

تقدير تباين المجتمع او S^2 او MSe او $\hat{\sigma}^2$

لدينا مجموع المربعات الخطاء هو

$$\begin{aligned}
 \Rightarrow SS_e &= \sum_{i=1}^n (e - \bar{e})^2 = \sum_{i=1}^n e_i^2 = \underline{e}' \underline{e} \\
 &= (\underline{y} - \hat{\underline{y}})'(\underline{y} - \hat{\underline{y}}) \\
 &= (\underline{y}' - \hat{\underline{\beta}}' \underline{X}')(\underline{y} - \underline{X} \hat{\underline{\beta}}) \\
 &= \underline{y}' \underline{y} - \underline{y}' \underline{X} \hat{\underline{\beta}} - \hat{\underline{\beta}}' \underline{X}' \underline{y} + \hat{\underline{\beta}}' \underline{X}' \underline{X} \hat{\underline{\beta}} \\
 &= \underline{y}' \underline{y} - 2\hat{\underline{\beta}}' \underline{X}' \underline{y} + \hat{\underline{\beta}}' \underline{X}' \underline{X} \hat{\underline{\beta}} \\
 &= \underline{y}' \underline{y} - 2\hat{\underline{\beta}}' \underline{X}' \underline{y} + \hat{\underline{\beta}}' \underline{X}' \underline{X} \hat{\underline{\beta}} \\
 &= \underline{y}' \underline{y} - 2\hat{\underline{\beta}}' \underline{X}' \underline{y} + \hat{\underline{\beta}}' \underline{X}' \underline{X} \hat{\underline{\beta}} \\
 &= \underline{y}' \underline{y} - \hat{\underline{\beta}}' \underline{X}' \underline{y}
 \end{aligned}$$

And $\hat{\underline{\beta}}' \underline{X}' \underline{y} = (\underline{y}' \underline{X} \hat{\underline{\beta}})$

إذا

$$\hat{\sigma}^2 = \frac{SS_e}{d.f} = \frac{\underline{y}' \underline{y} - \hat{\underline{\beta}}' \underline{X}' \underline{y}}{n - (m + 1)} \quad E(\hat{\sigma}^2) = \sigma^2 \quad \text{Where}$$

وبهذا يكون لدينا التباين المشترك للمعلمات المقدرة $\beta_0, \beta_1, \beta_2, \dots, \beta_m$ كما يلي

$$\begin{cases} V(\hat{\beta}_j) = \hat{\sigma}^2 c_{jj} \\ V(\hat{\beta}_0) = \hat{\sigma}^2 c_{00} \end{cases} \quad COV(\hat{\beta}_0, \hat{\beta}_j) = \hat{\sigma}^2 c_{0j}$$

وهكذا لأي من المعلمات المقدرة $\hat{\beta}_j$

خواص المقدرات بطريقة المربعات الصغرى:

بالإضافة إلى الخواص المذكورة أعلاه حول تباين المجتمع ومصفوفة التباين للمعلمات المقدرة تتميز مقدرات المربعات الصغرى كذلك بخاصية عدم التحيز أي أن:

$\hat{\beta}$ is unbiased estimate of β

proof:

we have $\hat{\beta}_{OLS} = (X'X)^{-1}X'Y$

$$\begin{aligned} E(\hat{\beta})_{OLS} &= E[(X'X)^{-1}X'Y] \\ &= E[(X'X)^{-1}X'(X\beta + \epsilon)] \\ &= E[(X'X)^{-1}X'X\beta + (X'X)^{-1}X'\epsilon] \\ &= E[\beta + (X'X)^{-1}X'U] \\ \because E(U) &= 0 \end{aligned}$$

$$\therefore E(\hat{\beta})_{OLS} = \beta$$

$\therefore \hat{\beta}$ is unbiased estimate of β

تباین متوسط الاستحابة:

we have $\hat{Y}_1 = \hat{\beta}_0 + \hat{\beta}_1 X_{i1} + \hat{\beta}_2 X_{i2} + \dots + \hat{\beta}_m X_{im}$

$$\underline{x}'_0 = [1 \quad x_{i1} \quad \dots \quad \dots \quad x_{im}]$$

للمشاهدة الأولى

$$\underline{x}'_0 = [1 \quad x_{11} \quad \dots \quad \dots \quad x_{1m}]$$

$$\therefore \hat{y}_1 = \underline{x}'_0 \hat{\beta}$$

$$V(\hat{y}_0) = \hat{\sigma}^2 X'_0 (X X)^{-1} X_0$$

معامل الانحدار الجزئي القياسي Standard partial regr.coeff

هو عبارة عن معامل الانحدار الجزئي عندما تكون كل متغير على شكل قياسي

$$X_i^* = \frac{X_i - \bar{X}}{S_{X_i}} \quad Y_i^* = \frac{Y_i - \bar{Y}}{S_{Y_i}}$$

$$S_{X_i} = \sqrt{S_{X_i}^2} = \sqrt{\frac{S_{X_i X_i}}{n-1}} = \sqrt{\frac{\sum X_{ii} - \frac{(\sum X_{ii})^2}{n}}{n-1}}$$

$$S_{Y_i} = \sqrt{S_{Y_i}^2} = \sqrt{\frac{S_{Y_i Y_i}}{n-1}} = \sqrt{\frac{\sum Y_{ii} - \frac{(\sum Y_{ii})^2}{n}}{n-1}}$$

$$\left. \begin{array}{l} \hat{\beta}_j^* = \hat{\beta}_j \left(\frac{S_{X_i}}{S_{Y_i}} \right) \\ \hat{\beta}_j = \hat{\beta}_j \left(\frac{S_{Y_i}}{S_{X_i}} \right) \end{array} \right\} \Rightarrow \hat{Y}_1^* = \hat{\beta}_0^* + \hat{\beta}_1^* X_{11}^* + \hat{\beta}_2^* X_{12}^* + \dots + \hat{\beta}_m^* X_{1m}^*$$

وهنا $\hat{\beta}_0$ يساوي صفر لأننا طرحا \bar{X} و \bar{Y} من المتغيرات

ولكون $\hat{\beta}_j^*$ خالٍ من وحدات القياس لذا فهو يشير إلى الأهمية النسبية للمتغير في التنبؤ ب Y ، فمثلا لو كان $\hat{\beta}_1^*$ ضعف قيمة $\hat{\beta}_1$ فان أهمية X_1 هي ضعف أهمية X_2 فمثلا

$$\left. \begin{array}{l} \hat{Y}_1 = 2 - 5X_1 + 3X_2 + 10X_3 \\ \hat{Y}_1^* = 2 - X_1 + 5X_2 - 2X_3 \end{array} \right\} \begin{array}{l} \text{أهمية } X_1 \text{ ضعف أهمية } X_2 \text{ في التنبؤ ب } Y \text{ مثلا} \\ \text{أهمية } X_2 \text{ ضعف أهمية } X_1 \text{ في التنبؤ ب } Y \text{ مثلا} \end{array}$$

أمثلة حول الانحدار المتعدد

مثال 1: إذا كانت لديك البيانات التالية:

Y	1	3	5	2	2	6
X_1	2	4	1	3	1	2
X_2	4	16	1	9	1	4

م/1- جد معادلة الانحدار المتعدد 2- جد قيمة تباين معاملات الانحدار وكذلك التباين المشترك ل $\hat{\beta}_1$ و3- جد متوسط الاستجابة وتباین متوسط الاستجابة عند $x_1=3$ و $x_2=7$ $\hat{\beta}_2$

Sol:

$$\sum X_1^2 = 35$$

$$\sum X_1 Y = 39$$

$$\sum X_2^2 = 371$$

$$\sum X_1 X_2 = 109$$

$$\sum Y = 79$$

$$\sum X_2 Y = 101$$

ومعادلة الانحدار لهذه المسألة ستكون:

$$\hat{Y}_1 = \hat{\beta}_0 + \hat{\beta}_1 X_{i1} + \hat{\beta}_2 X_{i2}$$

$$\hat{\underline{\beta}} = (X'X)^{-1}X'Y$$

$$\underline{X} = \begin{bmatrix} 1 & 2 & 4 \\ 1 & 4 & 16 \\ \cdot & \cdot & \cdot \\ 1 & 2 & 4 \end{bmatrix} \quad \underline{X}' = \begin{bmatrix} 1 & 1 & \dots & 1 \\ 2 & 4 & \dots & 2 \\ 4 & 16 & \dots & 4 \end{bmatrix}$$

$$(XX) = \begin{bmatrix} n & \sum X_1 & \sum X_2 \\ \sum X_1 & \sum X_1^2 & \sum X_1 X_2 \\ \sum X_2 & \sum X_1 X_2 & \sum X_2^2 \end{bmatrix} = \begin{bmatrix} 6 & 13 & 35 \\ 13 & 35 & 109 \\ 35 & 109 & 371 \end{bmatrix}$$

$$\underline{X'Y} = \begin{bmatrix} 1 & 1 & \dots & 1 \\ 2 & 4 & \dots & 2 \\ 4 & 16 & \dots & 4 \end{bmatrix} \begin{bmatrix} 1 \\ 3 \\ 6 \end{bmatrix} = \begin{bmatrix} 19 \\ 39 \\ 101 \end{bmatrix}$$

نوجد معكوس للمصفوفة باستخدام احد الطرق

اللاتي دخلت المكتبة المفتوحة بطريقة دارليت Doolittle

L.N.	XX			I		check
1	6	13	35	1	0	55
2	13	35	109	0	1	158
3	35	109	371	0	0	516
4	6	13	35	1	0	55
5	1	2.1667	5.8333	0.1667	0	9.1667
6	$15.8 - 13(2.1667)$ $= 6.8329$	33.167	-2.1671	1	0	$15.8 - 13(2.1667) = 3.83$
7	1	4.8560	-0.3172	0.1466	0	$15.8 - 13(2.1667) = 3.83$ 5.8333
8	5.8444	4.6861	-4.8566	1		$371 - [55(5.8333 + 3.83) - 5.8333]$ $= 5.8444$
9	1	0.8022	$\underbrace{-0.33125}_{(XX^2 - 1) \times 0.1466}$	0.1700		$0 - [55(5.8333 + 3.83) - 5.8333]$ $= 5.8444$

$$\therefore \hat{\beta} = \begin{bmatrix} 4.6 & -4.2 & 0.8022 \\ & 4.171 & -0.83123 \\ & & 0.17119 \end{bmatrix} * \begin{bmatrix} 19 \\ 39 \\ 101 \end{bmatrix} = \begin{bmatrix} 4.62 \\ 0.62 \\ 0.114 \end{bmatrix}$$

$$2 - \hat{\sigma}^2 = \frac{SS_e}{d.f} = \frac{\underline{y}' \underline{y} - \underline{\beta}' X' \underline{y}}{n - (m+1)}$$

$$\underline{\beta}' X' \underline{y} = [4.62 \quad 0.62 \quad 0.114] * \begin{bmatrix} 19 \\ 39 \\ 101 \end{bmatrix} = 56.979$$

$$\underline{y}' \underline{y} = 79$$

$$\therefore \hat{\sigma}^2 = 7.34$$

$$V(\hat{\beta}) = \hat{\sigma}^2 (X X)^{-1} = 7.34 \begin{bmatrix} 4.6 & -4.2 & 0.8022 \\ & 4.171 & -0.83123 \\ & & 0.17119 \end{bmatrix}$$

$$V(\hat{\beta}_0) = \hat{\sigma}^2 C_{00} = 33.764$$

$$V(\hat{\beta}_1) = \hat{\sigma}^2 C_{11} = 5.42$$

$$V(\hat{\beta}_2) = \hat{\sigma}^2 C_{22} = 0.222$$

$$COV(\hat{\beta}_1, \hat{\beta}_2) = \hat{\sigma}^2 C_{12} = -1.0767$$

3-

$$\hat{Y}_1 = 4.62 + 0.62 X_{11} + 0.114 X_{12}$$

$$\hat{Y}_1 = 4.62 + 0.62 (3) + 0.114 (7)$$

$$= 2.163$$

و

$$\therefore \hat{y}_1 = \underline{x}'_0 \underline{\beta}$$

$$\hat{y}_1 = [1 \quad 3 \quad 7] * \begin{bmatrix} 4.62 \\ 0.62 \\ 0.114 \end{bmatrix} = 2.163$$

$$V(\hat{y}_0) = \hat{\sigma}^2 X'_0 (X X)^{-1} X_0$$

$$V(\hat{y}_0) = 7.34 * [1 \quad 3 \quad 7] * \begin{bmatrix} 4.6 & -4.2 & 0.8022 \\ & 4.171 & -0.83123 \\ & & 0.17119 \end{bmatrix} * \begin{bmatrix} 1 \\ 3 \\ 7 \end{bmatrix} = 8.0899$$