

# Statistiques

---

« *Objectiver un fonctionnement en quantifiant ses observations* »

→ *économie, prévisions, aspect synthèse*

*hubert.perrot@upmc.fr*

## **Plan du cours :**

- I) Séries statistiques – Généralités
- II) Paramètre de position et de dispersion
- III) Ajustement de séries statistiques
- IV) Indices statistiques
- V) Séries statistiques à deux caractères
- VI) Séries chronologiques

# Chapitre 1. Séries statistique – Généralité

## I) Définition

- Population : ensemble d'éléments faisant l'objet d'une étude statistique.

Exemples :

- Ensemble des élèves d'un amphithéâtre (étude sur l'âge, étude sur le lieu d'habitation, les notes ...)
- Ensemble de pièces produites par une machine (étude sur la taille, qualité, couleur ...)
- Ensemble des assurés d'une compagnie d'assurance (étude sur le nombre de voitures par assuré, le nombre d'accidents ...)

- Echantillon : partie de la population.

Exemples :

- Les élèves du groupe B
- Pièces fabriquées un jour donné ou sélection de 100 pièces prises au hasard
- Assurés d'un département donné

- Unité statistique : Un élément de la population étudié dont on veut examiner un ou plusieurs caractères. On parle aussi d'individu.

- Caractère :

- qualitatif (nominale, ordinale) : non mesurable (*bon, mauvais; lieu d'habitation*)
- quantitatif (discrète, continue) : mesurable à l'aide d'une variable statistique (*nombre d'individus, longueur d'une pièce fabriquée ...*)

- Variable statistique :

- discrètes : correspond à des valeurs isolées (*nombre d'individus*)
- continues : correspond à des valeurs sur un intervalle (*longueur, ...*)

- Séries statistique : ensemble des valeurs prises par une variable statistique sur l'ensemble de la population ou sur un échantillon.

## II) Séries statistique d'un caractère quantitatif discret

Soit un échantillon de taille  $n$  ( $x_1, x_2, x_3, \dots, x_p$ ) sont les valeurs prises par le caractère  $x$ , avec  $p$  le nombre de valeurs possible des  $x$ .

- Séries statistique : les valeurs prise par les n membres de l'échantillon.
- Effectif total : n
- Effectif partiel de  $x_i$  (fréquence absolue) : c'est le nombre de fois  $n_i$  qu'apparait la valeur  $x_i$  ( $n_1 + n_2 + \dots + n_p = n$ ).
- Fréquence relative de  $x_i$  :  $f_i = \frac{n_i}{n}$  ( $f_1 + f_2 + \dots + f_p = 1$ )
- Etude de la série : écart entre la plus grande et la plus petite des valeurs de  $x_i$

### Exemple :

On considère 100 familles (*l'échantillon*) de 4 enfants.  
Le caractère retenu : nombre de garçons.

- Valeurs prises par  $x_i = \{0, 1, 2, 3, 4\}$
- Effectif total : 100
- Série statistique : 3, 1, 3, 2, 4, 0, 1, 2, 3, 0, ...

On compte les valeurs :

$x_i$	0	1	2	3	4	Total
$n_i$ (effectifs partiels)	7	20	43	25	5	100

Fréquence relative de famille avec 2 garçons :  $\frac{43}{100}$ : 43 %

### III) Séries statistique d'un caractère quantitatif continu

Le nombre p de valeurs prises par la variable statistique  $x_i$  est infini (en réalité c'est fini à cause de la précision des mesures  $\rightarrow$  les  $f_i$  sont presque nulles).

- On va constituer les classes en divisant l'étendu de la série en un certain nombre d'intervalles

Donc si  $x_i$  variable statistique :



N° des classes :	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>p</b>
Effectifs partiels :	$n_1$	$n_2$	$n_3$	$n_4$	$n_p$
Centre des classes :	$x_1$	$x_2$	$x_3$	$x_4$	$x_p$

Avec pour la classe i : un centre de classe  $x_i$  et un effectif  $u_i$ .

Exemple : des nourrissons

Effectif total : 161

Pesées effectuée à 10 g près. Donnée le poids entre 2,24 et 4,45.



	2,2-2,5	2,5-2,8	2,8-3,1	3,1-3,4	3,4-3,7	3,7-4,0	4,0-4,3	4,3-4,6	total
Classe	1	2	3	4	5	6	7	8	
Centre	2,35	2,65	2,95	3,25	3,55	3,85	4,15	4,45	
Effectif	5	11	24	40	42	20	13	6	161
Relatives $f_i$	3,1	6,8	14,9	24,8	26,1	12,4	8,1	3,7	99,9 %

#### IV) Séries statistiques d'un caractère qualitatif

On va grouper les résultats en autant de classes qu'il existe de modalités du caractère.

Exemple : étude statistique sur des fleurs avec 3 couleurs possibles :

- 3 classes : une classe par couleur avec un effectif par classe.

Deux types de variables :

- Variable ordinale : si les modalités peuvent être ordonnées (taille vestimentaire, préférences, ...)
- Variable nominale : si elles ne peuvent être ordonnées (couleurs, profession, ...)

Variable dichotomiques : si on a seulement deux modalités.

#### V) Représentation graphique des série statistiques

##### 1) Séries à caractère discret :


- Diagramme en bâtons : (des effectifs et des fréquences absolues)

On trace  $n_i$  en fonction de  $x_i$  ou  $f_i$  en fonction de  $x_i$

Exemple des familles de 4 enfants : ( $x_i$  = nombre de garçons)

$x_i$	0	1	2	3	4	Total
$n_i$ (effectifs partiels)	7	20	43	25	5	100

**Cas discret**




Polygone des effectifs

- Polygone (des effectifs et de fréquences absolues) : On joint l'extrémité des bâtons par des segments
- Polygone (des fréquences relatives) : idem sauf que  $n_i \rightarrow f_i$
- Diagramme cumulé :
  - o Effectif cumulé : On va additionner les effectifs  $n_i$ , jusqu'à la  $i^{\text{ème}}$  valeur  $x_i$  du caractère :  $n_1+n_2+\dots+n_i$
  - o Fréquence relative cumulée : idem sauf qu'on additionne le  $f_i$

Exemple :

$x_i$	0	1	2	3	4	Total
$\Sigma n_i$ (effectifs cumulés)	7	27	70	95	100	100

**Diagramme cumulé des effectifs**



## 2) Caractère continu


Le diagramme en bâton est impossible car on a trop de valeurs de  $x_i$ :

- Histogramme :

- Classer les égales : amplitude des classes identique

Exemple des nourrissons :

Intervalles	2,2-2,5	2,5-2,8	2,8-3,1	3,1-3,4	3,4-3,7	3,7-4,0	4,0-4,3	4,3-4,6
Classe	1	2	3	4	5	6	7	8
$n_i$	5	11	24	40	42	20	13	6
$f_i$	3,1	6,8	14,9	24,8	26,1	12,4	8,1	3,7



○ Classes inégales

Exemple

Classes	5-6	6-7	7-8	8-10
$n_i$	12	13	16	6

$N = 47$

Problème d'amplitude pour la dernière classe : l'idéal est d'avoir quedes classes d'amplitude donc la classe [8-10] est divisée en 2 avec  $6/2 = 3$  comme effectif

D'où le nouveau tableau :


Classes	5-6	6-7	7-8	8-9	8-10
$n_i$	12	13	16	3	3

D'où l'histogramme

...

- Polygones des effectifs et des fréquences relatives :

Ligne brisée qui va rejoindre les milieux des sommets des rectangles



## Chapitre 2 . Paramètre de position et de dispersion

Objectif : on veut obtenir des paramètres pour condenser l'information contenue dans une série statistique

- Paramètres de position : donnent l'ordre de grandeur des mesures et l'existence de valeurs centrales autour desquelles se groupent des mesures
- Paramètres de dispersion : donnent la dispersion des mesures autour de la valeur centrale

### I) Paramètre de position

Soit une série statistique prenant n valeurs  $x_1, x_2, \dots, x_n$

#### 1) Moyenne arithmétique

On aura  $\bar{x} = \frac{x_1 + x_2 + \dots + x_n}{n} = \frac{1}{n} \sum_{(i=1)}^n n_i$

- Séries à caractère discret :

On a p valeurs des effectifs  $n_1, n_2, n_3, \dots, n_p$

Moyenne des  $\bar{x} = \frac{n_1x_1 + n_2x_2 + \dots + n_px_p}{n} = \frac{1}{n} \sum_{(i=1)}^p n_i x_i = \frac{1}{n} \sum_{(i=1)}^p f_i x_i$

Remarque : on parle de moyenne pondérée par les  $f_i$

- Séries à caractère continu :

On a p classes, d'effectifs  $n_i$  et de centre  $x_i$

Moyenne des  $x = \frac{n_1x_1 + n_2x_2 + \dots + n_px_p}{n} = \frac{1}{n} \sum_{(i=1)}^p n_i x_i$  ( $x_i$  est le centre de classe n°i)

Même formule que dans le cas discret, on rend la variable x discrète en considérant que celle-ci n peut prendre comme valeur que le centre des classes.

Exemple :

Avec  $n = 161$  (cas des nourrissons)

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

Après calcul on a  $\bar{x} = 3,406 \text{ kg}$

Remarque : astuce de calcul !

On remarque que le centre  $x_i$  des classes est corrélé avec le n° des classes  $z_i$

En effet, on peut écrire que  $x_i = M + a.z_i$  (M = Valeur initiale)

On a  $x_i = 2,35$   $a = 0,3$  et  $z_i = 1$  → d'ou  $M = 2,05$

$$\begin{aligned} \text{On a } \bar{x} &= \frac{1}{n} \sum_{(i=1)}^p n_i x_i = \frac{1}{n} \sum_{(i=1)}^p n_i (M + a \cdot z_i) \\ &= M \times \frac{n}{n} + a \times \frac{1}{n} \sum_{(i=1)}^p n_i z_i = M + a \bar{z} \end{aligned}$$

## 2) Médiane

On commence par ordonner les valeurs de la série et on prend la valeur qui sépare l'effectif en deux.

Notation = Me (Médiane)

- Série à caractère discret :

*Deux exemples :*

*3, 3, 4, 5, 7, 7, 9 → Me = 5 (3 valeurs au dessus, 3 valeurs en dessous)*

*3, 3, 4, 5, 6, 7, 7, 9 → 5 < Me < 6 : Me = 5,5 par exemple*

- Série à caractère continu :

La série est déjà ordonnée par classes alors la médiane va tomber dans une certaine classe  $[l_1, l_2[$  :  $F_1 \quad n/2 \quad F_2$  ) effectifs cumulés




où  $F_1$  : effectif cumulé en  $l_1$

$F_2$  : effectif cumulé en  $l_2$

$N$  : effectif total

$$h_0 = F_2 - F_1 = \text{effectif de la classe } [l_1, l_2[$$

On peut tracer le diagramme des effectifs cumulés :



$$\text{On a } \text{tg}(\alpha) = \frac{h}{Me - l_1} = \frac{h_0}{l_2 - l_1} = \frac{F_2 - F_1}{l_2 - l_1}$$

$$\text{On a } \frac{n}{2} = F_1 + h \quad \text{et } h = \frac{F_2 - F_1}{l_2 - l_1} \times (Me - l_1)$$

$$\text{Donc } \frac{n}{2} = F_1 + \frac{Me - l_1}{l_2 - l_1} \times (F_2 - F_1)$$

### Exemple

Or  $F_1 = 80$  et  $F_2 = 122$

$$\begin{aligned}\text{Donc } Me &= 3,4 + (80,5 - 80) \times \frac{3,7-3,4}{122-80} \\ &= 3,4 + 0,5 \times \frac{0,3}{42} = 3,503 \text{ kg}\end{aligned}$$

remarque ...

### 3) Quartiles

La médiane sépare la série en deux groupes de même effectif

Les quartiles séparent la série en quatre groupes de même effectif

- Cas des séries à caractère discret :

*Exemples :* 4, 5, 6, 11, 13, 14, 16.

$$Q_1 = 5, Q_2 = 11, Q_3 = 14$$

4, 5, 6, 7, 11, 13, 14, 15, 16.

$$Q_1 = 6, Q_2 = 11, Q_3 = 14$$