




normalisasi dapat digunakan untuk meningkatkan akurasi dari hasil output serta memfasilitasi proses learning dari neural network. Untuk implemetasi model Neural Network, digunakan operator *Neural Net* seperti Gambar 5. 24 Operator ini melakukan pembelajaran model ANN dengan algoritma *backpropagation*.



**Gambar 5. 23 Operator *Neural Net***


Langkah pertama yang dilakukan, data *input* dilakukan normalisasi terlebih dahulu, menggunakan parameter *normalize* seperti pada Gambar 5.26. Operator *Neural Net* menggunakan fungsi sigmoid sebagai fungsi aktivasi. Sehingga, rentang antar atribut harus diskalakan dari -1 hingga 1. Normalisasi dilakukan sebelum proses *learning*.



**Gambar 5. 24 Parameter *Normalize***

#### 5.2.4. Pembentukan *Artificial Neural Network*

Selanjutnya dari operator *Neural Net*, yaitu pembentukan model jaringan ANN. Parameter yang diatur yaitu jumlah *Hidden Layer* dan *Layer Size* (jumlah neuron) seperti pada Gambar 5.8 Untuk pembentukan model awal, pada pengerjaan tugas akhir ini menggunakan 1 *hidden layer* dengan 1 neuron.



**Gambar 5. 25 Parameter *Hidden Layer***

### 5.2.5. Penentuan Parameter *Artificial Neural Network*


Parameter yang diatur selanjutnya pada pengerjaan tugas akhir ini adalah *training*, *cycles*, *learning rate*, dan *momentum* seperti Gambar 5. 25. Untuk parameter awal digunakan 100 *training cycles* 0.1 *learning rate* dan 0.1 *momentum*.

training cycles	<input type="text" value="100"/>	ⓘ
learning rate	<input type="text" value="0.1"/>	ⓘ
momentum	<input type="text" value="0.1"/>	ⓘ

Gambar 5. 26 Parameter Jaringan pada Operator Neural Net

### 5.2.6. Penerapan Model *Artificial Neural Network*

Setelah semua parameter dalam operator telah diatur, selanjutnya menerapkan model ANN menggunakan operator *Apply Model* seperti Gambar 5.26 Operator ini menerapkan model yang telah dilatih.



Gambar 5. 27 Operator *Apply Model*

### 5.2.7. Denormalisasi Data Pelatihan

Langkah terakhir dalam data pelatihan adalah dilakukan denormalisasi. Dalam penggunaan operator *Neural Net*, data akan terdenormalisasi secara otomatis.


### 5.2.8. Pengujian

Setelah data dinormalisasi, dilakukan penerapan model ANN yang telah terbentuk sebelumnya ke data pengujian ini.

Penerapan model dilakukan menggunakan operator *Apply Model*.

### 5.2.9. Peramalan Periode Kedepan

Implementasi untuk data ramalan kedepan menggunakan proses yang sama seperti pada sub-bab 5.1. Data yang telah melalui proses ANN akan masuk dalam operator *Write Excel* yang berfungsi untuk memasukkan nilai atau hasil dari ANN kedalam *Excel*. Setelah data masuk dalam *Excel* maka selanjutnya dilakukan proses pengembalian nilai untuk mendapatkan hasil ramalan untuk periode mendatang. Data yang telah diolah menggunakan *RapidMiner* akan di-*import* dan akan disimpan kedalam bentuk *file spreadsheet Excel*, menggunakan operator *Write Excel*.



**Gambar 5. 28 Operator Write Excel**

*(Halaman ini sengaja dikosongkan)*

## **BAB VI**

### **HASIL DAN PEMBAHASAN**

Bab ini menjelaskan tentang hasil dan pembahasan setelah melakukan perancangan dan implementasi. Hasil yang akan dijelaskan adalah hasil uji coba model, validasi model, dan hasil peramalan untuk periode yang akan datang.


#### **6.1. Hasil Uji Coba Model**

Dalam tahapan ini model yang dihasilkan dari implementasi dibandingkan menggunakan data pelatihan untuk menentukan model terbaik dan untuk melakukan pengecekan tingkat keakuratan dari model yang didapatkan.

**Tabel 6. 1 Hasil Uji Coba Model Data Jumlah Penumpang Kedatangan**


Model	MAPE
ARIMA (0,1,1)	7,74%
ARIMA (1,1,0)	7,33%

Pada Tabel 6. 1 didapatkan bahwa MAPE uji coba untuk keseluruhan model didapatkan yaitu  $\leq 10\%$ . Hal tersebut dapat diartikan bahwa keseluruhan model yang dihasilkan memiliki kemampuan yang sangat baik. Model ARIMA (1,1,0) memiliki tingkat akuratan yang lebih tinggi dibandingkan dengan ARIMA (0,1,1) yaitu sebesar 7,33%. Hasil tersebut berbeda dengan hasil yang didapat dengan hasil penentuan model terbaik dengan menggunakan AIC dan SIC. Sehingga dilakukan pengujian untuk mengetahui keakuratan dari setiap model dan sebagai dasar dalam menentukan model terbaik. Hasil pengujian untuk melakukan validasi pada setiap model ada pada tahap berikutnya.



**Gambar 6. 1 Hasil Peramalan Data Training Menggunakan Model ARIMA (0,1,1)**

Pada Gambar 6.1 menunjukkan grafik perbandingan antara data actual dan data ramalan pada training menggunakan model ARIMA (0,1,1). Sedangkan untuk Gambar 6.2 adalah grafik perbandingan antara data actual dan data ramalan yang menggunakan model (1,1,0).




**Gambar 6. 2 Hasil Peramalan Data Training Menggunakan Model ARIMA (1,1,0)**

Pada Gambar 6.1 menunjukkan grafik perbandingan antara data actual dan data ramalan dengan menggunakan data training ARIMA (0,1,1), sedangkan pada Gambar 6.2 menunjukkan perbandingan antara data actual dan hasil peramalan dengan menggunakan data training ARIMA (1,1,0). Pada kedua grafik tersebut terlihat bahwa hasil peramalan yang didapatkan mampu mengikuti pola data actual. Hal itu menunjukkan bahwa hasil peramalan hasil yang baik.

**Tabel 6. 2 Hasil Uji Coba Model Data Jumlah Penumpang Keberangkatan**

Model	MAPE
ARMA (1,1)	5,2%

Pada Tabel 6.2 didapatkan bahwa MAPE uji coba untuk keseluruhan model didapatkan yaitu  $\leq 10\%$ . Hal tersebut dapat diartikan bahwa keseluruhan model yang dihasilkan memiliki kemampuan yang sangat baik.



**Gambar 6. 3 Hasil Peramalan Model Data Jumlah Penumpang Keberangkatan**

Pada Gambar 6.3 menunjukkan grafik perbandingan antara data actual dan data ramalan dengan menggunakan data training

ARMA (1,1). Pada grafik tersebut terlihat bahwa hasil peramalan yang didapatkan mampu mengikuti pola data aktual. Hal itu menunjukkan bahwa hasil peramalan hasil yang baik

## 6.2. Hasil Validasi Model

Pada tahapan ini dilakukan validasi dari hasil model yang dilakukan pada data training, validasi ini dilakukan sebanyak dua kali untuk memastikan tingkat keakuratan dan ketepatan model yang dipilih untuk peramalan pada periode 2017-2018. Hasil validasi model menggunakan metode ARIMA terdapat dalam LAMPIRAN D.

### 6.2.1. Hasil Validasi Pertama Model

Hasil uji coba dilakukan pada data training diaplikasikan pada data testing lain sebagai validasi model yang telah ditemukan. Persentase kesalahan yang semakin kecil menunjukkan bahwa model telah valid dan siap digunakan untuk meramalkan data lainna. Tabel 6.3 menunjukkan rangkuman dari hasil validasi pertama pada data jumlah penumpang kedatangan pada periode Mei 2014 – Mei 2016.


**Tabel 6. 3 Hasil Validasi Pertama Model Jumlah Penumpang Kedatangan**

Model	MAPE	Kemampuan Peramalan
ARIMA (0,1,1)	7,64%	Sangat Baik
ARIMA (1,1,0)	8,05%	Sangat Baik

Berdasarkan hasil validasi pertama pada Tabel 6.3 seluruh model ARIMA yang telah dimodelkan memiliki nilai MAPE yang kecil yaitu  $\leq 10\%$ . Sehingga memiliki tingkat keakuratan yang sangat baik. Model ARIMA (0,1,1) merupakan model yang memiliki tingkat keakuratan yang lebih tinggi dibandingkan dengan model ARIMA (1,1,0) yaitu sebesar 7,64% pada validasi pertama. Untuk memastikan tingkat

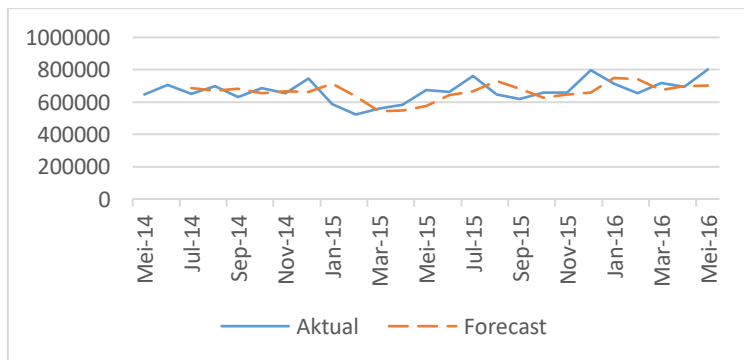


keakuratan hasil validasi tersebut, maka validasi dilakukan sebanyak dua kali yang ditunjukkan pada langkah selanjutnya.



**Gambar 6. 4 Hasil Peramalan Validasi Pertama Menggunakan Model ARIMA (0,1,1)**

Pada Gambar 6.4 menunjukkan grafik perbandingan antara data actual dan data ramalan pada pengujian pertama menggunakan model ARIMA (0,1,1). Sedangkan untuk Gambar 6.5 adalah grafik perbandingan antara data actual dan data ramalan yang menggunakan model (1,1,0)




**Gambar 6. 5 Hasil Peramalan Validasi Pertama Menggunakan Model ARIMA (1,1,0)**

Hasil uji coba pada data jumlah penumpang keberangkatan dilakukan pada data training diaplikasikan pada data testing lain sebagai validasi model yang telah ditemukan. Persentase kesalahan yang semakin kecil menunjukkan bahwa model telah valid dan siap digunakan untuk meramalkan data lainnya. Tabel 6.4 menunjukkan rangkuman dari hasil validasi pertama pada data jumlah penumpang kedatangan pada periode Mei 2014 – Mei 2016.

**Tabel 6. 4 Hasil Peramalan Validasi Pertama Menggunakan Model ARMA (1,1)**

Model	MAPE
ARMA (1,1)	5,86%

Berdasarkan hasil validasi pertama pada Tabel 6.4 model ARMA yang telah dimodelkan memiliki nilai MAPE yang kecil yaitu  $\leq 10\%$ . Sehingga memiliki tingkat keakuratan yang sangat baik. Model ARMA (1,1) merupakan model yang memiliki tingkat keakuratan yang lebih tinggi yaitu sebesar 5,86% pada validasi pertama.



**Gambar 6. 6 Hasil Peramalan Validasi Pertama Menggunakan Model ARMA (1,1)**


### 6.2.2. Hasil Validasi Kedua Model

Hasil uji coba selanjutnya dilakukan dengan menggunakan data testing kedua. Persentase kesalahan yang semakin kecil menunjukkan bahwa model telah valid dan siap digunakan untuk meramalkan data lainnya. Tabel 6.3 menunjukkan rangkuman dari hasil validasi kedua pada data jumlah penumpang kedatangan pada periode Juni 2016 – Maret 2017.


**Tabel 6. 5 Hasil Validasi Kedua Model Jumlah Penumpang Kedatangan**

Model	MAPE	Kemampuan Peramalan
ARIMA (0,1,1)	8,68%	Sangat Baik
ARIMA (1,1,0)	8,45%	Sangat Baik

Berdasarkan hasil validasi kedua pada Tabel 6.3, seluruh model ARIMA yang telah dimodelkan memiliki nilai MAPE yang kecil yaitu  $\leq 10\%$ , sehingga memiliki tingkat keakuratan yang sangat baik. Model ARIMA (1,1,0) merupakan model yang memiliki tingkat keakuratan yang lebih tinggi dibandingkan dengan model ARIMA (0,1,1) yaitu sebesar 8,45% pada validasi kedua.



**Gambar 6. 7 Hasil Peramalan Validasi Kedua Menggunakan Model ARIMA (0,1,1)**




**Gambar 6. 8 Hasil Peramalan Validasi Kedua Menggunakan Model ARIMA (1,1,0)**

Hasil uji coba dilakukan pada data training diaplikasikan pada data testing lain sebagai validasi model yang telah ditemukan. Persentase kesalahan yang semakin kecil menunjukkan bahwa model telah valid dan siap digunakan untuk meramalkan data lainna. Tabel 6.2 menunjukkan rangkuman dari hasil validasi pertama pada data jumlah penumpang kedatangan pada periode Juni 2016 – Maret 2017

**Tabel 6. 6 Hasil Peramalan Validasi Kedatangan Menggunakan Model ARMA (1,1)**

Model	MAPE
ARMA (1,1)	5,35%

Pada Tabel 6. 6 didapatkan bahwa MAPE uji coba untuk keseluruhan model didapatkan yaitu  $\leq 10\%$ . Hal tersebut dapat diartikan bahwa model yang dihasilkan memiliki kemampuan yang sangat baik. Model ARMA (1,1) memiliki tingkat akuratan yang tinggi yaitu sebesar 5,35%.



**Gambar 6. 9 Hasil Peramalan Validasi Kedua Menggunakan Model ARMA (1,1)**

### 6.3. Analisis Hasil Peramalan

Pada tahap ini dengan menggunakan input dari nilai error yang dihasilkan menggunakan metode ARIMA, proses selanjutnya adalah melakukan peramalan menggunakan ANN sebagai metode *hybrid*.

#### 6.3.1. Uji Coba Parameter Model ANN


Uji coba dilakukan terhadap model ANN terbaik pada hasil pembentukan model ANN. Tujuan dari uji coba parameter yaitu untuk mendapatkan tingkat akurasi yang lebih baik berdasarkan RMSE, dengan menggunakan parameter yang paling optimal. Semakin kecil nilai RMSE, semakin akurat model.

Uji coba parameter dilakukan dengan mencoba parameter: *training cycles* sebanyak 100-500; *momentum* dari 0.1 hingga 0.9; dan *learning rate* dari 0.1 sampai 0.9.

**Tabel 6. 7 Uji Coba Parameter Model ANN Data Jumlah Penumpang Kedatangan**

Input	Hidden Layer	Training Cycles	Momentum	Learning Rate	RMSE
8	1	500	0,5	0,6	33785,51
	2	100	0,5	0,6	36700,38
	3	100	0,8	0,1	34016,43
	4	250	0,8	0,2	35625,25
	5	150	0,3	0,9	27925,17
	6	450	0,4	0,8	44692,83
	7	150	0,9	0,3	37155,73
	8	250	0,8	0,3	38210,42
	9	400	0,8	0,2	38858,09

Dari hasil uji coba pada Tabel 6.7, menunjukkan bahwa nilai input 8, hidden layer 5, training cycle 150, momentum 0,3, dan learning rate 0,9 menunjukkan nilai RMSE lebih kecil dibandingkan dengan yang lainnya yaitu sebesar 27.925,17. Sehingga hasil output yang dihasilkan oleh ANN, dimasukkan kedalam *Excel* untuk dilakukan proses perhitungan peramalan untuk data training. Pada Gambar 6.10 berikut ini adalah hasil dari data actual dan data ramalan jumlah penumpang kedatangan.




**Gambar 6. 10 Uji Coba Parameter Model ANN Data Jumlah Penumpang Kedatangan**

Uji coba parameter dilakukan dengan mencoba parameter: *training cycles* sebanyak 100-500; *momentum* dari 0.1 hingga 0.9; dan *learning rate* dari 0.1 sampai 0.9.

**Tabel 6. 8 Uji Coba Parameter Model ANN Data Jumlah Penumpang Keberangkatan**

Input	Hidden Layer	Training Cycles	Momentum	Learning Rate	RMSE
8	1	250	0,7	0,5	19834,91
	2	100	0,4	0,7	22372,63
	3	350	0,7	300	24421,06
	4	300	0,5	0,6	21934,62
	5	150	0,7	0,4	22030,23
	6	500	0,4	0,7	23476,08
	7	450	0,4	0,8	23229,16
	8	350	0,4	0,8	22078,3
	9	400	0,5	0,6	21120,61

Dari hasil uji coba pada Tabel 6.8, menunjukkan bahwa nilai input 8, hidden layer 1, training cycle 250, momentum 0,7, dan learning rate 0,5 menunjukkan nilai RMSE lebih kecil dibandingkan dengan yang lainnya yaitu sebesar 19834,91. Sehingga hasil output yang dihasilkan oleh ANN, dimasukkan kedalam *Excel* untuk dilakukan proses perhitungan peramalan untuk data training. Pada Gambar 6.11 berikut ini adalah hasil dari data actual dan data ramalan jumlah penumpang keberangkatan.




**Gambar 6. 11 Uji Coba Parameter Model ANN Data Jumlah Penumpang Keberangkatan**

### 6.3.2. Hasil Pengujian

Pengujian jumlah penumpang kedatangan dilakukan dengan menggunakan model ANN dengan parameter yang paling optimal sebelumnya, berdasarkan nilai RMSE yang paling kecil. Dengan menggunakan parameter pada hasil uji coba menggunakan model ANN, maka data akan diuji apakah parameter yang digunakan baik akurasinya.


Pada Gambar 6.11 didapatkan hasil pengujian pertama menggunakan inputan yang digunakan pada uji training, sehingga nilai MAPE yang didapatkan sebesar 4,97%





**Gambar 6. 12 Hasil Pengujian Pertama Menggunakan Data Penumpang Kedatangan**

Pada Gambar 6.12 didapatkan hasil pengujian kedua menggunakan inputan yang digunakan pada uji training, sehingga nilai MAPE yang didapatkan sebesar 3,95%




**Gambar 6. 13 Hasil Pengujian Kedua Menggunakan Data Penumpang Kedatangan**

Pengujian jumlah penumpang keberangkatan dilakukan dengan menggunakan model ANN dengan paramater yang paling optimal sebelumnya, berdasarkan nilai RMSE yang paling


kecil. Dengan menggunakan parameter pada hasil uji coba menggunakan model ANN, maka data akan diuji apakah parameter yang digunakan baik akurasinya.

Pada Gambar 6.13 didapatkan hasil pengujian pertama menggunakan inputan yang digunakan pada uji training, sehingga nilai MAPE yang didapatkan sebesar 1,83%



**Gambar 6. 14 Hasil Pengujian Pertama Menggunakan Data Penumpang Keberangkatan**

Pada Gambar 6.15 didapatkan hasil pengujian kedua menggunakan inputan yang digunakan pada uji training, sehingga nilai MAPE yang didapatkan sebesar 1,57%



**Gambar 6. 15 Hasil Pengujian Kedua Menggunakan Data Penumpang Keberangkatan**

#### **6.4. Analisis Hasil Peramalan**

Dalam sub-bab ini akan dilakukan perbandingan hasil peramalan menggunakan metode ARIMA dengan metode pembandingan yaitu *hybrid* ARIMA-ANN. Tujuan dari pembandingan hasil dari kedua metode ini adalah untuk membandingkan metode yang mampu memberikan hasil peramalan yang terbaik. Peramalan yang terbaik dapat dilihat melalui persentase nilai kesalahan yang dihasilkan setiap ramalan (MAPE). Hasil MAPE yang memiliki nilai terkecil menunjukkan bahwa, metode menghasilkan ramalan yang terbaik dibandingkan dengan metode lainnya. Dalam melakukan perbandingan ini, data yang akan dibandingkan adalah hasil peramalan pada data pelatihan, pengujian pertama, dan pengujian kedua. Hasil peramalan menggunakan metode ARIMA terdapat dalam LAMPIRAN F.

**Tabel 6. 9 Perbandingan Jumlah Penumpang Kedatangan Menggunakan Hasil MAPE ARIMA dan *Hybrid* ARIMA-ANN pada Data Pelatihan**

Metode	Model	MAPE
ARIMA	ARIMA (1,1,0)	7,74%
	ARIMA (0,1,1)	7,33%
<i>Hybrid</i> ARIMA-ANN	ARIMA (1,1,0) ANN (8,5,1)	6,51%

Pada Tabel 6.9 dilakukan perbandingan MAPE pada data pelatihan antara metode ARIMA dan *Hybrid* ARIMA-ANN. Pada model ARIMA (1,1,0) dan ARIMA (0,1,1) dipilih dikarenakan kedua model tersebut merupakan model ARIMA yang telah lolos dalam uji diagnostic dan layak untuk dilakukan peramalan. Hasil perbandingan MAPE didapatkan bahwa, menggunakan metode *Hybrid* ARIMA-ANN memiliki nilai persentase kesalahan yang lebih kecil jika dibandingkan dengan kedua model metode ARIMA (1,1,0) dan ARIMA (0,1,1) yaitu sebesar 6,51%

**Tabel 6. 10 Perbandingan Jumlah Penumpang Kedatangan Menggunakan Hasil MAPE ARIMA dan *Hybrid* ARIMA-ANN pada Data Pengujian Pertama**

Metode	Model	MAPE
ARIMA	ARIMA (1,1,0)	7,64%
	ARIMA (0,1,1)	7,60%
<i>Hybrid</i> ARIMA-ANN	ARIMA (1,1,0) ANN (8,5,1)	4,97%


Pada Tabel 6.10 dilakukan perbandingan MAPE pada data pelatihan antara metode ARIMA dan *Hybrid* ARIMA-ANN. Hasil perbandingan MAPE didapatkan bahwa, *Hybrid* ARIMA-ANN memiliki nilai persentase kesalahan yang lebih kecil jika dibandingkan dengan kedua model metode ARIMA yaitu sebesar 4,97%

**Tabel 6. 11 Perbandingan Jumlah Penumpang Kedatangan Menggunakan Hasil MAPE ARIMA dan Hybrid ARIMA-ANN pada Data Pengujian Kedua**

Metode	Model	MAPE
ARIMA	ARIMA (1,1,0)	7,64%
	ARIMA (0,1,1)	7,60%
<i>Hybrid</i> ARIMA-ANN	ARIMA (1,0,0) ANN (8,5,1)	3,95%

Pada Tabel 6.11 dilakukan perbandingan MAPE pada data pelatihan antara metode ARIMA dan *Hybrid* ARIMA-ANN. Hasil perbandingan MAPE didapatkan bahwa, *Hybrid* ARIMA-ANN memiliki nilai persentase kesalahan yang lebih kecil jika dibandingkan dengan kedua model metode ARIMA yaitu sebesar 3,95%

Berdasarkan hasil perbandingan ketiga pengelompokan data yaitu data pelatihan, data pengujian pertama, dan data pengujian kedua, didapatkan hasil bahwa model menggunakan metode *Hybrid* ARIMA-ANN dengan model ARIMA (1,1,0) ANN (8,5,1) merupakan metode terbaik yang dapat digunakan untuk melakukan peramalan pada jumlah penumpang kedatangan terminal 1 di Bandara Juanda. Hal tersebut dapat dilihat berdasarkan nilai MAPE yang dihasilkan memiliki nilai MAPE yang terkecil. Diantaranya menghasilkan nilai terkecil jika dibandingkan dengan metode pembanding lainnya pada ketiga kelompok data.



Pada Gambar 6.15 menunjukkan hasil total peramalan menggunakan data jumlah penumpang keberangkatan dengan nilai MAPE 7,33%.

**Tabel 6. 12 Perbandingan Jumlah Penumpang Keberangkatan Menggunakan Hasil MAPE ARIMA dan Hybrid ARIMA-ANN pada Data Pelatihan**

Metode	Model	MAPE
ARMA	ARIMA (1,1)	9,8%
<i>Hybrid</i> ARIMA-ANN	ARIMA (1,1) ANN (8,1,1)	4,68%

Pada Tabel 6.12 dilakukan perbandingan MAPE pada data pelatihan antara metode ARIMA dan *hybrid* ARIMA-ANN. Pada model *hybrid* ARIMA (1,1) ANN (8,1,1) dipilih dikarenakan model tersebut merupakan model *hybrid* yang telah lolos dalam uji diagnostic dan layak untuk dilakukan peramalan. Hasil perbandingan MAPE didapatkan bahwa, *Hybrid* ARIMA-ANN memiliki nilai persentase kesalahan yang lebih kecil jika dibandingkan dengan model metode ARMA yaitu sebesar 4,68%

**Tabel 6. 13 Perbandingan Jumlah Penumpang Keberangkatan Menggunakan Hasil MAPE ARIMA dan Hybrid ARIMA-ANN pada Data Pengujian Pertama**

Metode	Model	MAPE
ARIMA	ARIMA (1,1)	9,85%
<i>Hybrid</i> ARIMA-ANN	ARIMA (1,1) ANN (8,1,1)	1,83%


Pada Tabel 6.13 dilakukan perbandingan MAPE pada data pelatihan antara metode ARIMA dan *hybrid* ARIMA-ANN Pada model *hybrid* ARIMA (1,1) ANN (8,1,1) dipilih dikarenakan model tersebut merupakan model *hybrid* yang telah lolos dalam uji diagnostic dan layak untuk dilakukan peramalan. Hasil perbandingan MAPE didapatkan bahwa, *Hybrid* ARIMA-ANN memiliki nilai persentase kesalahan yang lebih kecil jika dibandingkan dengan model metode ARMA yaitu sebesar 1,83%

**Tabel 6. 14 Perbandingan Jumlah Penumpang Keberangkatan Menggunakan Hasil MAPE ARIMA dan Hybrid ARIMA-ANN pada Data Pengujian Kedua**

Metode	Model	MAPE
ARIMA	ARIMA (1,1)	8,54%
<i>Hybrid</i> ARIMA-ANN	ARIMA (1,1) ANN (8,1,1)	1,57%

Pada Tabel 6.14 dilakukan perbandingan MAPE pada data pelatihan antara metode ARIMA dan *hybrid* ARIMA-ANN Pada model *hybrid* ARIMA (1,1) ANN (8,1,1) dipilih dikarenakan model tersebut merupakan model *hybrid* yang telah lolos dalam uji diagnostic dan layak untuk dilakukan peramalan. Hasil perbandingan MAPE didapatkan bahwa, *Hybrid* ARIMA-ANN memiliki nilai persentase kesalahan yang lebih kecil jika dibandingkan dengan model metode ARMA yaitu sebesar 1,57%

Berdasarkan hasil perbandingan ketiga pengelompokan data yaitu data pelatihan, data pengujian pertama, dan data pengujian kedua, didapatkan hasil bahwa model menggunakan metode *hybrid* ARIMA-ANN merupakan metode terbaik yang dapat digunakan untuk melakukan peramalan pada jumlah penumpang keberangkatan terminal 1 di Bandara Juanda. Diantaranya menghasilkan nilai terkecil jika dibandingkan dengan metode pembandingan lainnya pada ketiga kelompok data.



Pada Gambar 6.15 menunjukkan hasil total peramalan menggunakan data jumlah penumpang keberangkatan dengan nilai MAPE 4,18%.



## BAB VII

### KESIMPULAN DAN SARAN

#### 7.1. Kesimpulan

Berdasarkan hasil dari uji coba menggunakan kedua metode tersebut pada tugas akhir ini, dapat ditarik kesimpulan sebagai berikut:

1. Model ARIMA dan *hybrid* ARIMA-ANN dapat digunakan untuk meramalkan jumlah penumpang pesawat (kedatangan dan keberangkatan) terminal 1 di Bandara Juanda.
2. Model ARIMA terdiri dari AR dengan ordo 1 menunjukkan nilai lag 1, *differencing* dengan ordo 1 dilakukan 1 kali sehingga data menunjukkan stasioner, MA dengan ordo 0 menunjukkan nilai lag 0; sehingga model ARIMA tersebut sudah dikatakan layak untuk digunakan dalam peramalan data jumlah penumpang kedatangan yang memiliki tingkat akurat sebesar 7,93%. Model ARIMA ini dilanjutkan dengan *hybrid* menggunakan metode ANN dengan input layer sebanyak 8 neuron, hidden layer sebanyak 5 neuron, dan output layer sebanyak 1 neuron sehingga dengan tingkat akurat sebesar 7,33%. Sehingga model *hybrid* ARIMA-ANN dapat meramalkan jumlah penumpang kedatangan terminal 1 di Bandara Juanda pada periode April 2017 – Maret 2018.
3. Model ARIMA terdiri dari AR dengan ordo  $p$  menunjukkan nilai lag 1,  $I$  atau *differencing* dengan ordo  $d$  tidak dilakukan karena data telah stasioner, MA dengan ordo  $q$  dengan cara melihat nilai lag pada grafik ACF yang menunjukkan nilai lag 1; sehingga model ARIMA tersebut sudah dikatakan layak untuk digunakan dalam peramalan data jumlah penumpang kedatangan yang memiliki tingkat akurat

sebesar 5,14% Model ARIMA ini dilanjutkan dengan *hybrid* menggunakan metode ANN dengan input layer sebanyak 8 neuron, hidden layer sebanyak 1 neuron, dan output layer sebanyak 1 neuron sehingga dengan tingkat akurat sebesar 4,18%. Sehingga dengan model *hybrid* ARIMA-ANN dapat meramalkan jumlah penumpang keberangkatan terminal 1 di Bandara Juanda pada periode April 2017 – Maret 2018.

4. Peramalan menggunakan metode *hybrid* ARIMA-ANN pada data jumlah penumpang kedatangan dan keberangkatan menghasilkan peramalan yang lebih baik dari metode ARIMA.
5. Hasil peramalan jumlah penumpang kedatangan dan keberangkatan masing-masing menggunakan metode *hybrid* ARIMA-ANN memiliki nilai MAPE 7,33% dan 4,18% yang menunjukkan bahwa model memiliki tingkat keakuratan yang bagus karena nilai MAPE < 10%.

## 7.2. Saran

Berdasarkan kesimpulan yang didapatkan berdasarkan pengerjaan tugas akhir ini, terdapat beberapa saran dari penulis untuk penelitian serupa kedepan:

1. Parameter yang digunakan dalam proses ANN, *training cycles* menggunakan 100-500 *cycles*, momentum dan *learning rate* menggunakan nilai 0,1-0,9. Untuk penelitian kedepan dapat menambahkan nilai *training cycles* dengan menggunakan nilai diatas 500.
2. Dalam pengerjaan tugas akhir dengan menggunakan data yang sama dapat dilakukan dengan metode *hybrid* lain, seperti ARIMA-ANFIS, ARIMA-Regresi, dan metode *hybrid* lainnya.

3. Untuk pengerjaan tugas akhir kedepan dapat menggunakan metode yang lain seperti ARIMAX, ARIMA-GARCH, atau menggunakan metode peramalan lainnya.

*(Halaman ini sengaja dikosongkan)*

## DAFTAR PUSTAKA

- [1 A. BPS, "<https://www.bps.go.id/>," Badan Pusat Statistika,  
] 18 Februari 2014. [Online]. Available:  
<https://www.bps.go.id/linkTabelStatis/view/id/1276>.  
[Accessed 27 Februari 2017].
- [2 P. S. Tarigan, "Proyeksi Jumlah Penumpang Domestik  
] pada PT. Angkasa Pura II Bandara Polonia Medan 2010-  
2011," Tugas Akhir Mahasiswa USU, Medan, 2009.
- [3 U. Umaedah, "<http://phinemo.com/>," Phinemo.com, 20 Juni  
] 2015. [Online]. Available: [http://phinemo.com/6-bandara-  
terbaik-indonesia-dengan-berbagai-keunggulannya/](http://phinemo.com/6-bandara-terbaik-indonesia-dengan-berbagai-keunggulannya/).  
[Accessed 27 Februari 2017].
- [4 J. E. Hanke and D. W. Wichern, Business Forecasting  
] Eight Edition, New Jersey: Pearson Prentice Hall, 2005.
- [5 M. A. Mukhyi, 2008. [Online]. Available:  
] [mukhyi.staff.gunadarma.ac.id/Downloads/files/9309/FOR  
CASTING.pdf](http://mukhyi.staff.gunadarma.ac.id/Downloads/files/9309/FORCASTING.pdf). [Accessed 03 Januari 2017].
- [6 D. E. Rufiyanti, "IMPLEMENTASI JARINGAN SARAF  
] TIRUAN BACKPROPAGATION DENGAN INPUT  
MODEL ARIMA UNTUK PERAMALAN HARGA  
SAHAM," Universitas Negeri Semarang, Semarang, 2015.
- [7 G. P. Zhang, Neural Networks for Classification: A Survey,  
] IEEE Transactions On Systems, Man and Cybernetics,  
2000.

- [8] X. Wang and M. Meng, A Hybrid Neural Network and ARIMA Model for Energy Consumption Forecasting, Journal Of Computer, 2012.
- [9] Sudjana, "Metode Statistika," Tarsito, Bandung, 1986.
- [10] Z. Soejoeti, Analisis Runtun Waktu, Jakarta: Karunika Jakarta, 1987.
- [11] Makridakis, "Metode dan aplikasi peramalan Edisi 2," Binarupa Aksara, Jakarta, 1999.
- [12] S. Makridakis, Metode dan Aplikasi Peramalan, Jakarta: Erlangga, 1999.
- [13] S. Santoso, Business Forecasting: Metode Peramalan Bisnis Masa Kini dengan MINITAB dan SPSS, Jakarta: PT. Elex Media Komputindo, 2009.
- [14] A. Supangat, Statistika dalam Kajian Deskriptif, Inferensi, dan Non Parametrik, Jakarta: Kencana, 2007.
- [15] P. A, Forecasting With Univariate Box – Jenkins Model, New Jersey (US): John Willey & Sons, Inc, 1983.
- [16] H. C, Neural Network and Their Statistical Application, SSRN Working Paper, 2006.

- [17] I. Herlambang, "Peramalan Hasil Penangkapan Ikan Konsumsi Air Tawar di Kabupaten Mojokerto dengan Metode ARIMA Box-Jenkins," Institut Teknologi Sepuluh Nopember, Juni 2008. [Online]. Available: <http://www.slideshare.net/indraherlangga/tugas-akhir-indra-herlangga-1305030029>. [Accessed 04 Januari 2017].
- [18] C. Gershenson, "Artificial Neural Networks for Beginners," 20 aGUSTUS 2003. [Online]. Available: <https://arxiv.org/ftp/cs/papers/0308/0308031.pdf>. [Accessed 05 Januari 2017].
- [19] A. Halim, M. Eric and Layong, "Analisis dan Perancangan Pengenal Tanda Tangan dengan Jaringan Syaraf Tiruan Metode Propagasi Balik," Universitas Bina Nusantara, Jakarta, 2004.
- [20] J. J. Siang, "Jaringan Syaraf Tiruan dan Pemrogramannya Menggunakan MATLAB," Andi, Yogyakarta, 2005.
- [21] S. Kusumadewi, "Membangun Jaringan Syaraf Tiruan Menggunakan MATLAB & EXCEL LINK," Graha Ilmu, Yogyakarta, 2004.
- [22] S. Makridakis and S. C. Wheelright, "Accuracy of Forecasting : An Ampirical Investigation," J. R. Statist. Soc, 1979.
- [23] G. P. Zhang, "Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model," 2003. [Online]. Available: [www.elsevier.com/locate/neucom](http://www.elsevier.com/locate/neucom). [Accessed 27 Februari 2017].

- [24] Nurmahaludin, Perbandingan Algoritma Particle Swarm Optimization dan Regresi pada Peramalan Waktu Beban Puncak, *Jurnal POROS TEKNIK*, 2014.
- [25] B. H. and R. K. A., "Rencana Restorasi Lahan Rawa," [Online]. Available: <http://cs.unsyiah.ac.id/tpsf/images/pdf/09-Wetland-Restoration-Plan.pdf>. [Accessed 05 Juni 2017].
- [26] B. G. E. and C. D. R., "An Analysis of Transformations," *Journal of the Royal Statistical Society*, vol. 26, no. 2, pp. 211-252, 1964.
- [27] I. G. Inc, "EViews 9 User's Guide II," IHS Global Inc, California, 2015.
- [28] Enaryasih, "Hubungan Iklim (Suhu Udara, Curah Hujan, Kelembapan dan Kecepatan Angin) dengan Kasus Diare di DKI Jakarta Tahun 2007-2011," 2012.
- [29] T. Hayati, R. F. Umbara and E. Sumaryatie, "PERAMALAN NILAI TUKAR RUPIAH (IDR) TERHADAP DOLAR (USD) DENGAN MENGGUNAKAN METODE GABUNGAN ARIMA (AUTOREGRESSIVE INTEGRATED MOVING AVERAGE) DAN ANN (ARTIFICIAL NEURAL NETWORK)," Telkom University, Bandung, 2014.
- [30] A. Machmudin and B. S. S. Ulama, "Peramalan Temperatur Udara di Kota Surabaya dengan Menggunakan ARIMA dan Artificial Neural Network," ITS, Surabaya, 2012.



- [31] D. E. Rufiyanti, "IMPLEMENTASI JARINGAN SYARAF TIRUAN BACKPROPAGATION DENGAN INPUT MODEL ARIMA UNTUK PERAMALAN HARGA SAHAM," Universitas Negeri Malang, Malang, 2015.
- [32] H. Demuth, "Neural Network Toolbox 6 User's Guide," MathWorks, Natick, 2009.
- [33] M. A. Shahin, H. R. Maier and M. B. Jaksa, Data Division for Developing Neural Networks Applied to Geotechnical Engineering, Journal of Computing in Civil Engineering ASCE, 2004.
- [34] G. Pramudita, "Visualisasi dan Peramalan Jumlah Kasus Demam Berdarah Dengue di Kabupaten Malang Menggunakan Metode Google Maps API dan Artificial Neural Network," ITS, Surabaya, 2015.
- [35] Herlina, "Sistem Saraf Fisiologi Veteriner," Universitas Brawijaya, Maret 2015. [Online]. Available: <http://herlina.lecture.ub.ac.id/files/2015/03/SISTEM-SARAF.q.pdf>. [Accessed 05 Januari 2017].
- [36] T. Mulyadi, "Cara Kerja Neuron (Saraf)," April 2015. [Online]. Available: <http://budisma.net/2015/04/cara-kerja-neuron-saraf.html>. [Accessed 05 Januari 2017].
- [37] Sugiyono, Metode Penelitian Kuantitatif Kualitatif dan R & D, Bandung: Alfabeta, 2013.

*(Halaman ini sengaja dikosongkan)*

## BIODATA PENULIS



Penulis lahir di Surabaya pada 4 Maret 1995. Penulis merupakan anak ketiga dari Bapak Agus I Supriyanto dan Ibu Annik Lestari. Penulis telah menempuh pendidikan formal di SD Negeri III/463 Surabaya, SMP Negeri 16 Surabaya, dan SMA Negeri 6 Surabaya. Pada 2013, penulis diterima di Jurusan Sistem Informasi, Institut Teknologi Sepuluh Nopember (ITS) Surabaya melalui jalur Mandiri (PKM) dan terdaftar dengan NRP 5213100186. Selain pada bidang teknologi informasi yang ditekuni pada jurusan ini, penulis memiliki ketertarikan dalam bidang jurnalistik dan menulis. Selama masa kuliah, penulis memiliki beberapa pengalaman organisasi di ITS, diantaranya adalah menjadi anggota Departemen Media Informasi, Himpunan Mahasiswa Sistem Informasi (HMSI). Selain itu, penulis juga sering mengikuti kepanitiaan, seperti sekretaris umum Pelatihan Jurnalistik Tingkat Dasar yang diadakan HMSI, anggota tim konsumsi ISE 2014, dan bendahara umum 2015, Penulis juga pernah melakukan kerja praktik di PT. Pertamina EP pada Divisi ICT Solution, Fungsi Business Solution selama 2 bulan pada tahun 2016.

Dalam pengerjaan tugas akhir di Jurusan Sistem Informasi ITS, penulis mengambil bidang minat Rekayasa Data dan Intelegensi Bisnis dengan topik Forecasting. Apabila terdapat kritik, saran, atau pertanyaan mengenai tugas akhir ini, dapat dikirimkan pada *email* penulis: [pramitaluciannaps@gmail.com](mailto:pramitaluciannaps@gmail.com)

*(Halaman ini sengaja dikosongkan)*

## LAMPIRAN A DATA MENTAH

**Tabel A. 1 Lampiran Data Mentah**

Periode	Jumlah Penumpang	
	Kedatangan	Keberangkatan
Jan-07	302.539	301.274
Feb-07	249.045	236.082
Mar-07	294.833	270.626
Apr-07	294.854	270.891
Mei-07	314.862	288.669
Jun-07	312.516	289.945
Jul-07	364.672	340.639
Agu-07	343.046	321.013
Sep-07	309.192	269.195
Okt-07	374.704	327.779
Nov-07	369.777	332.135
Des-07	376.991	324.457
Jan-08	346.055	328.446
Feb-08	308.714	282.242
Mar-08	333.249	310.829
Apr-08	301.165	275.959
Mei-08	318.660	281.806
Jun-08	304.289	281.428
Jul-08	330.681	313.235
Agu-08	327.916	298.881
Sep-08	250.660	221.823
Okt-08	352.207	340.406
Nov-08	301.234	294.919
Des-08	291.032	309.608
Jan-09	334.165	330.203
Feb-09	322.738	289.838
Mar-09	339.224	319.658
Apr-09	332.520	311.808
Mei-09	345.461	337.949
Jun-09	392.981	356.683

Periode	Jumlah Penumpang	
	Kedatangan	Keberangkatan
Jul-09	416.390	391.103
Agu-09	402.553	381.083
Sep-09	402.680	316.356
Okt-09	492.869	444.027
Nov-09	416.127	381.768
Des-09	433.749	405.232
Jan-10	368.933	387.690
Feb-10	370.322	350.787
Mar-10	450.212	389.281
Apr-10	389.521	387.993
Mei-10	441.320	410.342
Jun-10	450.294	414.672
Jul-10	488.498	458.060
Agu-10	392.894	345.599
Sep-10	394.889	431.243
Okt-10	457.448	477.450
Nov-10	459.691	449.042
Des-10	473.164	466.425
Jan-11	471.325	457.763
Feb-11	437.005	412.203
Mar-11	446.102	436.203
Apr-11	423.303	428.087
Mei-11	460.133	441.048
Jun-11	516.560	459.600
Jul-11	549.007	503.243
Agu-11	460.825	347.598
Sep-11	502.203	546.766
Okt-11	515.656	508.784
Nov-11	535.958	507.776
Des-11	556.917	521.433
Jan-12	553.330	530.692
Feb-12	514.305	494.799

Periode	Jumlah Penumpang	
	Kedatangan	Keberangkatan
Mar-12	550.877	554.229
Apr-12	526.268	522.512
Mei-12	583.471	535.935
Jun-12	611.292	528.568
Jul-12	637.443	526.652
Agu-12	671.624	572.259
Sep-12	585.304	649.035
Okt-12	648.606	584.012
Nov-12	649.681	607.734
Des-12	688.973	607.416
Jan-13	655.399	611.667
Feb-13	579.762	514.135
Mar-13	649.873	584.354
Apr-13	617.811	555.150
Mei-13	673.209	589.633
Jun-13	731.454	625.357
Jul-13	629.873	510.154
Agu-13	712.554	658.649
Sep-13	613.451	620.257
Okt-13	697.160	624.384
Nov-13	642.028	593.866
Des-13	703.276	622.828
Jan-14	664.046	616.951
Feb-14	532.374	485.351
Mar-14	603.741	544.989
Apr-14	572.023	510.996
Mei-14	647.387	554.209
Jun-14	705.679	609.627
Jul-14	651.936	455.616
Agu-14	697.084	743.276
Sep-14	632.443	604.234
Okt-14	684.668	635.975

Periode	Jumlah Penumpang	
	Kedatangan	Keberangkatan
Nov-14	653.296	593.137
Des-14	745.163	644.558
Jan-15	587.187	550.925
Feb-15	523.015	461.200
Mar-15	557.819	492.993
Apr-15	583.588	513.301
Mei-15	674.270	568.271
Jun-15	662.017	518.583
Jul-15	763.157	608.491
Agu-15	647.933	699.259
Sep-15	618.349	545.042
Okt-15	658.365	605.023
Nov-15	658.108	587.291
Des-15	797.545	671.396
Jan-16	714.786	656.208
Feb-16	653.932	571.726
Mar-16	719.666	618.395
Apr-16	695.548	596.535
Mei-16	801.991	675.702
Jun-16	715.523	523.451
Jul-16	886.902	825.715
Agu-16	707.513	683.946
Sep-16	733.269	649.375
Okt-16	692.759	621.999
Nov-16	696.837	603.190
Des-16	807.475	693.125
Jan-17	729.101	672.153
Feb-17	633.231	546.280
Mar-17	705.927	614.205



## LAMPIRAN B UJI SIGNIFIKANSI PARAMETER

Dependent Variable: D(TKEDATANGAN)  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 05/29/17 Time: 15:17  
 Sample: 2 88  
 Included observations: 87  
 Convergence achieved after 11 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(1)	-0.538740	0.091981	-5.857079	0.0000
SIGMASQ	0.008952	0.001438	6.226020	0.0000

**Gambar B. 1 Uji Signifikansi Parameter ARIMA (0,1,1)**

Dependent Variable: D(T\_TRAINKEDATANGAN)  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 05/29/17 Time: 21:24  
 Sample: 2 88  
 Included observations: 87  
 Convergence achieved after 8 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	-0.481070	0.103603	-4.643417	0.0000
SIGMASQ	0.009324	0.001390	6.709996	0.0000

**Gambar B. 2 Uji Signifikansi Parameter ARIMA (1,1,0)**

Dependent Variable: D(T\_TRAINKEDATANGAN)  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 05/29/17 Time: 21:26  
 Sample: 2 88  
 Included observations: 87  
 Convergence achieved after 20 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	-0.165472	0.234902	-0.704431	0.4831
MA(1)	-0.425853	0.208553	-2.041943	0.0443
SIGMASQ	0.008872	0.001430	6.205648	0.0000

**Gambar B. 3 Uji Signifikansi Parameter ARIMA (1,1,1)**

Dependent Variable: D(T\_TRAINKEDATANGAN)  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 05/29/17 Time: 21:28  
 Sample: 2 88  
 Included observations: 87  
 Convergence achieved after 9 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(2)	0.055552	0.125685	0.441993	0.6596
SIGMASQ	0.012038	0.001833	6.566420	0.0000

**Gambar B. 4 Uji Signifikansi Parameter ARIMA (2,1,0)**

Dependent Variable: D(T\_TRAINKEDATANGAN)  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 05/29/17 Time: 21:30  
 Sample: 2 88  
 Included observations: 87  
 Convergence achieved after 15 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(2)	0.080990	0.150993	0.536381	0.5931
MA(1)	-0.566011	0.103701	-5.458123	0.0000
SIGMASQ	0.008908	0.001431	6.224872	0.0000

**Gambar B. 5 Uji Signifikansi Parameter ARIMA (2,1,1)**

Dependent Variable: D(T\_TRAINKEDATANGAN)  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 05/29/17 Time: 21:30  
 Sample: 2 88  
 Included observations: 87  
 Convergence achieved after 7 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(3)	0.050267	0.125237	0.401378	0.6891
SIGMASQ	0.012046	0.001876	6.420511	0.0000

**Gambar B. 6 Uji Signifikansi Parameter ARIMA (3,1,0)**

Dependent Variable: D(T\_TRAINKEDATANGAN)  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 05/29/17 Time: 21:31  
 Sample: 2 88  
 Included observations: 87  
 Convergence achieved after 11 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(3)	0.049194	0.119096	0.413060	0.6806
MA(1)	-0.548387	0.094360	-5.811659	0.0000
SIGMASQ	0.008934	0.001502	5.949021	0.0000

### Gambar B. 7 Uji Signifikansi Parameter ARIMA (3,1,1)

Dependent Variable: D(T\_TRAINKEDATANGAN,2)  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 06/04/17 Time: 14:06  
 Sample: 3 88  
 Included observations: 86  
 Failure to improve objective (non-zero gradients) after 45 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(1)	-0.999999	1096.392	-0.000912	0.9993
SIGMASQ	0.012161	0.349160	0.034828	0.9723

### Gambar B. 8 Uji Signifikansi Parameter ARIMA (0,2,1)

Dependent Variable: D(T\_TRAINKEDATANGAN,2)  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 06/04/17 Time: 14:09  
 Sample: 3 88  
 Included observations: 86  
 Convergence achieved after 21 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(2)	0.237538	0.131781	1.802521	0.0751
SIGMASQ	0.033806	0.004564	7.406651	0.0000

### Gambar B. 9 Uji Signifikansi Parameter ARIMA (0,2,2)

Dependent Variable: D(T\_TRAINKEDATANGAN,2)  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 06/04/17 Time: 14:36  
 Sample: 3 88  
 Included observations: 86  
 Convergence achieved after 21 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(3)	0.261567	0.113268	2.309267	0.0234
SIGMASQ	0.034466	0.005625	6.127712	0.0000

**Gambar B. 10 Uji Signifikansi Parameter ARIMA (0,2,3)**

Dependent Variable: D(T\_TRAINKEDATANGAN,2)  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 06/04/17 Time: 14:44  
 Sample: 3 88  
 Included observations: 86  
 Convergence achieved after 5 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	-0.688838	0.079521	-8.662371	0.0000
SIGMASQ	0.019102	0.002549	7.493616	0.0000

**Gambar B. 11 Uji Signifikansi Parameter ARIMA (1,2,0)**

Dependent Variable: D(T\_TRAINKEDATANGAN,2)  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 06/04/17 Time: 14:46  
 Sample: 3 88  
 Included observations: 86  
 Failure to improve objective (non-zero gradients) after 7 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	-0.485778	0.111733	-4.347677	0.0000
MA(1)	-1.000000	884.6530	-0.001130	0.9991
SIGMASQ	0.009279	0.182207	0.050924	0.9595

**Gambar B. 12 Uji Signifikansi Parameter ARIMA (1,2,1)**

Dependent Variable: D(T\_TRAINKEDATANGAN,2)  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 06/04/17 Time: 14:50  
 Sample: 3 88  
 Included observations: 86  
 Failure to improve objective (non-zero gradients) after 12 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	-0.948898	0.074533	-12.73118	0.0000
MA(2)	-0.999999	151.3622	-0.006607	0.9947
SIGMASQ	0.011842	0.903898	0.013102	0.9896

**Gambar B. 13 Uji Signifikansi Parameter ARIMA (1,2,2)**

Dependent Variable: D(T\_TRAINKEDATANGAN,2)  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 06/04/17 Time: 14:54  
 Sample: 3 88  
 Included observations: 86  
 Convergence achieved after 27 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	-0.692654	0.082791	-8.366298	0.0000
MA(3)	0.205497	0.143117	1.435867	0.1548
SIGMASQ	0.018567	0.002614	7.102837	0.0000

**Gambar B. 14 Uji Signifikansi Parameter ARIMA (1,2,3)**

Dependent Variable: D(T\_TRAINKEDATANGAN,2)  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 06/04/17 Time: 15:06  
 Sample: 3 88  
 Included observations: 86  
 Convergence achieved after 8 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(2)	0.179240	0.122094	1.468051	0.1458
SIGMASQ	0.034314	0.004735	7.247081	0.0000

**Gambar B. 15 Uji Signifikansi Parameter ARIMA (2,2,0)**

Dependent Variable: D(T\_TRAINKEDATANGAN,2)  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 06/04/17 Time: 15:10  
 Sample: 3 88  
 Included observations: 86  
 Failure to improve objective (non-zero gradients) after 9 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(2)	0.064108	0.125396	0.511248	0.6105
MA(1)	-1.000000	971.6348	-0.001029	0.9992
SIGMASQ	0.012131	0.261223	0.046440	0.9631

**Gambar B. 16 Uji Signifikansi Parameter ARIMA (2,2,1)**

Dependent Variable: D(T\_TRAINKEDATANGAN,2)  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 06/04/17 Time: 15:13  
 Sample: 3 88  
 Included observations: 86  
 Convergence achieved after 15 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(2)	-0.072637	0.558236	-0.130119	0.8968
MA(2)	0.297423	0.553123	0.537716	0.5922
SIGMASQ	0.033778	0.004583	7.370087	0.0000

**Gambar B. 17 Uji Signifikansi Parameter ARIMA (2,2,2)**

Dependent Variable: D(T\_TRAINKEDATANGAN,2)  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 06/04/17 Time: 15:16  
 Sample: 3 88  
 Included observations: 86  
 Convergence achieved after 14 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(2)	0.288819	0.139360	2.072467	0.0413
MA(3)	0.373033	0.147048	2.536804	0.0131
SIGMASQ	0.031901	0.005004	6.374989	0.0000

**Gambar B. 18 Uji Signifikansi Parameter ARIMA (2,2,3)**

Keberangkatan

Dependent Variable: T\_TRAINKEBERANGKATAN  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 07/04/17 Time: 07:33  
 Sample: 1 88  
 Included observations: 88  
 Failure to improve objective (non-zero gradients) after 18 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(1)	0.999999	782.8089	0.001277	0.9990
SIGMASQ	42.44442	880.9327	0.048181	0.9617

**Gambar B. 19 Uji Signifikansi Parameter ARMA (0,1)**

Dependent Variable: T\_TRAINKEBERANGKATAN  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 07/04/17 Time: 07:45  
 Sample: 1 88  
 Included observations: 88  
 Convergence achieved after 20 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.999944	0.000768	1301.281	0.0000
SIGMASQ	0.018645	0.002034	9.167442	0.0000

**Gambar B. 20 Uji Signifikansi Parameter ARMA (1,0)**

Dependent Variable: T\_TRAINKEBERANGKATAN  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 07/04/17 Time: 07:47  
 Sample: 1 88  
 Included observations: 88  
 Convergence achieved after 26 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.999996	0.000215	4641.710	0.0000
MA(1)	-0.660836	0.089565	-7.378325	0.0000
SIGMASQ	0.011503	0.001738	6.619461	0.0000

**Gambar B. 21 Uji Signifikansi Parameter ARMA (1,1)**

Dependent Variable: T\_TRAINKEBERANGKATAN  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 07/04/17 Time: 07:51  
 Sample: 1 88  
 Included observations: 88  
 Convergence achieved after 20 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.999944	0.000768	1301.281	0.0000
SIGMASQ	0.018645	0.002034	9.167442	0.0000

**Gambar B. 22 Uji Signifikansi Parameter ARMA (1,0)**

Dependent Variable: T\_TRAINKEBERANGKATAN  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 07/04/17 Time: 08:11  
 Sample: 1 88  
 Included observations: 88  
 Convergence achieved after 27 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(2)	0.999964	0.000344	2904.682	0.0000
MA(1)	-0.126772	0.137588	-0.921388	0.3595
SIGMASQ	0.015758	0.002093	7.527015	0.0000

**Gambar B. 23 Uji Signifikansi Parameter ARMA (2,1)**

Dependent Variable: T\_TRAINKEBERANGKATAN  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 07/04/17 Time: 08:12  
 Sample: 1 88  
 Included observations: 88  
 Convergence achieved after 13 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(3)	0.999950	0.000501	1994.769	0.0000
SIGMASQ	0.016588	0.002487	6.669456	0.0000

**Gambar B. 24 Uji Signifikansi Parameter ARMA (3,0)**



Dependent Variable: T\_TRAINKEBERANGKATAN  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 07/04/17 Time: 08:15  
 Sample: 1 88  
 Included observations: 88  
 Convergence achieved after 21 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(3)	0.999948	0.000520	1923.212	0.0000
MA(1)	0.017398	0.136933	0.127053	0.8992
SIGMASQ	0.016601	0.002498	6.645081	0.0000

**Gambar B. 25 Uji Signifikansi Parameter ARMA (3,1)**

Dependent Variable: D(T\_TRAINKEBERANGKATAN,2)  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 07/04/17 Time: 08:18  
 Sample: 3 88  
 Included observations: 86  
 Failure to improve objective (non-zero gradients) after 21 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(1)	-0.999999	1426.996	-0.000701	0.9994
SIGMASQ	0.018825	0.697928	0.026973	0.9785

**Gambar B. 26 Uji Signifikansi Parameter ARIMA (0,2,1)**

Dependent Variable: D(T\_TRAINKEBERANGKATAN,2)  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 07/04/17 Time: 08:19  
 Sample: 3 88  
 Included observations: 86  
 Convergence achieved after 18 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(2)	0.263574	0.134738	1.956199	0.0538
SIGMASQ	0.054982	0.005937	9.261352	0.0000

**Gambar B. 27 Uji Signifikansi Parameter ARIMA (0,2,2)**

Dependent Variable: D(T\_TRAINKEBERANGKATAN,2)  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 07/04/17 Time: 08:26  
 Sample: 3 88  
 Included observations: 86  
 Convergence achieved after 9 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
MA(3)	0.101861	0.196743	0.517736	0.6060
SIGMASQ	0.057574	0.006900	8.344031	0.0000

**Gambar B. 28 Uji Signifikansi Parameter ARIMA (0,2,3)**

Dependent Variable: D(T\_TRAINKEBERANGKATAN,2)  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 07/04/17 Time: 08:28  
 Sample: 3 88  
 Included observations: 86  
 Failure to improve objective (non-zero gradients) after 14 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	-0.574736	0.081607	-7.042729	0.0000
MA(1)	-1.000000	1094.421	-0.000914	0.9993
SIGMASQ	0.012619	0.306257	0.041205	0.9672

**Gambar B. 29 Uji Signifikansi Parameter ARIMA (1,2,1)**

Dependent Variable: D(T\_TRAINKEBERANGKATAN,2)  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 07/04/17 Time: 08:31  
 Sample: 3 88  
 Included observations: 86  
 Convergence achieved after 30 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	-0.999995	0.055812	-17.91729	0.0000
MA(2)	-0.999183	0.002769	-360.8431	0.0000
SIGMASQ	0.018497	0.002057	8.991660	0.0000

**Gambar B. 30 Uji Signifikansi Parameter ARIMA (1,2,2)**

Dependent Variable: D(T\_TRAINKEBERANGKATAN,2)  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 07/04/17 Time: 08:35  
 Sample: 3 88  
 Included observations: 86  
 Convergence achieved after 14 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	-0.753422	0.083576	-9.014815	0.0000
MA(3)	0.309530	0.175568	1.763027	0.0816
SIGMASQ	0.026385	0.003616	7.296772	0.0000

**Gambar B. 31 Uji Signifikansi Parameter ARIMA (1,2,3)**

Dependent Variable: D(T\_TRAINKEBERANGKATAN,2)  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 07/04/17 Time: 08:36  
 Sample: 3 88  
 Included observations: 86  
 Failure to improve objective (non-zero gradients) after 206 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(2)	0.087436	0.179652	0.486698	0.6278
MA(1)	-0.999997	2429.196	-0.000412	0.9997
SIGMASQ	0.018724	1.726093	0.010848	0.9914

**Gambar B. 32 Uji Signifikansi Parameter ARIMA (2,2,1)**

Dependent Variable: D(T\_TRAINKEBERANGKATAN,2)  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 07/04/17 Time: 08:38  
 Sample: 3 88  
 Included observations: 86  
 Convergence achieved after 27 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(2)	-0.171224	0.723374	-0.236702	0.8135
MA(2)	0.415532	0.669502	0.620658	0.5365
SIGMASQ	0.054735	0.005994	9.131775	0.0000

**Gambar B. 33 Uji Signifikansi Parameter ARIMA (2,2,2)**

Dependent Variable: D(T\_TRAINKEBERANGKATAN,2)  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 07/04/17 Time: 08:39  
 Sample: 3 88  
 Included observations: 86  
 Convergence achieved after 17 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(2)	0.410819	0.154839	2.653202	0.0096
MA(3)	0.367830	0.185392	1.984068	0.0506
SIGMASQ	0.050956	0.005348	9.528482	0.0000

**Gambar B. 34 Uji Signifikansi Parameter ARIMA (2,2,3)**

Dependent Variable: D(T\_TRAINKEBERANGKATAN,2)  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 07/04/17 Time: 08:43  
 Sample: 3 88  
 Included observations: 86  
 Failure to improve objective (non-zero gradients) after 89 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(3)	0.104902	0.218514	0.480071	0.6324
MA(1)	-0.999997	2125.743	-0.000470	0.9996
SIGMASQ	0.018673	1.410491	0.013239	0.9895

**Gambar B. 35 Uji Signifikansi Parameter ARIMA (3,2,1)**

Dependent Variable: D(T\_TRAINKEBERANGKATAN,2)  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 07/04/17 Time: 08:46  
 Sample: 3 88  
 Included observations: 86  
 Convergence achieved after 11 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(3)	0.238589	0.246128	0.969371	0.3352
MA(2)	0.338896	0.138741	2.442647	0.0167
SIGMASQ	0.052102	0.005964	8.736463	0.0000

**Gambar B. 36 Uji Signifikansi Parameter ARIMA (3,2,2)**

Dependent Variable: D(T\_TRAINKEBERANGKATAN,2)  
Method: ARMA Maximum Likelihood (OPG - BHHH)  
Date: 07/04/17 Time: 08:48  
Sample: 3 88  
Included observations: 86  
Convergence achieved after 23 iterations  
Coefficient covariance computed using outer product of gradients































Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(3)	-0.244874	1.499644	-0.163288	0.8707
MA(3)	0.350357	1.358103	0.257975	0.7971
SIGMASQ	0.057341	0.007140	8.030889	0.0000

**Gambar B. 37 Uji Signifikansi Parameter ARIMA (3,2,3)**

*(Halaman ini sengaja dikosongkan)*































## LAMPIRAN C Uji DIAGNOSTIK PARAMETER

Date: 05/31/17 Time: 16:01  
 Sample: 1 88  
 Included observations: 87  
 Q-statistic probabilities adjusted for 1 ARMA term

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.090	-0.090	0.7360	
		2 0.017	0.009	0.7638	0.382
		3 -0.005	-0.003	0.7662	0.682
		4 -0.112	-0.114	1.9401	0.585
		5 0.157	0.139	4.2545	0.373
		6 -0.143	-0.121	6.2213	0.285
		7 0.207	0.193	10.350	0.111
		8 -0.083	-0.078	11.022	0.138
		9 -0.125	-0.107	12.565	0.128
		10 -0.169	-0.252	15.433	0.080
		11 -0.143	-0.102	17.514	0.064
		12 0.375	0.321	32.045	0.001
		13 -0.139	-0.065	34.064	0.001
		14 -0.029	-0.129	34.152	0.001
		15 -0.066	-0.090	34.623	0.002

**Gambar C. 1 Uji Diagnostik (Acak) ARIMA(0,1,1)**

Date: 05/31/17 Time: 16:05  
 Sample: 1 88  
 Included observations: 87

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.011	0.011	0.0102	0.920
		2 -0.150	-0.150	2.0569	0.358
		3 -0.007	-0.004	2.0613	0.560
		4 -0.047	-0.071	2.2674	0.687
		5 0.004	0.004	2.2692	0.811
		6 -0.133	-0.155	3.9495	0.684
		7 0.023	0.029	4.0005	0.780
		8 0.013	-0.040	4.0173	0.856
		9 0.115	0.131	5.3314	0.805
		10 -0.025	-0.058	5.3918	0.864
		11 -0.039	0.013	5.5447	0.902
		12 0.185	0.158	9.0793	0.696
		13 0.078	0.103	9.7220	0.716
		14 0.021	0.071	9.7689	0.779
		15 -0.021	0.045	9.8178	0.831

**Gambar C. 2 Uji Diagnostik (Homogen) ARIMA(0,1,1)**

Date: 05/31/17 Time: 16:06  
 Sample: 188  
 Included observations: 87  
 Q-statistic probabilities adjusted for 1 ARMA term

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1	-0.106	-0.106	1.0147
		2	-0.195	-0.208	4.4661
		3	-0.015	-0.066	4.4876
		4	-0.085	-0.145	5.1576
		5	0.121	0.078	6.5355
		6	-0.110	-0.144	7.6844
		7	0.206	0.234	11.788
		8	-0.011	-0.029	11.799
		9	-0.129	-0.009	13.440
		10	-0.228	-0.330	18.673
		11	-0.084	-0.119	19.393
		12	0.433	0.268	38.767
		13	-0.102	-0.046	39.862
		14	-0.089	-0.052	40.694
		15	-0.040	-0.099	40.866

**Gambar C. 3 Uji Diagnostik (Acak) ARIMA(1,1,0)**

Date: 05/31/17 Time: 16:09  
 Sample: 188  
 Included observations: 87

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1	0.034	0.034	0.1017
		2	-0.120	-0.122	1.4213
		3	-0.041	-0.033	1.5733
		4	-0.068	-0.082	2.0103
		5	0.011	0.007	2.0217
		6	-0.183	-0.208	5.2215
		7	0.033	0.045	5.3256
		8	0.039	-0.024	5.4777
		9	0.053	0.055	5.7614
		10	0.006	-0.029	5.7656
		11	-0.059	-0.031	6.1181
		12	0.227	0.208	11.429
		13	0.047	0.043	11.660
		14	-0.037	0.020	11.807
		15	-0.006	0.035	11.810

**Gambar C. 4 Uji Diagnostik (Homogen) ARIMA(1,1,0)**



Date: 06/04/17 Time: 16:24  
 Sample: 1 88  
 Included observations: 86  
 Q-statistic probabilities adjusted for 1 ARMA term

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.663	-0.663	39.187	0.000
		2 0.247	-0.345	44.676	0.000
		3 -0.083	-0.186	45.301	0.000
		4 -0.119	-0.410	46.604	0.000
		5 0.272	-0.100	53.519	0.000
		6 -0.322	-0.295	63.324	0.000
		7 0.300	-0.159	71.925	0.000
		8 -0.113	0.092	73.161	0.000
		9 -0.029	0.112	73.243	0.000
		10 0.066	0.127	73.680	0.000
		11 -0.290	-0.353	82.170	0.000
		12 0.464	-0.059	104.15	0.000
		13 -0.308	0.090	113.98	0.000
		14 0.113	-0.025	115.34	0.000
		15 -0.014	-0.058	115.36	0.000

**Gambar C. 5 Uji Diagnostik Parameter (Acak) ARIMA(0,2,3)**

Date: 06/04/17 Time: 16:53  
 Sample: 1 88  
 Included observations: 86

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.419	0.419	15.655	0.000
		2 0.026	-0.182	15.717	0.000
		3 -0.032	0.039	15.811	0.001
		4 -0.065	-0.075	16.201	0.003
		5 -0.055	0.001	16.483	0.006
		6 -0.098	-0.101	17.388	0.008
		7 -0.056	0.031	17.691	0.013
		8 -0.143	-0.187	19.673	0.012
		9 -0.112	0.033	20.915	0.013
		10 -0.137	-0.173	22.775	0.012
		11 -0.134	-0.019	24.584	0.010
		12 0.149	0.231	26.855	0.008
		13 0.114	-0.121	28.201	0.008
		14 0.024	0.013	28.262	0.013
		15 0.057	0.065	28.604	0.018

**Gambar C. 6 Uji Diagnostik Parameter (Homogen) ARIMA(0,2,3)**

Date: 06/04/17 Time: 16:05  
 Sample: 188  
 Included observations: 86  
 Q-statistic probabilities adjusted for 1 ARMA term

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.316	-0.316	8.9134	
		2 -0.276	-0.418	15.761	0.000
		3 0.128	-0.172	17.248	0.000
		4 -0.077	-0.280	17.800	0.000
		5 0.142	0.004	19.679	0.001
		6 -0.202	-0.310	23.555	0.000
		7 0.190	0.099	26.995	0.000
		8 0.045	-0.004	27.192	0.000
		9 -0.036	0.267	27.321	0.001
		10 -0.214	-0.279	31.869	0.000
		11 -0.118	-0.266	33.264	0.000
		12 0.474	0.061	56.229	0.000
		13 -0.177	0.018	59.469	0.000
		14 -0.093	0.018	60.383	0.000
		15 0.039	-0.089	60.543	0.000

**Gambar C. 7 Uji Diagnostik Parameter (Acak) ARIMA(1,2,0)**

Date: 06/04/17 Time: 16:49  
 Sample: 188  
 Included observations: 86

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.222	0.222	4.3834	0.036
		2 -0.048	-0.102	4.5924	0.101
		3 -0.062	-0.030	4.9465	0.176
		4 -0.030	-0.014	5.0290	0.284
		5 -0.008	-0.006	5.0352	0.412
		6 -0.075	-0.082	5.5633	0.474
		7 0.016	0.054	5.5894	0.588
		8 -0.102	-0.140	6.6076	0.580
		9 -0.030	0.027	6.6976	0.669
		10 -0.090	-0.116	7.5123	0.676
		11 -0.073	-0.036	8.0450	0.709
		12 0.205	0.225	12.345	0.418
		13 0.111	-0.005	13.634	0.400
		14 -0.023	-0.059	13.691	0.473
		15 -0.013	0.056	13.708	0.548

**Gambar C. 8 Uji Diagnostik Parameter (Homogen) ARIMA(1,2,0)**

Date: 06/04/17 Time: 16:03  
 Sample: 1 88  
 Included observations: 86  
 Q-statistic probabilities adjusted for 2 ARMA terms

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.523	-0.523	24.400	
		2 0.053	-0.305	24.650	
		3 -0.065	-0.287	25.035	0.000
		4 -0.089	-0.435	25.768	0.000
		5 0.236	-0.174	30.984	0.000
		6 -0.257	-0.443	37.255	0.000
		7 0.270	-0.263	44.260	0.000
		8 -0.054	-0.040	44.538	0.000
		9 -0.059	0.109	44.875	0.000
		10 -0.042	0.112	45.052	0.000
		11 -0.221	-0.345	49.979	0.000
		12 0.480	-0.002	73.549	0.000
		13 -0.237	0.041	79.385	0.000
		14 0.026	-0.048	79.457	0.000
		15 -0.021	-0.078	79.503	0.000

**Gambar C. 9 Uji Diagnostik Parameter (Acak) ARIMA(2,2,3)**

Date: 06/04/17 Time: 16:51  
 Sample: 1 88  
 Included observations: 86

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.287	0.287	7.3512	0.007
		2 -0.076	-0.173	7.8698	0.020
		3 -0.081	-0.007	8.4715	0.037
		4 -0.060	-0.049	8.8023	0.066
		5 -0.031	-0.012	8.8915	0.113
		6 -0.089	-0.100	9.6423	0.141
		7 -0.006	0.049	9.6462	0.210
		8 -0.121	-0.181	11.057	0.198
		9 -0.109	-0.022	12.228	0.201
		10 -0.096	-0.113	13.152	0.215
		11 -0.098	-0.077	14.114	0.227
		12 0.236	0.278	19.786	0.071
		13 0.113	-0.111	21.100	0.071
		14 -0.054	-0.052	21.411	0.092
		15 -0.037	0.024	21.559	0.120

**Gambar C. 10 Uji Diagnostik Parameter (Homogen) ARIMA(2,2,3)**

Keberangkatan

Date: 07/04/17 Time: 07:55

Sample: 1 88

Included observations: 88

Q-statistic probabilities adjusted for 1 ARMA term

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	-0.576	-0.576	30.201	
		2	0.081	-0.375	30.807	0.000
		3	0.084	-0.117	31.471	0.000
		4	-0.102	-0.108	32.450	0.000
		5	0.062	-0.047	32.814	0.000
		6	-0.034	-0.054	32.924	0.000
		7	0.111	0.147	34.135	0.000
		8	-0.183	-0.049	37.440	0.000
		9	0.163	0.047	40.114	0.000
		10	-0.147	-0.114	42.299	0.000
		11	-0.142	-0.464	44.360	0.000
		12	0.549	0.345	75.713	0.000

Gambar C. 11 Uji Diagnostik Parameter (Acak) ARMA (0,1)

Date: 07/04/17 Time: 07:58

Sample: 1 88

Included observations: 88

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.353	0.353	11.330	0.001
		2	-0.142	-0.304	13.175	0.001
		3	-0.163	0.012	15.651	0.001
		4	-0.154	-0.159	17.879	0.001
		5	-0.100	-0.025	18.840	0.002
		6	-0.059	-0.086	19.173	0.004
		7	-0.067	-0.079	19.611	0.006
		8	-0.124	-0.152	21.130	0.007
		9	-0.145	-0.131	23.245	0.006
		10	-0.071	-0.081	23.754	0.008
		11	0.079	0.023	24.389	0.011
		12	0.356	0.289	37.577	0.000

Gambar C. 12 Uji Diagnostik Parameter (Homogen) ARMA (0,1)

Date: 07/04/17 Time: 08:03  
 Sample: 1 88  
 Included observations: 88  
 Q-statistic probabilities adjusted for 2 ARMA terms

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	-0.207	-0.207	3.9106	
		2	0.035	-0.008	4.0261	
		3	0.068	0.077	4.4516	0.035
		4	-0.074	-0.046	4.9622	0.084
		5	0.034	0.007	5.0723	0.167
		6	-0.007	-0.001	5.0767	0.280
		7	0.058	0.067	5.4065	0.368
		8	-0.171	-0.161	8.2959	0.217
		9	0.042	-0.025	8.4741	0.293
		10	-0.171	-0.181	11.437	0.178
		11	-0.015	-0.059	11.459	0.246
		12	0.499	0.524	37.399	0.000

**Gambar C. 13 Uji Diagnostik Parameter (Acak) ARMA (1,1)**

Date: 07/04/17 Time: 08:05  
 Sample: 1 88  
 Included observations: 88

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.233	0.233	4.9480	0.026
		2	-0.078	-0.140	5.5130	0.064
		3	-0.122	-0.074	6.9026	0.075
		4	-0.162	-0.134	9.3829	0.052
		5	-0.097	-0.050	10.272	0.068
		6	-0.126	-0.143	11.814	0.066
		7	-0.092	-0.081	12.638	0.081
		8	-0.139	-0.185	14.547	0.069
		9	-0.072	-0.084	15.070	0.089
		10	0.037	-0.043	15.209	0.125
		11	0.018	-0.097	15.241	0.172
		12	0.336	0.300	26.981	0.008

**Gambar C. 14 Uji Diagnostik Parameter (Homogen) ARMA (1,1)**

Date: 07/04/17 Time: 08:07

Sample: 1 88

Included observations: 88

Q-statistic probabilities adjusted for 1 ARMA term

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.084	-0.084	0.6363	
		2 -0.378	-0.388	13.791	0.000
		3 0.168	0.109	16.422	0.000
		4 -0.060	-0.216	16.764	0.001
		5 0.008	0.125	16.771	0.002
		6 0.135	0.016	18.521	0.002
		7 -0.041	0.075	18.682	0.005
		8 -0.095	-0.078	19.574	0.007
		9 0.031	0.029	19.669	0.012
		10 -0.340	-0.504	31.397	0.000
		11 0.142	0.281	33.485	0.000
		12 0.542	0.248	64.150	0.000

Gambar C. 15 Uji Diagnostik Parameter (Acak) ARMA (2,0)

Date: 07/04/17 Time: 08:08

























Sample: 1 88

Included observations: 88

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.093	-0.093	0.7932	0.373
		2 0.264	0.257	7.2024	0.027
		3 -0.118	-0.082	8.5028	0.037
		4 -0.130	-0.228	10.087	0.039
		5 -0.122	-0.104	11.499	0.042
		6 -0.166	-0.109	14.175	0.028
		7 -0.129	-0.147	15.803	0.027
		8 -0.095	-0.116	16.701	0.033
		9 -0.129	-0.179	18.375	0.031
		10 0.145	0.081	20.524	0.025
		11 0.018	0.017	20.556	0.038
		12 0.439	0.339	40.664	0.000

























Gambar C. 16 Uji Diagnostik Parameter (Homogen) ARMA (2,0)

Date: 07/04/17 Time: 08:14  
 Sample: 188  
 Included observations: 88  
 Q-statistic probabilities adjusted for 1 ARMA term

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.044	-0.044	0.1726	
		2 0.176	0.175	3.0372	0.081
		3 -0.324	-0.321	12.825	0.002
		4 0.046	0.012	13.028	0.005
		5 0.164	0.314	15.601	0.004
		6 -0.043	-0.212	15.778	0.008
		7 0.114	0.066	17.050	0.009
		8 -0.209	-0.001	21.358	0.003
		9 -0.224	-0.484	26.373	0.001
		10 -0.005	0.249	26.375	0.002
		11 0.048	0.214	26.615	0.003
		12 0.442	0.075	46.957	0.000

**Gambar C. 17 Uji Diagnostik Parameter (Acak) ARMA (3,0)**

Date: 07/04/17 Time: 08:14  
 Sample: 188  
 Included observations: 88

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.171	-0.171	2.6704	0.102
		2 -0.041	-0.073	2.8266	0.243
		3 0.091	0.074	3.6058	0.307
		4 -0.098	-0.074	4.5067	0.342
		5 -0.019	-0.043	4.5427	0.474
		6 -0.127	-0.160	6.1028	0.412
		7 -0.020	-0.065	6.1433	0.523
		8 -0.072	-0.112	6.6495	0.575
		9 -0.043	-0.073	6.8310	0.655
		10 0.062	0.007	7.2272	0.704
		11 -0.108	-0.122	8.4188	0.675
		12 0.279	0.227	16.515	0.169

**Gambar C. 18 Uji Diagnostik Parameter (Homogen) ARMA (3,0)**

Date: 07/04/17 Time: 08:21  
 Sample: 1 88  
 Included observations: 86  
 Q-statistic probabilities adjusted for 1 ARMA term

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.590	-0.590	31.015	
		2 -0.026	-0.575	31.078	0.000
		3 0.205	-0.366	34.896	0.000
		4 -0.101	-0.285	35.838	0.000
		5 0.028	-0.125	35.914	0.000
		6 -0.046	-0.148	36.111	0.000
		7 0.080	-0.019	36.721	0.000
		8 -0.113	-0.162	37.965	0.000
		9 0.209	0.221	42.240	0.000
		10 -0.216	0.187	46.906	0.000
		11 -0.141	-0.488	48.917	0.000
		12 0.569	0.040	81.990	0.000

**Gambar C. 19 Uji Diagnostik Parameter (Acak) ARIMA (0,2,2)**

























Date: 07/04/17 Time: 08:22  
 Sample: 1 88  
 Included observations: 86

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.351	0.351	10.979	0.001
		2 -0.094	-0.248	11.772	0.003
		3 -0.156	-0.033	13.978	0.003
		4 -0.156	-0.121	16.222	0.003
		5 -0.111	-0.051	17.373	0.004
		6 -0.092	-0.095	18.170	0.006
		7 -0.084	-0.078	18.853	0.009
		8 -0.155	-0.186	21.175	0.007
		9 -0.125	-0.082	22.720	0.007
		10 -0.020	-0.057	22.758	0.012
		11 0.062	-0.024	23.141	0.017
		12 0.360	0.331	36.381	0.000

**Gambar C. 20 Uji Diagnostik Parameter (Homogen) ARIMA (0,2,2)**



























Date: 07/04/17 Time: 08:32  
 Sample: 188  
 Included observations: 86  
 Q-statistic probabilities adjusted for 2 ARMA terms

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	-0.524	-0.524	24.464	
		2	0.067	-0.286	24.873	
		3	0.114	0.015	26.063	0.000
		4	-0.115	-0.018	27.277	0.000
		5	0.093	0.059	28.093	0.000
		6	-0.081	-0.035	28.713	0.000
		7	0.122	0.113	30.151	0.000
		8	-0.162	-0.084	32.681	0.000
		9	0.169	0.088	35.491	0.000
		10	-0.180	-0.133	38.721	0.000
		11	-0.135	-0.385	40.572	0.000
		12	0.527	0.375	68.958	0.000

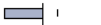













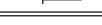



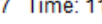

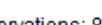

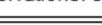

**Gambar C. 21 Uji Diagnostik Parameter (Acak) ARIMA (1,2,2)**

Date: 07/04/17 Time: 08:33  
 Sample: 188  
 Included observations: 86

























Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.353	0.353	11.081	0.001
		2	-0.142	-0.305	12.903	0.002
		3	-0.166	0.009	15.419	0.001
		4	-0.141	-0.140	17.251	0.002
		5	-0.112	-0.058	18.415	0.002
		6	-0.056	-0.053	18.711	0.005
		7	-0.066	-0.103	19.122	0.008
		8	-0.140	-0.156	21.013	0.007
		9	-0.146	-0.123	23.096	0.006
		10	-0.065	-0.086	23.515	0.009
		11	0.090	0.037	24.338	0.011
		12	0.351	0.269	36.936	0.000

**Gambar C. 22 Uji Diagnostik Parameter (Homogen) ARIMA (1,2,2)**

Date: 07/08/17 Time: 11:05  
 Sample: 1 88  
 Included observations: 86  
 Q-statistic probabilities adjusted for 2 ARMA terms

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 -0.555	-0.555	27.461	
		2 0.028	-0.406	27.532	
		3 0.014	-0.327	27.550	0.000
		4 -0.036	-0.362	27.672	0.000
		5 0.058	-0.333	27.987	0.000
		6 -0.028	-0.384	28.059	0.000
		7 0.102	-0.224	29.058	0.000
		8 -0.102	-0.173	30.065	0.000
		9 0.083	0.131	30.746	0.000
		10 -0.150	0.139	32.992	0.000
		11 -0.127	-0.520	34.619	0.000
		12 0.560	0.039	66.697	0.000

Date: 07/08/17 Time: 11:06  
 Sample: 1 88  
 Included observations: 86

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.291	0.291	7.5162	0.006
		2 -0.104	-0.206	8.4971	0.014
		3 -0.164	-0.077	10.941	0.012
		4 -0.151	-0.106	13.034	0.011
		5 -0.086	-0.049	13.719	0.017
		6 -0.067	-0.084	14.138	0.028
		7 -0.053	-0.062	14.405	0.044
		8 -0.143	-0.185	16.403	0.037
		9 -0.145	-0.121	18.461	0.030
		10 -0.032	-0.055	18.564	0.046
		11 0.058	-0.034	18.905	0.063
		12 0.365	0.317	32.566	0.001

## LAMPIRAN D HASIL PERAMALAN MODEL ARIMA

Tabel D. 1 Pemodelan ARIMA (0,1,1) Data Pelatihan

Periode	Penumpang Kedatangan	Nilai Peramalan	APE
Jan-07	302.539		
Feb-07	249.045	302.539,0	21,48%
Mar-07	294.833	270.123,4	8,38%
Apr-07	294.854	282.066,6	4,34%
Mei-07	314.862	288.014,7	8,53%
Jun-07	312.516	300.174,1	3,95%
Jul-07	364.672	305.814,9	16,14%
Agu-07	343.046	331.693,2	3,31%
Sep-07	309.192	336.883,1	8,96%
Okt-07	374.704	323.814,4	13,58%
Nov-07	369.777	346.367,2	6,33%
Des-07	376.991	356.975,2	5,31%
Jan-08	346.055	366.072,1	5,78%
Feb-08	308.714	356.699,1	15,54%
Mar-08	333.249	333.702,8	0,14%
Apr-08	301.165	333.493,4	10,73%
Mei-08	318.660	318.171,6	0,15%
Jun-08	304.289	318.396,8	4,64%
Jul-08	330.681	311.809,9	5,71%
Agu-08	327.916	320.376,7	2,30%
Sep-08	250.660	323.832,5	29,19%
Okt-08	352.207	287.747,8	18,30%
Nov-08	301.234	315.866,9	4,86%
Des-08	291.032	309.031,1	6,18%
Jan-09	334.165	300.594,5	10,05%
Feb-09	322.738	315.638,3	2,20%
Mar-09	339.224	318.893,5	5,99%

Periode	Penumpang Kedatangan	Nilai Peramalan	APE
Apr-09	332.520	328.115,2	1,32%
Mei-09	345.461	330.139,7	4,44%
Jun-09	392.981	337.120,5	14,21%
Jul-09	416.390	361.825,2	13,10%
Agu-09	402.553	386.043,6	4,10%
Sep-09	402.680	393.572,9	2,26%
Okt-09	492.869	397.747,8	19,30%
Nov-09	416.127	439.098,6	5,52%
Des-09	433.749	428.349,2	1,24%
Jan-10	368.933	430.831,5	16,78%
Feb-10	370.322	401.085,5	8,31%
Mar-10	450.212	386.590,2	14,13%
Apr-10	389.521	414.735,2	6,47%
Mei-10	441.320	402.908,3	8,70%
Jun-10	450.294	420.192,1	6,68%
Jul-10	488.498	433.818,4	11,19%
Agu-10	392.894	458.234,9	16,63%
Sep-10	394.889	426.844,9	8,09%
Okt-10	457.448	411.795,7	9,98%
Nov-10	459.691	432.257,9	5,97%
Des-10	473.164	444.702,1	6,02%
Jan-11	471.325	457.611,3	2,91%
Feb-11	437.005	463.886,6	6,15%
Mar-11	446.102	451.287,6	1,16%
Apr-11	423.303	448.888,3	6,04%
Mei-11	460.133	436.900,1	5,05%
Jun-11	516.560	447.467,1	13,38%
Jul-11	549.007	478.107,0	12,91%
Agu-11	460.825	509.594,9	10,58%

Periode	Penumpang Kedatangan	Nilai Peramalan	APE
Sep-11	502.203	486.489,0	3,13%
Okt-11	515.656	493.675,2	4,26%
Nov-11	535.958	503.695,2	6,02%
Des-11	556.917	518.328,1	6,93%
Jan-12	553.330	535.783,7	3,17%
Feb-12	514.305	543.806,9	5,74%
Mar-12	550.877	529.994,2	3,79%
Apr-12	526.268	539.526,4	2,52%
Mei-12	583.471	533.369,8	8,59%
Jun-12	611.292	555.921,4	9,06%
Jul-12	637.443	580.809,3	8,88%
Agu-12	671.624	606.278,4	9,73%
Sep-12	585.304	635.589,9	8,59%
Okt-12	648.606	611.879,6	5,66%
Nov-12	649.681	628.554,2	3,25%
Des-12	688.973	638.212,4	7,37%
Jan-13	655.399	661.144,1	0,88%
Feb-13	579.762	658.487,9	13,58%
Mar-13	649.873	620.927,7	4,45%
Apr-13	617.811	634.115,2	2,64%
Mei-13	673.209	626.542,0	6,93%
Jun-13	731.454	647.651,5	11,46%
Jul-13	629.873	685.041,6	8,76%
Agu-13	712.554	659.018,5	7,51%
Sep-13	613.451	683.193,3	11,37%
Okt-13	697.160	650.089,8	6,75%
Nov-13	642.028	671.393,0	4,57%
Des-13	703.276	657.684,8	6,48%
Jan-14	664.046	678.334,9	2,15%

Periode	Penumpang Kedatangan	Nilai Peramalan	APE
Feb-14	532.374	671.706,2	26,17%
Mar-14	603.741	603.405,6	0,06%
Apr-14	572.023	603.560,3	5,51%

**Tabel D. 2 Pemodelan Pertama ARIMA (0,1,1) Data Pelatihan Pertama**

Periode	Penumpang Kedatangan	Nilai Peramalan	APE
Mei-14	647.387		
Jun-14	705.679	647.387	8,26%
Jul-14	651.936	678.784	4,12%
Agu-14	697.084	667.673	4,22%
Sep-14	632.443	678.484	7,28%
Okt-14	684.668	662.438	3,25%
Nov-14	653.296	670.003	2,56%
Des-14	745.163	664.377	10,84%
Jan-15	587.187	691.454	17,76%
Feb-15	523.015	656.580	25,54%
Mar-15	557.819	611.948	9,70%
Apr-15	583.588	593.867	1,76%
Mei-15	674.270	590.435	12,43%
Jun-15	662.017	618.430	6,58%
Jul-15	763.157	632.985	17,06%
Agu-15	647.933	676.452	4,40%
Sep-15	618.349	666.929	7,86%
Okt-15	658.365	650.707	1,16%
Nov-15	658.108	653.264	0,74%
Des-15	797.545	654.882	17,89%
Jan-16	714.786	702.519	1,72%
Feb-16	653.932	706.615	8,06%
Mar-16	719.666	689.024	4,26%

Periode	Penumpang Kedatangan	Nilai Peramalan	APE
Apr-16	695.548	699.256	0,53%
Mei-16	801.991	698.018	12,96%

**Tabel D. 3 Pemodelan Pertama ARIMA (0,1,1) Data Pelatihan Kedua**

Periode	Penumpang Kedatangan	Nilai Peramalan	APE
Jun-16	715.523		0,00%
Jul-16	886.902	715.523	19,32%
Agu-16	707.513	801.787	13,32%
Sep-16	733.269	769.664	4,96%
Okt-16	692.759	760.144	9,73%
Nov-16	696.837	745.606	7,00%
Des-16	807.475	736.511	8,79%
Jan-17	729.101	748.338	2,64%
Feb-17	633.231	745.402	17,71%
Mar-17	705.927	729.419	3,33%

**Tabel D. 4 Pemodelan ARIMA (1,1,0) Data Pelatihan**

Periode	Penumpang Keberangkatan	Nilai Peramalan	APE
Jan-07	302.539		
Feb-07	249.045		
Mar-07	294.833	273.483	7,24%
Apr-07	294.854	271.841	7,80%
Mei-07	314.862	294.844	6,36%
Jun-07	312.516	305.073	2,38%
Jul-07	364.672	313.642	13,99%
Agu-07	343.046	338.576	1,30%
Sep-07	309.192	353.285	14,26%
Okt-07	374.704	325.040	13,25%

Periode	Penumpang Keberangkatan	Nilai Peramalan	APE
Nov-07	369.777	341.616	7,62%
Des-07	376.991	372.139	1,29%
Jan-08	346.055	373.503	7,93%
Feb-08	308.714	360.607	16,81%
Mar-08	333.249	326.146	2,13%
Apr-08	301.165	321.212	6,66%
Mei-08	318.660	316.195	0,77%
Jun-08	304.289	310.120	1,92%
Jul-08	330.681	311.120	5,92%
Agu-08	327.916	317.711	3,11%
Sep-08	250.660	329.243	31,35%
Okt-08	352.207	285.243	19,01%
Nov-08	301.234	299.046	0,73%
Des-08	291.032	324.762	11,59%
Jan-09	334.165	295.896	11,45%
Feb-09	322.738	312.671	3,12%
Mar-09	339.224	328.186	3,25%
Apr-09	332.520	331.191	0,40%
Mei-09	345.461	335.728	2,82%
Jun-09	392.981	339.174	13,69%
Jul-09	416.390	369.356	11,30%
Agu-09	402.553	404.960	0,60%
Sep-09	402.680	409.151	1,61%
Okt-09	492.869	402.619	18,31%
Nov-09	416.127	447.206	7,47%
Des-09	433.749	451.427	4,08%
Jan-10	368.933	425.180	15,25%
Feb-10	370.322	398.807	7,69%
Mar-10	450.212	369.653	17,89%



Periode	Penumpang Keberangkatan	Nilai Peramalan	APE
Apr-10	389.521	409.831	5,21%
Mei-10	441.320	417.622	5,37%
Jun-10	450.294	415.593	7,71%
Jul-10	488.498	445.954	8,71%
Agu-10	392.894	469.731	19,56%
Sep-10	394.889	436.293	10,49%
Okt-10	457.448	393.928	13,89%
Nov-10	459.691	426.204	7,28%
Des-10	473.164	458.611	3,08%
Jan-11	471.325	466.634	1,00%
Feb-11	437.005	472.209	8,06%
Mar-11	446.102	453.192	1,59%
Apr-11	423.303	441.702	4,35%
Mei-11	460.133	434.122	5,65%
Jun-11	516.560	442.032	14,43%
Jul-11	549.007	488.600	11,00%
Agu-11	460.825	533.151	15,69%
Sep-11	502.203	501.323	0,18%
Okt-11	515.656	481.853	6,56%
Nov-11	535.958	509.140	5,00%
Des-11	556.917	526.093	5,53%
Jan-12	553.330	546.734	1,19%
Feb-12	514.305	555.053	7,92%
Mar-12	550.877	532.723	3,30%
Apr-12	526.268	532.970	1,27%
Mei-12	583.471	537.966	7,80%
Jun-12	611.292	555.215	9,17%
Jul-12	637.443	597.746	6,23%
Agu-12	671.624	624.726	6,98%

Periode	Penumpang Keberangkatan	Nilai Peramalan	APE
Sep-12	585.304	654.958	11,90%
Okt-12	648.606	625.350	3,59%
Nov-12	649.681	617.342	4,98%
Des-12	688.973	649.164	5,78%
Jan-13	655.399	669.783	2,19%
Feb-13	579.762	671.341	15,80%
Mar-13	649.873	614.992	5,37%
Apr-13	617.811	615.145	0,43%
Mei-13	673.209	633.033	5,97%
Jun-13	731.454	645.965	11,69%
Jul-13	629.873	702.831	11,58%
Agu-13	712.554	676.848	5,01%
Sep-13	613.451	671.505	9,46%
Okt-13	697.160	659.277	5,43%
Nov-13	642.028	655.553	2,11%
Des-13	703.276	667.984	5,02%
Jan-14	664.046	673.115	1,37%
Feb-14	532.374	682.637	28,23%
Mar-14	603.741	592.094	1,93%
Apr-14	572.023	568.287	0,65%

**LAMPIRAN E NILAI RESIDUAL ARIMA (INPUT ANN)**

Bulan	Error
Jan-07	0
Feb-07	-53494
Mar-07	24710
Apr-07	12787
Mei-07	26847
Jun-07	12342
Jul-07	58857
Agu-07	11353
Sep-07	-27691
Okt-07	50890
Nov-07	23410
Des-07	20016
Jan-08	-20017
Feb-08	-47985
Mar-08	-454
Apr-08	-32328
Mei-08	488
Jun-08	-14108
Jul-08	18871
Agu-08	7539
Sep-08	-73173
Okt-08	64459
Nov-08	-14633
Des-08	-17999

Bulan	Error
Jan-09	33571
Feb-09	7100
Mar-09	20331
Apr-09	4405
Mei-09	15321
Jun-09	55861
Jul-09	54565
Agu-09	16509
Sep-09	9107
Okt-09	95121
Nov-09	-22972
Des-09	5400
Jan-10	-61899
Feb-10	-30764
Mar-10	63622
Apr-10	-25214
Mei-10	38412
Jun-10	30102
Jul-10	54680
Agu-10	-65341
Sep-10	-31956
Okt-10	45652
Nov-10	27433
Des-10	28462

Bulan	Error
Jan-11	13714
Feb-11	-26882
Mar-11	-5186
Apr-11	-25585
Mei-11	23233
Jun-11	69093
Jul-11	70900
Agu-11	-48770
Sep-11	15714
Okt-11	21981
Nov-11	32263
Des-11	38589
Jan-12	17546
Feb-12	-29502
Mar-12	20883
Apr-12	-13258
Mei-12	50101
Jun-12	55371
Jul-12	56634
Agu-12	65346
Sep-12	-50286
Okt-12	36726
Nov-12	21127
Des-12	50761
Jan-13	-5745

Bulan	Error
Feb-13	-78726
Mar-13	28945
Apr-13	-16304
Mei-13	46667
Jun-13	83803
Jul-13	-55169
Agu-13	53536
Sep-13	-69742
Okt-13	47070
Nov-13	-29365
Des-13	45591
Jan-14	-14289
Feb-14	-139332
Mar-14	335
Apr-14	-31537
Mei-14	
Jun-14	647387
Jul-14	678784
Agu-14	667673
Sep-14	678484
Okt-14	662438
Nov-14	670003
Des-14	664377
Jan-15	691454
Feb-15	656580

Bulan	Error
Mar-15	611948
Apr-15	593867
Mei-15	590435
Jun-15	618430
Jul-15	632985
Agu-15	676452
Sep-15	666929
Okt-15	650707
Nov-15	653264
Des-15	654882
Jan-16	702519
Feb-16	706615
Mar-16	689024

Bulan	Error
Apr-16	699256
Mei-16	698018
Jun-16	
Jul-16	171.379
Agu-16	-94.274
Sep-16	-36.395
Okt-16	-67.385
Nov-16	-48.769
Des-16	70.964
Jan-17	-19.237
Feb-17	-112.171
Mar-17	-23.492

*(Halaman ini sengaja dikosongkan)*

## LAMPIRAN F PERAMALAN PENUMPANG

**Tabel F. 1 Peramalan Penumpang Kedatangan Menggunakan ARIMA (1,1,0)**

Bulan	Aktual	Forecast	Error	Absolute Error	Absolute Percentage Error
Jan-07	302539		0,00	0,00	0,00
Feb-07	249045	302539	-53494	53494	21,48%
Mar-07	294833	270123,4	24709,6	24709,6	8,38%
Apr-07	294854	282066,6	12787,4	12787,4	4,34%
Mei-07	314862	288014,7	26847,3	26847,3	8,53%
Jun-07	312516	300174,1	12341,9	12341,9	3,95%
Jul-07	364672	305814,9	58857,1	58857,1	16,14%
Agu-07	343046	331693,2	11352,8	11352,8	3,31%
Sep-07	309192	336883,1	-27691,1	27691,1	8,96%
Okt-07	374704	323814,4	50889,6	50889,6	13,58%
Nov-07	369777	346367,2	23409,8	23409,8	6,33%
Des-07	376991	356975,2	20015,8	20015,8	5,31%
Jan-08	346055	366072,1	-20017,1	20017,1	5,78%
Feb-08	308714	356699,1	-47985,1	47985,1	15,54%
Mar-08	333249	333702,8	-453,8	453,8	0,14%
Apr-08	301165	333493,4	-32328,4	32328,4	10,73%
Mei-08	318660	318171,6	488,4	488,4	0,15%
Jun-08	304289	318396,8	-14107,8	14107,8	4,64%
Jul-08	330681	311809,9	18871,1	18871,1	5,71%
Agu-08	327916	320376,7	7539,3	7539,3	2,30%
Sep-08	250660	323832,5	-73172,5	73172,5	29,19%
Okt-08	352207	287747,8	64459,2	64459,2	18,30%
Nov-08	301234	315866,9	-14632,9	14632,9	4,86%
Des-08	291032	309031,1	-17999,1	17999,1	6,18%
Jan-09	334165	300594,5	33570,5	33570,5	10,05%
Feb-09	322738	315638,3	7099,7	7099,7	2,20%
Mar-09	339224	318893,5	20330,5	20330,5	5,99%
Apr-09	332520	328115,2	4404,8	4404,8	1,32%
Mei-09	345461	330139,7	15321,3	15321,3	4,44%

Bulan	Aktual	Forecast	Error	Absolute Error	Absolute Percentage Error
Jun-09	392981	337120,5	55860,5	55860,5	14,21%
Jul-09	416390	361825,2	54564,8	54564,8	13,10%
Agu-09	402553	386043,6	16509,4	16509,4	4,10%
Sep-09	402680	393572,9	9107,1	9107,1	2,26%
Okt-09	492869	397747,8	95121,2	95121,2	19,30%
Nov-09	416127	439098,6	-22971,6	22971,6	5,52%
Des-09	433749	428349,2	5399,8	5399,8	1,24%
Jan-10	368933	430831,5	-61898,5	61898,5	16,78%
Feb-10	370322	401085,5	-30763,5	30763,5	8,31%
Mar-10	450212	386590,2	63621,8	63621,8	14,13%
Apr-10	389521	414735,2	-25214,2	25214,2	6,47%
Mei-10	441320	402908,3	38411,7	38411,7	8,70%
Jun-10	450294	420192,1	30101,9	30101,9	6,68%
Jul-10	488498	433818,4	54679,6	54679,6	11,19%
Agu-10	392894	458234,9	-65340,9	65340,9	16,63%
Sep-10	394889	426844,9	-31955,9	31955,9	8,09%
Okt-10	457448	411795,7	45652,3	45652,3	9,98%
Nov-10	459691	432257,9	27433,1	27433,1	5,97%
Des-10	473164	444702,1	28461,9	28461,9	6,02%
Jan-11	471325	457611,3	13713,7	13713,7	2,91%
Feb-11	437005	463886,6	-26881,6	26881,6	6,15%
Mar-11	446102	451287,6	-5185,6	5185,6	1,16%
Apr-11	423303	448888,3	-25585,3	25585,3	6,04%
Mei-11	460133	436900,1	23232,9	23232,9	5,05%
Jun-11	516560	447467,1	69092,9	69092,9	13,38%
Jul-11	549007	478107	70900	70900	12,91%
Agu-11	460825	509594,9	-48769,9	48769,9	10,58%
Sep-11	502203	486489	15714	15714	3,13%
Okt-11	515656	493675,2	21980,8	21980,8	4,26%
Nov-11	535958	503695,2	32262,8	32262,8	6,02%
Des-11	556917	518328,1	38588,9	38588,9	6,93%
Jan-12	553330	535783,7	17546,3	17546,3	3,17%



Bulan	Aktual	Forecast	Error	Absolute Error	Absolute Percentage Error
Feb-12	514305	543806,9	-29501,9	29501,9	5,74%
Mar-12	550877	529994,2	20882,8	20882,8	3,79%
Apr-12	526268	539526,4	-13258,4	13258,4	2,52%
Mei-12	583471	533369,8	50101,2	50101,2	8,59%
Jun-12	611292	555921,4	55370,6	55370,6	9,06%
Jul-12	637443	580809,3	56633,7	56633,7	8,88%
Agu-12	671624	606278,4	65345,6	65345,6	9,73%
Sep-12	585304	635589,9	-50285,9	50285,9	8,59%
Okt-12	648606	611879,6	36726,4	36726,4	5,66%
Nov-12	649681	628554,2	21126,8	21126,8	3,25%
Des-12	688973	638212,4	50760,6	50760,6	7,37%
Jan-13	655399	661144,1	-5745,1	5745,1	0,88%
Feb-13	579762	658487,9	-78725,9	78725,9	13,58%
Mar-13	649873	620927,7	28945,3	28945,3	4,45%
Apr-13	617811	634115,2	-16304,2	16304,2	2,64%
Mei-13	673209	626542	46667	46667	6,93%
Jun-13	731454	647651,5	83802,5	83802,5	11,46%
Jul-13	629873	685041,6	-55168,6	55168,6	8,76%
Agu-13	712554	659018,5	53535,5	53535,5	7,51%
Sep-13	613451	683193,3	-69742,3	69742,3	11,37%
Okt-13	697160	650089,8	47070,2	47070,2	6,75%
Nov-13	642028	671393	-29365	29365	4,57%
Des-13	703276	657684,8	45591,2	45591,2	6,48%
Jan-14	664046	678334,9	-14288,9	14288,9	2,15%
Feb-14	532374	671706,2	-139332,2	139332,2	26,17%
Mar-14	603741	603405,6	335,4	335,4	0,06%
Apr-14	572023	603560,3	-31537,3	31537,3	5,51%
Mei-14	647387	603560,3	43826,7	43826,7	6,77%
Jun-14	705679	647387	58292	58292	8,26%
Jul-14	651936	678784	-26848	26848	4,12%
Agu-14	697084	667673	29410,7	29410,7	4,22%
Sep-14	632443	678484	-46041,1	46041,1	7,28%

Bulan	Aktual	Forecast	Error	Absolute Error	Absolute Percentage Error
Okt-14	684668	662438	22230,3	22230,3	3,25%
Nov-14	653296	670003	-16707,4	16707,4	2,56%
Des-14	745163	664377	80785,8	80785,8	10,84%
Jan-15	587187	691454	-104267,2	104267,2	17,76%
Feb-15	523015	656580	-133564,8	133564,8	25,54%
Mar-15	557819	611948	-54128,7	54128,7	9,70%
Apr-15	583588	593867	-10279,4	10279,4	1,76%
Mei-15	674270	590435	83835,5	83835,5	12,43%
Jun-15	662017	618430	43586,9	43586,9	6,58%
Jul-15	763157	632985	130172,2	130172,2	17,06%
Agu-15	647933	676452	-28518,7	28518,7	4,40%
Sep-15	618349	666929	-48579,9	48579,9	7,86%
Okt-15	658365	650707	7657,7	7657,7	1,16%
Nov-15	658108	653264	4843,7	4843,7	0,74%
Des-15	797545	654882	142663,3	142663,3	17,89%
Jan-16	714786	702519	12267	12267	1,72%
Feb-16	653932	706615	-52683,1	52683,1	8,06%
Mar-16	719666	689024	30642,5	30642,5	4,26%
Apr-16	695548	699256	-3707,5	3707,5	0,53%
Mei-16	801991	698018	103973,5	103973,5	12,96%
Jun-16	715523	698018	17505,5	17505,5	2,45%
Jul-16	886902	715523	171379	171379	19,32%
Agu-16	707513	801787,2	-94274,2	94274,2	13,32%
Sep-16	733269	769664	-36395	36395	4,96%
Okt-16	692759	760143,8	-67384,8	67384,8	9,73%
Nov-16	696837	745606,3	-48769,3	48769,3	7,00%
Des-16	807475	736511,3	70963,7	70963,7	8,79%
Jan-17	729101	748338,3	-19237,3	19237,3	2,64%
Feb-17	633231	745401,5	-112170,5	112170,5	17,71%
Mar-17	705927	729418,5	-23491,5	23491,5	3,33%

**Tabel F. 2 Peramalan Penumpang Kedatangan Menggunakan *hybrid* ARIMA-ANN**

Bulan	Aktual	Forecast	Error	Absolute Error	Absolute Percentage Error
Jan-07	302.539	302.539	0	0	0
Feb-07	249.045	249.045	0	0	0
Mar-07	294.833	294.833	0	0	0
Apr-07	294.854	294.854	0	0	0
Mei-07	314.862	314.862	0	0	0
Jun-07	312.516	305.073	7443,3	7443,3	2,38%
Jul-07	364.672	313.642	51029,6	51029,6	13,99%
Agu-07	343.046	338.576	4470,0	4470	1,30%
Sep-07	309.192	353.285	-44092,7	44092,7	14,26%
Okt-07	374.704	325.040	49664,5	49664,5	13,25%
Nov-07	369.777	341.616	28161,0	28161	7,62%
Des-07	376.991	372.139	4851,9	4851,9	1,29%
Jan-08	346.055	373.503	-27448,2	27448,2	7,93%
Feb-08	308.714	360.607	-51893,0	51893	16,81%
Mar-08	333.249	326.146	7103,0	7103	2,13%
Apr-08	301.165	321.212	-20046,7	20046,7	6,66%
Mei-08	318.660	316.195	2465,4	2465,4	0,77%
Jun-08	304.289	310.120	-5831,3	5831,3	1,92%
Jul-08	330.681	311.120	19561,3	19561,3	5,92%
Agu-08	327.916	317.711	10205,5	10205,5	3,11%
Sep-08	250.660	329.243	-78583,3	78583,3	31,35%
Okt-08	352.207	285.243	66963,9	66963,9	19,01%
Nov-08	301.234	299.046	2188,2	2188,2	0,73%
Des-08	291.032	324.762	-33730,4	33730,4	11,59%
Jan-09	334.165	295.896	38269,0	38269	11,45%
Feb-09	322.738	312.671	10067,4	10067,4	3,12%
Mar-09	339.224	328.186	11038,4	11038,4	3,25%
Apr-09	332.520	331.191	1329,5	1329,5	0,40%
Mei-09	345.461	335.728	9732,6	9732,6	2,82%
Jun-09	392.981	339.174	53807,2	53807,2	13,69%
Jul-09	416.390	369.356	47034,3	47034,3	11,30%
Agu-09	402.553	404.960	-2406,5	2406,5	0,60%
Sep-09	402.680	409.151	-6471,2	6471,2	1,61%
Okt-09	492.869	402.619	90250,1	90250,1	18,31%

Bulan	Aktual	Forecast	Error	Absolute Error	Absolute Percentage Error
Nov-09	416.127	447.206	-31078,7	31078,7	7,47%
Des-09	433.749	451.427	-17677,7	17677,7	4,08%
Jan-10	368.933	425.180	-56247,3	56247,3	15,25%
Feb-10	370.322	398.807	-28484,6	28484,6	7,69%
Mar-10	450.212	369.653	80559,4	80559,35455	17,89%
Apr-10	389.521	409.831	-20309,7	20309,7	5,21%
Mei-10	441.320	417.622	23697,6	23697,6	5,37%
Jun-10	450.294	415.593	34700,6	34700,6	7,71%
Jul-10	488.498	445.954	42543,7	42543,7	8,71%
Agu-10	392.894	469.731	-76836,7	76836,7	19,56%
Sep-10	394.889	436.293	-41404,3	41404,3	10,49%
Okt-10	457.448	393.928	63520,0	63520	13,89%
Nov-10	459.691	426.204	33487,1	33487,1	7,28%
Des-10	473.164	458.611	14553,4	14553,4	3,08%
Jan-11	471.325	466.634	4691,0	4691	1,00%
Feb-11	437.005	472.209	-35203,8	35203,8	8,06%
Mar-11	446.102	453.192	-7089,6	7089,6	1,59%
Apr-11	423.303	441.702	-18399,3	18399,3	4,35%
Mei-11	460.133	434.122	26011,3	26011,3	5,65%
Jun-11	516.560	442.032	74528,5	74528,5	14,43%
Jul-11	549.007	488.600	60407,4	60407,4	11,00%
Agu-11	460.825	533.151	-72325,9	72325,9	15,69%
Sep-11	502.203	501.323	880,2	880,2	0,18%
Okt-11	515.656	481.853	33803,0	33803	6,56%
Nov-11	535.958	509.140	26818,2	26818,2	5,00%
Des-11	556.917	526.093	30823,6	30823,6	5,53%
Jan-12	553.330	546.734	6596,1	6596,1	1,19%
Feb-12	514.305	555.053	-40747,7	40747,7	7,92%
Mar-12	550.877	532.723	18154,3	18154,3	3,30%
Apr-12	526.268	532.970	-6701,6	6701,6	1,27%
Mei-12	583.471	537.966	45504,7	45504,7	7,80%
Jun-12	611.292	555.215	56076,7	56076,7	9,17%
Jul-12	637.443	597.746	39696,6	39696,6	6,23%
Agu-12	671.624	624.726	46898,2	46898,2	6,98%
Sep-12	585.304	654.958	-69653,6	69653,6	11,90%
Okt-12	648.606	625.350	23256,4	23256,4	3,59%

Bulan	Aktual	Forecast	Error	Absolute Error	Absolute Percentage Error
Nov-12	649.681	617.342	32339,5	32339,5	4,98%
Des-12	688.973	649.164	39809,4	39809,4	5,78%
Jan-13	655.399	669.783	-14383,7	14383,7	2,19%
Feb-13	579.762	671.341	-91579,2	91579,2	15,80%
Mar-13	649.873	614.992	34880,8	34880,8	5,37%
Apr-13	617.811	615.145	2665,8	2665,8	0,43%
Mei-13	673.209	633.033	40176,3	40176,3	5,97%
Jun-13	731.454	645.965	85489,3	85489,3	11,69%
Jul-13	629.873	702.831	-72957,6	72957,6	11,58%
Agu-13	712.554	676.848	35706,5	35706,5	5,01%
Sep-13	613.451	671.505	-58054,2	58054,2	9,46%
Okt-13	697.160	659.277	37883,4	37883,4	5,43%
Nov-13	642.028	655.553	-13525,0	13525	2,11%
Des-13	703.276	667.984	35292,2	35292,2	5,02%
Jan-14	664.046	673.115	-9068,5	9068,5	1,37%
Feb-14	532.374	682.637	-150263,4	150263,4	28,23%
Mar-14	603.741	592.094	11647,1	11647,1	1,93%
Apr-14	572.023	568.287	3735,7	3735,7	0,65%
Mei-14	647387			0	0,00%
Jun-14	705679			0	0,00%
Jul-14	651936			0	0,00%
Agu-14	697084			0	0,00%
Sep-14	632443			0	0,00%
Okt-14	684668	672326,1	12341,9	12341,9	1,80%
Nov-14	653296	594438,9	58857,1	58857,1	9,01%
Des-14	745163	733810,2	11352,8	11352,8	1,52%
Jan-15	587187	614878,1	-27691,1	27691,1	4,72%
Feb-15	523015	472125,4	50889,6	50889,6	9,73%
Mar-15	557819	534409,2	23409,8	23409,8	4,20%
Apr-15	583588	563572,2	20015,8	20015,8	3,43%
Mei-15	674270	694287,1	-20017,1	20017,1	2,97%
Jun-15	662017	710002,1	-47985,1	47985,1	7,25%
Jul-15	763157	763610,8	-453,8	453,8	0,06%
Agu-15	647933	680261,4	-32328,4	32328,4	4,99%
Sep-15	618349	617860,6	488,4	488,4	0,08%
Okt-15	658365	672472,8	-14107,8	14107,8	2,14%

Bulan	Aktual	Forecast	Error	Absolute Error	Absolute Percentage Error
Nov-15	658108	639236,9	18871,1	18871,1	2,87%
Des-15	797545	790005,7	7539,3	7539,3	0,95%
Jan-16	714786	787958,5	-73172,5	73172,5	10,24%
Feb-16	653932	589472,8	64459,2	64459,2	9,86%
Mar-16	719666	734298,9	-14632,9	14632,9	2,03%
Apr-16	695548	713547,1	-17999,1	17999,1	2,59%
Mei-16	801991	768420,5	33570,5	33570,5	4,19%
Jun-16	715523			0	0,00%
Jul-16	886902	863099,5	23802,5	23802,5	2,68%
Agu-16	707513	732681,6	-25168,6	25168,6	3,56%
Sep-16	733269	709733,5	23535,5	23535,5	3,21%
Okt-16	692759	722501,3	-29742,3	29742,3	4,29%
Nov-16	696837	689766,8	7070,2	7070,2	1,01%
Des-16	807475	816840,0	-9365,0	9365	1,16%
Jan-17	729101	723509,8	5591,2	5591,2	0,77%
Feb-17	633231	635519,9	-2288,9	2288,9	0,36%
Mar-17	705927	735259,2	-29332,2	29332,2	4,16%