

3100097008490

TUGAS AKHIR

PENERAPAN ANALISA STATE SPACE DALAM PENENTUAN MODEL PERAMALAN PENJUALAN OBAT-OBATAN OLEH TEAM HOSPITAL DI PT. EURINDO COMBINED

Oleh :

HERRU RISWANTO

NRP. 1392030051



RSMi
519.535
Ris
p-1
1996

PROGRAM STUDI DIPLOMA III STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
S U R A B A Y A
1 9 9 6

TUGAS AKHIR

**PENERAPAN ANALISA STATE SPACE DALAM PENENTUAN
MODEL PERAMALAN PENJUALAN OBAT-OBATAN OLEH
TEAM HOSPITAL DI PT. EURINDO COMBINED**

DIAJUKAN SEBAGAI
SYARAT KELULUSAN DI PROGRAM STUDI DIPLOMA III STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
INSTITUT TEKNOLOGI SEPULUH NOPEMBER SURABAYA

Oleh :

HERRU RISWANTO
NRP. 1392030051

**PROGRAM STUDI DIPLOMA III STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
1996**

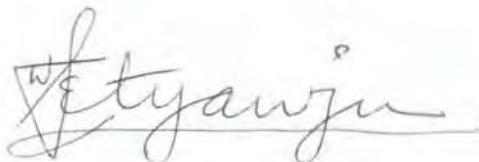
LEMBAR PENGESAHAN

PENERAPAN ANALISA STATE SPACE DALAM PENENTUAN MODEL PERAMALAN PENJUALAN OBAT-OBATAN OLEH TEAM HOSPITAL DI PT. EURINDO COMBINED

Oleh :

HERRU RISWANTO
NRP. 1392030051

Surabaya, Nopember 1996
MENYETUJUI
DOSEN PEMBIMBING



Dra. Wiwiek Setya Winahyu, MS
NIP. 131283375

MENGETAHUI

KETUA PRODI DIPLOMA III
STATISTIKA FMIPA - ITS :



Ir. Hj. MUTIAH SALAMAH F.
NIP. 131283368

*Kepada Kedua Orang Tua dan Kakak-kakakku
Serta Adik-adikku yang tersayung*

ABSTRAK

MULIA PERTIWI STAKAM
INSTITUT TEKNOLOGI
SEPULUH NOPEMBRA

ABSTRAK

PENERAPAN ANALISA STATE SPACE DALAM PENENTUAN MODEL PERAMALAN PENJUALAN OBAT-OBATAN OLEH TEAM HOSPITAL DI PT. EURINDO COMBINED

OLEH : HERRU RISWANTO
PEMBIMBING : Dra. WIWIEK SETYA WINAHYU. MS

Salah satu usaha dalam menyediakan jenis obat di bidang farmasi dengan jumlah dan waktu yang tepat serta akurat, tergantung pada kelancaran proses promosi dan penjualan obat, salah satunya adalah ketersediaan obat-obatan dan kemanjuran dari obat tersebut. Dengan ketersediaan obat-obatan tersebut akan memperlancar dan menjaga kepuasan pelanggan dalam pengadaan obat dalam waktu yang tepat. Dalam penelitian ini menentukan model peramalan penjualan obat sebagai kasus *multivariate time series*.

Pada PT. EURINDO COMBINED dilakukan penelitian dengan menggunakan metode state space didapatkan model peramalan sebagai berikut :

1. Model ke satu untuk penjualan obat jenis flegyl.
Flegyl infusion : $FI_{t+1} = 0.227 FI_t + a_{1,t+1}$

Flegyl Suppo 500 Mg :

$$FS_{t+1} = 0.133 FI_t + 0.241 FS_t + 0.483 F1_t + a_{2,t+1}$$

Flegyl Suppo 1 Gr : $F1_{t+1} = 0.353 F1_t + a_{3,t+1}$

2. Model ke dua untuk jenis obat profined.

Profined Suppo 100 Mg : $PS_{t+1} = 0.592 Ps_t + a_{1,t+1}$

Profined Inj : $PI_{t+1} = 0.229 PI_t + a_{2,t+1}$

3. Model ke tiga adalah univariate time series untuk jenis obat Peflecine I.V /5 AMP adalah sebagai berikut :

$$Z_t = 0.59183 Z_{t-1} + a_t$$

Dengan didapatkan ketiga model peramalan dari tiga kelompok tersebut, maka perusahaan dapat menyediakan obat-obat untuk mengantisipasi permintaan Rumah Sakit.

Untuk nilai ramalan 5 bulan yang akan datang, berikut ini :

Hasil Peramalan Obat Flegyl Peflecine dan Profined

OBS	Flegyl infusion 100 M	Flegyl Suppo 500 Mg	Flegyl Suppo 1 Gr	Peflecine I.V/5 AMP	Profined Suppo 100 Mg	Profined INJ
1	984.66	365.80	915.01	141.574	1196.61	974.48
2	975.72	355.01	960.41	141.574	1195.22	973.92
3	973.68	354.10	976.13	141.574	1194.41	973.13
4	973.22	361.69	981.68	141.574	1193.94	973.40
5	973.11	362.50	983.64	141.574	1193.66	973.29

KATA PENGANTAR

KATA PENGANTAR

Dengan memanjatkan puji syukur yang tidak terhingga atas kehadiran Allah SWT, karena Rahmat dan Hidayah-nya, akhirnya penulis dapat menyelesaikan Tugas Akhir ini dengan judul PERAMALAN PENJUALAN OBAT-OBATAN DIRUMAH SAKIT SELURUH JAWA TIMUR OLEH TEAM HOSPITAL PT. EURINDO COMBINED Tugas Akhir ini dibuat guna memenuhi salah satu syarat kelulusan program Diploma III Jurusan Statistik, Institut Teknologi Sepuluh Nopember di Surabaya.

Dalam penulisan Tugas Akhir ini penulis telah berusaha semaksimal mungkin agar dapat menghindari kesalahan dan kekurangan yang ada. tetapi mengingat keterbatasan kemampuan penulis, maka tidak mengherankan jika ada kekurangan dan kesalahan dalam penulisan ini. Untuk itu penulis mohon adanya saran maupun kritik yang bersifat membangun dari pembaca demi kesempurnaan penulisan.

Pada kesempatan ini penyusun menyampaikan ucapan terima kasih yang sedalam-dalamnya kepada :

1. Bapak Drs. Haryono MSIE selaku Kepala Jurusan Statistika.
2. Ibu Dra. A. Mutia Salama Fauzi selaku Kepala Program Studi Diploma III Statistika.

3. Ibu Dra. Wiwiek Setyo Winahyu Ms selaku dosen pembimbing yang telah berkenan membimbing hingga selesaiya Tugas Akhir ini.
4. Bapak dan Ibu dosen yang telah berkenan memberikan bekal ilmu pengetahuan.
5. Bapak dan Ibu yang dengan sabar, iklas dan doa serta restunya selama menempuh kuliah hingga terselesaiya Tugas Akhir ini.
6. Kakak-kakakku serta adik-adikku yang telah banyak memberikan semangat, dorongan dan bantuannya sehingga dapat terselesaikannya Tugas Akhir ini.
7. Teman-temanku yang tidak mungkin kami sebutkan satu persatu, serta Lailiyah yang telah banyak memberikan spiritnya, hingga terselesaikannya Tugas Akhir ini.
8. Seluruh karyawan dan staff jurusan Statistik yang telah banyak membantu hingga terselesaikannya Tugas Akhir.

Akhirnya Tugas Akhir ini dapat berguna bagi semua pihak yang memerlukan.

Surabaya, september 1996

Penulis

DAFTAR ISI

DAFTAR ISI

ABSTRAK	i
KATA PENGANTAR	ii
DAFTAR ISI	iv
DAFTAR TABEL	vi
DAFTAR LAMPIRAN	vii
BAB I. PENDAHULUAN	1
1.1. Latar Belakang	1
1.2. Permasalahan	2
1.3. Tinjauan Penelitian	3
1.4. Manfaat Penelitian	3
BAB II. TINJAUAN PUSTAKA	4
2.1. Model Multivariant Time Series	4
2.2. Analisis State Space	6
2.3. Identifikasi Model Vektor Time series	14
2.4. Penetapan Model State Space dan analisa Korelasi kanonik	17
2.5. Penelitian Diagnostik dan Peramalan ...	21
BAB III. BAHAN DAN METODOLOGI	24
3.1. Bahan Penelitian	24
3.2. Metodologi Penelitian	25
BAB IV. ANALISIS DAN PEMBAHASAN	28
4.1. Pembentukan Peramalan Obat Flegyl Infusion	

100 M. Flegyl Suppo 500 Mg. dan Flegyl Suppo 1 Gr	28
4.2. Pembentukan Peramalan Obat Profined Suppo 100 Mg dan Profenid INJ	45
4.3 Pembentukan Model Tiga Untuk Jenis Obat Plefleicin I.V /5 AMP	59
EAF V. KESIMPULAN DAN SARAN	64
5.1. Kesimpulan	64
5.2. Saran	67
DAFTAR PUSTAKA	68
LAMPIRAN	

DAFTAR TABEL

DAFTAR TABEL

Tabel 4.1	Deskripsi Data Asli	31
Tabel 4.2	Representasi Skematik MACF Deret Data	33
Tabel 4.3	Representasi Skematik MPACF Deret Data ...	34
Tabel 4.4	Nilai AIC Deret Data	35
Tabel 4.5	Tabel Analisa Korelasi Kanonik	37
Tabel 4.6	Estimasi Parameter Model State Space Pendahuluan	39
Tabel 4.7	Estimasi Prameter Model state Space akhir	40
Tabel 4.8	Representasi Skematik MACF Residual	43
Tabel 4.9	Representasi Skematik MPACF Residual	44
Tabel 4.10	Nilai AIC Deret Data	45
Tabel 4.11	Nilai Peramalan Penjualan Obat-Obatan	46
Tabel 4.12	Representasi Skematik MACF Deret Data	48
Tabel 4.13	Representasi Skematik MPACF Deret Data ...	49
Tabel 4.14	Nilai AIC Deret Data	50
Tabel 4.15	Tabel Analisa Korelasi Kanonik	52
Tabel 4.16	Estimasi Parameter Model State Space Pendahuluan	54
Tabel 4.17	Estimasi Prameter Model state Space akhir	55
Tabel 4.18	Representasi Skematik MACF Residual	58
Tabel 4.19	Representasi Skematik MPACF Residual	59
Tabel 4.20	Nilai AIC Deret Data	60
Tabel 4.21	Nilai Peramalan Penjualan Obat-Obatan	61

Tabel 4.22 Estimasi Model ARIMA (1,0,0)	63
Tabel 4.23 Presentase Kesalahan Peramalan	65
Tabel 4.24 Hasil Peramalan Sepuluh Kedepan	65

DAFTAR LAMPIRAN

DAFTAR LAMPIRAN

- A. Daftar Data Penjualan Obat-Obatan Team Hospital.
- B. Gambar Plot Data Asli untuk Jenis Obat Flegyl.
- C. Gambar Plot Data Asli untuk Jenis Obat Profenid.
- D. Gambar Plot Data Asli untuk Jenis Obat Pleflecine.
 - Plot Data ACF.
 - Plot Data PACF.
- E. Plot Data ACF Residual.
 - Plot Data PACF Residual.
 - Plot Data Normal Residual.
- F. Matrik Variant Kovariant dan Korelasi Deret Input Model State Space Untuk Jenis Obat Flegyl.
- G. Matrik Variant kovariant dan Korelasi Deret Input Model State Space Untuk jenis Obat Profenid.
- H. Estimasi Model ARIMA dan Peramalan Untuk Jenis Obat Pleflecine.

BAB I

PENDAHULUAN

BAB I

PENDAHULUAN

1.1. Latar Belakang

Dalam suatu kegiatan menajemen yang harus direncanakan dengan baik adalah meramalkan suatu permintaan saat ini atau yang akan datang. Dimana perhitungan kuantitatif sangat berperan dalam analisis peluang pasar, perencanaan program pemasaran dan pengendalian pemasaran. Perusahaan harus dapat menyiapkan beberapa ramalan permintaan dari seisi produksi, dimensi waktu dan tempat.

Perusahaan harus dapat menyiapkan ramalan yang didasarkan pada jumlah permintaan produk dimasa lalu. Asumsi yang mendasari ini adalah bahwa data masa lalu mempunyai korelasi linier. Ini untuk selanjutnya dapat dimanfaatkan untuk membuat modal peramalan tentang penjualan yang akan datang.

PT.EURINDO COMBINED adalah salah satu perusahaan yang bergerak dalam bidang farmasi (obat-obatan). Dengan melihat persaingan yang sangat ketat maka kebutuhan konsumen akan ketepatan dan pelayanan semakin besar.

Dari variasi produk serta jumlah penjualan, maka perusahaan berkepentingan untuk mengetahui pola - pola dari penjualannya. Dari sini perusahaan berhak menentukan kebijaksanaan dibidang penjualan sesuai dengan permintaan dan penjualan hasil produk, yang nantinya mengarah kepada

da pencapaian stabilitas pemasaran untuk upaya pengendalian.

Oleh karena itu untuk mengetahui prilaku dari produk serta penjualan dilakukan usaha pemecahan, dimana variasi dari penjualan dan variasi produk yang bersifat Probabilistik menimbulkan permasalahan yang tidak dapat dianalisa secara sendiri-sendiri karena adanya korelasi antara variable-variable jenis produk dan jumlah permintaan produk yang akan diterima dimasa mendatang pernyataannya sulit di duga dengan pasti dan sangat bervariasi. Hal ini menuntut adanya pendekatan stastistik untuk mengestimasi ketidakpastian dimasa yang akan datang berdasarkan data masa lalu.

1.2. Permasalahan

Perusahaan perlu mendapatkan informasi yang sangat akurat mengenai jenis obat untuk kebutuhan Rumah Sakit seluruh Jawa Timur. Dengan kebutuhan obat yang bervariasi di antaranya obat flegyl infusion 100 Mg, flegyl suppo 500 Mg dan flegyl suppo 1 gr mempunyai fungsi yang sama, tetapi cara penggunaan yang berbeda. Jenis obat profenid suppo 100 Mg dan Profenid INJ juga mempunyai fungsi yang sama, tetapi penggunaan yang berbeda. Serta jenis obat peflecine I.V/5 AMP yang mempunyai fungsi untuk infeksi typoid. Dari keenam jenis obat akan dicari suatu model peramalan untuk pendistribusian ke rumah sakit yang ada di seluruh Jawa Timur.

1.3. Tujuan Penelitian

Tujuan penelitian secara umum adalah untuk mengetahui jumlah penjualan obat-obatan yang akan didistribusikan pada 5 bulan yang akan datang.

Tujuan penelitian secara khusus :

1. Menetapkan suatu model peramalan terhadap pola penjualan obat flegyl infusion 100 Mg, flegyl suppo 500 Mg, flegyl suppo 1 Gr, profenid suppo 100 Mg, profenid INJ dan peflecine I.V/5 AMP.
2. Meramalkan nilai-nilai peramalan untuk periode yang akan datang untuk jenis obat flegyl infusion 100 Mg flegyl suppo 500 Mg, flegyl suppo 1 Gr, Profenid suppo 100 Mg, profenid INJ dan peflecine I.V/5 AMP.

1.4. Manfaat Penelitian

Sesuai dengan tujuan penelitian, maka manfaat penelitian adalah sebagai berikut :

1. Pihak perusahaan mendapat informasi mengenai pendistribusian obat-obatan di rumah sakit berdasarkan penjualan.
2. Mengetahui penjualan obat - obatan yang akan datang serta dapat sebagai masukan menentukan jumlah atau rancangan persediaan.

BAB II

TINJAUAN PUSTAKA

BAB II

TINJAUAN PUSTAKA

2.1. Model Multivariate Time Series

2.1.1. Konsep Dasar Multivariate Time Series

Suatu sistem peramalan model time series harus mempunyai kaitan antara ramalan yang dibuat supaya di dapat model peramalan yang akurat maka perlu diperhatikan adanya saling ketergantungan antara faktor-faktor yang berpengaruh untuk mendapatkan model yang layak.

Dalam pendekatan untuk memperoleh peramalan suatu model untuk mengetahui parameter dari data pengamatan yang dicatat menurut urutan waktu menggunakan analisis time series. Data pada pengamatan time series harus mempunyai interval waktu yang sama. Pengamatan pada analisis time series dari satu periode bergantung pada periode sebelumnya. Pengamatan time series dapat didekati dengan hukum-hukum probabilistik yang disebut dengan proses stokastik, dimana setiap nilai dari suatu variabel random mempunyai suatu distribusi tertentu.

Peramalan time series dimana pada pengamatan itu merupakan kasus time series univariate, maka dapat dilihat bahwa time series pada saat t_1, t_2, \dots, t_n akan mempunyai variabel random Z_1, Z_2, \dots, Z_n . Fungsi distribusi bersama yang bersesuaian adalah $P(Z_1, Z_2, \dots, Z_n)$. Akan tetapi dalam banyak studi empiris sering dijumpai adanya obser-

vasi yang mempunyai beberapa variabel. Apabila diinginkan model time series yang dibentuk, menjelaskan pula hubungan antar variabelnya, maka kasus ini dapat dipandang sebagai kasus multivariate time series. dengan vektor variabel randomnya : $Z_t = [Z_{1t}, Z_{2t}, \dots, Z_{mt}]$.

2.1.2. Fungsi Matriks Kovarians dan Matrik Korelasi

Pada variabel pengamatan dalam multivariate time series dinyatakan dalam bentuk matriks seperti berikut :

$$Z_t = [Z_{1,t} \ Z_{2,t} \ \dots \ Z_{m,t}] ; t = 0, 1, \dots, n$$

dan vektor mean dapat dinyatakan sebagai berikut :

$$E(Z_t) = \mu_t = [\mu_1 \ \mu_2 \ \dots \ \mu_m]^\top \quad (2.1)$$

Matrik kovarians-nya berbentuk :

$$\Gamma(k) = \text{Cov}(Z_t, Z_{t+k}) = E[(Z_t - \mu)(Z_{t+k} - \mu)^\top]$$

$$= \begin{bmatrix} Z_{1,t} - \mu_1 \\ Z_{2,t} - \mu_2 \\ \vdots \\ Z_{m,t} - \mu_m \end{bmatrix} [Z_{1,t+k} - \mu_1, \dots, Z_{m,t+k} - \mu_m]$$

$$\begin{bmatrix} \gamma_{11(k)} & \gamma_{12(k)} & \dots & \gamma_{1m(k)} \\ \gamma_{21(k)} & \gamma_{22(k)} & \dots & \gamma_{2m(k)} \\ \vdots & \vdots & \ddots & \vdots \\ \gamma_{m1(k)} & \gamma_{m2(k)} & \dots & \gamma_{mm(k)} \end{bmatrix} = \text{Cov}[Z_{t-k}, Z_t] \quad (2.2)$$

dimana :

$$\begin{aligned} \gamma_{ijk(k)} &= E((Z_{i,t} - \mu_i)(Z_{j,t+k} - \mu_j)) \\ &= E((Z_{i,t-k} - \mu_i)(Z_{j,t} - \mu_j)) \end{aligned}$$

$$k = 0, \pm 1, \pm 2, \dots, n \quad ; \quad i = 1, 2, \dots, m \quad ; \quad j = 1, 2, \dots, m$$

$\Gamma(k)$ adalah fungsi matriks kovarians untuk proses vektor Z_t . Jika $i=j$ maka γ_{ikk} adalah fungsi autokovarians pro-

ses $Z_{i,j}$. Sedangkan jika $i \neq j$ maka $\gamma_{ij(k)}$ adalah fungsi kovarians silang antara proses $Z_{i,t}$ dan $Z_{j,t-k}$.

Fungsi matriks korelasi untuk proses vektor didefinisikan oleh :

$$\rho(k) = D^{-1/2} \Gamma(k) D^{-1/2} = [\rho_{ij}(k)] \quad (2.3)$$

$i = 1, 2, \dots, m$; $j = 1, 2, \dots, m$; dimana D adalah matriks diagonal elemen diagonal ke- i adalah varians dari proses ke- i .

$$D = \text{Diag}[\gamma_{11}(0), \gamma_{22}(0), \dots, \gamma_{mm}(0)]$$

Sedangkan fungsi korelasi silang antara $Z_{i,t}$ dan $Z_{j,t}$ dinyatakan dalam bentuk berikut :

$$\rho_{ij}(k) = \frac{\gamma_{ij}(k)}{[\gamma_{ii}(0) \gamma_{jj}(0)]^{1/2}} \quad (2.4)$$

2.2. Analisa State Space

2.2.1. Konsep Dasar Model State Space

Bentuk state space dari suatu sistem merupakan konsep dasar dalam teori kontrol modern. Model state space dari suatu sistem didefinisikan sebagai suatu himpunan terkecil dari informasi-informasi mengenai tingkah laku atau keadaan di masa sekarang dan masa lampau sedemikian hingga tingkah laku dimasa yang akan datang dari suatu sistem dapat diterangkan secara sempurna sebagai pengetahuan bagi keadaan sekarang dan sebagai masukan bagi keadaan dimasa yang akan datang.

a. State (keadaan)

State atau keadaan suatu sistem dinamik adalah himpunan

terkecil dari variabel-variabel (yang disebut variabel state) sedemikian rupa sehingga dengan mengetahui variabel-variabel ini pada $t=t_0$ (present value), bersama-sama masukkan untuk $t \geq t_0$ (future input). dapatlah ditentukan secara lengkap perilaku sistem untuk setiap waktu $t \geq t_0$. Jadi keadaan suatu sistem dinamik pada saat t secara unik ditentukan oleh state tersebut pada $t=t_0$ dan masukkan untuk $t \geq t_0$ dan tidak bergantung pada keadaan dari masukkan sebelum t_0 (independent of its past).

Untuk sistem linier parameter konstan biasanya dipilih waktu acuan $t_0=0$.

b. Variabel State

Variabel state suatu sistem dinamis adalah himpunan terkecil dari variabel-variabel yang menentukan keadaan sistem dinamik. Jika paling tidak diperlukan n variabel $X_1(t)$, $X_2(t)$, ..., $X_n(t)$; untuk melukiskan secara lengkap perilaku suatu sistem dinamik, sedemikian rupa sehingga setelah diberikan masukkan untuk $t \geq t_0$ maka keadaan sistem yang akan datang telah ditentukan secara lengkap, maka n variabel $X_1(t)$, $X_2(t)$, ..., $X_n(t)$ tersebut merupakan suatu himpunan variabel state (keadaan) salah satu keunggulan model state space adalah variabel state terpilih tidak perlu menyatakan besaran - besaran fisis dari sistem atau yang secara fisis dapat diukur atau diamati. Meskipun demikian secara praktis sebaiknya dipilih variabel state yang dapat diukur secara mudah.

c. Vektor State

Jika diperlukan n variabel keadaan untuk menggambarkan secara lengkap perilaku suatu sistem yang diberikan. Maka n variabel keadaan ini dapat dianggap sebagai komponen suatu vektor $X(t)$. Vektor semacam ini disebut vektor state. Jadi vektor state adalah suatu vektor yang menentukan secara unik keadaan sistem $X(t)$ untuk setiap $t \geq t_0$ setelah ditetapkan masukan untuk $t \geq t_0$.

d. State Space (ruang keadaan)

Ruang n dimensi yang sumbu koordinatnya terdiri dari sumbu x_1, x_2, \dots, x_n disebut state space (ruang keadaan). Setiap state dapat dinyatakan dengan suatu titik pada state space.

Kita pandang Y_{1t} dan Y_{2t} sebagai out-put dari suatu sistem terhadap input X_{1t} dan X_{2t} . Suatu sistem dikatakan linier jika dan hanya jika suatu kombinasi linier dari input $aX_{1t} + bX_{2t}$ menghasilkan output dengan kombinasi linier yang sama yaitu $aY_{1t} + bY_{2t}$ untuk sembarang konstanta a dan b . Suatu sistem dikatakan time-invariant jika karakteristik dari suatu sistem tidak berubah terhadap waktu, sedemikian hingga jika input X_t menghasilkan output Y_t , maka input X_{t-t_0} akan menghasilkan output Y_{t-t_0} . Suatu sistem dapat dikatakan linier time-invariant jika suatu sistem itu linier dan juga time-invariant. Dan juga suatu sistem akan mempunyai proses yang stasioner apabila sistem ini merupakan sistem yang linier time-invariant.

2.2.2. Bentuk Umum Model State Space

Sistem yang linier dengan parameter konstan (linier time-invariant), bentuk state spacenya digambarkan oleh persamaan state :

$$Y_{t+1} = A Y_t + G X_{t+1} \quad (2.5)$$

dan persamaan output :

$$Z_t = H Y_t \quad (2.6)$$

dimana Y_t adalah vektor state dengan dimensi k

A adalah matriks transisi kxk

G adalah matriks input kxn

X_t adalah vektor input sistem nx1

Z_t adalah vektor output mx1

H adalah matriks observasi mxk

Jika input X_t dan output Z_t adalah suatu proses stokastik maka bentuk state vektorya menjadi :

$$\begin{aligned} Y_{t+1} &= A Y_t + G a_{t+1} \\ Z_t &= H Y_t + b_t \end{aligned} \quad (2.7)$$

dimana $a_{t+1} = X_{t+1} - E(X_{t+1} | X \leq n)$ adalah vektor one step-ahead dari error peramalan proses input X_{t+1} , sedangkan b_t adalah vektor disturbansi mx1, yang diasumsikan independen dari a_t . Vektor a_{t+1} dikenal juga sebagai inovasi dari input X_t pada waktu t+1. Bila $Z_t = X_t$ dan b_t dihilangkan dari (2.7) maka bentuk state spacenya adalah bentuk yang berasal dari proses stokastik Z_t yang stasioner.

$$\begin{aligned} Y_{t+1} &= A Y_t + G a_{t+1} \\ Z_t &= H Y_t \end{aligned} \quad (2.8)$$

Jadi proses Z_t adalah output dari suatu sistem stokastik

yang linier dengan parameter konstan yang dikendalikan oleh input white noise a_t . Sedangkan Y_t adalah state dari proses.

Persamaan state disebut juga sebagai persamaan sistem atau persamaan transisi dan persamaan output disebut juga persamaan observasi.

2.2.3. Hubungan antara Model State Space Dengan Model ARMA

2.2.3.1. Bentuk State Space Dari Model ARMA

Untuk melihat hubungan antara model state space dengan model ARMA baik untuk kasus univariate maupun multivariate, kita pandang kembali model vektor ARMA(p,q) yang berdimensi m, stasioner dan mempunyai rataan nol.

$$\Phi_p(B)Z_t = \Theta(B)a_t \quad (2.9)$$

atau :

$$Z_t = \Phi_1 Z_{t-1} + \dots + \Phi_p Z_{t-p} + a_t - \Theta_1 a_{t-1} - \dots - \Theta_q a_{t-q}$$

dimana :

$$\Phi(B) = (I - \Phi_1 B - \dots - \Phi_p B^p)$$

$$\Theta(B) = (I - \Theta_1 B - \dots - \Theta_q B^q)$$

a_t = proses white noise rataan nol multivariate berdimensi m

Bila persamaan (2.9) dituliskan kembali ke dalam bentuk moving average, maka akan membentuk :

$$\begin{aligned} Z_t &= \Phi^{-1}(B)\Theta(B)a_t \\ &= \sum_{j=0}^{\infty} \Psi_j a_{t-j} \end{aligned} \quad (2.10)$$

Bila $\Phi_0 = I$, maka dapat dituliskan :

$$\tilde{Z}_{t+i} = \sum_{j=0}^{\infty} \Psi_j a_{t+i-j} \quad (2.11)$$

Diketahui :

$$Z_{t+i}|_t = E [Z_{t+i}|Z_k, k \leq t] \quad (2.12)$$

sehingga dapat dituliskan :

$$\begin{aligned} Z_{t+i}|_{t+1} &= E [Z_{t+i}|Z_k, k \leq t+1] \\ &= \sum_{j=(i-1)}^{\infty} \Psi_j a_{t+i-j} \\ &= \sum_{j=i}^{\infty} \Psi_j a_{t+i-j} + \Psi_{i-1} a_{t+i} \\ &= Z_{t+i}|_t + \Psi_{i-1} a_{t+i} \end{aligned}$$

Jadi :

$$\begin{aligned} Z_{t+i}|_{t+1} &= Z_{t+i}|_t + a_{t+i} \\ Z_{t+i}|_{t+2} &= Z_{t+2}|_t + \Psi_1 a_{t+i} \\ &\vdots \\ Z_{t+p-1}|_{t+1} &= Z_{t+p-1}|_t + \Psi_{p-2} a_{t+i} \\ Z_{t+p}|_{t+1} &= Z_{t+p}|_t + \Psi_{p-1} a_{t+i} \\ &= \Psi_p Z_t|_t + \Psi_{p-1} Z_{t+1}|_t + \dots \\ &\quad + \Psi_1 Z_{t+p-1}|_t + \Psi_{p-1} a_{t+i} \end{aligned}$$

Bila diasumsikan $p > q$ serta menambahkan $\Psi_i = 0$ jika diperlukan maka didapat :

$$\begin{aligned} Z_{t+p}|_t &= \Psi_1 Z_{t+p-1}|_t + \dots + \Psi_p Z_t \\ Z_{t+p+i}|_t &= \Psi_1 Z_{t+p}|_t + \dots + \Psi_p Z_{t+i}|_t \\ &= f(Z_t, Z_{t+1}|_t, \dots, Z_{t+p-1}|_t) \end{aligned}$$

Jadi jelaslah bahwa $Z_{t+p+i}|_t$ untuk $i \geq 0$ adalah fungsi dari

$Z_t, Z_{t+1}|_t, \dots, Z_{t+p+1}|_t$. Dari sini, suatu vektor statenya adalah $(Z_t, Z_{t+1}|_t, \dots, Z_{t+p+1}|_t)$, dan bentuk state space-nya dari model vektor ARMA (p,q) adalah :

$$\begin{bmatrix} Z_{t+1}|_{t+1} \\ Z_{t+2}|_{t+1} \\ \vdots \\ Z_{t+p}|_{t+1} \end{bmatrix} = \begin{bmatrix} 0 & I & 0 & \dots & 0 \\ 0 & 0 & I & \dots & 0 \\ \vdots & \vdots & \vdots & & \vdots \\ \Phi_p & \Phi_{p-1} & \dots & \Phi_1 \end{bmatrix} \begin{bmatrix} Z_t \\ Z_{t+1}|_t \\ \vdots \\ Z_{t+p-1}|_t \end{bmatrix} + \begin{bmatrix} I \\ \Psi_1 \\ \vdots \\ \Psi_{p-1} \end{bmatrix} a_{t+1} \quad (2.13)$$

dan

$$Z_t = [I_m \ 0 \ \dots \ 0] \begin{bmatrix} Z_t \\ Z_{t+1}|_t \\ \vdots \\ Z_{t+p-1}|_t \end{bmatrix} \quad (2.14)$$

2.2.3.2. Bentuk Vektor ARMA dari Model State Space

Diberikan suatu proses Z_t yang mempunyai model state space :

$$Y_{t+1} = A Y_t + G a_{t+1}$$

$$Z_t = H Y_t \quad (2.15)$$

Diasumsikan Y_t adalah vektor state space px1, dan a_t adalah inovasi dari Z_t . Jika polinomial karakteristik dari A yang diberikan oleh $|I - A| = \sum_{i=0}^p \Theta_i A^{p-i}$, dimana $\Theta_0 = 1$, maka dengan teorema Cayley-Hamilton :

$$\sum_{i=0}^p \Theta_i A^{p-i} = 0 \quad (2.16)$$

Dengan melakukan substitusi pada persamaan pertama dari persamaan (2.15) di dapat :

$$\begin{aligned}
 Y_{t+1} &= A_{t+1} Y_t + G_{t+1} \\
 &= A + A Y_{t+1-1} + G a_{t+1-1} + G a_{t+1} \\
 &= A^2 Y_{t+1-2} + A G a_{t+1-1} + G a_{t+1} \\
 &\vdots \\
 &= A^t Y_t + A^{t-1} G a_{t+1} + \dots + G a_{t+1} \quad (2.17)
 \end{aligned}$$

sekarang,

$$\begin{aligned}
 \tilde{z}_{t+p} &= H Y_{t+p} \\
 &= H(A^p Y_t + A^{p-1} + \dots + G a_{t+p}) \\
 O_{t+p-1} \tilde{z}_{t+1} &= H O_1 Y_{t+p-1} \\
 &= H O_1 (A^{p-1} Y_t + A^{p-2} G a_{t+p} + \dots + G a_{t+p-1}) \\
 &\vdots \\
 O_{p-1} \tilde{z}_{t+1} &= H O_{p-1} Y_{t+1} \\
 &= H O_{p-1} (A Y_t + G a_{t+1}) \\
 O_p \tilde{z}_{t+1} &= H O_p Y_t
 \end{aligned}$$

Dari sini \tilde{z}_t mempunyai suatu bentuk ARMA :

$$\begin{aligned}
 &= Z_{t+p} + O_1 Z_{t+p-1} + \dots + O_{p-1} Z_{t+1} + O_p Z_t \\
 &= H (A^p + O_1 A^{p-1} + \dots + O_{p-1} A + O_p I) Y_t + \\
 &\quad + H (A^{p-1} + O_1 A^{p-2} + \dots + O_{p-1} I) G a_{t+1} + \dots + H G a_{t+p} \\
 &= \Theta_O a_{t+p} + \Theta_1 a_{t+p-1} + \dots + \Theta_{p-1} a_{t+1} \quad (2.18)
 \end{aligned}$$

dimana, $H(A^p + O_1 A^{p-1} + \dots + O_{p-1} A + O_p I) Y_t = 0$

dan $\Theta_i = H(A^i + O_1 A^{i-1} + \dots + O_i I) G$.

Jadi secara teoritis, tidak ada perbedaan antara bentuk state space dengan bentuk ARMA dalam suatu proses yang stasioner. Hasil yang di dapat dari model state space dapat digunakan untuk model ARMA, demikian juga sebaliknya. Akan tetapi harus diingat, bahwa kecuali kalau semua komponen vektor state independen secara linier, bilahendak

mengubah dari bentuk state space ke dalam bentuk ARMA akan ada nontrivial common factors di dalam polinomial autoregresif dan moving average. Diketahui model ARMA yang dihasilkan akan mempunyai orde p dan q yang lebih besar dari yang dibutuhkan.

2.3. Identifikasi Model Vektor Time Series

Pada prinsipnya, identifikasi model vektor time series mempunyai bentuk yang serupa dengan identifikasi univariate time series. Bila diberikan suatu vektor time series Z_1, Z_2, \dots, Z_n maka identifikasi model ini ditentukan melalui pola /struktur dari matriks korelasi sampel dan matriks korelasi parsial, setelah suatu transformasi diterapkan untuk meredam ketidakstasioneran data.

2.3.1. Fungsi Matriks korelasi Sampel

Bila diberikan suatu vektor time series dengan n buah observasi Z_1, Z_2, \dots, Z_n maka fungsi matriks korelasi sampelnya adalah :

$$\rho(k) = [\rho_{ij}(k)]$$

dimana $\rho_{ij}(k)$ adalah korelasi silang sampel dari komponen deret ke i,j,

$$\rho_{ij}(k) = \frac{\sum_{t=1}^{n-k} (Z_{it} - \bar{Z}_i)(Z_{j,t+k} - \bar{Z}_j)}{\left[\sum_{t=1}^n (Z_{it} - \bar{Z}_i)^2 \sum_{t=1}^n (Z_{jt} - \bar{Z}_j)^2 \right]^{1/2}} \quad (2.19)$$

Bila Z_t adalah suatu proses yang white noise, maka :

$$\text{Cov}[\rho_{ij}(k), \rho_{ij}(k+\varepsilon)] \approx 1/(n-k) \quad (2.20)$$

$$\text{Var}[\rho(k)] \geq 1/(n-k)$$

Fungsi matriks korelasi sampel sangat berguna didalam menentukan besarnya derajat model moving average. Bila matriks korelasinya bernilai nol setelah lag $k=q$, maka model yang berseuaian adalah MA(q).

2.3.2. Matriks Partial Autoregression

Matrik partial autoregression pada lag s menurut Tiao dan Box , ditandai dengan $P(s)$, sebagai koefisien matriks terakhir bila data ditetapkan sebagai suatu proses vektor autoregresif dengan derajat s . Hal ini merupakan perluasan langsung dari definisi Box dan Jenkins mengenai definiisi fungsi autokorelasi parsial untuk time series univariate. Jadi $P(s)$ sama dengan $\Phi_{s,s}$, dalam regresi linier multivariat.

$$Z_{t+s} = \Phi_{s,1} Z_{t+s-1} + \Phi_{s,2} Z_{t+s-2} + \dots + \Phi_{s,s} Z_t + \epsilon_{s,t+s}$$

dimana $\epsilon_{s,t+s}$ adalah eror, dan koefisien matriks $\Phi_{s,k}$:

$k=1,2,\dots,s$ akan meminimumkan :

$$E[(Z_{t+s} - \Phi_{s,1} Z_{t+s-1} - \dots - \Phi_{s,s} Z_t)^2] \quad (2.21)$$

Minimasi (2.7) akan membawa ke dalam bentuk umum multivariate persamaan Yule Walker sebagai berikut :

$$\begin{bmatrix} \Gamma(0) & \Gamma(1) & \dots & \Gamma(s-1) \\ \Gamma(1) & \Gamma(0) & \dots & \Gamma(s-2) \\ \vdots & \vdots & & \vdots \\ \Gamma(s-1) & \Gamma(s-2) & \dots & \Gamma(0) \end{bmatrix} \begin{bmatrix} \Phi_1 \\ \Phi_2 \\ \vdots \\ \Phi_s \end{bmatrix} = \begin{bmatrix} \Gamma(1) \\ \Gamma(2) \\ \vdots \\ \Gamma(s) \end{bmatrix} \quad (2.22)$$

$P(s)$ ini selanjutnya mengindikasikan model dari vektor AR(p). $P(s)=\Phi_p$ untuk $s=p$; dan $P(s)=0$ untuk $s>p$.

2.3.3. Model Vektor Autoregressif (p)

Model vektor AR(p) mempunyai bentuk :

$$(I - \Phi_1 B - \dots - \Phi_p B^p) Z_t = a_t$$

atau :

$$Z_t = \Phi_1 Z_{t-1} + \dots + \Phi_p Z_{t-p} + a_t \quad (2.23)$$

Proses vektor AR(p) ini selalu invertibel. Agar supaya proses menjadi stasioner maka $|I - \Phi_1 B - \dots - \Phi_p B^p| = 0$ haruslah terletak di luar lingkaran satuan (unit circle), atau dengan kata lain akar dari :

$$|\lambda^p I - \lambda^{p-1} \Phi_1 - \dots - \Phi_p| = 0$$

berada di dalam lingkaran satuan. Proses vektor autoregressif ini dapat ditulis pula dalam bentuk :

$$\begin{aligned} Z &= [\Phi_p(B)]^{-1} a_t \\ &= \sum_{s=0}^{\infty} \Psi_s \hat{a}_{t-s} \end{aligned} \quad (2.24)$$

dimana bobot Ψ_s adalah jumlahan kuadrat dan dapat ditentukan dengan menyamakan koefisien dari B^j dalam persamaan matriks berikut :

$$(I - \Phi_1 B - \dots - \Phi_p B^p) (I + \Psi_1 B + \Psi_2 B^2 + \dots) = I \quad (2.25)$$

sehingga :

$$\begin{aligned} \Psi_1 &= \Phi_1 \\ &\vdots \\ \Psi_j &= \Phi_1 \Psi_{j-1} + \dots + \Phi_p \Psi_{j-p}, \quad j \geq p \end{aligned}$$

Oleh karena :

$$[\Phi_p(B)]^{-1} = \frac{1}{|I - \Phi_p(B)|} \Psi_p^+(B) \quad (2.26)$$

dimana $\Psi_p^+(B) = [\Psi_{ij}^+(B)]$ adalah adjoint matriks dari

$\Phi_p(B)$. Persamaan 2.9, dapat ditulis sebagai :

$$|\Phi_p(B)| Z_t = \Phi_p^+(B) a_t \quad (2.27)$$

Sekarang, $|\Phi_p(B)|$ adalah polinomial dalam B dengan orde mp , dan masing-masing $\Phi_{ij}^+(B)$ adalah polinomial di dalam B dengan orde $(mp.(m-1)p)$. Orde bisa menjadi lebih sedikit jika dijumpai common factor antara polinomial AR dan MA.

2.4. Penetapan Model State space dan Analisa Korelasi Kanonik

Bentuk state space yang diberikan pada pembahasan di atas, jelaslah tidak unik. Sebagai contoh jika diberikan persamaan (2.17) dapat dibentuk vektor state yang baru $V_t = MY_t$ untuk sembarang matriks non singuler M sehingga bentuk statte spacenya adalah :

$$V_{t+1} = A_t V_t + G_1 a_{t+1} \quad (2.28)$$

$$Z_t = H_t V_t \quad (2.29)$$

Dimana $A_1 = MAM^{-1}$, $G_1 = MG$, dan $H_1 = HM^{-1}$. Akan tetapi melalui suatu bentuk kanonik, dapatlah ditentukan suatu solusi tunggal. Di dalam bentuk korelasi kanonik, vektor state secara unik ditentukan melalui analisa korelasi kanonik antara himpunan current and past observations (Z_n, Z_{n-1}, \dots) dan himpunan current and future values ($Z_n, Z_{n+1}|_n, \dots$).

Setelah fungsi peramalan akhir ditentukan arri polinomial AR dalam model AR(p) pendahuluan dan $(Z_n, Z_{n-1}, \dots, Z_{n-p})$ memuat semua informasi penting yang berkaitan dengan future values proses, analisa korelasi kanonik se-

cara sederhana ditentukan antara ruang data :

$$D_n = (Z_n, Z_{n-1}, \dots, Z_{n-p}) \quad (2.30)$$

dan ruang prediktor :

$$F_n = (Z_n, Z_{n+1}|_n, \dots, Z_{n+p}|_n) \quad (2.31)$$

Diberikan suatu matriks blok Hankel untuk kovarians antara D_n dan F_n sebagai berikut :

$$\Gamma = \begin{bmatrix} \Gamma(0) & \Gamma(1) & \dots & \Gamma(p) \\ \Gamma(1) & \Gamma(2) & \dots & \Gamma(p+1) \\ \vdots & \vdots & & \vdots \\ \Gamma(p) & \Gamma(p+1) & \dots & \Gamma(\Sigma p) \end{bmatrix} \quad (2.32)$$

Melalui suatu eksperasi kondisional dapat ditunjukkan bahwa $\text{Cov}(Z_{n-i}, Z_{n+j}|_n) = \text{Cov}(Z_{n-i}, Z_{n+j})$. Bila $\Gamma(0)$ diasumsikan non singular, untuk model vektor ARMA umum rank Γ sama dengan banyaknya korelasi kanonik yang tidak nol antara D_n dan F_n .

Ketika model telah diketahui, pemilihan order p ditentukan dari data yang mempunyai fitting AR optimal. Untuk menentukan order p ini dapat digunakan AIC (Akaike's Information Criterion).

Untuk suatu proses vektor, AIC didefinisikan sebagai : $AIC = n \ln |\Sigma_p| + 2pm^2$
dimana n = banyaknya observasi.

$|\Sigma|$ = determinan matriks kovarians untuk inovasi atau deret white noise dari AR(p) yang ditegaskan.

m = dimensi proses vektor Z_t .

Order p dari model AR yang optimal ditentukan dengan memi-

lih nilai AIC yang minimum. Jadi analisa korelasi kanonik akan didasarkan pada matriks blok Hankel Kovarians sampel sebagai berikut :

$$\hat{\Gamma} = \begin{bmatrix} \hat{\Gamma}(0) & \hat{\Gamma}(1) & \dots & \hat{\Gamma}(p) \\ \hat{\Gamma}(1) & \hat{\Gamma}(2) & \dots & \hat{\Gamma}(p+1) \\ \vdots & \vdots & & \vdots \\ \hat{\Gamma}(p) & \hat{\Gamma}(p+1) & \dots & \hat{\Gamma}(2p) \end{bmatrix} \quad (2.33)$$

Karena komponen-komponen vektor prediksi $Z_{n+i|n}$ kemungkinan dependen linier, analisa korelasi kanonik dilakukan antara semua komponen dari ruang data :

$$D_n = [Z_{1,n}, Z_{2,n}, \dots, Z_{m,n}, Z_{2,n-1}, \dots, Z_{m,n-1}, \dots, Z_{1,n-p}, Z_{2,n-p}, \dots, Z_{m,n-p}]$$

Dengan semua komponen dari :

$$F_n = [Z_{1,n}, Z_{2,n}, \dots, Z_{m,n}, Z_{1,n+1|n}, \dots, Z_{2,n+1|n}, \dots, Z_{m,n+1|n}, \dots, Z_{1,n+p|n}, Z_{2,n+p|n}, \dots, Z_{m,n+p|n}]$$

Vektor state adalah himpunan bagian dari ruang prediktor. Suatu deretan vektor state yang potensial, Y_n ditantukan melalui analisa korelasi kanonik antara deret F_n , sehingga bagian dari F_n dengan ruang data D_n . Analisa ini idasarkan pada sub matriks $\hat{\Gamma}^j$ yang dibentuk dari kolom-kolom $\hat{\Gamma}$ yang berkorespondensi dengan komponen-komponen D_n dan F_n .

Lebih khususnya, oleh karena korelasi kanonik antara $Z_n = [Z_{1,n}, Z_{2,n}, \dots, Z_{m,n}]$ dan D_n adalah $1, \dots, 1$, yang tidak nol, maka vektor statenya disesuaikan dengan Z_n dan himpunan bagian yang pertama dari urutan F_n disesuaikan.

kan dengan $[Z_{1,n}, Z_{2,n}, \dots, Z_{m,n}, Z_{1,n+1}|_n]$. Jika korelasi kanonik terkecil dari F_n^1 ditetapkan sama dengan nol, maka kombinasi linier F_n^1 tidak berkorelasi dengan ruang data D_n . Jadi komponen $Z_{1,n+1}|_n$ dan sembarang $Z_{1,n+1}|_n$ dikeluarkan dari vektor state pada pertimbangan lebih lanjut. Jika korelasi kanonik terkecil tidak sama dengan nol, maka $Z_{1,n+1}|_n$ ditambahkan pada vektor state yang ada.

Untuk setiap tahapan di dalam analisa korelasi kanonik, korelasi kanonik terkecil yang significant, ρ_{\min} didasarkan pada nilai AIC berikut :

$$C = n \ln(1 - \rho_{\min}^2) - 2[m(p+1) - q + 1] \quad (2.34)$$

dimana q adalah dimensi dari F_n pada tahap yang bersesuaian, jika $C < 0$, ρ_{\min} ditetapkan sama dengan nol dan jika sebaliknya maka ditetapkan lebih besar dari nol. Untuk menguji signifikan dari korelasi kanonik p, maka dapat digunakan uji X^2 dengan H_0 : korelasi kanonik adalah nol. Statistik ujinya adalah :

$$X^2 = -(n^{-1/2}[m(p+1) + q + 1]) \ln(1 - \rho^2) \quad (2.35)$$

Distribusi X^2 yang bersesuaian mempunyai derajat bebas $[m(p+1) - q + 1]$.

Bila vektor state telah diidentifikasi, maka bentuk kanonik dari model state spacenya adalah :

$$Y_{t+1} = A Y_t + G a_{t+1} \quad (2.36)$$

$$Z_t = H Y_t \quad (2.37)$$

dimana a_t adalah deret white noise dengan rataan nol dan matriks varians-varians Σ , $N(0, \Sigma)$; dan $H = [I_m, 0]$ dimana I_m adalah matriks identitas mxm.

Matriks taksiran A , G dan Σ dapat ditentukan dari parameter yang diestimasi dari model AR optimal yang ditetapkan. Akan tetapi estimasi yang lebih natural terhadap matriks transisi A dapat ditentukan melalui analisa korelasi kanonik.

Untuk menaksir A , G dan Σ secara lebih efisien dapat prosedur maksimum likelihood. Jika diberikan turunan urutan observasi : Z_1, Z_2, \dots, Z_n ; oleh karena :

$$Y_t = (I - AB)^{-1}G a_t \quad (2.38)$$

maka didapat :

$$Z_t = H(I - AB)^{-1}G a_t \quad (2.39)$$

Jadi fungsi log-likelihood-nya menjadi :

$$\ln L(A, G, \Sigma | Z_1, \dots, Z_n) = -n/2 \ln |\Sigma|^{-1/2} \operatorname{tr} \Sigma^{-1} S(A, A) \quad (2.40)$$

$$\text{dimana : } S(A, G) = \sum_{t=1}^n a_t a_t^* \quad (2.41)$$

Analisa korelasi kanonik menyediakan taksiran initial prosedur penaksiran yang lebih efisien ini. Dalam prosedur penaksirannya nilai A dan G ditetapkan sebagai suatu konstanta, misalnya nol atau satu.

2.5. Pemeriksaan Diagnostik Dan Peramalan

2.5.1. Uji multivariate normal Residual

Salah satu tahapan dalam pemeriksaan diagnostik ini adalah dengan melakukan pengujian terhadap pola distribusi residual model. apabila residual yang bersesuaian ini berdistribusi multinormal hal ini menjamin bahwa data penelitian yang dipakai benar-benar berasal dari proses

yang stasioner.

Berikut ini ada dua prosedur yang digunakan untuk menguji apakah suatu data sampel mempunyai distribusi normal multivariate. Prosedur ini digunakan untuk menghitung dua statistik uji, yang pada dasarnya merupakan ukuran dari multivariate skewness dan multivariate kurtosis dengan hipotesis pengujian :

H_0 : Data berdistribusi multivariate normal

H_1 : Data tidak berdistribusi multivariate normal

Dengan statistik uji :

$$1. b_{1,p} = (1/n^2) \sum_{u=1}^n \sum_{u=1}^n [(X_u - \bar{X})' S^{-1} (X_u - \bar{X})]^3 \quad (2.42)$$

Untuk sampel besar, diuji dengan menggunakan :

$$n b_{1,p} / 6 \sim X_{\alpha,f}^2 \text{ dimana } f = [p(p+1)(p+2)/6]$$

$$2. b_{2,p} = (1/n) \sum_{u=1}^n [(X_u - \bar{X})' S^{-1} (X_u - \bar{X})]^2 \quad (2.43)$$

Untuk sampel besar, diuji dengan menggunakan :

$$(b_{2,p} - p(p-2)/(8p(p+2)/n))^{1/2} \sim N(0,1)$$

Apabila salah satu atau kedua nilai :

$$n b_{1,p} / 6 < X_{\alpha,f}^2 \text{ dan } (b_{2,p} - p(p-2)/(8p(p+2)/n))^{1/2} < Z_{\alpha/2}$$

maka H_0 diterima, yang berarti data berdistribusi multivariat normal, serta dilihat plot (setelah diurutkan) dari nilai-nilai yang didapat dari persamaan di atas membentuk garis lurus maka dapat disimpulkan bahwa multivariate tersebut berdistribusi multivariate normal (Karson, 1982).

2.5.2. Pemeriksaan Residual

Pemeriksaan residual ini dilakukan dengan melakukan

kembali prosedur state space di muka terhadap residualnya.

$$\text{Residual} = \text{Actual} - \text{Forecast}$$

Apabila deret residual ini tidak mempunyai suatu model state space yang jelas/tertentu, maka dapat dijamin bahwa residual ini mempunyai sifat white noise. Dengan demikian model peramalan yang ditetapkan sudah memadai untuk diimplementasikan.

2.5.3. Peramalan

Dalam analisis time series langkah terakhir adalah peramalan. Penggunaan peramalan ini dapat dilaksanakan setelah nilai taksiran model state space.

Penyimpangan adalah suatu selisih dari ramalan (forecasts) yang dibandingkan dengan hasil actual, dengan rumus sebagai berikut:

$$\frac{(\text{Actual} - \text{Forecast})}{\text{Actual}} \times 100 \%$$

BAB III

BAHAN DAN METODOLOGI

BAB III

BAHAN DAN METODOLOGI PENELITIAN

3.1. Bahan Penelitian

3.1.1. Data dan Variabel Penelitian

PT.EURINDO COMBINED adalah salah satu perusahaan yang bergerak dibidang farmasi (obat). Dimana daerah pemasaran PT. EURINDO COMBINED Surabaya mencakup seluruh Jawa Timur sistem penjualannya dilakukan dengan cara pesanan dan promosi ke seluruh rumah sakit di Jawa Timur.

Dalam proses promosi dibagi menjadi tiga team :

1. Team A(mempromosikan obat di seluruh apotik Jawa Timur)
2. Team B(mempromosikan obat di seluruh apotik Jawa Timur)
3. Team Hospital(mempromosikan obat di seluruh rumah sakit Jawa Timur)

Dalam penelitian ini yang akan diramalkan adalah Team Hospital yang mempromosikan obat di seluruh rumah sakit Jawa Timur adapun obat yang dipromosikan adalah sebagai berikut :

1. Flegyl Infusion 100 M adalah jenis obat infeksi yang disebabkan oleh kuman un-aerob yang digunakan via infus
2. Flegyl Suppo 500 Mg adalah jenis obat infeksi yang disebabkan oleh kuman un-aerob yang digunakan via anus.
3. Flegyl Suppo 1 Gr adalah jenis obat infeksi yang disebabkan oleh kuman un-aerob yang digunakan via anus.
4. Peflecine I.V /5 AMP adalah jenis obat infeksi Thypoid

- atau Simpel Lower UTI (Urinary Track Infection).
5. Profined Suppo 100 Mg adalah jenis obat rematik, dan nyeri akut (gejala nyeri, infeksi dan bengkak) via anus.
 6. Profined INJ adalah jenis obat rematik, dan nyeri akut (gejala nyeri, infeksi dan bengkak) via suntik.

Adapun data yang digunakan adalah data sekunder (data penjualan dengan periode pencatatan antara bulan Juli 1991 sampai dengan bulan Juli 1996).

3.1.2. Perangkat Lunak

Untuk keperluan pengolahan data, maka digunakan beberapa program paket statistik. Untuk analisa state space digunakan paket SAS/ETS untuk jenis obat Flegyl Infusion 100 Mg, Flegyl Suppo 500 Mg, Flegyl Suppo 1 Gr pembentukan model pertama, Profined Suppo 100 Mg, Profined INJ untuk model kedua. Sedangkan paket Statgraf digunakan untuk menganalisa/mengolah time series univariate jenis obat Peflecine I.V/5 AMP.

3.2. Metodologi Pengolahan Data

Pada metodologi penelitian ini digunakan untuk menjawab suatu tujuan penelitian, dimana pada model peramalan pertama untuk jenis obat Flegyl infusion 100 Mg, Flegyl Suppo 500 Mg, Flegyl Suppo 1 Gr yang mempunyai korelasi, tetapi dengan penggunaan yang berbeda menggunakan metode State space. pada model peramalan kedua untuk jenis obat Profined Suppo 100 Mg dan Profined INJ juga mempunyai

fungsi yang sama. tetapi penggunaannya yang berbeda. Sedangkan pada jenis obat Peflecine I.V /5 AMP menggunakan Time Series Univariate.

Adapun tahap-tahapnya sebagai berikut :

- Tahap Identifikasi Bentuk Model.
- Tahap Penaksiran
- Tahap Pemeriksaan Diagnostik
- Tahap peramalan
- Tahap Penyimpangan

Tahap Identifikasi Bentuk Model

Tahap Identifikasi Bentuk Model ini dimulai dari mempersiapkan deret input yang berupa data multivariant yang telah berhasil dikumpulkan. Langkah selanjutnya membuat plot data asli dan melihat statistik deskripsi dari variabel yang bersesuaian.

Pokok dari tahap ini adalah menetapkan fungsi matrik autoregresi partial dari deret input. Berdasarkan struktur MACF dan MPACF serta didukung pengamatan terhadap plot data dan statistik deskriptif tersebut, maka akan dapat diidentifikasikan apakah data penelitian berasal dari proses yang stasioner atau belum stasioner, jika data tidak stasioner dalam mean maka dilakukan differencing, sedangkan data tidak stasioner dalam varian maka dilakukan transformasi. Jika data sudah stasioner dapat dilakukan pembentukan model.

Tahap Penaksiran

Dengan didasarkan pada struktur MACF dan MPACF data stasioner serta ditunjang oleh perhitungan AIC, maka dapat diterapkan model ARMA pendahuluan. Model ini adalah model awal karena asumsi kelayakannya belum diuji. akan tetapi dari model ini akan didapatkan nilai dari estimasi.

Tahap Pemeriksaan diagnostik

Pemeriksaan diagnostik ini dilakukan dalam dua bagian. Pertama, pemerikasaan dilakukan terhadap keacakan deret residual yang dihasilkan, atau dengan kata lain apakah data tersebut berdistribusi Multivariate normal. Kedua adalah pemerikasaan yang dilakukan untuk mengamati apakah masih ada korelasi antara residual variabel yang satu dengan residual yang lain.

Tahap Peramalan

Yaitu memasukkan nilai (data ramalan) terhadap model peramalan sampai periode yang diharapkan. Hal ini penting agar peramalan yang diperolehnya dapat mendekati aktualnya.

Tahap Penyimpangan

Yaitu menghitung selisih dari nilai peramalan dengan nilai actual yang kemudian dicari simpangannya.

BAB IV

ANALISIS DAN PEMBAHASAN

BAB IV

ANALISIS DAN PEMBAHASAN

Dalam penelitian ini menggunakan data *Multivariate Time Series*, untuk 6 jenis obat yang dikelompokan menjadi 3 (tiga) kelompok dan akan dibentuk 3 model peramalan.

4.1. Pembentukan Model Peramalan Obat Flegyl Infusion 100 M, Flegyl Suppo 500 M, dan Flegyl Suppo 1 Gr

4.1.1. Identifikasi Model

4.1.1.1. Pemeriksaan Data

Kelompok ke 1 terdiri dari 3 buah variabel, yaitu :

1. Jenis obat Flegyl Infusion 100 M
2. Jenis obat Flegyl Suppo 500 Mg.
3. Jenis obat Flegyl Suppo 1 Gr.

Ke tiga jenis obat tersebut adalah obat infeksi yang disebabkan oleh kuman un-aerob, tetapi cara pemakaiannya yang berbeda. Dari ketiga variabel dapat dilihat nilai deskripsi sebagai berikut :

Tabel 4.1. Deskripsi data asli

Deskripsi	Flegyl Infusion	Flegyl Suppo 500M	Flegyl Suppo 1 Gr
Jumlah data	60	60	60
Rata-rata	979.0833	363.5167	384.7176
Std. dev	275.4447	111.5945	82.55006

Sumber perhitungan

Pada tabel 4.1. diatas tampak bahwa jumlah penjualan obat-obatan rata-ratatertinggi dalam satu bulan adalah jenis obat Flegyl infusion, juga pada variansnya. Sedang untuk penjualan jenis obat-obatan terendah dalam satu bulan adalah jenis obat flegyl Suppo 1 gr. Untuk memeriksa apakah deret data ini stasioner secara multivariate, maka dapat dibuktikan lewat tahap identifikasi model.

4.1.1.2. Identifikasi Model Multivariate Time Series

Pada dasarnya identifikasi model multivariate time-series mempunyai bentuk yang serupa dengan model time series univariate. Identifikasi ini dilakukan dengan mengamati pola fungsi matriks korelasi (MACF) dan fungsi matriks par-sial autoregresi (MPACF) yang berasal dari sampel. Pada tahap ini juga dilakukan pemeriksaan awal data apakah data yang digunakan sudah memenuhi syarat stasioneritas.

Seandainya pola data masih menunjukkan bahwa data berasal dari proses yang tidak stasioner, maka dapat segera dilakukan tindakan perbaikan dengan melakukan kembali transformasi data sedemikian hingga mampu menghilangkan sifat ketidakstasioneran data tersebut. Dengan besar dimensi matriks (3x3) pola korelasi (MACF) data penjualan jenis obat infeksi yang disebabkan oleh kuman un-aerob ini cukup rumit dikenali secara langsung. Untuk menyederhanakan permasalahan maka digunakan simbol +, -, ., yang ditemukan oleh Tiao & Box yang berfungsi untuk menggambarkan matriks korelasi

sampel, dimana tanda (+) artinya berada diatas batas atau ρ tidak sama dengan nol, tanda (-) artinya dibawah batas atau ρ tidak sama dengan nol dan tanda (.) artinya ada pada batas atau ρ sama dengan nol.

Penghitungan matriks korelasi ditetapkan pada lag nol sampai lag sepuluh, maka representasi skematik dari fungsi matriks korelasi deret data asli penjualan obat-obatan jenis Flegyl adalah sebagai berikut :

Tabel 4.2. Tampilan Skematik MACF Deret Data

Name/Lag	0	1	2	3	4	5
Flegyl Infusion	++.
Flegylc Suppo 500M	+++
Flegyl Suppo 1 Mg	.++	..++

Name/Lag	6	7	8	9	10
Flegyl Infusion
Flegylc Suppo 500M
Flegyl Suppo 1 Mg

(+) is > 2xstd error, (-) is < 2xstd error,
(.) is between

sumber perhitungan

Bahwa fungsi korelasi data pejualan obat-obatan di PT. Eurindo Combined ini mempunyai nilai autokorelasi secara positif (lebih besar dari 2x standard error). Nilai autokorelasi terlihat cepat menuju nol hal ini mengindikasikan kan bahwa ada kecenderungan data sudah stasioner secara

multivariate. Adanya nilai autokorelasi yang cepat menuju nol dilihat secara bersama-sama dengan variabel lainnya, dan dapat diduga kemungkinan bahwa deret data berasal dari dari proses autoregresif.

Tabel 4.3. Tampilan Skematik MPACF Deret Data

Name/Lag	0	1	2	3	4	5
Flegyl Infusion
Flegylc Suppo 500M
Flegyl Suppo 1 Mg	...+

Name/Lag	6	7	8	9	10
Flegyl Infusion
Flegylc Suppo 500M
Flegyl Suppo 1 Mg

(+) is > 2xstd error, (-) is < 2xstd error,
 (..) is between

sumber perhitungan

Identifikasi bahwa deret data sudah stasioner karena secara jelas terlihat dengan turunnya nilai korelasi setelah lag kesatu dan akhirnya habis pada lag-lag terakhir. Bahwa MPACF ini memencil pada lag awal (lebih besar dari 2* standard error), kemudian cut-off pada lag-lag selanjutnya. Kenyataan ini memberikan dukungan bahwa model autoregresif multivariate data pejualan obat-obatan PT.Eurindo Combined adalah model AR (1).

4.1.2. Tahap Penaksiran

4.1.2.1. Model Multivariate Autoregresi pendahuluan

Dari pola umum struktur MACF dan MPACF deret input telah diperoleh pada tahap identifikasi dimana terdapat satu lag yang signifikan pada struktur MACF-nya sehingga model AR(1) dapat dianggap sebagai model pendahuluan dari data penjualan obat Flegyl.

Untuk menetapkan derajat p pada model autoregressif ini dapat digunakan nilai AIC (Akaike's Information Criterion), dimana AIC didefinisikan :

$$AIC = n \ln |\Sigma| + 2pm^2$$

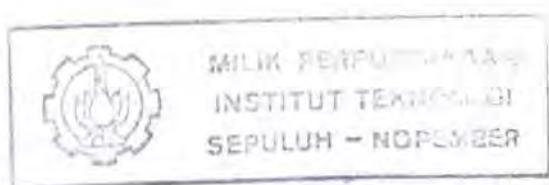
dimana : n = banyaknya observasi

$|\Sigma|$ = determinan matriks kovarians pada lag p

m = dimensi vektor proses Z_t

q = dimensi dari F_n^j

Dari nilai AIC pada lag tertentu yang mempunyai nilai paling kecil (minimum) akan didapatkan derajat p untuk model AR yang optimal. Untuk besar lag antara p = 0 sampai dengan p = 10 nilai AIC untuk model autoregressif penjualan obat Flegyl infusion 100M, Flegyl Suppo 500M, dan Flegyl Suppo 1Gr di PT. Eurindo Combined pada tabel di bawah ini :



Tabel 4.4. Nilai Akaike's Information Criterion Deret Data

Lag	AIC	Lag	AIC
0	1742.510548	6	1782.046581
1	1740.344982	7	1785.790627
2	1750.852727	8	1793.271602
3	1757.387876	9	1799.665013
4	1768.277089	10	1811.403059
5	1774.776520		

sumber perhitungan

Dari Tabel 4.4. ternyata nilai AIC yang paling kecil (minimum) adalah pada lag pertama yaitu sebesar 1740.344982. Jadi dapat disimpulkan bahwa penghitungan AIC sesuai dengan pendahuluan yang diidentifikasi dari struktur MPACF, yaitu model AR(1). Bentuk umum model AR(1) adalah :

$$(1-\Phi B)Z_t = a_t \text{ atau } Z_t = \Phi Z_{t-1} + a_t$$

Taksiran Yule-Walker untuk nilai matriks Φ , adalah :

$$\begin{bmatrix} 0.212 & 0.035 & -0.501 \\ 0.087 & -0.205 & 0.378 \\ -0.048 & 0.061 & 0.308 \end{bmatrix}$$

Dengan mengamati secara terpisah dari vektor white noise a_t dapat dilihat bahwa masing-masing $Z_{t,t}$ tidak hanya memuat lagged values dari $Z_{t,t}$ saja tetapi juga lagged values dari variabel $Z_{j,t}$ yang lain.

Parameter autoregresif yang diestimasi sebenarnya sudah dapat digunakan untuk keperluan forecasting yang didasarkan pada model autoregressif, akan tetapi sesuai de-

ngan tujuan penelitian, model autoregressif ini sebagai landasan yang baik untuk pembentukan model lebih lanjut.

4.1.2.2. Fase Korelasi Kanonik

Dalam fase korelasi kanonik ini merupakan tahap yang penting dalam menentukan solusi tunggal dari model akhir state space yang diharapkan sebelum digunakan dalam peramalan. Pada fase ini vektor state space secara tunggal ditentukan melalui analisa korelasi kanonik antara himpunan ruang data (past observations) dan ruang prediktor (future values).

Dari model autoregresif pendahuluan AR(1) telah ditetapkan besarnya derajat p adalah satu, sebagai implikasinya analisa korelasi kanonik ini akan didasarkan pada matriks blok Hankel untuk kovarians sampel adalah sebagai berikut :

$$\Gamma = \begin{bmatrix} \Gamma(0) & \Gamma(1) \\ \Gamma(1) & \Gamma(2) \end{bmatrix}$$

Berdasarkan pada p=1 ini maka analisa korelasi kanonik dapat diterapkan antara ruang data $D = \{Z_n, Z_{n-1}\}$ dan ruang prediktor $F = \{Z_n, Z_{n+2}|_n\}$. Akan tetapi meskipun $\{Z_{n+1}|_n\}$ ini potensial dalam vektor state, masih harus dilakukan pengujian apakah $\{Z_{n+1}|_n\}$ layak diperhitungkan dalam final state vektor. Secara keseluruhan analisa korelasi kanonik ini dapat dilihat pada tabel di bawah ini :

Tabel 4.5. Tabel Analisa Korelasi Kanonik

State Vektor	Correlations	Infor.	Chi ²	D.F
FT(T;T), FS(T;T), FI(T;T), FI(T+1;T)	1.00 1.00 1.00 0.1098	-5.27185	0.709946	3
FI(T;T), FS(T;T) FI(T;T), FS(T+1;T)	1.00 1.00 1.00 0.0557	-5.8133	0.182034	3
FI(T;T), FS(T;T) FI(T;T), FI(T+1;T)	1.00 1.00 1.00 0.2801	-1.09853	4.778929	3

sumber perhitungan

Pada saat $Z_{1,t+1|t}$ Flegyl Infusion(T+1;T) dimasukkan kedalam vektor state diperoleh nilai korelasi kanoniknya sebesar 0.3418 dan kriteria informasinya sama dengan :

$$\begin{aligned} AIC &= -60 \ln(1-(0.1098)^2) - 2(3(1+1)-5+1) \\ &= -5.27185 \end{aligned}$$

Nilai AIC 0.07743 dan uji χ^2 dari Bartlet dimana statistik uji $\chi^2 = 0.709946 < \chi^2_{0.05(3)} = 7.81$, jadi $Y_{1,t+1|t}$ tidak dimasukkan ke dalam vektor state.

Pada saat $Z_{2,t+1|t}$ Flegyl Suppo 500Mg(T+1;T) dimasukkan kedalam vektor state diperoleh nilai korelasi kanoniknya sebesar 0.0557 dan kriteria informasinya adalah -5.8133.

Nilai AIC -5.8133 dan uji χ^2 dari Bartlet dimana statistik uji $\chi^2 = 0.182034 < \chi^2_{0.05(3)} = 7.81$, Jadi $Y_{2,t+1|t}$ tidak dimasukkan ke dalam vektor state.

Dengan demikian final state vektornya adalah :

$$\begin{bmatrix} FI_{t+1} \\ FS_{t+1} \\ F1_{t+1} \end{bmatrix} = \begin{bmatrix} Flegyl Infusion (T;T) \\ Flegyl Suppo 500 Mg(T;T) \\ Flegyl Suppo 1 Mg(T;T) \end{bmatrix}$$

4.1.2.3. Estimasi Parameter

Tahap selanjutnya setelah ditetapkan final vektor spacenya, maka dilakukan estimasi parameter dari model state spacenya. Hasil yang diperoleh yaitu : bentuk umum state space untuk data pemakaian bahan baku ini adalah sebagai berikut :

$$\begin{bmatrix} FI_{t+1} \\ FS_{t+1} \\ F1_{t+1} \end{bmatrix} = A \begin{bmatrix} FI_t \\ FS_t \\ F1_t \end{bmatrix} + G \begin{bmatrix} a_{1,t+1} \\ a_{2,t+1} \\ a_{3,t+1} \end{bmatrix}$$

Dimana $[a_{1,t+1} \ a_{2,t+1} \ a_{3,t+1}]$ adalah vektor white noise yang berdistribusi $\approx N(0, \Sigma)$. A = matriks transisi.

G = matriks input inovasi. Elemen matriks transisi, matriks input untuk inovasi serta matriks varians untuk inovasi adalah sebagai berikut :

$$A = \begin{bmatrix} 0.212 & 0.000 & 0.251 \\ 0.087 & -0.205 & 0.378 \\ 0.000 & 0.000 & 0.308 \end{bmatrix}.$$

$$G = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}$$

$$\Sigma = \begin{bmatrix} 71344.7082 & 14073.4647 & 4600.8084 \\ 14073.4647 & 11291.1707 & 3602.72754 \\ 4600.80840 & 3602.72754 & 5971.46753 \end{bmatrix}$$

Secara keseluruhan estimasi parameter ini tertera dalam tabel dibawah ini :

Tabel 4.6. Estimasi parameter model state space pendahuluan

Parameter	Estimate	Std. Error	T value
F(1,1)	0.211784	0.14089	1.503193
F(1,2)	0.035035	0.380571	0.092059
F(1,3)	-0.50087	0.461024	-1.08642
F(2,1)	0.087466	0.056086	1.559507
F(2,2)	-0.20518	0.151877	-1.35095
F(2,3)	0.378432	0.184182	2.054666
F(3,1)	-0.04816	0.040819	-1.1798
F(3,2)	0.061478	0.110665	0.555531
F(3,3)	0.307865	0.134241	2.293379

sunber perhitungan

Nilai-nilai parameter tersebut pada tabel 4.6 baru merupakan taksiran parameter awal dari model state space. Untuk mengetahui apakah parameter-parameter tersebut layak dipertahankan dalam model, maka perlu dilakukan pengujian, yaitu dengan statistik uji t untuk setiap taksiran parameter yang dapat dilihat dari tabel 4.6.

Pengujian parameter ini dilakukan terlebih dahulu terhadap parameter yang mempunyai harga mutlak statistik ujinya yang paling kecil dalam hal ini pada parameter F(1,2), dimana nilai $|t| = |0.092059|$.

Dengan melakukan hipotesa :

$H_0 = F(1,2) = 0$, Pengaruh Flegyl Suppo 500 M saat ini pada Flegyl Infusion satu periode yang akan datang tidak bermakna.

$H_1 = F(1,2) \neq 0$. Pengaruh Flegyl Suppo 500 M saat ini pada Flegyl Infusion satu periode yang akan datang bermakna

dan t tabel = $t_{(0.025;60)} = 1.96$.

Karena $|t \text{ hitung}| < t \text{ tabel}$, maka disimpulkan bahwa H_0 tidak ditolak, yang berarti parameter $F(1,2)$ tidak layak dimasukkan dalam model. Demikian seterusnya dengan cara yang sama pengujian terus dilakukan terhadap parameter yang lain sampai didapatkan semua nilai parameter yang signifikan.

Adapun hasil akhir dari taksiran parameter, setelah dilakukan penaksiran yang berulang-ulang hasilnya adalah sebagai berikut :

Tabel 4.7. Estimasi parameter model state space akhir

Parameter	Estimate	Std. Error	T value
$F(1,1)$	0.227405	0.123424	1.842464
$F(2,1)$	0.112941	0.049469	2.283057
$F(2,2)$	-0.24022	0.122101	-1.96734
$F(2,3)$	0.486494	0.15854	3.049663
$F(3,3)$	0.353349	0.119223	2.963765

sumber perhitungan

Dengan demikian model state space akhir adalah :

$$\begin{bmatrix} FI_{t+1} \\ FS_{t+1} \\ F1_{t+1} \end{bmatrix} = A \begin{bmatrix} FI_t \\ FS_t \\ F1_t \end{bmatrix} + G \begin{bmatrix} a_{1,t+1} \\ a_{2,t+1} \\ a_{3,t+1} \end{bmatrix}$$

dimana nilai A, G dan varians Σ adalah sebagai berikut :

$$A = \begin{bmatrix} 0.277 & 0.000 & 0.000 \\ 0.133 & -0.240 & 0.483 \\ 0.000 & 0.000 & 0.353 \end{bmatrix}$$

$$G = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}$$

$$\Sigma = \begin{bmatrix} 72981.6523 & 14417.8293 & 4751.56165 \\ 144417.8293 & 11393.2063 & 3696.74794 \\ 4751.56165 & 3696.74794 & 6116.54023 \end{bmatrix}$$

Dapat dijabarkan sebagai berikut :

$$FI_{t+1} = 0.227 FI_t + a_{1,t+1}$$

$$FS_{t+1} = 0.133 FI_t - 0.240 FS_t + 0.483 F1_t + a_{2,t+1}$$

$$F1_{t+1} = 0.353 F1_t + a_{3,t+1}$$

maksudnya :

- FI(Flegyl Infusion) akan datang dipengaruhi oleh Flegyl Infusion saat ini sebesar 0.227 dan error $a_{1,t+1}$
- FS (Flegyl Suppo 500M) akan datang dipengaruhi oleh FI (Flegyl Infusion) saat ini sebesar 0.133 dan ada penurunan FS(Flegyl Suppo 500) sebesar -0.240 serta ada

- peningkatan untuk F_1 (Flegyl Suppo 1Gr) sebesar 0.483 dan error $\epsilon_{2,t+1}$
- F_1 (Flegyl Suppo 1Gr) yang akan datang dipengaruhi oleh F_1 (Flegyl Suppo 1Gr) saat ini sebesar 0.353 dan error $\epsilon_{3,t+1}$

4.1.3. Tahap Pemeriksaan Model

Setelah didapatkan taksiran nilai - nilai parameter model state spacenya, maka tahap berikutnya adalah pemeriksaan diagnostik yang ditujukan untuk membuktikan bahwa model tersebut cukup memadai. Pemeriksaan diagnostik dilakukan dengan mengamati pola dari residualnya apakah memenuhi pola distribusi normal $N(0, \Sigma)$ dan apakah residualnya memenuhi syarat white noise atau masih terdapat beberapa pola yang belum diperhitungkan.

4.1.3.1. Pengujian Residual

Untuk menguji apakah residual dari model mempunyai distribusi normal multivariate atau tidak, digunakan dua statistik uji dengan hipotesa :

H_0 = Data berdistribusi multivariat normal

H_1 = Data tidak berdistribusi multivariat normal

1. Pengamatan terhadap multivariat skewness data residual.
dari perhitungan didapat :

$$\text{Statistik Uji } B_1 = (n/6)b_{1,p}$$

$$X^2_{\text{hit}} = 6.340'766 < X^2_{(0.05,\infty)} = 26.2926$$

2. Pengamatan terhadap multivariat kurtosis data residual,
dari perhitungan didapat :

$$\text{Statistik Uji } |B_2| = (b_{2,p} - p(p+2))/(8p(p+2)/n)^{1/2}$$

$$\text{Normal}_{\text{hit}} = 1.7013446 < 1.96$$

Dari kedua uji tersebut maka dapat disimpulkan bahwa residual model memang mempunyai distribusi normal multivariat, dan didukung pula oleh plot yang mendekati garis lurus (pada gambar lampiran ..) maka dapat disimpulkan bahwa residual model mempunyai distribusi multivariat normal. Dengan dipenuhinya syarat kenormalan tersebut berarti juga mendukung bahwa data yang digunakan untuk menganalisis penjualan jenis obat flegyl telah stasioner.

4.1.3.2. Pemeriksaan Model Residual

Pemeriksaan residual model ini dilakukan dengan menggunakan cara yang sama dengan cara pembentukan model state space. Setelah fungsi matriks korelasi (MACF) dihitung, maka didapatkan representasi skematik dari korelasi seperti yang tertera dibawah ini :

Tabel 4.8. Representasi Skematik MACF Residual

Name/Lag	0	1	2	3	4	5
Residual 1	++.
Residual 2	+++
Residual 3	+++

Name/Lag	6	7	8	9	10
Residual 1
Residual 2
Residual 3
+ is > 2* std error, - is < 2* std error . is between					

sumber perhitungan

Dari tabel 4.8 dapat terlihat bahwa fungsi matrik autokorelasi ini hanya signifikan pada lag nol, sedangkan perhitungan fungsi matriks parsial autoregresif diperoleh bahwa fungsi ini pada semua lag tidak significant seperti yang terlihat pada tabel 4.9 jadi dapat dikatakan bahwa residual tersebut sudah memenuhi sifat white noise.

Tabel 4.9. Tampilan Skematik MPACF Residual

Name/Lag	1	2	3	4	5
Residual 1
Residual 2
Residual 3

Name/Lag	7	8	9	10	10
Residual 1
Residual 2
Residual 3
+ is > 2* std error, - is < 2* std error . is between					

sumber perhitungan

Langkah selanjutnya adalah menghitung nilai AIC, dimana hasil perhitungannya untuk memperkuat kesimpulan diatas dalam tabel 4.10 dapat dilihat nilai minimum didapat pada lag p=0.

Tabel 4.10. Nilai AIC Deret Data

Lag	AIC
0	1723.568166
1	1738.886687
2	1750.341930
3	1755.361129
4	1765.629507
5	1773.734478

Sumber perhitungan

Lag	AIC
6	1781.377657
7	1783.625004
8	1794.321673
9	1800.106222
10	1807.455878

Karena derajat p = 0 maka matriks transisi A pada model state spacenya akan mempunyai nilai nol juga di semua elemenya.

4.2.4. Pembahasan Fitted Model State Space dan Peramalan

Dari hasil persamaan model yang didapat di interpre tasikan sebagai berikut :

FI_{t+1} adalah jumlah penjualan flegyl infusion pada waktu t+1. Pada penjualan jenis obat flegyl infusion pada bulan yang akan datang dipengaruhi oleh jumlah penjualan jenis obat flegyl infusion, serta ada peningkatan jumlah penjual

an sebesar 0.227.

FS_{t+1} adalah jumlah penjualan Flegyl Suppo 500 M pada waktu $t+1$. Pada penjualan jenis obat flegyl Suppo 500M pada bulan yang akan datang dipengaruhi oleh jumlah penjualan jenis obat flegyl infusion, serta ada peningkatan jumlah penjualan sebesar 0,133, dan ada penurunan untuk jenis obat Flegyl Suppo 500 M, sebesar 0.240 serta dipengaruhi oleh jenis obat flegyl Suppo 1 Gr dengan kenaikan sebesar 0.483.

$F1_{t+1}$ adalah jumlah penjualan jenis obat Flegyl Suppo 1 Gr pada waktu bulan ke $t+1$. Pada penjualan jenis obat Flegyl Suppo 1 Gr yang akan datang ada kenaikan sebesar 0.353.

Hasil Peramalan yang diberikan oleh model state space untuk jenis obat Flegyl Infusion, Flegyl Suppo 500 M, dan Flegyl Suppo 1 Gr untuk lima bulan yang akan datang adalah sebagai berikut :

Tabel 4.11 Nilai peramalan penjualan obat-obatan

Obs	Flegyl Infusion	Flegyl Suppo 500 M	Flegyl Suppo 1 Gr
1	984.66	365.897	315.914
2	975.72	355.013	360.405
3	973.68	354.102	376.126
4	973.22	361.692	381.681
5	973.11	362.503	383.644

Sumber: perhitungan

4.2. Pembentukan Model Peramalan obat Profined Suppo 100 Mg dan Profined INJ

4.2.1. Identifikasi Model

4.2.1.1. Pemeriksaan Data

Kelompok ke 2 terdiri dari 3 buah variabel, yaitu :

1. Jenis obat Profined Suppo 100 Mg
2. Jenis obat Profined INJ.

Dari kedua variabel dapat dilihat nilai deskripsi sebagai berikut :

Tabel 4.12. Deskripsi data asli

Deskripsi	Profined Suppo 100	Profined INJ
Jumlah Data	60	60
Rata-rata	1181	385.2334
Std. dev	973.4667	275.1328

Sumber perhitungan

Pada tabel deskripsi diatas tampak bahwa jumlah penjualan obat-obatan rata-rata tertinggi dalam satu bulan adalah jenis obat Profined Suppo 100 Mg, juga pada variansnya. Sedang untuk penjualan jenis obat-obatan terendah dalam satu bulan adalah jenis obat Profined INJ. Untuk memeriksa apakah deret data ini stasioner secara multivariat maka dapat dibuktikan lewat tahap identifikasi model.

4.2.1.2. Identifikasi Model Multivariate Time Series

Identifikasi ini dilakukan dengan mengamati pola fungsi matriks korelasi (MACF) dan fungsi matriks parsial autoregresi (MPACF) yang berasal dari sampel. Pada tahap

ini juga dilakukan pemeriksaan awal data apakah data yang digunakan sudah memenuhi syarat stasioneritas.

Penghitungan matriks korelasi ditetapkan pada lag nol sampai lag sepuluh, maka representasi skematik dari fungsi matriks korelasi deret data asli penjualan obat-obatan jenis Flegyl adalah sebagai berikut :

Tabel 4.13. Tampilan Skematik MACF Deret Data

Name/Lag	0	1	2	3	4	5
Profined Suppo 100	++	+. .	+. .	+. .	+. .	+. .
Profined INJ	++	+.

Name/Lag	6	7	8	9	10
Profined Suppo 100	+. .	+. .	+.
Profined INJ	+.

sumber perhitungan

Dari tampilan skematik diatas, dapat dilihat bahwa fungsi autokorelasi data penjualan obat Profined Suppo 100 dan Profined INJ di PT. Eurindo Combined ini mempunyai nilai autokorelasi (lebih besar dari $2 \times$ standard error). Nilai auto kerelasi terlihat cepat menuju nol hal ini mengindikasikan bahwa ada kecenderungan data sudah stasioner secara multivariate. Adanya Nilai autokorelasi yang lambat menuju nol dilihat secara bersama-sama dengan variabel lainnya, dan dapat diduga kemungkinan bahwa deret data berasal dari proses autoregresif.

Tabel 4.14. Tampilan Skematik MPACF Deret Data

Name/Lag	0	1	2	3	4	5
Profined Suppo 100	++	+	..	+
Profined INJ	++

Name/Lag	6	7	8	9	10
Profined Suppo 100
Profined INJ

(+) is $> 2 \times \text{std error}$, (-) is $< 2 \times \text{std error}$,
 (..) is between

sumber perhitungan

Identifikasi bahwa deret data sudah stasioner karena secara jelas terlihat dengan turunnya nilai korelasi setelah lag kesatu dan akhirnya habis pada lag-lag terakhir. Bahwa MPACF ini memencil pada lag awal (lebih besar dari $2 \times$ standard error), kemudian cut-off pada lag-lag selanjutnya. Kenyataan ini memberikan dukungan bahwa model autoregresif multivariate data penjualan obat Profined Suppo 100 dan Profined INJ di PT. Eurindo Combined adalah Model AR (1).

4.2.2. Tahap Penaksiran

4.2.2.1. Model Multivariate Autoregresi pendahuluan

Dari pola umum struktur MACF dan MPACF deret input telah diperoleh pada tahap identifikasi dimana terdapat satu lag yang signifikan pada struktur MACF-nya sehingga model AR(1) dapat dianggap sebagai model pendahuluan dari data penjualan obat Profined.

Untuk menetapkan derajat p pada model autoregressif ini dapat digunakan nilai AIC (Akaike's Information Criterion).

Dari nilai AIC pada lag tertentu yang mempunyai nilai paling kecil (minimum) akan didapatkan derajat p untuk model AR yang optimal. Untuk besar lag antara p = 0 sampai dengan p = 10 nilai AIC untuk model autoregressif penjualan obat-obatan di PT. Eurindo Combined pada tabel di bawah ini :

Tabel 4.15. Nilai Akaike's Information Criterion Deret Data

Lag	AIC	Lag	AIC
0	1383.430123	6	1387.787840
1	1362.621511	7	1392.416895
2	1366.316960	8	1394.749129
3	1367.487897	9	1396.04840
4	1374.870844	10	1402.085305
5	1381.085305		

sumber perhitungan

Dari Tabel 4.15. ternyata nilai AIC yang paling kecil (minimum) adalah pada lag pertama yaitu sebesar 1362.62151 jadi dapat disimpulkan bahwa penghitungan AIC sesuai dengan pendahuluan yang diidentifikasi dari struktur MPACF yaitu model AR(1), bentuk umum model AR(1) adalah :

$$(1-\Phi B)Z_t = a_t \text{ atau } Z_t = \Phi Z_{t-1} + a_t$$

Taksiran Yule-Walker untuk nilai matriks Φ_1 adalah :

$$\begin{bmatrix} 0.590 & 0.012 \\ 0.209 & 0.094 \end{bmatrix}$$

Dengan mengamati secara terpisah dari vektor white noise a_t dapat dilihat bahwa masing-masing $Z_{i,t}$ tidak hanya memuat lagged values dari $Z_{i,t}$ saja tetapi juga lagged values dari variabel $Z_{j,t}$ yang lain.

Parameter autoregresif yang diestimasi sebenarnya sudah dapat digunakan untuk keperluan forecasting yang didasarkan pada model autoregressif, akan tetapi sesuai dengan tujuan penelitian, model autoregressif ini sebagai landasan yang baik untuk pembentukan model lebih lanjut.

4.2.2.2. Fase Korelasi Kanonik

Dalam fase korelasi kanonik ini merupakan tahap yang penting dalam menentukan solusi tunggal dari model akhir state space yang diharapkan sebelum digunakan dalam peramalan. Pada fase ini vektor state space secara tunggal ditentukan melalui analisa korelasi kanonik antara himpunan ruang data (past observations) dan ruang prediktor (future values).

Dari model autoregresif pendahuluan AR(1) telah ditetapkan besarnya derajat p adalah satu, sebagai implikasinya analisa korelasi kanonik ini akan didasarkan pada matriks blok Hankel untuk kovarians sampel adalah sebagai

berikut :

$$\Gamma = \begin{bmatrix} \Gamma(0) & \Gamma(1) \\ \Gamma(1) & \Gamma(2) \end{bmatrix}$$

Berdasarkan pada $p=1$ ini maka analisa korelasi kanonik dapat diterapkan antara ruang data $D = \{Z_n, Z_{n+1}\}$ dan ruang prediktor $F = \{Z_n, Z_{n+2}\}_n$. Akan tetapi meskipun $\{Z_{n+1}\}_n$ ini potensial dalam vektor state, masih harus dilakukan pengujian apakah $\{Z_{n+1}\}_n$ layak diperhitungkan dalam final state vektor. Secara keseluruhan analisa korelasi kanonik ini dapat dilihat pada tabel di bawah ini :

Tabel 4.16. Tabel Analisa Korelasi Kanonik

State Vektor	Correlations	Infor.	chi ²	D. F
PS(T;T), PI(T;T), PS(T+1;T)	1.00 1.00 1.00 0.2464	-0.2259	0.371194	2
PS(T;T), PI(T;T) PI(T+1;T)	1.00 1.00 1.00 0.1139	-3.2167	0.770247	2

Sumber perhitungan

Pada saat $Z_{t,t+1}|_t$ Profenid Suppo (T+1;T) dimasukkan kedalam vektor state diperoleh nilai korelasi kanoniknya sebesar 0.2469 dan kriteria informasinya sama dengan :

$$AIC = -60 \ln(1-(0.2469)^2) + 2(2(1+1)-5+1) \\ = -0.2259$$

Nilai AIC = -0.2259 dan uji χ^2 dari Bartlett dimana statistik uji $\chi^2 = 0.371194 < \chi^2_{0.05(2)} = 5.99$ jadi $Z_{t,t+1}|_t$ tidak dimasukkan ke dalam vektor state.

Pada saat $z_{2,t+1|t}$ Profenid Ind (T+1:T) dimasukkan kedalam vektor state diperoleh nilai korelasi kanonik nya sebesar 0,0557 dan kriteria informasinya adalah -5,8133. Nilai AIC -5,8133 dan uji χ^2 dari Bartlett dimana statistik uji $\chi^2 = 0,770247 < \chi^2_{0.05(2)} = 5,99$. Jadi $Y_{2,t+1|t}$ tidak dimasukkan ke dalam vektor state. Dengan demikian final state vektornya adalah :

$$\begin{bmatrix} PS_{t+1} \\ PI_{t+1} \end{bmatrix} = \begin{bmatrix} \text{Profined Suppo 100mg(T;T)} \\ \text{Profined INJ(T;T)} \end{bmatrix}$$

4.3.2.3. Estimasi Parameter

Tahap selanjutnya setelah ditetapkan final vektor spacennya, maka dilakukan estimasi parameter dari model state spacennya. Hasil yang diperoleh yaitu :

obatan ini adalah :

$$\begin{bmatrix} PS_{t+1} \\ PI_{t+1} \end{bmatrix} = A \begin{bmatrix} PS_t \\ PI_t \end{bmatrix} + G \begin{bmatrix} a_{1,t+1} \\ a_{2,t+1} \end{bmatrix}$$

dimana $[a_{1,t+1} \ a_{2,t+1} \ a_{3,t+1}]$ adalah vektor white noise Bentuk umum state space untuk data penjualan Profined Suppo 100 Mg dan Profined INJ yang berdistribusi $\approx N(0, \Sigma)$, A = matriks transisi, G = matriks input inovasi. Elemen matriks transisi, matriks input untuk inovasi serta matrik varians untuk inovasi adalah sebagai berikut :

$$A = \begin{bmatrix} 0.590 & 0.012 \\ 0.209 & 0.094 \end{bmatrix}$$

$$G = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$$

$$\Sigma = \begin{bmatrix} 96322.3245 & 10092.9982 \\ 10092.9982 & 67332.6971 \end{bmatrix}$$

Secara keseluruhan estimasi parameter ini tertera dalam tabel dibawah ini :

Tabel 4.17. Estimasi parameter model state space pendahuluan

Parameter	Estimate	Std. Error	T value
F(1,1)	0.589939	0.108414	5.441523
F(1,2)	0.011843	0.151751	0.078041
F(2,1)	0.209414	0.090654	2.310028
F(2,2)	0.093884	0.126903	0.739807

sumber perhitungan

Nilai-nilai parameter tersebut pada tabel 4.17. maka perlu dilakukan pengujian, yaitu dengan statistik uji t untuk setiap taksiran parameter yang dapat dilihat dari tabel 4.17.

Pengujian parameter ini dilakukan terlebih dahulu terhadap parameter yang mempunyai harga mutlak statistik ujinya yang paling kecil dalam hal ini pada parameter F(1,2), dimana nilai $|t| = |0.078041|$.

Dengan melakukan hipotesa :

$H_0 : F(1,2) = 0$, pengaruh antara profined INJ pada waktu yang akan datang dengan profined Suppo

bermakna.

$H_1 = F(1,2) = 0$. Pengaruh Profined Suppo 100 M saat ini pada Profined INJ yang akan datang bermakna.

dan t tabel = $t_{(0.025;60)} = 1.96$.

Karena $|t \text{ hitung}| < t \text{ tabel}$, maka disimpulkan bahwa H_0 tidak ditolak, yang berarti parameter $F(1,2)$ tidak layak dimasukkan dalam model. Demikian seterusnya dengan cara yang sama pengujian terus dilakukan terhadap parameter yang lain sampai didapatkan semua nilai parameter yang signifikan.

Adapun hasil akhir dari taksiran parameter. setelah dilakukan penaksiran yang berulang-ulang hasilnya adalah sebagai berikut :

Tabel 4.18. Estimasi parameter model state space akhir

Parameter	Estimate	Std. Error	T value
$F(1,1)$	0.592354	0.103925	5.699821
$F(2,1)$	0.228559	0.087289	2.618418

rumus perhitungan

Dengan demikian model state space akhir adalah :

$$\begin{bmatrix} PS_{t+1} \\ PI_{t+1} \end{bmatrix} = A \begin{bmatrix} PS_t \\ PI_t \end{bmatrix} + G \begin{bmatrix} a_{1,t+1} \\ a_{2,t+1} \end{bmatrix}$$

dimana nilai A, G dan varians Σ adalah sebagai berikut :

$$A = \begin{bmatrix} 0.592 & 0.000 \\ 0.229 & 0.000 \end{bmatrix}$$

$$G = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$$

$$\Sigma = \begin{bmatrix} 96332.0757 & 10170.3016 \\ 10170.3016 & 67945.5236 \end{bmatrix}$$

Dapat dijabarkan sebagai berikut :

$$PS_{t+1} = 0.592 PS_t + \epsilon_{1,t+1}$$

$$PI_{t+1} = 0.229 PI_t + \epsilon_{2,t+1}$$

artinya :

- PS (Profined Suppo 100) akan datang dipengaruhi oleh Profined Suppo 100 saat ini sebesar 0.592 dan error $\epsilon_{1,t+1}$.
- PI (Profined INJ) akan datang dipengaruhi oleh profined INJ saat ini sebesar 0.229

4.2.3. Tahap Pemeriksaan Model

Setelah didapatkan taksiran nilai - nilai parameter model state spacenya, maka tahap berikutnya adalah pemeriksaan diagnostik yang ditujukan untuk membuktikan bahwa model tersebut cukup memadai. Pemeriksaan diagnostik dilakukan dengan mengamati pola dari residualnya apakah memenuhi pola distribusi normal $N(0, \Sigma)$ dan apakah residualnya memenuhi syarat white noise atau masih terdapat beberapa pola yang belum diperhitungkan.

4.2.3.1. Pengujian Residual

Untuk menguji apakah residual dari model mempunyai distribusi normal multivariat atau tidak, digunakan dua statistik uji dengan hipotesa :

H_0 = Data berdistribusi multivariat normal

H_1 = Data tidak berdistribusi multivariat normal

1. Pengamatan terhadap multivariat skewness data residual, dari perhitungan didapat :

Statistik Uji $B_1 = (n/6)b_{1,p}$

$$X^2_{hit} = 4.221090 < X^2_{(0.05,60)} = 26.2926$$

2. Pengamatan terhadap multivariat kurtosis data residual, dari perhitungan didapat :

Statistik Uji $|B_2| = (b_{2,p} - p(p+2))/(8p(p+2)/n)^{1/2}$

$$\text{Normal}_{hit} = 1.210986 < 1.96$$

Dari kedua uji tersebut maka dapat disimpulkan bahwa residual model memang mempunyai distribusi normal multivariat, dan didukung pula oleh plot yang mendekati garis lurus (pada gambar lampiran ..) maka dapat disimpulkan bahwa residual model mempunyai distribusi multivariat normal. Dengan dipenuhinya syarat kenormalan tersebut berarti juga mendukung bahwa data yang digunakan untuk menganalisis penjualan jenis obat flegyl telah stasioner.

4.2.3.2. Pemeriksaan Model Residual

Pemeriksaan residual model ini dilakukan dengan menggunakan cara yang sama dengan cara pembentukan model

state space. Setelah fungsi matriks korelasi (MACF) dihitung, maka didapatkan representasi skematik dari korelasi seperti yang tertera dibawah ini :

Tabel 4.19. Tampilan Skematik MACF Residual

Name/Lag	0	1	2	3	4	5
Residual 1	+
Residual 2	+

Name/Lag	6	7	8	9	10
Residual 1
Residual 2

+ is > 2* std error, - is < 2* std error
. is between

sumber perhitungan -

Dari tabel 4.19 dapat terlihat bahwa fungsi matrik autokorelasi ini hanya signifikan pada lag nol, sedangkan perhitungan fungsi matriks parsial autoregresif diperoleh bahwa fungsi ini pada semua lag tidak signifikan seperti yang terlihat pada tabel 4.19 jadi dapat dikatakan bahwa residual tersebut sudah memenuhi sifat white noise.

Tabel 4.20. Tampilan Skematik MPACF Residual

Name/Lag	0	1	2	3	4	5
Residual 1
Residual 2

Name/Lag	6	7	8	9	10
Residual 1
Residual 2
+ is > 2* std error, - is < 2* std error .is between					

sumber perhitungan

Langkah selanjutnya adalah menghitung nilai AIC, dimana hasil perhitungannya untuk memperkuat kesimpulan diatas dalam tabel 4.10 dapat dilihat nilai minimum didapat pada lag p=0.

Tabel 4.21. Nilai AIC Deret Data

Lag	AIC
0	1354.625345
1	1360.120585
2	1366.186214
3	1367.644144
4	1373.575514
5	1380.828583

sumber perhitungan

Lag	AIC
6	1387.446750
7	1392.152002
8	1397.590971
9	1395.648267
10	1399.695671

Karena derajat p = 0 maka matriks transisi A pada model state spacenya akan mempunyai nilai nol juga di semua elemenya.

4.2.4. Pembahasan Fitted Model State Space dan Peramalan

Dari hasil persamaan model yang didapat di interpre tasikan sebagai berikut :

PS_{t+1} adalah jumlah penjualan Profined Suppo pada waktu $t+1$. Pada penjualan jenis obat Profined Suppo pada bulan yang akan datang dipengaruhi oleh jumlah penjualan jenis obat Profined Suppo, serta ada peningkatan jumlah penjualan sebesar 0,592.

PI_{t+1} adalah jenis penjualan Profined Inj pada waktu $t+1$. Untuk jenis penjualan obat Profined Inj dipengaruhi oleh penjualan Profined Inj dengan kenaikan sebesar 0,133.

Hasil Peramalan yang diberikan oleh model state space untuk lima bulan kedepan adalah :

Tabel 4.22 Nilai peramalan

Obs	Profined Suppo 100M	Profined Inj
1	1196.61	974.48
2	1195.22	973.92
3	1194.41	973.59
4	1193.94	973.40
5	1193.66	973.29

4.3. Pembentukan Model Peramalan Untuk Obat Peflecine

I.V. /5 AMP

4.3.1. Identifikasi Model

4.3.1.1. Pemeriksaan Data

Pemeriksaan deret data dilakukan dengan cara mengamati plot series data asli pada lampiran data (C1). Dari plot data asli terlihat bahwa data telah stasioner pada varians, plot terlihat pada awal data terjadi peningkatan yang kemudian rata pada lag ke-12

4.3.1.2. Identifikasi Model Univariate Time Series

Identifikasi model pada plot fungsi autokorelasi dan plot parsial autokorelasi pada lampiran (C1). Dari plot fungsi autokorelasi nampak bahwa membentuk pola lambat menuju nol.

Sedangkan dari plot fungsi parsial autokorelasi terlihat pada lag pertama tampak keluar batas, kemudian pada lag yang kedua sampai dengan lag selanjutnya berada didalam batas .

Dari pengamatan kedua plot autokorelasi dan autokorelasi parsial diatas diduga deret merupakan deret autoregressive sata AR(1).

Hasil estimasi deret AR(1) data penjualan obat Peflecine I.V/5 AMP adalah :

Tabel 4.29. Estimasi model ARIMA(1,0,0)

Parameter	Estimasi	Std.error	t-ratio	P-value
AR (1)	.59183	.10841	5.45936	.00000
MEAN	151.14409	1.26850	119.15142	.00000
CONSTANT	61.69269			
Estimasi varians white noise = 17.88746				, df = 58
Chi-kuadrat = 14.22935				
Probabilitas White noise = 0.711366				

Sumber: perhitungan

Langkah selanjutnya adalah melakukan pengujian terhadap parameter model dengan hipotesis :

$$H_0 : \theta_p = 0$$

$$H_1 : \theta_p \text{ tidak sama dengan nol}$$

Untuk AR (1)

$$H_0 : \theta_1 = 0$$

$$H_1 : \theta_1 \text{ tidak sama dengan nol}$$

Dengan menentukan tingkat significant 95% ($\alpha = 5\%$)

$$\text{Nilai t-hitung} = | 5.45936 |$$

$$\text{Nilai t-tabel} = t_{(0.025, 58)} = 1.96$$

Karena $|t\text{-hitung}| > t\text{-tabel}$, maka tolak H_0 yang berarti parameter AR(1) masuk ke dalam model.

4.3.1.3. Pemeriksaan Model

Setelah didapatkan taksiran nilai-nilai parameter model, maka tahap selanjutnya pemeriksaan dianalisis yang ditujukan untuk membuktikan bahwa model tersebut cukup memadai. Pemeriksaan dilakukan dengan mengamati pola residual

apakah berdistribusi normal $N(0, \Sigma)$ dan memenuhi syarat White Noise.

Pengamatan terhadap pola plot fungsi autokorelasi deret residual dan autokorelasi parsial residual. Dari pengamatan kedua plot tersebut pada lampiran (C2), terlihat bahwa residual model tidak significant pada semua lag atau semua lag berada diantara ($2 \times$ standart error). Dari pengamatan kedua plot tersebut dapat disimpulkan bahwa residual dari model sudah memenuhi white noise.

Pemeriksaan selanjutnya adalah terhadap plot normal residualnya. Dari plot normal residualnya pada lampiran gambar(C2), tampak bahwa titik-titik plot berada disekitar garis lurus 45° . dari pemeriksaan ini disimpulkan bahwa residual model berdistribusi normal.

4.3.1.4. Estimasi Parameter

Hasil dari pemeriksaan model diatas dapat disimpulkan bahwa model layak digunakan. Model yang didapatkan adalah:

$$(1 - \Theta_1 B) Z_t = a_t$$

atau :

$$Z_t = \Theta_1 Z_{t-1} + a_t$$

$$Z_t = 0.59183 Z_{t-1} + a_t$$

dimana Z_t adalah jumlah penjualan obat-obatan peflecine I.V /5 AMP pada waktu ke-t.

Dari persamaan di atas dapat di terangkan bahwa peng-

aruh jumlah penjualan obat Peflecine I.V /5 AMP untuk bulan ini dipengaruhi oleh kenaikan jumlah penjualan bulan lalu sebesar 0.59183.

4.3.2. Peramalan

Dari persamaan yang didapat dilakukan peramalan untuk lima periode (bulan) kedepan, hasil dari peramalan adalah sebagai berikut:

Tabel 4.23. Persentase kesalahan peramalan.

obs	forecast	lower	upper	actual	kesalahan
56	140.843	120.58	161.106	152	7.34 %
57	141.631	121.307	161.955	147	3.65 %
58	141.57	121.245	161.894	149	4.97 %
59	141.574	121.25	161.899	151	6.24 %
60	141.574	121.25	161.898	152	6.86 %

Tabel 4.24. Hasil peramalan lima periode ke depan.

Periode	Peramalan
61	141.574
62	141.574
63	141.574
64	141.574
65	141.574

Sumber : perhitungan

Dari hasil ramalan diatas diketahui bahwa jumlah penjualan obat Peflecine I.V /5 AMP untuk sepuluh periode kedepan cenderung mengalami penurunan .

Hal ini menunjukan pola penjualan obat Peflecine I.V/5 AMP yang akan menurun pada periode mendatang dan merupakan informasi bagi pihak perusahaan untuk mengambil kebijaksanaan lebih lanjut.

BAB V

KESIMPULAN DAN SARAN

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Untuk daerah pemasaran PT. EURIDO COMBINED SURABAYA yang meliputi seluruh Jawa Timur, pada kelompok penjualan dibagi menjadi 3 kelompok. Dalam penelitian ini yang diteliti team Hospital yang penjualannya keseluruhan rumah sakit di Jawa Timur.

Dengan metode analisa state space mempunyai bentuk multivariate autoregresisive yang bersesuaian dengan AR(1) seperti terlihat pada berikut ini :

Adapun hasil akhir dari taksiran parameter, setelah dilakukan penaksiran yang berulang-ulang hasilnya adalah sebagai berikut :

- Model Flegyl infusion : $FI_{t+1} = 0.227 FI_t + a_{1,t+1}$

Jumlah penjualan Flegyl Infusion pada waktu ke $t+1$ bulan yang akan datang sama dengan jumlah penjualan flegyl infusion saat ini kali 0.227.

- Model Flegyl Suppo 500 Mg :

$$FS_{t+1} = 0.133 FI_t - 0.240 FS_t + 0.483 F1_t + a_{2,t+1}$$

Jumlah penjualan flegyl suppo 500 Mg pada waktu $t+1$,

sama dengan 0.133 kali jumlah penjualan flegyl infusion saat ini dikurangi (jumlah penjualan jenis obat flegyl suppo 500Mg saat ini kali 0.240) ditambah 0.483 kali jumlah penjualan Flegyl Suppo 1 Gr saat ini.

- Model Flegyl Suppo 1 Gr : $F1_{t+1} = 0.353 F1_t + a_{3,t+1}$

Jumlah penjualan untuk jenis obat flegyl suppo 1gr pada periode yang akan datang sama dengan 0.353 kali jumlah penjualan Flegyl Suppo Saat ini.

- Model Profined Suppo 100 Mg : $PS_{t+1} = 0.592 PS_t + a_{4,t+1}$

Jumlah penjualan Profined Suppo 100 Mg pada waktu yang akan datang sama dengan sebesar 0.592 dikali jumlah penjualan obat Profined Suppo 100 Mg saat ini.

- Model Profined Inj : $PI_{t+1} = 0.229 PI_t + a_{2,t+1}$

Pada penjualan obat Profined INJ yang akan datang sama dengan 0.229kali jumlah penjualan Profined INJ saat ini.

Untuk kelompok univariate time series yaitu peflecine I.V /5 AMP mempunyai model berikut :

$$Z_t = 0.59183 Z_{t-1} + a_t$$

Artinya jumlah penjualan bulan ini sama dengan 0.59183 dikali jumlah penjualan Peflecine I.V /5 AMP bulan lalu.

Berikut hasil ramalan untuk setiap jenis obat yang diramalkan lima periode ke depan :

Nilai peramalan penjualan obat-obatan

Obs	Flegyl Infusion	Flegyl Suppo 500M	Flegyl Suppo 1 Mg
1	984.66	365.879	315.914
2	975.72	355.013	360.405
3	973.68	354.102	376.126
4	973.22	361.692	381.681
5	973.11	362.503	383.644

Nilai peramalan

Obs	Profined Suppo 100M	Profined Inj
1	1196.61	974.48
2	1195.22	973.92
3	1194.41	973.59
4	1193.94	973.40
5	1193.66	973.29

Hasil peramalan lima periode ke depan.

Periode	Peflecin I.V /5 AMP
1	141.574
2	141.574
3	141.574
4	141.574
5	141.574

5.2. SARAN

- Dari analisa dan pembahasan model state space yang didapat sudah layak digunakan untuk peramalan penjualan obat-obatan dibulan yang akan datang.
- Dalam pengambilan kebijaksanaan juga harus diperhatikan situasi dan kondisi di masa yang akan datang yaitu faktor-faktor yang dapat membantu yang belum diterangkan oleh model.

DAFTAR PUSTAKA

DAFTAR PUSTAKA

1. Judge, Hill, Griffiths., (1980), Introduction to the Theory and Practice of Econometric.
2. Karson, Marvin J., (1982), Multivariate Statistical Methods, Ames, Iowa.
3. Makridakis, Sypros, Wheelwright, C., Steven, McGee, Victor, E, Forescaing, Airlangga (1992), Jakarta.
4. Wei, William W. S., (1990), Time Series Analysis : Univariate and Multivariate Methods, Addison-Wesley Publishing Company.
5. Peter J. Brockwell, Richard A. Davir (1990) Springer Series In Statistics Fort Collins, Colorado.

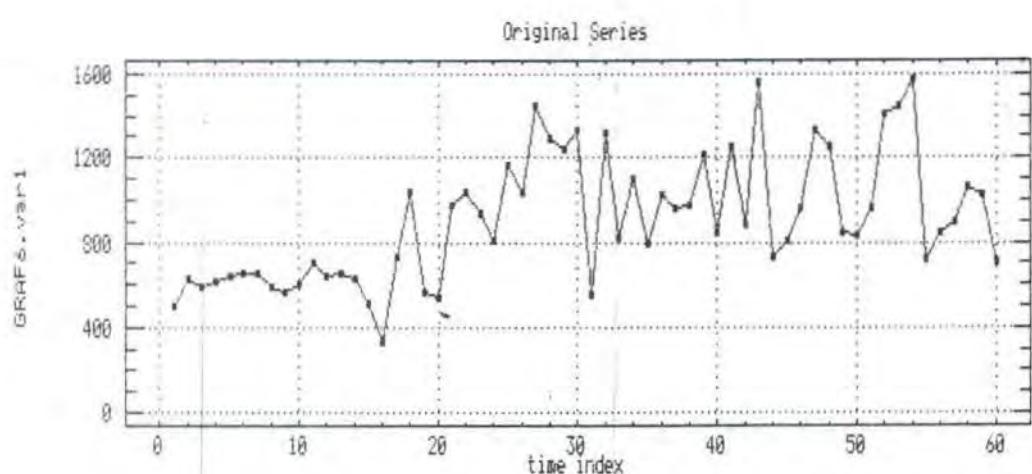
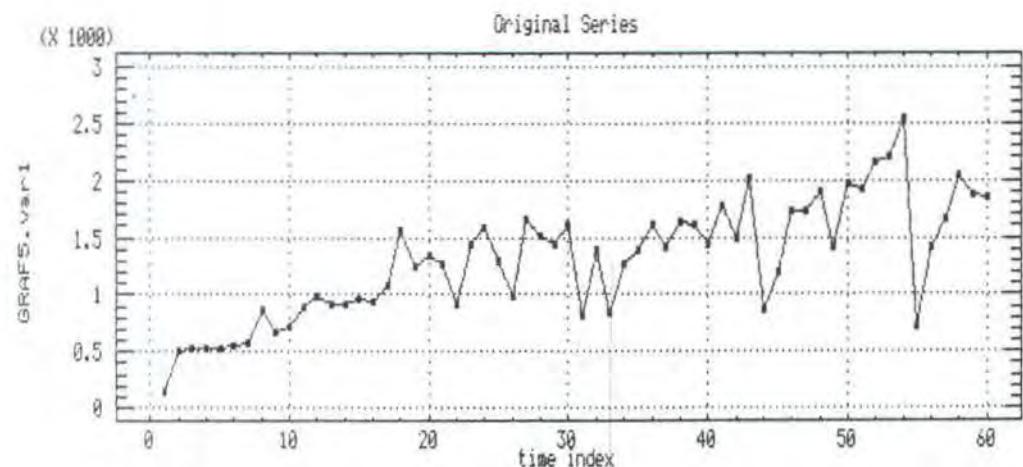
LAMPIRAN

DATA PENJUALAN OBAT-OBATAN TEAM HOSPITAL
(DATA DALAM BULANAN)

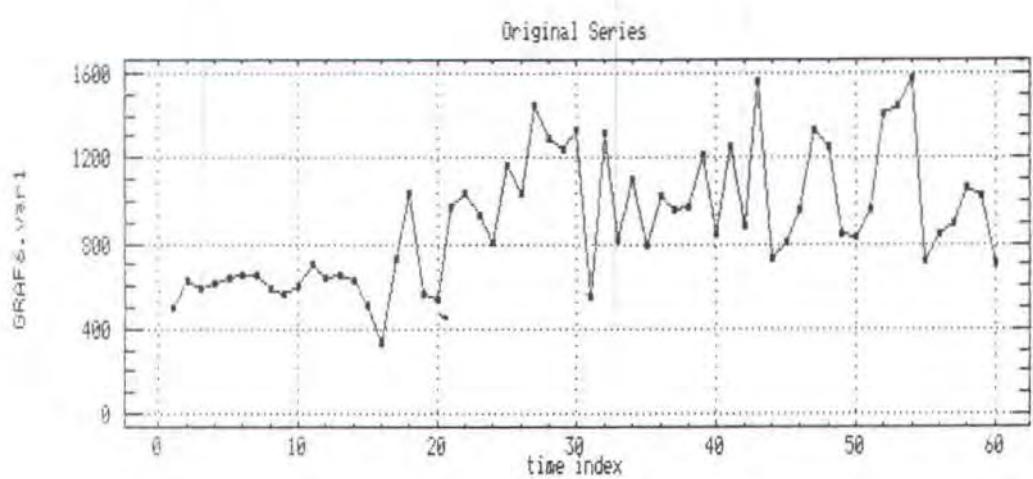
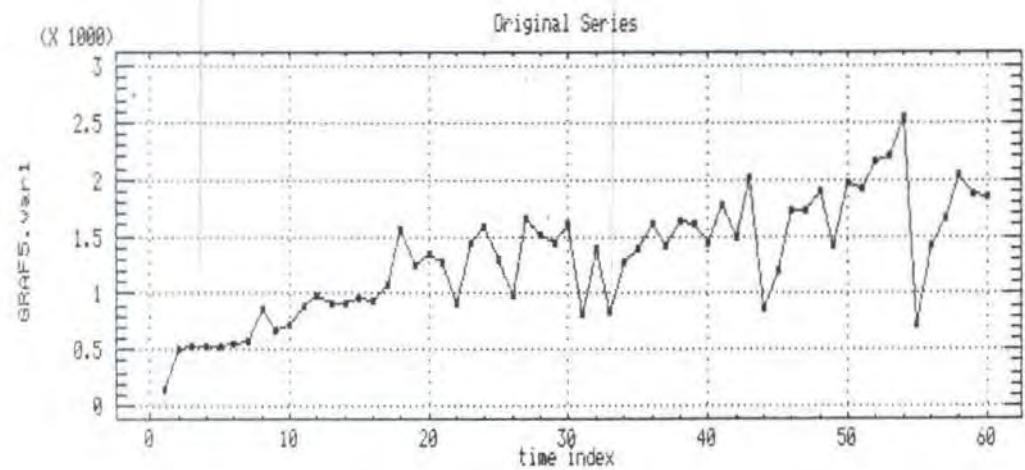
BLN	Flegyl Infusion 100	Flegyl Suppo 500Mg	Flegyl Suppo 1 Gr	Peflecine I. V / 5 A M P	Profined Suppo 100 Mg	Profined INJ
1991						
Jul	750	285	388	141	505	632
Ags	793	295	391	144	509	625
Spt	802	299	399	143	525	590
Okt	783	301	405	140	535	610
Nop	789	300	400	144	540	645
Des	798	311	385	135	543	650
1992						
Jan	793	307	403	133	565	656
Feb	735	285	437	140	870	591
Mrt	1016	396	237	134	674	560
Apr	1080	209	300	122	722	602
Mei	1057	314	338	134	896	702
Jun	909	365	337	140	973	643
Jul	609	420	398	139	905	654
Agt	582	317	254	138	915	630
Spt	781	378	394	141	953	514
Okt	280	308	359	131	928	329
Nop	1042	318	277	131	1089	735
Des	1224	371	421	169	1567	1033
1993						
Jan	1100	450	444	123	1244	564
Feb	595	398	477	135	1342	538
Mrt	1197	395	424	133	1267	971
Apr	1041	454	460	140	912	1039
Mei	805	355	437	124	1439	939
Jun	1403	406	502	139	1590	806
Jul	1159	639	403	145	1298	1159
Agt	1358	407	438	135	990	1038
Spt	947	566	614	145	1645	1447
Okt	985	318	410	147	1520	1299
Nop	857	533	450	146	1430	1238
Des	1207	344	575	145	1602	1327

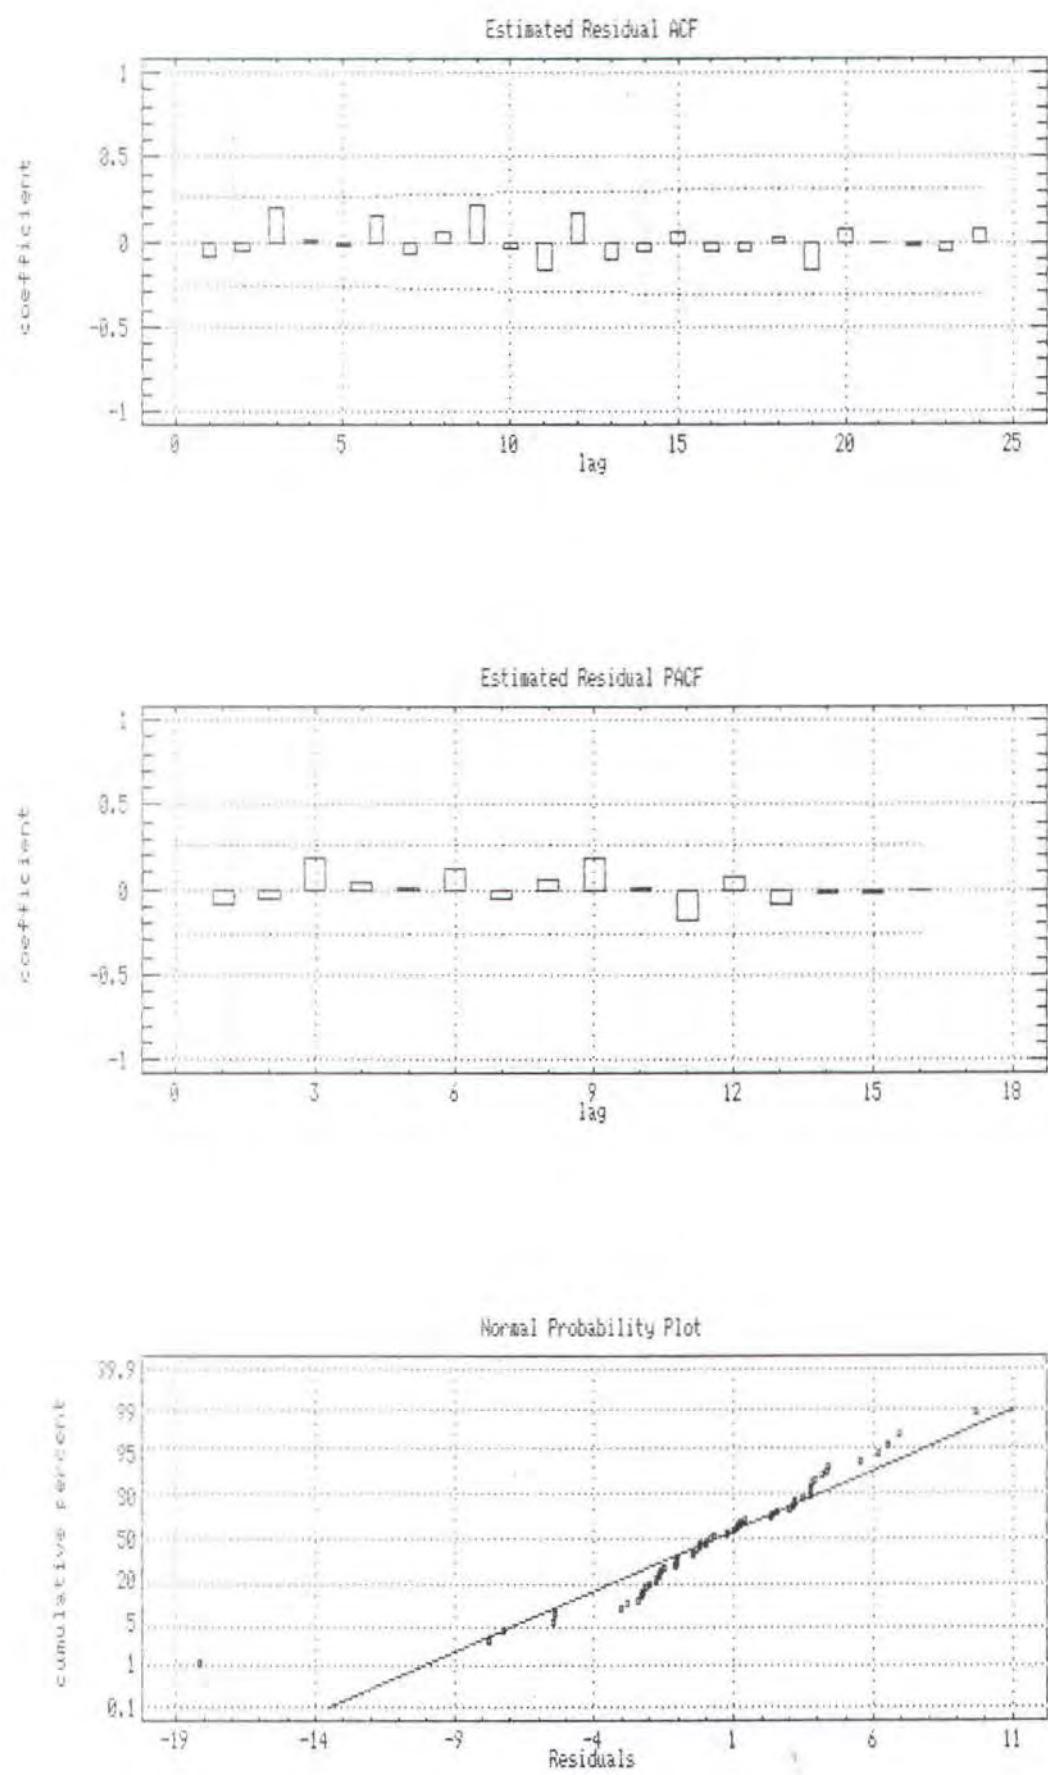
LANJUTAN LAMPIRAN A..

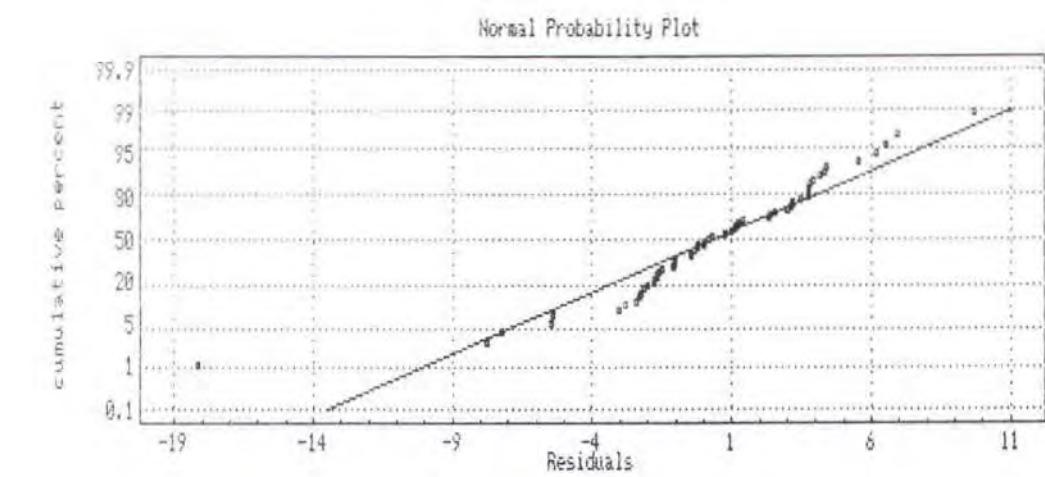
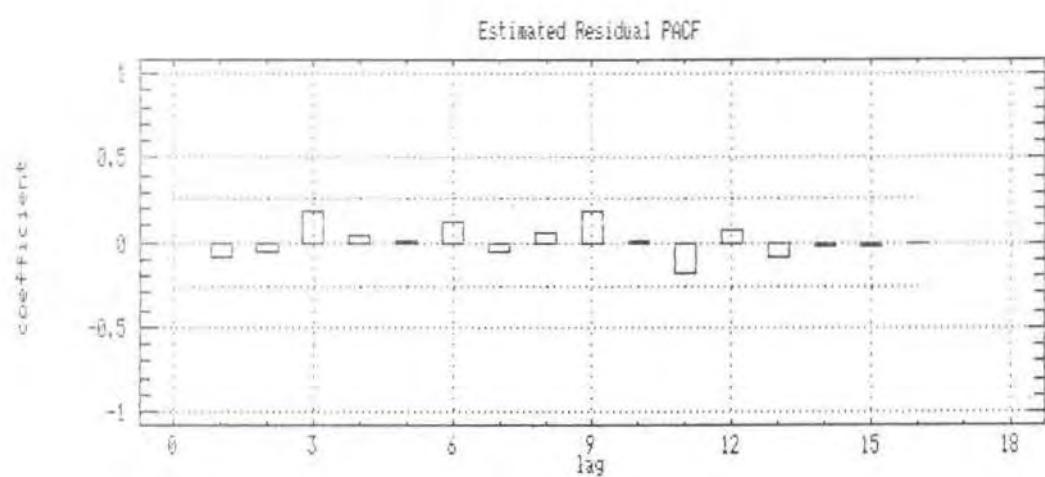
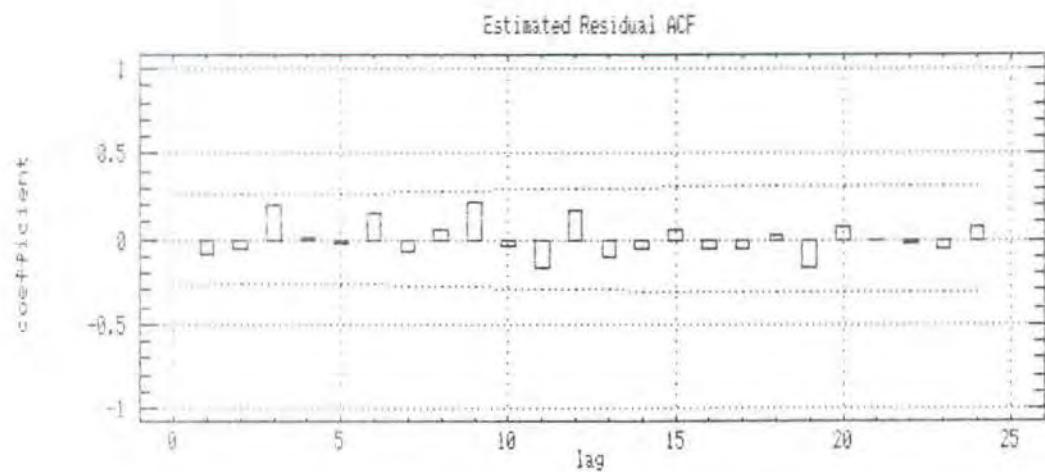
1994						
Jan	489	272	308	150	810	545
Feb	921	429	414	143	1401	1323
Mrt	806	284	419	132	833	817
Apr	713	285	375	142	1279	1105
Mei	918	426	382	146	1399	796
Jun	1375	403	486	151	1604	1029
Jul	610	256	353	145	1406	966
Agt	674	286	356	148	1644	976
Spt	1215	558	439	146	1604	1217
Okt	805	484	470	146	1449	840
Nop	1093	489	424	145	1784	1252
Des	851	255	485	144	1484	878
1995						
Jan	1392	485	523	147	2007	1565
Feb	908	337	380	138	869	732
Mrt	848	340	335	151	1193	803
Apr	942	348	371	138	1739	963
Mei	1023	264	358	158	1727	1329
Jun	1129	303	303	175	1902	1253
Jul	844	231	315	113	1408	846
Agt	1238	368	294	146	1965	830
Spt	959	301	317	144	1930	962
Okt	1073	325	325	141	2169	1405
Nop	1564	437	440	142	2210	1453
Des	1878	843	409	149	2554	1575
1996						
Jan	1073	171	185	151	725	720
Feb	1103	271	393	152	1422	842
Mrt	1059	409	322	147	1659	901
Apr	919	283	290	149	2047	1066
Mei	1462	222	265	151	1870	1022
Jun	1024	402	413	152	1860	708



LAMPIRAN C







STATESPACE Procedure

Nobs = 60

Variable	Mean	Std
FI	973.0833	275.4447
FS	363.5167	111.5945
F1	384.7167	82.55006

Information Criterion for Autoregressive Models

Lag=0	Lag=1	Lag=2	Lag=3	Lag=4
1742.510548	1740.344982	1750.852727	1757.387876	1768.277089
Lag=5	Lag=6	Lag=7	Lag=8	Lag=9
1774.77652	1782.046581	1785.790627	1793.271602	1799.665013

Lag=10
1811.403059

STATESPACE Procedure
Var/Cov Matrices of the Input Series

Lag=0			
	FI	FS	F1
FI	75869.7726	14107.39689	3165.566384
FS	14107.39689	12453.3387	4003.064124
F1	3165.566384	4003.064124	6814.511582
Lag=1			
	FI	FS	F1
FI	14976.74988	1419.023847	-2602.50214
FS	4939.427519	193.636718	2034.360673
F1	-1811.92813	1318.617453	2191.601747
Lag=2			
	FI	FS	F1
FI	11629.40654	305.400235	-1626.417
FS	-1532.45485	385.818917	405.977844
F1	-1895.57265	2172.349595	1750.080047
Lag=3			
	FI	FS	F1
FI	12734.91914	2513.382274	1397.338206
FS	3535.506568	1588.027952	794.8286299
F1	1014.842444	2248.740212	3049.196483

LANJUTAN LAMPIRAN F..

Lag=4

	FI	FS	F1
FI	10095.00942	-835.92919	-4289.12608
FS	3030.493409	1557.035857	-323.982166
F1	-1846.35546	1461.035913	1130.977891

Lag=5

	FI	FS	F1
FI	-829.931379	1447.718668	-2832.21382
FS	-5155.52568	-1814.02093	215.291219
F1	-5491.29715	465.594609	1202.967773

Lag=6

	FI	FS	F1
FI	10607.47105	-1569.11963	2144.751271
FS	-2463.23263	-426.585904	-579.631723
F1	-2719.20071	-1161.87071	799.7912712

Lag=7

	FI	FS	F1
FI	10865.03731	-257.662735	-2251.67206
FS	318.290654	591.749685	287.968498
F1	-5379.50398	1243.509741	680.317029

Lag=8

	FI	FS	F1
FI	-4692.39642	-3359.13465	-4842.46798
FS	-2599.03465	-905.408512	-975.393145
F1	-1268.692	1303.730866	366.615386

Lag=9

	FI	FS	F1
FI	2774.924082	51.034958	-2197.74188
FS	-5159.13001	-942.999195	-336.125410
F1	-884.516455	117.213008	300.934929

Lag=10

	FI	FS	F1
FI	-9780.45315	-1276.98074	-2497.26662
FS	-842.453908	305.223399	-489.368691
F1	-1326.65363	262.040066	223.278484

LANJUTAN LAMPIRAN F ..

STATESPACE Procedure

Correlation Matrices of the Input Series

	Lag=0			Lag=1		
	FI	FS	F1	FI	FS	F1
FI	1.00000	0.45895	0.13922	0.19740	0.04616	-0.11446
FS	0.45895	1.00000	0.43454	0.16069	0.01555	0.22083
F1	0.13922	0.43454	1.00000	-0.07969	0.14314	0.32161

	Lag=2			Lag=3		
	FI	FS	F1	FI	FS	F1
FI	0.15328	0.00994	-0.07153	0.16785	0.08177	0.06145
FS	-0.04986	0.03098	0.04407	0.11502	0.12752	0.08628
F1	-0.08337	0.23581	0.25682	0.04463	0.24411	0.44746

	Lag=4			Lag=5		
	FI	FS	F1	FI	FS	F1
FI	0.13306	-0.02720	-0.18863	-0.01094	0.04710	-0.12456
FS	0.09859	0.12503	-0.03517	-0.16772	-0.14567	0.02337
F1	-0.08120	0.15860	0.16597	-0.24150	0.05054	0.17653

	Lag=6			Lag=7		
	FI	FS	F1	FI	FS	F1
FI	0.13981	-0.05105	0.09432	0.14321	-0.00838	-0.09903
FS	-0.08014	-0.03425	-0.06292	0.01035	0.04752	0.03126
F1	-0.11959	-0.12612	0.11737	-0.23659	0.13499	0.09983

STATESPACE Procedure
Correlation Matrices of the Input Series

	Lag=8			Lag=9		
	FI	FS	F1	FI	FS	F1
FI	-0.06185	-0.10928	-0.21297	0.03657	0.00166	-0.09666
FS	-0.08455	-0.07270	-0.10588	-0.16784	-0.07572	-0.03649
F1	-0.05580	0.14152	0.05380	-0.03890	0.01272	0.04416

	Lag=10		
	FI	FS	F1
FI	-0.12891	-0.04154	-0.10983
FS	-0.02741	0.02451	-0.05312
F1	-0.05835	0.02845	0.03277

LANJUTAN LAMPIRAM F..

STATESPACE Procedure
Schematic Representation of Correlations

Name/Lag	0	1	2	3	4	5	6	7	8	9	10
FI	++.
FS	+++
F1	.++	..++

+ is $> 2 \times \text{std error}$, - is $< -2 \times \text{std error}$, . is between

STATESPACE Procedure
Partial Autoregressive Matrices

Lag=1			
	FI	FS	F1
FI	0.2117843	0.0350350	-0.5008674
FS	0.0874659	-0.2051792	0.3784317
F1	-0.0481587	0.0614781	0.3078651

Lag=2			
	FI	FS	F1
FI	0.1237130	-0.0820169	-0.0405274
FS	-0.0164582	-0.0149901	0.0600176
F1	-0.0581584	0.2046104	0.0508369

Lag=3			
	FI	FS	F1
FI	0.0834302	0.0392821	0.4504214
FS	0.0433971	0.0132834	0.0073567
F1	-0.0028513	0.0652799	0.3003662

Lag=4			
	FI	FS	F1
FI	0.1270568	-0.0240581	-0.8127250
FS	0.0208688	0.1340776	-0.4012350
F1	-0.0362943	0.1340972	-0.0971816

Lag=5			
	FI	FS	F1
FI	-0.1649835	0.4359103	-0.3238960
FS	-0.0719568	-0.1337728	0.2228581
F1	-0.0856026	0.0360854	0.1240199

	Lag=6		
	FI	FS	F1
FI	0.0996590	-0.4515181	0.8427166
FS	0.0206829	-0.0603564	-0.1671547
F1	0.0275191	-0.1819080	-0.0518899

	Lag=7		
	FI	FS	F1
FI	0.2341467	-0.2986487	-0.2349760
FS	-0.0305291	0.1793391	0.0213459
F1	-0.0840353	0.2046236	0.0927894

	Lag=8		
	FI	FS	F1
FI	-0.1970907	0.2230382	-0.6451502
FS	0.0042209	-0.0332339	-0.1850474
F1	0.0281750	0.1266246	-0.1934991

	Lag=9		
	FI	FS	F1
FI	-0.0699505	0.4017941	-0.5790108
FS	-0.0877337	-0.0129046	0.1556586
F1	0.0124181	0.1006551	-0.1005238

	Lag=10		
	FI	FS	F1
FI	-0.2729403	0.3572239	-0.1672750
FS	-0.0345634	0.0285024	-0.1913573
F1	0.0178576	0.0139758	0.0033794

SAS

76

STATESPACE Procedure

Schematic Representation of Partial Autocorrelations

Name/Lag	1	2	3	4	5	6	7	8	9	10
FI
FS
F1	...+

+ is > 2*std error, - is < -2*std error, . is between

SAS

STATESPACE Procedure

Nobs = 60

	Variable	Mean	Std
PS		1181	385.2334
PI		971.4667	275.1328

Information Criterion for Autoregressive Models

Lag=0	Lag=1	Lag=2	Lag=3	Lag=4
1383.430123	1362.621511	1366.31696	1367.487897	1374.870844
Lag=5	Lag=6	Lag=7	Lag=8	Lag=9
1381.682071	1387.78784	1392.416895	1394.749129	1396.0484
Lag=10				
1402.085305				

Var/Cov Matrices of the Input Series

Lag=0		Lag=1	
		PS	PI
PS	148404.7458	30262.45763	87908.08475 18749.46667
PI	30262.45763	75698.04972	33919.19322 13444.22569
Lag=2		Lag=3	
		PS	PI
PS	74150.81356	22173.30395	80926.89831 11433.14915
PI	26200.79548	12693.46041	20422.48249 14003.26802
Lag=4		Lag=5	
		PS	PI
PS	67487.33898	6347.988701	58671.11864 1719.477966
PI	19811.15141	6320.710659	13371.17514 1901.786064
Lag=6		Lag=7	
		PS	PI
PS	49753.47458	5796.228249	53991.42373 -7986.64407
PI	24375.30169	7015.102147	22872.10169 5780.762863
Lag=8		Lag=9	
		PS	PI
PS	50090.11864	12352.7096	37254.08475 -2730.14802
PI	10940.40565	-6741.87473	31965.92881 6376.518192
Lag=10			
		PS	
PS	24840.25424	-7179.21921	
PI	14068.41921	-4681.73183	

LANJUTAN LAMPIRAN G ..

Correlation Matrices of the Input Series

	Lag=0		Lag=1		Lag=2	
	PS	PI	PS	PI	PS	PI
PS	1.00000	0.28552	0.59235	0.17690	0.49965	0.20920
PI	0.28552	1.00000	0.32002	0.17760	0.24720	0.16769
	Lag=3		Lag=4		Lag=5	
	PS	PI	PS	PI	PS	PI
PS	0.54531	0.10787	0.45475	0.05989	0.39535	0.01622
PI	0.19268	0.18499	0.18691	0.08350	0.12615	0.02512
	Lag=6		Lag=7		Lag=8	
	PS	PI	PS	PI	PS	PI
PS	0.33526	0.05469	0.36381	-0.07535	0.33752	0.11655
PI	0.22998	0.09267	0.21579	0.07637	0.10322	-0.08906
	Lag=9		Lag=10			
	PS	PI	PS	PI		
PS	0.25103	-0.02576	0.16738	-0.06773		
PI	0.30159	0.08424	0.13273	-0.06185		

Schematic Representation of Correlations

Name/Lag	0	1	2	3	4	5	6	7	8	9	10
PS	++	+	+	+	+	+	+	+	+
PI	++	+	+	..

+ is $> 2 \times \text{std error}$, - is $< -2 \times \text{std error}$, . is between

STATESPACE Procedure

Partial Autoregressive Matrices

	Lag=1		Lag=2	
	PS	PI	PS	PI
PS	0.5899386	0.0118428	0.2177969	0.1008765
PI	0.2094140	0.09388841	0.0320420	0.0966968
	Lag=3		Lag=4	
	PS	PI	PS	PI
PS	0.3098811	-0.1137882	0.0697192	-0.0805917
PI	-0.0302847	0.1077761	-0.0325364	0.0135531
	Lag=5		Lag=6	
	PS	PI	PS	PI
PS	0.0676610	-0.1219884	-0.0465717	0.0515110
PI	-0.0604282	-0.0153439	0.1307399	0.0478962

LANJUTAN LAMPIRAN G..

	Lag=7		Lag=8	
	PS	PI	PS	PI
PS	0.1630682	-0.1976488	0.0008381	0.2521283
PI	0.0727929	0.0343999	-0.0698554	-0.1179078
	Lag=9		Lag=10	
	PS	PI	PS	PI
PS	-0.0541520	-0.1884442	-0.1308182	0.0212919
PI	0.2233192	-0.0065478	-0.0888440	-0.0864693

Schematic Representation of Partial Autocorrelations

Name/Lag	1	2	3	4	5	6	7	8	9	10
PS	+	..	+
PI

+ is $> 2^{\text{std error}}$, - is $< -2^{\text{std error}}$, . is between

STATESPACE Procedure

Yule-Walker Estimates for the Min AIC

	Lag=1	
	PS	PI
PS	0.58994	0.01184
PI	0.20941	0.09388

Variance/Covariance of the Residuals

	Lag=0		Lag=1	
	PS	PI	PS	PI
PS	148404.7458	30262.45763	96322.32447	10092.99823
PI	30262.45763	75698.04972	10092.99823	67332.69713
	Lag=2		Lag=3	
	PS	PI	PS	PI
PS	90450.11915	8332.513274	82133.85642	9490.432229
PI	8332.513274	66459.37904	9490.432229	65657.18887
	Lag=4		Lag=5	
	PS	PI	PS	PI
PS	81470.49102	9692.153657	80342.34977	9788.901503
PI	9692.153657	65573.36073	9788.901503	65236.04277
	Lag=6		Lag=7	
	PS	PI	PS	PI
PS	80066.85448	10030.43553	76359.16134	9710.449512
PI	10030.43553	63523.14794	9710.449512	62957.84168

LANJUTAN LAMPIRAN G ..

	Lag=8				Lag=9			
	PS	PI	PS	PI	PS	PI	PS	PI
PS	72164.75111	11960.73956	69520.9501	13367.87879				
PI	11960.73956	61405.90506	13367.87879	57735.77794				

	Lag=10			
	PS	PI	PS	PI
PS	68385.78082	12570.34279		
PI	12570.34279	56586.48161		

Residual Correlations from AR Models

	Lag=0		Lag=1		Lag=2	
	PS	PI	PS	PI	PS	PI
PS	1.00000	0.28552	1.00000	0.12533	1.00000	0.10747
PI	0.28552	1.00000	0.12533	1.00000	0.10747	1.00000

	Lag=3		Lag=4		Lag=5	
	PS	PI	PS	PI	PS	PI
PS	1.00000	0.12924	1.00000	0.13260	1.00000	0.13521
PI	0.12924	1.00000	0.13260	1.00000	0.13521	1.00000

	Lag=6		Lag=7		Lag=8	
	PS	PI	PS	PI	PS	PI
PS	1.00000	0.14065	1.00000	0.14005	1.00000	0.17968
PI	0.14065	1.00000	0.14005	1.00000	0.17968	1.00000

	Lag=9		Lag=10	
	PS	PI	PS	PI
PS	1.00000	0.21100	1.00000	0.20207
PI	0.21100	1.00000	0.20207	1.00000

STATESPACE Procedure

Canonical Correlations Analysis

State Vector	Correlations	Infor.	Chisq	D.F.
PS(T;T), PI(T;T), PS(T+1;T)	1.0000 1.0000 0.2469	-0.2259	3.711194	2
PS(T;T), PI(T;T), PI(T+1;T)	1.0000 1.0000 0.1139	-3.2167	0.770247	2

Estimation begins....

Initial: RSS = 5406.87 b = -0.0766886 141.582

Final: RSS = 5406.85 ...stopped on criterion 2

Summary of Fitted Model for: RSS.var1

Parameter	Estimate	Stnd.error	T-value	P-value
AR (1)	-.07755	.13810	-.56152	.57681
MEAN	141.57404	1.26669	111.76658	.00000
CONSTANT	152.55254			

Estimated white noise variance = 102.016 with 53 degrees of freedom.

Estimated white noise standard deviation (std err) = 10.1003

Chi-square test statistic on first 20 residual autocorrelations = 13.9692
with probability of a larger value given white noise = 0.731099

Backforecasting: no

Number of iterations perfor

Variable: WORKAREA.FORECASTS (length = 10 3)

(1,1) 140.843	(1,2) 120.58	(1,3) 161.106
(2,1) 141.631	(2,2) 121.307	(2,3) 161.955
(3,1) 141.57	(3,2) 121.245	(3,3) 161.894
(4,1) 141.574	(4,2) 121.25	(4,3) 161.899
(5,1) 141.574	(5,2) 121.25	(5,3) 161.898
(6,1) 141.574	(6,2) 121.25	(6,3) 161.899
(7,1) 141.574	(7,2) 121.25	(7,3) 161.899
(8,1) 141.574	(8,2) 121.25	(8,3) 161.899
(9,1) 141.574	(9,2) 121.25	(9,3) 161.899
(10,1) 141.574	(10,2) 121.25	(10,3) 161.899

