

Contrôle : Statistique pour les big data

Patrick Tardivel,
Université de Bourgogne

1er avril 2022

Exercice 1 (Question de cours) On considère le problème de test suivant

$$\begin{cases} X : (\Omega, \mathcal{F}, Pr) \rightarrow (\mathbb{X}, \mathcal{X}) \\ \mathbb{P}^X \in \mathcal{P}, \text{ où } \mathbb{P}^X \text{ est la loi } X \text{ et } \mathcal{P} \text{ est une famille de lois de probabilité sur } (\mathbb{X}, \mathcal{X}) \\ \mathcal{H}^0 : \mathbb{P}^X \in \mathcal{P}^0 \text{ où } \mathcal{P}^0 \text{ est un sous-ensemble de } \mathcal{P} \end{cases} .$$

Soit $(R_\alpha)_{\alpha \in [0,1]}$ une famille emboîtée de régions de rejet telle que $R_0 = \emptyset$, $R_1 = \mathbb{X}$, $R_\alpha \subset R_{\alpha'}$ lorsque $\alpha \leq \alpha'$ et contrôlant le risque de première espèce au niveau α , c'est-à-dire que

$$\forall \alpha \in [0, 1], \sup\{\mathbb{P}(R_\alpha) : \mathbb{P} \in \mathcal{P}^0\} \leq \alpha.$$

On pose $p(X) := \inf\{\alpha \in]0, 1] : X \in R_\alpha\}$. Montrer que sous l'hypothèse nulle \mathcal{H}^0 la variable aléatoire réelle $p(X)$ satisfait

$$\forall u \in [0, 1], Pr(p(X) \leq u) \leq u.$$

Exercice 2

- Rappeler la procédure de Benjamini-Hochberg. Que peut-on dire du contrôle du FDR lorsque les p -valeurs sont indépendantes ? Même question lorsqu'aucune hypothèse d'indépendance n'est faite sur les p -valeurs.
- Soit $p_1(X), \dots, p_5(X)$ des p -valeurs indépendantes associées aux hypothèses nulles $\mathcal{H}_1^0, \dots, \mathcal{H}_5^0$. Les valeurs expérimentales des p -valeurs sont : $p_1(X^{exp}) = 0,035, p_2(X^{exp}) = 0,012, p_3(X^{exp}) = 0,080, p_4(X^{exp}) = 0,016$ et $p_5(X^{exp}) = 0,052$. Pour un contrôle du FDR au niveau $0,05$, donner les hypothèses nulles rejetées par la procédure de Benjamini-Hochberg. Vous justifierez votre réponse.

Exercice 3

- Rappeler les procédures de Bonferroni et de Holm.
- Soit $p_1(X), \dots, p_5(X)$ des p -valeurs associées aux hypothèses nulles $\mathcal{H}_1^0, \dots, \mathcal{H}_5^0$. Les valeurs expérimentales des p -valeurs sont : $p_1(X^{exp}) = 0,027, p_2(X^{exp}) = 0,015, p_3(X^{exp}) = 0,008, p_4(X^{exp}) = 0,014$ et $p_5(X^{exp}) = 0,062$. Lorsque le FWER est contrôlé au niveau $0,05$, donner les hypothèses nulles rejetées par la procédure de Bonferroni. Même question pour la procédure de Holm. Vous justifierez vos réponses.

Exercice 4

- Soit X_1, \dots, X_n un échantillon de loi normale $\mathcal{N}(\mu, \sigma^2)$ où $\mu \in \mathbb{R}$ et σ^2 sont inconnues. On souhaite tester l'hypothèse nulle $\mathcal{H}^0 : \mu \leq 0$ contre l'hypothèse alternative $\mathcal{H}^1 : \mu > 0$. On pose $\bar{X} := \frac{1}{n} \sum_{i=1}^n X_i$, $S_{corr}^2(X) := \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$ et $T := \bar{X} / \sqrt{S_{corr}^2(X)/n}$. Avec un risque de première espèce $\alpha \in]0, 1[$ on rejette \mathcal{H}_0 lorsque $T > F^{-1}(1 - \alpha)$ où F est la fonction de répartition d'une loi de Student à $n - 1$ degrés de liberté.

(a) Déterminer la p -valeur de cette procédure de test.

(b) Pour quelle valeur de $\mu \in \mathbb{R}$ la p -valeur suit une loi uniforme sur $[0, 1]$? Vous justifierez votre réponse.

2. Soit X_1, \dots, X_{n_1} un échantillon de loi normale $\mathcal{N}(\mu_X, \sigma_X^2)$ indépendant de l'échantillon Y_1, \dots, Y_{n_2} de loi normale $\mathcal{N}(\mu_Y, \sigma_Y^2)$ où $\mu_X \in \mathbb{R}, \mu_Y \in \mathbb{R}, \sigma_X^2 > 0$ et $\sigma_Y^2 > 0$ sont inconnues. On souhaite tester l'hypothèse nulle $\mathcal{H}^0 : \sigma_X^2 = \sigma_Y^2$ contre l'hypothèse alternative $\mathcal{H}^1 : \sigma_X^2 > \sigma_Y^2$. On pose $\bar{X} = \frac{1}{n_1} \sum_{i=1}^{n_1} X_i, \bar{Y} = \frac{1}{n_2} \sum_{i=1}^{n_2} Y_i$ $S_{corr}^2(X) := \frac{1}{n_1-1} \sum_{i=1}^{n_1} (X_i - \bar{X})^2$ et $S_{corr}^2(Y) := \frac{1}{n_2-1} \sum_{i=1}^{n_2} (Y_i - \bar{Y})^2$ et $S := S_{corr}^2(X)/S_{corr}^2(Y)$. Avec un risque de première espèce $\alpha \in]0, 1[$ on rejette \mathcal{H}_0 lorsque $S > F^{-1}(1-\alpha)$ où F est la fonction de répartition d'une loi de Fisher à $n_1 - 1, n_2 - 1$ degrés de liberté.

(a) Déterminer la p -valeur de cette procédure de test.

(b) Montrer que sous l'hypothèse nulle \mathcal{H}^0 , lorsque $\sigma_X^2 = \sigma_Y^2$, la p -valeur suit une loi uniforme sur $[0, 1]$.