

ABSTRAK

PERAMALAN JUMLAH SURAT JASA POS KILAT KHUSUS DENGAN PENDEKATAN ANALISA FUNGSI TRANSFER DI DAERAH POS DAN GIRO III JAWA TIMUR

Perencanaan mutlak diperlukan untuk mewujudkan tujuan manusia agar efisien dan efektif. Perencanaan banyak digunakan pendekatan berbagai disiplin ilmu sehingga dengan integrasi tersebut akan sangat mendukung terwujudnya perencanaan yang tepat. Sehingga akhirnya berbagai keputusan yang tepat dan bijaksana dapat dihasilkan.

Dalam perencanaan maka salah satu sisi yang penting adalah peramalan. Karena dengan peramalan dapat diketahui bagaimana keadaan di waktu waktu yang akan datang berdasarkan informasi masa lalu. Kebutuhan akan semakin meningkat manakala diinginkan ketidaktergantungan akan faktor ketidakpastian.

Perum Pos Dan Giro sebagai salah satu BUMN tentu ingin mengembangkan usahanya agar lebih maju. Oleh karena itu tentunya dikembangkan pula sistem perencanaan yang baik. Maka dari itu faktor peramalan tentunya juga menjadi penting seiring dengan perencanaan. Dalam tugas akhir ini dikaji satu sisi dari peramalan yang dilakukan oleh Perum Pos Dan giro yaitu peramalan untuk jumlah surat jasa pos kilat khusus.

BAB 2

LANDASAN TEORI

2.1 PENDAHULUAN

Teknik-teknik peramalan terbagi dalam dua kategori, yaitu kuantitatif dan kualitatif. Peramalan kuantitatif dapat diterapkan jika dimiliki ketiga syarat berikut:

1. Adanya informasi tentang masa lampau.
2. Informasi itu dapat ditransformasikan ke dalam bentuk data masa lampau.
3. Pola data dimasa lampau dianggap akanberkelanjutan dimasa depan (anggapan kekonstanan atau assumption of constancy).

Dalam peramalan kuantitatif ada dua jenis prosedur yakni prosedur menurut metode formal dan metode nonformal/intuisi. Dasar dari metode formal tentunya yaitu hukum-hukum dalam statistika. Metode intuisi tentu lebih bersifat subyektif. Misal inflasi tahun depan akan naik 1%. Dalam kenyataan dalam metode intuisi sering juga digunakan prinsip ekstrapolasi, hanya tidak ada aturan yang standar dandasarnya hanya pengalaman empiris saja.

Dalam tugas akhir ini yang dikaji adalah metode formal, dimana ekstrapolasi dilakukan secara sistematis dan bersifat baku dan ditujukan untuk meminimumkan error(galat) dari ramalan. Pada prinsipnya ada dua untuk metode formal yaitu model kausal (regresi) dan model


-x analisa runtun waktu yang kita kenal dengan analisa time series. Pengkajian dalam tugas akhir ini menggunakan metode analisa time series yang akan dijelaskan lebih lanjut secara terperinci.

Time series adalah sekelompok nilai-nilai pengukuran yang diperoleh, ^{di}kumpulkan pada suatu kurun waktu yang berurutan. Time series ini dapat didekati dengan hukum-hukum probabilitas yang disebut Proses Stokastik, artinya setiap nilai dari suatu rangkaian pengamatan berasal dari suatu variabel random yang mempunyai fungsi distribusi tertentu. Secara mudah dapat digambarkan dengan jelas sebagai suatu variabel random berdimensi n , (Z_1, Z_2, \dots, Z_n) dengan fungsi distribusi bersama sebagai berikut $P(Z_1, Z_2, \dots, Z_n)$.

Pada umumnya, perhatian utama dalam analisis time series bukan pada titik waktu pengamatan t_1 , melainkan pada urutan waktu pengamatan. Karena itu, time series yang diamati pada waktu t_1, t_2, \dots, t_n dapat dicatat sebagai Z_t , dimana t menyatakan urutan (Box and Jenkins, 1976).

2.1 STASIONAIRITAS TIME SERIES

Time series dikatakan stasioner jika bentuk fungsi distribusi bersama (joint distributions) dari pengamatan $Z_t, Z_{t+1}, \dots, Z_{t+m}$ pada waktu ke $t, t+1, t+2, \dots, t+m$ sama dengan bentuk fungsi distribusi



bersama dari pengamatan Z_1, Z_2, \dots, Z_{t+m} pada waktu ke $t+k, t+k+1, \dots, t+k+m$. Dengan kata lain

$$\begin{aligned} P(Z_t, Z_{t+1}, \dots, Z_{t+m}) &= \\ P(Z_{t+k}, Z_{t+k+1}, \dots, Z_{t+k+m}) &\dots (1) \end{aligned}$$

untuk k, t dan m sembarang. Dalam Box and Jenkins (1976), series yang memenuhi syarat ini dikatakan bersifat stasioner kuat (Stricktly Stationary).

Jika suatu time series bersifat stasioner kuat, maka μ , σ^2 dan kovarians tidak terpengaruh oleh waktu pengamatan, sehingga

$$E(Z_t) = E(Z_{t+k}) = \mu$$

$$E(Z_t - \mu)^2 = E(Z_{t+k} - \mu)^2 = \sigma^2 \dots (2)$$

$$\begin{aligned} E(Z_t - \mu)(Z_{t+k} - \mu) &= E(Z_{t+m} - \mu)(Z_{t+k+m} - \mu) \\ &= \gamma_k \end{aligned}$$

dimana t, k dan m sembarang.

Ketiga persamaan ini dapat ditafsirkan bahwa series Z_t akan berfluktuasi disekitar mean μ dengan varian σ^2 tetap. Selanjutnya, γ_k disebut autokovarians lag k , hubungan autokovarians sebagai fungsi dari k ini disebut fungsi autokovarians.

Jika beberapa variabel random mempunyai distribusi normal ganda, maka seluruh informasi tentang distribusinya dapat diterangkan oleh nilai mean, varians dan kovariansnya. Oleh karena itu jika time series yang diamati berasal dari variabel random dengan distribusi normal, maka series tersebut sudah dapat dikatakan stricktly stationary asal mempunyai mean, varians dan kovarians yang sama untuk sembarang waktu pengamatan (Box and Jenkins, 1976).

AUTOKORELASI

Keeratan hubungan antara dua variabel time series yang mempunyai selisih waktu k diukur dengan suatu besaran yang disebut autokorelasi dengan lag k dan didefinisikan sebagai :

$$\begin{aligned} \rho_k &= \frac{E(Z_t - \mu)(Z_{t+k} - \mu)}{\sqrt{E(Z_t - \mu)^2(Z_{t+k} - \mu)^2)}} \dots (3) \\ &= \frac{E(Z_t - \mu)(Z_{t+k} - \mu)}{\sigma^2} \end{aligned}$$

untuk proses stationer , maka $\sigma^2 = \tau_0$ sebab pada waktu ke $t+k$ sama dengan waktu ke t .

Sehingga, autokorelasi pada lag k adalah

$$\rho_k = \frac{\tau_k}{\tau_0} \dots (4)$$

2.2 MODEL STOKASTIK TIME SERIES


Time series dapat dipandang sebagai variabel random shock yang dibangkitkan oleh suatu deret white noise. White noise sendiri adalah suatu deret data yang tidak mempunyai pola apapun dalam deret tersebut. Jadi merupakan variabel random yang bersifat tidak saling berkorelasi dan berdistribusi normal dengan mean (μ) nol dan variansi σ_a^2 konstan, ditulis $a_t \sim N(0; \sigma_a^2)$. Perubahan dari proses white noise a_t menjadi suatu time series Z_t tersebut melalui suatu linear filter

dengan fungsi transfer $W(B)$, seperti ditunjukkan dalam gambar 2-1 dan dapat dinyatakan dalam bentuk kombinasi kombinasi linier berikut :

$$Z_t = W(B) a_t$$

$$= \mu + a_t + W_1 a_{t-1} + W_2 a_{t-2} \dots\dots$$

$$W(B) = (1 + W_1 B + W_2 B^2 + W_3 B^3 + \dots) \dots (5)$$




Gambar 2-1 Representasi Time Series Sebagai Hasil Dari Linear Filter.

Mean (μ) adalah suatu parameter yang menunjukkan tingkat proses itu. $W(B)$ sebagai operator linear yang mentransformasikan a_t ke Z_t , dan dinamakan filter.

Sedangkan B adalah operator langkah mundur (Backward shift) yang didefinisikan $B_1 a_t = a_{t-1}$ (Box and Jenkins, 1976).

Persamaan (5) merupakan sebuah pernyataan yang menerangkan pembangkitan deret Z_t melalui proses stokastik. Selanjutnya, dari persamaan tersebut dapat diturunkan bentuk-bentuk khusus model stokastik, yaitu model autoregresi $AR(p)$, model moving average $MA(q)$, model campuran (ARMA) dan model-model terintegrasi. Ketiga model



yang pertama berlaku bagi time series stasioner, sedangkan model yang terakhir berlaku bagi time series nonstasioner. Penurunan dari persamaan linear umum menjadi bentuk-bentuk khusus ini dijelaskan dalam Box and Jenkins (1976).

2.2.1 MODEL AUTOREGRESI

Model autoregresi dengan ordo p , disingkat $BAR(p)$ atau $ARIMA(p,0,0)$ menyatakan nilai pengamatan pada waktu ke t merupakan hasil regresi dari nilai-nilai pengamatan sebelumnya sepanjang p periode atau ditulis dalam bentuk

$$\begin{aligned}
 Z_t &= \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} + a_t \quad \dots (6) \\
 Z_t &- \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} \\
 &= a_t \\
 (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) Z_t &= \phi(B) Z_t \\
 &= a_t \\
 &\dots (7)
 \end{aligned}$$

dimana $a_t \sim N(\mu, \sigma^2)$.

Agar persamaan diatas sah sebagai model stasioner, maka model tersebut harus memenuhi suatu syarat yang disebut syarat kestasioneran (Box and Jenkins, 1976).

SYARAT STASIONER MODEL AR (p)

Pada model (7), model $\phi(B)$ dapat dipandang polinomial dalam B . Sehingga dapat dikatakan $\phi(B)=0$ merupakan persamaan karakteristik dalam proses tersebut. Syarat

Kestasioner menghendaki bahwa nilai mutlak dari persamaan karakteristik harus lebih besar dari satu atau $|B| > 1$.

Misal untuk AR(1)

$$\begin{aligned} 1 - \phi_1 B &= 0 \\ \phi_1 B &= 1 \\ B &= \phi_1^{-1} \end{aligned}$$

Jika $|B| > 1$ maka didapat $|\phi_1| < 1$, jadi

$$-1 < \phi_1 < 1 \quad \dots (8)$$

Untuk AR(2)

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 = 0$$

harus terletak diluar lingkaran satuan. Jadi

$$\begin{aligned} \phi_2 + \phi_1 &< 1 \\ \phi_2 - \phi_1 &< 1 \\ -1 < \phi_2 &< 1 \end{aligned} \quad \dots (9)$$

(Box and Jenkins, 1976).

FUNGSI AUTOKORELASI MODEL AR(p).

Jika didefinisikan

$$Z_t = Z_t - \mu$$

maka persamaan (2) menjadi


$$\begin{aligned} \tau_k &= E(Z_t - \mu)(Z_{t+k} - \mu) \\ &= E(Z_t \cdot Z_{t+k}) \end{aligned}$$

Dari persamaan (6)

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p}$$

digandakan dengan Z_{t+k} ,

$$\begin{aligned} Z_t Z_{t+k} &= \phi_1 Z_{t-1} Z_{t+k} + \dots \\ &+ \phi_p Z_{t-p} Z_{t+k} + Z_{t+k} a_t \end{aligned}$$



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

dimana $E(Z_{t+k} a_t) = 0$ untuk $k \geq 1$

Jadi fungsi autokorelasi dapat dinyatakan

$$\begin{aligned} \gamma_0 &= \phi_1 \gamma_1 + \phi_2 \gamma_2 + \dots + \phi_p \gamma_p \\ \gamma_2 &= \phi_1 \gamma_1 + \phi_2 \gamma_1 + \dots + \phi_p \gamma_{p-1} \\ \dots & \\ \gamma_p &= \phi_1 \gamma_1 + \phi_2 \gamma_2 + \dots + \phi_p \gamma_0 \end{aligned}$$

karena $\gamma_k = \gamma_{-k}$ maka persamaan menjadi

$$\gamma_k = \phi_1 \gamma_{k-1} + \phi_2 \gamma_{k-2} + \dots + \phi_p \gamma_{k-p} \quad \dots(10)$$

Dengan cara yang sama dan persamaan (4) maka didapat γ_k sebagai berikut :

$$\begin{aligned} \gamma_k &= \phi_1 \gamma_{k-1} + \phi_2 \gamma_{k-2} + \dots \\ &+ \phi_p \gamma_{k-p} \quad \dots(11) \end{aligned}$$

(Box and Jenkins, 1976).

FUNGSI AUTOKORELASI PARSIAL

Autokorelasi parsial merupakan Koefisien terakhir dari suatu persamaan autoregresi, misal pada $AR(k)$, jika ϕ_{kj} ($j = 1, 2, \dots, k$) menyatakan Koefisien ke j maka ϕ_{kk} dikatakan sebagai autokorelasi parsial. Dengan demikian untuk untuk $k = 1, 2, \dots, k$, maka $\phi_{11}, \phi_{22}, \dots, \phi_{kk}$

dimana $a_t \sim N(0, \sigma^2)$

Agar persamaan (15) sah sebagai model untuk time series stasioner, maka persamaan tersebut harus dapat dinyatakan sebagai model autoregresi yang konvergen (mempunyai ordo berhingga). Untuk itu diperlukan batasan-batasan terhadap parameter θ_i ($i = 1, 2, \dots, q$) pada persamaan (15). Pembatasan-pembatasan ini dikenal dengan nama syarat invertibilitas model MA(q).

SYARAT INVERTIBEL MODEL MA(q)

Seperti halnya syarat stationer model AR(q). $\Theta(B)$ dapat dipandang sebagai polinomial dalam B, sehingga mempunyai persamaan karakteristik : $\Theta(B) = 0$. MA(q) dapat dikatakan invertibel jika nilai mutlak akar persamaan karakteristik lebih besar satu.

Untuk MA(1)

$$-1 < \theta_1 < 1$$

Untuk MA(2)

$$-1 < \theta_2$$

$$\theta_1 + \theta_2 < 1$$

$$\theta_1 - \theta_2 < 1$$



...(17)

FUNGSI AUTOKORELASI MA(q)

Dari persamaan (14) akan didapatkan fungsi autokovarian

$$\begin{aligned} \gamma_k &= 1 - \theta_k + \theta_1 \theta_{k+1} + \dots + \theta_{k-q} \theta_q, \quad k = 1, 2, \dots \\ &= (1 + \theta_1^2 + \dots + \theta_q^2) \sigma_a^2, \quad k = 0 \\ &= 0, \quad k > q \end{aligned} \quad \dots (18)$$

$$\hat{\gamma}_k \text{ didapat dari } \hat{\gamma}_k = \frac{r_k}{r_0}$$

Sehingga fungsi autokorelasi untuk model MA(q) dapat dinyatakan sebagai berikut :

$$\hat{\gamma}_k = \frac{-\theta_k + \theta_1\theta_{k+1} + \dots + \theta_{q-k}\theta_q}{1 + \theta_1^2 + \dots + \theta_q^2}, k=1,2,\dots$$

$$= 0, k < q \dots(19)$$

2.2.3 MODEL CAMPURAN AUTOREGRESI DAN MOVING AVERAGE

Model ini merupakan gabungan antara model AR(p) dan model MA(q) sehingga disebut ARMA(p q) atau ARIMA(p 0 q), dengan bentuk persamaan

$$Z_t = \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} + a_t$$

$$(1 - \theta_1 B - \dots - \theta_p B^p) Z_t = (1 - \theta_1 B - \dots - \theta_q B^q) a_t$$

$$\phi(B) Z_t = \theta(B) a_t \dots(20)$$

dimana $a_t \approx N(0, \sigma_2)$

KESTASIONERAN DAN INVERTIBILITAS MODEL ARMA(p,q).

Karena model ini gabungan antara AR(p) dan MA(q) maka syarat stasioner mengikuti model AR(p) dan invertibel mengikuti model MA(q).

Pada umumnya model campuran merupakan model yang sederhana karena mempunyai nilai p dan q yang kecil (Box and Jenkins, 1976), sehingga pembatasan terhadap parameteranya dapat ditentukan dengan mudah.

FUNGSI AUTOKORELASI MODEL ARMA (p,q).

Fungsi autokovarian model ARMA(p,q) diperoleh dengan

mendefinisikan $Z_t = Z_t - \mu$

dan $Z_{t-k} = Z_{t-k} - \mu$, dari persamaan (20)

didapat $r_k = E(Z_t Z_{t-k})$

$$r_k = \sum_{i=1}^p \phi_i E(Z_t Z_{t-k}) + \sum_{j=1}^q \theta_j E(a_{t-j} Z_{t-k})$$

$E(a_{t-j} Z_{t-k}) = 0$ untuk $k < j$ sebab a_{t-j} berkorelasi dengan Z_{t-k} .

$E(a_{t-j} Z_{t-k}) = 0$ untuk $j = 1, 2, \dots, q$ dengan demikian persamaan (21) menjadi

$$r_k = \phi_1 r_{k-1} + \phi_2 r_{k-2} + \dots + \phi_p r_{k-p}, k$$

Dan fungsi autokorelasinya

$$f_k = \phi_1 f_{k-1} + \phi_2 f_{k-2} + \dots + \phi_p f_{k-p}$$

Persamaan(23) sama dengan struktur fungsi Korelasi AR(p)

sehingga dapat dikatakan struktur fungsi autokorelasi

ARMA(p,q) didominasi pengaruh AR(p) untuk $k > q$, sedang

untuk $k = 1, 2, \dots, q$ struktur autokorelasi ARMA(p,q)

sangat kompleks dan dipengaruhi model MA(q).

2.2.4 MODEL-MODEL TERINTEGRASI

Misal suatu model autoregresi :

$$\phi(B)Z_t = a_t$$

tidak memenuhi syarat stasioner yang disebabkan oleh ada-



nya d akar sama dengan satu. Pada persamaan karakteristik $\phi(B) = 0$, polinomial dapat diuraikan menjadi

$$\phi(B)(1-B)^d Z_t = a_t \quad \dots (24)$$

$$\phi(B) \nabla^d Z_t = a_t$$

$\phi(B)$ merupakan operator autoregresi yang telah memenuhi syarat stationer, dan $\nabla^d = (1-B)^d$ (Box and Jenkins, 1976).

Jika dimisalkan bahwa $\nabla^d Z_t = w_t$ maka persamaan (24) tak lain adalah model autoregresi bagi w_t , dimana w_t dikatakan sebagai hasil differenzi ordo ke d dari deret Z_t . Sebaliknya Z_t merupakan hasil integrasi dari deret w_t .

Oleh karena itu model persamaan (24) disebut model autoregresi terintegrasi dengan ordo p dan q , disingkat $ARI(p, d)$ atau $ARIMA(p, d, 0)$. Selanjutnya, ∇^d disebut operator differenzi dan d disebut ordo differenzi (Box and Jenkins, 1976).


Model lain yang tak stasioner yaitu moving average terintegrasi (IMA) dan model campuran autoregresi - moving average terintegrasi (ARIMA). Model IMA(p,q) dinyatakan dalam bentuk

$$(1 - B)^d Z_t = \theta(B)a_t \quad \dots (25)$$

$$\nabla^d Z_t = \theta(B)a_t$$

dimana

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



Model ARIMA (p, d, q) dinyatakan sebagai

$$\phi(B)(1-B)^d Z_t = \theta(B)a_t \dots (26)$$

$$\phi(B)\nabla^d Z_t = \theta(B)a_t$$

Karena model-model terintegrasi merupakan model stationer bagi deret $w_t = (1-B)^d Z_t$, maka karakteristik model ini mengikuti karakteristik model-model stasioner yang telah dibicarakan sebelumnya.

2.2.5 MODEL ARIMA MULTIPLIKATIF

PENGARUH MUSIMAN.

Jika time series Z_t dibangkitkan oleh suatu proses stokastik yang bersifat periodik pada setiap interval waktu tertentu, maka proses tersebut digambarkan sebagai model musiman atau model tersebut dipengaruhi musim. Misal sifat proses tersebut berulang pada setiap s satuan waktu, maka modelnya dinyatakan sebagai berikut :

$$\begin{aligned} \phi_s(B^s)(1-B^s)^d Z_t &= \theta_s(B^s)a_t \\ \phi_s(B^s)\nabla_s^d Z_t &= \theta_s(B^s)a_t \dots (27) \end{aligned}$$

$$\begin{aligned} \text{dimana } \phi_s(B^s) &= 1 - \phi_s B^s - \phi_{2s} B^{2s} + \dots \\ &\quad - \phi_{ps} B^{ps} \end{aligned}$$

$$\begin{aligned} \theta_s(B^s) &= 1 - \theta_s B^s - \theta_{2s} B^{2s} - \dots \\ &\quad - \theta_{ps} B^{ps} \end{aligned}$$

D : order differenzi musiman

s : operator differensi musiman

sZ_t : $Z_t - Z_{t-s}$

PERSAMAAN MODEL MULTIPLIKATIF

Model (27) dapat dikatakan pembangkit deret Z_t oleh a_t berlangsung dengan jarak waktu s . Dari hasil diatas didapat persamaan model multiplikatif dengan mensubstitusikan persamaan (26) ke dalam persamaan (27).

$$\phi_s(B^s)\phi(B)s^{Dd}Z_t = \theta_s(B^s)\theta(B)a_t \quad \dots (28)$$

(Box and Jenkins, Makridaki's, Wheelwrights and Mcgee, 1988)

Model diatas dapat dizingkat ARIMA $(p \ d \ q) (P \ D \ Q)_s$.

Untuk $d \geq 1$ dan $D \geq 1$, persamaan tersebut merupakan pernyataan model terintegrasi yang berlaku bagi deret tak stasioner Sedangkan untuk $d=0$ dan $D=0$, model tersebut berlaku bagi deret stationer.

2.3 PERUMUSAN MODEL STOKASTIK TIME SERIES

Model-model stokastik yang dibicarakan sebelumnya tak lain adalah suatu alat yang digunakan untuk menerangkan proses stokastik yang membangkitkan time series. Oleh karena itu dengan mengambil n pengamatan Z_1, Z_2, \dots, Z_n dapat ditarik kesimpulan mengenai populasi time series Z_t . Jika terlebih dahulu dilakukan pendugaan model yang sesuai. Dengan kata lain,




nilai ramalan pada waktu yang akan datang baru dapat diketahui jika model terbentuk.

2.3.1 FUNGSI AUTOKORELASI DAN KESTASIONAIRAN TIME SERIES

Kaitan antara fungsi autokorelasi dan kestasioneran time series, antara lain telah dinyatakan dalam Box and Jenkins (1976). Time series yang bersifat stasioner akan mempunyai bentuk fungsi autokorelasi (Korelogram) yang menurun (menuju ke nol) secara eksponensial sejalan dengan bertambahnya lag. Jika deret tersebut semakin dekat ke batas tidak stasioner, maka kecenderungan menurun korelogramnya akan terjadi semakin lambat, dan sebaliknya. Jika deret tersebut semakin jauh dari batas stasioner maka penurunan korelogramnya akan semakin cepat. Korelogram bagi kedua sifat series stasioner tersebut masing-masing dapat dilihat contoh pada Gambar 2-1.

Berdasarkan pernyataan di atas, maka dapat dinyatakan lebih lanjut bahwa bentuk korelogram yang tidak cenderung menurun merupakan ciri series tidak stasioner.



Gambar 2-2 Grafik Fungsi Autokorelasi Time Series stationer.

Jika diperhatikan lebih lanjut struktur fungsi autokorelasi bagi deret stasioner, maka akan dijumpai kenyataan bahwa setiap time series mempunyai struktur fungsi autokorelasi yang bersifat khas, sesuai proses yang membangkitkan series tersebut (Box and Jenkins, 1976).

Dijumpai pula bahwa fungsi autokorelasi parsialnya memperlihatkan hubungan antar autokorelasi yang sama. Dengan demikian dapat dikatakan bahwa karakteristik kedua besaran tersebut merupakan cerminan dari proses stokastik.


Secara umum, karakteristik fungsi autokorelasi dan autokorelasi parsial untuk ketiga proses stasioner, yaitu AR(p), MA(q) dan ARMA(p, q), diberikan pada tabel 2.1 sebagai berikut :

Tabel 2-1 Karakteristik Fungsi Autokorelasi dan Fungsi Autokorelasi Parsial Proses AR(p), MA(q) dan ARMA(p, q)

Jenis Proses	Autokorelasi	Autokorelasi Parsial
AR(p)	Mengecil (mengekor) menurut persamaan $\hat{\rho}_k = \phi_1 \hat{\rho}_{k-1} + \dots + \phi_p \hat{\rho}_{k-p}$	Memencil pada lag 1 sampai p kemudian terpotong (cut off).
MA(q)	Memencil pada lag 1 sampai q kemudian terpotong (cut off)	Mengecil sejalan dengan bertambahnya lag (mengekor).
ARMA(p, q)	berpola tak beraturan pada lag 1 sampai q, kemudian mengecil menurut persamaan :	mengecil sejalan dengan bertambahnya lag, 'mengekor' (tail off)
	$\hat{\rho}_k = \phi_1 \hat{\rho}_{k-1} + \dots + \phi_{k-p} \hat{\rho}_{k-p}$	

Selain dua hal diatas, fungsi autokorelasi dan autokorelasi parsial juga dapat menunjukkan adanya pengaruh musiman dalam proses pembangkit time series.

Pengaruh ini ditandai oleh nilai autokorelasi atau autokorelasi parsial yang memencil secara berulang pada periode-periode musim tertentu.



Gambar 2-3 Grafik ACF Dan PACF Musiman.

2.3.2 PENDUGA AUTOKORELASI dan AUTOKORELASI PARSIAL


PENDUGA AUTOKORELASI.

Autokorelasi yang didefinisikan pada persamaan (4) diduga dengan autokorelasi yang dihitung berdasarkan n pengamatan Z_1, Z_2, \dots, Z_n yaitu

$$r_k = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2} \dots (29)$$

r_k : fungsi autokorelasi sampel.

$$\bar{Z} = \frac{\sum_{t=1}^n Z_t}{n}$$



Untuk ukuran sampel n yang cukup besar, autokorelasi sampel r_K (29) akan mempunyai distribusi normal dengan mean μ nol dan varians $\sigma^2 = V(r_K)$

$$V(r_K) = 1/n (1 + 2(r_{12} + \dots + r_{q2})), \quad K > q, \dots (30)$$

dimana q ordo dari model moving average yang dihipotesiskan $q = 0, 1, \dots, k$, sedangkan k adalah konstanta tertentu. Selang Kepercayaan $(1-\alpha)$ bagi ρ_K ialah

$$P(-Z_{\frac{\alpha}{2}} S(r_K) \leq \rho_K \leq Z_{\frac{\alpha}{2}} S(r_K)) = 1-\alpha.$$

PENDUGA AUTOKORELASI PARTIAL

Parsial autokorelasi ϕ_{kk} dapat ditentukan dengan persamaan Yule-Walker yang dirumuskan dalam bentuk matrik sebagai berikut :

$$\begin{vmatrix} 1 & \Gamma_1 & \Gamma_2 & \dots & \Gamma_{k-1} \\ \Gamma_1 & 1 & \Gamma_1 & \dots & \Gamma_{k-2} \\ \Gamma_2 & \Gamma_1 & 1 & \dots & \Gamma_{k-3} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \Gamma_{k-1} & \Gamma_{k-2} & \Gamma_{k-3} & \dots & 1 \end{vmatrix} = \begin{vmatrix} \phi_{k1} \\ \phi_{k2} \\ \phi_{k3} \\ \vdots \\ \phi_{kk} \end{vmatrix} \begin{vmatrix} \Gamma_1 \\ \Gamma_2 \\ \Gamma_3 \\ \vdots \\ \Gamma_k \end{vmatrix}$$

dimana :

$$k = 1, 2, 3, \dots$$

$\Gamma_1, \Gamma_2, \Gamma_3, \dots, \Gamma_k$ merupakan koefisien

autokorelasi.

Untuk $k = 1$, maka : $\phi_{11} = \Gamma_1$

Untuk $k = 2$, maka :

$$\phi_{22} = \frac{\begin{vmatrix} 1 & \Gamma_1 \\ \Gamma_1 & \Gamma_2 \end{vmatrix}}{\begin{vmatrix} 1 & \Gamma_1 \\ \Gamma_1 & 1 \end{vmatrix}} = \frac{\Gamma_2 - \Gamma_1^2}{1 - \Gamma_1^2}$$


Untuk $k = 3$, maka :

$$\phi_{33} = \frac{\begin{vmatrix} 1 & \Gamma_1 & \Gamma_2 \\ \Gamma_1 & 1 & \Gamma_1 \\ \Gamma_1 & \Gamma_2 & \Gamma_3 \end{vmatrix}}{\begin{vmatrix} 1 & \Gamma_1 & \Gamma_2 \\ \Gamma_1 & 1 & \Gamma_1 \\ \Gamma_2 & \Gamma_1 & 1 \end{vmatrix}} = \frac{\Gamma_1^2 - 2\Gamma_1\Gamma_2 + \Gamma_1\Gamma_2^2 - \Gamma_1^2\Gamma_3 + \Gamma_3}{1 - 2\Gamma_1^2 + 2\Gamma_1^2\Gamma_2 - \Gamma_2^2}$$

Nilai estimate ϕ_{kk} dapat diperoleh dengan mengganti Γ_k dengan r_k .

Sedang standar errornya didapat dengan rumus :


$$se(\phi_{kk}) = \sqrt{1/N}$$



2.4 Analisis Fungsi Transfer

2.4.1. Model Fungsi Transfer Linier

Fungsi Transfer merupakan pemodelan suatu deret waktu X_t sebagai variabel input dan deret waktu Y_t sebagai variabel output pada suatu proses yang dinamis. Sebagai ilustrasi dapat dilihat pada gambar berikut.



Gambar 2-4 Variabel Input Dan Variabel Output Dalam Sistem Dinamis

Kedua variabel X_t dan Y_t ini berada dalam kondisi dinamik, menyebabkan sistem yang mempengaruhinya juga akan berada dalam kondisi dinamis.

Model Fungsi Transfer yang merupakan sistem dinamis pengaruhnya tidak hanya sekedar hubungan linear antara waktu ke- t pada input X dan waktu ke- t pada output Y . Akan tetapi juga merupakan hubungan pada saat t input X dan saat t , $t+1$, $t+2$, ..., $t+k$ pada output Y . Atau dapat dikatakan, deret input X_t memberikan pengaruh terhadap deret output Y_t dimana pengaruh X_t ini berlangsung sampai beberapa periode waktu mendatang. Pada hubungan seperti ini, dalam fungsi transfer kemungkinan akan timbul *time delay* (waktu senjang) antara variabel input dan variabel output. Dimana pengaruh X_t tampak setelah waktu t pada output Y_t .

Seperti pada Analisis Time Series Univariabel, konsep dinamis yang terkendali juga berlaku disini. Input dan output harus berupa dalam kondisi stasioner. Kestasioneran untuk kedua variabel ini dilakukan agar mean serta variansi masing-masing variabel tidak dipengaruhi oleh waktu pengamatan.

Proses membuat data menjadi stasioner dalam Fungsi Transfer disebut *prewhitening*. *Prewhitening* ini dapat diartikan usaha untuk menghilangkan seluruh *pattern* (pola) yang ada dalam deret data sehingga deret tersebut menjadi konstan.

Pada variabel input, *prewhitening* dilakukan sampai mendapatkan kondisi input yang *white noise*, atau dengan lain kata mendapatkan operator *prewhitening* yang menyebabkan input *white noise*. Setelah mendapatkan operator *prewhitening* variabel input, operator ini kemudian dikenakan pada deret output. Proses ini disebut *Prewhitening* output. Pada *prewhitening* output tidak harus mengubah deret output menjadi *white noise*, akan tetapi kestasionerannya harus tetap dilakukan.

Dari *prewhitening* input dan *prewhitening* output, akan diperoleh deret α_t untuk input dan β_t untuk output. Kedua deret ini yang digunakan dalam identifikasi model Fungsi Transfer dengan membuat Korelasi silangnya.

Model linear Fungsi Transfer secara umum dapat ditulis sebagai :

$$\begin{aligned}
Y_t &= V_0 X_t + V_1 X_{t-1} + V_2 X_{t-2} + \dots \\
&= (V_0 + V_1 B + V_2 B^2 + \dots) X_t \\
&= V(B) X_t \qquad (31)
\end{aligned}$$

Dimana output pada waktu ke t menyatakan jumlah linear dari input pada waktu t, t-1, t-2, ... dengan operator v(B) yang disebut sebagai filter fungsi transfer dan v₀, v₁, v₂, ... merupakan *respon impuls* dari sistem.

Hubungan antara pengamatan t dengan pengamatan t-1 adalah :

$$\begin{aligned}
Y_t &= Y_t - Y_{t-1} = (1 - B) Y_t \\
x_t &= X_t - X_{t-1} = (1 - B) X_t
\end{aligned}$$


Hal ini untuk menandakan suatu deret yang di *difference* (pembedaan) dalam usaha untuk mendapatkan deret yang stasioner. Dengan demikian persamaan (31) menjadi :

$$Y_t = V(B) x_t$$

deret $V_0 + V_1 B + V_2 B^2 + \dots$ infinite, akan konvergen untuk nilai $|B| < 1$, maka sistem akan stasioner.

Dari waktu ke waktu, akan ditunjukkan tingkat *steady state* dari output yang diperoleh dari deret input. dengan demikian nilai Y (X) merupakan output dari sistem yang stabil dengan input yang mempunyai nilai tetap X. Hubungan antara Y (X) dan X merupakan hubungan linier. Dimana bila digunakan Y dan X dengan penyimpangan dari dari situasi sebenarnya, maka dapat ditulis suatu hubungan *steady state*

$$Y = g X$$



dimana g merupakan fungsi pertambahan yang tetap dan Y merupakan fungsi dari X . Dan nilai g ditentukan dari persamaan

$$g = \frac{w_0 - w_1 - \dots - w_s}{1 - \partial_1 - \dots - \partial_r} \quad (33)$$

2.4.2. Model Dinamik

Sistem dinamis diskrit sering dinyatakan dalam persamaan linier dengan pembedaan sebagai berikut.

$$\begin{aligned} & (1 + x_1 \nabla + x_2 \nabla^2 + \dots + x_r \nabla^r) Y_t \\ & = g (1 + h_1 \nabla + h_2 \nabla^2 + \dots + h_s \nabla^s) X_{t-b} \end{aligned} \quad (34)$$

Model diatas merupakan model fungsi transfer orde (r, s) , jika ditulis dalam operator back-ward menjadi :

$$\begin{aligned} & (1 - \partial_1 B - \partial_2 B^2 - \dots - \partial_r B^r) Y_t \\ & = (w_0 - w_1 B - w_2 B^2 - \dots - w_s B^s) X_{t-b} \end{aligned} \quad (35)$$

atau

$$\partial(B) Y_t = w(B) X_{t-b}$$

jika nilai $\Omega(B) = w(B)B^b$, maka model menjadi

$$\partial(B) Y_t = \Omega(B) X_t \quad (36)$$

Dengan membandingkan persamaan (36) dan persamaan (31) terlihat bahwa fungsi transfer untuk model ini adalah

$$V(B) = \delta^{-1}(B)\Omega(B) \quad (37)$$

maka fungsi transfer dapat dinyatakan dengan perbandingan antara dua polinomial dalam B.

Suatu model stokastik dinamis dari ARIMA

$$f(B) Z_t = \theta(B) a_t$$

dapat digunakan untuk menyatakan deret waktu Z_t dan dengan a_t dengan menggunakan operasi filter linier

$$Z_t = f^{-1}(B) \theta(B) a_t$$

dimana a_t adalah *white noise*. Maka model deret waktu dapat dinyatakan sebagai output dari sistem dinamis, yang mana inputnya adalah *white noise*.

Kestasioneran dari fungsi transfer yang ternyata sejalan dengan kestasioneran dari model stokastik dari deret waktu, maka kestasioneran ini diperlukan untuk mendapatkan akar-akar karakteristik dari persamaan

$$\delta(B) = 0$$

sebagai contoh untuk model orde satu, maka nilai estimasi parameter δ_1 adalah


$$-1 < \delta_1 < 1$$

dan untuk orde dua, nilai parameter dari δ_1 dan δ_2 adalah :

$$\delta_2 + \delta_1 < 1$$

$$\delta_2 - \delta_1 < 1$$

$$-1 < \delta_2 < 1$$



seandainya persamaan (35) ditulis secara lengkap maka diperoleh :

$$Y_t = \partial_1 Y_{t-1} + \partial_2 Y_{t-2} + \dots + \partial_r Y_{t-r} + w_0 X_{t-b} - w_1 X_{t-b-1} - \dots - w_s X_{t-b-s} \quad (38)$$

Model fungsi transfer yang telah didefinisikan pada persamaan (35) disubstitusi dengan :

$$Y_t = V(B) X_t \quad (39)$$

maka diperoleh persamaan :

$$(1 - \partial_1 B - \partial_2 B^2 - \dots - \partial_r B^r) (V_0 + V_1 B + \dots) = (w_0 - w_1 B - \dots - w_s B^s) B^b \quad (40)$$

Dengan memperhatikan koefisien dari pada B diperoleh ketentuan :

$$\begin{aligned} V_j &= 0 & j < b \\ V_j &= \partial_1 V_{j-1} + \partial_2 V_{j-2} + \dots + \partial_r V_{j-r} - w_0 & j = b \\ V_j &= \partial_1 V_{j-1} + \partial_2 V_{j-2} + \dots + \partial_r V_{j-r} - w_{j-b} & j = b+1, b+2, \dots, b+s \\ & & (41) \\ V_j &= \partial_1 V_{j-1} + \partial_2 V_{j-2} + \dots + \partial_r V_{j-r} & j > b+s \end{aligned}$$

Model fungsi transfer yang telah diberikan pada persamaan terdahulu adalah :

$$\begin{aligned} Y_t - \partial_1 Y_{t-1} - \partial_2 Y_{t-2} - \dots - \partial_r Y_{t-r} \\ = w_0 X_{t-b} - w_1 X_{t-b-1} - \dots - w_s X_{t-b-s} \end{aligned}$$

atau

$$Y_t = \delta^{-1}(B) w(B) X_{t-b}$$

dimana $\delta(B) = 1 - \delta_1 B - \delta_2 B^2 - \dots - \delta_r B^r$ dan

$$w(B) = w_0 - w_1 B - \dots - w_s B^s$$

Dalam fungsi transfer terdapat deret input (X_t) yang diharapkan akan mempengaruhi deret output (Y_t), serta dipengaruhi oleh deret input lain yang disebut *noise* (N_t).

Untuk sistem linier dengan N_t pada output dan mengasumsikan dibangkitkan dengan proses ARIMA yang menjamin bahwa N_t independen dari input X_t . Jika dalam Model Fungsi Transfer digunakan order r dan s untuk parameter δ , w dan waktu senjang b . Dan penambahan N_t bertujuan untuk membuat estimasi dari parameter p, d, q dari proses ARIMA yang menggambarkan noise at pada output dan untuk memperoleh estimasi parameter ϕ dan θ dalam model. Model yang menggabungkan antara X_t , Y_t dan N_t dapat ditulis.

$$Y_t = \delta^{-1}(B) w(B) X_{t-b} + N_t \quad (42)$$

atau dengan menggunakan model ARIMA

$$Y_t = \delta^{-1}(B) w(B) X_{t-b} + \Theta(B) \phi(B)^{-1} a_t \quad (43)$$

Model ini digunakan bila dalam menguji N_t masih terdapat pola yang dapat diidentifikasi sebagai model stokastik ARIMA. Jika dalam pengujian N_t tidak ditemukan pola lagi, model (42) yang digunakan sebagai model fungsi Transfer.

2.4.3. Korelasi Silang


Dengan cara yang sama pada identifikasi model stokastik yaitu dengan menggunakan autokorelasi, maka untuk mengidentifikasi model fungsi transfer digunakan korelasi silang antara deret input dan deret output.

Sebagai gambaran deret waktu input X_t berhubungan sistem dengan deret waktu output Y_t dari proses stokastik bivariate yang berpasangan (X_t, Y_t) . Suatu proses stokastik linier mempunyai mean μ dan autokovariansi ϵ_k , atau ekuivalen dengan mean μ dan variansi σ^2 serta autokorelasi r_k . Apabila data dari proses stokastik (X_t, Y_t) tidak stasioner, maka dilakukan pembedaan sehingga proses menjadi stasioner

(x_t, y_t) , dimana $x_t = (1 - B)^d X_t$ dan $y_t = (1 - B)^d Y_t$.

Kestasioneran tercapai apabila x_t dan y_t mempunyai mean yang konstan (μ_x, μ_y) serta variansi yang konstan yaitu (σ_x^2, σ_y^2) . Jika proses diasumsikan mempunyai distribusi normal, maka mempunyai karakteristik mean μ_x dan μ_y serta matriks kovariansi :

$$\Sigma_{XY} = \begin{bmatrix} \epsilon_{XX} & \epsilon_{XY} \\ \epsilon_{YX} & \epsilon_{YY} \end{bmatrix}$$



Koefisien autokovariansi dari masing-masing deret didefinisikan sebagai :

$$\epsilon_{XX}(k) = E[(x_t - \mu_x)(x_{t+k} - \mu_x)] = E[(x_t - \mu_x)(x_{t-k} - \mu_x)]$$

(44)

$$g_{yy}(k) = E[(Y_t - \mu_y)(Y_{t+k} - \mu_y)] = E[(Y_t - \mu_y)(Y_{t-k} - \mu_y)]$$

Bentuk Kovariansi lain yang dapat diizinkan ke dalam bentuk matrik adalah Kovariansi silang antara deret waktu x_t dan deret waktu y_t .

$$g_{xy}(k) = E[(x_t - \mu_x)(y_{t+k} - \mu_y)] \quad k = 1, 2, \dots \quad (45)$$

$$g_{yx}(k) = E[(y_t - \mu_y)(x_{t+k} - \mu_x)] \quad k = 1, 2, \dots$$

Secara umum g_{xy} tidak sama dengan g_{yx} , namun apabila diatur kembali pada persamaan diatas diperoleh :

$$\begin{aligned} g_{xy}(k) &= E[(x_{t-k} - \mu_x)(y_t - \mu_y)] = E[(y_t - \mu_y)(x_{t-k} - \mu_x)] \\ &= g_{yx}(-k) \end{aligned} \quad (46)$$

Koefisien korelasi silang dari proses bivariate adalah :

$$\begin{aligned} r_{xy}(k) &= g_{xy}(k) \{\sigma_x \sigma_y\}^{-1} \\ k &= \pm 1, \pm 2, \dots \end{aligned} \quad (47)$$

Dalam model Fungsi Transfer, selain digunakan untuk identifikasi korelasi silang digunakan untuk melihat apakah *noise* a_t pada model ARIMA sudah *white noise*.

Untuk mengetahui dibuat korelasi silang antara deret a_t dan α_t yang diperoleh pada waktu melakukan prewhitening input.

2.4.4. Perumusan model

Kombinasi fungsi transfer dengan *noise* adalah :

$$Y_t = \delta^{-1}(B) w(B) X_{t-b} + N_t \quad (48)$$

atau

$$Y_t = V_0 x_t + V_1 x_{t-1} + \dots + n_t$$

jika persamaan (48) dikalikan dengan x_{t-k} untuk $k \geq 0$ diperoleh :

$$x_{t-k} Y_t = V_0 x_{t-k} x_t + V_1 x_{t-k} x_{t-1} + \dots + x_{t-k} n_t \quad (49)$$

dengan asumsi bahwa x_{t-k} tidak berkorelasi dengan n_t untuk semua nilai k . maka persamaan (49) apabila diekspektasikan menjadi :

$$\begin{aligned} g_{xy}(k) &= V_0 g_{xx}(k) + V_1 g_{xx}(k-1) + \dots \\ k &= 0, 1, 2, \dots \end{aligned} \quad (50)$$

2.4.4.1. *Prewhitening* Deret Input Dan Output

Identifikasi dapat dilakukan apabila deret input adalah *white-noise* yang stasioner dalam model Autoregresi dan Moving Average. Identifikasi dan model untuk deret input dinyatakan dalam :

$$\phi(B) \theta^{-1}(B) x_t = \alpha_t \quad (51)$$

dimana x_t dan α_t tidak berkorelasi.

untuk mempertahankan integritas hubungan antara deret input dan output, maka deret output juga dimodelkan sama seperti deret input.

$$\phi(B) \theta^{-1}(B) Y_t = \beta_t \quad (52)$$

Model dari persamaan (47) dapat ditulis :

$$B_t = V(B) \alpha_t + e_t \quad (53)$$

e_t adalah model dari deret *noise* yang dimodelkan sebagai : 07 3

$$e_t = \phi(B) \theta^{-1}(B) n_t \quad (54)$$

Persamaan (53) jika dikalikan dengan α_{t-k} untuk kedua sisinya dan diekspektasikan diperoleh :

$$g_{\alpha\beta}(k) = V_k \sigma_\alpha^2 \quad (55)$$

dimana $g_{\alpha\beta}(k) = E(\alpha_{t-k} B_t)$ adalah kovarians silang antara α dan β pada lag k , maka :

$$V_k = \frac{g_{\alpha\beta}(k)}{\sigma_\alpha^2}$$

atau dengan mensubstitusikan korelasi silang diperoleh :

$$V_k = r_{\alpha\beta}(k) \sigma_\beta (\sigma_\alpha)^{-1} \quad (56)$$

Dalam praktek korelasi silang dan standart deviasi diestimasi dengan $r_{\alpha\beta}(k)$, s_α dan s_β . Maka persamaan (56) menjadi:

$$V_k = r_{\alpha\beta}(k) s_\beta (s_\alpha)^{-1} \quad (57)$$

Memperhatikan dua deret *white noise* yang bebas, maka korelasi silang antara kedua deret *white noise* tersebut diharapkan akan nol dan kesalahan standar diperkirakan $n^{-1/2}$.

Bartlett memperluas gagasan untuk dua kasus yang tidak berkorelasi satu diantaranya *white-noise*, dan untuk korelasi

silang dengan lag k mempunyai standar deviasi

$$SE r_{\alpha\beta}(k) = (n-k)^{-1/2}$$

2.4.4.2. Model Deret *Noise*

Model yang telah diberikan pada persamaan terdahulu adalah :

$$y_t = V(B) x_t + n_t$$

Dengan menggunakan estimasi dari bobot respons impuls $V(B)$ dari fungsi transfer diperoleh estimasi dari deret *noise* yaitu :

$$n_t = \delta(B)y_t - w(B) x_t \quad (58)$$

Sehingga diperoleh suatu model dari deret *noise* yang berasal dari deret input output.

2.4.4.3. Menentukan Nilai r, s, b

Konstanta fungsi transfer adalah r, z, b serta $p, d,$ dan q . Untuk nilai r, s dan b adalah sebagai berikut :

1. Nilai b menyatakan bahwa Y_t tidak dipengaruhi oleh X_t sampai periode $t+b$ atau

$$Y_t = 0X_t + 0X_{t+1} + \dots + wX_{t+b}$$

2. Nilai s menyatakan untuk seberapa lama deret output (Y_t) terus dipengaruhi oleh nilai X yang baru Y_t dipengaruhi oleh ($X_{t-b-1}, X_{t-b-2}, \dots, X_{t-b-s}$)

3. Nilai r menunjukkan bahwa Y_t berkaitan dengan nilai masa lalunya.

$$Y_t \text{ dipengaruhi oleh } (Y_{t-1}, Y_{t-2}, \dots, Y_{t-r})$$

Dari sini dapat digaris bawahi bahwa nilai (r, z, b) menun-

jukkan :

1. Sampai lag ke b Korelasi silang tidak berbeda dengan nol secara statistik.
2. Untuk s lag selanjutnya, Korelasi silang tidak akan menunjukkan pola yang jelas.
3. Untuk r lag selanjutnya, korelasi silang menunjukkan pola yang jelas.

2.4.4.4. Estimasi Parameter

Estimasi parameter dalam perumusan model adalah penting untuk melihat keterkaitan dari pada variabel yang ada dalam model. Dengan mengambil nilai awal X_0 , Y_0 dan a_0 yang berguna untuk memilih parameter $(b, \delta, w, \phi, \theta)$ berturut-turut nilai a_t adalah :

$$a_t = a_t(b, \delta, w, \phi, \theta | X_0, Y_0, a_0) \quad \text{untuk } t > 1$$

dengan mengasumsikan a_t berdistribusi normal, maka pendekatan maksimum likelihood dapat diperoleh dengan meminimumkan kondisi dari jumlahan kuadrat

$$S_0(b, \delta, w, \phi, \theta) = \sum_{t=1}^n a_t^2(b, \delta, w, \phi, \theta) \quad (59)$$

Untuk mendapatkan nilai estimate parameter dari δ dan w dengan menggunakan substitusi dari persamaan (41)

2.4.4.5 Statistik Uji

Uji Statistik dalam model fungsi transfer digunakan untuk menguji residualnya. Model Fungsi Transfer telah ze-

suai bila :

1. Autokorelasi dari a yaitu $r_{aa}(k)$ tidak signifikan dengan nol.
2. Korelasi silang yang melibatkan input dan residualnya, dalam hal ini korelasi silang antara residual a_t dengan α_t secara statistik tidak signifikan.

Untuk pengujian secara Keseluruhan dari model dengan menggunakan dapat uji Chi-kuadrat

$$Q = n \sum_{k=1}^m r_{\alpha\beta}(k)^2 \quad (60)$$

dimana n = jumlah pengamatan

m = lag yang diperhitungkan

nilai dari perhitungan persamaan (60) dibandingkan dengan nilai dari Chi-kuadrat tabel dengan derajat kebebasan $(m-p-q-r-s)$.

2.4.4.6. Peramalan Fungsi Transfer


Dalam meramalkan fungsi transfer deret waktu $Y_t, Y_{t-1}, Y_{t-2}, \dots$ diperlukan informasi yang dihasilkan dari deret X_t, X_{t-1}, \dots , apabila fungsi transfer telah dimodelkan

$$y_t = \delta^{-1}(B) w(B) x_{t-b} + \phi^{-1}(B) \theta(B) a_t$$

$b \geq 0$

dimana *noise* independen tidak tergantung pada input x_t .

Persamaan diatas dapat ditulis



$$y_t = V(B) \alpha_t + q(B) a_t \quad (51)$$

maka peramalan $y_t(1)$ dari y_{t+1} adalah :

$$y_t(1) = \sum_{j=0}^{\infty} V_{1+j} \alpha_j + \sum_{j=0}^{\infty} q_{1+j} a_t$$

$$\begin{aligned} y_t(1) = (y_{t+1}) = & \theta_1(y_{t+1-1}) + \theta_2(y_{t+1-2}) + \dots + \\ & \theta_{p+r}(y_{t+1-p-r}) + w_0(x_{t+1-b}) + w_1(x_{t+1-b-1}) - \\ & \dots - w_{p+s}(x_{t+1-b-p-s}) + a_{t+1} - \theta_1(a_{t+1-1}) \\ & - \dots - \theta_{q+r}(a_{t+1-q-r}) \end{aligned}$$

dimana

$$y_{t+j} \begin{cases} y_{t+j} & j \leq 0 \\ y_t(j) & j \geq 0 \end{cases}$$

$$x_{t+j} \begin{cases} x_{t+j} & j \leq 0 \\ x_t(j) & j \geq 0 \end{cases}$$

$$a_{t+j} \begin{cases} a_{t+j} & j \leq 0 \\ 0 & j \geq 0 \end{cases}$$

dan a_t dihitung dari

$$a_t = y_t - y_{t-1}(1)$$

maka variansi peramalan adalah

$$\begin{aligned} y_{t+1} - y_t(1) = & \sum_{i=0}^{1-1} \{V_i \alpha_{t+1-i} + q_i a_{t+1-i}\} + \sum_{j=0}^{\infty} \{ (V_{1+j} - \\ & V_{1+j}) \alpha_{t-j} + (q_{1+j} - q_{1+j}) a_{t-j} \} \end{aligned}$$

dan

$$\begin{aligned} E\{y_{t+1} - y_t(1)\}^2 = & \{V^2_0 + V^2_1 + \dots + V^2_{1-1}\} \sigma^2_\alpha + \\ & \{1 + q^2_1 + \dots + q^2_{1-1}\} \sigma^2_a + \end{aligned}$$

$$\sum_{j=0}^{\infty} \{ (V_{1+j} - V_{1+j}') \sigma^2_{\alpha} + (q_{1+j} - q_{1+j}') \sigma^2_a \}$$

akan minimum jika $V_{1+j}' = V_{1+j}$ dan $q_{1+j}' = q_{1+j}$ maka varians dari peramalan selang 1 tahap kedepan adalah :

$$\begin{aligned} \text{Var}(1) &= E (Y_{t+1} - Y_t(1))^2 \\ &= \sigma^2_{\alpha} \sum_{j=0}^{1-1} V_j^2 + \sigma^2_a \sum_{j=0}^{1-1} q_j^2 \end{aligned}$$

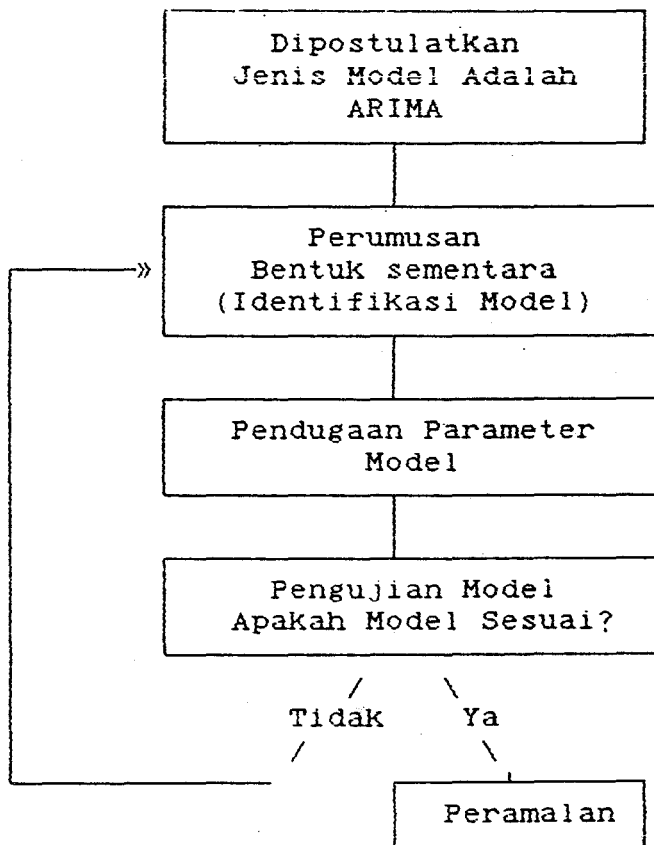
(62)

BAB 3 METODOLOGI

3.1 METODE PENELITIAN

Dalam penelitian ini digunakan metode analisis time series, dengan menerapkan metode perumusan model stokastik yang dikembangkan oleh Box and Jenkins (1976), atau lebih dikenal dengan nama perumusan model ARIMA. Metode ini pada dasarnya mempunyai tiga tahapan, yaitu identifikasi, pendugaan parameter dan pengujian model.

Dalam algoritma dilukiskan sebagai berikut :



Gambar 3-1 Metode Perumusan Model ARIMA

Dari interaksi antara teori dan praktek, digunakan general model untuk selanjutnya dipertimbangkan, yaitu

dengan mengambil n pengamatan Z_1, Z_2, \dots, Z_n sebagai sampel, dipostulatkan bahwa model stokastik bagi deret Z_t ialah $ARIMA(p\ d\ q)(P\ Q\ D)_s$.

3.1.1 TAHAP IDENTIFIKASI

Identifikasi, disini sebagai langkah awal untuk mengestimate parameter-parameter dari model secara sederhana, yaitu digunakan fungsi autoKorelasi dan fungsi korelasi parsial. Untuk mempermudah permasalahan, maka dibuat grafik dari kedua fungsi tersebut.

PEMERIKSAAN KESTASIONAIRAN TIMESERIES.

Sifat kestasioneran time series diperiksa melalui korelogram sampel bersama-sama plot data pengamatan Z_1, Z_2, \dots, Z_n .

Seperti telah dinyatakan sebelumnya, time series dikatakan stasioner jika korelogramnya cenderung menurun (menuju nol), dan dikatakan tidak stasioner jika korelogramnya tidak cenderung menurun. Akan tetapi, karena struktur autokorelasi sampel ada kemungkinan menyimpang dari struktur teoritis tersebut, maka suatu time series yang mempunyai korelogram sampel yang menurun secara perlahan-lahan dapat dianggap sebagai time series yang tidak stasioner (*Box and Jenkins, 1976*). Dengan kata lain, time series dapat dipastikan stasioner hanya jika kecenderungan menurun dari korelogram sampelnya terjadi secara cepat. Plot data pengamatan dalam masalah

ini, digunakan untuk membantu memastikan sifat kestasioneran time series.

Jika data yang dianalisis bersifat tidak stasioner atau ada bentuk / pola deterministik maka dicoba melakukan adiferensi, baik diferensi jangka pendek (diferensi reguler) ataupun diferensi jangka panjang (diferensi musiman). Diferensi musiman ini dilakukan jika ketidakstasioneran data tersebut disebabkan oleh pengaruh musiman, misalnya setelah lag 2 atau 3 kali periode musim masih ada nilai autokorelasi sampel yang berbeda nyata dengan nol atau lambat turun menuju nol sejalan dengan bertambahnya lag.

Selanjutnya, ordo diferensi ditentukan dengan menghitung banyaknya diferensi yang perlu dilakukan untuk membuat series Z_t menjadi stasioner. Misalnya w_t adalah series stasioner yang berasal dari Z_t , setelah melakukan diferensi reguler sebanyak d kali dan diferensi musiman sebanyak D kali dengan panjang periode musiman s , maka antara Z_t dan w_t terdapat hubungan sebagai berikut

$$w_t = v_s^D v^d Z_t$$

sedangkan $v Z_t = Z_t - Z_{t-1}$ dan $v_s Z_t = Z_t - Z_{t-s}$.

Jika cara diferensi tidak dapat menghasilkan series yang stasioner, maka dilakukan transformasi. Kemudian diikuti diferensi sampai mendapatkan series yang

stasioner.

IDENTIFIKASI SERIES STASIONER

Setelah didapat w_t yang stasioner, ditentukan jenis model yang kira-kira sesuai bagi series stasioner tersebut. Hal ini dimaksudkan apakah model tersebut AR murni, MA murni, model campuran atau model yang bersifat multiplikatif.

Mengingat bahwa model-model AR, MA atau model campuran tersebut masing-masing mempunyai struktur autokorelasi dan autokorelasi parsial yang bersifat khas, maka identifikasi model bagi series w_t dapat dilakukan dengan memeriksa karakteristik fungsi autokorelasi dan fungsi autokorelasi parsial secara bersama-sama. Karakteristik kedua besaran ini, secara teoritis disajikan pada Tabel 2-1.

Dari Tabel 2-1, selanjutnya dapat ditentukan ordo dari masing-masing jenis model di atas. Dalam hal ini, ordo autoregresi ditentukan dari autokorelasi parsial dan ordo moving average ditentukan dari autokorelasi sampel, sedangkan ordo model campuran ditentukan dari keduanya.

PENENTUAN KONSTANTA MODEL

Box and Jenkins (1976) menyatakan bahwa mean time series stasioner hasil duferensi pada umumnya diasumsikan bernilai nol, sehingga dianggap tidak perlu memasukkan

Konstanta ke dalam model terintegrasi. Akan tetapi, jika ternyata mean time series tersebut tidak nol, maka perlu memasukkan Konstanta ke dalam model.

3.2 METODA FUNGSI TRANSFER

3.2.1. PENYAJIAN PREWHITENING DERET INPUT

Dengan pembuatan model time series dari deret input melalui beberapa tahapan identifikasi (kestasioneran dan bentuk model ARIMANYA), estimasi parameter ARIMA serta penyajian-penyajian model ~~secara~~ statistik akan dapat diperoleh prewhitening deret input bagi model fungsi transfer yang akan disusun.

Deret input dapat dipandang sebagai data deret waktu X_t . Untuk penyajian prewhitening deret input perlu diidentifikasi X_t sebagai model deret waktu (model time series). Sehingga memerlukan pemeriksaan kestasioneran dari deret input bagi model fungsi transfer yang akan disusun.

Identifikasi kestasioneran dapat dilihat dari plot diagram autokorelasi dari data deret waktu asal X_t . Bila ada tanda-tanda bahwa X_t tidak stasioner maka dilakukan langkah pengambilan difference (pembedaan) baik itu berupa difference reguler atau difference seasonal (musiman) tergantung dari bentuk plot diagram

autokorelasi yang diperlihatkan. Dengan memberikan difference biasa atau difference musiman atau diberikan keduanya secara bersama-sama sesuai keperluan yang ditunjukkan dari plot diagram autokorelasinya maka data deret waktu asal X_t dapat dinyatakan sebagai data deret waktu difference x_t yaitu sebagai berikut :

$$x_t = (1-B)^d (1-B^s)^{\delta} X_t$$

dimana :

x_t = data deret waktu hasil difference yang telah stasioner yang selanjutnya dipandang sebagai data deret waktu baru sebagai input sistem

d = order difference biasa

s = periode musiman deret waktu

δ = order difference musiman

Tahap selanjutnya adalah menentukan model ARIMA sesuai dengan identifikasi data deret waktu yang telah stasioner. Berdasarkan plot diagram autokorelasi dan partial autokorelasi dapat ditentukan apakah model deret waktu untuk data yang telah stasioner (dengan atau tanpa difference) adalah model AR, MA atau ARMA.

$$\phi(B) x_t = \theta(B) a_t$$

Sehingga prewhitening deret input a_t dapat dinyatakan sebagai berikut :

$$a_t = \phi_x^{-1}(B) \theta_x^{-1}(B) x_t$$

3.2.2. PENYAJIAN PREWHITENING DERET INPUT

Untuk menjaga tingkat hubungan antara input dan output maka deret output akan diberikan difference (pembedaan) dengan tingkat atau order yang sama baik biasa maupun musiman dengan data deret waktu input awal. Kita pandang deret output awal sebagai Y_t .

$$y_t = (1-B)^d (1-BS)^d Y_t$$

Kita pandang y_t sebagai deret input baru.


Selanjutnya untuk tujuan menjaga tingkat hubungan deret input dan deret output seperti diatas, maka untuk memperoleh prewhitening deret output (B_t), y_t kita transformasi dengan model dan nilai estimasi yang sama dengan model ARMA deret input

$$B_t = \phi_x(B) \Theta_x^{-1}(B) y_t$$

3.2.3. ESTIMASI BOBOT RESPONS IMPULS

Dengan mengasumsikan bahwa deret input yang akan menentukan atau mempengaruhi deret output maka diharapkan deret input ke t tidak mempengaruhi deret output ke $t-1$, $t-2$ dan seterusnya atau sebasliknya deret output ke t tidak berkorelasi (cross corelasi tidak signifikan) dengan deret input ke $t+1$, $t+2$ dan seterusnya.

Bobot respons impuls ini dapat diestimate secara



langsung dengan menggunakan Korelasi silang (cross corelasi) antara α_t dan β_t dengan asumsi diatas

$$v_k = r_{\alpha\beta}(k) \frac{S_\beta}{S_\alpha} \quad \text{dimana } k = 0, 1, 2, \dots$$

dimana:

v_k = bobot respons impuls untuk lag k

$r_{\alpha\beta}(k)$ = Korelasi silang antara prewhitening deret input dan prewhitening deret output

S_α = standar deviasi prewhitening deret input

S_β = standar deviasi prewhitening deret output

V_k merupakan suatu deret bobot respon impuls yang jumlahnya cukup banyak, maka untuk itu perlu mensubtitusi nilai bobot respons impuls dengan :

$$v_k = \frac{w(B)}{\delta(B)}$$

dimana

$$w(B) = w_0 - w_1B - w_2B^2 - \dots - w_sB^s$$

$$\delta(B) = 1 - \delta_1B - \delta_2B^2 - \dots - \delta_rB^r$$

peramaan ini dianggap lebih singkat karena nilai r dan s biasanya lebih kecil dari k .

3.2.4. IDENTIFIKASI MODEL FUNGSI TRANSFER (r, s, b)

Model fungsi transfer dinyatakan dalam (r, s, b) dimana r menunjukkan deret output y_t berkaitan dengan masa lalunya, s menyatakan seberapa lama deret output y_t dipengaruhi oleh nilai deret input x_t setelah lag b dan seterusnya ($x_{t-b-1}, x_{t-b-2}, \dots, x_{t-b-s}$)

Sedang nilai b merupakan nilai penundaan mutlak (absolut delay) sebelum deret input mulai mempengaruhi deret output. Untuk menentukan nilai b ini dapat dilakukan dengan melihat kerelasi silang atau bobot respons impuls.

Dengan menggunakan bobot respons impuls, maka dapat dihitung nilai dari komponen noise model fungsi transfer sebagai berikut :

$$n_t = y_t - v(B) x_t$$

Selanjutnya kita buat model ARIMA yang sesuai untuk deret noise n_t dimana deret noise n_t biasanya mempunyai sifat saling independent sehingga untuk memodelkannya tidak memerlukan atau memberikan pembedaan (difference)

$$\phi(B) n = \theta(B) a_t$$

Dengan menggunakan substitusi dari bobot respons impuls dan model deret noise nt maka model fungsi transfer dapat ditulis sebagai

$$y_t = \frac{w(B)}{\theta(B)} x_{t-b} + \frac{\Theta(B)}{\phi(B)} a_t$$

3.2.5. ESTIMASI PARAMETER

Untuk model fungsi transfer yang telah diperoleh diatas yaitu

$$y_t = \frac{w(B)}{\theta(B)} x_{t-b} + \frac{\Theta(B)}{\phi(B)} a_t$$

diperlukan nilai estimate parameter w , θ , Θ dan ϕ .

Dengan menggunakan persamaan yang menyatakan hubungan antara $v(B)$ dengan $w(B)$ dan $\theta(B)$ yaitu

$$v_j = 0 \quad \text{untuk } j < b$$

$$v_j = \theta_1 v_{j-1} + \theta_2 v_{j-2} + \dots + \theta_r v_{j-r} + w_0, \quad j = b$$

$$v_j = \theta_1 v_{j-1} + \theta_2 v_{j-2} + \dots + \theta_r v_{j-r} - w_{j-b}, \quad j = b+1, \dots, b+s$$

$$v_j = \theta_1 v_{j-1} + \theta_2 v_{j-2} + \dots + \theta_r v_{j-r}, \quad j > b+s$$

Dengan menyelesaikan persamaan linear diatas (dengan substitusi maupun eliminasi) maka dapat diperoleh estimate dari w (w_0, w_1, \dots, w_s) dan θ ($\theta_0, \theta_1, \dots, \theta_r$) dimana $\theta_0 = 1$.

Nilai estimate dari parameter model deret noise ϕ dan Θ diperoleh dari identifikasi model ARIMA deret noise didepan.

3.2.6 PENGUJIAN FUNGSI TRANSFER

Pengujian fungsi transfer dilakukan untuk menguji validitas dari model yang dibuat. Yang perlu mendapatkan perhatian adalah deret nilai residual a_t dalam hubungannya dengan deret input baik x_t maupun X_t .

Untuk menguji bahwa residual independen (bebas satu dengan yang lainnya) maka perlu dilakukan dengan melihat nilai autokorelasinya

$$|r_k| < 2 SE, \text{ dimana } SE = \text{Standar Error}$$

Menggunakan uji statistik Q Box-Pierce dengan membandingkannya dengan tabel Chi-Square.

$$Q = n \sum_{k=1}^m \hat{r}_k^2$$

dimana

n = jumlah pengamatan

m = banyaknya lag yang diperhatikan

r_k = autokorelasi untuk lag k

dengan derajat bebas $m-1$, nilai 1 adalah banyaknya parameter di dalam model, maka sifat white-noise dari residual dapat diuji dengan hipotesa

$$H_0 : a_t = \text{white - noise}$$

$$H_1 : a_t = \text{tidak white-noise}$$

Apabila nilai $Q <$ nilai tabel maka model sesuai sedangkan apabila nilai $Q >$ nilai tabel maka model tidak sesuai.

3.2.7 PERAMLAN

Model fungsi transfer yang telah didapatkan , dengan menghitung secara perkalian aljabar dan menyusun kembali , maka akan didapatkan suatu persamaan yang menunjukkan model peramalan dari fungsi transfer.

BAB 4

ANALISA DATA DAN PEMBAHASAN

4.1 KEADAAN UMUM DATA

Data yang digunakan dalam penelitian ini diambil dari Perusahaan Umum Pos dan Giro wilayah Jawa Timur atau dalam organisasinya dikenal dengan daerah Pos dan giro III (Dapos III). Data tersebut meliputi data jumlah yang dikirim dan jumlah yang diterima untuk wilayah Jawa Timur , keduanya untuk jenis jasa pos kilat khusus . Adapun yang dimaksudkan jumlah produksi tidak lain adalah jumlah yang dikirimkan oleh kantor Pos dan Giro wilayah Jawa Timur , sebab inilah yang mendatangkan pendapatan sebagai nilai tukar jasa yang diberikan.

Karena yang diperlukan dalam time series berupa data yang runtun dalam periode tertentu , maka kedua data ini tentunya harus memenuhi syarat tersebut. Adapun periode dari kedua data tersebut adalah bulanan yang dimulai bulan Januari 1984 hingga Juli 1989. Jadi jumlah keseluruhan data masing-masing 67 data.

Untuk data jumlah yang dikirim mempunyai rata-rata setiap bulan adalah 142003 dan mempunyai varian 671017216 . Sedang untuk data jumlah jasa pos surat kilat khusus yang diterima oleh Perum Pos dan Giro Jawa Timur mempunyai rata-rata 132 250 setiap bulan dan mempunyai varian sebesar 550887841 .

Karena keadaan kedua data yaitu data jumlah yang dikirim maupun data jumlah yang diterima tidak berfluktuasi, dalam artian keseragaman data telah terpenuhi maka data tersebut tidak perlu dilakukan suatu transformasi.

4.2 IDENTIFIKASI MODEL

Setiap analisa time series dalam melakukan identifikasi diawali dengan melihat dari plot data deret waktu kemudian didukung oleh plot acf dan pacf untuk mendapatkan gambaran awal secara kasar tentang karakteristik data tersebut. Plot deret waktu dari jumlah yang dikirim oleh Perum Pos dan Giro wilayah Jawa timur untuk jasa pos surat kilat khusus menunjukkan tidak adanya suatu pola musiman dan tampak tidak stasioner hal ini didukung pula oleh grafik autokorelasinya. Dari grafik autokorelasi tersebut tampak jelas bahwa data tidak stasioner karena turun lambat menuju nol. Maka dari itu perlu dilakukan difference 1 agar stasioner. Setelah dilakukan difference 1 tampak jelas bahwa data menjadi stasioner. Secara matematis difference 1 dapat ditulis sebagai berikut :

$$\nabla X_t = (1-B) X_t$$

Kestasioneran tampak baik dari plot deret waktu X_t maupun dari grafik yang ditunjukkan oleh autokorelasinya.

Model deret waktu yang dicobakan untuk memodelkan jumlah yang dikirim oleh Perum Pos dan Giro wilayah Jawa Timur untuk jenis jasa pelayanan pos kilat ARIMA(1,1,0) , ARIMA(2,1,0) dan ARIMA(0,1,1). Dari ketiga model yang dicobakan menggunakan data asli , maka model yang terbaik yang dipilih adalah ARIMA (2 , 1 , 0) . Pemilihan ini didasarkan karena disamping variannya yang kecil juga nilai ramalannya mendekati nilai aslinya , selain itu juga selisih ramalannya juga lebih kecil seperti tampak dalam tabel berikut ini ramalan untuk pengamatan ke 61 hingga ke 67.

Tabel 4.1 Selisih antara ramalan dengan actual model ARIMA (0 , 1 , 1)

Data Ramalan Deret input		
R a m a l a n	S e l i s i h	A c t u a l
179791	2565	182356
179791	14237	194028
179791	18994	198785
179971	20619	200410
179971	11916	191707
179971	26537	206328
179791	16957	196748

Tabel 4.2 Selisih antara ramalan dengan actual model ARIMA (1 , 1 , 0)

Data Ramalan Deret input		
R a m a l a n	S e l i s i h	A c t u a l
180825	1531	182356
183103	10925	194028
181907	16878	198785
182535	17875	200410
182205	9502	191707
182379	23949	206328
182288	14460	196748

Tabel 4.3 Selisih antara ramalan dengan actual model ARIMA (2 , 1 , 0)

Data Ramalan Deret input		
R a m a l a n	S e l i s i h	A c t u a l
188914	6558	182356
183235	10793	194028
185927	12858	198785
186068	14342	200410
184990	6717	191707
185708	20620	206328
185587	11161	196748

Dengan menggunakan model ARIMA (2 , 1 , 0) , maka ramalan akan mendekati yang sebenarnya . Hal ini tampak pada ramalan data ke 61 sampai ke 67 dari data asli.

Sehingga model jumlah yang dikirim oleh Perum Pos dan giro untuk jasa pelayanan surat kilat khusus yang dikenal sebagai deret input dari fungsi transfer yang dianalisa adalah :

$$(1-B) X_t = \theta_1 X_{t-1} + \theta_2 X_{t-2} + \alpha_t$$

$$\alpha_t = (1-B) X_t - \theta_1 X_{t-1} - \theta_2 X_{t-2}$$

Karena deret waktu tersebut merupakan deret input yang akan berpengaruh pada deret output , yaitu jumlah yang diterima untuk jasa pos kilat khusus wilayah Jawa Timur, maka untuk mempertahankan hubungan antara deret input dan deret output haruslah deret output juga dimodelkan seperti deret input . Sehingga dapat dituliskan sebagai berikut :

$$(1-B) Y_t = \theta_1 Y_{t-1} + \theta_2 Y_{t-2} + \beta_t$$

$$\beta_t = (1-B) Y_t - \theta_1 Y_{t-1} - \theta_2 Y_{t-2}$$

Untuk mempelajari pola hubungan antara jumlah yang dikirim dan jumlah diterima Perum Pos dan Giro wilayah Jawa Timur untuk jenis jasa pelayanan surat

kilat khusus , maka perlu menghitung korelasi silang antara a_t dan β_t . Dengan mengambil lag -17 hingga lag 17 maka jelas nampak sekali bahwa korelasi silang anantara a_t dan β_t tidak significant dengan nol atau dengan kata lain tidak menunjukkan pola, hal ini seperti yang diharapkan , karena tidak mungkin jumlah yang dikirim pada saat t akan berpengaruh pada jumlah diterima pada saat t-1 , t-2 dan seterusnya.

Setelah mendapatkan korelasi silang maka hasil dari korelasi silang tersebut dapat digunakan untuk mengestimate bobot respons impuls dari fungsi Transfer secara langsung.

$$V(k) = r_{\alpha\beta}(k) \frac{s_{\beta}}{s_{\alpha}}$$

nilai bobot respons impuls ini digunakan untuk mencari deret noise . Deret noise perlu dimodelkan dengan ARIMA (p , d , q) untuk menjabarkan secara lengkap fungsi Transfer . Berdasarkan plot deret noise serta didukung oleh grafik autokorelasi dan autokorelasi parsial , maka deret noise dimodelkan ARIMA (0 , 1 , 2). Mengingat nilai korelasi silang antara α_t dan β_t ada 2 yang signifikan atau berbeda dengan nol , yakni pada lag nol dan pada lag ke 2 , maka nilai b akan sama dengan dengan nol yang berarti pada waktu yang sama jumlah yang dikirim oleh Perum Pos dan giro wilayah Jawa Timur untuk

jasa pelayanan surat kilat khusus akan berpengaruh terhadap jumlah yang diterimanya , setelah itu korelasi silang antara α_t dan β_t tidak ada lagi yang significant dengan nol.?

Dengan adanya kesulitan praktis untuk menetapkan nilai r dan s ,dengan alasan ada satu korelasi silang

antara α_t dan β_t nilai r dan s dapat ditetapkan sebagai berikut : $r + s \leq 2$.

Model selengkapnya dari fungsi Transfer ini apabila dijabarkan akan menjadi persamaan sebagai berikut :

$$Y_t = W_0 X_t - W_1 X_{t-1} - W_2 X_{t-2} + a_t - \theta a_{t-1} - \theta a_{t-2} + K$$

4.3 Evaluasi Model

Model yang terbaik untuk deret input adalah ARIMA (2 , 1 , 0) yang berarti deret waktu mempunyai model AR (2) dengan difference 1 . Setelah proses estimasi maka diperoleh estimate sebagai berikut :

FINAL ESTIMATES OF PARAMETERS

NUMBER	TYPE	ESTIMATE	ST. DEV.	T-RATIO
1	AR 1	-.7139	.1236	-5.77
2	AR 2	-.3632	.1247	-2.91

DIFFERENCING. 1 REGULAR

RESIDUALS. SS = 25177214976

(BACKFORECASTS EXCLUDED)

DF = 57 MS = 441705536

NO. OF OBS. ORIGINAL SERIES 60
 AFTER DIIFERENCING 59

Dari model estimate diatas maka kemudian nilai parameter dimasukkan maka diperoleh model persamaan :

$$(1-B) X_t = \theta_1 X_{t-1} + \theta_2 X_{t-2} + \alpha_t$$

Kemudian dapat disusun model deret residualnya dari model persamaan diatas sebagai berikut :

$$\alpha_t = (1-B) X_t - \theta_1 X_{t-1} - \theta_2 X_{t-2}$$

Dengan menghitung nilai Autokorelasinya dari residual dan melihat grafik Autokorelasinya terlihat bahwa nilai minimum dan nilai maksimum adalah -0.157 dan 0.226 semuanya terletak dalam selang kepercayaan.

Plot normal dari residual menunjukkan bahwa residual mengikuti distribusi normal. Plot residual dengan nilai taksiran menunjukkan tidak adanya pola dengan demikian berarti residual berdistribusi identik.


Dengan menggunakan uji statistik Q Box - Pierce

$$Q = 17 \sum_{k=1}^{17} r(k)^2 = 17 \times 0.15894 = 9.37746$$

Dari tabel didapatkan nilai Chi - Square dengan derajat kebebasan (df) 16 yang berasal dari 17 - 1 dan dengan tingkat kesalahan 5 persen diperoleh 26.2962 .

Disusun suatu hipotesa :

$$H_0 : \alpha_t =$$



H1: α_t = tidak white - noise

Setelah nilai Q dibandingkan dengan nilai tabel Chi-Square ternyata nilai Q lebih kecil dari nilai tabel, maka hipotesa awal (H0) diterima yang berarti residual dari X_t yaitu a_t adalah white noise.

Kemudian deret output harus dimodelkan seperti deret input yaitu :

$$(1-B) Y_t = \theta_1 Y_{t-1} + \theta_2 Y_{t-2} + \beta_t$$

Sedangkan deret residualnya diperoleh :

$$\beta_t = (1-B) Y_t - \theta_1 Y_{t-1} - \theta_2 Y_{t-2}$$

Model deret output dimodelkan seperti deret input dimaksudkan agar hubungan deret input dan deret output dapat dipertahankan. Apabila deret output dimodelkan tersendiri maka estimate parameteranya dapat dilihat seperti pada tabel berikut :

FINAL ESTIMATES OF PARAMETERS

NUMBER	TYPE	ESTIMATE	ST. DEV.	T-RATIO
1	MA 1	.6997	.0938	7.46

DIFFERENCING. 1 REGULAR

RESIDUALS.SS = 23403888640 (BACKFORECASTS EXCLUDED)

DF = 58 MS = 403515328

NO.OF OBS.ORIGINAL SERIES 60 AFTER DIIFERENCING 59

Dari model estimate diatas maka kemudian nilai parameter dimasukkan maka diperoleh model persamaan :

$$(1 - B) Y_t = (1 - \theta B) d_t$$

$$Y_t - Y_{t-1} = d_t - \theta d_{t-1}$$

$$Y_t = Y_{t-1} + d_t - \theta d_{t-1}$$

Kemudian dapat disusun model deret residualnya dari model persamaan diatas sebagai berikut :

$$d_t = Y_t - Y_{t-1} + \theta d_{t-1}$$

Dengan menghitung nilai Autokorelasinya dari residual dan melihat grafik Autokorelasinya terlihat bahwa nilai minimum dan maksimum adalah -0.248 dan 0.178 yang semuanya terletak dalam selang kepercayaan .

Jadi antar residual satu dengan yang lainnya adalah independen (saling bebas) . Sedangkan didapatkan dari plot normal residual menunjukkan bahwa residual mengikuti distribusi normal. Plot residual dengan nilai taksiran menunjukkan tidak adanya pola dengan demikian berarti residual berdistribusi identik.

Dengan menggunakan uji statistik Q Box-Pierce

$$Q = 59 \sum_{k=1}^{17} r^2(k) = 59 \times 0.15524 = 8.983396$$

Dari tabel didapatkan nilai Chi - Square dengan derajat kebebasan (df) 16 yang berasal dari 17 - 1 dan dengan tingkat kesalahan 5 persen diperoleh 26,2962 .

Disusun suatu hipotesa :

$$H_0 : d_t = \text{white - noise}$$

$$H_1 : d_t = \text{tidak white - noise}$$

Setelah nilai Q dibandingkan dengan nilai tabel Chi-Square ternyata nilai Q lebih kecil dari nilai tabel ,

maka hipotesa awal (H_0) diterima yang berarti residual dari X_t yaitu d_t adalah white noise.

Model lain dari jumlah yang diterima oleh Perum Pos dan Giro wilayah Jawa Timur untuk jenis pelayanan jasa khusus adalah ARIMA (0, 1, 2) dengan estimate parameter sebagai berikut :

```
FINAL ESTIMATES OF PARAMETERS
NUMBER      TYPE      ESTIMATE      ST. DEV.      T-RATIO
  1         MA 1       .3170         .117          2.17
  2         MA 2       .4965         .117          4.24
DIFFERENCING. 1 REGULAR
RESIDUALS.SS = 19930587136 (BACKFORECASTS EXCLUDED)
NO.OF OBS.ORIGINAL SERIES 60 AFTER DIIFERENCING 59
```

Karena jumlah surat yang diterima untuk jenis jasa pos kilat khusus ini dalam fungsi transfer sebagai deret output maka residualnya tidak harus white noise, hal ini disebabkan karena variabel output adalah variabel yang dependent (tak bebas) yang bergantung pada variabel input yang merupakan variabel independent (bebas).

Fungsi transfer yang terdiri deret input dan deret output ini bila dimodelkan dengan model ARIMA (2, 1, 0) dengan parameter $\theta_1 = -0.7139$ $\theta_2 = -0.3632$ dapat diperoleh sebagai berikut :

Tabel 4.4 Residual input output

	Residual	
	input	output
Rata - rata	2795	2040
Standar Deviasi	20482	21305

Dari korelasi silang antara residual input dan output diperoleh suatu nilai estimate dari bobot respons impuls sebagai berikut :

Tabel 4.5 Nilai bobot respons impuls

t	$r_{\alpha\beta}$	v
0	0.734	0.75382
1	-0.161	-0.16535
2	-0.312	-0.32042
3	-0.075	-0.07702
4	-0.045	-0.04621
5	0.076	0.07805
6	-0.130	-0.13351
7	0.100	0.01027
8	0.005	0.00513
9	0.075	0.07702
10	0.052	0.05340
11	-0.040	-0.04108
12	0.052	0.05340
13	-0.119	-0.12221
14	-0.036	-0.03697
15	-0.002	-0.00205
16	-0.002	-0.00205
17	0.049	0.05030

Untuk mendapatkan deret noise maka diperlukan nilai estimate dari w dan :

$$V_0 = w_0 \quad b = 0 \implies w_0 = 0.75382$$

untuk $j=b+s \implies j=0+2=2$, dimana $\delta_i = 0$

$$V_1 = \delta_1 V_0 - w_1$$

$$V_2 = \delta_1 V_1 + \delta_2 V_0 - w_2$$

maka didapatkan :

$$w_1 = 0.16535$$

$$w_2 = 0.32042$$

sehingga untuk mendapatkan deret noise diperoleh dengan persamaan :

$$n_t = Y_t - 0.75382 X_t - 0.16535 X_{t-1} \\ - 0.32042 X_{t-2}$$

Deret noise yang diperoleh perlu dimodelkan lebih dahulu untuk memperoleh persamaan fungsi transfer yang lengkap.

Model deret noise adalah ARIMA (0 , 0 , 2) dimana diperoleh persamaan dari estimate suatu parameter

FINAL ESTIMATES OF PARAMETERS

NUMBER	TYPE	ESTIMATE	ST. DEV.	T-RATIO
1	MA 1	.6680	.1326	5.04
2	MA 2	.3052	.1364	2.24
3	CONSTANT	-492.4	187.9	-2.62
	MEAN	-492.4	187.9	

RESIDUALS. SS = 13239816192

(BACKFORECASTS EXCLUDED)

DF = 57 MS = 232277472
 NO. OF OBS. 60

Dengan menghitung nilai Autokorelasinya dari residual deret noise dan melihat grafik Autokorelasinya menunjukkan saling independent ,sedangkan terlihat bahwa plot normal dari residual menunjukkan bahwa residual mengikuti distribusi normal. Plot residual dengan nilai taksiran menunjukkan tidak adanya pola dengan demikian berarti residual berdistribusi identik.


Dengan menggunakan uji statistik Q Box - Pierce

$$Q = 57 \sum_{k=1}^{17} r(k) = 57 \times 0.133926 = 7.633782$$

Dari tabel didapatkan nilai Chi - Square dengan derajat kebebasan (df) 15 dan tingkat kesalahan 5 persen adalah 24.9958

Disusun suatu hipotesa :

$$u_t : \epsilon_t = \text{white - noise}$$



H1 : a_t = tidak white - noise

Setelah nilai Q dibandingkan dengan nilai tabel Chi-Square ternyata nilai Q lebih kecil dari nilai tabel , maka hipotesa awal (H0) diterima yang berarti residual dari X_t yaitu a_t adalah white noise.

Sekarang dapat disusun model fungsi.Transfer secara lengkap yaitu (0 , 2 , 0) (0 , 0 , 2) yang berarti model fungsi Transfer mempunyai persamaan sebagai berikut :

$$Y_t = 0.75382 X_t + 0.16535 X_{t-1} + \\ 0.32042X_{t-2} + a_t - 0.68800 a_{t-1} - \\ 0.35020 a_{t-2} - 492.2$$

Untuk menguji model fungsi Transfer tersebut digunakan korelasi silang antara a_t dengan α_t dan X_t . Mengingat nilai korelasi silangnya kecil tidak significant dengan nol ,maka model diterima . Dengan pengujian menggunakan statistik Q Box - Pierce diperoleh nilai 10.8152 . Bila dibandingkan dengan nilai tabel Chi - Square dengan derajat bebas 16 dan tingkat kepercayaan 5 persen diperoleh nilai sebesar 26.262962 , maka nilai residual a_t adalah white - noise atau dengan kata lain a_t berdistribusi IIDN (0 , σ^2).

4.4 . Peramalan

Dengan menggunakan persamaan fungsi Transfer yang didapatkan diatas maka dapat digunakan untuk mera-

mal untuk masa yang akan datang , apabila nilai X_t tidak diketahui maka X_t maka nilai dari X_t diestimate dengan deret input .

Sebelum digunakan untuk meramal perlu dibandingkan dulu dengan menggunakan model ARIMA dan model fungsi Transfer ,dapat diperlihatkan disini mulai data ke 61 hingga 67 .

Tabel 4.6 Perbandingan ramalan


	PERBANDINGAN HASIL			Actual
	ARIMA 0,1,1	F. Transfer	ARIMA0,1,2	
61	156303	164491	158417	150299
62	156303	161570	152731	148160
63	156303	162785	152731	164095
64	156303	161080	152731	163102
65	156303	161463	152731	186544
66	156303	161636	152731	225747
67	156303	160589	152731	224461

Jika persamaan fungsi Transfer digunakan untuk meramal 16 tahap kedepan diperoleh :

Tabel 4.7

Hasil ramalan Fungsi Transfer

Periode	Y t
68 AGUSTUS 89	194497
69 SEPTEMBER	203215
70 OKTOBER	205082
71 NOPEMBER	201599
72 DESEMBER	202550
73 JANUARI 90	202394
74 FEBRUARI	201910
75 MARET	201688
76 MEI	201505
77 JUNI	201240
78 JULI	200959
79 AGUSTUS	200748
80 SEPTEMBER	200491
81 OKTOBER	200234
82 NOPEMBER	200000
83 DESEMBER	199748



BAB 5

K E S I M P U L A N

5.1 Kesimpulan

Jumlah surat jasa pos kilat khusus yang diterima oleh Perum Pos dan Giro wilayah Jawa Timur mempunyai rata-rata sebesar 132250 setiap bulan dan varian 550887841 .

Sedangkan jumlah surat yang dikirim untuk jasa pos kilat khusus wilayah Jawa Timur setiap bulan mempunyai rata - rata sebesar 142003 dan mempunyai varian sebesar 6710117216.

Model dari Jumlah surat jasa pos kilat khusus yang dikirim oleh Perum Pos dan Giro wilayah Jawa Timur adalah ARIMA (2 , 1 , 0) dengan persamaan sebagai berikut :

$$(1-B)^2 X_t = \theta_1 X_{t-1} + \theta_2 X_{t-2} + a_t$$

yang berarti Jumlah surat jasa pos kilat khusus yang dikirim oleh Perum Pos dan Giro Jawa Timur tersebut dipengaruhi oleh pengamatan pada periode ke t - 1 ,periode ke t-2

Model jumlah surat yang diterima oleh Perum Pos dan Giro wilayah Jawa Timur untuk pelayanan jasa pos kilat khusus adalah ARIMA (0 , 1 , 1) dengan persamaan sebagai berikut :

$$(1 - B) Y_t = (1 - BB) a_t$$

Apabila masing - masing jumlah surat yaitu yang dikirim maupun yang diterima untuk jasa pos kilat khusus di Jawa Timur (Daerah Pos dan Giro III) dimodelkan sendiri-sendiri maka ramalannya tentunya juga bisa didapatkan .Sedangkan hasil ramalan dari model yang didapat diatas (model yang dikirim dan yang diterima) dapat dilihat didalam lampiran .

Model fungsi Transfer dari jumlah yang diterima dalam kaitanya dengan jumlah yang dikirim oleh Perum Pos dan Giro wilayah Jawa Timur untuk jasa pos surat kilat khusus adalah $(r,s,b)(p,q)$, jika harga r,s,b,p,q diisi-kan maka diperoleh $(0,2,0)(0,2)$ atau dijabarkan sebagai berikut:

$$Y_t = 0.75382 X_t + 0.16535 X_{t-1} + 0.32042 X_{t-2} + a_t - 0.68800 a_{t-1} - 0.35020 a_{t-2} - 492.2$$

yang berarti bahwa jumlah yang diterima jasa pos surat kilat khusus dipengaruhi oleh jumlah yang dikirim pada periode yang sama dari bulan ke n , $n-1$ dan $n-2$.Apabila faktor-faktor yang mempengaruhi jumlah surat kilat khusus yang diterima ini lebih banyak lagi yang diperhitungkan maka nilai ramalannya akan menjadi lebih baik ,tetapi berhubung banyak keterbatasan yang ada maka hasil ramalan ini sudah cukup bagus.Adapun hasil ramalan untuk model fungsi transfer ini terdapat dalam tabel 4.7

5.2 Saran

Sebaiknya digunakan fungsi Transfer untuk mer-
malkan jumlah produksi jasa pos kilat khusus wilayah
propinsi Jawa Timur karena hasil ramalannya lebih baik
daripada model - model lain yang telah dicoba dalam
tugas akhir ini.

Dalam fungsi Transfer disamping memperhitungkan
apa yang akan terjadi dari suatu kondisi di masa lalu
,juga memperhitungkan faktor yang lain yang berpengaruh.
Dalam kasus ini selain data masa lalu yaitu jumlah
surat yang diterima juga memperhitungkan faktor lain
yang berpengaruh yaitu jumlah surat yang dikirim untuk
jasa pos surat kilat khusus wilayah Jawa Timur .

Diperlukan adanya evaluasi terhadap ramalan
setiap akhir periode karena nilai dari kesalahan dari
periode yang lalu juga akan berpengaruh .

Data deret input

104782
107067
116729
107135
115171
119516
120453
124862
112743
128735
122753
233900
125064
118450
131544
117630
126931
107074
135552
126588
119589
143838
130542
144694
128452
121114
127772
127507
138902
115558
145511
134336
139677
189635
135886
135796
144295
131895
141960
143898
135979
143404
158431
144336
156009
165314
148387
163370
148945
155327
159480
164590
151494

Data deret output

98554
98781
109747
99134
111630
110955
104942
116896
106928
116628
192668
217088
116623
106381
132193
104929
119108
101156
122906
117942
112520
131830
116733
114206
114147
114740
117108
123663
131591
107016
146533
133097
126347
137691
129178
131424
129183
123384
152196
131061
131322
146446
153599
136972
147499
151728
138687
151819
142278
148625
156891
154189
137671

Data deret input

181660
185271
174018
175114
203469
176898
185165
182356
194028
198785
200410
191707
206328
196748

Data deret output

166353
167010
144126
150090
173450
151420
155991
150299
148160
164095
163102
186544
225747
224561


```
MTB > print c2
C2
```

Data jumlah surat jasa pos Kilat Khusus yang dikirim (input)

104782	107067	116729	107135	115171	119516	120453	124862
112743	128735	122753	233900	125064	118450	131544	117630
126931	107074	135552	126588	119589	143838	130542	144694
128452	121114	127772	127507	138902	115558	145511	134336
139677	189635	135886	135796	144295	131895	141960	143898
135979	143404	158431	144336	156009	165314	148387	163370
148945	155327	159480	164590	151494	181660	185271	174018
175114	203469	176898	185165				

```
MTB > tsplot c2
```


plot data input



```
MTB > acf c2
```

Autokorelasi input



ACF OF C2



1	.455	XXXXXXXXXXXXXX
2	.449	XXXXXXXXXXXXXX
3	.408	XXXXXXXXXXXXXX
4	.292	XXXXXXXXXX
5	.307	XXXXXXXXXXXX
6	.187	XXXXXX
7	.214	XXXXXX
8	.149	XXXXXX
9	.186	XXXXXX
10	.184	XXXXXX
11	.114	XXXX
12	.318	XXXXXXXXXXXX
13	.132	XXXX
14	.146	XXXXXX
15	.120	XXXX
16	.043	XX
17	.100	XXX

MTB > pacf c2

Autokorelasi Parsial input



MTB > diff c2 c3


MTB > print c3

C3 Data input setelah difference 1

* 2285	9662	-9594	8036	4345		937	4409
-12119	15992	-5982	111147	-108836	-6614	13094	-13914
9301	-19857	28478	-8964	-6999	24249	-13296	14152
-16242	-7338	6658	-265	11395	-23344	29953	-11175
5341	49958	-53749	-90	8499	-12400	10065	1938
-7919	7425	15027	-14095	11673	9305	-16927	14983
-14425	6382	4153	5110	-13096	30166	3611	-11253
1096	28355	-26571	8267				

MTB > tsplot c3

1 Plot data input setelah didifference1




MTB > acf c3

1

Autokorelasi input setelah didifference 1


ACF OF C3



MTB > pacf c3

Autokorelasi input setelah difference 1

PACF OF C3



Pemodelan deret input dengan model Arima 0 1 1

> arima 0 1 1 c2 c3 c4;

> fore 60 7.

ESTIMATES AT EACH ITERATION

ITERATION	SSE	PARAMETERS
0	36096770048	0.100
1	31582976000	0.250
2	28184801280	0.400
3	25721174016	0.550
4	24240848896	0.700
5	24060497920	0.766
6	24058011648	0.760
7	24058009600	0.760

RELATIVE CHANGE IN EACH ESTIMATE LESS THAN .0010

FINAL ESTIMATES OF PARAMETERS

NUMBER	TYPE	ESTIMATE	ST. DEV.	T-RATIO
1	MA 1	.7600	.0881	8.63

DIFFERENCING. 1 REGULAR

RESIDUALS. SS = 23982426112 (BACKFORECASTS EXCLUDED)

DF = 58 MS = 413490112

OF OBS. ORIGINAL SERIES 60 AFTER DIFFERENCING 59

FORECASTS FROM PERIOD 60


PERIOD	FORECAST	95 PERCENT LIMITS		ACTUAL
		LOWER	UPPER	
61	179791	139928	219655	
62	179791	138796	220787	
63	179791	137694	221889	
64	179791	136620	222963	
65	179791	135572	224011	
66	179791	134549	225034	
67	179791	133548	226035	

Pengecekan Autokorelasi Residual

MTB > acf c3


1

ACF OF C3



Plot residual dan taksiran

MTB > plot c3 c4



1 MISSING OBSERVATIONS

Pemodelan Arima 1 1 1 deret input
 MTB > arima 1 1 1 c2

ESTIMATES AT EACH ITERATION

ITERATION	SSE	PARAMETERS	
0	39899062272	0.100	0.100
1	30449465344	-0.050	0.248
2	28817805312	0.031	0.398
3	26830698496	0.078	0.548
4	24498683904	0.038	0.698
5	23926009856	-0.092	0.714
6	23923810304	-0.099	0.715
7	23923798016	-0.100	0.716
8	23923798016	-0.100	0.716

RELATIVE CHANGE IN EACH ESTIMATE LESS THAN .0010

FINAL ESTIMATES OF PARAMETERS

NUMBER	TYPE	ESTIMATE	ST.	DEV.	T-RATIO
1	AR 1	-.0996		.1749	-.57
2	MA 1	.7157		.1252	5.72

DIFFERENCING. 1 REGULAR

RESIDUALS. SS = 23867324416 (BACKFORECASTS EXCLUDED)
 DF = 57 MS = 418724992

NO. OF OBS. ORIGINAL SERIES 60 AFTER DIFFERENCING 59

MTB > arima 1 1 0 c2;
 MTB > fore 60 7.

ESTIMATES AT EACH ITERATION

ITERATION	SSE	PARAMETERS	
0	44479197184	0.100	
1	37907685376	-0.050	
2	33128327168	-0.200	
3	30141114368	-0.350	
4	28946049024	-0.500	
5	28921171968	-0.524	
6	28921108480	-0.525	
7	28921108480	-0.525	

RELATIVE CHANGE IN EACH ESTIMATE LESS THAN .0010

FINAL ESTIMATES OF PARAMETERS

NUMBER	TYPE	ESTIMATE	ST.	DEV.	T-RATIO
1	AR 1	-.5250		.1119	-4.69

DIFFERENCING. 1 REGULAR

RESIDUALS. SS = 28920072192 (BACKFORECASTS EXCLUDED)
 DF = 58 MS = 498621920

NO. OF OBS. ORIGINAL SERIES 60 AFTER DIFFERENCING 59

FORECASTS FROM PERIOD 60

PERIOD	FORECAST	95 PERCENT LIMITS		ACTUAL
		LOWER	UPPER	
61	180825	137049	224600	
62	183103	134641	231566	
63	181907	123355	240459	
64	182535	118256	246814	
65	182205	111333	253077	
66	182379	106138	258619	
67	182288	100711	263865	

Pemodelan Arima 1 1 0 deret input

MTB > arima 1 1 0 c2 c3 c4;
 MTB > fore 60 7.

ESTIMATES AT EACH ITERATION

ITERATION	SSE	PARAMETERS
0	44479197184	0.100
1	37907685376	-0.050
2	33128327168	-0.200
3	30141114368	-0.350
4	28946049024	-0.500
5	28921171968	-0.524
6	28921108480	-0.525
7	28921108480	-0.525

RELATIVE CHANGE IN EACH ESTIMATE LESS THAN .0010

FINAL ESTIMATES OF PARAMETERS

NUMBER	TYPE	ESTIMATE	ST. DEV.	T-RATIO
1	AR 1	-.5250	.1119	-4.69

DIFFERENCING. 1 REGULAR


RESIDUALS. SS = 28920072192 (BACKFORECASTS EXCLUDED)
 DF = 58 MS = 498621920

NO. OF OBS. ORIGINAL SERIES 60 AFTER DIFFERENCING 59

FORECASTS FROM PERIOD 60

PERIOD	FORECAST	95 PERCENT LIMITS		ACTUAL
		LOWER	UPPER	
61	180825	137049	224600	
62	183103	134641	231566	
63	181907	123355	240459	
64	182535	118256	246814	
65	182205	111333	253077	
66	182379	106138	258619	
67	182288	100711	263865	

Plot residual dan taksiran model Arima 1 1 0
 MTB > plot c3 c4





1 MISSING OBSERVATIONS

MTB > acf c3

1


Autokorelasi residual model Arima 1 1 0
 ACF OF C3



Plot Normal Residual untuk model Arima 1 1 0

MTB > nscore c3 c5

MTB > plot c5 c3



1 MISSING OBSERVATIONS

Pemodelan deret input dengan model Arima 2 1 0

MTB > arima 2 1 0 c2 c3 c4;

MTB > fore 60 7.

ESTIMATES AT EACH ITERATION

ITERATION	SSE	PARAMETERS	
0	44332806144	0.100	0.100
1	37929807872	-0.050	0.015
2	32825921536	-0.200	-0.070
3	29021523968	-0.350	-0.155
4	26516830208	-0.500	-0.240
5	25312114688	-0.650	-0.326
6	25194240000	-0.710	-0.361
7	25193883648	-0.714	-0.363
8	25193881600	-0.714	-0.363

RELATIVE CHANGE IN EACH ESTIMATE LESS THAN .0010

FINAL ESTIMATES OF PARAMETERS

NUMBER	TYPE	ESTIMATE	ST.	DEV.	T-RATIO
1	AR 1	-.7139		.1236	-5.77
2	AR 2	-.3632		.1247	-2.91

DIFFERENCING. 1 REGULAR

RESIDUALS. SS = 25177214976 (BACKFORECASTS EXCLUDED)

DF = 57 MS = 441705536

NO. OF OBS. ORIGINAL SERIES 60 AFTER DIFFERENCING 59


FORECASTS FROM PERIOD 60

PERIOD	FORECAST	95 PERCENT LIMITS		ACTUAL
		LOWER	UPPER	
61	188914	147712	230115	
62	183235	140381	226089	
63	185927	139515	232340	
64	186068	133727	238409	
65	184990	129815	240164	
66	185708	127037	244380	
67	185587	123398	247776	

MTB > acf c3


ACF OF C3

Autokorelasi residual



Plot residual dan taksiran


MTB > plot c3 c4
1



1 MISSING OBSERVATIONS

Plot Normal Residual untuk model Arima 2 1 0

MTB > nscore c3 c5
MTB > plot c5 c3



1 MISSING OBSERVATIONS

MTB > outf

1


MTB > print c1 c7

ROW	C 1
Data	Jumlah surat kilat khusus yang diterima (output)
1	98554
2	98781
3	109747
4	99134
5	111630
6	110955
7	104942
8	116896
9	106928
10	116628
11	192668
12	217088
13	116623
14	106381
15	132193
16	104929
17	119108
18	101156
19	122906
20	117942
21	112520
22	131830
23	116733
24	114206
25	114147
26	114740
27	117108
28	123663
29	131591
30	107016
31	146533
32	133097
33	126347
34	137691
35	129178
36	131424
37	129183
38	123384
39	152196
40	131061
41	131322
42	146446
43	153599
44	136972
45	147499
46	151728
47	138687
48	151819
49	142278
50	148625
51	156891

52 154189
 53 137671
 54 166353
 55 167010
 56 144126
 57 150090
 58 173450
 59 151420
 60 155991

Plot deret ouput


MTB > tsplot c1



MTB > acf c1

Autokorelasi Deret Output


ACF OF C1



MTB > pacf c1

Parsial Autokorelasi deret output

PACF OF C1



MTB > diff c1 c3

MTB > print c3


C3

Deret ouput setelah difference 1

*	227	10966	-10613	12496	-675	-6013	11954
-9968	9700	76040	24420	-100465	-10242	25812	-27264
14179	-17952	21750	-4964	-5422	19310	-15097	-2527
-59	593	2368	6555	7928	-24575	39517	-13436
-6750	11344	-8513	2246	-2241	-5799	28812	-21135
261	15124	7153	-16627	10527	4229	-13041	13132
-9541	6347	8266	-2702	-16518	28682	657	-22884
5964	23360	-22030	4571				

MTB > tsplot c3

Plot deret output setelah difference 1




Autokorelasi deret output setelah difference 1

MTB > acf c3

1


ACF OF C3



MTB > pacf c3

Autokorelasi Parsial setelah difference 1

PACF OF C3



Pemodelan deret output dengan model Arima 0 1 1
 MTB > arima 0 1 1 c1 c2 c3;
 MTB > fore 60 7.

ESTIMATES AT EACH ITERATION

ITERATION	SSE	PARAMETERS
0	27258038272	0.100
1	25804187648	0.250
2	24629993472	0.400
3	23911946240	0.524
4	23610867712	0.599
5	23500630016	0.643
6	23461974016	0.667
7	23448393728	0.681
8	23443572736	0.689
9	23441846272	0.693
10	23441229824	0.696
11	23441012736	0.698
12	23440936960	0.699
13	23440912384	0.700

RELATIVE CHANGE IN EACH ESTIMATE LESS THAN .0010

FINAL ESTIMATES OF PARAMETERS

NUMBER	TYPE	ESTIMATE	ST. DEV.	T-RATIO
1	MA 1	.6997	.0938	7.46

DIFFERENCING. 1 REGULAR

RESIDUALS. SS = 23403888640 (BACKFORECASTS EXCLUDED)

DF = 58 MS = 403515328

NO. OF OBS. ORIGINAL SERIES 60 AFTER DIFFERENCING 59


FORECASTS FROM PERIOD 60

PERIOD	FORECAST	95 PERCENT LIMITS		ACTUAL
		LOWER	UPPER	
61	156303	116923	195682	
62	156303	115185	197420	
63	156303	113518	199087	
64	156303	111913	200692	
65	156303	110365	202240	
66	156303	108867	203738	
67	156303	107415	205190	

Autokorelasi residual untuk model Arima 0 1 1


MTB > acf c2

ACF OF C2



MTB > plot c2 c3


1 Plot Residual dan Taksiran untuk model Arima 0 1 1



1 MISSING OBSERVATIONS

Plot Normal residual untuk model Arima 0 1 1

MTB > nscore c2 c4
 MTB > plot c4 c2



1 MISSING OBSERVATIONS

Pemodelan deret output dengan model Arima 0 1 2

MTB > arima 0 1 2 c1 c2 c3;
 MTB > fore 60 7.

ESTIMATES AT EACH ITERATION

ITERATION	SSE	PARAMETERS	
0	25353781248	0.100	0.100
1	22422335488	0.198	0.250
2	20496334848	0.300	0.400
3	20135571456	0.343	0.485
4	20119613440	0.323	0.490
5	20118888448	0.319	0.494
6	20118773760	0.318	0.496
7	20118755328	0.317	0.496
8	20118753280	0.317	0.496

RELATIVE CHANGE IN EACH ESTIMATE LESS THAN .0010

FINAL ESTIMATES OF PARAMETERS

NUMBER	TYPE	ESTIMATE	ST. DEV.	T-RATIO
1	MA 1	.3170	.1170	2.71
2	MA 2	.4965	.1171	4.24

DIFFERENCING. 1 REGULAR

RESIDUALS. SS = 19930587136 (BACKFORECASTS EXCLUDED)

DF = 57 MS = 349659424

NO. OF OBS. ORIGINAL SERIES 60 AFTER DIFFERENCING 59



FORECASTS FROM PERIOD 60

PERIOD	FORECAST	95 PERCENT LIMITS		ACTUAL
		LOWER	UPPER	
61	158417	121759	195075	
62	152731	108338	197124	
63	152731	107814	197648	
64	152731	107296	198165	
65	152731	106784	198677	
66	152731	106278	199184	
67	152731	105777	199685	

MTB > acf c2

Autokorelasi Residual model Arima 0 1 2


ACF OF C2



Plot residual dan taksiran model Arima 0 1 2

MTB > plot c2 c3


1



1 MISSING OBSERVATIONS

MTB > nscore- c2 c4

MTB > plot c4 c2



1 MISSING OBSERVATIONS

pemodelan deret output dengan model Arima 1 1 0

MTB > arima 1 1 0 c1 c2 c3;

MTB > fore 60 7.

ESTIMATES AT EACH ITERATION

ITERATION	SSE	PARAMETERS
0	29829552128	0.100
1	27856627712	-0.050
2	27159906304	-0.199
3	27158155264	-0.207
4	27158151168	-0.207
5	27158149120	-0.207

RELATIVE CHANGE IN EACH ESTIMATE LESS THAN .0010

FINAL ESTIMATES OF PARAMETERS

NUMBER	TYPE	ESTIMATE	ST.	DEV.	T-RATIO
1	AR 1	-.2070		.1285	-1.61

DIFFERENCING. 1 REGULAR

RESIDUALS. SS = 27158149120 (BACKFORECASTS EXCLUDED)

DF = 58 MS = 468243936

NO. OF OBS. ORIGINAL SERIES 60 AFTER DIFFERENCING 59


FORECASTS FROM PERIOD 60

PERIOD	FORECAST	95 PERCENT LIMITS		ACTUAL
		LOWER	UPPER	
61	155045	112624	197466	
62	155241	101099	209382	
63	155200	90481	219920	
64	155209	81592	228825	
65	155207	73625	236789	
66	155207	66377	244037	
67	155207	59677	250738	

Autokorelasi residual model Arima 1 1 0

MTB > acf c2

ACF OF C2



Pemodelan deret output dengan model Arima 2 1 0

MTB > arima 2 1 0 c1 c2 c3;

MTB > fore 60 7.

ESTIMATES AT EACH ITERATION

ITERATION	SSE	PARAMETERS	
0	32221413376	0.100	0.100
1	27238131712	-0.007	-0.050
2	23786893312	-0.114	-0.200
3	21865228288	-0.221	-0.350
4	21426182144	-0.297	-0.458
5	21424695296	-0.301	-0.464
6	21424689152	-0.301	-0.464

RELATIVE CHANGE IN EACH ESTIMATE LESS THAN .0010

FINAL ESTIMATES OF PARAMETERS


NUMBER	TYPE	ESTIMATE	ST.	DEV.	T-RATIO
1	AR 1	-.3015		.1175	-2.56
2	AR 2	-.4645		.1185	-3.92

DIFFERENCING. 1 REGULAR

RESIDUALS. SS = 21404569600 (BACKFORECASTS EXCLUDED)

DF = 57 MS = 375518752


NO. OF OBS. ORIGINAL SERIES 60 AFTER DIFFERENCING 59




FORECASTS FROM PERIOD 60

PERIOD	FORECAST	95 PERCENT LIMITS		ACTUAL
		LOWER	UPPER	
61	164846	126856	202835	
62	160053	113713	206393	
63	157385	109429	205340	
64	160415	107678	213152	
65	160741	102101	219381	
66	159235	97257	221214	
67	159538	94403	224673	

MTB > acf c2



MTB > plot c2 c3






Deret noise (nt)

TB > print c1

1	0.0	0.0	3304.8	-5710.6	4928.8	-2205.0	-10012.7	7083.
	1861.7	-1763.9	81788.2	-63499.9	-34883.7	-22873.9	51908.3	-16821.
	5272.8	-63.0	585.8	3447.0	-7788.7	5060.1	-6841.2	-18766.
	4104.8	4275.6	3766.7	8005.1	-2751.3	-8777.1	17146.6	-2484.
	8525.9	-23617.8	22032.2	-4806.3	8589.4	2171.9	20551.9	-20286.
	2685.0	10215.3	-2865.0	-10865.7	-756.7	-199.1	-5559.9	1654.
	4279.2	-879.6	8702.2	-9285.6	-8821.6	6470.3	-2856.8	-24664.
	5841.5	5409.9	-7039.9	-6352.8				


TB > tsplot c1



1


MTB > acf c1

ACF OF C1



MTB > pacf c1

PACF OF C1



MTB > arima 0 0 1 c1 c2 c3;

MTB > fore 55 10.

ESTIMATES AT EACH ITERATION

ITERATION	SSE	PARAMETERS
0	19492972544	0.100 -753.358
1	18358894592	0.250 -1.6E+03
2	17288206336	0.400 -777.137
3	16424506368	0.550 -680.257
4	15701457920	0.687 -661.313
5	15185425408	0.797 -607.084
6	14886478848	0.873 -547.918
7	14650968064	0.928 -489.620
1		
8	14455982080	0.962 -450.578
9	14437157888	0.964 -473.902
10	14434383872	0.965 -477.543
11	14434380800	0.965 -478.659
12	14434206720	0.965 -479.595
13	14434098176	0.965 -479.683

RELATIVE CHANGE IN EACH ESTIMATE LESS THAN .0010

FINAL ESTIMATES OF PARAMETERS

NUMBER	TYPE	ESTIMATE	ST. DEV.	T-RATIO
1	MA 1	.9648	.0645	14.96
2	CONSTANT	-479.7	172.9	-2.77
	MEAN	-479.7	172.9	

RESIDUALS. SS = 14427715584 (BACKFORECASTS EXCLUDED)

DF = 58 MS = 248753712


NO. OF OBS. 60

FORECASTS FROM PERIOD 55

PERIOD	FORECAST	95 PERCENT LIMITS		ACTUAL
		LOWER	UPPER	
56	-1380.2	-32299.4	29539.0	-24664.1
57	-479.7	-43442.6	42483.3	5841.5
58	-479.7	-43442.6	42483.3	5409.9
59	-479.7	-43442.6	42483.3	-7039.9
60	-479.7	-43442.6	42483.3	-6352.8
61	-479.7	-43442.6	42483.3	
62	-479.7	-43442.6	42483.3	
63	-479.7	-43442.6	42483.3	
64	-479.7	-43442.6	42483.3	
65	-479.7	-43442.6	42483.3	


MTB > acf c2

ACF OF C2




MTB > plot c2 c3

1




103



MTB > nscore c2 c4

MTB > plot c4 c2



MTB > arima 0 0 2 c1 c2 c3;

MTB > fore 55 10.

ESTIMATES AT EACH ITERATION

ITERATION	SSE	PARAMETERS		
0	18773889024	0.100	0.100	-753.358
1	16857595904	0.250	0.191	-1.1E+03
2	15215570944	0.400	0.264	-726.247
3	13957118976	0.550	0.316	-536.898
4	13376075776	0.625	0.332	-445.044
5	13317399552	0.633	0.336	-448.036
6	13280348160	0.644	0.326	-482.945
7	13246253056	0.669	0.303	-483.172
8	13245766656	0.668	0.304	-492.319
9	13245679616	0.668	0.305	-492.402

1
 10 13245677568 0.668 0.305 -492.414
 RELATIVE CHANGE IN EACH ESTIMATE LESS THAN .0010

FINAL ESTIMATES OF PARAMETERS


NUMBER	TYPE	ESTIMATE	ST. DEV.	T-RATIO
1	MA 1	.6680	.1326	5.04
2	MA 2	.3052	.1364	2.24
3	CONSTANT	-492.4	187.9	-2.62
	MEAN	-492.4	187.9	

RESIDUALS. SS = 13239816192 (BACKFORECASTS EXCLUDED)

DF = 57 MS = 232277472

NO. OF OBS. 60

104




FORECASTS FROM PERIOD 55

PERIOD	FORECAST	95 PERCENT LIMITS		ACTUAL
		LOWER	UPPER	
56	-2951.9	-32829.6	26925.8	-24664.1
57	-774.8	-36704.6	35155.1	5841.5
58	-492.4	-37561.3	36576.5	5409.9
59	-492.4	-37561.3	36576.5	-7039.9
60	-492.4	-37561.3	36576.5	-6352.8
61	-492.4	-37561.3	36576.5	
62	-492.4	-37561.3	36576.5	
63	-492.4	-37561.3	36576.5	
64	-492.4	-37561.3	36576.5	
65	-492.4	-37561.3	36576.5	

MTB > acf c2

ACF OF C2



Deret α_t

MTB > print c1

c1

0	2285	11293	-1866	4696	6597	6958	6656
-8631	8942	1033	112685	-31661	-43943	-31157	-6968
4124	-18271	17680	4154	-3055	15997	1473	13467
-10968	-13793	-4480	1823	13624	-15305	17426	1730
8242	49712	-16144	-20317	-11087	-6365	4299	4620
-2880	2476	17452	-670	7068	12519	-6045	6278
-9877	1526	3470	10393	-7940	22673	20390	2281
-5626	25050	-5930	-404				

Deret β_t

MTB > print c2

c2


0.0	227.0	11128.1	-2701.9	8902.2	4391.3	-1956.3	7416.
3618.0	6925.5	79344.5	82228.0	-55413.8	-73094.6	-17988.7	-12556.
4090.1	-17731.9	14083.9	4043.2	-1066.2	13636.3	-3280.9	-6291.
7346.3	-366.9	2769.9	8460.9	13467.7	-16534.4	24852.4	5849.
1989.4	1645.2	-2866.1	288.7	-3729.5	-6583.1	23858.2	-2672.
4362.8	7634.1	18044.8	-6027.4	1255.0	5705.3	-6198.5	5358.
4902.6	4305.2	9331.8	5504.3	-15444.7	15908.4	15133.7	-11997.
0134.3	19306.2	-3187.2	-2671.9				



Korelasi Silang α_t dengan β_t

MTB > ccf c1 c2


1



Deret at

0.0	0.0	3797.0	-2606.1	4786.8	785.1	-7519.4	2641.1
-1846.9	-1736.1	80522.3	-8138.2	-15415.1	-35471.1	23291.7	-11130.0
5216.2	621.0	3097.3	6259.7	-2044.6	6056.1	-2806.4	-18356.0
1111.1	-70.2	4549.7	11606.0	7114.4	152.0	19914.6	11755.0
-3868.4	-22199.4	6070.5	-6912.8	6178.3	4805.0	26235.6	-278.0
0992.9	18185.7	13494.1	4460.7	6922.8	6417.4	1460.3	5110.0
8733.0	7180.6	16799.9	4956.4	208.0	8618.3	3628.3	-19045.0
-5662.2	-3806.1	-10894.4	-14517.6				

Korelasi Silang antara at dan ct



Korelasi silang antara α_t dan x_t

CCF - CORRELATES	C1(T) AND	C3(T+K)									
	-1.0	-.8	-.6	-.4	-.2	.0	.2	.4	.6	.8	1.0
	+-----+-----+-----+-----+-----+-----+-----+-----+-----+-----+-----+										
-17	.039					XX					
-16	-.006					X					
-15	-.026					XX					
-14	-.078					XXX					
-13	-.014					X					
-12	-.056					XX					
-11	.041					XX					
-10	.061					XXX					
-9	-.005					X					
-8	.105					XXXX					
-7	-.076					XXX					
-6	-.028					XX					
-5	.060					XX					
-4	-.134					XXXX					
-3	.195					XXXXXX					
-2	-.102					XXXX					
-1	.156					XXXXX					
0	.052					XX					
1	.061					XX					
2	-.087					XXX					
3	-.028					XX					
4	.114					XXXX					
5	-.064					XXX					
6	.080					XXX					
7	-.028					XX					
8	-.023					XX					
9	.049					XX					
10	-.154					XXXXX					
11	.068					XXX					
12	.012					X					
13	.037					XX					
14	-.012					X					
15	-.066					XXX					
16	.085					XXX					
17	-.033					XX					

Hasil estimate dan ramalan untuk jumlah surat yang dikirim oleh Perum Pos dan Giro Jawa Timur.

1

MTB > arima 2 1 0 c1 c2 c3;
MTB > fore 67 16.

ESTIMATES AT EACH ITERATION

ITERATION	SSE	PARAMETERS	
0	44898234368	0.100	0.100
1	38450458624	-0.050	0.017
2	33320955904	-0.200	-0.066
3	29510023168	-0.350	-0.150
4	27017857024	-0.500	-0.234
5	25844688896	-0.650	-0.318
6	25745057792	-0.705	-0.349
7	25744758784	-0.708	-0.351
8	25744756736	-0.708	-0.351

RELATIVE CHANGE IN EACH ESTIMATE LESS THAN .0010

FINAL ESTIMATES OF PARAMETERS

NUMBER	TYPE	ESTIMATE	ST. DEV.	T-RATIO
1	AR 1	-.7083	.1171	-6.05
2	AR 2	-.3513	.1174	-2.99

DIFFERENCING. 1 REGULAR

RESIDUALS. SS = 25728778240 (BACKFORECASTS EXCLUDED)

DF = 64 MS = 402012160

NO. OF OBS. ORIGINAL SERIES 67 AFTER DIFFERENCING 66

FORECASTS FROM PERIOD 67

PERIOD	FORECAST	95 PERCENT LIMITS		ACTUAL
		LOWER	UPPER	
68	198398	159091	237704	
69	200594	159650	241539	
70	198459	153979	242939	
71	199200	149140	249260	
72	199425	146579	252272	
73	199005	142764	255247	
74	199224	139623	258824	
75	199217	136789	261644	
76	199145	133825	264464	
77	199198	131124	267272	
78	199186	128516	269855	
79	199176	125962	272389	
80	199187	123526	274848	
81	199183	121157	277209	
82	199182	118853	279511	
83	199184	116620	281748	

MTB > outf

