

CHAPITRE 02 : PARAMÈTRES DE TENDANCE CENTRALE ET DE DISPERSION

INTRODUCTION

Après avoir appris comment représenter une série statistique à une seule dimension dans un tableau statistique et graphiquement, nous allons résumer et synthétiser cette série à l'aide des valeurs caractéristiques comme la moyenne, le mode, la médiane, écart-type...

Il existe 3 types de paramètres :

- Paramètres de position (ou de tendance centrale)
- Paramètres de dispersion
- Paramètres de forme (asymétrie, aplatissement, concentration)

SECTION 01 : PARAMÈTRES DE POSITION CENTRALE

I. MOYENNE ARITHMÉTIQUE

La moyenne \bar{x} ne se définit que pour une variable statistique quantitative. C'est le rapport de la somme des valeurs de la série statistique par l'effectif total N.

1. Cas d'une variable discrète ou caractère discret

Pour une variable statistique discrète X, on peut calculer la moyenne arithmétique simple ou pondérée. Pour les données détaillées, on calcule une **moyenne simple** est :

$$\bar{x} = \frac{\sum_{i=1}^N x_i}{N}$$

Avec :

$$N = \sum_{i=1}^N n_i$$

Pour les données agrégées et regroupées dans un tableau statistique, on calcule une **moyenne pondérée** est :

$$\bar{x} = \frac{\sum_{i=1}^k n_i x_i}{N}$$

Avec :

$$N = \sum_{i=1}^k n_i$$

Et

K : le nombre de modalités statistiques.

$$\bar{x} = \frac{\sum_{i=1}^k n_i x_i}{N}$$

$$\bar{x} = \sum_{i=1}^k f_i x_i$$

Puisque : $f_i = \frac{n_i}{N}$

Exemple : Répartition de 20 logements selon leur nombre de pièces

Nombre de pièces xi	nombre de logements ni	ni . xi
1	5	5
2	3	6
3	1	3
4	5	20
5	4	20
6	2	16
Total	20	66

$$\bar{x} = \frac{\sum_{i=1}^k x_i n_i}{N} = \frac{66}{20} = 3,3 \text{ pièces}$$

Le nombre moyen des pièces s'élève à 3,3 pièces.

2. Cas d'une variable continue ou caractère continu

Soit X une variable quantitative continue, ses valeurs sont incluses dans des classes $[e_i, e_{i+1}]$.

Pour pouvoir calculer la moyenne arithmétique, on doit calculer le centre de ces classes :

$$c_i = \frac{e_i + e_{i+1}}{2}$$

La moyenne est :

$$\bar{x} = \frac{\sum_{i=1}^k n_i c_i}{N}$$

K : est le nombre de classes.

$$f_i = \frac{n_i}{N}$$

On peut écrire : $\bar{x} = \sum_{i=1}^k f_i x_i$

Exemple : Répartition de 425 salariés, d'une entreprise Z, selon leurs salaires nets (en dollars américains) en 2010.

Montant du salaire (en dollars Américains) x_i	nombre de salariés n_i	Centre de classe c_i	$c_i n_i$
[750 - 1000 [150	875	131 250
[1000 - 1500 [100	1250	125 000
[1500- 2500 [99	2000	198 000
[2500 - 3000 [50	2750	137 500
[3000 - 5000 [26	4000	104 000
Total	425	---	695 750

Source : Réalisé par nos soins

$$c_1 = \frac{e_1 + e_2}{2} = \frac{750 + 1000}{2} = 875$$

$$\bar{x} = \frac{\sum_{i=1}^k n_i c_i}{N} = 695\ 750 / 425 = 1637,06 \text{ dollars.}$$

Le salaire moyen s'élève à 1637,06 dollars américains.

3. Changement de variable et calculs sur la moyenne arithmétique

Soit Y une nouvelle variable statistique et Y est une fonction de X.

$$Y = h(X) \text{ avec } h : \mathbb{R} \rightarrow \mathbb{R}$$

Les valeurs y_i sont en fonction de valeurs initiales x_i :

$$y_i = h(x_i)$$

$$y_i = \frac{x_i - x_0}{a}$$

Les effectifs n_i restent identiques (le même échantillon) que x_i pour tout $i=1,\dots,k$. On a :

$$\bar{y} = h(\bar{x}) \Leftrightarrow \bar{y} = \frac{\bar{x} - x_0}{a}$$

Démonstration :

$$\bar{y} = \frac{1}{N} \sum_{i=1}^k n_i y_i = \frac{1}{N} \sum_{i=1}^k n_i \left(\frac{x_i - x_0}{a} \right) = \frac{1}{aN} \left(\sum_{i=1}^k n_i x_i - x_0 \sum_{i=1}^k n_i \right)$$

$$\bar{y} = \frac{1}{aN} \left(\sum_{i=1}^k n_i x_i - x_0 N \right) = \frac{1}{a} (\bar{x} - x_0) = \frac{\bar{x} - x_0}{a}$$

Comment choisir a et x_0 ?

- ⊕ Cas discret : Pour x_0 , on choisit le mode ou la médiane et $a = 1$ si $X \in \mathbb{Z}$ sinon $a = PGCD(x_{i+1} - x_i)$ pour tout $i=1, \dots, k-1$.
- ⊕ Cas continu : x_0 est égal au centre de classe médiane et $a = PGCD(c_{i+1} - c_i)$ pour tout $i=1, \dots, k-1$.

Dans tous les cas, on y prend des petites valeurs en valeurs absolues ce qui nous facilitera les calculs.

4. Avantages et inconvénients de la moyenne

La moyenne arithmétique présente plusieurs avantages :

- ⊕ Elle est relativement facile à déterminer.
- ⊕ Son calcul fait intervenir toutes les observations.
- ⊕ Elle est unique car chaque série n'a qu'une et une seule moyenne.
- ⊕ Quand on dispose de plusieurs échantillons observant la même variable, il est possible de calculer une moyenne générale à partir des moyennes des différents échantillons (la moyenne des moyennes).

La moyenne arithmétique présente notamment des inconvénients :

- ⊕ Elle est sensible aux valeurs extrêmes, ce qui en fait un paramètre moins stable que la médiane.
- ⊕ Elle ne prend son sens que si elle est accompagnée d'une estimation de sa précision.

II. MÉDIANE

La médiane **Me** est telle que l'effectif des observations dont les modalités sont inférieures à **Me** est égal à l'effectif des observations dont les modalités sont supérieures à **Me**. Autrement dit, les valeurs étant rangées par ordre croissant, c'est la valeur de la variable qui sépare les observations en deux groupes d'effectifs égaux.

Cette définition n'a de sens que si les modalités sont toutes ordonnées.

1. Cas d'une variable discrète

Pour déterminer la médiane, on doit ranger la série statistique des N données par ordre croissant ou décroissant.

- Si la série est de taille N impaire, la médiane est de rang $\frac{N+1}{2}$ et la médiane est la valeur qui lui correspond.
- Si la série est de taille N paire, la médiane est la demi-somme des données de rang $\frac{N}{2}$ et $\frac{N}{2} + 1$.

Exemple 1 : Répartition des 9 personnes selon âge exact en années (N = 9).

10 11 8 9 15 17 7 14 13

Étape 1 : On classe les valeurs par ordre croissant : 7 8 9 10 11 13 14 15 17

Étape 02 : On cherche le rang de la médiane $\frac{N+1}{2} = 5$

Étape 03 : la valeur de la médiane est **Me = 11 ans**

Exemple 2 : Répartition 10 immeubles selon leurs nombre d'appartements (N =10) :

10 11 8 9 15 17 7 14 12 16

Étape 1 : On classe les valeurs par ordre croissant : 7 8 9 10 11 12 14 15 16 17

Étape 02 : On cherche le rang de la médiane $\frac{N}{2} = 5$ et $\frac{N}{2} + 1 = 6$

Étape 03 : la valeur de la médiane est **Me = (11 + 12)/2 = 11,5 appartements**

Remarque

On peut trouver la médiane Me à partir du diagramme cumulatif (des fréquences cumulées de la variable X). Puisque la médiane divise la série en deux parties égales donc $F(Me) = 0,5$. On repère la valeur 0,5 sur l'axe des ordonnées et on détermine le point A ayant les coordonnées $A(Me, F(Me))$. C'est aussi le point d'intersection entre F et G et

$$F(Me) = G(Me) = 0,5.$$

2. Le cas d'une variable continue

Pour une série regroupée en classes c'est-à-dire à caractère continu, la médiane correspond à la valeur du caractère ayant une fréquence cumulée croissante 0,5. La classe à laquelle appartient la médiane est appelée classe médiane.

Après avoir déterminé la classe médiane, on calcule la Me :


$$Me = (e_{i+1} - e_i) \cdot \frac{0.5 - F(e_i)}{F(e_{i+1}) - F(e_i)} + e_i$$

On peut aussi la calculer en utilisant les effectifs cumulés croissant :

La médiane correspond à la valeur du caractère ayant un effectif cumulé croissant $\frac{N}{2}$. La classe à laquelle appartient la médiane est appelée classe médiane.

Après avoir déterminé la classe médiane, on calcule la Me :

$$Me = (e_{i+1} - e_i) \cdot \frac{\frac{N}{2} - \vec{N}(e_i)}{\vec{N}(e_{i+1}) - \vec{N}(e_i)} + e_i$$



3. Avantages et inconvénients de la médiane

- Elle est facile à déterminer.
- Elle part du classement de toutes les observations, donc elle est représentative de l'ensemble.
- Elle est unique pour une série statistique.
- Elle est insensible aux valeurs extrêmes, ce qui en fait un paramètre remarquablement stable.

Elle présente un inconvénient : Lorsqu'on dispose de plusieurs échantillons qui observent la même variable, il n'est possible de calculer une médiane générale à partir des médianes partielles.

III. LE MODE STATISTIQUE

Le mode (Mo) d'une variable statistique est la modalité statistique x ayant le plus grand effectif ou la plus grande fréquence :

$$f(Mo) = \text{Max}(f_i); \quad i \in [1, k]$$


Ou bien

$$f(Mo) = \text{Max}(n_i); \quad i \in [1, k]$$

1. Le cas d'une variable discrète

Le mode est la valeur qui correspond au plus grand effectif.

Exemple : Répartition de 20 logements selon leur nombre de pièces



Source : Réalisé par nos soins

$M_o = 1$ pièce ; modalité à 5 logements .

$M_o = 5$ pièces ; modalité à 5 logements.

Remarque : On constate qu'une série statistique peut avoir plusieurs modes.

2. Le cas d'une variable continue

Pour une variable quantitative continue, on cherche d'abord la classe modale qui correspond à l'effectif le plus élevé (si les amplitudes sont égales) sinon la classe modale est celle qui correspond à la densité maximale.

Nous définissons le **mode**, pour une variable quantitative continue, en tenant compte des densités de fréquence des 2 classes adjacentes par la méthode ci-dessous.


Si les amplitudes des classes sont égales :

La classe modale $[e_i, e_{i+1}] = [x_i, x_{i+1}]$ étant déterminée, le mode M_o vérifie :

$$\frac{Mo - x_i}{\Delta_1} = \frac{x_{i+1} - Mo}{\Delta_2}$$

Dans une proportion, on ne change pas la valeur du rapport en additionnant les numérateurs et en additionnant les dénominateurs :

$$\frac{Mo - x_i}{\Delta_1} = \frac{x_{i+1} - Mo}{\Delta_2} = \frac{x_{i+1} - x_i}{\Delta_1 + \Delta_2}$$



$$\text{d'où : } Mo = x_i + \frac{\Delta_1}{\Delta_1 + \Delta_2} (x_{i+1} - x_i)$$

avec $(x_{i+1} - x_i)$ est l'amplitude de la classe modale.

$\Delta_1 = n_0 - n_{[x_{i-1}, x_i]}$ est la différence entre l'effectif de la classe modale et l'effectif de la classe qui la précède.

$\Delta_2 = n_0 - n_{[x_{i+1}, x_{i+2}]}$ est la différence entre l'effectif de la classe modale et l'effectif de la classe qui la suit :

$$Mo = x_i + \frac{n_0 - n_{[x_{i-1}, x_i]}}{2n_0 - n_{[x_{i-1}, x_i]} - n_{[x_{i+1}, x_{i+2}]}} (x_{i+1} - x_i)$$

Si les amplitudes des classes sont inégales :

Prenons l'exemple précédent de la répartition de 425 salariés, d'une entreprise Z, selon leurs salaires nets (en dollars américains) en 2010.

L'idée est d'utiliser **l'amplitude de base**, ici est **250** et le rapport de correction :

pour la première classe : $250*1 = 250$, rapport de correction est $1 = 250/250$

deuxième classe : $250*2 = 500$, rapport de correction est $2 = 500/250$

troisième classe : $250*4 = 1000$, rapport de correction est $4 = 1000/250$

....

Les rapports obtenus vont servir à corriger les effectifs (deuxième méthode de corriger les effectifs)

Montant du salaire (en dollars Américains) x_i	nombre de salariés n_i	amplitude a_i	Rapport de correction amplitude	Effectifs corrigés (2ème méthode)	Première méthode de correction n_i^c
[750 - 1000 [150	250	1	150	0.6
[1000 - 1500 [100	500	2	50	0.2
[1500 - 2500 [99	1000	4	24.75	0.099
[2500 - 3000 [50	500	2	25	0.1
[3000 - 5000 [26	2000	8	3.25	0.013
Total	425				

Source : Réalisé par nos soins

La classe modale est [750 , 1000[.

$$Mo = x_i + \frac{\Delta_1}{\Delta_1 + \Delta_2} (x_{i+1} - x_i)$$

$$Mo = 750 + \frac{150 - 0}{(150 - 0) + (150 - 50)} (1000 - 750)$$

$$Mo = 900 \text{ dollars américains}$$

Deuxième méthode avec les n_i^c

$$Mo = 750 + \frac{0.6 - 0}{(0.6 - 0) + (0.6 - 0.2)} (1000 - 750)$$

$$Mo = 900 \text{ dollars américains}$$

Le choix entre le mode, la moyenne et la médiane est fonction du type de distribution que l'on observe :

- Le mode fait apparaître le comportement le plus fréquent. Dans le cas d'une distribution fortement asymétrique, cette valeur peut être peu représentative du comportement de l'ensemble des observations effectuées.
- La moyenne donne la même importance à chaque observation. Elle est donc sensible aux observations extrêmes.
- La médiane, qui partage en deux la distribution, n'est pas sensible à l'importance de l'éloignement des données extrêmes. Elle est en ce sens plus robuste.


Remarques:

Il peut être intéressant de connaître ces trois indicateurs à la fois, car, ensemble, ils permettent déjà d'obtenir certaines précisions sur une distribution. En particulier, comme la moyenne est « tirée » vers les valeurs extrêmes, on sait que :

Si la moyenne est beaucoup plus basse que la médiane, quelques individus statistiques ont des valeurs de caractère beaucoup plus basses que l'ensemble des autres.

Si la moyenne est beaucoup plus haute que la médiane, quelques individus ont des valeurs de caractère beaucoup plus hautes que l'ensemble des autres.

- Si : $\bar{x} < Me < Mo$, la distribution est alors étalée à gauche (asymétrie positive).
- Si : $Mo < Me < \bar{x}$, la distribution est étalée à droite (asymétrie négative)
- Si $\bar{x} = Me = Mo$, la distribution est symétrique.



Source : <https://www.ecom-store.fr/469-panier-moyen-median-e-commerce/>

Remarque 4 :

Il existe une relation mathématique entre la moyenne arithmétique, le mode et la médiane.

$$Me - \bar{x} = (Mo - \bar{x})/3$$

III . AUTRES MOYENNES

1. Moyenne géométrique

À côté de la moyenne arithmétique que nous avons vue dans ce cours, il existe d'autres moyennes.

$$\text{Cas discret : } \bar{X}_g = \sqrt[N]{\prod_{i=1}^k x_i^{n_i}}$$

$$\bar{X}_g = \exp \left(\frac{\sum_{i=1}^k n_i \ln x_i}{N} \right)$$

$$\text{Cas continu : : } \bar{X}_g = \sqrt[N]{\prod_{i=1}^k c_i^{n_i}}$$

$$\text{Avec } N = \sum_{i=1}^k n_i$$

2. Moyenne harmonique

$$\text{Cas discret : } \bar{X}_H = \frac{1}{\frac{1}{N} \sum_{i=1}^k \frac{n_i}{x_i}} = \frac{N}{\sum_{i=1}^k \frac{n_i}{x_i}}$$

$$\text{d'où } \frac{1}{\bar{X}_H} = \frac{1}{N} \sum_{i=1}^k \frac{n_i}{x_i}$$

$$\text{Cas continu : } \frac{1}{\bar{X}_H} = \frac{1}{N} \sum_{i=1}^k \frac{n_i}{c_i}$$

3. Moyenne quadratique

La moyenne quadratique est une moyenne d'une série de valeurs, définie comme la racine de la moyenne des carrés des valeurs :

$$\bar{X}_q = \sqrt{\frac{1}{N} \sum_{i=1}^k n_i x_i^2}$$

4. Relation entre les différentes moyennes

Pour une variable statistique X, les différentes moyennes, harmonique, géométrique, arithmétique, quadratique, sont liées par la relation :

$$\overline{X_H} < \overline{X_g} < \bar{X} < \overline{X_q}$$

Il y a égalité si, et seulement si, toutes les valeurs de X sont égales.

La moyenne géométrique est bien adaptée à l'étude des phénomènes de croissance.

La moyenne harmonique est utilisée pour les calculs d'indices économiques.

SECTION 02 : PARAMÈTRES DE DISPERSION

I. POSITION DU PROBLÈME

Nous allons découvrir dans cette section les paramètres de dispersion qui complètent les paramètres de tendance centrale dans une analyse statistique. En effet, on peut trouver des séries ayant mêmes paramètres de tendance centrale et pourtant sont en réalité différentes. Soient 4 classes (C1, C2, C3 et C4) de 5 élèves répartis selon leurs âges.

classe	C1	C2	C3	C4
Age en années	16	14	12	08
	16	15	14	13
	16	16	16	16
	16	17	18	19
	16	18	20	24
Moyenne arith.	16	16	16	16
Médiane	16	16	16	16

Les quatre séries C1, C2, C3 et C4 ont même médiane et même moyenne arithmétique et pourtant sont différentes :

- ⊕ Il n'a pas de dispersion dans C1
- ⊕ Les valeurs sont plus proches dans C2 que dans C3
- ⊕ Il existe deux valeurs extrêmes dans C4.

Les paramètres de position caractérisent l'ordre de grandeur des observations alors que les paramètres de dispersion caractérisent l'étalement des valeurs autour d'un paramètre de position. Il est donc clair que les paramètres de position tels que la moyenne et la médiane ne suffisent pas pour décrire l'hétérogénéité de ces séries. Or, ce qui les distingue est l'étalement des âges observés. En d'autres termes, il nous manque un paramètre (ou des paramètres) pour caractériser la dispersion des observations autour d'un paramètre de position.

Définition de la dispersion : C'est la variabilité ou l'étendue des différentes valeurs que peut prendre une variable statistique. Si la différence entre les valeurs est grande, la dispersion est grande et si la différence entre les valeurs est petite, la dispersion est petite.

II ÉTENDUE STATISTIQUE

L'étendue statistique est le plus simple paramètre de dispersion, notée E. C'est la différence entre la valeur maximale et la valeur minimale du caractère statistique.

$$\text{Etendue} = x_{\max} - x_{\min}$$

Si l'étendue est petite cela signifie que les valeurs de la série statistique sont proches l'une de l'autre. Donc ces valeurs sont peu dispersées.

Exemple 1 :

B : 29 26 24 21 20 avec **E = 29 - 20 = 9**

C : 52 33 24 8 3 avec **E = 52 - 3 = 49**

Exemple 2 :

Montant du salaire (en dollars Américains) xi	nombre de salariés ni	amplitude ai
[750 - 1000 [150	250
[1000 - 1500 [100	500
[1500- 2500 [99	1000
[2500 - 3000 [50	500
[3000 - 5000 [26	2000
Total	425	

Source : Réalisé par nos soins

$$E = 5000 - 750 = 4250 \text{ dollars}$$

La différence entre le salaire minimum et le salaire le plus élevé est de 4 250 dollars.

III LES QUANTILES OU QUARTILES

Soit une série de N données, rangées par ordre croissant.

- Le premier quartile Q_1 est la plus petite valeur x de la série statistique telle qu'au moins un quart des données (25%) de la série soit inférieure ou égale à Q_1 .
- Le troisième quartile Q_3 est la plus petite valeur x de la série telle qu'au moins les trois quarts des données (75%) de la série sont inférieures ou égales à Q_3 .

Remarque : calcul pratique des quartiles pour une série à caractère discret.

- Pour Q_1 , on calcule $N/4$ puis on détermine le premier entier p supérieur ou égal à $N/4$, cet entier p est le rang de Q_1 que l'on peut alors déterminer.

- Pour Q_3 , on fait de même en remplaçant $N/4$ par $3N/4$.

Remarque : Pour le calcul des quartiles d'une série à caractère continu on utilisera le polygone des fréquences cumulées comme pour la médiane.

- Dans le cas du polygone des fréquences cumulées croissantes, le premier quartile est l'abscisse du point du polygone qui a pour ordonnée 0,25 et le troisième quartile est l'abscisse du point du polygone qui a pour ordonnée 0,75.

- Dans le cas du polygone des fréquences cumulées décroissantes le premier quartile est l'abscisse du point du polygone qui a pour ordonnée 0,75 et le troisième quartile est l'abscisse du point du polygone qui a pour ordonnée 0,25.

Exemple :

Cas discret :

C : 52 33 24 8 3

On range cette série par ordre croissant : 3 8 24 33 52

On a : $N = 5$ $N/4 = 1,25$ $3N/4 = 3,75$

Q_1 correspond à la valeur du rang $p \geq N/4$ donc 2 et $Q_1 = 8$

Q_3 correspond à la valeur du rang $p \geq 3N/4$ donc 4 et $Q_3 = 33$.

Cas continu :

On commence par déterminer la classe $[e_i, e_{i+1}]$ qui contient Q_1

$Q_1 \in [e_i, e_{i+1}]$, le rang de Q_1 est $\frac{N}{4}$ où $F(Q_1) = 0,25$

$F(e_i) \leq F(Q_1) < F(e_{i+1})$.

Puis on calcule Q_1 par la relation suivante d'une façon analogue au calcul de la médiane :

$$Q_1 = (e_{i+1} - e_i) \cdot \frac{0,25 - F(e_i)}{F(e_{i+1}) - F(e_i)} + e_i$$

Ou bien

$$Q_1 = (e_{i+1} - e_i) \cdot \frac{\frac{N}{4} - \vec{N}(e_i)}{\vec{N}(e_{i+1}) - \vec{N}(e_i)} + e_i$$

De la même façon, on calcule Q_3 est $3N/4$ où $F(Q_3) = 0.75$ et $F(e_i) \leq F(Q_3) < F(e_{i+1})$

Puis on calcul Q_3 par la relation suivante d'une façon analogue au calcul de la M_e :

$$Q_3 = (e_{i+1} - e_i) \cdot \frac{0.75 - F(e_i)}{F(e_{i+1}) - F(e_i)} + e_i$$

$$Q_3 = (e_{i+1} - e_i) \cdot \frac{\frac{3N}{4} - \vec{N}(e_i)}{\vec{N}(e_{i+1}) - \vec{N}(e_i)} + e_i$$


IV

L'ÉCART INTERQUARTILE OU L'INTERVALLE INTERQUARTILE

L'écart interquartile est la différence entre le troisième et le premier quartile.

$$IQ = Q_3 - Q_1$$

L'écart interquartile correspond à l'étendue de la série statistique après élimination de 25 % des valeurs les plus faibles et de 25 % des valeurs les plus fortes. Cette mesure est plus robuste que l'étendue, qui est sensible aux valeurs extrêmes.



V LA VARIANCE

L'utilisation des valeurs absolues est souvent une impasse en mathématique (parce que la fonction valeur absolue n'est pas dérivable). Pour rendre positifs les écarts, un autre outil est à notre disposition : la mise au carré. On ne va donc pas calculer la moyenne des écarts mais la moyenne des carrés des écarts. C'est ce qu'on appelle la variance :

- Cas d'un caractère discret :

$$V(X) = \frac{1}{N} \sum_{i=1}^k (x_i - \bar{x})^2 \quad \text{formule simple pour les données détaillées}$$

$V(X) = \frac{\sum_{i=1}^k n_i(x_i - \bar{x})^2}{N} = \sum_{i=1}^k f_i(x_i - \bar{x})^2$ formule pondérée pour les tableaux statistiques

- Cas d'un caractère **continu**

$$V(X) = \frac{1}{N} \sum_{i=1}^k (c_i - \bar{x})^2$$

$$V(X) = \frac{\sum_{i=1}^k n_i(c_i - \bar{x})^2}{\sum_{i=1}^k n_i} = \sum_{i=1}^k f_i(c_i - \bar{x})^2$$

La disparition des valeurs absolues permet des calculs plus simples. On démontre que la variance peut se calculer plus simplement par les formules suivantes :

- ⊕ Dans le cas d'une série **discrète** :

$$V(X) = \frac{1}{N} \sum_{i=1}^k x_i^2 - \bar{x}^2 \quad \text{formule simple}$$

$$V(X) = \frac{\sum_{i=1}^k n_i x_i^2}{N} - \bar{x}^2 = \sum_{i=1}^k f_i x_i^2 - \bar{x}^2 \quad \text{formule pondérée}$$

- ⊕ Dans le cas d'une série **continue** :

$$V = \frac{1}{N} \sum_{i=1}^k c_i^2 - \bar{x}^2$$

$$V = \frac{\sum_{i=1}^k n_i c_i^2}{N} - \bar{x}^2 = \sum_{i=1}^k f_i c_i^2 - \bar{x}^2$$

VI L'ÉCART TYPE

De par la mise au carré des écarts, l'unité de la variance est le carré de celle du caractère (si le caractère est en kg , sa moyenne est en kg mais sa variance est en kg^2) d'où l'impossibilité d'additionner la moyenne et la variance. On a donc défini l'écart type noté σ . L'écart type est la racine de la variance (son unité est donc la même que celle de la

moyenne). Cela a l'air anecdotique mais la possibilité d'additionner moyenne et écart type est fondamentale, en particulier pour le calcul d'intervalle de confiance (voir plus bas).

- Dans le cas d'une série **discrète** :

$$\sigma = \sqrt{\frac{\sum_{i=1}^k (x_i - \bar{x})^2}{N}}$$

$$\sigma = \sqrt{\frac{\sum_{i=1}^k n_i(x_i - \bar{x})^2}{\sum_{i=1}^k n_i}} = \sqrt{\sum_{i=1}^k f_i(x_i - \bar{x})^2}$$

- Dans le cas d'une série **continue** :

$$\sigma = \sqrt{\frac{\sum_{i=1}^k n_i(c_i - \bar{x})^2}{\sum_{i=1}^k n_i}} = \sqrt{\sum_{i=1}^k f_i(c_i - \bar{x})^2} \quad \text{et} \quad \sigma^2 = V$$

VII Le COEFFICIENT DE VARIATION

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

Pour comparer la dispersion de deux séries statistiques à caractère différents ('deux unités de mesure différentes), on utilise le CV qui ne possède pas d'unité de mesure.