

# Intervalle de confiance - Données censurées

## 1 Durées de vie exponentielles: Echantillon complet

Supposons que nous avons enregistré un échantillon complet de  $n$  durées de vie  $T_1, T_2, \dots, T_n$  qui sont i.i.d. suivant une exponentielle dont le taux de défaillance  $\lambda$  est inconnu. La fonction de vraisemblance s'écrit classiquement:

$$L(\lambda; t_1, \dots, t_n) = \lambda^n e^{-\lambda \sum_{j=1}^n t_j} \quad \text{pour } \lambda > 0, t_j > 0, j = 1, \dots, n \quad (1)$$

Le MLE de  $\lambda$  est

$$\lambda^* = \frac{n}{\sum_{j=1}^n t_j} = \frac{n}{\mathcal{T}(T_{(n)})} \quad (2)$$

où  $\mathcal{T}(T_{(n)})$  est le temps total de test défini par la dernière défaillance  $T_{(n)}$ . Etudions les propriétés de cet estimateur et en premier déterminons s'il est biaisé ou non.

Comme  $T_j$  est distribuée exponentiellement de paramètre  $\lambda$ ,  $2\lambda T_j$  sera  $\mathcal{X}^2$  distribué avec deux degrés de liberté pour  $j = 1, \dots, n$ .

La preuve est la suivante:

Comme les  $T_j$  sont indépendants,  $2\lambda \sum_{j=1}^n T_j$  sera  $\mathcal{X}^2$  distribué avec  $2n$  degrés de liberté. Ainsi,

$$\lambda^* = \frac{n}{\sum_{j=1}^n T_j} = \frac{2n\lambda}{2\lambda \sum_{j=1}^n T_j}$$

a la même loi que  $2n\lambda/Z$  où  $Z$  est  $\mathcal{X}^2$  distribué à  $2n$  degrés de liberté. On a

$$E(\lambda^*) = 2n\lambda E\left(\frac{1}{Z}\right)$$

et

$$\begin{aligned} E\left(\frac{1}{Z}\right) &= \int_0^\infty \frac{1}{z} \cdot \frac{1}{2^n} \cdot \frac{1}{\Gamma(n)} \cdot z^{n-1} e^{z/2} dz \\ &= \frac{1}{2(n-1)} \int_0^\infty \frac{1}{2^{n-1}\Gamma(n-1)} z^{n-2} e^{-z/2} dz \\ &= \frac{1}{2(n-1)} \end{aligned}$$

D'où

$$E(\lambda^*) = 2n\lambda \cdot \frac{1}{2(n-1)} = \frac{n}{n-1} \cdot \lambda$$

L'estimateur  $\lambda^*$  est trivialement non biaisé. L'estimateur  $\hat{\lambda}$ , donné par

$$\hat{\lambda} = \frac{n-1}{n} \cdot \lambda^* = \frac{n-1}{\sum_{j=1}^n t_j} = \frac{n-1}{\mathcal{T}(T_{(n)})}$$

est donc non biaisé. Regardons maintenant  $var(\hat{\lambda})$ :

$$var(\hat{\lambda}) = \left(\frac{n-1}{n}\right)^2 \cdot var(\lambda^*) = 4(n-1)^2 \lambda^2 var\left(\frac{1}{Z}\right)$$

où  $Z$  a la même signification que précédemment. Maintenant

$$var\left(\frac{1}{Z}\right) = E\left(\frac{1}{Z^2}\right) - \left[E\left(\frac{1}{Z}\right)\right]^2$$

et

$$E\left(\frac{1}{Z^2}\right) = \int_0^\infty \frac{1}{z^2} \cdot \frac{1}{2^n} \cdot \frac{1}{\Gamma(n)} \cdot z^{n-1} e^{z/2} dz = \frac{1}{4(n-1)(n-2)}$$

Ainsi

$$\begin{aligned} var(\hat{\lambda}) &= 4(n-1)^2 \lambda^2 \cdot \left(\frac{1}{4(n-1)(n-2)} - \frac{1}{4(n-1)^2}\right) \\ &= (n-1) \lambda^2 \cdot \left(\frac{1}{n-2} - \frac{1}{n-1}\right) = \frac{\lambda^2}{n-2} \end{aligned}$$

L'estimateur

$$\hat{\lambda} = \frac{n-1}{\mathcal{T}(T_{(n)})} \tag{3}$$

est alors non biaisé et de variance

$$var(\hat{\lambda}) = \frac{\lambda^2}{n-2} \tag{4}$$

Pour établir un intervalle de confiance à  $\alpha$  pour  $\lambda$ , on utilise le fait que  $2\lambda \sum_{j=1}^n T_j$  est  $\chi^2$  distribué à  $2n$  degrés de liberté. Ainsi

$$Pr \left( z_{\alpha/2, 2n} \leq 2\lambda \sum_{j=1}^n T_j \leq t_{1-\alpha/2, 2n} \right) = \alpha$$

et

$$Pr \left( \frac{z_{\alpha/2, 2n}}{2 \sum_{j=1}^n T_j} \leq \lambda \leq \frac{z_{1-\alpha/2, 2n}}{2 \sum_{j=1}^n T_j} \right) = \alpha$$

Donc un intervalle de confiance à  $\alpha$  pour  $\lambda$  est

$$\left( \frac{z_{\alpha/2, 2n}}{2 \sum_{j=1}^n T_j}, \frac{z_{1-\alpha/2, 2n}}{2 \sum_{j=1}^n T_j} \right) \quad (5)$$

Pour affirmer ou non que le taux de défaillance  $\lambda$  est plus petit qu'un certain  $\lambda_0$ , on formule ce problème comme un problème de test d'hypothèse. On teste

$$H_0 : \lambda \geq \lambda_0 \quad \text{contre} \quad H_1 : \lambda < \lambda_0$$

Comme première étape, construisons le test pour

$$H'_0 : \lambda = \lambda_0 \quad \text{contre} \quad H_1 : \lambda < \lambda_0$$

Il semble raisonnable de rejeter  $H'_0$  quand  $\hat{\lambda} \leq k$ , où  $k$  est déterminé pour donner au test le niveau significatif  $\epsilon$ :

$$Pr(\hat{\lambda} \leq k \mid H'_0) \leq \epsilon$$

Maintenant

$$\begin{aligned} \hat{\lambda} \leq k &\iff \frac{1}{\hat{\lambda}} \geq \frac{1}{k} \\ &\iff \frac{1}{(n-1)} \sum_{j=1}^n T_j \geq \frac{1}{k} \\ &\iff 2\lambda_0 \sum_{j=1}^n T_j \geq \frac{2(n-1)}{k} \cdot \lambda_0 \end{aligned}$$

En introduisant  $2\lambda_0(n-1)/k = c$ , le test peut se ré-écrire comme

$$\text{Rejeter } H'_0 \text{ quand } 2\lambda_0 \sum_{j=1}^n T_j \geq c$$

Sous l'hypothèse  $H'_0$ ,  $2\lambda_0 \sum_{j=1}^n T_j$  est  $\mathcal{X}^2$  distribué à  $2n$  degrés de liberté et, par conséquence,  $c$  est choisi égal à  $z_{\epsilon, 2n}$ .

Intuitivement, le même test peut être utilisé pour tester  $H_0$  contre  $H_1$ . Le test repose sur l'équation

$$\begin{aligned} Pr \left( 2\lambda_0 \sum_{j=1}^n T_j \geq z_{\epsilon, 2n} \mid \lambda \right) &= Pr \left( 2\lambda \sum_{j=1}^n T_j \geq \frac{\lambda}{\lambda_0} z_{\epsilon, 2n} \right) \\ &= 1 - \Gamma_{2n} \left( z_{\epsilon, 2n} \cdot \frac{\lambda}{\lambda_0} \right) \end{aligned} \quad (6)$$

Ici,  $\Gamma_{2n}(z)$  représente la fonction de distribution d'une loi du  $\mathcal{X}^2$  à  $2n$  degrés de liberté, et est donc non décroissante en  $z$ . Par conséquent,  $1 - \Gamma_{2n}(z_{\epsilon, 2n} \cdot \lambda/\lambda_0)$  est non croissante en  $\lambda$  et

$$Pr \left( 2\lambda_0 \sum_{j=1}^n T_j \geq z_{\epsilon, 2n} \mid \lambda \right) \leq \epsilon \quad \text{pour } \lambda \geq \lambda_0$$

avec l'égalité pour  $\lambda = \lambda_0$ . Pour tester

$$H_0 : \lambda \geq \lambda_0 \quad \text{contre} \quad H_1 : \lambda < \lambda_0 \quad (7)$$

on utilise alors le critère de test:

$$\text{Rejeter } H_0 \text{ quand } 2\lambda_0 \sum_{j=1}^n T_j \geq z_{\epsilon, 2n} \quad (8)$$

La fonction de précision du test est donnée par (6).

## 2 Durées de vie exponentielles: Données censurées

Supposons que  $n$  produits identiques et indépendants présentant un taux de défaillance constant  $\lambda$  aient été observées jusqu'à leur défaillance ou bien la date de censure. Soit  $U$  le sous-ensemble des indices correspondant aux temps de fonctionnement non censurés, signifiant que si  $j \in U$  alors le temps  $T_j$  est un temps de défaillance, pour  $j = 1, \dots, n$ . De manière équivalente, soit  $C$  l'ensemble des indices des temps censurés. La fonction de vraisemblance est dans ce cas

$$\begin{aligned} L(\lambda; t_1, t_2, \dots, t_n) &= \prod_{j \in U} f(t_j; \lambda) \prod_{i \in C} R(t_i; \lambda) \\ &= \prod_{j \in U} \lambda e^{-\lambda t_j} \prod_{i \in C} e^{i\lambda t_i} \end{aligned} \quad (9)$$

## 2.1 Censure de type II

Avec une censure de type II, le test de durée de vie est terminé dès qu'on observe  $r$  défaillances. L'ensemble des données contiendra alors  $r$  dates de défaillance et  $n - r$  dates de censure. On peut alors montrer que la fonction de vraisemblance dans ce cas est

$$\begin{aligned} L(\lambda; t_1, t_2, \dots, t_n) &\propto \frac{n!}{(n-r)!} \lambda^r e^{-\lambda[\sum_{j=1}^r t_j + (n-r)t_r]} \\ &= \frac{n!}{(n-r)!} \lambda^r e^{-\lambda \mathcal{T}(t_r)} \text{ pour } 0 < t_1 < t_2 < \dots < t_r \end{aligned}$$

et on détermine l'estimateur du maximum de vraisemblance  $\lambda_{II}^*$  de  $\lambda$  de façon classique:

$$\lambda_{II}^* = \frac{r}{\mathcal{T}(t_r)} \quad (10)$$

Etudions les propriétés d'un tel estimateur. Cherchons en premier lieu sa distribution de probabilité. Si  $D_j$  est l'intervalle de temps entre la  $(j-1)$ -ème à la  $j$ -ème défaillance, alors on a

$$\begin{aligned} T_1 &= D_1 \\ T_2 &= D_1 + D_2 \\ &\vdots \\ T_r &= D_1 + D_2 + \dots + D_r \end{aligned}$$

et

$$\sum_{j=1}^r T_{(j)} = rD_1 + (r-1)D_2 + \dots + D_r$$

On a par ailleurs,

$$(n-r)T_{(r)} = (n-r)(D_1 + D_2 + \dots + D_r)$$

On en déduit la durée totale du test à  $T_{(r)}$ :

$$\begin{aligned} \mathcal{T}(T_{(r)}) &= nD_1 + (n-1)D_2 + \dots + (n-(r-1))D_r \\ &= \sum_{j=1}^r (n-(j-1))D_j \end{aligned}$$

En introduisant la notation suivante:

$$D_j^* = (n-(j-1))D_j \text{ pour } j = 1, 2, \dots, r$$

, on peut facilement montrer que  $2\lambda D_1^*, 2\lambda D_2^*, \dots, 2\lambda D_r^*$  sont indépendants et sont  $\mathcal{X}^2$  distribués, chacun à 2 degrés de liberté. Ainsi,  $2\lambda\mathcal{T}(T_{(r)})$  est  $\mathcal{X}^2$  distribué à  $2r$  degrés de liberté, et on peut l'utiliser pour trouver  $E(\lambda_{II}^*)$ :

$$E(\lambda_{II}^*) = E\left(\frac{r}{\mathcal{T}(T_{(r)})}\right) = 2\lambda r \cdot E\left(\frac{1}{2\lambda\mathcal{T}(T_{(r)})}\right) = 2\lambda r \cdot E\left(\frac{1}{Z}\right)$$

où  $Z$  est  $\mathcal{X}^2$  distribuée à  $2r$  degrés de liberté. Ceci implique que

$$E\left(\frac{1}{Z}\right) = \frac{1}{2(r-1)}$$

Ainsi,

$$E(\lambda_{II}^*) = 2\lambda r \cdot \frac{1}{2(r-1)} = \lambda \cdot \frac{r}{r-1}$$

L'estimateur  $\lambda_{II}^*$  est donc biaisé. Par contre,

$$\hat{\lambda}_{II} = \frac{r-1}{\mathcal{T}(T_{(r)})} \tag{11}$$

est non biaisé. On peut montrer par analogie avec la section précédente que

$$var(\hat{\lambda}_{II}) = \frac{\lambda^2}{r-2}$$

Les intervalles de confiance, de même que les tests pour les hypothèses classiques sur  $\lambda$ , peuvent être dérivés par le fait que  $2\lambda\mathcal{T}(T_{(r)})$  est  $\mathcal{X}^2$  distribué à  $2r$  degrés de liberté. La procédure est la même que pour la section précédente.

## 2.2 Censure de type I

Le fait que le nombre ( $S$ ) de produits qui tombent en panne avec la date  $t_0$  soit stochastique rend ce cas plus difficile à traiter d'un point de vue probabiliste. Nous chercherons cependant à suggérer un estimateur intuitif de  $\lambda$ .

En tout premier lieu, remarquons que les estimateurs de  $\lambda$ , dérivés pour des données complètes ou censurées de type II, pouvaient tous être écrits comme le ratio avec le numérateur égal au "nombre de défaillances observées-1" et le dénominateur égal à la durée totale de test à la fin du test. Intuitivement, il semble raisonnable d'utiliser la même fraction pour une censure de type I.

Dans ce cas, le nombre de défaillances est  $S$  tandis que la durée totale de test est

$$\mathcal{T}(t_0) = \sum_{j=1}^S T_{(j)} + (n - S)t_0 \quad (12)$$

Ainsi,

$$\hat{\lambda}_I = \frac{S - 1}{\mathcal{T}(t_0)}$$

semble être un estimateur raisonnable de  $\lambda$ . On peut montrer que cet estimateur est biaisé pour de petits échantillons. Toutefois, on peut montrer qu'asymptotiquement il possède les mêmes propriétés que celles de  $\hat{\lambda}_{II}$ .