



Méthodes statistiques


Biostatistiques - camiléon

Once upon a time...

Introduction



Biostatistiques = stats
appliquées au domaine de la SP



3 objectifs :

Description pop
Évaluation ttt, techniques, coûts
Mise en place observations
épidémiologiques



Biostats → décider si
observation explicable ou due
au hasard?

Statistiques

= art de collecter, analyser et interpréter des données



Biostatistiques

stats appliquées à la médecine

2 types de biostatistiques



- **Descriptives** = on décrit une situation avec paramètre (taille, âge pop française)
- **Déductives** = observation due au hasard ? (personnes 1m65 brunes, hasard?)

Données

= résultat de l'observation d'un individu, grâce à un instrument de mesure / sens




Définitions

- But d'une donnée → **observer** / **comparer** plusieurs individus
- Une donnée est une variable

VARIABLE PREND UNE VALEUR POUR UN INDIVIDU

- **Grande variabilité** due au hasard ou physiologique :
 - Inter sujet (entre 2 sujets)
 - Intra sujet (1 sujet)





Paramètres

Grandeur apportant une **information résumée/synthétisée** sur la variable étudiée

→ Moyenne, écart-type



Série statistique

Collection d'objets de **même nature** mais de **caractéristiques différentes**

→ Hommes et femmes



fx

Variable quantitative

Mesurable, obtenue par appareil de mesure

→ taille, poids

fx

Variable qualitative

Non mesurable

→ Couleur yeux, douleur

Population

Série **exhaustive** de tous les individus étudiés sur lesquels on veut **inférer**
des décisions

→ Population française

Echantillon

Sous ensemble fini et d'effectif limité, extrait de la population

Il doit être **représentatif** d'où la nécessité d'un **TAS**

→ 100 personnes prises dans la pop française

/!\ échantillon connu // population inconnue /!\

Types de variables

- 2 types
 - Qualitatives
 - ***Binaires*** (H/F)
 - ***Nominales*** (couleur yeux)
 - ***Ordinales*** (douleur)
 - Quantitatives
 - ***Discrètes*** (âge)
 - ***Continues*** (poids)
- La différence être les deux c'est que la variable continue possède un nombre infini de valeurs entre deux valeurs

Variable qualitative ordinale

- Une **variable qualitative ordinale** peut être approximée en variable pseudo quantitative

/!\ une variable pseudo quantitative reste qualitative /!\

→ Les classements en médecine

Paramètres

- Moyenne

- Variable quantitative discrète $m = \frac{\sum x_i}{n}$
- Variable quantitative continue $m = \frac{\sum x_i n_i}{n}$

- Variance

- Indique la **dispersion** des données autour de la moyenne

Calcul de la
moyenne :

- Moyenne de 12/16/5 ?
 - J'ai 3 valeurs donc $n=3$
 - $m = \frac{\sum x_i}{n} = \frac{12+16+5}{3} = \frac{33}{3} = 11$

Paramètres

- Médiane

- Valeur de l'observation centrale, divise la série d'effectif **en 2 sous-séries de même effectif**
 - Pour n pair = la médiane est la moyenne des deux valeurs correspondantes à $\frac{n}{2}$ et $\left(\frac{n}{2}\right) + 1$
 - Pour n impair = la médiane est donnée par $\frac{n+1}{2}$

- Quartiles

- Valeur de la variable qui partagent la série d'effectif en **4 sous-séries de même effectif**

Calcul de la médiane :

- Médiane de 12/16/5
 - On classe nos valeurs $\rightarrow 5/12/16$
 - On a 3 valeurs donc $n=3$
 - Comme n est impair on applique :
 - $med = \frac{n+1}{2} = \frac{4}{2} = 2$
 - Ma 2^e valeur est ma médiane $\rightarrow 12$

Calcul du quartile :

- Quartile 1 de 12/16/5/8/14
 - On classe les valeurs \rightarrow 5/8/12/14/16
 - On a 5 valeurs donc $n=5$
 - On applique la formule du quartile :
 - $Q1 = \frac{1}{4} * n = \frac{5}{4} = 1,25$
 - Donc Q1 entre valeur 1 et valeur 2
 - Moyenne des deux valeurs $m = \frac{5+8}{2} = 6,5$
 - $Q1 = 6,5$

Avantages / Inconvénients moyenne/médiane

	<u>Avantages</u>	<u>Inconvénients</u>
<u>Moyenne</u>	<ul style="list-style-type: none">- <u>simple</u> à calculer- facile à <u>manipuler</u> dans les test stats donc adaptées aux calculs statistiques- <u>très significative</u> si la répartition des données est assez symétrique et avec une <u>faible dispersion</u>	<ul style="list-style-type: none">- <u>sensible</u> aux valeurs anormales (max et min)
<u>Médiane</u>	<ul style="list-style-type: none">- calcul <u>facile</u>- <u>peu sensible</u> aux valeurs anormales- <u>utilisable</u> pour les valeurs ordinales, les classes...	<ul style="list-style-type: none">- se <u>prête moins aux calculs statistiques</u>

Estimations en statistiques

- Les études biostats sont réalisées sur des **échantillons représentatifs**
→ échantillonnage
- Après l'étude on doit être sûr que les résultats sont légitimes et qu'on peut les extrapoler à la population
- On va réaliser une **estimation** du résultat vrai à partir des données obtenues avec l'échantillon

Estimations en statistiques

- 2 types d'estimations
 - Ponctuelles : meilleure à instant t
 - Par intervalle : notion **d'intervalle de confiance**,
+++fiable





Ecart-type

Dispersion d'un ensemble de données autour de la moyenne


= **variabilité des mesures entre elles et // moyenne**

+ faible + homogène



Degré de liberté

Nombre de valeurs nécessaires à connaître pour pouvoir résoudre l'équation et **connaître toutes les valeurs de la série**



Intervalle de confiance

Estimation de la moyenne vraie μ à partir de la moyenne m
calculée sur l'échantillon

Intervalle de confiance

- On donne un intervalle auquel μ appartient :

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

- IC = intervalle au risque α



Risque α

Risque d'erreur dans l'estimation de la moyenne vraie

Risque α

- Risque que notre IC ne comprenne pas la valeur vraie de μ
- En général on prend un risque $\alpha = 5\%$



Ecart-réduit ε

Valeur qui **dépend du risque α** , ils varient en sens inverse

Ecart-réduit ε

Mesure de combien d'écart-types une **observation particulière** est éloignée de la population

$$\alpha = 5\%$$

$$\varepsilon = 1,96$$

$$\alpha = 1\%$$

$$\varepsilon = 2,60$$



Précision de l'estimation

- Les variation du risque α vont **conditionner la précision** de l'estimation et la **largeur de l'IC**
- - de risque $\alpha \rightarrow$ IC + grand donc $\varepsilon \uparrow \rightarrow$ + de chances que la moyenne soit dedans



Indice de précision i

Permet de calculer la **précision de l'estimation** de μ

Indice de précision i

- Permet de calculer la précision de l'estimation de μ
- = largeur de l'IC

$$i = \frac{\varepsilon s}{\sqrt{n}}$$



Précision / IC

- IC est compris

entre $[m - \frac{\varepsilon s}{\sqrt{n}}]$ et $[m + \frac{\varepsilon s}{\sqrt{n}}]$ donc entre $[m - i]$ et $[m + i]$.

- Donc d'après la formule de i

si $n \uparrow$ alors $i \downarrow$ donc l'IC \downarrow donc la précision \uparrow

- On peut conclure que $+ n \uparrow \rightarrow + \text{précision} \uparrow$



RECAP

- **L'IC** = **estimation de la moyenne vraie μ** à partir de la **moyenne m** calculée sur l'échantillon. Il est aussi appelé **"intervalle au risque α "**.
- **Risque α** = **risque d'erreur** dans l'estimation de μ .
- ϵ = **écart-réduit** **distribution des données** autour de la **moyenne**.
- Les variations du risque α déterminent la précision de l'estimation.
- i représente la **largeur de l'IC** : $i = \frac{\epsilon s}{\sqrt{n}}$

$$IC = [m \mp i]$$

- Si $n \uparrow$ alors $i \downarrow$ donc l'IC \downarrow donc la **précision** \uparrow
- Si $\alpha \uparrow$ alors $\epsilon \downarrow$ donc $i \downarrow$ donc l'IC \downarrow donc la **précision** \uparrow



Loi de Gauss = loi Normale

- Distribution des variables plutôt symétriques autour de la moyenne avec forme de cloche = **courbe gaussienne** = **courbe de Gauss**
- Courbe en cloche avec
 - Abscisses = IC $[m \pm \epsilon s]$
 - Ordonnée = n
 - Aire sous la courbe = % de la pop concernée




Figure 9.4 : densité de la loi normale de moyenne nulle et de variance un (courbe en cloche)

Loi de Gauss = loi Normale

- Cette loi permet de visualiser l'IC autour de la moyenne, l'écart-type, la dispersion autour de cette valeur moyenne et la moyenne.
- On utilise la **loi Normale** : pour chaque (μ, σ) il existe une loi normale de moyenne μ et d'écart type σ : on la note **N** (μ, σ)



Estimation données qualitatives

- On estime un %
- Estimation assurant **correspondance entre échantillon – population**



IC

= **estimation de la moyenne vraie μ** à partir de la moyenne \bar{m} calculée sur échantillon

IC

- On donne un intervalle :

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

FIN

Socrative : BIOSTATSDUFEU

Reposez vous bien, on revient vite
pour votre plus grand bonheur 😊

