



TUGAS AKHIR - SS 091324

**PERAMALAN BAHAN MENTAH KARET DI WILAYAH
JAWA TIMUR MENGGUNAKAN METODE REGRESI *TIME
SERIES* DAN ARIMA**

**RIDZWAN ABU YAZID AL BUSTANI
NRP 1311 030 036**

**Dosen Pembimbing
Prof. Drs. Nur Iriawan, M.Ikom, Ph.D**

**JURUSAN STATISTIKA
Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember
Surabaya 2013**



FINAL PROJECT - SS 091324

FORCASTING RUBBER RAW MATERIAL IN EAST JAVA WITH TIME SERIES REGRESSION METHOD AND ARIMA

RIDZWAN ABU YAZID AL BUSTANI
NRP 1311 030 036

Supervisor
Prof. Drs. Nur Iriawan, M.Ikom, Ph.D

DEPARTMENT OF STATISTICS
Faculty of Mathematics and Natural Sciences
Sepuluh Nopember Institute Of Technology
Surabaya 2013

PERAMALAN BAHAN MENTAH KARET DI WILAYAH JAWA TIMUR MENGGUNAKAN METODE REGRESI *TIME SERIES* DAN ARIMA

Nama Mahasiswa : Ridzwan Abu Yazid Al Bustani
NRP : 1311 030 036
Program Studi : Diploma III
Jurusan : Statistika FMIPA-ITS
Dosen Pembimbing : Prof. Drs. Nur Iriawan, M.Ikom, Ph.D

Abstrak

Karet merupakan polimer hidrokarbon yang terbentuk dari emulsi kesesuain (dikenal sebagai latex) yang diperoleh dari getah beberapa jenis tumbuhan karet tetapi dapat juga diproduksi secara sintesis. Produksi karet di Jawa Timur hanya memproduksi sebagian kecil produksi karet di Indonesia, maka perlu adanya peningkatan produksi di Jawa Timur. Setiap kebutuhan manusia di dunia banyak menggunakan karet misalnya alas kaki, alat rumah tangga, sparepart kendaraan dan lain-lain. Data yang digunakan dalam penelitian ini merupakan data sekunder yang diperoleh dari PT Perkebunan Nusantara XII (PTPN XII) Surabaya mulai tahun 2012 sampai 2014. Dari hasil analisis ARIMA diperoleh model terbaik ARIMA (0,1,1) dengan memperhatikan proses data Outlier. Untuk model regression time series menghasilkan parameter yang signifikan dan memenuhi asumsi IIDN dengan $R_{sq}(\text{adj})$ 81,1%. Sedangkan untuk model terbaik antara ARIMA dan Regression Time Series adalah metode Regression Time Series karena memiliki nilai error yang terkecil.

Kata kunci : Karet, ARIMA, Regression Time Series

FORECASTING RUBBER RAW MATERIALS IN THE REGION OF EAST JAVA USING REGRESSION METHODS AND ARIMA TIME SERIES

Name of Student : Ridzwan Abu Yazid Al Bustani
NRP : 1311 030 036
Study Program : Diploma III
Department : Statistics FMIPA-ITS
Supervisor : Prof. Drs. Nur Iriawan, M.Ikom, Ph.D

Abstract

Rubber is a hydrocarbon polymer formed by specific emulsion (known as latex) that is obtained from the sap of several types of rubber plants but it can also be produced synthetically. Rubber production in East Java is produced only a small fraction of rubber production in Indonesia. It would be increased in the future. Every human in the world needs a lot of this material, for example rubber footwear, household appliances, vehicle spare parts and another. The data used in this study is a secondary data obtained from PT PTPN XII Surabaya from 2012 to 2014. ARIMA analysis of the results obtained by the best model ARIMA (0,1,1) with outlier. For the second model, regression time series produce significant parameters and can fulfill the assumptions of IIDN with R^2 (adj) 81.1%. Comparing between ARIMA and Regression Time series, Regression Time series shows as the best model because it has the smallest value error.

Keywords : *Rubber, ARIMA, Regression Time Series*

LEMBAR PENGESAHAN

PERAMALAN BAHAN MENTAH KARET DI WILAYAH JAWA TIMUR MENGGUNAKAN METODE REGRESI *TIME SERIES* DAN ARIMA

TUGAS AKHIR

Diajukan untuk Memenuhi Syarat
Memperoleh Gelar Ahli Madya
Pada

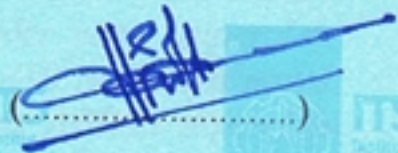
Program Studi Diploma III Jurusan Statistika
Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember

Oleh :

RIDZWAN ABU YAZID AL BUSTANI
NRP. 1311 030 036

Disetujui oleh Pembimbing Tugas Akhir :

Prof. Drs. Nur Iriawan, M.Ikom, Ph.D
NIP. 19621015 198803 1 002



Mengetahui
Ketua Jurusan Statistika FMIPA-ITS



Dr. Muhammad Mashuri, MT
NIP. 19621108 198701 1 001

SURABAYA, Juli 2014

KATA PENGANTAR

Puji syukur alhamdulillah atas kehadiran Allah SWT yang telah melimpahkan rahmat dan hidayah-Nya, sehingga penulis dapat menyelesaikan Tugas Akhir yang berjudul **”Peramalan Bahan Mentah Karet Di Wilayah Jawa Timur Menggunakan Metode *Regression Time Series* Dan ARIMA”** sesuai dengan waktu yang telah ditentukan. Tugas Akhir ini dapat terselesaikan dengan baik tidak terlepas dari dukungan, doa serta semangat yang diberikan oleh berbagai pihak pada penulis. Pada kesempatan ini penulis mengucapkan terima kasih kepada:

1. Bapak Prof. Drs. Nur Iriawan, M.Ikom, Ph.D selaku dosen pembimbing yang selama ini sudah banyak bersabar dan memberi semangat, bimbingan, ilmu, motivasi, kritik dan saran kepada penulis untuk kesempurnaan Tugas Akhir ini.
2. Bapak Dr. Brodjol Sutijo Suprih Ulama, M.Si dan ibu Dr. Irhamah, M.Si selaku dosen penguji yang telah memberi banyak saran dan kritik untuk kesempurnaan Tugas Akhir ini
3. Bapak Dr. Muhammad Mashuri, MT selaku Ketua Jurusan Statistika ITS
4. Ibu Dra. Sri Mumpuni Retnaningsih, MT selaku Ketua Program Studi Diploma III Jurusan Statistika yang telah banyak membantu dan memberi motivasi serta doa demi kelancaran dan terselesaikannya Tugas Akhir ini dengan sempurna.
5. Terima kasih kepada kedua orang tua saya yang selalu memberi banyak dukungan dan doa untuk kelancaran dan kesuksesan penulis, Mbak Diana dan seluruh keluarga besar yang selalu mendukung dan memberi semangat dalam pengerjaan Tugas Akhir.
6. Terima kasih kepada PT Perkebunan Nusantara XII (PTPN XII) Surabaya yang telah bersedia membantu dalam mendapatkan data untuk Tugas Akhir.

7. Teman-teman Laboratorium Komputasi yang saling memberi pembelajaran, pengetahuan baru, dan motivasi dalam menyelesaikan Tugas Akhir
8. Teman-teman DIII B terima kasih atas kekompakan dalam perkuliahan maupun lainnya.
9. Keluarga sigma 22 selalu sukses untuk semua.
10. Pihak-pihak yang sudah banyak membantu penulis dalam proses pengerjaan Tugas Akhir yang tidak dapat penulis sebutkan satu per satu.

Penulis sangat berharap hasil Tugas Akhir ini dapat memberikan manfaat bagi pembaca dan dibutuhkan kritik serta saran dalam penelitian-penelitian selanjutnya. Penulis menyadari bahwa Tugas Akhir ini belum menjadi sempurna karena sempurna hanya milik Allah SWT.

Surabaya, Juli 2014

Penulis

DAFTAR ISI

	halaman
HALAMAN JUDUL	i
LEMBAR PENGESAHAN	iii
ABSTRAK	v
ABSTRACT	vii
KATA PENGANTAR	ix
DAFTAR ISI	xi
DAFTAR GAMBAR	xiii
DAFTAR TABEL	xv
DAFTAR LAMPIRAN	xvii
BAB I PENDAHULUAN	
1.1 Latar Belakang	1
1.2 Rumusan Masalah	2
1.3 Tujuan Penelitian	3
1.4 Manfaat Penelitian	3
1.5 Batasan Masalah	3
BAB II TINJAUAN PUSTAKA	
2.1 Model <i>Time Series Regression</i>	5
2.1.1 Model Regresi <i>Trend</i>	5
2.1.2 Model Regresi <i>Seasonal</i>	6
2.1.3 Model Regresi <i>Trend</i> dan <i>Seasonal</i>	7
2.1.4 Uji Signifikansi Parameter Regresi	8
2.2 Pengujian Asumsi Residual	8
2.2.1 Pengujian Asumsi Residual Identik	9
2.2.2 Pengujian Asumsi Residual Independen	9
2.2.3 Pengujian Asumsi Residual Distribusi Normal	9
2.3 Analisis <i>Time Series</i>	10
2.3.1 Stasioneritas	10
2.3.2 Fungsi Autokorelasi	11
2.3.3 Model ARIMA	11
2.3.4 Deteksi <i>Outlier</i>	15

2.3.5	Pemilihan Model Terbaik	16
2.4	Deskriptif Karet	18
BAB III METODOLOGI PENELITIAN		
3.1	Sumber Data dan Variabel Penelitian	19
3.2	Metode Analisis	20
3.3	Diagram Alir	21
BAB IV ANALISIS DAN PEMBAHASAN		
4.1	Statistika Deskriptif	25
4.2	Pemodelan Produksi Karet Menggunakan Metode ARIMA	27
4.2.1	Identifikasi Produksi Karet Di Jawa Timur	27
4.2.2	Pendugaan Model Produksi Karet Di Jawa Timur	30
4.3	Regresi Runtun Waktu	34
4.4	Pemilihan Model Terbaik dan Peramalan Produksi	39
BAB V KESIMPULAN DAN SARAN		
5.1	Kesimpulan	41
5.2	Saran	41
DAFTAR PUSTAKA		
LAMPIRAN		
BIODATA PENULIS		

DAFTAR GAMBAR

	halaman
Gambar 2.1 Ilustrasi Grafik yang Menunjukkan <i>Trend</i>	5
Gambar 2.2 Ilustrasi Grafik yang Menunjukkan <i>Seasonal</i>	6
Gambar 2.3 Ilustrasi Grafik yang Menunjukkan <i>Trend dan Seasonal</i>	7
Gambar 3.1 Diagram Alir	21
Gambar 4.1 <i>Box Plot</i> Produksi Karet di Jawa Timur	26
Gambar 4.2 <i>Box Plot</i> Produksi Karet di Jawa Timur tahun 2013 dan 2013	27
Gambar 4.3 <i>Time Series Plot</i> Data Produksi Karet	28
Gambar 4.4 <i>Box-cox Plot</i> Data Produksi Karet di Jawa Timur	28
Gambar 4.5 <i>Autocorelation Function</i> Data Produksi Karet di Jawa Timur	29
Gambar 4.6 <i>Time Serie Plot</i> Data <i>Differencing</i>	30
Gambar 4.7 <i>Autocorelation Function</i> Data <i>Differncing</i> Produksi Karet di Jawa Timur	30
Gambar 4.8 <i>Partial Autocorelation Function</i> Data <i>Differncing</i> Produksi Karet di Jawa Timur	31
Gambar 4.9 Plot ACF Residual Produksi Karet di Jawa Timur	35
Gambar 4.10 Plot Distribusi Normal Produksi Karet di Jawa Timur	36
Gambar 4.11 Plot ACF Residual Produksi Karet di Jawa Timur Setelah Dimasukkan <i>Outlier</i>	38

Gambar 4.12 Plot Distribusi Normal Produksi Karet di Jawa Timur Setelah Memasukkan *Outlier* 38

DAFTAR TABEL

	halaman	
Tabel 2.1	Teoritik ACF Dan PACF Dari Proses Yang Stasioner	12
Tabel 3.1	Struktur Data	19
Tabel 4.1	Statistika Deskriptif Produksi Karet Di Jawa Timur	25
Tabel 4.2	Statistika Deskriptif Produksi Karet di Jawa Timur Tahun 2012 dan 2013	26
Tabel 4.3	Estimasi Parameter Model ARIMA	32
Tabel 4.4	Deteksi <i>Outlier</i> Model ARIMA	32
Tabel 4.5	Estimasi Parameter Model ARIMA	33
Tabel 4.6	Kriteria Kebaikan Model ARIMA	33
Tabel 4.7	Uji Glejser Produksi Karet di Jawa Timur	35
Tabel 4.8	Deteksi <i>Outlier</i> Produksi Karet di Jawa Timur	36
Tabel 4.9	Uji Glejser Produksi Karet di Jawa Timur Setelah Memasukkan <i>Outlier</i>	37
Tabel 4.10	Pemilihan Model Terbaik	39
Tabel 4.11	Peramalan Data Produksi Karet 11 Minggu Ke Depan	40

“Halaman Ini Sengaja Dikosongkan”

BAB I

PENDAHULUAN

1.1 Latar Belakang

Karet merupakan polimer hidrokarbon yang terbentuk dari emulsi kesesuain (dikenal sebagai latex) yang diperoleh dari getah beberapa jenis tumbuhan karet tetapi dapat juga diproduksi secara sintesis. Sumber utama dari latex yang di gunakan untuk menciptakan karet adalah pohon karet *Hevea brasiliensis* (Euphorbiaceae). Menghasilkan getah karet dapat dilakukan dengan cara melukai kulit pohon sehingga pohon akan memberikan respon yang menghasilkan lebih banyak latex (Wikipedia, 2014). Menurut Setiawan (2005) tanaman karet merupakan pohon yang tumbuh tinggi dan berbatang cukup besar. Pohon dewasa mencapai tinggi antara 15 -30 m. Akarnya cukup kuat serta akar tunggangnya dalam akar cabang yang kokoh. Pohon tumbuh lurus dan memiliki percabangan yang tinggi diatas.

Karet mempunyai warna putih hingga kuning kecoklatan, ban mobil berwarna hitam karena karbon yang berallotrop dengan karbon hitam ditambahkan untuk memperkuat polimer. Bila sepotong vulkanisir karet yang berikatan silang seperti pita karet diulur kemudian dilepas maka ikatan silang itu akan menarik rantai-rantai polimer kembali ke bentuk semula. Tanpa proses vulkanisasi, rantai-rantai polimer akan meluncur lepas ke satu monomer yang lainnya. Karet alam adalah jenis karet pertama yang dibuat sepatu. Sesudah penemuan proses vulkanisasi oleh Charles Goodyear yang membuat karet menjadi tahan terhadap cuaca dan tidak larut dalam minyak, maka karet mulai digemari sebagai bahan dasar dalam pembuatan berbagai macam alat untuk keperluan dalam rumah ataupun pemakaian di luar rumah seperti sol sepatu dan bahkan sepatu yang semuanya terbuat dari bahan karet. Karet alam sangat mudah dilengketkan satu sama lain sehingga sangat disukai dalam pembuatan barang-barang yang perlu dilapisi sebelum vulkanisasi dilakukan. Keunggulan daya lengket inilah yang menyebabkan karet alam sulit disaingi oleh

karet sintetik dalam pembuatan karkas untuk ban radial ataupun dalam pembuatan sol karet yang sepatunya diproduksi dengan cara vulkanisasi langsung. (Nazaruddin dan Paimin, 2006)

Produksi karet di Propinsi Jawa Timur sebesar 24.551 ton pada tahun 2008, 22.315 ton pada tahun 2009, 23.577 ton pada tahun 2010, 26.754 ton pada tahun 2011, dan 28.146 ton pada tahun 2012 dengan laju pertumbuhan sebesar 5,20%. (Direktorat Jendral Perkebunan, 2013). Menurut direktorat jendral perkebunan, produksi karet di Jawa Timur hanya memproduksi sebagian kecil produksi karet di Indonesia, maka perlu adanya peningkatan produksi di Jawa Timur dan Jawa adalah salah satu pulau di Indonesia yang menggunakan bahan karet sebagai alat utama untuk memproduksi barang. Penelitian ini dilakukan karena karet adalah kebutuhan sehari-hari bagi manusia. Pada penelitian Agus, dkk (2013) yang berjudul Analisis Peramalan Produksi Karet di PT Perkebunan Nusantara IX (Persero) Batujamus Kabupaten Karanganyar menyebutkan bahwa peramalan produksi tahun 2012 sampai 2013 cenderung meningkat dari tahun ketahun dengan tingkat kesalahan peramalan kecil. Setiap kebutuhan manusia banyak menggunakan karet misalnya alas kaki, alat rumah tangga, *sparpart* kendaraan dan lain-lain. Indonesia merupakan salah satu penghasil karet terbesar di dunia. Dengan penghasilan mencapai 2.982.000 ton di tahun 2011 indonesia menduduki posisi ke 2 di dunia penghasil karet terbesar (Direktorat Jendral Perkebunan, 2013). Penelitian Erni (2011) menjelaskan bahwa indonesia merupakan penghasil karet spesifikasi teknis terbesar di dunia, dengan nilai ekspor mencapain 92 % dari total ekspor karet alam indonesia. Permintaan dunia meningkat sejalan dengan pertumbuhan industri.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah dibahas diatas, maka permasalahan yang diangkat dalam penelitian ini adalah.

1. Bagaimana model yang sesuai untuk meramal data produksi bahan mentah karet tingkat perkebunan di wilayah Jawa Timur menggunakan metode ARIMA ?
2. Bagaimana model yang sesuai untuk meramal data produksi bahan mentah karet tingkat perkebunan di wilayah Jawa Timur menggunakan metode *Regression Time series* ?
3. Bagaimana pemilihan model terbaik antara metode ARIMA dan *Regression Time Series* ?

1.3 Tujuan Penelitian

Tujuan yang ingin dicapai dari penelitian ini adalah.

1. Mendapatkan model dan peramalan data produksi bahan mentah karet tingkat perkebunan di wilayah Jawa Timur menggunakan metode ARIMA.
2. Mendapatkan model dan peramalan data produksi bahan mentah karet tingkat perkebunan di wilayah Jawa Timur menggunakan metode *Regression Time Series*.
3. Mendapatkan model terbaik antara metode ARIMA dan *Regression Time Series*.

1.4 Manfaat Penelitian

Manfaat yang ingin diperoleh dalam penelitian ini adalah untuk memberikan informasi mengenai peramalan bahan mentah karet di wilayah Jawa Timur, sehingga dapat menjadi acuan dalam menentukan kebijakan bagi instansi tertentu yang membutuhkan informasi ini dan untuk mengembangkan wawasan statistika khususnya pemodelan *Regression Time Series* dan ARIMA.

1.5 Batasan Masalah

Penelitian dalam tugas akhir ini dibatasi di wilayah Jawa Timur tahun 2003-2013 dan produksi karet hanya melibatkan hasil produksi bahan mentah karet tanpa melibatkan variabel lain yang mempengaruhi.

“Halaman Ini Sengaja Dikosongkan”

BAB II TINJAUAN PUSTAKA

2.1 Model *Time Series Regression*

Time series regression merupakan model yang digunakan untuk tujuan peramalan dimana variabel dependen (y_t) dan variabel prediktor merupakan deretan waktu. Model *time series regression* sebagaimana tertulis pada Bowerman dan O'Connell (1993) adalah :


$$Z_t = T_t + S_t + \varepsilon_t \quad (2.1)$$

dengan

- Z_t : Nilai observasi pada periode t
- T_t : Komponen trend pada periode t
- S_t : Komponen musiman pada periode t
- ε_t : Komponen galat pada periode t

2.1.1 Model Regresi *Trend*

Model Regresi linier *Trend* adalah Pemodelan regresi yang menunjukkan pola data semakin naik atau turun jika dilihat pada plot *Time Series*.



Gambar 2.1 Ilustrasi Grafik yang Menunjukkan *Trend*

Menurut Cryer (1986) model regresi linier *trend* dapat dituliskan sebagai berikut:

$$Z_t = \beta_0 + \beta_1 t + a_t \quad (2.2)$$

dengan

Z_t : Data pengamatan yang berderet waktu

β_0 : Parameter constant

β_1 : Parameter indeks waktu

t : Indeks waktu

a_t : Nilai Eror

$$\hat{Z}_t = \hat{\beta}_0 + \hat{\beta}_1 t \quad (2.3)$$

dengan

\hat{Z}_t : Nilai dugaan dari Z_t


$\hat{\beta}_0$: Estimasi parameter constanta

$\hat{\beta}_1$: Estimasi parameter indeks waktu

t : Indeks waktu

2.1.2 Model Regresi *Seasonal*

Model Regresi *Seasonal* adalah Pemodelan regresi yang berpola musiman dan terdapat kenaikan atau penurunan setiap musimannya jika dilihat dalam plot *Time Series*.



Gambar 2.2 Ilustrasi Grafik yang Menunjukkan *Seasonal*

Menurut Cryer (1986) model regresi *seasonal* 12 dapat dituliskan sebagai berikut:

$$Z_t = \beta_0 + \beta_1 D_1 + \beta_2 D_2 + \beta_3 D_3 + \dots + \beta_{11} D_{11} + a_t \quad (2.4)$$

dengan


Z_t : Data pengamatan yang berderet waktu

β_0 : Parameter constant

- β_i : Parameter dummy, $i = 1, 2, 3, \dots, 11$
 D_i : Dummy waktu dalam satu periode *seasonal*, $i = 1, 2, 3, \dots, 11$
 a_t : Nilai Error

2.1.3 Model Regresi *Trend* dan *Seasonal*

Model regresi *Trend* dan *Seasonal* adalah pemodelan yang berpola naik atau turun dan terdapat musiman diantara kenaikan atau penurunan jika dilihat dalam plot *Time Series*.



Gambar 2.3 Ilustrasi Grafik yang Menunjukkan *Trend* dan *Seasonal*

Menurut Cryer (1986) model regresi *seasonal* 12 dapat dituliskan sebagai berikut :

$$Z_t = \theta t + \beta_1 D_1 + \beta_2 D_2 + \beta_3 D_3 + \dots + \beta_{11} D_{11} + a_t \quad (2.5)$$

dengan

- Z_t : Data pengamatan yang berderet waktu
 θ : Parameter *trend*
 t : Indeks waktu
 β_0 : Parameter constant
 β_i : Parameter dummy, $i = 1, 2, 3, \dots, 11$
 D_i : Dummy waktu dalam satu periode *seasonal*, $i = 1, 2, 3, \dots, 11$
 a_t : Nilai Error

2.1.4 Uji signifikansi Parameter Regresi

Ada dua macam pengujian dalam uji signifikansi parameter regresi, yaitu uji parameter regresi secara serentak dan secara parsial. Pengujian serentak dilakukan dengan menguji serentak parameter yang terdapat dalam model regresi, dengan hipotesis sebagai berikut:

$$H_0 : \beta_1 = \beta_2 = \dots = \beta_k = 0,$$

$$H_1 : \text{minimal terdapat satu } \beta_i \neq 0, i = 1, 2, \dots, k,$$

dengan k adalah jumlah parameter yang terdapat dalam model regresi. Statistik ujinya adalah sebagai berikut. (Draper dan Smith, 1992)

$$F = \frac{MS_{\text{regresi}}}{MS_{\text{residual}}} \quad (2.6)$$

Nilai F yang didapat dibandingkan dengan $F_{(k, n-k-1)}$. Jika $F > F_{(k, n-k-1)}$ maka Tolak H_0 dan dapat disimpulkan bahwa minimal terdapat satu $\beta_i \neq 0$.

Pengujian parsial bertujuan untuk mengetahui pengaruh variabel bebas terhadap variabel respon secara individu, dengan hipotesis sebagai berikut :

$$H_0 : \beta_i = 0,$$

$$H_1 : \beta_i \neq 0, i = 1, 2, \dots, k,$$

Dengan hipotesis diatas maka didapat statistik ujinya sebagai berikut:

$$t = \frac{\hat{\beta}_i}{SE(\hat{\beta}_i)} \quad (2.7)$$

membandingkan statistik uji pada persamaan (2.7) dengan table t maka Tolak H_0 apabila $|t| > t_{(1-\frac{\alpha}{2}, n-k)}$ dan dapat disimpulkan bahwa $\beta_i \neq 0$, artinya variabel *dummy* berpengaruh terhadap variabel respon.

2.2 Pengujian Asumsi Residual

Pengujian asumsi residual dalam regresi ada tiga yaitu pengujian asumsi residual identik, pengujian asumsi residual independen, dan pengujian asumsi residual berdistribusi normal.

2.2.1 Pengujian Asumsi Residual Identik

Pemeriksaan asumsi varians residual identik dilakukan dengan uji Glejser yaitu meregresikan antara nilai error dengan semua variabel independen pada model regresi *Time Series* dengan tujuan untuk mengetahui penyebaran residualnya identik (homogen varians residual). Berikut ini model yang diperoleh dari meregresikan nilai error dengan semua variabel independen pada model regresi:

$$\varepsilon_t^2 = \partial_0 + \partial_1 \varepsilon_{t-1}^2 + \partial_2 \varepsilon_{t-2}^2 + \dots + \partial_p \varepsilon_{t-p}^2 \quad (2.8)$$

Adapun hipotesis pengujiannya sebagai berikut:

H₀: Varians residual identik, ($\partial_1 = \partial_2 = \partial_3 = \dots = \partial_p = 0$)

H₁: Varians residual tidak identik, ($\partial_i \neq 0$) salah satu i , $i=1,2,3,\dots,p$

Statistik uji yang digunakan pada persamaan (2.6) dibandingkan dengan tabel F maka Tolak H₀, Jika $F_{hit} > F_{\alpha,(p-1,n-p)}$.

2.2.2 Pengujian Asumsi Residual Independen

Autocorrelation function (ACF) adalah korelasi antara Z_t dengan Z_{t+k} . Berikut merupakan rumus ACF :

$$\hat{\rho}_k = \frac{\hat{\gamma}_k}{\hat{\gamma}_0} = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2}, k = 0,1,2,\dots \quad (2.9)$$

dimana $\bar{Z} = \sum_{t=1}^n \frac{Z_t}{n}$ yang merupakan nilai rata-rata dari data time series yang digunakan (Wei, 2006).

2.2.3 Pengujian Asumsi Residual Distribusi Normal

Pemeriksaan residual berdistribusi normal dilakukan untuk melihat apakah residual telah memenuhi asumsi berdistribusi normal. Dalam pemeriksaan suatu kenormalan residual data dapat dilakukan dengan uji *Kolmogorov-Smirnov* dengan hipotesis sebagai berikut (Daniel, 1989):

H_0 : residual data berdistribusi normal,

H_1 : residual data tidak berdistribusi normal,

Dengan hipotesis di atas berdasarkan Minitab, statistik ujinya sebagai berikut:

$$D = \max(D^+, D^-) \quad (2.10)$$

dimana,

$$D^+ = \max_i \left(\frac{i}{n} - F(Z_i) \right)$$

$$D^- = \max_i \left(F(Z_i) - \frac{(i-1)}{n} \right)$$

$i = 1, 2, 3, \dots, n$

Dari statistik uji di atas maka Tolak H_0 jika pada taraf α , jika $D > D_{(n,1-\alpha)}$ yang terdapat pada tabel *Kolmogorov-Smirnov*.

dengan

$F(Z_i)$: Nilai distribusi peluang sampel

$D_{(n,1-\alpha)}$: Nilai kritis uji *Kolmogorov-Smirnov* satu sampel diperoleh dari tabel *Kolmogorov-Smirnov* satu sampel.

2.3 Analisis Time Series

2.3.1 Stasioneritas

Data stasioner adalah data runtun waktu yang paling sederhana dan sangat bermanfaat untuk menjelaskan beragam jenis analisis runtun waktu lainnya. Menurut Box-Jenkins, time series yang bersifat stasioner memiliki nilai mean (μ), varians (σ^2) dan kovarians (τ_k) tidak berpengaruh oleh waktu pengamatan. Sedangkan tidak stasioner dalam *time series* ada dua macam yaitu tidak stasioner dalam mean yang dikarenakan μ tidak konstan dan tidak stasioner dalam varians yang disebabkan σ^2 yang dependen terhadap deret waktu.

1. Stasioner dalam mean

Time series yang tidak stasioner dalam mean berarti mean dipengaruhi oleh waktu pengamatan. Untuk mengatasi keadaan ini maka perlu dilakukam pembedaan (*differencing*) data *time series* yang dirumuskan sebagai berikut:

$$W_t = Z_t - Z_{t-1} \quad (2.11)$$

dengan

W_t : Differencing ke 1
 t : Indeks waktu
 Z_t : Data pengamatan ke t

2. *Stasioner* dalam varians

Pada kasus tidak stasioner dalam varians Z_t berubah sejalan dengan perubahan level $\text{var}(Z_t) = c f(\mu_t)$. Untuk konstan c yang positif dan fungsi f dibutuhkan transformasi $T(Z_t)$ yang memiliki varians konstan, yang disebut sebagai transformasi varians. Pada umumnya untuk menstabilkan varians yang digunakan adalah alat transformasi *Box-Cox* (Wei, 1990) sebagai berikut:

$$T(Z_t) = Z_t^{(\lambda)} = \frac{Z_t^{(\lambda)} - 1}{\lambda} \quad (2.12)$$

dengan

$T(Z_t)$: Transformasi data ke t
 t : Indeks Waktu
 λ : Nilai koefisien dari transformasi *Box-cox*

2.3.2 Fungsi Autokorelasi

Fungsi autokorelasi adalah korelasi antara nilai-nilai suatu deret berkala yang sama dengan selisih waktu (*time lag*) 0,1,2 periode atau lebih. Fungsi autokorelasi parsial digunakan untuk mengukur tingkat keeratan antara Z_t dan Z_{t+k} apabila pengaruh dari *time lag* 1,2, ..., $k-1$ dianggap berpisah.

2.3.3 Model ARIMA

Metode ARIMA (*Autoregressive Integrated Moving Average*) merupakan salah satu model dalam peramalan atau *time series* yang bertujuan untuk memodelkan dan meramalkan variabel *time series univariate*. Ada empat tahap pendekatan *Box-Jenkins* untuk penggunaan peramalan ARIMA, yaitu sebagai berikut:

1. Identifikasi Model ARIMA

Sebelum dilakukan identifikasi model ARIMA perlu dilihat keadaan data apakah sudah *stasioner* atau belum dengan

menggunakan plot *time series*, plot ACF. Jika tidak *stasioner* dalam mean dan varians maka dilakukan langkah pembedaan (*differencing*) dan transformasi *Box-Cox*. Setelah data *stasioner* maka dilakukan pendugaan awal model ARIMA dengan melihat plot ACF dan PACF dari data yang *stasioner* (Wei, 1990) sebagai berikut:

Tabel 2.1 Teoritik ACF dan PACF dari proses yang *stasioner*

Model	ACF	PACF
Autoregressive (p)	Turun eksponensial (<i>Dies Down</i>)	Terpotong setelah lag- p (<i>Cut Off After Lag-p</i>)
Moving Average (q)	Terpotong setelah lag- q (<i>Cut Off After Lag-q</i>)	Turun eksponensial (<i>Dies Down</i>)
Autoregressive Moving Average (p,q)	Turun eksponensial (<i>Dies Down</i>) menuju nol setelah lag ($q-p$)	Turun eksponensial (<i>Dies Down</i>) menuju nol setelah lag ($p-q$)

ARIMA memiliki asumsi data *time series* yang digunakan harus *stasioner* dalam varians dan mean. Model ARIMA non musiman (p,d,q) adalah gabungan dari model *Autoregressive* ($AR(p)$) dan *Moving Average* ($MA(q)$). Apabila data tidak *stasioner* terhadap mean, maka *differencing* non musiman orde d . Bentuk umum dari model ARIMA non musiman adalah sebagai berikut:

$$\phi_p(B)(1-B)^d Z_t = \theta_0 + \theta_q(B) a_t \quad (2.13)$$

dengan

$$\phi_p(B) = (1 - \phi_1 B - \dots - \phi_p B^p) \quad (2.14)$$

$$\theta_q(B) = (1 - \theta_1 B - \dots - \theta_q B^q) \quad (2.15)$$

2. Estimasi Parameter Model

Salah satu metode estimasi parameter pada ARIMA adalah *Maximum Likelihood* (Wei, 2006). Model ARMA (p,q) secara umum adalah seperti persamaan sebagai berikut:

$$\dot{Z}_t = \phi_1 \dot{Z}_{t-1} + \dots + \phi_p \dot{Z}_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (2.16)$$

dimana $\dot{Z}_t = Z_t - \mu$ dan $\{a_i\}$ berdistribusi normal $(0, \sigma_a^2)$ dan *white noise*, fungsi kepadatan peluang bersama dari $\mathbf{a} = (a_1, a_2, \dots, a_n)$ sebagai berikut.

$$P(\mathbf{a} | \phi, \mu, \theta, \sigma_a^2) = (2\pi\sigma_a^2)^{-n/2} \exp\left(-\frac{1}{2\sigma_a^2} \sum_{i=1}^n a_i^2\right) \quad (2.17)$$

Selanjutnya persamaan (2.15) dapat ditulis.

$$a_t = \theta_1 a_{t-1} + \dots + \theta_q a_{t-q} \phi_1 + \dot{Z}_t - \phi_1 \dot{Z}_{t-1} - \dots - \phi_p \dot{Z}_{t-p} \quad (2.18)$$

Diberikan nilai $\mathbf{Z} = (Z_1, Z_2, \dots, Z_n)'$ dan diasumsikan kondisi awal $\mathbf{Z}^* = (Z_{1-p}, \dots, Z_{-1}, Z_0)'$ serta $\mathbf{a}^* = (a_{1-p}, \dots, a_{-1}, a_0)$ maka fungsi kondisional *likelihood* adalah

$$\ln L^*(\phi, \mu, \theta, \sigma_a^2) = -\frac{n}{2} \ln 2\pi\sigma_a^2 - S^*(\phi, \mu, \theta) \quad (2.19)$$

dimana

$$S^*(\phi, \mu, \theta) = \sum_{i=1}^n a_i^2(\phi, \mu, \theta | Z^*, \mathbf{a}^*, Z) \quad (2.20)$$

$S^*(\phi, \mu, \theta)$ adalah fungsi jumlah kuadrat bersyarat.

Untuk memperoleh parameter ϕ dan θ pada model ARIMA dilakukan dengan cara menurunkan persamaan (2.19) secara parsial terhadap parameter ϕ dan θ dan nilainya disama dengarkan 0.

3. Signifikansi Parameter Model ARIMA

Langkah kedua setelah identifikasi yaitu melakukan pengujian signifikansi parameter model ARIMA. dengan hipotesis sebagai berikut:

a. Pengujian Parameter AR

$$H_0 : \phi_i = 0, i = 1, 2, \dots, p$$

$$H_1 : \phi_i \neq 0,$$

Dengan hipotesis di atas maka didapat statistik uji sebagai berikut:

$$t_{hit} = \frac{\hat{\phi}_i}{SE(\hat{\phi}_i)} \quad (2.21)$$

dengan statistik uji di atas maka Tolak H_0 , jika $|t_{hit}| > t_{\frac{\alpha}{2}}(df=n-p)$

dengan

- ϕ_i : Parameter AR lag ke i
- $\hat{\phi}_i$: Estimasi parameter AR lag ke i
- n : Banyaknya observasi
- i : Jumlah parameter yang ditaksir

b. Pengujian Parameter MA

$$H_0 : \theta_i = 0, i = 1, 2, \dots, q$$

$$H_1 : \theta_i \neq 0,$$

Dengan hipotesis di atas maka didapat statistik uji sebagai berikut:

$$t_{\text{hit}} = \frac{\hat{\theta}_i}{SE(\hat{\theta}_i)} \quad (2.22)$$

dengan statistik uji di atas maka Tolak H_0 , jika $|t_{\text{hit}}| > t_{\frac{\alpha}{2}}(df=n-p)$

dengan

- θ_i : Parameter MA lag ke i
- $\hat{\theta}_i$: Estimasi parameter MA lag ke i
- n : Banyaknya observasi
- i : Jumlah parameter yang ditaksir

4. Asumsi Residual

Langkah selanjutnya setelah signifikansi parameter model terpenuhi yaitu dengan menggunakan pemeriksaan diagnostik. Pemeriksaan diagnostik ini tentang asumsi residual. Pengujian ini meliputi dua bagian, yaitu uji asumsi residual dan *White Noise*.

a. Distribusi Normal

Pada pemodelan ARIMA terdapat asumsi residual berdistribusi normal. Pengujian asumsi residual berdistribusi normal dilakukan dengan uji *kolmogorov smirnov*. Hipotesis, statistik uji dan daerah kritis yang digunakan telah dibahas pada sub bab 2.3.3 pengujian asumsi distribusi normal.

b. *White Noise*

Residual dikatakan *White Noise* yaitu jika tidak terdapat korelasi antar residual dengan mean sama dengan 0 dan varians konstan. Dengan hipotesis sebagai berikut :

$$H_0 : \rho_1 = \rho_2 = \dots = \rho_K,$$

$$H_1 : \text{minimal ada satu nilai } \rho_k \neq 0, k = 1, 2, \dots, K,$$

Dari hipotesis di atas maka didapat statistik uji sebagai berikut:

$$Q = n(n+2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{n-k} \quad (2.23)$$

Dari statistik uji di atas Tolak H_0 , jika $Q > \chi^2_{(\alpha; k-p-q)}$ atau $P\text{-value} < \alpha$

dengan

k : Banyaknya lag

n : Banyaknya data

$\hat{\rho}$: Nilai *autocorrelation function*

Setelah dilakukan pemeriksaan asumsi residual, selanjutnya dilakukan pemilihan model terbaik dengan menggunakan kriteria pemilihan model berdasarkan *in sample* yaitu AIC dan SBC.

2.3.4 Deteksi *Outlier*

Analisis *Time series* kadang-kadang dipengaruhi oleh suatu kejadian tertentu seperti perang, krisis ekonomi atau bencana alam. Konsekuensi dari kejadian tersebut membuat suatu observasi menjadi tidak seperti biasanya, kejadian seperti itu disebut *Outlier*. Ada 2 model dalam *outlier* yaitu additive dan innovational.

Diberikan suatu data time series Z_t dan X_t adalah data outlier pada Z_t , diasumsikan X_t mengikuti model ARMA(p,q). Maka model *Additive Outlier (AO)* dapat ditulis sebagai berikut.

$$\begin{aligned} Z_t &= \begin{cases} X_t & t \neq T \\ X_t + \omega_t & t = T \end{cases} \\ &= X_t + \omega I_t^{(T)} \\ &= \frac{\theta(B)}{\phi(B)} a_t + \omega I_t^{(T)} \end{aligned} \quad (2.24)$$

dengan

$$I_t^{(T)} = \begin{cases} 1, & t = T \\ 0, & t \neq T \end{cases} \quad (2.25)$$

dan *Innovational Outlier (IO)* model dapat dituliskan sebagai berikut.

$$\begin{aligned}
 Z_t &= X_t + \frac{\theta(B)}{\phi(B)} \omega I_t^{(T)} \\
 &= \frac{\theta(B)}{\phi(B)} (a_t + \omega I_t^{(T)})
 \end{aligned} \tag{2.26}$$

Efek dari *Additive Outlier (AO)* hanya terjadi pada waktu ke T observasi saja, tetapi efek dari *Innovational Outlier (IO)* terjadi pada semua observasi Z_T, Z_{T+1}, \dots dimana waktu T digambarkan

dengan $\frac{\theta(B)}{\phi(B)}$

Selain AO dan IO ada metode lain untuk mendeteksi *outlier* yaitu menggunakan model *level shift (LF)* dan *temporary change (TC)*. Rumus *LF* dan *TC* pada persamaan (2.27) dan persamaan (2.28).

$$LS: Z_t = X_t + \frac{1}{(1-B)} \omega_L I_t^{(T)} \tag{2.27}$$

dan

$$TC: Z_t = X_t + \frac{1}{(1-\delta B)} \omega_C I_t^{(T)} \tag{2.28}$$

(Wei, 2006)

2.3.5 Pemilihan Model Terbaik

Pemodelan dari data *time series* terdapat beberapa model. Asumsi yang harus dipenuhi terlebih dahulu adalah parameter signifikan, residualnya memenuhi asumsi *white noise*, dan berdistribusi normal. Untuk menentukan model yang terbaik dan akurat dapat digunakan kriteria dari data *in sample* dan data *out sample* antara lain sebagai berikut:

1. Akaike's Information Criterion (AIC)

Kriteria AIC digunakan sebagai penentuan model terbaik untuk data *in sample* dan dapat dirumuskan pada persamaan (2.29).

$$AIC(M) = n \ln \hat{\sigma}_a^2 + 2M \tag{2.29}$$

dengan

- n : Jumlah observasi
 $\hat{\sigma}$: Estimasi varian
 M : Banyaknya variabel independen

2. *Schwart's Bayesian Criterion* (SBC)

Kriteria SBC digunakan sebagai penentuan model terbaik untuk data *in sample*. Schwart'(1978) didalam (Wei, 1990) menggunakan kriteria Bayesian dalam pemilihan model terbaik yang disebut dengan SBC dengan perumusan pada persamaan (2.30).

$$SBC(M) = n \ln \hat{\sigma}_a^2 + M \ln n \quad (2.30)$$

dengan

- n : Jumlah observasi
 $\hat{\sigma}$: Estimasi varian
 M : Banyaknya variabel independen

3. *Mean Square Error* (MSE) dan *Root Mean Square Error* (RMSE)

Kriteria MSE digunakan sebagai penentuan model terbaik untuk data *out sample* dan dirumuskan pada persamaan (2.31) dan (2.32). (Arsyad, 1994)

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

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{m} \sum_{t=1}^m (Z_t - \hat{Z}_t)^2} \quad (2.32)$$

dengan

- m : Banyaknya ramalan
 n : Banyaknya observasi
 Z_t : Data pengamatan yang berderet waktu
 \hat{Z}_t : Nilai dugaan dari Z_t

4. *Mean Absolute Percentage Error* (MAPE)

Kriteria MAPE digunakan sebagai penentuan model terbaik untuk data *out sample* dan dirumuskan pada persamaan (2.33). (Arsyad, 1994)

$$\text{MAPE} = \frac{\sum_{t=1}^n \frac{|Z_t - \hat{Z}_t|}{Z_t}}{n} \times 100\% \quad (2.33)$$

dengan

n : Banyaknya observasi

Z_t : Data pengamatan yang berderet waktu

\hat{Z}_t : Nilai dugaan dari Z_t

2.4 Deskriptif Karet

Karet merupakan polimer hidrokarbon yang terbentuk dari emulsi kesesuain (dikenal sebagai latex) yang diperoleh dari getah beberapa jenis tumbuhan karet tetapi dapat juga diproduksi secara sintetis. Sumber utama latex yang di gunakan untuk membuat karet adalah pohon karet *Hevea brasiliensis* (Euphorbiaceae). Menghasilkan getah karet dapat dilakukan dengan cara melukai kulit pohon sehingga pohon akan memberikan respon yang menghasilkan lebih banyak latex. (Wikipedia, 2014)

Jenis karet pertama yang dibuat sepatu adalah karet alam. Sesudah penemuan proses vulkanisasi oleh Charles Goodyear yang membuat karet menjadi tahan terhadap cuaca dan tidak larut dalam minyak, maka karet mulai digemari sebagai bahan dasar dalam pembuatan berbagai macam alat untuk keperluan dalam rumah ataupun pemakaian di luar rumah seperti sol sepatu dan bahkan sepatu yang semuanya terbuat dari bahan karet. Karet alam sangat mudah dilengketkan satu sama lain sehingga sangat disukai dalam pembuatan barang-barang yang perlu dilapisi sebelum vulkanisasi dilakukan. Keunggulan daya lengket inilah yang menyebabkan karet alam sulit disaingi oleh karet sintetis dalam pembuatan karkas untuk ban radial ataupun dalam pembuatan sol karet yang sepatunya diproduksi dengan cara vulkanisasi langsung.

BAB III METODOLOGI PENELITIAN

3.1 Sumber Data dan Variabel Penelitian

Data yang digunakan dalam penelitian ini merupakan data sekunder dimana data diperoleh dari PT Perkebunan Nusantara XII (PTPN XII) Surabaya. Data yang digunakan adalah data produksi bahan mentah karet di wilayah Jawa Timur yang diambil setiap minggu. Penelitian ini menggunakan variabel produksi mingguan bahan mentah karet di wilayah Jawa Timur mulai tahun 2012-2014. Metode analisis statistik yang digunakan dalam penelitian Tugas Akhir ini adalah metode regresi *time series* dan ARIMA. Data yang akan dianalisis dibagi menjadi data *in sample* dan *out sample*. Berikut ini struktur data yang digunakan.

Tabel 3.1 Struktur Data

Tahun	Minggu ke-	Produksi Karet
2012	1	Z_1
	2	Z_2

	51	Z_{51}
	52	Z_{52}
2013	1	Z_{53}
	2	Z_{54}

	51	Z_{103}

Tabel 3.1 Struktur Data (Lanjutan)

Tahun	Minggu ke-	Produksi Karet
2013	52	Z_{104}
2014	1	Z_{105}
	2	Z_{106}

	15	Z_{121}
	16	Z_{122}

3.2 Metode Analisis

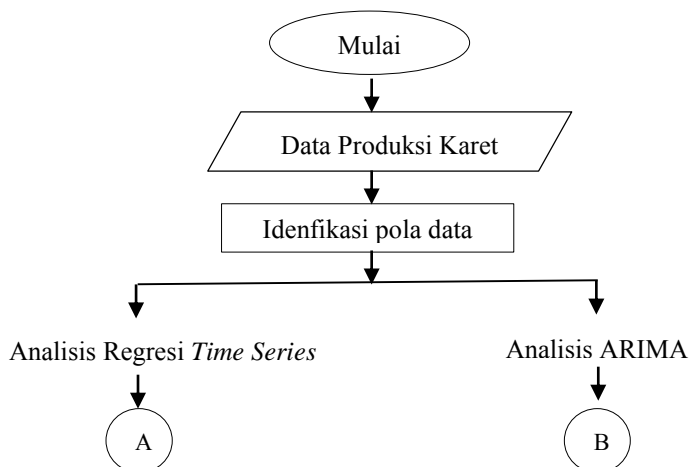
Berdasarkan dari metode analisis yang digunakan di atas yaitu metode regresi *time series* maka terdapat langkah-langkah yang harus dilakukan dengan masing-masing metode tersebut adalah sebagai berikut:

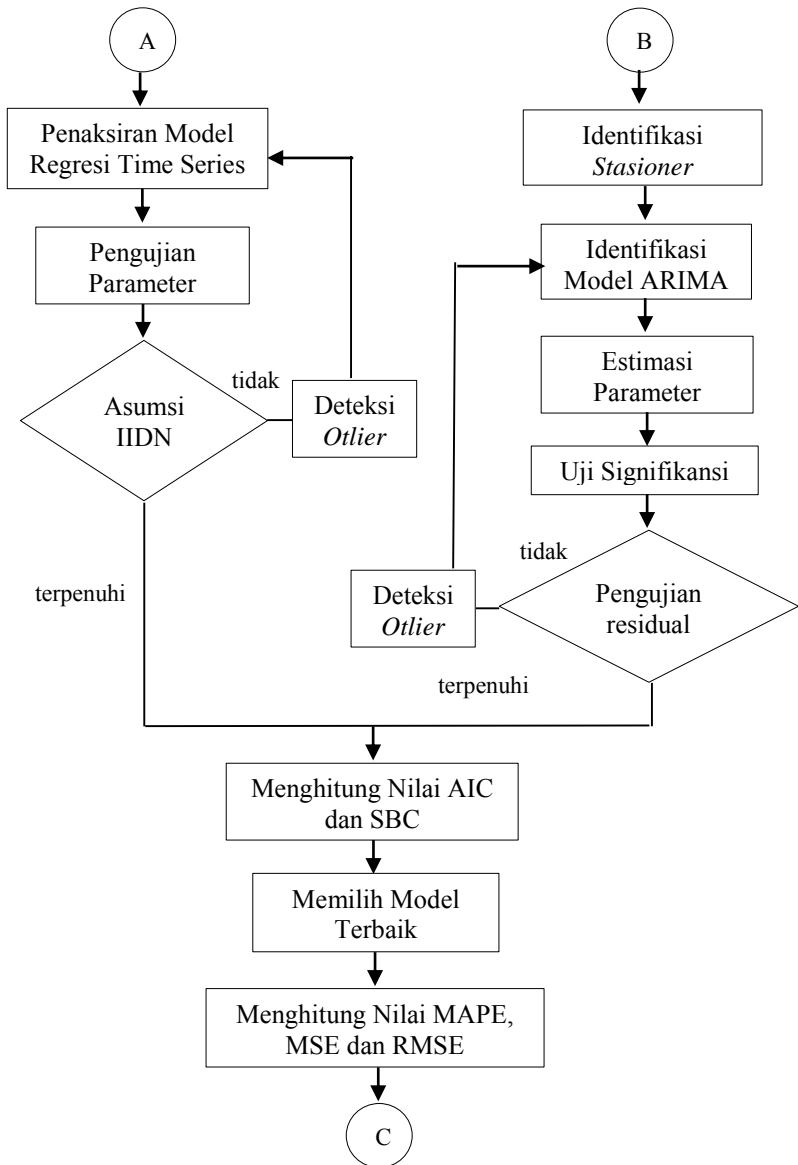
1. Data dibagi menjadi dua, yaitu data *in sample* dan data *out sample*.
2. Identifikasi pola bertujuan untuk mengetahui apakah bahan mentah karet di wilayah Jawa Timur dipengaruhi oleh waktu sehingga membentuk pola tren, musiman, atau keduanya. Identifikasi dapat dilakukan secara visual melalui *time series* plot.
3. Melakukan pemodelan dengan metode regresi.
 - a. Penaksiran model (Estimasi parameter)
 - b. Pengujian parameter (uji signifikansi parameter) dan apabila semua parameter telah signifikan maka dapat dilanjutkan pada tahap berikutnya.
 - c. Pengujian asumsi IIDN
 - d. Identifikasi *Outlier*.
4. Melakukan pemodelan ARIMA dengan langkah sebagai berikut:

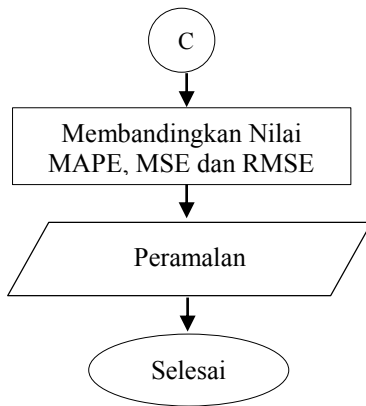
- a. Identifikasi stasioner dengan menggunakan *Box-cox* dan plot ACF.
 - b. Identifikasi model ARIMA menggunakan plot ACF dan PACF.
 - c. Estimasi parameter model ARIMA.
 - d. Uji signifikansi parameter model ARIMA.
 - e. Melakukan Pengujian terhadap residual, meliputi uji asumsi *white noise* (independen dan identik) serta kenormalan.
 - f. Identifikasi *Outlier*.
5. Menghitung nilai AIC dan SBC pada model *in sample* serta MAPE, MSE dan RMSE pada model *out sample*.
 6. Membandingkan nilai MAPE, MSE dan RMSE antara model *Regresi Time Series* dan model ARIMA.
 7. Memilih model terbaik berdasarkan kriteria kebaikan model dari metode ARIMA dan *Regresi Time Series*.
 8. Melakukan peramalan produksi bahan mentah karet di Jawa Timur beberapa periode ke depan menggunakan model terbaik yang telah dipilih.

3.3 Diagram Alir

Berdasarkan metode analisis di atas maka dapat digambarkan dalam bentuk diagram alir sebagai berikut.







Gambar 3.1 Diagram Alir

“Halaman Ini Sengaja Dikosongkan”

BAB IV ANALISIS DAN PEMBAHASAN

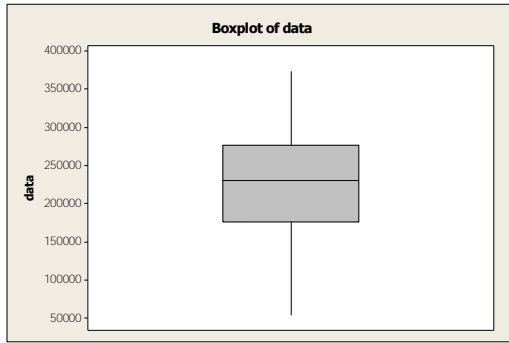
4.1 Statistika Deskriptif

Produksi karet di Jawa Timur mengalami banyak perubahan, mulai kenaikan yang drastis hingga penurunan yang sangat drastis. Umumnya produksi karet mengalami penurunan akibat terjadinya hujan yang lebat, sehingga hasil produksi tidak bisa di ambil. Hasil analisis statistika deskriptif dari data produksi karet dapat dilihat pada tabel 4.1.

Tabel 4.1 Statistika Deskriptif Produksi Karet di Jawa Timur

Variable	Data
Mean	226627
StDev	65211
Variance	4252461781
Minimum	53882
Median	230446
Maximum	372729
Skewness	-0,07
Kurtosis	-0,65

Data produksi karet di Jawa Timur memiliki nilai rata-rata sebesar 226627. Produksi karet terkecil 53882 yaitu terjadi pada bulan agustus 2012 dan produksi karet terbanyak 372729 terjadi pada bulan april 2012. Nilai keragaman sebesar 4252461781, dengan nilai tengah 23882. Untuk mengetahui adanya data *outlier* dan untuk mengetahui apakah data berdistribusi normal dapat dilihat dari *box plot*. Berdasarkan *Box Plot* pada Gambar 4.1 menunjukkan bahwa data tidak berdistribusi normal sehingga lebih condong ke salah satu sisi. Hal ini terlihat dari panjang *whisker* yang tidak sama, dimana *whisker* bawah lebih panjang daripada *whisker* atas. Selain itu tidak terdapat data *outlier* pada data produksi karet di Jawa Timur.



Gambar 4.1 *Box plot* Produksi Karet di Jawa Timur Mingguan

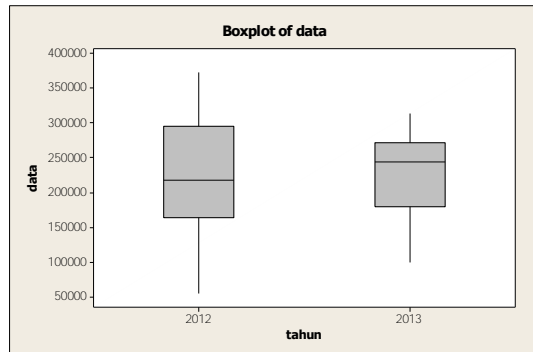
Tabel 4.2 Statistika Deskriptif Produksi Karet di Jawa Timur Tahun 2012 dan 2013

Variable	2012	2013
Mean	226430	226825
StDev	76606	52152
Variance	5868417930	2719807855
Minimum	53882	98874
Median	217461	242972
Maximum	372729	312582
Skewness	0,01	-0,32
Kurtosis	-0,92	-0,94

Data produksi karet di Jawa Timur pada tahun 2012 dan 2013 memiliki karakteristik yang berbeda. Rata-rata produksi karet pada tahun 2012 adalah 226430, sedangkan pada tahun 2013 sebesar 226825. Tahun 2012 produksi karet terkecil 53882 yaitu terjadi pada bulan agustus dan produksi karet terbanyak 372729 terjadi pada bulan april 2012. Nilai keragaman pada tahun 2012 sebesar 5868417930, dengan nilai tengah 217461.

Tahun 2013 produksi karet terkecil 98874 yaitu terjadi pada bulan agustus dan produksi karet terbanyak 312582 terjadi pada bulan maret 2013. Nilai keragaman pada tahun 2013 sebesar

2719807855, dengan nilai tengah 242972. Dari perbandingan produksi pada tahun 2012 dan 2013, produksi pada tahun 2013 lebih baik dibandingkan 2012, karena pada tahun 2013 memiliki rata-rata produksi lebih besar. Selain itu pada tahun 2013 produksi terkecil tidak terlalu jauh dari nilai rata-ratanya.



Gambar 4.2 Boxplot Produksi Karet di Jawa Timur Mingguan Tahun 2012 dan 2013

Berdasarkan *Box Plot* pada Gambar 4.2 menunjukkan bahwa data tahun 2012 dan 2013 tidak berdistribusi normal sehingga lebih condong ke salah satu sisi. Hal ini terlihat dari panjang *whisker* yang tidak sama, dimana *whisker* bawah lebih panjang daripada *whisker* atas. Selain itu tidak terdapat data *outlier* pada data produksi karet tahun 2012 dan 2013 di Jawa Timur.


4.2 Pemodelan Produksi Karet menggunakan Metode ARIMA

4.2.1 Identifikasi Produksi Karet di Jawa Timur


Identifikasi model dapat dilihat melalui *time series plot*, *box-cox* dan plot ACF. *Time series plot* digunakan untuk mengetahui pola data. Berikut adalah hasil *time series plot* produksi karet di Jawa Timur :

Gambar 4.3 *Time Series Plot* data *in sample* secara visual menunjukkan bahwa data produksi karet di Jawa Timur belum

stasioner maka perlu dilakukan tranformasi dan *differencing*. Namun untuk lebih jelasnya akan dilakukan analisis stasioner dalam *mean* menggunakan ACF dan stasioner dalam *variance* menggunakan *box-cox*. Selain itu dapat diketahui pada minggu ke 33, 34, dan 84 terjadi penurunan produksi. Hal itu terjadi karena pada minggu tersebut terjadi hujan yang menyebabkan produksi menjadi nol. Selanjutnya dilakukan identifikasi dengan *box-cox* untuk mengetahui kestasioneran data dalam *variance*.

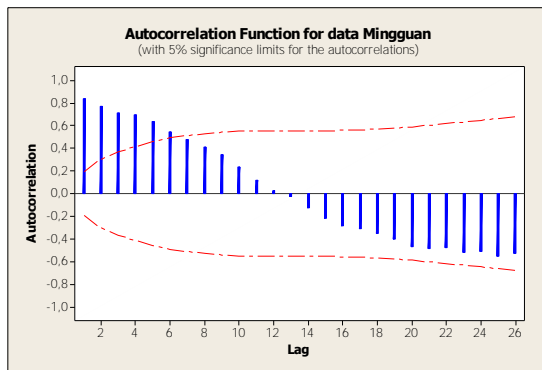


Gambar 4.3 Time Series Plot Data Produksi Karet




Gambar 4.4 Box-Cox Plot Data Produksi Karet di Jawa Timur

Berdasarkan transformasi *box-cox* diperoleh nilai estimasi 1,19 dengan nilai *rounded value* sebesar 1,00. Hal ini menunjukkan bahwa data produksi karet di Jawa Timur sudah stasioner terhadap *variance*. Selain dari *rounded value* dapat dilihat dari nilai *lower CL* 0,71 dan *upper CL* 1,78 maka interval tersebut memuat angka satu, sehingga dapat disimpulkan data produksi karet di Jawa Timur tidak perlu di transformasi. Selanjutnya dilakukan identifikasi dengan *Autocorelation Fuction* untuk mengetahui kestasioneran data dalam *mean* yang disajikan pada Gambar 4.5.



Gambar 4.5 *Autocorelation Fuction* Data Produksi Karet di Jawa Timur


Hasil identifikasi stasioneritas terhadap *mean* pada Gambar 4.5 menunjukkan bahwa nilai *Autocorelation Fuction* data produksi karet turun secara lambat menuju nol. Hal ini menunjukkan bahwa data produksi karet perlu dilakukan *differencing* sebanyak satu kali. Setelah dilakukan *differencing* dapat ditunjukkan dengan *time series plot*. Pada Gambar 4.6 menunjukkan bahwa *Time Series Plot* data yang telah *didifferencing* berfluktuatif disekitar *mean*. Hal tersebut dapat disimpulkan bahwa data produksi karet di Jawa Timur telah stasioner terhadap *mean*. Data hasil *differencing* tersebut dapat digunakan untuk analisis selanjutnya.



Gambar 4.6 Time Series Plot Data Differencing

4.2.2 Pendugaan Model Produksi Karet di Jawa Timur


Pendugaan model ARIMA dapat menggunakan *plot Autocorelation Fuction (ACF)* dan *Partial Autocorelation Fuction (PACF)*. Hasil analisis ACF dan PACF dapat dilihat pada Gambar 4.7 dan Gambar 4.8.



Gambar 4.7 Autocorelation Fuction Data Differencing Produksi Karet di Jawa Timur

Setelah dilakukan *differencing* sebanyak satu kali dan dibuat *plot Autocorelation Fuction (ACF)* seperti Gambar 4.7 terlihat bahwa nilai *Autocorelation Fuction (ACF)* tidak turun

lambat. Selain itu *plot Autocorelation Fuction* (ACF) juga menunjukkan lag *Moving Average* (MA). lag *Moving Average* (MA) yang signifikan pada Gambar 4.7 adalah lag ke-1. Sedangkan signifikansi untuk model AR dapat dilihat pada *plot Partial Autocorelation Fuction* (PACF) seperti pada gambar 4.8.



Gambar 4.8 *Partial Autocorelation Fuction Data Differencing*
Produksi Karet di Jawa Timur

Gambar 4.8 merupakan *plot Partial Autocorelation Fuction* (PACF) yang telah *differencing* menunjukkan bahwa lag yang signifikan adalah lag ke-1.

Hasil identifikasi model ARIMA berdasarkan *plot Autocorelation Fuction* (ACF) dan *Partial Autocorelation Fuction* (PACF) memberikan kombinasi beberapa kemungkinan model. Adapun diantaranya model-model ARIMA yang didapatkan adalah ARIMA (0,1,1) dan ARIMA (1,1,0). Berdasarkan Tabel 4.3 menunjukkan bahwa semua parameter pada kedua kemungkinan model ARIMA tersebut signifikan karena *p-value* kurang dari α sebesar 0,05 dan pada kedua model *white noise*. Namun hasil pada kedua model ARIMA tidak normal, maka perlu dilakukan deteksi *outlier*.

Tabel 4.3 Estimasi Parameter Model ARIMA

	ARIMA (0,1,1)	ARIMA (1,1,0)
ϕ_1	-	-0,2939 (0,0024)
θ_1	0,3633 (0,0001)	-
<i>White Noise</i>	Ya	Ya
Normal	Tidak	Tidak

*nilai didalam kurung adalah *p-value*

Setelah dilakukan deteksi *outlier* diperoleh beberapa data yang *outlier*, yaitu sebagai berikut:

Tabel 4.4 Deteksi *Outlier* Model ARIMA

Obs	Chi - square	p- value
84	55,12	<,0001
33	18,49	<,0001
13	13,04	0,0003
104	9,61	0,0019
85	10,13	0,0015
34	9,17	0,0025
29	8,52	0,0035
18	7,33	0,0068
53	6,15	0,0132

Berdasarkan model ARIMA ada beberapa data yang *outlier* seperti pada Tabel 4.4. Data yang terdeteksi *outlier* adalah data yang memiliki *p-value* kurang dari α yaitu sebanyak 9 obesrvasi, diantara 9 observasi tersebut dua data tertinggi yang dideteksi *outlier* yaitu pada observasi ke 84 dan 33. Selajutnya dilakukan estimasi pemodelan ARIMA dengan memasukkan data yang *outlier*.

Tabel 4.5 Estimasi Parameter Model ARIMA

	ARIMA (0,1,1)	ARIMA (1,1,0)
ϕ_1	-	-0,3765 (0,0001)
<i>Outlier</i> obs ke 84	-	-150524,6 (<0,0001)
<i>Outlier</i> obs ke 33	-	-108266,1 (<0,0001)
θ_1	0,3380 (0,0008)	-
<i>Outlier</i> obs ke 84	-144652,4 (<0,0001)	-
<i>Outlier</i> obs ke 33	-102606,0 (0,0002)	-
<i>White Noise</i>	Ya	Ya
Normal	Ya	Ya

*nilai didalam kurung adalah *p-value*

Semua parameter pada Tabel 4.5 sudah signifikan, dilihat dari nilai *p-value* kurang dari α sebesar 0,05 dan parameter pada data yang *outier* signifikan. Kedua model juga normal dan *white noise*, selanjutnya dilakukan pemilihan model terbaik berdasarkan kriteria kebaikan model AIC dan SBC pada data *in sample* dan MAPE , MSE dan RMSE pada data *out sample*.

Tabel 4.6 Kriteria Kebaikan Model ARIMA

Model	<i>In Sample</i>		<i>Out Sample</i>		
	AIC	SBC	MAPE	MSE	RMSE
ARIMA (0,1,1)	2449,6370	2452,2710	18,3422	2650372094	51481,7600
ARIMA (1,1,0)	2451,8370	2454,4720	53,0526	14989544655	122431,800 0

Pada perhitungan nilai *in sample* dan *out sample* didapat nilai yang terbaik pada ARIMA (0,1,1), karena ARIMA (0,1,1)

memiliki nilai *error* terkecil, dengan nilai AIC 2449,6370, SBC 2452,2710, MAPE 18,3422, MSE 2650372094, dan RMSE 51481,7600. Berikut model matematis dari ARIMA (0,1,1) dengan *outlier* observasi ke 84 dan ke 33 pada data produksi karet di Jawa Timur :

$$Z_t = (1 - \theta B)(a_t + \omega_1 I_t^{(84)}) + \left(\frac{1}{(1-B)} \omega_2 I_t^{(33)} \right)$$

$$Z_t = (1 - 0,3380B)(a_t - 144652,4000 I_t^{(84)}) + \left(\frac{1}{(1-B)} (-102606) I_t^{(33)} \right)$$

$$Z_t = a_t - 144652,4000 I_t^{(84)} - 0,3380 a_{t-1} + 48885,2800 I_{t-1}^{(84)} + \left(\frac{1}{(1-B)} (-102606) I_t^{(33)} \right)$$

$$Z_t - a_t + 144652,4000 I_t^{(84)} + 0,3380 a_{t-1} - 48885,2800 I_{t-1}^{(84)} = \left(\frac{1}{(1-B)} (-102606) I_t^{(33)} \right)$$

$$(Z_t - a_t + 144652,4000 I_t^{(84)} + 0,3380 a_{t-1} - 48885,2800 I_{t-1}^{(84)}) (1-B) = -102606 I_t^{(33)}$$

$$Z_t - a_t + 144652,4000 I_t^{(84)} + 0,3380 a_{t-1} - 48885,2800 I_{t-1}^{(84)} + Z_{t-1} - a_{t-1}$$

$$+ 144652,4000 I_{t-1}^{(84)} + 0,3380 a_{t-2} - 48885,2800 I_{t-2}^{(84)} = -102606 I_t^{(33)}$$

Dari model diatas maka dapat dituliskan model sebagai berikut:

$$Z_t = a_t - Z_{t-1} + a_{t-1} - 144652,4000 I_t^{(84)} - 0,33795 a_{t-1} - 95767,1200 I_{t-1}^{(84)} - 0,33795 a_{t-2} + 48885,2800 I_{t-2}^{(84)} + 102606 I_t^{(33)}$$

dengan

$$I_t^{(84)} = \begin{cases} 1, & t = 84 \\ 0, & t \neq 84 \end{cases} \quad \text{dan} \quad I_t^{(33)} = \begin{cases} 1, & t = 33 \\ 0, & t \neq 33 \end{cases}$$

4.3 Regresi Runtun Waktu

Hasil analisis regresi antara produksi karet mingguan dengan deret waktu diperoleh model sebagai berikut :

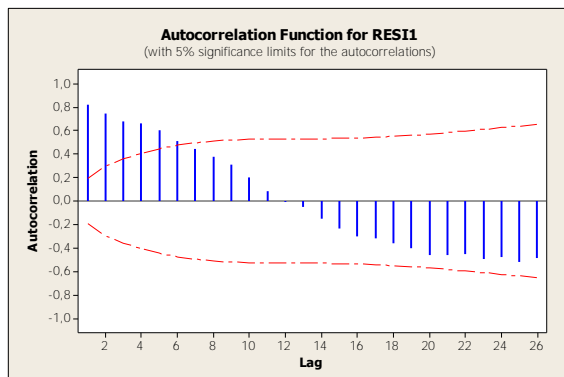
$$Z_t = 255094 - 542t$$

Dari model di atas maka dapat disimpulkan bahwa jika waktu bertambah satu minggu maka produksi berkurang 542. Untuk melihat signifikansi parameter maka dilakukan pengujian serentak dan parsial yang disajikan pada Tabel 4.4 dan Tabel 4.5.

Tabel 4.7 Uji Glejser Produksi Karet di Jawa Timur


Source	DF	SS	MS	F	P
Regression	1	6,02E+09	6,02E+09	5,6000	0,0200
Residual	102	1,10E+11	1,08E+09		
Total	103	1,16E+11			

Dari Tabel 4.7 dapat disimpulkan bahwa tolak H_0 karena $F_{hitung} (5,6000) > F_{tabel} (3,9342)$ dan diketahui nilai p -value kurang dari α . Karena tolak H_0 maka disimpulkan bahwa residual tidak identik karena terjadi heterokedastisitas, sehingga pada model regresi *time series* tidak memenuhi asumsi residual identik. Selanjutnya dilakukan deteksi adanya otokorelasi dengan menggunakan *plot autocorelation*, *plot autocorelation* disajikan pada Gambar 4.9.



Gambar 4.9 Plot ACF Residual Produksi Karet di Jawa Timur

Berdasarkan Gambar 4.9 dapat diketahui bahwa masih ada lag yang keluar dari garis signifikansi, lag yang keluar batas signifikansi adalah lag ke 1, 2, 3, 4, 5 dan 6. Dapat disimpulkan bahwa data produksi karet belum memenuhi asumsi residual *independent*. Selanjutnya dilakukan pengujian distribusi normal menggunakan *kolmogorov-smirnov*.



Gambar 4.10 Plot Distribusi Normal Produksi Karet di Jawa Timur

Uji *Kolmogorov-Smirnov* diketahui bahwa nilai *p-value* 0,0440. Karena *p-value* data produksi karet di Jawa Timur kurang dari α (0,05) maka dapat disimpulkan bahwa data produksi Karet di Jawa Timur tolak H_0 maka data tidak berdistribusi normal.

Dari pengujian identik, independen dan distribusi normal data peroduksi karet di Jawa Timur tidak memenuhi asumsi tersebut maka teridentifikasi adanya *outlier* seperti pada Tabel 4.8.

Tabel 4.8 Deteksi *Outlier* Produksi Karet di Jawa Timur

Obs	t	abs resi1	Fit	SE Fit	Residual	st Resid
18	18	127395	61975	4900	65420	2,02R
33	33	136408	58172	3836	78236	2,40R
34	34	182776	57919	3778	124858	3,83R
84	84	110673	45242	4663	65431	2,02R

Dari deteksi *outlier* terdapat beberapa data yang teridentifikasi *outlier* yaitu pada data ke 18, 33, 34, dan 84. Oleh karena itu untuk menanggulangi asumsi-asumsi yang tidak terpenuhi pada analisis regresi *time series*, maka dilakukan pemodelan regresi dengan memasukkan data *outlier* pada model. Berikut ini hasil pemodelan regresi *time series* dengan memasukkan data *outlier*.


$$\hat{Z}_t = 21027 - 21396 D_{34} - 22121 D_{84} - 21701 D_{33} + 0,0037 Z_{t-1}$$

Dari model diatas jika untuk minggu ke 34 maka produksi karet akan berkurang sebesar 21396. Jika pada minggu ke 84 maka produksi maka produksi karet akan berkurang sebesar 22121 dan jika pada minggu ke 33 maka produksi karet akan berkurang sebesar 21701. Jika produksi satu minggu sebelumnya meningkat satu satuan maka produksi akan meningkat sebesar 0,0037.


Tabel 4.9 Uji Glejser Produksi Karet di Jawa Timur Setelah Memperhatikan Proses Data *Outlier*

Source	DF	SS	MS	F	P
Regression	4	1,4E+09	3,49E+08	1,1100	0,3560
Residual	98	3,08E+10	3,15E+08		
Total	102	3,22E+10			

Dari Tabel 4.9 diperoleh nilai *p-value* sebesar 0,3560, maka dapat disimpulkan bahwa gagal tolak H_0 karena nilai *p-value* lebih dari α . Maka data produksi karet di Jawa Timur setelah memperhatikan proses data *outlier* sudah identik. Selanjutnya dilakukan pengujian *independent*. Pada Gambar 4.11 dapat diketahui bahwa tidak ada lag yang keluar dari garis signifikansi atas dan bawah, maka dapat disimpulkan bahwa residual data sudah memenuhi asumsi residual *independent*. Selanjutnya dilakukan pengujian distribusi normal pada Gambar 4.12.



Gambar 4.11 Plot ACF Residual Produksi Karet di Jawa Timur Setelah Memperhatikan Proses *Outlier*



Gambar 4.12 Plot Distribusi Normal Produksi Karet di Jawa Timur Setelah Memperhatikan Proses data *Outlier*

Uji *Kolmogorov-Smirnov* diketahui bahwa nilai *p-value* 0,1410. Karena *p-value* data produksi karet di Jawa Timur lebih dari α (0,05) maka dapat disimpulkan bahwa data produksi Karet di Jawa Timur gagal tolak H_0 maka residual sudah berdistribusi normal.

Dari hasil analisis regresi, semua parameter sudah signifikan dan memenuhi asumsi dengan nilai *R-sq (adj)* sebesar

81,1% dan nilai MSE sebesar 28325. Dari perhitungan kebaikan model diperoleh nilai AIC sebesar 2114,6830 dan nilai SBC sebesar 2125,2220. Untuk perhitungan nilai *out sample* diperoleh nilai MAPE sebesar 11,0697, MSE sebesar 1193729388 dan RMSE sebesar 34550,3900.

4.4 Pemilihan Model Terbaik dan Peramalan Produksi

Untuk membandingkan model terbaik antara metode ARIMA dan *Regression Time Series* dapat dilihat dari nilai *in sample* dan *out sample*, yaitu dari nilai AIC, SBC, MAPE, MSE dan RMSE. Berikut ini adalah perbandingan antara metode ARIMA dan *Regression Time Series* dengan nilai *in sample* dan *out sample*.

Tabel 4.10 Pemilihan Model Terbaik

Model	<i>In Sample</i>		<i>Out Sample</i>		
	AIC	SBC	MAPE	MSE	RMSE
ARIMA (0,1,1)	2449,6370	2452,2710	18,3422	2650372094	51481,7600
ARIMA (1,1,0)	2451,8370	2454,4720	53,0526	14989544655	122431,8000
<i>Regression Time Series</i>	2114,7000	2125,2000	11,0697	1193729388	34550,3900

Pada Tabel 4.10 dapat diketahui bahwa metode terbaik adalah metode *regression time series* karena memiliki nilai *error* yang paling kecil, dengan nilai *in sample* sebesar 2114,7000 untuk AIC dan 2125,2000 untuk SBC. Sedangkan nilai *out sample* sebesar 11,0697 untuk MAPE, 1193729388 untuk MSE dan 34550,3900 untuk RMSE. Karena metode regresi runtun waktu adalah metode terbaik dibandingkan dengan metode ARIMA maka diperoleh hasil peramalan sebagai berikut:

Tabel 4.11 Peramalan Data Produksi Karet 11 Minggu ke Depan

Minggu ke-	Peramalan Produksi Karet
Minggu ke-116	250556
Minggu ke-117	177208
Minggu ke-118	200126
Minggu ke-119	217261
Minggu ke-120	202717
Minggu ke-121	244684
Minggu ke-122	245889
Minggu ke-123	247576
Minggu ke-124	287174
Minggu ke-125	282118
Minggu ke-126	300057

Dari hasil *forecast* produksi karet di Jawa Timur diperoleh hasil paling maksimum pada minggu ke 126 yaitu sebesar 300057, sedangkan paling minimum yaitu terjadi pada minggu ke 117 yaitu sebesar 177208.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan analisis, maka diperoleh beberapa kesimpulan sebagai berikut :

1. Model yang sesuai untuk metode ARIMA adalah ARIMA (0,1,1) dengan memasukkan data yang outlier. *Error* untuk hasil ramalannya MAPE sebesar 18,34218, MSE Sebesar 2650372094, dan RMSE sebesar 51481,76.
2. Model *regression time series* dengan *outlier* menghasilkan parameter yang signifikan dan memenuhi asumsi residual identik, independen dan berdistribusi normal, dengan *R-sq (adj)* sebesar 81,1%.
3. Model terbaik yang diperoleh dari perbandingan metode ARIMA dan *regression time series* adalah metode *regression time series*. Karena pada perbandingan kedua metode, metode *regression time series* memiliki nilai *error* yang paling kecil.

5.2 Saran

Penelitian ini bisa di lanjutkan dengan menggunakan metode lain untuk mendapatkan peramalan yang lebih baik. Untuk mengetahui lebih detail tentang data produksi karet sebaiknya menggunakan data harian. Saran untuk PT Perkebunan Nusantara XII mampu mengatasi produksi karet pada saat hujan, agar pada hari tersebut produksi karet tidak nol. Karena pada evaluasi hasil analisis *outlier* pada minggu tersebut ada data yang nol.

“Halaman Ini Sengaja Dikosongkan”

DAFTAR PUSTAKA

- Arsyad, L. (1994). *Peramalan Bisnis, Edisi Pertama*. Yogyakarta: BPFE- Yogyakarta
- Bowermann, B.L dan O'Connell, R.T. (1993). *Forecasting and time series*. Belmont, California: Duxbury Press.
- Cryer, J. D. (1986). *Time Series Analisis*. Boston: Duxbury Press.
- Daniel, W. W. (1989). *Statistika Nonparametrik Terapan*. Jakarta: PT Gramedia
- Direktorat Jendral Perkebunan. (2013). *Statistik Perkebunan Indonesia Tahun 2008-2012*. Direktorat Jendral Perkebunan. Jakarta.
- Draper, R. N., dan Smith, H. (1992). *Analisis Regresi Terapan, edisi II*. Jakarta: PT Gramedia.
- Nazaruddin dan Paimin F. B. (2006). *Budidaya dan Pengolahan Strategi Pemasaran Tanaman Karet*. Penebaran Swadaya. Jakarta.
- Erni, N. (2011). *Rekayasa Sistem Manajemen Ahli Perencanaan Produksi Karet Spesifikasi Teknis*. Laporan Tesis Pasca Sarjana Institut Pertanian Bogor.
- Setiawan, D. H. (2005). *Petunjuk Lengkap Budaya Karet*. Argomedia Pustaka, Jakarta.
- Wei, W. (1990). *Time Analysis Univariate and Multivariate Methods*. New York: Person Education Inc.
- Wikipedia. (2014). *Perkebunan Karet*. Diakses 20 Januari 2014 Di situs Wikipedia [<http://id.wikipedia.org/wiki/Karet>]

“Halaman Ini Sengaja Dikosongkan”

BIODATA PENULIS



Penulis dengan nama lengkap Ridzwan Abu Yazid Al Bustani dan nama panggilan Abu dengan tempat tanggal lahir Surabaya, 20 Januari 1993 adalah anak kedua dari bapak Saifuddin dan ibu Aliyah. Penulis telah menempuh pendidikan formal di TK YPI Surabaya, SD Hang Tuah 1 Surabaya, SMP Hang tuah 1 Surabaya, SMA Trimurti Surabaya, dan melanjutkan di perguruan tinggi ITS jurusan staistika-FMIPA dengan jalur DIII reguler. Selama 3 tahun perkuliahan, penulis cukup aktif dalam kegiatan kemahasiswaan mekipun tidak termasuk dalam anggota himpunan mahasiswa diantaranya adalah *ISSMA*, Pekan Raya Statistika 2012 dan 2013, *Organizing Committe* Bina Cinta Statistika 2012, Panitia OKKKBK 2013. Selain itu, penulis juga pernah melaksanakan Kerja Praktek di Pabrik Gula Candi sidoarjo, survey Honda MPM, dan masih banyak lagi. Motto hidup penulis adalah “kegagalan adalah guru yang paling berharga”. Untuk saran dan kritik terhadap penulis atau ingin diskusi mengenai Tugas Akhir ini dapat menghubungi penulis melalui:

Email : ridzwanalbustani@[gmail.com](mailto:ridzwanalbustani@gmail.com)

Twitter : @ridzwan_abu

DAFTAR LAMPIRAN

	halaman
Lampiran A Data Produksi Karet Tahun 2012-2014	45
Lampiran B Output SAS sebelum Dimasukkan Data <i>Outlier</i>	47
Lampiran C Output SAS setelah Memasukkan Data <i>Outlier</i>	49
Lampiran D Regresi Deret Waktu	51
Lampiran E Syntak SAS	63

“Halaman Ini Sengaja Dikosongkan”

LAMPIRAN

LAMPIRAN A

Data Produksi Karet tahun 2012 - 2014

data Produksi Mingguan
162916
189474
208109
237850
222217
259377
277041
271700
257311
226409
276484
247120
350882
311559
334818
325123
341591
372729
316817
296543
325584
329282
319675

data Produksi Mingguan
315744
290940
312431
261521
259599
191275
242257
212705
184174
100793
53882
127003
132158
140211
135504
151862
124994
144501
136170
131310
163084
161982
178012

data Produksi Mingguan
177832
193510
184961
195215
199385
210730
151167
170737
209229
209801
231545
258585
271600
239022
279514
246922
268039
284134
312582
271943
257939
256652
299262

data Produksi Mingguan
294855
292164
256503
285067
270571
259044
259578
263008
278501
249787
255711
274692
287472
298916
98874
182361

data Produksi Mingguan
229346
200204
182145
181737
175184
190526
160756
166177
127300
164188
176357
176536
169821
202882
184527
177647

data Produksi Mingguan
200204
182145
250067
162512
189869
210323
192962
243058
244496
246510
293778
287743
309156
294506

LAMPIRAN B
Output SAS
Sebelum dimasukkan data *Outlier*
ARIMA (1,1,0)

Tests for Normality									
Test	--Statistic---		-----p Value-----						
Shapiro-Wilk	W	0.882061	Pr < W	<0.0001					
Kolmogorov-Smirnov	D	0.110914	Pr > D	<0.0100					
Cramer-von Mises	W-Sq	0.308218	Pr > W-Sq	<0.0050					
Anderson-Darling	A-Sq	1.986153	Pr > A-Sq	<0.0050					
Outlier Details									
Approx									
Obs	Type	Chi- Estimate	Prob> Square	ChiSq					
84	Additive	-148354.7	55.12	<.0001					
33	Shift	-103790.1	18.49	<.0001					
13	Shift	85180.3	13.04	0.0003					
104	Additive	76209.4	9.61	0.0019					
85	Additive	-60106.9	10.13	0.0015					
34	Additive	-57187.5	9.17	0.0025					
29	Additive	-54529.7	8.52	0.0035					
18	Additive	50337.9	7.33	0.0068					
53	Additive	-44600.3	6.15	0.0132					
The ARIMA Procedure									
Maximum Likelihood Estimation									
Parameter	Standard Estimate	Error	Approx t Value	Pr > t	Lag				
AR1,1	-0.29389	0.09698	-3.03	0.0024	1				
	Variance Estimate	1.2618E9							
	Std Error Estimate	35522.25							
	AIC	2451.837							
	SBC	2454.472							
	Number of Residuals	103							
Autocorrelation Check of Residuals									
Lag	Square	DF	To ChiSq	Chi- -----	Pr > -----Autocorrelations-----				
6	8.90	5	0.1131	-0.033	-0.147	-0.111	0.149	0.154	-0.037
12	14.44	11	0.2096	-0.038	0.027	0.157	0.061	-0.108	-0.076
18	22.00	17	0.1848	0.118	-0.000	-0.131	-0.162	0.061	0.020
24	28.82	23	0.1865	-0.009	-0.170	-0.077	0.074	-0.087	0.059

ARIMA (0,1,1)

Tests for Normality									
Test		--Statistic--		----p Value-----					
Shapiro-Wilk		W	0.871025	Pr < W	<0.0001				
Kolmogorov-Smirnov		D	0.112688	Pr > D	<0.0100				
Cramer-von Mises		W-Sq	0.358888	Pr > W-Sq	<0.0050				
Anderson-Darling		A-Sq	2.34608	Pr > A-Sq	<0.0050				
Outlier Details									
Approx									
	Chi-	Prob>		Square	ChiSq				
Obs	Type	Estimate							
84	Additive	-144566.9		40.44	<.0001				
33	Shift	-103526.5		15.60	<.0001				
13	Shift	86673.5		11.42	0.0007				
104	Additive	75604.6		7.64	0.0057				
34	Additive	-60174.6		7.23	0.0072				
85	Shift	-66477.6		8.65	0.0033				
29	Additive	-56479.7		8.20	0.0042				
18	Additive	47929.3		6.05	0.0139				
53	Additive	-44806.0		5.75	0.0165				
27	Shift	-49821.3		5.59	0.0181				
94	Additive	-40863.9		5.53	0.0187				
65	Additive	40045.4		5.89	0.0152				
86	Additive	39243.8		6.71	0.0096				
The ARIMA Procedure									
Maximum Likelihood Estimation									
Parameter	Standard		Approx	Pr > t	Lag				
	Estimate	Error	t Value						
MA1,1	0.36333	0.09431	3.85	0.0001	1				
Variance Estimate			1.2345E9						
Std Error Estimate			35136.05						
AIC			2449.637						
SBC			2452.271						
Number of Residuals			103						
Autocorrelation Check of Residuals									
Lag	Square	DF	To	Chi-	Pr >	-----Autocorrelations-----			
			ChiSq	-----	-----				
6	6.02	5	0.3042	0.016	-0.036	0.149	0.154	-0.008	
12	10.75	11	0.4647	-0.005	0.042	0.153	0.059	-0.084	-0.070
18	17.83	17	0.3998	0.091	-0.027	-0.131	-0.173	0.034	-0.015
24	25.70	23	0.3151	-0.029	-0.179	-0.095	0.060	-0.112	0.041

LAMPIRAN C
Output SAS
Setelah dimasukkan data *Outlier*
ARIMA (1,1,0)

The ARIMA Procedure									
Maximum Likelihood Estimation									
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift		
AR1,1	-0.37649	0.09819	-3.83	0.0001	1	pengunjung	0		
NUM1	-150524.6	23463.6	-6.42	<.0001	0	AONUM1	0		
NUM2	-108266.1	26745.9	-4.05	<.0001	0	LSNUM2	0		
Variance Estimate					8.1499E8				
Std Error Estimate					28547.99				
AIC					2408.834				
SBC					2416.738				
Number of Residuals					103				
Correlations of Parameter Estimates									
Variable		pengunjung	AONUM1	LSNUM2					
Parameter		AR1,1	NUM1	NUM2					
pengunjung	AR1,1	1.000	-0.185	0.062					
AONUM1	NUM1	-0.185	1.000	-0.011					
LSNUM2	NUM2	0.062	-0.011	1.000					
Autocorrelation Check of Residuals									
Lag	Square	DF	To ChiSq	Chi-	Pr >	-----Autocorrelations-----			
6	4.03	5	0.5445	0.088	-0.006	-0.072	0.091	0.140	-0.060
12	11.46	11	0.4054	-0.038	0.005	-0.220	-0.002	-0.068	-0.099
18	27.26	17	0.0544	0.186	-0.050	-0.047	-0.297	0.006	0.028
24	32.65	23	0.0873	-0.036	-0.072	-0.098	0.149	-0.047	-0.005

ARIMA (0,1,1)

Tests for Normality							
Test	--Statistic---		-----p Value-----				
Shapiro-Wilk	W	0.978865	Pr < W	0.0982			
Kolmogorov-Smirnov	D	0.066841	Pr > D	>0.1500			
Cramer-von Mises	W-Sq	0.077868	Pr > W-Sq	0.2250			
Anderson-Darling	A-Sq	0.569498	Pr > A-Sq	0.1409			
The SAS System			21:46 Saturday, May 22, 2014 35				
The ARIMA Procedure							
Maximum Likelihood Estimation							
Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag	Variable	Shift
MA1,1	0.33795	0.10081	3.35	0.0008	1	pengunjung	0
NUM1	-144652.4	24069.1	-6.01	<.0001	0	AONUM1	0
NUM2	-102606.0	27422.8	-3.74	0.0002	0	LSNUM2	0
Variance Estimate				8.2864E8			
Std Error Estimate				28786.18			
AIC				2410.514			
SBC				2418.418			
Number of Residuals				103			
Correlations of Parameter Estimates							
Variable	pengunjung		AONUM1	LSNUM2			
Parameter	MA1,1	NUM1	NUM1	NUM2	NUM2		
pengunjung	MA1,1	1.000	0.211	-0.158			
AONUM1	NUM1	0.211	1.000	-0.033			
LSNUM2	NUM2	-0.158	-0.033	1.000			

LAMPIRAN D

Regresi Deret Waktu

Regression Analysis: data Mingguan versus t

The regression equation is
data Mingguan = 255094 - 542 t

Predictor	Coef	SE Coef	T	P
Constant	255094	12531	20,36	0,000
t	-542,2	207,2	-2,62	0,010

S = 63434,8 R-Sq = 6,3% R-Sq(adj) = 5,4%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	1	27557785167	27557785167	6,85	0,010
Residual Error	102	4,10446E+11	4023978218		
Total	103	4,38004E+11			

Unusual Observations

data

Obs	t	Mingguan	Fit	SE Fit	Residual	St Resid
18	18	372729	245334	9476	127395	2,03R
33	33	100793	237201	7417	-136408	-2,17R
34	34	53882	236658	7307	-182776	-2,90R

R denotes an observation with a large standardized residual.

Regression Analysis: abs res1 versus t

The regression equation is
abs res1 = 66539 - 254 t

Predictor	Coef	SE Coef	T	P
Constant	66539	6480	10,27	0,000
t	-253,5	107,1	-2,37	0,020

S = 32803,9 R-Sq = 5,2% R-Sq(adj) = 4,3%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	1	6024583889	6024583889	5,60	0,020
Residual Error	102	1,09762E+11	1076097203		
Total	103	1,15786E+11			

Unusual Observations

Obs	t	abs res1	Fit	SE Fit	Residual	St Resid
18	18	127395	61975	4900	65420	2,02R
33	33	136408	58172	3836	78236	2,40R
34	34	182776	57919	3778	124858	3,83R
84	84	110673	45242	4663	65431	2,02R

R denotes an observation with a large standardized residual.

Regression Analysis: data Mingguan versus D34; yt-1; t

The regression equation is
 data Mingguan = 56370 - 77268 D34 + 0,795 yt-1 - 156 t

103 cases used, 1 cases contain missing values

Predictor	Coef	SE Coef	T	P
Constant	56370	16222	3,47	0,001
D34	-77268	36134	-2,14	0,035
yt-1	0,79470	0,05620	14,14	0,000
t	-156,5	121,2	-1,29	0,200

S = 35045,2 R-Sq = 72,0% R-Sq(adj) = 71,1%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	3	3,12317E+11	1,04106E+11	84,77	0,000
Residual Error	99	1,21588E+11	1228164480		
Total	102	4,33905E+11			

Source	DF	Seq SS
D34	1	30349655925
yt-1	1	2,79919E+11
t	1	2048000497

Unusual Observations

Obs	D34	Mingguan	Fit	SE Fit	Residual	St Resid
13	0,00	350882	250721	5829	100161	2,90R
33	0,00	100793	197569	5226	-96776	-2,79R
34	1,00	53882	53882	35045	-0	* X
84	0,00	98874	280774	7097	-181900	-5,30R
104	0,00	250067	174871	7029	75196	2,19R

R denotes an observation with a large standardized residual.

X denotes an observation whose X value gives it large leverage.

Regression Analysis: abs resi2 versus D34; yt-1; t

The regression equation is

$$\text{abs resi2} = 16004 - 19779 \text{ D34} + 0,0327 \text{ yt-1} + 14,2 \text{ t}$$

103 cases used, 1 cases contain missing values

Predictor	Coef	SE Coef	T	P
Constant	16004	11534	1,39	0,168
D34	-19779	25691	-0,77	0,443
yt-1	0,03265	0,03996	0,82	0,416
t	14,23	86,15	0,17	0,869

S = 24917,2 R-Sq = 1,6% R-Sq(adj) = 0,0%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	3	996877401	332292467	0,54	0,659
Residual Error	99	61465766016	620866323		
Total	102	62462643417			

Source	DF	Seq SS
D34	1	579663139
yt-1	1	400280450
t	1	16933812

Unusual Observations

Obs	D34	abs resi2	Fit	SE Fit	Residual	St Resid
13	0,00	100161	24259	4145	75902	3,09R
33	0,00	96776	22488	3716	74288	3,02R
34	1,00	0	0	24917	0	* X
84	0,00	181900	26960	5046	154940	6,35R
104	0,00	75196	23022	4997	52174	2,14R

R denotes an observation with a large standardized residual.

X denotes an observation whose X value gives it large leverage.

Regression Analysis: data Mingguan versus D84; D34; yt-1; t

The regression equation is

data Mingguan = 43433 - 189678 D84 - 71831 D34 + 0,838 yt-1 - 66 t

103 cases used, 1 cases contain missing values

Predictor	Coef	SE Coef	T	P
Constant	43433	13954	3,11	0,002
D84	-189678	30441	-6,23	0,000
D34	-71831	30748	-2,34	0,022
yt-1	0,83850	0,04832	17,35	0,000
t	-65,7	104,1	-0,63	0,529

S = 29809,9 R-Sq = 79,9% R-Sq(adj) = 79,1%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	4	3,46819E+11	86704792248	97,57	0,000
Residual Error	98	87085865780	888631283		
Total	102	4,33905E+11			

Source	DF	Seq SS
D84	1	16640874946
D34	1	30794866329
yt-1	1	2,99029E+11
t	1	354228287

Unusual Observations

data							
Obs	D84	Mingguan	Fit	SE Fit	Residual	St Resid	
13	0,00	350882	249787	4961	101095	3,44R	
29	0,00	191275	259199	3895	-67924	-2,30R	
33	0,00	100793	195693	4456	-94900	-3,22R	
34	0,00	53882	53882	29810	-0	*	X
53	0,00	151167	216646	3067	-65479	-2,21R	
84	1,00	98874	98874	29810	-0	*	X
85	0,00	182361	120752	6792	61609	2,12R	
104	0,00	250067	178800	6012	71267	2,44R	

R denotes an observation with a large standardized residual.

X denotes an observation whose X value gives it large leverage.

Regression Analysis: data Mingguan versus D84; D34; yt-1; t; yt-4

The regression equation is

data Mingguan = 28072 - 184512 D84 - 95813 D34 + 0,671 yt-1 - 46 t + 0,229 yt-4

100 cases used, 4 cases contain missing values

Predictor	Coef	SE Coef	T	P
Constant	28072	14556	1,93	0,057
D84	-184512	29174	-6,32	0,000
D34	-95813	30382	-3,15	0,002
yt-1	0,67088	0,06841	9,81	0,000
t	-46,3	105,9	-0,44	0,663
yt-4	0,22941	0,06475	3,54	0,001

S = 28488,7 R-Sq = 82,3% R-Sq(adj) = 81,4%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	5	3,55687E+11	71137423585	87,65	0,000
Residual Error	94	76291103046	811607479		
Total	99	4,31978E+11			

Source	DF	Seq SS
D84	1	16766071560
D34	1	30982838027
yt-1	1	2,97648E+11
t	1	103489915
yt-4	1	10186596535

Unusual Observations

Obs	D84	Mingguan	Fit	SE Fit	Residual	St Resid
13	0,00	350882	252289	5178	98593	3,52R
29	0,00	191275	267635	4674	-76360	-2,72R
33	0,00	100793	193985	4583	-93192	-3,31R
34	0,00	53882	53882	28489	-0	* X
35	0,00	127003	111398	12307	15605	0,61 X
53	0,00	151167	209427	3554	-58260	-2,06R
84	1,00	98874	98874	28489	-0	* X
104	0,00	250067	179370	5793	70697	2,53R

R denotes an observation with a large standardized residual.

X denotes an observation whose X value gives it large leverage.

Regression Analysis: data Mingguan versus t; yt-1; D34; D84; D33; D18

The regression equation is

$$\text{data Mingguan} = 50697 - 85,3 t + 0,813 \text{ yt-1} - 75887 \text{ D34} - 187759 \text{ D84} - 96874 \text{ D33} + 45758 \text{ D18}$$

103 cases used, 1 cases contain missing values

Predictor	Coef	SE Coef	T	P
Constant	50697	13302	3,81	0,000
t	-85,32	98,81	-0,86	0,390
yt-1	0,81328	0,04629	17,57	0,000
D34	-75887	29019	-2,62	0,010
D84	-187759	28716	-6,54	0,000
D33	-96874	28433	-3,41	0,001
D18	45758	28784	1,59	0,115

S = 28113,7 R-Sq = 82,5% R-Sq(adj) = 81,4%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	6	3,58028E+11	59671408302	75,50	0,000
Residual Error	96	75876584958	790381093		
Total	102	4,33905E+11			

Source	DF	Seq SS
t	1	32187315915
yt-1	1	2,74513E+11
D34	1	5615962597
D84	1	34502417784
D33	1	9211842709
D18	1	1997438112

Unusual Observations

Obs	t	Mingguan	Fit	SE Fit	Residual	St Resid
13	13	350882	250566	4763	100316	3,62R
18	18	372729	372729	28114	-0	* X
29	29	191275	259350	3752	-68075	-2,44R
33	33	100793	100793	28114	-0	* X
34	34	53882	53882	28114	-0	* X
53	53	151167	217558	2918	-66391	-2,37R
84	84	98874	98874	28114	-0	* X
85	85	182361	123857	6480	58504	2,14R
104	104	250067	179750	5689	70317	2,55R

R denotes an observation with a large standardized residual.

X denotes an observation whose X value gives it large leverage.

Regression Analysis: data Mingguan versus t; yt-1; D34; D84; D33

The regression equation is
 data Mingguan = 49203 - 96,1 t + 0,824 yt-1 - 75145 D34 - 188677 D84 - 97069 D33

103 cases used, 1 cases contain missing values

Predictor	Coef	SE Coef	T	P
Constant	49203	13372	3,68	0,000
t	-96,14	99,34	-0,97	0,336
yt-1	0,82439	0,04612	17,88	0,000
D34	-75145	29243	-2,57	0,012
D84	-188677	28935	-6,52	0,000
D33	-97069	28656	-3,39	0,001

S = 28334,2 R-Sq = 82,1% R-Sq(adj) = 81,1%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	5	3,56031E+11	71206202340	88,69	0,000
Residual Error	97	77874023070	802824980		
Total	102	4,33905E+11			

Source	DF	Seq SS
t	1	32187315915
yt-1	1	2,74513E+11
D34	1	5615962597
D84	1	34502417784
D33	1	9211842709

Unusual Observations

Obs	t	Mingguan	Fit	SE Fit	Residual	St Resid
13	13	350882	251677	4748	99205	3,55R
29	29	191275	260426	3720	-69151	-2,46R
33	33	100793	100793	28334	-0	* X
34	34	53882	53882	28334	-0	* X
53	53	151167	217832	2936	-66665	-2,37R
84	84	98874	98874	28334	-0	* X
85	85	182361	122542	6477	59819	2,17R
104	104	250067	179015	5715	71052	2,56R

R denotes an observation with a large standardized residual.

X denotes an observation whose X value gives it large leverage.

Regression Analysis: C17 versus t; yt-1; D34; D84; D33

The regression equation is

$$C17 = 24128 - 44,6 t - 0,0000 yt-1 - 22609 D34 - 20373 D84 - 22650 D33$$

103 cases used, 1 cases contain missing values

Predictor	Coef	SE Coef	T	P
Constant	24128	8351	2,89	0,005
t	-44,56	62,04	-0,72	0,474
yt-1	-0,00004	0,02880	-0,00	0,999
D34	-22609	18263	-1,24	0,219
D84	-20373	18071	-1,13	0,262
D33	-22650	17897	-1,27	0,209

S = 17695,4 R-Sq = 4,9% R-Sq(adj) = 0,0%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	5	1555550797	311110159	0,99	0,426
Residual Error	97	30373471698	313128574		
Total	102	31929022495			

Source	DF	Seq SS
t	1	158971457
yt-1	1	14681821
D34	1	473090398
D84	1	407228158
D33	1	501578963

Unusual Observations

Obs	t	C17	Fit	SE Fit	Residual	St Resid
13	13	99205	23539	2965	75666	4,34R
29	29	69151	22826	2323	46325	2,64R
33	33	0	0	17695	-0	* X
34	34	0	0	17695	-0	* X
53	53	66665	21758	1834	44907	2,55R
84	84	0	0	17695	-0	* X
85	85	59819	20336	4045	39482	2,29R
104	104	71052	19487	3569	51565	2,98R

R denotes an observation with a large standardized residual.

X denotes an observation whose X value gives it large leverage.

Regression Analysis: data Mingguan versus t; D34; D84; D33

The regression equation is

data Mingguan = 260826 - 570 t - 187554 D34 - 114047 D84 - 141213 D33

Predictor	Coef	SE Coef	T	P
Constant	260826	11784	22,13	0,000
t	-570,3	194,4	-2,93	0,004
D34	-187554	59372	-3,16	0,002
D84	-114047	59577	-1,91	0,058
D33	-141213	59384	-2,38	0,019

S = 58971,1 R-Sq = 21,4% R-Sq(adj) = 18,2%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	4	93722564293	23430641073	6,74	0,000
Residual Error	99	3,44281E+11	3477585850		
Total	103	4,38004E+11			

Source DF Seq SS

t	1	27557785167
D34	1	33856401494
D84	1	12643806594
D33	1	19664571038

Unusual Observations

Obs	t	Mingguan	Fit	SE Fit	Residual	St Resid
18	18	372729	250560	8921	122169	2,10R
33	33	100793	100793	58971	0	* X
34	34	53882	53882	58971	-0	* X
84	84	98874	98874	58971	-0	* X

R denotes an observation with a large standardized residual.

X denotes an observation whose X value gives it large leverage.

Regression Analysis: data Mingguan versus D34; D84; D33; yt-1

The regression equation is

data Mingguan = 41067 - 71623 D34 - 192604 D84 - 94562 D33 + 0,838 yt-1

103 cases used, 1 cases contain missing values

Predictor	Coef	SE Coef	T	P
Constant	41067	10395	3,95	0,000
D34	-71623	29006	-2,47	0,015
D84	-192604	28640	-6,73	0,000
D33	-94562	28530	-3,31	0,001
yt-1	0,83773	0,04399	19,04	0,000

S = 28325,0 R-Sq = 81,9% R-Sq(adj) = 81,1%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	4	3,55279E+11	88819801495	110,71	0,000
Residual Error	98	78625828792	802304375		
Total	102	4,33905E+11			

Source	DF	Seq SS
D34	1	30349655925
D84	1	17086085350
D33	1	16922328045
yt-1	1	2,90921E+11

Unusual Observations

Obs	D34	Mingguan	Fit	SE Fit	Residual	St Resid
13	0,00	350882	248087	2963	102795	3,65R
29	0,00	191275	258541	3168	-67266	-2,39R
33	0,00	100793	100793	28325	-0	* X
34	1,00	53882	53882	28325	-0	* X
53	0,00	151167	217602	2925	-66435	-2,36R
84	0,00	98874	98874	28325	-0	* X
85	0,00	182361	123897	6322	58464	2,12R
104	0,00	250067	183140	3805	66927	2,38R

R denotes an observation with a large standardized residual.

X denotes an observation whose X value gives it large leverage.

Regression Analysis: C20 versus D34; D84; D33; yt-1

The regression equation is

$$C20 = 21027 - 21396 D34 - 22121 D84 - 21701 D33 + 0,0037 yt-1$$

103 cases used, 1 cases contain missing values

Predictor	Coef	SE Coef	T	P
Constant	21027	6510	3,23	0,002
D34	-21396	18165	-1,18	0,242
D84	-22121	17936	-1,23	0,220
D33	-21701	17867	-1,21	0,227
yt-1	0,00366	0,02755	0,13	0,895

S = 17738,9 R-Sq = 4,3% R-Sq(adj) = 0,4%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	4	1397282005	349320501	1,11	0,356
Residual Error	98	30837679816	314670202		
Total	102	32234961821			

Source	DF	Seq SS
D34	1	454812421
D84	1	463818608
D33	1	473094980
yt-1	1	5555996

Unusual Observations

Obs	D34	C20	Fit	SE Fit	Residual	St Resid
13	0,00	102795	21932	1856	80863	4,58R
29	0,00	67266	21977	1984	45289	2,57R
33	0,00	0	0	17739	-0	* X
34	1,00	0	0	17739	-0	* X
53	0,00	66435	21798	1832	44637	2,53R
84	0,00	0	0	17739	-0	* X
85	0,00	58464	21389	3959	37075	2,14R
104	0,00	66927	21648	2383	45280	2,58R

R denotes an observation with a large standardized residual.

X denotes an observation whose X value gives it large leverage.

Regression Analysis: data Mingguan versus D34; D84; D33; yt-1

The regression equation is

data Mingguan = 41067 - 71623 D34 - 192604 D84 - 94562 D33 + 0,838 yt-1

103 cases used, 1 cases contain missing values

Predictor	Coef	SE Coef	T	P
Constant	41067	10395	3,95	0,000
D34	-71623	29006	-2,47	0,015
D84	-192604	28640	-6,73	0,000
D33	-94562	28530	-3,31	0,001
yt-1	0,83773	0,04399	19,04	0,000

S = 28325,0 R-Sq = 81,9% R-Sq(adj) = 81,1%

Analysis of Variance

Source	DF	SS	MS	F	P
Regression	4	3,55279E+11	88819801495	110,71	0,000
Residual Error	98	78625828792	802304375		
Total	102	4,33905E+11			

Source	DF	Seq SS
D34	1	30349655925
D84	1	17086085350
D33	1	16922328045
yt-1	1	2,90921E+11

Unusual Observations

Obs	D34	Mingguan	Fit	SE Fit	Residual	St Resid
13	0,00	350882	248087	2963	102795	3,65R
29	0,00	191275	258541	3168	-67266	-2,39R
33	0,00	100793	100793	28325	-0	* X
34	1,00	53882	53882	28325	-0	* X
53	0,00	151167	217602	2925	-66435	-2,36R
84	0,00	98874	98874	28325	-0	* X
85	0,00	182361	123897	6322	58464	2,12R
104	0,00	250067	183140	3805	66927	2,38R

R denotes an observation with a large standardized residual.

X denotes an observation whose X value gives it large leverage.

LAMPIRAN E**Syntak SAS****AR 1**

```
data produksi;
input x;
datalines;
162916
189474
208109
237850
222217
259377
277041
271700
257311
226409
276484
.
.
.
.
202882
184527
177647
184106
169592
250067
;

proc arima data=produksi;
identify var=x(1);
estimate p=(1) q=(0) noconstant method=ml;
forecast out=ramalan lead=11;
outlier maxnum=30;
run;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run;
```

Syntak SAS
MA 1

```
data produksi;
input x;
datalines;
162916
189474
208109
237850
222217
259377
277041
271700
257311
226409
.
.
.
.
169821
202882
184527
177647
184106
169592
250067
;

proc arima data=produksi;
identify var=x(1);
estimate p=(0) q=(1) noconstant method=ml;
forecast out=ramalan lead=11;
outlier maxnum=30;
run;
proc print data=ramalan;
run;
proc univariate data=ramalan normal;
var residual;
run
```


Syntak SAS***Outlier AR 1***

```
data ARIMA;
input produksi;
datalines;
162916
189474
208109
237850
222217
259377
277041
.
.
.
.
169821
202882
184527
177647
184106
169592
250067
;
data ARIMA;
set ARIMA;
if _n_=84 then AONUM1 =1; else AONUM1 =0;
if _n_>=33 then LSNUM2 =1; else LSNUM2 =0;

run;
proc arima data=ARIMA;
identify var=produksi(1)
crosscorr=(AONUM1(1) LSNUM2(1)) noprint;
estimate p=(1) q=(0) input=(AONUM1 LSNUM2 )
constant noconstant method=ml;
forecast out=ramalan lead=11;
run;
proc univariate data=ramalan normal;
var residual;
run;
```

Syntak SAS
Outlier MA 1

```
data ARIMA;
input produksi;
datalines;
162916
189474
208109
237850
222217
259377
277041
271700
.
.
.
.
169821
202882
184527
177647
184106
169592
250067
;
data ARIMA;
set ARIMA;
if _n_=84 then AONUM1 =1; else AONUM1 =0;
if _n_>=33 then LSNUM2 =1; else LSNUM2 =0;

run;
proc arima data=ARIMA;
identify var=produksi(1)
crosscorr=(AONUM1(1) LSNUM2(1)) noprint;
estimate p=(0) q=(1) input=(AONUM1 LSNUM2 )
constant noconstant method=ml;
forecast out=ramalan lead=11;
run;
proc univariate data=ramalan normal;
var residual;
run;
```