

# Chapitre : Statistiques



⊗ **Activité** : Rappels et tests page 126

## I. Diagrammes en boîte

---

**Rappel** On considère une série statistique.

- Le **premier quartile**, noté  $Q_1$ , est la plus petite valeur de la série telle qu'au moins 25% des valeurs lui soient inférieures ou égales.
- Le **troisième quartile**, noté  $Q_3$ , est la plus petite valeur de la série telle qu'au moins 75% des valeurs lui soient inférieures ou égales.
- La **médiane**, notée  $Me$ , est la plus petite valeur de la série telle qu'au moins 50% des valeurs lui soient inférieures ou égales.
- On appelle intervalle interquartile l'intervalle  $[Q_1; Q_3]$ .
- On appelle écart interquartile le nombre  $Q_3 - Q_1$ .

**Exemple** Soit le tableau statistique suivant :


Valeurs	3	5	6	8	11	12	15
f.c.c. (en %)	7	23	36	52	72	84	100

Où f.c.c. est la fréquence cumulée croissante ; On peut aussi utiliser les effectifs cumulés croissants (e.c.c.).

Alors :

- $Me = 8$  (première valeur pour laquelle la fréquence cumulée dépasse 50%)
- $Q_1 = 6$  (première valeur pour laquelle la fréquence cumulée dépasse 25%)
- $Q_3 = 12$  (première valeur pour laquelle la fréquence cumulée dépasse 75%)

On peut représenter une série statistique à une variable par un **diagramme en boîte** de la manière suivante, en reprenant les valeurs de l'exemple plus haut :



 La droite est graduée. En particulier, il faut respecter une échelle choisie au départ. Ne pas oublier non plus de donner un titre à l'axe.

**Remarque** On peut alors lire dans ce diagramme plusieurs zones de valeurs correspondant à 25% de la population, ou à 50% de la population (à mettre en évidence sur le diagramme).

**Méthode** Voir page 136 pour l'utilisation de la calculatrice

► Exercices : 30 à 37p139

► Exercice : 39p139 (lecture de diagrammes et détermination de valeurs)

► Exercice : (en DM?) 62p147, 65p148

## II. Variance et écart-type

---

⊗ **Activité** : page 127

**Définition** Soit la série statistique suivante :

Valeurs	$x_1$	$x_2$	...	$x_p$
Effectifs	$n_1$	$n_2$	...	$n_p$

On note  $N$  l'effectif total ( $N = n_1 + n_2 + \dots + n_p$ ).

On rappelle que la moyenne, notée ici  $\bar{x}$ , est donnée par :

$$\bar{x} = \frac{n_1 \times x_1 + n_2 \times x_2 + \dots + n_p \times x_p}{N}$$

La **variance**  $V$  de la série est la moyenne des carrés des écarts entre les valeurs et la moyenne :

$$V = \frac{n_1 \times (x_1 - \bar{x})^2 + n_2 \times (x_2 - \bar{x})^2 + \dots + n_p \times (x_p - \bar{x})^2}{N}$$

**Remarque** La variance est toujours un nombre positif.

Cet indicateur statistique permet d'évaluer les écarts des valeurs autour de la moyenne.

Plus les écarts à la moyenne sont grands, plus la variance est grande, et réciproquement.

**Définition** La variance  $V$  étant positive, on appelle **écart-type** le nombre  $\sigma = \sqrt{V}$ .

**Exemple** Soit la série statistique suivante :

Valeurs	1	4	6
Effectifs	2	1	3

L'effectif total est  $N = 2 + 1 + 3 = 6$ .

La moyenne est  $\bar{x} = \frac{2 \times 1 + 1 \times 4 + 3 \times 6}{6} = \frac{24}{6} = 4$ .

La variance est alors  $V = \frac{2 \times (1 - 4)^2 + 1 \times (4 - 4)^2 + 3 \times (6 - 4)^2}{6} = \frac{2 \times 9 + 3 \times 4}{6} = \frac{30}{6} = 5$ .

Enfin l'écart-type est  $\sigma = \sqrt{V} = \sqrt{5}$ .

► Exercices : 19 à 22p138

► Exercices : 26 à 28p138 (Formule de König)

★ **Approfondissement** : 40,41,42p140, 48p142, 49p143

# III. Échantillonnage

---

## 1. Intervalle de fluctuation

**Voir :** cours page 184 (rappel de seconde et représentation de la loi binomiale)

**Définition** On s'intéresse à un caractère de proportion  $p$  dans une population.

On prélève un échantillon aléatoire de taille  $n$  et on considère la variable aléatoire  $X$ , nombre d'individus de cet échantillon ayant ce caractère. La variable aléatoire  $X$  suit la loi binomiale  $\mathcal{B}(n; p)$ .

On appelle intervalle de fluctuation au seuil de confiance 95% de la fréquence l'intervalle  $\left[ \frac{a}{n}; \frac{b}{n} \right]$  où :

- $a$  est le plus petit entier tel que  $\mathbb{P}(X \leq a) > 0,025$  ;
- $b$  est le plus petit entier tel que  $\mathbb{P}(X \leq b) \geq 0,975$ .

Il faut retenir que la probabilité que la fréquence observée pour un échantillon (autrement dit la valeur observée de  $X$  divisée par  $n$ ) a une probabilité au moins égale à 0,95 d'appartenir à cet intervalle.

On obtient les valeurs de  $a$  et de  $b$  à l'aide de la calculatrice :

**Casio :** InvBinomCD(k,n,p) où l'on remplace  $k$  par 0,025 puis par 0,975 ;

**TI :** On peut afficher le tableau des valeurs des  $\mathbb{P}(X \leq k)$  en définissant la fonction :

Y1=binomFRep(n,p,X)

Puis l'on cherche les valeurs de  $X$  qui font dépasser 0,025 puis 0,975.

**Exemple** Pour  $n = 100$  et  $p = 0,5$ , on trouve  $a = 40$  et  $b = 60$ .

L'intervalle de fluctuation au seuil de confiance 95% est donc  $\left[ \frac{40}{100}; \frac{60}{100} \right]$  soit  $[0,4; 0,6]$ .

**Remarque** Il s'agit d'un intervalle de fréquences, les valeurs sont donc nécessairement comprises entre 0 et 1.

► **Exercices :** exercice 37p192 (voir exercice corrigé Ep191), 120,121,124pp208-209

## 2. Prise de décision

**On fait l'hypothèse** que la proportion d'un caractère étudié dans une population est  $p$ .

Pour vérifier cette hypothèse on prélève un échantillon de taille  $n$ .

Une fois l'échantillon prélevé on observe une fréquence  $f$  d'apparition du caractère étudié dans l'échantillon. D'après la section précédente, la probabilité que  $f$  appartienne à l'intervalle de fluctuation au seuil 95% est de 0,95. Par conséquent on utilise la règle de décision suivante :

- Si  $f$  appartient à l'intervalle de fluctuation, l'hypothèse selon laquelle la proportion est  $p$  dans la population est validée.
- Si  $f$  n'appartient pas à l'intervalle de fluctuation, l'hypothèse est rejetée. Il y a alors un risque d'erreur de 5%.

**Exemple** Comme dans l'exemple précédent on suppose que  $p = 0,5$  et  $n = 100$ . Supposons maintenant que dans un échantillon de 100 individus, 36 individus aient le caractère étudié.

Alors  $f = \frac{36}{100} = 0,36$ .

On rappelle que l'intervalle de fluctuation au seuil de confiance 95% est  $I = [0,4; 0,6]$ .

On observe que  $f \notin I$ , donc on rejette l'hypothèse que la proportion  $p$  soit égale à 0,5 dans la population.

**Remarque** En seconde on a déjà vu un intervalle de fluctuation. La formule était la suivante :  $\left[ p - \frac{1}{\sqrt{n}}; p + \frac{1}{\sqrt{n}} \right]$ .

Cet intervalle est proche de celui de première, mais moins précis. De plus il son utilisation est soumise à des conditions portant sur  $n$  et  $p$  : il faut que  $n \geq 25$  et  $0,2 \leq p \leq 0,8$ .

L'intervalle de première n'est soumis à aucune condition, par contre sa détermination est techniquement plus difficile (bien que ça devienne moins vrai avec les calculatrices actuelles).

► **Exercices :** 132 à 137pp211-212