

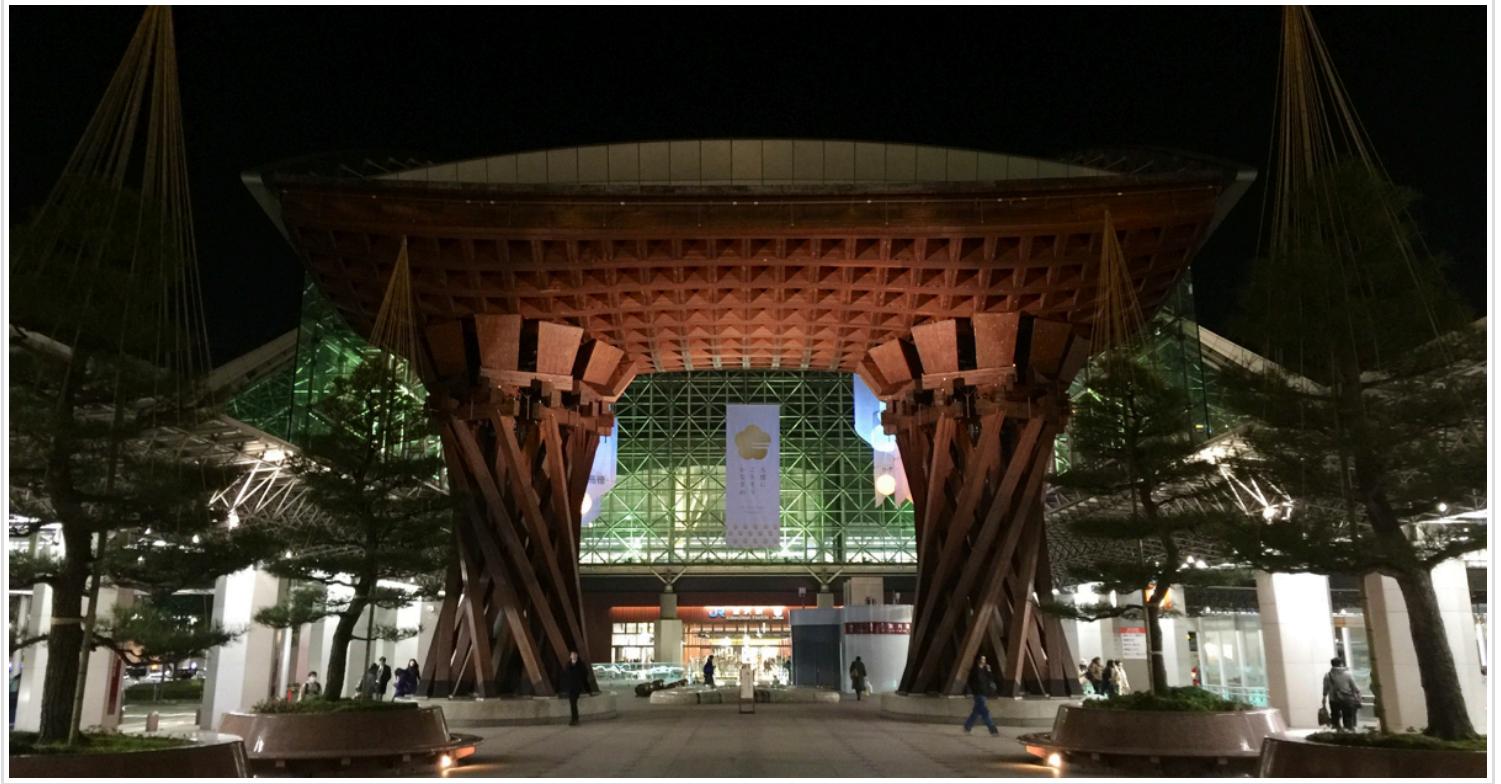


McK & Note

[首頁](#) [分類](#) [文庫](#) [標籤](#)

/ Advanced Econometrics I

發表於 2016-12-26 | 分類於 <#> | [0 Comments](#) | [Like 1](#) [Share](#)



找完工作以後，日子依舊忙碌。這個學期 MSBA 有三門課，分別代表 Business Analytics 中三個滿重要的發展方向：分析理論、程式設計、和資料庫。這篇先從偏理論的計量經濟學談起。

秋季學期的安排

和之前上 *Data Visualization* 和 *Statistics* 的夏季學期不同，秋季學期有整整十週（加期末考一週），所以排課就變得滿正常，不過當然也滿考驗時間安排，畢竟不能像夏季學期，可以把全部時間花在單一科目上。這學期 MSBA 學生要修的課有三門：

- *Advanced Econometrics I* (理論、分析)
- *Computational Methods* (實作)
- *Data Management* (資料庫操作、管理)

雖然每門課看起來都滿難的 (Computational? Advanced? !)，但其實也真的滿難認真修完一遍以後，真的能體會到學好這三門課是在 Business Analytics 或 Data Science 領域必備的基礎；而且如果有心繼續鑽研，會發現業界前沿的技術和應用，都和這三個發展方向脫離不了關係，所以不管是入門或進階、研究或應用，似乎都得從這三門課開始。

以 Advanced Econometrics 這門課為例，雖然一開始會被各式各樣的公式、證明佐矩陣運算，外加數十頁的作業搞得有點暈頭轉向，但只要跨過計算的門檻後，回頭一看，就比較能理解線性迴歸模型（LRM）中各項假設和定理的關係，也才清楚如何正確計算、解讀各項統計數據。所以儘管讀者可能跟我一樣，曾經感覺自己踏入 Data Science，就是比較想走應用，對理論則敬而遠之；但要能正確使用工具與解讀結果，仍需要紮實的理論知識，這就是 Advanced Economics 的教學目的。以下我想盡量簡單介紹我們學了些什麼。

註：本文公式較多，建議請用電腦閱讀；如果無法正常顯示，請試用其它瀏覽器，或[下載全文（3.6 MB）](#)。

老師和教學方法

這門課的老師是 Dr. Jonathan James，他是個熱情洋溢，也很關心學生的好教授，而且平均一門課會講三四個很棒的笑話，活潑的風格常讓我聯想 BoJack Horseman 裡的 Mr. Peanutbutter。教學方法是版書和投影片，作業形式包括手寫證明題，還有用 R 實作數據分析、並解讀結果。順帶一提，Dr. Jonathan 的所有文件都是用 LaTeX 編排，其精美程度讓我忍不住也跳入學習 LaTeX 的深淵了……。

由於 Dr. Jonathan 已經把上課內容都寫進講義裡了，我們整堂課下來也沒用到教科書，不過在 Syllabus 上他指定的教科書是 William H. Greene 的 Econometric Analysis。但因為這本書讀起來實在有點生硬（可能是我個人閱讀能力問題），我在朋友推薦下，找了一本 Jeffrey M. Wooldridge 的 Introductory Econometrics: A Modern Approach。後者的優點包括：

- **清晰的架構，深入淺出：**在 Simple Regression Model 中就介紹了許多數值和性質，接下來的 Multiple Regression Model 再談 Asymptotics 等等
- **貼心的附錄，照顧數學弱勢：**包括 Linear Function、Matrix、Probability、Statistics 等基本概念，記憶模糊時（which is always）可以快速回顧

Introductory Econometrics 成功救了我好幾次作業和考試，也是我心目中 Econometrics 領域最棒的教科書之一。

課前準備

當然，從附錄的內容可以看出要學好 Econometrics 需要一點線性代數（linear algebra）和統計（statistics）基礎。粗淺一點來說，需要具備的能力如下：

- **矩陣：**會讀矩陣表達式，熟練加減乘除、轉置、逆矩陣等運算

- 統計：熟練平均、方差（變異數）、標準差等運算，以及母體和樣本的關係
- 機率：瞭解條件機率、CDF、PMF / PDF 的意義

以上這些算是最低要求，實際開始學以後，還會碰到許多衍生的觀念、證明和公式，入門先具備清晰的基本觀念就好。有任何不清楚的觀念，可以參考 *Statistics* 中提到的相關資源。既然都學到 Econometrics 了，一定要捨得花時間把所有觀念弄懂，畢竟這會直接影響日後的分析能力。例如，如果不熟矩陣運算，就沒辦法很有效率地思考線性迴歸（*Linear Regression*）中參數的性質，也就很難理解什麼情況下參數會出現偏誤（bias），以及怎樣避免偏誤。如前所述，要能正確使用各類統計工具，必須先瞭解這些工具背後的理論。

線性迴歸

如果上面的運算都沒什麼問題（或是感覺沒什麼問題想先繼續往下讀），就可以來認識 *Advanced Economics* 中主角中的主角——線性迴歸模型（linear regression model, LRM）了：

$$y_i = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \varepsilon_i \quad (1)$$

公式中的 i 表示第 i 個樣本（sample observation）； y 為因變量（dependent variable），即模型打算解釋的反應變量（response）； x 為自變量（independent variable），即模型中用來解釋 y 的控制變量（control）。 y 和 x 的其它名稱可以參考以下 *Introductory Econometrics* 的整理：

Y 的名稱	X 的名稱
Dependent variable	Independent variable
Explained variable	Explanatory variable
Response variable	Control variable
Predicted variable	Predictor variable
Regressand	Regressor

另外，公式中的 β 為參數（parameter or estimate），表示不同 x 對 y 的影響，其中 β_0 為用來調整大小的截距項（intercept）；最後， ε 是 y 中無法以 x 解釋的殘差項（residual）。如果用一句話簡單說明 y 、 x 、 β 和 ε ，即試

著用 β 組合 x ，得出最接近 y 、即 ε 最小的預估值。在這裡，線性 (linear) 的意義在於組合的方式為線性組合 (linear combination)，即 β 是線性的，不會出現 $\beta_1 x_1 + \beta_1^2 x_2$ 之類的情況。

由此可見，LRM 是試著用 x 基於 β 的線性組合來預測（或說描述） y 。為了和實際的反應變量 y 區別， $(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k)$ 這部分又被稱為 \hat{y} （讀作 Y-hat，可稱作 fitted value），所以上述 (1) 式可以表示為：

$$y_i = \hat{y}_i + \varepsilon_i \quad (2)$$

可以理解為「觀測值 = 預估值 + 雜訊」。到這裡，我已經用第 i 個樣本（一列）解釋完 LRM 的結構，如果用矩陣記錄 n 個樣本（多列）的運算，就可以推廣成下式：

$$Y = X\beta + \varepsilon \quad (3)$$

- Y 是一個 $(n \times 1)$ 的矩陣，因為有 n 個樣本
- X 是一個 $(n \times k)$ 的矩陣，因為根據 (1) 式，在這 n 個樣本中，我們試著用 k 組自變量來解釋 Y
- 最後， ε 是一個 $(n \times 1)$ 的矩陣

如果將 Y 、 X 和 ε 化為日常中常見的 Excel 表格，可以這樣表示：

樣本編號	Y (銷量)	X_1 (價格)	X_2 (廣告)	...	X_k (人流)	ε (殘差)
1	20	15	3	...	180	1
2	23	14	3	...	170	1.5
...
n	21	15	4	...	200	1.3

可以看到樣本有 n 個，自變量有 k 組。另外，請回想一下 (1) 式中 β 的表達形式，由於這個模型中有 k 組自變量，相應地應該要有 k 個 β 作為線性組合的比例，所以 (3) 式中的 β 是一個 $(k \times 1)$ 的矩陣。

利用 (3) 式中的矩陣表達，可以很精簡地將上面表格中的數值，以 Y 、 X 、 β 和 ε 來表示，它們之間的關係仍和單一樣本中的 y 、 x 、 β 和 ε 一致：試著用 β 組合 X ，得出最接近 Y 、即 ε 最小的預估值。



最小平方法

介紹完 LRM 基本架構後的第一個問題，就是「如何算出 β 和 ε ？」關鍵在於前面提到的一句話：得出最接近 Y 、即 ε 最小的預估值。從上面的公式可以得知 ε 的計算方法為：

$$\varepsilon = Y - \hat{Y} = Y - X\beta \quad (4)$$

考慮到 ε 是一個 $(n \times 1)$ 的矩陣，最小值的目標自然是 $\sum_{i=1}^n \varepsilon_i$ ；不過，為了避免 ε_i 正負抵銷，我們實際要計算的是 $\sum_{i=1}^n \varepsilon_i^2$ 。用矩陣來表示，就是 $\varepsilon' \varepsilon$ ，解釋如下：

$$\varepsilon' = [\varepsilon_1, \varepsilon_2 \dots, \varepsilon_n], \quad \varepsilon = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{bmatrix}, \quad \varepsilon' \varepsilon = (\varepsilon_1^2 + \varepsilon_2^2 + \dots + \varepsilon_n^2) = \sum_{i=1}^n \varepsilon_i^2$$

所以找到使 $\sum_{i=1}^n \varepsilon_i^2$ 達到最小值的 β 的方法就是最小平方法 (ordinary least squares, OLS)。

母體和樣本

在談如何計算 β 和 ε 前，我想先來小小澄清一下（？）母體和樣本的關係。雖然說我們想預測的是 β 和 ε ，但隨著資料的不同，所得到的 β 和 ε 也會不同。比方說，在前面的表格中：

- 用從第一個到第 n 個樣本所得到的 β_n 和 ε_n
- 用從第一個到第 $(n/2)$ 個樣本所得到的 $\beta_{n/2}$ 和 $\varepsilon_{n/2}$

兩組數據可能會不一樣，而就算我們選擇採用 β_n 和 ε_n ，在我們沒觀測到的地方可能還有：

- 由從第一個到第 $2n$ 個樣本所得到的 β_{2n} 和 ε_{2n}

這是因為我們觀察到的數值，幾乎永遠都是樣本（sample）而非象徵全貌的母體（population），所以統計值（ β_n 、 ε_n 、平均、方差等等）會不斷隨著資料改變而浮動。為了將這些浮動的數值和母體中固定的數值區分開來，我們會說母體中不變的參數和殘差是 β 和 ε ，而我們試著用樣本估計的參數和殘差是 b 和 e 。 β 和 ε 是不變的，而 b 和 e 會隨著樣本的變化而改變。類似的作法也涵蓋了平均和方差：

統計值	母體（不變）	樣本（浮動）
平均	μ	\bar{x}
方差	σ^2	s^2
參數	β	b
殘差	ε	e

所以前面提到的（3）式可以再進一步如下表示：

$$Y = X\beta + \varepsilon = Xb + e \quad (5)$$

這邊 b 和 e 的矩陣維度，和 β 和 ε 是相同的。需要注意的是，雖然 ε 和 e 都是殘差（實際上兩者的稱呼會有所區別），但兩者的性質有著微妙的差異：

- ε 是母體中的實際誤差
- e 除了實際誤差外，還包含了受限於樣本數的解釋誤差

比方說，小明是個消費完全理性的人，他平常有記帳的習慣，但有時候記得太快，會按錯個位數，這個誤差就是 ε ；小華根據小明的行為，分析他一半的帳目，發現其中有些無法解釋的零頭，這個誤差就是 e 。由於樣本只佔母體的一半， e 除了包含小明確實按錯的誤差以外，也包含了樣本資訊不及母體資訊的誤差。這時，根據 e 所計算出的 b 就會和 β 不太一樣，就算拿這個模型去預測小明另一半的帳目，也不會完全準確。

因此從(5)式還有上面這個例子可以看出，真正準確的 b ，來自一個非常接近 ε 的 e 。除了增加樣本數以外，避免分析過程中可能出現的誤差（bias）也是一個方法，這在後面的假設會提到。

計算結果和延伸

言歸正傳，為了根據樣本求出達成最小 $\sum_{i=1}^n e_i^2$ 的 b ，可以採取的方法有兩個：

1. Method of Moments: 根據 MOM 推導等式
2. Derivative: 利用微分後的一階條件得出 b 的最大值

因為計算過程有點複雜，如果都寫在這邊，可能就得轉型成 Math & Note 了，所以上面兩個連結是簡略的證明過程，前面提到的兩本教科書裡也有完整說明。簡而言之，最後可以得出下式：

$$b = (X'X)^{-1}X'Y \quad (6)$$

記得 b 是一個 $(k \times 1)$ 的矩陣。另外(4)式中的 \hat{Y} 也可以寫成：

$$\hat{Y} = Xb = X(X'X)^{-1}X'Y \quad (7)$$

雖然這個公式看起來很複雜，但實際推導過一次以後會比較習慣；而有了標準的表達方式以後，也就能推導出 b 的各項性質，也就是在解讀參數時應該注意的細節。例如：

1. 和母體的關係： $b = (X'X)^{-1}X'Y = (X'X)^{-1}X'(X\beta + \varepsilon) = \beta + (X'X)^{-1}X'\varepsilon$

由此可看出 b 中包含 ε ，以及樣本 X 如何左右 ε 的影響程度。

2. 方差分析： $SST = \sum_{i=1}^n (y_i - \bar{y})^2 = SSR_{egression} + SSE_{rror} = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 + \sum_{i=1}^n e_i^2$

當 LRM 的擬合度越好， $SSE = \sum_{i=1}^n e_i^2$ 越小，解釋程度 $R^2 = \frac{SSR}{SST}$ 越高。

3. 期望值： $E(b|X) = \beta + (X'X)^{-1}X'E(\varepsilon|X) = \beta$

隨著樣本數增加， b 將逼近 β 的漸進 (asymptotic) 和一致 (consistency) 性質。

4. 方差 (和協方差矩陣) : $\widehat{Var(b|X)} = s^2(X'X)^{-1}$, $s^2 = \frac{e'e}{n-k}$

利用總體方差計算 b 的標準差，確認預估的精準度和有效性 (efficiency) 。

5. 分布函數： $b|X \sim N\left(\beta, s^2(X'X)^{-1}\right)$, $b_k|X \sim N\left(\beta, s^2(X'X)^{-1}\right)_{(k \times k)}$

對 b_k 進行假設檢驗 (hypothesis test) 、構建信賴區間 (confidence interval) 等。

對於讀到這邊感到一頭霧水的讀者，我想說（一）不用擔心，到目前為止提到的內容，都是 R 等統計軟體中內建好的功能，所以就算不懂怎麼用矩陣算 b 也沒關係，分析結果中已經包含所有計算；但（二）這些內容有點類似判斷模型好壞的基礎，後面會提到這些計算、證明所衍生的性質，它們會直接影響分析過程中選擇什麼工具、如何處理資料和解讀結果。

以 R 來比喻的話，（一）的情況如下：

```

1 Call:
2 lm(formula = mpg ~ cyl + disp + hp + drat + wt, data = mtcars)
3
4 Residuals:
5   Min     1Q Median     3Q    Max
6 -3.7014 -1.6850 -0.4226  1.1681  5.7263
7
8 Coefficients:
9             Estimate Std. Error t value Pr(>|t|)
10            #1          #4          #5          #5
11 (Intercept) 36.00836  7.57144  4.756  6.4e-05 ***
12 cyl         -1.10749  0.71588 -1.547  0.13394
13 disp        0.01236  0.01190  1.039  0.30845
14 hp          -0.02402  0.01328 -1.809  0.08208 .
15 drat        0.95221  1.39085  0.685  0.49964
16 wt          -3.67329  1.05900 -3.469  0.00184 **
```

```

17   ---
18 Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
19
20 Residual standard error: 2.538 on 26 degrees of freedom
21             #2
22 Multiple R-squared:  0.8513,    Adjusted R-squared:  0.8227
23             #2
24 F-statistic: 29.77 on 5 and 26 DF,  p-value: 5.618e-10 #5
25             #5

```

註：上述註記中，#1 為由第一個性質（和母體的關係）推導而得，以此類推。

(二) 所涵蓋的問題則包括：

- 一開始 `lm()` 中的資料選取是否妥當？
- Estimate、Std. Error 是否有偏差？如何解決？
- 如何正確解讀 (Adjusted) R-squared、F-statistic 和 t value？
- 分析結果是否有改進空間？如何取捨 bias 和 variance？

所以，這邊的分水嶺大概是「我知道怎麼操作 `lm()`、`glm()` 甚至 `rpart()` 等函數，但我不清楚這些統計結果是否正確，也不知道應該按什麼步驟處理資料、或微調 (`tweak`) 函數來改善預測結果」。*Econometrics* 可以幫助你瞭解背後的原理，但要學好 *Econometrics*，還是得從上面這些內容開始。

假設與性質

學好上面這些基礎的重要理由之一，在於弄清楚 LRM 內部是怎麼一回事，還有這些分析是建立在哪些假設上。說到這裡，我不得不說 Dr. Peanutbutter Jonathan 把課程規劃得滿好。他先介紹了 LRM 的五個很重要的假設，它們分別是：

1. **Linearity**: b 的關係一定要是線性 (X 則不在此限)
2. **Full Rank**: X 矩陣必須為滿秩，可以理解為不能有兩組以上完全相關的 X
3. **Mean Independence**: $E(\varepsilon|X) = 0$ ，瞭解 X 無助於瞭解 ε
4. **Homoskedasticity & Non-autocorrelation**: $Var(\varepsilon|X) = \sigma^2$ 和 $Cov(\varepsilon_i, \varepsilon_j|X) = 0, \forall i \neq j$ ，即 ε 的分布獨立於 X ，且 ε 之間不相關
5. **Normality**: $\varepsilon \sim N(0, \sigma^2)$ ， ε 的分布符合正態分布 N

註：這邊提到的五個假設，和 [Wikipedia - Linear regression](#) 與 *Introductory Econometrics* 上所提到的有些微差異，但在原理上應該是相通的，端看講者側重說明 LRM 的哪些面向。

介紹完這五個基本假設後，我們就開始探討「如果實際資料不（完全）符合這些假設，該如何避免潛在的偏差」。於是，基於這五項假設，我們另外學了以下內容，它們的證明和推導，都是來自上面所提到的計算結果和延伸。

假設	期中考前的延伸	期末考前的延伸
Linearity	利用多項式 (polynomial) 改善 R^2	增設交互項 (interaction term) 以解讀 X 之間的交互關係
Full Rank	留意虛擬變量 (dummy variable) 的設定	當 $k > n$ 時，可採取 Ridge 或 Lasso 等 Penalized Regression
Mean Independence	檢討 b 在不同樣本情況下可能出現的偏差 (bias)，並判斷偏差方向	利用工具變量 (instrumental variable, IV) 消弭 b 偏差
Homoske & Non-Auto	瞭解 OLS 估計的 MVLUE 性質，以及影響 $Var(b_k)$ 的三個因素	利用多種方法 (註) 修正 $\widehat{SE}(b_k)$ 偏差，和用 Bootstrapping 取樣
Normality	對 b_k 或 \hat{y}_0 進行假設檢驗、計算信賴區間、 t 值、 F 值和 p 值	基於 MLE 構建 $L(\theta)$ ，並用 <u>Newton-Raphson</u> 等方法估計 b

註：針對 Heteroskedasticity 的解決方案，包括 Weighted Least Squares (WLS) 、Huber-White Standard Errors、Breusch-Pagan Test、DoubleJ Test 和 Clustered Standard Error 等。



解決潛在問題

讀者如果沒學過這些性質，可能會覺得一頭霧水，所以我想沿用前面的例子，說明瞭解這些性質有多重要，如果讀者有一些數據分析經驗，應該能比較好理解。

首先，前面我用來說明(3)式表達法 $Y = X\beta + \varepsilon$ 的例子如下：

樣本編號	Y (銷量)	X1 (價格)	X2 (廣告)	...	Xk (人流)	e (殘差)
1	20	15	3	...	180	1
2	23	14	3	...	170	1.5
...
n	21	15	4	...	200	1.3

Mean Independence

乍看之下這份資料很正常，但如果我們試著質疑它，就會引出一些潛在的問題。例如，如果我將第 k 項資料（人

流) 刪除:

樣本編號	Y (銷量)	X1 (價格)	X2 (廣告)	...	Xk-1 (車流)	e (殘差)
1	20	15	3	...	40	2
2	23	14	3	...	50	2.5
...
n	21	15	4	...	45	0.3

表格一：少了第 k 項資料（人流）

請問：

- 跟原始資料相比，除了少了最後一項以外， b （即分析結果中的 Estimate）會出現怎樣的變化？
- 如果「人流」確實和「銷量」有關，這樣的變化是偏差還是修正？

如果將和「銷量」幾乎毫不相關的「極光強度」加入模型中：

樣本編號	Y (銷量)	X1 (價格)	X2 (廣告)	...	Xk (極光強度)	e (殘差)
1	20	15	3	...	100%	0.9
2	23	14	3	...	70%	1.7
...
n	21	15	4	...	15%	3.2

表格二：將第 k 項資料換成「極光強度」

請問：

- 跟表格一相比，除了多最後一項以外， b 會出現怎樣的變化？

如果我們知道「體驗」，即顧客對消費過程中的感受，會對銷量會造成影響，但實際上「體驗」卻難以量化：

樣本編號	Y (銷量)	X1 (價格)	X2 (廣告)	...	Xk (體驗)	e (殘差)
1	20	15	3	...	?	2
2	23	14	3	...	?	2.5
...
n	21	15	4	...	?	0.3

表格三：將第 k 項資料換成「體驗」

註：因「體驗」無法量化，此處殘差沿用自表格一。

請問：

- 少了「體驗」這項參數的 b ，可能存在的偏差為何？

以上三個狀況，都是在 Mean Independence 這項假設背後可能存在的問題，而且延續母體和樣本的思考，就連最初的表格也值得我們思考「 b 是否存在偏差」以及「這樣的資料選取是否正確」。由於算出正確的 Estimate 幾乎是 LRM 基本中的基本，從性質和假設出發，培養對偏差的判斷能力非常重要。

Homoskedasticity & Non-autocorrelation

除了 Mean Independence 以外，假設四是否成立會影響分析結果中的 Std. Error，即 Estimate 的分布。由於 Homoskedasticity (*homo* 單一, *skedasticity* 方差性) 假設殘差 ε 的方差 (variance) 不隨 X 變化，且 Non-autocorrelation 假設各 X 間的 ε 不相關，因此，理論上的方差矩陣 $Var(b|X)$ 長得像這樣：

$$Var(b|X) = \sigma^2(X'X)^{-1} = \begin{bmatrix} Var(\beta_1) & 0 & \dots & 0 \\ 0 & Var(\beta_2) & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & Var(\beta_k) \end{bmatrix}$$

將矩陣對角線上所有 $Var(\beta_k)$ 開根號，就會得到分析結果中的 Std. Error。然而，實際上我們預估的 $\widehat{Var(b|X)}$ 却可能面臨（一）方差隨 X 變化，且（二） ε 彼此相關的狀況：

$$\widehat{Var(b|X)} = \Sigma = \begin{bmatrix} Var(b_1) & Cov(\varepsilon_2, \varepsilon_1) & \dots & Cov(\varepsilon_k, \varepsilon_1) \\ Cov(\varepsilon_1, \varepsilon_2) & Var(b_2) & \dots & Cov(\varepsilon_k, \varepsilon_2) \\ \vdots & \vdots & \ddots & \vdots \\ Cov(\varepsilon_1, \varepsilon_k) & Cov(\varepsilon_2, \varepsilon_k) & \dots & Var(b_k) \end{bmatrix}$$

其中 Σ 無法以 $s^2(X'X)^{-1}$ 形式表達。

什麼情況下，分析會違反這兩個假設呢？首先是資料本身的性質。比方說在上面的原始資料裡，「銷量」和「價格」之間的關係就有可能違反 Homoskedasticity：便宜商品的銷量分布（很多到很少），和昂貴商品的銷量分布（少到很少）不同，因此分析結果中的 Std. Error 就可能出現偏差，後續的分析，如 t value、Pr(>|t|)、F-statistic 等等也就不可靠。（不過倒是不會影響回 Estimate，因為 b 偏差與否和 Mean Independence 有關。）

另一種情況，則和資料的分群（cluster）有關。例如，如果原始資料和「地區」有關：

樣本來源	Y (銷量)	X1 (價格)	X2 (廣告)	...	Xk (人流)	e (殘差)
台北	20	15	3	...	180	1
台北	23	14	3	...	170	1.5
...
台中	21	15	4	...	200	1.3

表格四：將「樣本編號」換成「樣本來源」

這時可以看出因為某些樣本來自相同地區，殘差也較有可能彼此相關，而出現某種特徵（pattern），如果用一般的方式計算方差會得到錯誤的 Std. Error。對以上兩個問題的處理方法有興趣的讀者，可以參考這份 University of Maryland 的 [Introduction to Robust and Clustered Standard Errors \(PDF\)](#)；R 的處理方法可以參考這篇 [Easy Clustered Standard Errors in R](#)。

Normality

最後的 Normality 雖然看起來很簡單：就算是在漸進（asymptotic，即樣本數足夠多）的情況下，只要接受這項假設，就能利用不同的分布計算信心區間等；但另一方面，一旦接受了這個假設，我們也能用之前提過的最大似然估計法（MLE）估計 b 。簡略的步驟如下：

1. 利用假設的分布密度函數（pdf）得出特定參數 θ （包含 b 和 s^2 ）的機率函數： $p(y|X=x; \theta)$
2. 連乘機率函數，得 likelihood function： $L(\theta) = \prod_{i=1}^n p(y_i|x_i; \theta)$
3. 對似然函數取自然對數（註），得 log-likelihood function： $\log L(\theta) = \sum_{i=1}^n \log p(y_i|x_i; \theta)$
4. 在 $\log L(\hat{\theta})$ 最大的情況下， $\hat{\theta}$ 即估計結果。

註：這個步驟的理由通常是連加 \sum 比連乘 \prod 更便於計算，詳細的說明可以參考這份 CMU 的 [The Method of Maximum Likelihood for Simple Linear Regression \(PDF\)](#)。

最後的 $\hat{\theta}$ 會包含 b 和 s^2 ，理論上和 OLS 所得出的結果會一樣。雖然在單一模型的情況下，用以上四個步驟代替 lm() 有點多此一舉，但在聯立模型（simultaneous equations models）的情況下，需要用 MLE 方法才能考慮到殘差之間的相關性。

一樣用前面的資料說明，不過這次除了「銷量」以外，我們還得考慮另一個「利潤」的表格：

樣本來源	Y (利潤)	X1 (價格)	X2 (廣告)	...	Xk (人流)	e (殘差)
台北	1.8	15	3	...	180	1.1
台北	2.5	14	3	...	170	0.9
...
台中	1.7	15	4	...	200	1.4

表格五：將「銷量」換成「利潤」

這時，如果我們想估計「利潤」、「銷量」這兩個 Y 和 X 的關係，不能只對這兩個表格分別用 $\text{lm}()$ ，因為兩組殘差 e 之間的關係是不確定的；如果我們也要為兩組 e 建立一個類似 $\text{Var}(b|X)$ 的 covariance matrix，就得用 MLE 一次估計兩組模型，這時的 θ 會包含兩組 b 、兩個 s^2 、和一個 e 間的相關係數 ρ （註）。

註：為了確保估計出來的 s^2 恒正，這邊其實要用到一些特殊方法；一般來說也可以用 e^x 。

本質上，MLE 估計方法有點像在玩拉霸：不斷投入一組 θ ，看得出來的 $\log L(\theta)$ 多大，直到找到最大的 $\log L(\hat{\theta})$ 。這也的確就是網格式參數搜尋（grid-search）的原理，不過我們也可以用一階微分、Newton-Raphson 等方法求出最大值；在 R 裡面，有 `optim()`、`nlsminb()` 等函數可以用來求極值，不過要注意的是大部分的函數只支援求最小值，所以可能需要先將 log-likelihood function 加上負號，求 $-\log L(\theta)$ 的最小值。

MLE 方法裡最核心也最困難的步驟，應該是在前幾步將模型化為 likelihood function，不過，也可以說只要能寫出 likelihood function，MLE 方法可以用來預估各式各樣的模型。所以不只是一般的 LRM，效用函數（utility function）、強化學習（reinforcement learning）等問題也能用 MLE 方法解決。比較可惜的是我們這學期幾乎沒什麼機會自己建構 likelihood function……或許得涉獵一些期刊才能見識 MLE 方法應用之廣。然而為了寫這篇文章我最近是沒什麼空。



延伸學習

學完這麼多東西以後，我的直接感受是用 `lm()`、`glm()` 等函數要注意的事情真多，不能像以前一樣，一看到資料，以為排個 $Y \sim X_1 + X_2 + \dots + X_k$ 下去分析就好；解讀結果的時候，除了瞭解 causal effect，也要注意是否有偏差。當然，如果要精進分析結果，也不能只是盲目嘗試，唯有清楚原理中影響結果的因素，才有改善的空間。總之就是面倒くさいなあ。

具體來說，我覺得學完這門課程之後可以精進的方向有三：

1. 熟練前面的內容

從課前準備開始提到的矩陣運算、統計和機率，到最後的 MLE 都很重要，但老實說我學了一遍、外加參考不少資料，也不太確定自己到底掌握了幾分。考慮到 *Econometrics* 還是偏基礎的科目，想接觸其它分支前，還是得先把上面提到的內容學好。

2. 處理更多樣的資料

前面舉利用的幾個表格是橫截面數據（cross-sectional data），即在特定時間點下的數據，但 *Econometrics* 會面對的資料型態，還包括考慮到時間變化的時間序列（time series data）和縱橫 / 面板數據（panel data）。*Introductory Econometrics* 的中後部分就是在講解後兩者，相信這也是我們下學期 *Advanced Econometrics II* 的重心。

3. 使用更多分析方法

除了 `lm()` 裡包含的基本統計數據以外，依照不同的數據型態，還有不同的 bias 和 variance 取捨所衍生出的分析方法也不同；前者包括 ANOVA、時間序列分析等等，後者包括 Ridge、Lasso 等等，也和後續的降維（dimension reduction）、非線性方法有關，之前推薦過的 An Introduction to Statistical Learning 裡有詳細說明這些進階方法；姊妹書 The Elements of Statistical Learning 更包含背後的數理推導。

結語和勘誤表

落落長的文章到此也差不多該告一個段落。雖然我剛開始寫 McK & Note 的時候，從沒想過自己會寫這樣一篇充滿數學公式的文章，不過在蒐集資料的過程中，我也意識到網路上把這些假設統整起來、寫清楚的文章比較少，所以決定把自己還記得的上課內容都寫一寫，也當作是把 *Econometrics* 複習了一遍。希望這篇文章能為中文讀者填補一些資訊落差，也希望我的講解能讓讀者對 *Econometrics* 產生一些興趣，至少別把它當成艱澀、難懂的知識。

不過，我也清楚這篇文章是個大工程，充滿了公式和標注，即使寫完了也不敢說完全沒有錯誤，所以我在這篇文章最後預留了勘誤表。我還有一段時間要跟 *Econometrics* 打交道，想必偶爾還是會回來讀一讀這篇文章，如果發現有誤，會將修正記錄在這裡；如果讀者發現有任何不清楚的地方，也請不吝指正。

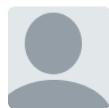
日期	位置	修改前	修改後	原因
'16 Dec 28	五個表格	ε (殘差)	e (殘差)	樣本估計應為 e

攝影地點：JR 金沢駅、飛驒高山、穴水町、JR 新宿駅

感謝雪人、阿飄（飄哥）學長對本文數學公式的技術支援，與許多好友協助測試

[# Cal Poly](#) [# MSBA](#) [# Econometrics](#)

◀ # / (How) I got an offer

[Recommend](#)[Share](#)[從最好的優先排列 ▾](#)

Start the discussion...

ALSO ON MCK & NOTE

/ (How) I got an offer

2 comments • 2個月前•

 Jimmy Lin — 感謝賴董 <(_ _)>**# / CFA IRC 東南亞神秘力量**

2 comments • 8個月前•

 Jimmy Lin — 真假，我來看看！**# / 台中市有多少台高級新車？**

2 comments • 9個月前•

 Jimmy Lin — Exactly.**# / 《經濟學人》學習計畫**

4 comments • 6個月前•



Fu Wei Tsao — 想問Espresso是付費的嗎？

[Subscribe](#)[加入 Disqus 到你的網站](#)[Add Disqus Add](#)[隱私](#)

© 2015 - 2016 ❤ Jimmy Lin

Powered by [Hexo](#) | Theme - [NexT.Muse](#)