

UNIVERZITA PAVLA JOZEFA ŠAFÁRIKA V KOŠICIACH  
PRÍRODOVEDECKÁ FAKULTA

Norbert Kopčo

**Výpočtová  
a kognitívna  
neuroveda II**  
(Návody na cvičenia)

Košice 2024, Vydavateľstvo ŠafárikPress



**UNIVERZITA PAVLA JOZEFA ŠAFÁRIKA V KOŠICIACH  
PRÍRODOVEDECKÁ FAKULTA**



**Výpočtová a kognitívna neuroveda II**  
**(Návody na cvičenia)**

*Norbert Kopčo*

**Košice 2024**

## Výpočtová a kognitívna neuroveda II

(Návody na cvičenia)

*Vysokoškolská učebnica*

### Autor:

doc. Ing. Norbert Kopčo, PhD.

*Ústav informatiky, Prírodovedecká fakulta UPJŠ v Košiciach*

### Recenzenti:

prof. Ing. Rudolf Andoga, PhD.

*Letecká fakulta, Technická Univerzita v Košiciach*

Ing. Ľuboš Hládek, PhD.

*Acoustics Research Institute, Austrian Academy of Sciences*

Tento text je publikovaný pod licenciou CC BY NC ND Creative Commons Attribution-NonCommercial-No-derivates 4.0 („Uveďte pôvod – Nepoužívajte komerčne - Nespracováajte“)



Za odbornú a jazykovú stránku tejto publikácie zodpovedá autor. Rukopis neprešiel redakčnou ani jazykovou úpravou.

Dostupné od: 20.06.2024

Umiestnenie: [www.unibook.upjs.sk](http://www.unibook.upjs.sk)

ISBN 978-80-574-0332-6 (e-publikácia)

# Obsah

Úvod .....	4
1 Neurálne kódovanie, lineárna regresia, konvolúcia.....	5
2 Hodgkin-Huxleyho model .....	10
3 Zatekajúci integrátor – jednoduchý model krátkodobej pamäti .....	12
4 Stroopov experiment .....	14
5 Binaurálny sluch a psychofyzikálne metódy .....	18
6 Priestorové sluchové vnímanie.....	25
7 Konekcionistické modelovanie: Grossbergova „shunting competitive network“ a vizuálne vnímanie .....	31
8 Aditívne a shunting neurónové siete .....	36
9 Neurónová sieť OUTSTAR.....	39
10 Analýza psychofyzikálnych dát použitím modelu rozhodovania.....	42
11 Multivariačná analýza patternov dát funkčnej magnetickej rezonancie.....	45
12 Analýza EEG záznamov pomocou funkcie koherencie alebo metód strojového učenia.....	51
13 Všeobecné návody k projektom .....	56
Záver.....	61
Použitá literatúra.....	62

## Úvod

Neuroveda je interdisciplinárny vedný odbor na rozhraní biologických, psychologických a informatických vied, ktorého cieľom je popísať fungovanie mozgu a mysle. Výpočtová a kognitívna neuroveda sú podoblasti neurovedy zamerané na štúdium spracovania informácií v ľudskej a zvieracej nervovej sústave, a na teoretický popis mozgu a mysle. Táto vysokoškolská učebnica obsahuje viacero zadaní, ktoré poskytujú prehľad o metódach používaných vo výpočtovej a kognitívnej neurovede, s dôrazom na matematické modelovanie a na behaviorálne štúdium kognitívnych procesov. Učebnica nadväzuje na predošlé učebnice autora (Kopčo, 2011a; 2011b).

K vysokoškolskej učebnici existuje aj web stránka, prístupná cez adresy <https://pcl.upjs.sk/> alebo <http://sites.google.com/site/kogneuro/>. Na web stránke sú ďalšie doplnkové materiály, a to jednak multimédiá objasňujúce špecifické príklady niektorých konceptov, a jednak dáta alebo simulačné skripty, ktoré čitateľom umožnia priamo sa oboznámiť s niektorými modelmi a dátami. Táto vysokoškolská učebnica z predmetov Úvod do neurovied, Matlab a neurokognícia a Výpočtová a kognitívna neuroveda. Preto veľmi dôležitými doplnkovými materiálmi sú aj prezentácie a ďalšie materiály z týchto dvoch predmetov, na ktoré sa webstránka odkazuje, a ktoré ponúkajú okrem výpočtovej neurovedy aj všeobecnejší úvod do kognitívnej neurovedy z biologického aj psychologického hľadiska.

V tejto vysokoškolskej učebnici prezentujeme dvanásť kapitol z oblasti výpočtových a kognitívnych neurovied, v rámci ktorých predstavujeme ciele, krátky úvod, poznámky, pomôcky a obsah zadania pre danú tému, napríklad vybraným metódam neurónových sietí, analýzy EEG záznamov, či fMRI dát. Posledná, trinásta, kapitola je venovaná všeobecným návodom a usmerneniam k tvorbe projektov, ktoré boli vytvorené na základe dlhoročných skúsenosti autora pri výučbe predmetov v tejto oblasti.

Táto vysokoškolská učebnica je určená najmä pre študentov predmetov Úvod do neurovied, Matlab a neurokognícia a Výpočtová a kognitívna neuroveda, ale aj študentov všetkých informatických študijných programov so záujmom pre túto oblasť, oblasť strojového učenia, či neurónových sietí. Učebnica je vhodná aj pre ďalších záujemcov o získanie praktických skúseností v oblastiach informatického zamerania. Poskytuje návody pre študentov pri riešení praktických úloh v oblasti výpočtovej a kognitívnej neurovedy.

# 1 Neurálne kódovanie, lineárna regresia, konvolúcia

**Cieľom zadania** v oblasti neurálneho kódovania, lineárnej regresie a konvolúcie je oboznámiť sa s MATLABom a so základnou metódou analýzy dát nazývanou lineárna regresia. Matematické metódy požadované pri tomto zadaní (regresia) boli vysvetlené na prednáške.

**Úlohou študentov** v oblasti neurálneho kódovania, lineárnej regresie a konvolúcie je odovzdanie referátu, ktorého obsahom je:

- Hlavička s názvom zadania, menami ľudí, ktorí ho vypracovali (tak ako pri projekte by ste mali robiť v skupinách maximálne 4 osoby), ročník, skupinu a podobne.
- Ku každej otázke je potrebné uviesť MATLABovský príkaz (kód), ktorý ste na jej zodpovedanie použili, ako aj slovnú odpoveď na otázku. Niekedy sú otázky voľne uvedené v texte zadania. Takže si ho čítajte pozorne, a uistite sa, že ste zodpovedali na všetky otázky.
- Stále je potrebné uviesť priame slovné odpovede na otázky. Následne uveďte kód, ktorým ste odpovede získali.
- V grafoch je potrebné popísať význam rôznych farieb (funkcia legend), ako aj vysvetlenie obsahu jednotlivých osí grafu. Je potrebné vysvetliť aj obsah samotného grafu, prípadne aj slovne vyhodnotiť, či obsah grafu zodpovedá tomu, čo sme očakávali.
- Z referátu vygenerujete PDF súbor (napr. použitím programu PDFCreator), ktorý je potrebné odovzdať elektronicky na zadanú e-mailovú adresu. V predmete e-mailovej správy uveďte skratku predmetu a mená autorov.

## Postup:

Toto zadanie je založené na dátach popísaných v článku R. Wessel, C. Koch, and F. Gabbiani, Coding of time-varying electric field amplitude modulations in a wave-type electric fish. *J Neurophysiol* 75:2280-93 (1996) (Seung, 2004). Eigenmannia je druh ryby so špeciálnym orgánom, ktorým generuje slabé oscilujúce elektrické pole s frekvenciou niekoľko sto Hz. Má aj elektrosenzorický orgán, citlivý na takéto elektrické pole.

Z adresy <http://sites.google.com/site/kogneuro/> si stiahnite súbor fish.mat. Tento súbor obsahuje dáta, ktoré budete mať v zadaní analyzovať.

Spustíte si MATLAB (príkazom matlab) a načítajte dáta príkazom

```
>> load fish.mat
```


Príkaz whos vypíše zoznam premenných v pracovnom priestore:

- `time` je vzorkovací čas počas experimentu v milisekundách.
- `rho` je binárny vektor zodpovedajúci impulzom neurónu v elektrosenzorickom orgáne
- `stim` je stimulus, t.j., náhodná hĺbka amplitúdovej modulácie oscilujúceho elektrického poľa, ktorému bola ryba vystavená.

### Úlohy:

1. Z nasledujúcich 15 otázok si náhodne vyberte 5 (z každej trojice jednu, napr. a2, b1, c1, d3, e1). Na každú z vybraných otázok odpovedajte tak, že napíšete odpoveď ako aj MATLABovské príkazy (najviac dva), ktorým ste k odpovedi dospeli. MATLABovské príkazy by mali byť veľmi krátke, nesmiete používať cykly (`for`, `while`).
  - (a1) Koľko impulzov bolo zaznamenaných počas celého experimentu?
  - (a2) Aký dlhý, v sekundách, bol tento experiment?
  - (a3) Aká je priemerná frekvencia impulzov (v Hz) za celý experiment?
  - (b1) Koľko impulzov sa vyskytlo v prvej polovici experimentu?
  - (b2) Aká je priemerná frekvencia impulzov (v Hz) za prvú polku experimentu?
  - (b3) Aká je maximálna hodnota stimulu?
  - (c1) Aká je minimálna hodnota stimulu?
  - (c2) Udajte čas, v milisekundách, keď sa objavil stý impulz?
  - (c3) Aká je stredná hodnota (aritmetický priemer) sekvencie impulzov?
  - (d1) Aká je variancia (rozptyl) tejto sekvencie impulzov?
  - (d2) Vypočítajte strednú hodnotu (aritmetický priemer) tejto sekvencie impulzov bez použitia funkcie `mean`.
  - (d3) Aká vzorkovacia frekvencia bola použitá v tomto experimente?
  - (e1) Aká je štandardná odchýlka tejto sekvencie impulzov.
  - (e2) Aký je druhý moment hodnôt tejto sekvencie impulzov?
  - (e3) Vypočítajte rozptyl tejto sekvencie impulzov bez použitia funkcie `var` alebo `std`?

- Napíšte program, ktorý zobrazí niekoľko sto vzoriek sekvencie impulzov a stimulu, tak ako je to v nasledovnom obrázku 1 (ktorý zobrazuje prvých 500 milisekúnd). Vy si začiatok úseku, ktorý vykreslíte, zvolíte ľubovoľne a veľkosť vykresleného úseku nech je určená generátorom náhodných čísel MATLABu ale nech je rádovo niekoľko sto milisekúnd.



Obrázok 1: Sekvencie impulzov a stimulu (prvých 500 milisekúnd)

**Pomôcka:** použijete príkaz `plot` pre prvý obrázok, a príkaz `line` alebo `bar` pre druhý. Príkazom `subplot` vložíte dva obrázky do jedného veľkého, a príkazmi `xlabel` a `ylabel` ich popíšete. Nesmiete používať slučky. Priložte program, ktorým ste obrázok vytvorili.

- Napíšte program, ktorý vygeneruje odhad časovej závislosti pravdepodobnosti impulzov použitím pravouhlého vyhladzovacieho kernelu. Použite na to konvolúciu (`conv`) impulznej sekvencie s kernelom definovaným ako  $\text{ones}(K,1)/K$  kde  $K$  je ľubovoľné vami zvolené nepárne číslo medzi 50 a 250. Prečo je číslo, ktorým delíte kernel, nepárne? Z výsledného vektora vyberte strednú časť (vynechaním prvých a posledných  $K/2-1$  vzoriek), čím sa získa vektor rovnakej dĺžky ako  $\rho$ . Pomenujte nový vektor `prob`. Prenásobte `prob` správnou konštantou tak, aby ste získali vektor



frekvencie impulzov (v Hz čiže v impulzoch za sekundu). Tento nový vektor nazvete rate (= anglicky frekvencia). Vytvorte premennú rate2, ktorá bude lineárne preškálovanou verziou vektora rate (tj,  $rate2 = k1 * rate + k2$ ), kde preškálovanie (konštanty  $k1$  a  $k2$ ) určíte tak, aby minimum a maximum rate2 bolo zhodné s minimumom a maximumom stimulu. Odovzdajte program a graf, ktorý zobrazuje rate2 a stimulus ako funkciu času tak, že sa budú prekrývať v jednom obrázku (pomôcka: príkaz hold).

4. Aproximujte pravdepodobnosť impulzov ako funkciu stimulu. Použitím funkcie polyfit nájdite koeficienty a a b, tak aby funkcia  $a*stim+b$  optimálne aproximovala pravdepodobnosť impulzov (prob). Odovzdajte program a obrázok, ktorý do toho istého grafu zobrazí pravdepodobnosť impulzov (prob) ako funkciu času a  $a*stim+b$  ako funkciu času. Aproximácia by mala byť veľmi dobrá. Taktiež vygeneruje obrázok, ktorý do jedného grafu zobrazí prob ako funkciu stim (bez toho, aby boli dáta spojené čiarou – príkaz plot(x,y,'. ')) a  $a*stim+b$  ako funkciu stimulu. Tento obrázok by mal obsahovať čiaru, ktorá je aproximáciou dát zobrazených bodmi. Použite príkaz corcoef na výpočet korelačného koeficientu.
5. Zvoľte si jednu z nasledujúcich dvoch úloh:
  - určíte koeficienty a a b bez použitia matlabových funkcií polyfit, var a cov;
  - úloha rovnaká ako 4, ale tentokrát otestujte polynomiálny model nultého a druhého rádu, a pre všetky tri modely vypočítajte aj strednú kvadratickú chybu.
6. Akú časť (alebo aký podiel) variancie v dátach je tento model schopný vysvetliť?

### Poznámka ku korelačnému koeficientu:

Náš lineárny model je optimálny v zmysle najmenších štvorcov, t.j., chybu sme v ňom definovali ako varianciu odchýlky dát od priamky  $ax+b$ :

$$E = \sum_{i=1}^m \frac{1}{2} (a + bx_i - y_i)^2$$

Táto variancia (t.j., táto chyba) je nulová len keď je model dokonalý.

Význam korelačného koeficientu sa dá chápať tak, že tento koeficient meria pokles vo variancii (t.j., v chybe), ktorý získame použitím lineárneho modelu dát (model prvého rádu) oproti použitiu konštanty (čo by bol model nultého rádu).

Aby sme našli najlepší model nultého rádu, stačí ak v hore uvedenej rovnici dáme  $b=0$ .  $E$  je v tomto prípade minimálne pre  $a=\langle y \rangle$  (stredná hodnota  $y$ ). Konkrétne bude hodnota  $E$  priamo úmerná variancii  $y$ .

Pri hľadaní najlepšieho modelu prvého rádu hľadáme hodnoty dvoch premenných  $a$  a  $b$  tak, aby sme minimalizovali  $E$ . Hodnota  $E$  sa v porovnaní s modelom nultého rádu zníži. A pomer tejto novej hodnoty  $E$  k tej starej je rovný  $1-r^2$ . To znamená, že  $r^2$  vyjadruje zlomok variancie v  $y$ , ktorý bol vysvetlený pridaním lineárneho člena ( $b$ ) do modelu.

## 2 Hodgkin-Huxleyho model

**Cieľom zadania** v oblasti Hodgkin-Huxleyho modelu je vypracovať zadanie vo forme piatich úloh zameraných na prácu so skriptom v Matlabe a vykreslením grafov.

**Úlohou študentov** v oblasti Hodgkin-Huxleyho modelu je odovzdanie referátu, ktorého obsahom je:

- Hlavička s názvom zadania, menami ľudí, ktorí ho vypracovali (tak ako pri projekte by ste mali robiť v skupinách maximálne 4 osoby), ročník, skupinu a podobne.
- Ku každej otázke je potrebné uviesť MATLABovský príkaz (kód), ktorý ste na jej zodpovedanie použili, ako aj slovnú odpoveď na otázku. Niekedy sú otázky voľne uvedené v texte zadania. Takže si ho čítajte pozorne, a uistite sa, že ste zodpovedali na všetky otázky.
- Z referátu vygenerujete PDF súbor (napr. použitím programu PDFCreator), ktorý je potrebné odovzdať elektronicky na zadanú e-mailovú adresu. V predmete e-mailovej správy uveďte skratku predmetu a mená autorov.

### Postup:

Stiahnite si MATLABový súbor <http://sites.google.com/site/kogneuro/> (súbory v Matlabe sa volajú „skripty“.), v ktorom je naprogramovaná simulácia Hodgkin-Huxleyho modelu v prúdovej svorke (current clamp). Rovnice použité v tejto simulácii sú popísané v piatej kapitole knihy autorov Dayan a Abbott (2001) a Seung (2004). Taktiež, ak vám nie je jasná niektorá otázka, skúste si podrobne prečítať prednášku o Hodgkin-Huxleyho modeli.

### Úlohy:

1. Závislosť frekvencie impulzov na privedenom prúde. Modifikujte skript cc.m tak, aby ste mohli simulovať odozvu H-H modelu na skokovú zmenu privedeného prúdu ( $I_{app}$ ) z nulovej na pozitívnu hodnotu.

Simulujte správanie pri privedení prúdu 0,01; 0,05; 0.1 a 5  $\mu\text{A}/\text{cm}^2$ . Nemeňte začiatkové podmienky (t.j., inicializačné hodnoty  $v$ ,  $m$ ,  $h$ ,  $n$ ). Správanie pre každú hodnotu prúdu zobrazte v grafe závislosti napätia na čase a slovne popíšte.

Nájdite prahové hodnoty prúdu, pri ktorých sa kvalitatívne správanie systému mení. Inými slovami: v predošlom odseku ste pozorovali 4 rôzne typy správania sa. Pri akej hodnote prúdu neurón prejde z jedného typu správania sa na ďalší?

Jeden zo 4 typov správania sa je opakované generovanie akčných potenciálov. Aká je minimálna frekvencia impulzov. Aká je maximálna? Viete vysvetliť, prečo neurón pri prekročení maxima nemôže vygenerovať opakované impulzy?

2. Skript cc.m má začiatkové hodnoty  $V$ ,  $m$ ,  $h$ ,  $n$  nastavené približne na pokojové hodnoty, keď nie je privedený žiadny prúd. V tomto probléme sa pozrieme na to, ako inicializačné podmienky ovplyvňujú správanie sa neurónu.

Zvýšte začiatkovú hodnotu napätia  $V$  o 5 mV, a simulujte správanie sa neurónu počas nasledovných 100 ms. Vygenerujte graf závislosti napätia na čase. Model by sa mal vrátiť priamo na pokojovú hodnotu.

Teraz zvýšte počiatkovú hodnotu  $V$  o 10 mV oproti pôvodnej hodnote, a spustíte 100-milisekundovú simuláciu. Vygenerujte graf závislosti napätia na čase. Tentokrát by model mal vygenerovať jeden akčný potenciál a až potom sa vrátiť na pokojovú hodnotu.

Nájdite prahovú hodnotu napätia, potrebnú na vygenerovanie akčného potenciálu.

3. „Post-inhibitory rebound.“ Pripravte nasledovnú simuláciu: začnite s nulovým prúdom, potom prúd skokovo zmeňte na negatívnu hodnotu, a potom ho vráťte na nulu. Pri určitej hodnote amplitúdy a dĺžky poklesu vygeneruje modelový neurón pri návrate prúdu na nulu akčný potenciál. Tento fenomén sa nazýva „post-inhibitory rebound“ (niečo ako postinhibičná reakcia). Zobrazte  $V$ ,  $m$ ,  $h$ , a  $n$  ako funkciu času. Slovné popíšte čo spôsobuje vygenerovanie tohto impulzu.
4. Vygenerujte grafy, ktoré ukazujú, že Hodgkin-Huxleyho neurón má „absolútne a relatívne refraktérne obdobie.“ Grafy slovné popíšte. Pomôcka: Uvažujte, že do neurónu privádzate krátke prúdové impulzy (napr. 2 ms) o veľkosti 0,05  $\mu\text{A}$ .
5. Vygenerujte grafy, ktoré vysvetľujú pojem latencie, teda ukážte, že čím je nižší prúd, tým viac je akčný potenciál oneskorený.

### 3 Zatekajúci integrátor – jednoduchý model krátkodobej pamäti

**Cieľom zadania** v oblasti zatekajúceho integrátora – jednoduchého modelu krátkodobej pamäti je vypracovať zadanie vo forme štyroch úloh zameraných na precvičenie numerickej integrácie a tiež analýzu jednoduchých diferenciálnych rovníc.

**Úlohou študentov** v oblasti zatekajúceho integrátora – jednoduchého modelu krátkodobej pamäti je odovzdať referát, ktorého obsahom je:

- Hlavička s názvom zadania, menami ľudí, ktorí ho vypracovali (tak ako pri projekte by ste mali robiť v skupinách maximálne 4 osoby), ročník, skupinu a podobne.
- Ku každej otázke je potrebné uviesť MATLABovský príkaz (kód), ktorý ste na jej zodpovedanie použili, ako aj slovnú odpoveď na otázku. Niekedy sú otázky voľne uvedené v texte zadania. Takže si ho čítajte pozorne, a uistite sa, že ste zodpovedali na všetky otázky.
- Z referátu vygenerujete PDF súbor (napr. použitím programu PDFCreator), ktorý je potrebné odovzdať elektronicky na zadanú e-mailovú adresu. V predmete e-mailovej správy uveďte skratku predmetu a mená autorov.

#### Postup:

Vašou úlohou je simulovať a analyzovať „zatekajúci“ integrátor (angl. „leaky integrator“), t.j., jednoduchý dynamický neurálny model krátkodobej pamäti (short-term memory, STM).

Tento model je „integrátor“, pretože predpokladá, že aktivita neurónu je integrálom (súčtom) prichádzajúceho vstupného signálu za určitý čas. Slovo „zatekajúci“ vyjadruje to, že aktivita modelového neurónu klesá rýchlosťou, ktorá je priamo úmerná tejto aktivite (analógia so zatekajúcou nádobou, ktorá stráca tým viac vody, čím viac vody v nej je). Zatekajúci integrátor je popísaný nasledovnou rovnicou:

$$dx / dt = -Ax + I \quad (1)$$

kde  $I$  je vstupný podnet a  $x = x(t)$  je krátkodobá pamäť neurónu. Konštanta  $A$  reprezentuje rýchlosť spontánneho poklesu aktivity neurónu (t.j., rýchlosť zabúdania).

#### Úlohy:

1. Nech  $A=1$  a nech  $x(0)=0$ , t.j., na začiatku neurón nemá žiadnu aktivitu. Nech je vstupný podnet rovný  $I=5$  v čase od  $t=1$  do  $t=6$ , inak nech vstup je  $I=0$ . Numericky

integrujte rovnicu (1) v čase  $t=0$  až  $t=10$ . Zobrazte priebeh aktivity. Aká je asymptotická hodnota keď je vstupný podnet nenulový?

2. Zopakujte simuláciu z úlohy 1. pre hodnoty  $A=0.5$  a  $A=2$ . Čo sa zmenilo?
3. Nájdite ekvilibrium (riešenie) rovnice (1) pre konštantnú hodnotu vstupu  $I$  (t.j., pre  $I$ , ktoré sa v čase nemení). Riešenie nájdete tak, že ľavú stranu rovnice nahradíte nulou a nájdete hodnotu  $x$ . Zhoduje sa táto hodnota s výsledkom vašej simulácie?
4. Predpokladajte, že  $I$  je konštantné a že počiatkové  $x(0)=0$ , takže rovnica (1) sa zmení na lineárnu diferenciálnu rovnicu prvého rádu s konštantnými koeficientmi. Vyriešte rovnicu analyticky, teda nájdite explicitnú rovnicu ktorá popisuje  $x(t)$  ako funkciu  $t$  a parametrov  $A$  a  $I$ .

Pre numerickú integráciu v častiach 1. a 2. použite Eulerovu metódu, teda na aproximáciu  $x(t)$  použite algoritmus

$$x(t+\Delta t) = x(t) + (dx/dt)\Delta t,$$

kde  $\Delta t$  je malý časový krok. Správa by mala obsahovať grafy pre časti 1. a 2. a riešenia rovnice v častiach 3. a 4. Priložte aj MATLABový skript, ktorý ste použili pre numerickú integráciu.

## 4 Stroopov experiment

**Cieľom zadania** v oblasti Stroopovho experimentu je vypracovať zadanie zamerané na metódy používanými pri behaviorálnych štúdiách fungovania ľudského mozgu a mysle.

**Úlohou študentov** v oblasti Stroopovho experimentu je mierne upraviť experimentálny matlabový skript, ktorý vám je poskytnutý, nazbierať dáta na sebe, t.j., ľuďoch, s ktorými ste v skupine (prípadne aj na ďalších rodinných a iných príslušníkoch), dáta zanalyzovať a vypracovať správu z experimentu. Úlohou je odovzdanie referátu, ktorého obsahom je:

- Hlavička s názvom zadania (s označením časti), menami ľudí, ktorí ho vypracovali (tak ako pri projekte by ste mali robiť v skupinách maximálne 4 osoby), ročník, skupinu a podobne.
- Ku každej otázke je potrebné uviesť MATLABovský príkaz (kód), ktorý ste na jej zodpovedanie použili, ako aj slovnú odpoveď na otázku. Niekedy sú otázky voľne uvedené v texte zadania. Takže si ho čítajte pozorne, a uistite sa, že ste zodpovedali na všetky otázky.
- Z referátu vygenerujete PDF súbor (napr. použitím programu PDFCreator), ktorý je potrebné odovzdať elektronicky na zadanú e-mailovú adresu. V predmete e-mailovej správy uveďte skratku predmetu a mená autorov.

### Postup:

Toto zadanie je založené na experimente J. Stroopa z roku 1935, ktorým ilustroval fenomén **interferencie** v kognitívnych procesoch ([psychclassics.yorku.ca/Stroop/](http://psychclassics.yorku.ca/Stroop/)), popis v slovenčine je napríklad na [www.percepcia.szm.sk/Stroop.html](http://www.percepcia.szm.sk/Stroop.html). Pod interferenciou tu rozumieme ovplyvnenie určitého kognitívneho procesu zmenou (napr. perceptuálnych) parametrov, ktoré s daným procesom *striktne povedané* nesúvisia. Konkrétne Stroop ukázal, že rýchlosť, akou sme schopní pomenovať farbu písma je nižšia, ak je farba v rozpore s významom slova, ktoré je daným písmom/farbou napísané (t.j., určiť, že nasledujúce slovo „**modrá**“ je napísané zelenou farbou nám trvá dlhšie než keď je napísané „**modrou**“). V tomto zadaní si na sebe overíte tento efekt v krátkom experimente.

Cieľom zadania je:

- priblížiť Vám, ako je možné takéto experimenty v MATLABe realizovať,
- oboznámiť Vás so štatistickými metódami používanými na analýzu dát, a

- dať Vám možnosť precvičiť si, ako sa píše články, ktoré takéto experimenty popisujú.

V adresári <http://sites.google.com/site/kogneuro/> nájdete dva MATLABové skripty:

- `expltr.m` MATLABový súbor s tréningovou rutinou pre prípravu experimentu,
- `expl.m` skript na spustenie samotného experimentu a nazbieranie dát.

Vašou úlohou bude:

- zorganizujete sa do skupín približne 4 ľudí,
- každý jednotlivec v skupine sa zúčastní experimentu, ktorý má dve fázy – tréning a samotný experiment,
- zanalyzujete nazbierané dáta, a
- napíšete správu, v ktorej zhodnotíte svoje výsledky.

Na prednáške respektíve cvičení sú vysvetlené štatistické procedúry, ktoré budete mať použiť pri analýze. Sami si ich môžete naštudovať zo súboru `tests_of_significance.pdf` na webe skript.

### **Tréning:**

Pred začatím experimentu každý absolvuje tréning, v ktorom sa naučí asociovať určité klávesy počítača s farbami na obrazovke. Pri tréningu budú prezentované farebné štvorce, a vy musíte odpovedať stlačením príslušnej klávesy (c – modrá, v – zelená, medzera – hnedá, čiarka (,) – fialová a bodka (.) – červená). Pri tréningu systém stále oznamuje, či ste odpovedali správne, a tréning pokračuje tak dlho, dokiaľ neodpoviete správne 15-krát za sebou s priemernou dĺžkou odpovede kratšou ako 0.8 sekundy.

### **Experiment:**

V samotnom experimente je úloha rovnaká, ale miesto farebných štvorcov sa objavujú názvy farieb (vždy zobrazené inou ako správnou farbou) alebo text „xxxxx“. **Úlohou pri experimente je stále správne určiť farbu textu, nie to, čo je na obrazovke napísané.** Prezentácie, keď sa objavujú názvy farieb sú experimentálne prezentácie, zatiaľčo keď sa prezentuje text „xxxxx“ hovoríme o kontrolnej prezentácii.

Celkovo pozostáva experiment zo 120 prezentácií.



## Analýza dát:

Po ukončení experimentu skript `exp1.m` vygeneruje MATLABový súbor vo formáte „`stroop_deň_hodina_minúta.mat`“, v ktorom sú zaznamenané odpovede jednotlivca, ktorý sa na experimente podieľal. Tento súbor pri analýze načítate do MATLABu príkazom `load`. Po načítaní sa v MATLABe objavia dve premenné, jedna z nich sa volá `trial_data`. Toto je dvojrozmerná matica, ktorej každý riadok zodpovedá záznamu z jednej prezentácie (t.j., dokopy má 120 riadkov). Význam stĺpcov je nasledovný:

- stĺpec: kód prezentovaného textu (0-xxxx, 1-modrá, 2-zelená,...),
- stĺpec: kód prezentovanej farby (1-modrá...),
- správnosť odpovede: 1 – správne, 0 – nesprávne,
- reakčný čas RT: čas (v sekundách), za ktorý subjekt pri danej prezentácii odpovedal.

Pre každého jednotlivca urobte nasledovnú analýzu (štatistické pojmy budú vysvetlené na prednáške):

Pre každého jednotlivca urobte nasledovnú analýzu (štatistické pojmy budú vysvetlené na prednáške):

- vypočítajte strednú hodnotu (aritmetický priemer) a medián reakčných časov zvlášť pre experimentálne a zvlášť pre kontrolné prezentácie (v MATLABe príkazy `mean`, `median`). Ktorá štatistická mierka je vhodnejšia? Taktiež vypočítajte štandardnú deviáciu reakčných časov pre tieto dva typy prezentácií,
- vygenerujte obrázok, ktorý rôznymi symbolmi v tom istom grafe ukáže distribúciu reakčných časov v kontrolných a experimentálnych prezentáciách (príkazy `hist`, `plot`, `axis`, `xlabel`, `legend`, `title`),
- použitím štatistického „studentovho t-testu“ rozhodnite, či je rozdiel v reakčných časoch medzi experimentálnymi a kontrolnými prezentáciami štatisticky významný (na úrovni  $\alpha=0.05$ , MATLABová funkcia `ttest`).
- Vygenerujte aj zhrnujúce grafy, ktoré uvedú priemerné hodnoty analyzovaných parametrov za celú skupinu. K vypracovanej správe priložte kúsky MATLABového kódu, ktoré ste použili pri analýze.
- Vygenerujte aj zhrnujúce grafy, ktoré uvedú priemerné hodnoty analyzovaných parametrov za celú skupinu. K vypracovanej správe priložte kúsky MATLABového kódu, ktoré ste použili pri analýze.

**Správa z experimentu:**

Výsledok experimentu popíšete v správe (textový dokument odovzdaný v elektronickej alebo vytlačenej forme), ktorá bude obsahovať minimálne časti:

- Úvod – stručný popis cieľov
- Metódy – popis metód použitých pri experimente
- Výsledky – prezentácia výsledkov
- Diskusia – diskusia výsledkov experimentu.

**Doplňkové úlohy:**

V prípade záujmu je možné vypracovať aj nasledujúce úlohy:

- Modifikovať experiment tak, aby kontrolné prezentácie neukazovali „xxxxx“ ale text správnej farby. Zmenili sa nejak výsledky v porovnaní s pôvodnou verziou?
- Vypočítať strednú hodnotu a medián pravdepodobnosti správnej odpovede namiesto analýzy reakčného času.
- Zanalyzovať dáta zvlášť podľa jednotlivých farieb. V priemere, pri prezentácii ktorej farby boli reakcie najrýchlejšie, kedy najpomalšie?
- Vykresliť ako sa percento chýb a reakčné časy menili počas trvania tréningu (teda, ako funkciu bloku).
- V prípade riešenia týchto úloh môžete získať 10% bonusových bodov za toto zadanie.

## 5 Binaurálny sluch a psychofyzikálne metódy

**Cieľom zadania** v oblasti binaurálneho sluchu a psychofyzikálnych metód je vypracovať zadanie zamerané na fenomén nazývaný binaural masking level differences (BMLD). Tento fenomén ilustruje schopnosť nášho sluchového systému porovnať, čo počujeme ľavým a pravým uchom, a výsledok tohto porovnania použiť na potlačenie rušivého šumu a na zlepšenie schopnosti vnímať užitočný zvuk.

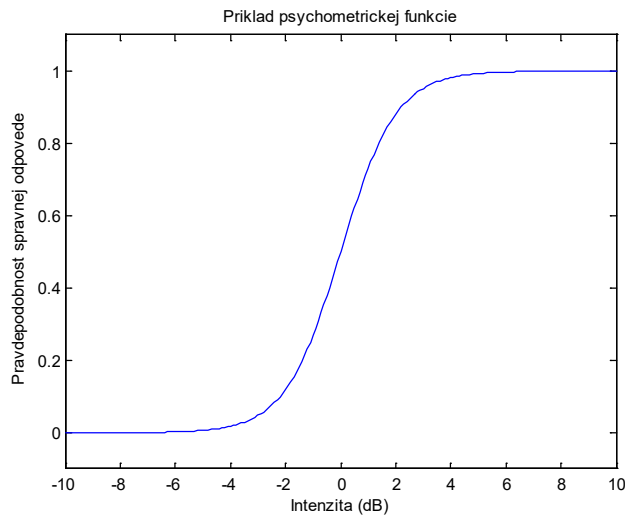
**Úlohou študentov** v oblasti binaurálneho sluchu a psychofyzikálnych metód je odovzdanie referátu, ktorého obsahom je:

- Hlavička s názvom zadania (s označením časti), menami ľudí, ktorí ho vypracovali (tak ako pri projekte by ste mali robiť v skupinách maximálne 4 osoby), ročník, skupinu a podobne.
- Ku každej otázke je potrebné uviesť MATLABovský príkaz (kód), ktorý ste na jej zodpovedanie použili, ako aj slovnú odpoveď na otázku. Niekedy sú otázky voľne uvedené v texte zadania. Takže si ho čítajte pozorne, a uistite sa, že ste zodpovedali na všetky otázky.
- Z referátu vygenerujete PDF súbor (napr. použitím programu PDFCreator), ktorý je potrebné odovzdať elektronicky na zadanú e-mailovú adresu. V predmete e-mailovej správy uveďte skratku predmetu a mená autorov.

### Úvod do psychofyzikálnych metód:

Na **objektívne** meranie ľudskej schopností vnímať a reagovať na určité podnety sa používajú psychometrické alebo psychofyzikálne metódy. Cieľom aplikácie týchto metód môže byť napr. charakterizovať, aký silný (intenzívny) musí byť (napr. zvukový) podnet na to, aby ho človek bol schopný detekovať, čiže rozpoznať.

Pre mnoho typov stimulov platí, že závislosť medzi intenzitou stimulu a schopnosťou správne ho detekovať je monotónne rastúca. Teda v prípade štúdia sluchu, čím je zvuk hlasnejší, tým väčšia je pravdepodobnosť, že ho počujeme. Často má psychometrická funkcia sigmoidálny (esovitý) tvar, ako ilustruje obrázok 2. Konkrétne, tento obrázok nám vraví, že ak prezentujeme zvuk s intenzitou (hlasitosťou) -8 dB, nebudeme počuť nič, ak ho prezentujeme s hlasitosťou 0 dB, budem schopní detekovať ho s 50% pravdepodobnosťou, a ak ho prezentujeme s hlasitosťou nad 8 dB, budeme ho správne počuť vždy (samozrejme, existujú aj horné medze – napr. skúste zvuk prezentovať s hlasitosťou 200 dB).



Existuje

*Obrázok 2: Sigmoidálny tvar psychometrickej funkcie*

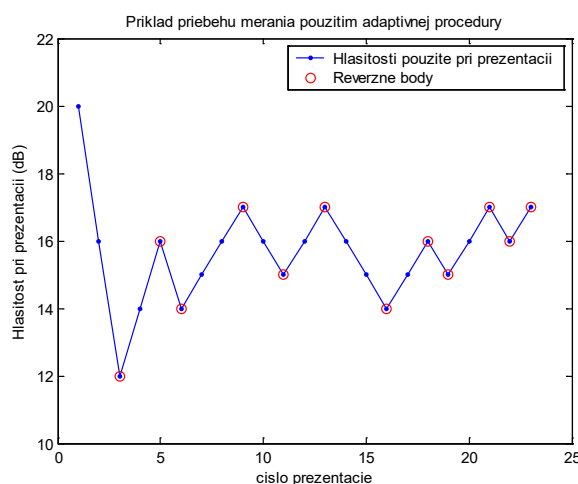
mnoho metód,

ako merať psychometrické funkcie. My sa pozrieme na tri z nich:

### 1. Metóda konštantných stimulov:

Dopredu si zvolíme niekoľko úrovní intenzity (napr. pre odhad psychometrickej funkcie na obrázku 3 si môžeme zvoliť úrovne -6, -4, -2, 0, 2, 4 a 6 dB) a pre každú úroveň intenzity sa experimentálneho subjektu pýtame či zvuk počul alebo nie, s tým, že meranie zopakujeme pre každú úroveň napr. 20 krát. Na základe týchto hodnôt potom môžeme odhadnúť celú psychometrickú funkciu. Ak chceme určiť prah pre 50% schopnosť detekcie, musíme interpolovať medzi nameranými hodnotami.

### 2. Metóda limit:



*Obrázok 3: Odhad psychometrickej funkcie použitím adaptívnej procedúry*

Táto metóda sa od predošlej líši tým, že nemeria celú psychometrickú funkciu, ale len prahovú hodnotu zodpovedajúcu bodu, pri ktorom subjekt počuje stimul s 50-percentnou

pravdepodobnosťou. Každý prah sa meria v dvoch blokoch: stúpajúcom a klesajúcom. Pri vzostupnom bloku sa začne s hlasitosťou oveľa menšou než je prah (určí sa predtým pri pilotnej štúdií), a hlasitosť sa postupne zvyšuje až kým subjekt zvuk nepočuje. Pri zostupnom bloku sa začne s hlasitosťou, pri ktorej subjekt zvuk jasne počuje, a hlasitosť sa postupne znižuje až kým zvuk počuť neprestane. Meranie sa zopakuje niekoľko krát vzostupne aj zostupne, a priemer konečných hodnôt (vzostupných aj zostupných blokov) sa použije ako nameraná hodnota prahu.

### **3. Adaptívna/schodová metóda:**

Táto metóda je podobná metóde limit v tom, že pri jednom meraní sa meria len jeden bod na psychometrickej krivke. Experimentátor si ale môže zvoliť, ktorý bod chce merať. Postupuje sa tak, že sa definujú podmienky, za akých sa intenzita zvuku zvýši a za akých sa zníži. Napr. sa povie, že hlasitosť sa zníži vždy, keď subjekt zvuk počul, a naopak, že hlasitosť sa zvýši vždy, keď zvuk nepočul. Priebeh takéhoto merania môže byť nasledovný: subjekt pri prvých troch prezentáciách zvuk počul, takže hlasitosť sa postupne znižovala. Potom ale zvuk dvakrát nepočul, takže hlasitosť sa zas dvakrát zvýšila. Potom zas počul, atď. atď. Hlasitosť, pri ktorej sa zmení smerovanie zmeny hlasitosti (napr. ak sa v predošlom meraní hlasitosť znížila ale v následnom sa zvýši) sa nazýva reverzný bod (viď obrázok). Tento postup sa opakuje, napr. dokým sa nezíska 12 reverzných bodov. Meraný prah sa potom určí ako priemer posledných ôsmich reverzných bodov (pre meranie na obrázku je to 15,8 dB). Zvyčajne sa taktiež behom merania mení krok, s akým sa hlasitosť mení. Pri sluchových experimentoch sa väčšinou do prvého reverzného bodu používa krok 4 dB, pre ďalšie dva reverzné body krok 2 dB, a potom krok 1 dB.

V uvedenom príklade bolo pravidlo pre zmenu hlasitosti jednoduché: nepočutie zvuku znamenalo zvýšenie hlasitosti v ďalšom kroku, zatiaľčo počutie znamenalo zníženie hlasitosti. Týmto pravidlom získame prah, ktorý zodpovedá bodu na psychometrickej krivke, pri ktorom subjekt počuje stimul s 50-percentnou pravdepodobnosťou. Takéto pravidlo sa nazýva „1-down-1-up“). Ak ale použijeme procedúru, pri ktorej musí subjekt na to, aby sa hlasitosť znížila, odpovedať správne dvakrát po sebe, prah ktorý takto získame zodpovedá bodu na psychometrickej krivke zodpovedajúci pravdepodobnosti počutia 70% (pravidlo pre zvýšenie nemení, procedúra sa označuje „2-down-1-up“). Podobne, procedúra „3-down-1-up“ meria bod na psychometrickej krivke zodpovedajúci 79% pravdepodobnosti počutia.

### **Prehľad zadania:**

V tomto zadaní bude vašou úlohou overiť si fenomén nazývaný **binaural masking level differences** (BMLD, niečo ako binaurálny rozdiel v úrovni maskovania, vid' prednášku zo 7.4.). Tento fenomén ilustruje schopnosť nášho sluchového systému porovnať čo počujeme ľavým a pravým uchom, a výsledok tohto porovnania použiť na potlačenie **rušivého** šumu a na zlepšenie schopnosti vnímať **užitočný** zvuk. Pri experimente budete prezentovať zvuk (čistý tón, ktorého frekvenciou budete meniť) maskovaný bielym šumom a budete merať prahovú hlasitosť pre detekovanie tónu. Šum bude prezentovaný vždy s konštantnou hlasitosťou (nemeniť počas celého experimentu) a identicky pre oba kanály (ľavé a pravé sluchátko). Hlasitosť tónu budete meniť, aby ste určili jej prahovú hodnotu. Prah budete merať pri prezentácii identického tónu do ľavého a pravého ucha (tzv. diotická prezentácia) a pri prezentácii s invertovaním zvuku v jednom uchu (t.j., do ľavého ucha púšťate signál  $x$ , do pravého  $-x$ ; keďže sa jedná o sínusový signál, invertovanie znamená posunutie fázy o  $180^\circ$ ; túto prezentáciu budeme nazývať dichotická). Vašou úlohou bude odmerať prah pre detekovanie dioticky a dichoticky prezentovaných tónov rôznych frekvencií (maskovací šum bude prezentovaný vždy dioticky). Diotickú prezentáciu budeme označovať aj NoSo (tj, tón aj šum v oboch ušiach rovnaký). Dichotickú prezentáciu budeme označovať aj NoS $\pi$  (tj, šum identický, tón v jednom uchu invertovaný). Pre tóny nízkej frekvencie by mal byť rozdiel medzi NoS $\pi$  a NoSo prahmi veľký, zatiaľčo pre vyššie frekvencie by sa rozdiel mal znižovať.

### **Poznámka:**

Hlasitosť zvukov sa často vyjadruje v decibeloch (dB), čo je relatívna logaritmická mierka. Bez toho, aby ste potrebovali rozumieť detailom, zapamätajte si, že na prevod medzi amplitúdovým a decibelovým vyjadrením hlasitosti potrebujete spraviť nasledujúcu operáciu:

hodnota\_v\_dB =  $20 \cdot \log_{10}(\text{amplituda})$ . Napr., ak mám dva tóny, jeden s amplitúdou  $A$  (t.j.,  $A \cdot \sin(t)$ ) a druhý  $2 \cdot A$  (t.j.,  $2 \cdot A \cdot \sin(t)$ ), rozdiel ich hlasitostí v dB bude  $20 \cdot \log_{10}(2 \cdot A/A)$ , t.j., približne 6 dB, zatiaľ kým pomer amplitúd je 2.

## Postup:

1. Z webu si stiahnite MATLABový skript <http://sites.google.com/site/kogneuro/>. Tento skript umožňuje prehrať tón zvolenej frekvencie a dĺžky so zvolenou hlasitosťou (zadanou amplitúdou, nie v dB). Zároveň táto funkcia prehrá so zvolenou hlasitosťou aj biely maskovací šum. V súčasnom stave funkcia prehrá tón aj šum identicky cez obe slúchadlá (zo stereo výstupu). Vy skript `playsound.m` modifikujete tak, že bude môcť prehrať tón dioticky alebo dichoticky (zatiaľčo maskovací šum bude vždy dichotický). Na určenie či sa má prehrať zvuk dioticky alebo dichoticky môžete funkcii `playsound` zadávať ďalší parameter, prípadne môžete vytvoriť novú funkciu.
2. Každá skupina si z horeuvedených troch metód pre psychometrické merania zvolí **dve**, a tieto dve metódy implementuje v MATLABe. Použitím zvolených metód potom pre 4 subjektov odmeriate detekčné prahy pri  $No\pi$  a  $NoSo$  prezentácii pre frekvencie tónu 250, 500, 1000, 2000 a 4000 Hz (t.j., odmeriame 10 rôznych prahov zodpovedajúcich desiatim rôznym typom prezentácie).  
Súčasťou vašej meracej procedúry bude funkcia, ktorá prezentuje zašumený tón, a vypýta si od poslucháča odpoveď (napr. 1, ak tón počul a 0 ak nie).  
Je dôležité, aby ste behom merania nemenili žiadne nastavenia týkajúce sa hlasitosti počítača (a teda nemeňte ani počítač). Pred začatím merania nastavte vo WINDOWS všetky indikátory pre nastavovanie hlasitosti na maximum (alebo do polovice). Pohrajte sa s hlasitosťou šumu, a zvolte si takú, kde šum jasne a relatívne hlasno počujete, ale zároveň kde ešte šum nie je príliš hlasný (nezabudnite, že behom experimentu budete tento šum počuť niekoľko sto krát).  
Dĺžku stimulov si zvolte medzi 0.5 a 1 sekundou a behom experimentu ju nemeňte.
3. **Analýza dát:** Pre každého subjektu zvlášť zobrazte do jedného grafu priemerné hodnoty a rozptyly prahov pre všetkých 10 prezentačných módov a zvlášť pre dve zvolené metódy merania. Porozmýšľajte nad takou formou vizuálnej prezentácie (t.j., grafov), ktorá ukáže jednak BMLD, jednak závislosť BMLD na frekvencii. Zároveň porovnajte výsledky dosiahnuté zvolenými dvomi metódami: Líšia sa nejak priemery alebo rozptyly? Vygenerujte aj súhrnné grafy, ktoré zobrazia priemerné hodnoty za všetkých subjektov. Ak sa vám zdá, že v grafoch vidíte nejaký signifikantný efekt, môžete skúsiť použiť **Studentov t-test** na overenie vašej hypotézy.

4. **Správa:** Podobne ako u Stroopa, výsledok experimentu popíšete v správe (textový dokument odovzdaný v elektronickej alebo vytlačenej forme), ktorá bude obsahovať minimálne časti:

- Úvod – stručný popis cieľov
- Metódy – popis metód použitých pri experimente
- Výsledky – prezentácia výsledkov
- Diskusia – diskusia výsledkov experimentu

#### **Poznámky k meraniu jednotlivými metódami:**

**Konštantné stimuly:** Predtým, než začnete vlastný experiment, musíte trochu „pilotovať“, tzn., pohrať sa s hlasitosťou tónu pre každý z 10 typov prezentácií. Konkrétne, metódou pokus-chyba musíte určiť takú hlasitosť, pri ktorej je tón jasne počuteľný (napr., hlasitosť zodpovedajúca hodnote 7 dB na prvom obrázku) a pri ktorej nie je počuteľný vôbec (napr. -8 dB z prvého obrázku). Z tohto intervalu hlasitostí potom zvolíte 5 približne rovnomerne rozmiestnených hodnôt (napr. -8, -4, -1, 3 a 7 dB). Meranie pre každý typ prezentácie a každú hlasitosť zopakujete 20 krát (v úplne náhodnom poradí). Na základe týchto meraní určíte pravdepodobnosť detekcie pre danú hlasitosť. A použitím týchto pravdepodobností určíte prahovú hodnotu hlasitosti pre 50% pravdepodobnosť detekcie.

**Metóda limit:** Zase musíte trochu „pilotovať“, aby ste určili dobrú počiatočnú hlasitosť pre vzostupné a zostupné bloky. Potom behom jedného merania meňte amplitúdu tónu pre násobovaním konštantnou hodnotou (napr. 1.2, NIE v dB) až kým nedosiahnete konečnú hodnotu. Poradie, v ktorom sa budú jednotlivé bloky prezentovať by zase malo byť náhodné (napr. vzostupný blok pre 500-Hz tón prezentovaný v NoS $\pi$  móde nasledovaný zostupným blokom pre 2000-Hz tón prezentovaný v NoSo móde). Na určenie jedného prahu potrebujete urobiť 5 vzostupných a 5 zostupných meraní. Prah pre 50% pravdepodobnosť detekcie potom určíte ako priemer takto získaných desiatich konečných hodnôt.

**Adaptívna metóda:** Túto metódu implementujte vo forme „1-down-1-up“ presne ako je uvedené na začiatku (tj, 12 reverzných bodov s krokom 4, 2, 1, 1.... dB a s priemerom posledných 8 reverzných krokov určujúcim výsledný prah). Pred samotným experimentom potrebujete trošička pilotovať, t.j., pre každý prezentačný mód treba nájsť hlasitosť tónu, pri ktorej je tón jasne počuť. Meranie pre každý prezentačný mód opakujte 5 krát, a výsledný prah určíte ako priemer týchto piatich meraní.



**Bonusová otázka:**

Čo myslíte, aký v porovnaní s  $NoSo$  a  $NoS\pi$  bude detekčný prah pri prezentácii  $N_M S_M$  a  $NoS_M$ , kde  $M$  znamená, že zvuk prezentujeme monaurálne (t.j., len do jedného ucha)? Ako tradične, ak spravíte dodatočný experiment a nájdete odpoveď na túto otázku, máte šancu získať bonusové body v rozsahu 10% z celkového zadania.

## 6 Priestorové sluchové vnímanie

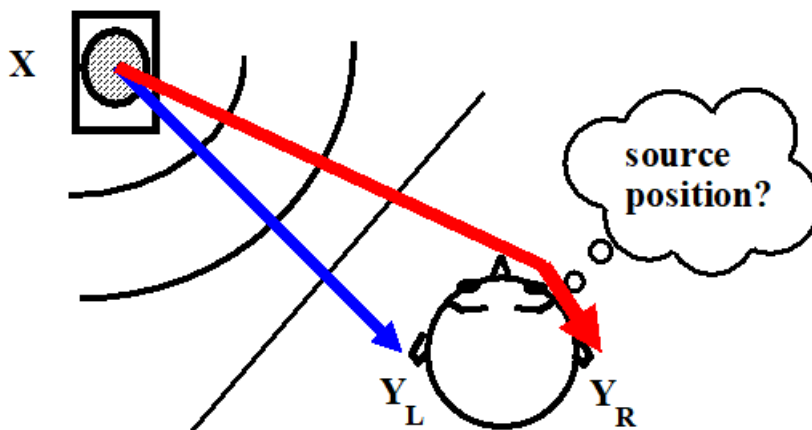
**Cieľom zadania** v oblasti priestorového sluchového vnímania je vypracovať zadanie zamerané na smerové prenosové funkcie HRTFs.

**Úlohou študentov** v oblasti priestorového sluchového vnímania je odovzdať referát, ktorého obsahom je:

- Hlavička s názvom zadania (s označením časti), menami ľudí, ktorí ho vypracovali (tak ako pri projekte by ste mali robiť v skupinách maximálne 4 osoby), ročník, skupinu a podobne.
- Ku každej otázke je potrebné uviesť MATLABovský príkaz (kód), ktorý ste na jej zodpovedanie použili, ako aj slovnú odpoveď na otázku. Niekedy sú otázky voľne uvedené v texte zadania. Takže si ho čítajte pozorne, a uistite sa, že ste zodpovedali na všetky otázky.
- Z referátu vygenerujete PDF súbor (napr. použitím programu PDFCreator), ktorý je potrebné odovzdať elektronicky na zadanú e-mailovú adresu. V predmete e-mailovej správy uveďte skratku predmetu a mená autorov.

### Úvod do priestorového sluchového vnímania:

Keď sa zvuk šíri od zdroja (napr. reproduktora) do našich uší, transformuje sa tento zvuk interakciou s prostredím, našou hlavou, plecami, ušnicami a sluchovým kanálom (viď. Obrázok 4). Táto transformácia spôsobí, že zvuk, ktorý počujeme sa v skutočnosti líši od toho, aký zvuk vyšiel zo zdroja. Navyše, líši sa aj to, aký zvuk v skutočnosti počujeme ľavým a pravým uchom. My si to, že sme ľavým a pravým uchom počuli niečo iné za normálnych okolností neuvedomujeme. Práve naopak, náš mozog sa snaží analyzovať rozdiely v tom, ako zvuk dorazil do ľavého a pravého ucha (napr. do ktorého ucha dorazil hlasnejší alebo do ktorého dorazil skôr), a na základe týchto rozdielov sa snaží vypočítať, odkiaľ zvuk prišiel. My si potom uvedomujeme len to, že sme počuli jeden zvuk a že ten zvuk prišiel napr. zľava, miesto toho aby sme si uvedomili, že sme počuli dva trochu rozdielne zvuky, jeden ľavým a jeden pravým uchom.



Obrázok 4: Priestorové sluchové vnímanie

Matematicky sa transformácia, ktorou zvuk prešiel po ceste od zdroja (reproduktoru) po bubienky ľavého resp. pravého ucha dá charakterizovať tzv. prenosovou funkciou (tiež nazývanou impulzná odozva). Každému bodu v priestore okolo nás zodpovedá jeden pár prenosových funkcií, jedna pre ľavé a jedna pre pravé ucho. Tieto prenosové funkcie sa v angličtine nazývajú Head-Related Transfer Function a my ich budeme nazývať **smerové prenosové funkcie** a značiť anglickou skratkou HRTF. Keď máme nejakého človeka k dispozícii takýto pár prenosových funkcií zodpovedajúci určitému bodu v priestore (napr. na obrázku hore sú farebne vyznačené prenosové funkcie pre bod  $50^\circ$  vľavo od stredovej osi – t.j.  $0^\circ$  je priamo pred nami), potom vieme veľmi jednoducho nasimulovať, ako tento človek vníma akýkoľvek zvuk (reč, husle, bubon, buldozér), keď ten zvuk prichádza z daného bodu v priestore.

Povedali sme si, že dva základné parametre, ktoré náš mozog extrahuje z počutého zvuku na to, aby odhadol odkiaľ ten zvuk prišiel, sú interaurálne (t.j. „medziušné“) rozdiely v čase a v hlasitosti s akou zvuk do uší dorazil. Prvý rozdiel označíme skratkou ITD, druhý ILD. Keďže vo funkciách HRTF sú zakódované všetky informácie, ktoré mozog extrahuje na to, aby odhadol odkiaľ zvuk prišiel, sú v nich zakódované aj hodnoty ITD a ILD zodpovedajúce danej polohe zdroja zvuku.

Keď sa HRTF merajú v reálnej miestnosti (tak ako je to v našom prípade), neobsahujú tieto odozvy len to, ako zvuk dorazil zo zdroja priamo do našich uší, ale aj to, ako dorazili do našich uší odrazy tohto zvuku od stien. V zásade prídu tieto odrazy do našich uší neskôr než priamy zvuk, takže vo všeobecnosti môžeme získať HRTF bez odrazov od stien tak, že túto funkciu usekneme po prvom impulze.

## Postup:

V tomto zadaní bude vaša úlohou pohrať sa so smerovými prenosovými funkciami HRTFs. Z adresára <http://sites.google.com/site/kogneuro/> si stiahnete súbor hrtf3.mat.

Spustíte si MATLAB a načítajte svoju HRTF príkazom


```
>> load hrtf3.mat
```

Príkaz `whos` vypíše zoznam premenných v pracovnom priestore. Pre vás sú dôležité vektory `impl` a `impr`, ktoré obsahujú ľavú a pravú smerovú prenosovú funkciu (HRTF) zodpovedajúcu zdroju zvuku niekde pred poslucháčom v rovine jeho uší. HRTFs boli zaznamenané pri vzorkovacej frekvencii 44.1 kHz, takže na to, aby ste si mohli **CEZ SLÚCHADLÁ** vypočítať ako znejú, môžete použiť príkaz `soundsc([impr impl], 44100)`. Mali by ste počuť jediný klik (niečo ako tlesknutie), ktorý akoby prišiel odniekiaľ pred vami. Občas môžu nastať problémy so zvukovkou, ktoré sa prejavujú počutím viacerých kliknutí. V tom prípade skúste pridať na začiatok a koniec stimulu vektor núl `soundsc([zeros(30000,2); [impr impl]; zeros(30000,2)], 44100)`. Keď si vymeníte slúchadlá, zvuk by mal zaznieť z druhej strany (napr., ak najprv znel zľava, teraz by mal zniesť sprava; samozrejme, ak bol v strede, tak tam zostane). Pozn.: ak sa vám nezdá, že by ten zvuk prichádzal odniekiaľ pred vami, alebo zľava či sprava, možnože máte chabú zvukovú kartu resp. slúchadlá. Skúste si nájsť lepšie, príp. prísť za mnou (resp. môžete robiť veci aj bez toho, aby ste počúvali, čo ako znie). Dôležité je ale hlavne to, že **kedykoľvek máte niečo počúvať, máte to počúvať cez slúchadlá, nie z reproduktoru.**

V odovzdanom zadaní sa snažte zodpovedať na všetky otázky a priložiť aj matlabový kód, ktorým ste k výsledku dospeli.

1. V jednom grafe zobrazte prvých 20 milisekúnd ľavej (modrou) aj pravej (červenou) impulznej odozvy, tak ako je to ukázané na nasledovnom obrázku 5.
2. Impulzná odozva obsahuje priamu časť (prvý impulz, ktorý na obrázku hore prichádza zhruba v 6. milisekunde), ktorá charakterizuje ako sa zvuk šíril od zdroja priamo k ušiam, nasledovanú impulzmi zodpovedajúcimi odrazom od stien (na obrázku hore dorazí prvý odraz k ľavému uchu približne v 11. milisekunde). Všimnite si na obrázku 5, že v tomto konkrétnom príklade dorazil zvuk najprv k ľavému uchu a že bol v ľavom uchu aj silnejší než v pravom. Priamu časť impulznej odozvy budeme označovať D (direct sound), odrazy od stien označíme R (reverberation). Určite čas, kedy sa začína R časť odozvy, t.j., udajte čas tesne predtým, než do pravého alebo ľavého ucha dorazí prvý odraz od stien (ak prvý


odraz nedorazí do oboch uší v rovnaký čas, zvolte minimálnu hodnotu). Tento čas označte  $t_{cut}$  (v obrázku hore by to bolo as 11 milisekúnd).



Obrázok 5: Impulzná odozva


3. Použitím premennej  $t_{cut}$  rozdeľte vektor  $impr$  na vektor  $imprd$  (obsahujúci len D-časť odozvy) a  $imprl$  (obsahujúci len R-časť odozvy). Tak isto rozdeľte vektor  $impl$  na  $implr$  a  $impld$ . Vygenerujte obrázok podobný tomu z predošlej strany, ktorý ukazuje len D-časť ľavej a pravej odozvy.
4. Z D-časti ľavej a pravej odozvy určite ITD (interaaurálny časový rozdiel), t.j. rozdiel v čase, kedy zvuková vlna dorazila k ľavému a pravému uchu. Urobte to vizuálne, ako je to ukázané v nasledujúcom obrázku 6, ktorý je len zväčšením časti obrázku z úlohy 1 (napr. MATLABová funkcia `axis`).

V tomto prípade prirazil zvuk k ľavému uchu približne v čase 5,55 ms, a k pravému uchu v čase 6,25 ms, tzn., že ITD je približne  $-700 \mu\text{s}$  (pozitívne ITD znamená, že zvuk dorazil prv k pravému uchu). Presnejší odhad ITD získate tak, že nájdete maximum kroskorelácie (príkaz `xcorr` v matlabe). Uveďte odhad ITD získaný z obrázku aj ten získaný použitím kroskorelácie.



Obrázok 6: Zväčšená impulzná odozva

5. Priestorové prenosové funkcie (HRTF) boli získané pre zdroje zvuku nachádzajúce sa pred poslucháčom v úrovni uší. Na základe vypočítaného ITD určíte približne azimut, ktorému zodpovedá vaša HRTF (poznámka: zvuk sa šíri rýchlosťou 334 m/s) za predpokladu, že zdroj zvuku je od poslucháča vzdialený 1 meter a šírka hlavy poslucháča je 16 cm. Pod azimutom sa tu myslí uhol medzi nosom, stredom hlavy a zdrojom zvuku (červená čiara na nasledujúcom obrázku 7).



Obrázok 7: Azimut priestorovej prenosovej funkcie

6. Načítajte do MATLABu ľubovoľný zvuk (nie priveľmi dlhý, tak do 5 sekúnd), napr. príkazom wavread. Môže to byť nejaký zvuk stiahnutý webu, môžete nahráť seba počítat' od jedna po päť, alebo čokoľvek iné, napr. biely šum (dôležité: zvuk musí byť **MONO**, nie **STEREO**). Konvolúciou (conv) tohto zvuku s priestorovými prenosovými funkciami (impr, impl) získate priestorovú simuláciu tohto zvuku z určitej polohy (voči poslucháčovi) v špecifickej miestnosti, kde boli HRTFs nahrané (pozn: Na to, aby ste mohli konvolúciu použiť, musí byť zvuk navzorkovaný na 44.1 kHz, tak ako je to u HRTFs. Ak váš zvuk nemá správnu vzorkovaciu frekvenciu, prevzorkujte ho príkazom resample). Konvolúciou s priamymi časťami odoziev

(`imprd`, `impld`) získate simuláciu zvuku v bežeckej miestnosti. Príkazom `wavwrite` uložte vygenerovaný simulovaný zvuk (z reálnej aj bežeckej miestnosti). Pôvodný zvuk aj simulácie sprístupnite na webe. V zadaní mi odovzdajte webový odkaz na váš zvuk. Popíšte, aký je rozdiel, keď počúvate bežeckú simuláciu a simuláciu v reálnej miestnosti. Napr. odkiaľ (z akého azimutu, elevácie, vzdialenosti) zvuk prichádza?

## 7 Konekcionistické modelovanie: Grossbergova „shunting competitive network“ a vizuálne vnímanie

**Cieľom zadania** v oblasti konekcionistického modelovania je vypracovať zadanie zamerané na modelovanie kognitívnych systémov použitím neurónových sietí na jednoduchom príklade modelu vizuálneho systému.

**Úlohou študentov** v oblasti konekcionistického modelovania je odovzdať referát, ktorého obsahom je:


- Hlavička s názvom zadania (s označením časti), menami ľudí, ktorí ho vypracovali (tak ako pri projekte by ste mali robiť v skupinách maximálne 4 osoby), ročník, skupinu a podobne.
- V texte správy odpovedzte hlavne na otázky, ktoré sú vám zadané. Nezabudnite na grafy, ak sa od vás žiadajú. Niekedy sú otázky voľne uvedené v texte zadania. Takže si ho čítajte pozorne, a uistite sa, že ste zodpovedali na všetky otázky. Matlabovský kód, ktorý ste použili k vypracovaniu zadania, priložte na koniec zadania ako prílohu (teda nemiešajte ho s textom odpovedí).
- Z referátu vygenerujete PDF súbor (napr. použitím programu PDFCreator), ktorý je potrebné odovzdať elektronicky na zadanú e-mailovú adresu. V predmete e-mailovej správy uveďte skratku predmetu a mená autorov.

### Úvod do konekcionistického modelovania:

Cieľom tohto zadania je uviesť vás do problematiky konekcionistického modelovania (teda modelovania kognitívnych systémov použitím neurónových sietí) na jednoduchom príklade modelu vizuálneho systému. V tomto príklade budete simulovať konkurenčnú neurónovú sieť (competitive neural network) s paralelnou inhibíciou (with shunting inhibition) navrhnutú Grossbergom (1982a, 1982b, 1983). Simuláciami máte ukázať, že táto sieť podobne ako ľudský zrak, má vlastnosti „brightness contrast“ a „shift property“.

Shunting competitive network (ďalej len SCN) je jednovrstvová neurónová sieť, ktorá reprezentuje relatívne periférnu úroveň nášho vizuálneho systému. Aktivita jednotlivých neurónov je charakterizovaná premennými  $x_i$  a intenzita vstupných signálov (t.j., jasový profil toho, čo vidíme) je reprezentovaná premennými  $I_i$ . Ako je zrejmé z obrázku 8, v tejto neurónovej sieti pripadá na každý neurón jeden vstup, ktorý excituje neurón s rovnakým indexom ( $I_i$  a  $x_i$ ) ale inhibuje neuróny s rozdielnym indexom (indexy  $i$  a  $j$ ).





Obrázok 8: Náčrt spojení vstupov a neurónov v SCN

Aktivita každého neurónu v tejto neurónovej sieti je popísaná dynamicky nasledovnou rovnicou (1):

$$\frac{dx_i}{dt} = -Ax_i + (B - x_i)I_i - x_i \sum_{k \neq i} I_k$$

v ktorej je vyjadrené:


- $-Ax_i$  popisuje, ako spontánne klesá aktivita neurónu, ak naň nie je privedený žiaden vstup,
- $+(B-x_i)I_i$  hovorí, ako vstup aktivuje neaktivovanú časť neurónu ( $B$  je maximálna aktivácia),
- $-x_i \sum_{k \neq i} I_k$  hovorí, že aktivácia neurónu je potláčaná vstupmi ostatných neurónov (t.j., paralelná „shunting“ inhibícia).

### Shift vlastnosť (shift property):

„Shift property“ je niečo ako invariancia zrkovného systému voči celkovému jas. Teda táto vlastnosť hovorí, že nezávisle na celkovej intenzite svetla z prostredia si neurón uchováva celý svoj dynamický rozsah. Napr., ak označíme


$$L = \sum_{k \neq i} I_k$$

súčet inhibičných vstupov do neurónu (posledný výraz v rovnici 1), potom „shift property“ je vyjadrená nasledovným pozorovaním na obrázku 9 (Mingolla, 2002):



Obrázok 9: Shift property

Tento obrázok hovorí, že keď sa zvýši celková intenzita pozadia (krivka pre  $L_2$  v porovnaní s  $L_1$ ), zvýši sa aj prahová hodnota vstupnej intenzity  $I_i$ , pri ktorej daný neurón začne odpovedať (porovnaj ľavý dolný bod krivky  $L_2$  s ľavým dolným bodom krivky  $L_1$ ), a rovnako aj intenzita  $I_i$ , pri ktorej sa neurón saturuje (ľavý dolný bod krivky  $L_2$  v porovnaní s ľavým dolným bodom krivky  $L_1$ ). Nervová sústava, ktorá by túto „shift“ vlastnosť nemala, by sa mohla správať napr. ako na obrázku 10, teda pri vyššej intenzite svetla z pozadia by sa znížila maximálna aktivácia daného neurónu (a tým znížil jeho dynamický rozsah).



Obrázok 10: Nervová sústava bez shift vlastnosti

### Úloha 1:

Ukážte, že SCN je invariantná voči celkovému jasú prostredia. Nemusíte na to robiť žiadnu numerickú integráciu diferenciálnej rovnice. Stačí ak:

- z rovnice 1 vyjadríte ekvilibriovú hodnotu  $x_i$  (t.j., hodnotu pre  $dx/dt=0$ )
- zvolíte si vhodné hodnoty parametrov A a B (tieto parametre musia byť pozitívne)
- vytvoríte graf závislosti  $x_i$  na  $I_i$  pre niekoľko rôznych hodnôt L

*Pomôcky:*

- Shift property v sieti SCN je najlepšie viditeľná, ak je v grafe x-ová os zobrazená logaritmicke (skúste príkaz `semilogx` miesto `plot`).
- Skúste rôzne rozmiestnenia hodnôt L (napr. 10, 100, 1000 alebo 500, 600, 700).


### Brightness contract:

Vlastnosť jasového kontrastu (brightness contrast) hovorí, že to, ako jasný sa nám zdá určitý objekt (napr. kruh) nakreslený šedou, závisí na okolí pozorovaného objektu. Takže, ak máme dva šedé kruhy (obrázok 11), jeden obkolesený čiernou a druhý bielou, ten prvý kruh sa nám bude zdať svetlejší než ten druhý.



Obrázok 11: Brightness contrast

Ak obrázok hore trochu zjednodušíme, a to tak, že sa pozrieme na jeho jednorozmerný prierez jasového profilu, ten bude vyzerat' ako na obrázku dole vľavo, a ak uvažujeme, že tento profil je jasovým vstupom pre konečné množstvo (napr. 10 neurónov), potom vstupy týchto neurónov vyzerajú ako obrázku 12.



Obrázok 12: Jednorozmerný prierez jasového profilu

## Úloha 2:

Ukážte, že SCN, podobne ako ľudský zrakový systém, má vlastnosť jasového kontrastu. Tzn., ukážte, že aktivita neurónu, ktorého stred receptívneho poľa je vnútri kruhu sa mení, keď meníme intenzitu okolia kruhu. Zas stačí, keď na to použijete riešenie rovnice 1 v ekvilibriu.

*Poznámka:* Tento efekt by mal fungovať nezávisle na počte neurónov, ktoré použijete.

Všimnite si, že v SCN v skutočnosti nie je definovaná funkcia susednosti medzi neurónmi. Teda, čo sa týka vzájomného vplyvu, je pre neurón  $x_3$  rovnako dôležitý neurón  $x_3$  ako neurón  $x_8$ .

## Správa:

Výsledok experimentu popíšete v správe (textový dokument odovzdaný v elektronickej alebo vytlačenej forme), ktorá bude obsahovať minimálne časti:

- Úvod – stručný popis cieľov
- Popis a výsledky simulácií
- Diskusia – diskusia výsledkov experimentu

**Bonusová úloha:**

Efekt jasového kontrastu by u človeka fungoval aj v prípade, ak by obkolesené kruhy z obrázku hore boli priamo jeden vedľa druhého. Prejavil by sa tento efekt aj v SCN?

Pomôcka: Skúste simuláciu, kde naše dve jasové distribúcie privediete jednu vedľa druhej do tej istej neurónovej siete (napr. s 18 neurónmi).

## 8 Aditívne a shunting neurónové siete

**Cieľom zadania** v oblasti aditívnych a shunting neurónových sietí je vypracovať zadanie zamerané na simuláciu a vyšetrenie vlastností aditívnych a shunting neurónových sietí.

**Úlohou študentov** v oblasti aditívnych a shunting neurónových sietí je odovzdať referát, ktorého obsahom je:

- Hlavička s názvom zadania (s označením časti), menami ľudí, ktorí ho vypracovali (tak ako pri projekte by ste mali robiť v skupinách maximálne 4 osoby), ročník, skupinu a podobne.
- V texte správy odpovedzte hlavne na otázky, ktoré sú vám zadané. Nezabudnite na grafy, ak sa od vás žiadajú. Niekedy sú otázky voľne uvedené v texte zadania. Takže si ho čítajte pozorne, a uistite sa, že ste zodpovedali na všetky otázky. Matlabovský kód, ktorý ste použili k vypracovaniu zadania, priložte na koniec zadania ako prílohu (teda nemiešajte ho s textom odpovedí).
- Z referátu vygenerujete PDF súbor (napr. použitím programu PDFCreator), ktorý je potrebné odovzdať elektronicky na zadanú e-mailovú adresu. V predmete e-mailovej správy uveďte skratku predmetu a mená autorov.

### Postup:

Cieľom tohto zadania je simulovať a vyšetriť vlastnosti aditívnych a shunting neurónových sietí. Obe neurónové siete budú vo vašich štúdiách pozostávať z desiatich buniek. Rovnica pre doprednú aditívnu sieť sa dá zapísať nasledovne:

$$dx_i / dt = -Ax_i + BI_i - \sum_{k=i} I_k$$

kde  $I_i$  reprezentuje  $i$ -tú zložku vektora vstupného podnetu a  $x_i$  reprezentuje STM aktivity ( $i = 1, 2, \dots, 10$ ). Konštanty  $A$  a  $B$  sú parametrami siete, ktoré musia mať pozitívnu hodnotu. Rovnicu pre doprednú shunting sieť môžeme definovať nasledovne:

$$dx_i / dt = -Ax_i + (B - x_i)I_i - x_i \sum_{k=i} I_k$$

kde  $I_i$  reprezentuje  $i$ -tú zložku vektora vstupného podnetu a  $x_i$  reprezentuje STM aktivity ( $i = 1, 2, \dots, 10$ ). Konštanty  $A$  a  $B$  sú parametrami siete, ktoré musia mať pozitívnu hodnotu.

*Poznámka:* V zadaniach (a), (b), a (c) sa od vás nevyžaduje, aby ste čokoľvek simulovali (odpovede sa dajú nájsť analyticky). Očakáva sa ale, že na zodpovedanie úlohy (d) použijete simuláciu. A keďže sieť v úlohe (d) je komplikovaná, môže byť užitočné ak svoj simulačný kód odladíte na jednoduchšej sieti z úlohy (a) a až potom ju skúsíte rozšíriť na sieť z úlohy (d). Vo väčšine úloh sa od vás očakáva nájdenie konečnej (ekvilibriovej alebo asymptotickej) hodnoty aktivácie neurónov pre daný vstupný podnet. Keď budete používať simulácie, môže byť pre lepšie pochopenie parametrov siete užitočné vykresliť dynamiku siete (t.j., časový priebeh). Tieto grafy sa ale v odovzdanej správe nevyžadujú.

### Úloha 1:

Nech  $A = 0,1$  a  $B = 1$ . Inicializujte hodnoty  $x_i$  na nulu a na vstup prezentujte nasledovný pattern reprezentujúci vstupný podnet:  $I = \{ 1; 0,9; 0,8; 0,7; 0,6; 0,5; 0,4; 0,3; 0,2; 0,1 \}$ . Ukážte ako aditívna a shunting sieť odpovedajú na takýto pattern vykreslením grafu hodnôt  $x_i$  a  $X_i$  (t.j., skutočnej a normalizovanej STM aktivity)

$$X_i = x_i / \sum_{k=1}^{10} x_k$$

po tom, čo sieť dosiahne ekvilibrium.

Pre obe siete použite rovnaké hodnoty parametrov siete. Aká je horná a dolná medza rozsahu hodnôt aktivácie  $x_i$  pre takto zvolené sieťové parametre a pre ľubovoľné nezáporné hodnoty vstupov?

### Úloha 2:

Rýchlosť ekvilibrácie je rýchlosť s akou sa  $dx/dt$  mení v závislosti na zmenách hodnoty  $x$ , t.j.,  $d(dx/dt)/dx$ . To jest, táto veličina popisuje ako sa zmení rýchlosť, ktorou sa  $x$  blíži k svojej asymptotickej hodnote, keď sa zmení hodnota  $x$ . Alternatívne, v prípade, že ste analyticky vyriešili rovnice popisujúce našu sieť, potom rýchlosť ekvilibrácie zodpovedá konštante  $K$ , ktorou je prenasobené  $t$  v člene  $e^{-Kt}$ . Ktorý parameter riadi rýchlosť ekvilibrácie v našich dvoch sieťach? Závisí rýchlosť ekvilibrácie na vstupnom patterne?

### Úloha 3:

Modifikujte nasledovne aditívnu sieť:

$$dx_i / dt = -Ax_i + (B - x_i)I_i - \sum_{k=1} I_k$$

Aká je horná a dolná medza hodnôt  $x_i$  (opäť pre ľubovoľné nezáporné vstupy a malú hodnotu  $A$ ) pri takto upravenej aditívnej sieti? Ako táto zmena ovplyvní rýchlosť ekvibrácie? Ako sa v tomto prípade zmení asymptotická odozva siete na lineárny vstup použitý v úlohe 1?

#### Úloha 4:

Rozšírte shunting sieť o receptívne pole závislé na vzdialenosti:

$$dx_i / dt = -Ax_i + (B - x_i) \sum_{k=i-4}^{i+4} C_{ki} I_k - x_i \sum_{k=i-4}^{i+4} E_{ki} I_k$$

kde koeficienty receptívneho poľa  $C_{ki}$  a  $E_{ki}$  majú hodnoty:

$$C_{ki} = e^{-(k-i)^2/4}$$

$$E_{ki} = 0.5 \cdot e^{-(k-i)^2/16}$$

Vyneste do grafu hodnoty týchto koeficientov ako funkciu  $|k - i|$ . Do samostatných grafov vykreslite asymptotickú odozvu siete na nasledovné štyri 10-rozmerné vzorky dát:

$$A = \{ 0.1, 0.1, 0.1, 0.1, 0.1, 0.8, 0.8, 0.8, 0.8, 0.8 \}$$

$$B = \{ 0.1, 0.1, 0.1, 0.1, 0.8, 0.8, 0.1, 0.1, 0.1, 0.1 \}$$

$$C = \{ 0.1, 0.1, 0.8, 0.8, 0.8, 0.8, 0.8, 0.8, 0.1, 0.1 \}$$

$$D = \{ 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 1.0 \}$$

Ak by ste použili len tieto vstupy, do buniek na okraji by z časti ich receptívnych polí neprichádzali žiadne vstupy. Aby ste eliminovali tento typ „okrajových efektov“, môžete jednoducho rozšíriť vstupnú vzorku na oboch koncoch o štyri zložky, ktorým prisúdite hodnotu z daného konca vektora. Alternatívne môžete vstupné vzorky na koncoch prepojiť, t.j., spracovať ich ako keby boli prezentované na kružnici, kde zložka č. 1 susedí so zložkou č. 10.

Porovnajzte odozvu tejto siete s odozvou shunting siete bez koeficientov závislosti na vzdialenosti:

$$dx_i / dt = -Ax_i + (B - x_i) I_i - x_i \sum_{k=i} I_k$$

pre tie isté štyri vstupné vzorky. Popíšte rozdiel v kódovaní vzoriek (t.j., rozdiel v patterne/distribúcii asymptotických aktivácií neurálnej reprezentácie) spôsobený použitím koeficientov závislosti na vzdialenosti. Ktoré črty vstupného vektora sú zdôraznené pri použití týchto koeficientov?

## 9 Neurónová sieť OUTSTAR

**Cieľom zadania** v oblasti neurónovej siete OUTSTAR je vypracovať zadanie zamerané na simuláciu tejto siete s tromi okrajovými bunkami.

**Úlohou študentov** v oblasti neurónovej siete OUTSTAR je odovzdať referát, ktorého obsahom je:

- Hlavička s názvom zadania, menami ľudí, ktorí ho vypracovali (tak ako pri projekte by ste mali robiť v skupinách maximálne 4 osoby), ročník, skupinu a podobne.
- V texte správy odpovedzte hlavne na otázky, ktoré sú vám zadané. Nezabudnite na grafy, ak sa od vás žiadajú. Niekedy sú otázky voľne uvedené v texte zadania. Takže si ho čítajte pozorne, a uistite sa, že ste zodpovedali na všetky otázky. Matlabovský kód, ktorý ste použili k vypracovaniu zadania, priložte na koniec zadania ako prílohu (teda nemiešajte ho s textom odpovedí).
- Z referátu vygenerujete PDF súbor (napr. použitím programu PDFCreator), ktorý je potrebné odovzdať elektronicky na zadanú e-mailovú adresu. V predmete e-mailovej správy uveďte skratku predmetu a mená autorov.

### Postup:

Cieľom tohto zadania je simulovať neurónovú sieť Outstar s tromi okrajovými bunkami. Rovnice pre popis tejto siete môžeme zhrnúť nasledovne:

$$\begin{aligned}dx_0 / dt &= -A_0 x_0 + I_0 \\dx_i / dt &= -A x_i + B[x_0(t - \tau) - \Gamma]^+ z_{0i} + I_i \\dz_{0i} / dt &= -C z_{0i} + D[x_0(t - \tau) - \Gamma]^+ x_i\end{aligned}$$

kde  $x_0$  reprezentuje aktiváciu zdrojovej bunky,  $x_i$  sú aktivácie okrajových buniek ( $i = 1; 2; 3$ ) a  $z_{0i}$  reprezentujú LTM stopy. Konštanty  $A_0, A, B, C, D, \Gamma$  a  $\tau$  sú parametrami siete, ktoré môžu nadobúdať len nezáporné hodnoty. O signále  $I_0$  môžeme uvažovať ako o podmieňovanom stimule, zatiaľ čo signály  $I_i$  reprezentujú nepodmienené stimuly. Samplovací signál zdrojovej bunky  $S_0(t) = [x_0(t - \tau) - \Gamma]^+$  je definovaný prah-lineárnou funkciou  $[x]^+ = \max(x, 0)$

a okrajové bunky dosiahne s oneskorením  $\tau$ . Patternové premenné sú definované nasledovne:



$$\theta_i = I_i / \sum_{k=1}^3 I_k$$


$$X_i = x_i / \sum_{k=1}^3 x_k$$

$$Z_{0i} = z_{0i} / \sum_{k=1}^3 z_{0k}$$

*Poznámka:* parametre našich troch okrajových buniek sa zhodujú, takže simulujeme sieť „unbiased outstar“.

### Úloha 1:

Nech  $A_0 = 1$ ,  $A = 5$ ,  $B = C = D = 1$ ,  $\Gamma = 0,2$ , a  $\tau = 0,05$ . Predpokladajte, že sieť je inicializovaná nasledovne:  $x_0(0) = 0$ ,  $x_i(0) = \{0,6; 0,1; 0,3\}$  a  $z_{0i}(0) = \{0,7; 0,2; 0,1\}$ . Predpokladajte, že pre  $t \geq 0$  je na okrajové bunky privedený podnet s patternom  $I_i = \{0,1; 0,7; 0,2\}$  a pre  $t \geq 2$  sa na zdrojovú bunku privádza signál  $I_0 = 1$ , ako je zobrazené na obrázku 13. Analyticky určite hodnoty  $X_i(t)$  a  $Z_{0i}(t)$  pre  $t \rightarrow \infty$ .



Obrázok 13: Časový priebeh vstupného patternu

### Pomôcky k úlohe 1:

1. Všimnite si, že prvá rovnica nie je závislá na zvyšných rovniciach, a že pre  $t \rightarrow \infty$  má jednoduché riešenie, pretože  $I_0$  je pre  $t \geq 2$  konštantné.
2. Taktiež, keďže  $x_0(\infty)$  je známe,  $S_0(\infty)$  je tiež známe.

3. Keďže hodnoty  $I_i$  sú pre  $t \geq 0$  konštantné, rovnice pre  $dx_i/dt$  a  $dz_{0i}/dt$  sa, potom čo  $S_0$  nadobudne pozitívnu hodnotu, dajú zapísať ako (nehomogénny autonómny) systém lineárnych diferenciálnych rovníc.
4. Všetky vlastné hodnoty (eigenvalues) tohto systému majú záporné reálne zložky, čo znamená, že pre  $t \rightarrow \infty$  platí  $dx_i/dt = dz_{0i}/dt = 0$ . Alternatívne, môžete jednoducho použiť Teorému o učení Outstar.

### Úloha 2:

Numericky integrujte uvedené outstar rovnice pre čas  $t = 0$  až  $t = 10$  s  $\Delta t = 0,05$  a pre rovnaké hodnoty parametrov ako v úlohe 1. Vykreslite grafy patternových premenných  $\Theta_i(t)$ ,  $X_i(t)$  a  $Z_{0i}(t)$  pre  $t$  idúce od 0 po 10 (vytvorte tri grafy, jeden pre každé  $i$ ). Ako veľmi sa hodnoty  $X_i$  a  $Z_{0i}$  zhodujú s patternom stimulu  $\Theta_i$  v čase  $t = 10$ ? Do akej miery sa numerické hodnoty  $X_i$  a  $Z_{0i}$  zhodujú s analytickými hodnotami pre  $t \rightarrow \infty$  určenými v úlohe 1?

### Úloha 3:

Zmeňte parameter  $A$  z hodnoty 5 na 0,5 a zamyslite sa nad tým, aký efekt to môže mať na náš systém dlhodobej a krátkodobej pamäti. Potom simulujte outstar rovnice s týmto parametrom. Porovnajte výsledky s tými z úloh a a b. Predtým, než zhrniete svoje výsledky, pozrite sa na to, ako sa menia nenormalizované aj normalizované (patternové) premenné. Porovnajte tieto výsledky s podmienkami definovanými pre Teorému učenia Outstar.

## 10 Analýza psychofyzikálnych dát použitím modelu rozhodovania

**Cieľom zadania** v oblasti analýzy psychofyzikálnych dát použitím modelu rozhodovania je vypracovať zadanie zamerané vlastnosti štandardného psychofyzikálneho modelu rozhodovania.

**Úlohou študentov** v oblasti analýzy psychofyzikálnych dát použitím modelu rozhodovania je odovzdať referát, ktorého obsahom je:

- Hlavička s názvom zadania, menami ľudí, ktorí ho vypracovali (tak ako pri projekte by ste mali robiť v skupinách maximálne 4 osoby), ročník, skupinu a podobne.
- V texte správy odpovedzte hlavne na otázky, ktoré sú vám zadané. Nezabudnite na grafy, ak sa od vás žiadajú. Niekedy sú otázky voľne uvedené v texte zadania. Takže si ho čítajte pozorne, a uistite sa, že ste zodpovedali na všetky otázky. Matlabovský kód, ktorý ste použili k vypracovaniu zadania, priložte na koniec zadania ako prílohu (teda nemiešajte ho s textom odpovedí).
- Z referátu vygenerujete PDF súbor (napr. použitím programu PDFCreator), ktorý je potrebné odovzdať elektronicky na zadanú e-mailovú adresu. V predmete e-mailovej správy uveďte skratku predmetu a mená autorov.


### Postup:

Cieľom tohto projektu je oboznámiť sa s niekoľkými vlastnosťami štandardného psychofyzikálneho modelu rozhodovania, popísaného napr. autormi Macmillan and Creelman (1991) a Durlach (1968).

Pre definície pojmov a skratiek, vid' kapitolu „Teória optimálneho rozhodovania a modelovanie psychofyzikálnych dát“ v knihe Výpočtová a kognitívna neuroveda a doplňujúce údaje na stránke <http://sites.google.com/site/kogneuro/>

### Úloha 1:

Pre pravdepodobnostné distribučné funkcie na obrázku 14, vypočítajte hodnoty  $P_D$  a  $P_F$  pre  $C = 0, 1$  a  $2$ , a vykreslite ROC krivku pre tieto funkcie.



Obrázok 14: Pravdepodobnostné distribučné funkcie

### Úloha 2:

Nech  $Q$  je pravdepodobnosť správnej odpovede. Odvoďte vzťah pre výpočet  $Q$  na základe apriórnych pravdepodobností prezentácie stimulov  $P(S_1)$ ,  $P(S_2)$  a na základe pravdepodobností hit rate a false alarm rate  $P_D$  a  $P_F$ .

### Úloha 3:

V štyri experimentoch (E1 až E4), ktoré používali rovnaké stimuly  $S_1$  a  $S_2$ , boli získané dáta uvedené na obrázku 15. V každej matici zodpovedá položka v  $j$ -tom riadku a  $i$ -tom stĺpci počtu, koľkokrát stimul  $S_j$  vyvolal odpoveď  $R_i$ .

E1	$R_1$	$R_2$	E2	$R_1$	$R_2$
$S_1$	32	166	$S_1$	97	101
$S_2$	8	197	$S_2$	25	180
$S_1$	152	48	$S_1$	188	17
$S_2$	84	119	$S_2$	174	24
E3			E4		

Obrázok 15: Dáta štyroch experimentov

- a) Vykreslite štyri body na ROC krivke, ktoré zodpovedajú týmto dátam.
- b) Vypočítajte hodnoty PD a PF, ZD a ZF, ako aj hodnoty indexu citlivosti  $d'$  a strannosti  $\beta$ . Uvažujte, že v každom experimente bol subjektom iný človek. Ktorý z poslucháčov bol najcitlivejší? A ktorý bol najnestrannejší?

## 11 Multivariačná analýza patternov dát funkčnej magnetickej rezonancie

**Cieľom zadania** v oblasti multivariačnej analýzy patternov (anglicky multivariate pattern analysis, skratka MVPA) je vypracovať zadanie zamerané na analýzu patternov dát získaných pomocou zobrazovania funkčnou magneticou rezonanciou, anglicky functional magnetic resonance imaging, skratka fMRI).

**Úlohou študentov** v oblasti multivariačnej analýzy patternov je odovzdať referát, ktorého obsahom je:

- Hlavička s názvom zadania, menami ľudí, ktorí ho vypracovali (tak ako pri projekte by ste mali robiť v skupinách maximálne 4 osoby), ročník, skupinu a podobne.
- V texte správy odpovedzte hlavne na otázky, ktoré sú vám zadané. Nezabudnite na grafy, ak sa od vás žiadajú. Niekedy sú otázky voľne uvedené v texte zadania. Takže si ho čítajte pozorne, a uistite sa, že ste zodpovedali na všetky otázky. Matlabovský kód, ktorý ste použili k vypracovaniu zadania, priložte na koniec zadania ako prílohu (teda nemiešajte ho s textom odpovedí).
- Z referátu vygenerujete PDF súbor (napr. použitím programu PDFCreator), ktorý je potrebné odovzdať elektronicky na zadanú e-mailovú adresu. V predmete e-mailovej správy uveďte skratku predmetu a mená autorov.

### Postup:

Nainštalujte a nastavte nástroj CosmoMVPA (Oosterhof et al., 2016) v Matlabe a analyzujte súbor údajov fMRI. Konkrétne vykonajte korelačnú analýzu metódou split half na dekódovanie mozgovej aktivity.

### Cosmo MVPA nastavenie:

Ak je Git už nainštalovaný, postupujte podľa nasledujúcich krokov:

1. Presuňte sa do adresára, kde bude nainštalovaný MVPA.
2. Stiahnite kód Cosmo MVPA do počítača.

```
git clone https://github.com/CoSMoMVPA/CoSMoMVPA.git
```

3. Aktualizujte kód. Všimnite si, že musíte byť v adresári, do ktorého bol kód stiahnutý.

```
git checkout master
```

```
git pull origin master
```

4. Tým sa automaticky nastaví cesty a ďalšie nastavenia pre matlab. Ak je matlab spustený z klastra, nemusí to fungovať.

```
make -C CoSMoMVPA install
```

*Poznámka:* Ak vyššie uvedený príkaz nebol úspešný, môžete ho nastaviť ručne.

Ak nepoužívate Git, postupujte podľa nasledujúcich krokov:

1. Stiahnite si kód z archívu zip. Rozbaľte ho.
2. Otvorte matlab, prejdite do adresára, z ktorého bol stiahnutý program mvpa.
3. Pridajte priečinky a podpriečinky do cesty, aby bolo možné pristupovať k priečinku mvpa odkiaľkoľvek.
4. Pridajte adresáre zdrojového kódu do cesty Matlabu zmenou adresára na adresár CoSMoMVPA /mvpa

5. Spustite

```
cosmo_set_path
```

*Poznámka:* Ak sa vyskytne chyba, skúste pridať priečinky a podpriečinky mvpa do cesty v matlabe (kliknite pravým tlačidlom myši na priečink a vyberte Pridať do cesty - > Vybrané priečinky a podpriečinky).

Spustite znova:

```
cosmo_set_path
```

6. Príkazom savepath sa všetky cesty natrvalo uložia do súboru pathdef.m.

*Poznámka:* Ak sa objaví chyba, znamená to, že sa nepodarilo nájsť súbor pathdef.m, ktorý sa nachádza v predvolených zložkách inštalácie matlabu. Môže sa to stať aj vtedy, keď matlab beží na klastri. V tomto prípade:

Vytvorte prázdny nový súbor pathdef.m v priečinku CoSMoMVPA/mvpa/.

Príkazom savepath

```
/autofs/space/aisti_001/users/FD12/MVPA_KK/CoSMoMVPA/mvpa/pathdef.m
```

sa všetky cesty natrvalo uložia do súboru pathdef.m.

7. Potom skontrolujte, či je všetko správne nastavené:

```
cosmo_wtf
```

*Poznámka:* Toto by malo poskytnúť správu o dostupných informáciách o systéme.

### Dataset:

Stiahnite si súbor údajov z adresy: <http://www.cosmomvpa.org/datadb-v0.3.zip>

Rozbaľte a uložte súbor do priečinka projektu.

### Korelačná analýza:

Korelácia je štatistická miera, ktorá vyjadruje, do akej miery sú dve premenné lineárne závislé (čo znamená, že sa ich hodnoty menia spoločne).


Korelačné koeficienty sú ukazovatele sily lineárneho vzťahu medzi dvoma rôznymi premennými  $x$  a  $y$ .

Lineárny korelačný koeficient, ktorý je väčší ako nula, znamená pozitívny vzťah. Hodnota, ktorá je menšia ako nula, znamená negatívny vzťah.

Možný rozsah hodnôt korelačného koeficientu je od  $-1,0$  do  $1,0$ .

Ak je korelačný koeficient väčší ako nula, ide o kladný vzťah. Naopak, ak je hodnota menšia ako nula, ide o negatívny vzťah (obrázok 16).

Pri interpretácii korelácie je dôležité mať na pamäti, že to, že dve premenné sú korelované, neznamená, že jedna spôsobuje druhú.



Obrázok 16: Typy korelácie

### Úloha 1:

Korelačný koeficient medzi dvoma premennými  $x$  a  $y$  je 0. Ako spolu tieto premenné súvisia?



## Úvod do multivariačnej analýzy patternov (MVPA):


Pri analýze údajov fMRI sa bežne vykonáva jednorozmerná analýza, pri ktorej sa aktivita neurónov v jednotlivých voxeloch (podobne ako pixel na obrázku) analyzuje samostatne a spriemeruje sa v rámci celého mozgu alebo vybranej oblasti záujmu (ROI).

Z toho nevieme popísať vzťah medzi jednotlivými voxelmi. V MVPA sa skúma aj vzťah medzi voxelmi, čím sa zvyšuje možnosť nájsť opakovateľné vzory v mozgovej aktivite, a teda ich mapovať na správanie.

V tomto zadaní sa zameriavame najmä na jednu takúto techniku nazývanú korelačná analýza metódou rozdelenia na polovice (half split). Pri tejto metóde sa dané údaje (riadok ako rôzne vzorky a stĺpec ako rôzne znaky) pre každý stav (triedu, kategóriu) rozdelia na dve polovice. Potom sa zisťujú korelácie medzi týmito dvoma polovicami a medzi nimi pre každú podmienku.

Prvá možnosť spočíva v rozdelení údajov na dve polovice (napr. nepárne a párne série) a v odhade odozvy pre každú kategóriu, voxel a polovicu samostatne. Ak oblasť reprezentuje kategórie distribuovaným spôsobom (cez voxely), potom korelácie (cez voxely) zodpovedajúcich kategórií môžu byť vyššie ako korelácie nezodpovedajúcich kategórií. Ak kategórie nie sú reprezentované takýmto spôsobom, neočakávali by sme žiadne rozdiely medzi koreláciami zodpovedajúcich a nezodpovedajúcich kategórií.

Pre korelácie rozdelené na polovicu sú potrebné dva kusy (napr. nepárne a párne behy) so zhodnými cieľmi. Ak sa tak ešte nestalo, údaje sa rozdelia na dva časti (horný a dolný). Každý vzor v jednej polovici sa koreluje s každým vzorom v druhej polovici, čím sa vytvorí korelačná matica  $N \times N$  (pričom  $N$  je počet cieľov). Hodnoty v tejto korelačnej matici sa vážia kladne, ak sú na diagonále (zhodný cieľ v oboch poloviciach), a záporne v ostatných prípadoch tak, aby sa všetky váhy spolu sčítali do nuly, čím sa získa vážená korelačná matica (vpravo dole). Ak je súčet všetkých prvkov v tejto matici kladný, znamená to, že vzory obsahujú informácie špecifické pre cieľ.



Obrázok 17: Korelačná analýza metódou rozdelenia na polovice

## Úloha 2 (analýza jedného subjektu):

Pomocou súboru údajov cosmo\_fmri načítajte t-štatistiky pre „nepárne“ a „párne“ behy pre s01 (glm\_T\_stats\_odd.nii a glm\_T\_stats\_even.nii), pričom zadajte masku VT. Na pripomenutie, označenia podnetov pre každý beh štúdie fMRI boli opica, lemur, kačica divá, bojovnica, beruška a lunamoht - v tomto poradí. Tieto dva súbory nifti obsahujú súhrnné štatistiky (T štatistiky z analýzy všeobecného lineárneho modelu, GLM) pre každý stimul pre nepárne, resp. párne behy.

Na každú polovicu použite masku VT a potom vypočítajte všetky párové korelácie medzi vzormi v prvej a druhej polovici, čím vznikne matica 6x6. Po použití Fisherovej transformácie vypočítajte priemerný rozdiel medzi hodnotami na diagonále a hodnotami mimo diagonály. Ak neexistuje žiadna informácia o kategórii, očakával by sa nulový rozdiel.

Pozrite sa na súbor „Split\_Half\_Single\_Subject.m“ a na požadované miesta doplňte úryvky kódu a vygenerujte výsledky/grafy. Ďalej podrobne prediskutujte výsledky.

## Úloha 3 (skupinová analýza):

Rovnako ako v predchádzajúcej úlohe vypočítajte rozdiel medzi priemerom na diagonále a na nepárnej diagonále Fisherovej transformovanej korelácie. Tentoraz to urobte pre každý subjekt a pre tri oblasti záujmu (region of interest, ROI), a teda ev, vt, mozog. Pre každú ROI zhromaždíte rozdiel korelácií pre každý subjekt a uložte ich, potom vykonajte

jednovýberový t-test proti nule, aby ste získali p-hodnotu proti nulovej hypotéze o neexistencii korelačnej informácie v každej oblasti. Pri vykonávaní týchto výpočtov použite vnorenú slučku for (nad ROI vo vonkajšej slučke a nad subjektmi vo vnútornej slučke).

Odvolaajte sa na súbor „Split\_Half\_Group.m“ a v prípade potreby doplňte úryvky kódu a vygenerujte výsledky/grafy. Ďalej podrobne prediskutujte výsledky.

Odošlite vyplnený kód, výsledky, grafy a ich podrobnú interpretáciu.

### **Bonusová úloha:**

Natrénujte klasifikátor (SVM, LDA alebo iný) na kategorizáciu tried vo vzorke údajov použitej predtým. A tiež sa pokúste vykonať krížovú validáciu.

## 12 Analýza EEG záznamov pomocou funkcie koherencie alebo metód strojového učenia

**Cieľom zadania** v oblasti analýzy EEG záznamov je vypracovať zadanie zamerané na vizuálne vs. sluchové ovplyvňovanie pozornosti a sluchové priestorové rozlišovanie napríklad pomocou funkcie koherencie alebo metód strojového učenia.

**Úlohou študentov** v oblasti analýzy EEG záznamov je odovzдание referátu, ktorého obsahom je:

- Hlavička s názvom zadania, menami ľudí, ktorí ho vypracovali (tak ako pri projekte by ste mali robiť v skupinách maximálne 4 osoby), ročník, skupinu a podobne.
- V texte správy odpovedzte hlavne na otázky, ktoré sú vám zadané. Nezabudnite na grafy, ak sa od vás žiadajú. Niekedy sú otázky voľne uvedené v texte zadania. Takže si ho čítajte pozorne, a uistite sa, že ste zodpovedali na všetky otázky. Matlabovský kód, ktorý ste použili k vypracovaniu zadania, priložte na koniec zadania ako prílohu (teda nemiešajte ho s textom odpovedí).
- Z referátu vygenerujete PDF súbor (napr. použitím programu PDFCreator), ktorý je potrebné odovzdať elektronicky na zadanú e-mailovú adresu. V predmete e-mailovej správy uveďte skratku predmetu a mená autorov.

### Úvod do EEG:


Elektroencefalografia (EEG) predstavuje meranie synaptických potenciálov nervových buniek mozgu. Snímacie elektródy môžu byť umiestené na povrchu kože hlavy (Luck, 2014).

Pre niektoré klinické aplikácie postačuje jedna aktívna elektróda (popri jednej referenčnej a uzemňovacej elektródy). Pre väčšinu štúdií je však potrebné použitie viacerých elektród – výskumníci navrhli a testovali riešenia od 32 aktívnych elektród až po 256 aktívnych elektród. Vysoký počet elektród však vedie aj k vyšším nákladom a náročnejšej analýze údajov, ale tiež k horšej kvalite dát.


Na obrázku 18 je príklad EEG záznamu z jednej vybranej elektródy.

Na obrázku 19 je príklad EEG záznamu z jednej vybranej elektródy narušený hlukom alebo auditóriom.


Na obrázku 20 je príklad EEG záznamu z jednej vybranej elektródy narušený vizuálnymi podnetmi.



Obrázok 18: Príklad EEG záznamu z jednej elektródy v časovej doméne



Obrázok 19: Príklad EEG záznamu z jednej vybranej elektródy narušený hlukom alebo auditóriom



Obrázok 20: Príklad EEG záznamu z jednej elektródy v časovej doméne narušený vizuálnym podnetom

### Popis dát získaných z experimentu:

Sluchové a vizuálne podnety v experimente sú podrobne popísané v štúdií Kopčo et al. (2021). Experiment bol riadený s rozšírením Psychtoolbox 3. Zvukové podnety boli prezentované pomocou slúchadiel ER-1 s vložkou Etymotic Research (Elk Grove Village, IL) pripojených k systému Datapixx (VPixx Technologies, Saint-Bruno, QC).


Počas experimentu subjekty sedeli v odzvučenej kabínke (Eckel Laboratories). Experiment pozostával z pokusov vizuálnych a sluchových podnetov. V každom pokuse bol cieľ pozostávajúci z dvoch zvukov prezentovaných z mierne odlišných miest a úlohou poslucháčov bolo rozlíšiť smer zmeny cieľového miesta.

Dáta tvoria EEG záznamy 14 subjektov, u ktorých sa sledovalo 32 podnetov – 16 zrakových a 16 sluchových. Každý záznam bol meraný pomocou 32 elektród a mal dĺžku 512 časových jednotiek.

Dáta sú v súbore reprezentované v štruktúre, v ktorej je dimenzia dát jedného subjektu  
(32, 512, 32),

Pričom prvá zložka je dimenzia elektród, druhá EEG záznam príslušnej elektródy, tretia podmienky. Prvých 16 podmienok je pre vizuálny podnet, 8 pravá fixácia, 8 ľavá fixácia. Podobne pre ďalších 16 zvukových podnetov.

Obrázok 21 ilustruje, ako sú jednotlivé elektródy usporiadané v datasete, teda prvá elektróda je FP1, druhá AF3 a podobne.



Obrázok 21: Popis elektród v datasete

### Funkcia koherencie:

Funkcia koherencie sa používa na analýzu konektivity medzi elektródami, teda na kvantifikáciu štatistických závislostí medzi EEG záznamami z rôznych elektród. Funkcia koherencie má takýto tvar:

$$K_{xy}(f) = \frac{S_{xy}(f)}{\sqrt{S_{xx}(f)S_{yy}(f)}}$$

Pričom  $S_{xx}(f)$  a  $S_{yy}(f)$  sú spektrálne hustoty dvoch signálov na dvoch rôznych elektródach a  $S_{xy}(f)$  je krížová spektrálna hustota, ktorá spriemeruje výsledok na dvoch signáloch pomocou Welchovej metódy. Samotná koherencia je počítaná ako druhá mocnina absolútnej hodnoty funkcie koherencie a dáva hodnoty z intervalu  $[0, 1]$ . 0 znamená, že medzi elektródami nie je žiadna závislosť, 1 znamená, že sú úplne závislé.

## Úloha 1:

Preskúmať vplyv exogénnej pozornosti na priestorovú diskrimináciu (napríklad pomocou funkcie koherencie) pre:

- vizuálne verzus sluchové podnety,
- pohľad upretý na neutrálne miesto,
- v plne simulovanom virtuálnom sluchovom prostredí,
- meranie EEG na vyšetrenie neurónových korelátov.

Predpokladáme, že automatická pozornosť priťahovaná podnetom, nielen smerom pohľadu, ovplyvňuje priestorové rozlišovanie. Ďalej môžeme predpokladať, že:

- platné podnety budú viesť k zlepšeniu výkonu,
- platné zrakové podnety budú užitočnejšie ako platné sluchové podnety (aj bez zmien pohľadu), kvôli vyššej zrakovej priestorovej ostrosti,
- neplatné zrakové a sluchové podnety sú podobne rozptyľujúce.

## Úloha 2:

Skonstruujte model strojového učenia (pomocou algoritmov rozhodovacích stromov, booleovskej formuly, rozhodovacieho zoznamu, neurónovej siete alebo iných metód) na základe tréningovej množiny s najviac 80 % datasetu s vybraným cieľovým atribútom (napríklad, či je EEG záznam ovplyvnený zvukovým alebo zrakovým podnetom, zľava alebo sprava a podobne).

Vyberte si aspoň dva vhodné algoritmy. Použite vybrané algoritmy na konštrukciu modelu na základe tréningovej množiny, spracujte výsledky a skúsenosti.

Popis riešenia problému má pozostávať z nasledujúcich častí:

- popis dát: aké vlastnosti majú dáta,
- popis použitých algoritmov: ako reprezentujú svoje hypotézy, ako fungujú,
- popis evaluačných kritérií: ako a čím ste merali kvalitu získaných výsledkov - na osobitnej testovacej množine, pomocou cross-validation, a podobne,
- popis výsledkov: získané výsledky a ich presnosť, porovnanie úspešnosti použitých algoritmov, prezentácia výsledkov pomocou tabuliek/grafov,
- interpretácia výsledkov vlastnými slovami, porovnanie výsledkov s očakávaniami: prečo bol ten-ktorý algoritmus lepší/horší, diskusia (napr. porovnať zrozumiteľnosť nájdených riešení, výpočtovú rýchlosť jednotlivých algoritmov, návrhy na možné vylepšenia).



## 13 Všeobecné návody k projektom

V predchádzajúcich 12 kapitolách sme prezentovali zadania na vybrané témy v oblasti kognitívnej a výpočtovej neurovedy. Na základe skúseností z výučby sme spracovali aj túto kapitolu venovanú všeobecným návodom, ktoré nie sú závislé od konkrétnej témy.

Jednou z vašich úloh v predmete Úvod do neurovied a Matlab a neurokognícia je vypracovať projekt na zvolenú tému. Cieľom tohto projektu je precvičiť si:

- vyhľadávanie vedeckých informácií na webe,
- schopnosť implementovať matematický model na počítači,
- modelovanie (napríklad, krátkou simuláciu, ktorou otestujete, čo sa deje pri zmene parametrov modelu),
- prácu s textom, schopnosť čítať a analyzovať vedecký text, a
- písanie gramaticky korektných a štylisticky jasných vedeckých dokumentov.

Zároveň Vám projekt dáva príležitosť zoznámiť sa hlbšie so zvolenou témou z oblasti neurálnych a kognitívnych vied.

Projekty môžu byť vo všeobecnosti zamerané na dva výstupy:

1. napísať esej / urobiť rešerš ku konkrétnemu problému súvisiacemu s výpočtovou a kognitívnu neurovedou.
2. implementovať (a prípadne aj rozšíriť) výpočtový alebo neurálny model ľubovoľného neurálneho procesu alebo kognitívnej funkcie a otestovať ho na vybraných fyziologických alebo psychologických dátach.

V nasledujúcej časti uvádzame všeobecné príklady projektov s odkazmi na články, ktoré si môžete na svoj projekt zvoliť.

### Rešerše (eseje)

Pri rešerši sa od vás očakáva, že si zvolíte tému, ktorá vás osobne zaujíma, a že na túto tému napíšete 5-10 stranovú esej prípadne rešerš. Rozdiel medzi týmito dvomi formami je v tom, že rešerš nevyžaduje veľa vlastného príspevku, keďže zhŕňa výsledky získané z rôznych zdrojov (ktorých by malo byť relatívne viac – aspoň 3). Na druhej strane pri eseji sa očakáva, že okrem zhrnutia nejakých článkov bude obsahovať aj vlastný pohľad autora (takže citovanej literatúry môže byť menej). V ideálnom prípade eseje by ste mali k zvolenej téme nájsť približne dva až tri články, ktoré sa na ňu dívajú z trocha iného pohľadu. V eseji by ste potom

mali roanalyzovať, v čom sa jednotlivé články zhodujú, v čom nie, a v diskusii sa pokúsiť o vlastné hodnotenie. Takže Vaša esej môže mať štyri časti:

- **Prehľad témy**, ktorý širšie uvedie zvolenú vednú oblasť a priblíži konkrétnu tému, ktorú ste si zvolili.
- **Prehľad/sumár výsledkov** z článkov ktoré ste si zvolili, bez porovnávania a hodnotenia.
- **Analýza** by mala obsahovať porovnanie toho, v čom sa články zhodujú a v čom rozchádzajú.
- **Diskusia**, v ktorej by ste sa mali pokúsiť prepojiť výsledky svojej analýzy so širším kontextom daného odboru, zhrnúť Vaše výsledky, a prípadne navrhnúť budúce smerovanie.

Okrem toho by Váš článok mal mať Abstrakt, Úvod, Záver a Zoznam literatúry, tak ako štandardné články.

**Dôležité:** Esej ako aj rešerš môže obsahovať len vami napísaný text. Ak text odniekiaľ doslovne preberáte alebo citujete, musíte uviesť odkiaľ a musíte ho napísať v úvodzovkách. Napr., váš článok môže obsahovať nasledujúcu stať: Juraj Jánošík v roku 1748 pred skokom na hák vykrikol „Keď ste si ma upiekli...“. Ak vo vašom článku zhŕňate informácie z cudzieho článku, musíte to tiež patrične označiť. Napr. „Konček (2003) tvrdí, že zem je guľatá...“ pričom na konci vášho článku v Zozname literatúry budete mať položku: „Konček, P. (2003) Moderná teória o tvare zemského povrchu. Košice: Vydavateľstvo ELFA“.

### **Ako (začať) hľadať vedecké informácie na webe**

Dnes je drvivá väčšina vedeckých informácií dostupná na webe, časť bezplatne a časť za určitý poplatok. Naša univerzita má predplatené niektoré databázy. Navyiac, v Laboratóriu vnímania a kognície máme prístup takmer neobmedzený. Základné zdroje, ktoré by ste mali použiť vy pri vyhľadávaní literatúry:

- Elektronické zdroje, knihy a časopisy dostupné v Laboratóriu vnímania a kognície (Bookshelf na <https://pcl.upjs.sk/>).
- [MIT Encyklopédia kognitívnych vied](#) (dostupná len s heslom) – táto encyklopédia obsahuje základné informácie na takmer každú relevantnú tému.
- [www.google.com](http://www.google.com) alebo ešte lepšie [scholar.google.com](http://scholar.google.com) resp. [books.google.com](http://books.google.com) – napr. ak vás zaujíma, ako funguje tzv. krátkodobá pamäť, skúste do googla zadať heslo connectionist model of working memory a dostanete sa k hromade článkov.

- [Web of Science](#) je databáza, ktorá obsahuje odkazy na veľké množstvo článkov aj s obojsmernými prepojeniami. T.j., máte z nej možnosť zistiť nie len ktoré články sú citované v danom článku, ale aj ktoré články citovali daný článok.
- <http://www.ncbi.nlm.nih.gov/PubMed/> – MEDLINE je databáza biomedicínskych článkov obsahujúca napr. abstrakty článkov.
- [Behavioral and Brain Sciences](#) – voľne prístupný časopis s článkami na mnohé témy týkajúce sa neurálnych a kognitívnych vied.
- <http://www.upjs.sk/pracoviska/univerzitna-kniznica/katalogy/> – informácie o databázach prístupných cez UPJS.
- [MIT CogNet](#) – viac než by ste kedy mohli chcieť o fungovaní mozgu vedieť (platená webstránka)

### **Témy esejí, rešerší a projektov:**

V roku 2014 a 2015 sme organizovali workshopy “Cognitive neuroscience of auditory and cross-modal perception” ([Workshop2014](#) a [Workshop2015](#)). Každý prednášajúci k téme pripravil prednášky a zadanie, ktoré môže byť základom vašej práce.

Pripájame aj ďalšie návrhy na eseje. Ku každej uvádzam článok, z ktorého môžete pri eseji vychádzať.

**Teórie o fungovaní ľudskeho mozgu.** Vo vašej eseji sa môžete zamyslieť nad otázkami ako: Ako majú vyzeráť dobré teórie o fungovaní ľudskeho mozgu. Aké experimenty (behaviorálne alebo fyziologické) nám môžu pomôcť pri snahe pochopiť fungovanie mozgu. Ako je vývoj teórií o ľudskej mysli ovplyvnený technickým pokrokom.

Literatúra: Churchland P. S. (1986) [Theories of Brain Function](#) (Kapitola 10 knihy Neurophilosophy: Toward a Unified Science of the Mind-Brain).

Daugman J. G. (1990) [Brain Metaphor and Brain Theory](#) (Kapitola 2 knihy Computational Neuroscience od Erica Schwartza)

**Teórie o fungovaní ľudskej pamäti a učenia.** Témami vašich esejí môže byť napr.: Aké neurálne modely učenia existujú. Aké sú základné teórie o fungovaní pamäti. Je pamäť skôr exemplárna alebo prototypická?

Literatúra: Carpenter GA [Neural-network models of learning and memory: leading questions and an emerging framework](#). TRENDS COGN SCI 5 (3): 114-118 MAR 2001

**Sluchové vnímanie.** Aká je úloha priestoru a času pri počúvaní? Ako je organizovaný sluchový kortex?

Literatúra: Shamma S [On the role of space and time in auditory processing](#), TRENDS in Cognitive Sciences Vol. 5 No. 8, August 2001.

Rauschecker J.P. and Tian B. [Mechanisms and streams for processing of “what” and “where” in auditory cortex](#). PNAS 97, 11800–11806

**Ako môžeme študovať ľudský mozog použitím zobrazovacích techník? A ako ho môžeme modelovať?**

Horwitz B, Tagamets MA, McIntosh AR. [Neural modeling, functional brain imaging, and cognition](#). Trends in Cognitive Science 3:91-98, 1999.

Grossberg, S. (2003). [How does the cerebral cortex work? Development, learning, attention, and 3D vision by laminar circuits of visual cortex](#). Behavioral and Cognitive Neuroscience Reviews, in press

**Ako sa v mozgu spracúva reč? Ako sa tento proces dá modelovať neurónovou sieťou?**

McClelland, J.L. & Rumelhart, D.E. (1981). [An interactive activation model of context effects in letter perception: Part 1](#). Psychological Review, 5, 375-407.

**Ako sa v mozgu reprezentujú objekty, ktoré vnímame zrakom?**

Edelman S. (1998) [Representation is representation of similarities](#). Behavioral and Brain Sciences, Volume 21, Issue 04. August 1998. pp449-467

**Ďalšie možné témy:**

Sluch:

- Prehľad tém súčasného výskumu si môžete spraviť napr. na základe [príspevkov z nedávnej konferencie](#)
- Teórie vnímania výšky tónu (pitch perception)
- Súčasná hypotéza o organizácii primárneho sluchového kortexu
- Vnímanie vzdialenosti zdroja zvuku
- Prehľad typov buniek v kochleárnom jadre

Zrak:

- Reprezentácia farby vo vizuálnej dráhe
- Teórie funkcie jednotlivých vrstiev neurónov (laminárnej organizácie) v primárnej vizuálnej oblasti (V1, 17)
- Vnímanie trojrozmerného priestoru

Metódy:

- Prehľad súčasných metód optického zobrazovania

## **Modely:**

Druhou alternatívou pre váš projekt je implementovať výpočtový model nejakej kognitívnej funkcie resp. neurálneho procesu, a porovnať vašu implementáciu s výsledkami popísanými v nejakom článku. Takže postup bude taký, že si nájdete článok (viac článkov), v ktorom je model popísaný. Vy tento model implementujete (najskôr v MATLABe) a vygenerujete grafy, ktoré by sa mali podobieť tomu, čo je popísané v zvolenom článku. Modely sa veľmi líšia svojou implementačnou náročnosťou a pri hodnotení k tomu budem prihliadať. Takže, potenciálne môže človek dostať viac bodov za nie úplne implementovaný zložitý model než za jednoduchý model, ktorý otestoval na mnohých dátach.

Príklad modelu, ktoré si môžete zvoliť pre implementáciu je napríklad Colburnov model toho, ako nám binaurálny sluch pomáha pri počúvaní zvukov v zašumenom prostredí (Kopčo a Shinn-Cunningham, 2003).

## **Návrh projektu:**

Z návrhu projektu musí byť jasné, že ste sa na danú tému už pozreli, a že aspoň zhruba viete, z akých zdrojov budete čerpať. Takže, dobrý návrh bude okrem názvu témy obsahovať aj jeden odstavec (4-5 viet) s popisom toho, o čo sa v projekte bude jednať, čo je cieľom projektu, a z čoho (akých zdrojov) budete čerpať.

Tie zdroje nemusia byť finálne, ale každý z vás by v rámci návrhu mal uviesť aj aspoň tri odkazy na články (plnú citáciu: Autor, Rok, Názov, Časopis/kniha a linku), ktoré ste na danú tému našli a z ktorých chcete vychádzať.

## Záver

Výpočtová a kognitívna neuroveda patrí medzi podoblasť neurovedy, ktorá je zameraná na štúdium spracovania informácií v ľudskej a zvieracej nervovej sústave, ako aj na teoretický popis mozgu a mysle.

V tejto vysokoškolskej učebnici sme prezentovali viacero zadaní, ktoré poskytujú prehľad o metódach používaných vo výpočtovej a kognitívnej neurovede, s dôrazom na matematické modelovanie a na behaviorálne štúdium kognitívnych procesov.

Tieto zadania sú spracované v štruktúre ciele, úlohy, poznámky a pomôcky, pričom niektoré časti sú ilustrované pomocou krátkych príkazov v jazyku MATLAB. Súčasťou práce je aj viacero obrázkov, ktoré dopĺňajú text učebnice.

V záverečnej časti sme prezentovali univerzálne metódy spracovania projektov pre predmety Úvod do neurovied a Matlab a neurokognícia, ktoré môžu slúžiť ako pomôcka pre študentov pre spracovanie ľubovoľnej témy zadania. Tieto návody môžu slúžiť aj pre výučbu iných predmetov v oblasti výpočtovej a kognitívnej neurovedy alebo strojového učenia.

## Použitá literatúra

- DAYAN P AND LF ABBOTT. Theoretical Neuroscience: Computational and Mathematical Modeling of Neural Systems. Cambridge, MA: MIT Press, 2001.
- DURLACH NI (1968). "A decision model for psychophysics." unpublished manuscript.
- GROSSBERG S (1982a). Studies of Mind and Brain. Holland: Kluwer/Reidel Press.
- GROSSBERG S (1982b). Why do cells compete? UMAP Unit 484, UMAP Journal, Vol 3.
- GROSSBERG S (1983). The quantized geometry of visual space: The coherent computation of depth, form, and lightness. Behavioral and Brain Sciences, 6, 625-692.
- KOPČO N A BG SHINN-CUNNINGHAM (2003) Spatial unmasking of nearby pure-tone targets in a simulated anechoic environment, J Acoust Soc Am, 114, 2856-2870.
- KOPČO N (2011a) Výpočtová neuroveda (Úvod do modelovania neurofyziologických a behaviorálnych dát), Technická univerzita v Košiciach.
- KOPČO N (2011b) Výpočtová a kognitívna neuroveda (Návody na cvičenia), Technická univerzita v Košiciach.
- KOPČO N, SEBENA R, AHVENINEN J, BEST V, SHINN-CUNNINGHAM, B (2021), "Electrophysiological correlates of auditory and visual attentional cueing in fine-grained auditory spatial discrimination task", DAGA 2021, Vienna, Austria.
- LUCK SJ (2014) An Introduction to the Event-Related Potential Technique, second edition. MIT Press.
- OOSTERHOF NN, CONNOLLY AC, AND HAXBY JV (2016). CoSMoMVPA: multi-modal multivariate pattern analysis of neuroimaging data in Matlab / GNU Octave. Frontiers in Neuroinformatics, doi:10.3389/fninf.2016.00027.
- MACMILLAN NA AND CD CREELMAN (1991). Detection theory : a user's guide. Cambridge England ; New York, Cambridge University Press.
- SEUNG S. Introduction to Computational Neuroscience. 2004. Massachusetts Institute of Technology: MIT OpenCourseWare, <https://ocw.mit.edu/>. License: Creative Commons BY-NC-SA.
- STROOP JR (1935) Studies of interference in serial verbal reactions. Journal of Experimental Psychology, 18, 643-662.
- WESSEL R., C KOCH, AND F GABBIANI (1996), Coding of time-varying electric field amplitude modulations in a wave-type electric fish. J Neurophysiol 75:2280-93.
- XU X., YURUK N., FENG Z., SCHWEIGER TA (2007). SCAN: a structural clustering algorithm for networks. In: Proceedings of KDD '07. ACM, pp 824–833.

**Výpočtová a kognitívna neuroveda II**  
**(Návody na cvičenia)**

*Vysokoškolská učebnica*

Autor: doc. Ing. Norbert Kopčo, PhD.

Vydavateľ: Univerzita Pavla Jozefa Šafárika v Košiciach  
Vydavateľstvo ŠafárikPress

Rok vydania: 2024

Počet strán: 62

Rozsah: 3 AH

Vydanie: prvé

ISBN 978-80-574-0332-6 (e-publikácia)

