

### 5. Contrôle du FDR

Considérons une procédure de seuillage

$$R^t(p) = \{i = 1, \dots, m \mid p_i \leq t(p)\}$$

On peut alors calculer

$$FDR(R^t(p), p) = \mathbb{E} \left( \frac{\#(R^t(p) \cap \mathcal{H}_0(p))}{\#(R^t(p)) \vee 1} \right)$$

$$= \mathbb{E} \left( \frac{\sum_{i \in \mathcal{H}_0(p)} \mathbb{1}(p_i \leq t(p))}{\left( \sum_{i=1}^m \mathbb{1}(p_i \leq t(p)) \right) \vee 1} \right)$$

$$= \frac{\alpha}{m} \mathbb{E} \left( \sum_{i \in \mathcal{H}_0(p)} \frac{\mathbb{1}(p_i \leq t(p))}{\left( \frac{\alpha}{m} \sum_{i=1}^m \mathbb{1}(p_i \leq t(p)) \right) \vee \frac{\alpha}{m}} \right) (*)$$

on reconnaît la fdr empirique des p-values.

Notons  $\hat{G}_m(p, x) = \frac{1}{m} \sum_{i=1}^m \mathbb{1}(p_i \leq x)$

⚠ Avec les mains : si  $\hat{G}_m$  était déterministe, de même que  $t(p)$ , on aimerait choisir  $t$  tel que  $t \leq \alpha \hat{G}_m(p, t) \Leftrightarrow t \vee \frac{\alpha}{m} \leq \alpha \hat{G}_m(p, t) \vee \frac{\alpha}{m}$

car dans ce cas on aurait.

$$\frac{\alpha}{m} \mathbb{E} \left( \sum_{i \in \mathcal{H}_0(p)} \frac{\mathbb{1}(p_i \leq t(p))}{\alpha \hat{G}_m(p, t(p)) \vee \frac{\alpha}{m}} \right)$$

$$\leq \frac{\alpha}{m} \frac{1}{t(p) \vee \frac{\alpha}{m}} \sum_{i \in \mathcal{H}_0(p)} \mathbb{E}(\mathbb{1}(p_i \leq t(p)))$$

$$\leq \frac{\alpha}{m} \frac{1}{t(p) \vee \frac{\alpha}{m}} \sum_{i \in \mathcal{H}_0(p)} t(p) \leq \frac{\alpha}{m} \frac{1}{t(p) \vee \frac{\alpha}{m}} t(p) m_0(p) \leq \alpha \frac{m_0(p)}{m} \leq \alpha$$

des p-values

On introduit des seuils dits "auto-consistants"

$$t \in \mathcal{I}(p) \quad \mathcal{I}(p) = \{u \in [0, 1], \hat{G}_m(p, u) \geq \frac{u}{\alpha}\}$$

On les dit auto-consistants car si  $t \in \mathcal{I}(p)$ , on a

$$\hat{G}_m(p, t) \geq \frac{t}{\alpha} \Leftrightarrow \#(p_i \leq t) \geq \frac{t \cdot m}{\alpha} (*)$$

Donc pour un seuil  $t$ , on écrit : si  $t \in \mathcal{I}(p)$

$$R^t(p) = \{i = 1, \dots, m, p_i \leq t\} \subset \{i = 1, \dots, m, p_i \leq \frac{\alpha}{m} \#(R^t(p))\}$$

Un test auto-corrélat sera en pratique très simple à utiliser car il ne dépend que de  $x$  et des p. valeurs  $p$ .

Si on choisit  $t(p) \in \mathcal{I}(p)$ , on peut écrire.

$$FDR(R^c(p), p) \leq \frac{\alpha}{m} \sum_{i \in \mathcal{H}_0(p)} \mathbb{E} \left( \frac{\mathbb{1}(p_i \leq t(p))}{t(p) \vee \frac{\alpha}{m}} \right) \leq \frac{\alpha}{m} \sum_{i \in \mathcal{H}_0(p)} \mathbb{E} \left( \frac{\mathbb{1}(p_i \leq t(p))}{t(p)} \right)$$

↑ on a utilisé (v) et (v\*)

↑ avec la convention  $\frac{0}{0} = 0$

Lemme

Soit  $u \geq 0$  v.a. telle que  $\mathbb{P}(u \leq u) \leq u \forall u \in [0, 1]$  et  $g$  une fonction de  $\mathbb{R}_+$  dans  $\mathbb{R}_+$  décroissante. On pose  $v = g(u)$

alors  $\mathbb{E} \left( \frac{\mathbb{1}(u \leq v)}{v} \right) \leq 1$

Preuve: Soit  $\mathcal{U} = \{u \geq 0, g(u) \geq u\}$  et  $u^* = \sup \mathcal{U}$ .

On pose  $C^* = \inf_{u \in \mathcal{U}} g(u)$ .

Pour tout  $u$  dans  $\mathcal{U}$ , on a  $u \leq u^* \leq g(u^*)$ . Comme  $g$  est décroissante et que  $u^* \geq u$ , on a  $g(u^*) \leq g(u)$  (c'est vrai pour tout  $u \in \mathcal{U}$ )

donc  $g(u^*) \leq C^*$  (on peut choisir une suite  $(u_n)$  dans  $\mathcal{U}$  croissante vers  $u^*$  avec  $g(u_n) \searrow C^*$ )

on en déduit que  $C^* \geq u^*$ .

On a donc  $C^* = 0 \Rightarrow u^* = 0$

si non.

$$\mathbb{E} \left( \frac{\mathbb{1}(u \leq g(u))}{g(u)} \right) \leq \frac{\mathbb{E}(\mathbb{1}(u \leq g(u)))}{C^*} = \frac{\mathbb{P}(u \leq g(u))}{C^*}$$

$$\leq \frac{\mathbb{P}(u \leq u^*)}{C^*} \leq \frac{u^*}{C^*} \leq 1$$

via l'hyp. (v\*)

On se restreint maintenant à la famille des lois suivantes

$$\mathcal{P}^I = \left\{ P \in \mathcal{P} \mid (p_i(x))_{i \in \mathcal{H}_0(p)} \text{ indépendantes, } (p_i(x))_{i \in \mathcal{H}_1(p)} \text{ indépendantes de } (p_i(x))_{i \in \mathcal{H}_0(p)} \right\}$$

C'est une famille très restrictive qui demande l'indépendance des p. valeurs. Cela peut être amélioré. On trouve dans des papiers récents  $\mathcal{P}$  loi gaussienne multivariée avec par exemple covariances  $\geq 0$  (cf notamment Benjamini & Yekutieli, Annals of Stat.)

On peut dans cette famille et grâce au lemme montrer le théorème suivant.

Théorème  
 Soit  $R^t$  une procédure de tests multiples basée sur une fonction de seuil  $t(\cdot)$  vérifiant.

- (\*)  $t$  est auto-constante
- (\*\*)  $t(q) \leq t(q') \forall q, q' \in [0,1]^m$  vérifiant  $q_i' \leq q_i \forall i=1, \dots, m$  (i.e.  $t$  est "décroissante" par rapport à toutes les  $p$ -valeurs)

alors  $FDR(R^t(p), p) \leq \frac{\alpha m_0(p)}{m} \leq \alpha \forall p \in \mathcal{P}^I$

Preuve: Soit  $i \in \mathcal{I}(p)$ , on reprend le calcul du haut de la page 8 et on s'intéresse au terme.

$$E \left( \frac{\mathbb{1}(p_i \leq t(p))}{t(p)} \right)$$

L'astuce est de conditionner par rapport à  $p_{(-i)} = (p_{(1)}, \dots, p_{(i-1)}, p_{(i+1)}, \dots, p_{(m)})$  la fonction  $t^{(i)}: p_i \rightarrow t(p_i; p_{(-i)}) = t^{(i)}(p_i)$  (on fixe  $p_{(-i)}$ ) est décroissante en  $p_i$  par l'hypothèse (\*\*) du théorème.

On peut donc appliquer le lemme avec  $g = t^{(i)}$  et  $u = p_i$

$$E \left( \frac{\mathbb{1}(p_i \leq t(p))}{t(p)} \right) = E \left( E \left( \frac{\mathbb{1}(p_i \leq t^{(i)}(p_i))}{t^{(i)}(p_i)} \mid p_{(-i)} \right) \right)$$

L'hypothèse d'indépendance sur ici à rendre la fonction  $t^{(i)}$  déterministe après conditionnement. et  $\mathbb{P}(p_i \leq u) \leq u$  ce qui prouve le théorème.  $\square$

### 6. La procédure de Benjamini. Hochberg (1994)

Le théorème précédent montre que, sous une hypothèse sur les  $p$ -valeurs, toute procédure de test basée sur une fonction de seuil décroissante et auto-constante contrôle le FDR. Il est donc naturel de considérer le seuil

suivant (pour maximiser  $R^t$ ):


$$\hat{t}(p) = \max \mathcal{J}(p)$$

$$= \max \left\{ u \in \left\{ \frac{\alpha k}{m}, k=0, \dots, m \right\}, G_m(p, u) \geq \frac{u}{\alpha} \right\}$$

$$= \frac{\alpha}{m} \max \left\{ k=0, \dots, m : p^{(k)} \leq \frac{\alpha k}{m} \right\}$$

où  $p(1) \leq \dots \leq p(m)$ .

Ce choix est appelé linear-step-up ou seuillage de Benjamini-Hochberg



et la procédure rejette les p-values telles que  $p_i \leq \hat{t}$ .

Note: il existe des démonstrations plus élégantes, voir notamment [statweb.stanford.edu/~vckirby/brad/LSI/chapter6.pdf](http://statweb.stanford.edu/~vckirby/brad/LSI/chapter6.pdf) avec un argument martingale et un théorème d'arrêt optionnel.