

**ANALISIS DATA *TIME SERIES* UNTUK PERAMALAN EFEK
RUMAH KACA**

SKRIPSI

**FAUZAH UMAMI
73154027**



**PROGRAM STUDI MATEMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI SUMATERA UTARA
MEDAN
2019**

**ANALISIS DATA *TIME SERIES* UNTUK PERAMALAN EFEK
RUMAH KACA**

SKRIPSI

*Diajukan untuk Memenuhi Syarat Mencapai Gelar Sarjana Matematika (S.Mat)
Dalam Sains dan Teknologi*

FAUZAH UMAMI

73154027



**PROGRAM STUDI MATEMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI SUMATERA UTARA
MEDAN
2019**

PERSETUJUAN SKRIPSI

Hal : Surat Persetujuan Skripsi

Lamp : -

Kepada Yth.,
Dekan Fakultas Sains dan Teknologi
Universitas Islam Negeri Sumatera Utara Medan

Assalamu'alaikum Wr. Wb.

Setelah membaca, meneliti, memberikan petunjuk, dan mengoreksi serta mengadakan perbaikan, maka kami selaku pembimbing berpendapat bahwa skripsi saudara,

Nama	: Fauzah Umami
Nomor Induk Mahasiswa	: 73154027
Program Studi	: Matematika
Judul	: Analisis Data <i>Time Series</i> Untuk Peramalan Efek Rumah Kaca.

dapat disetujui untuk segera *dimunaqasyahkan*. Atas perhatiannya kami ucapkan terimakasih.

Medan, 1 November 2019 M
04 Rabiul Awal 1441 H

Komisi Pembimbing,

Pembimbing Skripsi I,

Pembimbing Skripsi II,

Riri Syafitri Lubis, S.Pd., M.Si
NIP.198407132009122002

Hendra Cipta, S.Pd.I., M.Si
NIB. 1100000069

SURAT PERNYATAAN KEASLIAN SKRIPSI

Saya yang bertanda tangan di bawah ini,

Nama : Fauzah Umami
Nomor Induk Mahasiswa : 73154027
Program Studi : Matematika
Judul : Analisis Data *Time Series* Untuk Peramalan
Efek Rumah Kaca

Menyatakan bahwa skripsi ini adalah hasil karya saya sendiri, kecuali beberapa kutipan dan ringkasan yang masing-masing disebutkan sumbernya. Apabila di kemudian hari ditemukan plagiat dalam skripsi ini maka saya bersedia menerima sanksi pencabutan gelar akademik yang saya peroleh dan sanksi lainnya sesuai dengan peraturan yang berlaku.

Medan, 1 November 2019

Fauzah Umami
NIM. 73154027



**KEMENTERIAN AGAMA REPUBLIK INDONESIA
UNIVERSITAS ISLAM NEGERI SUMATERA UTARA MEDAN
FAKULTAS SAINS DAN TEKNOLOGI**

Jl. IAIN No. 1 Medan 20235

Telp. (061) 6615683-6622925, Fax. (061) 6615683
Url: <http://saintek.uinsu.ac.id>, E-mail: saintek@uinsu.ac.id

PENGESAHAN SKRIPSI

Nomor: 032/ST/ST.V/PP.01.1/02/2020

Judul : Analisi Data Time Series Untuk Peramalan Efek Rumah Kaca
Nama : Fauzah Uamami
Nomor Induk Mahasiswa : 73154027
Program Studi : Matematika
Fakultas : Sains dan Teknologi

Telah dipertahankan di hadapan Dewan Penguji Skripsi Program Studi Matematika Fakultas Sains dan Teknologi UIN Sumatera Utara Medan dan dinyatakan **LULUS**.

Pada hari/tanggal : Jum'at, 1 November 2019
Tempat : Ruang Sidang Fakultas Sains dan Teknologi

Tim Ujian Munaqasyah,
Ketua,

Dr. Sajaratud Dur, ST., MT
NIP.197310132005012005

Dewan Penguji,

Penguji I,

Penguji II,

Riri Syafitri Lubis, S.Pd., M.Si
NIP.198407132009122002

Hendra Cipta, S.Pd.I., M.Si
NIB. 1100000069

Penguji III,

Penguji IV,

Fibri Rakhmawati, M.Si
NIP.198002112003122014

Ismail Husein, M.Si
NIP. 199104222019031015

Mengesahkan,
Dekan Fakultas Sains dan Teknologi
UIN Sumatera Utara Medan,

Dr. H. M. Jamil, M.A.
NIP. 196609101999031002

ABSTRAK

Efek rumah kaca merupakan istilah yang digunakan untuk menggambarkan bumi memiliki efek rumah kaca dimana panas matahari terperangkap oleh atmosfer bumi. Penelitian ini bertujuan untuk memodelkan efek rumah kaca dan kemudian memprediksi efek rumah kaca pada periode yang akan datang dengan menggunakan metode Autoregressive Integrated Moving Average (ARIMA). Dalam hal ini digunakan analisis deret waktu (*time series*) dan data acuan selama 31 bulan, dari periode Januari 2017 – Juli 2019, hasil model ARIMA yang sesuai untuk meramalkan efek rumah kaca adalah ARIMA (4,2,0) dengan *Mean Square Error* (MSE) sebesar 161885.

Kata Kunci: Time Series, Model, Peramalan, ARIMA, Efek Rumah Kaca.

ABSTRACT

The greenhouse effect is a term used to describe the earth having a greenhouse effect where the sun's heat is trapped by the earth's atmosphere. This study aims to model the greenhouse effect and then predict the greenhouse effect in the coming period using the Autoregressive Integrated Moving Average (ARIMA) method. In this case, time series analysis and reference data for 31 months are used, from the period January 2017 - July 2019, the results of the ARIMA model that are suitable for forecasting the greenhouse effect are ARIMA (4.2.0) with Mean Square Error (MSE) of 161885.

Keywords: Time Series, Models, Forecasting, ARIMA, Greenhouse Effect.

KATA PENGANTAR

Syukur Alhamdulillah kepada Allah SWT atas rahmat-Nya sehingga penulis dapat menyelesaikan skripsi yang berjudul “Pengelompokan Kabupaten/Kota Berdasarkan Faktor-Faktor yang Mempengaruhi Tingkat Kemiskinan di Sumatera Utara dengan menggunakan Analisis Klaster.”.

Penulisan skripsi ini dapat diselesaikan dengan bantuan baik moril maupun materil serta dorongan dan arahan dari berbagai pihak. Oleh karena itu, penulis mengucapkan terima kasih yang sebesar-besarnya kepada:

1. Prof. Dr. Saidurrahman, M.Ag. selaku Rektor UIN Sumatera Utara Medan.
2. Dr. H. M. Jamil, M.A. selaku Dekan Fakultas Sains dan Teknologi UIN Sumatera Utara Medan.
3. Dr. Sajaratud Dur, ST., MT Selaku Ketua Program Studi Matematika Fakultas Sains dan Teknologi UIN Sumatera Utara Medan, serta dosen-dosen dan staff administrasi yang telah membantu selama proses perkuliahan.
4. Riri Syafitri Lubis,, M.Si dan Hendra Cipta, M.Si selaku Pembimbing Skripsi yang telah memberikan motivasi dan bimbingan selama proses penyelesaian skripsi.
5. Ismail Husein, M.Si selaku dosen Penasehat Akademik yang telah memberikan bimbingan selama menempuh pendidikan di Fakultas Sain dan Teknologi UIN Sumatera Utara Medan.
6. Bapak Harun dan Ibu Fathonah selaku orang tua yang telah membimbing dan mengarahkan dengan penuh kasih sayang serta memberikan arti sebuah kesabaran dalam menjalani kehidupan, serta kepada keluarga besar matematika stambuk 2015 yang senantiasa memberikan tawa, duka, semangat, dan motivasi.

Penulis berharap semoga skripsi ini dapat bermanfaat dan menambah wawasan keilmuan. Kritik dan saran yang sifatnya membangun sangat penulis harapkan untuk perbaikan dimasa yang akan datang.

Medan, 1 November 2019
Penulis,

Fauzah Umami

DAFTAR ISI

ABSTRAK	i
ABSTRACT	ii
KATA PENGANTAR	iii
DAFTAR ISI	v
DAFTAR GAMBAR	vii
DAFTAR TABEL	ix
DAFTAR LAMPIRAN	x

BAB I PENDAHULUAN

1.1 Latar Belakang	1
1.2 Rumusan Masalah	6
1.3 Batasan Masalah	6
1.4 Tujuan Penelitian	6
1.5 Manfaat Penelitian	6

BAB II TINJAUAN PUSTAKA

2.1 Deret Waktu (<i>Time Series</i>)	7
2.2 Stasioner dan Nonstasioneritas Data.....	8
2.3 Fungsi Autokorelasi (ACF)	11
2.4 Fungsi Autokorelasi Parsial (FAKP)	12
2.5 White Noise Procces	13
2.6 Uji Asumsi Distribusi Normal	14
2.7 Metode Autoregressive Integrated Moving Average (ARIMA)	15
2.7.1 Proses Autoregresif (AR)	15
2.7.2 Model Moving Average (MA)	16
2.7.3 Model ARMA	16
2.7.4 Model ARIMA	17
2.8 Penelitian yang Relavan	19

BAB III METODE PENELITIAN

3.1 Lokasi dan Waktu Penelitian	21
3.2 Jenis dan Variabel Penelitian	21
3.3 Prosedur Penelitian	21
3.4 Analisis Data.....	22

BAB IV PEMBAHASAN

4.1 Pengidentifikasian dan pendugaan parameter Model	25
4.2 Pemeriksaan Diagnosa Model ARIMA	29
4.2.1 Model ARIMA (0,2,1)	29
4.2.2 Model ARIMA (0,2,3)	31
4.2.3 Model ARIMA (1,2,0)	33
4.2.4 Model ARIMA (2,2,0)	35
4.2.5 Model ARIMA (4,0,2)	37
4.3 Kriteria Pemilihan Model	39
4.3 Peramalan.....	39

BAB V KESIMPULAN DAN SARAN

5.1 Kesimpulan	42
5.2 Saran	43

DAFTAR PUSTAKA	44
-----------------------------	-----------

LAMPIRAN	46
-----------------------	-----------

DAFTAR GAMBAR

Gambar	Judul Gambar	Halaman
1.1	Grafik Emisi Karbon Dioksida (CO_2)	2
2.1	Plot <i>Time Series</i> yang Stasioner dalam Varians.....	9
2.2	Plot <i>Time Series</i> yang Stasioner dalam Mean.....	10
2.3	Plot <i>Time Series</i> yang Tidak Stasioner dalam Mean dan Varians.....	10
2.4	Plot ACT <i>Time Series</i> yang tidak Stasioner dalam Mean.....	10
2.5	Plot ACF <i>Time Series</i> yang Stasioner dalam Mean dan Varians.....	10
2.6	Grafik Data Berdistribusi Normal.....	14
4.1	Plot <i>Time Series</i> Emisi Karbon Dioksida (CO_2)	25
4.2	Plot Stasioner Emisi Karbon Dioksida (CO_2)	25
4.3	Plot ACF Data Emisi Karbon Dioksida (CO_2)	25
4.4	Plot FACF Data Emisi Karbon Dioksida (CO_2)	26
4.5	Plot Emisi Karbon Dioksida (CO_2) setelah <i>Differencing-1</i>	26
4.6	Plot ACF Data Emisi Karbon Dioksida (CO_2) setelah <i>Differencing-1</i>	27
4.7	Plot FACF Data Emisi Karbon Dioksida (CO_2) setelah <i>Differencing-1</i>	27
4.8	Plot Emisi Karbon Dioksida (CO_2) setelah <i>Differencing-2</i>	28
4.9	Plot ACF Data Emisi Karbon Dioksida (CO_2) setelah <i>Differencing-2</i>	28

4.10	Plot ACF Data Emisi Karbon Dioksida (CO_2) Setelah <i>Differencing-2</i>	28
4.11	<i>Output</i> Minitab 19.....	30
4.12	Plot Distribusi Normal.....	31
4.13	<i>Output</i> Minitab 19.....	32
4.14	Plot Distribusi Normal.....	33
4.15	<i>Output</i> Minitab 19.....	34
4.16	Plot Distribusi Normal.....	35
4.17	<i>Output</i> Minitab 19.....	36
4.18	Plot Distribusi Normal.....	37
4.19	<i>Output</i> Minitab 19.....	38
4.20	Plot Distribusi Normal.....	39
4.21	Plot Hasil Peramalan Emisi Karbon Dioksida (CO_2)	40

DAFTAR TABEL

Tabel	Judul Tabel	Halaman
4.1	Konsentrasi (CO_2) pada bulan Januari 2017 – Juli 2019.....	23
4.2	Peramalan (CO_2) pada bulan Januari 2017 – Juli 2019.....	39

DAFTAR LAMPIRAN

Lampiran	Judul Lampiran
1	Data Awal
2	<i>Output SPSS</i> Estimasi Plot ACF
3	<i>Output SPSS</i> Estimasi Plot PACF
4	<i>Output SPSS</i> Estimasi Plot ACF setelah <i>Differencing-1</i>
5	<i>Output SPSS</i> Estimasi Plot PACF setelah <i>Differencing-1</i>
6	<i>Output SPSS</i> Estimasi Plot ACF setelah <i>Differencing-2</i>
7	<i>Output SPSS</i> Estimasi Plot PACF setelah <i>Differencing-2</i>
8	<i>Output Minitab 19</i> Model ARIMA (0,2,1)
9	<i>Output Minitab 19</i> Model ARIMA (0,2,3)
10	<i>Output Minitab 19</i> Model ARIMA (1,2,0)
11	<i>Output Minitab 19</i> Model ARIMA (2,2,0)
12	<i>Output Minitab 19</i> Model ARIMA (4,2,0)

BAB I

PENDAHULUAN

1.1. Latar Belakang

Efek rumah kaca merupakan suatu istilah yang digunakan untuk menggambarkan bumi memiliki emisi gas rumah kaca, yang mana atmosfer bumi menangkap panas dari matahari. Gas-gas di atmosfer seperti karbon dioksida (CO_2) biasanya menahan panas matahari yang mengakibatkan atmosfer bumi menangkap panas dari matahari. Biasanya, pada siang hari matahari memantulkan cahayanya ke bumi yang mengakibatkan permukaan bumi menjadi hangat, dan biasanya pada malam hari permukaan bumi dingin. Akibat dari efek rumah kaca ini sendiri, sebagian panas yang harusnya menyinari permukaan bumi pada atmosfer bumi menangkap panas dari matahari. Yang menyebabkan bumi semakin hangat dari waktu ke waktu.


Pemanasan global (*global warming*) adalah suatu kejadian meningkatnya suhu global yang biasanya berada di daratan bumi, atmosfer, dan laut. Rata-rata suhu global di daratan bumi terus meningkat meningkat $0,18\text{ }^{\circ}\text{C}$ selama seratus tahun terakhir. *Intergovernmental Panel on Climate Change* (IPCC) membuat kesimpulan bahwa, dimana sebagian besar peningkatan suhu global meningkat sejak pertengahan abad ke-20 penyebab terbesarnya adalah meningkatnya gas rumah kaca yang dihasilkan oleh rinititas manusia paling besar melalui efek rumah kaca. Peningkatan suhu bumi menyebabkan perubahan yang lain, yaitu menyebabkan peningkatan intensitas cuaca ekstrim dan naiknya air laut dipermukaan (Smart, 2011).

Istilah pemanasan global (*global warming*) tidak hal lumrah bagi masyarakat. Peristiwa ini tersebut merupakan penyebab terjadinya perubahan suhu temperatur, cuaca eskrim, banjir, longsor, dan bencana alam lainnya. Istilah dari efek rumah kaca muncul bukan tidak ada alasannya. Eksploitasi yang dilakukan secara berlebihan oleh oknum yang tak bertanggung jawab (Yanto, 2007).

Akibatnya, secara perlahan-lahan, alam juga akan mengalami perubahan yang ekstrim. Efek rumah kaca adalah suatu meningkatnya suhu bumi setiap tahunnya yang diakibatkan oleh pemanasan global (*greenhouse effect*) yang itu terjadi dikarenakan peningkatan karbondioksida (CO_2), metana (CH_4), dinitrooksida (N_2O), dan chlorofluorocarbons (CFC) (ini dinamakan dengan gas rumah kaca (GRK) sehingga atmosfer bumi menangkap energy panas matahari (Riebeek, 2010).

Perubahan iklim yang ekstrim yang menyebabkan sudah tidak bias dikendalikan lagi menyebabkan muncul permasalahan- permasalahan lainnya. Menurut (Griffith *et al*, 2007) efek rumah kaca dan resiko perubahan cuaca yang secara ekstrim diakui oleh seluruh negara sebagai masalah yang ada di berbagai negara. Bukti ilmiah member tahukan emisi gas rumah kaca dari aktivitas manusia yang membuat keadaanya semakin buruk, seperti pemanasan global dan perubahan cuaca (IPCC, 2007).

Meningkatnya penggunaan energi ini disebabkan oleh keperluan kegiatan industri, intensifikasi budidaya tanaman dan aktivitas jasa non komersial dan komersial yang berada di tengah kota yang sangat pesat, ini membuktikan perkembangan didunia pada tahun terakhir ini. Negara berkembang yaitu seperti Indonesia butuh peningkatan pembangunan yang tinggi untuk menyamakan ketertinggalanya dengan Negara maju (Rachmad, 2007).



Sumber: Badan meteorologi klimatologi dan geofisika

Gambar. 1.1 Grafik Emisi Karbon Dioksida (CO_2)

Kontribusi efek rumah kaca pada pemanasan global dilihat dari jenis gasnya. Gas rumah kaca (GRK) yang paling berpengaruh terhadap pemanasan global adalah karbondioksida (CO_2), metana (CH_4), dinitrogen oksida (N_2O), perfluorocarbon (PFC), *hydrofluoro-carbon* (HFC) dan *sulphur hexafluoride* (SF_6). Sifat emisi rumah kaca memiliki masing-masing potensi efek rumah kaca yang berbeda-beda (*Global Warming Potential / GWP*) yang diukur secara relatif berdasarkan emisi CO_2 dengan nilai satu. (Sugiono, 2006).

Emisi CO_2 biasanya berasal dari pembakaran bahan bakar fosil, seperti: minyak bumi, gas bumi, dan batubara, gas rumah kaca dari konversi lahan dan industri semen. Berdasarkan data dari *Carbon Dioxide Information Analysis Center* tahun 2000 bahan bakar dari fosil merupakan sumber utama emisi (CO_2) paling besar di dunia dengan mencapai 74% dari total emisi. Industri semen sebesar 3% dan konversi lahan juga ikut berkontribusi dengan sebesar 24%. Emisi (CO_2) merupakan penyebab terbesar dari gas rumah kaca (GRK) di Indonesia dengan kontribusi sebesar 70 % sedangkan emisi gas rumah kaca lainnya sebesar 30 %. Berdasarkan laporan Komunikasi Nasional Pertama, sumber utama gas rumah kaca (GRK) merupakan sektor kehutanan dan sektor energi. Sektor energi menyumbangkan kontribusi sebesar 46% dari total gas rumah kaca (GRK) yang berasal dari pemakaian bahan bakar fosil pada bermacam-macam kegiatan lainnya seperti: pengolahan energi, juga pembakaran energi yang digunakan baik untuk pembangkit listrik ataupun untuk keperluan industri lainnya (Anonim, 2009)

Karena efek rumah kaca juga merupakan sesuatu yang harus diperhatikan bagi kehidupan masyarakat yang perlu diberantas dengan solusi agar dapat diminimalisirkan. Dalam Al-Quran dijelaskan pada Surat Al-Anbiya Ayat 32:

وَجَعَلْنَا السَّمَاءَ سَقْفًا مَحْفُوظًا وَهُمْ عَنْ آيَاتِهَا مُعْرِضُونَ

Artinya : "Dan Kami menjadikan langit itu sebagai atap yang terpelihara, sedang mereka berpaling dari segala tanda-tanda (kekuasaan Allah) yang terdapat padanya".

Isi kandungan ayat ini adalah memahami bahwa langit yang dijadikan pelindung dan atap tersebut adalah lapisan ozon yang ada pada atmosfer bumi. Sebab jika dilihat fungsinya, ozon telah melindungi bumi dari pancaran sinar ultraviolet yang dipancarkan matahari, sebagaimana sebuah atap yang melindungi penghuni rumah dari panas dan hujan. Dan dengan adanya air laut yang meluap, telah dapat ditarik kesimpulan bahwa dengan terbelahnya langit (berlubangnya lapisan ozon), yang menurut penelitian banyak terjadi di daerah kutub bumi yang berupa *vorteks*, mengakibatkan pelelehan es di kedua kutub bumi sehingga menambah volume air laut secara terus-menerus. Dengan demikian permukaan laut akan terus meningkat dan dalam waktu tertentu akan dapat menenggelamkan daratan yang ada secara keseluruhan (Hisnam, 2010).

Untuk melihat seberapa buruk pemanasan global yang ada di Indonesia dilakukan dengan cara peramalan. Untuk meramalkan estimasi (CO_2) yang ada di udara dapat digunakan analisis data runtun waktu berkala (*time series*). Metode prediksi ini didasarkan atas observasi saat ini yang dipengaruhi hasil observasi masa lalu dan hasil observasi yang akan datang dipengaruhi oleh observasi saat ini. Metode yang cocok untuk digunakan untuk meramalkan data *time series* adalah metode intervensi dan metode *Autoregressive Integrated Moving Average (ARIMA)* (Wei, 2006).

Metode *Autoregressive Integrated Moving Average (ARIMA)* adalah suatu model yang biasa dipakai untuk memprediksi data runtun waktu *time series*. Model *ARIMA* merupakan data *time series* memenuhi stationeritas pada rata-rata dan varians. Peristiwa yang tidak bias diperhitungkan, kemungkinan sangat mempengaruhi stationeritas data *time series*. Peristiwa itu disebut intervensi. Suatu intervensi dapat berupa bencana alam, perubahan ekonomi di pemeritahan dan peristiwa tidak terduga lainnya (Wei, 2006).

Analisis *time series* adalah metode yang digunakan untuk data deret waktu yang didasari oleh suatu peristiwa. Model data *time series* yang pertama kali dikenalkan oleh Box dan Tiao yaitu pada tahun 1975 yang meneliti pengaruh pemberlakuan undang-undang desain mesin terhadap tingkat polusi *oxidant* di

daerah Los Angeles. Deret waktu yang dilakukan oleh Box dan Tiao pada tahun 1975 ini yaitu analisis *Time series* (Suhartono, 2007).

Analisis *Time series* merupakan prediksi yang paling banyak dikembangkan yaitu *time series* dengan menggunakan pendekatan kuantitatif dengan data masa lampau dikumpulkan dan dijadikan acuan untuk prediksi masa depan. Prediksi *time series* inilah digunakan untuk meramalkan efek rumah kaca yang ada di Indonesia. Peranan prediksi menjelajah banyak dibidang ekonomi, keuangan, pemasaran, produksi, riset operasional, administrasi Negara, dan meteorologi geofisika. Dalam bidang meteorologi dan geofisika prediksi sangat dibutuhkan khususnya dalam meramalkan efek rumah kaca yaitu meramalkan emisi karbon dioksida (CO_2). Analisis yang digunakan untuk meramalkan efek rumah kaca adalah data *time series* (Wiyanti, 2012).

Analisis *Time series* adalah metode yang dimana data masa lalu yang dipakai sebagai memproyeksi data untuk masa yang akan datang. Metode ini dapat memberikan prediksi yang sangat akurat berdasarkan beberapa penelitian sebelumnya sehingga lebih efektif digunakan untuk mengetahui seberapa besar efek rumah kaca yaitu memprediksi emisi karbon dioksida (CO_2) dengan model *ARIMA time series* dengan hasil peramalan yang diperoleh memiliki akurasi yang tinggi dan mampu menghasilkan peramalan yang efektif (Hernasari, 2007).

Berdasarkan latar belakang di atas, penulis akan melakukan suatu penelitian tentang peramalan dengan judul “**Analisis Data *Time Series* Untuk Peramalan Efek Rumah Kaca**”.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang tertarik dikemukakan sebelumnya, masalah yang dapat dirumuskan dalam penelitian ini adalah :

1. Bagaimanakah cara menentukan model ARIMA terbaik terhadap efek rumah kaca?
2. Bagaimanakah hasil peramalan efek rumah kaca menggunakan model ARIMA?

1.3 Batasan Masalah

Dalam penelitian ini dilakukan beberapa batasan masalah sebagai berikut :

1. Data yang digunakan adalah data yang diambil dari Badan Meteorologi Klimatologi dan Geofisika (BMKG) Medan pada bulan Januari 2017 sampai Juli 2019.
2. Peramalan yang dilakukan tiga puluh satu bulan kedepan.
3. Analisis yang digunakan adalah analisis model ARIMA.

1.4 Tujuan Penelitian

Dari penelitian di atas tujuan yang ingin diperoleh adalah sebagai berikut:

1. Untuk mengetahui model ARIMA terbaik yang digunakan untuk meramalkan efek rumah kaca.
2. Untuk mengetahui hasil peramalan efek rumah kaca tiga puluh satu bulan kedepan.

1.5 Manfaat Penelitian

Adapun manfaat penelitian dari pembahasan masalah ini adalah :

1. Menambah referensi terapan mengenai analisis *time series* menggunakan metode pemodelan ARIMA bagi mahasiswa.
2. Mengetahui peramalan efek rumah kaca tiga puluh satu bulan kedepan.

BAB II TINJAUAN PUSTAKA

2.1 Deret Waktu (Time Series)

Data runtun waktu (*time series*) adalah suatu penelitian terhadap variabel yang diambil secara deret berdasarkan yang tetap pada interval waktunya. Analisis runtun waktu (*time series*) pertama kali dikemukakan pada tahun 1970 oleh George E. P. Box dan Gwilym M. Jenkins melalui bukunya *Time Series Analysis : forecasting and control*. Sejak itu, data runtun waktu yang banyak digunakan. Konsep dasar runtun waktu (*time serie*) merupakan waktu dimasa sekarang Z_t tergantung pada satu atau beberapa data sebelumnya (Z_{t+k}) dimana t adalah indeks waktu dari urutan pengamatan. Tujuan analisis *time series* menjelaskan mekanisme dan memahami tertentu, memprediksi suatu nilai dimasa depan, dengan mengoptimalkan sistem kendali (Siska, 2017).

Data runtun waktu adalah suatu data deret waktu atau deret dari kronologi pengamatan pada suatu peubah terkait. Suatu data deret waktu dapat diolah sehingga diperoleh inferensi yang bermanfaat untuk pengambilan keputusan dimasa yang akan datang. Banyak himpunan data muncul sebagai data deret waktu misalkan indeks harga konsumen, curah hujan harian, kuantitas barang yang dikirim dari pabrik dalam waktu bulanan, jumlah uang beredar, dan lain sebagainya. Mempelajari hubungan timbal balik dengan menggunakan data runtun waktu disebut dengan analisis deret waktu (Nalar, 2015).

Dalam memprediksi suatu nilai variabel di masa yang akan datang harus mengetahui dahulu sifat variabel itu di masa sebelumnya. Nilai pada variabel biasanya di prediksi dari sifat dari variabel tersebut diketahui pada masa sekarang dan di masa sebelumnya, untuk mengetahui kejadian dari suatu variabel, biasanya diamati dari waktu yang sudah ditentukan. Serangkaian terhadap pengamatan suatu kejadian pada variabel yang diambil dari waktu yang beruntun yang kemudian di catan seterusnya disusun dan dijadikan data beupa data mingguan, bulanan maupun tahunan (Samsiah, 2008).

Langkah yang harus dilakukan untuk memilih suatu metode runtun waktu yang tepat harus memperhatikan terlebih dahulu jenis pola data, sehingga menghasilkan pola yang benar dan pola itu dapat diuji, dan dikelompokkan menjadi empat kelompok yaitu:

1. Pola horizontal, terlihat bila nilai data berfluktuasi yang berada disekitar nilai rata-rata yang tetap.
2. Pola musiman, terlihat bila nilai suatu deret waktu dipengaruhi oleh faktor musiman.
3. Pola siklis, terlihat bila suatu nilai data dipengaruhi oleh faktor jangka panjang seperti siklus bisnis.
4. Pola trend, terlihat bila nilai mengalami kenaikan atau penurunan sekuler jangka panjang dalam data.

2.2 Stasioneritas dan Nonstasioneritas Data

Jika dilihat dari histori pada masa sekarang suatu runtun waktu mampu diprediksi dengan akurat maka deret waktu ini disebut deterministik. Sebaliknya jika pengalaman dimasa lampau hanya dapat menunjukkan struktur probabilistik keadaan masa yang mendatang suatu deret waktu, maka deret waktu seperti ini dinamakan proses stokastik. Deret waktu statistik dapat dilihat sebagai realisasi dari suatu proses stokastik. Biasanya kita tidak mungkin memperoleh realisasi yang lain suatu proses stokastik, yaitu kita tidak dapat mengulang kembali dimana untuk memperoleh data observasi serupa seperti yang telah kita kumpulkan (Wei, 2006).

Dalam analisis data runtun waktu disimbolkan data yang sering mengikuti proses stokastik. Urutan dari pengubah acak disebut $Z(\omega, t)$ yang memiliki ruang sampel dan satuan waktu dinyatakan sebagai proses stokastik. Berdasarkan ada atau tidaknya kejadian di waktu yang akan datang, maka, *Time Series* dibagi atas dua macam yaitu:

1. Jika nilai suatu masa depan (*future value*) dari suatu runtun waktu dapat dengan tepat dapat ditentukan oleh suatu fungsi matematika.


2. Jika nilai suatu masadepan (*future value*) hanyadapat digambarkan dalam suatu distribusi probabilitas, maka deret waktu dikatakan sebagai stokastik (Halim, 2006).

Dalam membentuk suatu model analisis data runtun waktu yang harus dilakukan pertama kali yaitu menstasionerkan data . data runtun waktu dapat dikatakan stasioner jika tidak ada perubahan yang terlalu tajam dalam varans dan rata-rata. Dengan kata lain, dalam halnya dapat disimpulkan keadaan stasioner bila pola datanya tidak mengalami kenaikan dan penurun secara tajam pada varian maupun rata-rata, maka keadaan ini sudah stasioner (Sukarna, 2006).

Data yang dikatakan stasioner jka tidak mengalami perubahan secara tajam pada waktu atau pola trendnya. Menurut (Wei,2006) suatu proses stasioner pada suatu $\{Z_t\}$, memiliki mean $E(Z_t) = \mu$ dan $Var(Z_t) = E(Z_t - \mu)^2 = \sigma^2$, yang keduanya konstan dan kovarian $Cov(Z_t, Z_s)$ yang merupakan fungsi dari perbedaan waktu $|t - s|$. Oleh karena itu, kovarian Z_t dari dan Z_{t+k} dapat ditulis sebagai berikut:


$$Cov(Z_t, Z_{t+k}) = E[Z_t - \mu)(Z_{t+k} - \mu)] = \gamma_k \quad (2.1)$$

Stasioneritas merupakan tidak terdapat kenaikan atau penurunan yang tajam pada data. Bisa dilihaat data harus horizontal sepanjang sumbu waktu.dapat dikatakan, fluktuasi data yang prnyebaranya di sekitar suatu nilai rata – rata yang konstan. Data yang todak stasioner akan membentuk berpola *trend*.




Sumber: *Time Series Analysis*

Gambar 2.1. Plot Time Series yang Stasioner dalam Varians



Sumber: *Time Series Analysis*

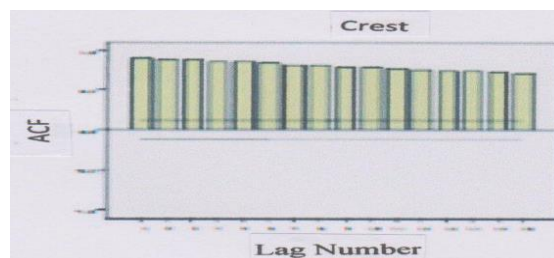
Gambar 2.2. Plot Time Series yang Stasioner Dalam Mean




Sumber: *Time Series Analysis*

Gambar 2.3. Plot Time Series yang Tidak Stasioner dalam Mean dan Varians

Pada plot autokorelasi dapat dilihat kestasioneritas datanya. Nilai – nilai autokorelasi dari data stasioner akan menurun sampai nol sesudah time-lag kedua atau ketiga, sedangkan untuk data yang tidak stasioner, nilai – nilai tersebut berbeda signifikan dari nol untuk beberapa periode waktu.



Gambar 2.4. Plot ACT Time Series yang Tidak Stasioner Dalam Mean



Sumber: *Time Series Analysis*

Gambar 2.5. Plot ACF Time Series yang Sasioner Dalam Mean dan Varians

Ketidakstasioneran daam data dapat dilihat apakah data membentuk pola *trend* pada varians dan rata-ratanya. Kestasioneritas data dalam varians dapat menggnakan cara dengan transformasi *Box-Cox*, sedangkan proses stasioneritas data dalam rata-rata dapat menggunakan cara dengan pembedaan (*differencing*).

2.3 Fungsi Autokorelasi (ACF)

Stasioneritas berarti bahwa tidak terdapat Autokorelasi mengukur arah (positif atau negatif) dan keeratan hubungan antara pengamatan dalam *single* deret waktu Z_t ketika pengamatan terpisah pada waktu periode k , untuk $k = 1, 2, \dots, K$. Misalnya, mengukur bagaimana sebarang nilai deret saat ini berkaitan dengan nilai yang dimiliki dimasa akan datang (Z_{t+1}, Z_{t+2}, \dots) atau sama nilainya, dengan nilai pada masa lampau (Z_{t-1}, Z_{t-2}, \dots). Studi mengenai pola-pola autokorelasi dalam data deret waktu membantu kita dalam mengidentifikasi model ARIMA untuk *series* tersebut (Pankratz, 1991).

Koefessien autokorelasi didefenisikan sebagai:

$$\rho_k = \frac{E[(Z_t - \mu_z)(Z_{t+k} - \mu_z)]}{\sqrt{E[(Z_t - \mu_z)^2] \cdot E[(Z_{t+k} - \mu_z)^2]}} = \frac{Cov(Z_t, Z_{t+k})}{Var(Z_t)} = \frac{\gamma_k}{\gamma_0} \quad (2.2)$$

Dengn $Var(Z_t) = Var(Z_{t+k}) = \gamma_0, \gamma_k$ merupakan fungsi autokovarians pada lag k , ρ_k merupakan koefisien aotokorelasi untuk lag k , dengan $\rho_0 = 1$ dan kumpulan dari niai $\rho_k, k=1,2,\dots$, disebut fungsi aotokorelasi (ACF). Sehingga γ_k dan ρ_k menggambarkan kovarians dan kolerasi antara Z_t dan Z_{t+k} dari proses yang sama tetapi dipisahkan oleh waktu periode k . Fungsi autokovariansi γ_k dan fungsi autokorelasi ρ_k memiliki sifat-sifat sebagai berikut:

1. $\gamma_0 = \text{var}(x_t) : \rho_0 = 1$
2. $|\gamma_k| \leq \gamma_0 : |\rho_k| \leq 1$.
3. $\gamma_k = \gamma_{-k}$ dan $\rho_k = \rho_{-k}$ untuk semua k . γ_k dan ρ_k adalah fungsi yang sama dan simetris lag $k = 0$

2.4 Fungsi autokorelasi parsial (FAKP)

Autokorelasi parsial digunakan untuk mengukur keeratan hubungan antar pengamatan suatu *time series* yaitu Z_t dan Z_{t+k} . Korelasi antara Z_t dan Z_{t+k} digambarkan sebagai berikut: (Wei, 2006).

$$\phi_{kk} = \text{Corr}(Z_t, Z_{t+k} \mid Z_{t+1}, \dots, Z_{t+k-1}) \quad (2.3)$$

Autokorelasi parsial dinotasikan dengan $\{\phi_{kk} : k = 1, 2, \dots\}$, merupakan himpunan dari autokorelasi parsial pada lag k (Anderson, 1976). Autokorelasi parsial didefinisikan sebagai:

$$\phi_{kk} = \frac{|P_k^*|}{|P_k|} \quad (2.4)$$

dengan P_k adalah matriks autokorelasi berukuran $k \times k$, dan P_k^* adalah P_k yang kolom terakhirnya diganti dengan

$$P_{k \times 1} = \begin{bmatrix} \rho_1 \\ \rho_2 \\ \vdots \\ \rho_k \end{bmatrix} \quad (2.5)$$

Matriks autokorelasi P berukuran $k \times k$ didefinisikan sebagai

$$P_{k \times k} = \begin{bmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & & \rho_{k-2} \\ \rho_2 & \rho_1 & 1 & & \rho_{k-3} \\ \vdots & & & \ddots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & 1 \end{bmatrix} \quad (2.6)$$

Maka, untuk autokorelasi parsial pada lag 1 dan lag 2 berturut-turut didefinisikan dengan

$$\begin{aligned} \phi_{11} &= \rho_1 \\ \phi_{22} &= \frac{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & \rho_2 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & 1 \end{vmatrix}} = \frac{\rho_2 - \rho_1^2}{1 - \rho_1^2} \end{aligned} \quad (2.7)$$

Autokorelasi parsial antara Z_t dan Z_{t+k} adalah ϕ_{kk} yang didefinisikan dengan

$$\phi_{kk} = \begin{bmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_1 \\ \rho_1 & 1 & \rho_1 & & \rho_2 \\ \rho_2 & \rho_1 & 1 & & \rho_3 \\ \vdots & & & & \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & 1 \\ 1 & \rho_1 & \rho_2 & \cdots & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & & \rho_{k-2} \\ \rho_2 & \rho_1 & 1 & & \rho_{k-3} \\ \vdots & & & \ddots & \vdots \\ \rho_{k-k} & \rho_{k-2} & \rho_{k-3} & \cdots & 1 \end{bmatrix} \quad (2.8)$$

2.5 White noise Procces

Suatu proses $\{a_t\}$ disebut dengan *white noise process* apabila suatu proses itu indentik dan independen dan suatu peubah acak yang tidak saling berkolerasi tetapi beruntun dan mengikuti distribusi. Rata-rata $E(a_t) = \mu_a$ dari proses tersebut diasumsikan memiliki variansi yang konstan dan bernilai nol yaitu $\text{var}(a_t) = \sigma_a^2$ dan nilai kovariansi untuk proses ini $\gamma_k = \text{cov}(a_t, a_{t+k}) = 0$ untuk $k \neq 0$. Berdasarkan paparan tersebut, dapat dikatakan bahwa suatu *white noise process* $\{a_t\}$ adalah stasioner dengan beberapa sifat berikut.

Fungsi autokovariansi :

$$\gamma_k = \begin{cases} \sigma_a^2, & \text{untuk } k = 0 \\ 0, & \text{untuk } k \neq 0 \end{cases} \quad (2.9)$$

Fungsi autokorelasi:

$$\rho_k = \begin{cases} 1, & \text{untuk } k = 0 \\ 0, & \text{untuk } k \neq 0 \end{cases} \quad (2.10)$$

Fungsi autokorelasi parsial:


$$\phi_{kk} = \begin{cases} 1, & \text{untuk } k = 0 \\ 0, & \text{untuk } k \neq 0 \end{cases} \quad (2.11)$$

Dengan demikian, suatu deret waktu disebut *white noise* jika rata-rata dan variansinya konstan dan saling bebas (Sukarna, 2006).

2.6 Uji Asumsi Distribusi Normal

Uji distribusi normal harus dilakukan untuk mengetahui apakah data sudah memenuhi kenormalannya. Uji ini biasanya digunakan untuk mengukur data berskala ordinal, interval ataupun rasio. Cara yang dapat kita lakukan untuk melakukan uji kenormalan suatu data dapat dilakukan dengan cara uji *Anderson Darling* dengan melihat nilai *p-value* pada *probability plot* menggunakan pengambilan keputusan sebagai berikut:

- 1) Jika nilai $p < 0,05$, data tidak berasal dari populasi yang berdistribusi normal. (Sukarna, 2006).



Gambar 2.6. Grafik Data Berdistribusi Normal

Namun apabila dengan mengamati distribusi normal dengan *p-value* dan tidak berdistribusi normal, maka dapat digunakan Q-Q plot untuk melihat apakah data berdistribusi normal atau tidak. Apabila pada Q-Q plot semua titik-titik mengarah kepada garis kenormalan maka dapat diasumsikan bahwa data berdistribusi normal dan dapat digunakan untuk peramalan.

2.7 Metode Autoregressive Integrated Moving Average (ARIMA)

2.7.1 Proses Autoregresif (AR)

Proses autoregresif memiliki arti regresi pada diri sendiri. Lebih apesifik, proses autiregresif $\{Z_t\}$ orde p:

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t \quad (2.12)$$

Dimana diasumsikan bahwa Z_t adalah stasioner dan $E(Z_t) = 0$

Jadi, nilai besaran Z_t adalah perpaduan linier dari jumlah p nilai Z_t terakhir di masa lalu ditambah sebuah a_t yang menyatakan sesuatu yang tidak dapat dijelaskan oleh nilai-nilai Z_t di masa lalu tersebut. Selain itu a_t merupakan variable acak yang *independent* dengan rata-rata nol.

Secara umum rumus untuk mencari nilai autokorelasi untuk proses AR(p) secara umum dapat diperoleh sebagai berikut:

$$\rho_k = \phi_1 \rho_{k-1} + \phi_2 \rho_{k-2} + \dots + \phi_p \rho_{k-p}, \text{ untuk } k \geq 1 \quad (2.13)$$

Dan varians dari prose AR (p) adalah:

$$\gamma_0 = \frac{\sigma_a^2}{1 - \phi_1 \rho_1 - \phi_2 \rho_2 - \dots - \phi_p \rho_p}$$

Dengan mengganti $k = 1, 2, \dots, p$ dan $\rho_0 = 1$ serta $\rho_{-k} = \rho_k$ pada persamaan di atas maka diperoleh persamaan Yule-Walker sebagai berikut:

$$\begin{aligned} \rho_1 &= \phi_1 + \phi_2 \rho_1 + \dots + \phi_p \rho_{p-1} \\ \rho_2 &= \phi_1 \rho_1 + \phi_2 + \dots + \phi_p \rho_{p-2} \\ \rho_p &= \phi_1 \rho_{p-1} + \phi_2 \rho_{p-2} + \dots + \phi_p \end{aligned} \quad (2.14)$$

Jika diberikan nilai $\phi_1, \phi_2, \dots, \phi_p$, system persamaan linear ini dapat diselesaikan untuk mendapatkan $\rho_1, \rho_2, \dots, \rho_1$ dan untuk ρ_k pada orde lebih tinggi.

Suatu indentifikasi model, jika suatu runtun waktu memiliki grafik fungsi autokorelasi yang turun secara eksponensial dan fungsi autokorelasi parsial terputus pada lag ke-p, maka deret waktu dimasukkan kedalam proses AR(p).

2.7.2 Model Moving Average (MA)

Model $MA(q)$ merupakan metode untuk meramalkan Z_t sebagai fungsi dari kesalahan peramalan dimasa lalu (*past forecast error*) dalam meramalkan Z_t . Secara umum model $MA(q)$ adalah sebagai berikut:

$$Z_t = a_t - \theta_1 B - \dots - \theta_q B^q a_{t-q} \quad (2.15)$$

Persamaan diatas dapat ditulis dalam bentuk:

$$Z_t = (1 - \theta_1 B - \dots - \theta_q B^q) a_{t-q} \quad (2.16)$$

Dimana :

Z_t	= variable <i>dependent</i> pada waktu t
$\theta_{t-1}, \theta_{t-2}, \dots, \theta_{t-p}$	= variable <i>independent</i> yang merupakan lag dari Z_t
$\phi_1, \phi_2, \dots, \phi_p$	= parameter model <i>Autoregresif</i> (AR)
a_t	= nilai residual pada waktu ke-t
$a_{t-1}, a_{t-2}, \dots, a_{t-q}$	= nilai residual pada periode sebelumnya
q	= orde MA

Persamaan diatas dapat ditulis dengan operator B menjadi:

$$Z_t (1 - \theta_1 B - \dots - \theta_q B^q) a_t \quad (2.17)$$

2.7.3 Model ARMA

Menurut Halim (2006) Model ARMA (p,q) merupakan perpaduan dari model AR(p) dan MA(q), yaitu:

$$\begin{aligned} Z_t &= \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \\ Z_t - \phi_1 Z_{t-1} - \dots - \phi_p Z_{t-p} &= a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \end{aligned} \quad (2.18)$$

Persamaan diatas dapat ditulis dalam bentuk:

$$(1 - \phi_1 B - \dots - \phi_p B^p) Z_t = (1 - \theta_1 B - \dots - \theta_q B^q) a_t$$

Apabila kedua ruas pada persamaan dikalikan dengan Z_{t-k} hasilnya:

$$Z_t Z_{t-k} = \phi_1 Z_{t-1} Z_{t-k} + \dots + \phi_p Z_{t-p} Z_{t-k} + a_t Z_{t-k} - \phi_1 a_{t-1} Z_{t-k} - \dots - \phi_q a_{t-q} Z_{t-k} \quad (2.19)$$

Jika persamaan diatas diekspetasikan maka:

$$\gamma_k = \phi_1 \gamma_{k-1} + \dots + \phi_p \gamma_{k-p} + E[a_t Z_{t-k}] - \dots - \theta_q E[a_{t-q} Z_{t-k}] \quad (2.20)$$

2.7.4 Model ARIMA

Model *Autoregressive Integrated Moving Average* (ARIMA) merupakan model dikemukakan oleh Georgee Boxx dan Gwilyn Jenkins pada tahun 1976 adalah metode ini yang tidak menjelaskan pola tertentu pada data masa lampau yang diprediksi dan metode yaang secara penuh tidak melihat variabel bebas dalam melakukan prediksi dikarenakan model ini yang digunakan adalah masa sekarang dan masa lalu dari variabel terikat untuk menghasilkan prediksi jangka pendek yang akurat. ARIMA adalah model yang sering disebut metode runtun waktu Box-Jenkins merupan salah satu yang dapat dilakukan untuk sekelompok data (*curve fitting*), maka dari itu ARIMA sangat berguna mempunyai data masa lampau dan sekarang dengan variabel tidak terikat untuk melakukan prediksi waktu pendek memiliki nilai akurat sedangkan juga dapat memprediksi jangka panjang ketepatan prediksinya tidak begitu baik. Model ARIMA merupakan metode perpaduan antara *Autoregressive* (AR) dan *Moving Average* (MA) dimana model ini dapat mewakili data runtun wakttu yang stasioner dan non-stasioner (Sari, 2014).

Dalam model ARIMA ada konstanta p , d dan q . dimana p disebut konstanta untuk *Autoregressive*, d disebut dengan pembedaan yang membuat data menjadi stasioner, sedangkan q adalah konstanta yang disebut *Moving Average*. Nilai konstanta p dan q dapat diperoleh dari pola atau gambar pada ACF dan PACF. Sedangkan untuk nilai d dilakukan dengan trial errorr terhadap nilai p dan q yang sudah didapatkan. Secara umum metode ARIMA dapat dirumuskan sebagai berikut:

$$ARIMA(p, d, q)$$

Model ARIMA dapat disimbolkan sebagai ARIMA (p, d, q) dimana apabila $d = 0$ dan $q = 0$, maka model *Autoregressive* dinotasikan sebagai AR (p). Apabila

$p = 0$ dan $d = 0$, maka model *Moving Average* dinotasikan sebagai MA (q) (Wibowo, 2012).

Model ARIMA biasanya digunakan untuk data yang sudah stasioner maupun data yang belum stasioner. Data deret waktu tapi biasanya belum semuanya stasioner maka dari itu perlu dilakukan pembedaan *differencing* sebanyak d kali agar membuat data menjadi stasioner. Rumus umum dari model ARIMA (p, d, q) adalah sebagai berikut:

$$Z_t = (1 + \phi_1)Z_{t-1} + \phi_2 Z_{t-2} + a_t + \theta a_{t-1} \quad (2.21)$$

Berdasarkan dengan menggunakan *Box-Jenkins* dalam melakukan analisis deret waktu mempunyai lima tahapan, yaitu:

1. Pengidentifikasi model

Pertama biasanya yang harus dilakukan adalah mengidentifikasi model sementara, guna untuk melihat data stasioner atau belum biasanya dalam varians ataupun dalam rata-rata. Jika data belum juga stasioner maka akan dilakukan pembedaan (*differencing*) apabila data belum juga stasioner dalam varian dapat dilakukan dengan melihat plot FAK dan FAKP dari *correlogram*, dari plot tersebut dapat dilakukan pengidentifikasi beberapa model dan akan dicari satu terbaik dari model dari beberapa model tersebut (Sukarna, 2006).

2. Pendugaan parameter model

Setelah memperoleh kandidat model awal ARIMA (p, d, q), selanjutnya parameter dari model tersebut ditaksir, sehingga didapatkan besaran koefisien model. Penaksiran parameter model ARIMA Box-Jenkins dapat dilakukan dengan menggunakan beberapa metode seperti metode *moment*, metode *least squared*, metode *maximum likelihood*, dan sebagainya. (Sukarna, 2006).

3. Pemeriksaan diagnosis model

Pemeriksaan diagnosa (*diagnostic checking*) bias dilakukan ke dalam dua bagian, yaitu dengan uji kesignifikan parameter dan uji kesesuaian model (meliputi uji asumsi *white noise* dan distribusi normal) (Sukarna, 2006).

4. Kriteria pemilihan model

Pemodelan data runtun waktu waktu, pemilihan dapat dilakukan jika sudah memenuhi uji asumsi *white noise* dan datanya sudah berdistribusi normal, dan

juga sudah memenuhi syarat: kriteria *Mean Square Error* (MSE), *Information Criterion* (AIC) dan *Schwarz Bayesian Criterion* (SBC). Model terbaik dipilih yang nilai kriterianya terkecil (Rosadi, 20011).

5. Peramalan

Langkah terakhir yaitu merupakan memprediksi dan akan dijadikan model terbaik yang sudah kita dapat. Jika melakukan peramalan jjangka pendek hasilnya sudah pasti sangat akurat, sebaliknya jika melakukan prediksi jangka panjang untuk menghasilkan nilai yang akurat perlu dilakukan untuk melihat pola trendnya, jika tidak ada trend tidak memiliki penurunan atau kenaikan dengan tajam. Peramalan dapat dilakukan jika kita sudah mengidentifikasi model serta data nya sudah stasioner yang sudah memenuhi syarat seperti uji white noise dan data sudah berdistribusi normal (Susanto, 2009).

2.8 Penelitian Yang Relevan

Adapun penelitian terdahulu yang relevan dengan penelitian ini adalah sebagai berikut

1. Berdasarkan penelitian yang dilakukan oleh Febi Satya Purnomo yang berjudul “Penggunaan Metode ARIMA (*Autoregressive Integrated Moving Average*) Untuk Perkiraan Beban Konsumsi Listrik Jangka Pendek ”. pada tahun 2015 Dilaksanakannya penelitian ini bertujuan untuk mengetahui model terbaik dan untuk melakukan perkiraan beban onsumsi listrik. Hasil penelitian ini menunjukkan bahwa model ARIMA terbaik diperoleh model ARIMA (0,2,1) (2,2,1) dengan memiliki nilai MAPE (Mean Absolut Precentage Error) sebesar 6,03%.
2. Berdasarkan penelitian yang dilakukan oleh Moh. Fahmi yang berjudul “Peramalan Kebutuhan Pelumas Castrol Di PT. ASTRA International Daihatsu dengan Metode ARIMA (*Autoregressive Integrated Moving Average*) Untuk Optimasi Persediaan”. pada tahun 2017 Dilaksanakannya penelitian ini bertujuan untuk mengetahui model terbaik dan untuk melakukan perkiraan beban onsumsi listrik. Hasil penelitian ini menunjukkan bahwa model ARIMA

terbaik diperoleh model ARIMA (2,0,1) dengan memiliki nilai MAPE (*Mean Absolut Precentaged Error*) sebesar 14,98%.

3. Berdasarkan penelitian yang dilakukan oleh Hani Nastiti Tantika yang berjudul “Metode Seanseol ARIMA (Autoregressive Integrated Moving Average Untuk meramalkan produksi Kopi dengan indicator curah hujan menggunakan aplikasi R di kabupaten Lampung Barat”. pada tahun 2018. Dilaksanakannya penelitian ini bertujuan untuk mengetahui model terbaik dan untuk melakukan perkiraan beban konsumsi listrik. Hasil penelitian ini menunjukkan bahwa model ARIMA terbaik diperoleh model ARIMA (3,1,1) (1,2,1) dan untuk curah hujan ARIMA (0,1,1) dan (1,1,0) dengan hasil produksi terbesar 4.856.561,41 ton.
4. Berdasarkan penelitian yang dilakukan oleh Nurulita yang berjudul “Penerapan Metode Peramalan ARIMA (*Autoregressive Integrated Moving Average*) Untuk penentuan tingkat Safety Stock Pada Industri Elektronik”. pada tahun 2010. Dilaksanakannya penelitian ini bertujuan untuk mengetahui model terbaik dan untuk melakukan perkiraan beban onsumsi listrik. Hasil penelitian ini menunjukkan bahwa model ARIMA terbaik diperoleh model ARIMA (3,1,1) dengan dengan memiliki nilai MAPE (*Mean Absolut Precentaged Error*) sebesar 64% turun sebesar 19% dari metode peramalan sebelumnya yaitu 83%.
5. Berdasarkan penelitian yang dilakukan oleh Fitriani yang berjudul “Peramalan Curah Hujan Di Kota Makassar Menggunakan Model ARIMAX”. Pada tahun 3014, Dilaksanakannya penelitian ini bertujuan untuk mengatahui cara menentukan model intervensi dan mengetahui hasil model intervensi fungsi *step*. Hasil penelitian ini menunjukkan hasil curah hujan yang berada dikota Makassar dibulan januari 2013 – desember 2015 yang sebesar 1,9mm- 640,88 mm dengan rata-rata 240,1 dilihat dari kelembapanya menggunakan model ARIMA yaitu sebagai berikut:

$$y_t = 12,667773x_t + (1 - 0,62697B^{12})a_t$$

BAB III

METODE PENELITIAN

3.1. Lokasi dan Waktu Penelitian

Penelitian ini dilakukan di Badan Meteorologi Klimatologi dan Geofisika (BMKG), Jl. Meteorologi Raya No.17, Tembung, Kec. Percut Sei Tuan, Kabupaten Deli Serdang Sumatera Utara. Dilaksanakan pada bulan Juli s/d selesai.

3.2. Jenis dan Variabel Penelitian

Jenis penelitian ini merupakan penelitian yang dengan pendekatan kuantitatif yaitu dengan mengambil dan mengumpulkan data mentah yang diperlukan, dan menganalisisnya dengan data *time series*.

Pada penelitian ini variabel waktu sebagai (Y_t) yang diasumsikan dipengaruhi oleh variabel *time series* yaitu Emisi karbon dioksida (CO_2) sebagai (X_t).

3.3. Prosedur Penelitian

Prosedur penelitian dalam penelitian ini yaitu:

1. Pembuatan rancangan penelitian

Pada tahap ini yang pertama dilakukan dengan menentukan Masalah yang ingin dikajih. Dengan cara membuat pendahuluan, selanjutnya membuat rumusan masalah dan adanya batasan masalah, dan menyimpulkan tujuan penelitian serta manfaat penelitian, dan membuat tujuan pustaka dan metodeologi penelitian dengan mencari referensi-referensi yang akurat yang mendukung untuk menuliskan penelitian.

2. Pelaksanaan penelitian

Pelaksanaan penelitian dilakukan untuk mengumpulkan data yang akan diolah menjadi penelitian.

3. Pembuatan laporan penelitian

Pembuatan laporan penelitian bertujuan guna untuk melihat apakah data sudah sesuai dengan data yang diperoleh yang selanjutnya dituliskan dalam bentuk skripsi .

3.4. Analisis Data

Pada penelitian ini digunakan analisis *time series* dengan metode peramalan yaitu *forecasting*. Data penelitian ini diolah menggunakan *software* IBM SPSS 22 dan MINITAB 19. Analisis data yang digunakan adalah sebagai berikut:

1. Mengumpulkan data dari BMKG.
2. Melakukan deskripsi data estimasi karbon dioksida (CO_2)
3. Deskripsikan data, Setelah data di deskripsikan maka langkah selanjutnya adalah menganalisis data.
4. Melakukan uji stasioneritas.
5. Pada penelitian ini digunakan pemodelan ARIMA.
6. Melakukan interpretasi hasil analisis.
Setelah mendapatkan hasil analisis, maka tahap selanjutnya adalah menjelaskan mengenai model yang terbentuk dan hasil peramalan.
7. Menarik kesimpulan.

BAB IV

HASIL DAN PEMBAHASAN

Pada bab ini akan dibahas mengenai hasil dan pembahasan dari penelitian dan analisis yang akan dilakukan oleh peneliti data *time series* dengan menentukan model terhadap efek rumah kaca dengan menggunakan model ARIMA dan bagaimanakah hasil peramalan efek rumah kaca menggunakan model ARIMA. Berikut ini diberikan data yang akan digunakan pada penelitian yaitu:


Tabel. 4.1 Konsentrasi (CO_2) pada bulan Januari 2017 – Juli 2019

No	Waktu	CO_2 (ppm)
1	Januari 2017	396
2	Februari 2017	397
3	Maret 2017	403
4	April 2017	398
5	Mei 2017	397
6	Juni 2017	394
7	Juli 2017	390
8	Agustus 2017	391
9	September 2017	393
10	Oktober 2017	392
11	November 2017	395
12	Desember 2017	391
13	Januari 2018	360
14	Februari 2018	361
15	Maret 2018	371
16	April 2018	376
17	Mei 2018	363
18	Juni 2018	372

No	Waktu	CO_2 (ppm)
19	Juli 2018	362
20	Agustus 2018	390
21	September 2018	395
22	Oktober 2018	361
23	November 2018	390
24	Desember 2018	395
25	Januari 2019	391
26	Februari 2019	400
27	Maret 2019	401
28	April 2019	403
29	Mei 2019	410
30	Juni 2019	400
31	Juli 2019	405

Sumber: Badan Meteorologi Klimatologi dan Geofisika (BMKG)


Tabel 4.1 di atas merupakan deskripsi dari data untuk emisi karbon dioksida (CO_2) dan suhu udara pada periode waktu Januari 2017 – Juli 2019, berdasarkan data di atas dapat dilihat bahwa emisi karbon dioksida (CO_2) tertinggi pada bulan April 2019 yaitu sebesar 410 dan emisi karbon dioksida (CO_2) terendah pada bulan Januari 2018 yaitu sebesar 360. Berdasarkan uraian di atas telah diketahui data di atas untuk menentukan model data *time series* terhadap efek rumah kaca dengan menggunakan model ARIMA dan bagaimanakah hasil peramalan efek rumah kaca menggunakan model data *time series*.



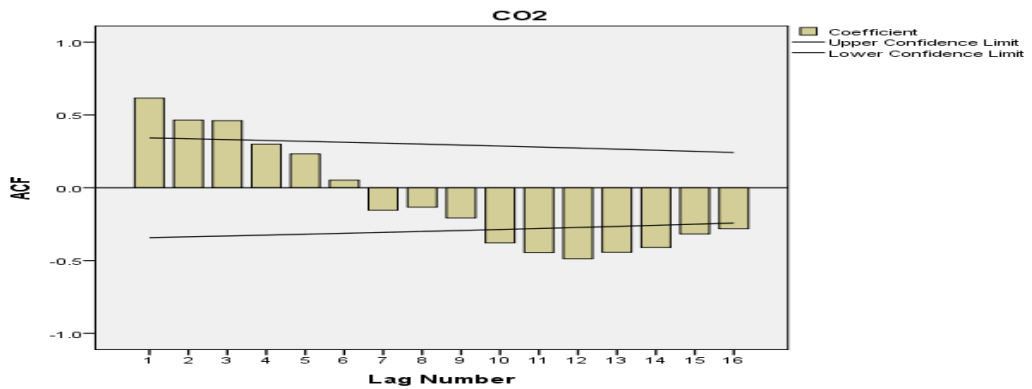
Gambar 4.1 Plot Time Series Emisi Kabron Dioksida (CO_2)

4.1 Pengindentifikasian dan Pendugaan Parameter Model

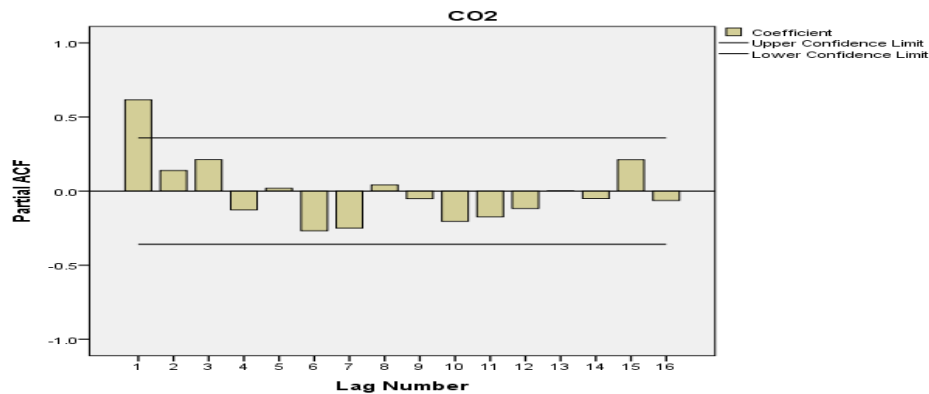
Gambar 4.2 dan Gambar 4.3 berikut merupakan diagram deret waktu (plot data asli), diagram ACF dan PACF dari data emisi karbon dioksida (CO_2).



Gambar 4.2 Plot Stasioner Emisi Karbon Dioksida (CO_2)

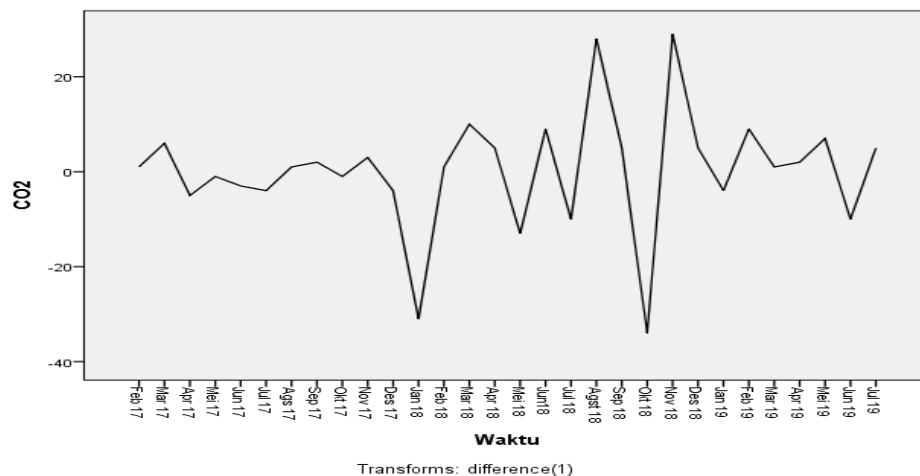


Gambar 4.3 Plot ACF Data Emisi Karbon Dioksida (CO_2)




Gambar 4.4 Plot FACP Data Emisi Karbon Dioksida (CO₂)


Pada diagram ACF (Gambar 4.3) di atas menunjukkan koefisien korelasi yang tinggi pada sebagian lag dan adanya penurunan yang lambat dari plot ACF. Hal ini menandakan bahwa data deret waktu tersebut tidak stasioner. Data yang sudah didapat belum bias langsung dijadikan sebagai model karena datanya belum stasioner maka dari itu dapat dilakukan dengan cara pembedaan (*differencing*) ($d=1$) dan dilakukan untuk melihat apakah masih ada pola *trend* maka dilakukan pembedaan *differencing*. Diagram deret waktu, diagram AFC dan FACP data emisi karbon dioksida hasil pembedaan (*differencing*) dengan $d=1$ dapat dilihat pada gambar 4.5 gambar 4.6, dan gambar 4.7 berikut:



Gambar 4.5 Plot Emisi Karbon Dioksida (CO₂) Setelah Differencing-1




Gambar 4.6 Plot ACF Data Emisi Karbon Dioksida (CO₂) Setelah *Differencing-1*




Gambar 4.7 Plot FACF Data Emisi Karbon Dioksida (CO₂) Setelah *Differencing-1*


Pada diagram ACF (Gambar 4.6) di atas menunjukkan koefesien korelasi yang tinggi pada sebagian lag dan adanya penurunan yang lambat dari plot ACF. Hal ini dapat dilihat karena data belum stasioner . Data belum dapat digunakan sebagai acuan model ARIMA untuk deret *output*, karena stasioneran belum terpenuhi. Karena belum juga stasioner maka dilakukan kembali pembedaan (*differencing*) pertama non musiman ($d=2$) dan untuk tidak memiliki pola musiman maka dilakukan *differencing*. Diagram deret waktu, diagram ACF dan FACF data emisi karbon dioksida hasil *differencing* dengan $d=2$ dapat dilihat pada gambar 4.7 gambar 4.8, dan gambar 4.9 berikut:



Gambar 4.8 Plot Emisi Karbon Dioksida (CO_2) Setelah *Differencing-2*



Gambar 4.9 Plot ACF Data Emisi Karbon Dioksida (CO_2) Setelah *Differencing-2*



Gambar 4.10 Plot ACF Data Emisi Karbon Dioksida (CO_2) Setelah *Differencing-2*

Dari Gambar 4.9 dan 4.10 di atas dapat dilihat bahwa pada plot Analisis Trend data perubahan emsi karbon dioksida tersebut telah sejajar dengan sumbu horizontal. Semua titik pada plot tersebut cenderung menuju ke titik 0. Sedangkan plot Autokorelasi dan Autokorelasi Parsial hasil *differencing* orde 2 pada Gambar

4.6 dan 4.7 telah menunjukkan stasioner dalam mean, sehingga data telah memenuhi syarat kestasioneran dalam varian dan mean. Oleh karena itu bisa langsung digunakan untuk mendapatkan model ARIMA terbaik untuk model preintervensi. Pada diagram ACF Gambar 4.9 terlihat pada lag1 mengalami *tail off*, dan juga pada diagram PACF Gambar 4.10 pada lag 1 lag 2 dan lag 4 mengalami *cuts off*. Hal ini menunjukkan bahwa dugaan model ARIMA untuk sementara yaitu ARIMA (0,2,1) ARIMA (0,2,3), ARIMA (1,2,0), ARIMA (2,2,0), dan ARIMA (4,2,0).

4.2 Pemeriksaan Diagnosa model ARIMA

Untuk tahap pemeriksaan diagnosis masing-masing model ARIMA terdiri dari uji signifikansi parameter dan uji kesesuaian model (distribusi normal). Berikut adalah pemeriksaan diagnosis untuk setiap model ARIMA :

4.2.1 Model ARIMA (0,2,1)

Untuk melakukan estimasi parameter model ARIMA(0,2,1) digunakan *software* Minitab 19, dengan menggunakan analisis *time series* metode ARIMA, adapun estimasi parameter dengan menggunakan ARIMA yaitu :

Final Estimates of Parameters

Type	Coef	SE Coef	T-Value	P-Value
MA 1	0.946	0.218	4.34	0.000
Constant	0.127	0.395	0.32	0.751

Differencing: 2 regular differences

Number of observations: Original series 31, after differencing 29

Residual Sums of Squares

DF	SS	MS
27	4880.51	180.760

Back forecasts excluded

Modified Box-Pierce (Ljung-Box) Chi-Square Statistic

Lag	12	24	36	48
Chi-Square	22.64	25.63	*	*
DF	10	22	*	*
P-Value	0.012	0.268	*	*

Gambar 4.11 Output Minitab 19.

Uji statistik parameter ini digunakan untuk melihat sigifikansi parameter pada model dari data runtun waktu dengan model ARIMA (0,2,1).

Hipotesis:

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

$H_0 : \theta \neq 0$ (parameter ARIMA cukup signifikan dalam model)


Kriteria penolakan H_0 , yaitu jika $p\text{-value} < \alpha$ dengan menggunakan $\alpha = 5\%$ maka berdasarkan estimasi parameter hasil pengolahan data yang ditunjukkan nilai $p\text{-value}$ parameter ARIMA (0,2,1) adalah $p\text{-value} < 0.005$ maka dapat disimpulkan bahwa dalam model ARIMA (0,2,1), parameter θ diterima dan signifikan jadi persamaan modelnya adalah:

$$Z_t = (1 + \phi_1)Z_{t-1} + \phi Z_{t-2} + a_t + \theta_1 a_{t-1}$$

$$Z_t = (1 + 0,946)Z_{t-1} + 0,946Z_{t-2} + a_t + 0,127a_{t-1}$$

Tabel taksiran model menunjukkan besarnya *Mean Square Error* (MSE) model sebesar 180760 dan derajat kebebasan (df) model sebesar 27. Dengan melihat nilai MSE dapat diketahui model mana yang terbaik semakin kecil nilai MSE maka model semakin baik.

Uji normalitas residual model digunakan untuk mendeteksi kenormalan residual model ARIMA (0,2,1). Cara yang dapat dilakukan dengan menggunakan uji *Anderson Darling* pada minitab 19:



Gambar 4.12 Plot Distribusi Normal

Uji distribusi normal digunakan uji *Anderson Darling* $P\text{-value} < 0,05$. Pada gambar di atas menunjukkan bahwa $P\text{-value} < 0,05$ sehingga dapat ditarik kesimpulan bahwa data telah berdistribusi normal.

4.2.2 Model ARIMA (0,2,3)

Untuk melakukan estimasi parameter model ARIMA(0,2,3) digunakan *software* Minitab 19, dengan menggunakan analisis *time series* metode ARIMA, adapun estimasi parameter dengan menggunakan ARIMA yaitu:

Final Estimates of Parameters

Type	Coef	SE Coef	T-Value	P-Value
MA 1	1.037	0.231	4.48	0.000
MA 2	0.420	0.218	1.93	0.066
MA 3	-0.438	0.230	-1.90	0.069
Constant	0.1423	0.0710	2.00	0.056

Differencing: 2 regular differences

Number of observations: Original series 31, after differencing 29

Residual Sums of Squares

DF	SS	MS
25	3879.55	155.182

Back forecasts excluded

Modified Box-Pierce (Ljung-Box) Chi-Square Statistic

Lag	12	24	36	48
Chi-Square	17.98	20.92	*	*
DF	8	20	*	*
P-Value	0.021	0.402	*	*

Gambar 4.13 Output Minitab 19.

Uji statistik parameter ini digunakan untuk melihat signifikansi parameter pada model dari data runtun waktu dengan model ARIMA (0,2,3).

Hipotesis:

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

$H_0 : \theta \neq 0$ (parameter ARIMA cukup signifikan dalam model)


Kriteria penolakan H_0 , yaitu jika $p\text{-value} < \alpha$ dengan menggunakan $\alpha = 5\%$ maka berdasarkan estimasi parameter hasil pengolahan data yang ditunjukkan nilai $p\text{-value}$ parameter ARIMA (0,2,3) adalah $p\text{-value} < 0,005$ maka dapat disimpulkan bahwa dalam model ARIMA (0,2,3), parameter θ diterima dan signifikan dikarenakan $p\text{-value} < \alpha$. jadi persamaan modelnya adalah:

$$Z_t = (1 + \phi_1)Z_{t-1} + \phi Z_{t-2} + a_t + \theta_1 a_{t-1}$$

$$Z_t = (1 + 1,037)Z_{t-1} + 1,037Z_{t-2} + a_t + 0,1423a_{t-1}$$

Tabel taksiran model menunjukan besarnya *Mean Square Error* (MSE) model sebesar 155182 dan derajat kebebasan (df) model sebesar 25. Dengan melihat nilai MSE dapat diketahui model mana yang terbaik semakin kecil nilai MSE maka model semakin baik.

Uji normalitas residual model digunakan untuk melihat kenormalan model ARIMA (0,2,3). Cara yang dapat dilakukan dengan menggunakan uji *Anderson Darling* pada minitab 19 :



Gambar 4.14 Plot Distribusi Normal

Uji distribusi normal digunakan uji *Anderson Darling* $P\text{-value} < 0,05$. Pada gambar di atas menunjukkan bahwa $P\text{-value} < 0,05$ sehingga dapat ditarik kesimpulan bahwa data telah berdistribusi normal.

4.2.3 Model ARIMA (1,2,0)

Untuk melakukan estimasi parameter model ARIMA(1,2,0) digunakan *software* Minitab 19, dengan menggunakan analisis *time series* metode ARIMA, adapun estimasi parameter dengan menggunakan ARIMA yaitu:

Final Estimates of Parameters

Type	Coef	SE Coef	T-Value	P-Value
AR 1	-0.530	0.165	-3.20	0.003
Constant	-0.16	3.36	-0.05	0.963

Differencing: 2 regular differences

Number of observations: Original series 31, after differencing 29

Residual Sums of Squares

DF	SS	MS
27	8836.22	327.267

Back forecasts excluded

Modified Box-Pierce (Ljung-Box) Chi-Square Statistic

Lag	12	24	36	48
Chi-Square	28.36	30.09	*	*
DF	10	22	*	*
P-Value	0.002	0.116	*	*

Gambar 4.15 Output Minitab 19.

Uji statistik parameter ini digunakan untuk melihat signifikansi parameter pada model dari data runtun waktu dengan model ARIMA (1,2,0).

Hipotesis:

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

$H_0 : \theta \neq 0$ (parameter ARIMA cukup signifikan dalam model)


Kriteria penolakan H_0 , yaitu jika $p\text{-value} < \alpha$ dengan menggunakan $\alpha = 5\%$ maka berdasarkan estimasi parameter hasil pengolahan data yang ditunjukkan nilai $p\text{-value}$ parameter ARIMA (1,2,0) adalah $0,003 < 0,05$ maka dapat disimpulkan bahwa dalam model ARIMA (1,2,0) parameter θ diterima signifikan jadi persamaan modelnya adalah:

$$Z_t = (1 + \phi_1)Z_{t-1} + \phi_2 Z_{t-2} + a_t + \theta_1 a_{t-1}$$

$$Z_t = (1 + (-0,530)Z_{t-1} + (-0,530)Z_{t-2} + a_t + (-0,16)a_{t-1}$$

Tabel taksiran model menunjukan besarnya *Mean Square Error* (MSE) model sebesar 327267 dan derajat kebebasan (df) model sebesar 27. Dengan melihat nilai MSE dapat diketahui model mana yang terbaik semakin kecil nilai MSE maka model semakin baik.

Uji normalitas residual model digunakan untuk mendeteksi kenormalan residual model ARIMA (0,2,1). Cara yang dapat dilakukan dengan menggunakan uji *Anderson Darling* pada minitab 19:



Gambar 4.16 Plot Distribusi Normal

Uji distribusi normal digunakan uji *Anderson Darling* $P\text{-value} < 0,05$. Pada gambar di atas menunjukkan bahwa $P\text{-value} < 0,05$ sehingga dapat ditarik kesimpulan bahwa data telah berdistribusi normal.

4.2.4 Model ARIMA (2,2,0)

Untuk melakukan estimasi parameter model ARIMA (2,2,0) digunakan *software* Minitab 19, dengan menggunakan analisis time series metode ARIMA, adapun estimasi parameter dengan menggunakan ARIMA yaitu:

Final Estimates of Parameters

Type	Coef	SE Coef	T-Value	P-Value
AR 1	-0.844	0.155	-5.44	0.000
AR 2	-0.624	0.157	-3.98	0.000
Constant	-0.07	2.70	-0.03	0.979

Differencing: 2 regular differences

Number of observations: Original series 31, after differencing 29

Residual Sums of Squares

DF	SS	MS
26	5515.93	212.151

Back forecasts excluded

Modified Box-Pierce (Ljung-Box) Chi-Square Statistic

Lag	12	24	36	48
Chi-Square	19.85	21.88	*	*
DF	9	21	*	*
P-Value	0.019	0.407	*	*

Gambar 4.17 Output Minitab 19.

Uji statistik parameter ini digunakan untuk melihat signifikansi parameter pada model dari data runtun waktu dengan model ARIMA (2,2,0).

Hipotesis:

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

$H_0 : \theta \neq 0$ (parameter ARIMA cukup signifikan dalam model)


Kriteria penolakan H_0 , yaitu jika $p\text{-value} < \alpha$ dengan menggunakan $\alpha = 5\%$ maka berdasarkan estimasi parameter hasil pengolahan data yang ditunjukkan nilai $p\text{-value}$ parameter ARIMA (2,2,0) adalah $p\text{-value} < 0.005$ maka dapat disimpulkan bahwa dalam model ARIMA (2,2,0) parameter θ diterima dan signifikan jadi persamaan modelnya adalah:

$$Z_t = (1 + \phi_1)Z_{t-1} + \phi Z_{t-2} + a_t + \theta_1 a_{t-1}$$

$$Z_t = (1 + (-0,844)Z_{t-1} + (-0,844)Z_{t-2} + a_t + (-0,07)a_{t-1}$$

Tabel taksiran model menunjukan besarnya Mean Square Error (MSE) model sebesar 212151 dan derajat kebebasan (df) model sebesar 26. Dengan melihat nilai MSE dapat diketahui model mana yang terbaik semakin kecil nilai MSE maka model semakin baik.

Uji normalitas residual model digunakan untuk mendeteksi kenormalan residual model ARIMA (0,2,1). Cara yang dapat dilakukan dengan menggunakan uji *Anderson Darling* pada minitab 19:



Gambar 4.18 Plot Distribusi Normal

Uji distribusi normal digunakan uji *Anderson Darling* $P\text{-value} < 0,05$. Pada gambar di atas menunjukkan bahwa $P\text{-value} < 0,05$ sehingga dapat ditarik kesimpulan bahwa data telah berdistribusi normal.

4.2.5 Model ARIMA (4,2,0)

Untuk melakukan estimasi parameter model ARIMA (4,2,0) digunakan *software* Minitab 19, dengan menggunakan analisis *time series* metode ARIMA, adapun estimasi parameter dengan menggunakan ARIMA yaitu:

Final Estimates of Parameters

Type	Coef	SE Coef	T-Value	P-Value
AR 1	-1.138	0.178	-6.40	0.000
AR 2	-1.266	0.248	-5.10	0.000
AR 3	-0.768	0.249	-3.09	0.005
AR 4	-0.501	0.180	-2.78	0.010
Constant	0.21	2.36	0.09	0.931

Differencing: 2 regular differences

Number of observations: Original series 31, after differencing 29

Residual Sums of Squares

DF	SS	MS
24	3885.25	161.885

Back forecasts excluded

Modified Box-Pierce (Ljung-Box) Chi-Square Statistic

Lag	12	24	36	48
Chi-Square	10.24	13.29	*	*
DF	7	19	*	*
P-Value	0.175	0.823	*	*

Gambar 4.19 Output Minitab 19.

Uji statistik parameter ini digunakan untuk melihat sigifikansi parameter pada model dari data runtun waktu dengan model ARIMA (4,2,0).

Hipotesis:

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

$H_0 : \theta \neq 0$ (parameter ARIMA cukup signifikan dalam model)


Kriteria penolakan H_0 , yaitu jika $p\text{-value} < \alpha$ dengan menggunakan $\alpha = 5\%$ maka berdasarkan estimasi parameter hasil pengolahan data yang ditunjukkan nilai $p\text{-value}$ parameter ARIMA (4,2,0) adalah $p\text{-value} < 0.005$ maka dapat disimpulkan bahwa dalam model ARIMA (4,2,0) parameter θ diterima dan signifikan jadi persamaan modelnya adalah:

$$Z_t = (1 + \phi_1)Z_{t-1} + \phi Z_{t-2} + a_t + \theta_1 a_{t-1}$$

$$Z_t = (1 + (-1,138)Z_{t-1} + (-1,138)Z_{t-2} + a_t + 0,21a_{t-1}$$

Tabel taksiran model menunjukan besarnya *Mean Square Error* (MSE) model sebesar 161885 dan derajat kebebasan (df) model sebesar 24. Dengan melihat nilai MSE dapat diketahui model mana yang terbaik semakin kecil nilai MSE maka model semakin baik.

Uji normalitas residual model digunakan untuk mendeteksi kenormalan residual model ARIMA (4,0,2). Cara yang dapat dilakukan dengan menggunakan uji *Anderson Darling* pada minitab 19:



Gambar 4.20 Plot Distribusi Normal

Uji distribusi normal digunakan uji *Anderson Darling* $P\text{-value} < 0,05$. Pada gambar di atas menunjukkan bahwa $P\text{-value} < 0,05$ sehingga dapat ditarik kesimpulan bahwa data telah berdistribusi normal.

4.3 Kriteria Peilihan Model

Pemilihan model terbaik ARIMA yaitu ARIMA (0,2,3) telah lulus uji signfikan dan uji normalitas dengan *Mean Square Error* (MSE) terendah yaitu 155.182.


4.4 Peramalan

Berikut adalah peramalan efek rumah kaca untuk data *time series* dalam 31 bulan ke depan yaitu:

Tabel. 4.2 Peramalan Konsentrasi (CO_2)

Period	Forecast	Lower	Upper
32	401.441	381.839	421.043
33	394.962	375.088	414.837
34	391.508	371.629	411.387
35	387.279	366.619	407.939
36	381.655	360.792	402.517
37	376.927	356.033	397.821
38	373.122	352.185	394.059
39	369.799	348.743	390.854
40	367.513	346.033	388.992
41	366.573	344.465	388.681
42	366.847	344.036	389.658
43	368.310	344.716	391.905

Period	Forecast	Lower	Upper
44	370.945	346.595	395.296
45	374.553	349.594	399.512
46	378.875	353.489	404.260
47	383.646	358.015	409.277
48	388.560	362.837	414.283
49	393.290	367.558	419.022
50	397.531	371.785	423.278
51	401.013	375.161	426.864
52	403.508	377.399	429.618
53	404.858	378.321	431.394
54	404.977	377.874	432.080
55	403.861	376.118	431.604
56	401.584	373.210	429.959
57	398.297	369.376	427.218
58	394.214	364.885	423.543
59	389.602	360.022	419.182
60	384.761	355.071	414.451
61	380.005	350.294	409.717
62	375.643	345.929	405.357



Gambar 4.21 Plot Hasil Peramalan Emisi Karbon Dioksida

Hasil peramalan dengan menggunakan Minitab 19, menunjukkan penurunan emisi karbon dioksida pada juli 2019 yaitu 405 pmm menjadi 375 dan yang mengalami kenaikan emisi karbon dioksida pada bulan oktober 2018 yaitu 361 menjadi 404. Hasil peramalan yang pertama menunjukkan angka 401, peramalan yang ke dua 394, peramalan yang ke tiga 391, peramalan yang ke empat 387, dan peramalan yang ke lima menunjukkan angka 381. Dari peramalan ini dapat

disimpulkan bahwa peramalan efek rumah kaca mengalami kenaikan dan penurunan yang tidak konstan.

Untuk menanggulangi efek rumah kaca yang ada di Indonesia dengan cara penghijauan lahan dengan cara menanam pohon sebanyak mungkin dan menjaga kelestarian hutan, karena pohon mampu menyerap karbon dioksida yang terbang bebas di udara, membudayakan hemat listrik karena pembangkit listrik saat ini banyak menggunakan bahan bakar fosil yang menghasilkan karbon dioksida, mengelolah sampah dengan baik serta mengurangi alat transportasi yang menggunakan bahan bakar minyak yang banyak menghasilkan karbon dioksida.

BAB V
KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil pembahasan mengenai analisis data *time series* untuk Peramalan efek rumah kaca, maka dapat ditarik kesimpulan sebagai berikut:

1. Model terbaik analisis data *time series* dengan menggunakan model ARIMA yaitu: ARIMA (0,2,3) dengan *Mean Square Error* (MSE) model sebesar 155.182 dan derajat kebebasan (df) model sebesar 25 dan persamaan modelnya adalah:

$$Z_t = (1 + \phi_1)Z_{t-1} + \phi_2 Z_{t-2} + a_t + \theta_1 a_{t-1}$$

$$Z_t = (1 + 1,037)Z_{t-1} + 1,037Z_{t-2} + a_t + 0,1423a_{t-1}$$

2. Berdasarkan hasil peramalan dengan menggunakan *Software Minitab19*, diperoleh hasil peramalan efek rumah kaca untuk 31 bulan kedepan yaitu:

Periode	Prediksi
1	401
2	394
3	391
4	387
5	381
6	376
7	373
8	369
9	367
10	366
11	366
12	368
13	370
14	374
15	378
16	383
17	388
18	393
19	397
20	401
21	403
22	404
23	404

Periode	Prediksi
24	403
25	401
26	398
27	394
28	389
29	384
30	380
31	375

5.2 Saran

Masalah yang dibahas dalam skripsi ini hanya menggunakan model ARIMA pada peramalan efek rumah kaca, oleh karena itu penulis menyarankan untuk penelitian selanjutnya dengan menggunakan metode *time series* yang sebaiknya melanjutkan penelitian dengan menggunakan model intervensi fungsi *step* dan *pulse* agar dapat membedakan lebih jelas bagaimana penggunaan ARIMA dan intervensi *step* dan *pulse* dalam menganalisis pengaruh-pengaruh intervensi yang terjadi di Indonesia.

DAFTAR PUSTAKA

- Andriani, Siska. 2017. *Uji Park Dan Uji Breusch Pangan Dalam Pendeteksian Heteroskedastisitas Pada Analisis Regresi*. Al- Jabar: Jurnal Pendidikan Matematika No.8, hal. 63-72.
- Anonim. 2009. *Pencemaran udara* <http://henlearning.blogspot.com./2009/04/-pencemaranudara.html>[4 Juni 2012].
- Aswi dan Sukarna, 2006.*Analisis Deret Waktu: Teori dan aplikasi*, ed. Muhammad Arif Tiro. Makassar: Andira Publisher.
- Halim, Siana 2006. Diktat: *Time Series Analysis*. Surabaya : Universitas Kristen Petra.
- Hernasari, Yunita. *Metode Time Invariant Fuzzy Time series untuk Peramalan Pendaftaran Calon Mahasiswa*. Skripsi, Medan : Universitas Sumatera Utara.
- Intergovernmental Panel on Climate Change (IPPC, (2007), *Climate Change*, 2007:Assesment Report 4, IPCC, Geneva.
- Istiqomah, Nalar. 2015. *Prediksi Kemunculan Titik Panas Di Provinsi Riau Menggunakan Sensasional Autoregressive Integrated Moving Avverage (SARIMA)*.
- Mendenhal, William dan James E. Reinmuth. 1982. *Statistik untuk Manajemen dan Ekonomi*. Jakarta: Erlangga.
- Riebeek, H.2010. *Global Waming*.Diunduh pada tanggal 31 Maret 2015, <http://earthobservatory.nasa.gov/Features/GlobalWarming/printall.php>.
- Rachmad C. 2007. *Pengurangan Emisi Gas Rumah Kaca Sektor Pertanian*. Jakarta: Departemen Pertanian.
- Reta Ekayati Sari Br. 2014.*Analisis Model Intervensi Fngsi Step Untuk Peamalan Kebaikan Tarif Dasar Listrik (TDL) Terhadap Besarnya Pemakaian Listrik*.Vol.03, No.3, hal.176.-177.
- Rosadi, Dedi. 2011. *Analisis Ekonometrika & Runtun Waktu Terapan dengan R Aplikasi untuk Bidang Ekonomi, Bisnis, & Keuangan*. Yogyakarta: Penerbit Andi.
- Samsiah, Dewi. 2008.*Analisis Data Runtun Waktu Menggunakan Model ARIMA (p,d,q)*. Skripsi UIN Sunan Kalijaga hal. 1-80.

- Smart Click.2011. *Didalam Buku Praktek Lingkungan Hidup* Oleh Dr.Ir.H. Ali Hanapiah Muhi, MP. Institut Pemerintah Dalam Negri (IPDN), Jatinangor, Jawa Barat.
- Soejati, Zanzawi,Ph D. 1987. *Buku Materi Pokok Analisis Runtun Waktu: Modul 1-9 STAT4532*.(Jakarta: Kurnika, Universtas Terbuka) hal. 24.
- Suhartono & Nuvtasari. 2007. *Evaluasi Dampak Krisis Moneter, Bom Bali I dan II terhadap Jumlah Kunjungan Wisatawan ke Bali dengan Model Intervensi Multi Input. Jurnal Ilmiah MatStat.*
- Sugiono A. 2006. *Penanggulangan Pemanasan Global Disektor Pengguna Energi. Jurnal Sains & Teknologi Modif Cuaca*No.7, hal.15-19.
- Santoso & Singgih. 2009. *Bussiness Forecasting*. Penerbit-Elex Media Komputindo.
- Thalbah, Hisnam. 2010. *Ensiklopedia Mukjizat Al-Quran dan Hadist Jilid 8 Jakarta : PT Sapta Sentosa.*
- Wei, W.S. 2006.*Time Series Analysis: Univariate and Multivariate 2nd Edition*. New Jersey: Pearson Education.
- Wibowo, Yudi, dkk. 2012. *Analisis Data Runtun Waktu Menggunakan Metode Wafalet Theresholding.Gussian1*, No. 1, hal. 249-258.
- Wiyanti & R pulungan.*Peramalan Deret Waktu Menggunakan Model Fungsi Basis Radial (RBF) & Autoregressive Integrated Moving Average (ARIMA)*. Jurnal MIPA, vol. 35, No. 2.
- Yanto, S. 2007. *Akutansi Hijau: Sarana Pendeteksi Dini Bencana Lingkungan Akuntan Indonesia* No. 3, hal.23

LAMPIRAN

Lampiran 1. Data Awal

No	Waktu	CO2
1	Januari 2017	396
2	Februari 2017	397
3	Maret 2017	403
4	April 2017	398
5	Mei 2017	397
6	Juni 2017	394
7	Juli 2017	390
8	Agustus 2017	391
9	September 2017	393
10	Oktober 2017	392
11	November 2017	395
12	Desember 2017	391
13	Januari 2018	360
14	Februari 2018	361
15	Maret 2018	371
16	April 2018	376
17	Mei 2018	363
18	Juni 2018	372
19	Juli 2018	362
20	Agustus 2018	390
21	September 2018	395
22	Oktober 2018	361
23	November 2018	390
24	Desember 2018	395
25	Januari 2019	391
26	Februari 2019	400
27	Maret 2019	401
28	April 2019	403
29	Mei 2019	410
30	Juni 2019	400
31	Juli 2019	405

Lampiran 2. *Output* SPSS Estimasi plot ACF

Autocorrelations

Series: CO2

Lag	Autocorrelation	Std. Error ^a	Box-Ljung Statistic		
			Value	df	Sig. ^b
1	.616	.171	12.923	1	.000
2	.465	.168	20.555	2	.000
3	.461	.165	28.323	3	.000
4	.300	.162	31.729	4	.000
5	.232	.159	33.855	5	.000
6	.052	.156	33.965	6	.000
7	-.154	.153	34.970	7	.000
8	-.133	.150	35.758	8	.000
9	-.207	.147	37.744	9	.000
10	-.378	.143	44.715	10	.000
11	-.445	.140	54.845	11	.000
12	-.488	.136	67.674	12	.000
13	-.443	.133	78.831	13	.000
14	-.410	.129	88.944	14	.000
15	-.317	.125	95.370	15	.000
16	-.281	.121	100.772	16	.000

a. The underlying process assumed is independence (white noise).

b. Based on the asymptotic chi-square approximation.

Lampiran 3. *Output* SPSS Estimasi plot PACF

Partial Autocorrelations

Series: CO2

Lag	Partial Autocorrelation	Std. Error
1	.616	.180
2	.139	.180
3	.212	.180
4	-.127	.180
5	.018	.180
6	-.268	.180
7	-.250	.180
8	.041	.180
9	-.051	.180
10	-.204	.180
11	-.173	.180
12	-.117	.180
13	.001	.180
14	-.050	.180
15	.212	.180
16	-.063	.180

Lampiran 4. *Output SPSS Estimasi Plot ACF differencing-1*

Autocorrelations

Series: CO2

Lag	Autocorrelation	Std. Error ^a	Box-Ljung Statistic		
			Value	df	Sig. ^b
1	-.310	.174	3.183	1	.074
2	-.250	.171	5.319	2	.070
3	.252	.168	7.568	3	.056
4	-.122	.165	8.122	4	.087
5	.166	.161	9.175	5	.102
6	.073	.158	9.387	6	.153
7	-.331	.155	13.955	7	.052
8	.146	.151	14.880	8	.062
9	.243	.148	17.574	9	.040
10	-.272	.144	21.116	10	.020
11	-.009	.141	21.120	11	.032
12	.026	.137	21.156	12	.048
13	-.021	.133	21.182	13	.069
14	-.067	.129	21.454	14	.091
15	.025	.125	21.496	15	.122
16	-.088	.121	22.021	16	.143

a. The underlying process assumed is independence (white noise).

b. Based on the asymptotic chi-square approximation.

Lampiran 5. *Output SPSS Estimasi Plot PACF differencing-1*

Partial Autocorrelations

Series: CO2

Lag	Partial Autocorrelation	Std. Error
1	-.310	.183
2	-.383	.183
3	.034	.183
4	-.129	.183
5	.231	.183
6	.181	.183
7	-.151	.183
8	-.062	.183
9	.168	.183
10	-.081	.183
11	-.105	.183
12	-.107	.183
13	-.005	.183
14	-.309	.183
15	-.030	.183
16	-.048	.183

Lampiran 6. *Output SPSS Estimasi Plot ACF differencing-2*

Autocorrelations

Series: CO2

Lag	Autocorrelation	Std. Error ^a	Box-Ljung Statistic		
			Value	df	Sig. ^b
1	-.518	.176	8.628	1	.003
2	-.175	.173	9.643	2	.008
3	.336	.170	13.553	3	.004
4	-.253	.167	15.849	4	.003
5	.142	.163	16.609	5	.005
6	.124	.160	17.207	6	.009
7	-.340	.156	21.932	7	.003
8	.136	.153	22.719	8	.004
9	.258	.149	25.719	9	.002
10	-.312	.145	30.323	10	.001
11	.079	.141	30.635	11	.001
12	.044	.138	30.739	12	.002
13	-.008	.133	30.743	13	.004
14	-.044	.129	30.860	14	.006
15	.073	.125	31.198	15	.008
16	-.110	.120	32.036	16	.010

a. *The underlying process assumed is independence (white noise).*

b. *Based on the asymptotic chi-square approximation.*

Lampiran 7. *Output SPSS Estimasi Plot PACF Differencing-2*

Partial Autocorrelations

Series: CO2

Lag	Partial Autocorrelation	Std. Error
1	-.518	.186
2	-.606	.186
3	-.267	.186
4	-.468	.186
5	-.304	.186
6	.039	.186
7	-.080	.186
8	-.306	.186
9	-.016	.186
10	.001	.186
11	-.009	.186
12	-.119	.186
13	.168	.186
14	-.141	.186
15	-.116	.186
16	-.169	.186

Lampiran 8. *Output* Minitab 19 Model ARIMA (0,2,1)

Estimates at Each Iteration

Iteration	SSE	Parameters
0	10997.8	0.100 0.238
1	9453.1	0.250 0.110
2	8146.7	0.400 0.033
3	7037.2	0.550 -0.002
4	6099.0	0.700 0.004
5	5310.1	0.850 0.053
6	4963.5	0.925 0.096
7	4906.1	0.947 0.123
8	4906.1	0.947 0.125
9	4906.1	0.946 0.126
10	4906.1	0.946 0.126
11	4906.1	0.946 0.127

Relative change in each estimate less than 0.001

Final Estimates of Parameters

Type	Coef	SE	Coef T-Value	P-Value
MA 1	0.946	0.218	4.34	0.000
Constant	0.127	0.395	0.32	0.751

Residual Sums of Squares

DF	SS	MS
27	4880.51	180.760

Back forecasts excluded

Modified Box-Pierce (Ljung-Box) Chi-Square Statistic

Lag	12	24	36	48
Chi-Square	22.64	25.63	*	*
DF	10	22	*	*
P-Value	0.012	0.268	*	*

Lampiran 9. *Output* Minitab 19 Model ARIMA (0,2,3)

Estimates at Each Iteration

Iteration	SSE	Parameters			
0	11411.3	0.100	0.100	0.100	0.238
1	9664.7	0.250	0.222	0.135	0.133
2	8185.9	0.400	0.330	0.149	0.120
3	7171.2	0.550	0.415	0.133	0.138
4	5656.3	0.700	0.400	-0.017	0.118
5	4706.0	0.849	0.369	-0.167	0.114
6	4288.5	0.947	0.374	-0.242	0.088
7	4228.4	0.949	0.374	-0.247	0.087
8	4225.0	0.953	0.375	-0.252	0.085
9	4207.9	0.956	0.377	-0.256	0.083
10	4190.5	0.959	0.379	-0.259	0.081
11	4178.2	0.960	0.381	-0.262	0.080
12	4169.3	0.962	0.382	-0.264	0.079
13	4162.3	0.963	0.383	-0.266	0.079
14	4160.9	0.965	0.393	-0.279	0.078
15	4153.1	0.964	0.442	-0.312	0.058
16	4112.6	0.967	0.440	-0.370	0.127
17	4044.2	1.005	0.407	-0.433	0.169
18	3941.8	1.028	0.407	-0.433	0.176
19	3918.9	1.038	0.404	-0.443	0.170
20	3910.1	1.040	0.409	-0.439	0.168
21	3905.6	1.040	0.408	-0.444	0.165
22	3900.9	1.041	0.411	-0.442	0.162
23	3900.0	1.040	0.413	-0.443	0.156
24	3897.5	1.039	0.418	-0.439	0.148
25	3897.1	1.037	0.420	-0.438	0.142

*** Convergence criterion not met after 25 iterations ***

Final Estimates of Parameters

Type	Coef	SE Coef	T-Value	P-Value
MA 1	1.037	0.231	4.48	0.000
MA 2	0.420	0.218	1.93	0.066
MA 3	-0.438	0.230	-1.90	0.069
Constant	0.1423	0.0710	2.00	0.056

Residual Sums of Squares

DF	SS	MS
25	3879.55	155.182

Back forecasts excluded

Modified Box-Pierce (Ljung-Box) Chi-Square Statistic

Lag	12	24	36	48
Chi-Square	17.98	20.92	*	*
DF	8	20	*	*
P-Value	0.021	0.402	*	*

Lampiran 10. *Output* Minitab 19 Model ARIMA (1,2,0)

Estimates at Each Iteration

Iteration	SSE	Parameters
0	13570.3	0.100 0.214
1	11585.5	-0.050 0.141
2	10137.5	-0.200 0.061
3	9226.3	-0.350 -0.026
4	8851.9	-0.500 -0.126
5	8841.5	-0.528 -0.153
6	8841.5	-0.530 -0.158
7	8841.5	-0.530 -0.158
8	8841.5	-0.530 -0.158

Relative change in each estimate less than 0.001

Final Estimates of Parameters

Type	Coef	SE Coef	T-Value	P-Value
AR 1	-0.530	0.165	-3.20	0.003
Constant	-0.16	3.36	-0.05	0.963

Residual Sums of Squares

DF	SS	MS
27	8836.22	327.267

Back forecasts excluded

Modified Box-Pierce (Ljung-Box) Chi-Square Statistic

Lag	12	24	36	48
Chi-Square	28.36	30.09	*	*
DF	10	22	*	*
P-Value	0.002	0.116	*	*

Lampiran 11. *Output* Minitab 19 Model ARIMA (2,2,0)

Estimates at Each Iteration

Iteration	SSE	Parameters		
0	13991.1	0.100	0.100	0.190
1	11521.0	-0.050	-0.014	0.121
2	9475.2	-0.200	-0.128	0.071
3	7854.3	-0.350	-0.242	0.029
4	6658.8	-0.500	-0.357	-0.007
5	5889.4	-0.650	-0.472	-0.040
6	5547.5	-0.800	-0.588	-0.069
7	5528.7	-0.841	-0.622	-0.074
8	5528.6	-0.844	-0.624	-0.074
9	5528.6	-0.844	-0.624	-0.074
10	5528.6	-0.844	-0.624	-0.074

Relative change in each estimate less than 0.001

Final Estimates of Parameters

Type	Coef	SE Coef	T-Value	P-Value
AR 1	-0.844	0.155	-5.44	0.000
AR 2	-0.624	0.157	-3.98	0.000
Constant	-0.07	2.70	-0.03	0.979

Residual Sums of Squares

DF	SS	MS
26	5515.93	212.151

Back forecasts excluded

Modified Box-Pierce (Ljung-Box) Chi-Square Statistic

Lag	12	24	36	48
Chi-Square	19.85	21.88	*	*
DF	9	21	*	*
P-Value	0.019	0.407	*	*

Lampiran 12. *Output* Minitab 19 Model ARIMA (4,2,0)

Estimates at Each Iteration

Iteration	SSE	Parameters				
0	13774.7	0.100	0.100	0.100	0.100	0.143
1	11684.3	-0.039	-0.050	0.006	0.035	0.023
2	9858.9	-0.177	-0.200	-0.089	-0.030	0.012
3	8281.6	-0.315	-0.350	-0.184	-0.095	0.020
4	6950.1	-0.452	-0.500	-0.279	-0.160	0.036
5	5862.9	-0.589	-0.650	-0.375	-0.226	0.058
6	5018.3	-0.725	-0.800	-0.471	-0.293	0.085
7	4414.0	-0.860	-0.950	-0.566	-0.359	0.116
8	4046.7	-0.994	-1.100	-0.662	-0.426	0.152
9	3911.3	-1.126	-1.250	-0.758	-0.493	0.196
10	3910.2	-1.137	-1.265	-0.767	-0.500	0.205
11	3910.2	-1.138	-1.266	-0.768	-0.501	0.207
12	3910.2	-1.138	-1.266	-0.768	-0.501	0.207

Relative change in each estimate less than 0.001

Final Estimates of Parameters

Type	Coef	SE	Coef	T-Value	P-Value
AR 1	-1.138	0.178	-6.40	0.000	
AR 2	-1.266	0.248	-5.10	0.000	
AR 3	-0.768	0.249	-3.09	0.005	
AR 4	-0.501	0.180	-2.78	0.010	
Constant	0.21	2.36	0.09	0.931	

Residual Sums of Squares

DF	SS	MS
24	3885.25	161.885

Back forecasts excluded

Modified Box-Pierce (Ljung-Box) Chi-Square Statistic

Lag	12	24	36	48
Chi-Square	10.24	13.29	*	*
DF	7	19	*	*
P-Value	0.175	0.823	*	*