



## Chapitre 3 Statistiques

### Table des matières

<b>1</b>	<b>Indicateurs de position</b>	<b>2</b>
1.1	Moyenne . . . . .	2
1.2	Médiane . . . . .	2
1.3	Quartiles . . . . .	3
1.4	Valeur minimale et maximale . . . . .	3
<b>2</b>	<b>Indicateurs de dispersion</b>	<b>3</b>
2.1	Étendue . . . . .	3
2.2	Écart interquartile . . . . .	3
2.3	Écart-type . . . . .	4
<b>3</b>	<b>Échantillonnage</b>	<b>4</b>

Dans l'ensemble de ce cours, on considère l'exemple de la série statistiques suivante, donnant les distances des planètes du système solaire au Soleil :

Planète	Distance au soleil en millions de km
Mercuré	58
Vénus	108
Terre	150
Mars	228
Jupiter	778
Saturne	1429
Uranus	2871
Neptune	4503

## 1 Indicateurs de position

### 1.1 Moyenne

#### Définition 1

La **moyenne** d'une série statistique  $x_1, x_2, \dots, x_n$  se note  $\bar{x}$  et est donné par la formule suivante :

$$\bar{x} = \frac{x_1 + x_2 + \dots + x_n}{n}$$

#### Exemple.

En moyenne, la distance d'une planète du système solaire au Soleil est d'environ 1266 millions de km.

$$\bar{x} = \frac{58 + 108 + 150 + 228 + 778 + 1429 + 2871 + 4503}{8} \simeq 1266$$

### 1.2 Médiane

#### Définition 2

La **médiane** d'une série statistique  $x_1, x_2, \dots, x_n$  est une valeur qui permet de couper l'ensemble des valeurs en deux parties égales : la moitié des valeurs étant plus grande que la médiane et l'autre moitié étant moins grande.

#### Remarque.

- Lorsque la série comprend un nombre impair de valeurs, la médiane est simplement une des valeurs de la série.
- Lorsque la série comprend un nombre pair de valeurs, la médiane est la moyenne entre les deux valeurs du « milieu ».

#### Exemple.

Dans le cas des distances planète-Soleil, la médiane est la moyenne entre la 4<sup>e</sup> et la 5<sup>e</sup> plus grande valeur étant donné que la série comporte 8 valeurs.

$$m = \frac{228 + 778}{2} = 503 \text{ millions de km}$$



## 1.3 Quartiles

### Définition 3

- Le **premier quartile** d'une série statistique est une valeur, notée  $Q_1$  telle qu'au moins 25% des valeurs soient plus petites que  $Q_1$ .
- Le **troisième quartile** d'une série statistique est une valeur, notée  $Q_3$  telle qu'au moins 75% des valeurs soient plus petites que  $Q_3$ .

### Exemple.

Dans le cas des distances planète-Soleil,

$Q_1$  correspond à la deuxième valeur (car  $8 \times \frac{1}{4} = 2$ ) et  $Q_3$  correspond à la sixième valeur (car  $8 \times \frac{3}{4} = 6$ ).

$$Q_1 = 108 \quad \text{et} \quad Q_3 = 1429$$

### Remarque.

L'intervalle interquartile est l'intervalle  $[Q_1; Q_3]$ . Il contient donc 50% des valeurs de la série statistique.

## 1.4 Valeur minimale et maximale

### Définition 4

La **valeur minimale** d'une série statistique est la plus petite valeur de la série. la **valeur maximale** est la plus grande valeur de la série.

### Exemple.

Dans le cas des distances planète-Soleil, la valeur minimale est 58 et la valeur maximale est 4503.

## 2 Indicateurs de dispersion

### 2.1 Étendue

#### Définition 5

L'**étendue** d'une série statistique est la différence entre la valeur maximale et la valeur minimale.

### Exemple.

Dans le cas des distances planète-Soleil, l'étendue est de  $4503 - 58 = 4445$  millions de km.

### 2.2 Écart interquartile

#### Définition 6

L'**écart interquartile** est  $Q_3 - Q_1$ .

### Exemple.

Dans le cas des distances planète-Soleil, l'écart interquartile est  $1429 - 108 = 1321$  millions de km.



## 2.3 Écart-type

### Définition 7

- La **variance**  $V$  d'une série statistique  $x_1, x_2, \dots, x_n$  est définie par :

$$V = \frac{(x_1 - \bar{x})^2 + (x_2 - \bar{x})^2 + \dots + (x_n - \bar{x})^2}{n}$$

- L'**écart type**  $\sigma$  d'une série statistique est définie par :

$$\sigma = \sqrt{V}$$

### Remarque.

On retiendra que la variance est « la moyenne des carrés des écarts à la moyenne »

### Exemple.

Dans le cas des distances planète-Soleil, on a  $\bar{x} = 1266$ . Ainsi,

$$V = \frac{(58 - 1266)^2 + (108 - 1266)^2 + (150 - 1266)^2 + \dots + (4503 - 1266)^2}{8} \simeq 2304324$$

$$\sigma = \sqrt{V} \simeq 1518$$

### Remarque.

La donnée de la médiane et de l'écart interquartile n'est pas sensible aux valeurs extrêmes, contrairement à la donnée de la moyenne et de l'écart-type.

## 3 Échantillonnage

### Proposition 1 – (admise)

Si l'effectif d'une série statistique est suffisamment grand, et si le phénomène étudié suit une loi de Gauss (la répartition des valeurs se fait selon une courbe en cloche) :

- L'intervalle  $[\bar{x} - \sigma ; \bar{x} + \sigma]$  contient environ 68% des valeurs.
- L'intervalle  $[\bar{x} - 2\sigma ; \bar{x} + 2\sigma]$  contient environ 95% des valeurs.
- L'intervalle  $[\bar{x} - 3\sigma ; \bar{x} + 3\sigma]$  contient environ 99% des valeurs.

### Exemples.

Les phénomènes suivants suivent une loi de Gauss :

- Pourcentage de Pile obtenus lors du lancer de 50 pièces ;
- La taille des femmes dans la population française ;
- Le nombre de votants par bureau de vote lors d'une élection ;
- La taille des tiges des coquelicots dans un champ ;
- Les notes d'une évaluation.

Ainsi, si la moyenne a une évaluation est  $\bar{x} = 10$  et l'écart-type est  $\sigma = 3$ , cela signifie qu'environ 68% des notes sont comprises entre 7 et 13.



**Proposition 2 – Loi des Grands Nombres (admise)**

On répète  $n$  fois une même expérience aléatoire de façon indépendante et dont la probabilité de succès est  $p$ . Expérimentalement, plus  $n$  sera grand, plus la fréquence du succès se rapprochera de  $p$ . De plus, on peut considérer que la fréquence de succès suit une loi de Gauss et on a :

$$\sigma \simeq \sqrt{\frac{p(1-p)}{n}}.$$

**Remarque.**

En général, lorsque  $n \geq 25$ , on considère que  $n$  est suffisamment grand pour utiliser la loi des Grands Nombres.

**Exemple.**

On lance 200 fois un dé équilibré à six faces et on compte le nombre de 6 obtenus. Déterminer avec une marge d'erreur de 5%, un intervalle contenant la fréquence de 6 obtenus.

Solution :

Les lancers étant indépendants les uns des autres, on peut utiliser la loi des Grands Nombres.

On a  $p = \frac{1}{6}$  donc :

$$\sigma \simeq \sqrt{\frac{\frac{1}{6}(1 - \frac{1}{6})}{200}} \simeq 0,0264.$$

Par conséquent, cela signifie que l'intervalle suivant contient 95% des fréquences expérimentales :

$$[p - 2\sigma ; p + 2\sigma] \simeq \left[ \frac{1}{6} - 2 \times 0,0264 ; \frac{1}{6} + 2 \times 0,0264 \right] \simeq [0,114 ; 0,219].$$

Autrement dit, avec une marge d'erreur de 5%, l'intervalle  $[0,114 ; 0,219]$  contient la fréquence de 6 obtenus.

**Savoir-faire du chapitre**

- Connaître et savoir calculer les différents indicateurs de position (moyenne, médiane, quartiles, valeur minimale et maximale).
- Connaître et savoir calculer les différents indicateurs de dispersion (étendue, écart interquartile, écart-type).
- Comparer des séries statistiques en utilisant des indicateurs pertinents.

