

Properties of the Least Squares Estimates

تتضمن نظرية غاوس-ماركوف Guss-Markov theory ان طريقة المربعات العكسية الاعتيادية (OLS) فهي افضل تقدير خطي غير متحيز او انحراف (BLUE)

Best Linear Unbiased Estimates

لنرى تحقق كافة شروط صلاحيات كوكوشي

ان هذه النظرية تفيد في ان تطبيق (OLS) وتفسيرها لها عند الطرق المتقدمة في التقدير لمؤزج خطي ومصادره مفردة ومستوعب محتوى هذه النظرية وكالاتي من خلال تلك الخواص

0- الخطية Linearity

تعريف: خطية مقدر معين وانته يؤكد ان الخطية كالتالي

الاهمية
عندنا نقول ان الرتبة الكبار هو مقدر خطي لمعرفه معلوم ذلك نقول انه مقدر خطي، اذا ان هذا المقدر خطي.

$$w_1x_1 + w_2x_2 + w_3x_3 + \dots + w_n x_n$$

حيث w هي ثوابت معينة ان نذهب الى ان الوط الكبار هو مقدر خطي

$$\bar{y} = \frac{\sum y_i}{n} = \frac{1}{n} (y_1 + y_2 + y_3 + \dots + y_n)$$

$$= \frac{1}{n} y_1 + \frac{1}{n} y_2 + \frac{1}{n} y_3 + \dots + \frac{1}{n} y_n$$

حيث $\frac{1}{n}$ ثابت لاننا نرسله الى w

$$\bar{y} = w_1 y_1 + w_2 y_2 + w_3 y_3 + \dots + w_n y_n$$

لذا هو مقدر خطي

ولان نريد هذا الشكل (a^1, b^1) ونسب الترددات

عند الخصائص

$$\sum w_i^2 = \frac{1}{n}, \quad \sum w_i = 0, \quad \sum w_i x_i = 1, \quad \sum u_i = 0$$

$$w_i = \frac{x_i}{\sum x_i}, \quad \sum w_i = 0, \quad \sum u_i^2 = \sigma_{u_i}^2$$

ان تصير = الانواع اخرى و دالة فية في العينات

$$a^1 = f(y_i) \quad \text{و} \quad b^1 = f(y_i)$$

Ⓐ

$$b^1 = f(y_i)$$

$$b^1 = \frac{\sum y_i x_i}{\sum x_i^2}$$

$$\begin{cases} y_i = y_i - \bar{y} \\ x_i = x_i - \bar{x} \end{cases}$$

$$b^1 = \frac{\sum x_i (y_i - \bar{y})}{\sum x_i^2} = \frac{\sum y_i x_i - \bar{y} \sum x_i}{\sum x_i^2} = 0$$

$$b^1 = \frac{\sum y_i x_i}{\sum x_i^2} \quad \sum x_i = 0, \quad w_i = \frac{x_i}{\sum x_i}$$

$$b^1 = \sum w_i y_i$$

الانواع اخرى و دالة فية في العينات (y_i)

$$b^1 = f(y_i)$$

Ⓑ

$$a^1 = f(y_i)$$

$$a^1 = \bar{y} - b^1 \bar{x}$$

$$b^1 = \sum w_i y_i$$

$$a^1 = \bar{y} - \bar{x} \sum w_i y_i$$

$$= \frac{\sum y}{n} - \bar{x} \sum w_i y_i = \sum \left[\frac{y_i}{n} - \bar{x} w_i y_i \right]$$

$$= \sum \left[\frac{1}{n} - \bar{x} w_i \right] y_i$$

معاني \bar{x} و w_i معاني اخرى كذا ان a^1 فية في العينات (y_i)

$$a^1 = f(y_i)$$

99
بيان

③ - خاصية المفضل بين اقل معدل خطأ (Best Estimator) PROPERTY
The minimum variance

لعبدي معدل افضل منه كغيره من التقديرات اذ ان بيان المفضل بين التقديرات الاخرى التي افضل على من فرق الاخطاء والتباين الاخرى، ولذا
رأيت بقول ان $(b^?)$ مفضل لعبد معدل افضل اذ ان

$$\text{var}(b^?) < \text{var}(b^*)$$

$$E[b^? - E(b_i)]^2 < E[b^* - E(b_i^*)]^2$$

حيث ان b^* اي تقدير اخر للمعامل الضيف β_1
علا ان الضيف الواحد لبيان $b^?$ هو
$$\text{var}(b^?) = \frac{\sigma_u^2}{\sum x_i^2}$$

البرهان

$$b^? = \sum w_i y_i$$

$$\text{var}(b^?) = \text{var}(\sum w_i y_i)$$

$$= \sum w_i^2 \text{var}(y_i)$$

ملاحظة - عند قول (var) بمجموعة اي معدل تباين لبيان (var) مفرد في معدل بيان (var) فان نتائج يكون عبارة عن مجموع مربع التباين مفرد بيان (var) المتقدير

$$\text{var}(\sum w_i y_i) = \sum w_i^2 \text{var}(y_i)$$

$$\text{var}(b^?) = \sum w_i^2 \sigma_u^2 = \sigma_u^2 \sum w_i^2$$
$$\sum w_i^2 = \frac{1}{\sum x_i^2}$$

$$\text{var}(b^?) = \frac{\sigma_u^2}{\sum x_i^2}$$

المفضل بين
اقل معدل

(3)

var(a^1) = ...

$$\text{var}(a^1) = \sigma_u^2 \left(\frac{1}{n} + \frac{\bar{X}^2}{\sum x_i^2} \right)$$

OR, $\text{var}(a^1) = \frac{\sigma_u^2 \sum x_i^2}{n \sum x_i^2}$

$$\hat{a} = \sum \left(\frac{1}{n} - \bar{X} w_i \right) y_i$$

$$\text{var}(a^1) = \text{var} \left[\sum \left(\frac{1}{n} - \bar{X} w_i \right) y_i \right]$$

$$\leq \sigma_u^2 \left[\sum \left(\frac{1}{n^2} - \frac{2\bar{X} w_i}{n} + \bar{X}^2 w_i^2 \right) \right]$$

$$\text{var}(y_i) = \sigma_u^2$$

$$\text{var}(a^1) \leq \sigma_u^2 \left(\frac{n}{n^2} - \frac{2\bar{X} \sum w_i}{n} + \bar{X}^2 \sum w_i^2 \right)$$

$$\text{var}(a^1) \leq \sigma_u^2 \left(\frac{1}{n} + \frac{\bar{X}^2}{\sum x_i^2} \right)$$

$$\text{var}(a^1) \leq \sigma_u^2 \left(\frac{\sum x_i^2 + n\bar{X}^2}{n \sum x_i^2} \right)$$

$$\sum x_i^2, \sum x_i^2 - n\bar{X}^2$$

$$\text{var}(a^1) \leq \sigma_u^2 \left(\frac{\sum x_i^2 - n\bar{X}^2 + n\bar{X}^2}{n \sum x_i^2} \right)$$

$$\text{var}(a^1) \leq \frac{\sigma_u^2 \sum x_i^2}{n \sum x_i^2}$$

من أجل أن تكون العلاقة بين المتغيرين الخطية، يجب أن تكون العلاقة بين المتغيرين الخطية، ومن حيث ذلك جميع العلاقات الرامدة بالصورة الرياضية الخطية (خطية أو غير خطية).

$$Y_i = \alpha + \beta X_i + u_i$$

توزيع المتغير التابع هو توزيع معياري، تكون قيمة المتوسطية هي:

$$E(Y_i) = \alpha + \beta X_i$$

البرهان:

$$\begin{aligned} \text{mean of } Y_i &= E(Y_i) \\ &= E(\alpha + \beta X_i + u_i) \\ &= \alpha + \beta X_i + E(u_i) \\ &= \alpha + \beta X_i \end{aligned}$$

لأن X_i أصبحت ثابتة حسب الفرض السابق و $(E(u_i) = 0)$ حسب الفرض الثاني، أما قيمة تباين (Y_i) variance:

$$\text{Var}(Y_i) = E[(Y_i - E(Y_i))^2] = \sigma_u^2$$

البرهان:

$$\begin{aligned} \text{Var}(Y_i) &= E[(Y_i - E(Y_i))^2] \\ &= E[(\alpha + \beta X_i + u_i - \alpha - \beta X_i)^2] \\ &= E(u_i)^2 = \sigma_u^2 \end{aligned}$$

وذلك حسب الفرض الثالث، الذي ينص على أن تباين u هو مقدار ثابت.

الوزن التزجيحي



(1) $\sum w_i = 1$

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

$$\sum w_i = \sum \left(\frac{x_i}{\sum x_i^2} \right) = \frac{\sum x_i}{\sum x_i^2} = \frac{0}{\sum x_i^2} = 0$$

البرهان:

(2) $\sum w_i x_i = 1$

$$\begin{aligned} \sum w_i x_i &= \sum \left(\frac{x_i}{\sum x_i^2} \cdot x_i \right) = \frac{\sum x_i^2}{\sum x_i^2} \\ &= \frac{\sum (x_i - \bar{x})(x_i - \bar{x})}{\sum (x_i - \bar{x})^2} = \frac{\sum x_i^2 - \bar{x} \sum x_i}{\sum (x_i^2 - 2\bar{x}x_i + \bar{x}^2)} = \frac{\sum x_i^2 - \bar{x} \sum x_i}{\sum x_i^2 - 2\bar{x} \sum x_i + n\bar{x}^2} \end{aligned}$$

البرهان:

(23)

$$\frac{\sum x_i^2 - \bar{x} \sum x_i}{\sum x_i^2 - n \bar{x}^2} = \frac{\sum x_i^2 - \bar{x} \sum x_i}{\sum x_i^2 - 2n\bar{x}^2 + n\bar{x}^2}$$

$$= \frac{\sum x_i^2 - \bar{x} \sum x_i}{\sum x_i^2 - n\bar{x}^2} = \frac{\sum x_i^2 - \bar{x} \sum x_i}{\sum x_i^2 - n\bar{x}^2} = 1$$

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

$$\sum w_i x_i = \sum [w_i (x_i + \bar{x})] = \sum [w_i x_i + w_i \bar{x}]$$

$$= \sum w_i x_i + \bar{x} \sum w_i = \sum w_i x_i + \bar{x} (0)$$

$$= \sum w_i x_i$$

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

$$\sum w_i^2 = \sum \left(\frac{x_i}{\sum x_i^2} \right)^2 = \frac{\sum x_i^2}{(\sum x_i^2)^2} = \frac{1}{\sum x_i^2}$$

(5) $\sum w_i y_i = B^{\wedge}$

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

$$= \frac{\sum x_i y_i}{\sum x_i^2} = \sum \left(\frac{x_i}{\sum x_i^2} y_i \right) = \sum w_i y_i$$

Best, Linear, Unbiased Estimation

BLUE

(1) $B^{\wedge} = f(y_i)$ (Linearity): أي أن تصديرات البرهان هي دالة خطية لقيم المتغير التابع y_i

(a) $B^{\wedge} = f(y_i)$

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

$$= \frac{\sum x_i y_i}{\sum x_i^2} - \frac{\bar{y} \sum x_i}{\sum x_i^2} = \frac{\sum x_i y_i}{\sum x_i^2} = \sum w_i y_i$$

$$B^{\wedge} = w_1 y_1 + w_2 y_2 + \dots + w_n y_n$$

∴ $B^{\wedge} = f(y_i)$ أي أن دالة B^{\wedge} هي دالة خطية لقيم المتغير التابع y_i

(24)