



TUGAS AKHIR – SS 145561

**PERAMALAN BILANGAN *SUNSPOT* TAHUN 2018
DENGAN MENGGUNAKAN ARIMA *BOX-JENKINS***

Henni Jovita Sari
NRP 10611500000074

Pembimbing

Dr. WahyuWibowo,S.Si, M.Si

**Program Studi Diploma III
Departemen Statistika Bisnis
Fakultas Vokasi
Institut Teknologi Sepuluh Nopember
Surabaya 2018**



TUGAS AKHIR – SS 145561

**PERAMALAN BILANGAN *SUNSPOT* TAHUN 2018
DENGAN MENGGUNAKAN *ARIMA BOX-JENKINS***

Henni Jovita Sari
NRP 10611500000074

Pembimbing

Dr. Wahyu Wibowo, S.Si, M.Si

**Program Studi Diploma III
Departemen Statistika Bisnis
Fakultas Vokasi
Institut Teknologi Sepuluh Nopember
Surabaya 2018**



FINAL PROJECT – SS 145561

**FORECASTING SUNSPOT NUMBER IN 2018
USING ARIMA *BOX-JENKINS***

Henni Jovita Sari
NRP 10611500000074

Supervisor

Dr. WahyuWibowo,S.Si, M.Si

**Study Program Diploma III
Departement Of Business Statistics
Faculty Of Vocations
Institut Teknologi Sepuluh Nopember
Surabaya 2018**

LEMBAR PENGESAHAN

PERAMALAN BILANGAN *SUNSPOT* TAHUN 2018 DENGAN MENGGUNAKAN ARIMA *BOX-JENKINS*

TUGAS AKHIR

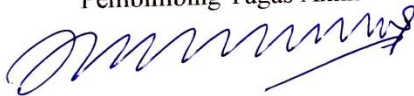
Diajukan Untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Ahli Madya Pada
Departemen Statistika Bisnis
Fakultas Vokasi
Institut Teknologi Sepuluh Nopember

Oleh:

HENNI JOVITA SARI
NRP: 1061150000074

SURABAYA, 29 JUNI 2018

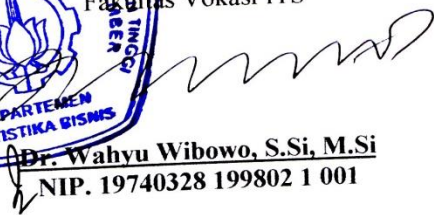
Menyetujui,
Pembimbing Tugas Akhir



Dr. Wahyu Wibowo, S.Si, M.Si
NIP. 19740328 199802 1 001



Mengetahui,
Kepala Departemen Statistika Bisnis
Fakultas Vokasi ITS



Dr. Wahyu Wibowo, S.Si, M.Si
NIP. 19740328 199802 1 001

PERAMALAN BILANGAN *SUNSPOT* TAHUN 2018 DENGAN MENGGUNAKAN *ARIMA BOX-JENKINS*

Nama : Henni Jovita Sari
NRP : 1061150000074
Departemen : Statistika Bisnis Fakultas Vokasi ITS
Pembimbing : Dr. Wahyu Wibowo, S.Si, M.Si

Abstrak

Sunspot merupakan bintik hitam yang berada di lapisan fotosfer matahari yang memiliki suhu lebih rendah dibandingkan daerah lain di fotosfer. Semakin banyak jumlah sunspot dan grup sunspot maka dapat menyebabkan ledakan berupa flare dan Coronal Mass Ejection (CME) yang dapat berpengaruh pada cuaca antariksa, gangguan magnetosfer bumi, dan pancaran sinar yang dihasilkan matahari. Selama ini LAPAN Watukosek melakukan prediksi bilangan sunspot namun tidak secara rutin dilakukan dan dipublikasikan kepada masyarakat. Melihat kondisi tersebut pada penelitian ini akan meramalkan bilangan sunspot periode 2018 dengan menggunakan metode ARIMA Box-Jenkins. Model peramalan yang dihasilkan dapat digunakan untuk mengetahui aktivitas matahari sehingga dapat mencegah dampak yang ditimbulkan jika bilangan sunspot tergolong tinggi. Model terbaik dari peramalan bilangan sunspot yaitu ARIMA([1,2,29],1,0). Bilangan sunspot tertinggi diprediksi terjadi pada bulan November dan yang terendah terjadi pada bulan Februari, walaupun bilangan sunspot tertinggi di bulan November tetapi memiliki bilangan sunspot yang rendah dan kemungkinan tidak berdampak pada bumi. Kondisi matahari pada tahun 2018 merupakan *quiet cycle* yaitu matahari berada pada kondisi tenang dan merupakan akhir dari siklus matahari ke- 24 sehingga kemungkinan besar tidak ada efek astronomi yang membahayakan.

Kata kunci : ARIMA, Bilangan Sunspot, Siklus Matahari.

FORECASTING SUNSPOT NUMBER IN 2018 USING ARIMA BOX- JENKINS

Name : Henni Jovita Sari
NRP : 10611500000074
Departmen : Business Statistics Faculty of Vocations ITS
Supervisor : Dr. Wahyu Wibowo, S.Si, M.Si

Abstract

Sunspot is a black dot area located in the solar photosphere layer having lower temperature compared to the other areas of the photosphere. The more total number and group of sunspot cause several types of explosion called flare and coronal mass ejection (CME), that influences astronomical weather, earth magnetosfer disruption and the sunrays emitted by the sun per se. Until recently, LAPAN Watukosek has predicted the sunspot number but in a non-regular manner and the results were not publicly published. Based on that condition, this study forecasted the sunspot number in 2018 by using ARIMA Box-Jenkins. The resulted forecasting model can be used to mitigate solar activity so that avoiding the destructive impact of the solar activity when the number of sunspot considerably high. The best model from the sunspot number forecasting were ARIMA([1,2,29],1,0). The highest sunspot number was predicted to occur on November and the lowest one was on February. Although the highest sunspot number was predicted on November, but in fact, it was with lower number, implying no significant effect on Earth. Solar condition in 2018 is classified as a quiet cycle, that is the sun is on the steady condition and in its latest 24th cycle, thereby less likely a catastrophic effect will occur.

Keywords: ARIMA, Solar Cycle, Sunspot Number.

KATA PENGANTAR

Puji syukur kehadiran Allah SWT atas limpahan rahmat dan hidayah-Nyayang tidak pernah berhenti sehingga penulis dapat menyelesaikan laporan Tugas Akhir yang berjudul **“PERAMALAN BILANGAN *SUNSPOT* TAHUN 2018 DENGAN MENGGUNAKAN ARIMA *BOX-JENKINS*”**. Penulis menyadari bahwa dalam penyusunan Tugas Akhir ini tidak terlepas dari bantuan dan dukungan dari berbagai pihak. Oleh karena itu, pada kesempatan ini penulis mengucapkan terima kasih yang kepada:

1. Bapak Dr. Wahyu Wibowo, S.Si, M.Si selaku Kepala Departemen Statistika Bisnis Fakultas Vokasi ITS dan sebagai dosen pembimbing yang telah mengarahkan dan memberikan dukungan bagi penulis untuk dapat menyelesaikan Tugas Akhir.
2. Bapak Ir. Nanang Widodo, M.Si selaku pembimbing lapangan Tugas Akhir di Balai Pengamatan Antariksa dan Atmosfer Pasuruan yang telah memberikan arahan dalam melakukan pengamatan langsung pada *sunspot* serta memberikan penjelasan tentang kondisi antariksa.
3. Ibu Ir. Sri Pingit Wulandari, M.Si selaku Kepala Program Studi Diploma III Departemen Statistika Bisnis Fakultas Vokasi ITS, dosen penguji sekaligus sebagai validator yang telah memberikan saran dan perbaikan pada Tugas Akhir ini.
4. Ibu Noviyanti Santoso, S.Si, M.Si selaku dosen penguji atas saran dan kritikan yang membangun dalam menyelesaikan Tugas Akhir ini.
5. Bapak Dr. Drs. Brodjol Sutijo Suprih Ulama, M.Si selaku dosen wali dan dosen mata kuliah Metode Peramalan sekaligus sebagai Sekretaris Departemen Statistika Bisnis yang telah memberikan nasehat, motivasi, serta bimbingan kepada penulis selama menempuh pendidikan.

6. Seluruh dosen dan karyawan Departemen Statistika BisnisFakultas Vokasi ITS.
7. Bapak Dian Yudha Risdianto, S.T.,M.T selaku kepala Balai Pengamatan Antariksa dan Atmosfer Pasuruan yang telah memberikan kesempatan pada penulis untuk melakukan pengamatan dan pengambilan data bilangan *sunspot*.
8. Ibu, Ayah,mbak Pritha, mbak Ines, Mas Ridzky, Mas Eko atas doa, kasih sayang, dukungan, dan Alfatih yang telah memberikan semangat untuk penulis sehingga dilancarkan dalam menyelesaikan Tugas Akhir ini.
9. Amyl, Era, Rani, dan Rianis yang selalu memberikan dukungan, semangat, dan masukan dalam penyelesaian Tugas Akhir.
10. Teman-teman HEROES Angkatan 2015 yang telah menjadi teman yang baik dan memberikan masukan bagi penulis untuk menyelesaikan Tugas Akhir.
11. Semua pihak yang telah memberikan dukungan yang tidak dapat disebutkan satu persatu oleh penulis.

penulis menyadari bahwa dalam penulisan Tugas Akhir ini masih jauh dari kesempurnaan sehingga kritik dan saran yang membangun sangat diperlukan demi perbaikan isi Tugas Akhir kedepannya. Harapan penulis bahwa Tugas Akhir ini dapat memberikan manfaat kepada berbagai pihak.

Surabaya, Juni2018

Penulis

DAFTAR ISI

	Halaman
HALAMANJUDUL	i
LEMBAR PENGESAHAN	iii
ABSTRAK	v
ABSTRACT	vii
KATA PENGANTAR	ix
DAFTAR ISI	xi
DAFTAR TABEL	xiii
DAFTAR GAMBAR	xv
DAFTAR LAMPIRAN	xvii
BAB IPENDAHULUAN	1
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah.....	3
1.3 Tujuan.....	3
1.4 Manfaat.....	4
1.5 Batasan Masalah.....	4
BAB IITINJAUAN PUSTAKA	5
2.1 Analisis Time Series.....	5
2.1.1 Model ARIMA <i>Box-Jenkins</i>	5
2.1.2 Identifikasi Model.....	7
2.1.3 Estimasi dan Pengujian Parameter.....	10
2.1.4 Asumsi Residual.....	13
2.1.5 Pemilihan Model Terbaik.....	14
2.2 Matahari.....	15
BAB IIIMETODOLOGI PENELITIAN	19
3.1 Sumber Data.....	19
3.2 Variabel Penelitian.....	19
3.3 Langkah Analisis.....	20
3.4 Diagram Alir.....	20
BAB IVANALISIS DAN PEMBAHASAN	23
4.1 Karakteristik Bilangan <i>Sunspot</i> Tahun 1988 hingga 2017.....	23

4.2	Peramalan Bilangan <i>Sunspot</i> tahun 2018 dengan Menggunakan ARIMA <i>Box-Jenkins</i>	25
4.2.1	Identifikasi Model ARIMA <i>BoxJenkins</i>	25
4.2.2	Estimasi Model Bilangan <i>Sunspot</i>	28
4.2.3	Pengujian Model Bilangan <i>Sunspot</i>	29
4.2.4	Pengujian Asumsi Residual	32
4.2.5	Pemilihan Model Terbaik.....	35
4.2.6	Peramalan Bilangan <i>Sunspot</i>	37
BAB V KESIMPULAN DAN SARAN		39
5.1	Kesimpulan	39
5.2	Saran	39
DAFTAR PUSTAKA		41
LAMPIRAN		43
BIODATA PENULIS		

DAFTAR TABEL

Tabel 2.1	Transformasi <i>Box-Cox</i>	8
Tabel 2.2	Identifikasi Model ARIMA	10
Tabel 3.1	Struktur Data Penelitian.....	19
Tabel 4.1	Hasil Pengujian Parameter.....	30
Tabel 4.2	Hasil Uji Residual <i>White Noise</i>	32
Tabel 4.3	Hasil Uji Residual Berdistribusi Normal	34
Tabel 4.4	Kriteria Pemilihan Model Terbaik.....	35
Tabel 4.5	Hasil Ramalan Bilangan <i>Sunspot</i>	37

DAFTAR GAMBAR

Gambar 2.1	Sket dan Posisi <i>Sunspot</i>	16
Gambar 2.2	Rotasi Differensial	17
Gambar 2.3	Puntiran Medan Magnet yang Keluar	18
Gambar 3.1	Diagram Alir	21
Gambar 4.1	Time Series Plot Bilangan <i>Sunspot</i>	23
Gambar 4.2	<i>Boxplot</i> Bilangan <i>Sunspot</i> pada Siklus ke-22 hingga Siklus ke-24	24
Gambar 4.3	(a) <i>Box-Cox</i> Sebelum Transformasi dan (b) <i>Box-Cox</i> Setelah Transformasi.....	26
Gambar 4.4	Plot ACF Bilangan <i>Sunspot</i> Sebelum <i>Differencing</i>	27
Gambar 4.5	<i>Time Series Plot</i> Setelah <i>Differencing</i>	27
Gambar 4.6	Plot ACF Bilangan <i>Sunspot</i> yang Telah Stasioner	28
Gambar 4.7	Plot PACF Bilangan <i>Sunspot</i> yang Telah Stasioner	29
Gambar 4.8	<i>Time Series Plot</i> Data Aktual dan Hasil Ramalan <i>Out Sample</i>	36
Gambar 4.9	Plot Data Aktual dengan Ramalan Periode Januari 1988 hingga Desember 2018.....	38

DAFTAR LAMPIRAN

	Halaman
Lampiran 1	Data Bilangan <i>Sunspot</i> Tahun 1988- 2017 Sebelum Penambahan Nilai Minimal Sebesar 0,23.....43
Lampiran 2	Data Bilangan <i>Sunspot</i> Tahun 1988-2017 Setelah Penambahan Nilai Minimal Sebesar 0,23.....44
Lampiran 3	Surat Permohonan Memperoleh Data.....45
Lampiran 4	Surat Balasan Permohonan Memperoleh Data. .46
Lampiran 5	Surat Pernyataan Keaslian Data.....47
Lampiran 6	Data <i>In Sample</i> Setelah Transformasi.....48
Lampiran 7	<i>Output</i> Minitab Autocorrelation Function Sebelum <i>Differencing</i>49
Lampiran 8	<i>Output</i> Minitab Autocorrelation Function Sesudah <i>Differencing</i>51
Lampiran 9	<i>Output</i> Minitab Partial Autocorrelation Function Sesudah <i>Differencing</i>.....53
Lampiran 10	Perhitungan Manual RMSE dan SMAPE Model ARIMA (2,1,0)55
Lampiran 11	Perhitungan Manual RMSE dan SMAPE Model ARIMA ([1,2,29],1,0).....56
Lampiran 12	<i>Syntax</i> SAS Model ARIMA (2,1,2).....57
Lampiran 13	<i>Syntax</i> SAS Model ARIMA (2,1,0).....58
Lampiran 14	<i>Syntax</i> SAS Model ARIMA (0,1,2).....59
Lampiran 15	<i>Syntax</i> SAS Model ARIMA ([1,2,0,20,29],1,[1,2,22,30])60
Lampiran 16	<i>Syntax</i> SAS Model ARIMA ([1,2,9,20,29],1,0)61
Lampiran 17	<i>Syntax</i> SAS Model ARIMA ([1,2,29],1,0)62
Lampiran 18	<i>Syntax</i> SAS Model ARIMA (0,1,[1,2,22,30]) ...63
Lampiran 19	<i>Output</i> SAS Pengujian Model ARIMA (2,1,2) .64
Lampiran 20	<i>Output</i> SAS Pengujian Model ARIMA (2,1,0) .65
Lampiran 21	<i>Output</i> SAS Pengujian Model ARIMA (0,1,2) .66
Lampiran 22	<i>Output</i> SAS Pengujian Model ARIMA ([1,2,9,20,29],1,[1,2,22,30])67

Lampiran 23	<i>Output</i> SAS Pengujian Model ARIMA ([1,2,9,20,29],1,0)	68
Lampiran 24	<i>Output</i> SAS Pengujian Model ARIMA ([1,2,29],1,0)	69
Lampiran 25	<i>Output</i> SAS Pengujian Model ARIMA (0,1,[1,2,22,30])	70
Lampiran 26	<i>Output</i> Visual Pengujian Asumsi Distribusi Normal pada ARIMA (2,1,0).....	71
Lampiran 27	<i>Output</i> Visual Pengujian Asumsi Distribusi Normal pada ARIMA([1,2,20],1,0)	71
Lampiran 28	Perhitungan Manual Distribusi Normal <i>Outsample</i>	72
Lampiran 29	<i>Output</i> Visual Distribusi Normal <i>Outsample</i>	72

BAB I

PENDAHULUAN

1.1 LatarBelakang

Aurora merupakan cahaya yang muncul di malam hari akibat dari pelepasan massa pada aktivitas matahari yang bersinggungan dengan medan magnet bumi sehingga menghasilkan partikel yang bertabrakan dengan nitrogen dan oksigen di atmosfer bumi (National Resources Canada, 2017). Dibalik keindahan aurora yang biasa terdapat pada daerah lintang tinggi ternyata aurora merupakan indikasi gangguan medan magnet bumi yang disebabkan oleh pelepasan partikel akibat dari aktivitas matahari. Aktivitas matahari yang ditandai oleh adanya ledakan pada kromosfer yang disebut *flare*, *flare* tersebut akan memunculkan lontaran massa di korona yang disebut *Corona Mass Ejection (CME)*. Semakin tinggi aktivitas matahari maka semakin banyak *flare* dan CME yang akan terlontar keluar dari matahari yang dapat menyebabkan gangguan pada medan magnet bumi dan cuaca antariksa. Aktivitas matahari dalam kondisi maksimum yang menghasilkan *flare* dan CME dapat menyebabkan badai matahari. Akibat dari CME yang terjadi pada badai matahari jika mengenai *magnetosfer* bumi akan menyebabkan badai geomagnet. Badai matahari yang menyebabkan gangguan *magnetosfer* terjadi lebih dari 2 minggu pada bulan Oktober dan November 2003, *flare* yang terbentuk mencapai kelas tertinggi sehingga CME yang terbentuk menyebabkan gangguan pada komunikasi radio, penerbangan, dan jaringan listrik (ESA, 2016). Badai matahari yang menyebabkan badai geomagnet juga menyebabkan kerusakan pembangkit listrik Quebec di Kanada tahun 1989 yang berakibat pada rusaknya pembangkit listrik sehingga dilakukan pemadaman listrik selama 12 jam (NASA, 2009).

Banyaknya *flare* yang terbentuk pada kromosfer matahari ditentukan oleh bintik hitam pada lapisan fotosfer yang disebut *sunspot*. *Sunspot* memiliki medan magnet mencapai 1000 hingga

4000 *Gauss* dimana memiliki suhu yang lebih rendah dibandingkan daerah sekelilingnya. Kemunculan *sunspot* tidak hanya berguna untuk menentukan periode rotasi diferensial matahari tetapi juga sebagai penentu tingkat aktivitas matahari. Semakin banyak jumlah *sunspot* maka semakin tinggi aktivitas matahari. Jumlah kemunculan *sunspot* memiliki periode tertentu yang teratur dan membentuk sebuah siklus yang akan menjadi indikator bagi siklus matahari. Periode siklus matahari berkisar antara 9 hingga 13 tahun dengan rata-rata siklus sekitar 11 tahun. Puncak siklus matahari memiliki aktivitas yang sangat tinggi yang menyebabkan terjadi ledakan berupa *flare* dan CME yang sangat mempengaruhi cuaca antariksa. Dampak dari aktivitas matahari yaitu semburan radio matahari, badai matahari, gangguan sistem dan orbit wahana antariksa yang dapat meningkatkan resiko tabrakan antar benda buatan (LAPAN, 2012).

Cuaca antariksa sangat berpengaruh pada teknologi yang ada di bumi maupun di luar angkasa mengingat saat ini kehidupan manusia tidak lepas dari teknologi maka pemantauan dan prediksi cuaca antariksa sangat berguna untuk mencegah dampak negatif yang ditimbulkan, oleh karena itu pada penelitian ini akan meramalkan bilangan *sunspot* untuk mengetahui aktivitas matahari pada tahun 2018. Penelitian sebelumnya oleh Nurfahmi (2015) tentang analisis pergerakan *sunspot* untuk mengkaji potensi terjadinya *flare* bulan Maret hingga Juni 2015 didapatkan hasil bahwa pergerakan *sunspot* selalu berubah setiap harinya dan *flare* yang terjadi bulan Maret hingga Juni 2015 berpotensi rendah untuk menimbulkan *event* astronomi. Werner (2012) juga melakukan penelitian untuk memprediksikan bilangan *sunspot* dengan model *autoregressive* dan didapatkan model yang sesuai adalah AR (9) dengan data yang digunakan adalah tahun 1749 hingga 2010.

LAPAN merupakan lembaga penerbangan dan antariksa yang menjadi pusat studi sains antariksa dan teknologi dirgantara di Indonesia termasuk melakukan pengamatan aktivitas matahari,

namun LAPAN tidak melakukan peramalan aktivitas matahari untuk beberapa periode kedepan secara rutin padahal dengan adanya ramalan tersebut dapat memprediksi pengaruh aktivitas matahari terhadap penerbangan, jaringan listrik, operasional satelit, bahkan bahaya radiasi sinar ultraviolet. Oleh sebab itu perlu dilakukan peramalan aktivitas matahari dengan menggunakan bilangan *sunspot* bulanan untuk mengetahui aktivitas matahari tahun 2018 yang dapat digunakan untuk mengantisipasi dampak buruk aktivitas matahari. Pesnell (2008) merangkum metode penelitian dari beberapa peneliti yang memprediksikan siklus matahari ke-24 pada jurnal yang ditulisnya, berdasarkan jurnal tersebut terdapat beberapa peneliti yang menggunakan metode *Autoregressive*, *Moving Average*, dan ARMA untuk meramalkan bilangan *sunspot*. Oleh karena itu pada penelitian ini digunakan metode ARIMA *Box-Jenkins* karena mampu menganalisis data yang memiliki pola acak, trend, dan musiman.

1.2 RumusanMasalah

Sunspot sangat berpengaruh pada tingkat aktivitas matahari, puncak aktivitas matahari dapat menyebabkan badai matahari yang dapat mengganggu *magnetosfer* bumi yang berakibat pada gangguan dan rusaknya teknologi di permukaan bumi maupun di luar angkasa, serta adanya pancaran sinar ultraviolet yang berlebih yang dapat membahayakan kesehatan kulit, namun badan pusat antariksa di Indonesia (LAPAN) tidak melakukan prediksi aktivitas matahari untuk beberapa periode secara rutin, sehingga pada penelitian ini dilakukan peramalan bilangan *sunspot* tahun 2018 menggunakan metode ARIMA *Box-Jenkins*.

1.3 Tujuan

Berdasarkan latar belakang dan rumusan masalah yang telah dijelaskan sebelumnya, tujuan yang ingin dicapai pada penelitian ini adalah memperoleh model peramalan terbaik mendapatkan hasil ramalan dari bilangan *sunspot* untuk tahun 2018.

1.4 Manfaat

Model peramalan yang didapatkan mampu memprediksi bilangan *sunspot* sehingga dapat mengetahui aktivitas matahari bulanan pada tahun 2018 yang dapat digunakan untuk mengetahui potensi terjadinya *flare* yang berpengaruh pada bumi sehingga dapat memberikan informasi khususnya kepada masyarakat jika aktivitas matahari sangat tinggi maka perlu berhati-hati terhadap pancaran sinar ultraviolet yang dipancarkan matahari.

1.5 Batasan Masalah

Penelitian ini menggunakan data bilangan *sunspot* bulanan yang diambil di Balai Pengamatan Atmosfer dan Antariksa Pasuruan pada bulan Januari 1988 hingga Desember 2017.

BAB II TINJAUAN PUSTAKA

2.1 Analisis *Time Series*

Analisis *time series* merupakan salah satu metode kuantitatif yang digunakan untuk menduga keadaan masa depan berdasarkan data masa lalu. Tujuan dari metode peramalan *time series* adalah menemukan pola data masa lalu yang dapat digunakan untuk memprediksi data dimasa depan (Makridakis, Wheelwright, & McGEE, 1999).

2.1.1 Model ARIMA *Box-Jenkins*

Model ARIMA terdiri dari unsur *Autoregressive* (AR) dan *Moving Average* (MA). Kombinasi dari model AR dan MA menghasilkan model *Autoregressive Moving Average* (ARMA), sedangkan model *Autoregressive Integrated Moving Average* (ARIMA) adalah model yang berisi unsur *differencing*.

1. Model *Autoregressive* (AR)

Model *autoregressive* (AR) merupakan model yang menggambarkan kondisi pengamatan pada waktu ke- t berhubungan linear dengan pengamatan pada waktu sebelumnya $t-1, t-2, \dots, t-p$. Bentuk fungsi persamaan untuk model pada *autoregressive* (AR) pada orde p ditunjukkan pada Persamaan 2.1.

$$\dot{Z}_t = \phi_1 \dot{Z}_{t-1} + \dots + \phi_p \dot{Z}_{t-p} + a_t \quad (2.1)$$

dimana :

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

ϕ_p : parameter *autoregressive* ke- p

a_t : nilai kesalahan pada waktu ke- t

μ : suatu konstanta rata-rata

2. Model *Moving Average* (MA)

Model *moving average* menunjukkan adanya hubungan antara waktu ke- t dengan residual data pada waktu sebelumnya yang persamaannya dapat ditulis pada Persamaan 2.2.

$$\dot{Z}_t = a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (2.2)$$

dimana :

$$\begin{aligned} \theta_q &= \text{parameter } \textit{moving average} \text{ ke-}q \\ a_t &= \text{nilai kesalahan pada waktu ke-}t \end{aligned}$$

3. Model *Autoregressive Moving Average* (ARMA)

Model *autoregressive moving average* (ARMA) merupakan model gabungan antara model AR (p) dan MA (q). Bentuk fungsi persamaan untuk model *autoregressive moving average* (ARMA) seperti pada Persamaan 2.3.

$$\dot{Z}_t = \phi_1 \dot{Z}_{t-1} + \dots + \phi_p \dot{Z}_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (2.3)$$

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

Model ARIMA adalah model peramalan yang termasuk dalam kelompok linier. Model ARIMA dapat digunakan pada data yang memiliki pola non musiman ataupun musiman. Model data yang memiliki pola non musiman dengan *differencing* orde d yang dapat dinotasikan sebagai ARIMA (p, d, q). Secara matematis model ARIMA (p, d, q) dapat ditulis sebagai berikut (Wei, 2006).

$$\phi_p (B)^p (1 - B)^d \dot{Z}_t = \theta_q (B)^q a_t \quad (2.4)$$

Model ARIMA $(P, D, Q)^S$ merupakan model yang membentuk pola musiman, dimana P merupakan orde untuk AR, D untuk *differencing* dan Q untuk orde MA. Bentuk model ARIMA $(P, D, Q)^S$ sesuai dengan persamaan berikut.

$$\Phi_p (B^s)(1 - B^s)^D \dot{Z}_t = \Theta_Q (B^S) a_t \quad (2.5)$$

Model ARIMA multiplikatif dinotasikan dengan ARIMA $(p, d, q) (P, D, Q)^S$ yang mempunyai non musiman dan musiman pada pengamatan waktu ke- t . Bentuk fungsi persamaan model ARIMA multiplikatif adalah sebagai berikut.

$$\Phi_p(B^s)\phi_p(B)(1-B^s)^d(1-B^s)^D\dot{Z}_t = \theta_q(B)\Theta_Q(B^s)a_t \quad (2.6)$$

dimana :

- \dot{Z}_t : $Z_t - \mu$
- B : operator *back shift*
- Φ_p : orde P pada koefisien komponen AR musiman
- Θ_Q : orde Q pada koefisien komponen MA musiman
- d : banyaknya *differencing* yang dilakukan saat kondisi non musiman
- D : banyaknya *differencing* yang dilakukan saat kondisi musiman

2.1.2 Identifikasi Model

Identifikasi model dapat diketahui melalui fungsi autokorelasi (ACF) dan fungsi autokorelasi parsial (PACF). Pendugaan model dilakukan untuk mengetahui kestasioneran data dalam *mean* dan stasioner dalam *varians*.

1. Stasioneritas Data

Analisis *time series* ARIMA Box Jenkins memiliki syarat yaitu data historis yang akan diramalkan harus stasioner dalam *mean* dan stasioner dalam *varians*. Pemeriksa kestasioneran dapat menggunakan plot data *time series* antara nilai Z_t dengan waktu t . jika plot *time series* berfluktuasi di sekitar garis yang sejajar dengan sumbu waktu (t) maka dikatakan deret stasioner dalam *mean*. Dalam *time series* ada kemungkinan data tersebut tidak stasioner baik dalam *mean* maupun *varians*. Hal ini dikarenakan *mean* tidak konstan atau variansnya tidak konstan sehingga untuk menghilangkan ketidakstasioneran terhadap *mean*, maka menggunakan metode perbedaan atau *differencing*. Metode *differencing* terdapat pada Persamaan 2.7 dengan Z_t' merupakan nilai *series* setelah dilakukan *differencing* (Makridakis, Wheelwright, & McGee, 1999).

$$Z_t' = Z_t - Z_{t-1} \quad (2.7)$$

Jika menggunakan operator *backshift* maka nilai *series* setelah dilakukan *differencing* seperti pada Persamaan 2.8

$$Z_t' = (1 - B)Z_t$$

Maka secara umum *differencing* orde ke-d dapat dituliskan sebagai berikut

$$Z_t' = (1 - B)^d Z_t \quad (2.9)$$

Sedangkan untuk mengatasi ketidakstasioneran dalam varians, dapat dilakukan transformasi data. Transformasi yang umum digunakan adalah tranformasi *Box-cox*. Persamaan umum tranformasi *Box-Cox* terdapat pada Persamaan 2.10

$$T(Z_t) = \frac{Z_t^\lambda - 1}{\lambda} \quad (2.10)$$

Keterangan

λ : nilai parameter transformasi (*rounded value*)

Tabel 2.1 menunjukkan rumus tranformasi *Box-Cox* berdasarkan nilai estimasi *rounded value* (λ) yang didapatkan (Wei, 2006).

Tabel 2.1. Tranformasi *Box-Cox*

Nilai Estimasi λ	Transformasi
-1,0	$1/Z_t$
-0,5	$1/\sqrt{Z_t}$
0	$\text{Ln } Z_t$
0,5	$\sqrt{Z_t}$
1	Z_t

2. Fungsi ACF dan PACF

Fungsi Autokorelasi (ACF) adalah hubungan linier antara Z_t dengan Z_{t+k} pada suatu data *time series*. Pada data yang telah stasioner memiliki nilai rata-rata μ dan *varians* σ^2 yang konstan. Berikut merupakan persamaan antara Z_t dengan Z_{t+k} (Wei, 2006).

$$\gamma_k = \text{cov}(Z_t, Z_{t+k}) = E(Z_t - \mu)(Z_{t+k} - \mu) \quad (2.11)$$

Fungsi autokorelasi dapat dituliskan sebagai berikut.

$$\hat{\rho}_k = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2}; k = 0, 1, 2, 3, \dots \quad (2.12)$$

Dimana $\bar{Z} = \frac{\sum_{t=1}^n Z_t}{n}$

Identifikasi model lainnya adalah Fungsi Autokorelasi Parsial (PACF). PACF merupakan suatu fungsi untuk mengukur keeratan hubungan antara Z_t dengan Z_{t+k} setelah pengaruh variabel $Z_{t+1}, Z_{t+2}, \dots, Z_{t+k-1}$ dihilangkan yang terdapat pada Persamaan berikut. (Wei, 2006). Perhitungan nilai PACF lag ke- k dimulai dari menghitung $\hat{\phi}_{11} = \hat{\rho}_1$ sedangkan untuk menghitung $\hat{\phi}_{kk}$ dilakukan dengan menggunakan persamaan berikut.

$$\hat{\phi}_{kk} = \text{corr}(Z_t, Z_{t+k} \mid Z_{t+1}, Z_{t+1}, \dots, Z_{t+k-1}) \quad (2.13)$$

$$\hat{\phi}_{k+1, k+1} = \frac{\hat{\rho}_{k+1} - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_{k+1-j}}{1 - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_j} \quad (2.14)$$

dimana $\phi_{k+1, j} = \phi_{kj} - \phi_{k+1, k+1}, \phi_{k, k+1-j} \quad j = 1, 2, \dots, k$

Pengidentifikasi model ARIMA dapat dilakukan dengan melihat plot *time series*, plot ACF dan PACF. Plot ACF dan PACF digunakan untuk menentukan orde p dan q dari model ARIMA. Secara teoritis, bentuk-bentuk plot ACF dan PACF dari model ARIMA terdapat pada Tabel 2.2.

Tabel 2.2.Identifikasi Model ARIMA

Model	ACF	PACF
AR (p)	Turun cepat secara eksponensial	Terpotongsetelah lag p
MA (q)	Terpotongsetelah lag q	Turun cepat secara eksponensial
ARMA (p,q)	Turun cepat setelah lag $(q-p)$	Turun cepat setelah lag $(p-q)$

2.1.3 Estimasi dan Pengujian Parameter

Metode penaksiran parameter yang dapat digunakan adalah *conditional least square* (CLS). Metode *Conditional Least Square* (CLS) dilakukan dengan cara mencari nilai parameter yang meminimumkan jumlah kuadrat *error* atau SSE. Misalkan untuk AR(1), maka model regresi dengan variabel predictor Z_{t-1} dan variabel respon Z_t yang dinyatakan sebagai berikut (Wei, 2006).

$$Z_t - \mu = \phi(Z_{t-1} - \mu) + a_t \quad (2.15)$$

Kemudian meregresikan variabel prediktor Z_{t-1} dengan variabel respon Z_t yang dinyatakan sebagai berikut

$$(Z_t - \mu) - \phi(Z_{t-1} - \mu) \quad (2.16)$$

karena observasi dimulai dari Z_1, Z_2, \dots, Z_n maka regresi hanya dapat dimulai pada saat $t = 2$ sampai $t = n$, sehingga didapatkan fungsi *conditional sum of square* sebagai berikut

$$S_c(\phi, \mu) = \sum_{t=2}^n [(Z_t - \mu) - \phi(Z_{t-1} - \mu)]^2 \quad (2.17)$$

Penaksiran parameter metode *least square*, taksiran μ dan ϕ dilakukan dengan meminimumkan $S_c(\phi, \mu)$ oleh karena itu, perlu dilakukan penurunan terhadap ϕ dan μ kemudian disamakan dengan nol. Selanjutnya operasi turunan terhadap μ dengan membuat $\partial S_c / \partial \mu = 0$ sehingga didapatkan persamaan

$$\frac{\partial S_c}{\partial \mu} = \sum_{t=2}^n 2[(Z_t - \bar{Z}) - \phi(Z_{t-1} - \bar{Z})](-1 + \phi) = 0 \quad (2.18)$$

Kemudian, untuk memperoleh nilai μ untuk model AR (1) adalah sebagai berikut

$$\mu = \frac{1}{(n-1)(1-\phi)} = \left[\sum_{t=2}^n Z_t - \phi \sum_{t=2}^n Z_{t-1} \right] \quad (2.19)$$

Sedangkan untuk n yang sangat besar, maka persamaan menjadi berikut

$$\hat{\mu} = \frac{1}{1-\phi} (\bar{Z} - \phi \bar{Z}) = \bar{Z} \quad (2.20)$$

Kemudian untuk parameter ϕ dengan cara yang sama didapatkan operasi turunan sebagai berikut.

$$\frac{\partial S_c(\phi, \bar{Z})}{\partial \phi} = \sum_{t=2}^n 2[(Z_t - \bar{Z}) - \phi(Z_{t-1} - \bar{Z})](Z_{t-1} - \bar{Z}) = 0 \quad (2.21)$$

Sehingga taksiran parameter ϕ untuk model AR(1) adalah sebagai berikut.

$$\hat{\phi} = \frac{\sum_{t=2}^n (Z_t - \bar{Z})(Z_{t-1} - \bar{Z})}{\sum_{t=2}^n (Z_{t-1} - \bar{Z})^2} \quad (2.22)$$

Pengujian signifikansi parameter ϕ dan θ menggunakan statistik uji t yang dibandingkan dengan nilai tabel $t_{\alpha/2; (n-n_p)}$. Pengujian untuk signifikansi parameter AR adalah sebagai berikut:

Hipotesis:

H_0 : $\phi = 0$ (Parameter model AR tidak signifikan)

H_1 : $\phi \neq 0$ (Parameter model AR signifikan)

Statistik Uji :

$$t_{hitung} = \frac{\hat{\phi}}{SE(\hat{\phi})} \quad (2.23)$$

dengan

$$SE(\hat{\phi}) = \sqrt{\frac{\hat{\sigma}_\alpha^2}{\sum_{t=1}^n Z_{t-1}^2}} \quad (2.24)$$

dan

$$\hat{\sigma}_\alpha^2 = \sum_{t=1}^n \frac{(Z_t - \hat{\phi}Z_{t-1})^2}{(n-1)} \quad (2.25)$$

Jika ditetapkan tingkat signifikan α , maka H_0 ditolak jika $|t_{hitung}| > t_{\alpha/2; (n-p)}$ atau $P_{value} < \alpha$.

Sedangkan pengujian untuk parameter MA dengan hipotesis,
Hipotesis

H_0 : $\theta = 0$ (Parameter model MA tidak signifikan)

H_1 : $\theta \neq 0$ (Parameter model MA signifikan)

Statistik Uji:

$$t_{hitung} = \frac{\hat{\theta}}{SE(\hat{\theta})} \quad (2.26)$$

dengan

$$SE(\hat{\theta}) = \sqrt{\frac{\hat{\sigma}_\alpha^2}{\sum_{t=1}^n Z_{t-1}^2}} \quad (2.27)$$

$$\hat{\sigma}_\alpha^2 = \sum_{t=1}^n \frac{(Z_t - \hat{\theta}Z_{t-1})^2}{(n-1)} \quad (2.28)$$

Jika ditetapkan tingkat signifikan α , maka H_0 ditolak jika $|t_{hitung}| > t_{\alpha/2; (n-q)}$ atau $P_{value} < \alpha$, dimana n adalah banyaknya observasi, p adalah jumlah parameter dari model AR yang ditaksir

ϕ sedangkan q adalah jumlah parameter dari model MA yang ditaksir θ (Wei, 2006).

2.1.4 Asumsi Residual

Pada tahap ini dilakukan pengujian tentang asumsi residual untuk model ARIMA yaitu meliputi asumsi residual *white noise* dan distribusi normal.

a. Uji Residual *White Noise*

Pengujian residual *white noise* menggunakan uji Ljung & Box dilakukan untuk mengetahui apakah *varians* bernilai konstan atau tidak. Bertujuan untuk menguji apakah residual memenuhi asumsi *white noise* dengan statistik uji yang diberikan oleh Ljung & Box (Wei, 2006) menggunakan hipotesis sebagai berikut:

H_0 : $\rho_1 = \rho_2 = \dots = \rho_n = 0$ (Residual *white noise*)

H_1 : Minimal ada satu $\rho_k \neq 0$ untuk $k = 1, 2, \dots, n$ (Residual tidak *white noise*)

Statistik Uji :

$$Q = n(n+2) \sum_{k=1}^K (n-k)^{-1} \hat{\rho}_k^2 \quad (2.29)$$

Jika ditetapkan tingkat signifikan α , maka H_0 ditolak jika nilai $Q > \chi^2_{(\alpha; k-p-q)}$ atau $P_{value} < \alpha$.

dimana :

n : Jumlah observasi.

p : Banyaknya parameter model AR.

q : Banyaknya parameter model MA.

$\hat{\rho}_k$: Taksiran autokorelasi residual lag k .

k :Lag.

b. Uji Residual Distribusi Normal

Pengujian residual distribusi normal menggunakan uji *Kolmogorov-Smirnov*. Uji *Kolmogorov-Smirnov* memiliki dua fungsi distribusi kumulatif yaitu $F_0(a_t)$ sebagai fungsi distribusi normal dan $S(a_t)$ sebagai fungsi distribusi empiris (Daniel, 1989).

Hipotesis:

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

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

Pada taraf signifikan sebesar α , H_0 ditolak apabila $D_{hitung} > D_{(1-\alpha, n)}$

Statistik Uji :

$$D_{hitung} = \sup_{a_t} |S(a_t) - F_0(a_t)| \quad (2.30)$$

dimana,

$S(a_t)$ = fungsi peluang kumulatif yang dihitung dari data sampel

$F_0(a_t)$ = fungsi peluang kumulatif yang dihitung dari distribusi normal

\sup_{a_t} = nilai maksimum untuk semua a_t dari $|S(a_t) - F_0(a_t)|$

2.1.5 Pemilihan Model Terbaik

Penentuan model terbaik pada peramalan dengan menggunakan metode *ARIMA Box-Jenkins* dapat dilihat dengan menggunakan nilai RMSE dan SMAPE. Model terbaik adalah model dengan nilai RMSE dan SMAPE terkecil. RMSE merupakan kriteria pemilihan model terbaik berdasarkan pada hasil sisa ramalan yang digunakan untuk segala satuan data. RMSE digunakan dengan tujuan supaya satuan pengukuran data tidak berubah, dapat dihitung dengan rumus sebagai berikut (Gooijer & Hyndman, 2006).

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Z_t - \hat{Z}_t)^2} \quad (2.31)$$

Keterangan:

n : banyaknya observasi

Z_t : nilai aktual pada waktu ke- t

\hat{Z}_t : nilai ramalan pada waktu ke- t

Sedangkan *Symmetric Mean Absolute Percentage Error* (SMAPE) digunakan untuk mengetahui rata-rata harga mutlak dari persentase kesalahan tiap model. SMAPE digunakan untuk data yang mempunyai nilai besar dan dapat menghindari permasalahan *error* yang besar ketika nilai aktualnya melebihi nilai ramalannya atau sebaliknya. Rumus SMAPE dapat dituliskan seperti berikut ini (Gooijer & Hyndman, 2006).

$$SMAPE = \frac{1}{n} \sum_{t=1}^n \frac{|Z_t - \hat{Z}_t|}{\frac{1}{2}(Z_t + \hat{Z}_t)} \times 100\% \quad (2.32)$$

2.2 Matahari

Matahari merupakan bintang yang menjadi pusat tata surya sekaligus menjadi sumber energi disekitar tata surya. Jarak matahari dan bumi sebesar 150 juta kilometer dengan massa sebesar $1,9 \times 10^{30}$ kg sehingga massa matahari lebih besar 330.000 kali massa bumi. Secara umum matahari dibagi menjadi tiga bagian yaitu angkasa matahari, permukaan, dan bagian dalam matahari. Hasil pengamatan memperlihatkan beragam aktivitas matahari yang terjadi pada bagian angkasa matahari yaitu pada lapisan fotosfer, kromosfer, dan korona (Admirianto, 2009).

Sunspot merupakan daerah gelap dipermukaan matahari yang memiliki medan magnet yang sangat kuat dan terjadi karena adanya perbedaan temperatur di permukaan matahari. Daerah sunspot memiliki suhu yang lebih rendah dibandingkan daerah *fotosfer* lainnya. *Sunspot* terdapat dua bagian yaitu inti yang disebut *umbra* dan daerah yang lebih terang disebut *penumbra*. Banyaknya *sunspot* dapat mempengaruhi aktivitas matahari,

semakin banyak *sunspot* di *fotosfer* maka aktivitas matahari semakin tinggi begitu sebaliknya. Jumlah *sunspot* pada *fotosfer* umumnya dinyatakan dengan bilangan *sunspot* (*sunspot number*). Bilangan *sunspot* dikenalkan oleh R. Wolf pada tahun 1868 dengan persamaan berikut (Kaufmann, 1978) .


$$R = k(10g + f) \quad (2.33)$$

Keterangan

k : konstanta (0,624)

g : jumlah grup *sunspot*


f : jumlah *sunspot* individu



Gambar 2.1 Sket dan Posisi *Sunspot*

Gambar 2.1 menunjukkan perbedaan aktivitas matahari, aktivitas matahari maksimum ditunjukkan oleh gambar (a) dimana terdapat banyak grup *sunspot*. Untuk menghitung bilangan *sunspot* maka posisi *sunspot* dibagi kedalam posisi *north* (utara) dan *south* (selatan). Pada posisi utara terdapat 2 grup *sunspot* dan 38 *sunspot* individu sehingga bilangan *sunspot* pada posisi utara adalah 36,19. Posisi selatan terdapat 8 grup *sunspot* dan 124 *sunspot* individu sehingga memiliki bilangan *sunspot* sebesar 127,3. Secara keseluruhan terdapat 10 grup *sunspot* dan 162 *sunspot* individu dengan bilangan *sunspot* sebesar 163,49 pada tanggal 19 Maret 1991. Gambar (b) menunjukkan matahari


pada aktivitas minimum hal ini dapat diketahui karena tidak terdapat *sunspot* baik pada posisi utara maupun selatan. Pengamatan dilakukan pada cuaca cerah tanggal 19 Maret 2009.



Gambar 2.2 Rotasi Differensial

Tahun 1960, H. A. Babcock mencetuskan teori aktivitas medan magnet yang dapat membentuk *sunspot*. Gambar 2.2 diketahui bahwa arah rotasi medan magnet terbagi dalam dua daerah yaitu rotasi pada bagian kutub dan rotasi pada ekuator. Garis- garis medan magnet berjalan dari kutub utara ke kutub selatan dan ketika garis medan magnet tersebut berada pada ekuator maka memiliki kecepatan rotasi yang lebih cepat dibandingkan daerah kutub. Perbedaan rotasi pada matahari disebut rotasi differensial. Setelah mengalami satu putaran, garis medan magnet pada ekuator memiliki jarak lebih panjang dan setelah mengalami dua hingga tiga putaran garis- garis medan magnet tersebut memiliki jarak semakin panjang. Sehingga setelah beberapa rotasi garis medan magnet akan terpuntir. Jika puntiran garis medan magnet maka intensitas lokal dari medan magnet semakin besar, akibatnya setelah mencapai puncak puntiran intensitas medan magnet beratus- ratus kali lebih kuat

dibandingkan daerah lainnya sehingga dapat menyebabkan keluarnya medan magnet dari daerah fotosfer seperti Gambar 2.3.



Gambar 2.3 Puntiran Medan Magnet yang Keluar

Sesuai Gambar 2.3 semakin banyak garis- garis medan magnet yang keluar dan memiliki bentuk tidak beraturan maka akan menyebabkan ledakan pada atmosfer matahari yang disebut *flare*. *Flare* adalah pelepasan energi elektromagnetik dari matahari dalam bentuk cahaya sinar-X dan sinar gamma disertai dengan panas. Sinar- X dan sinar gamma mencapai bumi sekitar 8 menit dan dapat mengganggu komunikasi radio. Ada 3 kelas *flare* yaitu:

1. Kelas C adalah *flare* terkecil dan memiliki sedikit efek pada bumi
2. Kelas M adalah *flare* dengan kekuatan sedang yang dapat menyebabkan badai geomagnetik kecil.
3. Kelas X adalah *flare* yang terkuat yang dapat menyebabkan badai geomagnetik yang besar.

(Natural Resources Canada, 2017)

BAB III METODOLOGI PENELITIAN

3.1 Sumber Data

Data yang digunakan dalam penelitian ini adalah data sekunder yaitu data bilangan *sunspot* bulan Januari 1988 hingga Desember 2017 yang diperoleh secara resmi dari Balai Pengamatan Antariksa dan Atmosfer Pasuruan yang beralamat di Jl. Raya Watukosek No.1 Gempol, Pasuruan pada tanggal 11 Januari 2018 yang ditunjukkan pada surat keterangan sesuai Lampiran 3 hingga Lampiran 5.

3.2 Variabel Penelitian

Variabel penelitian yang digunakan adalah data bilangan *sunspot* bulan Januari tahun 1988 hingga Desember 2017. Struktur data penelitian ini dapat dilihat pada Tabel 3.1.

Tabel 3.1 Struktur Data Penelitian

Tahun	Bulan	Bilangan <i>Sunspot</i>
1988	Januari	Z_1
	Februari	Z_2

	November	Z_{11}
	Desember	Z_{12}
2000	Januari	Z_{145}
	Februari	Z_{146}

	November	Z_{155}
	Desember	Z_{156}
...
2017	Januari	Z_{349}
	Februari	Z_{350}

	November	Z_{359}
	Desember	Z_{360}


3.3 Langkah Analisis

Langkah-langkah analisis peramalan bilangan *sunspot* menggunakan metode ARIMA *Box-jenkins* dapat dituliskan sebagai berikut :

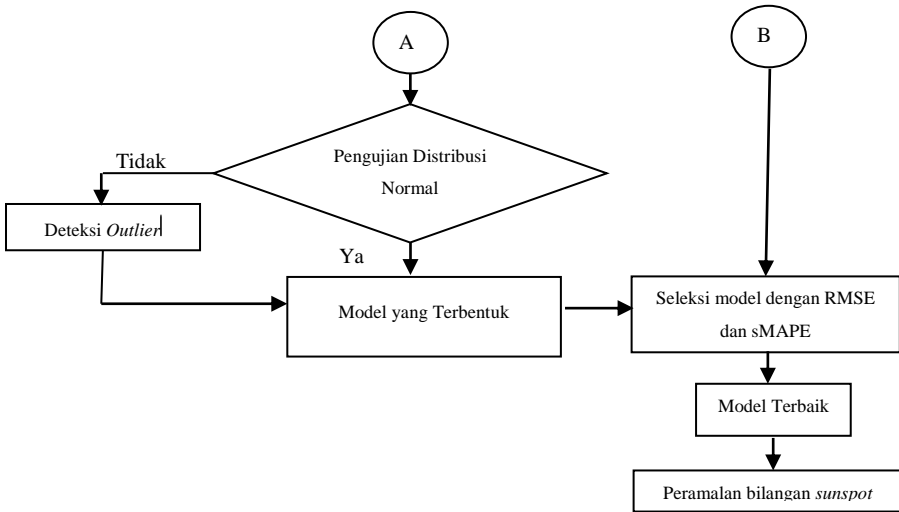
1. Membagi data bilangan *sunspot* menjadi *in sample* dan *out sample*. *In sample* dimulai bulan Januari 1988 hingga Desember 2016 dan *out sample* dimulai bulan Januari 2017 hingga Desember 2017.
2. Membuat pola *time series* untuk mengidentifikasi stasioneritas data *in sample*, jika data tidak stasioner dalam varians maka dilakukan transformasi *Box-Cox* dan jika data tidak stasioner dalam *mean* maka dilakukan *differencing*.
3. Membuat plot ACF dan PACF
4. Mengidentifikasi dan menduga orde model ARIMA berdasarkan plot ACF dan PACF
5. Melakukan estimasi parameter dan pengujian signifikansi parameter model, jika parameter tidak signifikan maka dilakukan estimasi parameter dari model dugaan lainnya.
6. Melakukan pemeriksaan diagnostic uji residual *white noise* dan distribusi normal. Apabila model yang ada tidak memenuhi asumsi residual *white noise* dan distribusi normal maka dilakukan deteksi *outlier*.
7. Apabila model yang didapatkan lebih dari satu, maka dilakukan seleksi model dengan hasil *out sample* digunakan kriteria RMSE dan SMAPE yang mempunyai nilai terkecil.
8. Setelah tahap pertama hingga ketujuh terpenuhi dan didapatkan model peramalan terbaik maka dapat dilakukan peramalan bilangan *sunspot* tahun 2018.

3.4 Diagram Alir

Alur peramalan bilangan *sunspot* dengan menggunakan ARIMA *Box-Jenkins* dapat dilihat pada Gambar 3.1



Gambar 3.1 Diagram Alir



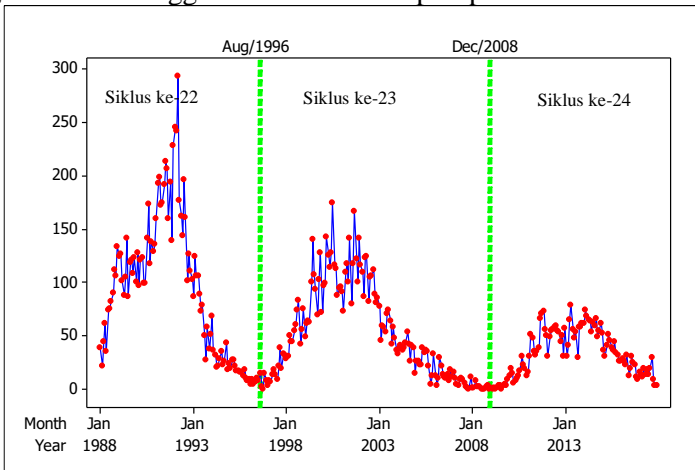
Gambar 3.1 Diagram Alir (Lanjutan)

BAB IV ANALISIS DAN PEMBAHASAN

Padababiniakandijelaskananalisisdanpembahasantentangpe ramalan bilangan *sunspot* tahun 2018 yang dimulai dengan karakteristik data menggunakan *time series plot* dan *boxplot*, pemodelan ARIMA yang terdiri dari identifikasi model, pengujian model, pengujian asumsi residual, dan peramalan.

4.1 Karakteristik bilangan *sunspot* tahun 1988 hingga 2017


Karakteristik bilangan *sunspot* pada bulan Januari 1988 hingga Desember 2017 sesuai pada Lampiran 1 dapat digambarkan menggunakan *time series plot* pada Gambar 4.1



Gambar 4.1 Time Series Plot Bilangan Sunspot

Gambar 4.1 menunjukkan bahwa terdapat tiga siklus pada tahun 1988 hingga 2017 dimana siklus matahari ke-22 terjadi pada bulan September tahun 1986 hingga Juli 1996, dan siklus matahari ke-23 terjadi pada bulan Agustus 1996 hingga Desember tahun 2008 serta siklus matahari ke-24 dimulai pada Januari 2009 dan berjalan hingga sekarang. Aktivitas matahari tertinggi tahun 1988 hingga 2017 terjadi pada siklus ke-22 yaitu pada bulan

Maret 1992. Tingginya aktivitas matahari disebabkan oleh banyaknya *sunspot* yang berada pada lapisan fotosfer matahari yang dapat menyebabkan ledakan yang disebut *flare*. Gambar 4.1 menunjukkan terjadinya penurunan siklus dari siklus ke-22 hingga siklus ke-24 yang mana dapat mempengaruhi cuaca antariksa, satelit, dan radiasi ultraviolet yang dipancarkan matahari. Berikut merupakan *boxplot* bilangan *sunspot* siklus matahari ke-22 hingga ke-24.



Gambar 4.2 *Boxplot* Bilangan *Sunspot* pada Siklus ke- 22 hingga Siklus ke- 24

Gambar 4.2 pada siklus matahari ke-22 hingga 24 memiliki bentuk *boxplot* yang semakin pendek yang berarti data bilangan *sunspot* pada siklus matahari ke- 22 memiliki keragaman yang paling besar dibandingkan dengan siklus ke- 24, sedangkan siklus ke- 24 memiliki bentuk yang hampir simetris. Sebesar 25% bilangan *sunspot* pada siklus ke-22 berada dibawah 27,19 sedangkan 50% data bilangan *sunspot* berada diatas 96,84 dan 25% data bilangan *sunspot* berada diatas 133,34. Siklus matahari ke-23 memiliki aktivitas yang lebih rendah dibandingkan siklus

ke- 22 yaitu terdapat 75% bilangan *sunspot* berada diatas 11,84, 50% bilangan *sunspot* berada diatas 38,81, serta 25% berada diatas 85,945. Siklus matahari ke- 24 juga memiliki aktivitas yang lebih rendah dibandingkan siklus ke- 23 sebanyak 25% data bilangan *sunspot* berada dibawah 13,945, 50% data bilangan *sunspot* dibawah 31,16, dan 25% data diatas 54,057.

4.2 Peramalan Bilangan *Sunspot* Tahun 2018 dengan menggunakan ARIMA *Box-Jenkins*


Sebelum melakukan pemodelan ARIMA, maka langkah pertama yaitu membagi data menjadi dua bagian yaitu data *in sample* sebanyak 348 data dan data *out sample* sebanyak 12 data. Data *in sample* digunakan untuk memodelkan bilangan *sunspot*, sedangkan data *out sample* digunakan untuk memilih model peramalan terbaik. Terdapat beberapa bulan yang memiliki bilangan *sunspot* sebesar 0 yaitu pada tahun 2008 di bulan Juli, Agustus dan Desember, serta tahun 2009 pada bulan April dan Agustus sehingga untuk melakukan tahapan peramalanbilangan *sunspot* tahun 2018 maka data akan ditambah dengan nilai minimal yang terdapat pada bulan Oktober 1996 yaitu sebesar 0,23 sesuai pada Lampiran 2.

4.2.1 Identifikasi Model ARIMA *Box-Jenkins*


Identifikasi stasioneritas model ARIMA dilakukan untuk mengetahui apakah bilangan *sunspot* telah stasioner dalam *mean* dan varians. Stasioneritas dalam varians dapat dilihat dari nilai *rounded value* (λ) atau nilai *Lower CL* dan *Upper CL* yang memuat nilai 1. Transformasi *Box-Cox* yang dapat dilihat pada Gambar 4.3

Gambar 4.3 menunjukkan bahwa nilai λ pada plot *Box-Cox* sebelum transformasi sebesar 0,4 dan memiliki batas 0,33 hingga 0,48 sehingga dapat dikatakan bahwa bilangan *sunspot* belum stasioner dalam varians karena tidak memenuhi salah satu syarat dari stasioneritas terhadap varians yaitu $\lambda=1$ atau nilai *Lower CL* dan *Upper CL* yang melewati nilai 1, maka perlu


dilakukan transformasi sebesar $Z_t^{0,4}$ sesuai pada Lampiran 6, setelah dilakukan transformasi didapatkan nilai λ sebesar 1 dengan batas atas sebesar 1,19 dan batas bawah sebesar 0,82 yang artinya data bilangan *sunspot* tahun 1988 hingga 2016 telah stasioner dalam varians.



Gambar 4.3 (a) *Box-Cox* Sebelum Transformasi dan
(b) *Box-Cox* Setelah Transformasi



Gambar 4.4 Plot ACF Bilangan *Sunspot* Sebelum *Differencing*



Gambar 4.5 *Time Series Plot* Setelah *Differencing*


Setelah data stasioner dalam varians maka langkah selanjutnya yaitu melihat kestasioneran data dalam *mean* yang dapat dilihat pada Gambar 4.4. Pada Gambar 4.4 menunjukkan bahwa bilangan *sunspot* memiliki pola yang turun dengan sangat

lambat sehingga data bilangan *sunspot* belum stasioner terhadap *mean* selain itu dapat dilihat pula pada Lampiran 7 bahwa lag- lag ACF juga memiliki selisih yang sedikit maka perlu dilakukan *differencing* sesuai Gambar 4.5.


Gambar 4.5 menunjukkan bahwa *time series plot* data in *sample* bilangan *sunspot* sudah stasioner dalam *mean* dikarenakan memiliki pola yang acak dan tidak membentuk *trend* serta memiliki pola yang berfluktuasi mengikuti garis rata- rata sebesar $-0,005$.

4.2.2 Estimasi Model Bilangan *Sunspot*

Setelah didapatkan bahwa data bilangan *sunspot* telah stasioner dalam *mean* dan varians, langkah selanjutnya adalah menduga orde model ARIMA. Hal ini dapat dilakukan dengan melihat plot ACF dan PACF dari data bilangan *sunspot* yang telah stasioner dalam *mean*.



Gambar 4.6 Plot ACF Bilangan *Sunspot* yang Telah Stasioner



Gambar 4.7 Plot PACF Bilangan *Sunspot* yang Telah Stasioner

Gambar 4.6 dan Gambar 4.7 yang menunjukkan bahwa pada plot ACF dan PACF signifikan pada lag awal yaitu lag 1 dan 2 sehingga model dugaan yang dapat diidentifikasi yaitu ARIMA (0,1,2) dan ARIMA (2,1,0). Selain itu terdapat beberapa lag pada ACF yang signifikan yaitu lag ke-22 dan 30 yang dapat dilihat pada Lampiran 8. Sedangkan pada PACF juga signifikan pada lag 9, 29, dan 78, namun dikarenakan lag ke-78 sangat jauh dari lag-lag yang signifikan sebelum itu maka digunakan lag ke-9 dan 29. Nilai *Partial Autocorrelation* dapat dilihat pada Lampiran 9. Sehingga terdapat indikasi model ARIMA yang subset beserta kombinasinya sesuai pada Tabel 4.1.

4.2.3 Pengujian Model Bilangan *Sunspot*

Setelah mendapatkan model dugaan ARIMA, maka langkah selanjutnya yaitu melakukan pengujian signifikansi parameter. Pengujian parameter pada masing-masing model ARIMA dinyatakan dengan hipotesis sebagai berikut.

Hipotesis :

$H_0 : \phi = 0$ (parameter AR tidak signifikan)

$H_1 : \phi \neq 0$ (parameter AR signifikan)

Hipotesis :

$H_0 : \theta = 0$ (parameter MA tidak signifikan)

$H_1 : \theta \neq 0$ (parameter MA signifikan)

dengan menggunakan taraf signifikan $\alpha = 0,05$, H_0 di tolak jika nilai $|t| > t_{\alpha/2, n-m}$ dan P_{value} kurang dari $\alpha = 0,05$. Sesuai pada data Lampiran 2 dengan menggunakan syntax pada Lampiran 12 hingga Lampiran 18 yang diperoleh *output* pada Lampiran 19 hingga Lampiran 25. Kemudian dilakukan pengujian parameter dengan hasil yang disajikan pada Tabel 4.1

Tabel 4.1 Hasil Pengujian Parameter

Model ARIMA	Parameter	Lag	Estimasi	$ t $	P_{value}
(2,1,2)	ϕ_1	1	-0.37075	1,47	0.1431
	ϕ_2	2	-0.12237	0,88	0.3781
	θ_1	1	0.02033	0,08	0.9357
	θ_2	2	0.22715	1,14	0.2555
(2,1,0)	ϕ_1	1	-0.36225	7,06*	0,0001
	ϕ_2	2	-0.30559	5,94*	0,0001
(0,1,2)	θ_1	1	0.37173	6,97*	0,0001
	θ_2	2	0.14456	2,70*	0,0072
([1,2,9,20,29],1, [1,2,22,30])	ϕ_1	1	-0.45894	3,70*	0,0002
	ϕ_2	2	-0.05621	0,53	0.5952
	ϕ_9	9	0.06106	1,23	0.2205
	ϕ_{20}	20	-0.02975	0,59	0.5524
	ϕ_{29}	29	-0.06922	1,26	0.2082

Keterangan *: Signifikan

Tabel 4.1 Hasil Pengujian Parameter (Lanjutan)

Model ARIMA	Parameter	Lag	Estimasi	t	P _{value}
([1,2,9,20,29],1, [1,2,22,30])	θ_1	1	-0.08373	0,73	0.4647
	θ_2	2	0.36402	3,45*	0.0006
	θ_{22}	22	-0.17144	3,31*	0.0010
	θ_{30}	30	-0.10168	1,78	0.0764
([1,2,9,20,29],1,0)	ϕ_1	1	-0.35698	6,98*	0,0001
	ϕ_2	2	-0.31282	6,12*	0,0001
	ϕ_9	9	0.05129	1,03	0,3034
	ϕ_{20}	20	-0.06239	1,25	0,2107
	ϕ_{29}	29	-0.10912	2,17*	0,0305
([1,2,29],1,0)	ϕ_1	1	-0.35855	7,03*	0,0001
	ϕ_2	2	-0.31107	6,08*	0,0001
	ϕ_{29}	29	-0.11640	2,33*	0,0205
(0,1,[1,2,22,30])	θ_1	1	0.36335	6,94*	0,0001
	θ_2	2	0.17363	3,35*	0,0009
	θ_{22}	22	-0.12895	2,73*	0,0067
	θ_{30}	30	-0.15367	3,14*	0,0018

Keterangan *: Signifikan

Tabel 4.1 menunjukkan bahwa dalam model dugaan ARIMA yang telah dilakukan pengujian, model yang memiliki parameter signifikan yaitu mempunyai nilai P_{value} yang kurang dari taraf signifikansi sebesar 0,05 dan |t| lebih besar dari $t_{\alpha/2,df}$ sebesar 1,967, sehingga dapat disimpulkan bahwa model ARIMA (2,1,2) tidak signifikan sedangkan model ARIMA(2,1,0) dan ARIMA (0,1,2) signifikan. Model ARIMA dengan subset ARIMA ([1,2,9,20,29],1,[1,2,22,30]) tidak signifikan maka dicoba

hanya menggunakan model AR atau MA. ARIMA([1,2,9,20,29],1,0) tidak signifikan pada lag 9 dan 20 maka kemungkinan model yang digunakan selanjutnya tidak menggunakan lag ke 9 dan 20 sehingga dicoba ARIMA([1,2,29],1,0). Pengujian asumsi *white noise* dapat dilakukan pada ARIMA(2,1,0), ARIMA(0,1,2), ARIMA([1,2,29],1,0), dan ARIMA(0,1,[1,2,22,30]).

4.2.4 Pengujian Asumsi Residual

Asumsi yang harus terpenuhi pada model ARIMA yaitu asumsi residual *white noise* dan berdistribusi normal. Pengujian untuk melihat residual telah *white noise* dapat dilakukan dengan menggunakan hipotesis dan statistic uji *Ljung-Box* sebagai berikut.

Hipotesis :

$$H_0 : \rho_{a_1} = \rho_{a_2} = \rho_{a_3} = \dots = \rho_{a_k} = 0 \text{ (residual white noise)}$$

$$H_1 : \text{minimal ada satu } \rho_{a_k} \neq 0 \text{ untuk } k = 1, 2, \dots, K \text{ (residual tidak white noise)}$$

dengan menggunakan taraf signifikan $\alpha = 0,05$ dan H_0 ditolak jika nilai Q lebih besar dari $\chi^2_{(\alpha, k-p-q)}$ dan P_{value} kurang dari taraf signifikan. Selain itu model ARIMA dikatakan memiliki residual *white noise* apabila memiliki lag dengan keputusan gagal menolak H_0 mulai lag ke-6 hingga lag ke-24. Hasil uji *Ljung-Box* pada masing-masing model yang telah signifikan dapat dilihat pada Tabel 4.2.

Tabel 4.2 Hasil Uji Residual *White Noise*

Model ARIMA	Lag	Q	Df	$\chi^2_{\alpha, df}$	P_{value}
(2,1,0)	6	5.71	4	9,488*	0.2223
	12	13.00	10	18,307*	0.2237
	18	19.30	16	26,296*	0.2533
	24	30.64	22	36,415*	0.1037
	30	44.26	28	41,337	0.0262
	36	49.10	34	48,602	0.0453

Tabel 4.2 Hasil Uji Residual *White Noise* (Lanjutan)

Model ARIMA	Lag	Q	Df	χ^2_{tabel}	Pvalue
(2,1,0)	42	54.59	40	55,758*	0.0619
	48	57.99	46	62,830*	0.1105
(0,1,2)	6	6.78	4	9,488*	0.1479
	12	18.85	10	18,307	0.0422
	18	25.13	16	26,296*	0.0675
	24	37.41	22	36,415	0.0213
	30	47.85	28	41,337	0.0111
	36	53.68	34	48,602	0.0172
	42	59.54	40	55,758	0.0240
	48	65.06	46	62,830	0.0335
([1,2,29],1,0)	6	6.72	3	7,815*	0.0816
	12	14.32	9	16,919*	0.1113
	18	20.84	15	24,996*	0.1420
	24	32.11	21	32,671*	0.0571
	30	41.24	27	40,113	0.0390
	36	44.90	33	47,400*	0.0810
	42	49.93	39	54,572*	0.1128
	48	53.90	45	61,656*	0.1707
(0,1,[1,2,22,30])	6	6.79	2	5,991	0.0335
	12	16.28	8	15,507	0.0385
	18	22.18	14	23,685*	0.0750
	24	29.83	20	31,410*	0.0726
	30	34.50	26	38,885*	0.1230
	36	40.49	32	46,194*	0.1443
	42	46.12	38	53,384*	0.1717
	48	49.08	44	60,481*	0.2769

Keterangan *: *White Noise*

Tabel 4.2 menunjukkan bahwa pada model ARIMA (2,1,0) dan ARIMA([1,2,29],1,0) telah memenuhi asumsi residual *white noise*, karena didapatkan nilai statistik uji χ^2 yang diperoleh lebih kecil dari $\chi^2_{(0,05;df)}$ dan nilai P_{value} lebih dari taraf signifikan $\alpha=0,05$, sedangkan ARIMA(0,1,2) dan ARIMA(0,1,[1,2,22,30]) tidak memenuhi asumsi *white noise* maka untuk melakukan pengujian asumsi residual berdistribusi normal hanya menggunakan model ARIMA (2,1,0) dan ARIMA([1,2,29],1,0).

Asumsi selanjutnya yang harus dipenuhi adalah residual berdistribusi normal, hal ini dapat diketahui dengan menggunakan uji *kolmogorov smirnov*. Berikut adalah hipotesis yang digunakan dalam pengujian ini.

Hipotesis :

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

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

Pada pengujian ini digunakan taraf signifikan sebesar $\alpha = 0,05$. dengan daerah keputusan H_0 ditolak jika $D \geq D_{(1-\alpha),n}$ selain itu juga bisa dilihat dari nilai P_{value} kurang dari taraf signifikan $\alpha = 0,05$. Hasil pengujian asumsi residual berdistribusi normal dengan menggunakan uji *Kolomogorov Smirnov* dapat dilihat pada Tabel 4.3

Tabel 4.3 Hasil Uji Residual Berdistribusi Normal

Model ARIMA	D_{hitung}	$D_{(1-\alpha),347}$	P_{value}	Keputusan
(2,1,0)	0.039864	0,073	0,1500	Berdistribusi normal
([1,2,29],1,0)	0.035021	0,073	0,1500	Berdistribusi normal

Tabel 4.3 menunjukkan bahwa model ARIMA(2,1,0) ARIMA([1,2,29],1,0), ARIMA(0,1,[1,2,30]) telah memenuhi asumsi residual berdistribusi normal, karena nilai D_{hitung} pada masing-masing model ARIMA kurang dari $D_{0,95;347}$ dan P_{value} yang diperoleh juga lebih besar dari taraf signifikan $\alpha = 0,05$. Selain itu juga dapat dilihat secara visual sesuai pada Lampiran 26 dan Lampiran 27 yang menunjukkan bahwa plot-plot residual pada kedua model tersebut mendekati garis sehingga dapat dikatakan

bahwa model dugaan ARIMA(2,1,0) dan ARIMA([1,2,29],1,0) berdistribusi normal.

4.2.5 Pemilihan Model Terbaik

Pemilihan model terbaik dilakukan untuk mendapatkan model yang paling akurat diantara model-model lainnya. Pada penelitian ini pemilihan model terbaik menggunakan menggunakan nilai RMSE dan SMAPE yang disajikan pada Tabel 4.4

Tabel 4.4 Kriteria Pemilihan Model Terbaik

Model	RMSE	SMAPE
ARIMA (2,1,0)	7,49395	46,06967
ARIMA ([1,2,29],1,0)	7,3862967	44,55453


Tabel 4.4 menunjukkan hasil perhitungan pemilihan model terbaik dengan melihat nilai RMSE dan SMAPE terkecil. Perhitungan nilai RMSE dan SMAPE sesuai pada Lampiran 10 dan 11 didapatkan model terbaik adalah ARIMA ([1,2,29],1,0) dikarenakan memiliki nilai RMSE maupun SMAPE lebih kecil daripada ARIMA (2,1,0), sehingga model terbaik untuk meramalkan bilangan *sunspot* tahun 2018 adalah ARIMA ([1,2,29],1,0).

Berikut ini merupakan bentuk matematis model terbaik dari ARIMA ([1,2,29],1,0) yaitu :

$$\begin{aligned} (1 - \phi_1 B^1 - \phi_2 B^2 - \phi_{29} B^{29})(1 - B)Z_t &= a_t \\ (1 - B - \phi_1 B^1 + \phi_1 B^2 - \phi_2 B^2 + \phi_2 B^3 - \phi_{29} B^{29} + \phi_{29} B^{30})Z_t &= a_t \\ Z_t - BZ_t - \phi_1 B^1 Z_t + \phi_1 B^2 Z_t - \phi_2 B^2 Z_t + \phi_2 B^3 Z_t - \phi_{29} B^{29} Z_t + \phi_{29} B^{30} Z_t &= a_t \\ Z_t - Z_{t-1} - \phi_1 Z_{t-1} + \phi_1 Z_{t-2} - \phi_2 Z_{t-2} + \phi_2 Z_{t-3} - \phi_{29} Z_{t-29} + \phi_{29} Z_{t-30} &= a_t \\ Z_t = Z_{t-1} + \phi_1 Z_{t-1} - \phi_1 Z_{t-2} + \phi_2 Z_{t-2} - \phi_2 Z_{t-3} + \phi_{29} Z_{t-29} - \phi_{29} Z_{t-30} + a_t & \\ Z_t = Z_{t-1} - 0,35855Z_{t-1} + 0,35855Z_{t-2} - 0,31107Z_{t-2} + 0,31107Z_{t-3} & \\ - 0,1164Z_{t-29} + 0,1164Z_{t-30} + a_t & \end{aligned}$$

Berdasarkan model matematis yang telah diuraikan, diketahui bahwa peramalan bilangan *sunspot* dipengaruhi oleh nilai bilangan *sunspot* pada 1 bulan, 2 bulan, 3 bulan, 29 bulan

dan 30 bulan sebelumnya. Setelah mengetahui model terbaik dari bilangan *sunspot* tahun 1988 hingga 2017, maka langkah selanjutnya adalah melihat *time series* plot perbandingan antara data aktual *out sample* dengan hasil ramalan yang dapat dilihat pada Gambar 4.8.



Gambar 4.8 Time Series Plot Data Aktual dan Ramalan Out Sample

Gambar 4.8 menunjukkan bahwa plot data aktual *out sample* dengan ramalan mempunyai perbedaan, model yang didapatkan yaitu ARIMA $([1,2,29],1,0)$ belum bisa menangkap pola data yang ekstrim pada data *out sample* dan mampu meramalkan pada kondisi mendekati rata-rata. Dikarenakan terdapat plot-plot yang ekstrim maka dilakukan pemeriksaan residual berdistribusi normal sesuai Lampiran 28 yang didapatkan nilai D_{hitung} sebesar 0,134 yang lebih kecil dari $D_{(0,95;12)}$ sebesar 0,375 sehingga diputuskan bahwa data *out sample* telah berdistribusi normal selain itu untuk memastikan hasil perhitungan dapat dibandingkan dengan plot secara visual sesuai pada Lampiran 29. Secara visual sebagian besar plot *out sample* mendekati garis walaupun terdapat beberapa plot yang tidak mengikuti garis selain itu dapat dilihat dari nilai P_{value} sebesar 0,15 yang lebih dari 0,05 maka dapat diputuskan bahwa data residual

out sample berdistribusi normal walaupun pada Gambar 4.8 terdapat plot-plot yang ekstrim.

4.2.6 Peramalan Bilangan *Sunspot*


Setelah didapatkan model terbaik ARIMA $([1,2,29],1,0)$, selanjutnya melakukan peramalan satu tahun ke depan. Hasil peramalan bilangan *sunspot* pada tahun 2018 yang dapat dilihat pada Tabel 4.5

Tabel 4.5 Hasil Ramalan Bilangan *Sunspot*

Bulan	NilaiRamalan	Batas Bawah	Batas Atas
Januari	4,66	0,23	15,84
Februari	3,80	-0,14	16,95
Maret	3,93	-0,18	18,68
April	4,20	-0,22	22,01
Mei	4,27	-0,23	24,78
Juni	4,15	0,00	26,56
Juli	4,12	0,00	28,69
Agustus	4,24	0,00	31,32
September	4,33	0,00	33,81
Oktober	3,94	0,00	34,64
November	4,90	0,00	40,19
Desember	4,35	0,00	40,41

Tabel 4.5 menunjukkan bahwa nilai bilangan *sunspot* tertinggi pada tahun 2018 terjadi pada bulan November dan yang terendah terjadi pada bulan Februari. Rata-rata bilangan *sunspot* dari Januari hingga Desember memiliki pengaruh terhadap kemunculan *flare* yang rendah sehingga kemungkinan terjadi pengaruh negatif terhadap bumi dan pancaran ultraviolet tidak terlalu berpengaruh.

Setelah diketahui nilai ramalan tahun 2018 maka langkah selanjutnya yaitu melihat *time series plot* bilangan *sunspot* bulan Januari 1988 hingga Desember 2018 seperti pada Gambar 4.8



Gambar 4.8 Plot Data Aktual dengan Ramalan Periode Januari 1988 hingga Desember 2018

Gambar 4.8 menunjukkan bahwa nilai bilangan *sunspot* tahun 2018 mengalami penurunan dibandingkan dengan tahun 2017, dan dapat dilihat pula bahwa ramalan bilangan *sunspot* pada tahun 2018 cenderung stabil dan kemungkinan merupakan akhir dari siklus matahari ke-24 sehingga diperkirakan aktivitas matahari tidak terlalu berdampak pada bumi, satelit, dan pancaran sinar ultraviolet yang dapat berdampak pada kesehatan.

BAB V KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan analisis dan pembahasan yang telah dilakukan, didapatkan sebuah kesimpulan sebagai berikut.

1. Model terbaik dari bilangan *sunspot* tahun 1988 hingga 2017 yaitu ARIMA ([1,2,29],1,0) dengan persamaan model :

$$Z_t = Z_{t-1} - 0,35855Z_{t-1} + 0,35855Z_{t-2} - 0,31107Z_{t-2} + 0,31107Z_{t-3} - 0,1164Z_{t-29} + 0,1164Z_{t-30} + a_t$$

Persamaan model diatas menunjukkan bahwa peramalan bilangan *sunspot* dipengaruhi oleh bilangan *sunspot* pada 1 bulan, 2 bulan, 3 bulan, 29 bulan dan 30 bulan sebelumnya.

2. Peramalan bilangan *sunspot* tertinggi terjadi pada bulan November dan terendah pada bulan Februari, walaupun tertinggi pada bulan November tetapi memiliki bilangan *sunspot* yang rendah dan kemungkinan tidak berdampak pada bumi. Kondisi matahari tahun 2018 merupakan *quiet cycle* yaitu matahari berada dalam kondisi tenang dan merupakan akhir dari siklus matahari ke-24 sehingga kemungkinan besar tidak ada efek astronomi yang membahayakan.

5.2 Saran

Saran untuk Balai Pengamatan Antariksa dan Atmosfer Pasuruan setelah mengetahui prediksi bilangan *sunspot* tahun 2018 adalah dapat mempublikasikan secara umum ramalan bilangan *sunspot* tahun 2018 dan memberikan informasi kepada instansi yang berkaitan dengan astronomi tentang prediksi aktivitas matahari. Saran untuk penelitian selanjutnya dapat menggunakan metode yang mampu meramalkan untuk periode yang panjang sehingga dapat mengetahui perkiraan awal dan akhir siklus matahari ke-25 beserta prediksi terjadinya *flare*.

(Halaman ini sengaja dikosongkan)

DAFTAR PUSTAKA

- Admirianto, A. G. (2009). *Menjelajahi Tata Surya*. Yogyakarta: Kanisius.
- Daniel, W. W. (1989). *Statistika Nonparametrik Diterjemahkan oleh: Alex Tri Kantjono W.* Jakarta: PT. Gramedia Pustaka Utama.
- ESA. (2016). *Impact Of A Solar Storm*. Retrieved January 10, 2018, from European Space Astronomy Center: www.esa.int
- Gooijer, J. D., & Hyndman, R. J. (2006). International Journal Of Forecasting vol. 22. *25 Years Of Time Series Forecasting*, 443-473.
- Kaufmann, W. J. (1978). *Eksplorasi Of The Solar System*. New York: Macmillan Publishing Co., Inc.
- LAPAN. (2012). *Fenomena Cuaca Antariksa*. Bandung: Pusat Sains Antariksa LAPAN.
- Markidakis, S., Wheelwright, S. C., & McGEE, V. E. (1999). *Metode dan Aplikasi Peramalan Jilid 1*. Jakarta: Binarupa Aksara Publisher.
- NASA. (2009). *The Day The Sun Brought Darkness*. Retrieved January 10, 2018, from www.nasa.gov
- Natural Resources Canada. (2017). *What is Space Weather?* Retrieved January 2, 2018, from Space Weather Canada: www.nrcan.gc.ca
- Nurfahmi. (2015). *Analisis Pola Pergerakan Sunspot Untuk Mengkaji POLa Terjadinya Flare Bulan Maret- Juni 2015*. Yogyakarta: UIN Sunan Kalijaga.
- Pesnell, W. D. (2008). Prediction Of Solar Cycle 24. *Solar Phys*, 210-211.
- Wei, W. W. (2006). *Time Series Analysis Univariate And Multivariate Method*. Canada: Addison Wesley Publishing Company.

Werner, R. (2012). *Sunspot Number Prediction by an Autoregressive Model*. Bulgaria: Bulgarian Academy Of Sciences.

LAMPIRAN

Lampiran 1. Data Bilangan *Sunspot* Tahun 1988-2017 Sebelum Penambahan Nilai Minimal Sebesar 0,23

Bulan	Tahun				
	1988	1989	...	2016	2017
Januari	38,34	124,96	...	26,56	16,34
Februari	21,29	126,26	...	27,86	13,61
Maret	44,34	101,09	...	26,01	10,97
April	61,45	88,08	...	23	19,77
Mei	35,64	105,54	...	31,52	13,94
Juni	73,89	142,12	...	12,79	17,63
Juli	74,86	86,25	...	18,94	13,96
Agustus	81,72	118,37	...	30,52	18,68
September	90,23	121,39	...	24,63	30,06
Oktober	111,93	108,3	...	22,69	8,64
November	105,76	123,44	...	11,67	2,95
Desember	133,34	99,89	...	9,38	3,21

Lampiran 2. Data Bilangan *Sunspot* Tahun 1988-2017
Setelah Penambahan Nilai Minimal Sebesar 0,23

Bulan	Tahun				
	1988	1989	...	2016	2017
Januari	38,57	125,19	...	26,79	16,57
Februari	21,52	126,49	...	28,09	13,84
Maret	44,57	101,32	...	26,24	11,2
April	61,68	88,31	...	23,23	20
Mei	35,87	105,77	...	31,75	14,17
Juni	74,12	142,35	...	13,02	17,86
Juli	75,09	86,48	...	19,17	14,19
Agustus	81,95	118,6	...	30,75	18,91
September	90,46	121,62	...	24,86	30,29
Oktober	112,16	108,53	...	22,92	8,87
November	105,99	123,67	...	11,9	3,18
Desember	133,57	100,12	...	9,61	3,44

Lampiran 3. Surat Permohonan Memperoleh Data



KEMENTERIAN RISET, TEKNOLOGI, DAN PENDIDIKAN TINGGI
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
 FAKULTAS VOKASI
 DEPARTEMEN STATISTIKA BISNIS

Kampus ITS Sukolilo, Surabaya 60111
 Telp. : 031-594 3352, 031-599 4251 Fax. : 031-592 2940 PABX: 1213, 1214
<http://www.statistics.its.ac.id>

Nomor : 081556/IT2.VI.8.6 /TU.00.09/2018
 Perihal : Permohonan ijin memperoleh data untuk Tugas Akhir

Yth : Kepala Balai Pengamatan Antariksa dan Atmosfer Pasuruan
 Jl. Raya Watukosek No. 1 Gempol,
 Pasuruan, Jawa Timur

Dengan Hormat,


Dalam rangka menyelesaikan studi di Departemen Statistika Bisnis - ITS, mahasiswa diwajibkan untuk melakukan Tugas Akhir. Sehubungan dengan hal tersebut, kami mohon agar mahasiswa berikut :

Nama : HENNI JOVITA SARI
 NRP : 1061150000074
 Program Studi : Diploma III (D III)
 Judul Tugas Akhir : Peramalan Bilangan Sunspot Menggunakan ARIMA box Jenkins

diperkenankan memperoleh data dan penelitian untuk :

1. Keperluan pengamatan dan perhitungan bilangan sunspot.
2. Memperoleh data pembandingan R (bilangan sunspot BPPA Pasuruan dengan NOAA)
3. Pengamatan sket sunspot mulai 8 Januari - 12 Januari 2018.

Demikian surat ini kami sampaikan, atas bantuan dan kerjasama yang baik, kami mengucapkan terima kasih.



Dr. Wahyu Wibowo, S.Si., M.Si
 NIP. 197403281998021001

Lampiran 4. Surat Balasan Permohonan Memperoleh Data



LEMBAGA PENERBANGAN DAN ANTARIKSA NASIONAL (LAPAN)

JALAN RAYA WATUKOSEK, GEMPOL, PASURUAN, JAWA TIMUR 67155
TELEPON (0343) 851887, FAKSIMILE (0343) 851569

Nomor : B/08/SA.00.02/01/2018/LAPAN Pasuruan 04 Januari 2018
Sifat : Biasa
Lampiran :
Hal : Balasan Permohonan Memperoleh data

Yth. Kepala Departemen Statistika Bisnis
Fakultas Vokasi
Institut Teknologi Sepuluh Nopember
Surabaya

Dengan Hormat,

Sehubungan dengan permohonan memperoleh data penelitian dalam rangka menyelesaikan studi dari mahasiswa Departemen Statistika Bisnis - ITS, Nomor: 081556/IT2.VI.8.6/TU.00.09/2018 tanggal 2 Januari 2018, dengan nama mahasiswa yang akan melaksanakan penelitian sebagai berikut:

Nama : Henni Jovita Sari
NRP : 10611500000074
Program Studi : Diploma III (D III)
Judul Tugas Akhir : Peramalan Bilangan Sunspot Menggunakan ARIMA box Jenkins

Dengan ini kami menerima mahasiswa tersebut diatas untuk dapat memperoleh data di Balai Pengamatan Antariksa dan Atmosfer (BPAA) Pasuruan.

Demikian kami sampaikan, atas perhatiannya kami ucapkan terima kasih.



Dian Yudha Nisianto, ST., MT.
NIP. 19800728 200604 1 003

Lampiran 5. Surat Pernyataan Keaslian Data

SURAT PERNYATAAN

Saya yang bertanda tangan dibawah ini, mahasiswa Departemen Statistika Bisnis
Fakultas Vokasi ITS :

Nama : Henni Jovita Sari
NRP : 10611500000074

Menyatakan bahwa data yang digunakan dalam Tugas Akhir ini merupakan data
sekunder yang diambil dari :

Sumber : Balai Pengamatan Antariksa dan Atmosfer Pasuruan
Keterangan : Data Bilangan *Sunspot* Tahun 1988 hingga 2017

Surat Pernyataan ini dibuat dengan sebenarnya. Apabila terdapat pemalsuan data,
maka saya siap menerima sanksi sesuai dengan peraturan yang berlaku.

Mengetahui,
Pejabat Pemberi Data,

Surabaya,
Yang membuat Pernyataan



(Henni Jovita Sari)
NRP. 10611500000074

Menyetujui,
Dosen Pembimbing Tugas Akhir,

(Dr. Wahyu Wibowo, S.Si., M.Si)
NIP. 19740328 199802 1 001

Lampiran 6. Data *In Sample* Setelah Transformasi

Bulan	Tahun				
	1988	1989	...	2015	2016
Januari	4,31	6,90	...	4,89	3,73
Februari	3,41	6,93	...	4,20	3,80
Maret	4,57	6,34	...	3,93	3,69
April	5,20	6,00	...	4,43	3,52
Mei	4,19	6,45	...	4,83	3,99
Juni	5,60	7,27	...	4,63	2,79
Juli	5,63	5,95	...	4,35	3,26
Agustus	5,83	6,76	...	4,21	3,94
September	6,06	6,82	...	4,55	3,62
Oktober	6,61	6,52	...	4,10	3,50
November	6,46	6,87	...	4,02	2,69
Desember	7,08	6,31	...	3,71	2,47

Lampiran 7. Output Minitab Autocorrelation Function sebelum differencing

Lag	ACF	T	LBQ
1	0.942065	17.57	311.52
2	0.915426	10.25	606.51
3	0.913200	8.07	900.93
4	0.901081	6.80	1188.41
5	0.891341	5.98	1470.54
6	0.878277	5.36	1745.25
7	0.865101	4.89	2012.57
8	0.851223	4.51	2272.14
9	0.832684	4.18	2521.26
10	0.810169	3.88	2757.79
11	0.789501	3.62	2983.07
12	0.766177	3.39	3195.87
13	0.745930	3.20	3398.17
14	0.722460	3.01	3588.51
15	0.692341	2.81	3763.83
16	0.662144	2.63	3924.68
17	0.635575	2.48	4073.32
18	0.609563	2.33	4210.47
19	0.586378	2.21	4337.76
20	0.556259	2.07	4452.66
21	0.534626	1.96	4559.12
22	0.510435	1.85	4656.47
23	0.473629	1.70	4740.54
24	0.450664	1.61	4816.89
25	0.418697	1.48	4883.00
26	0.385057	1.36	4939.08
27	0.352123	1.23	4986.13
28	0.326419	1.14	5026.68
29	0.295111	1.03	5059.93
30	0.276466	0.96	5089.21
31	0.240866	0.83	5111.50
32	0.203433	0.70	5127.45
33	0.177625	0.61	5139.65
34	0.152587	0.52	5148.68
35	0.123741	0.43	5154.64
36	0.088828	0.31	5157.72
37	0.063371	0.22	5159.30
38	0.038041	0.13	5159.86
39	0.007197	0.02	5159.88
40	-0.022273	-0.08	5160.08

Lampiran 7. Output Minitab Autocorrelation Function sebelum differencing (Lanjutan)

41	-0.055148	-0.19	5161.29
42	-0.086693	-0.30	5164.28
43	-0.107722	-0.37	5168.91
44	-0.132094	-0.45	5175.90
45	-0.157960	-0.54	5185.93
46	-0.183825	-0.63	5199.56
47	-0.212136	-0.73	5217.77
48	-0.231301	-0.79	5239.49
49	-0.252987	-0.86	5265.56
50	-0.273600	-0.93	5296.16
51	-0.292545	-0.99	5331.26
52	-0.302549	-1.02	5368.92
53	-0.327312	-1.10	5413.16
54	-0.346486	-1.17	5462.89
55	-0.356124	-1.19	5515.61
56	-0.367358	-1.23	5571.91
57	-0.382177	-1.27	5633.04
58	-0.387910	-1.28	5696.24
59	-0.395618	-1.30	5762.20
60	-0.406126	-1.33	5831.96
61	-0.408004	-1.33	5902.60
62	-0.417345	-1.35	5976.78
63	-0.418611	-1.35	6051.67
64	-0.412574	-1.32	6124.67
65	-0.413219	-1.32	6198.16
66	-0.420780	-1.34	6274.64
67	-0.419416	-1.33	6350.88
68	-0.412558	-1.30	6424.92
69	-0.409129	-1.28	6498.00
70	-0.398107	-1.24	6567.44
71	-0.392972	-1.22	6635.34
72	-0.387635	-1.20	6701.65
73	-0.376223	-1.16	6764.34
74	-0.365721	-1.12	6823.80
75	-0.360621	-1.10	6881.82
⋮	⋮	⋮	⋮
344	0.000199	0.00	13735.35
345	0.001988	0.00	13735.51
346	0.002336	0.01	13735.84
347	0.000450	0.00	13735.86

Lampiran 8. Output Minitab Autocorrelation Function setelah differencing

Lag	ACF	T	LBQ
1	-0.277122	-5.16	26.88
2	-0.203328	-3.53	41.39
3	0.090923	1.52	44.30
4	-0.018384	-0.31	44.42
5	0.022198	0.37	44.60
6	-0.005929	-0.10	44.61
7	0.024168	0.40	44.82
8	0.034953	0.58	45.25
9	0.038912	0.65	45.80
10	-0.015318	-0.25	45.88
11	0.023655	0.39	46.08
12	-0.028024	-0.46	46.37
13	0.033093	0.55	46.76
14	0.059249	0.98	48.04
15	0.006549	0.11	48.05
16	-0.036458	-0.60	48.54
17	-0.001572	-0.03	48.54
18	-0.023597	-0.39	48.75
19	0.066126	1.09	50.36
20	-0.081281	-1.34	52.81
21	0.014718	0.24	52.89
22	0.116796	1.91	57.97
23	-0.114159	-1.85	62.84
24	0.086072	1.38	65.62
25	0.009493	0.15	65.65
26	-0.007987	-0.13	65.68
27	-0.055449	-0.88	66.84
28	0.045040	0.72	67.61
29	-0.110869	-1.76	72.29
30	0.148260	2.33	80.69
31	0.022309	0.35	80.88
32	-0.105184	-1.63	85.13
33	-0.004575	-0.07	85.14
34	0.036186	0.56	85.65
35	0.048396	0.74	86.56
36	-0.083567	-1.28	89.28
37	-0.001784	-0.03	89.28
38	0.049511	0.76	90.24
39	-0.030828	-0.47	90.61
40	0.045255	0.69	91.42

Lampiran 8. Output Minitab Autocorrelation Function setelah differencing (Lanjutan)

41	-0.014661	-0.22	91.51
42	-0.088938	-1.35	94.65
43	0.040737	0.62	95.31
44	0.005436	0.08	95.32
45	-0.011953	-0.18	95.38
46	0.012521	0.19	95.44
47	-0.062896	-0.95	97.04
48	0.007164	0.11	97.06
49	0.002107	0.03	97.06
50	-0.017108	-0.26	97.18
51	-0.077258	-1.16	99.62
52	0.131082	1.97	106.67
53	-0.048029	-0.71	107.63
54	-0.083875	-1.24	110.53
55	0.011422	0.17	110.59
56	0.029019	0.43	110.94
57	-0.082696	-1.22	113.79
58	0.004345	0.06	113.80
59	0.037010	0.54	114.38
60	-0.074316	-1.09	116.71
61	0.076514	1.12	119.19
62	-0.073621	-1.07	121.49
63	-0.067537	-0.98	123.43
64	0.043370	0.63	124.24
65	0.058634	0.85	125.72
66	-0.081891	-1.18	128.61
67	-0.048114	-0.69	129.61
68	0.036363	0.52	130.18
69	-0.063225	-0.91	131.92
70	0.037753	0.54	132.55
71	-0.014627	-0.21	132.64
72	-0.056955	-0.81	134.07
73	0.013714	0.20	134.15
74	0.051032	0.73	135.31
75	-0.051448	-0.73	136.48
⋮	⋮	⋮	⋮
344	-0.006758	-0.08	408.10
345	0.003248	0.04	408.74
346	0.001340	0.02	408.96

**Lampiran 9. Output Minitab Partial Autocorrelation Function
setelah differencing**

Lag	PACF	T
1	-0.277122	-5.16
2	-0.303427	-5.65
3	-0.079464	-1.48
4	-0.087527	-1.63
5	0.000674	0.01
6	-0.013488	-0.25
7	0.038095	0.71
8	0.064397	1.20
9	0.111191	2.07
10	0.072680	1.35
11	0.094198	1.75
12	0.021255	0.40
13	0.059456	1.11
14	0.091441	1.70
15	0.093345	1.74
16	0.025195	0.47
17	0.002892	0.05
18	-0.061562	-1.15
19	0.022216	0.41
20	-0.110407	-2.06
21	-0.056520	-1.05
22	0.039263	0.73
23	-0.085506	-1.59
24	0.062696	1.17
25	0.031168	0.58
26	0.073601	1.37
27	-0.031783	-0.59
28	0.039034	0.73
29	-0.148143	-2.76
30	0.098487	1.83
31	0.047435	0.88
32	-0.005953	-0.11
33	-0.072739	-1.35
34	-0.005886	-0.11
35	0.027775	0.52
36	-0.059522	-1.11
37	-0.048120	-0.90
38	-0.015532	-0.29
39	-0.055549	-1.03
40	0.062377	1.16

**Lampiran 9. Output Minitab Partial Autocorrelation Function
setelah differencing (Lanjutan)**

41	0.014085	0.26
42	-0.024338	-0.45
43	-0.024271	-0.45
44	-0.030806	-0.57
45	-0.025908	-0.48
46	0.002206	0.04
47	-0.075189	-1.40
48	-0.048041	-0.89
49	-0.078930	-1.47
50	-0.049216	-0.92
51	-0.086820	-1.62
52	0.039377	0.73
53	0.004554	0.08
54	-0.071974	-1.34
55	-0.044017	-0.82
56	0.001036	0.02
57	-0.061133	-1.14
58	-0.012308	-0.23
59	0.000777	0.01
60	-0.081574	-1.52
61	0.066513	1.24
62	-0.059034	-1.10
63	-0.069090	-1.29
64	-0.039917	-0.74
65	0.023855	0.44
66	-0.045207	-0.84
67	-0.039342	-0.73
68	-0.021908	-0.41
69	-0.084239	-1.57
70	-0.011157	-0.21
71	-0.025293	-0.47
72	-0.041115	-0.77
73	-0.010364	-0.19
74	0.016052	0.30
75	-0.010844	-0.20
⋮	⋮	⋮
344	0.002486	0.05
345	0.025374	0.47
346	0.008796	0.16

Lampiran 10. Perhitungan Manual *RMSE* dan *SMAPE* Model ARIMA (2,1,0)

t	Z_t	\hat{Z}_t	$e_t = (Z_t - \hat{Z}_t)$	e_t^2	$ e_t $	$\frac{ e_t }{1/2(Z_t + \hat{Z}_t)}$
349	16,57	16,57	3,69463	13,65032	3,694634	0,250948
350	13,84	13,84	1,55222	2,40940	1,552223	0,118818
351	11,2	11,2	-0,18151	0,03295	0,181514	0,016076
352	20	20	8,12206	65,96792	8,122064	0,509573
353	14,17	14,17	2,19633	4,82385	2,196326	0,16802
354	17,86	17,86	6,07455	36,90012	6,074547	0,409813
355	14,19	14,19	2,36570	5,59652	2,365697	0,181877
356	18,91	18,91	7,04238	49,59507	7,042377	0,45763
357	30,29	30,29	18,44998	340,40165	18,44998	0,875859
358	8,87	8,87	-2,96678	8,80179	2,96678	0,286552
359	3,18	3,18	-8,66638	75,10622	8,666384	1,153489
360	3,44	3,44	-8,40390	70,62547	8,403896	1,099706
Jumlah				673,91127		5,52836
			RMSE	7,49395	sMAPE	46,06967

Lampiran 11. Perhitungan Manual *RMSE* dan *SMAPE* Model
ARIMA ([1,2,29],1,0)

T	Z_t	\hat{Z}_t	$e_t = (Z_t - \hat{Z}_t)$	e_t^2	$ e_t $	$\frac{ e_t }{1/2(Z_t + \hat{Z}_t)}$
349	16,57	1117,421	3,473457	12,06491	3,473457	0,234167
350	13,84	712,3608	1,721671	2,964151	1,721671	0,132649
351	11,2	419,5725	-0,84035	0,706188	0,84035	0,072318
352	20	1788,624	7,878494	62,07067	7,878494	0,490543
353	14,17	755,6009	2,403143	5,775095	2,403143	0,185307
354	17,86	1347,813	5,568291	31,00586	5,568291	0,369352
355	14,19	758,2707	1,043038	1,087928	1,043038	0,07631
356	18,91	1554,764	5,880098	34,57556	5,880098	0,368198
357	30,29	5049,268	18,15669	329,6654	18,15669	0,855977
358	8,87	234,0898	-3,098	9,597574	3,097995	0,297341
359	3,18	17,80299	-9,38773	88,12945	9,387729	1,192264
360	3,44	21,71806	-9,33825	87,20286	9,338247	1,151573
Jumlah				664,8456		5,425998
			RMSE	7,443373	sMAPE	45,21665

Lampiran 12.Syntax SAS Model ARIMA (2,1,2)

```
data sunspot;
input z;
datalines;
4.31022
3.41300
4.56685
5.20065
4.18690
5.59724
5.62643
5.82666
6.06154
6.60595
6.45812
7.08408
6.90284
6.93142
6.34276
6.00349
6.45275
7.26680
:
:
3.50014
2.69289
2.47223
;
proc arima data=sunspot;
identify var=z(1);
estimate p=2 q=2 method=cls noconstant;
forecast lead=12 out=out2;
run;

proc univariate data=out2 normal;
var residual;
run;
proc export data=WORK.out2
outfile='e:\ARIMA(2,1,2).xls'
dbms=excel
replace;
run;
```

Lampiran 13.Syntax SAS Model ARIMA (2,1,0)

```
data sunspot;
input z;
datalines;
4.31022
3.41300
4.56685
5.20065
4.18690
5.59724
5.62643
5.82666
6.06154
6.60595
6.45812
7.08408
6.90284
6.93142
6.34276
6.00349
6.45275
7.26680
5.95342
:
:
3.50014
2.69289
2.47223
;
proc arima data=sunspot;
identify var=z(1);
estimate p=2 q=0 method=cls noconstant;
forecast lead=12 out=out2;
run;

proc univariate data=out2 normal;
var residual;
run;
proc export data=WORK.out2
outfile='e:\ARIMA(2,1,0).xls'
dbms=excel
replace;
run;
```


Lampiran 14.Syntax SAS Model ARIMA (0,1,2)

```
data sunspot;
input z;
datalines;
4.31022
3.41300
4.56685
5.20065
4.18690
5.59724
5.62643
5.82666
6.06154
6.60595
6.45812
7.08408
6.90284
6.93142
6.34276
6.00349
6.45275
7.26680
5.95342
:
3.50014
2.69289
2.47223
;
proc arima data=sunspot;
identify var=z(1);
estimate p=0 q=2 method=cls noconstant;
forecast lead=12 out=out2;
run;

proc univariate data=out2 normal;
var residual;
run;
proc export data=WORK.out2
outfile='e:\ARIMA(2,1,2).xls'
dbms=excel
replace;
run;
```

Lampiran 15. Syntax SAS ModelARIMA**([1,2,9,20,29],1,[1,2,22,30])**

```
data sunspot;
input z;
datalines;
4.31022
3.41300
4.56685
5.20065
4.18690
5.59724
5.62643
5.82666
6.06154
6.60595
6.45812
7.08408
6.90284
6.93142
6.34276
6.00349
6.45275
7.26680
5.95342
:
3.50014
2.69289
2.47223
;
proc arima data=sunspot;
identify var=z(1);
estimate p=(1,2,9,20,29) q=(1,2,22,30) method=cls noconstant;
forecast lead=12 out=out2;
run;
proc univariate data=out2 normal;
var residual;
run;
proc export data=WORK.out2
outfile='e:\ARIMA([1,2,9,20,29],1,[1,2,22,30]).xls'
dbms=excel
replace;
run;
```

Lampiran 16. Syntax SAS Model ARIMA ([1,2,9,20,29],1,0)

```
data sunspot;
input z;
datalines;
4.31022
3.41300
4.56685
5.20065
4.18690
5.59724
5.62643
5.82666
6.06154
6.60595
6.45812
7.08408
6.90284
6.93142
6.34276
6.00349
6.45275
7.26680
5.95342
:
3.50014
2.69289
2.47223
;
proc arima data=sunspot;
identify var=z(1);
estimate p=(1,2,9,20,29) q=0 method=cls noconstant;
forecast lead=12 out=out2;
run;
proc univariate data=out2 normal;
var residual;
run;
proc export data=WORK.out2
outfile='e:\ARIMA([1,2,9,20,29],1,0).xls'
dbms=excel
replace;
run;
```

Lampiran 17.Syntax SAS Model ARIMA ([1,2,29],1,0)

```
data sunspot;
input z;
datalines;
4.31022
3.41300
4.56685
5.20065
4.18690
5.59724
5.62643
5.82666
6.06154
6.60595
6.45812
7.08408
6.90284
6.93142
6.34276
6.00349
6.45275
7.26680
5.95342
:
:
3.50014
2.69289
2.47223
;
proc arima data=sunspot;
identify var=z(1);
estimate p=(1,2,29) q=0 method=cls noconstant;
forecast lead=12 out=out2;
run;

proc univariate data=out2 normal;
var residual;
run;
proc export data=WORK.out2
outfile='e:\ARIMA([1,2,29],1,0).xls'
dbms=excel
replace;
run;
```

Lampiran 18.Syntax SAS Model ARIMA (0,1,[1,2,22,30])

```
data sunspot;
input z;
datalines;
4.31022
3.41300
4.56685
5.20065
4.18690
5.59724
5.62643
5.82666
6.06154
6.60595
6.45812
7.08408
6.90284
6.93142
6.34276
6.00349
6.45275
7.26680
5.95342
:
:
3.50014
2.69289
2.47223
;
proc arima data=sunspot;
identify var=z(1);
estimate p=0 q=(1,2,22,30) method=cls noconstant;
forecast lead=12 out=out2;
run;

proc univariate data=out2 normal;
var residual;
run;
proc export data=WORK.out2
outfile='e:\ARIMA(0,1,[1,2,22,30]).xls'
dbms=excel
replace;
run;
```

Lampiran 19. Output SAS Pengujian Model ARIMA (2,1,2)

Conditional Least Squares Estimation										
Parameter	Estimate		Standard Error	t Value		Approx Pr > t				Lag
MA1,1	0.02033		0.25187	0.08		0.9357				1
MA1,2	0.22715		0.19942	1.14		0.2555				2
AR1,1	-0.37075		0.25262	-1.47		0.1431				1
AR1,2	-0.12237		0.13865	-0.88		0.3781				2
Variance Estimate				0.345623						
Std Error Estimate				0.587897						
AIC				620.0654						
SBC				635.4627						
Number of Residuals				347						
Autocorrelation Check of Residuals										
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----						
6	1.73	2	0.4204	-0.002	-0.006	-0.012	0.009	0.053	0.042	
12	13.53	8	0.0949	0.087	0.094	0.102	0.039	0.063	0.026	
18	20.36	14	0.1192	0.086	0.089	0.042	-0.027	-0.003	-0.030	
24	32.47	20	0.0385	0.045	-0.033	0.033	0.123	-0.043	0.107	
30	44.75	26	0.0125	0.001	0.015	-0.086	0.030	-0.072	0.136	
36	49.22	32	0.0265	0.014	-0.073	-0.020	0.013	0.035	-0.065	
42	54.61	38	0.0395	-0.009	0.036	-0.005	0.016	-0.044	-0.100	
48	59.79	44	0.0565	-0.009	-0.016	-0.030	-0.028	-0.098	-0.034	
Tests for Normality										
Test	--Statistic--			----p Value-----						
Shapiro-Wilk	W	0.997386		Pr < W	0.8594					
Kolmogorov-Smirnov	D	0.028175		Pr > D	>0.1500					
Cramer-von Mises	W-Sq	0.043976		Pr > W-Sq	>0.2500					
Anderson-Darling	A-Sq	0.251593		Pr > A-Sq	>0.2500					

Lampiran 20. Output SAS Pengujian Model ARIMA (2,1,0)

Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag				
AR1,1	-0.36225	0.05132	-7.06	<.0001	1				
AR1,2	-0.30559	0.05143	-5.94	<.0001	2				
Variance Estimate		0.348013							
Std Error Estimate		0.589926							
AIC		620.4736							
SBC		628.1722							
Number of Residuals		347							
* AIC and SBC do not include log determinant.									
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	5.71	4	0.2223	-0.025	-0.047	-0.086	-0.039	0.062	0.025
12	13.00	10	0.2237	0.071	0.080	0.085	0.016	0.037	0.007
18	19.30	16	0.2533	0.076	0.085	0.033	-0.037	-0.010	-0.042
24	30.64	22	0.1037	0.043	-0.038	0.025	0.115	-0.046	0.106
30	44.26	28	0.0262	-0.003	0.011	-0.098	0.024	-0.065	0.145
36	49.10	34	0.0453	0.014	-0.077	-0.020	0.009	0.043	-0.064
42	54.59	40	0.0619	-0.014	0.041	0.005	0.024	-0.043	-0.098
48	57.99	46	0.1105	0.002	-0.001	-0.012	-0.017	-0.086	-0.023
Forecasts for variable z									
Obs	Forecast	Std Error	95% Confidence Limits						
349	2.7989	0.5899	1.6426	3.9551					
350	2.7480	0.6997	1.3766	4.1193					
351	2.6666	0.7512	1.1943	4.1389					
352	2.7116	0.8400	1.0652	4.3580					
353	2.7202	0.9180	0.9210	4.5194					
354	2.7033	0.9792	0.7840	4.6226					
355	2.7068	1.0410	0.6664	4.7472					
356	2.7107	1.1008	0.5532	4.8682					
357	2.7082	1.1558	0.4429	4.9735					
358	2.7079	1.2085	0.3393	5.0765					
359	2.7088	1.2594	0.2404	5.1771					
360	2.7086	1.3081	0.1447	5.2724					
Tests for Normality									
Test	--Statistic--	-----p Value-----							
Shapiro-Wilk	W	0.997538	Pr < W	0.8887					
Kolmogorov-Smirnov	D	0.039864	Pr > D	>0.1500					
Cramer-von Mises	W-Sq	0.05213	Pr > W-Sq	>0.2500					
Anderson-Darling	A-Sq	0.3057	Pr > A-Sq	>0.2500					

Lampiran 21. Output SAS Pengujian Model ARIMA (0,1,2)

Conditional Least Squares Estimation									
Parameter	Estimate		Standard Error	t Value	Approx Pr > t		Lag		
MA1,1	0.37173		0.05333	6.97	<.0001		1		
MA1,2	0.14456		0.05347	2.70	0.0072		2		
	Variance Estimate			0.34918					
	Std Error Estimate			0.590915					
	AIC			621.6354					
	SBC			629.334					
	Number of Residuals			347					
	* AIC and SBC do not include log determinant.								
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	6.78	4	0.1479	-0.020	-0.066	0.086	0.020	0.065	0.051
12	18.85	10	0.0422	0.084	0.098	0.098	0.045	0.067	0.029
18	25.13	16	0.0675	0.080	0.094	0.037	-0.017	0.001	-0.017
24	37.41	22	0.0213	0.056	-0.044	0.039	0.122	-0.052	0.094
30	47.85	28	0.0111	0.021	-0.003	-0.059	0.026	-0.075	0.131
36	53.68	34	0.0172	0.023	-0.087	-0.016	0.022	0.034	-0.071
42	59.54	40	0.0240	-0.009	0.037	-0.019	0.020	-0.041	-0.104
48	65.06	46	0.0335	-0.004	-0.022	-0.036	-0.030	-0.097	-0.041
Tests for Normality									
Test	--Statistic--		-----p Value-----						
Shapiro-Wilk	W	0.998268	Pr < W	0.9798					
Kolmogorov-Smirnov	D	0.02983	Pr > D	>0.1500					
Cramer-von Mises	W-Sq	0.030085	Pr > W-Sq	>0.2500					
Anderson-Darling	A-Sq	0.174632	Pr > A-Sq	>0.2500					

Lampiran 22. Output SAS Pengujian Model ARIMA

((1,2,9,20,29),1,[1,2,22,30])

Conditional Least Squares Estimation									
Parameter	4Estimate		Standard Error	t Value	Approx Pr > t	Lag			
MA1,1	-0.08373		0.11440	-0.73	0.4647	1			
MA1,2	0.36402		0.10545	3.45	0.0006	2			
MA1,3	-0.17144		0.05173	-3.31	0.0010	22			
MA1,4	-0.10168		0.05721	-1.78	0.0764	30			
AR1,1	-0.45894		0.12396	-3.70	0.0002	1			
AR1,2	-0.05621		0.10570	-0.53	0.5952	2			
AR1,3	0.06106		0.04975	1.23	0.2205	9			
AR1,4	-0.02975		0.05001	-0.59	0.5524	20			
AR1,5	-0.06922		0.05489	-1.26	0.2082	29			
Variance Estimate				0.331558					
Std Error Estimate				0.575811					
AIC				610.5532					
SBC				645.1971					
Number of Residuals				347					
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	.	0	.	-0.005	-0.001	-0.011	0.035	0.059	0.051
12	11.83	3	0.0080	0.100	0.067	0.041	0.076	0.051	0.034
18	18.36	9	0.0312	0.057	0.097	0.030	-0.054	-0.015	-0.035
24	22.55	15	0.0943	0.045	0.010	0.025	-0.047	-0.029	0.074
30	25.04	21	0.2454	0.018	0.002	-0.072	0.026	-0.016	0.011
36	29.78	27	0.3243	0.021	-0.081	-0.008	0.008	0.039	-0.060
42	35.30	33	0.3599	-0.017	0.060	-0.006	0.037	-0.030	-0.088
48	39.41	39	0.4514	-0.019	-0.012	0.005	-0.042	-0.080	-0.039
Tests for Normality									
Test	--Statistic--		-----p Value-----						
Shapiro-Wilk	W	0.997263	Pr < W	0.8337					
Kolmogorov-Smirnov	D	0.041649	Pr > D	0.1474					
Cramer-von Mises	W-Sq	0.056501	Pr > W-Sq	>0.2500					
Anderson-Darling	A-Sq	0.343771	Pr > A-Sq	>0.2500					

Lampiran 23. Output SAS Pengujian Model ARIMA ([1,2,9,20,29],1,0)

Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag				
AR1,1	-0.35698	0.05113	-6.98	<.0001	1				
AR1,2	-0.31282	0.05114	-6.12	<.0001	2				
AR1,3	0.05129	0.04976	1.03	0.3034	9				
AR1,4	-0.06239	0.04976	-1.25	0.2107	20				
AR1,5	-0.10912	0.05022	-2.17	0.0305	29				
		Variance Estimate	0.343031						
		Std Error Estimate	0.585688						
		AIC	618.4396						
		SBC	637.6863						
		Number of Residuals	347						
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	7.34	1	0.0067	-0.017	-0.045	-0.095	-0.047	0.079	0.033
12	14.02	7	0.0507	0.076	0.078	0.036	0.047	0.057	-0.001
18	20.89	13	0.0752	0.060	0.094	0.044	-0.044	-0.023	-0.045
24	30.36	19	0.0474	0.045	0.029	-0.000	0.091	-0.032	0.114
30	39.28	25	0.0345	-0.014	-0.003	-0.098	0.018	0.038	0.109
36	42.65	31	0.0795	-0.028	-0.048	-0.029	0.002	0.045	-0.052
42	47.33	37	0.1190	-0.022	0.044	-0.002	0.016	-0.029	-0.091
48	52.15	43	0.1600	-0.013	0.001	-0.006	-0.021	-0.103	-0.024
Tests for Normality									
Test	--Statistic--		-----p Value-----						
Shapiro-Wilk	W	0.997814	Pr < W	0.9333					
Kolmogorov-Smirnov	D	0.028562	Pr > D	>0.1500					
Cramer-von Mises	W-Sq	0.043407	Pr > W-Sq	>0.2500					
Anderson-Darling	A-Sq	0.287716	Pr > A-Sq	>0.2500					

Lampiran 24. Output SAS Pengujian Model ARIMA

([1,2,29],1,0)

Conditional Least Squares Estimation

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
AR1,1	-0.35855	0.05102	-7.03	<.0001	1
AR1,2	-0.31107	0.05116	-6.08	<.0001	2
AR1,3	-0.11640	0.05000	-2.33	0.0205	29

Variance Estimate	0.343612
Std Error Estimate	0.586184
AIC	617.0499
SBC	628.5979
Number of Residuals	347

Autocorrelation Check of Residuals

To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----						
6	6.72	3	0.0816	-0.013	-0.046	-0.090	-0.046	0.076	0.024	
12	14.32	9	0.1113	0.079	0.079	0.081	0.023	0.041	0.003	
18	20.84	15	0.1420	0.063	0.092	0.042	-0.033	-0.012	-0.049	
24	32.11	21	0.0571	0.045	-0.033	0.029	0.112	-0.036	0.111	
30	41.24	27	0.0390	-0.020	-0.001	-0.100	0.015	0.043	0.108	
36	44.90	33	0.0810	-0.018	-0.057	-0.032	0.001	0.047	-0.051	
42	49.93	39	0.1128	-0.015	0.039	0.001	0.019	-0.038	-0.096	
48	53.90	45	0.1707	0.003	-0.005	-0.015	-0.019	-0.090	-0.032	

Forecasts for variable z

Obs	Forecast	Std Error	95% Confidence Limits	
349	2.8176	0.5862	1.6688	3.9665
350	2.7330	0.6964	1.3681	4.0980
351	2.7261	0.7466	1.2629	4.1894
352	2.7333	0.8345	1.0978	4.3688
353	2.7016	0.9123	0.9135	4.4898
354	2.7483	0.9729	0.8414	4.6552
355	2.8219	1.0341	0.7952	4.8486
356	2.8120	1.0934	0.6689	4.9551
357	2.7343	1.1480	0.4843	4.9844
358	2.7197	1.2003	0.3672	5.0721
359	2.7724	1.2508	0.3210	5.2238
360	2.7905	1.2991	0.2443	5.3367


Tests for Normality

Test	--Statistic--	-----p Value-----	
Shapiro-Wilk	W 0.9973	Pr < W	0.8418
Kolmogorov-Smirnov	D 0.035021	Pr > D	>0.1500
Cramer-von Mises	W-Sq 0.053913	Pr > W-Sq	>0.2500
Anderson-Darling	A-Sq 0.330702	Pr > A-Sq	>0.2500


Lampiran 25. Output SAS Pengujian Model ARIMA (0,1,[1,2,22,30])

Conditional Least Squares Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag				
MA1,1	0.36335	0.05235	6.94	<.0001	1				
MA1,2	0.17363	0.05176	3.35	0.0009	2				
MA1,3	-0.12895	0.04723	-2.73	0.0067	22				
MA1,4	-0.15367	0.04887	-3.14	0.0018	30				
Variance Estimate		0.337697							
Std Error Estimate		0.581117							
AIC		612.0145							
SBC		627.4118							
Number of Residuals		347							
Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	-----Autocorrelations-----					
6	6.79	2	0.0335	-0.028	-0.055	0.092	0.019	0.070	0.043
12	16.28	8	0.0385	0.094	0.064	0.085	0.046	0.058	0.030
18	22.18	14	0.0750	0.061	0.096	0.022	-0.042	-0.010	-0.031
24	29.83	20	0.0726	0.044	-0.036	0.038	-0.010	-0.091	0.087
30	34.50	26	0.1230	-0.001	-0.004	-0.072	0.035	-0.076	-0.008
36	40.49	32	0.1443	-0.016	-0.088	-0.031	0.011	0.031	-0.073
42	46.12	38	0.1717	-0.013	0.046	-0.019	0.038	-0.033	-0.095
48	49.08	44	0.2769	-0.007	-0.023	-0.011	-0.023	-0.070	-0.035
Forecasts for variable z									
Obs	Forecast	Std Error	95% Confidence Limits						
349	2.7387	0.5811	1.5997	3.8776					
350	2.8669	0.6889	1.5167	4.2171					
351	2.9749	0.7396	1.5254	4.4244					
352	2.9478	0.7870	1.4053	4.4903					
353	2.9551	0.8317	1.3250	4.5853					
354	3.0166	0.8742	1.3033	4.7299					
355	3.0364	0.9146	1.2437	4.8290					
356	2.8680	0.9534	0.9994	4.7366					
357	2.7344	0.9906	0.7928	4.6760					
358	2.7095	1.0265	0.6976	4.7215					
359	2.7592	1.0612	0.6793	4.8391					
360	2.7856	1.0948	0.6398	4.9313					
Tests for Normality									
Test	--Statistic--	-----p Value-----							
Shapiro-Wilk	W	0.997204	Pr < W	0.8208					
Kolmogorov-Smirnov	D	0.02716	Pr > D	>0.1500					
Cramer-von Mises	W-Sq	0.044037	Pr > W-Sq	>0.2500					
Anderson-Darling	A-Sq	0.28474	Pr > A-Sq	>0.2500					

Lampiran 26. *Output* Visual Pengujian Asumsi Distribusi Normal pada ARIMA (2,1,0)



Lampiran 27. *Output* Visual Pengujian Asumsi Distribusi Normal pada ARIMA ([1,2,29],1,0)




Lampiran 28. Perhitungan Manual Distribusi Normal *Outsample*

Z_t	\bar{Z}_t	Resi	f	fk	Fn	Z	f0	fn-f0
3,18	12,80	-9,62	1	1	0,083	-1,512	0,065	0,018
3,44	13,01	-9,57	1	2	0,167	-1,505	0,066	0,101
8,87	12,20	-3,33	1	3	0,250	-0,674	0,250	0,000
11,2	12,27	-1,07	1	4	0,333	-0,373	0,355	0,021
14,19	13,38	0,81	1	5	0,417	-0,122	0,452	0,035
13,84	12,35	1,49	1	6	0,500	-0,031	0,488	0,012
14,17	12,00	2,17	1	7	0,583	0,060	0,524	0,060
16,57	13,33	3,24	1	8	0,667	0,202	0,580	0,086
17,86	12,52	5,34	1	9	0,750	0,482	0,685	0,065
18,91	13,26	5,65	1	10	0,833	0,523	0,700	0,134
20	12,35	7,65	1	11	0,917	0,790	0,785	0,132
30,29	12,36	17,93	1	12	1,000	2,160	0,985	0,015

$$D_{\text{hitung}} = \text{Maksimal}(|fn-f0|)$$

$$= 0,134$$

Lampiran 29. Output Visual Distribusi Normal *Outsample*

BIODATA PENULIS



Penulis Bernama Lengkap HENNI JOVITA SARI yang lahir di Surabaya pada tanggal 26 Juni 1996 sebagai anak ketiga dari tiga bersaudara dari pasangan Bapak Prin Siswoyo dan Ibu Siti Nurhayatin, Penulis bertempat tinggal di Perumahan Bumi Candi Asri Blok N3 no. 26, Desa Ngampelsari, Kecamatan Candi, Sidoarjo. Pendidikan formal yang ditempuh penulis yaitu SDN Ngampelsari, SMPN 2 Candi, SMAN 3 Sidoarjo dan pada tahun 2015 penulis diterima di Program Studi Diploma III Departemen Statistika Bisnis ITS melalui jalur seleksi reguler Program Diploma III dengan NRP 1061150000074. Selama perkuliahan penulis pernah berpartisipasi sebagai Sie Acara Data Analysis Competition, peserta Pelatihan Karya Tulis Ilmiah, LKMM Pra- TD, Pelatihan Kewirausahaan, dll. Apabila pembaca memiliki kritik dan saran atau ingin berdiskusi lebih lanjut mengenai tugas akhir ini, dapat dihubungi melalui email hennijovitasr@gmail.com atau nomor *handphone* 081999764775