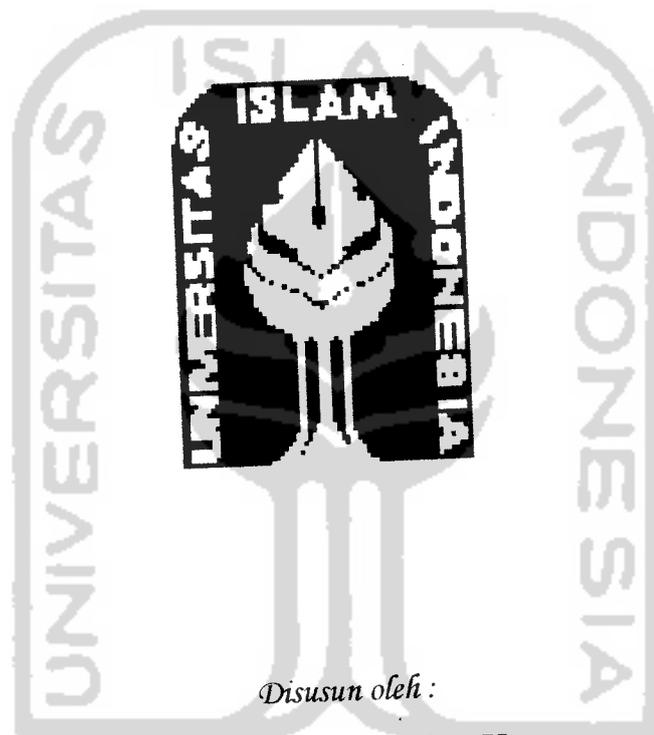


**PERAMALAN VOLUME PENJUALAN KACAMATA  
DI PERUSAHAAN OPTIK AKUR JOGJAKARTA  
DENGAN METODE BOX-JENKINS (ARIMA)**

**SKRIPSI**

Diajukan Sebagai Salah Satu Syarat Untuk Memperoleh Gelar Strata-1  
Pada Jurusan Statistika



*Disusun oleh :*

**M. Isrok. Ibrahim. H**

**NIM : 99 611 007**

**NIRM : 990051013206120007**

**JURUSAN STATISTIKA  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS ISLAM INDONESIA  
JOGJAKARTA  
2004**

**LEMBAR PENGESAHAN PEMBIMBING**

**PERAMALAN VOLUME PENJUALAN KACAMATA DI PERUSAHAAN  
OPTIK AKUR JOGJAKARTA  
DENGAN METODE BOX-JENKINS (ARIMA)**

*Disusun oleh:*



M. Isrok. Ibrahim. H  
NIM: 99 611 007  
NIRM: 990051013206120007

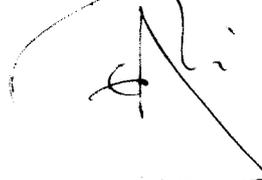
Telah dikoreksi dan disetujui pada:

Tanggal: Februari 2004



Jogjakarta, Februari 2004

Pembimbing



Drs. Gunardi, M.Si

## LEMBAR PENGESAHAN PENGUJI

### PERAMALAN VOLUME PENJUALAN KACAMATA DI PERUSAHAAN OPTIK AKUR JOGJAKARTA DENGAN METODE BOX-JENKINS (ARIMA)

*Disusun oleh:*

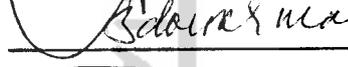
M. Isrok. Ibrahim. H

NIM: 99 611 007

NIRM: 990051013206120007

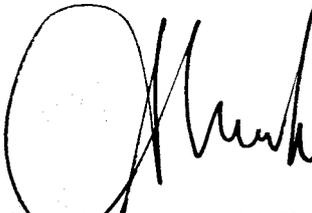
Telah dipertahankan dihadapan Panitia Penguji Skripsi Jurusan Statistika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Islam Indonesia, Jogjakarta Pada Tanggal, 1 Maret 2004 dan dinyatakan telah memenuhi syarat guna memperoleh gelar sarjana sains.

#### Susunan Tim Penguji:

Jabatan	Nama	Tanda tangan
1. Pembimbing	Drs. Gunardi, M.Si	
2. Penguji I	Jaka Nugraha, M.Si	
3. Penguji II	Drs. Abdurrahman, M.Si	
4. Penguji III	Kariyam, M.Si	

Jogjakarta, 1 Maret 2004

Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam  
Universitas Islam Indonesia

  
(Jaka Nugraha, M.Si)

## PERSEMBAHAN

Dengan penuh kesabaran, ketekunan & keikhlasan hati  
kupersembahkan hasil karyaku ini kepada:

- ❖ **Allah SWT**, yang telah memberikan taufiq, inaya, keridloan, serta lindungan-Nya sehingga tugas akhir ini dapat diselesaikan.
- ❖ **Bapak dan Ibu** tercinta atas do'a, dukungan, serta semangat yang beliau berikan selama ini semoga Allah akan membalas kebaikannya & meridloi kita semua. Amin
- ❖ Buat kakakku **Wiwik, Budi, Akbar, Natsir**, Adikku **Isah, Minah**, keponakanku **Fahmi, Fahma** yang selalu memberi keceriaan dalam hari-hariku, jangan lupa wujudkan harapan orang tua.
- ❖ Untuk seseorang yang pernah mengisi hatiku, memberii semangat, biarlah ini menjadi pengalaman, kenangan buat kita.
- ❖ Buat saudaraku, **Yogi Fridayana** (lanjutkan TA-nya....jangan bunuh aku dengan pisamu...Please dech Gpp Gilaaa lu...)
- ❖ Buat saudaraku, **Teza** (lanjutkan TA-nya, jangan pernah menyerah, teruskan perjuanganmu, arungi kehidupan yang keras dan kejam....Ok dab?)



- ❖ Buat kakakku **Edy ST** + Kak **Ena** (Semoga langgeng dan rukun-rukun aja....amien)
- ❖ Semua keluarga besar yang telah memberikan do'a dukungan, semangat, perhatian selama ini.
- ❖ Buat special sobatku **Ani** (makasih bimbingannya selama ini Thank's Very Much), **Ari** (makasih printernya), **Novia**, **Gede**, **Yeyen**.
- ❖ Buat Sohibku **Andhi**, **Yohan ST**, **Gopung**, **Ivan-k**, Dirsu, Irul, Redhan, Dimas, Arif, Meyer, Nugie, Ika, Lia terima kasih atas persahabatannya selama ini.
- ❖ Buat temen-temenku KKN Unit-83 terimakasih atas kerjasamanya.
- ❖ Buat temen-temenku Statistik angkatan 99, Adikku **Iela Imut**, **Luwis**, **Erni**, Sigit Ucok, Wartu, Novi, **Mbak wati**, Mbak yekti, Tuti, **Lia cute**, Titin, Nurul, Wirda, Ita, **Bambang** makasih atas persahabatannya semoga kita akan selalu ingat selalu.
- ❖ Buat temen-temen Sipil angkatan 99 Nur "manies", Dewi, Vicke, Sohir, Nino, Ari ST (Ableh), Pudik ST, Dek Niken (farmasi).
- ❖ Buat Yaya, Elli, Syam makasih ya....Kalian adalah temen-temen Ekonomi yang cantik-cantik dech he.....
- ❖ Buat Special **Geng Ijo** (Kapan kita berkelana lagi....Jangan Lupa Ya.....Iya Sich....)

## MOTTO

*“Sesungguhnya sesudah kesulitan itu ada kemudahan, Maka apabila kamu telah selesai (dari suatu urusan) Kerjakanlah dengan sungguh-sungguh urusan yang lain, Dan hanyalah kepada Tuhanmulah Hendaknya Kamu berharap”*  
[Q.S Al Baqoroh 45]

*“Ilmu lebih utama dari pada harta,  
Karena pemilik harta bisa mengaku menjadi Tuhan  
Akibat harta yang dimilikinya,  
Sedang orang yang berilmu justru mengaku sebagai Hamba karena  
ilmunya”*  
[Sayidina Ali]

*“Tidak akan bertambah baik segala sesuatu  
Bila kita tidak pernah berani mencoba memperbaikinya”*  
[Isrok]

*“Telah kusadari bahwa seseorang Sahabat  
Adalah karunia tersuci dari Tuhan  
Karena kasih sayang, persahabatan  
Adalah cinta tanpa pamrih”*  
[Khalil Gibran]

## KATA PENGANTAR



Assalaamu 'alaikum wr.wb.

Alhamdulillah puji dan syukur penulis panjatkan kehadiran Allah SWT yang telah melimpahkan rahmat dan berkat ridlo-Nya, sehingga penulis dapat menyelesaikan tugas akhir yang berjudul “ Peramalan Volume Penjualan Kacamata Di Perusahaan Optik Akur Jogjakarta Dengan Metode Box-Jenkins (ARIMA)”.

Penyusunan skripsi ini diajukan sebagai salah satu syarat untuk memenuhi gelar sarjana S-1 pada Jurusan Statistik, Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Islam Indonesia.

Dalam penyusunan tugas akhir ini, penulis banyak menemukan hal-hal baru dan sedikit kesulitan, namun berkat bantuan dan masukan dari berbagai pihak yang pada akhirnya dapat terselesaikan. Untuk itu dengan rasa syukur penulis ingin menyampaikan ucapan terima kasih yang sebesar-besarnya kepada :

1. Bapak Jaka Nugraha, M.Si selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Islam Indonesia.
2. Bapak Gunardi, M.Si selaku Dosen Pembimbing yang telah memberikan pengarahan dan perhatiannya untuk membimbing penulis.
3. Ibu Rohmatul Fajriyah, M.Si dan Ibu Kariyam, M.Si selaku Ketua dan Sekertaris Jurusan Statistika atas bimbingan, waktu dan didikannya.

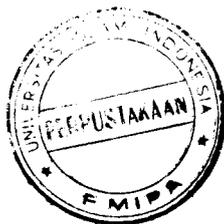
4. Bapak dan Ibu Dosen Jurusan Statistik di F-MIPA UII terima kasih untuk semua didikan, wawasan dan ilmu pengetahuan yang telah diberikan.
5. Bapak & Ibu tercinta, Kakak-kakakku dan adik-adikku dan segenap keluarga yang senantiasa memberikan do'a, kesabaran, bimbingan dan dukungan baik moril maupun materil.
6. Sahabatku *Andhi, Kang Edi, Yogi, Teza, Yohan, Ghofur, Irul, Reidhan, Dimas, Ani, Ari, Novia, Gedhe, Lela, lia, Titin, Nurul* kalian adalah sahabat sejawatku terima kasih atas segala kerjasamanya kapan bertemu lagi.
7. Teman-teman Statistik angkatan "99" kapan kita kumpul lagi.
8. Teman-teman KKN angkatan "26" unit "83" kapan kita kumpul lagi.
9. Untuk anak-anak kost Uswatun Khasanah (*Ivan-k, Meyer, Nugi, Arif, Jaka, Desta*) makasih atas kekompakkan dikost yang penuh kenangan itu.
10. Dan semua pihak yang telah membantu hingga tersusun laporan ini yang tidak bisa disebutkan satu per satu.

Akhir penulis menyadari bahwa dalam penulisan skripsi ini masih jauh dari kesempurnaan, oleh karena itu, saran dan kritik yang bersifat membangun sangat penulis harapkan. Semoga skripsi ini dapat bermanfaat bagi kita semua.

Wassalamu 'alaikum wr.wb.

Jogjakarta, Februari 2004

Penulis



## DAFTAR ISI

Halaman Judul	i
Halaman Pengesahan Pembimbing	ii
Halaman Pengesahan Penguji	iii
Halaman Persembahan	iv
Halaman Motto	vi
Kata Pengantar	vii
Daftar Isi	ix
Daftar Tabel	xiii
Daftar Gambar	xiv
Abstraksi	xvi
<b>BAB I. PENDAHULUAN</b>	<b>1</b>
1.1. Latar Belakang Masalah	1
1.2. Rumusan Masalah	3
1.3. Batasan Masalah	3
1.4. Tujuan Penelitian	4
1.5. Manfaat Penelitian	4
1.6. Metodologi Penelitian	5
1.6.1. Studi Kepustakaan	5
1.6.2. Penelitian Lapangan	5
1.6.3. Tempat dan Waktu Penelitian	5

1.6.4. Teknik Pengumpulan Data	5
1.6.5. Teknik Pengolahan Data	5
<b>BABA II. LANDASAN TEORI</b>	<b>8</b>
2.1. Metode Box Jenkins (ARIMA)	9
2.2. Fungsi Autokorelasi dan Fungsi Autoorelasi Parsial	9
2.3. Stasioneritas dan Non-Stasioneritas	9
2.3.1. Non Stasioner Mean	15
2.3.2. Non Stasioner Varian	15
2.3.3. Proses Autoregresif (AR)	17
2.3.4. Prose Moving Average (MA)	18
2.3.5. Campuran: Proses ARIMA	19
2.3.6. Verifikasi Model ARIMA	20
2.3.7. Identifikasi Model	23
2.3.7. Pemeriksaan Diagnostik	25
2.3.7.1. Forecasting	26
2.4. Mengenali Adanya Faktor Musiman (Seasonality)	
Dalam Suatu Deret Berkala	27
<b>BAB III. PENGUMPULAN DAN PENGOLAHAN DATA</b>	<b>29</b>
3.1. Objek Penelitian	29
3.2. Pengumpulan Data	31
3.3. Pengolahan Data	31
3.3.1. TS PLOT CHRISTIAN DIOR	32
3.3.2. Box-Cox Plot	33

3.3.3. Plot Trend Analisis	34
3.3.4. Plot Trend Analisis (Pembedaan Satu)	34
3.3.5. Plot Autokorelasi (ACF) dan Plot Autokorelasi Parsial (PACF)	25
3.3.6. Model ARIMA (1,1,2)	36
3.3.7. Diagnostik Check ARIMA (1,1,2)	39
3.3.8. Grafik Histogram Residual	40
3.3.9. Plot Residual Autokorelasi (ACF) dan Residual Autokorelasi Parsial (PACF)	41
3.3.10. Plot Residual Probabilitas Normal	42
3.3.11. TS PLOT RAYBAN	43
3.3.12. Box-Cox Plot	44
3.3.13. Plot Trend Analisis	45
3.3.14. Plot Trend Analisis (Pembedaan Satu)	45
3.3.15. Plot Autokorelasi (ACF) dan Plot Autokorelasi Parsial (PACF)	46
3.3.16. Model ARIMA (1,1,2)	48
3.3.17. Diagnostik Check ARIMA (1,1,2)	50
3.3.18. Grafik Histogram Residual	51
3.3.19. Plot Residual Autokorelasi (ACF) dan Residual Autokorelasi Parsial (PACF)	52
3.3.20. Plot Residual Probabilitas Normal	53
3.3.21. TS PLOT CARRARA	53

3.3.22. Box-Cox Plot	54
3.3.23. Plot Trend Analisis	55
3.3.24. Plot Trend Analisis (Pembedaan Satu)	56
3.3.25. Plot Autokorelasi (ACF) dan Plot Autokorelasi Parsial (PACF)	57
3.3.26. Model ARIMA (1,1,2)	58
3.3.27. Diagnostik Check ARIMA (1,1,2)	60
3.3.28. Grafik Histogram Residual	61
3.3.29. Plot Residual Autokorelasi (ACF) dan Residual Autokorelasi Parsial (PACF)	62
3.3.30. Plot Residual Probabilitas Normal	63
BAB IV. ANALISIS DAN PEMBAHASAN	67
BAB V. KESIMPULAN DAN SARAN	72
5.1. Kesimpulan	72
5.2. Saran	73
DAFTAR PUSTAKA	75
LAMPIRAN	



## DAFTAR TABEL

1. Tabel 2.1 Penentuan Transformasi	16
2. Tabel 3.1 Data Volume Penjualan kacamata Akur Optik Jogjakarta	76
3. Tabel 3.2 Nilai Forcest Christian Dior untuk ARIMA (1,1,2)	64
4. Tabel 3.3 Nilai Forcest Rayban untuk ARIMA (1,1,1)	65
5. Tabel 3.4 Nilai Forcest Carrara untuk ARIMA (1,1,1)	66
6. Tabel 3.5 Model ARIMA yang terpilih, tanpa konstanata	77
7. Tabel 3.6. Nilai Box-Cox Plot Transformasi	78
8. Tabel 3.7 Nilai Cek Box- Cox Plot Transformasi untuk Christian Dior	79
9. Tabel 3.8 Nilai Cek Box- Cox Plot Transformasi untuk Rayban	80
10. Tabel 3.9 Nilai Cek Box- Cox Plot Transformasi untuk Carrara	81
11. Nilai Pembedaan Satu	82
12. Nilai Peramalan 6 Bulan	83

## DAFTAR GAMBAR

1. Gambar 1.1 Skema yang Memperlihatkan Pendekatan Box-Jenkins	7
2. Gambar 3.1 TS PLOT CHRISTIAN DIOR	32
3. Gambar 3.2 Box-Cox Plot Transformasi	33
4. Gambar 3.3 Trend Analisis	34
5. Gambar 3.4 Trend Analisis (Pembedaan Satu)	34
6. Gambar 3.5 Plot Autokorelasi (ACF) dan Autokorelasi Parsial (PACF)	35
7. Gambar 3.6 Plot Residual	40
8. Gambar 3.7 Grafik Histogram Residual	40
9. Gambar 3.8 Plot Residual Autokorelasi (ACF) dan Residual Autokorelasi Parsial (PACF)	41
10. Gambar 3.9 Plot Residual Probabilitas Normal	42
11. Gambar 3.10 TS PLOT RAYBAN	43
12. Gambar 3.11 Box-Cox Plot Transformasi	44
13. Gambar 3.12 Trend Analisis	45
14. Gambar 3.13 Trend Analisis (Pembedaan Satu)	45
15. Gambar 3.14 Plot Autokorelasi (ACF) dan Autokorelasi Parsial (PACF)	46
16. Gambar 3.15 Plot Residual	50
17. Gambar 3.16 Grafik Histogram Residual	51

18. Gambar 3.17 Plot Residual Autokorelasi (ACF) dan Residual Autokorelasi Parsial (PACF)	52
20. Gambar 3.18 Plot Residual Probabilitas Normal	53
21. Gambar 3. 19 TS PLOT CARRARA	53
22. Gambar 3.20 Box-Cox Plot Transformasi	54
23. Gambar 3.21 Trend Analisis	55
24. Gambar 3.22 Trend Analisis (Pembedaan Satu)	56
25. Gambar 3.23 Plot Autokorelasi (ACF) dan Autokorelasi Parsial (PACF)	57
26. Gambar 3.24 Plot Residual	61
27. Gambar 3.25 Grafik Histogram Residual	61
28. Gambar 3.26 Plot Residual Autokorelasi (ACF) dan Residual Autokorelasi Parsial (PACF)	62
29. Gambar 3.27 Plot Residual Probabilitas Normal	63



## ABSTRAKSI

Model-model *Autoregressive Integrated Moving Average* (ARIMA) telah dipelajari secara mendalam oleh George Box dan Jenkins (1976), dan nama mereka sering disinonimkan dengan proses ARIMA yang diterapkan untuk analisis deret berkala, peramalan dan pengendalian. Model Autoregresif (AR) pertama kali diperkenalkan oleh Yule (1926) dan kemudian dikembangkan oleh Walker (1937), sedangkan model moving average (MA) pertama digunakan oleh Slutsky (1973). Akan tetapi Wold-lah (1938) yang menghasilkan dasar-dasar teoritis dari proses kombinasi ARMA. Wold membentuk model ARMA yang dikembangkan pada tiga arah: Identifikasi efisien dan prosedur penaksiran (untuk proses AR, MA dan ARMA campuran), perluasan dari hasil tersebut untuk mencakup deret berkala musiman (*seasonal time series*) dan pengembangan sederhana yang mencakup proses-proses non-stasioner (no-stationary processes) (ARIMA).

Dasar dari pendekatannya terdiri dari tiga tahap: Identifikasi, penaksiran dan pengujian serta penerapan. Pengolahan data pada model ARIMA ini dilakukan dengan program Minitab Versi 13. Dari pengolahan data tersebut dapat disimpulkan model ARIMA yang diperoleh cocok/layak digunakan untuk meramalkan volume penjualan kaca mata Optik Akur Jogjakarta.

**Kata Kunci:** *Autoregresif (AR), Moving Average (MA), ARMA Campuran, ARIMA, Minitab Versi 13.*

# BAB I

## PENDAHULUAN

### 1.1 Latar Belakang Masalah

Sistem perdagangan barang dan jasa dari waktu ke waktu terus mengalami perkembangan, baik dalam bentuk baru atau peningkatan bentuk yang sudah ada sesuai dengan permintaan konsumen. Permintaan konsumen suatu barang dipasar ditanggapi oleh pengusaha dengan menawarkan barang yang sama. Dibelakang harga penawaran suatu barang terdapat biaya produksi, biaya produksi yang rendah mempunyai harga penawaran yang rendah pula. [Marsudi D, 1994].

Begitupun dengan perdagangan kacamata yang selalu mengalami perubahan sesuai perkembangan mode yang selalu berganti-ganti, sehingga setiap perusahaan perlu mengetahui berapa barang yang harus diproduksi untuk memenuhi permintaan pasar atau meningkatkan volume penjualan. Karena salah satu tujuan utama perusahaan adalah menjual barang/produknya sebanyak mungkin untuk memperoleh keuntungan yang maksimal. Jadi perusahaan harus mengetahui hal-hal yang menyebabkan tingginya penjualan. [Supranto, 1982].

Untuk itu seorang manajer perusahaan harus mengetahui faktor-faktor yang mempengaruhi volume penjualan, baik faktor yang terkendali atau faktor yang tidak terkendali. Faktor yang terkendali adalah faktor-faktor yang berhubungan dengan perusahaan atau proses produksi, sedangkan faktor yang tidak terkendali adalah faktor dari luar perusahaan seperti keadaan negara, bencana alam, dan lain sebagainya [Subijanto, 1983].



Biaya produksi adalah salah satu faktor terkendali yang perlu diperhatikan karena biaya produksi sangat berhubungan dengan keuntungan yang diperoleh suatu perusahaan. Biaya produksi sendiri terdiri dari beberapa antara lain, biaya variabel, yaitu biaya yang dikeluarkan untuk biaya pembuatan suatu produk. Biaya variabel merupakan fungsi dari produksi sehingga muncul suatu teori bahwa semakin banyak barang yang diproduksi maka semakin banyak biaya yang dikeluarkan. Biaya variabel total selalu berubah sebanding dengan volume kegiatan perusahaan. Besar kecilnya biaya variabel mempengaruhi besar kecilnya volume penjualan. Contoh biaya variabel adalah biaya bahan baku, bahan pendukung, tenaga kerja, biaya *over head* pabrik dan lain sebagainya. Dengan demikian perusahaan harus memperhitungkan hal-hal yang berhubungan dengan biaya suatu produksi seperti khususnya biaya variabel yang digunakan dalam suatu produksi. Karena biaya variabel total ini akan berpengaruh terhadap volume penjualan. Salah satu aspek penting dalam pengelolaan suatu organisasi adalah perencanaan untuk masa depan. Kelangsungan hidup suatu organisasi dipengaruhi oleh pengelolaan yang baik, antara lain kemampuan untuk mengetahui prospek ke depan dengan menerapkan strategi yang tepat [Ansori Muslikh, 1996].

Berkaitan dengan hal itu, seorang mengambil kebijakan dalam suatu organisasi harus mempunyai latar belakang pengetahuan yang memadai tentang ilmu peramalan (*forecasting*) data. Sebagai contoh seorang peneliti pada suatu perusahaan diminta untuk memperkirakan volume penjualan suatu produk tertentu selama periode satu tahun yang akan datang. Sehingga peneliti harus mencari tahu metode apa yang cocok untuk meramalkan kondisi tersebut, karena salah

menentukan metode dapat berakibat fatal bagi pengambilan keputusan oleh seorang manajer. Dalam prakteknya masyarakat yang bergerak dalam dunia perdagangan masih banyak yang asing dan ragu-ragu untuk memanfaatkan sistem peramalan yang ada. Pemanfaatan metode peramalan dalam berbagai disiplin ilmu tersebut menjadi perhatian menarik bagi peneliti khususnya yang bekerja dalam penelitian dan konsultasi. Oleh karena itu banyak metode peramalan yang dikembangkan sesuai dengan pemanfaatan kebutuhan pada masing-masing bidang [Supranto, 1982].

Oleh sebab itu, persaingan penjualan kacamata di Jogjakarta ini sangat ketat sehingga sebuah perusahaan dituntut bagaimana dapat menjual produknya sebanyak mungkin untuk memperoleh keuntungan yang maksimal. Pada kesempatan ini penulis mencoba menentukan model peramalan yang sesuai untuk meramalkan volume penjualan kacamata, agar perusahaan kacamata ini dapat memenuhi permintaan pasar yang akan datang.

## **1.2 Rumusan Masalah**

Berdasarkan uraian diatas dapat dirumuskan permasalahan sebagai berikut:  
Bagaimana meramalkan volume penjualan kacamata dimasa yang akan datang.

## **1.3 Batasan Masalah**

Untuk membatasi ruang lingkup penelitian dan tidak melebar nya masalah yang ada, maka peneliti memberikan batasan masalah adalah sebagai berikut:

1. Jenis produk yang dianalisis adalah kacamata yang dijual Optik Akur Jogjakarta.
2. Data yang diambil adalah data bulanan volume penjualan kacamata dari tahun 1997 sampai tahun 2002.
3. Selain variabel diatas maka variabel lain dianggap konstan.
4. Mutu atau kualitas kacamata dianggap standar.
5. Alat analisis yang digunakan adalah runtun waktu metode ARIMA Box-Jenkins (*Autoregresif Integreted Moving Average*).
6. Software statistik yang digunakan dalam penelitian ini adalah MINITAB versi 13.

#### **1.4 Tujuan Penelitian**

Adapun tujuan yang ingin dicapai dari penelitian ini adalah:

Mengetahui model yang sesuai untuk meramalkan volume penjualan kaca mata di masa yang akan datang.

#### **1.5 Manfaat Penelitian**

Adapun manfaat yang diharapkan dari penelitian ini yaitu:

Dapat mengetahui model yang sesuai untuk meramalkan volume penjualan kacamata di masa yang akan datang.

## **1.6 Metodologi Penelitian**

### **1.6.1 Studi Kepustakaan**

Dilakukan dengan memanfaatkan literatur-literatur kepustakaan sebagai bahan untuk mendapatkan informasi tentang perusahaan dan dasar teori yang digunakan dalam penelitian ini.

### **1.6.2 Penelitian Lapangan**

Penelitian lapangan dilakukan dengan cara pengamatan langsung pada perusahaan yang menjadi objek penelitian dengan cara:

#### **a. Wawancara**

Dengan mengajukan pertanyaan kepada pihak perusahaan untuk melengkapi data yang diperlukan.

#### **b. Observasi**

Dengan cara melihat langsung proses, kegiatan produksi perusahaan.

### **1.6.3 Tempat dan Waktu Penelitian**

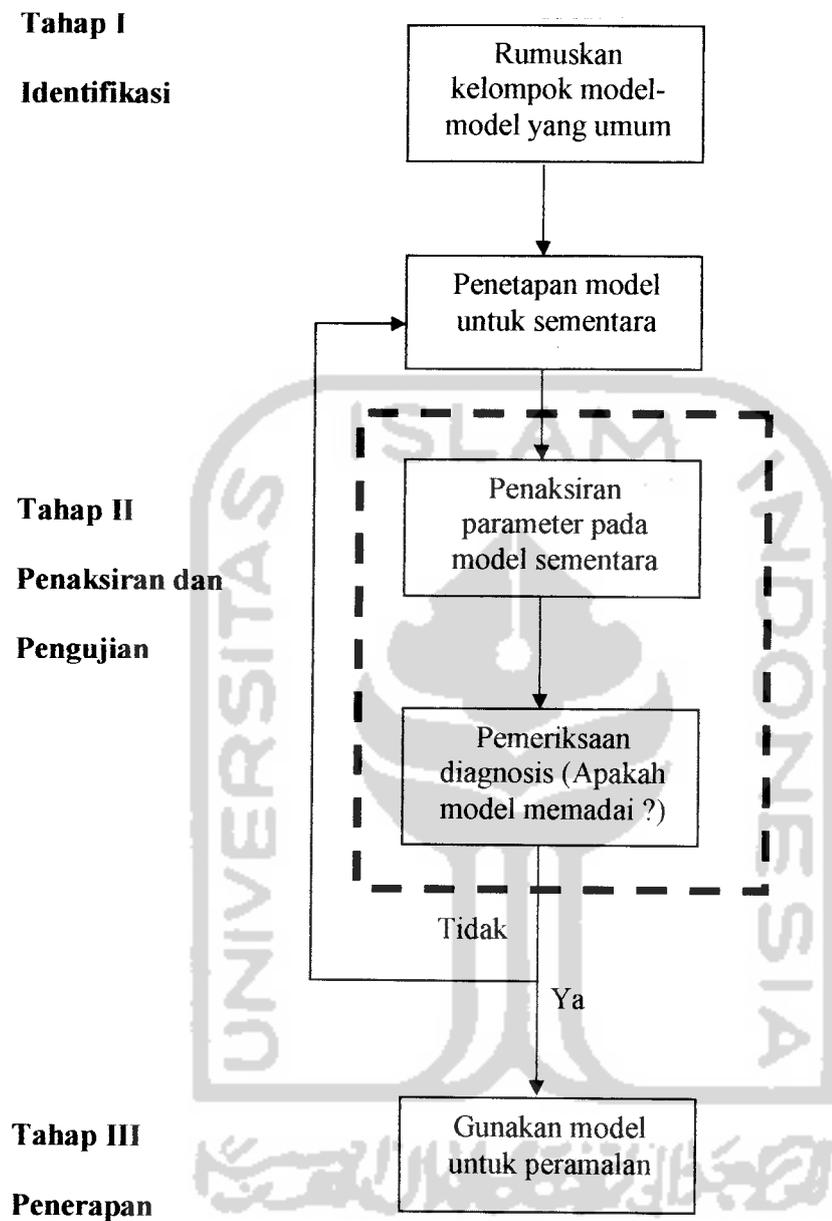
Penelitian ini dilakukan di Perusahaan Kacamata Optik Akur Jogjakarta Jalan Perwakilan No. 8 Jogjakarta. Pada tanggal 1-30 Agustus 2003.

### **1.6.4 Teknik Pengumpulan Data**

Pengumpulan data dilakukan dengan cara mengambil data sekunder yang telah dikumpulkan oleh perusahaan.

### **1.6.5 Teknik Pengolahan Data**

Pengolahan data dilakukan dengan software statistik Minitab versi 13. Ada beberapa tahap dan beberapa sub-tahap dalam proses pembentukan model ARIMA (Box-Jenkins) adalah sebagai berikut:



Gambar 1.1 Skema yang memperlihatkan pendekatan Box-Jenkins

[Makridakis dkk,1995, hal 451]

## BAB II

### LANDASAN TEORI

#### 2.1 Metode Box-Jenkins (ARIMA)

Model-model *Autoregressive Integrated Moving Average* (ARIMA) telah dipelajari secara mendalam oleh George Box dan Gwilym Jenkins (1976), dan nama mereka sering disinonimkan dengan proses ARIMA yang diterapkan untuk analisis deret berkala, peramalan dan pengendalian. Model Autoregresif (AR) pertama kali diperkenalkan oleh Yule (1926) dan kemudian dikembangkan oleh Walker (1931), sedang model Moving Average (MA) pertama kali digunakan oleh Slutsky (1937). Akan tetapi Wold-lah (1938) yang menghasilkan dasar-dasar teoritis dari proses kombinasi ARMA. Wold membentuk Model ARMA yang dikembangkan pada tiga arah yaitu identifikasi efisien dan prosedur penaksiran (untuk proses AR, MA dan ARMA campuran), perluasan dari hasil tersebut untuk mencakup deret berkala musiman (*seasonal time series*) dan pengembangan sederhana yang mencakup proses-proses non stasioner (*non-stationary processes*).

Box dan Jenkins (1976) secara efektif telah berhasil mencapai kesepakatan mengenai informasi relevan yang diperlukan untuk memahami dan memakai model-model ARIMA untuk deret berkala univariat. Dasar pendekatan ini terdiri dari tiga tahap: identifikasi, penaksiran dan pengujian serta penerapan.

Dalam metode Box-Jenkins akan dibangun model ARIMA yang merupakan proses yang stasioner. Suatu proses dikatakan stasioner jika memenuhi sifat-sifat sebagai berikut:

1.  $E(X_t) = \mu$  konstan untuk semua  $t$
2.  $Var(X_t) = \sigma^2$  konstan untuk semua  $t$
3.  $Cov(X_t, X_{t+k}) = \gamma_k$  konstan untuk semua  $t$  dan  $k \neq 0$

## 2.2 Fungsi Autokorelasi dan Fungsi Autokorelasi Parsial

### 2.1.1 Fungsi Autokorelasi (ACF)

suatu proses stasioner dari suatu data runtun waktu  $\{X_t\}$ , mempunyai mean  $E(Y_t) = \mu$  dan variansi  $Var(X_t) = E(X_t - \mu)^2 = \sigma^2$  yang konstan, dan kovariansi  $Cov(X_t, X_s)$  adalah fungsi-fungsi selang waktu  $|t-s|$  saja. Oleh karenanya, dalam kasus ini dituliskan kovariansi antara  $X_t$  dan  $X_{t+k}$  sebagai

$$\gamma_k = Cov(X_t, X_{t+k}) = E(X_t - \mu)(X_{t+k} - \mu) \quad \dots(2.1)$$

dan korelasi antara  $X_t$  dan  $X_{t+k}$  adalah

$$\rho_k = \frac{Cov(X_t, X_{t+k})}{\sqrt{Var(X_t)}\sqrt{Var(X_{t+k})}} = \frac{\gamma_k}{\gamma_0} \quad \dots(2.2)$$

dengan catatan bahwa  $Var(X_t) = Var(X_{t+k}) = \gamma_0$ . Sebagai fungsi dari  $k$ ,  $\gamma_k$  disebut sebagai fungsi autokovariansi dan  $\rho_k$  disebut sebagai fungsi autokorelasi (ACF). Dalam praktek dapat menggunakan fungsi autokovariansi sampel dan fungsi autokorelasi sampel, dimana

$$\hat{\gamma}_k = \frac{1}{T} \sum (X_t - \hat{X})(X_{t+k} - \bar{X}) \quad \dots(2.3)$$

dan

$$\hat{\rho}_k = \frac{\hat{\gamma}_k}{\hat{\gamma}_0} = \frac{\sum_{t=1}^{T-k} (X_t - \bar{X})(X_{t+k} - \bar{X})}{\sum (X_t - \bar{X})^2}, k = 0, 1, 2, \dots \quad \dots(2.4)$$

dengan  $\bar{X} = \frac{1}{T} \sum_{t=1}^T X_t$

Adapun sifat-sifat dari fungsi autokovarian  $\gamma_k$  dan fungsi autokorelasi  $\rho_k$  adalah sebagai berikut:

1.  $\gamma_0 = \text{Var}(X_t)$  dan  $\rho_0 = 1$
2.  $|\gamma_k| \leq \gamma_0$  dan  $|\rho_k| \leq 1$
3.  $\gamma_k = \gamma_{-k}$  dan  $\rho_k = \rho_{-k}$ , untuk semua k, yaitu  $\gamma_k$  dan  $\rho_k$  simetris terhadap k = 0. Sifat ini berasal dari fakta bahwa perbedaan waktu antara  $X_t$  dan  $X_{t+k}$  serta  $X_t$  dan  $X_{t-k}$  adalah sama. Karena itulah fungsi autokorelasi biasanya diplot hanya untuk lag non negatifnya saja.

### 2.2.2 Fungsi Autokorelasi Parsial (PACF)

Autokorelasi Parsial digunakan untuk mengukur tingkat keeratan  $X_t$  dan  $X_{t+k}$ , dengan menganggap ketergantungan linier pada variabel-variabel diantara keduanya yaitu  $X_{t+1}, X_{t+2}, \dots, X_{t+k-1}$  dihilangkan.

Autokorelasi parsial dapat diturunkan dengan menggunakan model regresinya, dimana variabel dependen  $X_{t+k}$  dari proses stasioner dengan mean nol diregresikan pada lag k variabel  $X_{t+k-1}, X_{t+k-2}, \dots$  dan  $X_t$

$$X_{t+k} = \phi_{k1}X_{t+k-1} + \phi_{k2}X_{t+k-2} + \dots + \phi_{kk}X_t + e_{t+k} \quad \dots(2.5)$$

dimana  $\phi_{ki}$  dinotasikan sebagai parameter regresi ke-i dan  $e_{t+k}$  adalah suatu error normal yang tidak berkorelasi dengan  $X_{t+k-1}$  untuk  $j \geq 1$ . Dengan mengalikan  $X_{t+k-j}$  pada kedua sisi persamaan (2.5) dan mengambil ekspektasinya, diperoleh:

$$\gamma_j = \phi_{k1}\gamma_{j-1} + \phi_{k2}\gamma_{j-2} + \dots + \phi_{kk}\gamma_{j-k} \quad \dots(2.6)$$

Bila persamaan (2.6) diatas dibagi dengan  $\gamma_0$  maka didapat

$$\rho_j = \phi_{k1}\rho_{j-1} + \phi_{k2}\rho_{j-2} + \dots + \phi_{kk}\rho_{j-k} \quad \dots(2.7)$$

Untuk  $j = 1, 2, \dots, k$  didapatkan sistem persamaan sebagai berikut:

$$\rho_1 = \phi_{k1}\rho_0 + \phi_{k2}\rho_1 + \dots + \phi_{kk}\rho_{k-1}$$

$$\rho_2 = \phi_{k1}\rho_1 + \phi_{k2}\rho_0 + \dots + \phi_{kk}\rho_{k-2}$$

$\vdots$

$$\rho_k = \phi_{k1}\rho_{k-1} + \phi_{k2}\rho_{k-2} + \dots + \phi_{kk}\rho_0$$

Dengan menggunakan aturan Cramer untuk  $k = 1, 2, \dots$ , didapatkan:

$$\phi_{11} = \rho_1$$

$$\phi_{22} = \frac{\begin{vmatrix} 1 & \rho \\ \rho_1 & \rho_2 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & 1 \end{vmatrix}}$$

$$\phi_{33} = \frac{\begin{vmatrix} 1 & \rho_1 & \rho_1 \\ \rho_1 & 1 & \rho_2 \\ \rho_2 & \rho_1 & \rho_3 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_1 \\ \rho_2 & \rho_1 & 1 \end{vmatrix}}$$

$$\phi_{kk} = \frac{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_{k-2} & \rho_1 \\ \rho_1 & 1 & \rho_1 & \cdots & \rho_{k-3} & \rho_2 \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & \rho_1 & \rho_k \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_{k-2} & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & \cdots & \rho_{k-3} & \rho_{k-2} \\ \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & \rho_1 & 1 \end{vmatrix}} \dots(2.8)$$

Jadi autokorelasi parsial antara  $X_t$  dan  $X_{t+k}$  dapat diperoleh sebagai koefisien regresi yang berhubungan dengan  $X_t$  dan  $X_{t+k}$  pada k lag variabel dari dirinya yaitu  $X_{t+k-1}, X_{t+k-2}, \dots$  dan  $X_t$ .  $\phi_{kk}$  menjadi notasi standar untuk autokorelasi parsial antara  $X_t$  dan  $X_{t+k}$  dalam analisis runtun waktu.

Selanjutnya akan dibahas cara pemakaian autokorelasi parsial untuk menetapkan model ARIMA yang tepat. Apabila proses yang mendasari diperolehnya rangkaian runtun waktu adalah model AR(1), maka harus dimengerti bahwa hanya  $\phi_1$  yang secara nyata akan berbeda dari nol, sedangkan  $\phi_2, \phi_3, \dots, \phi_{m-1}, \phi_m$ , tidak akan berbeda nyata secara statistika. Apabila proses pembangkit yang sebenarnya adalah AR(2), maka hanya  $\phi_1$  dan  $\phi_2$  yang akan berbeda nyata dari nol, sedangkan  $\phi_3, \phi_4, \dots, \phi_{m-1}, \phi_m$  tidak akan berbeda secara statistika. hal ini juga berlaku untuk proses AR dengan orde yang lebih tinggi.

Dengan kata lain, karena cara pembentukan  $\phi_1, \phi_2, \phi_3, \dots, \phi_{m-1}, \phi_m$ , maka koefisien yang akan berbeda nyata dari nol hanya sampai pada orde proses AR yang digunakan untuk membangkitkan data. dalam identifikasi model kemudian diasumsikan bahwa apabila hanya terdapat dua autokorelasi parsial yang berbeda nyata dari nol, maka proses pembangkitnya berorde dua dan orde peramalannya adalah AR(2). Apabila ada  $p$  autokorelasi parsial yang signifikan, maka orde yang digunakan haruslah AR( $p$ ).

Untuk tujuan identifikasi, apabila proses tersebut adalah suatu proses autoregresif (koefisien-koefisien autokorelasinya turun mendekati nol secara eksponensial), maka autokorelasi parsial dapat diuji untuk menetapkan orde proses tersebut. Orde tersebut adalah sama dengan jumlah autokorelasi parsial yang signifikan.

Apabila proses pembentukan datanya adalah MA (*Moving Average*) bukan AR (*Autoregressive*), maka autokorelasi parsial tidak akan menunjukkan orde proses MA tersebut, karena nilai tersebut dibentuk untuk mencocokkan proses AR. Kenyataannya, nilai tersebut menunjukkan suatu ketergantungan dari satu lag ke lag berikutnya yang membuatnya menyerupai cara autokorelasi untuk proses AR. Autokorelasi parsial akan menurun secara eksponensial. Untuk tujuan identifikasi, apabila autokorelasi parsial tidak memperlihatkan penurunan nilai secara acak sesudah  $p$  waktu lag, melainkan menurun sampai nol secara eksponensial, hal ini dapat diasumsikan bahwa proses pembangkit yang sebenarnya adalah MA.

Sebagai ringkasan, apabila hanya terdapat  $p$  autokorelasi parsial signifikan berbeda dari nol, maka diasumsikan bahwa proses tersebut adalah  $AR(p)$ . Jika autokorelasi parsial menurun secara eksponensial, proses tersebut diasumsikan sebagai proses MA.

Kemudian memperoleh estimasi parameter-parameter dalam model ARIMA yaitu  $\phi_i$  untuk proses AR dan  $\theta_j$  untuk proses MA adalah dengan menggunakan bantuan computer. Dengan penentuan nilai  $p$  dan  $q$  pun biasanya tidak besar, dengan memperbesar  $p$  atau  $q$  pada umumnya akan memperkecil MSE namun persamaan untuk model ARIMA mungkin akan menjadi tidak efisien apabila model memuat koefisien AR atau MA yang tidak signifikan di dalamnya.

### 2.3 Stasioneritas dan Non-stasioneritas

Bentuk visual dari suatu plot runtun waktu sering kali cukup untuk meyakinkan para peramal bahwa data tersebut adalah stasioner atau tidak stasioner, demikian pula plot autokorelasi dapat dengan mudah memperlihatkan ketidakstasioneran. Nilai-nilai autokorelasi dari data stasioner akan turun sampai dengan nol sesudah time lag kedua atau ketiga, sedangkan untuk data yang tidak stasioner, nilai-nilai tersebut signifikan berbeda dari nol untuk beberapa periode waktu. Apabila disajikan secara grafik, autokorelasi data yang tidak stasioner memperlihatkan suatu trend searah diagonal dari kanan ke kiri bersama dengan meningkat jumlah time lag (selisih waktu).

### 2.3.1 Non Stasioner Mean

#### 2.3.1.1 Model Trend Deterministik

Mean dari fungsi sebuah proses non stasioner dapat dituliskan dalam sebuah trend deterministik dari waktu. Model regresi standar dapat digunakan untuk melukiskan fenomena tersebut. Sebagai contoh, jika mean fungsi  $\mu_t$  mengikuti trend linier,  $\mu_t = \alpha_0 + \alpha_1 t$ , kita dapat menggunakan model trend linier deterministik  $X_t = \alpha_0 + \alpha_1 t + a_t$ , dengan  $a_t$  merupakan deret *white noise* dengan mean nol. Secara umum, jika trend deterministik dapat dituliskan sebagai polynomial orde  $k$  dari waktu, kita dapat dituliskan proses sebagai  $X_t = \alpha_0 + \alpha_1 t + \dots + \alpha_k t^k$ .

#### 2.3.1.2 Model Trend Stokastik dan Pembedaan (differencing)

Sebuah deret non stasioner homogen dapat dijadikan deret yang stasioner dengan mengambil pembedaan (difference) yang sesuai. Dengan kata lain deret  $\{X_t\}$  adalah non stasioner, tetapi setelah pembedaan tingkat  $d$  dari deret tersebut  $\{(1-B)^d X_t\}$ , untuk beberapa bilangan bulat  $d \geq 1$ , adalah stasioner. Mean dari proses  $X_t$  dalam  $(1-B)^d X_t$  untuk  $d \geq 1$  berubah sepanjang waktu secara stokastik, dan digolongkan proses tersebut mempunyai trend stokastik.

#### 2.3.1.3 Non Stasioner Variansi

Ketidakstasioneran dalam variansi dapat dihilangkan dengan melakukan transformasi untuk menstabilkan variansi. Misalkan  $T(X_t)$  adalah fungsi transformasi dari  $X_t$  maka menurut Box dan Cox (1964) untuk menstabilkan variansi, kita dapat menggunakan transformasi kuasa (*the power transformation*)

$T(X_t) = X_t^{(\lambda)} = \frac{X_t^\lambda - 1}{\lambda}$ , dengan  $\lambda$  disebut parameter transformasi. Beberapa

nilai  $\lambda$  yang umum digunakan adalah sebagai berikut:

Nilai $\lambda$	Transformasi
-1	$1/X_t$
-0,5	$1/\sqrt{X_t}$
0	$\ln X_t$
0,5	$\sqrt{X_t}$
1	$X_t$ (tidak ada transformasi)

Apabila data deret waktu tersebut tidak stasioner, maka perlu dilakukan pengolahan data untuk merubah data yang non-stasioner menjadi data yang stasioner yaitu dengan melakukan pembedaan atau transformasi. Rumus yang digunakan adalah sebagai berikut:

$$BX_t = X_{t-1} \quad \dots(2.9)$$

Di mana  $B$  = adalah pembeda

$X_t$  = adalah nilai  $X$  pada orde ke- $t$

$X_{t-1}$  = adalah nilai  $X$  pada orde ke- $t-1$

Artinya, notasi  $B$  yang dipasang pada  $X_t$  mempunyai pengaruh menggeser data 1 periode kebelakang. Sebagai contoh, apabila diinginkan untuk mengalihkan perhatian ke keadaan pada “bulanan yang sama pada tahun sebelumnya”, maka digunakan  $B^{12}$  dan notasinya adalah  $B^{12} X_t = X_{t-12}$ . Tujuan dilakukan pembedaan adalah untuk mencapai stasioneritas, dan secara umum pembeda orde ke- $d$  untuk mencapai stasioneritas akan kita tulis sebagai berikut:

**Pembeda Orde ke-d****ARIMA (0,d,0)**

$$X^d = (1-B)^d X_t \quad \dots(2.10)$$

Sebagai deret yang stasioner, maka model ARIMA (0,2,0) akan menjadi:

**ARIMA (0, 2, 0)**

$$(1-B)^2 X_t = e_t$$

↑
↑  
 (pembeda orde ke 2)    (nilai kesalahan)

... (2.11)

Dan perlu diingat bahwa ARIMA (0,2,0) mempunyai arti, bahwa data setelah dilakukan pembedaan tidak mengandung aspek *Autoregresif* (AR), tidak mengandung aspek *Moving Average* (MA) dan mengalami pembedaan sebanyak dua kali. [Spyros Makridakis dkk, 1995, hal 382-383].

**2.4 Proses Autoregresif (AR)**

Secara umum untuk proses *Autoregresif* (AR) orde  $p$ , maka akan diperoleh bentuk sebagai berikut: [Spyros Makridakis dkk, 1995, hal 385].

**ARIMA (p,0,0)**

$$X_t = \mu' - \phi_1 X_{t-1} + \phi_2 X_{t-2} - \dots + \phi_k X_{t-p} + e_t \quad \dots(2.12)$$

- Di mana:
- $\mu'$  = nilai konstanta
  - $\phi_1, \phi_2, \dots, \phi_k$  = parameter *Autoregresif* (AR) ke- $k$
  - $e_t$  = nilai kesalahan pada saat orde ke- $t$
  - $X_{t-p}$  = nilai data pada saat  $t-p$

***Tahap 1 : Identifikasi***

1-1: Merumuskan kelompok model-model yang umum.

1-2: Penetapan model untuk sementara.

***Tahap 2 : Penaksiran dan Pengujian***

2-1: Penaksiran parameter pada model sementara.

2-2: Pemeriksaan diagnosa (Apakah model memadai).

***Tahap 3 : Penerapan***

3-1: Penggunaan model untuk peramalan.



Sekarang, dengan menggunakan operator *shif* mundur, maka untuk nilai  $p = 1$  atau model AR (1) akan diperoleh persamaan sebagai berikut:

**ARIMA (1,0,0)**

$$(1 - \phi_1 B) X_t = \mu' - e_t$$

Selain persamaan diatas, ada satu persamaan yang harus diingat untuk suatu model *Autoregresif* (AR) pada orde  $p$ , persamaan Yule-Walker yaitu sebagai berikut: [Spyros Makridakis dkk, 1995, hal 407].

$$\begin{aligned} \text{Untuk model AR (1)} \quad & \phi_1 = r_1 \\ \text{Untuk model AR (2)} \quad & \phi_1 = \frac{r_1(1-r_2)}{1-r_1^2} \quad \dots(2.13) \end{aligned}$$

Keterangan:  $r_1, r_2$  = nilai koefisien autokorelasi parsial

$\phi_1, \phi_2$  = nilai parameter untuk model *Autoregresif* (AR)

## 2.5 Proses *Moving Average* (MA)

Proses *Moving Average* (MA) berorde  $q$  secara umum dapat ditulis sebagai berikut: [Spyros Makridakis dkk, 1995, hal 388].

**ARIMA (0,0,q)**

$$X_t = \mu' - e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_k e_{t-q} \quad \dots(2.14)$$

Di mana:  $\mu'$  = nilai konstanta

$\theta_1, \theta_2, \dots, \theta_k$  = parameter *Moving Average* (MA) ke- $k$

$e_{t-q}$  = nilai kesalahan pada  $t-q$ .

$\theta_1, \theta_2, \dots, \theta_k$  = parameter *Moving Average* (MA) ke-  $k$

$e_{t-k}$  = nilai kesalahan pada  $t-k$ .

Sekarang, dengan menggunakan operator *shif* mundur, maka untuk nilai  $p = 1$  dan  $q = 2$  atau model ARIMA (1,0,2) akan diperoleh persamaan sebagai berikut:

### ARIMA (1,0,2)

$$(1 - \phi_1) X_{t-1} = \mu' + (1 - \theta_1 B - \theta_2 B^2) e_t$$

↑  
AR (1)

↑  
MA (2)

Dalam persamaan diatas model ARIMA yang terbentuk adalah seperti persamaan regresi biasa, kecuali bahwa terdapat lebih dari satu nilai kesalahan pada ruas sebelah kanan persamaan. [Spyros Makridakis dkk, 1995, hal 394].

## 2.7 Verifikasi Model ARIMA

Langkah selanjutnya dalam metode Box-Jenkins yakni memeriksa apakah model yang kita estimasi cukup cocok dengan data yang ada. Biasanya dalam langkah verifikasi akan diperoleh bagaimana model yang kurang sesuai itu dimodifikasi menjadi model baru. Apabila diperlukan model lain yang lebih luas maka dapat dilakukan *overfitting*. Selanjutnya setelah *overfitting* dilakukan akan diperoleh beberapa model, sehingga perlu diingat tentang prinsip parsimony yaitu dari model yang sederhana diharapkan mempunyai informasi sebanyak mungkin atau kesimpulan yang signifikan. Dengan membandingkan nilai *Sum Square Residualnya*, dipilih yang terkecil. Namun jika melalui langkah perbandingan



*Sum Square Residual* semua model menunjukkan nilai yang tidak berbeda secara signifikan, maka pemilihan terakhir ditujukan pada model yang memiliki parameter paling sedikit. Di dalam *overfitting* model ARIMA ada dua hal yang perlu di uji untuk menetapkan model yang sesuai, yaitu [Zanzawi S, 1995, hal 6.20].

• **Uji Overall**

Uji yang digunakan untuk menguji apakah data antar pengamatan independen satu sama lain, residual antara nilai peramalan dan nilai sebenarnya kecil, dan dipandang sebagai observasi random dengan mean nol dan variansi satu. Statistik uji yang digunakan adalah uji chi kuadrat ( $\chi^2$ ), yang dikenal dengan statistik Box-Pierce Q seperti dibawah ini. [Lincoln Arsyad, 1999, 294].

1. Uji Hipotesa

$H_0 : \varepsilon_k = 0$  (Residual bersifat random).

$H_1 : \varepsilon_k \neq 0$  (Residual tidak bersifat random)

2. Tingkat Signifikan ( $\alpha$ ),  $\chi^2_{(\alpha-m-p-q)}$

3. Daerah Kritis

Terima  $H_0$  jika  $\chi^2_{hitung} \leq \chi^2_{tabel}$

Tolak  $H_0$  jika  $\chi^2_{hitung} > \chi^2_{tabel}$

4. Statistik Uji

$$Q = (N - d) \sum_{k=1}^m r_k^2$$

Dimana  $N =$  banyaknya pengamatan

$k$  = otokorelasi k pertama yang di uji

$m$  = jumlah lag maksimum yang di uji

$r_k$  = fungsi otokorelasi sampel dari residual ke-k

$d$  = tingkat pembeda

## 5 Kesimpulan.

### • Uji Parsial

Dasar pemikiran pengambilan estimasi parameter adalah jika absolut / tidak sama dengan nol dan besar, maka hipotesis nol nilai-nilai parameter sama dengan nol ditolak. Dan hipotesis satu bagi nilai-nilai parameter tidak sama dengan nol tidak ditolak. Hal ini berarti parameter dapat dimasukkan dalam model.

#### 1. Uji Hipotesa

$H_0$  : nilai parameter  $\phi_i, \theta_i = 0$  dimana  $i = 1, 2$ .

$H_1$  : nilai parameter  $\phi_i, \theta_i \neq 0$

#### 2. Tingkat Signifikansi ( $\alpha$ ), $t_{tabel}(\frac{\alpha}{2}, n - p - d - q)$ .

#### 3. Daerah Kritis

Terima  $H_0$  jika  $T_{hitung} \leq T_{tabel}$ .

Tolak  $H_0$  jika  $T_{hitung} > T_{tabel}$  atau  $-T_{hitung} < -T_{tabel}$

#### 4. Statistik Uji

$$T_{hitung} \text{ AR} = \frac{S_{\phi_k}}{\phi_k}$$

$$T_{hitung} \text{ MA} = \frac{S_{\theta_k}}{\theta_k}$$

Dimana,  $S_{\phi_k}$  = standar deviasi dari *autoregresif*

$S_{\theta_k}$  = standar deviasi dari *moving average*

$\phi_k$  = nilai parameter *autoregresif* ke- $k$ ,

$k = 0, 1, 2$ .

$\theta_k$  = nilai parameter *moving average* ke- $k$ ,

$k = 0, 1, 2$ .

## 5. Kesimpulan

### 2.8 Identifikasi Model

Identifikasi model merupakan metodologi dalam mengidentifikasi transformasi yang diperlukan, seperti transformasi untuk menstabilkan variansi dan pembedaan (*differencing*), dan menentukan orde  $p$  dan  $q$  yang sesuai untuk model.

#### Langkah 1

Plot data runtun waktu dan pilih transformasi yang sesuai.

Dalam banyak analisis runtun waktu, langkah pertama biasanya adalah memplot data. Melalui pengujian yang seksama terhadap plot, biasanya dapat mengetahui apakah data mengandung trend, musiman, pencilan, variansi yang tidak konstan, dan fenomena ketidakstasioneran dan ketidaknormalan lainnya. Dalam analisis runtun waktu, transformasi untuk menstabilkan variansi dan *differencing* (pembedaan). Karena *differencing* mungkin menghasilkan nilai negatif, maka sebaiknya transformasi untuk menstabilkan variansi dilakukan sebelum

*differencing*. Deret yang memiliki variansi tidak konstan biasanya memerlukan transformasi logaritma.

### **Langkah 2**

Hitung dan uji ACF dan PACF sample dari deret asli untuk mengetahui apakah diperlukan *differencing*.

### **Langkah 3**

Hitung dan uji ACF dan PACF sampel dari data yang telah ditransformasi atau di-*difference* untuk mengidentifikasi orde dari  $p$  dan  $q$ . Biasanya orde dari  $p$  dan  $q$  kurang dari atau sama dengan 3.

## **2.9 Estimasi Parameter**

Setelah berhasil menetapkan identifikasi model sementara, selanjutnya parameter-parameter dari AR dan MA, musiman dan tidak musiman harus ditetapkan dengan cara yang terbaik. Kita menginginkan taksiran nilai yang terbaik untuk mencocokkan runtun waktu yang sedang dimodelkan. Ada dua cara yang mendasar untuk mendapatkan parameter-parameter tersebut:

1. Dengan cara mencoba-coba, menguji beberapa nilai yang berbeda dan memilih salah satu nilai tersebut yang meminimumkan jumlah kuadrat nilai sisa (*sum of squared residual*).
2. Perbaiki secara, iteratif, memilih taksiran awal dan kemudian membiarkan program computer memperhalus penaksiran tersebut secara iteratif.

## 2.10 Pemeriksaan Diagnostik

Pembentukan model runtun waktu merupakan suatu prosedur iteratif. Dimulai dari identifikasi model dan estimasi parameter. Setelah estimasi parameter, kemudian memeriksa apakah asumsi dari terpenuhi. Asumsi dasar adalah bahwa  $\{a_t\}$  adalah proses *white noise*, yaitu  $a_t$  adalah *random shock* yang tidak berkorelasi dan memiliki mean nol dan variansi konstan. Pemeriksaan diagnostic dilakukan melalui analisis terhadap residual dari deret  $\{\hat{a}_t\}$ , karena deret residual merupakan produk dari estimasi parameter. Untuk memeriksa apakah error berdistribusi normal, dapat membuat histogram dari residual terstandarisasi (*standardized residuals*)  $\hat{a}_t/\hat{\sigma}_a$  dan membandingkannya dengan distribusi normal dengan menggunakan uji *goodness of fit chi-square*. Untuk memeriksa apakah residual merupakan proses *white noise*, dapat dihitung ACF dan PACF sampel dari residual dan dapat dilihat apakah tidak menunjukkan pola tertentu dan semuanya tidak signifikan. Uji lain yang berguna adalah uji *Portmanteau lack of fit*. Uji ini menggunakan ACF sample dari residual untuk mengecek hipotesis nol  $H_0 = \rho_1 = \rho_2 = \dots = \rho_k$ , dengan statistik uji  $Q = (N - d) \sum_{k=1}^m r_k^2$ . Statistik Q secara pendekatan mengikuti distribusi  $\chi^2(K - m)$ , dimana m adalah jumlah dari parameter yang diestimasi.

### a. Overfitting

Yang dimaksud dengan *overfitting* yaitu menggunakan beberapa parameter lebih banyak dari pada yang diperlukan, atau memilih AR orde

kedua bilamana AR orde pertama telah ditetapkan. [Makridakis dkk, hal 488 – 489].

Hal ini dapat dilakukan jika :

- Estimasi dari parameter tambahan secara tidak signifikan berbeda dengan nol.
- Estimasi dari parameter model awal (sebelum dilakukan penambahan parameter) tidak berubah secara signifikan setelah dilakukan penambahan parameter.
- Jika model dengan parameter tambahan menyebabkan *Sum Square Error* bertambah besar, maka model yang digunakan adalah model semula (awal).

## 2.11 Forecasting

Langkah terakhir dalam proses runtun waktu adalah peramalan runtun waktu di masa mendatang berdasarkan tingkah geraknya di masa lalu (data sebelumnya).

Sebagai contoh, digambarkan sebagai berikut :

Model ARIMA  $(0,1,1)(0,1,1)^2$

$$(1-B)(1-B^{12})X_t = (1 - \theta_1 B)(1 - \theta_1 B^{12})e_t \quad \dots(2.17)$$

Namun agar dapat menggunakan suatu model yang ditetapkan untuk peramalan, perlu dilakukan pengembangan persamaan tersebut dan membuatnya lebih menyerupai persamaan regresi biasa. Untuk model diatas, bentuknya adalah :

$$X_t = X_{t-1} + X_{t-12} - X_{t-13} + e_t - \theta_1 e_{t-1} - \theta_1 e_{t-12} + \theta_1 \theta_1 e_{t-13} \quad \dots(2.18)$$

Agar dapat menggunakan persamaan ini untuk meramalkan 1 periode ke depan, yaitu  $X_{t+1}$  kita tambahkan satu angka pada yang menunjukkan waktu (ditambah garis) seperti pada persamaan di bawah ini :

$$X_{t+1} = X_t + X_{t-1} - X_{t-2} + e_{t+1} - \theta_1 e_t - \theta_2 e_{t-1} + \theta_1 \theta_2 e_{t-2}. \quad \dots(2.19)$$

Nilai  $e_{t+1}$  tidak akan diketahui, karena nilai yang diharapkan untuk galat acak pada masa yang akan datang harus ditetapkan sama dengan nol. Akan tetapi dari model yang disesuaikan (*fitted model*) kita boleh mengganti model nilai  $e_t$ ,  $e_{t-1}$  dan  $e_{t-2}$  dengan nilai mereka yang ditetapkan secara empiris yaitu, seperti yang diperoleh sesudah iterasi terakhir algoritma Marquardt. Tentu saja bila kita meramalkan jauh kedepan, tidak akan kita peroleh nilai empiris untuk "e" sesudah beberapa waktu, dan oleh sebab itu nilai harapan mereka akan seluruhnya nol.

Untuk nilai-nilai  $X$ , pada awal proses peramalan, kita akan mengetahui nilai  $X_t$ ,  $X_{t-1}$ , dan  $X_{t-2}$ . Akan tetapi sesudah beberapa saat, nilai  $X$  pada persamaan diatas akan berupa nilai ramalan (*forecasted value*), bukan nilai-nilai masa lalu yang telah diketahui.

## 2.12 Mengenali Adanya Faktor musiman (*Seasonality*) dalam suatu Deret

### Berkala

Musiman didefinisikan sebagai pola yang berulang-ulang dalam selang waktu yang tetap. Sebagai contoh, penjualan untuk alat pemanas, adalah tinggi pada musim dingin dan rendah pada musim panas yang memperlihatkan suatu pola musim 12 bulan. Apabila pola tersebut konsisten, maka koefisien autokorelasi dengan lag 12 bulan akan mempunyai nilai positif yang tinggi yang

memperlihatkan adanya pengaruh musiman. Apabila signifikansinya tidak berbeda dari nol, ini akan memperlihatkan bahwa bulan-bulan di dalam satu tahun adalah tidak berhubungan (random) dan tanpa pola yang konsisten dari satu tahun kepada tahun berikutnya. Data seperti ini bukanlah data musiman (*seasonal*). [Spyros Makridakis dkk, 1995, hal 356].

Untuk data yang stasioner, faktor musiman dapat ditentukan dengan mengidentifikasi koefisien autokorelasi pada dua atau tiga time-lag yang berbeda nyata dari nol. Autokorelasi yang secara signifikan berbeda dari nol menyatakan adanya suatu pola dalam data. Untuk mengenali adanya faktor musiman seseorang harus melihat pada autokorelasi yang tinggi.

Adanya faktor musim dapat dengan mudah dilihat di dalam grafik autokorelasi atau dilihat sepiintas pada autokorelasi dari time-lag yang berbeda, apabila hanya ini pola yang ada. Namun, hal ini tidaklah selalu mudah apabila dikombinasikan dengan pola lain seperti trend. Semakin kuat pengaruh trend akan semakin tidak jelas adanya faktor musim, karena secara relatif besarnya autokorelasi yang positif merupakan hasil dari adanya ketidakstasioneran data (adanya trend). Sebagai pedoman, data tersebut harus ditransformasikan ke bentuk yang stasioner sebelum ditentukan adanya faktor musim.

Sekarang, dengan menggunakan operator *shif* mundur, maka untuk nilai  $q = 2$  atau model MA (2) akan diperoleh persamaan sebagai berikut:

### **ARIMA (0,0,2)**

$$X_t = \mu' + (1 - \theta_1 B - \theta_2 B^2) e_t$$

Selain persamaan diatas, ada satu persamaan yang harus diingat untuk suatu model *Moving Average* pada orde  $q$ , persamaan Yule-Walker yaitu sebagai berikut: [Spyros Makridakis dkk, 1995, hal 408].

$$\begin{aligned} \text{Untuk model MA (1)} \quad r_1 &= \frac{-\theta_1}{1 + \theta_1^2} \\ \text{Untuk model MA (2)} \quad r_1 &= \frac{-\theta_1 + \theta_1 \theta_2}{1 + \theta_1^2 + \theta_2^2} \\ r_2 &= \frac{-\theta_2}{1 + \theta_1^2 + \theta_2^2} \quad \dots(2.15) \end{aligned}$$

Keterangan:  $r_1, r_2$  = nilai koefisien autokorelasi  
 $\theta_1, \theta_2$  = nilai parameter untuk model *Moving Average* (MA)

## **2.6 Campuran: Proses ARIMA**

Apabila non-stasioner ditambahkan pada proses campuran ARIMA, maka model umum ARIMA  $(p,d,q)$  terpenuhi. Persamaan untuk kasus yang paling sederhana, ARIMA  $(p,0,q)$  diperoleh persamaan sebagai berikut:

### **ARIMA (p,0,q)**

$$\phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_k X_{t-p} = \mu' + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_k e_{t-q} \dots(2.16)$$

Di mana:  $\mu'$  = nilai konstanta

$\phi_1, \phi_2, \dots, \phi_k$  = parameter *Autoregresif* (AR) ke- $k$

## BAB III

### PENGUMPULAN DAN PENGOLAHAN DATA

#### 3.1. Objek Penelitian

Penelitian dilakukan di Perusahaan Kacamata Jogjakarta yang bergerak dalam bidang penjualan kacamata dan jasa reparasi. Usaha ini didirikan pada tahun 1940 oleh almarhum Tn. Alwy Barekbah dan langsung dipimpin oleh beliau.

Usaha kacamata ini semula didirikan dengan modal usaha yang relatif kecil. Disamping itu lokasi usahanya pun masih sangat sederhana, peralatan yang dimiliki belum selengkap sekarang, penjualannya masih dalam kuantitas yang kecil serta dengan macam dan jenis yang masih sangat terbatas. Tetapi karena Tn. Alwi Barekbah adalah seorang yang mempunyai jiwa usaha yang dinamis serta didukung oleh keuletannya maka usaha yang dijalankannya tersebut terus berkembang dari tahun ketahun.

Semenjak tahun 1950 beliau mulai mencurahkan perhatiannya hanya pada bidang optik, yaitu bidang yang khusus menangani masalah penglihatan dan kesehatannya. Usaha ini ternyata mendapatkan hasil yang sangat menggembirakan, sehingga enam tahun kemudian beliau mengganti nama usahanya menjadi "Optik Akur". Dengan perubahan nama tersebut diharapkan masyarakat akan lebih cepat dan lebih mudah mengingat nama perusahaan tersebut. Hal ini tidak kecil artinya bagi perkembangan usaha selanjutnya. Selain itu juga diharapkan masyarakat akan lebih mengenal dan semakin yakin bahwa

Perkembangan yang berhasil dicapai tidak hanya sampai di situ. Pada tahun 1964 mulai dibuka cabang pertama di Magelang. Kemudian dalam jangka waktu relatif singkat kemajuan perusahaan menuntut dibukanya cabang-cabang baru yang lain. Sehingga secara berturut-turut berdiri beberapa cabang yaitu :

- Cabang di Jl. KHA. Dahlan 36, Yogyakarta.
- Cabang di Jl. Pasar 1, Yogyakarta.
- Cabang di Kendal, Semarang.
- Cabang di Jl. Solo 71, Yogyakarta.
- Cabang di Jl. Perwakilan No. 8

Sebagai pusat dari cabang-cabang tersebut di atas adalah optik akur yang berada di Jl. Perwakilan 8, Yogyakarta.

### **3.2. Pengumpulan Data**

Data yang diambil dalam penelitian ini adalah data sekunder yang telah dikumpulkan oleh perusahaan pada waktu sebelumnya, dan disajikan dalam tabel yang sistematis dan terencana.

### **3.3. Pengolahan Data**

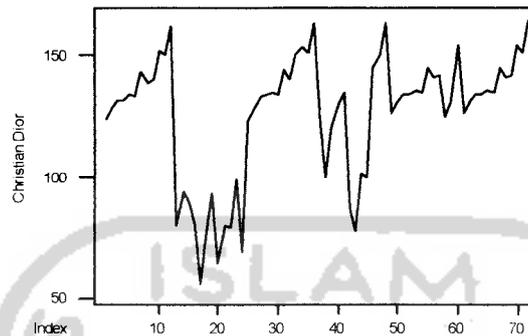
Pengolahan data dalam bentuk data asli dilakukan dengan paket program minitab versi 13 antara lain sebagai berikut:

Dari data asli kemudian akan dilakukan analisis untuk meramalkan volume penjualan kacamata dengan metode ARIMA, dengan langkah-langkah sebagai berikut:



Membuat plot dari data asli:

### 1. TS PLOT CHRISTIAN DIOR

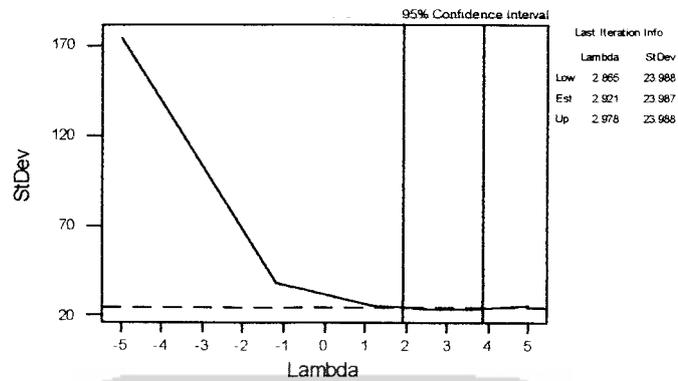


Gambar 3.1 Plot data volume penjualan kacamata merk Cristian Dior

Dari grafik diatas untuk menerapkan metodologi Box-Jenkins pertama kali menganggap bahwa data runtun waktu yang akan di analisis bersifat stasioner. Selanjutnya dilakukan tahap untuk mengetahui apakah data tersebut sudah stasioner baik dalam mean ataupun dalam varian.

Didapat output sebagai berikut:

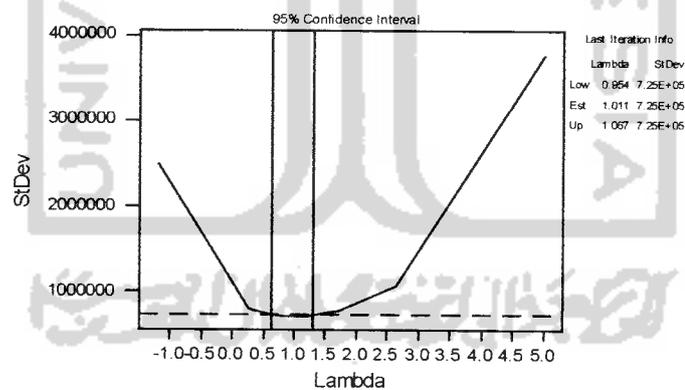
Box-Cox Plot for Christian Di



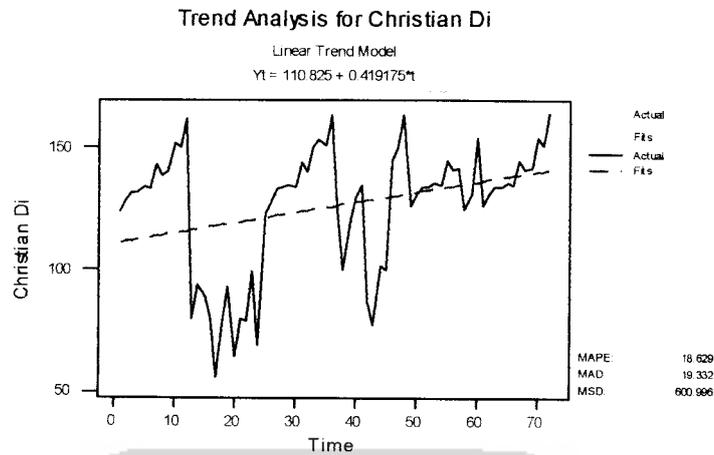
Gambar 3.2 Grafik Box-Cox Plot volume penjualan kacamata merk Cristian Dior

Dari gambar diatas diperoleh nilai dari lambda sebesar 2.921. Sehingga data harus ditransformasikan dengan nilai  $Z' = Z^3$  dan diperoleh lambda sebesar 1.011 maka transformasi tidak perlu dilakukan.

Box-Cox Plot for Christian Di

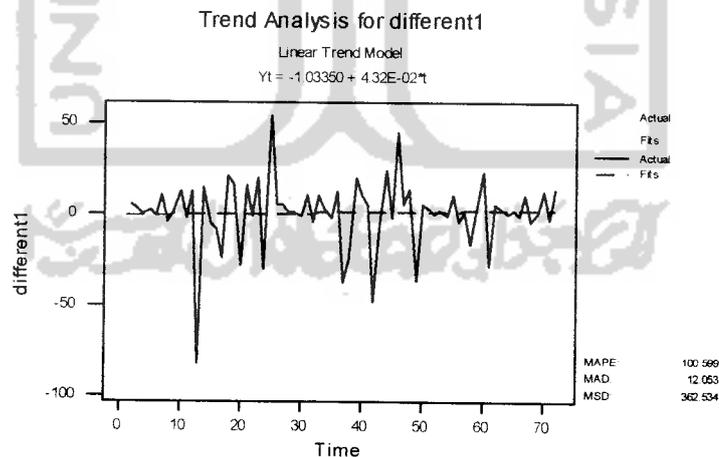


Gambar 3.3 Grafik Box-Cox Plot volume penjualan kacamata merk Cristian Dior



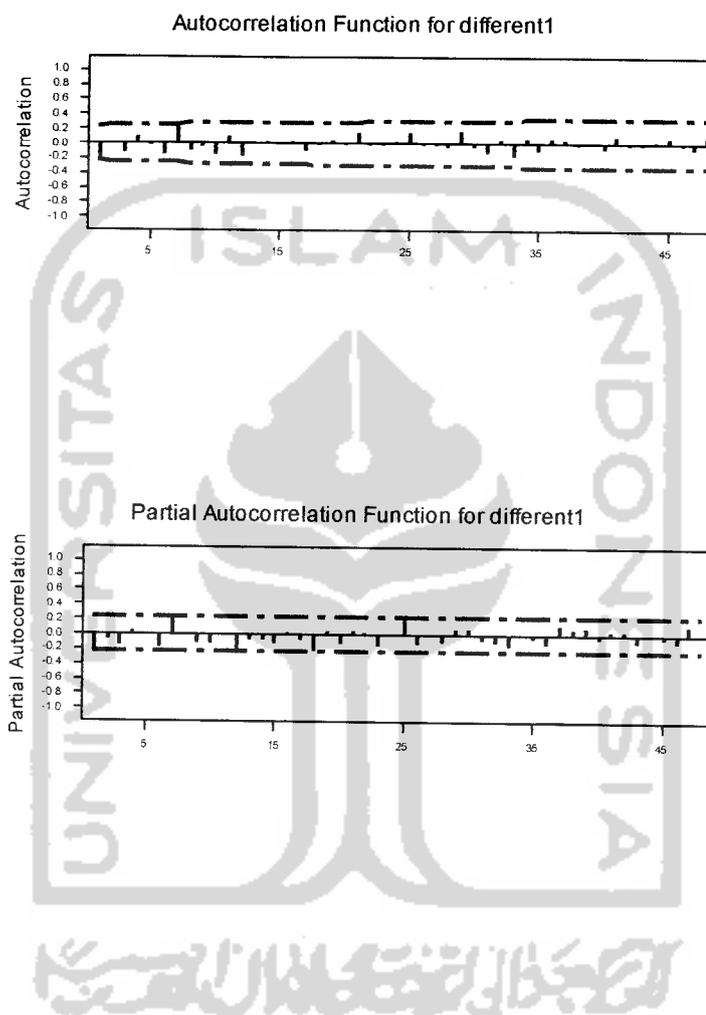
Gambar 3.4 Plot trend analisis Christian Dior sebelum dilakukan pembedaan

Dari grafik diatas dapat dilihat bahwa data yang telah di transformasi belum memenuhi asumsi stasioner, yaitu bahwa meannya belum konstan. Sehingga langkah berikutnya adalah melakukan pembedaan 1 (*differences*). Sehingga seiring dengan waktu nilai rata-rata dapat berubah. Berikut hasil data yang telah mengalami pembedaan 1:



Gambar 3.5 Plot Trend analisis data Chirstian Dior setelah dilakukan pembedaan satu

Dari grafik diatas dapat dilihat bahwa garis biru atau model trend diatas telah konstan. Dan kebetulan konstan di nilai  $-1,03350$  dengan nilai trend sebesar  $0,0432$ . Sehingga dengan perbedaan 1 diperoleh data telah konstan dalam rata-rata sehingga asumsi kestasioneran dari data runtun waktu telah terpenuhi.



Gambar 3.6 Plot Autokorelasi setelah di defferent (ACF) dan Autokorelasi Parsial (PACF) setelah di defferent

Dari grafik diatas memperlihatkan bahwa deret berkala tidak musiman dimana plot autokorelasi memberikan indikasi non stasioneritas dan plot data juga memperjelas keadaan tersebut. Parsial pertama adalah dominan yang didalam

kasus ini menunjukkan sifat non-stasioneritas. Dari grafik autokorelasi diatas memperlihatkan pola gelombang sinus dan terdapat dua parsial yang signifikan. Ini memberikan kesan bahwa proses AR (1) yang ditandai dengan adanya satu nilai pertama yang berbeda secara signifikan dengan nol. Begitupun dengan autokorelasi yang menunjukkan proses moving average MA (2) yang ditandai dengan adanya dua nilai pertama yang berbeda secara signifikan dengan nol.

Berdasarkan sifat-sifat fungsi autokorelasi parsial, maka diperoleh model-model yang diperkirakan cocok atau layak untuk data yang dimiliki adalah ARIMA (0,1,1), ARIMA (1,1,0), ARIMA (1,1,2). Pemilihan model dilakukan dengan menguji signifikan parameter. Setelah itu dilakukan diagnostic check masing-masing model untuk menguji apakah model yang telah dipilih sudah layak untuk digunakan atau belum. *Diagnostic check* yang dilakukan disini adalah melakukan analisis residual. Jika semua perkiraan model memenuhi asumsi, langkah berikutnya adalah membandingkan nilai *Sum Square Residualnya*, dipilih yang terkecil. Namun jika melalui langkah perbandingan *Sum Square Residual* semua model menunjukkan nilai yang tidak berbeda secara signifikan, maka pemilihan terakhir ditujukan pada model yang memiliki parameter paling sedikit.

• **ARIMA(1,1,2)**

Final Estimates of Parameters

Type		Coef	SE Coef	T	P
AR	1	0.8169	0.0837	9.76	0.000
MA	1	1.1600	0.0080	144.47	0.000
MA	2	-0.1781	0.0423	-4.21	0.000

Differencing: 1 regular difference

Number of observations: Original series 72, after differencing 71

Residuals: SS = 22674.1 (backforecasts excluded)  
MS = 333.4 DF = 68

Modified Box-Pierce (Ljung-Box) Chi-Square statistic				
Lag	12	24	36	48
Chi-Square	12.4	18.0	33.2	38.3
DF	9	21	33	45
P-Value	0.191	0.647	0.456	0.749

### • Uji Overall

#### 1. Hipotesa

$H_0$ : Model sesuai / layak

$H_1$ : Model tidak sesuai / layak dipakai

#### 2. Tingkat Signifikan ( $\alpha$ ), $\chi^2_{(\alpha-m-p-q)}$

#### 3. Daerah Kritis

Terima  $H_0$  jika  $\chi^2_{hitung} \leq \chi^2_{tabel}$

Tolak  $H_0$  jika  $\chi^2_{hitung} > \chi^2_{tabel}$

#### 4. Statistik Uji

$$Q = (N - d) \sum_{k=1}^m r_k^2$$

#### 5. Kesimpulan

Dari tingkat signifikan 5% diperoleh nilai  $38,3 < 64,20$  maka  $H_0$  tidak ditolak artinya model dikatakan sesuai atau layak dipakai untuk peramalan

- Uji Parsial

- a. Uji Koefisien AR(1)

- 1. Hipotesis :

$$H_0 : \phi_1 = 0, \theta_1 = 0 \text{ atau } \theta_2 = 0$$

$$H_1 : \phi_1 \neq 0, \theta_1 \neq 0 \text{ atau } \theta_2 \neq 0$$

- 2. Tingkat signifikansi 0,05

- 3. Daerah kritik :  $H_0$  ditolak jika p-value  $< 0,05$

Hasil : AR(1), p-value = 0,000  $< 0,05$  berarti  $H_0$  ditolak

- 4. Dari data diatas dapat diambil kesimpulan bahwa AR(1) signifikan terhadap model.

$$SS \text{ Residual} = 22674.1$$

$$MS = 333.4$$

- b. Uji Koefisien MA(1)

- 1. Hipotesis :

$$H_0 : \phi_1 = 0, \theta_1 = 0 \text{ atau } \theta_2 = 0$$

$$H_1 : \phi_1 \neq 0, \theta_1 \neq 0 \text{ atau } \theta_2 \neq 0$$

- 2. Tingkat signifikansi 0,05

- 3. Daerah kritik :  $H_0$  ditolak jika p-value  $< 0,05$

Hasil : MA(1), p-value = 0,000  $< 0,05$  berarti  $H_0$  ditolak

- 4. Dari data diatas dapat diambil kesimpulan bahwa MA(1) signifikan terhadap model.

$$SS \text{ Residual} = 22674.1$$

$$MS = 333.4$$

c. Uji Koefisien MA(2)

1. Hipotesis :

$$H_0 : \phi_1 = 0, \theta_1 = 0 \text{ atau } \theta_2 = 0$$

$$H_1 : \phi_1 \neq 0, \theta_1 \neq 0 \text{ atau } \theta_2 \neq 0$$

2. Tingkat signifikansi 0,05

3. Daerah kritik :  $H_0$  ditolak jika p-value  $< 0,05$

Hasil : MA(2), p-value = 0,000  $< 0,05$  berarti  $H_0$  ditolak

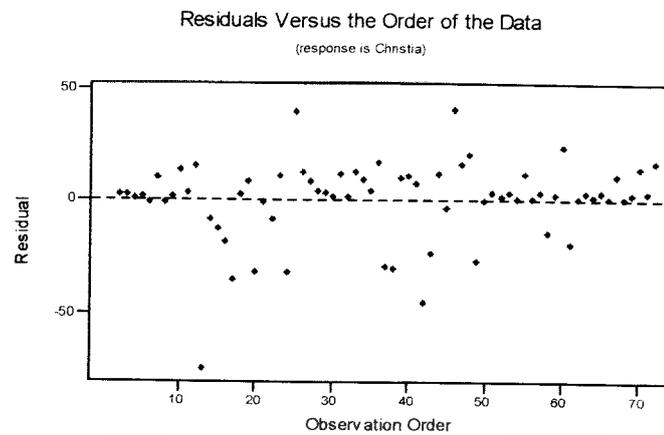
4. Dari data diatas dapat diambil kesimpulan bahwa MA(2) signifikan terhadap model.

$$SS \text{ Residual} = 22674.1$$

$$MS = 333.4$$

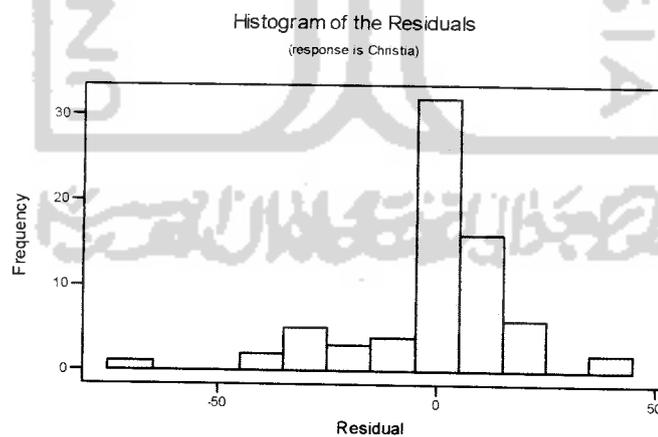
**Diagnostic check ARIMA (1,1,2)**

Memeriksa gambar "*plot of residual overtime*". Model dikatakan baik jika data-data dari residual menyebar secara acak disekitar garis 0 dan tidak membentuk suatu pola.



Gambar 3.7 Plot residual data asli

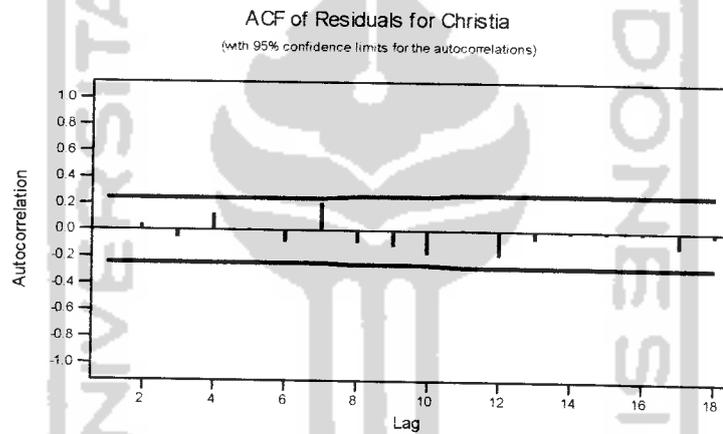
Dari gambar diatas, Residu tersebut tidak membentuk suatu pola tertentu dan menyebar secara acak. Sehingga dapat disimpulkan bahwa model ini layak. Kenormalan dari data residual merupakan salah satu faktor asumsi yang harus terpenuhi. Untuk menganalisa hal ini dapat dilihat dari histogram of residualnya, seperti dibawah ini:



Gambar 3.8 Grafik Histogram residual data asli

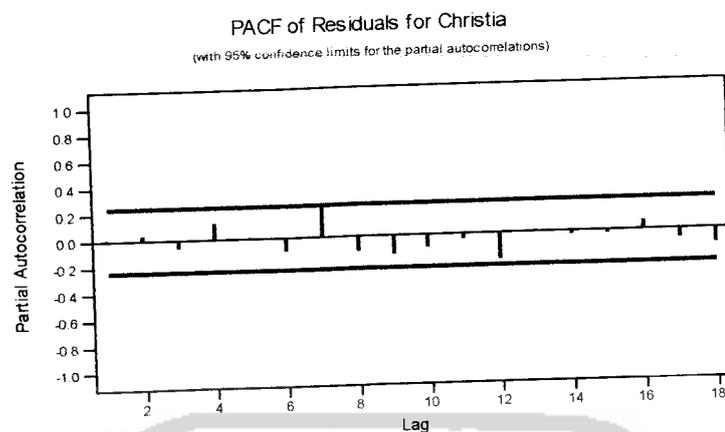
Gambar diatas memperlihatkan, bahwa data residual cenderung membentuk distribusi normal. Dari informasi tadi dapat disimpulkan bahwa residual berdistribusi normal.

Untuk memeriksa independensi dalam model dengan membuat plot fungsi autokorelasi. Model dikatakan layak jika fungsi autokorelasi untuk lag 1, 2, ....dst tidak secara signifikan berbeda dengan nol. Jika ada 1 lag yang secara independen berbeda dengan nol, berarti tidak independen. Ini dikarenakan nilai korelasi tersebut merupakan estimasi, jadi akan selalu mengandung resiko kesalahan.



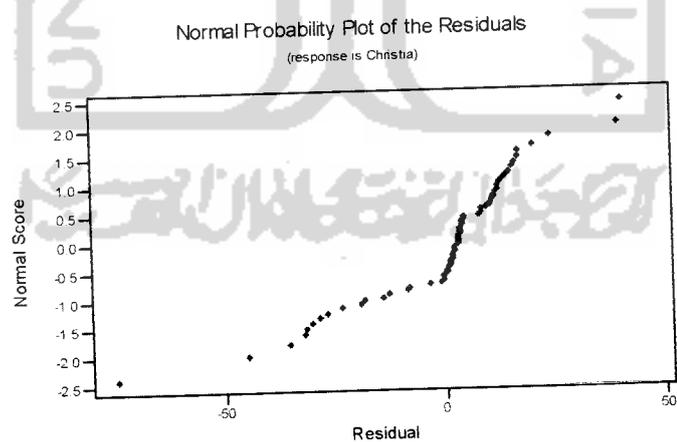
perusahaan dapat menyediakan kebutuhan akan kacamata serta kesehatannya dengan berbagai pilihan merk, model dan ukuran yang tepat sesuai dengan kebutuhan dan selera calon pembeli.

Pada tahun 1962, pucuk pimpinan perusahaan diserahkan anak beliau yang bernama H. AM. Alwy. Hal ini disebabkan karena Tn. Alwi Berekbah sudah merasa tua, kemampuan yang dapat disumbangkan untuk kemajuan usahanya sudah semakin menurun. Dan beliau percaya bahwa ditangan anaknya usaha optik ini akan semakin berkembang. Ternyata apa yang menjadi perkiraan Tn. Alwy Berekbah adalah benar. H. AM. Alwy selain melanjutkan usaha yang telah dirintis oleh ayahanda juga terus melakukan usaha-usaha pembaharuan. Diantaranya yang dirasa banyak memberikan kemajuan adalah usaha beliau untuk memperdalam pengetahuan optikalnya keluar negeri. Hal ini dimaksudkan agar perkembangan teknologi perkacamataan selalu dapat diikuti. Dengan demikian maka terbuka kesempatan bagi usahanya untuk selalu menyesuaikan dengan perkembangan optik modern. Dengan semakin luasnya pengetahuan yang dimiliki berarti terbuka pula kesempatan untuk bersaing dengan perusahaan optik terkemuka yang lain. Selain usaha diatas, H. AM. Alwy terus berupaya untuk memperbaiki sistem manajemen perusahaan. Pelayanan semakin ditingkatkan misalnya dengan lebih selektif dalam menjaga kualitas barang-barang yang ditawarkan. Yang cukup menjadi perhatiannya pula adalah masalah promosi sebagai usaha untuk meningkatkan volume penjualan. Segala usaha yang telah dilakukan tersebut, berhasil menjadikan optik akur sebagai salah satu optik yang modern dan eksklusif.



Gambar 3.9 Plot residual Autokorelasi (ACF) dan residual Autokorelasi Parsial (PACF)

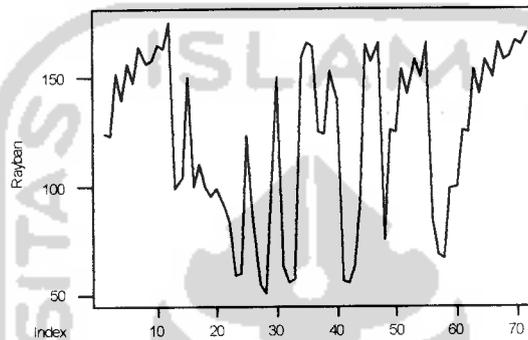
Fungsi autokorelasi dan autokorelasi parsial untuk lag 1, 2, ...dst tidak secara signifikan berbeda dari nol. Dengan demikian model dikatakan layak. Dan ada satu analisis lagi untuk memenuhi asumsi residual, yaitu memeriksa kelinieran dari residual. Model dikatakan layak jika residual tersebut cenderung membentuk garis lurus atau linier.



Gambar 3.10 Plot residual probabilitas normal data asli

Dari gambar diatas, residual dari model cenderung membentuk satu garis lurus, maka model dikatakan layak. Setelah semua asumsi dari model ARIMA (1,1,2) terpenuhi maka model ini layak digunakan untuk data yang dimiliki.

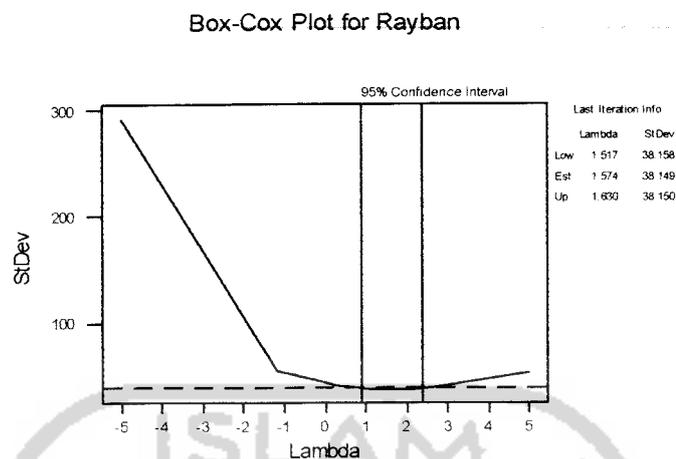
## 2. TS PLOT RAYBAN



Gambar 3.11 Plot data volume penjualan kacamata merk Rayban

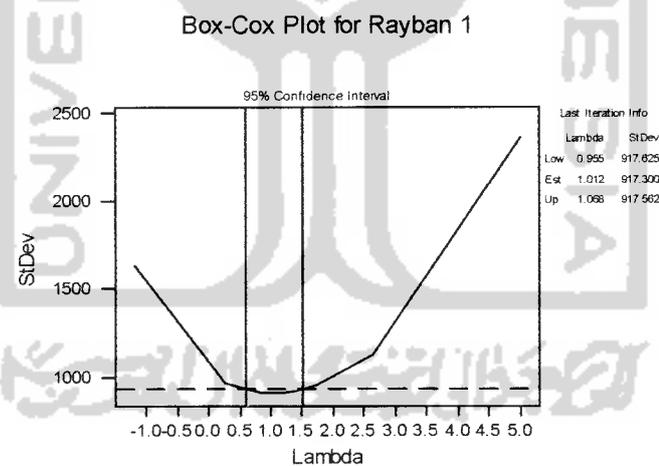
Dari grafik diatas untuk menerapkan metodologi Box-Jenkins pertama kali menganggap bahwa data runtun waktu yang akan di analisis bersifat stasioner. Selanjutnya dilakukan tahap untuk mengetahui apakah data tersebut sudah stasioner baik dalam mean ataupun dalam varian.

Didapat output sebagai berikut:

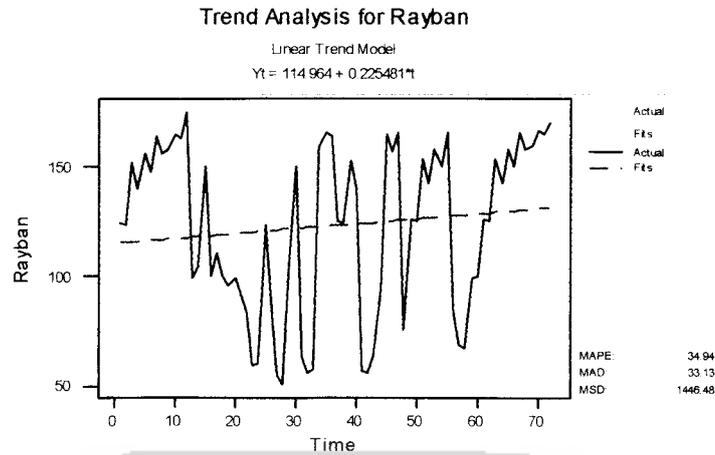


Gambar 3.12 Grafik Box-Cox Plot volume penjualan kacamata merk Rayban

Dari gambar diatas diperoleh nilai dari lambda sebesar 1,574. Sehingga data harus ditransformasikan dengan nilai  $Z' = Z^2$  dan diperoleh nilai lambda sebesar 1.012 maka transformasi tidak perlu dilakukan.

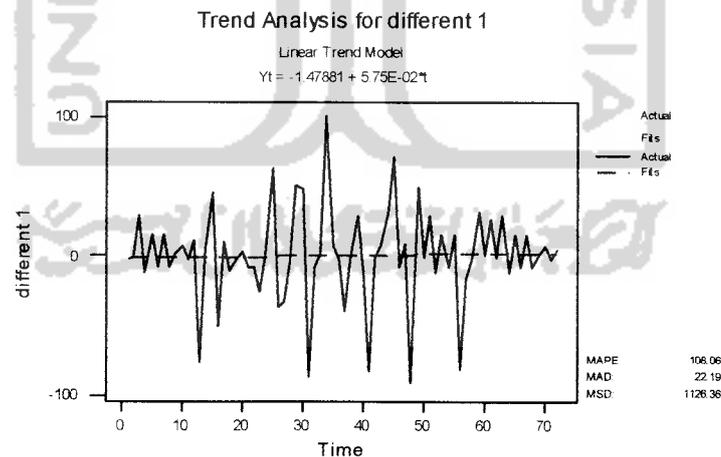


Gambar 3.13 Grafik Box-Cox Plot volume penjualan kacamata merk Rayban



Gambar 3.14 Trend analisis Rayban sebelum dilakukan pembedaan

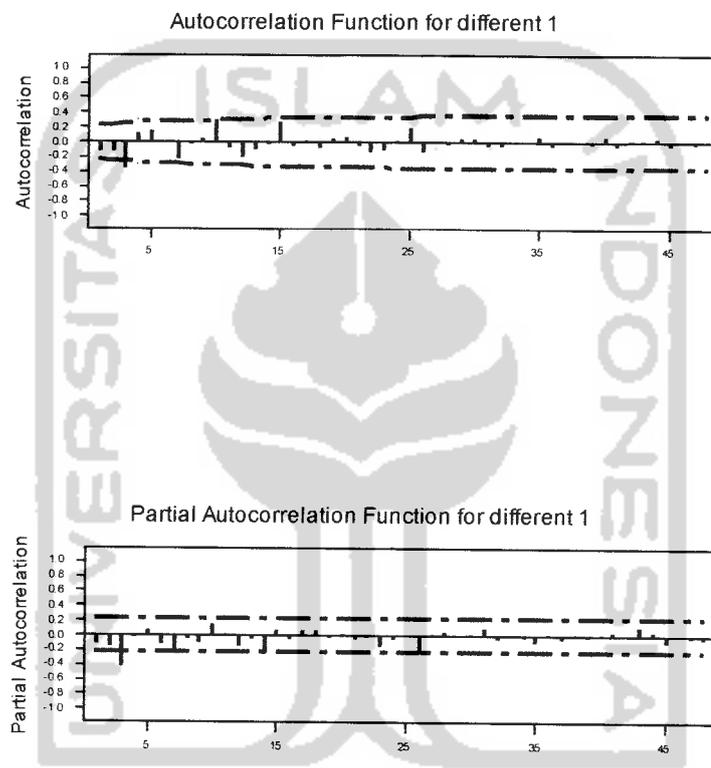
Dari grafik TS Plot diatas dapat diamati bahwa data belum memenuhi asumsi stasioner, yaitu bahwa meannya belum konstan. Sehingga langkah berikutnya adalah melakukan pembedaan 1 (*differences*). Sehingga seiring dengan waktu nilai rata-rata dapat berubah. Berikut hasil data yang telah mengalami pembedaan 1:



Gambar 3.15 Plot trend analisis Rayban setelah dilakukan pembedaan Satu



Dari grafik diatas dapat diamati bahwa garis biru atau model trend diatas telah konstan. Dan kebetulan konstan di nilai  $-1,47881$  dengan nilai trend sebesar  $0,0575$ . Sehingga dengan pembedaan 1 telah didapatkan bahwa data telah konstan dalam rata-rata sehingga asumsi kestasioneran dari data runtun waktu telah terpenuhi.



Gambar 3.16 Plot Autokorelasi (ACF) dan autokorelasi parsial (PACF) setelah dilakukan pembedaan

Dari grafik diatas memperlihatkan bahwa deret berkala tidak musiman dimana plot autokorelasi memberikan indikasi non-stasioneritas dan plot data juga memperjelas keadaan tersebut. Parsial pertama adalah dominan yang didalam kasus ini menunjukkan sifat non-stasioneritas. Dari grafik autokorelasi diatas memperlihatkan pola gelombang sinus dan terdapat dua parsial yang signifikan. Ini memberikan kesan bahwa proses AR (1) yang ditandai dengan adanya satu nilai pertama yang berbeda secara signifikan dengan nol. Begitupun dengan autokorelasi yang menunjukkan proses moving average MA (1) yang ditandai dengan adanya satu nilai pertama yang berbeda secara signifikan dengan nol.

Berdasarkan sifat-sifat fungsi autokorelasi parsial, maka diperoleh model-model yang diperkirakan cocok atau layak untuk data yang dimiliki adalah ARIMA (1,1,1), ARIMA (2,1,2), ARIMA (0,1,2). Pemilihan model dilakukan dengan menguji signifikan parameter. Setelah itu dilakukan diagnostic check masing-masing model untuk menguji apakah model yang telah dipilih sudah layak untuk digunakan atau belum. Diagnostic check yang dilakukan disini adalah melakukan analisis residual. Jika semua perkiraan model memenuhi asumsi, langkah berikutnya adalah membandingkan nilai *Sum Square Residualnya*, dipilih yang terkecil. Namun jika melalui langkah perbandingan *Sum Square Residual* semua model menunjukkan nilai yang tidak berbeda secara signifikan, maka pemilihan terakhir ditujukan pada model yang memiliki parameter paling sedikit.

• **ARIMA(1,1,1)**

Final Estimates of Parameters

Type	Coef	SE Coef	T	P
AR 1	0.6307	0.0957	6.59	0.000
MA 1	0.9833	0.0191	51.40	0.000

Differencing: 1 regular difference

Number of observations: Original series 72, after differencing 71

Residuals: SS = 66536.0 (backforecasts excluded)  
MS = 964.3 DF = 69

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

Lag	12	24	36	48
Chi-Square	21.7	34.6	41.1	45.3
DF	10	22	34	46
P-Value	0.016	0.043	0.186	0.502

• **Uji Overall**

1. Hipotesa

$H_0$ : Model sesuai / layak dipakai

$H_1$ : Model tidak sesuai / layak dipakai

2. Tingkat Signifikan ( $\alpha$ ),  $\chi^2_{(\alpha-m-p-q)}$

3. Daerah Kritis

Terima  $H_0$  jika  $\chi^2_{hitung} \leq \chi^2_{tabel}$

Tolak  $H_0$  jika  $\chi^2_{hitung} > \chi^2_{tabel}$

4. Statistik Uji

$$Q(N-d) \sum_{k=1}^m r_k^2$$

5. Kesimpulan

Dari tingkat signifikan 5% diperoleh nilai  $45,3 < 74,30$  maka  $H_0$  tidak ditolak artinya model dikatakan sesuai atau layak dipakai untuk peramalan

- Uji Parsial

- a. Uji Koefisien AR(1)

1. Hipotesis :

$$H_0 : \phi_1 = 0, \theta_1 = 0 \text{ atau } \theta_2 = 0$$

$$H_1 : \phi_1 \neq 0, \theta_1 \neq 0 \text{ atau } \theta_2 \neq 0$$

2. Tingkat signifikansi 0,05

3. Daerah kritik :  $H_0$  ditolak jika  $p\text{-value} < 0,05$

Hasil : AR(1),  $p\text{-value} = 0,000 < 0,05$  berarti  $H_0$  ditolak

4. Dari data diatas dapat diambil kesimpulan bahwa AR(1) signifikan terhadap model.

$$SS \text{ Residual} = 66536,0$$

$$MS = 964,3$$

- b. Uji Koefisien MA(1)

1. Hipotesis :

$$H_0 : \phi_1 = 0, \theta_1 = 0 \text{ atau } \theta_2 = 0$$

$$H_1 : \phi_1 \neq 0, \theta_1 \neq 0 \text{ atau } \theta_2 \neq 0$$

2. Tingkat signifikansi 0,05

3. Daerah kritik :  $H_0$  ditolak jika  $p\text{-value} < 0,05$

Hasil : MA(1),  $p\text{-value} = 0,000 < 0,05$  berarti  $H_0$  ditolak

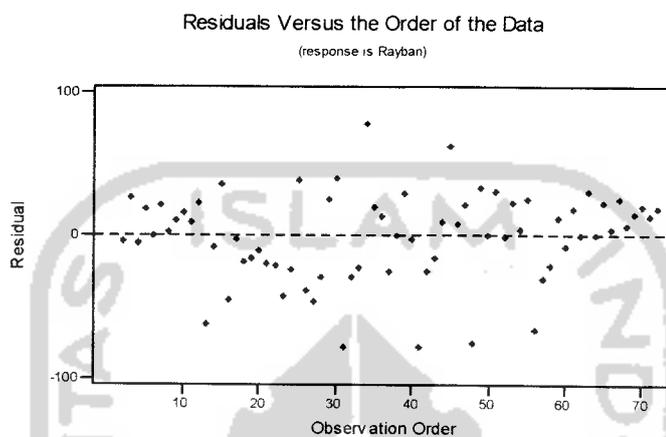
4. Dari data diatas dapat diambil kesimpulan bahwa MA(1) signifikan terhadap model.

$$SS \text{ Residual} = 66536,0$$

$$MS = 964,3$$

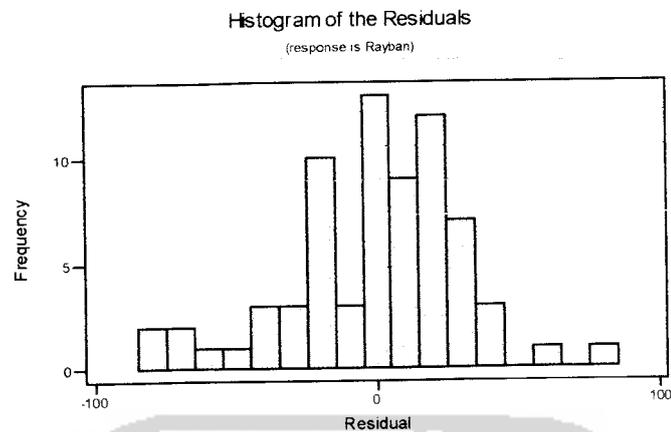
### Diagnostic check ARIMA (1,1,1)

Memeriksa gambar “*plot of residual overtime*”. Model dikatakan baik jika data-data dari residual menyebar secara acak disekitar garis 0 dan tidak membentuk suatu pola.



Gambar 3.17 Plot residual Rayban data asli

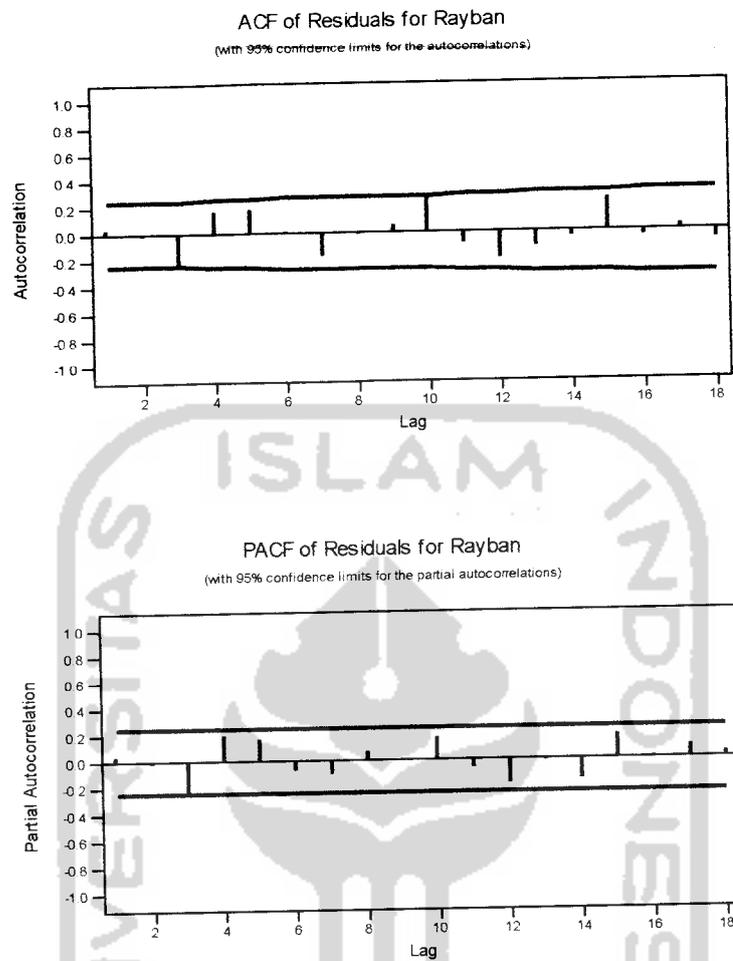
Dari gambar diatas, Residu tersebut tidak membentuk suatu pola tertentu dan menyebar secara acak. Sehingga dapat disimpulkan bahwa model ini layak. Kenormalan dari data residual merupakan salah satu faktor asumsi yang harus terpenuhi. Untuk menganalisa hal ini dapat dilihat dari histogram of residualnya, seperti dibawah ini:



Gambar 3.18 Grafik histogram data asli

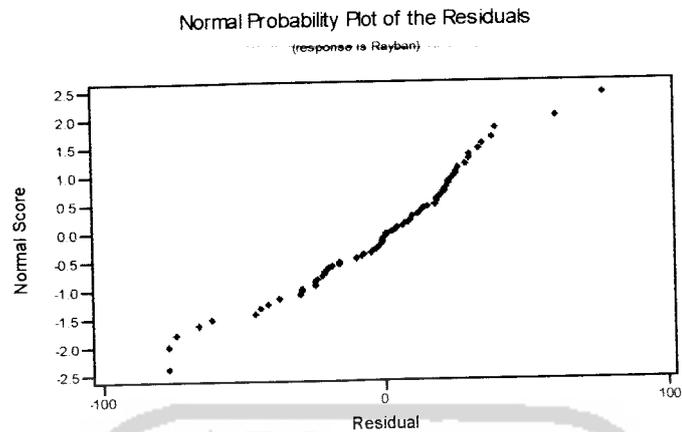
Gambar diatas memperlihatkan, bahwa data residual cenderung membentuk distribusi normal. Dari informasi tadi dapat disimpulkan bahwa residual berdistribusi normal.

Untuk memeriksa independensi dalam model dengan membuat plot fungsi autokorelasi. Model dikatakan layak jika fungsi autokorelasi untuk lag 1, 2, ....dst tidak secara signifikan berbeda dengan nol. Jika ada 1 lag yang secara independen berbeda dengan nol, berarti tidak independen. Ini dikarenakan nilai korelasi tersebut merupakan estimasi, jadi akan selalu mengandung resiko kesalahan.



Gambar 3.19 Plot autokorelasi (ACF) dan autokorelasi parsial (PACF) sebelum dilakukan pembedaan

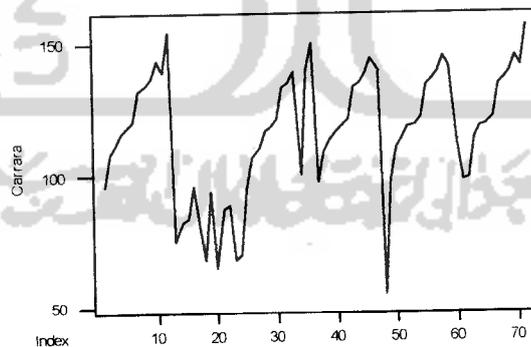
Fungsi autokorelasi dan autokorelasi parsial untuk lag 1, 2, ...dst tidak secara signifikan berbeda dari nol. Dengan demikian model dikatakan layak. Ada satu analisis lagi untuk memenuhi asumsi residual, yaitu memeriksa kelinieran dari residual. Model dikatakan layak jika residual tersebut cenderung membentuk garis lurus atau linier.



Gambar 3.20 Plot residual probabilitas normal data asli

Dari gambar diatas, residual dari model cenderung membentuk satu garis lurus, maka model dikatakan layak. Setelah semua asumsi dari model ARIMA (1,1,1) terpenuhi maka model ini layak digunakan untuk data yang dimiliki.

### 3. TS PLOT CARRARA

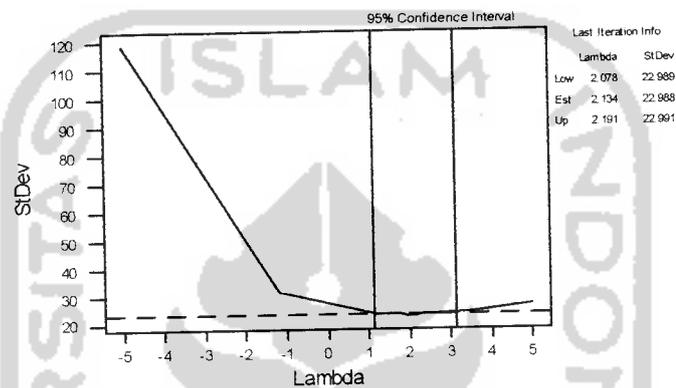


Gambar 3.21 Plot data volume penjualan kacamata merk Carrara

Dari grafik diatas untuk menerapkan metodologi Box-Jenkins pertama kali menganggap bahwa data runtun waktu yang akan di analisis bersifat stasioner. Selanjutnya dilakukan tahap untuk mengetahui apakah data tersebut sudah stasioner baik dalam mean ataupun dalam varian.

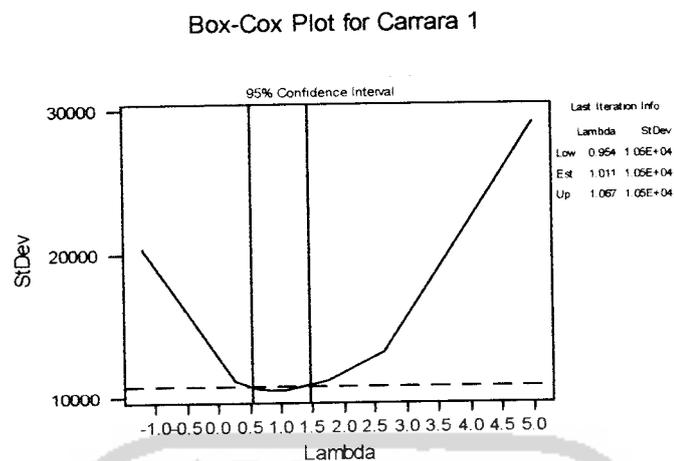
Didapat output sebagai berikut:

Box-Cox Plot for Carrara

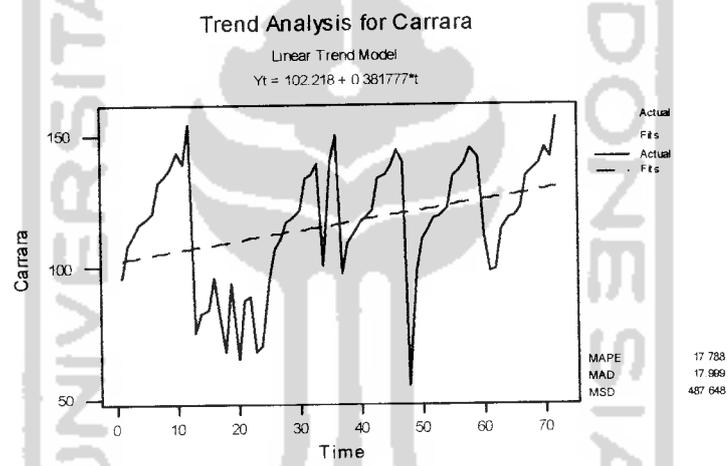


Gambar 3.22 Grafik Box-Cox Plot untuk volume penjualan Carrara

Dari gambar diatas diperoleh nilai dari lambda sebesar 2,134. Sehingga data harus ditransformasikan dengan nilai  $Z' = Z^2$  dan diperoleh nilai lambda sebesar 1,011 maka transformasi tidak perlu dilakukan.



Gambar 3.23 Grafik Box-Cox Plot untuk volume penjualan Carrara



Gambar 3.24 Trend analisis Carrara sebelum dilakukan pembedaan

Dari grafik TS Plot diatas dapat diamati bahwa data belum memenuhi asumsi stasioner, yaitu bahwa meannya belum konstan. Sehingga langkah berikutnya adalah melakukan pembedaan 1 (*differences*). Sehingga seiring dengan waktu nilai rata-rata dapat berubah. Berikut hasil data yang telah mengalami pembedaan 1:

nilai pertama yang berbeda secara signifikan dengan nol. Begitupun dengan autokorelasi yang menunjukkan proses moving average MA (1) yang ditandai dengan adanya satu nilai pertama yang berbeda secara signifikan dengan nol.

Berdasarkan sifat-sifat fungsi autokorelasi parsial, maka diperoleh model-model yang diperkirakan cocok atau layak untuk data yang dimiliki adalah ARIMA (1,1,1), ARIMA (0,1,1), ARIMA (0,1,2). Pemilihan model dilakukan dengan menguji signifikan parameter. Setelah itu dilakukan diagnostic check masing-masing model untuk menguji apakah model yang telah dipilih sudah layak untuk digunakan atau belum. *Diagnostic check* yang dilakukan disini adalah melakukan analisis residual. Jika semua perkiraan model memenuhi asumsi, langkah berikutnya adalah membandingkan nilai *Sum Square Residualnya*, dipilih yang terkecil. Namun jika melalui langkah perbandingan *Sum Square Residual* semua model menunjukkan nilai yang tidak berbeda secara signifikan, maka pemilihan terakhir ditujukan pada model yang memiliki parameter paling sedikit.

• **ARIMA(1,1,1)**

```
Final Estimates of Parameters
Type      Coef      SE Coef      T      P
AR 1      0.6471    0.0965      6.71   0.000
MA 1      0.9999    0.0118     85.00  0.000
Differencing: 1 regular difference
Number of observations: Original series 72, after
differencing 71
Residuals:  SS = 23759.8 (backforecasts excluded)
              MS = 344.3  DF = 69
Modified Box-Pierce (Ljung-Box) Chi-Square statistic
Lag        12         24         36         48
Chi-Square 6.3        22.7       31.6       33.4
DF         10         22         34         46
P-Value    0.789     0.416     0.587     0.917
```

- **Uji Overall**

1. Uji Hipotesa

$H_0$  : Model sesuai / layak dipakai

$H_1$  : Model tidak sesuai / layak dipakai

2. Tingkat Signifikan ( $\alpha$ ),  $\chi^2_{(\alpha-m-p-q)}$

3. Daerah Kritis

Terima  $H_0$  jika  $\chi^2_{hitung} \leq \chi^2_{tabel}$

Tolak  $H_0$  jika  $\chi^2_{hitung} > \chi^2_{tabel}$

4. Statistik Uji

$$Q = (N - d) \sum_{k=1}^m r_k^2$$

5. Kesimpulan

Dari tingkat signifikan 5% diperoleh nilai  $33,4 < 54,20$  maka  $H_0$  tidak ditolak artinya model dikatakan sesuai atau layak dipakai untuk peramalan

- **Uji Parsial**

- a. Uji Koefisien AR(1)

1. Hipotesis :

$H_0$  :  $\phi_1 = 0$ ,  $\theta_1 = 0$  atau  $\theta_2 = 0$

$H_1$  :  $\phi_1 \neq 0$ ,  $\theta_1 \neq 0$  atau  $\theta_2 \neq 0$

2. Tingkat signifikansi 0,05

3. Daerah kritik :  $H_0$  ditolak jika p-value  $< 0,05$

Hasil : AR(1), p-value =  $0,000 < 0,05$  berarti  $H_0$  ditolak

4. Dari data diatas dapat diambil kesimpulan bahwa AR(1) signifikan terhadap model.

$$SS \text{ Residual} = 23759.8$$

$$MS = 344.3$$

b. Uji Koefisien MA(1)

1. Hipotesis :

$$H_0 : \phi_1 = 0, \theta_1 = 0 \text{ atau } \theta_2 = 0$$

$$H_1 : \phi_1 \neq 0, \theta_1 \neq 0 \text{ atau } \theta_2 \neq 0$$

2. Tingkat signifikansi 0,05

3. Daerah kritik :  $H_0$  ditolak jika  $p\text{-value} < 0,05$

Hasil : MA(1),  $p\text{-value} = 0,000 < 0,05$  berarti  $H_0$  ditolak

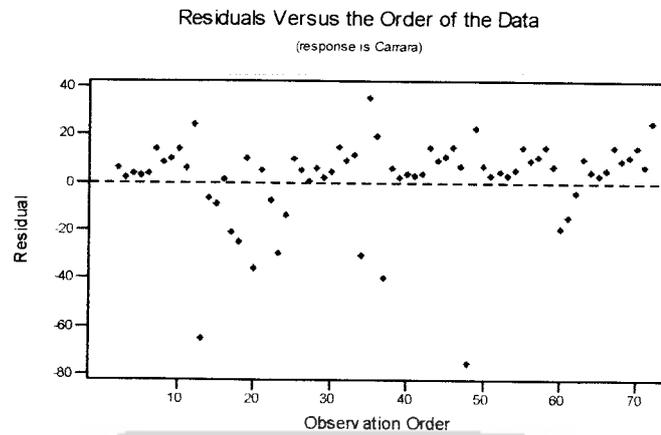
4. Dari data diatas dapat diambil kesimpulan bahwa MA(1) signifikan terhadap model.

$$SS \text{ Residual} = 23759.8$$

$$MS = 344.3$$

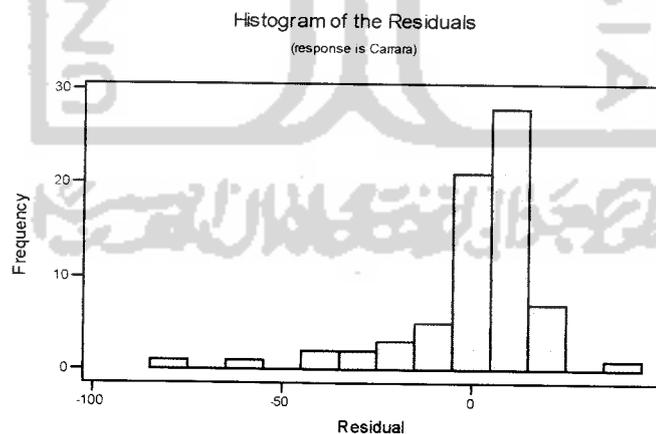
**Diagnostic check ARIMA (1,1,1)**

Memeriksa gambar “*plot of residual overtime*”. Model dikatakan baik jika data-data dari residual menyebar secara acak disekitar garis 0 dan tidak membentuk suatu pola.



Gambar 3.27 Plot residual data asli

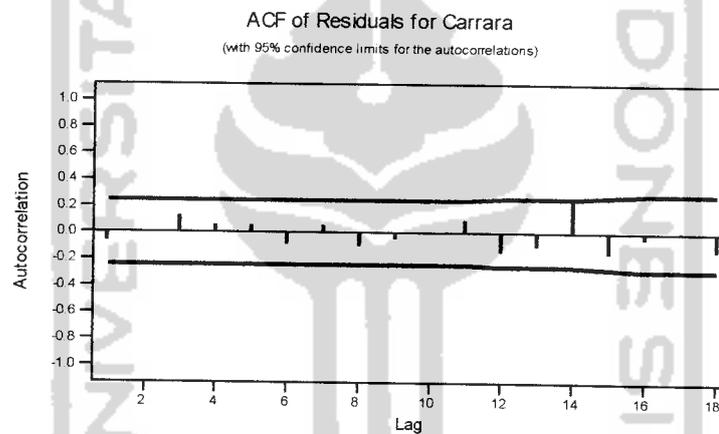
Dari gambar diatas, Residu tersebut tidak membentuk suatu pola tertentu dan menyebar secara acak. Sehingga dapat disimpulkan bahwa model ini layak. Kenormalan dari data residual merupakan salah satu faktor asumsi yang harus terpenuhi. Untuk menganalisa hal ini dapat dilihat dari histogram of residualnya, seperti dibawah ini:

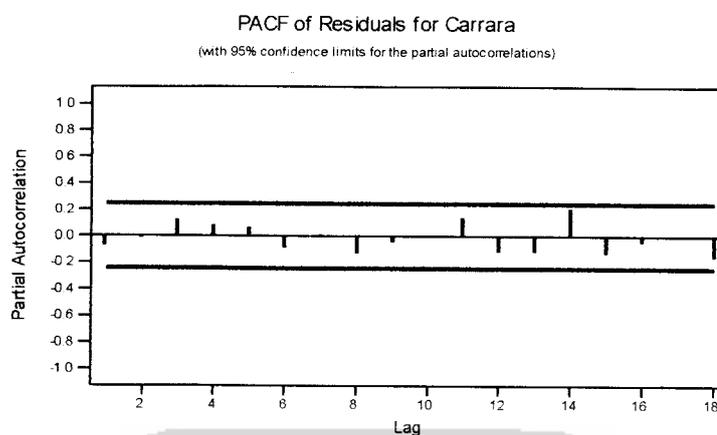


Gambar 3.28 Grafik histogram data asli

Gambar diatas memperlihatkan, bahwa data residual cenderung membentuk distribusi normal. Dari informasi tadi dapat disimpulkan bahwa residual berdistribusi normal.

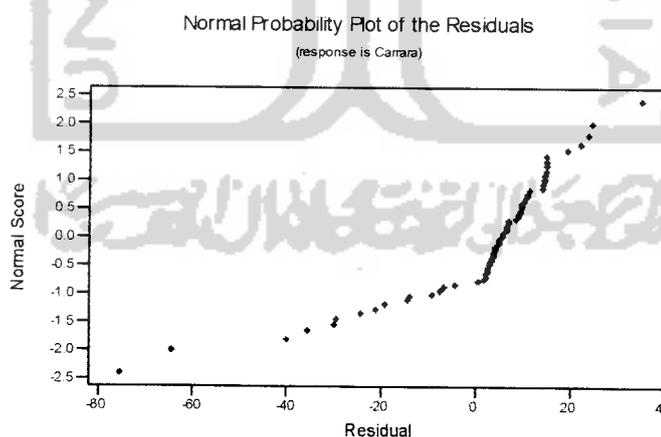
Untuk memeriksa independensi dalam model dengan membuat plot fungsi autokorelasi. Model dikatakan layak jika fungsi autokorelasi untuk lag 1, 2, ....dst tidak secara signifikan berbeda dengan nol. Jika ada 1 lag yang secara independen berbeda dengan nol, berarti tidak independen. Ini dikarenakan nilai korelasi tersebut merupakan estimasi, jadi akan selalu mengandung resiko kesalahan.





Gambar 3.29 Plot Autokorelasi (ACF) dan Autokorelasi Parsial (PACF) setelah dilakukan pembedaan

Fungsi autokorelasi dan autokorelasi parsial untuk lag 1, 2, ...dst tidak secara signifikan berbeda dari nol. Dengan demikian model dikatakan layak. Ada satu analisis lagi untuk memenuhi asumsi residual, yaitu memeriksa kelinieran dari residual. Model dikatakan layak jika residual tersebut cenderung membentuk garis lurus atau linier.



Gambar 3.30 Plot residual probabilitas normal data asli

Dari gambar diatas, residual dari model cenderung membentuk satu garis lurus, maka model dikatakan layak. Setelah semua asumsi dari model ARIMA (1,1,1) terpenuhi maka model ini layak digunakan untuk data yang dimiliki.

Setelah semua perkiraan model dilakukan uji estimasi parameter dan *diagnostic check* dan semua perkiraan model ternyata layak dipakai peramalan. Maka langkah berikutnya memilih satu model ARIMA yang memiliki *sum square residual* paling kecil:

1. Christian Dior dengan ARIMA (1,1,2), diperoleh:

$$SS \text{ Residual} = 22674,1$$

$$MS = 333,4$$

Sehingga model runtun waktunya adalah:

$$X_t = 0,8169 X_{t-1} - 1,1600 e_{t-1} + 0,1781 e_{t-2}$$

Dari model diatas dapat diramalkan jumlah volume penjualan kacamata merk Christian Dior untuk 6 bulan periode kedepan adalah sebagai berikut:

Periode	Forecast
73	155,379
74	151,392
75	148,135
76	145,475
77	143,302
78	141,527

2. Rayban dengan ARIMA (1,1,1), diperoleh:

$$SS \text{ Residual} = 66536,0$$

$$MS = 964,4$$



Sehingga model runtun waktunya adalah:

$$X_t = 0,6307 X_{t-1} - 0,9833 e_{t-1}$$

Dari model diatas dapat diramalkan jumlah volume penjualanacamata merk Rayban untuk 6 bulan periode kedepan adalah sebagai berikut:

Periode	Forecast
73	154,789
74	145,194
75	139,142
76	135,325
77	132,918
78	131,399

3. Carrara dengan ARIMA (1,1,1), diperoleh:

$$SS \text{ Residual} = 23759,8$$

$$MS = 344,3$$

Sehingga model runtun waktunya adalah:

$$X_t = 0,6471 X_{t-1} - 0,9999 e_{t-1}$$

Dari model diatas dapat diramalkan jumlah volume penjualanacamata merk Carrara untuk 6 bulan periode kedepan adalah sebagai berikut:

Periode	forecast
73	141,010
74	131,310
75	125,033
76	120,970
77	118,341
78	116,640

Maka keputusan terakhir dalam pemilihan model ini jatuh pada model ARIMA (1,1,2) dengan kacamata merk Christian Dior, karena parameternya paling sedikit dan *sum square* paling kecil dibanding model dengan jumlah parameter yang sama. Sehingga model runtun waktunya adalah:

$$X_t = 0,8169 X_{t-1} - 1,1600 e_{t-1} + 0,1781 e_{t-2}$$

Dari model diatas akan diramal jumlah volume penjualan untuk 6 periode kedepan dan hasilnya adalah:

Periode	forecast
73	115,379
74	151,392
75	148,135
76	135,325
77	132,918
78	131,399

Karena nilai peramalan dan nilai sebenarnya tidak terlalu jauh beda, maka model ini cocok digunakan untuk peramalan volume penjualan kacamata yang akan datang.

## BAB IV

### ANALISIS DAN PEMBAHASAN

Secara umum langkah-langkah yang dilakukan dalam menganalisa menggunakan Box-Jenkins ada beberapa langkah yang perlu dilakukan dalam bab 3 :

#### 1. CHRISTIAN DIOR

Berdasarkan plot data diatas terlihat bahwa data belum stasioner seperti pada gambar 3.1, langkah selanjutnya dilakukan transformasi menggunakan Box-Cox Plot seperti tampak pada gambar 3.2 diatas. Setelah dilakukan transformasi ternyata data belum stasioner seperti pada gambar 3.3, selanjutnya dilakukan pembedaan pertama, setelah dilakukan pembedaan pertama ternyata data telah stasioner baik dalam mean ataupun dalam varian seperti pada gambar 3.4. Kemudian langkah selanjutnya yaitu dengan melihat grafik autokorelasi (ACF) dan parsial autokorelasi (PACF) yang terlihat pada gambar 3.5 memperlihatkan bahwa deret berkala tidak musiman dimana plot autokorelasi memberikan indikasi non stasioneritas dan plot data juga memperjelas keadaan tersebut. Parsial pertama adalah dominan yang didalam kasus ini menunjukkan sifat non-stasioneritas. Kemudian langkah selanjutnya adalah pemilihan model ARIMA, dan model yang terpilih adalah ARIMA (1,1,2) sehingga model runtun waktunya diperoleh adalah sebagai berikut:

$$X_t = 0,8169 X_{t-1} - 1,1600 e_{t-1} + 0,1781 e_{t-2}$$

Kemudian dari model ARIMA (1,1,2) dilakukan uji hipotesis lihat hal 36, selanjutnya dilakukan *diagnostic check* dengan memeriksa gambar “*plot of residual overtime*” lihat gambar 3.6, model ini dikatakan baik jika data-data dari residual menyebar secara acak disekitar garis nol dan tidak membentuk suatu pola. Kemudian langkah selanjutnya memeriksa kenormalan dari data residual dengan memeperlihatkan *histogram of residual* gambar 3.7 diatas bahwa data residual cenderung membentuk distribusi normal, kemudian langkah selanjutnya memeriksa independensi dalam model dengan membuat plot fungsi autokorelasi. Model dikatakan layak jika fungsi autokorelasi untuk lag 1, 2, ... dst tidak secara signifikan berbeda dengan nol. Jika ada 1 lag yang secara independen berbeda dengan nol, berarti tidak independen. Ini dikarenakan nilai korelasi tersebut merupakan estimasi, jadi akan selalu mengandung resiko kesalahan. Fungsi autokorelasi dan autokorelasi parsial untuk lag 1, 2, ... dst tidak secara signifikan berbeda dari nol seperti terlihat pada gambar 3.8 diatas. Dengan demikian model dikatakan layak. Langkah selanjutnya adalah memeriksa kelinieran dari residual. Model dikatakan layak jika residual tersebut cenderung membentuk garis lurus atau linier. Dari gambar 3.9 diatas, residual dari model cenderung membentuk satu garis lurus, maka model dikatakan layak.

## 2. RAYBAN

Berdasarkan plot data diatas terlihat bahwa data belum stasioner seperti pada gambar 3.10, langkah selanjutnya dilakukan transformasi menggunakan Box-

Cox Plot seperti tampak pada gambar 3.11 diatas. Setelah dilakukan transformasi ternyata data belum stasioner seperti pada gambar 3.12, selanjutnya dilakukan pembedaan pertama, setelah dilakukan pembedaan pertama ternyata data telah stasioner baik dalam mean ataupun dalam varian seperti pada gambar 3.13. Kemudian langkah selanjutnya yaitu dengan melihat grafik autokorelasi (ACF) dan parsial autokorelasi (PACF) memperlihatkan bahwa deret berkala tidak musiman dimana plot autokorelasi memberikan indikasi non stasioneritas dan plot data juga memperjelas keadaan tersebut. Parsial pertama adalah dominan yang didalam kasus ini menunjukkan sifat non-stasioneritas seperti pada gambar 3.14. Kemudian langkah selanjutnya adalah pemilihan model ARIMA, dan model yang terpilih adalah ARIMA (1,1,1) sehingga model runtun waktunya diperoleh adalah sebagai berikut:

$$X_t = 0,6307 X_{t-1} - 0,9833 e_{t-1}$$

Kemudian dari model ARIMA(1,1,1) dilakukan uji hipotesis lihat hal 48, selanjutnya dilakukan *diagnostic check* dengan memeriksa gambar “*plot of residual overtime*” lihat gambar 3.15, model ini dikatakan baik jika data-data dari residual menyebar secara acak disekitar garis nol dan tidak membentuk suatu pola. Kemudian langkah selanjutnya mermeriksa kenormalan dari data residual dengan memperlihatkan *histogram of residual* gambar 3.16 diatas bahwa data residual cenderung membentuk distribusi normal, kemudian langkah selanjutnya memeriksa independensi dalam model dengan membuat plot fungsi autokorelasi. Model dikatakan layak jika fungsi autokorelasi untuk lag 1, 2, ...dst tidak secara signifikan berbeda dengan nol. Jika ada 1 lag yang

secara independen berbeda dengan nol, berarti tidak independen. Ini dikarenakan nilai korelasi tersebut merupakan estimasi, jadi akan selalu mengandung resiko kesalahan. Fungsi autokorelasi dan autokorelasi parsial untuk lag 1, 2, ... dst tidak secara signifikan berbeda dari nol seperti terlihat pada gambar 3.17 diatas. Dengan demikian model dikatakan layak. Langkah selanjutnya adalah memeriksa kelinieran dari residual. Model dikatakan layak jika residual tersebut cenderung membentuk garis lurus atau linier. Dari gambar 3.18 diatas, residual dari model cenderung membentuk satu garis lurus, maka model dikatakan layak.

### 3. CARRARA

Berdasarkan plot data diatas terlihat bahwa data belum stasioner seperti pada gambar 3.19, langkah selanjutnya dilakukan transformasi menggunakan Box-Cox Plot seperti tampak pada gambar 3.20 diatas. Setelah dilakukan transformasi ternyata data belum stasioner seperti pada gambar 3.21, selanjutnya dilakukan pembedaan pertama, setelah dilakukan pembedaan pertama ternyata data telah stasioner baik dalam mean ataupun dalam varian seperti pada gambar 3.22. Kemudian langkah selanjutnya yaitu dengan melihat grafik autokorelasi (ACF) dan parsial autokorelasi (PACF) yang terlihat pada gambar 3.23 memperlihatkan bahwa deret berkala tidak musiman dimana plot autokorelasi memberikan indikasi non stasioneritas dan plot data juga memperjelas keadaan tersebut. Parsial pertama adalah dominan yang didalam kasus ini menunjukkan sifat non-stasioneritas. Kemudian langkah selanjutnya

## 5.2. Saran

Dalam memahami metode Box-Jenkins diperlukan kajian yang hati-hati, namun sejak adanya teknologi komputer yang semakin canggih maka pengerjaan dalam berbagai perhitungan dapat dikerjakan dengan cepat. Hambatan yang dialami dalam dalam penggunaan metodologi Box-Jenkins ini bukan lagi dalam hal perhitungan, tetapi tingkat pemahaman berbagai tahapan dalam identifikasi model, estimasi dan penggunaan model ARIMA yang sesuai. Dengan ini maka ada beberapa prinsip yang dapat dipakai antar lain:

1. Membuat deret stasioner.

Analisis sementara terhadap data mentah dapat dengan mudah memperlihatkan apakah suatu data deret berkala stasioner pada nilai tengah dan ragamnya. Perbedaan orde pertama atau kedua (bukan musim dan atau musim) biasanya akan mengenai nonstasioneritas nilai tengah.

2. Mempertimbangkan aspek-aspek bukan musiman.

Suatu pengujian terhadap autokorelasi, parsial dari deret stasioner yang diperoleh dari langkah 1.

3. Aspek-aspek musiman.

Pengujian autokorelasi, parsial dan spektrum garis dapat membantu penetapan proses AR dan MA untuk aspek-aspek musiman dari data, akan tetapi petunjuk tersebut sama sekali tidak mudah untuk ditemukan seperti kasus aspek-aspek tidak musiman. Untuk data

Lampiran 1

Tabel 3.1 Data volume penjualan kacamata optik akur dari tahun 1997-2002

<i>Periode</i>	<i>Christian Dior</i>	<i>Rayban</i>	<i>Carrara</i>	<i>Periode</i>	<i>Christian Dior</i>	<i>Rayban</i>	<i>Carrara</i>
<i>Jan 97</i>	124	124	96	<i>Jan 00</i>	125	125	97
<i>Feb 97</i>	129	123	108	<i>Feb 00</i>	100	124	109
<i>Mar 97</i>	132	152	112	<i>Mar 00</i>	120	153	113
<i>Apr 97</i>	132	140	116	<i>Apr 00</i>	130	140	117
<i>Mei 97</i>	134	156	118	<i>Mei 00</i>	135	57	119
<i>Jun 97</i>	133	148	120	<i>Jun 00</i>	87	56	121
<i>Jul 97</i>	143	164	132	<i>Jul 00</i>	78	64	133
<i>Aug 97</i>	139	156	134	<i>Aug 00</i>	102	94	135
<i>Sep 97</i>	140	158	137	<i>Sep 00</i>	100	165	138
<i>Okt 97</i>	152	165	143	<i>Okt 00</i>	145	157	144
<i>Nov 97</i>	150	163	139	<i>Nov 00</i>	150	166	140
<i>Des 97</i>	162	175	154	<i>Des 00</i>	163	76	55
<i>Jan 98</i>	80	99	75	<i>Jan 01</i>	126	126	98
<i>Feb 98</i>	94	104	82	<i>Feb 01</i>	131	125	110
<i>Mar 98</i>	89	150	84	<i>Mar 01</i>	134	154	114
<i>Apr 98</i>	80	100	96	<i>Apr 01</i>	134	142	118
<i>Mei 98</i>	56	110	81	<i>Mei 01</i>	136	158	119
<i>Jun 98</i>	77	100	68	<i>Jun 01</i>	135	150	122
<i>Jul 98</i>	93	96	94	<i>Jul 01</i>	145	166	134
<i>Aug 98</i>	65	99	65	<i>Aug 01</i>	141	85	136
<i>Sep 98</i>	80	91	87	<i>Sep 01</i>	142	69	139
<i>Okt 98</i>	79	84	89	<i>Okt 01</i>	125	67	145
<i>Nov 98</i>	99	59	68	<i>Nov 01</i>	131	99	141
<i>Des 98</i>	69	60	70	<i>Des 01</i>	154	100	112
<i>Jan 99</i>	123	123	95	<i>Jan 02</i>	126	126	98
<i>Feb 99</i>	128	87	107	<i>Feb 02</i>	131	125	99
<i>Mar 99</i>	133	55	110	<i>Mar 02</i>	134	154	114
<i>Apr 99</i>	134	51	117	<i>Apr 02</i>	134	142	118
<i>Mei 99</i>	135	102	118	<i>Mei 02</i>	136	158	119
<i>Jun 99</i>	134	150	121	<i>Jun 02</i>	135	150	122
<i>Jul 99</i>	144	64	133	<i>Jul 02</i>	145	166	134
<i>Aug 99</i>	140	56	135	<i>Aug 02</i>	141	158	136
<i>Sep 99</i>	150	58	139	<i>Sep 02</i>	142	160	139
<i>Okt 99</i>	153	159	100	<i>Okt 02</i>	154	167	145
<i>Nov 99</i>	151	166	140	<i>Nov 02</i>	151	165	141
<i>Des 99</i>	163	164	150	<i>Des 02</i>	164	170	156

Sumber: Perusahaan Optik Akur Jogjakarta

### Lampiran 1

**Tabel 3.2 Model ARIMA yang terpilih, tanpa menggunakan konstanta**

<b>Merk Kacamata</b>	<b>Model</b>	<b>Type</b>	<b>Nilai MS</b>	<b>p-value</b>	<b>Keterangan</b>
Christian Dior	ARIMA (0,1,1)	MA(1)	343,4	0,014	Signifikan
	ARIMA (1,1,0)	AR(1)	346,7	0,038	Signifikan
	ARIMA (1,1,2)	AR(1)	333,4	0,000	Signifikan
		MA(1)		0,000	Signifikan
		MA(2)	0,000	Signifikan	
Rayban	ARIMA (1,1,1)	AR(1)	964,3	0,000	Signifikan
		MA(1)		0,000	Signifikan
	ARIMA (0,1,1)	MA(1)	1107,6	0,013	Signifikan
	ARIMA (0,1,2)	MA(1)	1021,3	0,001	Signifikan
MA(2)		0,015		Signifikan	
Carrara	ARIMA (1,1,1)	AR(1)	344,3	0,000	Signifikan
		MA(1)		0,000	Signifikan
	ARIMA (0,1,1)	MA(1)	365,9	0,001	Signifikan
	ARIMA (0,1,2)	MA(1)	364,9	0,007	Signifikan
MA(2)		0,211		Tidak Signifikan	



Lampiran 1

Tabel 3.3 Data hasil Box-cox plot transformasi

<i>Christian Dior</i>	<i>Rayban</i>	<i>Carrara</i>	<i>Christian Dior</i>	<i>Rayban</i>	<i>Carrara</i>
1305010	1968.20	17014.7	1335994	1993.24	17395.2
1464764	1943.28	21877.6	696140	1968.20	22312.3
1566517	2711.47	23643.4	1185803	2739.59	24096.3
1566517	2382.35	25482.2	1498183	2382.35	25953.4
1636869	2824.59	26429.1	1672811	579.33	26909.5
1601439	2600.04	27394.4	463459	563.42	27884.0
1979189	3055.85	33574.4	336874	695.16	34119.6
1821766	2824.59	34669.4	737600	1272.87	35224.0
1860319	2881.78	36347.1	696140	3085.22	36915.7
2365512	3085.22	39829.2	2061146	2853.13	40426.0
2275729	3026.58	37489.0	2275729	3114.69	38067.0
2849463	3384.51	46654.6	2901152	911.01	5182.2
362734	1381.02	10046.2	1367458	2018.38	17780.2
581024	1492.35	12153.8	1532099	1993.24	22751.4
495276	2655.54	12795.3	1636869	2767.82	24553.7
362734	1403.03	17014.7	1636869	2436.12	26429.1
127958	1630.05	11839.7	1709269	2881.78	26909.5
324412	1403.03	8150.4	1672811	2655.54	28378.1
563150	1315.74	16267.1	2061146	3114.69	34669.4
197766	1381.02	7402.2	1899405	1086.44	35783.2
362734	1209.53	13790.4	1939027	782.51	37489.0
349647	1066.40	14475.9	1335994	747.12	41027.6
675998	611.64	8150.4	1532099	1381.02	38649.7
235461	628.03	8670.6	2457593	1403.03	23643.4
1274503	1943.28	16638.6	1367458	2018.38	17780.2
1431839	1126.94	21447.5	1532099	1993.24	18169.7
1601439	547.67	22751.4	1636869	2767.82	24553.7
1636869	486.32	25953.4	1636869	2436.12	26429.1
1672811	1447.44	26429.1	1709269	2881.78	26909.5
1636869	2655.54	27884.0	1672811	2655.54	28378.1
2019894	695.16	34119.6	2061146	3114.69	34669.4
1860319	563.42	35224.0	1899405	2881.78	35783.2
2275729	595.41	37489.0	1939027	2939.39	37489.0
2411263	2910.53	18563.6	2457593	3144.27	41027.6
2320335	3114.69	38067.0	2320335	3085.22	38649.7
2901152	3055.85	44106.2	2953455	3233.60	47957.3

**Lampiran 1**  
**Tabel 3.4 Data hasil cek Box-cox plot transformasi untuk**  
**Christian Dior**

tranz1 tanpa ( $\lambda$ )	tranz2 dengan ( $\lambda=0$ )	tranz3 tanpa ( $\lambda$ )	tranz1 tanpa ( $\lambda$ )	tranz2 dengan ( $\lambda=0$ )	tranz3 tanpa ( $\lambda$ )
1305010	14.0817	477252	1335994	14.1052	481196
1464764	14.1972	496917	696140	13.4533	380827
1566517	14.2644	508647	1185803	13.9859	461416
1566517	14.2644	508647	1498183	14.2198	500833
1636869	14.3083	516439	1672811	14.33	520326
1601439	14.2864	512546	463459	13.0465	327188
1979189	14.4982	551224	336874	12.7275	289498
1821766	14.4153	535820	737600	13.5112	388992
1860319	14.4363	539679	696140	13.4533	380827
2365512	14.6765	585562	2061146	14.5388	558892
2275729	14.6378	577969	2275729	14.6378	577969
2849463	14.8626	623206	2901152	14.8806	626942
362734	12.8014	297911	1367458	14.1285	485135
581024	13.2725	356192	1532099	14.2421	504743
495276	13.1129	335503	1636869	14.3083	516439
362734	12.8014	297911	1636869	14.3083	516439
127958	11.7595	195795	1709269	14.3516	524208
324412	12.6898	285284	1672811	14.33	520326
563150	13.2413	352066	2061146	14.5388	558892
197766	12.1948	234347	1899405	14.4571	543533
362734	12.8014	297911	1939027	14.4777	547381
349647	12.7647	293707	1335994	14.1052	481196
675998	13.4239	376736	1532099	14.2421	504743
235461	12.3693	251396	2457593	14.7147	593133
1274503	14.0581	473301	1367458	14.1285	485135
1431839	14.1745	492995	1532099	14.2421	504743
1601439	14.2864	512546	1636869	14.3083	516439
1636869	14.3083	516439	1636869	14.3083	516439
1672811	14.33	520326	1709269	14.3516	524208
1636869	14.3083	516439	1672811	14.33	520326
2019894	14.5186	555061	2061146	14.5388	558892
1860319	14.4363	539679	1899405	14.4571	543533
2275729	14.6378	577969	1939027	14.4777	547381
2411263	14.6957	589350	2457593	14.7147	593133
2320335	14.6572	581768	2320335	14.6572	581768
2901152	14.8806	626942	2953455	14.8985	630672

**Lampiran 1**  
**Tabel 3.5 Data hasil cek Box-cox plot transformasi untuk**  
**Rayban**

tranz1 tanpa ( $\lambda$ )	tranz2 dengan ( $\lambda=0$ )	tranz3 tanpa ( $\lambda$ )	tranz1 tanpa ( $\lambda$ )	tranz2 dengan ( $\lambda=0$ )	tranz3 tanpa ( $\lambda$ )
1968.20	4.82028	2382.25	1993.24	4.82831	2401.94
1943.28	4.81218	2362.53	1968.20	4.82028	2382.25
2711.47	5.02388	2922.89	2739.59	5.03044	2941.80
2382.35	4.94164	2693.86	2382.35	4.94164	2693.86
2824.59	5.04986	2998.37	579.33	4.04305	998.76
2600.04	4.99721	2846.98	563.42	4.02535	977.33
3055.85	5.09987	3148.06	695.16	4.15888	1148.44
2824.59	5.04986	2998.37	1272.87	4.54329	1777.97
2881.78	5.06260	3035.95	3085.22	5.10595	3166.66
3085.22	5.10595	3166.66	2853.13	5.05625	3017.17
3026.58	5.09375	3129.44	3114.69	5.11199	3185.23
3384.51	5.16479	3351.22	911.01	4.33073	1402.96
1381.02	4.59512	1880.51	2018.38	4.83628	2421.60
1492.35	4.64439	1982.33	1993.24	4.82831	2401.94
2655.54	5.01064	2884.99	2767.82	5.03695	2960.68
1403.03	4.60517	1900.94	2436.12	4.95583	2732.31
1630.05	4.70048	2103.54	2881.78	5.06260	3035.95
1403.03	4.60517	1900.94	2655.54	5.01064	2884.99
1315.74	4.56435	1819.07	3114.69	5.11199	3185.23
1381.02	4.59512	1880.51	1086.44	4.44265	1591.57
1209.53	4.51086	1716.09	782.51	4.23411	1254.87
1066.40	4.43082	1570.72	747.12	4.20469	1212.36
611.64	4.07754	1041.59	1381.02	4.59512	1880.51
628.03	4.09434	1062.99	1403.03	4.60517	1900.94
1943.28	4.81218	2362.53	2018.38	4.83628	2421.60
1126.94	4.46591	1633.19	1993.24	4.82831	2401.94
547.67	4.00733	955.89	2767.82	5.03695	2960.68
486.32	3.93183	870.10	2436.12	4.95583	2732.31
1447.44	4.62497	1941.69	2881.78	5.06260	3035.95
2655.54	5.01064	2884.99	2655.54	5.01064	2884.99
695.16	4.15888	1148.44	3114.69	5.11199	3185.23
563.42	4.02535	977.33	2881.78	5.06260	3035.95
595.41	4.06044	1020.18	2939.39	5.07517	3073.42
2910.53	5.06890	3054.70	3144.27	5.11799	3203.77
3114.69	5.11199	3185.23	3085.22	5.10595	3166.66
3055.85	5.09987	3148.06	3233.60	5.13580	3259.25

**Lampiran 1**  
**Tabel 3.6** Data hasil cek Box-cox plot transformasi untuk  
**Carrara**

tranz1 tanpa ( $\lambda$ )	tranz2 dengan ( $\lambda=0$ )	tranz3 tanpa ( $\lambda$ )	tranz1 tanpa ( $\lambda$ )	tranz2 dengan ( $\lambda=0$ )	tranz3 tanpa ( $\lambda$ )
17014.7	9.7418	77208	17395.2	9.7639	78078
21877.6	9.9932	87572	22312.3	10.0129	88427
23643.4	10.0708	90986	24096.3	10.0898	91837
25482.2	10.1457	94381	25953.4	10.1641	95227
26429.1	10.1822	96071	26909.5	10.2002	96914
27394.4	10.2181	97756	27884.0	10.2358	98597
33574.4	10.4215	107763	34119.6	10.4376	108589
34669.4	10.4536	109413	35224.0	10.4695	110237
36347.1	10.5009	111880	36915.7	10.5164	112700
39829.2	10.5924	116783	40426.0	10.6072	117596
37489.0	10.5318	113519	38067.0	10.5471	114337
46654.6	10.7505	125662	5182.2	8.5530	40571
10046.2	9.2150	58652	17780.2	9.7858	78948
12153.8	9.4054	64894	22751.4	10.0324	89282
12795.3	9.4568	66667	24553.7	10.1086	92686
17014.7	9.7418	77208	26429.1	10.1822	96071
11839.7	9.3792	64005	26909.5	10.2002	96914
8150.4	9.0058	52359	28378.1	10.2534	99436
16267.1	9.6969	75463	34669.4	10.4536	109413
7402.2	8.9095	49649	35783.2	10.4852	111059
13790.4	9.5317	69318	37489.0	10.5318	113519
14475.9	9.5802	71080	41027.6	10.6220	118408
8150.4	9.0058	52359	38649.7	10.5623	115153
8670.6	9.0677	54162	23643.4	10.0708	90986
16638.6	9.7195	76336	17780.2	9.7858	78948
21447.5	9.9734	86715	18169.7	9.8075	79816
22751.4	10.0324	89282	24553.7	10.1086	92686
25953.4	10.1641	95227	26429.1	10.1822	96071
26429.1	10.1822	96071	26909.5	10.2002	96914
27884.0	10.2358	98597	28378.1	10.2534	99436
34119.6	10.4376	108589	34669.4	10.4536	109413
35224.0	10.4695	110237	35783.2	10.4852	111059
37489.0	10.5318	113519	37489.0	10.5318	113519
18563.6	9.8290	80682	41027.6	10.6220	118408
38067.0	10.5471	114337	38649.7	10.5623	115153
44106.2	10.6944	122449	47957.3	10.7781	127261

Lampiran 1  
Tabel 3.7 Nilai Perbedaan satu

<i>Christian Dior</i>	<i>Rayban</i>	<i>Carrara</i>	<i>Christian Dior</i>	<i>Rayban</i>	<i>Carrara</i>
*	*	*	-38	-39	-53
5	-1	12	-25	-1	12
3	29	4	20	29	4
0	-12	4	10	-13	4
2	16	2	5	-83	2
-1	-8	2	-48	-1	2
10	16	12	-9	8	12
-4	-8	2	24	30	2
1	2	3	-2	71	3
12	7	6	-45	-8	6
-2	-2	-4	5	9	-4
12	12	15	13	-90	-85
-82	-76	-79	-37	50	43
14	5	7	5	-1	12
-5	46	2	3	29	4
-9	-50	12	0	-12	4
-24	10	-15	2	16	1
21	-10	-13	-1	-8	3
16	-4	26	10	16	12
-28	3	-29	-4	-81	2
15	-8	22	1	-16	3
-1	-7	2	-17	-2	6
20	-25	-21	6	32	-4
-30	1	2	23	1	-29
54	63	25	-28	26	-14
5	-36	12	5	-1	1
5	-32	3	3	29	15
1	-4	7	0	-12	4
1	51	1	2	16	1
-1	48	3	-1	-8	3
10	-86	12	10	16	12
-4	-8	2	-4	-8	2
10	2	4	1	2	3
3	101	-39	12	7	6
-2	7	40	-3	-2	-4
12	-2	10	13	5	15

Lampiran 1  
Tabel 3.8 Hasil peramalan 6 bulan

<i>Forecast_1</i>	<i>Forecast_2</i>	<i>Forecast_3</i>
155,379	154,789	141,010
151,392	145,194	131,310
148,135	139,142	125,033
145,475	135,325	120,970
143,302	132,918	118,341
141,527	131,339	116,640



## Lampiran 2

### Overfitting Model ARIMA

#### 1. Christian Dior:

##### ARIMA 011

ARIMA model for Christian Dior

Estimates at each iteration

Iteration	SSE	Parameters
0	24797.4	0.100
1	24077.2	0.250
2	24045.2	0.282
3	24044.2	0.288
4	24044.1	0.289
5	24044.1	0.289

Relative change in each estimate less than 0.0010

Final Estimates of Parameters

Type	Coef	SE Coef	T	P
MA 1	0.2889	0.1149	2.51	0.014

Differencing: 1 regular difference

Number of observations: Original series 72, after differencing 71

Residuals: SS = 24041.2 (backforecasts excluded)  
MS = 343.4 DF = 70

Modified Box-Pierce (Ljung-Box)	Chi-Square	Statistic		
Lag	12	24	36	48
Chi-Square	13.4	19.5	36.0	42.2
DF	11	23	35	47
P-Value	0.268	0.671	0.422	0.673

Forecasts from period 72

Period	Forecast	95 Percent Limits	
		Lower	Upper
Actual			
73	160.201	123.870	196.532
74	160.201	115.621	204.781
75	160.201	108.676	211.726
76	160.201	102.561	217.840
77	160.201	97.036	223.366
78	160.201	91.957	228.445

### ARIMA 110

ARIMA model for Christian Dior

Estimates at each iteration

Iteration	SSE	Parameters
0	27334.8	0.100
1	25251.8	-0.050
2	24321.8	-0.200
3	24267.7	-0.244
4	24267.6	-0.246
5	24267.6	-0.246

Relative change in each estimate less than 0.0010

Final Estimates of Parameters

Type	Coef	SE Coef	T	P
AR 1	-0.2460	0.1163	-2.12	0.038

Differencing: 1 regular difference

Number of observations: Original series 72, after differencing 71

Residuals: SS = 24266.2 (backforecasts excluded)  
MS = 346.7 DF = 70

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

Lag	12	24	36	48
Chi-Square	13.7	19.4	35.5	42.6
DF	11	23	35	47
P-Value	0.249	0.678	0.446	0.653

Forecasts from period 72

Period	Forecast	95 Percent Limits	
		Lower	Upper
Actual			
73	160.802	124.302	197.303
74	161.589	115.875	207.302
75	161.395	106.864	215.926
76	161.443	99.592	223.294
77	161.431	92.982	229.880
78	161.434	86.983	235.886

UNIVERSITAS ISLAMAZON

## ARIMA 112

ARIMA model for Christian Dior

Estimates at each iteration

Iteration	SSE	Parameters		
0	26053.4	0.100	0.100	0.100
1	25393.1	0.206	0.250	0.095
2	24859.2	0.312	0.400	0.074
3	24401.2	0.411	0.550	0.038
4	24104.0	0.518	0.700	-0.010
5	23901.1	0.642	0.850	-0.059
6	23583.5	0.774	1.000	-0.109
7	23129.5	0.899	1.150	-0.161
8	22815.5	0.797	1.155	-0.185
9	22698.7	0.813	1.158	-0.177
10	22696.9	0.815	1.159	-0.177
11	22696.5	0.817	1.160	-0.178

Unable to reduce sum of squares any further

Final Estimates of Parameters

Type		Coef	SE Coef	T	P
AR	1	0.8169	0.0837	9.76	0.000
MA	1	1.1600	0.0080	144.47	0.000
MA	2	-0.1781	0.0423	-4.21	0.000

Differencing: 1 regular difference

Number of observations: Original series 72, after differencing 71

Residuals: SS = 22674.1 (backforecasts excluded)  
MS = 333.4 DF = 68

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

Lag	12	24	36	48
Chi-Square	12.4	18.0	33.2	38.3
DF	9	21	33	45
P-Value	0.191	0.647	0.456	0.749

Forecasts from period 72

Period	Forecast	95 Percent Limits	
		Lower	Upper
Actual			
73	155.379	119.581	191.176
74	151.392	108.562	194.222
75	148.135	100.926	195.345
76	145.475	95.343	195.607
77	143.302	91.135	195.469
78	141.527	87.899	195.155

## 2. Rayban

### Arima 111

ARIMA model for Rayban

Estimates at each iteration

Iteration	SSE	Parameters	
0	80100.0	0.100	0.100
1	77936.0	0.029	0.172
2	76947.1	0.176	0.322
3	75719.8	0.321	0.472
4	74245.3	0.462	0.622
5	72348.4	0.595	0.772
6	69401.7	0.701	0.922
7	67085.0	0.648	0.990
8	66834.6	0.648	0.989
9	66708.3	0.642	0.987
10	66642.4	0.638	0.986
11	66608.4	0.635	0.985
12	66591.0	0.633	0.984
13	66581.9	0.632	0.984
14	66577.0	0.631	0.983
15	66574.3	0.631	0.983

Relative change in each estimate less than 0.0010

Final Estimates of Parameters

Type	Coef	SE Coef	T	P
AR 1	0.6307	0.0957	6.59	0.000
MA 1	0.9833	0.0191	51.40	0.000

Differencing: 1 regular difference

Number of observations: Original series 72, after differencing 71

Residuals: SS = 66536.0 (backforecasts excluded)  
MS = 964.3 DF = 69

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

Lag	12	24	36	48
Chi-Square	21.7	34.6	41.1	45.3
DF	10	22	34	46
P-Value	0.016	0.043	0.186	0.502

Forecasts from period 72

Period	Forecast	95 Percent Limits	
		Lower	Upper
Actual			
73	154.789	93.913	215.665
74	145.194	72.672	217.716
75	139.142	62.142	216.143
76	135.325	56.397	214.254
77	132.918	53.089	212.746
78	131.399	51.114	211.685

**ARIMA 011**

ARIMA model for Rayban

Estimates at each iteration

Iteration	SSE	Parameters
0	78513.1	0.100
1	77912.8	0.168
2	77707.3	0.207
3	77619.6	0.232
4	77578.2	0.249
5	77557.5	0.261
6	77546.9	0.269
7	77541.2	0.275
8	77538.2	0.280
9	77536.6	0.283
10	77535.7	0.285
11	77535.2	0.287
12	77535.0	0.288
13	77534.8	0.289
14	77534.7	0.290
15	77534.7	0.291
16	77534.7	0.291
17	77534.6	0.291

Relative change in each estimate less than 0.0010

Final Estimates of Parameters

Type	Coef	SE Coef	T	P
MA 1	0.2913	0.1144	2.55	0.013

Differencing: 1 regular difference

Number of observations: Original series 72, after differencing 71

Residuals: SS = 77530.7 (backforecasts excluded)  
MS = 1107.6 DF = 70

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

Lag	12	24	36	48
Chi-Square	36.6	54.1	62.0	64.2
DF	11	23	35	47
P-Value	0.000	0.000	0.003	0.049

Forecasts from period 72

Period	Forecast	95 Percent Limits	
		Lower	Upper
Actual			
73	168.534	103.291	233.776
74	168.534	88.567	248.500
75	168.534	76.161	260.906
76	168.534	65.235	271.832
77	168.534	55.358	281.709
78	168.534	46.277	290.790

### ARIMA 012

ARIMA model for Rayban

Estimates at each iteration

Iteration	SSE	Parameters	
0	76223.2	0.100	0.100
1	72396.5	0.246	0.193
2	71070.7	0.326	0.242
3	70743.1	0.359	0.267
4	70662.9	0.374	0.279
5	70642.7	0.381	0.285
6	70637.6	0.384	0.288
7	70636.3	0.386	0.289
8	70635.9	0.387	0.290
9	70635.8	0.387	0.290
10	70635.8	0.387	0.290

Relative change in each estimate less than 0.0010  
Forecasts from period 72

Period	Forecast	95 Percent Limits	
		Lower	Upper
Actual			
73	164.033	101.383	226.683
74	160.866	87.396	234.336
75	160.866	84.674	237.059
76	160.866	82.045	239.688
77	160.866	79.501	242.232
78	160.866	77.035	244.698

### 3. Carrara

#### ARIMA 111

ARIMA model for Carrara

Estimates at each iteration

Iteration	SSE	Parameters	
0	28516.0	0.100	0.100
1	25992.5	-0.035	0.235
2	25670.5	0.099	0.385
3	25405.7	0.224	0.535
4	25235.7	0.314	0.655
5	25148.5	0.383	0.722
6	25008.5	0.457	0.791
7	24698.3	0.547	0.874
8	24203.4	0.637	0.962
9	24101.4	0.650	0.986
10	24092.2	0.658	1.005
11	23945.0	0.651	1.003
12	23937.6	0.647	1.000

Unable to reduce sum of squares any further

Final Estimates of Parameters

Type	Coef	SE Coef	T	P
AR -1	0.6471	0.0965	6.71	0.000
MA 1	0.9999	0.0118	85.00	0.000

Differencing: 1 regular difference

Number of observations: Original series 72, after differencing 71

Residuals: SS = 23759.8 (backforecasts excluded)  
MS = 344.3 DF = 69

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

Lag	Chi-Square	DF	P-Value
12	6.3	10	0.789
24	22.7	22	0.416
36	31.6	34	0.587
48	33.4	46	0.917

Forecasts from period 72

Period	Forecast	95 Percent Limits	
		Lower	Upper
Actual			
73	141.010	104.632	177.389
74	131.310	87.977	174.643
75	125.033	79.097	170.968
76	120.970	73.987	167.954
77	118.341	70.925	165.757
78	116.640	69.044	164.236

**ARIMA 011**

ARIMA model for Carrara

Estimates at each iteration

Iteration	SSE	Parameters
0	27243.2	0.100
1	26019.9	0.250
2	25672.6	0.348
3	25647.5	0.374
4	25645.7	0.380
5	25645.6	0.382
6	25645.6	0.383
7	25645.6	0.383

Relative change in each estimate less than 0.0010

Final Estimates of Parameters

Type	Coef	SE Coef	T	P
MA 1	0.3828	0.1109	3.45	0.001

Differencing: 1 regular difference

Number of observations: Original series 72, after differencing 71

Residuals: SS = 25615.3 (backforecasts excluded)  
MS = 365.9 DF = 70

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

Lag	12	24	36	48
Chi-Square	7.4	23.5	32.0	38.2
DF	11	23	35	47
P-Value	0.765	0.432	0.614	0.816

Forecasts from period 72

Period	Forecast	95 Percent Limits	
		Lower	Upper
Actual			
73	150.383	112.882	187.884
74	150.383	106.315	194.451
75	150.383	100.607	200.159
76	150.383	95.489	205.276
77	150.383	90.810	209.956
78	150.383	86.472	214.294

**ARIMA 012**

ARIMA model for Carrara

Estimates at each iteration

Iteration	SSE	Parameters	
0	26686.5	0.100	0.100
1	25410.6	0.250	0.159
2	25234.1	0.325	0.152
3	25231.6	0.334	0.150
4	25231.5	0.335	0.151
5	25231.5	0.335	0.151
6	25231.5	0.335	0.151
7	25231.5	0.335	0.151

Relative change in each estimate less than 0.0010

Final Estimates of Parameters

Type	Coef	SE Coef	T	P
MA 1	0.3354	0.1197	2.80	0.007
MA 2	0.1512	0.1199	1.26	0.211

Differencing: 1 regular difference

Number of observations: Original series 72, after differencing 71

Residuals: SS = 25175.8 (backforecasts excluded)  
MS = 364.9 DF = 69

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

Lag	12	24	36	48
Chi-Square	6.7	22.6	31.4	37.0
DF	10	22	34	46
P-Value	0.758	0.426	0.594	0.825

Forecasts from period 72

Period	Forecast	95 Percent Limits	
		Lower	Upper
Actual			
73	150.363	112.917	187.810
74	147.851	102.889	192.812
75	147.851	98.953	196.749
76	147.851	95.310	200.392
77	147.851	91.904	203.798
78	147.851	88.694	207.008

