



Les statistiques

Chapitre 8

À quoi ça sert???


- ❖ Parce que nous avons besoin de renseignements pour surveiller les changements importants et les répercussions que ces changements ont sur chacun d'entre nous.
- ❖ Les statistiques fiables nous aident à faire face aux nombreux défis que notre monde doit relever. Nos gouvernements, nos entreprises et nos collectivités ont absolument besoin des renseignements statistiques pour prendre des décisions éclairées.

On les utilise...

- ❖ Pour comprendre la situation de votre pays, évaluer le rendement des gouvernements
- ❖ Syndicats utilisent les statistiques sur la moyenne des salaires versés
- ❖ Environnement: gaz à effet de serre
- ❖ Enseignants suivent les statistiques pour dégager les nouvelles tendances
- ❖ Vérifier les rendements à la bourse...

Nombre

Répartition des joueurs de basket selon leur grandeur



grandeur

L' **histogramme** permet de **représenter** des données groupées en **classes**.

TABLEAUX

Le **tableau** de données condensées est **utilisé** pour représenter une distribution qui comporte un grand nombre de données ayant tendance à de **répéter**.

L' **effectif** de chaque modalité ou valeur correspond au nombre de fois qu'elle apparaît dans la **distribution**.

Tableaux de données condensées

Nombre d'employés	Effectif
3	4
4	7
5	5
6	3
7	4
8	2
TOTAL	25

Le tableau de données groupées en classes est utilisé pour représenter une distribution qui comporte un grand nombre de données ayant tendance à ne pas se répéter.

Toutes les classes du tableau ont la même amplitude.

L'effectif de chaque classe correspond au nombre de données que cette classe comprend.

Participants à un sondage

Âge	Effectif
[15,20[17
[20,25[25
[25,30[34
[30,35[45
[35,40[41
[40,45[32
TOTAL	194

Mesures de tendance centrale

MESURE	DÉFINITION	TYPES DE DISTRIBUTIONS	
		DONNÉES CONDENSÉES	DONNÉES GROUPEES EN CLASSE
MODE	Valeur de la variable la plus fréquente	Modalité dont l'effectif est le plus élevé	Milieu de la classe modale dont l'effectif est le plus élevé
MÉDIANE	Le centre de position d'une distribution	Donnée du centre si impair, moyenne des deux si pair	Milieu de la classe médiane
MOYENNE	Centre d'équilibre d'une distribution	somme des produits divisée par effectif	somme des produits par leurs effectifs

EXEMPLE

Dans un processus d'embauche pour un poste dans la fonction publique fédérale, on veut garder ceux qui ont obtenu les meilleurs résultats, en %, parmi les suivants:

62 64 65 65 66 68 69 72 75 78 **79 79 81 82 82 84 85 86 87 89**

Dans le but de diminuer significativement la taille du groupe, on décide d'éliminer la moitié des candidats. Pour établir la note minimale de sélection, on utilise alors la médiane qui sera 78,5 (donnée entre 78 et 79).

Mode: donnée la plus populaire: 65, 79 et 82

Moyenne: $62+64+65+65+66+68+69+72+75+78+79+79+81+82+82+84+85+86+87+89 = 1518$ divisé par 20 = 75,9

MESURES DE DISPERSION

L' **étendue** est l' **écart** de l'échantillon. Il suffit de déterminer la valeur **maximale** et la valeur **minimale**.

$$E = x_{\max} - x_{\min}$$

DIAGRAMME DE QUARTILES

Une mesure de quartile permet d'établir la position d'une donnée par rapport aux autres _____ de la série.

Les quartiles (Q_1 , Q_2 , Q_3) sont des mesures de répartition qui divisent une série de «n» (nombre de données) données ordonnées en quatre ensembles renfermant le même nombre de donnée.

Q2: médiane


Q1: premier quartile

Q3: troisième quartile

Le diagramme de quartiles permet d'analyser la dispersion de l'étendue des données d'une distribution.

Exemple: Déterminer les quartiles de cette distribution:
60,32,87,98,56,75,35,68,86,90,75,59,61,84,64,48

- ❖ 1. Placer en ordre croissant: 32,35,48,56,59,60,61,64,68,75,75,84,86,87,90,98
- ❖ 2. Déterminer la médiane: Cette distribution est constituée de 16 données. Par conséquent, la médiane sera la moyenne entre la 8e et la 9e donnée.
$$(64+68)/2=66$$
- ❖ 3. Déterminer la valeur du premier quartile: La première moitié est composée des données suivantes : 32,35,48,56,59,60,61,64, la médiane est donc: 57,5
- ❖ 4. Déterminer la valeur du troisième quartile: La deuxième moitié est composée des données suivantes : 68,75,75,84,86,87,90,98, la médiane est donc 85.
- ❖ 5. Tracer le diagramme:



8.1 DIAGRAMME À TIGE ET À FEUILLES

Distribution à un caractère: Une **distribution** à un caractère correspond à l'**ensemble** des données recueillies au cours d'une étude statistique portant sur un **seul** caractère.

Exemple

Femmes		Hommes
6-5-2-2	0	2-3-4-5
4-3-3-1	1	0-0-1-6-8
9-9-8-4-3	2	2-2-5-7-8
9-8-7-6-5	3	1-8-8-8-9

La colonne du centre représente la tige et la donnée à droite représente les données des femmes (unités).
Femmes: 2 - 2 - 5 - 6 - 11 - 13 - 13 - 14 - 23 - 24 - 28 - 29 - 29 - 35 - 36 - 37 -38 - 39
Hommes: 2 -3 -4 - 5 - 10 - 10 - 11 - 16 - 18 - 22 - 22 - 25 - 27 -28 - 31 - 38 - 38 - 38 - 38 - 39

DIAGRAMME À TIGE ET À FEUILLES

Un **diagramme** à tige et à **feuilles**, permet de mieux visualiser la répartition des **données**. Les nombres situés à **gauche** de la ligne verticale s'appellent **tiges** et correspondent aux chiffres des **dizaines**, tandis que les **données** situés à **droite** de la ligne verticale s'appellent feuilles et correspondent aux chiffres des **unités** dans les **données**.

Chaque **rangée** est associée à une classe et chaque donnée est **séparée** en deux parties se trouvant sur une même ligne.

8.2 ÉCART MOYEN ET RANG CENTILE

L'écart **moyen** est une mesure de **dispersion** qui indique de combien en moyenne les **données** d'une **série** s'écartent de la moyenne des données de la série.

$$\text{Écartmoyen} = \frac{\text{somme des écarts à la moyenne}}{\text{moyenne}}$$

1. **CALCULER LA MOYENNE**

2. **CALCULER LES ÉCARTS ENTRE LA MOYENNE ET CHAQUE DONNÉE (VALEUR ABSOLUE)**

3. ADDITIONNER TOUS LES ÉCARTS

4. DIVISER CETTE SOMME PAR LE NOMBRE DE DONNÉES

L'ÉCART TYPE

La **VARIANCE** ou l'écart type est une mesure de **DISPERSION** qui indique la moyenne des **DONNÉES** des écarts à la **MOYENNE**

1. **CALCULER LA MOYENNE** _____
2. **CALCULER LES ÉCARTS ENTRE LA MOYENNE ET CHAQUE DONNÉE (VALEUR ABSOLUE) ET METTRE AU CARRÉ**
3. **ADDITIONNER TOUS LES ÉCARTS**
4. **DIVISER CETTE SOMME PAR LE NOMBRE DE DONNÉES ET EXTRAIRE LA RACINE**

Ex 1: Trouve l' écart moyen et l' écart type dans la liste suivante

4 – 8 – 12 – 13 – 18

Donnée	Moyenne de la distribution	Écart à la moyenne	Écart à la moyenne au carré
4	11	7	49
8	11	3	9
12	11	1	1
13	11	2	4
18	11	7	49
Total = 55	55	20	112

$$\text{Moyenne} = \frac{4 + 8 + 12 + 13 + 18}{5} = 11$$

Ex 1: Suite

$$\text{Écart moyen} = \frac{\text{Somme des écarts à la moyenne}}{\text{Nombre total de données}}$$

$$\text{Écart moyen} = \frac{20}{5}$$

$$\text{Écart moyen} = 4$$

$$\text{Écart type} = \sqrt{\frac{\text{Somme des carrés des écarts à la moyenne}}{\text{Nombre total de données}}}$$

$$\text{Écart type} = \sqrt{\frac{112}{5}}$$

$$\text{Écart type} = \sqrt{22,4}$$

$$\text{Écart type} = 4,73$$

Effectue les opérations suivantes et regarde les réponses par la suite.

Trouve l'écart moyen et l'écart type.

Résultat	1	2	3	4	5
Effectif	2	1	5	12	10

Réponses

a) Écart moyen = 0,813
Écart type = 1,106

Résultat	2	4	6	8	10
Effectif	2	1	5	12	10

b) Écart moyen = 1,627
Écart type = 2,212

Résultat	0	1	2	3	4
Effectif	10	8	6	4	2

c) Écart moyen = 1,067
Écart type = 1,247

Résultat	0	2	4	6	8
Effectif	10	10	4	3	3

d) Écart moyen = 2,133
Écart type = 2,59

CENTILES ET RANG CENTILE

Les centiles ou rang centile partagent la série de données en 100 tranches renfermant chacune 1% des données. De gauche à droite, on attribue aux données situées dans la 1ère tranche, le 1er rang centile, aux données situées dans la 2e tranche, le 2e rang centile...

La formule suivante permet de déterminer le rang centile d'une donnée dans une série:

$$\text{Rang centile de } x = \frac{\text{Nombre inf. de données à } x + \frac{1}{2} \text{ Nombre de données égales à } x}{\text{Nombre total de données}} \times 100$$

On arrondit le rang centile obtenu à l'entier supérieur le plus proche.

Exemple:

- ❖ Calculer le rang centile de 45 dans cette distribution:
- ❖ 3, 10, 12, 34, 37, 42, 45, 45, 45, 48, 51, 65, 79, 80, 90

$$\text{Rang centile de } x = \frac{\text{Nombre inf. de données à } x + \frac{1}{2} \text{ Nombre de données égales à } x}{\text{Nombre total de données}} \times 100$$

Il y a 6 données inférieures à 45

Il y a 3 données égales à 45

$$\text{Rangcentile } 45 = \frac{6 + \frac{1}{2}(3)}{15} \times 100$$

$$\text{Rang centile } 45 = \frac{7,5}{15} \times 100 = 50$$

Le rang centile de 45 est 50.

Exemple: Voici les résultats sur 100, de 150 personnes à un test de maths: 45, 54, 56, 57,...69, 70, 70, 71, 71, 73, 74, 74, 76, 76, 78, 79,..., 84, 84, 86, 89, 92, 97.

60 données

67 données

Détermine le rang centile de 74:

$$= \frac{70 + 1/2(2)}{150} \times 100 = 47,333 = 48$$

Détermine le rang centile de 86:

Si on connaît le rang centile et on cherche la donnée:

$$\frac{\text{Rangcentile}}{100} \times \text{Nombre de données}$$

Détermine la donnée dont le rang centile est 3:

$$\frac{3}{100} \times 150 = 4,5e \text{ donnée}$$

Arrondir à la
donnée inférieure

La 4e donnée est
57

On utilise le **rang centile** lorsqu'une série contient un très grand **nombre** de données.

8.3 CORRÉLATION, TABLEAU DE DISTRIBUTION À DOUBLE ENTRÉE ET NUAGE DE POINTS

Toute étude **statistique** faisant intervenir deux variables X et Y permet d'**associer** à chaque individu d'un **échantillon** le couple (x, y) .

On appelle **distribution** à deux **variables** l'ensemble des couples obtenus.

Un **tableau** à double entrée est un tableau donnant la répartition des individus d'un échantillon selon les modalités conjointes de deux **variables**.

Un tableau qui met en **relation** deux variables permet de faire des **comparaisons** et d'établir, lorsqu'il y a lieu, un lien entre les **deux variables**.

NUAGE DE POINTS

Lorsque que les variables x et y sont reliées, on peut représenter chaque donnée par un point dans le plan cartésien. L'ensemble des points correspondant aux données s'appelle un nuage de points. On appelle donnée aberrante, toute donnée qui s'éloigne passablement des autres données du nuage. La représentation du nuage permet de vérifier s'il existe un lien entre les deux variables. Lorsque les variables sont quantitatives, un tel lien est appelé corrélation.

CORRÉLATION LINÉAIRE

On dit qu'il y a corrélation entre des variables quantitatives x et y pour indiquer une dépendance statistique entre les deux variables.

La corrélation est dite linéaire lorsque les points du nuage ont tendance à se rapprocher d'une droite.

La corrélation est dite non linéaire lorsque les points ont tendance à se rapprocher d'une courbe.

La corrélation est dite positive lorsque les variables varient dans le même sens.

La corrélation est dite négative lorsque les variables varient en sens contraire.


8.4 INTERPRÉTATION QUANTITATIVE DE LA CORRÉLATION ET COEFFICIENT DE CORRÉLATION LINÉAIRE

COEFFICIENT DE CORRÉLATION LINÉAIRE		SIGNIFICATION
NÉGATIF	POSITIF	
PRÈS DE 0	PRÈS DE 0	Corrélation nulle
PRÈS DE -0,5	PRÈS DE 0,5	Corrélation faible
PRÈS DE -0,75	PRÈS DE 0,75	Corrélation moyenne
PRÈS DE -0,87	PRÈS DE 0,87	Corrélation forte
ÉGAL À -1	ÉGAL À 1	Corrélation parfaite

ESTIMATION DU COEFFICIENT LINÉAIRE GRAPHIQUEMENT

1. Tracer une droite qui représente le plus possible les points
2. Construire un rectangle (+< possible) excluant données aberrantes
3. Calculer d(largeur) et D(longueur) du rectangle et appliquer la formule:

$$r \sim \pm(1 - \frac{d}{D})$$



$$d = 1,1$$

$$D = 5,3$$

$$r \sim \pm \left(1 - \frac{1,1}{5,3}\right)$$

$$r \sim 0,8$$

Corrélation forte et positive

ESTIME LE COEFFICIENT DE CORRÉLATION LINÉAIRE:

(3,5) (4,7) (7,12) (2,4) (1,5) (8,12) (3,6) (4,8) (5,8) (8,11)

8.5 DROITE DE RÉGRESSION OU LA DROITE DE MAYER

Pour déterminer l'équation de la droite de Mayer lorsqu'on se retrouve avec un nuage de points, on veut en fait trouver une équation qui serait le plus possible représentative du résultat de l'étude statistique. Voilà les étapes:

1. Placer les données en ordre croissant (selon les valeurs en x)
 2. Séparer les données en deux groupes égaux (pour les groupes impairs, utiliser la donnée du centre dans les deux groupes)
 3. Faire la moyenne du premier groupe (moyenne en x et moyenne en y), ce sera le premier point utilisé pour trouver l'équation.
 4. Faire la moyenne du deuxième groupe (moyenne en x et moyenne en y), ce sera le deuxième point utilisé pour trouver l'équation.
- Utiliser ces deux points pour trouver l'équation de la droite.

Exemple: Voici une étude statistique effectuée quant au nombre d'inscriptions à différentes activités sportives en fonction du nombre d'enfants.

NB D'ENFANTS	2	6	5	4	1	5	3
NB D'INSCRIPTIONS	6	9	7	6	5	8	4

Placer les données en ordre croissant (selon les valeurs en x)

NB D'ENFANTS	1	2	3	4	5	5	6
NB D'INSCRIPTIONS	5	6	4	6	7	8	9

Séparer les données en deux groupes égaux (pour les groupes impairs, utiliser la donnée du centre dans les deux groupes)

Faire la moyenne du premier groupe (moyenne en x et moyenne en y), ce sera le premier point utilisé pour trouver l'équation.

Faire la moyenne du deuxième groupe (moyenne en x et moyenne en y), ce sera le deuxième point utilisé pour trouver l'équation.

$$x_1 = \frac{4 + 5 + 5 + 6}{4} = 5$$

$$y_1 = \frac{6 + 7 + 8 + 9}{4} = 7,5$$

Trouver l'équation (2,5 ; 8,75) et (5, 7,5)