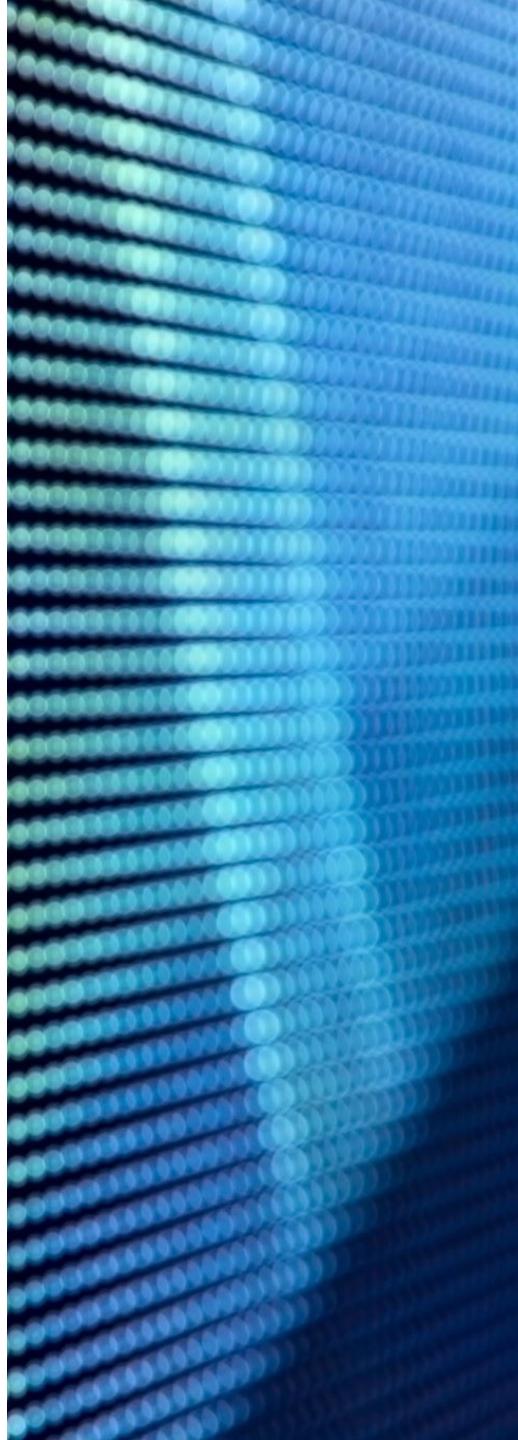


# Detekce biomarkerů z omics experimentů

- Mgr. Eva Budinská, PhD
- RECETOX
- [eva.budinska@recetox.muni.cz](mailto:eva.budinska@recetox.muni.cz)
- Podzim 2024

# Jak probíhá předzpracová- ní omicsových dat

---



# Biomarkery z omicsových dat

Jsou často komplexní:

- Složené z více charakteristik (více genů, proteinů...)
- Bez jasné definovaného biologického zdůvodnění

Pocházejí z dat:

- zatížených **významným technickým šumem** z různých zdrojů
- analyzovaných **metodami**, které **nejsou standardizované**
- které jsou pouze **korelované** s měřenou proměnnou (např. nejsou koncentrace ani počty molekul)
- které jsou **komplexní** a **obtížně se sdílejí**

# Jak vznikají čestné chyby?

## **Práce ve skupinách:**

Napište tři příklady ke každému bodu  
(10 min)



**Nejčastější  
zdroje  
“čestných chyb”  
(honest errors)**

**Chyby v měření a v  
laboratorních postupech**

**Nesprávně zvolena  
statistická metodologie**

**Manuální práce s daty**

# Jak můžeme tyto chyby minimalizova t?

Nedostatek  
kontroly:

Nedostatek  
znalostí:

Nedostatek  
času:

Nedostatek  
financí:

Čestná  
chyba  
(honest  
error) – jak ji  
minimalizov  
at

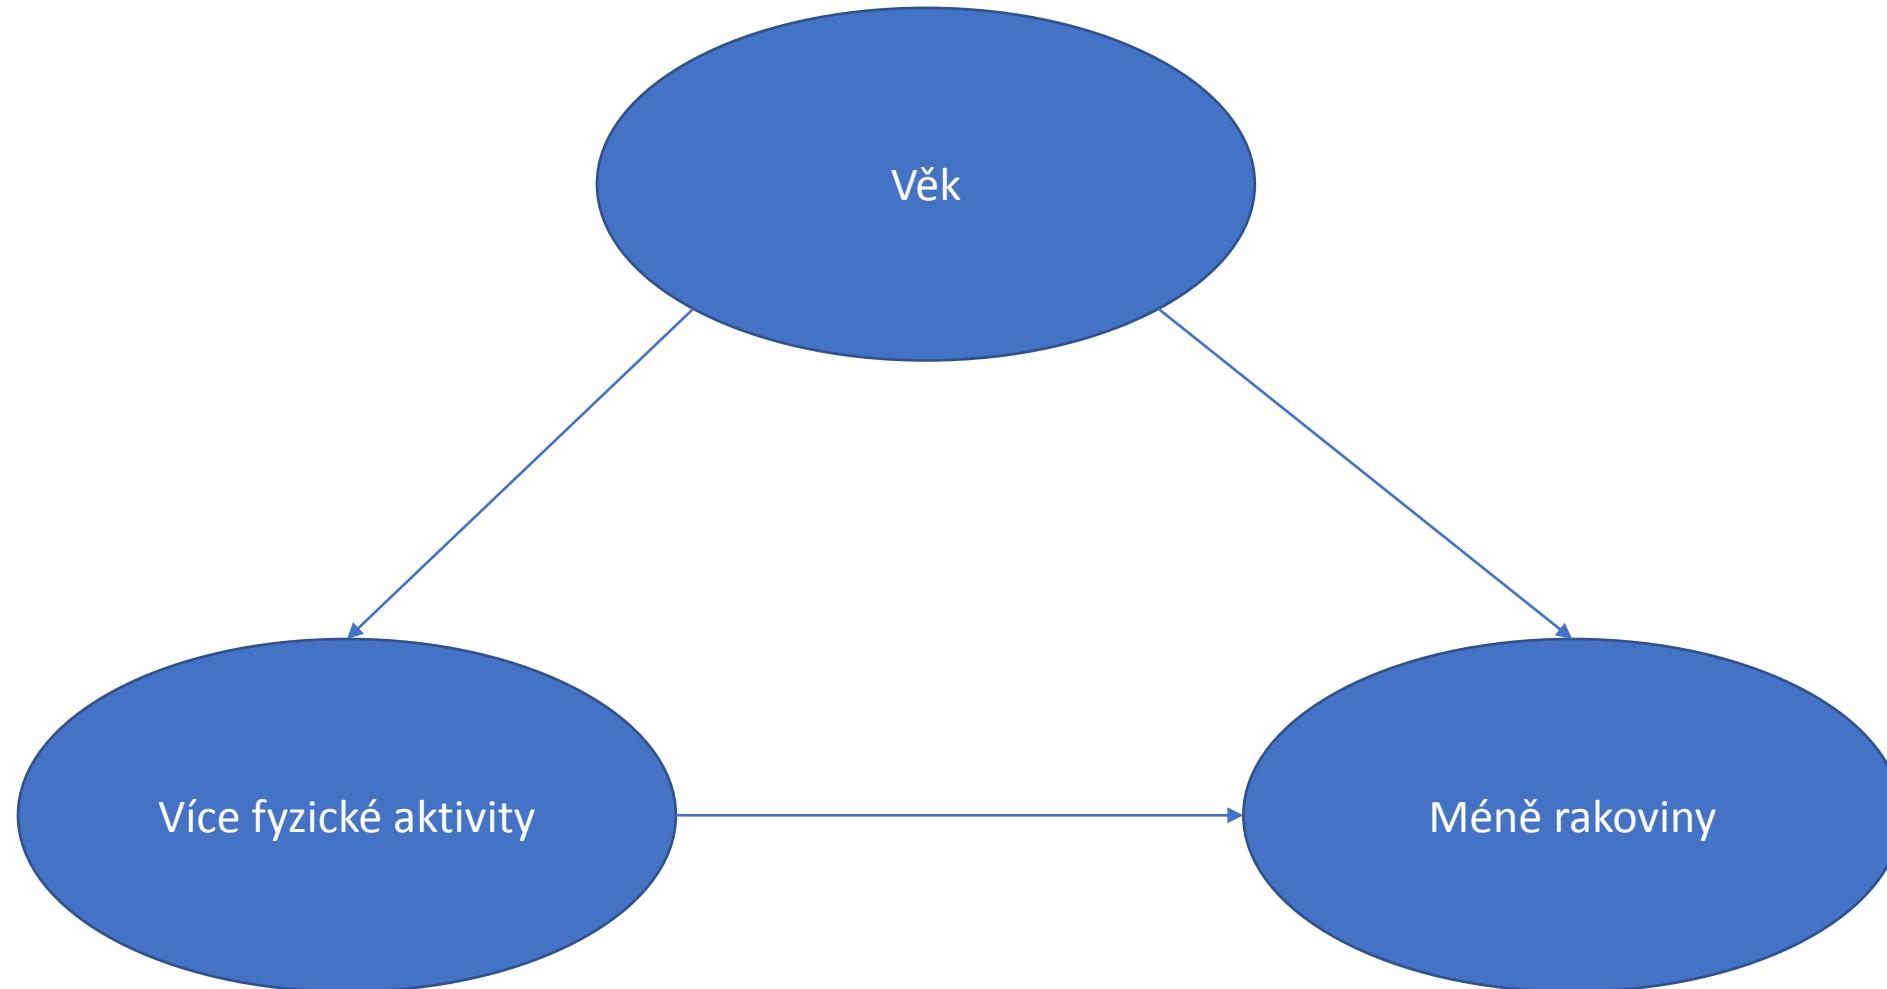
Za všechno mohou  
matoucí vlivy  
(confounding effects)?

# Co je to matoucí faktor

Matoucí faktor (*confounding factor*) je (neznámá) vnější proměnná, která ovlivňuje závislou proměnnou i nezávislou proměnnou v analýze, což způsobuje jejich falešnou asociaci a špatnou interpretaci.

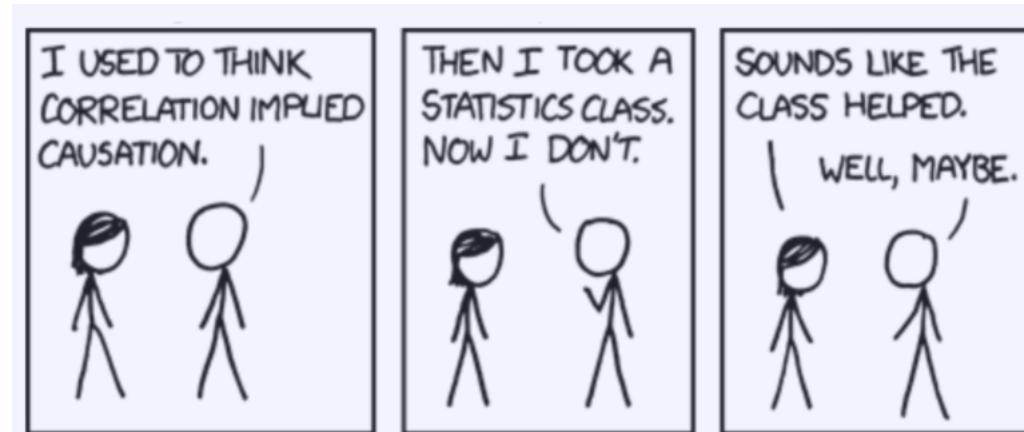
Jiným způsobem, vzniká korelace, která není kauzalita....

# Matoucí vliv



# Pochybné korelace....

<https://www.tylervigen.com/spurious-correlations>



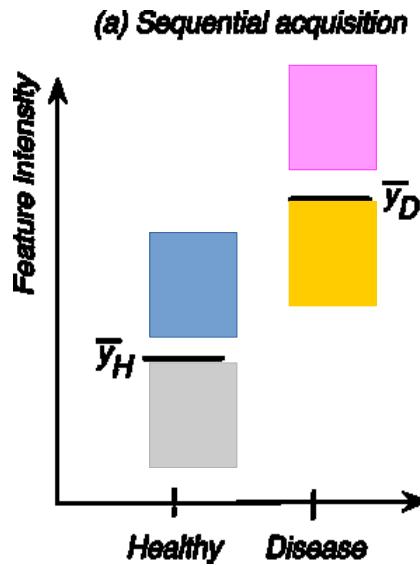
<http://xkcd.com/552/>

# Efekt dávky

- Efekt dávky (*batch effect*) se objevuje vždy, když externí faktory spojené s laboratorní prací ovlivňují výsledky, které měříte ve studii.
- Efekt dávky je speciální typ matoucího faktoru v případě, že je dávka spojená s proměnnou, kterou sledujeme

# Efekt dávky

Pozorovaná proměnná (zdraví vs nemoc) se překrývá s jinou technickou proměnnou, např:



1. a 2. den analýza zdravé tkáně
3. a 4. den analýza nádorové tkáně

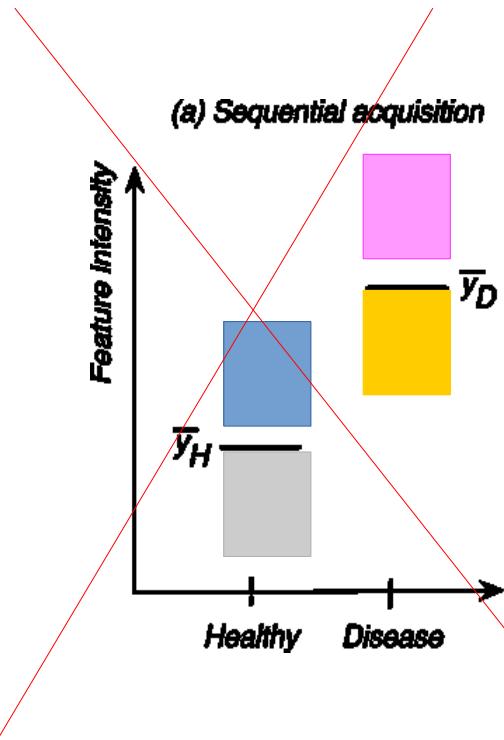
Nebo

Laborant 1 – zdravá tkáň, laborant 2 – nádorová tkáň

Nebo

Illumina primery (pro sekvenaci) 1-6 pro vzorky stolice,  
Illumina primery 7-12 pro bukální stěry

# Efekt dávky



Pozorovaná proměnná (zdraví vs nemoc) se překrývá s jinou technickou proměnnou, např:

1. a 2. den analýza zdravé tkáně
3. a 4. den analýza nádorové tkáně

Nebo

Laborant 1 – zdravá tkáň, laborant 2 – nádorová tkáň

Nebo

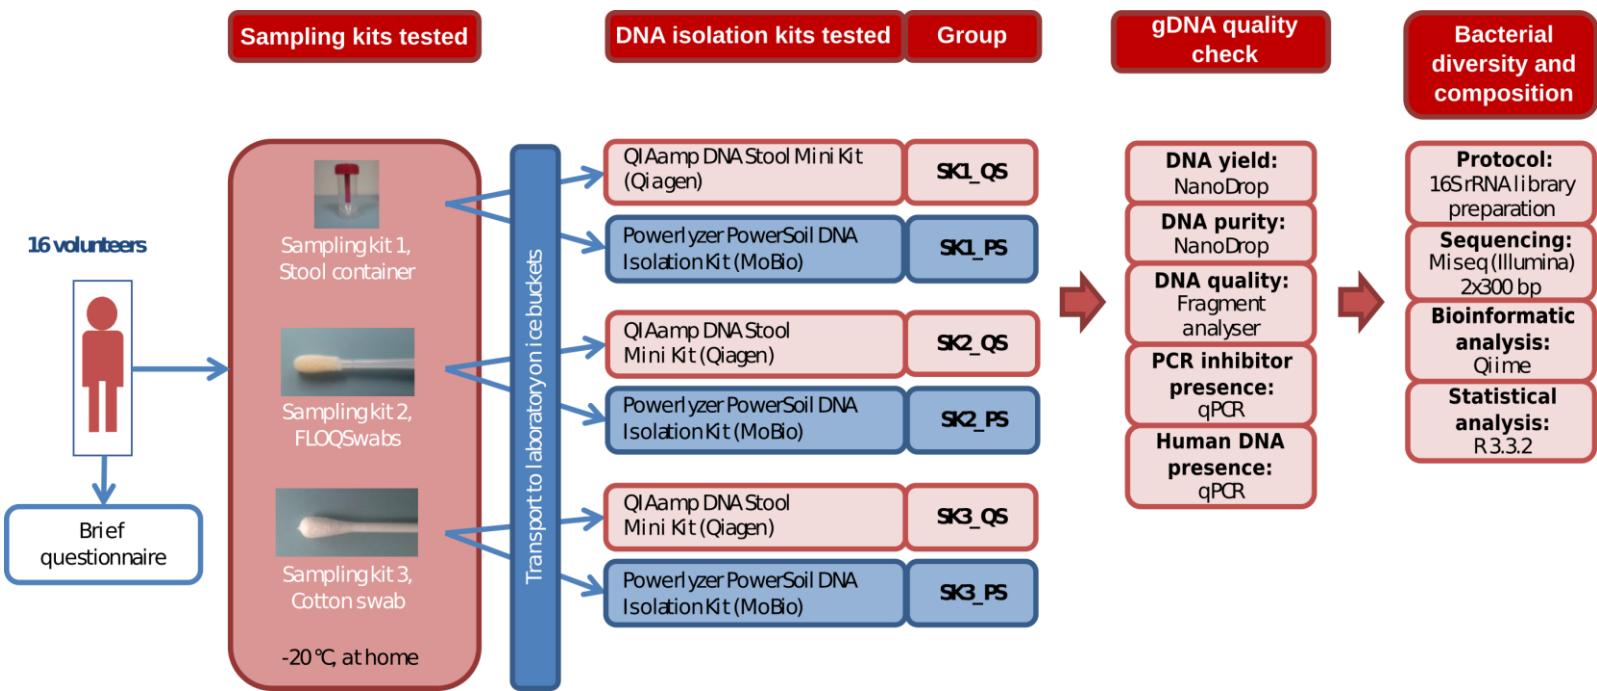
Illumina primery (pro sekvenaci) 1-6 pro vzorky stolice,  
Illumina primery 7-12 pro bukální stěry

NENÍ MOŽNÉ STATISTICKY ODDĚLIT TECHNICKÝ EFEKT OD BIOLOGICKÉHO!!!

# Příklady efektu dávky z praxe

# Sekvencování mikrobiomu – efekt primeru Illumina

**Experiment:**  
Sekvenace genu pro 16S rRNA  
**Cíl:** Porovnat vliv odběrových a izolačních kitů na složení mikrobiomu ve stolici

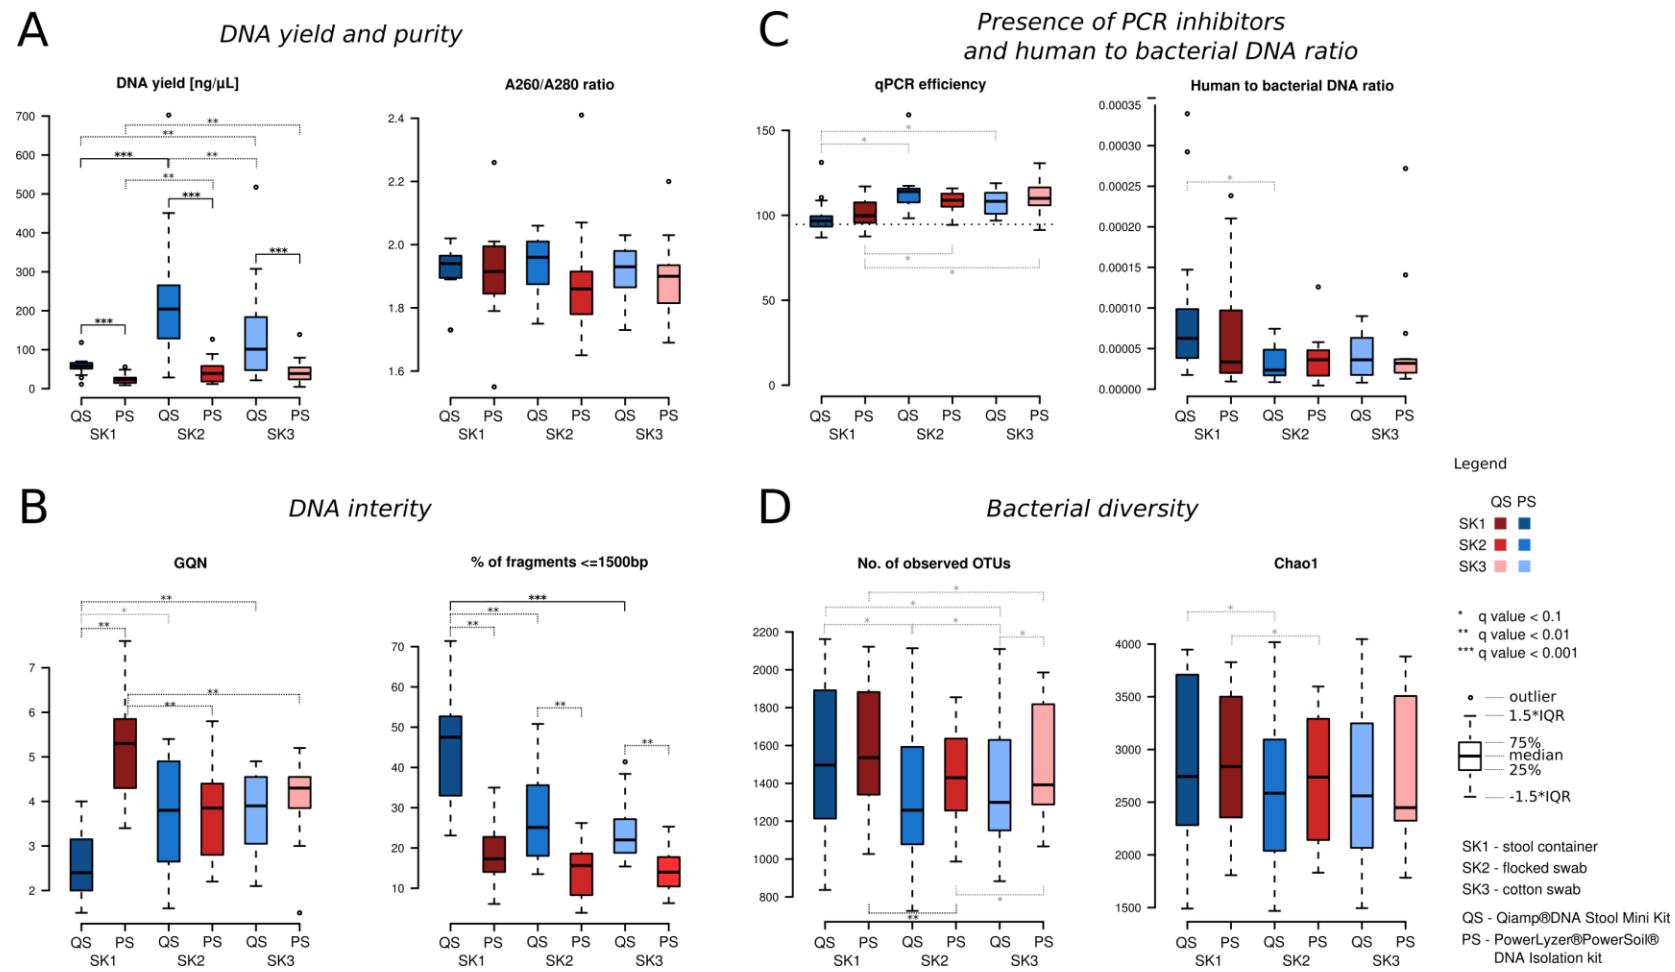


Porovnání 3 odběrových kitů (S1, S2, S3) a 2 DNA izolačních kitů (1,2)

**16** dobrovolníků použilo všechny odběrové kity na odběr stolice, z každého odběru izolace DNA dvěma kity

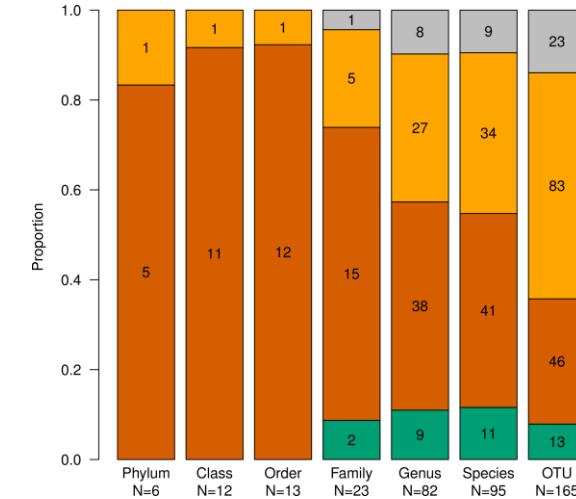
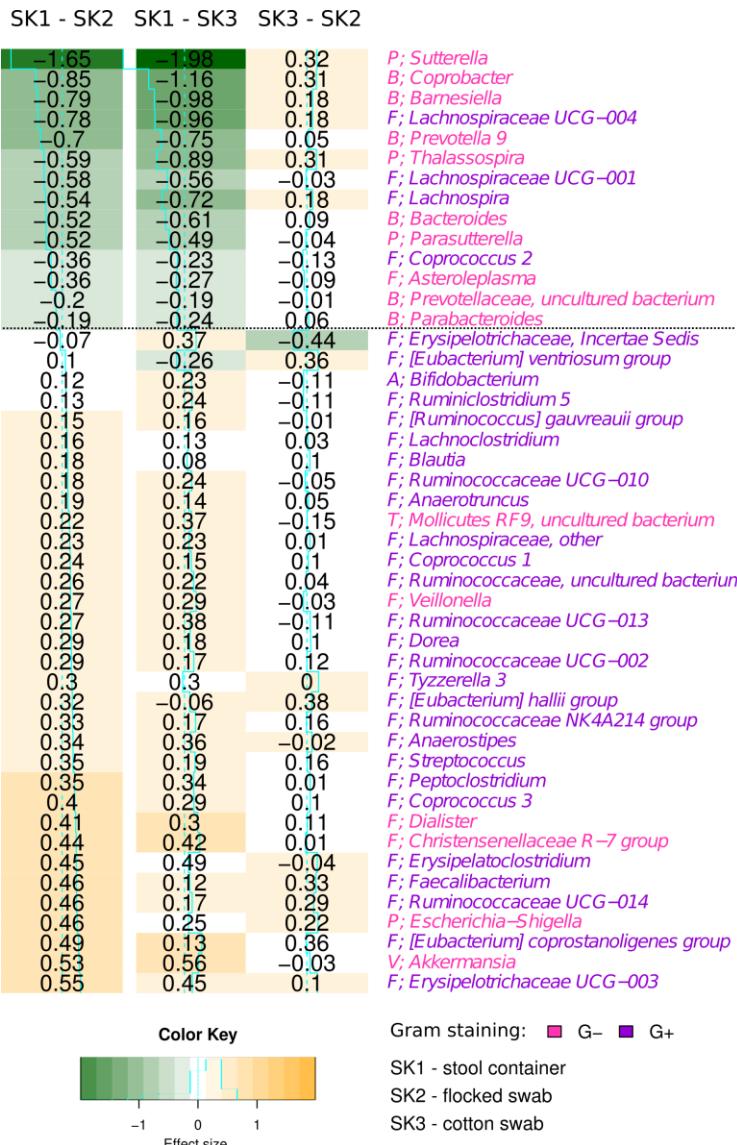
=> sekvenační analýza genu pro 16S rRNA

**Experiment:**  
Sekvenace genu pro  
16S rRNA  
**Cíl:** Porovnat vliv  
odběrových a  
izolačních kitů na  
složení mikrobiomu  
ve stolici



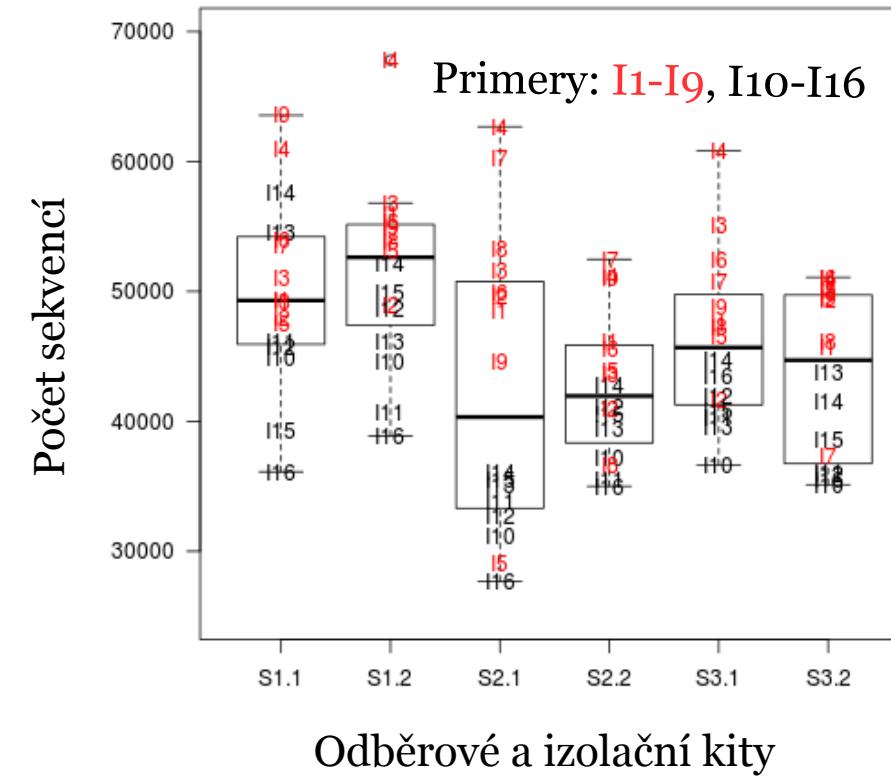
Nalezen vliv odběrového a izolačního kitu na kvalitu a kvantitu DNA a také na složení mikrobiomu!

Experiment:  
Sekvenace genu pro  
16S rRNA  
Cíl: Porovnat vliv  
odběrových a  
izolačních kitů na  
složení mikrobiomu  
ve stolici



Nalezen vliv odběrového a izolačního kitu na kvalitu a kvantitu DNA a také na složení mikrobiomu!

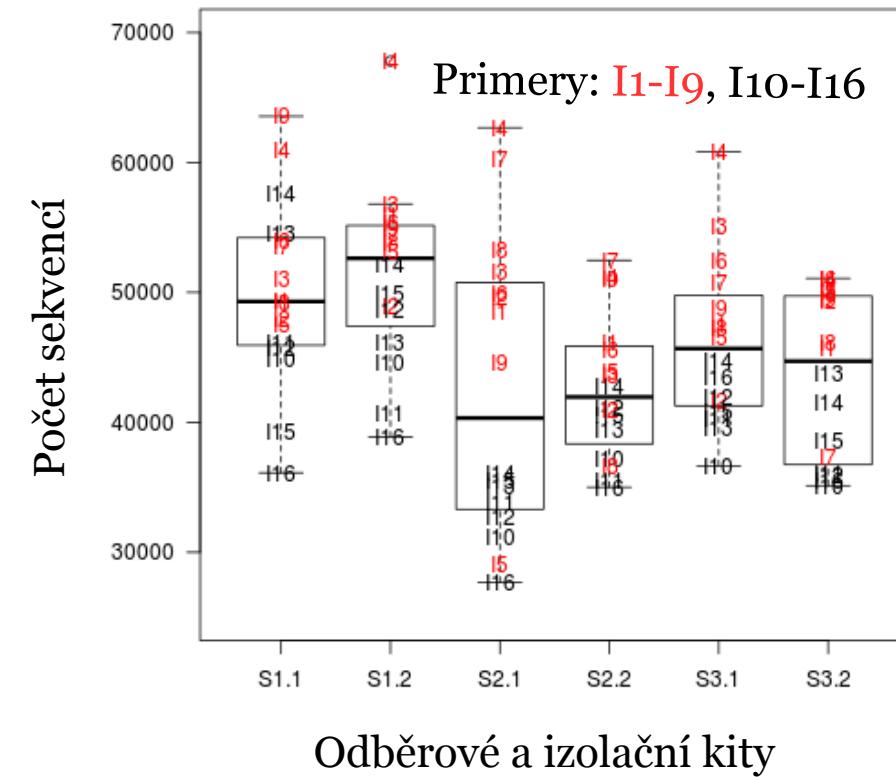
Experiment:  
Sekvenace genu pro  
16S rRNA  
Cíl: Porovnat vliv  
**odběrových a**  
**izolačních kitů** na  
složení mikrobiomu  
ve stolici



Každý účastník měl vždy stejný primer.

**Počet sekvencí je statisticky významně vyšší u  
primerů I1-I9 v porovnání s primery I10-I16!!!**

Experiment:  
Sekvenace genu pro  
16S rRNA  
Cíl: Porovnat vliv  
**odběrových a**  
**izolačních kitů** na  
složení mikrobiomu  
ve stolici

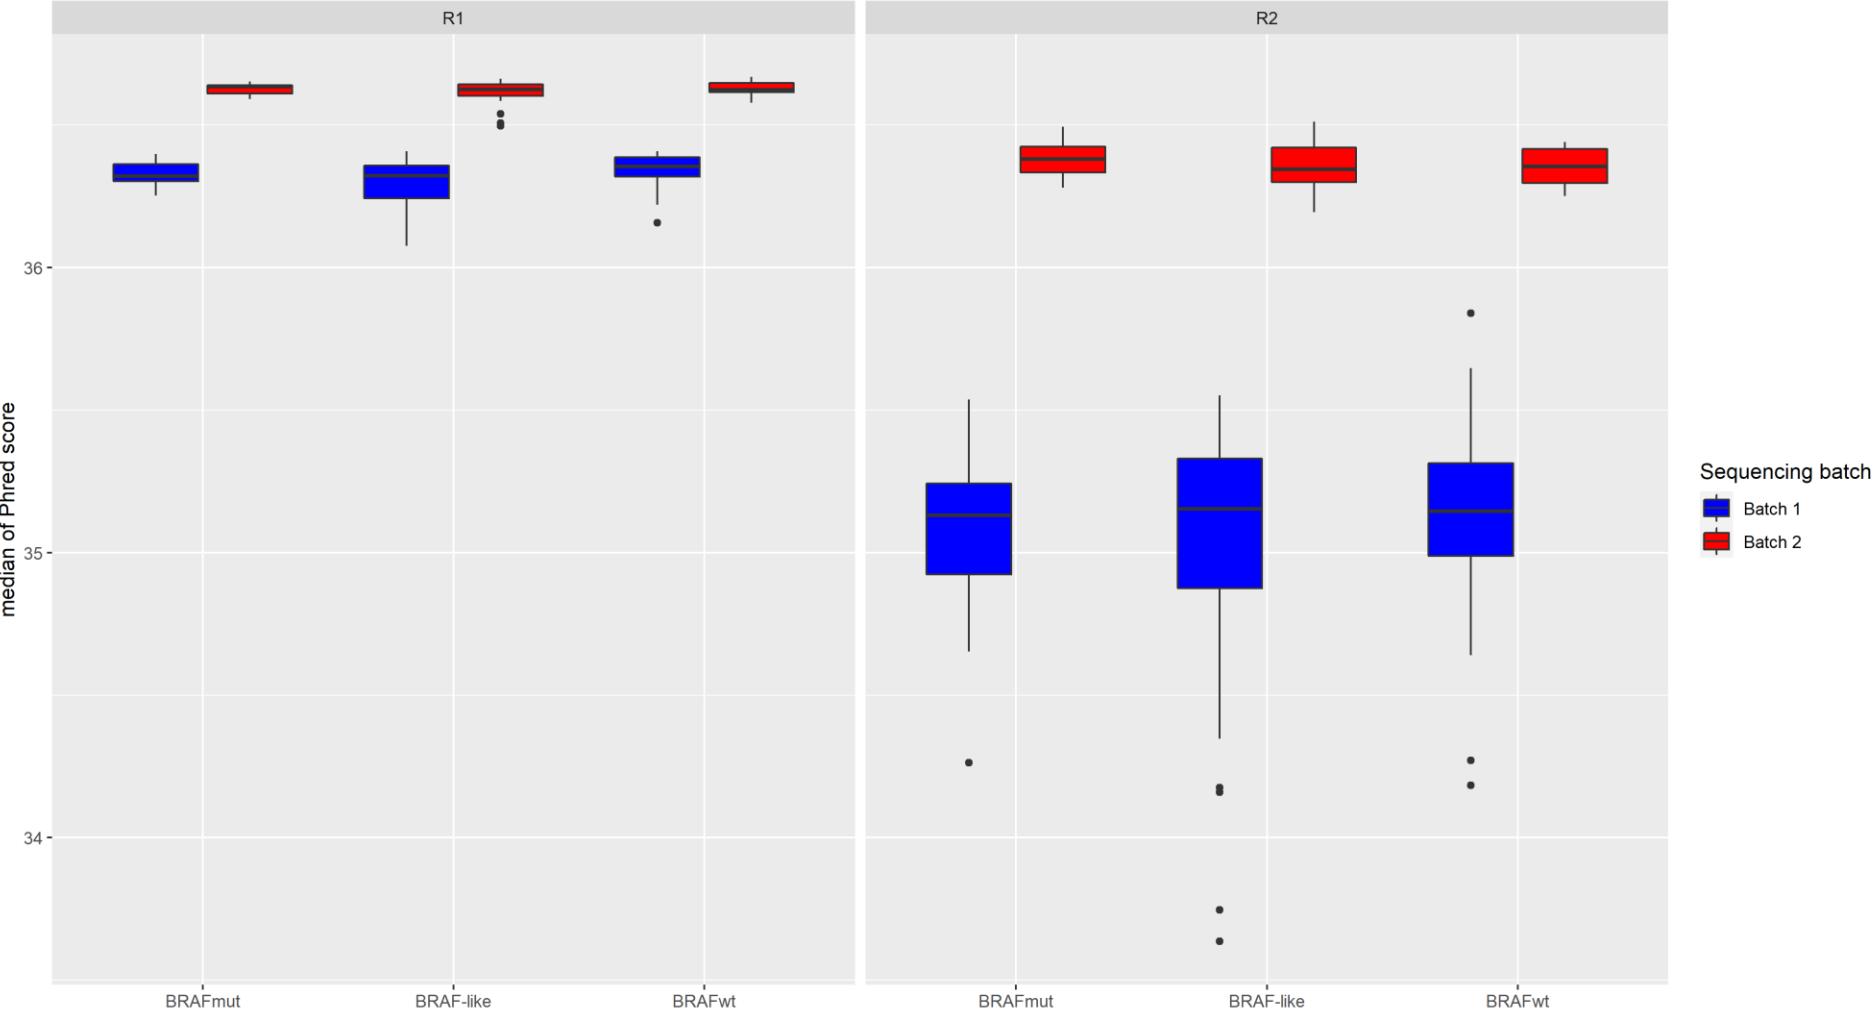


PROBLÉM: primer může mít efekt na složení mikrobiomu

ŘEŠENÍ: primer (nebo lépe řečeno skupina I1-I9 vs I10-I16) jako nová proměnná ve statistické analýze, odhad efektu skupiny primerů:

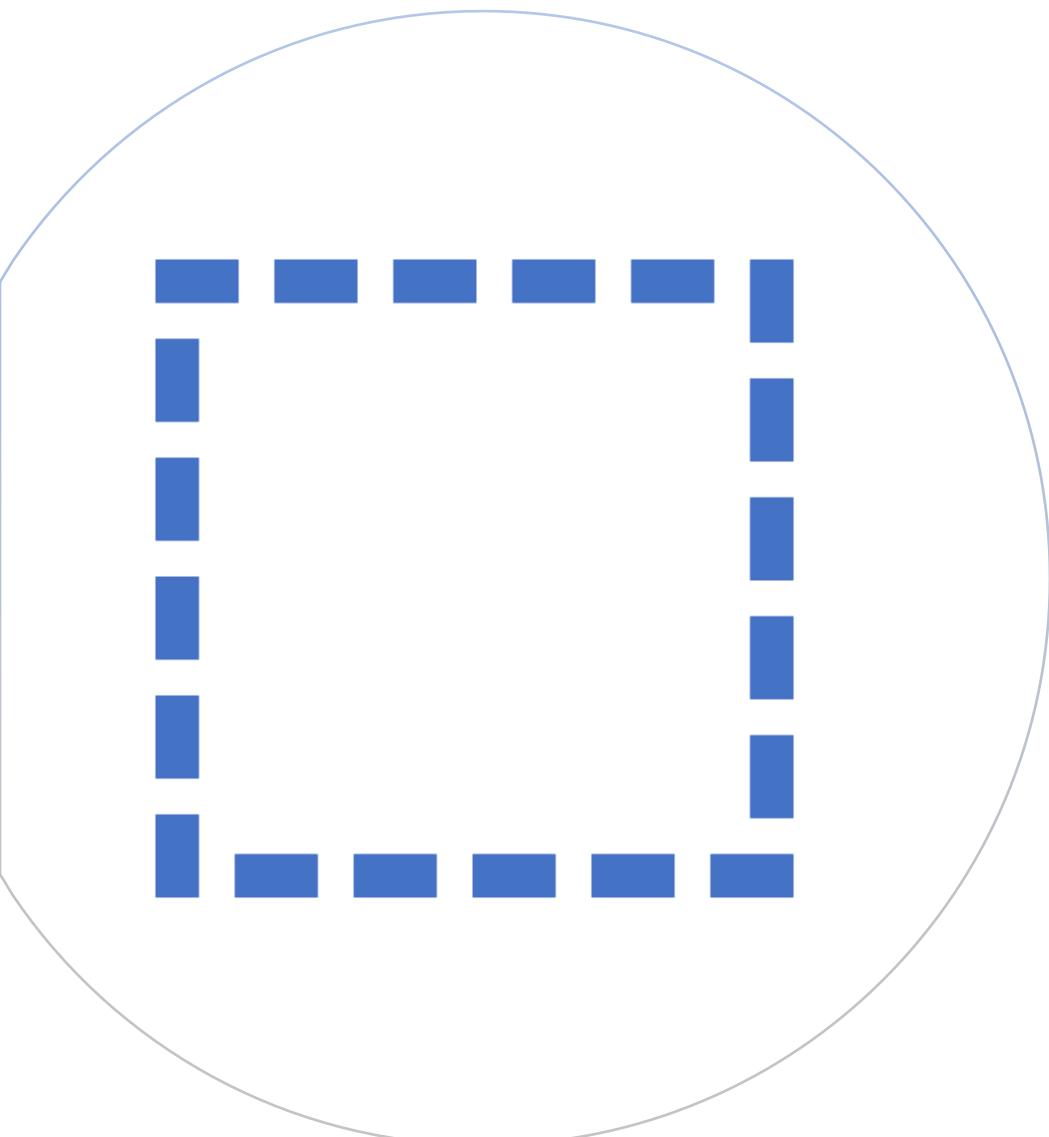
VÝSLEDEK: zdá se, že primer ovlivňuje pouze počet sekvencí, ne složení mikrobiomu (?).

# Illumina sekvencování RNAseq kolorektálního karcinomu ve 2 dávkách



- Kvalita čtení se výrazně liší mezi dávkami

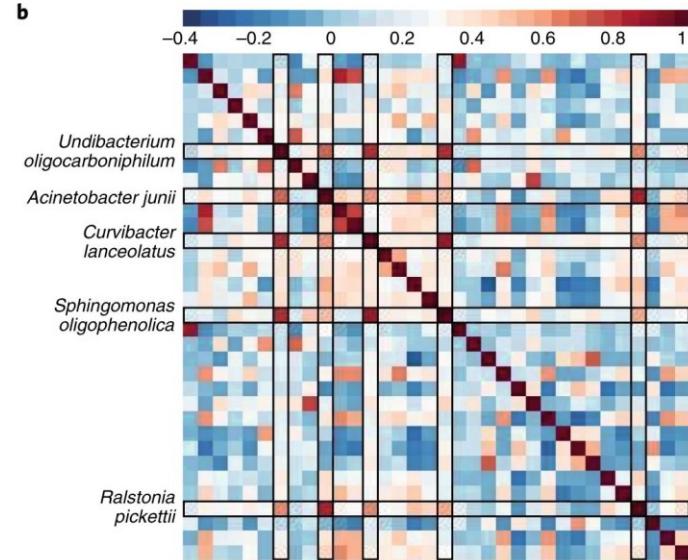
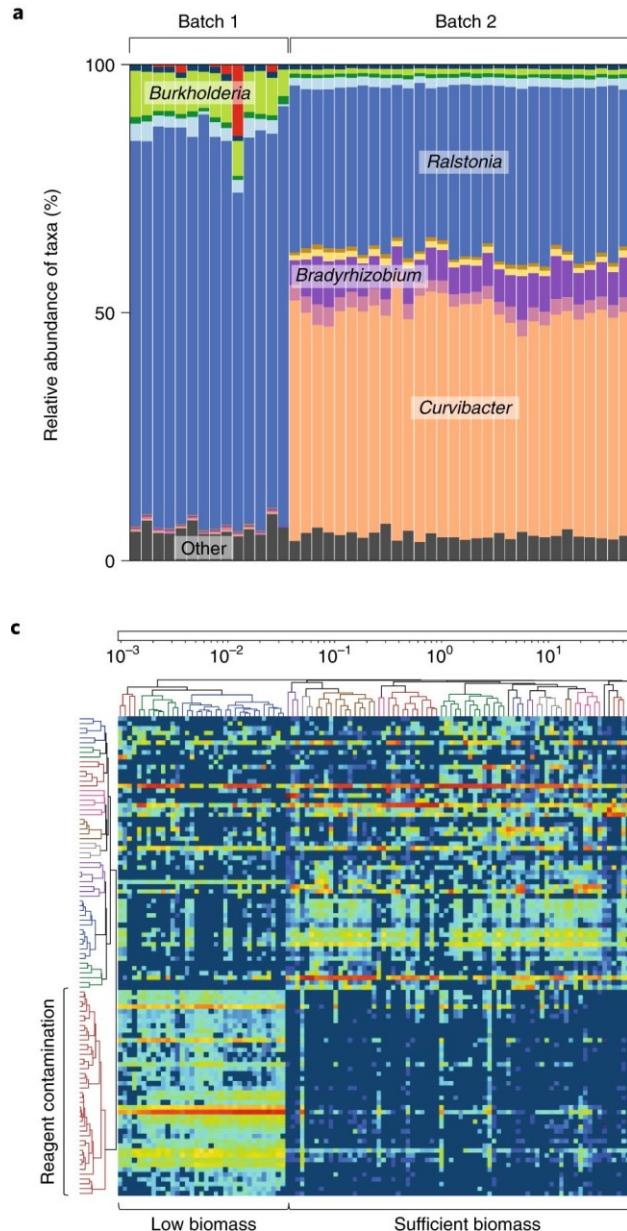
# Mikrobiální kontaminace v NGS



# Mikrobiální kontaminace

- Velký problém zejména u metagenomických studií a u vzorků s nízkým obsahem bakteriální DNA





**Fig. 1: Reagent contamination recognition strategies.**

**a**, Between-batch variation allows for rapid identification of reagent contamination. This example is from a 16S analysis of placental tissues... FastDNA SPIN kits with different lot numbers were used for batches 1 and 2.

...

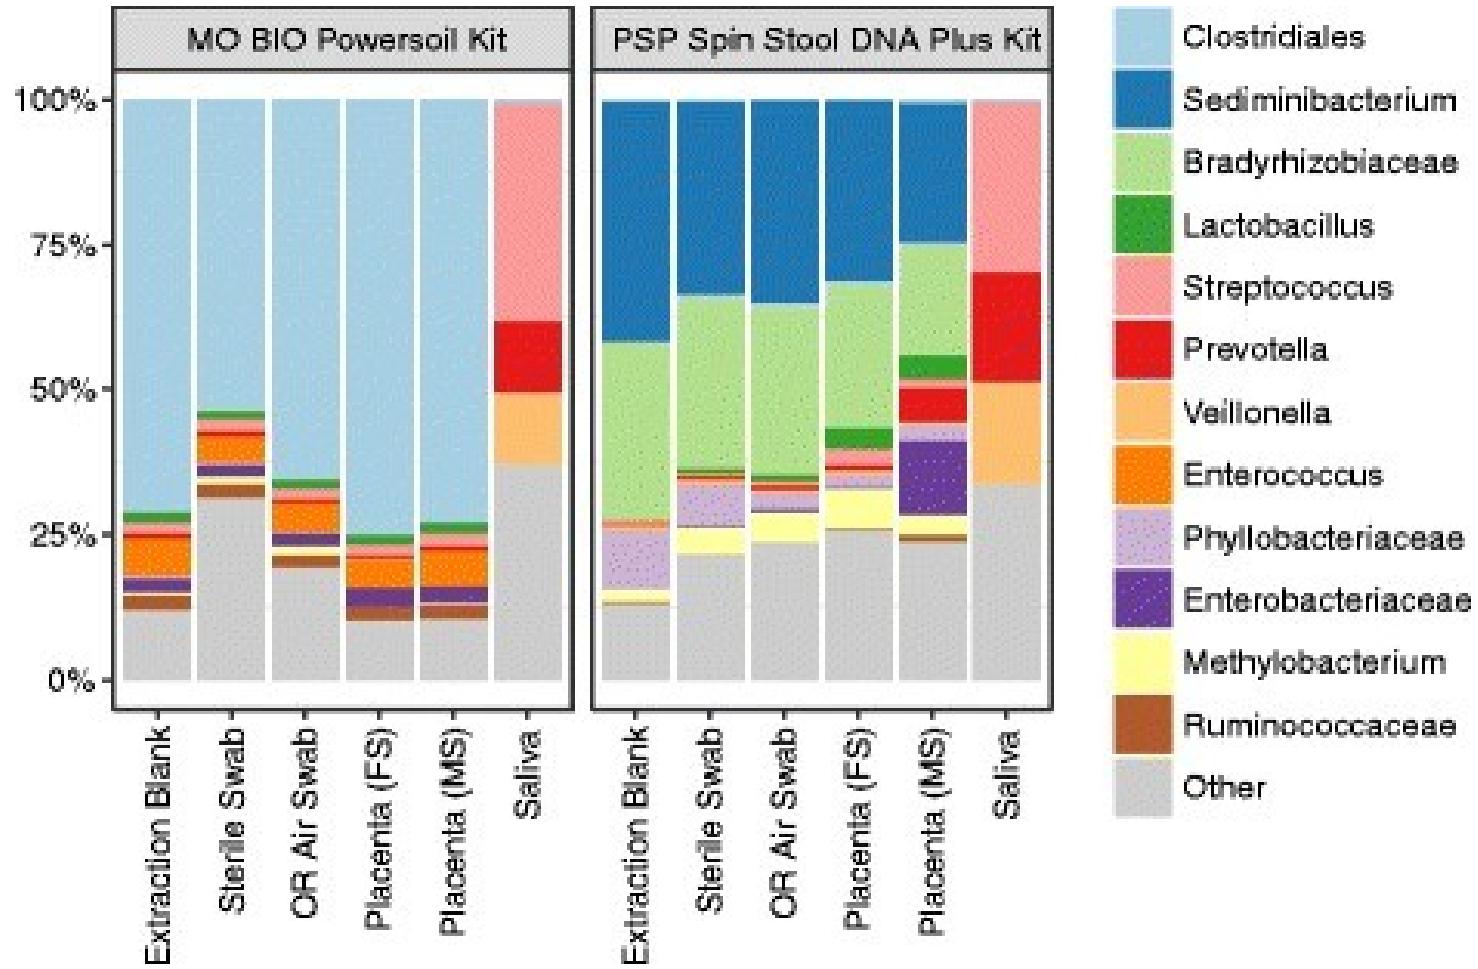
**b**, Spearman's rho correlation coefficient heatmap of a subset of the most common species detected ( $x$ - and  $y$ -axes) during a study of necrotizing enterocolitis in pre-term infants

...

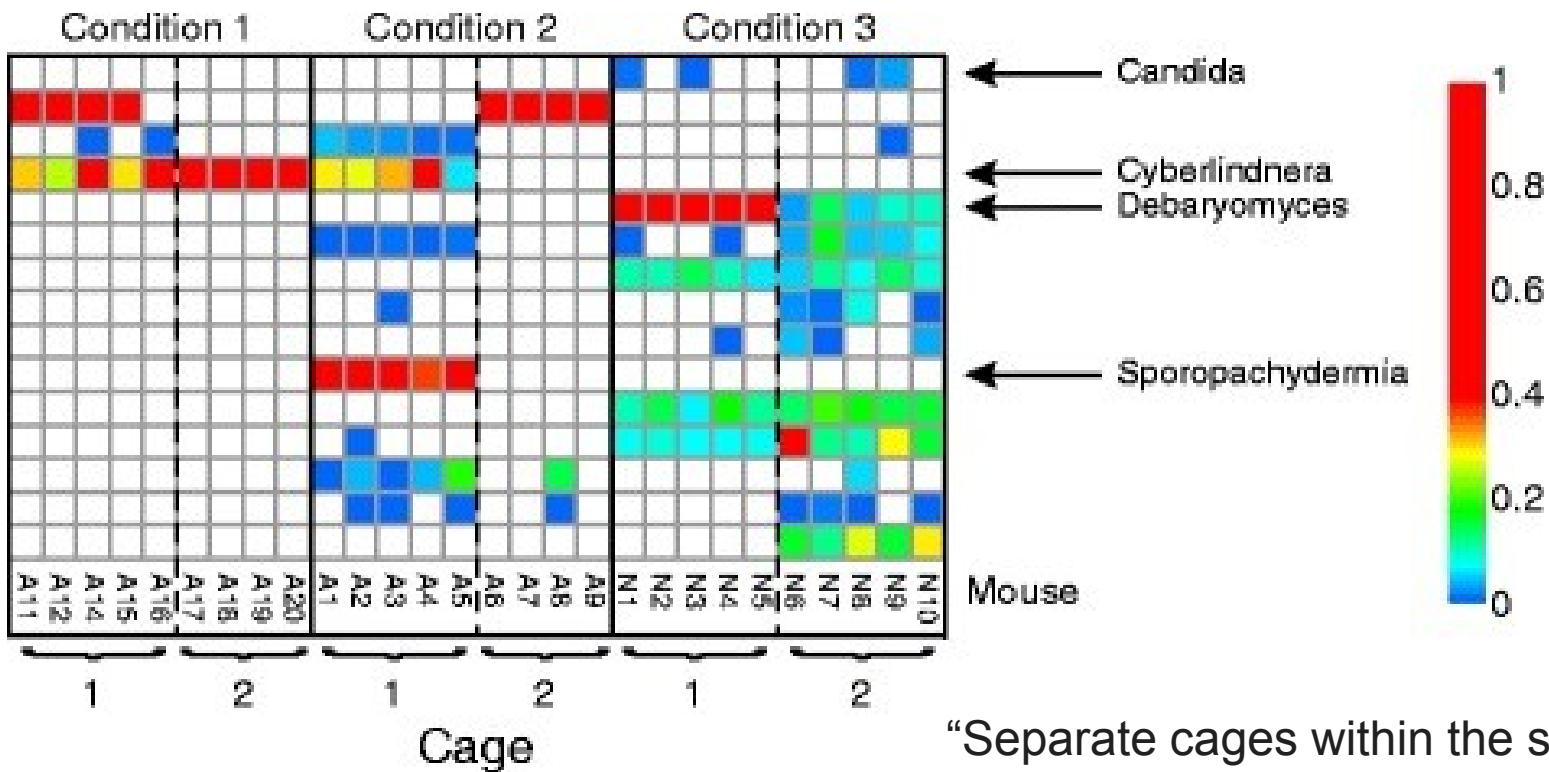
**c, Reagent contaminants are especially abundant in samples with low biomass** that failed 16S amplification, and in negative controls; both of which cluster together in the lower left corner. This dataset is from a study where bacterial DNA was enriched from nasal swabs and sequenced with an ILLUMINA HiSeq v4 sequencing kit.

...

**d, Genuine signals are reproducible** and separate measurements from the same sample using different DNA isolation kits should correlate with one another while reagent contamination signals do not. The genuine *Moraxella* signal is from a reanalysis of the 16S data of Salter et al.<sup>1</sup>, whereas the reagent contamination example, *Thiohalocapsa halophila*, is from an analysis of placental tissues.



**Fig. 3** Wrestling with kit contamination—similar bacterial composition in placental samples and negative controls.



**Fig. 1** Example of cage effects dominating a mouse study of fungal communities.

...

The three conditions studied were continuous exposure to antibiotics (*Condition 1*), short-term exposure to antibiotics (*Condition 2*), and no exposure to antibiotics (*Condition 3*).

“Separate cages within the same treatment group showed radical differences, but mice within a cage generally behaved similarly”

# Efekt dávky - platforma

# Lidé a myši na mikročipech

V článku z roku 2004, mikročipová analýza genové exprese několika různých tkání u lidí a myší vedla autory k závěru, že „**jakákoli lidská tkáň je více podobná jakékoli jiné vyšetřované lidské tkáni než její odpovídající tkáni myší**“.

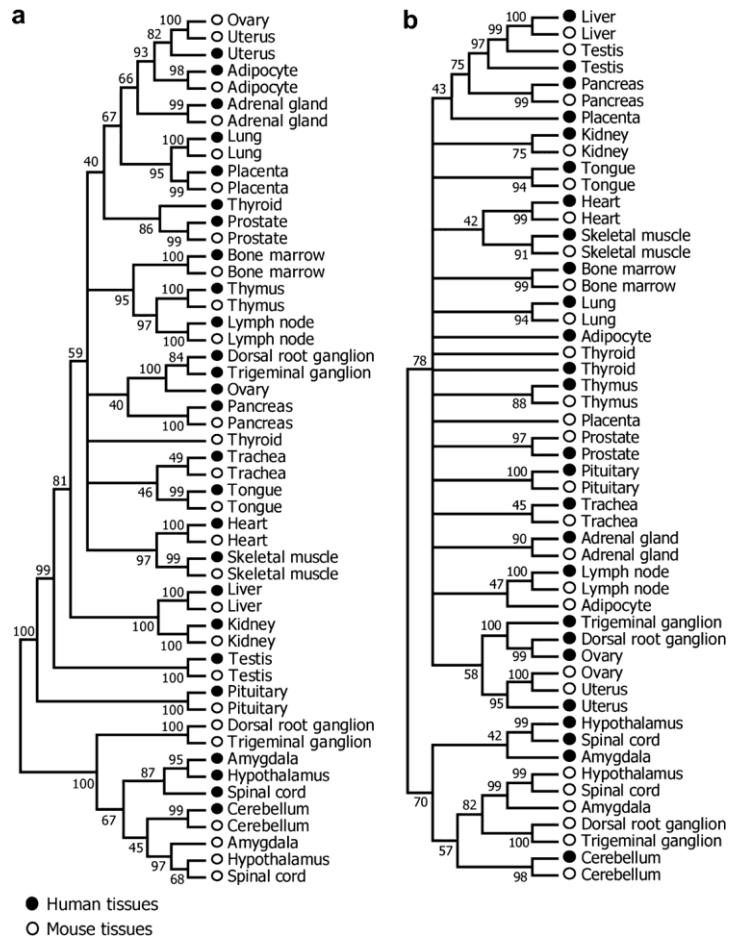
Yanai I, Graur D, Ophir R. Incongruent expression profiles between human and mouse orthologous genes suggest widespread neutral evolution of transcription control.  
OMICS. 2004 Spring;8(1):15-24.

# Lidé a myši na mikročipech

Následují články (2006, 2007, 2010), které dokazují, že tyto rozdíly jsou založeny pouze na faktu, že se jednalo o dva různé mikročipy...:

1. Sondy na mikročipech jsou navrženy odděleně pro lidské a myší ortologické geny a necílí na stejné sekvence. Proto mají lidské sondy a myší sondy různé affinity k jejich cílovým RNA
2. Signál ( $S$ ) detekovaný mikročipem je přibližně lineární se skutečným množstvím cílové RNA v rozumných rozsazích měření (Affymetrix 2001), hodnoty  $S$  transformované  $\log_2$  mají tendenci přečeňovat rozdíl mezi dvěma nízkými hodnotami exprese, ale podceňují rozdíl mezi dvěma vysokými hodnotami exprese.

# Lidé a myši na mikročipech



**FIG. 5.—**

Dendograms of 26 human and 26 mouse tissues based on (a) 1 – Pearson's correlation coefficient  $r$  and (b) Euclidean distance  $d$  of tissues..

Ben-Yang Liao, Jianzhi Zhang (2006) Evolutionary Conservation of Expression Profiles Between Human and Mouse Orthologous Genes . Molecular Biology and Evolution, Volume 23, Issue 3, March 2006, Pages 530-540

# Lidé a myši na RNAseq

Navzdory tomu se problém v roce 2014 opakuje!!



## Comparison of the transcriptional landscapes between human and mouse tissues

Shin Lin<sup>a,b,1</sup>, Yiing Lin<sup>c,1</sup>, Joseph R. Nery<sup>d</sup>, Mark A. Urich<sup>d</sup>, Alessandra Breschi<sup>e,f</sup>, Carrie A. Davis<sup>g</sup>, Alexander Dobin<sup>g</sup>, Christopher Zaleski<sup>g</sup>, Michael A. Beer<sup>h</sup>, William C. Chapman<sup>c</sup>, Thomas R. Gingeras<sup>g,i</sup>, Joseph R. Ecker<sup>d,j,2</sup>, and Michael P. Snyder<sup>a,2</sup>

<sup>a</sup>Department of Genetics, Stanford University, Stanford, CA 94305; <sup>b</sup>Division of Cardiovascular Medicine, Stanford University, Stanford, CA 94305;

<sup>c</sup>Department of Surgery, Washington University School of Medicine, St. Louis, MO 63110; <sup>d</sup>Genomic Analysis Laboratory, The Salk Institute for Biological Studies, La Jolla, CA 92037; <sup>e</sup>Centre for Genomic Regulation and UPF, Catalonia, 08003 Barcelona, Spain; <sup>f</sup>Departament de Ciències Experimentals i de la Salut, Universitat Pompeu Fabra, 08003 Barcelona, Spain; <sup>g</sup>Functional Genomics, Cold Spring Harbor Laboratory, Cold Spring Harbor, NY 11742; <sup>h</sup>McKusick-Nathans Institute of Genetic Medicine and the Department of Biomedical Engineering, Johns Hopkins University, Baltimore, MD 21205; <sup>i</sup>Affymetrix, Inc., Santa Clara, CA 95051; and <sup>j</sup>Howard Hughes Medical Institute, The Salk Institute for Biological Studies, La Jolla, CA 92037

Contributed by Joseph R. Ecker, July 23, 2014 (sent for review May 23, 2014)

# Lidé a myši na RNAseq

„V této studii velkého počtu tkání mezi lidmi a myšmi odhalila vysoce výkonná transkriptomická a epigenomická sekvenace, že obecně dominují rozdíly mezi těmito dvěma druhy.“

Tentokrát byla RNAseq použita pro oba druhy, a proto to vypadalo, že není žádný problém s rozdílnou platformou....

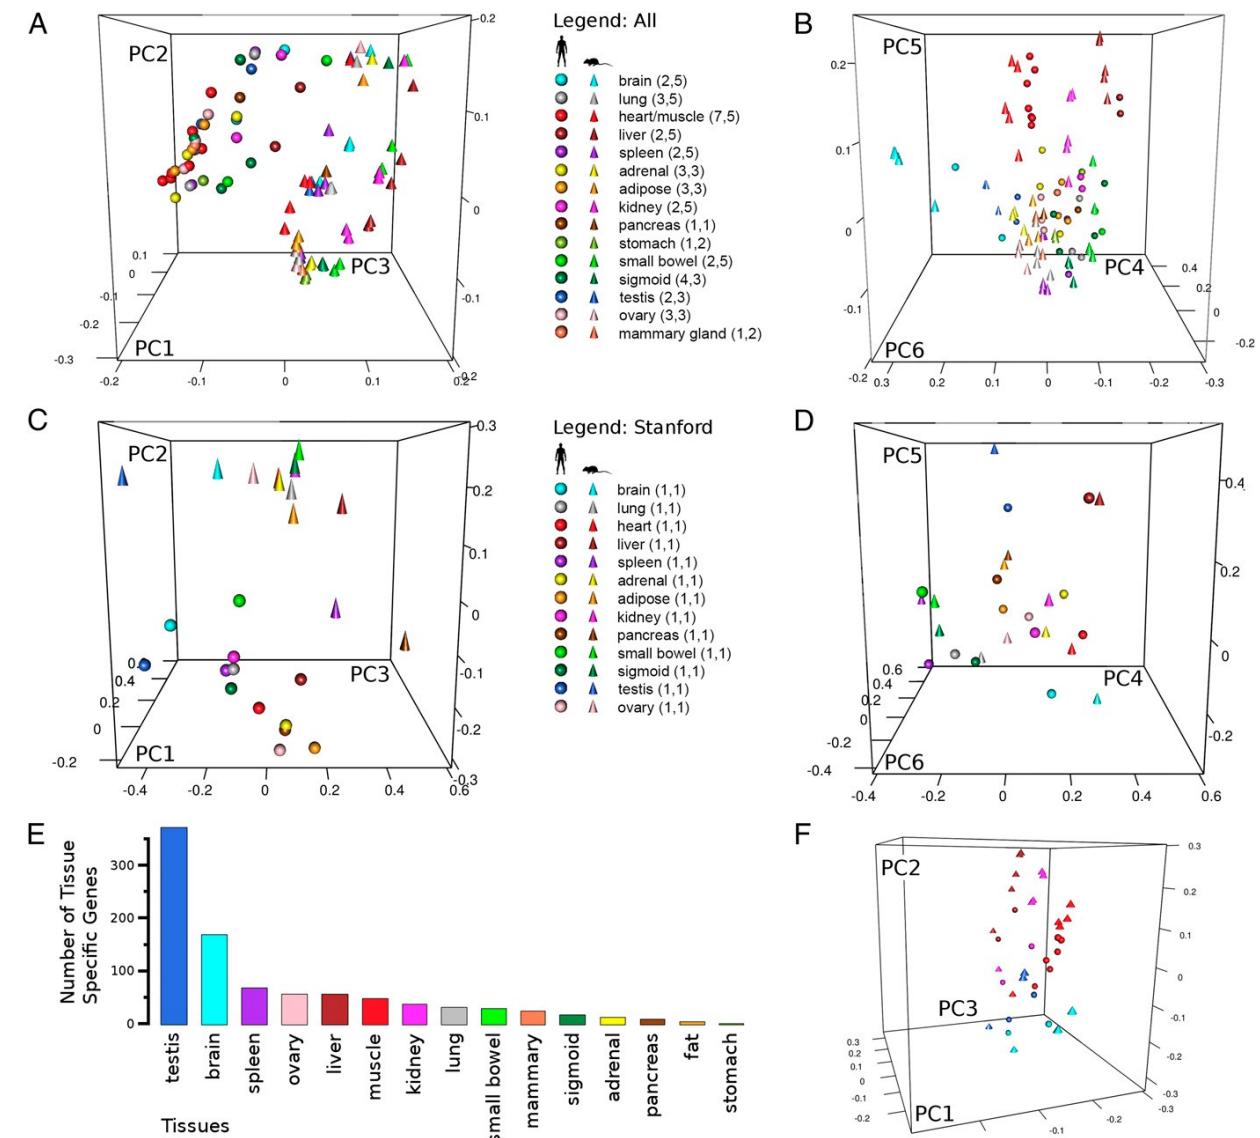


Fig. 1. Loading plots from PCA on human and mouse gene expression data.

# Lidé a myši na RNAseq

- Následná reanalýza z roku 2015 ukázala, že rozdíly jsou pravděpodobně způsobeny efektem dávky flow cell a ranu!

## RESEARCH ARTICLE

## A reanalysis of mouse ENCODE comparative gene expression data [version 1; peer review: 3 approved, 1 approved with reservations]

Yoav Gilad, Orna Mizrahi-Man

Department of Human Genetics, University of Chicago, Chicago, IL, 60637, USA

D87PMJN1 (run 253, flow cell D2GUAACXX, lane 7)	D87PMJN1 (run 253, flow cell D2GUAACXX , lane 8)	D4LHBFN1 (run 276, flow cell C2HKJACXX , lane 4)	MONK (run 312, flow cell C2GR3ACXX , lane 6)	HWI-ST373 (run 375, flow cell C3172ACXX , lane 7)
heart	adipose	adipose	heart	brain
kidney	adrenal	adrenal	kidney	pancreas
liver	sigmoid colon	sigmoid colon	liver	brain
small bowel	lung	lung	small bowel	spleen
spleen	ovary	ovary	testis	<span style="color:red;">●</span> Human
testis		pancreas		<span style="color:blue;">●</span> Mouse

Figure 1. Study design.

Sequencing batches as inferred based on the sequence identifiers of the RNA-Seq reads

# Lidé a myši na RNAseq

... po korekci efektu dávky to vypadá tak jak má

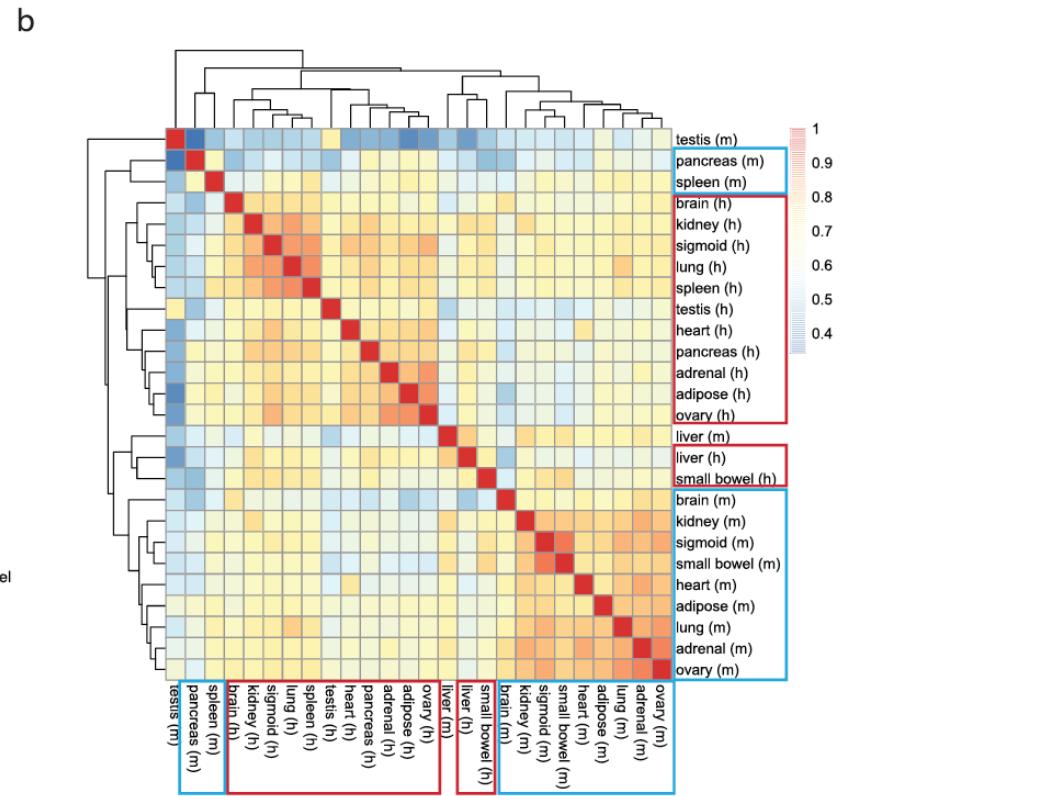


Figure 2. Recapitulating the patterns reported by the mouse ENCODE papers.

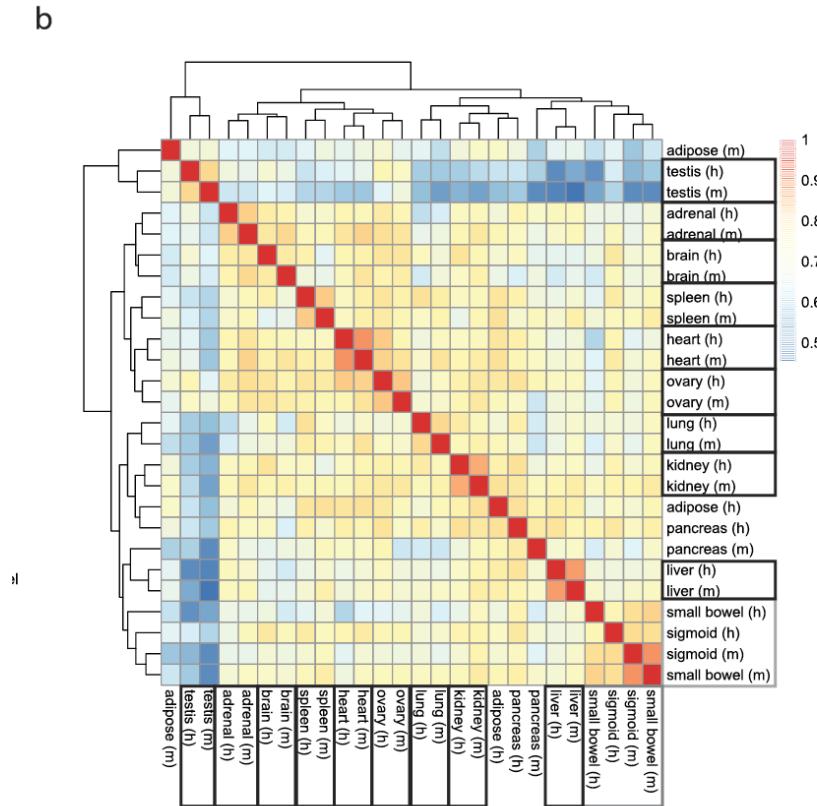


Figure 3. Clustering of data once batch effects are accounted for



# Lidé a myši na RNAseq

Ovšem pozor, v čem je problém?

Protože šlo v tomto případě o téměř perfektní batch efekt – tedy téměř 100% překryv efektu lane a ranu vs organizmus, odstraněné rozdíly batch efektu mohou být také ty biologické.

Jinak řečeno - tyto data nemohou odpovědět na otázku která byla položena.

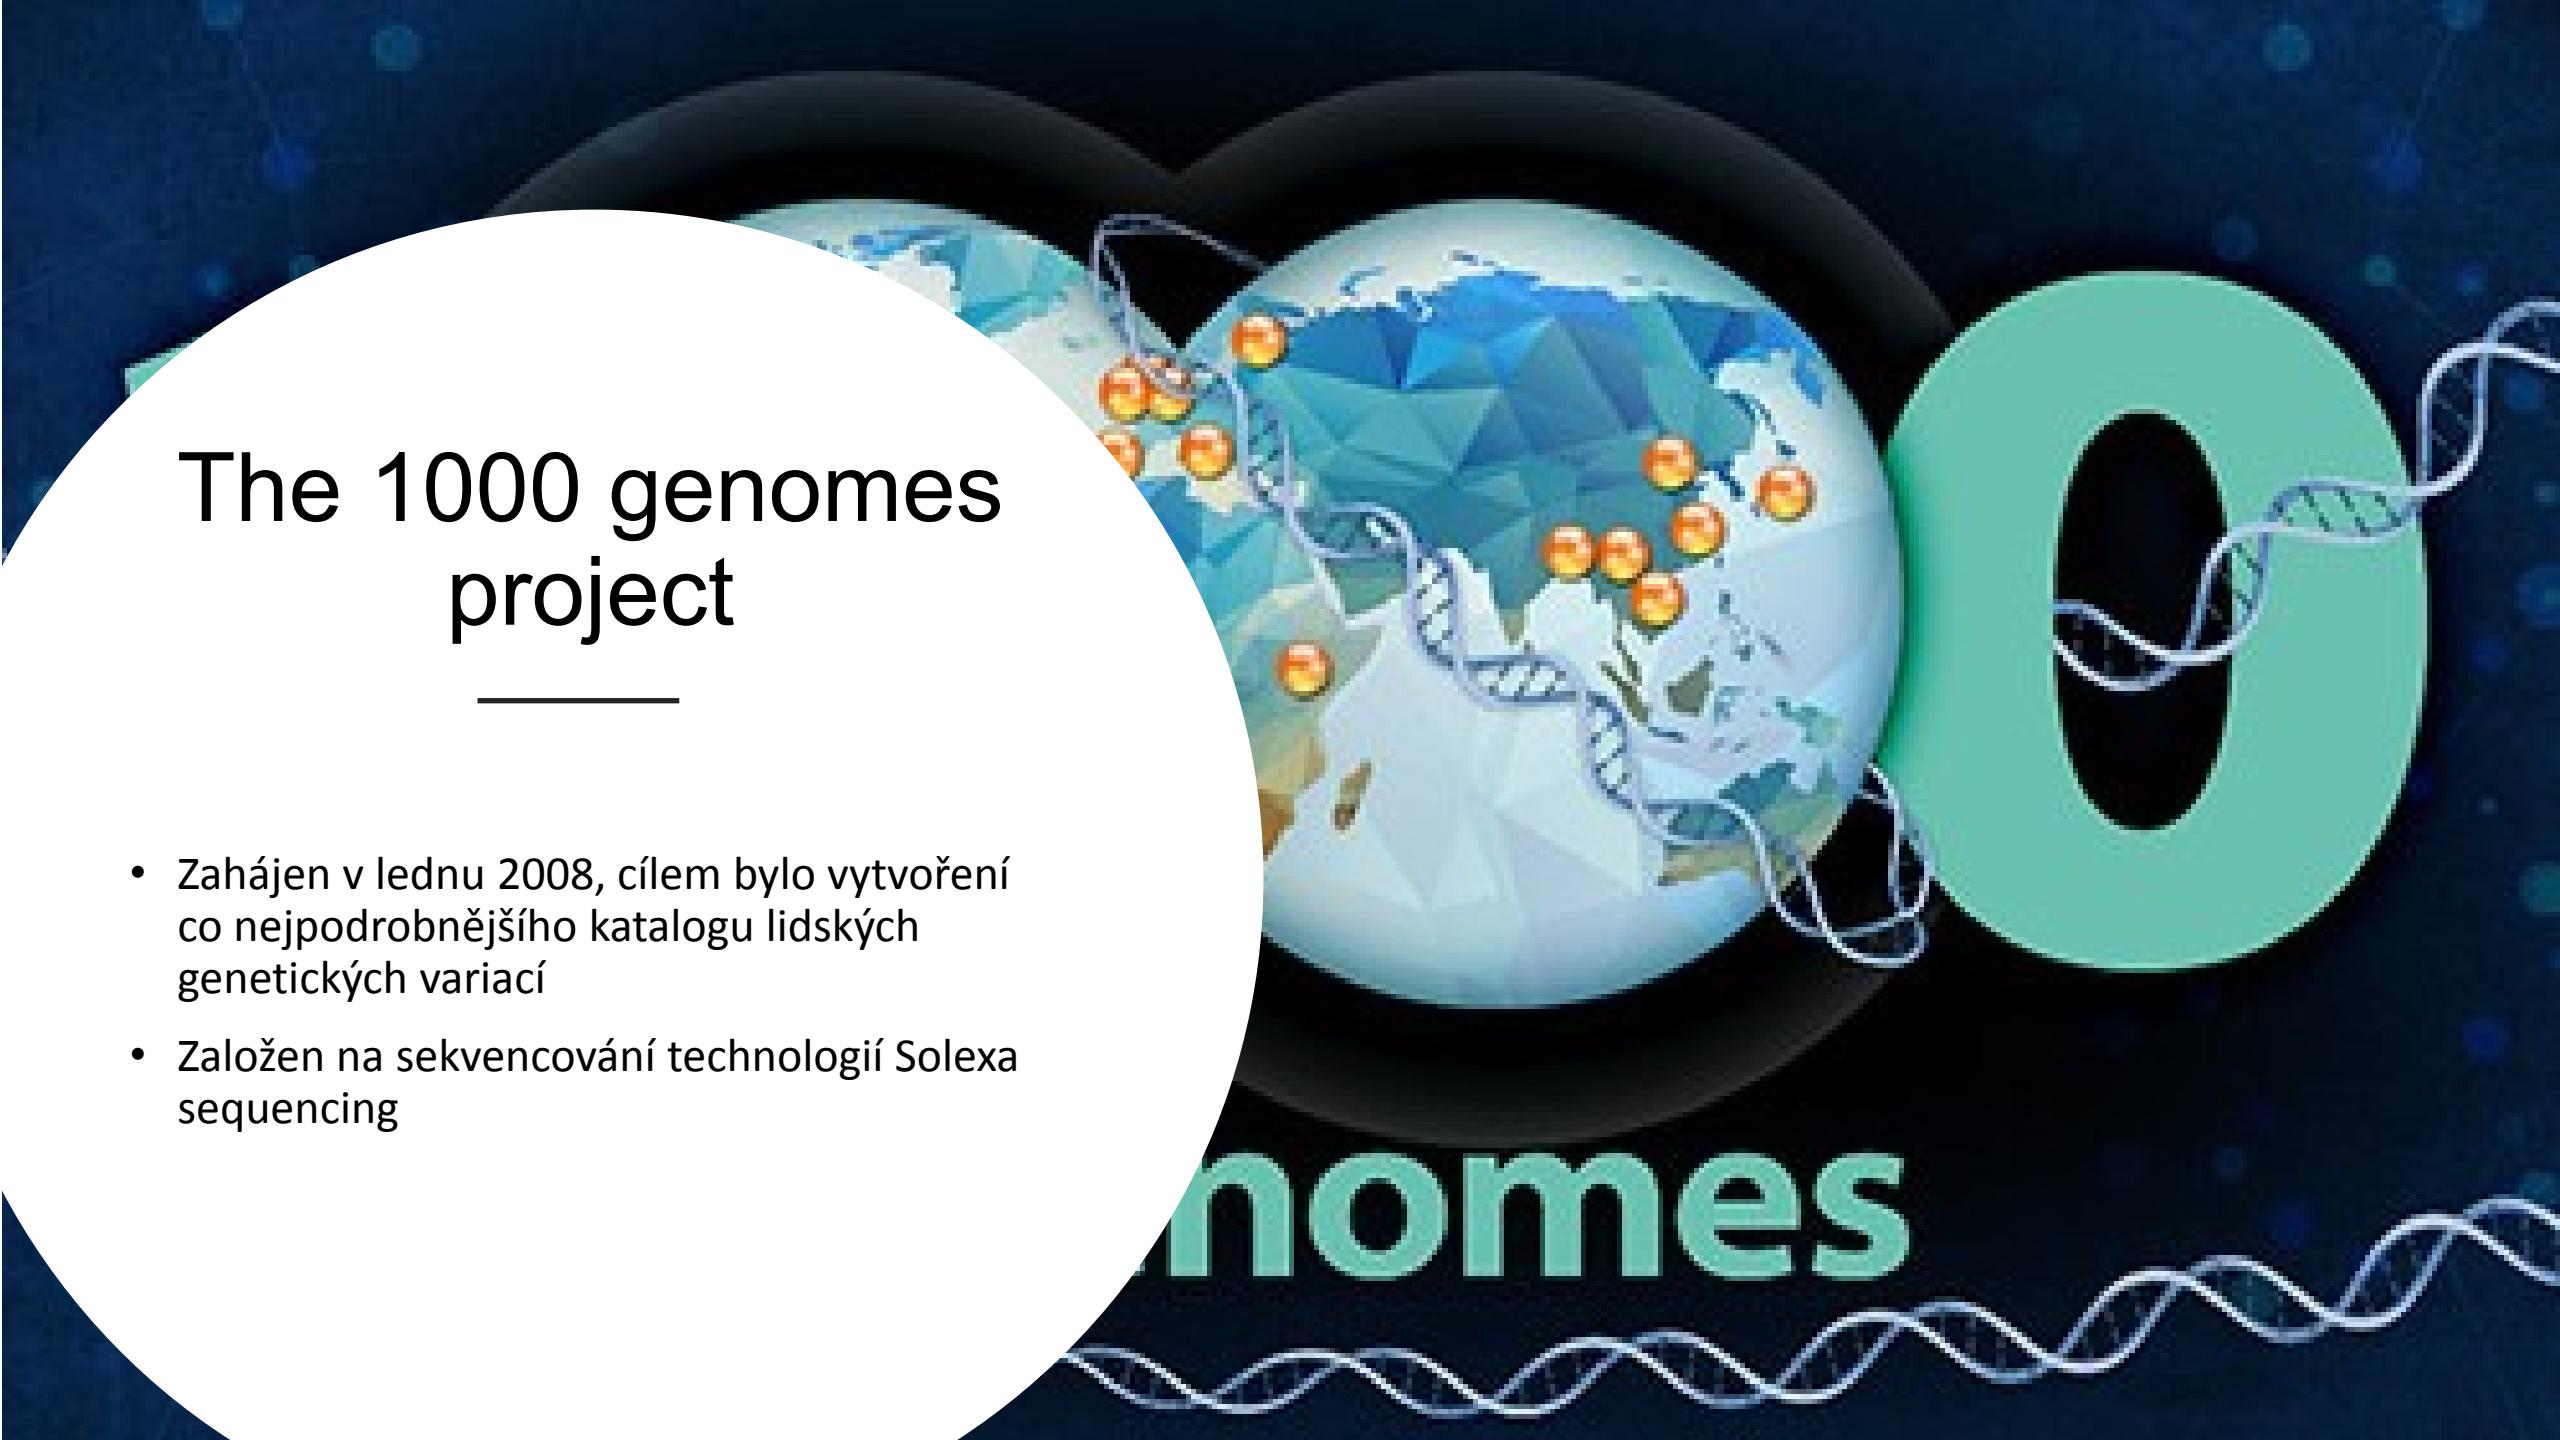
Doporučuji diskuzi pod článkem z F1000research...

# The 1000 genomes project

---

- Zahájen v lednu 2008, cílem bylo vytvoření co nejpodrobnějšího katalogu lidských genetických variací
- Založen na sekvencování technologií Solexa sequencing

omes



# Jaký je vliv data sekvencování na genetickou variabilitu mezi sekvencemi?

Opinion | Published: 14 September 2010

## Tackling the widespread and critical impact of batch effects in high-throughput data

Jeffrey T. Leek, Robert B. Scharpf, Héctor Corrada Bravo, David Simcha, Benjamin Langmead, W. Evan Johnson, Donald Geman, Keith Baggerly & Rafael A. Irizarry 

*Nature Reviews Genetics* **11**, 733–739 (2010) | Download Citation   
**5716** Accesses | **732** Citations | **182** Altmetric | Metrics »

Zjistili, že se studovanými biologickými rozdíly bylo spojeno pouze 17% variability sekvencí, zatímco neuvěřitelných 32% bylo možné vysvětlit datem, kdy byly vzorky zpracovány.

Ani jeden z těchto  
článků nebyl stažen z  
tisku....

**Preventivně:**  
Stratifikací a  
randomizací

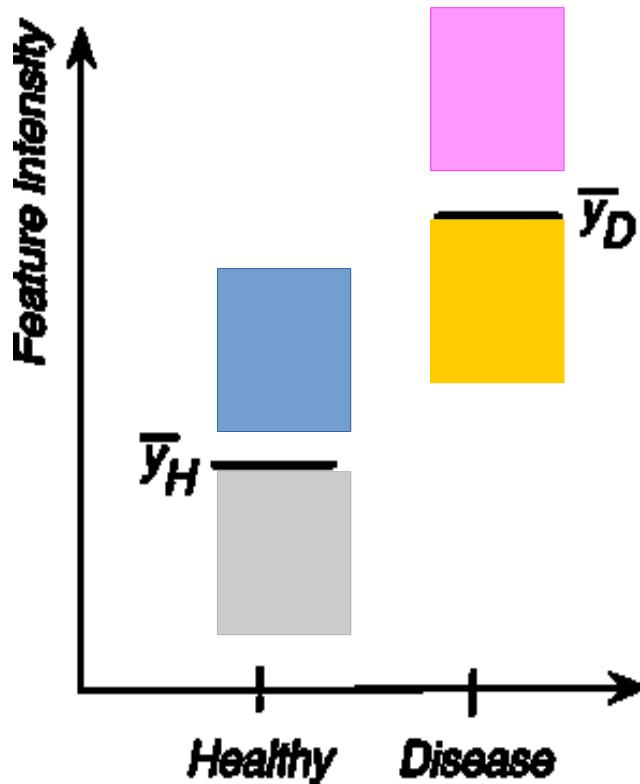
**Ad-hoc:**  
Regresními  
strategiemi

**Preventivně:**  
Stratifikací a  
randomizací

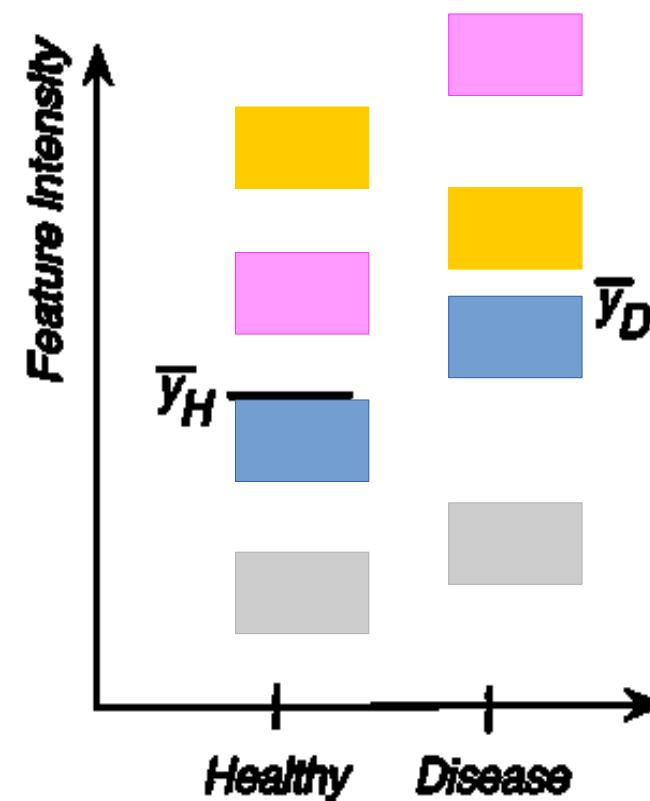
**Ad-hoc:**  
Regresními  
strategiemi

# Randomizace pomáhá minimalizovat efekt dávky

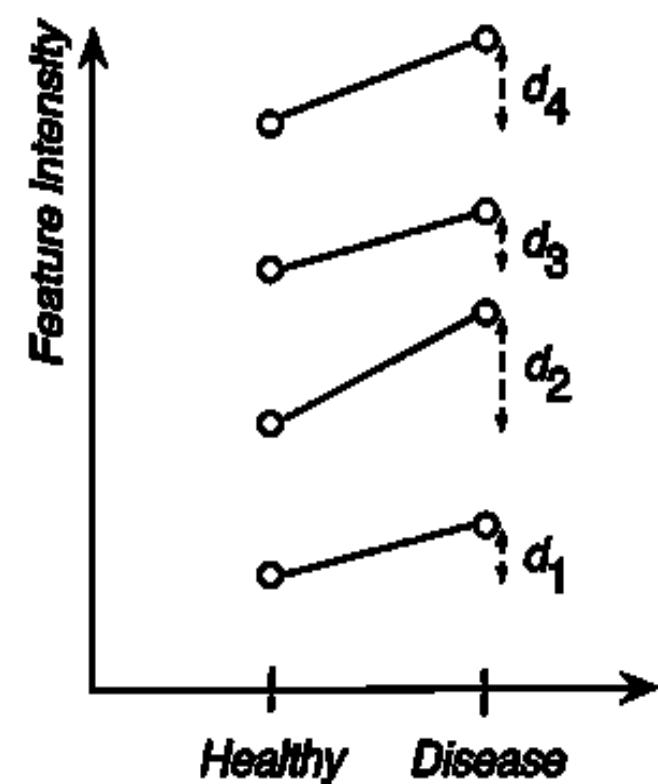
(a) Sequential acquisition



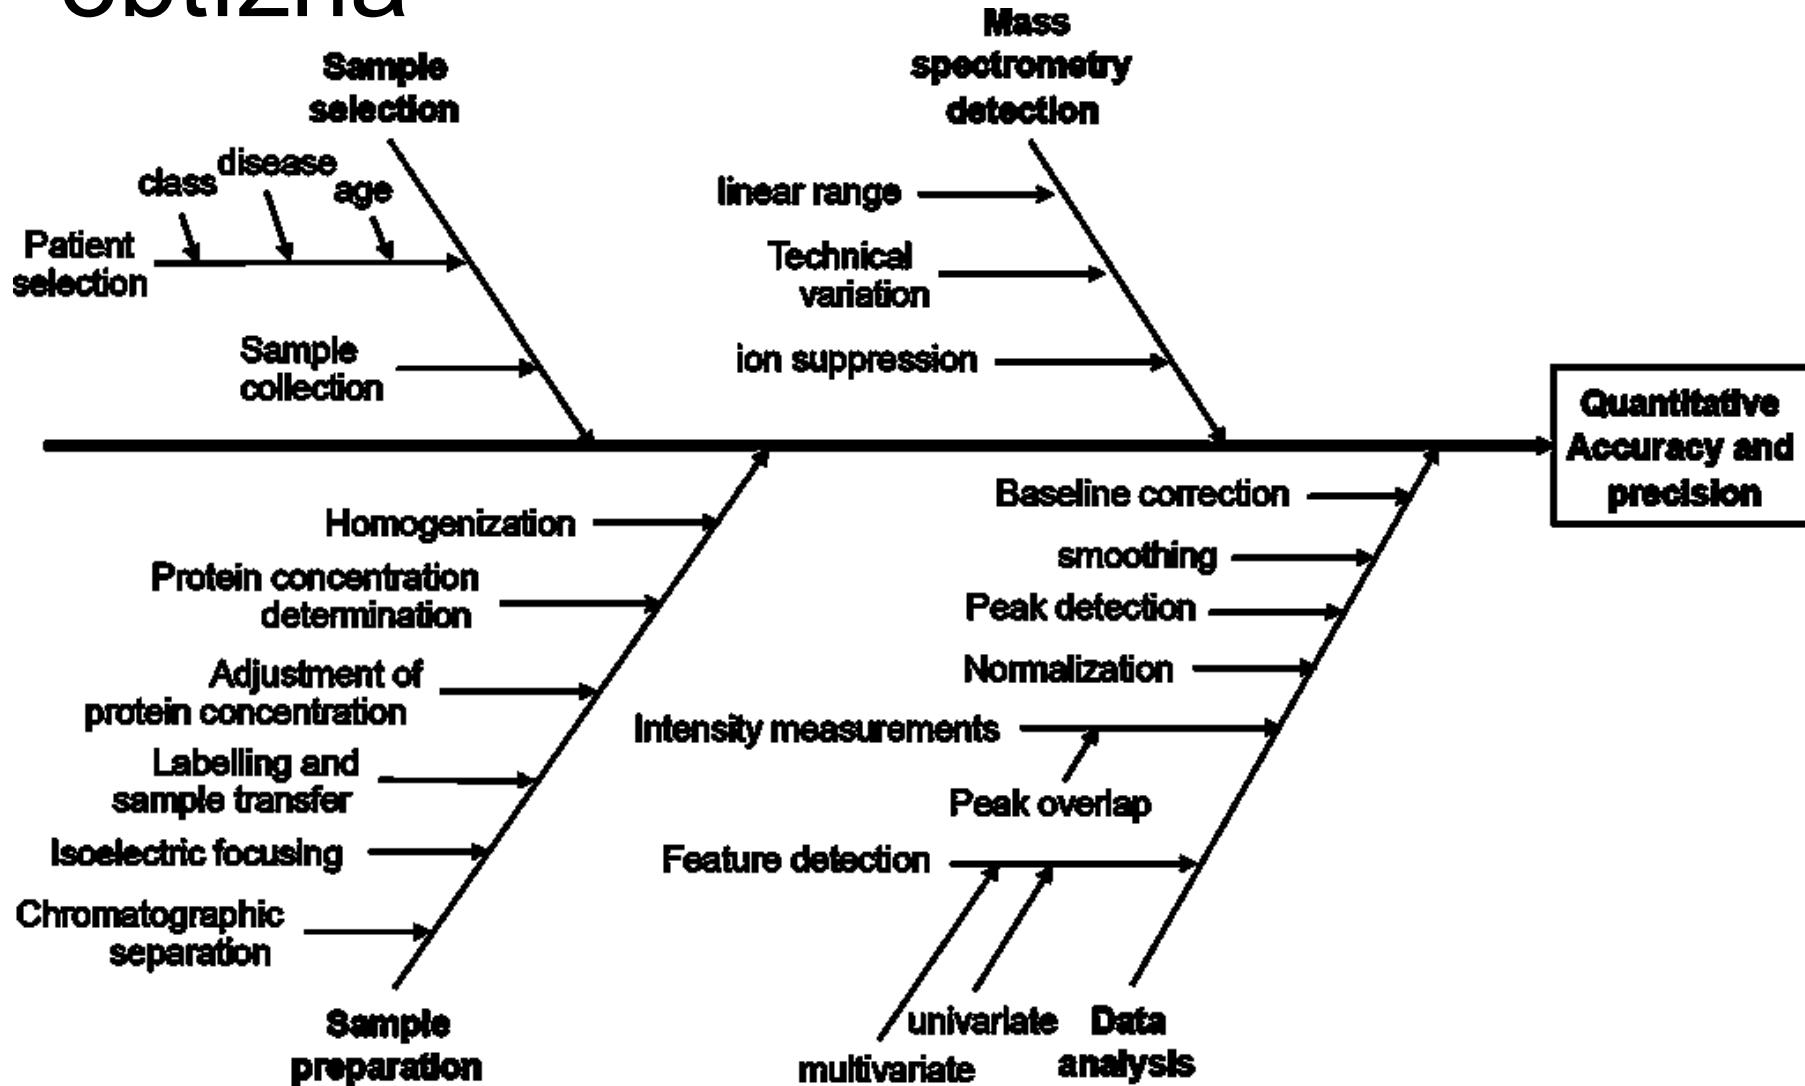
(b) Complete randomization



(c) Day = block



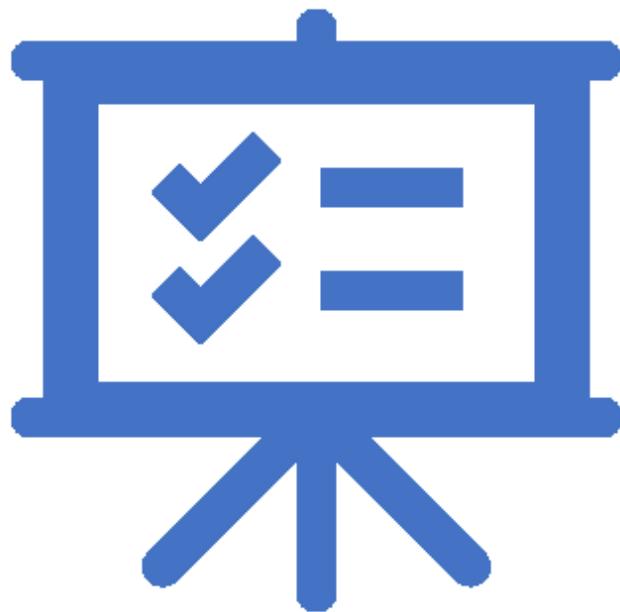
# U 'omics dat je randomizace obtížná



# Co když je randomizace nemožná (nebo ohrožena)

- Někdy všechno nejde naplánovat a něco se změní – experimenty můžou být dlouhodobé a spolupracovat může více stran, laboratoří, každá s vlastními postupy.
- Spolupráce více laboratoří – možnost randomizace na všech úrovních.
- Problematické bývá znovuoživení experimentu, který byl “uledu” kvůli nedostatku financí (mezitím se změnili postupy).
- Další změny běžně ohrožující plánovanou randomizaci.
  - výměna laboranta...
  - pokazení stroje a nutná oprava nebo výměna
  - staré kity pro izolaci DNA už nevyrábějí, nutno použít jiné
  - ...

# Preventivní minimalizace chyb



1. Protože vždy nevíme, co všechno může mít vliv, je důležité vést **PODROBNÉ ZÁZNAMY** – všechno co nás napadne!

- přesný záznam postupu, včetně uskladnění vzorku a jeho pozice v lednici
- kdo prováděl který typ analýzy a KDY
- každá změna v protokolu
- zaznamenáme všechny identifikační čísla jednotlivých kitů, primerů, čehokoliv
- všechny změny v kalibraci přístrojů, nebo informace o jejich čištění
- změny v teplotách
- způsob odběru vzorku (ležel materiál někde několik hodin mimo mrazák?)
- ...

2. Provádíme po konzultaci se statistikem – **randomizaci a dizajn experimentu**.

3. V případě změn znovu konzultujeme další postup.

# Co když je randomizace nemožná (nebo ohrožena)

- **KAŽDOU ZMĚNU KONZULTUJTE SE STATISTIKEM!**
- **ŘEŠENÍ (OBVYKLE) EXISTUJE !**
- Efekt dávky se dá odstranit, máme-li dostatek stejných vzorků analyzovaných před i po změně – vhodnými metodami se odhadne efekt a ten se pak z dat odstraní.
- **POZOR** – je to nákladné a není to dokonalé, takže lépe je tyto efekty minimalizovat.

Preventivně:  
Stratifikací a  
randomizací

Ad-hoc:  
Regresními  
strategiemi

# Regresní strategie

Základní myšlenka je modelovat efekt dávky jako jednu z proměnných kterých vliv sledujeme

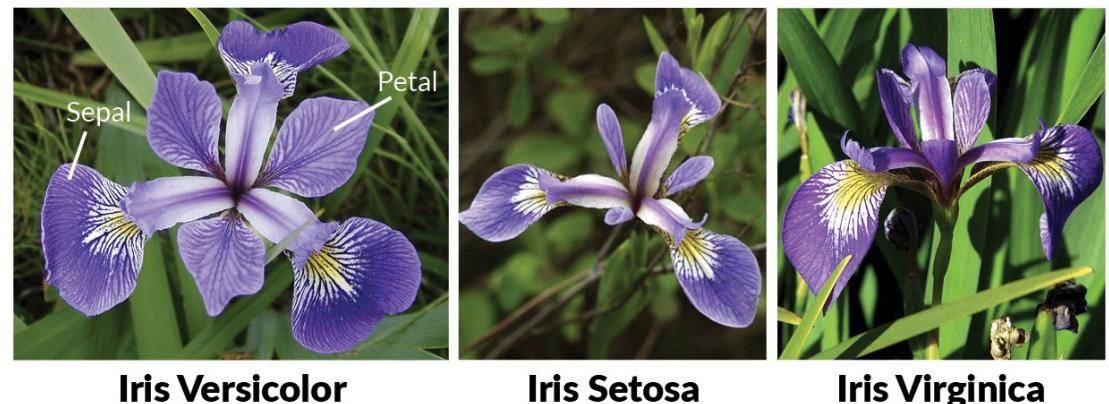
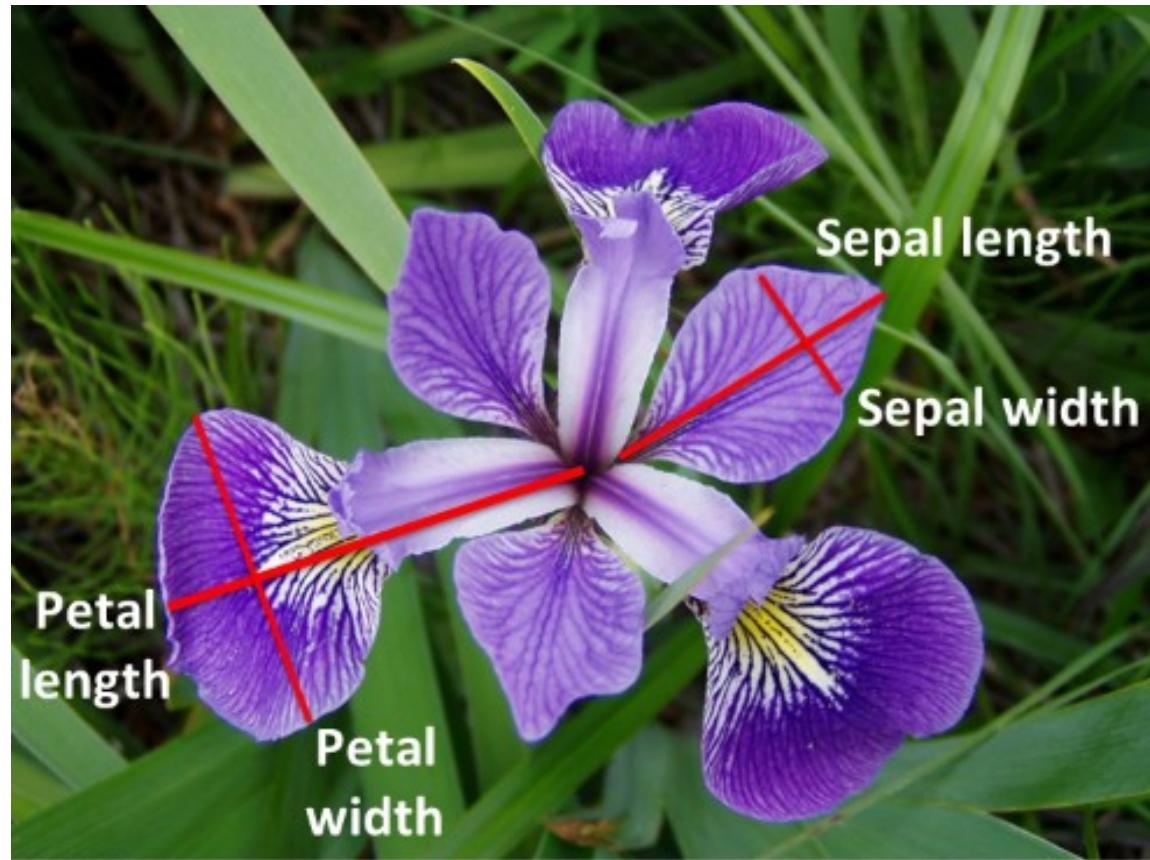
Odhadnutý efekt pak můžeme odstranit

Nejčastěji regresní strategie

ComBat (R)

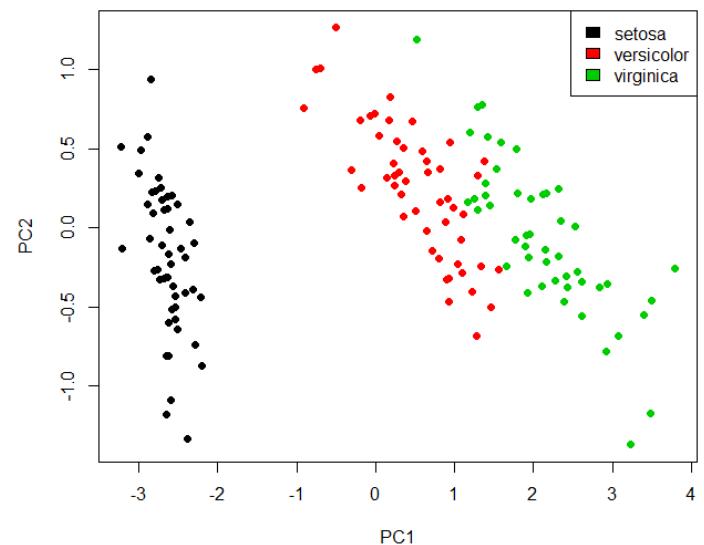
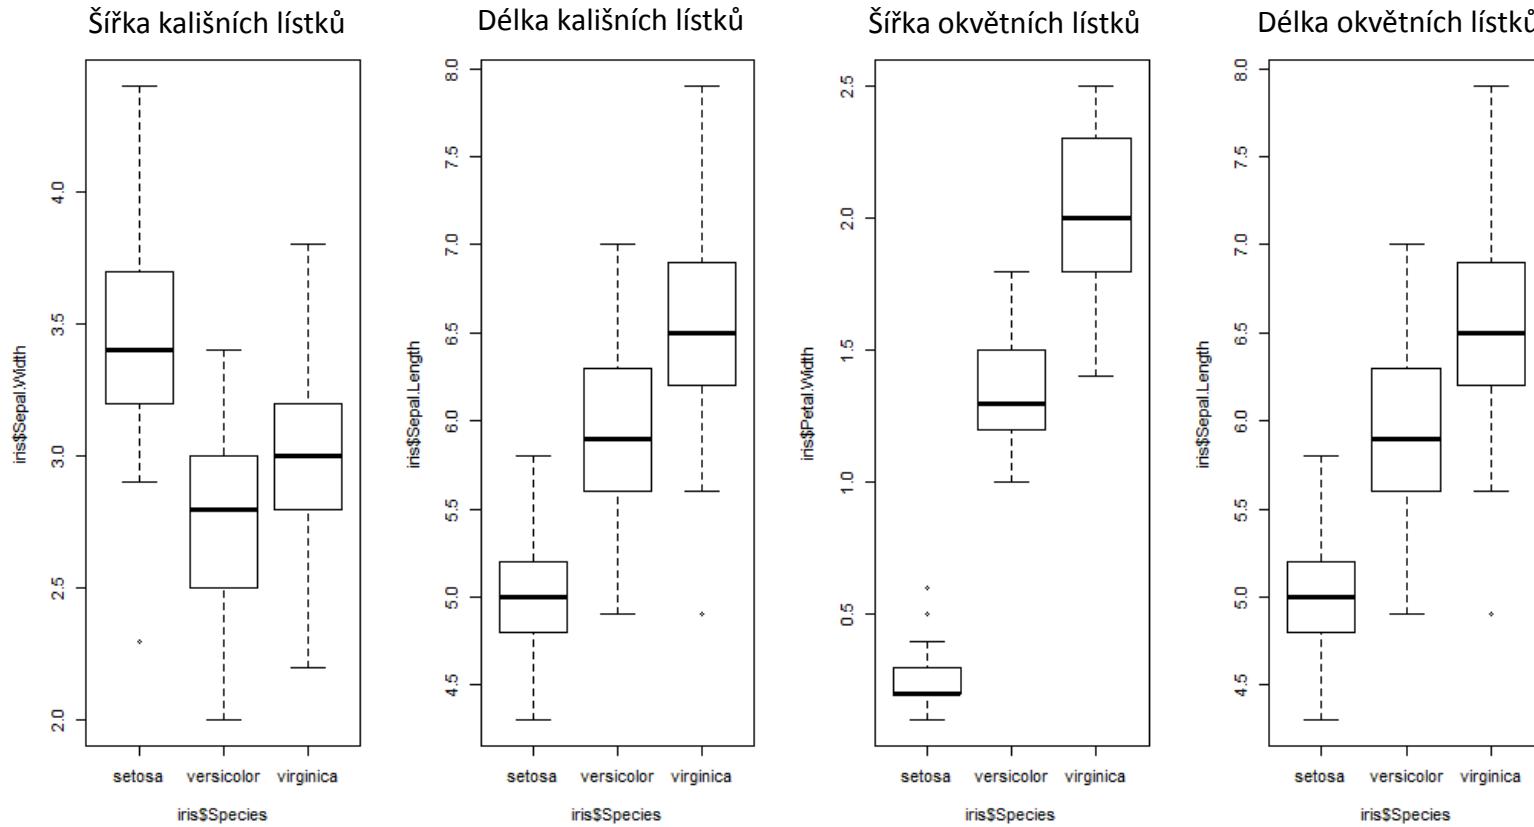
# Odstranění batch efektu – jednoduchý příklad

3 druhy kosatců se liší na základě **šířky** a **délky** kališních (sepal) a okvětních (petal) lístků



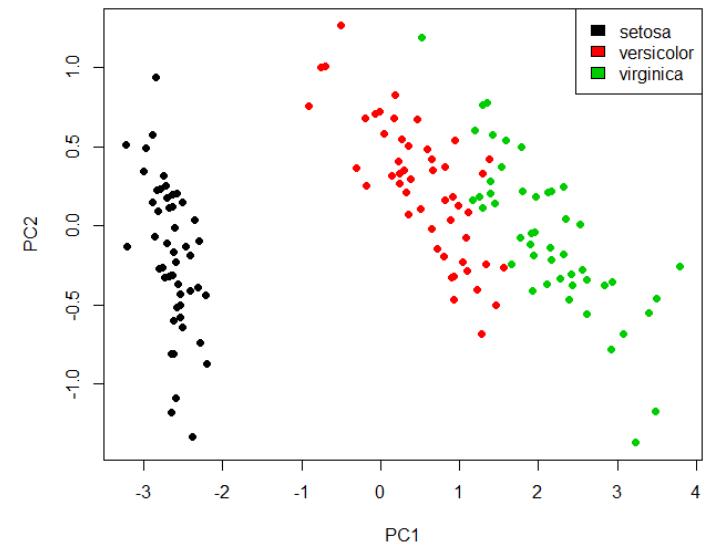
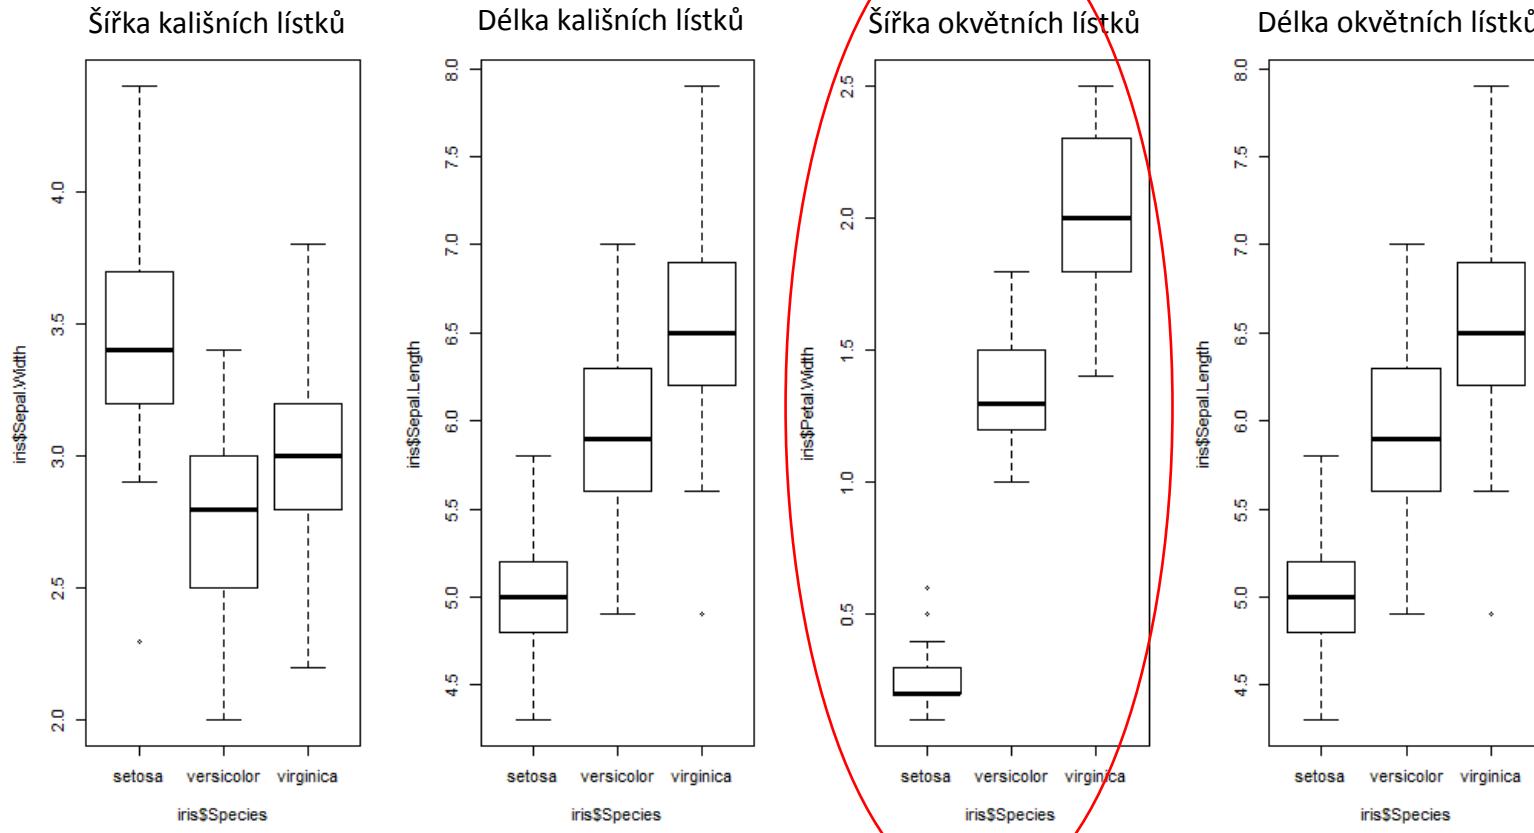
# Odstranění batch efektu – jednoduchý příklad

- 3 druhy kosatců se liší na základě šířky a délky kališních (sepal) a okvětních (petal) lístků



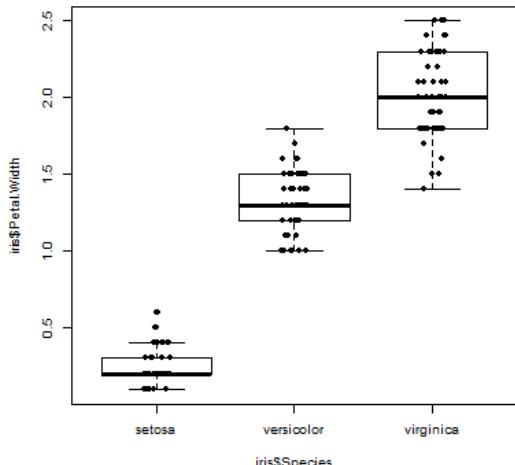
# Odstranění batch efektu – jednoduchý příklad

- 3 druhy kosatců se liší na základě šířky a délky kališních (sepal) a okvětních (petal) lístků

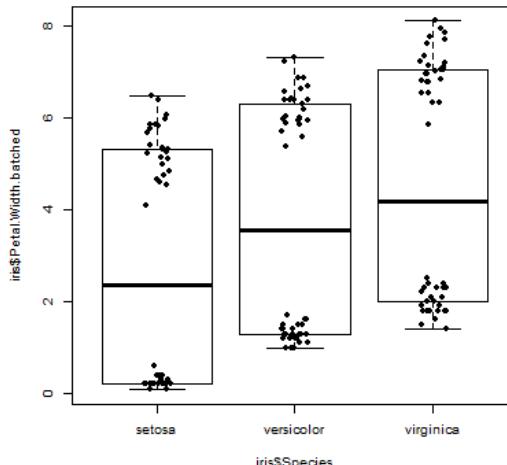
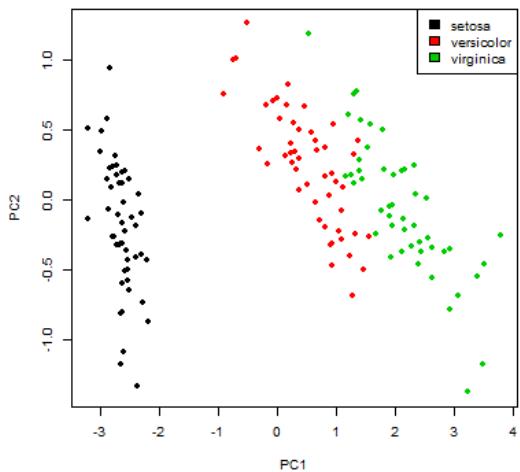


Přidejme teď uměle efekt dávky u této proměnné.

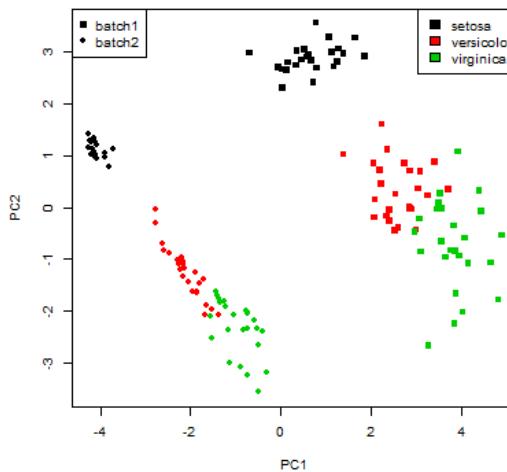
# Odstranění batch efektu – jednoduchý příklad



PCA na původním souboru

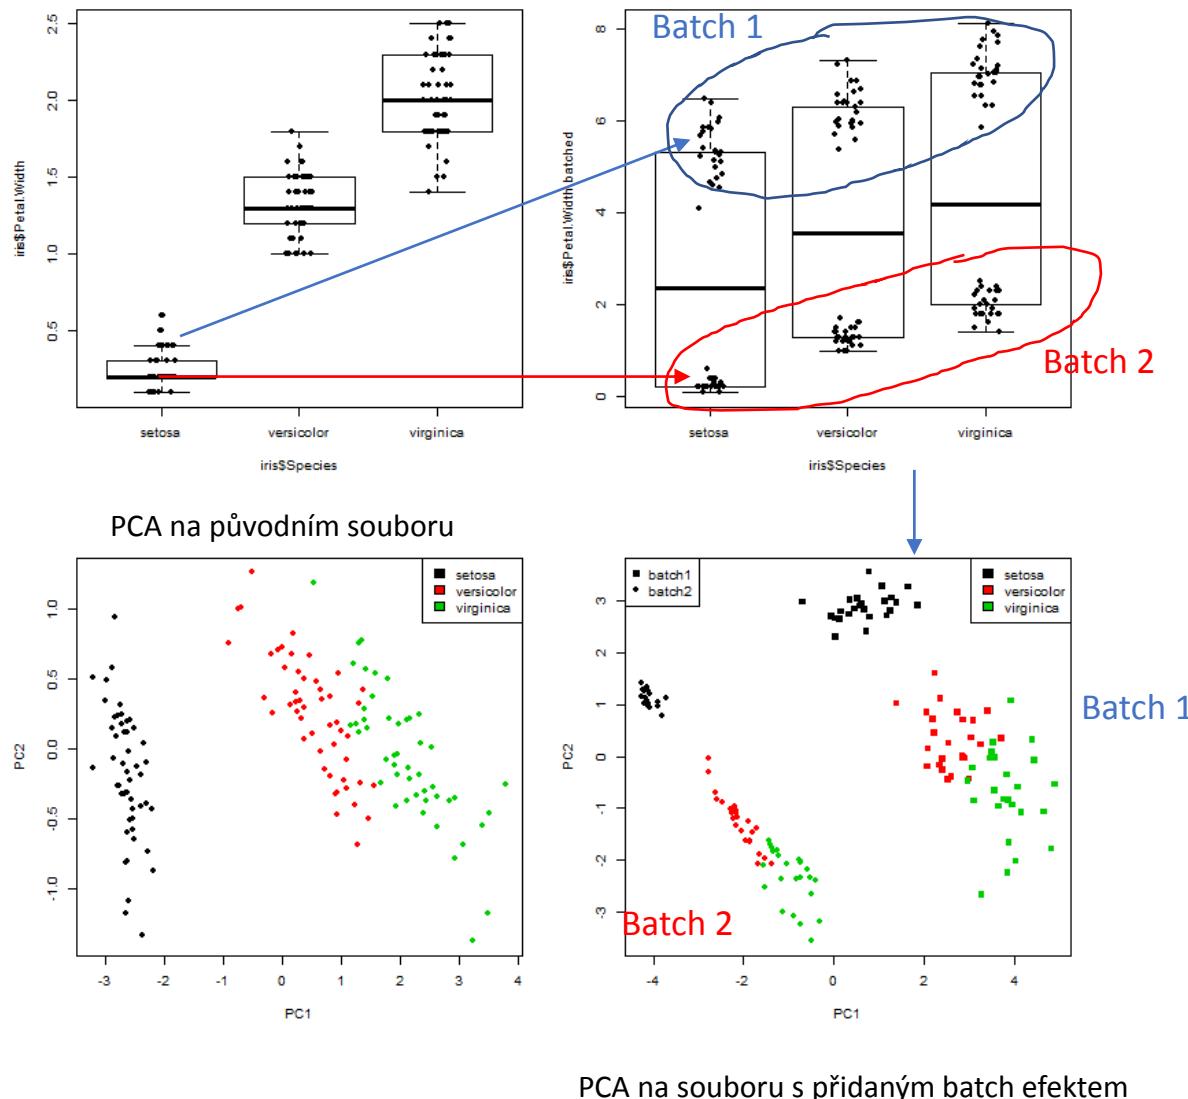


- 3 druhy kosatců se liší na základě **šířky** a **délky** kališních (sepal) a okvětních (petal) lístků
- K šířce okvětních lístků byl přidán batch efekt: k polovině hodnot u každého z druhů kosatce jsem připočítala hodnoty z normálního rozložení o **průměru 5** a standardní odchýlce **0,5**



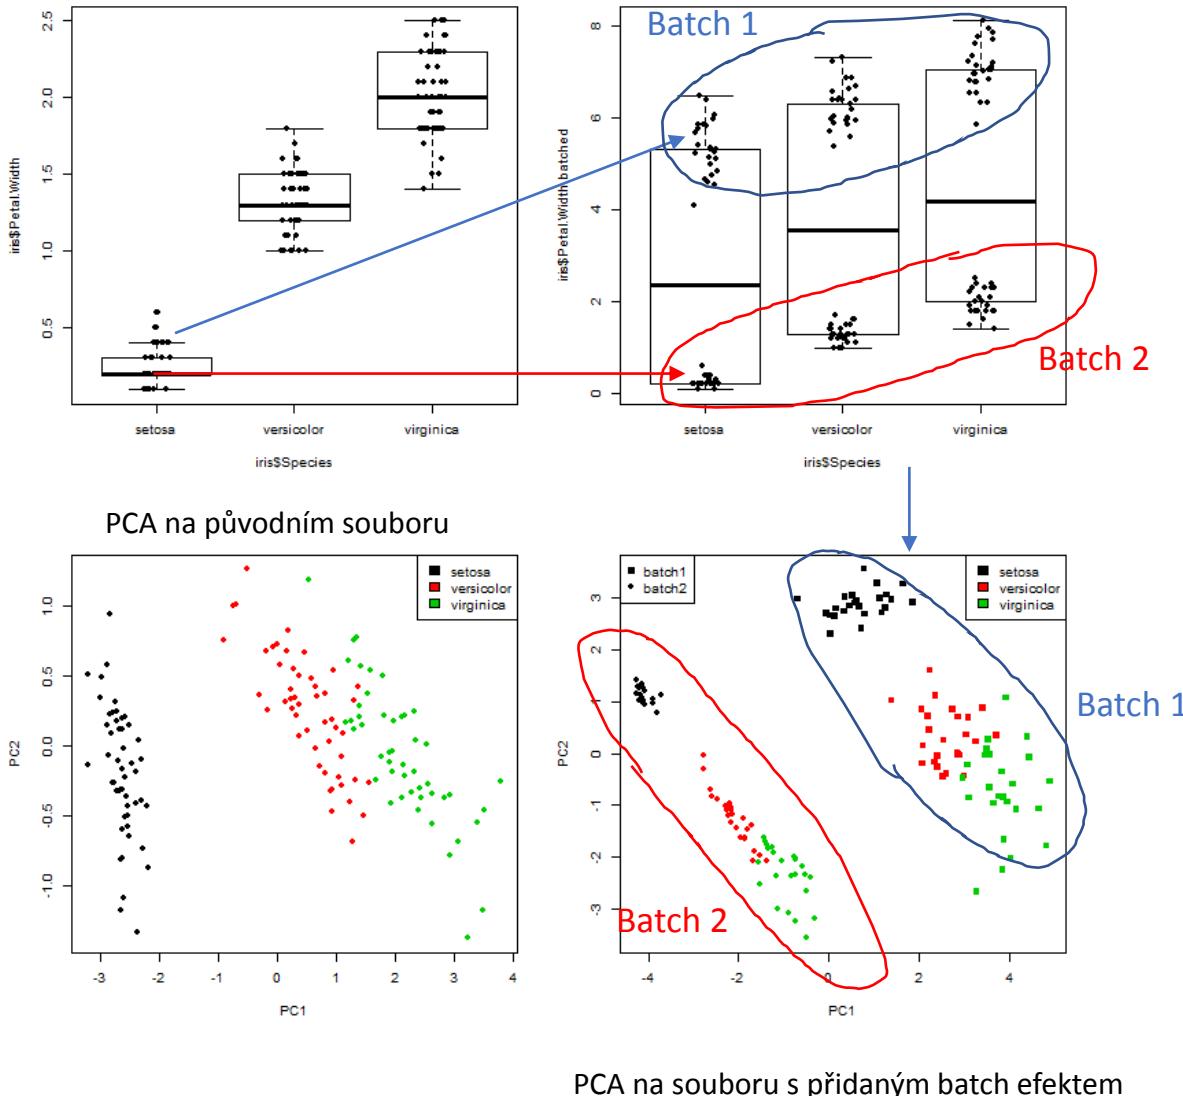
PCA na souboru s přidaným batch efektem

# Odstranění batch efektu – jednoduchý příklad



- 3 druhy kosatců se liší na základě **šířky** a **délky** kališních (sepal) a okvětních (petal) lístků
- K šířce okvětních lístků byl přidán batch efekt: k polovině hodnot u každého z druhů kosatce jsem připočítala hodnoty z normálního rozložení o **průměru 5** a standardní odchylce 0,5

# Odstranění batch efektu – jednoduchý příklad



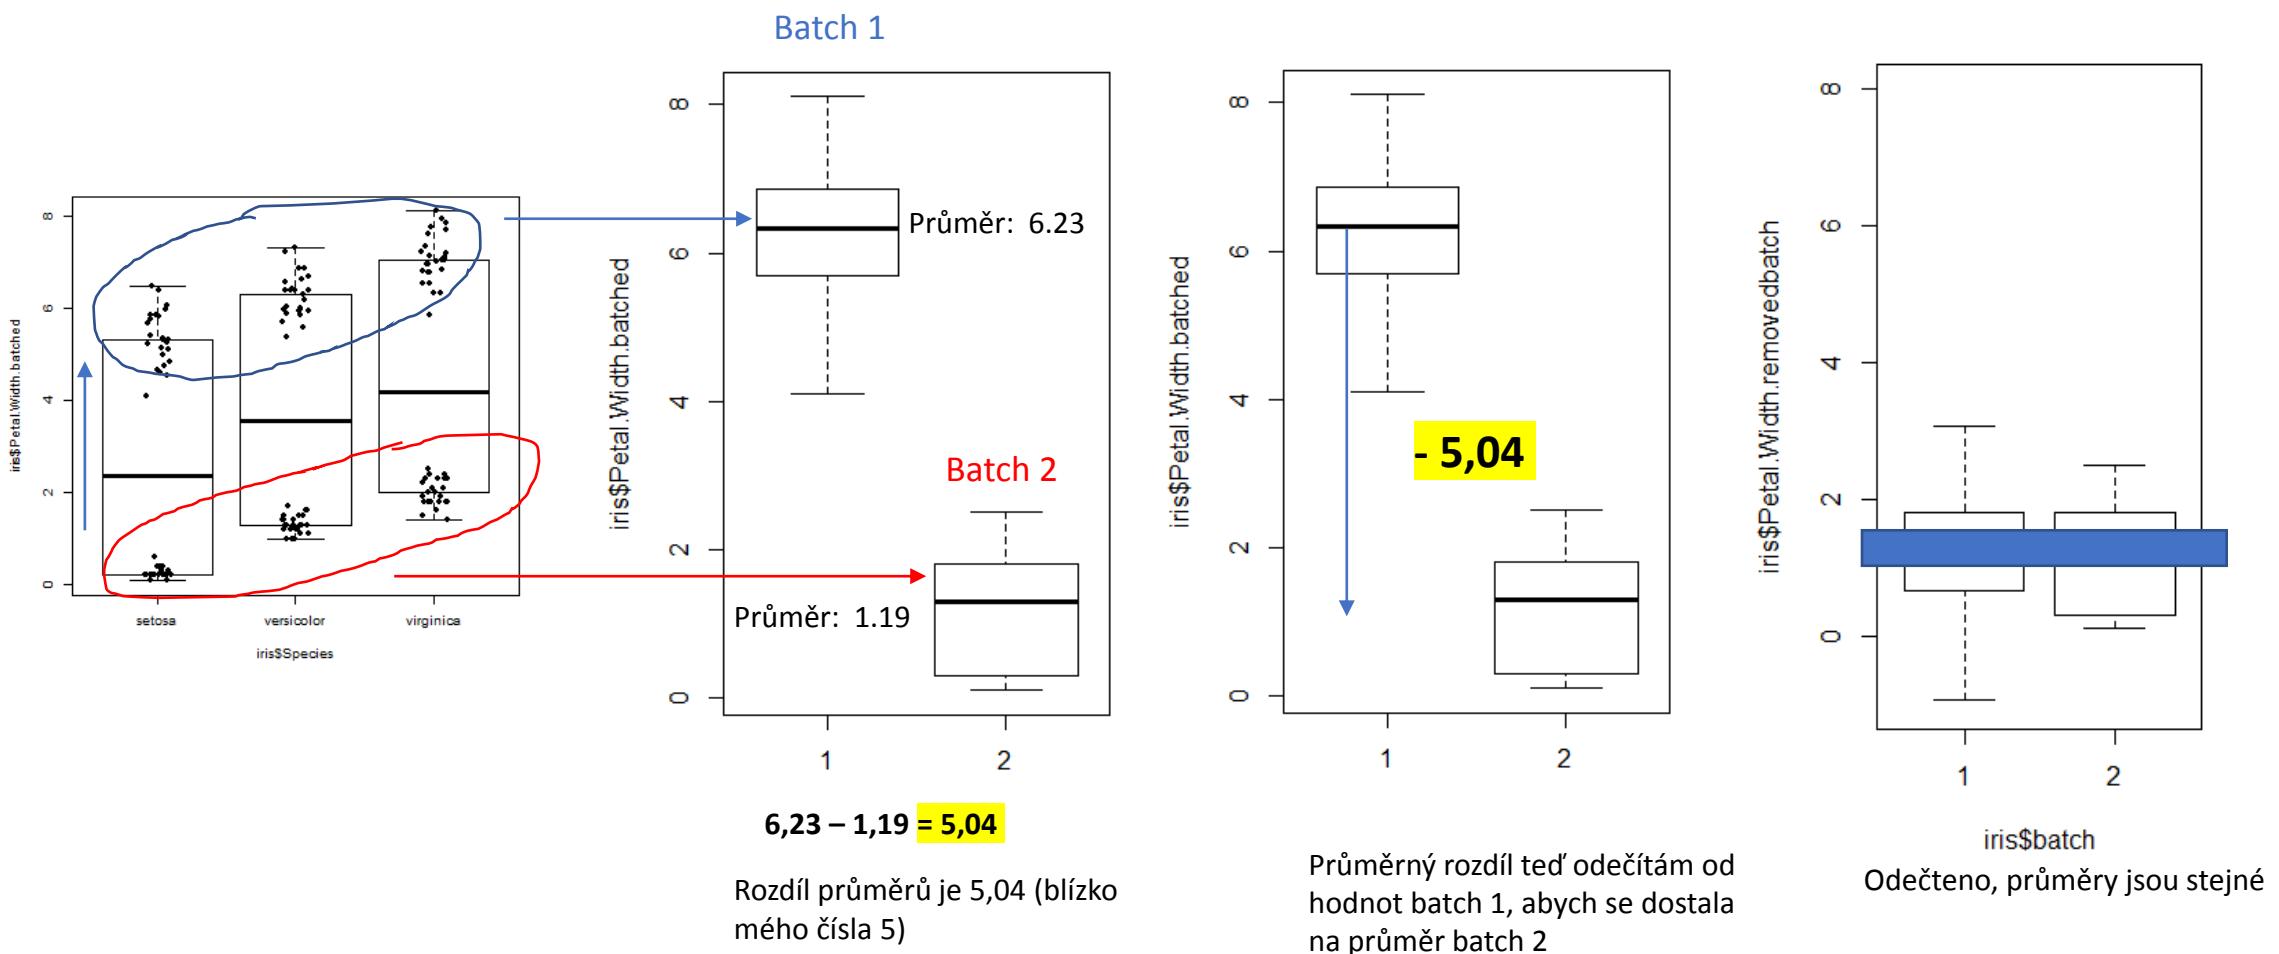
- 3 druhy kosatců se liší na základě **šířky** a **délky** kališních (sepal) a okvětních (petal) lístků
- K šířce okvětních lístků byl přidán batch efekt: k polovině hodnot u každého z druhů kosatce jsem připočítala hodnoty z normálního rozložení o **průměru 5** a standardní odchýlce 0,5

# Odstranění batch efektu – jednoduchý příklad

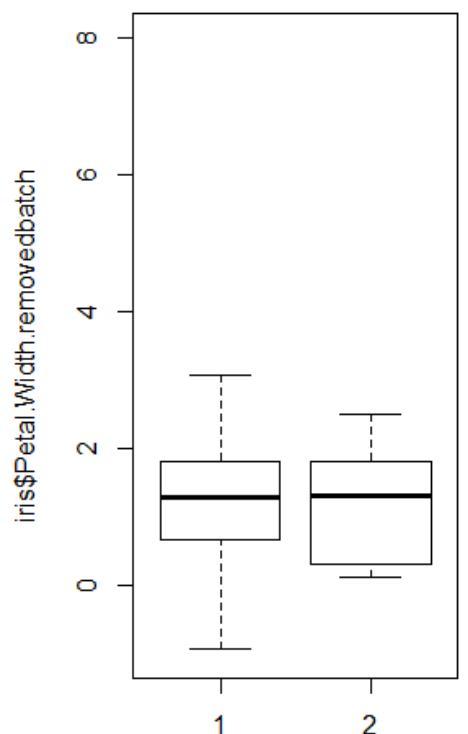
- Jak odstranit batch efekt?
1. Nejdříve efekt odhadneme - je to posun v průměrné nebo mediánové hodnotě? Nebo je rozdíl i ve variabilitě?
    - Použijeme regresní modelování, testování hypotéz, stanovíme fold change a změnu variability
  2. Tyto efekty pak odstraníme tak, že je odečteme (například průměr), nebo provedeme škálovou normalizaci a podobně

# Údaje získané z dat – jež mohou být využity příklad

- V našem příkladě: polovici hodnot jsem zvýšila v průměru o 5

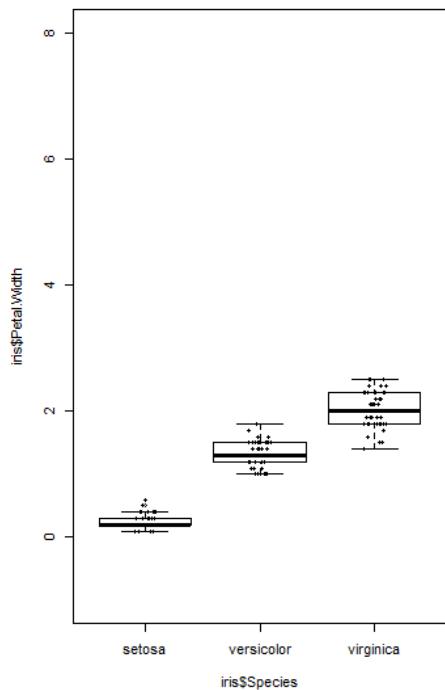


# Údaje o květech květiny – jež má vyučovací příklad

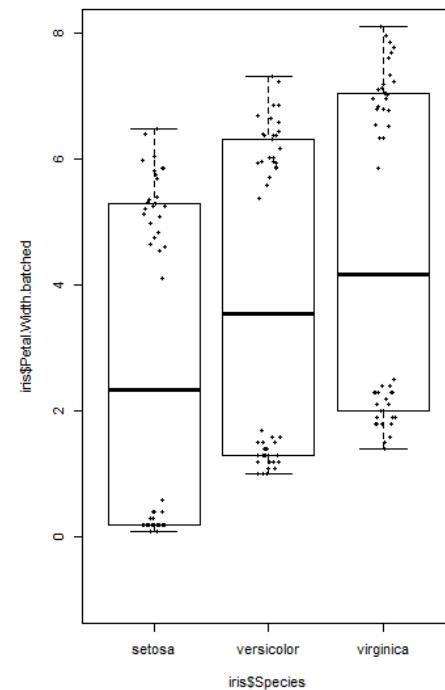


Odečteno, průměry jsou stejné

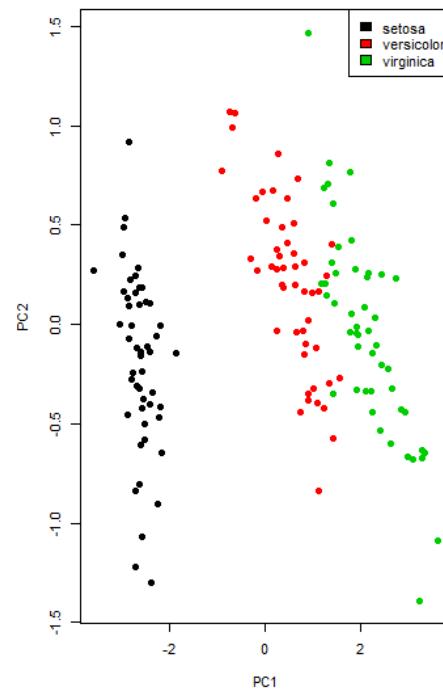
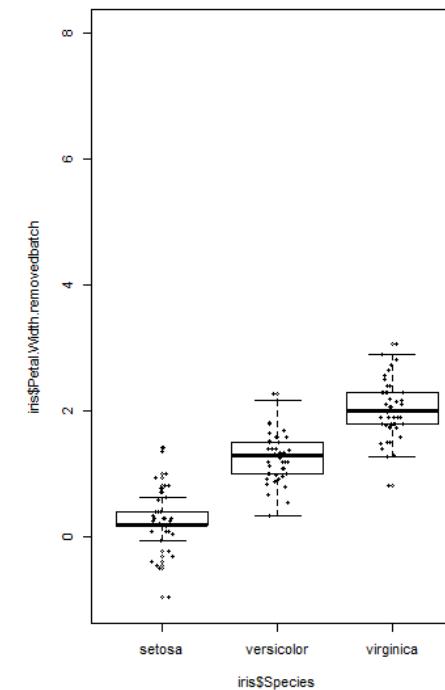
Původní



S batch  
efektem

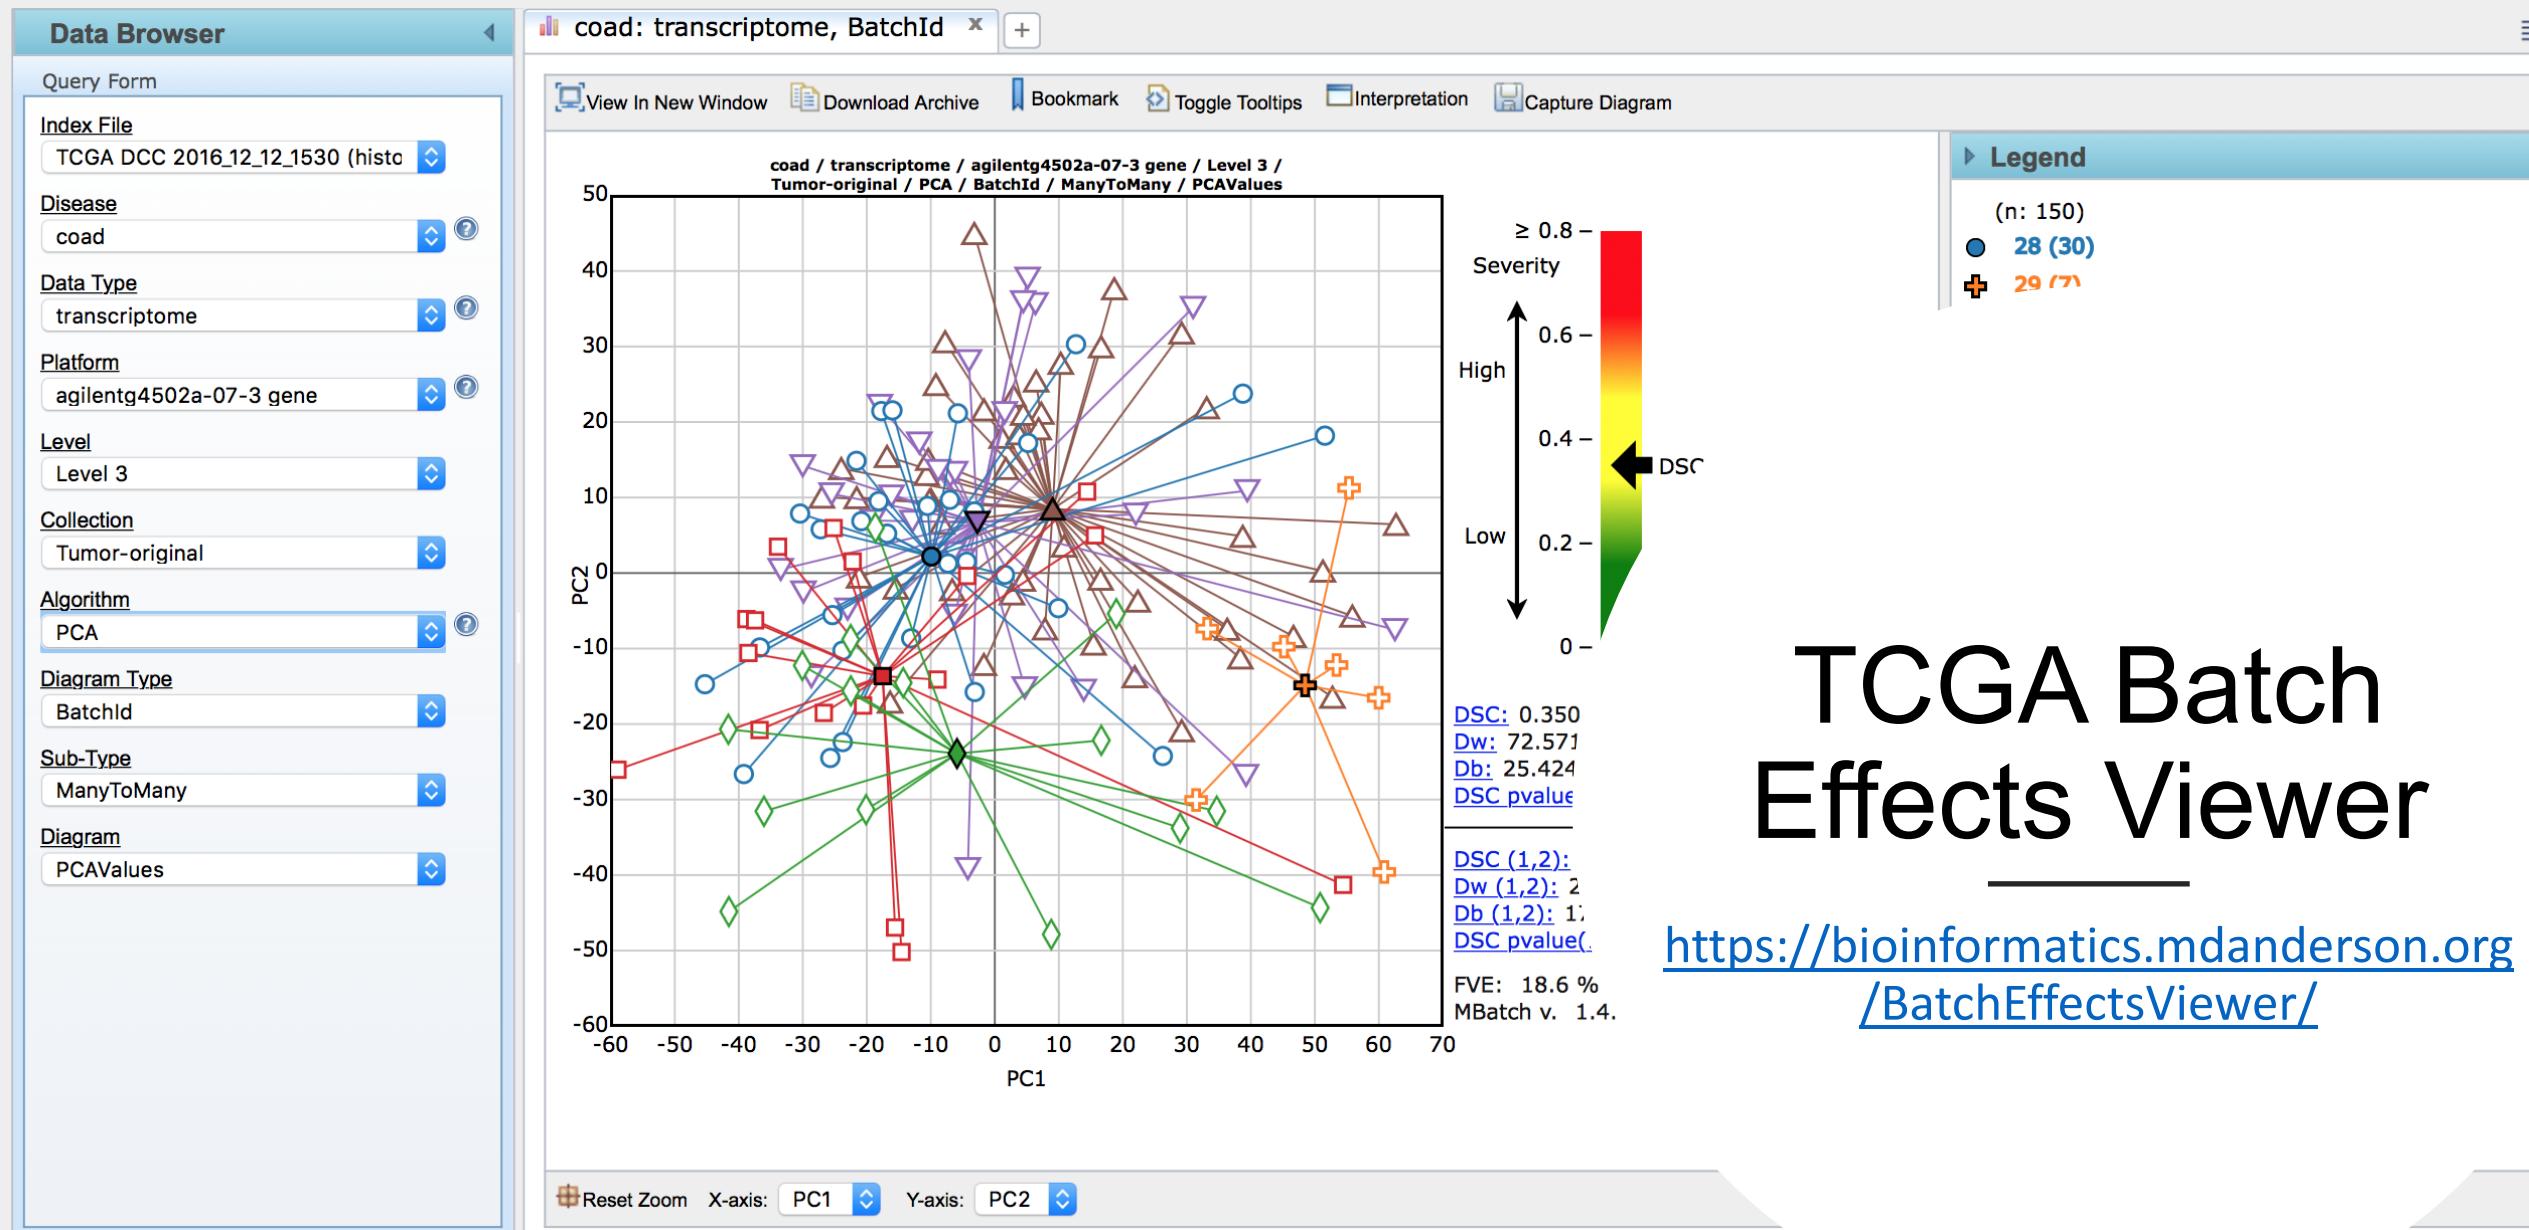


Po odstranění



# Doporučená literatura a další zdroje

## Batch Effects Viewer 2019-07-31-1100



*Ann. Appl. Stat.*

Volume 3, Number 4 (2009), 1309–1334.

[← Previous article](#)

[TOC](#)

[Next article →](#)

## Deriving chemosensitivity from cell lines: Forensic bioinformatics and reproducible research in high-throughput biology

[Keith A. Baggerly](#) and [Kevin R. Coombes](#)

Opinion | Published: 14 September 2010

# Tackling the widespread and critical impact of batch effects in high-throughput data

Jeffrey T. Leek, Robert B. Scharpf, Héctor Corrada Bravo, David Simcha, Benjamin Langmead, W. Evan Johnson, Donald Geman, Keith Baggerly & Rafael A. Irizarry 

*Nature Reviews Genetics* **11**, 733–739 (2010) | Download Citation 

**5716** Accesses | **732** Citations | **182** Altmetric | Metrics 

METHODOLOGY ARTICLE

Open Access

# Risk-conscious correction of batch effects: maximising information extraction from high-throughput genomic datasets



CrossMark

Yalchin Oytam<sup>1,2\*</sup>, Fariborz Sobhanmanesh<sup>1</sup>, Konsta Duesing<sup>1</sup>, Joshua C. Bowden<sup>3</sup>, Megan Osmond-McLeod<sup>2</sup>  
and Jason Ross<sup>1</sup>

# Trends in Biotechnology

CellPress

Volume 36 Number 4 April 2018  
Pages 498-507

Opinion

Special Issue: Computation and Modeling

## Why Batch Effects Matter in Omics Data, and How to Avoid Them

Wilson Wen Bin Goh<sup>1, 2</sup>  , Wei Wang<sup>1</sup>, Limsoon Wong<sup>2, 3</sup>  

 [Show more](#)

<https://doi.org/10.1016/j.tibtech.2017.02.012>

[Get rights and content](#)

This is an open access article published under an ACS AuthorChoice [License](#), which permits copying and redistribution of the article or any adaptations for non-commercial purposes.



Tutorial

[pubs.acs.org/jpr](https://pubs.acs.org/jpr)

## Experimental Design in Clinical 'Omics Biomarker Discovery

Jenny Forshed\*<sup>ID</sup>

Department of Oncology-Pathology, Karolinska Institutet, BOX 1031, SE-171 21, Stockholm, Sweden