

第 5 章

簡單線性迴歸之矩陣方法

Matrices Approach to Simple Linear Regression

- 在**複迴歸**中，由於**矩陣方法**可以透過較為精簡的表達方式，來表示出廣大的**聯立方程組**，以及龐大的資料陣列，所以經常是必須使用的工具。
- 本章首先介紹**矩陣代數**，然後介紹如何將矩陣方法應用至**簡單線性迴歸模型**中，雖然在簡單線性迴歸模型中，尚不需使用到矩陣代數，不過透過矩陣代數的應用，將有助於進入第二與第三部分關於複迴歸模型的討論。
- 將**焦點放在如何應用於迴歸分析的部分**。

5.1 矩陣 Matrices

- 矩陣之定義

矩陣是將元素依照行與列排成一矩形之形式，如下例：

	第一行	第二行
第一列	16,000	23
第二列	33,000	47
第三列	21,000	35

- 例如第一列第二行之數字(23)表示年齡為23歲，其所得表示在第一列第一行之數字（16,000），上述矩陣之階數（*dimension*）為3x2，亦即三列二行，所以如果想透過矩陣表示1,000個人的所得與年齡，則所需矩陣之階數為1000x2。

- 一般而言，矩陣的階數先寫出它的列，再表示它的行，接下來我們定義一些符號來代表下面這個 2×3 之矩陣中的元素：

$$\begin{array}{cccc}
 & j=1 & j=2 & j=3 \\
 i=1 & a_{11} & a_{12} & a_{13} \\
 i=2 & a_{21} & a_{22} & a_{23}
 \end{array}$$

這裡第一個下標示指該元素的列，第二個下標則是行，所以符號 a_{ij} 表示第 i 列第 j 行之元素。在上面的例子中， $i=1,2$ 以及 $j=1,2,3$ 。

- 習慣上用粗黑體的樣式符號來代表一個矩陣，因此上述矩陣可以寫成：

$$\mathbf{A} = \begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \end{bmatrix}$$

或是 $\mathbf{A} = [a_{ij}] \quad i = 1, 2 ; j = 1, 2, 3$

所以對於一個具有 r 列 c 行之矩陣可以表是為：

$$\mathbf{A} = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1j} & \cdots & a_{1c} \\ a_{21} & a_{22} & \cdots & a_{2j} & \cdots & a_{2c} \\ \vdots & \vdots & & \vdots & & \vdots \\ a_{i1} & a_{i2} & \cdots & a_{ij} & \cdots & a_{ic} \\ \vdots & \vdots & & \vdots & & \vdots \\ a_{r1} & a_{r2} & \cdots & a_{rj} & \cdots & a_{rc} \end{bmatrix} \quad (5.1)$$

或是採用簡略之形式

$$\mathbf{A} = [a_{ij}] \quad i = 1, \dots, r ; j = 1, \dots, c$$

甚至直接以 \mathbf{A} 作為表示方式。

- 方陣

當矩陣之列數等於行數時，稱之為方陣(*square matrix*)

$$\begin{pmatrix} 4 & 7 \\ 3 & 9 \end{pmatrix} \begin{pmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{pmatrix}$$

- 向量

當矩陣之行數僅為1，我們稱為行向量(*column vector*)或簡稱向量(*vector*)，當矩陣之列數僅為1，我們稱為列向量(*row vector*)

$$A = \begin{pmatrix} 4 \\ 7 \\ 10 \end{pmatrix} \quad C = \begin{pmatrix} c_1 \\ c_2 \\ c_3 \\ c_4 \end{pmatrix} \quad B' = [15 \ 25 \ 50]$$

- 向量A是一個3×1之矩陣、向量C是一個5×1之矩陣，列向量的符號右上方加一撇之表示方式稱之為轉置(*transpose*)

轉置

- 矩陣A之轉置我們習慣上用符號A'來表示。

例如

$$A = \begin{matrix} & \begin{bmatrix} 2 & 5 \\ 7 & 10 \\ 3 & 4 \end{bmatrix} \\ \begin{matrix} 3 \times 2 \end{matrix} & \end{matrix}$$

所以轉置矩陣A'為：

$$A' = \begin{matrix} \begin{bmatrix} 2 & 7 & 3 \\ 5 & 10 & 4 \end{bmatrix} \\ \begin{matrix} 2 \times 3 \end{matrix} \end{matrix}$$

- 轉置結果是行向量轉置成列向量，反之，則是列向量轉置成行向量

轉置

在一般的情形下， \mathbf{A} 矩陣轉置的規則為：

$$\mathbf{A}_{r \times c} = \begin{bmatrix} a_{11} & \cdots & a_{1c} \\ \vdots & & \vdots \\ a_{r1} & \cdots & a_{rc} \end{bmatrix} = [a_{ij}] \quad i=1, \dots, r; \quad j=1, \dots, c \quad (5.2)$$

列下標 行下標

其轉置矩陣為：

$$\mathbf{A}'_{c \times r} = \begin{bmatrix} a_{11} & \cdots & a_{r1} \\ \vdots & & \vdots \\ a_{1c} & \cdots & a_{rc} \end{bmatrix} = [a_{ji}] \quad j=1, \dots, c; \quad i=1, \dots, r \quad (5.3)$$

列下標 行下標

所以在矩陣 \mathbf{A} 中的第 i 列第 j 行的元素，轉置後出現在矩陣 \mathbf{A}' 中的第 j 列第 i 行。

矩陣相等

$$\mathbf{A} = \begin{pmatrix} a_1 \\ a_2 \\ a_3 \end{pmatrix} \quad \mathbf{B} = \begin{pmatrix} 4 \\ 7 \\ 3 \end{pmatrix} \quad \text{表示 } a_1=4, \quad a_2=7, \quad a_3=3$$

在迴歸分析中由反應變數的 n 個觀測值所組成的向量 \mathbf{Y} ，可以表示成基本的矩陣形式如下：

$$\mathbf{Y} = \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} \quad (5.4)$$

其轉置矩陣 \mathbf{Y}' 為：

$$\mathbf{Y}' = [Y_1 \quad Y_2 \quad \cdots \quad Y_n] \quad (5.5)$$

另外一個基本矩陣是由一行全為 1，以及另外一行是預測變數的 n 個觀測值所組成的 \mathbf{X} 矩陣：

$$\mathbf{X} = \begin{bmatrix} 1 & X_1 \\ 1 & X_2 \\ \vdots & \vdots \\ 1 & X_n \end{bmatrix} \quad (5.6)$$

其轉置矩陣為：

$$\mathbf{X}' = \begin{bmatrix} 1 & 1 & \cdots & 1 \\ X_1 & X_2 & \cdots & X_n \end{bmatrix} \quad (5.7)$$

矩陣 \mathbf{X} 有時稱為**設計矩陣**(*design matrix*)。

- 一般而言，如果

則

$$\mathbf{A} = \begin{bmatrix} a_{ij} \end{bmatrix}_{r \times c} \quad \mathbf{B} = \begin{bmatrix} b_{ij} \end{bmatrix}_{r \times c} \quad i = 1, \dots, r; \quad j = 1, \dots, c$$
$$\mathbf{A} + \mathbf{B} = \begin{bmatrix} a_{ij} + b_{ij} \end{bmatrix}_{r \times c} \quad \text{或} \quad \mathbf{A} - \mathbf{B} = \begin{bmatrix} a_{ij} - b_{ij} \end{bmatrix}_{r \times c} \quad (5.8)$$

(5.8)式可以一般化推廣至多於兩個矩陣之加減運算，而且與一般代數規則有相同的性質： $\mathbf{A} + \mathbf{B} = \mathbf{B} + \mathbf{A}$ 。

$$Y_i = E\{Y_i\} + \varepsilon_i \quad i = 1, \dots, n$$

可以透過矩陣符號精簡地表示出。首先定義平均反應向量與誤差項向量：

$$\mathbf{E}\{\mathbf{Y}\}_{n \times 1} = \begin{bmatrix} E\{Y_1\} \\ E\{Y_2\} \\ \vdots \\ E\{Y_n\} \end{bmatrix} \quad (5.9)$$

$$\boldsymbol{\varepsilon}_{n \times 1} = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{bmatrix} \quad (5.10)$$

根據(5.4)式， n 個觀測值所組成的向量 \mathbf{Y} 可以表示為：

$$\mathbf{Y}_{n \times 1} = \mathbf{E}\{\mathbf{Y}\}_{n \times 1} + \boldsymbol{\varepsilon}_{n \times 1}$$

因為，

$$\begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} E\{Y_1\} \\ E\{Y_2\} \\ \vdots \\ E\{Y_n\} \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{bmatrix} = \begin{bmatrix} E\{Y_1\} + \varepsilon_1 \\ E\{Y_2\} + \varepsilon_2 \\ \vdots \\ E\{Y_n\} + \varepsilon_n \end{bmatrix}$$

所以觀測值向量 \mathbf{Y} 可以等於平均反應向量與誤差項向量兩個向量之和。

5.3 矩陣相乘 Matrix Multiplication

- 純量與矩陣之相乘

一般而言，當 $\mathbf{A} = [a_{ij}]$ ，而 k 為一個純量，則

$$k\mathbf{A} = \mathbf{A}k = [ka_{ij}] \quad (5.11)$$

- 兩矩陣之相乘

一般而言，當矩陣 \mathbf{A} 之階數為 $r \times c$ ，而矩陣 \mathbf{B} 之階數為 $c \times s$ ，則乘積 \mathbf{AB} 之階數為 $r \times s$ ，且其第 i 列第 j 行的元素為：

$$\sum_{k=1}^c a_{ik} b_{kj}$$

所以我們可以得到：

$$\mathbf{AB}_{r \times s} = \left[\sum_{k=1}^c a_{ik} b_{kj} \right] \quad i = 1, \dots, r; j = 1, \dots, s \quad (5.12)$$

更多的例題

$$1. \quad \begin{bmatrix} 4 & 2 \\ 5 & 8 \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \end{bmatrix} = \begin{bmatrix} 4a_1 + 2a_2 \\ 5a_1 + 8a_2 \end{bmatrix}$$

$$2. \quad [2 \ 3 \ 5] \begin{bmatrix} 2 \\ 3 \\ 5 \end{bmatrix} = [2^2 + 3^2 + 5^2] = [38]$$

在此乘積結果為一個 1×1 之矩陣，也是一個純量，所以此二矩陣之乘積為純量 38。

$$3. \quad \begin{bmatrix} 1 & X_1 \\ 1 & X_2 \\ 1 & X_3 \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix} = \begin{bmatrix} \beta_0 + \beta_1 X_1 \\ \beta_0 + \beta_1 X_2 \\ \beta_0 + \beta_1 X_3 \end{bmatrix}$$

迴歸例題

考慮反應變數觀測值所組成的向量 \mathbf{Y} 被其本身的轉置矩陣 \mathbf{Y}' 進行乘積運算：

$$\mathbf{Y}'\mathbf{Y} = \begin{bmatrix} Y_1 & Y_2 & \cdots & Y_n \end{bmatrix} \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} = [Y_1^2 + Y_2^2 + \cdots + Y_n^2] = [\sum Y_i^2] \quad (5.13)$$

上式中 $\mathbf{Y}'\mathbf{Y}$ 是一個純量，也就是反應變數觀測值之平方和： $\mathbf{Y}'\mathbf{Y} = \sum Y_i^2$ ，另外關於 $\mathbf{X}'\mathbf{X}$ 與 $\mathbf{X}'\mathbf{Y}$ 可以分別計算如下：

$$\mathbf{X}'\mathbf{X} = \begin{bmatrix} 1 & 1 & \cdots & 1 \\ X_1 & X_2 & \cdots & X_n \end{bmatrix} \begin{bmatrix} 1 \\ X_1 \\ X_2 \\ \vdots \\ X_n \end{bmatrix} = \begin{bmatrix} n & \sum X_i \\ \sum X_i & \sum X_i^2 \end{bmatrix} \quad (5.14)$$

同時階數 2×1 的矩陣 $\mathbf{X}'\mathbf{Y}$ 為：

$$\mathbf{X}'\mathbf{Y} = \begin{bmatrix} 1 & 1 & \cdots & 1 \\ X_1 & X_2 & \cdots & X_n \end{bmatrix} \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} \sum Y_i \\ \sum X_i Y_i \end{bmatrix} \quad (5.15)$$

5.4 特殊矩陣 Special Types of Matrices

- 對稱矩陣

- 當 $\mathbf{A} = \mathbf{A}'$ ，則矩陣 \mathbf{A} 為對稱矩陣

- 所有的對稱矩陣均為方陣。在迴歸分析中，對稱矩陣經常是出現在矩陣 \mathbf{X} 前面乘上其轉置 \mathbf{X}' ， $\mathbf{X}\mathbf{X}'$ 必為對稱矩陣，這結果由 (5.14) 得知

- 對角線矩陣

當矩陣之主對角線以外的元素均為零，則此矩陣為一個對角線矩陣 (diagonal matrix)，

- 單位矩陣

單位矩陣 (diagonal matrix) (或 unit matrix) 之符號習慣上用 \mathbf{I} 來表示，該矩陣主對角線之元素均為 1，而主對角線以外的元素均為零，任意矩陣乘上或被乘上相同階數的單位矩陣，其結果不變，

所以對於一個 $r \times r$ 之矩陣 \mathbf{A} ，我們有

$$\mathbf{A}\mathbf{I} = \mathbf{I}\mathbf{A} = \mathbf{A} \quad (5.16)$$

- **純量矩陣**：純量矩陣(scalar matrix)為主對角線元素均相同之對角線矩陣
- **元素全為一之向量與矩陣**：當行向量內所有的元素均為1，我們用符號 $\mathbf{1}$ 來表示，

$$\mathbf{1}_{r \times 1} = \begin{bmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{bmatrix} \quad (5.17)$$

- 而對於方陣內所有的元素均為1，我們用符號 \mathbf{J} 來表示，

$$\mathbf{J}_{r \times r} = \begin{bmatrix} 1 & \cdots & 1 \\ \vdots & & \vdots \\ 1 & \cdots & 1 \end{bmatrix} \quad (5.18)$$

對於一個 $n \times 1$ 之向量 I ，我們有

$$I' I = \begin{bmatrix} 1 & \cdots & 1 \end{bmatrix} \begin{bmatrix} 1 \\ \vdots \\ 1 \end{bmatrix} = \begin{bmatrix} n \end{bmatrix} = n$$

而

$$I I' = \begin{bmatrix} 1 \\ \vdots \\ 1 \end{bmatrix} \begin{bmatrix} 1 & \cdots & 1 \end{bmatrix} = \begin{bmatrix} 1 \cdots 1 \\ \vdots \quad \vdots \\ 1 \cdots 1 \end{bmatrix} = J_{n \times n}$$

- **零向量**

零向量是指向量內所有的元素均為0，用符號 $\mathbf{0}$ 來表示：

$$\mathbf{0}_{r \times 1} = \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix} \quad (5.19)$$

5.5 線性相依與矩陣的秩

Linear Dependence and Rank of Matrix

- 線性相依
 - 當矩陣中存在有某一個行向量，可以等於其他行向量之線性組合時，該矩陣之各行為 **線性相依** (*linear dependent*)。若矩陣中不存在有任何一個行向量，可以等於其他行向量之線性組合時，該矩陣之各向量行為 **線性獨立** (*linear independent*)
 - 如果存在 c 個不全為 0 之純量 k_1, \dots, k_c ，可以滿足：

$$K_1\mathbf{C}_1 + K_2\mathbf{C}_2 + \dots + K_c\mathbf{C}_c = \mathbf{0} \quad (5.20)$$

則 c 個向量 $\mathbf{C}_1, \dots, \mathbf{C}_c$ 為 **線性相依**；反之，若滿足 $k_1\mathbf{C}_1 + k_2\mathbf{C}_2 + \dots + k_c\mathbf{C}_c = \mathbf{0}$ 之唯一條件為 $k_1 = k_2 = \dots = k_c = 0$ ，則 c 個向量 $\mathbf{C}_1, \dots, \mathbf{C}_c$ 為 **線性獨立**。

矩陣的秩

- 矩陣中可以滿足線性獨立最多數目之行向量，該數稱為矩陣的秩(rank)，舉前例而言，由於四個行向量不為線性獨立，所以矩陣A之秩不是4，不過第一、第二、第四行為線性獨立，所以矩陣A之秩為3。
- 一個矩陣的秩是固定的，而且可以透過最大線性獨立之列數來做等價之定義，亦即一個 $r \times c$ 之矩陣，矩陣的秩不會大於 r 與 c 兩者之最小值 $\min(r, c)$ 。
- 當矩陣A與B相乘後得到矩陣C，則矩陣C的秩不會大於矩陣A的秩與矩陣B的秩兩者之最小值 $\min(\text{rank}A, \text{rank}B)$ 。

5.6 反矩陣 Inverse of Matrix

- 一個數的反元素(inverse)是指該數的倒數，所以6的反元素是 $\frac{1}{6}$ 。例如：

$$6 \cdot \frac{1}{6} = \frac{1}{6} \cdot 6 = 1$$

$$\chi \cdot \frac{1}{\chi} = \chi \cdot \chi^{-1} = \chi^{-1} \cdot \chi = 1$$

- 在矩陣代數中，矩陣 \mathbf{A} 的反元素用符號 \mathbf{A}^{-1} 來表示，同時有性質：

$$\mathbf{A}^{-1}\mathbf{A} = \mathbf{A}\mathbf{A}^{-1} = \mathbf{I} \quad (5.21)$$

- 唯有方陣中才有所謂反矩陣之定義，不過有些方陣其反矩陣並不存在，當方陣之反矩陣存在時，必定是唯一一個

例題

1. 矩陣

$$\mathbf{A}_{2 \times 2} = \begin{bmatrix} 2 & 4 \\ 3 & 1 \end{bmatrix}$$

其反矩陣為

$$\mathbf{A}_{2 \times 2}^{-1} = \begin{bmatrix} -.1 & .4 \\ .3 & -.2 \end{bmatrix}$$

因為

$$\mathbf{A}^{-1}\mathbf{A} = \begin{bmatrix} -.1 & .4 \\ .3 & -.2 \end{bmatrix} \begin{bmatrix} 2 & 4 \\ 3 & 1 \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} = \mathbf{I}$$

或

$$\mathbf{A}\mathbf{A}^{-1} = \begin{bmatrix} 2 & 4 \\ 3 & 1 \end{bmatrix} \begin{bmatrix} -.1 & .4 \\ .3 & -.2 \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} = \mathbf{I}$$

2. 矩陣

$$\mathbf{A}_{3 \times 3} = \begin{bmatrix} 3 & 0 & 0 \\ 0 & 4 & 0 \\ 0 & 0 & 2 \end{bmatrix}$$

其反矩陣為

$$\mathbf{A} = \begin{bmatrix} 3 & 0 & 0 \\ 0 & 4 & 0 \\ 0 & 0 & 2 \end{bmatrix} \quad \mathbf{A}^{-1} = \begin{bmatrix} \frac{1}{3} & 0 & 0 \\ 0 & \frac{1}{4} & 0 \\ 0 & 0 & \frac{1}{2} \end{bmatrix}$$

因為

$$\mathbf{A}^{-1} \mathbf{A} = \begin{bmatrix} \frac{1}{3} & 0 & 0 \\ 0 & \frac{1}{4} & 0 \\ 0 & 0 & \frac{1}{2} \end{bmatrix} \begin{bmatrix} 3 & 0 & 0 \\ 0 & 4 & 0 \\ 0 & 0 & 2 \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} = \mathbf{I}$$

所以對角線矩陣之反矩陣，僅需將原矩陣中之主對角線元素取倒數，而成為一個新的對角線矩陣。

反矩陣之求法

一個 $r \times r$ 之矩陣當其秩為 r 時，則存在反矩陣，這種矩陣我們稱之為非奇異(*nonsingular*)或全秩(*full rank*)，其反矩陣的秩也是 r ；反之，當 $r \times r$ 之矩陣當其秩小於 r 時，則不存在反矩陣，這種矩陣我們稱之為奇異(*singular*)或非全秩(*not of full rank*)。

- 反矩陣之求法 (對 2×2 與 3×3 之矩陣)

1. 矩陣

則
$$\mathbf{A}_{2 \times 2} = \begin{bmatrix} a & b \\ c & d \end{bmatrix}$$

$$\mathbf{A}_{2 \times 2}^{-1} = \begin{bmatrix} a & b \\ c & d \end{bmatrix}^{-1} = \begin{bmatrix} \frac{d}{D} & \frac{-b}{D} \\ \frac{-c}{D} & \frac{a}{D} \end{bmatrix} \quad (5.22)$$

其中，

$$D = ad - bc \quad (5.22a)$$

D 稱為矩陣 \mathbf{A} 之**行列式值**，當矩陣 \mathbf{A} 為奇異，則 $D = 0$ ，而矩陣 \mathbf{A} 之反矩陣不存在。

2. 矩陣

$$\mathbf{B}_{3 \times 3} = \begin{bmatrix} a & b & c \\ d & e & f \\ g & h & k \end{bmatrix}$$

則

$$\mathbf{B}_{3 \times 3}^{-1} = \begin{bmatrix} a & b & c \\ d & e & f \\ g & h & k \end{bmatrix}^{-1} = \begin{bmatrix} A & B & C \\ D & E & F \\ G & H & K \end{bmatrix} \quad (5.23)$$

其中，

$$\begin{aligned} A &= (ek - fh) / Z & B &= -(bk - ch) / Z & C &= (bf - ce) / Z \\ D &= -(dk - fg) / Z & E &= (ak - cg) / Z & F &= -(af - cd) / Z \\ G &= (dh - eg) / Z & H &= -(ah - bg) / Z & K &= (ae - bd) / Z \end{aligned} \quad (5.23a)$$

且

$$Z = a(ek - fh) - b(dk - fg) + c(dh - eg) \quad (5.23b)$$

Z 稱為矩陣 \mathbf{B} 之行列式值

迴歸分析中常用的矩陣為(5.14)的 $\mathbf{X}'\mathbf{X}$:

$$\mathbf{X}'\mathbf{X}_{2 \times 2} = \begin{bmatrix} n & \sum X_i \\ \sum X_i & \sum X_i^2 \end{bmatrix}$$

利用(5.22)的方法，

$$\begin{aligned} a &= n & b &= \sum X_i \\ c &= \sum X_i & d &= \sum X_i^2 \end{aligned}$$

於是，

$$D = n \sum X_i^2 - (\sum X_i)(\sum X_i) = n \left[\sum X_i^2 - \frac{(\sum X_i)^2}{n} \right] = n \sum (X_i - \bar{X})^2$$

所以，

$$(\mathbf{X}'\mathbf{X})_{2 \times 2}^{-1} = \begin{bmatrix} \frac{\sum X_i^2}{n \sum (X_i - \bar{X})^2} & \frac{-\sum X_i}{n \sum (X_i - \bar{X})^2} \\ \frac{-\sum X_i}{n \sum (X_i - \bar{X})^2} & \frac{n}{n \sum (X_i - \bar{X})^2} \end{bmatrix} \quad (5.24)$$

所以，

$$(\mathbf{X}'\mathbf{X})_{2 \times 2}^{-1} = \begin{bmatrix} \frac{\sum X_i^2}{n \sum (X_i - \bar{X})^2} & \frac{-\sum X_i}{n \sum (X_i - \bar{X})^2} \\ \frac{-\sum X_i}{n \sum (X_i - \bar{X})^2} & \frac{n}{n \sum (X_i - \bar{X})^2} \end{bmatrix} \quad (5.24)$$

因為 $\sum X_i = n\bar{X}$ 以及 $\sum (X_i - \bar{X})^2 = \sum X_i^2 - n\bar{X}^2$ ，(5.24)式也可以簡化成：

$$(\mathbf{X}'\mathbf{X})_{2 \times 2}^{-1} = \begin{bmatrix} \frac{1}{n} + \frac{\bar{X}^2}{\sum (X_i - \bar{X})^2} & \frac{-\bar{X}}{\sum (X_i - \bar{X})^2} \\ \frac{-\bar{X}}{\sum (X_i - \bar{X})^2} & \frac{1}{\sum (X_i - \bar{X})^2} \end{bmatrix} \quad (5.24a)$$

- 反矩陣之使用

在一般代數裡，方程式： $5y = 20$

其解法為等號兩邊均乘上5之反元素，亦即， $\frac{1}{5} = (5y) = \frac{1}{5}(20)$

則可以解出：

$$y = \frac{1}{5}(20) = 4$$

在矩陣代數中，方程式： $\mathbf{AY}=\mathbf{C}$

假設矩陣 \mathbf{A} 之反矩陣存在，則在等號兩邊乘上 \mathbf{A} 之反矩陣：

$\mathbf{A}^{-1}\mathbf{AY}=\mathbf{A}^{-1}\mathbf{C}$ ，因為 $\mathbf{A}^{-1}\mathbf{AY}=\mathbf{IY}=\mathbf{Y}$ ，所以可以解出： $\mathbf{Y}=\mathbf{A}^{-1}\mathbf{C}$

舉例來說，假設聯立方程組：

$$2y_1 + 4y_2 = 20$$

$$3y_1 + y_2 = 10$$

我們可以用矩陣表示成：

$$\begin{pmatrix} 2 & 4 \\ 3 & 1 \end{pmatrix} \begin{pmatrix} y_1 \\ y_2 \end{pmatrix} = \begin{pmatrix} 20 \\ 10 \end{pmatrix}$$

於是，

$$\begin{pmatrix} y_1 \\ y_2 \end{pmatrix} = \begin{pmatrix} 2 & 4 \\ 3 & 1 \end{pmatrix}^{-1} \begin{pmatrix} 20 \\ 10 \end{pmatrix}$$

所以解出：

$$\begin{pmatrix} y_1 \\ y_2 \end{pmatrix} = \begin{pmatrix} -0.1 & 0.4 \\ 0.3 & -0.2 \end{pmatrix} \begin{pmatrix} 20 \\ 10 \end{pmatrix} = \begin{pmatrix} 2 \\ 4 \end{pmatrix}$$

因此 $y_1 = 2$ ， $y_2 = 4$ 可以滿足原來的聯立方程組。

5.7 矩陣之基本定理

- 一些常用的矩陣基本定理：

$$\mathbf{A} + \mathbf{B} = \mathbf{B} + \mathbf{A} \quad (5.25)$$

$$(\mathbf{A} + \mathbf{B}) + \mathbf{C} = \mathbf{A} + (\mathbf{B} + \mathbf{C}) \quad (5.26)$$

$$(\mathbf{AB})\mathbf{C} = \mathbf{A}(\mathbf{BC}) \quad (5.27)$$

$$\mathbf{C}(\mathbf{A} + \mathbf{B}) = \mathbf{CA} + \mathbf{CB} \quad (5.28)$$

$$k(\mathbf{A} + \mathbf{B}) = k\mathbf{A} + k\mathbf{B} \quad (5.29)$$

$$(\mathbf{A}')' = \mathbf{A} \quad (5.30)$$

$$(\mathbf{A} + \mathbf{B})' = \mathbf{A}' + \mathbf{B}' \quad (5.31)$$

$$(\mathbf{AB})' = \mathbf{B}'\mathbf{A}' \quad (5.32)$$

$$(\mathbf{ABC})' = \mathbf{C}'\mathbf{B}'\mathbf{A}' \quad (5.33)$$

$$(\mathbf{AB})^{-1} = \mathbf{B}^{-1}\mathbf{A}^{-1} \quad (5.34)$$

$$(\mathbf{ABC})^{-1} = \mathbf{C}^{-1}\mathbf{B}^{-1}\mathbf{A}^{-1} \quad (5.35)$$

$$(\mathbf{A}^{-1})^{-1} = \mathbf{A} \quad (5.36)$$

$$(\mathbf{A}')^{-1} = (\mathbf{A}^{-1})' \quad (5.37)$$

5.8 隨機向量與矩陣 Random Vectors and Matrices

- 一個**隨機向量**或**隨機矩陣**是指的其內部元素是隨機變數，所以在(5.4)中的觀測值向量 Y 即為一個**隨機向量**
- **隨機向量與矩陣之期望值**

假設有 $n=3$ 個觀測值，構成隨機向量 Y ：

$$Y = \begin{matrix} & \begin{pmatrix} Y_1 \\ Y_2 \\ Y_3 \end{pmatrix} \\ \begin{matrix} 3 \times 1 \end{matrix} & \end{matrix}$$

則 Y 的期望值為一個向量，用符號 $E\{Y\}$ 表示，其定義如下

$$E\{Y\} = \begin{matrix} & \begin{pmatrix} E\{Y_1\} \\ E\{Y_2\} \\ E\{Y_3\} \end{pmatrix} \\ \begin{matrix} 3 \times 1 \end{matrix} & \end{matrix}$$

一般情形下，一個隨機向量 \mathbf{Y} 之期望值我們可以表示為：

$$\mathbf{E}\{\mathbf{Y}\} = \left[E\{Y_i\} \right]_{n \times 1} \quad i = 1, \dots, n \quad (5.38)$$

而對於一個階數為 $n \times p$ 之隨機矩陣 \mathbf{Y} ，我們可以將其期望值表示為：

$$\mathbf{E}\{\mathbf{Y}\} = \left[E\{Y_{ij}\} \right]_{n \times p} \quad i = 1, \dots, n; j = 1, \dots, p \quad (5.39)$$

例題

假設迴歸應用中的觀測值 $n = 3$ ，三個誤差項 $\varepsilon_1, \varepsilon_2, \varepsilon_3$ 之期望值均為零，則誤差向量：

$$\mathbf{\varepsilon} = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \varepsilon_3 \end{bmatrix}$$

因為

$$\begin{bmatrix} E\{\varepsilon_1\} \\ E\{\varepsilon_2\} \\ E\{\varepsilon_3\} \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix}$$

我們得到：

$$\mathbf{E}\{\mathbf{\varepsilon}\} = \mathbf{0}$$

隨機向量之共變異矩陣

- 假設一隨機向量 \mathbf{Y} 之三個隨機變數為 Y_1 ， Y_2 ， Y_3 ，若其變異數分別為 $\sigma^2\{Y_i\}$ ，另外還存在有三個隨機變數中的任一兩個變數間之共變異數 $\sigma^2\{Y_i, Y_j\}$ ，則可以 $\sigma^2\{Y_i\}$ 來表示 \mathbf{Y} 共變異矩陣(*variance-covariance matrix*)：

$$\sigma^2\{\mathbf{Y}\} = \begin{bmatrix} \sigma^2\{Y_1\} & \sigma\{Y_1, Y_2\} & \sigma\{Y_1, Y_3\} \\ \sigma\{Y_2, Y_1\} & \sigma^2\{Y_2\} & \sigma\{Y_2, Y_3\} \\ \sigma\{Y_3, Y_1\} & \sigma\{Y_3, Y_2\} & \sigma^2\{Y_3\} \end{bmatrix} \quad (5.40)$$

由於

$$\sigma^2\{\mathbf{Y}\} = \mathbf{E}\left\{[\mathbf{Y} - \mathbf{E}\{\mathbf{Y}\}][\mathbf{Y} - \mathbf{E}\{\mathbf{Y}\}]'\right\} \quad (5.41)$$

在上述的例子中，有：

$$\sigma^2\{\mathbf{Y}\} = \mathbf{E}\left\{ \begin{bmatrix} Y_1 - E\{Y_1\} \\ Y_2 - E\{Y_2\} \\ Y_3 - E\{Y_3\} \end{bmatrix} \begin{bmatrix} Y_1 - E\{Y_1\} & Y_2 - E\{Y_2\} & Y_3 - E\{Y_3\} \end{bmatrix} \right\}$$

經過矩陣之相乘運算，並取期望值後，我們可以得到下面結果：

乘積位置	項	期望值
第一列，第一行	$(Y_1 - E\{Y_1\})^2$	$\sigma^2\{Y_1\}$
第一列，第二行	$(Y_1 - E\{Y_1\})(Y_2 - E\{Y_2\})$	$\sigma\{Y_1, Y_2\}$
第一列，第三行	$(Y_1 - E\{Y_1\})(Y_3 - E\{Y_3\})$	$\sigma\{Y_1, Y_3\}$
第二列，第一行	$(Y_2 - E\{Y_2\})(Y_1 - E\{Y_1\})$	$\sigma\{Y_2, Y_1\}$
等等	等等	等等

將上述結果推廣至一個 $n \times 1$ 的隨機向量 \mathbf{Y} ，其**共變異矩陣**為：

$$\sigma^2\{\mathbf{Y}\}_{n \times n} = \begin{bmatrix} \sigma^2\{Y_1\} & \sigma\{Y_1, Y_2\} & \cdots & \sigma\{Y_1, Y_n\} \\ \sigma\{Y_2, Y_1\} & \sigma^2\{Y_2\} & \cdots & \sigma\{Y_2, Y_n\} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma\{Y_n, Y_1\} & \sigma\{Y_n, Y_2\} & \cdots & \sigma^2\{Y_n\} \end{bmatrix} \quad (5.42)$$

此處的 $\sigma^2(\mathbf{Y})$ 是一個對稱矩陣

同樣是觀測值 $n = 3$ 的例子，三個誤差項 $\varepsilon_1, \varepsilon_2, \varepsilon_3$ 之變異數均為常數 $\sigma^2\{\varepsilon_i\} = \sigma^2$ ，同時誤差項間均為獨立，所以對於所有的 $i \neq j$ ，我們有 $\sigma\{\varepsilon_i, \varepsilon_j\} = 0$ ，則隨機向量 $\boldsymbol{\varepsilon}$ 之共變異矩陣為：

$$\sigma^2_{3 \times 3}\{\boldsymbol{\varepsilon}\} = \begin{bmatrix} \sigma^2 & 0 & 0 \\ 0 & \sigma^2 & 0 \\ 0 & 0 & \sigma^2 \end{bmatrix}$$

由於所有的變異數均為相同常數 σ^2 ，而非主對角線之元素均為零，所以該共變異矩陣可以視為一個純量為 σ^2 之純量矩陣，可以用一個較為簡單之形式來表示：

$$\sigma^2_{3 \times 3}\{\boldsymbol{\varepsilon}\} = \sigma^2_{3 \times 3}\mathbf{I}$$

因為

$$\sigma^2\mathbf{I} = \sigma^2 \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} = \begin{bmatrix} \sigma^2 & 0 & 0 \\ 0 & \sigma^2 & 0 \\ 0 & 0 & \sigma^2 \end{bmatrix}$$

- **基本定理**

有時我們經常會遇到一個**常數矩陣** \mathbf{A} （元素固定之矩陣），乘上一個隨機向量 \mathbf{Y} ，而形成一個隨機向量 \mathbf{W} 如下：

$$\mathbf{W} = \mathbf{A}\mathbf{Y} \quad (5.43)$$

則可能會用到一些基本定理：

$$\mathbf{E}\{\mathbf{A}\} = \mathbf{A}$$

$$\mathbf{E}\{\mathbf{W}\} = \mathbf{E}\{\mathbf{A}\mathbf{Y}\} = \mathbf{A}\mathbf{E}\{\mathbf{Y}\} \quad (5.44)$$

$$\sigma^2\{\mathbf{W}\} = \sigma^2\{\mathbf{A}\mathbf{Y}\} = \mathbf{A}\sigma^2\{\mathbf{Y}\}\mathbf{A}' \quad (5.45)$$

$$(5.46)$$

其中， $\sigma^2\{\mathbf{Y}\}$ 為 \mathbf{Y} 的**共變異矩陣**。

例題

我們考慮：

$$\begin{array}{c} \begin{bmatrix} W_1 \\ W_2 \end{bmatrix} \\ \mathbf{W} \\ 2 \times 1 \end{array} = \begin{array}{c} \begin{bmatrix} 1 & -1 \\ 1 & 1 \end{bmatrix} \\ \mathbf{A} \\ 2 \times 2 \end{array} \begin{array}{c} \begin{bmatrix} Y_1 \\ Y_2 \end{bmatrix} \\ \mathbf{Y} \\ 2 \times 1 \end{array} = \begin{array}{c} \begin{bmatrix} Y_1 - Y_2 \\ Y_1 + Y_2 \end{bmatrix} \end{array}$$

則根據(5.45)，可以得到：

$$\mathbf{E}\{\mathbf{W}\}_{2 \times 1} = \begin{bmatrix} 1 & -1 \\ 1 & 1 \end{bmatrix} \begin{bmatrix} E\{Y_1\} \\ E\{Y_2\} \end{bmatrix} = \begin{bmatrix} E\{Y_1\} - E\{Y_2\} \\ E\{Y_1\} + E\{Y_2\} \end{bmatrix}$$

又從(5.46)，我們有結果：

$$\begin{aligned} \sigma^2\{\mathbf{W}\}_{2 \times 2} &= \begin{bmatrix} 1 & -1 \\ 1 & 1 \end{bmatrix} \begin{bmatrix} \sigma^2\{Y_1\} & \sigma\{Y_1, Y_2\} \\ \sigma\{Y_2, Y_1\} & \sigma^2\{Y_2\} \end{bmatrix} \begin{bmatrix} 1 & 1 \\ -1 & 1 \end{bmatrix} \\ &= \begin{bmatrix} \sigma^2\{Y_1\} + \sigma^2\{Y_2\} - 2\sigma\{Y_1, Y_2\} & \sigma^2\{Y_1\} - \sigma^2\{Y_2\} \\ \sigma^2\{Y_1\} - \sigma^2\{Y_2\} & \sigma^2\{Y_1\} + \sigma^2\{Y_2\} + 2\sigma\{Y_1, Y_2\} \end{bmatrix} \end{aligned}$$

所以，

$$\begin{aligned} \sigma^2\{W_1\} &= \sigma^2\{Y_1 - Y_2\} = \sigma^2\{Y_1\} + \sigma^2\{Y_2\} - 2\sigma\{Y_1, Y_2\} \\ \sigma^2\{W_2\} &= \sigma^2\{Y_1 + Y_2\} = \sigma^2\{Y_1\} + \sigma^2\{Y_2\} + 2\sigma\{Y_1, Y_2\} \\ \sigma\{W_1, W_2\} &= \sigma\{Y_1 - Y_2, Y_1 + Y_2\} = \sigma^2\{Y_1\} - \sigma^2\{Y_2\} \end{aligned}$$

多元常態分配

- 密度函數 對於一個多元常態分配的密度函數，最好是透過矩陣的方式來表示，先定義一些向量與矩陣，假設觀測值向量 \mathbf{Y} 是由 p 個 Y 變數所組成，則習慣上可以寫成：

$$\mathbf{Y}_{p \times 1} = \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_p \end{bmatrix} \quad (5.47)$$

用符號 $\boldsymbol{\mu}$ 表示向量 \mathbf{Y} 之期望值 $\mathbf{E}\{\mathbf{Y}\}$ ，所以

$$\boldsymbol{\mu}_{p \times 1} = \begin{bmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_p \end{bmatrix} \quad (5.48)$$

最後， \mathbf{Y} 的共變異矩陣 $\sigma^2\{\mathbf{Y}\}$ 用符號 Σ 來表示：

$$\Sigma_{p \times p} = \begin{bmatrix} \sigma_1^2 & \sigma_{12} & \cdots & \sigma_{1p} \\ \sigma_{21} & \sigma_2^2 & \cdots & \sigma_{2p} \\ \vdots & \vdots & & \vdots \\ \sigma_{p1} & \sigma_{p2} & \cdots & \sigma_p^2 \end{bmatrix} \quad (5.49)$$

在這裡， σ_1^2 為 Y_1 的變異數，而 σ_{12} 則是 Y_1 與 Y_2 共變係數。

對於一個多元常態分配的密度函數，可以寫成：

$$f(\mathbf{Y}) = \frac{1}{(2\pi)^{p/2} |\Sigma|^{1/2}} \exp \left[-\frac{1}{2} (\mathbf{Y} - \boldsymbol{\mu})' \Sigma^{-1} (\mathbf{Y} - \boldsymbol{\mu}) \right] \quad (5.50)$$

其中， $|\Sigma|$ 表示共變異矩陣 Σ 之行列式值

5.9 簡單線性迴歸模型的矩陣表示

Simple Linear Regression Model in Matrix Terms

- 在本節中將利用矩陣來處理簡單線性迴歸，首先考慮的是常態誤差迴歸模型(2.1)：

$$Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i \quad i = 1, \dots, n \quad (5.51)$$

亦即，

$$\begin{aligned} Y_1 &= \beta_0 + \beta_1 X_1 + \varepsilon_1 \\ Y_2 &= \beta_0 + \beta_1 X_2 + \varepsilon_2 \\ &\vdots \\ Y_n &= \beta_0 + \beta_1 X_n + \varepsilon_n \end{aligned} \quad (5.51a)$$

- 另外還需增加迴歸係數所組成的向量：

$$\mathbf{Y} = \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix}_{n \times 1} \quad \mathbf{X} = \begin{bmatrix} 1 & X_1 \\ 1 & X_2 \\ \vdots & \vdots \\ 1 & X_n \end{bmatrix}_{n \times 2} \quad \boldsymbol{\beta} = \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix}_{2 \times 1} \quad \boldsymbol{\varepsilon} = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{bmatrix}_{n \times 1} \quad (5.52)$$

於是可以將(5.51a)利用 $\boldsymbol{\beta}$ 矩陣做一個較為精簡的表達方式：

$$\mathbf{Y} = \mathbf{X} \boldsymbol{\beta} + \boldsymbol{\varepsilon} \quad (5.53)$$

$\begin{matrix} n \times 1 & n \times 2 & 2 \times 1 & n \times 1 \end{matrix}$

因為

$$\begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} 1 & X_1 \\ 1 & X_2 \\ \vdots & \vdots \\ 1 & X_n \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{bmatrix} = \begin{bmatrix} \beta_0 + \beta_1 X_1 \\ \beta_0 + \beta_1 X_2 \\ \vdots \\ \beta_0 + \beta_1 X_n \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{bmatrix} = \begin{bmatrix} \beta_0 + \beta_1 X_1 + \varepsilon_1 \\ \beta_0 + \beta_1 X_2 + \varepsilon_2 \\ \vdots \\ \beta_0 + \beta_1 X_n + \varepsilon_n \end{bmatrix}$$

- 上式中 $\mathbf{X}\boldsymbol{\beta}$ 表示各個觀測值 Y_i 之期望值所組成之向量，而 $E\{Y_i\} = \beta_0 + \beta_1 X_i$ ，所以

$$\boxed{\begin{matrix} \mathbf{E}\{\mathbf{Y}\} = \mathbf{X}\boldsymbol{\beta} \\ n \times 1 \qquad n \times 1 \end{matrix}} \quad (5.54)$$

在 X 矩陣中有一全為1，我們可以將其視為一個虛擬變數 $X_0=1$ ，用以作為替代之迴歸模型(1.5)

$$Y_i = \beta_0 X_0 + \beta_1 X_i + \varepsilon_i \quad \text{其中 } X_0=1$$

故 X 矩陣包含了虛擬變數 $X_0=1$ 之行向量及預測變數觀測值 X_i 之行向量。

- 在誤差項部分中，迴歸模型(2.1)假設 $E\{\varepsilon_i\}=0$ ， $\sigma^2\{\varepsilon_i\}=\sigma^2$ 且 ε_i 之間為獨立之常態隨機變數，我們可以將條件寫成矩陣之形式：

$$\mathbf{E}\{\boldsymbol{\varepsilon}\} = \mathbf{0} \quad (5.55)$$

$n \times 1$ $n \times 1$

- 上式所代表之意義為：

$$\begin{bmatrix} E\{\varepsilon_1\} \\ E\{\varepsilon_2\} \\ \vdots \\ E\{\varepsilon_n\} \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix}$$

- 由於 ε_i 具備有 **常數變異數**，而且 ε_i 與 ε_j 彼此間無相關性，亦即 **共變異數為零** (換句話說，對於所有的 i 與 j ， $i \neq j$ ， $\sigma\{\varepsilon_i, \varepsilon_j\} = 0$)，誤差項之共變異矩陣可以表示如下：

$$\sigma^2_{n \times n} \{\varepsilon\} = \begin{bmatrix} \sigma^2 & 0 & 0 & \dots & 0 \\ 0 & \sigma^2 & 0 & \dots & 0 \\ \vdots & \vdots & \vdots & & \vdots \\ 0 & 0 & 0 & \dots & \sigma^2 \end{bmatrix} \quad (5.56)$$

而此一共變異矩陣為一個 **純量矩陣**，所以可以進一步表示為：

$$\sigma^2_{n \times n} \{\varepsilon\} = \sigma^2_{n \times n} \mathbf{I} \quad (5.56a)$$

- 因此常態誤差迴歸模型(2.1)寫成矩陣形式為：

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon} \quad (5.57)$$

其中 $\boldsymbol{\varepsilon}$ 為獨立常態隨機變數之向量，且 $\mathbf{E}\{\boldsymbol{\varepsilon}\} = \mathbf{0}$ ，
 $\sigma^2\{\boldsymbol{\varepsilon}\} = \sigma^2 \mathbf{I}$

5.10 迴歸參數的最小平方估計

Least Squares Estimation of Regression Parameters

- 標準方程式

在第1章中的(1.9)式之標準方程式：

$$\begin{aligned}nb_0 + b_1 \sum X_i &= \sum Y_i \\ b_0 \sum X_i + b_1 \sum X_i^2 &= \sum X_i Y_i\end{aligned}\tag{5.58}$$

用矩陣形式表示則為：

$$\begin{array}{ccc} \mathbf{X}'\mathbf{X} & \mathbf{b} & = & \mathbf{X}'\mathbf{Y} \\ 2 \times 2 & 2 \times 1 & & 2 \times 1 \end{array}\tag{5.59}$$

其中 \mathbf{b} 為最小平方法估計下的迴歸係數向量：

$$\mathbf{b}_{2 \times 1} = \begin{bmatrix} b_0 \\ b_1 \end{bmatrix}\tag{5.59a}$$

$$nb_0 + b_1 \sum X_i = \sum Y_i$$

$$b_0 \sum X_i + b_1 \sum X_i^2 = \sum X_i Y_i$$

$$\mathbf{X}'\mathbf{X} = \begin{bmatrix} 1 & 1 & \cdots & 1 \\ X_1 & X_2 & \cdots & X_n \end{bmatrix} \begin{bmatrix} 1 & X_1 \\ 1 & X_2 \\ \vdots & \vdots \\ 1 & X_n \end{bmatrix} = \begin{bmatrix} n & \sum X_i \\ \sum X_i & \sum X_i^2 \end{bmatrix}$$

$$\mathbf{X}'\mathbf{Y} = \begin{bmatrix} 1 & 1 & \cdots & 1 \\ X_1 & X_2 & \cdots & X_n \end{bmatrix} \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} \sum Y_i \\ \sum X_i Y_i \end{bmatrix}$$

$$\mathbf{X}'\mathbf{X} \mathbf{b} = \mathbf{X}'\mathbf{Y}$$

$\begin{matrix} 2 \times 2 & 2 \times 1 & & 2 \times 1 \end{matrix}$

- 迴歸係數之估計

透過(5.59)的矩陣形式之標準方程式運算出所估計的迴歸係數，必須先假設 $X'X$ 的反矩陣存在，然後在等號兩邊同時乘上 $X'X$ 的反矩陣：

$$(X'X)^{-1} X'Xb = (X'X)^{-1} X'Y$$

由於 $(X'X)^{-1} X'X = I$ ，而 $Ib = b$ ，所以

$$\underset{2 \times 1}{\mathbf{b}} = \underset{2 \times 2}{(X'X)^{-1}} \underset{2 \times 1}{X'Y} \quad (5.60)$$

其結果與先前的估計量 b_0 (1.10a) 及估計量 b_1 (1.10b) 相同。

例題

我們在此透過矩陣運算形式重新計算一次Toluca公司的案例，案例中變數 Y 與 X 的資料均列出在表 1.1 中，於是我們可以定義觀測向量 \mathbf{Y} 與 \mathbf{X} 之矩陣如下：

$$(5.61a) \quad \mathbf{Y} = \begin{bmatrix} 399 \\ 121 \\ \vdots \\ 323 \end{bmatrix} \quad (5.61b) \quad \mathbf{X} = \begin{bmatrix} 1 & 80 \\ 1 & 30 \\ \vdots & \vdots \\ 1 & 70 \end{bmatrix} \quad (5.61)$$

同時可以計算矩陣乘積：

$$\mathbf{X}'\mathbf{X} = \begin{bmatrix} 1 & 1 & \cdots & 1 \\ 80 & 30 & \cdots & 70 \end{bmatrix} \begin{bmatrix} 1 & 80 \\ 1 & 30 \\ \vdots & \vdots \\ 1 & 70 \end{bmatrix} = \begin{bmatrix} 25 & 1,750 \\ 1,750 & 142,300 \end{bmatrix} \quad (5.62)$$

$$\mathbf{X}'\mathbf{Y} = \begin{bmatrix} 1 & 1 & \cdots & 1 \\ 80 & 30 & \cdots & 70 \end{bmatrix} \begin{bmatrix} 399 \\ 121 \\ \vdots \\ 323 \end{bmatrix} = \begin{bmatrix} 7,807 \\ 617,180 \end{bmatrix} \quad (5.63)$$

並且應用(5.22)得出 $\mathbf{X}'\mathbf{X}$ 的反矩陣：

$$(\mathbf{X}'\mathbf{X})^{-1} = \begin{bmatrix} .287475 & -.003535 \\ -.003535 & .00005051 \end{bmatrix} \quad (5.64)$$

最後代入(5.60)，可以得到：

$$\begin{aligned} \mathbf{b} = \begin{bmatrix} b_0 \\ b_1 \end{bmatrix} &= (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{Y} = \begin{bmatrix} .287475 & -.003535 \\ -.003535 & .00005051 \end{bmatrix} \begin{bmatrix} 7,807 \\ 617,180 \end{bmatrix} \\ &= \begin{bmatrix} 62.37 \\ 3.5702 \end{bmatrix} \end{aligned} \quad (5.65)$$

於是得出結果 $b_0 = 62.37$ 與 $b_1 = 3.5702$ ，自然與第 1 章之結果吻合。

2. 比較標準方程式以及 $\mathbf{X}'\mathbf{X}$ ，可以發現當 $\mathbf{X}'\mathbf{X}$ 之各行線性相依，則標準方程式之各行也會線性相依，此時 b_0 與 b_1 不存在唯一解，不過對於大部分的迴歸應用而言， $\mathbf{X}'\mathbf{X}$ 之各行總是線性獨立的，因此可以得到 b_0 與 b_1 的唯一解。 ■

5.11 配適值與殘差 Fitted Values and Residuals

- 配適值

在矩陣向量的形式中，我們可以用向量 $\hat{\mathbf{Y}}$ 來表示各個配適值 \hat{Y}_i ：

$$\underset{n \times 1}{\hat{\mathbf{Y}}} = \begin{bmatrix} \hat{Y}_1 \\ \hat{Y}_2 \\ \vdots \\ \hat{Y}_n \end{bmatrix} \quad (5.70)$$

然後用矩陣代數：

$$\underset{n \times 1}{\hat{\mathbf{Y}}} = \underset{n \times 2}{\mathbf{X}} \underset{2 \times 1}{\mathbf{b}} \quad (5.71)$$

因為：

$$\begin{bmatrix} \hat{Y}_1 \\ \hat{Y}_2 \\ \vdots \\ \hat{Y}_n \end{bmatrix} = \begin{bmatrix} 1 & X_1 \\ 1 & X_2 \\ \vdots & \vdots \\ 1 & X_n \end{bmatrix} \begin{bmatrix} b_0 \\ b_1 \end{bmatrix} = \begin{bmatrix} b_0 + b_1 X_1 \\ b_0 + b_1 X_2 \\ \vdots \\ b_0 + b_1 X_n \end{bmatrix}$$

例題

在Toluca公司的案例中，利用矩陣(5.61b)與(5.65)可以得出配適值向量：

$$\hat{\mathbf{Y}} = \mathbf{X}\mathbf{b} = \begin{bmatrix} 1 & 80 \\ 1 & 30 \\ \vdots & \vdots \\ 1 & 70 \end{bmatrix} \begin{bmatrix} 62.37 \\ 3.5702 \end{bmatrix} = \begin{bmatrix} 347.98 \\ 169.47 \\ \vdots \\ 312.28 \end{bmatrix} \quad (5.72)$$

其結果自然與表 1.2 相同。

帽子矩陣

- 應用(5.60)中的**b**公式可以將(5.71)的 \hat{Y} 成 $\mathbf{b} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{Y}$

$$\hat{\mathbf{Y}} = \mathbf{X} \mathbf{b} \quad \hat{\mathbf{Y}} = \mathbf{X} (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{Y}$$

$\begin{matrix} n \times 1 & n \times 2 & 2 \times 1 \end{matrix}$

亦即

$$\hat{\mathbf{Y}} = \mathbf{H} \mathbf{Y} \quad (5.73)$$

$\begin{matrix} n \times 1 & n \times n & n \times 1 \end{matrix}$

其中，

$$\mathbf{H} = \mathbf{X} (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}' \quad (5.73a)$$

$n \times n$

透過(5.73)可知適配值 \hat{Y}_i 可以表示為反應變數觀測值 Y_i 的線性組合，而係數則為矩陣 \mathbf{H} 中的元素，同時矩陣 \mathbf{H} 僅僅牽涉到預測變數 \mathbf{X} 。 $n \times n$ 之方陣 \mathbf{H} 稱為帽子矩陣(hat matrix)，該矩陣使用於迴歸分析時是否會受到少數觀測值之影響

- 矩陣 \mathbf{H} 為一個對稱矩陣，並且具備一個冪等性的特殊性質：

$$\mathbf{H}\mathbf{H} = \mathbf{H} \quad (5.74)$$

在矩陣代數中，當矩陣 \mathbf{M} 滿足 $\mathbf{M}\mathbf{M} = \mathbf{M}$ 時，則稱該矩陣為冪等的。

- 殘差

將殘差 $e_i = Y_i - \hat{Y}_i$ 所組成之向量用符號 \mathbf{e} 表示：

$$\mathbf{e}_{n \times 1} = \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_n \end{bmatrix} \quad (5.75)$$

透過矩陣代數，我們有：

$$\mathbf{e}_{n \times 1} = \mathbf{Y}_{n \times 1} - \hat{\mathbf{Y}}_{n \times 1} = \mathbf{Y}_{n \times 1} - \mathbf{X}_{n \times 1} \mathbf{b}_{n \times 1} \quad (5.76)$$

在 Toluca 公司的案例中，應用(5.61a)與(5.72)可以得出殘差向量：

$$\mathbf{e} = \begin{bmatrix} 399 \\ 121 \\ \vdots \\ 323 \end{bmatrix} - \begin{bmatrix} 347.98 \\ 169.47 \\ \vdots \\ 312.28 \end{bmatrix} = \begin{bmatrix} 51.02 \\ -48.47 \\ \vdots \\ 10.72 \end{bmatrix} \quad (5.77)$$

其結果自然與表 1.2 相同。

殘差之共變異矩陣 一如配適值 \hat{Y}_i ，殘差 e_i 可以表示為反應變數觀測值 Y_i 的線性組合，應用(5.73)中 $\hat{\mathbf{Y}}$ 的結果：

$$\mathbf{e} = \mathbf{Y} - \hat{\mathbf{Y}} = \mathbf{Y} - \mathbf{H}\mathbf{Y} = (\mathbf{I} - \mathbf{H})\mathbf{Y}$$

我們可以得到：

$$\mathbf{e} = (\mathbf{I} - \mathbf{H}) \mathbf{Y} \quad (5.78)$$

$n \times 1$ $n \times n$ $n \times n$ $n \times 1$

其中 \mathbf{H} 為(5.73a)所定義之帽子矩陣，而矩陣 $\mathbf{I} - \mathbf{H}$ 與 \mathbf{H} 都是對稱且為冪等的。

殘差向量 \mathbf{e} 的共變異矩陣，與矩陣 $\mathbf{I} - \mathbf{H}$ 有關：

$$\sigma^2 \{\mathbf{e}\} = \sigma^2 (\mathbf{I} - \mathbf{H}) \quad (5.79)$$

$n \times n$

其估計式為：

$$\mathbf{s}^2 \{\mathbf{e}\} = MSE (\mathbf{I} - \mathbf{H}) \quad (5.80)$$

$n \times n$

5.12 變異數分析 Analysis of Variance Results

- 平方和

首先從(2.43)有關於SSTO (總平方和) 之定義開始，進行有關於如何利用矩陣來表達變異數分析：

$$SSTO = \sum (Y_i - \bar{Y})^2 = \sum Y_i^2 - \frac{(\sum Y_i)^2}{n} \quad (5.81)$$

而(5.13)為：

$$\mathbf{Y}'\mathbf{Y} = \sum Y_i^2$$

透過(5.18)所定義之矩陣 \mathbf{J} ，可以將 $(\sum Y_i)^2/n$ 表示為：

$$\frac{(\sum Y_i)^2}{n} = \left(\frac{1}{n}\right) \mathbf{Y}'\mathbf{J}\mathbf{Y} \quad (5.82)$$

舉例來說，若 $n=2$ ，則可得：

$$\begin{pmatrix} 1 \\ 2 \end{pmatrix} \begin{pmatrix} Y_1 & Y_2 \end{pmatrix} \begin{pmatrix} 1 & 1 \\ 1 & 1 \end{pmatrix} \begin{pmatrix} Y_1 \\ Y_2 \end{pmatrix} = \frac{(Y_1 + Y_2) \cdot (Y_1 + Y_2)}{2} = \frac{1}{2} (Y_1 + Y_2)^2$$

因此 $SSTO$ 可以表示為：

$$SSTO = \mathbf{Y}'\mathbf{Y} - \left(\frac{1}{n}\right)\mathbf{Y}'\mathbf{J}\mathbf{Y} \quad (5.83)$$

同理， $SSE = \sum e_i^2 = \sum (Y_i - \hat{Y}_i)^2$ ，也可以透過矩陣來表達：

$$SSE = \mathbf{e}'\mathbf{e} = (\mathbf{Y} - \mathbf{X}\mathbf{b})'(\mathbf{Y} - \mathbf{X}\mathbf{b}) \quad (5.84)$$

而且可以證明出下面的結果：

$$SSE = \mathbf{Y}'\mathbf{Y} - \mathbf{b}'\mathbf{X}'\mathbf{Y} \quad (5.84a)$$

以及 SSR ：

$$SSR = \mathbf{b}'\mathbf{X}'\mathbf{Y} - \left(\frac{1}{n}\right)\mathbf{Y}'\mathbf{J}\mathbf{Y} \quad (5.85)$$

例題

在 Toluca 公司的案例中，應用矩陣(5.61a)與(5.84a)可以得到：

$$\mathbf{Y}'\mathbf{Y} = [399 \quad 121 \quad \dots \quad 323] \begin{bmatrix} 399 \\ 121 \\ \vdots \\ 323 \end{bmatrix} = 2,745,173$$

另外，根據(5.65)與(5.63)，我們可以發現：

$$\mathbf{b}'\mathbf{X}'\mathbf{Y} = [62.37 \quad 3.5702] \begin{bmatrix} 7,807 \\ 617,180 \end{bmatrix} = 2,690,348$$

所以可以計算出 SSE ：

$$SSE = \mathbf{Y}'\mathbf{Y} - \mathbf{b}'\mathbf{X}'\mathbf{Y} = 2,745,173 - 2,690,348 = 54,825$$

其結果自然與第 1 章相同。

- 平方和的二次式表示

對於ANOVA中的平方和，事實上均可以證明它們為二次式，例如 $n = 2$ 時，觀測值 Y_i 的二次式：

$$5Y_1^2 + 6Y_1Y_2 + 4Y_2^2 \quad (5.86)$$

就是一個二階的多項式，該多項式之各項均為觀測值之平方或是兩兩之乘積，用矩陣表示(5.86)如下：

$$\begin{bmatrix} Y_1 & Y_2 \end{bmatrix} \begin{bmatrix} 5 & 3 \\ 3 & 4 \end{bmatrix} \begin{bmatrix} Y_1 \\ Y_2 \end{bmatrix} = \mathbf{Y}'\mathbf{A}\mathbf{Y} \quad (5.86a)$$

其中， \mathbf{A} 為一個對稱矩陣。

- 一般對於二次式之定義為：

$$\mathbf{Y}'\mathbf{A}\mathbf{Y} = \sum_{i=1}^n \sum_{j=1}^n a_{ij} Y_i Y_j \quad \text{其中 } a_{ij} = a_{ji} \quad (5.87)$$

而 \mathbf{A} 為一個 $n \times n$ 之對稱矩陣，特別稱它為二次式矩陣。

ANOVA中的平方和： $SSTO$ 、 SSE 、 SSR 都是二次式。從(5.71)式應用(5.32)可以得到：

$$\mathbf{b}'\mathbf{X}' = (\mathbf{X}\mathbf{b})' = \hat{\mathbf{Y}}'$$

利用(5.73)之結果可得出：

$$\mathbf{b}'\mathbf{X}' = (\mathbf{H}\mathbf{Y})'$$

因 \mathbf{H} 為對稱矩陣，並利用(5.32)可得：

$$\mathbf{b}'\mathbf{X}' = \mathbf{Y}'\mathbf{H} \quad (5.88)$$

此一結果可以讓我們以下列方式表示ANOVA中之平方和：

$$SSTO = \mathbf{Y}' \left[\mathbf{I} - \left(\frac{1}{n} \right) \mathbf{J} \right] \mathbf{Y} \quad (5.89a)$$

$$SSE = \mathbf{Y}' (\mathbf{I} - \mathbf{H}) \mathbf{Y} \quad (5.89b)$$

$$SSR = \mathbf{Y}' \left[\mathbf{H} - \left(\frac{1}{n} \right) \mathbf{J} \right] \mathbf{Y} \quad (5.89c)$$

- 每個平方和均可以表示為 $\mathbf{Y}'\mathbf{A}\mathbf{Y}$ ，相對應的 \mathbf{A} 矩陣則為：

$$\mathbf{I} - \left(\frac{1}{n}\right)\mathbf{J} \quad (5.90a)$$

$$\mathbf{I} - \mathbf{H} \quad (5.90b)$$

$$\mathbf{H} - \left(\frac{1}{n}\right)\mathbf{J} \quad (5.90c)$$

5.13 迴歸分析推論

Inference in Regression Analysis

- 區間估計的共同形式，均為利用點估計量加減所估計標準差之某一個倍數，在此進行點估計之變異數估計，其矩陣形式之討論。
- 迴歸係數

迴歸係數向量**b**，有下面的共變異矩陣：

$$\sigma_{2 \times 2}^2 \{\mathbf{b}\} = \begin{bmatrix} \sigma^2 \{b_0\} & \sigma \{b_0, b_1\} \\ \sigma \{b_1, b_0\} & \sigma^2 \{b_1\} \end{bmatrix} \quad (5.91)$$

可以表示為：

$$\sigma_{2 \times 2}^2 \{\mathbf{b}\} = \sigma^2 (\mathbf{X}'\mathbf{X})^{-1} \quad (5.92)$$

或是應用(5.24a)，表示為：

$$\sigma^2 \{ \mathbf{b} \}_{2 \times 2} = \begin{bmatrix} \frac{\sigma^2}{n} + \frac{\sigma^2 \bar{X}^2}{\sum (X_i - \bar{X})^2} & \frac{-\bar{X} \sigma^2}{\sum (X_i - \bar{X})^2} \\ \frac{-\bar{X} \sigma^2}{\sum (X_i - \bar{X})^2} & \frac{\sigma^2}{\sum (X_i - \bar{X})^2} \end{bmatrix} \quad (5.92a)$$

用 MSE 取代(5.92a)中的，可以得到 \mathbf{b} 之估計的共變異矩陣 $\mathbf{s}^2 \{ \mathbf{b} \}$ ：

$$\mathbf{s}^2 \{ \mathbf{b} \}_{2 \times 2} = MSE (\mathbf{X}'\mathbf{X})^{-1} = \begin{bmatrix} \frac{MSE}{n} + \frac{\bar{X}^2 MSE}{\sum (X_i - \bar{X})^2} & \frac{-\bar{X} MSE}{\sum (X_i - \bar{X})^2} \\ \frac{-\bar{X} MSE}{\sum (X_i - \bar{X})^2} & \frac{MSE}{\sum (X_i - \bar{X})^2} \end{bmatrix} \quad (5.93)$$

在(5.92a)中可以看出(2.3)中 b_0 的變異數與(2.9)中 b_1 的變異數，以及(4.5)中 b_0 與 b_1 共變異數。

在 Toluca 公司的案例中，應用圖 2.2 與(5.64)可以得到 $s^2\{b_0\}$ 與 $s^2\{b_1\}$ ：

$$\begin{aligned} \mathbf{s}^2_{2 \times 2}\{\mathbf{b}\} &= MSE(\mathbf{X}'\mathbf{X})^{-1} = 2,384 \begin{bmatrix} .287475 & -.003535 \\ -.003535 & .00005051 \end{bmatrix} \\ &= \begin{bmatrix} 685.34 & -8.428 \\ -8.428 & .12040 \end{bmatrix} \end{aligned} \quad (5.94)$$

所以 $s^2\{b_0\} = 685.34$ ，而 $s^2\{b_1\} = .12040$ ，結果與第 2 章相同。

平均反應

在此將針對 X_h 進行平均反應之估計，首先定義向量：

$$\mathbf{X}_h = \begin{bmatrix} 1 \\ X_h \end{bmatrix}_{2 \times 1} \quad \text{或} \quad \mathbf{X}'_h = [1 \quad X_h]_{1 \times 2} \quad (5.95)$$

用矩陣符號表示其配適值為：

$$\hat{Y}_h = \mathbf{X}'_h \mathbf{b}$$

因為，

$$\mathbf{X}'_h \mathbf{b} = [1 \quad X_h] \begin{bmatrix} b_0 \\ b_1 \end{bmatrix} = [b_0 + b_1 X_h] = [\hat{Y}_h] = \hat{Y}_h \quad (5.96)$$

在式子(2.29b)中給定 \hat{Y}_h 之變異數，利用矩陣形式表示如下：

$$\sigma^2 \{ \hat{Y}_h \} = \sigma^2 \mathbf{X}'_h (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}_h \quad (5.97)$$

應用式子(5.92)，(5.93)中 \hat{Y}_h 之變異數，可以表示為估計迴係數時，其共變異矩陣 $\sigma^2 \{ \mathbf{b} \}$ 之函數：

$$\sigma^2 \{ \hat{Y}_h \} = \mathbf{X}'_h \sigma^2 \{ \mathbf{b} \} \mathbf{X}_h \quad (5.97a)$$

在(2.30)中所列出 \hat{Y}_h 之估計變異數，在此利用矩陣形式表示為：

$$s^2 \left\{ \hat{Y}_h \right\} = MSE \left(\mathbf{X}'_h (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}_h \right) \quad (5.98)$$

例題

在 Toluca 公司的案例中，當 $X_h = 65$ 時，我們可以計算 $s^2\{\hat{Y}_h\}$ ，首先定義

$$\mathbf{X}'_h = [1 \quad 65]$$

並應用(5.94)之結果，我們有：

$$\begin{aligned} s^2 \left\{ \hat{Y}_h \right\} &= \mathbf{X}'_h \mathbf{s}^2 \{ \mathbf{b} \} \mathbf{X}_h \\ &= [1 \quad 65] \begin{bmatrix} 685.34 & -8.428 \\ -8.428 & .12040 \end{bmatrix} \begin{bmatrix} 1 \\ 65 \end{bmatrix} = 98.37 \end{aligned}$$

結果與第 2 章相同。

- 新觀測值之預測

在式子(2.38)中所給的估計變異數 $s^2\{\text{pred}\}$ 用矩陣形式表示為：

$$s^2\{\text{pred}\} = MSE \left(1 + \mathbf{X}'_h (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}_h \right) \quad (5.100)$$