

Statistiques descriptives

Variance et écart type

I) Rappel : la moyenne (caractéristique de position)

1) Définition

Soit la série statistique définie dans le tableau suivant :

Valeur	x_1	x_2	x_p
Effectif	n_1	n_2	n_p
Fréquences	f_1	f_2		f_p

Effectif total : $N = n_1 + n_2 + \dots + n_p$ et $f_i = \frac{n_i}{N}$

La **moyenne** de cette série statistique est le réel, noté \bar{x} , tel que :

$$\bar{x} = \frac{n_1x_1 + n_2x_2 + \dots + n_px_p}{N}$$

ou en utilisant les fréquences :

$$\bar{x} = f_1x_1 + f_2x_2 + \dots + f_px_p$$

Exemple 1: Soit la série statistique répertoriant la taille en mètres de 100 requins blancs

taille (en m)	1,5	2	2,5	3	3,5	4	4,5
Effectif	8	10	25	32	19	4	2

La taille moyenne est :

$$\bar{x} = \frac{1,5 \times 8 + 2 \times 10 + 2,5 \times 25 + 3 \times 32 + 3,5 \times 19 + 4 \times 4 + 4,5 \times 2}{100} = 2,82$$

Exemple 2 :

Un supermarché a relevé les dépenses (en €) de ses clients en 2 heures un jour donné, les résultats sont rassemblés dans le tableau suivant :

Dépenses (en €)	[0 ; 30 [[30 ; 60 [[60 ; 100 [[100 ; 120 [
Milieu de classe	15	45	80	110
Effectif	12	25	42	67

Pour calculer la moyenne on détermine les milieux des classes de la distribution puis on

$$\text{effectue le calcul : } \bar{x} = \frac{15 \times 12 + 45 \times 25 + 80 \times 42 + 110 \times 67}{146} \approx 82,43 \text{ €}$$

(146 est l'effectif total)

Exemple 3 :

On étudie dans une maternité la taille de 50 nouveaux nés

Taille en cm	47	48	49	50	51	52
Effectif	5	8	12	15	9	1
Fréquence	0,1	0,16	0,24	0,3	0,18	0,02

$$\bar{x} = 0,1 \times 47 + 0,16 \times 48 + 0,24 \times 49 + 0,3 \times 50 + 0,18 \times 51 + 0,02 \times 52 = 49,36$$

2) Propriété 1

Si on ajoute le même nombre k à toutes les valeurs de la série statistique, la moyenne augmente de k

Exemple :

Dans l'exemple précédent on pourrait soustraire 50 à toutes les tailles on obtiendrait une nouvelle moyenne :

$$\bar{y} = 0,1 \times (-3) + 0,16 \times (-2) + 0,24 \times (-1) + 0,3 \times 0 + 0,18 \times 1 + 0,02 \times 2 = -0,64$$

et on retrouve \bar{x} en rajoutant 50 à \bar{y} : $\bar{x} = -0,64 + 50 = 49,36$

3) Propriété 2

Si on multiplie toutes les valeurs de la série statistique par un même nombre k , la moyenne est multipliée par k

Exemple :

En étudiant maintenant la masse de 50 nouveaux nés de la maternité on obtient :

Masse en kg	2,8	2,9	3	3,1	3,2
Effectif	14	10	18	7	1

On peut multiplier les masses par 10 on calcule ainsi une moyenne \bar{y} :

$$\bar{y} = \frac{28 \times 14 + 29 \times 10 + 30 \times 18 + 31 \times 7 + 32 \times 1}{50} = 29,42$$

et on retrouve la moyenne en divisant \bar{y} par 10 : $\bar{x} = \frac{29,42}{10} = 2,942$

II) Variance et écart type (caractéristique de dispersion)

1) Définition

Soit la série statistique définie dans le tableau suivant :

Valeur	x_1	x_2	x_p
Effectif	n_1	n_2	n_p
Fréquences	f_1	f_2		f_p

Effectif total : $N = n_1 + n_2 + \dots + n_p$ et $f_i = \frac{n_i}{N}$

Soit \bar{x} la moyenne de cette série .

Le réel $V = \frac{1}{N} [n_1(x_1 - \bar{x})^2 + n_2(x_2 - \bar{x})^2 + \dots + n_i(x_i - \bar{x})^2 + \dots + n_p(x_p - \bar{x})^2]$ est appelé **variance** de cette série statistique.

La racine carrée de la variance $\sigma = \sqrt{V}$ est l'**écart type** de cette série.

La **variance** et l'**écart type** permettent de mesurer la « **dispersion** » des valeurs de la série autour de la moyenne.

Si les valeurs de la série possèdent une unité, l'écart type s'exprime dans la même unité.

Autre formule pour calculer la variance :

$$V = \frac{1}{N} [n_1x_1^2 + n_2x_2^2 + \dots + n_ix_i^2 + \dots + n_px_p^2] - (\bar{x})^2$$

Exemple :

Démonstration :

En reprenant la formule de définition :

$$V = \frac{1}{N} [n_1(x_1 - \bar{x})^2 + n_2(x_2 - \bar{x})^2 + \dots + n_i(x_i - \bar{x})^2 + \dots + n_p(x_p - \bar{x})^2]$$

En développant les carrés

$$V = \frac{1}{N} [n_1(x_1^2 - 2x_1\bar{x} + (\bar{x})^2) + n_2(x_2^2 - 2x_2\bar{x} + (\bar{x})^2) + \dots + n_i(x_i^2 - 2x_i\bar{x} + (\bar{x})^2) + \dots + n_p(x_p^2 - 2x_p\bar{x} + (\bar{x})^2)]$$

En regroupant les termes

$$V = \frac{1}{N} [n_1x_1^2 + n_2x_2^2 + \dots + n_ix_i^2 + \dots + n_px_p^2] - 2\bar{x} \left[\frac{1}{N} (n_1x_1 + n_2x_2 + \dots + n_ix_i + \dots + n_px_p) \right] + \bar{x}^2 \left[\frac{1}{N} (n_1 + n_2 + \dots + n_i + \dots + n_p) \right]$$

En simplifiant

$$V = \frac{1}{N} [n_1 x_1^2 + n_2 x_2^2 + \dots + n_i x_i^2 + \dots + n_p x_p^2] - 2\bar{x} \bar{x} + \bar{x}^2$$

D'où le résultat $V = \frac{1}{N} [n_1 x_1^2 + n_2 x_2^2 + \dots + n_i x_i^2 + \dots + n_p x_p^2] - (\bar{x})^2$

Exemples : Calculs de la variance et de l'écart type des séries précédentes

1°) Soit la série statistique répertoriant la taille en mètres de 100 requins blancs

taille (en m)	1,5	2	2,5	3	3,5	4	4,5
Effectif	8	10	25	32	19	4	2

La taille moyenne est :

$$\bar{x} = \frac{1,5 \times 8 + 2 \times 10 + 2,5 \times 25 + 3 \times 32 + 3,5 \times 19 + 4 \times 4 + 4,5 \times 2}{100} = 2,82$$

La variance $V = \frac{1,5^2 \times 8 + 2^2 \times 10 + 2,5^2 \times 25 + 3^2 \times 32 + 3,5^2 \times 19 + 4^2 \times 4 + 4,5^2 \times 2}{100} - 2,82^2$

(on utilise la deuxième formule)

$V = 8,395 - 7,9524 = 0,4426$ et $\sigma = \sqrt{0,4426} \approx 0,665$ m

2°) On étudie dans une maternité la taille de 50 nouveaux nés

Taille en cm	47	48	49	50	51	52
Effectif	5	8	12	15	9	1
Fréquence	0,1	0,16	0,24	0,3	0,18	0,02

$$\bar{x} = 0,1 \times 47 + 0,16 \times 48 + 0,24 \times 49 + 0,3 \times 50 + 0,18 \times 51 + 0,02 \times 52 = 49,36$$

• Disposition pratique de calcul de la variance et de l'écart type (avec la formule de la définition)

Taille en cm (x_i)	Effectifs (n_i)	$(x_i - \bar{x})^2$	$n_i(x_i - \bar{x})^2$
47	5	$(47 - 49,36)^2 = 5,5696$	$5 \times 5,5696 = 27,848$
48	8	$(48 - 49,36)^2 = 1,8496$	$8 \times 1,8496 = 14,7968$
49	12	$(49 - 49,36)^2 = 0,1296$	$12 \times 0,1296 = 1,5552$
50	15	$(50 - 49,36)^2 = 0,4096$	$15 \times 0,4096 = 6,144$
51	9	$(51 - 49,36)^2 = 2,6896$	$9 \times 2,6896 = 24,2064$
52	1	$(52 - 49,36)^2 = 6,9696$	$1 \times 6,9696 = 6,9696$
Sommes	50		81,52

$V = \frac{81,52}{50} = 1,6304$ et $\sigma = \sqrt{V} \approx 1,277$ cm

- Disposition pratique de calcul de la variance et de l'écart type (avec la deuxième formule)

Taille en cm (x_i)	Effectifs (n_i)	x_i^2	$n_i x_i^2$
47	5	$47^2 = 2\ 209$	$5 * 2\ 209 = 11\ 045$
48	8	$48^2 = 2\ 304$	$8 * 2\ 304 = 18\ 432$
49	12	$49^2 = 2\ 401$	$12 * 2\ 401 = 28\ 812$
50	15	$50^2 = 2\ 500$	$15 * 2\ 500 = 37\ 500$
51	9	$51^2 = 2\ 601$	$9 * 2\ 601 = 23\ 409$
52	1	$52^2 = 2\ 704$	$1 * 2\ 704 = 2\ 704$
Sommes	50		121 902

$$V = \frac{121\ 902}{50} - 49,36^2 = 1,6304 \quad \text{et} \quad \sigma = \sqrt{V} \approx 1,277 \text{ cm}$$

2) Propriété 1

Si on ajoute le même nombre k à toutes les valeurs de la série statistique, la variance et l'écart type ne changent pas

Exemple :

Dans l'exemple précédent on pourrait soustraire 50 à toutes les tailles on obtiendrait une nouvelle moyenne :

$$\bar{y} = 0,1 \times (-3) + 0,16 \times (-2) + 0,24 \times (-1) + 0,3 \times 0 + 0,18 \times 1 + 0,02 \times 2 = -0,64$$

$$\text{On aurait ainsi } V = \frac{5(-3)^2 + 8(-2)^2 + 12(-1)^2 + 15(0)^2 + 9(1)^2 + 1(2)^2}{50} - (-0,64)^2 = 2,04 - 0,4096$$

$$V = 1,6304$$

3) Propriété 2

Si on multiplie toutes les valeurs de la série statistique par un même nombre k , la variance est multipliée par k^2 et l'écart type est multiplié par $|k|$

Exemple :

En étudiant maintenant la masse de 50 nouveaux nés de la maternité on obtient :

Masse en kg	2,8	2,9	3	3,1	3,2
Effectif	14	10	18	7	1

On peut multiplier les masses par 10 on calcule ainsi une moyenne \bar{y} :

$$\bar{y} = \frac{28 \times 14 + 29 \times 10 + 30 \times 18 + 31 \times 7 + 32 \times 1}{50} = 29,42$$

et on retrouve la moyenne en divisant \bar{y} par 10 : $\bar{x} = \frac{29,42}{10} = 2,942$

Pour la variance le calcul avec les masses données par le tableau donne

$$V = \frac{2,8^2 \times 14 + 2,9^2 \times 10 + 3^2 \times 18 + 3,1^2 \times 7 + 3,2^2 \times 1}{50} - 2,942^2 = 0,012036$$

et $\sigma = \sqrt{0,012036} \approx 0,11$

En multipliant les masses par 10 on trouve :

$$V_1 = \frac{28^2 \times 14 + 29^2 \times 10 + 30^2 \times 18 + 31^2 \times 7 + 32^2 \times 1}{50} - 29,42^2 = 1,2036 \text{ soit } 100 \times V$$

et bien sûr $\sigma_1 = \sqrt{V_1} \approx 1,1$ soit $10 \times \sigma$