

المحاشرة المائية

خواص مقدرات طریقات (صغری)

$$\hat{y} = 55 + 0.312x$$

خصائص المقدرات بواسطة المربعات الصغرى: ندرس خصائص المقدرات ضمن شروط ان  $x_i$  معطاة اي ان  $x_i$  ثابتة ضمن عدد من العينات مع العلم ان  $y_i$  تتغير من عينة لآخرى حسب  $u_i$ .

لنفرض لدينا مجموعة من العينات عددها  $m$  من القيم  $x_i$  و  $y_i$ .

(1)	(2)	(m)
$x_i \quad y_i$	$x_i \quad y_i$	$x_i \quad y_i$
$x_1 \quad y_1 \quad \hat{\alpha}$	$x_1 \quad y_1 \quad \hat{\alpha}$	$x_1 \quad y_1 \quad \hat{\alpha}$
$x_2 \quad y_2$	$x_2 \quad y_2$	$x_2 \quad y_2$
$  \quad   \quad \beta$	$  \quad   \quad \beta$	$  \quad   \quad \beta$
$x_n \quad y_n$	$x_n \quad y_n$	$x_n \quad y_n$

و الملاحظة ان الزوج  $(\hat{\alpha}, \beta)$  و الممكن تقديره من واقع مشاهدات العينة الاولى و كذلك من واقع مشاهدات العينة الثانية باعتماد طريقة المربعات الصغرى فان الزوجين يختلفان طبقاً لتغير قيم  $u_i$  في كلتا العينتين.

وبذلك تتولد لدينا سلسلة من قيم  $\hat{\alpha}$  و  $\beta$  عندما انتقل من عينة لآخرى و بذلك يمكن ان يتصور ان  $\beta$  و  $\hat{\alpha}$  متحولان عشوائيان لهما قانون احتمالي معين ذلك لأن  $\beta$  و  $\hat{\alpha}$  يتاثران بمتغيرات  $u_i$  و  $y_i$  تابع لتغير المتحول العشوائي  $u_i$ .

**ملاحظة:** ان تقديرات المربعات الصغرى هي توابع خطية للمشاهدات الفعلية حول قيم  $y_i$  اثبات هذه الملاحظة:

$$\beta = \frac{\sum x_i y_i}{\sum x_i^2} = \frac{\sum x_i(y - \bar{y})}{\sum x_i^2} = \frac{\sum x_i y_i - \bar{y} \sum x_i}{\sum x_i^2}$$

$$\beta = \frac{\sum x_i y_i}{\sum x_i^2}$$

نفرض ان:

$$\frac{x_i}{\sum x_i^2} = w_i$$

حيث :

$$\beta = \sum w_i y_i$$

لأن:  $x_2 \Rightarrow x_i = x_i - \bar{x}$

و منه: ثابت  $\frac{x_i}{\sum x_i^2}$

اذن العلاقة خطية بين  $\beta$  و  $y_i$

$$\beta = \sum w_i y_i$$

ونريد ان نبين ان العلاقة خطية بين  $\beta$  و  $y_i$  اي  $\hat{\alpha} = \sum d_i y_i$

لدينا  $\hat{\alpha} = \bar{y} - \beta \bar{x}$

$$\hat{\alpha} = \frac{1}{N} \sum y_i - \sum w_i y_i \bar{x}$$

$$= \frac{\sum y_i}{N} - \sum \bar{x} w_i y_i$$

$$= \left( \frac{1}{N} - \bar{x} w_i \right) y_i$$

و اذا رمزنَا  $\hat{\alpha} = \sum \frac{1}{N} - \bar{x} w_i$

$$\hat{\alpha} = \sum d_i y_i$$

لدراسة خصائص المتدرات  $\hat{\alpha}$  و  $\beta$  يجب ان ندرس تحيزهما و انهم اقل تباين اي ان مقدرات المربعات الصغرى هي مقدرات غير متحيزة و ذات اقل تباين.

$$\beta = \sum w_i y_i$$

$$= \sum w_i (\alpha + \beta x_i + u_i)$$

$$= \alpha \sum w_i + \beta \sum w_i x_i + \sum w_i u_i$$

$$\beta = \bar{\beta} + \sum w_i u_i$$

$$= (\beta) = E(B) + \sum w_i E(u_i) \quad : \text{و منه}$$

و بذلك فان  $\beta$  هو تقدير غير متحيز لـ  $\beta$

$$w_i = \frac{x_i}{\sum x_i^2} \Rightarrow \sum w_i = \frac{\sum x_i}{\sum x_i^2} = 1$$

$$\sum w_i x_i = \sum (x_i \bar{x}) w_i = \bar{x} \sum w_i - \bar{x} \sum w_i$$

$$\sum w_i x_i = \sum w_i x_i$$

$$w_i = \frac{x_i}{\sum x_i^2} \quad \text{كان:}$$

$$x_i w_i = \frac{x_i}{\sum x_i^2}$$

$$\sum x_i w_i = \frac{\sum x_i^2}{\sum x_i^2} = 1$$

$$\sum w_i x_i = \sum w_i x_i = 1 \quad \text{و منه}$$

اثبات ان  $\hat{\alpha}$  هو تقدير غير متحيز لـ  $\alpha$

لدينا:

$$\hat{\alpha} = \sum \left( \frac{1}{N} - \bar{x} w_i \right) y_i$$

$$= \sum \left( \frac{1}{N} - \bar{x} w_i \right) (\alpha + \beta x_i + u_i)$$

$$= \sum \left( \frac{\alpha + \beta}{N} x_i + \frac{u_i}{N} - \alpha \bar{x} w_i - \beta \bar{x} w_i x_i - \bar{x} w_i u_i \right)$$

$$= \frac{N\alpha}{N} + \beta \frac{\sum X_i}{N} - \alpha \bar{x} \sum w_i = \alpha + \beta \sum w_i + \sum \left( \frac{1}{N} - \bar{x} w_i \right) u$$

$$= \alpha + \beta \bar{x} - \alpha \bar{x} \sum w_i - \beta \bar{x} \sum X_i w_i + \sum \left( \frac{1}{N} - \bar{x} w_i \right) u_i$$

$$\hat{\alpha} = \alpha + \sum \left( \frac{1}{N} - \bar{x} w_i \right) u_i = \alpha + \sum d_i u_i$$

$$= \alpha + \frac{\sum u_i}{N} - \bar{x} \sum w_i u_i$$

$$E(\hat{\alpha}) = E(\alpha) - E\left(\frac{\sum u_i}{n} - \bar{x} \sum w_i E(u_i)\right)$$

$$E(\hat{\alpha}) = E(\alpha) + \sum d_i E(u_i)$$

ثابت

$$E(\hat{\alpha}) = \alpha$$

**تباينات التقديرات:**

لحساب التباينات لكل من  $\beta$  و  $\hat{\alpha}$  نعلم ان كل من  $\hat{\alpha}$  و  $\beta$  تقدير خطى اي مرتبط في علاقه خطية مع  $\alpha$  كذلك فان كل  $\hat{\alpha}$  و  $\beta$  يتبعان في علاقه خطية مع حد الاضطراب  $u$  حيث:

$$\beta = \beta + \sum w_i u_i$$

$$\hat{\alpha} = \alpha + \sum d_i u_i$$

**تباين  $\beta$ :** لدينا:-

$$\beta = \beta + \sum w_i u_i$$

و منه:-

$$\beta - \beta = \sum w_i u_i$$

$$(\beta - \bar{\beta})^2 = (\sum w_i u_i)^2$$

$$\text{Var}(\beta) = E(\beta - \bar{\beta})^2 = E[(\sum w_i u_i)^2]$$

لدينا:-

$$(\sum w_i u_i)^2 = (w_1 u_1 + w_2 u_2 + \dots + w_n u_n)^2$$

$$= w_1^2 u_1^2 + w_2^2 u_2^2 + \dots + w_n^2 u_n^2 + 2w_1 w_2 u_1 u_2 + \dots + 2w_{n-1} w_n u_{n-1} u_n$$

$$E(\sum w_i u_i)^2 = w_1^2 E(u_1^2) + w_2^2 E(u_2^2) + \dots + w_n^2 E(u_n^2) + 0 + \dots + 0$$

لكن:-

$$\text{Cov}(u_i u_j) = 0 \quad i \neq j$$

$$= w_1^2 \delta_u^2 + \dots + w_n^2 \delta_u^2$$

$$\text{Var}(\beta) = \delta_u^2 \sum_{i=1}^n w_i^2$$

و منه لدينا:-

$$W_i = \frac{x_i}{\sum x_i^2}$$

$$W_i^2 = \frac{x_i^2}{(x_i^2)^2}$$

$$\sum W_i^2 = \frac{\sum x_i^2}{(\sum x_i^2)^2}$$

$$\sum W_i^2 = \frac{1}{\sum x_i^2}$$

$$\text{Var}(\beta) = \frac{\delta u^2}{\sum_{i=1}^n x_i^2}$$

بما ان تباين حد  $\alpha$  الاخطاء مجهول اذن تباين  $\beta$  مجهول و الاول يتم تقديره وبال التالي يتم تقدير تباين  $\beta$ .

بيان  $\hat{\alpha}$ :

لدينا:-

$$E(\hat{\alpha}) = \alpha$$

و منه:-

$$Var(\hat{\alpha}) = E[(\hat{\alpha} - \alpha)^2]$$

لكن لدينا:-

$$\hat{\alpha} = \bar{Y} - \beta \bar{x}$$

$$\hat{\alpha} = \alpha + \beta \bar{x} + \bar{u} - \beta \bar{x}$$

$$\hat{\alpha} - \alpha = \beta \bar{x} + \bar{u} - \beta \bar{x}$$

$$= -(\beta - \beta) \bar{x} + \bar{u}$$

$$\hat{\alpha} - \alpha = \bar{u} - (\beta - \beta) \bar{x}$$

$$(\hat{\alpha} - \alpha)^2 = \bar{u}^2 (\beta - \beta)^2 \bar{x}^2 - 2 \bar{x} (\beta - \beta) \bar{u}$$

$$E(\hat{\alpha} - \alpha)^2 = E(\bar{u}^2) + \bar{x}^2 E^2(\beta - \beta)^2 - 2 \bar{x} E\{(\beta - \beta) \bar{u}\}$$

$$= \frac{\delta u^2}{n} + \bar{x}^2 \frac{\delta u^2}{\sum x^2}$$

$$= \delta u^2 \left( \frac{1}{n} + \frac{\bar{x}^2}{\sum x_i^2} \right)$$

لأن:-

$$E\{(\beta - \beta) \bar{u}\} = E\{(\sum w_i u_i) (\frac{1}{n} \sum u_i)\} = 0$$

لدينا:-

$$\beta - \bar{\beta} = \sum w_i u_i$$

و منه وبالتعويض

$$E[(\beta - \bar{\beta}) \bar{u}] = E[\sum w_i u_i \bar{u}]$$

$$E[\sum w_i u_i \frac{\bar{u}}{n}] = \frac{1}{n} E[\sum w_i u_i \sum u_i]$$

$$\frac{1}{n} E[(w_1 u_1 + w_2 u_2 + \dots + w_n u_n)(u_1 + u_2 + \dots + u_n)]$$

$$\begin{aligned} \frac{1}{n} E[(w_1 u_1^2 + w_2 u_2^2 + \dots + w_n u_n^2) + (w_1 u_1 w_2 u_2 + w_1 u_1 w_3 u_3 + \dots + w_1 u_1 w_n u_n + \dots + w_n u_n w_1 u_1 + w_n u_n w_2 u_2 + \dots + w_n u_n w_{n-1} u_{n-1})] \end{aligned}$$

$$\frac{1}{n} [w_1 E(u_1^2) + \dots + w_n E(u_n^2)]$$

$$\frac{1}{n} \delta_n^2 \sum w_i = \frac{\delta_u^2}{n} \cdot 0 = 0$$

$$= E\left\{ \frac{1}{n} [\sum w_i u_i^2 + \sum_{i \neq j} (w_i + w_j) u_i u_j] \right\} ? ? ?$$

$$= 0$$

التبالين المشترك له  $\hat{\alpha}$  و  $\beta$  :-

$$\text{Cov}(\hat{\alpha}, \beta) = E[(\hat{\alpha} - \alpha)(\beta - \bar{\beta})]$$

لدينا:-

$$\hat{\alpha} - \alpha = -(\beta - \bar{\beta}) \bar{x} + \bar{u}$$

$$= E\{[\bar{u} - (\beta - \bar{\beta}) \bar{x}] (\beta - \bar{\beta})\}$$

$$= E\{(\beta - \bar{\beta}) \bar{u}\} - \bar{x} E(\beta - \bar{\beta})^2$$

لدينا سابقا:-

$$E[(\beta - \hat{\beta})\bar{u}] = E[\sum w_i u_i \bar{u}]$$

و منه:-

$$\text{Cov}(\hat{\alpha}, \beta) = -\bar{x} \frac{\delta_{\bar{u}}^2}{\sum x_i^2}$$

سوف نبين ان تباين  $\beta$  هو اصغر تباين:-  $\text{var}(\beta)$

اذا افترضنا ان:  $\beta = \sum c_i y_i$  هو تقدير خطى لـ  $\beta$  بالتعريف.

حيث:-  $c_i (i=1,2,\dots,n)$

تمثل معاملات تتقبل

$$\beta = \alpha \sum c_i + \beta \sum c_i x_i + \sum c_i u_i$$

و منه لكي يكون  $\beta$  مقدر غير متحيز فان المعامل  $c_i$  لابد ان يملا الشروط التالية:-

$$\sum c_i = 0 \quad \sum c_i x_i = 1$$

$$\beta = \beta + \sum c_i u_i$$

و منه:-

$$E(\beta) = 0 + \beta + E[\sum c_i u_i]$$

$$E(\beta) = \beta$$

تبعا لذلك فان تباين  $\beta$

$$\text{Var}(\beta) = \delta_u^2 \sum c_i^2$$

و لمقارنة هذا التباين مع تباين المربعات الصغرى( $\text{Var}(\beta)$ )

نفرض:  $c_i = w_i + (c_i - w_i)$

$$\sum c_i^2 = \sum w_i^2 + \underbrace{[(c_i - w_i)^2 + 2\sum w_i(c_i - w_i)]}_{0}$$

$$\sum w_i c_i = \frac{\sum c_i x_i}{\sum x_i^2} \quad \text{لأن:}$$

بما أن:  $\sum c_i x_i = 1$

$$\sum w_i c_i = \frac{1}{\sum x_i^2}$$

$$\sum w_i^2 = \frac{1}{\sum x_i^2} \quad \text{ولدينا:}$$

$$\sum w_i(c_i - w_i) = 0 \quad \text{و منه:}$$

$$\sum w_i(c_i - w_i) = \sum w_i c_i - \sum w_i^2 = 0 \quad \text{لأن:}$$

و منه:  $\sum w_i^2 = 1$

$$\sum c_i^2 = \sum w_i^2 + \sum (c_i - w_i)^2$$

و بضرب طرفي العلاقة بـ  $\delta_u^2$ :

$$\delta_u^2 \sum c_i^2 = \delta_u^2 \sum w_i^2 + \delta_u^2 \sum (c_i - w_i)^2$$

و منه:

$$Var(\beta) = var(\beta) + \delta_u^2 \sum (c_i - w_i)^2$$

$$\sum (c_i - w_i)^2 > 0 \quad \text{وبما أن:}$$

لا اذا كان  $c_i = w_i$  مهما كانت قيمة  $\beta$  و منه:

$$Var(\beta) < var(\beta)$$

و منه فان تباين مقدر المربعات الصغرى اقل من المقدر الخطى: و بالتالى فان مقدر المربعات الصغرى يعد من المقدرات الخطية غير المتحيزه ذات اقل تباين و بالتالى فان  $\beta$  هو افضل تقدير خطى غير متحيز.

**تبليغ:** بما ان  $\hat{\alpha}$  و  $\beta$  هي توابع خطية لـ  $u$  و بما ان  $u$  متغير عشوائى يخضع للتوزيع الطبيعي اذن:-

$$\hat{\alpha} \sim N\left[\alpha, \delta_u^2 \left(\frac{1}{n} + \frac{\bar{x}^2}{\sum x_i^2}\right)\right]$$

$$\beta \sim N\left(\beta, \frac{\delta_u^2}{\sum x_i^2}\right)$$

$$y_i \sim N\left(\alpha + \beta x_i, \delta_u^2\right)$$

**تقدير تباين  $u$  المجهول:** نحن نعلم ان افضل تقدير هو الغير متحيز. و الان نبرهن ان تقدير تباين  $u$   $\delta_u^2$  غير المتحيز:-

$$\delta_u^2 = E\left(\frac{\sum e_i^2}{n-2}\right)$$

$$s^2 = \frac{\sum e_i^2}{n-2} \quad \text{هو}$$

$$e_i = y_i - \hat{y}_i \quad \text{لدينا:-}$$

$$e_i = \alpha + \beta x_i + u_i - \hat{\alpha} - \hat{\beta} x_i$$

$$= u_i - (\hat{\alpha} - \alpha) - (\hat{\beta} - \beta) x_i$$

لكن لدينا سابقا من  $(\hat{\alpha} = \bar{y} - \beta \bar{x})$

$$\hat{\alpha} - \alpha = \bar{u} - (\beta - \beta) \bar{x}$$

$$e_i = u_i - \bar{u} - (\beta - \beta) \bar{x} \quad \text{و منه:}$$

$$\sum e_i^2 = \sum (u_i - \bar{u})^2 + (\beta - \beta)^2 \sum x_i^2 - 2(\beta - \beta) \sum (u_i - \bar{u}) x_i$$

و منه:

$$E(\sum e_i^2) = E[\sum (u_i - \bar{u})^2] + E[(\beta - \hat{\beta})^2 \sum x_i^2] - 2E[(\beta - \hat{\beta}) \sum x_i(u_i - \bar{u})]$$

1/  $E[(\beta - \hat{\beta})^2 \sum x_i^2]$

$$\text{Var}(\beta) = E(\beta - \hat{\beta})^2 = \frac{\delta u^2}{\sum x_i^2} \Rightarrow E[(\beta - \hat{\beta})^2 \sum x_i^2] = \delta_u^2$$

ثابت

2/  $E[\sum (u_i - \bar{u})^2] = E[\sum (u_i^2 - 2\bar{u}u_i + \bar{u}^2)]$

$$\begin{aligned} &= E[\sum u_i^2 - 2\frac{\bar{u}}{n} \sum u + \frac{1}{n} (\sum u)^2] \\ &= E[\sum u^2 - \frac{2}{n} (\sum u)^2 + \frac{1}{n} (\sum u)^2] \\ &= E[\sum u^2 - \frac{1}{n} (\sum u)^2] \\ &= E[(\sum u^2) - \frac{1}{n} E(u)^2] \\ &= n \delta_u^2 - \frac{1}{n} \delta_u^2 \\ &= n \delta_u^2 - \delta_u^2 = \delta_u^2(n-1) \end{aligned}$$

3/  $E[(\beta - \hat{\beta}) \sum x_i(u_i - \bar{u})]$

لدينا:

$$\beta = \hat{\beta} + \sum w_i u_i$$

$$\beta - \hat{\beta} = \sum w_i u_i \quad w_i = \frac{x_i}{\sum x_i^2}$$

$$\beta - \hat{\beta} = \frac{\sum x_i u_i}{\sum x_i^2}$$

و منه:

$$E(\beta - \bar{\beta}) \sum x_i (u_i - \bar{u}) = E\left[\frac{\sum x_i u_i}{\sum x_i^2} \sum x_i (u_i - \bar{u})\right]$$

$$= E\left[\frac{\sum x_i u_i}{\sum x_i^2} (\sum x_i u_i - \bar{u} \sum x_i)\right] \rightarrow 0$$

$$= E\left[\frac{\sum x_i u_i}{\sum x_i^2} \sum x_i u_i\right]$$

$$= E\left[\frac{(\sum x_i u_i)^2}{\sum x_i^2}\right]$$

$$E[(\sum x_i u_i)^2] = E(x_1 u_1 + x_2 u_2 + \dots + x_u u_u)^2$$

$$= E(x_1^2 u_1^2 + x_2^2 u_2^2 + \dots + x_u^2 u_u^2)$$

$$= x_1^2 \delta_u^2 + x_2^2 \delta_u^2 + \dots + x_u^2 \delta_u^2$$

$$= \delta_u^2 \sum_{i=1}^n x_i^2$$

و منه:

$$E\left[\frac{(\sum x_i u_i)^2}{\sum x_i^2}\right] = \frac{\delta_u^2 \sum x_i^2}{\sum x_i^2} = \delta_u^2$$

و منه:

$$-2E[(\beta - \bar{\beta}) \sum x_i (u_i - \bar{u})] = -2\delta_u^2$$

و منه:

$$E(\sum e_i^2) = \delta_u^2 + (n-1)\delta_u^2 - 2\delta_u^2$$

$$E(\sum e_i^2) = (n-2)\delta_u^2$$