

الانحدار والارتباط البسيط Simple Regression and Correlation

التوزيع ذو متغيرين Bivariate Distribution ويرمز لهذين المتغيرين x و y فمثلا قد يكون x هو عدد نباتات القطن في وحدة المساحة بينما المتغير y هو كمية المحصول الناتج ... من ذلك يتضح بان كل فرد من افراد العينة له قياسان احدهما للمتغير x والاخر للمتغير y .

ان الغاية الرئيسية من دراسة توزيع ذو متغيرين هي:

- 1- لتحديد العلاقة بين المتغيرين x و y ووضعها بشكل معادلة بحيث يمكن التنبؤ من x بدلالة y (وهذا ما يسمى بالانحدار Regression).
- 2- لقياس درجة العلاقة بين المتغيرين (x و y) وهذا ما يسمى بالارتباط (Correlation) او بمعنى اخر قياس مدى التلازم او الترابط بين متغيرين مستقلين.

الانحدار الخطي البسيط Simple linear regression

هو خط مستقيم يمر بمجموعة من النقاط تجعل مجموع مربعات النقاط المتبقية من النموذج (اي المسافات الراسية بين النقاط المتبقية والخط) اقل ما يمكن. والنحدار بصورة عامة ينقسم الى قسمين:

- 1- انحدار بسيط Simple regression ويشمل على متغيرين فقط احدهما مستقل x والاخر معتمد y .
- 2- انحدار متعدد Multiple regression ويشمل على اكثر من متغيرين احدهما معتمد y والاخرى متغيرات مستقلة (x_1, x_2, \dots, x_n)

وسوف يقتصر شرحنا هنا فقط على الانحدار الخطي البسيط اي ان المعادلة تصف العلاقة بين x و y هي معادلة خطية (linear) وتمثل بيانيا بخط مستقيم. نفرض باننا نريد التنبؤ بالدرجات النهائية لطالب في مادة الاحصاء (y) معتمدين بذلك على معدل درجته الفصلية في الاحصاء x لذا فان (x, y) تمثل النتيجة لاي طالب في المجتمع (population).

ان عينة عشوائية من المجتمع ذات حجم n يمكن تمثيلها بالمجموعة

$$(x_i, y_i) \text{ where } i = 1, 2, 3, \dots, n$$

ان قيمة y ستكون متغيرة من عينة الى اخرى لذا فان y_i هي قيمة من قيم المتغير العشوائي. وللسهولة سنعني بالرمز $y|x_i$ بانه يمثل المتغير العشوائي y التابع لقيمة ثابتة x_i وسنرمز لتوزيعه الاحتمالي بالرمز $f_{y|x}$. وسنرمز للوسط الحسابي لتوزيع جميع الدرجات النهائية في مادة الاحصاء عند كل معدل فصلي معلوم x بالرمز $\mu_{y|x}$ اي ان:

$$\mu_{y|x} = E(y|x)$$

بينما سنرمز لتباين هذا التوزيع بالرمز $\sigma_{y|x}^2$

هذا وسنفترض بان: y_1, y_2, \dots, y_n

لها توزيع طبيعي اي ان $y \sim N(\mu_{y|x}, \sigma_{y|x}^2)$

وان تبايناتها متساوية اي $\sigma_{y|x}^2 = \sigma^2$

لجميع قيم x

ان المعلمة $\mu_{y|x}$ هي ثابتة لاي قيمة معينة من x ولكنها تتغير للقيم المختلفة من x .

ان ما سبق ذكره يمكن تلخصه ببيانيا بثلاثة قيم من x (x_1, x_2, x_3) وكما في الشكل التالي:

ان المنحني الذي يصل الاوساط الحسابية لجميع التوزيعات يسمى بمنحني الانحدار Regression curve فاذا كان هذا المنحني يمثل خطا مستقيما كما في الشكل اعلاه

فان الانحدار خطي linear يمكن تمثيله بالمعادلة التالية:

$$\mu_{y|x} = \alpha + \beta x \text{ Where } \alpha \text{ and } \beta \text{ are constants}$$

وتسمى هذه المعادلة بمعادلة خط الانحدار للمجتمع وهي تمثل معدل العلاقة بين x and y في المجتمع.

الشكل

ان الثابت α (a) هو معدل قيمة y عندما تكون $x=0$ (الشكل 333)

وتسمى نقطة تقاطع خط الانحدار بالمحور الراسي (y- Intercept) بينما الثابت β (b)

فهو ميل خط انحدار المجتمع ويسمى ايضا بمعامل انحدار y على x ويعرف بانه معدل

التغير في y عندما تتغير قيمة x وحدة واحدة.

$$y_x = a + bx$$

β تكون موجبة	β تكون سالبة

تقدير الثوابت او المعالم Estimation of Parameters

1- تقدير النقطة Point Estimation

ان خط الانحدار لعينة عشوائية حجمها n من المشاهدات

(x_i, y_i) where $i = 1, 2, 3, \dots, n$

يمثل بالمعادلة التالية

$$\bar{y}_x = a + bx$$

والذي هو تقدير لقيمة خط انحدار المجتمع $(\mu_{y|x})$ هذا وان كل زوج من المشاهدات (x_i, y_i) تتمثل بالعلاقة التالية

$$y_i = a + bx_i + e_i$$

حيث ان e_i يدعى بالخطا العشوائي

وباستخدام طريقة المربعات الصغرى Method of the least squares فيمكن

ايجاد قيمة كل من a و b اللذان هما تقديران لكل من α و β على التوالي وذلك بجعل مجموع مربعات الانحرافات (عن الخط المستقيم) اقل ما يمكن اي:

$$\sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - a - bx_i)^2$$

وباستخدام التفاضل الجزئي بالنسبة لكل من a و b ثم جعل الناتج مساويا لصفر نحصل على المعادلتين الطبيعيين (Normal equations)

$$\sum y_i = na + b \sum x_i \dots\dots\dots(1)$$

$$\sum x_i y_i = a \sum x_i + b \sum x_i^2 \dots\dots\dots(2)$$

وبحل هاتين المعادلتين نحصل على:

$$b = \frac{\sum x_i y_i - \frac{(\sum x_i)(\sum y_i)}{n}}{\sum x_i^2 - \frac{(\sum x_i)^2}{n}}$$

$$a = \bar{y} - b\bar{x}$$

الارتباط البسيط