


**PERAMALAN JUMLAH PRODUKSI GRANIT
DENGAN MODEL ARIMA
(Studi Kasus pada PT. Karimun Granite, Tanjung Balai Karimun, Riau)**

SKRIPSI



Oleh
FAKHRIWAN ARIES
97611017

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

HALAMAN JUDUL SKRIPSI

**PERAMALAN JUMLAH PRODUKSI GRANIT
DENGAN MODEL ARIMA**

(Studi Kasus pada PT. Karimun Granite, Tanjung Balai Karimun, Riau)

SKRIPSI

Ditulis dan diajukan untuk memenuhi syarat akhir guna memperoleh gelar Sarjana Strata-1 di Jurusan Statistika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Islam Indonesia



Disusun oleh :

Nama : FAKHRIWAN ARIES

Nomor Mahasiswa : 97611017

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

HALAMAN PENGESAHAN PEMBIMBING

Peramalan Jumlah Produksi Granit dengan Model ARIMA
(Studi Kasus pada PT. Karimun Granite, Tanjung Balai Karimun, Riau)



Nama : FAKHRIWAN ARIES
Nomor Mahasiswa : 97611017

Yogyakarta, 26 Juni 2004
Telah disetujui dan disahkan

Dosen Pembimbing I

A handwritten signature in black ink, consisting of a large, sweeping initial 'S' followed by a series of loops and a horizontal line.

Drs. Supriyono, M.Sc

Dosen Pembimbing II

A handwritten signature in black ink, featuring a large, stylized initial 'R' followed by several loops and a horizontal line.

Rohmatul Fajriyah, M.Si

HALAMAN PENGESAHAN UJIAN

Telah dipertahankan / diujikan dan disahkan
untuk memenuhi syarat guna memperoleh gelar Sarjana Strata-1
di Jurusan Statistika Fakultas Matematika dan Ilmu Pengetahuan Alam
Universitas Islam Indonesia

Nama : FAKHRIWAN ARIES

Nomor Mahasiswa : 97611017

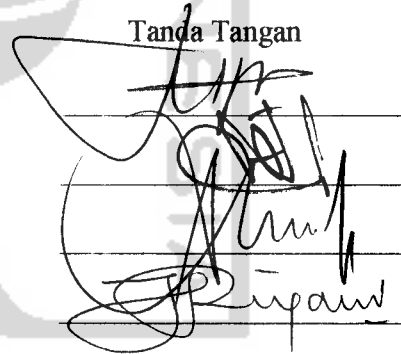
Yogyakarta, 3 Juli 2004

Disahkan oleh

Tim Penguji :

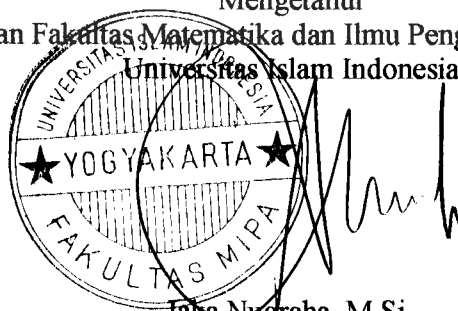
1. Drs. Supriyono, M.Sc.
2. Rohmatul Fajriyah, M.Si.
3. Jaka Nugraha, M.Si.
4. Kariyam, M.Si.

Tanda Tangan



Mengetahui

Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam
Universitas Islam Indonesia



Jaka Nugraha, M.Si.

HALAMAN PERSEMBAHAN



Kupersembahkan Karya Sederhana ini Untuk :
Papa Masyhur By dan Mama Martizawari Tercinta
Atas segala kasih sayang, pengharapan, serta do'a yang tiada hentinya.

Saudara Bungsku
Adhari Donora
Atas perhatian dan dukungannya selama ini.

Fatikah Irsad, S.E
Atas kesabaran, dukungan dan kasih sayangnya

HALAMAN MOTO

“Allah tidak membebani seseorang melainkan sesuai dengan kesanggupannya”

(Q. S. Al Baqarah : 286)

“Katakanlah : Adakah sama orang - orang yang mengetahui dengan orang - orang yang tidak mengetahui ? Sesungguhnya orang yang berakallah yang dapat menerima pelajaran”

(QS. Az Zumar : 9)

“ Tidak ada sesuatu yang lebih baik dari pada akal yang diperindah dengan ilmu, dan ilmu yang diperindah dengan kebenaran (siddiq), dan kebenaran yang dipeindah dengan kebaikan, dan kebaikan yang diperindah dengan taqwa”

(Abdul Aziz Salim Basyarahil)

KATA PENGANTAR



Assalamu'alaikum Wr.Wb

Alhamdulillah robbil alamin, segala puji syukur kepada Allah SWT, atas segala karunia dan kemudahan petunjuk yang telah diberikan-Nya. Hanya Engkau ya Allah, Yang Maha Pengasih lagi Maha Penyayang, yang memberikan kasih sayang kepada makhluk ciptaan-Mu, dan atas Ridha-Mu serta kehendak-Mu akhirnya penulis dapat menyelesaikan skripsi ini.

Skripsi ini merupakan salah satu syarat yang ditempuh untuk menyelesaikan studi tingkat sarjana di Jurusan Statistika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Islam Indonesia.

Penulis menyadari dalam penyusunan tugas akhir ini banyak bantuan, saran, nasehat maupun kritik yang penulis terima sehingga naskah ini dapat diselesaikan dengan baik. Dengan segala kerendahan hati penulis mengucapkan terima kasih yang sebesar-besarnya kepada:

1. Bapak Jaka Nugraha, M.Si, selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Islam Indonesia, beserta seluruh staf akademik maupun non akademik yang telah mendidik penulis di Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Islam Indonesia ini.

2. Bapak Drs. Supriyono, M.Sc, selaku dosen pembimbing pertama yang senantiasa membantu dan membimbing penulis dalam menyelesaikan skripsi ini.
3. Ibu Rohmatul Fajriyah M.Si, selaku pembimbing pendamping kedua dan pembimbing akademik atas bimbingan, tuntunan serta dorongan untuk menyelesaikan studi dengan sebaik-baiknya dan kerjasamanya memberikan kesempatan berdiskusi, serta dukungan dan koreksi yang diberikan kepada penulis.
4. Seluruh keluarga besar staf dan karyawan PT. Karimun Granite atas kerjasama dan bantuannya dalam penelitian ini.
5. Seluruh keluarga besar Zainun, khususnya yang di Jogja, Bang Ibon S.S & Mbak Hana S.S, Bang Yudi S.Ag, Bang Eki S.T, Bang Noki S.Psi, Kak Mega S.Ag & Bang Rey S.HI, Idun S.P, dan Pipin.
6. Chadeng S.Si dan Wiwi S.E, Amoy S.Si, Zaki S.Si, Ida S.Si, Wahyu S.Si, Pahlawan S.S, Chandra S.H, Iin Chakay, Amex, Mbak Tachie, Jerdoet, Izon S.E, Son, Ieph atas bantuan dan dorongannya untuk cepat-cepat menyelesaikan skripsi ini.
7. Teman-teman Statistika '97 UII atas bantuan yang telah diberikan dan suka duka yang kita lewati bersama. Semoga Ukhuwah Islamiyah yang kita jalin selama ini tetap terjaga dengan baik.
8. Teman-teman seluruh angkatan Jurusan Statistika Universitas Islam Indonesia atas persahabatannya selama ini, semoga kampus kita semakin maju.

9. Semua pihak yang karena keterbatasan penulis untuk mengingat maka tidak dapat disebutkan satu persatu, yang telah membantu menyelesaikan skripsi ini.

Semoga Allah SWT, membalas segala amal perbuatan mereka dengan sebaik-baiknya balasan. Penulis berharap semoga karya yang sederhana ini dapat bermanfaat bagi semua pihak. Apabila ada kesalahan yang telah dilakukan, penulis mohon maaf yang tak terkira *Amin ya robbal 'alamin*.

Wassalamu'alaikum Wr.Wb



Yogyakarta, Juli 2004

Penulis

DAFTAR ISI

	Halaman
HALAMAN JUDUL SKRIPSI	i
HALAMAN PENGESAHAN DOSEN PEMBIMBING	ii
HALAMAN PENGESAHAN UJIAN	iii
HALAMAN PERSEMBAHAN	iv
HALAMAN MOTO	v
KATA PENGANTAR	vi
DAFTAR ISI	ix
DAFTAR TABEL	xiii
DAFTAR GAMBAR	xiv
DAFTAR LAMPIRAN	xv
INTISARI	xvi
BAB I. PENDAHULUAN	
1.1. Latar Belakang Masalah	1
1.2. Rumusan Masalah	2
1.3. Batasan Masalah	3
1.4. Tujuan Penelitian	3
1.5. Manfaat Penelitian	3
1.6. Sistematika Penulisan	4

BAB II. TEORI PENUNJANG

2.1. Stasioner	5
2.2. Non Stasioner	7
2.3. <i>Backward Shift Operator</i> (Operator Shift Mundur)	7
2.4. Autokorelasi	7
2.5. Autokorelasi Parsial	8
2.6. Autoregresif (AR)	9
2.7. <i>Moving Average</i> (MA)	10
2.8. <i>Integrated</i> (I)	12
2.9. Musiman	12

BAB III. METODOLOGI PENELITIAN

3.1. Objek dan Tempat Penelitian	13
3.2. Sumber Data	13
3.3. Metode Pengumpulan Data	13
3.4. Analisis Data	13
3.4.1. Metode Box-Jenkins (ARIMA)	13
3.4.1.1. Model ARIMA	14
3.4.1.2. Membangun Model ARIMA	15
3.4.1.2.1. Identifikasi Model	15
3.4.1.2.2. Pengujian Parameter	19
3.4.2. Model Autoregresif Moving Average (ARMA)	20
3.4.2.1. Membangun Model ARMA	21



3.4.2.1.1. Identifikasi Model	21
3.4.3. Langkah-langkah Pengolahan dan Analisis Data	24
3.4.4. Pemeriksaan Diagnostik	26
3.4.5. Peramalan	27

BAB IV. ANALISA DATA DAN PEMBAHASAN

4.1. Pembahasan Produksi <i>Tertiary</i>	28
4.1.1. Identifikasi Model	28
4.1.2. Pengujian Parameter	29
4.1.2.1. Uji <i>Over All</i>	31
4.1.2.2. Uji Parsial	31
4.1.3. Pemeriksaan Diagnostik	32
4.1.3.1. <i>Overfitting</i>	32
4.1.3.2. Analisis Residu	33
4.1.4. Peramalan dengan Model ARIMA (1 0 0)	35
4.2. Pembahasan Produksi <i>Road Base</i>	36
4.2.1. Identifikasi Model	36
4.2.2. Pengujian Parameter	37
4.2.2.1. Uji <i>Over All</i>	37
4.2.2.2. Uji Parsial	38
4.2.3. Pemeriksaan Diagnostik	39
4.2.3.1. <i>Overfitting</i>	39
4.2.3.2. Uji <i>Over All</i>	40

4.2.3.3. Uji Parsial	41
4.2.3.4. Analisis Residu	42
4.2.4. Peramalan dengan Model ARIMA (1 0 1)	43

BAB V. KESIMPULAN DAN SARAN

5.1. Kesimpulan	45
5.2. Saran	46

DAFTAR PUSTAKA

LAMPIRAN



DAFTAR TABEL

	Halaman
Tabel 4.1 Nilai <i>Modified Box-Pierce (Ljung-Box) Chi-Square statistic</i>	31
Tabel 4.2 Hasil Pengujian Parameter	31
Tabel 4.3 Hasil Peramalan Produksi <i>Tertiary</i>	35
Tabel 4.4 Nilai <i>Modified Box-Pierce (Ljung-Box) Chi-Square statistic</i>	38
Tabel 4.5 Hasil Pengujian Parameter	38
Tabel 4.6 Nilai <i>Modified Box-Pierce (Ljung-Box) Chi-Square statistic</i>	40
Tabel 4.7 Hasil Pengujian Parameter	41
Tabel 4.8 Hasil Peramalan Produksi <i>Road Base</i>	43



DAFTAR GAMBAR

	Halaman
Gambar 3.1 Fungsi- fungsi autokorelasi dan autokorelasi parsial untuk model-model AR(1), AR(2), MA(1) dan MA(2)	18
Gambar 3.2 Fungsi-fungsi autokorelasi dan autokorelasi parsial untuk model-model ARMA (1,1)	24
Gambar 3.3 Skema yang memperlihatkan pendekatan Box-Jenkins	25
Gambar 4.1 Time series plot data produksi <i>tertiary</i>	29
Gambar 4.2 Fungsi autokorelasi data produksi <i>tertiary</i>	29
Gambar 4.3 Fungsi autokorelasi parsial data produksi <i>tertiary</i>	30
Gambar 4.4 Fungsi autokorelasi residual produksi <i>tertiary</i>	33
Gambar 4.5 Fungsi autokorelasi parsial residual produksi <i>tertiary</i>	34
Gambar 4.6 Time series plot data produksi <i>road base</i>	36
Gambar 4.7 Fungsi autokorelasi data produksi <i>road base</i>	36
Gambar 4.8 Fungsi autokorelasi parsial data produksi <i>road base</i>	37
Gambar 4.9 Fungsi autokorelasi residual produksi <i>road base</i>	42
Gambar 4.10 Fungsi autokorelasi parsial residual produksi <i>road base</i>	42

DAFTAR LAMPIRAN

- Lampiran A.** Data jumlah produksi granit untuk periode Januari 2001 sampai dengan Desember 2002.
- Lampiran B.** Hasil estimasi parameter untuk data produksi *tertiary* untuk model-model ARIMA yang memenuhi syarat uji *overall* dan uji parsial.
- Lampiran C.** Hasil estimasi parameter untuk data produksi *road base* untuk model-model ARIMA yang memenuhi syarat uji *overall* dan uji parsial.
- Lampiran D.** Tabel I : Hasil Peramalan Produksi *Tertiary*.
- Lampiran E.** Tabel II : Hasil Peramalan Produksi *Road Base*.
- Lampiran F.** Komputasi data.
- Lampiran G.** Tabel III : Distribusi Chi kuadrat.
- Lampiran H.** Tabel IV : Distribusi normal.

INTISARI

Telah dilakukan suatu penelitian tentang data pada produksi granit tertiary dan produksi granit road base selama periode Januari 2001 sampai dengan Desember 2002. Dari data-data tersebut dapat dibuat peramalan untuk menentukan jumlah produksi granit tertiary dan produksi granit road base. Dalam menentukan model-model peramalan dan peramalan besar produksi granit tertiary dan produksi granit road base dari PT. Karimun Granite, digunakan langkah atau cara dengan metode time series ARIMA. Hasil peramalan menunjukkan bahwa produksi granit tertiary menggunakan model ARIMA (1 0 0) sebagai model peramalannya dan produksi granit road base menggunakan model ARIMA (1 0 1) sebagai model peramalannya.

Kata kunci : ARIMA, produksi granit tertiary, produksi granit road base.



BAB I

PENDAHULUAN

1.1. Latar Belakang Masalah

Perkembangan ekonomi dan dunia bisnis yang sangat pesat dewasa ini, yang ditandai dengan tingkat persaingan yang semakin keras, menuntut pihak manajemen untuk dapat memahami dan meramalkan keadaan dimasa depan yang didasarkan pada kerangka pikir yang sistematis, rasional dan ekonomis. Salah satu aspek yang penting dalam pengelolaan suatu organisasi adalah perencanaan untuk masa yang akan datang. Kelangsungan hidup suatu organisasi dipengaruhi secara penuh oleh pengelolaan yang baik, antara lain kemampuan untuk mengetahui prospek ke depan dengan menerapkan strategi yang tepat. Berkaitan dengan itu seorang pengambil keputusan, pengambil kebijakan atau peneliti dalam suatu organisasi seharusnya mempunyai latar belakang yang memadai tentang ilmu peramalan data (*forecasting*).

Peramalan pada dasarnya merupakan bagian dari proses pengambilan keputusan. Kebutuhan akan peramalan akan semakin meningkat bila semakin diinginkan ketidaktergantungan akan faktor ketidakpastian. Hanya saja patut dicatat bagaimanapun baiknya metode peramalan yang digunakan, faktor ketidakpastian tidak dapat dieliminasi seluruhnya. Dengan demikian pengetahuan yang luas akan metode-metode peramalan adalah sangat penting mengingat masing-masing metode peramalan tersebut memiliki kelemahan dan kelebihan sendiri.

Seorang peneliti pada suatu perusahaan membutuhkan peramalan untuk memperkirakan jumlah produksi selama beberapa periode dimasa mendatang. Konsekuensinya, apabila peramalannya tidak akurat akan menghasilkan perencanaan yang tidak tepat. Akibatnya, akan menimbulkan biaya proses produksi yang tinggi, sehingga tidak efisien bagi suatu perusahaan.

PT. Karimun Granite yang beroperasi di daerah Tanjung Balai Karimun adalah sebuah perusahaan yang memproduksi granit untuk dijadikan produk *amour rock*, *tertiary*, *road base* dan *manufacturing sand*. Untuk memperkirakan jumlah produksi dalam perusahaan selama waktu tertentu, maka dibutuhkan peramalan yang akurat agar menghasilkan perencanaan yang tepat. Oleh karena itu, perlu dilakukan penelitian tentang jumlah produksi granit dari data hasil produksi granit tahun-tahun sebelumnya. Dalam penelitian ini, metode yang dipakai adalah metode *time series*, menggunakan model ARIMA. Diharapkan, metode tersebut akan menghasilkan perhitungan yang akurat dan kesimpulan yang tepat.

1.2. Rumusan Masalah

Dari latar belakang permasalahan diatas, maka timbul permasalahan sebagai berikut :

1. Bagaimanakah model ARIMA yang tepat untuk meramalkan jumlah produksi granit untuk produk *tertiary* dan *road base* di PT. Karimun Granite.
2. Berapakah jumlah produksi granit untuk produk *tertiary* dan *road base* untuk periode Januari 2003 sampai dengan Desember 2003.

1.3. Batasan Masalah

Untuk membatasi ruang lingkup penelitian agar tidak terlalu luas, diambil objek penelitian dengan batasan sebagai berikut :

1. Data yang digunakan adalah data jumlah produksi granit untuk produk *tertiary* dan *road base* periode Januari 2001 sampai dengan Desember 2002.
2. Analisis dilakukan dengan menggunakan model peramalan ARIMA.
3. *Software* komputer yang digunakan sebagai alat bantu perhitungan adalah Minitab 11.

1.4. Tujuan Penelitian

Berdasarkan permasalahan penelitian, maka penelitian ini bertujuan untuk :

1. Menentukan model ARIMA yang tepat, yang akan digunakan untuk meramalkan jumlah produksi granit untuk produk *tertiary* dan *road base* untuk periode Januari 2003 sampai dengan Desember 2003.
2. Mengetahui seberapa besar jumlah produksi granit untuk produk *tertiary* dan *road base* untuk periode Januari 2003 sampai dengan Desember 2003.

1.5. Manfaat Penelitian

Dari penelitian ini, diharapkan menghasilkan manfaat, sebagai berikut :
Diharapkan dapat dijadikan masukan bagi perusahaan sebagai pertimbangan dalam menetapkan kebijakan dalam memproduksi batu granit.

1.6. Sistematika Penulisan

Penulisan tugas akhir ini dibagi kedalam bab yang disusun sebagai berikut :

BAB I PENDAHULUAN

Berisi tentang latar belakang penelitian, rumusan masalah, batasan masalah, tujuan penelitian, manfaat penelitian dan sistematika penulisan.

BAB II TEORI PENUNJANG

Berisi uraian tentang pengertian-pengertian umum berkaitan dengan analisis runtun waktu ARIMA.

BAB III METODOLOGI PENELITIAN

Membahas tentang metodologi penelitian, konsep dasar ARIMA, dan perangkat statistik yang digunakan dalam pembentukan model peramalan ARIMA.

BAB IV ANALISIS DATA DAN PEMBAHASAN

Merupakan uraian tentang hasil output komputer dan kemudian dilakukan pembahasan hasil olahan data dari output komputer tersebut.

BAB V KESIMPULAN DAN SARAN

Berisi kesimpulan yang diperoleh dari analisis pemecahan masalah serta saran-saran.

BAB II

TEORI PENUNJANG

2.1. Stasioner

Suatu deret berkala menunjukkan sifat stasioner jika proses pembangkit yang mendasari memiliki nilai tengah konstan dan nilai ragam (varians) konstan.

Data yang non stasioner dapat dibuat lebih mendekati stasioner dengan menggunakan operator *shift* mundur B, yang penggunaannya adalah sebagai berikut : (Napa J. Awat, 1990).

$$BX_t = X_{t-1} \quad (2.1)$$

yang artinya, notasi B yang dipasang pada X_t bertujuan untuk menggeser data satu periode ke belakang. Untuk menggeser data 2 periode ke belakang adalah :

$$B(BX_t) = B^2 X_t = X_{t-2} \quad (2.2)$$

Operator *shift* mundur sangat tepat untuk menggambarkan proses pembedaan (*differencing*). Apabila suatu deret berkala tidak stasioner maka data tersebut dapat dibuat lebih mendekati stasioner dengan melakukan pembedaan pertama dari deret data dan persamaan (2.3) memberi batasan mengenai apa yang dimaksud dengan pembedaan pertama.

Pembedaan pertama

$$X'_t = X_t - X_{t-1} \quad (2.3)$$

apabila menggunakan operator *shift* mundur, persamaan (2.3) dapat di tulis sebagai berikut :

$$\begin{aligned}
 X'_t &= X_t - BX_t \\
 &= (1-B)X_t
 \end{aligned}
 \tag{2.4}$$

Pembedaan pertama dinyatakan dengan $(1-B)$. Maka pembedaan orde kedua (yaitu perbedaan pertama dari perbedaan pertama sebelumnya) dapat dihitung sebagai berikut :

Pembedaan orde kedua

$$\begin{aligned}
 X''_t &= X'_t - X'_{t-1} \\
 &= (X_t - X_{t-1})(X_{t-1} - X_{t-2}) \\
 &= X_t - 2X_{t-1} + X_{t-2} \\
 &= (1 - 2B + B^2)X_t \\
 &= (1-B)^2 X_t
 \end{aligned}
 \tag{2.5}$$

dimana :

B = *backshift* (adalah fungsi transfer dari linear filter yang menghubungkan X_t dengan e_t)

X_t = observasi runtun waktu variabel itu pada waktu 1, 2, ..., t

X_{t-1} = nilai pengamatan pada data satu periode ke belakang

X'_t = pembedaan pertama

X''_t = pembedaan orde kedua

Pembedaan orde kedua dinyatakan dengan $(1-B)^2$. Tujuan menghitung pembedaan adalah untuk mencapai stasioneritas, dan secara umum, apabila terdapat pembedaan orde ke-d ditulis :

$$\text{Pembedaan orde ke-d} = (1 - B)^d X_t \quad (2.6)$$

2.2. Non Stasioner

Suatu deret berkala menunjukkan sifat non stasioner jika proses pembangkit (*generating process*) yang mendasari tidak memiliki rata-rata yang konstan dan atau nilai ragam yang konstan.

2.3. Backward Shift Operator (Operator Shift Mundur)

Backward shift operator (operator *shift* mundur) dinotasikan dengan B, dipakai untuk menunjukkan pemunduran satu periode. Jadi B yang dioperasikan pada X_t mempunyai pengaruh memindahkan perhatian ke X_{t-1} .

2.4. Autokorelasi

Autokorelasi adalah asosiasi atau ketergantungan bersama antara nilai-nilai suatu deret berkala yang sama pada periode waktu yang berlainan. Autokorelasi mirip dengan korelasi, tetapi berhubungan dengan deret berkala untuk selang waktu (*time lag*) yang berbeda. Pola dari koefisien-koefisien autokorelasi sering digunakan untuk menetapkan ada atau tidaknya faktor musiman (*seasonality*) di dalam deret berkala tertentu (beserta panjangnya musim) untuk menentukan model deret berkala yang tepat pada situasi tertentu dan untuk menentukan adanya kestasioneran data.

Kriteria stasioner melalui plot autokorelasi, adalah :

- Nilai-nilai dari data stasioner akan turun dengan cepat atau mendekati nol sesudah time lag kedua atau ketiga.
- Sedangkan untuk data yang tidak stasioner, nilai-nilai autokorelasi akan berbeda signifikan dari nol untuk beberapa periode waktu.

Autokorelasi untuk *time lag* 1,2,...,k dapat dicari dengan menggunakan rumus autokorelasi, r_k yaitu : (Makridakis, Wheelwright dan McGee, 1999)

$$r_k = \frac{\sum_{t=1}^{n-k} (Y_t - \bar{Y})(Y_{t+k} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2} \quad (2.7)$$

dimana :

- r_k = autokorelasi ke-k
 Y_t = data pengamatan ke-t
 \bar{Y} = rata-rata pengamatan
 Y_{t+k} = data pengamatan ke-t+k

2.5. Autokorelasi Parsial

Ukuran korelasi ini dipakai untuk menunjukkan besarnya hubungan antara nilai suatu variabel dengan nilai sebelumnya dari variabel yang sama (nilai-nilai untuk kelambatan waktu) dengan menganggap pengaruh dari semua kelambatan waktu lainnya adalah konstan.

Autokorelasi parsial untuk *time lag* 1,2,...,k dapat dicari dengan menggunakan rumus autokorelasi parsial, r_{kk} yaitu : (B.L Bowerman dan R.T O'Connel, 1983).

$$r_{kk} = \begin{cases} r_1 & ; \text{jika } k = 1 \\ \frac{r_k - \sum_{j=1}^{k-1} (r_{k-1,j})(r_{k-j})}{1 - \sum_{j=1}^{k-1} (r_{k-1,j})(r_j)} & ; \text{jika } k = 2,3,\dots \end{cases} \quad (2.8)$$

dimana :

r_{kk} = autokorelasi parsial ke-k

r_k = autokorelasi ke-k

r_{k-1} = autokorelasi ke-k-1

2.6. Autoregresif (AR)

Autoregresif adalah suatu bentuk persamaan regresi tetapi bukan yang menghubungkan variabel tak bebas (item yang diramalkan) dengan variabel bebas, melainkan menghubungkan nilai-nilai sebelumnya (*past value*) dengan diri sendiri (masing-masing variabel) pada *time lag* (selang waktu) yang bermacam-macam. Jadi suatu model AR akan menyatakan suatu ramalan sebagai fungsi nilai-nilai sebelumnya dari deret berkala tertentu.

Bentuk umum dari pada model autoregresif atau model AR orde ke-p adalah : (Napa J.Awat, 1990).

$$X_t = \Phi_1 X_{t-1} + \Phi_2 X_{t-2} + \dots + \Phi_p X_{t-p} + e_t \quad (2.9)$$

dimana :

X_{t-p} = nilai pengamatan pada saat t-p

$\Phi_1, \Phi_2, \dots, \Phi_p$ = parameter - parameter autoregresif

e_t = nilai galat pada saat t



Bentuk umum tersebut tergantung dari besarnya orde ke-p. Untuk orde $p=1$ atau model AR(1), dapat ditulis sebagai berikut :

$$X_t = \Phi_1 X_{t-1} + e_t \quad (2.10)$$

untuk model AR(2) atau orde $p=2$, dapat ditulis :

$$X_t = \Phi_1 X_{t-1} + \Phi_2 X_{t-2} + e_t \quad (2.11)$$

Sekarang dengan menggunakan operator *shift* mundur B, maka persamaan (2.10) dapat ditulis ulang sebagai berikut :

$$\left. \begin{array}{l} X_t - \Phi_1 X_{t-1} = e_t \\ \text{atau} \\ (1 - \Phi_1 B) X_t = e_t \end{array} \right\} \quad (2.12)$$

Sedangkan untuk persamaan (2.11) dengan menggunakan operator *shift* mundur B, dapat ditulis sebagai berikut :

$$\left. \begin{array}{l} X_t - \Phi_1 X_{t-1} - \Phi_2 X_{t-2} = e_t \\ \text{atau} \\ (1 - \Phi_1 B - \Phi_2 B^2) X_t = e_t \end{array} \right\} \quad (2.13)$$

Dan selang nilai yang diizinkan untuk Φ_1 didalam model AR(1) adalah : $-1 < \Phi_1 < +1$, sedangkan untuk model AR(2), selang nilai yang diizinkan untuk Φ_1 dan Φ_2 adalah : $-2 < \Phi_1 < +2$ dan $-1 < \Phi_2 < +1$.

2.7. Moving Average (MA)

Moving average atau rata-rata bergerak berarti bahwa nilai deret berkala pada waktu t dipengaruhi oleh unsur galat pada saat ini dan (mungkin) unsur galat terbobot pada masa lalu.

Bentuk umum dari pada model *Moving Average* berorde q atau $MA(q)$ adalah : (Napa J.Awat, 1990).

$$X_t = e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \quad (2.14)$$

dimana :

$\theta_1, \theta_2, \dots, \theta_q$ = parameter-parameter *moving average*

e_{t-k} = nilai galat pada saat $t-k$

Untuk orde $q = 1$ atau model $MA(1)$, dapat ditulis sebagai berikut :

$$X_t = e_t - \theta_1 e_{t-1} \quad (2.15)$$

dan untuk model $MA(2)$ atau orde $q = 2$, dapat ditulis :

$$X_t = e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} \quad (2.16)$$

Sekarang dengan menggunakan operator *shift* mundur B , maka persamaan (2.15) dapat ditulis ulang sebagai berikut :

$$\begin{aligned} X_t &= e_t - \theta_1 e_{t-1} \\ &= e_t - \theta_1 B e_{t-1} \\ &= (1 - \theta_1 B) e_t \end{aligned} \quad (2.17)$$

Sedangkan untuk persamaan (2.16) dengan menggunakan operator *shift* mundur B , dapat ditulis sebagai berikut :

$$X_t = (1 - \theta_1 B - \theta_2 B^2) e_t \quad (2.18)$$

Dan selang nilai yang diizinkan untuk θ_1 didalam model $MA(1)$ adalah :

$-1 < \theta_1 < +1$, sedangkan untuk model $MA(2)$, selang nilai yang diizinkan untuk

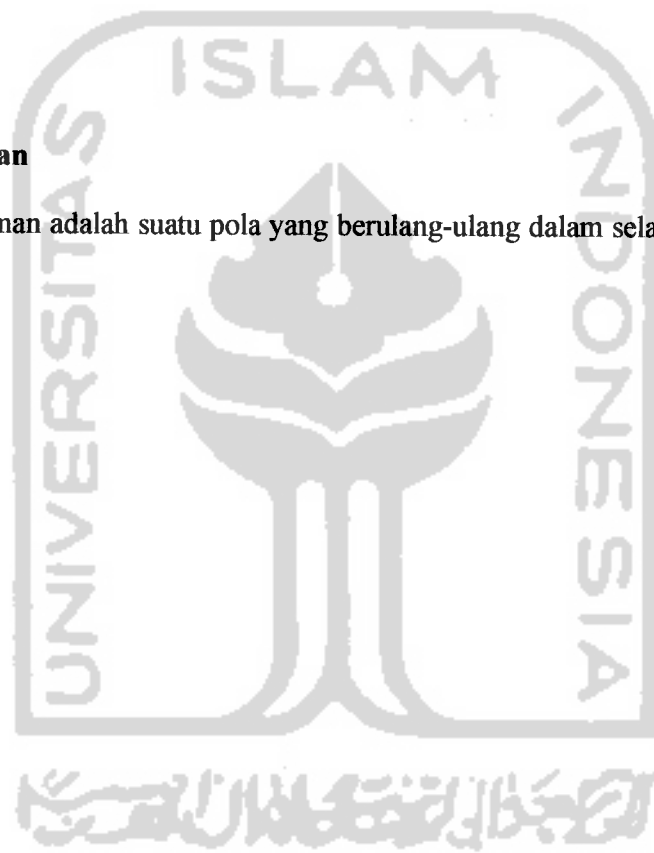
θ_1 dan θ_2 adalah : $-2 < \theta_1 < +2$ dan $-1 < \theta_2 < +1$.

2.8. *Integrated (I)*

Integrated merupakan bagian model-model deret berkala (I dalam model ARIMA) di mana satu atau lebih perbedaan-perbedaan deret berkala tercakup dalam model. Istilah itu datang dari suatu kenyataan bahwa rangkaian yang asli dapat dilukiskan kembali dari sebuah rangkaian yang berbeda dengan proses integrasi.

2.9. Musiman

Musiman adalah suatu pola yang berulang-ulang dalam selang waktu yang tetap.



BAB III

METODOLOGI PENELITIAN

3.1. Objek dan Tempat Penelitian

Penelitian dilakukan di PT. Karimun Granite, Pasir Panjang, Tanjung Balai Karimun, Riau. Dengan objek penelitian adalah data produksi granit untuk produk *tertiary* dan *road base*.

3.2. Sumber Data

Sumber data penelitian ini adalah data jumlah produksi granit untuk produk *tertiary* dan *road base* untuk periode Januari 2001 sampai dengan Desember 2002.

3.3. Metode Pengumpulan Data

Metode pengumpulan data dalam penelitian ini adalah melalui pencatatan data sekunder yang diperoleh dari bagian produksi PT. Katimun Granite tentang jumlah produksi granit untuk produk *tertiary* dan *road base* untuk periode Januari 2001 sampai dengan Desember 2002.

3.4. Analisis Data

3.4.1. Metode Box – Jenkins (ARIMA)

Model-model *Autoregressive Integrated Moving Average* (ARIMA) telah dipelajari secara mendalam oleh George Box dan Gwilym Jenkins (Makridakis,

Wheelwright dan McGee, 1999) dan nama mereka sering disinonimkan dengan proses ARIMA yang diterapkan untuk analisis deret berkala, peramalan dan pengendalian. Box dan Jenkins secara efektif telah berhasil mencapai kesepakatan mengenai informasi yang relevan yang diperlukan untuk memahami dan memakai model-model ARIMA untuk data deret berkala unvariat. Dasar dari pendekatan mereka dirangkum dalam bentuk skema pada Gambar 3.3 (Makridakis, Wheelwright dan McGee, 1999).

Metode peramalan Box-Jenkins menggunakan pendekatan yang bersifat saling mempengaruhi dalam mengidentifikasi suatu model yang paling tepat dari semua kemungkinan model yang ada. Model yang telah dipilih diuji lagi dengan data historis untuk melihat apakah model tersebut menggambarkan keadaan data secara akurat ataukah tidak. Model tersebut dikatakan tepat (sesuai) jika residual antara model peramalan dengan titik-titik data historis adalah kecil, terdistribusi random, dan independen satu sama lain. Jika spesifikasi model tersebut tidak memuaskan, proses diulangi dengan menggunakan rancangan model yang lain untuk menyempurnakan spesifikasi sebelumnya. Pemilihan model terbaik dapat dilakukan dengan membandingkan distribusi koefisien-koefisien autokorelasi dari data runtun waktu tersebut dengan distribusi teoritis dari berbagai macam model (Arsyad, 1999).

3.4.1.1. Model Autoregresif *Integrated Moving Average* (ARIMA)

Apabila nonstasioneritas ditambahkan pada campuran model ARMA, maka model umum ARIMA(p,d,q) terpenuhi. Jika ARMA(1,1)

menggunakan *first differencing* (pembedaan pertama), maka sering ditulis ARIMA(1,1,1). Persamaan ARIMA(1,1,1) dituliskan sebagai berikut (Napa J.Awat, 1990) :

$$(1-B)(1-\theta_1 B)X_t = (1-\theta_1)e_t \quad (3.1)$$

3.4.1.2. Membangun Model ARIMA

Untuk membangun model ARIMA yang baik dan sesuai dengan data, maka perlu dilakukan tahap-tahap seperti Gambar 3.3.

3.4.1.2.1. Identifikasi Model

Langkah identifikasi dimaksudkan untuk mengetahui nilai yang tepat dari p , d dan q . Alat yang digunakan untuk identifikasi adalah *autocorrelation function* (ACF) dan *partial autocorrelation* (PACF), serta hasil dari *correlograms* yang memplot *autocorrelation function* (ACF) dan *partial autocorrelation* (PACF) sepanjang *lag*.

Untuk mengidentifikasi sebuah model dapat dibagi menjadi tiga tahap, yaitu :

1. Mencapai stasioneritas melalui *differencing* (pembedaan)
 2. Memilih p dan q untuk data tidak musiman
 3. Memilih p dan q dan parameter musiman untuk data musiman
1. Mencapai stasioneritas melalui *differencing* (pembedaan)

Stasioneritas berarti bahwa tidak terdapat pertumbuhan atau penurunan pada data. Data secara kasarnya harus horizontal sepanjang

sumbu waktu. Dengan kata lain, fluktuasi data berada di sekitar suatu nilai rata-rata yang konstan, tidak tergantung pada waktu dan ragam dari fluktuasi tersebut pada pokoknya tetap konstan setiap waktu (Makridakis dan Wheelwright, 1995).

Nilai – nilai autokorelasi dari data yang stasioner akan turun sampai kenol sesudah *time lag* kedua atau ketiga, sedangkan untuk data yang tidak stasioner nilai-nilai tersebut berbeda signifikan dari nol untuk beberapa periode waktu. Untuk data yang tidak stasioner dapat di stasionerkan dengan melakukan pembedaan pertama terhadap data asli dan hitung autokorelasinya, apabila tetap tidak stasioner maka lakukanlah pembedaan pertama terhadap data yang telah dilakukan pembedaan pertama tersebut dan hitung autokorelasinya sampai nilai autokorelasi mendekati nol didalam dua atau tiga *time lag*.

2. Mengidentifikasi p dan q untuk data tidak musiman ataupun data musiman.

Setelah data bersifat stasioner, maka p dan q dapat diidentifikasi dengan melihat autokorelasi dan autokorelasi parsial dalam data. Gambar 3.1 memperlihatkan berbagai bentuk autokorelasi dan autokorelasi parsial dan model-model AR dan MA yang sesuai untuk autokorelasi yang bersangkutan, untuk memudahkan dalam mengidentifikasi model. Sebagai ketentuan umum :

- Untuk model AR, apabila autokorelasi menurun secara eksponensial menjadi nol, dimana orde p ditetapkan dengan jumlah autokorelasi parsial yang signifikan berbeda dengan nol.
- Untuk model MA, apabila autokorelasi parsial menurun eksponensial menjadi nol, dimana orde q ditetapkan dengan jumlah autokorelasi yang signifikan berbeda dengan nol.
- Jika pada sampel autokorelasi dan autokorelasi parsialnya tidak terdapat puncak-puncak pada semua lag, maka tidak digunakan baik operasi autoregresif maupun *moving average*

Untuk memperkirakan nilai-nilai musiman p dan q (biasanya ditunjukkan dengan P dan Q), dipergunakan cara yang sama seperti yang digunakan untuk data non musiman. Yaitu, autokorelasi dan autokorelasi parsial diperiksa, tetapi saat ini autokorelasi dan autokorelasi parsial yang non musiman diabaikan dan hanya yang bersifat musiman diteliti. Dengan demikian pola dalam data bulanan yang bernilai 12, 24, 36, 48 dan seterusnya akan diteliti dengan cara yang sama seperti Gambar 3.3. Tetapi seringkali tidak tersedia autokorelasi dan autokorelasi parsial yang memadai untuk menghasilkan proses identifikasi yang tepat seperti yang dimungkinkan dalam kasus data non-musiman. Jadi, cukup banyak diperlukan penilaian dan percobaan. Untungnya, P dan Q biasanya

bernilai 0 dan 1, yang membuat tugas pemilihan menjadi relatif lebih mudah (Makridakis dan Wheelwright, 1994).

Dibawah ini dijelaskan mengenai notasi umum untuk musiman :

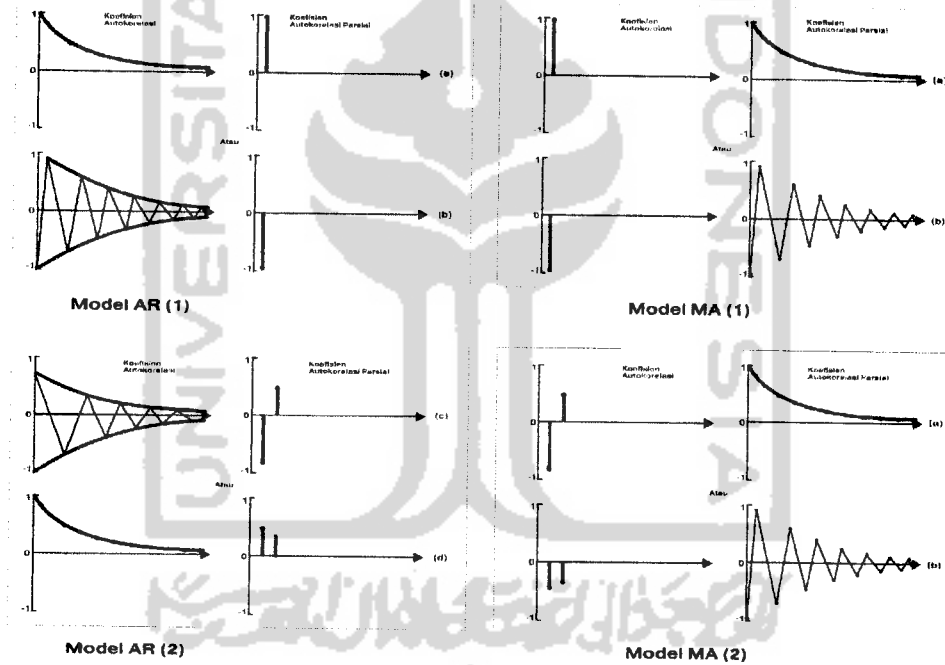
$$\text{ARIMA}(p,d,q)(P,D,Q)^S$$

dimana :

p,d,q = bagian yang tidak musiman dari model

P,D,Q = bagian musiman dari model

S = jumlah periode permusim



Gambar 3.1. Fungsi- fungsi autokorelasi dan autokorelasi parsial untuk model-model AR(1), AR(2), MA(1) dan MA(2)

3.4.1.2.2. Pengujian Parameter

Setelah mengidentifikasi nilai p dan q dengan benar, langkah selanjutnya adalah menguji parameter AR dan MA yang masuk ke dalam model secara *over all* menggunakan uji chi-square (χ^2) dan uji parsial untuk menguji kesesuaian model.

Hipotesis untuk pengujian *over all* adalah sebagai berikut :

- H_0 : Model yang teridentifikasi sesuai
- H_1 : Model yang teridentifikasi tidak sesuai

- Tingkat signifikansi (α) = 0,05

- Uji statistik

$$\chi^2 = \sum_{i=1}^k \frac{(O_i - E_i)^2}{E_i}$$

- Daerah kritis :

H_0 diterima jika nilai chi kuadrat (χ^2) hitung \leq chi kuadrat (χ^2) tabel. Dengan derajat bebas, $db = k - p - d - q$, dimana k adalah jumlah lag yang diamati, p adalah jumlah parameter AR, q adalah jumlah parameter MA dan d adalah derajat stasioneritas atau pembedaan (*differencing*).

- Kesimpulan

Hipotesis untuk pengujian parsial adalah sebagai berikut :

- $H_0 : \phi = 0$

$$H_1 : \phi \neq 0$$

- Tingkat signifikansi (α) = 0,05
- Daerah kritis :
Tolak H_0 jika $t_{hitung} > t_{tabel}$ atau $t_{hitung} < -t_{tabel}$
- Kesimpulan

3.4.2. Model Autoregresif *Moving Average* (ARMA)

Model Autoregresif *Moving Average* (ARMA) ini merupakan campuran antara model AR dan model MA. Bentuk umum daripada model ARMA adalah campuran dari persamaan (2.9) dan persamaan (2.14) sebagai berikut : (Napa J. Awat, 1990).

$$X_t = \Phi_1 X_{t-1} + \Phi_2 X_{t-2} + \dots + \Phi_p X_{t-p} + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \quad (3.2)$$

untuk ARMA(1,1) dituliskan sebagai berikut :

$$X_t = \Phi_1 X_{t-1} + e_t - \theta_1 e_{t-1} \quad (3.3)$$

Apabila menggunakan operator *shift* mundur, B, maka persamaan (3.3) dapat ditulis ulang sebagai berikut :

$$\begin{aligned} X_t &= \Phi_1 B X_t + e_t - \theta_1 B e_t \\ X_t - \Phi_1 B X_t &= e_t - \theta_1 B e_t \\ (1 - \Phi_1 B) X_t &= (1 - \theta_1 B) e_t \end{aligned} \quad (3.4)$$

3.4.2.1. Membangun Model ARMA

Secara umum, langkah-langkah dalam membangun model ARMA sama halnya dengan langkah-langkah dalam membangun model ARIMA, seperti yang telah dibahas sebelumnya. Proses tersebut harus mengikuti tahap-tahap seperti didalam Gambar 3.3, mulai dari mengidentifikasi model, menguji parameter, memeriksa diagnostik sampai dengan meramalkan model yang telah didapat. Sedangkan yang membedakan antara membangun model ARMA dan membangun model ARIMA adalah cara mengidentifikasi model.

3.4.2.1.1. Identifikasi Model

Langkah identifikasi dimaksudkan untuk mengetahui nilai yang tepat dari p , d dan q . Alat yang digunakan untuk identifikasi adalah *autocorrelation function* (ACF) dan *partial autocorrelation* (PACF), serta hasil dari *correlograms* yang memplot *autocorrelation function* (ACF) dan *partial autocorrelation* (PACF) sepanjang *lag*.

Untuk mengidentifikasi sebuah model ARMA dapat dibagi menjadi dua tahap, yaitu :

1. Memilih p dan q untuk data tidak musiman
 2. Memilih p dan q dan parameter musiman untuk data musiman
1. Mengidentifikasi p dan q untuk data tidak musiman ataupun data musiman.

Data untuk model ARMA harus bersifat stasioner, karena apabila data tidak stasioner, maka perlu dilakukan pembedaan pertama

terhadap data untuk mencapai kestasioneran. Dengan melakukan perbedaan pertama terhadap data, mengakibatkan model yang didapat bukan model ARMA melainkan model ARIMA. Order p dan q untuk model ARMA dapat diidentifikasi dengan melihat autokorelasi dan autokorelasi parsial dalam data. Gambar 3.2 memperlihatkan berbagai bentuk autokorelasi dan autokorelasi parsial dan model-model ARMA yang sesuai untuk autokorelasi yang bersangkutan, untuk memudahkan dalam mengidentifikasi model. Sebagai ketentuan umum :

- Untuk model ARMA, apabila autokorelasi maupun autokorelasi parsial keduanya menurun secara eksponensial ke nol.
- Untuk model ARMA orde yang lebih tinggi, fungsi autokorelasi menyerupai proses AR(p) setelah $lag(q-p)$ sedangkan fungsi autokorelasi parsial mirip proses MA(q) setelah $lag(p-q)$.

Untuk memperkirakan nilai-nilai musiman p dan q (biasanya ditunjukkan dengan P dan Q), dipergunakan cara yang sama seperti yang digunakan untuk data non musiman, yaitu autokorelasi dan autokorelasi parsial diperiksa, tetapi saat ini autokorelasi dan autokorelasi parsial yang non musiman diabaikan dan hanya yang bersifat musiman diteliti. Dengan demikian pola dalam data bulanan yang bernilai 12, 24, 36, 48 dan seterusnya akan diteliti dengan cara yang sama seperti Gambar 3.3. Tetapi seringkali tidak tersedia autokorelasi dan autokorelasi parsial yang memadai untuk

menghasilkan proses identifikasi yang tepat seperti yang dimungkinkan dalam kasus data non-musiman. Jadi, cukup banyak diperlukan penilaian dan percobaan. Untungnya, P dan Q biasanya bernilai 0 dan 1, yang membuat tugas pemilihan menjadi relatif lebih mudah (Makridakis dan Wheelwright, 1994).

Dibawah ini dijelaskan mengenai notasi umum untuk musiman :

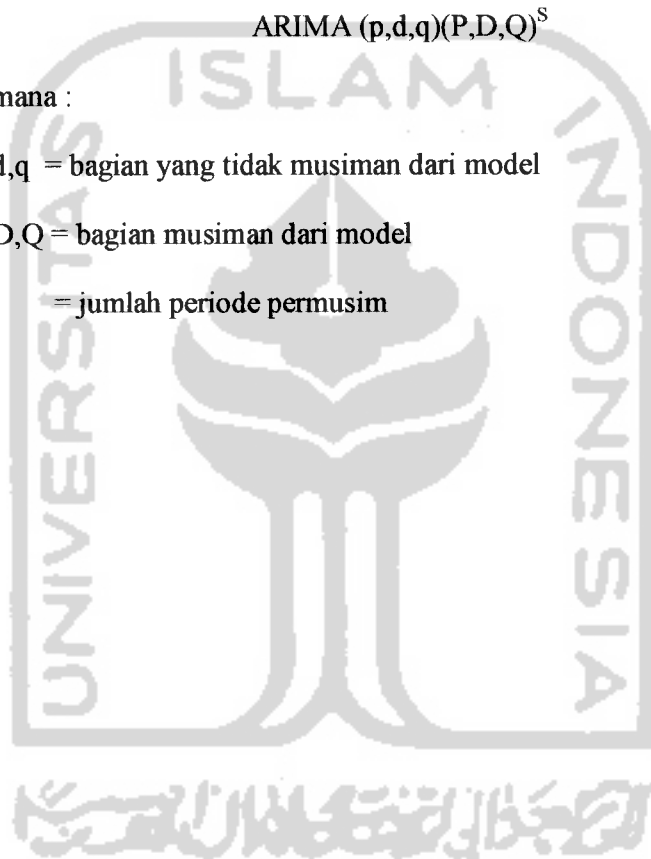
$$\text{ARIMA}(p,d,q)(P,D,Q)^S$$

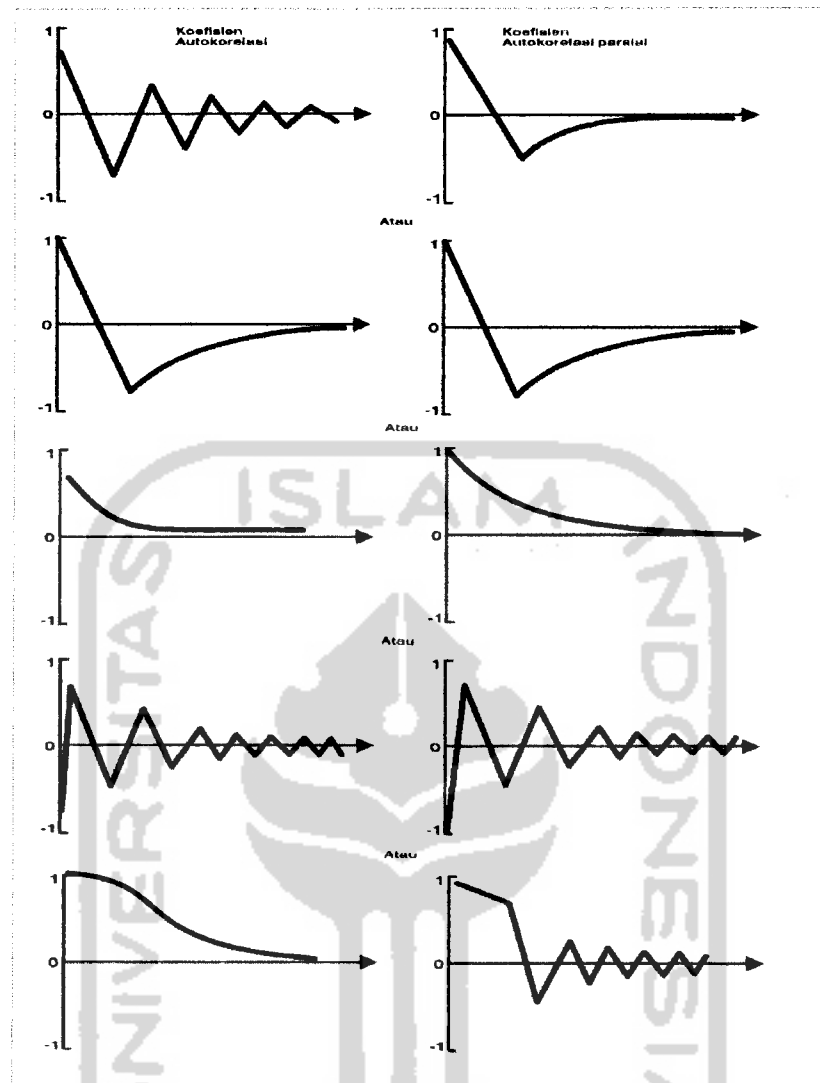
dimana :

p,d,q = bagian yang tidak musiman dari model

P,D,Q = bagian musiman dari model

S = jumlah periode permusim





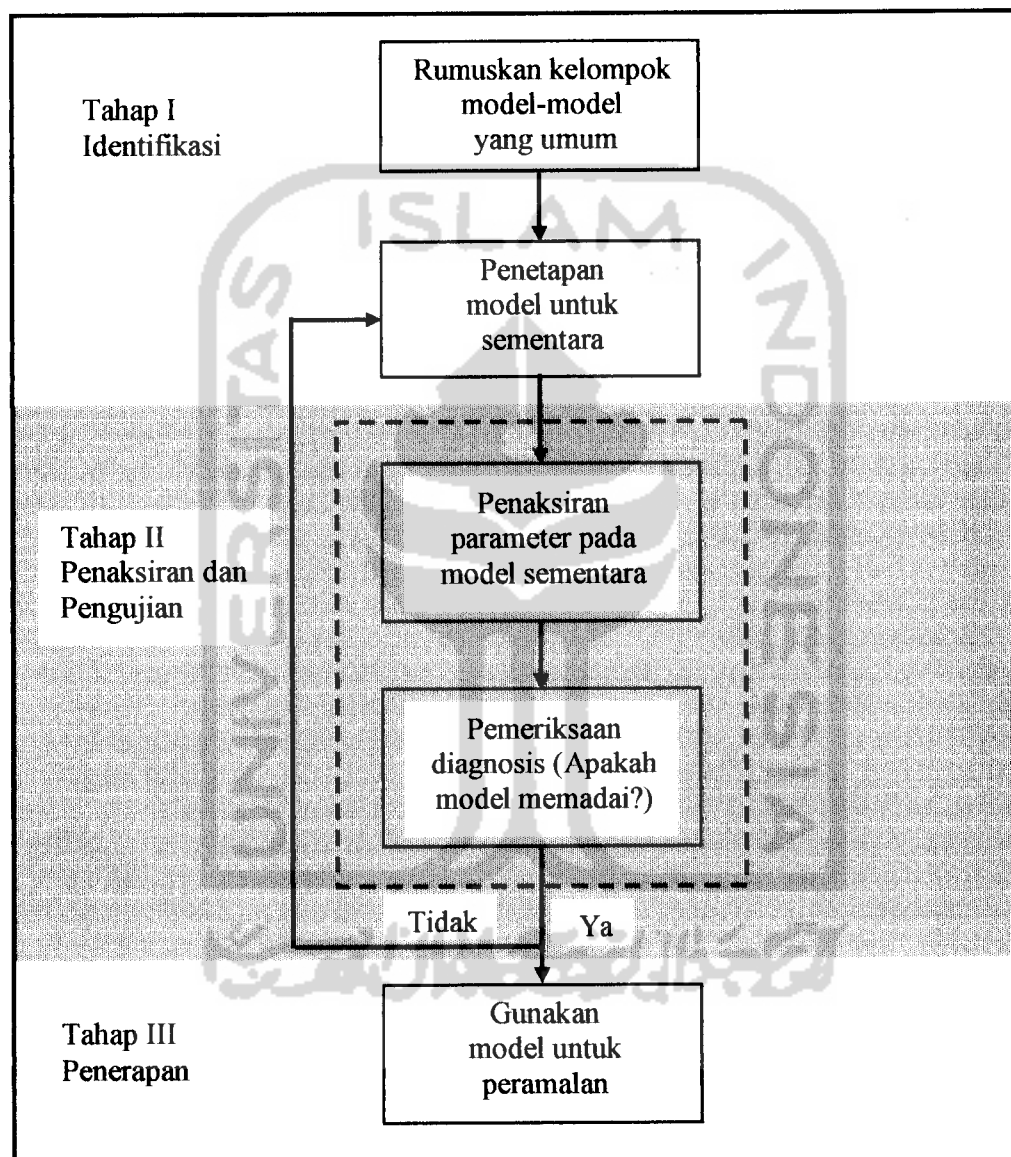
Gambar 3.2. Fungsi- fungsi autokorelasi dan autokorelasi parsial untuk model-model ARMA (1,1)

3.4.3. Langkah-langkah Pengolahan dan Analisis Data

Pengolahan data dilakukan dengan bantuan *software* Minitab 11, dan akan didapatkan hasil-hasil untuk :

1. Identifikasi model

2. Pengujian parameter
3. Pemeriksaan diagnostik
4. Peramalan (*forecasting*)



Gambar 3.3. Skema yang memperlihatkan pendekatan Box-Jenkins



3.4.4. Pemeriksaan Diagnostik

Setelah parameter yang optimal (yang menghasilkan kesalahan kuadrat rata-rata minimum) diperkirakan, kesalahan e_i dapat diperiksa. Cara memeriksanya adalah dengan menganalisa nilai-nilai residual yang diperoleh dari model. Hasil yang ditemukan memiliki dua kemungkinan :

1. Kesalahan bersifat random, yang berarti model yang digunakan telah menghapus pola dari data dan yang tersisa adalah kesalahan random, atau
2. Model yang diidentifikasi tersebut belum menghapus semua pola, seperti yang diperlihatkan dengan kenyataan bahwa e_i tidak bersifat random.

Nilai-nilai tersebut diperiksa apakah dapat dipandang sebagai observasi random dengan *mean* nol, atau diuji dengan uji statistik yang disebut uji *overall*, yaitu :

$$\chi^2 = \sum_{i=1}^k \frac{(O_i - E_i)^2}{E_i} \quad (3.5)$$

dimana :

χ^2 adalah berdistribusi Chi-kuadrat

O_i = frekuensi observasi ke- i , $i = 1, 2, \dots, k$

E_i = frekuensi yang diharapkan ke- i , $i = 1, 2, \dots, k$

Proses pembentukan model menggunakan hubungan antar runtun waktu yang diobservasi. Apabila hubungan tersebut ada, maka residual harus tidak saling berhubungan dan dengan demikian autokorelasi dari residual ini harus kecil atau autokorelasi yang ada harus secara signifikan tidak berbeda dari nol. Semakin besar χ^2 , maka autokorelasi dari residual semakin besar dan residual-residual

tersebut saling berhubungan. Dengan demikian nilai χ^2 yang besar menunjukkan bahwa model adalah tidak tepat, maka model lainnya harus diidentifikasi.

3.4.5. Peramalan

Setelah sebuah model diidentifikasi, parameter-parameter diperkirakan dan residu yang diperlihatkan bersifat random, maka peramalan dengan menggunakan model tersebut dapat dilakukan.



BAB IV


ANALISIS DATA DAN PEMBAHASAN

Untuk menerapkan teori analisis *time series* dengan menggunakan model ARIMA sebagaimana diuraikan dalam bab III, pada bab ini disajikan data tentang jumlah produksi produk granit (lampiran A) untuk dianalisis dengan metode tersebut. Semua proses pengolahan data menggunakan paket program Minitab 11.

4.1. Pembahasan Produksi *Tertiary*

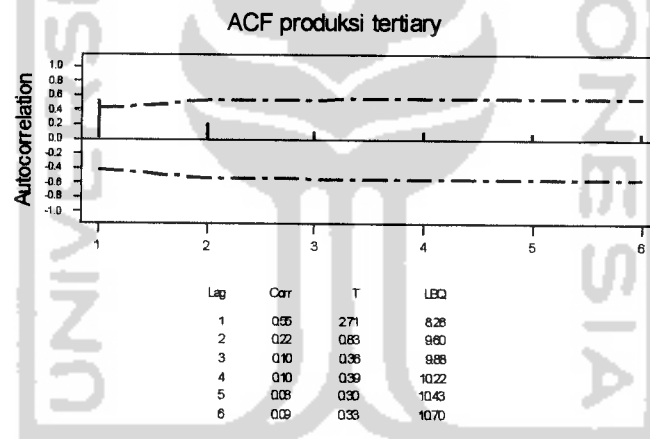
4.1.1. Identifikasi Model

Identifikasi model digunakan untuk melihat apakah data (lampiran A) stasioner. Stasioner atau tidak stasionernya data, dapat diperoleh dengan memplot data atau dengan melihat grafik ACF (fungsi autokorelasi) dan grafik PACF (fungsi autokorelasi parsial). Bila data hasil plot tidak stasioner, maka dilakukan pembedaan pertama atas data asli. Apabila kestasioneran dari data telah diperoleh, maka langkah selanjutnya adalah menetapkan model sementara dari data tersebut. Untuk menetapkan model sementara dapat dilakukan dengan melihat grafik ACF (fungsi autokorelasi) dan grafik PACF (fungsi autokorelasi parsial). Hasil plot data produksi *tertiary* ditampilkan dalam Gambar 4.1 dibawah ini.




Gambar 4.1. Time series plot data produksi *tertiary*

Dari Gambar 4.1 diatas tampak jelas data produksi *tertiary* telah stasioner, karena fluktuasi data berada di sekitar suatu nilai rata-rata yang konstan.



Gambar 4.2. Fungsi autokorelasi data produksi *tertiary*



Gambar 4.3. Fungsi autokorelasi parsial data produksi *tertiary*

Dari Gambar 4.2 tampak jelas lag kedua langsung berada dalam batas sehingga memperkuat dugaan bahwa data sudah stasioner dan dari Gambar 4.2 serta Gambar 4.3 dapat diduga model sementara yang digunakan untuk data produksi *tertiary* adalah mengikuti pola AR(1) atau model ARIMA (1 0 0), karena grafik PACF (fungsi autokorelasi parsial) turun setelah lag pertama.

4.1.2. Pengujian Parameter

Pengujian parameter digunakan untuk melihat apakah model sementara yang telah diidentifikasi tersebut baik. Jika dari hasil pengujian parameter tersebut, model yang telah diidentifikasi tidak baik, maka kembali ketahap I (Gambar 3.3) dan alternatif model lain diidentifikasi. Berdasarkan output komputer lampiran B, maka diperoleh hasil pengujian parameter yang ditampilkan pada Tabel 4.1 dan Tabel 4.2.

4.1.2.1. Uji OverAll

Berdasarkan output komputer, diperoleh nilai chi kuadrat seperti pada tampilan output di Tabel 4.1 di bawah ini:

Tabel 4.1.

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

<i>Modified Box-Pierce (Ljung-Box) Chi-Square statistic</i>	
<i>Lag</i>	12
<i>Chi-Square</i>	14.7(DF=11)

Dalam hal ini nilai chi kuadrat tabel $(0,05;11) = 19,6751$ (berdasarkan tabel III, lampiran G).

Kesimpulan :

Karena nilai *Modified Box-Pierce (Ljung-Box) Chi-Square statistic* $14,7 < 19,6751$ maka H_0 diterima. Artinya bahwa model ARIMA (1 0 0) secara keseluruhan layak untuk dipakai.

4.1.2.2. Uji Parsial

Tabel 4.2.

Hasil Pengujian Parameter

Type	Koef	StDev	T
AR 1	0.9986	0.0388	25.70

Dari hasil tampilan output di Tabel 4.2, dapat diambil kesimpulan, untuk model AR(1) diketahui bahwa nilai t hitung $= 25,70 > 1,96$. Nilai 1,96 diperoleh

dari nilai $Z_{\alpha/2}$, berdasarkan tabel IV (lampiran H) sehingga H_0 ditolak, artinya model AR(1) dimasukkan kedalam model.

Berdasarkan uji *overall* dan uji parsial diatas dapat dikatakan bahwa model ARIMA (1 0 0) tepat untuk digunakan sebagai peramalan jumlah produksi *tertiary*.

4.1.3. Pemeriksaan Diagnostik

Pemeriksaan diagnostik dilakukan dengan *overfit* atau dapat juga dengan memeriksa plot residual dari model yang telah diestimasi. *Overfitting* digunakan apabila diperlukan model lain yang lebih luas dengan parameter-parameter ekstra dan selanjutnya dilihat apakah model ini benar-benar unggul.

4.1.3.1. *Overfitting*

Model yang dicoba adalah model yang semua parameternya memenuhi syarat uji *overall* dan uji parsial. Sehingga dapat dibandingkan MS (*mean square*)nya sehingga dengan prinsip parsimoni (menggunakan parameter sesedikit mungkin) dapat diputuskan model yang akan digunakan untuk peramalan.

Berdasarkan output komputer lampiran B, maka model yang memenuhi uji *overall* dan uji parsial untuk produksi *tertiary* adalah :

ARIMA (1 0 0)

Residuals : SS = 18515008792 (*backforecasts excluded*)

MS = 805000382 DF = 23

ARIMA (0 0 1)

Residuals: SS = 161869458940 (*backforecasts excluded*)

MS = 7037802563 DF = 23

ARIMA (0 0 2)


Residuals: SS = 66932592344 (*backforecasts excluded*)

MS = 3042390561 DF = 22


Dengan prinsip parsimoni, maka model yang digunakan untuk peramalan jumlah produksi *tertiary* adalah model ARIMA (1 0 0).

4.1.3.2. Analisis Residu

Pemeriksaan diagnostik juga dapat dilakukan dengan memeriksa plot residual dari model yang telah diuji parameternya. Dari plot residual tersebut diharapkan tidak adanya nilai-nilai yang signifikan dan tidak adanya pola tertentu (*trend*).



Gambar 4.4. Fungsi autokorelasi residual produksi *tertiary*



Gambar 4.5. Fungsi autokorelasi parsial residual produksi *tertiary*

Dari Gambar 4.4 dan Gambar 4.5 tampak jelas residual dari produksi *tertiary* tidak menunjukkan pola tertentu (*trend*) dan tidak menunjukkan adanya nilai-nilai yang signifikan. Maka model yang dipakai untuk meramalkan produksi *tertiary* adalah ARIMA (1 0 0) atau $(1 - B\Phi_1)X_t = e_t$, suku-suku tersebut dikalikan dan disusun kembali sehingga didapat model umumnya yaitu :

$$X_t - \Phi_1 B X_t = e_t$$

$$X_t = \Phi_1 X_{t-1} + e_t$$

Dengan memasukkan nilai parameter AR(1), maka model umum diatas akan menjadi :

$$X_t = 0.9986 X_{t-1} + e_t$$

4.1.4. Peramalan dengan Model ARIMA (1 0 0)

Dengan menggunakan model ARIMA (1 0 0) atau, $X_t = 0.9986 X_{t-1} + e_t$ maka peramalan jumlah produksi *tertiary* untuk periode Januari 2003 sampai dengan Desember 2003 dapat diperoleh. Hasil peramalan tersebut ditunjukkan dalam Tabel 4.3 dibawah ini.

Tabel 4.3.

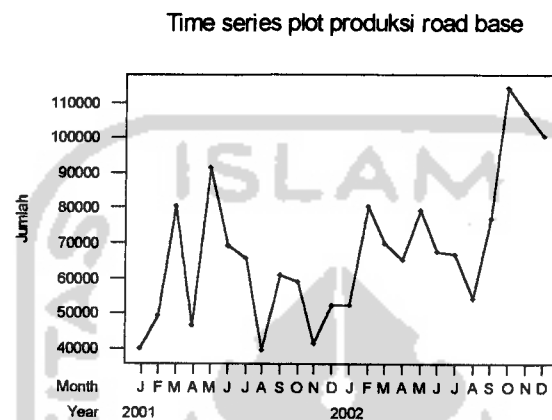
Hasil Peramalan Produksi *Tertiary*

Bulan	Ramalan	Batas bawah ramalan	Batas atas ramalan
Januari	167119	111498	222741
Februari	166878	88274	245482
Maret	166637	70437	262837
April	166396	55394	277398
Mei	166156	42141	290170
Juni	165916	30163	301669
Juli	165676	19151	312201
Agustus	165437	8908	321966
September	165198	-706	331102
Oktober	164959	-9794	339712
Nopember	164721	-18430	347872
Desember	164483	-26674	355640

4.2. Pembahasan Produksi *Road Base*


4.2.1. Identifikasi Model

Hasil plot data produksi *road base* ditampilkan dalam Gambar 4.6 dibawah ini.



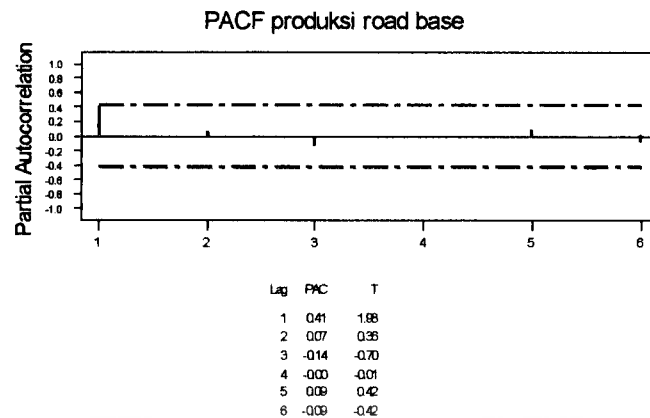
Gambar 4.6. *Time series plot data produksi road base*

Dari Gambar 4.6 tampak jelas data produksi *road base* telah stasioner, karena fluktuasi data berada di sekitar suatu nilai rata-rata yang konstan.



Lag	Corr	T	LEQ
1	0.41	1.98	4.45
2	0.23	0.96	5.09
3	-0.01	-0.02	5.80
4	-0.03	-0.14	5.93
5	0.02	0.09	5.95
6	-0.04	-0.15	6.00

Gambar 4.7. *Fungsi autokorelasi data produksi road base*



Gambar 4.8. Fungsi autokorelasi parsial data produksi *road base*

Dari Gambar 4.7 tampak jelas lag kedua langsung berada dalam batas sehingga memperkuat dugaan bahwa data sudah stasioner. Dan dari Gambar 4.7 dan Gambar 4.8 dapat diduga model sementara yang digunakan untuk data produksi *road base* adalah mengikuti pola AR(1) atau ARIMA (1 0 0), karena grafik PACF (fungsi autokorelasi parsial) turun setelah lag pertama.

4.2.2. Pengujian Parameter

Berdasarkan output komputer lampiran C, maka diperoleh hasil pengujian parameter yang ditampilkan pada Tabel 4.4 dan Tabel 4.5.

4.2.2.1. Uji *OverAll*

Berdasarkan output komputer, diperoleh nilai chi kuadrat seperti pada tampilan output di Tabel 4.4 di bawah ini :

Tabel 4.4.

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

<i>Modified Box-Pierce (Ljung-Box) Chi-Square statistic</i>	
<i>Lag</i>	12
<i>Chi-Square</i>	13.7(DF=11)

Dalam hal ini nilai chi kuadrat tabel $(0,05;11) = 19,6751$ (berdasarkan tabel III, lampiran G).

Kesimpulan :

Karena nilai *Modified Box-Pierce (Ljung-Box) Chi-Square statistic* $13,7 < 19,6751$ maka H_0 diterima. Artinya bahwa model ARIMA (1 0 0) secara keseluruhan layak untuk dipakai.

4.2.2.2. Uji Parsial

Tabel 4.5.

Hasil Pengujian Parameter

Type	Koef	StDev	T
AR 1	0.9989	0.0617	16.19

Dari hasil tampilan output di Tabel 4.5, dapat diambil kesimpulan, untuk model AR(1) diketahui bahwa nilai t hitung = $16,19 > 1,96$. Nilai 1,96 diperoleh dari nilai $Z_{\alpha/2}$, berdasarkan tabel IV (lampiran H) sehingga H_0 ditolak, artinya model AR(1) dimasukkan kedalam model.

Berdasarkan uji *overall* dan uji parsial diatas dapat dikatakan bahwa model ARIMA (1 0 0) baik untuk digunakan sebagai peramalan jumlah produksi *road base*.

4.2.3. Pemeriksaan Diagnostik

4.2.3.1. *Overfitting*

Berdasarkan output komputer lampiran C, maka model yang memenuhi uji *overall* dan uji parsial untuk produksi *road base* adalah :

ARIMA (1 0 0)

Residuals : SS = 9807334989 (*backforecasts excluded*)
MS = 426405869 DF = 23

ARIMA (2 0 0)

Residuals : SS = 8123289733 (*backforecasts excluded*)
MS = 369240442 DF = 22

ARIMA (1 0 1)

Residuals : SS = 7865243156 (*backforecasts excluded*)
MS = 357511053 DF = 22

ARIMA (0 0 1)

Residuals : SS = 45916590852 (*backforecasts excluded*)
MS = 1996373515 DF = 23

ARIMA (0 0 2)

Residuals : SS = 21805054319 (*backforecasts excluded*)

MS = 991138833 DF = 22

Dengan prinsip parsimoni, maka model yang digunakan untuk peramalan jumlah produksi *road base* adalah model ARIMA (1 0 1).

Model ARIMA (1 0 1)

4.2.3.2. Uji *OverAll*

Berdasarkan output komputer, diperoleh nilai chi kuadrat seperti pada tampilan output di Tabel 4.6 di bawah ini :

Tabel 4.6.

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

<i>Modified Box-Pierce (Ljung-Box) Chi-Square statistic</i>	
<i>Lag</i>	12
<i>Chi-Square</i>	5.7(DF=10)

Dalam hal ini nilai chi kuadrat tabel $(0,05;10) = 18,307$ (berdasarkan tabel III, lampiran G).

Kesimpulan :

Karena nilai *Modified Box-Pierce (Ljung-Box) Chi-Square statistic* $5,7 < 18,307$ maka H_0 diterima. Artinya bahwa model ARIMA (1 0 1) secara keseluruhan layak untuk dipakai.

4.2.3.3. Uji Parsial

Tabel 4.7.

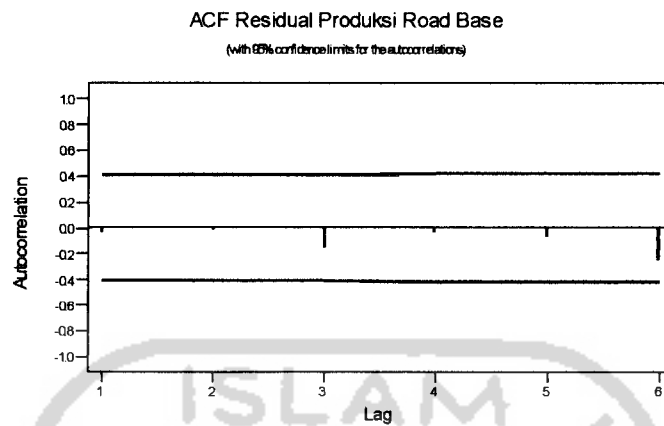
Hasil Pengujian Parameter

Type	Koef	SE Dev	T
AR 1	1.0012	0.0306	32.71
MA 1	0.5449	0.2120	2.57

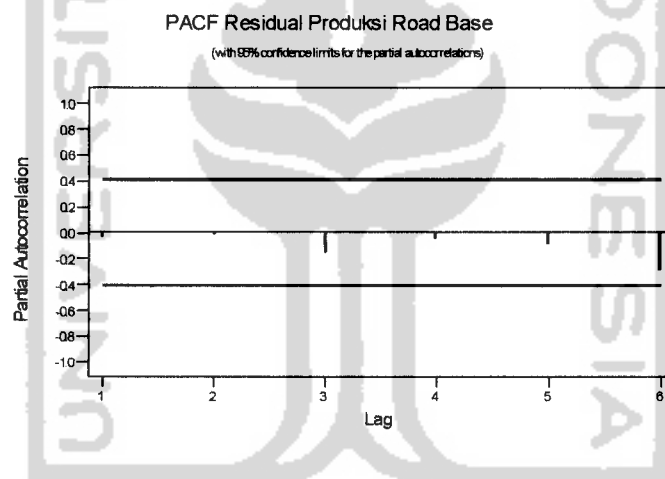
Dari hasil tampilan output di Tabel 4.7, dapat diambil kesimpulan, untuk model AR(1) diketahui bahwa nilai t hitung = $32,71 > 1,96$. Nilai 1,96 diperoleh dari nilai $Z_{\alpha/2}$, berdasarkan tabel IV (lampiran H) sehingga H_0 ditolak, artinya model AR(1) dimasukkan kedalam model dan untuk model MA(1) diketahui bahwa nilai t hitung = $2,57 > 1,96$ sehingga H_0 ditolak, artinya model MA(1) dimasukkan kedalam model.

Berdasarkan uji *overall* dan uji parsial diatas dapat dikatakan bahwa model ARIMA (1 0 1) baik untuk digunakan sebagai peramalan jumlah produksi *road base*.

4.2.3.4. Analisis Residu



Gambar 4.9. Fungsi autokorelasi residual produksi *road base*



Gambar 4.10. Fungsi autokorelasi parsial residual produksi *road base*

Dari Gambar 4.9 dan Gambar 4.10 tampak jelas residual dari produksi *road base* tidak menunjukkan pola tertentu (*trend*) dan tidak menunjukkan adanya nilai-nilai yang signifikan. Maka model dipakai untuk meramalkan produksi *road*

base adalah ARIMA (1 0 1) atau $X_t = \Phi_1 X_{t-1} + e_t - \theta_1 e_{t-1}$, suku-suku tersebut dikalikan dan disusun kembali sehingga didapat model umumnya yaitu :

$$(1 - \Phi_1 B)X_t = (1 - \theta_1 B)e_t$$

$$X_t - \Phi_1 B X_t = e_t - \theta_1 B e_t$$

$$X_t = \Phi_1 B X_t + e_t - \theta_1 B e_t$$

Dengan memasukkan nilai parameter AR(1) dan MA(1), maka model umum diatas akan menjadi :

$$X_t = 1.0012 X_{t-1} + e_t - 0.5449 e_{t-1}$$

4.2.4. Peramalan dengan Model ARIMA (1 0 1)

Dengan menggunakan model ARIMA (1 0 1) atau $X_t = 1.0012 X_{t-1} + e_t - 0.5449 e_{t-1}$, maka peramalan jumlah produksi *road base* untuk periode Januari 2003 sampai dengan Desember 2003 dapat diperoleh. Hasil peramalan tersebut ditunjukkan dalam Tabel 4.8 dibawah ini.

Tabel 4.8.

Hasil Peramalan Produksi *Road Base*

Bulan	Ramalan	Batas bawah ramalan	Batas atas ramalan
Januari	99154	62087	136221
Februari	99269	58525	140012
Maret	99383	55261	143505
April	99498	52231	146765
Mei	99613	49391	149835
Juni	99728	46710	152746

Tabel 4.8 (lanjutan).

Juli	99843	44163	155524
Agustus	99958	41731	158185
September	100074	39402	160746
Oktober	100190	37162	163217
Nopember	100305	35001	165609
Desember	100421	32913	167929



BAB V
KESIMPULAN DAN SARAN

5.1. Kesimpulan

Dari hasil analisis data yang telah dilakukan dapat diambil kesimpulan yaitu :

- 1a. Model yang baik untuk meramalkan jumlah produksi *tertiary* adalah dengan menggunakan model ARIMA (1 0 0) atau model umumnya adalah $X_t = 0.9986 X_{t-1} + e_t$
- b. Hasil peramalan jumlah produksi *tertiary* untuk periode Januari 2003 sampai dengan Desember 2003 berdasarkan model ARIMA (1 0 1) $X_t = 0.9986 X_{t-1} + e_t$ dapat dilihat dalam tabel I lampiran D.
- 2a. Model yang baik untuk meramalkan jumlah produksi *road base* adalah dengan menggunakan model ARIMA (1 0 1) atau model umumnya adalah $X_t = 1.0012 X_{t-1} + e_t - 0.5449 e_{t-1}$
- b. Hasil peramalan jumlah produksi *road base* untuk periode Januari 2003 sampai dengan Desember 2003 berdasarkan model ARIMA (1 0 1) $X_t = 1.0012 X_{t-1} + e_t - 0.5449 e_{t-1}$ dapat dilihat dalam tabel II lampiran E.

5.2. Saran

Dari hasil penelitian dan pembahasan yang telah dilakukan, maka saran yang dapat di kemukakan, yaitu :

1. Perusahaan dapat menggunakan model peramalan ini sebagai model dasar peramalan untuk meramalkan jumlah produksi *tertiary* dan jumlah produksi *road base*.
2. Penelitian ini adalah masih jauh dari sempurna karena keterbatasan data. Oleh sebab itu agar kesimpulan yang diambil dapat lebih tajam, mungkin dapat direvisi dan diuji kembali dengan memperbanyak jumlah periode data pada masa-masa mendatang.



DAFTAR PUSTAKA

- Djauhari, A.M. 1986. *Metode Peramalan*. Modul 1-5. Universitas Terbuka. Jakarta : Penerbit Karunika.
- Kuncoro, M. 2001. *Metode Kuantitatif : Teori dan Aplikasi untuk Bisnis dan Ekonomi*. Yogyakarta : UPP AMP YKPN.
- Lincoln, A. 1999. *Peramalan Bisnis*. Yogyakarta : Fakultas Ekonomi UGM.
- Makridakis, S., S. Wheelwright., dan McGee. 1999. *Metode Aplikasi dan Peramalan*. Edisi 2. Jilid I. Jakarta : Binarupa Aksara
- Makridakis, S., dan S. Wheelwright. 1999. *Metode-metode Peramalan untuk Manajemen*. Edisi Kelima. Jakarta : Binarupa Aksara
- Napa J.Awat. 1990. *Metode Peramalan Kuantitatif*. Yogyakarta : Penerbit Liberty.
- Robert A. Yaffi dan McGee. 1997. *Introduction to Time Series Analysis and Forecasting with Applications of SAS and SPSS*. New York : Academic Press.
- Soejoeti, Z. 1987. *Analisis Runtun Waktu*. Universitas Terbuka. Jakarta : Penerbit Karunika.



وَمَا كُنَّا بِمُعَظَّمِي الْبَلَاءِ

Lampiran A

Data jumlah produksi granit untuk periode Januari 2001 sampai dengan
Desember 2002

Jumlah produksi tahun 2001

Dalam *metric tone* (m/t)

Month	Product	
	Tertiary	Road Base
January	185.121	39.712
February	159.303	49.319
March	185.193	80.636
April	214.336	46.367
May	184.575	91.497
June	132.890	69.294
July	133.698	65.594
August	170.450	39.248
September	147.761	60.989
October	172.545	58.870
November	112.429	41.287
December	94.248	52.278
Total	1.892.549	695.091

Jumlah produksi tahun 2002

Dalam *metric tone* (m/t)

Month	Product	
	Tertiary	Road Base
January	79.855	52.396
February	128.922	80.513
March	138.919	69.804
April	112.597	65.404
May	146.562	79.243
June	157.311	67.736
July	136.599	66.664
August	121.091	54.309
September	120.875	76.947
October	123.882	114.423
November	151.983	107.149
December	167.361	100.484
Total	1.585.957	935.072

Sumber : Bagian produksi PT. Karimun Granite

Lampiran B

Hasil estimasi parameter untuk data produksi *tertiary* untuk model-model ARIMA yang memenuhi syarat uji *overall* dan uji parsial

ARIMA (1 0 0)

Final Estimates of Parameters

Type	Coef	StDev	T
AR 1	0.9986	0.0388	25.70

Number of observations: 24

Residuals: SS = 18515008792 (backforecasts excluded)
MS = 805000382 DF = 23

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

Lag	12	24	36	48
Chi-Square	14.7(DF=11)	*(DF=*)	*(DF=*)	*(DF=*)

ARIMA (0 0 1)

Final Estimates of Parameters

Type	Coef	StDev	T
MA 1	-0.9284	0.1147	-8.10

Number of observations: 24

Residuals: SS = 161869458940 (backforecasts excluded)
MS = 7037802563 DF = 23

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

Lag	12	24	36	48
Chi-Square	38.1(DF=11)	*(DF=*)	*(DF=*)	*(DF=*)

Lampiran B (lanjutan)

ARIMA (0 0 2)

Final Estimates of Parameters

Type	Coef	StDev	T
MA 1	-1.3298	0.1741	-7.64
MA 2	-0.8805	0.1752	-5.02


Number of observations: 24

Residuals: SS = 66932592344 (backforecasts excluded)

MS = 3042390561 DF = 22

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

Lag	12	24	36	48
Chi-Square	19.3(DF=10)	*(DF=*)	*(DF=*)	*(DF=*)



Lampiran C

Hasil estimasi parameter untuk data produksi *road base* untuk model-model

ARIMA yang memenuhi syarat uji *overall* dan uji parsial

ARIMA (1 0 0)

Final Estimates of Parameters

Type	Coef	StDev	T
AR 1	0.9989	0.0617	16.19

Number of observations: 24

Residuals: SS = 9807334989 (backforecasts excluded)
MS = 426405869 DF = 23

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

Lag	12	24	36	48
Chi-Square	13.7(DF=11)	*(DF=*)	*(DF=*)	*(DF=*)

ARIMA (2 0 0)

Final Estimates of Parameters

Type	Coef	StDev	T
AR 1	0.5714	0.1943	2.94
AR 2	0.4315	0.2032	2.12

Number of observations: 24

Residuals: SS = 8123289733 (backforecasts excluded)
MS = 369240442 DF = 22

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

Lag	12	24	36	48
Chi-Square	9.1(DF=10)	*(DF=*)	*(DF=*)	*(DF=*)

ARIMA (1 0 1)

Final Estimates of Parameters

Type	Coef	StDev	T
AR 1	1.0012	0.0306	32.71
MA 1	0.5449	0.2120	2.57

Number of observations: 24

Residuals: SS = 7865243156 (backforecasts excluded)
MS = 357511053 DF = 22

Lampiran C (lanjutan)

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

Lag	12	24	36	48
Chi-Square	5.7(DF=10)	*(DF=*)	*(DF=*)	*(DF=*)

ARIMA (0 0 1)

Final Estimates of Parameters

Type	Coef	StDev	T
MA 1	-0.8777	0.1017	-8.63

Number of observations: 24

Residuals: SS = 45916590852 (backforecasts excluded)
MS = 1996373515 DF = 23

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

Lag	12	24	36	48
Chi-Square	20.8(DF=11)	*(DF=*)	*(DF=*)	*(DF=*)

ARIMA (0 0 2)

Final Estimates of Parameters

Type	Coef	StDev	T
MA 1	-1.0491	0.1647	-6.37
MA 2	-0.8460	0.1638	-5.16

Number of observations: 24

Residuals: SS = 21805054319 (backforecasts excluded)
MS = 991138833 DF = 22

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

Lag	12	24	36	48
Chi-Square	12.1(DF=10)	*(DF=*)	*(DF=*)	*(DF=*)

Tabel I : Lampiran D
Hasil Peramalan Produksi *Tertiary*

Bulan	Ramalan	Batas bawah ramalan	Batas atas ramalan
Januari	167119	111498	222741
Februari	166878	88274	245482
Maret	166637	70437	262837
April	166396	55394	277398
Mei	166156	42141	290170
Juni	165916	30163	301669
Juli	165676	19151	312201
Agustus	165437	8908	321966
September	165198	-706	331102
Oktober	164959	-9794	339712
Nopember	164721	-18430	347872
Desember	164483	-26674	355640

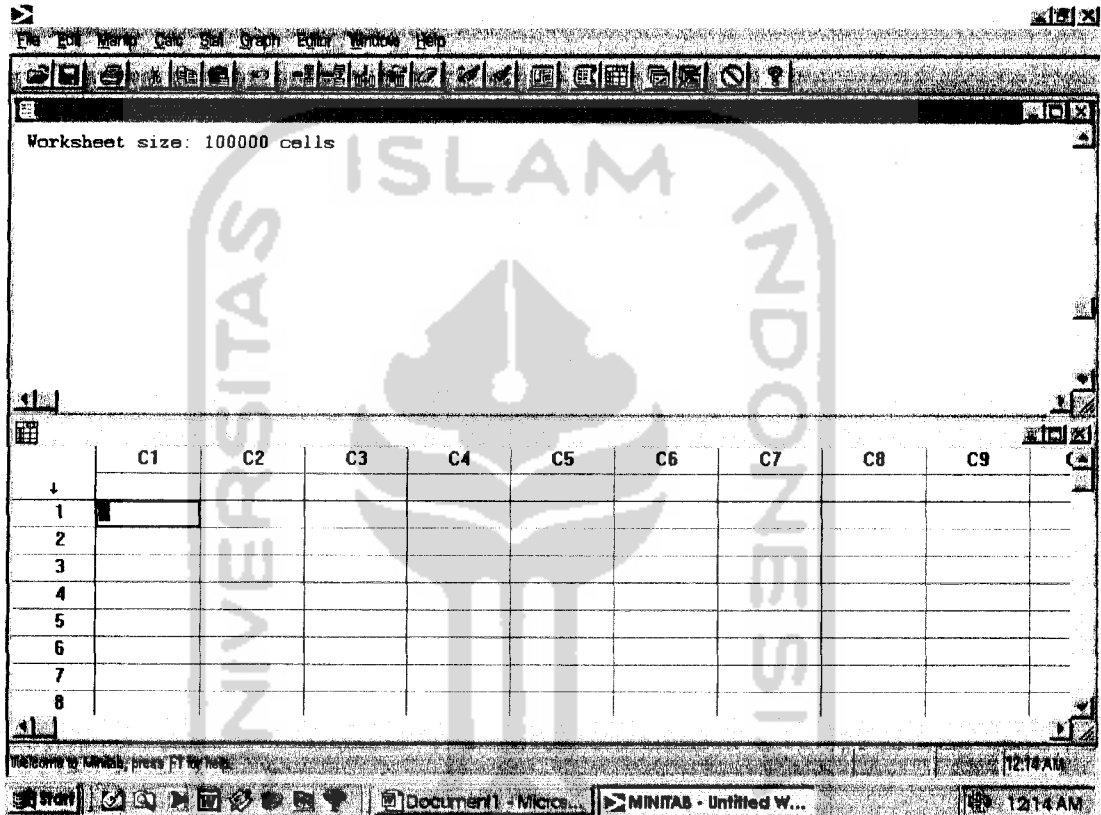
Tabel II : Lampiran E
Hasil Peramalan Produksi Road Base

Bulan	Ramalan	Batas bawah ramalan	Batas atas ramalan
Januari	99154	62087	136221
Februari	99269	58525	140012
Maret	99383	55261	143505
April	99498	52231	146765
Mei	99613	49391	149835
Juni	99728	46710	152746
Juli	99843	44163	155524
Agustus	99958	41731	158185
September	100074	39402	160746
Oktober	100190	37162	163217
November	100305	35001	165609
Desember	100421	32913	167929

Lampiran F

Komputasi data

Semua proses pengolahan data dari penelitian ini memakai *software* Minitab 11 sebagai alat bantu dalam menganalisis data. Layar tampilan Minitab 11 adalah seperti terlihat Gambar 1 dibawah.



Gambar 1. Tampilan Minitab versi 11

Langkah selanjutnya adalah memasukan data hasil penelitian ke dalam kolom-kolom kerja, seperti terlihat pada Gambar 2 dibawah.

Worksheet size: 100000 cells

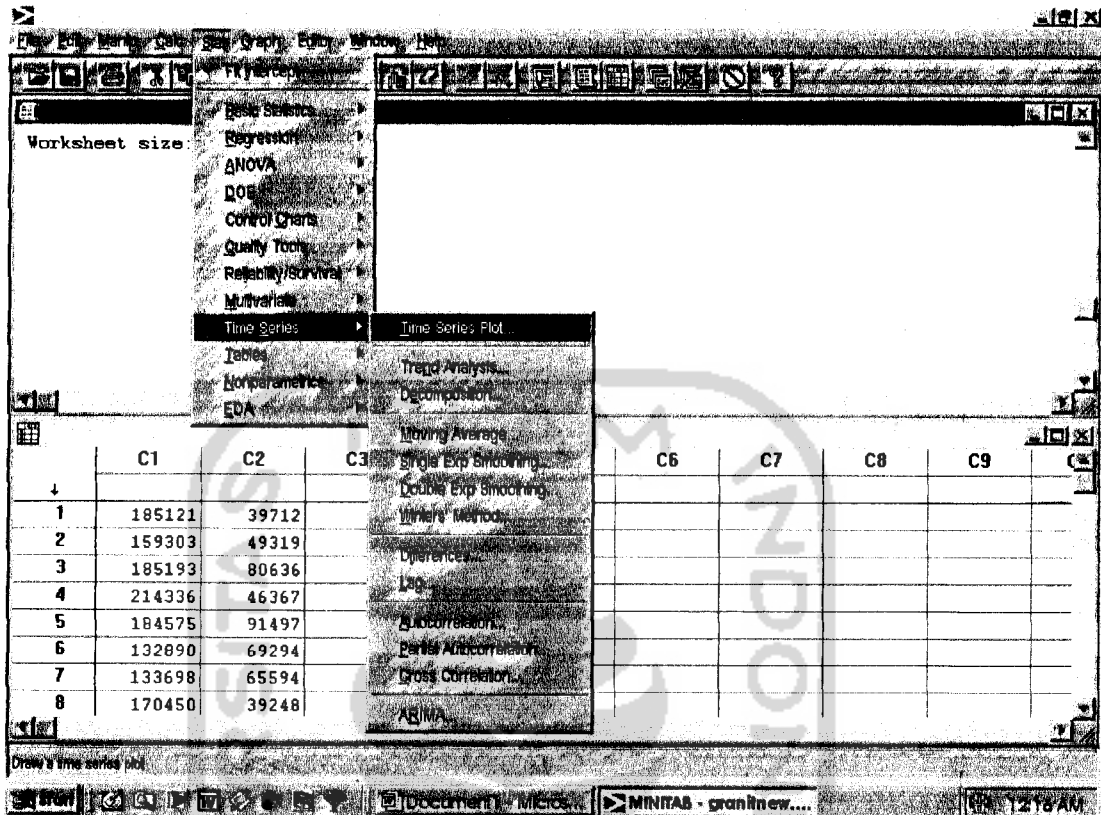
	C1	C2	C3	C4	C5	C6	C7	C8	C9
1	185121	39712							
2	159303	49319							
3	185193	80636							
4	214336	46367							
5	184575	91497							
6	132890	69294							
7	133698	65594							
8	170450	39248							

Gambar 2. Tampilan masukan data

Pengisian :

- Masukkan data ke kolom C1 atau ke kolom-kolom diinginkan.
- Pengisian data tersebut akan tampak di layar tampilan seperti Gambar 2

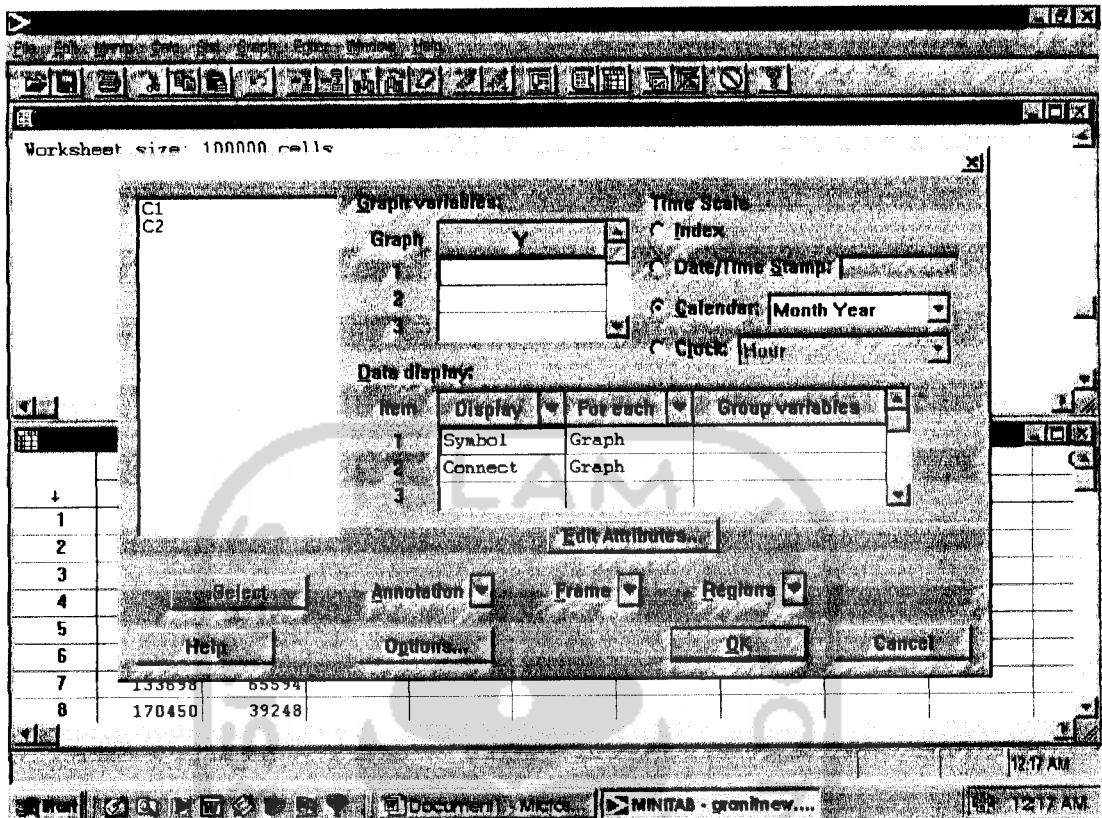
a. Identifikasi model



Gambar 3. Tampilan menu *time series plot*

Setelah data dimasukkan seperti Gambar 2, maka langkah-langkah yang dilakukan untuk mendapatkan plot *time series* adalah :

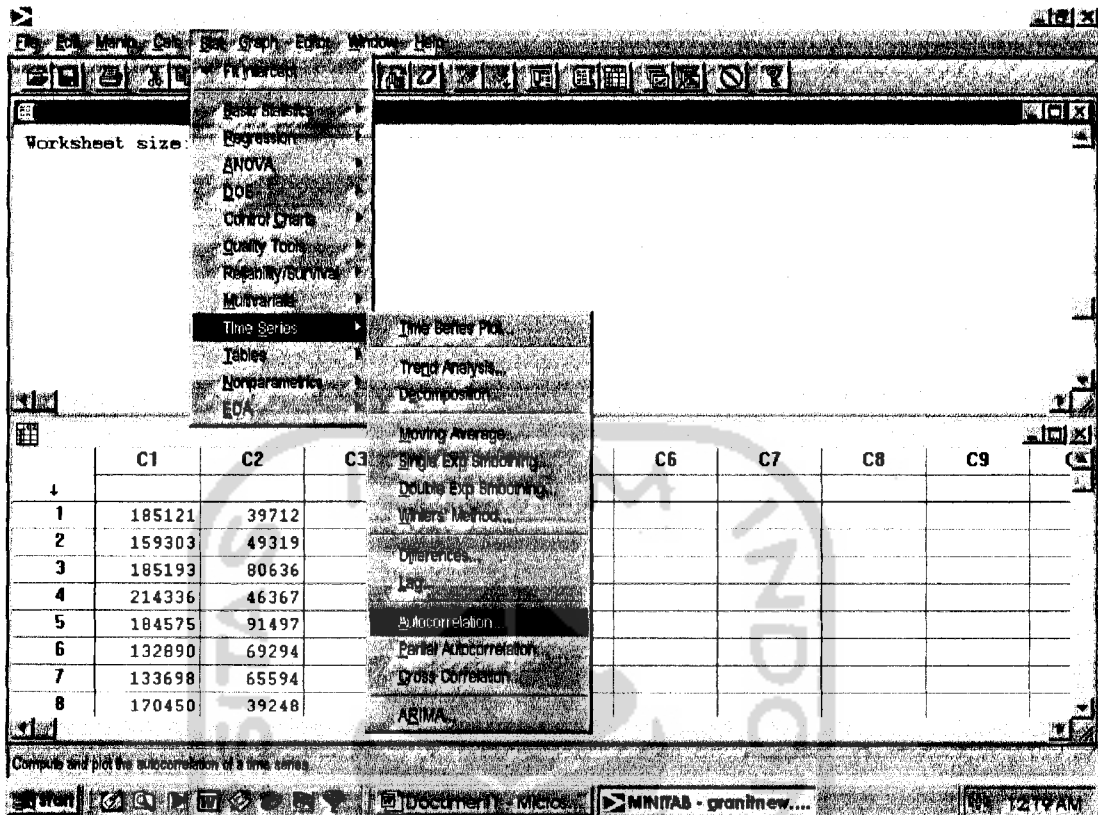
- Dari menu utama Minitab, pilih menu Stat kemudian submenu *Time series plot*, lalu pilih *Time series plot...* seperti Gambar 3
- Akan tampil di layar kotak dialog *time series plot* seperti Gambar 4



Gambar 4. Tampilan kotak dialog *time series plot*

Pengisian :

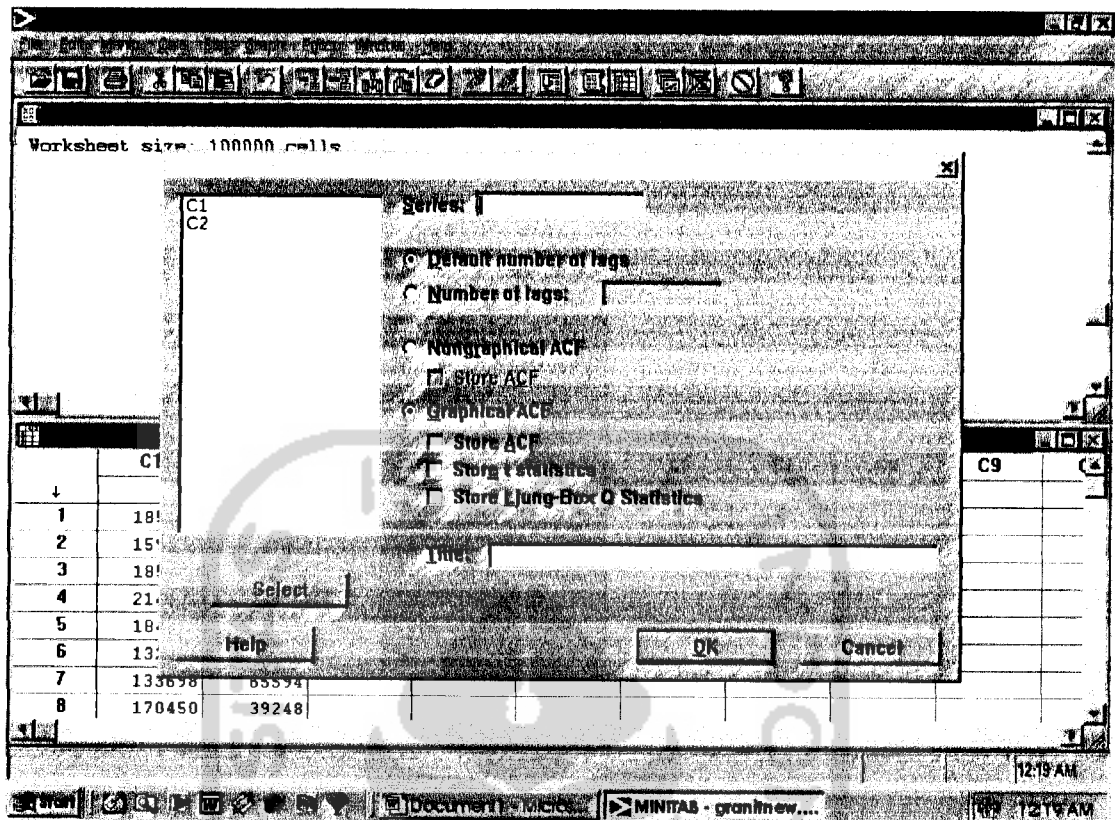
- *Graph variables*, masukan kolom data yang akan dioperasikan
- *Time scale*, pilih *calendar* dan pilih *month year*
- Abaikan bagian lain dan tekan OK untuk proses data



Gambar 5. Tampilan menu autokorelasi

Untuk mendapatkan plot autokorelasi, maka langkah-langkah yang dilakukan adalah :

- Dari menu utama Minitab, pilih menu Stat kemudian submenu *Time series* plot, lalu pilih *Autocorrelation...* seperti tampak pada Gambar 5
- Akan tampil di layar kotak dialog *Autocorrelation Function* seperti tampak pada Gambar 6



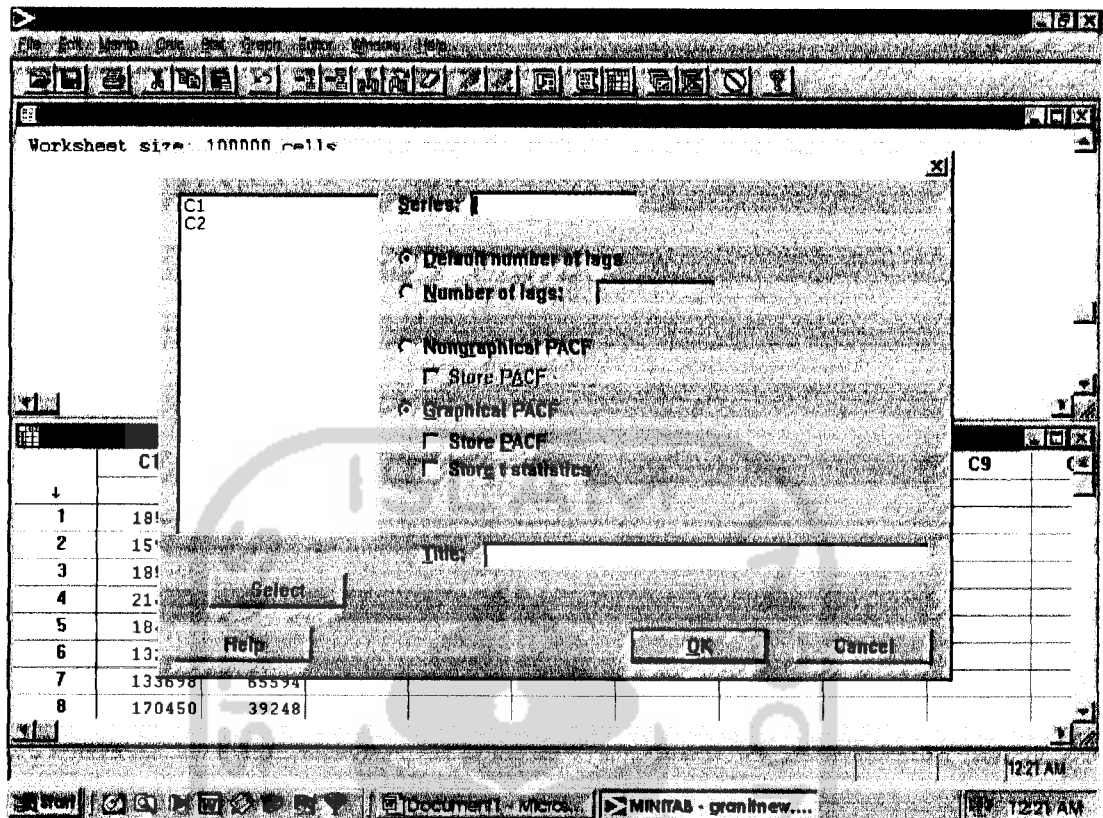
Gambar 6. Tampilan kotak dialog fungsi autokorelasi

Pengisian :

- *Series*, masukan kolom data yang akan dioperasikan
- Abaikan bagian lain dan tekan OK untuk proses data

Keterangan gambar :

- *Series* adalah masukan kolom data yang akan dioperasikan
- *Default number of lags* digunakan untuk $n/4$ series pertama saja dengan data kurang dari 240, sedangkan untuk data lebih dari 240 digunakan $\sqrt{n} + 45$, dimana n adalah jumlah data
- *Number of lags* digunakan untuk berapa jumlah lags diinginkan.
- *Non graph ACF* digunakan apabila tidak dibutuhkan tampilan grafik ACF
- *Graph ACF* digunakan apabila dibutuhkan tampilan grafik ACF



Gambar 8. Tampilan kotak dialog fungsi autokorelasi parsial

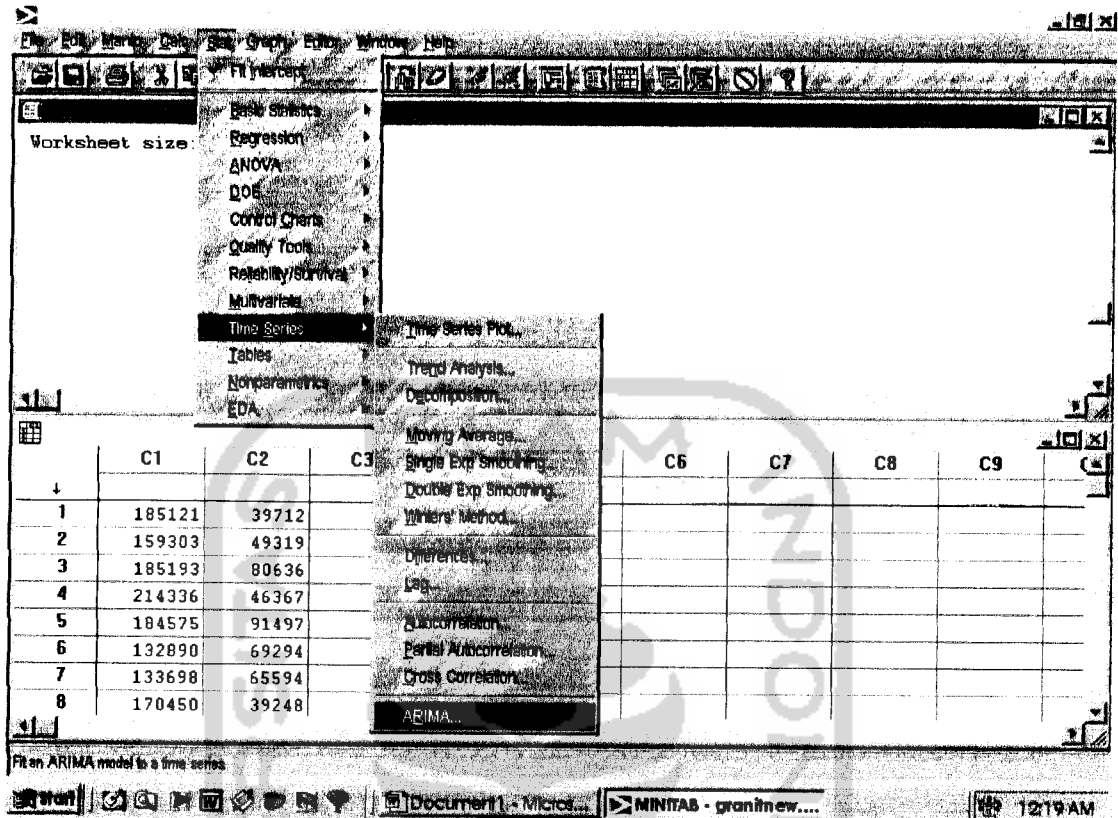
Pengisian :

- *Series*, masukan kolom data yang akan dioperasikan
- Abaikan bagian lain dan tekan OK untuk proses data

Keterangan gambar :

- *Series* adalah masukan kolom data yang akan dioperasikan
- *Default number of lags* digunakan untuk $n/4$ series pertama saja dengan data kurang dari 240, sedangkan untuk data lebih dari 240 digunakan $\sqrt{n} + 45$, dimana n adalah jumlah data
- *Number of lags* digunakan untuk berapa jumlah lags diinginkan.
- *Non graph PACF* digunakan apabila tidak dibutuhkan tampilan grafik PACF
- *Graph PACF* digunakan apabila dibutuhkan tampilan grafik PACF


b. Estimasi Model



Gambar 9. Tampilan menu ARIMA

Untuk mendapatkan apakah model ARIMA yang telah diidentifikasi tersebut baik, maka langkah-langkah yang dilakukan adalah :

- Dari menu utama Minitab, pilih menu Stat kemudian submenu *time series*, lalu pilih ARIMA... seperti tampak pada Gambar 9
- Akan tampil di layar kotak dialog ARIMA seperti tampak pada Gambar 10

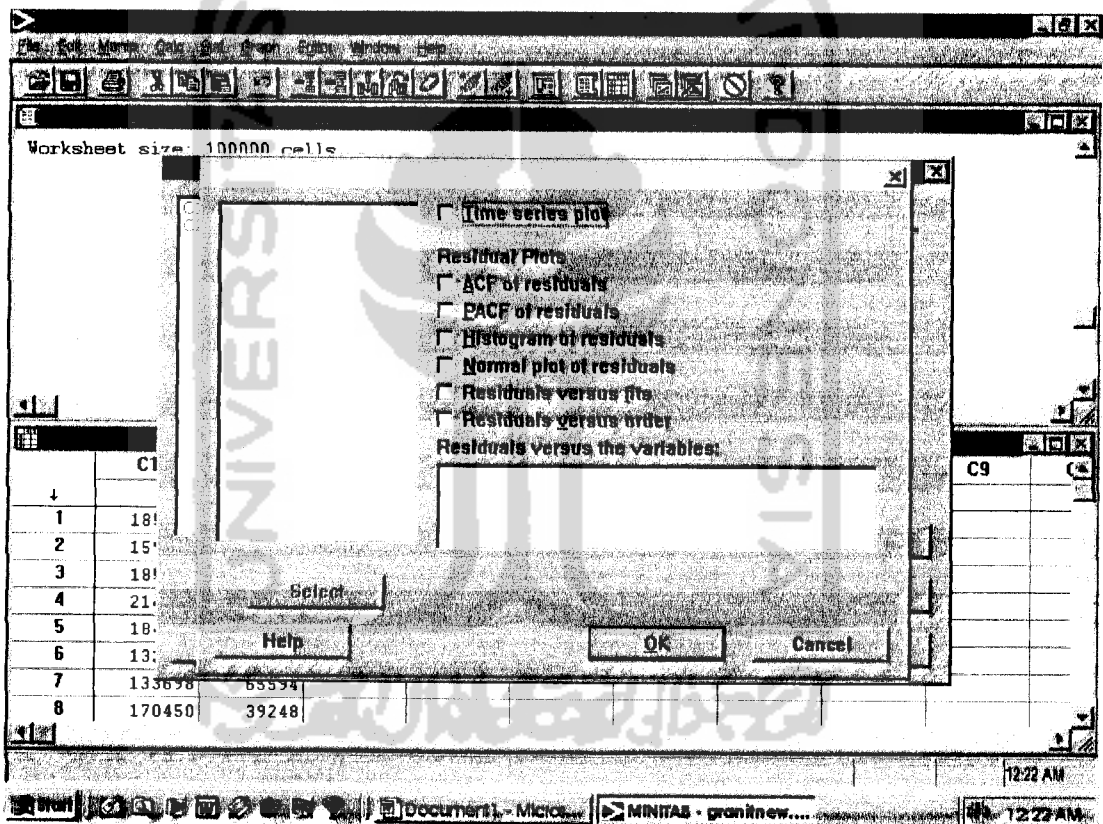


- *Include constant term in model* apabila dimasukan konstan kedalam model ARIMA

Untuk mendapatkan plot *time series*, plot residual ACF dan plot residual PACF, maka langkah-langkah yang dilakukan adalah :

- Pada kotak dialog ARIMA pilih *Graphs*
- Akan tampil di layar kotak dialog ARIMA-*Graphs* seperti tampak pada Gambar 11

c. Pemeriksaan Diagnostik



Gambar 11. Tampilan kotak dialog plot *time series*, plot residual ACF dan plot residual PACF

Pengisian :

- Pilih (aktifkan) *ACF of Residual* dan *PACF of Residual*

- Abaikan bagian lain dan tekan OK untuk proses data

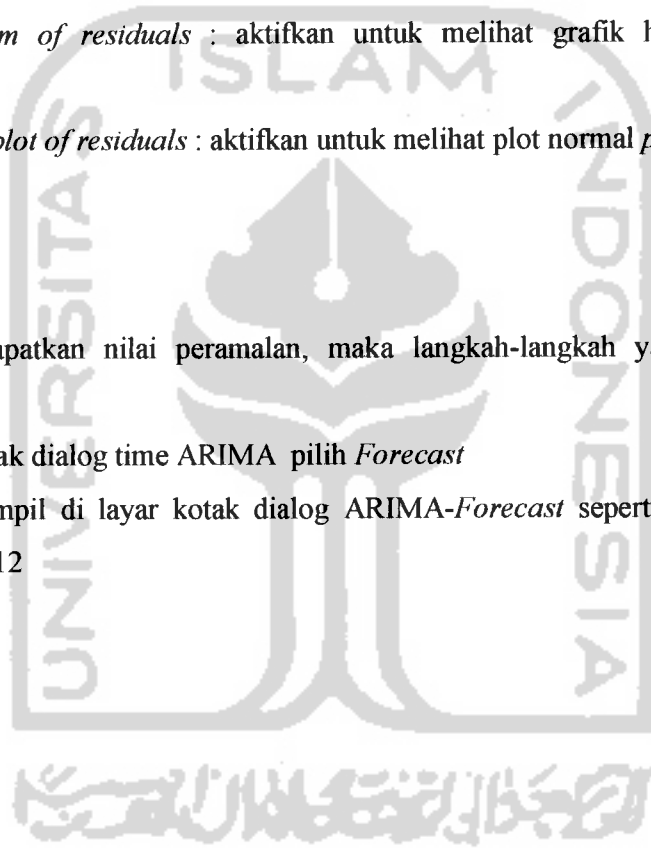
Keterangan gambar :

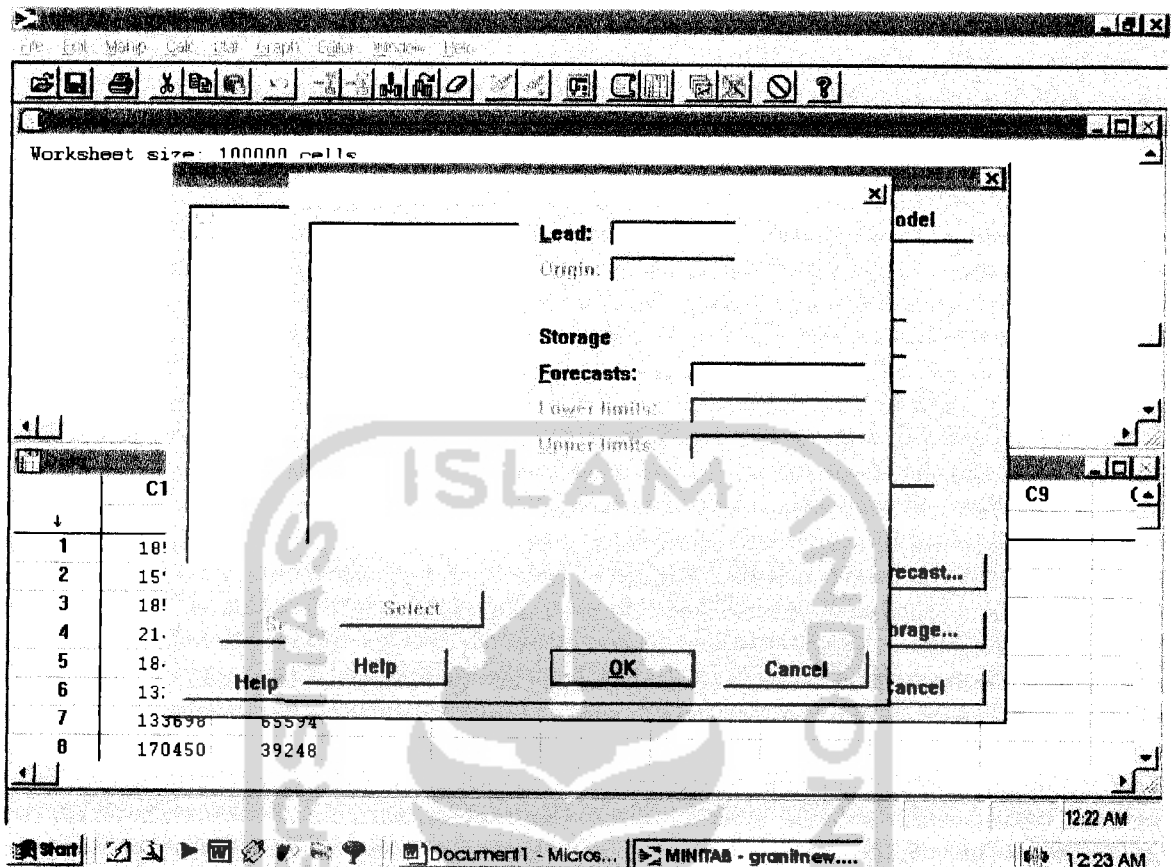
- *Time series plot* : aktifkan untuk melihat plot *time series* hasil ramalan
- *ACF of residuals* : aktifkan untuk melihat plot fungsi autokorelasi untuk residual.
- *PACF of residuals* : aktifkan untuk melihat plot fungsi autokorelasi parsial untuk residual.
- *Histogram of residuals* : aktifkan untuk melihat grafik histogram dari residual.
- *Normal plot of residuals* : aktifkan untuk melihat plot normal *probability* dari residual.

d. Peramalan

Untuk mendapatkan nilai peramalan, maka langkah-langkah yang dilakukan adalah :

- Pada kotak dialog time ARIMA pilih *Forecast*
- Akan tampil di layar kotak dialog *ARIMA-Forecast* seperti tampak pada Gambar 12





Gambar 12. Tampilan kotak dialog peramalan

Pengisian :

- *Lead*, masukan jumlah peramalan yang ingin diketahui
- Abaikan bagian lain dan tekan OK untuk proses data

Keterangan gambar :

- *Lead* adalah masukan jumlah peramalan yang ingin diketahui
- *Origin* adalah masukan jumlah data asli untuk pengolahan historis nilai peramalan
- *Forecasts* adalah masukan kolom tampilan untuk peramalan
- *Lower limits* adalah masukan kolom tampilan untuk batas bawah peramalan
- *Upper limits* adalah masukan kolom tampilan untuk batas atas peramalan

Lampiran G


Tabel III

Distribusi Chi-Square untuk Alpa 10%, 5%, 2.5% dan 1%

Derajat Bebas	0.1	0.05	0.025	0.01	Derajat Bebas	0.1	0.05	0.025	0.01
1	2.71	3.84	5.02	6.63	51	64.30	68.67	72.62	77.39
2	4.61	5.99	7.38	9.21	52	65.42	69.83	73.81	78.62
3	6.25	7.81	9.35	11.34	53	66.55	70.99	75.00	79.84
4	7.78	9.49	11.14	13.28	54	67.67	72.15	76.19	81.07
5	9.24	11.07	12.83	15.09	55	68.80	73.31	77.38	82.29
6	10.64	12.59	14.45	16.81	56	69.92	74.47	78.57	83.51
7	12.02	14.07	16.01	18.48	57	71.04	75.62	79.75	84.73
8	13.36	15.51	17.53	20.09	58	72.16	76.78	80.94	85.95
9	14.68	16.92	19.02	21.67	59	73.28	77.93	82.12	87.17
10	15.99	18.31	20.48	23.21	60	74.40	79.08	83.30	88.38
11	17.28	19.68	21.92	24.72	61	75.51	80.23	84.48	89.59
12	18.55	21.03	23.34	26.22	62	76.63	81.38	85.65	90.80
13	19.81	22.36	24.74	27.69	63	77.75	82.53	86.83	92.01
14	21.06	23.68	26.12	29.14	64	78.86	83.68	88.00	93.22
15	22.31	25.00	27.49	30.58	65	79.97	84.82	89.18	94.42
16	23.54	26.30	28.85	32.00	66	81.09	85.96	90.35	95.63
17	24.77	27.59	30.19	33.41	67	82.20	87.11	91.52	96.83
18	25.99	28.87	31.53	34.81	68	83.31	88.25	92.69	98.03
19	27.20	30.14	32.85	36.19	69	84.42	89.39	93.86	99.23
20	28.41	31.41	34.17	37.57	70	85.53	90.53	95.02	100.43
21	29.62	32.67	35.48	38.93	71	86.64	91.67	96.19	101.62
22	30.81	33.92	36.78	40.29	72	87.74	92.81	97.35	102.82
23	32.01	35.17	38.08	41.64	73	88.85	93.95	98.52	104.01
24	33.20	36.42	39.36	42.98	74	89.96	95.08	99.68	105.20
25	34.38	37.65	40.65	44.31	75	91.06	96.22	100.84	106.39
26	35.56	38.89	41.92	45.64	76	92.17	97.35	102.00	107.58
27	36.74	40.11	43.19	46.96	77	93.27	98.48	103.16	108.77
28	37.92	41.34	44.46	48.28	78	94.37	99.62	104.32	109.96
29	39.09	42.56	45.72	49.59	79	95.48	100.75	105.47	111.14
30	40.26	43.77	46.98	50.89	80	96.58	101.88	106.63	112.33
31	41.42	44.99	48.23	52.19	81	97.68	103.01	107.78	113.51
32	42.58	46.19	49.48	53.49	82	98.78	104.14	108.94	114.69
33	43.75	47.40	50.73	54.78	83	99.88	105.27	110.09	115.88
34	44.90	48.60	51.97	56.06	84	100.98	106.39	111.24	117.06
35	46.06	49.80	53.20	57.34	85	102.08	107.52	112.39	118.24
36	47.21	51.00	54.44	58.62	86	103.18	108.65	113.54	119.41
37	48.36	52.19	55.67	59.89	87	104.28	109.77	114.69	120.59
38	49.51	53.38	56.90	61.16	88	105.37	110.90	115.84	121.77
39	50.66	54.57	58.12	62.43	89	106.47	112.02	116.99	122.94
40	51.81	55.76	59.34	63.69	90	107.57	113.15	118.14	124.12
41	52.95	56.94	60.56	64.95	91	108.66	114.27	119.28	125.29
42	54.09	58.12	61.78	66.21	92	109.76	115.39	120.43	126.46
43	55.23	59.30	62.99	67.46	93	110.85	116.51	121.57	127.63
44	56.37	60.48	64.20	68.71	94	111.94	117.63	122.72	128.80
45	57.51	61.66	65.41	69.96	95	113.04	118.75	123.86	129.97
46	58.64	62.83	66.62	71.20	96	114.13	119.87	125.00	131.14
47	59.77	64.00	67.82	72.44	97	115.22	120.99	126.14	132.31
48	60.91	65.17	69.02	73.68	98	116.32	122.11	127.28	133.48
49	62.04	66.34	70.22	74.92	99	117.41	123.23	128.42	134.64
50	63.17	67.50	71.42	76.15	100	118.50	124.34	129.56	135.81

Lampiran H. Tabel IV : Distribusi normal.

Luas distribusi normal standar, memberikan luas di bawah kurve dari 0 sampai suatu bilangan positif h atau $P(0 < z < h)$.



b	.00	.01	.02	.03	.04	.05	.06	.07	.08	.09
0.0	.0000	.0040	.0080	.0120	.0160	.0199	.0239	.0279	.2319	.0359
0.1	.0398	.0438	.0478	.0517	.0557	.0596	.0636	.0675	.0714	.0753
0.2	.0793	.0832	.0871	.0910	.0948	.0987	.1026	.1064	.1103	.1141
0.3	.1179	.1217	.1255	.1293	.1331	.1368	.1406	.1443	.1480	.1517
0.4	.1554	.1591	.1628	.1664	.1700	.1736	.1772	.1808	.1844	.1879
0.5	.1915	.1950	.1985	.2019	.2054	.2088	.2123	.2157	.2190	.2224
0.6	.2257	.2291	.2324	.2357	.2389	.2422	.2454	.2486	.2517	.2549
0.7	.2580	.2611	.2642	.2673	.2703	.2734	.2764	.2794	.2823	.2852
0.8	.2881	.2910	.2939	.2967	.2995	.3023	.3051	.3078	.3106	.3133
0.9	.3159	.3186	.3212	.3238	.3264	.3289	.3315	.3340	.3365	.3389
1.0	.3413	.3438	.3461	.3485	.3508	.3531	.3554	.3577	.3599	.3621
1.1	.3643	.3665	.3686	.3708	.3729	.3749	.3770	.3790	.3810	.3830
1.2	.3849	.3869	.3888	.3907	.3925	.3944	.3962	.3980	.3997	.4015
1.3	.4032	.4049	.4066	.4082	.4099	.4115	.4131	.4147	.4162	.4177
1.4	.4192	.4207	.4222	.4236	.4251	.4265	.4279	.4292	.4308	.4319
1.5	.4332	.4345	.4357	.4370	.4382	.4394	.4406	.4418	.4429	.4441
1.6	.4452	.4463	.4474	.4484	.4495	.4505	.4515	.4525	.4535	.4545
1.7	.4554	.4564	.4573	.4582	.4591	.4599	.4608	.4616	.4625	.4633
1.8	.4641	.4649	.4656	.4664	.4671	.4678	.4686	.4693	.4699	.4706
1.9	.4713	.4719	.4726	.4732	.4738	.4744	.4750	.4756	.4761	.4767
2.0	.4772	.4778	.4783	.4788	.4793	.4798	.4803	.4808	.4812	.4817
2.1	.4821	.4826	.4830	.4834	.4838	.4842	.4846	.4850	.4854	.4857
2.2	.4861	.4864	.4868	.4871	.4875	.4878	.4881	.4884	.4887	.4890
2.3	.4893	.4896	.4898	.4901	.4904	.4906	.4909	.4911	.4913	.4916
2.4	.4918	.4920	.4922	.4925	.4927	.4929	.4931	.4932	.4934	.4936
2.5	.4938	.4940	.4941	.4943	.4945	.4946	.4948	.4949	.4951	.4952
2.6	.4953	.4955	.4956	.4957	.4959	.4960	.4961	.4962	.4963	.4964
2.7	.4965	.4966	.4967	.4968	.4969	.4970	.4971	.4972	.4973	.4974
2.8	.4974	.4975	.4976	.4977	.4977	.4978	.4979	.4979	.4980	.4981
2.9	.4981	.4982	.4982	.4983	.4984	.4984	.4985	.4985	.4986	.4986
3.0	.4987	.4987	.4987	.4988	.4988	.4989	.4989	.4989	.4990	.4990