

TUTORAT UE 4 2013-2014 – Biostatistiques

CORRECTION Séance n°4 – Semaine du 14/10/2013

Lois de Probabilités ; Tests statistiques
M.SABATIER ; M MOLINARI

Séance préparée par les tuteurs du TSN.

QCM n°1: A, B, C

- A. **Vrai.**
- B. **Vrai.** Avec les valeurs de l'énoncé on calcule :
La moyenne : $(1,5+1,96+\dots+0,90+2,80)/10 = 1,751$
La variance observée avec la formule : $s^2 = 1/n \times \sum x_i^2 - m^2 = 0,3359$ ainsi que l'écart type observé $s = 0,5796$
La variance estimée grâce à la formule : $S^2 = n/n-1 \times s^2 = 0,3732$ et l'écart type estimé $S = 0,6109$.
- C. **Vrai.** On cherche l'intervalle au seuil de 95%.
 $n < 30$ donc on cherche t dans la table de Student à $n-1$ ddl pour $\alpha = 5\% \Rightarrow t = 2,262$
grâce à la formule $[m - t_{\alpha/2, n-1} \cdot S/\sqrt{n} ; m + t_{\alpha/2, n-1} \cdot S/\sqrt{n}]$, on trouve que l'IC est de $[1,3140 ; 2,1880]$.
- D. **Faux.** On cherche l'intervalle au seuil de 90%
 $n < 30$ donc on cherche t dans la table de Student à $n-1$ ddl pour $\alpha = 10\% \Rightarrow t = 1,833$.
grâce à la formule $[m - t_{\alpha/2, n-1} \cdot S/\sqrt{n} ; m + t_{\alpha/2, n-1} \cdot S/\sqrt{n}]$, on trouve que l'IC est de $[1,397 ; 2,105]$.
On trouve les valeurs de l'énoncé si l'on prend l'écart type observé et non celui estimé !
- E. **Faux.** Si on avait eu 45 patients, alors n étant supérieur à 30, on n'aurait pas eu à supposer que la variable suit une loi normale. Le calcul de l'IC aurait utilisé le c de la table de la loi normale et non pas le t de la table de Student.
- F. **Faux**

QCM n°2 : A;C;D;E

- A. **Vrai.** Pour cela on utilise la formule suivante $S^2 = n/n-1 \times s^2$ avec $s^2 = 5,76$.
- B. **Faux.** $n > 30$. On n'a donc pas besoin de supposer que la v.a.r suit une loi normale puisque l'effectif est assez grand et donc que le théorème central limite s'applique.
- C. **Vrai.** On lit le c dans la table de l'écart réduit (loi normale centrée réduite)
- D. **Vrai.** On prend $c = 1,96$ et $S = 2,4310$ et on calcule grâce à la formule suivante : $[m - c_{\alpha/2} \cdot S/\sqrt{n} ; m + c_{\alpha/2} \cdot S/\sqrt{n}]$
- E. **Vrai.** Pour un seuil de confiance de 90% on lit dans le tableau que $c = 1,645$. On utilise la même formule que ci dessus et on trouve bien $[8,77 ; 10,03]$
- F. **Faux**

QCM n°3 : A, B, E

- A. **Vrai.** On a en effet $n < 30$, cette hypothèse est donc obligatoire.
- B. **Vrai.** On a $m = 2$, la variance observée $= 0,5^2 = 0,25$ et donc $S^2 = n/n-1 \times s^2 = 0,2639$.
On trouve $t = 2,101$ dans la table de student à $n-1 = 18$.
On utilise la formule $[m - t_{\alpha/2, n-1} \cdot S/\sqrt{n} ; m + t_{\alpha/2, n-1} \cdot S/\sqrt{n}]$ et on trouve bien $[1,752 ; 2,248]$.
- C. **Faux.** Pour la variance on utilise la loi du chi deux à $n-1$ ddl.
- D. **Faux.** C'est l'IC pour l'écart type !
En effet, on va utiliser la formule suivante : $[(n-1) \times S^2/b ; (n-1) \times S^2/a]$ qui nous donne l'intervalle de confiance pour la variance. On prend $a = 10,865$ tel que $P((n-1)S^2/\sigma^2 \leq a) = \alpha/2$ et $b = 25,989$ tel que $P((n-1)S^2/\sigma^2 \leq b) = 1 - \alpha/2$.

Pour la variance on obtient $[0,1828 ; 0,4372] \approx [0,18 ; 0,44]$ et on a $[0,4276 ; 0,6612]$ pour l'écart type (on prend la racine carrée).

- E. **Vrai.**
- F. Faux.

QCM n°4 : A, D, E

- A. **Vrai.**
- B. Faux. On vérifie si on peut approximer par une loi normale: $n=80>30$, $n \times p = 80 \times 0,625 = 50>5$
 $n \times (1 - p) = 80 \times 0,375 = 30 >5$, on peut donc faire l'approximation.
- C. Faux. $[p_0 - C_{\alpha/2} \sqrt{(p_0(1-p_0)/n)} ; p_0 + C_{\alpha/2} \sqrt{(p_0(1-p_0)/n)}]$
On lit dans la table de l'écart réduit $C_{\alpha/2} = 1,96$ d'où l'intervalle $[0,5189 ; 0,731]$.
- D. **Vrai.** On multiplie chaque borne de l'intervalle par $n = 80$ d'où l'intervalle $[41,5 ; 58,5]$.
- E. **Vrai.** Plus on augmente la taille de l'intervalle, plus le risque de tomber à l'extérieur diminue : Ex: pour $\alpha = 3\%$, on a $[0,508 ; 0,742]$
- F. Faux.

QCM 5: B, E

- A. Faux. $H_1: m_0 \neq \mu$. H_0 est ce que l'on veut rejeter donc $H_0: \mu = 42,4$.
- B. **Vrai.** On a $80 \geq 30$ donc on fait une approximation par le test de l'écart réduit, mais on pourrait aussi utiliser le test de Student.
- C. Faux. $T_{\text{obs}} = (43,2 - 42,4) / (3,3 / \sqrt{80}) = 2,168$.
- D. Faux. On rejette bien H_0 pour $\alpha = 5\%$ car $T_{\text{obs}} \geq 1,96$
On ne rejette pas pour $\alpha = 2\%$ car $T_{\text{obs}} \leq 2,326$
On n'accepte JAMAIS H_0 .
- E. **Vrai.** Dans la table on lit $T_{\alpha} = 2,17$ pour $\alpha = 0,03$.
- F. Faux

QCM n°6 : B, E

- A. Faux. On utilise un test de student mais pour données appariées donc avec 9 degrés de liberté.
- B. **Vrai.** Calcul de la variable $(x_1 - y_1)$: 5 ; 2 ; -4 ; 18 ; -3 ; 0 ; -1 ; 6 ; -3 ; -1
On trouve une moyenne de 1,9.
- C. Faux. Variance = $[5^2 + 2^2 + (-4)^2 \dots] \times 1/9 - 10/9 \bar{x}^2 = 47,2 - 4,0111 = 43,2111$
Donc l'écart type = 6,57
- D. Faux. $T_{\text{obs}} = 1,9 / (6,87 / \sqrt{10}) = 0,915$ or $T_{\alpha} = 2,262$ donc on ne rejette pas H_0 .
- E. **Vrai.** Le fait d'avoir des données appariées ne changent rien, on crée donc une nouvelle variable qu'on compare à une valeur de référence donc on peut utiliser le test de student ou de l'écart réduit pour $n > 30$.
- F. Faux.

QCM n°7: A, D, E

- A. **Vrai.** (cf. cours)
- B. Faux. on utilise des estimateurs qui peuvent être ponctuels ou par intervalle
- C. Faux ; Un intervalle de confiance permet d'estimer un paramètre avec un risque alpha de première espèce connu.
- D. **Vrai.**
- E. **Vrai.**
- F. Faux.

QCM n°8: B

- A. Faux: Pour les populations on utilise les lettres grecques (μ) et non m_1 et m_2 !!!
- B. **Vrai.**
- C. Faux: on doit vérifier l'égalité des variances (grâce au test de Fisher) et la variable doit suivre une loi normale dans chaque population. n doit être inférieur à 30.
- D. Faux. Il n'y a pas de degré de liberté avec le test de l'écart réduit.

- E. Faux. On les utilise aussi pour les échantillons appariés mais en travaillant sur les différences.
- F. Faux.

QCM n°9: D

- A. Faux. Le test de Fisher permet de comparer des variances, le test exact de Fisher permet de comparer 2 pourcentages observés.
- B. Faux. On veut vérifier les conditions d'application de certains tests paramétriques qui exigent que les variances soient identiques (test de student)
- C. Faux. T_{obs} est un rapport de variances et non d'écart type!!
- D. **Vrai.** Le test F permet de vérifier les conditions d'utilisation du test de Student pour comparer 2 moyennes observées sur des échantillons indépendants.
- E. Faux. Attention car ANOVA permet de comparer des moyennes par l'analyse de la variance!
- F. Faux.

QCM n°10: D, E

- A. Faux. Ce sont les effectifs attendus (théoriques) qui doivent être supérieurs à 5. Ici c'est le cas, on peut donc appliquer le test du χ^2 .
- B. Faux. Le test du χ^2 d'homogénéité et de l'écart-réduit sont permis, on préfère donc les utiliser. Le test exact de Fisher est aussi permis mais sera plutôt employé pour de petits échantillons
- C. Faux. On réalise d'abord le tableau des effectifs théoriques. Chaque case est le résultat du produit de la ligne * le produit de la colonne divisé par le nombre total de l'échantillon.

$34 \cdot 127 / 200 = 21,59$	$166 \cdot 127 / 200 = 105,41$
$34 \cdot 73 / 200 = 12,41$	$166 \cdot 73 / 200 = 60,59$

On calcule ensuite la "distance" entre les deux tableaux. O_{ij} sont les effectifs calculés et E_{ij} sont les effectifs théoriques.

$$T_{obs} = \sum (O_{ij} - E_{ij})^2 / E_{ij}$$

$$= (18 - 21,59)^2 / 21,59 + (109 - 105,41)^2 / 105,41 + (16 - 12,41)^2 / 12,41 + (57 - 60,59)^2 / 60,59$$

$$= 1,97$$

- D. **Vrai.**
- E. **Vrai.** $t_{obs} < \chi^2$, on ne rejette pas H_0 .
- F. Faux.

QCM n°11: A, B, C

- A. **Vrai.** $p = 13/75 = 17,33\%$
- B. **Vrai.** Les conditions d'applications sont $np > 5$ et $n(1-p) > 5$
- C. **Vrai.** $T_{obs} = (0,1733 - 0,09) / \sqrt{(0,1733 * (1 - 0,1733) / 75)} = 1,91$
- D. Faux. La formulation de l'hypothèse H_0 impose de faire un test en bilatéral, on n'a pas d'a priori sur le sens de la différence.

On a $T_{obs} = 1,91 < 1,96$, on ne rejette donc pas H_0 . Attention car même si on avait pu rejeter H_0 , on n'aurait pas pu conclure que les PACES sont plus susceptibles de déprimer ; on aurait seulement pu conclure à une différence significative entre le nombre de déprimés dans la population générale et chez les PACES.

- E. Faux. $T_{obs} = (0,1733 - 0,09) / \sqrt{(0,1733 * (1 - 0,1733) / 80)} = 1,968$ qui est supérieur à 1,96. Cela montre qu'avec un plus grand échantillon, une différence est plus facile à montrer.
- F. Faux.

QCM n°12 : D, E

- A. Faux. Ils doivent être supérieurs ou égaux à 5.

- B. Faux. Le χ^2 suit une loi à (r-1)ddl avec r le nombre de classes. Donc 3 ddl pour cet exemple.
- C. Faux. D'abord il faut calculer les effectifs attendus d'après les fréquences de la population française.

A	$0,44 \cdot 2369 = 1042,36$
O	$0,45 \cdot 2369 = 1066,05$
B	$0,08 \cdot 2369 = 189,52$
AB	$0,03 \cdot 2369 = 71,07$

$$\chi^2_{\text{obs}} = (1018-1042,36)^2/1042,36 + (1113-1066,05)^2/1066,05 + \dots = 23,30$$

Attention, 23,55 c'est ce que l'on trouve lorsqu'on utilise les valeurs approchées, donc attention à vos arrondis.

- D. **Vrai.** On lit dans la table à $\alpha=5\%$ et 3ddl. $23,30 > 7,815$
- E. **Vrai.** On lit dans la table à $\alpha=0,1\%$ et 3ddl. $23,30 > 16,266$.
- F. Faux.

QCM 13 : A, B, C, E

- A. **Vrai.**
- B. **Vrai.** $\chi^2_{\text{obs}} = \frac{(f-g)^2}{f+g} = \frac{(50-30)^2}{50+30} = 5$
- C. **Vrai.** χ^2_{α} à 1 ddl et à 5% est 3.841
- D. Faux. $\chi^2_{\text{obs}} > \chi^2_{\alpha}$ donc on rejette H_0
- E. **Vrai.** $\chi^2_{\alpha} = 5,412$ donc $\chi^2_{\text{obs}} < \chi^2_{\alpha}$ donc on ne rejette pas H_0
- F. Faux.

QCM n°14 : A, C, D

- A. **Vrai.** On cherche un lien
- B. Faux. $T_{\text{obs}} = \frac{\sum(O_{ij} - E_{ij})^2}{E_{ij}}$
- C. **Vrai.** (r-1)(k-1) ddl = (3-1)(2-1) = 2 ddl
- D. **Vrai.** χ^2_{α} à 2 ddl et $\alpha=5\%$ est de 5.991 donc $\chi^2_{\text{obs}} > \chi^2_{\alpha}$ donc on rejette H_0 donc on met en évidence un lien statistique entre le système rhésus et la nature de la maladie
- E. Faux. χ^2_{α} à 2 ddl et $\alpha=1\%$ est de 9.210 donc $\chi^2_{\text{obs}} < \chi^2_{\alpha}$ donc on ne rejette pas H_0 donc on ne met pas en évidence un lien statistique entre le système rhésus et la nature de la maladie
- F. Faux.