

# Contrôle : Statistique pour les big data

Patrick Tardivel, Université de Bourgogne

31 mars 2023

**Durée 2 heures, calculatrice autorisée, notes de cours interdite.**

**Exercice 1 (Question de cours)** On rappelle que la proportion de faux positifs (FDP) est le quotient du nombre de Faux Positifs  $|FP(X)|$  sur le nombre d'hypothèses nulles Rejetées  $|R(X)|$  :

$$FDP(X) = \frac{|FP(X)|}{\max\{|R(X)|, 1\}}, \text{ où } R(X) = FP(X) \cup VP(X).$$

Le taux de faux positifs (FDR) est l'espérance de la proportion de faux positifs :  $FDR = \mathbb{E}(FDP(X))$ . On rappelle également que la probabilité d'avoir au moins un faux positif (FWER) est  $\mathbb{P}(|FP(X)| \geq 1)$ . Montrer les résultats suivants :

1. Le FDR est plus petit que le FWER.
2. Lorsque les hypothèses nulles sont toutes vraies alors  $FDR = FWER$ .

**Exercice 2** On considère le problème de test multiple suivant

$$\left\{ \begin{array}{l} X : (\Omega, \mathcal{F}, Pr) \rightarrow (\mathbb{X}, \mathcal{X}) \\ \mathbb{P}^X \in \mathcal{P} \text{ où } \mathcal{P} \text{ est une famille de loi sur } (\mathbb{X}, \mathcal{X}) \\ \text{Pour tout } j \in \{1, \dots, n\}, \mathcal{H}^{0,j} : \mathbb{P}^X \in \mathcal{P}^{0,j} \text{ où } \mathcal{P}^{0,j} \text{ est un sous-ensemble de } \mathcal{P} \end{array} \right. .$$

Pour  $j \in \{1, \dots, n\}$ ,  $p_j(X)$  est une  $p$ -valeur, c'est-à-dire une variable aléatoire vérifiant l'inégalité suivante dès que  $\mathbb{P}^X \in \mathcal{P}^{0,j}$  :

$$\forall t \in [0, 1] \quad Pr(p_j(X) \leq t) \leq t.$$

1. 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.
2. 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  $p$ -valeurs expérimentales sont :  $p_1(X^{exp}) = 0,015$ ,  $p_2(X^{exp}) = 0,002$ ,  $p_3(X^{exp}) = 0,090$ ,  $p_4(X^{exp}) = 0,036$  et  $p_5(X^{exp}) = 0,032$ . Pour un contrôle du FDR au niveau 0,05, donner les hypothèses nulles rejetées par la procédure de Benjamini-Hochberg lorsque
  - (a) Les  $p$ -valeurs sont indépendantes.
  - (b) Aucune hypothèse n'est faite sur les  $p$ -valeurs.

Vous justifierez vos réponses.

**Exercice 3** Soit  $X = (X_1, \dots, X_n)$  un échantillon de loi normale  $\mathcal{N}(\mu, \sigma^2)$  où  $\mu \in \mathbb{R}$  et  $\sigma^2 > 0$  sont inconnus. On souhaite tester l'hypothèse nulle  $\mathcal{H}^0 : \sigma^2 \leq \sigma_0^2$  (où  $\sigma_0^2$  est une valeur donnée) contre l'hypothèse alternative  $\mathcal{H}^1 : \sigma^2 > \sigma_0^2$ .

1. Réécrire formellement le problème de test.

Soit  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ , on pose  $Y(X) = \sum_{i=1}^n (X_i - \bar{X})^2 / \sigma_0^2$ . Avec un risque de première espèce  $\alpha \in ]0, 1[$  on rejette  $\mathcal{H}^0$  lorsque  $Y(X) > F_0^{-1}(1 - \alpha)$  où  $F_0$  est la fonction de répartition d'une loi du khi deux à  $n - 1$  degrés de liberté.

2. Déterminer la  $p$ -valeur  $p(X)$  de cette procédure de test.

3. Montrer que la  $p$ -valeur suit une loi uniforme lorsque  $\sigma^2 = \sigma_0^2$ .

4. On rappelle que la statistique  $\sum_{i=1}^n (X_i - \bar{X})^2 / \sigma^2$  suit une loi khi deux à  $n - 1$  degrés de liberté. Montrer que lorsque  $\sigma^2 < \sigma_0^2$ , pour tout  $x \in ]0, 1[$  on a  $\Pr(p(X) \leq x) < x$ . Comment qualifie-t-on une  $p$ -valeur satisfaisant cette inégalité ?

**Exercice 4** Soit  $X = (X_1, \dots, X_{n_1})$  un échantillon de taille  $n_1$  de loi  $\mathcal{N}(\mu_X, \sigma_X^2)$  et  $Y = (Y_1, \dots, Y_{n_2})$  un échantillon de taille  $n_2$  indépendant du premier échantillon et de loi  $\mathcal{N}(\mu_Y, \sigma_Y^2)$ . On souhaite tester l'hypothèse nulle  $\mathcal{H}^0 : \sigma_X^2 = \sigma_Y^2$  contre l'hypothèse alternative  $\mathcal{H}^1 : \sigma_X^2 \neq \sigma_Y^2$ . On rappelle que sous l'hypothèse nulle, lorsque  $\sigma_X^2 = \sigma_Y^2$ , la statistique

$$F(X, Y) = \frac{\frac{1}{n_1-1} \sum_{i=1}^{n_1} (X_i - \bar{X})^2}{\frac{1}{n_2-1} \sum_{i=1}^{n_2} (Y_i - \bar{Y})^2}$$

suit une loi de Fisher à  $n_1 - 1, n_2 - 1$  degrés de liberté.

1. Proposer une procédure de test pour  $\mathcal{H}^0$  contre  $\mathcal{H}^1$  contrôlant le risque de première espèce au niveau  $\alpha \in ]0, 1[$ .

2. Déterminer la  $p$ -valeur  $p(X, Y)$  de cette procédure de test.

3. Montrer que la  $p$ -valeur suit une loi uniforme lorsque  $\sigma_X^2 = \sigma_Y^2$ .