

## Practice#1 : Canonical Correlation

目的：

Canonical Correlation Analysis 在探討複迴歸分析中有多個因變數的情形。如果去考慮每個因變數與自變數的關係，問題將變的非常麻煩。但是，如果可以將多個因變數組合成一個新的變數，問題將單純許多。Canonical Correlation Analysis 便是在探討什麼樣的組合才是最恰當的。這樣的關係推展到類別分析時，對於變數太多的情況可以得到比較簡單的判別方式，雖然犧牲了精準度，對於許多應用而言卻已經足夠了。本單元僅對 Canonical Correlation 做初步的探討，著眼點仍在如何應用 MATLAB 程式的寫作去處理一般常見的統計方法。

複迴歸分析在找出因變數與多個自變數之間的關係，其模式如

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \cdots + \beta_p X_p \quad (1)$$

$\underline{\beta} = [\beta_0 \ \ \beta_1 \ \ \cdots \ \ \beta_p]$  決定了自變數與因變數間的關係。一般對  $\underline{\beta}$  估計採最小平方法，也就是求一組最佳值  $\underline{\beta}^o$ ，使得上述模式與因變數樣本資料得到最佳的配適。這裡的「最佳」指的是

$$\min_{\underline{\beta}} \sum_{k=1}^N (y_k - \beta_0 - \beta_1 x_{1k} - \beta_2 x_{2k} - \cdots - \beta_p x_{pk})^2 \quad (2)$$

最佳值  $\underline{\beta}^o$  滿足正規方程式(Normal Equation)

$$(X' X) \underline{\beta}^o = X' \underline{y} \quad (3)$$

其中資料矩陣  $X$  與  $y$  的結構請參考前面關於迴歸分析的單元。

另一種「最佳」的表示法：在所有自變數的線性組合中，找出一組使得其線性組合後的變數與因變數的相關係數最大。即

$$\max_{\underline{b}} \frac{\text{cov}(Y, X \underline{b})}{\sqrt{\text{var}(Y) \text{var}(X \underline{b})}} \quad (4)$$

$$\text{其中 } X = \begin{bmatrix} X_1 & X_2 & \cdots & X_p \end{bmatrix}, \underline{b} = \begin{bmatrix} b_1 & b_2 & \cdots & b_p \end{bmatrix}^T$$

為方便進一步的推導，假設變數  $X_i$  與  $Y$  都已經標準化，即  $\text{var}(Y) = \text{var}(X_i) = 1$ 。此外，也假設組合係數  $\underline{b}$  的選擇使得  $\text{var}(X\underline{b}) = 1$ 。式(4)變為

$$\max_{\underline{b}, s.t. \text{var}(X\underline{b})=1} \text{cov}(Y, X\underline{b}) \quad (5)$$

或

$$\max_{\substack{\underline{b}, s.t. \\ \frac{1}{N-1}\underline{b}^T X^T X \underline{b} = 1}} \frac{1}{N-1} \underline{y}^T X \underline{b} \quad (6)$$

$$\text{其中 } \underline{y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_N \end{bmatrix}, X = \begin{bmatrix} x_{11} & x_{21} & \cdots & x_{p1} \\ x_{12} & x_{22} & \cdots & x_{p2} \\ \vdots & \vdots & \ddots & \vdots \\ x_{1N} & x_{2N} & \cdots & x_{pN} \end{bmatrix}$$

式(6)經 Lagrangian method 求得最佳解滿足下列條件（作業 1）

$$X^T X \underline{b}^o = 2\lambda X^T \underline{y} \quad (7)$$

其中  $\lambda$  即所謂的 Lagrangian multiplier。最佳的組合係數與最小平方法的解幾乎相同。這也說明最小平方法的精神就是求最大相關係數。

「找出自變數最佳的組合，使得該組合與因變數之間的相關係數最大，」可以推展到當因變數不只一個時。即「找出最佳的自變數組合與因變數的組合，使得兩個組合變數之間的相關係數最大。」假設  $\underline{u} = X\underline{b}$ ,  $\underline{t} = Y\underline{a}$  分別代表自變數與因變數的線性組合，也稱為 canonical variates。問題變成

$$\max_{\substack{\underline{a}, \underline{b}, s.t. \\ \frac{1}{N-1}\underline{a}^T Y^T Y \underline{a} = 1, \frac{1}{N-1}\underline{b}^T X^T X \underline{b} = 1}} \frac{1}{N-1} \underline{a}^T Y^T X \underline{b} \quad (8)$$

其中目標函數為  $\underline{u}$  及  $\underline{t}$  間的相關係數  $r(\underline{u}, \underline{t})$ ，又稱為 canonical correlation。(8)的最佳解分別滿足

$$\begin{aligned} (R_{YY}^{-1} R_{YX}^{-1} R_{XX}^{-1} R_{XY}) \underline{a} &= r^2(\underline{u}, \underline{t}) \underline{a} \\ (R_{XX}^{-1} R_{XY}^{-1} R_{YY}^{-1} R_{YX}) \underline{b} &= r^2(\underline{u}, \underline{t}) \underline{b} \end{aligned} \quad (9)$$

其中

$$R_{YX} = \frac{1}{N-1} Y^T X$$

$$R_{XX} = \frac{1}{N-1} X^T X$$

$$R_{YY} = \frac{1}{N-1} Y^T Y$$

式(9)是一個 eigenvector-eigenvalue 的問題。最佳解  $\underline{a}$  與  $\underline{b}$  分別為  $R_{YY}^{-1} R_{YX} R_{XX}^{-1} R_{XY}$  及  $R_{XX}^{-1} R_{XY} R_{YY}^{-1} R_{YX}$  的 eigenvector 中 eigenvalue 最大的那一個。或是以下列的關係從一個最佳解  $\underline{b}$  計算另一個最佳解  $\underline{a}$

$$\underline{a} = \frac{1}{r(\underline{u}, \underline{t})} R_{YY}^{-1} R_{YX} \underline{b} \quad (10)$$

練習：

1. 從共變異矩陣(Covariance Matrix)與相關矩陣(Correlation Matrix)說起；  
i、兩變數  $x, y$  間的共變異數 (covariance) 及樣本共變異數 (sample covariance) 分別定義為： $(x(k), y(k))$  代表變數  $x$  與  $y$  的第  $k$  個樣本值)

$$\text{cov}(x, y) = \sigma_{xy} = E[(x - \mu_x)(y - \mu_y)] \quad (11)$$

$$s_{xy} = \frac{1}{N-1} \sum_{k=1}^N (x(k) - \bar{x})(y(k) - \bar{y}) \quad (12)$$

- ii、當變數超過兩個（假設為  $p$  個），變數與變數間的共變異數可以透過共變異矩陣來觀察，其定義及數值計算的方式如

$$\Sigma = \text{cov}(X) = E[(X - \underline{\mu}_X)(X - \underline{\mu}_X)^T] = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \cdots & \sigma_{1p} \\ \sigma_{21} & \sigma_{22} & \cdots & \sigma_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{p1} & \sigma_{p2} & \cdots & \sigma_{pp} \end{bmatrix} \quad (13)$$

$$\text{其中 } X = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_p \end{bmatrix}, \quad \underline{\mu}_X = E[X] = \begin{bmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_p \end{bmatrix}$$

$$\begin{aligned}
S &= \begin{bmatrix} s_{11} & s_{12} & \cdots & s_{1p} \\ s_{21} & s_{22} & \cdots & s_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ s_{p1} & s_{p2} & \cdots & s_{pp} \end{bmatrix} = \\
&\quad \left[ \begin{array}{ccc} \frac{1}{N-1} \sum_{k=1}^N (x_1(k) - \mu_1)(x_1(k) - \mu_1) & \frac{1}{N-1} \sum_{k=1}^N (x_1(k) - \mu_1)(x_2(k) - \mu_2) & \cdots \\ \frac{1}{N-1} \sum_{k=1}^N (x_2(k) - \mu_2)(x_1(k) - \mu_1) & \frac{1}{N-1} \sum_{k=1}^N (x_2(k) - \mu_2)(x_2(k) - \mu_2) & \cdots \\ \vdots & \vdots & \ddots \\ \frac{1}{N-1} \sum_{k=1}^N (x_p(k) - \mu_p)(x_1(k) - \mu_1) & \frac{1}{N-1} \sum_{k=1}^N (x_p(k) - \mu_p)(x_2(k) - \mu_2) & \cdots \end{array} \right] = \\
&\quad \frac{1}{N-1} X_c^T X_c \quad \text{where } X_c = \begin{bmatrix} x_1(1) - \mu_1 & x_2(1) - \mu_2 & \cdots & x_p(1) - \mu_p \\ x_1(2) - \mu_1 & x_2(2) - \mu_2 & \cdots & x_p(2) - \mu_p \\ \vdots & \vdots & \ddots & \vdots \\ x_1(N) - \mu_1 & x_2(N) - \mu_2 & \cdots & x_p(N) - \mu_p \end{bmatrix} \tag{14}
\end{aligned}$$

iii、兩變數  $x, y$  間的相關係數(correlation coefficient)及其數值計算  
(sample correlation coefficient)定義為

$$\rho_{xy} = \text{corr}(x, y) = \frac{\sigma_{xy}}{\sigma_x \sigma_y} \tag{15}$$

$$r_{xy} = \frac{s_{xy}}{s_x s_y} \tag{16}$$

iv、當變數超過兩個 (假設為  $p$  個)，變數與變數間的相關係數可以透過相關矩陣來觀察，其數值計算的方式如

$$R = \begin{bmatrix} 1 & r_{12} & \cdots & r_{1p} \\ r_{21} & 1 & \cdots & r_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ r_{p1} & r_{p2} & \vdots & 1 \end{bmatrix} = \frac{1}{N-1} Z^T Z \tag{17}$$

$$\text{其中 } Z = \begin{bmatrix} \frac{x_1(1) - \mu_1}{\sigma_1} & \frac{x_2(1) - \mu_2}{\sigma_2} & \dots & \frac{x_p(1) - \mu_p}{\sigma_p} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{x_1(N) - \mu_1}{\sigma_1} & \frac{x_2(N) - \mu_2}{\sigma_2} & \dots & \frac{x_p(N) - \mu_p}{\sigma_p} \end{bmatrix}$$

- v、Matlab 亦提供共變異矩陣與相關矩陣的功能函數，分別為 *cov* 及 *corrcoef*。雖然 MATLAB 提供了這些功能，不過使用者最好能根據定義實際去計算一次，以確定 MATLAB 的函數與自己預期的一致。請自網路下載資料：canonical\_data2.txt，分別利用(13)及(16)計算其 sample covariance matrix 及 sample correlation matrix。並驗證 MATLAB 提供的指令 *cov* 及 *corrcoef*。

Hint:式(13)可以一個指令完成

```
Xc=X-(ones(length(X(:,1)),1)*mean(X));
```

- vi、其實當資料經過標準化後，共變異矩陣等於相關矩陣。標準化一個資料矩陣可以使用 *zscore* 指令。
2. 本單元探討了變數間的相關性，我們可以從已知的資料中計算彼此間的相關係數，一般稱為相關矩陣(correlation matrix)。請從網路下載一組資料檔（資料來源[1]） canonical\_data1.txt，該檔案資料包括兩個輸入變數及兩個輸出變數的資料。計算這四個變數的相關矩陣：
- i、檢查這四組資料是否為標準化資料？
  - ii、觀察變數間的相關係數，即計算相關矩陣。
  - iii、所謂 canonical variates 是輸入變數的組合  $u=b_1x_1+b_2x_2$  與輸出變數的組合  $t=a_1y_1+a_2y_2$ ，係數的選擇使得  $u$  與  $t$  間的相關係數最大。在尚未計算最佳組合前，先就一些組合來觀察其相關性；譬如

$u_1 = \frac{100}{100}x_1 + \frac{0}{100}x_2$ $u_2 = \frac{90}{100}x_1 + \frac{10}{100}x_2$ $\vdots$ $u_{11} = \frac{0}{100}x_1 + \frac{100}{100}x_2$	$t_1 = \frac{100}{100}y_1 + \frac{0}{100}y_2$ $t_2 = \frac{90}{100}y_1 + \frac{10}{100}y_2$ $\vdots$ $t_{11} = \frac{0}{100}y_1 + \frac{100}{100}y_2$
---	---

建立一關係矩陣來觀察輸入變數的 11 種組合與輸出變數的 11 種組

合間的相關係數。

- iv、利用式(9) 計算最佳的組合係數及 canonical correlations.

#### 觀察：

1. 計算式(9) 的 eigenvector 時，請留意限制條件  $\underline{a}^T R_{YY} \underline{a} = 1$ ,  $\underline{b}^T R_{XX} \underline{b} = 1$  必須被滿足。因此適當的調整 eigenvector 的 scale 是有必要的。
2. Canonical Correlation Analysis 及 principal component 在觀念上非常近似，但實際上確實不同的東西，請仔細比對這兩個分析方法的異同，才不會在應用時搞錯方向。

#### 作業：

1. 證明最佳化問題(6)的解為(7)。
2. 證明最佳化問題(8)的解為(9)。
3. 推導(10)。

#### 參考文獻

1. J. Latin, D. Carroll, P. E. Green, "Analyzing Multivariate Data," 2003, Duxbury.
2. A. C. Rencher, "Multivariate Statistical Inference and Applications," 1998, John Wiley & Sons.
3. 黃俊英，"多變量分析<第七版>，"中國經濟企業研究所。