

CHAPITRE III

La statistique bidimensionnelle

I) Introduction

On s'intéresse au rapprochement possible entre 2 variables statistiques observées sur une même population, 3 cas sont possibles soit :

- 2 variables quantitatives
- 2 variables qualitatives

Variable quantitative/variable qualitative dans le cadre du cours les 2 variables sont de même nature. On cherche pour ces variables une étude simultanée de celles-ci à traduire au moyen de table graphique et/ou de méthode numérique, la liaison pouvant exister entre ces 2 variables.

II) Représentation graphique

1) Deux variables quantitatives

- juxtaposition d'histogramme et/ou de diagramme en bâtons.

- Nuage de points

Si $(x_i; y_i)_{i=1..n}$ ou $(y_i; x_i)_{i=1..n}$

Si $(x_i)_{i=1..n}$ et $(y_i)_{i=1..n}$ sont respectivement les observations de 2 variables x et y.

2) Deux variables qualitatives

Juxtaposition de diagramme en bâtons.

III) La statistique bidimensionnelle des paramètres.

1) La série double à doubles indices.

On considère 2 variables statistiques x et y admettent (resp. p et q) modalités, classes et/ou valeur observées mesurées sur une même population de taille n.

Ex1:

a) x = poids $(x_i)_{i=1..n}$
y = taille $(y_i)_{i=1..n}$

b) $(x_i; y_j; n_{ij})$
Valeurs observées.
Centre de classes

1.1) Tableau croisé (ou tri croisé).

Définition: déterminer le tableau croisé associé aux variables x et y, c'est déterminer le nombre d'unité statistique n_{ij} répondant simultanément aux

modalités classes ou valeurs observées x_i et y_j de x et y pour $i \in \{1 \dots p\}$ et $j \in \{1 \dots q\}$ $(n_{ij})_{i=1 \dots p, j=1 \dots q}$ constitue un tableau d'effectif croisés.

$$\begin{pmatrix} n_{11}, n_{12}, \dots, n_{1q} \\ n_{21}, n_{22}, \dots, n_{2q} \\ \dots \\ n_{i1}, n_{i2}, \dots, n_{ij}, \dots, n_{iq} \\ \dots \\ n_{p1}, n_{p2}, \dots, n_{pq} \end{pmatrix}$$

Ex 2 : On considère une variable quantitative discrète x et y (resp. 3 et 2) valeurs observées soit :
 $x_1 = 0 \quad x_2 = 1 \quad x_3 = 2$
 $y_1 = 0 \quad y_2 = 1$
 $n = 10$

v	X ₁	X ₂	X ₃	Y ₁	Y ₂
1	0	0	1	1	0
2	1	0	0	1	0
3	1	0	0	0	1
4	0	1	0	1	0
5	0	0	1	1	0
6	0	1	0	0	1
7	0	1	0	0	1
8	1	0	0	1	0
9	1	0	0	1	0
10	0	1	0	0	1

Construisons le tableau des effectifs croisés associés à ces donnés, c'est un tableau de 3 lignes (car X prend 3 valeurs) et 2 colonnes (car Y prend 2 valeurs).

s_{ij} $i=1 \dots 3$ est le nombre d'unité statistique pour lesquelles on a simultanément observés x_i et y_j avec $i=1 \dots 3$ et $j=1 \dots 2$
 n_{11} associé à X_1 et Y_1 on lit $n_{11} = 3$
 n_{12} associé à X_1 et Y_2 on lit $n_{12} = 1$
 n_{21} associé à X_2 et Y_1 on lit $n_{21} = 1$
 n_{22} associé à X_2 et Y_2 on lit $n_{22} = 3$
 n_{31} associé à X_3 et Y_1 on lit $n_{31} = 2$
 n_{32} associé à X_3 et Y_2 on lit $n_{32} = 0$

Le tableau croisé est donc $\begin{pmatrix} n_{11} \dots n_{12} \\ n_{21} \dots n_{22} \\ n_{31} \dots n_{32} \end{pmatrix} = \begin{pmatrix} 3 & 1 \\ 1 & 3 \\ 2 & 0 \end{pmatrix}$

1.2) Transformation d'un tableau croisé

On considère le tableau croisé $(n_{ij})_{i=1 \dots p, j=1 \dots q}$

$n_i = \sum_{j=1 \dots q} n_{ij}$ pour $i=1 \dots p$ on appelle marge colonne et on note n_j la quantité définit

par $n_{.j} = \sum_{i=1 \dots p} n_{ij}$ pour $j=1 \dots q$

On définit le tableau des fréquences croisé par f_{ij} pour $i=1\dots p$ $j=1\dots q$

Avec $f_{ij} = \frac{n_{ij}}{n}$.

On définit aussi :

Les fréquences marges lignes $f_{i.} = \sum_{j=1\dots q} f_{ij}$ pour $i=1\dots p$.

Les fréquences marges colonne $f_{.j} = \sum_{i=1\dots p} f_{ij}$ pour $j=1\dots q$.

On a les relations suivantes $n = \sum_{i=1}^p n_{i.} = \sum_{j=1}^q n_{.j} = \sum_{i=1}^p \sum_{j=1}^q n_{ij}$

$$1 = \sum_{i=1}^p f_{i.} = \sum_{j=1}^q f_{.j} = \sum_{i=1}^p \sum_{j=1}^q f_{ij}$$

Définition: on appelle distribution de X liée pour Y = Y_j les valeurs (n_{1j}, n_{2j}, ... n_{pj} par j=1...p.

Distribution de Y liée pour X = X_i la suite des valeurs (n_{i1}, n_{i2}, ... n_{iq}) pour i=1...p.

Ex 3 (suite ex 2) :

On a le tableau croisé $\begin{pmatrix} 3 & 1 \\ 1 & 3 \\ 2 & 0 \end{pmatrix}$

Déterminons les effectifs des lignes et des colonnes.

$$n_{1.} = \sum n_{1j} = n_{11} + n_{12} = 4$$

$$n_{2.} = \sum n_{2j} = n_{21} + n_{22} = 4$$

$$n_{3.} = \sum n_{3j} = n_{31} + n_{32} = 2$$

$$n_{.1} = \sum n_{i1} = n_{11} + n_{21} + n_{31} = 6$$

$$n_{.2} = \sum n_{i2} = n_{12} + n_{22} + n_{32} = 4$$

$$n = \sum n_{i.} = \sum n_{.j} = \sum_{i=1}^2 \sum_{j=1}^2 n_{ij}$$

	Y ₁	Y ₂	n _i
X ₁	3	1	4
X ₂	1	3	4
X ₃	2	0	2
n _{ij}	6	4	10

La distribution de X liée à Y = Y₁ est

(n₁₁, n₂₁, n₃₁) = (3 ; 1 ; 2).

La distribution de Y liée à X = X₁ est (n₂₁, n₂₂) = (1 ; 3).

Pour les fréquences on a le tableau des fréquences croisées.

$$f_{ij} = \frac{n_{ij}}{n} = \frac{n_{ij}}{10} \text{ pour } i = 1, 2, 3, j = 1, 2$$

Les fréquences marginales s'écrivent $f_{i.} = \sum_{j=1}^2 f_{ij}$ pour $i=1,2,3$

$$f_{.j} = \sum_{i=1,2} f_{ij} \text{ pour } j=1,2$$

De manière générale on a une présentation de la fréquence.

- Propriété d'indépendance des distributions à 2 variables qualitatives.

Définition : distribution théorique

On appelle distribution théorique et on note :

$$(V_{ij})_{i=1, \dots, p}$$

$$\text{La distribution définie par } V_{ij} = \frac{n_{i.} \cdot n_{.j}}{n} \text{ pour } i=1, \dots, p \quad j=1, \dots, q$$

Problème a-t-on indépendance des 2 caractères observés.

A-t-on donc pour cela

$i \in \{1, \dots, p\}$ et $j \in \{1, \dots, q\}$.

$$n_{ij} = V_{ij} = \frac{n_{i.} \cdot n_{.j}}{n} \text{ ou de manière équivalente } f_{ij} = n_{i.} \cdot b_j \cdot f_{i.} ?$$

- Une mesure de l'indépendance de 2 variables :

On a les effectifs observés

$$n_{ij} \quad i=1, \dots, p$$

$$j=1, \dots, q$$

On a les effectifs théoriques

$$(Y_{ij})_{i=1, \dots, p}$$

$$j=1, \dots, q$$

$$Y_{ij} = \frac{n_{i.} \cdot n_{.j}}{n} \quad \text{où} \quad \begin{cases} n_{i.} = \sum n_{ij} \\ n_{.j} = \sum n_{ij} \end{cases}$$

On s'intéresse à la différence $n_{ij} - y_{ij}$

Si pour tout $(i; j)$ $n_{ij} - Y_{ij} = 0$ alors les variables sont indépendantes.

Si pour tout $(i; j)$ donné on a $n_{ij} - Y_{ij} > 0$ alors on dit que le couple $(x_i; y_j)$ est surreprésenté.

Si $n_{ij} - Y_{ij} < 0$, alors on dit que $(x_i; y_j)$ est sous-représenté.

Déterminons les effectifs théoriques :

$$Y_{ij} = \frac{n_{i.} \cdot n_{.j}}{n} \quad \text{où } \begin{matrix} i = 1, 2, 3 \\ j = 1, 2. \end{matrix}$$

effectif	y_1	y_2
x_1	2.4	1.6

x_2	2.4	1.6
x_3	1.2	0.8

$$y_{11} = \frac{n_{1.} \cdot n_{.1}}{n} = \frac{4 \cdot 6}{10} = 2.4$$

$$y_{12} = \frac{n_{1.} \cdot n_{.2}}{n} = \frac{4 \cdot 4}{10} = 1.6$$

$$y_{21} = \frac{n_{2.} \cdot n_{.1}}{n} = \frac{4 \cdot 6}{10} = 2.4$$

$$y_{22} = \frac{n_{2.} \cdot n_{.2}}{n} = \frac{4 \cdot 4}{10} = 1.6$$

$$y_{31} = \frac{n_{3.} \cdot n_{.1}}{n} = \frac{2 \cdot 6}{10} = 1.2$$

$$y_{32} = \frac{n_{3.} \cdot n_{.2}}{n} = \frac{2 \cdot 4}{10} = 0.8$$

Par exemple le couple (1 ; 2) tel que $n_{12} - y_{12} = 1 - 1.6 = -0.6 < 0$.

Donc le couple $(x_i ; y_{12})$ est sous population.

2) Paramètres associés à 2 variables quantitatives double à double indice.

1) Les données

On considère la série $(x_i, y_j, n_{ij})_{i=1, \dots, p}$ associée à 2 variables quantitatives X et Y observée sur une population de taille n et ayant respectivement p et q valeurs observées.

2) Les résumés numériques

a) Les moyennes et les variances marginales

Définition : La moyenne marginale de x est \bar{x}

$$\bar{x} = 1/n \sum_{i=1}^p n_{i.} x_i$$

La moyenne marginale de y est \bar{y}

$$\bar{y} = 1/n \sum_{j=1}^q n_{.j} y_j$$

i=1

Définition : La variance marginale de x est :

$$\begin{aligned} V(x) &= 1/n \sum_{i=1}^p n_i (x_i - \bar{x})^2 \\ &= 1/n \sum_{i=1}^p n_i x_i^2 - \bar{x}^2 \end{aligned}$$

La variance marginale de y est :

$$\begin{aligned} V(y) &= 1/n \sum_{i=1}^q n_{.j} (y_j - \bar{y})^2 \\ &= 1/n \sum_{i=1}^q n_{.j} y_j^2 - \bar{y}^2 \end{aligned}$$

b) Moyenne et variance conditionnelle

Définition : La moyenne conditionnelle de X liée par Y = y_j est :

$$\bar{x}_j = 1/n_{.j} \sum_{i=1}^p n_{ij} x_i$$

La moyenne conditionnelle de Y liée par X = x_i est :

$$\bar{y}_i = 1/n_{i.} \sum_{j=1}^q n_{ij} y_j$$

Définition : La variance conditionnelle de X liée par Y = y_j est :

$$\begin{aligned} V_j(x) &= 1/n_{.j} \sum_{i=1}^p n_{ij} (x_i - \bar{x}_j)^2 \\ &= 1/n_{.j} \sum_{i=1}^p n_{ij} x_i^2 - \bar{x}_j^2 \end{aligned}$$

La variance conditionnelle de Y liée par X = x_i est :

$$V_i(y) = 1/n_{i.} \sum_{j=1}^q n_{ij} (y_j - \bar{y}_i)^2$$

$$V_i(y) = 1/n_{i.} \sum_{j=1}^q n_{ij} y_j^2 - \bar{y}_i^2$$

i=1

c) Relation entre moyenne marginale et moyenne conditionnelle

Propriété :

La moyenne arithmétique pondérée des moyennes conditionnelles de Y (resp. de Y) est égale et la moyenne marginale de X (resp. de Y) soit :

$$\mathbf{x} = 1/n \sum_{i=1}^p n_{.j} \mathbf{x}_j \quad (\text{resp. } \mathbf{y} = 1/n \sum_{i=1}^q n_{i.} \mathbf{y}_i)$$

d) Décomposition de la variance marginale

⇒ Relation entre les variances de X.

$$V(\mathbf{x}) = 1/n \sum_{i=1}^p n_{.j} \cdot V_j(\mathbf{x}) + 1/n \sum_{i=1}^q n_{i.} (\mathbf{x}_j - \mathbf{x})^2$$

Variance résiduelle + variance expliquée

⇒ Relation entre les variances de Y.

$$V(\mathbf{x}) = 1/n \sum_{i=1}^p n_{i.} \cdot V_i(\mathbf{Y}) + 1/n \sum_{j=1}^q n_{i.} (\mathbf{y}_i - \mathbf{y})^2$$

	Y ₁	Y ₂	n _{i.}
x ₁	3	1	4
x ₂	1	3	4
x ₃	2	0	2
n _{.j}	6	4	10

Calculons les moyennes conditionnelles de X liée par $\mathbf{y} = \mathbf{y}_j$ pour $j=1..2$

On a \mathbf{x}_1 moyenne conditionnelle

$$\mathbf{x}_1 = 1/n \sum_{i=1}^3 n_{.1} \mathbf{x}_i$$

$$= 1/6 \cdot (3 \cdot 0 + 1 \cdot 1 + 2 \cdot 2)$$

$$= 5/6.$$

$$\mathbf{x}_2 = 1/n \sum_{i=1}^3 n_{.2} \mathbf{x}_i$$

$$= 1/4 \cdot (1 \cdot 0 + 3 \cdot 1 + 0 \cdot 2) = 3/4 = 0.75$$

La moyenne marginale de x est donc :

$$\mathbf{x} = 1/n \sum_{j=1}^2 n_{.j} \mathbf{x}_j$$

$$\begin{aligned}
&= \frac{1}{n} \cdot (n_{\cdot 1} \bar{x}_1 + n_{\cdot 2} \bar{x}_2) \\
&= \frac{7}{10} \cdot (6 \cdot \frac{5}{6} + 6 \cdot \frac{3}{4}) = \frac{8}{10} \\
&= \frac{4}{5} = 0.8
\end{aligned}$$

Calculons les variances conditionnelles de X liée par $y = y_j \quad j=1..2$
On a :

$$\begin{aligned}
V_1(x) &= \frac{1}{n_{\cdot 1}} \sum_{i=1}^3 n_{\cdot 1} (x_i - \bar{x}_1)^2 \\
&= \frac{1}{n_{\cdot 1}} \sum_{i=1}^3 n_{\cdot 1} x_i^2 - \bar{x}_1^2 \\
&= \frac{1}{6} ((3 \cdot 0^2 + 1 \cdot 1^2 + 2 \cdot 2^2) - (\frac{5}{6})^2) \\
&= \frac{9}{6} - \frac{35}{36} = \frac{29}{36}.
\end{aligned}$$

$$\begin{aligned}
V_2(x) &= \frac{1}{n_{\cdot 2}} \sum_{i=1}^3 n_{\cdot 2} x_i^2 - (\bar{x}_2)^2 \\
&= \frac{1}{4} ((1 \cdot 0^2 + 3 \cdot 1^2 + 0 \cdot 2^2) - (\frac{3}{4})^2) = \frac{3}{4} - (\frac{3}{4})^2 = \frac{3}{4} (\frac{1}{4}) \\
&= \frac{3}{4} - (\frac{3}{4})^2 = \frac{3}{4} (\frac{1}{4}) = \frac{3}{16}.
\end{aligned}$$

$$\begin{aligned}
\text{On obtient } V(x) &= \frac{1}{n} \sum_{i=1}^2 n_{\cdot j} V_j(x) + \frac{1}{n} \sum_{j=1}^2 n_{\cdot j} (\bar{x}_j - \bar{x})^2 \\
&= \frac{1}{10} (6 \cdot \frac{29}{36} + 4 \cdot \frac{3}{16}) + \frac{1}{10} [6 \cdot (\frac{5}{6})^2 + 4 \cdot \\
(3/4)^2 - (0.8)^2] & \\
&= 0.56.
\end{aligned}$$

Paramètre de liaison entre 2 caractères quantitatifs.

1) La covariance

Définition :

La série observée (x_i, y_i, n_{ij}) associée aux variances x et y est tel que la variance de x et y est défini par :

$$\text{Cos}(x ; y) = \frac{1}{n} \sum_{i=1}^p \sum_{j=1}^q (x_i - \bar{x})(y_j - \bar{y})$$

Propriété 2: on a

$$\text{Cos}(x ; y) = \frac{1}{n} \sum_{i=1}^p \sum_{j=1}^q n_{ij} x_i y_j - \bar{x} \bar{y}$$

Propriété 3 : on a

La covariance est un paramètre symétrique.

$$\text{Cov}(x; y) = \text{Cov}(y; x).$$

Propriété 4 :

Pour $(a, b, c) \in \mathbb{R}^4$ on a :

$$\text{Cov}(ax + b, cy + d) = a \cdot c \text{cov}(x; y).$$

Exercice 7 (suite ex 2)

La covariance de x est de y s'écrit:

$$\begin{aligned} \text{cov}(x; y) &= \frac{1}{n} \sum_{i=1}^3 \sum_{j=1}^2 n_{ij} (x_i - \bar{x})(y_j - \bar{y}) \\ &= \frac{1}{n} \sum_{i=1}^3 \sum_{j=1}^2 n_{ij} x_i y_j - \bar{x}\bar{y} \\ &= \frac{1}{n} \sum_{i=1}^3 \sum_{j=2}^2 (n_{i1} x_i y_1 + n_{i2} x_i y_2) - \bar{x}\bar{y} \\ &= \frac{1}{n} (n_{11} x_1 y_1 + n_{12} x_2 y_1 + n_{22} x_2 y_2 + n_{31} x_3 y_1 + n_{32} x_3 y_2) \\ &= \frac{3}{10} - 0.8 \cdot 0.4 \text{ (calculs fait à l'ex 5 } \bar{y} = 0.4 \bar{x} = 0.8) \\ &= 0.3 - 0.32 = -0.02 \end{aligned}$$

La corrélation

Définition : La corrélation entre les variables x et y est défini par :

$$\begin{aligned} r(x; y) &= \rho(x; y) = \frac{\text{cov}(x; y)}{\sqrt{V(x) \cdot V(y)}} \\ &= \frac{\text{cov}(x; y)}{\sigma(x) \cdot \sigma(y)} \end{aligned}$$

Le coefficient de corrélation est le coefficient de corrélation de Bravais Pearson.

Propriété : le coefficient de corrélation est un paramètre symétrique.

3) Série statistique à indice simple.

On considère la série statistique double à indice simple (x_i, y_i, n_i) associée aux variables X et Y observée sur une même population de taille n réécrivons les paramètres du § III) 2) pour cette série.

Propriété : Les moyennes arithmétique de X et de Y s'écrivent :

$$\bar{x} = \frac{1}{n} \sum_{i=1}^p n_i x_i \text{ et } \bar{y} = \frac{1}{n} \sum_{j=1}^q n_j y_j$$

La variance de X et de Y s'écrivent :

$$V(x) = \frac{1}{n} \sum_{i=1}^p n_i (x_i - \bar{x})^2 = \frac{1}{n} \sum_{i=1}^p n_i x_i^2 - \bar{x}^2$$

$$V(y) = \frac{1}{n} \sum_{j=1}^q n_j (y_j - \bar{y})^2 = \frac{1}{n} \sum_{j=1}^q n_j y_j^2 - \bar{y}^2$$

$j=1$ $j=1$

La variance entre X et Y s'écrit :

$$\begin{aligned} \text{Cos}(x; y) &= \frac{1}{n} \sum n_i (x_i - \bar{x})(y_i - \bar{y}) \\ &= \frac{1}{n} \sum n_i x_i y_i - \bar{x}\bar{y}. \end{aligned}$$

La propriété énoncé dans le § III) 2.2) (les résumés numériques) restent vraies pour les séries double à indice simple.

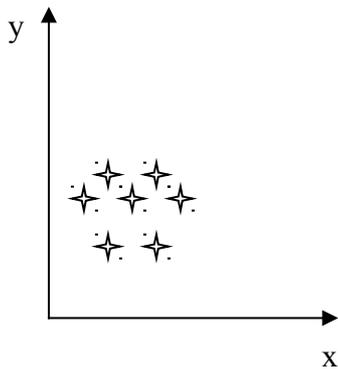
IV) Etude de la liaison entre 2 variables quantitatives

La régression

On considère la série statistique double $(x_i, y_i, n_i)_{i=1, \dots, p}$ observée pour les variables doubles quantitative X et Y sur une même population de taille n.

1) Approche graphique le nuage de points.

Le nuage de points est constitué des points (x_i, y_i) pour $i=1, \dots, 7$

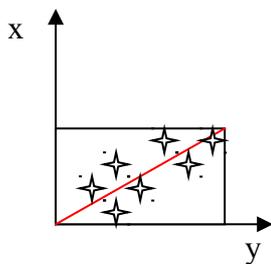


2) Régressions linéaires droites des moindres carrées.

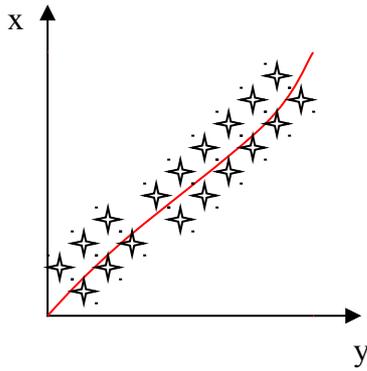
1) Le principe

Définition : la régression linéaire de Y en X consiste à déterminer la fonction affine et les valeurs $(a; b) \in \mathbb{R}^2$ qui rendait minimum la quantité.

$$\sum_{i=1}^p n_i (y_i - (ax_i + b))^2$$



Régression de X en Y $\sum n_i (x_i - (ay_i + b))^2$



2) Définition et propriété

La régression linéaire de Y en X par la méthode des moindres carrés conduit aux coefficients approchés pour a et b.

$$\hat{a} = \frac{\text{cov}(x, y)}{V(x)}$$

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

Propriété : Pour $(a, b, c, d) \in \mathbb{R}^4$ tel que $(a, b) \in \mathbb{R}^*$

On a :

$$|r(ax + b; cy + d)| = |r(x; y)|.$$

En effet on a :

$$\begin{aligned} r(ax + b; cy + d) &= \frac{\text{cov}(ax + b; cy + d)}{\sigma(ax + b) \cdot \sigma(cy + d)} \\ &= \frac{ac \text{cov}(y, x)}{|a| \sigma(x) \cdot |c| \sigma(y)} \\ &= \frac{ac}{|ac|} \cdot r(x; y) = \pm r(x; y) \\ &\quad \text{en fonction des signes de } ac \end{aligned}$$

Exercice 8

Le coefficient de corrélation de X et de Y est :

$$r(x; y) = \frac{\text{cov}(x; y)}{\sqrt{V(x)} \sqrt{V(y)}} = \frac{-0.02}{\sqrt{0.56} \cdot 0.24} = \frac{-1}{4\sqrt{2}} < 0$$

Le rapport de corrélation :

Définition :

Le rapport de corrélation de X en Y est défini par :

$$\frac{\text{Variance expliquée de } x}{\text{Variance total de } x} = \frac{1}{n} \sum_{j=1}^q n_{.j} (x_j - \bar{x})^2$$

Le rapport de corrélation de Y en X est défini par :

$$\frac{\text{Variance expliquée de } y}{\text{Variance total de } y} = \frac{1}{n} \sum_{i=1}^p n_{i.} (y_i - \bar{y})^2}{V(y)}$$

Propriété :

Quand les variables sont indépendantes, le rapport est nul (les variances des moyennes card. est réelle). Quand il existe une liaison fonctionnelle entre X et Y, la variance résiduelle est nulle et le rapport vaut 1.

Rq : Le rapport de corrélation correspond donc à la proportion de variance expliquée

Ex 9 (suite ex2) :

Le rapport de corrélation de X en Y est donné par :

$$\begin{aligned} & \frac{1/n \sum n_{ij} (x_j - \bar{x})^2}{V(x)} \\ &= \frac{1/10 (n_{.1} \bar{x}_1^2 + n_{.2} \bar{x}_2^2) - \bar{x}^2}{V(x)} \\ &= \frac{1/10 (6 (5/6)^2 + 4 (3/4)^2) - (0.8)^2}{0.56} \\ &= \frac{1/10 (25/6 + 9/6) - 0.64}{0.56} \\ &= \frac{\frac{50 + 27}{120} - 0.64}{0.56} \\ &= 0.2/120 \approx 0.00016. \end{aligned}$$

La droite de régression a pour équation :

$$\hat{y} = \bar{a}x + b^{\wedge}$$

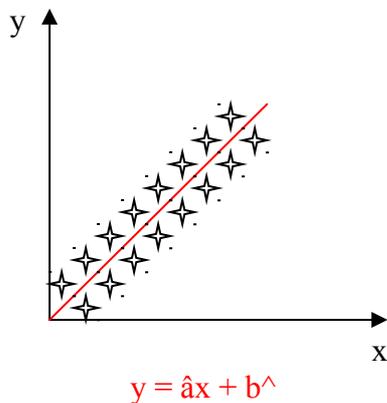
Les valeurs estimées sont pour $i=1..p$

Propriété : \hat{y} est une nouvelle variable et on a :

$$\begin{cases} \hat{y} = y \\ V(y) = 1/n \sum_{i=1}^p n_i (\hat{y}_i - y)^2 \\ = 1/n \sum_{i=1}^p n_i (y_i - y)^2 \end{cases}$$

Définition : on appelle point moyen dans le cadre de la régression de Y en X le point de coordonnées $(\bar{x} ; \bar{y})$.

Propriété : Le point moyen est un point de la droite de régression de Y en X.

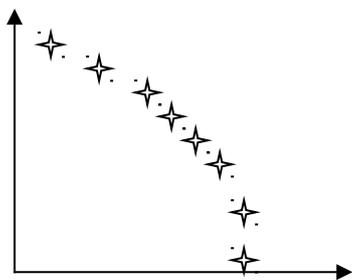


On a en effet $\hat{a}x + b^{\wedge} = \hat{a}x + y - \hat{a}x = y(x ; y)$ est donc un point de la droite de régression de Y en X.

Propriété : Les coefficients de la régression de Y en X et le coefficients de la régression de X en Y sont tel que :

$$\hat{a} \hat{a}' = R^2(x ; y)$$

On a \hat{a} (resp. \hat{a}') est l'estimation du coefficient de l'équation $y = ax + b$ (resp. $x = ay + b'$).



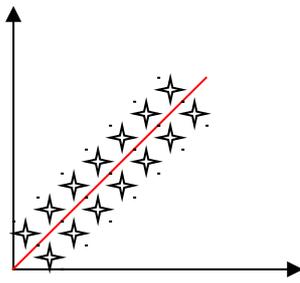
Calcul de l'indice moyen sur 1 an

$$\begin{aligned} \bar{y} &= 1/n \sum_{i=1}^p n_i y_i \\ &= 1/n \sum_{i=1}^p y_i = 2170/10 = 217 \end{aligned}$$

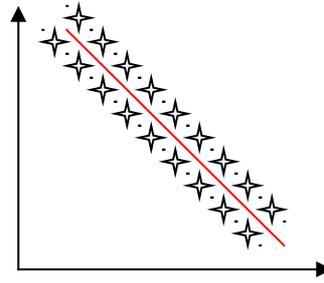
Rq : La partie de la droite de régression est liée aux signes de la covariance :

$$\hat{a} = \frac{\text{cov}(xy)}{\text{var}(x)} \geq 0 \text{ si } \text{cov}(xy) \geq 0$$

$V(x) \leq 0$ si $\text{cov}(xy) \leq 0$.



$\hat{a} > 0$



$\hat{a} < 0$

3) Mesure de la qualité de la régression.

a) Variance expliquée et variance résiduelle dans le cadre de la régression.

Définition :

On appelle variance résiduelle ou variance des écarts de la quantité :

$$V_R(y) = 1/n \sum n_i (y_i - \hat{y}_i)^2$$

On appelle variance expliquée la quantité :

$$V_C(y) = 1/n \sum n_i (\hat{y}_i - \bar{y})^2$$

Propriété :

on a :

$$V_R(y) = \sigma(y) (1 - r^2(x; y))$$

$$= V(x) (1 - r^2(x; y))$$

$$V_E(y) = V(y) - V_R(x) = V(y) r^2(x; y)$$

b) Coefficient de corrélation

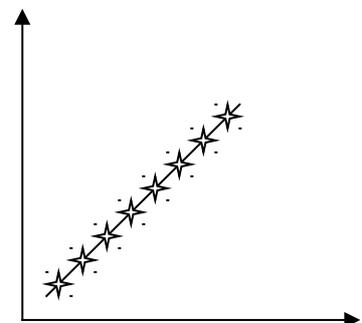
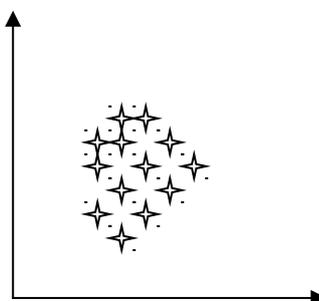
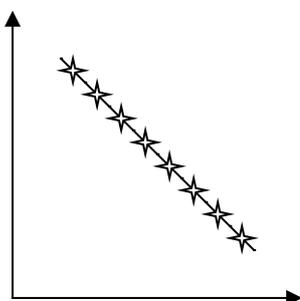
Propriété :

Pour 2 variables X et Y de coefficient de corrélation :

$$r(x; y) = \frac{\text{cov}(xy)}{\sqrt{V(x) V(y)}} \text{ est tel que } r(x; y) \in [-1; 1].$$

La régression est considérée \hat{c} justifié si :

$|r(x; y)| \approx 1$ c'est-à-dire $r(x; y) \approx -1$ ou $r(x; y) \approx 1$



$$r(x; y) \approx -1$$

$$r(x; y) \approx 0$$

$$r(x; y) \approx 1$$

$$\hat{a} = \frac{\text{cov}(x; y)}{V(x)} < 0 \text{ pente négative}$$

$$\hat{a} = \frac{\text{cov}(x; y)}{V(x)} > 0 \text{ pente positive}$$

c) Erreur absolue

Définition : l'erreur absolue est liée à la variance résiduelle soit e tel que :

$$e^2 = 1/n \sum n_i (y_i - \hat{y}_i)^2 \\ = V_R(y)$$

d) Erreur relative

Définition : l'erreur absolu est défini par :

$$\frac{\sigma(\hat{y})}{\sigma(y)}$$

Propriété :
on a :

$$\frac{\sigma(\hat{y})}{\sigma(y)} = |r(x; y)|$$

e) Coefficient de détermination

Définition :

On appelle coefficient de détermination le carré du coefficient de corrélation. on la note en général R^2 .

Ex 12 (suite ex 10)

On a :

$$r(x; y)$$

$$\frac{\sqrt{V(x) V(y)}}{\text{Avec}}$$

$$\text{cov}(x; y) = 1/n \sum^p x_i y_i - \bar{x}\bar{y}$$

$$\bar{y} = \frac{1}{n} \sum_{i=1}^p y_i$$

$$V(x) = \frac{1}{n} \sum_{i=1}^p x_i^2 - \bar{x}^2$$

$$V(y) = \frac{1}{n} \sum_{i=1}^p y_i^2 - \bar{y}^2$$

Avec les données on a

$$\bar{y} = \frac{2170}{10} = 217$$

$$\text{cov}(x; y) = \frac{11275}{10} - 217 \cdot 5.5 = -66$$

$$V(x) = \frac{325}{10} = (5.5)^2 = 8.25$$

$$V(y) = \frac{476532}{10} = (217)^2 = 564.2 \text{ d'ou}$$

$$r(x; y) = \frac{-66}{\sqrt{8.25 \cdot 564.2}} \approx -0.96$$

Ê |r(x; y) ≈ 1 l'argument linéaire est envisageable.

Le coefficient de la régression sont $\hat{a} = \frac{\text{cov}(x; y)}{V(x)}$ et $\hat{b} = \bar{y} - \hat{a}\bar{x}$

$$\text{soit } \hat{a} = \frac{-66}{8.25} = -8 \text{ et } \hat{b} = 217 + 8 \cdot 5.5 \approx 26$$

L'équation de la droite de régression est $\hat{y} = -8x + 26$

Rq : On aurait pu considérer $e^2 = V_R(y) = V(y) - V_E(y)$.

- L'existence d'une corrélation n'implique pas toujours un lien de causalité.

4) Régression non linéaire

1) Ajustement d'une fonction puissance

On a $Y = \beta x^a$ (E_p)

Avec $\beta > 0$ et $x > 0$ or linéaire (E_p) et on a $\ln y = \ln \beta + \alpha \ln x$, on pose $Y' = \ln y$ et $x' = \ln x$.

$$Y' = ax' + b$$

Avec $a = \alpha$
 $b = \ln \beta$

a et b sont estimés par

$$\hat{a} = \frac{\text{cov}(x; y)}{V(x)}$$

$$\hat{b} = y' - \hat{a}x'$$

On déduit de \hat{a} et \hat{b} des estimations de α et β

$$\begin{cases} \alpha = \hat{a} \\ \beta = e^{\hat{b}} \end{cases}$$

Ex 12

$$Y = ax + b$$

On estime a par :

$$\hat{a} = \frac{\text{cov}(x; y)}{V(x)}$$

et b par $\hat{b} = y - \hat{a}x$

On obtient :

$$x = 13.5 \quad y = 180$$

$$\text{cov}(x; y) = 325.375$$

$$V(x) = 17.25$$

$$V(y) = 6928.75$$

$$\text{D'où} \begin{cases} \hat{a} \approx 18.86 \\ \hat{b} \approx 134.64 \end{cases}$$

$$\text{On a } \hat{y} = 18.86x + 134.64$$

On considère le modèle puissance $y = bx^a$

On linéarise et on a $\ln y = \ln b + a \ln x$

On pose :

$$\begin{cases} y' = \ln y \\ b' = \ln b \\ a' = \ln a \\ x' = \ln x \end{cases}$$

$$\text{D'où } y' = a'x' + b'$$

On estime a' et b' par

$$\hat{a}' = \frac{\text{cov}(x'; y')}{V(x')} \quad \text{et } \hat{b}' = y' - \hat{a}'x'$$

On obtient $\bar{x}' = 1/n \sum_{i=1}^p x_i = 2.55$

$$\bar{y}' = 1/n \sum_{i=1}^p y_i = 4.5$$

$$\text{cov}(\bar{x}', \bar{y}') = 1/n \sum_{i=1}^p x_i y_i - \bar{x}' \bar{y}' \approx 0.2231$$

$$V(\bar{x}') = 1/n \sum_{i=1}^p x_i'^2 - \bar{x}'^2 = 0.12$$

$$V(\bar{y}') \approx 0.48$$

On aboutit $\begin{cases} \hat{a} \approx 2.017 \\ \hat{b} \approx -0.59 \end{cases}$

Comme $\begin{cases} a = a' \\ b = b' \end{cases}$

On a $\begin{cases} a = a' \\ b = e^{\hat{b}} \end{cases}$

D'où les estimations :

$$\hat{a} \approx 2.017$$

$$\hat{b} \approx e^{\hat{b}'} \approx e^{-0.59} \approx 0.55$$

On a :

$$\hat{Y} = \hat{b} \cdot \hat{a} = 0.55 \cdot 2.017$$

Pour déterminer le meilleur modèle, on considère l'erreur absolue.

Ces linéaires $e^2 = 1/n \sum_{i=1}^p (y_i - \hat{y}_i)^2$ avec

$$\hat{y}_i = \hat{a}x_i + \hat{b}$$

$$\hat{a} \approx 18.86 \quad \hat{b} \approx -134.44$$

Ces puissances $e^2 = 1/n \sum_{i=1}^p (y_i - \hat{y}_i)^2$

avec $\hat{y}_i = \hat{b} x_i^{\hat{a}}$

$$\hat{a} \approx 2.017$$

$$\hat{b} \approx 0.55$$

On obtient $e^2 \approx \frac{6331.384}{8}$ et $e^2 \approx \frac{4372.59}{8}$

Soit $e^{2'} < e^2$ le meilleur modèle est le modèle puissance.

Utilisons le modèle puissance pour donner une valeur ou $\hat{y}_0 = b^{\wedge} x_0 \hat{a} \approx 0.55 \cdot 26^{2.017}$

≈ 2

2) Ajustement d'une fonction exponentielle.

$$Y = e^{\alpha x + \beta}$$

$$Y' = \ln y = \alpha x + \beta$$

3) Ajustement d'une fonction logarithme

$$Y = \ln(\alpha x + \beta)$$

$$e^y = \alpha x + \beta \text{ avec } \alpha x + \beta > 0$$

$$Y = \alpha x + b \quad Y = \alpha x^{0.5} + b$$

$$Y = a \ln x + b$$

Modèle 1

$$\hat{a} = \frac{\text{cov}(x; y)}{V(x)} \quad b^{\wedge} = \hat{y} = \hat{a}x$$

Modèle 2

$$\hat{a} = \frac{\text{cov}(x; y)}{V(x^{0.5})} \quad \text{avec } X' = x^{0.5} \quad b^{\wedge} = y - \hat{a}x'$$

Modèle 3

$$\hat{a} = \frac{\text{cov}(x''; y)}{V(x'')} \quad \text{avec } x'' = \ln x$$

On obtient :

$$\begin{cases} \hat{a} = 0.31 & b^{\wedge} = 533.5 \\ \hat{a}' \approx 27.68 & b^{\wedge'} = 1208.35 \\ \hat{a}'' \approx 614.88 & b^{\wedge''} = -4644.38 \end{cases}$$

\Rightarrow Recherche du meilleur modèle

$$e^2 = 1/n \sum_{i=1}^p (y_i - \hat{y}_i)^2 \text{ avec } \hat{y}_i = \hat{a}x_i + b^{\wedge}$$

$$e^{2'} = 1/n \sum_{i=1}^p (y_i - \hat{y}_i')^2 \text{ avec } \hat{y}_i' = \hat{a}x_i^{0.5} + b^{\wedge'}$$

$$e^{2''} = 1/n \sum_{i=1}^p (y_i - \hat{y}_i'')^2 \text{ avec } \hat{y}_i'' = \hat{a}x_i + b^{\wedge}$$

2.18

2.18

2.07

On obtient $e^2 \approx \frac{\quad}{6}$ $e^{2'} \approx \frac{\quad}{6}$ $e^{2''} \approx \frac{\quad}{6}$

Le meilleur modèle est $n_0 Y = a \ln x + b$

\Rightarrow Prévision pour $x_0 = 2020$
 $\hat{y}_0'' = \hat{a}'' \ln(x_0) + \hat{b}'' \approx 35.39$