

## BAB II

### KONSEP DASAR

#### 2.1 Regresi Linier

Regresi Linier adalah salah satu cara yang digunakan dalam analisis data statistik. Model regresi menggambarkan hubungan antara variabel bebas ( $x$ ) dengan variabel terikat/respon ( $Y$ ). Model tersebut dapat dituliskan sebagai berikut:

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + \varepsilon_i, \quad i = 1, 2, 3, \dots, n. \quad (2.1.1)$$

Model regresi linier dalam persamaan (2.1.1) disebut model regresi linier berganda dengan  $k$  variabel bebas yaitu  $X_1, X_2, \dots, X_k$ . Parameter  $\beta_j, j=0, 1, \dots, k$  disebut koefisien regresi. Model ini menggunakan asumsi  $\varepsilon_i \sim N(0, \sigma^2)$ .

##### 2.1.1 Metode Kuadrat Terkecil

Dalam model regresi linier, untuk taksiran parameternya digunakan metode kuadrat terkecil. Diberikan fungsi kuadrat terkecil sebagai berikut:

$$\begin{aligned} L &= \sum_{i=1}^n \varepsilon_i^2 \\ &= \sum_{i=1}^n \left[ y_i - \beta_0 - \sum_{j=1}^k \beta_j X_{ji} \right]^2 \end{aligned}$$

Fungsi L tersebut diminimumkan terhadap  $\beta_0, \beta_1, \dots, \beta_k$  Estimator kuadrat terkecil

$\beta_0, \beta_1, \dots, \beta_k$  harus memenuhi:

$$\frac{\partial L}{\partial \beta_0} \Big|_{\beta_0, \beta_1, \dots, \beta_k} = -2 \sum_{i=1}^n (y_i - \hat{\beta}_0 - \sum \hat{\beta}_j x_{ij}) = 0 \text{ dan}$$

$$\frac{\partial L}{\partial \beta_j} \Big|_{\beta_0, \beta_1, \dots, \beta_k} = -2 \sum_{i=1}^n (y_i - \hat{\beta}_0 - \sum \hat{\beta}_j x_{ij}) x_{ij} = 0 \text{ dengan } i=1,2,3,\dots,n; j=1,2,3,\dots,k$$

Sehingga diperoleh persamaan - persamaan normal kuadrat terkecil sebagai berikut:

$$\begin{aligned} n\hat{\beta}_0 + \hat{\beta}_1 \sum_{i=1}^n x_{i1} + \hat{\beta}_2 \sum_{i=1}^n x_{i2} + \dots + \hat{\beta}_k \sum_{i=1}^n x_{ik} &= \sum_{i=1}^n y_i \\ \hat{\beta}_0 \sum_{i=1}^n x_{i1} + \hat{\beta}_1 \sum_{i=1}^n x_{i1}^2 + \hat{\beta}_2 \sum_{i=1}^n x_{i1}x_{i2} + \dots + \hat{\beta}_k \sum_{i=1}^n x_{i1}x_{ik} &= \sum_{i=1}^n x_{i1}y_i \\ \vdots & \\ \hat{\beta}_0 \sum_{i=1}^n x_{ik} + \hat{\beta}_1 \sum_{i=1}^n x_{ik}x_{i1} + \hat{\beta}_2 \sum_{i=1}^n x_{ik}x_{i2} + \dots + \hat{\beta}_k \sum_{i=1}^n x_{ik}^2 &= \sum_{i=1}^n x_{ik}y_i \end{aligned} \quad (2.1.1.1)$$

Penyelesaian model ini akan lebih sederhana dengan menggunakan bentuk matriks. Jika didefinisikan dalam bentuk matrik dan vektor maka persamaan (2.1.1) dapat ditulis sebagai berikut:

$$y = X\beta + \varepsilon \quad (2.1.1.2)$$

dengan,

$$y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} \quad X = \begin{bmatrix} 1 & x_{11} & x_{12} & \dots & x_{1k} \\ 1 & x_{21} & x_{22} & \dots & x_{2k} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & x_{n2} & \dots & x_{nk} \end{bmatrix} \quad \beta = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_k \end{bmatrix} \quad \varepsilon = \begin{bmatrix} \varepsilon_0 \\ \varepsilon_1 \\ \vdots \\ \varepsilon_k \end{bmatrix}$$

y adalah vektor pengamatan pada variabel tak bebas berukuran  $n \times 1$

$X$  adalah matriks variabel bebas berukuran  $n \times (k+1)$

$\beta$  adalah vektor koefisien regresi berukuran  $(k+1) \times 1$

$\varepsilon$  adalah vektor random error berukuran  $n \times 1$

Untuk mendapatkan vektor penaksir kuadrat terkecil  $\hat{\beta}$  dilakukan dengan cara meminimumkan jumlah kuadrat galatnya, yaitu:

$$\begin{aligned} L &= \sum_{i=1}^n \varepsilon_i^2 = \varepsilon' \varepsilon \\ &= (y - X\beta)'(y - X\beta) \\ &= y'y - \beta'X'y - y'X\beta + \beta'X'X\beta \\ &= y'y - 2\beta'X'y + \beta'X'X\beta \end{aligned}$$

Karena  $\beta'X'y$  adalah sebuah vektor matriks skalar ( $1 \times 1$ ), dan  $(\beta'X'y) = y'X\beta$  adalah skalar yang sama, maka penaksir kuadrat terkecil itu harus memenuhi:

$$\begin{aligned} \frac{\partial L}{\partial \beta} \Big|_{\hat{\beta}} &= 0 \\ -2X'y + 2X'X\hat{\beta} &= 0 \end{aligned}$$

penyederhanaannya menjadi:

$$X'X\hat{\beta} = X'y \quad (2.1.1.3)$$

Jika  $(X'X)^{-1}$  ada maka diperoleh penyelesaian untuk  $\hat{\beta}$  yaitu:

$$\hat{\beta} = (X'X)^{-1} X'y \quad (2.1.1.4)$$

Jaminan bahwa nilai dari LSE adalah minimum yaitu bahwa turunan ke dua dari L terhadap  $\beta$  harus bernilai positif. Diberikan:

$$\frac{\partial^2 L}{\partial \beta} = 2X'X$$

dengan demikian nilai L akan minimum apabila nilai  $2X'X$  lebih besar dari 0. Karena matrix  $X'X$  adalah definit positif dengan semua unsur diagonalnya berbentuk kuadrat, maka turunan kedua dari L terhadap  $\beta$  bernilai positif.

Estimasi  $\hat{\beta}$  dapat dinyatakan dengan persamaan:

$$\begin{aligned} E(\hat{\beta}) &= E[(X'X)^{-1} X'y] = (X'X)^{-1} X'X\beta \\ &= \beta \end{aligned} \quad (2.1.1.5)$$

Matriks variansi dari persamaan (2.1.1.4) adalah:

$$\begin{aligned} \text{var}(\hat{\beta}) &= E[(\hat{\beta} - E(\hat{\beta}))(\hat{\beta} - E(\hat{\beta}))'] \\ &= E(X'X)^{-1} X[y - E(y)][y' - E(y)'] X(X'X)^{-1} \\ &= (X'X)^{-1} X E(\varepsilon\varepsilon') X(X'X)^{-1} \\ &= (X'X)^{-1} \sigma^2 \end{aligned} \quad (2.1.1.6)$$

Persamaan (2.1.1.6) merupakan varian terkecil dari semua estimator linier tak bias, hal ini dijamin dengan teorema Gauss-Markov.

Teorema Gauss-Markov

Estimator kuadrat terkecil  $\hat{\beta} = (X'X)^{-1}X'y$  mempunyai variansi terkecil dalam himpunan semua estimator linier tak bias.

Bukti:

Misal  $\hat{\beta}^*$  estimator linier lain dari  $\beta$  yang juga tak bias. Karena  $\hat{\beta}^*$  estimator linier maka dapat dimisalkan bentuknya sebagai

$$\hat{\beta}^* = [(X'X)^{-1}X' + U]Y$$

untuk suatu matrix U yang merupakan fungsi dari x, sehingga nilai estimasi untuk  $\hat{\beta}^*$  dapat diberikan:

$$\begin{aligned} E(\hat{\beta}^*) &= [(X'X)^{-1}X' + U]E(Y) \\ &= [(X'X)^{-1}X' + U]X\beta \\ &= \beta + UX\beta \\ &= (I + UX)\beta \end{aligned}$$

Agar  $\hat{\beta}^*$  estimasi tak bias dari  $\beta$  maka  $UX = 0$ , sehingga:

$$\begin{aligned} \text{Var}(\hat{\beta}^*) &= [(X'X)^{-1}X' + U]\text{Var}(Y)[U' + X(X'X)^{-1}] \\ &= \sigma^2 [(X'X)^{-1}X'U' + UU' + (X'X)^{-1} + UX(X'X)^{-1}] \end{aligned}$$

karena  $UX = X'U' = 0$  maka

$$\text{var}(\hat{\beta}^*) = \sigma^2 [(X'X)^{-1} + UU']$$

Matrix  $UU'$  adalah definit positif, karena semua unsur diagonalnya berbentuk kuadrat. Jadi terbukti bahwa variansi dari setiap unsur dari vektor  $\hat{\beta}^*$  selalu lebih besar, atau paling kecil sama dengan variansi unsur  $\hat{\beta}$  yang sesuai.

### 2.1.2 Estimasi $E(y)$

Estimator  $\hat{\beta}$  dapat digunakan untuk mengestimasi  $E(y)$ , dengan persamaan:

$$E(\hat{y}) = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \hat{\beta}_2 x_2 + \dots + \hat{\beta}_k x_k \quad (2.1.2.1)$$

berkaitan dengan  $E(y) = X\beta$ , diperoleh:

$$E(\hat{y}) = X\hat{\beta} \quad (2.1.2.2)$$

Variansi dari estimator di atas adalah:

$$\text{var}[E(\hat{y})] = X(X'X)^{-1}X'\sigma^2 \quad (2.1.2.3)$$

Pandang  $y_f$  sebagai nilai observasi yang akan datang, yang berkaitan dengan nilai  $x$ , yaitu  $x_f$ . Maka dengan model  $y_f = x_f'\beta + e_f$  dengan  $e_f$  adalah error. Oleh karena itu prediksi terbaik dari  $y_f$  yaitu  $\tilde{y}_f$ , adalah  $\tilde{y}_f = x_f'\hat{\beta}$ . Dengan demikian  $x_f'\hat{\beta}$  dapat digunakan sebagai prediksi dari observasi yang akan datang dan dapat digunakan sebagai suatu estimator dari nilai harapan  $E(y_f)$  berkaitan dengan  $x_f$ . Kemudian dapat diturunkan suatu variansi dari simpangan  $y_f$  dan  $\tilde{y}_f$  sebagai berikut:

$$y_f - \tilde{y}_f = y_f - x_f'\hat{\beta} = x_f'(\beta - \hat{\beta}) + e_f \quad (2.1.2.4)$$

Karena  $\hat{\beta}$  dan  $e_f$  independen maka  $\text{cov}(\hat{\beta}, e_f) = 0$ . Hal ini berakibat:

$$\text{var}(y_f - \tilde{y}_f) = \mathbf{x}'_f \text{var}(\beta - \hat{\beta}) \mathbf{x}_f + \text{var}(e_f) = \left[ \mathbf{x}'_f (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_f + 1 \right] \sigma^2 \quad (2.1.2.5)$$

Variansi dari  $E(\hat{y}) = \mathbf{X}\hat{\beta}$  adalah  $\left[ \mathbf{x}'_f (\mathbf{X}'\mathbf{X})^{-1} \mathbf{x}_f \right] \sigma^2$ . Dan  $\text{Var}(y_f) = \sigma^2$ .

### 2.1.3 Jumlah Kuadrat Galat (JKG)

Jika  $\hat{y}$  merupakan nilai harapan dari  $y$  yang terestimasi berkaitan dengan observasi  $y$ , maka :

$$\hat{y} = \mathbf{X}\hat{\beta} \quad (2.1.3.1)$$

sehingga simpangan dari  $y_i$  yang merupakan nilai observasi dengan nilai prediksinya adalah:

$$\mathbf{y} - \hat{\mathbf{y}} = \mathbf{y} - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y} = \left[ \mathbf{I} - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}' \right] \mathbf{y} \quad (2.1.3.2)$$

dengan  $\mathbf{I} - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'$  adalah simetris dan Idempoten (2.1.3.3)

serta  $[\mathbf{I} - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}']\mathbf{X} = 0$  (2.1.3.4)

Jumlah kuadrat dari simpangan  $y_i$  dan nilai prediksinya biasa disebut sebagai residual, atau Jumlah Kuadrat Galat (Sum Squares Error=SSE), dengan persamaan:

$$\text{SSE} = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = (\mathbf{y} - \hat{\mathbf{y}})'(\mathbf{y} - \hat{\mathbf{y}}) \quad (2.1.3.5)$$

Untuk selanjutnya rumus SSE dapat diperoleh dengan mensubstitusikan persamaan (2.1.3.2) ke dalam persamaan (2.1.3.5) serta menggunakan persamaan (2.1.3.3) dan (2.1.3.4), sehingga persamaannya adalah:

$$SSE = y' [I - X(X'X)^{-1}X'] y \quad (2.1.3.6)$$

$$= y'y - y'X(X'X)^{-1}X'y$$

$$= y'y - \hat{\beta}'X'y \quad (2.1.3.7)$$

dengan diketahui bahwa  $\hat{\beta}' = y'X(X'X)^{-1}$ ,  $\hat{\beta}'X'y$  merupakan jumlah dari perkalian elemen-elemen  $\hat{\beta}$  dengan  $X'y$ , yaitu ruas kanan dari persamaan  $X'X\hat{\beta} = X'y$ .

SSE pada persamaan (2.1.3.6) ditulis dalam bentuk kuadratis dalam  $y$  yaitu:

$$SSE = y' [I - X(X'X)^{-1}X'] y$$

Menurut Teorema 1 (Searle, 1971) bahwa : jika  $x$  berdistribusi  $N(\mu, V)$

$$E(x'Ax) = \text{tr}(AV) + \mu'A\mu$$

Hal ini berakibat, jika  $y$  berdistribusi  $N(X\beta, I\sigma^2)$ , maka diperoleh:

$$\begin{aligned} E(SSE) &= \text{tr}[I - X(X'X)^{-1}X']I\sigma^2 + \beta'X'[I - X(X'X)^{-1}X']X\beta \\ &= \text{tr}[I - X(X'X)^{-1}X']\sigma^2 \\ &= [n - r(X)] \sigma^2 \end{aligned}$$

Diketahui bahwa trace dari suatu matriks idempoten sama dengan ranknya. Dengan demikian suatu estimator tak bias untuk  $\sigma^2$  adalah

$$\hat{\sigma}^2 = \frac{SSE}{n - r(X)} = \frac{SSE}{n - r}$$

dengan  $r = r(X)$ , rank dari matriks  $X$ . Dalam model regresi penuh  $r(X) = k+1$  dengan  $k$  adalah banyaknya variabel prediktor yang terlibat.



#### 2.1.4 Jumlah Kuadrat Total (JKT)

Jumlah Kuadrat Total ( Sum Squares Total = SST ) diberikan dengan persamaan:

$$SST = \mathbf{y}'\mathbf{y} = \sum_{i=1}^n y_i^2 \quad (2.1.4.1)$$

Jumlah Kuadrat Regresi (Sum Square Regression = SSR) dari  $y_i$  dengan nilai prediksinya adalah yang tertera pada persamaan (2.1.3.7) merupakan selisih antara nilai jumlah kuadrat total dengan jumlah kuadrat galat dan dapat ditulis dalam persamaan:

$$SSR = SST - SSE = \mathbf{y}'\mathbf{y} - (\mathbf{y}'\mathbf{y} - \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{y}) = \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{X}\hat{\boldsymbol{\beta}} \quad (2.1.4.2)$$