

## PERAMALAN DATA RUNTUN WAKTU MENGGUNAKAN METODE BOX – JENKINS

Oleh :

Fahrudin Muhtarulloh

Universitas Swadaya Gunung Jati

fahrudinmuhtar.math@gmail.com

### ABSTRAK

Peramalan merupakan hal yang sangat diperlukan oleh manusia modern. Berdasarkan data yang digunakan, peramalan dibagi dalam dua hal yaitu peramalan dengan menggunakan data sekarang dan peramalan menggunakan data masa lalu (runtun waktu/ *time series*). Peramalan yang pertama menggunakan metode regresi sedangkan peramalan yang terakhir menggunakan model – model *time series*. Pemodelan data runtun waktu bertujuan untuk menghasilkan sebuah formula yang dapat digunakan untuk peramalan data dimasa yang akan datang. Adapun data yang digunakan dalam makalah ini adalah data runtun waktu (data masa lalu) dengan menggunakan metode Box – Jenkins. Metode Box – Jenkins adalah sebutan metode peramalan data runtun waktu yang menggunakan fungsi autokorelasi (fak) dan fungsi autokorelasi parsial (fakp) dalam tahapan identifikasi model.

#### Kata kunci :

Metode Box – Jenkins, Fungsi Autokorelasi (fak), Fungsi Autokorelasi Parsial (fakp)

### A. Pendahuluan

Adanya sebuah keinginan untuk mendapatkan sebuah hasil yang optimal, menjadikan masalah peramalan menjadi dirasa sangat penting pada era modern. Sementara terdapat selang waktu antara keinginan tersebut dengan kejadian yang akan terjadi pada masa yang akan datang. Peramalan memegang peranan penting dalam pengambilan keputusan yang dilakukan oleh manajer – manajer di perusahaan dan atau perorangan serta lembaga tertentu, dengan

tujuan keputusan yang diambil sekarang memberikan hasil yang optimal pada masa yang akan datang. Peramalan yang dimaksud menggunakan data runtun waktu (data masa lalu).

Data Runtun waktu adalah jenis data yang dikumpulkan menurut urutan waktu dalam suatu rentang waktu tertentu. Frekuensi pengumpulan data selalu sama (*equidistant*). Dalam kasus diskrit, frekuensi dapat berupa detik, menit, jam, hari, bulan ataupun tahun. Secara umum data runtun waktu dibagi

dua, yaitu data runtun waktu stasioner dan data runtun waktu nonstasioner. Pada data runtun waktu stasioner berlaku sifat-sifat berikut:  $E(Z_t) = \mu$  dan  $\gamma_k = \gamma_0$  dimana  $k > 0$ , artinya data bergerak disekitar rata-rata ( $\mu$ ) dan kovarians lag ke depan dan ke belakang adalah sama. Kestasioneran akan lebih mudah dilihat dengan *output* Minitab yakni dari plot data yang bergerak disekitar rata-rata ( $\mu$ ), grafik fungsi autokorelasi (fak) yang terputus pada suatu lag dan fungsi autokorelasi parsial (fakp) yang turun secara eksponensial. Sedangkan data nonstasioner, akan sangat membantu dengan melihat *output* Minitab, yakni dari plot data yang membentuk trend, grafik fak menurun secara lambat, grafik fakp hampir sama dengan 1 dan yang lainnya tidak berbeda secara signifikan dengan nol.

Rosadi (2006) menjelaskan pengelompokan model runtun waktu, yaitu model stasioner, model nonstasioner, model univariat, dan model multivariat. Model stasioner adalah suatu model yang bersifat invariant (sifat statistiknya tidak berubah dengan pergeseran waktu). Sifat statistik yang sering menjadi perhatian adalah rata-rata, variansi serta fungsi kovarian. Pada model stasioner, sifat-sifat statistik data di masa depan dapat diramalkan berdasarkan data historis yang telah terjadi di masa lalu. Menurut Model stasioner diantaranya: *White Noise*, *Moving Average (MA)*, dan *Autoregresi Moving Average (ARMA)*. Model nonstasioner adalah model yang tidak memiliki sifat model stasioner di atas. Model nonstasioner diantaranya: model *Trend*, *Autoregresi Integrated Moving Average (ARIMA)*, *Seasonal ARIMA (SARIMA)*, model ARIMAX (model ARIMA dengan variable predictor).

Fungsi autokorelasi diturunkan dari fungsi autokovarian. Autokovarian lag ke- $k$ ,

$\gamma_k = Cov(Z_t, Z_{t-k}) = E(Z_t Z_{t-k}) - \mu E(Z_t) \mu E(Z_{t-k})$  Sedangkan autokorelasi lag ke- $k$  didefinisikan oleh persamaan berikut :

$$\rho_k = \frac{Cov(Z_t, Z_{t-k})}{\sqrt{Var(Z_t)} \sqrt{Var(Z_{t-k})}} = \frac{\gamma_k}{\gamma_0} ; k = 1, 2, 3, \dots \quad (2.1)$$

dimana  $\rho_k$  disebut sebagai fungsi autokorelasi. Pada praktiknya, nilai  $\rho_k$  ditaksir oleh  $r_k$ . Sehingga diperoleh persamaan berikut :

$$r_k = \frac{c_k}{c_0} = \frac{\rho_k}{\rho_0} = \frac{Cov(Z_t, Z_{t-k})}{\sqrt{Var(Z_t)} \sqrt{Var(Z_{t-k})}} = \frac{\sum_{i=1}^n (Z_i - \bar{Z})(Z_{i-k} - \bar{Z})}{\sum_{i=1}^n (Z_i - \bar{Z})^2} \quad (2.2)$$

dimana  $r_k$  = koefisien autokorelasi data observasi lag ke- $k$

$\bar{Z}$  = rata-rata nilai observasi

$Z_t$  = observasi pada periode  $t$

$Z_{t-k}$  = observasi pada periode  $t-k$

Rosadi (2006) menjelaskan sifat-sifat yang dimiliki fungsi autokorelasi (fak) adalah sebagai berikut:

1. Simetris  $\rho(t,s) = \rho(s,t)$
2.  $\rho(t,t) = 1$
3. Memenuhi ketidaksamaan Schwarz:  $|\gamma(t,s)| \leq \sqrt{\gamma(t,t)\gamma(s,s)}$  dan  $|\rho(t,s)| \leq 1 \quad \forall t,s \in T$
4. Definit nonnegatif  $\sum_{i=1}^n \sum_{j=1}^n x_i \gamma(t_i, t_j) \geq 0$  dan  $\sum_{i=1}^n \sum_{j=1}^n x_i \rho(t_i, t_j) x_j \geq 0$

Mulyana (2004) menjelaskan bahwa statistik Q Box-Pierce dapat digunakan untuk menguji suatu data runtun waktu berautokorelasi atau tidak, sebagaimana dijelaskan berikut :

Hipotesis :  $H_0: \rho_1 = \rho_2 = \dots = \rho_k = 0$  (tidak terdapat autokorelasi pada data)

$H_1$  : minimal ada satu  $\rho_k \neq 0$  (terdapat autokorelasi pada data)

$\alpha = 5\%$

Statistik Uji :

$$Q = n \sum_{k=1}^m r_k^2(\hat{u}_t) \quad (2.3)$$

Kriteria Uji :

Tolak  $H_0$  Jika nilai  $Q$  lebih besar dari  $X^2$  tabel, dengan taraf nyata  $\alpha = 5\%$  dan derajat kebebasan  $(m-p-q)$ , dimana:

$m$  = jumlah lag yang diuji

$n$  = jumlah pengamatan

$p$  = jumlah parameter yang ditaksir dari model autoregresi (AR)

$q$  = jumlah parameter yang ditaksir dari model rata-rata bergerak (MA)

$r_k$  = autokorelasi sampel.

Fungsi autokorelasi parsial adalah korelasi antar data pengamatan suatu data runtun waktu. Seperti halnya autokorelasi yang merupakan fungsi atas lag, yang mana hubungannya disebut fungsi autokorelasi (*autocorrelation function, ACF*), autokorelasi parsial juga merupakan fungsi atas lag, dan hubungannya disebut fungsi autokorelasi parsial (*partial autocorrelation function, PACF*). Fungsi autokorelasi parsial menunjukkan tingkat keeratan antara  $Z_t$  dan  $Z_{t-k}$  dengan syarat menghilangkan pengaruh dari lag 1, 2, dan seterusnya sampai  $k-1$ .

Fungsi autokorelasi parsial ditulis dengan notasi  $\{\phi_{kk}; k = 1, 2, \dots\}$  yakni himpunan autokorelasi parsial untuk berbagai lag  $k$ . Koefisien autokorelasi parsial lag ke  $k$  dapat dicari dengan persamaan berikut.

$$\phi_{kk} = \frac{|P_k^*|}{|P_k|} \quad (2.4)$$

dimana  $P$  adalah matriks autokorelasi  $k \times k$ , dan  $P_k^*$  adalah  $P_k$  dengan kolom terakhir diganti dengan  $\begin{bmatrix} P_1 \\ P_2 \\ \vdots \\ P_k \end{bmatrix}$  atau rumus tersebut juga dapat ditulis sebagai berikut :

$$\begin{bmatrix} P_1 \\ P_2 \\ \vdots \\ P_k \end{bmatrix}$$

$$\phi_{k \times} = \frac{P_k}{P_k} = \begin{vmatrix} 1 & \rho_1 & \rho_2 & \dots & \rho_{k-2} \rho_1 \\ \rho_1 & 1 & \rho_1 & \dots & \rho_{k-3} \rho_2 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ & & & & \vdots \\ P_{k-1} & \rho_{k-1} & \rho_{k-2} & \dots & \rho_1 \rho_k \\ 1 & \rho_1 & \rho_2 & \dots & \rho_{k-2} \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & \dots & \rho_{k-3} \rho_{k-2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ P_{k-2} & \rho_{k-2} & \rho_{k-3} & \dots & \rho_1 1 \end{vmatrix} \quad (2.5)$$

Metode peramalan Box-Jenkins (ARIMA) adalah suatu metode yang sangat tepat untuk menangani atau mengatasi kerumitan runtun waktu dan situasi peramalan lainnya. Dalam hal ini, kerumitan yang dimaksud adalah terdapatnya variansi dari pola data yang ada. Metode Box-Jenkins dikembangkan karena metode yang ada selalu mengasumsikan atau dibatasi hanya untuk macam-macam pola tertentu dari data. Sebagai contoh hal tersebut, metode penghalusan eksponensial menggunakan asumsi adanya suatu pola stasioner dari data yang ada.

Untuk menganalisis data runtun waktu, metode Box-Jenkins menggunakan operator *back shift*,  $B$  yang didefinisikan oleh :

$$BZ_t = Z_{t-1} \quad (2.6)$$

dan operator diferensi,  $\nabla$  yang didefinisikan oleh :

$$\nabla Z_t = Z_t - Z_{t-1} \quad (2.7)$$

Hubungan kedua operator tersebut dinyatakan dengan persamaan berikut :

$$\nabla = 1 - B \quad (2.8)$$

Pada praktiknya sering ditemui model proses statistic dalam bentuk berikut :

$$Z_t = \frac{\theta(B)}{\phi(B)} a_t$$

$$Z_t = \psi(B) a_t \quad (2.9)$$

dengan  $\phi$ ,  $\theta$  dan  $\psi(B)$  adalah parameter model AR( $p$ ), MA( $q$ ) dan fungsi transfer. Sehingga  $\{Z_t\}$  dapat dipandang sebagai runtun waktu yang melewati proses *white noise*  $\{a_t\}$  melalui *linear filter* dengan fungsi transfer  $\psi(B)$  dimana  $\phi$  dan  $\theta$  adalah polinomial dan  $\{a_t\}$  adalah galat yang dibangkitkan oleh proses *white noise* (gerakan random). Deret  $\{a_t\}$  independen dan berdistribusi normal dengan mean 0 dan variansi konstan  $\{\sigma_a^2\}$  ditulis  $a_t \sim N(0, \sigma_a^2)$

Periksaan terhadap estimasi faktor dan faktor yang diperoleh dari data runtun waktu, dapat dikenali pola runtun waktu tersebut mengikuti model AR, MA, ARMA. Atau ARIMA. Hal tersebut disebut sebagai proses identifikasi model, proses ini akan lebih mudah jika data yang dimiliki stasioner. Oleh karena itu, untuk mempermudah proses identifikasi model data runtun waktu yang tidak stasioner diubah ke dalam bentuk data stasioner dengan menggunakan operator *diferensi* pada data asli.

Langkah selanjutnya, adalah menaksir nilai dari parameter-parameter pada model awal dengan penaksir yang paling efisien. Selanjutnya melakukan verifikasi model, yaitu pengujian untuk menentukan apakah model sementara yang dimiliki adalah model yang cukup memadai. Jika tidak, kembali lagi pada tahap identifikasi sampai diperoleh model yang cocok. Tahap verifikasi ini menggunakan prinsip *parsimony*, yakni parameter-parameter dalam model harus dinyatakan dalam bentuk yang sederhana (variabelnya sedikit).

Proses Autoregresi (AR) dari orde  $p$ , ditulis AR( $p$ ) memiliki bentuk umum sebagai berikut :

$$Z_t = \theta_1 Z_{t-1} + \theta_2 Z_{t-2} + \cdots + \theta_p Z_{t-p} + a_t \quad (2.10)$$

dimana nilai sekarang dari proses AR( $p$ ) dinyatakan sebagai jumlah terbilang nilai-nilai yang lalu ditambah sebuah sesatan (error) sekarang. Jadi  $Z_t$  dapat dianggap diregresikan pada nilai  $p$  nilai  $Z$  yang lalu. Dengan menggunakan notasi operator *back shift* persamaan di atas bisa ditulis sebagai  $\theta(B)Z_t = a_t$  dengan  $\theta(B) = 1 - \theta_1B - \theta_2B^2 - \cdots - \theta_pB^p$  yang selanjutnya dinamakan operator AR( $p$ ).

Selanjutnya perhatikan proses AR (1), dalam bentuk :

$$Z_t = \theta_1 Z_{t-1} + a_t \quad (2.11)$$

dimana sesatan  $a_t \sim N(0, \sigma_a^2)$  dan model ini dianggap stasioner. Karena  $a_t$  independen dengan  $Z_{t-1}$  maka variansinya

$$\sigma_z^2(1 - \theta^2) = \sigma_a^2 \quad (2.12)$$

agar  $\sigma_a^2$  terbatas dan non-negatif, maka  $-1 < \theta < 1$ . Untuk keperluan identifikasi model, jika fak turun secara eksponensial dan fakp terputus pada lag ke- $p$ . Hal ini dilakukan dengan mencocokannya dengan hasil keluaran *soft ware Minitab 14*.

Proses Moving Average (MA) Bentuk umum untuk proses moving average dari ord  $q$ , ditulis MA( $q$ ) diberikan oleh

$$Z_t = a_t + \theta_1 a_{t-1} + \cdots + \theta_q a_{t-q} \quad (2.13)$$

dimana diasumsikan,  $a_t \sim N(0, \sigma_a^2)$ . Persamaan di atas dapat dituliskan dalam bentuk  $Z_t = \theta(B)a_t$   $\quad (2.14)$

dengan  $\theta(B) = 1 + \theta_1(B)^1 + \cdots + \theta_q(B)^q$  disebut operator MA( $q$ ). Adapun variansnya adalah

$$\sigma_z^2 = (1 + \theta_1^2 + \cdots + \theta_q^2)\sigma_a^2 \quad (2.15)$$

Dan untuk  $q$  yang terbatas proses akan selalu stasioner.

Persamaan (2.14) dapat juga ditulis

$$\theta^{-1}(B)Z_t = a_t \quad (2.16)$$

Dalam keperluan identifikasi model, data runtun waktu termasuk ke dalam model MA( $q$ ), jika faktor pada lag ke- $q$  dan faktor turun secara eksponensial. Hal ini dilakukan dengan mencocokannya dengan hasil keluaran *software Minitab 14*.

### B. Rumusan Masalah

- 1) Bagaimana mendapatkan model peramalan dengan menggunakan metode Box – Jenkins yang sesuai dengan karakteristik data yang dimiliki?
- 2) Bagaimana membuat nilai peramalan dengan model peramalan yang sudah dipilih?

### C. Pembahasan

Data yang digunakan pada makalah ini merupakan data sekunder tentang data harian jumlah transaksi penjualan pulsa elektronik kartu AS denominasi 10.000 bulan April dan Mei, ukuran sampel 61 (sumber: Tugas Akhir "Pembaharuan Model Peramalan pada Metode Box – Jenkins"). Berikut langkah-langkah analisis data dan pencarian model peramalan.

#### Pemeriksaan Kestasioneran Data

Stasioneritas data ditunjukkan oleh dua hal, yaitu stasioner dalam varians dan stasioner dalam rata-rata. Stasioner dalam varians digunakan metode Box – Cox. Dengan menggunakan program Minitab 14 pada data asli diperoleh  $\lambda = -2$ , artinya data tersebut sudah stasioner dalam varians. Jika dilakukan transformasi pembedaan orde 1 pada data tersebut kemudian dilakukan uji stasioner varians, maka akan menunjukkan hasil yang sama. Selanjutnya, masih pada data asli dilakukan uji stasioner dalam rata-rata, yaitu uji ADF dengan bantuan program Eviews. Namun diperoleh hasil pengujian data tidak stasioner dalam rata-rata karena pada  $\alpha = 0.05$  diperoleh  $|t_{\delta}| < |t_{(61,0.05)}|$  atau  $0.386087 < 1.9462$ . Selanjutnya dilakukan transformasi pada data asli, yaitu pembedaan orde 1 dengan menggunakan operator *Backshift* sehingga diperoleh hasil uji ADFb sebagai berikut.

Tabel 1. Output Eviews Data Pembedaan Orde 1

ADF Test Statistic	$t_{\delta}$	Critical Value*	$t_{(60,0.05)}$
-6.627592	0.01	-2.6033	
-6.627592	0.05	-1.9463	
-6.627592	0.10	-1.6188	

\* MacKinnon critical values for rejection of hypothesis of a unit root.

Hasil pengujian ADF di atas memperlihatkan data sudah stasioner dalam rata-rata, karena pada  $\alpha = 0.05$  diperoleh  $|t_{\delta}| > |t_{(61,0.05)}|$  atau  $6.627592 > 1.9463$ . Dilihat dari uji stasioner varians dan

stasioner rata-rata tersebut dapat disimpulkan bahwa data perbedaan orde 1 stasioner. Untuk analisis selanjutnya akan digunakan data perbedaan orde 1.

### Identifikasi Model

Identifikasi model dilakukan dengan membandingkan secara grafik fakt dan fakt dari data dengan fakt dan fakt teoritis dengan bantuan program Minitab. Output Minitab 14 menunjukkan plot fakt terputus pada lag ke-1 (artinya hanya lag ke-1 yang signifikan) sedangkan pada plot fakt terputus pada lag ke-2 (artinya lag ke-1 dan lag ke-2 nilanya signifikan). Berdasarkan fakt dan fakt tersebut dapat diidentifikasi beberapa model yaitu: AR (1), AR (2), MA (1), dan ARMA (1, 1) dan ARMA (2, 1).

### Penaksiran Parameter Pada Model

Setelah diperoleh beberapa model pada tahap di atas, langkah selanjutnya adalah mencari penaksir terbaik untuk parameter pada model tersebut. Dengan menggunakan Minitab 14 diperoleh penaksir parameter untuk model AR (1), AR (2), MA (1), ARMA (1,1) dan ARMA (2,1) adalah sebagai berikut.

*Jurnal Euclid, vol.2, No.1, p.199*

- 1) Model AR (1), penaksir parameternya adalah  $\theta_1 = -0.4921$ , sehingga diperoleh:

$$Y_t = \theta_1 Y_{t-1} + a_t; Y_t = Z_t - Z_{t-1} \\ = -0.4921 Y_{t-1} + a_t \quad (3.1)$$

- 2) Model MA (1), penaksir parameternya adalah  $\theta_1 = 0.9776$ , sehingga diperoleh:

$$Y_t = \theta_1 a_t + a_{t-1}; Y_t = Z_t - Z_{t-1} \\ = 0.9776 a_t + a_{t-1} \quad (3.2)$$

- 3) Model AR (2), penaksir parameternya adalah  $\theta_1 = -0.6405$  dan  $\theta_2 = -0.3070$ , sehingga diperoleh:

$$Y_t = -0.6405 Y_{t-1} - 0.3070 Y_{t-2} + a_t \quad (3.3)$$

- 4) Model ARMA (1,1), penaksir parameternya adalah  $\theta_1 = 0.0592$  dan  $\theta_1 = 0.9744$ , sehingga diperoleh:

$$Y_t = 0.0592 Y_{t-1} + a_t + 0.9744 a_{t-1} \quad (3.4)$$

- 5) Model ARMA (2,1), penaksir parameternya adalah  $\theta_1 = -1.3157$ ,  $\theta_2 = -0.5450$  dan  $\theta_1 = -0.7846$ , sehingga diperoleh:

$$Y_t = -1.3157 Y_{t-1} - 0.5450 Y_{t-2} + a_t - 0.7846 a_{t-1}$$

### Pengujian Model

Terdapat tiga tahap pengujian yaitu : uji keberartian koefisien, uji kecocokan model (*lack of fit*), uji variansi sesatan

#### 1) Uji Keberartian Koefisien

Kriteria pengujian keberartian koefisien yaitu: Koefisien dikatakan berarti (signifikan) jika  $|Coef| > 2 SE Coef$  atau dengan jika  $P\text{-Value} < \alpha$ . Untuk selanjutnya dalam makalah ini digunakan kriteria  $P\text{-Value}$ . Hasil pengujian seperti pada table dibawah ini.

Tabel 2. $P\text{-Value}$  Koefisien Model

Model	Koefisien	$P\text{-Value}$
AR (1)	$\theta_1$	0.000
MA (1)	$\theta_1$	0.000
AR (2)	$\theta_1$	0.000
	$\theta_2$	0.000
ARMA (1,1)	$\theta_1$	0.682
	$\theta_1$	0.000
ARMA (2,1)	$\theta_1$	0.000
	$\theta_2$	0.000
	$\theta_1$	0.000
	$\theta_1$	0.000

Dari table di atas hanya ARMA (1,1) yang memiliki nilai  $P\text{-Value} = 0.682 > 0.05$ , artinya model ini tidak cocok untuk digunakan dalam peramalan. Sedangkan empat model lainnya memiliki  $P\text{-Value} < 0.05$ , artinya dapat dilakukan pengujian lebih lanjut.

#### 2) Uji Kecocokan (*Lack of Fit*)

Pengujian *lack of fit* menggunakan uji Chi-Kuadrat dari statistik Q Box-Pierce. Model diterima jika nilai  $P\text{-Value} > \alpha$ , sedangkan sebaliknya maka model ditolak. Hasil pengujian seperti di bawah ini.

Tabel 3.Nilai Q Box-Pierce model AR (1), MA (1), AR(2) dan ARMA (2,1)

Lag	AR(1)	MA(1)	AR (2)	ARMA (2,1)
	$P\text{-Value}$	$P\text{-Value}$	$P\text{-Value}$	$P\text{-Value}$
12	0.403	0.780	0.382	0.374
24	0.705	0.893	0.666	0.707
36	0.628	0.753	0.391	0.729
48	0.903	0.953	0.853	0.929

Dari tabel di atas, terlihat nilai *P-Value* keempat model disetiap lag memiliki nilai yang lebih besar dari 0.05. Ini berarti, keempat model tersebut cukup sesuai dengan data yang ada.

### 3) Uji Variansi Sesatan

Langkah selanjutnya untuk memperoleh model terbaik dengan membandingkan nilai variansi sesatan diantara keempat model tersebut. Model yang terbaik adalah yang memiliki nilai variansi sesatan yang paling kecil, cocok untuk semua lag dan memenuhi prinsip parsimony (jumlah parameternya lebih sedikit). Hasil pengujian variansi sesatan diperoleh seperti dibawah ini.

**Tabel 4.**Variansi Sesatan AR (1), MA (1), AR(2) dan ARMA (2,1)

Besaran	AR(1)	MA(1)	AR (2)	ARMA (2,1)
SS	130269	94991.9	118391	120679
MS	2246	1637.8	2077	2155
DF	58	58	57	56
$\sigma^2 = \frac{SS - MS}{DF}$	2207.29	1609.55	2040.60	2116.5

Dari tabel di atas dapat dilihat bahwa model MA (1) memiliki nilai variansi sesatan paling kecil dibandingkan model yang lainnya. Selain itu MA (1) cocok untuk semua lag dan memenuhi sifat parsimony (jumlah parameter sedikit). Berdasarkan hal tersebut, model yang paling sesuai dengan data adalah model MA (1). Tahap peramalan akan menggunakan model terpilih,yaitu MA (1).

### Peramalan Data Beberapa Period ke Depan

Setelah mendapat model yang paling sesuai, dalam hal ini MA (1). Langkah selanjutnya adalah meramalkan jumlah transaksi penjualan pulsa elektrik AS denominasi 10.000 untuk beberapa periode yang akan datang. Dari output Minitab 14 diperoleh nilai ramalan untuk beberapa period ke depan adalah sebagai berikut.

**Tabel 5.**Ramalan data beberapa period eke depan

Forecasts from Period 61 95 Percent Limits			
Period	Forecast	Lower	Upper
62	235.460	156.124	314.797
63	235.221	155.864	314.577
64	234.981	155.604	314.357
65	234.741	155.345	314.137
66	234.501	155.0855	313.917

#### D. Kesimpulan dan Saran

Berdasarkan permasalahan yang telah dikemukakan dan analisis data yang telah dilakukan, maka dapat diambil beberapa kesimpulan sebagai berikut:

- 1) Model peramalan yang sesuai dengan data yang dimiliki, dalam hal ini data jumlah transaksi harian pulsa elektrik AS denominasi 10.000 di P-Tronik Cell Geger Kalong Girang Bandung dengan menggunakan metode Box - Jenkins adalah model MA(1), yaitu:  

$$Y_t = 0.9776 a_t + a_{t-1}$$
- 2) Peramalan data periode yang akan datang dengan menggunakan model yang sudah diperoleh, MA(1), hasilnya sebagai berikut.

**Tabel 6.**Peramalan Jumlah Transaksi Penjualan Pulsa Elektri  
Lima Hari ke Depan

No	Tanggal	Jumlah Transaksi
1.	1	235
2.	2	235
3.	3	235
4.	4	234
5.	5	234

Adapun saran yang dapat diberikan untuk kajian berikutnya baik secara teoritis dan praktis adalah sebagai berikut.

- 1) Saran Teoritis: metode peramalan runtun waktu menafikan adanya pengaruh eksternal, seperti hari libur, promosi, perubahan harga yang selanjutnya disebut dengan intervensi. Sedangkan menurut, Bovas (1983) intervensi dapat menimbulkan beberapa respon, yaitu perubahan rata-rata dari data, perubahan trend, atau respon lainnya yang lebih kompleks. Tujuan utama dari analisis intervensi adalah mengukur pengaruh kejadian eksternal. Dari uraian tersebut Jelaslah bahwa analisis intervensi sangat diperlukan dalam mengatasi masalah pengaruh eksternal tersebut.
- 2) Saran Praktis: Penggunaan aplikasi Minitab 14 dalam pengolahan data dirasakan sangat mensenjang dalam menentukan kestasioneran data. Namun demikian Minitab memiliki kekurangan, yaitu pengujian kestasioneran hanya berdasarkan pada grafik. Untuk menentukan kestasioneran data secara lebih detail lagi menurut statistik diperlukan penggunaan program lain yaitu Eviews.

#### DAFTAR PUSTAKA

- Abraham, Bovas and Johannes, L. 1983. *Statistical Methods for Forecasting*. New York : Jhon Wiley & Sons, Inc.
- Box, George and Jenkins, G. 1970. *Times Series Analysis and Control*. San Fransisco: Holden-Day.
- Muhtarulloh, Fahrudin . 2008. *Tugas Akhir Pembaharuan Model Peramalan Padat Metode Box-Jenkins*. Bandung: FPMIPA Universitas Pendidikan Indonesia.
- Mulyana, 2004. *Buku Ajar Analisis Data Deret Waktu*. Bandung : FMIPA Universitas Padjadjaran.
- Rosadi, Dedi. 2006. *Diktat Kuliah Pengantar Analisis Data Runtun Waktu*. Yogyakarta : FPIMA Universitas Gadjah Mada.