


Probabilités et Biostatistique

PCEM1 Pitié-Salpêtrière


A. Mallet et V. Morice

Cours 5 et 6




Statistiques descriptives

- **Rappels et compléments (1)**
 - variable aléatoire: caractéristique observable, variable, sans anticipation
 - expérience aléatoire: permet l'obtention d'une valeur (réalisation)
 - types usuels de variables aléatoires:
 - quantitatives: continues ou discrètes
 - qualitatives: nominales ou ordinales




Rappels et compléments (2)

- Définition de l'**unité statistique**: entité sur laquelle s'observe la variable aléatoire.
- Interprétation de la probabilité d'un événement aléatoire:
 - valeur **limite** de la fréquence avec laquelle l'événement se réalise au cours d'un nombre **croissant** de répétitions de l'expérience.




Rappels et compléments (3)

- la probabilité d'un événement aléatoire:
 - est une fiction
 - peut résulter d'une théorie
- pour l'approcher: répéter des expériences aléatoires
- les fréquences sont les contreparties expérimentales des probabilités



Echantillon (1)

- 1. Echantillon d'unités statistiques
 - n répétitions -> n unités statistiques concernées (sous population): constituent l'échantillon
- 2. Echantillon de valeurs de la variable étudiée X
 - tirage au 'hasard pur'
 - i-ème répétition -> résultat x_i
 - x_1, x_2, \dots, x_n : échantillon de valeurs de X




Echantillon (2)

- 3. Echantillon d'une variable aléatoire X
 - ensemble X_1, X_2, \dots, X_n de n variables aléatoires, indépendantes entre elles, de même distribution que X
 - un échantillon de valeurs de X est une réalisation de l'échantillon de X
- n s'appelle la taille de l'échantillon


Echantillon (3)



X



premier échantillon de valeurs de X



second échantillon de valeurs de X

x_1, x_2, x_3, x_4 indépendantes entre elles

Echantillon (3)

X

x_1

x_2

x_3

x_4

premier échantillon de valeurs de X
première réalisation de X_1, X_2, X_3, X_4

x'_1

x'_2

x'_3

x'_4

second échantillon de valeurs de X
seconde réalisation de X_1, X_2, X_3, X_4

X_1

X_2

X_3


X_4

échantillon de la variable X



- un échantillon de valeurs de X est une réalisation de l'échantillon de X

Représentation des résultats variable qualitative

- Référence: répartition




Représentation des résultats variable qualitative



(variable à 5 modalités)

Représentation des résultats variable quantitative discrète


- Référence: répartition



Répartition observée ou **histogramme en bâtons**


Représentation des résultats variable quantitative continue (1)

- Référence: densité de probabilité




Représentation des résultats variable quantitative continue (2)

- Référence: densité de probabilité




Représentation des résultats variable quantitative continue (3)

- Référence: densité de probabilité




Représentation des résultats variable quantitative continue (4)

- Référence: densité de probabilité




Représentation des résultats variable quantitative continue (5)

- Référence: densité de probabilité




Représentation des résultats variable quantitative continue (6)

- Référence: densité de probabilité




Représentation des résultats variable quantitative continue (7)

- Référence: densité de probabilité



Représentation des résultats variable quantitative continue (8)


- Référence: densité de probabilité



• Réponse : HISTOGRAMME

Représentation des résultats variable quantitative continue (9)

- Référence: densité de probabilité



• Réponse : HISTOGRAMME


Représentation simplifiée des résultats variables quantitatives



■ Localisation des valeurs


- Médiane observée: valeur telle qu'il y ait autant de valeurs qui lui sont supérieures que de valeurs qui lui sont inférieures

- Moyenne observée: $m = \frac{1}{n} \sum_{i=1}^n x_i$

- Remarque: m est une réalisation de la variable aléatoire $M_n = \frac{1}{n} \sum_{i=1}^n X_i$ appelée **variable aléatoire moyenne arithmétique construite sur un échantillon de taille n de X .**







Représentation simplifiée des résultats variables quantitatives


- Dispersion des valeurs:



- variance observée $s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - m)^2$


- Écart type observé: $\sqrt{s^2}$ noté s

- Remarque: s^2 est une réalisation de la variable aléatoire variance:

$$S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - M_n)^2$$







Reformulation de la moyenne observée (1)

- X variable aléatoire discrète finie à k valeurs possibles: $val_1, val_2, \dots, val_k$
(ex: jeu de dé)
- Toute valeur de l'échantillon de valeurs, x_i , égale val_j pour un j bien choisi.
- Alors:

$$m = \frac{1}{n} \sum_{i=1}^n x_i = \sum_{j=1}^k \frac{n_j}{n} val_j$$

Reformulation de la moyenne observée (2)

- Exemple

$$m = \frac{1}{8} (2 + 4 + 6 + 3 + 3 + 1 + 4 + 5)$$

$$x_1 = \text{val}_2; \dots; x_3 = \text{val}_6; \dots$$

$$n_1 = 1, n_2 = 1, n_3 = 2, n_4 = 2, n_5 = 1, n_6 = 1$$

$$m = \frac{1}{8} (1 * 1 + 1 * 2 + 2 * 3 + 2 * 4 + 1 * 5 + 1 * 6)$$

Reformulation de la moyenne observée (3)

- Donc:
$$m = \frac{1}{n} \sum_{i=1}^n x_i = \sum_{j=1}^k \frac{n_j}{n} \text{val}_j$$
- Proche de :
$$\sum_{j=1}^k \text{val}_j \Pr(X = \text{val}_j)$$
- Qui est l'espérance mathématique de X , $E(X)$: μ
->synonymes
 - Espérance mathématique
 - Moyenne 'vraie'
 - Moyenne théorique
- Ce résultat vaut pour toute variable aléatoire

Reformulation de la variance observée

- De la même façon: la variance observée

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - m)^2$$

approche

$$\sum_{j=1}^k (\text{val}_j - \mu)^2 \Pr (X = \text{val}_j)$$

- qui est la variance de X , $E (X - \mu)^2 : \sigma^2$


-> synonymes

- variance
- variance 'vraie'
- variance théorique

- Ce résultat vaut pour toute variable aléatoire


Cas d'une variable de Bernoulli (1)

- Variable très utilisée en médecine
 - à la frontière qualitative-quantitative
 - codage 0-1 des modalités
 - $E(X) = \Pr(X=1) = \pi =$ probabilité (un individu présente la modalité 1)
- Interprétation de la moyenne observée
 - $m = \frac{1}{n} \sum_{i=1}^n x_i = \frac{1}{n} (0 + 1 + 0 + 0 + 1 + 1 + \dots) =$
 $\frac{\text{nombre de fois où } X = 1}{n} = \text{proportion observée}$




Cas d'une variable de Bernoulli (2)

- la proportion observée, **notée p** , est une moyenne observée
- la proportion observée p approche $E(X)$ donc approche π
- π pourra s'appeler proportion 'vraie'



Cas d'une variable de Bernoulli (3)

- Rappel : m est une réalisation de M_n
- Si X est une variable de Bernoulli, M_n sera noté P_n et on parlera de **variable aléatoire** ~~moyenne arithmétique~~ **proportion construite sur un échantillon de taille n**
- Avec ces notations adaptées, p est une réalisation de P_n .




Conclusion

- Ces premiers résultats (m approche $E(X)$; p approche π) engagent à étudier les variables M_n et P_n .
- Objet de la suite.

La variable aléatoire moyenne arithmétique

Cours 6





Etude de la variable aleatoire moyenne arithmétique (M_n et P_n)

- Variable étudiée: X
- Remarque: $M_1 = P_1 = X$
- Exemple: la variable P_2 ; elle repose sur:
 - une variable de Bernoulli: X . Ici on choisit $\pi = 1/2$
 - un échantillon de taille 2: X_1, X_2

X_1	X_2	P_2	Probabilité	
0	0	$\frac{1}{2}(0+0) = 0$	1/4	$[(1-\pi)^2$ en général]
0	1	$\frac{1}{2}(0+1) = 1/2$	1/4	
1	0	$\frac{1}{2}(1+0) = 1/2$	1/4	
1	1	$\frac{1}{2}(1+1) = 1$	1/4	



La variable aléatoire P_2 (suite)

- Répartition si $\pi=1/2$



La variable aléatoire P_2 (suite)

- Répartition si $\pi=0,4$



La variable aléatoire P_2 (suite)

En particulier:

- $E(P_2) = \text{val}_1 * \Pr(P_2 = \text{val}_1) + \text{val}_2 * \Pr(P_2 = \text{val}_2) + \text{val}_3 * \Pr(P_2 = \text{val}_3)$

$$= 0 * 1/4 \quad + 1/2 * 1/2 \quad + 1 * 1/4$$

$$= 1/2 = E(X)$$

Généralement: $= \pi$

- $\text{var}(P_2) = E[(P_2 - 1/2)^2] = (0 - 1/2)^2 * 1/4 + (1/2 - 1/2)^2 * 1/2 + (1 - 1/2)^2 * 1 = 1/8$

$$= 1/2 * 1/4 = 1/2 \text{ var}(X)$$

Généralement: $= 1/2 \pi(1 - \pi)$

Propriété de M_n (donc de P_n) (2)

- Résultat général:


$$E(M_n) = E(X)$$

$$\text{var}(M_n) = \frac{1}{n} \text{var}(X) \quad ; \text{ donc } \text{var}(\sqrt{n} M_n) = \text{var}(X)$$

- Attendu en fait car:

$$E\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n} \sum_{i=1}^n E(X_i) = \frac{1}{n} \sum_{i=1}^n E(X) = E(X)$$

$$\text{var}\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n^2} \sum_{i=1}^n \text{var}(X_i) = \frac{1}{n^2} \sum_{i=1}^n \text{var}(X) = \frac{1}{n} \text{var}(X)$$




Propriété de M_n (donc de P_n) (1)


- Habillage dans le cas d'une proportion P_n :

$$E(P_n) = \pi$$

$$\text{var}(P_n) = \frac{1}{n} \boxed{\pi(1 - \pi)}$$

var(X)






Une étude ambitieuse


- Etude simultanée des variables moyennes arithmétiques, M_n et Q_n construites sur 2 variables aléatoires X et Y
 - X : nombres entre 0 et 1 écrits sur des papiers contenus dans une urne
 - Y : taille des adultes dans la population humaine
- $n=1$: étude pratique de $M_1(X)$ et $Q_1(Y)$
 - Constitution d'un échantillon de chaque variable
 - Construction des histogrammes

Histogramme de $M_1(X)$

papiers 1




Histogramme de Q1 (Y)




n=1: histogrammes de M1 (X) et Q1 (Y)

papiers 1




taille M1




n=2: histogrammes de M_2 et Q_2 (*)

papiers 2





taille M2




* en réalité de $\sqrt{2}M_2$ et $\sqrt{2}Q_2$, ramenés à moyennes observées 0,5 et 1,3

n=30: histogrammes de M_{30} et Q_{30} (*)




* en réalité de $\sqrt{30}M_2$ et $\sqrt{30}Q_2$, ramenés à moyennes observées 0,5 et 1,3



densité asymptotique

Histogramme de M_{30}




Le théorème central limite*** (Laplace, Gauss)

- Pour toute variable quantitative, la distribution limite (lorsque n croît indéfiniment) de:


$$\frac{M_n - E(X)}{\sqrt{\frac{\text{var}(X)}{n}}}$$

$E(M_n)$

$\text{var}(M_n)$



est la distribution d'une variable normale centrée réduite ($N(0,1)$)



Le théorème central limite, version pratique (1)

- Lorsque n est 'assez grand', la variable

$$\frac{M_n - E(X)}{\sqrt{\frac{\text{var}(X)}{n}}}$$

- a 'à peu près' une distribution d'une variable normale centrée réduite.
- est 'à peu près' distribuée selon une loi normale centrée réduite


Le théorème central limite, version pratique (2)

- Lorsque n est 'assez grand'

- $$\frac{M_n - E(X)}{\sqrt{\frac{\text{var}(X)}{n}}} \underset{\text{à peu près}}{\sim} N(0,1)$$


- $$M_n \underset{\text{à peu près}}{\sim} N\left(E(X), \frac{\text{var}(X)}{n}\right)$$

Diverses distributions de M_n pour divers n 'assez grands'



Le théorème central limite, version pratique (3)

- Qu'est-ce qu'assez grand ? Trois cas.
 - 1. X est une variable normale.
Alors le théorème est vrai pour tout n
 - 2. X n'est ni normale ni de Bernoulli.
Alors on considère que l'approximation est valide
si $n \geq 30$
 - 3. X est une variable de Bernoulli.
Alors l'approximation est valide si $n\pi \geq 5$ et
 $n(1-\pi) \geq 5$




Le théorème central limite, version pratique (4)

- Forme habillée du théorème dans ce dernier cas:

Lorsque $n\pi \geq 5$ et $n(1-\pi) \geq 5$, la variable

$$\frac{P_n - \pi}{\sqrt{\frac{\pi(1-\pi)}{n}}} \underset{\text{à peu près}}{\sim} \mathbf{N}(0,1)$$



Le rôle majeur de $N(0,1)$ (1)


- vaut bien une convention: la convention u_α
 - Soit X distribuée $N(0,1)$
 - Pour toute valeur α entre 0 et 1, u_α est la valeur telle que

$$\Pr (X \notin [-u_\alpha \ u_\alpha]) = \alpha$$

- Le calcul de u_α connaissant α , ou l'inverse, se fait à l'aide d'une table numérique

Le rôle majeur de $N(0,1)$ (2)

loi normale centrée réduite



Application du théorème central limite (1)

- Problème: déterminer $[a \ b]$ tel que


$$\Pr (M_n \in [a \ b]) = 1 - \alpha$$

pour α choisi (exemple 0,3)


- Un tel intervalle s'appelle INTERVALLE DE PARI pour la variable aléatoire M_n
 - de niveau $1-\alpha$
 - au risque α

Application du théorème central limite (2)


- Solution: on suppose que les conditions d'application du théorème central limite s'appliquent



Application du théorème central limite (3)




Application du théorème central limite (4)



Application du théorème central limite (5)

- Les solutions sont multiples: choisir $[a, b]$ centré en $E(X)$ → solution unique



Application du théorème central limite (6)

- Solution: on suppose que les conditions d'application du théorème central limite s'appliquent

$$M_n \in [E(X) - c \quad E(X) + c] \Leftrightarrow M_n - E(X) \in [-c \quad c] \Leftrightarrow$$

$$\frac{M_n - E(X)}{\frac{\sigma(X)}{\sqrt{n}}} \in \left[\frac{-c}{\frac{\sigma(X)}{\sqrt{n}}} \quad \frac{c}{\frac{\sigma(X)}{\sqrt{n}}} \right]$$

$$P\left(\frac{M_n - E(X)}{\frac{\sigma(X)}{\sqrt{n}}} \in \left[\frac{-c}{\frac{\sigma(X)}{\sqrt{n}}} \quad \frac{c}{\frac{\sigma(X)}{\sqrt{n}}} \right]\right) = 1 - \alpha$$

Application du théorème central limite (7)

$$P\left(\frac{M_n - E(X)}{\frac{\sigma(X)}{\sqrt{n}}} \in \left[\frac{-c}{\frac{\sigma(X)}{\sqrt{n}}} \quad \frac{c}{\frac{\sigma(X)}{\sqrt{n}}} \right] \right) = 1 - \alpha$$

$[-u_\alpha \quad u_\alpha]$

$\sim N(0,1)$


$$IP_{1-\alpha}(M_n) = \left[E(X) - u_\alpha \frac{\sigma(X)}{\sqrt{n}} \quad E(X) + u_\alpha \frac{\sigma(X)}{\sqrt{n}} \right]$$

$n \geq 30$

- Pour une variable de Bernoulli

$$IP_{1-\alpha}(P_n) = \left[\pi - u_\alpha \frac{\sqrt{\pi(1-\pi)}}{\sqrt{n}} \quad \pi + u_\alpha \frac{\sqrt{\pi(1-\pi)}}{\sqrt{n}} \right]$$

$n\pi \geq 5$ et $n(1-\pi) \geq 5$



Terminologie


- Généralisation

Tout intervalle $[a \ b]$ tel que

$$\Pr(X \in [a \ b]) = 1 - \alpha$$

se nomme INTERVALLE DE PARI POUR X

- de niveau $1-\alpha$
- au risque α

- 
- Site:

<http://www.jcu.edu/math/isep/Quincunx/Quincunx.html>