




# Méthodes



# Statistiques






**Salle Socrative : BIOSTATREINE**



# 1. Introduction & Definitions




Biostatistiques : statistiques appliquées au domaine de la santé publique

- But : décider si une observation est due au hasard ou explicable
- 3 objectifs : description, évaluation et mise en place des observations



# 1. Introduction & Definitions



Statistiques : art de collecter analyser et interpréter des données

→ 2 types de statistiques :

- Descriptives : description grâce à des paramètres
- Déductives : Observation due au hasard ?



## Données : résultat d'une observation

-> observation ou comparaison à d'autres individus -> variable

Une variable prend une valeur pour un individu

Grande variabilité inter-sujet ou intra-sujet

# Définitions (oui encore...)

👑 Paramètre : grandeur apportant une information résumée sur la variable

👑 Série statistique : collection d'objets de même nature avec des caractéristiques différentes

👑 Population : série exhaustive de tous les individus étudiés

👑 Échantillon : sous-ensemble fini et d'effectif limité. Représentatif : TAS



## Points ++

L'échantillon est **connu**

La population est **inconnue**





# Variables :

## Quantitative :

**Mesurée ou dénombrée**

Peut être :

- ❖ **Continue**
- ❖ **Discrète**


*Ex : Taille, poids, nombre de cigarettes fumées par jour...*

## Qualitative :

Ne peut être mesuré mais susceptible d'être **classée**

- ❖ Binaire : oui/non
- ❖ Multiple
  - **Nominale** (statut marital)
  - **Ordonnées** (gravité maladie)






# Variable qualitative ordinale :

- ❖ Une variable qualitative ordinale peut être approximée en une variable pseudo quantitative



Une variable pseudo quantitative reste Qualitative



### 3. Les Paramètres :

#### I- Moyenne :

Variable quantitative  
discrète :

$$m = \frac{\sum x_i}{n}$$

Variable quantitative  
continue :

$$m = \frac{\sum x_i n_i}{n}$$

### 3. Les Paramètres :

#### II- Variance :

Variance : la dispersion des  
données autour de la  
moyenne



# 3. Les Paramètres :

## III- Mediane :

### N Pair :

moyenne des valeurs  
 $\frac{n}{2}$  et  $(\frac{n}{2}) + 1$

### N impair :

$$\frac{n + 1}{2}$$

### 3. Les Paramètres :

#### IV- Quartiles :


Quartiles : séparent la série en  
4 sous-séries de même  
effectif






# Comparaison :

	Avantages	Inconvénients
<b>Moyenne</b>	<ul style="list-style-type: none"><li>+ Simple à calculer</li><li>+ Facile à manipuler dans des tests stats donc adaptée aux calculs statistiques</li><li>+ Très significative si la répartition des données est assez symétrique avec une faible dispersion</li></ul>	<ul style="list-style-type: none"><li>- Sensible aux valeurs anormales (max et min)</li></ul>
<b>Médiane</b>	<ul style="list-style-type: none"><li>+ Calcul facile</li><li>+ Peu sensible aux valeurs anormales</li><li>+ Utilisable pour des valeurs ordinales, des classes</li></ul>	<ul style="list-style-type: none"><li>- Se prête moins aux calculs statistiques</li></ul>






# Estimation :


❖ 2 types d'estimation :

- Ponctuelle : meilleure à un instant  $t$
- Par intervalle : Intervalle de Confiance




L'estimation par intervalle est moins précise mais plus fiable






# Données quantitatives :

- ❖ Écart-type : dispersion des données entre elles et autour de la moyenne
- ❖ Degré de liberté ou DDL : nombre de valeur à connaître pour résoudre une équation et connaître toutes les valeurs de la série








# Intervalle de confiance :

- ❖ Intervalle de confiance : estimation de la moyenne vraie  $\mu$  à partir de la moyenne  $m$  calculée sur l'échantillon

$$\mu \in \left[ m \pm \frac{\varepsilon s}{\sqrt{n}} \right]$$


- ❖ Aussi appelé intervalle au risque  $\alpha$





# Risque $\alpha$

- ❖ C'est le risque d'erreur dans l'estimation de la moyenne vraie : le risque que  $\mu$  ne soit pas dans l'intervalle
- ❖ En général  $\alpha=5\%$







# Écart réduit $\varepsilon$

❖ Il varie en sens inverse du risque  $\alpha$


- Pour  $\alpha = 5\%$   $\varepsilon=1,96$
- Pour  $\alpha = 1\%$   $\varepsilon=2,60$






# Précision de l'estimation


- ❖ Le risque  $\alpha$  va conditionner la précision de l'estimation
- ❖ Moins de risque  $\rightarrow$  intervalle augmente donc  $\varepsilon$  augmente : la moyenne a plus de chance d'être dedans mais la précision diminue






# Indice de précision


- ❖ Permet de calculer la précision de l'estimation de  $\mu$  = largeur de l'IC
- ❖  $i = \varepsilon s / \sqrt{n}$
- ❖ Donc  $\mu \in [m \pm i]$
- ❖ D'après la formule : si  $n \uparrow$ ,  $i \downarrow$  donc l'IC se resserre donc la précision  $\uparrow$








# Loi de Gauss ou loi normale

- ❖ Distribution en forme de cloche plutôt symétrique par rapport à la moyenne
- ❖ En abscisse : l'IC
- ❖ En ordonnée : n




- ❖ L'aire sous la courbe correspond au % de la population concernée
- ❖ Cette loi de Gauss est approximable par une loi normale  $N(\mu, \sigma)$






# Données qualitatives

- ❖ On estime un pourcentage  $p$  à partir du pourcentage observé  $P_{obs}$
- ❖ L'estimation assure une correspondance entre échantillon et population







# Intervalle de confiance

❖ Estimation du pourcentage vrai  $p$  à partir du pourcentage observé  $p_{obs}$  sur l'échantillon

❖  $p \in [p_{obs} \pm \varepsilon s]$

