

Correction Session 2 (sur f. ori. Du)

COURS

Soit (X_1, \dots, X_n) un échantillon simple au hasard. On note

$$S_m^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X}_m)^2 \text{ la "variance empirique" ou "d'échantillon".}$$

Celle-ci est un estimateur de la variance de la variable aléatoire parente $X_i \sim \mathcal{D}(\mu, \sigma^2)$.

S_m^2 est un estimateur convergent mais biaisé de σ^2 .


Exercice 1

① $f(x) = \begin{cases} \frac{k}{2} & \text{si } x \leq 20 \\ k & \text{si } x > 20 \end{cases}$ la fonction est définie pour $x \in [0, 30]$.

f est une densité si $\int_{\text{supp } x} f(x) dx = 1$

L'aire située sous le graphique de la densité doit correspondre à 1.

Tracer le graphique de la densité :



$$\int_0^{30} f(x) dx = \text{aire A} + \text{aire B}$$

$$\text{aire A} = 20 \times \frac{k}{2} = 10k$$

$$\text{aire B} = (30 - 20) \times k = 10k$$

$$\text{Donc } \int_0^{30} f(x) dx = 10k + 10k = 20k = 1$$

D'où $k = \frac{1}{20}$

Ex. 1 (2)

La fonction de répartition $F(x) = \int_{-\infty}^x f(t) dt$

- Pour $x \leq 20$ $F(x) = \int_0^x \frac{k}{2} dt = \left[\frac{kt}{2} \right]_0^x = \frac{kx}{2} - \frac{k \cdot 0}{2} = \frac{kx}{2}$


- Pour $x > 20$ $F(x) = \int_0^{20} \frac{k}{2} dx + \int_{20}^{30} k dt = \frac{k \cdot 20}{2} + \left[kt \right]_{20}^{30}$

$$F(30) = 10k + kx - 20k = kx - 10k$$

or $k = \frac{1}{2}$ donc

$$F(x) = \begin{cases} 0 & \text{si } x < 0 \\ \frac{x}{40} & \text{si } 0 \leq x \leq 20 \\ \frac{x}{20} - \frac{1}{2} & \text{si } x > 20 \\ 1 & \text{si } x \geq 30 \end{cases}$$

(3) graphes de la fonction de répartition F :
il est composé de segments de droites
quand $x = 20$ $F(20) = 20/40 = 1/2$ } on a continuité
 $F(20) = \frac{20}{20} - \frac{1}{2} = 1/2$ } en 20.



Ex. 1 (4)

La loi n'est pas symétrique, la médiane vaut 20 car $F(20) = \frac{1}{2}$

(5) Le quantile $Q_{20\%}$ est défini tel que $F(Q_{20\%}) = 0,2$

$Q_{20\%} = F^{-1}(0,2)$ il est situé sur la portion séquent de la fonction puisque $20\% < 50\%$.

Donc $\frac{Q_{20\%}}{40} = 0,2$ $Q_{20\%} = 8$ $P(X \leq 8) = 20\%$.

De la même façon $Q_{80\%} = F^{-1}(0,8)$ deuxième séquent.

Donc $\frac{Q_{80\%}}{20} - \frac{1}{2} = 0,8 \Leftrightarrow \frac{Q_{80\%}}{20} = 0,8 + \frac{1}{2} = 1,3$

$Q_{80\%} = 1,3 \times 20 = 26$ $Q_{80\%} = 26$ $P(X \leq 26) = 80\%$

(6) $Q_{905} = F^{-1}(0,905)$

$\Leftrightarrow \frac{Q_{0,905}}{40} = 0,905 \Leftrightarrow Q_{0,905} = 0,905 \times 40 = \underline{\underline{2}}$

$P(X < Q_{905}) = 0,905$

Il y a 5% de chances pour que X soit inférieure à 2.

Exercice 2

(1) La population mère est constituée des 6100 électeurs d'une ville. L'échantillon mère au hasard de taille n .

La variable aléatoire parente X vaut 1 lorsque l'électeur se déclare favorable au candidat B.

$X \sim \mathcal{B}(p)$ où p est la probabilité qu'un individu soit favorable au candidat B.

Ex. 2

① suit

Pour une bernoulli on sait que $E(X) = p$ et $V(X) = p(1-p)$

Par le théorème central limite :

$$\sqrt{n} \frac{\bar{X}_n - \mu}{\sigma} \underset{\infty}{\sim} N(0,1) \quad \text{ou} \quad E(X_i) = \mu \text{ et } V(X_i) = \sigma^2$$

X_i étant une suite iid de v.a.

$$\text{ainsi } \bar{X}_n \underset{\infty}{\sim} N\left(\mu, \frac{\sigma}{\sqrt{n}}\right)$$

Comme $V(X) = p(1-p) \Rightarrow \sigma = \sqrt{p(1-p)}$ et $E(X) = \mu = p$.

et donc dans le cas discuté \bar{X}_n est ainsi la fréquence empirique


$$F_n \text{ on a } \boxed{F_n \underset{\infty}{\sim} N\left(p, \frac{\sqrt{p(1-p)}}{\sqrt{n}}\right)}$$

② On cherche un intervalle de confiance de ^{niveau $1-\alpha$ tel} $P(a \leq p \leq b) = 1-\alpha$ ^{pour la proba}
que ^{inconnue p}

on centre et réduit F_n : $\sqrt{n} \frac{F_n - p}{\sqrt{p(1-p)}} \underset{\infty}{\sim} N(0,1)$

$$\text{ainsi } P\left(-z_{1-\frac{\alpha}{2}} \leq \sqrt{n} \frac{F_n - p}{\sqrt{p(1-p)}} \leq z_{1-\frac{\alpha}{2}}\right) = 1-\alpha$$

$$\text{où } z_{1-\frac{\alpha}{2}} = \Phi^{-1}\left(1-\frac{\alpha}{2}\right)$$



Ex 2 ② suite

$$x \frac{\sqrt{p(1-p)}}{\sqrt{n}} : P\left(-z_{1-\frac{\alpha}{2}} \sqrt{\frac{p(1-p)}{n}} \leq F_m - p \leq z_{1-\frac{\alpha}{2}} \sqrt{\frac{p(1-p)}{n}}\right) = 1-\alpha$$

$$-F_m : P\left(-F_m - z_{1-\frac{\alpha}{2}} \sqrt{\frac{p(1-p)}{n}} \leq p \leq -F_m + z_{1-\frac{\alpha}{2}} \sqrt{\frac{p(1-p)}{n}}\right) = 1-\alpha$$

$$x(1) : P\left(F_m - z_{1-\frac{\alpha}{2}} \sqrt{\frac{p(1-p)}{n}} \leq p \leq F_m + z_{1-\frac{\alpha}{2}} \sqrt{\frac{p(1-p)}{n}}\right) = 1-\alpha$$

on remplace $p(1-p)$ par son estimateur $F_m(1-F_m)$

$$P\left(F_m - z_{1-\frac{\alpha}{2}} \sqrt{\frac{F_m(1-F_m)}{n}} \leq p \leq F_m + z_{1-\frac{\alpha}{2}} \sqrt{\frac{F_m(1-F_m)}{n}}\right) = 1-\alpha$$

③ Application de la formule

Pour un niveau $1-\alpha = 90\% = 0,9 \Rightarrow \alpha = 10\% = 0,1$

Donc $1-\frac{\alpha}{2} = 0,95$ Donc $z_{1-\frac{\alpha}{2}} = z_{0,95} = \Phi^{-1}(0,95) = 1,645$

Taille de l'échantillon $n = 40 + 142 + 352 + 28 + 46 + 344 = 952$

fréquence empirique $F_m = \frac{28 + 46 + 344}{952} = \frac{418}{952} \approx 43,91\%$

$$z_{1-\frac{\alpha}{2}} \sqrt{\frac{F_m(1-F_m)}{n}} = 1,645 \times \sqrt{\frac{0,4391 \times 0,5609}{952}} \approx 0,02646$$

$$P(0,4126 \leq p \leq 0,4656) = 99$$

④ Il y a 90% de chances pour que le candidat B récolte entre 41,26% et 46,56% des voix.

Avec un nivel d'erreur de 10% le candidat B ne remportera pas les élections

Ex 2 suite

$$\textcircled{5} \quad \hat{P}(X=1/Y=y_1) = \frac{28}{28+40} = \frac{28}{68} = 0,41176.$$

on estime que 41,18% des cadres sont favorables au candidat B.

$$\hat{P}(X=1/Y=y_2) = \frac{46}{46+142} = \frac{46}{188} = 0,24467$$

On estime que 24,47% des professions intermédiaires sont favorables au candidat B.

$\hat{P}(X=1/Y=y_1) > \hat{P}(X=1/Y=y_2)$ les cadres apparaissent davantage favorables au candidat B que les professions intermédiaires.

$\textcircled{6}$ On souhaite savoir s'il y a indépendance entre la catégorie socio professionnelle et les préférences électorales. si Y est la v.a. décrivant la CSP et X celle décrivant la préférence pour B. on cherche à tester :

H_0 : X et Y sont indépendants

H_1 : X et Y ne sont pas indépendants

on utilisera pour cela le test du χ^2 à deux.

Ex 2

① suite

Calculer les effectifs théoriques sous hypothèse d'indépendance (H_0):

Y_j	X_i	$X=0$	$X=1$	
$j=y_1$		38,14	29,86	68
$y=y_2$		105,45	82,55	188
$y=y_3$		390,40	305,60	696
		534	418	952

$$m_{ij}^t = \frac{n_i \times m_j}{n}$$

la stat de test $D = \sum_{ij} \frac{(m_{ij} - m_{ij}^t)^2}{m_{ij}^t} \underset{H_0}{\sim} \chi^2 ((3-1) \times (2-1))$
 $\chi^2(2)$

Dans l'attente des données $d_{ij} = \frac{(m_{ij} - m_{ij}^t)^2}{m_{ij}^t}$

Y_j	X_i	0	1	
y_1		0,09	0,11	\sum
y_2		12,56	16,18	
y_3		3,78	4,83	

$$D = 37,65$$

niveau $\alpha = 10\% = 0,1$

valeur critique $c_\alpha = 4,6$

zone de rejet $\mathcal{R}_\alpha = [c_\alpha, +\infty[$

$$D > 4,6$$

donc on rejette H_0

Il n'y a pas indépendance
 avec 10% de chances de se tromper

