



Deuxième année
2002-2003

Théorie des tests
Séance de travaux dirigés n° 1

Guillaume Lacôte
Bureau **E03**

✉ Guillaume.Lacote@ensae.fr

☞ <http://ensae.no-ip.com//SE207/>

Dernière mise-à-jour: 20030402.10h07

Exercice 1

Dans l'outillage de votre usine vous utilisez une grande quantité de pièces d'un certain modèle. Dans les conditions usuelles d'emploi, vous avez observé que la durée de vie de ces pièces est une variable aléatoire normale dont l'espérance mathématique est $m_0 = 123,5$ heures, et l'écart-type est $\sigma = 19,4$ heures.

Le représentant d'un fournisseur vous propose un nouveau modèle, en promettant un gain de performance en moyenne de 5%, pour une dispersion identique σ .

Vous décidez de tester le nouveau modèle sur un échantillon de $n = 64$ unités. On notera $X_i (i = 1, \dots, 64)$ la durée de vie des pièces testées.

☞ Q1 Soit μ l'espérance mathématique du nouveau modèle. Donner un estimateur sans biais de μ , et la variance de cet estimateur.

☞ Q2 Vous ne voulez pas changer de modèle si le nouveau n'est pas plus performant que l'ancien (hypothèse \mathcal{H}). Plus précisément vous voulez que la probabilité d'adopter à tort le nouveau modèle ne dépasse pas le seuil 0,05.

Quelle est alors la procédure de décision ?

Évaluez le risque que cette procédure vous fasse rejeter le nouveau modèle si l'annonce du représentant est exacte.

Les 64 pièces testées ont eu une durée de vie moyenne égale à 123,5 heures. Que concluez-vous ?

☞ Q3 (*facultatif*) Le représentant conteste cette procédure, prétextant qu'il vaut mieux partir de l'hypothèse \mathcal{H}' , selon laquelle le gain de performance moyen est réellement de 5% (hypothèse \mathcal{H}'). Il souhaite que la probabilité de rejeter à tort le nouveau modèle ne dépasse pas le seuil 0,05.

Quelle est alors la procédure de décision ? Quel est le risque de l'acheteur ? Quel est le résultat de cette procédure au vu des observations faites. Commentez.

☞ Q4 (*facultatif*) Quelle procédure proposez-vous pour égaliser les risques de l'acheteur et du vendeur ? Quel est alors ce risque ?

Corrigé de l'exercice 1

*
* *

Exercice 2

Les fonctions positives considérées sont à valeurs dans $\mathbb{R}^+ \cup \{+\infty\}$. Par convention, pour $a > 0$, $a/0 = +\infty$. Le rapport $0/0$ est indéterminé. Soit x_1, \dots, x_n un échantillon d'observations de variables aléatoires X_1, \dots, X_n i.i.d. uniformes sur l'intervalle $[0, \theta^*]$, avec $\theta^* > 0$. On note $x_{(1,n)} \leq \dots \leq x_{(n,n)}$ l'échantillon ordonné correspondant. Il est associé aux variables aléatoires ordonnées $X_{(1,n)} \leq \dots \leq X_{(n,n)}$.

- ☞ Q1 (a) Montrer que la fonction de répartition $F^{(n)}$ de la variable aléatoire $X_{(n,n)}$ vérifie $F^{(n)}(x) = 0$ pour $x < 0$, $F^{(n)}(x) = 1$ pour $x \geq \theta^*$, et

$$F^{(n)}(x) = \left(\frac{x}{\theta^*}\right)^n \text{ pour } 0 \leq x \leq \theta^*.$$

- (b) Montrer que la fonction de vraisemblance $\theta \rightarrow L_n(\theta)$ de l'échantillon vaut θ^{-n} si $x_{(n,n)} \leq \theta$ et 0 si $x_{(n,n)} > \theta$.
- (c) Montrer que la statistique $X_{(n,n)}$ est exhaustive pour θ . Quel estimateur de θ proposer ?
- (d) Soient $0 \leq \theta_0 < \theta_1$ deux valeurs distinctes du paramètre θ . On souhaite tester l'hypothèse $H_0 = [\theta = \theta_0]$ contre l'alternative $H_1 = [\theta = \theta_1]$. Quelle forme aurait le test le plus puissant de niveau $0 < \alpha < 1$ de H_0 contre H_1 ?

On cherche maintenant à déterminer un test déterministe sans biais de niveau α de $H_0 = [\theta \leq \theta_0]$ contre $H_1 = [\theta > \theta_0]$.

- (a) i. Soient $0 < \theta_0 < \theta_1$ deux valeurs distinctes du paramètre θ . On souhaite d'abord construire un test déterministe de niveau α exactement de l'hypothèse simple $H_0 = [\theta = \theta_0]$ contre l'alternative simple $H_1 = [\theta = \theta_1]$.
- ii. Déterminer $c_{\alpha,n}$ de sorte que le test de région de rejet $W_n = \{(x_1, \dots, x_n) : x_{(n,n)} > c_{\alpha,n}\}$ soit de niveau α exactement. La valeur critique $c_{\alpha,n}$ dépend-elle de θ_1 ?
- (b) b) Proposer une approximation simple de $c_{\alpha,n}$ pour α petit.
- (c) Calculer la puissance du test ainsi construit. Quelle est la limite de cette puissance quand $n \rightarrow \infty$?
- (d) Déterminer précisément la fonction

$$\theta \geq 0 \quad \longrightarrow \quad E_\theta[\mathbf{1}_{W_n}(x_1, \dots, x_n)].$$

Montrer qu'elle est croissante. En déduire que le test est un test déterministe sans biais de niveau α de $H_0 = [\theta \leq \theta_0]$ contre $H_1 = [\theta > \theta_0]$.

- (e) Comment construire un test déterministe sans biais de niveau α de $H_0 = [\theta \geq \theta_0]$ contre $H_1 = [\theta < \theta_0]$?

Corrigé de l'exercice 2

*
* *

Exercice 3

☞ Q1 Variables suivant une loi de Poisson

Soient X_1, \dots, X_n et Y_1, \dots, Y_n deux échantillons de taille $n \geq 1$ de variables aléatoires (va) indépendantes et identiquement distribuées (iid), à valeurs dans l'ensemble \mathbb{N} des entiers naturels. On suppose les va X_i et Y_j indépendantes. On suppose les va X_i issues d'une loi de Poisson de paramètre $\lambda_1 > 0$, et les va Y_j issues d'une loi de Poisson de paramètre $\lambda_2 > 0$. Les paramètres λ_1 et λ_2 sont inconnus. On souhaite étudier un test de $H_0 [\lambda_1 \leq \lambda_2]$ contre $H_1 [\lambda_1 > \lambda_2]$, puis un test de $H_0 [\lambda_1 = \lambda_2]$ contre $H_1 [\lambda_1 \neq \lambda_2]$. On note $T_1 = \sum_{i=1}^n X_i$ et $T_2 = \sum_{j=1}^n Y_j$.

- (a) Exprimer $P \{X_1 = x_1, \dots, X_n = x_n\}$ en fonction de $P \{T_1 = t_1\}$. Pourquoi cela établit-il que T_1 est une statistique exhaustive ?
- (b) Exprimer $P \{T_1 = t_1, T_2 = t_2\}$ sous la forme

$$P \{T_1 = t_1, T_2 = t_2\} = Z_{\mathbf{T}}^{-1}(\theta_1, \theta_2) h_{\mathbf{T}}(t_1, t_2) \exp(\theta_1 t_1 + \theta_2 t_2),$$

en précisant ce que sont θ_1, θ_2 , et en explicitant $Z_{\mathbf{T}}(\theta_1, \theta_2)$ et $h_{\mathbf{T}}(t_1, t_2)$.

☞ Q2 Test bilatéral

On veut tester $H_0 [\lambda_1 = \lambda_2]$ contre $H_1 [\lambda_1 \neq \lambda_2]$. On effectue le changement de paramètre $\tau_1 = \theta_1 - \theta_2, \tau_2 = \theta_2$, d'où

$$\exp(\theta_1 T_1 + \theta_2 T_2) = \exp(\tau_1 T_1 + \tau_2 (T_1 + T_2)),$$

et l'on note $U = T_1 + T_2$.

- (a) Démontrer *de manière détaillée* que la loi conditionnelle de T_1 sachant que $U = u, u \geq 1$, est une loi binomiale $\text{Bin}(u; p = \lambda_1/(\lambda_1 + \lambda_2))$. Exprimer cette loi conditionnelle à l'aide des paramètres θ_1 et θ_2 , en faisant apparaître la différence $\tau_1 = \theta_1 - \theta_2$.
- (b) Montrer *rigoureusement* que le test de $H_0 [\lambda_1 = \lambda_2]$ contre $H_1 [\lambda_1 \neq \lambda_2]$, de niveau de signification α , UPP parmi les tests α -semblables sur l'ensemble $\{\lambda_1 = \lambda_2\}$, admet une région de rejet de la forme

$$0 \leq T_1 \leq a(u) \quad \text{ou} \quad b(u) \leq T_1 \leq u$$

si $U = u$ avec $u \geq 1, a(u) \leq b(u)$ désignant des entiers, et écrire *avec précision* les deux équations permettant de déterminer les entiers $a(u)$ et $b(u)$, en faisant apparaître la symétrie par rapport à $u/2$.

- (c) Si u est assez grand, comment pourrait-on déterminer $a(u)$ et $b(u)$ de manière approchée? Donnez des *formules explicites* de ces approximations de $a(u)$ et $b(u)$, de telle sorte que l'on puisse utiliser ces formules pour implémenter effectivement ce test.

Corrigé de l'exercice 3

- ☞ Q1 (a) Notant $t_1 = \sum_{i=1}^n x_i$ il vient

$$\begin{aligned} \mathbb{P}X_1 = x_1, \dots, X_n = x_n &= \frac{\lambda_1^{t_1}}{x_1! \cdots x_n!} e^{-n\lambda_1} \\ &= \frac{t_1!}{x_1! \cdots x_n!} \frac{e^{(\ln \lambda_1)t_1}}{t_1!} e^{-n\lambda_1} \end{aligned}$$

- (b) Les variables aléatoires T_1 et T_2 suivent chacune une loi de Poisson de paramètre $n\lambda_1$ et $n\lambda_2$ respectivement. Par conséquent pour $i \in \{1, 2\}$ on a

$$\mathbb{P}T_i = t_i = \frac{(n\lambda_i)^{t_i}}{t_i!} e^{-n\lambda_i}$$

et donc

$$\mathbb{P}X_1 = x_1, \dots, X_n = x_n = n^{-t_1} \frac{t_1!}{x_1! \cdots x_n!} \mathbb{P}T_1 = t_1$$

On pose $\theta_i = \ln \lambda_i$; d'après le théorème de factorisation la statistique T_1 est bien exhaustive pour le paramètre θ_1 .

- (c) Par indépendance des variables T_1 et T_2 il vient

$$\begin{aligned} \mathbb{P}T_1 = t_1 \wedge T_2 = t_2 &= \mathbb{P}T_1 = t_1 \cdot \mathbb{P}T_2 = t_2 \\ &= \frac{(n\lambda_1)^{t_1} (n\lambda_2)^{t_2}}{t_1! t_2!} e^{-n(\lambda_1 + \lambda_2)} \\ &= \frac{n^{t_1 + t_2}}{t_1! t_2!} e^{-n(\lambda_1 + \lambda_2)} e^{\ln(\lambda_1)t_1 + \ln(\lambda_2)t_2} \\ &= (e^{n(\lambda_1 + \lambda_2)})^{-1} \cdot \left(\frac{n^{t_1 + t_2}}{t_1! t_2!} \right) \cdot (e^{\ln(\lambda_1)t_1 + \ln(\lambda_2)t_2}) \end{aligned}$$

On pose donc

$$\begin{aligned} Z_{\mathbf{T}}(\theta_1, \theta_2) &= e^{n(e^{\theta_1} + e^{\theta_2})} \\ h_{\mathbf{T}}(t_1, t_2) &= \frac{n^{t_1 + t_2}}{t_1! t_2!} \end{aligned}$$

- ☞ Q2 (a) La démarche est la même que celle présentée en cours.

(b) Le rapport p s'écrit, en divisant par λ_2 :

$$\frac{\lambda_1}{\lambda_1 + \lambda_2} = \frac{e^{\tau_1}}{1 + e^{\tau_1}}$$

Le fait que l'expression ne dépende que de τ_1 est une propriété de la famille des lois exponentielles.

(c) (facultative)

(d) (facultative)

☞ Q3 (a) Cette propriété est démontrée en cours.

(b) Notons $W(u) = \{\hat{E} \leq t_1 \leq a(u)\} \cup \{b(u) \hat{E} \leq t_1 \leq u\}$ la région de rejet. On a

$$\mathbb{P}T_1 \in W(t) \mid U = u = 2^{-u} \sum_{k=0}^{a(u)} C_u^k \frac{e^{k\tau_1}}{(e^{\tau_1} + 1)^u} + 2^{-u} \sum_{k=b(u)}^u C_u^k \frac{e^{k\tau_1}}{(e^{\tau_1} + 1)^u}$$

Les conditions recherchées expriment d'une part que la mesure de la région de rejet $W(u)$ sous H_0 est α lorsque $\tau_1 = 0$, c'est-à-dire

$$\mathbb{P}T_1 \in W(t) \mid U = u = 2^{-u} \sum_{k=0}^{a(u)} C_u^k + 2^{-u} \sum_{k=b(u)}^u C_u^k \approx \alpha$$

et d'autre part que la dérivée de l'application

$$\tau_1 \mapsto \mathbb{P}T_1 \in W(t) \mid U = u$$

est nulle en $\tau_1 = 0$, ce qui s'écrit

$$\sum_{k=0}^{a(u)} \left(k - \frac{u}{2}\right) C_u^k + \sum_{k=b(u)}^u \left(k - \frac{u}{2}\right) C_u^k = 0$$

soit

$$\begin{aligned} \sum_{k=0}^{a(u)} \left(k - \frac{u}{2}\right) C_u^k &= \sum_{k=b(u)}^u \left(\frac{u}{2} - k\right) C_u^k \\ &= \sum_{l=0}^{u-b(u)} \left(\frac{u}{2} - (u-l)\right) C_u^{u-l} \\ &= \sum_{l=0}^{u-b(u)} \left(l - \frac{u}{2}\right) C_u^l \end{aligned}$$

Cette égalité étant vérifiée lorsque $a(u) = b(u)$, la région de rejet est symétrique par rapport à $\frac{u}{2}$ et la condition s'écrit finalement

$$2^{-u} \sum_{k=0}^{a(u)} C_u^k = 2^{-u} \sum_{k=b(u)}^u C_u^k \approx \frac{\alpha}{2}$$

(c) $a(u)$ et $b(u)$ peuvent être approchés en utilisant l'approximation normale des lois binômiales.

*
* *