

## الفصل الثاني: الانحدار الخطي البسيط

### 1.2 مقدمة:

إن دراسة العلاقة بين المتغيرات الاقتصادية يتطلب تحديد المتغيرات المؤثرة في تلك العلاقة ومن أبسط وأسهل أنواع العلاقات في التقدير والتحليل الإحصائي والاقتصادي، العلاقة بين متغيرين أحدهما المتغير التابع  $X$  والثاني المتغير المستقل Independent Variable ، فإذا رمزنا للمتغيرين بـ  $Y$  وعلى التوالي، فإن العلاقة الدالية التي تجمعهما تكون كالتالي:

$$Y = F(x) \dots \dots \dots \quad (1.2)$$

حيث يشير الرمز  $F$  إلى كون المتغير التابع  $Y$  يعتمد على المتغير المستقل  $X$ . ولتحديد شكل العلاقة هذه - ما إذا كان خطياً أم غير خطى - يمكن الاستعانة بالنظرية الاقتصادية، كما يستعان بالاقتصاد الرياضي والإحصاء لصياغة العلاقة واختبار المتغيرات، كما لابد من تحديد شكل العلاقة هذه إذ تحكم العلاقة بين المتغيرات بعدد من الأشكال (الصيغ) أبسطها وأكثرها شيوعاً الصيغة الخطية، وتسمى العلاقة الخطية بين متغيرين بالانحدار الخطي البسيط ، Simple Linear Regression ، فالعلاقة الخطية بين  $X$  ولتكن دخل الأسرة و  $Y$  ولتكن الإنفاق على سلعة معينة يمكن أن تكتب بالصيغة الرياضية الآتية:

$$Y_i = B_0 + B_1 X_i \dots \dots \dots \quad (2.2)$$

حيث  $B_0$  و  $B_1$  عبارة عن معلمات مجهرولة القيم وثوابت يُشرحان من وجهة النظر الرياضية كالتالي:  $B_0$  : تمثل تقاطع خط الانحدار مع المحور العمودي وهي عبارة عن القيمة التي تتخذها  $Y$  عندما تكون قيمة  $X$  مساوية لـ الصفر .  $B_1$ : تمثل الميل.

ومن وجهة النظر الاقتصادية تمثل  $(B_0)$  حالة الكفاف و  $(B_1)$  الميل الحدي للاستهلاك، وقيمة الميل عبارة عن مقدار الزيادة المتحققة في قيمة المتغير التابع  $Y$  نتيجة زيادة المتغير المستقل بمقدار وحدة واحدة. غير أن العلاقة أعلاه (2.2) لا يمكن أن تشرح العلاقة بين المتغيرين بشكل دقيق، فهناك أسباب مهمة تجعل هذه المعادلة غير معبرة عن العلاقة بين  $X$  و  $Y$  تعبيراً كاملاً فقد يكون هناك انحراف بين العلاقة الحقيقة والمعادلة الإحصائية التي تمثلها نتيجة أخطاء في القياسات أو في اختيار المتغير المستقل، مما يتطلب إضافة متغير جديد يسمى بالحد العشوائي Random Variable ويرمز له عادة بالرمز  $(U)$  ودوره امتصاص العوامل غير القابلة للقياس، وكذلك أخطاء القياس، عليه فإن العلاقة من الصيغة (2.2) يجب أن تعدل لكي تضم حد الخطأ العشوائي حيث يصبح:

$$Y_i = B_0 + B_1 X_i + U_i \dots \dots \dots \quad (3.2)$$

### 2.2 الفرضيات الخاصة بالمتغير العشوائي:

1- إن المتغير العشوائي ( $U_i$ ) هو متغير تعتمد قيمته في أية فترة زمنية على عامل الصدفة (بخيت على ، فقد تكون أكبر أو أصغر أو مساوية إلى الصفر، إلا أنها في المتوسط تساوي صفر، أي  $E(U_i) = 0$ ، ويمكن توضيح ذلك على النحو الآتي:

$$Y_i = B_0 + B_1 X_i + U_i \dots \dots \dots \quad (4.2)$$

$$U_i = Y_i - B_0 - B_1 X_i \dots \dots \dots \quad (5.2)$$

وبإدخال  $\Sigma$  على طرفي المعادلة 5.2:

$$\begin{aligned} \sum U_i &= \sum (Y_i - B_0 - B_1 X_i) \\ \sum U_i &= \sum Y_i - n B_0 - B_1 \sum X_i \dots \dots \dots \quad (6.2) \\ \therefore B_0 &= \bar{Y} - B_1 \bar{X} \end{aligned}$$

نفرض عن  $B_0$  بما يساويها في المعادلة (6.2)

$$\begin{aligned} \sum U_i &= \sum Y_i - n(\bar{Y} - B_1 \bar{X}) - B_1 \sum X_i \dots \dots \dots \quad (7.2) \\ \therefore \bar{Y} &= \frac{\sum Y_i}{n}, \quad \bar{X} = \frac{\sum X_i}{n} \end{aligned}$$

وبحاصل ضرب الطرفين في الوسطين نحصل:

$$\sum Y_i = n\bar{Y}, \quad \sum X_i = n\bar{X}$$

وبالتقسيم عن ذلك في المعادلة (7.2) تكون:

$$\begin{aligned} \sum U_i &= \sum Y_i - \sum Y_i + B_1 \sum X_i - B_1 \sum X_i \\ \sum U_i &= 0 \\ E(U_i) &= 0 \end{aligned}$$

2- إن المتغير العشوائي ( $U_i$ ) يتوزع توزيعاً طبيعياً ، Normally distributed حول القيمة المتوقعة أو حول الوسط الحسابي المساوي للصفر عند كل قيمة من قيم المتغير المستقل  $X$  أي بشكل جرس.

3-إن تباين Variance ، المتغير العشوائي (حد الخطأ)، حول الوسط الحسابي مقدار ثابت عند كل قيمة من قيم  $X$  أي:

$$\begin{aligned} var(U_i) &= E[U_i - E(U_i)^2] \\ \therefore E(U_i) &= 0 \\ \therefore var(U_i) &= E(U_i)^2 = 6^2 \end{aligned}$$

وإذا كان تباين الخطأ غير ثابت عندئذ تظهر مشكلة تسمى مشكلة عدم تجانس التباين Heteroscedasticity، والتي سنتناولها بشيء من التفصيل لاحقاً.

الفرضيات الثلاث السابقة يمكن جمعها بشكل مختصر وتمثيلها كالتالي:

$$U_i \sim N(0, \sigma^2)$$

أي بمعنى أن الخطأ العشوائي،  $U_i$ ، يتوزع ~ توزيعاً طبيعياً،  $N$ ، بوسط حسابي مساوي للصفر، 0، وتباين

. $\sigma^2$

4- أن قيم  $U_i$  غير مرتبطة بأي من المتغيرات المستقلة، أي انعدام التباين المشترك Covariance بين

:  $X_i$  و  $U_i$

$$\text{Cov}(U_i X_i) = E(U_i X_i)$$

$$\text{Cov}(U_i X_i) = X_i E(U_i)$$

$$\therefore E(U_i) = 0$$

$$\therefore E(U_i X_i) = 0$$

ويمكن توضيح ذلك على النحو الآتي:

$$Y_i = B_0 + B_1 X_i + U_i \dots \dots \dots (8.2)$$

$$U_i = Y_i - B_0 - B_1 X_i \dots \dots \dots (9.2)$$

: وبضرب طرفي المعادلة ب  $\sum X_i$

$$\sum X_i U_i = \sum X_i Y_i - B_0 \sum X_i - B_1 \sum X_i^2$$

$$\therefore B_0 = \bar{Y} - B_1 \bar{X}$$

: وعند تعويض ذلك :

$$\sum X_i U_i = \sum X_i Y_i - \sum X_i (\bar{Y} - B_1 \bar{X}) - B_1 \sum X_i^2 \dots \dots \dots (10.2)$$

$$\therefore \bar{Y} = \frac{\sum Y_i}{n}, \quad \bar{X} = \frac{\sum X_i}{n}$$

وبتعويض ذلك يكون:

$$\sum X_i U_i = \sum X_i Y_i - \sum X_i \left( \frac{\sum Y_i}{n} - B_1 \frac{\sum X_i}{n} \right) - B_1 \sum X_i^2$$

$$\sum X_i U_i = \sum X_i Y_i \sum X_i \left( \frac{\sum Y_i - B_1 \sum X_i}{n} \right) - B_1 \sum X_i^2$$

$$\sum X_i U_i = \sum X_i Y_i \sum X_i Y_i + B_1 \sum X_i^2 - B_1 \sum X_i^2$$

وبعد الحذف والتبسيط يكون:

$$\sum X_i U_i = 0$$

5- القيم المختلفة للمتغير العشوائي ( $U_i$ ) تكون مستقلة عن بعضها البعض، بعبارة أخرى التباين المشترك  $- U_i$  مع  $U_j$  مساوٍ للصفر، وعليه فإن قيمة العنصر العشوائي في أي فترة لا تعتمد على قيمته في فترة أخرى أي:

$$\text{cov}(U_i U_j) = E(U_i U_j) = 0 \quad (i, j = 1, 2, 3, \dots, n, i \neq j)$$

وإذا حدث وجود ارتباط بينها تظهر مشكلة تسمى مشكلة الارتباط الذاتي Autocorrelation، وسيتم شرحها لاحقاً.

6- انعدام العلاقة بين المتغيرات المستقلة وفي حالة وجود علاقة قوية بينها تظهر مشكلة تسمى مشكلة الارتباط الخطى المتعدد Multicollinearity، والتي سيتم تناولها فيما بعد (بخت علي ،صفحة 39) .

### 3.2 طريقة المرربعات الصغرى (OLS)

بالرجوع إلى العلاقة الخطية بين دخل الأسرة X وإنفاقها على سلعة معينة Y:

$$Y_i = B_0 + B_1 X_i + U_i \dots \dots \dots \quad (11.2)$$

يتبيّن لنا بأن تأثير الدخل في الإنفاق على السلعة موضوع البحث يتحدد من خلال العلاقة المنتظمة  $(B_0 + B_1 X_1)$ ، أما تأثير العوامل الأخرى فإنه متجلّس في  $(U_i)$ .

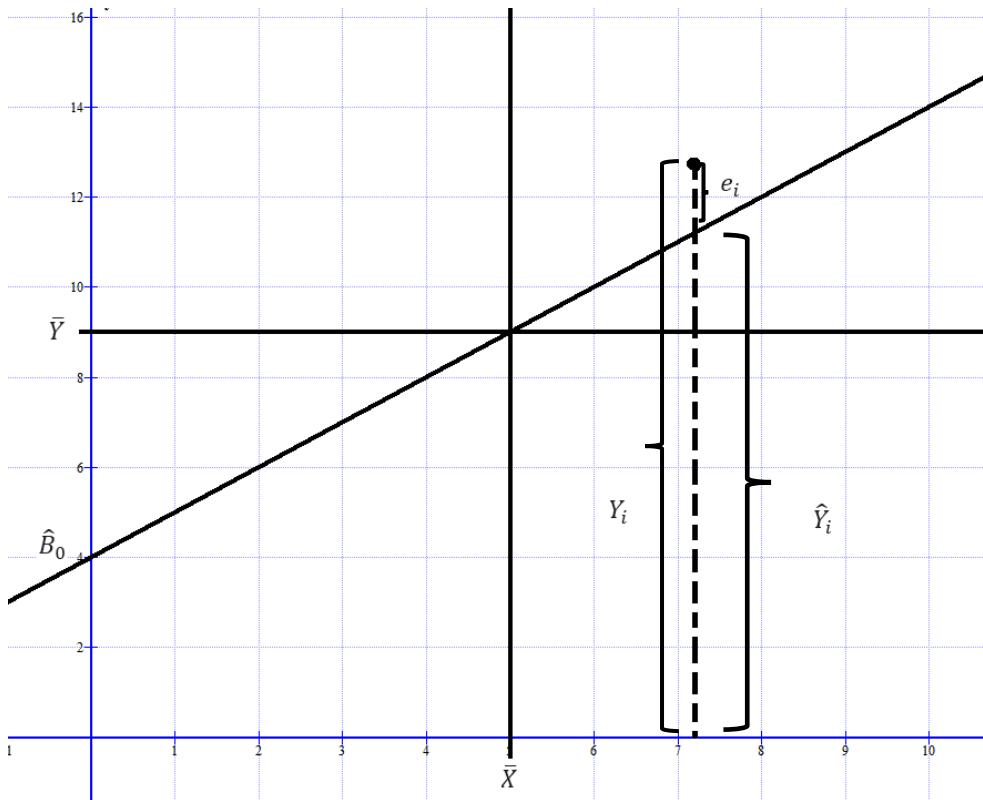
وعليه فإنه لمعرفة العلاقة الحقيقية بين دخل الأسرة وإنفاقها على السلعة في القطر يتطلّب احتساب  $B_0$  و  $B_1$  ، إلا أن احتساب المعالم المذكورة لا يمكن أن يتم إلا في حالة الحصول على دخل وإنفاق جميع الأسر في ذلك القطر وهذا أمر غير ممكن بسبب صعوبة العملية الإحصائية الالزامية ولتسهيل العمل تسحب عينة من أسر القطر، ومن ثم تقدّر قيم المعالم ويتم التقدير بواسطة المعادلة:

$$Y_i = \hat{B}_0 + \hat{B}_1 X_i + e_i \dots \dots \dots \quad (12.2)$$

ولتقدير تأثير الدخل بصورة مستقلة في الإنفاق فإنه يتم بواسطة المعادلة التالية:

$$\hat{Y}_i = \hat{B}_0 + \hat{B}_1 X_i \dots \dots \dots \quad (13.2)$$

تسمى المعادلة (13.2) بمعادلة خط الانحدار، وتشير العلامة (^) إلى كون القيم تقديرية وليس حقيقة وكل نقطة من نقاطه ( $\hat{Y}_i$ ) تمثل القيمة التقديرية لمتوسط إنفاق جميع العوائل ذات الدخل البالغ X . ويتبّين من المعادلتين (12.2) و (13.2) بأن قيم المشاهدات الفعلية  $Y_i$  تتحرف عن القيم التقديرية ( $\hat{Y}_i$ ) بمقدار  $e_i$  وكما مبيّن في الشكل الآتي: الشكل (1.2)



$$e_i = Y_i - \hat{Y}_i$$

حيث يمكن للبواقي  $e_i$  أن تكون سالبة أو موجبة حسب موضع نقطة المشاهدة من الخط المقدر . ولإيجاد أفضل خط مستقيم لعينة مشاهدات  $Y$  ،  $X$  من بين خطوط لا نهائية العدد تصف المعادلة الخطية تستخدم طريقة المربعات الصغرى (OLS)، ويتضمن ذلك في محاولة جعل مجموع مربع انحرافات القيم الحقيقية  $Y_i$  عن القيم التقديرية  $\hat{Y}_i$  أقل ما يمكن، أي جعل مجموع مربعات الأخطاء العشوائية عند نهايتها الصغرى وبما أن طريقة OLS تشرط تصغير القيمة  $(\sum e_i^2)$  إلى الحد الأدنى فإنها عبارة عن مشكلة النهايات الصغرى أي:

$$\min \rightarrow \sum_{i=1}^n e_i^2$$

$$e_i = Y_i - \hat{Y}_i$$

$$\sum e_i^2 = \sum (Y_i - \hat{Y}_i)^2 \quad \text{إذا:}$$

بما أن معادلة الخط المستقيم الحقيقية غير المعروفة هي:

فإن معادلة الخط المستقيم التقديرية تكون:

بالتعميض عن  $\hat{Y}_i$  بما يساويها نحصل:

$$\sum e_i^2 = \sum (\hat{Y}_i - \hat{B}_0 - \hat{B}_1 X_i)^2$$

وشرط رياضي لتصغير  $\sum e_i^2$  تؤخذ المشتقات الجزئية لكل من  $\hat{B}_0$  و  $\hat{B}_1$  ومساواة كل منها بالصفر.

، Coefficient وإن الشرط الجوهرى للتصغير هوأخذ التقابل الجزئي لمجموع المربعات بالنسبة لمعاملات النموذج  $\hat{B}_0$  و  $\hat{B}_1$  ومساواة المشتقه الأولى بالصفر.

أى بتطبيق الشرط الضروري:

$$\frac{\partial \sum e_i^2}{\partial \hat{B}_0} = 2 \sum (Y_i - \hat{B}_0 - \hat{B}_1 X_i)(-1) = 0$$

$$-2 \sum (Y_i - \hat{B}_0 - \hat{B}_1 X_i) = 0$$

بالقسمة على (2) وفك القوس وترتيب المعادلة نحصل على:

$$\begin{aligned} \sum (Y_i - \hat{B}_0 - \hat{B}_1 X_i) &= 0 \\ \sum Y_i - n\hat{B}_0 - \hat{B}_1 \sum X_i &= 0 \\ \sum Y_i &= n\hat{B}_0 + \hat{B}_1 \sum X_i \dots \dots \dots (14.2) \end{aligned}$$

$$\frac{\partial \sum e_i^2}{\partial \hat{B}_1} = 2 \sum (Y_i - \hat{B}_0 - \hat{B}_1 X_i)(-X_i) = 0$$

$$-2 \sum X_i (Y_i - \hat{B}_0 - \hat{B}_1 X_i) = 0$$

بالقسمة على (2) نحصل على :

$$\begin{aligned} \sum X_i (Y_i - \hat{B}_0 - \hat{B}_1 X_i) &= 0 \\ \sum X_i Y_i - \hat{B}_0 \sum X_i - \hat{B}_1 \sum X_i^2 &= 0 \\ \sum X_i Y_i &= \hat{B}_0 \sum X_i - \hat{B}_1 \sum X_i^2 \dots \dots \dots (15.2) \end{aligned}$$

تسمى المعادلتين (14.2) و (15.2) بالمعادلتين الطبيعيتين (الآنبيتين) حيث ( $n$ ) عدد المشاهدات  $X_i$  و  $Y_i$  هي معلومة دائمًا باعتبارهما قيم المشاهدات الحقيقية وب مجرد تعويضهما في المعادلتين (14.2) و (15.2)

وبحلهما آنئًا نحصل على قيم  $\hat{B}_0$  و  $\hat{B}_1$  اللتان تمثلان مقدرتان للمعلمتين الحقيقيتين  $B_0$  و  $B_1$ .

### 1.3.2 طرق تقدير معاملات النموذج:

ولتقدير معاملات النموذج  $B_0$  و  $B_1$  نستعين بعدة طرق منها:

1 - طريقة الحذف والتعويض.

2 - طريقة المحددات.

3 - طريقة التقدير حول نقطة المتوسط.

4 - طريقة المصفوفات.

و سنين هذه الطرق من خلال المثال الآتي، من دون تكرارها هنا وهناك.

**مثال 1.2:** الجدول الآتي يمثل عدد سنوات الخدمة ( $X_I$ ) ومعدل الأجر السنوي ( $Y_I$ ) بآلاف الدنانير لعينة

تمثل (8) موظفين في أحد الدوائر.

$X_i$	$Y_i$	$X_i Y_i$	$X_i^2$
4	25.6	102.4	16
8	32.7	261.6	64
12	45.4	544.8	144
16	53.9	862.4	256
20	59.0	1180	400
24	62.6	1502.4	576
28	65.0	1820	784
32	65.5	2105.6	1024
$\sum X_i = 144$	$\sum Y_i = 410$	$\sum X_i Y_i = 8379.2$	$4 \sum X_i^2 = 326$
$\bar{X} = 18$	$\bar{Y} = 51.25$		

المطلوب : تقدير خط الانحدار بواسطة المعادلتين الطبيعيتين أعلاه.

### 1.1.3.2 طريقة الحذف والتعويض :Substitution Method

$$\sum Y_i = n\hat{B}_0 + \hat{B}_1 \sum X_i \dots \dots \dots \quad (16.2)$$

$$\sum X_i Y_i = \hat{B}_0 \sum X_i + \hat{B}_1 \sum X_i^2 \dots \dots \quad (17.2)$$

وبتعويض القيم من الجدول في المعادلتين 16.2 ، 17.2 نحصل على:

$$410 = 8\hat{B}_0 + 144\hat{B}_1 \dots \dots \dots \quad (18.2)$$

$$8379.2 = 144\hat{B}_0 + 3264\hat{B}_1 \dots \dots \dots \quad (19.2)$$

وبضرب المعادلة (18.2) في 18 نحصل:

$$7380 = 144\hat{B}_0 + 2592\hat{B}_1 \dots \dots \dots \quad (20.2)$$

$$8379.2 = 144\hat{B}_0 + 3264\hat{B}_1 \dots \dots \dots \quad (21.2)$$

وبطرح المعادلة (20.2) من (21.2) نحصل:

$$999.2 = 672\hat{B}_1$$

$$\hat{B}_1 = \frac{999.2}{672} = 1.486904762$$

للحصول على قيمة  $\hat{B}_0$  نعوض عن قيمة  $\hat{B}_1$  في أحد المعادلتين الرئيسيتين ولتكن معادلة (18.2) :

$$410 = 8\hat{B}_0 + 144\hat{B}_1$$

$$410 = 8\hat{B}_0 + 144(1.486904762)$$

$$410 = 8\hat{B}_0 + 214.1142857$$

$$410 - 214.1142857 = 8\hat{B}_0$$

$$195.8857143 = 8\hat{B}_0$$

$$\hat{B}_0 = \frac{195.8857143}{8} = 24.48571429$$

وعليه فإن المعادلة المقدرة Estimated، للعلاقة بين عدد سنوات الخدمة  $X_i$  ومعدل الأجر السنوي  $Y_i$

للعينة المعنية تكون:

$$\hat{Y}_i = \hat{B}_0 + \hat{B}_1 X_i$$

$$\hat{Y}_i = 24.48571429 + 1.486904762 X_i$$

تشير المعادلة التقديرية إلى وجود علاقة طردية بين المتغير التابع  $y_i$  الذي يمثل معدل الأجر السنوي للموظف والمتغير المستقل  $X_i$  الذي يمثل عدد سنوات الخدمة، فزيادة خدمته الوظيفية بمقدار سنة واحدة يزداد معدل أجره السنوي بمقدار 1486 دينار.

### 2.1.3.2 طريقة المحددات :Determinates Method

ويمكن الحصول على قيم  $\hat{B}_0$  و  $\hat{B}_1$  باعتماد المحددات (قاعدة كرايمرو) وذلك بإعادة كتابة المعادلتين

الطبيعيتين (16.2) و (17.2) في صيغة مصفوفة وعلى النحو الآتي:

$$\sum Y_i = n\hat{B}_0 + \hat{B}_1 \sum X_i$$

$$\sum X_i Y_i = \hat{B}_0 \sum X_i + \hat{B}_1 \sum X_i^2$$

$$\begin{bmatrix} \sum Y_i \\ \sum X_i Y_i \end{bmatrix} = \begin{bmatrix} n & \sum X_i \\ \sum X_i & \sum X_i^2 \end{bmatrix} \begin{bmatrix} \hat{B}_0 \\ \hat{B}_1 \end{bmatrix}$$

ولتقدير  $\hat{B}_1$  و  $\hat{B}_0$  ينبغي تكوين المحددات الآتية:

$$|D| = \begin{vmatrix} n & \sum X_i \\ \sum X_i & \sum X_i^2 \end{vmatrix} = (n)(\sum X_i^2) - (\sum X_i)(\sum X_i)$$

$$|A_0| = \begin{vmatrix} \sum Y_i & \sum X_i \\ \sum X_i Y_i & \sum X_i^2 \end{vmatrix} = (\sum Y_i)(\sum X_i^2) - (\sum X_i Y_i)(\sum X_i)$$

$$|A_1| = \begin{vmatrix} n & \sum Y_i \\ \sum X_i & \sum X_i Y_i \end{vmatrix} = (n)(\sum X_i Y_i) - (\sum X_i)(\sum Y_i)$$

$$\hat{B}_1 = \frac{|A_1|}{|D|} = \frac{n(\sum X_i Y_i) - (\sum Y_i)(\sum Y_i)}{n(\sum X_i^2) - (\sum X_i)^2}$$

$$\hat{B}_0 = \frac{|A_0|}{|D|} = \frac{(\sum Y_i)(\sum X_i^2) - (\sum X_i Y_i)(\sum X_i)}{n(\sum X_i^2) - (\sum X_i)^2}$$

or:  $\hat{B}_0 = \bar{Y} - \hat{B}_1 \bar{X}$

بالرجوع إلى بيانات المثال (1.2) وباعتماد المحددات نحصل على قيم  $\hat{B}_0$  و  $\hat{B}_1$  وكما يلي:

$$\begin{bmatrix} \sum Y_i \\ \sum X_i Y_i \end{bmatrix} \begin{bmatrix} n & \sum X_i \\ \sum X_i & \sum X_i^2 \end{bmatrix} \begin{bmatrix} \hat{B}_0 \\ \hat{B}_1 \end{bmatrix}$$

$$|D| = \begin{vmatrix} n & \sum X_i \\ \sum X_i & \sum X_i^2 \end{vmatrix} = \begin{vmatrix} 8 & 144 \\ 144 & 3264 \end{vmatrix}$$

$$|D| = (8)(3264) - (144)(144)$$

$$|D| = 26112 - 20736$$

$$|D| = 5376$$

$$|A_0| = \begin{vmatrix} \sum Y_i & \sum X_i \\ \sum X_i Y_i & \sum X_i^2 \end{vmatrix} = \begin{vmatrix} 410 & 144 \\ 8379.2 & 3254 \end{vmatrix}$$

$$|A_0| = (410)(3264) - (144)(9379.2)$$

$$|A_0| = 1338240 - 1206604.8$$

$$|A_0| = 131635.2$$

$$|A_1| = \begin{vmatrix} n & \sum Y_i \\ \sum X_i & \sum X_i Y_i \end{vmatrix} = \begin{vmatrix} 8 & 410 \\ 144 & 8379.2 \end{vmatrix}$$

$$|A_1| = (8)(8379.2) - (410)(144)$$

$$|A_1| = 67033.6 - 59040$$

$$|A_1| = 7993.6$$

$$\hat{B}_0 = \frac{|A_0|}{|D|} = \frac{131635.2}{5376} = 24.48571429$$

$$\hat{B}_1 = \frac{|A_1|}{|D|} = \frac{7993.6}{5376} = 1.486901762$$

وبذلك تكون المعادلة التقديرية:

$$\therefore \hat{Y}_i = 24.4857 + 1.486X_i$$

### 3.1.3.2 طريقة التقدير حول نقطة المتوسط:

كما يمكن تقدير  $\hat{B}_0$  و  $\hat{B}_1$  بواسطة انحرافات المتغيرين  $Y_i$  و  $X_i$  عن وسطهما الحسابي  $\bar{Y}$  و  $\bar{X}$  باستخدام فكرة الباقي  $e_i$  فبقسمة المعادلة الطبيعية رقم (1) على  $n$  نحصل على:

$$\sum Y_i = n\hat{B}_0 + \hat{B}_1 \sum X_i \dots \dots \dots \quad (22.2)$$

$$\frac{\sum Y_i}{n} = \hat{B}_0 \frac{n}{n} + \hat{B}_1 \frac{\sum X_i}{n}$$

$$\bar{Y} = \hat{B}_0 + \hat{B}_1 \bar{X} \dots \dots \dots \quad (23.2)$$

$$\therefore \hat{B}_0 = \bar{Y} - \hat{B}_1 \bar{X} \dots \dots \dots \quad (24.2)$$

ولإيجاد  $\hat{B}_1$  نعود إلى معادلة الخط المستقيم التقديرية حيث:

$$\hat{Y}_i = \hat{B}_0 + \hat{B}_1 X_i \dots \dots \dots \quad (25.2)$$

وبطرح المعادلة رقم (23.2) من (25.2) نحصل على:

$$\hat{Y}_i - \bar{Y} = \hat{B}_0 + \hat{B}_1 X_i - \hat{B}_0 - \hat{B}_1 \bar{X} \dots \dots \dots \quad (26.2)$$

$$\hat{Y}_i - \bar{Y} = \hat{B}_1 X_i - \hat{B}_1 \bar{X}$$

$$\hat{Y}_i - \bar{Y} = \hat{B}_1 (X_i - \bar{X})$$

$$\hat{y}_i = \hat{B}_1 X_i \dots \dots \dots \quad (27.2)$$

$$\therefore e_i = y_i - \hat{y}_i$$

$$e_i = y_i - \hat{B}_1 x_i \dots \dots \dots \quad (28.2)$$

وبإدخال  $\Sigma$  وتربيع الطرفين:

$$\sum e_i^2 = \sum (y_i - \hat{B}_1 x_i)^2 \dots \dots \dots \quad (29.2)$$

لإيجاد المشتقية الجزئية  $\frac{\partial}{\partial \hat{B}_1}$  ومساواتها بالصفر:

$$\frac{\partial \sum e_i^2}{\sum \hat{B}_1} = 2 \sum (y_i - \hat{B}_1 x_i)(-x_i) = 0 \dots \dots \dots \quad (30.2)$$

$$-2 \sum x_i (y_i - \hat{B}_1 x_i) = 0$$

وبالقسمة على (-2) :

$$\sum x_i (y_i - \hat{B}_1 x_i) = 0$$

$$\sum x_i y_i - \hat{B}_1 \sum x_i^2 = 0$$

$$\sum x_i y_i = \hat{B}_1 \sum x_i^2$$

حيث أن  $\sum x_i y_i$  تمثل مجموع حاصل ضرب انحرافات القيم عن الوسط الحسابي للمتغيرين  $X_i$  و  $Y_i$  وأن

$\sum x_i^2$  تمثل مجموع مربع الانحرافات لقيمة المتغير  $X_i$  عن وسطه الحسابي. وعليه فإن المعادلتين (24.2)

و(31.2) هي المعادلات الأساسية التي تستخدم في إيجاد قيم  $\hat{B}_0$  و  $\hat{B}_1$  بموجب طريقة الانحرافات.

وبالرجوع إلى بيانات الجدول (1.2) والتعبير عنها بصيغة انحرافات يمكن الحصول على قيم  $\hat{B}_0$  و  $\hat{B}_1$  كما يأتي:

$X_i$	$Y_i$	$x_i$	$y_i$	$x_i y_i$	$x_i^2$
4	25.6	-14	-25.65	359.1	196
8	32.7	-10	-18.55	185.5	100
12	45.4	-6	-5.85	35.1	36
16	53.9	-2	2.65	-5.3	4
20	59.0	2	7.75	15.5	4
24	62.6	6	11.35	68.1	36
28	65.0	10	13.75	137.5	100
32	68.5	14	14.55	203.7	196
$\sum X_i = 144$	$\sum Y_i = 410$	$\sum x_i = 0$	$\sum y_i = 0$	$\sum x_i y_i = 999.2$	$\sum x_i^2 = 672$
$\bar{X} = 18$	$\bar{Y} = 51.25$	$x_i = X - \bar{X}$	$y_i = Y - \bar{Y}$		

$$\hat{B}_1 = \frac{\sum x_i y_i}{\sum x_i^2} = \frac{999.2}{672} = 1.486904762$$

$$\hat{B}_1 = \bar{Y} - \hat{B}_1 \bar{X}$$

$$\hat{B}_0 = 51.25 - (1.486904762)(18)$$

$$\hat{B}_0 = 51.25 - 26.76428572$$

$$\hat{B}_0 = 24.48571428$$

$$\therefore \hat{Y}_i = 24.485 + 1.486 X_i$$

#### 4.1.3.2 طريقة المصفوفات :Matrices Method

إضافة إلى الطرق السابقة فإنه يمكن تقدير قيم  $\hat{B}_0$  و  $\hat{B}_1$  باعتماد صيغة المصفوفات حيث يمكن كتابة المعادلات الطبيعية على شكل مصفوفات Matrices ومتغيرات Vectors، وكما يلي (بختي

علي ، 2009 صفحة 50) :

نفترض أن هناك علاقة تحتوي على  $i$  من المشاهدات من  $1 \leftarrow n$  وأن هناك عدد من المتغيرات من

$$.K \leftarrow 1$$

$$Y_i = B_0 + B_1 X_i + U_i \dots \dots \dots \dots \quad (32.2)$$

$$Y_1 = B_0 + B_1 X_{11} + B_2 X_{12} + \dots + B_k X_{1K} + U_1$$

$$Y_2 = B_0 + B_1 X_{21} + B_2 X_{22} + \dots + B_k X_{2K} + U_2$$

$$\vdots \quad \vdots \quad \vdots \quad \vdots \quad \vdots \quad \vdots$$

$$Y_n = B_0 + B_1 X_{n1} + B_2 X_{n2} + \dots + B_k X_{nK} + U_n$$

يمكن تمثيل هذه المعادلات بصيغة رمز المصفوفات:

$$\begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} 1 & X_{11} & X_{12} & \cdots & X_{1k} \\ 1 & X_{21} & X_{22} & \cdots & X_{2k} \\ \vdots & \vdots & \vdots & & \vdots \\ 1 & X_{n1} & X_{n2} & \cdots & X_{nk} \end{bmatrix} \begin{bmatrix} B_0 \\ B_1 \\ \vdots \\ B_k \end{bmatrix} + \begin{bmatrix} U_1 \\ U_2 \\ \vdots \\ U_n \end{bmatrix}$$

$Y = XB + U \dots \dots \dots \quad (33.2)$

حيث أن:

$Y$  : متوجه عمودي أبعاده ( $nx1$ ) يحتوي على  $n$  مشاهدة للمتغير التابع  $Y$ .

$X$  : مصفوفة أبعادها ( $n \times k + 1$ ) تحتوي مشاهدات المتغيرات المستقلة  $X$ . وعمودها الأول يحتوي على قيم الواحد. صحيح لأن الثابت بنظر الاعتبار.

$B$  : منحه عمودي أبعاده ( $1 \times k + 1$ ) تحتوي المعالم المجهولة.

$U$  : سبحة عمودي أبعاده ( $nx1$ ) يحتوي الخطأ العشوائي.

وللحصول على تقديرات المربعات الصغرى العادية لمتجه المعلمات يمكن كتابة المعادلة المقدرة التي يراد الحصول عليها وبصيغة المصفوفات كما يلي:

$$Y = \hat{Y} + e$$

$$Y = X\hat{B} + e$$

$$\therefore e = Y - X\hat{B} \dots \dots \dots \quad (34.2)$$

وباستخدام المبدلة  $L$   $e$

$$e'e = (Y - X\hat{B})'(Y - X\hat{B})$$

$$e'e = (Y' - \hat{B}'X')(Y - X\hat{B})$$

$$e'e = Y'Y - \hat{B}'X'Y - Y'X\hat{B} + \hat{B}'X'X\hat{B} \dots \dots \dots \quad (35.2)$$

بما أن الحد الثاني والثالث يمثلان قيمة واحدة وأن كل حد يمثل مبدلة لآخر فإن:

$$[\hat{B}'X'Y = (\hat{B}'X'Y)' = \hat{B}XY']$$

$$\therefore e'e = Y'Y - 2\hat{B}'X'Y + \hat{B}'X'X\hat{B} \dots \dots \dots \quad (36.2)$$

ولما كانت  $\hat{B}' = (\hat{B}')' = \hat{B}$

وبأخذ المشقة الجزئية  $L'$  ومساواتها بالصفر :

$$2X'X\hat{B} = 2X'Y$$

وبقسمة طرفي المعادلة على (2) نحصل:

$$X'X\hat{B} = X'Y$$

وبضرب طرفي المعادلة بالمعكوس  $(X'X)^{-1}$  نحصل:

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

وبما أن حاصل ضرب المعكوس  $(X'X)^{-1}$  في المصفوفة  $X'X$  يساوي مصفوفة الوحدة 1 ، إذاً المعادلة

$$\therefore \hat{B} = (X'X)^{-1}X'Y \dots \dots \dots \quad (37.2)$$

أعلاه تصبح:

حيث أن:

$\hat{B}$ : تمثل معاملات الانحدار المطلوب تقديرها.

$(X'X)^{-1}$  : تمثل معكوس المصفوفة  $(X'X)$ .

$X'Y$ : تمثل المتوجه.

وبالرجوع إلى البيانات الواردة في الجدول (1.2) وباعتماد صيغة المصفوفات يمكن الحصول على قيم  $\hat{B}_0$

وكلالاتي :

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

$$(X'X) = \begin{bmatrix} 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 4 & 8 & 12 & 16 & 20 & 24 & 28 & 32 \end{bmatrix} \begin{bmatrix} 1 & 4 \\ 1 & 8 \\ 1 & 12 \\ 1 & 16 \\ 1 & 20 \\ 1 & 24 \\ 1 & 28 \\ 1 & 32 \end{bmatrix}$$

$$(X'X) = \begin{bmatrix} 8 & 144 \\ 144 & 3264 \end{bmatrix}$$

$$(X'X)^{-1} = \frac{1}{|X'X|} adj X'X$$

$$|X'X| = \begin{bmatrix} 8 & 144 \\ 144 & 3264 \end{bmatrix} = (8)(3264) - (144)(144)$$

$$|X'X| = 26112 - 20736$$

$$|X'X| = 5376$$

$$adj X'X = \begin{bmatrix} 3264 & -144 \\ -144 & 8 \end{bmatrix}$$

$$(X'X)^{-1} = \frac{1}{5376} \begin{bmatrix} 3264 & -144 \\ -144 & 8 \end{bmatrix}$$

$$(X'X)^{-1} = \begin{bmatrix} 0.607142857 & -0.026785714 \\ -0.026785714 & 0.001488095 \end{bmatrix}$$

$$X'X = \begin{bmatrix} 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 4 & 8 & 12 & 16 & 20 & 24 & 28 & 32 \end{bmatrix} \begin{bmatrix} 25.6 \\ 32.7 \\ 45.4 \\ 53.9 \\ 59.0 \\ 62.6 \\ 65.0 \\ 65.8 \end{bmatrix}$$

$$X'Y = \begin{bmatrix} 410 \\ 8379.2 \end{bmatrix}$$

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

$$\hat{B} = \begin{bmatrix} 0.607142857 & -0.026785714 \\ -0.026785714 & 0.001488095 \end{bmatrix} \begin{bmatrix} 410 \\ 8379.2 \end{bmatrix}$$

$$\begin{bmatrix} \hat{B}_0 \\ \hat{B}_1 \end{bmatrix} = \begin{bmatrix} 248.9285714 & +(-224.4428547) \\ -10.98214274 & +12.46904562 \end{bmatrix}$$

$$\begin{bmatrix} \hat{B}_0 \\ \hat{B}_1 \end{bmatrix} = \begin{bmatrix} 24.48571 \\ 1.48690 \end{bmatrix}$$

$$\therefore \hat{Y}_i = 24.485 + 1.486 X_i$$

يتضح مما سبق بأن النتائج التي تم التوصل إليها في المعادلة التقديرية هي نفسها تماماً بالطرق الأربع الآتية الذكر.

### 2-3-2 الخواص الأساسية لمقدرات المربعات الصغرى:

في كل تقدير يتم الحصول عليه، هناك خصائص عدة مرغوب فيها لذلك التقدير، ومن هذه الخصائص خاصية أفضل مقدر خطى غير متحيز، Best Linear Unbiased Estimator (BLUE) فكل مقدر ( $\hat{B}$ ) يمكن التعبير عنه كدالة خطية بالنسبة لمشاهدات المتغير التابع ( $Y$ )، أي أن:

$$\hat{B} = K_1 Y_1 + K_2 Y_2 + \dots + K_n Y_n$$

حيث أن:  $K_i$ ،  $i = 1, 2, \dots, n$  عبارة عن أوزان أو قيم ثابتة. ومن بين جميع المقدرات الخاملية نبحث عن المقدرات غير المتحيز، ونقصد بعدم التحيز هو أن يكون الفرق بين القيمة المتوقعة للمقدر وقيمة المعلمة

$$I: (B) = B - 0 \quad \text{أي:}$$

وأفضل مقدر هو ذلك المقدر الذي يكون تباينه حول الوسط الحسابي أقل ما يمكن فإذا كان  $B^*$

مقدرات خطية غير متحيز فإن  $\hat{B}$  أفضل مقدر إذا تحققت العلاقة الآتية:

$$var(\hat{B}) < var(B^*)$$

وسوف نتناول أدناه هذه الخصائص بشيء من التفصيل:

#### 1.2.3.2 الخواص الخطية :Linearity Property

مقدرات المربعات الصغرى خطية في المتغير التابع حيث نلاحظ أن تلك المقدرات يمكن وصفها في صورة

دالة أو ترتيب خطى من قيم المتغير  $Y$ ، أي:

$$\hat{B}_1 = K_1 Y_1 + K_2 Y_2 + \dots + K_n Y_n$$

$$\therefore \hat{B}_1 = \sum_{i=1}^n K_i Y_i$$

$$\therefore \hat{B}_1 = \frac{\sum x_i y_i}{\sum x_i^2}$$

وأن: للمشاهدة الواحدة:

$$\therefore \hat{B}_1 = \frac{\sum x_i (Y_i - \bar{Y})}{\sum x_i^2} = \frac{\sum x_i Y_i}{\sum x_i^2} - \frac{\bar{Y} \sum x_i}{\sum x_i^2}$$

$$\therefore \sum x_i = \sum (X_i - \bar{X}) = 0$$

$$\therefore \frac{\bar{Y} \sum x_i}{\sum x_i^2} = 0$$

$$\hat{B}_1 = \frac{\sum x_i y_i}{\sum x_i^2} = \sum \left[ \frac{x_i}{\sum x_i^2} Y_i \right] \quad \text{لذلك تكون:}$$

ولما كانت قيم  $X$  ثابتة نجد أن:  $\frac{\sum x_i}{\sum x_i^2}$  هي مقادير ثابتة، ويمكن أن نرمز لها بالرمز  $K_i$ ، وهي ثابتة في

$$K_i = \frac{x_i}{\sum x_i^2} \quad \text{كل العينات، أي:}$$

$Y_i$  مجموع مرجح لقيمة المتغير التابع،  $\hat{B}_1$

$$\therefore \hat{B}_1 = \sum K_i Y_i$$

$$\therefore \hat{B}_1 = F(Y_i)$$

إذاً  $\hat{B}_1$  هو مقدر خططي.

### خصائص الأوزان : Weighted Properties

وبما أن الأوزان تعتمد على قيم  $X$  الثابتة فقط فإنها تعتبر ثابتة أيضاً، وتت雪花ض  $K_i$  للشروط الآتية:

1-مجموع الأوزان يساوي صفر، أي أن:

$$\sum_{i=1}^n K_i = 0$$

إذاً:

$$\therefore K_i = \frac{x_i}{\sum x_i^2}$$

$$\therefore x_i = \sum (X_i - \bar{X}) = 0$$

وبالتعمييض، فإن:

$$\therefore \sum K_i = \frac{0}{\sum x_i^2} = 0$$

- مجموع حاصل الضرب للأوزان ( $K$ ) في قيم المتغير المستقل ( $X_i$ ) أو في انحرافاتها عن متوسطها الحسابي ( $x_i$ ) يساوي الواحد صحيح، أي:

$$\sum_{i=1}^n K_i X_i = \sum_{i=1}^n k_i x_i = 1$$

$$\sum K_i x_i = \sum K_i (X_i - \bar{X}) = \sum K_i X_i - \bar{X} \sum K_i$$

وقد بينا سابقاً أن:

$$\therefore \sum K_i X_i = 0$$

$$\therefore \sum K_i x_i = \sum K_i X_i$$

وبما أن:

$$\therefore K_i = \frac{x_i}{\sum x_i^2}$$

إذاً:

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

لذلك تكون:

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

$$\therefore \sum_{i=1}^n K_i x_i = \sum_{i=1}^n K_i X_i = 1$$

- مجموع مربعات الأوزان  $\sum K_i^2$ ، يساوي معكوس مجموع مربعات انحرافات المتغير المستقل  $\frac{1}{\sum x_i^2}$ ، أي

أن:

$$K_i = \frac{x_i}{\sum x_i^2} = \frac{(X_i - \bar{X})}{\sum (X_i - \bar{X})^2}$$

وعند تربيع الطرفين، ثم جمعهما، يكون:

$$\sum K_i^2 = \frac{\sum (X_i - \bar{X})^2}{[\sum (X_i - \bar{X})^2]^2}$$

وبعد الاختصار والترتيب:

$$\sum K_i^2 = \frac{1}{\sum (X_i - \bar{X})^2} = \frac{1}{\sum x_i^2}$$

وبطريقة مماثلة يمكن البرهنة بأن  $\hat{B}_0$  دالة خطية من قيم المتغير  $Y$ .

$$\begin{aligned}\hat{B}_0 &= W_1 Y_1 + W_2 Y_2 \dots \dots + W_n Y_n \\ \therefore \hat{B}_0 &= \sum_{i=1}^n W_i Y_i \\ \therefore \hat{B}_0 &= \bar{Y} - \hat{B}_1 \bar{X}\end{aligned}$$

وأن:

$$\begin{aligned}\bar{Y} &= \frac{\sum Y_i}{n}, \hat{B}_1 = \sum K_i Y_i \\ \therefore \hat{B}_0 &= \frac{\sum Y_i}{n} - \bar{X} \sum K_i Y_i\end{aligned}$$

ومن خلال إعادة الترتيب، نحصل:

$$\hat{B}_0 = \sum \left[ \frac{1}{n} - \bar{X} K_i \right] Y_i$$

ولما كانت  $K_i, \bar{X}$  مقادير ثابتة، نرمز لها بالرمز  $W_i$ ، أي أن:

$$W_i = \left[ \frac{1}{n} - \bar{X} K_i \right]$$

وبتعويض ذلك في المعادلة أعلاه، نجد أن  $\hat{B}_0$  تعتمد على قيم  $Y_i$  فقط، بعبارة أخرى:

$$\begin{aligned}\hat{B}_0 &= \sum W_i Y_i \\ \therefore \hat{B}_0 &= F(Y_i)\end{aligned}$$

إذاً  $\hat{B}_0$  هو مقدر خطيء.

### (نظير مذكور 2006-2007، صفحة 22) : Unbiasedness Property 2.2.3.2

تقصد بعدم التحيز هو أن يكون الفرق بين القيمة المتوقفة للمقدر  $E(\hat{B})$  وقيمة المعلمة الحقيقية للمجتمع

$$E(\hat{B}) - B = 0 \quad \text{أي: الإحصائي } (B) \text{ يساوي صفر، أي:}$$

$E(\hat{B}) = B$  يعني المقدر غير متحيز إذا كان وسطها يساوي القيمة الحقيقة للمعلمة:

ولإثبات خاصية عدم التحيز بالنسبة  $\hat{B}_1$  نتبع ما يلي:

$$\hat{B}_1 = \sum K_i Y_i \quad \text{من خاصية الخطية:}$$

$Y_i = B_0 + B_1 X_i + U_i \quad \text{وباستحضار المعادلة:}$

$$\hat{B}_1 = \sum K_i (B_0 + B_1 X_i + U_i) \quad \text{وبتعويض ذلك في أعلاه:}$$

وبفتح القوس نحصل:

$$\hat{B}_1 = B_0 \sum K_i + B_1 \sum K_i X_i + \sum K_i U_i \dots \dots \dots \quad (38.2)$$

وباستخدام شروط الأوزان فإن:

$$\begin{aligned}\sum K_i &= 0 \\ B_0 \sum K_i &= 0 \\ \sum K_i X_i &= 1\end{aligned}$$

وبتعويض ذلك في المعادلة (38.2)، نحصل :

$$\therefore \hat{B}_1 = B_1 + \sum K_i U_i \dots \dots \dots \quad (39.2)$$

وبأخذ توقع طرفي المعادلة :

$$E(\hat{B}_1) = B_1 + \sum K_i E(U_i)$$

من فرضيات الخطأ العشوائي :

$$\begin{aligned}\therefore E(U_i) &= 0 \\ \therefore EK_i E(U_i) &= 0 \\ \therefore E(\hat{B}_1) &= B_1 \dots \dots \dots \dots \quad (40.2)\end{aligned}$$

ويعني ذلك أن  $\hat{B}_1$  هو تقدير غير متحيز للقيمة الأصلية،  $B$ .

إثبات خاصية عدم التحيز لـ  $\hat{B}_0$  :

وبنفس المنهجية يمكن البرهنة بأن  $\hat{B}_0$  تعتبر مقدرة غير متحيز للمعلمة الحقيقية  $B_0$ .

من الخاصية الخطية يتبيّن لنا :

$$\begin{aligned}\hat{B}_0 &= \sum W_i Y_i \\ W_i &= \left[ \frac{1}{n} - \bar{X} K_i \right]\end{aligned}$$

وأن :

$$Y_i = B_0 + B_1 X_i + U_i$$

وعند التعويض نحصل :

$$\therefore \hat{B}_0 = \sum \left[ \frac{1}{n} - \bar{X} K_i \right] [B_0 + B_1 X_i + U_i]$$

وعند فك الأقواس والتعويض، نحصل :

$$\hat{B}_0 = B_0 - B_0 \bar{X} \sum K_i + B_1 \bar{X} - \bar{X} B_1 \sum K_i X_i + \sum \left( \frac{1}{n} - \bar{X} K_i \right) U_i \dots \dots \quad (41.2)$$

وباستخدام شروط الأوزان :

$$\begin{aligned}\therefore \sum K_i &= 0 \\ \therefore B_0 \bar{X} \sum K_i &= 0\end{aligned}$$

$$\begin{aligned} & \because \sum K_i X_i = 1 \\ \therefore \hat{B}_0 &= B_0 + \sum \left( \frac{1}{n} - \bar{X} K_i \right) U_i \dots \dots \dots (42.2) \end{aligned}$$

وبأخذ توقع طرفي المعادلة:

$$\begin{aligned} E(\hat{B}_0) &= B_0 + \sum \left( \frac{1}{n} - \bar{X} K_i \right) E(U_i) \\ &\because E(U_i) = 0 \\ \therefore \sum \left( \frac{1}{n} - \bar{X} K_i \right) E(U_i) &= 0 \\ \therefore E(\hat{B}_0) &= B_0 \dots \dots \dots (43.2) \end{aligned}$$

ويعني ذلك أن  $\hat{B}_0$  هو تقدير غير متحيز للقيمة الأصلية،  $B_0$

### 3.2.3.2 خاصية أفضل مقدر أقل تباين :Best Minimum Variance

إن مفهوم تباين المعالم يحدد بواسطة الانحراف بين المعالم المقدرة لـ  $B$  وقيمتها المتوقعة.  $E(\hat{B})$

بالنسبة لـ  $\hat{B}_1$  فإن (نظير مذكور 2006-2007 صفحة 28) :

$$var(\hat{B}_1) = E[\hat{B}_1 - E(\hat{B}_1)]^2 \dots \dots \dots (44.2)$$

من خاصية عدم التحيز :

$$var(\hat{B}_1) = E[\hat{B}_1 - B_1]^2 \dots \dots \dots (45.2)$$

بالرجوع إلى المعادلة (39.2) من خاصية عدم التحيز والخاصة بـ  $\hat{B}_1$  نجد أن:

$$\begin{aligned} \hat{B}_1 &= B_1 + \sum K_i U_i \\ \hat{B}_1 - B_1 &= \sum K_i U_i \end{aligned}$$

بتربيع الطرفين:

$$(\hat{B}_1 - B_1)^2 = \left( \sum K_i U_i \right)^2$$

وبأخذ توقع طرفي المعادلة:

$$\begin{aligned} E(\hat{B}_1 - B_1)^2 &= E \left( \sum K_i U_i \right)^2 \\ var(\hat{B}_1) &= E \left[ \sum K_i U_i \right]^2 \dots \dots \dots \dots \dots (46.2) \end{aligned}$$

وبفك القوس، نحصل:

$$var(\hat{B}_1) = \sum K_i^2 (U_i)^2 + 2 \sum_{i < j} \sum K_i U_j E(U_i U_j)$$

ومن فرضيات الخطأ العشوائي أن:

$$E(U_i)^2 = \sigma^2$$

$$E(U_i U_j) = 0 \quad \text{For all } i \neq j \quad \text{وأن:}$$

$$\therefore \text{var}(\hat{B}_1) = \sum K_i^2 \sigma^2 \dots \dots \dots \quad (47.2)$$

$$\therefore K_i = \frac{x_i}{\sum x_i^2}$$

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

$$\therefore \text{var}(\hat{B}_1) = \frac{1}{\sum x_i^2} \cdot \sigma^2 = \frac{\sigma^2}{\sum x_i^2}$$

وبالأسلوب نفسه يمكن تحديد التباين لـ  $\hat{B}_0$  على النحو الآتي:

$$\therefore \text{var}(\hat{B}_0) = E[\hat{B}_0 - E(\hat{B}_0)]^2 \dots \dots \dots \quad (48.2)$$

$$E(\hat{B}_0) = B_0 \quad \text{من خاصية عدم التحيز :}$$

$$\text{var}(\hat{B}_0) = E[\hat{B}_0 - B_0]^2$$

وبالرجوع إلى المعادلة (42.2) من خاصية عدم التحيز والخاصة بـ  $\hat{B}_0$  نجد أن:

$$\begin{aligned} \hat{B}_0 &= B_0 + \sum \left( \frac{1}{n} - \bar{X} K_i \right) U_i \\ \hat{B}_0 - B_0 &= \sum \left( \frac{1}{n} - \bar{X} K_i \right) U_i \\ \text{var}(\hat{B}_0) &= E \left[ \sum \left( \frac{1}{n} - \bar{X} K_i \right) U_i \right]^2 \\ \text{var}(\hat{B}_0) &= \sum \left( \frac{1}{n} - \bar{X} K_i \right)^2 E(U_i)^2 \\ E(U_i)^2 &= \sigma^2 \\ \therefore \text{var}(\hat{B}_0) &= \sigma^2 \left[ \sum \left( \frac{1}{n} - \bar{X} K_i \right)^2 \right] \end{aligned}$$

وبفك القوس وباستخدام شروط الأوزان نحصل على:

$$\begin{aligned} \sum K_i &= 0 \\ \therefore \frac{2\bar{X}^2}{n} \sum K_i &= 0 \end{aligned}$$

وأن:

$$\sum K_i^2 = \frac{1}{\sum X_i^2}$$

$$\therefore \text{var}(\hat{B}_0) = \sigma^2 \left( \frac{1}{n} + \frac{\bar{X}^2}{\sum X_i^2} \right)$$

ولإثبات أن مقدرات (OLS) هي أفضل مقدرات خطية غير متحيز أي أنها تتسم بالكفاءة، ونتيجة لنسبية معيار الأفضلية فإننا نقوم بتعريف مقدرة أخرى ولتكن  $B_1^*$  تختلف عن مقدرة OLS ،  $\hat{B}_1$  حيث سيتضح لاحقاً أن تباين تلك المقدرة  $B_1^*$  لابد أن يفوق تباين مقدرة OLS ،  $\hat{B}_1$  وبالتالي نفضل المقدرة الأخيرة  $\hat{B}_1$  صاحبة التباين الأقل.

$$B_1^* = \sum C_i Y_i \dots \quad (49.2)$$

$$C_i = K_i + d_i$$

وأن  $d_i \neq 0$  ، حيث  $d_i$  كميات ثابتة:

$$\therefore Y_i = B_0 + B_1 X_i + U_i$$

$$B_1^* = \sum C_i (B_0 + B_1 X_i + U_i) \dots \dots \dots \quad (50.2)$$

$$B_1^* = B_0 \sum C_i + B_1 \sum C_i X_i + \sum C_i X_i U_i$$

ولكي تكون  $B_1^*$  غير متحيز أي  $E(B_1^*) = B_1$  يجب أن تتصف  $C_i$  بالصفات الآتية:

$$\sum C_i = 0 \quad (\text{أ})$$

$$\sum K_i + \sum d_i = 0 \quad \text{أو:}$$

$\therefore \sum K_i = 0 \quad \text{معروفة مسبقاً :}$

$$\sum d_i = 0 \quad -$$

$$\therefore \sum C_i = 0 \quad \text{أي إن:}$$

$$\sum C_i X_i = 1 \quad (\text{ب})$$

$$\therefore \sum K_i X_i + \sum d_i X_i = 1 \quad \text{أو:}$$

معروفة مسبقاً.

$$\sum K_i X_i = 1$$

$$\sum d_i X_i = 0 \quad \text{أي أن:}$$

$$\therefore \sum C_i X_i = 1 + 0 + 1$$

$$B_1^* = B_1 + \sum C_i U_i \dots \dots \dots \quad (51.2)$$

$$\therefore E(U_i) = 0$$

$$\therefore \sum C_i E(U_i) = 0$$

$$E(B_1^*) = B_1 \dots \dots \dots \quad (52.2)$$

هنا المقدر  $B_1^*$  غير متحيز ولتحديد تباين هذه المقدرة الخطية غير المتحizza فإننا نعوض في قانون var.

$$varB_1^* = E[B_1^* - E(B_1^*)]^2$$

من المعادلة رقم (52.2) :

$$varB_1^* = E[B_1^* - B_1]^2$$

وباستخدام المعادلة رقم (51.2) :

$$B_1^* = B_1 + \sum C_i U_i$$

$$B_1^* - B_1 = \sum C_i U_i$$

$$var(B_1^*) = E \left[ \sum C_i U_i \right]^2 \dots (53.2)$$

وبفك القوس، نحصل على:

$$var(B_1^*) = \sum C_i^2 E(U_i)^2 + 2 \sum_{i>j} C_i C_j E(C_i C_j)$$

ومن فرضيات الخطأ العشوائي:  $E(U_i)^2 = \sigma^2$

وأن:  $E(C_i C_j) = 0$

$$var(B_1^*) = \sum C_i^2 \sigma^2 \dots \dots \dots (54.2)$$

ولما كانت:  $C_i = K_i + d_i$

$$var(B_1^*) = \sum \left( K_i + \sum d_i \right)^2 \sigma^2$$

$$var(B_1^*) = \sigma^2 \left[ \sum K_i^2 + \sum d_i^2 + \sum K_i d_i \right]$$

$$var(B_1^*) = \sigma^2 \sum K_i^2 + \sigma^2 \sum d_i^2 + 2\sigma^2 \sum K_i d_i$$

$$\because \sum K_i = 0$$

$$\therefore \sum K_i d_i = 0$$

$$var(B_1^*) = \sigma^2 \sum K_i^2 + \sigma^2 \sum d_i^2 \dots \dots \dots (55.2)$$

ولما كانت:  $\sum K_i^2 = \frac{1}{\sum x_i^2}$

$$var(B_1^*) = \sigma^2 \frac{1}{\sum x_i^2} + \sigma^2 \sum d_i^2 \dots \dots \dots (56.2)$$

$$\sigma^2 \frac{1}{\sum x_i^2} = var(B_1^*)$$

$$\therefore var(B_1) = var(\hat{B}_1) + \sigma^2 \sum d_i^2 \dots \dots \dots (57.2)$$

وحيث أن:  $\sum d_i^2 > 0$

عليه فإن:  $var(B_1^*) > var(\hat{B}_1)$

ومن ثم فإننا نرى أن مقدمة OLS الخاصة بالمعلمة  $\hat{B}_1$  تتميز بأصغر تباين من بين المقدرات الخطية غير المتحيزة للمعلمة  $B_1^*$ .

#### 4.2 تقدير تباين حد الخطأ العشوائي:

يستعمل تباين  $\hat{B}_0$  و  $\hat{B}_1$  في إجراء الاختبارات المعنوية الخاصة بتلك المقدرات، غير أن تباين المقدرات يحتوي على معلمة مجهولة هي  $(\sigma^2)$  تباين حد الخطأ العشوائي الذي يرمز له بالرمز  $(S_e^2)$  و يمكن اشتقاقه كالتالي:

بما أن المعادلة التقديرية تأخذ الصيغة الآتية:

$$\hat{Y}_i = \hat{B}_0 + \hat{B}_1 X_i \dots \dots \dots (58.2)$$

وبإدخال  $\Sigma$  على طرفي المعادلة :

$$\sum \hat{Y}_i = n \hat{B}_0 + \hat{B}_1 \sum X_i$$

وبالقسمة على  $n$ :

$$\frac{\sum \hat{Y}_i}{n} = \frac{n}{n} \hat{B}_0 + \hat{B}_1 \frac{\sum X_i}{n}$$

$$\bar{Y} = \hat{B}_0 + \hat{B}_1 \bar{X} \dots \dots \dots \dots \dots (59.2)$$

وبطرح المعادلة (59.2) من المعادلة (58.2) نحصل:

$$\hat{Y}_i - \bar{Y} = \hat{B}_0 + \hat{B}_1 X_i - \hat{B}_0 - \hat{B}_1 \bar{X}$$

وبعد الاختصار، نحصل:

$$\hat{Y}_i = \hat{B}_1 X_i - \hat{B}_1 \bar{X}$$

$\hat{Y}_i = \hat{B}_1 (X_i - \bar{X})$  إذاً:

$$\hat{Y}_i = \hat{B}_1 x_i \dots \dots \dots (60.2)$$

$$\therefore e_i = y_i - \hat{y}_i$$

وبالتغيير من المعادلة (60.2):

$$\therefore e_i = y_i - \hat{B}_1 x_i$$

وبتربيع طرفي هذه المعادلة:

$$e_i^2 = (y_i - \hat{B}_1 x_i)^2$$

وعند فك الأقواس، نحصل:

$$e_i^2 = y_i^2 + \hat{B}_1^2 x_i^2 - 2 \hat{B}_1 x_i y_i$$

وبإدخال  $\Sigma$  على طرفي المعادلة:

$$\sum e_i^2 = \sum y_i^2 + \hat{B}_1^2 \sum x_i^2 - 2\hat{B}_1 \sum x_i y_i \dots \dots \dots \quad (61.2)$$

$$\therefore \hat{B}_1 = \frac{\sum x_i y_i}{\sum x_i^2}$$

وإن حاصل ضرب الطرفين في الوسطين لذلك سيكون:

$$\hat{B}_1 \sum x_i^2 = \sum x_i y_i$$

وبالتعميض في المعادلة (61.2) بما يساويها:

$$\sum e_i^2 = \sum y_i^2 + \hat{B}_1 \sum x_i y_i - 2\hat{B}_1 \sum x_i y_i$$

وبعد الاختصار نحصل:

$$\sum e_i^2 = \sum y_i^2 + \hat{B}_1 \sum x_i y_i \dots \dots \dots \dots \quad (62.2)$$

$$\sigma^2 = \frac{\sum e_i^2}{n-2} \quad \text{وقد جرى تعريف } \sigma^2 \text{ على أنها:}$$

وبالتعميض عن البسط من المعادلة 62.2 ، نحصل:

$$\sigma^2 = \frac{\sum y_i^2 - \hat{B}_1 \sum x_i y_i}{n-2} \dots \dots \dots \quad (63.2)$$

وهذا يعني أن تباين أخطاء العينة تمثل النسبة بين مجموع مربعات انحرافات القيم المشاهدة عن خط انحدار العينة إلى درجة الحرية لخطأ.

إذا رمنا إلى التقدير الخطأ غير المتحيز لتباین الخطأ بالرمز ( $S_e^2$ ) ، فأن:

ذلك يعني أن  $S_e^2$  أفضل مقدر غير متحيز لتباین المتغير العشوائي أوحد الخطأ،  $U_i$ .