

BAB II

MATERI PENUNJANG

2.1 Matriks dan Differensiasi Matriks

Oleh karena banyaknya konsep-konsep dasar dalam analisa statistik menggunakan matriks, sebab itu akan lebih baik bila ditinjau terlebih dahulu mengenai matriks aljabar beserta differensiasinya.

Theorema 1: (theorema decomposisi spektral)

Ambil matriks simetris A ukuran $(n \times n)$ maka ada matriks orthogonal P sedemikian sehingga:

$P'AP = \Lambda$ atau $A = PAP'$ dengan $P'P = PP' = I$,
dimana P merupakan matriks yang mempunyai kolom P_1, \dots, P_n , dan Λ matriks diagonal dengan diagonal $(\lambda_1, \lambda_2, \dots, \lambda_n)$ dan merupakan matriks eigenvalue dari A .

Maka

$$\text{tr } A = \sum \lambda_i$$

Bukti:

$$\text{tr } A = \text{tr } P'AP = \text{tr } APP' = \text{tr } A = \sum \lambda_i. \blacksquare$$

Theorema 2:

A adalah matriks simetris $(n \times n)$ dan D adalah definit non negatif, yaitu:

$$D \geq 0 \iff \text{tr } CD \geq 0 \quad \text{untuk semua } C \geq 0$$

Bukti:

Mengikuti theorem 1, maka dapat direpresentasikan $D = PAP' = \sum_{i=1}^n \lambda_i P_i P_i'$ dimana $\lambda_1, \lambda_2, \dots, \lambda_n$ adalah eigenvalue dari D ($A = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_n)$) dan $P = (P_1 \dots P_n)$ adalah eigenvektor orthogonal yang sesuai.

$$\begin{aligned} \text{Sehingga } \text{tr } (CD) &= \text{tr} \left[\sum_{i=1}^n \lambda_i C P_i P_i' \right] \\ &= \sum_{i=1}^n \lambda_i P_i C P_i' \end{aligned}$$

Syarat $P_i' C P_i$ adalah non negatif untuk semua $C \geq 0$.

Jika $D \geq 0$, semua λ_i adalah non negatif sehingga didapat

$$\text{tr } CD \geq 0.$$

Sebaliknya, jika $\text{tr } CD \geq 0$ untuk semua $C \geq 0$ hal ini adalah benar terutama untuk $C = P_i P_i' \geq 0$. Kemudian

$$\begin{aligned} \text{didapat: } \text{tr } CD &= \text{tr} \left[P_i P_i' \left(\sum_{j=1}^n \lambda_j P_j P_j' \right) \right] \\ &= \lambda_i \geq 0 \quad (i=1, 2, \dots, n) \quad \blacksquare \end{aligned}$$

Selanjutnya jika $f(x)$ adalah sebuah fungsi skalar riil dari sebuah matriks $X = [x_{ij}]$ ukuran $(m \times n)$, maka differensi partial f terhadap X didefinisikan sebagai matriks $(m \times n)$ dari differensial parsial $\frac{\partial f}{\partial x_{ij}}$, yaitu:

$$\frac{\partial f}{\partial X} = \begin{bmatrix} \frac{\partial f}{\partial x_{11}} & \frac{\partial f}{\partial x_{12}} & \dots & \frac{\partial f}{\partial x_{1n}} \\ \frac{\partial f}{\partial x_{21}} & \frac{\partial f}{\partial x_{22}} & \dots & \frac{\partial f}{\partial x_{2n}} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial f}{\partial x_{m1}} & \frac{\partial f}{\partial x_{m2}} & \dots & \frac{\partial f}{\partial x_{mn}} \end{bmatrix}$$

Contoh 1:

$$y = \text{tr } AX + \text{tr } XBX'$$

yang mempunyai nilai maximum atau minimum terhadap X .
Jika X mempunyai m baris dan n kolom maka turunan $\partial y / \partial X$ dengan elemen ke- (i,j) -nya adalah $\partial y / \partial x_{ij}$ ($i=1,2,3,\dots,m$; $j=1,2,3,\dots,n$).

Dimisalkan $y = \text{tr } Z$; dimana $Z = AX + XBX'$

$$\text{Sekarang } \frac{\partial X}{\partial x_{ij}} = E_{ij} = e_i e_j'$$

$$\text{dan } \frac{\partial X'}{\partial x_{ij}} = E_{ji} = e_j e_i'$$

dimana E_{ij} adalah matriks dengan elemen pada posisi ke (i,j) adalah satu dan elemen ditempat lain nol. Vektor-vektor e_i dan e_j didefinisikan secara sama.

Jadi:

$$Z = AX + XBX'$$

$$\frac{\partial Z}{\partial x_{ij}} = AE_{ij} + E_{ij}BX' + XBE_{ji}$$

Oleh karena itu,

$$\begin{aligned} \frac{\partial y}{\partial x_{ij}} &= \text{tr } \frac{\partial Z}{\partial x_{ij}} \\ &= \text{tr } (AE_{ij} + E_{ij}BX' + XBE_{ji}) \\ &= \text{tr } (Ae_i e_j' + e_i e_j' BX' + XBe_j e_i') \end{aligned}$$

$$\begin{aligned}\frac{\partial y}{\partial x_{ij}} &= \text{tr} (e_j' A e_i + e_j' B X' e_i + e_i' X B e_j) \\ &= (A)_{ji} + (B X')_{ji} + (X B)_{ij}\end{aligned}$$

Hasil ini sama dengan elemen ke-(i,j) dari $(A' + X B' + X B)$.

Contoh 2:

$$y = \text{tr} Z \quad ; \quad \text{dimana } Z = A X B X C X'$$

$$\text{Maka } \frac{\partial Z}{\partial x_{ij}} = A E_{ij} B X C X' + A X B E_{ij} C X' + A X B X C E_{ji}$$

Oleh karena itu:

$$\begin{aligned}\frac{\partial y}{\partial x_{ij}} &= \text{tr} \frac{\partial Z}{\partial x_{ij}} \\ &= \text{tr} (A E_{ij} B X C X' + A X B E_{ij} C X' + A X B X C E_{ji}) \\ &= \text{tr} (A e_i e_j' B X C X' + A X B e_i e_j' C X' + A X B X C e_j e_i') \\ &= \text{tr} (e_j' A B X C X' e_i + e_j' A X B C X' e_i + e_i' A X B X C e_j) \\ &= (A B X C X')_{ji} + (A X B C X')_{ji} + (A X B X C)_{ij}\end{aligned}$$

$$\text{Jadi } \frac{\partial y}{\partial X} = X C' X' B' A' + X C' B' X' A' + A X B X C$$

Catatan:

$$\frac{\partial}{\partial X} A B = \frac{\partial A}{\partial X} B + A \frac{\partial B}{\partial X}$$

Theorema 3:

Jika $y = \text{tr} A C' W C$ maka:

$$\text{a) } \frac{\partial y}{\partial C} = W C A + W' C A'$$

$$\text{b) Jika } W \text{ dan } A \text{ adalah simetris, maka: } \frac{\partial y}{\partial C} = 2 W C A$$

Bukti:

Misal $AC'WC = Z$

Jadi, $y = \text{tr } AC'WC = \text{tr } Z$

Sehingga:

$$\begin{aligned} \frac{\partial y}{\partial c_{ij}} &= \text{tr} \frac{\partial Z}{\partial c_{ij}} \\ &= \text{tr} (AE_{ji}WC + AC'WE_{ij}) \\ &= \text{tr} (Ae_j e_i' WC + AC' We_i e_j') \\ &= \text{tr} (e_i' AWCe_j + e_j' AC' We_i) \\ &= (AWC)_{ij} + (AC'W)_{ji} \end{aligned}$$

Jadi,

$$\begin{aligned} \frac{\partial y}{\partial C} &= (AWC) + (AC'W)' \\ &= WCA + W'CA' \end{aligned}$$

untuk W dan A simetris, maka

$$\frac{\partial y}{\partial C} = 2WCA$$

2.2 Model Linier dan Estimator-estimatornya

Model standar yang digunakan dalam tulisan ini adalah:

$$y = X\beta + u \quad ; \text{ dengan } u \sim (0, \Sigma) \quad \langle 2.2.1 \rangle$$

dimana:

y : vektor ($n \times 1$) dari variabel dependen, yang bersifat random dan terobservasi

X : matriks ($n \times p$) dari variabel penjelas, yang

bersifat tetap dan terobservasi

β : vektor ($p \times 1$) dari koefisien regresi, yang bersifat tetap dan tak terobservasi

u : vektor ($n \times 1$) pengganggu, yang bersifat random dan tak terobservasi

Σ : matriks penyebaran ($n \times n$), yang bersifat tetap dan tak terobservasi.

2.2.1 Ordinary Least Square (OLS)

Notasi $u \sim (0, \Sigma)$ berarti bahwa u vektor pengganggu mempunyai ekspektasi $E[u]=0$ dan penyebaran (kovarian) $E[uu'] = \Sigma$. Dan model diatas disingkat oleh RAO (1971) dengan tiga simbol yaitu $(y, X\beta, \Sigma)$. Dalam kasus khusus dimana $\Sigma = \sigma^2 I$, sehingga elemen-elemen dari vektor pengganggu tidak berkorelasi, maka estimator standar dari β adalah estimator Ordinary Least Square (OLSE):

$$\hat{\beta} = (X'X)^{-1}X'y \quad \langle 2.2.2 \rangle$$

Yang dapat ditulis sebagai:

$$\hat{\beta} = T^{-1}X'y \quad \text{atau} \quad \hat{\beta} = GX'y$$

dengan $T = X'X$ dan $G = T^{-1}$, serta model $\langle 2.2.1 \rangle$ disebut *regresi klasik* atau *regresi dengan vektor pengganggu bervarian sama*.

2.2.2 Generalized Least Square

GLS dapat digunakan pada situasi dimana syarat pengganggu (elemen-elemen u) tidak semuanya berdistribusi sama, atau jika variabel-variabel tersebut berkorelasi.

Estimator GLS (GLSE) dari β didefinisikan sebagai:

$$b = (X' \Sigma^{-1} X)^{-1} X' \Sigma^{-1} y \quad \langle 2.2.3 \rangle$$

Catatan, ketika $\Sigma = \sigma^2 I$ maka estimator diatas akan menjadi estimator OLS seperti yang telah dibicarakan pada bagian sebelumnya.

Beberapa ide diatas mungkin akan menjadi jelas jika diambil contoh pada kasus univariat berikut:

$$y_i = \mu + u_i$$

yang menggambarkan kumpulan observasi y_1, y_2, \dots, y_n , yang masing-masing mempunyai rata-rata μ . Persamaan ke-n dapat dituliskan kembali oleh:

$$y = 1\mu + u$$

dimana 1 adalah vektor satuan yang berukuran $(n \times 1)$ yang jelas berbentuk:

$y = X\beta + u$, dengan $X=1$ dan vektor β yang berukuran $(p \times 1)$ adalah sebuah skalar μ .

OLSE untuk model diatas adalah:

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

$$\begin{aligned}\hat{\beta} &= (\mathbf{1}'\mathbf{1})^{-1}\mathbf{1}'\mathbf{y} \\ &= \frac{1}{n}n\bar{y} \\ &= \bar{y}\end{aligned}$$

Dengan kata lain, OLSE untuk kasus ini adalah benar-benar merupakan rata-rata sampel.

2.2.3 Estimator Linier

Jika \mathbf{y} adalah sebuah vektor random, dan \mathbf{C} serta \mathbf{d} adalah matriks dan vektor yang berukuran sesuai, maka vektor:

$$\mathbf{b}_0 = \mathbf{C}\mathbf{y} + \mathbf{d} \quad \langle 2.2.4 \rangle$$

dapat disebut "estimator linier" dari vektor β . Dalam kasus khusus dimana $\mathbf{d}=\mathbf{0}$, dikatakan bahwa \mathbf{b}_0 adalah estimator "homogen". Ketika $\mathbf{d}\neq\mathbf{0}$, \mathbf{b}_0 disebut "estimator heterogen". Dan OLSE yang diberikan oleh persamaan $\langle 2.2.2 \rangle$ adalah kasus khusus dari estimator linier homogen, didapat dengan mengambil $\mathbf{C}=(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'$ dan $\mathbf{d}=\mathbf{0}$ dalam persamaan $\langle 2.2.4 \rangle$.

2.2.4 Estimator Ridge

Sebagai perluasan dari estimator OLS, HOERL dan KENNARD (1970) mengusulkan suatu estimator yang

disebut "estimator ridge" dan didefinisikan sebagai :

$$\beta_k = (X'X + kI)^{-1} X'y \quad \langle 2.2.5 \rangle$$

Jelaslah bahwa $\langle 2.2.3 \rangle$ adalah kasus khusus dari $\langle 2.2.5 \rangle$ yang didapat dengan menempatkan $k = 0$.

2.3 Sesatan Kuadrat Rata-Rata Pada Model Linier Umum

Vektor Bias dan matriks Kovarian (penyebaran) dari $\hat{\beta}$ dalam model $(y, X\beta, \sigma^2 I)$ adalah:

$$B_{\hat{\beta}} = E[\hat{\beta}] - \beta = 0 \quad \text{dan} \quad V_{\hat{\beta}} = \sigma^2 (X'X)^{-1} \quad \langle 2.3.1 \rangle$$

Karena itu matriks SKR dari model tersebut adalah:

$$SKR_{\hat{\beta}} = E \left[(\hat{\beta} - \beta)(\hat{\beta} - \beta)' \right]$$

$$SKR_{\hat{\beta}} = \sigma^2 (X'X)^{-1} \quad \langle 2.3.2 \rangle$$

Secara umum, jika b_0 adalah sebuah estimator linier heterogen yang diberikan oleh persamaan $\langle 2.2.4 \rangle$, maka :

$$\begin{aligned} B_{b_0} &= E[b_0] - \beta \\ &= CX\beta + d - \beta \\ &= (CX - I)\beta + d \end{aligned} \quad \langle 2.3.3 \rangle$$

$$\text{dan} \quad V_{b_0} = \sigma^2 CC' \quad \langle 2.3.4 \rangle$$

Matriks SKR dari b_0 adalah:

$$\text{SKR}_{b_0} = \sigma^2 \text{CC}' + \left[(\text{CX} - \text{I})\beta + d \right] \left[(\text{CX} - \text{I})\beta + d \right]' \quad \langle 2.3.5 \rangle$$

Ekspresi terakhir ini merupakan rumus "Sesatan Kuadrat Rata-rata = Varian + Bias kuadrat" yang diperluas untuk matriks. Dan ketika $\text{C} = (\text{X}'\text{X})^{-1}\text{X}'$ dan $d=0$ (syarat akhir dalam persamaan $\langle 2.3.3 \rangle$ adalah nol), maka keseluruhan ekspresi ekuivalen dengan persamaan $\langle 2.3.2 \rangle$. Catatan bahwa ketika b_0 merupakan estimator homogen dan $d=0$, syarat akhir dalam persamaan $\langle 2.3.5 \rangle$ adalah :

$$(\text{CX} - \text{I})\beta\beta' (\text{CX} - \text{I})' \quad \langle 2.3.6 \rangle$$

Perlu dibedakan antara SKR dalam bentuk matriks dengan definisi lain, yaitu SKR dalam bentuk skalar (SKR skalar) yaitu :

$$\text{SKR skalar } (\beta) = \mathbb{E} \left[[\hat{\beta} - \beta]' [\hat{\beta} - \beta] \right]$$

Aplikasi dari operator trace didapat persamaan

$$\begin{aligned} \text{SKR skalar } (\hat{\beta}) &= \text{tr} \mathbb{E} \left[[\hat{\beta} - \beta]' [\hat{\beta} - \beta] \right] \\ &= \text{tr} \text{SKR skalar } (\hat{\beta}) \end{aligned}$$

Dalam tulisan ini akan dicari estimator yang meminimalkan harga dari persamaan $\langle 2.3.5 \rangle$. Secara umum, tujuannya adalah memperbaiki estimasi berdasarkan kerugian kuadrat rata-rata dengan ukuran kerugian estimator $\hat{\beta}$ oleh fungsi kerugian

$$L(\hat{\beta}, A) = [\hat{\beta} - \beta]' A [\hat{\beta} - \beta]$$

dimana A adalah matriks simetris definit positif yang sesuai dengan order $p \times p$.

Catatan:

$A > 0$ jika A definit positif

$A \geq 0$ jika A definit non negatif

Sedangkan resiko dari estimator $\hat{\beta}$ didefinisikan sebagai:

$$\begin{aligned} R(\hat{\beta}, A) &= E[L(\hat{\beta}, A)] \\ &= E\left[[\hat{\beta} - \beta]' A [\hat{\beta} - \beta]\right] \end{aligned} \quad \langle 2.3.7 \rangle$$

Aplikasi dari operator trace didapatkan hubungan antara resiko dan (harga matriks) SKR dari estimator yaitu :

$$\begin{aligned} R(\hat{\beta}, A) &= \text{tr } A E [\hat{\beta} - \beta]' [\hat{\beta} - \beta] \\ &= \text{tr } A \text{ SKR}(\hat{\beta}) \end{aligned} \quad \langle 2.3.8 \rangle$$

Rumus ini bersama-sama theorema 1 dan theorema 2 menunjukkan kepadanan untuk mengestimasi resiko $R(\hat{\beta}, A)$ atau SKR $(\hat{\beta})$ untuk estimator-estimator $\hat{\beta}$ yang ada dalam kelas tetap dari estimator yang mungkin.

Theorema 4:

Ambil dua estimator β_1 dan β_2 . Maka dua pernyataan berikut adalah ekuivalen:

$$a) \text{SKR}(\beta_1) - \text{SKR}(\beta_2) \geq 0$$

jika:

$$R(\underline{\beta}) \leq R(\hat{\beta}) \quad \text{untuk semua } \beta \text{ dalam } \mathcal{H}$$

dengan tanda lebih kecil berlaku paling sedikit untuk satu β dalam \mathcal{H} . Maka estimator $\underline{\beta}(x_1, x_2, x_3, \dots, x_n)$ dikatakan *admissible* jika dan hanya jika tidak ada estimator yang lebih baik.

2.5 Pengganda/Pengali Lagrange

Akan ditentukan nilai stasioner (maksimum atau minimum relatif) suatu fungsi $f(\theta_1, \theta_2, \dots, \theta_m)$ yang tersusun atas m peubah $\theta_1, \theta_2, \dots, \theta_m$ dengan kendala-kendala terhadap θ_i berupa $g_j(\theta_1, \theta_2, \dots, \theta_m) = 0$ ($j = 1, 2, \dots, q$). Untuk mengerjakan masalah ini, dibuat suatu fungsi:

$$F = f - \sum_{j=1}^q \lambda_j g_j$$

dimana $\lambda_1, \lambda_2, \dots, \lambda_j$ tidak diketahui. Dengan membuat turunan pertamanya terhadap setiap θ_i dan menyamakannya dengan nol, yaitu:

$$\frac{\partial F}{\partial \theta_i} \equiv \frac{\partial f}{\partial \theta_i} - \sum_{j=1}^q \lambda_j \frac{\partial g_j}{\partial \theta_i} = 0 \quad (i = 1, 2, \dots, m)$$

Dengan memandang

$$F = f + \Lambda G \quad (\text{dengan } G = \sum_{j=1}^q g_j)$$

maka didapatkan

$$\frac{\partial f}{\partial \theta_i} + \Lambda \frac{\partial G}{\partial \theta_i} = 0$$

Konstanta Λ inilah yang dinamakan suatu *pengali Lagrange* (*Lagrange Multiplier*). Seringkali λ_j berhasil dieliminasi dan tidak dicari nilainya, karena alasan inilah λ_j juga disebut "pengganda yang tidak ditentukan" (*undertermined multiplier*).

