

31000 00011170

TUGAS AKHIR

PEMODELAN DAN PERAMALAN PENJUALAN PRODUK PT. ABBATOIR SURYA JAYA SURABAYA DENGAN ANALISIS MULTIVARIATE TIME SERIES

Oleh :

KARYO UTOMO

1393.100.008

RSST
519.55
Uto
P-1
1998



PERPUSTAKAAN ITS	
Tgl. Terima	18-4-99
Terima Dari	n
No. Agenda Pkp.	8959

JURUSAN STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
S U R A B A Y A
1998

**PEMODELAN DAN PERAMALAN PENJUALAN PRODUK
PT. ABBATOIR SURYA JAYA SURABAYA
DENGAN ANALISIS MULTIVARIATE TIME SERIES**

TUGAS AKHIR

Diajukan sebagai
Syarat Kelulusan di Jurusan Statistika
Fakultas Matematika dan Ilmu Pengetahuan Alam
Institut Teknologi Sepuluh Nopember Surabaya

Oleh :

KARYO UTOMO
1393.100.008



**JURUSAN STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
S U R A B A Y A
1998**

TUGAS AKHIR

PEMODELAN DAN PERAMALAN PENJUALAN PRODUK PT. ABBATOIR SURYA JAYA SURABAYA DENGAN ANALISIS MULTIVARIATE TIME SERIES

Oleh :

KARYO UTOMO

1393.100.008

Surabaya, Agustus 1998

Mengetahui / Menyetujui,
Dosen Pembimbing



Ir. SETIAWAN
NIP. 131 651 428

Mengetahui,
Ketua Jurusan Statistika FMIPA ITS



Drs. Slamet Mulyono, M.Sc., Ph.D.
NIP. 130 312 520

ABSTRAK

PEMODELAN DAN PERAMALAN PENJUALAN PRODUK
PT. ASJ SURABAYA
DENGAN ANALISIS MULTIVARIATE TIME SERIES
Oleh : Karyo Utomo (1393100008)
Pembimbing : Ir. setiawan MS.

Seiring dengan makin maju dan berkembangnya negara kesadaran masyarakat akan pentingnya makanan yang bergizi pun semakin meningkat. Daging sapi merupakan salah satu sumber gizi yang banyak diminati masyarakat karena selain dagingnya halal dan enak rasanya, daging sapi juga bisa diolah menjadi berbagai macam jenis makanan. Produk dari pemotongan sapi dapat dikelompokkan menjadi Retail cuts, Whole sale cuts, Offal dan By product.

Berkaitan dengan usaha mengetahui pola penjualan dimasa yang akan datang maka diperlukan suatu model peramalan terhadap pola penjualan, dengan mempertahankan kesederhanaannya tanpa banyak kehilangan informasi didalamnya. Karena penjualan pada saat sekarang dipengaruhi penjualan sebelumnya maka dalam pembuatan model ini digunakan metode time series.

Keterbatasan kapasitas produksi ini, juga mengakibatkan adanya dependensi antara variabel yang satu dengan variabel yang lain. Oleh karena adanya ketergantungan antara variabel ini maka permasalahan penjualan ini dapat dipandang sebagai kasus multivariate.

Model peramalan pola penjualan untuk keempat jenis produk yang didasarkan pada analisa state space mempunyai bentuk multivariate autoregresif yang bersesuaian dengan AR(1) dan mempunyai bentuk sebagai berikut :

1. Untuk produk retail cuts mempunyai persamaan

$$Z_{1,t+1} = 11534.223 + 0.299632 Z_2$$

Artinya jumlah penjualan retail cuts pada bulan mendatang dipengaruhi oleh kenaikan jumlah penjualan whole sale cuts pada bulan ini sebesar 29.96 %.

2. Untuk produk whole sale cuts mempunyai persamaan

$$Z_{2,t+1} = 592.620 + 0.748898 Z_2$$

Artinya jumlah penjualan whole sale cuts pada bulan mendatang dipengaruhi oleh kenaikan jumlah penjualan whole sale cuts pada bulan ini sebesar 74.90 %.

3. Untuk produk offal mempunyai persamaan

$$Z_{3,t+1} = 2098.127 - 0.06945 Z_2$$

Artinya jumlah penjualan offal pada bulan mendatang dipengaruhi oleh kenaikan jumlah penjualan whole sale cuts pada bulan ini sebesar 6.94 %.

4. Untuk produk by produk mempunyai persamaan

$$Z_{4,t+1} = 3013.042 + 0.591604 Z_2$$

Artinya jumlah penjualan by product pada bulan mendatang dipengaruhi oleh kenaikan jumlah penjualan whole sale cuts pada bulan ini sebesar 59.16 %.

KATA PENGANTAR

Dengan mengucap puji syukur yang tak terhingga kepada Allah swt, penulis telah
meyelesaikan tugas akhir ini, dengan judul :

PEMODELAN DAN PERAMALAN PENJUALAN PRODUK PT. ABBATOIR SURYA
JAYA SURABAYA DENGAN ANALISIS MULTIVARIATE TIME SERIES .

Seiring dengan ini penulis sangat berterima kasih kepada

1. Bapak Drs. Slamet Mulyono Msc. PhD. selaku Ketua jurusan Statistika ITS
2. Bapak Ir. Setiawan MS. selaku Dosen pembimbing
3. Bapak dan Ibu Dosen serta seluruh staf Tata Usaha Jurusan Statistika
4. Bapak, Ibu dan Adikku tercinta
5. Herry, Suhe dan Adit atas bantuan dan pinjaman komputernya serta printernya.
6. Parto, Sugeng, Slamet, Taufik, Tri M, Syamsudin dan Kukuh atas bantuan dan dukungannya
7. Ghufron, Fais dan Gito atas segala bantuannya
8. Rekan-rekan dan semua pihak yang tidak dapat disebutkan satu persatu.

Akhirnya semoga tugas akhir ini dapat bermanfaat bagi rekan-rekan dan semua
pihak yang membutuhkannya.



Surabaya, Agustus 1998

Penulis

DAFTAR ISI

ABSTRAK	i
KATA PENGANTAR.....	ii
DAFTAR ISI.....	iii
DAFTAR LAMPIRAN.....	v
DAFTAR TABEL.....	vi
DAFTAR GAMBAR.....	vii
BAB I PENDAHULUAN.....	1
1.1. Latar Belakang.....	1
1.2. Perumusan Masalah.....	2
1.3. Tujuan Penelitian.....	3
1.4. Manfaat Penelitian.....	4
1.5. Batasan Masalah.....	5
BAB II TINJAUAN PUSTAKA.....	6
2.1. Konsep Dasar Time Series.....	6
2.2. Model Vektor Time Series.....	12
2.3. Analisis State Space.....	21
2.4. Pemeriksaan Model dan Peramalan.....	33
BAB III BAHAN DAN METODOLOGI PENELITIAN.....	36
3.1. Bahan Penelitian.....	36

3.2. Metodologi Penelitian.....	36
BAB IV ANALISIS DAN PEMBAHASAN.....	41
4.1. Model Penjualan Produk PT.ASJ Surabaya.....	41
4.2. Peramalan Penjualan Produk PT.ASJ Surabaya.	55
BAB V KESIMPULAN DAN SARAN.....	56
5.1. Kesimpulan.....	56
5.2. Saran.....	57
DAFTAR PUSTAKA.....	59

DAFTAR LAMPIRAN

Lampiran 1. Data jumlah penjualan produk PT. ASJ Surabaya Januari 1992 - November 1997.....	60
Lampiran 2. Program dan output pembentukan model state space awal.....	62
Lampiran 3. Program dan output pembentukan model state space akhir.....	67
Lampiran 4. Program dan output uji multinormal residual.....	78
Lampiran 5. Program dan output pemeriksaan pola residual.....	80
Lampiran 6. Peta daging sapi.....	84

DAFTAR TABEL

Tabel 4.1.	Deskripsi data jumlah penjualan produk daging.....	41
Tabel 4.2.	Representasi skematik deret data (MACF)...	42
Tabel 4.3.	Representasi skematik autokorelasi parsial (MPACF).....	43
Tabel 4.4.	Nilai AIC model.....	44
Tabel 4.5.	Analisis korelasi kanonik.....	46
Tabel 4.6.	Penaksiran parameter awal.....	48
Tabel 4.7.	Penaksiran parameter akhir.....	49
Tabel 4.8.	Representasi skematik MACF residual.....	53
Tabel 4.9.	Representasi skematik MACF residual.....	53
Tabel 4.10.	Nilai AIC residual model.....	54
Tabel 4.11.	Nilai peramalan jumlah penjualan produk daging.....	55
Tabel 4.12.	Nilai simpangan peramalan.....	55
Tabel 5.1.	Nilai peramalan penjualan sepuluh periode kedepan.....	57

DAFTAR GAMBAR

Gambar 3.1. Algoritma metode deret berkala Box-Jenkins...39
Gambar 3.2. Algoritma metode deret berkala Box-Jenkins lanjutan.....40
Gambar 3.3. Plot multivariate normal dari residual.....52

HGS

BAB I

PENDAHULUAN

BAB I
P E N D A H U L U A N

1.1. Latar Belakang

Seiring dengan makin maju dan berkembangnya negara kesadaran masyarakat akan pentingnya makanan yang bergizi pun semakin meningkat. Daging sapi merupakan salah satu sumber gizi yang banyak diminati masyarakat karena selain dagingnya halal dan enak rasanya, daging sapi juga bisa diolah menjadi berbagai macam jenis makanan yaitu diantaranya bistik, baso, rawon, empal dan soto.

Produk pemotongan sapi dapat dikelompokkan menjadi 4 macam yaitu :

1. Retail cuts yang meliputi tenderloin (has dalam), sirloin (has luar), minced beef dan oxtail (buntut).
2. Whole sale cuts yang meliputi sirloin (has luar), topside (penutup), rump (tanjung), silverside (pendasar gandik), inside (kelapa), leg (betis), brisket (sandung lamur), chuck (paha depan), blade (daging leher), rib meat (daging iga), flank (samcah), oxtail (buntut), cube roll (lamusir depan), shin dan daging kepala.



3. offal atau jeroan yang meliputi hati, lidah, babat, usus, paru, jantung, limpha, ginjal, otak dan lemak.
4. By product atau produk sampingan yang meliputi kepala, kulit, kikil, phenis, gurung dan tulang.

PT. Abbatoir Surya Jaya Surabaya merupakan perusahaan yang bergerak dalam bidang produksi dan pemasaran daging sapi. Besarnya penjualan produk selalu bervariasi tergantung dari permintaan pasar. Dengan mempelajari variasi penjualan dapat diketahui pola kebutuhan konsumen dan keberhasilan marketing perusahaan. Dengan menggunakan metode yang tepat dapat dicari model yang paling sesuai sehingga bisa diramalkan kebutuhan dimasa mendatang berdasarkan data masa lalu.

Ramalan pada dasarnya merupakan dugaan atau prediksi peristiwa dimasa depan untuk memperkecil resiko yang terjadi akibat kesalahan dalam pengambilan keputusan. Dengan mengetahui ramalan penjualan perusahaan bisa membuat perencanaan yang lebih efektif tentang berapa kira-kira jumlah produksi yang akan terjual pada masa mendatang sehingga perusahaan tidak memproduksi secara berlebihan sebagai akibatnya akan menimbulkan barang tertimbun atau memproduksi terlalu sedikit sehingga menimbulkan permintaan yang tidak dapat dipenuhi yang berarti kehilangan kesempatan menjual.

Konsumsi daging cenderung meningkat dari waktu ke waktu, agar ketersediaan daging tersebut dapat memenuhi kebutuhan konsumen maka diperlukan suatu perencanaan penjualan yang tepat. Salah satu masalah yang harus diketahui dalam perencanaan penjualan adalah jumlah daging yang harus dipasarkan untuk memenuhi kebutuhan konsumen pada masa mendatang. Dalam menghadapi masalah tersebut, perusahaan harus bisa meramalkan. Namun demikian meramalkan penjualan daging dimasa yang akan datang tidak mudah, karena kebutuhan konsumen akan daging selalu berubah setiap waktu. Berkaitan dengan usaha mengetahui pola penjualan dimasa yang akan datang maka diperlukan suatu model peramalan terhadap pola penjualan, dengan mempertahankan kesederhanaannya tanpa banyak kehilangan informasi didalamnya.

Karena penjualan pada saat sekarang dipengaruhi penjualan sebelumnya maka dalam pembuatan model ini digunakan metode time series. Keterbatasan kapasitas produksi ini, juga mengakibatkan adanya keterkaitan antara variabel yang satu dengan variabel yang lain. Oleh karena ada ketergantungan antara variabel ini maka permasalahan penjualan ini dapat dipandang sebagai kasus multivariate. Oleh karenanya kehadiran suatu model yang sederhana sangat diperlukan dalam rangka memenuhi

kebutuhan informasi dimasa mendatang tanpa menyimpang dari tujuan awal.

1.2. Perumusan Masalah

Dengan demikian permasalahan dalam penelitian ini adalah :

1. Bagaimana model realisasi penjualan daging di PT. ASJ Surabaya.
2. Bagaimana nilai ramalan penjualan untuk beberapa periode mendatang.

1.3. Tujuan Penelitian

Bertitik tolak dari latar belakang dan permasalahan diatas maka tujuan dari penelitian ini adalah :

1. Menetapkan model realisasi penjualan keempat macam produk yang dihasilkan perusahaan, yaitu *retail, whole sale, offal dan by product*.
2. Menentukan perkiraan penjualan untuk beberapa periode mendatang berdasarkan model yang telah diperoleh.

1.4. Manfaat Penelitian

Manfaat dari penelitian ini adalah memberikan informasi kepada perusahaan tentang kebutuhan daging dimasa mendatang sehingga perusahaan dapat mengambil kebijakan

ساناان mengenai produksi dan bisa membuat strategi marketing yang tepat. Disamping itu dengan mengetahui model penjualan bisa dicari nilai ramalannya untuk beberapa periode mendatang dan perusahaan bisa membuat perencanaan produksi yang lebih efektif tentang jumlah produksi sehingga tidak memproduksi terlalu berlebihan ataupun terlalu sedikit.

1.5. Batasan Masalah

1. Data yang dipergunakan adalah data penjualan bulanan P.T. ASJ untuk produk dari sapi lokal yang dihitung dalam satuan kilogram.
2. Data yang dipakai mulai Januari 1992 sampai Desember 1997.

I
T
S

BAB II

TINJAUAN PUSTAKA

BAB II

TINJAUAN PUSTAKA

2.1. Konsep Dasar Time Series

Time Series adalah serangkaian nilai-nilai pangamatan terhadap suatu variabel yang diamati dari waktu ke waktu dan dicatat sesuai dengan urutan waktu kejadian. Time series ini merupakan fungsi runtun waktu dimana observasi yang dilakukan mempunyai selang waktu yang sama. Secara umum time series pada saat $t_1, t_2, t_3, \dots, t_n$ mempunyai variabel random Z_1, Z_2, \dots, Z_n dengan fungsi distribusi bersama yang bersetujuan $P(Z_1, Z_2, Z_3, \dots, Z_n)$.

Dalam aplikasinya, adakalanya dijumpai kasus yang melibatkan banyak variabel. Dalam kasus ini maka time series yang digunakan adalah model time series multivariate, atau time series yang melibatkan banyak variabel. Vektor variabel randomnya $Z_t = [Z_{t_1}, Z_{t_2}, Z_{t_3}, \dots, Z_{t_n}]$.

2.1.1. Kestasioneran Proses Stokastik

Sekumpulan variabel random $\{Z_{t_1}, Z_{t_2}, Z_{t_3}, \dots, Z_{t_n}\}$ dan suatu proses stokastik $\{Z(w, t); t = 0, \pm 1, \pm 2, \dots\}$, maka fungsi distribusi berdimensi n didefinisikan sebagai:

$$F(z_{t_1}, \dots, z_{t_n}) = P\{w; Z(w, t_1) \leq z_{t_1}, \dots, Z(w, t_n) \leq z_{t_n}\} \quad (2.1)$$

dimana w menyatakan suatu ruang sampel dan t menyatakan suatu indeks waktu.

Proses stokastik diatas dikatakan memiliki sifat stasioner kuat jika probabilitas bersamanya tidak terpengaruh dengan adanya perubahan dari waktu asal yaitu jika probabilitas bersama dari m observasi $Z_{t_1}, Z_{t_2}, \dots, Z_{t_m}$ yang terjadi pada waktu t_1, t_2, \dots, t_m sama dengan m observasi $Z_{t_1+k}, Z_{t_2+k}, \dots, Z_{t_m+k}$ yang terjadi pada waktu $t_{1+k}, t_{2+k}, \dots, t_{m+k}$.

Asumsi kestasioneran membawa implikasi bahwa distribusi probabilitas $P(Z_t)$ sama untuk semua t baik observasi maju maupun mundur sehingga proses memiliki mean dan varian konstan yaitu:

$$\mu_t = \mu = E(Z_t) \quad (2.2)$$

$$\sigma_t^2 = \sigma^2 = E(Z_t - \mu)^2 \quad (2.3)$$

Kovarians antara Z_t dan Z_{t+k} yang terpisah dalam interval waktu k disebut autokovarians pada lag k dan definisikan sebagai :

$$\gamma_k = \text{Cov}(Z_t, Z_{t+k}) = E[(Z_t - \mu)(Z_{t+k} - \mu)] \quad (2.4)$$

Untuk autokorelasi didefinisikan sebagai:

$$\rho_k = \frac{\text{cov}(Z_t, Z_{t+k})}{\sqrt{\text{var}(Z_t)} \sqrt{\text{var}(Z_{t+k})}} \quad (2.5)$$

karena untuk proses yang stasioner,

$$\text{Var}(z_t) = \text{Var}(z_{t+k}) = \gamma_0$$

maka autokorelasi pada lag k adalah

$$\rho_k = \frac{\gamma_k}{\gamma_0} \quad (2.6)$$

untuk proses yang stasioner mempunyai sifat-sifat sebagai berikut:

1. $\rho_0 = \text{Var}(z_t); \rho_0 = 1$
2. $|\gamma_k| \leq \gamma_0; |\rho_k| \leq 1$
3. $\gamma_k = \gamma_{-k}$ dan $\rho_k = \rho_{-k}$ untuk semua k

2.1.2. Proses Autoregresif Dan Proses Moving Average

Dalam time series, terdapat dua cara untuk menyatakan suatu proses yaitu proses autoregresif dan proses moving average. Proses autoregresif menyatakan regresi nilai-nilai dari Z pada waktu t, ditambah dengan suatu kejutan random (aspek error) yaitu,

$$\tilde{z}_t = \pi_1 \tilde{z}_{t-1} + \pi_2 \tilde{z}_{t-2} + \dots + a_t \quad (2.7)$$

$$\text{atau } \pi(B)\tilde{z}_t = a_t \quad (2.8)$$

dimana $\tilde{z}_t = z_t - \mu$ adalah penyimpangan proses dari nilai rata-ratanya, jika proses stasioner, π_i menyatakan bobot atau koefisien, $\pi(B) = 1 - \sum_{j=1}^{\infty} \pi_j B^j$, B menyatakan operator mundur, $B^j x_i = x_{i-j}$.

Proses moving average dinyatakan dengan:

$$\hat{Z}_t = a_t - \psi_1 a_{t-1} - \psi_2 a_{t-2} \quad (2.9)$$

$$\text{atau } \hat{Z}_t = \psi(B) a_t \quad (2.10)$$

dimana ψ_1 menyatakan bobot atau koefisien, dan

$$\psi(B) = 1 - \sum_{j=1}^{\infty} \psi_j B^j.$$

Proses time series yang digambarkan dalam bentuk autoregresive dan hanya sejumlah terbatas bobot π yang tidak sama dengan nol, yaitu $\pi_1 = \phi_1, \pi_2 = \phi_2, \dots, \pi_p = \phi_p$ dan $\pi_k = 0$ untuk $k > p$, maka proses yang dihasilkan disebut proses autoregresive orde p [AR (p)] dan dinyatakan sebagai

$$Z_t = \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} + a_t \quad (2.11)$$

$$\text{atau } \phi_p(B) Z_t = a_t \quad (2.12)$$

$$\text{dimana } \phi_p(B) = (1 - \phi_1 B - \dots - \phi_p B^p)$$

Karena $\sum_{j=1}^{\infty} |\pi_j| = \sum_{j=1}^{\infty} |\phi_j| < \infty$ maka proses autoregresive ini selalu invertible. Kondisi invertible ini dimaksudkan agar proses memiliki arti untuk tujuan proses peramalan. Agar proses menjadi stasioner maka $\phi_p(B) = (1 - \phi_1 B - \dots - \phi_p B^p) = 0$.

Sebagaimana dinyatakan dalam proses autoregresive, maka proses moving average yang hanya memiliki sejumlah

terbatas bobot ψ yang tidak sama dengan nol, yaitu $\psi_1 = -\theta_1, \psi_2 = -\theta_2, \dots, \psi_q = -\theta_q$ dan $\psi_k = 0$ untuk $k > q$, maka proses ini disebut proses moving average orde q [MA(q)] dan dinyatakan dengan

$$\hat{z}_t = a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (2.13)$$

$$\text{atau } \hat{z}_t = \theta(B) a_t \quad (2.14)$$

$$\text{dimana } \theta(B) = (1 - \theta_1 B - \dots - \theta_q B^q)$$

Karena $1 + \theta_1^2 + \dots + \theta_q^2 < \infty$ maka proses MA (q) selalu stasioner. Proses moving average dikatakan invertible jika akar-akar dari $\theta(B) = 0$ berada diluar lingkaran satuan.



2.1.3. Ketidakstasioneran Model Autoregresive Moving Average

Syarat kestasioneran data dalam analisis *time series* dimaksudkan agar memudahkan pada saat melakukan paramalan kondisi-kondisi yang akan datang. Data yang tidak stasioner akan menyebabkan kesalahan dalam penaksiran parameteranya maupun dalam interpretasi hasilnya.

Salah satu cara untuk meredam ketidakstasioneran data adalah dengan melakukan *differencing*. Misal sebuah model dinyatakan sebagai:

$$\varphi(B)Z_t = \theta(B)a_t \quad (2.15)$$

dimana $\varphi(B)$ adalah operator autoregresive non stasioner. Dengan mengambil suatu nilai d sedemikian hingga akar-akar dari $\varphi(B) = 0$ memiliki sifat unik dan berada di luar lingkaran satuan maka persamaan (2.15) dapat ditulis sebagai

$$\varphi(B)Z_t = \phi(B)(1 - B)^d Z_t = \theta(B)a_t \quad (2.16)$$

dimana $\phi(B)$ adalah operator autoregresive non stasioner. Persamaan (2.16) diatas disebut proses autoregresive integrated moving average (ARIMA).

Jika pada persamaan (2.16), operator autoregresive $\phi(B)$ memiliki derajat p , mengambil differencing ke- d dan memiliki operator moving average $\theta(B)$ derajat q maka

proses diatas disebut model ARIMA dengan derajat (p, d, q) dan dinyatakan sebagai:

$$\phi(B)z_t = \phi_p(B)(1 - B)^d z_t = \theta_0 + \theta_q(B)a_t \quad (2.17)$$

2.2. Model Vektor Time Series

2.2.1. Fungsi Matriks Kovarians Dan Matriks Korelasi

Dalam studi empiris sering dijumpai data-data time series yang mengandung lebih dari satu variabel. Pendekatan yang sesuai untuk kasus tersebut adalah dengan metode *multivariate time series*.

Misalkan $z_t = (z_{1,t}, z_{2,t}, \dots, z_{m,t})'$, $t = 0, \pm 1, \pm 2, \dots$ adalah suatu nilai vektor riil bersama sebanyak m dengan vektor rata-rata dapat dinyatakan sebagai

$$E(z_t) = \mu = [\mu_1, \mu_2, \dots, \mu_m]' \quad (2.18)$$

maka matriks kovariansnya berbentuk:

$$\begin{aligned} \Gamma(k) &= \text{Cov}(z_t, z_{t+k}) = E[(z_t - \mu)(z_{t+k} - \mu)'] \\ &= \begin{bmatrix} \gamma_{11}(k) & \gamma_{12}(k) & \dots & \gamma_{1m}(k) \\ \gamma_{21}(k) & \gamma_{22}(k) & \dots & \gamma_{2m}(k) \\ \vdots & \ddots & \ddots & \vdots \\ \vdots & \ddots & \ddots & \vdots \\ \gamma_{m1}(k) & \gamma_{m2}(k) & \dots & \gamma_{mm}(k) \end{bmatrix} \\ &= \text{Cov}(z_{t-k}, z_t) \quad (2.19) \end{aligned}$$

dimana: $\gamma_{ij}(k) = E(z_{i,t} - \mu_i)(z_{j,t+k} - \mu_j) = E(z_{i,t-k} - \mu_i)(z_{j,t} - \mu_j)$
untuk $k = 0, \pm 1, \pm 2, \dots$; $i = 1, 2, \dots, m$; dan $j = 1, 2, \dots, m$. Sebagai fungsi dari k maka $\Gamma(k)$ disebut fungsi matriks kovarians proses vektor Z_t . Jika $i=j$, maka $\gamma_{ii}(k)$ disebut fungsi autokovarians untuk komponen proses z_i ke-i dan jika $i \neq j$, maka $\gamma_{ij}(k)$ adalah fungsi kovarians silang antar $z_{i,t}$ dan $z_{j,t}$.

Fungsi korelasi silang antara $z_{i,t}$ dan $z_{j,t}$ dan dinyatakan dalam bentuk

$$\rho_{ij}(k) = \frac{\gamma_{ij}(k)}{[\gamma_i(0) \gamma_j(0)]^{1/2}} \quad (2.20)$$

2.2.2. Proses Vektor Autoregresive Moving Average

Model sederhana yang sangat berguna dalam analisis time series adalah vektor autoregresive moving average ARMA(p,q) yang dinyatakan dalam

$$\Phi_p(B) z_t = \Theta_q(B) a_t \quad (2.21)$$

$$\Phi_p(B) = \Phi_0 - \Phi_1 B - \Phi_2 B^2 - \dots - \Phi_p B^p \quad (2.22)$$

adalah polinomial autoregresive derajat p dan

$$\Theta_q(B) = \Theta_0 - \Theta_1 B - \Theta_2 B^2 - \dots - \Theta_q B^q$$

adalah polinomial moving average derajat q, Φ_0 dan Θ_0 matriks ukuran $m \times m$ yang non singular.

Jika $p = 0$, maka proses menjadi model vektor MA(q)

$$z_t = a_t - \Theta_1 a_{t-1} - \dots - \Theta_q a_{t-q} \quad (2.23)$$

Dan jika $q = 0$, proses menjadi model vektor AR(p)

$$z_t = \Phi_1 z_{t-1} + \dots + \Phi_p z_{t-p} + a_t \quad (2.24)$$

Proses menjadi stasioner jika determinan polinomial yang sama dengan nol, $|\Phi_p(B)|$ terletak diluar lingkaran satuan. Dalam kasus ini bisa dituliskan:

$$z_t = \psi(B) a_t \quad (2.25)$$

$$\text{dimana: } \psi(B) = [\phi_p(B)]^{-1} \theta_q(B) = \sum_{s=0}^{\infty} \psi_s(B)^s$$

dimana bobot ψ_s adalah dapat dijumlahkan kuadrat dan dapat dicari dengan menyatakan koefisien dari B^j dalam persamaan matriks berikut ini:

$$(I - \Phi_1 B - \Phi_2 B^2 - \dots - \Phi_p B^p)(I + \psi_1 B + \psi_2 B^2 + \dots) = I \quad (2.26)$$

sehingga $\psi_1 = \Phi_1$

⋮

$$\psi_1 = \Phi_1 \psi_{j-1} + \dots + \Phi_p \psi_{j-p}, j \leq p \quad (2.27)$$

Proses menjadi invertibel jika determinan polinomial $|\Theta_q(B)|$ yang sama dengan nol terletak di luar lingkaran satuan sehingga bisa dituliskan

$$\pi(B) z_t = a_t \quad (2.28)$$

$$\pi(B) = [\Theta_q(B)]^{-1} \Phi_p(B) = I - \sum_{s=1}^{\infty} \pi_s B^s \quad (2.29)$$

dimana bobot π_s dapat dicari dengan menyamakan koefisien dan B^s pada

$$\pi(B)\Theta_q(B) = I$$

$$[I - \pi_1 B - \pi_2 B^2 - \dots] [I - \Theta_1 B - \dots - \Theta_q B^q] = I \quad (2.30)$$

sehingga π_s dapat dihitung secara rekursif dari Θ_j sebagai

$$\pi_s = \pi_{s-1}\Theta_1 + \dots + \pi_{s-q}\Theta_q, \quad s = 1, 2, \dots \quad (2.31)$$

dimana: $\pi_0 = 1$ dan $\pi_j = 0$ untuk $j < 0$

2.2.3. Ketidakstasioneran Model Vektor Autoregresive Moving Average

Sebagaimana halnya pada model univariate maka untuk mengatasi adanya ketidakstasioneran data adalah dengan melakukan differencing yang sesuai. Misalnya untuk kasus univariate, suatu data yang tak stasioner z_t dijadikan stasioner dengan $(1 - B)^d z_t$ untuk $d > 0$ sehingga dapat dituliskan:

$$\Phi_p(B)(1 - B)^d z_t = \Theta_q(B)a_t \quad (2.32)$$

dimana $\Theta_q(B)$ adalah operator stasioner AR. Perluasan dari persamaan (2.32) kedalam vektor proses adalah:

$$\Phi_p(B)(I - IB)^d z_t = \Theta_q(B)a_t \quad (2.33)$$

atau sama dengan

$$\Phi_p(B)(I - B)^d z_t = \Theta_q(B)a_t \quad (2.34)$$

Perluasan diatas menunjukkan bahwa semua komponen data di *difference* pada bilangan waktu yang sama. Untuk lebih fleksibelnya, diasumsikan bahwa setiap z_t yang tidak stasioner dapat distasionerkan dengan menggunakan operator differencing, dimana:

$$D(B) = \begin{bmatrix} (1 - B)^{d_1} & & & \\ & (1 - B)^{d_2} & & \\ & & \ddots & \\ & & & (1 - B)^{d_m} \end{bmatrix} \quad (2.35)$$

dengan (d_1, d_2, \dots, d_m) adalah bilangan integer positif.

Sehingga didapatkan model vektor ketidakstasioneran ARMA:

$$\Phi_p(B) D(B) z_t = \Theta_q(B)a_t \quad (2.36)$$

dimana nilai dari $|\Phi_p(B)|$ dan $|\Theta_q(B)|$ yang sama dengan nol terletak di luar lingkaran satuan.



2.2.4. 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 atau struktur dari matriks korelasi sampel dan matriks korelasi parsial, setelah suatu transformasi yang sesuai diterapkan untuk meredam ketidakstasioneran data.

Fungsi Matriks Korelasi Sampel

Bila diberikan suatu vektor time series z_1, z_2, \dots, z_n maka matriks korelasi sampelnya adalah :

$$\hat{\rho}(k) = \begin{bmatrix} \hat{\rho}_{ij}(k) \end{bmatrix} \quad (2.37)$$

$$\hat{\rho}_{ij}(k) = \frac{\sum_{t=1}^{n-k} (z_{i,t} - \bar{z}_i)(z_{j,t+k} - \bar{z}_j)}{\left[\sum_{t=1}^n (z_{i,t} - \bar{z}_i)^2 \sum_{t=1}^n (z_{j,t} - \bar{z}_j)^2 \right]^{1/2}} \quad (2.38)$$

dimana $\hat{\rho}_{ij}(k)$ adalah korelasi silang sampel dari komponen deret ke- i dan j dan \bar{z}_i dan \bar{z}_j adalah rata-rata sampel dari komponen deret data.

Fungsi matriks korelasi sampel sangat berguna dalam menentukan besarnya derajat model moving average. Bila matriks korelasinya bernilai nol setelah lag ke- q maka model yang bersesuaian adalah $MA(q)$.

Metode untuk identifikasi matriks korelasi sampel ini adalah dengan menggunakan simbol +, - dan . pada letak matriks korelasi sampel ke-(ij) dimana:

1. Simbol + menyatakan suatu nilai korelasi silang yang lebih besar dari 2 standard error
2. Simbol - menyatakan suatu nilai korelasi silang yang lebih kecil dari -2 standard error
3. Simbol . menyatakan suatu nilai korelasi silang yang berada diantara 2 standard error

Matriks Parsial Autokorelasi

Sebagaimana pada kasus univariate dimana fungsi autokorelasi parsial digunakan untuk mengidentifikasi derajat model AR(p) maka hal ini juga diterapkan pada kasus multivariate.

Misal $\mathbf{P}(s)$ menyatakan matriks parsial autoregresi pada lag s yaitu koefisien matriks terakhir bila data ditetapkan sebagai suatu proses vektor autoregresive dengan derajat s, maka $\mathbf{P}(s)$ sama dengan $\Phi_{s,s}$ dalam regresi linear multivariate

$$\mathbf{z}_{t+s} = \Phi_{s,1} \mathbf{z}_{t+s-1} + \Phi_{s,2} \mathbf{z}_{t+s-2} + \dots + \Phi_{s,s} \mathbf{z}_t + \mathbf{e}_{s,t+s} \quad (2.39)$$

dimana $\mathbf{e}_{s,t+s}$ adalah error dan koefisien matriks ukuran $m \times m$, $\Phi_{s,k}$; $k = 1, 2, \dots, s$ akan meminimumkan:

$$E \left[|z_{t+s} - \Phi_{s,1} z_{t+s-1} - \dots - \Phi_{s,s} z_t|^2 \right] \quad (2.40)$$

Minimisasi persamaan (2.40) akan membawa ke dalam bentuk persamaan Yule Walker:

$$\begin{bmatrix} \Gamma(0) & \Gamma'(1) & \dots & \Gamma'(s-1) \\ \Gamma(1) & \Gamma(0) & \dots & \Gamma'(s-2) \\ \vdots & \vdots & & \vdots \\ \vdots & \vdots & & \vdots \\ \Gamma(s-1) & \Gamma(s-2) & \dots & \Gamma(0) \end{bmatrix} \begin{bmatrix} \Phi'_{s,1} \\ \Phi'_{s,2} \\ \vdots \\ \vdots \\ \Phi'_{s,s} \end{bmatrix} = \begin{bmatrix} \Gamma(1) \\ \Gamma(2) \\ \vdots \\ \vdots \\ \Gamma(s) \end{bmatrix} \quad (2.41)$$

Definisi Tiao dan Box tentang $\Phi(s)$ akan menyelesaikan persamaan (2.41) untuk $\Phi'_{s,s}$ dan menentukan matriks parsial autoregresi untuk masing-masing derajat dari s yang lebih tinggi. Jika $s \geq 2$ maka

$$A(s) = \begin{bmatrix} \Gamma(0) & \Gamma'(1) & \dots & \Gamma'(s-2) \\ \Gamma(1) & \Gamma(0) & \dots & \Gamma'(s-3) \\ \vdots & \vdots & & \vdots \\ \vdots & \vdots & & \vdots \\ \Gamma(s-2) & \Gamma(s-3) & \dots & \Gamma(0) \end{bmatrix} \quad b(s) = \begin{bmatrix} \Gamma'(s-1) \\ \Gamma'(s-2) \\ \vdots \\ \vdots \\ \Gamma(1) \end{bmatrix}$$

$$c(s) = \begin{bmatrix} \Gamma(1) \\ \Gamma(2) \\ \vdots \\ \vdots \\ \Gamma(s-1) \end{bmatrix} \quad \text{dan } \Phi'_s(s-1) = \begin{bmatrix} \Phi'_{s,1} \\ \Phi'_{s,2} \\ \vdots \\ \vdots \\ \Phi'_{s,s-1} \end{bmatrix} \quad (2.42)$$

$$\begin{bmatrix} A(s) & b(s) \\ b(s) & \Gamma(0) \end{bmatrix} \begin{bmatrix} \Phi'_{s,s-1} \\ \Phi'_{s,s} \end{bmatrix} = \begin{bmatrix} c(s) \\ \Gamma(s) \end{bmatrix} \quad (2.43)$$

dalam hal ini

$$A(s)\Phi'_{s,s-1} + b(s)\Phi'_{s,s} = c(s) \quad (2.44)$$

$$b(s)\Phi'_{s,s-1} + \Gamma(0)\Phi'_{s,s} = \Gamma(s) \quad (2.45)$$

Persamaan (2.44) menghasilkan:

$$\Phi'_{s,s-1} = [A(s)]^{-1}c(s) - [A(s)]^{-1}b(s)\Phi'_{s,s} \quad (2.46)$$

Substitusi persamaan (2.46) pada persamaan (2.45) akan didapatkan $\Phi'_{s,s}$

$$\Phi'_{s,s} = \left\{ \Gamma(0) - b'(s)[A(s)]^{-1}b(s) \right\}^{-1} \left\{ \Gamma(s) - b'(s)[A(s)]^{-1}c(s) \right\} \quad (2.47)$$

Sehingga fungsi matriks parsial autoregresi didefinisikan sebagai berikut:

$$P(s) = \begin{cases} \Gamma'_1[\Gamma'_1]^{-1}, & s=1 \\ \left\{ \Gamma'_s - c'_s[A(s)]^{-1}b(s) \right\} \left\{ \Gamma'_0 - b'_s[A(s)]^{-1}b(s) \right\}^{-1}, & s>1 \end{cases} \quad (2.48)$$

Dari definisi di atas maka jika suatu model adalah AR(p) maka $P(s)$ akan mempunyai sifat-sifat:

$$P(s) = \begin{cases} \phi_p & , s=p \\ 0 & , s>p \end{cases}$$

2.3. Analisis State Space

2.3.1. Konsep Dasar Model State Space (Ruang Keadaan)

Model state space ini direkayasa sedemikian, terutama sekali untuk mengatasi keterbatasan dari teori kontrol konvensional yaitu hanya dapat diterapkan pada sistem linear parameter konstan (*time invariant*) yang mempunyai satu masukan dan satu keluaran.

State variabel (variabel keadaan) adalah himpunan terkecil dari variabel-variabel yang menentukan keadaan sistem dinamik. Jika paling tidak diperlukan n variabel $x_1(t), x_2(t), \dots, x_n(t)$ untuk melukiskan secara lengkap perilaku suatu sistem dinamik sedemikian rupa sehingga setelah masukan $t \geq t_0$ dan syarat awal pada $t = t_0$ maka keadaan sistem yang akan datang telah ditentukan secara lengkap, maka n variabel $x_1(t), x_2(t), \dots, x_n(t)$ tersebut merupakan suatu himpunan variabel keadaan.

Jika diperlukan n variabel keadaan untuk menggambarkan secara lengkap perilaku sistem yang diberikan, maka n variabel keadaan ini dapat dianggap sebagai n komponen suatu vektor $\mathbf{x}(t)$. Vektor semacam ini disebut *State vector* (vektor keadaan).

State Space (ruang keadaan) adalah ruang dimensi n yang sumbu koordinatnya terdiri dari sumbu x_1 , sumbu x_2 , ..., dan sumbu x_n .

Misalkan nilai-nilai observasi dari suatu time series pada waktu t , yaitu z_t adalah fungsi dari satu atau lebih variabel random, misal $y_{t_1}, y_{t_2}, \dots, y_{t_k}$. Variabel ini disebut sebagai state variable (variabel keadaan) dan dapat dinyatakan dalam state vector (vektor keadaan) $\mathbf{y}_t = (y_{t_1}, y_{t_2}, \dots, y_{t_k})'$.

Model sederhana dari hubungan antara z_t dan y_{t_1} adalah dengan mengasumsikan bahwa z_t adalah fungsi linier dari y_{t_1} . Hubungan ini tidak memasukkan aspek error, sehingga hubungan yang lebih fleksibel adalah dengan memasukkan unsur aspek error kedalam persamaannya yaitu:

$$z_t = h_1 y_{t_1} + h_2 y_{t_2} + \dots + h_k y_{t_k} + a_t \quad (2.49)$$

dimana h_i adalah konstanta parameter dan deret a_t adalah unsur gangguan (noise) dengan rataan nol dan varians σ^2 . Dalam bentuk matriks bisa dinyatakan dalam:

$$\mathbf{z}_t = H \mathbf{y}_t + a_t \quad (2.50)$$

dimana H adalah konstanta parameter dalam vektor baris.

Jika variabel keadaan pada saat t , $\mathbf{y}_t = (y_{t_1}, y_{t_2}, \dots, y_{t_k})'$ tergantung pada keadaan sebelumnya, y_{t-1}, y_{t-2} dan seterusnya, maka model untuk vektor keadaan menjadi:

$$\mathbf{y}_t = A \mathbf{y}_{t-1} \quad (2.51)$$

dimana A adalah matriks parameter berukuran $k \times k$.

Hubungan yang lebih fleksibel dari persamaan diatas adalah dengan memasukkan unsur gangguan (*noise*), sehingga persamaan (2.51) dapat dinyatakan dalam:

$$Y_{t+1} = AY_t + Ga_{t+1} \quad (2.52)$$

dimana G adalah koefisien matriks input berukuran $k \times n$. a_t adalah unsur gangguan yang telah bersifat *white noise* ukuran $n \times 1$ dengan kovarians Σ . Jumlah parameter dalam model multivariate bisa menjadi sangat banyak sehingga identifikasinya lebih sulit dibandingkan dengan model univariate.

Jika Z_t adalah proses stokastik, maka bentuk *state space*-nya menjadi:

$$Y_{t+1} = AY_t + Ga_{t+1} \quad (2.53)$$

$$Z_t = HY_t + b_t \quad (2.54)$$

dimana $a_{t+1} = X_{t+1} - E(X_{t+1}|X_t \leq n)$ adalah vektor *error* ramalan satu tahap kedepan dari proses input. X_t dan b_t adalah suatu vektor gangguan ukuran $m \times 1$, yang diasumsikan independen terhadap a_t . Vektor a_{t+1} juga diketahui sebagai inovasi dan input X_t pada waktu $t+1$.

Ketika $Z_t = X_t$, maka faktor b_t hilang dari persamaan (2.54) dan bentuk proses stokastik Z_t yang stasioner yaitu:

$$\begin{cases} Y_{t+1} = AY_t + G a_{t+1} \\ Z_t = H Y_t \end{cases} \quad (2.55)$$

Jadi proses Z_t adalah output dari sistem stokastik yang linier dengan parameter konstan yang dikendalikan oleh input *white noise* a_t sedangkan Y_t diketahui sebagai state dari proses.

2.3.2. Hubungan Antara Model *Statespace* Dengan Model ARMA

Untuk melihat hubungan antara *statespace* dan model ARMA baik untuk kasus univariate maupun multivariate, adalah dengan memandang model vektor ARMA (p, q) yang berdimensi m yang stasioner dengan rataan sama dengan nol

$$\Phi(B)Z_t = \Theta(B)a_t \quad (2.56)$$

$$\text{atau } Z_t = \Phi_1 Z_{t-1} + \dots + \Phi_p Z_{t-p} + a_t - \Theta_1 a_{t-1} - \dots - \Theta_p a_{t-p} \quad (2.57)$$

$$\text{dimana } \Phi(B) = (I - \Phi_1 B - \dots - \Phi_p B^p)$$

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

dan a_t adalah proses white noise dengan mean nol multivari-ate berdimensi m . Penulisan kembali (2.56) dalam suatu bentuk moving average:

$$\begin{aligned} Z_t &= \Phi^{-1}(B)\Theta(B)a_t \\ &= \sum_{j=0}^{\infty} \Psi_j a_{t-j} \end{aligned} \quad (2.58)$$

bila $\Psi_0 = I$,

$$\text{maka didapatkan } Z_{t+1} = \sum_{j=0}^{\infty} \psi_j a_{t+i-j} \quad (2.59)$$

$$\text{misal } Z_{t+1|t} = E[Z_{t+1}|Z_k, k \leq t] \quad (2.60)$$

$$\text{maka } Z_{t+1|t} = \sum_{j=i}^{\infty} \psi_j a_{t+i-j}$$

$$\text{sekarang } Z_{t+1|t} = E[Z_{t+1}|Z_k, k \leq t+1]$$

$$\begin{aligned} &= \sum_{j=(i-1)}^{\infty} \psi_j a_{t+i-j} \\ &= \sum_{j=i}^{\infty} \psi_j a_{t+i-j} + \psi_{i-1} a_{t+1} \end{aligned}$$

$$= Z_{t+i|t} + \psi_{i-1} a_{t+1}$$

$$\text{Jadi } Z_{t+1|t+1} = Z_{t+i|t} + a_{t+1}$$

$$Z_{t+2|t+1} = Z_{t+2|t} + \psi_1 a_{t+1}$$

:

$$Z_{t+p|t+1} = Z_{t+p|t} + \psi_{p-1} a_{t+1}$$

$$\begin{aligned} &= \Phi_p Z_{t|t} + \Phi_{p-1} Z_{t+1|t} + \dots + \Phi_1 Z_{t+p-1|t} + \\ &\quad \psi_{p-1} a_{t+1} \end{aligned}$$

Diasumsikan bahwa $p > q$ dengan menambahkan $\Phi_i = 0$
sehingga didapat

$$Z_{t+p|t} = \Phi_1 Z_{t+p-1|t} + \dots + \Phi_p Z_t$$

$$Z_{t+p+1|t} = \Phi_1 Z_{t+p|t} + \dots + \Phi_p Z_{t+1|t}$$

$$= f(Z_t, Z_{t+1|t} + \dots + Z_{t+p-1|t})$$

Jadi jelas bahwa $z_{t+p-1|t}$ untuk $i \geq 0$ adalah suatu fungsi dari $z_t, z_{t+1|t}, \dots, z_{t+p-1|t}$. Dari sini, vektor state adalah $(z_t, z_{t+1|t}, \dots, z_{t+p-1|t})$ dan bentuk state space dari bentuk vektor ARMA (p, q) adalah dinyatakan dengan:

$$\begin{bmatrix} z_{t+1|t+1} \\ z_{t+2|t+1} \\ \vdots \\ z_{t+p|t+1} \end{bmatrix} = \begin{bmatrix} 0 & I & 0 & 0 & \dots & 0 \\ 0 & 0 & I & 0 & \dots & 0 \\ \vdots & & & \ddots & & \vdots \\ \phi_p & \phi_{p-1} & \dots & \phi_1 & & \end{bmatrix} \begin{bmatrix} z_t \\ z_{t+1|t} \\ \vdots \\ z_{t+p-1|t} \end{bmatrix} + \begin{bmatrix} I \\ \psi_1 \\ \vdots \\ \psi_{p-1} \end{bmatrix} a_{t+1} \quad (2.61)$$

$$z_t = [I_m \ 0 \ \dots \ 0] \begin{bmatrix} z_t \\ z_{t+1|t} \\ \vdots \\ z_{t+p-1|t} \end{bmatrix} \quad (2.62)$$

Dalam rumus (2.62) diatas, komponen m dari vektor state adalah sama dengan z_t .

Jadi secara teoritis, tidak ada perbedaan antara bentuk state space dengan bentuk ARMA dalam suatu proses yang stasioner. Hasil yang didapat dari model state space dapat digunakan untuk model ARMA, demikian juga sebaliknya.

2.3.3. Penetapan Model State Space Dan Analisis Korelasi Kanonik

Bentuk state space yang terdapat pada persamaan-persamaan terdahulu, secara jelas adalah tidak tunggal, sebagai contoh, bila diberikan persamaan (2.55),

didapat bentuk vektor space yang baru $v_t = M Y_t$ untuk sembarang matriks non singular M dan memperoleh suatu bentuk *state space* baru:

$$v_{t+1} = A_1 v_t + G_1 a_{t+1} \quad (2.63)$$

$$\text{dan } z_t = H_1 v_t \quad (2.64)$$

dimana $A_1 = MAM^{-1}$, $G_1 = MG$, dan $H_1 = HM^{-1}$. Tetapi, melalui suatu bentuk kanonik, dapat diperoleh suatu pemecahan yang tunggal. Di dalam bentuk korelasi kanonik, vektor state secara unik dihitung melalui analisis korelasi kanonik antara himpunan pengamatan sekarang dan lampau (*set of current and past observations*) (z_n, z_{n-1}, \dots) dan himpunan nilai-nilai sekarang dan mendatang (*set of current and future values*) (z_n, z_{n+1}, \dots) . Setelah fungsi peramalan akhir dihitung dengan polinomial AR dan $(z_n, z_{n-1}, \dots, z_{n-p})$ memuat semua informasi penting yang berkaitan dengan nilai-nilai masa datang (*future values*) dari proses, analisis korelasi kanonik secara sederhana ditentukan antara ruang data

$$D_n = (z_n, z_{n-1}, \dots, z_{n-p})$$

dan ruang prediktor

$$F_n = (z_n, z_{n+1|n}, \dots, z_{n+p|n})$$

Pandang suatu matriks blok *Hanzel* untuk kovariansi antara

D_n dan F_n yang didefinisikan sebagai berikut:

$$\Gamma = \begin{bmatrix} \Gamma(0) & \Gamma(1) & \dots & \Gamma(p) \\ \Gamma(1) & \Gamma(2) & \dots & \Gamma(p+1) \\ \vdots & \vdots & \ddots & \vdots \\ \Gamma(p) & \Gamma(p+1) & \dots & \Gamma(2p) \end{bmatrix} \quad (2.65)$$

Melalui suatu ekspektasi bersyarat dapat ditunjukkan bahwa $\text{Cov}(z_{n-1}, z_{n+j}|n) = \text{Cov}(z_{n-1}, z_{n+j})$. Bila $\Gamma(0)$ diasumsikan non singular, untuk model umum vektor ARMA, rank Γ sama dengan dimensi dari vektor space. Rank Γ ini akan sama juga dengan banyaknya korelasi kanonik yang tidak sama dengan nol antara D_n dan F_n .

Ketika model telah diketahui, pemilihan derajat p diperoleh dari data yang mempunyai pengepasan (*fitting*) AR yang optimal, yang mana biasanya didasarkan pada nilai AIC (*Akaike's Information Criterion*), yang didefinisikan sebagai:

$$AIC = n \ln |\Sigma_p| + 2pm^2 \quad (2.66)$$

dimana: n = banyaknya observasi

$|\Sigma_p|$ = determinan dari matriks kovarians untuk inovasi atau deret white noise dari AR(p) yang ditetapkan, dan

m = dimensi proses vektor Z_t

Derajat p dari AR yang optimal adalah dipilih sedemikian



hingga AIC minimum. Jadi, analisis korelasi kanonik akan didasarkan pada matriks blok *Hanzel* kovarians sampel, yaitu

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

dimana $\hat{\Gamma}(j)$, $j = 0, 1, \dots, 2p$ adalah matriks kovarian sampel.

Oleh karena komponen-komponen vektor prediksi $Z_{n+1|n}$ kemungkinan dependen linier, analisis korelasi kanonik dilakukan antara semua komponen dari ruang data:

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

dan komponen-komponen dari ruang prediktor:

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

Karena vektor state diketahui sebagai himpunan bagian dari ruang prediktor, suatu deret dari vektor space yang potensial, Y_n^j , adalah dihitung melalui suatu analisis korelasi kanonik antara deret F_n^j dengan ruang

data D_n , yang didasarkan pada sub matriks $\hat{\Gamma}^{jj}$ yang diben-

tuk dari kolom-kolom $\hat{\Gamma}$, yang berkorespondensi dengan komponen-komponen D_n dan F_n^j .

Lebih khususnya, oleh karena korelasi kanonik antara $Z_n = [Z_{1,n}, Z_{2,n}, \dots, Z_{m,n}]$ dan D_n adalah 1, ..., 1 yang tidak nol, maka vektor statenya disesuaikan dengan Z_n , dan himpunan bagian yang pertama dari F_n^j disesuaikan dengan $[Z_{1,n}, Z_{2,n}, \dots, Z_{m,n}, Z_{1,n+1|n}]$. Jika korelasi terkecil dari $\hat{\Gamma}$ ditetapkan sama dengan nol, maka kombinasi linier F_n^j tidak berkorelasi dengan ruang data D_n . Jadi, komponen $Z_{1,n+1|t}$ dan sembarang $Z_{1,n+1|t}$ dikeluarkan dari vektor state dengan 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 dalam analisis korelasi kanonik, korelasi kanonik yang signifikan, ρ_{\min} , adalah didasarkan pada nilai AIC berikut:

$$C = -n \ln(1 - \rho_{\min}^2) - 2[m(p + 1) - q + 1] \quad (2.67)$$

dimana q adalah dimensi dari F_n^j pada tahap yang bersesuaian. Jika $C < 0$, ρ_{\min} ditetapkan sama dengan nol. Untuk menguji signifikansi dari korelasi kanonik ρ , maka

dapat digunakan uji χ^2 , dengan hipotesa sebagai berikut:

H_0 : Korelasi kanonik adalah sama dengan nol.

H_1 : Korelasi kanonik tidak sama nol

Statistik ujinya adalah:

$$\chi^2 = -[n - \frac{1}{2} \{m(p+1) + q + 1\}] \ln(1 - p^2) \quad (2.68)$$

adalah suatu pendekatan *Chi-Square* dengan derajat bebas $[m(p+1)-q+1]$, dimana m adalah jumlah variabel, p adalah jumlah lag minimum, q adalah dimensi dari F_n^1 pada tahap yang bersesuaian, dan n adalah banyaknya observasi.

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

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

$$Z_t = H Y_t \quad (2.69)$$

dimana a_t adalah deret vektor white noise normal dengan rataan nol dan matriks varians-kovarians Σ , $N(0, \Sigma)$ serta $H = [I_m, 0]$ dimana I_m adalah matriks identitas $m \times m$.

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

Pemilihan model pada deret multivariate lebih serampangan dibandingkan dengan kasus univariate,

meskipun matriks autokorelasi memberikan petunjuk ekstra. Sebagai contoh jika matriks autokorelasi tidak mengecil pada lag yang lebih besar maka satu atau lebih variabel dapat *di-deferencing* secara sendiri-sendiri meskipun metode *state space* dapat mengepaskan model secara langsung dari data yang ada yang tidak stasioner.

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

$$Y_t = (I - AB)^{-1}G a_t \quad (2.70)$$

didapat: $Z_t = H(I - AB)^{-1}G a_t$

$$a_t = [H(I - AB)^{-1}G]^{-1} Z_t \quad (2.71)$$

Jadi, fungsi *log-likelihoodnya* menjadi:

$$\ln L(A, G, \Sigma | Z_1, Z_2, \dots, Z_n) \propto -\frac{n}{2} \ln |\Sigma| - \frac{1}{2} \text{tr} \Sigma^{-1} S(A, G)$$

$$S(A, G) = \sum_{t=1}^n a_t a_t'$$

Analisis korelasi kanonik menyediakan taksiran awal prosedur penaksiran nilai A , G , dan Σ yang lebih efisien ini. Di dalam proses penaksirannya nilai A dan G dapat ditetapkan sebagai suatu konstanta, misalnya nol atau satu.

2.4. Pemeriksaan Model Dan Peramalan

Pada tahap pemeriksaan model terdiri dari dua bagian yaitu uji multivariate normal residual dan pemeriksaan pola residual.

2.4.1. Uji Multivariate Normal Residual

Salah satu tahapan dalam pemeriksaan model ini adalah dengan melakukan pengujian terhadap pola distribusi residual model. Apabila residual yang bersesuaian ini berdistribusi multivariate normal maka hal ini menjamin bahwa data penelitian yang dipakai benar-benar dari suatu proses yang stasioner. Uji multivariate normal dilakukan dengan mencari nilai kuadrat untuk setiap pengamatan yaitu :

$$d_j^2 = (X_j - \bar{X})' S^{-1} (X_j - \bar{X}) \quad (2.73)$$

Kemudian diurutkan dari kecil kebesar (sebagai absisnya), dan diplotkan dengan $\chi^2_{(\alpha, (i-0.5)/n)}$ (sebagai ordinat) dimana $i=1, 2, \dots, n$; dan n = banyaknya observasi.

Uji multivariate normal dapat juga dilakukan dengan :

$$P((x - \mu)' \Sigma^{-1} (x - \mu) \leq \chi^2_{(p; 0.5)}) = 0.5$$

Dimana p = jumlah variabel dan μ = rata-rata. Bila 50% dari sampel yang digunakan terletak dalam ellips untuk semua x , sehingga $(x - \mu)' \Sigma^{-1} (x - \mu) \leq \chi^2_{(p; 0.5)}$, maka residual berdistribusi multivariate normal.

Adapun uji hipotesa yang digunakan adalah :

H_0 = Residual berdistribusi multivariate normal

H_1 = Residual tidak berdistribusi multivariate normal

2.4.2. Pemeriksaan Residual

Pemeriksaan residual ini dilakukan dengan melakukan kembali prosedur state space terhadap deret residualnya:

$$\begin{aligned} E_{t+1} &= Z_{t+1} - Z_t(1) \\ &= Z_{t+1} - HA\hat{y}_t \\ &= HY_{t+1} + b_{t+1} - HA\hat{Y}_t \\ &= H(Y_{t+1} - A\hat{y}_t) + b_{t+1} \end{aligned}$$

Apabila deret residual ini tidak mempunyai model state space yang jelas dan tertentu, maka dapat dijamin bahwa residual ini white noise. Dengan demikian model peramalan yang ditapkan sudah memadai untuk digunakan.

2.4.3. Peramalan

Sekali suatu model state space dibentuk, maka ramalan satu tahap kedepan dari peramalan asli (original) waktu ke-t dapat dihitung sebagai berikut :

$$\hat{y}_t(1) = E(Y_{t+1}/Y_j, j \leq t)$$

$$= A\hat{y}_t(1 - 1)$$

$$\begin{aligned}
 &= A + A \hat{Y}_t(\ell - 2) \\
 &\vdots \\
 &= A^\ell \hat{Y}_t
 \end{aligned} \tag{2.76}$$

Sehingga

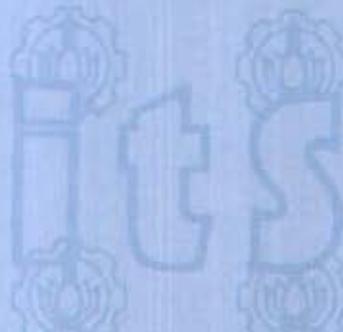
$$\begin{aligned}
 z_t(\ell) &= E(z_{t+\ell} | Z_t, j \leq t) = H \hat{Y}_t(\ell) \\
 &= H A^\ell \hat{Y}_t
 \end{aligned} \tag{2.77}$$

$$\text{dimana } \hat{Y}_t = E(Y_t | Y_j, j \leq t)$$

Dari persamaan diatas jelaslah bahwa keandalan dari peramalan $\hat{z}_t(\ell)$ tergantung pada kualitas estimasi \hat{Y}_t dari vektor state Y_t yang mana menyimpulkan informasi dari nilai terakhir yang dibutuhkan untuk peramalan periode berikutnya.

Matriks error peramalannya adalah:

$$\begin{aligned}
 e_{t+1} &= z_{t+1} - \hat{z}_t(1) \\
 &= HY_{t+1} + b_{t+1} - HA \hat{Y}_t \\
 &= H(Y_{t+1} - AY_t) + b_{t+1}
 \end{aligned} \tag{2.78}$$



BAB III

BAHAN DAN METODOLOGI PENELITIAN

BAB III

BAHAN DAN METODOLOGI PENELITIAN

3.1. Bahan Penelitian

Data yang digunakan dalam penelitian ini merupakan data sekunder yang berupa data bulanan realisasi penjualan produk PT. ASJ Surabaya mulai bulan januari 1992 sampai November 1997. Variabel-varibel yang digunakan dalam penelitian ini meliputi :

1. Z_1 = Retail cuts yang meliputi tenderloin, minceed beef, cxtail, sirloin, rawonan, tenderbone steak, tetelan yang diukur dalam satuan kilogram.
2. Z_2 = Whole sale cuts yang meliputi sirloin, topside, rump, silverside, inside, leg, brisket, chuck, blade, flank, dan shank yang diukur dalam satuan kilogram.
3. Z_3 = Offal meliputi hati, babat, usus, paru, jantung, limpha dan lemak diukur dalam satuan kilogram.
4. Z_4 = By product meliputi kepala, kulit, kikil, phenis, gurung dan tulang diukur dalam satuan kilogram juga.

Untuk keperluan pengolahan data digunakan beberapa paket program statistik yaitu untuk analisis utama digunakan paket SAS, sedang untuk penunujang digunakan paket Minitab dan Statgraph.

3.2. Metode Pengolahan Data

Analisis dan pemodelan terhadap pengamatan yang beruntun dari masa lalu dan bergantung pada waktu dianalisis dengan analisis *time series*. Karena pengamatan dilakukan atas beberapa variabel yang saling terkait maka pendekatan yang dipakai adalah analisis *multivariate time series* dengan model *state space*. Metode ini digunakan untuk peramalan pada masa mendatang secara bersama-sama antar variabel.

Tahap Identifikasi Bentuk Model

Tahap identifikasi bentuk model ini dimulai dari menyiapkan deret input berupa data multivariate yang telah dikumpulkan. Langkah berikutnya adalah membuat plot data asli dan melihat statistik deskriptif dari variabel yang bersesuaian.

Pokok dari tahap ini adalah menetapkan matrik korelasi dan matrik autokorelasi parsial dari deret input. Berdasarkan struktur MACF dan MPACF serta didukung oleh pengamatan terhadap data dan statistik diskriptifnya maka dapat diindikasikan data telah stasioner atau tidak. Jika data tidak stasioner dalam varians maka dilakukan transformasi, sedang jika tidak stasioner dalam mean maka dilakukan pembedaan (*differencing*).

Tahap Penaksiran

Dengan didasarkan pada struktur MACF dan MPACF dari data yang telah stasioner, serta ditunjang oleh perhitungan nilai AIC yang minimum maka dapat ditetapkan model ARMA pendahuluan. Model yang diperoleh disini merupakan model sementara karena asumsi kelayakannya belum diuji.

Tahap Pemeriksaan Diagnostik

Pemeriksaan diagnostik ini dilakukan dalam dua bagian. Pertama pemeriksaan dilakukan terhadap keacakan deret residual yang dihasilkan. Pemeriksaan kedua adalah pemeriksaan yang dilakukan untuk mengamati apakah masih ada korelasi antara residual variabel yang satu dengan residual variabel yang lain atau dengan kata lain untuk mengetahui apakah residualnya telah bersifat white noise.

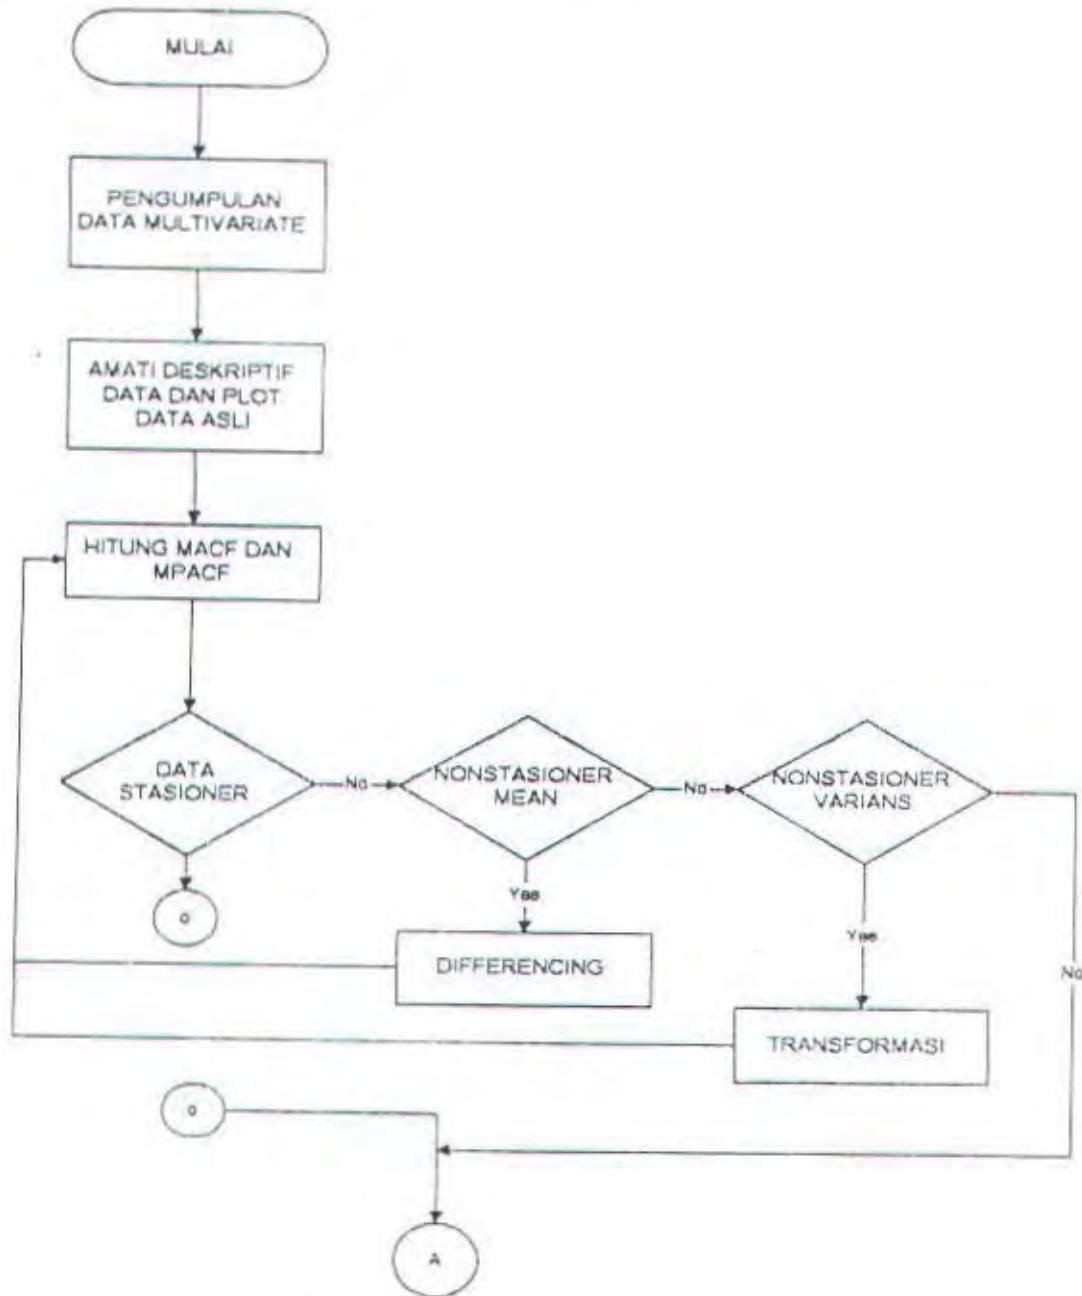
Tahap Peramalan

Berdasarkan model terbaik yang diperoleh dari tahap pemeriksaan diagnostik dilakukan peramalan.

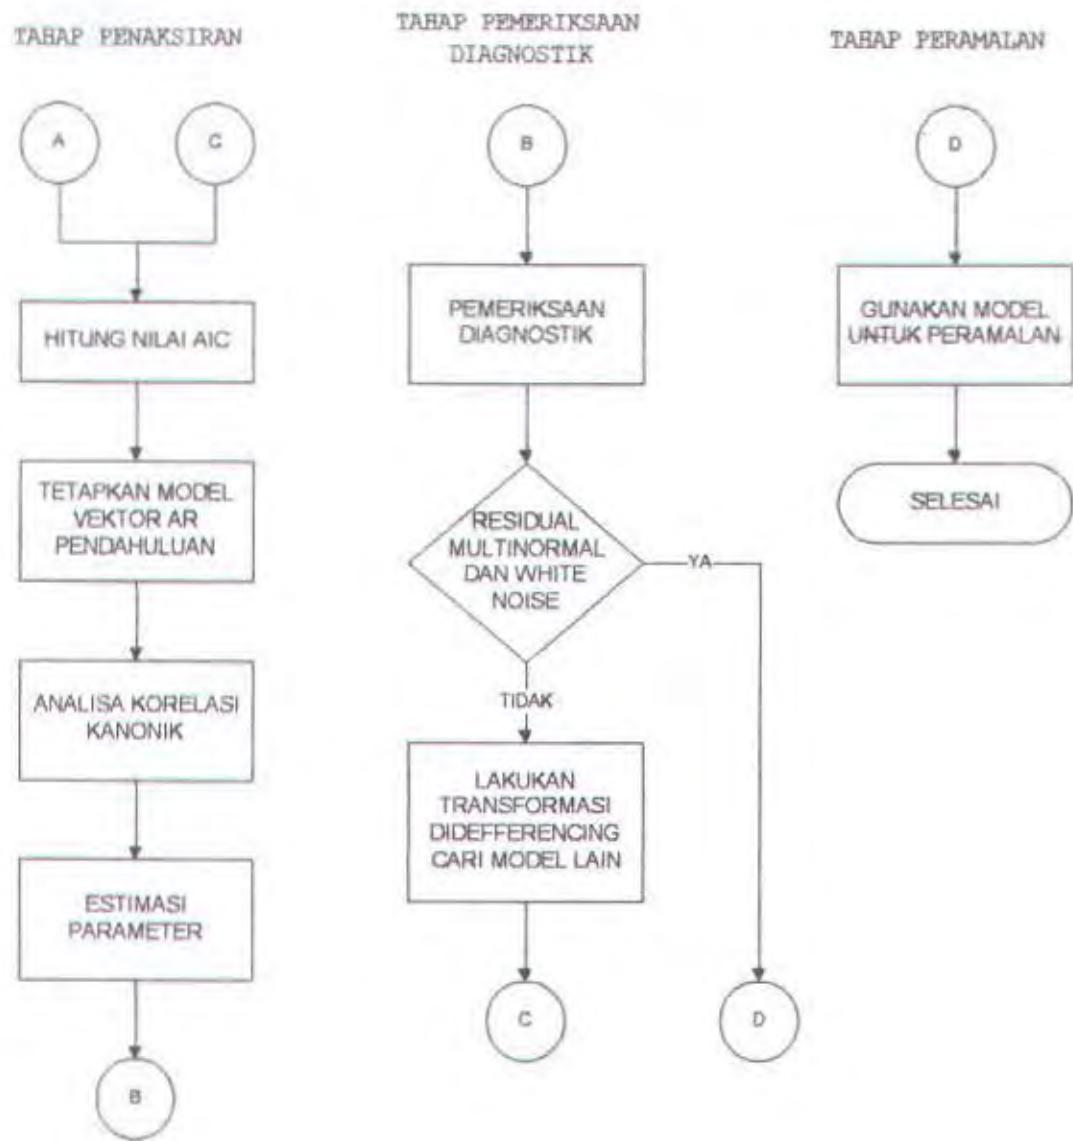
Untuk diagram alir tentang metode pengolahan data ini dapat dilihat pada gambar 3.1. dan gambar 3.2.



TAHAP IDENTIFIKASI



Gambar 3.1 Algoritma metode deret berkala Box-Jenkins



Gambar 3.2 Algoritma metode deret berkala Box-Jenkins (Lanjutan)



BAB IV

ANALISIS DAN PEMBAHASAN

BAB IV

ANALISIS DAN PEMBAHASAN

4.1. Tahap Identifikasi Model

Dalam penelitian ini menggunakan data *multivariate time series* yang terdiri dari empat buah variabel yaitu *Retail cuts* (Z_1), *Whole sale cuts* (Z_2), *Offal* (Z_3) dan *By product* (Z_4). Keempat variabel tersebut disebut sebagai variabel deret input, adapun deskripsi dari masing-masing variabel tersebut dapat dilihat pada tabel berikut :

Tabel 4.1. Deskripsi data jumlah penjualan daging

Variabel	Rata-rata(Kg)	st. dev	std/mean
<i>Retail</i>	7894.518	3868.006	0.48996
<i>WSC</i>	9532.249	4644.557	0.48724
<i>Offal</i>	1436.092	602.411	0.41947
<i>Byproduk</i>	3235.606	1540.985	0.47625

Dari tabel diatas tampak bahwa rata-rata penjualan tertinggi adalah produk *whole sale cuts* (Z_2), sedangkan rata-rata penjualan terendah adalah produk *offal* (Z_3).

Berdasarkan deskripsi data diatas dapat diketahui bahwa keempat variabel secara multivariate sudah stasioner yaitu dapat dilihat dari nilai-nilai standar

deviasi dibagi rata-ratanya yang lebih kecil dari 0.5 sehingga tidak diperlukan lagi transformasi ataupun pembedaan (*differencing*). Untuk pemeriksaan lebih lanjut mengenai deret input apakah telah stasioner secara multivariate atau belum akan dilakukan pada identifikasi model dan tahap pemeriksaan diagnostik.

Identifikasi model *multivariate time series* dilakukan dengan mengamati pola fungsi matriks korelasi (MACF) dan pola fungsi matriks autokorelasi parsial (MPACF). Karena besar dimensi matriks (4x4), maka pola fungsi matriks korelasi data penelitian ini cukup sulit untuk dikenali secara langsung, maka digunakan simbol (+), (-), dan (.) untuk menggambarkan posisi matriks korelasi sampel, seperti yang disarankan oleh Tiao dan Box (1981).

Dengan menetapkan perhitungan sampai lag kesepuluh, maka representasi skematik dari fungsi matriks korelasi adalah sebagai berikut :

Tabel 4.2. Representasi skematik korelasi deret data

Name/Lag	0	1	2	3	4	5	6	7	8	9	10
Retail	+.+	+..	+..	+..	...-	...-	...-	...-	...-	...-	...
WSC	.-.	+.+	+.+	+.+	+.+	+.+	+.+	+.+	+.+	+.+	+.+
Offal	.-.	...-	...-	...-	...-+
By produk	...+	...+	...+	...+	...+

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

Berdasarkan struktur skematik diatas dapat dilihat bahwa fungsi matriks korelasi telah *signifikan* (yaitu lebih besar dari 2 *standard error*) dan dapat diketahui bahwa deret input berasal dari proses *autoregresi* yang stasioner. Untuk mengetahui besarnya orde p dari proses autoregresi ditentukan dengan mengamati struktur skematik autokorelasi parsial yang terlihat pada tabel berikut :

Tabel 4.3. Representasi skematik autokorelasi parsial

Name/Lag	1	2	3	4	5	6	7	8	9	10
z1	+	-	-	-	-	-	-	-	-	-
z2	+	-	-	-	-	-	-	-	-	-
z3	+	-	-	-	-	-	-	-	-	-
z4	+	-	-	-	-	-	-	-	-	-

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

Dari representasi skematik autokrelasi parsial tersebut terlihat nilai korelasi yang *signifikan* memencil pada lag pertama (lebih besar dari 2 *standard error*) kemudian *cut off* pada lag-lag selanjutnya dan masing-masing variabel saling berkorelasi. Hal ini mengindikasikan bahwa deret input berasal dari proses autoregresi dengan order yang optimal 1 atau AR(1).

4.2. Tahap Penaksiran

4.2.1. Model Multivariate Autoregresi Pendahuluan

Pada tahap sebelumnya yaitu tahap identifikasi telah diperoleh model pendahuluan yaitu model AR(1). Untuk menetapkan derajat p pada model autoregresi dapat pula digunakan nilai AIC (*Akaike's Information Criterion*). Dari nilai AIC pada lag tertentu yang mempunyai nilai paling kecil akan didapatkan derajat p untuk model AR yang optimal.

Nilai AIC untuk model autoregresi dengan besar lag antara lag 0 sampai lag 10 adalah sebagai berikut :

Tabel 4.4. Nilai AIC

Lag	AIC	Lag	AIC
0	4391.596464	6	4390.493095
1	4318.818895	7	4415.804954
2	4327.109780	8	4426.785892
3	4347.857251	9	4430.165787
4	4365.817959	10	4435.324397
5	4374.552063		

Dari tabel diatas terlihat bahwa nilai AIC minimum terdapat pada lag 1 yaitu sebesar 4318.818895. Jadi dapat diambil kesimpulan bahwa model autoregresi yang didapatkan adalah AR(1). Hal ini sejalan dengan identifikasi dari struktur autokorelasi parsial yang menunjukkan bahwa model pendahuluannya adalah AR(1).

Bentuk umum dari model vektor AR(1) adalah sebagai berikut :

$$z_t = \phi_1 z_{t-1} + \dots + \phi_p z_{t-p} + a_t$$

$$\text{atau } \phi_p(B) z_t = a_t$$

$$\text{dimana } \phi_p(B) = (1 - \phi_1 B - \dots - \phi_p B^p)$$

Taksiran Yule-Walker untuk nilai matriks ϕ adalah :

$$\begin{bmatrix} 0.24676 & -0.16565 & 0.51493 & 0.45058 \\ -0.05225 & 0.71026 & -0.25778 & -0.16481 \\ 0.00092 & -0.05859 & 0.16188 & -0.01475 \\ 0.02975 & -0.02437 & -0.00527 & 0.57352 \end{bmatrix}$$

Parameter autoregresi yang diestimasi sebenarnya sudah dapat digunakan untuk keperluan peramalan, akan tetapi peramalan yang dilakukan pada penelitian ini tidak akan didasarkan pada model autoregresi ini, oleh sebab itu model ini dinyatakan sebagai model pendahuluan. Meskipun demikian model ini memberikan landasan yang baik dalam pembentukan model lebih lanjut.

Fase Korelasi Kanonik

Melalui analisis korelasi kanonik akan ditentukan vektor state yang akan masuk dalam model. Berdasarkan model pendahuluan AR(1), analisis kanonik diterapkan pada

ruang data $D = \{z_n, z_{n-1|n}\}$ dan ruang prediktor $E = \{z_n, z_{n+1|n}\}$. Meskipun $(z_{n+1|n})$ merupakan elemen potensial dalam vektor state tetapi harus dilakukan pengujian apakah layak dimasukkan dalam final state vektor. Hasil analisa korelasi kanonik secara keseluruhan dapat dilihat pada tabel 4.5.

Tabel 4.5. Analisa korelasi kanonik

State vector	Correlations	Infor.	Chisq	D.F.
$z_1(T;T), z_2(T;T), z_3(T;T), z_4(T;T), z_1(T+1;T)$	1.0000 1.0000 1.0000 1.0000 0.2658	-2.79636	5.057059	4
$z_1(T;T), z_2(T;T), z_3(T;T), z_4(T;T), z_2(T+1;T)$	1.0000 1.0000 1.0000 1.0000 0.3646	-2.12505	5.839038	4
$z_1(T;T), z_2(T;T), z_3(T;T), z_4(T;T), z_3(T+1;T)$	1.0000 1.0000 1.0000 1.0000 0.2035	-4.99768	2.91775	4
$z_1(T;T), z_2(T;T), z_3(T;T), z_4(T;T), z_4(T+1;T)$	1.0000 1.0000 1.0000 1.0000 0.2697	-2.63671	5.212212	4

Dari analisa korelasi kanonik pada tabel diatas kemudian dilakukan pengujian untuk setiap state. Pada saat $z_1(t+1;t)$ dimasukkan dalam vektor state diperoleh nilai korelasi kanonik sebesar 0.2658 dengan nilai AIC sebesar -2.79636 dan karena nilai AIC bernilai negatif maka $z_1(t+1;t)$ tidak dimasukkan kedalam vektor state. Hal ini juga didukung oleh uji chisquare dari Bartlet dimana statistik uji chisquare hitung = 5.057059 lebih kecil dari χ^2 tabel ($\alpha=5\%$, $db=4$) yaitu = 9.488, demikian seterusnya.

Dari hasil korelasi kanonik diatas maka vektor state finalnya adalah sebagai berikut :

$$\begin{cases} Z_{1,t} = \text{Refail cuts (T:T)} \\ Z_{2,t} = \text{White sale cuts (T:T)} \\ Z_{3,t} = \text{Offal (T:T)} \\ Z_{4,t} = \text{By product (T:T)} \end{cases}$$

Penaksiran Parameter

Selain vektor state ditetapkan, maka penaksiran parameter tiga model state spacenya dapat dilakukan. Bentuk umum state space dari data penjualan produk adalah

$$\begin{array}{|c|c|c|c|} \hline & Z_{1,t+1} & Z_{2,t+1} & Z_{3,t+1} \\ \hline Z_{1,t+1} & = \tilde{A} & Z_{2,t} & + G & a_{1,t+1} \\ \hline Z_{2,t+1} & & Z_{3,t} & & a_{2,t+1} \\ \hline Z_{3,t+1} & & Z_{4,t} & & a_{3,t+1} \\ \hline \end{array}$$

dengan $a_{1,t+1}, a_{2,t+1}, a_{3,t+1}$ adalah vektor white noise.

Persamaan besarnya matrik transisi (A) dan matrik koefisien (G) adalah :

$$A = \begin{vmatrix} 0.247 & -0.166 & 0.515 & 0.451 \\ -0.052 & 0.710 & -0.258 & -0.165 \\ 0.001 & 0.059 & 0.162 & 0.015 \\ 0.4030 & 0.024 & -0.005 & 0.574 \end{vmatrix}$$

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

Untuk hasil penaksiran parameter awal secara keseluruhan dapat dilihat pada tabel 4.6.

Tabel 4.6. Penaksiran parameter awal

Parameter	Estimate	Std. Err.	T value
F(1,1)	0.246762	0.113784	-1.71179
F(1,2)	-0.16565	0.096769	2.168686
F(1,3)	0.514931	0.433784	1.187068
F(1,4)	0.45058	0.270653	1.664789
F(2,1)	-0.05225	0.101645	-0.51407
F(2,2)	0.710262	0.086445	8.216359
F(2,3)	-0.25778	0.387945	-0.66446
F(2,4)	-0.16481	0.241866	-0.6814
F(3,1)	0.000923	0.030094	0.030678
F(3,2)	-0.05859	0.025592	-2.28922
F(3,3)	0.161877	0.115362	1.403199
F(3,4)	-0.01475	0.071707	-0.20563
F(4,1)	0.02975	0.042478	0.700359
F(4,2)	-0.02437	0.036125	5.668044
F(4,3)	-0.00527	0.162671	-0.03237
F(4,4)	0.573519	0.101185	-0.67458

Langkah berikutnya adalah melakukan pengujian terhadap nilai-nilai parameter pada taksiran awal untuk menentukan apakah parameter tersebut layak dipertahankan dalam model yang diperoleh. Pengujian dilakukan terlebih dahulu terhadap parameter yang mempunyai harga mutlak statistik ujinya paling kecil yaitu F(3,1) yang mempunyai nilai $T_{hitung} = 0.030678$.

Dengan melakukan hipotesa :

$$H_0 : F(3,1) \text{ tidak signifikan}$$

$$H_1 : F(3,1) \text{ signifikan}$$

dan dengan $\alpha = 5\%$, derajat bebas 71 diperoleh $t_{tabel} = 1.9939$.

Karena T_{hitung} lebih kecil dari t_{tabel} maka disimpulkan H_0 diterima yang artinya parameter $(3,1)$ tidak layak dipertahankan dalam model. Demikian seterusnya dilakukan pengujian untuk parameter-parameter yang lain hingga tidak ditemukan lagi parameter yang nilainya tidak signifikan.

Adapun hasil akhir dari taksiran parameter setelah dilakukan penaksiran yang berulang-ulang dapat dilihat pada tabel 4.7.

Tabel 4.7. Penaksiran parameter akhir

Parameter	Estimate	Std. Err.	T value
F(1,2)	0.299632	0.110086	2.721811
F(2,2)	0.748998	0.077066	9.718911
F(3,2)	-0.06945	0.024262	-2.86264
F(4,2)	0.591609	0.09016	6.561792

Dengan demikian model state space akhir adalah :

$$Z_{1,t} = 11534.223 + 0.299632 Z_2$$

$$Z_{2,t} = 592.620 + 0.748998 Z_2$$

$$Z_{3,t} = 2098.127 - 0.06945 Z_2$$

$$Z_{4,t} = 3013.042 + 0.591604 Z_2$$

dimana nilai matriks transisi (A), matrik input untuk inovasi (G) dan matriks varians untuk inovasi (Σ) adalah sebagai berikut :

$$A = \begin{vmatrix} 0.000 & 0.300 & 0.000 & 0.000 \\ 0.000 & 0.749 & 0.000 & 0.000 \\ 0.000 & -0.069 & 0.000 & 0.000 \\ 0.000 & 0.592 & 0.000 & 0.000 \end{vmatrix}$$

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

$$\Sigma = \begin{vmatrix} 13284847 & -38887.535 & 281112.112 & 555820.386 \\ -38887.535 & 10268278.7 & -100119.48 & 1460149.38 \\ 281112.112 & -100119.48 & 904243.148 & -68508.97 \\ 555820.386 & 1460149.38 & -68508.97 & 1783778.31 \end{vmatrix}$$

Dari model diatas dapat diinterpretasikan sebagai berikut, Jumlah penjualan *retail cuts* akan berubah satu satuan pada bulan depan, dipengaruhi oleh kenaikan jumlah penjualan *whole sale cuts* pada bulan ini sebesar 0.3 satuan.

Untuk jumlah penjualan *whole sale cuts* akan berubah satu satuan pada bulan depan, dipengaruhi oleh kenaikan jumlah penjualan *whole sale cuts* pada bulan ini sebesar 0.749 satuan.

Jumlah penjualan *offal* akan berubah satu satuan pada bulan depan, karena dipengaruhi oleh kenaikan jumlah penjualan *whole sale cuts* pada bulan ini sebesar -0.069 satuan.

Untuk jumlah penjualan *by product* akan berubah satu satuan pada bulan depan, dipengaruhi oleh kenaikan jumlah penjualan *whole sale cuts* pada bulan ini sebesar 0.592 satuan.

4.1.2. Tahap Pemeriksaan *Diagnostic*

Pengujian Multivariate Normal Residual

Untuk mengetahui apakah residual model mempunyai distribusi multivariate normal atau tidak, dilakukan uji multinormal dengan hipotesa

H_0 = data berdistribusi multivariate normal

H_1 = data tidak berdistribusi multivariate normal

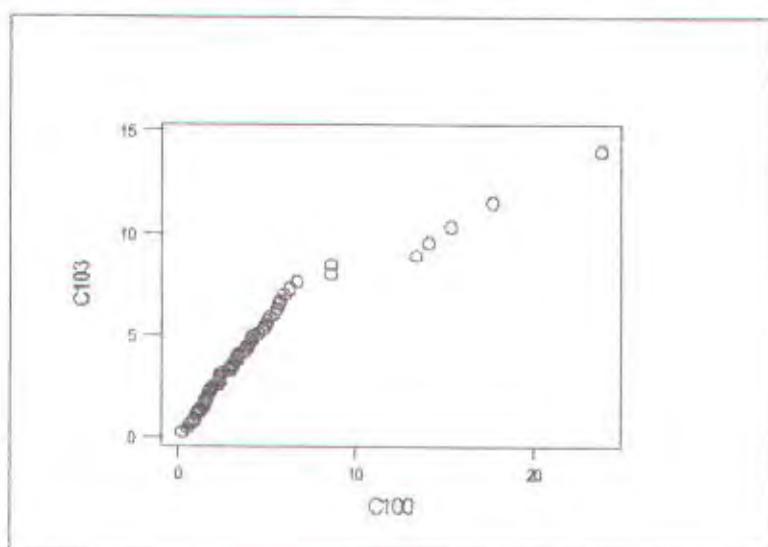
dengan menghitung nilai dj^2 dan diperoleh nilai-nilai sebagai berikut :

2.1616	0.4012	0.5167	0.7036	0.7520	0.8738	0.9578
0.9832	1.0753	1.1027	1.1606	1.1825	1.3223	1.3761
1.4242	1.4511	1.4675	1.5163	1.5598	1.6080	1.6198
1.6553	1.7508	1.7606	1.7904	1.9114	2.1412	2.2117

2.2580	2.2613	2.2916	2.3210	2.3421	2.7665	2.8387
2.9226	2.9596	2.9840	3.0561	3.1680	3.2036	3.2199
3.2637	3.4996	3.6809	3.8123	3.8227	3.8756	3.9768
4.0477	4.1627	4.4746	4.6406	4.7298	4.8211	4.9703
5.0315	5.3508	5.4550	5.5524	5.6984	5.8309	6.1890
6.5990	8.5320	8.5542	13.3809	14.0673	15.3312	17.7501
23.8372						

dari tabel *chisquare* dengan $\alpha = 50\%$ dan derajat bebas 4 diperoleh $\chi^2 = 3.35669$

Jika banyaknya nilai-nilai $d_j^2 < \chi^2$ tabel ada sebanyak 50% maka dikatakan data tersebut berdistribusi *multivariate normal*. Ternyata nilai-nilai $d_j < 3.35669$ ada sebanyak 44 dari 71 data atau 61.97% maka dapat disimpulkan bahwa data berdistribusi *multivariate normal*.



Keterangan : $C_{100} = d_j^2$ dan $C_{103} = \chi^2$

Gambar 4.1. Plot multinormal dari residual

Hal ini juga didukung dengan plot yang mendekati garis lurus seperti yang terlihat pada gambar 4.1. dan dengan dipenuhinya syarat kenormalan data residual tersebut berarti mendukung bahwa data yang digunakan untuk menganalisa jumlah penjualan daging telah stasioner.

4.3.2. Pemeriksaan pola residual

Pada pemeriksaan pola residual ini diterapkan cara yang sama seperti pada waktu pembentukan model *state space*, dengan melakukan perhitungan pada MACF dan MPACF yang dapat dilihat pada tabel berikut :

Tabel 4.8. Representasi skematik MACF residual

Name/Lag	0	1	2	3	4	5	6	7	8	9	10
Retail
WSC	+.+	-..	-..
Offal	..+	-..
By produk	+.+	+.+	-..	..++

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

Tabel 4.9. Representasi skematik MPACF residual

Name/Lag	1	2	3	4	5	6	7	8	9	10
Retail+
WSC	-..
Offal	-..
By produk	4...

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

Dari MACF dan MPACF terlihat bahwa fungsi matrik korelasi dan matrik korelasi parsial sudah tidak

membentuk pola tertentu didalam residualnya atau dengan kata lain residualnya telah memenuhi sifat *white noise*. Langkah selanjutnya adalah menghitung nilai AIC, dimana hasil perhitungan memperkuat kesimpulan diatas yaitu nilai AIC minimum didapat pada lag nol seperti yang terlihat pada tabel berikut:

Tabel 4.10. Nilai AIC residual model

Lag=0 4172.193494	Lag=1 4187.469014	Lag=2 4210.977943	Lag=3 4226.521407	Lag=4 4240.294892
Lag=5 4234.136092	Lag=6 4242.411398	Lag=7 4252.057998	Lag=8 4267.483398	Lag=9 4284.554849
Lag=10 4285.660603				

Karena derajat $p=0$ maka matriks *transisi A* pada model state spacenya akan mempunyai nilai nol disemua elemennya.

Dengan indikasi bahwa deret residual telah berdistribusi multivariate normal dan *white noise*, maka model sudah cukup memadai untuk digunakan dalam peramalan.



4.2. Peramalan Penjualan Produk PT. ASJ Surabaya

Hasil peramalan 10 periode (bulan) mendatang berdasarkan model state space akhir adalah :

Tabel 4.11. Nilai peramalan penjualan produk daging

Bulan	Retail	WSC	Offal	By produk
Desember '97	12638.40	3352.75	1842.20	5193.16
Januari '98	12538.81	3103.82	1865.28	4996.54
Februari '98	12464.23	2917.38	1882.57	4849.27
Maret '98	12408.36	2777.73	1895.51	4738.98
April '98	12366.52	2673.13	1905.21	4656.36
Mei '98	12335.18	2594.79	1912.48	4594.48
Juni '98	12311.71	2536.11	1917.92	4548.13
Juli '98	12294.12	2492.16	1921.99	4513.41
Agustus '98	12280.95	2459.25	1925.05	4487.41
September '98	12271.04	2434.59	1927.33	4467.94

Tabel 4.12. Simpangan peramalan

Retail cuts			Whole sale cuts			
No.	ACT	FORE	%	ACT	FORE	%
68	15271.4	12528.97	20.50	2562.6	3079.22	20.16
69	12305.6	12302.06	0.03	3198.3	2512.00	21.46
70	15304.4	12492.54	18.37	3002.3	2988.14	0.47
71	9017.5	12433.81	37.89	3685.1	2841.34	22.90

Offal				By Produk		
No.	ACT	FORE	%	ACT	FORE	%
68	1840.2	1867.56	1.49	5422.0	4977.11	8.21
69	1677.6	1920.15	14.46	4890.0	4529.09	7.38
70	2595.6	1876.00	27.72	5894.5	4905.17	16.78
71	2461.0	1889.62	23.21	4573.0	4789.21	4.73

Dari nilai peramalan diatas terlihat bahwa penjualan produk daging mengalami penurunan untuk itu diperlukan langkah yang tepat untuk penyediaan stok.

BAB V

KESIMPULAN DAN SARAN

BAB V

KESIMPULAN DAN SARAN

5.1. Kesimpulan

5.1.1. Model Penjualan Produk PT. ASJ Surabaya

Model peramalan pola penjualan untuk keempat jenis produk yang didasarkan pada analisa *state space* mempunyai bentuk *multivariate autoregresif* yang bersesuaian dengan AR(1) dan mempunyai bentuk sebagai berikut :

1. Untuk produk *retail cuts* mempunyai persamaan

$$Z_{1,t+1} = 11534.223 + 0.299632 Z_2$$

Artinya jumlah penjualan *retail cuts* pada bulan mendatang dipengaruhi oleh kenaikan jumlah penjualan *whole sale cuts* pada bulan ini sebesar 29.96 %.

2. Untuk produk *whole sale cuts* mempunyai persamaan

$$Z_{2,t+1} = 592.620 + 0.748998 Z_2$$

Artinya jumlah penjualan *whole sale cuts* pada bulan mendatang dipengaruhi oleh kenaikan jumlah penjualan *whole sale cuts* pada bulan ini sebesar 74.90 %.

3. Untuk produk *offal* mempunyai persamaan

$$Z_{3,t+1} = 2098.127 - 0.06945 Z_2$$

Artinya jumlah penjualan *offal* pada bulan mendatang dipengaruhi oleh kenaikan jumlah penjualan *whole sale cuts* pada bulan ini sebesar 6.94 %.

4. Untuk by product (produk sampingan) mempunyai persamaan : $Z_{4,t+1} = 3013.042 + 0.591604 Z_2$

Artinya jumlah penjualan by product pada bulan mendatang dipengaruhi oleh kenaikan jumlah penjualan whole sale cuts pada bulan ini sebesar 59.16 %.

5.1.2. Peramalan Penjualan Produk PT. ASJ Surabaya

Nilai peramalan untuk 10 periode mendatang adalah sebagai berikut:

Tabel 5.1. Nilai peramalan penjualan 10 periode kedepan

Bulan	Retail	WSC	Offal	By produk
Desember '97	12638.40	3352.75	1842.20	5193.16
Januari '98	12538.81	3103.82	1865.28	4996.54
Pebruari '98	14424.23	2917.38	1882.57	4849.27
Maret '98	12408.36	2777.73	1895.51	4738.98
April '98	12366.52	2673.13	1905.21	4656.36
Mei '98	12335.18	2594.79	1912.48	4594.48
Juni '98	12311.71	2536.11	1917.92	4548.13
Juli '98	12294.12	2492.16	1621.99	4513.41
Agustus '98	12280.95	2459.25	1625.05	4487.41
September '98	12271.04	2434.59	1927.33	4467.94

5.2. Saran

Model peramalan yang dihasilkan dari analisa state space ini hanyalah memberikan gambaran secara umum dari penjualan daging di PT.ASJ Surabaya untuk lebih mendukungnya dapat juga digunakan model-model lain yang mampu menjelaskan secara lebih spesifik.

Dari hasil peramalan terlihat adanya penurunan jumlah penjualan sehingga perlu adanya perhatian pada penyediaan stok sehingga tidak menimbulkan adanya penumpukan di-gudang.

I
I
G
S

DAFTAR PUSTAKA

DAFTAR PUSTAKA

1. Ronald E Walpole, Myers, *Ilmu Peluang dan Statistika untuk Insinyur dan Ilmuwan*, ITB Bandung, 1984.
2. Wei, William W.S., *Time Series Analysis, Univariate and Multivariate Methods*, Addison-Wesley, Publishing Company, USA, 1990.
3. Andrew C Harvey, *Time Series Models*, Harvester Wheatsheaf, 1981.
4. Karson, Marvin J, *Multivariate Statistical Methods*, Ames, Iowa, 1982.

I
U
S

LAMPIRAN

LAMPIRAN 1 :

DATA JUMLAH PENJUALAN PRODUK PT ABATTOIR SURYA JAYA
 JANUARI 1992 SAMPAI NOVEMBER 1997
 (DALAM KG)

Bulan	Retail	WSC	Offal	By Product
Jan '92	5964.7	11955.2	1636.9	135.6
Feb '92	5752.9	11222.5	1433.1	572.4
Mar '92	7833.5	23780.8	604.0	826.1
Apr '92	15545.8	10461.0	547.6	1301.4
Mei '92	6207.4	10841.8	1231.1	1229.8
Jun '92	6170.5	13271.8	787.2	2487.0
Jul '92	5221.9	9632.5	1465.2	1885.3
Ags '92	4644.5	10519.8	2371.3	2383.8
Sep '92	4800.1	5807.5	2119.6	1506.1
Okt '92	4064.2	6346.3	2252.6	1806.1
Nop '92	5473.1	9332.5	3098.4	2565.6
Des '92	7494.5	8595.5	1965.4	1932.9
Jan '93	7596.3	13208.1	1181.6	2009.8
Feb '93	5711.5	13452.1	1439.8	1922.7
Mar '93	29440.9	14298.7	1912.7	1911.3
Apr '93	7303.1	16617.4	1233.8	3300.9
Mei '93	5081.5	11265.9	1842.3	4236.3
Jun '93	4438.5	8758.5	733.0	3245.8
Jul '93	6309.0	14048.8	846.3	3875.0
Ags '93	4154.0	6552.9	1133.0	2562.6
Sep '93	5182.0	9267.5	841.9	1961.5
Okt '93	5938.3	9684.5	421.0	2875.5
Nop '93	5763.4	13457.3	439.4	2947.5
Des '93	4666.8	11779.8	12712.1	32323.3
Jan '94	4171.0	10835.4	750.0	3332.4
Feb '94	6016.3	17749.9	1147.0	3291.7
Mar '94	20810.1	11505.1	1370.2	3680.1
Apr '94	7133.9	15737.7	955.2	4379.7
Mei '94	8030.0	14656.2	1033.8	4175.0
Jun '94	6245.5	19076.3	692.9	8532.5
Jul '94	4050.0	13777.3	1062.0	4801.4
Ags '94	5802.6	18674.5	593.7	6161.0
Sep '94	5609.4	18203.9	367.3	4593.1
Okt '94	5039.6	12552.9	501.5	3146.1
Nop '94	7787.3	17394.8	799.9	4979.5
Des '94	6868.0	16339.6	959.9	6013.5
Jan '95	6508.8	18040.4	1381.5	3335.8
Feb '95	3800.6	13548.4	1798.2	3181.0
Mar '95	5048.5	9794.8	1560.1	2629.3
Apr '95	3681.7	8981.4	621.0	2529.8
Mei '95	4973.4	12548.7	1476.1	2605.2
Jun '95	5336.9	7657.4	300.2	123.2
Jul '95	2676.2	5247.7	493.5	2495.5
Ags '95	7184.3	7846.8	1202.1	2643.6
Sep '95	2697.6	4465.5	1724.9	2753.0

Bulan	Retail	WSC	Offal	By Product
Okt '95	6450.0	3379.4	10358.6	172.5
Nop '95	5356.7	4439.6	6357.1	678.0
Des '95	8275.5	7887.1	10526.7	3527.9
Jan '96	9290.3	9595.4	551.0	4291.7
Feb '96	4598.7	6583.8	367.8	3259.7
Mar '96	7786.4	5997.7	874.5	4103.3
Apr '96	9667.9	3579.8	922.4	2667.2
Mei '96	8099.5	3749.9	1053.2	1782.7
Jun '96	8303.2	4898.3	376.5	3740.1
Jul '96	13124.7	6556.8	556.3	4617.3
Ags '96	6452.8	4797.0	732.0	3727.0
Sep '96	12894.8	10942.7	4958.3	4823.2
Okt '96	25498.1	9888.9	2078.6	2943.8
Nop '96	11252.7	5807.8	1319.7	4369.2
Des '96	14694.8	4637.4	1655.9	4481.5
Jan '97	12849.7	5422.5	1516.0	2639.2
Feb '97	9938.7	2282.7	1076.7	1093.0
Mar '97	9010.5	4876.1	2175.7	4958.9
Apr '97	13310.9	4088.7	2967.7	3882.2
Mei '97	13531.9	3509.8	1803.2	4149.6
Jun '97	5308.2	3297.7	2774.3	4795.0
Jul '97	12285.2	3319.9	1335.8	7319.8
Ags '97	15761.4	2562.6	1840.2	5422.0
Sep '97	12305.6	3198.3	1677.6	4890.0
Okt '97	15304.4	3002.3	2595.6	5894.5
Nop '97	9017.5	3685.1	2461.0	4573.0

Lampiran 2 :

Program dan output pembentukan model state space
pendahuluan

PROGRAM STATE SPACE AWAL

```
data series;
  input z1 z2 z3 z4;
cards;
  5884.7  11855.2   1636.9   135.6
  5752.9  11222.5   1433.1   572.4
  7833.5  23790.8   804.0    826.1
  15545.8 10461.0   547.6   1301.4
  6207.4  10841.8   1231.1   1229.8
  6170.5  13271.8   787.2    2467.0
  5221.9  9632.5   1465.2   1885.3
  4644.5  10519.8   2371.3   2363.8
  4800.1  5807.5   2119.6   1506.1
  4064.2  6346.3   2252.6   1806.1
  5473.1  9332.5   3098.4   2565.6
  7494.5  6596.5   1965.4   1932.9
  7596.3  13208.1   1191.6   2008.8
  5711.5  13452.1   1439.6   1822.7
  29440.9 14298.7   1912.7   1911.3
  7303.1  16617.4   1233.8   3300.9
  5081.5  11265.9   1842.3   4236.3
  4438.5  9758.5   733.0    3245.8
  6308.0  14048.8   846.3    3875.0
  4154.0  6552.9   1133.0   2562.6
  5192.0  9267.5   841.9    1961.5
  5938.3  9684.5   421.0    2875.5
  5763.4  13457.3   438.4    2947.5
  4666.8  11779.8   12712.1  32323.3
  4171.0  10835.4   750.0    3332.4
  6016.8  17749.8   1147.0   3291.7
  20610.1 11505.1   1370.2   3680.1
  7133.9  15737.7   855.2    4379.7
  8030.0  14856.2   1033.8   4175.0
  6245.5  18076.3   682.9    8532.5
  4050.0  13777.3   1062.0   4601.4
  5802.6  18674.5   593.7    6161.0
  5609.4  18203.9   367.3    4593.1
  5039.6  12552.9   501.5    3146.1
  7787.3  17384.8   799.9    4879.5
  6868.0  16338.6   959.9    6013.5
  6508.8  18040.4   1381.5   3335.8
  3800.6  13546.4   1798.2   3181.0
  5048.5  8784.8   1560.1    2629.3
  3681.7  8981.4   621.0    2529.8
  4973.4  12548.7   1476.1   2605.2
  5336.9  7857.4   300.2    123.2
  2676.2  5247.7   493.5    2495.5
```

```

7184.3    7846.8    1202.1    2643.6
2697.6    4465.5    1724.9    2753.0
6450.0    3379.4    10358.6    172.5
5356.7    4439.6    6357.1    678.0
8275.5    7887.1    10526.7    3527.9
9290.3    9595.4    551.0     4291.7
4598.7    6583.8    367.8     3259.7
7786.4    5997.7    874.5     4103.3
9667.9    3579.8    922.4     2667.2
8099.5    3749.8    1053.2    1782.7
8303.2    4898.3    376.5     3740.1
13124.7    6556.8    556.3     4617.3
6452.8    4787.0    732.0     3727.0
12894.8    10842.7   4958.3    4823.2
25498.1    9888.9    2078.6    2943.8
11252.7    5807.3    1319.7    4369.2
14694.8    4637.4    1655.9    4461.5
12949.7    5422.5    1518.0    2638.2
9938.7    2282.7    1076.7    1093.0
9010.5    4876.1    2175.7    4958.9
13310.9    4088.7    2967.7    3882.2
13531.9    3509.8    1803.2    4149.6
5308.2    3297.7    2774.3    4795.0
12285.2    3318.9    1335.8    7318.8
15781.4    2562.6    1840.2    5422.0
12305.6    3198.3    1677.6    4890.0
15304.4    3002.3    2595.6    5894.5
9017.5    3685.1    2461.0    4573.0
;
run;
proc statespace cancorr printout=short lead=10 out=out1
outmodel=model;
var z1 z2 z3 z4;
run;

```

HASIL PROGRAM (OUTPUT)

STATESPACE Procedure

Nobs = 71		
Variable	Mean	Std
Z1	7894.518	3868.006
Z2	9532.249	4644.557
Z3	1436.092	602.411
Z4	3235.606	1540.985

Information Criterion for Autoregressive Models

	Lag=0	Lag=1	Lag=2	Lag=3	Lag=4
4391.596464	4318.818895	4327.10978	4347.857251	4365.817959	
	Lag=5	Lag=6	Lag=7	Lag=8	Lag=9
4374.552063	4390.493095	4415.804954	4426.785892	4430.165787	
	Lag=10				
4435.324397					



Schematic Representation of Correlations

Name/Lag	0	1	2	3	4	5	6	7	8	9	10
Z1	***	***	***	***	***	***	***	***	***	***	***
Z2	***	***	***	***	***	***	***	***	***	***	***
Z3	***	***	***	***	***	***	***	***	***	***	***
Z4	***	***	***	***	***	***	***	***	***	***	***

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

Schematic Representation of Partial Autocorrelations

Name/Lag	1	2	3	4	5	6	7	8	9	10
Z1	***	***	***	***	***	***	***	***	***	***
Z2	***	***	***	***	***	***	***	***	***	***
Z3	***	***	***	***	***	***	***	***	***	***
Z4	***	***	***	***	***	***	***	***	***	***

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

Yule-Walker Estimates for the Min AIC

Lag=1

	Z1	Z2	Z3	Z4
Z1	0.24676	-0.16565	0.51493	0.45058
Z2	-0.05225	0.71026	-0.25778	-0.16481
Z3	0.00092	-0.05859	0.16188	-0.01475
Z4	0.02975	-0.02437	-0.00527	0.57352

Canonical Correlations Analysis

State vector	Correlations	Infor.	Chisq	D.F.
Z1(T;T),Z2(T;T),Z3(T;T), Z4(T;T),Z1(T+1;T)	1.0000 1.0000 1.0000 1.0000 0.2658	-2.79636	5.057059	4
Z1(T;T),Z2(T;T),Z3(T;T), Z4(T;T),Z2(T+1;T)	1.0000 1.0000 1.0000 1.0000 0.3646	-2.12505	5.839838	4
Z1(T;T),Z2(T;T),Z3(T;T), Z4(T;T),Z3(T+1;T)	1.0000 1.0000 1.0000 1.0000 0.2035	-4.99768	2.91775	4
Z1(T;T),Z2(T;T),Z3(T;T), Z4(T;T),Z4(T+1;T)	1.0000 1.0000 1.0000 1.0000 0.2697	-2.63671	5.212212	4

Selected Statespace Form and Preliminary Estimates

State Vector			
Z1(T;T)	Z2(T;T)	Z3(T;T)	Z4(T;T)

Estimate of the Transition Matrix

0.247	-0.166	0.515	0.451
-0.052	0.710	-0.258	-0.165
0.001	-0.059	0.162	-0.015
0.030	-0.014	-0.005	0.574

Selected Statespace Form and Preliminary Estimates

Input Matrix for the Innovation

1	0	0	0
0	1	0	0
0	0	1	0
0	0	0	1

Selected Statespace Form and Preliminary Estimates

Variance Matrix for the Innovation

12581203.8	260621.132	224301.971	564517.996
260621.132	10040202.8	-64184.983	1468853.45
224301.971	-64184.983	878724.671	-69295.903
564517.996	1468853.45	-69295.903	1751976.11

Selected Statespace Form and Fitted Model

State Vector

Z1(T;T)	Z2(T;T)	Z3(T;T)	Z4(T;T)
---------	---------	---------	---------

Estimate of the Transition Matrix

0.247	-0.166	0.515	0.451
-0.052	0.710	-0.258	-0.165
0.001	-0.059	0.162	-0.015
0.030	-0.024	-0.005	0.574

Selected Statespace Form and Fitted Model

Input Matrix for the Innovation

1	0	0	0
0	1	0	0
0	0	1	0
0	0	0	1

Selected Statespace Form and Fitted Model

Variance Matrix for the Innovation

12581203.8	260621.132	224301.971	564517.996
260621.132	10040202.8	-64184.983	1468853.45
224301.971	-64184.983	878724.671	-69295.903
564517.996	1468853.45	-69295.903	1751976.11

Parameter Estimates

Parameter Estimate Std. Err. T value

F(1,1)	0.246762	0.113784	-1.71179
F(1,2)	-0.16565	0.096769	2.168586
F(1,3)	0.514931	0.433784	1.187068
F(1,4)	0.45058	0.270653	1.664789
F(2,1)	-0.05225	0.101645	-0.51407

F(2,2)	0.710262	0.086445	8.216359
F(2,3)	-0.25778	0.387945	-0.66446
F(2,4)	-0.16481	0.241866	-0.6814
F(3,1)	0.000923	0.030094	0.030678
F(3,2)	-0.05859	0.025592	-2.28922
F(3,3)	0.161877	0.115362	1.403199
F(3,4)	-0.01475	0.071707	-0.20563
F(4,1)	0.02975	0.042478	0.700359
F(4,2)	-0.02437	0.036125	5.868044
F(4,3)	-0.00527	0.162671	-0.03237
F(4,4)	0.573519	0.101185	-0.67458

Lampiran 3 :

Program dan output pembentukan model state space akhir

PROGRAM STATE SPACE

```
data series;
  input z1 z2 z3 z4;
cards;
  5964.7  11955.2   1636.9    135.6
  5752.9  11222.5   1433.1    572.4
  7833.5  23790.8   604.0     828.1
  15545.8 10461.0   547.6    1301.4
  6207.4  10841.8   1231.1   1228.8
  6170.5  13271.8   787.2    2467.0
  5221.9  9632.5   1465.2   1885.3
  4644.5  10519.8   2371.3   2363.8
  4800.1  5807.5   2119.6   1506.1
  4064.2  6346.3   2252.6   1806.1
  5473.1  9332.5   3098.4   2565.6
  7494.5  6596.5   1965.4   1932.9
  7598.3  13208.1   1191.8   2009.8
  5711.5  13452.1   1438.6   1922.7
  29440.9 14298.7   1912.7   1911.3
  7303.1  16617.4   1233.8   3300.9
  5081.5  11265.9   1842.3   4236.3
  4438.5  8758.5   733.0    3245.8
  6309.0  14048.8   846.3    3875.0
  4154.0  6552.9   1133.0   2562.6
  5192.0  9267.5   841.9    1961.5
  5938.3  9684.5   421.0    2875.5
  5763.4  13457.3   439.4    2947.5
  4666.8  11779.8  12712.1  32323.3
  4171.0  10835.4   750.0    3332.4
  6016.9  17749.8   1147.0   3291.7
  20610.1 11505.1   1370.2   3680.1
  7133.9  15737.7   955.2    4378.7
  8030.0  14656.2   1033.8   4175.0
  6245.5  19076.3   692.9    8532.5
  4050.0  13777.3   1062.0   4601.4
  5802.6  18674.5   593.7    6161.0
  5809.4  18203.9   367.3    4593.1
  5038.8  12552.9   501.5    3146.1
  7787.3  17394.8   799.9    4979.5
  6868.0  16339.6   959.9    6013.5
  6508.8  18040.4   1381.5   3335.8
  3800.6  13546.4   1798.2   3181.0
  5048.5  8794.8   1560.1   2629.3
  3681.7  8981.4   621.0    2529.8
  4973.4  12548.7   1475.1   2605.2
  5336.9  7657.4   300.2    123.2
```

```

2876.2    5247.7    493.5    2495.5
7184.3    7846.8    1202.1    2643.8
2697.6    4465.5    1724.9    2753.0
6450.0    3379.4    10358.6    172.5
5356.7    4439.8    6357.1    678.0
8275.5    7887.1    10526.7    3527.9
9290.3    8585.4    551.0    4291.7
4598.7    6583.8    367.8    3259.7
7786.4    5887.7    874.5    4103.3
9667.9    3579.8    922.4    2667.2
8099.5    3749.9    1053.2    1782.7
8303.2    4898.3    376.5    3740.1
13124.7   6556.8    556.3    4617.3
6452.8    4797.0    732.0    3727.0
12894.8   10842.7   4858.3    4823.2
25498.1   9888.9    2078.6    2943.8
11252.7   5807.8    1319.7    4369.2
14894.8   4637.4    1655.9    4461.5
12949.7   5422.5    1516.0    2638.2
9938.7    2282.7    1076.7    1093.0
9010.5    4876.1    2175.7    4958.9
13310.9   4088.7    2967.7    3882.2
13531.9   3509.8    1803.2    4149.6
5308.2    3297.7    2774.3    4795.0
12285.2   3319.9    1335.8    7319.8
15761.4   2582.6    1840.2    5422.0
12305.6   3198.3    1677.6    4890.0
15304.4   3002.3    2595.6    5894.5
9017.5   3685.1    2461.0    4573.0
;
run;
proc statespace cancorr printout=short lead=10  out=out1
outmodel=model;
var z1 z2 z3 z4;
restrict f(2,1)=0 f(2,3)=0 f(2,4)=0  f(3,1)=0  f(3,4)=0
f(4,1)=0  f(4,4)=0 f(4,3)=0 f(1,3)=0  f(3,3)=0  f(1,4)=0
f(1,1)=0;
proc print data=model;
data;
merge out1;
run;
proc print data=_last_(firsttobs=0);
run;

```

HASIL PROGRAM (OUTPUT PROGRAM)

STATESPACE Procedure

Variable	Nobs = 71	Mean	Std
z1	7894.518	3868.006	
z2	9532.249	4644.557	
z3	1436.092	602.411	
z4	3235.606	1540.985	

Information Criterion for Autoregressive Models

Lag=0	Lag=1	Lag=2	Lag=3	Lag=4
4391.596464	4318.818895	4327.10978	4347.857251	4365.817959
Lag=5	Lag=6	Lag=7	Lag=8	Lag=9
4374.552063	4390.493095	4415.804954	4426.785892	4430.165787
Lag=10				
4435.324397				

Schematic Representation of Correlations

Name/Lag	0	1	2	3	4	5	6	7	8	9	10
Z1	++	++	++	++	-	-	-	-	-	-	-
Z2	-	-	-	-	-	-	-	-	-	-	-
Z3	-	-	-	-	-	-	-	-	-	-	-
Z4	++	++	++	++	-	-	-	-	-	-	-

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

Schematic Representation of Partial Autocorrelations

Name/Lag	1	2	3	4	5	6	7	8	9	10
Z1	-	-	-	-	-	-	-	-	-	-
Z2	-	-	-	-	-	-	-	-	-	-
Z3	-	-	-	-	-	-	-	-	-	-
Z4	-	-	-	-	-	-	-	-	-	-

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

Yule-Walker Estimates for the Min AIC

	Lag=1			
	Z1	Z2	Z3	Z4
Z1	0.24676	-0.16565	0.51493	0.45058
Z2	-0.05225	0.71026	-0.25778	-0.16481
Z3	0.00092	-0.05859	0.16188	-0.01475
Z4	0.02975	-0.02437	-0.00527	0.57352

Canonical Correlations Analysis

State vector	Correlations	Infor.	Chi sq	D.F.
Z1(T;T),Z2(T;T),Z3(T;T),	1.0000 1.0000 1.0000	-2.7963	5.057059	4
Z4(T;T),Z1(T+1;T)	1.0000 0.2658			
Z1(T;T),Z2(T;T),Z3(T;T),	1.0000 1.0000 1.0000	-2.12505	5.839838	4
Z4(T;T),Z2(T+1;T)	1.0000 0.3646			
Z1(T;T),Z2(T;T),Z3(T;T),	1.0000 1.0000 1.0000	-4.99768	2.91775	4
Z4(T;T),Z3(T+1;T)	1.0000 0.2035			
Z1(T;T),Z2(T;T),Z3(T;T),	1.0000 1.0000 1.0000	-2.63671	5.212212	4
Z4(T;T),Z4(T+1;T)	1.0000 0.2697			

Selected Statespace Form and Preliminary Estimates

State Vector

100-1000-0000-0000-0000-0000-0000-0000

0.000	0.247	0.000	0.000
0.000	0.710	0.000	0.000
3.000	-0.059	0.000	0.000
0.000	0.574	0.000	0.000

Selected Stratigraphic Units and Preliminary Estimation

Input Matrix for the Innovation

1	0	0	0
0	1	0	0
0	0	1	0
0	0	0	1

Selected Statespace Form and Preliminary Estimates

Variance Matrix for the Innovation

12581203,8 260621,132 224301,971 564517,996
 260621,132 10040202,8 -64184,983 1468853,45
 224301,971 -64184,983 878724,671 -69295,903
 564517,996 1468853,45 -69295,903 1751976,11

Selected Statespace Form and Fitted Model

State Vector

Estimate of the Transition Matrix

0.000	0.300	0.000	0.000
0.000	0.749	0.000	0.000
0.000	-0.069	0.000	0.000
0.000	0.592	0.000	0.000

For a more detailed discussion of the results, see the following section.

Input Matrix for the Innovation

$$\begin{matrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{matrix}$$

Saturated Statespace Form and Fitted Node

Variance Matrix for the Innovation

```

13284847 -38887.535 281112.112 555820.386
-38887.535 1026B278.7 -100119.48 1460149.38
281112.112 -100119.48 904243.148 -68508.97
555820.386 1460149.38 -68508.97 1283778.31

```

Parameter Estimates

Parameter Estimate Std. Err. T value

F(1,2)	0.299632	0.110086	2.721811
F(2,2)	0.748998	0.077066	9.718911
F(3,2)	-0.06945	0.024162	-2.86264
F(4,2)	0.591609	0.09016	6.561792

DSS STATEVEC F_1 F_2 F_3 F_4 F_5 F_6 F_7 F_8 F_9 F_10 G_1

1 Z1(T;T)	0.29963	-0.15071	0	0.00000	1
2 Std	0.11009	0.09445
3 Z2(T;T)	0.00000	0.74900	0	0.00000	0
4 Std	.	0.07707
5 Z3(T;T)	0.00000	-0.06945	0	0.00000	0
6 Std	.	0.02426
7 Z4(T;T)	0.00000	0.00000	0	0.59161	0

DSS G_2 G_3 G_4 S16_1 S16_2 S16_3 S16_4

1 0 0 0	13284847.05	-38887.53	281112.11	555820.39
2
3 1 0 0	-38887.53	10268278.68	-100119.48	1460149.38
4
5 0 1 0	281112.11	-100119.48	904243.15	-68508.97
6
7 0 0 1	555820.39	1460149.38	-68508.97	1793778.31

DSS STATEVEC F_1 F_2 F_3 F_4 F_5 F_6 F_7 F_8 F_9 F_10 G_1

8 Std	.	.	.	0.09016
-------	---	---	---	---------	---	---	---	---	---	---

DSS G_2 G_3 G_4 S16_1 S16_2 S16_3 S16_4

9
---------	---	---	---	---	---	---	---

DSS Z1 FOR1 RES1 STD1 Z2 FOR2 RES2 STD2

1 5964.7	7894.52	-1929.82	3644.84	11955.2	9532.25	2422.95	3204.42
2 5752.9	6951.13	-1198.23	3644.84	11222.5	11347.03	-124.53	3204.42
3 7833.5	6998.09	835.41	3644.84	13790.9	10798.24	2992.56	3204.42
4 15545.8	7234.45	8311.35	3644.84	10461.0	12721.89	-2260.89	3204.42
5 6207.4	10047.12	-3839.72	3644.84	10841.8	10227.88	613.92	3204.42
6 6170.5	7191.65	-1021.15	3644.84	13271.8	10513.10	2758.70	3204.42
7 5221.9	6814.37	-1592.47	3644.84	9632.5	12333.16	-2700.66	3204.42
8 4644.5	7078.61	-2434.11	3644.84	10519.8	9607.34	912.46	3204.42
9 4800.1	6771.88	-1971.78	3644.84	5807.5	10271.92	-4464.42	3204.42
10 4064.2	7528.67	-3464.47	3644.84	6346.3	6742.42	-396.12	3204.42
11 5473.1	7226.97	-1753.87	3644.84	9332.5	7145.98	2186.52	3204.42
12 7494.5	7199.09	295.41	3644.84	6596.5	9382.64	-2786.14	3204.42
13 7596.3	8217.10	-620.80	3644.84	13208.1	7333.38	5874.72	3204.42
14 5711.5	7251.19	-1539.69	3644.84	13452.1	12285.45	1166.65	3204.42
15 19440.9	6649.67	12791.23	3644.84	14298.7	12468.21	1830.49	3204.42

16 7503.1 10635.86 -3332.76 3644.84 16617.4 13102.31 3515.09 3204.42
 17 5081.5 6649.53 -1568.03 3644.84 11265.9 14839.01 -3573.11 3204.42

085	I3	FOR3	RES3	STD3	Z4	FOR4	RES4	STD4	STATEVEC
1	1636.9	1436.09	200.81	950.917	155.6	3235.61	-3100.01	1335.58	21(T;T)
2	1433.1	1267.81	165.29	950.917	572.4	1401.61	-829.21	1335.58	Std
3	604.0	1318.70	-714.70	950.917	826.1	1680.03	-833.93	1335.58	22(T;T)
4	547.6	1140.32	-592.72	950.917	1301.4	1810.12	-508.72	1335.58	Std
5	1231.1	1371.59	-140.49	950.917	1229.8	2091.31	-961.51	1335.58	23(T;T)
6	787.2	1345.14	-557.94	950.917	2457.0	2048.95	418.05	1335.58	Std
7	1465.2	1176.37	288.93	950.917	1695.3	2780.89	-895.59	1335.58	24(T;T)
8	2371.3	1429.13	942.17	950.917	2361.8	2458.75	-72.95	1335.58	Std
9	2119.6	1367.50	752.10	950.917	1506.1	2719.84	-1213.74	1335.58	
10	2252.6	1694.79	557.81	950.917	1806.1	2212.41	-408.31	1335.58	
11	3098.4	1657.37	1441.03	950.917	2565.6	2389.90	175.70	1335.58	
12	1965.4	1449.96	515.44	950.917	1932.9	2839.22	-906.32	1335.58	
13	1191.6	1639.99	-448.39	950.917	2009.8	2464.91	-455.11	1335.58	
14	1439.6	1180.79	258.81	950.917	1922.7	2510.41	-587.71	1335.58	
15	1912.7	1163.85	748.85	950.917	1911.3	2458.88	-547.58	1335.58	
16	1233.8	1105.05	128.75	950.917	3300.9	2452.13	848.77	1335.58	
17	1842.3	944.00	898.30	950.917	4236.3	3274.23	962.07	1335.58	

088	F_1	F_2	F_3	F_4	F_5	F_6	F_7	F_8	F_9	F_10	F_11	F_12	F_13
1	0.29963	-0.15071	0	0.00000	,	,	,	,	,	1	0	0	
2	0.11009	0.09445	,	,	,	,	,	,	,	,	,	,	
3	0.00000	0.74900	0	0.00000	,	,	,	,	,	0	1	0	
4	,	0.07707	,	,	,	,	,	,	,	,	,	,	
5	0.00000	-0.06945	0	0.00000	,	,	,	,	,	0	0	1	
6	,	0.02426	,	,	,	,	,	,	,	,	,	,	
7	0.00000	0.00000	0	0.59161	,	,	,	,	,	0	0	0	
8	,	,	,	0.09016	,	,	,	,	,	,	,	,	
9	,	,	,	,	,	,	,	,	,	,	,	,	
10	,	,	,	,	,	,	,	,	,	,	,	,	
11	,	,	,	,	,	,	,	,	,	,	,	,	
12	,	,	,	,	,	,	,	,	,	,	,	,	
13	,	,	,	,	,	,	,	,	,	,	,	,	
14	,	,	,	,	,	,	,	,	,	,	,	,	
15	,	,	,	,	,	,	,	,	,	,	,	,	
16	,	,	,	,	,	,	,	,	,	,	,	,	
17	,	,	,	,	,	,	,	,	,	,	,	,	

088	SIG_4	SIG_1	SIG_2	SIG_3	SIG_4
1	0	13204847.05	-33887.53	281112.11	555820.39
2	,	,	,	,	,
3	0	-38087.53	10268278.68	-100119.48	1460149.38
4	,	,	,	,	,
5	0	281112.11	-100119.48	904243.15	-68508.97
6	,	,	,	,	,
7	1	555820.39	1460149.38	-68508.97	1793778.31
8	,	,	,	,	,
9	,	,	,	,	,
10	,	,	,	,	,

11 .
 12 .
 13 .
 14 .
 15 .
 16 .
 17 .

DBS	Z1	FOR1	RES1	STD1	Z2	FOR2	RES2
18	4438.5	6790.37	-2351.87	3644.84	9758.5	10830.75	-1072.25
19	6309.0	6824.89	-515.89	3644.84	14048.8	9701.71	4347.09
20	4154.0	6738.77	-2584.77	3644.84	6552.9	12915.13	-6362.23
21	5192.0	7222.74	-2030.74	3644.84	9267.5	7300.72	1966.78
22	5958.3	7124.66	-1186.36	3644.84	9684.5	9333.95	350.55
23	5763.4	7285.43	-1522.03	3644.84	13457.3	9646.28	3811.02
24	4666.8	6664.44	-1997.64	3644.84	11779.8	12472.10	-692.30
25	4171.0	6588.67	-2617.57	3644.84	10835.4	11215.56	-380.26
26	6016.9	6582.44	-565.54	3644.84	17749.9	10508.31	7241.59
27	20610.1	6093.47	14516.63	3644.84	11505.1	15687.25	-4182.15
28	7133.9	11407.20	-4273.30	3644.84	15737.7	11009.91	4727.79
29	8030.0	6731.41	1298.59	3644.84	14656.2	14180.12	4761.08
30	6245.5	7162.90	-917.40	3644.84	19076.3	13370.08	5706.22
31	4050.0	5982.07	-1912.07	3644.84	13777.3	16680.72	-2903.42
32	5802.6	6102.82	-300.22	3644.84	18674.5	12711.78	5982.72
33	5809.4	5889.92	-280.52	3644.84	18203.9	16379.77	1824.13
34	5039.6	5902.95	-863.35	3644.84	12552.9	16027.29	-3474.39

DBS	STD2	Z3	FOR3	RES3	STD3	Z4	FOR4
18	3204.42	733.0	1315.68	-592.68	950.917	3245.8	3827.63
19	3204.42	846.3	1420.38	-574.08	950.917	3875.0	3241.64
20	3204.42	1133.0	1121.40	10.80	950.917	2562.6	3813.89
21	3204.42	841.9	1643.02	-501.12	950.917	1951.5	2837.45
22	3204.42	421.0	1454.48	-1033.48	950.917	2875.5	2481.83
23	3204.42	439.4	1425.52	-986.12	950.917	2947.5	3022.56
24	3204.42	2712.1	1163.46	1548.62	950.917	2323.3	3065.16
25	3204.42	750.0	1279.99	-529.99	950.917	3332.4	2695.88
26	3204.42	1147.0	1345.58	-199.58	950.917	3291.7	3292.87
27	3204.42	1370.2	865.35	504.85	950.917	3680.1	3268.79
28	3204.42	955.2	1299.07	-343.87	950.917	4379.7	3498.57
29	3204.42	1033.8	1005.10	28.70	950.917	4175.0	3912.46
30	3204.42	692.9	1080.22	-387.32	950.917	8532.5	3791.36
31	3204.42	1062.0	773.23	288.77	950.917	4601.4	6369.30
32	3204.42	593.7	1141.26	-547.56	950.917	6161.0	4043.62
33	3204.42	367.3	801.13	-433.83	950.917	4593.1	4966.30
34	3204.42	501.5	833.82	-332.32	950.917	3146.1	4038.71

DBS	RES4	STD4	STATEVEC	F_1	F_2	F_3	F_4	F_5	F_6	F_7	F_8
18	-581.83	1335.58									
19	633.36	1335.58									
20	-1051.28	1335.58									
21	-875.95	1335.58									
22	393.67	1335.58									

23	-75.06	1335.58									
24	-741.66	1335.58									
25	636.52	1335.58									
26	-1.17	1335.58									
27	411.31	1335.58									
28	881.13	1335.58									
29	262.54	1335.58									
30	4741.14	1335.58									
31	-1767.90	1335.58									
32	2117.38	1335.58									
33	-373.20	1335.58									
34	-892.61	1335.58									

089	F_9	F_10	G_1	G_2	G_3	G_4	SIG_1	SIG_2	SIG_3	SIG_4
-----	-----	------	-----	-----	-----	-----	-------	-------	-------	-------

18										
19										
20										
21										
22										
23										
24										
25										
26										
27										
28										
29										
30										
31										
32										
33										
34										

089	II	FOR1	RES1	STD1	II	FOR2	RES2	STD2	II
-----	----	------	------	------	----	------	------	------	----

35	7787.3	6583.86	1203.44	3644.84	17394.5	11794.71	5600.09	3204.42	799.7
36	6368.0	6577.48	190.54	3644.84	16339.6	15421.28	918.32	3204.42	959.9
37	6508.8	6561.03	-52.23	3644.84	18040.4	14630.94	3409.46	3204.42	1381.5
38	3800.6	6197.08	-2396.48	3644.84	13546.4	15904.87	-2358.43	3204.42	1798.2
39	5048.5	6082.89	-1014.39	3644.84	9794.8	12538.84	-2744.04	3204.42	1560.1
40	3681.7	7002.19	-3320.49	3644.84	8981.4	9728.90	-747.50	3204.42	421.0
41	4973.4	6715.24	-1741.84	3644.84	12549.7	9119.66	3429.04	3204.42	1476.1
42	5336.9	6564.66	-1227.76	3644.84	7657.4	11791.56	-4134.16	3204.42	300.2
43	2676.2	7419.72	-4734.52	3644.84	5247.7	8127.99	-2880.29	3204.42	493.5
44	7184.3	6976.65	207.65	3644.84	7846.8	6323.13	1523.67	3204.42	1202.1
45	2897.6	7935.72	-5238.12	3644.84	4465.5	8269.85	-3804.35	3204.42	1724.9
46	6450.0	7100.94	-650.94	3644.84	3379.4	5737.27	-2357.87	3204.42	1358.6
47	5356.7	8388.97	-3032.27	3644.84	4439.6	4923.78	-484.18	3204.42	6357.1
48	8275.5	7901.60	373.90	3644.84	7887.1	5717.87	2169.23	3204.42	1528.7
49	9290.3	8256.61	1033.69	3644.84	9595.4	8300.04	1295.36	3204.42	551.0
50	4598.7	8303.22	-3704.52	3644.84	6583.8	9579.55	-2995.75	3204.42	367.8
51	7786.4	7351.33	435.07	3644.84	5997.7	7323.87	-1326.17	3204.42	874.5

OBS	FOR3	RES3	STD3	Z4	FOR4	RES4	STD4	STATEVEC	F_1	F_2
-----	------	------	------	----	------	------	------	----------	-----	-----

35	1226.30	-426.40	950.917	4979.5	3182.65	1796.65	1335.58		.	.
36	890.01	69.89	950.917	6013.5	4267.31	1746.19	1335.58		.	.
37	963.30	418.20	950.917	3335.8	4079.03	-1543.23	1335.58		.	.
38	845.17	953.03	950.917	3181.0	3294.88	-113.88	1335.58		.	.
39	1157.30	402.80	950.917	2629.3	3203.30	-574.00	1335.58		.	.
40	1417.86	-790.86	950.917	2529.8	2676.91	-347.11	1335.58		.	.
41	1474.35	1.75	950.917	2605.2	2818.04	-212.84	1335.58		.	.
42	1228.59	-926.39	950.917	127.2	2862.65	-2739.45	1335.58		.	.
43	1566.31	-1072.81	950.917	2493.5	1394.28	1101.22	1335.58		.	.
44	1733.57	-531.57	950.917	2643.6	2797.75	-154.15	1335.58		.	.
45	1553.15	171.75	950.917	2753.0	2885.37	-132.37	1335.58		.	.
46	1787.99	-429.39	950.917	172.5	2950.09	-2777.59	1335.58		.	.
47	1863.43	4495.67	950.917	678.0	1423.44	-745.44	1335.58		.	.
48	1789.79	-263.09	950.917	3527.9	1722.50	1805.40	1335.58		.	.
49	1550.35	-999.35	950.917	4291.7	3408.53	883.17	1335.58		.	.
50	1431.71	-1063.91	950.917	3259.7	3860.40	-600.70	1335.58		.	.
51	1640.87	-766.37	950.917	4103.3	3249.86	853.44	1335.58		.	.

OBS	F_3	F_4	F_5	F_6	F_7	F_8	F_9	F_10	G_1	G_2	G_3	G_4	SIG_1	SIG_2	SIG_3	SIG_4
-----	-----	-----	-----	-----	-----	-----	-----	------	-----	-----	-----	-----	-------	-------	-------	-------

35
36
37
38
39
40
41
42
43
44
45
46
47
48
49
50
51

OBS	Z1	FOR1	RES1	STD1	Z2	FOR2	RES2	STD2	Z3
-----	----	------	------	------	----	------	------	------	----

52	9667.9	8394.80	1273.10	3644.84	3579.8	6984.88	-3305.08	3204.42	922.4
53	8099.5	9322.95	-1223.45	3644.84	3749.9	5073.88	-1323.98	3204.42	1053.2
54	8303.2	8827.37	-524.17	3644.84	4898.3	5201.28	-302.98	3204.42	376.5
55	13124.7	8715.34	4409.36	3644.84	6556.8	6061.43	495.37	3204.42	556.3
56	6452.8	9910.07	-3457.27	3644.84	4797.0	7303.65	-2506.65	3204.42	732.0
57	12894.8	8176.16	4718.64	3644.84	10942.7	5985.56	4957.14	3204.42	4958.3
58	15498.1	9180.20	6317.90	3644.84	9888.9	10588.67	-699.77	3204.42	2078.6
59	11252.7	10119.05	1133.65	3644.84	5807.8	9799.38	-3991.59	3204.42	1319.7
60	14694.8	9462.04	8232.76	3644.84	4637.4	6742.65	-2105.25	3204.42	1855.9
61	12949.7	10669.79	2279.91	3644.84	5422.5	5866.02	-443.52	3204.42	1516.0
62	9938.7	10028.58	-89.88	3644.84	2282.7	6454.06	-4171.36	3204.42	1076.7
63	9010.5	9599.57	-589.07	3644.84	4876.1	4102.35	773.75	3204.42	2175.7
64	13310.9	8930.61	4380.29	3644.84	4088.7	6044.80	-1958.10	3204.42	2987.7

65	13531.9	10337.82	3194.08	3644.84	3509.8	5455.04	-1945.24	3204.42	1803.2
66	5308.2	10491.28	-5183.08	3644.84	3297.7	5021.45	-1723.75	3204.42	2774.3
67	12285.2	8059.16	4226.04	3644.84	3319.9	4862.59	-1542.69	3204.42	1335.8
68	15761.4	12526.97	3232.43	3644.84	2562.6	3079.22	-516.62	3204.42	1840.2

085	FOR3	RES3	STD3	14	FOR4	RES4	STD4	STATEVEC	F_1 F_2
-----	------	------	------	----	------	------	------	----------	---------

52	1681.58	-759.18	950.917	2667.2	3743.74	-1081.74	1335.58		
53	1849.51	-795.31	950.917	1782.7	2899.33	-1116.63	1335.58		
54	1837.89	-1451.19	950.917	3740.1	2376.05	1364.05	1335.58		
55	1757.93	-1201.63	950.917	4617.3	3534.07	1083.23	1335.58		
56	1642.75	-910.75	950.917	3727.0	4053.03	-326.03	1335.58		
57	1784.97	3193.33	950.917	4823.2	3526.32	1295.88	1335.58		
58	1338.13	740.47	950.917	2943.8	4174.84	-1231.04	1335.58		
59	1411.32	+91.62	950.917	4369.2	3062.97	1306.23	1335.58		
60	1694.77	-38.87	950.917	4461.5	3906.25	555.25	1335.58		
61	1776.05	-260.05	950.917	2638.2	3860.86	-1322.66	1335.58		
62	1721.53	-644.93	950.917	1093.0	2882.18	-1789.18	1335.58		
63	1939.80	236.10	950.917	4958.9	1968.02	2990.88	1335.58		
64	1759.48	1208.22	950.917	3882.2	4255.12	-372.92	1335.58		
65	1814.16	-10.96	950.917	4149.6	3618.14	531.46	1335.58		
66	1854.37	919.93	950.917	4795.0	3776.33	1018.67	1335.58		
67	1869.10	-533.30	950.917	7319.8	4158.16	3161.64	1335.58		
68	1867.56	-27.36	950.917	5422.0	4977.11	444.89	1335.58		

085	F_3 F_4 F_5 F_6 F_7 F_8 F_9 F_10 G_1 G_2 G_3 G_4 SIG_1 SIG_2 SIG_3 SIG_4
-----	--

52	*	*	*	*	*	*	*	*	*	*	*
53	*	*	*	*	*	*	*	*	*	*	*
54	*	*	*	*	*	*	*	*	*	*	*
55	*	*	*	*	*	*	*	*	*	*	*
56	*	*	*	*	*	*	*	*	*	*	*
57	*	*	*	*	*	*	*	*	*	*	*
58	*	*	*	*	*	*	*	*	*	*	*
59	*	*	*	*	*	*	*	*	*	*	*
60	*	*	*	*	*	*	*	*	*	*	*
61	*	*	*	*	*	*	*	*	*	*	*
62	*	*	*	*	*	*	*	*	*	*	*
63	*	*	*	*	*	*	*	*	*	*	*
64	*	*	*	*	*	*	*	*	*	*	*
65	*	*	*	*	*	*	*	*	*	*	*
66	*	*	*	*	*	*	*	*	*	*	*
67	*	*	*	*	*	*	*	*	*	*	*
68	*	*	*	*	*	*	*	*	*	*	*

085	Z1	FOR1	RES1	STD1	Z2	FOR2	RES2	STD2	Z3
-----	----	------	------	------	----	------	------	------	----

69	12305.6	12302.06	3.54	3644.84	3198.3	2512.00	686.3	3204.42	1677.6
70	15304.4	12492.54	2811.86	3644.84	3002.3	2988.14	14.46	3204.42	2595.6
71	9017.5	12433.81	-3416.31	3644.84	3685.1	2841.34	843.76	3204.42	2461.0
72	.	12638.40	.	3644.84	.	3352.75	.	3204.42	.
73	.	12538.81	.	3835.92	.	3103.02	.	4003.37	.
74	.	12464.23	.	7893.16	.	2917.39	.	4288.66	.
75	.	12403.36	.	907.36	.	2777.73	.	4590.57	.
76	.	12386.52	.	3921.75	.	2673.13	.	4700.04	.

77	,	12335.18	,	1929.37	,	2594.79	,	4750.35	,
78	,	12311.71	,	3933.91	,	2536.11	,	4793.85	,
79	,	12294.12	,	3936.47	,	2492.16	,	4812.54	,
80	,	12280.95	,	3937.91	,	2459.25	,	4823.00	,
81	,	12271.04	,	3939.71	,	2434.59	,	4828.85	,

085	FDR3	RES3	STD3	Z4	FDR4	RES4	STD4	STATEVEC	F_1	F_2
-----	------	------	------	----	------	------	------	----------	-----	-----

69	1920.15	-242.55	950.92	4890.0	4529.10	350.90	1335.58		,	,
70	1876.00	719.60	950.92	5994.5	4905.17	989.33	1335.58		,	,
71	1889.62	571.38	950.92	4573.0	4789.21	-216.21	1335.58		,	,
72	1842.20	,	950.92	,	5193.16	,	1335.58		,	,
73	1865.28	,	976.61	,	4996.54	,	1551.81		,	,
74	1882.57	,	990.74	,	4849.27	,	1620.68		,	,
75	1895.51	,	998.57	,	4738.98	,	1644.11		,	,
76	1905.21	,	1002.94	,	4656.36	,	1652.23		,	,
77	1912.48	,	1005.39	,	4594.46	,	1655.06		,	,
78	1917.92	,	1006.75	,	4548.13	,	1656.05		,	,
79	1921.99	,	1007.52	,	4513.41	,	1656.40		,	,
80	1925.05	,	1007.95	,	4487.41	,	1656.52		,	,
81	1927.33	,	1008.19	,	4467.94	,	1656.56		,	,

085	F_3	F_4	F_5	F_6	F_7	F_8	F_9	F_10	G_1	G_2	G_3	G_4	SIG_1	SIG_2	SIG_3	SIG_4
-----	-----	-----	-----	-----	-----	-----	-----	------	-----	-----	-----	-----	-------	-------	-------	-------

69	,	,	,	,	,	,	,	,	,	,	,	,	,	,	,	,
70	,	,	,	,	,	,	,	,	,	,	,	,	,	,	,	,
71	,	,	,	,	,	,	,	,	,	,	,	,	,	,	,	,
72	,	,	,	,	,	,	,	,	,	,	,	,	,	,	,	,
73	,	,	,	,	,	,	,	,	,	,	,	,	,	,	,	,
74	,	,	,	,	,	,	,	,	,	,	,	,	,	,	,	,
75	,	,	,	,	,	,	,	,	,	,	,	,	,	,	,	,
76	,	,	,	,	,	,	,	,	,	,	,	,	,	,	,	,
77	,	,	,	,	,	,	,	,	,	,	,	,	,	,	,	,
78	,	,	,	,	,	,	,	,	,	,	,	,	,	,	,	,
79	,	,	,	,	,	,	,	,	,	,	,	,	,	,	,	,
80	,	,	,	,	,	,	,	,	,	,	,	,	,	,	,	,
81	,	,	,	,	,	,	,	,	,	,	,	,	,	,	,	,

Lampiran 4 :

Program dan output uji multinormal residual

PROGRAM UJI MULTINORMAL

```
gnmacro
nm
do k1=1:4
  let c5(k1)=mean (ck1)
enddo
prin c5
do k1=1:71
  let k2=k1+5
  do k4=1:4
    . let ck2(k4)=ck4(k1)-c5(k4)
  enddo
enddo
copy c1-c4 m1
cova c1-c4 m2
inve m2 m3
invcdf 0.5 k51;
chis 4.
let k53=0
do k1=1:71
  let k2=k1+5
  copy ck2 m10
  tran m10 m11
  multi m3 m10 m12
  multi m11 m12 k3
  let c100(k1)=k3
  sort c100 c100
enddo

note dj kuadrat
print c100

note tabel chisquare
prin k51

do k52=1:71
  let k55=(k52-0.5)/71
  invcdf k55 k58;
  chis 4.
  let c103(k52)=k58
enddo

note plot multinormal residual
plot c103*c100
endmacro
```

HASIL PROGRAM (OUTPUT PROGRAM)

Nilai dj kuadrat

0.1616	0.4013	0.5367	0.7036	0.7520	0.8738	0.9578
0.9833	1.0753	1.1037	1.1606	1.1825	1.3223	1.3761
1.4242	1.4513	1.4675	1.5163	1.5598	1.6080	1.6198
1.6553	1.7588	1.7606	1.7904	1.9134	2.1412	2.2117
2.2580	2.2613	2.2918	2.3210	2.3421	2.7665	2.8387
2.9226	2.9596	2.9840	3.0561	3.1680	3.2036	3.2199
3.2637	3.4996	3.6809	3.8123	3.8227	3.8756	3.9768
4.0477	4.1627	4.4746	4.6406	4.7298	4.8211	4.9703
5.0315	5.3508	5.4550	5.5524	5.6984	5.8309	6.1890
6.5990	8.5320	8.5542	13.3809	14.0673	15.3312	17.7501
23.8372						

Nilai tabel chisquare

K51 3.35669

Lampiran 8 :

Program dan output pemeriksaan pola residual

PROGRAM STATE SPACE RESIDUAL

```
data series;
  input Z1 Z2 Z3 Z4;
cards;
-1929.82  2422.95   200.81 -3100.01
-1198.23  -124.53    165.29 -829.21
  835.41   2982.56   -714.70 -833.93
  8311.35 -2260.89   -592.72 -508.72
-3839.72   613.92   -140.49 -861.51
-1021.15  2758.70   -557.94  418.05
-1592.47 -2700.66   288.83 -895.59
-2434.11  912.46   942.17 -72.95
-1971.78 -4464.42   752.10 -1213.74
-3464.47 -396.12   557.81 -406.31
-1753.87  2186.52  1441.03  175.70
  295.41 -2786.14   515.44 -906.32
  -620.80  5874.72  -448.39 -455.11
-1538.69  1166.65   258.81 -587.71
12791.23  1830.49   748.85 -547.58
-3332.76  3515.09   128.75  848.77
-1568.03 -3573.11   898.30  862.07
-2351.87 -1072.25  -582.68 -581.83
  -515.89  4347.09  -574.08  633.36
-2584.77 -6362.23   10.60 -1051.28
-2030.74  1966.78  -801.12 -875.95
-1186.36  350.55 -1033.48  393.67
-1522.03  3611.03  -986.12 -75.08
-1997.84  -682.30  1548.62 -741.88
-2417.67  -380.26  -529.99  636.52
  -565.54  7241.59  -198.58 -1.17
14516.63 -4182.15   504.85  411.31
-4273.30  4727.79  -343.87  881.13
  1298.59   476.08   28.70  262.54
  -817.40  5706.22  -387.32  4741.14
-1912.07 -2903.42   288.77 -1767.90
  -300.22  5962.72  -547.56  2117.38
  -280.52  1824.13  -433.83 -373.20
  -863.35 -3474.39  -332.32 -892.61
  1203.44  5600.09  -426.40  1796.85
  180.54   918.32   69.89  1746.19
  -52.23   3408.46   418.20 -1543.23
-2396.48 -2358.43   953.03 -113.88
-1014.39 -2744.04   402.80 -574.00
-3320.49 -747.50  -796.86 -347.11
-1741.84  3429.04   1.75 -212.84
-1227.76 -4134.16  -826.39 -2739.45
-4734.52 -2880.29  -1072.81  1101.22
  207.65  1523.67  -531.57 -154.15
-5238.12 -3804.35  171.75 -132.37
```



```

-850.94 -2357.87 -429.39 -2777.59
-3032.27 -484.18 4493.67 -745.44
 373.90 2169.23 -263.09 1805.40
1033.69 1285.38 -999.35 883.17
-3704.52 -2995.75 -1063.91 -600.70
 435.07 -1326.17 -766.37 853.44
1273.10 -3305.08 -759.18 -1081.74
-1223.45 -1323.98 -796.31 -1116.63
-524.17 -302.98 -1461.19 1364.05
4409.36 495.37 -1201.63 1083.23
-3457.27 -2506.65 -810.75 -326.03
4718.64 4957.14 3193.33 1286.88
8317.90 -699.77 740.47 -1231.04
1133.85 -3891.58 -81.62 1306.23
5232.76 -2105.25 -38.87 555.25
2279.91 -443.52 -280.05 -1322.66
-89.88 -4171.36 -844.83 -1789.18
-589.07 773.75 236.10 2890.88
4380.29 -1856.10 1208.22 -372.92
3194.08 -1845.24 -10.96 531.46
-5183.08 -1723.75 919.93 1018.67
4226.04 -1542.69 -533.30 3161.64
3232.43 -516.62 -27.30 444.89
 3.54 686.30 -242.55 360.91
2811.86 14.16 719.60 989.33
-3416.31 843.76 571.38 -216.21
;
run;
proc statespace cancorr printout=short lead=10 out=out
outmodel=model;
var Z1 Z2 Z3 Z4;
run;

```

HASIL PROGRAM (OUTPUT PROGRAM)

```

STATESPACE Procedure
Nobs = 69

Variable      Mean      Std
Z1           42.97522  3691.32
Z2           -39.8914   3203.043
Z3            165.3223  927.3383
Z4            7.001594  1334.644

Information Criterion for Autoregressive Models

Lag=0          Lag=1          Lag=2          Lag=3          Lag=4
4172.193494  4187.469014  4210.977943  4226.521407  4240.294892

Lag=5          Lag=6          Lag=7          Lag=8          Lag=9
4234.136092  4242.411398  4252.057998  4267.483398  4284.554849

Lag=10
4285.668683

```

Schematic Representation of Correlations

Name/Lag	0	1	2	3	4	5	6	7	8	9	10
Z1	+
Z2	-	+	-
Z3	..	+	+
Z4	..	+	+	...	-

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

Schematic Representation of Partial Autocorrelations

Name/Lag	1	2	3	4	5	6	7	8	9	10
Z1	+
Z2	-
Z3	+
Z4	+

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

State Vector

Z1(T;T) Z2(T;T) Z3(T;T) Z4(T;T)

Estimate of the Transition Matrix

0	0	0	0
0	0	0	0
0	0	0	0
0	0	0	0

Input Matrix for the Innovation

1	0	0	0
0	1	0	0
0	0	1	0
0	0	0	1

Variance Matrix for the Innovation

13625843.5 13973.3002 103774.568 548079.566
 13973.3002 10259482.6 -248693.3 1538708.72
 103774.568 -248693.3 859956.353 5863.71935
 548079.566 1538708.72 5863.71935 1781275.45

State Vector

Z1(T;T) Z2(T;T) Z3(T;T) Z4(T;T)

Estimate of the Transition Matrix

0	0	0	0
0	0	0	0
0	0	0	0
0	0	0	0

Input Matrix for the Innovation

1	0	0	0
0	1	0	0
0	0	1	0
0	0	0	1

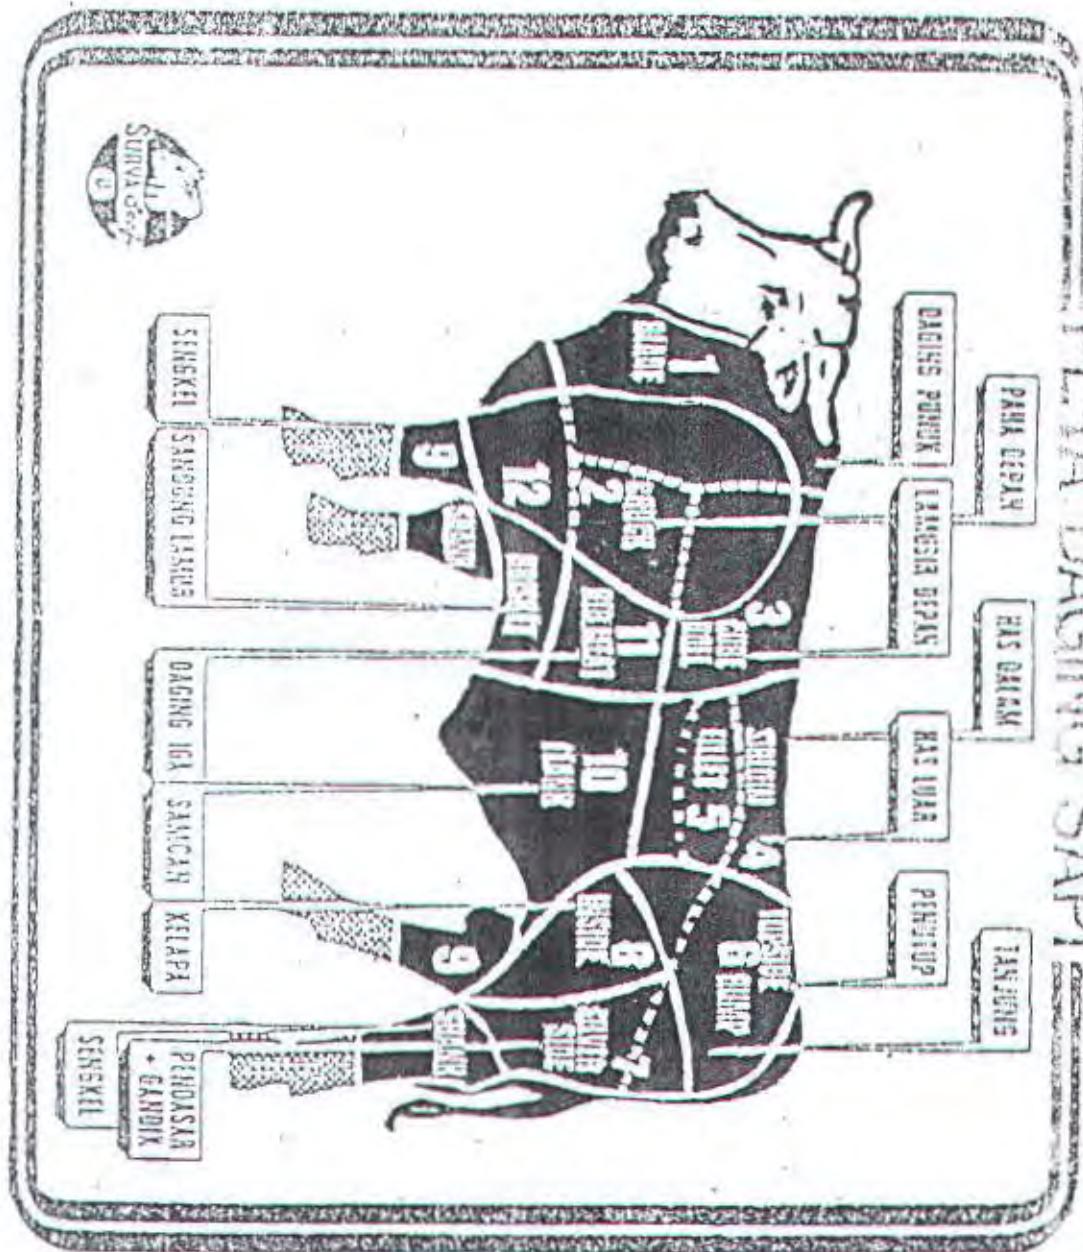
Variance Matrix for the Innovation

13625843.5	13973.3002	103774.568	548079.566
13973.3002	10259482.6	-248693.3	1538708.72
103774.568	-248693.3	859936.353	5863.71935
548079.566	1538708.72	5863.71935	1781275.45

JESUS MENGINGGUNG SEMUA DAPAT
DILAKUKAN DI SINI DAN
DIINGGUNGKAN ASIKANNA YANG SEDI

PETA-DAGING SAPI

BAGI
JENIS BAKS BEKAS
DILINDUNG DAN



LAMPIRAN 2		DUGI PASANG BANTAI SIRAPAN ANGKAN MELARAKA SUDU		
7	LAZIK RINGANE EMPAK BENDENG BASO LACK	NO.	8	CRANED SALE DAG. CURE SOP
8	RIVER SENIOR SOP KANG	NO.	9	CRANED SALE DAG. CURE SOP
10	CRANED SALE DAG. CURE SOP	NO.	11	CRANED ROLL RAWAN SOP ROAS

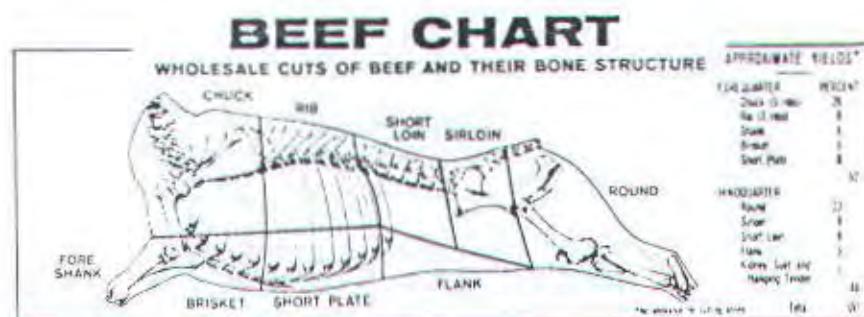


FIGURE 10-3. Beef chart—wholesale cuts of beef and their bone structure (National Live Stock and Meat Board.)

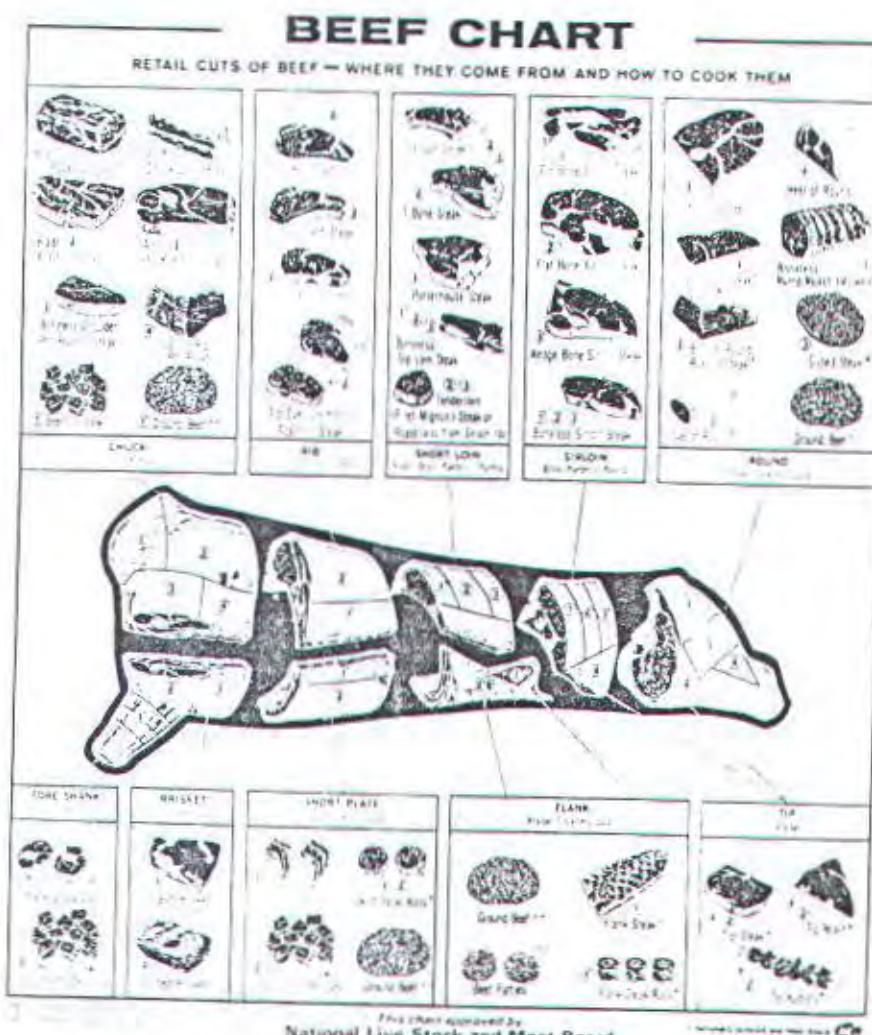


FIGURE 10-4. Retail cuts of beef—where they come from and how to cook them (National Live Stock and Meat Board.)