



SKRIPSI - ME141501

IMPLEMENTASI METODE *AUTOREGRESSIVE INTEGRATED MOVING AVERAGE* (ARIMA) DALAM PERAMALAN JANGKA PENDEK (*SHORT TERM FORECASTING*) TERHADAP JUMLAH PENUMPANG KAPAL DENGAN *EVIIEWS*

SOFIATUR ROHMAH
NRP 0421134000020

Dosen Pembimbing
Ir. Dwi Priyanta, M.SE
Nurhadi Siswantoro, S.T, M.T.

DEPARTEMEN TEKNIK SISTEM PERKAPALAN
Fakultas Teknologi Kelautan
Institut Teknologi Sepuluh Nopember
Surabaya 2018



SKRIPSI - ME 141501

IMPLEMENTASI METODE *AUTOREGRESSIVE INTEGRATED MOVING AVERAGE* (ARIMA) DALAM PERAMALAN JANGKA PENDEK (*SHORT TERM FORECASTING*) TERHADAP JUMLAH PENUMPANG KAPAL DENGAN *EVIIEWS*

SOFIATUR ROHMAH
NRP 0421134000020

Dosen Pembimbing
Ir. Dwi Priyanta, M.SE
Nurhadi Siswantoro, S.T, M.T.

DEPARTEMEN TEKNIK SISTEM PERKAPALAN
Fakultas Teknologi Kelautan
Institut Teknologi Sepuluh Nopember
Surabaya 2018

Halaman ini sengaja dikosongkan



FINAL PROJECT - ME 141501

**THE IMPLEMENTATION OF AUTOREGRESSIVE INTEGRATED
MOVING AVERAGE (ARIMA) ON SHORT TERM FORECASTING
OF THE NUMBER OF SHIP PASSENGERS WITH EIEWS**

SOFIATUR ROHMAH
NRP 0421134000020

Supervisors
Ir. Dwi Priyanta, M.SE
Nurhadi Siswantoro, S.T, M.T.

DEPARTMENT OF MARINE ENGINEERING
Faculty of Marine Technology
Institut Teknologi Sepuluh Nopember
Surabaya 2018

This page is intentionally blank

LEMBAR PENGESAHAN

IMPLEMENTASI METODE *AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (ARIMA)* DALAM PERAMALAN JANGKA PENDEK (*SHORT TERM FORECASTING*) TERHADAP JUMLAH PENUMPANG KAPAL DENGAN *EVIIEWS*

TUGAS AKHIR

Diajukan Untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Teknik
pada
Program Studi S-1 Departemen Teknik Sistem Perkapalan
Fakultas Teknologi Kelautan
Institut Teknologi Sepuluh Nopember

Oleh:

SOFIATUR ROHMAH

NRP 0421134000020

Disetujui oleh Pembimbing Tugas Akhir:

Ir. Dwi Priyanta, M.SE
NIP. 196807031994021001

Nurhadi Siswanto, S.T, M.T.
NIP. 1992201711049



Halaman ini sengaja dikosongkan

LEMBAR PENGESAHAN

IMPLEMENTASI METODE *AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (ARIMA)* DALAM PERAMALAN JANGKA PENDEK (*SHORT TERM FORECASTING*) TERHADAP JUMLAH PENUMPANG KAPAL DENGAN *EVIIEWS*

TUGAS AKHIR

Diajukan Untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Teknik
pada
Program Studi S-1 Departemen Teknik Sistem Perkapalan
Fakultas Teknologi Kelautan
Institut Teknologi Sepuluh Nopember

Oleh:

SOFIATUR ROHMAH

NRP 0421134000020

Disetujui oleh Kepala Departemen Teknik Sistem Perkapalan:



Dr. Eng. M. Badrus Zaman, S.T., M.T.

NIP. 197708022008011007

LEMBAR PENGESAHAN

IMPLEMENTASI METODE *AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (ARIMA)* DALAM PERAMALAN JANGKA PENDEK (*SHORT TERM FORECASTING*) TERHADAP JUMLAH PENUMPANG KAPAL DENGAN *EIEWS*

TUGAS AKHIR

Diajukan Untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Teknik
pada
Program Studi S-1 Departemen Teknik Sistem Perkapalan
Fakultas Teknologi Kelautan
Institut Teknologi Sepuluh Nopember

Oleh:

SOFIATUR ROHMAH

NRP 0421134000020

Disetujui oleh Kepala Departemen Teknik Sistem Perkapalan:

Dr. Eng. M. Badrus Zaman, S.T., M.T.

NIP. 197708022008011007

Halaman ini sengaja dikosongkan

IMPLEMENTASI METODE AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (ARIMA) DALAM PERAMALAN JANGKA PENDEK (SHORT TERM FORECASTING) TERHADAP JUMLAH PENUMPANG KAPAL DENGAN EIEWS

Nama : Sofiaturohmah
NRP : 4213100020
Departemen : Teknik Sistem Perkapalan
Dosen Pembimbing : 1. Ir. Dwi Priyanta, M.SE
2. Nurhadi Siswantoro, S.T, M.T.

Abstrak

Adanya penurunan terhadap jumlah penumpang kapal laut pada jalur-jalur tertentu di Indonesia ditengarai sebagai konsekuensi adanya peningkatan daya beli masyarakat sebagai pencerminan peningkatan ekonomi. Selama satu decade, terjadi penurunan di beberapa jalur pelabuhan besar di Indonesia. Dikutip dari harian Kompas, penurunan terjadi pada Pelabuhan Tanjung Perak sebesar 13,23% dan pada Pelabuhan Tanjung Priok sebesar 12,88%. Hal ini menjadi sangat riskan bagi perusahaan pelayaran angkutan penumpang dalam negeri, baik yang berbadan hukum BUMN maupun swasta PT. PELNI mengalami penurunan drastis sebesar 50% sehingga berimbasnya terdapat pendapatan perusahaan. Maka dari itulah, dibutuhkan perkiraan jumlah penumpang di masa yang akan datang untuk dapat melihat pangsa pasar di sektor ini, mengingat tren yang turun setiap tahunnya. Perkiraan jumlah penumpang dari tahun ke tahun dapat dilakukan dengan menggunakan metode ARIMA Box-Jenkins. ARIMA merupakan kepanjangan dari *Auto Regressive Integrated Moving Average*, yaitu metode peramalan berdasarkan data *time series* atau kurun waktu. Dengan metode ini akan diberikan pemodelan terbaik yang nantinya dapat menginterpretasikan keadaan di masa yang akan datang, khususnya untuk jumlah penumpang angkutan laut di Pelabuhan Tanjung Priok, Jakarta Utara. Model terbaik yang didapatkan yaitu MA(1) dan MA(12) menghasilkan rata-rata error 14% dengan error paling besar terjadi pada bulan Januari dan bulan Agustus yaitu sebesar 25%.

Kata Kunci : ARIMA, error, jumlah penumpang

Halaman ini sengaja dikosongkan

THE IMPLEMENTATION OF AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (ARIMA) ON SHORT TERM FORECASTING OF THE NUMBER OF SHIP PASSENGERS WITH EVIEWS

Name : Sofiatur Rohmah
NRP : 4213100020
Departement : Teknik Sistem Perkapalan
Supervisors : 1. Ir. Dwi Priyanta, M.SE
2. Nurhadi Siswanto, S.T, M.T.

Abstract

A decrease in the number of seafarers on certain routes in Indonesia is suspected as a consequence of increasing public purchasing power as a reflection of economic improvement. For a decade, there has been a decline in some of Indonesia's major ports. Quoted from Kompas daily, the decrease occurred at Tanjung Perak Port at 13.23% and at Tanjung Priok Port at 12.88%. This becomes very risky for domestic passenger shipping companies, both state-owned and private companies PT. PELNI has decreased drastically by 50% so that the impact of the company's revenue. Therefore, it takes an estimate of the number of passengers in the future to be able to see market share in this sector, given the downward trend each year. Estimated number of passengers from year to year can be done using ARIMA Box-Jenkins method. ARIMA is an extension of Auto Regressive Integrated Moving Average, that is forecasting method based on time series data or time frame. With this method will be given the best modeling that will be able to interpret the situation in the future, especially for the number of sea transport passengers at the Port of Tanjung Priok, North Jakarta. The best models obtained were MA (1) and MA (12) resulting in an average error of 14% with the greatest error occurring in January and August at 25%.

Keywords: ARIMA, error, number of passenger ship

Halaman ini sengaja dikosongkan

KATA PENGANTAR

Puji syukur kepada Allah Maha kuasa atas segala pertolongan dan kasih-Nya penulis dapat menyelesaikan tugas akhir dengan judul “Implementasi Metode *Autoregressive Integrated Moving Average* (ARIMA) Dalam Peramalan Jangka Pendek (*Short Term Forecasting*) Terhadap Jumlah Penumpang Kapal Dengan *Eviews*”. Dalam menyelesaikan tugas akhir ini, penulis dibantu oleh banyak pihak diantaranya :

1. Orang tua penulis, ayah yang telah lebih dahulu pergi ke surga, dan ibu yang sering menangis karena hal kecil, mbah yang terbaring namun selalu mengucap doa, lek ica, lek ridwan, lek nurul, om mukhlis, bude As, mas Yofi serta keluarga besar yang senantiasa memberikan dukungan dan kekuatan dalam setiap doa yang dipanjatkan.
2. Bapak Ir. Dwi Priyanta, M.SE selaku dosen pembimbing 1 serta sebagai Bapak kedua setelah ayah saya, terima kasih telah memberi pengarahan selama di office serta bimbingan selama menyelesaikan tugas akhir dengan sabar.
3. Bapak Nurhadi Siswantoro, S.T, M.T. sebagai Bapak ketiga dan dosen pembimbing kedua, terima kasih untuk semua arahan, nasehat, candaan dan keisengan yang telah diberikan.
4. Bapak Badruz Zaman selaku ketua Departemen Teknik Sistem Perkapalan-FTK-ITS
5. Bapak Prof Semin Sanuri, S.T, M.T, Ph.D selaku sekretaris Departemen Teknik Sistem Perkapalan-FTK-ITS.
6. Bapak Ir. Alam Baheramsyah, M.Sc selaku dosen wali yang telah memberikan arahan dan nasehat selama ini.
7. Terima kasih untuk Pak Fuad, Mas Wildan, Mas Basong, Mbak Chory, Mas Gigih, Mas Rokim, Mas Bayu, Apri, Didit, Chika, Sholeh, Andri, Ipyul, Linggar, Agung, Babrek, Nungsky, Fyan, Jamsky, Endang (Nina), Triska, Mbak Tiwi, dan Mbak Arin atas canda tawa, keisengan, kerja sama, kesulitan, dan perasaan memiliki keluarga, terima kasih.
8. Terima kasih kepada ABANG untuk dukungannya dan makanan yang diantar malam-malam meskipun bukan *go food*.
9. Terima kasih kepada Keluarga CUPYU (Rosyi dan Dyah) atas semangatnya.
10. Terima kasih pada Septi atas guyonan anehnya.
11. Terima kasih kepada Fia Cusnul untuk mengirimkan foto selfienya tiap hari yang benar-benar menghibur.
12. Teman-teman seperjuangan, Barakuda'13 Huhaa

Halaman ini sengaja dikosongkan

DAFTAR ISI

| | |
|---|--------------|
| JUDUL | i |
| KATA PENGANTAR..... | xii |
| DAFTAR ISI | xv |
| DAFTAR GAMBAR..... | xvii |
| DAFTAR TABEL..... | xviii |
| DAFTAR PERSAMAAN..... | xix |
| BAB I PENDAHULUAN..... | 1 |
| 1.1. Latar Belakang | 1 |
| 1.2. Perumusan Masalah | 3 |
| 1.3. Batasan Masalah | 4 |
| 1.4. Tujuan Skripsi..... | 4 |
| 1.5. Manfaat | 4 |
| BAB II KAJIAN PUSTAKA | 5 |
| 2.1. Konsep Peramalan..... | 5 |
| 2.2. Metode Deret Berkala (<i>Time Series</i>) Box-Jenkins ARIMA..... | 6 |
| 2.2.1. Historis ARIMA Box-Jenkins..... | 6 |
| 2.2.2. Konsep Dasar | 7 |
| 2.2.3. Model – Model Stasioner | 13 |
| 2.2.4. Model-Model Tak Stasioner | 15 |
| 2.2.5. <i>Diagnostic Checking</i> | 18 |
| 2.2.6. <i>Forecast dalam Eviews</i> | 19 |
| BAB III METODOLOGI..... | 21 |
| 3.1. <i>Flowchart</i> Pengerjaan Skripsi..... | 21 |
| 3.2. Deskripsi <i>Flowchart</i> | 22 |
| 3.2.1. Identifikasi dan Perumusan Masalah..... | 22 |
| 3.2.2. Studi Literatur | 23 |
| 3.2.3. Pengumpulan Data | 23 |
| 3.2.4. Tahap Identifikasi..... | 23 |
| 3.2.5. Tahap Penaksiran dan Pengujian..... | 26 |
| 3.2.6. Tahap Penerapan..... | 27 |
| BAB IV ANALISA DAN PEMBAHASAN | 29 |
| 4.1. Persiapan Data..... | 29 |
| 4.2. Tahap Identifikasi..... | 30 |
| 4.2.1. Plot Data | 30 |

| | |
|--|-----------|
| 4.2.2. Transformasi Data..... | 31 |
| 4.2.3. Plot ACF dan PACF | 33 |
| 4.3. Tahap Penaksiran dan Pengujian | 36 |
| 4.4. Tahap Penerapan | 36 |
| 4.5. Kecocokan dengan Data Asli dan Perhitungan Error..... | 37 |
| BAB V KESIMPULAN DAN SARAN..... | 41 |
| 5.1. Kesimpulan..... | 41 |
| 5.2. Saran..... | 41 |
| DAFTAR PUSTAKA..... | 43 |

DAFTAR GAMBAR

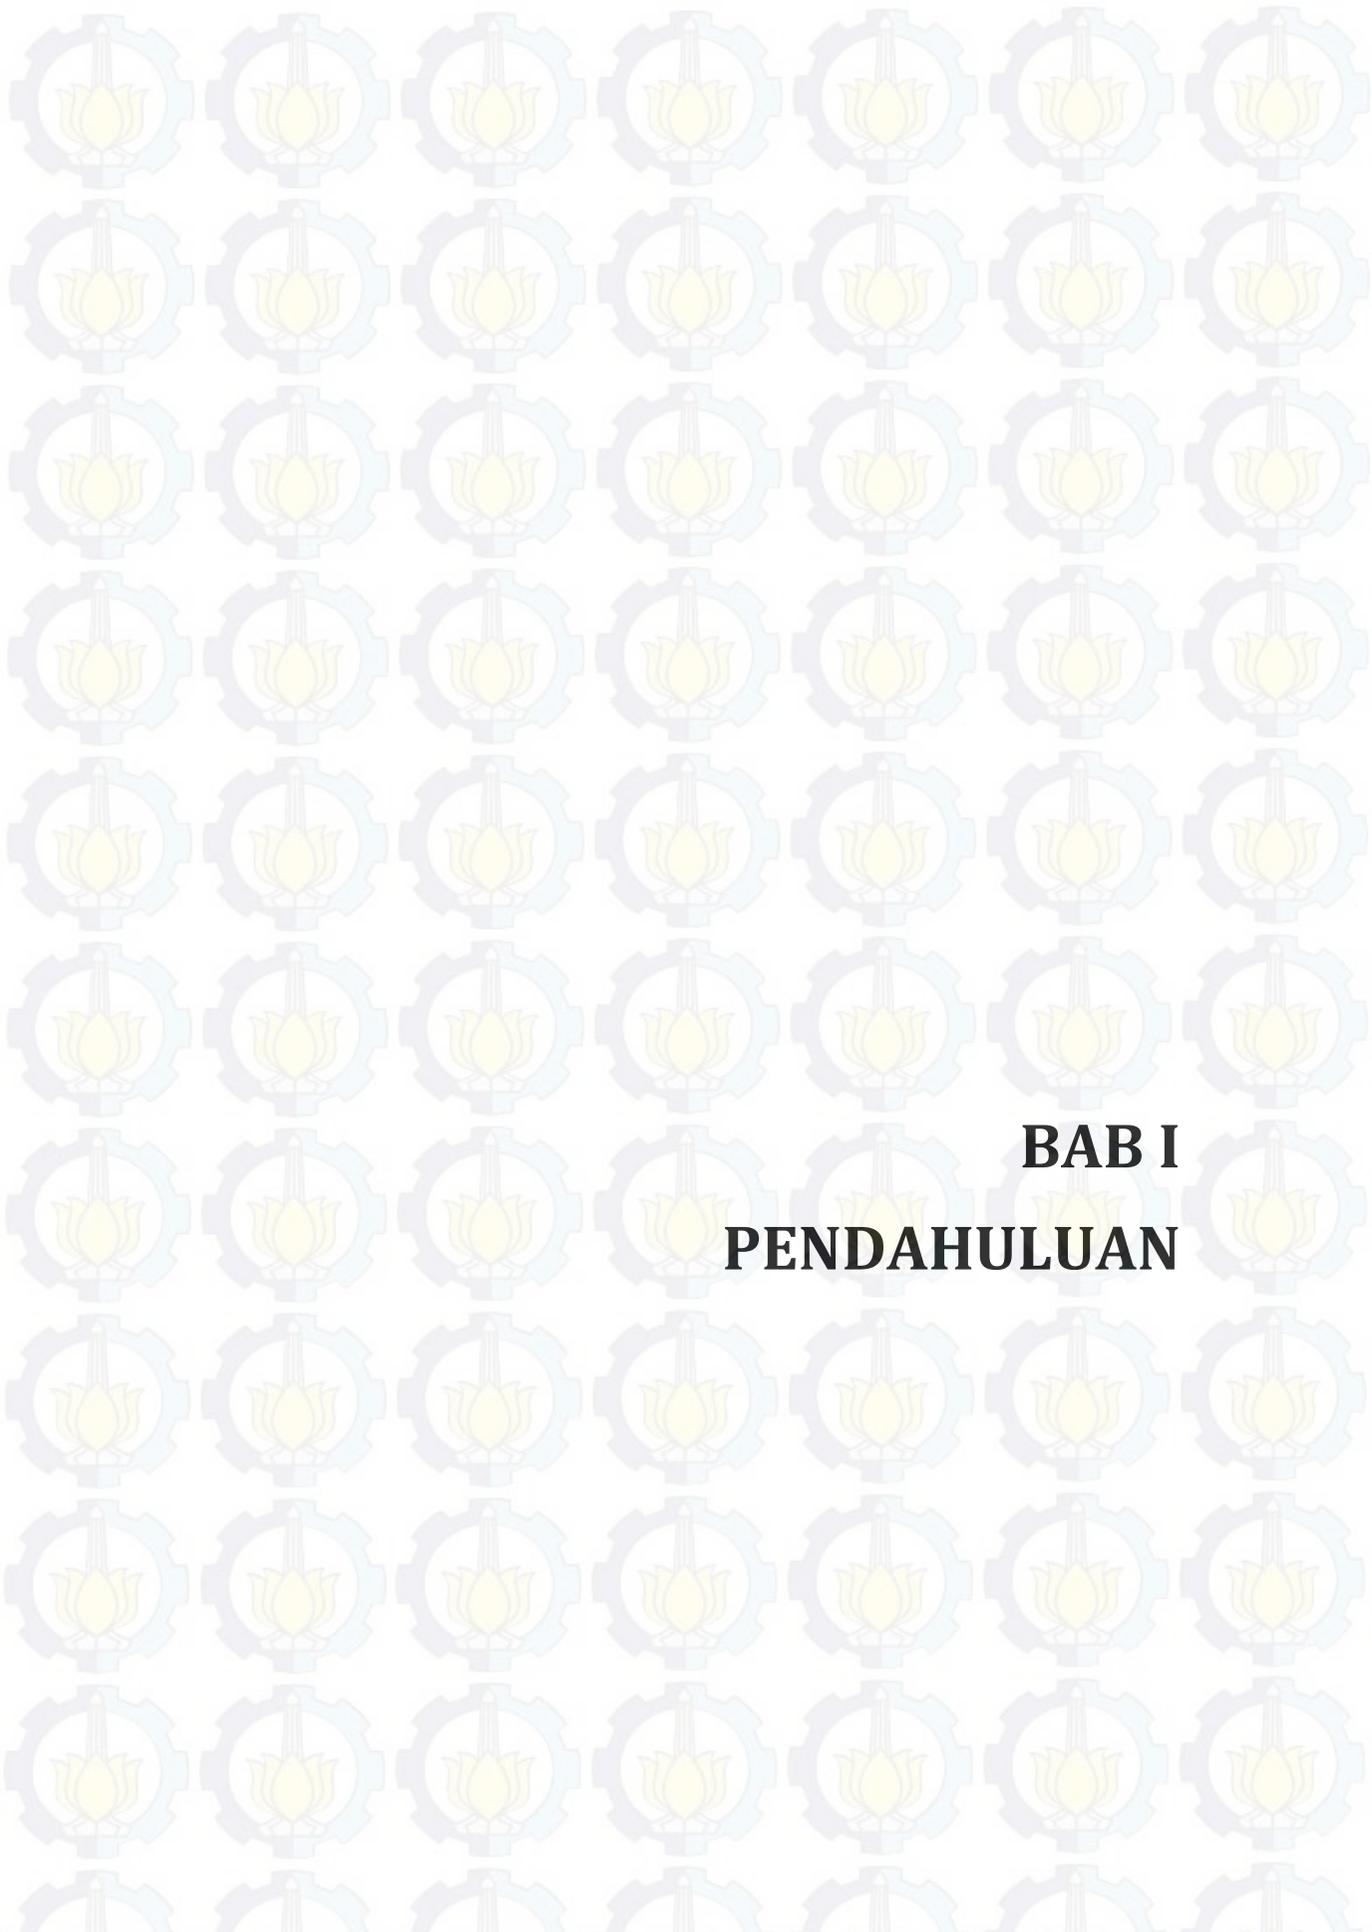
| | |
|--|----|
| Gambar 1. 1 Kondisi Mudik di Pelabuhan Tanjung Priok | 2 |
| Gambar 2. 1 Skema Pendekatan ARIMA..... | 7 |
| Gambar 2. 2 Contoh-contoh <i>time series</i> dengan 50 pengamatan, dimana A adalah contoh <i>time series</i> yang deterministik, sedangkan B, C dan D adalah contoh yang stokastik..... | 8 |
| Gambar 2. 3 Fungsi autokorelasi suatu data Z_t | 13 |
| Gambar 2. 4 Fungsi parsial autokorelasi suatu data Z_t | 14 |
| | |
| Gambar 3. 1 Diagram Air Pengerjaan Skripsi | 21 |
| Gambar 3. 2 Diagram Air Pengerjaan Skripsi Lanjutan..... | 22 |
| Gambar 3. 3 Contoh hasil plot data pada EViews | 24 |
| Gambar 3. 4 Contoh hasil plot ACF dan PACF..... | 26 |
| | |
| Gambar 4. 1 Data Jumlah Penumpang Kapal tahun 2009-2015..... | 29 |
| Gambar 4. 2 Tren Jumlah Penumpang Kapal tahun 2009-2015 | 30 |
| Gambar 4. 3 Plot Data Jumlah Penumpang Kapal tahun 2009-2015 (series utama percobaan1)..... | 31 |
| Gambar 4. 4 Plot Data Series dslog1percobaan1 | 32 |
| Gambar 4. 5 Plot Data Series dslog1percobaan1 dan dslog2percobaan1 dalam satu grup..... | 32 |
| Gambar 4. 6 Plot ACF dan PACF dari series percobaan1 | 33 |
| Gambar 4. 7 Plot ACF dan PACF dari series dslog1percobaan1 | 34 |
| Gambar 4. 8 Plot ACF dan PACF dari series difdslog1percobaan1 | 35 |
| Gambar 4. 9 Hasil Forecast..... | 36 |
| Gambar 4. 10 Perbandingan Hasil Peramalan dan Data Asli | 38 |
| Gambar 4. 11 Perbandingan Error..... | 38 |

DAFTAR TABEL

| | |
|---|----|
| Tabel 1. 1 Jumlah Penumpang Pelabuhan-Pelabuhan di Indonesia periode Januari-Oktober, 2012 | 1 |
| Tabel 2. 1 Pembagian metode peramalan dan contoh penggunaannya | 6 |
| Tabel 2. 2 Rangkuman perintah untuk operasi diferensi | 11 |
| Tabel 2. 3 Rangkuman perintah log dan log return..... | 12 |
| Tabel 2. 4 Pola teoritik ACF dan PACF dari proses stasioner..... | 14 |
| Tabel 4. 1 Hasil Rangkuman Semua Model Dugaan | 36 |
| Tabel 4. 2 Hasil Peramalan 12 Bulan ke Depan | 37 |

DAFTAR PERSAMAAN

| | |
|--|----|
| Persamaan 2- 1 Stasioneritas rata-rata | 9 |
| Persamaan 2- 2 Stasioneritas varians..... | 10 |
| Persamaan 2- 3 Diferensi orde 1 | 10 |
| Persamaan 2- 4 Diferensi orde n | 11 |
| Persamaan 2- 5 Diferensi orde s seasonal | 11 |
| Persamaan 2- 6 Kombinasi diferensi orde n dan orde s (<i>seasonal</i>)..... | 11 |
| Persamaan 2- 7 Fungsi autokorelasi..... | 12 |
| Persamaan 2- 8 Fungsi Parsial Autokorelasi..... | 13 |
| Persamaan 2- 9 Bentuk umum AR (p)..... | 14 |
| Persamaan 2- 10 Bentuk umum MA (q) | 15 |
| Persamaan 2- 11 Bentuk umum ARMA..... | 15 |
| Persamaan 2- 12 Bentuk umum ARIMA | 16 |
| Persamaan 2- 13 Model SARIMA <i>additive moving average</i> | 17 |
| Persamaan 2- 14 Model SARIMA <i>additive autoregressive</i> | 17 |
| Persamaan 2- 15 Model SARIMA multiplikatif <i>moving average</i> | 17 |
| Persamaan 2- 16 Model SARIMA multiplikatif <i>autoregressive</i> | 18 |



BAB I
PENDAHULUAN

BAB I

PENDAHULUAN

1.1. Latar Belakang

Menilik perkembangan transportasi laut Indonesia khususnya kapal penumpang, terjadi penurunan dalam 1 dekade terakhir. Dikutip dari Harian Kompas tertanggal 20 Juni 2017, Kepala Otoritas Pelabuhan Tanjung Priok I, Nyoman Gede Saputra mengatakan, terdapat kecenderungan penurunan jumlah penumpang saat mudik lebaran di Pelabuhan Tanjung Priok setiap tahunnya. Kepala Badan Pusat Statistik (BPS), Suryamin menyampaikan data penurunan jumlah penumpang kapal. Berdasarkan data BPS, penumpang kapal dalam negeri selama bulan Januari hingga bulan Oktober 2012, hanya tercatat 5,7 juta orang dengan tingkat penurunan sebesar 11,37% dibanding dengan periode yang sama pada tahun 2011. Telah diberitakan pula pada *website* Direktorat Jenderal Perhubungan Laut di tahun yang sama, penurunan jumlah penumpang terjadi di banyak pelabuhan di Indonesia, khususnya pada Pelabuhan Tanjung Priok dengan tingkat penurunan sebesar 12,28%. **Tabel 1.1** berikut ini menunjukkan kondisi di berbagai pelabuhan di Indonesia pada periode Januari-Oktober, tahun 2012.

Tabel 1. 1 Jumlah Penumpang Pelabuhan-Pelabuhan di Indonesia periode Januari-Oktober, 2012

| Nama Pelabuhan | Persentase | Kondisi |
|-------------------------|------------|---------|
| Pelabuhan Tanjung Perak | 13,23% | Turun |
| Pelabuhan Tanjung Priok | 12,88% | Turun |
| Pelabuhan Belawan | 4,12 % | Turun |
| Pelabuhan Makassar | 11,54 % | Naik |
| Pelabuhan Balikpapan | 5,62 % | Naik |

Adanya penurunan terhadap jumlah penumpang kapal laut pada jalur-jalur tertentu di Indonesia ditengarai sebagai konsekuensi adanya peningkatan daya beli masyarakat sebagai pencerminan peningkatan ekonomi. Namun hal ini menjadi sangat riskan bagi perusahaan pelayaran angkutan penumpang dalam negeri, baik yang berbadan hukum BUMN maupun swasta. Kenyataannya, terkecuali untuk bulan-bulan yang berbarengan dengan hari raya keagamaan, hari libur panjang dan hari libur nasional

lainnya, maka hampir selalu terjadi penurunan jumlah penumpang setiap bulannya. (*Majalah Dermaga*, edisi 170 Januari 2013).

Terjadinya penurunan jumlah penumpang ini telah menjadi pembicaraan sejak beberapa tahun lalu. Pada harian Tempo, tertanggal 22 November 2005, memberitakan bahwa PT. Pelayaran Nasional Indonesia (PT. Pelni) mengalami penurunan jumlah penumpang secara drastis sebesar 50% sehingga berimbas terhadap turunnya pendapatan perusahaan. Menilik waktu 12 tahun ke depan, yaitu tahun 2017, PT. Pelni telah menysasar pasar pariwisata dan logistik yang dikarenakan karena alasan yang sama yaitu turunnya jumlah penumpang. Berdasarkan harian Kompas tertanggal 17 Juni 2017, untuk arus mudik, PT. Pelni hanya dapat mengangkut 557.687 penumpang. Jumlah ini lebih rendah dibandingkan tahun 2016 yang mampu mengangkut penumpang sebanyak 568.739. Bahkan di tahun 2015, Pelni dapat mengangkut 683.793 pemudik. **Gambar 1.1** menunjukkan gambaran keadaan mudik tahun 2017 bulan Juni lalu.



Gambar 1.1 Kondisi Mudik di Pelabuhan Tanjung Priok

Maka dari itulah, dibutuhkan perkiraan jumlah penumpang di masa yang akan datang untuk dapat melihat pangsa pasar di sektor ini, mengingat tren yang turun setiap tahunnya. Perkiraan jumlah penumpang dari tahun ke tahun dapat dilakukan dengan menggunakan metode ARIMA Box-Jenkins. ARIMA merupakan kepanjangan dari *Auto Regressive Integrated Moving Average*, yaitu metode peramalan berdasarkan data *time series* atau kurun waktu.

ARIMA Box-Jenkins merupakan salah satu metode untuk meramalkan atau memperkirakan (*forecasting*) data masa yang akan datang berdasarkan data masa lalu, khususnya data *time series*. Metode ini telah dikembangkan oleh George Box dan Gwilym Jenkins (1976). Sehingga anonim nama mereka yang mengikuti setelah nama ARIMA. Konsep dasarnya yaitu data sekarang atau masa yang akan datang (z_t) bergantung pada beberapa data dari pengamatan sebelumnya (z_{t-k}). Dengan kata lain, model ini digunakan jika terdapat korelasi (dependen) antar deret pengamatan (Wei, 1990). Metode ini sangat baik akurasi jika digunakan untuk meramalkan (*forecasting*) dalam jangka pendek. Untuk jangka panjang, ketepatannya berkurang dan akan cenderung *flat* (Ekananda, 2014).

Dengan metode ini akan diberikan pemodelan terbaik yang nantinya dapat menginterpretasikan keadaan di masa yang akan datang, khususnya untuk jumlah penumpang angkutan laut di Pelabuhan Tanjung Priok, Jakarta Utara. Pemodelan terbaik yang dihasilkan dapat menjadi acuan dalam pengambilan keputusan serta mengidentifikasi penyebab penurunan atau kenaikan jumlah penumpang angkutan laut. Sehingga memudahkan perusahaan dalam sektor pelayaran untuk mengambil tindak lanjut dalam usaha ini.

Berdasarkan paparan diatas, maka penulis menggunakan metode ARIMA Box-Jenkins dalam memperkirakan jumlah penumpang angkutan kapal laut dan membandingkan akurasi dengan data di lapangan (merujuk pada data dari Jakarta Utara dalam Angka Tahun 2017). Analisis data akan dilakukan dengan menggunakan software EViews 9 dengan menggunakan data Jumlah Penumpang Kapal dari Pelabuhan Tanjung Priok per Bulan tahun 2009 hingga 2015.

1.2. Perumusan Masalah

Dari paparan latar belakang diatas, maka dapat diambil dua rumusan masalah untuk tugas akhir ini, yaitu sebagai berikut.

1. Bagaimanakah metode ARIMA dapat memberikan model terbaik untuk jumlah penumpang kapal dalam jangka waktu pendek?
2. Bagaimana tingkat akurasi model ARIMA terhadap jumlah penumpang kapal laut jika dibandingkan dengan data jumlah penumpang kapal Pelabuhan Tanjung Priok tahun 2016?

1.3. Batasan Masalah

Untuk memudahkan pengerjaan tugas akhir ini, maka dilakukan pembatasan terhadap permasalahan yang diangkat dalam penulisan ini. Batasan masalah yang digunakan adalah sebagai berikut.

1. Data yang digunakan yaitu data yang berasal dari Badan Pusat Statistik (BPS) Jakarta Utara, khususnya Jakarta Utara Dalam Angka (JUDA) untuk kurun waktu 2009 hingga 2016.
2. Perbandingan dilakukan dengan menggunakan data dari Jakarta Utara Dalam Angka tahun 2017.

1.4. Tujuan Skripsi

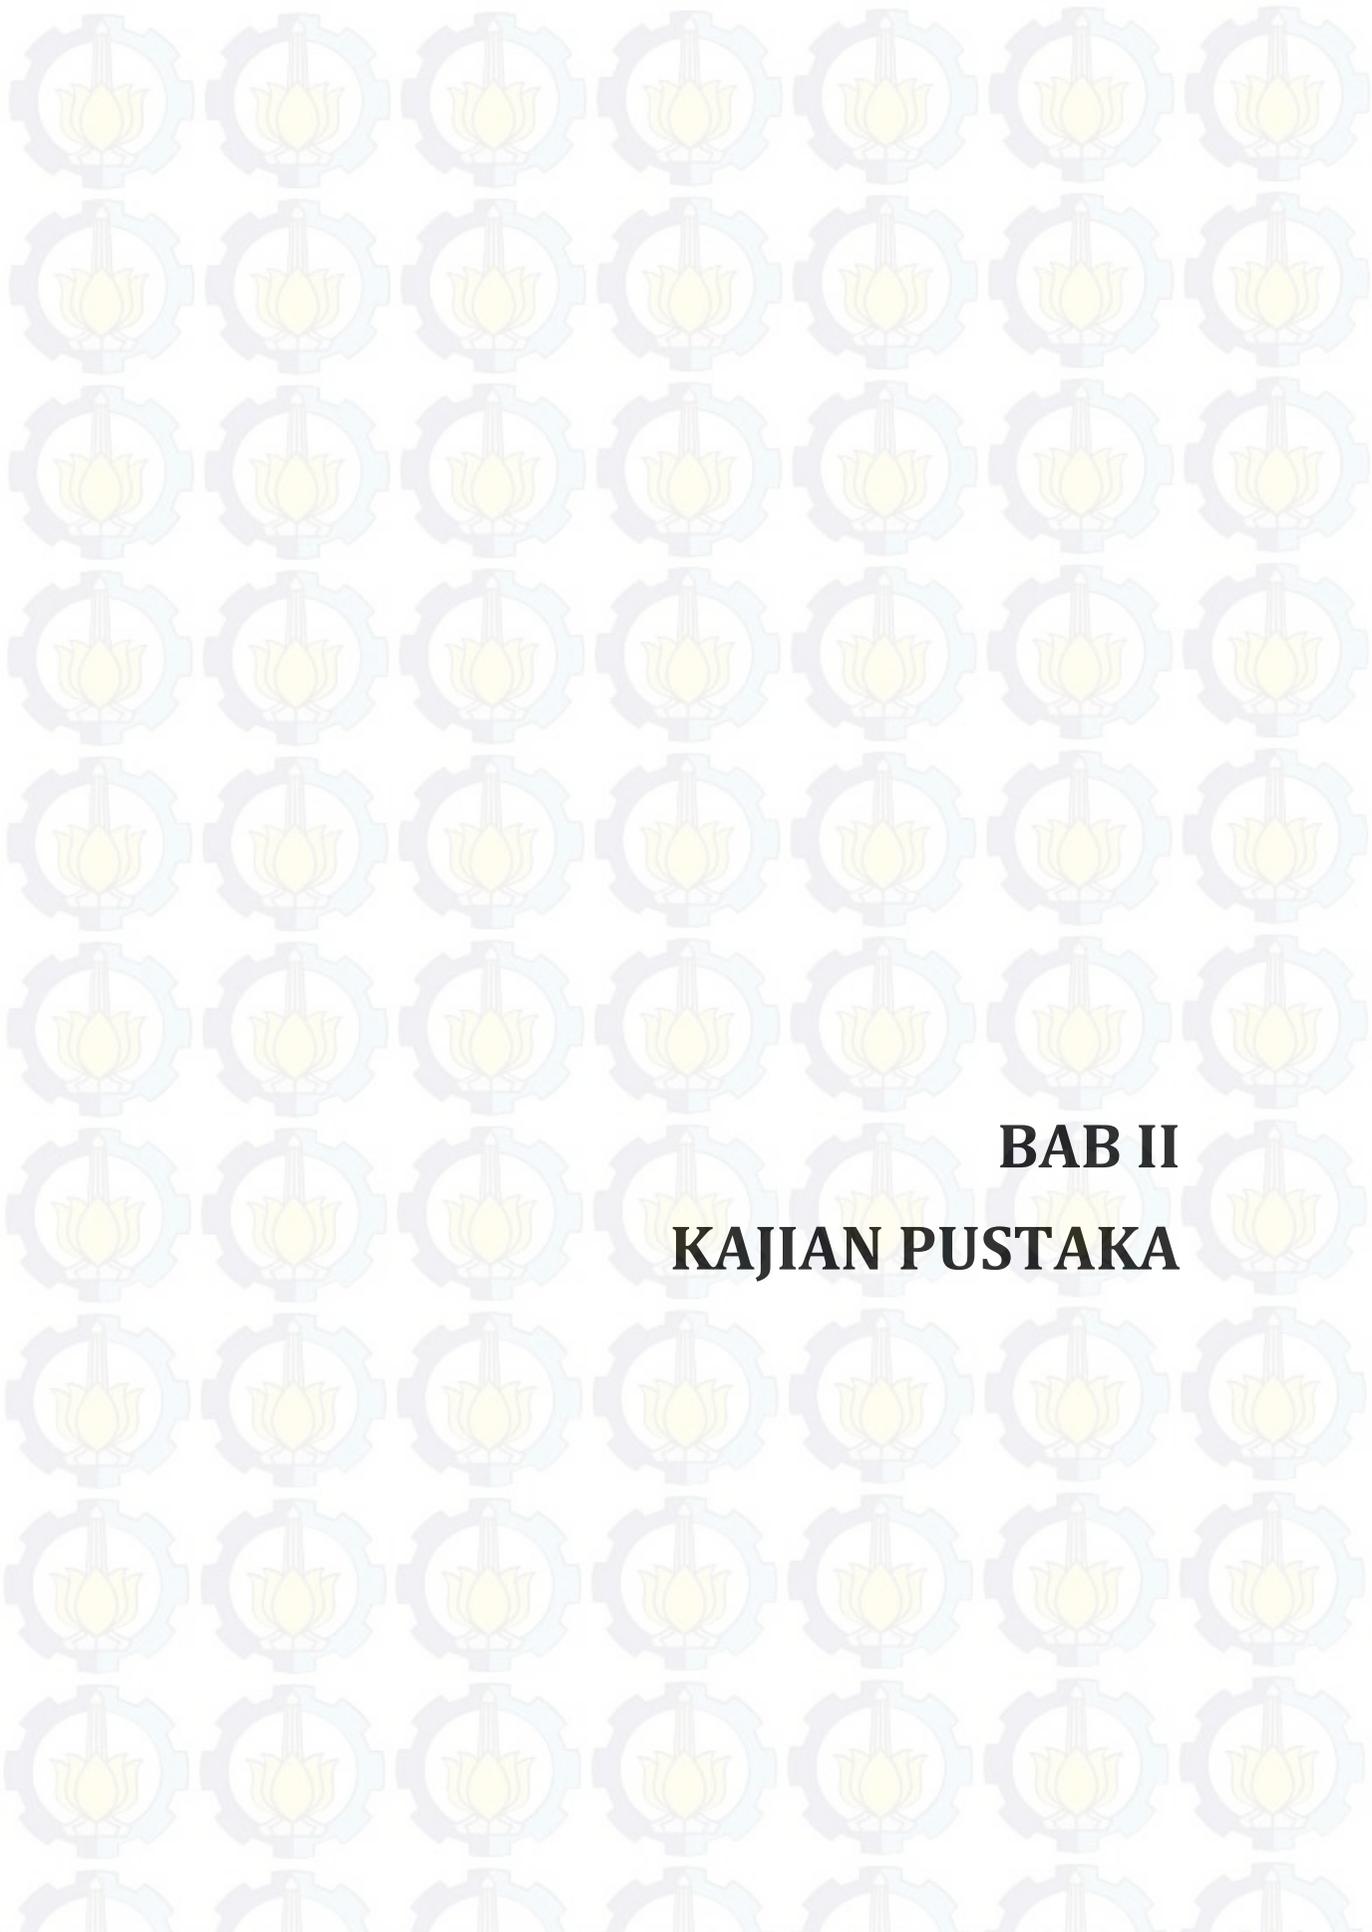
Pengerjaan tugas akhir ini memiliki dua tujuan utama yaitu sebagai berikut.

1. Menyajikan cara memperkirakan jumlah penumpang angkutan kapal laut di Pelabuhan Tanjung Priok dengan menggunakan metode ARIMA Box-Jenkins.
2. Membandingkan tingkat akurasi jumlah penumpang angkutan kapal laut antara hasil yang didapatkan dari model terbaik ARIMA dengan data riil di lapangan.

1.5. Manfaat

Adapun manfaat yang dapat diambil dari pengerjaan tugas akhir ini adalah sebagai berikut.

1. Mengetahui dan memahami cara membuat prakiraan jumlah penumpang kapal dengan menggunakan metode ARIMA Box-Jenkins.
2. Dapat digunakan sebagai bahan rujukan atau pertimbangan oleh peneliti selanjutnya dalam topik serupa untuk menentukan metode peramalan yang lebih efektif.



BAB II
KAJIAN PUSTAKA

BAB II

KAJIAN PUSTAKA

2.1. Konsep Peramalan

Sering terjadi selisih waktu (*time lag*) antara kejadian atau peristiwa saat ini dengan kebutuhan di masa yang akan datang menjadi alasan utama adanya peramalan. Hal ini dibutuhkan untuk memprediksi peristiwa di masa yang akan datang serta sebagai dasar pengambilan keputusan dalam suatu unit usaha. Pada dasarnya, peramalan merupakan proses menyusun informasi tentang kejadian masa lampau yang berurutan untuk menduga kejadian di masa depan (Frechtling, 2001). Kegiatan peramalan merupakan bagian integral dari pengambilan keputusan manajemen (Makridakis, 1983). Lebih lanjut, peramalan mengurangi ketidakpastian atau hal yang intuitif yang sebelumnya banyak digunakan sebagai dasar pengambilan keputusan.

Terdapat dua pendekatan untuk melakukan peramalan, yaitu dengan pendekatan kuantitatif dan pendekatan kualitatif. Lebih lanjutnya, pendekatan kuantitatif dibagi lagi ke dalam deret waktu (*time series*) dan metode kausal. Sedangkan metode kualitatif terdiri dari metode eksplanatoris dan normatif. **Tabel 2.1** menjelaskan ringkasan dari skema penggolongan peramalan.

Peramalan kuantitatif dapat diterapkan bila terdapat kondisi sebagai berikut.

1. Tersedia informasi tentang masa lalu.
2. Informasi tersebut dapat dikuantitatifkan dalam bentuk numerik.
3. Dapat diasumsikan bahwa beberapa aspek pola masa lalu akan terus berlanjut di masa mendatang.

Lain halnya dengan metode kuantitatif, metode kualitatif tidak membutuhkan data serupa. Input yang dibutuhkan biasanya merupakan hasil dari pemikiran intuitif, perkiraan (*judgement*) dan pengetahuan yang telah didapat.

Tabel 2. 1 Pembagian metode peramalan dan contoh penggunaannya

| Jenis Informasi yang Tersedia | | | | | |
|--|--|--|--|---|---|
| Jenis Situasi Peramalan | Cukup tersedia informasi kuantitatif | | Informasi kuantitatif sedikit atau tidak tersedia, tetapi terdapat pengetahuan kualitatif yang cukup | | Informasi sedikit atau tidak tersedia |
| | Metode deret berkala | Metode Kausal | Metode eksplanatoris | Metode normatif | |
| Meramalkan kesinambungan pola atau hubungan | Menduga kelanjutan pertumbuhan dalam penjualan atau GNP | Memahami bagaimana harga dan advertensi mempengaruhi penjualan | Menduga kecepatan transportasi sekitar tahun 2000 | Menduga bagaimana tampilan mobil tahun 1990 | Menduga pengaruh perjalanan antar planet; perjalanan bumi oleh - makhluk luar bumi; penemu energi baru yang sangat murah dan tidak menimbulkan polusi |
| Meramalkan perubahan atau jika perubahan terjadi dalam pola yang ada | Menduga resesi mendatang atau sejauh mana hal itu akan terjadi | Memahami bagaimana pengaruh pengendalian harga, atau pelarangan advertensi TV terhadap penjualan | Meramalkan bagaimana suatu kenaikan yang besar dari harga minyak akan mempengaruhi konsumsi minyak | Dapat menduga embargo minyak yang mengikuti yang mengikuti perang Arab-Israel | |

2.2. Metode Deret Berkala (*Time Series*) Box-Jenkins ARIMA

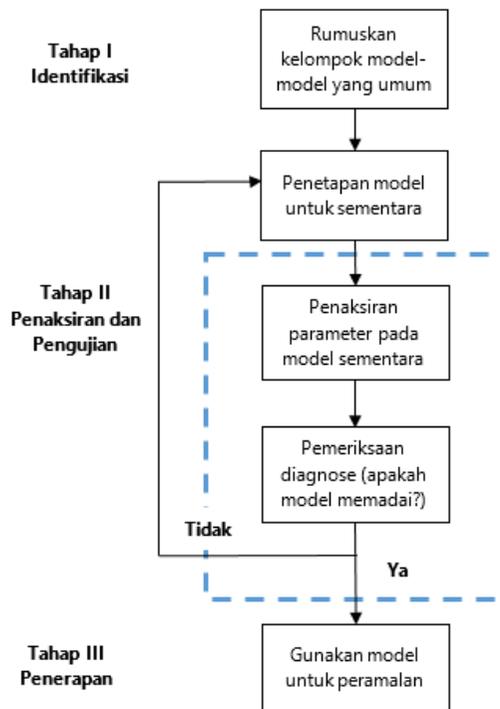
2.2.1. Historis ARIMA Box-Jenkins

Model-model *Autoregressive Integrated Moving Average* (ARIMA) telah dipelajari secara mendalam oleh George Box dan Gwilym Jenkins (1976) dan nama mereka berdualah yang disinonimkan dengan proses ARIMA yang diterapkan untuk proses deret berkala, peramalan dan kontrol atau pengendalian.

Model Autoregresif (AR) pertama kali dikenalkan oleh Yule (1926) dan kemudian dikembangkan oleh Walker (1931), sedangkan model Moving Average (MA) pertama kali digunakan oleh Slutsky (1937). Akan tetapi Wold-lah (1938) yang menghasilkan dasar-dasar teoritis dari proses kombinasi ARMA. Wold membentuk model ARMA yang berkembang dalam tiga arah (untuk proses AR, MA, dan ARMA campuran). Perluasan

dari hasil tersebut mencakup deret berkala musiman (*seasonal time series*) dan pengembangan sederhana yang mencakup proses-proses non-stasioner.

Box dan Jenkins berhasil dalam menentukan informasi relevan yang diperlukan untuk memahami dan memakai model-model ARIMA untuk deret berkala. Dasar dari tiga tahap dari pendekatan hasil mereka dapat dilihat pada **Gambar 2.1**. yaitu identifikasi, penaksiran dan pengujian, serta penerapan.



Gambar 2. 1 Skema Pendekatan ARIMA

2.2.2. Konsep Dasar

2.2.2.1. Proses Deterministik dan Stokastik

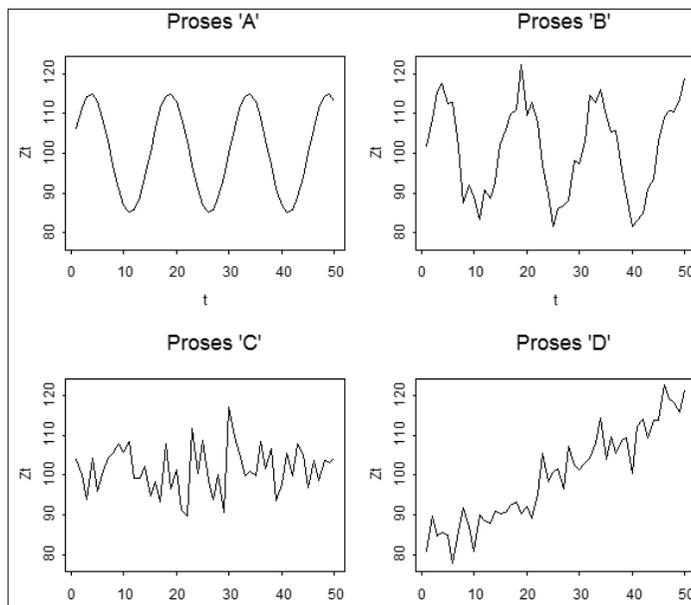
Berdasarkan ada tidaknya kepastian terjadinya suatu keadaan di masa yang akan datang, maka *time series* dibagi menjadi dua kelompok, yaitu *time series* yang merupakan proses deterministik dan proses stokastik (Box, 2008). Berikut penjelasan keduanya.

- Jika nilai suatu masa yang akan datang (*future value*) dari suatu runtun waktu dengan tepat dapat ditentukan oleh suatu fungsi

matematika, maka *time series* tersebut dikatakan proses deterministik atau dengan kata lain telah dapat ditentukan secara pasti.

- Jika *future value* dari suatu runtun waktu hanya dapat digambarkan dalam suatu distribusi probabilitas maka *time series* tersebut dikatakan sebagai stokastik.

Proses stokastik inilah yang digunakan untuk membuat peramalan, khususnya pada penelitian ini terkait data jumlah penumpang keberangkatan dari Pelabuhan Tanjung Perak pada kurun waktu tahun 2012 hingga tahun 2016. **Gambar 2.2.** di bawah ini menunjukkan contoh hasil plot data untuk proses deterministik dan stokastik. Untuk Z_t menunjukkan data runtun waktu dan untuk t menunjukkan waktu pengamatan.



Gambar 2. 2 Contoh-contoh *time series* dengan 50 pengamatan, dimana A adalah contoh *time series* yang deterministik, sedangkan B, C dan D adalah contoh yang stokastik.

2.2.2.2. Stasioneritas Data

Data runtun waktu haruslah memiliki sifat stasioner untuk dapat menghasilkan model terbaik. Stasioneritas didefinisikan sebagai proses yang berada dalam keseimbangan (*equilibrium*) di sekitar nilai *mean* yang konstan. Terdapat dua jenis stasioneritas, yaitu stasioner kuat atau

stasioner orde pertama dan stasioner lemah atau stasioner orde kedua (Yaffee,2000).

- a. Stasioner kuat (*strictly stationarity*)
Dikatakan memiliki stasioner yang kuat jika data runtun waktu memiliki rata-rata tetap dan varians tetap serta autokovarians yang konstan.
- b. Stasioner lemah (*weakly stationarity*)
Untuk stasioner lemah, hanya dua karakteristik yang ditentukan, yaitu nilai rata-rata dan varians yang konstan. Untuk autokovarians stasioneritas jenis ini merupakan fungsi dari lag (nilai selisih waktu pengamatan).

Pada aplikasinya, khususnya untuk peramalan dengan menggunakan pemodelan ARIMA menggunakan stasioner lemah untuk tahapan prosesnya. Seperti yang telah disebutkan sebelumnya, dua syarat menjadi karakteristik stasioneritas jenis ini, berikut penjelasan lebih lengkapnya.

Data dikatakan stasioner $\{Z_t\}$ jika memenuhi kedua syarat berikut ini (Box,2008).

a. *Mean stationarity*

Data bersifat stasioner terhadap rata-rata (*mean*) jika berfluktuasi di sekitar nilai rata-rata yang tetap dari waktu ke waktu seperti diformulasikan pada persamaan 2-1 berikut ini.

$$\mu = E[Z_t] = \int_{-\infty}^{\infty} Zp(Z)dZ$$

Persamaan 2- 1 Stasioneritas rata-rata

dengan,

Z_t : data ke-t

μ : rata-rata

$p(Z)$: distribusi probabilitas

b. *Variance stationerity*

Data bersifat stasioner terhadap varians jika berfluktuasi pada varian yang tetap dari waktu ke waktu yang diformulasikan pada persamaan 2-2 di bawah ini.

$$\sigma_z^2 = E[(Z_t - \mu)^2] = \int_{-\infty}^{\infty} (Z - \mu)^2 p(Z) dZ$$

Persamaan 2- 2 Stasioneritas varians

dengan,

Z_t : data ke-t

σ_z^2 : varians data ke-t

μ : rata-rata

$p(Z)$: distribusi probabilitas

2.2.2.3. Uji Stasioneritas

Di dalam analisis runtun waktu, asumsi stasioneritas dari data merupakan sifat yang penting. Pada model stasioner, sifat-sifat statistik di masa yang akan datang dapat diramalkan berdasarkan data historis yang telah terjadi di masa lalu. Pengujian stasioneritas dari data runtun waktu dapat dilakukan dengan beberapa cara, yaitu sebagai berikut.

- a. Untuk mendeteksi ketidakstasioneran data dalam mean dapat digunakan plot dari data dalam urutan waktu, plot fungsi autokorelasi (*autocorrelation function* / ACF) dan plot fungsi autokorelasi parsial (*partial autocorrelaton function* / PACF). Jika data mengandung komponen trend maka plot ACF/PACF akan meluruh secara perlahan dan data non-stasioner dalam mean.
- b. Untuk mendeteksi ketidakstasioneran dalam variansi dapat digunakan plot ACF/PACF dari residual kuadrat.

2.2.2.4. Transformasi Data

a. Transformasi Diferensi

Salah satu jenis transformasi yang sering digunakan dalam analisa data runtun waktu adalah transformasi diferensi. Tujuan dari transformasi ini adalah membentuk barisan data runtun waktu yang bersifat stasioner, yakni untuk mencari komponen stasioner dari dari data yang memuat komponen trend dan/atau komponen musiman. Diferensi orde 1 dari suatu data runtun waku X_t didefinisikan dengan persamaan sebagai berikut.

$$\Delta X_t = (1 - B)X_t = X_t - X_{t-1}$$

Persamaan 2- 3 Diferensi orde 1

Dengan $(B^j X)_t = X_{t-j}$ yakni operator backward orde ke-j. Sedangkan diferensi orde n didefinisikan sebagai berikut.

$$\Delta^n X_t = (1 - B)^n X_t = (1 - B)^{n-1}((1 - B)X_t)$$

Persamaan 2- 4 Diferensi orde n

Selain itu juga dapat dilakukan diferensi dengan komponen seasonal (musiman) orde s, yang didefinisikan sebagai berikut.

$$\Delta_s X_t = (1 - B^s)X_t = X_t - X_{t-s}$$

Persamaan 2- 5 Diferensi orde s seasonal

Kombinasi dari diferensi orde n dan diferensi pada komponen seasonal orde s, yakni sebagai berikut.

$$\Delta^n \Delta_s X_t = (1 - B)^n (1 - B^s) X_t$$

Persamaan 2- 6 Kombinasi diferensi orde n dan orde s (*seasonal*)

Dalam EViews, transformasi diatas dapat dilakukan dengan fungsi built-in yang terangkum dalam **Tabel 2.2** Sebagai berikut.

Tabel 2. 2 Rangkuman perintah untuk operasi diferensi

| Persamaan | Perintah |
|-----------|----------|
| 2-3 | d(x) |
| 2-4 | d(x,n) |
| 2-5 | d(x,0,s) |
| 2-6 | d(x,n,s) |

b. Transformasi Log

Jenis transformasi lain yang sering digunakan dalam analisis data runtun waktu adalah transformasi logaritma (yakni fungsi ln atau logaritma natural) yang sering pula digabungkan dengan melakukan diferensi terhadap data hasil logaritma. Perintah built-in dari EViews yang digunakan untuk transformasi ini dirangkum dalam **Tabel 2.3** berikut ini.

2.2.2.5. Fungsi Autokorelasi (ACF) dan Fungsi Autokorelasi Parsial (PACF)

Model peramalan *Box-Jenkins* diidentifikasi dengan mengamati perilaku dari *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF). Pada dasarnya baik ACF maupun PACF memiliki fungsi yang

sama yaitu untuk menunjukkan hubungan linear antar data-data *time series* yang dipisahkan oleh *lag-k* unit waktu.

Tabel 2. 3 Rangkuman perintah log dan log return

| Perintah | Definisi | Persamaan matematis |
|-------------|---|---|
| log(X) | Untuk melakukan transformasi logaritma terhadap X_t | $\log(X)$ |
| dlog(X,n) | Untuk melakukan diferensi order n terhadap data $\log(X_t)$ | $\Delta^n \log(X_t) = \Delta^n (\log(X_t) - \log(X_{t-1}))$ |
| dlog(X,n,s) | Untuk melakukan diferensi order n dan diferensi musiman terhadap data $\log(X_t)$ | $\Delta^n \Delta_s \log(X_t) = (1 - B)^n B^s \log(X_t)$ |

a. Fungsi Autokorelasi

Autokorelasi adalah hubungan yang terjadi antara anggota-anggota data runtun waktu melalui pengamatan yang dilakukan (Makridakis, 1999). Jika tidak terdapat autokorelasi dalam data, maka dapat dikatakan bahwa data tersebut random atau tidak memiliki pola.

Nilai ACF pada *lag-k* dapat diformulasikan sebagai berikut.

$$\rho_k = \frac{\sum_{t=1}^{N-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^N (Z_t - \bar{Z})^2}$$

Persamaan 2- 7 Fungsi autokorelasi

dengan,

ρ_k : fungsi autokorelasi
 Z_t : data waktu-t
 \bar{Z} : rata-rata data ke-t
 Z_{t+k} : data waktu t+k

Berikut contoh dari suatu fungsi autokorelasi dari suatu data runtun waktu dapat dilihat pada **Gambar 2.3**.

b. Fungsi Parsial Autokorelasi

Fungsi autokorelasi parsial menunjukkan tingkat keeratn antara Z_t dan Z_{t+k} dengan syarat menghilangkan pengaruh dari lag 1,2, dan seterusnya sampai k-1. Nilai *PACF* pada *lag-k* dapat ditentukan sebagai berikut.

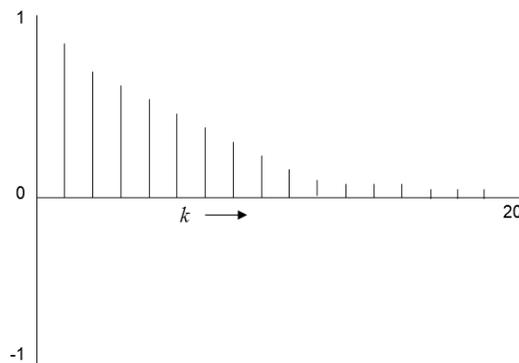
$$\phi_{kk} = \frac{\rho_k - \sum_{j=1}^{k-1} \phi_{k-1,j} \rho_{k-j}}{1 - \sum_{j=1}^{k-1} \phi_{k-1,j} \rho_j}$$

Persamaan 2- 8 Fungsi Parsial Autokorelasi

dengan,

ϕ_{kk} : fungsi autokorelasi parsial

ρ_k : fungsi autokorelasi



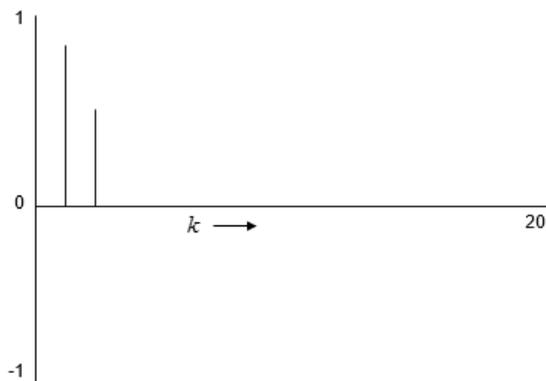
Gambar 2. 3 Fungsi autokorelasi suatu data Z_t

Contoh salah satu bentuk *PACF* teoritik dari suatu data runtun waktu dapat dilihat pada Gambar 2.4 sebagai berikut.

Melalui perhitungan *ACF* dan *PACF* dapat ditentukan model *autoregressive* (AR) atau model *moving average* (MA) orde ke berapa data yang sedang dianalisis. Tabel 2.3 berikut adalah tabel yang secara umum dapat digunakan untuk mengidentifikasi tingkat p dan q dari suatu data time series berdasarkan bentuk *ACF* dan *PACF* taksirannya.

2.2.3. Model – Model Stasioner

Model – Model Stasioner dibagi ke dalam 3 kelompok, yaitu metode *Autoregressive* (AR), *Moving Average* (MA), dan model campuran *ARIMA* (*Autoregressive and Moving Average*) yang mempunyai karakteristik dari dua model pertama.



Gambar 2. 4 Fungsi parsial autokorelasi suatu data Z_t

Tabel 2. 4 Pola teoritik ACF dan PACF dari proses stasioner

| Proses ACF | Sampel ACF | Sampel PACF |
|-------------------------------|---|---|
| White noise (random error) | Tidak ada yang melewati batas interval pada lag >0 | Tidak ada yang melewati batas interval pada lag >0 |
| AR (p) | Meluruh menuju 0 secara eskponensial | Diatas batas interval maksimum sampaipada lag ke p dan di bawah batas pada lag > p |
| MA (q) | Diatas batas interval maksimum sampaipada lag ke q dan di bawah batas pada lag > q | Meluruh menuju 0 secara eskponensial |
| ARMA (p,q) | Meluruh menuju 0 secara eskponensial | Meluruh menuju 0 secara eskponensial |

a. *Autoregressive* (AR)

Proses autoregresif sesuai dengan namanya adalah proses hasil regresi dengan dirinya sendiri. Bentuk umum dari proses autoregresif tingkat p atau AR(p) adalah sebagai berikut.

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t$$

Persamaan 2- 9 Bentuk umum AR (p)

dimana,

Z_t = data ke-t

ϕ_p = parameter *autoregressive* ke-t

a_t = nilai *error* pada saat ke-t

b. *Moving Average* (MA)

Bentuk umum dari proses moving average tingkat q atau MA(q) didefinisikan sebagai

$$Z_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_p a_{t-p}$$

Persamaan 2- 10 Bentuk umum MA (q)

dimana,

Z_t = data ke- t

θ_p = parameter *moving average* ke- t

a_t = nilai *error* pada saat ke- t

c. *Autoregressive and Moving Average* (ARMA)

Pada Metode ARMA ordo p dan q (AR(p) dan MA(q)) adalah gabungan antara *Autoregressive Model* (AR) dan *Moving Average* (MA). Berikut ini merupakan rumus dari ARMA.

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

Persamaan 2- 11 Bentuk umum ARMA

dimana,

Z_t = data ke- t

ϕ_p = parameter *autoregressive* ke- t

a_t = nilai *error* pada saat ke- t

θ_p = parameter *moving average* ke- t

2.2.4. Model-Model Tak Stasioner

Model-model tak stasioner dapat ditandai dengan adanya proses *differencing* pada pemodelannya. Proses *differencing* (d) mengindikasikan bahwa data telah dilakukan transformasi hingga mencapai stasioner. Model tak stasioner dapat dijelaskan padapaparan sebagai berikut.

a. Model ARIMA (p,d,q)

Suatu time series yang dihasilkan dari 3 proses meliputi autoregressive (p), moving average (q), dan integrated (d) yang menandakan telah dilakukan proses differencing.

Pemodelan ini dituliskan sebagai berikut.

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

Persamaan 2- 12 Bentuk umum ARIMA

dimana,

Z_t = data ke- t

ϕ_p = parameter *autoregressive* ke- t

a_t = nilai *error* pada saat ke- t

θ_p = parameter *moving average* ke- t

b. Model SARIMA (*Seasonal* ARIMA)

Selain ditandai dengan adanya proses diferensi, model tak stasioner ditandai dengan adanya faktor musiman. Musiman didefinisikan sebagai suatu pola yang berulang sendiri setelah interval waktu yang tetap. Pola musiman dapat berupa triwuanan (3 bulanan), kwartalan (4 bulanan), semesteran (6 bulanan), atau tahunan (12 bulanan). Contoh sederhananya penjualan pakaian akan melonjak ketika menjelang Hari Raya Keagamaan. Jika pola tersebut konsisten, koefisien autokorelasi dari lag 12 bulan akan mempunyai nilai positif yang besar, menunjukkan adanya faktor musiman.

Untuk data stasioner, faktor musiman dapat ditentukan dengan mengidentifikasi koefisien autokorelasi lebih dari dua atau tiga timelag yang signifikan berbeda dari nol. Faktor musiman tidak selalu mudah diidentifikasi jangka musiman tersebut berkombinasi dengan pola lain seperti trend. Semakin kuatnya pengaruh trend (data tak stasioner), maka semakin tidak jelaslah faktor musimannya. Dengan demikian, data harus ditransformasi ke bentuk stasioner sebelum menentukan faktor musimannya.

Untuk membuat model bagi data musiman, secara umum dapat digunakan dua jenis model sebagai berikut.

1. Model *seasonal additive*

Pada model ini, komponen musiman berinteraksi dengan komponen non-musiman dalam model secara *additive*, dinyatakan sebagai model SARIMA $((p,P,(d,D),(q,Q))_s$ (*Seasonal* ARIMA) bagi proses X_t , yang dapat ditulis sebagai berikut.

$$(1 - a_1B - \dots - a_pB^p)(1 - B)^d(1 - B_s)^D x_t \\ = (1 + b_1B + \dots + b_qB^q + \theta_sB^s + \dots + \theta_QB^{sQ}) \varepsilon_t$$

Persamaan 2- 13 Model SARIMA *additive moving average*

dengan,

B = operator *backward*

p dan q = orde komponen non-musiman dari model ARIMA

d = orde diferensi komponen non-musiman

P = orde koefisien autoregresi dari komponen musiman multiplikatif

D = orde diferensi musiman

Q = orde koefisien moving verage dari komponen musiman multiplikatif

Untuk model diatas, komponen musiman digambarkan dengan menggunakan komponen *moving average* orde s. komponen musiman dapat juga ditanayakan dengan menggunakan komponen autoregresif, yakni menggunakan model sebagai berikut.

$$(1 - a_1B - \dots - a_pB^p - \beta_sB^s - \dots - \beta_pB^{sP})(1 - B)^d(1 - B_s)^D x_t \\ = (1 + b_1B + \dots + b_qB^q) \varepsilon_t$$

Persamaan 2- 14 Model SARIMA *additive autoregressive*

2. Model seasonal multiplikatif

Pada model ini komponen berinteraksi dengan komponen non-musiman dalam model secara multiplikatif (berbentuk perkalian (berbentuk perkalian), dapat ditulis sebagai berikut.

$$(1 - a_1B - \dots - a_pB^p)(1 - B)^d(1 - B_s)^D x_t \\ = (1 + b_1B + \dots + b_qB^q)(1 + \theta_sB^s + \dots + \theta_QB^{sQ}) \varepsilon_t$$

Persamaan 2- 15 Model SARIMA multiplikatif *moving average*

Disini komponen musiman digambarkan menggunakan komponen *moving average* orde s. komponen musiman dapat juga dinyatakan

dengan menggunakan komponen *autoregressive*, yakni sebagai berikut.

$$(1 - a_1B - \dots - a_pB^p)(1 - B)^d(1 - B_s)^D(1 - \beta_sB^s + \dots - \beta_pB^{sp})x_t \\ = (1 + b_1B + \dots + b_qB^q)\varepsilon_t$$

Persamaan 2- 16 Model SARIMA multiplikatif *autoregressive*

Model multiplikatif ini dapat dinotasikan sebagai model ARIMA (p,d,q)(P,D,Q)_s.

2.2.5. Diagnostic Checking

Diagnostic check dari model yang telah diestimasi dilakukan dengan memverifikasi kesesuaian model dengan sifat-sifat data. Jika model dugaan yang didapatkan akan memiliki sifat-sifat yang mirip dengan data asli. Dengan demikian residual yang dihitung berdasarkan model yang telah diestimasi mengikuti asumsi error dari model yang teoretis, seperti sifat *white noise*. Untuk melihat apakah residual bersifat *white noise* dapat dilakukan dengan dua cara, yaitu sebagai berikut.

- a. Melihat apakah plot sampel ACF/PACF residual yang terstandarisasi (residual dibagi estimasi standar deviasi residual) telah memenuhi sifat-sifat proses *white noise* dengan *mean* 0 dan variansi 1.

- b. Melakukan uji korelasi serial, yakni menguji hipotesis :

$H_0: \rho_1 = \rho_2 = \dots = \rho_k, k < n$ tidak terdapat korelasi serial dalam residual lag-k, $k < n$)

Uji ini dapat dilakukan dengan menggunakan statistic uji Box-Pierce $Q = n \sum_{j=1}^k \hat{\rho}(j)^2$, atau L-Jung Box $Q = n(n+2) \sum_{j=1}^k \hat{\rho}(j)^2 / (n-j)$, yang akan berdistribusi $\chi^2(k - (p+q)), k > (p+q)$. Disini menunjukkan nilai sampel ACF pada lag-j sedangkan p dan q menunjukkan order dari model ARMA (p,q). Apabila hipotesis diagnostic check ditolak maka model dugaan yang telah didapatkan tidak dapat digunakan, dan selanjutnya dapat diidentifikasi kembali model yang sesuai dengan data.

Selanjutnya dalam praktik mungkin banyak model yang memenuhi pengujian diagnostic diatas. Untuk memilih model terbaik diantara model-model yang memenuhi uji diagnostik, dapat dipilih model yang meminimumkan ukuran kriteria informasi seperti *Akaike*

Information Criteria, $AIC = n \ln(\widehat{\sigma_\varepsilon^2}) + 2(p + q + 1)$, $\widehat{\sigma_\varepsilon^2} = SSE/n$, dengan $SSE = \text{Sum of Squared Error}$ yang dapat diestimasi dari jumlah kuadrat semua nilai residual. Akan tetapi, diketahui untuk model *autoregressive*, kriteria AIC tidak memberikan order p yang konsisten, sehingga untuk perbandingan dapat digunakan kriteria informasi lain, seperti *Schwartz Bayesian Information Criteria*, $SBC = n \ln(\widehat{\sigma_\varepsilon^2}) + 2(p + q + 1)$, $n \ln$, ataupun bentuk kriteria informasi lain yang diusulkan.

2.2.6. Forecast dalam EViews

Dalam EViews terdapat dua jenis peramalan yaitu sebagai berikut.

a. *Static forecast*

Dengan metode *static forecast* dilakukan peramalan satu langkah ke depan dari variabel dependen. Untuk setiap nilai peramalan satu langkah, EViews akan menghitung nilai peramalan dengan menggunakan nilai-nilai aktual dari nilai lag untuk variabel dependen yang digunakan untuk peramalan.

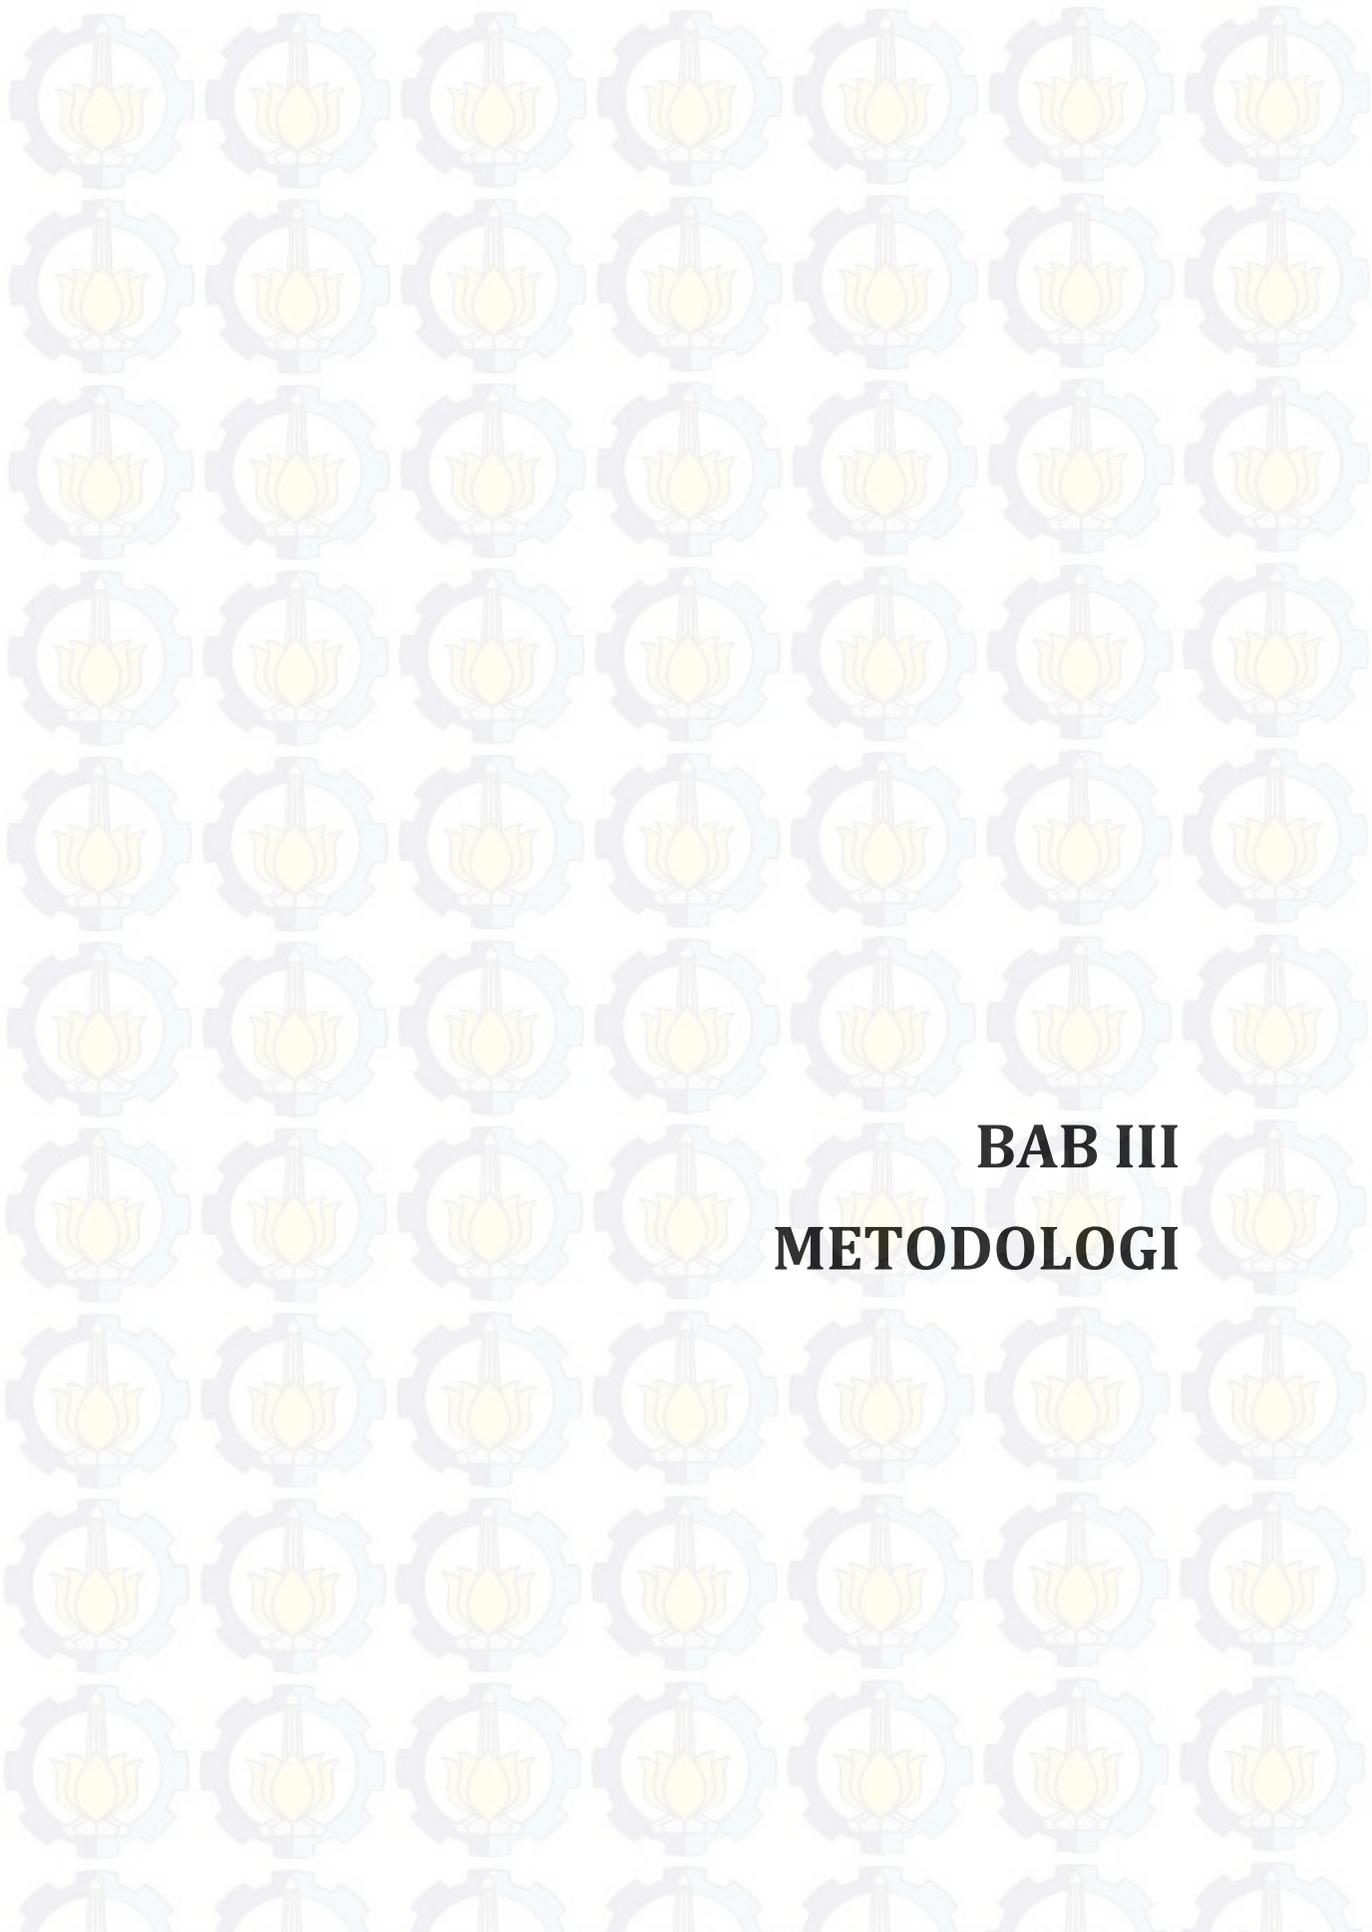
b. *Dynamic forecast*

Dengan menggunakan metode *dynamic forecasting*, EViews akan melakukan peramalan n -langkah dari variabel dependen, dimulai dari waktu awal, yang dipespesifikasikan pada range sampel peramalan. Untuk menjelaskan perbedaan antara metode dinamik dan *static*, akan digunakan contoh sederhana berikut ini.

Andaikan dimiliki model $Y_t = aY_{t-1} + X_t$ dengan Y menunjukkan variabel dependen dalam model, sedangkan X adalah variabel independen. Andaikan dimiliki data $X_1, X_2, \dots, X_n, X_{n-1}, \dots, X_{n+k}$ dan Y_1, Y_2, \dots, Y_n dan ingin melakukan peramalan data $Y_{n+1}, Y_{n+2}, \dots, Y_{n+k}$, $k \geq 2$ dan dipespesifikasikan rentang sampel untuk peramalan sebagai $s, \dots, n + k$, dengan $s \geq n + 1$. Dengan menggunakan metode *statik*, maka untuk setiap waktu $s, \dots, n + k$ akan dilakukan peramalan atau perhitungan nilai Y satu langkah ke depan, sampai waktu ke $n + 1$ yang akan dihitung sebagai $\hat{Y}_{k+1} = aY_k + X_{k+1}$, $k = s, \dots, n$. Sedangkan untuk metode *dinamik*, untuk perhitungan nilai \hat{Y}_{s+1} akan digunakan nilai sesungguhnya dari nilai Y_s , yakni dihitung menggunakan persamaan $\hat{Y}_{s+1} = aY_s + X_{s+1}$. Sedangkan untuk periode selanjutnya perhitungan nilai \hat{Y}_k , $k = s + 2, \dots, n + k$ akan menggunakan nilai peramalan untuk Y yang

diperoleh dari langkah sebelumnya, menggunakan rumus $\hat{Y}_{k+1} = a\hat{Y}_k + X_{k+1}, k = s + 1, \dots, n + k - 1$.

Dengan memperhatikan penjelasan diatas, dapat disimpulkan bahwa metode static forecasting merupakan metode yang baik untuk melakukan fitting model (menghitung variabel dependen menggunakan estimator dari parameter data-data yang bersesuaian) dan forecasting satu langkah kedepan (dari data terakhir yang dimiliki) dengan cara menspesifikasikan rentang indeks waktu dari forecasting sebagai $1, \dots, n + 1$. Sedangkan metode dynamic forecasting adalah baik untuk melakukan forecasting k langkah kedepan, $k \geq 1$, dengan cara menspesifikasikan rentang indeks waktu dari forecasting sebagai $n + 1, \dots, n + k$.

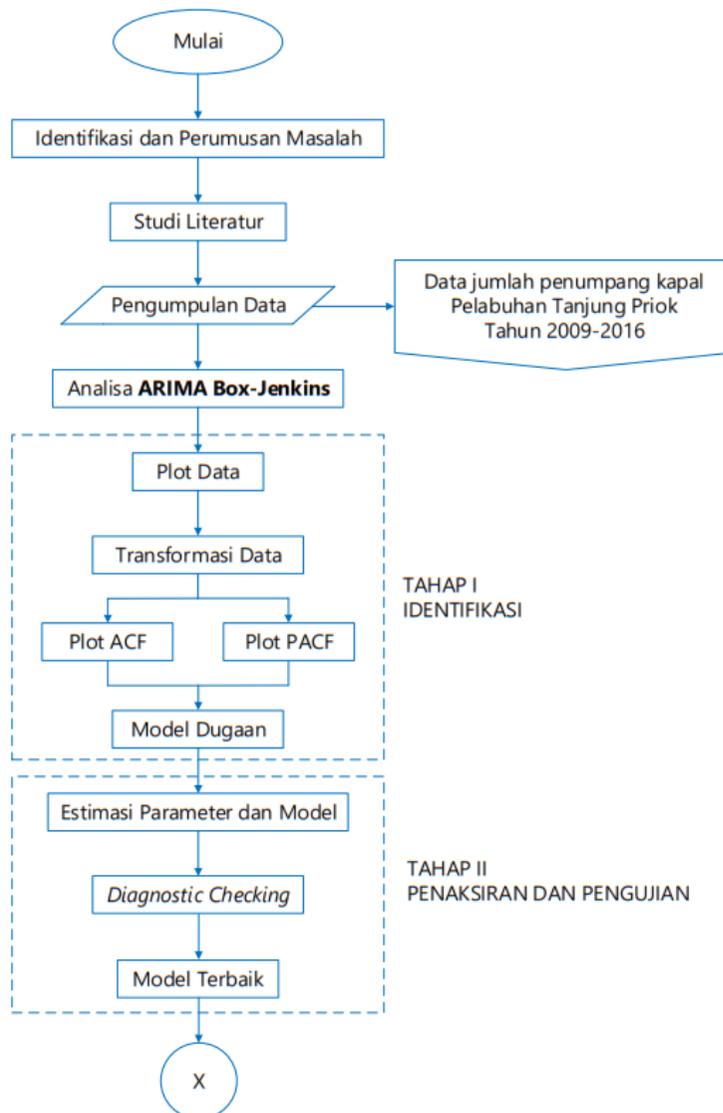


BAB III
METODOLOGI

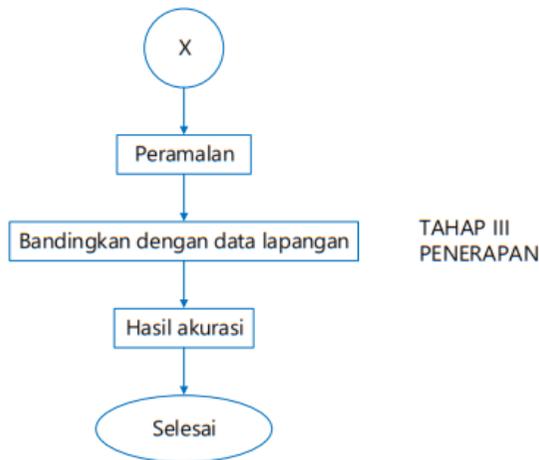
BAB III METODOLOGI

3.1. *Flowchart* Pengerjaan Skripsi

Metode penelitian mendeskripsikan rencana yang tersusun dalam suatu diagram alir mengenai langkah-langkah yang dilakukan dalam pengerjaan suatu penelitian. Untuk tahapan pengerjaan penelitian ini dapat dilihat pada diagram alir seperti yang ditunjukkan **Gambar 3.1** berikut ini.



Gambar 3. 1 Diagram Air Pengerjaan Skripsi



Gambar 3. 2 Diagram Air Pengerjaan Skripsi Lanjutan

3.2. Deskripsi *Flowchart*

3.2.1. Identifikasi dan Perumusan Masalah

Pada tahap ini dilakukan identifikasi serta perumusan permasalahan yang menjadi konsentrasi dalam pengerjaan tugas akhir ini. Seperti halnya yang telah dijelaskan pada bagian latar belakang, permasalahan yang diangkat yaitu menurunnya jumlah penumpang kapal dari tahun ke tahun, khususnya jumlah keberangkatan penumpang dari Pelabuhan Tanjung Priok. Tren penurunan tersebut disinyalir telah berlangsung dari 1 dekade kebelakang sehingga perusahaan BUMN maupun swasta yang bekecimpung dalam industri ini mengalami kerugian.

Pada **Tabel 1.1.** di bagian latar belakang, menunjukkan penurunan sebesar 12,88% terjadi pada periode bulan Januari-Oktober tahun 2012. Tren ini dapat diketahui dari data masa lampau yang diplot dalam sebuah grafik. Untuk mengetahui tren jumlah penumpang keberangkatan dari Pelabuhan Tanjung Priok dilakukan sejumlah peramalan atau prakiraan. Peramalan atau prakiraan ini akan berujung pada hasil ramalan berupa jumlah penumpang di masa yang akan datang yang dalam hal ini ditentukan untuk periode tahun 2016. Peramalan dilakukan menggunakan metode ARIMA Box-Jenkins, yaitu peramalan berdasarkan data runtun waktu (*time series*). Metode ini menggunakan data masa lalu untuk membuat model peramalan di masa yang akan datang. Dalam metode ini ada beberapa perumusan atau pemodelan dengan lebih jelasnya dapat dilihat pada bagian kajian pustaka.

Untuk membuat peramalan dengan metode ARIMA Box-Jenkins maka dibantu dengan software statistik EViews 9. Hasil akhir dari pemodelan ini yang nantinya akan menghasilkan pemodelan terbaik akan dibandingkan dengan data di lapangan (mengacu pada data Jakarta Utara Dalam Angka tahun 2017).

3.2.2. Studi Literatur

Tahapan selanjutnya adalah melakukan studi literature dengan tujuan untuk merangkum teori-teori dasar, acuan pengerjaan dan penggunaan metode peramalan serta memperoleh informasi tambahan sebagai pendukung dalam pengerjaan tugas akhir ini.

Pada penelitian ini, dilakukan studi literatur mengenai metode peramalan ARIMA Box-Jenkins dari beberapa buku teks, jurnal serta *paper* yang menaruh perhatian pada penggunaan metode ini. Studi literature ini lebih jelasnya dapat dilihat pada bagian tinjauan pustaka pada bab 2 sebelumnya. Beberapa informasi pendukung sebagai landasan sebab pengerjaan tugas akhir ini juga diperoleh dari artikel, buku teks serta website.

3.2.3. Pengumpulan Data

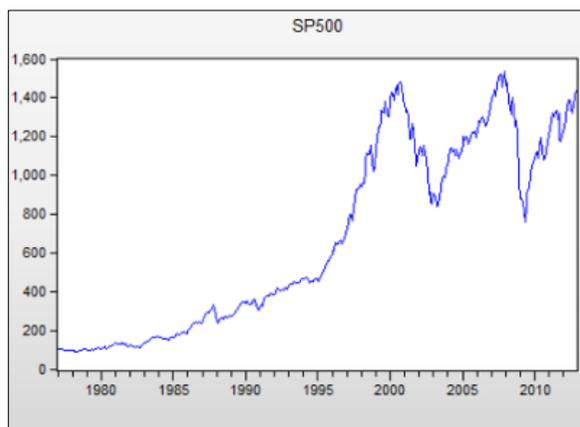
Data yang digunakan dalam tugas akhir ini meliputi data kuantitatif yang diambil dari data Jakarta Utara Dalam Angka (JUDA) yang merupakan publikasi tahunan yang diterbitkan secara berkala oleh Badan Pusat Statistik Jakarta Utara. JUDA ini dimaksudkan untuk memberikan gambaran tentang perkembangan Kota Jakarta Utara secara umum yang meliputi keadaan geografi, pemerintahan, penduduk dan tenaga kerja, social, pertanian, industri, perhubungan dan perhotelan, keuangan dan harga-harga serta pendapatan regional. Data yang diambil untuk tugas akhir ini adalah jumlah penumpang kapal dari Pelabuhan Tanjung Priok dari kurun waktu 2009 hingga 2016.

3.2.4. Tahap Identifikasi

Tahap identifikasi merupakan tahap awal dalam analisa ARIMA Box-Jenkins. Pada tahap ini data yang akan diolah diidentifikasi karakteristiknya, sehingga sesuai untuk peramalan jenis ini. Langkah-langkah dalam tahap ini akan dijelaskan pada paparan berikut ini.

3.2.4.1. Plot Data

Plot data dilakukan untuk mengetahui apakah data memiliki tren atau kecenderungan sebagai data musiman yang akan berlanjut pada analisa berikutnya. Plot data dilakukan dengan menginput data jumlah penumpang kapal Pelabuhan Tanjung Priok pada tahun 2009 hingga 2015 ke dalam workfile yang selanjutnya dinamai dengan *arima.wf1*. Tampilan yang dihasilkan yaitu dalam bentuk *spreadsheet*. Dari jendela yang aktif, maka klik *View* dan pilih *Line graph*. Jika terdapat unsur musiman dari plot data yang dihasilkan maka dibutuhkan transformasi data berupa diferensi.



Gambar 3. 3 Contoh hasil plot data pada EViews

3.2.4.2. Transformasi Data

Data yang dipakai dalam penelitian ini adalah data jumlah penumpang kapal dari Pelabuhan Tanjung Priok periode 2009 hingga 2015 yang cenderung memiliki unsur musiman. Sebelumnya telah dijelaskan bahwa syarat sebuah data dapat dimodelkan dengan metode ARIMA Box-Jenkins maka haruslah stasioner terhadap varians dan mean. Sebelumnya, series utama yang dioperasikan adalah percobaan1. Untuk itulah akan digunakan diferensi musiman terhadap data $\log(\text{percobaan1})$. Untuk melakukan diferensi terhadap data, dari jendela data percobaan1, klik tombol *Genr*. Akan muncul jendela dialog *Generate Equation*. Setelahnya melakukan diferensi *seasonal*. Dikarenakan data percobaan1 adalah data bulanan maka dapat digunakan diferensi *seasonal* orde $s=12$. Oleh sebab itu ke dalam dialog *Enter Equation* isikan :

$dslogpercobaan1 = dlog(percobaan1, 0, 12)$ dan kemudian klik OK. Pada jendela file kerja *arima.wf1* akan muncul obyek baru bernama *dslog1percobaan1*. Aktifkan series *dslog1percobaan1*, kemudian pilih menu View/Line graph dari data ini. Hasil plot data merupakan hasil diferensi dari data pada percobaan1.

Diferensi yang telah dilakukan di sini hanya untuk menghilangkan efek musiman. Selanjutnya, dengan menggunakan tombol *Genr*, buat data series baru pada file kerja *arima.wf1* dengan nama *dslog2percobaan1* menggunakan transformasi diferensi non-musiman orde 1 terhadap $\log(percobaan1)$, yakni pada dialog *Enter Equation* pada jendela *Generate Equation* gunakan persamaan:

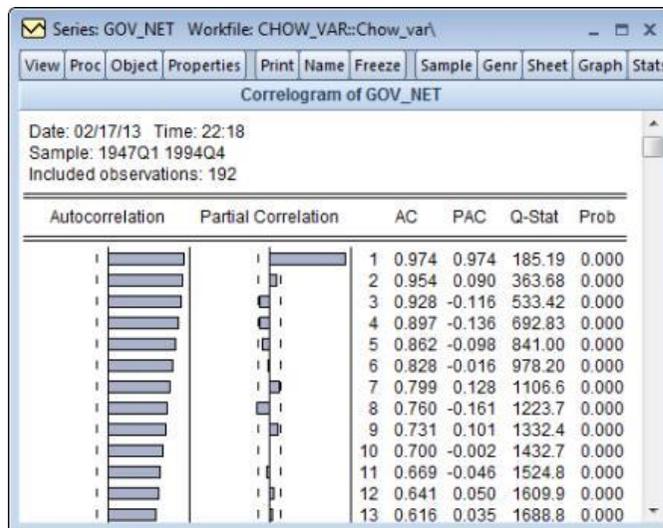
$$dslog2percobaan1 = dlog(percobaan1)$$

Selanjutnya, sorot kedua objek *dslog2percobaan1* dan *dslog1percobaan1*. Kemudian klik mouse kanan, dan pilih *Open/As Group* maka akan dibuka obyek group bernama *UNTITLED* berisikan dua kolom data *dslog2percobaan1* dan *dslog1percobaan1*. Bandingkan hasil plot kedua series, khususnya pola *seasonal* yang mengindikasikan variasi yang lebih besar. Gunakan series yang lebih lemah pola *seasonal*nya.

3.2.4.3. Plot ACF dan PACF

Plot Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF) digunakan untuk melihat stasioneritas data serta menentukan unsur AR dan MA dalam membuat model dugaan nantinya. Untuk itu, langkah yang dilakukan yaitu mengaktifkan obyek percobaan1. Selanjutnya, pada jendela obyek percobaan1, klik tombol menu View/Correlogram. Pada dialog yang muncul, pilih Correlogram of Level, dan gunakan banyaknya lag default sebesar 48. Klik OK. Pada jendela obyek percobaan1 diperoleh plot dan nilai ACF dan PACF dari lag 1 sampai lag 48. Contoh hasil plot ACF dan PACF dapat dilihat pada **Gambar 3.4** di bawah ini. Dengan langkah yang sama, dapatkan plot ACF dan PACF untuk *dslog1percobaan1*.

Langkah selanjutnya yaitu identifikasi pola ACF dan PACF dari *dslog1percobaan1*. Stasioneritas dalam mean dapat dilihat pada pola ACF, jika pola ACF menurun perlahan maka hal tersebut dapat menjadi indikasi bahwa data belum stasioner terhadap mean sehingga membutuhkan diferensi kembali.



Gambar 3. 4 Contoh hasil plot ACF dan PACF

Series terakhir yang telah stasioner, dibuat plot ACF dan PACF untuk mendapatkan model dugaan.

3.2.5. Tahap Penaksiran dan Pengujian

Untuk mengestimasi parameter-parameter dari model dugaan dapat dilakukan dengan langkah-langkah sebagai berikut. Aktifkan menu Quick/Estimate Equation yang merupakan menu utama dari EViews. Di sini, untuk mengestimasi parameter dari model digunakan metode Least square. Bentuk persamaan dari model yang akan diestimasi dapat dituliskan dalam kolom dialog Equation Specification. Untuk menyatakan persamaan untuk komponen model musiman perkalian dalam komponen moving average dapat digunakan perintah $sma(Q)$, dengan Q menyatakan harga lag, sedangkan untuk komponen model musiman perkalian dalam komponen *autoregressive* dapat menggunakan perintah $sar(P)$, dengan P menyatakan harga lag.

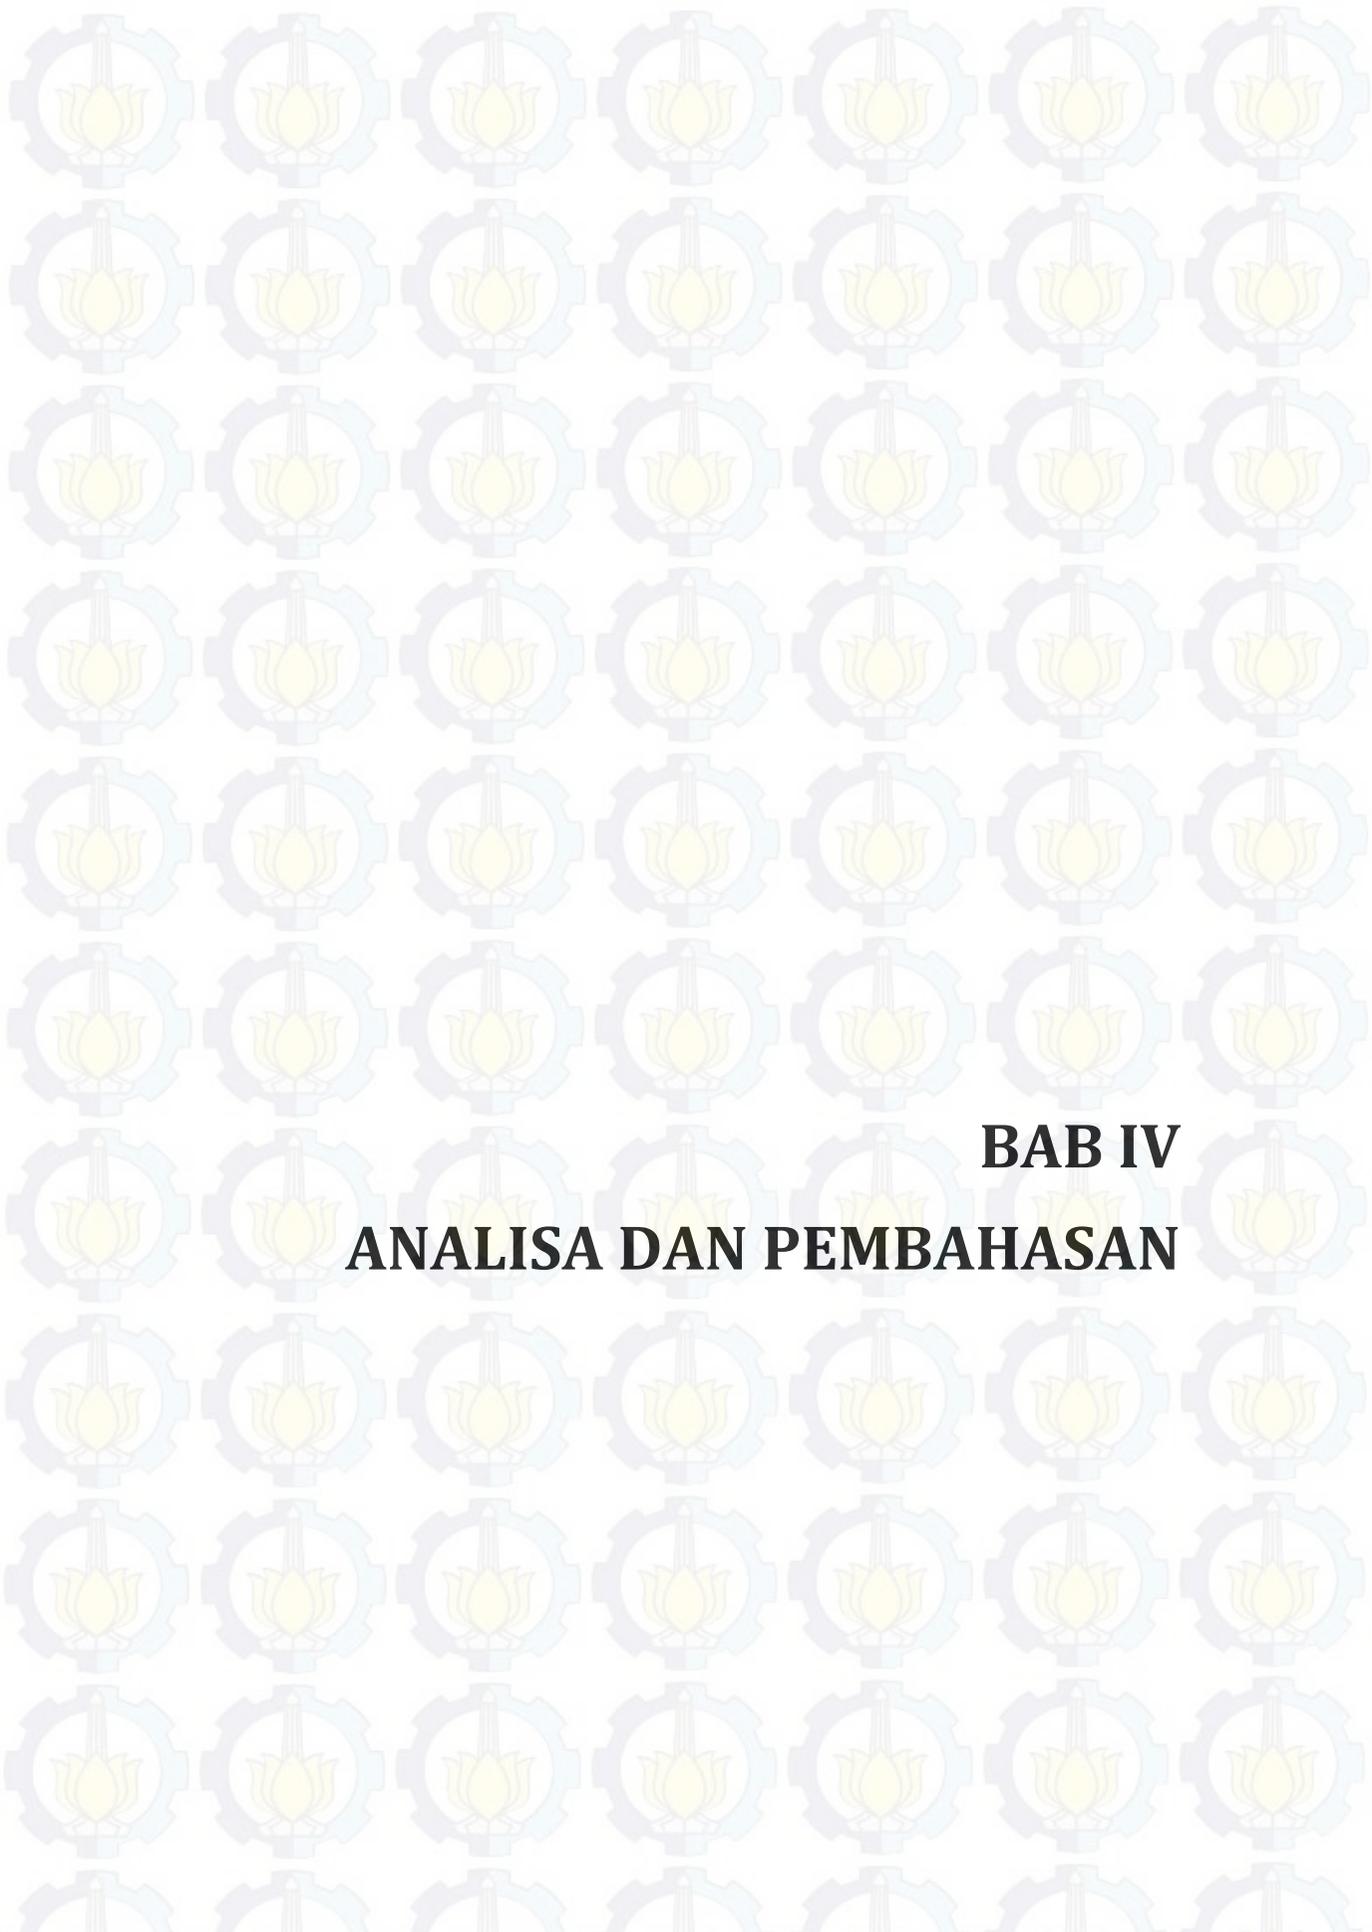
Setelah penaksiran parameter, kemudian melakukan *diagnostic checking*, selain menggunakan kriteria uji t (atau uji z) untuk parameter/koefisien dari model, maka analisa lain yang dilakukan adalah dengan melakukan uji Q-Ljung-Box dan plot ACF/PACF untuk melihat apakah terdapat korelasi serial dalam residual dari hasil estimasi dengan model yang diamati. Jika untuk menghitung harga statistic Q dan ACF/PACF di atas untuk model 1, maka langkah yang harus dilakukan adalah

- Aktifkan obyek Equation bernama Model1 yang menunjukkan hasil estimasi dari model 1. Dari jendela obyek *Equation* ini, aktifkan tombol menu View/Residual test/Correlogram Q Statistics.
- Pada jendela dialog *Lag Specification* yang muncul, isikan banyaknya lag yang diperlukan dalam test residual hasil estimasi model 4. Gunakan nilai lag = 48.
- Klik OK, maka pada jendela *equation* Model 1 akan tampil harga-harga statistic Q dan ACF dan PACF pada sejumlah lag untuk residual hasil estimasi dengan Model 1 tersebut.

3.2.6. Tahap Penerapan

Kemudian untuk mendapatkan hasil peramalan 12 bulan ke depan dari data terakhir yang tersedia (yakni data pada bulan Desember 2015), aktifkan kembali jendela Forecast. Kemudian, pilih metode dynamic, dan ubah range sample menjadi 2015:12 sampai 2016:12, yakni nilai rentang waktu dari peramalan yang akan dilakukan.

Halaman ini sengaja dikosongkan



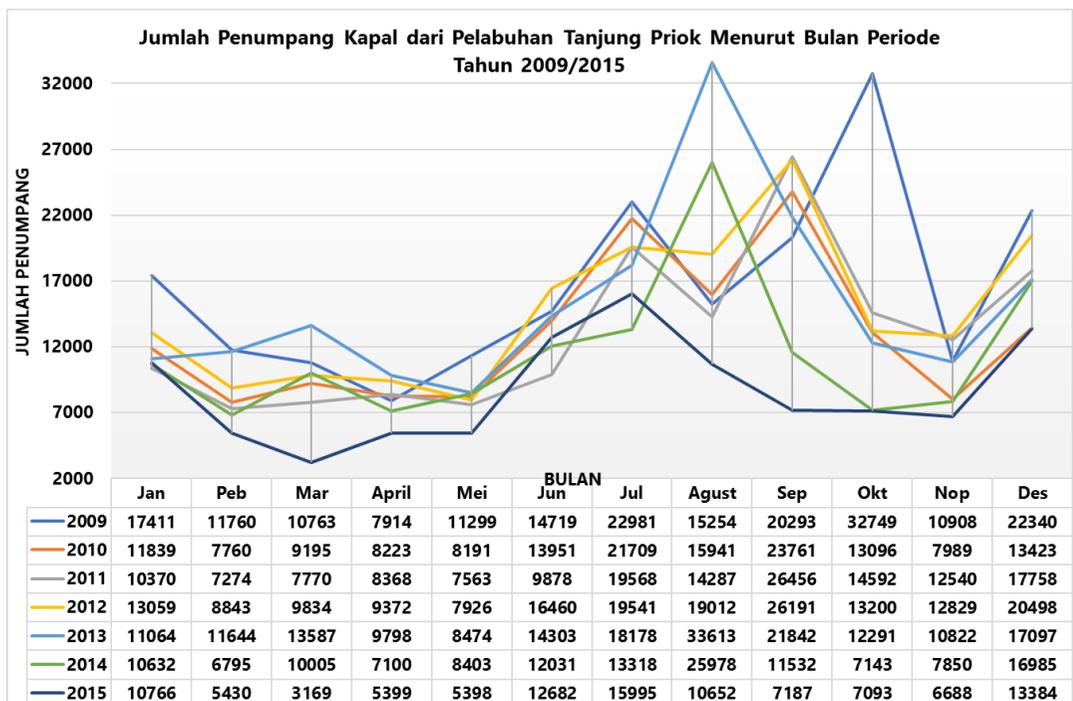
BAB IV
ANALISA DAN PEMBAHASAN

BAB IV ANALISA DAN PEMBAHASAN

Pada bab analisa dan pembahasan ini dilakukan sebagai proses awal hingga akhir khususnya dalam meramalkan jumlah penumpang kapal dari pelabuhan Tanjung Priok untuk periode tahun 2016 (12 bulan ke depan). Pada penelitian ini, seperti yang disebutkan sebelumnya menggunakan data dari Jakarta Utara dalam Angka periode 2009 hingga 2015. Data yang dimaksud adalah berdasarkan dari data PT. Pelni.

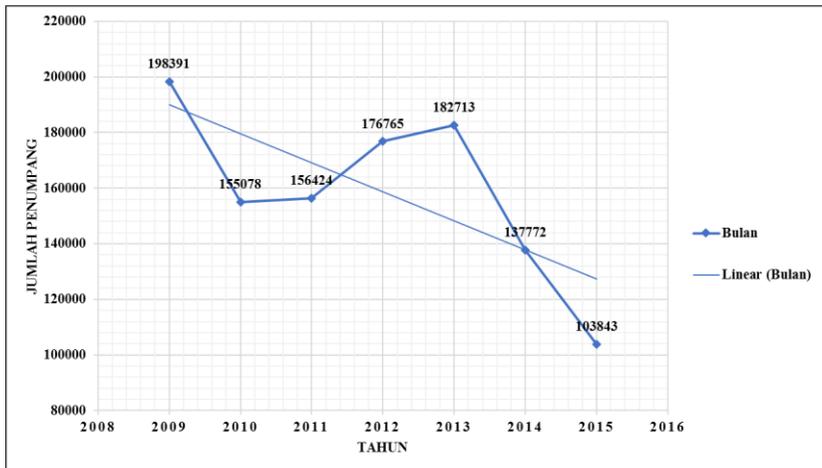
4.1. Persiapan Data

Data yang digunakan yaitu Jakarta Utara dalam Angka periode 2009 sampai 2015. Terdapat perbedaan *layout* untuk data jumlah penumpang kapal pada periode 2009 jika dibandingkan dengan data pada tahun-tahun berikutnya. Pada tahun 2009, tabel data berada pada sub bab 8.9 sedangkan pada tahun-tahun berikutnya menjadi sub bab 8.1.9. Berikut **Gambar 4.1** mencakup data jumlah penumpang kapal dari Pelabuhan Tanjung Priok berdasarkan bulan untuk tahun 2009 hingga 2015.



Gambar 4. 1 Data Jumlah Penumpang Kapal tahun 2009-2015

Berdasarkan data diatas, dapat dikatakan bahwa terjadi tren turun untuk jumlah penumpang kapal dari tahun ke tahun. Untuk lebih jelasnya dapat dilihat pada **Gambar 4.2** berikut ini.



Gambar 4. 2 Tren Jumlah Penumpang Kapal tahun 2009-2015

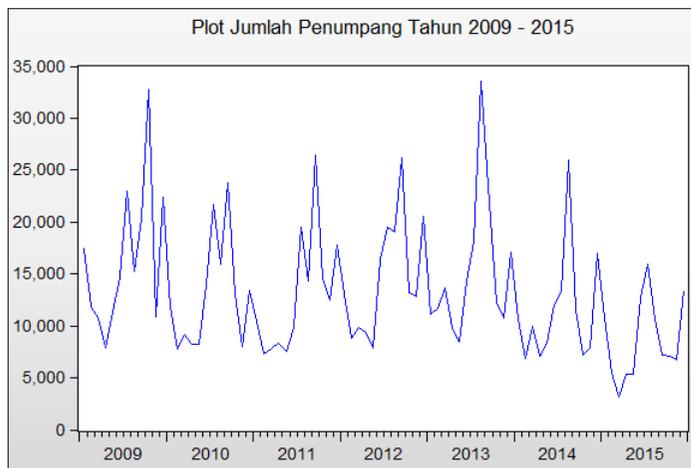
Secara umum, berdasarkan gambar 4.2. terjadi tren turun dari tahun 2009 hingga 2015, meskipun terdapat peningkatan pada tahun 2012 dan 2013 namun di tahun berikutnya yaitu tahun 2014 menurun sebesar 44.941 dibandingkan tahun 2013. Langkah-langkah dalam meramalkan jumlah penumpang berdasarkan data time series yang telah disebutkan diatas terdiri dari tiga tahap seperti yang telah dijelaskan pada bab metodologi penelitian. Lebih lanjut akan dijelaskan pada sub-sub bab berikutnya.

4.2. Tahap Identifikasi

Tahapan ini meliputi identifikasi data dengan maksud menstasionerkan data. Syarat data dapat dikatakan stasioner adalah jika data tersebut telah stasioner terhadap mean dan varian. Beberapa tahapan berikut akan menjelaskan hasil operasi pada Eviews 9.

4.2.1. Plot Data

Tahap identifikasi diawali dengan plot data untuk mengetahui tren data, apakah data bersifat non musiman atau musiman. Plot data berdasarkan data jumlah penumpang kapal pelabuhan Tanjung Priok tahun 2009 hingga 2015, untuk lebih lengkapnya, data jumlah penumpang kapal dapat dilihat pada Lampiran 1 **Tabel A.1**. Berikut hasil plot data dapat dilihat pada **Gambar 4.3**. di bawah ini.

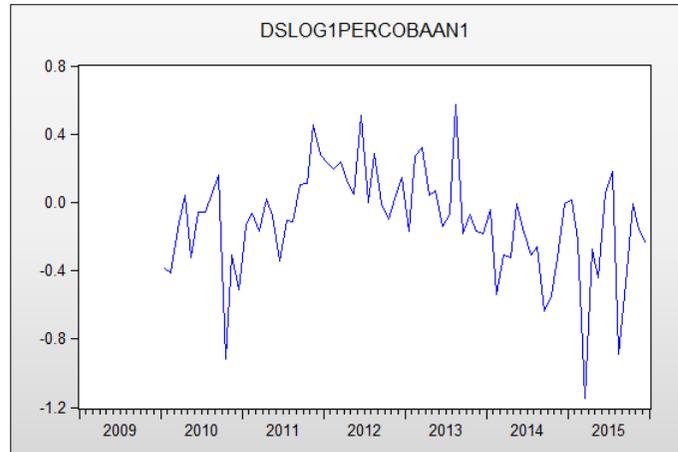


Gambar 4. 3 Plot Data Jumlah Penumpang Kapal tahun 2009-2015 (series utama percobaan1)

Hasil plot data diatas menunjukkan adanya pola berulang pada data runtun waktu. Hal ini mengindikasikan adanya unsur musiman pada data tersebut. Pada analisa selanjutnya, asumsi stasioneritas terhadap varian dan means diperlukan karena keduanya merupakan syarat utama peramalan dalam metode ARIMA ini. Metode ARIMA yang dipakai yaitu SARIMA atau Seasonal ARIMA dengan indikator P untuk *seasonal autoregressive* (SAR) dan Q untuk *seasonal moving average* (SMA) dan indikator AR dan MA yang non-musiman seperti p dan q masing-masing untuk AR dan MA serta indikator d untuk diferensi data

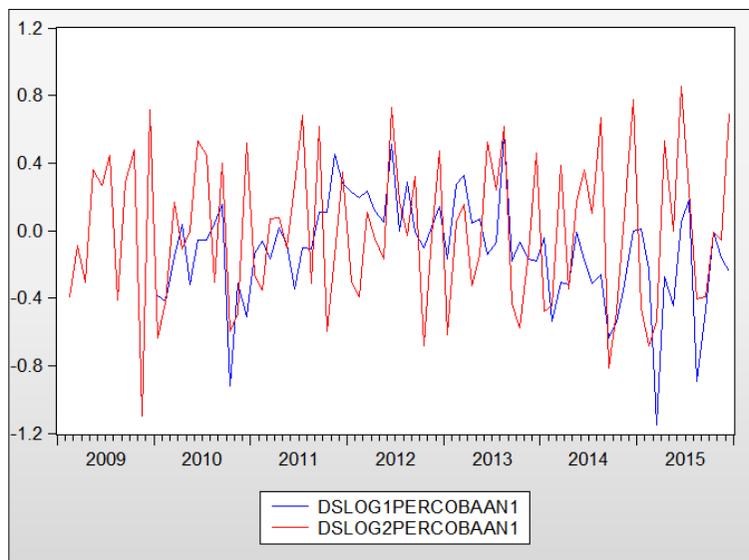
4.2.2. Transformasi Data

Telah dikatakan sebelumnya, syarat stasioneritas data adalah stasioner terhadap varians dan mean. Keduanya dapat dilakukan dengan membuat plot Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF). Pada plot data yang digambarkan pada Gambar 4.3. diatas, terdapat tren menurun serta unsur musiman dalam plot data. Oleh karena itu, sebelum data diplotkan dalam plot ACF dan PACF, maka sebelumnya perlu dilakukan transformasi musiman dari data series utama percobaan1 dengan cara diferensi musiman menghasilkan series baru dslog1percobaan1. Hasil plot diferensi musiman data series dslog1pcobaan1 digambarkan pada **Gambar 4. 4** berikut ini.



Gambar 4. 4 Plot Data Series dslog1percobaan1

Setelah transformasi data berupa diferensi musiman pada data, maka dilakukan transformasi non-musiman orde 1 terhadap data dslog1percobaan1 menghasilkan dslog2percobaan1.

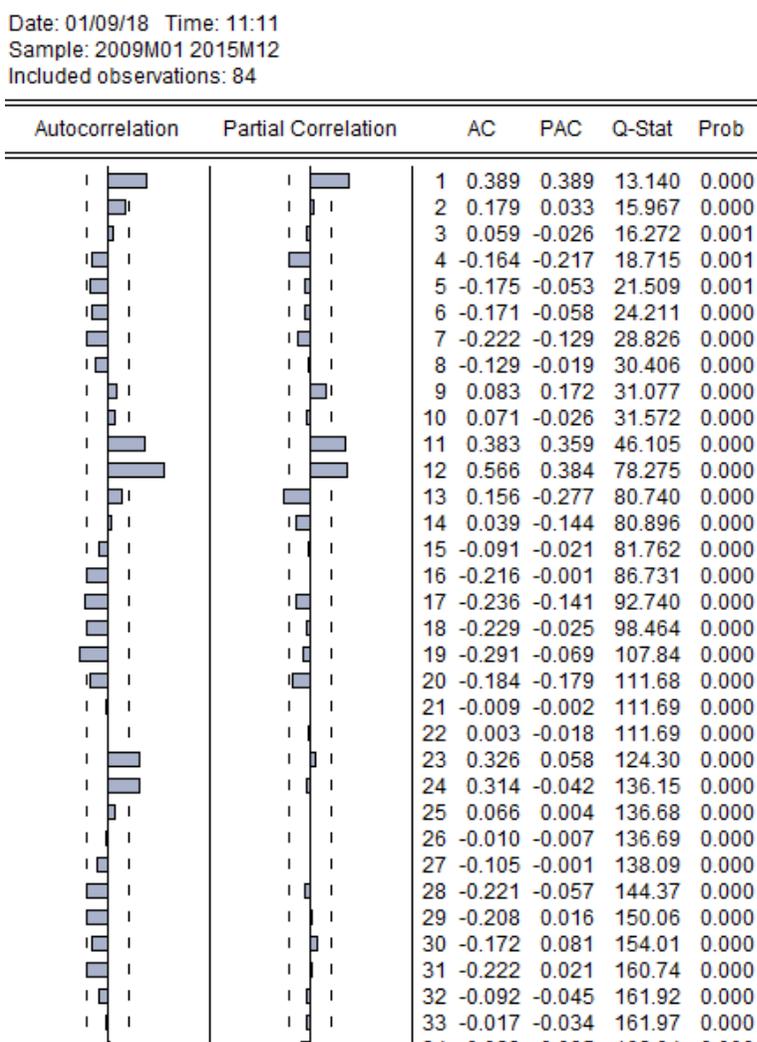


Gambar 4. 5 Plot Data Series dslog1percobaan1 dan dslog2percobaan1 dalam satu grup

Pada gambar diatas, masih terlihat bahwa terdapat pola musiman yang kuat pada dslog2percobaan1 dengan variansi yang lebih besar daripada dslog1percobaan1. Mempertimbangkan hal tersebut, maka untuk langkah selanjutnya akan menggunakan dslog1percobaan1.

4.2.3. Plot ACF dan PACF

Dalam memplotkan ACF dan PACF, series yang digunakan yaitu percobaan1 dan dslog1percobaan1. Menggunakan submenu correlogram pada tab View dan mengisi lag default sebesar 36, hasil plot ACF dan PACF untuk series percobaan1 dapat dilihat pada **Gambar 4.6** dibawah ini.

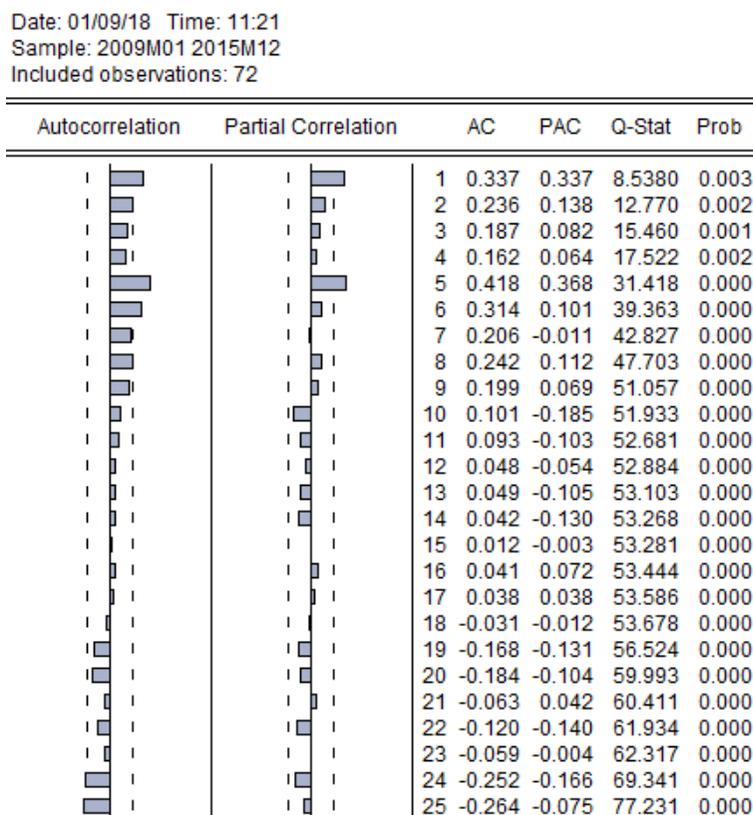


Gambar 4. 6 Plot ACF dan PACF dari series percobaan1

Hasil plot ACF dan PACF untuk series percobaan1 dapat dilihat pada Lampiran 1 **Tabel A.2**. Pada gambar diatas, tampak koefisien autokorelasi pada lag 12, 24 dan pengulangannya melebihi batas. Hal

ini biasa ditemui pada data yang memiliki pola musiman, dimana untuk data dengan periode s akan diperoleh puncak koefisien korelasi pada $2s$, $3s$ dan pengulangannya. Pada grafik, terlihat pula puncak lag musiman menurun secara perlahan, yang menunjukkan adanya keadaan non stasioner dalam mean.

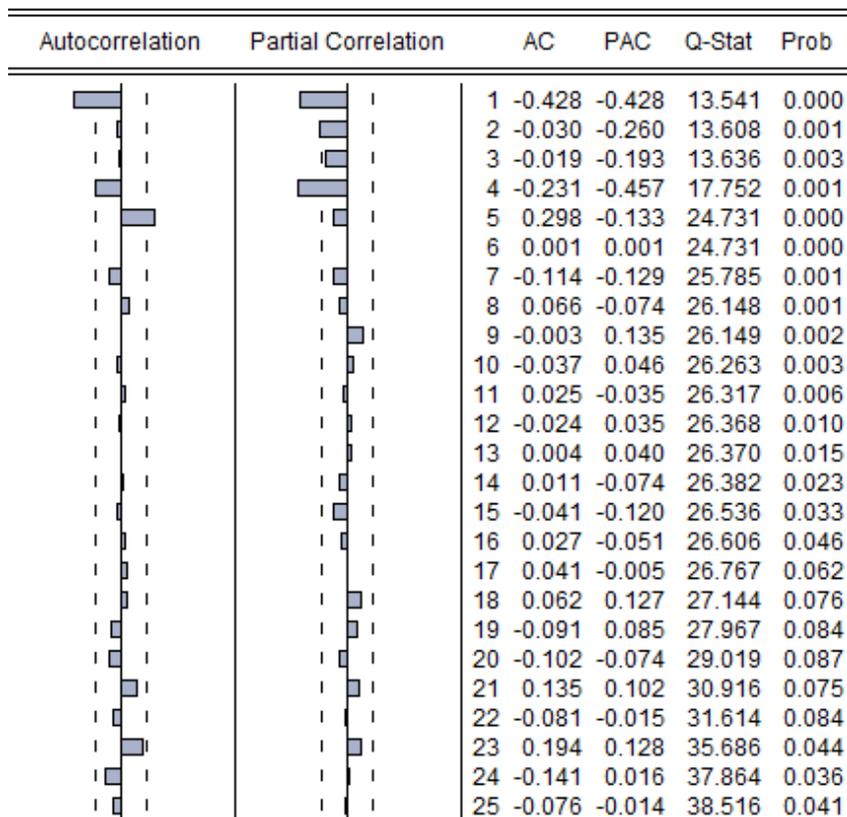
Berikutnya, yaitu hasil plot ACF dan PACF untuk series `dslog1percobaan1`. Dengan cara yang sama seperti sebelumnya, hasil plot ACF dan PACF untuk `dslog1percobaan1` dapat dilihat pada **Gambar 4.7** berikut ini.



Gambar 4. 7 Plot ACF dan PACF dari series `dslog1percobaan1`

Pada plot ACF dari series `dslog1percobaan1` menurun perlahan yang mengindikasikan bahwa data belum stasioner. Untuk itulah, perlu dilakukan diferensi terhadap data `dslog1percobaan1`. Series `difdslog1percobaan1` adalah hasil diferensi dari `dslog1percobaan1`. Hasil plot ACF dan PACFnya dapat dilihat pada **Gambar 4.8** berikut ini.

Date: 01/09/18 Time: 11:27
 Sample: 2009M01 2015M12
 Included observations: 71



Gambar 4. 8 Plot ACF dan PACF dari series difdslog1percobaan1

Pada plot ACF terdapat nilai yang melebihi batas interval pada lag 1, sementara PACF tampak meluruh cukupcepat menuju nol sehingga model dugaan yang sesuai dengan data difdslog1percobaan1 ini adalah MA (1). Jika diamati lebih jauh, maka pada lag 12 dan kelipatannya terdapat pola musiman yang mengindikasikan perlunya pola musiman dalam model dugaan. Sehingga model dugaan yang sesuai yaitu :

1. SAR (12), MA(1) atau ARIMA (0,1,1)(1,1,0)₁₂
2. MA(1), SMA(12) atau ARIMA (0,1,1)(0,1,1)₁₂
3. MA(1), MA(12)

4.3. Tahap Penaksiran dan Pengujian

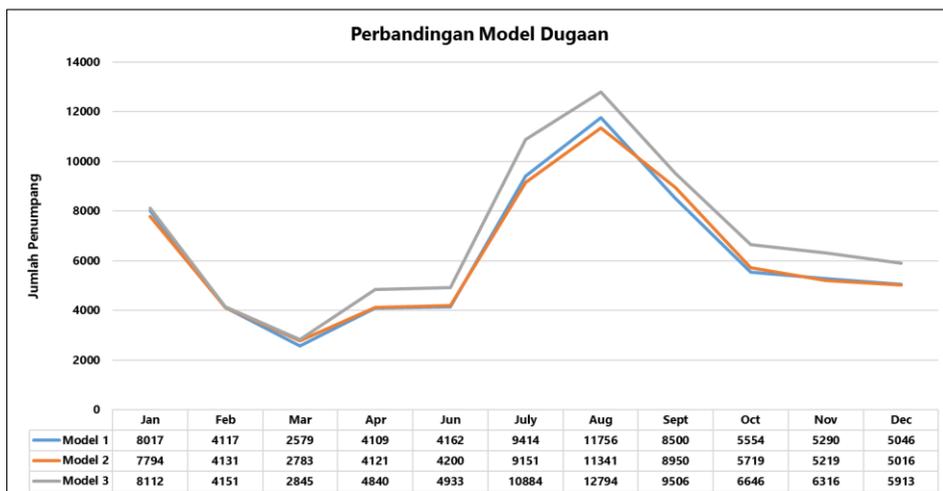
Dari ketiga model dugaan yang didapatkan sebelumnya, didapatkan hasil rangkuman yang dapat dilihat pada **Tabel 4.1** di bawah ini.

Tabel 4. 1 Hasil Rangkuman Semua Model Dugaan

| | Model 1 | Model 2 | Model 3 |
|--------|-----------|-----------|-----------|
| a12 | -0.076557 | -0.792248 | -0.841795 |
| | 0.7127 | 0.0000 | 0.0000 |
| b1 | -0.79407 | -0.162008 | -0.158205 |
| | 0.0000 | 0.4357 | 0.0025 |
| b12 | | 0.078799 | 0.076056 |
| | | 0.0000 | 0.0000 |
| SSR | 5.635076 | 5.594732 | 5.399959 |
| Q (12) | 0.303 | 0.253 | 0.339 |
| Q (24) | 0.527 | 0.504 | 0.454 |
| Q (48) | 0.85 | 0.843 | 0.736 |

Pada tabel diatas, ketiga model sesuai jika berdasarkan Q-Ljung Box dimana semua model sudah lebih dari 0,05 selang kepercayaan. Untuk mendapatkan model terbaik, maka indikator lainnya yaitu sum of square root (SSR) dengan dipilih nilai yang terkecil, sehingga model terbaik adalah model 3.

4.4. Tahap Penerapan



Gambar 4. 9 Hasil Forecast

Model 3 sebagai model terbaik digunakan sebagai dasar peramalan. Namun untuk memastikan bahwa model 3 adalah model terbaik, maka pada analisa ini akan dibuat pula peramalan menggunakan model 1 dan 2. Ketiga model akan dibandingkan hasil peramalannya untuk 12 bulan ke depan serta perbandingan grafis ketiganya dengan data asli jumlah penumpang kapal Pelabuhan Tanjung Priok tahun 2016. Dengan menggunakan sub menu forecast, maka didapatkan hasil seperti pada **Gambar 4.9** diatas sebagai perbandingan dari ketiga model dugaan. Untuk hasil lengkapnya, dapat dilihat pada Lampiran C.

Nilai-nilai hasil dari peramalan 12 bulan ke depan dapat dilihat pada **Tabel 4.2** berikut ini.

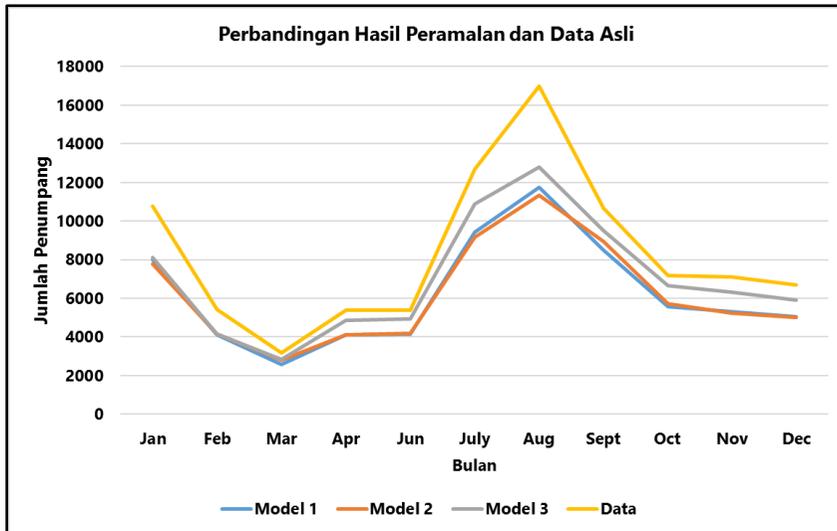
Tabel 4. 2 Hasil Peramalan 12 Bulan ke Depan

| Bulan | Model 1 | Model 2 | Model 3 |
|--------|---------|----------|---------|
| 16-Jan | 8017 | 7793.904 | 8112 |
| 16-Feb | 4117 | 4130.839 | 4151 |
| 16-Mar | 2579 | 2783.067 | 2845 |
| 16-Apr | 4109 | 4121.155 | 4840 |
| 16-May | 4162 | 4199.69 | 4933 |
| 16-Jun | 9414 | 9150.756 | 10884 |
| 16-Jul | 11756 | 11341.34 | 12794 |
| 16-Aug | 8500 | 8950.393 | 9506 |
| 16-Sep | 5554 | 5718.879 | 6646 |
| 16-Oct | 5290 | 5218.619 | 6316 |
| 16-Nov | 5046 | 5016.453 | 5913 |
| 16-Dec | 9655 | 9434.872 | 11782 |

4.5. Kecocokan dengan Data Asli dan Perhitungan Error

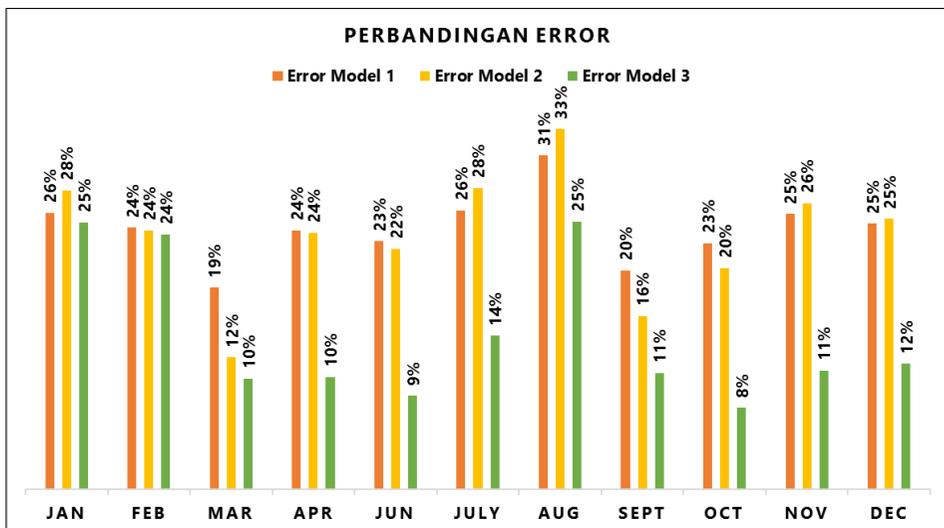
Langkah terakhir yaitu membandingkan kecocokan peramalan dengan data aslinya. Untuk lebih jelasnya, dapat dilihat perbandingannya pada **Gambar 4.10** berikut ini.

Dapat dilihat pada grafik bahwa hasil peramalan dengan model 3 sudah cukup menggambarkan keadaan data asli 2016 untuk jumlah penumpang kapal dari Pelabuhan Tanjung Priok. Untuk model 1 dan 2 berada dibawah model 3. Sehingga dapat dipastikan bahwa model 3 adalah model terbaik untuk meramalkan jumlah penumpang 12 bulan dalam tahun 2016.



Gambar 4. 10 Perbandingan Hasil Peramalan dan Data Asli

Perhitungan error diperlukan untuk mengetahui seberapa besar selisih antara data asli dengan ketiga perbandingan grafis, perhitungan error membantu memastikan model dugaan mana yang terbaik untuk meramalkan data jumlah penumpang kapal. Untuk Error terhitung dapat dilihat pada Lampiran D. Untuk perbandingan error masing-masing model dapat dilihat pada **Gambar 4.11** berikut ini.



Gambar 4. 11 Perbandingan Error

Pada **Gambar 4.11**, terlihat bahwa error terkecil dimiliki oleh model 3. Sehingga dengan perhitungan error dan perbandingan grafis dari ketiga model dapat dipastikan bahwa model 3 adalah model terbaik untuk menjadi dasar peramalan jumlah penumpang kapal tahun 2016

Untuk model 3, error terbesar terjadi pada bulan Januari, Februari, Agustus dan Desember. Keempat bulan tersebut mengindikasikan banyaknya jumlah penumpang yang tidak dapat diprediksi oleh peramalan ini. Hal ini terjadi karena adanya budaya pulang kampung untuk masyarakat Indonesia pada hari raya keagamaan, khususnya muslim. Serta adanya pergeseran bulan hijriyah setiap tahunnya sehingga dibutuhkan perhitungan lebih lanjut dengan memasukkan beberapa faktor yaitu kalender hijriyah dan hari besar keagamaan.

Halaman ini sengaja dikosongkan



BAB V
KESIMPULAN DAN SARAN

BAB V

KESIMPULAN DAN SARAN

5.1. Kesimpulan

Berdasarkan penelitian yang telah dilakukan maka dapat disimpulkan hasil dari peramalan jumlah penumpang kapal Pelabuhan Tanjung Priok adalah sebagai berikut:

1. Dari ketiga model dugaan, didapatkan bahwa model 3 adalah model terbaik dengan berdasarkan parameter Q-LjungBox dan SSR terkecil, tren model 3 telah mengikuti data asli.
2. Hasil peramalan yang didapatkan dari model 3 memberikan rata-rata error terkecil yakni 14% jika dibandingkan dengan model 1 dan 2 yang memiliki rata-rata error 24%. Error terbesar model 3 terjadi pada Januari, Februari, Agustus dan Desember yang mengindikasikan budaya masyarakat Indonesia pulang ke kampung halaman serta perayaan hari keagamaan.

5.2. Saran

Setelah melakukan penelitian, terdapat beberapa saran yakni:

1. Pemodelan dilakukan dengan data yang lebih banyak dalam artian memiliki jangka waktu yang panjang.
2. Dibutuhkan penelitian lebih lanjut terhadap faktor-faktor yang mempengaruhi jumlah penumpang kapal Pelabuhan Tanjung Priok, terutama untuk pergeseran kalender Hijriyah setiap tahunnya terhadap kalender Masehi sehingga dapat memperhitungkan peramalan yang lebih baik.

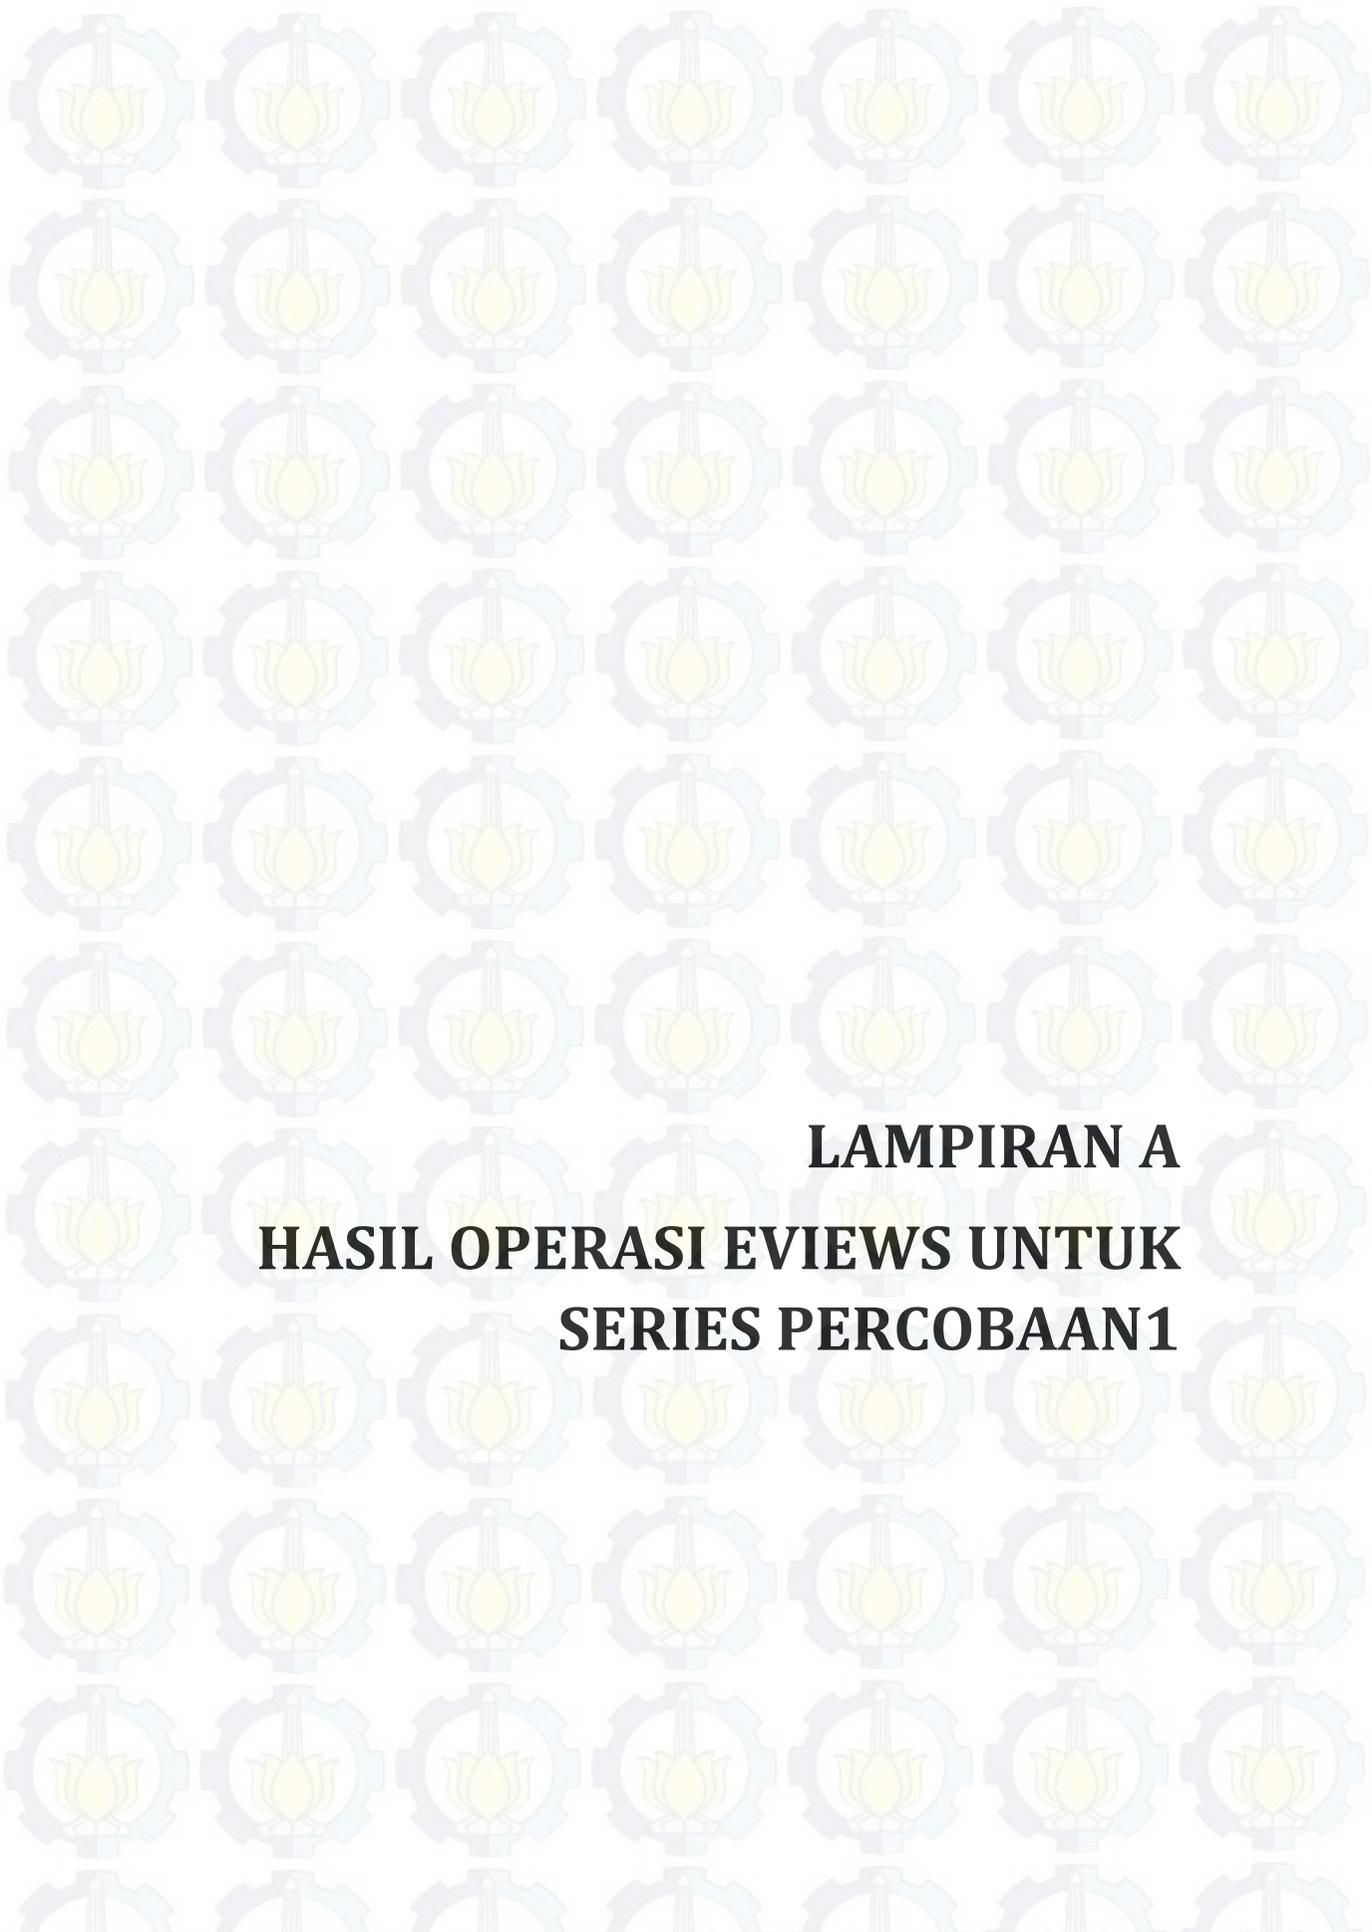
Halaman ini sengaja dikosongkan



DAFTAR PUSTAKA

DAFTAR PUSTAKA

- Box, J. R. (2008). *Time Series Analysis : Forecasting and Control* (4th ed.). Canada: John Wiley & Sons, Inc.
- Dr. Mahyus Ekananda, M. M. (2014). *Analisis Data Time Series*. Jakarta: Mitra Wacana Media.
- Dr. rer. nat. Dedi Rosadi, M. S. (2012). *Ekonometrika & Analisis Runtun Waktu Terapan dengan EViews*. Yogyakarta: Penerbit Andi.
- Frechtling, D. C. (2001). *Forecasting tourism demand: methods and strategies*.
Makridakis, S. S. (1999). *Metode dan Aplikasi Peramalan* (Edisi Kedua ed.). Jakarta: Penerbit Erlangga.
- Peter J. Brockwell, R. A. (2002). *Intoduction to Time Series and Forecasting* (2nd ed.). New York: Springer-Verlag, Inc.
- Robert A. Yaffee, M. M. (2000). *Introduction to Time Series Analysis and Forecasting : With Application of SAS and SPSS* (1st ed.). New York: Academic Press, Inc.



LAMPIRAN A
HASIL OPERASI EViews UNTUK
SERIES PERCOBAAN1

Lampiran A

Hasil Operasi EViews untuk series

PERCOBAAN1

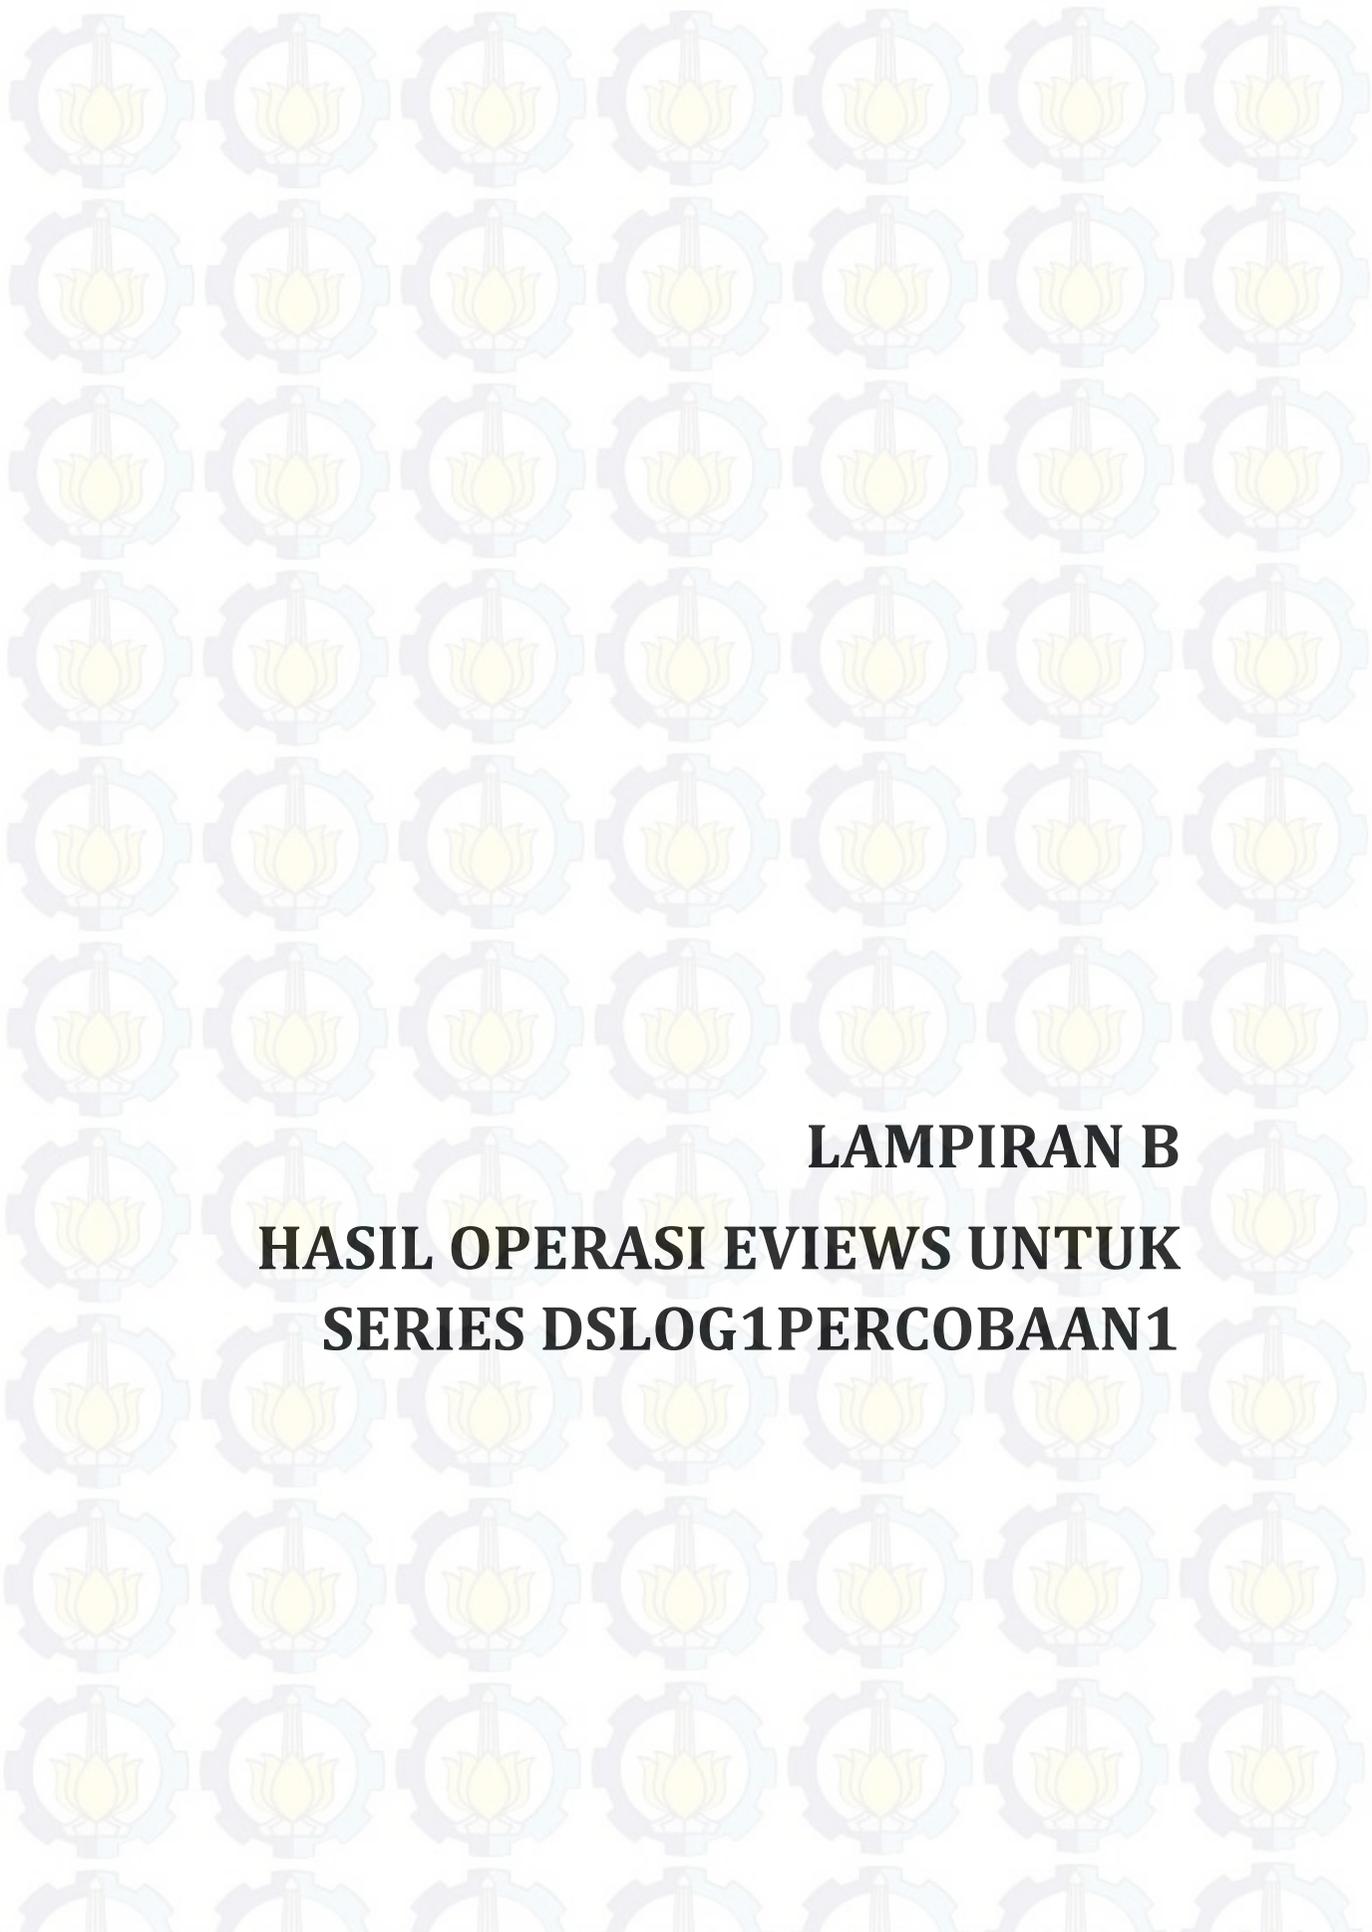
Tabel A. 1 Jumlah Penumpang Kapal dari Pelabuhan Tanjung Priok Menurut Bulan Periode Tahun 2009/2015

| Bulan | Tahun | | | | | | |
|------------------|--------|--------|--------|--------|--------|--------|--------|
| | 2009 | 2010 | 2011 | 2012 | 2013 | 2014 | 2015 |
| Januari | 17411 | 11839 | 10370 | 13059 | 11064 | 10632 | 10766 |
| Pebruari | 11760 | 7760 | 7274 | 8843 | 11644 | 6795 | 5430 |
| Maret | 10763 | 9195 | 7770 | 9834 | 13587 | 10005 | 3169 |
| April | 7914 | 8223 | 8368 | 9372 | 9798 | 7100 | 5399 |
| Mei | 11299 | 8191 | 7563 | 7926 | 8474 | 8403 | 5398 |
| Juni | 14719 | 13951 | 9878 | 16460 | 14303 | 12031 | 12682 |
| Juli | 22981 | 21709 | 19568 | 19541 | 18178 | 13318 | 15995 |
| Agustus | 15254 | 15941 | 14287 | 19012 | 33613 | 25978 | 10652 |
| September | 20293 | 23761 | 26456 | 26191 | 21842 | 11532 | 7187 |
| Oktober | 32749 | 13096 | 14592 | 13200 | 12291 | 7143 | 7093 |
| Nopember | 10908 | 7989 | 12540 | 12829 | 10822 | 7850 | 6688 |
| Desember | 22340 | 13423 | 17758 | 20498 | 17097 | 16985 | 13384 |
| Total | 198391 | 155078 | 156424 | 176765 | 182713 | 137772 | 103843 |

Tabel A. 2 Hasil Plot ACF dan PACF series PERCOBAAN1

| Date: 01/08/18 Time: 19:17 | | | | | | | |
|----------------------------|---------------------|----|--------|--------|--------|-------|--|
| Sample: 2009M01 2015M12 | | | | | | | |
| Included observations: 84 | | | | | | | |
| Autocorrelation | Partial Correlation | AC | PAC | Q-Stat | Prob | | |
| . *** | . *** | 1 | 0.389 | 0.389 | 13.140 | 0.000 | |
| . . | . . | 2 | 0.179 | 0.033 | 15.967 | 0.000 | |
| . . | . . | 3 | 0.059 | -0.026 | 16.272 | 0.001 | |
| .* . | ** . | 4 | -0.164 | -0.217 | 18.715 | 0.001 | |
| .* . | . . | 5 | -0.175 | -0.053 | 21.509 | 0.001 | |
| .* . | . . | 6 | -0.171 | -0.058 | 24.211 | 0.000 | |
| ** . | * . | 7 | -0.222 | -0.129 | 28.826 | 0.000 | |
| .* . | . . | 8 | -0.129 | -0.019 | 30.406 | 0.000 | |
| . . | . . | 9 | 0.083 | 0.172 | 31.077 | 0.000 | |
| . . | . . | 10 | 0.071 | -0.026 | 31.572 | 0.000 | |
| . *** | . *** | 11 | 0.383 | 0.359 | 46.105 | 0.000 | |
| . **** | . *** | 12 | 0.566 | 0.384 | 78.275 | 0.000 | |
| . . | ** . | 13 | 0.156 | -0.277 | 80.740 | 0.000 | |
| . . | * . | 14 | 0.039 | -0.144 | 80.896 | 0.000 | |
| .* . | . . | 15 | -0.091 | -0.021 | 81.762 | 0.000 | |
| ** . | . . | 16 | -0.216 | -0.001 | 86.731 | 0.000 | |
| ** . | * . | 17 | -0.236 | -0.141 | 92.740 | 0.000 | |
| ** . | . . | 18 | -0.229 | -0.025 | 98.464 | 0.000 | |
| ** . | * . | 19 | -0.291 | -0.069 | 107.84 | 0.000 | |

| | | | | | | | | | | |
|----|----|--|----|---|--|----|--------|--------|--------|-------|
| .* | . | | .* | . | | 20 | -0.184 | -0.179 | 111.68 | 0.000 |
| . | . | | . | . | | 21 | -0.009 | -0.002 | 111.69 | 0.000 |
| . | . | | . | . | | 22 | 0.003 | -0.018 | 111.69 | 0.000 |
| . | ** | | . | . | | 23 | 0.326 | 0.058 | 124.30 | 0.000 |
| . | ** | | . | . | | 24 | 0.314 | -0.042 | 136.15 | 0.000 |
| . | . | | . | . | | 25 | 0.066 | 0.004 | 136.68 | 0.000 |
| . | . | | . | . | | 26 | -0.010 | -0.007 | 136.69 | 0.000 |
| . | . | | . | . | | 27 | -0.105 | -0.001 | 138.09 | 0.000 |
| ** | . | | . | . | | 28 | -0.221 | -0.057 | 144.37 | 0.000 |
| ** | . | | . | . | | 29 | -0.208 | 0.016 | 150.06 | 0.000 |
| * | . | | . | * | | 30 | -0.172 | 0.081 | 154.01 | 0.000 |
| ** | . | | . | . | | 31 | -0.222 | 0.021 | 160.74 | 0.000 |
| * | . | | . | . | | 32 | -0.092 | -0.045 | 161.92 | 0.000 |
| . | . | | . | . | | 33 | -0.017 | -0.034 | 161.97 | 0.000 |
| . | . | | . | * | | 34 | 0.023 | -0.085 | 162.04 | 0.000 |
| . | ** | | . | . | | 35 | 0.293 | 0.027 | 174.67 | 0.000 |
| . | ** | | . | . | | 36 | 0.234 | 0.057 | 182.91 | 0.000 |
| . | * | | . | . | | 37 | 0.106 | 0.071 | 184.62 | 0.000 |
| . | . | | . | . | | 38 | 0.038 | -0.036 | 184.85 | 0.000 |
| . | . | | . | . | | 39 | -0.054 | -0.033 | 185.31 | 0.000 |
| * | . | | . | . | | 40 | -0.157 | -0.008 | 189.35 | 0.000 |
| * | . | | . | . | | 41 | -0.100 | 0.040 | 191.04 | 0.000 |
| * | . | | . | . | | 42 | -0.111 | -0.013 | 193.14 | 0.000 |
| * | . | | . | . | | 43 | -0.119 | 0.062 | 195.62 | 0.000 |
| . | . | | . | . | | 44 | 0.009 | 0.045 | 195.64 | 0.000 |
| . | . | | . | . | | 45 | 0.015 | 0.010 | 195.68 | 0.000 |
| . | * | | . | . | | 46 | 0.142 | 0.065 | 199.50 | 0.000 |
| . | ** | | . | * | | 47 | 0.218 | -0.144 | 208.76 | 0.000 |
| . | * | | . | * | | 48 | 0.151 | -0.077 | 213.35 | 0.000 |



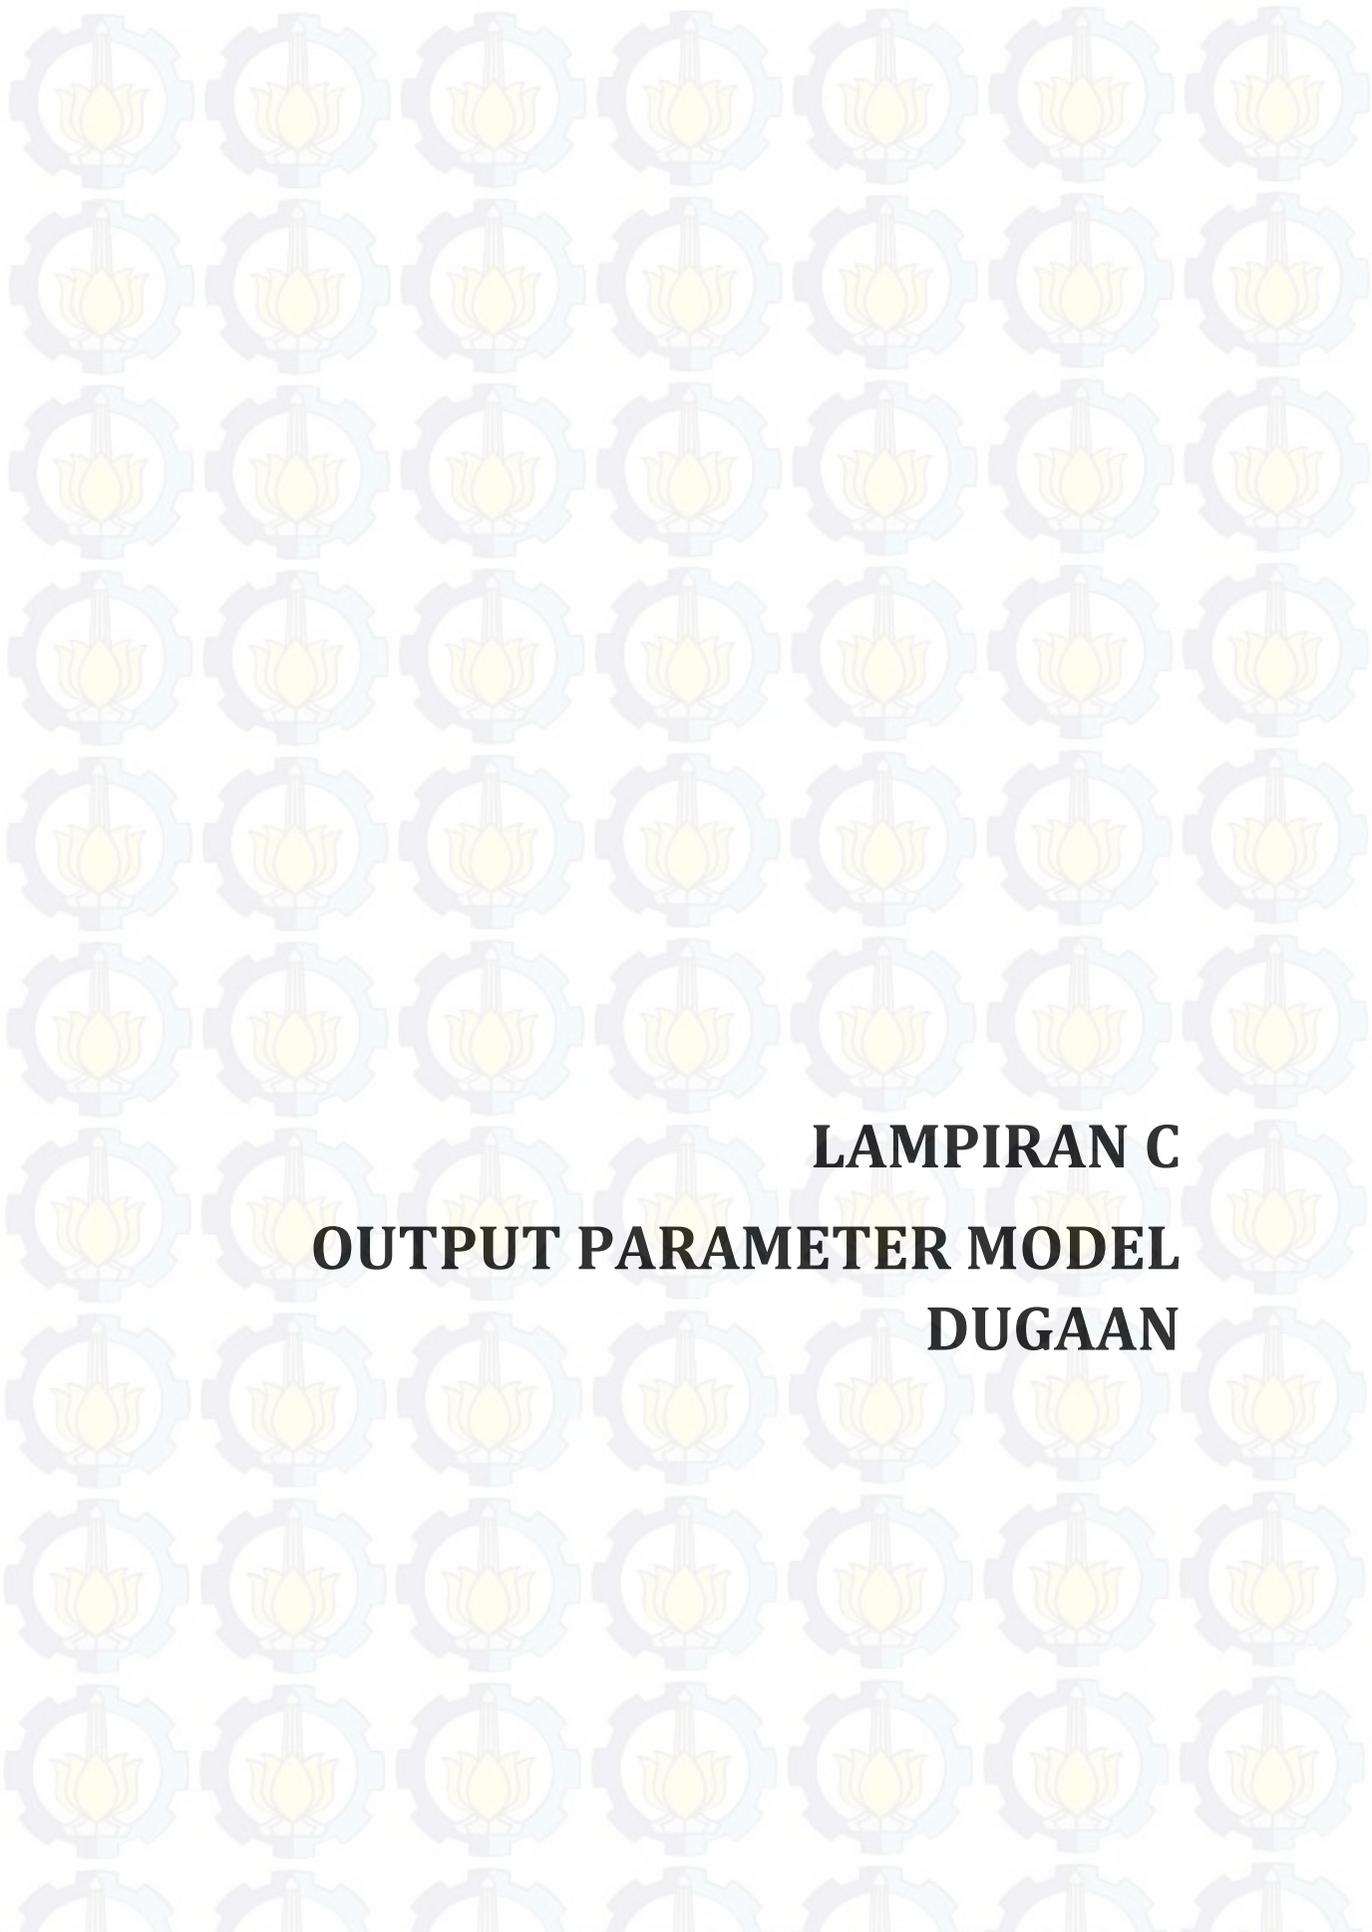
LAMPIRAN B
HASIL OPERASI EViews UNTUK
SERIES DSLOG1PERCOBAAN1

Lampiran B
Hasil Operasi EViews untuk series
DSLOG1PERCOBAAN1

Tabel B. 1 Hasil Plot ACF dan PACF series DSLOG1PERCOBAAN1

| Date: 01/08/18 Time: 19:29 | | | | | | |
|----------------------------|---------------------|----|--------|--------|--------|-------|
| Sample: 2009M01 2015M12 | | | | | | |
| Included observations: 72 | | | | | | |
| Autocorrelation | Partial Correlation | AC | PAC | Q-Stat | Prob | |
| . ** | . ** | 1 | 0.337 | 0.337 | 8.5380 | 0.003 |
| . ** | . * | 2 | 0.236 | 0.138 | 12.770 | 0.002 |
| . * | . * | 3 | 0.187 | 0.082 | 15.460 | 0.001 |
| . * | . . | 4 | 0.162 | 0.064 | 17.522 | 0.002 |
| . *** | . *** | 5 | 0.418 | 0.368 | 31.418 | 0.000 |
| . ** | . * | 6 | 0.314 | 0.101 | 39.363 | 0.000 |
| . * | . . | 7 | 0.206 | -0.011 | 42.827 | 0.000 |
| . ** | . * | 8 | 0.242 | 0.112 | 47.703 | 0.000 |
| . * | . . | 9 | 0.199 | 0.069 | 51.057 | 0.000 |
| . * | . * | 10 | 0.101 | -0.185 | 51.933 | 0.000 |
| . * | . * | 11 | 0.093 | -0.103 | 52.681 | 0.000 |
| . . | . . | 12 | 0.048 | -0.054 | 52.884 | 0.000 |
| . . | . * | 13 | 0.049 | -0.105 | 53.103 | 0.000 |
| . . | . * | 14 | 0.042 | -0.130 | 53.268 | 0.000 |
| . . | . . | 15 | 0.012 | -0.003 | 53.281 | 0.000 |
| . . | . . | 16 | 0.041 | 0.072 | 53.444 | 0.000 |
| . . | . . | 17 | 0.038 | 0.038 | 53.586 | 0.000 |
| . . | . . | 18 | -0.031 | -0.012 | 53.678 | 0.000 |
| . * | . * | 19 | -0.168 | -0.131 | 56.524 | 0.000 |
| . * | . * | 20 | -0.184 | -0.104 | 59.993 | 0.000 |
| . . | . . | 21 | -0.063 | 0.042 | 60.411 | 0.000 |
| . * | . * | 22 | -0.120 | -0.140 | 61.934 | 0.000 |
| . . | . . | 23 | -0.059 | -0.004 | 62.317 | 0.000 |
| . ** | . * | 24 | -0.252 | -0.166 | 69.341 | 0.000 |
| . ** | . * | 25 | -0.264 | -0.075 | 77.231 | 0.000 |
| . * | . . | 26 | -0.177 | -0.030 | 80.880 | 0.000 |
| . ** | . . | 27 | -0.235 | -0.039 | 87.428 | 0.000 |
| . ** | . . | 28 | -0.220 | -0.055 | 93.274 | 0.000 |
| . ** | . . | 29 | -0.234 | 0.005 | 100.08 | 0.000 |
| . * | . * | 30 | -0.164 | 0.143 | 103.50 | 0.000 |
| . * | . . | 31 | -0.167 | 0.015 | 107.14 | 0.000 |
| . * | . * | 32 | -0.141 | 0.075 | 109.77 | 0.000 |
| . ** | . . | 33 | -0.260 | -0.057 | 118.98 | 0.000 |
| . ** | . . | 34 | -0.227 | -0.039 | 126.23 | 0.000 |
| . * | . * | 35 | -0.095 | 0.078 | 127.51 | 0.000 |
| . * | . . | 36 | -0.154 | -0.054 | 131.03 | 0.000 |
| . * | . . | 37 | -0.092 | -0.023 | 132.32 | 0.000 |
| . * | . . | 38 | -0.129 | -0.047 | 134.92 | 0.000 |
| . * | . . | 39 | -0.130 | -0.029 | 137.65 | 0.000 |
| . . | . . | 40 | -0.031 | 0.044 | 137.81 | 0.000 |
| . * | . . | 41 | -0.110 | -0.035 | 139.90 | 0.000 |
| . * | . . | 42 | -0.135 | -0.053 | 143.15 | 0.000 |

| | | | | | | |
|-----|-----|----|--------|--------|--------|-------|
| . . | . . | 43 | -0.087 | -0.031 | 144.53 | 0.000 |
| . . | . . | 44 | -0.027 | 0.018 | 144.67 | 0.000 |
| . . | . * | 45 | 0.034 | 0.078 | 144.90 | 0.000 |
| . . | . . | 46 | 0.000 | -0.049 | 144.90 | 0.000 |
| . . | . * | 47 | 0.038 | 0.108 | 145.20 | 0.000 |
| . . | . . | 48 | 0.012 | -0.016 | 145.23 | 0.000 |



LAMPIRAN C
OUTPUT PARAMETER MODEL
DUGAAN

Lampiran C

Output Parameter Model Dugaan

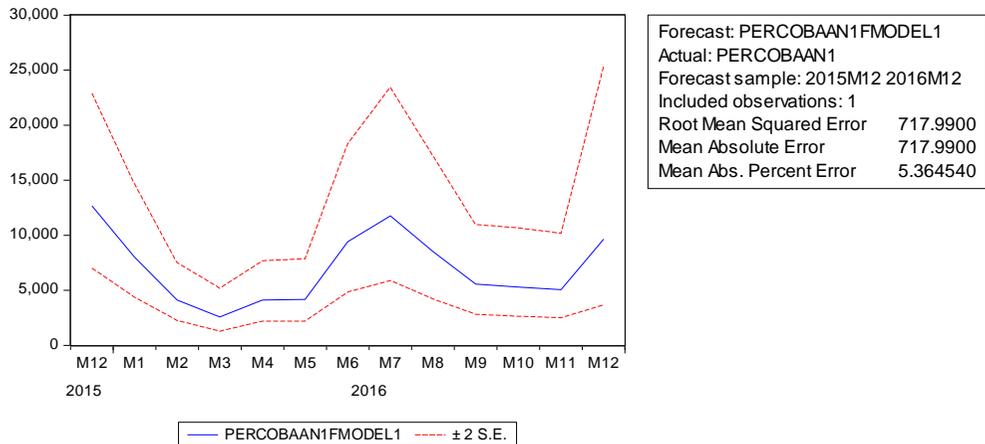
Model 1

| Dependent Variable: D(D(LOG(PERCOBAAN1),0,12)) | | | | |
|--|----------------------|-----------------------|-----------------------|-----------------------|
| Method: ARMA Maximum Likelihood (OPG - BHHH) | | | | |
| Date: 01/08/18 Time: 00:43 | | | | |
| Sample: 2010M02 2015M12 | | | | |
| Included observations: 71 | | | | |
| Convergence achieved after 36 iterations | | | | |
| Coefficient covariance computed using outer product of gradients | | | | |
| Variable | Coefficient | Std. Error | t-Statistic | Prob. |
| AR(12) | -0.076557 | 0.207020 | -0.369806 | 0.7127 |
| MA(1) | -0.794070 | 0.090715 | -8.753473 | 0.0000 |
| SIGMASQ | 0.079367 | 0.011276 | 7.038341 | 0.0000 |
| R-squared | 0.364060 | Mean dependent var | | 0.002077 |
| Adjusted R-squared | 0.345356 | S.D. dependent var | | 0.355789 |
| S.E. of regression | 0.287869 | Akaike info criterion | | 0.403868 |
| Sum squared resid | 5.635076 | Schwarz criterion | | 0.499474 |
| Log likelihood | -11.33732 | Hannan-Quinn criter. | | 0.441888 |
| Durbin-Watson stat | 1.917901 | | | |
| Inverted AR Roots | .78+.21i .21-.78i | .78-.21i .21+.78i | .57+.57i -.21-.78i | .57-.57i -.21+.78i |
| Inverted MA Roots | .79 | | | |

*Gambar C. 1 Output Parameter Model 1**Tabel C. 1 Hasil Plot ACF dan PACF Model 1*

| Date: 01/09/18 Time: 09:10 | | | | | | |
|---|---------------------|----|--------|--------|--------|-------|
| Sample: 2009M01 2015M12 | | | | | | |
| Included observations: 71 | | | | | | |
| Q-statistic probabilities adjusted for 2 ARMA terms | | | | | | |
| Autocorrelation | Partial Correlation | AC | PAC | Q-Stat | Prob | |
| . . | . . | 1 | 0.041 | 0.041 | 0.1221 | |
| * . | * . | 2 | -0.072 | -0.074 | 0.5143 | |
| * . | * . | 3 | -0.126 | -0.121 | 1.7222 | 0.189 |
| * . | * . | 4 | -0.136 | -0.135 | 3.1537 | 0.207 |
| . ** | . ** | 5 | 0.295 | 0.296 | 9.9700 | 0.019 |
| . * | . * | 6 | 0.138 | 0.093 | 11.493 | 0.022 |
| . . | . . | 7 | -0.022 | -0.033 | 11.533 | 0.042 |
| . . | . * | 8 | 0.036 | 0.105 | 11.638 | 0.071 |
| . . | . * | 9 | -0.001 | 0.112 | 11.638 | 0.113 |
| . . | * . | 10 | -0.034 | -0.109 | 11.736 | 0.163 |

| | | | | | | |
|-----|-----|----|--------|--------|--------|-------|
| . . | . . | 11 | 0.004 | -0.060 | 11.738 | 0.229 |
| . . | . . | 12 | 0.003 | 0.046 | 11.739 | 0.303 |
| . . | * . | 13 | -0.018 | -0.066 | 11.766 | 0.381 |
| . . | * . | 14 | 0.011 | -0.077 | 11.777 | 0.464 |
| . . | . . | 15 | -0.009 | 0.027 | 11.785 | 0.545 |
| . . | . * | 16 | 0.065 | 0.115 | 12.182 | 0.592 |
| . * | . * | 17 | 0.101 | 0.074 | 13.155 | 0.590 |
| . . | . * | 18 | 0.050 | 0.079 | 13.398 | 0.643 |
| * . | * . | 19 | -0.114 | -0.068 | 14.689 | 0.618 |
| * . | * . | 20 | -0.100 | -0.066 | 15.696 | 0.614 |
| . * | . * | 21 | 0.089 | 0.090 | 16.520 | 0.622 |
| . . | * . | 22 | 0.026 | -0.076 | 16.592 | 0.679 |
| . * | . . | 23 | 0.140 | 0.041 | 18.720 | 0.603 |
| * . | * . | 24 | -0.140 | -0.131 | 20.891 | 0.527 |
| * . | . . | 25 | -0.141 | -0.063 | 23.129 | 0.453 |
| . . | . . | 26 | 0.001 | -0.044 | 23.129 | 0.512 |
| * . | * . | 27 | -0.082 | -0.094 | 23.920 | 0.524 |
| . . | * . | 28 | -0.032 | -0.124 | 24.045 | 0.573 |
| * . | * . | 29 | -0.082 | -0.083 | 24.877 | 0.581 |
| . . | . . | 30 | -0.012 | 0.062 | 24.895 | 0.634 |
| . . | . . | 31 | -0.004 | -0.038 | 24.897 | 0.684 |
| . . | . . | 32 | 0.013 | 0.041 | 24.921 | 0.729 |
| * . | * . | 33 | -0.143 | -0.087 | 27.705 | 0.636 |
| * . | * . | 34 | -0.117 | -0.068 | 29.633 | 0.587 |
| . . | . * | 35 | 0.071 | 0.077 | 30.356 | 0.599 |
| . . | . . | 36 | -0.033 | -0.034 | 30.514 | 0.639 |
| . . | . . | 37 | 0.047 | -0.009 | 30.855 | 0.669 |
| . . | . . | 38 | -0.032 | -0.011 | 31.011 | 0.705 |
| . . | . . | 39 | -0.056 | 0.010 | 31.511 | 0.724 |
| . * | . . | 40 | 0.078 | 0.055 | 32.536 | 0.720 |
| . . | . . | 41 | -0.046 | -0.007 | 32.901 | 0.743 |
| * . | . . | 42 | -0.093 | -0.054 | 34.439 | 0.718 |
| . . | . . | 43 | -0.053 | -0.042 | 34.950 | 0.735 |
| . . | . . | 44 | -0.014 | -0.031 | 34.988 | 0.770 |
| . . | . . | 45 | 0.063 | 0.068 | 35.787 | 0.774 |
| . . | . . | 46 | -0.004 | -0.048 | 35.791 | 0.806 |
| . . | . * | 47 | 0.037 | 0.124 | 36.081 | 0.826 |
| . . | . . | 48 | -0.021 | 0.035 | 36.182 | 0.850 |



Gambar C. 2 Hasil Peramalan Model 1

Model 2

Dependent Variable: D(D(LOG(PERCOBAAN1),0,12))
 Method: ARMA Maximum Likelihood (OPG - BHHH)
 Date: 01/08/18 Time: 00:44
 Sample: 2010M02 2015M12
 Included observations: 71
 Convergence achieved after 37 iterations
 Coefficient covariance computed using outer product of gradients

| Variable | Coefficient | Std. Error | t-Statistic | Prob. |
|----------|-------------|------------|-------------|--------|
| MA(1) | -0.792248 | 0.094927 | -8.345901 | 0.0000 |
| SMA(12) | -0.162008 | 0.206600 | -0.784162 | 0.4357 |
| SIGMASQ | 0.078799 | 0.010568 | 7.456554 | 0.0000 |

| | | | |
|--------------------|-----------|-----------------------|----------|
| R-squared | 0.368613 | Mean dependent var | 0.002077 |
| Adjusted R-squared | 0.350043 | S.D. dependent var | 0.355789 |
| S.E. of regression | 0.286837 | Akaike info criterion | 0.400220 |
| Sum squared resid | 5.594732 | Schwarz criterion | 0.495826 |
| Log likelihood | -11.20781 | Hannan-Quinn criter. | 0.438240 |
| Durbin-Watson stat | 1.924886 | | |

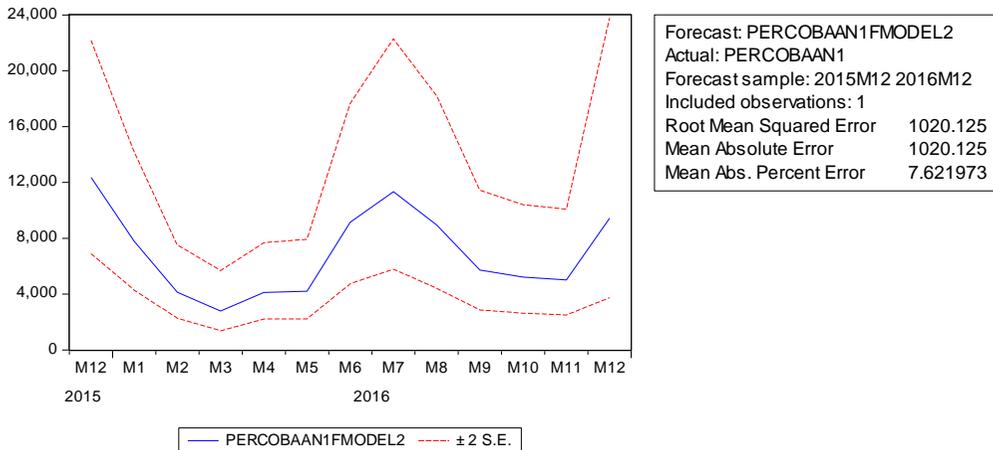
| Inverted MA Roots | | | | |
|-------------------|-----------|-----------|-----------|--|
| .86 | .79 | .74+.43i | .74-.43i | |
| .43-.74i | .43+.74i | .00+.86i | -.00-.86i | |
| -.43-.74i | -.43+.74i | -.74+.43i | -.74-.43i | |
| -.86 | | | | |

Gambar C. 3 Output Parameter Model 2

Tabel C. 2 Hasil Plot ACF dan PACF Model 2

| Date: 01/09/18 Time: 09:09 | | | | | | |
|---|---------------------|----|--------|--------|--------|-------|
| Sample: 2009M01 2015M12 | | | | | | |
| Included observations: 71 | | | | | | |
| Q-statistic probabilities adjusted for 2 ARMA terms | | | | | | |
| Autocorrelation | Partial Correlation | AC | PAC | Q-Stat | Prob | |
| . . | . . | 1 | 0.037 | 0.037 | 0.1005 | |
| .* . | .* . | 2 | -0.078 | -0.079 | 0.5550 | |
| .* . | .* . | 3 | -0.128 | -0.123 | 1.8106 | 0.178 |
| .* . | .* . | 4 | -0.128 | -0.128 | 3.0748 | 0.215 |
| . ** | . ** | 5 | 0.306 | 0.304 | 10.416 | 0.015 |
| . * | . * | 6 | 0.147 | 0.105 | 12.147 | 0.016 |
| . . | . . | 7 | -0.020 | -0.024 | 12.179 | 0.032 |
| . . | . * | 8 | 0.022 | 0.097 | 12.218 | 0.057 |
| . . | . * | 9 | -0.004 | 0.111 | 12.219 | 0.094 |
| . . | .* . | 10 | -0.032 | -0.110 | 12.304 | 0.138 |
| . . | . . | 11 | 0.018 | -0.054 | 12.332 | 0.195 |
| . . | . * | 12 | 0.043 | 0.079 | 12.493 | 0.253 |
| . . | .* . | 13 | -0.028 | -0.076 | 12.562 | 0.323 |
| . . | . . | 14 | 0.016 | -0.062 | 12.586 | 0.400 |
| . . | . . | 15 | -0.016 | 0.032 | 12.610 | 0.478 |
| . . | . * | 16 | 0.061 | 0.115 | 12.964 | 0.529 |
| . * | . . | 17 | 0.103 | 0.049 | 13.972 | 0.528 |
| . . | . * | 18 | 0.045 | 0.076 | 14.169 | 0.586 |
| .* . | .* . | 19 | -0.111 | -0.068 | 15.397 | 0.567 |
| .* . | .* . | 20 | -0.092 | -0.073 | 16.256 | 0.575 |
| . * | . * | 21 | 0.086 | 0.078 | 17.016 | 0.589 |
| . . | .* . | 22 | 0.017 | -0.075 | 17.046 | 0.650 |
| . * | . . | 23 | 0.143 | 0.053 | 19.240 | 0.570 |
| .* . | .* . | 24 | -0.136 | -0.124 | 21.272 | 0.504 |
| .* . | .* . | 25 | -0.147 | -0.069 | 23.719 | 0.420 |
| . . | . . | 26 | 0.002 | -0.040 | 23.719 | 0.478 |
| .* . | .* . | 27 | -0.084 | -0.092 | 24.546 | 0.488 |
| . . | .* . | 28 | -0.018 | -0.125 | 24.585 | 0.543 |
| .* . | .* . | 29 | -0.077 | -0.093 | 25.316 | 0.557 |
| . . | . . | 30 | -0.024 | 0.051 | 25.390 | 0.607 |
| . . | . . | 31 | -0.007 | -0.031 | 25.397 | 0.657 |
| . . | . . | 32 | 0.007 | 0.035 | 25.404 | 0.705 |
| .* . | .* . | 33 | -0.129 | -0.082 | 27.691 | 0.637 |
| .* . | . . | 34 | -0.116 | -0.063 | 29.586 | 0.589 |
| . * | . * | 35 | 0.078 | 0.084 | 30.460 | 0.594 |
| . . | . . | 36 | -0.032 | -0.021 | 30.616 | 0.634 |

| | | | | | | |
|-----|-----|----|--------|--------|--------|-------|
| . . | . . | 37 | 0.036 | -0.013 | 30.818 | 0.670 |
| . . | . . | 38 | -0.039 | -0.008 | 31.054 | 0.703 |
| . . | . . | 39 | -0.059 | 0.026 | 31.612 | 0.719 |
| . * | . . | 40 | 0.074 | 0.048 | 32.528 | 0.720 |
| . . | . . | 41 | -0.041 | -0.007 | 32.817 | 0.747 |
| * . | . . | 42 | -0.097 | -0.060 | 34.512 | 0.715 |
| . . | . . | 43 | -0.059 | -0.039 | 35.152 | 0.727 |
| . . | . . | 44 | -0.018 | -0.046 | 35.211 | 0.761 |
| . . | . . | 45 | 0.061 | 0.073 | 35.942 | 0.769 |
| . . | . . | 46 | -0.007 | -0.048 | 35.951 | 0.801 |
| . . | . * | 47 | 0.037 | 0.121 | 36.246 | 0.821 |
| . . | . . | 48 | -0.029 | 0.045 | 36.431 | 0.843 |



Gambar C. 4 Hasil Peramalan Model 2

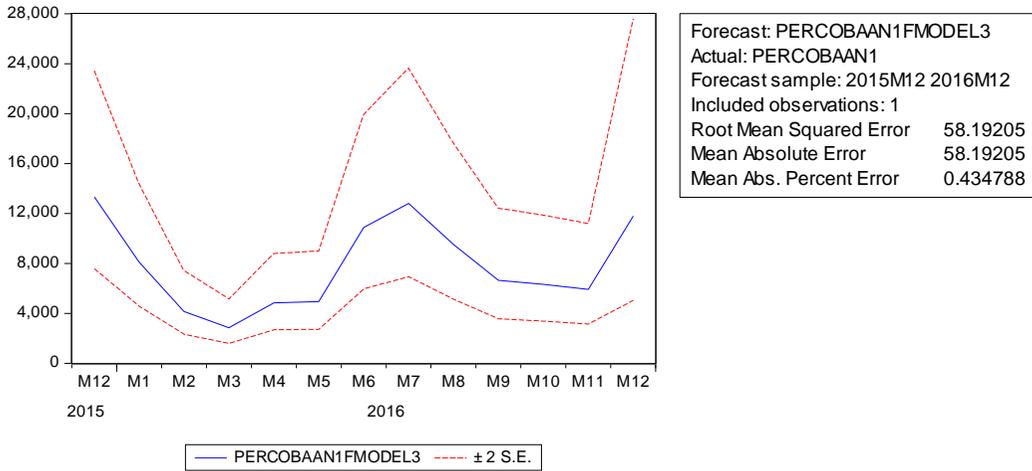
Model 3

| Dependent Variable: D(D(LOG(PERCOBAAN1),0,12)) | | | | |
|---|-------------|-----------------------|-------------|-----------|
| Method: ARMA Maximum Likelihood (OPG - BHHH) | | | | |
| Date: 01/08/18 Time: 00:45 | | | | |
| Sample: 2010M02 2015M12 | | | | |
| Included observations: 71 | | | | |
| Failure to improve objective (non-zero gradients) after 20 iterations | | | | |
| Coefficient covariance computed using outer product of gradients | | | | |
| Variable | Coefficient | Std. Error | t-Statistic | Prob. |
| MA(1) | -0.841795 | 0.133139 | -6.322692 | 0.0000 |
| MA(12) | -0.158205 | 0.050294 | -3.145565 | 0.0025 |
| SIGMASQ | 0.076056 | 0.012069 | 6.301922 | 0.0000 |
| R-squared | 0.390594 | Mean dependent var | | 0.002077 |
| Adjusted R-squared | 0.372670 | S.D. dependent var | | 0.355789 |
| S.E. of regression | 0.281800 | Akaike info criterion | | 0.391834 |
| Sum squared resid | 5.399959 | Schwarz criterion | | 0.487441 |
| Log likelihood | -10.91012 | Hannan-Quinn criter. | | 0.429854 |
| Durbin-Watson stat | 1.899896 | | | |
| Inverted MA Roots | 1.00 | .84+.38i | .84-.38i | .50-.71i |
| | | .50+.71i | .06-.83i | .06+.83i |
| | | -.38+.73i | -.69+.42i | -.69-.42i |
| | | | | -.81 |

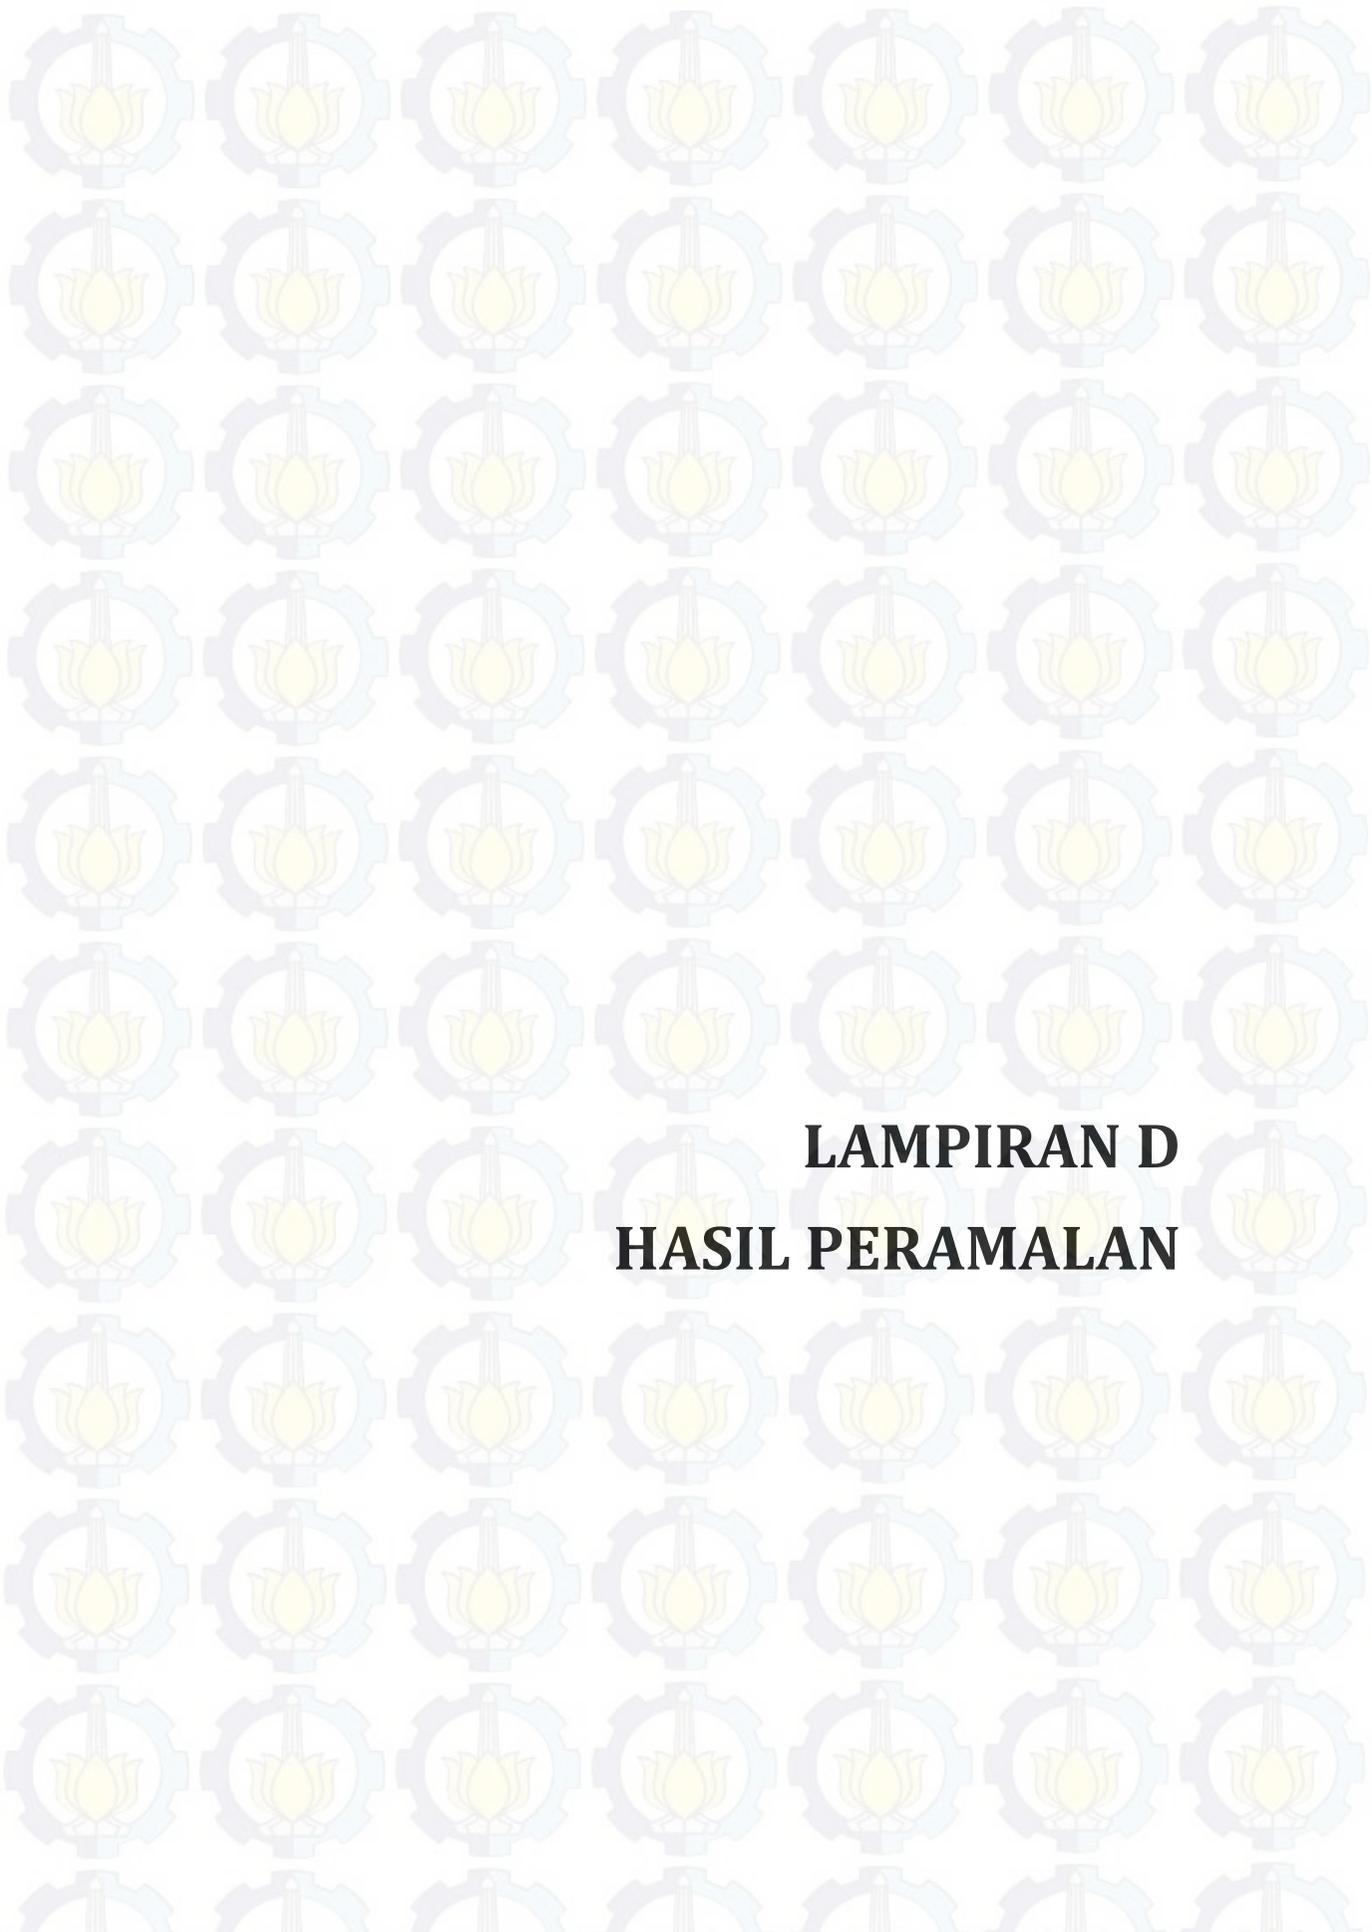
*Gambar C. 5 Output Parameter Model 3**Tabel C. 3 Hasil Plot ACF dan PACF Model 3*

| Date: 01/09/18 Time: 09:11 | | | | | | |
|---|---------------------|----|--------|--------|--------|-------|
| Sample: 2009M01 2015M12 | | | | | | |
| Included observations: 71 | | | | | | |
| Q-statistic probabilities adjusted for 2 ARMA terms | | | | | | |
| Autocorrelation | Partial Correlation | AC | PAC | Q-Stat | Prob | |
| . . | . . | 1 | 0.049 | 0.049 | 0.1799 | |
| .* . | .* . | 2 | -0.072 | -0.074 | 0.5641 | |
| .* . | .* . | 3 | -0.128 | -0.121 | 1.8072 | 0.179 |
| .* . | .* . | 4 | -0.135 | -0.132 | 3.2266 | 0.199 |
| . ** | . ** | 5 | 0.282 | 0.286 | 9.4739 | 0.024 |
| . * | . . | 6 | 0.119 | 0.066 | 10.605 | 0.031 |
| . . | . . | 7 | -0.028 | -0.042 | 10.670 | 0.058 |
| . . | . * | 8 | 0.042 | 0.109 | 10.813 | 0.094 |
| . . | . * | 9 | -0.009 | 0.090 | 10.820 | 0.147 |
| . . | .* . | 10 | -0.060 | -0.140 | 11.124 | 0.195 |
| . . | .* . | 11 | -0.036 | -0.084 | 11.236 | 0.260 |
| . . | . . | 12 | 0.002 | 0.057 | 11.237 | 0.339 |

| | | | | | | |
|-----|-----|----|--------|--------|--------|-------|
| . . | . . | 13 | 0.029 | -0.026 | 11.311 | 0.418 |
| . . | . . | 14 | 0.056 | -0.032 | 11.596 | 0.479 |
| . . | . * | 15 | 0.028 | 0.086 | 11.670 | 0.555 |
| . * | . * | 16 | 0.091 | 0.182 | 12.442 | 0.571 |
| . * | . * | 17 | 0.126 | 0.129 | 13.971 | 0.528 |
| . * | . * | 18 | 0.074 | 0.102 | 14.509 | 0.561 |
| * . | . . | 19 | -0.098 | -0.060 | 15.467 | 0.562 |
| * . | * . | 20 | -0.090 | -0.076 | 16.283 | 0.573 |
| . * | . . | 21 | 0.101 | 0.064 | 17.338 | 0.567 |
| . . | * . | 22 | 0.049 | -0.089 | 17.592 | 0.614 |
| . * | . . | 23 | 0.149 | 0.037 | 19.975 | 0.523 |
| * . | * . | 24 | -0.139 | -0.129 | 22.101 | 0.454 |
| * . | * . | 25 | -0.151 | -0.066 | 24.668 | 0.368 |
| . . | . . | 26 | -0.016 | -0.040 | 24.696 | 0.422 |
| * . | * . | 27 | -0.089 | -0.086 | 25.630 | 0.428 |
| . . | * . | 28 | -0.037 | -0.128 | 25.791 | 0.475 |
| * . | * . | 29 | -0.080 | -0.106 | 26.578 | 0.487 |
| . . | . . | 30 | -0.004 | 0.028 | 26.580 | 0.541 |
| . . | . . | 31 | 0.016 | -0.052 | 26.614 | 0.593 |
| . . | . . | 32 | 0.032 | 0.044 | 26.754 | 0.636 |
| * . | * . | 33 | -0.127 | -0.091 | 28.964 | 0.571 |
| * . | * . | 34 | -0.107 | -0.079 | 30.557 | 0.540 |
| . * | . . | 35 | 0.078 | 0.070 | 31.438 | 0.545 |
| . . | . . | 36 | -0.021 | -0.043 | 31.504 | 0.591 |
| . . | . . | 37 | 0.059 | -0.010 | 32.039 | 0.612 |
| . . | . . | 38 | -0.023 | -0.011 | 32.119 | 0.654 |
| . . | . . | 39 | -0.057 | 0.005 | 32.651 | 0.673 |
| . . | . . | 40 | 0.067 | 0.062 | 33.399 | 0.682 |
| * . | . . | 41 | -0.073 | 0.009 | 34.327 | 0.683 |
| * . | . . | 42 | -0.130 | -0.052 | 37.330 | 0.591 |
| * . | . . | 43 | -0.074 | -0.038 | 38.357 | 0.589 |
| . . | . . | 44 | -0.029 | -0.029 | 38.522 | 0.624 |
| . . | . * | 45 | 0.057 | 0.074 | 39.172 | 0.638 |
| . . | . . | 46 | -0.027 | -0.044 | 39.324 | 0.672 |
| . . | . * | 47 | 0.004 | 0.129 | 39.327 | 0.710 |
| . . | . . | 48 | -0.034 | 0.051 | 39.595 | 0.736 |



Gambar C. 6 Hasil Peramalan Model 3



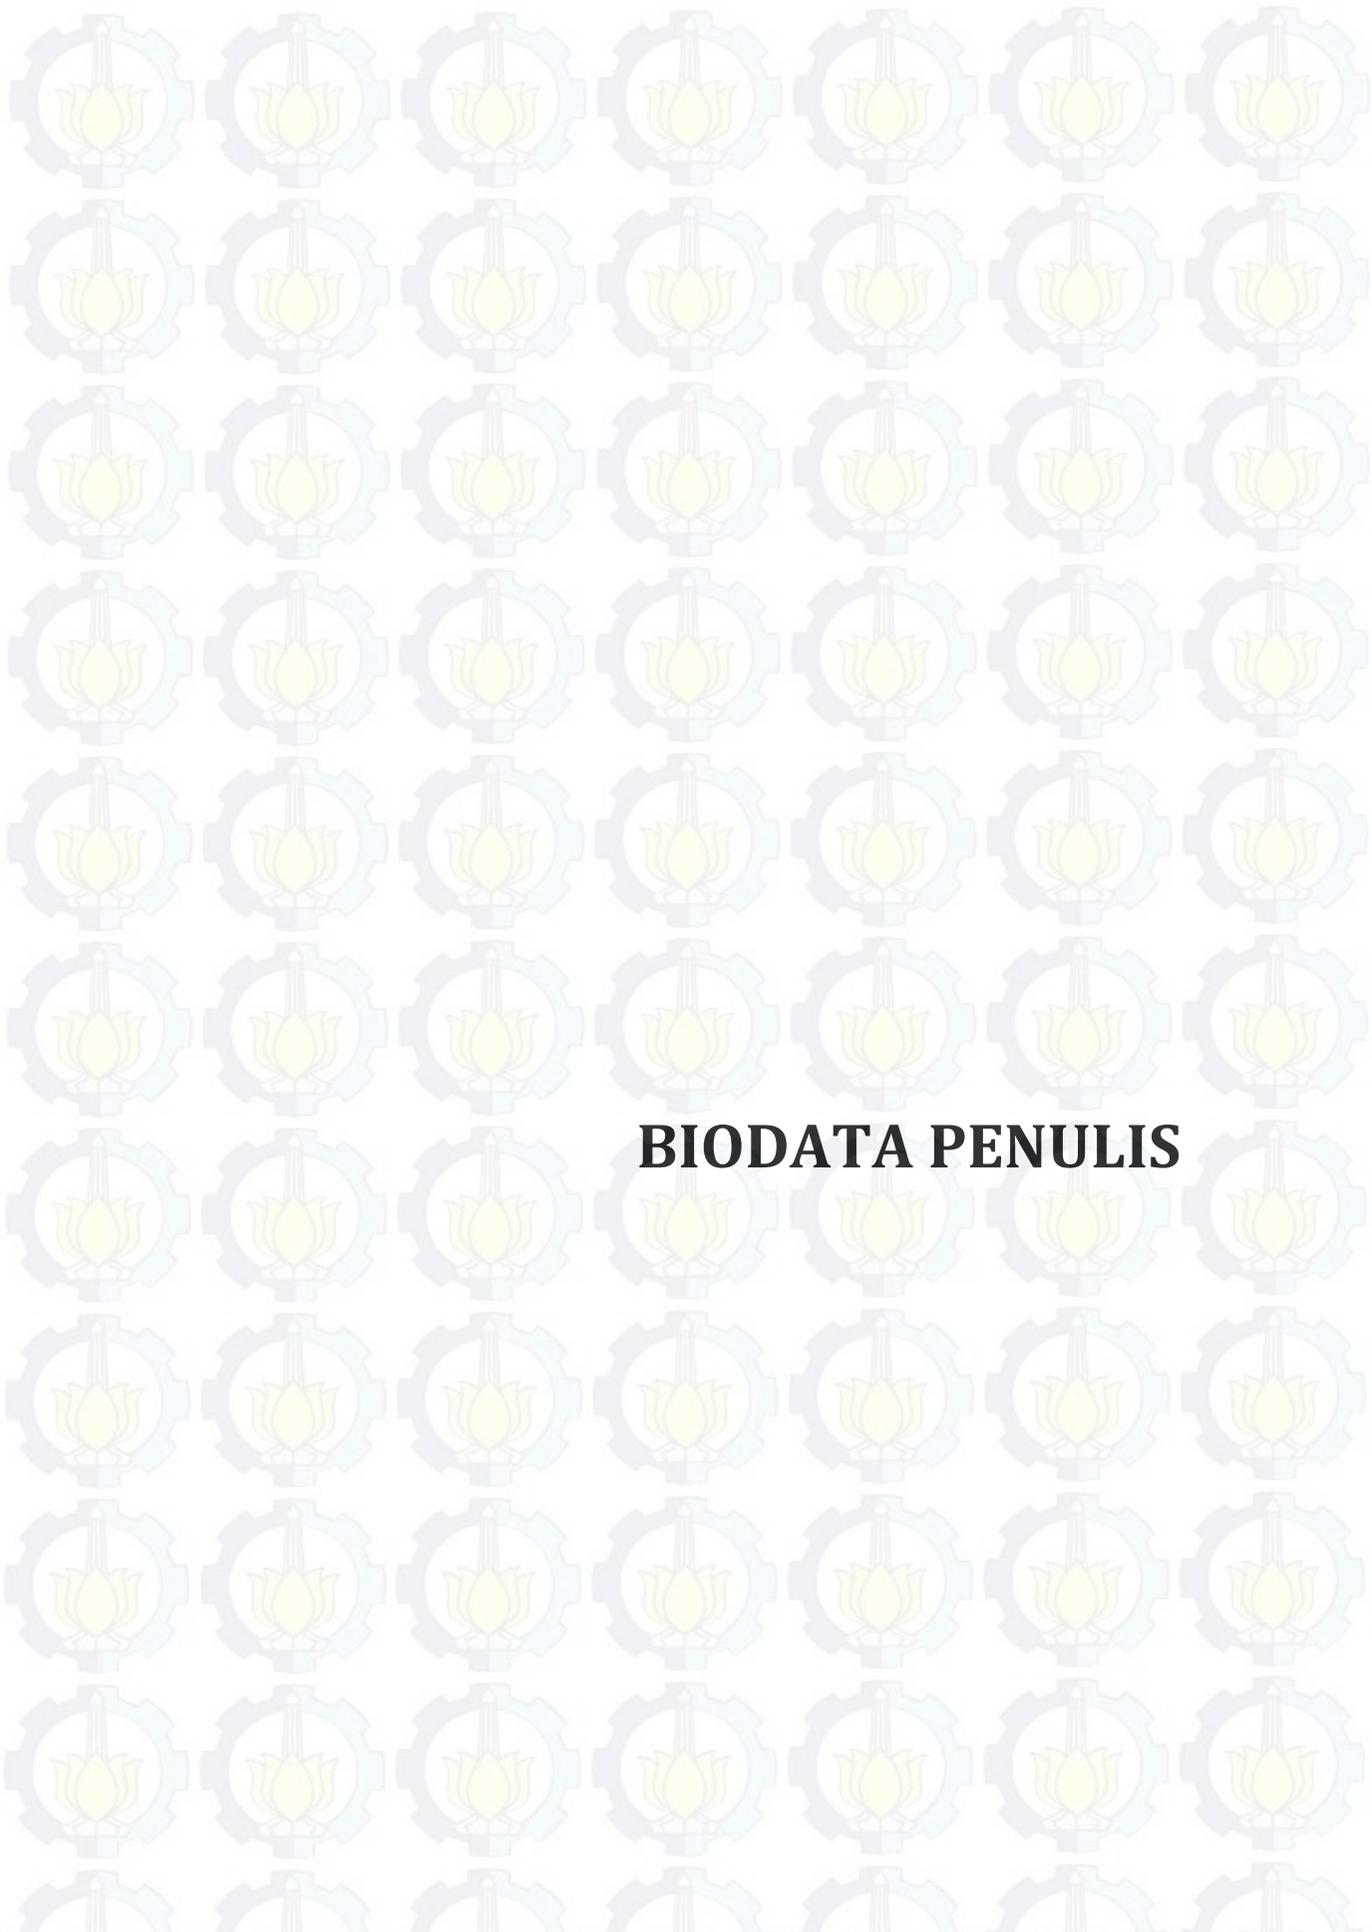
LAMPIRAN D
HASIL PERAMALAN

Lampiran D

Hasil Peramalan

Tabel D. 1 Hasil Peramalan dan Error

| Bulan | Model 1 | Model 2 | Model 3 | Data Asli | Error Model 1 | Error Model 2 | Error Model 3 |
|------------------------|---------|---------|---------|-----------|---------------|---------------|---------------|
| Jan | 8017 | 7794 | 8112 | 10766 | 26% | 28% | 25% |
| Feb | 4117 | 4131 | 4151 | 5430 | 24% | 24% | 24% |
| Mar | 2579 | 2783 | 2845 | 3169 | 19% | 12% | 10% |
| Apr | 4109 | 4121 | 4840 | 5399 | 24% | 24% | 10% |
| Jun | 4162 | 4200 | 4933 | 5398 | 23% | 22% | 9% |
| July | 9414 | 9151 | 10884 | 12682 | 26% | 28% | 14% |
| Aug | 11756 | 11341 | 12794 | 16995 | 31% | 33% | 25% |
| Sept | 8500 | 8950 | 9506 | 10652 | 20% | 16% | 11% |
| Oct | 5554 | 5719 | 6646 | 7187 | 23% | 20% | 8% |
| Nov | 5290 | 5219 | 6316 | 7093 | 25% | 26% | 11% |
| Dec | 5046 | 5016 | 5913 | 6688 | 25% | 25% | 12% |
| Total | 9655 | 9435 | 11782 | 13384 | 28% | 30% | 12% |
| Rata-rata error | | | | | 24% | 24% | 14% |



BIODATA PENULIS

BIODATA PENULIS



Penulis lahir di Probolinggo pada tanggal 04 Juni 1995 dengan nama Sofiaturn Rohmah. Penulis menempuh jenjang Pendidikan mulai dari SDN Bayeman II (2001-2007), SMPN 1 Tongas (2008-2010) dan SMAN 1 Probolinggo (2011-2013). Setelah lulus SMA, penulis diterima di Departemen Teknik Sistem Perkapalan, Fakultas Teknologi Kelautan, Institut Teknologi Sepuluh Nopember melalui jalur penerimaan SNMPTN undangan pada tahun 2013. Selama menempuh masa studi, penulis aktif di berbagai kegiatan dan organisasi di bidang akademik. Diantaranya organisasi BEM FTK (Badan Eksekutif Mahasiswa Fakultas Teknologi Kelautan) dan anggota dari *Marine Operation and Maintenance Laboratory* DTSP ITS. Selain itu dalam menunjang kehidupan di kampus, penulis juga turut serta membantu proyek-proyek dari Ir. Dwi Priyanta M.SE selaku sekretaris jurusan program studi sarjana (S1) *double degree* DTSP ITS, diantaranya yaitu proyek *Equipment Critically Analysys*, *Pipeline Risk Assessment*, dan *Pipeline Monitoring*. Dalam bidang akademis, penulis memiliki minat dalam bidang *safety engineering*, *pipeline engineering*, dan *maintenance*.