

Regression Analysis تحليل الانحدار

الانحدار الخطي المتعدد

في الانحدار الخطي البسيط لدينا متغير مستقل (X_i) واحد وكذلك متغير معتمد واحد

$\underline{Y_i}$	$\underline{X_i}$
y_1	x_1
y_2	x_2
.	.
.	.
y_n	x_n


أما في حالة الانحدار الخطي المتعدد فيكون لدينا m من المتغيرات المستقلة كل منها يحتوي على n من المشاهدات وكما يلي

$\underline{Y_i}$	$\underline{X_{i1}}$	$\underline{X_{i2}}$	 $\underline{X_{im}}$
y_1	x_{11}	x_{12}	 x_{1m}
y_2	x_{21}	x_{22}	 x_{2m}
.	.	.	.
.	.	.	.
y_n	x_{n1}	x_{n2}	 x_{nm}

ويمكن تمثيل العلاقة بين المتغير المعتمد y_i والمتغيرات المستقلة X_i ، فلو كان لدينا مثلا متغيرين مستقلين فقط X_{i1} و X_{i2} فمعادلة الانحدار المتعدد في هذه الحالة هي سيصبح متوسط قيم y لمختلف قيم X_1 و X_2

$$Y_i = \beta_0 + \beta_{i1} X_{i1} + \beta_{i2} X_{i2} + U_i$$

ويكون الشكل سطح بثلاث أبعاد كالآتي:



لذا فانه وبصورة عامة يمكن تمثيل العلاقة الدالية Functional Relationship بين المتغير المعتمد y والمتغيرات المستقلة X_i 's في تحليل الانحدار المتعدد كما يلي:

$$Y_i = \beta_0 + \beta_{i1} X_{i1} + \beta_{i2} X_{i2} + \dots + \beta_{iK} X_{iK} + \varepsilon_i$$

وتسمى هذه المعادلة بنموذج من الدرجة الأولى First order model

أو الانحدار السطحي surface model

أو الاستجابة السطحية Regression surface model

حيث أن :

$X_{i1}, X_{i2}, \dots, X_{im}$ عبارة عن قيم ثابتة لـ m من المتغيرات المستقلة وتسمى ثابتته لان ليس لها توزيع عشوائي

$\beta_0, \beta_1, \beta_2, \dots, \beta_m$ هي ثوابت او معاملات معادلة الانحدار.

β_0 : محل تقاطع مستوى الانحدار regression plane مع المحور y

أو متوسط الاستجابة عندما تكون كافة المتغيرات المستقلة تساوي صفر

β_j : يمثل معامل الانحدار الجزئي لـ y على X_j عندما تكون بقية المتغيرات المستقلة ثابتة.

أو مقدار التغير في y عند زيادة وحدة واحدة في X_j عندما تكون بقية المتغيرات ثابتة.

ε_i الخطأ العشوائي

وباستخدام المصفوفات يمكن كتابة النموذج أعلاه كما يلي

حيث أن :

$$\underline{y} = \underline{X} \underline{\beta} + \underline{u}$$

حيث أن :

$\underline{y}$: تمثل متجه لملاحظات متغير الاستجابة

X : تمثل مصفوفة لملاحظات المتغيرات التوضيحية

β : متجه معاملات الانحدار .

e : متجه الخطأ العشوائي

فروض التحليل Assumption of analysis

1- إن Y متغير عشوائي وقيمته مستقلة إحصائياً الواحد عن الآخر ويتوزع توزيعاً طبيعياً بوسط حسابي

قدره $\mu_{y|x_1x_2...x_m}$ وتباين $\sigma^2_{y|x_1x_2...x_m}$

أي أن

$$y \sim N(\mu_{y|x_1x_2...x_m}, \sigma^2_{y|x_1x_2...x_m})$$

$$\mu_{y|x_1x_2...x_m} = E(Y_i) = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_m X_{im}$$

$$\sigma^2_{y|x_1x_2...x_m} = \sigma^2_{(\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_m X_{im})} = \sigma_e^2 = \sigma^2 I_n$$

2- إن ε_i هو خطأ عشوائي يتبع التوزيع الطبيعي بوسط حسابي $E(\varepsilon_i)=0$ وتباين ثابت مقداره σ_e^2 .

$$e_i \sim N(0, \sigma_e^2)$$

3- إن قيمة الخطأ ε_i في فترة معينة غير مرتبطة بقيمتها في فترة أخرى ولذلك فإن التباين المشترك بينهما يساوي صفراً أي أن

$$\text{cov}(\varepsilon_i, \varepsilon'_i) = 0$$

4- إن قيم متغير المستقلة X ثابتة fixed أي أن معطاة ولا تتوزع عشوائياً

5- عدم وجود علاقة خطية تامة أو غير تامة بين المتغيرات المستقلة أي غياب مشكلة تعدد العلاقة الخطية Multicollinearity.

تقدير المعلمات بطريقة المربعات الصغرى

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_m X_{im} + \varepsilon_i$$

$$\varepsilon_i = Y_i - (\beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_m X_{im})$$

$$\Rightarrow \varepsilon_i = Y_i - \beta_0 - \sum_{j=1}^m \beta_j X_{ij}$$

$$\sum_{i=1}^n \varepsilon_i^2 = \sum_{i=1}^n (Y_i - \hat{\beta}_0 - \sum_{j=1}^m \hat{\beta}_j X_{ij})^2 = K$$

ويأخذ المشتقة الجزئية ل K ومساواتها بالصفر نحصل على:

$$\frac{\partial K}{\partial \beta_0} = -2 \sum_{i=1}^n (Y_i - \hat{\beta}_0 - \sum_{j=1}^m \hat{\beta}_j X_{ij}) = 0$$

$$\frac{\partial K}{\partial \beta_j} = -2 \sum_{i=1}^n (Y_i - \hat{\beta}_0 - \sum_{j=1}^m \hat{\beta}_j X_{ij}) X_{ij} = 0$$

وبحل المعادلتين أعلاه نحصل على المعادلات الطبيعية وكما يلي

$$\begin{bmatrix} n & \sum_{i=1}^n X_{i1} & \cdot & \cdot & \sum_{i=1}^n X_{im} \\ \sum_{i=1}^n X_{i1} & \sum_{i=1}^n X_{i1}^2 & \cdot & \cdot & \sum_{i=1}^n X_{i1} X_{im} \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \sum_{i=1}^n X_{ik} & \sum_{i=1}^n X_{im} X_{i1} & \cdot & \cdot & \sum_{i=1}^n X_{ik}^2 \end{bmatrix} * \begin{bmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \\ \cdot \\ \cdot \\ \hat{\beta}_m \end{bmatrix} = \begin{bmatrix} \sum y_i \\ \sum x_{i1} y_i \\ \sum x_{i2} y_i \\ \cdot \\ \sum x_{im} y_i \end{bmatrix}$$

$$\begin{matrix} (X'X) & \underline{\hat{\beta}} & (X'Y) \end{matrix}$$

$$\underline{X} = \begin{bmatrix} 1 & X_{11} & . & . & . & X_{1m} \\ 1 & X_{21} & . & . & . & X_{2m} \\ . & . & & & & . \\ . & . & & & & . \\ . & . & & & & . \\ 1 & X_{n1} & . & . & . & X_{nm} \end{bmatrix}_{n(m+1)}$$

هذا يعني

$$(X'X)\underline{\hat{\beta}} = (X'Y)$$

وبضرب كلا الطرفين في $(X'X)^{-1}$ فان مقدرات المربعات الصغرى الاعتيادية يعطى بالشكل التالي:

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

$$\Rightarrow \underline{\hat{\beta}}_{ols} = (X'X)^{-1}X'Y$$

$$\hat{Y}_1 = \hat{\beta}_0 + \hat{\beta}_1 X_{11} + \hat{\beta}_2 X_{12} + \dots + \hat{\beta}_m X_{1m}$$

$$\hat{Y}_2 = \hat{\beta}_0 + \hat{\beta}_1 X_{21} + \hat{\beta}_2 X_{22} + \dots + \hat{\beta}_m X_{2m}$$

$$\Rightarrow \underline{\hat{y}} = \underline{x}\underline{\hat{\beta}}$$

$$\underline{e} = \underline{y} - \underline{\hat{y}} \quad \triangleright \quad \underline{e} = \underline{y} - \underline{x}\underline{\hat{\beta}}$$

$$(X'X) = \underline{C} = \begin{bmatrix} C_{00} & C_{01} & \dots & C_{0m} \\ C_{10} & C_{11} & \dots & C_{1m} \\ . & . & & . \\ . & . & & . \\ C_{m0} & C_{m1} & \dots & C_{mm} \end{bmatrix}_{(m+1)(m+1)}$$

$$\triangleright V(\underline{\hat{\beta}}) = \sigma^2 (X'X)^{-1} = \sigma^2 \underline{C}$$