

## BAB II

### LANDASAN TEORI

Pada bab II ini akan dibahas dasar-dasar teori yang digunakan dalam penulisan skripsi, yaitu mengenai regresi linear, penaksiran *maximum likelihood* dan uji rasio *likelihood*.

#### 2.1 Penaksiran *Maximum Likelihood*

Misal  $X_1, X_2, \dots, X_n$  adalah variabel random yang *iid* dengan pdf  $f(x; \theta)$ ,  $\theta \in \Omega$  dimana  $\theta$  merupakan suatu parameter yang tidak diketahui dan  $\Omega$  adalah ruang parameter. Dalam melakukan penaksiran *maximum likelihood* ada beberapa tahapan yang harus dilakukan.

Pertama, cari pdf bersama dari  $X_1, X_2, \dots, X_n$  yaitu  $f(x_1, x_2, \dots, x_n; \theta)$ .

Karena  $X_1, X_2, \dots, X_n$  adalah peubah acak yang *iid* maka

$$f(x_1, x_2, \dots, x_n; \theta) = f(x_1; \theta) f(x_2; \theta) \dots f(x_n; \theta)$$

Kedua, cari fungsi *likelihood*nya. Fungsi *likelihood* didefinisikan sebagai pdf bersama dari  $X_1, X_2, \dots, X_n$  yang dapat dianggap sebagai fungsi dari  $\theta$ . Misalkan fungsi *likelihood*  $L(\theta; x_1, x_2, \dots, x_n) = L(\theta)$ .

$$L(\theta) = f(x_1, x_2, \dots, x_n; \theta) = f(x_1; \theta) f(x_2; \theta) \dots f(x_n; \theta) \quad , \quad \theta \in \Omega$$

$$= \prod_{i=1}^n f(x_i; \theta)$$

Ketiga, cari taksiran dari  $\theta$ . Dalam metode penaksiran *maximum likelihood* taksiran dari  $\theta$  diperoleh dengan menemukan nilai  $\theta$ , sebut  $\hat{\theta}$ , yang memaksimumkan fungsi likelihood,  $\hat{\theta}$  disebut taksiran *maximum likelihood* dari  $\theta$ . Nilai  $\theta$  yang memaksimumkan fungsi likelihood dapat diperoleh dengan mencari solusi dari persamaan berikut :

$$\frac{\partial L(\theta)}{\partial \theta} = 0 \quad \text{dan} \quad \frac{\partial^2 L(\theta)}{\partial \theta^2} < 0$$

Adakalanya lebih mudah untuk memaksimumkan  $\ln L(\theta)$  daripada  $L(\theta)$ . Mencari nilai  $\theta$  yang memaksimumkan fungsi  $\ln L(\theta)$ , sebut  $L^*(\theta)$ , akan memberikan hasil yang sama dengan mencari nilai  $\theta$  yang memaksimumkan  $L(\theta)$ . Maka baik  $L(\theta)$  atau  $L^*(\theta)$  dapat digunakan untuk mencari nilai  $\hat{\theta}$ .

Nilai  $\theta$  yang memaksimumkan  $L^*(\theta)$  dapat diperoleh dengan mencari solusi dari persamaan

$$S(\theta) = \frac{\partial L^*(\theta)}{\partial \theta} = \frac{\partial \ln L(\theta)}{\partial \theta} = 0 \quad \text{dan} \quad \frac{\partial^2 L^*(\theta)}{\partial \theta^2} < 0$$

## 2.2 Uji Rasio Likelihood

Terdapat variabel random  $X_1, X_2, \dots, X_n$  yang *iid* dan memiliki *probability density function*  $f_i(x_i; \theta_1, \theta_2, \dots, \theta_m)$  untuk  $i = 1, 2, \dots, n$ . Parameter-parameter dari populasi  $\theta_1, \theta_2, \dots, \theta_m$  dimisalkan berada dalam ruang parameter  $\Omega$ .

Misalkan  $\omega$  merupakan subset dari  $\Omega$  dan akan diuji hipotesis berikut :

$$H_0 : (\theta_1, \theta_2, \dots, \theta_m) \in \omega$$

$H_1$  : tidak demikian

Didefinisikan fungsi likelihood :

$$L(\theta_1, \theta_2, \dots, \theta_m; x_1, x_2, \dots, x_n) = \prod_{i=1}^n f_i(x_i; \theta_1, \theta_2, \dots, \theta_m)$$

Jika  $\theta_1, \theta_2, \dots, \theta_m \in \Omega$ , notasikan fungsi likelihood sebagai berikut :

$$L(\Omega).$$

Jika  $\theta_1, \theta_2, \dots, \theta_m \in \omega$ , notasikan fungsi likelihood sebagai berikut :

$$L(\omega).$$

Pandang rasio likelihood dari kedua fungsi *likelihood* diatas sebagai berikut :

$$\lambda^* = \frac{L(\omega)}{L(\Omega)}$$

Nilai  $\lambda^*$  tidak dapat digunakan sebagai statistik uji untuk menguji  $H_0$  dan  $H_1$  karena  $L(\omega)$  dan  $L(\Omega)$  pada umumnya tidak dapat ditetapkan secara lengkap.

Misalkan  $\hat{\omega}$  merupakan taksiran *maximum likelihood* untuk  $\omega$  dan  $\hat{\Omega}$  merupakan taksiran *maximum likelihood* untuk  $\Omega$ .

Pandang :

$$\lambda(x_1, x_2, \dots, x_n) = \lambda = \frac{L(\hat{\omega})}{L(\hat{\Omega})}.$$

Nilai  $\lambda$  dapat dicari.  $\lambda$  dapat digunakan sebagai statistik uji untuk menguji hipotesis  $H_0$  dan  $H_1$ .

Perhatikan :

$$\lambda = \frac{L(\hat{\omega})}{L(\hat{\Omega})}.$$

$L(\hat{\omega})$  dan  $L(\hat{\Omega})$  bernilai positif sehingga  $\lambda$  juga akan bernilai positif atau  $\lambda \geq 0$ . Kemudian karena  $\hat{\omega} \subset \hat{\Omega}$  maka  $L(\hat{\omega}) \leq L(\hat{\Omega})$ . Karena  $L(\hat{\omega}) \leq L(\hat{\Omega})$

maka nilai  $\frac{L(\hat{\omega})}{L(\hat{\Omega})} \leq 1$ . Sehingga diperoleh  $0 \leq \lambda = \frac{L(\hat{\omega})}{L(\hat{\Omega})} \leq 1$ . Apabila  $\lambda = 0$

maka  $L(\hat{\omega}) = 0$ ,  $H_0$  akan ditolak.

Jadi  $H_0$  akan ditolak apabila  $\lambda$  bernilai kecil (mendekati 0). Misalkan  $\lambda_0$  suatu bilangan pecahan positif sedemikian sehingga  $H_0$  akan ditolak apabila  $0 \leq \lambda \leq \lambda_0$ .

Misal  $\alpha$  adalah tingkat signifikansi yang dipilih.

$$\alpha = \Pr(\lambda(x_1, x_2, \dots, x_n) \leq \lambda_0; H_0)$$

Apabila *pdf* dari statistik  $\lambda(x_1, x_2, \dots, x_n)$  dapat diketahui untuk  $H_0$  benar maka konstanta  $\lambda_0$  dapat ditentukan, sedemikian sehingga :

$$\alpha = \Pr(\lambda(x_1, x_2, \dots, x_n) \leq \lambda_0; H_0).$$

Namun terkadang, dibawah  $H_0$  benar, sulit untuk menentukan distribusi dari statistik  $\lambda(x_1, x_2, \dots, x_n)$ . Karena itu tidak dimungkinkan untuk memperoleh  $\lambda_0$  yang memenuhi :

$$\alpha = \Pr(\lambda(x_1, x_2, \dots, x_n) \leq \lambda_0; H_0)$$

Karena distribusi dari statistik  $\lambda(x_1, x_2, \dots, x_n)$  sulit diketahui, maka dicari statistik lain yaitu  $G = -2\ln\lambda$ .

Dalam pengujian-pengujian yang menggunakan asumsi-asumsi tertentu dapat ditunjukkan bahwa  $G = -2\ln\lambda$  akan berdistribusi  $\chi^2$  dengan derajat bebas dimensi  $\Omega$  – dimensi  $\omega$  (A Course in Mathematical Statistics by George G. Roussas, 362).

## 2.3 Model Regresi Linear

Analisis regresi merupakan salah satu metode untuk melihat hubungan antara variabel penjelas dengan variabel *dependent* yang dinyatakan dalam model regresi.

### 2.3.1 Regresi Linear Sederhana

Regresi linear sederhana merupakan model regresi yang melibatkan satu variabel penjelas dan satu variabel *dependent*.

Bentuk model sebagai berikut:

$$y_j = \beta_0 + \beta_1 x_j + e_j$$

dengan :

$y_j$  : variabel *dependent* untuk pengamatan ke- $j$

$\beta_0, \beta_1$  : parameter-parameter model yang akan ditaksir

$x_j$  : variabel penjelas untuk pengamatan ke- $j$

$e_j$  : komponen *error*,  $e_j \sim N(0, \sigma^2)$

$j = 1, 2, \dots, n$ ;  $n$  merupakan banyak pengamatan.

### 2.3.2 Regresi Linear Berganda

Model regresi linear yang melibatkan lebih dari satu variabel penjelas  $X_1, X_2, \dots, X_p$  dengan satu variabel *dependent* disebut model regresi linier berganda. Bentuk model dituliskan sebagai berikut :

$$y_j = \beta_0 + \beta_1 x_{j1} + \beta_2 x_{j2} + \dots + \beta_p x_{jp} + e_j$$

$j = 1, 2, \dots, n$ ;  $n$  merupakan banyak pengamatan.

Apabila model dinyatakan dalam bentuk matriks menjadi :

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{e}$$

$$\mathbf{y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}, \quad \mathbf{X} = \begin{bmatrix} 1 & x_{11} & x_{12} & \cdots & x_{1p} \\ 1 & x_{21} & x_{22} & \cdots & x_{2p} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & x_{n2} & \cdots & x_{np} \end{bmatrix}, \quad \boldsymbol{\beta} = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_p \end{bmatrix}, \quad \mathbf{e} = \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_n \end{bmatrix}$$

Model regresi linear berganda di atas memiliki asumsi sebagai berikut :

- $E(e_j) = 0$ , untuk  $j = 1, 2, \dots, n$
- $E(e_i e_j) = \begin{cases} 0, & \text{untuk } i \neq j \\ \sigma^2, & \text{untuk } i = j \end{cases}$
- $e_j \sim N(0, \sigma^2)$

dan apabila dinyatakan dalam notasi matriks menjadi :

- $E(\mathbf{e}) = \mathbf{0}$ , dengan  $\mathbf{0}$  adalah matriks nol berukuran  $n \times 1$
- $E(\mathbf{e}\mathbf{e}^T) = \sigma^2 \mathbf{I}$ , dengan  $\mathbf{I}$  adalah matriks identitas berukuran  $n \times n$
- $\mathbf{e}$  memiliki distribusi normal dengan mean  $\mathbf{0}$  dan variansi  $\sigma^2 \mathbf{I}$ .

### 2.3.3 Penaksiran Parameter dalam Model Regresi Linear

Parameter-parameter pada model regresi linear biasanya ditaksir dengan menggunakan taksiran kuadrat terkecil atau dengan menggunakan taksiran *maximum likelihood*. Pada bagian ini akan dijelaskan mengenai penaksiran parameter dalam model regresi dengan menggunakan taksiran *maximum likelihood*.

Dari model regresi berganda dan asumsi  $e \sim N(0, \sigma^2)$  didapatkan bahwa  $y_i$  berdistribusi normal dengan mean  $[\beta_0 + \beta_1 x_{j1} + \dots + \beta_p x_{jp}]$  dan variansi  $\sigma^2$ :

$$f(y_j; \beta_0, \beta_1, \dots, \beta_p) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp \left\{ -\frac{y_j - [\beta_0 + \beta_1 x_{j1} + \dots + \beta_p x_{jp}]}{2\sigma^2} \right\}$$

Kemudian akan dicari taksiran *maximum likelihood* untuk parameter-parameter pada model.

Pertama, cari pdf bersama dari  $Y_1, Y_2, \dots, Y_n$  yaitu  $f(y_1, y_2, \dots, y_n; \beta_0, \beta_1, \dots, \beta_p)$ .

Karena  $Y_1, Y_2, \dots, Y_n$  adalah peubah acak yang *iid* maka

$$f(y_1, y_2, \dots, y_n; \beta_0, \beta_1, \dots, \beta_p) = f(y_1; \beta_0, \beta_1, \dots, \beta_p) f(y_2; \beta_0, \beta_1, \dots, \beta_p) \dots f(y_n; \beta_0, \beta_1, \dots, \beta_p).$$

Kemudian akan dicari fungsi likelihood. Fungsi likelihood didefinisikan

sebagai pdf bersama dari  $Y_1, Y_2, \dots, Y_n$ . Fungsi likelihood  $L(\beta_0, \beta_1, \dots, \beta_p)$

diperoleh sebagai berikut :

$$\begin{aligned}
 L(\beta_0, \beta_1, \dots, \beta_p) &= f(y_1, y_2, \dots, y_n; \beta_0, \beta_1, \dots, \beta_p) \\
 &= f(y_1; \beta_0, \beta_1, \dots, \beta_p) f(y_2; \beta_0, \beta_1, \dots, \beta_p) \dots f(y_n; \beta_0, \beta_1, \dots, \beta_p) \\
 &= \prod_{j=1}^n f(y_j; \beta_0, \beta_1, \dots, \beta_p) \\
 &= \prod_{j=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} \exp \left\{ -\frac{[y_j - (\beta_0 + \beta_1 x_{j1} + \dots + \beta_p x_{jp})]^2}{2\sigma^2} \right\} \\
 &= \left( \frac{1}{2\pi\sigma^2} \right)^{n/2} \exp \left\{ -\frac{1}{2\sigma^2} \sum_{j=1}^n [y_j - (\beta_0 + \beta_1 x_{j1} + \dots + \beta_p x_{jp})]^2 \right\}
 \end{aligned}$$

Mencari nilai  $\beta_0, \beta_1, \dots, \beta_p$  yang memaksimumkan fungsi  $L(\beta_0, \beta_1, \dots, \beta_p)$ , akan memberikan hasil yang sama dengan mencari nilai  $\beta_0, \beta_1, \dots, \beta_p$  yang memaksimumkan fungsi  $\ln L(\beta_0, \beta_1, \dots, \beta_p)$ , sebut  $L^*(\beta_0, \beta_1, \dots, \beta_p)$ . Untuk memaksimumkan  $L(\beta_0, \beta_1, \dots, \beta_p)$  sama saja dengan meminimumkan fungsi  $-L^*(\beta_0, \beta_1, \dots, \beta_p)$ , maka digunakan bentuk  $L^* = -\ln L$  :

$$L^* = -\ln L$$

$$\begin{aligned}
 &= -\ln \left\{ \left( \frac{1}{2\pi\sigma^2} \right)^{n/2} \exp \left\{ -\frac{1}{2\sigma^2} \sum_{j=1}^n [y_j - (\beta_0 + \beta_1 x_{j1} + \dots + \beta_p x_{jp})]^2 \right\} \right\} \\
 &= - \left\{ \ln \left( \frac{1}{2\pi\sigma^2} \right)^{n/2} + \ln \left\{ \exp \left\{ -\frac{1}{2\sigma^2} \sum_{j=1}^n [y_j - (\beta_0 + \beta_1 x_{j1} + \dots + \beta_p x_{jp})]^2 \right\} \right\} \right\} \\
 &= - \left\{ \frac{n}{2} \ln \left( \frac{1}{2\pi\sigma^2} \right) + \left\{ -\frac{1}{2\sigma^2} \sum_{j=1}^n [y_j - (\beta_0 + \beta_1 x_{j1} + \dots + \beta_p x_{jp})]^2 \right\} \right\} \\
 &= - \left\{ \frac{n}{2} (\ln 1 - \ln 2\pi\sigma^2) + \left\{ -\frac{1}{2\sigma^2} \sum_{j=1}^n [y_j - (\beta_0 + \beta_1 x_{j1} + \dots + \beta_p x_{jp})]^2 \right\} \right\} \\
 &= - \left\{ \frac{n}{2} (0 - \ln 2\pi\sigma^2) + \left\{ -\frac{1}{2\sigma^2} \sum_{j=1}^n [y_j - (\beta_0 + \beta_1 x_{j1} + \dots + \beta_p x_{jp})]^2 \right\} \right\} \\
 &= - \left\{ \frac{n}{2} (-\ln 2\pi\sigma^2) + \left\{ -\frac{1}{2\sigma^2} \sum_{j=1}^n [y_j - (\beta_0 + \beta_1 x_{j1} + \dots + \beta_p x_{jp})]^2 \right\} \right\} \\
 &= \frac{n}{2} \ln(2\pi\sigma^2) + \frac{\sum_{j=1}^n [y_j - (\beta_0 + \beta_1 x_{j1} + \dots + \beta_p x_{jp})]^2}{2\sigma^2}
 \end{aligned}$$

Untuk mendapatkan  $L^*(\beta_0, \beta_1, \dots, \beta_p)$  yang minimum, diperlukan  $(\beta_0, \beta_1, \dots, \beta_p)$

yang meminimumkan fungsi  $\sum_{j=1}^n [y_j - (\beta_0 + \beta_1 x_{j1} + \dots + \beta_p x_{jp})]^2$ .

Sekarang akan dicari taksiran untuk  $\beta_0, \beta_1, \dots, \beta_p$  yang meminimumkan fungsi :

$$H(\beta_0, \beta_1, \dots, \beta_p) = \sum_{j=1}^n [y_j - (\beta_0 + \beta_1 x_{j1} + \dots + \beta_p x_{jp})]^2.$$

Nilai  $\beta_0, \beta_1, \dots, \beta_p$  yang meminimumkan  $H(\beta_0, \beta_1, \dots, \beta_p)$  dapat diperoleh

dengan mencari solusi dari persamaan berikut :

$$\begin{aligned}\frac{\partial H(\beta_0, \beta_1, \dots, \beta_p)}{\partial \beta_0} &= 0, \\ \frac{\partial H(\beta_0, \beta_1, \dots, \beta_p)}{\partial \beta_1} &= 0, \\ &\vdots \\ \frac{\partial H(\beta_0, \beta_1, \dots, \beta_p)}{\partial \beta_p} &= 0.\end{aligned}$$

dimana masing-masing turunan parsialnya adalah sebagai berikut :

$$\begin{aligned}\frac{\partial H(\beta_0, \beta_1, \dots, \beta_p)}{\partial \beta_0} &= 2 \sum_{j=1}^n [y_j - (\beta_0 + \beta_1 x_{j1} + \dots + \beta_p x_{jp})] (-1) \\ \frac{\partial H(\beta_0, \beta_1, \dots, \beta_p)}{\partial \beta_1} &= 2 \sum_{j=1}^n [y_j - (\beta_0 + \beta_1 x_{j1} + \dots + \beta_p x_{jp})] (-x_{j1}) \\ &\vdots \\ \frac{\partial H(\beta_0, \beta_1, \dots, \beta_p)}{\partial \beta_p} &= 2 \sum_{j=1}^n [y_j - (\beta_0 + \beta_1 x_{j1} + \dots + \beta_p x_{jp})] (-x_{jp})\end{aligned}$$

### 2.3.4 Pengujian Hipotesis dalam Regresi Linear Berganda

Setelah diperoleh taksiran dari parameter-parameter dalam model selanjutnya dilakukan pengujian hipotesis terhadap parameter dalam model. Pengujian terbagi ke dalam dua bagian yaitu pengujian kegunaan model dan pengujian terhadap masing-masing koefisien regresi.

### 2.3.4.1 Pengujian kegunaan model

Pengujian kegunaan atau kecocokan model adalah pengujian untuk menentukan apakah ada hubungan linear antara variabel *dependent* dan variabel penjelas  $X_1, X_2, \dots, X_p$ .

Hipotesis :

$$H_0 : \beta_1 = \beta_2 = \dots = \beta_p = 0$$

$$H_1 : \exists \beta_i \neq 0, \text{ untuk } i = 1, 2, \dots, p$$

Jika  $H_0$  ditolak, berarti paling tidak ada satu dari variabel penjelas  $X_1, X_2, \dots, X_p$  mempunyai kontribusi yang signifikan pada model. Atau dengan perkataan lain setidaknya ada satu variabel penjelas yang dapat digunakan untuk memprediksi variabel *dependent*.

Dalam pengujian model di atas akan dilakukan pengujian dengan menggunakan Uji Rasio *Likelihood*.

Statistik uji sebagai berikut:

$$\begin{aligned} G &= -2 \ln \lambda \\ &= -2 \ln \frac{L(\hat{\omega})}{L(\hat{\Omega})} \end{aligned}$$

dengan  $G$  akan berdistribusi  $\chi^2$  ( Hosmer & Lemeshow 2000 : 13).

### 2.3.4.2 Pengujian terhadap masing-masing koefisien regresi ( $\beta$ )

Pengujian ini dilakukan untuk menentukan variabel penjelas mana yang signifikan memberikan kontribusi pada model atau dengan perkataan lain memberikan kontribusi yang signifikan dalam memprediksi variabel *dependent*.

Hipotesis sebagai berikut :

$$H_0 : \beta_i = 0$$

Variabel  $X_i$  tidak memberikan kontribusi yang signifikan dalam memprediksi variabel *dependent*.

$$H_1 : \beta_i \neq 0$$

Variabel  $X_i$  memberikan kontribusi yang signifikan dalam memprediksi variabel *dependent*.

untuk  $i = 1, 2, \dots, p$ .

$\hat{\beta}_i$  adalah taksiran untuk parameter  $\beta_i$  pada model dengan menggunakan metode *maximum likelihood*.  $\hat{\beta}_i$  adalah taksiran yang tak bias untuk  $\beta_i$  dengan taksiran variansi  $s_{\hat{\beta}_i}$  merupakan taksiran variansi yang bernilai lebih rendah (*underestimate*) daripada variansi yang sesungguhnya. Akan tetapi untuk jumlah sampel yang besar, nilai dari  $s_{\hat{\beta}_i}$  akan mendekati nilai yang sebenarnya.

Maka :

$$z = \frac{\hat{\beta}_i}{s_{\hat{\beta}_i}} \rightarrow N(0,1)$$

Jadi untuk pengujian di atas digunakan statistik uji sebagai berikut :

$$z = \frac{\hat{\beta}_i}{s_{\hat{\beta}_i}}$$

dengan  $z \sim N(0,1)$ .

Aturan keputusan :  $H_0$  akan ditolak pada tingkat signifikansi  $\alpha$  apabila

$$|z| > z_{\alpha/2}.$$

Apabila keputusannya  $H_0$  ditolak, yang memberi arti bahwa pada tingkat signifikansi  $\alpha$  parameter  $\beta_i$  tidak sama dengan nol, maka artinya variabel penjelas  $X_i$  memberikan kontribusi yang signifikan dalam memprediksi variabel *dependent*.

### 2.3.5 Mengukur Kecocokan Model

Selain melakukan pengujian seperti dijelaskan di atas ada beberapa metode untuk mengukur kecocokan model, salah satunya adalah dengan koefisien determinasi  $R^2$ .

$R^2$  merupakan proporsi variasi dari variabel *dependent* yang dapat dijelaskan oleh variabel penjelas melalui model ( $0 \leq R^2 \leq 1$ ). Semakin besar  $R^2$ , maka menunjukkan model yang terbentuk semakin baik.

Definisi :

Koefisien determinasi  $R^2$  didefinisikan sebagai berikut :

$$R^2 = 1 - \frac{SSE}{SS(Total)} ; 0 \leq R^2 \leq 1$$

$$= \frac{SS_{(Total)} - SSE}{SS_{(Total)}}$$

dengan

$$SSE = \sum (y_j - \hat{y}_j)^2$$

$$SS_{(Total)} = \sum (y_j - \bar{y})^2$$

$$SS_{(Model)} = SS_{(Total)} - SSE$$

$$= \sum (\hat{y}_j - \bar{y})^2$$

di mana  $\hat{y}_j$  merupakan nilai prediksi dari  $y_j$ .

Interpretasi dari  $R^2$  :

Sebesar  $100(R^2)\%$  dari variasi sampel  $y$  dapat dijelaskan melalui variabel-variabel penjelas dalam model regresi yang terbentuk.

Pandang :

$$e_j = (y_j - \hat{y}_j)$$

$$SSE = \sum_j e_j^2$$

Akan dibuktikan bahwa  $\frac{\sum_j e_j^2}{n}$  konvergen menuju  $\sigma^2$  secara probabilitas .

Ada beberapa teorema yang digunakan untuk membuktikan bahwa  $\frac{\sum_j e_j^2}{n}$

konvergen menuju  $\sigma^2$  secara probabilitas yaitu :

\*) Teorema 1 :

Jika variabel X memiliki distribusi  $N(\mu, \sigma^2)$ ;  $\sigma^2 > 0$  maka

$$V = \frac{(X - \mu)^2}{\sigma^2} \sim \chi_{(1)}^2.$$

\*) Teorema 2 :

Jika terdapat variabel-variabel yang *independent*  $X_1, X_2, \dots, X_n$  yang memiliki distribusi  $\chi_{(r_1)}^2, \chi_{(r_2)}^2, \dots, \chi_{(r_n)}^2$ , maka variabel random

$$Y = X_1 + X_2 + \dots + X_n \sim \chi_{(r_1+r_2+\dots+r_n)}^2.$$

Pembuktian  $\frac{\sum_j e_j^2}{n}$  konvergen menuju  $\sigma^2$  secara probabilitas :

Diketahui bahwa  $e_j \sim N(0, \sigma^2)$ .

Berdasarkan teorema 1 diperoleh :

$$\begin{aligned} & \frac{(e_j - 0)^2}{\sigma^2} \\ &= \frac{(e_j)^2}{\sigma^2} \\ &= \frac{e_j^2}{\sigma^2} \sim \chi_{(1)}^2 \end{aligned}$$

Dengan perkataan lain  $\frac{e_1^2}{\sigma^2} \sim \chi_{(1)}^2, \frac{e_2^2}{\sigma^2} \sim \chi_{(1)}^2, \dots, \frac{e_n^2}{\sigma^2} \sim \chi_{(1)}^2$ .

Kemudian, berdasarkan teorema 2 didapatkan :

$$\frac{e_1^2}{\sigma^2} + \frac{e_2^2}{\sigma^2} + \dots + \frac{e_n^2}{\sigma^2} \sim \chi_{(1+1+\dots+1)}^2$$

atau

$$\frac{\sum_j e_j^2}{\sigma^2} \sim \chi_{(n)}^2$$

Sehingga  $E\left(\frac{\sum_j e_j^2}{\sigma^2}\right) = n$  dan  $Var\left(\frac{\sum_j e_j^2}{\sigma^2}\right) = 2n$ .

Selanjutnya akan dicari ekspektasi dan variansi dari  $\frac{\sum_j e_j^2}{n}$ .

$$\begin{aligned}
E\left(\frac{\sum_j e_j^2}{n}\right) &= E\left(\frac{\sigma^2 \sum_j e_j^2}{\sigma^2 n}\right) \\
&= E\left(\frac{\sigma^2 \sum_j e_j^2}{n \sigma^2}\right) \\
&= \frac{\sigma^2}{n} E\left(\frac{\sum_j e_j^2}{\sigma^2}\right) \\
&= \frac{\sigma^2}{n} n \\
&= \sigma^2
\end{aligned}$$

$$\begin{aligned}
\text{Var}\left(\frac{\sum_i e_i^2}{n}\right) &= E\left(\left(\frac{\sum_i e_i^2}{n} - E\left(\frac{\sum_i e_i^2}{n}\right)\right)^2\right) \\
&= E\left(\left(\frac{\sum_i e_i^2}{n} - (\sigma^2)\right)^2\right) \\
&= E\left(\left(\frac{\sigma^2 \sum_i e_i^2}{\sigma^2 n} - (\sigma^2)\right)^2\right) \\
&= E\left(\left(\frac{\sigma^2 \sum_i e_i^2}{n \sigma^2} - (\sigma^2)\right)^2\right) \\
&= E\left(\left(\sigma^2 \left(\frac{1 \sum_i e_i^2}{n \sigma^2} - (1)\right)\right)^2\right) \\
&= E\left((\sigma^2)^2 \left(\frac{1 \sum_i e_i^2}{n \sigma^2} - (1)\right)^2\right) \\
&= E\left((\sigma^4) \left(\frac{1 \sum_i e_i^2}{n \sigma^2} - (1)\right)^2\right) \\
&= \sigma^4 E\left(\left(\frac{1 \sum_i e_i^2}{n \sigma^2}\right)^2 - 2 \frac{1 \sum_i e_i^2}{n \sigma^2} + 1\right) \\
&= \sigma^4 \left[ E\left(\frac{1 \sum_i e_i^2}{n \sigma^2}\right)^2 - 2E\left(\frac{1 \sum_i e_i^2}{n \sigma^2}\right) + 1 \right] \\
&= \sigma^4 \left[ \frac{1}{n^2} E\left(\frac{\sum_i e_i^2}{\sigma^2}\right)^2 - 2 \frac{1}{n} E\left(\frac{\sum_i e_i^2}{\sigma^2}\right) + 1 \right]
\end{aligned}$$

dari  $E\left(\frac{\sum e_j^2}{\sigma^2}\right)^2 = \left(\text{var}\left(\frac{\sum e_j^2}{\sigma^2}\right) + \left(E\left(\frac{\sum e_j^2}{\sigma^2}\right)\right)^2\right)$  diperoleh :

$$= \sigma^4 \left[ \frac{1}{n^2} \left( \text{var}\left(\frac{\sum e_j^2}{\sigma^2}\right) + \left(E\left(\frac{\sum e_j^2}{\sigma^2}\right)\right)^2 \right) - 2 \frac{1}{n} E\left(\frac{\sum e_j^2}{\sigma^2}\right) + 1 \right]$$

dengan mensubstitusi  $E\left(\frac{\sum e_j^2}{\sigma^2}\right) = n$  dan  $\text{var}\left(\frac{\sum e_j^2}{\sigma^2}\right) = 2n$  didapatkan :

$$= \sigma^4 \left[ \frac{1}{n^2} (2n + n^2) - 2 \frac{1}{n} n + 1 \right]$$

$$= \sigma^4 \left[ \frac{1}{n^2} (2n + n^2) - 2 + 1 \right]$$

$$= \sigma^4 \left[ \frac{1}{n^2} (2n + n^2) - 1 \right]$$

$$= \sigma^4 \left[ \frac{2n + n^2 - n^2}{n^2} \right]$$

$$= \sigma^4 \left[ \frac{2n}{n^2} \right]$$

$$= \sigma^4 \left[ \frac{2}{n} \right]$$

Untuk membuktikan bahwa  $\frac{\sum e_j^2}{n}$  konvergen menuju  $\sigma^2$  secara probabilitas

digunakan pertidaksamaan Chebyshev sebagai berikut :

$$\Pr \left[ \left| \frac{\sum e_j^2}{n} - \mu_{\frac{\sum e_j^2}{n}} \right| < k \sigma_{\frac{\sum e_j^2}{n}} \right] \geq 1 - \frac{1}{k^2}$$

$$\Pr \left[ \left| \frac{\sum e_j^2}{n} - \sigma^2 \right| < k \sigma^2 \sqrt{\frac{2}{n}} \right] \geq 1 - \frac{1}{k^2}$$

dengan mensubstitusi  $\varepsilon = k\sigma^2\sqrt{\frac{2}{n}}$ ,

$$\Pr \left[ \left| \frac{\sum_j e_j^2}{n} - \sigma^2 \right| < \varepsilon \right] \geq 1 - \frac{1}{\left( \frac{\varepsilon}{\sigma^2\sqrt{\frac{2}{n}}} \right)^2}$$

$$\Pr \left[ \left| \frac{\sum_j e_j^2}{n} - \sigma^2 \right| < \varepsilon \right] \geq 1 - \frac{2\sigma^4}{\varepsilon^2 n}$$

$$\lim_{n \rightarrow \infty} \Pr \left[ \left| \frac{\sum_j e_j^2}{n} - \sigma^2 \right| < \varepsilon \right] \geq \lim_{n \rightarrow \infty} \left( 1 - \frac{2\sigma^4}{\varepsilon^2 n} \right)$$

$$\lim_{n \rightarrow \infty} \Pr \left[ \left| \frac{\sum_j e_j^2}{n} - \sigma^2 \right| < \varepsilon \right] \geq 1 - \lim_{n \rightarrow \infty} \frac{2\sigma^4}{\varepsilon^2 n}$$

diperoleh :  $\lim_{n \rightarrow \infty} \Pr \left[ \left| \frac{\sum_j e_j^2}{n} - \sigma^2 \right| < \varepsilon \right] \geq 1 - 0$

karena nilai probabilitas antara 0 dan 1 maka :

$$\lim_{n \rightarrow \infty} \Pr \left[ \left| \frac{\sum_j e_j^2}{n} - \sigma^2 \right| < \varepsilon \right] = 1$$

Berdasarkan definisi konvergen probabilitas persamaan :

$$\lim_{n \rightarrow \infty} \Pr \left[ \left| \frac{\sum_j e_j^2}{n} - \sigma^2 \right| < \varepsilon \right] = 1$$

menunjukkan  $\frac{\sum_j e_j^2}{n}$  konvergen menuju  $\sigma^2$  secara probabilitas.

Jadi terbukti bahwa  $\frac{\sum_j e_j^2}{n}$  konvergen menuju  $\sigma^2$  secara probabilitas.

