

# Lecture 09. Regression Analysis

## 迴歸分析

### Introduction

- 前面所談的，大部份是“分佈”(distribution)。比如，一組資料，來自某一個分佈  $F(\theta)$ ， $\theta$  是 parameter (可以是一個“向量”!) 我們可以根據 data，來對  $F(\theta)$  做一個描述 (description)，比如 mean 是多少，variance 是多少，... 等等。
- 以 Normal distribution 為例： $F(\theta) \equiv N(\mu, \sigma^2)$ ，參數  $\theta = (\mu, \sigma^2)$ ，是 2-dimensional。你關心的是參數向量  $\theta = ?$ ，即  
 $mean(\mu) = ?$ ， $variance(\sigma^2) = ?$   
或者，你給出一個 confidence interval；  
或者，你檢定  $\theta = \theta_0$  (某個  $\theta_0$  值) 是否成立。  
這些主要都在想要了解  $F(\bullet) = ?$
- 再者，在 ANOVA 中，不管是 one-way 或 two-way，背後還是關心幾組的 distribution 是不是一樣。(要看 distribution 是否一樣，最簡單的看法是：先看 mean 一不一樣!)  
但是在 ANOVA 中，還可以引出一個問題：即不同的組 (不同的 treatment)，甚至不同的 block，若有不同的 mean，即是代表 treatment (或甚至 block) 與 outcome variable 之間有一個“關係”存在。不同的 treatment，引出不同的 outcome 平均值；不同的 block，引出不同的平均 outcome,.....。
- 所以，以下便談談“關係”(relationship)。

# Regression

○ 兩個變數，比如  $X$  和  $Y$  之間若有“不同的  $X$  值對應出不同的  $Y$  值”，這種情形（可能）存在，則我們常用一個方程式去描述這種對應關係： $Y = f(x)$ 。

○ 統計上，你看到的多是具有 random error 存在的情形，這個 random error 怎麼來的，有多大？這種問題常無法回答，無論如何，上面的關係式常是以如下的形式呈現：


$$Y = f(x) + \varepsilon$$

○  $\varepsilon$  即是一個 random error。

○ 我們的目標，便是根據 data 來猜測  $f(\bullet) = ?$

○ 這時 data 是什麼呢？Data 就是  $(Y_1, X_1), (Y_2, X_2), \dots, (Y_n, X_n)$ 。根據這  $n$  個 data (sample size =  $n$ )，你能正確的描述出  $f(\bullet)$  嗎？很困難，因為  $f(\bullet)$  是一個函數，你要正確的描述它，你必須把所有可能的  $X$  值所對應出來的  $Y = f(x)$  都描述正確，但這幾乎是不可能的！

○ 例如， $f(\bullet)$  如下圖



實線部份是  $f(\bullet)$ ，而 data 只是 6 個點（“x”的部份），你只看到如上圖(b)的情況。根據圖(b)，你怎麼可能把  $f(\bullet)$  從頭到尾都猜對？

[ continued ]

(i) 由上圖(b) ，你可以有兩個猜測法（比如說！）：

(a) 第一，你可以猜 Y 與 X 的關係是：

$$y = \sqrt{a + bx} \quad (\text{拋物線})$$

然後根據 data 去 estimate a 和 b (parameters)


(b) 第二，你可以猜 Y 與 X 的關係是：

$$y = a + bx \quad (\text{直線})$$

同樣根據 data 去 estimate a & b 。

(ii) 根據 (ii)(a) & (ii)(b) 的 estimates ，你可能可以得到對 Y 和 X 之關

係之兩種估計，示下圖 (a) & (b)



[ continued]

(iii) 在(ii)中，你等於把問題簡化了。即，你雖然不知道真正的答案

$f(\bullet)$ ，但你企圖把問題模式化（即給予一個模式（model））；或者說，你把  $f(\bullet)$  參數化（parameterize），以粗略地求得 Y 與 X 之關係。

(iv) 求得這個參數化後之  $Y=f(x)$  關係有一個好處，即你可以簡單地對不同的 X 值預測其 Y 值（但須注意其“有效範圍”及“可能誤差”！）

(v) (ii)(b)之模式  $y = a + bx$ ，即稱為一個線性模式（linear model 或 linear regression model）。

[continued]

(vi) 你的 data 可能更複雜： $(Y_1, X_1, Z_1), (Y_2, X_2, Z_2), \dots, (Y_n, X_n, Z_n)$ ，

而你建立如下之 model：

$$Y = a + bX + cZ$$

或者，再複雜一點：

$$Y = b_0 + b_1x_1 + b_2x_2 + \dots + b_px_p ,$$

而你的 data 乃是

$$\left. \begin{array}{l} y_1, x_{11}, x_{21}, x_{31}, \dots, x_{p1} \\ y_2, x_{12}, x_{22}, x_{32}, \dots, x_{p2} \\ \vdots \\ \vdots \\ y_n, x_{1n}, x_{2n}, x_{3n}, \dots, x_{pn} \end{array} \right\} \text{共 } n \text{ 個 data}$$

$Y = a + bX$  的模式，叫一個 simple linear regression model，

$Y = \beta_0 + \beta_1X_1 + \dots + \beta_pX_p$ ， $p \geq 2$ ，叫 **multiple linear**

**regression model**。

[continued]

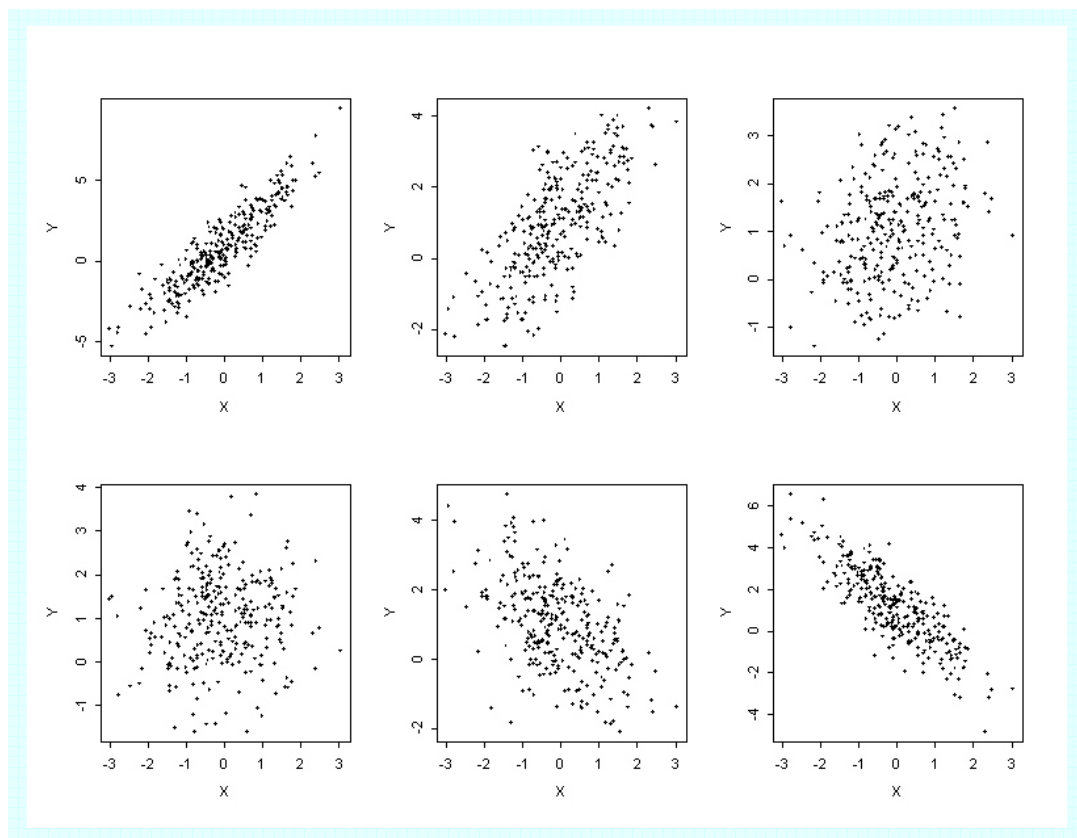
• **Correlation**

(i)  $Y = a + bX$ ，是對 Y-X 關係的一種描述，其關心的是 Y 與 X 之相對變化（即 b 之大小）。

(ii) 你也可以關心 Y-X 關係之“強度”。這種強度，一般用 correlation（相關性）或 correlation coefficient（相關係數）表示，其值一般介於 -1 和 +1 之間。

(iii) Several correlation type: (see below for bivariate-normal case).

A simulated illustration for correlation coefficient=**0.9, 0.7, 0.3, 0,-0.5,-0.8**; based on **300** pairs of observations.




# Regression Model

## • Simple Linear Regression (Model)

$$Y = \beta_0 + \beta_1 X + \varepsilon$$

$$EY = \beta_0 + \beta_1 X \quad (\text{或 } E(Y|X) = \beta_0 + \beta_1 X)$$



即假設真正的 model 為  $EY = \beta_0 + \beta_1 X$ ，或  $\mu_{Y|X} = \beta_0 + \beta_1 X$  意即  
給定  $X$  時，Y 的“期望值” 為  $\beta_0 + \beta_1 X$ ，而你看到的是

$\beta_0 + \beta_1 X + \varepsilon$ ， $\varepsilon$  為 random error 且  $E(\varepsilon) = 0$  [Q1]。

$X$  稱為 regressor，或 independent variable。(常是可被控制的)

$Y$  稱為 response，或 dependent variable，或 outcome variable，……

(關於 Q1)

$E(\varepsilon) = 0$  是必須的；若  $E(\varepsilon) = a \neq 0$ ，(for some “a”)，則  $a$  與  $\beta_0$  不可分辨，可以寫  $\beta_0^* = \beta_0 + a$ ，則仍變成  $E(\varepsilon^*) = 0$ ：

$$EY = \beta_0^* + \beta_1 X + \varepsilon^*$$

### • Other assumptions

(i) X 的測量沒有誤差 (without measurement error)，若 X 的測量有誤差，則上面的 model 便叫做一個有 measurement error 的 regression model，或叫 measurement error model，或叫 error-in-variable (EIV) model，這時問題較複雜。

(ii) x 與  $\varepsilon$  沒有“關係”，或者說  $\text{COV}(x, \varepsilon) = 0$ ，即 x 與  $\varepsilon$  之 *covariance* = 0，covariance 的定義為：

$$\begin{aligned}\text{COV}(x, \varepsilon) &= E\{(x - Ex)(\varepsilon - E\varepsilon)\} \\ &= E(x\varepsilon) - Ex \cdot E\varepsilon\end{aligned}$$

故若  $E\varepsilon = 0$ ，則  $\text{COV}(x, \varepsilon) = E(x\varepsilon)$

(iii)  $Y_1, Y_2, \dots, Y_n$  彼此互相獨立，或


$\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n$  彼此互相獨立。

(iv)  $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n$  之 variance 均等於  $\sigma^2$  (equal variance)

• (iv)'  $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n \sim N(0, \sigma^2)$




(圖形)



## Estimation

根據上圖之 data ( $\otimes$ )，你可能得到一條如下之估計線：

$$\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 X$$



# Estimation


## • Model and Data

$$\begin{cases} \text{Model} & EY = \beta_0 + \beta_1 X \\ \text{Data} & (Y_1, X_1), (Y_2, X_2), \dots, (Y_n, X_n) \end{cases}$$

說明：Model 不是預先設下的，而是根據 data 的“長相”來決定的。


如果畫出 Y-X 的 scatter plot（散布圖），而得如下之“形式”。

（pattern）：



你自然會覺得去 fit 一條直線（ $EY = \beta_0 + \beta_1 X$ ）是合理的。

但是，如果 Y-X（data）的 pattern 是這樣：



則你就該用別的 Model 了！

• [Continued]

## Least Squares (LS) Method

前面所說的  $\hat{Y} = \hat{\beta}_0 + \hat{\beta}_1 X$  這條線是怎樣得到的呢？方法有很多種，其中一種最有名的叫最小平方法（least square method）：

$$Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i, \quad i = 1, 2, \dots, n$$


$$\rightarrow \varepsilon_i = Y_i - (\beta_0 + \beta_1 X_i)$$

$$\rightarrow \sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n [Y_i - \beta_0 - \beta_1 X_i]^2 \equiv L$$

$L$  是一個“總誤差”（total error）的描述量。


想法：

如果 data 長得如下圖所示：



你比較相信這些 data (“x”) 是從  $l_1$  這條線生成的 (generate)，還是從  $l_2$ ？ (ANS: 當然是  $l_1$ )

但  $l_2$  是很容易被排除的 (相較於  $l_1$ )，因為它跟 data 差太多，很容易判別。如果有另一條  $l_2'$  如下，則你要選  $l_1$  還是  $l_2'$  呢？



這時很難選了！


必須有一個“判據” (criterion) 才行！

對於你所可能考慮的任一條線  $l$  而言，data 或觀測值

(observations) 與  $l$  的“縱垂距離” (可以有正負號)，

叫 **residual**，以  $e$  表示。

[continued]



把這些 residual 的平方加總起來得 residual sum of squares :

$$\begin{aligned}\sum_{i=1}^n e_i^2 &= \sum_{i=1}^n [Y_i - \hat{Y}_i]^2 \\ &= \sum_{i=1}^n [Y_i - \hat{\beta}_0 - \hat{\beta}_1 X_i]^2\end{aligned}$$

於是 least squares method 的想法便是考慮這樣的 criterion ; 你所得到的  $\hat{\beta}_0$ ,  $\hat{\beta}_1$  乃是所有可能的  $l$  線中, 使得 residual sum of squares 為最小的 (minimum) !

意思是說, 找到  $\beta_0 = \hat{\beta}_0$  值而  $\beta_1 = \hat{\beta}_1$  值, 使得

$$L = \sum_{i=1}^n [Y_i - \beta_0 - \beta_1 X_i]^2$$

為 minimum 。

[continued]

(i) 解法：

$$\text{解 } \begin{cases} \frac{\partial L}{\partial \beta_0} = 0 \\ \frac{\partial L}{\partial \beta_1} = 0 \end{cases} \quad (\text{這組方程式叫 normal equations})$$

(ii) Normal Equations : (★)

$$\begin{aligned} \frac{\partial L}{\partial \beta_0} = 0 &\Rightarrow \sum 2[Y_i - \beta_0 - \beta_1 X_i] \cdot (-1) = 0 \\ &\Rightarrow \sum [Y_i - \beta_0 - \beta_1 X_i] = 0 \\ \frac{\partial L}{\partial \beta_1} = 0 &\Rightarrow \sum 2[Y_i - \beta_0 - \beta_1 X_i] \cdot (-X_i) = 0 \\ &\Rightarrow \sum X_i [Y_i - \beta_0 - \beta_1 X_i] = 0 \end{aligned}$$

(iii) Solutions :

$$\begin{cases} \sum Y_i - n\beta_0 - \beta_1 \sum X_i = 0 & \dots\dots(1) \\ \sum X_i Y_i - \beta_0 \sum X_i - \beta_1 \sum X_i^2 = 0 & \dots\dots(2) \end{cases}$$

(1) 式  $\times \frac{1}{n} \sum X_i$  得

$$\frac{1}{n} \sum X_i \cdot \sum Y_i - \beta_0 \sum X_i - \beta_1 \cdot \frac{1}{n} (\sum X_i)^2 = 0 \dots\dots(1)'$$

(1)' - (2) 得

$$\beta_1 (\sum X_i^2 - \frac{1}{n} (\sum X_i)^2) + \frac{1}{n} \sum X_i \cdot \sum Y_i - \sum X_i Y_i = 0 \dots\dots(3)$$

解 (3) 式得

$$\hat{\beta}_1 = \frac{\sum X_i Y_i - \frac{1}{n} \sum X_i \cdot \sum Y_i}{\sum X_i^2 - \frac{1}{n} (\sum X_i)^2} \dots\dots(4)$$

[continued]

或分子分母同除以  $n$  :

$$\begin{aligned}\hat{\beta}_1 &= \frac{\frac{1}{n} \sum X_i Y_i - (\frac{1}{n} \sum X_i)(\frac{1}{n} \sum Y_i)}{\frac{1}{n} \sum X_i^2 - (\frac{1}{n} \sum X_i)^2} \\ &\equiv \frac{XY - \bar{X} \cdot \bar{Y}}{X^2 - (\bar{X})^2} \dots\dots\dots(5)\end{aligned}$$

或分子分母同乘以  $n$  :

$$\hat{\beta}_1 = \frac{n \sum X_i Y_i - \sum X_i \cdot \sum Y_i}{n \sum X_i^2 - (\sum X_i)^2} \dots\dots\dots(5)'$$

將 (5) 或 (5)' 代入 (1) 中，可得

$$\hat{\beta}_0 = \frac{1}{n} \sum Y_i - \hat{\beta}_1 \cdot \frac{1}{n} \sum X_i \quad (\text{直接由 (1) 解得})$$

$$= \bar{Y} - \hat{\beta}_1 \cdot \bar{X} \quad (\text{用這個式子即可!})$$

$$= \bar{Y} - \bar{X} \cdot \left( \frac{XY - \bar{X} \cdot \bar{Y}}{X^2 - (\bar{X})^2} \right) \quad (\text{將 (5) 代入})$$

## Model Evaluation (模式之評估)

### General:

模式之評估分兩部份：

- (i) 是迴歸係數之評估
- (ii) 是整個模式的適合性之評估

迴歸係數的評估，指的是迴歸係數的“顯著性”評估，意即迴歸係數

( $\beta_1$ ) 是否顯著地不等於 0 ( $\neq 0$ , significantly) !

整個模式的適合性評估又包括兩部份：


- (a) 模式的“配適程度” (fitness, fits)
- (b) 模式的“診斷” (diagnostics)



$(H_0 : \beta_1=0 \text{ v.s. } H_a : \beta_1 \neq 0)$  [ 單一參數 ]

Idea :

如果  $\beta_1$  顯著地不為 0，則 X 對 Y 才有解釋力（意即 X 的變化與 Y 的變化是有關係的）！ 這時  $\beta_0$  不是重點。  
如果  $\beta_1 = 0$ ，則你看到的 data 便是



如上圖，沒有什麼 pattern !

$$\begin{aligned} Y_i &= \beta_0 + 0 \cdot X_i + \varepsilon_i \\ &= \beta_0 + \varepsilon_i \end{aligned}$$

## Test statistic

Under  $H_0$ ,

$$\frac{\hat{\beta}_1 - 0}{\sqrt{\text{var } \hat{\beta}_1}} \equiv \frac{\hat{\beta}_1}{\sigma_{\hat{\beta}_1}} \sim N(0, 1)$$

$\sigma_{\hat{\beta}_1}$  裡有  $\sigma^2[\varepsilon \sim N(0, \sigma^2)]$ ，但  $\sigma$  為 unknown，要用一個“代替品” ( $\hat{\sigma}$ )，將這個估計子  $\hat{\sigma}$  放入  $\sqrt{\text{var } \hat{\beta}_1}$  ( $\equiv \sigma_{\hat{\beta}_1}$ ) 裡時，記為  $S_{\hat{\beta}_1}$ ，結果是

$$\frac{\hat{\beta}_1}{S_{\hat{\beta}_1}} \sim t_\nu, \quad \nu = n - 2$$

sample size                  參數個數 (參數:  $\beta_0, \beta_1$ )

在這裡  $\sigma_{\hat{\beta}_1} \equiv \sqrt{\text{var } \hat{\beta}_1}$  叫做  $\hat{\beta}_1$  的 standard error (標準誤)！

**Note:** ( $\hat{\beta}_1$  的期望值與 confidence interval)

(a)  $E\hat{\beta}_1 = \beta_1$  (true value); that means the so obtained **least square estimator** is **unbiased** !!

(b)  $\hat{\beta}_1$  的  $100(1-\alpha)\%$  省略，但若此 **CI** 包含 0，則表示不能 reject  $H_0: \beta_1 = 0$ 。

## Extension (★)

對 Multiple regression  $EY = \beta_0 + \beta_1 X_1 + \dots + \beta_p X_p$ ,

我們要做的是兩件事：

$$(i) \quad \left. \begin{array}{l} H_0 : \beta_1 = 0 \\ H_0 : \beta_2 = 0 \\ \vdots \\ H_0 : \beta_p = 0 \end{array} \right\} \text{分別一個一個看 v.s.} \left\{ \begin{array}{l} H_a : \beta_1 \neq 0 \\ H_a : \beta_2 \neq 0 \\ \vdots \\ H_a : \beta_p \neq 0 \end{array} \right.$$

$$(ii) \quad H_0 : \beta_1 = \beta_2 = \beta_3 = \dots = \beta_p = 0 \quad (\text{一起看!}) \quad \text{v.s.} \\ H_a : \text{至少有一個 } \beta_j \neq 0$$

[ → 至少有一個  $X_j$  可以解釋  $Y$  ]

對於(i)，我們得到的是個別的（分別對  $\beta_1 = 0, \beta_2 = 0, \dots, \beta_p = 0$  之 test）檢定統計量  $t_1, t_2, \dots, t_p$ 。

對於 (ii) 我們會得到一個 F 統計量  $F_{a,b}$ ：

$$\begin{cases} a = p \\ b = n - p - 1 \end{cases}$$

•  $R^2$  ; R-square

$R^2$  值又稱判定係數 (coefficient of determination)，是模式配適程度的一個指標，其定義及導出如下：

$$Y_i - \bar{Y} = (Y_i - \hat{Y}_i) + (\hat{Y}_i - \bar{Y})$$
$$\Rightarrow \sum (Y_i - \bar{Y})^2 = \sum (Y_i - \hat{Y}_i)^2 + \sum (\hat{Y}_i - \bar{Y})^2 + 2\sum (Y_i - \hat{Y}_i)(\hat{Y}_i - \bar{Y})$$

可以證明第三項 = 0，則：

Total sum of squares : (TSS)

$$\sum (Y_i - \bar{Y})^2 = \sum (Y_i - \hat{Y}_i)^2 + \sum (\hat{Y}_i - \bar{Y})^2 = RSS + MSS$$

$\bar{Y}$  是一個不變的東西 ( $\because$  data 已知)， $\hat{Y}_i$  是你估的，如果你定的模式不離譜， $\hat{Y}_i$  跟真正的  $EY_i = \beta_0 + \beta_1 X_i$  應該很接近，則  $\sum (\hat{Y}_i - \bar{Y})^2$  即表示來自於 model 的 sum of squares。剩下的 sum of squares 來自 random error  $\varepsilon_i$ ，故  $(Y_i - \hat{Y}_i)^2$  是模式沒辦法解釋的部份。 $R^2$  的定義為

$$R^2 = \frac{\sum (\hat{Y}_i - \bar{Y})^2}{\sum (Y_i - \bar{Y})^2} = 1 - \frac{\sum (Y_i - \hat{Y}_i)^2}{\sum (Y_i - \bar{Y})^2}$$
$$= 1 - \frac{RSS}{TSS}$$
$$= \frac{MSS}{TSS}$$

## Residual and Residual plot: predicted Y vs. residual (★)

$Y_i - \hat{Y}_i$  稱為 residual。

Residual 裡涵有許多在 model fitting 背後未知的訊息 (information)，

比如，若模式正確，則  $Y_i - \hat{Y}_i (\equiv e_i)$  對  $\hat{Y}_i$  的 plot 應該呈現隨機

分佈的情形 (沒有 pattern)。(\*\*)

如果有 pattern，則表示模式不正確，應重新考慮。

這個 plot，就叫 residual plot ! [ 其他還有很多 diagnostic 的方法 ]

**[\*\*]: This can be easily justified through ‘matrix algebra’ and calculations, and is left as a homework.]**

### Example:

```
Model: model ln_x51=ind1trsf ind2trsf ind_age x16 ind_op
      ind_ISS ind_GCSM ind_RTS/include=2 selection=b;
```

R-square=0.35.6

Variable	Parameter Estimate	Standard Error	Type II Sum of Squares	F	Prob>F
INTERCEP	10.61327698	0.08701823	10083.72635057	14875.7	0.0001
IND1TRSF	0.13118413	0.08299391	1.69360722	2.50	0.1145
IND2TRSF	0.55302609	0.09147250	24.77722443	36.55	0.0001
IND_OP	1.03361976	0.07889542	116.34844882	171.64	0.0001
IND_ISS	0.24761664	0.07766036	6.89133643	10.17	0.0015
IND_RTS	0.39342036	0.07527863	18.51453307	27.31	0.0001

	DF	Sum of Squares	Mean Square	F	Prob>F
Regression	5	203.62886430	40.72577286	60.08	0.0001
Error	543	368.08013585	0.67786397		
Total	548	571.70900015			

## The estimation of $\sigma^2$ (★)

設 model 
$$\begin{cases} Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i, \\ EY = \beta_0 + \beta_1 X, \end{cases}$$

Error term  $\varepsilon \sim N(0, \sigma^2)$

$$\varepsilon_i = Y_i - (\beta_0 + \beta_1 X_i)$$

Residual 
$$\begin{aligned} e_i &\equiv Y_i - \hat{Y}_i \\ &= Y_i - (\hat{\beta}_0 + \hat{\beta}_1 X_i) \end{aligned}$$

便形成用來“類比”  $\varepsilon_i$  的量。考慮以下對  $\sigma^2$  的一個估計方式：

$$\hat{\sigma}^2 = \frac{\sum (Y_i - \hat{\beta}_0 - \hat{\beta}_1 X_i)^2}{n-2}$$

這個估計式 (estimator) 是對  $\sigma^2$  的一個 **unbiased estimator**。亦即

$$E\hat{\sigma}^2 = \sigma^2$$

## Standard error (★)

標準誤 (standard error) 是對估計式 (estimator) 之精確度 (precision) 的一個描述 [in fact, the standard error is the “standard deviation” of the **sampling distribution** of the estimator], 一般即定為估計式之變異數之平方根, 以前文之  $\hat{\beta}_1$  為例, 標準誤等於  $\sqrt{Var(\hat{\beta}_1)}$ 。但這個 standard error 裡含有  $\sigma^2$ , 是 unknown 的, 所以一般便對這個  $\sigma^2$  給出一估計, 將  $\hat{\sigma}^2$  代入  $\sqrt{Var(\hat{\beta}_1)}$  中 (或即代入  $Var(\hat{\beta}_1)$  中)。此時不寫  $Var(\hat{\beta}_1)$ , 而寫成  $\hat{V}ar(\hat{\beta}_1)$ , 代表  $Var(\hat{\beta}_1)$  中仍有未知的成分是用其估計式代入的。

## 矩陣運算 (via matrix algebra) (★)

前述之估計方法若改用矩陣 (matrix) 的運算方式來表達，一切將變得  
得更簡單：

$$\begin{pmatrix} Y_1 \\ \vdots \\ Y_n \end{pmatrix} = \begin{pmatrix} \beta_0 + \beta_1 X_1 \\ \vdots \\ \beta_0 + \beta_1 X_n \end{pmatrix} + \begin{pmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{pmatrix}$$

$$\Leftrightarrow Y = X\beta + \varepsilon, \quad X = \begin{pmatrix} 1 & X_1 \\ 1 & X_2 \\ \vdots & \vdots \\ 1 & X_n \end{pmatrix}, \quad \beta = \begin{pmatrix} \beta_0 \\ \beta_1 \end{pmatrix}, \quad \varepsilon = \begin{pmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{pmatrix}$$

最小平方估計式  $\hat{\beta} = \begin{pmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \end{pmatrix} = (X'X)^{-1}X'Y$ ，而

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



## Prediction

當你估計出了  $\hat{\beta}_0$  及  $\hat{\beta}_1$  後，你可以針對任一“合理範圍內”之  $X$  值來預測  $Y$  值 (Q2)。但是這又分成兩部份：

因對一給定之  $X = x_p$ ， $Y$  可以有一個變動的範圍，其 variance 是  $\sigma^2$  ( $\sigma^2$  可以用  $\hat{\sigma}^2$  代替)。


我們可以預測兩樣東西，一是  $Y$  的 mean，二是  $Y$  的個別值，對於這

兩種情況，均說為“預測  $\hat{Y}_p = \hat{\beta}_0 + \hat{\beta}_1 X_p$  ”。

---

## On Q2

所謂“合理的範圍”指的是  $X_p$  不能離



“用來得到  $\hat{Y}$  的那些  $x$  值(以  $\{X\}$  表示)” 太遠。

**(continued)**

更精確地說，應該是“給定  $X = x_p$ ，利用  $\hat{\beta}_0$  及  $\hat{\beta}_1$ ，來預測 Y 之 mean、或預測 Y 之單一觀察值”！

所謂預測，就是給出一個  $100(1 - \alpha)\%$  CI。我們可以使用矩陣運算

符號很簡單地導出預測式。我們先給出其公式：

**預測 mean Y**

$$\hat{y} \pm t_{n-2, 1-\alpha/2} \cdot \hat{\sigma} \sqrt{\frac{1}{n} + \frac{(x_p - \bar{x})^2}{\sum (x_i - \bar{x})^2}}$$

**Derivation: see the next page!**

**預測單一的 Y**

**(variance=預測 mean Y 時之 variance+ $\sigma^2$ )**

$$\hat{y} \pm t_{n-2, 1-\alpha/2} \cdot \hat{\sigma} \sqrt{1 + \frac{1}{n} + \frac{(x_p - \bar{x})^2}{\sum (x_i - \bar{x})^2}}$$

顯然，這裡多出了一個  $\hat{\sigma}^2$ ！這可以理解。其餘的部分請參看本章之 Appendix 1.

## Appendix 1 of Regression (★)

It can be shown by **standard argument** that, for a sample size  $n$  (not necessarily to be large),

$$\frac{\hat{y} - E(\hat{y})}{\{\text{Var}(\hat{y})\}^{1/2}} \sim N(0,1),$$

provided the design matrix is 'regular' (spread out very uniformly!). Because  $\hat{y} = X\hat{\beta}$ , and  $E(\hat{y}) = X E(\hat{\beta})$ ;  $\hat{\beta} = (X'X)^{-1}X'Y$ ,  $E(\hat{\beta}) = (X'X)^{-1}X'E(Y) = (X'X)^{-1}X'X\beta = \beta$ . So,  $E(\hat{y}) = X\beta = E\hat{y}$ . The previous expression is equivalent to

$$\frac{\hat{y} - E(\hat{y})}{\{\text{Var}(X\hat{\beta})\}^{1/2}} \sim N(0,1).$$

It should be noted that, for calculating the variance at the denominator,  $X$  must be replaced by  $X_p = (1, x_p)'$  because the prediction is implemented **on the value of  $x_p$** . Moreover,  $\text{Var}(X\hat{\beta}) = X \text{Var}(\hat{\beta})X'$ . So, for the value of  $x = x_p$ , we need to calculate  $(1, x_p) \text{Var}(\hat{\beta}) (1, x_p)' = \sigma^2 (1, x_p)(X'X)^{-1}(1, x_p)'$ , due to  $\text{Var}(\hat{\beta}) = (X'X)^{-1}\sigma^2$ .

From a previous context,

$$(X'X)^{-1} = \frac{1}{n \sum x_i^2 - (\sum x_i)^2} \begin{pmatrix} \sum x_i^2 & -\sum x_i \\ -\sum x_i & n \end{pmatrix}.$$

So we have

$$\begin{aligned} (1, x_p)(X'X)^{-1}(1, x_p)' &= \frac{\sum x_i^2 - 2x_p \sum x_i + nx_p^2}{n \sum x_i^2 - (\sum x_i)^2} \\ &= \dots = \frac{1}{n} + \frac{(x_p - \bar{x})^2}{\sum (x_i - \bar{x})^2}. \end{aligned}$$

I left the part "... " as an exercise for the reader. Because  $\sigma$  should be substituted by its consistent estimator  $\hat{\sigma} = \hat{\sigma}_{\beta_0, \beta_1}$ , the sampling distribution is no longer Gaussian, but  $t$ -distribution on  $n - 2$  degrees of freedom.


## Example of SAS Code

```
data lbw;
  infile 'd:\class\biostat_under_2004\SAS_lab\lab08_infant.dat';
  input headcirc length gestage birthwt momage toxemia;

proc print;
run;

proc reg graphics;
  model headcirc=gestage/cli;
  plot headcirc*gestage/conf95 pred95;
run;

proc reg graphics;
  model length=gestage/cli;
  plot length*gestage/conf95 pred95;
run;
```



## Correlation: the bivariate normal distribution (★)

$X$  與  $Y$  兩個變數的相關強度可以用 correlation coefficient (相關係數) 來表示，先假設  $X, Y$  是 jointly normal (聯合常態分佈)。此時，固定任一  $X$  值來看， $Y$  均是常態分佈；相反的，固定任一  $Y$  值， $X$  也均是常態分佈，且假設其變異數分別為  $\sigma_Y^2$ 、 $\sigma_X^2$ 。

### Formulae: Bivariate Normal Distribution

$$f(X_1, X_2) = \frac{1}{2\pi\sigma_1\sigma_2\sqrt{1-\rho^2}} \exp \left\{ \frac{-1}{2(1-\rho^2)} \left[ \frac{(X_1-\mu_1)^2}{\sigma_1^2} + \frac{(X_2-\mu_2)^2}{\sigma_2^2} - 2\rho \frac{(X_1-\mu_1)(X_2-\mu_2)}{\sigma_1\sigma_2} \right] \right\}$$

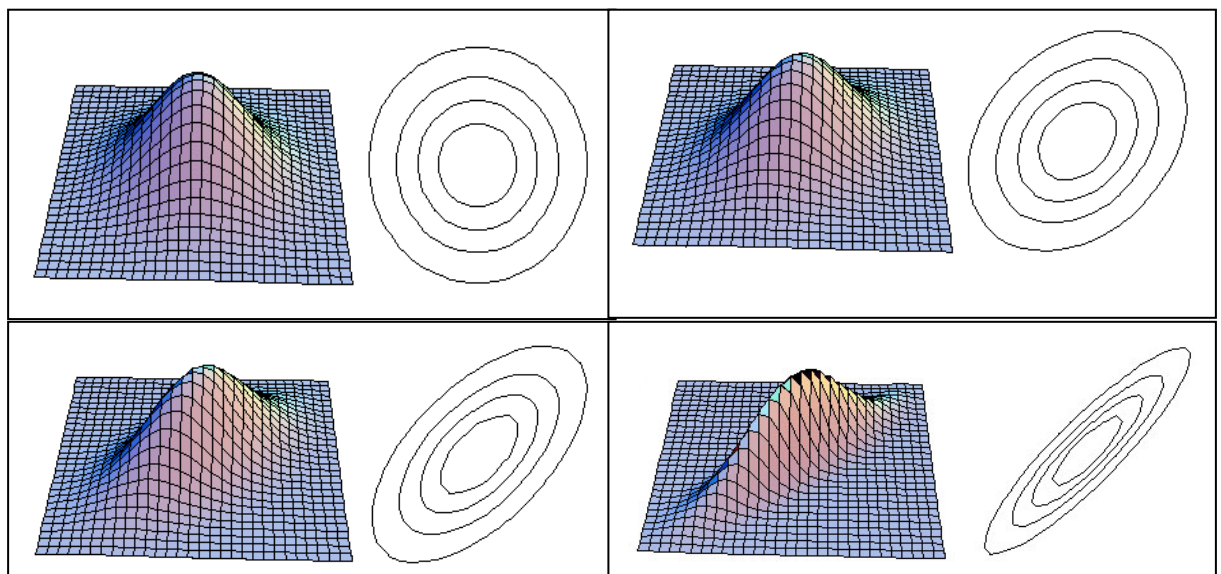
### Formulae: Multivariate Normal Distribution

- There is a vector  $\mu = [\mu_1, \dots, \mu_N]$  and a symmetric, [positive semi-definite covariance matrix](#)  $\Sigma$  ( $N \times N$  matrix) such that  $X$  has density

$$f_X(x_1, \dots, x_N) = \frac{1}{(2\pi)^{N/2} |\Sigma|^{1/2}} \exp \left( -\frac{1}{2} (x - \mu)^\top \Sigma^{-1} (x - \mu) \right)$$

where  $|\Sigma|$  is the [determinant](#) of  $\Sigma$ . Note how the equation above reduces to that of the univariate [normal distribution](#) if  $\Sigma$  is a scalar (i.e., a real number). The vector  $\mu$  in these conditions is the [expected value](#) of  $X$  and the matrix  $\Sigma = AA^\top$  is the [covariance matrix](#) of the components  $X_i$ .

**Figures: Bivariate Normal Distribution,  $\rho=0, 0.3, 0.6, 0.9$ .**



## Pearson's correlation coefficient

定義

$$\rho_{XY} = \frac{\text{Cov}(X, Y)}{\sqrt{\text{Var}X} \cdot \sqrt{\text{Var}Y}}$$

**Note:** If the data is not ranked data instead of continuously distributed, the **Spearman's rank correlation** is used.

Definition of the rank correlation has the same mathematical form, but with original X and Y replaced by ranks.

### 與迴歸係數之關係 (★)

$$Y_i = \beta_0 + \beta_1 X_i + \varepsilon_i, \quad \varepsilon \sim N(0, \sigma^2)$$

$$\bar{Y} = \beta_0 + \beta_1 \bar{X} + \bar{\varepsilon}, \quad \bar{\varepsilon} \approx E\varepsilon = 0$$

$$\Rightarrow Y_i - \bar{Y} \approx \beta_1 (X_i - \bar{X})$$

$$\Rightarrow \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{n} \approx \beta_1 \frac{\sum (X_i - \bar{X})^2}{n}$$

$$\Rightarrow \hat{\beta}_1 = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y}) / n}{\sum (X_i - \bar{X})^2 / n}$$

$$\begin{aligned} &= \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y}) / n}{\sqrt{\sum (X_i - \bar{X})^2 / n} \sqrt{\sum (Y_i - \bar{Y})^2 / n}} \cdot \frac{\sqrt{\sum (Y_i - \bar{Y})^2 / n}}{\sqrt{\sum (X_i - \bar{X})^2 / n}} \\ &= \hat{\rho}_{XY} \cdot \frac{\hat{\sigma}_Y}{\hat{\sigma}_X} \end{aligned}$$

[Note that  $R^2 = (\hat{\rho}_{XY})^2$  in simple regression !!]

## Multiple Regression (多變數迴歸) (★)

### Model

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \cdots + \beta_p X_{pi} + \varepsilon_i, \quad \varepsilon_i \sim N(0, \sigma^2), \quad i=1,2,\dots,n$$

$X_1, X_2, \dots, X_p$  乃是用來解釋  $Y$  的可能結果 (outcome) 的一組解

釋變數，一位研究者 (investigator) 應當儘可能地收集可以解釋

outcome  $Y$  的解釋變數  $X$ s。

遺漏了重要的  $X$ ，會使得估計結果有所偏差 (biased) ！



## Estimation : Least Square (LS) Method

$$\text{令 } L = \sum_{i=1}^n (Y_i - \beta_0 - \beta_1 X_{1i} - \beta_2 X_{2i} - \cdots - \beta_p X_{pi})^2$$

$$\text{解 } \frac{\partial L}{\partial \beta_j} = 0, \quad j=0,1,2,\dots,p, \text{ 得 } \hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_p,$$

## Testing

(i) 個別參數之檢定：

$$\begin{cases} H_0 : \beta_j = 0 & (\text{or } \beta_j = \beta_{j0}) \text{ v.s.} \\ H_a : \beta_j \neq 0 & (\text{or } \beta_j \neq \beta_{j0}) \end{cases}$$

$$\frac{\hat{\beta}_j - 0}{S_{\hat{\beta}_j}} \sim t_{n-(p+1)} \quad (\because \beta_{j0} = 0)$$

(ii) 模式顯著性檢定 (F-test)：


$$\begin{cases} H_0 : \beta_1 = \beta_2 = \cdots = \beta_p = 0 & \text{v.s.} \\ H_a : \beta_j \neq 0, \quad \text{for some } j \end{cases}$$

建構出一個統計量  $F_n(Y, X) \sim F$  分佈  $\equiv F_{a,b}$

$$d.f. \begin{cases} a = p \\ b = n - p - 1 \end{cases}$$

## Diagnostics

一個初步的診斷 (diagnostic) 方式是做  $\hat{Y}_i$  對  $e_i$  的散佈圖 (scatter plot) :



如果前面關於迴歸的假設 (Equal variance, normality, ...) 為正確的，則  $\hat{Y}_i$  應與  $e_i$  為 uncorrelated，則其 scatter plot 應沒有什麼 pattern (即非常 random)。反之若呈現某種 pattern (如上圖，是弓形)，表示有重要的 information 遺漏了，或變數搜集不足，或變數函數形式不對...

## $R^2$ ; multiple correlation coefficient

$$R^2 \equiv \frac{\sum (\hat{Y}_i - \bar{Y})^2}{\sum (Y_i - \bar{Y})^2}$$

## 迴歸係數之解釋

$\beta_1$  表當  $X_2, X_3, \dots; X_p$  固定時,  $X_1$  變動一個單位,  $Y$  的 mean 將變動  $\beta_1$  個單位。

( $\beta_2, \beta_3, \dots, \beta_p$  之意義仿之!)

## Confounding, 干擾 (★)

當 true model 是  $EY = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p$ , 而你卻遺漏了一個重要變數 (比如  $X_p$ ) 時, 則你將會 fit 如下之 model:

$$EY = b_0 + b_1 X_1 + b_2 X_2 + \dots + b_{p-1} X_{p-1}$$

此時, 你得到的估計式 (LSE),  $\hat{b}_j$  將會是 biased 的, 即

$E\hat{b}_j \neq \beta_j$ 。我們說此 bias 的大小為

$$\beta_j - E\hat{b}_j$$

而 Mean Square Error (MSE) = bias<sup>2</sup> + variance

$$= (\beta_j - E\hat{b}_j)^2 + \text{Var}(\hat{b}_j) \quad (*)$$

所以, 若  $X_p$  是一個重要的解釋變數而被你遺漏時, 其他變數的參數估計會有 bias 產生。(Q: 如何評估?)

若 bias 很嚴重, 我們稱  $X_p$  是  $(X_1 \dots X_{p-1})$  與  $Y$  之關係的一個干擾因子。故  $X_p$  一定要納入迴歸模式中, 以避免干擾 (i.e.: 避免 bias)

( \* )

$$\begin{aligned}MSE &\equiv E\{(\hat{b}_j - \beta_j)^2\} \\&= E\{(\hat{b}_j - E\hat{b}_j + E\hat{b}_j - \beta_j)^2\} \\&= E\{(\hat{b}_j - E\hat{b}_j)^2 + 2(\hat{b}_j - E\hat{b}_j)(E\hat{b}_j - \beta_j) + (E\hat{b}_j - \beta_j)^2\}\end{aligned}$$

↓

(1)

↓

(2)

↓

(3)

$$= E\{(1) + (2) + (3)\}$$

$$= \text{Var}(\hat{b}_j) + E(2) + E(3), \text{ 但 } E(3) = (3)$$

又，

$$E(2) = 2(E(\hat{b}_j) - \beta_j) \cdot E(\hat{b}_j - E\hat{b}_j) = 0 \quad (\because E(\hat{b}_j - E\hat{b}_j) = 0)$$

$$= \text{Var}(\hat{b}_j) + (\text{bias})^2$$

## 分部相關，partial correlation (★)

如果真正的 model 是

$$EY = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \cdots + \beta_p X_p$$

比如  $p=2$ ，而你卻 fit  $EY = b_0 + b_1 X_1$ ，根據你所相信的 model

(只有  $X_1$  對  $Y$  有解釋力)，計算出  $Y$  與  $X_1$  之 correlation coefficient

為  $\hat{\rho}_{Y, X_1}$ 。這個  $\hat{\rho}_{Y, X_1}$  事實上是 biased 的，即它並非反映真正的

的  $Y$  與  $X_1$  之關係。如前，你並未“控制干擾”(control the

confounding)。要達到控制干擾：

(i) 做迴歸，即必須做

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \cdots + \beta_p X_{pi} + \varepsilon_i$$

(ii) 求 correlation，即須求  $\rho_{Y, X_1 | X_2, \dots, X_p}$ 。

此時  $\beta_1$  即  $X_2, \dots, X_p$  固定時， $X_1$  改變一個單位， $Y$  之 mean 改變

幾個單位，而  $\rho_{Y, X_1 | X_2, \dots, X_p}$  即  $X_2, \dots, X_p$  固定時， $X_1$  與  $Y$

之 correlation，叫做 **partial correlation (coefficient)**。

用 regression 做兩組 data 之 mean 之比較(★)

$$\text{設 } \left. \begin{array}{l} X_{11}, \dots, X_{1n_1} \sim N(\mu_1, \sigma^2) \\ X_{21}, \dots, X_{2n_2} \sim N(\mu_2, \sigma^2) \end{array} \right\} X_{1\bullet} \text{ 與 } X_{2\bullet} \text{ 獨立。}$$

要看  $\mu_1$  是否等於  $\mu_2$  ( $H_0: \mu_1 = \mu_2$  v.s.  $H_a: \mu_1 \neq \mu_2$ ) 可以這樣

做：


$$\left\{ \begin{array}{l} Y_1 = X_{11} \\ Y_2 = X_{12} \\ \vdots \\ Y_{n_1} = X_{1n_1} \end{array} \right\} \text{ Group 1} \quad = \beta_0 + \beta_1 \left\{ \begin{array}{l} X_1 = 0 \\ X_2 = 0 \\ \vdots \\ X_{n_1} = 0 \end{array} \right\} \text{ Group 1}$$

$$\left\{ \begin{array}{l} Y_{n_1+1} = X_{21} \\ Y_{n_1+2} = X_{22} \\ \vdots \\ Y_{n_1+n_2} = X_{2n_2} \end{array} \right\} \text{ Group 2} \quad \left\{ \begin{array}{l} X_{n_1+1} = 1 \\ X_{n_1+2} = 1 \\ \vdots \\ X_{n_1+n_2} = 1 \end{array} \right\} \text{ Group 2}$$

對上面  $n (= n_1 + n_2)$  個 data  $(Y_1, X_1), \dots, (Y_{n_1}, X_{n_1}), (Y_{n_1+1}, X_{n_1+1}), \dots, (Y_n, X_n)$

做 simple linear regression, 看  $H_0: \beta_1 = 0$  v.s.  $H_a: \beta_1 \neq 0$

以圖形表示, 如果  $\beta_1 \neq 0$  表示下兩組人之 mean 有差異



如果  $\beta_1 = 0$ , 則表示上面的兩組人之 mean 沒有差異。

用 regression 作 one-way ANOVA (→ two-way 呢?) (★)

假設有 3 組人：

$$\begin{cases} X_{11}, \dots, X_{1n_1} \sim N(\mu_1, \sigma^2) \\ X_{21}, \dots, X_{2n_2} \sim N(\mu_2, \sigma^2) \\ X_{31}, \dots, X_{3n_3} \sim N(\mu_3, \sigma^2) \end{cases}$$

令

$$\begin{cases} Y_1 = X_{11} \\ Y_2 = X_{12} \\ \vdots \\ Y_{n_1} = X_{1n_1} \\ Y_{n_1+1} = X_{21} \\ Y_{n_1+2} = X_{22} \\ \vdots \\ Y_{n_1+n_2} = X_{2n_2} \\ Y_{n_1+n_2+1} = X_{31} \\ \vdots \\ Y_{n_1+n_2+n_3} = X_{3n_3} \end{cases} = \beta_0 + \beta_1 \begin{cases} X_{11} = 0 \\ X_{12} = 0 \\ \vdots \\ X_{1n_1} = 0 \\ X_{1,n_1+1} = 1 \\ X_{1,n_1+2} = 1 \\ \vdots \\ X_{1,n_1+n_2} = 1 \\ X_{1,n_1+n_2+1} = 0 \\ \vdots \\ X_{1,n_1+n_2+n_3} = 0 \end{cases} + \beta_2 \begin{cases} X_{21} = 0 \\ X_{22} = 0 \\ \vdots \\ X_{2n_1} = 0 \\ X_{2,n_1+1} = 0 \\ X_{2,n_1+2} = 0 \\ \vdots \\ X_{2,n_1+n_2} = 0 \\ X_{2,n_1+n_2+1} = 1 \\ \vdots \\ X_{2,n_1+n_2+n_3} = 1 \end{cases}$$

則  $H_0: \mu_1 = \mu_2 = \mu_3 \quad \equiv \quad H_0': \beta_1 = \beta_2 = 0$



## Dummy Variable Technique

前兩節中對解釋變數的設定是一種“技巧”，這種變數叫 dummy variable（啞變數）。

若定第 1 組人為 baseline（基準組）， $\beta_1$  代表的數便是第 2 組人與第 1 組人之關係； $\beta_3$  代表的則是第 3 組與第 1 組之關係。

### SAS-example for coding dummy variables:

```
data transf;
  infile 'd:\Dr_ChenRayJ\transfer\work1230.csv' dlm="," missover;
  input id $ name $ sex age ind_age lag $ ind_lag $ ind2_lag $
        x9 x10 $ x11-x21 GCSM ind_GCSM ind_RTS x25-x36 ISS X38 surv x40-x51 transfer;
        if sex="." then delete;
        xx=x9-transfer; /* to check whether or not x9=x52 */
  ind_trsf=(transfer=1); /* indicator variable for direct/indirect transfer */
  ind1trsf=(transfer=2); /* dummy variable 1 for transfer */
  ind2trsf=(transfer=3); /* dummy variable 2 for transfer */
  ln_x51=log(x51);
  RTS=0.93678*((x13>3)+(x13>5)+(x13>8)+(x13>12))+
       0.7326*((x16>0)+(x16>49)+(x16>75)+(x16>89))+
       0.2908*((x19>0)+(x19>5)+(x19>9)+(x19>29));
  ind_ISS=(ISS>=25);
  ind_age=(age>=40);
  ind_op=(x41>=1);
data temp; set transf; /* keep id name sex age iss ind_iss surv; */
proc sort; by surv ind_ISS iss;
proc print; run;
```

	x51	transfer	xx	indtrsf	ind1trsf	ind2trsf	lnx51	RTS	indISS	indop
27364	1	0	1	0	0	0	10.2170	7.54992	0	0
11462	1	0	1	0	0	0	9.3468	7.54992	0	0
114158	1	0	1	0	0	0	11.6453	7.54992	0	1
44125	3	0	0	0	1	0	10.6948	7.54992	0	0
12034	1	0	1	0	0	0	9.3955	7.54992	0	0
151345	1	0	1	0	0	0	11.9273	7.54992	0	1
485189	1	0	1	0	0	0	13.0923	4.73958	0	1
15630	1	0	1	0	0	0	9.6569	7.54992	0	0
61153	1	0	1	0	0	0	11.0211	7.54992	0	1
68333	1	0	1	0	0	0	11.1321	5.67636	0	0
110923	2	0	0	1	0	0	11.6166	7.54992	0	1
204101	2	0	0	1	0	0	12.2264	4.73958	0	1
349940	2	0	0	1	0	0	13.6529	4.80396	0	1

## Interaction (交互作用) (★)

### Model (2-variable)

$$EY = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_{12} X_1 \cdot X_2$$

當  $\beta_{12} \neq 0$ ，叫  $X_1$  與  $X_2$  之間有 interaction。

### Slope dummy

假設  $X_2$  只有兩種可能：
$$X_2 = \begin{cases} 0 \\ 1 \end{cases}$$

則當  $X_2 = 0$  時，

$$E(Y | X_2 = 0) = \beta_0 + \beta_1 X_1 + 0 + 0$$

當  $X_2 = 1$ ，

$$E(Y | X_2 = 1) = \beta_0 + \beta_1 X_1 + \beta_2 + \beta_{12} X_1$$

∴ 固定，(i) 在  $X_2 = 0$  時， $X_1$  改變一個單位， $EY$  改變  $\beta_1$ 。

(ii) 在  $X_2 = 1$  時， $X_1$  改變一個單位， $EY$  改變  $\beta_1 + \beta_{12}$ 。

### Interaction 之意義

$X_1$  在不同之  $X_2$  值時，其對  $Y$  的“解釋力”不同！

## A two-variable example

給定 Table 11.2.2 & Table 11.2.3 (課本), 設 fitted model 為

$$\hat{y}_i = 6.21 + 1.03X_{1i} + 41.3X_{2i} + 22.7X_{3i} - 0.703X_{1i} \cdot X_{2i} - 0.510X_{1i} \cdot X_{3i}$$

且有一個 computer output 為 figure 11.2.5 (課本), 問:

- (i) 如何描述  $X_1$  的 effect ( $X_1 = \text{age}$ ) ?
- (ii) 如何描述  $X_1$  treatment 的 effect ?
- (iii) Age 與 treatment 是否有 interaction ?