

Rappels de statistique mathématique  
*Enoncé des travaux dirigés n°1*

Guillaume Lacôte

☞ Bureau **E03**

✉ [Guillaume.Lacote@ensae.fr](mailto:Guillaume.Lacote@ensae.fr)

☞ <http://ensae.no-ip.com/SE222/>

Enoncé de l'exercice 1

On dispose d'observations  $Y_i$  relatives au comportement de remboursement ou de non-remboursement d'emprunteurs :

$$Y_i = \begin{cases} 1 & \text{si l'emprunteur } i \text{ rembourse son crédit} \\ 0 & \text{si l'emprunteur } i \text{ est défaillant} \end{cases}$$

Afin de modéliser ce phénomène, on suppose l'existence d'une variable aléatoire  $Y_i^*$  normale d'espérance  $m$  et de variance  $\sigma^2$ , qu'on appellera "capacité de remboursement de l'individu" telle que :

$$Y_i = \begin{cases} 1 & \text{si } Y_i^* \geq 0 \\ 0 & \text{si } Y_i^* < 0 \end{cases}$$

- ☞ Q1 On note  $\Phi$  la fonction de répartition de la loi  $\mathcal{N}(0, 1)$ .  
Exprimer la loi de  $Y_i$  en fonction de  $\Phi$ .
- ☞ Q2 Les paramètres  $m$  et  $\sigma^2$  sont-ils identifiables ?

Enoncé de l'exercice 2

Un système S fonctionne en utilisant deux machines de types différents. Les durées de vie  $X_1$  et  $X_2$  des deux machines suivent des lois exponentielles de paramètres  $\lambda_1$  et  $\lambda_2$ . Les variables aléatoires  $X_1$  et  $X_2$  sont supposées indépendantes.

- ☞ Q1 Montrer que

$$X \sim \mathcal{E}(\lambda) \Leftrightarrow \forall x \in \mathbb{R}, \mathbb{P}(X > x) = \exp(-\lambda x)$$

- ☞ Q2 Calculer la probabilité pour que le système ne tombe pas en panne avant la date  $t$ .  
En déduire la loi de la durée de vie  $Z$  du système.  
Calculer la probabilité pour que la panne du système soit due à une défaillance de la machine 1.
- ☞ Q3 On dispose de  $n$  systèmes  $S_1, \dots, S_n$  identiques dont on observe les durées de vie  $Z_1, \dots, Z_n$ .
  - (a) Ecrire le modèle statistique correspondant et la vraisemblance des observations.  
A-t-on suffisamment d'information pour estimer  $\lambda_1$  et  $\lambda_2$  ?
  - (b) Si on observe à la fois les durées de vie des systèmes et la cause de la défaillance (machine 1 ou 2), écrire le modèle statistique correspondant et la vraisemblance des observations.  
A-t-on alors suffisamment d'information pour estimer  $\lambda_1$  et  $\lambda_2$  ?

☞ Q4 Dans cette question, on considère un seul système  $S$  utilisant une machine de type 1 et une machine de type 2, mais on suppose que l'on dispose d'un stock de  $n_1$  machines de type 1, de durées de vie  $X_1^1, \dots, X_1^{n_1}$ , et d'un stock de  $n_2$  machines de type 2, de durées de vie  $X_2^1, \dots, X_2^{n_2}$ . Quand une machine tombe en panne, on la remplace par une machine du même type, tant que le stock de machines de ce type n'est pas épuisé. Quand cela arrive, on dit que le système  $S$  lui-même est en panne. On note toujours  $Z$  la durée de vie du système.

Le cas  $n_1 = n_2 = 0$  correspond donc à la première question (pas de stock).

- (a) Donner la loi de la somme de  $n$  variables indépendantes qui suivent une loi exponentielle de même paramètre  $\lambda$ .
- (b) Ecrire  $Z$  en fonction des  $X_j^i$  et en déduire  $P(Z \geq t)$  en fonction de certaines lois gamma, dont on précisera les paramètres.

On note alors  $N$  le nombre de machines (des deux types) sorties du stocks quand le système tombe en panne, et  $Z_0$  la durée écoulée avant la première panne d'une machine. On note  $Z_i$  la durée écoulée entre la  $i$ -ème panne et la  $(i + 1)$ -ème panne. La durée de vie totale du système est donc :

$$Z = \sum_{i=0}^N Z_i$$

La  $(N + 1)$ -ème panne est donc la panne fatale au système.

- (c) Montrer que les variables  $Z_i$  sont i.i.d. et donner leur loi. On pourra utiliser (après l'avoir démontré) le résultat suivant : Si  $X$  est une variable aléatoire de loi exponentielle de paramètre  $\lambda$ , alors

$$\mathbb{P}(X \geq s + t | X \geq s) = \mathbb{P}(X \geq t) = e^{-\lambda t}$$

(on dit que  $X$  est "sans mémoire").

- (d) Préciser l'ensemble des valeurs possibles pour la variable  $N$  et en donner la loi.
- (e) On admet que  $N$  et les  $Z_i$  sont indépendantes. Calculer  $\mathbb{E}(Z|N)$  en fonction de  $N, \lambda_1$  et  $\lambda_2$ . Donner l'expression de  $\mathbb{E}(Z)$  en fonction de  $\mathbb{E}(N), \lambda_1$  et  $\lambda_2$ .

### Énoncé de l'exercice 3

Ecrire la vraisemblance et déterminer une statistique exhaustive pour un échantillon de  $n$  observations i.i.d. de lois :

☞ Q1 loi de Poisson de paramètre  $\lambda$  :

$$P(X = k) = e^{-\lambda} \frac{\lambda^k}{k!}, \quad k \in \mathbb{N}^*$$

☞ Q2 loi de Pareto de paramètres  $\alpha$  et  $\theta$  avec  $\alpha > 1, \theta > 0$  de densité :

$$f(x) = \frac{\alpha - 1}{\theta} \left(\frac{\theta}{x}\right)^\alpha \mathbb{1}_{[\theta; +\infty[}(x)$$

☞ Q3 loi de Weibull de paramètre  $\alpha$  et  $\theta$  avec  $\alpha > 0, \theta > 0$  de densité :

$$f(x) = \alpha \theta x^{\alpha-1} e^{-\theta x^\alpha} \mathbb{1}_{[0; +\infty[}(x)$$

☞ Q4 loi uniforme sur  $[0, \theta]$  avec  $\theta > 0$  inconnu.

### Énoncé de l'exercice 4

On veut compter le nombre  $\theta$  de poissons dans un lac fermé. Pour cela, on tire un poisson au hasard, on le marque et on le remet dans le lac. On tire un second poisson. S'il est déjà marqué on en prend note et on le remet dans le lac. Sinon, on le marque à son tour et on le remet dans le lac. Et ainsi de suite.

On tire  $n$  poissons selon la procédure ci-dessus. Au  $n$ -ième tirage, l'observation consiste en une variable aléatoire  $Y_n$  qui vaut 1 si le poisson est déjà marqué, 0 sinon. Par définition, on a  $Y_1 = 0$ . Le but de l'exercice est de montrer que :

$$R_n = \sum_{i=1}^n Y_i$$

est une statistique exhaustive pour  $\theta$ .

☞ Q1 Montrer que :

$$\mathbb{P}(Y_n = y_n, \dots, Y_1 = y_1) = \begin{cases} \mathbb{P}(Y_n = y_n | Y_{n-1} = y_{n-1}, \dots, Y_1 = y_1) \\ \times \mathbb{P}(Y_{n-1} = y_{n-1} | Y_{n-2} = y_{n-2}, \dots, Y_1 = y_1) \\ \vdots \\ \times \mathbb{P}(Y_1 = y_1) \end{cases}$$

☞ Q2 Montrer que la loi conditionnelle de  $Y_n$  sachant  $R_{n-1} = r_{n-1}$  est une Bernoulli de paramètre

$$\frac{n - r_{n-1} - 1}{\theta}$$

et en déduire que la vraisemblance est proportionnelle à :

$$\prod_{i=1}^n \frac{(\theta - i + 1 + r_{i-1})^{1-y_i}}{\theta}$$

☞ Q3 Montrer que l'expression (1) se réécrit :

$$\frac{1}{\theta^n} \frac{(\theta - 1)!}{(\theta - n - 1 + r_n)!}$$

☞ Q4 En déduire que  $R_n$  est une statistique exhaustive pour  $\theta$ .

---