

# Načrtovanje in analiza podatkov DNA mikromrež z BRB-ArrayTools

Peter Juvan

UL MF


e-mail: peter.juvan@mf.uni-lj.si

Ljubljana, 31.3.2014

# Literatura

Simon, R.M., Korn, E.L., McShane, L.M., Radmacher, M.D., Wright, G.W., Zhao, Y.: Design and Analysis of DNA Microarray Investigations. Springer, 2004.

- <http://linus.nci.nih.gov/~brb/book.html>
- <http://books.google.si/books?id=bEJitvcC338C>




# Program BRB-ArrayTools

<http://linus.nci.nih.gov/BRB-ArrayTools.html>

- analiza in vizualizacija podatkov DNA mikromrež
- dodatek za **Microsoft Excel**
- z Visual Basic for Applications (VBA) povezan z analitičnimi orodji
- **R Project** for Statistical Computing  
<http://www.r-project.org/>
- **Bioconductor**  
<http://www.bioconductor.org/>
- programski jeziki C, Fortran in Java





# Poskus z DNA mikromrežami

Na primeru analize izražanja genov

# Analiza izražanja genov

- nivo RNA
- detekcija **razlik** v količini mRNA **med vzorci**
  - intenziteta signala je v sorazmerna količini mRNA
- izražanje = ekspresija
  - **relativna** vrednost (vzorec VS referenca)
  - **logaritmska** transformacija

$$e = \log_2(I_{vzorec}/I_{referenca})$$

# Poskus z DNA mikromrežami

1. Načrtovanje poskusa
2. Analiza slike
3. Kontrola kvalitete
4. Normalizacija podatkov
5. Primerjava razredov
6. Napovedovanje razreda
7. Oblikovanje razredov

# Poskus z DNA mikromrežami


1. Načrtovanje poskusa
2. Analiza slike
3. Kontrola kvalitete
4. Normalizacija podatkov
5. Primerjava razredov
6. Napovedovanje razreda
7. Oblikovanje razredov

# Načrtovanje poskusa

- opredelitev **biološkega vprašanja**
    - identifikacija neodvisnih spremenljivk
    - izbira vzorca


- določitev **ciljev**
    - primerjava razredov
    - napovedovanje razreda
    - oblikovanje razredov

- izbira **metod** za analizo podatkov
    - specifične za uporabljeno platformo mikromrež
    - splošne (statistika, strojno učenje)



# Cumulus Cells Gene Expression Profiling in Terms of Oocyte Maturity in Controlled Ovarian Hyperstimulation Using GnRH Agonist or GnRH Antagonist

Rok Devjak<sup>1</sup>, Klementina Fon Tacer<sup>2,3</sup>, Peter Juvan<sup>2</sup>, Irma Virant Klun<sup>1</sup>, Damjana Rozman<sup>2</sup>, Eda Vrtačnik Bokal<sup>1\*</sup>



**Experimental design.** Number of **patients** ( $m=21$ ) and **samples** ( $n=46$ ) included in the study. 11 patients were administered **GnRH agonist** and 10 **GnRH antagonist**. CC from **MI**, **MII-NF** and **MII-BL** oocytes were collected from 4 GnRH agonist treated patients. CC from **MII-NF** and **MII-BL** oocytes were collected from 5 GnRH agonist and 6 GnRH antagonist treated patients; and CC from **MI** and **MII-BL** were collected from 2 GnRH agonist and 4 GnRH antagonist treated patients. Altogether, **10** CC samples from **MI** oocytes, **15** from **MII-NF** oocytes and **21** from **MII-BL** oocytes were collected and considered in transcriptome analysis.

# Viri variabilnosti


- **razlike v izražanju genov** so posledica
  - razlik med **pogoji poskusa**
  - razlik med **osebki**
  - razlik med **vzorci** in izolirano RNA
  - razlik med **DNA čipi**
  - razlik med **probami** znotraj čipa
- neželene razlike odpravimo s **ponovitvami** meritev
  - **biološke ponovitve**
    - več osebkov pod enakimi pogoji poskusa
  - **tehnične ponovitve**
    - ponovitve meritev na istih vzorcih
- **združevanje vzorcev (pooling)**
  - zgolj v primeru premajhne količine RNA

# Eno/dvo-barvne mikromreže

- **enobarvne**
  - vsak vzorec na svoj DNA čip
  - npr. Affymetrix GeneChip
- **dvobarvne**
  - 2 vzorca, označena z različnimi barvili (**Cy3**, **Cy5**)
  - zmanjšamo problem **razlik med mikromrežami**
  - dodatna tehnična variabilnost zaradi **razlik med barvili**
  - problem **izbire parov** vzorcev, ki jih hibridiziramo skupaj
- **večbarvne**
  - redkeje v uporabi

# Združevanje vzorcev pri dvobarvnih mikromrežah

- načrt poskusa predstavimo z grafom
  - vozlišča: vzorci
  - povezave: hibridizacije
  - oznake povezav: št. ponovitev (hibridizacij)
  - določimo barvila, npr.
    - **Cy3** pri izvoru
    - **Cy5** pri ponoru



Yang YH, Speed T: Design issues for cDNA microarray experiments. *Nature reviews. Genetics* 2002; 3(8): 579-588.

## neposredna / posredna primerjava





Figure 1 | **Direct versus indirect designs.** Two possible designs that compare gene expression in two cell-population samples T and C. **a** | In a direct comparison, the differential expression of the genes in samples T and C is measured directly on the same slide (in a single experiment). **b** | In an indirect comparison, expression levels of samples T and C are measured separately on two different slides. The log ratio  $\log_2(T/C)$  is estimated by the difference  $\log_2(T/R) - \log_2(C/R)$ . R, reference.

## skupna referenca


- ciljni vzorec hibridiziramo skupaj z enotnim **referenčnim** vzorcem
- **najpogosteje** uporabljen
- preprost, možnost širitve poskusa
- problem izbire **referenčnega vzorca**
  - količina
  - izraženost genov
- priprava reference
  - kontrola
  - univerzalna (komercialna)
  - pool vseh vzorcev (problem širitve poskusov)
- **slaba izkoriščenost:**  $\frac{1}{2}$  hibridizacij odpade na referenčni vzorec



Yang YH, Speed T: Design issues for cDNA microarray experiments. *Nature reviews. Genetics* 2002; 3(8): 579-588.

## krožna zasnova

- primerna za **manjše št. vzorcev**
- več vzorcev -> več indirektnih primerjav
- neuspešna hibridizacija prekine krog -> vse primerjave niso možne




## menjava barvil (angl. *dye swap*)

- odpravlja razlike v intenziteti barvil (Cy3, Cy5, ...)
- **neučinkovite** (tehnične) ponovitve
  - bolje: več vzorcev (bioloških ponovitev)

# Št. bioloških ponovitev

- lahko **ocenimo**
  - za 2 razreda in specifične načrte
  - z ozirom na FP, FN, std. dev, pričakovanih razlik v ekspresiji
- težje oceniti pri več faktorjih / razredih
- **v praksi** pogojeno z
  - biološkim sistemom (človek, miš, kvasovka, ...)
  - pogoji poskusa
  - *financami ?!*



# Poskus z DNA mikromrežami

1. Načrtovanje poskusa
2. Analiza slike
3. Kontrola kvalitete
4. Normalizacija podatkov
5. Primerjava razredov
6. Napovedovanje razreda
7. Oblikovanje razredov

# Poskus z DNA mikromrežami


1. Načrtovanje poskusa
2. Analiza slike
- 3. Kontrola kvalitete**
4. Normalizacija podatkov
5. Primerjava razredov
6. Napovedovanje razreda
7. Oblikovanje razredov

# Kontrola kvalitete

- obravnavanje šuma
  - izračunaj mero kvalitete
  - izloči meritev, če mera pod pragom
  - obravnavaj/imputiraj izločene vrednosti
- kontrola kvalitete na **nivoju**
  1. sond
  2. genov
  3. čipov
- **komercialni** čipi bistveno bolj kvalitetni od „**doma narejenih**“
  - nanos cDNA/oligonukleotidov z robotom
  - sinteza oligonukleotidov „*in situ*“


## 1. Nivo sond

- nizka kvaliteta kot posledica
  - **tehnične napake**
    - pri izdelavi DNA mikromreže
    - nečistoče pri hibridizaciji
    - pomanjkljivo spiranje po hibridizaciji
  - **šibkega signala**
    - nizek SNR (angl. *signal-to-noise ratio*)
- **vizualni** pregled slike
  - umazanija -> visok signal
  - zračni mehurček med hibridizacijo -> nizek signal
  - meglice -> nizko razmerje med signalom in ozadjem
- št. slikovnih točk (px)
  - min. 25-50 px (radij = 3-4 px)
  - ustrezna **resolucija** skeniranja



**izločimo sonde, pri katerih:**

- **nizek signal v R in G hkrati**
  - zaradi visokega vpliva **aditivnega** šuma
  - npr:  $FR=FG$ ,  $FR\pm 10$ ,  $FG\pm 10$ 
    - $e = \log_2(510/490) = 0.057$
    - $e = \log_2(30/10) = 1.58$
- **visok signal ozadja**
  - prispevek ozadja ni zgolj aditiven
  - izloči, če  $FR/BR < 1.5$  ali  $FG/BG < 1.5$
- **korelacija** med slikovnimi točkami FR in FG
  - nizka -> izloči




## 2. Nivo genov

- običajno **več sond** za en gen
  - podvojene sonde
  - različne sonde za isti gen
- **razlike med sondami so posledica**
  - alternativnih spojitvenih variant
  - napačnih anotacij sond
  - razlik pri hibridizaciji
  - napak pri izdelavi mikromrež
- **testiramo razlike in izločimo sonde pri vseh čipih hkrati**
  - razlike med podvojenimi sondami (tehnične narave)
  - razlike med različnimi sondami za isti gen (biološke in tehnične narave)
- izločimo lahko tudi **nizko variabilne gene** pod različnimi eksperimentalnimi pogoji
  - njihovo izražanje je lahko zgolj posledica šuma

## Affymetrix

- 3' ekspresijski čipi
- gene čipi
- eksonski čipi



### 3. Nivo čipov

- posledica
  - slabše izdelave **čipov**
  - razgrajene **RNA**
  - napak pri **označevanju, hibridizaciji, skeniranju**
- **odstranimo** podatke celega čipa, če
  1. izločenih veliko sond
  2. slabo razmerje med ospredjem in ozadjem
  3. nizka varianca pri posameznem kanalu (Cy3, Cy5)
  4. veliko saturiranih sond (ponovimo skeniranje)
  5. neustrezne interne kontrole (spikes)

## **Imputacija manjkajočih vrednosti sond**

- oceni manjkajoče/izločene vrednosti na podlagi preostalih vrednosti
- možnosti
  - mediana izražanja gena preko vseh čipov
  - z upoštevanjem korelacije med geni

## **Obravnavo manjkajočih vrednosti**

- metode **prilagojene** za obravnavo manjkajočih vrednosti
- npr. test diferenčne izraženosti genov
  - **linearna regresija** namesto klasične analize variance (ANOVA)

# Poskus z DNA mikromrežami

1. Načrtovanje poskusa
2. Analiza slike
3. Kontrola kvalitete
- 4. Normalizacija podatkov**
5. Primerjava razredov
6. Napovedovanje razreda
7. Oblikovanje razredov

# Normalizacija podatkov

- odstranimo razlike, ki so **tehnične** narave
  - nastavitev PMT pri laserskem odčitavanju
  - količina hibridizirane RNA
  - učinkovitost vgradnje barvil
- na **nivoju**
  - blokov
  - čipov
  - poskusa
- **pristop**
  - izbira normalizacijskih **sond**
  - izbira norm. **algoritma**

## Izbira normalizacijskih sond

- **hišni geni**
  - njihovo izražanje se ne spreminja
    - vključeni v osnovne celične funkcije
    - preko pogojev poskusa (ocenimo iz podatkov – pristranost !!)
  - ne obstajajo ?!
- **zunanja RNA (spikes)**
  - vsem vzorcem dodamo zunanoj RNA
  - problem količine zunanje RNA
    - uskladiti s količino RNA pri obravnavanih vzorcih
    - napaka pipete
  - uporabno za **po meri narejene / diagnostične čipe**
- **vsi geni**
  - predpostavka: skupna količina RNA je pri vseh vzorcih konstantna
    - velja le za čipe, ki pokrivajo **celoten genom**
    - ne velja za po meri narejene / diagnostične čipe
  - najpogosteje uporabljeni

## Normalizacija dvobarvnih čipov

- za vsak čip  $j$  in gen  $k$  izračunamo normalizacijski faktor

$$C_{jk}$$

- prilagodimo izraženost genov

$$x_{jk} = \log_2 \left( \frac{R_{jk}}{G_{jk}} \right) - C_{jk}$$

- pristopi

- globalen pristop (skupen  $C_j$  za vse gene)

$$C_j = \text{median}_{k \in G} \left( \log_2 \left( \frac{R_{jk}}{G_{jk}} \right) \right)$$

- $C_{jk}$  odvisen od povprečne intenzitete


$$A_{jk} = \frac{1}{2} (\log_2 R_{jk} + \log_2 G_{jk})$$

- $C_{jk}$  odvisen od lokacije na čipu (po blokih)

- $C_{jk}$  odvisen od povprečne intenzitete in lokacije na čipu

## $C_{jk}$ odvisen od povprečne intenzitete vseh genov


- normalizacija mikromrež z geni iz celotnega genoma
- MA graf



$$A_{jk} = \frac{1}{2} (\log_2 R_{jk} + \log_2 G_{jk})$$


# $C_{jk}$ odvisen od povprečne intenzitete „spikes“ sond

- normalizacija po meri narejene mikromreže Steroltalk v1



## $C_{jk}$ odvisen od povprečne intenzitete in lokacije „spikes“ sond

- normalizacija po meri narejene mikromreže Sterolgene v0



# Poskus z DNA mikromrežami

1. Načrtovanje poskusa
2. Analiza slike
3. Kontrola kvalitete
4. Normalizacija podatkov
- 5. Primerjava razredov**
6. Napovedovanje razreda
7. Oblikovanje razredov

# Primerjava razredov

- cilja
  - izbira **diferenčno izraženih genov** med razredi
  - analiza **obogatenosti genskih skupin/poti**
- razrede določimo **v naprej** (neodvisno od rezultatov meritev)
  - rakaste ~ normalne celice
- sočasne primerjave **več razredov**
  - rakaste ~ normalne celice
  - pred ~ po administraciji zdravila
- **večnivojski** razredi
  - rak tipa1 ~ rak tipa 2 ~ normalno tkivo

# Primerjava razredov

## 1. Test diferenčne izraženosti posameznih genov

1. Studentov t-test
2. permutacijski t-test
3. Wilcoxon rang-sum test
4. več razredov
5. parni vzorci

## 2. Identifikacija diferenčno izraženih genov

1. Bonferronijev popravek
2. permutacijska metoda
3. nadzor števila lažno pozitivnih (FP)
4. nadzor FDR (False Discovery Rate)

## 3. Regresijski modeli

# Primerjava razredov

## 1. Test diferenčne izraženosti posameznih genov

1. Studentov t-test
2. permutacijski t-test
3. Wilcoxon rang-sum test
4. več razredov
5. parni vzorci

## 2. Identifikacija diferenčno izraženih genov

1. Bonferronijev popravek
2. permutacijska metoda
3. nadzor števila lažno pozitivnih (FP)
4. nadzor FDR (False Discovery Rate)

## 3. Regresijski modeli

## 1. Test diferenčne izraženosti posameznih genov

- geni z znanimi funkcijami -> razumevanje bioloških mehanizmov
- geni z neznanimi funkcijami -> napovedovanje novih funkcij
- podatki
  - 2 razreda z  $J_1$  in  $J_2$  vzorci (biološkimi replikami)
  - izražanje gena  $x$ 
$$\overline{x_1} = x_{11}, x_{12}, \dots x_{1J_1}$$
$$\overline{x_2} = x_{21}, x_{22}, \dots x_{2J_2}$$
- razlika srednjih vrednosti izražanja
  - ni zanesljiva ocena diferenčne izraženosti !!

$$|\overline{x_1} - \overline{x_2}| \geq 1$$

- **Studentov t-test**

- $H_0$ : porazdelitev izražanja pri razredih  $J_1$  in  $J_2$  je v populaciji enaka
- ocenimo verjetnost, da je razlika v izražanju taka, kot smo jo izmerili

$$t = \frac{\bar{x}_1 - \bar{x}_2}{\sqrt{s_p^2 \left( \frac{1}{J_1} + \frac{1}{J_2} \right)}}$$

- kjer je  $s_p^2$  **zdržena** (angl. *pooled*) varianca izražanja, pri čemer predpostavimo, da je znotraj razredov enaka

$$s_p^2 = \frac{(J_1 - 1)s_1^2 + (J_2 - 1)s_2^2}{J_1 + J_2 - 2}$$

$$s_i^2 = \frac{1}{J_i - 1} \sum_{j=1}^{J_i} (x_{ij} - \bar{x}_i)^2 \text{ za } i = 1, 2$$

- iz  $t$ -statistike po tabelah izračunamo  **$p$ -vrednost**
- $p$ -vrednost primerjamo z **izbrano stopnjo značilnosti** (običajno  $\alpha = 0.05$ )
- če je  $p < \alpha$ , zavrnemo ničelno hipotezo  $H_0$  in sklepamo, da je **gen diferenčno izražen**

- **permutacijski t-test**

- ocenimo, koliko lahko zaupamo *t-statistiki*
- ne predpostavimo normalnosti porazdelitve izražanja

### **algoritem**

1. izračunamo *t*-statistiko (*t*)
2. ponavljamo
  1. naključno označimo meritve z razredoma  $J_1$  in  $J_2$
  2. izračunamo *t*-statistiko ( $t^*$ )
3. izračunamo *p-vrednost* in primerjamo z izbrano stopnjo značilnosti  $\alpha$

$$p = \frac{1 + \#(|t^*| \geq |t|)}{1 + \#_P}$$

- pogosto lahko pregledamo vseh  $\binom{J_1 + J_2}{J_1}$  možnosti; v tem primeru velja

$$p = \frac{\#(|t^*| \geq |t|)}{\binom{J_1 + J_2}{J_1}}$$

	Class 1 data values					Class 2 data values					Parametric <i>t</i> -statistic
original data:	-0.18	-0.10	-0.13	0.30	-0.14	0.15	0.84	0.66	0.52	<i>t</i> = 3.64	
data permutation 1:	-0.18	-0.10	-0.13	0.30	-0.14	0.15	0.84	0.66	0.52	<i>t</i> * = 3.64	
data permutation 2:	-0.18	-0.10	-0.13	0.30	0.15	-0.14	0.84	0.66	0.52	<i>t</i> * = 2.15	
data permutation 3:	-0.18	-0.10	-0.13	0.15	0.84	0.30	-0.14	0.66	0.52	<i>t</i> * = 0.83	
data permutation 4:	-0.18	-0.10	-0.13	-0.14	0.15	0.30	0.84	0.66	0.52	<i>t</i> * = 5.48	
.	.	.	.	.	.	.	.	.	.	.	
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	
data permutation 124:	0.30	-0.14	0.84	0.66	0.52	-0.18	-0.10	-0.13	0.15	<i>t</i> * = -2.48	
data permutation 125:	0.30	0.15	0.84	0.66	0.52	-0.18	-0.10	-0.13	-0.14	<i>t</i> * = -4.49	
data permutation 126:	-0.14	0.15	0.84	0.66	0.52	-0.18	-0.10	-0.13	0.30	<i>t</i> * = -2.48	

$$\text{permutation } p\text{-value} = \frac{\# \text{ of the 126 permutations where } |t^*| \geq |t|}{126} = \frac{3}{126}$$

- **Wilcoxon rang-sum test**
  - neparametrična alternativa t-testa

### **algoritem**

1. zamenjamo  $J_1 + J_2$  vrednost izražanja z rangi
  2. izračunamo vsoto rangov za razreda 1 in 2
  3. izračunamo  $p$ -vrednost po tabelah in primerjamo z izbrano stopnjo značilnosti  $\alpha$
- 
- manjša občutljivost  
$$J_1 = 2, J_2 = 3: \#_p = 10, p_{min} = 0.1$$
  - + hiter izračun

- **več razredov**

- $J_1, J_2 \dots J_K$  vzorcev za  $K$  razredov
- $H_0$ : porazdelitev izražanja je enaka za vse razrede
- alternativna hipoteza: **vsaj pri enem** izmed razredov se porazdelitev izražanja razlikuje od ostalih razredov
- *F-statistika* (posplošitev t-testa)
- permutacijski *F-test* (posplošitev)
- neparametričen: *Kruskal-Wallis test*
- neparametričen, urejeni razredi: *Jonckhreere test*
- **post hoc** primerjave
- primerjave razredov po parih:  $\binom{(K-1)*K}{2}$  parov

- **parni vzorci**

- izražanje gena  $x$  izmerjeno v parih  
npr: pri isti osebi pred/po administraciji zdravila  
 $(x_{11}, x_{21}), (x_{12}, x_{22}), \dots (x_{1J}, x_{2J})$

- **parni t-test**

$$t = \frac{\bar{x}_1 - \bar{x}_2}{\sqrt{s_s^2/J}}$$

$$s_d^2 = \frac{1}{J-1} \sum_{j=1}^J [(x_{1j} - x_{2j}) - (\bar{x}_1 - \bar{x}_2)]^2$$

- **permutacijski parni t-test**

- permutacije izvedemo z upoštevanjem parnosti: oznake razredov permutiramo za vsak par posebej
- možnih permutacij:  $2^J$

- **Wilcoxon signed-rank test**

- rangiramo razlike po parih:  $d_1 = x_{11} - x_{21}$

# Primerjava razredov

## 1. Test diferenčne izraženosti posameznih genov

1. Studentov t-test
2. permutacijski t-test
3. Wilcoxon rang-sum test
4. več razredov
5. parni vzorci

## 2. Identifikacija diferenčno izraženih genov

1. Bonferronijev popravek
2. permutacijska metoda
3. nadzor števila lažno pozitivnih (FP)
4. nadzor FDR (False Discovery Rate)

## 3. Regresijski modeli

## 2. Identifikacija diferenčno izraženih genov

- testiramo veliko število hipotez (genov)
  - velika možnost **lažno pozitivnih (FP)** zaključkov
    - če pri 30.000 genih dovolimo 5% napako
    - v povprečju dobimo 1.500 lažno pozitivnih rezultatov !!
  - **problem multiplih primerjav:** kako nadzorovati št. FP
- 
- **Bonferronijev popravek**
    - *p-vrednosti* posameznih genov pomnožimo s št. genov (K)
    - popravljene *p-vrednost* primerjamo z izbrano stopnjo značilnosti  $\alpha$
    - preveč strikten
      - npr. pri K=10.000 je gen diferenčno izražen pri  $p \leq 0.000005$
    - za tako nizke p-vrednosti
      - Studentov t-test ni dovolj natančen
      - permutacijski test ni dovolj občutljiv

- **permutacijska metoda**

### **algoritem**


1. izračunamo  $p$ -vrednosti genov ( $p_k$ )
2. ponavljamo
  1. permutiramo oznake razredov
  2. izračunamo  $p$ -vrednosti genov ( $p_k^*$ ) in poiščemo minimum ( $p_{(1)}^*$ )
3. izračunamo popravljene  $p$ -vrednosti ( $adj\_p_k$ )

$$adj\_p_k = \frac{1 + \#(p_{(1)}^* \leq p_k)}{1 + \#_P}$$

4. popravljene  $p$ -vrednost primerjamo z izbrano stopnjo značilnosti  $\alpha$

+ manj strikten od Bonferronijevega popravka

– (pre)pogosto lahko pregledamo vseh  $\binom{J_1 + J_2}{J_1}$  možnosti



Identify gene  $k$  as differentially expressed if

$$\frac{\# \text{ of the 126 permutations where } p_{(1)}^* \leq p_k}{126} \leq .05$$

- **nadzor števila lažno pozitivnih (FP, angl. *False Positive*)**
  - Bonferronijev popravek in permutacijska metoda zagotavlja, da med odkritimi geni ni FP genov
  - posplošimo **permutacijski test**, da dovolimo v povprečju največ  $U$  FP genov

$$adj\_p_k = \frac{1 + \#(p_{(U+1)}^* \leq p_k)}{1 + \#_P}$$

- **nadzor stopnje lažnih odkritij (FDR, angl. *False Discovery Rate*) – postopek Benjamini-Hochberg (BH)**
  1. uredimo nepopravljene  $p$ -vrednosti  

$$p_{(1)} \leq p_{(2)} \leq \dots \leq p_{(K)}$$
  2. poiščemo najvišji indeks  $D$ , pri katerem velja  

$$p_{(D)} * \frac{K}{D} < \alpha$$
  3. izračunamo popravljene  $p$ -vrednosti ( $D$  predstavlja št. odkritih genov)  

$$adj\_p_{(k)} = p_{(k)} * \frac{K}{D}$$
- postopek Tusher *et al.* (**SAM**)
- **permutacijski FDR**

# Primerjava razredov

## 1. Test diferenčne izraženosti posameznih genov

1. Studentov t-test
2. permutacijski t-test
3. Wilcoxon rang-sum test
4. več razredov
5. parni vzorci

## 2. Identifikacija diferenčno izraženih genov

1. Bonferronijev popravek
2. permutacijska metoda
3. nadzor števila lažno pozitivnih (FP)
4. nadzor FDR (False Discovery Rate)

## 3. Regresijski modeli

### 3. Regresijski modeli

$$y_j = \alpha + \beta z_j + e_j$$

- $j = 1, 2, \dots, J$  vzorcev
- $y$ : odvisna spremenljivka: izražanje gena
- $z$ : neodvisna spremenljivka (faktor vpliva)
- $\alpha$ : srednja vrednost izražanja gena
- $e$ : napaka
- $\beta$ : regresijski koeficient


Hipoteza  $H_0: \beta = 0$ : ni povezave med izražanjem gena in faktorjem  $z$

- večje število neodvisnih spremenljivk (faktorjev)  
$$y_j = \alpha + \beta_1 z_j + \beta_2 w_j + e_j$$
- obravnava motečih dejavnikov (diskretne/zvezne vrednosti)

# Regresijski model z dvema faktorjema


$$y_j = \alpha + \beta_T T_j + \beta_M M_j + \beta_I (T_j * M_j) + e_j$$

- $H_0^T: \beta_T = 0$ : ni povezave med izražanjem gena in časom  $T$
- $H_0^M: \beta_M = 0$ : ni povezave med izražanjem gena in vplivom mutacije  $M$
- $H_0^I: \beta_I = 0$ : ni interakcije med vplivom časa  $T$  in mutacije  $M$




$p_T$     $p_M$     $p_I$


(a) 0.703, 0.255, 0.631




(b) 0.815, 0.429, 0.005




(c) 0.005, 0.000, 0.006




(d) 0.006, 0.436, 0.003




(e) 0.730, 0.006, 0.000





(f) 0.007, 0.681, 0.634



(g) 0.001, 0.004, 0.402




(h) 0.655, 0.001, 0.420



# Novel Insights into the Downstream Pathways and Targets Controlled by Transcription Factors CREM in the Testis

Rok Kosir<sup>1,7</sup>, Peter Juvan<sup>1</sup>, Martina Perse<sup>2</sup>, Tomaz Budelfeld<sup>3</sup>, Gregor Majdic<sup>3,5</sup>, Martina Fink<sup>4</sup>, Paolo Sassone-Corsi<sup>6</sup>, Damjana Rozman<sup>1\*</sup>

**1** Center for Functional Genomics and Bio-Chips, Institute of Biochemistry, Faculty of Medicine, University of Ljubljana, Ljubljana, Slovenia, **2** Medical Experimental Centre, Institute of Pathology, Faculty of Medicine, University of Ljubljana, Ljubljana, Slovenia, **3** Center for Animal Genomics, Veterinary Faculty, University of Ljubljana, Ljubljana, Slovenia, **4** Department of Haematology, University Medical Center Ljubljana, Ljubljana, Slovenia, **5** Institute of Physiology, Faculty of Medicine, University of Maribor, Maribor, Slovenia, **6** Department of Pharmacology, University California Irvine, Irvine, California, United States of America, **7** Diagenomi Ltd, Ljubljana, Slovenia



**Figure 3. Euler diagrams representing genes from different datasets.** Euler diagrams were drawn to visualize the comparisons of genes from different datasets. The size of the circles corresponds to the number of genes present in each dataset. Three comparisons were made in order to retrieve the data for further functional analysis of DE genes.


doi:10.1371/journal.pone.0031798.g003

# Poskus z DNA mikromrežami


1. Načrtovanje poskusa
2. Analiza slike
3. Kontrola kvalitete
4. Normalizacija podatkov
5. Primerjava razredov
- 6. Napovedovanje razreda**
7. Oblikovanje razredov

# Napovedovanje razreda


- cilj: na podlagi izražanja genov **določi razred neznanega vzorca**
    - uporaba: diagnostični čipi
1. priprava **učnih primerov**
    - meritve izražanja genov večjega števila vzorcev s poznanim razredom
  2. izdelava **napovednega modela**
    - izbira spremenljivk
    - izbira metode **nadzorovanega** strojnega učenja
    - validacija modela
  3. uporaba modela za **napovedovanje** razreda neznanih vzorcev
    - ločevanje tumorskega in normalnega tkiva
    - izbira metode zdravljenja
    - ...



**B MDS na 3226 genih**



**c MDS na 51 genih (F-test,  $\alpha=0.001$ )**




# Izbira spremenljivk (genov)

- št. spremenljivk (genov) << števila primerov (vzorcev)
  - problem pretiranega prileganja (angl. *overfitting*)
- diferenčno izraženi geni
  - t-test, F-test, permutacijski in neparametrični testi
  - izbira ustrezne  $\alpha$  (0.01, 0.001, ...)
- analiza glavnih komponent (PCA)
  - redukcija dimenzij
  - komponenta: linearna kombinacija genov
  - vključenih veliko genov
  - problem interpretacije modela
- gruče genov


# Metode nadzorovanega strojnega učenja

- diskriminantna analiza
  - poišči tako linearno kombinacijo izbranih genov,
  - da si bodo razredi glede na vrednosti linearne kombinacije med seboj čim bolj različni
- metoda K najbližjih sosedov
  - napovej razred na podlagi K primerov,
  - ki so najbolj podobni z ozirom na izraženost izbranih genov
  - običajno  $K < 7$
- odločitvena drevesa
- metoda podpornih vektorjev
- ...

# Metoda najbližjih sosedov




# Odločitvena drevesa



# Validacija modela: prečno preverjanje

- izbira učne / testne množice



- izračunamo statistiko (kontingenčna tabela)

		Resnični razred		Skupaj
		+	-	
Napovedan razred	+	TP	FP	TP+FP
	-	FN	TN	FN+TN
Skupaj		TP+FN	FP+TN	N

- izračunamo statistike, npr.
  - napovedno točnost:  $(TP+TN)/N$
  - občutljivost:  $TP/(TP+FN)$
  - specifičnost:  $TN/(FP+TN)$


# Poskus z DNA mikromrežami

1. Načrtovanje poskusa
2. Analiza slike
3. Kontrola kvalitete
4. Normalizacija podatkov
5. Primerjava razredov
6. Napovedovanje razreda
7. Oblikovanje razredov

# Oblikovanje razredov

- **cilji**
  - na podlagi izražanja genov **določiti tipične razrede** v populaciji
  - odkriti **biološke značilnosti** posameznih razredov (npr. različnih vrst tumorjev)
  - odkriti tipične **profile izražanja genov**
- metode **nenadzorovanega** strojnega učenja
  - večrazsežnostno lestvičenje (MDS)
  - gručenje
  - vizualizacijske metode
    - razsevni diagram
    - radviz diagram
- **validacija**
  - razrede je moč oblikovati tudi na **naključnih** podatkih !!!

# MDS



## Dieta

- Altromin
- Western
- Zero cholesterol

## Spol

- Male
- Female

## Genotip

- cP (Cre +)
- cM (Cre -)

## Serija

- 1
- 2
- 3


Lorbek G et al. (2012) Unpublished data.

# Hierarhično gručenje

36 vzorcev


- 3 diete
- 2 spola
- 2 genotipa
- 3 biološke ponovitve

77 genov ( $\alpha < 0.05$ )



Lorbek G et al. (2012) Unpublished data.

# Razsevni in radviz diagram



# Orodja

- R Project for Statistical Computing  
<http://www.r-project.org/>



- Bioconductor  
<http://www.bioconductor.org/>
- BRB-Array Tools  
<http://linus.nci.nih.gov/BRB-ArrayTools.html>



# Literatura

- Simon RM *et al.* Design and analysis of DNA microarray investigations. Springer, 2003.  
<http://linus.nci.nih.gov/~brb/book.html>
- Hovatta I *et al.* DNA microarray data analysis, 2nd edition. CSC, 2005.  
<http://www.csc.fi/english/research/sciences/bioscience/books/microarraybook2nd>

