

## Kapitola II


---

Technologie studující genomiku a proteomiku


Mikročipy (microarrays)

# Průběh genomického experimentu


## 1. Příprava a provedení experimentu v laboratoři




## 4. Biologická a klinická interpretace



## 2. Extrakce a úprava dat




## 3. Statistická analýza dát



# Technika mikročipů

- **Mikročipy** – biotechnologie simultánně srovnávající biologické objekty (molekuly, tkanivá) na základě jejich imobilizace na jediný **podklad** do oblastí (spotů) které jsou pravidelně uspořádány do řádků a sloupců
- Podklad: sklo, gel, parafin, ...
- Mikročipy v genomice a proteomice:
  - DNA mikročipy
  - Proteínové mikročipy



## Kapitola II.1


# Princip a rozdělení DNA mikročipů

# DNA mikročipy

- Séria **krátkych DNA sekvencií** imobilizovaných rovnomerne na podklad, používaná na detekciu DNA alebo RNA (obvykle vo forme cDNA) vo vzorkách. Najčastejšie aplikovaná na:
  - meranie zmien v hladinách génovej expresie (gene expression profiling, detekcia RNA - cDNA) - **expresné arraye**
  - detekciu štruktúrnych zmien genómu (SNPs - jednonukleotidové polymorfizmy alebo zmeny v počte kópií génov) - **arrayCGH, SNP arrays**
- Taktiež sa úspešne používa na **detekciu väzbových miest proteínov** na genóme (**ChIP-on-chip**), detekciu alternatívneho **zostrihu** (**exon junction arrays**) a takisto na presnú detekciu neznámych a nepredikovaných transkriptov alebo alternatívnych foriem zostrihu (**tiling arrays**)


# Sonda (probe)

- Krátke DNA sekvencie (oligonukleotidy) na microarray sklíčku sa nazývajú *sondy*, anglicky *probes*
- Každá oblast' DNA (obvykle gén), ktorú chceme skúmať
- Sondy sú navrhnuté tak, aby boli pre daný gén/oblast' čo najšpecifickejšie





# Základný princíp

- Fragmenty DNA/cDNA zo vzorky sa spárujú s komplementárnymi sondami na microarray sklíčku a tým sa imobilizujú.
- Imobilizované molekuly DNA, ktoré boli predtým označené **fluorescenčným farbivom** sa potom dajú detektovať pomocou **UV skenera** a kvantifikovať tak množstvo mRNA/DNA s danou sekvenciou prítomnej vo vzorku.



# Mikročipy



# Postup mikročipového experimentu

1. Výroba mikročipového sklíčka
  2. Příprava vzorků  
Příprava čipu a vzorků
  3. Hybridizace
  4. Skenování  
Vznik dat
  5. Analýza obrazu (kvantifikace signálu, vznik expresních dat)

# Postup mikročipového experimentu

1. Výroba mikročipového sklíčka
  2. Příprava vzorků
  3. Hybridizace

---



  4. Skenování
  5. Analýza obrazu (kvantifikace signálu, vznik expresních dat)
- Příprava čipu a vzorků
- Vznik dat

# Princip výroby DNA mikročipu


---

- Výroba sklíčka spočívá v připojení sond na podložné sklíčko do oblastí spotů
- Dvě hlavní metody:
  - *Spotting* - sondy jsou syntetizované PŘED umístěním na microarray sklíčko, potom umístěné na sklíčko pomocí speciálního robota

# Spotovací robot



# Princip spotování




# Princip výroby DNA mikročipu

- Výroba sklíčka spočívá v připojení sond na podložné sklíčko do oblastí spotů
- Dvě hlavní metody:
  - *Spotting* – sondy jsou syntetizované PŘED umístěním na microarray sklíčko, potom umístěné na sklíčko pomocí speciálního robota
  - *In-situ syntéza* – sondy jsou syntetizované přímo na podklad, *fotolitografickou syntézou*  
<http://www.youtube.com/watch?v=ui4BOtwJEXs&feature=related>
- Spotting – u delších cDNA sekvencí
- In-situ syntéza – pro krátke oligonukleotidy

# Typy sond

- **cDNA sondy** - 500-5000 párů bazí dlouhé cDNA klony cílového genu nebo známé sekvence. Obvykle syntetizované před umístěním na microarray sklíčko pomocí spotovacího robota
  - Výhoda: jsou více specifické, a v případě úspěšné hybridizace s cílovou DNA můžeme téměř s jistotou říct, že se spojily právě s daným genem
- **Oligonukleotidové sondy** – maximálně 25 párů bazí dlouhé sekvence, které jsou designované tak, aby odpovídaly jen částem sekvence známých kódujících genových ORF (open reading frames).



# Typ mikročipů dle typu sondy

- Podle typu sondy rozlišujeme:
  - **cDNA mikročipy** – používají cDNA sondu
    - hybridizace závislá na délce sond
    - neznáme přesný počet klonů v každém spotu

Hybridizaci nutno stanovit relativně (k referenci). Tato relativní informace je robustnější než absolutní informace o intenzitě každého spotu. Proto jsou tyto experimenty obvykle **dvoukanálové** (jeden kanál pro DNA, kterou zkoumáme, druhý kanál pro referenční DNA).

- **Oligonukleotidové mikročipy** – oligonukleotidové sondy, obvykle syntetizované in-situ
  - známe přesný počet klonů
  - stejná délka sondy

Není nutná reference, proto jsou **jednokanálové** (jeden vzorek na čip bez reference).

# Postup mikročipového experimentu


1. Výroba mikročipového sklíčka
  2. Příprava vzorků
  3. Hybridizace

---


  4. Skenování
  5. Analýza obrazu (kvantifikace signálu, vznik expresních dat)
- Příprava čipu a vzorků
- Vznik dat

# Příprava vzorků

1. Izolace DNA/RNA: molekuly které chceme zkoumat (DNA či mRNA) jsou extrahované ze vzorku.




2. Přepis a amplifikace: mRNA se přepisuje do cDNA a amplifikuje se pomocí RT-PCR. DNA zas pomocí PCR.



# Příprava vzorků: 3. značení

**3. Značení:** Amplifikovaná DNA (cDNA) je obarvená fluorescenčním barvivem (nejčastěji Cy3 nebo Cy5). Toto s nazývá přímé označení. U nepřímého značení nejdříve skupina, většinou primární amin je inkorporována do cDNA a Cy3/Cy5 jsou potom inkorporované do cDNA při následné reakci.




# Postup mikročipového experimentu

---

1. Výroba mikročipového sklíčka
2. Příprava vzorků
3. Hybridizace
4. Skenování
5. Analýza obrazu
6. Kvantifikace obrázku na hodnoty exprese

# Hybridizace DNA



- DNA mikročipová technologie je založená na hybridizaci


- Hybridizace je proces komplementárního párování dvou jednořetězcových nukleových kyselin do dvouřetězcové molekuly (duplexu) na základě párování bazí.

# Hybridizace na mikročipu


1. Fragmentovaná a namnožená cDNA(DNA) vzorku se vylije na microarray sklíčko, kde už jsou navázané jednořetězcové sondy.
2. Zahřátím na určitou teplotu se zruší vodíkové vazby mezi řetězci a DNA vzorku se rozplétá na dva samostatné řetězce – tento proces nazýváme **denaturace**.
3. Teplota se zase sníží a jednořetězcové molekuly se snaží znova spárovat se svými komplementárními řetězci

4. Nastává komplementární párování

- původním párem DNA řetězců
- DNA a sondou – vzniká **hybrid**



5. Sklíčko se nakonec omyje a zůstano pouze hybridizované řetězce.



## Kapitola II.1

---

### Vznik a charakter dat

# Postup mikročipového experimentu

1. Výroba mikročipového sklíčka
2. Příprava vzorků
3. Hybridizace

---

4. Skenování
5. Analýza obrazu (kvantifikace signálu, vznik expresních dat)

Příprava čipu a vzorků

Vznik dat

# Vznik a charakter dat

---

Každá technologie má svůj vlastní způsob kvantifikace signálu (teda proměny signálu na čísla - data).

Mnohé principy jsou společné.


1. Fluorescenční signál je excitován s pomocí laseru
2. Elektrony jsou zachycené mikroskopem přes filtry do obrazu
3. Tyto obrazová data se kvantifikují

## Kapitola II.1.1

Vznik a charakter dat -> cDNA  
mikročipy

# Jak získáváme základní data z cDNA


## A. RNA Isolation




## B. cDNA Generation

## C. Labeling of Probe

Reverse Transcriptase





## D. Hybridization to Array



## E. Imaging

- Sample A > B
- Sample B > A
- Sample A = B

spot



## F. Analýza obrazu (snímání intenzit jednotlivých kanálů)

Datový soubor:

tisíce řádků (genů)  
X desítky sloupců

- číselné hodnoty intenzit testované a referenční RNA (+ hodnoty pozadí... )
- kontrola kvality spotů
- ...



## Další analýza

1. úpravy datového souboru
2. určení odlišných genů
3. klasifikace, predikce....

# Dvoukanálové skenování

Po hybridizaci vkládáme sklíčko do skeneru aby ho vytvořili obrázek mikročipu.

Excitační a emisní spektra Cy3 a Cy5



# Analýza obrazu


Po skenování se uloží obrázek mikročipového sklíčka ve formátu .tiff, který se vloží do programu pro analýzu obrazu. Následuje kvantifikace signálu.

Kroky kvantifikace:

1. Lokalizace center spotů  
Automaticky pomocí *grid* (sítky), a manuální úpravou

2. Segmentace  
Klasifikace spotů, odlišené intenzity pozadí od popředí (pomocí kruhů, etc...).



3. Kvantifikace signálu  
V popředí i v pozadí spotu



# Lokalizace center spotů

Automaticky pomocí speciálního souboru *grid* (od výrobců mikročipu), který obsahuje informaci o:

- Počtu a umístění spotů na mikročipu
- Průměru spotů v pixelech




# Segmentace

- V tomto kroku jsou programem pro analýzu obrazu rozpoznávané oblasti **spotů** a **pozadí**
- Nastavení velikosti a pozice spotů – probíhá nejprve automaticky
- Obvykle nutná vizuální inspekce a další přizpůsobení ručně
- Navíc – nutné manuální označování špatných, případně prázdných spotů
- Nejčastější algoritmy vyhledávání spotů
  - Fixed circles
  - Adaptive circles
  - Histogram adaptive
- Různé programy různě definují **pozadí** spo

GenePix


QuantArray

ScanAlyse




# Kvantifikace signálu

- V této fázi se kvantifikuje signál spotu, používají se různé charakteristiky (průměr, medián, modus, kvantily)




# Kvantifikace signálu pozadí


- Tři druhy metod:
  1. Lokální metoda (local background)
  2. Morfologické otevření (morphological opening)
  3. Konstantní/globální metoda (constant/global background)



GenePix



QuantArray




ScanAnalyse


Vizualizace oblastí lokálního odhadu intenzity pozadí u tří různých programů analýzy obrazu cDNA mikročipu

# Kvantifikace signálu pozadí 2.


- Tři druhy metod:
  1. Lokální metoda (local background)
  2. Morfologické otevření (morphological opening)
  3. Konstantní/globální metoda (constant/global background)



Čtvercový element



Nový obraz  
s odhadnutým  
signálem pozadí



Schematické znázornění  
Center spotů, ze kterých  
je odhadnutý  
signál pozadí pro spot

# Kvantifikace signálu pozadí 3.

- Tři druhy metod:
  1. Lokální metoda (local background)
  2. Morfologické otevření (morphological opening)
  3. Konstantní/globální metoda (constant/global background)

Signál je odhadnutý jako jediná hodnota pro všechny spoty:

- Jako průměr intenzit signálů negativních kontrol (sondy jiného organismu, které **by neměly** hybridizovat se vzorkem)
- Nebo jako 3% kvantil rozdělení signálu všech spotů


# Kontrola kvality spotů I.

- Po dobu kvantifikace intenzit probíhá ještě **inspekce kvality** spotů na základě **parametrů** zadaných do algoritmu
- I po kvantifikaci je možné manuálně označit spotty, které považujeme za nekvalitní
- Spotem, které neprojdou kontrolou kvality je přiřazená příslušná hodnota v proměnné Flags:
- Např.
  - 100 ~ good ;
  - -100 ~ bad ;
  - -75 ~ absent;
  - -50 ~ not found;
  - 0 ~ unflagged;

# Kontrola kvality spotů II.

Charakteristiky kontroly kvality:


- **Velikost a tvar spotu**
  - Příliš malé spoty neposkytují věrohodné odhady intensity hybridizace (Simon et al., 2003) (spoty menší než < 25 pixelů by měly být odstraněny)
  - Spoty s nepravidelným tvarem, případně "koblihové spoty" by měly být označené jako nekvalitní
- **Intenzita signálu**
  - Spoty s příliš malou intenzitou signálu v obou kanálech
    - $\log_2(610/590) = 0.048$ , ale  $\log_2(30/10) = 1.58$
  - Poměr signál/šum by měl být dostatečně vysoký
- **Nasycení (saturace) spotu**
  - Spoty by neměly obsahovat nasycené pixely



Source: <http://probes.invitrogen.com/lit/catalog/2/images/g002230.gif>

# Kontrola kvality spotů III.

Příklady nekvalitních spotů (A-C) v porovnání s ideálním spotem (D)



- A) nasycený (saturovaný) spot, B) koblihový spot, C) spot s nepravidelnou strukturou, D) dobrý spot

# Ukázka základních cDNA mikročipových dat

Po kvantifikaci a kontrole získáváme základní datový soubor.

- Data z jednoho cDNA mikročipového sklíčka

	A	B	C	D	E	F	G	H	I	J	K	L	M		
1	Unique position ID		Chromosome	Mb positio	SES end	Plate info	Block	Column	Row	Name	X	Y	Dia.		
2		44	RP11-195a8		1	37581779	37726637	NKI2C1	26	11	19	44	8600	35890	140
3		44	RP11-195a8		1	37581779	37726637	NKI2C1	26	10	19	44	8370	35890	140
4		44	RP11-195a8		1	37581779	37726637	NKI2C1	26	12	19	44	8820	35890	140
5		102	RP11-124d4		1	87374825	87558032	NKI2B12	4	7	19	102	16600	8970	120
6		102	RP11-124d4		1	87374825	87558032	NKI2B12	4	9	19	102	17060	8970	130
7		102	RP11-124d4		1	87374825	87558032	NKI2B12	4	8	19	102	16830	8970	120
8		154	RP11-145H4		1	1.52E+08	1.52E+08	NKI2G5	26	11	20	154	8600	36110	150
9		154	RP11-145H4		1	1.52E+08	1.52E+08	NKI2G5	26	13	20	154	9040	36110	140
10		154	RP11-145H4		1	1.52E+08	1.52E+08	NKI2G5	26	12	20	154	8820	36110	150
11		187	RP11-1122M		1	1.83E+08	1.83E+08	NKI2F10	20	7	20	187	16690	27120	130
12		187	RP11-1122M		1	1.83E+08	1.83E+08	NKI2F10	20	6	20	187	16460	27120	130
13		187	RP11-1122M		1	1.83E+08	1.83E+08	NKI2F10	20	5	20	187	16240	27120	130
14		196	RP11-6618		1	1.89E+08	1.9E+08	NKI2C2	18	10	19	196	8330	26880	130
15		196	RP11-6618		1	1.89E+08	1.9E+08	NKI2C2	18	11	19	196	8560	26890	130
16		196	RP11-6618		1	1.89E+08	1.9E+08	NKI2C2	18	12	19	196	8780	26880	130
17		236	RP11-845b6		1	2.27E+08	2.27E+08	NKI2C3	10	10	19	236	8330	17960	140
18		236	RP11-845b6		1	2.27E+08	2.27E+08	NKI2C3	10	10	19	236	8330	17960	140
19		236	RP11-845b6		1	2.27E+08	2.27E+08	NKI2C3	10	12	19	236	8780	17960	150
20		236	RP11-845b6		1	2.27E+08	2.27E+08	NKI2C3	10	12	19	236	8780	17960	150
21		236	RP11-845b6		1	2.27E+08	2.27E+08	NKI2C3	10	11	19	236	8550	17960	140
22		236	RP11-845b6		1	2.27E+08	2.27E+08	NKI2C3	10	11	19	236	8550	17960	140
23		320	RP11-1084a2		2	47485695	47897380	NKI1F10	24	7	20	320	16660	31610	130
24		320	RP11-1084a2		2	47485695	47897380	NKI1F10	24	6	20	320	16440	31610	130
25		320	RP11-1084a2		2	47485695	47897380	NKI1F10	24	5	20	320	16220	31610	130
26		323	RP11-460n15		2	47854784	48034160	NKI2H8	4	12	20	323	17720	9190	130
27		323	RP11-460n15		2	47854784	48034160	NKI2H8	4	11	20	323	17500	9190	130
28		323	RP11-460n15		2	47854784	48034160	NKI2H8	4	13	20	323	17940	9190	130
29		324	RP11-3g11		2	47946940	48102089	NKI2H7	12	11	20	324	17540	18160	130
30		324	RP11-3g11		2	47946940	48102089	NKI2H7	12	12	20	324	17760	18160	140
31		324	RP11-3g11		2	47946940	48102089	NKI2H7	12	13	20	324	17990	18160	140
32		361	RP11-232j18		2	71372264	71537932	NKI1F4	8	20	19	361	19530	13430	130
33		361	RP11-232j18		2	71372264	71537932	NKI1F4	8	1	20	361	15250	13660	130
34		361	RP11-232j18		2	71372264	71537932	NKI1F4	8	19	19	361	19290	13430	130

# Podívejme se na reálná data!

V učebních materiálech k předmětu naleznete soubor cDNApriklad.zip

Soubor stáhneme a rozbalíme.

Struktura adresáře:

```
raw/  
cDNA.R  
E-GEO-45596.idf.txt  
E-GEO-45596.sdrf.txt  
SampleInfo.txt
```

Vyberte jeden ze souborů nacházejících se v adresáři raw/ a otevřete v EXCELU

```
GSM1110303_Texas_Tech_251485034901_S01_GE2-v5_91_0806_1_1.txt  
GSM1110304_Texas_Tech_251485036824_S01_GE2-v5_91_0806_1_1.txt  
GSM1110305_Texas_Tech_251485034901_S01_GE2-v5_91_0806_1_2.txt  
GSM1110306_Texas_Tech_251485036824_S01_GE2-v5_91_0806_1_2.txt  
...
```

# Základní datový soubor

Obsahuje (příklad GenePix 6.0)

- Pozice spotu
- Jméno a další identifikátory sondy na spotu
- Další charakteristiky spotu: (průměr, tvar, cirkularita, saturace, ...)
- Informace o intenzitě signálu pozadí, popředí (medián, průměr, suma, SD)
- Počet saturovaných pixelů
- Odvozené charakteristiky
  - i) % pixelů signálu s intenzitami většími než 1SD (2SD) intenzity pozadí
  - ii) intenzita signálu mínus intenzita pozadí
  - iii) poměr mediánů/průměrů obou kanálů
  - iv) logaritmus báze 2 tohoto poměru
- Informace o kvalitě spotu
- Proměnnou Flags

# Základní data

- Data v základním souboru **NEJSOU** koncentrace mRNA!
- Hodnoty získané z microarray experimentu jsou pozitivně korelované s množstvím přítomné mRNA, ale navíc v sobě nesou **ŠUM**, související s:
  - Kontaminací tkaniva
  - RNA degradací
  - Efektivitou
    - amplifikace DNA
    - reverzní transkripce
    - hybridizace a specifitou sond
  - Výběrem a identifikací sond
  - PCR výsledkem
- Efektivitou spotování
- Dalšími technickými vlivy při zpracování
- Segmentací obrazu
- Kvantifikací signálu
- Korekcí na pozadí

# Podívejme se na reálná data!

V učebních materiálech k předmětu naleznete soubor  
cDNApriklad.zip

Soubor stáhneme a rozbalíme.

Struktura adresáře:


```
raw/  
cDNA.R  
E-GEO-45596.idf.txt  
E-GEO-45596.sdrf.txt  
SampleInfo.txt
```

Vyberte jeden ze souborů nacházejících se v adresáři raw/ a otevřete ho v EXCELU

```
GSM1110303_Texas_Tech_251485034901_S01_GE2-v5_91_0806_1_1.txt  
GSM1110304_Texas_Tech_251485036824_S01_GE2-v5_91_0806_1_1.txt  
GSM1110305_Texas_Tech_251485034901_S01_GE2-v5_91_0806_1_2.txt  
GSM1110306_Texas_Tech_251485036824_S01_GE2-v5_91_0806_1_2.txt  
...
```


# Úrovně kontroly kvality

Úroveň mikročipu  
(základní datová matici)



Úroveň experimentu  
(finální datová matici)

Kvalita experimentu



Úroveň sondy: Kvalita jednoho spotu na mikročipu


Úroveň mikročipu: Kvalita celého mikročipu

Úroveň experimentu: Kvalita měření transkriptu všech mikročipů v experimentu

# Úrovně úpravy datových souborů

## Úroveň mikročipu

(základní datová matici)



Odstranění  
nekvalitních spotů

Sumarizace  
duplicátů

Normalizace  
uvnitř  
mikročipu

## Úroveň experimentu

(finální datová matici)

Kvalita experimentu

Normalizace  
mezi  
mikročipy

Mikročipy 1 ... n

Úroveň sondy: Kvalita jednoho spotu na mikročipu


Úroveň mikročipu: Kvalita celého mikročipu

Úroveň experimentu: Kvalita měření transkriptu všech mikročipů v experimentu

# Úrovně úpravy datových souborů

## Úroveň mikročipu

(základní datová matici)



Odstranění  
nekvalitních spotů

Sumarizace  
duplicátů




Normalizace  
uvnitř  
mikročipu

## Úroveň experimentu

(finální datová matici)

Kvalita experimentu



Normalizace  
mezi  
mikročipy

Úroveň sondy: Kvalita jednoho spotu na mikročipu

Úroveň mikročipu: Kvalita celého mikročipu

Úroveň experimentu: Kvalita měření transkriptu všech mikročipů v experimentu

# Kontrola dat v rámci mikročipového sklíčka

- Replikáty sond
  - Sumární statistiky replikátů spotů (nekvalitní spotty už vyloučené)

clone	Replicate			mean	median	SD	No. of non-flagged replicates
	1	2	3				
A_23_P347643	-0.186	-0.265	-0.313	-0.254	-0.265	0.052	3
A_23_P60243	0.523	flagged	flagged	0.523	0.523	0	1
A_23_P116057	0.039	-0.978	flagged	-0.495	-0.495	0.5	2
A_23_P203743	-0.614	0.537	1.589	0.504	0.537	0.899	3

- Bud' odstranit sondy s příliš velkou variabilitou mezi replikáty...
  - ...nebo si uschovat informaci o počtu validních replikátů (a vyhodit klony jen s jedním replikátem)


## Kvalita mikročipového sklíčka

- Procento nekvalitních spotů nesmí být příliš velké (<25 %)
- Systematické odchyly odstraníme procesem NORMALIZACE

# Úrovně úpravy datových souborů

## Úroveň mikročipu

(základní datová matici)



Odstranění  
nekvalitních spotů


Sumarizace  
duplicátů

Normalizace  
uvnitř  
mikročipu

## Úroveň experimentu

(finální datová matici)

Kvalita experimentu



Úroveň sondy: Kvalita jednoho spotu na mikročipu

Úroveň mikročipu: Kvalita celého mikročipu

Úroveň experimentu: Kvalita měření transkriptu všech mikročipů v experimentu


# Systematické odchylky uvnitř mikročipu

- Nerovnoměrná hybridizace (prostorové odchylky)
  - Příčina: nerovnoměrně umytý čip, nerovnoměrně distribuovaný vzorek, print-tip efekt (defektní jehla)
- Signál pozadí
  - Může být velmi silný, bud' špatně umytý čip, nebo špatná segmentace (část popředí je kvantifikovaná jako pozadí)
- Efekt barviva (rozdíly intenzit mezi kanály)
  - Příčina: odlišná schopnost inkorporace molekul barviva (Cy3, Cy5)  
odlišná reakce na excitaci (slabší intenzita UV, ...)


ODHALUJEME GRAFICKOU REPREZENTACÍ DAT

# Diagnostika nerovnoměrné hybridizace

Virtuální rekonstrukce mikročipu,  
vykreslení heatmapy log2  
poměru Cy5/Cy3 intenzit na  
základě jejich pozice na sklíčku




Box-ploty jednotlivých oblastí  
(nejčastejší print-tip)



# Diagnostika efektu barviva

- Často je efekt barviva větší u sond s nízkou expresí


Graf intensit kanálů



$$\begin{aligned} \text{Cy3} &= B_0 + B_1 * \text{Cy5} \\ (\text{Cy3}-B_0)/B_1 &= \text{Cy5}' \end{aligned}$$

Neukáže nelineární trendy

MA graf



$$\begin{aligned} M &= \log(R/G) \\ A &= 1/2(\log(R) + \log(G)) \end{aligned}$$

Ukáže nelineární trendy!

# Cvičení!

---

- Budeme pracovat v programu R-Studio
- 10 minutový krátký úvod do R – SW pro analýzu dat
- Ukážeme si jak instalovat balíky pro specifické analýzy genomických a proteomických dat
- Na příkladových datech uděláme diagnostiku kvality sklíčka

# Balík marray

- Balík **marray** poskytuje sadu funkcí pro analýzu cDNA čipů  
Instalace':

```
source("http://www.bioconductor.org/biocLite.R")
biocLite("marray")
```


- Základní strukturou, s kterou pracuje a která obsahuje základní data všech matic experimentu je třída  
**marrayRaw**

```
new('marrayRaw',
  maRf = ...., # matice intensit spotů červeného kanálu
  maGf = ...., # matice intensit spotů zeleného kanálu
  maRb = ...., # matice intensit pozadí červeného kanálu
  maGb = ...., # matice intensit pozadí zeleného kanálu
  maLayout = ...., # objekt třídy marrayLayout, popis mikročipu
  maGnames = ...., # objekt třídy marrayInfo, popis sond
  maTargets = ...., # objekt třídy marrayInfo, popis vzorků
  maNotes = ...., # text - poznámky )
```

# Další objekty balíku marray

- marrayLayout - popisuje mikročip, umístění spotů a jejich sondy

```
new('marrayLayout',
    maNgr = ... , #počet řádků matic
    maNgc = ... , #počet sloupců matic
    maNsR = ... , #počet řádků v matici
    maNsC = ... , #počet sloupců v matici
    maNsPots = ... , # maNgr x maNgc x maNsR x
    maNsC
    maSub = ... , # vektor TRUE/FALSE, které
    spoty se používají
    maPlate = ... , # faktor - print tip
    maControls = ... , # faktor - status sondy
    (kontrolná nebo ne?)
    maNotes = ... , # Object of class
    character)
```



# Další objekty balíku marray

- marrayInfo - popisuje vzorky nebo sondy

```
new( 'marrayInfo',
  maLabels = ...., # vektor jmen/názvů
  maInfo = ...., # datová tabulka s dalšími
  charakteristikami
  maNotes = ...., # text s poznámkami
  )
```

# Příklad I

- Načtěme si data **swirl**, které představují mikročipový experiment, porovnávající genovou expresi divokého druhu rybky Dánio pruhované a jejího mutanta v genu *BMP2*. Experiment byl proveden v *dye swap* designu, dohromady jsou k dispozici 4 mikročipy:

```
library(marray)  
data(swirl)  
str(swirl)
```

- Vytvořme si paletu barev a provedeme kontrolu kvality čipů  
`Gcol <- maPalette(low = "white", high = "green", k = 50)`  
`Rcol <- maPalette(low = "white", high = "red", k = 50)`  
`RGcol <- maPalette(low = "green", high = "red", k = 50)`

## Příklad II – kontrola prostorových efektů

- Vykreslíme si heatmapu třetího mikročipu s pomocí funkce **maImage**

```
maImage(swirl[, 3], x = "maRb") # vykreslíme pozadí  
červeného kanálu
```

```
maImage(swirl[, 3], x = "maGb") # vykreslíme pozadí  
zeleného kanálu
```

```
maImage(swirl[, 3], x = "maM") # vykreslíme poměr  
intensit spotů obou kanálů ( $M$  hodnoty)
```

- Funkce **maImage** dokáže vykreslit i efekt print-tipu:

```
maImage(swirl[, 1], x="maPrintTip")
```

- Funkce **maBoxplot** vykreslí krabicové grafy

```
maBoxplot(swirl[,1])
```

# Příklad III – efekt barviva

- Vykreslíme jednoduše pomocí základní funkce **plot**, a dvou funkcí, kterými z **marrayRaw** objektu extrahujeme intensity spotů červeného a zeleného kanálu:

```
R = maRf(swirl[,1])
```

```
G = maGf(swirl[,1])
```

```
plot(R, G)
```

```
abline(a=0, b=1) # vykreslíme diagonálu
```

- Funkce **plot** aplikována přímo na objekt třídy **marrayRaw** vykreslí MA graf, s odhadem křivek podle jednotlivých printtipů

```
plot(swirl[,1])
```

- Jiným způsobem je prvně vypočítat hodnoty  $A$  a  $M$ , a pak je vykreslit

```
A = maA(swirl[,3])
```

```
M = maM(swirl[,3])
```

```
plot(A, M)
```

# Normalizace uvnitř mikročipu I.

- Cíl: Upravit hodnoty signálu tak, aby chom odstranili systematické odchylky uvnitř mikročipu
- Princip: *Centrování a/nebo škálování* hodnot exprese  $M$

$$M_{norm} = \frac{M - l}{s},$$

kde  $l$  a  $s$  jsou normalizační hodnoty centra ( $l$ ) a škály ( $s$ )

# Normalizace uvnitř mikročipu I - metody

---

- Typy normalizace:

1) **Logaritmická transformace** – většinou používaná z důvodu transformace dat na normální rozdělení

$$M_{norm} = \log_2(M)$$

# Normalizace uvnitř mikročipu I - metody

- Typy normalizace:

1) **Logaritmická transformace** – většinou používaná z důvodu transformace dat na normální rozdělení

$$M_{norm} = \log_2(M)$$

2) **Korekce na pozadí**

- odstraňuje efekt pozadí
- odlišné přístupy:

1) odpočítá se odhadnutý signál pozadí – založené na předpokladu aditivity signálu

Pozorovaný signál (OS) = Signál pozadí (BS) + Signál sondy (TS)

$$TS = OS - BS$$

- bud' pro každý spot zvlášť, nebo globálně

$$M_{norm} = M - l$$

pozadí

2) bez korekce!


odhadnutý signál

# Normalizace uvnitř mikročipu I - metody

## 3) Normalizace prostorového efektu a rozdílů intenzit mezi kanály

- Centrování mediánem

- odčítá medián od intenzit všech spotů
- nejjednodušší, ale není schopný zkorigovat nelinearitu



$$M_{norm} = M - l,$$




*I je medián intenzit všech spotů*


# Problémy s mediánovým centrováním

Jedná sa o globální metodu, není schopná vyrovnat lokální efekty, problémy odlišných intenzit, print-tip efekty atd.

Graf intensit kanálů



MA graf



S nelinearitou si umí poradit **lokálně regresní metody (lo(w)ess)**


# Lowess normalizace I

Princip:


- 1.Odhad křivky pomocí neparametrické lokální vážené regrese (lowess - locally weighted scatterplot smoothing)
- 2.Odečtení odhadnuté křivky od naměřených hodnot

Výhoda : není nutné znát funkci křivky, je odhadnuta z dat!

Před lowess normalizací



Po lowess normalizaci



# Lowess normalizace II

## Princip lowess

- V každém kroku se určí lokální množina dat, na které se odhadne křivka s pomocí polynomiálu a metody nejmenších čtverců
- Parameter  $\lambda$  určuje stupeň polynomiálu ( $\lambda=0$  půměr,  $\lambda=1$  lineární regrese,  $\lambda=2$  kvadratická regrese)
- Množina dat na které se pracuje se určuje pomocí algoritmu nejbližšího souseda
- Vyhlašovací parameter  $\alpha$  určuje velikost této množiny ( $n\alpha$  bodů v okolí odhadovaného bodu)
- $\alpha$  nabývá hodnot mezi  $(\alpha + 1)/n$  a 1

# Normalizace uvnitř mikročipu II.

- Křivky odhadujeme:
  - na základě signálů **všech sond na mikročipu**  
Předpoklad: exprese většiny genů, které sondy představují, není změněná mezi porovnávanými skupinami! (závisí od mikročipu a od testované hypotézy)
  - na základě signálu **skupiny sond**:
    - i) skupina sond by měla mít přibližně stejnou expresi ve všech vzorcích (aby jsme neodstranili reálné biologické rozdíly)
    - ii) množina by měla být dostatečně velká, aby zachytily variabilitu sklíčka

*Napr. housekeeping geny*

# Příklad IV – normalizace uvnitř mikročipu

- Aplikujme centrování mediánem na  $M$  hodnoty prvního mikročipu z příkladu a zkontrolujme, jak se normalizace (ne)poprala s nelineárními efekty:

```
plot(swirl[,1])
swirl.norm <- maNormMain(swirl[,1], f.loc =
  list(maNormMed(x=NULL, y="maM")))
plot(swirl.norm)
```


- A teď aplikujme normalizaci pomocí loess:

```
swirl.norm.loess <- maNormMain(swirl[,1], f.loc =
  list(maNormLoess()))
plot(swirl.norm.loess)
```

# Úrovně úpravy datových souborů


## Úroveň mikročipu

(základní datová matici)



Odstranění  
nekvalitních spotů

Sumarizace  
duplicátů




Normalizace  
uvnitř  
mikročipu

## Úroveň experimentu

(finální datová matici)

Kvalita experimentu



Normalizace  
mezi  
mikročipy

mikročipy 1 ... n

Úroveň sondy: Kvalita jednoho spotu na mikročipu

Úroveň mikročipu: Kvalita celého mikročipu

Úroveň experimentu: Kvalita měření transkriptu všech mikročipů v experimentu

# Normalizace mezi mikročipy

- Když jsou všechny datové matice mikročipů znormalizované, tak vytváříme **finální datovou matici**, kterou použijeme pro následnou analýzu  
řádky ~ vzorky, sloupce ~ geny
- Jednotlivé soubory musíme normalizovat navzájem, abychom odstranili efekty mezi sklíčky, způsobené rozdílnou hybridizací, rozdílným množstvím vzorku (mRNA), rozdílným efektem skenování, chybami v segmentaci... apod.
- Princip – sjednocení rozložení (průměr, směrodatná odchylka, případně kvantily)

# Metody normalizace mezi mikročipy

- **Globální centrování**

Nastaví průměr a škálu všech sklíček na jednu hodnotu (medián, průměr, ořezaný průměr... všech čipů nebo hodnoty referenčního čipu)

Nevýhoda: předpokládá, že rozdíly jsou jen posunové, lineární

- **Škálování**

Tato metoda sjednocuje variabilitu jednotlivých mikročipů, například podělením hodnot mediánovou absolutní odchylkou jejich intenzit. Obvykle se kombinuje s centrováním.

- **Loess**

Probíhá cyklickým způsobem – vždy mezi páry mikročipů až do konvergence. Také je možné vybrat množinu sond na kterých se udělá odhad loess křivky

- **Kvantilová normalizace**

# Kvantilová normalizace

Je založena na **pořadí** pozorování, je tedy **neparametrická**. Bud' na skupině všech sond, nebo jen na skupině vybraných sond.


**Princip:** U každého mikročipu se geny seřadí dle hodnoty exprese a tyto hodnoty se potom nahradí průměrnou hodnotou kvantilu, který představuje v celém čipu

<b>hodnoty</b>				<b>pořadí</b>				<b>Seřazené hodnoty</b>			
Gen	čip1	čip2	čip3	Gen	čip1	čip2	čip3	čip1	čip2	čip3	
A	5	4	3	A	iv	iii	i	i	2	1	3
B	2	1	4	B	i	i	ii	ii	3	2	4
C	3	4	6	C	ii	iii	iii	iii	4	4	6
D	4	2	8	D	iii	ii	iv	iv	5	4	8

# Kvantilová normalizace

Je založena na **pořadí** pozorování, je tedy **neparametrická**. Bud' na skupině všech sond, nebo jen na skupině vybraných sond.

**Princip:** U každého mikročipu se geny seřadí dle hodnoty exprese a tyto hodnoty se potom nahradí průměrnou hodnotou kvantilu, který představuje v celém čipu



$$(2+1+3)/3 = 2.00 = \text{pořadí i}$$

$$(3+2+4)/3 = 3.00 = \text{pořadí ii}$$


$$(4+4+6)/3 = 4.67 = \text{pořadí iii}$$

$$(5+4+8)/3 = 5.67 = \text{pořadí iv}$$

# Kvantilová normalizace

Je založena na **pořadí** pozorování, je tedy **neparametrická**. Bud' na skupině všech sond, nebo jen na skupině vybraných sond.

**Princip:** U každého mikročipu se geny seřadí dle hodnoty exprese a tyto hodnoty se potom nahradí průměrnou hodnotou kvantilu, který představuje v celém čipu



# Příklad V – normalizace mezi čipy

- Provedeme normalizaci pomocí loess a následně škálovou normalizaci mezi čipy a znovu vykreslíme krabicové grafy.

```
swirl.norm <- maNormMain(swirl)
swirl.norm.scale = maNormScale(swirl.norm)
maBoxplot(swirl.norm.scale)
```

# Shrnutí

---

- Základní data nejsou mRNA koncentrace
- Musíme zkontolovat kvalitu dat na různých úrovních
  - Úroveň sondy
  - Úroveň sklíčka (všechny sondy na sklíčku)
  - Úroveň genu (gen mezi sklíčky)
- Data vždy transformujeme *logaritmem*, abychom zabezpečili normální rozložení hodnot
- Data normalizujeme aby jsme odstranili systematické (technické) chyby

# Příklad

---

- Podívame se do našeho adresáře s cDNA příkladem a otevřeme cDNA.R v programu Rstudio.
- Postupujeme dle instrukcí, na konci je dobrovolný úkol.

Do konce hodiny máte čas na práci na projektu