

Mitmese testimise probleem II

Permutatsioonitest; valeavastusmäär (FDR)

Mittetöötava rusikareegli näide:
t-test, "suur valim" ($n=100$)

kasutatud olulisuse nivoo	vale testitulemuse (I liiki vea) tõenäosus
0,05	0,0504
0,0005	0,00053
0,000005	0,0000073
0,000005 (ühepoolne)	0,000011

$$0,000011 * 10000 \neq 0,05$$

Bonferroni meetod võimendab üles ka kõige pisema eksimuse eeldustes suureks probleemiks.

Meenutuseks

- Bonferroni, Bonferroni-Holm'i meetodid

Tagavad, et 1. liiki viga kõigi testide peale kokku ei ületaks ettemääratud piiri (suvalises olukorras)

- Sidak, Sidak step-down (Sidak-Holm)

Tagavad, et 1. liiki viga kõigi testide peale kokku ei ületaks ettemääratud piiri (sõltumatute testide korral)

Mida siis teha?

Permutatsioonitest?

1. Paiguta fenotüübi väärтused juhuslikult;
2. leia olulisustõenäosus (p-väärtus) kõigi testide ehk kõigi SNP'de jaoks;
3. leia väikseim p-väärtus kõigi testide seast;
4. korda samme 1-3 palju kordi (näiteks 10000 korda)
5. vaata, kui sageli kohtasid sind huvitavast p-väärtusest pisemaid p-väärtuseid...

Statistiline test vs diagnostiline test

Diagnostiline test (T+/T-)	Statistiline test (otsus H ₀ / otsus H ₁)
inimene on haige H+	Kehtib H ₁
inimene on terve H-	Kehtib H ₀
Testi tundlikkus: P(T+ H+)	Test võimsus: P(otsus H ₁ H ₁)
Testi spetsiifilisus: P(T- H-)	~ kasutatav olulisuse nivoo: $\alpha = P(\text{otsus } H_1 H_1)$ spetsiifilisuse täpne analoog oleks $1-\alpha$
Positiivne proguosivärtus: P(H+ T+)	Valeavastusmäär (FDR – False Discovery Rate): $\approx P(H_1 \text{otsustame } H_1 \text{ kasuks})$

$$P(H+|T+) = \frac{P(T+|H+)P(H+)}{P(T+|H+)P(H+) + P(T+|H-)P(H-)}$$

$$PPV = \frac{\text{tundlikkus} \cdot \text{levimus}}{\text{tundlikkus} \cdot \text{levimus} + (1 - \text{spetsiifilisus})(1 - \text{levimus})}.$$

üksiku hüpoteesi testimise
puhul problemaatiline

False Discovery Rate

[Benjamini & Hochberg \(1995\)](#)

1. järjesta testide olulisustõenäosused kasvavalgt:

$$p_{(1)} \leq p_{(2)} \leq \dots \leq p_{(k)}$$

2. Leia $v^* = \max(1 \leq v \leq k: p_{(v)} \leq \alpha v/k)$

3. Kui leidub selline v^* , siis kummuta nullhüpoteesid mis vastavad olulisustõenäosustele:

$$p_{(1)} \leq p_{(2)} \leq \dots \leq p_{(v^*)}$$

Alternatiiv: kasuta parandatud olulisus-tõenäosuseid valemist

$$p_{(j)}^* = \min_{v=j \dots k} \{ \min ([k/v] p_{(v)}, 1) \}$$

k testi tulemused

	H ₀ kehtib	kehtib H _A	
Jääme H ₀ juurde (otsus H ₀)	A	B <i>Il-liiki viga</i>	
Kummutame H ₀ (otsus H _A)	C	D <i>I-liiki viga</i>	t _A
	k ₀	k ₁	k = k ₀ +k ₁

tavaline stat. hüp. kontroll: $E(C/k_0) < \alpha$

mitmene testimine (Bonf., Bonf.-Holm, ..): $P(C>0) < \alpha$

False Discovery Rate, FDR: $E(C/t_A) < \alpha$. Veidi ebakorrektne (mis siis, kui t_A=0) ?

$$\text{FDR} = E(C/t_A \mid t_A > 0) P(t_A > 0) \quad \text{Benjamini and Hochberg 1995}$$

$$\text{pFDR} = E(C/t_A \mid t_A > 0) \quad \text{Storey 2001}$$

Kirjeldatud meetod tagab, et valeavastusmäär (FDR) poleks suurem kui α (* - vaata lisatingimusi!).

Täpsemalt:

$$\text{FDR} \leq (k_0 / k) \alpha \leq \alpha$$

* Valeavastuste keskmist osakaalu kontrollitakse küll vaid sõltumatute testide või nn positiivselt korreleeritud testide korral (raskesti hoomatav keeruline tehniline tingimus). Enamikes praktilistes situatsioonides paistab meetod töötavat.

Üldine lahend sõltuvate testide jaoks Benjamini-Yekutiel (2001)

Lükka ümber nullhüpotees, kui

$$p_{(i)} \leq i/k \cdot \alpha/c(k)$$

Kus k on tehtud testide arv, α on valitud FDR ja $c(k)$ on testide arvust sõltuv konstant:

$$c(k) = \sum_{i=1}^k 1/i \approx \log(k) + 0,5772$$

Töötab universaalselt kuid on (enamasti) konservatiivne.

p -value ja q -value

- olulisustõenäosus ehk minimaalne olulisuse nivoo, mille korral nullhüpoteesi saaks kummutada.
- q -value e minimaalne FDR (valeavastusmäär) mille korral nullhüpoteesi saaks kummutada

FDR ja FWER kontrollimise võrdlus

	rawp	Bonferroni	Holm	Hochberg	SidakSS	SidakSD	BH	BY	Storey (qvalue)
[1,]	0.0001	0.01	0.0100	0.0100	0.0100	0.0100	0.0080	0.0415	0.0075
[2,]	0.0002	0.02	0.0198	0.0198	0.0198	0.0196	0.0080	0.0415	0.0075
[3,]	0.0003	0.03	0.0294	0.0294	0.0296	0.0290	0.0080	0.0415	0.0075
[4,]	0.0004	0.04	0.0388	0.0384	0.0392	0.0381	0.0080	0.0415	0.0075
[5,]	0.0004	0.04	0.0388	0.0384	0.0392	0.0381	0.0080	0.0415	0.0075
[6,]	0.0005	0.05	0.0475	0.0475	0.0488	0.0464	0.0083	0.0432	0.0079
[7,]	0.0006	0.06	0.0564	0.0564	0.0583	0.0549	0.0086	0.0445	0.0081
[8,]	0.0007	0.07	0.0651	0.0651	0.0676	0.0630	0.0087	0.0454	0.0083
[9,]	0.0010	0.10	0.0920	0.0920	0.0952	0.0879	0.0111	0.0576	0.0105
[10,]	0.0026	0.26	0.2366	0.2366	0.2292	0.2109	0.0260	0.1349	0.0245
							sõltumatu/ suvaline	sõltumatu/ pos. sõltuvus?
							positiivne sõltuvus	sõltumatud testid	kontrollivad FDR-i, mitte I- liiki vea tegemise tõenäosust!

False Discovery Rate Illustration:



