

# Chapitre 3 - Statistiques et Probabilités

## I - Les séries statistiques à une variable

### 1 - Définition:

On appelle série statistique  $X$ , l'ensemble de toutes les observations  $x_i$ ,  $i = 1 : N$ , liés à un caractère donné. Les observations  $x_i$  peuvent être des valeurs discrètes ou continues, comme elles peuvent exprimer des variables quantitatives ou qualitatives.

Une observation  $x_i$  peut être observée une, deux ou plusieurs fois le long de la série statistique, le nombre de fois où est observée la variable  $x_i$  est appelé effectif de  $x_i$  et il est noté  $n_i$ . Dans ce cas la fréquence d'observation de la variable  $x_i$  est notée  $f_i = \frac{1}{n_i}$ .

NB: Ces données sont collectées, puis dépolluées, puis classées pour qu'elles puissent être traitées.

exemple: Soit la série statistique  $X$  suivante, donner la fréquence d'observation de la valeur 7 et celle de la valeur 1?

Réponse:  $X = \{7, 6, 0, 1, 5, 0, 7, 1, 1, 6, 3, 1, 7, 5, 2, 1, 0, 3\}$

$x = 7$  est observée 3 fois  $\Rightarrow n_7 = 3 \Rightarrow f_7 = \frac{1}{n_7} = \frac{1}{3}$  ou 0.33

$x = 1$  est " 5 fois  $\Rightarrow n_1 = 5 \Rightarrow f_1 = \frac{1}{n_1} = \frac{1}{5}$  ou 0.20

NB: Les données de toute série statistique peuvent être résumées par un tableau.

exemple 2: Soit la série statistique  $X$  de l'exemple 1, représenter la sous forme de tableau.

Réponse: X peut être résumé par un tableau simple à deux colonnes : la première est celle correspondant aux valeurs observées, la deuxième concerne les effectifs de ces dernières valeurs, comme c'est indiqué ci-dessous.

$x_i$	$n_i$
0	3
1	5
2	1
3	2
5	2
6	2
7	3
	$\Sigma = 18$

$x_i$  est l'ensemble des valeurs observées  $\rightarrow$

$n_i$  est l'effectif des valeurs observées

Dans ce cas la somme des effectifs est égale

à  $N = \sum_i n_i$  et est appelé : Taille de la série

qui est égale à 18 dans le présent exemple, et la

fréquence ~~(effectif)~~ de  $x_i$  est égal à  $\frac{n_i}{N} = f_i$  (fréq. globale)

## 2. Représentation d'une série statistique.

L'ensemble des données d'une série statistique peut être résumé et représenté de différentes manières selon le cas et selon les besoins.

2.1. Sous forme de tableaux. ces derniers comprennent deux colonnes au moins

l'une pour le caractère  $x_i$ , l'autre pour les effectifs  $n_i$  correspondants.

. Pour les variables qualitatives les  $x_i$  sont codés

. Pour les variables quantitatives les  $x_i$  sont classés par ordre croissant.

2.2. Sous forme d'arbres :


Cette forme de représentation permet de visualiser les résultats d'un questionnaire, par exemple quand il ya différents choix possibles par question.

Exemple: On pose deux questions à 20 personnes et on leur demande de répondre par OUI (code 1) ou NON (code 0). On obtient 17 personnes qui ont répondu OUI à la 1<sup>ère</sup> question et 10 qui ont répondu OUI aux 2 questions. Combien de personnes ont, sur les 17, répondu Non à la 2<sup>ème</sup> question? représenter sous la forme adéquate.

Réponse: Sur les 20 personnes il y a 17 qui ont répondu OUI il reste 3 personnes pour la réponse NON de la 1<sup>ère</sup> question. Parmi ces 17 personnes 10 vont encore répondre OUI à la 2<sup>ème</sup> question, ce qui laisse 7 personnes pour la réponse NON des 17 personnes. La représentation la plus adéquate est elle sous forme d'arbre comme suit:

### Titre:

Représentation sous forme d'arbre de la série donnée



(Nombre de personnes interrogées)

↓ 1<sup>ère</sup> question 2 choix  
(OUI:1, NON:0)

17 ont répondu OUI et 3 Non

↓ 2<sup>ème</sup> question 2 choix  
(OUI:1, NON:0)

10 ont répondu OUI et 7 Non

donc le nombre de personnes qui ont répondu OUI à la 1<sup>ère</sup> question et OUI à la 2<sup>ème</sup> question est égal à 10, tandis que le nombre de personnes qui ont répondu OUI à la 1<sup>ère</sup> question et NON à la 2<sup>ème</sup> question est égal à 7.

### 2.3. Sous forme de graphiques:

C'est la forme de représentation la plus courante, dans ce cas quelque soit le graphique utilisé, il faut définir ce qu'il représente (le titre), indiquer de façon claire la signification des axes et choisir une unité de représentation adaptée au support utilisé.

Selon le cas, nous pouvons avoir des séries statistiques discrètes ou continues.

#### 2.3.1. Cas d'une série discrète:

Dans ce cas on utilise des diagrammes en bâtons où la hauteur du bâton est proportionnelle à l'effectif  $n_i$  (en ordonnées)

correspondant à la valeur du caractère  $x_i$  considéré (en abscisses).

**Exemple:** Soit la série  $X = \{ 4, 1, 3, 4, 4, 2, 1, 3, 4, 4, 1, 2, 3, 3, 4, 4, 2, 4, 4, 3, 2, 2, 3, 3, \}$


tracer le graphique qui la représente?

**Réponse:** Le graphique qui peut représenter la série  $X$  est celui qui représente les effectifs  $n_i$  en ordonnées en fonction des valeurs de  $X$  en abscisses.

Le passage par le tableau des valeurs et leurs effectifs est obligatoire.

nous obtenons:

$x_i$	$n_i$
1	3
2	5
3	7
4	9



- Diagramme en bâtons de  $X$  -

**NB:** Il faut noter les informations portées sur le graphique: le titre, la désignation des axes et puis l'échelle.

### 2.3.2. Cas d'une série continue:


Si la série de données est continue, il faut la diviser en plusieurs intervalles dans ce cas le graphique est appelé Histogramme. On porte en abscisses les valeurs  $x_i$  et en ordonnées les effectifs correspondants. Pour chaque classe ou intervalle de  $x_i$  on élève un rectangle dont la base est proportionnelle à l'amplitude de la classe  $x_i$  et dont la hauteur est proportionnelle à l'effectif  $n_i$ .

**Exemple:** Soit la distribution des effectifs suivante tracer son histogramme des effectifs?

$x_i$	$n_i$
10 - 20	5
20 - 30	10
30 - 40	20
40 - 50	5

Réponse:

Il faut observer l'égalité entre les triangles se trouvant au dessus et au dessous de la courbe des effectifs.




2.3.3. Cas d'une série à variable qualitative:

Dans ce cas on utilise soit des diagrammes à bandes, soit des diagrammes circulaires. La légende des couleurs s'impose.

Exemple: Une usine compte 85% de travailleurs, 10% de cadres supérieurs et 5% de cadres moyens. Représenter son effectif travailleur sous forme de bandes et sous forme de diagramme circulaire

Réponse:


Diagramme à bande: il faut choisir l'échelle adéquate et donner un titre et une légende.



1cm : 10%

Légende:  $\circ$  : travailleurs,  $\square$  : cadres supérieurs,  $\square$  : cadres moyens.

Diagramme circulaire: il faut savoir que l'angle qui fait le arc est égale  $360^\circ$  et il faudra calculer les angles  $\alpha_1$  correspondant à 5%,  $\alpha_2$  correspondant à 10% et  $\alpha_3$  correspondant à 85%. Ensuite il faut colorer ou désigner une légende pour la lecture du diagramme sans oublier de lui attribuer un titre.




## 2.4. Autres graphiques :

Il existe d'autres types de graphiques pour représenter les séries statistiques entre autres :

### 2.4.1. Graphes chronologiques :

Si les observations sont enregistrées au cours du temps, cela veut dire qu'elles sont indiquées dans le temps tel que  $x_t$  est l'observation d'un caractère  $x$  dans le temps  $t$ . Dans ce cas l'ensemble de toutes les observations est appelé série chronologique, pour la représenter on porte en abscisses le temps  $t$  et en ordonnées  $x_t$  correspondant.



- Graphique d'une série chronologique -

### 2.4.2. Graphes à coordonnées polaires :


On suppose que le temps s'écoule de manière circulaire, dans le sens des aiguilles d'une montre. Chaque période est représentée par un axe pour lequel on portera la valeur du caractère. L'angle entre les axes dépendra du nombre de périodes.

Exemple : Soit la série des bovins nés dans une ferme pendant les quatre saisons de 2008. Donner la représentation polaire de ses naissances au cours des 4 saisons.

Réponse :

$x_t$	50	60	100	30
$t$	1	2	3	4

$t$  : saison : 1:4  
 $x_t$  : nombre de bovins nés dans la saison  $t$



- Graphique polaire des bovins nés en 2008 de la ferme indiquée.

**NB:** La saison est désignée par le nombre de bovins qui sont nés à son courant. et le graphique permet de visualiser les variations saisonnières de cette naissance bovine.

### 2.4.3. Graphes à échelle logarithmique:

L'échelle logarithmique est une échelle graduée proportionnellement au Log decimal. Elle représente des phénomènes de croissance à taux constant par une droite et est généralement utilisée quand la variable croît très rapidement.

### 3. Effectifs et fréquences:

Il est déjà connu que l'effectif  $n_i$  d'une valeur est le nombre de fois où elle apparaît dans la série étudiée. Soit  $N$  l'effectif total.  $N$  est la somme de toutes les valeurs des effectifs  $n_i$ , tel que:

$$N = \sum_i n_i$$

la fréquence  $f_i$  correspondante :  $f_i = \frac{1}{n_i}$   
avec la fréquence globale:  $F_i = \frac{n_i}{N} / \sum_i F_i = 1 = 100\%$  -7-

### 3.1. Effectif cumulé croissant (ECC) et effectif cumulé décroissant (ECD) :

L'effectif cumulé croissant (ECC) est le cumul des effectifs dans le sens croissant du début vers la fin des effectifs partiels. L'effectif cumulé décroissant c'est le chemin inverse de la fin du cumul vers le début de celui-ci.

Exemple : soit la série des effectifs suivants calculer son ECC et son ECD ?

$x_i$	1	2	3	4	5
$n_i$	12	10	5	20	15

Réponse : on calcule et on reporte dans le tableau suivant les valeurs de l'ECC et l'ECD de la série considérée.

$x_i$	$n_i$	ECC	ECD
1	12	12	62
2	10	22	50
3	5	27	40
4	20	47	35
5	15	62	15
	$\Sigma = 62$		

- Il faut noter que la valeur la plus grande de l'ECC et l'ECD est égale à la somme des effectifs partiels  $n_i$ .
- Et que cette valeur la plus grande est la dernière valeur pour l'ECC et la première valeur pour l'ECD.

Dans le cas d'une série continue, les valeurs de  $x_i$  sont données sous forme de classes ou intervalles. Dans ce cas :

- ECC correspondant à une classe donnée  $[a, b[$  indique le nombre de fois où le caractère prend une valeur strictement inférieure à  $b$ .
- ECD correspondant à une classe donnée  $[a, b[$  indique le nombre de fois où le caractère prend une valeur supérieure ou égale ( $\geq$ ) à  $a$ .

### 3.2. Fréquence cumulée croissante (FCC) et fréquence cumulée décroissante (FCD) :

La même procédure de calcul est poursuivie pour les fréquences. On remplace dans les définitions "le nombre de fois" par "pourcentage" dans l'ECC et l'ECD pour obtenir FCC et FCD.



#### 4. Représentation Numérique d'une série statistique :

Après avoir exposé les différentes manières de représentation graphique d'une série statistique, dans le présent paragraphe, nous allons nous intéresser à la représentation numérique des séries statistiques. Cette représentation résume par le biais de quelques nombres les caractéristiques statistiques des séries. La première classe s'intéresse à la position centrale de la série et les paramètres qui la déterminent, la seconde classe s'intéresse à la dispersion autour de cette position centrale et les paramètres qui la désignent.

##### 4.1. Les paramètres de la position centrale (Moyenne)

###### 4.1.1. La moyenne arithmétique :

Soit  $(x_i, n_i)$  une série statistique. La moyenne arithmétique est désignée par  $\bar{X}$  telle que :

$$\bar{X} = \frac{1}{\sum_i n_i} \sum_i n_i x_i$$

• pour les séries continues,  $x_i$  est le centre des classes.

Exemple : Soit la série suivante, calculer sa moyenne arithmétique.

Réponse :

$x_i$	$n_i$	$x_i$	$n_i x_i$
[10 : 20[	100	15	1500
[20 : 30[	80	25	2000
[30 : 50[	120	40	4800
[50 : 100[	60	75	4500
[100 : 150[	10	125	1250
	$\sum_i = 370$		$\sum_i = 14050$

$$\bar{X} = \frac{1}{\sum_i n_i} \sum_i n_i x_i$$

AN:  $\bar{X} = \frac{14050}{370} = 38$  unité donc la moyenne arithmétique

est  $\boxed{\bar{X} = 38 \text{ unité}}$

N.B:  $\bar{X} \rightarrow$  Valeur Centrale

#### 4.1.2. La moyenne harmonique (H) :

$$\frac{1}{H} = \frac{1}{N} \sum_i n_i \frac{1}{x_i}$$

$$N = \sum_i n_i$$

H : moyenne harmonique des  $x_i$ .

#### 4.1.3. La moyenne géométrique (G) :

On l'utilise quand les valeurs sont liées entre elles par une liaison de croissance

$$G = \left( \prod_i x_i^{n_i} \right)^{\frac{1}{N}}$$

$\prod$  : produit

$$N = \sum_i n_i$$

G : moyenne géométrique des  $x_i$ .

Exemple : une plante augmente de 10% pendant 2 jours, puis de 5% pendant 4 jours et de 12% pendant 6 jours. Calculer le taux de croissance moyen sur la période ?

Réponse : Soit  $\tau$  le taux de croissance moyen sur cette période, il est donné par la moyenne géométrique et peut donc être calculé selon la formule :

$$\tau = \left( 1.10^2 \times 1.05^4 \times 1.12^6 \right)^{\frac{1}{12}}$$

AN

$$\tau = 9.2\%$$

#### 4.1.4. Le mode ( $m_0$ ) :

C'est la valeur du caractère  $x_i$  qui correspond à l'effectif le plus élevé.

#### 4.1.5. La médiane ( $m_e$ ) :

Pour une série  $(x_i, n_i)$ ,  $i:1:N$ , la médiane est la valeur du caractère  $x_i$  qui partage les effectifs en deux parties égales.

- Pour les séries discrètes, si le nombre d'observations est pair la médiane peut être indéterminée.

Exemple: Soit les 2 séries suivantes qui présentent un nombre d'observations pair,  
- déterminer la médiane pour chaque série?

Réponse:

1)

$x_i$	$n_i$	
0	2	
1	3	
2	4	
3	3	
$N = \Sigma = 12$		

• ici  $N = 12$  (il est pair)  
 $N/2 = 6$

L'observation  $x_i$  qui divise les effectifs  $n_i$  en deux parties égales se situe entre la 6<sup>ème</sup> et 7<sup>ème</sup> observation donc la médiane :

$$me = 2$$

2)

$x_i$	$n_i$	0
0	2	
1	3	
2	3	
3	2	
$N = \Sigma = 10$		

• ici  $N = 10$  (il est aussi pair)  
 $N/2 = 5$

la médiane  $x_i$  qui divise les effectifs  $n_i$  en deux parties égales est dans ce cas indéterminé.

- Pour les séries continues, la médiane se calcule par la formule suivante:

$$\frac{me - a}{b - a} = \frac{N/2 - ECC_{-1}}{n}$$

$$me \in [a, b[$$

La médiane  $me$  correspond à l'effectif  $N/2$ . On repère dans la colonne  $ECC$ , à quelle classe appartient cet effectif. Soit  $[a, b[$  cette classe,  $n$  son effectif et  $ECC_{-1}$  l'effectif cumulé croissant de la classe précédente.

Exemple: Soit la série  $(x_i, n_i)$  suivante, déterminer sa médiane.

Réponse:

$x_i$	$n_i$	$ECC$
500	1000	6
1000	2000	18
2000	3000	48
3000	4000	86
4000	5000	117
5000	6000	143
6000	8000	448
+ 8000	2	150
$N = 150$		

$$N/2 = 150/2 = 75$$

$$75 \in [3000, 4000[ \Rightarrow me \in [3000, 4000[$$

$$\frac{me - 3000}{4000 - 3000} = \frac{75 - 48}{38}$$

$$me = 3710 \text{ unités}$$

## 4.2. Les paramètres de dispersion autour de la moyenne

### 4.2.1. La variance ( $\sigma^2$ ou $s^2$ )

La variance est définie comme la moyenne des carrés des écarts à la moyenne. Soit  $e_i$  est écart par rapport à la moyenne  $\bar{x}$  des observations  $x_i$

$$x_i \left( \bar{x} = \frac{1}{\sum n_i} \cdot \sum_i n_i x_i \right)$$
$$e_i = x_i - \bar{x}$$

La moyenne des carrés des  $e_i$

est :

$$\sigma^2 = \frac{1}{N} \sum n_i e_i^2$$

$$\sigma^2 = \frac{1}{N} \sum n_i (x_i - \bar{x})^2$$

C'est la variance de la série  $(x_i, n_i)$

**Rq:** La formule la plus connue pour la variance est celle de **Koenig**. C'est généralement la formule la plus utilisée.

$$\sigma^2 = \frac{1}{N} \sum n_i x_i^2 - \bar{x}^2$$

### 4.2.2. L'écart type $\sigma$ :

C'est la racine carrée de la variance et mesure l'écart moyen autour de la moyenne. Ainsi une série statistique qui possède un faible écart-type est une série où les valeurs sont peu dispersées autour la moyenne qui présente alors un indicateur plus fiable.

### 4.2.3. Le coefficient de variation (Cv)

$$Cv = \frac{\sigma}{\bar{x}}$$

**NB:** La pratique et l'expérience montrent que pour une distribution unimodale et symétrique, 68% des valeurs  $\in [\bar{x} - \sigma, \bar{x} + \sigma]$  et 95% "  $\in [\bar{x} - 2\sigma, \bar{x} + 2\sigma]$

ceci est important dans le calcul des bornes de confiance (ou limites de confiance).