

B A B II  
KONSEP PENUNJANG

II.1 Aljabar Matriks

Definisi 1 :

Matriks A berukuran (  $m \times n$  ), berarti banyaknya baris matriks A adalah m dan banyaknya kolom adalah n

$$A = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \cdot & \cdot & \cdot & \cdot \\ a_{m1} & a_{m2} & \dots & a_{mn} \end{bmatrix}$$

Definisi 2 :

Vektor adalah matriks berukuran (  $n \times 1$  ) atau matriks berukuran (  $1 \times n$  ).

Definisi 3 :

Matriks satuan ( identitas ) adalah matriks bujur sangkar yang elemen diagonal utamanya = 1 dan elemen lainnya = 0.

Definisi 4 :

Rank matriks A ditulis  $r(A)$  adalah menyatakan jumlah maksimal vektor baris/kolom dari matriks A yang bebas linier.

Definisi 5 :

Suatu matriks bujur sangkar A disebut matriks non singular apabila  $\det(A) \neq 0$ .

Definisi 6 :

Suatu vektor V dikatakan sebagai kombinasi linier dari vektor-vektor  $\{\beta_1, \beta_2, \beta_3, \dots, \beta_n\}$ .

sedemikian hingga  $V = \sum_{i=1}^n c_i \beta_i$ .

**Definisi 7 :**

Setiap himpunan n vektor yang bebas linier dari vektor-vektor  $\{\beta_1, \beta_2, \dots, \beta_n\}$  dari ruang vektor berdimensi n, disebut basis dari ruang vektor.

**Definisi 8 :**

Suatu ruang vektor V dikatakan berdimensi n, bila banyaknya maksimal vektor  $\in V$  yang bebas linier adalah n.

**Definisi 9 :**

Jika  $V_s \subset V_r \subset V_n$ , maka seluruh vektor  $V_r$  yang tegak lurus ke  $V_s$ , dikatakan orthocomplement dari  $V_s$  didalam  $V_r$ .

**Definisi 10 :**

Bentuk kuadrat pada n variabel  $X_1, X_2, \dots, X_n$  adalah sebuah fungsi berbentuk :

$$Q = \sum_{i=1}^n \sum_{j=1}^n a_{ij} X_i X_j, \text{ dimana } (a_{ij}) \text{ konstan.}$$

**Teorema I :**

Untuk beberapa real (A), matriks  $AA'$  adalah simetris, positif indefinite dan mempunyai rank yang sama dengan rank matriks A.

**Teorema II :**

Jika  $V_r \subset V_n, r > 0$ .  $V_r$  dibentuk oleh :

$\{\alpha_1, \alpha_2, \alpha_3, \dots, \alpha_n\}$  dan  $X \in V_r$ , maka koefisien didalam  $X = a_1\alpha_1 + a_2\alpha_2 + \dots + a_s\alpha_s$  adalah tunggal bbb  $s = r$  dan  $\{\alpha_1, \alpha_2, \dots, \alpha_s\}$ .

**Teorema III :**

Orthocomplement dari  $V_s$  dalam  $V_r$  dari definisi diatas adalah ruang bagian vektor dari  $V_r$  yang mempunyai dimensi  $( r - s )$ .

**II.2 Model Matematika Dari Analisa Varian**

Didalam menghadapi persoalan Analisa Varian adalah mungkin untuk menggambarkan bahwa pengamatan yang diambil dapat dinyatakan dalam suatu bentuk model matematika.

**Definisi :**

Andaikan dipunyai  $n$  pengamatan yang merupakan random variabel  $Y_1, Y_2, \dots, Y_n$ , dimana setiap pengamatan dapat dinyatakan sebagai kombinasi linier dari sembarang  $p$  harga tidak diketahui

$\beta_1, \beta_2, \dots, \beta_p$  ditambah dengan kesalahan sedemikian hingga :

$$Y_i = x_{1i} \beta_1 + x_{2i} \beta_2 + \dots + x_{pi} \beta_p + e_i \quad (II.2.1)$$

$i = 1, 2, \dots, n$

Model analisa varian, dibawah anggapan  $\Omega$  :

$$\Omega : \begin{cases} Y_i = \sum_{j=1}^p x_{ji} \beta_j + e_i \\ \quad \quad \quad i = 1, 2, \dots, n \\ \quad \quad \quad j = 1, 2, \dots, p \\ e_i \sim NID(0, \sigma^2) \end{cases} \dots\dots (II.2.2)$$

dengan :

$Y_i$  : harga pengamatan ke- $i$

$x_{ji}$  : koefisien konstant

$\beta_j$  : efek-efek

$e_i$  : kesalahan acak

Karena  $\{e_i\}$  berdistribusi NID  $(0, \sigma^2)$  dengan demikian maka  $\{Y_i\}$  berdistribusi NID  $(\mu_i = E(Y_i), \sigma^2)$ , dimana fungsi padat dari  $\{Y_i\}$  adalah :

$$p(Y_i) = (2\pi \sigma^2)^{-n/2} \exp - \frac{\sum_{i=1}^n (Y_i - \mu_i)^2}{2 \sigma^2}$$

Untuk mempermudah didalam membicarakan teori secara umum, digunakan vektor dan aljabar matriks.

Didefinisikan vektor-vektor :

$$Y^{n \times 1} = \begin{bmatrix} Y_1 \\ Y_2 \\ \cdot \\ \cdot \\ Y_n \end{bmatrix}, \quad \beta^{p \times 1} = \begin{bmatrix} \beta_1 \\ \beta_2 \\ \cdot \\ \cdot \\ \beta_p \end{bmatrix}, \quad e^{n \times 1} = \begin{bmatrix} e_1 \\ e_2 \\ \cdot \\ \cdot \\ e_n \end{bmatrix}$$

dan matriks :

$$X' \text{ berukuran } (p \times n) = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1n} \\ x_{21} & x_{22} & \dots & x_{2n} \\ \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \dots & \cdot \\ x_{p1} & x_{p2} & \dots & x_{pn} \end{bmatrix}$$

Misal rank  $X' = r$ , dari definisi diatas persamaan (II.2.2) dapat ditulis dalam bentuk :

$$\Omega: \begin{cases} Y = X' \beta + e, \text{ rank } X' = r \\ \{e\} \sim \text{NID}(0, \sigma^2) \end{cases} \dots \dots \dots \text{(II.2.3)}$$

Matriks Random Variabel

**Definisi :** Diberikan suatu matriks  $V^{r \times s}$  adalah matriks dari ran-  
dom variabel  $\{v_{ij}\}$  dengan harga harapan berhingga,

$$V = \begin{bmatrix} v_{11} & v_{12} & \dots & v_{1s} \\ v_{21} & v_{22} & \dots & v_{2s} \\ \cdot & & & \\ \cdot & & & \\ v_{r1} & v_{r2} & \dots & v_{rs} \end{bmatrix}$$

maka didefinisikan harga harapan dari matriks V :

$$E(V) = \begin{bmatrix} E(v_{11}) & E(v_{12}) & \dots & E(v_{1s}) \\ E(v_{21}) & E(v_{22}) & \dots & E(v_{2s}) \\ \cdot & & & \\ \cdot & & & \\ E(v_{r1}) & E(v_{r2}) & \dots & E(v_{rs}) \end{bmatrix} \quad (II.2.4)$$

Definisi :

Diberikan vektor  $V = ( v_1 , v_2 , \dots , v_n )'$  dari variabel-variabel random dengan varian ber-hingga. Maka yang disebut dengan matriks covarian dari V adalah :  $\Sigma_V = ( cov(v_i, v_j) )$  (II.2.5)

Andaikan :  $\mu_i = E(v_i)$ , maka  $cov(v_i, v_j)$

$Cov ( v_i , v_j ) = E ( ( v_i - \mu_i ) ( v_j - \mu_j ) )$ , sehingga dengan menggunakan (II.2.3) dapat ditulis :

$$\Sigma_V = E ( ( V - \mu ) ( V - \mu )' ) \quad (II.2.6)$$

dengan :  $\mu = E ( V )$ .

Lemma :

Jika matriks A berukuran ( q x r ) dan matriks B berukuran ( s x t ) adalah matriks-matriks konstant dan matriks V berukuran ( r x s ) adalah matriks random variabel, maka berlaku :

$$E ( A V B ) = A E(V) B \dots \dots \dots (II.2.7)$$

Teorema :

Jika  $W^{m \times 1} = A^{m \times n} \cdot V^{n \times 1}$  adalah transformasi linier dari  $n$  variabel random  $V_1, V_2, \dots, V_n$  ke  $m$  variabel  $W_1, W_2, \dots, W_m$  dengan matriks  $A$ , maka matriks covarian dari  $W$  adalah :

$$\Sigma_W = A \Sigma_V A' \dots \dots \dots (II.2.8)$$

Bukti :

$$\begin{aligned} \Sigma_W &= E ( ( W - E(W))( W - E(W) )' ) \\ &= E ( A ( V - E(V))( V - E(V))' A' ) \\ &= A E ( ( V - E(V) )( V - E(V))' ) A' \\ &= A \Sigma_V A'. \end{aligned}$$

### II.3 Estimasi Kuadrat Terkecil Dan Persamaan Normal

Diketahui :  $Y^{n \times 1} = X' \beta^{p \times 1} + e^{n \times 1}$

dengan :  $E ( e ) = 0$  dan  $E ( ee' ) = \sigma^2 I$

Sehingga terlihat bahwa :  $E ( Y ) = X' \beta$  dan  $\Sigma_Y = \sigma^2 I$ .

Andaikan  $b_1, b_2, \dots, b_p$  adalah estimasi-estimasi dari  $\beta_1, \beta_2, \dots, \beta_p$  yang mungkin, dengan  $\beta_1, \beta_2, \dots, \beta_p$  adalah konstanta tetap adalah estimasi terbaik dalam hal-hal tertentu. Untuk setiap  $b = ( b_1, b_2, \dots, b_p )'$ , dibentuk :

$$J ( Y, b ) = \sum_{i=1}^n \hat{e}_i^2 = \sum_{i=1}^n ( Y_i - \sum_{j=1}^p x_{ji} b_j )^2 \quad (II.3.1)$$

dengan :

$\hat{e}_i$  adalah estimasi dari  $e_i$ , dalam pengamatan  $Y_i$  pada

(II.2.1) jika  $b$  adalah estimasi dari  $\beta$ . Sebagai ukuran dapat diperhatikan bahwa makin kecil harga  $\hat{e}$ , maka model dengan  $\beta$  akan menghasilkan estimasi  $b$  yang lebih tepat pada pengamatan-pengamatan. Dengan notasi matriks dapat di-

tulis :  $S(Y, b) = (Y - X'b)'(Y - X'b)$

Atau jika panjang vektor V ditulis sebagai  $V$  , maka :

$S(Y, b) = \|Y - X'b\|^2$  .....(II.3.2)

Definisi :

Suatu himpunan fungsi-fungsi dari vektor Y, yaitu himpunan dari statistik  $\hat{\beta}_1 = \hat{\beta}_1(Y), \dots, \hat{\beta}_p = \hat{\beta}_p(Y)$  sedemikian hingga harga  $b_j = \hat{\beta}_j$  , (  $j=1,2,\dots,p$  ) menentukan harga minimum dari  $S(Y, b)$  disebut himpunan dari estimasi-estimasi kuadrat terkecil dari  $\{\beta_j\}$  .

Persamaan Normal

Dapat diperlihatkan bahwa estimasi kuadrat terkecil dari  $\{\beta_j\}$  selalu ada, tetapi tidak perlu tunggal dan setiap himpunan estimasi kuadrat terkecil dari  $\{\beta_j\}$  akan memenuhi persamaan :

$\frac{\partial S(Y, b)}{\partial b_v} = 0$ , untuk  $v = 1, 2, \dots, p$

sehingga didapatkan :

$- 2 \sum_{i=1}^n (Y_i - \sum_{j=1}^p x_{ji} b_j) x_{vj} = 0$ , atau :  
 $\sum_{i=1}^n \sum_{j=1}^p x_{vj} x_{ji} b_j = \sum_{i=1}^n x_{vj} Y_i$  ,  $v=1,2,\dots,p$  .....(II.3.3)

Secara matriks dapat ditulis :  $X X' b = X Y$

dan jika diambil  $R = X X'$ , maka :

$R b = X Y$  .....(II.3.4)

Persamaan yang disajikan diatas ini disebut persamaan normal.

Sekarang dimisalkan simbol  $\hat{\beta}$  sebagai sembarang penyelesaian untuk b, dan  $\hat{\beta}$  adalah estimasi kuadrat terkecil dari  $\beta$  , maka dapat dibuktikan  $\hat{\beta} = \hat{\beta}$  atau setiap pe

nyelelesaian persamaan-persamaan normal merupakan himpunan dari estimasi kuadrat terkecil dan sebaliknya.

Bukti :

Dipandang ruang vektor  $V_n$  berdimensi  $n$  dan vektor  $\eta = E ( Y )$  sedemikian hingga :

$$\eta^{nx1} = X' \beta \dots\dots\dots(II.3.5)$$

yang dapat juga ditulis sebagai :

$$\eta = \beta_1 \xi_1 + \beta_2 \xi_2 + \dots\dots\dots + \beta_p \xi_p$$

dengan :  $\xi_j^{nx1}$  adalah vektor kolom ke- $j$  dari  $X'$ .

Andaikan  $r$  adalah rank dari  $X$  dan  $V_r$  adalah ruang vektor yang dibentuk oleh vektor  $\xi_1, \xi_2, \dots, \xi_p$ .

Maka suatu vektor  $z^{nx1}$  termuat dalam  $V_r$  bbb terdapat koefisien-koefisien  $b_1, b_2, \dots, b_p$  sedemikian hingga :

$$z = \sum_{i=1}^p b_i \xi_i$$

Pada khususnya :  $\eta \in V_r$  menurut (II.3.5). Ambil  $Z = X'b$ , maka dapat ditunjukkan bahwa  $\mathcal{J}(Y, B) = \|Y - Z\|^2$  mempunyai harga minimal bbb vektor  $Z$  adalah vektor  $\hat{\eta}$

yang didefinisikan sebagai proyeksi dari vektor  $Y$  pada  $V_r$ . Karena  $\hat{\eta} \in V_r$ , maka terdapat  $b_1, b_2, \dots, b_p$

sedemikian hingga :

$$\hat{\eta} = b_1 \xi_1 + b_2 \xi_2 + \dots\dots\dots + b_p \xi_p \dots\dots\dots(II.3.6)$$

Terlihat bahwa  $\hat{\eta}$  tunggal, tetapi  $\{b_j\}$  pada umumnya tidak perlu tunggal. Karena  $\hat{\eta}$  adalah suatu fungsi dari  $Y$  saja dan bukan fungsi dari parameter-parameter, maka  $\{b_j\}$  pada (II.2.6) dapat dinyatakan sebagai fungsi dari  $Y$  saja dan mereka adalah estimasi kuadrat terkecil.

Selanjutnya sembarang  $( b_1, b_2, \dots, b_p )$  yang hanya merupakan fungsi dari  $Y$  saja merupakan esti-



$$X' b = \hat{\eta}$$

$$(Y - X' b) \perp V_r$$

$$(Y - X' b) \perp \hat{\beta}_j, \text{ untuk } j=1,2,\dots,p \quad \dots\dots\dots(\text{II.3.7})$$

$$\hat{\beta}_j' (Y - X' b) = 0, \text{ untuk } j=1,2,\dots,p$$

$$X (Y - X' b) = 0$$

$$X X' b = X Y \quad \quad \quad (\text{II.3.8})$$

Dari (II.3.8) disimpulkan bahwa  $b$  memenuhi persamaan-persamaan normal, sehingga bukti selesai.

Dengan demikian telah dibuktikan bahwa estimasi kuadrat terkecil  $\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_p$  selalu ada dimana setiap himpunan estimasi kuadrat terkecil persamaan normal dan setiap penyelesaian  $\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_p$  dari persamaan-persamaan normal yang merupakan fungsi dari  $Y$  saja adalah suatu himpunan dari estimasi kuadrat terkecil. Jadi simbol  $\hat{\beta}$  tidak perlu digunakan lagi dan  $\hat{\beta}$  dianggap sebagai penyelesaian dari persamaan normal yang juga merupakan suatu himpunan dari estimasi kuadrat terkecil.

Definisi :

Akan digunakan simbol  $A_n$  sebagai harga minimal dari  $A(Y, b)$ . Jadi  $A_n = A(Y, \hat{\beta}) \dots(\text{II.3.9})$  dimana  $\hat{\beta}$  adalah sembarang himpunan dari estimasi kuadrat terkecil, atau sembarang penyelesaian dari persamaan-persamaan normal.  $A_n$  didefinisikan sebagai jumlah kuadrat dari kesalahan.

#### Keadaan Dimana $\hat{\beta}$ Adalah Tunggal

Bentuk dimana matriks  $X$  yang berukuran  $(p \times n)$  mempunyai rank  $p$  disebut bentuk matriks dengan rank maksimal, sebab pada umumnya  $p \geq n$ . Jika rank matriks  $X = p$ , maka persamaan (II.3.4) mempunyai penyelesaian tunggal. Dengan

Karena dalam hal ini  $R$  adalah matriks yang non singular, maka  $R^{-1}$  ada, sehingga penyelesaian yang tunggal dapat ditunjukkan dengan :  $\hat{\beta} = R^{-1} X Y$  ..... (II.3.10)

Dengan menggunakan (II.2.8) didapat matriks kovarian dari  $\hat{\beta}$ , yaitu :  $\Sigma_{\hat{\beta}} = (R^{-1} X)' \Sigma_y (R^{-1} X)$ .

Tetapi karena  $R^{-1}$  adalah matriks simetris, jadi :

$$\Sigma_{\hat{\beta}} = \sigma^2 R^{-1} X X' R^{-1}$$

$$\Sigma_{\hat{\beta}} = \sigma^2 R^{-1}.$$

#### II.4 Fungsi Estimabel Dan Teorema Gauss Markoff

Definisi :

Suatu fungsi  $\psi$  dikatakan merupakan fungsi parametrik jika untuk parameter-parameter  $(\beta_1, \dots, \beta_p)$ ,

$$\text{maka : } \psi = \sum_{j=1}^p c_j \beta_j \quad (\text{II.4.1})$$

dimana  $(c_1, c_2, \dots, c_p)$  adalah konstanta.

Jika vektor  $C^{p \times 1} = (c_1, c_2, \dots, c_p)'$ , maka

$$(\text{II.4.1}) \text{ dapat ditulis sebagai } \psi = C'\beta.$$

Definisi :

Suatu fungsi parametrik  $\psi$  disebut fungsi yang estimabel jika  $\psi$  mempunyai suatu estimasi tak bias yang linier atau jika dapat ditemukan suatu vektor koefisien konstan  $a^{n \times 1}$  sedemikian hingga :

$$E(a' Y) = \psi \quad \dots \dots \dots (\text{II.4.2})$$

Teorema 1 :

Fungsi parametrik  $\psi = C'\beta$  adalah estimabel bbb  $C'$  adalah suatu kombinasi linier dari baris - baris matriks  $X'$ .

Bukti :

$\psi = C'\beta$  adalah estimabel bbb terdapat vektor  $a^{n \times 1}$

Karena  $E(a'Y) = a'E(Y) = a'X'\beta = C'\beta$  dipenuhi untuk setiap  $\beta$ , maka berlaku  $a'X' = C'$ .

Jadi  $C'$  kombinasi linier dari baris-baris  $X'$ .

Lemma :

Jika  $\psi = C'\beta$  adalah estimabel dan  $V_p$  ruang vektor yang dihasilkan oleh vektor-vektor kolom dari matriks  $X'$ , maka terdapat dengan tunggal estimasi tak bias linier dari  $\psi$ , katakan  $(a^*)'Y$ ,  $a^* \in V_p$ .

Jika  $a'Y$  adalah sebagai estimasi tak bias linier dari  $\psi$ , maka  $a^*$  adalah proyeksi dari  $a$  pada  $V_p$ .

Bukti :

Karena  $\psi$  adalah estimabel, terdapat vektor  $a^{n \times 1}$  sedemikian hingga  $E(a'Y) = \psi$ . Ambil  $a = a^* + b$  dimana  $a^* \in V_p$  dan  $b \perp V_p$ , maka  $\psi = E(a'Y) = E((a^*)'Y) + E(b'Y) = E((a^*)'Y)$ . Hal ini disebabkan karena  $E(b'Y) = b'X'\beta$  dan  $b'X' = 0$ . Dengan demikian  $(a^*)'Y$  adalah suatu estimasi tak bias linier dari  $\psi$ , dengan  $a^* \in V_p$ . Andaikan sekurang hal yang sama berlaku untuk  $\alpha'Y$ , maka untuk setiap  $\beta$  berlaku :

$$0 = E(a^*'Y) - E(\alpha'Y) = (a^*' - \alpha')E(Y) \\ = (a^* - \alpha)'X'\beta \text{ sehingga } (a^* - \alpha)'X' = 0.$$

Jadi  $(a^* - \alpha) \perp V_p$  dan  $(a^* - \alpha) \in V_p$ , jadi  $a^* - \alpha = 0$ . Terbukti  $(a^*)'Y$  adalah tunggal.

Teorema 2 :

Dibawah anggapan  $\Omega: E(Y) = X'\beta$ ;  $\Sigma_y = \sigma^2 I$  setiap fungsi estimabel  $\psi = a'\beta$  mempunyai estimasi tak bias linier yang tunggal  $\hat{\psi}$  yang mempunyai varian minimal pada kelas dari setiap estimasi tak bias linier, dimana estimasi  $\hat{\psi}$  dapat dihasilkan dari

himpunan estimasi (  $\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_p$  ).

Bukti :

Andaikan  $(a^*)' Y$  adalah estimasi tak bias linier dari  $\mathcal{Y}$  dengan  $a^* \in V_r$ , dimana adanya dan tunggalnya terbukti dari teorema diatas. Dan andaikan pula bahwa  $a' Y$  sembarang estimasi tak bias linier dari  $\mathcal{Y}$ . Maka  $a^*$  adalah proyeksi dari  $a$  pada  $V_r$  dan  $\|a\|^2 = \|a^*\|^2 + \|a - a^*\|^2$ .

Dengan menggunakan (II.1.8) untuk  $m = 1$ , didapat:

$$\begin{aligned} \text{Var} ( a' Y ) &= a' \Sigma_Y a = \sigma^2 \|a\|^2 \\ &= \sigma^2 \|a^*\|^2 + \sigma^2 \|a - a^*\|^2 \\ &= \text{Var} ( (a^*)' Y ) + \sigma^2 \|a - a^*\|^2 \end{aligned}$$

Sehingga :  $\text{Var} ( a' Y ) \geq \text{Var} ( (a^*)' Y )$ , dengan

$\text{Var} ( a' Y ) = \text{Var} ( (a^*)' Y )$  hanya jika  $a = a^*$ .

Karena  $(a^*)' Y$  adalah estimasi tak bias linier dari  $\mathcal{Y}$  dengan varian minimal dimana  $(a^*)' Y$  adalah tunggal, maka dapat dibuktikan  $(a^*)' Y = C' \hat{\beta}$ .

Sekarang  $(a^*)' ( Y - \hat{\eta} ) = 0$  dengan  $\hat{\eta} = X' \hat{\beta}$  adalah proyeksi dari  $Y$  pada  $V_r$ , karena  $a^* \in V_r$  dan  $( Y - \hat{\eta} ) \perp V_r$ . Karena  $C' \hat{\beta} = E ( (a^*)' Y ) = (a^*)' X' \beta$  untuk sembarang  $\beta$ , maka  $C' = (a^*)' X'$ , sehingga :  $(a^*)' Y = (a^*)' \hat{\eta} = (a^*)' X' \hat{\beta} = C' \hat{\beta}$ .

Definisi :

Setiap fungsi estimabel  $\mathcal{Y}$  dengan varian minimum, estimasi tak bias linier  $\hat{\mathcal{Y}}$  yang tunggal disebut estimasi kuadrat terkecil dari  $\mathcal{Y}$ .

Sekarang sudah dipunyai  $\{ \hat{\beta}_j \}$  adalah estimasi kuadrat terkecil dari  $\{ \beta_j \}$ , maka dapat diperluas dengan menyatakan :

$$\sum_{j=1}^p c_j \hat{\beta}_j \text{ sebagai estimasi kuadrat terkecil dari semba-}$$

rang fungsi linier  $\sum_{j=1}^p c_j \beta_j$ , jika  $\{\hat{\beta}_j\}$  adalah sembarang himpunan estimasi kuadrat terkecil dari  $\{\beta_j\}$ .

Selanjutnya dikatakan bahwa estimasi kuadrat terkecil dari  $\sum_{j=1}^p c_j \beta_j$  adalah tunggal bbb  $\sum_{j=1}^p c_j \beta_j$  estimabel.

## II.5 Bentuk Kanonik $\Omega$ . Mean Square Untuk Kesalahan

Diketahui :  $\Omega \equiv E(Y) = X'\beta$ ,  $\Sigma_Y = \sigma^2 I$ , rank  $X' = r$ .

Dipandang ruang vektor  $V_n$  dengan vektor-vektor pengamatan  $Y^{n \times 1}$  punya basis orthonormal  $(\rho_1, \dots, \rho_n)$  dimana  $\rho_i = (\delta_{i1}, \delta_{i2}, \dots, \delta_{in})'$

sehingga  $Y = \sum_{i=1}^n Y_i \rho_i$ .

Dipandang juga  $(\alpha_1, \alpha_2, \dots, \alpha_r)$  adalah basis orthonormal untuk  $V_r$ , yaitu ruang vektor yang dibentuk oleh vektor-vektor kolom dari  $X'$ . Kemudian dilengkapi menjadi  $(\alpha_1, \dots, \alpha_r, \alpha_{r+1}, \dots, \alpha_n)$  untuk  $V_n$ .

Jika diambil :  $Y = \sum_{i=1}^n Z_i \alpha_i \dots \dots (II.5.1)$

dimana  $\{Z_i\}$  adalah koordinat dari  $Y$  relatif terhadap basis yang baru, sehingga :  $\alpha_i' Y = \sum_{i=1}^n \alpha_i' Z_i \alpha_i = Z_i$ .

Sehingga dapat ditulis  $Z = P Y$ , dimana  $P$  matriks orthogonal dengan baris ke- $i$  nya  $\alpha_i'$ .

Ambil  $\xi_i = E(Z_i)$ , maka  $\xi_i = E(\alpha_i' Y) = \alpha_i' E(Y) = \alpha_i' \eta$ . Karena  $\eta \in V_r$  maka  $\eta \perp \alpha_i$  untuk

$i > r$ , akibatnya  $\xi_i = 0$  untuk  $i > r$ . Dan matriks cova-

Dengan demikian bentuk kanoniknya :

$$\Omega \equiv \begin{cases} Z = ( Z_1 , Z_2 , \dots , Z_n )' \\ E ( Z_i ) = \xi_i , i = 1 , 2 , \dots , r \\ E ( Z_i ) = 0 , i = r+1 , r+2 , \dots , n \\ \Sigma_Z = \sigma^2 \cdot I \end{cases}$$

dimana  $\xi_1 , \xi_2 , \dots , \xi_r$  dan  $\sigma^2$  adalah parameter dan  $\{Z_i\}$  transformasi tertentu dari pengamatan Y.

### Estimasi Tak Bias Dari $\sigma^2$

Dipandang jumlah kuadrat kesalahan :

$$S_\Omega = \sum_{i=1}^n ( Y_i - \sum_{j=1}^p x_{ji} \hat{\beta}_j )^2 \quad (\text{II.5.2})$$

dimana  $\hat{\beta}_j$  adalah sembarang himpunan estimasi kuadrat terkecil dari  $\beta_j$ . Dapat juga ditulis  $S_\Omega = \|Y - \hat{\eta}\|^2$  dimana  $\hat{\eta}$  proyeksi dari Y pada  $V_r$ .

Karena  $Y = \sum_{i=1}^n Z_i \alpha_i$  dan  $\hat{\eta} = \sum_{i=1}^r Z_i \alpha_i$ , sedang basis dari bentuk kanoniknya adalah  $(\alpha_1, \alpha_2, \dots, \alpha_n)$

maka :

$$S_\Omega = \left\| \sum_{i=1}^n Z_i \alpha_i - \sum_{i=1}^r Z_i \alpha_i \right\|^2 = \left\| \sum_{i=r+1}^n Z_i \alpha_i \right\|^2,$$

$$\text{atau } S_\Omega = \sum_{i=r+1}^n Z_i^2 \cdot \dots \dots \dots (\text{II.5.3})$$

Sekarang jika  $i > r$ ,  $E ( Z_i ) = 0$ , mengakibatkan

$$E ( Z_i^2 ) = \text{Var} ( Z_i ) = \sigma^2. \text{ Sehingga dari persamaan}$$

$$(\text{II.5.3}) \text{ didapat : } E ( S_\Omega ) = (n-r) E ( Z_i^2 ) = (n-r) \sigma^2.$$

**Definisi :** UNDIP-IR may keep more than one copy of this submission for purpose of security, back-up and preservation.

$$s^2 = S_\Omega / (n-r) \text{ maka } E ( s^2 ) = E ( S_\Omega ) / (n-r).$$

$E ( s^2 ) = \sigma^2$ , maka  $s^2$  adalah estimasi tak bias dan

dari  $\sigma^2$  dimana  $s^2$  disebut mean square untuk kesalahan yang mempunyai derajat bebas  $(n - r)$ .

## II.6 Test Hipotesa H Ditentukan Dari Konfidensi Ellipsoid

Berdasarkan anggapan  $\Omega$ :  $Y$  adalah  $N(X; \beta^{p \times 1}, \sigma^2 I)$  dan  $\text{rank } X' = r$ , suatu hipotesa:  $H: \psi_1 = \dots = \psi_q = 0$  dengan  $(\psi_i)$  adalah fungsi-fungsi yang estimabel bebas linier, ditentukan oleh konfidensi ellipsoid:

$$(\hat{\psi} - \psi)' B^{-1} (\hat{\psi} - \psi) \leq q s^2 F_{\alpha, q, (n-r)}$$

H ditolak bbb konfidensi ellipsoid tidak memuat titik  $(\psi_1, \psi_2, \dots, \psi_q) = (0, 0, \dots, 0)$ .

Ini berarti bahwa H ditolak bbb:

$$\hat{\psi}' B^{-1} \hat{\psi} > q s^2 F_{\alpha, q, (n-r)} \quad \dots \dots \dots (II.6.1)$$

Jika H adalah benar, maka probabilitas menolak H adalah  $\alpha$ , sehingga tarap nyata untuk test hipotesa H adalah  $\alpha$ . Test hipotesa yang baru saja disajikan oleh hipotesa H, meliputi fungsi-fungsi estimabel  $(\psi_1, \dots, \psi_q)$  yang dipakai untuk mendefinisikan H. Berlaku juga untuk  $q$  fungsi estimabel yang lain  $(\psi_1^*, \psi_2^*, \dots, \psi_q^*)$  untuk mendefinisikan H.

## II.7 Test Yang Diturunkan Dengan Likelihood Ratio Statistik F

Prinsip likelihood ratio dapat digunakan untuk menurunkan bermacam-macam test statistik yang biasa dipakai.

Pada umumnya, jika dipikirkan untuk mengetest hipotesa H dengan dasar  $\Omega$  diberikan simbol:  $\omega = H \cap \Omega$ ,

Definisi :

Jika  $Y$  adalah pengamatan-pengamatan atau sampel dan  $p(Y)$  adalah fungsi kepadatan dari  $Y$ , maka likelihood ratio statistik  $\lambda$  untuk mengetest  $H$  adalah :

$\lambda = \max_{\omega} p(Y) / \max_{\Omega} p(Y)$ , dimana  $0 \leq \lambda \leq 1$ , karena setiap harga dari  $p(Y)$  yang mungkin dengan dasar  $\omega$ , adalah selalu mungkin dengan dasar  $\Omega$ .

Dengan likelihood ratio test, maka  $H$  ditolak jika  $\lambda < \lambda_0$ , dimana  $\lambda_0$  dipilih untuk menyatakan tarapnya yang layak.

Ada dua bentuk yang ekuivalen berdasar  $\Omega$  dan  $\omega$  dalam persoalan yang akan dihadapi, dimana untuk setiap bentuk  $Y$  berukuran  $(n \times 1)$  dan  $\omega = H \cap \Omega$ , yaitu :

- 1)  $\Omega$  :  $Y$  adalah  $N(X'\beta, \sigma^2 I)$ ,  $\text{rank } X^{p \times n} = r$   
 $H$  :  $\psi_1 = \psi_2 = \dots = \psi_q = 0$ , dimana  $(\psi_1)$  adalah  $q$  fungsi estimabel yang bebas linier.

- 2) Biasa dipakai dalam argumentasi geometrik :

$\Omega$  :  $Y$  adalah  $N(\eta, \sigma^2 I)$ ;  $\eta \in V_r \subset V_n$   
 $H$  :  $\eta \in V_{r-q} \subset V_r$ ; dimana  $V_r$  adalah ruang vektor yang dibentuk oleh kolom-kolom  $X'$ .

Untuk menentukan likelihood ratio statistik untuk mengetest  $H$  berdasarkan  $\Omega$ , ditentukan gabungan fungsi padat dari pengamatan-pengamatan.

$P(Y) = p_1(Y_1) \cdot p_2(Y_2) \cdot \dots \cdot p_n(Y_n)$ , dimana :

$$p_1(Y_1) = (2\pi\sigma^2)^{-n/2} \exp\left(-\frac{1}{2\sigma^2} \sum_{j=1}^p x_{j1}(\beta_j)^2\right)$$

$$p(Y) = (2\pi\sigma^2)^{-n/2} \exp\left(-\frac{1}{2\sigma^2} \mathcal{A}(Y, \beta)\right) \dots \text{(II.7.1)}$$

dengan  $\mathcal{A}(Y, \beta) = \|Y - X'\beta\|^2$ .

Andaikan  $\Omega = \Omega_1$ ;  $\omega = \Omega_2$ ;  $V_n = V_1$ ;



$V_{r-q} = V_2$ , maka akan dicari maksimum dari :

$$p(Y) = (2\pi\sigma^2)^{-n/2} \exp(-1/2\sigma^{-2} \|Y - \eta\|^2) \dots (II.7.2)$$

untuk  $0 < \sigma^2 < \infty$  dan  $\eta \in V_1, i = 1, 2$ .

1) Jika  $\sigma^2$  tetap maka (II.7.2) akan maksimal apabila  $\|Y - \eta\|^2$  minimal, jadi jika  $\eta$  proyeksi dari  $Y$  pada  $V$ , sehingga :

$$\max p(Y) = (2\pi\sigma^2)^{-n/2} \exp(-1/2 \mathcal{A}_{\Omega_i} / \sigma^2) \dots (II.7.3)$$

2) Jika  $\mathcal{A}_{\Omega_i}$  tetap :

$$\ln p(Y) = -n/2 \ln(2\pi\sigma^2) - 1/2(\mathcal{A}_{\Omega_i} / \sigma^2) \quad (II.7.4)$$

$$\partial \ln p(Y) / \partial \sigma^2 = -n/2\sigma^{-2} + \mathcal{A}_{\Omega_i} / 2\sigma^4 = 0.$$

$$\text{Jadi } n / 2\sigma^2 = \mathcal{A}_{\Omega_i} / 2\sigma^4, \text{ maka } 2n\sigma^4 = 2\sigma^2 \mathcal{A}_{\Omega_i}$$

$$\sigma^2 = \mathcal{A}_{\Omega_i} / n \quad \dots \dots \dots (II.7.5)$$

$$\partial^2 \ln p(Y) / \partial (\sigma^2)^2 = n / 2\sigma^4 - \mathcal{A}_{\Omega_i} / 2\sigma^6.$$

Untuk  $\sigma^2 = \mathcal{A}_{\Omega_i} / n$ , maka  $\partial \ln p(Y) / \partial (\sigma^2)^2 < 0$

Jadi (II.7.4) maksimum untuk  $\sigma^2 = \mathcal{A}_{\Omega_i} / n$ .

Sekarang (II.7.5) disubstitusikan ke (II.7.3) :

$$\max p(Y) = (2\pi \mathcal{A}_{\Omega_i} / n)^{-n/2} \exp(-n/2 \mathcal{A}_{\Omega_i} / \mathcal{A}_{\Omega_i})$$

$$\equiv (2\pi \mathcal{A}_{\Omega_i} / n)^{-n/2} \exp(-n/2)$$

$$\lambda = \frac{(2\pi \mathcal{A}_{\omega} / n)^{-n/2} \exp(-n/2)}{(2\pi \mathcal{A}_{\Omega} / n)^{-n/2} \exp(-n/2)}$$

$$= (\mathcal{A}_{\omega} / \mathcal{A}_{\Omega})^{-n/2} \quad (II.7.6)$$

$\hat{\eta}_{\Omega}$  adalah proyeksi dari  $Y$  pada  $V_r$  dan  $\hat{\eta}_{\omega}$  ada-

lah proyeksi dari  $Y$  pada  $V_{r-q}$ . Sehingga  $\mathcal{A}_{\Omega} = \|Y - \hat{\eta}_{\Omega}\|^2$

dan  $\mathcal{A}_{\omega} = \|Y - \hat{\eta}_{\omega}\|^2$  dalam konteks statistika.

$$F = (n - r) / q \cdot (\lambda_0 - \lambda) / \lambda \quad (II.7.7)$$

bisa dipakai disamping  $\lambda$ .

Hubungan F dan  $\lambda$  dapat ditulis :

$$F = F(\lambda) = (n - r) / q (\lambda^{-2/n} - 1).$$

Jika  $F_0 = F(\lambda_0)$  dan  $\lambda < \lambda_0$ , maka  $H$  ditolak bbb

$$F > F_0.$$

II.8 Bentuk Kanonik Untuk  $H$  dan  $\Omega$ . Distribusi Dari F.

Untuk ruang vektor  $V_{r-q} \subset V_r \subset V_n$ , maka dapat di tentukan basis orthonormal  $(\alpha_{q+1}, \alpha_{q+2}, \dots, \alpha_r)$

untuk  $V_{r-q}$ . Dapat diperluas menjadi basis orthonormal

$(\alpha_1, \dots, \alpha_q, \alpha_{q+1}, \dots, \alpha_r)$  untuk  $V_r$ , dan da

pat diperluas lagi menjadi basis orthonormal

$(\alpha_1, \dots, \alpha_q, \alpha_{q+1}, \dots, \alpha_r, \alpha_{r+1}, \dots, \alpha_n)$  untuk  $V_n$ .

Misal  $Z_1, Z_2, \dots, Z_n$  adalah koordinat  $Y$  rela- tip terhadap basis  $(\alpha_1, \alpha_2, \dots, \alpha_n)$ .

Maka bentuk kanoniknya :

$$\Omega : \begin{cases} Z_i \sim NID(\xi_i, \sigma^2) \\ \xi_{i+1} = \dots = \xi_n = 0 \\ \text{atau } E(Z_i) = 0, i > r \end{cases}$$

$$H : \xi_1 = \xi_2 = \dots = \xi_q = 0.$$

Karena  $\hat{\eta}_\Omega$  dan  $\hat{\eta}_\omega$  adalah proyeksi-proyeksi dari

$Y = \sum_{i=1}^n Z_i \alpha_i$  pada  $V_r$  dan  $V_{r-q}$ , maka :

$$\hat{\eta}_\Omega = \sum_{i=1}^r Z_i \alpha_i ; \hat{\eta}_\omega = \sum_{i=r+1}^n Z_i \alpha_i .$$

$$\begin{aligned}
 S_{\Omega} &= \|Y - \hat{\eta}_{\Omega}\|^2 = \left\| \sum_{i=r+1}^n z_i \alpha_i \right\|^2 \\
 &= \sum_{i=r+1}^n z_i^2 \quad \dots \dots \dots (II.8.1)
 \end{aligned}$$

$$\begin{aligned}
 S_{\omega} &= \|Y - \hat{\eta}_{\omega}\|^2 = \left\| \sum_{i=1}^q z_i \alpha_i + \sum_{i=r+1}^n z_i \alpha_i \right\|^2 \\
 &= \sum_{i=1}^q z_i^2 + \sum_{i=r+1}^n z_i^2 \quad \dots \dots \dots (II.8.2)
 \end{aligned}$$

$$\text{Maka : } S_{\omega} - S_{\Omega} = \sum_{i=1}^q z_i^2 \quad \dots \dots \dots (II.8.3)$$

### Teori Distribusi Berdasarkan $\Omega$

Himpunan random variabel ( $Z_{r+1}, Z_{r+2}, \dots, Z_n$ ) dan ( $Z_1, Z_2, \dots, Z_q$ ) pada (II.8.1) dan (II.8.2) adalah saling bebas, sehingga  $S_{\Omega}$  dan ( $S_{\omega} - S_{\Omega}$ ) adalah saling bebas pula. Karena  $E(Z_i) = 0$  untuk  $i > r$ , maka (II.8.1) didapat bahwa  $S_{\Omega} / \sigma^2$  didistribusikan menurut distribusi  $\chi^2_{(n-r)}$ .

$$\text{Karena } (S_{\omega} - S_{\Omega}) / \sigma^2 = \sum_{i=1}^q (Z_i / \sigma)^2$$

dimana  $Z_i / \sigma$  didistribusikan  $N(\mu_i / \sigma, 1)$  maka dari definisi "non central chi-square" didapat  $(S_{\omega} - S_{\Omega}) / \sigma^2$  didistribusikan  $\chi^2_{q, \delta}$  dimana non centrality parameter-nya

$$\text{adalah : } \delta = \left( \sum_{i=1}^q \mu_i^2 / \sigma^2 \right)^{1/2}.$$

Dan akhirnya dari definisi "non central F", maka :

$F = (n - r) / q \cdot (S_{\omega} - S_{\Omega}) / S_{\Omega}$  didistribusikan menurut distribusi  $F_{q, (n-r), \delta}$ .

Khusus berdasarkan  $\omega$ ,  $\delta = 0$  dan  $F_{q, (n-r), \delta}$  se -

hingga test F untuk  $H$  berdasar  $\Omega$  dengan tarap nyata  $\alpha$ ,

II.9 Ekuivalensi Dari Dua Buah Test

Telah diturunkan dua buah test berdasarkan  $\Omega$  : Y adalah  $N( X'\beta , \sigma^2 I )$  dan rank  $X' = r$ , dari hipotesa  $H : \psi_1 = \psi_2 = \dots = \psi_q = 0$ , dimana  $( \psi_i )$  adalah q buah fungsi estimabel yang bebas linier.

Test H dengan dasar konfidensi ellipsoid, H ditolak dengan tarap nyata  $\alpha$  bbb  $\hat{\psi}' B^{-1} \hat{\psi} > q s^2 F_{\alpha, q, (n-r)}$

dimana  $( \hat{\psi}_i )$  estimasi kuadrat terkecil dari  $( \psi_i )$ ,

$B = \sigma^{-2} \Sigma_{\hat{\psi}}$  dan  $s^2 = s_{\Omega} / ( n - r )$ .

Likelihood ratio test ( F - test ) dari H dengan tarap nyata  $\alpha$ , H ditolak bbb

$$\frac{n - r}{q} \frac{s_w - s_{\Omega}}{s_{\Omega}} > F_{\alpha, q, (n-r)}$$

Jadi  $s_w - s_{\Omega} > q s^2 F_{\alpha, q, (n-r)}$

Untuk membuktikan bahwa kedua test sama, cukup dibuktikan :  $\hat{\psi}' B^{-1} \hat{\psi} = s_w - s_{\Omega}$  ..... (II.9.1)

Bukti :

Dipilih himpunan  $( \psi_i^* )$  untuk mendefinisikan H, dimana

$\psi_i^* = \xi_i$ , yaitu  $E( Z_i )$  dimana  $Z_i$  adalah variabel kanonik. Berdasarkan  $\Omega$  setiap himpunan dari harga-harga  $( \xi_1, \xi_2, \dots, \xi_r )$  adalah mungkin, sebab  $\xi_i$  adalah koordinat ke-i dari  $\eta$  relatif terhadap basis orthonormal  $( \alpha_1, \alpha_2, \dots, \alpha_n )$  dimana

$( \alpha_1, \alpha_2, \dots, \alpha_r )$  menghasilkan  $V_r$  dan dengan de

mikian  $\eta = \sum_{i=1}^r \xi_i \alpha_i \in V_r$ , untuk setiap himpunan dari

harga  $( \xi_1, \xi_2, \dots, \xi_r )$ . Jadi  $( \psi_i^* )$  adalah

$f^{n \times 1} = P \eta = P X' \beta$ , dimana  $P$  adalah matriks ortho-  
 nal, sehingga  $(f_1, f_2, \dots, f_q)$  adalah fungsi li-  
 nier dari  $(\beta_j)$ . Mereka adalah fungsi-fungsi estimabel  
 sebab bentuk linier  $Z_i$  adalah estimasi tak bias dari  $f_i$ .  
 Hal ini disebabkan karena setiap estimasi kuadrat terke-  
 cil dari suatu fungsi estimabel harus merupakan kombinasi  
 linier dari  $Z_1, Z_2, \dots, Z_r$ , yaitu : 
$$\psi_i^* = \sum_{j=1}^r c_{ij} Z_j$$

Karena itu  $\psi_i^*$  merupakan estimasi tak bias dari  $f_i$  ber-

dasar  $\Omega$  bbb  $f = \sum_{j=1}^r c_{ij} f_j$ , identik dalam

$(f_1, f_2, \dots, f_r)$  yaitu bbb  $c_{ij} = \delta_{ij}$  atau

$\psi_i^* = Z_i$ . Sekarang dipunyai :

$$\hat{\psi}' B^{-1} \hat{\psi} = (\hat{\psi}^*)' (B^*)^{-1} \hat{\psi}^* = \sum_{i=1}^q \hat{\psi}_i^{*2} = \sum_{i=1}^q Z_i^2$$

Karena  $B^* = \sigma^{-2} I$  dan  $\hat{\psi}^* = \sigma^2 I$ , maka :

$$\hat{\psi}' B^{-1} \hat{\psi} = \sum_{i=1}^q (\hat{\psi}_i^*)^2 = \sum_{i=1}^q Z_i^2$$

Terbukti bahwa :  $\hat{\psi}' B^{-1} \hat{\psi} = \sigma^2 - \sigma^2 \Omega$ . (II.9.2)