

## BAB II TINJAUAN PUSTAKA

### 2.1 Analisis Regresi

Apabila memperhatikan ketergantungan antara suatu peubah respon  $Y$  terhadap peubah bebas  $X$  yang bervariasi, maka persamaan yang menghubungkan  $Y$  dan  $X$  disebut persamaan regresi. Suatu persamaan regresi diasumsikan bahwa peubah bebas ( $X$ ) bersifat tetap atau *fixed*, sedangkan peubah respon ( $Y$ ) bersifat acak (Drapper dan Smith, 1992).

Berikut merupakan persamaan garis lurus antara dua peubah, yaitu peubah  $Y$  dan  $X$  :

$$Y = \beta_0 + \beta_1 X \quad (2.1)$$

persamaan regresi linier (2.1) dengan peubah respon  $Y$  dan peubah bebas  $X$ , menggambarkan hubungan antara nilai peubah  $Y$  dan  $X$ , di mana besar nilai peubah  $Y$  dipengaruhi oleh besar nilai peubah  $X$  dengan  $\beta_0$  adalah *intercept* dan  $\beta_1$  adalah *slope* (koefisien regresi). Dalam banyak kasus nilai dari koefisien  $\beta_0$  tidak selalu diartikan sebagai besar nilai  $Y$  apabila  $X$  bernilai nol, akan tetapi sebagai koefisien penyesuaian.  $\beta_1$  menyatakan besarnya perubahan nilai  $Y$  pada setiap satuan perubahan nilai  $X$ , sehingga bisa dinyatakan sebagai berikut :

$$\beta_1 = \frac{\Delta Y}{\Delta X} \quad (2.2)$$

Hubungan antara peubah  $X$  dan  $Y$  tidak selalu tepat mengikuti persamaan linier (2.1), tetapi terdapat keragaman pada setiap nilai peubah bebas. Pada  $x_i$  misalnya, dapat dihasilkan bermacam-macam nilai *output*  $Y$  yang pusatnya diperkirakan terletak pada titik  $Y_i = \beta_0 + \beta_1 X_i$ . Adanya perbedaan nilai pengamatan dari garis regresi, maka Persamaan (2.1) harus dimodifikasi. Dimisalkan perbedaan antara nilai amatan dari  $Y$  dengan  $\hat{Y}$  adalah galat ( $\varepsilon_i$ ) yaitu peubah acak yang menjelaskan kesalahan dari persamaan dalam mencocokkan data dengan tepat. Oleh karena itu, persamaan untuk menjelaskan sebuah garis regresi adalah :

$$Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i \quad (2.3)$$

## 2.2 Uji Asumsi Klasik

Dalam analisis regresi terdapat beberapa asumsi yang harus dipenuhi agar persamaan regresi yang didapat baik dan mampu menggambarkan data yang sebenarnya sehingga menghasilkan kesimpulan yang sah dan tidak menyesatkan. Asumsi-asumsi yang harus dipenuhi dalam analisis regresi adalah :

### 1. Asumsi Linieritas

Linieritas dapat diartikan bahwa antar peubah mempunyai pola hubungan linier  $Y_i = \beta_0 + \beta_1 X_{1i} + \varepsilon_i$ . Jika hubungan antara peubah tidak linier, hasil analisis regresi akan di bawah duga. Untuk mendeteksi linieritas dapat digunakan beberapa metode yaitu (Montgomery and Peck, 1991) :

#### a. Metode Grafik

Melalui metode ini, pemeriksaan dilakukan melalui diagram pencar untuk melihat apakah hubungan antar peubah linier atau tidak. Diagram pencar menunjukkan hubungan antara nilai prediksi dengan galat yang menunjukkan pola acak.

#### b. Perbandingan nilai $R^2$

Nilai  $R^2$  adalah persentase kemampuan peubah bebas menerangkan peubah respon. Semakin besar nilai  $R^2$ , maka semakin baik persamaan yang terbentuk.

#### c. Uji $F$

Statistik Uji  $F$  dapat dijadikan sebagai salah satu pertimbangan untuk menentukan apakah data yang digunakan adalah linier atau tidak. Untuk mengetahui apakah antar peubah mempunyai pola hubungan linier atau tidak, dilakukan pengujian terhadap hipotesis :

$H_0$ : model linier

$H_1$ : model tidak linier

Statistik uji  $F$  didapatkan dari rumus :

$$F_{hitung} = \frac{\text{Kuadrat Tengah Linieritas}}{\text{Kuadrat Tengah Galat}} \quad (2.4)$$

di mana :

$$KT_L = \frac{JK_L}{db_L} = \frac{\sum(Y_i - \bar{Y})^2 - \sum_x \left\{ \sum Y_i^2 - \frac{(\sum Y_i)^2}{n} \right\}}{k-2} \quad (2.5)$$

$$KT_G = \frac{JK_G}{db_G} = \frac{\sum_x \left\{ \sum Y_i^2 - \frac{(\sum Y_i)^2}{n} \right\}}{n-k} \quad (2.6)$$

Jika  $F_{hitung} < F_{tabel}$  maka model hubungan yang teridentifikasi adalah linier.

## 2. Asumsi Kenormalan Galat

Galat atau  $\varepsilon_i$  merupakan peubah acak normal dengan nilai tengah (*mean*) nol dan ragam sebesar  $\sigma^2$ , atau  $E(\varepsilon_i) = 0$ ,  $var(\varepsilon_i) = \sigma^2$ . Kenormalan dari galat tersebut berpengaruh terhadap hasil dari pendugaan parameter, yaitu menyebabkan keputusan yang di bawah duga atau kelebihan duga terhadap taraf nyata percobaan atau  $\alpha$ . Untuk mengetahui apakah galat menyebar normal atau tidak, dilakukan pengujian terhadap hipotesis :

$H_0$ : galat menyebar normal

$H_1$ : galat tidak menyebar normal

Salah satu metode yang digunakan adalah uji *Anderson-Darling* dengan statistik uji :

$$A^2 = -N - \left( \frac{1}{N} \right) \sum (2i - 1) (\ln F(Y_i) + \ln(1 - F(Y_{N+1-i}))) \quad (2.7)$$

di mana  $A$  menyebar *Anderson Darling* dan  $F$  adalah fungsi sebaran kumulatif dari sebaran normal dan  $Y_i$  adalah nilai pengamatan ke- $i$ .

Kriteria yang digunakan dalam pengambilan keputusan adalah

$$A^2 \begin{cases} \leq A_\alpha; H_0 \text{ diterima} \\ > A_\alpha; H_0 \text{ ditolak} \end{cases} \quad (2.8)$$

(Drapper dan Smith, 1992).

## 3. Asumsi Autokorelasi

Satu dari asumsi penting dari model regresi linier klasik adalah bahwa galat  $\varepsilon_{it}$  yang masuk ke dalam fungsi regresi populasi adalah random atau tak berkorelasi. Jika asumsi ini dilanggar, maka terdapat masalah autokorelasi (Nachrowi dan Usman, 2006). Untuk mengetahui ada tidaknya autokorelasi pada model, dapat dilihat dari statistik uji *Durbin-Watson*, dengan hipotesis sebagai berikut :

$H_0$  : tidak ada autokorelasi baik positif atau korelasi negatif

$H_1$  : Ada autokorelasi baik positif atau korelasi negatif

Pengujian dilakukan dengan membandingkan statistik uji *Durbin-Watson* ( $d$ ) dengan nilai batas atas (*Upper Limit/*  $d_U$ ) dan nilai batas bawah (*Lower Limit/*  $d_L$ ) pada tabel dengan banyaknya pengamatan  $n$ , banyaknya peubah bebas  $k$  dan tingkat signifikansi (taraf nyata)  $\alpha$ , dengan kriteria pengujian sebagai berikut :

- $d < d_L$  : Tolak  $H_0$  (terdapat autokorelasi positif)
- $d \geq 4-d_L$  : Tolak  $H_0$  (terdapat autokorelasi negatif)
- $d_U < d < 4- d_U$  : Terima  $H_0$  (tidak terdapat autokorelasi)
- $d_L \leq d \leq d_U$  atau  $4- d_U \leq d \leq 4- d_L$

Di mana pada umumnya statistik uji *Durbin-Watson* dirumuskan sebagai berikut :

$$d = \frac{\sum_{i=2}^N (\hat{\varepsilon}_i - \hat{\varepsilon}_{(i-1)})}{\sum_{i=1}^N \hat{\varepsilon}_i} \quad (2.9)$$

#### 4. Asumsi Multikolinieritas

Multikolinieritas adalah adanya hubungan linier antara peubah bebas dalam model regresi. Salah satu cara yang digunakan untuk mendeteksi adanya masalah ini adalah dengan melihat nilai VIF (*Variance Inflation Factor*), apabila nilai  $VIF \leq 10$  disimpulkan tidak terjadi muktikolinieritas, namun jika nilai  $VIF > 10$  maka disimpulkan terjadi multikolinieritas. Di mana  $VIF_j = \frac{1}{(1-R_j^2)}$ , dan  $R_j^2$  adalah koefisien determinasi antara peubah bebas ke- $j$  dengan peubah bebas lainnya (Nachrowi dan Usman, 2006).

#### 5. Asumsi Homoskedastisitas

Menurut Gujarati (1991), homoskedastisitas adalah keadaan di mana masing-masing galat mempunyai ragam yang sama atau konstan, yaitu:  $var(\varepsilon_{it}) = \sigma^2$ . Konsekuensi adanya heteroskedastisitas adalah nilai penduga parameter

regresi yang didapatkan dari OLS tidak lagi efisien. Salah satu cara untuk mengetahui ada tidaknya heteroskedastisitas, adalah melalui uji *White*.

Pendeteksian kehomogenan ragam galat dengan menggunakan uji *White* diperlukan adanya *auxiliary regression*. Fungsi dari *auxiliary regression* tersebut adalah untuk menghasilkan nilai  $R^2$ . *Auxiliary regression* dilakukan dengan meregresikan galat kuadrat ( $\hat{\varepsilon}_i^2$ ) dengan peubah bebas, peubah bebas yang dikuadratkan, dan hasil kali silang peubah bebas.

Sebagai ilustrasi, pertimbangkan model regresi pada persamaan berikut :

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + \varepsilon_i \quad (2.10)$$

*Auxiliary regression* dapat dilakukan setelah persamaan tersebut diduga dengan menggunakan Metode Kuadrat Terkecil (MKT) atau *Ordinary Least Square* (OLS). Galat yang diperoleh dikuadratkan dan diregresikan berdasarkan persamaan regresi berikut :

$$\begin{aligned} \hat{\varepsilon}_i^2 = & \alpha_0 + \alpha_1 X_{1i} + \alpha_2 X_{2i} + \dots + \alpha_k X_{ki} + \alpha_{k+1} X_{1i}^2 + \\ & \alpha_{k+2} X_{2i}^2 + \dots + \alpha_{k+k} X_{k+1}^2 + \alpha_{k+k+1} X_{1i} X_{2i} + \\ & \alpha_{k+k+2} X_{1i} X_{3i} + \dots + \alpha_{k+k+k} C_2 X_{ki} X_{ki} + v_i \end{aligned} \quad (2.11)$$

di mana :

$k$  = banyak peubah bebas

${}_k C_2$  = banyak kombinasi hasil kali silang peubah bebas

Dari *auxiliary regression* akan diperoleh nilai  $R^2$  (koefisien determinasi) yang akan dijadikan sebagai statistik uji dalam uji *White*.

### 2.3 Konsep Dasar Homoskedastisitas


Salah satu asumsi utama dalam model regresi adalah homoskedastisitas yang menyatakan bahwa ragam galat  $\varepsilon_i$ , adalah sama atau konstan untuk semua nilai  $X$ , sebesar  $\sigma^2$ . Secara sistematis dapat dituliskan :

$$\begin{aligned} var(\varepsilon_i) &= E(\varepsilon_i - E(\varepsilon_i))^2 \\ &= E(\varepsilon_i^2) - E(\varepsilon_i)^2 \\ &= E(\varepsilon_i^2) - 0 \\ &= E(\varepsilon_i^2) \end{aligned}$$


$$= \sigma^2 \quad (2.12)$$

di mana  $E(\varepsilon_i) = 0$ , berarti ragam dari  $\varepsilon_i$  konstan sebesar  $\sigma^2$  dari pengamatan satu ke pengamatan yang lain. Jadi berapapun nilai  $X$ , ragamnya tidak berubah. Kondisi sebaliknya yaitu bila ragam galat  $var(\varepsilon_i) = E(\varepsilon_i^2) = \sigma_i^2$  untuk setiap nilai  $i$ , dinamakan heteroskedastisitas di mana ragam galat  $\varepsilon_i$  tidak lagi konstan (Gujarati, 2004).

Dalam bentuk diagram, dengan menggunakan regresi satu peubah  $Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i$ . Gambar 2.1 menunjukkan kondisi homoskedastisitas, di mana ragam bersyarat dari  $Y_i$  bergantung pada nilai  $X_i$ , tetap sama tanpa melihat nilai yang diambil untuk peubah  $X$ . Sebaliknya, Gambar 2.2 menunjukkan bahwa ragam bersyarat dari  $Y_i$  meningkat dengan meningkatnya  $X_i$ , sehingga ragam tidak sama yang menunjukkan kondisi heteroskedastisitas.

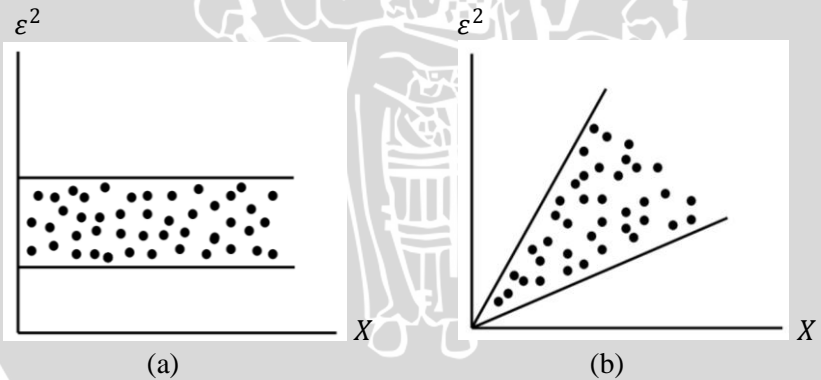


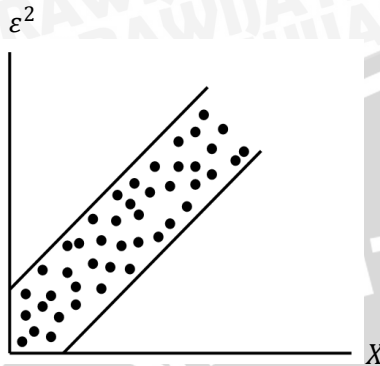
Gambar 2.1. Kondisi Homoskedastisitas



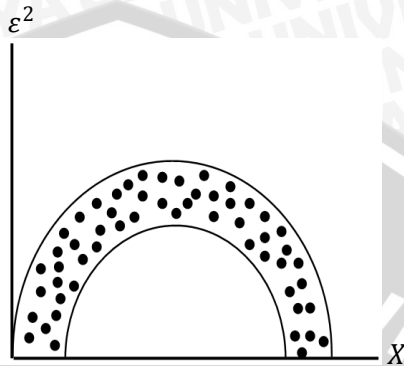
Gambar 2.2. Kondisi Heteroskedastisitas

Beberapa pola heteroskedastisitas dapat dilihat pada Gambar 2.3, yaitu dengan memetakan  $\varepsilon^2$  dengan peubah bebas  $X$ .






(c)



(d)



(e)

Gambar 2.3 Diagram pencar residual kuadrat yang ditaksir terhadap  $X$   
 Sumber : Gujarati, 2006

Dalam Gambar 2.3(a) tidak terdapat heteroskedastisitas karena tidak terdapat pola dalam plot, sedangkan Gambar 2.3(b) hingga 2.3(e) menunjukkan adanya pola dalam plot sehingga terdapat heteroskedastisitas dalam model regresi.

Menurut Sumodiningrat (1994), jika masalah heteroskedastisitas tidak dikoreksi, penggunaan hasil regresi akan berpengaruh pada ketelitian interval kepercayaan dan pengujian hipotesis. Heteroskedastisitas tidak mempengaruhi sifat tak bias dan konsistensi dari koefisien regresi, namun berpengaruh pada *Standard Error* yang mana nilai *Standard Error* pada situasi heteroskedastisitas lebih besar daripada situasi homoskedastisitas, sehingga tidak efisien.



## 2.4 Ordinary Least Square (OLS)

Pendugaan parameter untuk persamaan regresi linier sederhana biasa menggunakan OLS di mana nilai dari Jumlah Kuadrat Galat (JKG) akan menjadi minimum. Drapper dan Smith (1992) menyatakan bahwa pola hubungan antara peubah  $Y$  dan  $X$  yang bersifat linier dan sederhana dapat dimodelkan seperti Persamaan (2.3) di mana  $i = 1, 2, 3, \dots, n$ , sehingga JKG pada pengamatan-pengamatan garis regresi sebenarnya adalah :

$$S = \sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n (Y_i - \beta_0 - \beta_1 X_i)^2 \quad (2.13)$$

Sebagai nilai dugaan  $\beta_0$  dan  $\beta_1$ , dipilih nilai  $\hat{\beta}_0$  dan  $\hat{\beta}_1$ . Untuk menentukan nilai  $\hat{\beta}_0$  dan  $\hat{\beta}_1$ , Persamaan (2.13) dideferensial parsial terhadap  $\beta_0$  dan  $\beta_1$  dan kemudian menyamakan hasil diferensial dengan nol, sehingga :

$$\frac{\partial S}{\partial \beta_0} = -2 \sum_{i=1}^n (Y_i - \beta_0 - \beta_1 X_i) \quad (2.14)$$

$$\frac{\partial S}{\partial \beta_1} = -2 \sum_{i=1}^n X_i (Y_i - \beta_0 - \beta_1 X_i) \quad (2.15)$$

sehingga nilai dugaan  $\hat{\beta}_0$  dan  $\hat{\beta}_1$  dapat diperoleh dari :

$$\begin{aligned} \sum_{i=1}^n Y_i - n\hat{\beta}_0 - \hat{\beta}_1 \sum_{i=1}^n X_i &= 0 \\ \sum_{i=1}^n X_i Y_i - \hat{\beta}_0 \sum_{i=1}^n X_i - \hat{\beta}_1 \sum_{i=1}^n X_i^2 &= 0 \end{aligned} \quad (2.16)$$

atau

$$\begin{aligned} \hat{\beta}_0 n + \hat{\beta}_1 \sum_{i=1}^n X_i &= \sum_{i=1}^n Y_i \\ \hat{\beta}_0 \sum_{i=1}^n X_i + \hat{\beta}_1 \sum_{i=1}^n X_i^2 &= \sum_{i=1}^n X_i Y_i \end{aligned} \quad (2.17)$$

Persamaan (2.17) disebut dengan persamaan normal.

Penyelesaian dari Persamaan (2.17) untuk menentukan nilai  $\hat{\beta}_0$  dan  $\hat{\beta}_1$  adalah :

$$\hat{\beta}_0 = \bar{Y} - \hat{\beta}_1 \bar{X} \quad (2.18)$$

$$\hat{\beta}_1 = \frac{\sum_{i=1}^n X_i Y_i - [(\sum_{i=1}^n X_i)(\sum_{i=1}^n Y_i)]}{\sum_{i=1}^n X_i^2 - (\sum_{i=1}^n X_i)^2} \quad (2.19)$$

Model dugaan untuk regresi linier sederhana adalah :

$$\begin{aligned} \hat{Y} &= \hat{\beta}_0 + \hat{\beta}_1 X \\ &= \bar{Y} - \hat{\beta}_1 \bar{X} + \hat{\beta}_1 X \\ &= \bar{Y} - \hat{\beta}_1 (\bar{X} - X) \end{aligned} \quad (2.20)$$

Berdasarkan Persamaan (2.20), OLS terkait dengan konsep rata-rata karena garis regresi tepat melalui titik  $(\bar{X}, \bar{Y})$ .

### 2.4.1 Pendugaan *Ordinary Least Square* (OLS)

Salah satu metode yang dapat digunakan untuk menduga parameter bagi persamaan regresi adalah Metode Kuadrat Terkecil (MKT) atau *Ordinary Least Square* (OLS). Ada beberapa asumsi-asumsi terhadap  $\varepsilon_i$  agar hasil pengujian bagi parameter-parameter dalam regresi linier sederhana bersifat sah, antara lain :

1.  $(\varepsilon_i) = 0$  , nilai tengah galat adalah nol untuk semua  $i$  ( $i = 1, 2, \dots, n$ )
2.  $var(\varepsilon_i) = \sigma^2$ , ragam galat konstan sebesar  $\sigma^2$  untuk semua  $i$  ( $i = 1, 2, \dots, n$ ), dikenal dengan homoskedastisitas.
3.  $cov(\varepsilon_i, \varepsilon_j) = 0$ , tidak terdapat korelasi antar galat untuk  $i \neq j$ , dikenal dengan autokorelasi.
4.  $\varepsilon_i \sim N(0, \sigma^2)$ , galat menyebar normal dengan rata-rata 0 dan ragam  $\sigma^2$ .

Bila asumsi-asumsi ini terpenuhi, maka OLS akan menghasilkan pendugaan parameter yang memberikan jumlah kuadrat simpangan atau galat yang sekecil-kecilnya (Kmenta, 1990).

Yitnosumarto (1990) menyebutkan bahwa sifat-sifat penduga parameter dengan OLS antara lain :

#### 1. Tak Bias

Penduga parameter dikatakan tak bias jika penduga mendekati nilai sebenarnya dari parameter yang diduga. Misalkan  $\hat{\beta}$  penduga tak bias dari parameter  $\beta$  maka :

$$E(\hat{\beta}) = \beta \quad (2.21)$$

#### 2. Efisien

Penduga parameter dikatakan efisien jika ragamnya lebih kecil daripada ragam penduga parameter yang lain. Misalkan  $\hat{\beta}_0$  dengan ragam  $var(\hat{\beta}_0)$  dan  $\hat{\beta}_1$  dengan ragam  $var(\hat{\beta}_1)$ , adalah penduga untuk parameter tak bias untuk  $\beta$ , maka  $\hat{\beta}_0$  dikatakan lebih efisien dari  $\hat{\beta}_1$  apabila :

$$var(\hat{\beta}_0) \leq var(\hat{\beta}_1) \quad (2.22)$$

#### 3. Konsisten

Penduga parameter dikatakan konsisten jika semakin mendekati parameter yang diduga dengan semakin besarnya ukuran contoh  $n$ . Misal  $\hat{\beta}$ , merupakan penduga yang konsisten jika  $\hat{\beta} \rightarrow \theta$  dengan  $n \rightarrow \infty$ . Secara matematis dapat dituliskan :

$$\lim_{n \rightarrow \infty} P(|\hat{\beta}_n - \beta| < \varepsilon) = 1 \quad (2.23)$$

#### 2.4.2 Pendugaan OLS pada Keberadaan Heteroskedastisitas

Konsekuensi dari keadaan heteroskedastisitas adalah batas-batas keyakinan dan uji hipotesis tidak akan bisa diterapkan. Artinya jika ragam dari penduga model tidak memenuhi asumsi homoskedastisitas, maka pendugaan mengenai koefisien populasi keliru atau tidak valid. Selain itu, peramalan yang didasarkan pada pendugaan tersebut juga akan tidak bias. Tetapi karena penduga yang digunakan tidak efisien, maka peramalan juga akan tidak efisien (Ramanathan, 1992).

Berikut ini akan diperlihatkan apakah OLS masih tetap memberikan penduga yang memenuhi sifat-sifat yang baik apabila terjadi heteroskedastisitas.

##### a. Tak bias

Menurut Ghosh (1991), penduga  $\hat{\beta}$  dikatakan penduga tak bias dari parameter  $\beta$  kalau nilai harapan  $\hat{\beta}$  sama dengan parameter  $\beta$ , yaitu  $E(\hat{\beta}) = \beta$ .

$$\begin{aligned} \hat{\beta} &= (X'X)^{-1}(X'Y) \\ &= (X'X)^{-1}X'(X\beta + \varepsilon) \\ &= (X'X)^{-1}(X'X)\beta + (X'X)^{-1}(X'\varepsilon) \\ &= \beta + (X'X)^{-1}(X'\varepsilon) \end{aligned} \quad (2.24)$$

$$\begin{aligned} E(\hat{\beta}) &= E[\beta + (X'X)^{-1}(X'\varepsilon)] \\ &= E(\beta) + (X'X)^{-1}X'E(\varepsilon) \\ &= \beta + \mathbf{0} \\ &= \beta \end{aligned} \quad (2.25)$$

Sifat ketidakhacian tidak memerlukan bahwa galat,  $\varepsilon_i$ , adalah homoskedastisitas sehingga meskipun dibawah kondisi heteroskedastisitas, OLS memberikan penduga yang tidak bias.

##### b. Efisien

Menurut Ghosh (1991), jika asumsi klasik dari model regresi linier terpenuhi, maka,

$$\text{var}(\boldsymbol{\varepsilon}) = E(\boldsymbol{\varepsilon}\boldsymbol{\varepsilon}') = \sigma^2 \mathbf{I} = \begin{bmatrix} \sigma^2 & 0 & 0 & \dots & 0 \\ 0 & \sigma^2 & 0 & \dots & 0 \\ 0 & 0 & \sigma^2 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & \sigma^2 \end{bmatrix}$$

(2.26)

Sedangkan, jika tidak memenuhi asumsi homoskedastisitas, maka,

$$\text{var}(\boldsymbol{\varepsilon}) = E(\boldsymbol{\varepsilon}\boldsymbol{\varepsilon}') = \sigma^2 \boldsymbol{\Omega} = \begin{bmatrix} \sigma_1^2 & 0 & 0 & \dots & 0 \\ 0 & \sigma_2^2 & 0 & \dots & 0 \\ 0 & 0 & \sigma_3^2 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & \sigma_n^2 \end{bmatrix}$$

$$= \sigma^2 \begin{bmatrix} \omega_1 & 0 & 0 & \dots & 0 \\ 0 & \omega_2 & 0 & \dots & 0 \\ 0 & 0 & \omega_3 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & \omega_n \end{bmatrix} \quad (2.27)$$

di mana  $\sigma_i^2 = \sigma^2 \omega_i$ ,  $i = 1, 2, \dots, n$ , sehingga

$$\begin{aligned} \text{var}(\hat{\boldsymbol{\beta}}) &= E[(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta})(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta})'] \\ &= E\{[(X'X)^{-1}X'Y - \boldsymbol{\beta}][(X'X)^{-1}X'Y - \boldsymbol{\beta}']\} \\ &= E\{[(X'X)^{-1}X'(X\boldsymbol{\beta} + \boldsymbol{\varepsilon}) - \boldsymbol{\beta}][(X'X)^{-1}X'(X\boldsymbol{\beta} + \boldsymbol{\varepsilon} - \boldsymbol{\beta}')]\} \\ &= E\{[(X'X)^{-1}(X'X)\boldsymbol{\beta} + (X'X)^{-1}X'\boldsymbol{\varepsilon} - \boldsymbol{\beta}X'X - \mathbf{1}X'X\boldsymbol{\beta} + X'X - \mathbf{1}X'\boldsymbol{\varepsilon} - \boldsymbol{\beta}']\} \\ &= E\{[(X'X)^{-1}X'\boldsymbol{\varepsilon}][(X'X)^{-1}X'\boldsymbol{\varepsilon}']\} \\ &= E\{[(X'X)^{-1}X'\boldsymbol{\varepsilon}\boldsymbol{\varepsilon}'X(X'X)^{-1}]\} \\ &= (X'X)^{-1}X'E(\boldsymbol{\varepsilon}'\boldsymbol{\varepsilon})X(X'X)^{-1} \end{aligned} \quad (2.28)$$

$$\begin{aligned} \text{var}(\hat{\boldsymbol{\beta}}) &= (X'X)^{-1}X'\sigma^2\boldsymbol{\Omega}X(X'X)^{-1} \\ &= \sigma^2(X'X)^{-1}X'\boldsymbol{\Omega}X(X'X)^{-1} \\ &= \text{var}(\hat{\boldsymbol{\beta}}_{\text{homo}})X'\boldsymbol{\Omega}X(X'X)^{-1} \end{aligned} \quad (2.29)$$

di mana  $var(\hat{\beta}_{homo})$  adalah ragam  $\hat{\beta}$  dengan asumsi homoskedastisitas. Jadi ragam  $\hat{\beta}$  dengan heteroskedastisitas akan lebih besar daripada ragam  $\hat{\beta}$  dengan homoskedastisitas. Berarti dibawah kondisi heteroskedastisitas, penduga parameter dengan menggunakan OLS tidak lagi bersifat efisien.

c. Konsisten

OLS dikatakan konsisten apabila  $E(\hat{\beta}) = \beta$  dan  $\lim_{n \rightarrow \infty} var(\hat{\beta}) = 0$

$$\lim_{n \rightarrow \infty} \sigma^2 (X'X)^{-1} X' \Omega X (X'X)^{-1} = 0$$

$$\lim_{n \rightarrow \infty} \frac{\sigma^2}{n} \left( \frac{X'X}{n} \right)^{-1} \left( \frac{X' \Omega X}{n} \right) \left( \frac{X'X}{n} \right)^{-1} = 0 \quad (2.30)$$

$$\text{Jika } \lim_{n \rightarrow \infty} \frac{\sigma^2}{n} = 0, \quad (2.31)$$

$\lim_{n \rightarrow \infty} \left( \frac{X'X}{n} \right)^{-1}$  dan  $\lim_{n \rightarrow \infty} \left( \frac{X' \Omega X}{n} \right)$  nilainya terbatas, maka  $\hat{\beta}$  merupakan penduga yang konsisten (Daniel, 2002).

Menurut Gujarati dan Porter (2010), penduga *Ordinary Least Square* (OLS) dan nilai ragamnya jika memiliki kondisi heteroskedastisitas dengan menganggap  $E(\varepsilon_i^2) = \sigma_i^2$ , tetapi tetap mempertahankan semua asumsi model klasik lainnya adalah dengan memperhatikan kembali model dua peubah berikut:

$$Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i \quad (2.32)$$

sehingga didapat penduga OLS dari  $\beta_1$  adalah

$$\hat{\beta}_1 = \frac{\sum x_i y_i}{\sum x_i^2} = \frac{n \sum X_i Y_i - \sum X_i \sum Y_i}{n \sum X_i^2 - (\sum X_i)^2} \quad (2.33)$$

akan tetapi, kini ragamnya diekspresikan sebagai berikut :

$$\begin{aligned} var(\hat{\beta}_1) &= E(k_1^2 u_1^2 + k_2^2 u_2^2 + \dots + k_n^2 u_n^2 + 2 \text{ produk silang}) \\ &= E(k_1^2 u_1^2 + k_2^2 u_2^2 + \dots + k_n^2 u_n^2) \end{aligned} \quad (2.34)$$

oleh karena ekspektasi dari produk silang adalah nol akibat dari asumsi tidak ada korelasi serial atau autokorelasi, maka

$$\begin{aligned} var(\hat{\beta}_1) &= k_1^2 E(u_1^2) + k_2^2 E(u_2^2) + \dots + k_n^2 E(u_n^2) \\ &= k_1^2 \sigma_1^2 + k_2^2 \sigma_2^2 + \dots + k_n^2 \sigma_n^2 \end{aligned} \quad (2.35)$$

$$var(\hat{\beta}_1) = \sum k_i^2 \sigma_i^2 = \sum \left[ \left( \frac{x_i}{\sum x_i^2} \right)^2 \sigma_i^2 \right] = \frac{\sum x_i^2 \sigma_i^2}{(\sum x_i^2)^2} \quad (2.36)$$

di mana jelas berbeda dari formula ragam umum yang didapatkan di bawah asumsi homoskedastisitas, yaitu

$$\text{var}(\hat{\beta}_1) = \frac{\sigma^2}{\sum x_i^2} \quad (2.37)$$

$\hat{\beta}_1$  adalah penduga terbaik, linier, dan tidak bias atau bersifat *Best Linear Unbiased Estimator* (BLUE).

## 2.5 Uji Parsial Model Regresi

Uji parsial digunakan untuk menguji apakah sebuah peubah bebas  $X$  benar-benar memberikan kontribusi terhadap peubah respon  $Y$ . Dalam pengujian ini ingin diketahui apakah jika secara terpisah, suatu peubah bebas  $X$  masih memberikan kontribusi secara signifikan terhadap peubah respon  $Y$ .

Hipotesis untuk uji ini adalah :

$$H_0 : \beta_1 = 0$$

$$H_1 : \beta_1 \neq 0$$

Uji parsial ini menggunakan uji  $t$ , yaitu :

$$t_{hitung} = \frac{|\hat{\beta}_1 - \beta_1|}{se(\hat{\beta}_1)} \sim t_{tabel} (n - 2) \quad (2.38)$$

jika  $t_{hitung} \leq t_{tabel} (n - 2)$ , maka terima  $H_0$ .

jika  $t_{hitung} > t_{tabel} (n - 2)$ , maka tolak  $H_0$ .

Apabila  $H_0$  ditolak, maka peubah bebas  $X$  tersebut memiliki kontribusi yang signifikan terhadap peubah respon  $Y$  (Montgomery and Peck, 1991).

## 2.6 Uji Simultan Model Regresi

Uji simultan (bersama-sama) pada konsep regresi linier adalah pengujian mengenai apakah model regresi yang didapatkan benar-benar dapat diterima. Uji simultan bertujuan untuk menguji apakah antara peubah bebas  $X$  dan respon  $Y$ , atau setidaknya-tidaknya antara salah satu peubah  $X$  dengan peubah respon  $Y$ , benar-benar terdapat hubungan linier (*linear relation*).

Hipotesis yang berlaku untuk pengujian ini adalah :

$$H_0 : \beta_1 = 0$$

$$H_1 : \beta_1 \neq 0$$

Penjabaran secara hitungan untuk uji simultan ini dapat ditemui pada Tabel 2.1.

Tabel 2.1 Tabel ANOVA (*Analysis Of Variance*) Uji Simultan Regresi Linier

SK	db	JK	KT	$F_{hitung}$
Regresi	1	$JK_{Reg}$	$KT_{Reg}$	$KT_{Reg}/KT_R$
Residual	$n - 2$	$JK_R$	$KT_R$	
Total	$n - 1$	$JK_T$		

di mana :

$$JK_{Reg} = \hat{\beta}_1 \left( \sum_{i=1}^n x_i y_i - \frac{(\sum_{i=1}^n y_i)(\sum_{i=1}^n x_i)}{n} \right) \quad (2.39)$$

$$JK_R = \sum_{i=1}^n y_i^2 - \frac{(\sum_{i=1}^n y_i)^2}{n} - \hat{\beta}_1 \left( \sum_{i=1}^n x_i y_i - \frac{(\sum_{i=1}^n y_i)(\sum_{i=1}^n x_i)}{n} \right) \quad (2.40)$$

$$JK_T = \sum_{i=1}^n y_i^2 - \frac{(\sum_{i=1}^n y_i)^2}{n} \quad (2.41)$$

$$KT_{Reg} = \frac{JK_{Reg}}{db_{Reg}} = \frac{JK_{Reg}}{1} \quad (2.42)$$

$$KT_R = \frac{JK_R}{db_R} = \frac{JK_R}{n-1} \quad (2.43)$$

Di dalam tabel ANOVA akan ditemui nilai  $F_{hitung}$ , di mana :

jika  $F_{hitung} \leq F_{tabel}(db_{Reg}, db_R)$ , maka terima  $H_0$ ,

jika  $F_{hitung} > F_{tabel}(db_{Reg}, db_R)$ , maka tolak  $H_0$ .

Apabila  $H_0$  ditolak, maka model regresi yang diperoleh dapat digunakan (Montgomery and Peck, 1991).

Menurut Gujarati (1991), terdapat hubungan antara uji  $F$  dengan uji  $t$  pada analisis regresi linier sederhana, dapat ditunjukkan bahwa kuadrat nilai  $t$  dengan derajat kebebasan  $N - k$  adalah nilai  $F$  dengan derajat kebebasan 1 dan  $N - k$ . Sehingga pada analisis regresi linier sederhana, nilai  $t^2$  sama dengan nilai  $F$ .

## 2.7 Uji Heteroskedastisitas *White*

Metode *White* merupakan salah satu metode yang digunakan untuk mendeteksi kehomogenan ragam galat. Metode ini mudah diterapkan daripada metode lain. Fomby (2006) menunjukkan bahwa Metode *White* sudah dipelajari sejak 1980 dan metode ini sering disebut dengan uji *White*. Uji ini menggunakan galat dalam pengujiannya. Pendeteksian kehomogenan ragam galat dengan menggunakan uji *White* tidak memerlukan asumsi yang spesifik (Jeeshim, 2003).

Uji *White* sering digunakan pada sampel besar yaitu sampel yang mempunyai banyak pengamatan ( $n$ ) lebih dari atau sama dengan tiga puluh. Dalam uji *White* menggunakan *auxiliary regression* yaitu dengan meregresikan galat kuadrat ( $\hat{\epsilon}_i^2$ ) dengan semua peubah bebas, peubah bebas yang dikuadratkan, dan hasil kali silang peubah bebas. Kemudian dari regresi tersebut didapatkan nilai  $R^2$  yang digunakan sebagai statistik uji (Ramanathan, 1992).

Koefisien determinasi ( $R^2$ ) adalah ukuran kecukupan dari sebuah model. Koefisien determinasi mengukur keragaman di sekitar nilai tengah yang dapat dijelaskan oleh regresi tersebut. Koefisien determinasi dirumuskan dengan :

$$R^2 = \frac{JKR}{JKT} = \frac{\sum(\hat{Y}_i - \bar{Y})^2}{\sum(Y_i - \bar{Y})^2} \quad (2.44)$$

di mana JKR adalah jumlah kuadrat regresi, dan JKT adalah jumlah kuadrat total (Montgomery and Peck, 1991).

Pengujian umum yang dikemukakan oleh *White* tidak bergantung asumsi normalitas dan mudah untuk diimplementasikan. Sebagai ilustrasi dari ide dasarnya, kita perhatikan model regresi dengan satu peubah bebas :

$$Y_i = \beta_0 + \beta_1 X_{1i} \quad (2.45)$$

Prosedur pengujian uji *White* adalah sebagai berikut :

Langkah 1. Dari hasil pendugaan model regresi pada Persamaan (2.45), didapatkan nilai residualnya,  $\hat{\epsilon}_i$ .

Langkah 2. Kemudian dilakukan *auxiliary regression* sebagai berikut :

$$\hat{\epsilon}_i^2 = \alpha_0 + \alpha_1 X_{1i} + \alpha_2 X_{1i}^2 \quad (2.46)$$

Hal ini berarti bahwa residual yang dikuadratkan dari regresi awal data diregresikan terhadap peubah  $X$  awal, nilai-nilai  $X$  yang dikuadratkan, dan produk silang dari peubah  $X$ . Regresi dengan pangkat yang lebih tinggi juga dapat digunakan. Kemudian dapatkan nilai  $R^2$  dari regresi pada Persamaan (2.46).

Langkah 3. Hipotesis pendeteksian kehomogenan ragam galat dengan menggunakan uji *White* adalah sebagai berikut :

$H_0 : \alpha_1 = 0$  (kondisi homoskedastisitas) vs

$H_1 : \alpha_1 \neq 0$  (kondisi heteroskedastisitas)

Apabila  $H_0$  benar maka statistik uji *White* merupakan perkalian dari banyaknya pengamatan ( $n$ ) dengan nilai  $R^2$  yang diperoleh dari *auxiliary regression* pada Persamaan (2.46), yaitu :



$$\chi^{2*} = n \cdot R^2 \sim \chi_m^2 \quad (2.47)$$

di mana  $m$  adalah banyak peubah bebas dalam *auxiliary regression*. Langkah 4. Kaidah pengambilan keputusan dengan menggunakan tabel kritis  $\chi^2$  yaitu:

$$\chi^{2*} \begin{cases} \leq \chi_{m(\alpha)}^2, H_0 \text{ diterima} \\ > \chi_{m(\alpha)}^2, H_0 \text{ ditolak} \end{cases} \quad (2.48)$$

Jika nilai *chi-square* yang didapatkan dari Persamaan (2.47) lebih besar dari nilai *chi-square* kritis pada tingkat signifikansi yang dipilih, maka terdapat heteroskedastisitas. Sebaliknya, jika nilainya lebih kecil dari *chi-square* kritis, maka tidak terdapat heteroskedastisitas (Gujarati, 2004).

## 2.8 White's Robust Standard Error

Metode *White's Robust Standard Error* digunakan apabila  $\sigma_i^2$  tidak diketahui dan untuk memperoleh penduga ragam dan peragam dari penduga OLS yang konsisten jika terdapat masalah heteroskedastisitas. *White* telah menunjukkan bahwa pendugaan ini dapat dilakukan sehingga, secara asimtotik, inferensi statistik yang valid mengenai nilai-nilai parameter yang sebenarnya dapat dibuat. Metode ini juga dikenal dengan nama *White's Robust Standard Error*.

Sebagai ilustrasi dari ide dasar metode *White's Robust Standard Error*, perhatikan model regresi dua peubah berikut :

$$Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i \quad (2.49)$$

$$\text{var}(\varepsilon_i) = \sigma_i^2 \quad (2.50)$$

Seperti ditunjukkan pada Persamaan (2.36),

$$\text{var}(\hat{\beta}_1) = \frac{\sum x_i^2 \sigma_i^2}{(\sum x_i^2)^2} \quad (2.51)$$

Oleh karena  $\sigma_i^2$  tidak dapat diobservasi secara langsung, *White* menyarankan untuk menggunakan  $\varepsilon_i^2$ , residual kuadrat untuk setiap  $i$ , untuk menggantikan  $\sigma_i^2$  dan menduga  $\text{var}(\hat{\beta}_1)$  sebagai berikut:

$$\text{var}(\hat{\beta}_1) = \frac{\sum x_i^2 \varepsilon_i^2}{(\sum x_i^2)^2} \quad (2.52)$$

*White* telah menunjukkan bahwa Persamaan (2.52) merupakan penduga yang konsisten dari Persamaan (2.51), yaitu seiring dengan meningkatnya sampel secara tidak hingga, Persamaan (2.52) mengerucut ke Persamaan (2.51) (Gujarati dan Porter, 2010).

Hubungan antara  $\sigma_i^2$  dengan satu atau beberapa peubah bebas dapat diperkirakan karena residual kuadrat  $\varepsilon_i^2$  diperoleh dari regresi pada metode OLS yang merupakan penduga bagi  $\sigma_i^2$  apabila fungsi regresi ini telah sesuai. Ragam dari residual  $\varepsilon_i$  apabila terdapat masalah heteroskedastisitas adalah  $\sigma_i^2$ , dapat dinyatakan sebagai berikut :

$$\sigma_i^2 = E\{\varepsilon_i^2\} - (E\{\varepsilon_i\})^2 \quad (2.53)$$

di mana  $E\{\varepsilon_i\} = 0$  sesuai dengan model regresi, dapat diperoleh :

$$\sigma_i^2 = E\{\varepsilon_i^2\} \quad (2.54)$$

Oleh karena itu, residual kuadrat  $\varepsilon_i^2$  merupakan penduga bagi  $\sigma_i^2$ .

Pada kondisi heteroskedastisitas, penduga koefisien regresi yang dihasilkan dari metode OLS tetap bersifat tak bias dan konsisten, tetapi tidak lagi mempunyai ragam penduga yang minimum. Sehingga rumus ragam penduganya dapat ditulis sebagai berikut :

$$\text{var}(\hat{\beta}) = (X'X)^{-1}X'\sigma^2\Omega X(X'X)^{-1} \quad (2.55)$$

Jika ragam galat tidak sama dan tidak diketahui, penduga yang sesuai dari  $\text{var}(\hat{\beta})$  dapat diduga menggunakan metode *White's Robust Standard Error*, dengan rumus sebagai berikut :

$$\text{var}(\hat{\beta}) = (X'X)^{-1}X'S_0X(X'X)^{-1} \quad (2.56)$$

di mana :

$$S_0 = \begin{bmatrix} \varepsilon_1^2 & 0 & \dots & 0 \\ 0 & \varepsilon_2^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \varepsilon_n^2 \end{bmatrix} \quad (2.57)$$

Nilai  $\varepsilon_1, \dots, \varepsilon_n$  adalah penduga residual dari metode OLS. Metode *White's Robust Standard Error* dapat digunakan untuk membuat kesimpulan tentang parameter regresi yang sesuai jika didasarkan pada metode OLS, tanpa harus menentukan bentuk ragam kesalahan yang tidak konstan (Kurtner, M.H., C.J. Nachtsheim, J. Neter, and W. Li, 2005).

Menurut Asteriou and Hall (2007), nilai *Standard Error* dari penduga koefisien metode *Ordinary Least Square* (OLS) pada masalah heteroskedastisitas adalah tidak benar, sehingga pada metode *White's Robust Standard Error* dilakukan koreksi terhadap nilai *Standard Error*. Nilai *Standard Error* yang dihasilkan dapat

lebih besar atau lebih kecil daripada metode OLS. Untuk menghasilkan penduga yang lebih akurat, nilai *Standard Error* pada metode *White's Robust Standard Error* seharusnya lebih besar daripada *Standard Error* pada metode OLS. Peningkatan nilai *Standard Error* membuat nilai pada uji *t* atau *F* menurun serta selang kepercayaan menjadi lebih lebar yang mencerminkan sifat data yang sebenarnya. Oleh karena itu, hasil dari metode *White's Robust Standard Error* akan menghasilkan penduga yang lebih baik dan menghasilkan informasi yang valid.

## 2.9 Kriteria Keberartian Model

### 2.9.1 *Standard Error* (SE)

*Standard Error* adalah galat dari  $\hat{Y}$ . Ukuran ini dipakai sebagai salah satu kriteria evaluasi model, dengan rumus :

$$SE = \sqrt{\frac{\sum_{i=1}^n \varepsilon_i^2}{n-k}} = \sqrt{KTG} \quad (2.58)$$

di mana :

$\varepsilon_i$  : galat pada observasi ke- $i$  ( $i = 1, 2, \dots, n$ ).

$n$  : banyaknya observasi.

$k$  : banyaknya parameter regresi yang diduga.

KTG : Kuadrat Tengah Galat penduga model regresi.

KTG dihitung dengan rumus  $KTG = \frac{JKG}{db \text{ galat}}$  (Gujarati, 2004).

### 2.9.2 *P-Value*

*P-value* merupakan taraf keberartian terkecil sehingga nilai statistik uji yang diperoleh masih berarti dan dihitung berdasarkan peluang eksak berlandaskan statistik uji yang digunakan (Walpole, 1995). *P-value* menunjukkan tingkat terkecil untuk menolak  $H_0$ . Secara umum, jika *P-value* kurang dari atau sama dengan  $\alpha$  maka  $H_0$  akan ditolak. Sedangkan jika *P-value* melampaui  $\alpha$  maka  $H_0$  tidak dapat ditolak.

Menurut Hines dan Montgomery (1990), keuntungan dari *P-value* adalah tidak hanya menentukan hasil dalam suatu pengambilan keputusan tentang  $H_0$ , tetapi juga memberikan informasi tentang kuatnya keputusan yang diambil. Selain itu, dengan *P-value* juga dapat diketahui besarnya resiko salah secara eksak dalam pengambilan keputusan. Sehingga dalam berbagai pengujian, *P-*

*value* sering digunakan sebagai indikator dalam pengambilan keputusan. Semakin kecil *P-value* maka semakin kecil peluang untuk membuat kesalahan dengan menolak  $H_0$ .

*P-value* yang sangat kecil, misal 0.001 menunjukkan bahwa terdapat kemungkinan kecil untuk menolak  $H_0$  yang benar yaitu sebesar 0.001. *P-value* dapat diperoleh dengan menghitung :

$$\begin{aligned} P - value &= P[|t| \geq t_{hitung}] \\ &= P[t \leq -t_{hitung}] + P[t \geq t_{hitung}] \\ &= 2 \times P[t \geq t_{hitung}] \quad (2.59) \end{aligned}$$

Kemudian *P-value* dibandingkan dengan  $\alpha$ . Mengenai besarnya nilai  $\alpha$ , yang dapat digunakan sebagai pembanding bagi *P-value*, tergantung pada seberapa besar resiko salah yang masih ditolerir menurut jenis penelitian yang dilakukan (Johnson and Bhattacharyya, 1985).

