



TUGAS AKHIR - KS184822

**PERAMALAN PENUMPANG ANGKUTAN LAUT
ROUTE SURABAYA-JAYAPURA
DI PT. PELAYARAN NASIONAL INDONESIA (PERSERO)
CABANG SURABAYA**

**ELIYA AINUL FARRI
NRP 062117 4500 0017**

**Dosen Pembimbing
Irhamah, M.Si., Ph.D.**

**PROGRAM STUDI SARJANA
DEPARTEMEN STATISTIKA
FAKULTAS MATEMATIKA, KOMPUTASI, DAN SAINS DATA
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2019**



FINAL PROJECT - KS184822

**MARINE TRANSPORT PASSENGER FORECAST OF
SURABAYA-JAYAPURA ROUTE
AT PT. PELAYARAN NASIONAL INDONESIA
(PERSERO) SURABAYA BRANCH**

**ELIYA AINUL FARRI
SN 062117 4500 0017**

**Supervisor
Irhamah, M.Si., Ph.D.**

**UNDERGRADUATE PROGRAMME
DEPARTMENT OF STATISTICS
FACULTY OF MATHEMATICS, COMPUTING, AND DATA SCIENCE
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2019**

LEMBAR PENGESAHAN
PERAMALAN PENUMPANG ANGKUTAN LAUT
RUTE SURABAYA-JAKARTA
DI PT. PELAYARAN NASIONAL INDONESIA
(PERSERO) CABANG SURABAYA

TUGAS AKHIR

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

Oleh :

Eliya Ainul Farri
NRP. 062117 4500 0017

Disetujui oleh Pembimbing:
Irhamah, M.Si., Ph.D.
NIP. 19780406 200112 2 002

(*fhaz*)

Mengetahui,
Kepala Departemen Statistika



Dr. Suhartono
NIP. 19710929 199512 1 001

SURABAYA, JULI 2019

**PERAMALAN PENUMPANG ANGKUTAN LAUT
RUTE SURABAYA-JAYAPURA
DI PT. PELAYARAN NASIONAL INDONESIA (PERSERO)
CABANG SURABAYA**

Nama : Eliya Ainul Farri
NRP : 062117 4500 0017
Departemen : Statistika FMKSD-ITS
Dosen Pembimbing : Irhamah, M.Si., Ph.D.

Abstrak

Laut Indonesia memiliki peranan penting bagi kehidupan bangsa dan negara. Salah satunya dalam hal transportasi. Indonesia memiliki beberapa pelabuhan utama, salah satunya adalah Pelabuhan Tanjung Perak. Sejak tahun 2010 Pelabuhan Tanjung Perak menaungi 2 perusahaan kapal, salah satunya adalah PT Peln (Persero). Sebesar 41% dari total penumpang angkutan laut di Indonesia pada tahun 2017 menggunakan jasa PT Peln (Persero). Tingginya kebutuhan pelayanan di PT Peln (Persero) mengharuskan perusahaan memiliki *database* yang baik. Namun dikarenakan *human error*, data perusahaan tahun 2017 hilang. Pada penelitian ini akan didapatkan model terbaik untuk peramalan jumlah penumpang angkutan laut rute Surabaya-Jayapura di PT Peln (Persero) untuk tahun 2017 dengan menggunakan metode ARIMA *Box-Jenkins* dan regresi *time series* efek variasi kalender dengan residual data dilanjutkan dengan ARIMA *Box-Jenkins*. Efek variasi kalender digunakan karena pergeseran bulan terjadinya Hari Raya Idul Fitri. Hasil penelitian menunjukkan bahwa peramalan dengan menggunakan regresi *time series* memberikan hasil yang lebih baik dibandingkan dengan metode ARIMA *Box-Jenkins* karena nilai MAPE dan AIC yang dihasilkan cenderung lebih kecil.

Kata Kunci : ARIMA *Box-Jenkins*, Efek Variasi Kalender, Regresi *Time Series*.

**MARINE TRANSPORT PASSENGER FORECAST
OF SURABAYA-JAYAPURA ROUTE
AT PT. PELAYARAN NASIONAL INDONESIA
(PERSERO) SURABAYA BRANCH**

Name of Student : Eliya Ainul Farri
Student Number : 062117 45000 0017
Department : Statistics
Supervisor : Irhamah, M.Si., Ph.D.

Abstract

Indonesian's seas have an important role for the nation and state. Indonesia has several main ports, one of which is Tanjung Perak Port. Since 2010 Tanjung Perak Port has 2 ship transportation companies, one of which is PT Pelni (Persero). The high demand for services at PT Pelni (Persero) requires companies to have a good database. But, because the company's human error data in 2017 is gone. In this study the best model will be obtained for forecasting the number of sea transport passengers Surabaya-Jayapura route in 2017 at PT Pelni (Persero) using ARIMA method and time series regression with calendar variation effect with data residuals modeled with ARIMA. The results showed that forecasting using time series regression with calendar variation effect gave better result then ARIMA method because MAPE and AIC are smaller.

Key Word : ARIMA Method, Calendar Variaton Effect, Time Series Regression.

KATA PENGANTAR

Puji syukur kepada Allah SWT yang telah melimpahkan karunia dan rahmat-Nya sehingga penulis dapat menyelesaikan laporan tugas akhir dengan judul “**PERAMALAN PENUMPANG ANGKUTAN LAUT RUTE SURABAYA-JAYAPURA DI PT. PELAYARAN NASIONAL INDONESIA (PERSERO) CABANG SURABAYA**”. Penulis mengucapkan terimakasih kepada beberapa pihak yang telah membantu dalam penyusunan laporan tugas akhir yaitu sebagai berikut.

1. Irhamah, M.Si., Ph.D selaku dosen pembimbing yang memberikan bimbingan sehingga Laporan Tugas Akhir ini dapat diselesaikan dengan baik dan tepat waktu.
2. Prof. Drs. Nur Iriawan, Mikom, Ph.D dan Dr. Kartika Fithriasari, S.Si., M.Si selaku penguji yang telah memberikan kritik dan saran demi menyempurnakan Laporan Tugas Akhir ini.
3. Dr. Suhartono selaku Kepala Departemen Statistika dan Fakultas Matematika, Komputasi, dan Sains Data Institut Teknologi Sepuluh Nopember Surabaya.
4. Dra. Madu Ratna, M.Si selaku dosen wali yang merupakan orang tua bagi penulis selama 4 semester perkuliahan dan senantiasa memberikan motivasi pada tiap semester.
5. Seluruh dosen dan karyawan Departemen Statistika FMKSD-ITS yang telah memberikan ilmu maupun pengalaman selama penulis menjadi mahasiswa.
6. Presda Simangasih, SH selaku Kepala PT. Pelayaran Nasional Indonesia (Persero) Cabang Surabaya yang telah memberikan kesempatan penulis untuk melaksanakan penelitian di PT. Pelayaran Nasional Indonesia (Persero) Cabang Surabaya. Staff Bidang Umum dan Staff Transportasi Laut yang telah membantu mengumpulkan data demi terselesaikannya penelitian dan Laporan Tugas Akhir ini.

7. Orang tua tercinta, Almarhum Bapak Supriyadi yang telah memberikan izin penulis untuk menempuh pendidikan di luar kota, Ibu Muyasaroh yang senantiasa berdo'a untuk kebaikan anak-anaknya, dan kakak yang senantiasa menanyakan kabar Laporan Tugas Akhir ini.
8. Teman-teman PIONEER, Teman-teman LJ angkatan 2017, Teman-teman melingkar, dan beberapa orang yang tidak bisa disebut yang senantiasa memberikan semangat dan do'a selama proses penyelesaian Laporan Tugas Akhir ini serta atas kebersamaan dan pengalaman yang dilalui selama penulis menjadi mahasiswa.
9. Serta semua pihak yang telah membantu dalam pelaksanaan maupun pembuatan Laporan TA ini.

Tiada gading yang tak retak. Penulis menyadari bahwa laporan ini tidak luput dari kekurangan, maka kritik dan saran sangat diharapkan demi perbaikan di masa mendatang. Semoga tulisan ini dapat memberikan manfaat bagi semua pihak.

Surabaya, 27 Mei 2017

Penulis

DAFTAR ISI

	Halaman
HALAMAN JUDUL	i
TITLE PAGE	ii
LEMBAR PENGESAHAN	iii
ABSTRAK	iv
ABSTRACT	v
KATA PENGANTAR	vi
DAFTAR ISI	viii
DAFTAR TABEL	xi
DAFTAR LAMPIRAN	xiii
BAB I PENDAHULUAN	
1.1 Latar Belakang.....	1
1.2 Perumusan Masalah.....	4
1.3 Tujuan Penelitian.....	4
1.4 Manfaat Penelitian.....	4
1.5 Batasan Masalah.....	5
BAB II TINJAUAN PUSTAKA	
2.1 Metode Time Series.....	7
2.1.1 Stasioneritas Data.....	7
2.1.2 Autocorrelation Function (ACF).....	10
2.1.3 Partial Autocorrelation Function (PACF).....	11
2.2 ARIMA Box-Jenkins.....	12
2.2.1 Identifikasi Model.....	12
2.2.2 Estimasi dan Pengujian Parameter.....	16
2.2.3 Asumsi White Noise.....	17
2.2.4 Asumsi Residual Distribusi Normal.....	18
2.3 Regresi Time Series Efek Variasi Kalender.....	19
2.4 Pemeriksaan Asumsi Residual.....	20
2.4.1 Pemeriksaan Asumsi Residual Identik.....	20
2.4.2 Pemeriksaan Asumsi Residual Independen.....	21
2.5 Pemilihan Model Terbaik.....	22
2.6 PT. Pelayaran Nasional Indonesia (Persero).....	23

BAB III METODOLOGI PENELITIAN	
3.1	Sumber Data 25
3.2	Variabel Penelitian..... 25
3.3	Langkah Penelitian..... 26
BAB IV ANALISIS DAN PEMBAHASAN	
4.1	Deskripsi Data Kapal Penumpang 35
4.2	Pemodelan Kapal Penumpang Surabaya-Jayapura dengan Metode ARIMA 37
4.2.1	Stasioneritas Data Terhadap Varians 37
4.2.2	Stasioneritas Data Terhadap Mean 40
4.2.3	Identifikasi Model ARIMA..... 42
4.2.4	Pengujian Signifikansi Parameter 43
4.2.5	Pengujian Asumsi 44
4.2.6	Pemilihan Model Terbaik 45
4.2.7	Hasil Forecasting dengan Metode ARIMA 46
4.3	Pemodelan Kapal Penumpang Surabaya-Jayapura dengan Metode Regresi Time Series Efek Variasi Kalender..... 47
4.3.1	Pemodelan Regresi Time Series Efek Variasi Kalender 48
4.3.2	Pemeriksaan Asumsi Residual..... 51
4.3.3	Pemodelan ARIMA Data Residual 53
4.3.3.1	Identifikasi Model ARIMA Data Residual..... 57
4.3.3.2	Pengujian Signifikansi Parameter Data Residual..... 58
4.3.3.3	Pengujian Asumsi Data Residual 59
4.3.3.4	Pemilihan Model Terbaik Data Residual 60
4.3.5	Hasil Forecasting dengan Metode Regresi Time Series dan ARIMA 61
BAB V KESIMPULAN DAN SARAN	
5.1	Kesimpulan 65
5.2	Saran 66
DAFTAR PUSTAKA	67
LAMPIRAN	69

BIODATA PENULIS 117

DAFTAR TABEL

	Halaman
Tabel 2.1	Transformasi Box-Cox 9
Tabel 2.2	Bentuk ACF dan PACF model ARIMA 12
Tabel 3.1	Variabel Prediktor..... 25
Tabel 3.2	Struktur Data Penelitian..... 26
Tabel 3.3	Bulan Hari Raya Idul Fitri 26
Tabel 4.1	Karakteristik Data Kapal Penumpang Surabaya-Jayapura 37
Tabel 4.2	Pengujian Bartlett 38
Tabel 4.3	Pengujian Bartlett Data Transformasi..... 39
Tabel 4.4	Pengujian Dickey-Fuller 41
Tabel 4.5	Pengujian Dickey-Fuller Data Differencing 42
Tabel 4.6	Pengujian Signifikansi Parameter ARIMA..... 44
Tabel 4.7	Pengujian Asumsi ARIMA 44
Tabel 4.8	Hasil Forecasting ARIMA 46
Tabel 4.9	Pengujian Serentak Regresi Time Series Tahap Pertama 48
Tabel 4.10	Pengujian Parsial Regresi Time Series Tahap Pertama 48
Tabel 4.11	Pengujian Serentak Regresi Time Series Tahap Kedua 49
Tabel 4.12	Pengujian Parsial Regresi Time Series Tahap Kedua 50
Tabel 4.13	Pengujian Asumsi Identik 51
Tabel 4.14	Pengujian Bartlett Data Residual 54
Tabel 4.15	Pengujian Bartlett Data Residual Transformasi 56
Tabel 4.16	Pengujian Dickey-Fuller 57
Tabel 4.17	Pengujian Signifikansi Parameter ARIMA Data Residual..... 59
Tabel 4.18	Pengujian Asumsi ARIMA Residual Data 59
Tabel 4.19	Hasil Forecasting Menggunakan Regresi Time Series Efek Variasi Kalender 62

Tabel 4.20	Perbandingan Metode dengan Indikator Kebaikan Model.....	63
-------------------	---	----

DAFTAR LAMPIRAN


	Halaman
Lampiran 1. Data Penelitian.....	69
Lampiran 2. Pengujian Dickey-Fuller.....	70
Lampiran 3. Pengujian Dickey-Fuller Data <i>Differencing</i>	71
Lampiran 4. <i>Syntax</i> ARIMA ([12],1,1).....	72
Lampiran 5. <i>Output</i> ARIMA ([12],1,1).....	73
Lampiran 6. <i>Syntax</i> ARIMA (2,1,[12]).....	75
Lampiran 7. <i>Output</i> ARIMA (2,1,[12]).....	76
Lampiran 8. <i>Syntax</i> ARIMA (0,1,1)(0,0,1) ¹²	78
Lampiran 9. <i>Output</i> ARIMA (0,1,1)(0,0,1) ¹²	79
Lampiran 10. <i>Syntax</i> ARIMA (0,1,[1,12]).....	81
Lampiran 11. <i>Output</i> ARIMA (0,1,[1,12]).....	82
Lampiran 12. Hasil <i>Forecasting</i> <u>ARIMA</u>	84
Lampiran 13. Hasil Pemodelan TRS Efek Variasi Kalender Tahap Pertama.....	88
Lampiran 14. Hasil Pemodelan TRS Efek Variasi Kalender Tahap Kedua.....	91
Lampiran 15. Hasil Pengujian Asumsi Residual Identik.....	94
Lampiran 16. <i>Syntax</i> AR ([3,5]).....	97
Lampiran 17. <i>Output</i> AR ([3,5]).....	98
Lampiran 18. <i>Syntax</i> AR ([5]).....	102
Lampiran 19. <i>Output</i> AR ([5]).....	103
Lampiran 20. <i>Syntax</i> MA ([3,5]).....	105
Lampiran 21. <i>Output</i> MA ([3,5]).....	106
Lampiran 22. <i>Syntax</i> MA ([5]).....	108
Lampiran 23. <i>Output</i> MA ([5]).....	109
Lampiran 24. <i>Syntax Forecasting</i> Regresi <i>Time Series</i> dengan Memodelkan Residual Data dengan ARIMA.....	111
Lampiran 25. <i>Output Forecasting</i> Regresi <i>Time Series</i> dengan Memodelkan Residual Data dengan ARIMA.....	112
Lampiran 26. Surat Legalisir Data.....	116

BAB I

PENDAHULUAN

1.1 Latar Belakang

Indonesia merupakan negara kepulauan yang memiliki banyak pulau dan negara maritim yang memiliki laut yang luas serta garis pantai yang panjang. Laut memiliki peranan penting bagi kehidupan bangsa dan negara. Sektor maritim dapat menjadi sangat strategis bagi Indonesia karena sumber daya perikanan, mineral, energi terbarukan, transportasi, pariwisata, dan keanekaragaman hayati sangat melimpah serta menunggu untuk menjadi sumber *positioning* daya saing Indonesia dalam persaingan global. Namun, sektor maritim masih kurang mendapatkan perhatian dibandingkan dengan sektor daratan. Kontribusi sektor kelautan Indonesia masih di bawah 30% dan sektor perikanan hanya menyumbang 3% dari PDB nasional (Gumilang, 2016). Angka ini relatif kecil dibandingkan dengan potensi yang berada di sepanjang garis pantai Indonesia. Untuk meningkatkan daya saing nasional ke depan, laut perlu ditempatkan sebagai basis pembangunan nasional. Kualitas dan ketersediaan pelabuhan, kawasan industri, aktivitas distribusi barang, dan moda transportasi laut perlu menjamin hubungan dan konektivitas rantai nilai produksi nasional. (Baihaqi, 2014).



Gambar 1.1 Penumpang Angkutan Laut 2006-2017

Pelabuhan Tanjung Perak merupakan salah satu pelabuhan utama di Indonesia yang terletak di wilayah Jawa Timur dan merupakan pelabuhan paling sibuk kedua di Indonesia setelah Pelabuhan Tanjung Priok. Pelabuhan Tanjung Perak menjadi pelabuhan utama yang berfungsi sebagai kolektor dan distributor barang serta dari dan ke kawasan barat Indonesia (Kompasiana, 2015). Data publikasi BPS (2018) menunjukkan bahwa Pelabuhan Tanjung Perak cenderung mendominasi jumlah penumpang angkutan laut dari tahun 2006 hingga tahun 2017 dibandingkan dengan Pelabuhan Tanjung priok. Pergerakan penumpang angkutan laut di tiga pelabuhan utama menurun, yaitu masing-masing Pelabuhan Tanjung Priok berkurang sebanyak 12,11%, Pelabuhan Belawan berkurang sebanyak 0,83%, dan Pelabuhan Makassar berkurang sebanyak 13,56%. Berbeda dengan Pelabuhan Tanjung Perak yang tumbuh positif mencapai 2,02% (Maulana, 2018).

Pelabuhan Tanjung Perak menaungi 4 perusahaan kapal pada tahun 2010 namun karena terdapat beberapa permasalahan seperti pemisahan perusahaan, terjadi kapal rusak, maupun kapal yang dok sehingga perusahaan yang masih tetap beroperasi dari tahun 2010 hingga tahun 2016 adalah PT Pelayaran Nasional Indonesia (Persero) dan PT Dharma Lautan Utama (Fanani, 2017). PT Pelayaran Nasional Indonesia (Persero) merupakan perusahaan pelayaran yang senantiasa melakukan inovasi walaupun harus bersaing dengan transportasi udara yang semakin memberikan harga terjangkau dan waktu yang efektif. Karena dengan armada yang dimiliki PT Pelayaran Nasional Indonesia (Persero) bertekad untuk terus mengkoneksikan pulau-pulau di Indonesia termasuk pulau terdepan, terpencil, dan daerah perbatasan (3TP) untuk “Menghubungkan nusantara menyatukan Indonesia” (Kumpanan, 2018).

Penumpang angkutan laut pada tahun 2017 di Indonesia mencapai angka 8,27 juta penumpang dan sebesar 3,43 juta penumpang dilayani oleh PT Pelayaran Nasional Indonesia (Persero) (BPS, 2018). Artinya, pada tahun 2017 sebesar 41% penumpang angkutan laut menggunakan jasa PT Pelayaran Nasional In-

donesia (Persero). Berdasarkan tingginya angka tersebut maka pada penelitian ini akan dilakukan peramalan penumpang angkutan laut yang menggunakan jasa dari PT Pelayaran Nasional Indonesia (Persero) pada tahun 2017. Salah satu hal yang mendukung adanya penelitian ini adalah terjadinya *human error* sehingga data pelayaran pada tahun 2017 hilang. Harapan dari penelitian ini adalah memberikan informasi mengenai jumlah penumpang angkutan laut di PT Pelayaran Nasional Indonesia (Persero) rute Surabaya-Jayapura pada tahun 2017 karena data seluruh pelayaran di PT Pelayaran Nasional Indonesia (Persero) pada tahun 2017 telah hilang

Peramalan pada penelitian ini menggunakan metode ARIMA *Box-Jenkins* dengan menggunakan data jumlah penumpang angkutan laut dari beberapa tahun sebelumnya. Data jumlah penumpang angkutan laut dibagi menjadi dua bagian, yaitu data *insample* dan *outsample*. Data *insample* digunakan untuk menentukan pemodelan, sedangkan data *outsample* digunakan untuk pemilihan model. Data *insample* menggunakan data pada Januari tahun 2012 hingga Juni tahun 2016, sedangkan data *outsample* menggunakan data pada Juli hingga Desember tahun 2016. Penelitian dengan menggunakan ARIMA *Box-Jenkins* diantaranya pernah dilakukan oleh Dwijantari (2017), Fanani (2017), dan Endartyana (2017).

Jumlah penumpang angkutan laut diperkirakan akan meningkat cukup tinggi pada momen perayaan tertentu seperti Bulan Ramadhan dan Hari Raya Idul Fitri, kemudian kembali normal pada periode selanjutnya. Bulan Ramadhan dan Hari Raya Idul Fitri terjadi setiap tahun namun bergeser maju 10-11 hari. Bergeser bulan terjadinya Bulan Ramadhan dan Hari Raya Idul Fitri mengindikasikan adanya variasi kalender dalam model data penumpang angkutan laut PT Pelayaran Nasional Indonesia (Persero). Sehingga, selain menggunakan metode ARIMA *Box-Jenkins* penelitian ini akan menggunakan metode lain yaitu regresi *time series* dengan *calendar variation effect* dengan residual data dimodelkan dengan ARIMA *Box-Jenkins*.

Penelitian sebelumnya dengan menggunakan regresi *time series* dengan *calendar variation effect* dengan residual data dimodelkan dengan ARIMA *Box-Jenkins* adalah penelitian yang dilakukan oleh Permatasari (2015). Penelitian tersebut digunakan untuk meramalkan *inflow* dan *outflow* uang kartal di Bank Indonesia Surabaya khususnya di bulan yang memiliki momen perayaan tertentu yaitu Hari Raya Idul Fitri.

1.2 Perumusan Masalah

Tingginya jumlah penumpang angkutan laut yang menggunakan jasa dari PT Pelayaran Nasional Indonesia (Persero) yang mencapai angka 41% dari total penumpang angkutan laut di Indonesia menyebabkan PT Pelayaran Nasional Indonesia (Persero) harus menyiapkan kapal penumpang yang memadai di tahun-tahun berikutnya. Karena hal tersebut maka pada penelitian ini akan didapatkan model terbaik untuk peramalan jumlah penumpang angkutan laut di PT Pelayaran Nasional Indonesia (Persero).

1.3 Tujuan Penelitian

Berdasarkan permasalahan yang telah diuraikan di atas, tujuan penelitian ini adalah untuk mendapatkan model terbaik dengan metode ARIMA *Box-Jenkins* dan dengan *calendar variation effect* dengan residual data dimodelkan dengan ARIMA *Box-Jenkins* untuk peramalan jumlah penumpang angkutan laut di PT Pelayaran Nasional Indonesia (Persero) tahun 2017 sehingga dapat memberikan informasi terkait data yang hilang karena *human error* kepada PT Pelayaran Nasional Indonesia (Persero).

1.4 Manfaat Penelitian

Manfaat penelitian ini adalah memberikan informasi mengenai jumlah penumpang angkutan laut di PT Pelayaran Nasional Indonesia (Persero) rute Surabaya-Jayapura pada tahun 2017 karena data seluruh pelayaran di PT Pelayaran Nasional Indonesia (Persero) pada tahun 2017 telah hilang karena adanya *human*

error. Data pada tahun 2017 penting karena digunakan oleh pihak manajemen PT Pelayaran Nasional Indonesia (Persero) untuk melakukan prediksi jumlah penumpang kapal laut untuk beberapa tahun ke depan. Prediksi ini penting karena arus mudik menggunakan transportasi laut akan semakin meningkat seiring dengan naiknya harga tiket pesawat terbang. Selain itu, penelitian ini juga dimaksudkan untuk mengetahui pola penumpang angkutan laut jika terdapat momen perayaan tertentu seperti Hari Raya Idul Fitri secara statistik.

1.5 Batasan Masalah

Ruang lingkup pembahasan dibatasi pada jumlah penumpang angkutan laut tahun 2012 hingga tahun 2016 karena data yang disediakan oleh PT Pelayaran Nasional Indonesia (Persero) juga terbatas. Rute yang digunakan adalah 1 rute kapal penumpang dari PT Pelayaran Nasional Indonesia (Persero).

(Halaman ini sengaja dikosongkan)

BAB II TINJAUAN PUSTAKA

Tinjauan pustaka pada bab ini membahas mengenai metode *time series*, uji stasioneritas data, ACF, PACF, uji asumsi *white noise*, ARIMA, regresi *time series* dengan efek variasi kalender dengan residual data dimodelkan dengan ARIMA, dan kriteria pemilihan model yang dipakai pada penelitian.

2.1 Metode *Time Series*

Deret Waktu (*Time series*) adalah serangkaian pengamatan terhadap suatu variabel yang diambil dari waktu ke waktu dan dicatat secara berurutan menurut urutan waktu kejadian dengan interval waktu yang tetap (Wei, 2006). *Time series* dapat juga diartikan sebagai serangkaian data yang didapatkan berdasarkan pengamatan dari suatu kejadian pada urutan waktu terjadinya. Waktu kejadian bisa merupakan periode dalam satuan detik, menit, jam, hari, bulan, tahun dan periode waktu yang lainnya, semua hal tersebut merupakan serangkaian data pengamatan yang didasarkan pada waktu kejadian dengan interval waktu tertentu yang lebih dikenal dengan *time series* (Cryer & Chan, 2008), dimana setiap pengamatan dinyatakan sebagai variabel random Z_t yang didapatkan berdasarkan indeks waktu tertentu (t_i) sebagai urutan waktu pengamatan, sehingga penulisan data *time series* adalah $Z_{t1}, Z_{t2}, Z_{t3}, \dots, Z_m$. Dalam metode *time series* ada beberapa hal yang perlu diperhatikan, yaitu kestasioneran data, fungsi autokorelasi, dan fungsi autokorelasi parsial.

2.1.1 Stasioneritas Data

Data *time series* dikatakan stasioner apabila dalam *mean* dan varians berfluktuasi secara konstan dari waktu ke waktu. Untuk memeriksa kestasioneran data dapat menggunakan plot *Box-Cox* dan *time series* plot ACF. Stasioneritas terhadap varians adalah apabila data berfluktuasi di sekitar nilai varians yang konstan, artinya data memiliki keragaman yang homogen.

Pengujian stasioneritas terhadap varians dapat dilakukan dengan menggunakan pengujian Bartlett. Hipotesis yang digunakan dalam pengujian Bartlett yaitu $H_0 : \sigma_1^2 = \sigma_2^2 = \dots = \sigma_k^2$ (data telah stasioner terhadap varians) dan $H_1 : \exists \sigma_i^2 \neq \sigma_j^2, i \neq j$ (data tidak stasioner terhadap varians) dengan $i, j = 1, 2, \dots, k$. Statistik pengujian Bartlett disajikan pada persamaan (2.1) (Johnson & Winchern, 2007).

$$B = \frac{\left[\sum_{i=1}^k v_i \times \ln \left(\frac{\sum_{i=1}^k v_i s_i^2}{\sum_{i=1}^k v_i} \right) \right] - \left[\sum_{i=1}^k v_i \times \ln s_i^2 \right]}{\sum_{i=1}^k \frac{1}{v_i} - \frac{1}{\sum_{i=1}^k v_i}}, \quad (2.1)$$

$$1 + \frac{1}{3 \times (k-1)}$$

dengan $s_i^2 = \sum_{j=1}^{n_i} (x_{ij} - \bar{x})^2 / (n_i - 1)$,

$k =$ jumlah sampel,

$n_i =$ jumlah unit penelitian pada sampel ke- i ,

$v_i = n_i - 1$.

Daerah penolakan yang digunakan adalah hipotesis nol ditolak jika nilai statistik uji lebih besar dari nilai kritis atau jika nilai *p-value* kurang dari nilai taraf signifikan. Nilai kritis menggunakan $\chi_{(k-1, \alpha)}^2$.

Pemeriksaan stasioneritas terhadap varians dapat dilihat melalui plot *Box Cox*. Terdapat kemungkinan terjadinya data tidak stasioner terhadap varians, maka ketidakstasioneran tersebut dapat diatasi dengan menggunakan transformasi *Box-Cox* yang ditunjukkan oleh persamaan (2.2) (Wei, 2006).

$$T(Z_i) = \frac{Z_i^\lambda - 1}{\lambda}, \text{ dimana } \lambda \neq 0 \quad (2.2)$$

dimana nilai λ merupakan parameter transformasi, untuk $\lambda = 0$ dilakukan pendekatan sesuai persamaan (2.3).

$$\lim_{\lambda \rightarrow 0} (Z_t) = \lim_{\lambda \rightarrow 0} Z_t^\lambda = \lim_{\lambda \rightarrow 0} \frac{Z_t^\lambda - 1}{\lambda} = \ln(Z_t), \quad (2.3)$$

hasil transformasi bergantung pada nilai λ yang digunakan. Transformasi dilakukan apabila estimasi λ berada pada interval -1 hingga 0,5. Apabila estimasi λ diluar interval tersebut, maka tidak perlu dilakukan transformasi atau data stasioner terhadap varians. Jenis-jenis transformasi *Box-Cox* sesuai dengan estimasi λ ditunjukkan oleh Tabel 2.1.

Tabel 2.1 Transformasi *Box-Cox*

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

Sedangkan stasioner terhadap *mean* adalah fluktuasi data yang berada disekitar nilai *mean* yang konstan. Secara visual stasioneritas data terhadap mean dapat dilihat dari plot ACF. Apabila dalam plot ACF yang terbentuk banyak lag yang signifikan dan lag turun lambat, maka mengindikasikan bahwa data belum stasioner terhadap mean. Untuk pengujian stasioneritas terhadap mean dilakukan uji *unit root* menggunakan uji *Dickey-Fuller* (DF). Hipotesis yang digunakan dalam pengujian tersebut adalah $H_0 : \delta = 0$ (data belum stasioner terhadap *mean*) dan $H_1 : \delta < 0$ (data telah stasioner terhadap *mean*), dengan nilai $\delta = (\rho - 1)$ dan

$-1 < \delta < 1$. Statistik uji yang digunakan yaitu $\hat{\tau} = \frac{\delta - 1}{se(\delta)}$. Hipotesis

nol akan ditolak apabila nilai dari $|\hat{\tau}|$ lebih besar dari $\tau_{DF(n)}$ atau jika nilai *p-value* kurang dari nilai taraf signifikan (Gujarati & Porter, 2009).

Karena uji DF hanya terbatas pada proses *autoregressive* orde satu maka dikembangkan pengujian *Augmented Dickey Fuller* (ADF) yang dapat merepresentasikan persamaan *autoregressive* dengan orde yang lebih tinggi dengan persamaan (2.4) (Enders, 2004).

$$\Delta Z_t = \beta_0 + \beta_1 t + \delta Z_{t-1} + \sum_{i=1}^m \alpha_i \Delta Z_{t-i} + a_t, \quad (2.4)$$

dengan a_t = komponen residual,

Z_t = data *series*,

ΔZ_{t-i} = $(Z_{t-i} - Z_{t-i-1})$,

ΔZ_{t-2} = $(Z_{t-2} - Z_{t-3})$, dan seterusnya,

β_0 = intersept,

β_1 = tren stokastik,

δ = koefisien dari Z_{t-1} ,

α = koefisien dari ΔZ_{t-i} .

Apabila data tidak stasioner terhadap *mean*, maka perlu dilakukan *differencing* atau metode pembedaan (Wei, 2006). Proses *differencing* ditunjukkan oleh persamaan (2.5).

$$Y_t = Z_t - Z_{t-1}, \quad (2.5)$$

dengan Y_t = data hasil proses *differencing*,

Z_t = data pada waktu ke- t ,

Z_{t-1} = data pada waktu $t-1$.

2.1.2 Autocorrelation Function (ACF)

Autocorrelation Function (ACF) adalah hubungan linier antara Z_t dengan Z_{t+k} pada suatu data *time series*. Apabila nilai ACF diplotkan, maka plot tersebut dapat digunakan untuk memeriksa stasioneritas terhadap *mean*. Fungsi ACF ditunjukkan oleh persamaan (2.6) (Wei, 2006).

$$\hat{\rho}_k = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2}; k = 0, 1, 2, \dots, \quad (2.6)$$

dengan batas untuk nilai autokorelasi ditunjukkan oleh persamaan (2.7).

$$\hat{\rho}_k \pm t_{\frac{\alpha}{2}, df} (se(\hat{\rho}_k)) \quad (2.7)$$

dengan $se(\hat{\rho}_k) = \sqrt{\frac{1}{n}(1 + 2\hat{\rho}_1 + \dots + 2\hat{\rho}_m^2)}$ dimana $m = k - 1$,

$$\bar{Z} = \frac{1}{n} \sum_{t=1}^n Z_t \text{ adalah nilai rata-rata data } time \text{ series,}$$

$$Z_t = \text{pengamatan pada waktu ke-} t ,$$

$$Z_{t+k} = \text{pengamatan pada waktu ke-} t \text{ dan lag ke-} k ,$$

$$\hat{\rho}_k = \text{taksiran autokorelasi data } insample \text{ lag ke-} k .$$

2.1.3 Partial Autocorrelation Function (PACF)

Partial Autocorrelation Function (PACF) merupakan su-atau fungsi untuk mengetahui nilai korelasi antara Z_t dengan Z_{t+k} setelah terdapat pengaruh dari variabel $Z_{t+1}, Z_{t+2}, \dots, Z_{t+k-1}$ dihilangkan. Jika Z_t merupakan data *time series* berdistribusi normal maka,

$$\phi_{kk} = corr(Z_t, Z_{t+k} | Z_{t+1}, Z_{t+2}, \dots, Z_{t+k-1}) . \quad (2.8)$$

Metode umum dalam menentukan fungsi autokorelasi parsial untuk setiap proses stasioner dengan fungsi autokorelasi ρ_k sesuai dengan persamaan (2.7).

$$\begin{aligned} \phi_{k1} + \rho_1 \phi_{k2} + \rho_2 \phi_{k3} + \dots + \rho_{k-1} \phi_{kk} &= \rho_1 \\ \rho_1 \phi_{k1} + \phi_{k2} + \rho_2 \phi_{k3} + \dots + \rho_{k-1} \phi_{kk} &= \rho_2 \\ \vdots & \\ \rho_{k-1} \phi_{k1} + \rho_{k-2} \phi_{k2} + \rho_{k-3} \phi_{k3} + \dots + \phi_{kk} &= \rho_k . \end{aligned} \quad (2.9)$$

Levinson (1947) dan Durbin (1960) dalam (Cryer & Chan, 2008) memberikan metode yang efisien untuk solusi persamaan (2.8) dan menunjukkan bahwa secara independen per-samaan (2.9) dapat diselesaikan secara rekursif dengan persamaan (2.10) (Wei, 2006).

$$\hat{\phi}_{k+1,k+1} = \frac{\hat{\rho}_{k+1} - \sum_{j=1}^{k-1} \phi_{kj} \hat{\rho}_{k+1-j}}{1 - \sum_{j=1}^k \phi_{kj} \hat{\rho}_j}, \quad (2.10)$$

dengan batas untuk nilai PACF ditunjukkan oleh persamaan (2.11).

$$\pm t_{\frac{\alpha}{2}, df} \left(se \left(\hat{\phi}_{kk} \right) \right), \quad (2.11)$$

dengan $se \left(\hat{\phi}_{kk} \right) = \sqrt{\frac{1}{n}}$ dimana $\hat{\rho}_j$ adalah fungsi autokorelasi dari *insample* setelah lag ke- j .

2.2 ARIMA Box-Jenkins

ARIMA *Box-Jenkins* adalah salah satu metode untuk meramalkan suatu data yang berbasis *time series*. Model ARIMA *Box-Jenkins* merupakan gabungan antara model *Autoregressive* (AR) dan *Moving Average* (MA) dengan sebuah proses *differencing*. Berikut adalah prosedur peramalan menggunakan metode ARIMA *Box-Jenkins*.

2.2.1 Identifikasi Model

Identifikasi model adalah suatu tahapan yang harus dilakukan sebelum mendapatkan model guna meramalkan atau memprediksikan suatu data. Tahap identifikasi model terbagi menjadi dua, yaitu pemeriksaan pola data dan penentuan model. Pemeriksaan pola data dapat dilakukan dengan menggunakan *time series plot* dan plot ACF. Sedangkan untuk penentuan model dapat dilakukan dengan melihat plot ACF dan plot PACF. Ketentuan dalam mendapatkan model tertera pada Tabel 2.2 (Wei, 2006).

Tabel 2.2 Bentuk ACF dan PACF model ARIMA

Model	ACF	PACF
AR (p)	<i>Dies down</i>	<i>Cuts off after lag p</i>

Tabel 2.2 Bentuk ACF dan PACF model ARIMA (Lanjutan)

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

Persamaan model yang digunakan pada metode ARIMA *Box-Jenkins* adalah model AR, MA, dan ARMA.

1. Model Autoregressive (AR)

Model *autoregressive* (AR) orde p menyatakan bahwa suatu model pada pengamatan waktu ke- t merupakan kombinasi *linear* dari pengamatan sebelum $t-1, t-2, \dots, t-p$. Model *autoregressive* dengan orde p dapat didefinisikan AR(p) dengan persamaan (2.12).

$$\begin{aligned} \phi_p(B)\dot{Z}_t &= a_t \\ \dot{Z}_t &= \phi_1\dot{Z}_{t-1} + \phi_2\dot{Z}_{t-2} + \dots + \phi_p\dot{Z}_{t-p} + a_t, \end{aligned} \quad (2.12)$$

dengan ϕ_j = parameter AR pada lag ke- j dengan $j = 1, 2, \dots, p$,

$$\dot{Z}_t = Z_t - \mu,$$

Z_t = data *time series* pada waktu ke- t ,

a_t = residual pada waktu ke- t .

2. Model Moving Average (MA)

Model *moving average* (MA) orde q menyatakan bahwa suatu model pada pengamatan waktu ke- t dipengaruhi oleh kesa-lahan masa lalu. Model dari *moving average* orde q dituliskan dalam persamaan (2.13).

$$\begin{aligned} \dot{Z}_t &= \theta_q(B)a_t \\ \dot{Z}_t &= a_t - \theta_1a_{t-1} - \theta_2a_{t-2} - \dots - \theta_qa_{t-q}, \end{aligned} \quad (2.13)$$

dengan θ_l = parameter MA pada lag ke- l dengan $l = 1, 2, \dots, q$,

$$\dot{Z}_t = Z_t - \mu,$$

Z_t = data *time series* pada waktu ke- t ,

a_t = residual pada waktu ke- t .

3. Model *Autoregressive Moving Average* (ARMA)

Model dari *autoregressive moving average* pada orde p dan q dituliskan dengan persamaan (2.14).

$$\begin{aligned} \phi_p(B)\dot{Z}_t &= \theta_q(B)a_t \\ \dot{Z}_t &= \phi_1\dot{Z}_{t-1} + \dots + \phi_p\dot{Z}_{t-p} + a_t - \theta_1a_{t-1} - \dots - \theta_qa_{t-q}, \end{aligned} \quad (2.14)$$

dengan ϕ_p = parameter AR pada lag ke- j dengan $j=1,2,\dots,p$,

θ_q = parameter MA pada lag ke- l dengan $l=1,2,\dots,q$,

$$\dot{Z}_t = Z_t - \mu,$$

Z_t = data *time series* pada waktu ke- t ,

a_t = residual pada waktu ke- t .

4. Model *Autoregressive Integrated Moving Average* (ARIMA)

Model ini merupakan gabungan antara model *autoregressive* dan *moving average* dengan adanya pembedaan atau *differencing* (d) yang disebabkan karena ketidakstasioneran dalam mean. Sehingga model ARIMA (p,d,q) dapat dituliskan dengan persamaan (2.15).

$$\phi_p(B)(1-B)^d\dot{Z}_t = \theta_q(B)a_t, \quad (2.15)$$

dengan $\theta_q(B) = (1 - \theta_1B - \dots - \theta_qB^q)$,

$$\phi_p(B) = (1 - \phi_1B - \dots - \phi_pB^p),$$

ϕ_0 = koefisien tren deterministik,

ϕ_p = parameter AR pada lag ke- j dengan $j=1,2,\dots,p$,

θ_q = parameter MA pada lag ke- l dengan $l=1,2,\dots,q$,

$$\dot{Z}_t = Z_t - \mu,$$

Z_t = data *time series* pada waktu ke- t ,

p = orde *Autoregressive* (AR),

d = orde *differencing*,
 q = orde *Moving Average* (MA),
 a_t = residual pada waktu ke- t .

5. Model ARIMA *Restricted*

Model ARIMA *restricted* ini digunakan pada data *time series* yang menurut identifikasi plot ACF dan PACF hanya lag tertentu yang keluar dari batas, misalnya untuk orde AR([1,4]) dapat dituliskan dengan persamaan (2.16)

$$\begin{aligned}
 (1 - \phi_1 B - \phi_4 B^4) \dot{Z}_t &= a_t, \\
 \dot{Z}_t &= \phi_1 \dot{Z}_{t-1} + \phi_4 \dot{Z}_{t-4} + a_t
 \end{aligned}
 \tag{2.16}$$

dengan ϕ_1 = parameter AR pada lag ke-1 ,
 ϕ_4 = parameter AR pada lag ke-4 ,
 $\dot{Z}_t = Z_t - \mu$,
 Z_t = data *time series* pada waktu ke- t ,
 a_t = residual pada waktu ke- t .

6. Model ARIMA Musiman

Model ARIMA musiman ini digunakan pada data *time series* yang memiliki faktor musiman. Model ARIMA musiman dapat dituliskan dalam persamaan (2.17).

$$\Phi_p(B^s) \phi_p(B)^d (1 - B^s)^D \dot{Z}_t = \theta_q(B) \Theta_Q(B^s) a_t, \tag{2.17}$$

dengan ϕ_p = parameter AR pada lag ke- j dengan $j = 1, 2, \dots, p$,
 Φ_p = parameter AR musiman pada lag ke- J dengan $J = 1, 2, \dots, P$,
 θ_q = parameter MA pada lag ke- l dengan $l = 1, 2, \dots, q$,
 Θ_Q = parameter MA musiman pada lag ke- L dengan $L = 1, 2, \dots, Q$,
 $\dot{Z}_t = Z_t - \mu$,
 Z_t = data *time series* pada waktu ke- t ,
 a_t = residual pada waktu ke- t .

2.2.2 Estimasi dan Pengujian Parameter

Estimasi parameter pada model ARIMA menggunakan metode *Conditional Least Square*. Metode ini dilakukan dengan cara mencari nilai parameter dengan meminimumkan jumlah kua-drat *error* (SSE). Misalkan diterapkan pada model AR(1) maka dapat dinyatakan sesuai dengan persamaan (2.18) (Cryer & Chan, 2008).

$$Z_t - \mu = \phi(Z_{t-1} - \mu) + a_t, \quad (2.18)$$

dengan nilai SSE ditunjukkan oleh persamaan (2.19).

$$S(\phi, \mu) = \sum_{t=2}^n a_t^2 = \sum_{t=2}^n [(Z_t - \mu) - \phi(Z_{t-1} - \mu)]^2, \quad (2.19)$$

kemudian diturunkan terhadap μ dan ϕ kemudian disamakan dengan nol sehingga diperoleh taksiran parameter untuk μ yang dinyatakan pada persamaan (2.20).

$$\hat{\mu} = \frac{\sum_{t=2}^n Z_t - \phi \sum_{t=2}^n Z_{t-1}}{(n-1)(1-\phi)}, \quad (2.20)$$

dan nilai taksiran parameter ϕ yang dinyatakan pada persamaan (2.21).

$$\hat{\phi} = \frac{\sum_{t=2}^n (Z_t - \bar{Z})(Z_{t-1} - \bar{Z})}{\sum_{t=2}^n (Z_{t-1} - \bar{Z})^2}, \quad (2.21)$$

langkah selanjutnya setelah memperoleh estimasi parameter adalah melakukan uji signifikansi parameter. Pengujian ini dilakukan untuk menguji kelayakan parameter yang masuk ke dalam suatu model. Hipotesis yang digunakan untuk melakukan uji signifikansi parameter model AR adalah $H_0 : \phi_j = 0$ (parameter tidak signifikan) dan nilai $H_1 : \phi_j \neq 0$ (parameter signifikan). Statistik uji yang digunakan dinyatakan pada persamaan (2.22).

$$t_{hitung} = \frac{\hat{\phi}_j}{SE(\hat{\phi}_j)}, \quad (2.22)$$

dengan $SE(\hat{\phi}_i)$ = standar *error* estimasi parameter model AR. Hipotesis nol ditolak apabila nilai dari $|t_{hitung}|$ lebih besar dari nilai $t_{\alpha/2(n-p)}$ dengan n merupakan banyaknya pengamatan dan p merupakan banyaknya parameter yang diestimasi. Hipotesis yang digunakan untuk melakukan uji signifikansi parameter model MA adalah $H_0 : \theta_i = 0$ (parameter tidak signifikan) dan nilai $H_1 : \theta_i \neq 0$ (parameter signifikan). Statistik uji yang digunakan dinyatakan pada persamaan (2.23).

$$t_{hitung} = \frac{\hat{\theta}_i}{SE(\hat{\theta}_i)}, \quad (2.23)$$

dengan $SE(\theta_i)$ = standar *error* estimasi parameter model MA. Hipotesis nol ditolak apabila nilai dari $|t_{hitung}|$ lebih besar dari nilai $t_{\alpha/2(n-p)}$ dengan n merupakan banyaknya pengamatan dan p merupakan banyaknya parameter yang diestimasi. Setelah model diperoleh dan parameter telah diuji signifikansi, maka harus dilakukan pengujian asumsi residual. Pengujian asumsi residual berguna untuk menguji kesesuaian model.

2.2.3 Asumsi *White Noise*

Residual bersifat *white noise* jika terdapat korelasi antar residual dengan *mean* adalah nol dan varians konstan. Plot residual dapat digunakan untuk melihat apakah varians residual konstan, sedangkan untuk melihat residual bersifat *white noise* dapat dilakukan dengan menggunakan pengujian Ljung-Box. Pengujian ini dilakukan dengan menggunakan autokorelasi dari residual sampel (Wei, 2006). Hipotesis yang digunakan dalam pengujian ini adalah $H_0 : \rho_1 = \rho_2 = \dots = \rho_k = 0$ (residual pada lag ke- k memenuhi asumsi *white noise*) dan H_1 : minimal ada satu nilai $\rho_k \neq 0$. Statistik uji yang digunakan dalam penelitian ini dinyatakan pada persamaan (2.24).

$$Q^* = n(n+2) \sum_{k=1}^K (n-k)^{-1} \hat{\rho}_k^2, \quad (2.24)$$

dengan $k = 1, 2, \dots, K$
 $\hat{\rho}_k^2$ = ACF residual pada lag ke- k ,
 K = jumlah lag maksimum,
 n = banyaknya pengamatan,
 p = orde *Autoregressive* (AR),
 q = orde *Moving Average* (MA),
 α = nilai taraf signifikan.

Daerah penolakan yang digunakan adalah hipotesis nol ditolak jika nilai statistik uji lebih besar dari nilai kritis. Nilai kritis menggunakan $\chi_{(K-p-q, \alpha)}^2$.

2.2.4 Asumsi Residual Distribusi Normal

Uji asumsi kenormalan residual digunakan adalah uji normalitas metode *Kolmogorov-Smirnov* (Daniel, 1989). Hipotesis yang digunakan dalam pengujian ini adalah $H_0 : F(a_t) = F_0(a_t)$ (residual berdistribusi normal) dan $H_1 : F(a_t) \neq F_0(a_t)$ (residual tidak berdistribusi normal). Statistik uji yang digunakan dalam pengujian asumsi *white noise* ditunjukkan oleh persamaan (2.25).

$$D = \text{Sup} |F(\varepsilon_t) - F_0(\varepsilon_t)|, \quad (2.25)$$

dengan $F_0(\varepsilon_t)$ = fungsi peluang kumulatif distribusi normal,

$F(\varepsilon_t)$ = fungsi distribusi yang belum diketahui,

Sup = nilai maksimum dari $|F(\varepsilon_t) - F_0(\varepsilon_t)|$.

ε_t = residual data ke- t .

Daerah penolakan yang digunakan adalah H_0 ditolak jika nilai statistik uji lebih besar dari nilai kritis. Nilai kritis menggunakan tabel *Kolmogorov-Smirnov* dengan derajat bebas adalah n , dimana n merupakan banyaknya observasi.

2.3 Regresi *Time Series* Efek Variasi Kalender

Regression with Autocorelated Errors sering disebut juga dengan regresi *time series*. Model regresi *time series* merupakan model yang menghubungkan variabel dependen Y_t dengan fungsi waktu. Model ini bermanfaat saat parameter yang menjelaskan peramalan *time series* berada pada kondisi konstan secara terus menerus (Bowerman & O'Connell, 2005).

Berbeda dengan model regresi konvensional, regresi *time series* merupakan fungsi antara satu variabel respon dengan satu atau lebih variabel prediktor dimana kedua variabel tersebut bersyarat pada waktu. Secara umum model regresi *time series* dapat ditulis sesuai persamaan (2.26) (Wei, 2006).

$$Y_t = \beta_1 X_{1,t} + \beta_2 X_{2,t} + \dots + \beta_i X_{i,t} + \varepsilon_t, \quad (2.26)$$

atau dengan persamaan (2.27)

$$\mathbf{Y}_t = \mathbf{X}_t' \boldsymbol{\beta} + \varepsilon_t, \quad (2.27)$$

dengan \mathbf{Y}_t = respon regresi *time series*,

$\boldsymbol{\beta}_t$ = vektor parameter regresi *time series*,

\mathbf{X}_t = vektor prediktor regresi *time series*,

ε_t = residual data ke- t ,

variabel \mathbf{X}_t pada penelitian ini adalah variabel $M_{i,t}$ sebagai *dummy* bulan dan R_{t-1}, R_t, R_{t+1} berturut-turut sebagai *dummy* 1 bulan sebelum bulan hari raya Idul Fitri, *dummy* bulan hari raya Idul Fitri, dan *dummy* 1 bulan setelah bulan hari raya Idul Fitri.

Pada penelitian ini $X_{j,t}$ adalah variabel *dummy* untuk efek variasi kalender ke- k . Jumlah variabel *dummy* yang menyatakan efek variasi kalender dapat diidentifikasi berdasarkan *time series* plot dari data. Statistik Ljung-Box digunakan untuk menguji resi-dual *white noise*. Jika residual belum *white noise* maka lag Y_t di-gunakan sebagai variabel independen. Pemilihan lag yang sesuai pada model berdasarkan ACF dan PACF (Suhartono, Lee, & Hamzah, 2010).

Apabila residual tidak berdistribusi normal maka akan dilakukan deteksi *outlier* dengan menambahkan *outlier* ke dalam model regresi sebagai variabel independen. Cara mendeteksi *outlier* menggunakan nilai *deleted (studentized) residual*. Pengamatan dengan *deleted residual* lebih dari 3 atau 4 dinyatakan *outlier*. Proses perhitungan *deleted residual* ditunjukkan oleh persamaan (2.28) (Bowerman & O'Connell, 2005).

$$t^* = \frac{\varepsilon_t}{\sqrt{s^2(1-h_t)}} = \varepsilon_t \sqrt{\frac{n-n_p-1}{SSE(1-h_t)-\varepsilon_t^2}}, \quad (2.28)$$

dimana ε_t = residual data ke- t ,
 h_t = elemen diagonal ke- t dari matriks $\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'$,
 n = jumlah pengamatan,
 s^2 = MSE yang dihitung setelah menghilangkan observasi ke- t ,
 n_p = jumlah parameter dalam model.

2.4 Pemeriksaan Asumsi Residual

Apabila metode regresi dilakukan maka residual data harus memenuhi asumsi identik, independen, dan distribusi normal. Residual data berdistribusi normal dijelaskan pada subbab 2.2.4 sehingga pada subbab ini membahas mengenai residual data identik dan independen.

2.4.1 Pemeriksaan Asumsi Residual Identik

Uji residual identik dilakukan untuk melihat apakah residual memenuhi asumsi identik. Secara visual suatu data dikatakan identik apabila plot residualnya menyebar secara acak dan tidak membentuk suatu pola tertentu. Asumsi identik terpenuhi apabila $\text{var}(\varepsilon_i) = \sigma^2$ atau nilai varians rata-rata homogen antara varians satu dengan yang lainnya. Pemeriksaan residual identik bisa dilihat dengan cara plot *residual versus fits* dan bisa dihitung menggunakan uji Glejser dengan hipotesis

adalah $H_0 : \beta_0 = \beta_1 = \beta_2 = \dots = \beta_p = 0$ (asumsi residual identik terpenuhi) dan $H_1 : \text{minimal ada satu } \beta_i \neq 0 \text{ dengan } i = 1, 2, \dots, p$ (asumsi residual identik tidak terpenuhi). Statistik uji yang digunakan dinyatakan pada persamaan (2.29).

$$F = \frac{MSR}{MSE}, \quad (2.29)$$

dengan $MSR = \text{Mean Square Regression}$,

$MSE = \text{Mean Square Error}$.

Hipotesis nol ditolak apabila nilai dari F lebih besar dari nilai $F_{\alpha, (p, n-p)}$ dengan n merupakan banyaknya pengamatan dan p merupakan banyaknya parameter yang diestimasi (Gujarati & Porter, 2009).

2.4.2 Pemeriksaan Asumsi Residual Independen

Pemeriksaan residual independen dilakukan untuk melihat apakah residual memenuhi asumsi independen. Suatu data dikatakan independen apabila plot residualnya menyebar secara acak dan tidak membentuk suatu pola tertentu. Pemeriksaan asumsi residual independen bisa dilihat dengan cara *visual versus order* dan bisa menggunakan statistik inferensia yaitu uji Durbin-Watson (Gujarati & Porter, 2009). Statistik uji yang digunakan dinyatakan pada persamaan (2.30).

$$d = \frac{\sum_{t=2}^n (\varepsilon_t - \varepsilon_{t-1})^2}{\sum_{t=1}^n \varepsilon_t^2}, \quad (2.30)$$

dimana ε_t = residual data ke- t ,

ε_{t-1} = residual data ke- $t-1$.

Apabila asumsi independensi tidak terpenuhi maka bisa jadi residual data memiliki autokorelasi positif atau autokorelasi negatif. Terdapat beberapa hipotesis dari uji Durbin-Watson. Hipotesis pertama adalah $H_0 : \rho = 0$ yang berarti asumsi residual independen terpenuhi dan $H_1 : \rho > 0$ yang berarti asumsi residual inde-

penden tidak terpenuhi dan terjadi autokorelasi positif. Tolak H_0 jika nilai d lebih kecil dari nilai du pada tabel Durbin-Watson. Hipotesis kedua adalah $H_0 : \rho = 0$ yang berarti asumsi residual independen terpenuhi dan $H_1 : \rho < 0$ yang berarti asumsi residual inde-penden tidak terpenuhi dan terjadi autokorelasi negatif. Tolak hipotesis nol jika nilai $4-d$ lebih kecil dari nilai du pada tabel Durbin-Watson.

2.5 Pemilihan Model Terbaik

Pemilihan model terbaik atau seleksi model dilakukan jika terdapat lebih dari satu model time series yang layak dipakai yaitu dengan menggunakan dua pendekatan diantaranya pendekatan *insample* dan pendekatan *outsample*.

AIC (Akaike's Information Criterion) merupakan indikator kebaikan model yang pertama. *AIC* adalah suatu indikator pemilihan model terbaik yang diperkenalkan oleh Akaike pada tahun 1973 dengan mempertimbangkan banyaknya parameter dalam model. Kriteria *AIC* ditunjukkan pada persamaan (2.31) (Akaike, 1973).

$$AIC = n \ln \left(\frac{SSE}{n} \right) + 2f + n(1 + \ln(2\pi)), \quad (2.31)$$

dengan n = banyaknya pengamatan,
 f = banyaknya parameter dalam model,
 SSE = jumlah kuadrat *error*.

MAPE (Mean Absolute Presentage Error) merupakan indikator kebaikan model yang kedua. *MAPE* digunakan untuk data *outsample*. Nilai berkaitan dengan presentase residual (Wei, 2006). Proses perhitungan *MAPE* ditunjukkan oleh persamaan (2.32).1

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|Z_t - \hat{Z}_t|}{Z_t} \times 100 \%, \quad (2.32)$$

dengan n = jumlah pengamatan,
 Z_t = data aktual pada periode ke- t ,

\hat{Z}_t = data ramalan pada periode ke- t .

Nilai MAPE berkisar antara 0% hingga 100% sehingga nilai yang dihasilkan lebih mudah untuk diinterpretasi.

2.6 PT. Pelayaran Nasional Indonesia (Persero)

PT. Pelayaran Nasional Indonesia (Persero) adalah perusahaan pelayaran nasional yang menyediakan jasa transportasi laut, meliputi jasa angkutan penumpang, dan muatan barang antar pulau. Saat ini perusahaan mengoperasikan 26 kapal penumpang, 46 kapal perintis, 6 kapal barang tol laut, dan 1 kapal ternak.

PT. Pelayaran Nasional Indonesia (Persero) dalam melaksanakan tanggung jawab tidak hanya terbatas melayani rute komersial, tetapi juga melayani pelayaran dengan rute pulau-pulau kecil terluar. Saat ini kapal Pelnis menyinggahi 95 pelabuhan kapal penumpang dan lebih dari 300 pelabuhan kapal perintis dengan 46 kantor cabang dan dilayani di 400 travel agen yang tersebar di seluruh Indonesia.

Salah satu kantor cabang yang dimiliki PT. Pelayaran Nasional Indonesia (Persero) adalah kantor cabang Surabaya. PT. Pelayaran Nasional Indonesia (Persero) cabang Surabaya melayani pelayaran untuk 9 rute kapal penumpang, salah satunya adalah pelayaran dengan pelabuhan tujuan Jayapura. Rute Surabaya-Jayapura merupakan rute terpanjang dari semua rute yang dimiliki PT. Pelayaran Nasional Indonesia (Persero) cabang Surabaya.

Rute Surabaya-Jayapura menyinggahi beberapa pelabuhan diantaranya adalah Pelabuhan Balikpapan, Pantoloan (Donggala), Bitung, Ternate, Sorong, Manokwari, Nabire, Serui, hingga akhirnya tiba di Pelabuhan Jayapura. Rute tersebut hanya dilayani oleh satu kapal penumpang yaitu Kapal Labobar. Kapal tersebut beroperasi dengan 161 awak kapal dengan kapasitas penumpang maksimal yaitu 3076 penumpang.

(Halaman ini sengaja dikosongkan)

BAB III METODOLOGI PENELITIAN

3.1 Sumber Data

Data yang digunakan dalam penelitian ini adalah data sekunder yang diperoleh dari PT. Pelayaran Nasional Indonesia (Persero), yaitu data jumlah penumpang angkutan laut dari Januari 2012 hingga Desember 2016. Selain itu diperlukan informasi mengenai waktu terjadinya Bulan Ramadhan dan Hari Raya Idul Fitri.

3.2 Variabel Penelitian

Rute kapal penumpang PT Pelayaran Nasional Indonesia (Persero) yang digunakan dalam penelitian ini adalah dari Pelabuhan Tanjung Perak menuju Pelabuhan Jayapura. Pelabuhan yang dilewati antara kedua pelabuhan tersebut antara lain adalah Pelabuhan Balikpapan, Pantoloan (Donggala), Bitung, Ternate, Sorong, Manokwari, Nabire, dan Serui.

Variabel yang digunakan dalam penelitian ini terdiri dari variabel respon dan variabel prediktor. Berdasarkan rute yang diuraikan tersebut maka variabel respon yang digunakan adalah sebagai berikut.

Z_t : Jumlah penumpang angkutan laut rute Tanjung Perak – Jayapura.

Variabel prediktor yang digunakan dalam penelitian ini merupakan variabel *dummy* yaitu *dummy* bulan dan Hari Raya Idul Fitri. *Dummy* variabel prediktor secara lengkap dijelaskan oleh Tabel 3.1.

Tabel 3.1 Variabel Prediktor

No	Variabel Prediktor	Kategorik	
1	<i>Dummy</i> Bulan	$M_{1,t}$	1 = Bulan ke- t adalah Bulan Januari. 0 = Lainnya.
		$M_{2,t}$	1 = Bulan ke- t adalah Bulan Februari. 0 = Lainnya.

Tabel 3.1 Variabel Prediktor (Lanjutan)

No	Variabel Prediktor	Kategorik	
1	<i>Dummy</i> Bulan	\vdots	\vdots
		$M_{12,t}$	1 = Bulan ke- t adalah Bulan Desember. 0 = Lainnya.
2	<i>Dummy</i> Bulan Hari Raya Idul Fitri	R_{t-1}	1 = Bulan ke- $t-1$ adalah 1 bulan sebelum Idul Fitri. 0 = Lainnya.
		R_t	1 = Bulan terjadi Idul Fitri. 0 = Lainnya.
		R_{t+1}	1 = Bulan ke- $t+1$ adalah 1 bulan sesudah Idul Fitri. 0 = Lainnya.

Gambaran struktur data dalam penelitian ini dijelaskan oleh Tabel 3.2 sebagai berikut.

Tabel 3.2 Struktur Data Penelitian

Z_t	t	$M_{1,t}$...	$M_{12,t}$	R_{t-1}	R_t	R_{t+1}
Z_1	1	1		0	1	0	0
Z_2	2	1		0	0	1	0
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
Z_n	n	0		0	0	0	0

Bulan terjadinya Hari Raya Idul Fitri pada tahun 2012 hingga tahun 2017 ditampilkan pada Tabel 3.3.

Tabel 3.3 Bulan Hari Raya Idul Fitri

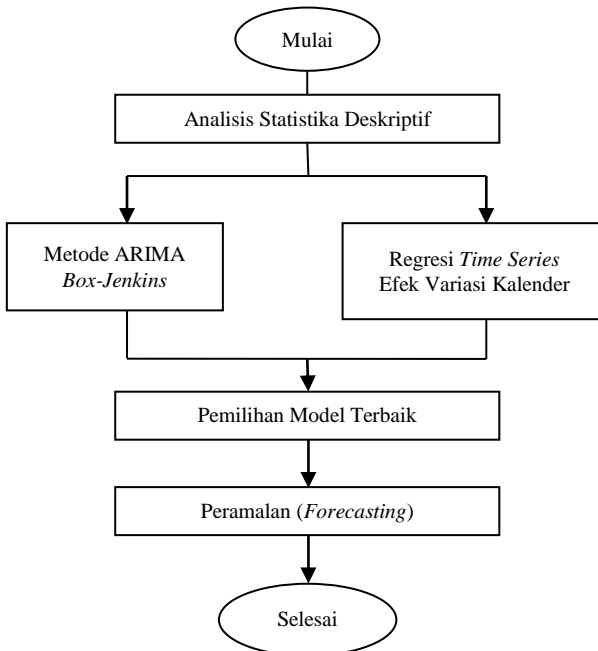
Tahun	2012	2013	2014	2015	2016	2017
Bulan	Agustus	Agustus	Juli	Juli	Juli	Juni

3.3 Langkah Penelitian

Data dibagi menjadi dua bagian, yaitu data *insample* dan *outsample*. Data *insample* adalah data jumlah penumpang angkutan laut pada Januari 2012 hingga Juni 2016. Sedangkan data *outsample* adalah data jumlah penumpang angkutan laut pada Juli

hingga Desember 2016. Langkah umum penelitian yang dilakukan adalah sebagai berikut.

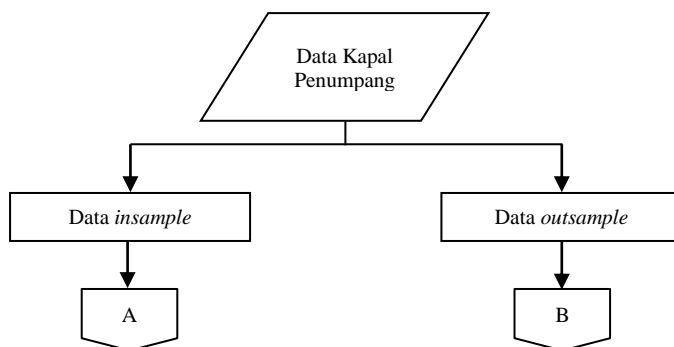
1. Menganalisis statistika deskriptif dari data jumlah penumpang angkutan laut PT Pelayaran Nasional Indonesia (Persero).
2. Meramalkan data jumlah penumpang angkutan laut PT Pelayaran Nasional Indonesia (Persero) menggunakan metode *ARIMA Box-Jenkins*.
3. Meramalkan data jumlah penumpang angkutan laut PT Pelayaran Nasional Indonesia (Persero) menggunakan metode Regresi *Time Series* (TSR) dengan efek variasi kalender.
4. Membandingkan hasil ramalan jumlah penumpang angkutan laut PT Pelayaran Nasional Indonesia (Persero) tahun 2019 dari kedua metode.




Gambar 3.1 Diagram Alir Penelitian

Langkah analisis dengan menggunakan metode ARIMA *Box-Jenkins* adalah sebagai berikut.

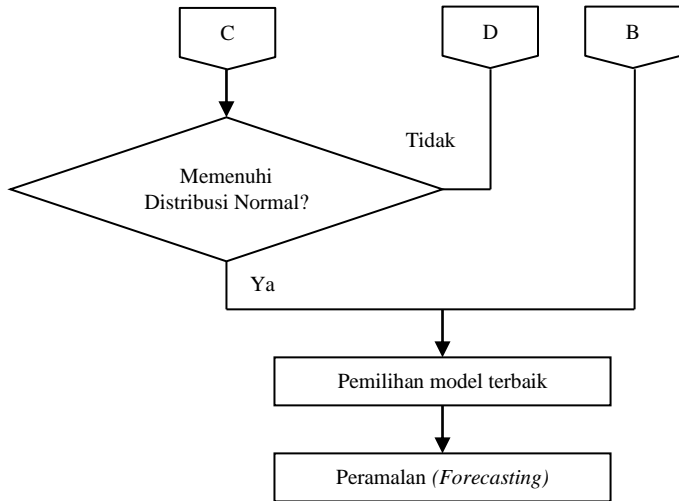
1. Data penumpang kapal penumpang dibagi menjadi dua bagian, yaitu data *insample* dan *outsample*.
2. Mengidentifikasi pola data dengan *time series plot* menggunakan data *insample*.
3. Mengidentifikasi stasioneritas data *insample* terhadap varians menggunakan plot *Box-Cox*.
4. Mengidentifikasi stasioneritas data *insample* terhadap *mean* menggunakan plot ACF dan uji Dickey-Fuller.
5. Menentukan model menggunakan plot ACF dan PACF pada data *insample*.
6. Melakukan estimasi parameter dan pengujian signifikansi parameter.
7. Melakukan pengujian asumsi residual *white noise* dan distribusi normal. Jika residual memenuhi asumsi *white noise* maka langkah selanjutnya melakukan pengujian asumsi distribusi normal.
8. Memilih model terbaik dengan menggunakan 2 indikator kebaikan model.
9. Melakukan peramalan jumlah kapal penumpang dengan menggunakan model terbaik yang telah dipilih melalui indikator kebaikan model.



Gambar 3.2 Diagram Alir Analisis Menggunakan Metode ARIMA *Box-Jenkins*



Gambar 3.2 Diagram Alir Analisis Menggunakan Metode ARIMA Box-Jenkins (Lanjutan)

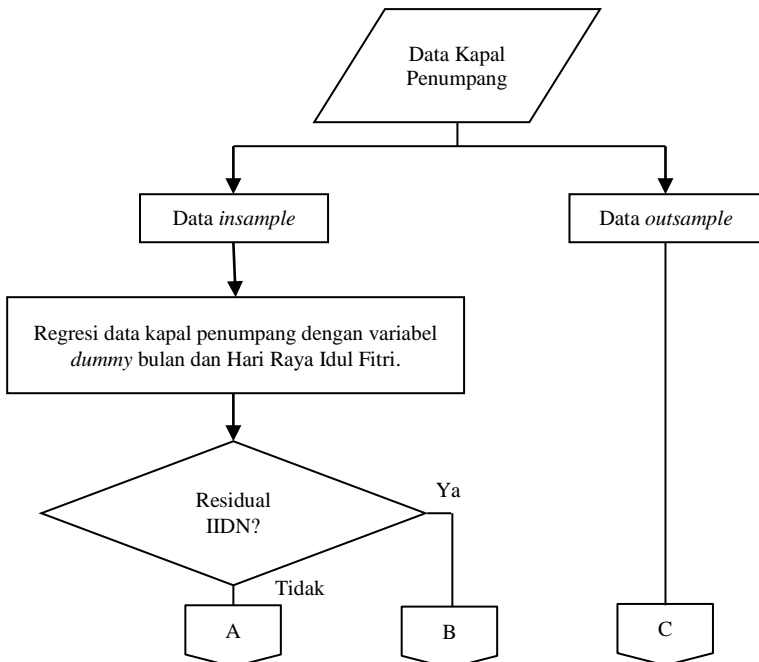


Gambar 3.2 Diagram Alir Analisis Menggunakan Metode ARIMA *Box-Jenkins* (Lanjutan)


Langkah analisis dengan menggunakan metode Regresi *Time Series* dengan efek variasi kalender dan dilanjutkan dengan memodelkan hasil residual data dengan ARIMA adalah sebagai berikut.

1. Data penumpang kapal penumpang dibagi menjadi dua bagian, yaitu data *insample* dan *outsample*.
2. Melakukan pemodelan regresi *time series* antara variabel *dummy* dengan variabel respon. Jika terdapat variabel yang tidak signifikan maka variabel dihilangkan sehingga diperoleh parameter yang signifikan.
3. Melakukan pemeriksaan asumsi IIDN terhadap residual. Ketika residual telah memenuhi asumsi IIDN, maka pemodelan selesai dan berhenti sampai regresi *dummy*. Namun, saat residual belum memenuhi asumsi IIDN, maka dilanjutkan pada pemodelan ARIMA.
4. Mengidentifikasi pola residual data dengan *time series plot* menggunakan data *insample*.

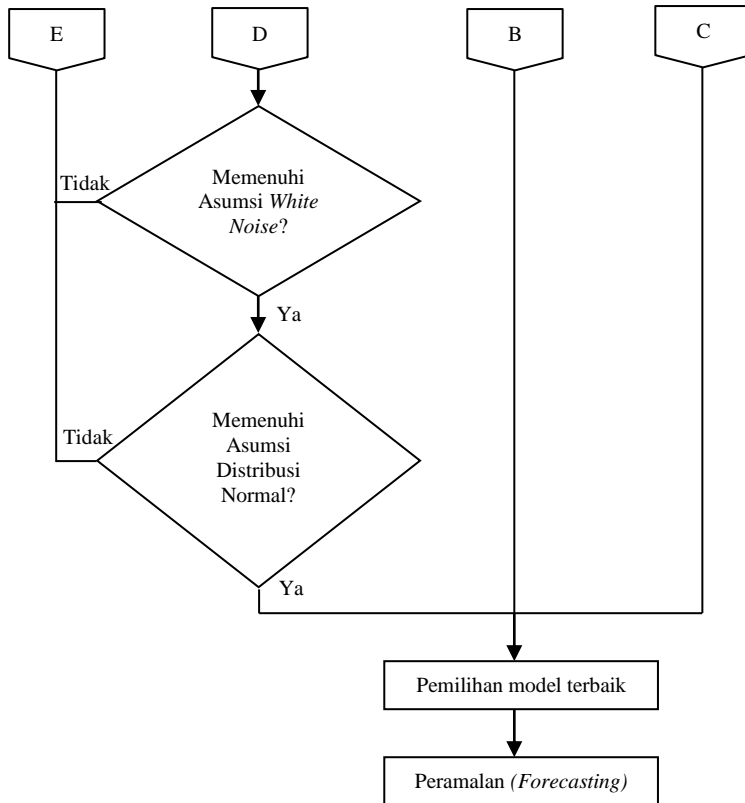
5. Mengidentifikasi stasioneritas data terhadap varians dan *mean*.
6. Melakukan estimasi parameter dan pengujian signifikansi parameter.
7. Melakukan pengujian asumsi residual *white noise* dan distribusi normal. Jika residual memenuhi asumsi *white noise* maka langkah selanjutnya melakukan pengujian asumsi distribusi normal.
8. Memilih model terbaik dengan menggunakan 2 indikator kebaikan model.
9. Melakukan peramalan jumlah kapal penumpang dengan menggunakan model terbaik yang telah dipilih melalui indikator kebaikan model.



Gambar 3.3 Diagram Alir Analisis Menggunakan Metode Regresi *Time Series With Variaton Calendar Effect*



Gambar 3.3 Diagram Alir Analisis Menggunakan Metode Regresi *Time Series With Variaton Calendar Effect* (Lanjutan)



Gambar 3.3 Diagram Alir Analisis Menggunakan Metode Regresi *Time Series With Variaton Calendar Effect* (Lanjutan)


(Halaman ini sengaja dikosongkan)

BAB IV ANALISIS DAN PEMBAHASAN

Analisis dan pembahasan pada bab ini akan dilakukan dengan menggunakan metode ARIMA dan Regresi *Time Series* dengan efek variasi kalender untuk data kapal penumpang rute Surabaya-Jayapura.

4.1 Deskripsi Data Kapal Penumpang


Eksplorasi data kapal penumpang rute Surabaya-Jayapura dilakukan sebelum tahap pemodelan. Eksplorasi data menggunakan *time series plot* disajikan pada Gambar 4.1.



Gambar 4.1 *Time Series Plot* Data Kapal Penumpang Rute Surabaya-Jayapura

Secara visual dengan Gambar 4.1 dapat diketahui bahwa terdapat indikasi pola musiman. Pola musiman terlihat pada Bulan Agustus tahun 2013, 2014, 2015, dan 2016 yang memiliki nilai lebih tinggi dibandingkan bulan lain. Data kapal penumpang rute Surabaya-Jayapura cenderung tidak stasioner terhadap *mean* dan varians. Untuk memastikan hal tersebut maka perlu dilakukan pengujian untuk stasioneritas *mean* maupun varians. Selain menggunakan *time series plot*, dilakukan pula analisis dengan menggunakan Boxplot pada data kapal penumpang rute Surabaya-Jayapura setiap bulan dari tahun 2012 hingga tahun 2016 un-

tuk mengetahui apakah terdapat identifikasi *outlier* pada data kapal penumpang rute Surabaya-Jayapura. Boxplot dapat dilihat pada Gambar 4.2.



Gambar 4.2 Boxplot Data Kapal Penumpang Rute Surabaya-Jayapura

Boxplot pada Gambar 4.2 menunjukkan bahwa data kapal penumpang rute Surabaya-Jayapura setiap bulan pada tahun 2012 hingga tahun 2016 memiliki karakteristik yang berbeda. Karakteristik yang pertama adalah median. Diketahui bahwa median dari Bulan Januari hingga Desember paling tidak ada beberapa yang memiliki media berbeda. Median tertinggi terdapat pada Bulan Agustus kemudian disusul oleh Bulan September.

Terkait penyebaran data kapal penumpang rute Surabaya-Jayapura pada tahun 2012 hingga tahun 2016 dapat dilihat dari nilai *interquartile range* yang secara visual dapat dilihat dari panjang *box* pada boxplot. *Box* pada Bulan Agustus dan September memiliki rentang yang lebih besar dibandingkan dengan bulan lain. Hal tersebut menunjukkan bahwa data kapal penumpang rute Surabaya-Jayapura pada tahun 2012 hingga tahun 2016 di Bulan Agustus dan September lebih menyebar dibandingkan dengan bulan lain.

Median yang dihasilkan oleh data kapal penumpang rute Surabaya-Jayapura pada tahun 2012 hingga tahun 2016 menunjukkan bahwa tidak ada data yang simetris di setiap bulan. Hal

tersebut dapat dilihat dari garis median yang tidak membagi data tepat di tengah. Berdasarkan boxplot yang terbentuk diketahui bahwa tidak terdapat data yang *outlier* di setiap bulan. Karakteristik data kapal penumpang rute Surabaya-Jayapura secara keseluruhan disajikan pada Tabel 4.1.

Tabel 4.1 Karakteristik Data Jumlah Penumpang Kapal Rute Surabaya-Jayapura

Statistik	Nilai
<i>Mean</i>	2880
Standar Deviasi	2572
Minimum	13
Maksimum	16905

Rata-rata jumlah penumpang di kapal penumpang rute Surabaya-Jayapura pada tahun 2012 hingga 2016 adalah sebanyak 2880 penumpang. Keragaman mencapai nilai 2572 yang berarti fluktuasi jumlah penumpang cenderung tidak pasti pada setiap pelayaran. Paling sedikit jumlah penumpang kapal rute Surabaya-Jayapura adalah 13 penumpang yaitu pada Oktober 2013 dan paling banyak mencapai 16905 penumpang yaitu pada Bulan Agustus 2014.

4.2 Pemodelan Kapal Penumpang Surabaya-Jayapura dengan Metode ARIMA

Data telah dibagi menjadi data *insample* dan data *out-sample*. Data *insample* merupakan data kapal penumpang rute Surabaya-Jayapura periode Januari 2012 hingga Juni 2016, sedangkan data *outsample* merupakan data periode Juli hingga Desember 2016. Tahap selanjutnya adalah memeriksa kestasioneran data baik dalam varians maupun *mean*.

4.2.1 Stasioneritas Data Terhadap Varians


Stasioner varians diuji dengan menggunakan uji Bartlett yang kemudian diperiksa dengan menggunakan transformasi Box-Cox. Pengujian dengan menggunakan uji Bartlett memberikan hasil sesuai pada Tabel 4.2.

Tabel 4.2 Pengujian Bartlett

Bartlett	p-value	Keputusan	Kesimpulan
35,327	0,0002189	Tolak H_0	Tidak stasioner


Pengujian kestasioneran data dalam varians dengan menggunakan pengujian Bartlett memberikan keputusan tolak H_0 . Karena nilai p-value sebesar 0,0002189 lebih kecil dari nilai taraf signifikan sebesar 0,05. Kesimpulan yang diperoleh adalah bahwa data jumlah penumpang kapal rute Surabaya-Jayapura tidak stasioner terhadap varians.

Setelah dilakukan pengujian dengan uji Bartlett kemudian dilakukan pemeriksaan dengan menggunakan transformasi Box-Cox sesuai yang ditampilkan pada Gambar 4.3. Selain menggunakan transformasi Box-Cox, stasioneritas terhadap varians juga dapat dilihat pada boxplot Gambar 4.2. Boxplot menunjukkan bahwa data tidak stasioner terhadap varians. Transformasi Box-Cox memberikan estimasi nilai lambda sebesar 0,29 dan rounded value sebesar 0,50. Berdasarkan nilai tersebut maka dapat disimpulkan bahwa data jumlah penumpang kapal rute Surabaya-Jayapura belum stasioner terhadap varians.



Gambar 4.3 Box-Cox Transformation

Perlu dilakukan transformasi agar data dapat memenuhi syarat stasioner terhadap varians. Transformasi data dilakukan dengan menggunakan nilai akar dari data. *Time series plot* yang terbentuk dari data transformasi disajikan pada Gambar 4.4.




Gambar 4.4 *Time Series Plot* Data Transformasi

Time series plot hasil transformasi data jumlah penumpang kapal rute Surabaya-Jayapura. *Time series plot* menunjukkan bahwa plot cenderung lebih stasioner dalam varians dibandingkan dengan *time series plot* dari data yang belum ditransformasi seperti yang disajikan pada Gambar 4.1 sehingga dapat diidentifikasi bahwa data telah stasioner dalam varians. Untuk memastikan bahwa data telah stasioner terhadap varians maka perlu dilakukan pengujian. Pengujian yang digunakan adalah uji Bartlett dan memberikan hasil pada Tabel 4.3.

Tabel 4.3 Pengujian Bartlett Data Transformasi

Bartlett	p-value	Keputusan	Kesimpulan
13,647	0,2531	Gagal Tolak H_0	Stasioner


Pengujian kestasioneran data dalam varians dengan menggunakan pengujian Bartlett memberikan keputusan tolak H_0 . Karena nilai p-value sebesar 0,2531 lebih besar dari nilai taraf signifikan sebesar 0,05. Kesimpulan yang diperoleh adalah bahwa data jumlah penumpang kapal rute Surabaya-Jayapura stasioner terhadap varians. Transformasi Box-Cox memberikan estimasi nilai lambda sebesar 0,59 dan *rounded value* sebesar 0,50. Selang kepercayaan telah melewati nilai 1, sehingga tidak diperlukan transformasi. Hasil transformasi Box-Cox disajikan pada Gambar 4.5.



Gambar 4.5 Box-Cox Transformation Data Transformasi

4.2.2 Stasioneritas Data Terhadap Mean

Secara visual pemeriksaan stasioneritas dalam *mean* dapat menggunakan plot ACF dari data jumlah penumpang kapal rute Surabaya-Jayapura yang telah ditransformasi dan disajikan pada Gambar 4.6. Gambar tersebut menunjukkan lag-lag pada ACF terlihat turun cepat. Hal tersebut mengindikasikan bahwa data cenderung telah stasioner terhadap *mean*. Stasioneritas terhadap *mean* juga dapat diindikasikan berdasarkan boxplot pada Gambar 4.2. Boxplot menunjukkan bahwa data tidak stasioner terhadap *mean*. Berbanding terbalik dengan indikasi pada plot ACF di Gambar 4.6.



Gambar 4.6 Plot ACF Data Transformasi


Untuk memastikan bahwa data telah stasioner terhadap *mean* maka perlu dilakukan pengujian. Pengujian yang digunakan adalah uji Dickey-Fuller dan memberikan hasil pada Tabel 4.4.

Tabel 4.4 Pengujian Dickey-Fuller

Dickey-Fuller	p-value	Keputusan	Kesimpulan
-3,2413	0,09011	Gagal Tolak H_0	Tidak stasioner

Pemeriksaan kestasioneran data dalam *mean* dengan menggunakan pengujian Dickey Fuller memberikan keputusan gagal tolak H_0 . Karena nilai p-value sebesar 0,09011 lebih besar dari nilai taraf signifikan sebesar 0,05. Kesimpulan yang diperoleh adalah bahwa data jumlah penumpang kapal rute Surabaya-Jayapura tidak stasioner terhadap *mean*.

Differencing perlu dilakukan agar data stasioner terhadap *mean*. Plot *time series* hasil *differencing* disajikan pada Gambar 4.7. Secara visual dapat diketahui bahwa data kapal penumpang rute Surabaya-Jayapura stasioner terhadap *mean* karena plot berfluktuatif di sekitar nilai *mean*. Untuk memastikan hal tersebut maka perlu dilakukan pemeriksaan kestasioneran data dalam *mean* dengan plot ACF dan hasil disajikan pada Gambar 4.8.



Gambar 4.7 Time Series Plot Data Differencing

Untuk memastikan bahwa data telah stasioner terhadap *mean* maka perlu dilakukan pengujian. Hasil dari uji Dickey-Fuller pada data hasil *differencing* disajikan pada Tabel 4.5.


Tabel 4.5 Pengujian Dickey-Fuller Data *Differencing*

Dickey-Fuller	p-value	Keputusan	Kesimpulan
-5,5644	0,01	Tolak H_0	Stasioner

Pemeriksaan kestasioneran data hasil *differencing* dalam *mean* dengan menggunakan pengujian Dickey-Fuller memberikan keputusan tolak H_0 . Karena nilai p-value sebesar 0,01 lebih besar dari nilai taraf signifikan sebesar 0,05. Kesimpulan yang diperoleh adalah bahwa data jumlah penumpang kapal rute Surabaya-Jayapura telah stasioner terhadap *mean* maka tidak perlu dilakukan differencing. Tahap selanjutnya adalah memeriksa plot ACF dan PACF.


4.2.3 Identifikasi Model ARIMA

Plot ACF dan PACF dapat digunakan untuk mengidentifikasi model yang terbentuk. Identifikasi model yang sesuai dilakukan dengan melihat lag-lag pada ACF dan PACF yang signifikan. Plot ACF dan PACF yang terbentuk disajikan pada Gambar 4.8.



(a)

Gambar 4.8 Plot ACF (a) dan PACF (b) Data Jumlah Kapal Penumpang Surabaya-Jayapura Setelah Proses Transformasi dan *Differencing*



(b)

Gambar 4.8 Plot ACF (a) dan PACF (b) Data Jumlah Kapal Penumpang Surabaya-Jayapura Setelah Proses Transformasi dan *Differencing* (Lanjutan)

Identifikasi model data jumlah penumpang kapal rute Surabaya-Jayapura dilakukan berdasarkan plot ACF dan PACF yang disajikan pada Gambar 4.8. Lag yang signifikan pada plot ACF adalah lag 1 dan 12, sedangkan pada plot PACF adalah lag 1, 2, dan 12. *Time series plot* pada Gambar 4.1 dan *boxplot* pada Gambar 4.2 mengindikasikan bahwa pada data jumlah penumpang kapal rute Surabaya-Jayapura memiliki pola musiman sehingga terdapat model dugaan yang mengandung model ARIMA seasonal. Beberapa model dugaan yang terbentuk antara lain adalah ARIMA ([12],1,1), ARIMA (2,1,[12]), ARIMA (0,1,1)(0,0,1)¹², dan ARIMA (0,1,[1,12]).

4.2.4 Pengujian Signifikansi Parameter

Beberapa model yang diduga merupakan model ARIMA dari data jumlah penumpang kapal rute Surabaya-Jayapura diperiksa signifikansi untuk masing-masing parameter yang terdapat dalam model. Hasil pengujian signifikansi parameter dari model-model dugaan tersebut disajikan pada Tabel 4.6.

Tabel 4.6 Pengujian Signifikansi Parameter ARIMA

Model	Parameter	Estimasi	p-value
ARIMA ([12],1,1)	ϕ_{12}	0,49939	0,0007
	θ_1	0,82965	<0,0001
ARIMA (2,1,[12])	ϕ_1	-0,51245	0,0006
	ϕ_2	-0,25445	0,0758
	θ_{12}	-0,44457	0,0041
ARIMA (0,1,1)(0,0,1) ¹²	θ_1	0,84157	<0,0001
	Θ_1	-0,43189	0,0049
ARIMA (0,1,[1,12])	θ_1	0,73223	<0,0001
	θ_{12}	-0,32679	0,0159

Keterangan : Tanda tebal merupakan parameter signifikan pada taraf 5%.

Hasil pengujian parameter pada Tabel 4.4 menunjukkan bahwa seluruh parameter pada model ARIMA ([12],1,1), ARIMA (2,1,[12]), ARIMA (0,1,1)(0,0,1)¹², dan ARIMA (0,1,[1,12]) telah signifikan karena memiliki nilai p-value yang lebih kecil dari taraf signifikan sebesar 5%. Tahap selanjutnya adalah melakukan pengujian asumsi.

4.2.5 Pengujian Asumsi

Pengujian sumsi dilakukan untuk memeriksa residual data telah memenuhi *white noise* dan distribusi normal pada model dugaan yang telah signifikan. Pengujian asumsi distribusi normal menggunakan Kolmogorov-Smirnov. Hasil pengujian asumsi disajikan pada Tabel 4.7.

Tabel 4.7 Pengujian Asumsi ARIMA

Model	White Noise		Normalitas	AIC
	Lag	p-value		
ARIMA ([12],1,1)	6	0,6692	0,0220	463,117
	12	0,8849		
	18	0,8317		
	24	0,4574		

Tabel 4.7 Pengujian Asumsi ARIMA (Lanjutan)

Model	White Noise		Normalitas	AIC
	Lag	p-value		
ARIMA (2,1,[12])	6	0,1695	>0,1500	473,5882
	12	0,4238		
	18	0,4722		
	24	0,0349		
ARIMA (0,1,1)(0,0,1) ¹²	6	0,5957	0,1280	465,3395
	12	0,8646		
	18	0,9093		
	24	0,3848		
ARIMA (0,1,[1,12])	6	0,3689	0,0696	471,0892
	12	0,1923		
	18	0,1776		
	24	0,0214		

Keterangan : Tanda tebal merupakan parameter signifikan pada taraf 5%.

Hasil pengujian asumsi residual pada Tabel 4.5 menunjukkan bahwa dari semua model dugaan, model ARIMA (0,1,1)(0,0,1)¹² saja yang memenuhi asumsi *white noise*. Asumsi distribusi normal dipenuhi oleh ARIMA (2,1,[12]), ARIMA (0,1,1)(0,0,1)¹², dan ARIMA (0,1,[1,12]). Nilai AIC paling minimum dihasilkan oleh model ARIMA (0,1,1)(0,0,1)¹².

4.2.6 Pemilihan Model Terbaik


Setelah membandingkan nilai AIC dari masing-masing model dugaan maka model terbaik yang digunakan pada data jumlah penumpang kapal rute Surabaya-Jayapura adalah ARIMA (0,1,1)(0,0,1)¹² dengan model pada persamaan (4.1).

$$Z_t^* = Z_{t-1} + a_t + 0,84157a_{t-1} + 0,43189a_{t-12} - 0,36346a_{t-13} \quad (4.1)$$

dengan $Z_t^* = (Z_t)^{1/2}$ yang dihasilkan dari proses transformasi data menggunakan nilai akar dari data dan dihasilkan *time series* plot pada Gambar 4.4.

Model ARIMA (0,1,1)(0,0,1)¹² menghasilkan nilai MAPE untuk kesalahan ramalan data *outsample* adalah sebesar 62,155%. Plot perbandingan hasil ramalan dengan data *outsample* sesuai dengan yang ditampilkan pada Gambar 4.9. Plot berwarna hitam

merupakan data aktual sedangkan plot berwarna merah merupakan data ramalan. Sedangkan Gambar 4.9 menunjukkan bahwa plot hasil ramalan dan data aktual belum sesuai karena bentuk pola ramalan berbeda jauh dari data aktual.



Gambar 4.9 Plot Ramalan Data *Outsample*

4.2.7 Hasil *Forecasting* dengan Metode ARIMA

Model pada persamaan (4.1) kemudian digunakan untuk meramalkan jumlah penumpang kapal rute Surabaya-Jayapura pada tahun 2017. Hasil yang diperoleh disajikan pada Tabel 4.8.

Tabel 4.8 Hasil *Forecasting* ARIMA


Tahun	Bulan	t	Forecast	Real Forecast
2017	Januari	61	37,3453	1394,7
2017	Februari	62	42,1488	1776,5
2017	Maret	63	41,4504	1718,1
2017	April	64	34,4959	1190,0
2017	Mei	65	36,0323	1298,3
2017	Juni	66	22,5581	508,9
2017	Juli	67	48,0977	2313,4
2017	Agustus	68	52,5006	2756,3
2017	September	69	44,0799	1943,0
2017	Oktober	70	35,3770	1251,5

Tabel 4.8 Hasil *Forecasting* ARIMA (Lanjutan)

Tahun	Bulan	t	Forecast	Real Forecast
2017	November	71	37,1733	1381,9
2017	Desember	72	31,2771	978,3

Keterangan : Tanda tebal merupakan bulan terjadinya Hari Raya Idul Fitri.

Hasil peramalan dengan metode ARIMA menunjukkan bahwa jumlah penumpang kapal rute Surabaya-Jayapura pada tahun 2017 terbesar bukan berada pada bulan terjadinya Hari raya Idul Fitri ataupun Tahun Baru Masehi. Nilai AIC yang dihasilkan dari ramalan ini adalah sebesar 517,8454. Plot hasil ramalan disajikan pada Gambar 4.10.

**Gambar 4.10** Plot Ramalan Data

4.3 Pemodelan Kapal Penumpang Surabaya-Jayapura dengan Metode Regresi *Time Series* Efek Variasi Kalender

Pembahasan pada subbab ini adalah mengenai analisis *trend* deterministik dengan regresi, penerapan serta penentuan model dengan metode regresi *time series* efek variasi kalender yang kemudian residual yang diperoleh dimodelkan dengan metode ARIMA, pengujian diagnosis, pemilihan model terbaik, dan *forecasting* dengan menggunakan model terbaik residual data hasil regresi *time series* efek variasi kalender.

4.3.1 Pemodelan Regresi *Time Series* Efek Variasi Kalender

Pemodelan yang dilakukan adalah pemodelan jumlah penumpang kapal rute Surabaya-Jayapura dengan variabel *dummy*. Variabel *dummy* yang digunakan pada penelitian ini disajikan pada Tabel 3.1. Pemodelan dilakukan menggunakan regresi *time series* dengan model umum pada persamaan (4.3).

$$Z_t = \beta_0 + \beta_1 M_{1t} + \dots + \beta_{11} M_{11t} + \beta_{12} R_{t-1} + \beta_{13} R_t + \beta_{14} R_{t+1} + e_t \quad (4.3)$$

dengan $e_t \sim IIDN$. Tahap pertama adalah melakukan pengujian serentak dan diperoleh hasil yang disajikan pada Tabel 4.9.

Tabel 4.9 Pengujian Serentak Regresi *Time Series* Tahap Pertama

Source	df	SS	MS	F	P
Regression	14	248463445	17747389	6,00	0,000
Residual Error	39	115425694	2959633		
Total	53	363889139			

Pengujian serentak menunjukkan bahwa *p-value* yang terbentuk adalah sebesar 0,000. Berdasarkan hasil tersebut maka keputusan yang diperoleh adalah tolak H_0 karena nilai *p-value* lebih kecil dari nilai taraf signifikan sebesar 0,05. Hal tersebut berarti bahwa minimal terdapat salah satu variabel *dummy* yang berpengaruh signifikan terhadap jumlah penumpang kapal rute Surabaya-Jayapura. Dilanjutkan pada pengujian secara parsial untuk memastikan hasil pada pengujian serentak. Hasil pengujian parsial disajikan pada Tabel 4.10.

Tabel 4.10 Pengujian Parsial Regresi *Time Series* Tahap Pertama

Prediktor	Koefisien	SE Koefisien	T	P
Konstan	2274,5	860,2	2,64	0,012
M_{1t}	754	1154	0,65	0,517
M_{2t}	-83	1154	-0,07	0,943
M_{3t}	90	1154	0,08	0,938
M_{4t}	-564	1154	-0,49	0,6c28
M_{5t}	-246	1154	-0,21	0,833
M_{6t}	-425	1281	-0,33	0,742
M_{7t}	-16	1820	-0,01	0,993
M_{8t}	5160	1855	2,78	0,008
M_{9t}	1068	1424	0,75	0,458

Tabel 4.10 Pengujian Parsial Regresi *Time Series* Tahap Pertama (Lanjutan)

Prediktor	Koefisien	SE Koefisien	T	P
M_{10t}	-63	1216	-0,05	0,959
M_{11t}	421	1216	0,35	0,731
R_{t-1}	-318	1389	-0,23	0,820
R_t	-897	1683	-0,53	0,597
R_{t+1}	4083	1479	2,76	0,009

Keterangan : Tanda tebal merupakan parameter signifikan pada taraf 5%.

Pengujian parsial menunjukkan bahwa hanya terdapat beberapa variabel *dummy* yang berpengaruh signifikan terhadap jumlah penumpang kapal rute Surabaya-Jayapura. Dari semua variabel diketahui bahwa variabel M_{8t} dan R_{t+1} yang berpengaruh signifikan terhadap model. Kesimpulan pertama yang diperoleh adalah Bulan Agustus yang berpengaruh signifikan terhadap jumlah penumpang kapal rute Surabaya-Jayapura dibandingkan dengan Bulan Desember. Kesimpulan kedua adalah 1 bulan setelah Hari Raya Idul Fitri berpengaruh signifikan terhadap jumlah penumpang kapal rute Surabaya-Jayapura.

Diperlukan pengujian regresi *time series* tahap kedua untuk memperoleh estimasi parameter pemodelan variasi efek kalender yang terbaik. Hasil pengujian diawali dengan pengujian serentak dan diperoleh hasil yang disajikan pada Tabel 4.11.

Tabel 4.11 Pengujian Serentak Regresi *Time Series* Tahap Kedua

Source	df	SS	MS	F	P
Regression	12	247604939	20633745	7,28	0,000
Residual Error	51	116284200	2836200		
Total	53	363889139			

Pengujian serentak menunjukkan bahwa *p-value* yang terbentuk adalah sebesar 0,000. Berdasarkan hasil tersebut maka keputusan yang diperoleh adalah tolak H_0 karena nilai *p-value* lebih kecil dari nilai taraf signifikan sebesar 0,05. Hal tersebut berarti bahwa minimal terdapat salah satu dari beberapa variabel *dummy* yang berpengaruh signifikan terhadap jumlah penumpang kapal rute Surabaya-Jayapura. Dilanjutkan pada pengujian secara par-

sial untuk memastikan hasil pada pengujian serentak. Hasil pengujian parsial disajikan pada Tabel 4.12.

Tabel 4.12 Pengujian Parsial Regresi *Time Series* Tahap Kedua

Prediktor	Koefisien	SE Koefisien	T	P
Konstan	2274,5	842,1	2,70	0,010
M_{1t}	754	1130	0,67	0,508
M_{2t}	-83	1130	-0,07	0,942
M_{3t}	90	1130	0,08	0,937
M_{4t}	-564	1130	-0,50	0,620
M_{5t}	-246	1130	-0,22	0,829
M_{6t}	-552	1130	-0,49	0,628
M_{7t}	-624	1191	-0,52	0,603
M_{8t}	4887	1331	3,37	0,002
M_{9t}	844	1331	0,63	0,530
M_{10t}	-63	1191	-0,05	0,958
M_{11t}	421	1191	0,35	0,726
R_{t+1}	4532	1191	3,81	0,000

Keterangan : Tanda tebal merupakan parameter signifikan pada taraf 5%.

Pengujian parsial menunjukkan bahwa *dummy* Bulan Agustus dan *dummy* 1 bulan setelah Hari Raya Idul Fitri yang berpengaruh signifikan terhadap jumlah penumpang kapal rute Surabaya-Jayapura. Hal tersebut dapat dilihat dari nilai *p-value* semua variabel yang lebih kecil dari nilai taraf signifikan sebesar 0,05. Kesimpulan pertama yang diperoleh adalah Bulan Agustus berpengaruh signifikan dibandingkan dengan Bulan Desember terhadap jumlah penumpang kapal rute Surabaya-Jayapura. Kesimpulan kedua adalah 1 bulan setelah Hari Raya Idul Fitri berpengaruh signifikan terhadap jumlah penumpang kapal rute Surabaya-Jayapura. Sehingga model yang terbentuk disajikan pada persamaan (4.2).


$$\begin{aligned}
 Z_t = & 2274,5 + 754M_{1t} - 83M_{2t} + 90M_{3t} - 564M_{4t} - 246M_{5t} + \dots \\
 & \dots + (-552)M_{6t} - 624M_{7t} + 4887M_{8t} + 844M_{9t} - 63M_{10t} + \dots \\
 & \dots + 421M_{11t} + 4532R_{t+1}
 \end{aligned} \quad (4.4)$$

Model yang terbentuk memberikan informasi bahwa apabila pelayaran kapal penumpang rute Surabaya-Jayapura terjadi

pada Bulan Agustus maka jumlah penumpang kapal rute Surabaya-Jayapura akan naik sebesar 7161,5 atau 7162 penumpang dibandingkan dengan pelayaran pada Bulan Desember. Selain itu diketahui pula bahwa apabila pelayaran dilakukan pada 1 bulan setelah Hari Raya Idul Fitri maka jumlah penumpang kapal rute Surabaya-Jayapura akan bertambah sebesar 6806,5 atau 6807 penumpang.

4.3.2 Pemeriksaan Asumsi Residual

Residual yang identik berarti bahwa varians residual cenderung konstan. Pemeriksaan asumsi identik secara visual dapat dilihat dari plot *residual versus fits* yang disajikan pada Gambar 4.10.



Gambar 4.10 *Residual Versus Fits*

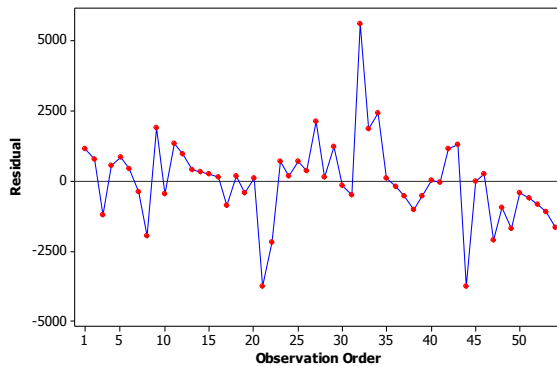
Secara visual menunjukkan bahwa residual data tidak memenuhi asumsi residual identik. Hal tersebut dapat dilihat karena terdapat plot yang berkumpul di satu titik. Namun, untuk memastikan hal tersebut maka perlu dilakukan pengujian dengan Uji Glejser. Hasil pengujian disajikan pada Tabel 4.13.

Tabel 4.13 Pengujian Asumsi Identik

<i>Source</i>	<i>df</i>	<i>SS</i>	<i>MS</i>	<i>F</i>	<i>P</i>
<i>Regression</i>	12	37642509	3136876	5,71	0,000
<i>Residual Error</i>	41	22523313	549349		
Total	53	60165823			

Uji Glejser menunjukkan bahwa *p-value* yang diperoleh dari pengujian adalah sebesar 0,000. Berdasarkan hal tersebut maka keputusan yang diperoleh adalah gagal tolak H_0 karena nilai *p-value* lebih kecil dari nilai taraf signifikan sebesar 0,05. Kesimpulan yang diperoleh adalah residual data hasil pemodelan efek variasi kalender tidak memenuhi asumsi identik yang berarti terjadi kasus heterokedastisitas.

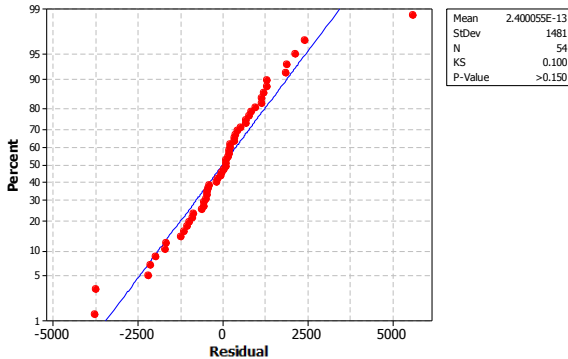
Residual yang independen berarti bahwa varians residual tidak terjadi kasus autokorelasi. Pemeriksaan asumsi independen secara visual dapat dilihat dari plot *residual versus order* yang disajikan pada Gambar 4.11.



Gambar 4.11 *Residual Versus Order*

Secara visual menunjukkan bahwa residual data tidak memenuhi asumsi residual independen. Hal tersebut dapat dilihat karena plot tidak membentuk suatu pola tertentu. Namun, untuk memastikan hal tersebut maka perlu dilakukan pengujian dengan Uji Durbin-Watson. Hasil pengujian menunjukkan bahwa nilai Durbin-Watson adalah sebesar 1,57988. Berdasarkan hal tersebut maka keputusan yang diperoleh adalah tolak H_0 karena nilai Durbin-Watson hasil perhitungan lebih kecil dari *du* sebesar 2,1242. Kesimpulan yang diperoleh adalah residual data hasil pemodelan efek variasi kalender tidak memenuhi asumsi independen yang berarti terjadi kasus autokorelasi.

Pemeriksaan asumsi distribusi normal dilakukan pada residual data. Pemeriksaan dilakukan dengan menggunakan pengujian Kolmogorov-Smirnov. Selain menggunakan pengujian, pemeriksaan asumsi distribusi normal dapat dilakukan secara visual dan hasil disajikan pada Gambar 4.12.



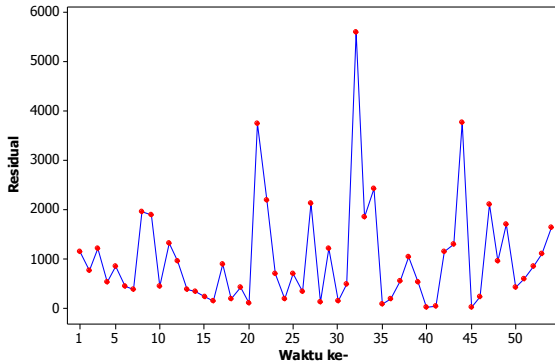
Gambar 4.12 Pemeriksaan Asumsi Distribusi Normal

Secara visual menunjukkan bahwa residual data memenuhi asumsi distribusi normal. Hal tersebut dapat dilihat karena plot cenderung menekati garis normal. Namun, untuk memastikan hal tersebut maka perlu dilakukan pengujian dengan Uji Kolmogorov-Smirnov. Hasil pengujian menunjukkan bahwa nilai *p-value* adalah sebesar $>0,150$. Berdasarkan hal tersebut maka keputusan yang diperoleh adalah gagal tolak H_0 karena nilai *p-value* lebih besar dari nilai taraf signifikan sebesar 0,05. Kesimpulan yang diperoleh adalah residual data hasil pemodelan efek variasi kalender memenuhi asumsi distribusi normal.

4.3.3 Pemodelan ARIMA Data Residual

Time series plot yang terbentuk dari residual data hasil pemodelan efek variasi kalender disajikan pada Gambar 4.13. *Time series plot* menunjukkan residual data hasil pemodelan efek variasi kalender cenderung tidak stasioner terhadap *mean* dan *varians*. Stasioneritas terhadap *varians* dilakukan pengujian dengan

menggunakan uji Bartlett kemudian dilakukan pemeriksaan dengan menggunakan transformasi Box-Cox. Stasioneritas terhadap *mean* dilakukan pengujian dengan menggunakan uji Dickey-Fuller.



Gambar 4.13 Time Series Plot Data Residual

Stasioner varians diuji dengan menggunakan uji Bartlett yang kemudian diperiksa dengan menggunakan transformasi Box-Cox. Pengujian dengan menggunakan uji Bartlett memberikan hasil sesuai pada Tabel 4.14.


Tabel 4.14 Pengujian Bartlett Data Residual

Bartlett	p-value	Keputusan	Kesimpulan
35,933	0,0001736	Tolak H_0	Tidak stasioner

Pengujian kestasioneran data dalam varians dengan menggunakan pengujian Bartlett memberikan keputusan tolak H_0 . Karena nilai *p-value* sebesar 0,0001736 lebih kecil dari nilai taraf signifikan sebesar 0,05. Kesimpulan yang diperoleh adalah bahwa residual data hasil pemodelan efek variasi kalender tidak stasioner terhadap varians.


Setelah dilakukan pengujian dengan uji Bartlett kemudian dilakukan pemeriksaan dengan menggunakan transformasi Box-Cox sesuai yang ditampilkan pada Gambar 4.14. Transformasi Box-Cox memberikan estimasi nilai lambda sebesar 0,20 dan

rounded value sebesar 0,00 sehingga residual data hasil pemodelan efek variasi kalender tidak stasioner terhadap varians.



Gambar 4.14 Box-Cox Transformation Data Residual

Perlu dilakukan transformasi agar data dapat memenuhi syarat stasioner terhadap varians. Transformasi data dilakukan dengan menggunakan nilai logaritma natural dari data. *Time series plot* yang terbentuk dari data transformasi disajikan pada Gambar 4.15.



Gambar 4.15 Time Series Plot Data Transformasi Residual

Time series plot hasil transformasi residual data hasil pemodelan efek variasi kalender. *Time series plot* menunjukkan


bahwa plot cenderung lebih stasioner dalam varians dibandingkan dengan *time series plot* dari data yang belum ditransformasi seperti yang disajikan pada Gambar 4.13 sehingga dapat diidentifikasi bahwa data telah stasioner dalam varians.

Stasioner varians residual data hasil pemodelan efek variasi kalender setelah proses transformasi diuji dengan menggunakan uji Bartlett Pengujian dengan menggunakan uji Bartlett memberikan hasil sesuai pada Tabel 4.15.

Tabel 4.15 Pengujian Bartlett Data Residual Transformasi

Bartlett	p-value	Keputusan	Kesimpulan
14,689	0,1972	Tolak H_0	Tidak stasioner

Pengujian kestasioneran data dalam varians dengan menggunakan pengujian Bartlett memberikan keputusan tolak H_0 . Karena nilai p-value sebesar 0,1972 lebih besar dari nilai taraf signifikan sebesar 0,05. Kesimpulan yang diperoleh adalah bahwa residual data hasil pemodelan efek variasi kalender stasioner terhadap varians.



Gambar 4.16 Box-Cox Transformation Data Transformasi Residual

Transformasi Box-Cox setelah residual data hasil pemodelan efek variasi kalender ditransformasi disajikan pada Gambar 4.16. Transformasi Box-Cox memberikan estimasi nilai lambda sebesar 1,97 dan *rounded value* sebesar 2,00, sehingga tidak diperlukan transformasi. Setelah pemeriksaan kestasioneran da-

lam varians maka dilanjutkan pemeriksaan kestasioneran data dalam *mean*.

Secara visual pemeriksaan stasioneritas dalam *mean* dapat menggunakan *time series plot* dari residual data hasil pemodelan efek variasi kalender yang telah ditransformasi dan disajikan pada Gambar 4.15. Gambar tersebut meng-indikasikan bahwa data cenderung telah stasioner terhadap *mean*. Untuk memastikan bahwa data telah stasioner terhadap *mean* maka perlu dilakukan pengujian. Pengujian yang digunakan adalah uji Dickey-Fuller dan memberikan hasil pada Tabel 4.16.

Tabel 4.16 Pengujian Dickey-Fuller


Dickey-Fuller	p-value	Keputusan	Kesimpulan
-4,0358	0,01464	Tolak H_0	Stasioner

Pemeriksaan kestasioneran data dalam *mean* dengan menggunakan pengujian Dickey Fuller memberikan keputusan gagal tolak H_0 . Karena nilai *p-value* sebesar 0,01464 lebih kecil dari nilai taraf signifikan sebesar 0,05. Kesimpulan yang diperoleh adalah bahwa residual data hasil pemodelan efek variasi kalender telah stasioner terhadap *mean*. Tahap selanjutnya adalah memeriksa plot ACF dan PACF.


4.3.3.1 Identifikasi Model ARIMA Data Residual

Plot ACF dan PACF dapat digunakan untuk mengidentifikasi model yang terbentuk. Identifikasi model yang sesuai dilakukan dengan melihat lag-lag pada ACF dan PACF yang signifikan. Plot ACF dan PACF yang terbentuk disajikan pada Gambar 4.18.

Identifikasi model residual data hasil pemodelan efek variasi kalender dilakukan berdasarkan plot ACF dan PACF yang disajikan pada Gambar 4.18. Lag yang signifikan pada plot ACF adalah lag 3 dan 5, sedangkan pada plot PACF adalah lag 3 dan 5. Beberapa model dugaan yang terbentuk antara lain adalah AR ([3,5]), AR([5]), MA ([3,5]), dan MA ([5]).



(a)



(b)

Gambar 4.18 Plot ACF (a) dan PACF (b) Residual Data Hasil Pemodelan Efek Variasi Kalender

4.3.3.2 Pengujian Signifikansi Parameter Data Residual

Beberapa model yang diduga merupakan model ARIMA dari residual data hasil pemodelan efek variasi kalender diperiksa signifikansi untuk masing-masing parameter yang terdapat dalam model. Hasil pengujian signifikansi parameter dari model-model dugaan tersebut disajikan pada Tabel 4.17.

Tabel 4.17 Pengujian Signifikansi Parameter ARIMA Data Residual

Model	Parameter	Estimasi	p-value
AR([3,5])	μ	6,38623	< 0,0001
	ϕ_3	-0,27193	0,0354
	ϕ_5	0,36151	0,0059
AR([5])	μ	6,43283	< 0,0001
	ϕ_5	0,40886	0,0024
MA([3,5])	μ	6,37538	< 0,0001
	θ_3	0,32991	0,0162
	θ_5	-0,21267	0,1244
MA([5])	μ	6,39721	< 0,0001
	θ_5	-0,26126	0,0602

Keterangan : Tanda tebal merupakan parameter signifikan pada taraf 5%.

Hasil pengujian parameter menunjukkan bahwa seluruh parameter pada model AR ([3,5]) dan AR([5]) telah signifikan karena memiliki nilai p-value yang lebih kecil dari taraf signifikan sebesar 5%. Pengujian pada model MA ([3,5]) dan MA ([5]) tidak dilanjutkan karena salah satu parameter pada model tersebut tidak signifikan. Tahap selanjutnya adalah melakukan pengujian asumsi.

4.3.3.3 Pengujian Asumsi Data Residual

Pengujian sumsi dilakukan untuk memeriksa residual data telah memenuhi *white noise* dan distribusi normal pada model dugaan yang telah signifikan. Pengujian asumsi distribusi normal menggunakan Kolmogorov-Smirnov. Hasil pengujian asumsi disajikan pada Tabel 4.18.

Tabel 4.18 Pengujian Asumsi ARIMA Residual Data

Model	White Noise		Normalitas	AIC
	Lag	p-value		
AR([3,5])	6	0,5616	> 0,1500	163,5623
	12	0,3738		
	18	0,4377		
	24	0,3127		

Tabel 4.18 Pengujian Asumsi ARIMA Residual Data (Lanjutan)

Model	White Noise		Normalitas	AIC
	Lag	p-value		
AR([5])	6	0,3804	>0,1500	166,261
	12	0,0568		
	18	0,1033		
	24	0,0764		

Keterangan : Tanda tebal merupakan parameter signifikan pada taraf 5%.

Hasil pengujian asumsi residual pada Tabel 4.5 menunjukkan bahwa dari semua model yaitu AR ([3,5]) dan AR([5]) memenuhi asumsi *white noise* dan distribusi normal. Nilai AIC paling minimum dihasilkan oleh model AR ([3,5]). Model terbaik residual data hasil pemodelan efek variasi kalender adalah model AR ([3,5]).

4.3.3.4 Pemilihan Model Terbaik Data Residual

Setelah membandingkan nilai AIC dari kedua model dugaan maka model terbaik yang digunakan pada residual data hasil pemodelan efek variasi kalender adalah model AR ([3,5]) dengan model pada persamaan (4.5).


$$\begin{aligned} \dot{Z}_t^* &= -0,27193\dot{Z}_{t-3} + 0,36151\dot{Z}_{t-5} + a_t \\ Z_t^* &= 5,8141 - 0,27193Z_{t-3} + 0,36151Z_{t-5} + a_t \end{aligned} \quad (4.5)$$

dengan $Z_t^* = \ln(Z_t)$ yang dihasilkan dari proses transformasi data menggunakan nilai logaritma natural dari data dan dihasilkan *time series* plot pada Gambar 4.15.

Model AR ([3,5]) menghasilkan nilai MAPE untuk kesalahan ramalan data *outsample* adalah sebesar 13,82 %. Nilai ini lebih kecil dibandingkan dengan ramalan menggunakan model ARIMA (0,1,1)(0,0,1)¹² pada data jumlah penumpang kapal rute Surabaya-Jayapura. Sehingga model lengkap yang terbentuk dengan menggunakan regresi *time series* dengan efek variasi kalender ditunjukkan oleh persamaan (4.6).

$$\begin{aligned}
Z_t = & 2274,5 + 754M_{1t} - 83M_{2t} + 90M_{3t} - 564M_{4t} - 246M_{5t} + \dots \\
& \dots + (-552)M_{6t} - 624M_{7t} + 4887M_{8t} + 844M_{9t} - 63M_{10t} + \dots \quad (4.6) \\
& \dots + 421M_{11t} + 4532R_{t+1} + (5,8141 - 0,27193Z_{t-3} + 0,36151Z_{t-5} + a_t)
\end{aligned}$$

Plot perbandingan hasil ramalan dengan data *outsample* sesuai dengan yang ditampilkan pada Gambar 4.9. Plot berwarna hitam merupakan data aktual sedangkan plot berwarna merah merupakan data ramalan. Sedangkan Gambar 4.9 menunjukkan bahwa plot hasil ramalan dan data aktual telah sesuai karena bentuk pola ramalan berbeda jauh dari data aktual.



Gambar 4.9 Plot Ramalan Data *Outsample* Menggunakan Regresi *Time Series* Efek Variasi Kalender

4.3.5 Hasil *Forecasting* dengan Metode Regresi *Time Series* dan ARIMA


Model pada persamaan (4.5) kemudian digunakan untuk meramalkan residual data hasil pemodelan efek variasi kalender pada tahun 2017. Kemudian dari hasil ramalan tersebut dengan menggunakan persamaan (4.6) didapatkan ramalan jumlah penumpang kapal rute Surabaya-Jayapura. Hasil yang diperoleh disajikan pada Tabel 4.19.

Tabel 4.19 Hasil *Forecasting* Menggunakan Regresi Time Series Efek Variasi Kalender

Tahun	Bulan	t	Forecast
2017	Januari	61	3031,4
2017	Februari	62	2194,4
2017	Maret	63	2367,4
2017	April	64	1713,5
2017	Mei	65	2031,5
2017	Juni	66	1725,5
2017	Juli	67	1653,5
2017	Agustus	68	7164,5
2017	September	69	7653,5
2017	Oktober	70	2214,5
2017	November	71	2698,5
2017	Desember	72	2277,5

Keterangan : Tanda tebal merupakan bulan terjadinya Hari Raya Idul Fitri.

Hasil peramalan dengan metode ARIMA menunjukkan bahwa jumlah penumpang kapal rute Surabaya-Jayapura pada tahun 2017 terbesar bukan berada pada bulan terjadinya Hari raya Idul Fitri ataupun Tahun Baru Masehi. Nilai AIC yang dihasilkan dari ramalan ini adalah sebesar 181,9194. Plot hasil ramalan disajikan pada Gambar 4.10.



Gambar 4.10 Plot Ramalan Data Menggunakan Regresi *Time Series* Efek Variasi Kalender

Plot berwarna hitam merupakan data aktual sedangkan plot berwarna merah merupakan data ramalan jumlah penumpang kapal rute Surabaya-Jayapura pada tahun 2012 hingga tahun 2016. Plot berwarna hijau menunjukkan data ramalan jumlah penumpang kapal rute Surabaya-Jayapura pada tahun 2017. Plot ramalan data menggunakan regresi *time series* efek variasi kalender pada tahun 2017 menunjukkan bahwa fluktuasi data lebih sesuai dengan data-data di tahun sbelumnya dibandingkan dengan menggunakan metode ARIMA. Secara ringkas perbandingan hasil peramalan disajikan pada Tabel 4.20.

Tabel 4.20 Perbandingan Metode dengan Indikator Kebaikan Model

Model	MAPE Data <i>Outsample</i>	AIC
ARIMA (0,1,1)(0,0,1) ¹²	62,155%	517,8454
Regresi <i>Time Series</i> dengan Pemodelan Residual Data Menggunakan AR ([3,5])	13,82%	181,9194

(Halaman ini sengaja dikosongkan)

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan analisis yang dilakukan maka diperoleh beberapa kesimpulan sebagai berikut.

1. *Time series plot* yang terbentuk dari data kapal penumpang rute Surabaya-Jayapura mengindikasikan bahwa data terdapat pola musiman. Berdasarkan *time series plot* diketahui bahwa data cenderung tidak *stasioner* terhadap *mean* dan varians. Hal yang sama ditunjukkan oleh *box-plot* yang terbentuk dari data.
2. Pengujian stasioneritas pada metode ARIMA memberikan hasil bahwa data membutuhkan transformasi dan *differencing*. Plot ACF dan PACF yang terbentuk menunjukkan bahwa lag yang signifikan pada plot ACF adalah lag 1 dan 12, sedangkan pada plot PACF adalah lag 1, 2, dan 12. Model terbaik yang terbentuk menggunakan model ARIMA (0,1,1)(0,0,1)¹². Ramalan data *outsample* menghasilkan nilai MAPE sebesar 62,155%. Sedangkan AIC untuk data ramalan tahun 2017 yang dihasilkan adalah sebesar 517,8454.
3. Pemodelan regresi *time series* efek variasi kalender menunjukkan bahwa *dummy* Bulan Agustus dan *dummy* 1 bulan setelah Hari Raya Idul Fitri berpengaruh signifikan terhadap model dengan model yang terbentuk disajikan pada persamaan 4.4. Pemeriksaan asumsi dari model yang terbentuk memberikan kesimpulan bahwa residual data tidak memenuhi asumsi identik dan independen namun memenuhi asumsi distribusi normal.
4. Pemodelan dilanjutkan dengan pemodelan residual data menggunakan metode ARIMA karena asumsi klasik pada regresi *time series* efek variasi kalender tidak terpenuhi. Pemodelan ARIMA menggunakan residual data hasil pemodelan efek variasi kalender memberikan hasil bahwa

AR ([3,5]) merupakan model terbaik. Nilai MAPE untuk kesalahan ramalan data *outsample* adalah sebesar 13,82%. Sedangkan AIC untuk data ramalan tahun 2017 yang dihasilkan adalah sebesar 181,9194. Nilai MAPE dan AIC tersebut lebih kecil dibandingkan dengan ramalan menggunakan model ARIMA (0,1,1)(0,0,1)¹² pada data jumlah penumpang kapal rute Surabaya-Jayapura.

5.2 Saran

Saran dalam penelitian selanjutnya adalah mengambil rute pelayaran yang memiliki frekuensi lebih sering dalam 1 bulan. Selain itu, efek variasi kalender dapat dicoba menggunakan efek variasi kalender Hijriyah, bukan hanya Masehi.

DAFTAR PUSTAKA

- Akaike, H. (1973). *Information Theory and An Extension of Maximum Likelihood Principle*. in Petrov, B.N.; Csaki, F. 2nd International Symposium on Information Theory, Thaskador, Armenia, USSR. Hal. 267-281.
- Andilas, D. D., & Yanggana, L. A. (2017). Pelaksanaan Program Tol Laut PT Pelayaran Nasional Indonesia. *Jurnal Manajemen Transportasi & Logistik - Vol. 04 No. 01*.
- Baihaqi, M. B. (2014, Desember 30). *Distribusi Barang Lewat Laut, Indonesia Bisa Hemat Rp300 Triliun*. Diakses pada 17 Januari 2019, dari Harian Ekonomi Neraca: <http://www.neraca.co.id/article/49073/distribusi-barang-lewat-laut-indonesia-bisa-hemat-rp300-triliun>.
- BPS. (2018). *Statistik Transportasi Laut 2017*. Jakarta: Badan Pusat Statistik.
- Cryer, J. D., & Chan, K. (2008). *Time Series Analysis With Application in R Second Edition*. New York: Springer Science Business Media.
- Daniel, W. W. (1989). *Statistik Nonparametrik Terapan*. Terjemahan oleh Alex Tri Kuncoro. Jakarta: Gramedia.
- Dwijantari, S. (2017). *Peramalan Konsumsi Listrik Pada Segmen Rumah Tangga PT PLN (Persero) Distribusi Jawa Timur*. Undergraduate Thesis, Institut Teknologi Sepuluh Nopember Surabaya.
- Endartyana, R. Y. (2017). *Peramalan Jumlah Kedatangan Wisatawan Mancanegara di Indonesia Melalui Pintu Masuk Bandara Ngurah Rai Bali Menggunakan ARIMA Box-Jenkins*. Undergraduate Thesis, Institut Teknologi Sepuluh Nopember Surabaya.
- Fanani, N. (2017). *Peramalan Jumlah Keberangkatan Penumpang Pelayaran Dalam Negeri dari Pelabuhan Tanjung Perak dengan ARIMA-Box Jenkins*. Undergraduate Thesis, Institut Teknologi Sepuluh Nopember Surabaya.
- Gujarati, D., & Porter, D. (2009). *Basic Econometrics 5th Edition*. New York: Mc. Graw-Hill Companies, Inc.

- Gumilang, A. P. (2016, November 24). *Ekonomi Kelautan dan Poros Maritim*. Diakses pada 13 Februari 2019, dari Investor Daily: <https://id.beritasatu.com/home/ekonomi-kelautan-dan-poros-maritim/153087>.
- Johnson, R. A., & Winchern, D. W. (2007). *Applied Multivariate Statistical Analysis*. United States: Prentice Hall.
- Kompasiana. (2015, Oktober 8). *5 Pelabuhan Penting di Indonesia*. Diakses pada 25 Februari 2019, dari Kompasiana: <https://www.kompasiana.com/selasarcom-/55f919f58923bdc307de1409/5-pelabuhan-penting-di-indonesia>.
- Kumparan. (2018, Juni 30). *Tak Andalkan PSO, Pelni Lakukan Sejumlah Inovasi*. Diakses pada 26 Februari 2019, dari KumparanBisnis: <https://kumparan.com/@kumparan-bisnis/tak-andalkan-pso-pelni-lakukan-sejumlah-inovasi-27431110790535838>.
- Makridakis, S., Wheelwright, S. C., & McGee, V. E. (1999). *Metode dan Aplikasi Peramalan*. Jakarta: Erlangga.
- Maulana, R. (2018, Februari 8). *Sepanjang 2017, Penumpang Angkutan Laut Naik 17,13%*. Diakses pada 25 Februari 2019, dari Ekonomi Bisnis: <https://ekonomi.bisnis.com/read/20180208/98/736368/sepanjang-2017penumpang-angkutan-laut-naik-1713>.
- Permatasari, R. A. (2015). *Pemodelan Regresi Time Series dan ARIMAX dengan Variasi Kalender untuk Perkiraan Arus Uang Kartal di Bank Indonesia Surabaya*. Undergraduate Thesis, Institut Teknologi Sepuluh Nopember Surabaya.
- Wei, W. (2006). *Time Series Analysis : Univariate and Multivariate Methods, 2nd edition*. New York: Pearson.
- Yovanda, Y. R. (2015, November 26). *Infrastruktur Buruk, Biaya Logistik RI Masih Paling Mahal*. Diakses pada 14 Februari 2019, dari SINDONEWS: <https://ekbis.sindonews.com/read/1064784/34/infrastruktur-buruk-biaya-logistik-ri-masih-paling-mahal-1448540405>.

60	372	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0
----	-----	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---

Lampiran 2. Pengujian Dickey-Fuller

Syntax

```
library(tseries)
adf.test(labobar11$Ztt)
```

Output

```
> adf.test(labobar11$Ztt)

Augmented Dickey-Fuller Test

data: labobar11$Ztt
Dickey-Fuller = -3.2413, Lag order = 3, p-value = 0.09011
alternative hypothesis: stationary
```

Lampiran 3. Pengujian Dickey-Fuller Data *Differencing*

Syntax

```
library(tseries)
labobar_diff = diff(labobar11$Ztt)
adf.test(labobar_diff)
```

Output

```
> labobar_diff = diff(labobar11$Ztt)
> adf.test(labobar_diff)

Augmented Dickey-Fuller Test

data: labobar_diff
Dickey-Fuller = -5.5644, Lag order = 3, p-value = 0.01
alternative hypothesis: stationary

Warning message:
In adf.test(labobar_diff) : p-value smaller than printed p-value
```

Lampiran 4. Syntax ARIMA ([12],1,1)

```
data labobar1;
input y;
datalines;

proc arima data=labobar1;
identify var=y(1);
estimate
p=(1,2) q=(1)
noconstant method=cls;
forecast out=ramalan lead=6;
run;
proc univariate data=ramalan normal;
var residual;
run;
proc export data=ramalan
outfile="E:\Ramalan (2,1,1).xls"
dbms=excel97
replace;
run;
```

Lampiran 5. Output ARIMA ([12],1,1)

Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag				
MA1,1	0.82965	0.08735	9.50	<.0001	1				
AR1,1	0.49939	0.13815	3.61	0.0007	12				
Variance Estimate			351.8394						
Std Error Estimate			18.75738						
AIC			463.117						
SBC			467.0576						
Number of Residuals			53						
* AIC and SBC do not include log determinant.									
The ARIMA Procedure									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.36	4	0.6692	0.095	0.043	-0.034	-0.129	-0.012	-0.105
12	5.09	10	0.8849	0.055	0.018	0.124	-0.144	0.021	-0.029
18	10.63	16	0.8317	-0.191	0.084	-0.061	0.113	0.044	0.104
24	22.04	22	0.4574	0.105	-0.128	-0.072	-0.240	0.176	0.037

Lampiran 5. Output ARIMA ([12],1,1) (Lanjutan)

Forecasts for variable y				
Obs	Forecast	Std Error	95% Confidence Limits	
55	36.8457	18.7574	0.0820	73.6095
56	52.9862	19.0276	15.6928	90.2796
57	37.4762	19.2940	-0.3393	75.2918
58	34.3596	19.5568	-3.9710	72.6903
59	21.6670	19.8161	-17.1719	60.5059
60	27.7531	20.0721	-11.5875	67.0937

Tests for Normality				
Test	--Statistic---	-----p Value-----		
Shapiro-Wilk	W 0.935382	Pr < W	0.0066	
Kolmogorov-Smirnov	D 0.131484	Pr > D	0.0220	
Cramer-von Mises	W-Sq 0.170718	Pr > W-Sq	0.0128	
Anderson-Darling	A-Sq 0.962353	Pr > A-Sq	0.0154	

Lampiran 6. Syntax ARIMA (2,1,[12])

```
data labobar1;
input y;
datalines;

proc arima data=labobar1;
identify var=y(1);
estimate
p=(1,2) q=(12)
noconstant method=cls;
forecast out=ramalan lead=6;
run;
proc univariate data=ramalan normal;
var residual;
run;
proc export data=ramalan
outfile="E:\Ramalan (2,1,[12]).xls"
dbms=excel97
replace;
run;
```

Lampiran 7. Output ARIMA (2,1,[12])

Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag				
MA1,1	-0.44457	0.14759	-3.01	0.0041	12				
AR1,1	-0.51245	0.13969	-3.67	0.0006	1				
AR1,2	-0.25445	0.14034	-1.81	0.0758	2				
Variance Estimate			421.0746						
Std Error Estimate			20.5201						
AIC			473.5882						
SBC			479.499						
Number of Residuals			53						
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.03	3	0.1695	-0.034	-0.105	-0.190	-0.144	0.009	-0.128
12	9.15	9	0.4238	0.101	0.026	0.173	-0.122	0.045	0.064
18	14.71	15	0.4722	-0.200	0.033	-0.106	0.096	0.035	0.104
24	34.15	21	0.0349	0.178	-0.111	-0.048	-0.318	0.191	0.153

Lampiran 7. Output ARIMA (2,1,[12])

Forecasts for variable y				
Obs	Forecast	Std Error	95% Confidence Limits	
55	24.1424	20.5201	-16.0763	64.3610
56	22.6474	22.8291	-22.0968	67.3916
57	13.8051	24.9927	-35.1797	62.7899
58	10.4674	28.0624	-44.5340	65.4687
59	6.1430	30.2866	-53.2177	65.5037
60	11.9707	32.3734	-51.4801	75.4214

Tests for Normality				
Test	--Statistic--		-----p Value-----	
Shapiro-Wilk	W	0.944484	Pr < W	0.0157
Kolmogorov-Smirnov	D	0.10243	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.089858	Pr > W-Sq	0.1517
Anderson-Darling	A-Sq	0.635869	Pr > A-Sq	0.0941

Lampiran 8. *Syntax* ARIMA (0,1,1)(0,0,1)¹²

```
data labobar1;
input y;
datalines;

proc arima data=labobar1;
identify var=y(1);
estimate
q=(1)(12)
noconstant method=cls;
forecast out=ramalan lead=6;
run;
proc univariate data=ramalan normal;
var residual;
run;
proc export data=ramalan
outfile="E:\Ramalan (0,1,(1,12)).xls"
dbms=excel97
replace;
run;
```

Lampiran 9. Output ARIMA (0,1,1)(0,0,1)¹²

Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag				
MA1,1	0.84157	0.08572	9.82	<.0001	1				
MA2,1	-0.43189	0.14688	-2.94	0.0049	12				
Variance Estimate			366.9066						
Std Error Estimate			19.15481						
AIC			465.3395						
SBC			469.28						
Number of Residuals			53						
* AIC and SBC do not include log determinant.									
The SAS System									
The ARIMA Procedure									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.78	4	0.5957	0.133	0.005	-0.053	-0.128	-0.022	-0.100
12	5.38	10	0.8646	0.058	0.028	0.123	-0.127	0.026	0.052
18	9.10	16	0.9093	-0.168	0.020	-0.059	0.086	0.045	0.088
24	23.30	22	0.3848	0.107	-0.113	-0.066	-0.268	0.176	0.139

Lampiran 9. Output ARIMA (0,1,1)(0,0,1)¹² (Lanjutan)

Forecasts for variable y				
Obs	Forecast	Std Error	95% Confidence Limits	
55	39.8031	19.1548	2.2604	77.3458
56	38.5506	19.3937	0.5396	76.5616
57	33.5898	19.6297	-4.8838	72.0633
58	28.5607	19.8629	-10.3699	67.4913
59	24.0860	20.0934	-15.2964	63.4684
60	30.2055	20.3213	-9.6235	70.0345

Tests for Normality				
Test	--Statistic--	-----p Value-----		
Shapiro-Wilk	W 0.923243	Pr < W	0.0022	
Kolmogorov-Smirnov	D 0.107533	Pr > D	0.1280	
Cramer-von Mises	W-Sq 0.150554	Pr > W-Sq	0.0230	
Anderson-Darling	A-Sq 0.946048	Pr > A-Sq	0.0169	

Lampiran 10. Syntax ARIMA (0,1,[1,12])

```
data labobar1;
input y;
datalines;

proc arima data=labobar1;
identify var=y(1);
estimate
q=(1,12)
noconstant method=cls;
forecast out=ramalan lead=6;
run;
proc univariate data=ramalan normal;
var residual;
run;
proc export data=ramalan
outfile="E:\Ramalan (0,1,1,12).xls"
dbms=excel97
replace;
run;
```


Lampiran 11. Output ARIMA (0,1,[1,12])

Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag				
MA1,1	0.73223	0.10428	7.02	<.0001	1				
MA1,2	-0.32679	0.13098	-2.49	0.0159	12				
Variance Estimate			408.9498						
Std Error Estimate			20.22251						
AIC			471.0892						
SBC			475.0298						
Number of Residuals			53						
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	4.28	4	0.3689	0.018	-0.079	-0.096	-0.188	-0.064	-0.129
12	13.59	10	0.1923	0.127	0.065	0.197	-0.165	0.089	0.207
18	21.02	16	0.1776	-0.282	-0.030	-0.103	0.076	0.022	0.058
24	37.40	22	0.0214	0.117	-0.097	-0.031	-0.293	0.197	0.156

Lampiran 11. Output ARIMA (0,1,[1,12]) (Lanjutan)

Forecasts for variable y				
Obs	Forecast	Std Error	95% Confidence Limits	
55	29.9788	20.2225	-9.6566	69.6142
56	35.8026	20.9349	-5.2291	76.8343
57	30.4304	21.6239	-11.9517	72.8124
58	23.1654	22.2916	-20.5253	66.8561
59	10.6640	22.9398	-34.2973	55.6252
60	7.1323	23.5702	-39.0645	53.3291
Tests for Normality				
Test	--Statistic---		-----p Value-----	
Shapiro-Wilk	W	0.925418	Pr < W	0.0027
Kolmogorov-Smirnov	D	0.117131	Pr > D	0.0696
Cramer-von Mises	W-Sq	0.164571	Pr > W-Sq	0.0159
Anderson-Darling	A-Sq	1.095743	Pr > A-Sq	0.0069

Lampiran 12. Hasil *Forecasting* ARIMA

Conditional Least Squares Estimation									
Parameter	Estimate		Standard Error	t Value	Approx Pr > t	Lag			
MA1,1	0.90577		0.05994	15.11	<.0001	1			
MA2,1	-0.44336		0.13645	-3.25	0.0019	12			
Variance Estimate				366.5468					
Std Error Estimate				19.14541					
AIC				517.7435					
SBC				521.8986					
Number of Residuals				59					
* AIC and SBC do not include log determinant.									
The SAS System									
The ARIMA Procedure									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	3.31	4	0.5068	0.175	-0.017	-0.087	-0.116	0.004	-0.018
12	5.78	10	0.8338	0.057	0.001	0.048	-0.144	0.033	0.078
18	6.98	16	0.9736	-0.083	0.031	-0.077	0.020	-0.025	0.013
24	23.60	22	0.3684	0.059	-0.119	-0.026	-0.143	0.288	0.212

Lampiran 12. Hasil Forecasting ARIMA (Lanjutan)

Forecasts for variable y					
Obs	Forecast	Std Error	95% Confidence Limits		
61	37.3453	19.1454	-0.1790	74.8696	
62	42.1488	19.2302	4.4583	79.8394	
63	41.4504	19.3147	3.5943	79.3064	
64	34.4959	19.3988	-3.5250	72.5168	
65	36.0323	19.4825	-2.1526	74.2172	
66	22.5581	19.5658	-15.7902	60.9064	
67	48.0977	19.6488	9.5867	86.6087	
68	52.5006	19.7315	13.8276	91.1736	
69	44.0799	19.8138	5.2456	82.9142	
70	35.3770	19.8958	-3.6179	74.3720	
71	37.1733	19.9774	-1.9817	76.3283	
72	31.2771	20.0587	-8.0372	70.5914	

Obs	y	FORECAST	The SAS System			RESIDUAL
			STD	L95	U95	
1	64.684
2	54.498	64.6840	19.1454	27.1597	102.208	-10.1860
3	33.853	63.7241	19.1454	26.1998	101.248	-29.8711
4	47.476	60.9093	19.1454	23.3849	98.434	-13.4333
5	53.666	59.6434	19.1454	22.1191	97.168	-5.9774
6	46.615	59.0801	19.1454	21.5558	96.604	-12.4651
7	35.679	57.9055	19.1454	20.3812	95.430	-22.2265
8	69.311	55.8110	19.1454	18.2867	93.335	13.5000
9	97.760	57.0831	19.1454	19.5588	94.607	40.6769
10	41.893	60.9163	19.1454	23.3920	98.441	-19.0233
11	63.396	59.1236	19.1454	21.5993	96.648	4.2724
12	56.912	59.5262	19.1454	22.0019	97.051	-2.6142
13	58.481	59.2799	19.1454	21.7556	96.804	-0.7989

Lampiran 12. Hasil Forecasting ARIMA (Lanjutan)

14	50.339	54.6885	19.1454	17.1642	92.213	-4.3495
15	51.000	45.1254	19.1454	7.6010	82.650	5.8746
16	43.197	51.7189	19.1454	14.1946	89.243	-8.5219
17	33.705	53.6603	19.1454	16.1360	91.185	-19.9553
18	43.726	48.6537	19.1454	11.1293	86.178	-4.9277
19	34.843	43.3407	19.1454	5.8163	80.865	-8.4977
20	82.940	57.4511	19.1454	19.9268	94.975	25.4889
21	62.466	72.4663	19.1454	34.9420	109.991	-10.0003
22	3.606	46.7545	19.1454	9.2302	84.279	-43.1485
23	58.284	52.2221	19.1454	14.6978	89.746	6.0619
24	49.608	49.9186	19.1454	12.3943	87.443	-0.3106
25	61.033	50.5850	19.1454	13.0606	88.109	10.4480
26	50.379	49.9619	19.1454	12.4376	87.486	0.4171
27	67.082	54.3525	19.1454	16.8282	91.877	12.7295
28	42.802	49.4146	19.1454	11.8903	86.939	-6.6126
29	56.947	43.3663	19.1454	5.8419	80.891	13.5807
30	39.686	50.4750	19.1454	12.9507	87.999	-10.7890
31	33.971	47.6696	19.1454	10.1453	85.194	-13.6986
32	130.019	61.0921	19.1454	23.5678	98.616	68.9269
33	70.555	52.9177	19.1454	15.3934	90.442	17.6373
34	68.066	39.4652	19.1454	1.9409	76.989	28.6008
35	52.811	62.1757	19.1454	24.6514	99.700	-9.3647
36	45.684	58.7212	19.1454	21.1969	96.246	-13.0372
37	49.830	62.2497	19.1454	24.7254	99.774	-12.4197
38	33.912	57.0685	19.1454	19.5441	94.593	-23.1565
39	42.673	60.3626	19.1454	22.8383	97.887	-17.6896
40	41.713	50.6519	19.1454	13.1276	88.176	-8.9389
41	44.430	58.4863	19.1454	20.9620	96.011	-14.0563
42	53.666	46.9244	19.1454	9.4001	84.449	6.7416
43	54.415	45.8189	19.1454	8.2946	83.343	8.5961
44	86.735	82.6899	19.1454	45.1656	120.214	4.0451
45	55.678	63.2109	19.1454	25.6865	100.735	-7.5329

Lampiran 12. Hasil *Forecasting* ARIMA (Lanjutan)

46	49.437	68.0987	19.1454	30.5744	105.623	-18.6617
47	24.021	50.7025	19.1454	13.1782	88.227	-26.6815
48	36.208	46.1687	19.1454	8.6444	83.693	-9.9607
49	36.469	44.9592	19.1454	7.4348	82.483	-8.4902
50	42.024	38.8799	19.1454	1.3556	76.404	3.1441
51	41.905	40.6325	19.1454	3.1082	78.157	1.2725
52	29.360	43.8931	19.1454	6.3688	81.417	-14.5331
53	30.183	39.8812	19.1454	2.3569	77.406	-9.6982
54	8.426	47.6011	19.1454	10.0768	85.125	-39.1751
55	67.134	45.0134	19.1454	7.4890	82.538	22.1206
56	75.406	45.4393	19.1454	7.9150	82.964	29.9667
57	51.449	43.2989	19.1454	5.7746	80.823	8.1501
58	26.571	38.8181	19.1454	1.2937	76.342	-12.2471
59	26.287	33.3286	19.1454	-4.1957	70.853	-7.0416

Tests for Normality

Test	--Statistic---	-----p Value-----
Shapiro-Wilk	W 0.930863	Pr < W 0.0024
Kolmogorov-Smirnov	D 0.118794	Pr > D 0.0377
Cramer-von Mises	W-Sq 0.208597	Pr > W-Sq <0.0050
Anderson-Darling	A-Sq 1.153705	Pr > A-Sq <0.0050

Lampiran 13. Hasil Pemodelan TRS Efek Variasi Kalender Tahap Pertama

Regression Analysis: abs resi5 versus M1t, M2t, ...

The regression equation is

$$\begin{aligned} \text{abs resi5} = & 575 + 322 \text{ M1t} + 11 \text{ M2t} + 373 \text{ M3t} - 236 \text{ M4t} + 251 \text{ M5t} + 375 \text{ M6t} \\ & + 691 \text{ M7t} + 1386 \text{ M8t} + 83 \text{ M9t} + 752 \text{ M10t} + 484 \text{ M11t} - 579 \text{ Rt-1} \\ & - 643 \text{ Rt} + 2449 \text{ Rt+1} \end{aligned}$$

Predictor	Coef	SE Coef	T	P
Constant	575.5	374.8	1.54	0.133
M1t	322.0	502.8	0.64	0.526
M2t	11.4	502.8	0.02	0.982
M3t	373.1	502.8	0.74	0.463
M4t	-236.0	502.8	-0.47	0.641
M5t	250.7	502.8	0.50	0.621
M6t	375.4	558.1	0.67	0.505
M7t	690.8	793.1	0.87	0.389
M8t	1385.7	808.3	1.71	0.094
M9t	83.1	620.3	0.13	0.894
M10t	751.8	530.0	1.42	0.164
M11t	483.8	530.0	0.91	0.367
Rt-1	-578.8	605.3	-0.96	0.345
Rt	-643.2	733.1	-0.88	0.386
Rt+1	2449.4	644.4	3.80	0.000

Lampiran 13. Hasil Pemodelan TRS Efek Variasi Kalender Tahap Pertama (Lanjutan)

S = 749.534 R-Sq = 63.6% R-Sq(adj) = 50.5%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	14	38255590	2732542	4.86	0.000
Residual Error	39	21910232	561801		
Total	53	60165823			

Source	DF	Seq SS
M1t	1	81887
M2t	1	1102566
M3t	1	101097
M4t	1	3313359
M5t	1	869856
M6t	1	1884032
M7t	1	2620494
M8t	1	8743048
M9t	1	2408000
M10t	1	693260
M11t	1	468028
Rt-1	1	180535
Rt	1	7672462
Rt+1	1	8116966

Lampiran 13. Hasil Pemodelan TRS Efek Variasi Kalender Tahap Pertama (Lanjutan)

Unusual Observations

		abs					
Obs	Mlt	resi5	Fit	SE Fit	Residual	St Resid	
9	0.00	1907	3108	494	-1201	-2.13R	
20	0.00	117	1318	494	-1201	-2.13R	
32	0.00	5612	4411	494	1201	2.13R	
33	0.00	1859	659	494	1201	2.13R	

R denotes an observation with a large standardized residual.

Lampiran 14. Hasil Pemodelan TRS Efek Variasi Kalender Tahap Kedua

Regression Analysis: Zt versus M1t, M2t, ...

The regression equation is

$$Z_t = 2275 + 754 M_{1t} - 83 M_{2t} + 90 M_{3t} - 564 M_{4t} - 246 M_{5t} - 552 M_{6t} - 624 M_{7t} \\ + 4487 M_{8t} + 844 M_{9t} - 63 M_{10t} + 421 M_{11t} + 4532 R_{t+1}$$

Predictor	Coef	SE Coef	T	P	VIF
Constant	2274.5	842.1	2.70	0.010	
M1t	754	1130	0.67	0.508	2.042
M2t	-83	1130	-0.07	0.942	2.042
M3t	90	1130	0.08	0.937	2.042
M4t	-564	1130	-0.50	0.620	2.042
M5t	-246	1130	-0.22	0.829	2.042
M6t	-552	1130	-0.49	0.628	2.042
M7t	-624	1191	-0.52	0.603	1.852
M8t	4487	1331	3.37	0.002	2.315
M9t	844	1331	0.63	0.530	2.315
M10t	-63	1191	-0.05	0.958	1.852
M11t	421	1191	0.35	0.726	1.852
Rt+1	4532	1191	3.81	0.000	1.852

Lampiran 14. Hasil Pemodelan TRS Efek Variasi Kalender Tahap Kedua (Lanjutan)

S = 1684.10 R-Sq = 68.0% R-Sq(adj) = 58.7%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	12	247604939	20633745	7.28	0.000
Residual Error	41	116284200	2836200		
Total	53	363889139			

Source	DF	Seq SS
M1t	1	53594
M2t	1	2951974
M3t	1	2293660
M4t	1	10818151
M5t	1	9267905
M6t	1	19158885
M7t	1	23730081
M8t	1	110878114
M9t	1	26829271
M10t	1	199837
M11t	1	354482
Rt+1	1	41068985

Lampiran 14. Hasil Pemodelan TRS Efek Variasi Kalender Tahap Kedua (Lanjutan)

Unusual Observations

Obs	Mlt	Zt	Fit	SE Fit	Residual	St Resid
21	0.00	3902	7650	1031	-3748	-2.82R
32	0.00	16905	11293	1031	5612	4.21R
44	0.00	7523	11293	1031	-3770	-2.83R

R denotes an observation with a large standardized residual.

Durbin-Watson statistic = 1.57988

Lampiran 15. Hasil Pengujian Asumsi Residual Identik

Regression Analysis: abs resi5 versus M1t, M2t, ...

The regression equation is

$$\text{abs resi5} = 575 + 322 \text{ M1t} + 11 \text{ M2t} + 373 \text{ M3t} - 236 \text{ M4t} + 251 \text{ M5t} + 144 \text{ M6t} \\ + 80 \text{ M7t} + 903 \text{ M8t} - 78 \text{ M9t} + 752 \text{ M10t} + 484 \text{ M11t} + 2771 \text{ Rt+1}$$

Predictor	Coef	SE Coef	T	P	VIF
Constant	575.5	370.6	1.55	0.128	
M1t	322.0	497.2	0.65	0.521	2.042
M2t	11.4	497.2	0.02	0.982	2.042
M3t	373.1	497.2	0.75	0.457	2.042
M4t	-236.0	497.2	-0.47	0.638	2.042
M5t	250.7	497.2	0.50	0.617	2.042
M6t	143.9	497.2	0.29	0.774	2.042
M7t	79.8	524.1	0.15	0.880	1.852
M8t	903.3	586.0	1.54	0.131	2.315
M9t	-77.7	586.0	-0.13	0.895	2.315
M10t	751.8	524.1	1.43	0.159	1.852
M11t	483.8	524.1	0.92	0.361	1.852
Rt+1	2771.0	524.1	5.29	0.000	1.852

S = 741.181 R-Sq = 62.6% R-Sq(adj) = 51.6%

Lampiran 15. Hasil Pengujian Asumsi Residual Identik (Lanjutan)

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	12	37642509	3136876	5.71	0.000
Residual Error	41	22523313	549349		
Total	53	60165823			

Source	DF	Seq SS
M1t	1	81887
M2t	1	1102566
M3t	1	101097
M4t	1	3313359
M5t	1	869856
M6t	1	1884032
M7t	1	2620494
M8t	1	8743048
M9t	1	2408000
M10t	1	693260
M11t	1	468028
Rt+1	1	15356882

Lampiran 15. Hasil Pengujian Asumsi Residual Identik (Lanjutan)

Unusual Observations

		abs					
Obs	Mlt	resi5	Fit	SE Fit	Residual	St Resid	
9	0.00	1907	3269	454	-1362	-2.32	R
20	0.00	117	1479	454	-1362	-2.32	R
32	0.00	5612	4250	454	1362	2.32	R
33	0.00	1859	498	454	1362	2.32	R

R denotes an observation with a large standardized residual.

Lampiran 16. Syntax AR ([3,5])

```
data labobar1;
input y;
datalines;

;
proc arima data=labobar1;
identify var=y(0);
estimate
p=(3,5)
noconstant method=cls;
forecast out=ramalan lead=6;
run;
proc print data=ramalan (obs=60);
run;
outlier maxnum=20 alpha=0.05;
proc univariate data=ramalan normal;
var residual;
run;
proc export data=ramalan
outfile="E:\AR[3,5].xls"
dbms=excel97
replace;
run;
```


Lampiran 17. Output AR ([3,5])

Conditional Least Squares Estimation									
Parameter	Estimate		Standard Error	t Value	Approx Pr > t	Lag			
AR1,1	-0.27193		0.12582	-2.16	0.0354	3			
AR1,2	0.36151		0.12592	2.87	0.0059	5			
Constant Estimate				5.814168					
Variance Estimate				1.146944					
Std Error Estimate				1.070955					
AIC				163.5623					
SBC				169.5292					
Number of Residuals				54					
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	2.98	4	0.5616	0.065	0.067	0.004	0.063	-0.100	-0.160
12	10.79	10	0.3738	-0.239	-0.073	-0.122	0.192	-0.013	0.059
18	16.22	16	0.4377	-0.012	-0.128	-0.045	-0.207	0.032	-0.080
24	24.68	22	0.3127	-0.148	0.050	0.210	0.145	0.053	0.013

Lampiran 17. Output AR ([3,5]) (Lanjutan)

Forecasts for variable y						
Obs	Forecast	Std Error	95% Confidence Limits			
55	6.1687	1.0710	4.0697	8.2677		
56	6.2233	1.0710	4.1242	8.3223		
57	6.2373	1.0710	4.1383	8.3363		
58	6.6742	1.1098	4.4989	8.8494		
59	6.8004	1.1098	4.6251	8.9756		
60	6.3481	1.1754	4.0443	8.6519		
The SAS System 05:37 Sunday, June 20, 2019 4						
Obs	y	FORECAST	STD	L95	U95	RESIDUAL
1	7.05237	6.38623	1.07095	4.28720	8.48527	0.66614
2	6.65724	6.38623	1.07095	4.28720	8.48527	0.27101
3	7.10562	6.38623	1.07095	4.28720	8.48527	0.71939
4	6.29748	6.20509	1.07095	4.10606	8.30412	0.09239
5	6.74665	6.31254	1.07095	4.21351	8.41157	0.43411
6	6.11102	6.43142	1.07095	4.33239	8.53046	-0.32040
7	5.93357	6.50834	1.07095	4.40931	8.60737	-0.57477
8	7.57968	6.54829	1.07095	4.44926	8.64732	1.03139
9	7.55329	6.42899	1.07095	4.32995	8.52802	1.12430
10	6.12304	6.63962	1.07095	4.54059	8.73865	-0.51658
11	7.18804	5.96221	1.07095	3.86317	8.06124	1.22583
12	6.87161	5.90523	1.07095	3.80620	8.00427	0.96638
13	5.97024	6.88925	1.07095	4.79021	8.98828	-0.91901
14	5.83598	6.59010	1.07095	4.49107	8.68913	-0.75412
15	5.46468	6.15910	1.07095	4.06007	8.25813	-0.69442

Lampiran 17. Output AR ([3,5]) (Lanjutan)

16	5.04471	6.78921	1.07095	4.69018	8.88825	-1.74450
17	6.79436	6.71133	1.07095	4.61230	8.81037	0.08303
18	5.24597	6.48645	1.07095	4.38741	8.58548	-1.24048
19	6.07879	6.55211	1.07095	4.45308	8.65115	-0.47332
20	4.76217	5.94210	1.07095	3.84307	8.04114	-1.17993
21	8.22898	6.21133	1.07095	4.11230	8.31037	2.01765
22	7.69542	6.61738	1.07095	4.51835	8.71641	1.07804
23	6.55322	6.41565	1.07095	4.31662	8.51468	0.13757
24	5.22843	5.77399	1.07095	3.67496	7.87302	-0.54556
25	6.54621	5.44311	1.07095	3.34408	7.54215	1.10310
26	5.84759	7.00699	1.07095	4.90796	9.10603	-1.15940
27	7.66632	7.17436	1.07095	5.07533	9.27339	0.49196
28	4.79744	6.40310	1.07095	4.30407	8.50213	-1.60566
29	7.10184	6.11415	1.07095	4.01512	8.21318	0.98769
30	4.99179	6.09597	1.07095	3.99694	8.19500	-1.10418
31	6.20758	6.62355	1.07095	4.52452	8.72258	-0.41597
32	8.63257	6.65440	1.07095	4.55537	8.75343	1.97817
33	7.52806	6.19106	1.07095	4.09203	8.29010	1.33700
34	7.79225	6.69351	1.07095	4.59448	8.79255	1.09874
35	4.53796	5.27128	1.07095	3.17225	7.37032	-0.73332
36	5.23378	6.01115	1.07095	3.91212	8.11018	-0.77737
37	6.30152	6.81596	1.07095	4.71693	8.91500	-0.51444
38	6.94851	7.30162	1.07095	5.20258	9.40065	-0.35311
39	6.29858	7.20791	1.07095	5.10888	9.30694	-0.90933
40	3.37417	5.74110	1.07095	3.64207	7.84014	-2.36693
41	4.00369	5.81671	1.07095	3.71768	7.91574	-1.81302
42	7.05428	6.37944	1.07095	4.28041	8.47848	0.67484
43	7.17816	7.40857	1.07095	5.30954	9.50761	-0.23041
44	8.23496	7.00243	1.07095	4.90340	9.10147	1.23253
45	2.91777	5.11569	1.07095	3.01665	7.21472	-2.19792

Lampiran 17. Output AR ([3,5]) (Lanjutan)

46	5.44996	5.30958	1.07095	3.21054	7.40861	0.14038
47	7.65846	6.12501	1.07095	4.02598	8.22405	1.53345
48	6.87057	7.61570	1.07095	5.51667	9.71474	-0.74513
49	7.43744	7.30917	1.07095	5.21013	9.40820	0.12827
50	6.05350	4.78640	1.07095	2.68736	6.88543	1.26710
51	6.41149	5.91606	1.07095	3.81702	8.01509	0.49543
52	6.74382	6.56030	1.07095	4.46127	8.65933	0.18352
53	7.01912	6.65181	1.07095	4.55277	8.75084	0.36731
54	7.40926	6.75939	1.07095	4.66035	8.85842	0.64987
55	.	6.16871	1.07095	4.06968	8.26774	.
56	.	6.22326	1.07095	4.12423	8.32230	.
57	.	6.23731	1.07095	4.13828	8.33635	.
58	.	6.67418	1.10985	4.49892	8.84944	.
59	.	6.80038	1.10985	4.62513	8.97564	.
60	.	6.34809	1.17544	4.04428	8.65190	.

Tests for Normality

Test	--Statistic--	-----p Value-----
Shapiro-Wilk	W 0.979609	Pr < W 0.4838
Kolmogorov-Smirnov	D 0.082157	Pr > D >0.1500
Cramer-von Mises	W-Sq 0.059458	Pr > W-Sq >0.2500
Anderson-Darling	A-Sq 0.364248	Pr > A-Sq >0.2500

Lampiran 18. *Syntax* AR ([5])

```
data labobar1;
input y;
datalines;

;
proc arima data=labobar1;
identify var=y(0);
estimate
p=(5)
noconstant method=cls;
forecast out=ramalan lead=6;
run;
outlier maxnum=20 alpha=0.05;
proc univariate data=ramalan normal;
var residual;
run;
proc export data=ramalan
outfile="E:\AR[5].xls"
dbms=excel97
replace;
run;
```

Lampiran 19. Output AR ([5])

Conditional Least Squares Estimation									
Parameter	Estimate		Standard Error	t Value	Approx Pr > t		Lag		
AR1,1	0.40886		0.12838	3.18	0.0024		5		
			Constant Estimate	3.802722					
			Variance Estimate	1.227153					
			Std Error Estimate	1.107769					
			AIC	166.261					
			SBC	170.239					
			Number of Residuals	54					
			* AIC and SBC do not include log determinant.						
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.30	5	0.3804	0.056	0.075	-0.233	0.116	-0.108	-0.024
12	19.25	11	0.0568	-0.302	-0.130	-0.119	0.262	0.107	0.083
18	24.63	17	0.1033	-0.058	-0.138	-0.018	-0.137	0.037	-0.157
24	33.28	23	0.0764	-0.130	0.006	0.235	0.139	0.054	-0.010

Lampiran 19. Output AR ([5]) (Lanjutan)

Forecasts for variable y				
Obs	Forecast	Std Error	95% Confidence Limits	
55	6.2777	1.1078	4.1065	8.4489
56	6.4241	1.1078	4.2529	8.5953
57	6.5600	1.1078	4.3888	8.7312
58	6.6725	1.1078	4.5013	8.8437
59	6.8320	1.1078	4.6609	9.0032
60	6.3694	1.1968	4.0238	8.7151

Tests for Normality				
Test	--Statistic--		-----p Value-----	
Shapiro-Wilk	W	0.977219	Pr < W	0.3905
Kolmogorov-Smirnov	D	0.085712	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.093742	Pr > W-Sq	0.1361
Anderson-Darling	A-Sq	0.497942	Pr > A-Sq	0.2113

Lampiran 20. Syntax MA ([3,5])

```
data labobar1;
input y;
datalines;

;
proc arima data=labobar1;
identify var=y(0);
estimate
q=(3,5)
noconstant method=cls;
forecast out=ramalan lead=6;
run;
outlier maxnum=20 alpha=0.05;
proc univariate data=ramalan normal;
var residual;
run;
proc export data=ramalan
outfile="E:\Ramalan.xls"
dbms=excel97
replace;
run;
```


Lampiran 21. Output MA ([3,5])

Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag				
MA1,1	0.32991	0.13272	2.49	0.0162	3				
MA1,2	-0.21267	0.13612	-1.56	0.1244	5				
Constant Estimate			6.375381						
Variance Estimate			1.237525						
Std Error Estimate			1.112441						
AIC			167.6669						
SBC			173.6339						
Number of Residuals			54						
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	1.33	4	0.8561	0.091	-0.009	-0.015	0.028	0.106	-0.039
12	13.75	10	0.1846	-0.219	-0.233	-0.165	0.239	0.005	-0.008
18	20.02	16	0.2193	-0.130	-0.182	0.044	-0.108	0.033	-0.128
24	28.19	22	0.1696	-0.151	0.096	0.187	0.145	0.040	-0.010

Lampiran 21. Output MA ([3,5]) (Lanjutan)

Forecasts for variable y				
Obs	Forecast	Std Error	95% Confidence Limits	
55	6.4608	1.1124	4.2804	8.6411
56	6.0606	1.1124	3.8803	8.2409
57	6.1256	1.1124	3.9452	8.3059
58	6.5823	1.1714	4.2863	8.8782
59	6.5690	1.1714	4.2730	8.8649
60	6.3754	1.1951	4.0331	8.7177
Tests for Normality				
Test	--Statistic--		-----p Value-----	
Shapiro-Wilk	W	0.974336	Pr < W	0.2969
Kolmogorov-Smirnov	D	0.071995	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.053911	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq	0.406074	Pr > A-Sq	>0.2500

Lampiran 22. Syntax MA ([5])

```
data labobar1;
input y;
datalines;

;
proc arima data=labobar1;
identify var=y(0);
estimate
q=(5)
noconstant method=cls;
forecast out=ramalan lead=6;
run;
outlier maxnum=20 alpha=0.05;
proc univariate data=ramalan normal;
var residual;
run;
proc export data=ramalan
outfile="E:\Ramalan.xls"
dbms=excel97
replace;
run;
```

Lampiran 23. Output MA ([5])

Conditional Least Squares Estimation									
Parameter	Estimate		Standard Error	t Value	Approx Pr > t		Lag		
MA1,1	-0.26126		0.13598	-1.92	0.0602		5		
			Constant Estimate	6.397205					
			Variance Estimate	1.315503					
			Std Error Estimate	1.146954					
			AIC	170.0152					
			SBC	173.9932					
			Number of Residuals	54					
			* AIC and SBC do not include log determinant.						
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.87	5	0.3193	0.061	-0.020	-0.284	0.077	0.089	-0.001
12	24.71	11	0.0100	-0.297	-0.192	-0.135	0.349	0.116	0.054
18	31.44	17	0.0177	-0.130	-0.168	0.041	-0.080	0.031	-0.177
24	40.94	23	0.0120	-0.156	0.061	0.227	0.148	0.014	-0.053

Lampiran 23. *Output* MA ([5]) (Lanjutan)

Forecasts for variable y				
Obs	Forecast	Std Error	95% Confidence Limits	
55	6.4978	1.1470	4.2498	8.7458
56	6.4285	1.1470	4.1805	8.6764
57	6.4163	1.1470	4.1683	8.6642
58	6.5407	1.1470	4.2927	8.7886
59	6.6252	1.1470	4.3772	8.8732
60	6.3972	1.1855	4.0738	8.7206

Tests for Normality				
Test	--Statistic--		-----p Value-----	
Shapiro-Wilk	W	0.977795	Pr < W	0.4117
Kolmogorov-Smirnov	D	0.10252	Pr > D	>0.1500
Cramer-von Mises	W-Sq	0.079457	Pr > W-Sq	0.2136
Anderson-Darling	A-Sq	0.436529	Pr > A-Sq	>0.2500

Lampiran 24. *Syntax Forecasting Regresi Time Series* dengan Memodelkan Residual Data dengan ARIMA

```
data labobar1;
input y;
datalines;

;
proc arima data=labobar1;
identify var=y(0);
estimate
p=(3,5)
noconstant method=cls;
forecast out=ramalan lead=12;
run;
proc print data=ramalan (obs=60);
run;
outlier maxnum=20 alpha=0.05;
proc univariate data=ramalan normal;
var residual;
run;
proc export data=ramalan
outfile="E:\AR[3,5] 61-72.xls"
dbms=excel97
replace;
run;
```

Lampiran 25. Output Forecasting Regresi Time Series dengan Memodelkan Residual Data dengan ARIMA

Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag				
AR1,1	-0.12678	0.13262	-0.96	0.3431	3				
AR1,2	0.14119	0.13565	1.04	0.3023	5				
Constant Estimate			6.53058						
Variance Estimate			1.156509						
Std Error Estimate			1.075411						
AIC			181.9194						
SBC			188.2024						
Number of Residuals			60						
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	6.07	4	0.1939	0.167	0.224	0.003	-0.007	-0.062	-0.110
12	28.24	10	0.0016	-0.297	-0.089	-0.214	0.374	0.058	0.136
18	40.19	16	0.0007	0.076	-0.098	-0.053	-0.155	-0.255	-0.179
24	59.33	22	<.0001	-0.324	0.116	0.075	0.137	0.196	0.143

Lampiran 25. Output Forecasting Regresi Time Series dengan Memodelkan Residual Data dengan ARIMA (Lanjutan)

Forecasts for variable y					
Obs	Forecast	Std Error	95% Confidence Limits		
61	6.6229	1.0754	4.5151	8.7307	
62	6.7565	1.0754	4.6488	8.8643	
63	6.6031	1.0754	4.4953	8.7109	
64	6.7329	1.0840	4.6083	8.8576	
65	6.7086	1.0840	4.5840	8.8332	
66	6.6285	1.0946	4.4832	8.7739	
67	6.6309	1.0947	4.4853	8.7766	
68	6.6124	1.0947	4.4667	8.7580	
69	6.6408	1.0954	4.4939	8.7878	
70	6.6371	1.0954	4.4901	8.7841	
71	6.6282	1.0956	4.4808	8.7755	
72	6.6249	1.0957	4.4774	8.7723	

The SAS System						
Obs	y	FORECAST	STD	L95	U95	RESIDUAL
1	7.05237	6.62607	1.07541	4.51830	8.73384	0.42630
2	6.65724	6.62607	1.07541	4.51830	8.73384	0.03117
3	7.10562	6.62607	1.07541	4.51830	8.73384	0.47955
4	6.29748	6.57202	1.07541	4.46426	8.67979	-0.27454
5	6.74665	6.62212	1.07541	4.51435	8.72989	0.12453
6	6.11102	6.62546	1.07541	4.51770	8.73323	-0.51444
7	6.85520	6.67213	1.07541	4.56436	8.77990	0.18307
8	7.60320	6.67849	1.07541	4.57073	8.78626	0.92471
9	8.06130	6.64498	1.07541	4.53721	8.75274	1.41632
10	5.04471	6.61405	1.07541	4.50628	8.72181	-1.56934

Lampiran 25. Output Forecasting Regresi Time Series dengan Memodelkan Residual Data dengan ARIMA (Lanjutan)

11	7.45263	6.42947	1.07541	4.32170	8.53723	1.02316
12	7.20415	6.47646	1.07541	4.36869	8.58423	0.72769
13	5.97024	6.96452	1.07541	4.85676	9.07229	-0.99428
14	5.83598	6.72392	1.07541	4.61616	8.83169	-0.88794
15	5.46468	6.32950	1.07541	4.22173	8.43727	-0.86482
16	5.04471	6.82592	1.07541	4.71816	8.93369	-1.78121
17	6.79436	6.80786	1.07541	4.70010	8.91563	-0.01350
18	5.24597	6.68072	1.07541	4.57295	8.78848	-1.43475
19	6.91553	6.71500	1.07541	4.60724	8.82277	0.20053
20	4.25419	6.44075	1.07541	4.33299	8.54852	-2.18656
21	7.81827	6.57776	1.07541	4.47000	8.68553	1.24051
22	7.54813	6.61313	1.07541	4.50537	8.72090	0.93500
23	7.00524	6.73192	1.07541	4.62416	8.83969	0.27332
24	6.34036	6.51579	1.07541	4.40802	8.62356	-0.17543
25	6.54621	6.17427	1.07541	4.06651	8.28204	0.37194
26	5.84759	6.74633	1.07541	4.63856	8.85410	-0.89874
27	7.66632	6.79248	1.07541	4.68472	8.90025	0.87384
28	4.79744	6.68973	1.07541	4.58197	8.79750	-1.89229
29	7.10184	6.68443	1.07541	4.57666	8.79219	0.41741
30	4.99179	6.48291	1.07541	4.37514	8.59068	-1.49112
31	6.97336	6.74799	1.07541	4.64023	8.85576	0.22537
32	8.73543	6.71263	1.07541	4.60486	8.82040	2.02280
33	7.81092	6.57508	1.07541	4.46731	8.68284	1.23584
34	7.90942	6.64922	1.07541	4.54145	8.75698	1.26020
35	6.20334	6.12789	1.07541	4.02012	8.23566	0.07545
36	5.26269	6.52489	1.07541	4.41712	8.63265	-1.26220
37	6.30152	6.76119	1.07541	4.65343	8.86896	-0.45967
38	6.94851	6.84696	1.07541	4.73919	8.95473	0.10155
39	6.29858	6.98012	1.07541	4.87236	9.08789	-0.68154
40	3.37417	6.60753	1.07541	4.49976	8.71530	-3.23336

Lampiran 25. Output Forecasting Regresi Time Series dengan Memodelkan Residual Data dengan ARIMA (Lanjutan)

41	4.00369	6.39269	1.07541	4.28492	8.50046	-2.38900
42	7.05428	6.62177	1.07541	4.51400	8.72953	0.43251
43	6.60557	7.08388	1.07541	4.97611	9.19165	-0.47831
44	8.05915	6.91230	1.07541	4.80454	9.02007	1.14685
45	6.37911	6.11263	1.07541	4.00487	8.22040	0.26648
46	6.28002	6.25841	1.07541	4.15064	8.36617	0.02161
47	7.44868	6.50484	1.07541	4.39708	8.61261	0.94384
48	6.36819	6.65449	1.07541	4.54672	8.76225	-0.28630
49	7.43744	6.87229	1.07541	4.76452	8.98005	0.56515
50	6.05350	6.48691	1.07541	4.37914	8.59468	-0.43341
51	6.41149	6.60991	1.07541	4.50214	8.71767	-0.19842
52	6.74382	6.63935	1.07541	4.53158	8.74712	0.10447
53	7.01912	6.66225	1.07541	4.55448	8.77002	0.35687
54	7.40926	6.76784	1.07541	4.66007	8.87560	0.64142
55	7.73421	6.53030	1.07541	4.42253	8.63807	1.20391
56	7.02340	6.54594	1.07541	4.43817	8.65371	0.47746
57	8.22700	6.54340	1.07541	4.43563	8.65117	1.68360
58	7.09357	6.54107	1.07541	4.43331	8.64884	0.55250
59	7.38001	6.68628	1.07541	4.57851	8.79404	0.69373
60	7.32778	6.57956	1.07541	4.47180	8.68733	0.74822

Tests for Normality

Test	--Statistic--	-----p Value-----
Shapiro-Wilk	W 0.956513	Pr < W 0.0318
Kolmogorov-Smirnov	D 0.128189	Pr > D 0.0155
Cramer-von Mises	W-Sq 0.160267	Pr > W-Sq 0.0182
Anderson-Darling	A-Sq 0.890772	Pr > A-Sq 0.0223

Lampiran 26. Surat Legalisir Data



PT Pelayaran Nasional Indonesia (Persero)
Kantor Cabang Surabaya J. Pahlawan No 112
Surabaya 60175 T. +62-31-3559950 (Hunting) |
Call Center : 081333604563 | www.pelni.co.id |
Email : surabaya@pelni.co.id

Surabaya, 28 Januari 2019

Nomor : 01.28/09/S/563/2019
Perihal : Surat Permohonan
Ijin Memperoleh Data untuk
Tugas Akhir

Kepada Yth.
Kepala Departemen
Institut Teknologi Sepuluh Nopember
Fakultas Matematika Komputasi dan Sains
Data Departemen Statistika
SURABAYA (60111)

Dengan Hormat,

1. Menunjuk Surat Saudara Perihal Ijin Pengambilan Data Mahasiswa, No.006447/IT2.VI.9.2/TU.00.09/2019, Tanggal 23 Januari 2019 pada prinsipnya dapat diterima.
2. Untuk Kelengkapan tugas agar memperhatikan hal-hal sebagai berikut :
 - a. Mahasiswa yang menjalankan Pengambilan Data harus mematuhi peraturan yang ada di PT. PELNI.
 - b. Asuransi Mahasiswa yang menjalankan Pengambilan Data di tanggung oleh Mahasiswa.
 - c. Akomodasi Mahasiswa selama menjalankan Pengambilan Data di tanggung Mahasiswa.
 - d. Jangka waktu Pengambilan Data selama 3 (tiga) bulan terhitung mulai tanggal 04 Pebruari s/d 02 Mei 2019.
3. Adapun penempatan untuk pengambilan data di Dinas Usaha, Dinas Administrasi dan Armada.
4. Demikian atas kerjasamanya yang baik kami ucapkan terimakasih

PT. PELNI (Persero)



PRESDA SIMANGASING, SH
Kepala Cabang Surabaya

Tembusan Yth.

1. Kabag Administrasi PT.Pelni Surabaya
2. Kabag Usaha PT.Pelni.Surabaya
3. Sdr. Eliya Ainul Farri
4. Dosen Pembimbing. Bapak/Ibu. Irhamah.M.Si,PhD



BIODATA PENULIS

Penulis bernama lengkap Eliya Ainul Farri, akrab dipanggil Eliya atau Ainul, yang terlahir dari pasangan Supriyadi dan Muyasaroh ini hampir dilahirkan di Kuala Lumpur, Malaysia. Namun, dikarenakan suatu hal akhirnya penulis lahir di Indonesia tepatnya di Tulungagung pada 11 Oktober 1995. Penulis merupakan anak bungsu dari 3 bersaudara. Pendidikan formal yang telah ditempuh oleh penulis antara lain SD Negeri 3 Batangsaren (2002-2008), SMP Negeri 1 Kauman (2008-2011), SMA Negeri 1 Kauman (2011-2014).



Penulis diterima sebagai mahasiswa Jurusan Statistika Prodi DIII yang kini berubah menjadi Departemen Statistika Bisnis melalui jalur ujian Diploma III reguler pada tahun 2014 dengan NRP 1314 030 040. Kemudian penulis melanjutkan pendidikan Sarjana dengan diterima sebagai mahasiswa Lintas Jalur Jurusan Statistika Fakultas Matematika, Komputasi, dan Sains Data pada tahun 2017 dengan NRP 062117 4500 0017.

Selama penulis menjadi mahasiswa selain aktif di bidang akademik, penulis juga terlibat dalam berbagai organisasi kemahasiswaan maupun kepanitiaan. Beberapa pengalaman organisasi kemahasiswaan penulis diantaranya adalah Anggota UKM Teater Tiyang Alit, Staff Kaderisasi JMMI AKSI, Staff Ahli Kaderisasi JMMI Integrasi, Staff Kaderisasi FORSIS, Ketua Muslimah FORSIS Al-Fatih, dan penulis juga aktif dalam kegiatan organisasi ekstra kampus yaitu KAMMI. Beberapa kepanitiaan penulis yang memiliki kepriibadian Koleris-Melankolis ini diantaranya adalah Koordinator Acara CERITA 2016, SC Acara GMAIL 2016, Koordinator Acara PSI 1, Pimpinan Produksi Pentas Studi Larva Teater Tiyang Alit ITS 2015, OC GMAIL 25, dan OC RDK 36.

Kontribusi penulis ketika menjadi mahasiswa lintas jalur adalah menjadi bagian penyusun Buku Panduan Bersama Lembaga Dakwah komisi kemuslimahan yang merupakan inti dari acara Mukhtamar

Dakwah Kampus. Penulis juga merupakan musyrifah dari asrama salah satu sekolah islam di Surabaya selama kurang lebih 1,5 tahun sampai penelitian ini diterbitkan.

Selama penulis menjadi mahasiswa prodi diploma, penulis memperoleh beasiswa bidikmisi. Penulis memiliki prinsip *Khairunnas anfauhum linnas*, sebaik-baik manusia adalah yang bermanfaat bagi manusia lain. Kritik dan saran kepada penulis terkait Tugas Akhir ini dapat disampaikan melalui email eliyaainul1@gmail.com.