

Devoir

Enseignant: Mohammed Sedki

pageweb: masedki.github.io

Instructions :

Le devoir est à rendre sous format d'un seul fichier pdf (scans de vos notes) nommé `prenom_nom.pdf` ou `prenom1_nom1_prenom2_nom2.pdf` pour un binôme.

Problème : Test du rapport des vraisemblances

(10 points)

Supposons que X et Y soient des variables aléatoires continues représentant les temps de survie (en années) des patients suivant deux types différents d'interventions chirurgicales pour le traitement d'un cancer du côlon avancé. Les fonctions de densité associées aux variables aléatoires X et Y sont respectivement données par

$$f_X(x, \alpha) = \alpha e^{-\alpha x}, x > 0, \quad \alpha > 0 \quad \text{et} \quad f_Y(y, \beta) = \beta e^{-\beta y}, y > 0, \quad \beta > 0.$$

Soit y_1, y_2, \dots, y_n un échantillon de réalisations de même loi que X et x_1, x_2, \dots, x_n un second échantillon de même loi que Y . On note $\bar{x}_n = \frac{1}{n} \sum_{i=1}^n x_i$ et $\bar{y}_n = \frac{1}{n} \sum_{i=1}^n y_i$.

L'objectif de ce problème est de mettre en place un mécanisme statistique pour tester les hypothèses $H_0 : \alpha = \beta$ versus $H_1 : \alpha \neq \beta$. Pour cela, nous allons faire appel au test dit *de rapport de vraisemblances*. Les ingrédients indispensables à la réalisation de ce test sont

- La vraisemblance du jeu de données complet $x_1, \dots, x_n, y_1, \dots, y_n$ notée $\mathcal{L}(\gamma)$ sous l'hypothèse $H_0 : \alpha = \beta = \gamma$ (sous H_0 , on considère les deux jeux de données de même loi de paramètre γ).
- La vraisemblance du jeu de données complet $x_1, \dots, x_n, y_1, \dots, y_n$ notée $\mathcal{L}(\alpha, \beta)$ sous l'hypothèse $H_1 : \alpha \neq \beta$ (sous H_1 , les deux jeux de données proviennent de lois distinctes de paramètres α et β respectivement).
- Les estimateurs par maximum de vraisemblance $\hat{\alpha}, \hat{\beta}$ et $\hat{\gamma}$ des paramètres α, β et γ respectivement.
- La statistique du rapport des vraisemblances donnée par¹

$$\hat{\lambda} = \frac{\mathcal{L}(\hat{\gamma})}{\mathcal{L}(\hat{\alpha}, \hat{\beta})}.$$

- Un théorème de statistique mathématique : lorsque n est grand, sous l'hypothèse H_0 , la variable aléatoire $-2 \ln \hat{\lambda}$ suit la loi χ_1^2 du khi-deux à 1 degré de liberté.

Q.1 Vérifier que

$$\mathcal{L}(\gamma) = \gamma^{2n} e^{-n\gamma(\bar{x}_n + \bar{y}_n)} \quad \text{et} \quad \mathcal{L}(\alpha, \beta) = \alpha^n e^{-n\alpha\bar{x}_n} \beta^n e^{-n\beta\bar{y}_n}.$$

Q.2 Calculer l'estimateur par maximum de vraisemblance $\hat{\gamma}$ en maximisant $\mathcal{L}(\gamma)$.**Q.3** Calculer les estimateurs par maximum de vraisemblance $\hat{\alpha}$ et $\hat{\beta}$ en maximisant $\mathcal{L}(\alpha, \beta)$.**Q.4** Vérifier que

$$\mathcal{L}(\hat{\gamma}) = e^{-2n} \left[\frac{2}{(\bar{x}_n + \bar{y}_n)} \right]^{2n} \quad \text{et} \quad \mathcal{L}(\hat{\alpha}, \hat{\beta}) = (\bar{x}_n \bar{y}_n)^{-n} e^{-2n}.$$

Q.5 Dédire que

$$\hat{\lambda} = [4u(1-u)]^n, \quad \text{où} \quad u = \frac{\bar{x}_n}{\bar{x}_n + \bar{y}_n}.$$

1. Dans cette expression, on remplace dans chaque expression de vraisemblance, le paramètre par son estimateur par maximum de vraisemblance.

Q.6 Sachant que $n = 100$, $\bar{x}_n = 1.25$ années et $\bar{y}_n = 0.75$ années, calculer la valeur numérique de $\hat{\lambda}$ et déduire la p-value donnée par

$$\mathbb{P}[\chi_1^2 > -2 \ln \hat{\lambda}],$$

pour conclure au rejet (ou pas) de H_0 en faveur de H_1 .

Q.7 Expliquer en quelques mots (3 lignes maximum) l'intuition à l'origine du test du rapport des vraisemblances.

Problème : Modèle géométrique

(10 points)

Supposons que n patients adultes de sexe masculin, sélectionnés au hasard et souffrant d'hypertension, se voient administrer un nouveau médicament d'hypotension au cours d'un essai clinique destiné à évaluer l'efficacité de ce nouveau médicament pour favoriser la rémission à long terme de l'hypertension artérielle. De plus, une fois que la pression artérielle de chaque patient est revenue à un niveau normal, chaque patient est examiné tous les mois pour voir si l'hypertension réapparaît. Pour le i ème patient de l'étude, x_i représente l'âge du patient au début de l'essai clinique et Y_i est la variable aléatoire représentant le nombre de mois de suivi jusqu'à la première réapparition de l'hypertension. Il est raisonnable de supposer que Y_i suit une loi géométrique.

$$p_{Y_i}(y_i; \theta_i) = (1 - \theta_i)^{y_i-1} \theta_i, \quad y_i = 1, 2, \dots, \infty, \quad 0 < \theta_i < 1 \quad \text{et} \quad i = 1, 2, \dots, n.$$

Il est bien établi que l'âge est un facteur de risque d'hypertension. Pour tenir compte des différences d'âge des patients au début de l'essai, il est proposé d'exprimer θ_i comme la fonction suivante de l'âge :

$$\theta_i = \frac{\beta x_i}{1 + \beta x_i}, \quad \beta > 0.$$

Étant donné les n paires d'observations $(x_i, y_i), i = 1, 2, \dots, n$, l'objectif de l'analyse est d'utiliser l'estimateur par maximum de vraisemblance $\hat{\beta}$ du paramètre β pour répondre à des questions d'inférence statistique autour du paramètre β .

Q.1 Vérifier que²

$$\ln \mathcal{L}(\beta) = \sum_{i=1}^n \left[\ln(\beta x_i) - y_i \ln(1 + \beta x_i) \right].$$

Q.2 Déduire que l'estimateur par maximum de vraisemblance $\hat{\beta}$ vérifie l'équation

$$\hat{\beta} = \frac{n}{\sum_{i=1}^n x_i y_i (1 + \hat{\beta} x_i)^{-1}}.$$

Q.3 Sachant que $\mathbb{E}(Y_i) = \theta_i^{-1} = \frac{1 + \beta x_i}{\beta x_i}$, vérifier que l'information de Fisher associée à l'échantillon entier est donnée par

$$\mathcal{I}_n(\beta) = \frac{1}{\beta^2} \sum_{i=1}^n (1 + \beta x_i)^{-1}.$$

Q.4 Déduire la variance asymptotique (lorsque n est grand) de l'estimateur $\hat{\beta}$.

Q.5 Si l'essai clinique concerne 50 patients âgés de 30 ans et 50 patients âgés de 40 ans au début de l'essai, proposer un intervalle de confiance à 95% de confiance pour β lorsque $\hat{\beta} = 0.5$.

2. Calculer la vraisemblance $\mathcal{L}(\beta)$ en premier !