

ÉLÉMENTS DE CORRECTION DU CONTRÔLE CONTINU # 2

Questions de cours (3 points)

1. Énoncer la loi des grands nombres. 1,5 points

Soient X_1, X_2, \dots des variables aléatoires indépendantes et identiquement distribuées, telles que $\mathbb{E}[|X_1|] < +\infty$. Alors lorsque n tend vers l'infini, avec probabilité un, on a la convergence

$$\frac{X_1 + \dots + X_n}{n} \xrightarrow{n \rightarrow +\infty} \mathbb{E}[X_1].$$

2. Soit $(\Omega, \mathcal{F}, \mathbb{P})$ un espace de probabilité. Si A, B , et C sont trois événements, à quelle condition sont-ils mutuellement indépendants? 1,5 points

Les événements A, B , et C sont mutuellement indépendants si

$$\begin{aligned} \mathbb{P}(A \cap B) &= \mathbb{P}(A)\mathbb{P}(B), & \mathbb{P}(A \cap C) &= \mathbb{P}(A)\mathbb{P}(C), & \mathbb{P}(B \cap C) &= \mathbb{P}(B)\mathbb{P}(C), \\ \text{et } \mathbb{P}(A \cap B \cap C) &= \mathbb{P}(A)\mathbb{P}(B)\mathbb{P}(C). \end{aligned}$$

Exercice 1 La stratégie de l'échec (9 points)

Un test d'évaluation comporte 100 questions, chaque question ayant 5 réponses possibles A, B, C, D ou E , dont une seule est correcte. Les auteurs du test font en sorte que les bonnes réponses soient réparties uniformément au hasard entre les réponses A, B, C, D et E .

1. Combien y a-t-il de réponses possibles au test? 1 point

Pour chaque question, il y a 5 réponses possibles et il y a 100 questions. Le nombre total de réponses distinctes est donc 5^{100} .

2. Un premier candidat répond totalement au hasard. Quelle est alors la loi du nombre de bonnes réponses? Quelle est la probabilité qu'il ait entre 20 et 22 bonnes réponses (on attend un résultat exact, sous forme littérale)? 2 points

Avec cette stratégie, à chaque question, la probabilité d'avoir la bonne réponse est $p = 1/5$. Le nombre total N de bonnes réponses aux $n = 100$ questions suit alors une loi binomiale $B(n, p)$ i.e. $N \sim B(100, 1/5)$ ici. On a alors

$$\begin{aligned} \mathbb{P}(20 \leq N \leq 22) &= \mathbb{P}(N = 20) + \mathbb{P}(N = 21) + \mathbb{P}(N = 22) \\ &= \binom{100}{20} \left(\frac{1}{5}\right)^{20} \left(\frac{4}{5}\right)^{80} + \binom{100}{21} \left(\frac{1}{5}\right)^{21} \left(\frac{4}{5}\right)^{79} + \binom{100}{22} \left(\frac{1}{5}\right)^{22} \left(\frac{4}{5}\right)^{78}. \end{aligned}$$

3. À l'aide d'une approximation de la loi binomiale, donner une estimation numérique de cette probabilité. 2 points

D'après le cours, comme $n = 100 > 30$, $np = 20 > 5$ et $np(1-p) = 16 > 5$, on peut approcher la loi $B(100, 1/5)$ de la variable N par la loi normale $\mathcal{N}(20, 16)$. Autrement dit $(N - 20)/4 \approx \mathcal{N}(0, 1)$ et

$$\begin{aligned} \mathbb{P}(20 \leq N \leq 22) &= \mathbb{P}\left(0 \leq \frac{N - 20}{4} \leq \frac{1}{2}\right) \approx \mathbb{P}\left(0 \leq \mathcal{N}(0, 1) \leq \frac{1}{2}\right) \\ &= \mathbb{P}\left(\mathcal{N}(0, 1) \leq \frac{1}{2}\right) - \mathbb{P}(\mathcal{N}(0, 1) < 0) = 0.191. \end{aligned}$$

4. Un deuxième candidat suit une autre stratégie : il répond systématiquement la réponse D . Quelle est la loi du nombre de bonnes réponses avec cette stratégie ? Justifier. **2 points**
 D'après l'énoncé, les bonnes réponses sont réparties uniformément parmi A, B, C, D, E , aussi à chaque question, le second candidat a une chance sur 5 de donner la bonne réponse. Comme précédemment, le nombre \tilde{N} du second candidat suit donc une loi binomiale $B(100, 1/5)$.
5. Estimer la probabilité que le second candidat ait entre 20 et 24 bonnes réponses ? **2 points**
 On utilise à nouveau l'approximation binomiale :

$$\begin{aligned} \mathbb{P}(20 \leq \tilde{N} \leq 24) &= \mathbb{P}\left(0 \leq \frac{\tilde{N} - 20}{4} \leq 1\right) \approx \mathbb{P}(0 \leq \mathcal{N}(0, 1) \leq 1) \\ &= \mathbb{P}(\mathcal{N}(0, 1) \leq 1) - \mathbb{P}(\mathcal{N}(0, 1) < 0) = 0.341. \end{aligned}$$

Exercice 2 Hypertension (8 points)

Dans deux pays A et B aux habitudes alimentaires distinctes, on considère un échantillon de 500 personnes (300 hommes et 200 femmes à chaque fois), dont on mesure la tension artérielle.

1. Dans la population A , on veut tester au niveau de confiance 95%, s'il existe un lien entre le genre d'un individu et sa tension artérielle.
- (a) Parmi les statistiques présentées au verso, laquelle faut-il considérer ici ? Justifier. **1 point**
 Il s'agit de faire un test du χ^2 d'indépendance, précisément, au niveau de confiance 95%, on veut tester l'hypothèse H_0 : "tension et genre sont indépendants" contre l'hypothèse H_1 : "tension et genre ne sont pas indépendants". Le tableau des fréquences empiriques est le suivant :

Observé	Hypertension	Tension normale	Hypotension	Total
Homme	72/500	192/500	36/500	300/500
Femme	38/500	118/500	44/500	200/500
Total	110/500	310/500	80/500	500/500

La statistique empirique du χ^2 associée est la statistique B) du verso, i.e.

$$F_{500}^{obs} = 500 \times \left(\left(\frac{\left(\frac{72}{500} - \frac{110 \cdot 300}{500 \cdot 500} \right)^2}{\frac{110 \cdot 300}{500 \cdot 500}} \right) + \dots + \left(\frac{\left(\frac{44}{500} - \frac{80 \cdot 200}{500 \cdot 500} \right)^2}{\frac{80 \cdot 200}{500 \cdot 500}} \right) \right) \approx 9,35.$$

- (b) Expliciter la zone de rejet du test et conclure. **1 point**
 Par ailleurs, sous l'hypothèse H_0 , la statistique du χ^2 suit une loi du χ^2 à $(3 - 1) \times (2 - 1) = 2$ degrés de liberté. D'après les données numériques de l'énoncé, on a $\mathbb{P}(\chi^2(2) > 5,99) = 95\%$ de sorte que la région de rejet du test d'indépendance est $W = \{F_{500} > 5,99\}$. Ici, on a clairement $F_{500}^{obs} \in W$ de sorte que l'on rejette l'hypothèse H_0 au niveau 95%.
2. On s'intéresse plus particulièrement à la population masculine. On souhaite savoir si les fréquences des hypertendus/"normaux"/hypotendus sont les mêmes dans les deux pays A et B . À cette fin, au niveau de confiance 95%, on met en place un test du χ^2 d'adéquation des fréquences de la population B à la loi cible $\pi = (72/300, 192/300, 36/300)$.
- (a) Parmi les statistiques présentées au verso, laquelle faut-il considérer ici ? Justifier. **1 point**
 Si p désigne le vecteur des fréquences théoriques dans la population B , il s'agit ici de tester, au niveau 95%, l'hypothèse H_0 : " $p = \pi$ " contre H_1 : " $p \neq \pi$ ". La statistique du χ^2 est associée est la statistique F) du verso i.e.

$$F_{300}^{obs} = 300 \times \left(\left(\frac{\left(\frac{75}{300} - \frac{72}{300} \right)^2}{\frac{72}{300}} \right) + \dots + \left(\frac{\left(\frac{38}{300} - \frac{36}{300} \right)^2}{\frac{36}{300}} \right) \right) \approx 0,37.$$

- (b) Expliciter la zone de rejet du test et conclure. **1 point**

Par ailleurs, sous l'hypothèse H_0 , la statistique théorique suit une loi du χ^2 à $(3-1) = 2$ degrés de liberté. On a toujours $\mathbb{P}(\chi^2(2) > 5,99) = 95\%$ de sorte que la région du test d'indépendance est $W = \{F_{300} > 5,99\}$. Ici, on a clairement $F_{300}^{obs} \notin W$ de sorte que l'on ne rejette pas l'hypothèse d'indépendance au niveau 95%.

3. Sans faire de distinction entre homme et femme, on souhaite enfin déterminer, au niveau de confiance 90%, si les proportions d'hypertendus sont les mêmes dans les pays A et B .

- (a) Répondre à question en effectuant un test du χ^2 d'adéquation. **2 points**

Dans la population hypertendue, on désigne par p la proportion d'individus issus du pays A , de sorte que la proportion d'individus issus de B est $1 - p$. Il s'agit d'effectuer, au niveau de confiance 90%, un test du χ^2 d'adéquation de $H_0 : "(p, 1 - p) = (1/2, 1/2)"$ contre l'hypothèse $H_1 : "(p, 1 - p) \neq (1/2, 1/2)"$. Les proportions empiriques sont ici $\hat{p} = 110/215$ et $1 - \hat{p} = 105/215$ de sorte que la statistique empirique du χ^2 vaut

$$F_{215}^{obs} = 215 \times \left(\left(\frac{\left(\frac{110}{215} - \frac{1}{2}\right)^2}{\frac{1}{2}} \right) + \left(\frac{\left(\frac{105}{215} - \frac{1}{2}\right)^2}{\frac{1}{2}} \right) \right) \approx 0,12.$$

Par ailleurs, sous l'hypothèse H_0 , la statistique théorique du χ^2 suit une loi du χ^2 à $(2 - 1) = 1$ degré de liberté. D'après les données numériques du verso de l'énoncé, on a $\mathbb{P}(\chi^2(1) > 2,71) = 90\%$ de sorte que la région de rejet du test d'indépendance est $W = \{F_{215} > 2,71\}$. Ici, on a clairement $F_{215}^{obs} \notin W$ de sorte que l'on ne rejette pas l'hypothèse H_0 au niveau 90%.

- (b) Répondre à question en effectuant un test basé sur une approximation gaussienne de la loi binomiale. **2 points**

Si dans la population hypertendue, on désigne encore par p la proportion d'individus issus du pays A , il s'agit de tester l'hypothèse $H_0 : "p = 1/2"$ contre l'hypothèse $H_1 : "p \neq 1/2"$. Ici la fréquence empirique observée est $\hat{p}^{obs} = 110/215$. Sous l'hypothèse H_0 , le nombre de personnes issues de A dans la population hypertendue suit une loi binomiale $B(215, 1/2) \approx \mathcal{N}((215/2), 215/4)$ et la fréquence théorique suit donc approximativement une loi $\mathcal{N}(1/2, 1/(4 \times 215))$. Autrement dit, sous H_0 ,

$$2\sqrt{215} \left(\hat{p} - \frac{1}{2} \right) \sim \mathcal{N}(0, 1).$$

D'après les données numériques $\mathbb{P}(|\mathcal{N}(0, 1)| > 1,64) = 10\%$ de sorte que sous H_0 :

$$\mathbb{P} \left(\hat{p} \notin \left[\frac{1}{2} - \frac{1,64}{2\sqrt{215}}, \frac{1}{2} + \frac{1,64}{2\sqrt{215}} \right] \right) = 10\%.$$

Autrement dit l'ensemble

$$W = [0, 1] \setminus \left[\frac{1}{2} - \frac{1,64}{2\sqrt{215}}, \frac{1}{2} + \frac{1,64}{2\sqrt{215}} \right] \approx [0, 1] \setminus [0,44, 0,56] \approx [0, 0,44] \cup [0,56, 1]$$

constitue une zone de rejet pour le test au niveau 90%. Ici $\hat{p}^{obs} = 110/215 \approx 0,51$ de sorte que $\hat{p}^{obs} \notin W$ et comme plus haut, on ne rejette pas l'hypothèse H_0 au niveau de confiance 90%.