

(1)

Tests multiples

1. Introduction

On mesure le niveau d'expression d'un ensemble de gènes $i=1, \dots, m$ au sein de 2 populations (tissus sains, tissus tumoraux) de tailles n_1 et n_2 . On pose $n = n_1 + n_2$. On se place dans le cadre où m est grand devant n . On cherche à savoir quels sont les gènes différentiellement exprimés dans les deux populations.

On note $X = (X^1, \dots, X^n) = (Y^1, \dots, Y^{n_1}, Z^1, \dots, Z^{n_2}) \in \mathbb{R}^{m \times n}$ et on suppose que $\frac{Y^1, \dots, Y^{n_1}}{Z^1, \dots, Z^{n_2}} \sim \text{iid de même loi que } Y \in \mathbb{R}^m$

On note P la loi de X (v.a. sur $\mathbb{R}^{m \times n}$) et \mathcal{P} la famille à laquelle appartient P et

$$\mu_{i,1}(P) = \mathbb{E}(Y_i) \quad \text{où } Y = \begin{pmatrix} Y_1 \\ \vdots \\ Y_m \end{pmatrix}$$

$$\mu_{i,2}(P) = \mathbb{E}(Z_i) \quad Z = \begin{pmatrix} Z_1 \\ \vdots \\ Z_m \end{pmatrix}$$

On veut décider si $P \in \mathcal{H}_{0,i}$ où $\mathcal{H}_{0,i} = \{P \in \mathcal{P}, \mu_{i,1}(P) = \mu_{i,2}(P)\}$
Pour tout $i = 1, \dots, m$ on considère des hypothèses

$$H_{0,i} : \mu_{i,1}(P) = \mu_{i,2}(P) \text{ v.s. } H_{1,i} = \overline{H_{0,i}}$$

On note $\mathcal{H}_0(P) = \{i = 1, \dots, m, H_{0,i} \text{ est vérifiée}\}$

= ensemble des hypothèses nulles vérifiées
(= ensemble des gènes non-différentiellement exprimés)

et $\mathcal{H}_1(P) = \{i = 1, \dots, m, H_{0,i} \text{ n'est pas vérifiée}\}$
= $\{1, \dots, m\} \setminus \mathcal{H}_0(P)$.

(= ensemble des gènes différemment exprimés)

On commence par construire les tests individuels, pour chaque hypothèse $H_{0,i}$. Dans le cas considéré, dans ce paragraphe, on va construire des tests de Student.

On pose $\bar{Y}_i = \frac{1}{n_1} \sum_{j=1}^{n_1} Y_i^j$ et $\bar{Z}_i = \frac{1}{n_2} \sum_{j=1}^{n_2} Z_i^j$ (2)

EXO En supposant que $Y_i^j \sim N(\mu_{i,1}, \sigma^2)$ et $Z_i^j \sim N(\mu_{i,2}, \sigma^2)$ et que $(Y_1^1, \dots, Y_{n_1}^1) \perp\!\!\!\perp (Z_1^1, \dots, Z_{n_2}^1)$, montrer que

$$\sqrt{\frac{n_1 n_2}{n \sigma^2}} (\bar{Y}_i - \bar{Z}_i) \sim \mathcal{N}(0, 1) \text{ si } H_{0,i} \text{ est vérifiée.}$$

$$\text{où } \hat{\sigma}^2 = \frac{1}{n-2} (S_i^1 + S_i^2) \text{ et } S_i^1 = \sum_{j=1}^{n_1} (Y_i^j - \bar{Y}_i)^2$$

$$S_i^2 = \sum_{j=2}^{n_2} (Z_i^j - \bar{Z}_i)^2$$

On choisit donc la statistique de F test

$$T_i(x) = \sqrt{\frac{n_1 n_2}{n \hat{\sigma}^2}} |\bar{Y}_i - \bar{Z}_i| \text{ et on rejette } H_{0,i}$$

lorsque $T_i(x) > s_\alpha$ (où s_α est un seuil à fixer) suivant la valeur de α

Définitions $T_{P,i}(s) = P_{X \sim P} (T_i(x) \geq s)$. Si $H_{0,i}$ est vérifiée (de façon équivalente si $P \in \Theta_{0,i}$) on a

$$\begin{aligned} T_{P,i}(s) &= P(|\bar{Z}_{n-2}| \geq s) \quad \text{où } \bar{Z}_{n-2} \sim \mathcal{N}(0, 1) \\ &= 2P(\bar{Z}_{n-2} \geq s) \xrightarrow{\text{par symétrie de la loi }} 2(1 - F_{\mathcal{N}(0,1)}(s)) \quad \text{où } F_{\mathcal{N}(0,1)} \text{ est la f.d.r.} \\ &\quad \text{de la loi } \mathcal{N}(0,1) \end{aligned}$$

Définition: p-value.

On définit la p-value $p_i(x)$ de ce test comme

$$p_i(x) = \sup_{P \in \Theta_{0,i}} T_{P,i}(T_i(x))$$

Dans notre exemple, $\forall P \in \Theta_{0,i} \quad T_{P,i}(T_i(x))$

$$\text{donc } p_i(x) = \sup_{P \in \Theta_{0,i}} 2(1 - F_{\mathcal{N}(0,1)}(T_i(x)))$$

(le sup n'est pas nécessaire dans cet exemple)

Montrez que dans notre exemple $T_{P,i}(T_i(x)) = p_i(x)$ une loi uniforme sur $[0,1]$ quand

$$\mathbb{P}(T_{P,i} \leq u) = \mathbb{P}(p_i(x) \leq u) = \mathbb{P}(T_{P,i}(T_i(x)) \leq u)$$

$$= \mathbb{P}(2(1 - F_{\mathcal{N}(0,1)}(T_i(x))) \leq u) = \mathbb{P}(1 - \frac{u}{2} \leq F_{\mathcal{N}(0,1)}(T_i(x)))$$

(3)

$$\begin{aligned}
 &= \mathbb{P}(F_{ST(n-2)}^{-1}(1-\frac{\alpha}{2}) \leq T_i(x)) \\
 &= \mathbb{P}\left(1 - F_{ST(n-2)}\left(F_{ST(n-2)}^{-1}(1-\frac{\alpha}{2})\right)\right) \xrightarrow{\text{car } P \in \Theta_0 \text{ ou}} \text{ donc } T_i(x) \sim ST(n-2) \\
 &= \alpha.
 \end{aligned}$$

Cette propriété est très souvent vérifiée et est fondamentale pour les tests multiples.

On passe maintenant aux tests multiples, on aura donc un vecteur $(p_i(x))_{i=1,\dots,m}$ de p-values et on va rejeter les hypothèses H_{0i} pour lesquelles les p-values associées sont "petites". Avant cela, on va écrire sous forme de théorème la

2. Propriété fondamentale des p-values

propriété de l'exercice précédent

On conviendra dans ce paragraphe que $m = 4$.

On adopte donc les notations \mathcal{H} : $P \in \Theta_0$, la statistique de test est $\mathcal{T}(x)$, la zone de rejet $\{\mathcal{T}(x) \geq s\}$.
 $T_p(s) = \mathbb{P}_{X \sim P}(\mathcal{T}(x) \geq s)$.

On note de plus $F_p(s) = \mathbb{P}_{X \sim P}(\mathcal{T}(x) \leq s)$

$$\bar{F}_p(s) = \mathbb{P}_{X \sim P}(\mathcal{T}(x) < s)$$

(remarquez qu'on a $\bar{F}_p(s) \leq F_p(s) \forall s \in \mathbb{R}$, avec égalité fonctionnelle si la loi admet une densité).

On peut alors écrire :

$$\begin{aligned}
 T_p(s) &= \mathbb{P}_{X \sim P}(\mathcal{T}(x) \geq s) = 1 - \mathbb{P}_{X \sim P}(\mathcal{T}(x) < s) \\
 &= 1 - \bar{F}_p(s).
 \end{aligned}$$

Propriété

La p-value définie par $p(x) = \inf_{P \in \Theta_0} T_p(\mathcal{T}(x))$ vérifie.

i) $p(x)$ est stochastiquement majoré par la loi $U_{[0,1]}$ ($\forall P \in \Theta_0 \quad \forall u \in [0,1] \quad \mathbb{P}(p(x) \leq u) \geq u$).

ii) Si F_p est continue pour tout $P \in \Theta_0$ alors

$$p(x) = \min\{\alpha \in [0,1], \mathcal{T}(x) > \sup_{P \in \Theta_0} F_p^{-1}(1-\alpha)\}$$

et si Θ_0 est un singleton $p(x) \sim U_{[0,1]}$

ici $\mathcal{T}(x)$ est générale, pas forcément la stat d'un test de Student

Point i) Préuve

$\forall P \in \Theta_0 \text{ tel que } \alpha \in [0,1]$.

$$\{ T_p(\mathcal{I}(x)) \leq \alpha \} = \{ 1 - \hat{F}_p(\mathcal{I}(x)) \leq \alpha \} = \{ 1 - \alpha \leq \hat{F}_p(\mathcal{I}(x)) \}. \text{ par définition}$$

On veut montrer que $\{ T_p(\mathcal{I}(x)) \leq \alpha \} \in \{ \mathcal{I}(x) > F_p^{-1}(1-\alpha) \}$. En effet si c'est vérifié on a alors.

$$\mathbb{P}(\rho(x) \leq \alpha) = \mathbb{P}\left(\sup_{P \in \Theta_0} T_p(\mathcal{I}(x)) \leq \alpha\right) \quad \text{car sup.}$$

$$\leq \mathbb{P}_{x \sim P \in \Theta_0} (T_p(\mathcal{I}(x)) \leq \alpha) \quad \text{grâce à}$$

$$\leq \mathbb{P}_{x \sim P \in \Theta_0} (\mathcal{I}(x) > F_p^{-1}(1-\alpha)) \quad \text{d'inclusion}$$

$$\leq \mathbb{P}_{x \sim P \in \Theta_0} (\mathcal{I}(x) > F_p^{-1}(1-\alpha)) = 1 - F_p(F_p^{-1}(1-\alpha)) = \alpha.$$

où $F_p^{-1}(u) = \inf \{ x \in \mathbb{R}, F_p(x) \geq u \}$. (c'est une inverse généralisée).

Montrons donc l'inclusion

$$\{ T_p(\mathcal{I}(x)) \leq \alpha \} = \{ 1 - T_p(\mathcal{I}(x)) \geq 1 - \alpha \} = \{ \hat{F}_p(\mathcal{I}(x)) \geq 1 - \alpha \}.$$

$$C. \quad \{ \hat{F}_p(\mathcal{I}(x)) \geq 1 - \alpha \} = \{ \mathcal{I}(x) > F_p^{-1}(1-\alpha) \} \quad \Delta$$

car $\hat{F}_p \leq F_p$ \star par définition de \hat{F}_p^{-1}

Point ii).

Si tous les $P \in \Theta_0$ sont absolument continues $\hat{F}_p = F_p$
l'inclusion précédente est donc une égalité.

Comme $\rho(u) = \sup_{P \in \Theta_0} T_p(\mathcal{I}(x))$ on peut également la définir comme $\rho(u) = \min \{ \alpha \in [0,1], \forall P \in \Theta_0, T_p(\mathcal{I}(x)) \leq \alpha \}$

$$= \min \{ \alpha \in [0,1], \forall P \in \Theta_0, \mathcal{I}(x) > F_p^{-1}(1-\alpha) \} \quad \text{grâce au fait que l'inclusion est une égalité dans ce cas.}$$

Si Θ_0 est un singleton, on a

$$\begin{aligned} \mathbb{P}(\rho(x) \leq u) &= \mathbb{P}(\min \{ \alpha \in [0,1] \mid \forall P \in \Theta_0, \mathcal{I}(x) > F_p^{-1}(1-\alpha) \} \leq u) \\ &= \mathbb{P}(\min \{ \alpha \in [0,1] \mid F_p(\mathcal{I}(x)) \geq F_p^{-1}(1-\alpha) \} \leq u) \\ &= \mathbb{P}(F_p^{-1}(F_p(\mathcal{I}(x))) \leq u) \\ &= \mathbb{P}\left(\sup_{P \in \Theta_0} T_p(\mathcal{I}(x)) \leq u\right) = \mathbb{P}_{x \sim P} (T_p(\mathcal{I}(x)) \leq u) \\ &= \dots = u. \end{aligned}$$

donc $\rho(x) \sim U_{[0,1]}$ D.

(3) Cadre général des tests multiples. ($m > 1$)

On note $\#(\mathcal{H}_0(P)) = m_0(P)$ nombre d'hypothèses nulles vérifiées par P . A partir de l'observation de X on veut découvrir $\mathcal{H}_1(P)$.

Note $\#(A) = \text{cardinal}(A)$

On va donc utiliser le vecteur $p = (p_i(x))_{i=1,\dots,m} \in [0,1]^m$. (5)

avec $\forall p \in P \quad \forall i \in \{1,\dots,m\} \quad \forall u \in [0,1] \quad \mathbb{P}(p_i(x) \leq u) \leq u$.

On note le vecteur $(p_i(x))_{i=1,\dots,m}$ quand la dépendance en x n'est pas importante.

[Définition: une procédure de tests multiples est une fonction $R: q = (q_i)_{i=1,\dots,m} \in [0,1]^m \rightarrow R(q) \in \{1,\dots,m\}$]

L'ensemble $R(p)$ est donc l'ensemble des hypothèses nulles H_0,i rejetées par la procédure.

On considère dans la suite des procédures particulières, les procédures de suillage qui prennent la forme:

$$R(q) = \{ i=1,\dots,m, q_i \leq \underline{\alpha}(q) \}$$

Exemple procédure de Bonferroni (de niveau α)

$$R(q) = \{ i=1,\dots,m, q_i \leq \frac{\alpha}{m} \}$$

④ Erreurs de type I

On considère l'approche de Neyman-Pearson qui consiste à contrôler l'erreur de type I en essayant de rendre celle de type II la plus petite possible.

Dans un cadre multi-tests, il y a plusieurs notions d'erreurs de type I.

a) k-FWER : k-family error rate.

$$k\text{-FWER}(R(p), P) = \mathbb{P}(\#(R(p) \cap H_0(P)) \geq k)$$

= proba que R fasse plus de k faux rejets quand P est P .

b) FDP = false discovery proportion.

$$FDP(R(p), P) = \frac{\#(R(p) \cap H_0(P))}{\#(R(p)) \vee 1}$$

\leftarrow car $\#(R(p))$ peut être nul!

= proportion d'erreurs dans l'ensemble des hypothèses rejetées.

c) FDR = false discovery rate

$$FDR(R(p), P) = \mathbb{E}(FDP(R(p), P))$$

Exemple procédure de Bonferroni $R^{\text{Bonf}}(p) = \{i=1, \dots, m, p_i = p_i(x)\} \leq \frac{\alpha}{m}$
 Dans ce cas $\#(R(p) \cap H_0(p)) = \#\{i \in H_0(p), p_i(x) \leq \frac{\alpha}{m}\}$

On a donc

$$\begin{aligned} \text{FDR}(R^{\text{Bonf}}(p), P) &= \mathbb{E} \left(\frac{\#(R(p) \cap H_0(p))}{\#(R(p)) \vee 1} \right) \\ &\leq \mathbb{E}(\#(R(p) \cap H_0(p))) \\ &= \sum_{i \in H_0(p)} \mathbb{P}(p_i(x) \leq \frac{\alpha}{m}) \\ &\leq \alpha \frac{m_0(p)}{m} \leq \alpha. \end{aligned}$$

2) par minoration
par 1 du dénominateur

Exemple : procédure de Holm.

A partir du vecteur des p-values $(p_i)_{i=1, \dots, m}$, on crée celui des p-values ordonnées $p(1) \leq \dots \leq p(m)$ auxquelles on associe les hypothèses correspondantes $H_{0,(1)}, \dots, H_{0,(m)}$.

On définit l'indice minimale k pour lequel $p(k) \geq \frac{\alpha}{m+1-k}$. On rejette les hypothèses $H_{0,(1)}, \dots, H_{0,(k-1)}$ (et on accepte $H_{0,(k)}, \dots, H_{0,(m)}$).

On note k^* la première hypothèse de $H_0(P)$ rejetée. Avec ces définitions, les hypothèses $H_{0,(1)}, \dots, H_{0,(k^*-1)}$ sont toutes rejetées à raison. On a donc $k^* - 1 \leq m - m_0(p)$.

$$\Leftrightarrow \frac{1}{m - k^* + 1} \leq \frac{1}{m_0(p)} \text{ et } p(k^*) \leq \frac{\alpha}{m + 1 - k^*} \leq \frac{\alpha}{m_0(p)}$$

car (k^) est rejetée.*

On peut alors calculer :

$$\mathbb{P}(\#(R(p) \cap H_0(p)) \geq 1) = \mathbb{P}(\exists i \in H_0(p) \text{ } p_i \leq \frac{\alpha}{m_0(p)})$$

bon peu rapide, n'ouvre pas la tête

D'où la procédure de Holm contrôle le 1-FWER.