

Contrôle : Statistique inférentielle

Patrick Tardivel
Université de Bourgogne

19/05/2022

Exercice 1. (4 points) La proportion d'informaticiennes parmi les informaticiens est de 20%. Dans un institut d'informatique de 50 personnes il y a seulement 5 informaticiennes. On pose p la probabilité inconnue que cet institut recrute une informaticienne lors d'une embauche. Peut-on dire que la probabilité de recruter une informaticienne lors d'une embauche est significativement inférieure à 20% ?

1. Faire un test statistique au niveau 5% pour conclure en rédigeant soigneusement chaque étape.
2. Calculer la p -valeur.
3. Calculer la puissance de ce test lorsque $p = 0,10$.

Indication : Soit X une variable aléatoire de loi binomiale $\mathcal{B}(50; 0,20)$. On pourra utiliser la fonction de répartition de X donnée ci-dessous :

k	0	1	2	3	4	5	6	7
$\mathbb{P}(X \leq k)$	0,00001	0,00019	0,00128	0,00565	0,018496	0,04802	0,10339	0,19040

Soit X une variable aléatoire de loi binomiale $\mathcal{B}(50; 0,1)$. On pourra utiliser la fonction de répartition de X donnée ci-dessous :

k	0	1	2	3	4	5	6	7
$\mathbb{P}(X \leq k)$	0,00515	0,03378	0,11172	0,25029	0,43119	0,61612	0,77022	0,87785

Exercice 2. (4 points) Deux types de calmants A et B sont administrés à des malades ayant subi une opération. Sur 754 malades ayant absorbé le calmant A , 301 ont déclaré leur douleur atténuée. Sur 587 malades ayant absorbé le calmant B , 198 ont déclaré leur douleur atténuée. Peut-on dire que les calmants ont une efficacité significativement différente.

1. Faire un test statistique au niveau 5% pour conclure en rédigeant soigneusement chaque étape.
2. Calculer la p -valeur.

Remarque (exercices 3 et 4) : on rappelle que pour une variable aléatoire réelle R de densité f_R et pour un entier k on a $\mathbb{E}(R^k) = \int_{\mathbb{R}} x^k f_R(x) dx$.

Exercice 3. (6 points) Soit X_1, \dots, X_n un n -échantillon d'une loi de densité

$$f_{\theta}(x) = \frac{x}{\theta} \exp\left(-\frac{x^2}{2\theta}\right) \mathbf{1}(x > 0), \text{ avec } \theta > 0.$$

1. Vérifier que f_{θ} est bien une densité.
2. Calculer l'estimateur $\hat{\theta}$ du maximum de vraisemblance de θ .
3. On pose $I_k(\theta) = \int_0^{+\infty} x^k f_{\theta}(x) dx$. Soit $k \in \mathbb{N}$, vérifier que $I_{k+2}(\theta) = (k+2)\theta I_k(\theta)$.
4. Dédurre de la question précédente que $\hat{\theta}$ est un estimateur sans biais pour θ puis calculer $EQM_{\theta}(\hat{\theta})$.

Exercice 4. (6 points) La méthode de Monte-Carlo permet de calculer numériquement une intégrale. Des étudiants souhaitent évaluer cette méthode sur un exemple très simple : le calcul numérique de $A = \int_0^1 x^2 dx = 1/3$ et comparer la méthode Monte-Carlo à une seconde méthode naïve.

Comparaison des deux méthodes :

Les deux estimateurs pour A sont définis ci-dessous :

Méthode de Monte-Carlo : Soit U_1, \dots, U_n des variables aléatoires iid de loi uniforme sur $[0, 1]$. On pose $T_1 = \frac{1}{n} \sum_{i=1}^n U_i^2$.

Méthode naïve : Soient les variables aléatoires suivantes permettant de modéliser le tirage uniforme de points dans $[-1, 1]^2 \subset \mathbb{R}^2$:

— X_1, \dots, X_n (pour les abscisses) des variables aléatoires iid de loi uniforme sur $[-1, 1]$

— Y_1, \dots, Y_n (pour les ordonnées) des variables aléatoires iid de loi uniforme sur $[-1, 1]$.

On admet que $\mathbb{P}(X_i^2 \leq Y_i) = A$, il est alors naturel d'estimer A via la statistique suivante : $T_2 = \frac{1}{n} \sum_{i=1}^n \mathbf{1}(X_i^2 \leq Y_i)$.

1. Est-ce que T_1 et T_2 sont des estimateurs biaisés pour A ?
2. Calculer l'erreur quadratique moyenne $EQM_A(T_1)$ et $EQM_A(T_2)$ des estimateurs T_1 et T_2 . Quel estimateur est le plus performant pour estimer A au sens de l'erreur quadratique moyenne ?

Intervalle de confiance pour A :

1. Justifiez la limite suivante :

$$\lim_{n \rightarrow +\infty} \mathbb{P} \left(T_2 - 1.96 \sqrt{\frac{2}{9n}} \leq A \leq T_2 + 1.96 \sqrt{\frac{2}{9n}} \right) = 0,95.$$

En déduire le nombre n de tirages à effectuer pour obtenir, au niveau de confiance 95%, une estimation de A avec la méthode naïve ayant une précision égale à 0,01.

2. Justifiez la limite suivante :

$$\lim_{n \rightarrow +\infty} \mathbb{P} \left(T_1 - 1.96 \sqrt{\frac{4}{45n}} \leq A \leq T_1 + 1.96 \sqrt{\frac{4}{45n}} \right) = 0,95.$$

En déduire le nombre n de tirages à effectuer pour obtenir, au niveau de confiance 95%, une estimation de A avec la méthode de Monte-Carlo ayant une précision égale à 0,01.

3. On considère le code R suivant :

```
n=1000
U=runif(n)
Estimateur=mean(U^2)
q=qnorm(0.975)
I=c(Estimateur-q*sqrt(4/45)/sqrt(n),Estimateur+q*sqrt(4/45)/sqrt(n))
```

dans ce code, que représentent : $Estimateur$, q ? Comment modifier ce code pour que I soit un intervalle de confiance pour A de niveau 0,90 ?