

## تحليل الانحدار الخطي Linear Regression Analysis

---

### المحور الثالث:

نموذج الانحدار الخطي المتعدد (النموذج الخطي المتعدد)

(خطوات صياغة نموذج متعدد، تقدير معاملات النموذج، دراسة صلاحية النموذج)

### 3- تحليل الانحدار الخطي العام (النموذج الخطي المتعدد)

#### 1|3 الكتابة الرياضية للنموذج:

يستند النموذج الخطي المتعدد في التحليل الساكن على افتراض وجود علاقة خطية بين متغير داخلي  $Y$  وعدد  $k$  من المتغيرات الخارجية المستقلة  $X_1, X_2, \dots, X_k$  ( $k \geq 2$ ).

$$Y_i = \beta_0 + \sum_{j=1}^k \beta_j X_{ij} + \varepsilon_i : i = \overline{1, n}$$

نعتبر النموذج التالي الذي يكتب بشكل مختصر كما يلي:  $\beta_0, \beta_1, \beta_2, \dots, \beta_k$  هي معالم (وسائط) النموذج يطلب تقديرها.

$\varepsilon_i$  هي الأخطاء العشوائية (الظاهرة غير المشاهدة).

#### 2|3 الشكل المصفوفي لنموذج الانحدار الخطي المتعدد:

$$= (Y_i = \beta_0 + \sum_{j=1}^k \beta_j X_{ij} + \varepsilon_i : i = \overline{1, n}) \Leftrightarrow \begin{cases} Y_1 = \beta_0 + \beta_1 X_{11} + \beta_2 X_{12} + \dots + \beta_k X_{1k} + \varepsilon_1 \\ Y_2 = \beta_0 + \beta_1 X_{21} + \beta_2 X_{22} + \dots + \beta_k X_{2k} + \varepsilon_2 \\ \dots \\ Y_n = \beta_0 + \beta_1 X_{n1} + \beta_2 X_{n2} + \dots + \beta_k X_{nk} + \varepsilon_n \end{cases}$$

ويمكن تحويل هذه الجملة إلى الشكل المصفوفي التالي:

$$Y = X \cdot \beta + \varepsilon \Leftrightarrow \begin{pmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{pmatrix} = \begin{bmatrix} 1 & X_{11} & X_{12} & \dots & X_{1k} \\ 1 & X_{21} & X_{22} & \dots & X_{2k} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & X_{n1} & X_{n2} & \dots & X_{nk} \end{bmatrix} \begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_k \end{pmatrix} + \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{pmatrix} \dots [1]$$

#### 3|3 الفرضيات الأساسية لطريقة المربعات الصغرى (OLS):

طريقة المربعات الصغرى العادية (Ordinary least squares method) عدة فرضيات أساسية، والإخلال بإحداها قد يؤدي إلى نتائج مظلمة، خاصة عند دراسة صلاحية النموذج. وسنتطرق إلى هذه الفرضيات، كما سنرى كيفية معالجة بعض المشاكل الناتجة عن الإخلال بإحداها. وفيما يلي عرض لهذه الفرضيات<sup>1</sup>:

**الفرضية الأولى:** خطية العلاقة بين المتغير التابع والمتغيرات المستقلة.

$$= Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \beta_3 X_{i3} + \dots + \beta_k X_{ik} + \varepsilon_i : i = \overline{1, n}$$

**الفرضية الثانية:** التوقع الرياضي للمتغيرات المفسرة المهمة معدوم، بمعنى:  $E(\varepsilon^2) = 0$

<sup>1</sup> - جلاطو جيلالي، الإحصاء التطبيقي، دار الخلدونية للنشر والتوزيع، القبة القديمة، الجزائر، الطبعة الأولى 2007، ص 16-17.

نستنتج أن التوقع الرياضي لـ  $Y$  هو:  $\hat{Y} = E(Y) = \hat{\beta}_0 + \hat{\beta}_1 X_1 + \hat{\beta}_2 X_2 + \dots + \hat{\beta}_k X_k$

الفرضية الثالثة: تباين الأخطاء متجانس، بمعنى أن:  $Var(\varepsilon_i) = E(\varepsilon_i^2) = \sigma_\varepsilon^2 : i = \overline{1, n}$

الفرضية الرابعة: استقلالية الأخطاء، بمعنى أن:  $Cov(\varepsilon_i, \varepsilon_j) = 0 : i \neq j$

وبناء على فرضيتي تجانس تباين الأخطاء واستقلالية البواقي، فإن مصفوفة التباين - التباين المشترك تكون على النحو التالي:

$$\varepsilon \varepsilon' = \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{pmatrix} (\varepsilon_1 \varepsilon_2 \dots \varepsilon_n) = \begin{pmatrix} \varepsilon_1^2 & \varepsilon_1 \varepsilon_2 & \dots & \varepsilon_1 \varepsilon_n \\ \varepsilon_2 \varepsilon_1 & \varepsilon_2^2 & \dots & \varepsilon_2 \varepsilon_n \\ \vdots & \vdots & \ddots & \vdots \\ \varepsilon_n \varepsilon_1 & \varepsilon_n \varepsilon_2 & \dots & \varepsilon_n^2 \end{pmatrix}$$

$$\begin{cases} Var(\varepsilon_i) = E(\varepsilon_i^2) = \sigma_\varepsilon^2 : i = \overline{1, n} \\ Cov(\varepsilon_i, \varepsilon_j) = E(\varepsilon_i \varepsilon_j) = 0 : i \neq j \end{cases} \Rightarrow \Omega_\varepsilon = \begin{bmatrix} \sigma_\varepsilon^2 & 0 & 0 \dots & 0 \\ 0 & \sigma_\varepsilon^2 & 0 \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 \dots & \sigma_\varepsilon^2 \end{bmatrix} = \sigma_\varepsilon^2 I_n \quad \text{إذن:}$$

$$\Omega_\varepsilon = Var(\varepsilon) = E(\varepsilon \varepsilon') = \sigma_\varepsilon^2 I_n$$

أي أن تباين البواقي يعطى بالعلاقة التالية:

تسمى  $\Omega_\varepsilon$  مصفوفة التباين - التباين المشترك للأخطاء

الفرضية الخامسة: عدم الارتباط بين المتغيرات المستقلة والبواقي:  $Cov(X_i, \varepsilon_i) = E(X_i \varepsilon_i) = X_i E(\varepsilon_i) = 0$

الفرضية السادسة: المتغير العشوائي يتبع التوزيع الطبيعي  $\varepsilon \rightarrow N(0, \sigma_\varepsilon^2 I_n)$

الفرضية السابعة: أن يكون حجم العينة أكبر بكثير من عدد المعالم المقدرة في النموذج:  $n \gg (k+1)$ .

4|3 تقدير شعاع المعالم  $\beta$  وتباين الأخطاء  $\sigma_\varepsilon^2$  بالطريقة (OLS):

1|4|3 تقدير مركبات شعاع المعالم  $\beta$ :

ليكن النموذج [1]  $Y = X\beta + \varepsilon$ .....، حيث  $\varepsilon$  كمية عشوائية غير معلومة.

وليكن الشعاع المقدر للشعاع  $\beta$  عندئذ يكتب النموذج المقدر بالشكل:  $\hat{Y} = X\hat{\beta}$

و نرسم لشعاع البواقي (Résidus) بالرمز  $\hat{\varepsilon}$ ، وهو الفرق بين القيمة الحقيقية  $Y$  والقيمة المقدرة  $\hat{Y}$ .

$$\hat{\varepsilon} = Y - \hat{Y} \Leftrightarrow \hat{\varepsilon} = Y - X\hat{\beta} \dots \dots \dots [2]$$

بمعنى أن:

ولتقدير معالم النموذج [1]  $Y = X\beta + \varepsilon$  بمفهوم المربعات الصغرى العادية، نقوم بتدنته مجموع مربعات البواقي الذي يكتب من الشكل:  $\hat{\varepsilon}'\hat{\varepsilon} = \sum_{i=1}^n \hat{\varepsilon}_i^2$  حيث  $\hat{\varepsilon}'$  هو منقول الشعاع  $\hat{\varepsilon}$ .

$$\text{Min} \sum_{i=1}^n \varepsilon_i^2 = \text{Min} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad \text{وبالتالي:}$$

$$\hat{\beta} = (X'X)^{-1} X'Y \dots \dots \dots [3]$$

وبنفس الطريقة المطبقة في نموذج الانحدار الخطي البسيط، يمكن الوصول إلى النتيجة نفسها فيما يتعلق مقدرات النموذج، ويتميز الشعاع المقدر  $\hat{\beta}$  بأنه عشوائي وذلك لارتباطه خطيا بالحد العشوائي  $\varepsilon$ .

3|4|1| أ) الخصائص الإحصائية للمقدرات  $\hat{\beta}$  و  $\sigma_\varepsilon^2$  :

هل تعطي طريقة المربعات الصغرى العادية (OLS) أحسن تقديرات خطية، غير متحيزة، وذات أصغر تباين؟

نظرية Gauss-Markov<sup>2</sup>:

في عائلة التقديرات الخطية وغير المتحيزة فان مقدر طريقة المربعات الصغرى يتميز بأنه أحسن تقدير خطي غير متحيز وذو أصغر تباين، والتي تعني باللغة الانجليزية: "BLUE" Best Linear Unbiased Estimators.

3|4|1| ب) مصفوفة التباين - التباين المشترك للمقدر  $\hat{\beta}$  :

لدينا  $(k+1)$  معلم مقدر في النموذج. نرمز إلى مصفوفة التباين - التباين المشترك للشعاع المقدر  $\hat{\beta}$  بالرمز  $\Omega_{\hat{\beta}}$ ، وهي

$$\Omega_{\hat{\beta}} = \sigma_\varepsilon^2 (XX')^{-1}$$

مصفوفة متناظرة وتعطى بالصيغة:

بتباين الأخطاء النظري  $\sigma_\varepsilon^2$ ، مما

المصفوفة  $\Omega_{\hat{\beta}}$  غير معروفة لأنها مرتبطة

يستوجب تقدير تباين الأخطاء للحصول على تباين البواقي.

3|4|2| تقدير تباين الأخطاء  $\sigma_\varepsilon^2$  :

يكون من الضروري إيجاد مقدر تباين البواقي المجهول. فإذا كان  $(k+1)$  عدد المعلمات المطلوب تقديرها في النموذج

$$\hat{\sigma}_\varepsilon^2 = \frac{\hat{\varepsilon}'\hat{\varepsilon}}{(n-k-1)} = \frac{1}{(n-k-1)} \sum_{i=1}^n \hat{\varepsilon}_i^2 \dots \dots \dots [3'] \quad \text{الخطي [1] فإن:}$$

$$\hat{\Omega}_{\hat{\beta}} = \hat{\sigma}_\varepsilon^2 (X'X)^{-1} \dots \dots \dots [4]$$

وعليه :

<sup>2</sup> - Christian Labrousse, Introduction à l'économie ·Dunod ,Paris, 1985, p26

### 3|4|3 تطبيق على نموذج خطي متعدد (بمتغيرين مستقلين)

البيانات الآتية تمثل الناتج المحلي الإجمالي  $Y_i$  ويمثل  $X_1$  قيمة الانتاج الزراعي،  $X_2$  يمثل قيمة الانتاج الصناعي لإحدى الدول كما يأتي:

$Y_i$	$X_1$	$X_2$
66	38	47.5
43	41	21.3
36	34	36.5
23	35	18
22	31	29.5
14	34	14.2
12	29	21
7.6	32	10
8.9	34	15
11	38	18

الحل: من هذه البيانات نكون جدول جديد يحتوي على مربعات المتغيرات والضرب ما بينهما كما يأتي:

$Y_i$	$X_1$	$X_2$	$Y_i^2$	$X_1^2$	$X_2^2$	$Y_i X_1$	$Y_i X_2$	$X_1 X_2$
66	38	47.5	4356.00	1444	2256.25	2508.0	3135.0	1805.0
43	41	21.3	1849.00	1681	453.69	1763.0	915.9	873.3
36	34	36.5	1296.00	1156	1332.25	1224.0	1314.0	1241.0
23	35	18	529.00	1225	324.00	805.0	414.0	630.0
22	31	29.5	484.00	961	870.25	682.0	649.0	914.5
14	34	14.2	196.00	1156	201.64	476.0	198.8	482.8
12	29	21	144.00	841	441.00	348.0	252.0	609.0
7.6	32	10	57.76	1024	100.00	243.2	76.0	320.0
8.9	34	15	79.21	1156	225.00	302.6	133.5	510.0
11	38	18	121.00	1444	324.00	418.0	198.0	684.0
$\sum Y_i = 243.5$	$\sum X_1 = 346$	$\sum X_2 = 231$	$\sum Y_i^2 = 9111.97$	$\sum X_1^2 = 12088$	$\sum X_2^2 = 6528.08$	$\sum Y_i X_1 = 8967.8$	$\sum Y_i X_2 = 7286.2$	$\sum X_1 X_2 = 8069.6$

### 3|4|3أ) طريقة المعادلات الاعتيادية او الطبيعية

من اشتقاق المعادلات الطبيعية او الاعتيادية في هذا الفصل والتي اخذت الشكل الآتي:

$$= \sum Y_i = n\beta_0 + \beta_1 \sum X_1 + \beta_2 \sum X_2 \dots \dots \dots (1)$$

$$= \sum X_1 Y_i = \beta_0 \sum X_1 + \beta_1 \sum X_1^2 + \beta_2 \sum X_1 X_2 \dots \dots \dots (2)$$

$$= \sum X_2 Y_i = \beta_0 \sum X_2 + \beta_1 \sum X_2 X_1 + \beta_2 \sum X_2^2 \dots \dots \dots (3)$$

نعوض بالقيم التي تم احتسابها في الجدول اعلاه كما يأتي:

$$243.5 = 10\beta_0 + 346\beta_1 + 231\beta_2 \dots \dots \dots (1)$$

$$8967.8 = 346\beta_0 + 12088\beta_1 + 8069.6\beta_2 \dots \dots \dots (2)$$

$$7286.2 = 231\beta_0 + 8069.6\beta_1 + 6528.08\beta_2 \dots \dots \dots (3)$$

حتى ننظم الحل يتم اول ايجاد قيمة معلمة من المعادلتين الاوليتين كما يأتي:

$$243.5 = 10\beta_0 + \beta_1 346 + \beta_2 231 \dots \dots \dots (1)$$

$$8967.8 = 346\beta_0 + 12088\beta_1 + 8069.6\beta_2 \dots \dots \dots (2)$$

لحذف معلمة الثابت  $\beta_0$  من المعادلتين نقسم قيمة معلمة الثابت فب المعادلة رقم 2 على قيمة معلمة الثابت في المعادلة رقم

$$1 \text{ كما يأتي: } 346/10=34.6$$

نضرب القيمة المتحصل عليها 34.6 في المعادلة رقم 1 كما يأتي:

$$243.5(34.6) = 10(34.6)\beta_0 + 346(34.6)\beta_1 + 231(34.6)\beta_2$$

$$8494.3 = 346\beta_0 + 11971.6\beta_1 + 7992.6\beta_2 \dots \dots \dots (4)$$

نطرح المعادلة رقم 4 من المعادلة رقم 2:

$$8967.8 = 346\beta_0 + 12088\beta_1 + 8069.6\beta_2 \dots \dots \dots (2)$$

$$-8494.3 = 346\beta_0 + 11971.6\beta_1 + 7992.6\beta_2 \dots \dots \dots (4)$$

$$473.5 = 116.4\beta_1 + 77\beta_2 \dots \dots \dots (5)$$

الان لنحذف معلمة الثابت من المعادلة رقم 3 وكما أسلفنا في الطريقة اعلاه اذ نقسم معلمة الثابت في المعادلة رقم 3 على قيمة

$$\text{المعلمة في المعادلة 1 كما يأتي: } 231/10=23.1$$

نضرب هذه القيمة المتحصل عليها في المعادلة 1:

$$243.5(23.1) = 10(23.1)\beta_0 + 346(23.1)\beta_1 + 231(23.1)\beta_2$$

$$5624.85 = 231\beta_0 + 7992.6\beta_1 + 5336.1\beta_2 \dots \dots \dots (6)$$

نطرح المعادلة رقم 6 من المعادلة رقم 3 :

$$7286.2 = 231\beta_0 + 8069.6\beta_1 + 6528.08\beta_2 \dots \dots \dots (3)$$

$$-5624.85 = 231\beta_0 + 7992.6\beta_1 + 5336.1\beta_2 \dots \dots \dots (6)$$

$$1661.35 = 77\beta_1 + 1191.98\beta_2 \dots \dots \dots (7)$$

لنحتسب قيمة المعلمة  $\beta_2$  عن طريق حذف المعلمة  $\beta_1$  وذلك باستخدام المعادلتين 5 و 7 :

$$473.5 = 116.4\beta_1 + 77\beta_2 \dots \dots \dots (5)$$

$$1661.35 = 77\beta_1 + 1191.98\beta_2 \dots \dots \dots (7)$$

نقسم قيمة المعلمة  $\beta_1$  في المعادلة رقم 7 على قيمتها في المعادلة رقم 5:  $116.4/77=1.512$

نضرب حاصل القسمة 1.512 في المعادلة رقم 7:

$$1661.35 = 77\beta_1 + 1191.98\beta_2 \dots \dots \dots (7) * (1.512)$$

$$1661.35(1.512) = 77\beta_1(1.512) + 1191.98\beta_2(1.512) \dots \dots \dots (7)$$

$$2511.44 = 116.4\beta_1 + 1801.9\beta_2 \dots \dots \dots (8)$$

نطرح المعادلة رقم 5 من المعادلة رقم 8:

$$2511.44 = 116.4\beta_1 + 1801.9\beta_2 \dots \dots \dots (8)$$

$$473.5 = 116.4\beta_1 + 77\beta_2 \dots \dots \dots (5)$$

$$2037.94 = 1724.9\beta_2$$

$$\therefore \hat{\beta}_2 = \frac{2037.94}{1724.9} = 1.2$$

نعوض قيمة المعلمة  $\hat{\beta}_2$  في المعادلة رقم 8 كما يأتي :

$$2511.44 = 116.4\beta_1 + 1801.9(1.2)$$

$$2511.44 = 116.4\beta_1 + 2162.28$$

$$2511.44 - 2162.28 = 116.4\beta_1$$

$$349.16 = 116.4\beta_1$$

$$\therefore \hat{\beta}_1 = \frac{349.16}{116.4} = 2.98$$

نعوض قيمة المعلمتين  $\hat{\beta}_2$  و  $\hat{\beta}_1$  في المعادلة رقم 1 كما يأتي :

$$243.5 = 10\beta_0 + 346(2.98) + 231(1.2) \dots \dots \dots (1)$$

$$243.5 = 10\beta_0 + 1031.08 + 277.2 = 10\beta_0 + 1308.28$$

$$243.5 - 1308.28 = 10\beta_0$$

$$-1064.78 = 10\beta_0$$

$$\therefore \hat{\beta}_0 = \frac{-1064.78}{10} = -106.478$$

وبالتالي اخذ النموذج المقدر الصيغة الرياضية الاتية:

$$\hat{Y}_i = -106.478 + 2.98X_1 + 1.2X_2$$

$$\begin{bmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \\ \hat{\beta}_2 \end{bmatrix} = [XX]^{-1}XY \quad \text{من صيغة المصفوفات الاتية:} \quad \text{3|4|3|ب) طريقة المصفوفات:}$$

$$= \begin{bmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \\ \hat{\beta}_2 \end{bmatrix} = \begin{bmatrix} N & \sum X_1 & \sum X_2 \\ \sum X_1 & \sum X_1^2 & \sum X_1X_2 \\ \sum X_2 & \sum X_2X_1 & \sum X_2^2 \end{bmatrix}^{-1} \cdot \begin{bmatrix} \sum Y_i \\ \sum X_1Y_i \\ \sum X_2Y_i \end{bmatrix}$$

$$\begin{bmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \\ \hat{\beta}_2 \end{bmatrix} = \begin{bmatrix} 10 & 346 & 231 \\ 346 & 12088 & 8069.6 \\ 231 & 8069.6 & 6528.08 \end{bmatrix}^{-1} \cdot \begin{bmatrix} 243.5 \\ 8967.8 \\ 7286.2 \end{bmatrix} = ?$$

لتقدير معكوس المصفوفة  $[XX]^{-1}$  يجب ان نحتسب المحدد اولا ومن ثم مصفوفة المرافقات كما يأتي:

$$D = |XX| \begin{vmatrix} 10 & 346 & 231 \\ 346 & 12088 & 8069.6 \\ 231 & 8069.6 & 6528.08 \end{vmatrix} \quad \text{محدد المصفوفة D:}$$

$$D = 10 \begin{vmatrix} 12088 & 8069.6 \\ 8069.6 & 6528.08 \end{vmatrix} - 346 \begin{vmatrix} 346 & 8069.6 \\ 231 & 6528.08 \end{vmatrix} + 231 \begin{vmatrix} 346 & 12088 \\ 231 & 8069.6 \end{vmatrix}$$

$$D = 137929868.8 - 136544775.68 - 56918.4 = 1328174.72$$

$$\therefore D = 1328174.72$$

مصفوفة المرافقات  $Adj[XX]$  كما يأتي:

$$Adj[XX] = \begin{bmatrix} + \begin{vmatrix} 12088 & 8069.6 \\ 8069.6 & 6528.08 \end{vmatrix} & - \begin{vmatrix} 346 & 8069.6 \\ 231 & 6528.08 \end{vmatrix} & + \begin{vmatrix} 346 & 12088 \\ 231 & 8069.6 \end{vmatrix} \\ - \begin{vmatrix} 346 & 231 \\ 8069.6 & 6528.08 \end{vmatrix} & + \begin{vmatrix} 10 & 231 \\ 231 & 6528.08 \end{vmatrix} & - \begin{vmatrix} 10 & 346 \\ 231 & 8069.6 \end{vmatrix} \\ + \begin{vmatrix} 346 & 231 \\ 12088 & 8069.6 \end{vmatrix} & - \begin{vmatrix} 10 & 231 \\ 346 & 8069.6 \end{vmatrix} & + \begin{vmatrix} 10 & 346 \\ 346 & 12088 \end{vmatrix} \end{bmatrix}$$

$$Adj[XX] = \begin{bmatrix} 1379298688 & -349638.08 & -246.4 \\ -349638.08 & 11919.8 & -770 \\ -246.4 & -770 & 1164 \end{bmatrix}$$

$$[XX]^{-1} = \frac{Adj[XX]}{|XX|} = \begin{bmatrix} \frac{1379298688}{1328174.72} & \frac{-349638.08}{1328174.72} & \frac{-246.4}{1328174.72} \\ \frac{-349638.08}{1328174.72} & \frac{11919.8}{1328174.72} & \frac{-770}{1328174.72} \\ \frac{-246.4}{1328174.72} & \frac{-770}{1328174.72} & \frac{1164}{1328174.72} \end{bmatrix}$$

$$[XX]^{-1} = \frac{Adj[XX]}{|XX|} = \begin{bmatrix} 1038.49 & -0.263 & -0.00019 \\ -0.263 & 0.009 & -0.00058 \\ -0.00019 & -0.00058 & 0.00088 \end{bmatrix}$$

بما ان المصفوفة مربعة فان منقولها هو يعطي نفس الترتيب ولذا تبقى على نفس حالة عناصرها إذ أن من الواجب ان نقوم بتحويل الى منقول المصفوفة لشروطها في ايجاد المعكوس ومن الصيغ يمكن أن نحصل على تقديرات معالم المعادلة الخطية كما يأتي:

$$\begin{bmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \\ \hat{\beta}_2 \end{bmatrix} = \begin{bmatrix} 1038.49 & -0.263 & -0.00019 \\ -0.263 & 0.009 & -0.00058 \\ -0.00019 & -0.00058 & 0.00088 \end{bmatrix} \begin{bmatrix} 243.5 \\ 8967.8 \\ 7286.2 \end{bmatrix} = \begin{bmatrix} -106.478 \\ 2.98 \\ 1.2 \end{bmatrix}$$

### 3|4|3 ت) طريقة المحددات (قاعدة كرامر)

كما أسلفنا يجب ان نستخرج محددات فرعية عن طريق ابدال عمود  $XY$  في العمود الاول من المحدد الرئيسي للحصول على المحدد الفرعي الاول ونستبدله بدلا من العمود الثاني في المحدد الرئيسي للحصول على المحدد الفرعي الثاني ومن ثم نستبدله

بدلا من العمود الثالث لنحصل على المحدد الفرعي الثالث ومن ثم نحتسب او نقدر المعالم كما عملنا سابقا في التوجه النظري لهذه الطريقة كما يأتي:

$$D = |XX| = \begin{vmatrix} 10 & 346 & 231 \\ 346 & 12088 & 8069.6 \\ 231 & 8069.6 & 6528.08 \end{vmatrix}$$

$$XY = \begin{bmatrix} 243.5 \\ 8967.8 \\ 7286.2 \end{bmatrix}$$

$$D_0 = \begin{vmatrix} 243.5 & 346 & 231 \\ 8967.8 & 12088 & 8069.6 \\ 7286.2 & 8069.6 & 6528.08 \end{vmatrix}$$

$$D_1 = \begin{vmatrix} 10 & 243.5 & 231 \\ 346 & 8967.8 & 8069.6 \\ 231 & 7286.2 & 6528.08 \end{vmatrix}$$

$$D_2 = \begin{vmatrix} 10 & 346 & 243.5 \\ 346 & 12088 & 8967.8 \\ 231 & 8069.6 & 7286.2 \end{vmatrix}$$

$$\hat{\beta}_0 = \frac{D_0}{D} = \frac{\begin{vmatrix} 243.5 & 346 & 231 \\ 8967.8 & 12088 & 8069.6 \\ 7286.2 & 8069.6 & 6528.08 \end{vmatrix}}{\begin{vmatrix} 10 & 346 & 231 \\ 346 & 12088 & 8069.6 \\ 231 & 8069.6 & 6528.08 \end{vmatrix}} = -106.478$$

وبالطريقة التي اتبعناها في الحصول على قيمة المحدد نحتسب ايضا قيمة المحددات

$$\hat{\beta}_1 = \frac{D_1}{D} = \frac{\begin{vmatrix} 10 & 243.5 & 231 \\ 346 & 8967.8 & 8069.6 \\ 231 & 7286.2 & 6528.08 \end{vmatrix}}{\begin{vmatrix} 10 & 346 & 231 \\ 346 & 12088 & 8069.6 \\ 231 & 8069.6 & 6528.08 \end{vmatrix}} = 2.98$$

$$\hat{\beta}_2 = \frac{D_2}{D} = \frac{\begin{vmatrix} 10 & 346 & 243.5 \\ 346 & 12088 & 8967.8 \\ 231 & 8069.6 & 7286.2 \end{vmatrix}}{\begin{vmatrix} 10 & 346 & 231 \\ 346 & 12088 & 8069.6 \\ 231 & 8069.6 & 6528.08 \end{vmatrix}} = 1.2$$

**4|4|3** توزيعات المقدرات وبناء مجالات الثقة لها:

إذا افترضنا أن  $\beta_j : j = \overline{0, k}$  معلم في النموذج فإن:

أ4|4|3 (أ) - إذا كان  $n \leq 30$ ، يكون التباين  $\sigma_\varepsilon^2$  غير معروف:  $(\hat{\beta}_j - \beta_j) / \hat{\sigma}_{\hat{\beta}_j} \rightarrow t(n-k-1, \alpha)$

أما مجال الثقة فيمكن استخلاصه بالطريقة التالية:

$$\Pr\left\{-t_{\alpha/2} \leq (\hat{\beta}_j - \beta_j) / \hat{\sigma}_{\hat{\beta}_j} \leq t_{\alpha/2}\right\} = 1 - \alpha : j = \overline{0, k}$$

$$\Pr\left\{\hat{\beta}_j - t_{\alpha/2} \cdot \hat{\sigma}_{\hat{\beta}_j} \leq \beta_j \leq \hat{\beta}_j + t_{\alpha/2} \cdot \hat{\sigma}_{\hat{\beta}_j}\right\} = 1 - \alpha : j = \overline{0, k} \quad \text{ومنه :}$$

$$\left[ \hat{\beta}_j \pm t_{\alpha/2} \cdot \hat{\sigma}_{\hat{\beta}_j} \right] \quad \text{إذن مجال الثقة للمقدر } \beta_j \text{ هو :}$$

$t_{\alpha/2}$  : هي القيمة الحرجة لتوزيع ستودنت بدرجة حرية  $v = n - k - 1$  ونسبة دلالة  $\alpha$ .

أ4|4|3 (ب) - إذا كان  $n > 30$ ، يكون التباين  $\sigma_\varepsilon^2$  معروفاً، أي أن:  $(\hat{\beta}_j - \beta_j) / \hat{\sigma}_{\hat{\beta}_j} \rightarrow N(0,1)$

أما مجال الثقة فيمكن استخلاصه بالطريقة التالية:

$$\Pr\left\{-z_{\alpha/2} \leq (\hat{\beta}_j - \beta_j) / \hat{\sigma}_{\hat{\beta}_j} \leq z_{\alpha/2}\right\} = 1 - \alpha : j = \overline{0, k}$$

$$\Pr\left\{\hat{\beta}_j - z_{\alpha/2} \cdot \hat{\sigma}_{\hat{\beta}_j} \leq \beta_j \leq \hat{\beta}_j + z_{\alpha/2} \cdot \hat{\sigma}_{\hat{\beta}_j}\right\} = 1 - \alpha : j = \overline{0, k} \quad \text{ومنه :}$$

$$\left[ \hat{\beta}_j \pm z_{\alpha/2} \cdot \hat{\sigma}_{\hat{\beta}_j} \right] \quad \text{إذن مجال الثقة للمقدر } \beta_j \text{ هو :}$$

ج-تتبع الكمية  $(n-k-1)\hat{\sigma}_\varepsilon^2 / \sigma_\varepsilon^2$  توزيع  $\chi^2$  بدرجة حرية  $(n-k-1)$ ، أي أن:

$$(n-k-1)\hat{\sigma}_\varepsilon^2 / \sigma_\varepsilon^2 \rightarrow \chi_\alpha^2(n-k-1)$$

أما مجال الثقة فيمكن استخلاصه بالطريقة التالية:

$$\Pr\left\{\chi_{\alpha/2}^2 \leq (n-k-1)\hat{\sigma}_\varepsilon^2 / \sigma_\varepsilon^2 \leq \chi_{1-\alpha/2}^2\right\} = 1 - \alpha$$

وبالتالي نحصل على ما يلي:

$$\sigma_\varepsilon^2 \in \left[ (n-k-1)\hat{\sigma}_\varepsilon^2 / \chi_{1-\alpha/2}^2, (n-k-1)\hat{\sigma}_\varepsilon^2 / \chi_{\alpha/2}^2 \right]$$

$\chi_{\alpha/2}^2, \chi_{1-\alpha/2}^2$  : هما القيمتان الحرجتان لتوزيع  $\chi^2$  بدرجة حرية  $v = n - k - 1$  ونسبة دلالة  $\alpha$ .

### 5|3 تحليل التباين والقدرة التفسيرية للنموذج:

#### 1|5|3 معادلة تحليل التباين:

يمكننا النموذج  $Y = X\beta + \mathcal{E}$  من قياس مدى تمثيل النموذج لمشاهدات العينة، وتستعمل البواقي كمقياس لجودة التوفيق لان قيمتها تعتمد على المتغير التابع  $Y$ . ويتغير  $Y$  حول وسطه كما يلي:

$$= Y_i = \hat{Y}_i + \hat{\varepsilon}_i \Leftrightarrow Y_i - \bar{Y} = \hat{Y}_i - \bar{Y} + \hat{\varepsilon}_i : i = \overline{1, n}$$

$$(Y_i - \bar{Y})^2 = (\hat{Y}_i - \bar{Y})^2 + \hat{\varepsilon}_i^2 : i = \overline{1, n} \quad \text{وبذلك نحصل على ما يلي:}$$

$$\sum_{i=1}^n (Y_i - \bar{Y})^2 = \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2 + \sum_{i=1}^n \hat{\varepsilon}_i^2 \dots \dots \dots [5]$$

ويمكن كتابة معادلة تحليل التباين على النحو التالي:

$$Y^t Y = \hat{Y}^t \hat{Y} + \hat{\varepsilon}^t \hat{\varepsilon} \Leftrightarrow TSS = ESS + RSS \dots \dots [5']$$

#### جدول تحليل التباين (ANOVA)

مصدر التغير	مجموع المربعات	درجة الحرية	المتوسط
$X_1, X_2, \dots, X_k$	$ESS = \sum (\hat{Y} - \bar{Y})^2$	$k$	$SSR/k$
البواقي	$RSS = \sum \hat{\varepsilon}_i^2$	$n - k - 1$	$SSE/(n - k - 1)$
المجموع	$TSS = ESS + RSS$	$n - 1$	$SST/(n - 1)$

### 2|5|3 معامل التحديد المتعدد (Multiple Coefficient of Determination):

هو نسبة تأثير كل المتغيرات المفسرة (المستقلة) على المتغير المفسر (التابع).

ويعرف على انه<sup>3</sup> "نسبة التشتت المفسر إلى التشتت الكلي، وهو مؤشر على النسبة المئوية من التغير الكلي في المتغير التابع التي يمكن تفسيرها بدلالة المتغيرات المستقلة المدرجة في النموذج. ونرمز لهذا المعامل بالرمز  $R^2$ ".

وهو يقيس جودة التوفيق والارتباط بين محددات الظاهرة المدروسة والظاهرة نفسها.

<sup>3</sup> شعوبي محمود فوزي، مرجع سابق، ص20.

▪ الاشتقاق الرياضي لمعامل التحديد:

$$R^2 = \frac{\hat{Y}'\hat{Y}}{Y'Y} = \frac{SSR}{SST} \Leftrightarrow R^2 = 1 - \frac{\hat{\varepsilon}'\hat{\varepsilon}}{Y'Y} = 1 - \frac{SSE}{SST} \dots\dots\dots [6] \quad \text{بالتعريف :}$$

▪ خواص معامل التحديد  $R^2$ :

(1) من معادلة تحليل التباين يكون لدينا:  $0 \leq R^2 \leq 1$ .

(2) يمكن التمييز بين حالتين كما يلي:

أ- إذا اقتربت قيمة  $R^2$  من الصفر فهو دلالة على ضعف العلاقة بين المتغير التابع والمتغيرات المستقلة، وإذا كان  $R^2 = 0$  فلا وجود للعلاقة بين المتغير التابع والمتغيرات المستقلة الداخلة في النموذج.

ب- وإذا كان  $R^2 = 1$  فإن ذلك يشير إلى أن (100%) من التغير في المتغير التابع يعود إلى التغير في المتغيرات المستقلة المدرجة في النموذج. لذلك كلما اقتربت قيمة  $R^2$  من الواحد الصحيح، كلما زادت درجة الثقة في النموذج المقدر.

(3) يعاب على المعامل  $R^2$  انه لا يأخذ في الاعتبار عدد المشاهدات ولا عدد المتغيرات.

### 3|5|3 معامل التحديد المعدل ( $\bar{R}^2$ ):

إن إضافة متغير مستقل أو أكثر إلى النموذج المقدر يؤدي إلى زيادة في قيمة  $R^2$  نتيجة لزيادة قيمة البسط في معادلة  $R^2$  وبقاء المقام على حاله دون تغيير. ، وبالتالي قيمة  $R^2$  لا تعبر عن القيمة الحقيقية له، ولتفادي هذا الإشكال أُقترح مؤشر آخر يأخذ بعين الاعتبار درجة الحرية في النموذج ، ويسمى معامل التحديد المعدل " $\bar{R}^2$ " حيث :

$$\bar{R}^2 = 1 - \left( \frac{n-1}{n-k-1} \right) (1 - R^2)$$

1. في العينات الصغيرة،  $k > 1$  فإن:  $\bar{R}^2 \leq R^2$  أما في العينات الكبيرة فإن:  $\bar{R}^2 \approx R^2 \Rightarrow \lim_{n \rightarrow +\infty} \left( \frac{n-1}{n-k-1} \right) = 1$

2. يمكن أن تنخفض قيمة  $R^2$  وذلك بإدخال متغيرة خارجية جديدة في النموذج.

3. يمكن أن يأخذ  $\bar{R}^2$  قيمة سالبة.

$$F_C = \left( \frac{n-k-1}{k} \right) \left( \frac{R^2}{1-R^2} \right)$$

4|5|3 العلاقة بين  $R^2$  واختبار  $F$ :

يمكن تحديد طبيعة العلاقة بين  $R^2$  و  $F$  من خلال بناء جدول تحليل التباين (ANOVA).

جدول (...): يوضح الشكل النهائي لجدول (ANOVA) ، والعلاقة بين  $R^2$  واختبار  $F$ .

Source	SS	d.f	MS	$F_C$
Regression	$ESS = \hat{Y}'\hat{Y}$	$k$	$R^2 Y'Y / (k)$	$F_C = \left( \frac{R^2}{1 - R^2} \right) \left( \frac{n - k - 1}{k} \right)$
Residuel	$RSS = \hat{\varepsilon}'\hat{\varepsilon}$	$n - k - 1$	$(1 - R^2) Y'Y / (n - k - 1)$	
Total	$TSS = Y'Y$	$n - 1$	.....	

### 6|3 الاختبارات الإحصائية لمعنوية تقديرات المربعات الصغرى:

تناولنا فيما سبق استخدام أسلوب المربعات الصغرى لتقدير معاملات النموذج. إلا أن ذلك يتطلب إجراء بعض الاختبارات الإحصائية حول قيم المعلمات التي تم تقديرها للتأكد من معنويتها الإحصائية.

### 1|6|3 اختبار المعنوية الكلية للنموذج (F - Fisher):

لاختبار المعنوية الكلية للنموذج الخطي المتعدد [1]  $Y = X\beta + \varepsilon$ ، أو بالأحرى اختبار ما إذا كانت المتغيرات المستقلة  $X_1, X_2, X_3, \dots, X_k$  لها تأثير جوهري على المتغير التابع  $Y$ ، يمكن صياغة الفرضيتين الصفرية والبدلية لها على النحو التالي:

الفرضية الصفرية هي:  $H_0 : \beta_1 = \beta_2 = \dots = \beta_k = 0$

والفرضية البديلة هي:  $H_1 : \exists \beta_i \neq 0; i = \overline{1, k}$

$$F_C = \frac{R^2 / k}{(1 - R^2) / (n - k - 1)} \rightarrow F_\alpha(k, n - k - 1) \quad \text{* إحصاءة الاختبار:}$$

حيث يمكن حساب  $F_C$  وتحديد قيمة  $F_\alpha$  المجدولة بالبحث في جدول القيم الحرجة لتوزيع  $F$  عند درجات حرية  $(df = n - k - 1)$  ومستوى معنوية معين 0,05 أو 0,01.

\***القرار:** يمكن إجراء هذا الاختبار باستخدام جدول تحليل التباين (ANOVA).

- فإذا كان  $F_C > F_\alpha$  نرفض الفرضية  $H_0$ ، بمعنى أن للنموذج ككل معنوية إحصائية بنسبة دلالة  $\alpha$ .

- أما إذا كان  $F_C \leq F_\alpha$  نقبل الفرضية  $H_0$ ، بمعنى أن النموذج غير مقبول إحصائياً عند مستوى الدلالة  $\alpha$ .

ويمكن اختبار المعنوية الكلية للنموذج اعتماداً على مفهوم P-value حسب القاعدة التالية<sup>4</sup>: " نرفض الفرضية الصفرية إذا كان  $p \leq \alpha$ ."

<sup>4</sup> P-value: هو احتمال البيانات التي توضح عزوفاً عن الفرضية الصفرية، عندما تكون هذه الفرضية صحيحة.

### 2|6|3 اختبار المعنوية الإحصائية للمعالم:

تركز هذه الفقرة على اختبار معنوية كل متغير مستقل منفردا في تفسير المتغير التابع. ومن الاختبارات الإحصائية التي يمكن تطبيقها في هذا الإطار هو التوزيع الطبيعي  $Z$ ، إذا كان حجم العينة كاف (30  $n$ ). وقد يصعب في الواقع العملي على معنوية المتغيرات المستقلة منفردة. ويتم تحويل قيم أي متغير إلى وحدات  $t$  باستخدام الصيغة التالية:

$$t = (\hat{\beta}_j - \beta_j) / \hat{\sigma}_{\hat{\beta}_j} \rightarrow N(0,1)$$

وتصاغ الفرضية الصفرية والبدلية لها كما يلي:

$$.5: \begin{cases} H_0 : \forall i = 1, n : \beta_i = 0 \\ H_1 : \exists \beta_i \neq 0 \end{cases}$$

$$t_c = \hat{\beta}_i / \hat{\sigma}_{\hat{\beta}_i} \rightarrow t_{\alpha/2}(n - k - 1) \quad \text{*إحصاءة الاختبار:}$$

\*القرار: تتم مقارنة قيمة  $t_C$  المحسوبة بقيمة  $t_{\alpha/2}$  المجدولة.

- فإذا كان:  $|t_c| \geq t_{\alpha/2}$ ، نرفض الفرضية  $H_0$  بمعنى أن المعلم  $\beta_i$  يختلف معنويا عن الصفر بنسبة دلالة  $\alpha$ .
  - وإذا كان:  $|t_c| < t_{\alpha/2}$ ، نقبل الفرضية  $H_0$ . أي أن المعلم  $\beta_i$  ليس له معنوية إحصائية عند مستوى الدلالة  $\alpha$ .
- كما يمكن اختبار المعنوية الإحصائية للمعلم  $\beta_i$  اعتمادا على مفهوم P-value حسب القاعدة التالية: " نرفض الفرضية  $H_0$  إذا كان  $p \leq \alpha$ ."

<sup>17</sup>David R. Anderson et autres, p694.