

## BAB II

### MATERI PENUNJANG

#### 2.1. Metode Kuadrat Terkecil Biasa (OLS)

Metode kuadrat terkecil biasa dikemukakan oleh Carl Friedrich Gauss, seorang ahli matematika bangsa Jerman. Untuk menjelaskan pendekatan cara Gauss, didefinisikan fungsi regresi populasi dua variabel,

$$Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i \quad (2.1.1)$$

dengan asumsi-asumsi sebagai berikut :

$$\text{Asumsi 1 : } E(\varepsilon_i | X_i) = 0 \quad (2.1.2)$$

Asumsi 1 menyatakan bahwa nilai bersyarat dari  $\varepsilon_i$  pada  $X_i$  tertentu adalah nol.

$$\begin{aligned} \text{Asumsi 2 : } \text{Cov}(\varepsilon_i, \varepsilon_j) &= E(\varepsilon_i - E(\varepsilon_i))(\varepsilon_j - E(\varepsilon_j)) \\ &= E(\varepsilon_i \varepsilon_j) \text{ karena asumsi 1} \\ &= 0 \quad i \neq j \end{aligned} \quad (2.1.3)$$

dengan  $i$  dan  $j$  dua pengamatan yang berbeda

Asumsi 2 menyatakan bahwa gangguan  $\varepsilon_i$  dan  $\varepsilon_j$  tidak berkorelasi atau tidak ada korelasi berurutan, atau tidak ada autokorelasi.

$$\begin{aligned} \text{Asumsi 3 : } \text{Var}(\varepsilon_i | X_i) &= E(\varepsilon_i - E(\varepsilon_i))^2 \\ &= E(\varepsilon_i^2) \text{ karena asumsi 1} \\ &= \sigma^2 \end{aligned} \quad (2.1.4)$$

Asumsi 3 menyatakan bahwa varians  $\varepsilon_i$  untuk tiap  $X_i$  adalah konstan sebesar  $\sigma^2$ . Secara teknis, menyatakan asumsi homoskedastisitas, atau penyebaran sama, atau varians sama.

$$\begin{aligned} \text{Asumsi 4 : Cov}(\varepsilon_i, X_i) &= E(\varepsilon_i - E(\varepsilon_i))(X_i - E(X_i)) \\ &= 0 \end{aligned} \quad (2.1.5)$$

Asumsi 4 menyatakan bahwa gangguan  $\varepsilon_i$  dan variabel yang menjelaskan  $X$  tidak berkorelasi.

Untuk asumsi 4 secara otomatis terpenuhi jika variabel  $X$  tak random atau tak stokastik dan asumsi 1 dipenuhi karena sebagian besar teori regresi persamaan didasarkan pada asumsi bahwa variabel  $X$  tak stokastik.

Suatu model regresi yang memenuhi keempat asumsi diatas dikenal dengan model regresi klasik standar, atau linear umum. Dari fungsi regresi populasi (2.1.1) diperoleh fungsi regresi sampel,

$$Y_i = \hat{\beta}_0 + \hat{\beta}_1 X_i + e_i \quad (2.1.6)$$

$$= \hat{Y}_i + e_i \quad (2.1.7)$$

dengan  $\hat{Y}_i$  adalah nilai taksiran (rata-rata bersyarat) dari  $Y_i$ . Dengan alternatif lain dinyatakan sebagai

$$\begin{aligned} e_i &= Y_i - \hat{Y}_i \\ &= Y_i - \hat{\beta}_0 + \hat{\beta}_1 X_i \end{aligned} \quad (2.1.8)$$

$e_i$  (residual) merupakan perbedaan antara nilai  $Y_i$  sebenarnya dengan nilai  $Y_i$  yang ditaksir.

Misalkan diberikan  $n$  pasang observasi atas  $Y$  dan  $X$  tertentu, dan ditentukan fungsi regresi sampel yang sedekat mungkin dengan nilai sebenarnya.

Adapun caranya dengan menjumlahkan residual (sisa)  $\sum_{i=1}^n e_i = (Y_i - \hat{Y}_i)$ . Untuk menghindari masalah digunakan metode kuadrat terkecil yang ditetapkan

$$\begin{aligned} \text{dengan meminimalkan } \sum_{i=1}^n e_i^2 &= \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \\ &= \sum_{i=1}^n (Y_i - \hat{\beta}_0 - \hat{\beta}_1 X_i)^2 \end{aligned} \quad (2.1.9)$$

Prinsip kuadrat terkecil memilih  $\hat{\beta}_0$  dan  $\hat{\beta}_1$  sedemikian rupa sehingga untuk suatu sampel tertentu  $\sum_{i=1}^n e_i^2$  sekecil mungkin.

Adapun caranya dengan meminimalkan  $\sum_{i=1}^n e_i^2$  yaitu menurunkan  $\sum_{i=1}^n e_i^2 = \sum_{i=1}^n (Y_i - \hat{\beta}_0 - \hat{\beta}_1 X_i)^2$  secara parsial terhadap  $\hat{\beta}_0$  dan  $\hat{\beta}_1$  untuk memperoleh

$$\begin{aligned} \frac{\partial \left( \sum_{i=1}^n e_i^2 \right)}{\partial \hat{\beta}_0} &= 2 \sum_{i=1}^n (Y_i - \hat{\beta}_0 - \hat{\beta}_1 X_i) \cdot (-1) \\ &= -2 \sum_{i=1}^n (Y_i - \hat{\beta}_0 - \hat{\beta}_1 X_i) \end{aligned} \quad (2.1.10)$$

$$\begin{aligned} \frac{\partial \left( \sum_{i=1}^n e_i^2 \right)}{\partial \hat{\beta}_1} &= 2 \sum_{i=1}^n (Y_i - \hat{\beta}_0 - \hat{\beta}_1 X_i) \cdot (-X_i) \\ &= -2 \sum_{i=1}^n (Y_i - \hat{\beta}_0 - \hat{\beta}_1 X_i) X_i \end{aligned} \quad (2.1.11)$$

Dengan menyamakan kedua persamaan (2.1.10) dan (2.1.11) dengan nol, setelah penyederhaan secara aljabar dan manipulasi, menghasilkan penaksir yang diberikan untuk menaksir  $\beta_0$  dan  $\beta_1$  :

$$\sum_{i=1}^n Y_i = n\hat{\beta}_0 + \hat{\beta}_1 \sum_{i=1}^n X_i \quad (2.1.12)$$

$$\sum_{i=1}^n Y_i X_i = \hat{\beta}_0 \sum_{i=1}^n X_i + \hat{\beta}_1 \sum_{i=1}^n X_i^2 \quad (2.1.13)$$

dengan  $n$  adalah besarnya sampel. Persamaan (2.1.12) dan (2.1.13) dikenal sebagai persamaan normal.

Dengan memecahkan persamaan normal secara simultan, diperoleh :

$$|\Delta| = \begin{vmatrix} n & \sum_{i=1}^n X_i \\ \sum_{i=1}^n X_i & \sum_{i=1}^n X_i^2 \end{vmatrix} = n \sum_{i=1}^n X_i^2 - \left( \sum_{i=1}^n X_i \right)^2$$

$$\hat{\beta}_0 = \frac{\begin{vmatrix} \sum_{i=1}^n Y_i & \sum_{i=1}^n X_i \\ \sum_{i=1}^n Y_i X_i & \sum_{i=1}^n X_i^2 \end{vmatrix}}{|\Delta|} = \frac{\sum_{i=1}^n Y_i \sum_{i=1}^n X_i^2 - \sum_{i=1}^n Y_i X_i \sum_{i=1}^n X_i}{n \sum_{i=1}^n X_i^2 - \left( \sum_{i=1}^n X_i \right)^2}$$

$$= \bar{Y} - \hat{\beta}_1 \bar{X} \quad (2.1.14)$$

$$\begin{aligned}
 \hat{\beta}_1 &= \frac{\begin{vmatrix} n & \sum_{i=1}^n Y_i \\ \sum_{i=1}^n X_i & \sum_{i=1}^n Y_i X_i \end{vmatrix}}{|\Delta|} = \frac{n \sum_{i=1}^n Y_i X_i - \sum_{i=1}^n X_i \sum_{i=1}^n Y_i}{n \sum_{i=1}^n X_i^2 - \left( \sum_{i=1}^n X_i \right)^2} \\
 &= \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sum_{i=1}^n (X_i - \bar{X})^2} \quad (2.1.15)
 \end{aligned}$$

Penaksir yang diperoleh (2.1.14 dan 2.1.15) dikenal sebagai penaksir kuadrat terkecil.

Dengan mengingat asumsi mengenai  $\varepsilon_i$ , maka sebagai akibatnya

$$E(\hat{\beta}_1) = \beta_1 + \sum_{i=1}^n k_i E(\varepsilon_i) = \beta_1, \text{ yang menunjukkan bahwa } \hat{\beta}_1 \text{ adalah penaksir tak}$$

bias. Dan sesuai dengan definisi  $\text{Var}(\hat{\beta}_1) = E(\hat{\beta}_1 - E(\hat{\beta}_1))^2$  maka

$$\begin{aligned}
 \text{Var}(\hat{\beta}_1) &= E(\hat{\beta}_1 - \beta_1)^2 \\
 &= E\left(\beta_1 + \sum_{i=1}^n k_i \varepsilon_i - \beta_1\right)^2 \\
 &= E\left(\sum_{i=1}^n k_i \varepsilon_i\right)^2
 \end{aligned}$$

Karena sesuai dengan asumsi,  $E(\varepsilon_i^2) = \sigma^2$  untuk tiap  $i$ , dan  $E(\varepsilon_i \varepsilon_j) = 0$

untuk  $i \neq j$ , Sebagai akibatnya

$$\text{Var}(\hat{\beta}_1) = \sigma^2 \sum_{i=1}^n k_i^2$$

$$= \frac{\sigma^2}{\sum_{i=1}^n k_i^2} \text{ dengan menggunakan definisi } k_i^2$$

Untuk varians  $\hat{\beta}_0$  dapat diperoleh dengan mengikuti prosedur diatas.

Hasilnya, 
$$\text{Var}(\hat{\beta}_0) = \frac{X_i^2}{n \sum_{i=1}^n x_i^2} \sigma^2$$

dengan  $x_i = X_i - \bar{X}$ .

Adapun kesalahan standar taksiran OLS dapat diperoleh sebagai berikut :

$$\text{Se}(\hat{\beta}_1) = \frac{\sigma}{\sqrt{\sum_{i=1}^n X_i^2}}$$

$$\text{Se}(\hat{\beta}_0) = \frac{\sqrt{\sum_{i=1}^n X_i^2}}{\sqrt{n \sum_{i=1}^n x_i^2}} \sigma$$

Adapun sifat-sifat penaksir kuadrat terkecil adalah :

Theorema Gauss Markov : dengan melihat asumsi model regresi linear klasik, penaksir kuadrat terkecil, dalam kelas penaksir linear tak bias, mempunyai varians minimum, yaitu penaksir tadi BLUE (Best Linear Unbiased Estimator).

## 2.2. Sifat-sifat Penaksir Titik

Sifat-sifat penaksir titik dibagi menjadi dua kategori yaitu sifat sampel kecil atau sampel terbatas dan sifat sampel besar atau asimptotik.

### 2.2.1. Sifat Sampel Kecil

#### 1. Ketakbiasan (unbiasednes)

Suatu penaksir  $\hat{\theta}$  dikatakan penaksir tak bias dari  $\theta$  jika nilai yang diharapkan dari  $\hat{\theta}$  sama dengan  $\theta$  sebenarnya; yaitu,  $E(\hat{\theta}) = \theta$ .

## 2. Varians minimum

Suatu penaksir  $\hat{\theta}_1$  dikatakan sebagai penaksir dengan varians minimum dari  $\theta$  jika varians dari  $\hat{\theta}_1$  lebih kecil atau sama dengan varians dari  $\hat{\theta}_2$ , untuk setiap  $\hat{\theta}_2$  yang merupakan penaksir lain dari  $\theta$ .

## 3. Efisiensi

Suatu penaksir  $\hat{\theta}_1$  dikatakan efisien jika  $\hat{\theta}_1$  dan  $\hat{\theta}_2$  adalah dua penaksir tak bias dari  $\theta$ , dan  $\hat{\theta}_1$  variansnya lebih kecil atau sama dengan varians  $\hat{\theta}_2$ , untuk semua  $\hat{\theta}_2$  estimator tak bias dari  $\theta$ .

## 4. Kelinieran (Linearity)

Suatu penaksir  $\hat{\theta}$  dikatakan penaksir linier dari  $\theta$  jika merupakan suatu fungsi linear dari observasi sampel.

## 5. Penaksir tak bias linier terbaik (Best Linier Unbias Estimator atau BLUE)

Suatu penaksir  $\hat{\theta}$  dikatakan BLUE jika  $\hat{\theta}$  adalah linier, tak bias dan mempunyai varians minimum.

### 2.2.2. Sifat Sampel Besar (asimptotik)

#### 1. Ketakbiasan asimptotik (asymptotic unbiasedness)

Suatu penaksir  $\hat{\theta}$  dikatakan tak bias asimtotik jika  $\lim_{n \rightarrow \infty} E(\hat{\theta}_n) = \theta$ .

## 1. Konsistensi

Suatu penaksir  $\hat{\theta}$  dikatakan konsisten jika  $\hat{\theta}$  mendekati nilai  $\theta$  yang sebenarnya dengan semakin besarnya ukuran sampel. Secara formal, suatu penaksir  $\hat{\theta}$  dikatakan penaksir konsisten dari  $\theta$  jika probabilitas dari nilai absolut untuk perbedaan  $\hat{\theta}$  dan  $\theta$  menjadi lebih kecil dari  $\delta$  (suatu kuantitas positif yang kecil secara arbitral) mendekati satu atau

$$\lim_{n \rightarrow \infty} P \{ |\hat{\theta}_n - \theta| < \delta \} = 1 \quad \delta > 0$$

Ini seringkali dinyatakan sebagai :

$$P \lim_{n \rightarrow \infty} E (\hat{\theta}_n) = \theta$$

Untuk mengetahui apakah suatu penaksir konsisten, kondisi cukup adalah bahwa  $\lim_{n \rightarrow \infty} E (\hat{\theta}_n) = \theta$  dan  $\lim_{n \rightarrow \infty} \text{Var} (\hat{\theta}_n) = 0$ .

Yaitu,  $\hat{\theta}$  tak bias secara asimtotik dan dengan meningkatnya  $n$  secara tak terbatas varians mendekati nol. Dengan kata lain, distribusi dari  $\hat{\theta}$  menjadi semakin terkonsentrasi pada nilai  $\theta$  dengan meningkatnya  $n$  secara tak terbatas.

## 2. Kenormalan asimtotik

Suatu penaksir  $\hat{\theta}$  dikatakan normal asimtotik jika distribusi samplingnya cenderung mendekati distribusi normal dengan meningkatnya ukuran sampel  $n$  secara tak terbatas.

### 2.3. Matriks dan Determinan untuk ordo 2 x 2

Suatu matriks adalah suatu barisan segiempat dari angka-angka atas unsur yang diatur dalam baris dan kolom. Matriks dengan ordo atau dimensi M dan N (ditulis sebagai M x N) adalah kumpulan dari M x N unsur yang disusun dalam M baris dan N kolom. Jadi matriks A (M x N) dinyatakan sebagai

$$A = [a_{ij}] = \begin{bmatrix} a_{11} & a_{12} & a_{13} & \dots & a_{1N} \\ a_{21} & a_{22} & a_{23} & \dots & a_{2N} \\ \dots & \dots & \dots & \dots & \dots \\ a_{M1} & a_{M2} & a_{M3} & \dots & a_{MN} \end{bmatrix}$$

dengan  $a_{ij}$  adalah unsur yang muncul dalam baris ke i dan kolom ke j dari A

$[a_{ij}]$  adalah pernyataan ringkas untuk matriks A yang unsur khususnya adalah  $(a_{ij})$

Ordo, atau dimensi dari suatu matriks adalah banyaknya baris dan kolom, yang seringkali ditulis dibawah matriksnya untuk memudahkan.

Matriks singular adalah matriks bujursangkar yang determinannya sama dengan 0 dan matriks nonsingular jika determinannya tidak sama dengan 0.

Untuk suatu matriks bujursangkar A ada angka (skalar) yang bersesuaian dengan A yang dikenal determinan suatu matriks yang dinyatakan  $\det \Delta$  atau simbol  $|\Delta|$  dimana  $|\Delta|$  berarti determinan.

Contoh:

$$A = \begin{bmatrix} a_{11} & a_{12} \\ a_{13} & a_{14} \end{bmatrix} \text{ maka } |A| = a_{11}a_{14} - a_{12}a_{13}$$

Rumus Cramer :

$$\text{Misal } a_{11}x + a_{21}y = b_1$$

$$a_{21}x + a_{22}y = b_2$$

dengan determinan matrik koefisien tak sama dengan nol adalah

$$x = \frac{\det \begin{bmatrix} b_1 & a_{12} \\ b_2 & a_{22} \end{bmatrix}}{\det \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix}}, y = \frac{\det \begin{bmatrix} a_{11} & b_1 \\ a_{21} & b_2 \end{bmatrix}}{\det \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix}}$$

Tingkat (rank) suatu matriks adalah ordo dari submatriks bujursangkar yang terbesar dan determinannya tidak sama dengan nol.

#### 2.4. Korelasi r

r didefinisikan sebagai korelasi untuk mengukur hubungan linier antara X dan Y, dengan

$$r = \frac{[n\sum X_i Y_i - (\sum X_i)(\sum Y_i)]}{\sqrt{n\sum X_i^2 - (\sum X_i)^2} \sqrt{n\sum Y_i^2 - (\sum Y_i)^2}}$$

sifat – sifat r adalah:

Batasnya adalah  $-1 \leq r \leq 1$

$r = 1$  berarti korelasi positif sempurna (kuat).

$r = 0$  berarti tidak berkorelasi.

$r = -1$  berarti korelasi negatif sempurna (kuat).

#### 2.5. Koefisien Determinasi $R^2$

$R^2$  didefinisikan sebagai koefisien determinasi (sampel) untuk mengukur kebaikan suai (goodness of fit) garis regresi. Secara verbal,  $R^2$  mengukur proporsi (bagian) atau prosentase sumbangan variabel yang menjelaskan terhadap variabel terikat..

$$\begin{aligned}
 R^2 &= \frac{\sum(\hat{Y}_i - \bar{Y})^2}{\sum(Y_i - \bar{Y})^2} \\
 &= \frac{(\sum x_i y_i)^2}{(\sum x_i^2)(\sum y_i^2)} \\
 &= \frac{[n\sum X_i Y_i - (\sum X_i)(\sum Y_i)]^2}{[n\sum X_i^2 - (\sum X_i)^2][n\sum Y_i^2 - (\sum Y_i)^2]}
 \end{aligned}$$

Sifat – sifat  $R^2$  adalah:

1.  $R^2$  merupakan besaran non negatif.
2. Batasnya adalah  $0 \leq R^2 \leq 1$

