

BAB II

MATERI PENUNJANG

Pada Bab II penulisan tugas akhir ini akan dibahas secara singkat konsep dasar dari materi-materi yang dijadikan penunjang untuk pembahasan materi pada Bab III. Materi-materi penunjang pada Bab II adalah regresi linier berganda univariat, matrik, distribusi normal multivariat, serta distribusi wishart.

2.1 Regresi Linier Berganda Univariat

Pembahasan mengenai analisis regresi multivariat tidak terlepas dari konsep dasar dari analisis regresi linier berganda univariat, karena masing-masing variabel tak bebas y yang terdapat dalam model regresi multivariat mengikuti model regresi linier berganda univariat.

Model regresi berganda univariat atau seringnya hanya disebut dengan model regresi linier berganda pada dasarnya digunakan untuk mengetahui ada tidaknya hubungan linier antara satu variabel tak bebas y dengan beberapa variabel bebas x . Pada umumnya variabel tak bebas y yang dihubungkan dengan q variabel bebas x mempunyai model:

$$y = \beta_0 + \beta_1 x_1 + \dots + \beta_q x_q + \varepsilon \quad (2.1.1)$$

Misalkan banyaknya pengamatan n , y_i menyatakan pengamatan ke $-i$ dari variabel tak bebas y dan x_{ik} menyatakan pengamatan ke- i dari variabel bebas x_k

($k=1,2,\dots,q$), maka data untuk regresi linier berganda dapat disusun seperti pada tabel 2.1.1.

Tabel 2.1.1 Data untuk Regresi Linier Berganda Univariat

y	X ₁	X ₂	...	X _q
y ₁	x ₁₁	x ₁₂	...	x _{1q}
y ₂	x ₂₁	x ₂₂	...	x _{2q}
...
y _n	x _{n1}	x _{n2}	...	x _{nq}

Dari data tersebut dapat dibentuk model regresi linier berganda yaitu:

$$\begin{aligned}
 y_i &= \beta_0 + \beta_1 x_{i1} + \dots + \beta_q x_{iq} + \varepsilon_i \\
 &= \beta_0 + \sum_{k=1}^q \beta_k x_{ik} + \varepsilon_i
 \end{aligned}
 \tag{2.1.2}$$

Biasanya untuk memudahkan analisis, persamaan (2.1.2) disajikan dalam bentuk matrik sebagai berikut:

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}
 \tag{2.1.3}$$

dimana

$$\mathbf{y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} \quad \mathbf{X} = \begin{bmatrix} 1 & x_{11} & x_{12} & \dots & x_{1q} \\ 1 & x_{21} & x_{22} & \dots & x_{2q} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & x_{n2} & \dots & x_{nq} \end{bmatrix}$$

$$\beta = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_q \end{bmatrix} \quad \varepsilon = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_q \end{bmatrix}$$

Pada persamaan (2.1.3) y adalah sebuah vektor pengamatan dari variabel tak bebas y berukuran $(n \times 1)$, X adalah sebuah matrik $n \times (q+1)$ dari variabel-variabel bebas x , β adalah sebuah vektor $(q+1) \times 1$ dari koefisien-koefisien regresi dan ε adalah sebuah vektor $(n \times 1)$ dari error random.

Dengan metode kuadrat terkecil diperoleh estimator kuadrat terkecil untuk β yaitu:

$$\hat{\beta} = (X'X)^{-1}Xy \quad (2.1.4)$$

$\hat{\beta}$ pada persamaan (2.1.4) merupakan estimator tak bias karena $E(\hat{\beta}) = \beta$ dan mempunyai varian yang minimum yaitu:

$$\text{Var}(\hat{\beta}) = \sigma^2(X'X)^{-1} \quad (2.1.5)$$

Bahwa $\text{Var}(\hat{\beta}) = \sigma^2(X'X)^{-1}$ mempunyai varian terkecil dari semua estimator linier tak bias dijamin oleh Gauss-Markov.

Theorema 2.1.1 (Theorema Gauss-Markov)

Estimator kuadrat terkecil $\hat{\beta} = (X'X)^{-1}Xy$ mempunyai varian terkecil dalam himpunan semua estimator linier tak bias.

Bukti :

Untuk menunjukkan bahwa $\hat{\beta}$ memiliki varian yang terkecil adalah dengan membandingkan varian dari estimator linier tak bias yang lain.

Misalkan $\hat{\gamma}$ adalah suatu estimator linier lain yang tak bias untuk β . Karena $\hat{\gamma}$ estimator linier, maka dapat dimisalkan bentuknya sebagai:

$$\hat{\gamma} = (\mathbf{U} + (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}')\mathbf{y} \quad (2.1.6)$$

untuk suatu matrik \mathbf{U} yang merupakan fungsi dari \mathbf{X} .

Karena pada persamaan (2.1.3) $\mathbf{y} = \mathbf{X}\beta + \varepsilon$, maka (2.1.6) menjadi

$$\begin{aligned} \hat{\gamma} &= (\mathbf{U} + (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}')(\mathbf{X}\beta + \varepsilon) \\ &= (\mathbf{U}\mathbf{X}\beta + \mathbf{U}\varepsilon + (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{X}\beta + (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\varepsilon) \\ &= \mathbf{U}\mathbf{X}\beta + \mathbf{U}\varepsilon + \beta + (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\varepsilon \end{aligned} \quad (2.1.7)$$

$$\begin{aligned} E(\hat{\gamma}) &= E(\mathbf{U}\mathbf{X}\beta + \mathbf{U}\varepsilon + \beta + (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\varepsilon) \\ &= \mathbf{U}\mathbf{X}\beta + \beta, \text{ karena } E(\varepsilon) = \mathbf{0} \\ &= (\mathbf{U}\mathbf{X} + \mathbf{I})\beta \\ &= \beta \end{aligned} \quad (2.1.8)$$

$$\text{Karena } \hat{\gamma} \text{ tak bias, maka } \mathbf{U}\mathbf{X} = \mathbf{0} \quad (2.1.9)$$

Jadi,

$$\text{Var}(\hat{\gamma}) = E(\hat{\gamma} - E(\hat{\gamma}))(\hat{\gamma} - E(\hat{\gamma}))'$$

sesuai persamaan (2.1.7) dan (2.1.8)

$$\begin{aligned} &= E((\mathbf{U}\mathbf{X}\beta + \mathbf{U}\varepsilon + \beta + (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\varepsilon) - (\mathbf{U}\mathbf{X}\beta + \beta)) \\ &\quad ((\mathbf{U}\mathbf{X}\beta + \mathbf{U}\varepsilon + \beta + (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\varepsilon) - (\mathbf{U}\mathbf{X}\beta + \beta))' \\ &= E((\mathbf{U} + (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}')\varepsilon)((\mathbf{U} + (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}')\varepsilon)' \\ &= E(\mathbf{U} + (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}')\varepsilon\varepsilon'(\mathbf{U}' + \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}) \end{aligned}$$

$$\begin{aligned}
&= (\mathbf{U} + (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}') E(\boldsymbol{\varepsilon}\boldsymbol{\varepsilon}') (\mathbf{U}' + \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}) \\
&= \sigma^2 (\mathbf{U} + (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}') (\mathbf{U}' + \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}) \\
&= \sigma^2 (\mathbf{U}\mathbf{U}' + \mathbf{U}\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} + (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{U}' \\
&\quad + (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}) \\
&= \sigma^2 (\mathbf{U}\mathbf{U}' + \mathbf{U}\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1} + (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{U}' + (\mathbf{X}'\mathbf{X})^{-1})
\end{aligned}$$

Menurut persamaan (2.1.9), $\mathbf{U}\mathbf{X} = \mathbf{0}$ dan menyebabkan $(\mathbf{U}\mathbf{X})' = \mathbf{0}$

Maka,

$$\text{Var}(\hat{\mathbf{y}}) = \sigma^2 (\mathbf{U}\mathbf{U}' + (\mathbf{X}'\mathbf{X})^{-1}) \quad (2.1.10)$$

Sedangkan menurut persamaan (2.1.5) $\text{var}(\hat{\boldsymbol{\beta}}) = \sigma^2 (\mathbf{X}'\mathbf{X})^{-1}$.

Untuk menentukan varian yang terkecil diperlukan Definisi 2.2.2 point 2 beserta kriteria Sylvester untuk kesemidefinitan positif bentuk kuadrat.

Dengan melihat $\mathbf{U}\mathbf{U}'$ yang merupakan matrik simetrik dengan diagonal utama positif (berbentuk kuadrat) sehingga determinan minor utamanya adalah positif atau sekurang-kurangnya sama dengan nol, dengan demikian $\mathbf{U}\mathbf{U}'$ adalah suatu matrik semidefinit positif. Maka estimator dalam persamaan (2.1.6) mempunyai varian (2.1.10) yang lebih besar atau sama dengan (2.1.5). Berarti di antara semua estimator linier tak bias, estimator kuadrat terkecil $\hat{\boldsymbol{\beta}}$ mempunyai varian terkecil.

(bukti selesai).

Untuk tujuan hipotesis terdapat asumsi-asumsi yang harus dipenuhi oleh model regresi linier berganda univariat. Asumsi-asumsi pada model regresi linier berganda univariat adalah:

1. Nilai harapan dari vektor error ε dari tiap unsurnya adalah nol, secara eksplisit, $E(\varepsilon) = \mathbf{0}$.
2. Varian ε_i adalah angka konstan positif yang sama dengan σ^2 , secara eksplisit $Var(\varepsilon) = E(\varepsilon\varepsilon') = \sigma^2\mathbf{I}_n$. Asumsi ini disebut dengan homokedastisitas varian.
3. Error ε_i dan ε_j tidak berkorelasi, $\forall i \neq j$
4. Error independen dan berdistribusi $N(0, \sigma^2)$
5. Tidak ada korelasi linier (multikolinearitas) antar variabel bebas x .

Pengujian hipotesis pada model regresi linier berganda dilakukan untuk mengetahui ada tidaknya hubungan linier antara sebuah variabel tidak bebas y dan variabel bebas x_1, x_2, \dots, x_q secara keseluruhan dengan pendekatan hipotesis sebagai berikut:

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

$$H_1 : \beta_k \neq 0 \text{ untuk paling sedikit satu } k, k=1,2,\dots,q \quad (2.1.11)$$

Didefinisikan jumlah kuadrat dengan perumusan sebagai berikut:

$$JKR = \hat{\beta}'\mathbf{X}'\mathbf{y} - n\bar{y}^2$$

$$JKE = \mathbf{y}'\mathbf{y} - \hat{\beta}'\mathbf{X}'\mathbf{y}$$

$$JKT = JKR + JKE$$

$$= \mathbf{y}'\mathbf{y} - n\bar{y}^2$$

di mana

JKR = Jumlah Kuadrat Regresi

JKE = Jumlah Kuadrat Residual

JKT = Jumlah Kuadrat Total

Derajat bebas (db) untuk masing-masing jumlah kuadrat adalah

db regresi = q yaitu banyaknya parameter regresi selain parameter konstanta

db residual = $n - q - 1$, dengan n banyaknya pengamatan

db total = $n - 1$

Statistik uji untuk hipotesis pada persamaan (2.1.11) adalah

$$F_0 = \frac{KTR}{KTE} = \frac{JKR/q}{JKE/n - q - 1} \quad (2.1.12)$$

di mana

KTR = Kuadrat Tengah Regresi

KTE = Kuadrat Tengah Residual

Statistik uji F_0 mengikuti distribusi $F_{q, n-q-1}$. Dengan taraf signifikansi α

tertentu, pengambilan keputusan untuk hipotesis pada persamaan (2.1.11) yaitu

menolak H_0 jika $F_0 > F_{\alpha, q, n-q-1}$, untuk $F_{\alpha, q, n-q-1}$ merupakan nilai kritis dari

distribusi F. Penolakan $H_0 : \beta_k = 0$ menyatakan paling sedikit satu variabel

bebas x_1, x_2, \dots, x_q memberikan sumbangan yang nyata pada model

tersebut. Prosedur pengujian dinyatakan dalam tabel analisis varian tabel 2.1.2

Tabel 2.1.2 Analisis Varian untuk Nyata Regresi

Pada Model Regresi Linier Berganda

Sumber variansi	Jumlah kuadrat	Derajat Bebas	Rata-rata jumlah kuadrat	F_0
Regresi	JKR	q	KTR	$\frac{KTR}{KTE}$
Residual	JKE	n-q-1	KTE	
Total	JKT	n-1		

Untuk menentukan signifikan tidaknya nilai dari setiap variabel-variabel bebas dalam model dilakukan uji nyata regresi secara individu. Pendekatan hipotesisnya adalah:

$$H_0 : \beta_k = 0$$

$$H_1 : \beta_k \neq 0, \text{ untuk masing-masing } k, k=1,2,\dots,q.$$

Statistik ujinya

$$t = \frac{\hat{\beta}_k}{\sqrt{\hat{\sigma}^2 C_{kk}}} \quad (2.1.13)$$

dengan C_{kk} adalah elemen diagonal $(X'X)^{-1}$ yang berhubungan dengan β_k .

Dengan pengambilan α tertentu, hipotesis nol ditolak jika $|t| > t_{\alpha/2, n-q-1}$.

$t_{\alpha/2, n-q-1}$ adalah nilai kritis dari distribusi t. Jika $H_0 : \beta_k = 0$ diterima,

menunjukkan bahwa x_k dapat dihilangkan dari model.

Untuk mengukur seberapa jauh kecocokan dari suatu model regresi digunakan koefisien determinasi berganda R^2 . Nilai R^2 menyatakan besarnya sumbangan keseluruhan variabel bebas x terhadap variabel tak bebas y . Besarnya R^2 didefinisikan:

$$R^2 = \frac{JKR}{JKT} = 1 - \frac{JKE}{JKT} \quad (2.1.14)$$

Nilai R^2 berkisar antara 0 sampai 1 ($0 \leq R^2 \leq 1$). Semakin besar nilai R^2 mengindikasikan semakin cocok model yang diperoleh.

2.2 Matrik

Konsep aljabar vektor matrik sangat diperlukan dalam analisis multivariat. Dengan menggunakan aljabar vektor matrik perhitungan-perhitungan yang rumit dapat dihindari. Telah diperlihatkan pada sub bab 2.1. vektor dan matrik dapat digunakan untuk memudahkan dalam menyatakan model regresi beserta analisisnya. Dalam sub bab 2.2. berikut akan dibahas hal-hal mengenai vektor dan matrik yang diperlukan dalam analisis regresi multivariat, yang kesemuanya terangkum dalam definisi-definisi di bawah ini.

Definisi 2.2.1

Misalkan $A = \{a_{ij}\}$ adalah matrik bujursangkar berukuran $p \times p$. Trace dari matrik

A ditulis $\text{tr}(A)$ adalah jumlahan dari elemen-elemen diagonalnya, sehingga

$$\text{tr}(A) = \sum_{i=1}^p a_{ii} \quad (2.2.1)$$

Sifat-sifat dari trace adalah sebagai berikut. Misalkan A dan B matrik bujursangkar berukuran $p \times p$ dan x vektor berukuran $p \times 1$.

$$1. \operatorname{tr}(A \pm B) = \operatorname{tr}(A) \pm \operatorname{tr}(B) \quad (2.2.2)$$

$$2. \operatorname{tr}(AB) = \operatorname{tr}(BA) \quad (2.2.3)$$

$$3. x'Ax = \operatorname{tr}(x'Ax) = \operatorname{tr}(Axx') \quad (2.2.4)$$

$$4. \operatorname{tr}(A) = \sum_{i=1}^p \lambda_i, \text{ dengan } \lambda \text{ merupakan nilai eigen untuk matrik simetrik } A \quad (2.2.5)$$

Definisi 2.2.2

Jika A adalah matrik bujur sangkar, maka A dikatakan matrik simetrik jika $A' = A$. Misalkan A matrik simetrik berukuran $p \times p$ dan x adalah vektor berukuran $p \times 1$.

1. Matrik A dikatakan matrik definit positif apabila bentuk kuadrat $x'Ax$ nilainya positif ($x'Ax > 0$) untuk setiap x kecuali $x = 0$.

Terdapat kondisi perlu untuk memenuhi bentuk kuadrat $x'Ax$ menjadi definit positif yaitu jika determinan A adalah positif dan minor utama determinan A (determinan matrik $k \times k$ pada sudut kiri matrik A dengan $k=1,2,\dots,p-1$) secara berturut-turut adalah positif yaitu

$$a_{11} > 0, \begin{vmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{vmatrix} > 0, \begin{vmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{vmatrix} > 0, \dots, |A| > 0$$

(kondisi ini disebut kriteria Sylvester untuk kedefinitan positif bentuk kuadrat)

2. Matrik A dikatakan matrik semidefinit positif apabila bentuk kuadrat $x'Ax$ nilainya nonnegatif ($x'Ax \geq 0$) untuk setiap x dan ada nilai-nilai $x \neq 0$ dimana $x'Ax = 0$.

Kondisi perlu dan mencukupi untuk bentuk kuadratik $x'Ax$, menjadi semi definit positif jika A singular ($|A| = 0$) dan semua minor utamanya adalah tak negatif.

$$a_{ii} \geq 0, \begin{vmatrix} a_{ii} & a_{ij} \\ a_{ji} & a_{jj} \end{vmatrix} \geq 0, \begin{vmatrix} a_{ii} & a_{ij} & a_{ik} \\ a_{ji} & a_{jj} & a_{jk} \\ a_{ki} & a_{kj} & a_{kk} \end{vmatrix} \geq 0, \dots, |A| = 0$$

dengan $i < j < k$

(kondisi ini disebut kriteria Sylvester untuk kesemidefinitan positif bentuk kuadrat)

Definisi 2.2.3

Misalkan A matrik nonsingular yaitu matrik dengan determinan tidak sama dengan nol, maka determinan dari invers matrik nonsingular didefinisikan sebagai

$$|A^{-1}| = \frac{1}{|A|} \quad (2.2.6)$$

Definisi 2.2.4

- Misalkan $u = f(x) = f(x_1, x_2, \dots, x_p)$ adalah fungsi skalar dari variabel x_1, x_2, \dots, x_p . Differensial parsial tingkat satu terhadap vektor x didefinisikan sebagai

$$\frac{\partial u}{\partial \mathbf{x}} = \begin{bmatrix} \frac{\partial u}{\partial x_1} \\ \frac{\partial u}{\partial x_2} \\ \vdots \\ \frac{\partial u}{\partial x_p} \end{bmatrix} \quad (2.2.7)$$

2. Misalkan $u = f(\mathbf{A}) = f(a_{11}, a_{22}, \dots, a_{pp})$, dimana \mathbf{A} matrik simetrik .

Differensial parsial tingkat satu u terhadap matrik \mathbf{A} didefinisikan sebagai

$$\frac{\partial u}{\partial \mathbf{A}} = \begin{bmatrix} \frac{\partial u}{\partial a_{11}} & \frac{\partial u}{\partial a_{12}} & \dots & \frac{\partial u}{\partial a_{1p}} \\ \frac{\partial u}{\partial a_{21}} & \frac{\partial u}{\partial a_{22}} & \dots & \frac{\partial u}{\partial a_{2p}} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial u}{\partial a_{p1}} & \frac{\partial u}{\partial a_{p2}} & \dots & \frac{\partial u}{\partial a_{pp}} \end{bmatrix} \quad (2.2.8)$$

Sifat-sifat derivatif parsial tingkat satu pada vektor dan matrik adalah sebagai berikut, misalkan \mathbf{x}, \mathbf{a} vektor berukuran $p \times 1$ dan \mathbf{A} dan \mathbf{C} matrik simetrik berukuran $p \times p$

1. Misalkan $u = \mathbf{a}'\mathbf{x} = \mathbf{x}'\mathbf{a}$

$$\frac{\partial(\mathbf{a}'\mathbf{x})}{\partial \mathbf{x}} = \frac{\partial(\mathbf{x}'\mathbf{a})}{\partial \mathbf{x}} = \mathbf{a} \quad (2.2.9)$$

2. Misalkan $u = \mathbf{x}'\mathbf{A}\mathbf{x}$

$$\frac{\partial(\mathbf{x}'\mathbf{A}\mathbf{x})}{\partial \mathbf{x}} = 2\mathbf{A}\mathbf{x} \quad (2.2.10)$$

3. $\frac{\partial \text{tr}(\mathbf{A}\mathbf{C})}{\partial \mathbf{A}} = 2\mathbf{C} - \text{diag}(\mathbf{C})$ (2.2.11)

$$4. \frac{\partial \ln|A|}{\partial A} = 2A^{-1} - \text{diag}(A^{-1}), A \text{ nonsingular} \quad (2.2.12)$$

Definisi 2.2.5

Vektor-vektor a_1, a_2, \dots, a_n dikatakan bergantung linier jika terdapat konstanta c_1, c_2, \dots, c_n (tidak semua nol) sedemikian hingga

$$c_1 a_1 + c_2 a_2 + \dots + c_n a_n = 0 \quad (2.2.13)$$

jika tidak demikian a_1, a_2, \dots, a_n dikatakan bebas linier.

Definisi 2.2.6

Rank suatu matrik A didefinisikan dengan

$$\begin{aligned} \text{Rank}(A) &= \text{jumlah dari baris yang bebas linier pada matrik } A \\ &= \text{jumlah dari kolom yang bebas linier pada matrik } A \end{aligned}$$

Definisi 2.2.7

Dua buah vektor a dan b yang masing-masing berukuran $n \times 1$ dikatakan ortogonal jika

$$a' b = a_1 b_1 + a_2 b_2 + \dots + a_n b_n = 0 \quad (2.2.14)$$

Dua buah vektor eigen yang berlainan pada matrik simetrik adalah saling ortogonal. Vektor eigen diterangkan lebih lanjut dalam Definisi 2.2.8.

Definisi 2.2.8

Misalkan A adalah matrik bujur sangkar berukuran $n \times n$, λ adalah skalar dan e adalah vektor kolom dengan $e \neq 0$, sedemikian sehingga memenuhi $Ae = \lambda e$, maka dikatakan bahwa λ adalah suatu nilai eigen dari A , dan e adalah vektor eigen yang bersesuaian dengan λ .

Nilai eigen dicari dengan menggunakan persamaan karakteristik:

$$\det(\mathbf{A} - \lambda \mathbf{I}) = 0 \quad (2.2.15)$$

Definisi 2.2.9

\mathbf{P} dikatakan matrik idempoten jika $\mathbf{P}^2 = \mathbf{P}$. Sebuah matrik idempoten sekaligus simetrik disebut dengan matrik proyeksi.

1. Jika \mathbf{P} matrik proyeksi berukuran $n \times n$ dan mempunyai rank r , maka \mathbf{P} akan mempunyai r nilai eigen yang berharga 1 dan $n-r$ sisanya nilai eigen berharga nol.
2. Jika \mathbf{P} matrik proyeksi maka $\text{tr}(\mathbf{P}) = \text{rank}(\mathbf{P})$.
3. Jika \mathbf{P} matrik idempoten, maka $(\mathbf{I} - \mathbf{P})$ juga matrik idempoten.

Definisi 2.2.10

\mathbf{A} adalah matrik simetrik $n \times n$ dengan nilai-nilai eigen $\lambda_1, \lambda_2, \dots, \lambda_n$ dan $\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_n$ merupakan vektor eigen ternormalisasi, maka *Dekomposisi spektral* dari matrik \mathbf{A} adalah

$$\begin{aligned} \mathbf{A} &= \lambda_1 \mathbf{e}_1 \mathbf{e}_1' + \lambda_2 \mathbf{e}_2 \mathbf{e}_2' + \dots + \lambda_n \mathbf{e}_n \mathbf{e}_n' \\ &= \sum_{i=1}^n \lambda_i \mathbf{e}_i \mathbf{e}_i' \end{aligned} \quad (2.2.16)$$

dengan $\mathbf{e}_i' \mathbf{e}_j = 1$ untuk $i = j$ dan 0 untuk $i \neq j$.

2.3 Distribusi Normal Multivariat

Kebanyakan prosedur inferensial multivariat didasarkan pada distribusi normal multivariat, yang merupakan generalisasi dari distribusi normal univariat.

Meskipun kebanyakan data yang sebenarnya tidak pernah tepat normal multivariat, distribusi normal multivariat sering digunakan untuk aproksimasi distribusi yang sebenarnya.

Definisi 2.3.1

Suatu vektor random y berukuran $p \times 1$, dikatakan berdistribusi p variat dengan rata-rata μ dan matrik kovarian Σ yang dinotasikan dengan $N_p(\mu, \Sigma)$, jika mempunyai fungsi densitas probabilitas sebagai berikut:

$$f(y) = \frac{1}{(\sqrt{2\pi})^p |\Sigma|^{1/2}} e^{-(y-\mu)' \Sigma^{-1} (y-\mu)/2} \quad (2.3.1)$$

dimana Σ definit positif dan $-\infty < y < \infty$.

Untuk mempermudah penulisan vektor y berukuran $p \times 1$ selanjutnya ditulis dengan y .

Theorema 2.3.1

Jika y berdistribusi $N_p(\mu, \Sigma)$, fungsi pembangkit momen dari y adalah

$$M_y(t) = e^{t' \mu + t' \Sigma t / 2} \quad (2.3.2)$$

Bukti :

Fungsi pembangkit momen dari y adalah

$$M_y(t) = E(e^{t'y})$$

$$\begin{aligned} &= \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} e^{t'y} \frac{1}{(\sqrt{2\pi})^p |\Sigma|^{1/2}} e^{-(y-\mu)' \Sigma^{-1} (y-\mu)/2} dy \\ &= \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} \frac{1}{(\sqrt{2\pi})^p |\Sigma|^{1/2}} e^{t' \mu + t' \Sigma t / 2 - (y-\mu-\Sigma t)' \Sigma^{-1} (y-\mu-\Sigma t)/2} dy \end{aligned}$$

$$\begin{aligned}
&= e^{\mathbf{t}'\boldsymbol{\mu} + \mathbf{t}'\boldsymbol{\Sigma}\mathbf{t}/2} \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} \frac{1}{(\sqrt{2\pi})^p |\boldsymbol{\Sigma}|^{1/2}} e^{-(\mathbf{y}-\boldsymbol{\mu}-\boldsymbol{\Sigma}\mathbf{t})' \boldsymbol{\Sigma}^{-1} (\mathbf{y}-\boldsymbol{\mu}-\boldsymbol{\Sigma}\mathbf{t})/2} d\mathbf{y} \\
&= e^{\mathbf{t}'\boldsymbol{\mu} + \mathbf{t}'\boldsymbol{\Sigma}\mathbf{t}/2} \quad (\text{bukti selesai})
\end{aligned}$$

Pada distribusi normal multivariat ada dua parameter yang nilainya tidak diketahui yaitu $\boldsymbol{\mu}$ dan $\boldsymbol{\Sigma}$, untuk itu nilai dari parameter tersebut harus diestimasi. Metode yang sering digunakan untuk menentukan estimator dari parameter adalah metode maksimum likelihood. Densitas bersama dari y_1, y_2, \dots, y_n disebut fungsi likelihood. Estimator maksimum likelihood adalah nilai parameter yang memaksimalkan fungsi likelihood. Berikut ini akan ditentukan estimator maksimum likelihood dari $\boldsymbol{\mu}$ dan $\boldsymbol{\Sigma}$ untuk suatu sampel random dari distribusi normal multivariat.

Theorema 2.3.2

Jika y_1, y_2, \dots, y_n vektor random yang independen berdistribusi $N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$, maka estimator maksimum likelihood dari $\boldsymbol{\mu}$ dan $\boldsymbol{\Sigma}$ adalah

$$\hat{\boldsymbol{\mu}} = \bar{\mathbf{y}} \quad (2.3.3)$$

$$\hat{\boldsymbol{\Sigma}} = \frac{1}{n} \sum_{i=1}^n (\mathbf{y}_i - \bar{\mathbf{y}})(\mathbf{y}_i - \bar{\mathbf{y}})' = \frac{1}{n} \mathbf{W} \quad (2.3.4)$$

dimana $\mathbf{W} = \sum_{i=1}^n (\mathbf{y}_i - \bar{\mathbf{y}})(\mathbf{y}_i - \bar{\mathbf{y}})'$

Bukti:

Fungsi Likelihood (densitas bersama) dari y_i adalah hasil kali densitas dari masing-masing y_i

$$\begin{aligned}
 L(\boldsymbol{\mu}, \boldsymbol{\Sigma}) &= \prod_{i=1}^n \frac{1}{(\sqrt{2\pi})^p |\boldsymbol{\Sigma}|^{1/2}} e^{-\frac{1}{2}(\mathbf{y}_i - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{y}_i - \boldsymbol{\mu})} \\
 &= \frac{1}{(\sqrt{2\pi})^{np} |\boldsymbol{\Sigma}|^{n/2}} e^{-\frac{1}{2} \sum_{i=1}^n (\mathbf{y}_i - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{y}_i - \boldsymbol{\mu})}
 \end{aligned} \tag{2.3.5}$$

Selanjutnya akan ditentukan nilai $\boldsymbol{\mu}$ dan $\boldsymbol{\Sigma}$ yang memaksimumkan persamaan (2.3.5). Berdasarkan persamaan (2.2.2) dan (2.2.4) diperoleh

$$\begin{aligned}
 \sum_{i=1}^n (\mathbf{y}_i - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{y}_i - \boldsymbol{\mu}) &= \sum_{i=1}^n \text{tr}(\mathbf{y}_i - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\mathbf{y}_i - \boldsymbol{\mu}) \\
 &= \text{tr}(\boldsymbol{\Sigma}^{-1} \sum_{i=1}^n (\mathbf{y}_i - \boldsymbol{\mu})(\mathbf{y}_i - \boldsymbol{\mu})')
 \end{aligned} \tag{2.3.6}$$

$$\begin{aligned}
 \sum_{i=1}^n (\mathbf{y}_i - \boldsymbol{\mu})(\mathbf{y}_i - \boldsymbol{\mu})' &= \sum_{i=1}^n (\mathbf{y}_i - \bar{\mathbf{y}} + \bar{\mathbf{y}} - \boldsymbol{\mu})(\mathbf{y}_i - \bar{\mathbf{y}} + \bar{\mathbf{y}} - \boldsymbol{\mu})' \\
 &= \sum_{i=1}^n (\mathbf{y}_i - \bar{\mathbf{y}})(\mathbf{y}_i - \bar{\mathbf{y}})' + \sum_{i=1}^n (\mathbf{y}_i - \bar{\mathbf{y}})(\bar{\mathbf{y}} - \boldsymbol{\mu})' \\
 &\quad + \sum_{i=1}^n (\bar{\mathbf{y}} - \boldsymbol{\mu})(\mathbf{y}_i - \bar{\mathbf{y}})' + \sum_{i=1}^n (\bar{\mathbf{y}} - \boldsymbol{\mu})(\bar{\mathbf{y}} - \boldsymbol{\mu})'
 \end{aligned}$$

karena

$$\begin{aligned}
 \sum_{i=1}^n (\mathbf{y}_i - \bar{\mathbf{y}})(\bar{\mathbf{y}} - \boldsymbol{\mu})' &= (\sum_{i=1}^n \mathbf{y}_i - \sum_{i=1}^n \bar{\mathbf{y}})(\bar{\mathbf{y}} - \boldsymbol{\mu})' \\
 &= (n\bar{\mathbf{y}} - n\bar{\mathbf{y}})(\bar{\mathbf{y}} - \boldsymbol{\mu})' \\
 &= \mathbf{0}
 \end{aligned}$$

$$\begin{aligned}
 \sum_{i=1}^n (\mathbf{y}_i - \boldsymbol{\mu})(\mathbf{y}_i - \boldsymbol{\mu})' &= \sum_{i=1}^n (\mathbf{y}_i - \bar{\mathbf{y}})(\mathbf{y}_i - \bar{\mathbf{y}})' + n(\bar{\mathbf{y}} - \boldsymbol{\mu})(\bar{\mathbf{y}} - \boldsymbol{\mu})' \\
 &= \mathbf{W} + n(\bar{\mathbf{y}} - \boldsymbol{\mu})(\bar{\mathbf{y}} - \boldsymbol{\mu})'
 \end{aligned} \tag{2.3.7}$$

Substitusi persamaan (2.3.7) ke dalam persamaan (2.3.6) kemudian substitusi ke dalam persamaan (2.3.5), sehingga diperoleh

$$L(\boldsymbol{\mu}, \boldsymbol{\Sigma}) = \frac{1}{(\sqrt{2\pi})^n p |\boldsymbol{\Sigma}|^{n/2}} e^{-\text{tr} \boldsymbol{\Sigma}^{-1} (\mathbf{W} + n(\bar{\mathbf{y}} - \boldsymbol{\mu})(\bar{\mathbf{y}} - \boldsymbol{\mu})')/2} \quad (2.3.8)$$

Karena logaritma natural adalah fungsi naik, maksimum dari $\ln L$ akan terjadi pada titik yang sama dengan maksimum L . Pengoperasian dengan $\ln L$ pada L untuk mempermudah dalam pendefferensialan. Dengan pengoperasian \ln pada L diperoleh

$$\ln L(\boldsymbol{\mu}, \boldsymbol{\Sigma}) = -n \ln(\sqrt{2\pi}) - \frac{n}{2} \ln |\boldsymbol{\Sigma}| - \frac{1}{2} \text{tr} \boldsymbol{\Sigma}^{-1} (\mathbf{W} + n(\bar{\mathbf{y}} - \boldsymbol{\mu})(\bar{\mathbf{y}} - \boldsymbol{\mu})') \quad (2.3.9)$$

Berdasarkan persamaan (2.2.2) dan (2.2.4) diperoleh

$$\begin{aligned} \ln L(\boldsymbol{\mu}, \boldsymbol{\Sigma}) &= -n \ln(\sqrt{2\pi}) - \frac{n}{2} \ln |\boldsymbol{\Sigma}| - \frac{1}{2} \text{tr}(\boldsymbol{\Sigma}^{-1} \mathbf{W}) - \frac{n}{2} ((\bar{\mathbf{y}} - \boldsymbol{\mu})' \boldsymbol{\Sigma}^{-1} (\bar{\mathbf{y}} - \boldsymbol{\mu})) \\ &= -n \ln(\sqrt{2\pi}) - \frac{n}{2} \ln |\boldsymbol{\Sigma}| - \frac{1}{2} \text{tr}(\boldsymbol{\Sigma}^{-1} \mathbf{W}) \\ &\quad - \frac{n}{2} (\bar{\mathbf{y}}' \boldsymbol{\Sigma}^{-1} \bar{\mathbf{y}} - \boldsymbol{\mu}' \boldsymbol{\Sigma}^{-1} \bar{\mathbf{y}} - \bar{\mathbf{y}}' \boldsymbol{\Sigma}^{-1} \boldsymbol{\mu} + \boldsymbol{\mu}' \boldsymbol{\Sigma}^{-1} \boldsymbol{\mu}) \end{aligned}$$

Karena $\boldsymbol{\Sigma}^{-1}$ simetrik maka $(\boldsymbol{\Sigma}^{-1})' = \boldsymbol{\Sigma}^{-1}$, sehingga

$$\begin{aligned} \ln L(\boldsymbol{\mu}, \boldsymbol{\Sigma}) &= -n \ln(\sqrt{2\pi}) - \frac{n}{2} \ln |\boldsymbol{\Sigma}| - \frac{1}{2} \text{tr}(\boldsymbol{\Sigma}^{-1} \mathbf{W}) \\ &\quad - \frac{n}{2} (\bar{\mathbf{y}}' \boldsymbol{\Sigma}^{-1} \bar{\mathbf{y}} - \boldsymbol{\mu}' (\boldsymbol{\Sigma}^{-1} \bar{\mathbf{y}}) - (\boldsymbol{\Sigma}^{-1} \bar{\mathbf{y}})' \boldsymbol{\mu} + \boldsymbol{\mu}' \boldsymbol{\Sigma}^{-1} \boldsymbol{\mu}) \end{aligned}$$

Untuk menentukan estimator maksimum likelihood untuk $\boldsymbol{\mu}$ dan $\boldsymbol{\Sigma}$, $\ln L(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ didefferensialkan ke $\boldsymbol{\mu}$ dan menyamakannya dengan nol. Berdasarkan persamaan (2.2.9) dan (2.2.10) diperoleh

$$\frac{\partial \ln L(\mu, \Sigma)}{\partial \mu} = \mathbf{0}$$

$$\mathbf{0} + \mathbf{0} + \mathbf{0} - \frac{n}{2}(\mathbf{0} - \Sigma^{-1}\bar{\mathbf{y}} - \Sigma^{-1}\bar{\mathbf{y}} + 2\Sigma^{-1}\hat{\mu}) = \mathbf{0}$$

$$(\Sigma^{-1}\bar{\mathbf{y}} - \Sigma^{-1}\hat{\mu}) = \mathbf{0}$$

$$\Sigma^{-1}\bar{\mathbf{y}} = \Sigma^{-1}\hat{\mu}$$

$$\hat{\mu} = \bar{\mathbf{y}} \quad (2.3.10)$$

Sebelum pendifferensialkan $\ln L(\mu, \Sigma)$ untuk mendapatkan $\hat{\Sigma}$, substitusikan persamaan (2.3.10) ke dalam persamaan (2.3.9) dan berdasarkan persamaan

(2.2.6), $|\Sigma^{-1}| = \frac{1}{|\Sigma|}$ dengan pengoperasian \ln pada kedua ruas diperoleh

$\ln|\Sigma^{-1}| = -\ln|\Sigma|$, sehingga persamaan (2.3.9) dapat ditulis

$$\ln L(\hat{\mu}, \Sigma) = -n \ln(\sqrt{2\pi}) + \frac{n}{2} \ln|\Sigma^{-1}| - \frac{1}{2}(\text{tr}\Sigma^{-1}\mathbf{W}) \quad (2.3.11)$$

Persamaan (2.3.11) didifferensialkan terhadap Σ^{-1} dan menyamakannya dengan nol, berdasarkan persamaan (2.2.11) dan (2.2.12) diperoleh

$$\frac{\partial \ln(\hat{\mu}, \Sigma)}{\partial \Sigma^{-1}} = \mathbf{0}$$

$$\mathbf{0} + n\hat{\Sigma} - \frac{n}{2} \text{diag}(\hat{\Sigma}) - \mathbf{W} + \frac{1}{2} \text{diag}(\mathbf{W}) = \mathbf{0}$$

$$\hat{\Sigma} - \frac{1}{2} \text{diag}(\hat{\Sigma}) = \frac{1}{n}(\mathbf{W} - \frac{1}{2} \text{diag}(\mathbf{W})) \quad (2.3.12)$$

dinotasikan

$$\hat{\Sigma} = \begin{bmatrix} \hat{\sigma}_{11} & \hat{\sigma}_{12} & \dots & \hat{\sigma}_{1p} \\ \hat{\sigma}_{21} & \hat{\sigma}_{22} & \dots & \hat{\sigma}_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ \hat{\sigma}_{p1} & \hat{\sigma}_{p2} & \dots & \hat{\sigma}_{pp} \end{bmatrix} \quad \mathbf{W} = \begin{bmatrix} w_{11} & w_{12} & \dots & w_{1p} \\ w_{21} & w_{22} & \dots & w_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ w_{p1} & w_{p2} & \dots & w_{pp} \end{bmatrix}$$

$$\text{diag}(\hat{\Sigma}) = \begin{bmatrix} \hat{\sigma}_{11} & 0 & \dots & 0 \\ 0 & \hat{\sigma}_{22} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \hat{\sigma}_{pp} \end{bmatrix}$$

$$\text{diag}(\mathbf{W}) = \begin{bmatrix} w_{11} & 0 & \dots & 0 \\ 0 & w_{22} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & w_{pp} \end{bmatrix}$$

Perhatikan untuk selain elemen diagonal diperoleh

$$\hat{\sigma}^2_{jj} = \frac{1}{n} w_{jk}, \text{ untuk } j \neq k \quad (2.3.13)$$

Perhatikan untuk elemen diagonal

$$\hat{\sigma}^2_{jj} = \frac{1}{n} w_{jj} \quad (2.3.14)$$

Dari persamaan (2.3.13) dan (2.3.14) dapat disimpulkan bahwa

$$\hat{\Sigma} = \frac{1}{n} \mathbf{W} \quad (2.3.15)$$

Sehingga estimator maksimum likelihood untuk Σ adalah

$$\hat{\Sigma} = \frac{1}{n} \mathbf{W}$$

(Bukti selesai)

Beberapa sifat penting dari distribusi normal multivariat adalah sebagai berikut, misalkan y_i independen berdistribusi $N_p(\mu, \Sigma)$, A matrik, b vektor dan a konstanta

$$1. \quad y+b \text{ berdistribusi } N_p(\mu +b, \Sigma) \quad (2.3.16)$$

$$2. \quad ay \text{ berdistribusi } N_p(a\mu, a^2 \Sigma) \quad (2.3.17)$$

$$3. \quad \sum_{i=1}^n y_i \text{ berdistribusi } N_p(n\mu, n\Sigma) \quad (2.3.18)$$

$$4. \quad \bar{y} = \frac{1}{n} \sum_{i=1}^n y_i \text{ berdistribusi } N_p(\mu, 1/n\Sigma) \quad (2.3.19)$$

$$5. \quad \sum_{i=1}^n a_i y_i \text{ berdistribusi } N_p\left(\sum_{i=1}^n a_i \mu, \sum_{i=1}^n a_i^2 \Sigma\right) \quad (2.3.20)$$

$$6. \quad Ay \text{ berdistribusi } N_q(A\mu, A\Sigma A'), A \text{ berukuran } q \times p \quad (2.3.21)$$

Dalam Theorema 2.3.3 berikut akan ditunjukkan bahwa kombinasi linier komponen-komponen yang berdistribusi normal multivariat juga berdistribusi normal multivariat.

Theorema 2.3.3:

y_1, y_2, \dots, y_n merupakan vektor random berukuran $p \times 1$ dan masing-masing independen dan berdistribusi $N_p(\mu_i, \Sigma)$ dan

$$V_1 = c_1 y_1 + c_2 y_2 + \dots + c_n y_n$$

$$V_2 = b_1 y_1 + b_2 y_2 + \dots + c_n y_n$$

maka V_1 dan V_2 mempunyai distribusi bersama normal multivariat dengan matrik kovarian

$$\begin{bmatrix} (\sum_{i=1}^n c_i^2)\Sigma & \mathbf{b}'\mathbf{c}\Sigma \\ \mathbf{b}'\mathbf{c}\Sigma & (\sum_{i=1}^n b_i^2)\Sigma \end{bmatrix}$$

dan V_1 dan V_2 independen bila $\mathbf{b}'\mathbf{c} = (\sum_{i=1}^n c_i b_i) = 0$.

Bukti:

y_1, y_2, \dots, y_n independen

$$\mathbf{y}' = (y_1', y_2', \dots, y_n')$$

$$= (y_{11}, y_{12}, \dots, y_{1p}, y_{21}, y_{22}, \dots, y_{2p}, y_{n1}, y_{n2}, \dots, y_{np})'$$

\mathbf{y}' berukuran $1 \times np$.

Sehingga \mathbf{y} berdistribusi $N_{np}(\boldsymbol{\mu}, \boldsymbol{\Sigma}_y)$ dengan

$$\boldsymbol{\mu} = \begin{bmatrix} \mu_1 \\ \vdots \\ \mu_p \end{bmatrix} \quad \boldsymbol{\Sigma}_y = \begin{bmatrix} \Sigma & 0 & \dots & 0 \\ 0 & \Sigma & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \Sigma \end{bmatrix}$$

Dengan memilih $\mathbf{A} = \begin{bmatrix} c_1 \mathbf{I} & c_2 \mathbf{I} & \dots & c_n \mathbf{I} \\ b_1 \mathbf{I} & b_2 \mathbf{I} & \dots & b_n \mathbf{I} \end{bmatrix}$, \mathbf{A} berukuran $2p \times np$

\mathbf{I} adalah matrik identitas berukuran $p \times p$.

Berdasarkan persamaan (2.3.21) $\mathbf{A}\mathbf{y}$ berdistribusi $N_{2p}(\mathbf{A}\boldsymbol{\mu}, \mathbf{A}\boldsymbol{\Sigma}_y\mathbf{A}')$

Kovarian

$$A \Sigma y A' = \begin{bmatrix} c_1 \mathbf{I} & c_2 \mathbf{I} & \dots & c_n \mathbf{I} \\ b_1 \mathbf{I} & b_2 \mathbf{I} & \dots & b_n \mathbf{I} \end{bmatrix} \begin{bmatrix} \Sigma & 0 & \dots & 0 \\ 0 & \Sigma & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \Sigma \end{bmatrix} \begin{bmatrix} c_1 \mathbf{I} & b_1 \mathbf{I} \\ c_2 \mathbf{I} & b_2 \mathbf{I} \\ \vdots & \vdots \\ c_n \mathbf{I} & b_n \mathbf{I} \end{bmatrix}$$

$$= \begin{bmatrix} c_1 \mathbf{I} \Sigma & c_2 \mathbf{I} \Sigma & \dots & c_n \mathbf{I} \Sigma \\ b_1 \mathbf{I} \Sigma & b_2 \mathbf{I} \Sigma & \dots & b_n \mathbf{I} \Sigma \end{bmatrix} \begin{bmatrix} c_1 \mathbf{I} & b_1 \mathbf{I} \\ c_2 \mathbf{I} & b_2 \mathbf{I} \\ \vdots & \vdots \\ c_n \mathbf{I} & b_n \mathbf{I} \end{bmatrix}$$

$$= \begin{bmatrix} (\sum_{i=1}^n c_i^2) \Sigma & (\sum_{i=1}^n c_i b_i) \Sigma \\ (\sum_{i=1}^n c_i b_i) \Sigma & (\sum_{i=1}^n b_i^2) \Sigma \end{bmatrix}$$

$$= \begin{bmatrix} (\sum_{i=1}^n c_i^2) \Sigma & \mathbf{b}' \mathbf{c} \Sigma \\ \mathbf{b}' \mathbf{c} \Sigma & (\sum_{i=1}^n b_i^2) \Sigma \end{bmatrix}$$

$(\sum_{i=1}^n c_i^2) \Sigma$ menyatakan varian V_1

$(\sum_{i=1}^n b_i^2) \Sigma$ menyatakan varian V_2

$(\sum_{i=1}^n c_i b_i) \Sigma = \mathbf{b}' \mathbf{c} \Sigma$ menyatakan kovarian antara V_1 dan V_2

bila $(\sum_{i=1}^n c_i b_i) = \mathbf{b}' \mathbf{c} = 0$ maka $(\sum_{i=1}^n c_i b_i) \Sigma = \mathbf{b}' \mathbf{c} \Sigma = \mathbf{O}$.

Karena kovarian antara V_1 dan V_2 sama dengan \mathbf{O} maka V_1 dan V_2 independen. (bukti selesai).

2.4 Distribusi Wishart

Distribusi wishart memegang peranan penting dari prosedur inferensial multivariat. Distribusi wishart dapat diturunkan dari distribusi normal multivariat.

Definisi 2.4.1

Jika matrik $\mathbf{Z}'\mathbf{Z} = \sum_{i=1}^n \mathbf{z}_i \mathbf{z}_i'$ dengan \mathbf{z}_i adalah baris ke- i dari matrik \mathbf{Z} berukuran $n \times p$, independen berdistribusi $N_p(\mathbf{0}, \Sigma)$, maka $\mathbf{Z}'\mathbf{Z}$ dikatakan berdistribusi wishart dengan derajat kebebasan n dan matrik kovarian Σ dinotasikan $W_p(n, \Sigma)$. Dengan \mathbf{Z} didefinisikan sebagai

$$\mathbf{Z} = \begin{bmatrix} \mathbf{z}_1 \\ \mathbf{z}_2 \\ \vdots \\ \mathbf{z}_n \end{bmatrix} \quad (2.4.1)$$

Subskrip p menunjukkan ukuran matrik $\mathbf{Z}'\mathbf{Z}$. Untuk $n \geq p$ $\mathbf{Z}'\mathbf{Z}$ mempunyai fungsi densitas

$$W(\mathbf{Z}'\mathbf{Z} / n, \Sigma) = \begin{cases} \frac{|\mathbf{Z}'\mathbf{Z}|^{1/2(n-p-1)} \exp\left(\frac{1}{2} \text{tr} \Sigma^{-1}(\mathbf{Z}'\mathbf{Z})\right)}{2^{1/2np} \pi^{p(p-1)/4} |\Sigma|^{1/2n} \prod_{i=1}^p \Gamma\left(\frac{1}{2}(n+1-i)\right)} \\ 0, \text{ yang lain} \end{cases} \quad (2.4.2)$$

$\mathbf{Z}'\mathbf{Z}$ definit positif.

Sebuah kondisi di bawah bentuk $Z'AZ$ dikatakan berdistribusi Wishart diberikan oleh theorema berikut.

Theorema 2.4.1

Andaikan $Z = [z_1, z_2, \dots, z_n]$ dimana z_1, z_2, \dots, z_n adalah independen dan masing-masing z_i berdistribusi $N_p(0, \Sigma)$. Kemudian apabila A adalah matrik simetrik idempoten berukuran $n \times n$ yang mempunyai rank r , maka $Z'AZ$ dikatakan berdistribusi $W_p(r, \Sigma)$.

Bukti:

Dengan (2.2.16) matrik A dapat dibawa ke dalam bentuk dekomposisi spektral $A = \sum_{i=1}^n \lambda_i e_i e_i'$ dengan λ_i adalah nilai eigen ke $-i$ dari matrik A , e_i berhubungan dengan vektor eigen berukuran $n \times 1$. Kemudian karena matrik A mempunyai rank r , dengan Definisi 2.2.9 point satu akan terdapat sebanyak r λ_i yang berharga 1 dan $n-r$ sisanya λ_i berharga nol. Sehingga $A = \sum_{i=1}^r e_i e_i'$.

$$\begin{aligned} Z'AZ &= Z' \left(\sum_{i=1}^r e_i e_i' \right) Z & (2.4.3) \\ &= \sum_{i=1}^r Z' e_i e_i' Z \\ &= \sum_{i=1}^r (Z' e_i) (Z e_i)' \end{aligned}$$

Sehingga didapat

$$Z'AZ = \sum_{i=1}^r (Z' e_i) (Z e_i)' \quad (2.4.4)$$

Untuk menunjukkan $Z'AZ$ pada persamaan (2.4.4) berdistribusi $W_p(n, \Sigma)$ perlu dibuktikan terlebih dahulu bahwa $Z'e_i$ berdistribusi $N_p(0, \Sigma)$ dan independen.

Yang pertama akan dibuktikan adalah bahwa $Z'e_i$ berdistribusi $N_p(0, \Sigma)$ sebagai

berikut. Hasil kali silang $Z'e_i$ dapat ditulis sebagai $Z'e_i = \sum_{k=1}^n e_{ik} z_k$ dimana

$e_i = [e_{i1}, e_{i2}, \dots, e_{in}]'$ dan z_k berdistribusi $N_p(0, \Sigma)$, maka berdasarkan

persamaan (2.3.20) $\sum_{k=1}^n e_{ik} z_k$ berdistribusi $N_p(\sum_{k=1}^n e_{ik} 0, e_{ik}^2 \Sigma) = N_p(0, \Sigma)$,

karena $e_i'e_i = 1$. Selanjutnya $Z'e_i$ independen dibuktikan dengan kovarian antara

$Z'e_i$ dan $Z'e_j$ merupakan matrik O .

Karena $Z'e_i$ dan $Z'e_j$ masing-masing dapat dinyatakan sebagai:

$$\begin{aligned} Z'e_i &= \sum_{k=1}^n e_{ik} z_k \\ &= e_{i1} z_1 + e_{i2} z_2 + \dots + e_{in} z_n \end{aligned}$$

$$\begin{aligned} Z'e_j &= \sum_{k=1}^n e_{jk} z_k \\ &= e_{j1} z_1 + e_{j2} z_2 + \dots + e_{jn} z_n \end{aligned}$$

menurut Theorema 2.3.3 kovarian antara $Z'e_i$ dan $Z'e_j$ sama dengan O jika

$$\sum_{k=1}^n e_{ik} e_{jk} z_k = \sum_{k=1}^n e_{jk} e_{ik} z_k = e_i'e_j = 0. \text{ Dalam hal ini } e_i'e_j = 0 \text{ terpenuhi}$$

karena vektor eigen yang berbeda pada matrik simetrik adalah saling ortogonal.

Dengan Definisi 2.4.1 terbukti bahwa $Z'AZ$ pada persamaan (2.4.4) berdistribusi $W_p(r, \Sigma)$. (bukti selesai).

Mengenai independensi antara dua matrik wishart akan diterangkan lebih lanjut dalam Theorema 2.4.2 berikut.

Theorema 2.4.2:

Andaikan matrik Z berukuran $n \times p$ yang didefinisikan pada Theorema 2.4.1 dan andaikan A dan C keduanya matrik simetrik idempoten berukuran $n \times n$ yang masing-masing mempunyai rank r dan s , kemudian matrik Wishart $Z'AZ$ dan $Z'CZ$ saling independen jika $AC = O$.

Bukti:

Untuk membuktikan $Z'AZ$ dan $Z'CZ$ independen dengan menunjukkan kovarian antara keduanya sama dengan O .

Berdasarkan persamaan (2.4.4)

$$Z'AZ = \sum_{i=1}^r (Z'e_i)(Z'e_i)', \quad Z'e_i \text{ independen berdistribusi } N_p(0, \Sigma).$$

Demikian juga untuk $Z'CZ$

$$Z'CZ = \sum_{j=1}^s (Z'u_j)(Z'u_j)', \quad Z'u_j \text{ independen berdistribusi } N_p(0, \Sigma).$$

dengan u_j merupakan vektor eigen dari C .

$$\begin{aligned} E(Z'AZ) &= E\left(Z' \sum_{i=1}^r e_i e_i' Z\right) \\ &= E\left((Z'e_1)(Z'e_1)' + (Z'e_2)(Z'e_2)' + \dots + (Z'e_r)(Z'e_r)'\right) \\ &= E\left((Z'e_1)(Z'e_1)'\right) + E\left((Z'e_2)(Z'e_2)'\right) + \dots + E\left((Z'e_r)(Z'e_r)'\right) \end{aligned}$$

$$\begin{aligned}
&= E(\mathbf{Z}'\mathbf{e}_1)E(\mathbf{Z}'\mathbf{e}_1)' + E(\mathbf{Z}'\mathbf{e}_2)E(\mathbf{Z}'\mathbf{e}_2)' + \dots + E(\mathbf{Z}'\mathbf{e}_r)E(\mathbf{Z}'\mathbf{e}_r)' \\
&= \mathbf{0} + \mathbf{0} + \dots + \mathbf{0} \\
&= \mathbf{0}
\end{aligned}$$

Analog untuk $\mathbf{Z}'\mathbf{CZ}$, $E(\mathbf{Z}'\mathbf{CZ}) = \mathbf{0}$

Sehingga didapat

$$\begin{aligned}
\text{Cov}(\mathbf{Z}'\mathbf{AZ}, \mathbf{Z}'\mathbf{CZ}) &= E((\mathbf{Z}'\mathbf{AZ} - E(\mathbf{Z}'\mathbf{AZ}))(\mathbf{Z}'\mathbf{CZ} - E(\mathbf{Z}'\mathbf{CZ})))' \\
&= E((\mathbf{Z}'\mathbf{AZ} - \mathbf{0})(\mathbf{Z}'\mathbf{CZ} - \mathbf{0}))' \\
&= E(\mathbf{Z}'\mathbf{AZZ}'\mathbf{C}'\mathbf{Z}) \quad (\text{karena A dan C matrik simetrik}) \\
&= E(\mathbf{Z}'\mathbf{ZACZ}'\mathbf{Z})
\end{aligned}$$

Jika $\mathbf{AC} = \mathbf{O}$ maka $\mathbf{Z}'\mathbf{ZAC} = \mathbf{O}$

$$\mathbf{Z}'\mathbf{ZACZ}'\mathbf{Z} = \mathbf{O}$$

Dan pada akhirnya

$$E(\mathbf{Z}'\mathbf{ZACZ}'\mathbf{Z}) = \mathbf{O}$$

Kovarian antara $\mathbf{Z}'\mathbf{AZ}$ dan $\mathbf{Z}'\mathbf{CZ}$ sama dengan \mathbf{O} dipenuhi jika $\mathbf{AC} = \mathbf{O}$, sehingga terbukti keduanya independen jika $\mathbf{AC} = \mathbf{O}$. (bukti selesai).