

STATISTIQUE DESCRIPTIVE

I Historique

- Questions de dénombrement (problèmes d'inventaire, de recensement) remontant à la préhistoire.
- Plus récemment : * Probabilités : 17^e siècle, Pascal et Fermat puis 19^e siècle, famille Bernoulli, Gauss, Laplace . début 20^e siècle : axiomatisation; Kolmogorov ...
- * Statistiques : 19^e siècle, Quételat (recensement de Bruxelles qui fut un exemple à suivre) (Adolphe Quételat 1796-1874) puis 20^e siècle, grand essor avec Pearson, Gosset (Student), Neyman, Fisher (de 1890 à 1965).

II Traitement des données

Présentation : tableau IC (individus caractères)

i : individus n individus
 j : variables p variables

$i \backslash j$	1	... i	... j	... p
1	x_{11}	...	x_{ij}	x_{1p}
...				
i	x_{i1}	...	x_{ij}	x_{ip}
...				
n	x_{n1}	...	x_{nj}	x_{np}

x_{ij} : caractères

m : effectif total

cas univarié : $\begin{array}{|c|c|c|c|} \hline & i & 1 & \dots & i & \dots & n \\ \hline x_i & x_1 & x_2 & \dots & x_i & \dots & x_n \\ \hline \end{array}$, cas bivarié : $\begin{array}{|c|c|c|c|} \hline i & 1 & \dots & i & \dots & n \\ \hline x_i & x_1 & x_2 & \dots & x_i & \dots & x_n \\ \hline y_i & y_1 & y_2 & \dots & y_i & \dots & y_n \\ \hline \end{array}$, etc...

Organisation : série observée - série ordonnée

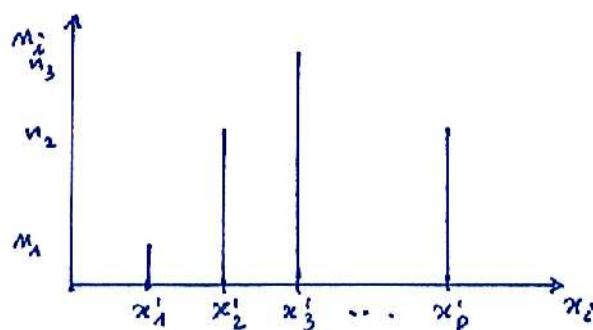
observations : $\{x_1, \dots, x_n\}$

on ordonne : $\{x_{(1)}, \dots, x_{(n)}\}$ avec $i \leq j \Rightarrow x_{(i)} \leq x_{(j)}$.

ordre strict : $\{x'_1, \dots, x'_p\}$ avec $i < j \Rightarrow x'_i < x'_j$
et nombre d'observations identiques x'_i : m_i (effectif de x'_i)

$\{(x'_i, m_i), 1 \leq i \leq p\}$ est appelé série statistique . $\sum_{i=1}^p m_i = m$.

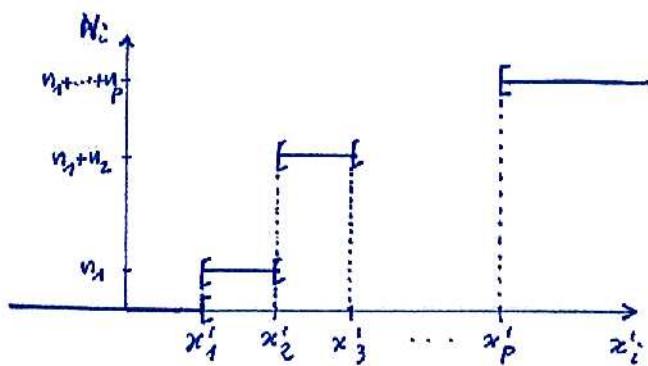
diagramme en batons :



fréquences, effectifs cumulés, fréquences cumulées

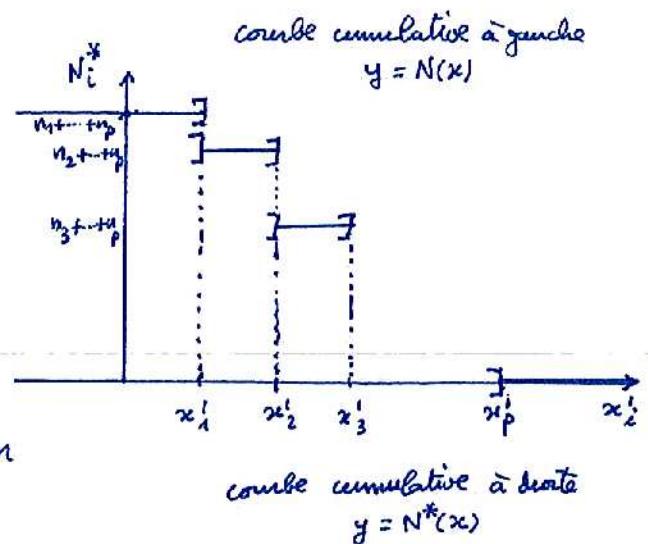
$$f_i = \frac{n_i}{n}, \quad \sum_{i=1}^P f_i = 1$$

$\left\{ \begin{array}{l} \text{effectifs cumulés à gauche } N_i = \sum_{k=1}^i n_k \\ \text{fréquences cumulées à gauche } F_i = \frac{N_i}{n} \end{array} \right.$



$$\left\{ \begin{array}{l} \text{effectifs cumulés à droite } N_i^* = \sum_{k=i}^P n_k \\ \text{fréquences cumulées à droite } F_i^* = \frac{N_i^*}{n} \end{array} \right.$$

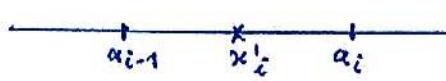
$$\text{On a } N(x) + N^*(x) = \begin{cases} n & \text{si } x \notin \{x'_1, \dots, x'_P\} \\ n + n_i & \text{si } x = x'_i \end{cases} \geq n$$



regroupement des données en classes

Si on dispose trop de données, le diagramme en bâtons est surchargeé.

On regroupe alors les données en classes $[a_0, a_1], [a_1, a_2], \dots, [a_{p-1}, a_p]$.



centre de la classe : x'_i
longueur de la classe : $l_i = a_i - a_{i-1}$
effectif de la classe : n_i

histogramme - polygone des effectifs (ou fréquences)

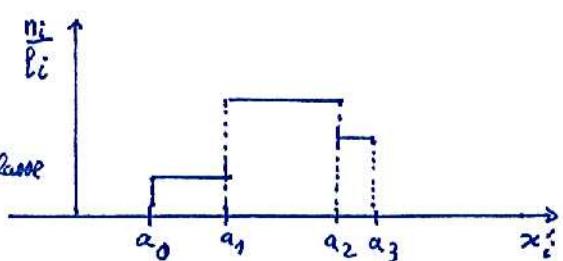
• histogramme des effectifs (ou fréquences)

$\frac{n_i}{l_i}$ = densité d'effectif = effectif par unité de longueur de classe

(idem avec les fréquences, $\frac{f_i}{l_i}$)

aire de chaque rectangle : $\frac{n_i}{l_i} \times l_i = n_i = \text{effectif de la classe } [a_{i-1}, a_i]$.

aire sous l'histogramme : $n = \text{effectif total}$.



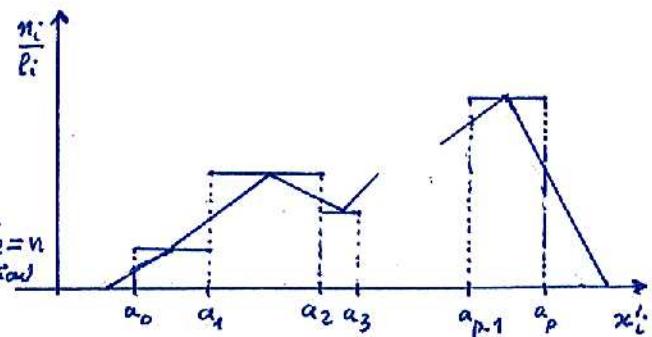
- "image plus continue" de l'histogramme

polygone des effectifs = interpolation linéaire entre les centres des classes.

On suppose l'uniformité des répartitions dans chaque classe.

L'aire sous la courbe polygonale est inchangée = n (les 2 bouts extrêmes sont placés pour vérifier cette condition)

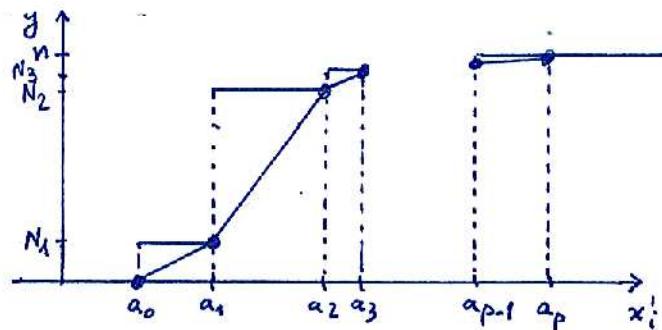
Lorsque les l_i deviennent petits, on obtient un "graphe de densité locale".



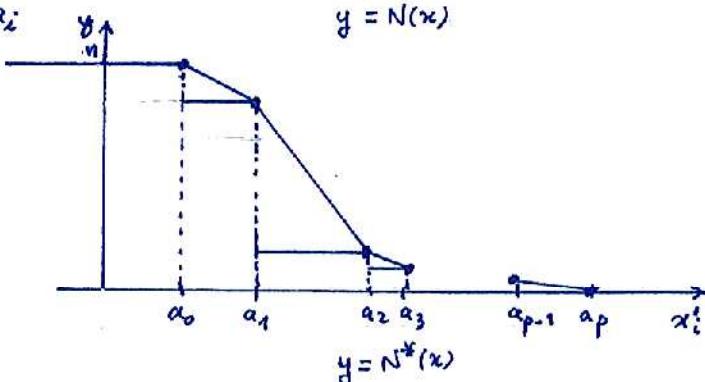
- courbes cumulées

courbe cumulée à gauche = ligne brisée joignant les points (a_i, N_i)

$$N(x) = \begin{cases} 0 & \text{si } x < a_0 \\ \frac{n_1}{l_1}(x - a_0) & \text{si } a_0 \leq x < a_1 \\ \vdots \\ N_{i-1} + \frac{n_i}{l_i}(x - a_{i-1}) & \text{si } a_{i-1} \leq x < a_i \\ \vdots \\ m & \text{si } x \geq a_p \end{cases}$$



On a $\forall x, N(x) + N^*(x) = m$.



III Paramètres de position

moyenne (pour les effectifs quantitatifs): $\bar{x} = \frac{1}{m} \sum_{i=1}^m x_i = \frac{1}{m} \sum_{i=1}^m m_i x'_i = \sum_{i=1}^p f_i x'_i$

Pour les observations groupées : $\bar{x} = \frac{1}{m} \sum_{i=1}^p m_i x'_i$, x'_i : centre de la classe $[a_i, a_{i+1}]$.

C'est le paramètre le plus répandu, mais pas nécessairement le plus adéquate.
Un inconvénient: e.g. s'il y a une donnée aberrante, elle affecte sensiblement la moyenne. On peut donc être amené à tronquer la moyenne, ou à la pondérer.

$$\frac{1}{p-2} \sum_{i=2}^{p-1} m_i x'_i, \quad \frac{\sum_{i=1}^p w_i x'_i}{\sum_{i=1}^p w_i} \quad \text{etc...}$$

Si on a deux séries statistiques $\{x_i, 1 \leq i \leq n_x\}$ et $\{y_j, 1 \leq j \leq n_y\}$, la série complète $\{z_k, 1 \leq k \leq n_x + n_y\} = \{x_i, 1 \leq i \leq n_x\} \cup \{y_j, 1 \leq j \leq n_y\}$ a pour moyenne

$$\bar{z} = \frac{m_x \bar{x} + m_y \bar{y}}{m_x + m_y}.$$

médiane: m_e est la valeur "centrale" de la série ordonnée $x_{(1)}, x_{(2)}, \dots, x_{(n)}$ (avec répétition)

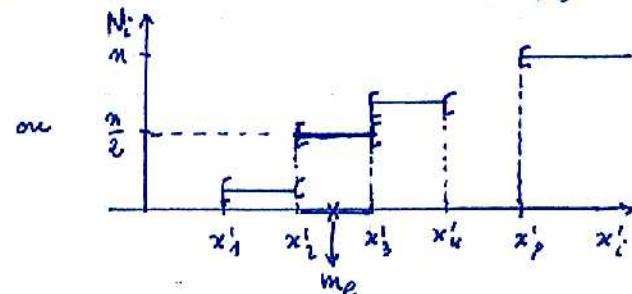
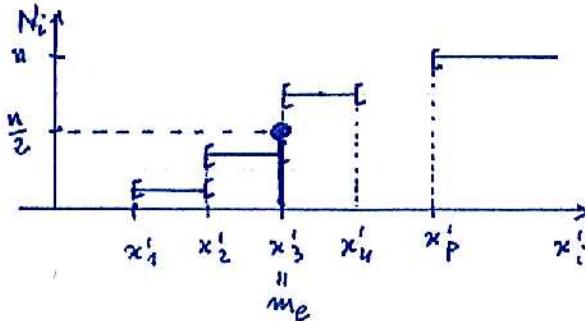
- si n est impair $m_e = x_{\left(\frac{n+1}{2}\right)}$

- si n est pair, il y a un intervalle médian $[x_{\left(\frac{n}{2}\right)}, x_{\left(\frac{n}{2}+1\right)}]$. On pose $m_e = \frac{x_{\left(\frac{n}{2}\right)} + x_{\left(\frac{n}{2}+1\right)}}{2}$.

ex: série ordonnée $1^1 2^2 3^1 4^4 4^4 5^1 6^1 \rightarrow n=9 \quad m_e = x_{(5)} = 4$

$$1^1 2^2 3^1 4^4 4^4 5^1 \rightarrow n=8 \quad m_e = \frac{x_{(4)} + x_{(5)}}{2} = 3,5$$

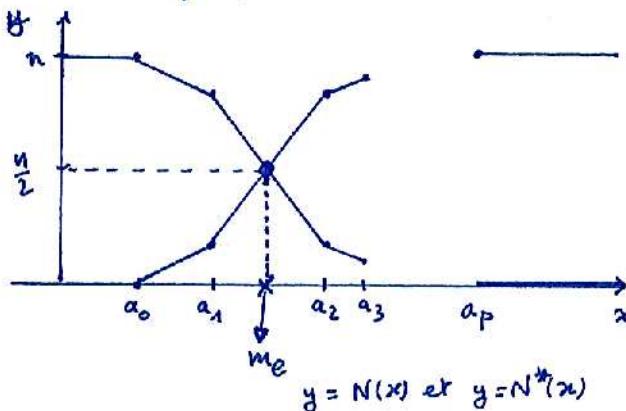
Détermination de m_e à l'aide des courbes cumulatives: on a $N(m_e) \geq \frac{n}{2}$ et $N^*(m_e) \geq \frac{n}{2}$ (i.e. le nombre de valeurs de la série $\leq m_e$ est égal au nombre de valeurs $> m_e$: $\left[\frac{n}{2}\right]$)



S'il existe un i tel que $N_{i-1} < \frac{n}{2} < N_i$ alors $m_e = x_i^1$

s'il existe un i tel que $N_i = \frac{n}{2}$ alors $[x_i^1, x_{i+1}^1]$ est l'intervalle médian et $m_e = \frac{x_i^1 + x_{i+1}^1}{2}$.

Cas des observations groupées: on utilise les courbes cumulatives continues:



$$N + N^* = n$$

$$N(m_e) = N^*(m_e) = \frac{n}{2}.$$

$$m_e = a_{i-1} + \frac{p_i}{M_i} (m - N_{i-1})$$

i étant l'indice de la classe contenant m_e .

quantiles (ou fractiles): Soit $p \in]0, 1[$. Q_p : p -quantile (ou quantile d'ordre p)

Q_p est la valeur du caractère telle que $N(Q_p) \geq np$ et $N^*(Q_p) \geq n(1-p)$. (i.e. le nombre de valeurs de la série $\leq Q_p$ est égal à $[np]$, et $> Q_p$: $[n(1-p)]$)

si $np \notin \mathbb{N}$ $Q_p = x_{\lfloor np \rfloor + 1}$; si $np \in \mathbb{N}$ alors $Q_p \in [x_{np}, x_{np+1}]$

ex: médiane: $p = \frac{1}{2}$, $m_e = Q_{1/2}$

cas d'observations groupées:

quantiles: $p = \frac{1}{4}, \frac{3}{4}, \frac{2}{4}, \frac{3}{4}$ $Q_{1/4}, Q_{2/4} = m_e, Q_{3/4}$

$$Q_p = a_{i-1} + \frac{p_i}{M_i} (np - N_{i-1})$$

déciles: $p = \frac{1}{10}, \frac{2}{10}, \dots, \frac{9}{10}$

percentiles: $p = \frac{1}{100}, \frac{2}{100}, \dots, \frac{99}{100}$

mode : valeur observée qui a le plus grand effectif
distribution unimodale (plurimodale) : qui contient un seul (plusieurs) mode(s).

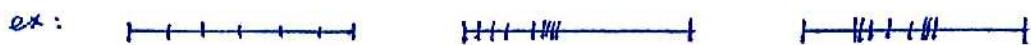
cas des observations groupées : si les classes ont même longueur, la classe modale est celle d'effectif maximal. Sinon, considérer l'histogramme des densités $\frac{m_i}{l_i}$.

autres paramètres de position : $c_1 = \frac{x_{(1)} + x_{(n)}}{2}$, $c_2 = \frac{Q_{1/4} + Q_{3/4}}{2}$, $c_3 = \frac{Q_{1/4} + 2Q_{2/4} + Q_{3/4}}{4}$ etc...

remarque : tous les paramètres considérés ici ont même dimension que les caractères.

IV Paramètres de dispersion

étendue (empan) : $x_{(n)} - x_{(1)}$. Inconvénient : l'étendue ne tient pas compte de toutes les observations.

ex : 

Ces trois séries ont même étendue.

écart interquartile : $[Q_p, Q_{1-p}]$ pour $0 < p < \frac{1}{2}$. Cet intervalle contient un effectif égal ou juste supérieur à $n(1-2p)$: $\begin{cases} n(1-2p) & \text{si } np \in \mathbb{N} \\ [n(1-2p)]+1 & \text{si } np \notin \mathbb{N} \end{cases}$

ex : intervalle interquartile $[Q_{1/4}, Q_{3/4}]$: contient $\approx 50\%$ d'observations
 intervalle interdeutile $[Q_{1/10}, Q_{9/10}]$: contient $\approx 80\%$ d'observations.

Ces intervalles sont utilisés pour éliminer les valeurs extrêmes (éventuellement) aberrantes.

écart moyen absolu : $e_m = \frac{1}{n} \sum_{i=1}^n |x_i - \bar{x}| = \frac{1}{n} \sum_{i=1}^n m_i |x'_i - \bar{x}| = \sum_{i=1}^P f_i |x'_i - \bar{x}|$

Pour les observations groupées : $e_m = \frac{1}{n} \sum_{i=1}^P m_i |x'_i - \bar{x}|$, x'_i centre de classe

écart médian absolu : $e_m^* = \frac{1}{n} \sum_{i=1}^n |x_i - m_e|$. m_e minimise $m \mapsto \sum_{i=1}^n |x_i - m|$.

Inconvénient : le calcul de e_m et e_m^* est peu maniable à cause de la valeur absolue, et ils ont peu de propriétés mathématiques.

écart-type et variance : $\sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n} \sum_{i=1}^P M_i (x'_i - \bar{x})^2 = \sum_{i=1}^P f_i (x'_i - \bar{x})^2$

Théorème de Körnig-Huygens : $\frac{1}{n} \sum_{i=1}^n (x_i - m)^2 = \sigma^2 + (\bar{x} - m)^2$

Donc σ^2 minimise $m \mapsto \sum_{i=1}^n (x_i - m)^2$ et $\sigma^2 = \bar{x}^2 - \bar{\bar{x}}^2$.
 (→ a été de calculer tous les écarts $x_i - \bar{x}$)

autre écriture : $\sigma^2 = \frac{1}{2n^2} \sum_{1 \leq i, j \leq n} (x_i - x_j)^2$

Valence centrée réduite : $y_i = \frac{x_i - \bar{x}}{\sigma}$, $\bar{y} = 0$, $\bar{y}^2 = 1$ (y est sans dimension)

Si on réunit deux séries statistiques $\{x_i, 1 \leq i \leq n_x\}$ et $\{y_j, 1 \leq j \leq n_y\}$ en une seule $\{z_k, 1 \leq k \leq n_x+n_y\}$, les écarts-type sont reliés par

$$\sigma_z^2 = \frac{n_x \sigma_x^2 + n_y \sigma_y^2}{n_x + n_y} + \frac{n_x (\bar{x} - \bar{z})^2 + n_y (\bar{y} - \bar{z})^2}{n_x + n_y}$$

variance DANS les groupes

= $\frac{n_x n_y}{(n_x + n_y)^2} (\bar{x} - \bar{y})^2$, variance ENTRE les groupes

démonstration : utiliser König : $\sigma_z^2 = \frac{1}{n_x + n_y} \left[\sum_{i=1}^{n_x} (x_i - \bar{z})^2 + \sum_{j=1}^{n_y} (y_j - \bar{z})^2 \right] = \frac{n_x}{n_x + n_y} [\sigma_x^2 + (\bar{x} - \bar{z})^2] + \frac{n_y}{n_x + n_y} [\sigma_y^2 + (\bar{y} - \bar{z})^2]$

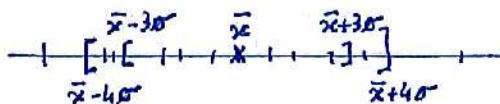
Inégalité de Bienaymé-Tchebycheff : $\begin{cases} \text{la fréquence des } x_i \text{ tels que } |x_i - \bar{x}| \geq k \text{ est } \leq \frac{\sigma^2}{k^2}, \\ \text{la fréquence des } x_i \text{ tels que } |x_i - \bar{x}| < k \text{ est } \geq 1 - \frac{\sigma^2}{k^2}. \end{cases}$

Démonstration : $\sigma^2 = \frac{1}{n} \sum_{i=1}^n |x_i - \bar{x}|^2 = \frac{1}{n} \sum_{i: |x_i - \bar{x}| \geq k} |x_i - \bar{x}|^2 + \frac{1}{n} \sum_{i: |x_i - \bar{x}| < k} |x_i - \bar{x}|^2 \geq \frac{k^2}{n} \text{ card}\{i : |x_i - \bar{x}| \geq k\}$.

Puis $\frac{1}{n} \text{ card}\{i : |x_i - \bar{x}| < k\} = 1 - \frac{1}{n} \text{ card}\{i : |x_i - \bar{x}| \geq k\} \geq 1 - \frac{\sigma^2}{k^2} \square$

application : $k = 3\sigma$: la fréquence des x_i tels que $|x_i - \bar{x}| \geq 3\sigma$ est $\leq \frac{1}{9} \approx 11,2\%$

$k = 4\sigma$: la fréquence des x_i tels que $|x_i - \bar{x}| \geq 4\sigma$ est $\leq \frac{1}{16} \approx 6,25\%$.



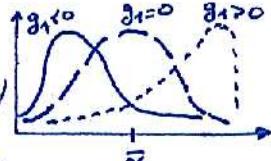
Autres paramètres de dispersion :

• coefficient de variation : $CV = \frac{\sigma}{\bar{x}}$: nombre sans dimension, se mesure en %

(mesure relative de dispersion)

• paramètres de forme : $m_3 = \overline{(x - \bar{x})^3} = \frac{1}{n} \sum_{i=1}^n M_i (x_i - \bar{x})^3$ moment centré d'ordre 3
c'est un coefficient de dissymétrie.

coefficient de Fisher $g_1 = \frac{m_3}{\sigma^3}$ (sans dimension)



coefficient empirique de Pearson : $S_{fe} = \frac{\bar{x} - m_p}{\sigma}$

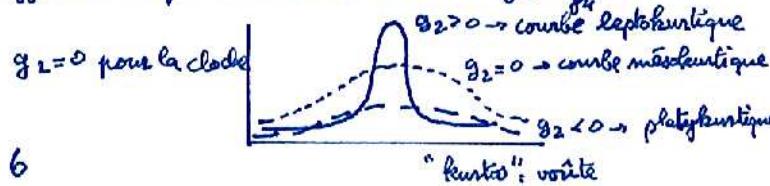
coefficient empirique de Yule-Kendall : $Y_{fe} = \frac{\alpha_{14} + \alpha_{34} - 2\alpha_{12}}{\alpha_{34} - \alpha_{14}}$

Attention : l'étude des signes de S_{fe} et Y_{fe} peut donner des contradictions.

* $m_4 = \overline{(x - \bar{x})^4} = \frac{1}{n} \sum_{i=1}^n M_i (x_i - \bar{x})^4$

coefficient d'aplatissement de Pearson : $b_2 = \frac{m_4}{\sigma^4}$

coefficient d'aplatissement de Fisher : $g_2 = \frac{m_4}{\sigma^4} - 3$



II Analyse bivariée

On part de deux caractères $x_i, y_i, 1 \leq i \leq n$. On ordonne strictement $x'_1 < \dots < x'_p$ et $y'_1 < \dots < y'_q$:
Série statistique double $\{(x'_i, y'_j), 1 \leq i \leq p, 1 \leq j \leq q\}$

Tableau de contingence

$$M_{i \cdot} = \sum_{j=1}^q M_{ij}$$

$$M_{\cdot j} = \sum_{i=1}^p M_{ij}$$

$$M = \sum_{i=1}^p M_{i \cdot} = \sum_{j=1}^q M_{\cdot j}$$

$i \setminus j$	y'_1	\dots	y'_j	\dots	y'_q	effectifs marginaux
$x'_{\cdot 1}$	n_{11}	\dots	n_{1j}	\dots	n_{1q}	$n_{1 \cdot}$
\vdots	\vdots	\dots	\vdots	\dots	\vdots	\vdots
x'_i	n_{i1}	\dots	n_{ij}	\dots	n_{iq}	$n_{i \cdot}$
\vdots	\vdots	\dots	\vdots	\dots	\vdots	\vdots
$x'_{\cdot p}$	n_{p1}	\dots	n_{pj}	\dots	n_{pq}	$n_{\cdot p}$
effectifs marginaux	$n_{\cdot 1}$	\dots	$n_{\cdot j}$	\dots	$n_{\cdot q}$	n

covariance : $\sigma_{xy} = \overline{(x - \bar{x})(y - \bar{y})} = \frac{1}{n} \sum_{1 \leq i, j \leq n} m_{ij} (x'_i - \bar{x})(y'_j - \bar{y}) = \bar{xy} - \bar{x}\bar{y}$

coefficient de corrélation de Bravais-Pearson : $r_{xy} = \frac{\sigma_{xy}}{\sigma_x \sigma_y} \in [-1, 1]$

matrice de covariance $\begin{pmatrix} \sigma_x^2 & \sigma_{xy} \\ \sigma_{xy} & \sigma_y^2 \end{pmatrix}$

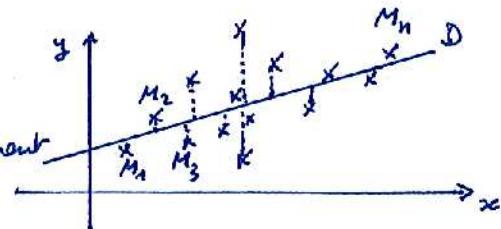
Régression linéaire

nuage de points $\{(x_i, y_i), 1 \leq i \leq n\}$

méthode des moindres carrés : droite d'ajustement

$$y = ax + b \text{ minimisant } \sum_{i=1}^n d(M_i, D)^2$$

régression de y par rapport à x : $d_V(M_i, D)$: distance "verticale" de M_i à D .



$$\begin{cases} a = \frac{\sigma_{xy}}{\sigma_x^2} : \text{coefficients de régression (pente a)} \\ b = \bar{y} - a\bar{x} \end{cases}$$

$$y = \bar{y} + \frac{\sigma_{xy}}{\sigma_x^2} (x - \bar{x})$$

variance résiduelle : $\sigma_{y|x}^2 = \frac{1}{n} \sum (y_i - ax_i - b)^2 = \sigma_y^2(1 - r^2)$

régression de x par rapport à y : $x = a'y + b'$ minimisant $\sum_{i=1}^n d_H(M_i, D)^2$, d_H distance "horizontale".

$$\begin{cases} a' = \frac{\sigma_{xy}}{\sigma_y^2} \quad (\text{pente } \frac{1}{a'}) \\ b' = \bar{x} - a'\bar{y} \end{cases}$$

$$x = \bar{x} + \frac{\sigma_{xy}}{\sigma_y^2} (y - \bar{y})$$

En général ces deux droites sont distinctes. $a a' = \frac{\sigma_{xy}^2}{\sigma_x^2 \sigma_y^2} = r^2$.

Les pentes se rapprochent de plus en plus lorsque $|r|$ est proche de 1.

On considère l'ajustement valable pour $0,7 \leq |r| \leq 1$, excellent si $|r| \geq 0,95$.

autres ajustements : $y = a x^\alpha \rightarrow$ régression linéaire en $(\ln x, \ln y)$: $\ln y = \alpha \ln x + \ln a$

$y = a e^{bx} \rightarrow$ régression linéaire en $(x, \ln y)$: $\ln y = b x + \ln a$.

Bibliographie : J.-J. Driebeke : éléments de statistiques 1988, chapitres 2, 3, 10

H. Egon : Statistique et probabilités 1992, chapitre A

G. Demongeot : probabilités, statistique inférentielle, fiabilité, 1997, chapitres 1, 2

M. Gaultier : statistique 1997, chapitre 2. - 7 -