

CHAPITRE 10 : STATISTIQUES

Dans tout ce chapitre, on considérera les 3 séries statistiques suivantes :

Série A :

Notes obtenues à un contrôle dans une classe de 30 élèves :

2 – 3 – 3 – 4 – 5 – 6 – 6 – 7 – 7 – 7 – 8 – 8 – 8 – 8 – 8 – 9 – 9 – 9 – 9 – 9 – 10 – 10 – 11 – 11 – 11 – 13 – 13 – 15 – 16

Série B :

Salaires en euros des employés d'une entreprise :

Salaires	[900; 1200[[1200; 1400[[1400; 1600[[1600; 1800[[1800; 2000[[2000; 2400[TOTAL
Effectif	30	30	60	80	40	40	280

Série C :

Proportion d'adhérents à un club sportif dans différentes sections :

- 17% jouent au handball,
- 25% jouent au rugby,
- 58% jouent au tennis.

I. Méthodes de représentation

1) Vocabulaire

La **population** est l'ensemble des individus sur lesquels portent l'étude statistique. (*Par exemple la section d'ECO1, la population féminine, les fonctionnaires ...*) dont chaque élément est appelé **individu**.

Un **échantillon** est une partie de la population considérée.

Le **caractère** (ou **variable**) d'une série statistique est une propriété étudiée sur chaque individu :

- ⇨ Lorsque le caractère ne prend que des valeurs (ou **modalités**) numériques, il est **quantitatif** :
 - ★ **discret** s'il ne peut prendre que des valeurs isolées (notes, âge ...)
 - ★ **continu** dans le cas contraire (*poids, taille ...*). Dans ce cas on effectue souvent un regroupement des valeurs par **classes**.
- ⇨ Sinon, on dit qu'il est **qualitatif** (*couleur des yeux, sport pratiqué ...*) : les modalités ne sont pas des nombres.

A chaque valeur (ou classe) est associée un **effectif** n : c'est le nombre d'individus associés à cette valeur.

2) Tableaux

Définition. On considère une série statistique X à caractère quantitatif, dont les p valeurs sont données par x_1, x_2, \dots, x_p d'effectifs associés n_1, n_2, \dots, n_p avec $n_1 + n_2 + \dots + n_p = N$.

- A chaque valeur (ou classe) est associée une fréquence f_i : c'est la proportion d'individus associés à cette valeur.
- $f_i = \frac{n_i}{N}$ est un nombre compris entre 0 et 1, que l'on peut écrire sous forme de pourcentage.
- L'ensemble des fréquences de toutes les valeurs du caractère s'appelle la distribution des fréquences de la série statistique.

Exemple 1. On peut représenter la **série A** par un tableau d'effectifs, et le compléter par la distribution des fréquences :

Notes	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19
Eff.	0	1	2	1	1	2	3	5	6	2	3	0	2	0	1	1	0	0	0
Fréq. en %	0	3	7	3	3	7	10	17	20	7	10	0	7	0	3	3	0	0	0

On peut aussi faire un regroupement par classe, ce qui rend l'étude moins précise, mais qui permet d'avoir une vision plus globale.

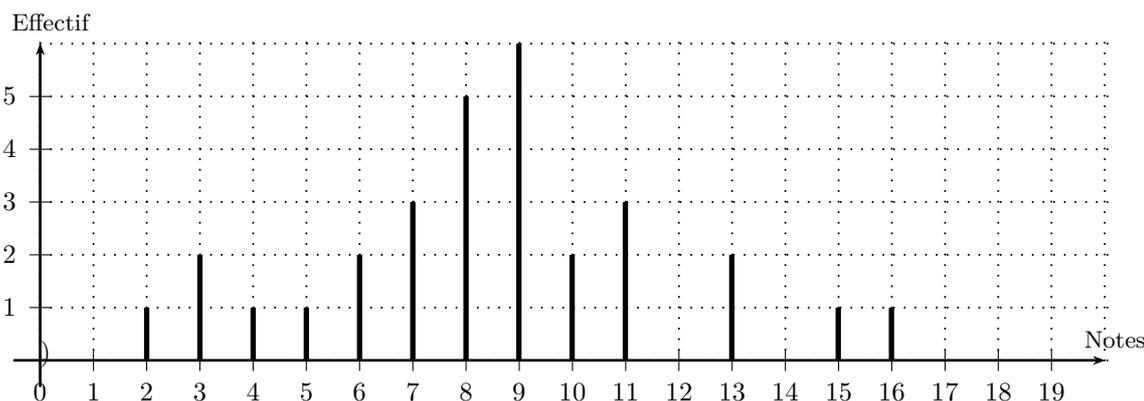
Exemple 2. Toujours pour la **série A**, si on regroupe les données par classes d'amplitude 5 points, on obtient :

Notes	[0 ; 5 [[5 ; 10 [[10 ; 15 [[15 ; 20 [total
Effectif	4	17	7	2	30
Fréquence	0,13	0,57	0,23	0,07	1

3) Graphiques

Lorsque le caractère étudié est **quantitatif et discret**, on peut représenter la série statistique étudiée par un **diagramme en bâtons** : la hauteur de chaque bâton est alors proportionnelle à l'effectif (ou à la fréquence) associé à chaque valeur.

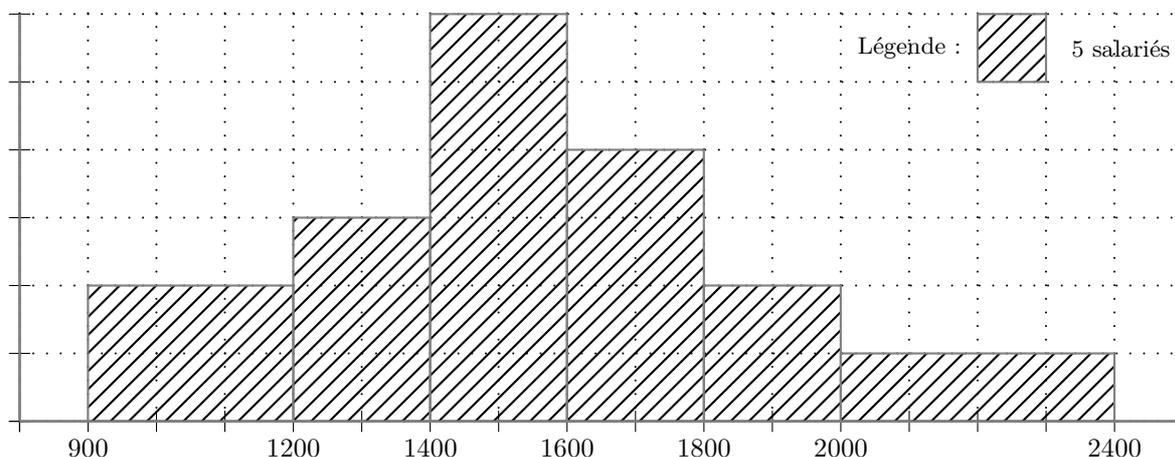
Exemple 3. Voici le diagramme en bâtons représentant la série des notes de la **série A** :



Lorsque le caractère étudié est **quantitatif et continu**, et lorsque les modalités sont regroupées en classes, on peut représenter la série par un **histogramme** : l'aire de chaque rectangle est alors proportionnelle à l'effectif (ou à la fréquence) associée à chaque classe.

Lorsque les classes ont la même **amplitude**, c'est la hauteur qui est proportionnelle à l'effectif.

Exemple 4. Pour la **série B**, on obtient par exemple l'histogramme suivant :



Lorsque le caractère est **qualitatif**, on peut représenter la série par :

• **Un diagramme circulaire** (« camemberts ») :

La mesure de chaque secteur angulaire est proportionnelle à l'effectif associé.

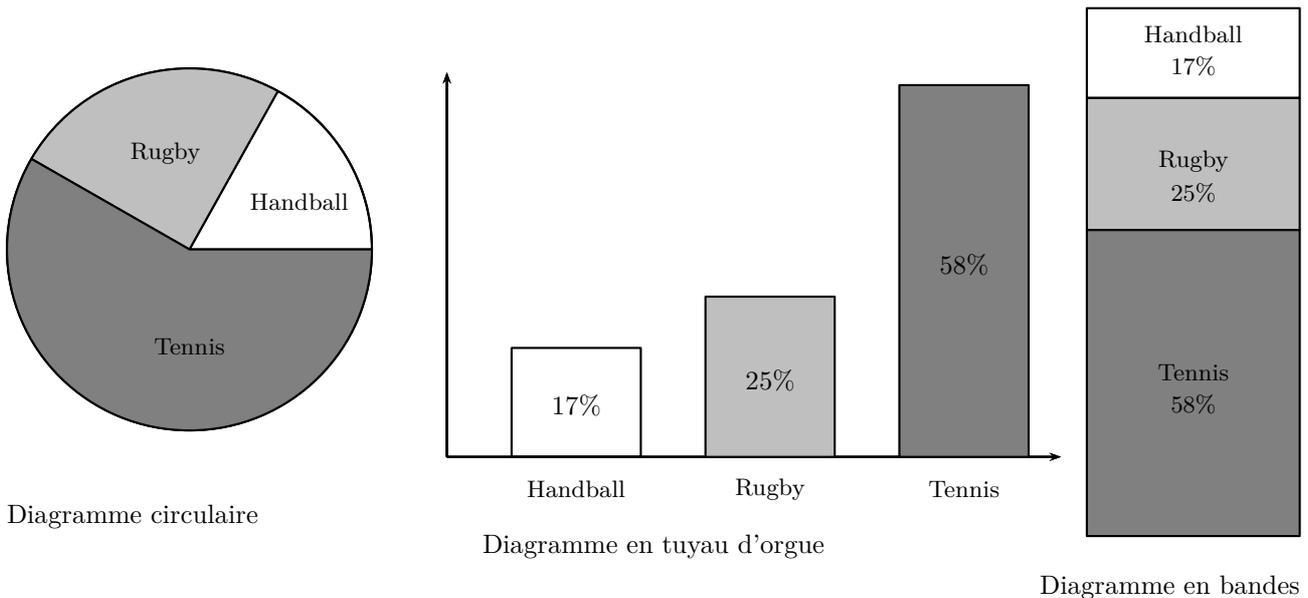
• **Un diagramme en tuyaux d'orgue** :

Chaque classe est représentée par un rectangle de même largeur et de longueur proportionnelle à l'effectif, donc à la fréquence.

• **un diagramme en bandes** :

Chaque classe est représentée par un rectangle de même largeur et de longueur proportionnelle à l'effectif, donc à la fréquence.

Exemple 5. Diagrammes de la **série C**



II. Caractéristiques de position

1) Moyenne

Définition. Soit une série statistique à caractère quantitatif, dont les p valeurs sont données par x_1, x_2, \dots, x_p d'effectifs associés n_1, n_2, \dots, n_p avec $n_1 + n_2 + \dots + n_p = N$.

La moyenne pondérée de cette série est le nombre noté \bar{x} qui vaut

$$\bar{x} = \frac{n_1x_1 + n_2x_2 + \dots + n_px_p}{n_1 + n_2 + \dots + n_p} = \frac{1}{N} \sum_{i=1}^p n_i x_i.$$

Remarque . Lorsque la série est regroupée en classes, on calcule la moyenne en prenant pour valeurs x_i le **centre de chaque classe** ; ce centre est obtenu en faisant la moyenne des deux extrémités de la classe.

Exemple 6. → Dans la **série A**, la moyenne du contrôle est égale à $\bar{m} = \frac{254}{30} \approx 8,47$.

→ Dans la **série B**, une estimation du salaire moyen est donné par : $\bar{S} = \frac{460500}{280} \approx 1644,64$.

Remarque . On peut aussi calculer une moyenne à partir de la distribution de fréquences :

$$\bar{x} = f_1x_1 + f_2x_2 + \dots + f_px_p = \sum_{i=1}^p f_i x_i.$$

Proposition 1. LINÉARITÉ DE LA MOYENNE

- ◆ Si on ajoute (ou soustrait) un même nombre k à toutes les valeurs d'une série, alors la moyenne de cette série se trouve augmentée (resp. diminuée) de k .
- ◆ Si on multiplie (ou divise) par un même nombre non nul k toutes les valeurs d'une série, alors la moyenne de cette série se trouve multipliée (resp. divisée) par k .

Exemple 7. On considère la **série A** :

- Si on ajoute 1,5 points à chaque note du contrôle, alors la moyenne de classe devient $\bar{m} = 8,47 + 1,5 = 9,97$.
- Si on augmente chaque note de 10%, cela revient à multiplier chaque note par 1,1, ce qui donne $\bar{m} = 8,47 \times 1,1 = 9,32$.

Proposition 2. MOYENNE PAR SOUS-GROUPES

Soit une série statistique, d'effectif total N , de moyenne \bar{x} .

Si on divise cette série en deux sous-groupes **disjoints** d'effectifs respectifs p et q (avec $p + q = N$) de moyennes respectives \bar{x}_1 et \bar{x}_2 , alors on a :

$$\bar{x} = \frac{p}{N} \times \bar{x}_1 + \frac{q}{N} \times \bar{x}_2.$$

Exemple 8. On suppose par exemple que les 12 garçons de la classe de la **série A** ont obtenu une moyenne globale de 8 sur 20.

- La moyenne du groupe formé par les filles de la classe vérifie : $9,47 = \frac{12}{30} \times 8 + \frac{18}{30} \times \bar{m}_f$.
- Soit $\bar{m}_f = \frac{30}{18} \left(9,47 - \frac{12}{30} \times 8 \right) = 10,45$.

2) Médiane

Définition. Soit une série statistique ordonnée dont les n valeurs sont $x_1 \leq x_2 \leq x_3 \leq \dots \leq x_n$.

La **médiane** est un nombre M qui permet de diviser cette série en deux sous-groupes de même effectif.

- ▶ Si n est impair, n est la valeur de cette série qui est située au milieu, à savoir la valeur dont le rang est $\frac{n+1}{2}$, notée $x_{\frac{n+1}{2}}$.
- ▶ Si n est pair, n est le centre l'intervalle médian, qui est l'intervalle formé par les deux nombres situés « au milieu » de la série, à savoir $x_{\frac{n}{2}}$ et $x_{\frac{n}{2}+1}$.

Exemple 9. → La médiane de la série « 2 – 5 – 6 – 8 – 9 – 9 – 10 » est 8.

- La médiane de la série « 2 – 5 – 6 – 8 – 9 – 9 » est 7.
- La médiane de la série « 2 – 5 – 6 – 6 – 9 – 10 » est 6.

Exemple 10. On souhaite calculer la médiane de la **série A**.

- Pour cela, on commence par remplir le tableau des effectifs cumulés croissants :

Notes	01	02	03	04	05	06	07	08	09	10	11	12	13	14	15	16	17	18	19	20
Eff.	0	1	2	1	1	2	3	5	6	2	3	0	2	0	1	1	0	0	0	0
ECC.	0	1	3	4	5	7	10	[15]	[21]	23	26	26	28	28	29	30	30	30	30	30

→ Ensuite, l'effectif étant de 30, on choisit la moyenne entre la 15^{ième} et la 16^{ième} note.

$$\text{On obtient } Med = \frac{8+9}{2} = 8,5.$$

→ Ce qui signifie que la moitié des notes est inférieure ou égale à 8,5, et que l'autre moitié des notes est supérieure ou égale à 8,5.

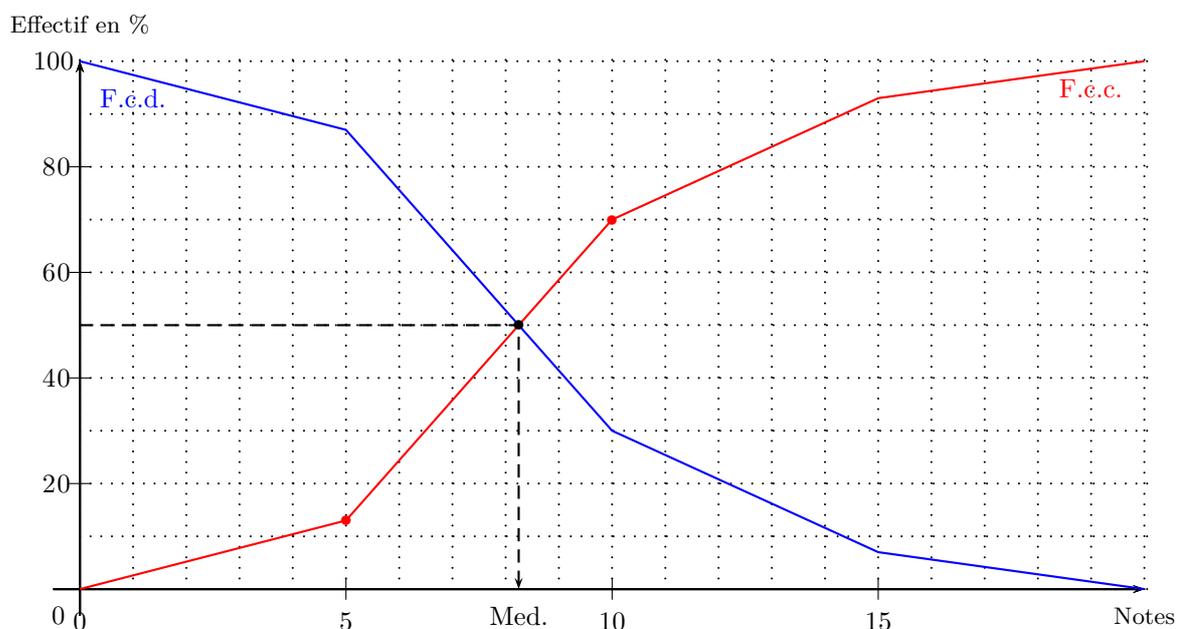
Dans le cas de répartition par classes, la médiane peut être évaluée soit graphiquement, soit par interpolation affine à l'aide d'un polygone des effectifs cumulés.

Exemple 11. On choisit la répartition par classes de la **série A** :

→ On crée le tableau des fréquences cumulées croissantes et décroissantes.

Notes	[0 ; 5 [[5 ; 10 [[10 ; 15 [[15 ; 20 [
Fréq. en %	13	57	23	7
F.c.c.	13	70	93	100
F.c.d.	87	43	7	0

→ Puis on place les points correspondants aux extrémités de chaque classe sur un graphique :



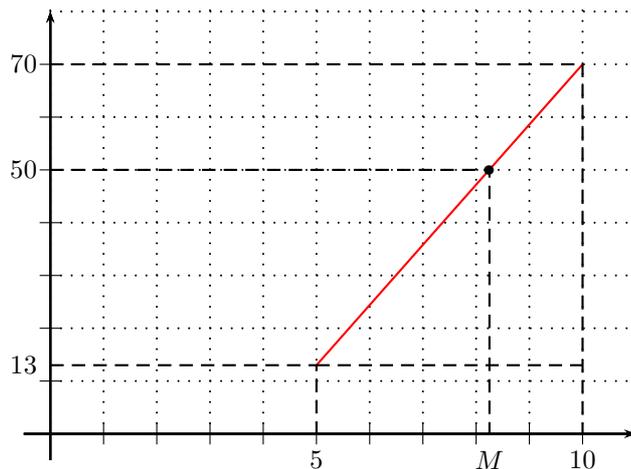
→ On détermine le point du polygone d'ordonnée 50% et on trouve environ 8,2.

→ Pour trouver la médiane, on peut utiliser le polygone des fréquences cumulées décroissantes et lire l'abscisse ou bien du point de concours des deux polygones. On trouve aussi 8,2.

→ Enfin, par le calcul, 50% se situe dans l'intervalle [5 ; 10 [.

On fait l'hypothèse que les longueurs des axes sont uniformément réparties dans cette classe.

On peut alors procéder à une interpolation linéaire d'après le théorème de Thalès :



$$\frac{M - 5}{10 - 5} = \frac{50 - 13}{70 - 13} \iff \frac{M - 5}{5} = \frac{37}{57} \iff M = 5 \times \frac{37}{57} + 5 = \frac{470}{57} \approx 8,25.$$

3) Quartiles, déciles ...

Définition. Soit une série statistique.

- On appelle quartiles de la série un triplet de réels ($Q_1 ; Q_2 ; Q_3$) qui sépare la série en quatre groupes de même effectif.
- On appelle déciles de la série un 9-uplet de réels ($D_1 ; D_2 ; \dots ; D_9$) qui sépare la série en dix groupes de même effectif.

Remarque . Par définition, si X est une série statistique, $Q_2 = D_5 = Med(X)$.

Le calcul des valeurs des quartiles ou des déciles se fait en général à partir des graphiques des effectifs (ou fréquences) cumulés croissants, par interpolation linéaire.

La calculatrice donne les valeurs de Q_1 , Med et Q_3 .

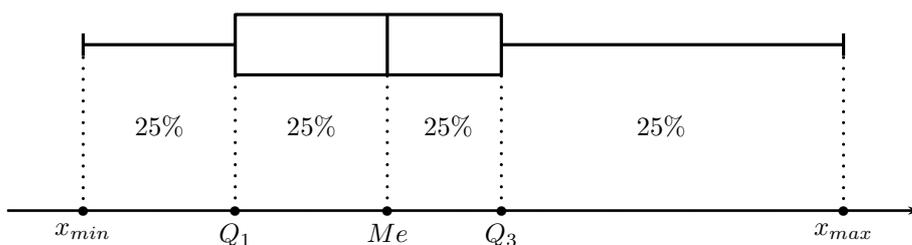
Exemple 12. ➔ Pour la **série A**, la calculatrice nous donne $Q_1 = 7$, $Med = 8,5$ et $Q_3 = 10$.

➔ Graphiquement, on trouve $D_1 \approx 3,8$ et $D_9 \approx 14,2$.

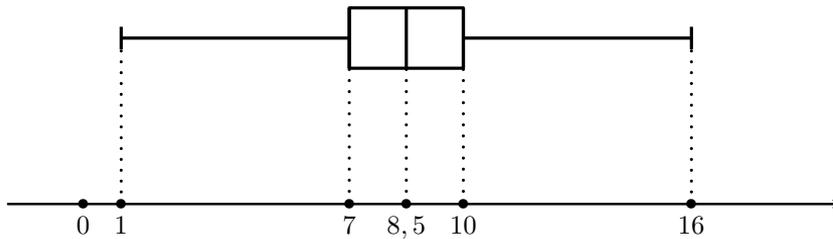
➔ Pour la **série B**, on trouve $Q_1 = 1500$, $Med = 1700$ et $Q_3 = 1900$.

4) Diagramme en boîtes :

Le diagramme en boîte affiche les quartiles et les valeurs extrémales comme suit :



Exemple 13. Pour la **série A** on obtient :



III. Caractéristiques de dispersion

1) Étendue

Il s'agit de la première mesure de la dispersion d'une série statistique. Son principal mérite a longtemps été d'exister, et de fournir une information sur la dispersion très simple à obtenir.

Définition. Soit X une série statistique discrète. On appelle étendue de la série le réel, défini par $Etd(X) = \max(X) - \min(X)$.

Exemple 14. L'étendue de la **série A** est de $16 - 2 = 14$.

2) Intervalle interquartile

Définition. On appelle intervalle inter-quartiles l'intervalle $[Q_1 ; Q_3]$. L'amplitude de cet intervalle est appelée écart inter-quartiles.

Exemple 15. → Dans la **série A**, l'intervalle interquartile est l'intervalle $[7 ; 10]$ dont l'écart vaut $10 - 7 = 3$.

→ Cet intervalle comprend donc la moitié des notes de la série située au centre de celle-ci.

3) Variance d'une série statistique

Définition. La variance d'une série statistique est le nombre noté $V(x)$ obtenu comme moyenne des carrés des écarts constatés par rapport à la moyenne de la série :

$$V(X) = \frac{n_1(x_1 - \bar{x})^2 + n_2(x_2 - \bar{x})^2 + \dots + n_p(x_p - \bar{x})^2}{n_1 + n_2 + \dots + n_p} = \frac{1}{N} \sum_{i=1}^p n_i(x_i - \bar{x})^2.$$

Remarque . Cette formule s'applique bien sûr au cas d'une série statistique sans coefficients : on est ramené à une série pour laquelle tous les coefficients valent 1.

Exemple 16. La variance de la **série B** vaut :

$$V(X) = \frac{30(1050 - 1645)^2 + 30(1300 - 1645)^2 + \dots + 40(2200 - 1645)^2}{280} \approx 109346.$$

Proposition 3.

On utilise aussi la formule :

$$V(X) = \frac{1}{N} \sum_{i=1}^p n_i x_i^2 - \bar{x}^2.$$

4) Écart-type d'une série statistique

Définition. L'écart-type d'une série statistique X , noté $\sigma(X)$, est la racine carrée de la variance de cette série :

$$\sigma(X) = \sqrt{V(X)}.$$

Exemple 17. L'écart-type de la **série B** vaut : $\sigma(X) = \sqrt{109561} = 331$.

Proposition 4.

La variance et l'écart-type présentent les propriétés suivantes :

- ◆ La variance et l'écart-type sont des nombres positifs ou nuls,
- ◆ Une variance nulle ou un écart-type nul signifient que toutes les valeurs de la série son égales à sa moyenne,
- ◆ Plus la variance (ou l'écart-type) d'une série est grande, plus cette série est dispersée autour de sa moyenne,