



Cursus Intégré
2004-2005

Rappels de statistique mathématique
Énoncé des travaux dirigés n°6

Guillaume Lacôte

 Bureau **E03**

✉ Guillaume.Lacote@ensae.fr

☞ <http://ensae.no-ip.com/SE222/>

Enoncé de l'exercice 1

On considère un échantillon X_1, \dots, X_n i.i.d. tiré de la loi de Poisson de paramètre λ .

☞ Q1 Donner $\mathbb{E}(X_i)$ et $\mathbb{V}(X_i)$.

Calculer $\phi(t) = \mathbb{E}(e^{tX_i})$.

En déduire que

$$\begin{aligned}\mathbb{E}(X) &= \lambda \\ \mathbb{E}(X^2) &= \lambda(1 + \lambda) \\ \mathbb{E}(X^3) &= \lambda(1 + 3\lambda + \lambda^2) \\ \mathbb{E}(X^4) &= \lambda(1 + 7\lambda + 6\lambda^2 + \lambda^3)\end{aligned}$$

☞ Q2 (a) On pose $\hat{\lambda}_1(x) = \frac{1}{n} \sum_{i=1}^n x_i = \bar{x}$ et $\hat{\lambda}_2(x) = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$.

Par quelle méthode d'estimation ont été obtenus $\hat{\lambda}_1$ et $\hat{\lambda}_2$?

(b) Les estimateurs $\hat{\lambda}_1$ et $\hat{\lambda}_2$ estiment-ils λ sans biais ?

Proposer un autre estimateur sans biais de λ , que l'on notera $\hat{\lambda}_3$.

(c) Donner la loi (à distance finie) de $\hat{\lambda}_1$.

(d) Donner la loi asymptotique jointe de $\begin{pmatrix} \hat{\lambda}_1 \\ \hat{\lambda}_2 \end{pmatrix}$, puis celle de $\begin{pmatrix} \hat{\lambda}_1 \\ \hat{\lambda}_3 \end{pmatrix}$.

(e) Soit $\hat{\lambda}_\infty = \alpha \hat{\lambda}_1 + \beta \hat{\lambda}_3$, $(\alpha, \beta) \in \mathbb{R}^{+2}$.

Donner la valeur de (α, β) telle que $\hat{\lambda}_\infty$ soit le meilleur estimateur asymptotiquement sans biais de λ .

Ce résultat est-il surprenant (donner l'e.m.v. de λ) ?

☞ Q3 Dans cette question, on se place dans le cas où $n = 2$.

(a) Calculer les erreurs quadratiques moyennes pour les trois estimateurs $\hat{\lambda}_1$, $\hat{\lambda}_2$ et $\hat{\lambda}_3$.

(b) Déterminer en fonction de λ lequel de ces estimateurs est le meilleur selon la critère de l'erreur quadratique moyenne.

(c) Comparer explicitement l'EQM de $\hat{\lambda}_3$ avec la borne FDCR.

Enoncé de l'exercice 2

On considère une population de n individus infectés par un virus; on étudie leurs durées d'incubation $(T_i)_{i \in [1, n]}$, dont on suppose qu'elle est observable.

Pour modéliser l'hétérogénéité de la population, on suppose qu'on peut caractériser chaque individu i par un "facteur de risque" inobservable, réalisation de la variable aléatoire Λ_i , de telle sorte que :

- la loi de T_i , conditionnellement à Λ_i est la loi exponentielle de paramètre λ_i (de densité $\lambda_i e^{-\lambda_i t} \mathbf{1}_{t \geq 0}$);
- la famille $(\Lambda_i)_{i \in [1, n]}$ est identiquement distribuée selon la loi \mathcal{L} de densité

$$f(\lambda) = \frac{\alpha^r}{\Gamma(r)} \lambda^{r-1} e^{-\alpha \lambda} \mathbf{1}_{\mathbb{R}^+}$$

où $\alpha > 0$ et $r > 2$;

- les couples (T_i, Λ_i) sont indépendants entre eux.

☞ Q1 Donner la vraisemblance de (T_1, \dots, T_n) .

☞ Q2 Calculer, lorsqu'il existe, le moment d'ordre k $\mathbb{E}(T_i^k)$.

☞ Q3 Calculer l'information de Fisher du modèle.

Dans le cas où α est connu, calculer l'estimateur du maximum de vraisemblance de r .

Que se passe-t-il si α et r sont tous deux inconnus ?

☞ Q4 On suppose α connu.

Déterminer au moyen de la méthode des moments un estimateur convergent de r .

Cet estimateur est-il sans biais ? Est-il asymptotiquement efficace ?

☞ Q5 On suppose α et r inconnus.

(a) En utilisant les deux premiers moments de T_i , trouver des estimateurs convergents $\tilde{\alpha}$ et \tilde{r} de α et r .

(b) Donner la loi limite du vecteur

$$\sqrt{n} \begin{pmatrix} \bar{T} - \mathbb{E}(T) \\ \bar{T}^2 - \mathbb{E}(T)^2 \end{pmatrix}$$

En déduire la loi asymptotique du vecteur $(\tilde{\alpha}, \tilde{r})$.

Enoncé de l'exercice 3

On considère les réalisations de T variables aléatoires i.i.d. Y_1, Y_2, \dots, Y_T , issues d'une loi de Poisson de paramètre λ inconnu.

On s'intéresse au test de l'hypothèse :

$$H_0 : " \lambda = \lambda_0 " \text{ contre } H_a : " \lambda \neq \lambda_0 "$$

où λ_0 est un réel donné.

☞ Q1 Pour tester ce type d'hypothèse, on dispose de trois tests asymptotiques usuels : test de **Wald**, du **score** et du **rapport de maximum de vraisemblance**. Rappeler rapidement leur principe et définir les statistiques de test sur lesquelles ils s'appuient.

⇒ Q2 Pratiquer explicitement chacun de ces tests, en calculant l'expression de la statistique de test ξ_T^{test} et en définissant la région critique au seuil $\alpha \in [0, 1]$: $W_\alpha = \{(y_1, \dots, y_T) / \xi_T^{test}(y_1, \dots, y_T) > q_{1-\alpha}^{\chi_1^2}\}$

⇒ Q3 On veut tester $\lambda_0 = 1$ au seuil $\alpha = 5\%$.

Décider de chacun des tests dans le cas où l'échantillon observé (y_1, \dots, y_T) est tel que :

– $T = 100$ et $\bar{y} = 1, 2$;

– $T = 200$ et $\bar{y} = 1, 1$.

Discuter de l'acceptation de H_0 et expliquer pourquoi certains tests ne conduisent pas à la même décision.

Conclure.