

## BAB III

### AUTOKOVARIAN

Pada bagian ini akan dibahas tentang Autokovarian yang menyatakan tingkat ketergantungan antara pengamatan waktu ke  $t$  dengan pengamatan pada waktu sebelum  $t$ . Dengan terlebih dahulu akan dibahas mengenai estimasi kwadrat terkecil dalam regresi sederhana; mean, varian, kovarian dan korelasi dari variabel random; dan mean, varian dari  $\hat{\beta}_1$ ,  $\hat{\phi}_1$  dan  $\hat{\rho}_k$ . Setelah itu baru sifat-sifat distribusi dari  $a_t$  pada model ARMA dan teori autokovarian.

#### 3.1 ESTIMASI KWADRAT TERKECIL DALAM REGRESI SEDERHANA

Model regresi biasa

$$\hat{y}_t = \beta_0 + \beta_1 \hat{x}_t + \varepsilon_t \quad \dots\dots\dots(3.1.1)$$

Estimasi kuadrat terkecil dari  $Y$  terhadap  $\beta_0$  dan  $\beta_1$  diperoleh dengan meminimalkan jumlah kuadrat dari error  $\varepsilon_t$

$$\sum \varepsilon_t^2 = \sum (\hat{y}_t - \beta_0 - \beta_1 \hat{x}_t)^2$$

dimana  $\sum$  menunjukkan penjumlahan dari  $t$  yang berjalan dari 1 sampai  $N$ . Jika dideferensialkan terhadap  $\beta_0$ ,  $\beta_1$  dan menyamakan dengan nol, estimasi dari  $\hat{\beta}_0$  dan  $\hat{\beta}_1$  adalah :

$$\frac{\partial \sum \varepsilon_t^2}{\partial \beta_0} = -2 \sum (\hat{y}_t - \beta_0 - \beta_1 \hat{x}_t) = 0 \quad \dots\dots\dots(3.1.2)$$

$$\frac{\partial \sum \varepsilon_t^2}{\partial \beta_1} = -2 \sum \dot{x}_t (\dot{y}_t - \beta_0 - \beta_1 \dot{x}_t) = 0 \quad \dots\dots\dots(3.1.3)$$

Membagi persamaan (3.1.2) dengan  $-2N$  akan didapatkan :

$$\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x} \quad \dots\dots\dots(3.1.4)$$

Karena

$$\sum \bar{x} (\dot{y}_t - \bar{y}) = \bar{x} (\sum \dot{y}_t - \sum \bar{y}) = 0$$

$$\sum \bar{x} (\dot{x}_t - \bar{x}) = \bar{x} (\sum \dot{x}_t - \sum \bar{x}) = 0$$

mengganti  $\beta_0$  dalam persamaan (3.1.3) dan membagi dengan  $-2$  akan didapatkan

$$\begin{aligned} \sum \dot{x}_t \left[ (\dot{y}_t - \bar{y}) - \hat{\beta}_1 (\dot{x}_t - \bar{x}) \right] &= \sum \dot{x}_t \left[ (\dot{y}_t - \bar{y}) - \beta_1 (\dot{x}_t - \bar{x}) \right] \\ &- \sum \bar{x} \left[ (\dot{y}_t - \bar{y}) - \beta_1 (\dot{x}_t - \bar{x}) \right] = 0 \end{aligned}$$

yaitu

$$\sum (\dot{x}_t - \bar{x}) \left[ (\dot{y}_t - \bar{y}) - \hat{\beta}_1 (\dot{x}_t - \bar{x}) \right] = 0$$

atau

$$\hat{\beta}_1 = \frac{\sum (\dot{y}_t - \bar{y}) (\dot{x}_t - \bar{x})}{\sum (\dot{x}_t - \bar{x})^2} = \frac{\sum y_t x_t}{\sum x_t^2} \quad \dots\dots\dots(3.1.5)$$

### 3.2 MEAN, VARIAN, KOVARIAN DAN KORELASI DARI VARIABEL RANDOM

Dua karakteristik utama dari variabel random adalah mean (rata-rata dari nilai observasi/pengamatan), dan varian, yang mana merupakan nilai ekspektasi kwadrat penyimpangan dari mean. Mean menunjukkan titik tengah dari

distribusi probabilitas dan varian menunjukkan penyebaran yang menyatakan seberapa jauhkah penyimpangan tersebut dari titik tengah atau mean. Akar kwadrat dari varian dinamakan standar error atau standar deviasi. Untuk dua variabel random sebagai karakteristik tambahan adalah kovarian, yaitu nilai ekspektasi dari hasil kali penyimpangan pada mean masing-masing. Kovarian menyatakan tingkat ketergantungan antara pasangan variabel random dan sama dengan nol ketika keduanya independen.

Jika  $X$  dan  $Y$  adalah dua variabel random dengan mean  $\mu_x$  dan  $\mu_y$ , varian  $\sigma_x^2$  dan  $\sigma_y^2$  dan kovarian  $\gamma_{xy}$ , dan nilai harapan (ekspektasi) dengan  $E$  maka

$$\text{Mean dari } X = \mu_x = E(x) \dots\dots\dots(3.2.1)$$

$$\text{Mean dari } Y = \mu_y = E(y) \dots\dots\dots(3.2.2)$$

$$\text{Varian dari } X = \sigma_x^2 = E(x-\mu_x)^2 \dots\dots\dots(3.2.3)$$

$$\text{Varian dari } Y = \sigma_y^2 = E(y-\mu_y)^2 \dots\dots\dots(3.2.4)$$

$$\text{Kovarian } (X,Y) = \gamma_{xy} = E(x-\mu_x)(y-\mu_y) \dots\dots\dots(3.2.5)$$

Membagi kovarian dengan akar kwadrat dari varian atau standar deviasi dinamakan korelasi yang juga mengukur tingkat ketergantungan tetapi dengan skala kovarian, dan dinyatakan dengan  $\rho_{xy}$ , yaitu :

$$\text{Korelasi} = \frac{\text{Kovarian } (X,Y)}{\sqrt{\text{Var}(X) \text{Var}(Y)}} \dots\dots\dots(3.2.6)$$

$$= \frac{E(X-\mu_x)(Y-\mu_y)}{\sqrt{E(X-\mu_x)^2 E(Y-\mu_y)^2}} \dots\dots\dots (3.2.6a)$$

$$\rho_{xy} = \frac{\gamma_{xy}}{\sigma_x \sigma_y} \dots\dots\dots (3.2.6b)$$

Nilai dari korelasi ini akan selalu lebih kecil atau sama dengan satu dalam nilai mutlak, atau  $|\rho_{xy}| \leq 1$ . Untuk membuktikannya, walaupun variabel random dapat positif atau negatif, nilai kwadratnya tidak akan negatif dan oleh karena itu nilai ekspektasi atau variannya tidak akan pernah negatif. Sekarang menganggap variabel random  $aX+bY$ .

$$\begin{aligned} \text{Mean dari } (aX+bY) &= \mu_{ax+by} = E(aX+bY) \\ &= aE(X)+bE(Y) \\ &= a\mu_x+b\mu_y \dots\dots\dots (3.2.7) \end{aligned}$$

$$\begin{aligned} \text{Varian dari } (aX+bY) &= \sigma_{ax+by}^2 = E(aX+bY-\mu_{ax+by})^2 \\ &= E[a(X-\mu_x)+b(Y-\mu_y)]^2 \\ &= E[a^2(X-\mu_x)^2+2ab(X-\mu_x)(Y-\mu_y) \\ &\quad +b^2(Y-\mu_y)^2] \\ &= a^2E(X-\mu_x)^2+2abE(X-\mu_x)(Y-\mu_y) \\ &\quad +b^2E(Y-\mu_y)^2] \\ &= a^2\text{Var}(X)+2ab\text{Kov}(X,Y)+b^2\text{Var}(Y) \dots\dots\dots (3.2.8) \end{aligned}$$

Misal :

$$a=1 \text{ dan } b^2 = \frac{\text{Var}(X)}{\text{Var}(Y)} \text{ atau } b = \pm \sqrt{\frac{\text{Var}(X)}{\text{Var}(Y)}}$$

maka persamaan (3.2.8) akan menjadi :

$$\text{Var}(X) \pm 2\sqrt{\frac{\text{Var}(X)}{\text{Var}(Y)}} \text{Kov}(X,Y) + \text{Var}(X) \geq 0$$

atau

$$\text{Kov}(X,Y) \leq \sqrt{\text{Var}(X)\text{Var}(Y)} \quad \dots\dots\dots(3.2.9a)$$

Sehingga  $|\rho_{xy}| \leq 1$

Apabila X dan Y independen maka kovarian  $(X,Y) = 0$  atau korelasi  $\rho_{xy} = 0$ . Sehingga persamaan (3.2.8) menjadi

$$\text{Var}(aX+bY) = a^2\text{Var}(X) + b^2\text{Var}(Y) \quad \dots\dots\dots(3.2.10)$$

Pada umumnya persamaan (3.2.10) dapat dikatakan bahwa varian dari jumlah atau selisih dari variabel random yang independen adalah jumlah dari variannya ( $a=1, b=\pm 1$ ).

Mean dari kombinasi linier pada variabel random (persamaan (3.2.7)) adalah sama dengan kombinasi linier dari mean dan varian dari kombinasi linier pada variabel random independen (persamaan (3.2.10)) adalah kombinasi linier dari varian dengan koefisien kwadrat. Sebagai catatan bahwa variabel independen tidak mempengaruhi dalam perhitungan mean tetapi untuk perhitungan varian dapat mempengaruhi.

Operasi ekspektasi yang digunakan dalam persamaan (3.2.1) sampai (3.2.5) adalah teori operasi pada populasi

atau sampel tak terbatas. Dalam praktek, biasanya yang dibutuhkan adalah mengestimasi banyaknya sampel yang terhingga dari  $N$  observasi/pengamatan, katakanlah  $X_1, X_2, \dots, X_N$ , dan  $Y_1, Y_2, \dots, Y_N$ . Jalan termudah untuk mendapatkan estimasi tersebut adalah dengan mengganti operasi ekspektasi dari sampel tak terhingga dalam persamaan (3.2.1) sampai (3.2.5) dengan operasi rata-rata pada sampel terhingga yang tersedia. Diberikan sekelompok estimasi dari mean, varian, kovarian dan korelasi seperti berikut :

$$\bar{X} = \frac{1}{N} \sum X_i \dots\dots\dots(3.2.11)$$

$$\hat{\sigma}_x^2 = \frac{1}{N} \sum (X_i - \bar{X})^2 \dots\dots\dots(3.2.12)$$

$$\hat{\gamma}_{xy} = \frac{1}{N} \sum (X_i - \bar{X})(Y_i - \bar{Y}) \dots\dots\dots(3.2.13)$$

$$\hat{\rho}_{xy} = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}} \dots\dots\dots(3.2.14)$$

dimana  $\sum$  pada persamaan diatas adalah penjumlahan dari  $i$  mulai 1 sampai  $N$ .

Jika disubstitusikan nilai observasi/pengamatan dalam persamaan (3.2.11) sampai (3.2.14) akan didapatkan nilai tertentu dari estimasi. Bagaimanapun nilai tersebut akan berbeda untuk kelompok sampel yang berbeda, karena estimator yang digunakan dalam persamaan (3.2.11) sampai (3.2.14) adalah variabel random mereka sendiri. Yang perlu

untuk dikemukakan dari estimator adalah sifat tak biasnya. Estimator dikatakan tak bias jika rata-rata (mean) atau nilai ekspektasi adalah parameternya. Untuk contoh,  $\bar{X}$  adalah estimator tak bias dari  $\mu_x$ , karena ini mudah untuk diperlihatkan bahwa mean dari  $\bar{X}$  adalah  $\mu_x$ , dengan menggunakan persamaan (3.2.7) :

$$\begin{aligned}
 E(\bar{X}) &= E\left(\frac{1}{N} \sum X_i\right) \\
 &= E\left(\frac{1}{N} X_1 + \frac{1}{N} X_2 + \dots + \frac{1}{N} X_N\right) \\
 &= \frac{1}{N} E(X_1) + \frac{1}{N} E(X_2) + \dots + \frac{1}{N} E(X_N) \\
 &= \frac{\mu_x}{N} + \frac{\mu_x}{N} + \dots + \frac{\mu_x}{N} = \mu_x \quad \dots\dots\dots(3.2.15)
 \end{aligned}$$

karena setiap  $X_i$  adalah sampel dari populasi yang sama dengan  $\mu_x$ .

Jadi estimator  $\bar{X}$  adalah titik tengah dari  $\mu_x$ , yang merupakan parameter estimasi. Bagaimanapun, untuk pengambilan sampel penghitungan rata-rata tidak akan sama untuk  $\mu_x$ . Seberapa jauh penghitungan rata-rata akan menyimpang dari  $\mu_x$ , untuk kelompok yang berbeda dari sampel akan ditunjukkan dengan varian dari  $\bar{X}$ . Jadi persamaan (3.2.7) akan digunakan untuk menghitung mean dari  $\bar{X}$ , dan persamaan (3.2.8) akan digunakan untuk menghitung varian dari  $\bar{X}$ . Bagaimanapun untuk menggunakan persamaan (3.2.8), haruslah diketahui dulu kovarian dari semua pasangan yang mungkin dari  $X_1, X_2, \dots, X_N$  yang mana

pada umumnya sulit didalam praktek. Kesulitan ini dapat diatasi jika pengamatan adalah independen, sedemikian hingga kovarian semuanya nol dan dapat digunakan pernyataan sederhana (3.2.10). Jadi untuk pengamatan independen  $X_1, X_2, \dots, X_N$  :

$$\begin{aligned} \text{Var}(\bar{X}) &= \text{Var}\left(\frac{1}{N}X_1 + \frac{1}{N}X_2 + \dots + \frac{1}{N}X_N\right) \\ &= \frac{1}{N^2} \text{Var}(X_1) + \frac{1}{N^2} \text{Var}(X_2) + \dots + \frac{1}{N^2} \text{Var}(X_N) \\ &= \frac{N \text{Var}(X)}{N^2} \\ &= \frac{1}{N} \text{Var}(X) \dots \dots \dots (3.2.16) \end{aligned}$$

yaitu :

$$\sigma_x^2 = E(\bar{X} - E(\bar{X}))^2 = E(\bar{X} - \mu_x)^2 = \frac{1}{N} \sigma_x^2 \dots \dots (3.2.16a)$$

atau

$$\sigma_{\bar{x}} = \frac{1}{\sqrt{N}} \sigma_x \dots \dots \dots (3.2.16b)$$

Jadi persamaan (3.2.16a) dan (3.2.16b) memperlihatkan standar deviasi dari  $\bar{X}$  yang mana jarak antara estimator  $\bar{X}$  dan parameter  $\mu_x$  adalah estimasinya, dengan skala  $1/\sqrt{N}$  seperti halnya jumlah pengamatan  $N$  meningkat. Khususnya  $\sigma_{\bar{x}} \longrightarrow 0$  untuk  $N \longrightarrow \infty$ , yang berarti bahwa jumlah pengamatan adalah besar, akhirnya estimator  $\bar{X}$  adalah untuk parameter dalam mengestimasi. Sifat yang lain dari estimator ini akan dinamakan konsistensi.



### 3.3 MEAN, VARIAN DARI $\hat{\beta}_1$ , $\hat{\phi}_1$ DAN $\hat{\rho}_k$

Dalam model regresi linier biasa persamaan (3.1.1) yaitu :

$$\hat{y}_t = \beta_0 + \beta_1 \hat{x}_t + \varepsilon_t$$

$\varepsilon_t$  mempunyai mean nol, karena independen pada  $t$  yang berbeda yaitu :

$$E(\varepsilon_t) = 0$$

$$\begin{aligned} \text{Kov}(\varepsilon_t, \varepsilon_{t-k}) &= E\left\{[\varepsilon_t - E(\varepsilon_t)][\varepsilon_{t-k} - E(\varepsilon_{t-k})]\right\} \\ &= E(\varepsilon_t \varepsilon_{t-k}) \\ &= 0 \text{ untuk } k \neq 0 \end{aligned}$$

dan mempunyai varian  $\sigma_\varepsilon^2$ , yaitu

$$\begin{aligned} \text{Var}(\varepsilon_t) &= E[\varepsilon_t - E(\varepsilon_t)]^2 \\ &= E \varepsilon_t^2 \\ &= \sigma_\varepsilon^2 \end{aligned}$$

Untuk variabel mean sama dengan nol, varian dan kovarian akan mudah dinyatakan dengan  $E(\varepsilon_t^2)$  dan  $E(\varepsilon_t \varepsilon_{t-k})$ .  $\beta_0$  dan  $\beta_1 \hat{x}_t$  adalah variabel deterministik (non random) dan oleh karena itu nilai ekspektasinya adalah sama. Pada kenyataannya, biasanya variabel deterministik dapat dikatakan sebagai "degenerasi" variabel random dengan mean yang sama dan variannya adalah nol, dan mereka akan independen pada beberapa variabel random lainnya. Jadi

untuk model (3.1.1) jika digunakan persamaan (3.2.7) :

$$\begin{aligned}
 \text{Mean } (\hat{y}_t) &= E(y_t) = E(\beta_0 + \beta_1 \hat{x}_t + \varepsilon_t) \\
 &= E(\beta_0 + \beta_1 \hat{x}_t) + E \varepsilon_t \\
 &= E(\beta_0) + E(\beta_1 \hat{x}_t) + 0 \\
 &= \beta_0 + \beta_1 \hat{x}_t \quad \dots\dots\dots(3.3.1)
 \end{aligned}$$

dan dengan persamaan (3.2.10) :

$$\begin{aligned}
 \text{Var } (\hat{y}_t) &= \text{Var} (\beta_0 + \beta_1 \hat{x}_t + \varepsilon_t) \\
 &= \text{Var} (\beta_0 + \beta_1 \hat{x}_t) + \text{Var} (\varepsilon_t) \\
 &= 0 + E(\varepsilon_t^2) \\
 &= \sigma_\varepsilon^2 \quad \dots\dots\dots(3.3.2)
 \end{aligned}$$

atau

$$\text{Var } (\hat{y}_t) = E(\hat{y}_t - E \hat{y}_t)^2 = E(\hat{y}_t - \beta_0 + \beta_1 \hat{x}_t)^2 = E(\varepsilon_t^2) = \sigma_\varepsilon^2$$

Juga jika diambil rata-rata mulai dari  $t=1$  sampai  $N$  dalam persamaan (3.1.1)

$$\begin{aligned}
 \bar{y} &= \beta_0 + \beta_1 \bar{x} + \bar{\varepsilon} \\
 E \bar{y} &= E \beta_0 + E \beta_1 \bar{x} + E \bar{\varepsilon} \\
 &= \beta_0 + \beta_1 \bar{x}
 \end{aligned}$$

Sekarang mengingat estimator  $\beta_1$  yang diberikan dalam persamaan (3.1.5) dapat dilihat bahwa :

$$E y_t = E(\hat{y}_t - \bar{y})$$

$$\begin{aligned}
&= E \hat{y}_t - E \bar{y} \\
&= \beta_0 + \beta_1 \hat{x}_t - \beta_0 - \beta_1 \bar{x} \\
&= \beta_1 (\hat{x}_t - \bar{x}) \\
&= \beta_1 x_t
\end{aligned}$$

dan karena hanya variabel random dalam sisi kanan dari persamaan (3.1.5) yaitu  $y_t = (\hat{y}_t - \bar{y})$ ,  $x_t$  adalah konstan, sehingga dapat diterapkan persamaan (3.2.7) ke persamaan (3.1.5) dan akan didapatkan :

Mean dari  $\hat{\beta}_1 = E(\hat{\beta}_1)$

$$\begin{aligned}
&= E \left[ \frac{\sum y_t x_t}{\sum x_t^2} \right] \\
&= \frac{1}{\sum x_t^2} E(y_1 x_1 + y_2 x_2 + \dots + y_N x_N) \\
&= \frac{1}{\sum x_t^2} (x_1 E y_1 + x_2 E y_2 + \dots + x_N E y_N) \\
&= \frac{1}{\sum x_t^2} (x_1 \beta_1 x_1 + x_2 \beta_1 x_2 + \dots + x_N \beta_1 x_N) \\
&= \beta_1 \dots \dots \dots (3.3.3)
\end{aligned}$$

sehingga  $\hat{\beta}_1$  adalah estimator *tak bias* dari  $\beta_1$ .

Demikian pula  $\hat{y}_t$  adalah independen karena  $\epsilon_t$  independen dan oleh karena itu jika diterapkan persamaan (3.2.10) dan sebagai catatan bahwa  $\sum \bar{y} x_t = 0$

$$\begin{aligned}
\text{Var}(\hat{\beta}_1) &= \text{Var} \left[ \left[ \frac{x_1}{\sum x_t^2} \right] \hat{y}_1 + \left[ \frac{x_2}{\sum x_t^2} \right] \hat{y}_2 + \dots + \left[ \frac{x_N}{\sum x_t^2} \right] \hat{y}_N \right] \\
&= \left[ \frac{x_1}{\sum x_t^2} \right]^2 \text{Var}(\hat{y}_1) + \left[ \frac{x_2}{\sum x_t^2} \right]^2 \text{Var}(\hat{y}_2) + \dots \\
&\quad + \left[ \frac{x_N}{\sum x_t^2} \right]^2 \text{Var}(\hat{y}_N) \\
&= \frac{\sum x_t^2}{(\sum x_t^2)^2} \text{Var}(\hat{y}_1) \\
&= \frac{1}{\sum x_t^2} \text{Var}(\hat{y}_1) \\
&= \frac{\sigma_\varepsilon^2}{\sum x_t^2} \dots \dots \dots (3.3.4)
\end{aligned}$$

Karena  $\sum x_t^2 \longrightarrow \infty$  untuk  $N \longrightarrow \infty$  persamaan (3.3.4) memperlihatkan bahwa  $\text{Var}(\hat{\beta}_1) \longrightarrow 0$  untuk  $N \longrightarrow \infty$ . Karena rata-rata dari  $\hat{\beta}_1$  sebenarnya adalah nilai  $\beta_1$ , ini memperlihatkan bahwa  $\hat{\beta}_1$  begitu mendekati nilai sebenarnya dengan bertambahnya jumlah pengamatan, dengan kata lain estimatornya adalah konsisten. Demikian pula, karena  $E\bar{y} = \beta_0 + \beta_1 \bar{x}$  dan  $E\hat{\beta}_1 = \beta_1$ , mengikuti dari persamaan (3.1.4) bahwa :

$$E(\hat{\beta}_0) = \beta_0 \dots \dots \dots (3.3.5)$$

dan dengan persamaan (3.2.10), karena  $\bar{y}$  dapat ditunjukkan keindependenannya pada  $\hat{\beta}_1$ ,

$$\text{Var}(\hat{\beta}_0) = \text{Var} \bar{y} + \bar{x}^2 \text{Var}(\hat{\beta}_1)$$

$$= \sigma^2 \left( \frac{1}{N} + \frac{\bar{x}^2}{\sum x_t^2} \right) \dots\dots\dots (3.3.6)$$

Hasil dari model regresi sederhana

$$y_t = \beta_1 x_t + \varepsilon_t$$

sebenarnya tidak dapat dipakai untuk model AR(1)

$$X_t = \phi_1 X_{t-1} + a_t$$

Sekalipun seperti  $\varepsilon_t$ ,  $a_t$  adalah independen, karena  $X_{t-1}$  adalah random variabel tidak seperti variabel deterministik  $x_t$ . Pada saat  $t-1$ , pengamatan  $X_{t-1}$  diketahui atau tertentu dan deterministik, maka model AR(1) dapat dipertimbangkan sebagai model regresi linier bersyarat dan persamaan (3.1.5) dapat digunakan untuk memperoleh estimator

$$\hat{\phi}_1 = \frac{\sum X_t X_{t-1}}{\sum X_{t-1}^2}$$

Jika kita asumsikan  $X_0$  itu ada, dengan cara lain penjumlahannya dapat dikurangi seperti dalam persamaan berikut :

$$\hat{\phi}_1 = \frac{\sum_{t=2}^N X_t X_{t-1}}{\sum_{t=2}^N X_{t-1}^2}$$

dimana  $X_t = \dot{X}_t - \bar{X}$ . Menurut kwadrat terkecil bersyarat ini,  $\hat{\phi}_1$  adalah tak bias dan konsisten, yaitu rata-rata atau mean dari  $\hat{\phi}_1$  adalah  $\phi_1$  dan variannya cenderung ke-nol untuk  $N \longrightarrow \infty$ .

Bagaimanapun, menurut kwadrat terkecil tak bersyarat, ketika  $X_{t-1}$  ditentukan sebagai variabel random dan  $t-1$  tidak dipertimbangkan secara khusus, maka hasilnya hanya kebenaran kira-kira. Penaksiran serupa dapat digunakan pada  $N$  yang besar untuk menghitung varian dari  $\hat{\phi}_1$  dengan mengganti  $\sum X_{t-1}^2$  dengan nilai ekspektasi

$$\begin{aligned} \text{Var}(\hat{\phi}_1) &\approx \frac{\sigma_a^2}{\sum X_{t-1}^2} \approx \frac{\sigma_a^2}{N \text{Var}(X_t)} \\ &= \frac{(1-\phi_1^2)}{N} \dots \dots \dots (3.3.7) \end{aligned}$$

dan

$$\begin{aligned} \text{Var}(\hat{\phi}_1) &= \frac{\sigma_a^2}{N \sigma_a^2} \text{ ketika } \phi_1 = 0 \\ &= \frac{1}{N} \dots \dots \dots (3.3.8) \end{aligned}$$

Alasan serupa dapat digunakan untuk estimator sampel autokorelasi

$$\hat{\rho}_k = \frac{\sum X_t X_{t-k}}{\sum X_{t-k}^2}$$

untuk mendapatkan varian saat  $\rho_k \equiv 0$  :

$$\text{Var}(\hat{\rho}_k) \approx \frac{1}{N} \quad (3.3.9)$$

### 3.4 SIFAT-SIFAT DISTRIBUSI DARI $a_t$ PADA MODEL ARMA

Ketika  $a_t$  pada model-model ARMA seperti diuraikan dalam bab terdahulu adalah variabel random untuk  $t$

tertentu atau proses stokastik untuk nilai-nilai  $t$  yang berbeda, karakteristik probabilitas sifat-sifat distribusinya diberikan sebagai berikut :

$$a_t \sim \text{NID}(0, \sigma_a^2)$$

Sifat ini menyatakan bahwa sekelompok data, katakanlah banyaknya  $N$  dari  $a_t \{a_1, a_2, \dots, a_N\}$  mempunyai distribusi normal multivariat dengan setiap  $a_t$  mempunyai rata-rata nol, varian  $\sigma_a^2$  dan kovarian antara dua  $a_t$  adalah nol. Karena kovarian yang dimaksud disini adalah proses stokastik dengan dirinya sendiri pada waktu  $t$  yang berbeda, maka dikatakan sebagai "autokovarian". Secara umum autokovarian  $a_t$  pada lag- $k$  akan diberikan dengan :

$$\text{Cov}(a_t, a_{t-k}) = E(a_t - \mu)(a_{t-k} - \mu)$$

dimana  $E$  adalah ekspektasi (nilai harapan),  $\mu$  adalah mean (rata-rata) dari  $a_t$  dan autokovarian pada lag nol adalah variannya. Karena rata-rata dari  $a_t$  adalah nol, maka  $\mu = 0$ . Sehingga dapat pula dinyatakan dengan :

$$\begin{aligned} E(a_t, a_{t-k}) &= \sigma_a^2, & k &= 0 \\ &= 0, & k &\neq 0 \end{aligned}$$

atau

$$E(a_t) = 0$$

$$E(a_t, a_{t-k}) = \delta_k \sigma_a^2 \dots \dots \dots (3.4.1)$$

dimana  $\delta_k$  adalah fungsi delta Kronecker yang sama dengan nol untuk semua  $k$  kecuali pada saat  $k=0$  sehingga  $\delta_k=1$ .

### 3.5 TEORI AUTOKOVARIAN

Seperti pada bab sebelumnya baik AR(1), ARMA(2,1) maupun ARMA(n,n-1) disebutkan bahwa :

$$X_t = \sum_{j=0}^{\infty} G_j a_{t-j}$$

Dapat dilihat bahwa  $X_t$  adalah kombinasi linier dari  $a_t$  dengan fungsi Green sebagai koefisien, maka juga berdistribusi normal multivariat dengan mean nol. Distribusi ini juga mempunyai karakteristik lengkap dengan autokovarian dari  $X_t$  yang didefinisikan dengan :

$$\gamma_k = E(X_t, X_{t-k})$$

yang merupakan autokovarian pada lag-k dan jika  $k=0$  maka akan didapatkan varian ( $\gamma_0$ ) dari  $X_t$ . Dengan mengetahui autokovarian  $\gamma_k$  yang ditunjukkan dengan persamaan (3.4.1) dan mengetahui fungsi Green dari sistem ARMA pada bab terdahulu, maka dapat ditentukan autokovarian  $\gamma_k$  dari  $X_t$ . Sehingga akan ditetapkan karakteristik probabilitasnya yang akan memberi karakteristik dari proses stokastik  $X_t$ . Pada waktu autokovarian  $\gamma_k$  dibagi varian  $\gamma_0$  akan didapatkan autokorelasi  $\rho_k$  pada lag-k, yaitu

$$\rho_k = \frac{\gamma_k}{\gamma_0}$$

dengan catatan bahwa  $\rho_0 = 1$

Autokovarian  $\gamma_k$  atau autokorelasi  $\rho_k$  menunjukkan ketergantungan  $X_t$  terhadap  $X_{t-k}$ . Perhitungannya dapat



diperoleh secara langsung dari data sebelum dimasukkan kemodelnya yaitu dengan :

$$\begin{aligned}\hat{\gamma}_k &= \frac{1}{N} \sum_{t=k+1}^N X_t X_{t-k} \\ &= \frac{1}{N} \sum_{t=k+1}^N (\hat{X}_t - \bar{X}) (\hat{X}_{t-k} - \bar{X}) \dots\dots\dots(3.5.1)\end{aligned}$$

dimana  $X_t$  adalah data pengamatan dikurangi dengan rata-rata atau  $\bar{X}$ , dan

$$\hat{\rho}_k = \frac{\hat{\gamma}_k}{\hat{\gamma}_0} \dots\dots\dots(3.5.2)$$

Hal-hal tersebut diatas disebut sampel autokovarian dan autokorelasi untuk membedakan dengan nilai-nilai  $\gamma_k$  dan  $\rho_k$  secara teoritik.

Dalam pembicaraan selanjutnya akan diperlukan kovarian antara  $a_{t-1}$  dan  $X_{t-k}$  yang dapat diperoleh dari persamaan (3.4.1) dan ekspansi fungsi Green dari setiap model ARMA,

$$X_t = \sum_{j=0}^{\infty} G_j a_{t-j} \dots\dots\dots(3.5.3)$$

dan karena  $G_0=1$ , maka akan didapatkan juga kovarian antara  $a_t$  dengan  $X_t$  yang dinyatakan dengan :

$$E(a_t X_t) = \sigma_a^2$$

dan

$$E(a_t X_{t-k}) = 0 \quad , \quad k > 0$$

Hubungan-hubungan ini dapat juga ditulis sebagai berikut :

$$E(a_t X_{t-k}) = \delta_k \sigma_a^2 \quad \dots\dots\dots(3.5.4)$$

Untuk model persamaan (3.5.3) dapat juga dinyatakan untuk  $X_{t-k}$  sehingga menjadi :

$$X_{t-k} = \sum_{j=0}^{\infty} G_j a_{t-k-j}$$

Maka kovarian antara  $a_{t-l}$  dan  $X_{t-k}$  secara umum dapat dinyatakan sebagai berikut :

$$\begin{aligned} E(a_{t-l} X_{t-k}) &= E \left[ a_{t-l} \left[ \sum_{j=0}^{\infty} G_j a_{t-k-j} \right] \right] \\ &= \sum_{j=0}^{\infty} G_j E(a_{t-l} a_{t-k-j}) \\ &= 0 \quad \text{jika } k > l \\ &= G_{l-k} \sigma_a^2 \quad \text{jika } k \leq l \quad \dots\dots\dots(3.5.5) \end{aligned}$$

Sebagai catatan

$$\gamma_k = E(X_t X_{t-k}) = E(X_{t-k} X_t) = E(X_t X_{t-k}) = \gamma_{-k} \quad \dots(3.5.6)$$