

CHAPITRE II

LES PARAMETRES DE TENDANCE CENTRALE

Le statisticien ou le chercheur dispose encore d'une multitude de techniques de synthèse qui permettent de renseigner sur le phénomène étudié, à travers la caractérisation de la série. Cette caractérisation, consiste à représenter la série statistique par des chiffres illustratifs ou représentatifs, appelés paramètres, que le chercheur calcule lui-même, selon la nature du phénomène qu'il veut mettre en évidence.

Il existe en statistique descriptive trois grands groupes de paramètres :

- Les paramètres de tendance centrale ou de position,
- Les paramètres de dispersion,
- Les paramètres de concentration.

Un paramètre statistique pour être pertinent, objectif et correctement utilisé doit remplir les (6) conditions suivantes émises par le statisticien britannique Yule (Goldfarb. B et Pardoux. C, 2013).

1. Etre défini de façon objective ou précise,
2. Dépendre de toutes les valeurs (modalités) de la série,
3. Avoir une signification concrète facile à concevoir,
4. Etre simple à calculer,
5. Etre peu sensible aux fluctuations d'échantillonnage,
6. Se prêter aisément au calcul algébrique.

Ainsi, plus un paramètre satisfait un grand nombre de ces conditions, plus il est considéré comme pertinent, voire parfait.

L'objet de ce troisième chapitre est l'étude des paramètres du premier groupe, à savoir ; les paramètres de tendance centrale. Nous y étudions successivement : le mode (section I), la médiane (section II), la moyenne arithmétique (section III) .

Section I : Le mode

I.1-Définition

Le mode d'une série ou distribution statistique, noté « Mo », est la modalité dominante ou la plus fréquente, c'est-à-dire la valeur de la variable qui correspond au plus grand effectif ou plus grande fréquence relative. Par exemple, dans la série : {5, 6, 7, 7, 8, 8, 8, 9, 10} ; $Mo=8$, 8 est la valeur qui se répète le plus (3 fois).

I.2-Détermination pratique

Le mode se détermine de manière algébrique et graphique, et la détermination diffère selon qu'il s'agisse de variable statistique discrète (VSD) ou variable statistique continue (VSC).

2.1-Cas de la variable statistique discrète (VSD)

Lorsque la variable est discrète, le mode peut être repéré :

- **Dans le tableau :** c'est la modalité « xi » pour laquelle l'effectif ou la fréquence relative est le plus élevé ;
- **Sur le diagramme en bâtons :** c'est la modalité xi correspondant au bâton le plus haut.

2.1.1-Par la méthode analytique ou algébrique

Il s'agit de repérer dans la colonne (ni) ou (fi) du tableau statistique l'effectif le plus élevé (ou le chiffre le plus élevé), la modalité (xi) (dans la colonne des xi) correspondant à celui-ci est le mode.

Exemple 01 : Soit la distribution suivante :

Xi	ni
1	4
2	3
3	8
4	3
5	2
Total	20

-Calcul du mode de cette distribution.

Il suffit de regarder la colonne (ni), le plus grand nombre c'est $ni=8$, la modalité correspondante dans la colonne (xi) c'est 3. Donc le Mode = 3.

Exemple 02 : Soit la distribution suivante :


Nombre d'enfants	Nombre de ménages	$f_i\%$
0	5	5.62
1	17	19.10
2 ←	31 ←	34.83
3	20	22.47
4	11	12.36
5 et plus	5	5.62
Σ	89	100%

$M_o=2$ enfants puisque " n_i " le plus élevé est 31 correspondant à la fréquence relative f_i la plus élevée aussi 34.83%.


2.1.2-Par la méthode graphique :

Il s'agit d'une variable statistique discrète (valeurs individuelles ou isolées), donc le graphique correspondant est le diagramme en bâtons. Le principe est de repérer le bâton le plus long (dont la hauteur indique l'effectif), la valeur (x_i) correspondante sur l'axe horizontal (l'axe xx') est le mode. On aura alors le graphique suivant :

Le mode graphiquement pour l'exemple n°01



Le mode graphiquement pour l'exemple n°02



2.2-Cas de la variable statistique continue (VSC)

Ici, les données sont regroupées sous forme de classes. La valeur (x_i) correspondant au mode appartient forcément à une classe. Cette classe s'appelle classe modale. Elle est repérée comme la classe « la plus dense », c'est-à-dire celle correspondant à la plus grande densité (d_i). Deux situations peuvent se présenter :

2.2.1-Cas où les amplitudes de classes constantes ou égales

On détermine d'abord la classe modale. Elle correspond à l'effectif le plus élevé et à la fréquence relative la plus élevée, puis on repère à l'intérieur de cette classe la valeur du mode. Dans ce cas, la classe la plus dense est celle aussi correspondant au plus grand effectif, car dans ce cas $d_i = \frac{n_i}{a_i}$ revient à diviser tous les effectifs par la même amplitude, donc la classe qui a le plus grand effectif sera aussi la plus dense.

De manière algébrique, la détermination du mode suit les étapes suivantes :

- Repérer dans la colonne (ni) ou (fi) la plus grande valeur (le plus grand effectif) ;
- Repérer la classe modale correspondant au plus grand effectif,
- Appliquer la formule du mode réservée au cas de la variable continue :

$$M_0 = x_0 + a_i \frac{(n_{mo} - n_{mo-1})}{(n_{mo} - n_{mo-1}) + (n_{mo} - n_{mo+1})}$$

Ou bien :

$$M_0 = x_0 + a_i \frac{(f_{i_{mo}} - f_{i_{mo-1}})}{(f_{i_{mo}} - f_{i_{mo-1}}) + (f_{i_{mo}} - f_{i_{mo+1}})}$$

Avec :

- x_0 = borne inférieure de la classe modale.
- a_i = amplitude de la classe modale.
- n_{mo} = effectif de la classe modale.
- n_{mo-1} = effectif de la classe avant ou précédent la classe modale.
- n_{mo+1} = effectif ou fréquence de la classe après ou suivant la classe modale.
- $f_{i_{mo}}$ = fréquence de la classe modale.
- $f_{i_{mo-1}}$ = fréquence de la classe avant ou précédent la classe modale.
- $f_{i_{mo+1}}$ = fréquence de la classe après ou suivant la classe modale.

Exemple : voici les dépenses mensuelles d'un échantillon de 100 ménages.

Dépenses (10^3) DA	Nombre de ménages	a_i	f_i
[10-30[	10	20	0.1
[30-50[	20	20	0.2
[50-70[	← 45	20	0.45
[70-90[	17	20	0.17
[90-110[	8	20	0.08
Σ	100	/	1

n_i le plus élevé est 45 donc la classe modale est [50-70]

$$M_0 = x_0 + a_i \frac{(n_{mo} - n_{mo-1})}{(n_{mo} - n_{mo-1}) + (n_{mo} - n_{mo+1})}$$

$$M_0 = 50 + 20 \frac{(45 - 20)}{(45 - 20) + (45 - 17)}$$

$$\rightarrow M_0 = 59.43 \times 10^3 \text{ DA}$$

Ou bien :

$$M_0 = x_0 + a_i \frac{(f_{i_{mo}} - f_{i_{mo-1}})}{(f_{i_{mo}} - f_{i_{mo-1}}) + (f_{i_{mo}} - f_{i_{mo+1}})}$$

$$M_0 = 50 + 20 \frac{(0.45 - 0.2)}{(0.45 - 0.2) + (0.45 - 0.17)}$$

$$\rightarrow M_0 = 59.43 \times 10^3 \text{ DA}$$

2.2.2-Cas où les amplitudes des classes sont inégales ou non constantes ($a_i \neq \text{Cte}$)

Lorsque les amplitudes sont inégales, il faut corriger les effectifs ou les fréquences relatives. Le mode sera calculé en utilisant ces effectifs ou fréquences corrigés.

En ce sens, la classe la plus dense n'est pas forcément celle qui correspond au plus grand effectif. En effet, $d_i = \frac{n_i}{a_i}$, ($a_i \neq \text{Cte}$), signifie que l'on divise les effectifs ou les fréquences par des valeurs de a_i différentes, ce qui implique que l'on peut tomber sur des situations où la classe correspondant au plus grand effectif n'est pas la classe la plus dense.

Aussi, avant de calculer le mode, il faut comme précédemment, calculer les densités (ou calculer les effectifs corrigés n_{ic}).

La détermination du mode suit les étapes suivantes :

- Calculer les densités (d_i) ou les effectifs corrigés (n_{ic}),
- Repérer dans la colonne (d_i) ou (n_{ic}) la plus grande valeur (plus grande densité),
- Repérer la classe modale correspondant à cette plus grande valeur,
- Appliquer la formule du mode réservée au cas continu avec amplitude non constante :

$$M_0 = x_0 + a_i \frac{(n_{icmo} - n_{icmo-1})}{(n_{icmo} - n_{icmo-1}) + (n_{icmo} - n_{icmo+1})}$$

Avec :

- x_0 = borne inférieure de la classe modale.
- a_i = amplitude de la classe modale.
- n_{icmo} = effectif ou fréquence de la classe modale.
- n_{icmo-1} = effectif ou fréquence de la classe avant ou précédent la classe modale.
- n_{icmo+1} = effectif ou fréquence de la classe après ou suivant la classe modale

Ou bien :

$$M_0 = x_0 + a_i \frac{(f_{icmo} - f_{icmo-1})}{(f_{icmo} - f_{icmo-1}) + (f_{icmo} - f_{icmo+1})}$$

Ou bien encore avec les densités :

$$M_0 = x_0 + a_i \frac{(d_{imo} - d_{imo-1})}{(d_{imo} - d_{imo-1}) + (d_{imo} - d_{imo+1})}$$

Avec :

- x_0 = borne inférieure de la classe modale.
- a_i = amplitude de la classe modale.
- d_{imo} = densité de la classe modale.
- d_{imo-1} = densité de la classe avant ou précédent la classe modale.
- d_{imo+1} = densité de la classe après ou suivant la classe modale.

Remarque :

L'étudiant a le choix dans les applications (exercices) de choisir, parmi les formules proposées.

Exercice n°01 (« ai » constante) : Calculer le mode de la distribution suivante et représenter le graphiquement :

Classes	Effectifs
[10-20[	10
[20-30[	10
[30-40[	15
[40-50[	5

Il faut d'abord, au préalable, calculer les amplitudes et voir si elles sont constantes ou pas. On ajoute alors une colonne (a_i) au tableau, on obtient le tableau ci-après :

Classes	n_i	f_i	a_i
[10-20[	10	0,250	10
[20-30[	10	0,250	10
[30-40[	15	0,375	10
[40-50[	5	0,125	10
Total	40	1	-

On constate donc que l'amplitude (a_i) est constante ($a_i=10$). Par conséquent, la classe modale est celle qui correspond au plus grand effectif. Si on regarde dans la colonne (n_i), la plus grande valeur c'est 15, ($n_i=15$). La classe correspondant (c'est-à-dire sur la même ligne) c'est [30-40], c'est la classe modale, donc $x_0 = 30$.

On applique la formule du mode développée précédemment ((1) ou (2)) :

$$M_0 = x_0 + a_i \frac{(n_{mo} - n_{mo-1})}{(n_{mo} - n_{mo-1}) + (n_{mo} - n_{mo+1})}$$

$$M_0 = 30 + 10 \frac{(15 - 10)}{(15 - 10) + (15 - 5)}$$

$M_0 = 33.33$ DA

Ou bien :


$$M_0 = x_0 + a_i \frac{(f_{imo} - f_{imo-1})}{(f_{imo} - f_{imo-1}) + (f_{imo} - f_{imo+1})}$$

$$M_0 = 30 + 10 \frac{(0.375 - 0.250)}{(0.375 - 0.250) + (0.375 - 0.125)}$$

$M_0 = 33.33$ DA

De manière graphique, il s'agit d'une VSC, donc la fonction de distribution est représentée graphiquement par l'histogramme. Compte tenu de l'amplitude de classe (constante ou pas), le mode se détermine de la même manière à partir du rectangle de la classe modale (la plus dense) dans l'histogramme).

Il suffit pour cela de relier par une ligne (ou un segment) la borne supérieure du rectangle de la classe modale à la borne supérieure du rectangle de la classe précédente. Ensuite, relier par une autre ligne ou segment la borne inférieure du rectangle de la classe modale à la borne inférieure de la classe suivante. Le point de croisement des deux lignes ou deux segments est ensuite projeté sur l'axe des abscisses (l'axe des classes ou horizontal). La valeur (x_i) correspondante sur cet axe est le mode. Voyons cela dans la représentation graphique suivante :



Exercice 02 (« ai » inconstante) : Calculer le mode de la distribution suivante :

Classes	Effectifs
[10-20[	10
[20-30[	20
[30-50[	30
[50-80[	25

Pour calculer le mode, il faut d'abord vérifier les amplitudes (a_i). On construit comme précédemment une colonne (a_i) de laquelle dépendra le nombre de colonnes à ajouter au tableau, selon que « a_i » soit Cte ou pas.

Classes	Effectifs	a_i	d_i	n_{ic}
[10-20[	10	10	1	10
[20-30[	20	10	2	20
[30-50[	30	20	1.5	15
[50-80[	25	30	0.83	8.33
Total	85	-	-	/

Si on regarde la colonne (a_i), on constate que l'amplitude de classe n'est pas constante. La classe modale est donc la classe la plus dense, c'est-à-dire celle qui a la plus grande densité ou le plus grand effectif corrigé, et qui n'est pas forcément celle qui a le plus grand effectif. L'amplitude de base (la plus petite

amplitude), d'après le tableau est $a_0 = 10$. On en déduit les (n_{ic}). Ou bien, on calcule directement les densités (d_i).

Dans la colonne (d_i), la plus grande valeur c'est 2. Sur la même ligne, la plus grande valeur correspondante dans la colonne (n_{ic}) doit automatiquement être la plus grande valeur de la colonne (n_{ic}). Si ce n'est pas le cas, cela voudrait dire qu'il y a erreur de calcul quelque part que l'étudiant doit vérifier et corriger.

Dans notre tableau, la densité la plus élevée $d_2 = 2$, correspond également sur la même ligne, dans la colonne (n_{ic}), à la plus grande valeur n_{ic} , $n_{ic} = 20$. La classe correspondante, à savoir ; **[20-30[**, est la classe modale ou la plus dense.

$$M_0 = x_0 + a_i \frac{(f_{icmo} - f_{icmo-1})}{(f_{icmo} - f_{icmo-1}) + (f_{icmo} - f_{icmo+1})}$$

$$M_0 = 20 + 10 \frac{(20 - 10)}{(20 - 10) + (20 - 15)}$$

$$M_0 = 26.67 \text{ DA}$$

Ou bien :

$$M_0 = x_0 + a_i \frac{(d_{imo} - d_{imo-1})}{(d_{imo} - d_{imo-1}) + (d_{imo} - d_{imo+1})}$$

$$M_0 = 20 + 10 \frac{(2-1)}{(2-1) + (2-1.5)}$$

$$M_0 = 26.67 \text{ DA}$$

Exercice 03 : Voici les dépenses hebdomadaires de 100 ménages.

Dépenses (10^2 DA)	n_i	a_i	n_{ic}	d_i
[30-50[	10	20	10	0.5
[50-80[	30	30	20	1
[80-100[	25	20	25	1.25
[100-130[	27	30	18	0.9
[130-150[	8	20	8	0.4
Σ	100	/	/	/

La classe modale est **[80-100[** car l'effectif corrigé le plus élevé est $n_{3c} = 25$, elle correspond aussi à la densité la plus élevée $d_3 = 1.25$. Une fois la classe modale déterminée, on applique les formules du carré ci-après.

$$M_0 = x_0 + a_i \frac{(n_{icmo} - n_{icmo-1})}{(n_{icmo} - n_{icmo-1}) + (n_{icmo} - n_{icmo+1})}$$

$$M_0 = 80 + 20 \frac{(25 - 20)}{(25 - 20) + (25 - 18)}$$

$$M_0 = 88.33 \text{ DA}$$



Ou bien :

$$M_0 = x_0 + a_i \frac{(d_{imo} - d_{imo-1})}{(d_{imo} - d_{imo-1}) + (d_{imo} - d_{imo+1})}$$

$$M_0 = 80 + 20 \frac{(1.25 - 1)}{(1.25 - 1) + (1.25 - 0.9)}$$

$$M_0 = 88.33 \text{ DA}$$

La manière graphique : Reprenant l'exemple 3 précédent et traçant le graphique correspondant. Il s'agit d'une VSC, donc le graphique correspondant est un histogramme, comme suit :

Exemple 03 par la méthode graphique :**Exemple 02 par la méthode graphique :****Remarque :**

- Le mode satisfait aux 1ère, 3ème, 4ème conditions de Yule mais pas aux autres conditions.
- Son principal avantage est d'être déterminé très rapidement et sa signification est simple. On l'utilise surtout dans le cas des variables statistiques discrètes et pour faire apparaître facilement une première estimation de valeur centrale de la distribution.

- Une série statistique peut présenter un, deux ou plusieurs modes à la fois, comme elle peut ne pas présenter du tout ($n_i \neq \text{constante}$), on l'appelle alors une distribution ou série « amodale ».

Section II : La médiane « M_e »

II.1-Définition

Etymologiquement¹, médiane signifie « Milieu ». C'est le milieu de la distribution ordonnée. Notée « M_e », elle est la modalité (x_i) qui est située dans la série ordonnée de telle sorte que le nombre de modalités situées avant la médiane (ou inférieure à la médiane) est le même que celui des modalités situées après la médiane (ou supérieure à la médiane). Autrement dit, la médiane est la modalité qui partage l'effectif total des modalités en deux groupes de même taille (50% chacun).

C'est donc la valeur (x_i) pour laquelle 50% des individus présentent des modalités inférieures à M_e , et 50% des individus restant présentent des modalités supérieures à M_e . Les modalités étant, bien entendu, obligatoirement ordonnées par ordre croissant. La médiane est donc un paramètre de position.

II.2-Détermination pratique de la médiane :

La médiane se détermine de deux manières ; algébrique et graphique, et la détermination diffère selon qu'il s'agisse de VSD ou VSC.

2.1-Cas de la variable statistique discrète

2.1.1-Détermination de la médiane par la méthode algébrique

Dans ce cas la détermination de la médiane dépend du nombre d'individus (N). Avant de déterminer la médiane, les individus de la population doivent être rangés dans un ordre croissant ou décroissant.

2.1.1.1-Si N est un nombre impair

Donc $N = 2K+1$, la médiane correspond à la valeur de $K+1^{\text{ème}}$ observation (le rang de M_e est $K+1$).

Dans ce cas il existe une modalité, parmi toutes les modalités de la série, qui divise la série en deux groupes de même effectif ($N/2$). Cette modalité est la médiane. On la détermine comme suit :

N impair, ceci implique que mathématiquement N s'écrit : $N = 2k+1$.

¹ Du point de vue de l'origine ou des racines du mot.

NB/- k est un effectif cumulé croissant. Il donne la position (ou le numéro) de la médiane dans la série ordonnée.

Dans ce cas la médiane est la modalité correspondant à la position numéro $(k+1)^{\text{ème}}$. Il suffit alors de calculer k.

Exemple 01 :

Soit la série ordonnée suivante : 3 – 6 – 12 – 18 – 20 – 23 – 28. Déterminer la médiane. Il y a sept (7) modalités ou individus dans la série, soit $N=7$.

7 étant un nombre impair, il s'écrit donc $N = 2k+1 = 7 \longrightarrow k = N-1/2 = 3$

Donc la médiane est la modalité numéro $(k+1)^{\text{ème}}$, soit $3+1=4$ ou la $4^{\text{ème}}$.

Dans la série ordonnée, on constate que la $4^{\text{ème}}$ modalité c'est 18. Donc $Me = 18$.

Exemple 02 : Soit la série des notes suivantes : {14, 7, 10, 5, 9, 8, 11}

Ordonnons la série : { 5, 7, 8, 9, 10, 11, 14}

$N=7 \rightarrow N$ est impair $\rightarrow N = 2K+1 \rightarrow K = \frac{N-1}{2} = \frac{7-1}{2} \rightarrow K = 3$ et $K + 1 = 4$; M_e correspond à la valeur de la 4^{ème} observation, donc $M_e = 9$.

2.1.1.2-Si N est un nombre pair

Dans ce cas il existe non pas une modalité médiane mais un intervalle médian délimité par $[k^{\text{ème}}$ et $(k+1)^{\text{ème}}$] modalités .

Exemple 01 :

Soit la série ordonnée suivante : 3 – 6 – 12 – 18 – 20 – 23 – 28 - 30. Déterminer la médiane. Il y a sept (8) modalités ou individus dans la série, soit $N=8$.

8 étant un nombre pair, il s'écrit donc $N = 2k = 8 \rightarrow k = N/2 = 4 \rightarrow$ l'intervalle médian est délimité par la 4^{ème} et $(4+1=5^{\text{ème}})$ modalités.

La 4^{ème} correspond à la modalité 18, et la 5^{ème} modalité à 20. Donc l'intervalle médian est : $[18-20[$, soit $Me \approx (18+20/2)=19$

Exemple 02 : Soit la série des notes suivantes : { 5, 7, 8, 9, 10, 11, 12, 14}

$N=8 \rightarrow N$ est pair $\rightarrow N = 2K \rightarrow K = \frac{N}{2} = \frac{8}{2} \rightarrow K = 4$ et $K + 1 = 5$; $M_e \in [4^{\text{ème}}, 5^{\text{ème}}] \rightarrow M_e \in [9,$

$10[\rightarrow M_e = \frac{9+10}{2} = 9.5$

2.1.2-Determination de la médiane dans le tableau statistique

Dans ce cas où N est trop élevé, on a recours alors au tableau statistique, où la colonne (N_i) nous permet de repérer les positions des modalités qu'on cherche, en suivant la même logique. La médiane est déterminée à partir des $f_i^{\wedge}$ ou des $n_i^{\wedge}$. On choisit la valeur $f_i^{\wedge}$ égale ou immédiatement supérieure à 0.5, ou la valeur des $n_i^{\wedge}$ égale ou immédiatement supérieure à $(N/2)$. Après, on suit le sens des flèches comme indiqué dans les tableaux suivants :

Exemple 01 : Déterminer la médiane de la distribution suivante :

x_i	n_i	N_i
0	10	10
1	32	42
2	36	78
3	15	93
4	5	98
5	2	100
Total	100	-

Dans cet exemple on déterminera la médiane en utilisant directement la colonne des N_i . $N=100$, donc N est un nombre pair. Il existe donc un intervalle médian.

$N=2k \rightarrow k = 50$ et $(k+1) = 51$. $Me \in [50^{\text{ème}}; 51^{\text{ème}}[$ modalités. C'est-à-dire Me se situe à la position entre la 50^{ème} et la 51^{ème} modalités du tableau. K étant un effectif cumulé (N_i), on peut lire dans le tableau que la 50^{ème} et la 51^{ème} se situent entre les effectifs cumulés $N_2= 42$ et $N_3= 78$, c'est-à-dire entre la 42^{ème} et la 78^{ème} modalités. Or, d'après le tableau on peut lire que de la 43^{ème} jusqu'à

78^{ème} ce sont toutes des modalités égale à 2.

Autrement dit, les deux modalités que nous cherchons (la 50^{ème} et 51^{ème}) font partie de ces modalités puisqu'elles sont situées entre la 43^{ème} et 78^{ème} modalités. Donc notre intervalle médian est $[2 - 2]$, ce qui donne $Me = 2$. Ou bien de manière plus simple encore, il suffit de calculer $N/2$, celui-ci nous donne l'effectif cumulé ou la position de la modalité médiane. Si cette position se situe entre deux effectifs cumulés ou entre deux lignes de la colonne N_i , on prend directement la ligne du bas, c'est-à-dire la valeur immédiatement supérieure ou égale à $(N/2)$.

C'est ce même principe qu'on utilise pour la détermination graphique.

Exemple 02 : Soit le nombre d'erreurs d'assemblage sur un ensemble d'appareils


Nombre d'erreurs	Nombre d'appareils	f_i	$f_i^{\wedge}$	$n_i^{\wedge}$
0	20	0.1	0.1	20
1	65	0.325	0.425	85
2	← 70 ←	0.35	0.775	155
3	30	0.15	0.925	185
4	10	0.05	0.975	195
5	5	0.02	1	200
Σ	200	1	/	/

→ $N/2$ ou 0.5

$N=200$, $N/2 = 100$ (Le rang de la médiane est 100 ou 0.5) : la valeur des $n_i^{\wedge}$ qui est immédiatement supérieure à 100 est 155, et la fréquence cumulée croissante " $f_i^{\wedge}$ " immédiatement supérieure à 0.5 est 0.775, donc $M_e = 2$ erreurs.

Remarque : Dans un tableau statistique, on considère que N est très grand et qu'il est fort possible de tomber sur des valeurs K et $K+1$ qui soient identiques, donc le rang de la médiane est $N/2$ ou 0.5 dans les cas de N pair et de N impair.


2.1.3-Détermination de la médiane par la méthode graphique



Dans le cas d'une VSD, la fonction cumulative $\{x_i ; N_i\}$ ou $\{x_i ; F_i\}$ est représentée graphiquement par la courbe cumulative en escalier. La médiane se déterminant par les effectifs cumulés, elle est donc logiquement déterminée graphiquement par la courbe représentant ces derniers. On peut illustrer la méthode de détermination à partir de la courbe cumulative de l'exemple c1 précédent.

Sur l'axe vertical (axe des N_i ou F_i), repérer la valeur correspondant à $N/2$. On projette, ensuite, ce point à l'horizontal parallèlement à l'axe des X_i , sur la courbe en escaliers. La première contremarche sur laquelle on tombe est directement projetée par une ligne verticale sur l'axe des X_i , la valeur sur laquelle on tombe est la médiane.

NB/- Si on tombe sur un palier au lieu d'une contremarche, cela voudrait dire que nous avons à faire un intervalle médian délimité par deux valeurs différentes, ce qui n'est pas le cas de l'exemple 1c.



2.2- Variable statistique continue

Dans ce cas, les données sont présentées sous forme de classes, la modalité médiane appartient forcément à une classe, appelée intervalle ou classe médiane, à partir de laquelle il faudrait la déterminer.

Comme pour la VSD, la détermination de la médiane pour une VSC se fait également de deux manières possibles : algébrique et graphique.

2.2.1-De manière algébrique

La méthode se déroule suivant les trois étapes ci-après :

- Repérer dans la colonne des N_i ou F_i , la valeur ou la position $N/2$ ou $F_i = 0.5$ (soit 50%), notée « Th_2 ».
- Déterminer la classe correspondant à cette position, c'est-à-dire la classe médiane.
- Appliquer la formule de la médiane suivante :

$$M_e = x_0 + a_i \frac{N/2 - N_{me-1}}{n_{me}}$$

Ou bien :

$$M_e = x_0 + a_i \frac{0.5 - F_{me-1}}{f_{me}}$$

Avec :

- X_0 = borne inférieure de la classe médiane.
- a = amplitude de la classe médiane.
- $Th_i = \frac{N}{2}$ ou 0,5.
- N_{me} ou F_{me} = effectif ou fréquence cumulé correspondant à la classe médiane.
- N_{me-1} ou F_{me-1} = effectif ou fréquence cumulé correspondant à la classe avant la classe médiane.
- n_{me} ou f_{me} effectif absolu ou fréquence relative correspondant à la classe médiane.

Exemple 01 : Déterminer la médiane de la distribution suivante :

Classes	Effectifs
15 – 25	26
25 – 30	33
30 – 40	64
40 – 50	7
50 – 65	10

$Th_2 = N/2 = 140/2 = 70$,
cette valeur se trouve entre
les valeurs 59 et 123, c'est-
à-dire entre deux lignes,
dans la colonne des N_i , ce
qui implique qu'on prendra

Pour déterminer la médiane, on a besoin des effectifs ou fréquences cumulées. On construit la colonne N_i . Le tableau complet nécessaire sera comme suit (on ajoutera d'emblée la colonne $N_i^{\vee}$ décroissantes pour les besoin du graphique) :

Classes	X_i	n_i	N_i	$N_i^{\vee}$	f_i	$f_i^{\vee}$	$f_i^{\vee}$
[15 - 25[	20	26	26	140	0.19	0.19	1
[25 – 30[	27,5	33	59	114	0.24	0.43	0.81
[30 – 40[	35	64	123	81	0.46	0.89	0.57
[40 – 50[	45	7	130	17	0.05	0.94	0.11
[50 - 65[	57,5	10	140	10	0.07	1	0.05
Total	-	140	-	-			

directement la ligne du bas, soit celle correspondant à $N_i = 123$, la classe correspondante, soit $[30 - 40[$, est la classe médiane, $\rightarrow Me \in [30 - 40[$.

$$M_e = x_0 + a_i \frac{N/2 - N_{me-1}}{n_{me}} = 30 + 10 \left[\frac{70-59}{64} \right] = 31,72$$

$$\rightarrow Me = 31,72$$

Ou bien :

$$M_e = x_0 + a_i \frac{0.5 - F_{me-1}}{f_{me}} = 30 + 10 \frac{0.5 - 0.43}{0.46}$$

$$\rightarrow M_e = 31.72$$

Exemple 02 : Le tableau suivant donne le nombre de litres de carburant consommé par 80 véhicules d'une entreprise « X ».

Nombre de litres	n_i	f_i	F_i	N_i
[50-100[	16	0.2	0.2	16
[100-200[	48	0.6	0.8	64
[200-250[	08	0.1	0.9	72
[250-500[	04	0.05	0.95	76
[500-600[	04	0.05	1	80
Σ	80	/	/	/

$N/2 = 80/2 = 40$, 64 est l'effectif cumulé croissant qui est immédiatement supérieur à 40, donc la classe médiane est $[100-200[$.

$$M_e = x_0 + a_i \frac{N/2 - N_{me-1}}{n_{me}} = 100 + \left[100 \left[\frac{40-16}{48} \right] \right] = 150$$

$$\rightarrow Me = 150$$

Ou bien :

$$M_e = x_0 + a_i \frac{0.5 - F_{me-1}}{f_{me}} = 100 + \left[100 \frac{0.5 - 0.2}{0.6} \right]$$


$$\rightarrow M_e = 150$$

2.2.2-De manière graphique :

A partir des deux courbes cumulatives en « S », on détermine la médiane en projetant le point de rencontre des deux courbes sur l'axe horizontal. La valeur correspondante est la médiane.

Remarque :

Logiquement le point où se rencontrent les deux courbes est le point correspondant sur l'axe vertical à $N_i = N/2$ ou $F_i = 0,5$ (50%). Il a donc pour coordonnées $(x_i ; N_i) = (Me ; N/2)$.

**Remarque :**

- La médiane satisfait assez bien les conditions de YULE à l'exception de la 2^{ème} et 6^{ème} ; elle ne se prête pas aux calculs algébriques et ne dépend pas de toutes les valeurs.
- Elle n'est pas affectée par les valeurs extrêmes, puisqu'elle ne dépend des valeurs que par leur position (leurs effectifs cumulés).

Notes :

- Le mode intéresse la fonction de distribution ou la distribution des fréquences, soit les couples $\{x_i ; n_i\}$ ou $\{x_i ; f_i\}$, donc graphiquement il se détermine par le diagramme en bâtons pour la VSD et l'histogramme pour la VSC.
- La médiane intéresse la fonction cumulative ou la fonction de répartition, soit les couples $\{x_i ; N_i\}$ ou $\{x_i ; F_i\}$, donc logiquement elle se détermine par la courbe cumulative en escaliers pour la VSD et les deux courbes cumulatives en « S » pour la VSC.

2.3-Généralisation de la médiane : les quantiles

En suivant la même logique de définition que celle de la médiane, on peut déterminer d'autres paramètres de position qui permettent de partager une série statistique, non seulement en deux groupes de mêmes effectifs, mais aussi en quatre, dix, cents, ... ; groupes de mêmes effectifs. On appelle ces paramètres les « quantiles ».


Nous définissons dans ce cours les trois quantiles les plus usités, à savoir ; les *quartiles*, les *déciles* et les *centiles*.

2.3.1-Les quartiles :

Notés « Q_i », ce sont des paramètres de position et aussi des modalités x_i qui, par leurs positions (notées « Th_i », partagent la série statistique en quatre groupes de mêmes effectifs, soit 25% chacun. Ils sont donc au nombre de trois : $Q_1; Q_2; Q_3$.

- Q_1 , appelé *premier quartile*, est la modalité de la série par rapport à laquelle 25% des modalités y sont inférieures (à Q_1) et 75% restantes y sont supérieures (à Q_1).
- Q_2 , appelé aussi deuxième quartile, est la modalité x_i par rapport à laquelle 50% des modalités de la série y sont inférieures et 50% restantes y sont supérieures. Ce n'est donc rien d'autre que la médiane que nous avons déjà définie ($Q_2 = Me$).
- Q_3 , appelé également troisième quartile, est la modalité de la série par rapport à laquelle 75% des modalités y sont inférieures et 25% restantes y sont supérieures. Il est donc le contraire de Q_1 .

L'intervalle $[Q_1; Q_3[$, s'appelle **l'intervalle interquartile** et contient 50% des modalités centrales. On peut schématiser ces quartiles comme suit :



Formule : elle est très proche de celle de la médiane :

$$Q_i = x_0 + a_i \frac{iN/4 - N_{Q_{i-1}}}{n_{Q_i}}$$

Avec :


$TH_i = \frac{iN}{4} \rightarrow C'$ est l'effectif cumulé croissant repéré dans la colonne N_i du tableau.

2.3.2- Les déciles

Notés « D_i », ce sont des paramètres de position et aussi des modalités x_i qui partagent la série statistique en dix groupes de même effectif, soit 10% chacun. Ils sont donc au nombre de neuf (9) : $D_1; D_2 \dots \dots \dots ; D_9$.

- D_1 ; appelé premier décile, est la modalité x_i par rapport à laquelle 90% des valeurs y sont supérieures (à D_1), et les 10% restantes y sont inférieures.
- D_5 ; appelé aussi cinquième décile, est la modalité x_i par rapport à laquelle 50% des valeurs y sont supérieures (à D_5), et les 50% restantes y sont inférieures. Ce n'est donc rien d'autre que la médiane : $D_5 = M_e$.
- D_9 ; appelé neuvième décile, est le contraire de D_1 . C'est la modalité x_i par rapport à laquelle 90% des modalités y sont inférieures, et les 10% restantes y sont supérieures.

L'intervalle $[D_1 ; D_9]$ s'appelle intervalle inter-décile. Il contient 80% des modalités centrales. On peut schématiser ces déciles comme dans la page suivante:



Formule :

$$D_i = x_0 + a_i \frac{iN/10 - N_{D_{i-1}}}{n_{D_i}}$$

Avec :


$TH_i = \frac{iN}{10} \rightarrow$ C'est l'effectif cumulé croissant repéré dans la colonne N_i du tableau.

2.3.3- Les centiles :

Notés « C_i », ce sont des paramètres de position et aussi des modalités x_i qui partagent la série statistique en cent groupes de même effectif, soit 1% chacun. Ils sont donc au nombre de 99 : $C_1 ; C_2 ; C_3 ; C_{99}$.

- C_1 ; appelé premier centile, est la modalité x_i de la série par rapport à laquelle 1% des valeurs y sont inférieures (à C_1), et les 99% restantes y sont supérieures.
- C_{50} ; appelé aussi cinquantième centile, est la modalité de la série x_i par rapport à laquelle 50% des valeurs y sont supérieures (à C_{50}), et les 50% restantes y sont inférieures. Ce n'est donc rien d'autre que la médiane : $C_{50} = M_e$.
- C_{99} ; appelé quatre-vingt-dix neuvième décile, est le contraire de C_1 . C'est la modalité x_i par rapport à laquelle 99% des modalités y sont inférieures, et les 1% restantes y sont supérieures.

L'intervalle $[C_1 ; C_{99}]$ [s'appelle intervalle inter-centile. Il contient 98% des modalités centrales. On peut schématiser ces centiles comme suit :



Formule :

$$C_i = x_0 + a_i \frac{iN/100 - N_{C-1}}{n_{C_i}}$$

Avec :

$THi = \frac{iN}{100} \rightarrow$ C'est l'effectif cumulé croissant repéré dans la colonne N_i du tableau.

Rappel :

- $M_e = Q_2 = D_5 = C_{50}$.
- $Q_3 = C_{75}$

Section III : La moyenne arithmétique ($\bar{X}$)

III.1-Définition

La moyenne arithmétique, notée ($\bar{X}$) d'une variable statistique est égale à la somme des valeurs prises par cette variable, divisée par le nombre d'observations.

1.1-La moyenne arithmétique simple :

($\bar{X}$) est dite simple lorsqu'à chaque valeur x_i ne correspond qu'une seule observation (toutes les valeurs se répètent une seule fois).

Soient les valeurs suivantes : $\{x_1, x_2, \dots, x_k\}$.

$$(\bar{X}) = \frac{x_1 + x_2 + \dots + x_k}{N}$$

$$(\bar{X}) = \frac{1}{N} \sum x_i \text{ (i varie de 1 à k)}$$

Exemple : Soit le nombre d'appareils vendus par cinq magasins au cours d'une semaine $\{7, 8, 9, 11, 14\}$

$\bar{X} = 1/5 (7+8+9+11+14) = 9.8$ appareils.

1.2-La moyenne arithmétique pondérée

On dit qu'une moyenne arithmétique est pondérée lorsqu'à chaque valeur x_i peut correspondre plusieurs observations.

$$(\bar{X}) = \frac{x_1 n_1 + x_2 n_2 + \dots + x_k n_k}{N}$$

$$(\bar{X}) = \frac{1}{N} \sum x_i n_i \quad (i \text{ varie de } 1 \text{ à } k)$$

$$(\bar{X}) = \sum x_i f_i$$

$$(\bar{X}) = x_1 f_1 + x_2 f_2 + \dots + x_k f_k$$

Exemple : Reprenons l'exemple précédent (08 magasins) : {7, 7 8, 9, 10, 10, 11, 14}

$$\bar{X} = \frac{(7 \times 2) + (8 \times 1) + (9 \times 1) + (10 \times 2) + (11 \times 1) + (14 \times 1)}{8} = 9.5 \text{ appareil}$$

III.2-Cas de la variable statistique discrète

Exemple : soit le nombre d'erreurs d'assemblage sur un ensemble d'appareils

Nombre d'erreurs	Nombre d'appareils	$x_i n_i$	f_i	$x_i f_i$
0	20	00	0.053	00
1	65	65	0.171	0.171
2	140	280	0.368	0.736
3	90	270	0.237	0.711
4	40	160	0.105	0.42
5	25	125	0.066	0.33
Σ	380	900	1	2.368

$$\bar{X} = \frac{1}{N} \sum x_i n_i$$

$$\rightarrow \bar{X} = \frac{900}{380} = 2.368 \text{ erreur}$$

Ou bien :

$$\bar{X} = \sum x_i f_i$$

$$\rightarrow \bar{X} = 2.368 \text{ erreur}$$

III.3-Cas de la variable statistique continue

Les modalités sont regroupées en classes et par convention, c'est le centre de classe qui est considérée comme valeur de la variable x_i .

Exemple 01 : Soit la distribution des employés d'une entreprise « X » en fonction de leur prime de rendement.

Primes (DA)	n_i	x_i	$x_i n_i$
[800-1000[	26	900	23 400
[1000-1100[	33	1050	34 650
[1100-1200[	64	1150	73 600
[1200-1300[	07	1250	8 750
[1300-1500[	10	1400	14 000
Σ	140	/	154 400

$$\bar{X} = \frac{1}{N} \sum x_i n_i$$

$$\rightarrow \bar{X} = \frac{154\,400}{140}$$

$$\rightarrow \bar{X} = 1102.86 \text{ DA}$$

III.4-Les propriétés de la moyenne arithmétique

La moyenne arithmétique a les caractéristiques suivantes :

4.1-La somme des écarts à la moyenne est nulle : $\sum (x_i - \bar{x})n_i = 0$

4.2-La somme des carrés des écarts à la moyenne arithmétique est minimale : Ça se traduit par : $\sum n_i (x_i - a)^2$ est minimale pour $a = \bar{x}$.

4.3-Lorsque on ajoute ou l'on soustrait une quantité constante « a » aux valeurs de la variable x_i , la moyenne arithmétique de la série augmente ou diminue de la même quantité par la constante « a ».

$$x_i' = x_i + a \rightarrow \bar{x}' = \bar{x} + a$$

$$x_i' = x_i - a \rightarrow \bar{x}' = \bar{x} - a$$

4.4-Si on mélange deux populations de tailles respectives N_1 et N_2 , de moyennes respectives $\bar{X}_1$ et $\bar{X}_2$, la moyenne arithmétique de l'ensemble, notée $\bar{X}_t$ est : $\bar{X}_t = \frac{N_1 \bar{X}_1 + N_2 \bar{X}_2}{N_1 + N_2} \rightarrow \bar{X}_t = f_1 \bar{X}_1 + f_2 \bar{X}_2$

4.5-La méthode de changement de variable

De ces deux dernières propriétés découle la méthode de calcul de la moyenne arithmétique par changement de variable. Cette méthode permet de simplifier les calculs de $\bar{X}$.

On pose $x_i' = \frac{x_i - x_0}{a_i}$ avec x_0 centre de la classe modale et a_i amplitude de la classe modale. Ça donne $\bar{x}' = \frac{\bar{x} - x_0}{a_i} \rightarrow \bar{X} = a \bar{X}' + x_0$

Exemple : soit le tableau suivant

Primes (DA)	n_i	x_i	x_i'	$x_i' n_i$
800-1000	26	900	-2.5	-65
1000-1100	33	1050	-1	-33
1100-1200	64	1150	0	0
1200-1300	07	1250	1	7
1300-1500	10	1400	2.5	25
Σ	140	/	/	-66

La classe modale : 1100-1200, donc
a=100 et $x_0 = 1150$

$$\rightarrow \bar{X}' = \frac{\sum x_i' n_i}{N} = \frac{-66}{140} = -0.47$$

$$\rightarrow \bar{X} = a \bar{X}' + x_0 = 100(-0.47) + 1150 = 1102,86 \text{ DA}$$

III.5-Généralisation de la moyenne : calcul d'autres types de moyennes

5.1-La moyenne géométrique

5.1.1-Rappels sur les taux de croissance et les coefficients multiplicateurs

Une quantité (ou valeur) passe de V_0 (valeur initiale ou de départ) à V_t (valeur finale ou d'arrivée), on dit que sa variation absolue est $V_t - V_0$ et sa variation relative est $\frac{V_t - V_0}{V_0} = \frac{V_t}{V_0} - 1$.

Cette variation s'appelle taux de croissance.

- Si $\frac{V_t}{V_0} - 1$ donne une valeur positive, donc il s'agit d'une hausse.
- $\frac{V_t}{V_0} - 1$ donne une valeur négative, donc il s'agit d'une baisse.

Exemple 01 : Un capital passe de 2000 DA à 3500 DA entre les dates 0 et t.

- Sa variation absolue est de 1500 DA ($V_t - V_0 = 3500 - 2000$).
- Sa variation relative est de 75% ($\frac{V_t - V_0}{V_0} = \frac{3500 - 2000}{2000} \times 100$)

Exemple 02 : Un capital passe de 2000 DA à 1500 DA entre les dates 0 et t.

- Sa variation absolue est de - 500 DA ($V_t - V_0 = 1500 - 2000$).
- Sa variation relative est de -25% ($\frac{V_t - V_0}{V_0} = \frac{1500 - 2000}{2000} \times 100$)

Le ratio $\frac{V_t}{V_0}$ s'appelle un coefficient multiplicateur. Taux de croissance = $\frac{V_t}{V_0} - 1$

Et $\frac{V_t}{V_0} = \text{taux de croissance} + 1$

Reprenons l'exemple précédent :

- $\frac{V_t}{V_0} = \frac{3500}{2000} = 1,5$: la valeur d'origine a été multipliée par 1,5
- $\frac{V_t}{V_0} = \frac{1500}{2000} = 0,75$: la valeur d'origine est multipliée par 0,75.

5.1.2-Définition et application de la moyenne géométrique

C'est la moyenne applicable à des mesures de grandeurs dont la croissance est géométrique ou exponentielle.

La moyenne géométrique G de la série de valeurs : $x_1, x_2, \dots, x_k$ dont les modalités sont strictement toutes positives, est définie ainsi :

$$G = \sqrt[N]{x_1^{n_1} \times x_2^{n_2} \times \dots \times x_k^{n_k}} = \sqrt[N]{\prod x_i^{n_i}}$$

Exemple 01: soit les nombres suivants: 1, 2, 4, 4, 5, 6, 6 $\rightarrow G = \sqrt[7]{1 \times 2 \times 4^2 \times 5 \times 6^2} = \sqrt[7]{5760} = 3,445$

La moyenne géométrique est employée dans le calcul des taux de croissance moyens, ou des moyennes des coefficients multiplicateurs.

Exemple 02 : Supposons que pendant une décennie, les salaires ont cru de 50% et que pendant la décennie suivante, ils ont cru de 30%.

$$G = \sqrt[20]{(1 + 0,5)^{10} \times (1 + 0,3)^{10}} = \sqrt[20]{1,5^{10} \times 1,3^{10}} = 1,39645$$

$T_m = 1,39645 - 1 = 0,39645$ soit une augmentation de 39,645%

Exemple 03 : le prix d'un produit a cru de 15% au mois d'octobre, puis a baissé de 8% au mois de novembre et a continué de baissé en enregistrant le même taux au mois de décembre.

Soit T_m ce taux moyen. $T_m = G - 1$, avec G la moyenne géométrique des coefficients multiplicateurs.

$$G = \sqrt[3]{(1 + 0,15) \times (1 - 0,08)^2} = \sqrt[3]{1,15 \times 0,92^2} = 0,991$$

$T_m = 0,991 - 1 = -0,009$ soit une diminution de 0,9%

5.2-La moyenne harmonique

5.2.2-Définition

La moyenne harmonique d'une série statistique, notée H , est égale à l'inverse de la moyenne arithmétique des inverses des valeurs observés.

$$H = \frac{N}{\sum \frac{1}{x_i}} = \frac{n_1 + n_2 + \dots + n_k}{\frac{1}{x_1} + \frac{1}{x_2} + \dots + \frac{1}{x_k}} \text{ (Moyenne harmonique simple) Ou } H = \frac{N}{\sum \frac{n_i}{x_i}} = \frac{n_1 + n_2 + \dots + n_k}{\frac{n_1}{x_1} + \frac{n_2}{x_2} + \dots + \frac{n_k}{x_k}}$$

(moyenne harmonique pondérée).

Exemple 1 : On achète des dollars une première fois pour 200 € au cours de 1,22 € le dollar, une seconde fois pour 100 € au cours de 0,98 € le dollar. Le cours moyen du dollar pour

$$\text{l'ensemble de ces deux opérations est } H = \frac{N}{\sum \frac{1}{x_i}} = \frac{n_1 + n_2}{\frac{n_1}{x_1} + \frac{n_2}{x_2}} = \frac{200 + 100}{\frac{200}{1,22} + \frac{100}{0,98}} = \frac{300}{163,94 + 102,04} = 1,128€$$

Exemple 02 : Un atelier de reproduction a photocopie 1000 documents à la vitesse de 800 documents à l'heure et un autre atelier a photocopie 2000 documents à la vitesse de 700 documents à l'heure. Quelle est la vitesse moyenne pour photocopier les 3000 documents ?

$$\text{Vitesse moyenne} = \frac{\text{Nombre de documents total}}{\text{nombre heures}} = \frac{Q}{T} = \frac{Q_1 + Q_2}{T_1 + T_2} = \frac{Q_1 + Q_2}{\frac{Q_1}{V_1} + \frac{Q_2}{V_2}} = \frac{1000 + 2000}{\frac{1000}{800} + \frac{2000}{700}} = 730,46 \text{ documents}$$

à l'heure. On retrouve donc la formule de la moyenne harmonique.

Conclusion :

Le chapitre précédent nous a permis de comprendre comment faire la synthèse des données statistiques et comment les présenter de manière lisible et compréhensible par un large éventail de lecteurs. Cependant, la synthèse et la présentation des données statistiques ne s'arrête pas uniquement à ce qui est développé dans le précédent chapitre.

La présentation graphique a permis une première synthèse des informations contenues dans les tableaux statistiques mais pour approfondir l'analyse et rendre l'interprétation plus objective des informations recueillies, on a établi des mesures typiques qui résument la distribution statistique. Ainsi, l'ensemble des observations est réduit à une seule valeur numérique. Ces mesures sont appelées paramètres de tendance centrale ou paramètres de position.