

## Suite des indicateurs statistiques dans le cadre d'une variable quantitative

- Mode :

Il existe une différence dans le calcul suivant que la variable est discrète ou continue :

- a. Discret : valeur prise par la variable qui est la plus observée (associée à l'effectif le plus grand)
- b. Continue : le mode est une classe -> classe modale  
La classe associée à la hauteur la plus grande dans l'histogramme (hauteur =  $\frac{\text{fréquence}}{\text{amplitude de la classe}}$ )

Remarque : Le mode n'est pas forcément unique

- Variance : il existe 2 variances

- Brutes :  $S_1^2 (= S_n^2) = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$
- Individuelles :  $S_1^2 = \frac{1}{n} \sum_{i=1}^p n_i (x_i - \bar{x})^2$
- Regroupées :  $S_1^2 = \frac{1}{n} \sum_{i=1}^k n_i (x_i - \bar{x})^2$

- Seconde variance (la plus utilisée) :

- Brutes :  $S^2 (= S_{n-1}^2) = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$
- Individuelles :  $S^2 = \frac{1}{n-1} \sum_{i=1}^p n_i (x_i - \bar{x})^2$
- Regroupées :  $S^2 = \frac{1}{n-1} \sum_{i=1}^k n_i (x_i - \bar{x})^2$

Remarque :  $S^2 = \frac{n}{n-1} S_1^2$

- La variance quantifie la dispersion des données autour de  $\bar{x}$
- Problème : une grandeur avec unité : son unité est (unité des données)<sup>2</sup>

- L'écart-type : racine carrée de la variance :

- $S_1 = \sqrt{S_1^2}$
- $S = \sqrt{S^2}$  <- la préférée
- L'unité de l'écart-type = unité des données

- Coefficient de la variation : CV

$CV = \frac{S}{\bar{x}} * 100$  : coefficient absolu (sans unité)

Interprétation :

- Si CV < 16% -> homogénéité des données  
→ La moyenne est représentative des données
- Si CV > 33% -> non homogénéité  
→ La moyenne n'est pas à elle seule représentative des données
- Si 16% < CV < 33% -> zone flou  
→ Cas par cas

- Etendue :

- Discret : (la plus grande valeur observée) – (la plus petite valeur observée)
- Continue : (la limite supérieure de la dernière classe) – (la limite inférieure de la première classe)

C'est-à-dire :  $[a_1, a_2[$ ,  $[a_2, a_3[$  ...  $[a_k, a_{k+1}[$

$$E = a_{k+1} - a_1$$

Il existe 2 paramètres de forme :

- Paramètre de symétrie (skewness)
- Paramètre d'aplatissement (kurtosis)


Objectif : comparaison à une loi normale

On calcule le coefficient de symétrie CB


$$CB = \begin{cases} \frac{n}{(n-1)(n-2)} \sum_{i=1}^n \left(\frac{x_i - \bar{x}}{5}\right)^3 & \text{si brute} \\ \frac{n}{(n-1)(n-2)} \sum_{i=1}^p n_i \left(\frac{x_i - \bar{x}}{5}\right)^3 & \text{si individuelle} \\ \frac{n}{(n-1)(n-2)} \sum_{i=1}^{\mathbb{R}} n_i \left(\frac{x_i - \bar{x}}{5}\right)^3 & \text{si regroupée} \end{cases}$$

Interprétation :


- Si « CB = 0 » -> la distribution des données est symétrique par rapport à  $\bar{x}$



- Si «  $CB < 0$  » -> distribution des données asymétrique à gauche



- Si «  $CB > 0$  » -> asymétrie à droite




On calcule kurtosis : CA


$$CA = \frac{n(n+1)}{(n-1)(n-2)(n-3)} \sum_{i=1}^n \frac{x_i - \bar{x}}{5} - \frac{3(n-1)^2}{(n-2)(n-3)} \text{ si brutes}$$

Interprétation :


Si «  $CA = 0$  » -> la distribution est normalement étalée



Si « CA < 0 » -> distribution plus aplatie que la gaussienne



Si « CA > 0 » -> distribution plus pointue que la gaussienne



Remarque :  $f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x_i - E[x])^2}{2\sigma^2}}$  -> la hauteur de la base  $\frac{1}{\sqrt{2\pi}\sigma}$

Tout ce qui a été fait était pour une variable


Que se passe-t-il si 2 variables ensemble ?


X	Y
$x_1$	$y_1$
...	...
$x_n$	$y_n$

1° étape : on étudie X et Y séparément

2° étape : recherche d'un éventuel lien entre X et Y


- Nuage de points






le nuage de point semble dirigé par une droite


Relation linéaire :  $\tilde{Y} = a + bX$  ( $Y = a + bX + \varepsilon$ )



lien quadratique :  $Y \sim P(X)$  avec  $P$  un polynôme



lien exponentiel :  $Y \sim c * e^{ax}$



pas de lien


Question : existe-t-il une fonction  $f$  telle que  $Y \sim f(X)$

Comment trouver  $f$  ?

On va mettre un postulat sur la forme de  $f$

- ➔ Linéaire  $f(x) = a + bx$
- ➔ Exponentielle :  $f(x) = ce^{ax}$
- ➔ Quadratique :  $f(x) = a_0 + a_1x + a_2x^2 + \dots + a_nx^n$

Problème : trouver les différentes constantes



principe : numériser la somme des distances élevées au carré

$$\text{Min} : \sum_{i=1}^n (y_i - f(x_i))^2$$

Dans le cadre linéaire :

On cherche  $a$  et  $b$  réel tq  $\sum_{i=1}^n (y_i - (a + bx_i))^2$  soit minimale

Dans le cas quadratique

On cherche  $a_0, a_1, \dots, a_n$  tel que  $\sum_{i=1}^n (y_i - (a_0 + a_1 x_i + \dots + a_n x_i^n))^2$  minimale

→ Méthode des moindres carrées

Principe de l'optimisation

On calcule les différentes dérivées partielles

On résout le système annulant simultanément toutes les dérivées partielles -> obtention de point critique

On cherche le minimum parmi ces points critique

Proposition


Si on suppose que  $f(x) = a + bx$

La solution de la minimisation est donnée par

$$\left| \begin{array}{l} a = \bar{y} - b\bar{x} \\ b = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sum (x_i - \bar{x})^2} = \frac{\sum x_i y_i - n \bar{x} \bar{y}}{\sum x_i^2 - n (\bar{x})^2} \end{array} \right.$$

*notation*

On note  $\hat{y} = f(x)$  : prédiction



Quantification du lien

Cadre général : coefficient de détermination :  $r^2$

$$r^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \text{ avec } \hat{y}_i = f(x_i)$$

Propriétés

- $0 \leq r^2 \leq 1$  car on peut montrer que  $\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 + \frac{1}{n-1} \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$

Interprétation :

Plus  $r^2$  est proche de 1 meilleur est le modèle  $f$

Inconvénient : Pour calculer  $r^2$  il faut avoir entièrement déterminé  $f$

Cas particulier des cadres linéaires

On peut montrer que

Coefficient de détermination = (coefficient de corrélation)

Coefficient de corrélation =  $r$

$$r = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{(n-1)S_x S_y} = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x}) \sum (y_i - \bar{y})}} \text{ avec } S_x^2 = \frac{1}{(n-1)} \sum_{i=1}^n (x_i - \bar{x})^2$$