

I / Statistiques descriptives: Généralités

I) Def et Objet

La statistique est la science qui a pour objet de recueillir un ensemble de données relatives à un certain phénomène et d'expliquer cette information par l'analyse et expliquer le phénomène étudié.

II) Notions de population, caractère.

Def 1: Une population est un ensemble fini, noté I ($\text{card}(I) < \infty$)
un élément de la population est dit unité ou individu.
Le cardinal de I noté $n < \infty$ est dit taille de la population.

Def 2

Un caractère (ou variable) est une application définie de I dans un ensemble E .

On note : $X: I \longrightarrow E$
 $w_i \longmapsto X(w_i) = x_i$

$I = \{w_1, \dots, w_n\}$

x_1, \dots, x_n est dit échantillon ou suite d'observations.
les différentes observations de la suite x_1, \dots, x_n sont dites modalités

Rq: selon la nature de E , une variable peut être quantitative ($E \subset \mathbb{R}$ mesurable) ou qualitative (non mesurable)

si $E \subset \mathbb{Z}$, X est dite variable quantitative discrète (dénombrable)

si $E = [a, b]$ X est dite " " continue (non dénombrable)

la variable qualitative peut être ordinal (on peut ordonner les modalités) ou nominal (cas contraire)

Exp

soit une population I formée de 10 étudiants de 1^{ère} année MI

on considère les 4 variables suivantes:

$I = \{w_1, \dots, w_{10}\}$ taille de la population est $n = 10$

a) $X_1: I \longrightarrow E_1 = \{F, M\}$ sexe de l'étudiant

X_1 qualitative nominale, les modalités F et M

b) $X_2: I \longrightarrow E_2 = \{TB, B, AB, S.M\}$ mention obtenue au bac

X_2 qualitative ordinale, les modalités TB, B, AB et S.M.

c) $X_3: I \longrightarrow E_3 = \{0, 1, 2, 3\}$ nombre de frères et sœurs.

X_3 : quantitative discrète

d) $X_4: I \longrightarrow E_4 = [155, 175]$ taille en cm.

X_4 : quantitative continue.

Def 3: Effectif et Fréquence.

Soit l'échantillon de taille n , x'_1, \dots, x'_n

on note par x_1, \dots, x_p les modalités

• l'effectif d'une modalité x_i est le nombre d'observations de la suite x'_1, \dots, x'_n égales à x_i . On note n_i

• la fréquence de x_i est le rapport noté $f_i = \frac{n_i}{n}$

Rqs

• $1 \leq n_i \leq n$

$$\sum_{i=1}^p n_i = n$$

• $0 \leq f_i \leq 1$

$$\sum_{i=1}^p f_i = 1$$

Def 4: Tableau statistique ou distribution statistique.

$X: I = \{w_1, \dots, w_n\} \longrightarrow E = \{x_1, \dots, x_p\}$

La distribution statistique de X est donnée par le tableau suivant.

Modalités	x_1	x_2	...	x_p
Effectif n_i	n_1	n_2	...	n_p
Freq f_i	f_1	f_2	...	f_p

Def 5: Mode

Le mode d'une distribution est la modalité x_i ayant la plus grande effectif n_i (ou fréquence f_i)

II / Variable qualitative

I / Introduction

Soit une population I de taille n .

X une variable qualitative.

x_1, \dots, x_p les modalités de X .

On note par n_i l'effectif de x_i pour $i = 1, \dots, p$
 et par f_i la fréquence ($f_i = \frac{n_i}{n}$)


La distribution statistique

θ_i	x_1	x_2	---	x_p
n_i	n_1	n_2		n_p
f_i	f_1	f_2		f_p


II / Représentation graphique

La variable qualitative peut être représentée graphiquement par deux graphes.

1) Batons - Tuteur d'orgue.



2) Le cercle



θ_i est proportionnelle à f_i

$$\sum_{i=1}^p \theta_i = 360^\circ \longrightarrow \sum_{i=1}^p f_i = 1$$

$$\theta_i \longrightarrow f_i$$

$$\theta_i = 360^\circ \times f_i$$

Rqs d'orgue
 le diagramme en batons
 est souvent utilisé dans
 le cas de variable qualitative
 ordinaire.
 le mode correspond à
 x_i qui a le plus long
baton tuteur

II / Variable qualitative quantitative discrète

I / Introduction

Soit une population de taille n .


X une variable quantitative discrète: x_1, \dots, x_p les modalités ordonnées dans l'ordre croissant ($x_1 < x_2 < \dots < x_p$)

Tableau statistique

x_i	x_1	- - - - -	x_p
n_i	n_1		n_p
f_i	f_1		f_p

II / Représentation graphique.

X est représentée graphiquement par un diagramme en Batons



Rq: Respecter l'échelle sur les axes des x et y .
le plus long baton correspond à ce mode.

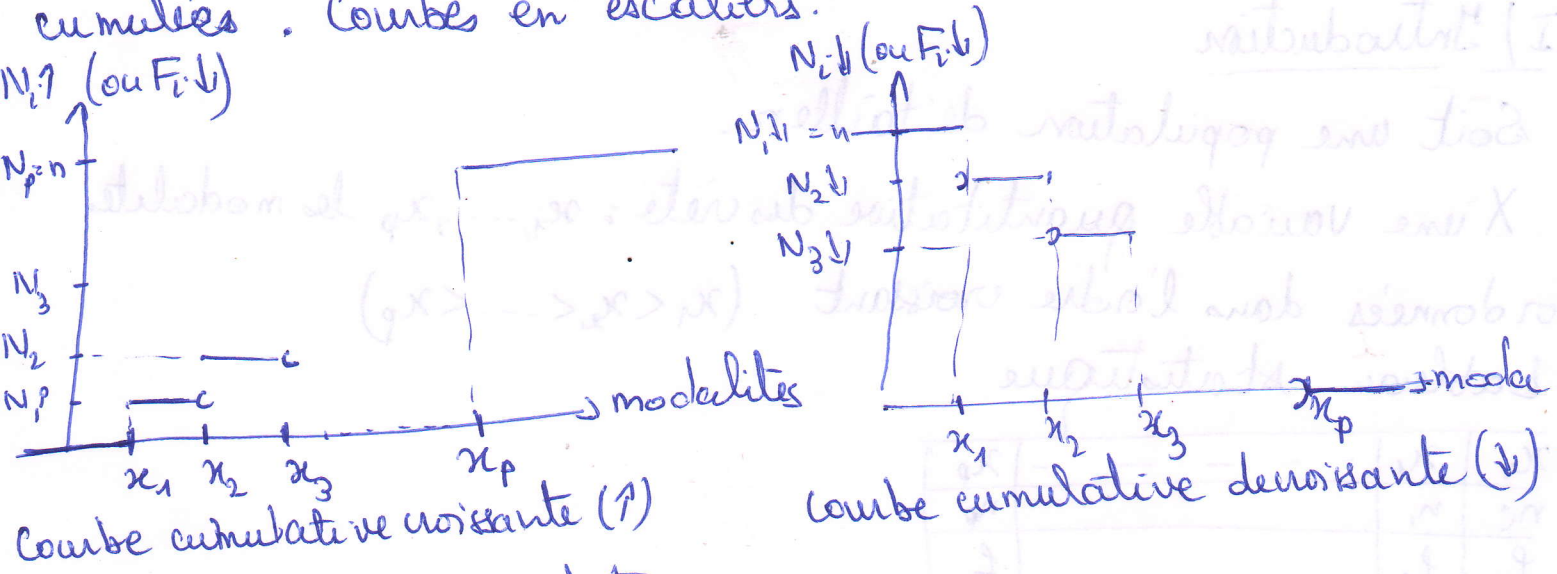
III / Fréquences Cumulées

Defs

- On appelle ~~fréquence~~ fréquence effective cumulée croissante d'une modalité x_i et on note $N_i \uparrow$ le nombre d'observations $\leq x_i$: $N_i \uparrow = n_1 + n_2 + \dots + n_i$
- La fréquence cumulée croissante d'une modalité x_i , est le rapport $F_i \uparrow = \frac{N_i \uparrow}{n} = f_1 + \dots + f_i$
- On appelle fréquence effective cumulée décroissante d'une modalité x_i et on note $N_i \downarrow$, le nombre d'observations $> x_i$: $N_i \downarrow = n_i + n_{i+1} + \dots + n_p$
- La fréquence cumulée décroissante de x_i , est le rapport $F_i \downarrow = \frac{N_i \downarrow}{n}$

IV / Courbes cumulatives

C'est la représentation graphique de effectifs (ou fréquences) cumulées. Courbes en escaliers.



V / Fonction de répartition

Déf

La fonction de répartition d'une distribution est une application

$$F: \mathbb{R} \longrightarrow [0, 1]$$

$$x \longmapsto \frac{\text{N}^{\text{bre}} \text{ d'Obs} \leq x}{n}$$

Pour la variable quantitative discrète, on a

$$x < x_1 \quad F(x) = 0$$

$$x_i \leq x < x_{i+1} \quad F(x) = F_i \quad i=1, \dots, p-1$$

$$x \geq x_p \quad F(x) = 1$$

VI / Paramètres de position et de dispersion

1/ Paramètres de position :

- Moyenne : $\bar{X} = \frac{1}{n} \sum_{i=1}^p n_i x_i = \sum_{i=1}^p f_i x_i$

- Médiane : si n est impaire $n = 2k+1$ $Med = x_{k+1}$
 si n est paire $n = 2k$ $Med = \frac{x_k + x_{k+1}}{2}$

La médiane Med est la valeur tq 50% des observations sont $\leq Med$


- Mode : note Mo la modalité ayant la plus grande effectif

- 1^{er} quantile : note Q_1 .

Q_1 est la valeur tq 25% des observations sont $\leq Q_1$.

- 3^{eme} quantile : note Q_3 .

Q_3 est la valeur tq 75% des observations sont $\leq Q_3$.



2) Parametre de dispersion.

- Etendue : $e = \max_{1 \leq i \leq n} x_i - \min_{1 \leq i \leq n} x_i = x_p - x_1$.

- Variance $\sigma^2 = \text{Var}(X) = \frac{1}{n} \sum_{i=1}^p n_i (x_i - \bar{x})^2 = \sum_{i=1}^p f_i (x_i - \bar{x})^2$

- Ecart type $\sigma = \sqrt{\text{Var}(X)}$

- Ecart interquartile $Q_3 - Q_1$

Proposition

On a les resultats suivants

• si $y_i = ax_i + b$ $\bar{y} = a\bar{x} + b$ ($a, b \in \mathbb{R}$)

• $\text{Var}(Y) = a^2 \text{Var}(X)$
 $\text{Var}(X) = \left(\frac{1}{n} \sum_{i=1}^p n_i x_i^2 \right) - \bar{x}^2 = \left(\sum_{i=1}^p f_i x_i^2 \right) - \bar{x}^2$

• Les parametres de dispersion sont positifs.