

Rappels de statistique mathématique  
*Enoncé des travaux dirigés n° 5*

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 souhaite évaluer et analyser le phénomène du chômage. Pour cela, on dispose de  $n$  observations sur les durées  $y_i, 1 \leq i \leq n$ , pendant lesquelles des individus sont restés sans emploi. On suppose dans la suite que les variables aléatoires correspondantes  $(Y_i)_{i \in \llbracket 1, n \rrbracket}$  sont i.i.d. et suivent la loi de Weibull de paramètres  $a$  et  $b$ . On rappelle que cette loi est continue sur  $\mathbb{R}^+$  et admet la fonction de répartition pour  $y > 0$

$$F(y; a, b) = 1 - \exp(-ay^b)$$

On définit la fonction de survie par

$$S(y) = 1 - F(y)$$

et la fonction de hasard par  $h(y) = \frac{f(y)}{S(y)}$ .

■ **Partie 1 Généralités**

- ☞ Q1 Donner l'expression de la fonction de hasard du modèle.
- ☞ Q2 Quelle est en terme de chômage l'interprétation de la fonction de hasard ? Expliquer alors pourquoi il est important de considérer le cas particulier où cette fonction est constante. Pour quelles valeurs des paramètres, la fonction de hasard est-elle constante ? Quelles sont alors les lois des durées de chômage ?
- ☞ Q3 Etudier l'évolution de la fonction de hasard en fonction de  $a$ , puis en fonction de  $b$ .

■ **Partie 2 Estimation contrainte**

On suppose dans cette partie  $b = 1$ . Le modèle est alors uniquement paramétré par  $a$ .

- ☞ Q1 Le modèle est-il exponentiel ? Si oui, expliciter une statistique exhaustive.
- ☞ Q2 Déterminer le vecteur du score et vérifier directement qu'il est centré.
- ☞ Q3 Quel est l'estimateur du maximum de vraisemblance  $\hat{a}_0$  de  $a$  ? Est-il sans biais, y a-t-il surestimation ou sous-estimation systématique ?
- ☞ Q4 Déterminer la variance asymptotique de cet estimateur  $\hat{a}_0$

■ **Partie 3 Estimation non contrainte**

On considère maintenant le cas où  $a$  et  $b$  peuvent a priori prendre toutes valeurs positives.

- ☞ Q1 Le modèle est-il exponentiel avec une statistique exhaustive dont la taille est indépendante du nombre  $n$  d'observations ? Si oui, expliciter une telle statistique.
- ☞ Q2 Ecrire les équations de vraisemblance. Sont-elles résolubles sous forme analytique ?

- ☞ Q3 Donner la forme de la variance asymptotique de l'estimateur du maximum vraisemblance  $\begin{pmatrix} \hat{a} \\ \hat{b} \end{pmatrix}$  du paramètre  $\begin{pmatrix} a \\ b \end{pmatrix}$ .
- ☞ Q4 En déduire la variance asymptotique de  $\hat{a}$  lorsque  $b = 1$ . Comparer alors les estimateurs  $\hat{a}$  et  $\hat{a}_0$  lorsque  $b = 1$ . Quelle conclusion en tirer ?
- ☞ Q5 Quelle démarche pourrait-on proposer pour étudier la distribution de l'estimateur  $\begin{pmatrix} \hat{a} \\ \hat{b} \end{pmatrix}$  lorsque l'échantillon est de petite taille, par exemple  $n = 10$  ?

#### ■ Partie 4 Cas indépendant - non équidistribué

On considère maintenant le cas de  $T$  observations  $Y_1, \dots, Y_T$  indépendantes, de lois respectives :

$$F(y; e^{\alpha t}, 1), \quad t \in \llbracket 1, T \rrbracket, \quad \alpha \in \mathbb{R}$$

- ☞ Q1 Déterminer la vraisemblance du modèle  $\mathcal{L}$ , et vérifier qu'elle est concave en  $\alpha$  à  $(y_1, \dots, y_T)$  fixé. En déduire l'équation caractérisant l'estimateur du maximum de vraisemblance  $\widehat{\alpha}_T$  de  $\alpha$ .
- ☞ Q2 On note  $u_t = y_t - e^{-\alpha t}$ . Donner l'interprétation de  $u_t$ .
- ☞ Q3 Montrer que l'équation de la vraisemblance correspond à la condition d'orthogonalité de  $(u_1, \dots, u_T)$  et de  $1, \dots, T$  pour un certain produit scalaire que l'on précisera.

### Énoncé de l'exercice 2

On étudie entre les dates 0 et  $T$  un groupe de  $n$  individus sans emploi à la date 0, et on cherche à modéliser les durées de chômage  $(T_i)_{i \in \llbracket 1, n \rrbracket}$ .

En pratique, on observe les durées de chômage en mois. Plus précisément, on ne dispose pas de la variable continue  $T_i$ , mais seulement de la variable discrète  $T_i^*$  donnée par

$$T_i^* = \lceil T_i \rceil$$

Autrement dit, la variable  $T_i^*$  vaut  $t + 1$  si l'individu  $i$  a retrouvé du travail entre le  $t$ -ème et  $(t + 1)$ -ième mois.

En outre entre  $t$  et  $t + 1$ , on suppose que :

- l'individu  $i$  reçoit  $N_t^i$  offres d'emploi, où  $N_t^i$  est une suite de variables i.i.d. de loi de Poisson  $\mathcal{P}(\lambda)$ ;

- si l'individu  $i$  est toujours au chômage à la date  $t$ , et si parmi les  $N_t^i$  offres qu'il reçoit, l'individu  $i$  au moins offre un salaire supérieur à une constante  $\xi_i$ , propre à l'individu (appelée salaire de réserve), alors l'individu n'est plus au chômage :  $(T_i^* = t + 1)$ ;
  - les salaires des offres d'emploi sont tirés indépendamment des dates d'arrivée des offres et leur nombre dans une loi de fonction de répartition  $F$ .
- On suppose dans un premier temps pour simplifier que  $T = +\infty$ .
- ☞ Q1 Calculer  $\mathbb{P}(T_i^* = t + 1 | T_i > t)$  en fonction de  $F, \xi_i, \lambda$ .
- ☞ Q2 En déduire la vraisemblance de  $(T_1^*, \dots, T_n^*)$ .
- ☞ Q3 On suppose que tous les individus ont le même salaire de réserve :  $\xi_i = \xi$  et que ce salaire de réserve commun  $\xi$  est connu, ainsi que la fonction de répartition  $F$ . Trouver l'estimateur du maximum de vraisemblance de  $\lambda$ . Montrer directement que cet estimateur est convergent et asymptotiquement efficace quand  $n \rightarrow +\infty$ .
- ☞ Q4 En pratique, l'enquête se termine à la fin du  $T$ -ième mois,  $T < +\infty$  : à cette date, certains individus sont encore au chômage ; on n'observe donc que :

$$T_i^{**} = \begin{cases} T_i^* & \text{si } T_i^* \leq T \\ T + 1 & \text{si } T_i^* > T \end{cases}$$

Écrire la vraisemblance des observations  $(T_1^{**}, \dots, T_n^{**})$ .

Donner l'estimateur du maximum de vraisemblance de  $\lambda$ .

Remarque : On suppose toujours le salaire de réserve commun  $\xi$  et la fonction de répartition  $F$  connue.

- ☞ Q5 On suppose désormais que  $F$  s'écrit :

$$F(x) = (1 - e^{-\gamma(\xi - \xi_0)}) \mathbf{1}_{\xi \geq \xi_0}$$

où  $\gamma$  est un paramètre inconnu à estimer et  $\xi_0$  est connu.

Le couple  $(\lambda, \gamma)$  est-il identifiable ?

### Énoncé de l'exercice 3

#### ■ Partie 1 Préliminaire

- ☞ Q1 On rappelle que la loi exponentielle de paramètre  $\lambda$  admet la densité  $f(y, \lambda) = \begin{cases} \lambda e^{-\lambda y}, & \text{si } y \geq 0 \\ 0 & \text{sinon.} \end{cases}$

Soient  $n$  variables aléatoires  $Y_1, \dots, Y_n$  i.i.d. de densité  $f(\cdot, \lambda)$ .

Montrer que  $\sum_{i=1}^n Y_i$  suit une loi de densité  $\lambda^n \frac{y^{n-1}}{(n-1)!} e^{-\lambda y} \mathbf{1}_{[0, +\infty[}(y)$  (on pourra commencer par le montrer pour  $n = 2$  puis procéder par récurrence).

Dans tout le problème,  $Z_i$  et  $C_i$ , pour  $i \in \llbracket 1, n \rrbracket$  désignent des variables aléatoires indépendantes suivant des lois exponentielles de paramètres respectifs  $\lambda, \mu \in \mathbb{R}^{+*}$ .

### ■ Partie 2 Observation parfaite

On dispose d'un échantillon d'observations  $(z_i, c_i)_{i \in \llbracket 1, n \rrbracket}$

- ☞ Q1 Ecrire le modèle statistique correspondant.  
S'agit-il d'une famille exponentielle ? Si oui, peut-on exhiber une statistique exhaustive ?
- ☞ Q2 Quel est l'estimateur du maximum de vraisemblance  $\begin{pmatrix} \hat{\lambda} \\ \hat{\mu} \end{pmatrix}$  du paramètre  $\begin{pmatrix} \lambda \\ \mu \end{pmatrix}$  ?
- ☞ Q3 Déterminer la loi asymptotiquement de  $\begin{pmatrix} \hat{\lambda} \\ \hat{\mu} \end{pmatrix}$ .
- ☞ Q4 Déterminer la loi (à distance finie) de  $\begin{pmatrix} \hat{\lambda} \\ \hat{\mu} \end{pmatrix}$ .  
Est-il biaisé à distance finie ?  
Calculer sa matrice de variance-covariance.
- ☞ Q5 Proposer des estimateurs sans biais optimaux de  $\lambda$  et  $\mu$ , si possible efficaces.

### ■ Partie 3 Observation imparfaite

On suppose dans cette seconde partie que les seules observations disponibles portent sur  $X_i = \text{Min}(Z_i, C_i)$ ,  $i = 1, \dots, n$ .

- ☞ Q1 Calculer la fonction de répartition de la variable  $X_i$  pour  $i \in \llbracket 1, n \rrbracket$
- ☞ Q2 Ecrire le modèle statistique correspondant et déterminer les fonctions identifiables du paramètre  $\begin{pmatrix} \lambda \\ \mu \end{pmatrix}$ .
- ☞ Q3 Quels sont les estimateurs du maximum de vraisemblance de  $\gamma = \lambda + \mu$  fondés :
  - i) sur  $(X_i)_{i \in \llbracket 1, n \rrbracket}$  ;
  - ii) sur  $(Z_i, C_i)_{i \in \llbracket 1, n \rrbracket}$  ?
 Est-il naturel que ces estimateurs soient différents ?
- ☞ Q4 Comparer les propriétés asymptotiques de ces estimateurs.

### ■ Partie 4 Conclusion

- ☞ Q1 Dédurre des parties **I** et **II** l'expression de l'espérance conditionnelle

$$E \left( \frac{1}{\sum_{i=1}^n \min(Z_i, C_i)} \middle| \sum_{i=1}^n Z_i, \sum_{i=1}^n C_i \right)$$


---