

## BAB II

### MATERI PENUNJANG

#### 2.1 ESTIMASI KWADRAT TERKECIL DALAM REGRESI SEDERHANA

Untuk mendapatkan estimasi parameter dari model regresi sederhana berbentuk:

$$\hat{y}_t = \beta_0 + \beta_1 \hat{x}_t + \varepsilon_t \quad \dots\dots\dots(2.1.1)$$

digunakan Metode Estimasi kuadrat terkecil, yaitu dengan meminimalkan jumlah kuadrat kesalahan  $\varepsilon_t$  sebagai berikut:

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

dengan mendiferensialkan ke  $\beta_0$  dan  $\beta_1$ , diperoleh estimasi dari  $\hat{\beta}_0$  dan  $\hat{\beta}_1$  sebagai berikut:

$$\frac{\partial \Sigma \varepsilon_t^2}{\partial \beta_0} = -2 \Sigma (\hat{y}_t - \beta_0 - \beta_1 \hat{x}_t) = 0 \quad \dots\dots\dots(2.1.2)$$

$$\frac{\partial \Sigma \varepsilon_t^2}{\partial \beta_1} = -2 \Sigma \hat{x}_t (\hat{y}_t - \beta_0 - \beta_1 \hat{x}_t) = 0 \quad \dots\dots\dots(2.1.3)$$

Dari persamaan (2.1.2) dan membaginya dengan  $-2N$ , didapatkan :

$$\hat{\beta}_0 = \bar{y} - \hat{\beta}_1 \bar{x} \quad \dots\dots\dots(2.1.4)$$

Karena

$$\Sigma \bar{x} (\hat{y}_t - \bar{y}) = \bar{x} (\Sigma \hat{y}_t - \Sigma \bar{y}) = 0$$

$$\Sigma \bar{x} (\hat{x}_t - \bar{x}) = \bar{x} (\Sigma \hat{x}_t - \Sigma \bar{x}) = 0$$

memasukan  $\hat{\beta}_0$  ke persamaan (2.1.3) akan didapatkan:

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

yaitu

$$\Sigma (\hat{x}_i - \bar{x}) \left[ (\hat{y}_i - \bar{y}) - \hat{\beta}_1 (\hat{x}_i - \bar{x}) \right] = 0$$

atau

$$\hat{\beta}_1 = \frac{\Sigma (\hat{y}_i - \bar{y}) (\hat{x}_i - \bar{x})}{\Sigma (\hat{x}_i - \bar{x})^2} = \frac{\Sigma y_i x_i}{\Sigma x_i^2} \dots \dots \dots (2.1.5)$$

## 2.2 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 merupakan nilai ekspektasi kwadrat penyimpangan dari mean. Mean menunjukkan titik tengah dari distribusi probabilitas dan varian menunjukkan penyebaran yang menyatakan seberapa jauh penyimpangan tersebut dari titik tengah atau mean. Akar kwadrat dari varian dinamakan standar deviasi. Karakteristik yang lain dari variabel random adalah kovarian, yaitu nilai ekspektasi dari hasil kali penyimpangan pada mean masing-masing. Kovarian menyatakan tingkat ketergantungan antara dua variabel random dan bernilai 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  $\gamma_{xy}$ , maka nilai ekspektasinya adalah:

$$\text{Mean dari } x = \mu_x = E(x) \dots\dots\dots(2.2.1)$$

$$\text{Mean dari } y = \mu_y = E(y) \dots\dots\dots(2.2.2)$$

$$\text{Varian dari } x = \sigma_x^2 = E(x - \mu_x)^2 \dots\dots\dots(2.2.3)$$

$$\text{Varian dari } y = \sigma_y^2 = E(y - \mu_y)^2 \dots\dots\dots(2.2.4)$$

$$\text{Kovarian } (x,y) = \gamma_{xy} = E(x - \mu_x)(y - \mu_y) \dots\dots\dots(2.2.5)$$

Korelasi ( $\rho_{xy}$ ) menyatakan tingkat ketergantungan antara variabel  $x$  dan  $y$  dan dinyatakan dengan :

$$\text{Korelasi} = \frac{\text{Kovarian } (x,y)}{\sqrt{\text{Var}(x)\text{Var}(y)}} \dots\dots\dots(2.2.6)$$

$$= \frac{E(x-\mu_x)(y-\mu_y)}{\sqrt{E(x-\mu_x)^2 E(y-\mu_y)^2}} \dots\dots\dots(2.2.6a)$$

$$\rho_{xy} = \frac{\gamma_{xy}}{\sigma_x \sigma_y} \dots\dots\dots(2.2.6b)$$

Penjumlahan dari dua variabel random  $x$  dan  $y$  menjadi  $ax+by$  dengan  $a$  dan  $b$  konstan, diperoleh mean dan varian sebagai berikut:

$$\begin{aligned} \text{Mean dari } (ax+by) &= \mu_{ax+by} = E(ax+by) \\ &= aE(x)+bE(y) \\ &= a\mu_x+b\mu_y \dots\dots\dots(2.2.7) \end{aligned}$$

$$\begin{aligned} \text{Varian dari } (ax+by) &= \sigma_{ax+by}^2 = E(ax+by-\mu_{ax+by})^2 \\ &= E[a(x-\mu_x)+b(y-\mu_y)]^2 \\ &= E[a^2(x-\mu_x)^2+2ab(x-\mu_x)(y-\mu_y) \\ &\quad +b^2(y-\mu_y)^2] \end{aligned}$$

$$= a^2 E(x - \mu_x)^2 + 2ab E(x - \mu_x)(y - \mu_y) + b^2 E(y - \mu_y)^2]$$

$$= a^2 \text{Var}(x) + 2ab \text{Kov}(x, y) + b^2 \text{Var}(y) \dots\dots\dots(2.2.8)$$

Apabila x dan y independen, maka kovarian (x,y) = 0 atau korelasi  $\rho_{xy} = 0$ . Sehingga persamaan (2.2.8) menjadi

$$\text{Var}(ax+by) = a^2 \text{Var}(x) + b^2 \text{Var}(y) \dots\dots\dots(2.2.10)$$

Varian dari jumlah atau selisih dari variabel random yang independen adalah jumlah dari variannya.

Mean dari kombinasi linier pada variabel random (persamaan (2.2.7)) adalah sama dengan kombinasi linier dari mean variabel random masing-masing dan varian dari kombinasi linier pada variabel random independen (persamaan (2.2.10)) adalah kombinasi linier dari varian dengan koefisien kwadrat.

Operasi ekspektasi dalam persamaan (2.2.1) sampai (2.2.5) adalah untuk populasi atau sampel tak berhingga. Operasi ekspektasi untuk sampel berhingga dengan N observasi/pengamatan, yaitu:  $x_1, x_2, \dots, x_N$ , dan  $y_1, y_2, \dots, y_N$ , digunakan rata-rata sampel sebagai berikut:

$$\bar{x} = \frac{1}{N} \sum x_i \dots\dots\dots(2.2.11)$$

$$\hat{\sigma}_x^2 = \frac{1}{N} \sum (x_i - \bar{x})^2 \dots\dots\dots(2.2.12)$$

$$\hat{\gamma}_{xy} = \frac{1}{N} \sum (x_i - \bar{x})(y_i - \bar{y}) \dots\dots\dots(2.2.13)$$

$$\hat{\rho}_{xy} = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2 \sum (y_i - \bar{y})^2}} \dots\dots\dots (2.2.14)$$

dimana  $i$  berjalan dari 1 sampai  $N$ .

Perlu untuk dikemukakan bahwa estimator mempunyai sifat bias dan tak bias. 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 mean dari  $\bar{x}$  adalah  $\mu_x$ . Dengan menggunakan persamaan (2.2.7) diperoleh:

$$\begin{aligned} E(\bar{x}) &= E\left(\frac{1}{N} \sum x_i\right) \\ &= E\left(\frac{1}{N} x_1 + \frac{1}{N} x_2 + \dots + \frac{1}{N} x_N\right) \\ &= \frac{1}{N} E(x_1) + \frac{1}{N} E(x_2) + \dots + \frac{1}{N} E(x_N) \\ &= \frac{\mu_x}{N} + \frac{\mu_x}{N} + \dots + \frac{\mu_x}{N} = \mu_x \dots\dots\dots (2.2.15) \end{aligned}$$

Jadi estimator  $\bar{x}$  adalah titik tengah dari  $\mu_x$ , yang merupakan estimasi parameter. Bagaimanapun, untuk pengambilan sampel, penghitungan rata-rata sampel tidak akan sama dengan  $\mu_x$  yang merupakan rata-rata populasi. Seberapa jauh penghitungan rata-rata akan menyimpang dari  $\mu_x$ , ditunjukkan dengan menggunakan varian dari  $\bar{x}$ . Persamaan (2.2.7) digunakan untuk menghitung mean dari  $\bar{x}$ , dan persamaan (2.2.8) digunakan untuk menghitung varian dari  $\bar{x}$ . Untuk pengamatan independen, persamaan (2.2.10) dapat digunakan untuk menghitung varian dari  $\bar{x}$ .

Untuk pengamatan independen  $x_1, x_2, \dots, x_N$ , Varian dari  $\bar{x}$  adalah:

$$\begin{aligned}
\text{Var}(\bar{x}) &= \text{Var}\left(\frac{1}{N}x_1 + \frac{1}{N}x_2 + \dots + \frac{1}{N}x_N\right) \\
&= \frac{1}{N^2} \text{Var}(x_1) + \frac{1}{N^2} \text{Var}(x_2) + \dots + \frac{1}{N^2} \text{Var}(x_N) \\
&= \frac{N \text{Var}(x)}{N^2} \\
&= \frac{1}{N} \text{Var}(x) \dots \dots \dots (2.2.16)
\end{aligned}$$

yaitu :

$$\sigma_x^2 = E(\bar{x} - E(\bar{x}))^2 = E(\bar{x} - \mu_x)^2 = \frac{1}{N} \sigma_x^2 \dots \dots (2.2.16a)$$

atau

$$\sigma_{\bar{x}} = \frac{1}{\sqrt{N}} \sigma_x \quad (2.2.16b)$$

persamaan (2.2.16a) dan (2.2.16b) memperlihatkan standar deviasi dari  $\bar{x}$  yang merupakan jarak antara estimator  $\bar{x}$  dan parameter  $\mu_x$ .

### 2.3 MEAN, VARIAN DARI $\hat{\beta}_1$ DAN $\hat{\beta}_0$

Dalam model regresi linier sederhana persamaan (2.1.1),  $\varepsilon_t$  mempunyai mean nol, ini dikarenakan  $\varepsilon_t$  independen pada  $t$  yang berbeda.

$$E(\varepsilon_t) = 0$$

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

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

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

$$= \sigma_{\varepsilon}^2$$

Parameter  $\beta_0$  dan  $\beta_1 \dot{x}_t$  adalah variabel deterministik (non random) dan oleh karena itu nilai ekspektasinya adalah dirinya sendiri. Variabel deterministik dapat dikatakan sebagai variabel random dengan mean yang sama dan variannya adalah nol, dan juga independen pada beberapa variabel random lainnya. Jadi untuk model (2.1.1) jika digunakan persamaan (2.2.7) diperoleh:

$$\begin{aligned} \text{Mean } (\dot{y}_t) &= E(y_t) = E(\beta_0 + \beta_1 \dot{x}_t + \varepsilon_t) \\ &= E(\beta_0 + \beta_1 \dot{x}_t) + E \varepsilon_t \\ &= E(\beta_0) + E(\beta_1 \dot{x}_t) + 0 \\ &= \beta_0 + \beta_1 \dot{x}_t \dots \dots \dots (2.3.1) \end{aligned}$$

dan dengan persamaan (2.2.10) :

$$\begin{aligned} \text{Var } (\dot{y}_t) &= \text{Var} (\beta_0 + \beta_1 \dot{x}_t + \varepsilon_t) \\ &= \text{Var} (\beta_0 + \beta_1 \dot{x}_t) + \text{Var} (\varepsilon_t) \\ &= 0 + E(\varepsilon_t) \\ &= \sigma_{\varepsilon}^2 \dots \dots \dots (2.3.2) \end{aligned}$$

atau

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

mengambil rata-rata persamaan (2.1.1) diperoleh:

$$\bar{y} = \beta_0 + \beta_1 \bar{x} + \bar{\varepsilon}$$

$$E \bar{y} = E \beta_0 + E \beta_1 \bar{x} + E \bar{\varepsilon}$$

$$= \beta_0 + \beta_1 \bar{x}$$

Dengan estimator  $\beta_1$  yang diberikan dalam persamaan (2.1.5) dapat dilihat bahwa :

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

Dari persamaan (2.1.5),  $y_t = (\hat{y}_t - \bar{y})$  adalah variabel random dan  $x_t$  adalah konstanta. Persamaan (2.2.7) dapat digunakan untuk menentukan Mean  $\hat{\beta}_1$  dalam persamaan (2.1.5) sebagai berikut:

$$\begin{aligned} \text{Mean dari } \hat{\beta}_1 &= E(\hat{\beta}_1) \\ &= E\left(\frac{\sum y_t x_t}{\sum x_t^2}\right) \\ &= \frac{1}{\sum x_t^2} E(y_1 x_1 + y_2 x_2 + \dots + y_N x_N) \\ &= \frac{1}{\sum x_t^2} (x_1 E y_1 + x_2 E y_2 + \dots + x_N E y_N) \\ &= \frac{1}{\sum x_t^2} (x_1 \beta_1 x_1 + x_2 \beta_1 x_2 + \dots + x_N \beta_1 x_N) \\ &= \beta_1 \dots \dots \dots (2.3.3) \end{aligned}$$

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

Variabel  $\hat{y}_t$  adalah independen, karena  $\varepsilon_t$  independen

dan oleh karena itu persamaan (2.2.10) dapat digunakan



untuk mendapatkan Varian  $\hat{\beta}_1$  sebagai berikut:

$$\begin{aligned} \text{Var}(\hat{\beta}_1) &= \text{Var} \left[ \left[ \frac{x_1}{\Sigma x_t^2} \right] \hat{y}_1 + \left[ \frac{x_2}{\Sigma x_t^2} \right] \hat{y}_2 + \dots + \left[ \frac{x_N}{\Sigma x_t^2} \right] \hat{y}_N \right] \\ &= \left[ \frac{x_1}{\Sigma x_t^2} \right] \text{Var}(\hat{y}_1) + \left[ \frac{x_2}{\Sigma x_t^2} \right] \text{Var}(\hat{y}_2) + \dots \\ &\quad + \left[ \frac{x_N}{\Sigma x_t^2} \right] \text{Var}(\hat{y}_N) \\ &= \frac{\Sigma x_t^2}{(\Sigma x_t^2)} \text{Var}(\hat{y}_1) \\ &= \frac{1}{\Sigma x_t^2} \text{Var}(\hat{y}_1) \\ &= \frac{\sigma^2}{\Sigma x_t^2} \dots \dots \dots (2.3.4) \end{aligned}$$

Untuk  $N \rightarrow \infty$ , maka  $\Sigma x_t^2 \rightarrow \infty$ , dan  $\text{Var}(\hat{\beta}_1) \rightarrow 0$ .  
 Dapat disimpulkan bahwa 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  $E\hat{\beta}_1 = \beta_1$ , dengan mengikuti persamaan (2.1.4) diperoleh :

$$E(\hat{\beta}_0) = \beta_0 \dots \dots \dots (2.3.5)$$

dan dengan persamaan (2.2.10), diperoleh varian dari  $\hat{\beta}_0$  sebagai berikut:

$$\begin{aligned} \text{Var}(\hat{\beta}_0) &= \text{Var} \bar{y} + \bar{x}^2 \text{Var}(\hat{\beta}_1) \\ &= \sigma^2 \left[ \frac{1}{N} + \frac{\bar{x}^2}{\Sigma x_t^2} \right] \dots \dots \dots (2.3.6) \end{aligned}$$

## 2.4 ANALISA VARIAN MODEL ARMA

Pembahasan analisa varian untuk model ARMA akan mengacu pada analisa varian model regresi.

### Model ARMA (1,0) / AR (1)

Hasil dari model regresi sederhana

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

sebenarnya tidak dapat dipakai untuk model AR(1) yang dibahas pada bab III dalam bentuk:

$$X_t = \phi_1 X_{t-1} + a_t \quad \dots \dots \dots (2.4.1)$$

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 (2.1.5) dapat digunakan untuk memperoleh estimator

$$\hat{\phi}_1 = \frac{\sum X_t X_{t-1}}{\sum X_{t-1}^2} \quad \dots \dots \dots (2.4.2)$$

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  $N \rightarrow \infty$ .

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.

Pada pembahasan dibelakang (bab III), disebutkan bahwa:

$$X_t = \sum_{j=0}^{\infty} \phi_1^j a_{t-j} \quad \dots\dots\dots(2.4.3)$$

$$\begin{aligned} \text{sehingga, Var}(X_t) &= \text{Var} \left[ \sum_{j=0}^{\infty} \phi_1^j a_{t-j} \right] \\ &= \sum_{j=0}^{\infty} \text{var} (\phi_1^j a_{t-j}) \\ &= \left[ \sum_{j=0}^{\infty} \phi_1^{2j} \right] \sigma_a^2 \\ &= \frac{\sigma_a^2}{1 - \phi_1^2} \quad \dots\dots\dots(2.4.4) \end{aligned}$$

$$N \text{ Var}(X_{t-1}) = N \text{ Var}(X_t) = N \sigma_a^2 / (1 - \phi_1^2)$$

$$\text{Var}(\hat{\phi}_1) \approx \frac{\sigma_a^2}{\sum X_{t-1}^2} \approx \frac{\sigma_a^2}{N \text{ Var}(X_t)} = \frac{(1 - \phi_1^2)}{N} \quad \dots\dots\dots(2.4.5)$$

dan

$$\begin{aligned} \text{Var}(\hat{\phi}_1) &\approx \frac{\sigma_a^2}{N \sigma_a^2} \quad \text{dimana } \phi_1 = 0 \\ &= \frac{1}{N} \quad \dots\dots\dots(2.4.6) \end{aligned}$$

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  $\rho_k \equiv 0$  :

$$\text{Var}(\hat{\rho}_k) \approx \frac{1}{N} \dots\dots\dots(2.4.7)$$

Model ARMA (2, 0) / AR (2)

Mengikuti penalaran yang sama pada model regresi berganda, untuk model AR (2) dengan bentuk :

$$X_t - \phi_1 X_{t-1} - \phi_2 X_{t-2} = a_t \dots\dots\dots(2.4.8)$$

Estimasi model ini adalah :

$$\begin{bmatrix} \hat{\phi}_1 \\ \hat{\phi}_2 \end{bmatrix} = (X'X)^{-1} X'Y \dots\dots\dots(2.4.9)$$

dimana

$$X = \begin{bmatrix} X_2 & X_1 \\ X_3 & X_2 \\ \vdots & \vdots \\ X_{N-1} & X_{N-2} \end{bmatrix}$$

$$Y = X_t = \begin{bmatrix} X_3 \\ X_4 \\ \vdots \\ X_N \end{bmatrix}$$

Varian dari parameter ini adalah :

$$\text{Var} \begin{bmatrix} \hat{\phi}_1 \\ \hat{\phi}_2 \end{bmatrix} = (X'X)^{-1} \sigma_a^2 = \begin{bmatrix} \sum X_t^2 & \sum X_t X_{t-1} \\ \sum X_t X_{t-1} & \sum X_t^2 \end{bmatrix}^{-1} \sigma_a^2 \dots\dots\dots(2.4.10)$$

Untuk jumlah N pengamatan yang besar, nilai-nilai dari  $\sum X_t^2$  dan  $\sum X_t X_{t-1}$  sama dengan nilai ekspektasinya :

$N \text{ Var} (X_t) = N \gamma_0$  dan  $N \text{ Kov} (X_t X_{t-1}) = N \gamma_1$

$$\gamma_0 = \frac{(1-\phi_2)\sigma_a^2}{(1+\phi_2)[(1-\phi_2)^2-\phi_1^2]} \dots\dots\dots(2.4.11)$$

$$\gamma_1 = \frac{\phi_1}{(1-\phi_2)} \gamma_0 \dots\dots\dots(2.4.12)$$

dimana pengertian  $\gamma_0$  dan  $\gamma_1$  dijelaskan pada bab III.

oleh karena itu :

$$\begin{aligned} \text{Var} \begin{bmatrix} \hat{\phi}_1 \\ \hat{\phi}_2 \end{bmatrix} &= \begin{bmatrix} N\gamma_0 & N\gamma_1 \\ N\gamma_1 & N\gamma_0 \end{bmatrix}^{-1} \sigma_a^2 \\ &= \frac{\sigma_a^2}{N\gamma_0} \begin{bmatrix} 1 & \frac{\phi_1}{(1-\phi_2)} \\ \frac{\phi_1}{(1-\phi_2)} & 1 \end{bmatrix}^{-1} \\ &= \frac{(1+\phi_2)[(1-\phi_2)^2-\phi_1^2]}{N(1-\phi_2)} \frac{(1-\phi_2)}{[(1-\phi_2)^2-\phi_1^2]} \\ & \quad \begin{bmatrix} 1 & -\frac{\phi_1}{(1-\phi_2)} \\ -\frac{\phi_1}{(1-\phi_2)} & 1 \end{bmatrix} \\ &= \frac{1}{N} \begin{bmatrix} 1-\phi_2^2 & -\phi_1(1+\phi_2) \\ -\phi_1(1+\phi_2) & 1-\phi_2^2 \end{bmatrix} \dots\dots\dots(2.4.13) \end{aligned}$$

#### Model ARMA (n, n-1)

Varian model ARMA dapat diperoleh dengan jalan yang sama seperti model AR (2). Ditentukan lebih dahulu nilai-nilai dari  $a_t$  dengan cara rekursive seperti yang dilakukan pada bab IV dan menganggap nilai-nilai dari  $a_t$

adalah sebagai data seperti  $X_t$ .

Contoh untuk model ARMA (2,1):

$$X_t - \phi_1 X_{t-1} - \phi_2 X_{t-2} = a_t - \theta_1 a_{t-1} \dots \dots \dots (2.4.14)$$

Apabila nilai estimasi telah ditentukan dengan prosedur estimasi (pada bab IV), maka  $a_t$  dapat ditentukan sebagai berikut:

$$a_t = X_t - \hat{\phi}_1 X_{t-1} - \hat{\phi}_2 X_{t-2} + \hat{\theta}_1 a_{t-1} \dots \dots \dots (2.4.15)$$

dimana  $\hat{\phi}_1, \hat{\phi}_2, \hat{\theta}_1$  adalah ekpektasi dari  $\phi_1, \phi_2, \theta_1$ .

Menulis kembali model ARMA (2,1) dalam bentuk:

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} - \theta_1 a_{t-1} + a_t \dots \dots \dots (2.4.16)$$

Bentuk persamaan (2.4.16) sama dengan model AR (3) :

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \phi_3 X_{t-3} + a_t \dots \dots \dots (2.4.17)$$

dengan :  $\phi_3 = -\theta_1$  ;  $X_{t-3} = a_{t-1}$

dengan cara yang sama seperti pada AR (2) , dapat ditentukan Varian dari  $\phi_1, \phi_2$  dan  $\theta_1$ .

## 2.5 DISTRIBUSI NORMAL DAN INTERVAL KONVIDENSI

Jika X adalah variabel random berdistribusi normal dengan mean  $\mu_x$  dan varian  $\sigma_x^2$  , ditulis secara singkat :

$$X \sim N(\mu_x, \sigma_x^2)$$

Probabilitas Kepadatan dari x pada X diberikan oleh:

$$f(x) = \frac{1}{\sqrt{2\pi} \sigma_x} \text{Exp.} - \left[ \frac{(x - \mu_x)^2}{2\sigma_x^2} \right] \dots \dots (2.5.1)$$

$$-\infty < x < \infty$$

$$\int_{-\infty}^{\infty} f(x) dx = 1 \quad \dots\dots(2.5.2)$$

Kemungkinan  $X$  akan mempunyai nilai antara  $a$  dan  $b$ , dinyatakan dengan :

$$P(a \leq X \leq b) = \int_a^b f(x) dx \quad \dots\dots\dots(2.5.3)$$

Kombinasi linier dari variabel berdistribusi normal adalah berdistribusi normal pula.

$$X \sim N(\mu_x, \sigma_x^2); Y \sim N(\mu_y, \sigma_y^2)$$

maka

$$aX + bY \sim N[(a\mu_x + b\mu_y), (a^2\sigma_x^2 + 2ab\sigma_{xy} + b^2\sigma_y^2)] \quad \dots\dots\dots(2.5.4)$$

jika  $X$  dan  $Y$  independen maka:

$$\text{Kov.}(X, Y) = \gamma_{xy} = \sigma_{xy} = 0$$

$$aX + bY \sim N[(a\mu_x + b\mu_y), (a^2\sigma_x^2 + b^2\sigma_y^2)] \quad \dots\dots\dots(2.5.5)$$

Mentransformasikan variabel random  $X$  kedalam variabel random  $Z$  sebagai berikut:

$$Z = \frac{X - \mu_x}{\sigma_x} = \frac{\text{Variabel} - \text{Mean}}{\text{Standar Deviasi}}$$

$$Z = \frac{1}{\sigma_x} X - \frac{\mu_x}{\sigma_x} \quad \dots\dots\dots(2.5.6)$$

dengan mempergunakan persamaan (2.5.5) dan mengambil harga  $a = 1/\sigma_x$  dan  $b = -1$  diperoleh:

$$\mu_z = E(Z) = \frac{\mu_x}{\sigma_x} - \frac{\mu_x}{\sigma_x} = 0$$

$$\sigma_z^2 = E(Z - \mu_z)^2 = E(Z^2)$$

$$= \frac{\sigma_x^2}{\sigma_x^2} + (-1)^2 \times 0 = 1$$

maka  $Z \sim N(0,1)$

Jadi  $Z$  berdistribusi normal standar dengan mean nol dan varian satu. Probabilitas kumulatif  $\Phi(z) = P(-\infty < Z \leq z)$  untuk semua harga  $z$  diberikan dalam Tabel pada Lampiran. Nilai-nilai yang banyak digunakan dalam praktek adalah:

$$\Phi(1,65) = 0,95053$$

$$\Phi(1,96) = 0,975$$

$$\Phi(2,58) = 0,99506$$

Distribusi Normal Standar adalah simetrik, sehingga untuk:

$$\begin{aligned} P(-1,65 \leq Z \leq 1,65) &= \Phi(1,65) - \Phi(-1,65) \\ &= \Phi(1,65) - [1 - \Phi(1,65)] \\ &\approx 0,90 = 90\% \end{aligned}$$

dengan cara yang sama:

$$P(-1,96 \leq Z \leq 1,96) = 0,95 = 95\%$$

$$P(-2,58 \leq Z \leq 2,58) = 0,99 = 99\%$$

Dengan kata lain, kepercayaan :90% , 95% , dan 99% batas probabilitas untuk  $Z$  berturut-turut adalah :  $\pm 1,65$  ,  $\pm 1,96$  , dan  $\pm 2,58$ .

Dari persamaan (2.5.6) diperoleh:

$$X = \mu_x + Z\sigma_x \quad \dots\dots\dots(2.5.7)$$

$$= \text{Mean} + Z \times \text{Standar Deviasi}$$

Dengan kepercayaan 90% , 95% , dan 99% , batas probabilitas untuk  $X$  adalah :

$$\mu_x \pm 1,65 \sigma_x , \mu_x \pm 1,96 \sigma_x , \text{ dan } \mu_x \pm 2,58 \sigma_x$$

pada umumnya kepercayaan  $(p \times 100\%)$  batas probabilitasnya



adalah :

$$\mu_x \pm z_{p+1/2} \sigma_x \dots\dots\dots(2.5.8)$$

dimana

$$\Phi(z_{p+1/2}) = p + \frac{1-p}{2} = \frac{p+1}{2} \dots\dots(2.5.9)$$

Jika diketahui Mean  $\mu_x$  dan Varian  $\sigma_x$  dari distribusi variabel normal, maka batas probabilitas dapat ditentukan dari persamaan (2.5.8). Dengan menggunakan Tabel pada Lampiran dapat ditentukan  $z_{(p+1)/2}$  yang didefinisikan oleh persamaan (2.5.9).

Contoh:

Batas probabilitas 80% dapat ditentukan dengan Tabel sebagai berikut:

$$\Phi(z_{p+1/2}) = \frac{0,8 + 1}{2} = 0,9$$

diperoleh  $z_{p+1/2} = 1,28$  sehingga batas probabilitasnya adalah:

$$\mu_x \pm 1,28 \sigma_x$$

Sekarang jelas bahwa (lihat persamaan (2.3.1) dan (2.3.2)) model Regresi sederhana:

$$\hat{y}_t = \beta_0 + \beta_1 \hat{x}_t + \varepsilon_t, \quad \varepsilon_t \sim \text{NID}(0, \sigma_\varepsilon^2)$$

ekivalen dengan:

$$\hat{y}_t \sim \text{NID}(\beta_0 + \beta_1 \hat{x}_t, \sigma_\varepsilon^2) \dots\dots\dots(2.5.10)$$

lebih singkatnya:

$$y_t = \beta_1 x_t + \varepsilon_t, \quad \varepsilon_t \sim \text{NID}(0, \sigma_\varepsilon^2)$$

ekivalen dengan:

$$y_t \sim \text{NID}(\beta_1 x_t, \sigma_\varepsilon^2) \dots\dots\dots(2.5.11)$$

Jika diasumsikan bahwa parameter  $\beta_0, \beta_1$ , dan  $\sigma_\varepsilon^2$  diketahui,

prediksi untuk kedua kasus adalah  $\beta_0 + \beta_1 \hat{x}_t$  atau  $\beta_1 x_t$  dan batas probabilitas 95% pada peramalan diberikan dengan:

$$\beta_0 + \beta_1 \hat{x}_t \pm 1,96\sigma_e \quad \text{dan} \quad \beta_1 x_t \pm 1,96\sigma_e$$

Bagaimanapun, dalam praktek baik mean maupun varian diketahui. Andaikata yang diketahui  $\sigma_e^2$ , maka  $\bar{x}$  adalah estimator terbaik untuk  $\mu_x$ . Sekarang dapat dibuat pernyataan probabilitas mengenai seberapa jauh  $\bar{x}$  dari  $\mu_x$ . Karena  $\bar{x}$  adalah kombinasi linier dari distribusi normal variabel independen:  $x_1, x_2, \dots, x_N$ , mengikuti persamaan (2.2.15), (2.2.16a) dan (2.5.5) bahwa

$$\bar{x} \sim N(\mu_x, \sigma_x^2 / N) \dots \dots \dots (2.5.12)$$

Jika mengambil kepercayaan 95% didapatkan:

$$P\left(\mu_x - \frac{1,96\sigma_x}{\sqrt{N}} \leq \bar{x} \leq \mu_x + \frac{1,96\sigma_x}{\sqrt{N}}\right) = 0,95 = 95\%$$

yaitu:

$$P\left(\bar{x} - \frac{1,96\sigma_x}{\sqrt{N}} \leq \mu_x \leq \bar{x} + \frac{1,96\sigma_x}{\sqrt{N}}\right) = 0,95 = 95\%$$

Jadi Interval Konfidensi untuk mean  $\mu_x$  adalah:

$$\bar{x} \pm 1,96 \sigma_x / \sqrt{N}$$

dan dengan carayang sama, Interval Konfidensi 90% dan 99% adalah:

$$\bar{x} \pm 1,65 \sigma_x / \sqrt{N} \quad \text{dan} \quad \bar{x} \pm 2,58 \sigma_x / \sqrt{N}$$

Dengan cara yang sama estimator kwadrat terkecil  $\hat{\beta}_0$  dan  $\hat{\beta}_1$  adalah kombinasi linier pada variabel normal independen:  $\hat{y}_1, \hat{y}_2, \dots, \hat{y}_N$  dan oleh karena itu, jika digunakan persamaan (2.1.4) sampai (2.3.6) didapatkan:

$$\hat{\beta}_0 \sim N \left\{ \beta_0, \sigma_\varepsilon^2 \left( \frac{1}{N} + \frac{\bar{X}^2}{\sum X_t^2} \right) \right\} \dots\dots\dots(2.5.13)$$

$$\hat{\beta}_1 \sim N \left\{ \beta_1, \frac{\sigma_\varepsilon^2}{\sum X_t^2} \right\} \dots\dots\dots(2.5.14)$$

oleh karena itu, Interval Konfidensi 95% untuk  $\beta_0$  dan  $\beta_1$  berturut-turut adalah:

$$\hat{\beta}_0 \pm 1,96 \sigma_\varepsilon \sqrt{\frac{1}{N} + \frac{\bar{X}^2}{\sum X_t^2}}$$

$$\hat{\beta}_1 \pm 1,96 \frac{\sigma_\varepsilon}{\sqrt{\sum X_t^2}}$$

Penggunaan metode yang demikian, dapat ditunjukkan bahwa untuk  $N \rightarrow \infty$ ,  $\hat{\phi}_1$  atau  $\hat{\rho}_k$  biasanya berdistribusi normal dengan mean  $\phi_1$  atau  $\rho_k$ . Oleh karena itu, untuk  $N$  berhingga aproksimasi interval konfidensi 95% dapat diberikan dengan persamaan (2.4.5) untuk syarat kecukupan model AR (1).

$$\hat{\phi}_1 \pm \frac{1,96 \sigma_\varepsilon}{\sqrt{\sum X_t^2}}$$

atau:

$$\hat{\phi}_1 \pm 1,96 \sqrt{(1-\phi_1^2)/N}$$

dan ketika  $\phi_1=0$  atau  $\rho_k=0$ , dengan persamaan (2.4.6) dan (2.3.9) didapatkan:

$$\pm 1,96 / \sqrt{N}$$

## 2.6 DISTRIBUSI CHI-KWADRAT

Distribusi Chi-Kwadrat ( $X^2$ ) didefinisikan sebagai:

Jumlah kwadrat pada variabel normal standar Independen.

Jika  $z_1, z_2, \dots, z_v$  adalah variabel normal standar independen, maka  $X_v^2$  dinyatakan dalam jumlah kwadrat sebagai berikut:

$$X_v^2 = z_1^2 + z_2^2 + \dots + z_v^2, \quad \dots\dots\dots(2.6.1)$$

$$z_i \sim \text{NID}(0,1)$$

dimana  $z$  didefinisikan oleh persamaan (2.2.6)

$$X_v^2 = \frac{(x_1 - \mu_1)^2}{\sigma_1^2} + \frac{(x_2 - \mu_2)^2}{\sigma_2^2} + \dots + \frac{(x_v - \mu_v)^2}{\sigma_v^2} \quad \dots\dots\dots(2.6.2)$$

$$x_i \sim \text{NID}(\mu_i, \sigma_i^2)$$

Mean dari  $X_v^2$  adalah:

$$E(X_v^2) = E(z_1^2) + E(z_2^2) + \dots + E(z_v^2)$$

$$= v \quad \dots\dots\dots(2.6.3)$$

Bilangan bulat  $v$  merupakan jumlah dari variabel normal standar independen untuk  $X_v^2$ , sehingga  $v$  merupakan derajat kebebasan dari  $X_v^2$ . Jika diambil  $\sigma_i^2 = \sigma^2$  dalam (2.6.2), mengikuti jumlah kwadrat dari variabel normal independen dengan mean nol dan varian  $\sigma^2$  adalah berdistribusi  $\sigma^2 X_v^2$ , yaitu:

$$\sum_{i=1}^v y_i^2 \sim \sigma^2 X_v^2, \quad y_i \sim (0, \sigma^2) \quad \dots\dots\dots(2.6.4)$$

$$E \sum_{i=1}^v y_i^2 = E(\sigma^2 X_v^2) = v\sigma^2 \quad \dots\dots\dots(2.6.5)$$

Fungsi probabilitas kepadatan dari  $X_v^2$  dapat dibuat dari persamaan (2.5.1) menggunakan definisi (2.6.1).

Distribusi Chi-kwadrat dibutuhkan ketika varian tak

estimator  $\hat{\sigma}_x^2$  yang dinyatakan dengan (2.2.12), dengan mengganti ekspektasi dengan rata-rata akan menjadi bias, dan dapat diubah untuk menjadi takbias.

$$\hat{\sigma}_x^2 = \frac{1}{N} \sum (x_i - \bar{x})^2$$

$$N\hat{\sigma}_x^2 = \sum (x_i - \bar{x})^2$$

Jadi  $N\hat{\sigma}_x^2$  adalah jumlah kwadrat dari variabel normal dengan mean nol,  $x_1 - \bar{x}$ ,  $x_2 - \bar{x}$ , ...,  $x_N - \bar{x}$ ; yang mana hanya  $N - 1$  yang independen, sebab:

$$\sum (x_i - \bar{x}) = \sum x_i - N\bar{x} = 0$$

oleh karena itu dengan persamaan (2.6.4) diperoleh:

$$N\hat{\sigma}_x^2 \sim \sigma_x^2 X_{N-1}^2 \quad \text{atau} \quad \frac{N\hat{\sigma}_x^2}{\sigma_x^2} \sim X_{N-1}^2 \quad \dots \dots (2.6.6)$$

dimana  $v = N - 1$

yaitu:

$$\text{Derajat kebebasan} = \text{pengamatan independen} - \text{estimator parameter} \dots \dots (2.6.7)$$

Dengan kata lain, dikatakan kehilangan satu derajat kebebasan yang disebabkan digunakannya satu estimator  $\bar{x}$  yang menggantikan parameter  $\mu_x$ . Catatan bahwa dengan persamaan (2.6.4) didapatkan:

$$\sum (x_i - \mu_x)^2 \sim \sigma_x^2 X_N^2$$

yang mana mempunyai  $N$  derajat kebebasan, yang disebabkan karena  $\mu_x$  diketahui, dengan persamaan (2.6.5) :

$$E(N\hat{\sigma}_x^2) = E \sum (x_i - \bar{x})^2 = (N - 1)\sigma_x^2 \quad \dots \dots (2.6.8)$$

$$E(\hat{\sigma}_x^2) = \frac{(N - 1)\sigma_x^2}{N} \quad \dots \dots (2.6.8a)$$

Terlihat bahwa estimasi dari  $\hat{\sigma}_x^2$  adalah bias. Hal ini dapat diperbaiki dengan estimator baru:

$$S^2 = \frac{N}{N-1} \hat{\sigma}_x^2 = \frac{1}{N-1} \sum (x_i - \bar{x})^2 \dots\dots\dots(2.6.9)$$

dimana:  $E(S^2) = \sigma_x^2$

yang merupakan estimator tak-bias dari  $\sigma_x^2$ . Kemudian:

$$\sum (x_i - \bar{x})^2 = (N-1)S^2 \sim \sigma_x^2 X_{N-1}^2$$

$$\frac{(N-1)S^2}{\sigma_x^2} \sim X_{N-1}^2 \dots\dots\dots(2.6.10)$$

Dengan cara yang sama, dapat digunakan untuk varian  $\sigma_e^2$  dari  $\dot{y}_t$  dalam model Regresi sederhana tidak diketahui. Jadi seperti pada  $\hat{\sigma}_x^2$ , estimator kwadrat terkecil  $\hat{\sigma}_e^2$  yang dinyatakan sebagai:

$$\hat{\sigma}_e^2 = \frac{1}{N} \sum (y_t - \hat{\beta}_1 x_t)^2 \dots\dots\dots(2.6.11)$$

adalah bias. Persamaan (2.6.11) dinyatakan dalam variabel data yang sesungguhnya dan dengan menggunakan persamaan (2.1.4) menjadi:

$$\begin{aligned} \hat{\sigma}_e^2 &= \frac{1}{N} \sum (y_t - \hat{\beta}_1 x_t)^2 \\ &= \frac{1}{N} \sum (\dot{y}_t - \bar{y} - \hat{\beta}_1 \dot{x}_t + \hat{\beta}_1 \bar{x})^2 \\ &= \frac{1}{N} \sum (\dot{y}_t - \hat{\beta}_0 - \hat{\beta}_1 \dot{x}_t)^2 \dots\dots\dots(2.6.12) \end{aligned}$$

Jadi  $\hat{\sigma}_e^2$  adalah jumlah kwadrat variabel random berdistribusi Normal dengan mean nol dari N pengamatan independen dengan dua parameter  $\beta_0$  dan  $\beta_1$  yang diganti dengan estimasinya. Oleh karena itu dengan persamaan

(2.6.7) diperoleh derajat kebebasan  $N - 2$ .

$$N\hat{\sigma}_{\varepsilon}^2 \sim \sigma_{\varepsilon}^2 X_{N-2}^2 \dots\dots\dots(2.6.13)$$

maka dengan persamaan (2.6.5) diperoleh:

$$E(N\hat{\sigma}_{\varepsilon}^2) = E \sum (\dot{y}_t - \hat{\beta}_0 - \hat{\beta}_1 \dot{x}_t)^2 = (N - 2)\sigma_{\varepsilon}^2$$

atau

$$E(\hat{\sigma}_{\varepsilon}^2) = \frac{(N - 2)\sigma_{\varepsilon}^2}{N} \dots\dots\dots(2.6.14)$$

ini menunjukkan bahwa estimatornya adalah Bias. Estimator tak-Bias akan menjadi:

$$\begin{aligned} S_R^2 &= \frac{N}{N - 2} \hat{\sigma}_{\varepsilon}^2 \\ &= \frac{1}{N - 2} \sum (\dot{y}_t - \hat{\beta}_0 - \hat{\beta}_1 \dot{x}_t)^2 \dots\dots\dots(2.6.15) \end{aligned}$$

dan

$$E(S_R^2) = \sigma_{\varepsilon}^2$$

dengan :

$$\sum (\dot{y}_t - \hat{\beta}_0 - \hat{\beta}_1 \dot{x}_t)^2 = (N - 2)S_R^2 \sim \sigma_{\varepsilon}^2 X_{N-2}^2$$

$$\frac{(N - 2)S_R^2}{\sigma_{\varepsilon}^2} \sim X_{N-2}^2 \dots\dots\dots(2.6.16)$$

Jadi  $S_R^2$  akan digunakan untuk mengganti  $\sigma_{\varepsilon}^2$ , jika diinginkan estimasi tak-Bias.