

BAB II
MATERI PENUNJANG

2.1 Vektor

Vektor adalah besaran yang mempunyai besar dan arah.

Definisi 2.1.1 : Jika x dan y dua vektor di R^n dimana $x = [x_1, x_2, \dots, x_n]$ dan $y = [y_1, y_2, \dots, y_n]$ maka bentuk $x_1y_1 + x_2y_2 + \dots + x_ny_n$ dinamakan perkalian dalam (inner product) dari x dan y dan dinyatakan dengan $x \cdot y$.

Definisi 2.1.2 : Jika x adalah sebuah vektor didalam R^n , maka panjang vektor x ditunjukkan oleh $\|x\|$, yang merupakan akar kuadrat dari hasil kali dalam vektor x dan x , jadi :

$$\|x\| = \sqrt{x \cdot x} = \sqrt{x_1^2 + x_2^2 + \dots + x_n^2}$$

dengan $x = [x_1, x_2, \dots, x_n]$

2.1.1 Ruang Vektor Linier

Definisi 2.1.3 : S dinamakan ruang vektor jika S adalah himpunan vektor yang tidak kosong dan memenuhi aksioma - aksioma berikut :

1. Untuk semua $x \in S, y \in S$ ada satu dan hanya satu $z \in S$ dimana $z = x + y$
2. $x + y = y + x$ untuk $x, y \in S$
3. $(x + y) + z = x + (y + z)$ untuk semua $x, y, z \in S$

4. Ada satu dan hanya satu $0 \in S$ sedemikian sehingga $x + 0 = x$ untuk setiap $x \in S$.
5. Untuk setiap $x \in S$ ada satu dan hanya satu $y \in S$ sehingga $x + y = 0$.
6. Untuk setiap $x \in S$, $\alpha \in R$ ada satu dan hanya satu $\alpha x \in S$.
7. $1 \cdot x = x$ untuk setiap $x \in S$.
8. $\alpha(\beta x) = (\alpha\beta)x$, untuk setiap $x \in S$ dan $\alpha, \beta \in R$.
9. $(\alpha + \beta)x = \alpha x + \beta x$ untuk setiap $x \in S$ dan $\alpha, \beta \in R$.
10. $\alpha(x + y) = \alpha x + \alpha y$ untuk setiap $x, y \in S$ dan $\alpha \in R$.

2.1.2 Kombinasi Linier

Definisi 2.1.4 : Jika x_1, x_2, \dots, x_n adalah vektor-vektor di R^n maka vektor $y = \alpha_1 x_1 + \alpha_2 x_2 + \dots + \alpha_n x_n$ dinamakan kombinasi linier dari x_1, x_2, \dots, x_n .

Definisi 2.1.5 : Kumpulan $\{x_1, x_2, \dots, x_n\}$ tak bebas linier jika terdapat skalar $\alpha_i \neq 0$, $i = 1, 2, \dots, n$ sedemikian sehingga $\sum_{i=1}^n \alpha_i x_i = 0$. Kumpulan $\{x_1, x_2, \dots, x_n\}$ dikatakan bebas linier jika $\sum_{i=1}^n \alpha_i x_i = 0$ hanya dipenuhi oleh $\alpha_i = 0$, $i = 1, 2, \dots, n$.

2.1.3 Basis

Definisi 2.1.6 : $V \subset S$ dikatakan membangun S , jika setiap vektor $x \in S$ dapat ditulis sebagai kombinasi linier dari vektor-vektor di V .

Definisi 2.1.7 : Misalkan S ruang vektor dan $V \subset S$, maka V dinamakan basis dari S , jika :

- (i) V kumpulan bebas linier
- (ii) V membangun S

2.1.4 Ruang Bagian dari R^n

Definisi 2.1.8 : Jika $S = \{u_1, u_2, u_3, \dots, u_s\}$ adalah suatu himpunan vektor yang berasal dari R^n , maka ruang bagian yang direntang oleh himpunan S didefinisikan sebagai :

$$REN\{u_1, \dots, u_s\} = \left\{ \sum_{k=1}^s \alpha_k u_k, \alpha_k \text{ bilangan riil} \right\}$$

atau ruang bagian itu terdiri dari semua kemungkinan kombinasi linier vektor-vektor dalam himpunan S .

Definisi 2.1.9 : Dua vektor v dan u di dalam R^n dikatakan ortogonal jika $u \cdot v = 0$. Suatu himpunan vektor-vektor $S = \{u_1, u_2, \dots, u_k\}$ di dalam R^n dikatakan saling ortogonal jika vektor-vektor itu ortogonal sepasang-sepasang dengan kata lain $u_i \cdot u_j = 0$ jika

$i \neq j$. Sedangkan jika vektor-vektor di

dalam himpunan S yang saling ortogonal itu semuanya vektor satuan, maka kita namakan himpunan itu ortonormal dengan kata lain $u_i \cdot u_j = 0$ jika $i \neq j$ dan $u_i \cdot u_i = 1$ untuk $i = 1, 2, 3, \dots, k$. Himpunan ortonormal yang juga membentuk suatu basis bagi \mathbb{R}^n dinamakan basis ortonormal bagi \mathbb{R}^n .

2.2 Ortogonalitas Gram - Schmidt

Misalkan u_1, u_2 adalah basis dari ruang bagian U . Basis yang saling ortogonal dari U dicari dengan cara sebagai berikut :

Vektor pertama dari basis ortogonal dapat diambil dari vektor pertama basis yang diketahui, yaitu :

$$w_1 = u_1$$

kemudian dicari vektor w_2 di U yang tegak lurus terhadap w_1 . Karena vektor w_2 harus terletak di U maka vektor tersebut haruslah dapat ditulis sebagai kombinasi linier dari u_1 dan u_2 .

$$w_2 = u_2 + s w_1$$

Kita hanya memakai satu parameter karena hanya ada satu syarat untuk menentukan w_2 yaitu :

$$w_2 \cdot w_1 = 0 \text{ atau } u_2 \cdot w_1 + s(w_1 \cdot w_1) = 0$$

dengan demikian

$$s = -\frac{u_2 \cdot w_1}{w_1 \cdot w_1} \text{ atau}$$

$$w_2 = u_2 - \frac{u_2 \cdot w_1}{w_1 \cdot w_1} \cdot w_1$$

Selanjutnya untuk ruang bagian U yang dibangun oleh 3 vektor u_1, u_2, u_3 .

$$\text{Ambil } w_3 = u_3 + s_1 w_2 + s_2 w_1$$

Karena w_1, w_2 dan w_3 harus saling ortogonal maka

$$w_1 \cdot w_3 = w_1 \cdot u_3 + s_1 w_1 \cdot w_2 + s_2 w_1 \cdot w_1 = w_1 \cdot u_3 + s_2 w_1 \cdot w_1 = 0$$

dan

$$w_2 \cdot w_3 = w_2 \cdot u_3 + s_1 w_2 \cdot w_2 + s_2 w_2 \cdot w_1 = w_2 \cdot u_3 + s_1 w_2 \cdot w_2 = 0$$

$$\text{sehingga diperoleh } s_1 = -\frac{w_2 \cdot u_3}{w_2 \cdot w_2}, \quad s_2 = -\frac{w_1 \cdot u_3}{w_1 \cdot w_1}$$

$$\text{jadi } w_3 = u_3 - \frac{w_2 \cdot u_3}{w_2 \cdot w_2} w_2 - \frac{w_1 \cdot u_3}{w_1 \cdot w_1} w_1$$

sehingga untuk langkah-langkah yang sama didapatkan

$$w_i = u_i - \frac{u_i \cdot w_1}{w_1 \cdot w_1} \cdot w_1 - \dots - \frac{u_i \cdot w_{i-1}}{w_{i-1} \cdot w_{i-1}} \cdot w_{i-1}$$

$$i = 1, 2, 3, \dots, k$$

Kalau didefinisikan $\frac{w_i}{\|w_i\|} = v_i$ ($i = 1, 2, 3, \dots, k$)

maka v_i adalah vektor-vektor satuan yang saling ortogonal dan juga merupakan basis ortonormal dari R^n .

2.3 Matrik

Definisi 2.3.1 : Matrik adalah kumpulan unsur - unsur yang disusun menurut baris dan kolom (yang berbentuk persegi panjang) dan dibatasi oleh 2 kurung besar.

contoh : $A = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix}$
(2x2)

Definisi 2.3.2 : Sebuah matrik bujur sangkar A berordo nxn disebut mempunyai invers bila ada suatu matrik B sedemikian sehingga $AB = BA = I_n$

2.3.1 Invers dengan partisi

Untuk mencari invers suatu matrik dengan partisi adalah sebagai berikut :

Misalkan suatu matrik $A = (a_{ij})$ dengan ordo nxn diberikan dalam bentuk matrik partisi yaitu :

$$A = \begin{bmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{bmatrix} \text{ dengan inversnya } B = \begin{bmatrix} B_{11} & B_{12} \\ B_{21} & B_{22} \end{bmatrix}$$

$\begin{matrix} p \times p & p \times q \\ q \times p & q \times q \end{matrix}$

karena $AB = BA = I_n$, sehingga didapatkan :

$$\begin{aligned} B_{11}A_{11} + B_{12}A_{21} &= I_p & B_{11}A_{12} + B_{12}A_{22} &= 0 \\ A_{21}B_{11} + A_{22}B_{21} &= 0 & A_{21}B_{12} + A_{22}B_{22} &= I_q \end{aligned}$$

misal $B_{11} = Z^{-1}$, diperoleh :

$$B_{12} = -Z^{-1}A_{12}A_{22}^{-1}$$

$$B_{21} = -A_{22}^{-1}A_{21}Z^{-1}$$

$$B_{22} = A_{22}^{-1}(I_q - A_{21}B_{12})$$

Sehingga invers dari A adalah :

$$\begin{bmatrix} Z^{-1} & -Z^{-1}A_{12}A_{22}^{-1} \\ -A_{22}^{-1}A_{21}Z^{-1} & A_{22}^{-1}(I_q - A_{21}B_{12}) \end{bmatrix}$$

Dari $B_{11}A_{11} + B_{12}A_{21} = I_p$, maka :

$$Z^{-1}A_{11} - Z^{-1}A_{12}A_{22}^{-1}A_{21} = I_p$$

$$Z^{-1}(A_{11} - A_{12}A_{22}^{-1}A_{21}) = I_p$$

$$\begin{aligned} Z^{-1} &= I_p (A_{11} - A_{12}A_{22}^{-1}A_{21})^{-1} \\ &= (A_{11} - A_{12}A_{22}^{-1}A_{21})^{-1} \end{aligned}$$

Definisi 2.3.3 : Sebuah matrik A adalah definit positif jika matrik tersebut adalah simetris dan memenuhi :

$$Q = x'Ax > 0, \text{ untuk } x \neq 0$$

Definisi 2.3.4 : Sebuah matrik A adalah definit nonnegatif jika matrik tersebut adalah simetris dan memenuhi :

$$Q = x'Ax \geq 0, \text{ untuk semua } x$$

Teorema 2.3.1 : Jika matrik A adalah definit positif maka $P'AP$ adalah definit nonnegatif untuk semua P. Jika P adalah matrik kuadrat dan mempunyai rank penuh maka $P'AP$ adalah definit positif.

Bukti : dari $x' P' A P x = y' A y$ dimana $y = P x$ maka $x' P' A P x \geq 0$, untuk semua x . Jika P adalah bentuk kuadrat dan mempunyai rank penuh, maka $y = 0$ hanya jika $x = 0$. Sehingga $x' P' A P x > 0$ untuk $x \neq 0$.

Teorema 2.3.2 : Untuk sembarang matrik P , $P' P \geq 0$

Bukti : Menggunakan teorema 2.3.1 dengan $A = I$
atau matrik A sama dengan matrik identitas

2.4 Model Linier

2.4.1 Model regresi linier berganda

Suatu model regresi yang mencakup lebih dari satu variabel bebas disebut model regresi berganda.

Definisi 2.4.1 : Secara umum model regresi linier berganda dengan variabel tak bebas y dapat dihubungkan pada k variabel bebas (x_1, x_2, \dots, x_k) , yaitu :

$$y = \alpha_0 + \alpha_1 x_1 + \alpha_2 x_2 + \dots + \alpha_k x_k + u$$

dimana $u \sim NID(0, \sigma_u^2)$ dengan $\alpha_i (i = 1, 2, \dots, k)$ disebut koefisien regresi.

2.4.2 Estimasi Koefisien Regresi linier Berganda

Model umum regresi linier berganda adalah :

$$y = \alpha_0 + \alpha_1 x_1 + \alpha_2 x_2 + \dots + \alpha_k x_k + u$$

Model regresi untuk setiap vektor pengamatan (misal pengamatan ke- i) adalah :

$$y_i = \alpha_0 + \alpha_1 x_{1i} + \alpha_2 x_{2i} + \dots + \alpha_k x_{ki} + u_i$$

Model ini dapat ditulis dalam bentuk matrik sebagai berikut :

$$y = X\alpha + u$$

dimana:

$$X = \begin{bmatrix} 1 & x_{11} & \dots & x_{k1} \\ 1 & x_{12} & \dots & x_{k2} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_{1n} & \dots & x_{kn} \end{bmatrix}, \quad y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}, \quad \alpha = \begin{bmatrix} \alpha_0 \\ \alpha_1 \\ \vdots \\ \alpha_k \end{bmatrix}$$

$$\text{dan } u = \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{bmatrix} \quad \text{dengan } k+1 = p$$

dengan menggunakan metode kuadrat terkecil biasa (OLS):

$$\begin{aligned} L &= \sum_{i=1}^n u_i^2 = u' u = (y - X\alpha)' (y - X\alpha) \\ &= y' y - \alpha' X' y - y' X\alpha + \alpha' X' X\alpha \\ &= y' y - 2\alpha' X' y + \alpha' X' X\alpha \end{aligned}$$

karena $\alpha' X' y$ adalah sebuah matrik (1x1) atau sebuah matrik skalar, dan transpose $\alpha' X' y$ atau $(\alpha' X' y)' = y' X\alpha$ adalah skalar yang sama. Estimator - estimator kuadrat terkecil tersebut harus memenuhi :

$$\frac{\partial L}{\partial \alpha} \bigg|_{\hat{\alpha}} = -2X' y + 2X' X\hat{\alpha} = 0$$

$$X' X\hat{\alpha} = X' y$$

$$\hat{\alpha} = (X' X)^{-1} X' y \quad (\text{OLSE})$$

Theorema 2.4.1 : (Gauss - Markov)

Didalam model linier klasik :

$$y = X\alpha + u$$

dimana $u \sim (0, \sigma^2 I)$

OLSE $\hat{\alpha}$ dengan matrik variansi $V(\hat{\alpha}) = \sigma^2(X'X)^{-1}$ adalah estimator tak bias linier yang terbaik (BLUE) dari α .

Bukti :

$$\begin{aligned} V(\hat{\alpha}) &= E(\hat{\alpha} - \alpha)(\hat{\alpha} - \alpha)' \\ &= E((X'X)^{-1}X'y - \alpha)((X'X)^{-1}X'y - \alpha)' \\ &= E((X'X)^{-1}X'(X\alpha + u) - \alpha)((X'X)^{-1}X'(X\alpha + u) - \alpha)' \\ &= E((X'X)^{-1}X'u)((X'X)^{-1}X'u)' \\ &= E((X'X)^{-1}X'u)(u'X(X'X)^{-1}) \\ &= (X'X)^{-1}X'E(uu')X(X'X)^{-1} \\ &= (X'X)^{-1}X'\sigma^2IX(X'X)^{-1} \\ &= \sigma^2(X'X)^{-1} \end{aligned}$$

a. Tak bias

$$\begin{aligned} E(\hat{\alpha}) &= E((X'X)^{-1}X'y) \\ &= E((X'X)^{-1}X'(X\alpha + u)) \\ &= \alpha + (X'X)^{-1}X'E(u) \\ &= \alpha \end{aligned}$$

b. Variansi minimum

Akan diperlihatkan bahwa diantara estimator - estimator linier tak bias (misal α^*) selain estimator $\hat{\alpha}$ (OLSE), estimator $\hat{\alpha}$ mempunyai varian terkecil. atau :

$$V(\hat{\alpha}) \leq V(\alpha^*)$$

Misal $\alpha^* = ((X'X)^{-1}X' + D) y$

dimana D adalah matrik konstan berukuran (pxn).

Agar α^* merupakan estimator tak bias maka :

$$\begin{aligned} E(\alpha^*) &= E((X'X)^{-1}X' + D) y \\ &= E((X'X)^{-1}X' + D)(X\alpha + u) \\ &= (X'X)^{-1}X'X\alpha + (X'X)^{-1}X'E(u) + DX\alpha + DE(u) \\ &= \alpha + DX\alpha \\ &= \alpha \end{aligned}$$

Jika dan hanya jika $DX = 0$

$$\begin{aligned} V(\alpha^*) &= E(\alpha^* - \alpha)(\alpha^* - \alpha)' \\ (\alpha^* - \alpha) &= ((X'X)^{-1}X' + D) y - \alpha \\ &= ((X'X)^{-1}X' + D)(X\alpha + u) - \alpha \\ &= (X'X)^{-1}X'X\alpha + (X'X)^{-1}X'(u) + DX\alpha + Du - \alpha \\ &= \alpha + (X'X)^{-1}X'u + DX\alpha + Du - \alpha \\ &= (X'X)^{-1}X'u + D(X\alpha + u) \\ V(\alpha^*) &= E((X'X)^{-1}X'u + D(X\alpha + u))((X'X)^{-1}X'u + D(X\alpha + u))' \\ &= E((X'X)^{-1}X'uu'X(X'X)^{-1}) + E((X'X)^{-1}X'u(X\alpha + u)'D') \\ &\quad + E(D(X\alpha + u)u'X(X'X)^{-1}) + E(D(X\alpha + u)(X\alpha + u)'D') \\ &= (X'X)^{-1}X'E(uu')X(X'X)^{-1} + (X'X)^{-1}X'E(u)\alpha'X'D' + \\ &\quad (X'X)^{-1}X'E(uu')D' + DX\alpha E(u')X(X'X)^{-1} + DE(uu')X(X'X)^{-1} \\ &\quad + DX\alpha\alpha'X'D' + DX\alpha E(u')D' + DE(u)\alpha'X'D' + DE(uu')D' \\ &= \sigma^2(X'X)^{-1} + \sigma^2DD' \end{aligned}$$

karena $DD' \geq 0$, maka terbukti :

$$V(\alpha) \leq V(\alpha^*)$$

Definisi 2.4.2 :Estimator Aitken atau GLSE (Generalized Least Squares Estimator) dari α dengan matrik variansi $E(uu') = \sigma^2\Gamma$ didefinisikan sebagai :

$$\hat{\alpha} = (X'\Gamma^{-1}X)^{-1}X'\Gamma^{-1}y$$

Theorema 2.4.2 :(Gauss - Markov - Aitken)

Jika $y = X\alpha + u$, dimana $u \sim (0, \sigma^2\Gamma)$ maka $\hat{\alpha}$ adalah tak bias dan lebih dari itu merupakan estimator linier terbaik (BLUE)

$$V(\hat{\alpha}) = \sigma^2(X'\Gamma^{-1}X)^{-1} \leq V(\alpha^*)$$

untuk estimator - estimator (α^*) tak bias linier yang lainnya.

Bukti :

$$\begin{aligned}(\hat{\alpha} - \alpha) &= ((X'\Gamma^{-1}X)^{-1}X'\Gamma^{-1}y - \alpha) \\ &= ((X'\Gamma^{-1}X)^{-1}X'\Gamma^{-1}(X\alpha + u) - \alpha) \\ &= (X'\Gamma^{-1}X)^{-1}X'\Gamma^{-1}X\alpha + (X'\Gamma^{-1}X)^{-1}X'\Gamma^{-1}u - \alpha \\ &= (X'\Gamma^{-1}X)^{-1}X'\Gamma^{-1}u\end{aligned}$$

$$V(\hat{\alpha}) = E(\hat{\alpha} - \alpha)(\hat{\alpha} - \alpha)'$$

$$\begin{aligned}V(\hat{\alpha}) &= E((X'\Gamma^{-1}X)^{-1}X'\Gamma^{-1}u)((X'\Gamma^{-1}X)^{-1}X'\Gamma^{-1}u)' \\ &= E((X'\Gamma^{-1}X)^{-1}X'\Gamma^{-1}uu'\Gamma^{-1}, X(X'\Gamma^{-1}, X)^{-1}) \\ &= (X'\Gamma^{-1}X)^{-1}X'\Gamma^{-1}E(uu')\Gamma^{-1}, X(X'\Gamma^{-1}, X)^{-1} \\ &= \sigma^2(X'\Gamma^{-1}X)^{-1}X'\Gamma^{-1}\Gamma\Gamma^{-1}, X(X'\Gamma^{-1}, X)^{-1} \\ &= \sigma^2(X'\Gamma^{-1}X)^{-1}\end{aligned}$$

a. Tak bias :

$$\begin{aligned} E(\hat{\alpha}) &= E((X' \Gamma^{-1} X)^{-1} X' \Gamma^{-1} y) \\ &= E((X' \Gamma^{-1} X)^{-1} X' \Gamma^{-1} (X\alpha + u)) \\ &= \alpha + (X' \Gamma^{-1} X)^{-1} X' \Gamma^{-1} E(u) \\ &= \alpha \end{aligned}$$

b. Variansi minimum

$$\text{misal : } \alpha^* = ((X' \Gamma^{-1} X)^{-1} X' \Gamma^{-1} + D)y$$

dimana D adalah matrik konstan yang berukuran $(p \times n)$.

Agar α^* merupakan estimator tak bias maka :

$$\begin{aligned} E(\alpha^*) &= E((X' \Gamma^{-1} X)^{-1} X' \Gamma^{-1} + D)y \\ E(\alpha^*) &= E((X' \Gamma^{-1} X)^{-1} X' \Gamma^{-1} + D)(X\alpha + u) \\ &= (X' \Gamma^{-1} X)^{-1} X' \Gamma^{-1} X\alpha + (X' \Gamma^{-1} X)^{-1} X' \Gamma^{-1} E(u) + DX\alpha + DE(u) \\ &= \alpha + DX\alpha \\ &= \alpha \end{aligned}$$

Jika dan hanya jika $DX = 0$

$$\begin{aligned} V(\alpha^*) &= E(\alpha^* - \alpha)(\alpha^* - \alpha)' \\ (\alpha^* - \alpha) &= (X' \Gamma^{-1} X)^{-1} X' \Gamma^{-1} + D)y - \alpha \\ &= (X' \Gamma^{-1} X)^{-1} X' \Gamma^{-1} + D)(X\alpha + u) - \alpha \\ &= \alpha + (X' \Gamma^{-1} X)^{-1} X' \Gamma^{-1} u + DX\alpha + Du - \alpha \\ &= (X' \Gamma^{-1} X)^{-1} X' \Gamma^{-1} u + D(X\alpha + u) \\ V(\alpha^*) &= E((X' \Gamma^{-1} X)^{-1} X' \Gamma^{-1} u + D(X\alpha + u))((X' \Gamma^{-1} X)^{-1} X' \Gamma^{-1} u + D(X\alpha + u))' \\ &= (X' \Gamma^{-1} X)^{-1} X' \Gamma^{-1} E(uu') \Gamma^{-1} X + (X' \Gamma^{-1} X)^{-1} X' \Gamma^{-1} u + (X\alpha + u)' D' + ED(X\alpha + u)u' \Gamma^{-1} X + (X' \Gamma^{-1} X)^{-1} \end{aligned}$$

$$\begin{aligned}
& + E(D(X\alpha + u)(X\alpha + u)' D') \\
= & (X' \Gamma^{-1} X)^{-1} X' \Gamma^{-1} E(uu') \Gamma^{-1} X (X' \Gamma^{-1} X)^{-1} + (X' \Gamma^{-1} X)^{-1} \\
& X' \Gamma^{-1} E(u) \alpha' X' D' + (X' \Gamma^{-1} X)^{-1} X' \Gamma^{-1} E(uu') D' + DX \alpha E(u') \\
& \Gamma^{-1} X (X' \Gamma^{-1} X)^{-1} D E(uu') \Gamma^{-1} X (X' \Gamma^{-1} X)^{-1} + DX \alpha \alpha' X' D' + \\
& DX \alpha E(u)' D' + E(u) \alpha' X' D' D E(uu') D' \\
= & \sigma^2 (X' \Gamma^{-1} X)^{-1} X' \Gamma^{-1} \Gamma \Gamma^{-1} X (X' \Gamma^{-1} X)^{-1} + \sigma^2 D' D'
\end{aligned}$$

karena $D' D' \geq 0$ maka terbukti :

$$V(\hat{\alpha}) \leq V(\alpha^*)$$

2.5 Runtun Waktu (Time Series) Univariate

Dalam pembahasan Runtun waktu univariate ini akan dikhususkan pada runtun waktu yang stasioner.

Definisi 2.5.1 : Bila T himpunan waktu yang diamati, t didalam T dan u_t adalah hasil pengamatan pada saat t , maka $\{u_t, t \in T\}$ disebut proses stokastik.

Untuk proses stokastik yang stasioner akan diberikan pada definisi 2.5.2 yaitu :

Definisi 2.5.2 : Misal $u_{t_1}, u_{t_2}, \dots, u_{t_n}$ adalah pengamatan pada saat t_1, t_2, \dots, t_n dari proses stokastik $\{u_t, t \in T\}$ dan distribusi peluang gabungan yang berkaitan adalah :

$$f(u_{t_1}, u_{t_2}, \dots, u_{t_n})$$

jika dipenuhi :

$$f(u_{t_1+k}, u_{t_2+k}, \dots, u_{t_n+k}) = f(u_{t_1}, u_{t_2}, \dots, u_{t_n})$$

Untuk setiap pergeseran waktu sebesar k , maka proses stokastik $\{u_t, t \in T\}$ disebut proses stokastik stasioner.

Akibat : $f(u_1, u_2, \dots, u_n)$ bebas dari waktu sehingga proses stokastik stasioner mempunyai mean dan varian yang konstan, yaitu :

$$\text{Mean} = \mu = E(u_t) = E(u_{t+k})$$

$$\text{Varian} = E(u_t - \mu)^2 = E(u_{t+k} - \mu)^2$$

Sementara itu fungsi autokovarian pada proses stokastik akan disajikan pada definisi berikut :

Definisi 2.5.3 : Fungsi autokovarian proses stokastik

$\{u_t, t \in T\}$ adalah :

$$\begin{aligned} \gamma_{u, u_{t+k}} &= \text{Cov}(u_t, u_{t+k}) \\ &= E(u_t u_{t+k}) \end{aligned}$$

Untuk proses stokastik stasioner, fungsi autokovariansi hanya bergantung pada selang waktu (lag) antara t_1 dan t_2 .

misal untuk proses stasioner, selang waktu dinyatakan dalam k , maka fungsi autokovariansi menjadi :

$$\begin{aligned} \gamma_{t, t+k} &= \text{Cov}(u_t, u_{t+k}) \\ &= E(u_t u_{t+k}) \end{aligned}$$

$\gamma_{t, t+k}$ ditulis γ_k .

Definisi 2.5.4 : White noise adalah barisan variabel acak

$\varepsilon_t, \varepsilon_{t-1}, \dots$ yang masing - masing tidak berkorelasi, dimana $\varepsilon_t \sim (0, \sigma_\varepsilon^2)$

Autokovarian lag k white noise adalah :

$$\text{Cov}(\varepsilon_t, \varepsilon_{t+k}) = E(\varepsilon_t - E\varepsilon_t)(\varepsilon_{t+k} - E\varepsilon_{t+k})$$

karena $E(\varepsilon_t) = 0$, sehingga :

$$\text{Cov}(\varepsilon_t, \varepsilon_{t+k}) = E(\varepsilon_t \varepsilon_{t+k})$$

untuk $k = 0$ ————— \rightarrow $\text{Cov}(\varepsilon_t, \varepsilon_{t+k}) = E(\varepsilon_t \varepsilon_{t+k})$

$$\begin{aligned} \text{Cov}(\varepsilon_t, \varepsilon_{t+k}) &= E(\varepsilon_t \varepsilon_t) \\ &= \sigma_\varepsilon^2 \end{aligned}$$

untuk $k \neq 0$ ————— \rightarrow $\text{Cov}(\varepsilon_t, \varepsilon_{t+k}) = E(\varepsilon_t \varepsilon_{t+k})$

$$\text{Cov}(\varepsilon_t, \varepsilon_{t+k}) = 0$$

karena nilai - nilai dari white noise bersifat acak /random dan suatu nilai white noise tidak berkorelasi dengan nilai white noise sesudah dan sebelumnya.

Salah satu proses dari runtun waktu univariat yang stasioner adalah rata-rata bergerak (Moving Average).

Definisi 2.5.5 :Bila u_t dinyatakan dalam bentuk :

$$u_t = \mu + \varepsilon_t - \lambda_1 \varepsilon_{t-1} - \dots - \lambda_q \varepsilon_{t-q}$$

dengan $\lambda_q \neq 0$ disebut proses rata - rata

bergerak dengan orde q atau RB(q)