

الانحدار الخطي البسيط

Linear Regression

يختص الانحدار الخطي البسيط بإيجاد المعادلة الرياضية التي تربط بين المتغيرين (X) و (Y) ، وسمي بالانحدار الخطي لأن العلاقة خطية (معادلة خط مستقيم) ويتم التأكد من ذلك من رسم شكل الانتشار، وايضا سمي الانحدار البسيط ؛ لأنه اختص بدراسة العلاقة بين متغيرين اثنين فقط ، و لإيجاد المعادلة التي تربط بين المتغيرين ، نحدد أولاً ايهما المتغير التابع ونرمز له بالرمز (Y) وايهما المستقل ونرمز له بالرمز (X) .

المعادلة التي تربط بين المتغيرين تسمى معادلة انحدار المتغير التابع (Y) على المتغير المستقل (X) ويكون شكل معادلة خط الانحدار (المستقيم) للمجتمع على الشكل : $Y = \beta_0 + \beta_1 X + E_i$.

وللعينة يكون شكل المعادلة : $Y = b_0 + b_1 X + e_i$.

وهنا تم اعتبار ان المتغير التابع هو المتغير (Y) وأن المتغير المستقل هو المتغير (X) في بعض التطبيقات يطلب من الاحصائي تحديد المتغير التابع من المتغير المستقل .

وحيث أن β_0 المعامل الثابت اما

β_1 = فهي تسمى ميل الانحدار أو معامل الانحدار، وهي تمثل مقدار التغير في المتغير التابع (Y) عند زيادة قيمة المتغير (X) بمقدار وحدة واحدة .

عندما تكون البيانات مأخوذة من عينة مسحوبة من المجتمع الاحصائي ، يتم تقدير نموذج الانحدار ويتم التعبير عن شكل معادلة الانحدار المقدرة كالاتي :

$$\hat{Y}_i = \hat{b}_0 + \hat{b}_1 X + e_i$$

\hat{Y} : تمثل القيمة المقدرة للمتغير التابع للمجتمع (الظاهرة التي تتأثر بالمتغير المستقل) .

X : تمثل قيمة أو قيم المتغير المستقل المسحوبة من المجتمع الاحصائي (الظاهرة المؤثرة على المتغير تابع)

\hat{b}_0 : المعامل الثابت .

\hat{b}_1 : معامل الانحدار أو ميل الانحدار .

e_i : يمثل انحراف القيم التقديرية \hat{Y} عن القيم الحقيقية Y ويمكن التعبير عن هذه العلاقة بالصيغة التالية $e_i = Y - \hat{Y}$.

تقدير معامل (ميل) الانحدار باستخدام المربعات الصغرى

يتم استخدام طريقة المربعات الصغرى في تقدير ميل الانحدار المجهول ، حيث تقوم هذه الطريقة بتقليل مجموع مربعات انحرافات القيم التقديرية عن القيم الحقيقية .

$$e_i = Y_i - \hat{Y}_i , \hat{Y}_i = b_0 + b_1 X_i .$$

و بالتعويض عن قيمة \hat{Y}_i ، بتربيع الطرفي وادخال المجموع ، ثم المفاضلة بالنسبة b_0 ومساواتها بالصفر ، وادخال المجموع بالقسمة على 2- نحصل على :

$$\sum_{i=1}^n Y_i = n\hat{b}_0 + \hat{b}_1 \sum_{i=1}^n X_i \dots \dots \dots (1)$$

وتربيع طرفي e_i ثم المفاضلة بالنسبة ل b_1 , ومساواتها بالصفر والقسمة على 2- نحصل على :

$$\sum_{i=1}^n X_i Y_i = \hat{b}_0 \sum_{i=1}^n X_i + \hat{b}_1 \sum_{i=1}^n X_i^2 \dots \dots \dots (2)$$

وبإجراء الاختصارات والاضافات والعمليات الرياضية نصل الى الصيغة النهائية :

$$\hat{b}_0 = \frac{n \sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i \sum_{i=1}^n y_i}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2}$$

$$\hat{b}_1 = \frac{\sum_{i=1}^n y_i}{n} + \hat{b}_0 \frac{\sum_{i=1}^n x_i}{n}, \quad \hat{b}_1 = \bar{Y} + b_0 \bar{X}$$

فرضيات نموذج الانحدار الخطي البسيط :

الافتراض هو ان معطيات المتغير المستقل قادرة على اظهار تأثيرها في تغير المتغير التابع

كما أن قيم المتغير المستقل تكون مستقلة عن بعضها ، ويمكن صياغة الفرض كالآتي

$\sum_{i=1}^n (x_i - \bar{x})^2 \neq 0$ كما ان قيم المتغير المستقل تكون مستقل عن بعضها ،ويمكن صياغة الفرض كالات

* الخطأ العشوائي يتبع التوزيع الطبيعي ، وتوزيع المعاينة y يتبع التوزيع الطبيعي وايضا المتغير التابع e_i * الخطأ العشوائي

* الخطأ العشوائي لمعالم نموذج الانحدار تتبع ايضا التوزيع الطبيعي $e_i \sim N(0, S^2)$.

* القيمة المتوقعة للخطأ العشوائي مساوي للصفر $E(e_i) = 0$.

* تباين حد الخطأ العشوائي ثابت لكل قيم المتغير العشوائي $V(e_i) = E(e_i^2) - E(e_i)^2$

* القيمة التي يأخذها الخطأ العشوائي في فترة ما تكون غير متعلقة بقيمة اخرى في فترة اخرى

$$\text{COV}(e_i, e_j) = 0 \quad j=1 \dots \dots n \quad i=1 \dots \dots n$$

*ملاحظة :

يمكن اختبار فرضيات نموذج الانحدار الخطي البسيط باستخدام اختبار F .

ان تحليل الانحدار هو وسيلة إحصائية تفيد في دراسة العلاقة بين متغيرين او اكثر بشكل معادلة بحيث يكون اجد هذه المتغيرات متغير معتمد والآخر متغير مستقل يؤثر في المتغير المعتمد ويمكن تقسيم الانحدار الى قسمين:

1- انحدار خطي بسيط Simple linear Regression

2- انحدار خطي متعدد Multiple linear Regression

ونظرا لضيق الوقت سوف نتناول الانحدار الخطي البسيط فقط.

في الانحدار الخطي البسيط: يكون هناك متغيرين فقط احدهما مستقل x_i والآخر معتمد y_i

اما في الانحدار الخطي المتعدد فيكون هناك عدة متغيرات مستقلة ومتغير معتمد واحد فقط

نموذج الانحدار (معادلة الانحدار)

$$\hat{y}_i = \hat{B}_0 + \hat{B}_1 x_i$$

حيث ان : \hat{Y} = المعتمد المتغير = *dependent variable*

x_i = المستقل المتغير = *independent variable*

معاملات الانحدار \hat{B}_0, \hat{B}_1

نقطة التقاطع مع المحور $\hat{B}_0 = Y$

ميل خط الانحدار \hat{B}_1

اما المعادلات الخاصة بمعاملات الانحدار فتحسب وفق القوانين التالية:

$$\hat{B}_1 = \frac{\sum x_i y_i - \frac{(\sum x_i)(\sum y_i)}{n}}{\sum x_i^2 - \frac{(\sum x_i)^2}{n}} \quad \text{او} \quad \hat{B}_1 = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sum (x_i - \bar{x})^2}$$

يمكن استخدام احد القانونين فقط

$$\hat{B}_0 = \bar{y} - \hat{B}_1 \bar{x}$$

مثال // البيانات التالية تمثل x المطر والنبات الطبيعي y والمطلوب حساب معادلة انحدار y/x ؟

xi	yi
30	73
20	50
60	128
80	170
40	87
50	108
60	135
30	69
70	148
60	132
المجموع	500

الحل نجد



الحل

➡

X_i^2	Y_i^2	$x_i y_i$
900	5329	2190
400	2500	1000
3600	16384	7680
6400	28900	13600
1600	7569	3480
2500	11664	5400
3600	18225	8100
900	4761	2070
4900	21904	10360
3600	17424	7920
المجموع	28400	134660

$$\hat{y}_i = \hat{B}_0 + \hat{B}_1 x_i$$

بما ان معادلة الانحدار

نحتاج الى
إيجاد

$$\bar{x} = \frac{\sum x_i}{n} = \frac{500}{10} = 50$$

$$\bar{y} = \frac{\sum y_i}{n} = \frac{1100}{10} = 110$$

$$\hat{B}_1 = \frac{\sum x_i y_i - \frac{(\sum x_i)(\sum y_i)}{n}}{\sum x_i^2 - \frac{(\sum x_i)^2}{n}} = \frac{61800 - \frac{(500)(1100)}{10}}{28400 - \frac{(500)^2}{10}} = 2$$

$$\hat{B}_0 = \bar{y} - \hat{B}_1 \bar{x} = 110 - (2)(50) = 10$$

$$\hat{y}_i = \hat{B}_0 + \hat{B}_1 x_i$$

$$\hat{y}_i = 10 + 2x_i$$

نموذج الانحدار الخطي المتعدد

وتكون صيغته كالتالي : $i=1,2,\dots,k$ $Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + e_i$ والنموذج الممثل للعينه المسحوبة من نفس المجتمع الاحصائي للدراسة :

$$Y_i = b_0 + b_1 X_{1i} + b_2 X_{2i} + \dots + b_k X_{ki}$$

أي أن المتغير التابع قد يتأثر بأكثر من متغير مستقل واحد كما هو الحال في المثال الذي يكون فيه وزن الطفل هو المتغير Y . بينما عمر الطفل هو المتغير المستقل (المفسر) ، ولكن يمكن اضافة متغير آخر وهو طول الطفل كمتغير مفسر ثاني حيث يصبح :

$$Y_i = b_0 + b_1 X_{1i} + b_2 X_{2i} + e_i$$

وهكذا النموذج يصبح X_2 هو طول الطفل و X_1 عمر الطفل .

عندما تكون المتغيرات المستقلة (X_1, X_2, \dots, X_p) تساوي صفر ، فإن β_0 يمثل متوسط المتغير التابع Y ، حيث أن المعامل β_1 يمثل الاثر الصافي أو المباشر لتغير (X_1) بوحدة واحدة على القيمة المتوقعة للمتغير Y مع ثبات باقي المتغيرات ، في حين أن المعامل β_2 تمثل التغير في القيمة المتوقعة للمتغير التابع Y ، ناتج عن تغير المتغير المستقل (X_2) بوحدة واحدة بفرض ثبات المتغيرات (X_1, X_3, \dots, X_p) ، وهكذا يستمر التفسير لباقي معاملات الانحدار الجزئية .

تقدير معالم النموذج

وتستخدم طريقة المربعات الصغرى في تقدير معالم نموذج الانحدار الخطي المتعدد ، ويأخذ نموذج الانحدار المقدّر من العينة المقابلة لمعادلة انحدار المجتمع الشكل :

$$Y_i = b_0 + b_1 X_{1i} + b_2 X_{2i} + \dots + b_p X_{pi} + e_i \quad i=1,2,\dots,n$$

حيث أن :

(b_0, b_1, \dots, b_p) هي القيم المقدرة للمعالم $(\beta_0, \beta_1, \dots, \beta_p)$

e_i : الباقي وهو الفرق بين القيمة الفعلية للمتغير التابع والقيمة المقدرة لها للمشاهدة رقم (i) .

n : عدد المشاهدات (حجم العينة) ، ويمكن كتابة المعادلة في شكل مصفوفة :

$$\begin{pmatrix} b_0 \\ b_1 \\ . \\ . \\ . \\ . \\ b_p \end{pmatrix} \begin{pmatrix} 1 & X_{11} & X_{21} & X_{31} & . & X_{p1} \\ 1 & X_{12} & X_{22} & X_{32} & . & X_{p2} \\ . & . & . & . & . & . \\ . & . & . & . & . & . \\ . & . & . & . & . & . \\ . & . & . & . & . & . \\ 1 & X_{1n} & X_{2n} & X_{3n} & . & X_{pn} \end{pmatrix} \begin{pmatrix} Y_1 \\ Y_2 \\ . \\ . \\ . \\ . \\ Y_n \end{pmatrix} \begin{pmatrix} e_1 \\ e_2 \\ . \\ . \\ . \\ . \\ e_n \end{pmatrix}$$

ويمكن باختصار كتابة نموذج الانحدار كالتالي :

$$e + b Y = X$$

حيث أن :

b = متجه عمودي من الدرجة $((p+1) \times 1)$ يحتوي على قيم المعاملات المقدرة .

X مصفوفة بيانات العينة من الدرجة $((n \times (p+1)))$ حيث n عدد المشاهدات (حجم العينة) .

e = متجه عمودي من الدرجة $n \times 1$ ويحتوي على البواقي .

وتستخدم طريقة المربعات الصغرى لتقدير معالم نموذج الانحدار المتعدد، وتنص على تصغير مجموع مربعات البواقي الى ادنى قيمة له $\min \sum_{i=1}^n e_i^2$.

. ويتم تقدير معالم نموذج الانحدار بحيث تكون الدالة دالة صغرى ،وبإجراء العمليات الرياضية والاختصارات نحصل على مقدر المربعات الصغرى .

$$\sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - b_0 - b_1 X_{1i} - b_2 X_{2i} - \dots - b_p X_{pi})$$

$$e^T e = \begin{bmatrix} e_1 & e_2 & e_3 & . & . & . & e_n \end{bmatrix} \begin{pmatrix} e_1 \\ e_2 \\ . \\ . \\ e_n \end{pmatrix} = \sum_{i=1}^n e_i^2$$

$$e^T e = (Y - Xb)^T (Y - Xb)$$

إذا :

$$e^T e = Y^T Y - 2b^T X^T Y + b^T X^T X b \quad \dots\dots\dots(1)$$

ومساواة الناتج بالصفر b وبمفاضلة المعادلة رقم 1 بالنسبة ل

$$= -2X^T Y + 2X^T X b = 0 \quad \dots\dots\dots(2) \frac{\partial e^T e}{\partial b}$$

$$X^T X b = X^T Y \quad \dots\dots\dots(3)$$

نحصل على $(X^T X)^{-1}$ وبضرب المعادلة (3) ف

$$(X^T X)^{-1} X^T X b = (X^T X)^{-1} X^T Y$$

$$Ib = (X^T X)^{-1} X^T Y \quad , \quad \hat{b} = (X^T X)^{-1} X^T Y$$

نموذج الانحدار متعدد الحدود (Polynomial Regression Models):

ويعرف نموذج الانحدار الخطي متعدد الحدود بأنه دالة بأنه يظهر فيها متغير مستقل اساسي عدد من المرات مرفوعا في كل مرة الى درجة أعلى . ويأخذ النموذج من الدرجة (p) الصيغة التالية :

$$Y_i = \beta_0 + \beta_1 X_i^1 + \beta_2 X_i^2 + \dots + \beta_p X_i^p + U_i \quad i=1 \dots n$$

ويعتبر نموذج الانحدار متعدد الحدود حالة خاصة من نموذج الانحدار الخطي المتعدد ، وبما انه يوجد متغير اساسي واحد فانه يمكن تمثيل أي نموذج متعدد الحدود ، برسم شكل الانتشار بين المتغير التابع والمتغير المستقل بهدف تحديد منحني يصف العلاقة بينهما .

وستقتصر دراستنا على نموذجي الانحدار من الدرجة الثانية والثالثة ؛ لان الدرجات الأعلى نادرا ما تستخدم في الواقع العملي فضلاً عن أن مشكلة الارتباط الخطي المتعدد تتفاقم بزيادة عدد الحدود . وبما أن هذه النماذج كما اسلفنا هي حالات خاصة من نموذج الانحدار الخطي المتعدد ، فانه يتم استخدام طريقة المربعات الصغرى الاعتيادية لتقدير معالم النموذج ، وكذلك يتم حساب الاحصاءات الاخرى كمعامل التحديد ، الخطأ المعياري وغيرها بنفس الصيغ المستخدمة لنموذج الانحدار الخطي المتعدد .

*اختبار معنوية نموذج الانحدار ككل

لاختبار معنوية كل المتغيرات المستقلة يتم اختبار الفرض التالي :

فرض العدم $\beta_0 = \beta_1 = \beta_2 = \dots = 0$: H_0 في مقابل الفرض البديل : ليست كل قيم المعالم مساوية للصفر .
ويكافئ هذا الاختبار اختبار F :

$$F_0 = \frac{ESS/P}{RSS/(n-p-1)} \sim F_{p, (n-p-1)}$$

ESS: مجموع مربعات الانحدار لنموذج الانحدار من الدرجة الثانية ز
RSS: مجموع مربعات البواقي للنموذج .

P: عدد المتغيرات المستقلة (X^2, X) .

n : عدد المشاهدات .