

المحاضرة (4) : تابع

ع- خصائص ومميزات المقدرات:

أعرض أن تكون المقدرات المحصل عليها $\hat{\alpha}$ و $\hat{\beta}$ ذات معنى إحصائي ورياضي قابل للاعتماد عليه يجب أن تتوفر بها بعض الخصائص الرياضية التي تسمح لها أن تكون أكثر كفاءة للواقع، وتمثل هذه الخصائص في:

1- خاصية عدم التحيز:

وهو أن يكون التوقع الرياضي للمقدرة يساوي تماما

$$E(\hat{\alpha}) = \alpha \quad , \quad E(\hat{\beta}) = \beta$$

1- هل $\hat{\beta}$ يتسم بخاصية عدم التحيز؟

$$\begin{cases} y_i = \alpha + \beta x_i + u_i & \text{--- (1)} \\ \bar{y} = \alpha + \beta \bar{x} + \bar{u} & \text{--- (2)} \end{cases}$$

نطرح المعادلة (2) من المعادلة (1)

$$y_i - \bar{y} = \beta (x_i - \bar{x}) + (u_i - \bar{u})$$

ونعلم أن:

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

نعوض $y_i - \bar{y}$ بما يساويها:

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

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

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

$$E(\hat{\beta}) = E(\beta) + \frac{\sum (x_i - \bar{x}) E(u_i)}{\sum (x_i - \bar{x})^2} = 0$$

و نعلم أن $E(\beta) = \beta$ إذن :

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

وهذا β يسمى بـ **معامل التحيز**

هل $\hat{\alpha}$ يسمى بـ **معامل التحيز**؟

$$\begin{cases} \bar{y} = \alpha + \beta \bar{x} + \bar{u} & \text{--- (1)} \\ \bar{y} = \hat{\alpha} + \hat{\beta} \bar{x} & \text{--- (2)} \end{cases}$$

$$\alpha + \beta \bar{x} + \bar{u} = \hat{\alpha} + \hat{\beta} \bar{x} \quad \text{--- (1) - (2)}$$

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

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

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

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

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

اذن α يتسم بخاصية عدم التحيز -

2. خاصية التقارب =

تعتبر خاصية التقارب خاصية مهمة جدا، حيث في حالة توفر هذه الخاصية للمقدرة فهي تعني أيضا أن تباينها سوف يتجه إلى الصفر كلما ارتفع عدد المشاهدات، بعبارة أخرى كلما أضفنا معلومات وبيانات جديدة لعملية التقدير بحيث تقترب المجتمع المدروس للمجتمع الكلي فهذا يعني أن قيمة المقدرة تصبح أكثر تمثيلا للواقع الأمر الذي يجعل تباينها في أصغر مستوى ويؤول إلى 0، وهذا ما يعني التعبير القوي للمقدرة للواقع.

هل $\hat{\beta}$ يتسم بالتقارب؟

نعول عن معلومة أنها متقاربة لما تكون $\lim_{n \rightarrow \infty} V(\hat{\beta}) = 0$

حيث $V(\hat{\beta})$ هي تباين المعلمة $\hat{\beta}$.

$$V(\hat{\beta}) = E[(\hat{\beta} - \beta)^2]$$

لهيئا:

نقوض $\hat{\beta} - \beta$ بما يساويها :

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

$$V(\hat{\beta}) = E \left[\underbrace{\left(\sum w_i u_i \right)^2}_{\text{تحويل شهير}} \right]$$

$$w_i = \frac{\sum (x_i - \bar{x})}{\sum (x_i - \bar{x})^2}$$

حيث :
(تحويل العوامل مع المعادلة) :

$$V(\hat{\beta}) = E \left[\sum w_i^2 u_i^2 + 2 \sum w_i w_i' u_i u_i' \right]$$

$$\left\{ \begin{array}{l} E(u_i^2) = V(u) \\ \quad = \sigma^2(u) \\ E(u_i, u_i') = 0 \end{array} \right. \text{ من الفرضيتين :}$$

$$V(\hat{\beta}) = \sum w_i^2 \sigma_u^2 = \frac{\sigma_u^2}{\sum (x_i - \bar{x})^2}$$

بإدخال النهاية على المعادلة الأخيرة سيؤول المقام إلى ما لا نهاية، بحيث كلما زادت n (عدد المشاهدات) يتجه المقام لكل إلى ما لا نهاية، وقيمة البسط ثابتة إذن

$$\lim_{n \rightarrow \infty} V(\hat{\beta}) = 0$$

وبالتالي المقدرة $\hat{\beta}$ تتسم بخاصية التقارب.

هل $\hat{\alpha}$ تتسم بالتقارب؟

بنفس الطريقة يبرهن على تقارب الحد الثابت حيث

$$V(\hat{\alpha}) = \delta_{uu} \left(\frac{1}{n} + \frac{\bar{x}^2}{\sum (x_i - \bar{x})^2} \right) \quad \text{لدينا}$$

وعندما نؤول المقام إلى ما لا نهاية كما اتجه n إلى

ما لا نهاية، نؤول المعادلة إلى 0 وبالتالي =

$$\lim_{n \rightarrow \infty} V(\hat{\alpha}) = 0$$

$\hat{\alpha}$ تتسم بخاصية التقارب.

4- مؤشرات حساب جودة التوزيع:

يتم قياس جودة التوزيع بمؤشرين هما: معامل التجميع

وتباين الخطأ العشوائي.

4-1- معامل التجميع:

و يقاس المدى الذي يفسر به المتغير المستقل x_i

المتغير التابع y_i ، وتتراوح قيمته بين 0 و 1، فكلما

اقترب هذا من 1 نقول أنه x_i يفسر نسبة كبيرة من

التغيرات التي تحدث في المتغير التابع y_i ، والعكس

صحيح.

وهو يمثل النسبة بين مجموع مربعات الانحدار SSR

ومجموع المربعات الكلي SST

حيث:

$$R^2 = \frac{SSR}{SST}$$

SST : هو مجموع المربعات الكلي والتي تحدث في

المتغير التابع وتكون هنا :

$$SST = SSR + SSE$$

$$\sum (y_i - \bar{y})^2 = \sum (\hat{y}_i - \bar{y})^2 + \sum u_i^2$$

SSR : مجموع مربعات الانحدار ، هو جزء هنا تبين

قيمة المتغير الذي تم تفسيره بواسطة الانحدار :

أي جزء من التغيرات التي تحدث في المتغير التابع

والذي تم تفسيره بواسطة النموذج المقدر .

$$SSR = \sum (\hat{y}_i - \bar{y})^2$$

SSE : مجموع مربعات الأخطاء ، وهو الجزء الذي

فشل النموذج في تفسيره

$$SSE = \sum u_i^2$$

وبالتالي :

$$R^2 = \frac{SSR}{SST}$$

$$R^2 = \frac{\sum (\hat{y}_i - \bar{y})^2}{\sum (y_i - \bar{y})^2} = \frac{\sum (y_i - \bar{y}) - \sum u_i^2}{\sum (y_i - \bar{y})^2}$$

$$R^2 = 1 - \frac{\sum u_i^2}{\sum (y_i - \bar{y})^2}$$

أو يمكن كتابته بالشكل التالي:

$$R^2 = 1 - \frac{SSE}{SST}$$

* كما يمكن حساب معامل التحديد وفق علاقتين أخريين
كما:

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

$$R^2 = \frac{[\sum (x_i - \bar{x})(y_i - \bar{y})]^2}{\sum (x_i - \bar{x})^2 \sum (y_i - \bar{y})^2}$$

وفي حالة إدخال الجذر التربيعي على العلاقة الأخيرة
نتحصل على:

$$r = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2} \sqrt{\sum (y_i - \bar{y})^2}} = r_{x,y}$$

$r_{x,y}$ = معامل الارتباط

في هذه الحالة، عان المتغير التابع في ظل نموذج الانحدار الخطي البسيط، يتبع متغير مستقل واحد، هذا يعني أن معامل التحديد الذي يشرح تغيرات وانحرافات المتغير التابع مبني على تغيرات وانحرافات متغير مستقل واحد، ففي هذه الحالة معامل التحديد هو نفسه مربع معامل

$$R^2 = r_{x,y}^2$$

الارتباط: معامل الارتباط الخطي =

يمكن صياغته بالعلاقة السابقة، وغير وحالات

لمعامل الارتباط -

$r_{x,y} = 1$: ارتباط موجب تام

$0.7 < r_{x,y} < 1$: ارتباط موجب قوي

$0.3 < r_{x,y} < 0.7$: ارتباط موجب متوسط القوة

$0 < r_{x,y} < 0.3$: موجب ضعيف

- $r_{x,y} = 0$: لا يوجد ارتباط .

- $0 < r_{x,y} < 0,3$: ارتباط سالب ضعيف

- $0,3 < r_{x,y} < 0,7$: ارتباط سالب متوسط القوة

- $0,7 < r_{x,y} < 1$: ارتباط سالب قوي

- $r_{x,y} = -1$: ارتباط سالب تام

7-2 - تباين الخطأ العشوائي :

تقدير الكرجات الصغيرة لتباين الخطأ العشوائي هو $\hat{\sigma}_u^2$

ويحسب بالمعادلة التالية :

$$\hat{\sigma}_u^2 = \frac{\sum u_i^2}{n-2} = \frac{\sum (y_i - \hat{y}_i)^2}{n-2}$$

يقيس هذا الكوشر مدى انحراف القيم الفعلية عن القيم المقدرة . فإذا كان هذا التقدير كبيراً فإن انحرافات القيم الفعلية للمتغير التابع عن القيم المقدرة لها كبير أي أن النموذج غير كفؤ .