

# PŘEDZPRACOVÁNÍ DAT

Radek Mareček

---

---

---

---

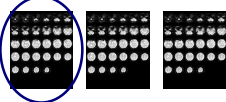
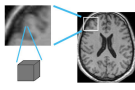
---

---

---

---

## TERMINOLOGIE

- **Session** – soubor skenů nasnímaných během jednoho běhu stimulačního paradigmatu (řádově desítky až stovky skenů)
- **Sken** – jeden nasnímaný objem
  - 
- **Voxel** – elementární nasnímaná část objemu
  - 

---

---

---

---

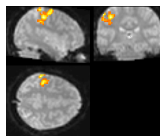
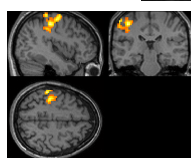
---

---

---

---

## NAMĚŘENÁ DATA

- **funkční skeny**  
nejčastěji EPI sekvence  
TR = 1.5 až 3 s ; TE = desítky ms ; FA = 90°  
voxel: cca 3x3x3 mm
  - 
- **strukturální sken**  
nejčastěji T1 sekvence  
Např.: MPRAGE TR = 1.7s ; TE = 3.93ms ; FA = 15°  
voxel: cca 1x1x1 mm
  - 
- data popisující chování subjektu během vykonávání úlohy

---

---

---

---

---


---

---

---

## KOREKCE POHYBU

- vlivem pohybu subjektu jsou jednotlivé skeny vzájemně posunuty a natočeny
- statistické zpracování signálu probíhá individuálně pro každý voxel
- voxel v jednotlivých skenech musí odpovídat stejnému místu v mozku



---

---

---

---

---


---

---

---

## KOREKCE POHYBU

- nalezení optimálních parametrů posunů a rotací vůči referenčnímu skenu (typicky první sken série)



- převzorkování

---

---

---

---

---


---

---

---

## KOREKCE ROZDÍLNÝCH AKVIZIČNÍCH ČASŮ JEDNOTLIVÝCH ŘEZŮ

- rozdíl v čase akvizice prvního a posledního řezu – řádově sekundy (-TR)
- v různých vrstvách rozdílné fáze hemodynamické odpovědi  
=> problém - statistické modely předpokládají stejný akviziční čas ve všech voxelch
- časová interpolace signálu na referenční okamžiky



---

---

---

---

---

---

---

---


# PROSTOROVÁ NORMALIZACE

NEUROVĚDNÍ VÝZKUM

X

KLINICKÁ APLIKACE

- umožňuje srovnat výsledky mezi subjekty (z hlediska lokalizace)
- transformace souřadného systému do standardního prostoru (např. MNI)




---

---

---

---

---

---

---


---

---

---

# PROSTOROVÁ FILTRACE

- zlepšení poměru signál/šum
- data lépe vyhovují požadavku na normální rozložení
- menší přesnost lokalizace výsledků




---

---

---

---

---

---

---

---


---

---

# DALŠÍ OPERACE


- grand mean scaling - průměrná intenzita skenů celé série normalizována na referenční hodnotu

- přechod z prostorové do časové domény



- filtrace v časové oblasti

- filtry typu horní a dolní propust
- ví šum, fyziologický šum, trendy v datech




---

---

---

---

---

---

---

---

---

---

# ANALÝZA POMOCÍ OBEČNÉHO LINEÁRNÍHO MODELU

Radek Mareček

---

---

---

---

---

---

---

---

## GLM

- GLM předpokládá, že BOLD signál v daném místě v mozku je tvořen lineární sumací modelových signálů

$$Y_i = x_1 \cdot \beta_{1i} + x_2 \cdot \beta_{2i} + \dots + x_n \cdot \beta_{ni} + e_i$$

naměřený signál      regresory / modelované signály      rezidua

---

---

---

---

---

---

---

---

## REGRESORY

- signály  $x_i$  tvoří sloupce matice návrhu (Design Matrix)

regresory modelující stimulaci  
konvoluce stimulace s HRF

=

- variabilita tvaru HRF
- => jiný model HRF
  - časová/disperzní derivace kanonické HRF
  - FIR
  - Fourierův rozvoj

regresory modelující arteficiální složky signálu

- arteficiální signál způsobený pohybem (pohybové parametry odhadnuté v kroku Realign)

---

---

---

---

---

---

---

---

## VÝPOČET GLM


- rovnice GLM

$$Y = X \cdot \beta + \epsilon$$

- řešením rovnice GLM je sada optimálně nalezených vah  $\beta$ , která minimalizuje residuální signál  $\epsilon$

- analytické řešení metodou nejmenších čtverců

$$\beta = (X^T X)^{-1} X^T Y$$



prostorové mapy efektů jednotlivých regresorů



prostorová mapa směrodatných odchylek reziduálního signálu

---

---

---

---

---

---

---

---

## HYPOTÉZY

- nejjednodušší případ: subjekt stimulován jednou stimulační podmínkou

$$Y = x_1 \cdot \beta_1 + e$$

nulová hypotéza:  $\beta_1 = 0$

alternativní hypotéza:  $|\beta_1| > 0$

- složitější případ: subjekt stimulován více než jednou stimulační podmínkou

$$Y = x_1 \cdot \beta_1 + \dots + x_n \cdot \beta_n + e$$

nulová hypotéza:  $c^T \beta = 0$

alternativní hypotéza:  $|c^T \beta| > 0$

- možno porovnávat odpověď na jednotlivé stimulační podmínky

---

---

---

---

---

---

---

---

## TESTOVÁNÍ HYPOTÉZ


- nejčastěji pomocí T-testu o parametrech  $\beta$

$$T \approx \frac{c^T \beta}{\sigma}$$

- T je přímo úměrné velikosti testovanému efektu
- T je nepřímo úměrné směrodatné odchylce reziduí
- T – test je proveden v každém voxelu přes celý mozek
- T statistika má Studentovo rozložení, pro  $df > 30$  se blíží normálnímu rozložení

Volbou hladiny statistické významnosti  $p$  získáme prahovou hodnotu  $T_{krit}$ .

Nadprahové voxely označují místa v mozku, kde je testovaný efekt signifikantní na dané hladině statistické významnosti.



Motorika pravé ruky  
 $p < 0.001 \sim T_{krit} = 3.1$

---

---

---

---

---

---

---

---

## TESTOVÁNÍ HYPOTÉZ

- F – test - porovnání dvou variant modelů
  - Model1 .. n1 regresorů
  - Model2 .. n2 regresorů

$n_2 > n_1$

$$F \approx \frac{RSS1 - RSS2}{RSS2}$$

RSS1 .. směrodatná odchylka reziduí Modelu 1

RSS2 .. směrodatná odchylka reziduí Modelu 2

F statistika má chí-kvadrát rozložení

- lze testovat, zda Model2 s více regresory lépe vysvětluje variabilitu v datech než Model1
  - např. zda regresory pohybových parametrů vysvětlují signifikantní část variability v signálu
  - testování efektu stimulace, pokud máme více bazových funkcí pro modelování HRF

---

---

---

---

---

---

---

---

---

---

## SKUPINOVÁ ANALÝZA


Průměrná aktivace skupiny  
Rozdíl aktivací mezi dvěma skupinami  
Rozdíl mezi aktivací před a po léčbě

### FIXED EFFECT

- výsledky vztahující se pouze na danou skupinu
- postačuje malý počet subjektů (3 až 8)
- implementace konkaténováním dat a Design matic jednotlivců

### RANDOM EFFECT

- výsledky lze zobecnit na celou populaci
- porovnává variabilitu mezi subjekty
- T-test na parametrech  $\beta$  jednotlivců



T-test

---

---

---

---

---

---

---

---

---

---