

المحاضرة الثانية

وان الشرط الجوهرى للتصغير هو اخذ التفاضل الجزئى لمجموع المربعات بالنسبة لمعاملات، Coefficient، النموذج \hat{B}_0 و \hat{B}_1 ومساواة المشتقة الأولى بالصفر.

أى بتطبيق الشرط الضرورى:

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

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

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

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

$$\sum Y_i - n\hat{B}_0 - \hat{B}_1 \sum X_i = 0$$

$$\sum Y_i = n\hat{B}_0 + \hat{B}_1 \sum X_i \quad \dots(14.2)$$

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

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

القسمة على (-2) نحصل على:

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

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

$$\sum X_i Y_i = \hat{B}_0 \sum X_i + \hat{B}_1 \sum X_i^2 \quad \dots(15.2)$$

تسمى المعادلتين (14.2) و (15.2) بالمعادلتين الطبيعيين (الأنيتين) حيث (n) عدد المشاهدات، X_i و Y_i هي معلومة دائماً باعتبارهما قيم المشاهدات الحقيقية وبمجرد

يعويضهما في المعادلتين (14.2) و (15.2) وبحلها أنياً نحصل على قيم \hat{B}_0 و \hat{B}_1 اللتان تمثلان المقدرتان 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.

وسنبين هذه الطرق من خلال المثال الآتي، من نون تكرر لها هنا وهناك.

مثال 1.2: الجدول الآتي يمثل عدد سنوات الخدمة (X_i) ومعدل الأجر السنوي (Y_i) بألاف الدينار 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
$\sum X_i = 144$ $\bar{X} = 18$	$\sum Y_i = 410$ $\bar{Y} = 51.25$	$\sum X_i Y_i = 8379.2$	$4 \sum X_i^2 = 326$

المطلوب: تقدير خط الانحدار بواسطة المعادلتين الطبيعيتين أعلاه.

1.1.3.2 طريقة الحذف والتعويض، Substitution Method:

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

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

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

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

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

وبضرب المعادلة (18.2) في 18 نحصل:

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

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

و نطرح معادلة (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:

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

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

تفسير 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 كرايمر) وذلك بإعادة كتابة المعادلتين الطبيعيين (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}_0 و \hat{B}_1 ينبغي تكوين المحددات الآتية:

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

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

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

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

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

or

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

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

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

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

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

$$|D| = 26112 - 20736$$

$$|D| = 5376$$

$$|A_0| = \begin{vmatrix} \sum Y_i & \sum X_i \\ \sum X_i Y_i & \sum X_i^2 \end{vmatrix} = \begin{vmatrix} 410 & 144 \\ 8379.2 & 3264 \end{vmatrix}$$

$$|A_0| = (410)(3264) - (144)(8379.2)$$

$$|A_0| = 1338240 - 1206604.8$$

$$|A_0| = 131635.2$$

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

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

$$|A_1| = 67033.6 - 59040$$

$$|A_1| = 7993.6$$

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

$$\hat{B}_t = \frac{|\Lambda_1|}{|D|} = \frac{7993.6}{5376} = 1.486904762$$

وبذلك تكون المعادلة التقديرية:

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

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 خطي غير متحيز، (BLUE) Best Linear Unbiased Estimator، فكل مقدر (\hat{B}) يمكن التعبير عنه كدالة خطية بالنسبة لملاحظات 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 الخطية نبحث عن المقدرات غير المتحيزة، ونفصد بعدم التحيز هو أن يكون الفرق بين القيمة المتوقعة للمقدر وقيمة المعلمة الحقيقية يساوي صفر، أي:

$$E(\hat{B}) - B = 0$$

وأفضل مقدر هو ذلك المقدر الذي يكون تباينه حول الوسط الحسابي أقل ما يمكن فإذا كان B^* ، \hat{B} مقدرات خطية غير متحيزة فإن \hat{B} أفضل مقدر إذا تحققت العلاقة الآتية:

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

وسوف نتناول أدناه هذه الخصائص بشيء من التفصيل:

1.2.3.2 الخاصية الخطية، Linearity Property:

مقدرات المربعات الصغرى خطية في المتغير التابع حيث نلاحظ أن تلك المقدرات يمكن وصفها في صورة دالة أو ترتيب خطي من قيم المتغير Y ، أي:

2.2.3.2 خاصية عدم التحيز، Unbiasedness Property:

تقصد بعدم التحيز هو ان يكون الفرق بين القيمة المتوقعة للمقدر $E(\hat{B})$ وقيمة المعلمة الحقيقية للمجتمع الإحصائي (B)، يساوي صفر، أي:

$$E(\hat{B}) - B = 0$$

بعبارة أخرى يعتبر المقدر غير متحيز إذا كان وسطها يساوي القيمة الحقيقية للمعلمة:

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

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

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

من خاصية الخطية

وباستحضار المعادلة:

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

وبتعويض ذلك في أعلاه:

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

وبفتح القوس نحصل:

$$\hat{B}_1 = B_0 \sum K_i + B_1 \sum K_i X_i + \sum K_i U_i$$

...(38.2)

وباستخدام شروط الأوزان فإن:

$$\sum K_i = 0$$

$$B_0 \sum K_i = 0$$

$$\sum K_i X_i = 1$$

وبتعويض ذلك في المعادلة (38.2)، نحصل:

$$\therefore \hat{B}_1 = B_1 + \sum K_i U_i$$

...(39.2)

وبأخذ توقع طرفي المعادلة:

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

من فرضيات الخطأ العشوائي

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

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

$$\therefore E(\hat{B}_1) = B_1$$

...(40.2)

وبعني ذلك ان \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 تعبر مقدرة غير متحيزة للمعلمة الحقيقية B_0 .

من الخاصية الخطية يتبين لنا:

$$\hat{B}_0 = \sum W_i Y_i$$

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

وان:

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

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:

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

وباستخدام شروط الأوزان:

$$\therefore \sum K_i = 0$$

$$\therefore B_0 \bar{X} \sum K_i = 0$$

$$\therefore \sum K_i X_i = 1$$

$$\therefore \hat{B}_0 = B_0 + \sum \left(\frac{1}{n} - \bar{X} K_i \right) U_i \quad \dots (42.2)$$

و يأخذ توقع طرفي المعادلة:

$$E(\hat{B}_0) = B_0 + \sum \left(\frac{1}{n} - \bar{X}K_i \right) E(U_i)$$

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

$$\therefore \sum \left(\frac{1}{n} - \bar{X}K_i \right) E(U_i) = 0$$

$$\therefore E(\hat{B}_0) = B_0 \quad \dots(43.2)$$

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

3.2.3.2 خاصية افضل مقدر (اقل تباين)، Best Minimum Variance:

ان مفهوم تباين المعالم يُحدد بواسطة الانحراف بين المعالم المقدره لـ B_1

وفيمتها المتوقعة $E(\hat{B}_1)$.

فبالنسبة لـ \hat{B}_1 فان:

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

$$\therefore E(\hat{B}_1) = B_1 \quad \text{من خاصية عدم التحيز}$$

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

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

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

$$\hat{B}_1 - B_1 = \sum K_i U_i$$

بتربيع الطرفين:

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

وبأخذ توقع طرفي المعادلة:

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

$$\text{var}(\hat{B}_1) = E[\sum K_i U_i]^2 \quad \dots(46.2)$$

وبفك القوس، نحصل:

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

ومن فرضيات الخطأ العشوائي ان :

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

وان:

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

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

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

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

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

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

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

من خاصية عدم التحيز:

$$\therefore E(\hat{B}_0) = B_0$$

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

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

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

$$\hat{B}_0 - B_0 = \sum \left(\frac{1}{n} - \bar{X}K_i \right) U_i$$

$$\text{var}(\hat{B}_0) = E \left[\sum \left(\frac{1}{n} - \bar{X}K_i \right) U_i \right]^2$$

$$\text{var}(\hat{B}_0) = \sum \left(\frac{1}{n} - \bar{X}K_i \right)^2 E(U_i)^2$$

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

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

وبفك القوس نحصل:

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

وباستخدام شروط الأوزان:

$$\sum K_i = 0$$

$$\therefore \frac{2\bar{X}}{n} \sum K_i = 0$$

وان:

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

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

ولاثبات ان مقدرات (OLS) هي افضل مقدرات خطية غير متحيزة أي أنها تتسم

بالكفاءة ، ونتيجة لنسبية معيار الأفضلية فإننا نقوم بتعريف مقدره أخرى ولكن \hat{B}_1^*

تختلف عن مقدره OLS ، \hat{B}_1 ، حيث سيتضح لاحقاً ان ثباين تلك المقدره \hat{B}_1^* لا بد

ان يفوق ثباين مقدره OLS ، \hat{B}_1 ، وبالتالي نفضل المقدره الأخيرة \hat{B}_1^* صاحبة الثباين الأقل.

$$\hat{B}_1^* = \sum C_i Y_i \quad \dots(49.2)$$

$$C_i = K_i + d_i$$

وان $d_i \neq 0$ ، حيث d_i كميات ثابتة.

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

$$\hat{B}_1 = \sum C_i (B_0 + B_1 X_i + U_i) \quad \dots(50.2)$$

$$\hat{B}_1 = B_0 \sum C_i + B_1 \sum C_i X_i + \sum C_i U_i$$

ولكي تكون \hat{B}_1 غير متحيزة أي $E(\hat{B}_1) = B_1$ يجب ان نتصف C_i بالصفات الآتية:

a: $\sum C_i = 0$

أو

$$\sum K_i + \sum d_i = 0$$

$$\therefore \sum K_i = 0$$

$$\sum d_i = 0$$

$$\therefore \sum C_i = 0$$

معروفة مسبقاً

أي إن:

b: $\sum C_i X_i = 1$

أو

$$\therefore \sum K_i X_i + \sum d_i X_i = 1$$

معروفة مسبقاً

$$\therefore \sum K_i X_i = 1$$

أي إن:

$$\sum d_i X_i = 0$$

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

$$\hat{B}_1 = B_1 + \sum C_i U_i \quad \dots(51.2)$$

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

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

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

$$E(\hat{B}_1) = B_1 \quad \dots(52.2)$$

هنا المقدر \hat{B}_1 غير متحيز ولتحديد تباين هذه المقدرة الخطية غير المتحيزة فإننا نعوض في قانون var.

$$\text{var } \hat{B}_1 = E \left[\hat{B}_1 - E(\hat{B}_1) \right]^2$$

من المعادلة رقم (52.2)

$$\because E(\hat{B}_1) = B_1$$

$$\text{var } \hat{B}_1 = E \left[\hat{B}_1 - B_1 \right]^2$$

وباستخدام المعادلة رقم (51.2)

$$\hat{B}_1 = B_1 + \sum C_i U_i$$

$$\hat{B}_1 - B_1 = \sum C_i U_i$$

$$\text{var } (\hat{B}_1) = E \left[\sum C_i U_i \right]^2 \quad \dots(53.2)$$

وبفك القوس، نحصل على:

$$\text{var}(\dot{B}_1) = \sum C_i^2 E(U_i)^2 + 2 \sum_{i>j} C_i C_j E(U_i U_j)$$

ومن فرضيات الخطأ العشوائي:

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

وإن

$$E(U_i U_j) = 0$$

$$\therefore \text{var}(\dot{B}_1) = \sum C_i^2 \sigma^2 \quad \dots(54.2)$$

ولما كانت

$$C_i = K_i + d_i$$

$$\text{var}(\dot{B}_1) = \sum (K_i + \sum d_i)^2 \sigma^2$$

$$\text{var}(\dot{B}_1) = \sigma^2 [\sum K_i^2 + \sum d_i^2 + 2 \sum K_i d_i]$$

$$\text{var}(\dot{B}_1) = \sigma^2 \sum K_i^2 + \sigma^2 \sum d_i^2 + 2\sigma^2 \sum K_i d_i$$

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

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

$$\text{var}(\dot{B}_1) = \sigma^2 \sum K_i^2 + \sigma^2 \sum d_i^2 \quad \dots(55.2)$$

و عند 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 \sum على طرفي المعادلة:

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

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

وان حاصل ضرب الطرفين في الوسطين لذلك سيكون:

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

وبالتعويض 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:

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

وقد جرى تعريف σ^2 على أنها:

$$\sigma^2 = \frac{\sum e_i^2}{n-2}$$

وبالتعويض عن البسط من المعادلة 62.2 ، نحصل:

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

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

وإذا رمزنا إلى التقدير الخطي غير المتحيز لتباين الخطأ بالرمز (S_e^2) ، فإن:

$$S_e^2 = \frac{\sum e_i^2}{n-2}$$

ذلك يعني أن S_e^2 أفضل مقدر غير متحيز لتباين المتغير العشوائي أو حد الخطأ، u_i .