

Rappels de statistique mathématique
Enoncé des travaux dirigés n°7

Guillaume Lacôte
Bureau **E03**

✉ Guillaume.Lacote@ensae.fr

☞ <http://ensae.no-ip.com/SE222/>

Enoncé de l'exercice 1

Pour étudier l'arrivée des appels dans un central téléphonique, on comptabilise lors de 2 observations consécutives, le nombre d'appels observés par seconde, ce qui produit les résultats suivants :

Nombre d'appels par seconde	Effectifs observés
0	6
1	15
2	40
3	42
4	37
5	30
6	10
7	9
8	5
9	3
10	2
11	1

On suppose les arrivées des appels indépendantes, et en outre que la probabilité élémentaire λdt qu'il arrive un appel entre les instants t et $t + dt$ est indépendante de la date t .

Autrement dit

- le nombre N_t d'appels observés sur l'intervalle de temps $[0, t]$ suit une loi de Poisson de paramètre λt .
- plus généralement $N_{t+s} - N_t$ est indépendant de N_t et suit une loi de Poisson de paramètre λs .

- ☞ Q1 (a) Tester l'adéquation de la loi empirique à la famille des lois de Poisson.
(b) Quel est le niveau limite permettant d'accepter l'adéquation à la loi de Poisson ?
- ☞ Q2 A une date antérieure le nombre d'appels sur un intervalle de temps $[0, t]$ suivait une loi de Poisson de paramètre 4.
Tester la stabilité du comportement entre les deux dates.
- ☞ Q3 Que donnerait un test d'adéquation à une loi de Poisson de paramètre 3,7 ? Conclure.

Table de la loi de Poisson :

	$\mathbb{P}_{3,7}(X = k)$	$\mathbb{P}_4(X = k)$
0	0.0247	0,0183
1	0.0915	0,0733
2	0.1684	0,1465
3	0.2087	0,1957
4	0.1930	0,1954
5	0.1428	0,1563
6	0.0881	0,1042
7	0.0465	0,0595
8	0.0215	0,0298
9	0.0099	0,0132
10	0.0046	0,0053
11	0.0021	0,0019
12	0.0001	0,0006
13	< 0.0001	0,0002
14	< 0.0001	0,0001

Enoncé de l'exercice 2

On s'intéresse à la proportion des ménages équipés d'un magnétoscope. Pour cela, on tire de manière équiprobable avec remise un échantillon de n ménages, et on observe pour chaque ménage $i \in \llbracket 1, n \rrbracket$ la variable

$$y_i = \begin{cases} 1 & \text{si le ménage } i \text{ est équipé} \\ 0 & \text{sinon.} \end{cases}$$

- ☞ Q1 Réaliser un test de l'hypothèse nulle : "la proportion des ménages équipés n'excède pas 20 %".
 - ☞ Q2 On se demande si la probabilité qu'un ménage i soit équipé n'est pas fonction d'une variable (scalaire) x_i donnée (revenu, âge du chef de famille...).
- On définit à cet effet un modèle statistique conditionnel à X_i de la façon suivante :

$$\mathbb{P}(y_i = 1 \mid x_i) = \frac{e^{a+bx_i}}{1 + e^{a+bx_i}}$$

où a et b sont deux paramètres réels inconnus.

On cherche alors à tester $H_0 : b = 0$.

- (a) Calculer le score et la matrice d'information de Fisher du modèle pour n observations.

- (b) Expliciter le modèle contraint par H_0 .
Calculer les estimateurs du maximum de vraisemblance \hat{a}^0 et \hat{b}^0 de a et b dans ce modèle puis évaluer le score en (\hat{a}^0, \hat{b}^0) .
- (c) Donner un estimateur $\hat{I}_1^{H_0}$ de I_1 , convergent sous H_0 et fonction des estimateurs construits des paramètres.
- (d) Exprimer la statistique du test du score de l'hypothèse H_0 .
Quelle est sa loi asymptotique sous H_0 ? Sur quelle corrélation repose le test?

Enoncé de l'exercice 3

Un industriel reçoit K lots de n pièces, avec la garantie que la proportion p de pièces défectueuses est la même dans chaque lot et inférieure à 5%. Pour vérifier que la garantie est exacte, on tire avec remise des pièces dans chaque lot, jusqu'à obtenir une pièce défectueuse par lot. Soit Y_k , la variable aléatoire désignant le nombre de tirages nécessaires dans le lot k .

- ☞ Q1 Calculer la loi de Y_k .
Calculer $\mathbb{E}(Y_k)$ et $\mathbb{V}(Y_k)$.
- ☞ Q2 Proposer un test de Wald de l'hypothèse :
 $H_0 : p = 5\%$
- ☞ Q3 Soit $A_k = \{\bar{Y} < k_\alpha\}$, pour k_α donné; calculer $\mathbb{P}_p(A_k)$ en fonction de $p = p_0$.
Montrer que $\sup_{p \leq 5\%} (\lim_{K \rightarrow \infty} \mathbb{P}_p(A_k)) = \lim_{K \rightarrow \infty} \mathbb{P}_{p=5\%}(A_k)$.
En déduire un test asymptotique de l'hypothèse :
 $H_0 : p \leq 5\%$

Enoncé de l'exercice 4

On dispose de n observations i.i.d. d'un couple de variables aléatoires positives scalaires (W_i, X_i) .

Le but de l'exercice est de suggérer une procédure pour tester l'hypothèse H_0 selon laquelle la loi conditionnelle de W_i sachant X_i est une loi de Pareto, de densité :

$$f(W|X, b) = \frac{bX}{W_0} \left(\frac{W_0}{W}\right)^{bX+1} \mathbf{1}_{W \geq W_0}$$

pour $b > 0$ et $W_0 > 0$

☞ Q1 On suppose dans un premier temps que les X_i sont tous égaux à $X \in \mathbb{R}$ connu, et que W_0 est connu, de sorte que le seul paramètre inconnu du modèle est $\alpha = bX + 1$.

- Calculer l'espérance et la variance de W , notées m et v .
A quelle condition sur α , supposée vérifiée par la suite, les moments m et v existent-ils ?
- Déterminer l'estimateur du maximum de vraisemblance $\hat{\alpha}$ de α .
- Déterminer le score et l'information de Fisher du modèle.
En déduire $\mathbb{E}(\ln W)$ et $\mathbb{E}((\ln W)^2)$.
- Soit $s = \frac{1}{n} \sum_{i=1}^n (\ln(W_i) - \overline{\ln W})^2$, où $\overline{\ln W}$ est la moyenne empirique des logarithmes de W_i .
On se propose de fonder un test de H_0 sur la différence :

$$s - \frac{1}{(\hat{\alpha} - 1)^2}$$

Justifier un tel test.

- Ecrire le Théorème Central Limite pour $(\ln W_i, (\ln W_i)^2)_{i \in [1, N]}$, et tester l'hypothèse H_0 (On donnera la forme de la matrice de variance-covariance sans pour autant la calculer explicitement).

☞ Q2 On suppose toujours W_0 connu, mais les X_i prennent désormais des valeurs a priori distinctes.

- Calculer l'estimateur du maximum de vraisemblance de b .
- Montrer que : $\mathbb{E} \left(X^2 \left(\ln \frac{W_0}{W} \right)^2 - \frac{2X}{b} \ln \frac{W_0}{W} \right) = 0$.
Comment testeriez-vous alors l'hypothèse H_0 ?

☞ Q3 On suppose enfin que W_0 est inconnu.

- Calculer l'estimateur du maximum de vraisemblance de W_0 .
- Peut-on adapter la procédure de test précédemment mise-en-œuvre ?