

Výpočtová a kognitívna neuroveda

Návody na cvičenia

NORBERT KOPČO

Technická univerzita v Košiciach

Autor: doc. Ing. Norbert Kopčo, PhD.

Názov: Výpočtová a kognitívna neuroveda (Návody na cvičenia)

Vydavateľ: Technická univerzita v Košiciach

Grafická úprava: Norbert Kopčo

Rok vydania: 2011

Miesto vydania: Košice

Vydanie: prvé

Počet strán (číslované): 35

Internetová adresa: <http://pcl.tuke.sk/vakn>

alebo <http://sites.google.com/site/kogneuro/>

ISBN: 978-80-553-0817-3

Kontaktný e-mail: kopco@tuke.sk

Pod'akovanie: Tieto skriptá vznikli s podporou Kultúrnej a edukačnej grantovej agentúry Slovenskej republiky v rámci projektu č. 3/7300/09 „Kognitívna veda – stredoeurópsky interdisciplinárny magisterský študijný program.“

Obsah

ÚVODNÉ POZNÁMKY	4
ZADANIE 1 NEURÁLNE KÓDOVANIE, LINEÁRNA REGRESIA, KONVOLÚCIA.....	5
ZADANIE 2 HODGKIN-HUXLEYHO MODEL.....	9
ZADANIE 3 ZATEKAJÚCI INTEGRÁTOR – JEDNODUCHÝ MODEL KRÁTKODOBEJ PAMÄTI	11
ZADANIE 4 STROOPOV EXPERIMENT.....	13
ZADANIE 5 BINAURÁLNY SLUCH A PSYCHOFYZIKÁLNE METÓDY.....	16
ZADANIE 6 PRIESTOROVÉ SLUCHOVÉ VNÍMANIE.....	21
ZADANIE 7 KONEKCIONISTICKÉ MODELOVANIE: GROSSBERGOVA „SHUNTING COMPETITIVE NETWORK“ A VIZUÁLNE VNÍMANIE	25
ZADANIE 8 ADITÍVNE A SHUNTING NEURÓNOVÉ SIETE.....	29
ZADANIE 9 NEURÓNOVÁ SIEŤ OUTSTAR.....	32
ZADANIE 10 ANALÝZA PSYCHOFYZIKÁLNYCH DÁT POUŽITÍM MODELU ROZHODOVANIA.....	34
LITERATÚRA.....	35

Úvodné poznámky

Neuroveda je interdisciplinárny vedný odbor na rozhraní biologických, psychologických a infromatických 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. Tieto skriptá obsahujú 10 zadaní, ktoré poskytujú prehľad o metódach používaných vo výpočtovej a kognitívnej neurovede, s dôrazom na matematické modelovanie a na behaviorálne štúdium kognitívnych procesov.

Teoretický výklad vybraných tém, na ktoré sa jednotlivé zadania zameriavajú, je v knižke Výpočtová neuroveda, rovnakého autora, ku ktorej sú tieto skriptá doplnkovým textom. Ku knihe existuje aj web stránka, prístupná cez adresy <http://pcl.tuke.sk/vakn> alebo <http://sites.google.com/site/kogneuro/>. Na web stránke sú 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. Tieto skriptá sú doplnkový text, založený na časti cvičení z predmetov Úvod do neurovied a Výpočtová a kognitívna neuroveda, ponúkaných na TU Košice. Preto veľmi dôležitými doplnkovými materiálmi sú aj slidy a ostatné 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.

Zadanie 1 Neurálne kódovanie, lineárna regresia, konvolúcia

Poznámky k vypracovaniu:

Zadanie mi odovzdáte vo forme referátu, ktorý bude obsahovať:

- hlavičku s názvom zadania, menami ľudí, ktorí ho vypracovali (tak ako pri projekte by ste mali robiť v skupinách max. 4 ľudí), ročník, skupinu atď.

- ku každej otázke uvediete 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 by ste mali uviesť priame slovné odpovede na otázky. Až potom kód, ktorým ste ich získali.

- v grafoch by malo byť popísane, čo znamenajú čiary rôznych farieb (funkcia legend) ako aj čo je na osiach. A vy musíte napísať, čo v grafe vidíte, prípadne aj slovne vyhodnotiť, či to čo graf ukazuje zodpovedá tomu, čo sme očakávali.

- z referátu vygenerujete PDF súbor (napr. použitím programu [PDFCreator](#)), ktorý mi odovzdáte elektronicky (emailom na adresu kogneuro@gmail.com – všimnite si, že je to iná adresa, než tá na ktorej si čítam štandardné maily). Subjekt emailu by mal mať následovnú štruktúru: **KUI342 Zx mená_autorov**.

Zadanie:

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 \(1996\)](#). 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.

Cieľom tohto zadania je oboznámiť sa s MATLABom a so základnou metódou analýzy dát nazývanou lineárna regresia. Každý z vás si z adresy <http://sites.google.com/site/kogneuro/> skopíruje súbor fish.mat. Tento súbor obsahuje dáta, ktoré budete mať v zadaní analyzovať.

Pozn: Matematické metódy požadované pri tomto zadaní (regresia) boli vysvetlené na prednáške.

Spustite si MATLAB (na neuron.tuke.sk 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.

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?

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

Pomôcka: použite 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.

3. 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 nazvte 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 minimum a maximum stimulu. Odovzdajte program a graf, ktorý zobrazuje $rate2$ a stimulus ako funkciu času tak, že sa budú prekryvať 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 `corrcoef` na výpočet korelačného koeficientu.

5. Zvoľte si jednu z nasledujúcich dvoch úloh:

a) určíte koeficienty a a b bez použitia matlabových funkcií `polyfit`, `var` a `cov`.

b) úloha rovnaká ako 4, ale tentokrát otestujte polinomiálny 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 (tj, 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.

Zadanie 2 Hodgkin-Huxleyho model

Úvod:

Zadanie mi odovzdáte vo forme referátu, ktorý bude obsahovať:

- hlavičku s názvom zadania, menami ľudí, ktorí ho vypracovali (tak ako pri projekte by ste mali robiť v skupinách max. 4 ľudí), ročník, skupinu atď.

- ak nie je v zadaní uvedené inak, ku každej otázke uvediete MATLABovský príkaz (kód), ktorý ste na jej zodpovedanie použili (doplnili/upravili), 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 mi odovzdáte elektronicky (emailom na adresu kogneuro@gmail.com – všimnite si, že je to iná adresa, než tá na ktorej si čítam štandardné maily). Subjekt emailu by mal mať nasledovnú štruktúru: **KUI342 Zx mená_autorov**).

Zadanie:

Stiahnite si MATLABový súbor <http://sites.google.com/site/kogneuro/> (matlabové súbory sa volajú „skripty“.), v ktorom je naprogramovaná simulácia Hodgkin-Huxleyho modelu v prúdovej svorke (current clamp). Rovnice použité v tejto simulácii sú popísané v 5. kapitole Dayanovej a Abbottovej knihy. 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 (tj, 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 kľudové hodnoty keď nie je privedený žiadny prúd. V tomto probléme sa pozrieme na to, ako inicializačné podmienky ovplyvňujú správanie sa neurónu.

Zvýšte začiatčnú 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 kľudovú hodnotu.

Teraz zvýšte počiatočnú 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 kľudovú 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). Zobraďte 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. T.j., ukážte, že čím je nižší prúd, tým viac je akčný potenciál opozdený.

Zadanie 3 Zatekajúci integrátor – jednoduchý model krátkodobej pamäti

Úvod:

Zadanie mi odovzdáte vo forme referátu, ktorý bude obsahovať:

- hlavičku s názvom zadania, menami ľudí, ktorí ho vypracovali (tak ako pri projekte by ste mali robiť v skupinách max. 4 ľudí), ročník, skupinu atď.

- ak nie je v zadaní uvedené inak, ku každej otázke uvediete MATLABovský príkaz (kód), ktorý ste na jej zodpovedanie použili (doplnili/upravili), 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 mi odovzdáte elektronicky (emailom na adresu kogneuro@gmail.com – všimnite si, že je to iná adresa, než tá na ktorej si čítam štandardné maily). Subjekt emailu by mal mať nasledovnú štruktúru: **KUI342 Z3 mená_autorov**).

Zadanie:

V tomto zadaní si precvičíte numerickú integráciu a tiež svoju schopnosť analyzovať jednoduché diferenciálne rovnice. 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:

a) 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 $t=10$. Zobraďte priebeh aktivity. Aká je asymptotická hodnota keď je vstupný podnet nenulový?

b) Zopakujte simuláciu z úlohy a) pre hodnoty $A=0.5$ a $A=2$. Čo sa zmenilo?

c) 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?

d) Predpokladajte, že I je konštantné a že počiatočné $x(0)=0$, takže rovnica (1) sa zmení na lineárnu diferenciálnu rovnicu prvého rádu s konštantnými koeficientmi.

Vyriešte rovnicu analyticky, t.j., nájdite explicitnú rovnicu ktorá popisuje $x(t)$ ako funkciu t a parametrov A a I .

Pre numerickú integráciu v častiach (a) a (b) použite Eulerovu metódu. Tj, na aproximáciu $x(t)$ použite algoritmus

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

kde Δt je malý časový krok. Správa by mala obsahovať grafy pre časti a) a b) a riešenia rovnice v častiach c) a d). Priložte aj MATLABový skript, ktorý ste použili pre numerickú integráciu.

Zadanie 4 Stroopov experiment

Úvod:

Cieľom tohto zadania je oboznámiť sa s metódami používanými pri behaviorálnych štúdiách fungovania ľudského mozgu a mysle. Vašou úlohou v rámci zadania bude:

- mierne upraviť experimentálny matlabový skript, ktorý vám je poskytnutý,
- nazbierať dáta na sebe, t.j., ľudí s ktorými ste v skupine (prípadne aj na ďalších rodinných a iných príslušníkoch),
- dáta zanalyzovať a vypracovať správu z experimentu.

Zadanie mi odovzdáte vo forme referátu, ktorý bude obsahovať:

- hlavičku s názvom zadania (a označením, či robíte „a“ alebo „b“), menami ľudí, ktorí ho vypracovali (tak ako pri projekte by ste mali robiť v skupinách max. 4 ľudí), ročník, skupinu atď.

- ak nie je v zadaní uvedené inak, ku každej otázke uvediete MATLABovský príkaz (kód), ktorý ste na jej zodpovedanie použili (doplnili/upravili), 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 mi odovzdáte elektronicky (emailom na adresu kogneuro@gmail.com – všimnite si, že je to iná adresa, než tá na ktorej si čítam štandardné maily). Subjekt emailu by mal mať nasledovnú štruktúru: **KUI342 Z4 mená_autorov**.

Stroopov experiment

Toto zadanie je založené na experimente J. Stroopa z roku 1935, ktorým ilustroval fenomén **interferencie** v kognitívnych procesoch (kópia článku je na psychclassics.yorku.ca/Stroop/, popis v slovenčine je napr. na 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: 1. priblížiť Vám, ako sa takéto experimenty dajú v MATLABe robiť, 2. oboznámiť Vás so štatistickými metódami používanými na analýzu dát, a 3. dať Vám možnosť precvičiť 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 resp. cviku v 9. týždni budú vysvetlené štatistické procedúry, ktoré budete mať použiť pri analýze. Sami si ich môžete naštudovať zo súboru `tests_of_significance.pdf` na webe skrípt.

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 experiment pozostáva zo 120 prezentácií.

Analýza dát

Po ukončení experimentu skript `expl.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-modra, 2-zelena....)

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):

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 signifikantný (na úrovni $\alpha=0.05$, MATLABová funkcia `ttest`).

Vygenerujte aj zhrnujúce grafy, ktoré uvedú priemerné hodnoty analyzovaný parametrov za celú skupinu. K vypracovanej správe priložte kúsok 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

Ak máte chuť pohrať sa s týmto experimentom viac, môžete skúsiť:

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 (tj, ako funkciu bloku)

Ak sa mi Váš doplnok bude páčiť, môže Vám zarobiť extra 10% kreditu za toto zadanie.

Zadanie 5 Binaurálny sluch a psychofyzikálne metódy

Poznámky k vypracovaniu:

Tak ako pri ostatných zadaniach aj tu môžete robiť v skupinách. V záujme vlastného vzdelávania, a taktiež preto, že otázky zo zadaní budú aj na písomkách, od vás ale očakávam, že si sami pozriete a minimálne pochopíte (ale prípadne aj urobíte) aj to druhé zadanie. Takže, ak sa na niečo z neho opýtam na skúške, nebude to pre vás žiaden problém. **Mne ale odovzdáte vypracované iba zadanie 5.**

Zadanie mi odovzdáte vo forme referátu, ktorý bude obsahovať:

- hlavičku s názvom zadania (a označením, či robíte „a“ alebo „b“), menami ľudí, ktorí ho vypracovali (tak ako pri projekte by ste mali robiť v skupinách max. 4 ľudí), ročník, skupinu atď.


- ak nie je v zadaní uvedené inak, ku každej otázke uvediete MATLABovský príkaz (kód), ktorý ste na jej zodpovedanie použili (doplnili/upravili), 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 mi odovzdáte elektronicky (emailom na adresu kogneuro@gmail.com – všimnite si, že je to iná adresa, než tá na ktorej si čítam štandardné maily). Subjekt vášho emailu nech obsahuje slová „: KUI440 Z2a mená_autorov“ (alebo b), aby som si to vedel zatriediť.

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. T.j., 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 vpravo. 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 mnoho metód, ako merať psychometrické funkcie. My sa pozrieme na tri z nich:

1. Metóda konštantných stimulov

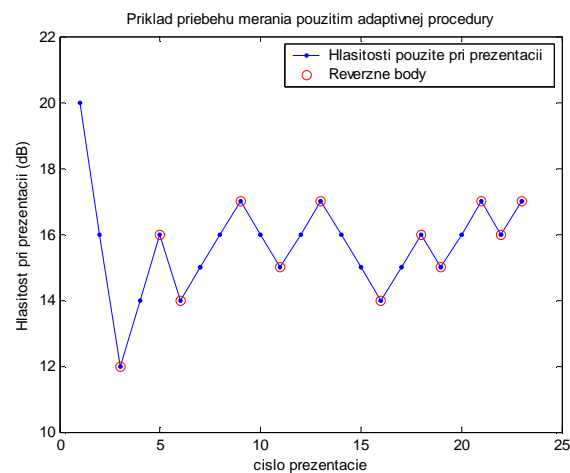
Dopredu si zvolíme niekoľko úrovní intenzity (napr. pre odhad psychometrickej funkcie na obrázku si môžeme zvoliť úrovne -6, -4, -2, 0, 2, 4 a 6 dB) a pre každú úroveň intenzity sa experimentálneho subjektu pýtame či zvuk počul alebo nie, s tým, že meranie zopakujeme pre každú úroveň napr. 20 krát. Na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

2. Metóda limít

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 limít 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, viď 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. Práh 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° ; 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 π (tj, šum identický, tón v jednom uchu invertovaný). Pre tóny nízkej frekvencie by mal byť rozdiel medzi NoS π a NoSo prahmi veľký, zatiaľčo pre vyššie frekvencie by sa rozdiel mal znižovať.

Pozn.: 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, zatiaľčo 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 funkciu `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 $NoS\pi$ 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 čudlíky pre nastavovanie hlasitosti na maximum (alebo do polovice alebo niekde...). 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.

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 hlasností 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 limít: 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 určte ako priemer týchto piatich meraní.

3. Analýza dát

Pre každého subjeka 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.

Prémiová otázka

Čo myslíte, aký v porovnaní s NoS_o a NoS_π 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 extra 10% kreditu.

Zadanie 6 Priestorové sluchové vnímanie

Poznámky k vypracovaniu:

Tak ako pri ostatných zadaniach aj tu môžete robiť v skupinách. V záujme vlastného vzdelávania, a taktiež preto, že otázky zo zadaní budú aj na písomkách, od vás ale očakávam, že si sami pozriete a minimálne pochopíte (ale prípadne aj urobíte) aj to druhé zadanie. Takže, ak sa na niečo z neho opýtam na skúške, nebude to pre vás žiaden problém. **Mne ale odovzdáte vypracované iba zadanie 6.**

Zadanie mi odovzdáte vo forme referátu, ktorý bude obsahovať:

- hlavičku s názvom zadania (a označením, či robíte „a“ alebo „b“), menami ľudí, ktorí ho vypracovali (tak ako pri projekte by ste mali robiť v skupinách max. 4 ľudí), ročník, skupinu atď.

- ak nie je v zadaní uvedené inak, ku každej otázke uvediete MATLABovský príkaz (kód), ktorý ste na jej zodpovedanie použili (doplnili/upravili), 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 mi odovzdáte elektronicky (emailom na adresu kogneuro@gmail.com – všimnite si, že je to iná adresa, než tá na ktorej si čítam štandardné maily). Subjekt vášho emailu nech obsahuje slová „: KUI440 Z2a mená_autorov“ (alebo b), aby som si to vedel zatriediť.


Úvod

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). Táto

transformácia spôsobí, že zvuk, ktorý počujeme sa

v skutočnosti líši od toho, aký zvuk vyšiel zo zdroja. Navyiac, 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.

Matematicky sa transformácia, ktorou zvuk prešiel po ceste od zdroja (reproduktora) 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° vľavo od stredovej osi – t.j. 0° 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 (tj. „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.

Úlohy

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


Spustíte si MATLAB (na neuron.tuke.sk príkazom 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 zvukovku resp. biedne 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.




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, 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 asi 11 milisekúnd).

3. Použitím premennej t_{cut} rozdeľte vektor *impr* na vektor *imprd* (obsahujúci len D-časť odozvy) a *impr*r (obsahujúci len R-časť odozvy). Tak isto rozdeľte vektor *impl* na *implr* a *impl*d. 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, 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.

5. Priestorové prenosové funkcie (HRTF) boli získané pre zdroje zvuku nachádzajúce sa pred poslucháčom v úrovni uší. Na základe vypočítaného ITD určite približne azimut, ktorému zodpovedá vaša HRTF (pozn: 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).



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?

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

Poznámky k vypracovaniu:

Zadanie mi odovzdáte vo forme referátu, ktorý bude obsahovať:

- hlavičku s názvom zadania, menami ľudí, ktorí ho vypracovali (tak ako pri projekte by ste mali robiť v skupinách max. 6 ľudí), ročník, skupinu atď.


- 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 (tj, nemiešajte ho s textom odpovedí)

- z referátu vygenerujete PDF súbor (napr. použitím programu [PDFCreator](#)), ktorý mi odovzdáte elektronicky (emailom na adresu kogneuro@gmail.com – všimnite si, že je to iná adresa, než tá na ktorej si čítam štandardné maily).

Úvod

Cieľom tohto zadania je uviesť vás do problematiky konekcionistického modelovania (tj, 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 Obr. 1, 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).



Obr 1. Náčrt spojení vstupov a neurónov v SCN

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

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

ktorá vraví:

$-Ax_i$ 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)


$-x_i \text{SUM}(I_k)$ hovorí, že aktivácia neurónu je potláčaná vstupmi ostatných neurónov (t.j.,

paralelná „shunting“ inhibícia).


SHIFT PROPERTY

„Shift property“ je niečo ako invariancia zrkovného systému voči celkovému jas. T.j., 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 (Mingolla, 2002):



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. nasledovne:



T.j., pri vyššej intenzite svetla **z pozadia** by sa znížila maximálna aktivácia daného neurónu (a tým znížil jeho dynamický rozsah).

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 logaritmicky (skúste príkaz `semilogx` miesto `plot`).


Skúste rôzne rozmiestnenia hodnôt L (napr. 10, 100, 1000 alebo 500, 600, 700)

BRIGHTNESS CONTRAST

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 (viď. obrázok dole), jeden obkolesený čiernou a druhý bielou, ten prvý kruh sa nám bude zdať svetlejší než ten druhý:



Ak obrázok hore trochu zjednodušíme, a to tak, že sa pozrieme na jeho jednorozmerný prierez jasového profilu, ten bude vyzeráť 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 obr. vpravo:



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.

Pozn.:

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. T.j., 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.

Prémiová 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).

Zadanie 8 Aditívne a shunting neurónové siete

Poznámky k vypracovaniu:

Zadanie mi odovzdáte vo forme referátu, ktorý bude obsahovať:

- hlavičku s názvom zadania, menami ľudí, ktorí ho vypracovali (tak ako pri projekte by ste mali robiť v skupinách max. 6 ľudí), ročník, skupinu atď.

- 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 (tj, nemiešajte ho s textom odpovedí)

- z referátu vygenerujete PDF súbor (napr. použitím programu [PDFCreator](#)), ktorý mi odovzdáte elektronicky (emailom na adresu kogneuro@gmail.com – všimnite si, že je to iná adresa, než tá na ktorej si čítam štandardné maily. . Subjekt emailu by mal mať nasledovnú štruktúru: **KUI440 Z3 mená_autorov**).

Zadanie:

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:

$$dx_i / dt = -Ax_i + BI_i - \sum_{k=1}^{10} I_k$$

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:

$$dx_i / dt = -Ax_i + (B - x_i)I_i - x_i \sum_{k=1}^{10} I_k$$

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 najst' 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 (a)

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

tom, čo sieť dosiahne $X_i = x_i / \sum_{k=1}^{10} x_k$ a normalizovanej STM aktivity;) po 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 (b)

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 (c)

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 ekvilibrácie? Ako sa v tomto prípade zmení asymptotická odozva siete na lineárny vstup použitý v úlohe (a)?

Úloha (d)

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.

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

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

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?

Zadanie 9 Neurónová sieť OUTSTAR

Poznámky k vypracovaniu:

Zadanie mi odovzdáte vo forme referátu, ktorý bude obsahovať:

- hlavičku s názvom zadania, menami ľudí, ktorí ho vypracovali (tak ako pri projekte by ste mali robiť v skupinách max. 4 ľudí), ročník, skupinu atď.

- 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 (tj, nemiešajte ho s textom odpovedí)

- z referátu vygenerujete PDF súbor (napr. použitím programu [PDFCreator](#)), ktorý mi odovzdáte elektronicky (emailom na adresu kogneuro@gmail.com – všimnite si, že je to iná adresa, než tá na ktorej si čítam štandardné maily. . Subjekt emailu by mal mať nasledovnú štruktúru: **KUI440 Z4 mená_autorov**).

Zadanie:

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 buky, x_i sú aktivácie okrajových buniek ($i= 1; 2; 3$) a z_{0i} reprezentujú LTM stopy. Konštanty A_0, A, B, C, D, Γ a τ sú parametrami siete, ktoré môžu nadobúdať len nezáporné hodnoty. O signále I_0 môžeme uvažovať ako o podmieňovanom stimule, zatiaľčo signály I_i reprezentujú nepodmieňované 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 opozdením τ . Patternové premenné sú definované nasledovne:

$$\begin{aligned} \theta_i &= I_i / \sum_{k=1}^3 I_k \\ X_i &= x_i / \sum_{k=1}^3 x_k \\ Z_{0i} &= z_{0i} / \sum_{k=1}^3 z_{0k} \end{aligned}$$

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

Úloha a:

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 Obr. 2.1. Analyticky určite hodnoty $X_i(t)$ a $Z_{0i}(t)$ pre $t \rightarrow \infty$.


Pomôcky k úlohe a: 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 b:

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 a. 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 Θ_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 a?

Úloha c:

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.



Obrázok 2.1 Časový priebeh vstupného patternu

Zadanie 10 Analýza psychofyzikálnych dát použitím modelu rozhodovania

Poznámky k vypracovaniu:

Zadanie mi odovzdáte vo forme referátu, ktorý bude obsahovať:

- hlavičku s názvom zadania, menami ľudí, ktorí ho vypracovali (tak ako pri projekte by ste mali robiť v skupinách max. 4 ľudí), ročník, skupinu atď.

- 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 (tj, nemiešajte ho s textom odpovedí)


- z referátu vygenerujete PDF súbor (napr. použitím programu [PDFCreator](#)), ktorý mi odovzdáte elektronicky (emailom na adresu kogneuro@gmail.com – všimnite si, že je to iná adresa, než tá na ktorej si čítam štandardné maily. . Subjekt emailu by mal mať následovnú štruktúru: **KUI440 mená_autorov**).

Zadanie:

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, viď kapitolu „Teória optimálneho rozhodovania a modelovanie psychofyzikálnych dát“ v knihe Výpočtová a kognitívna neuroveda a doplnujúce údaje na stránke <http://sites.google.com/site/kogneuro/>.

Úloha 1:

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



Úloha 2:

Nech Q je pravdepodobnosť správnej odpovede. Odvodte 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 v nasledovných tabuľkách. V každej matici zodpovedá položka v j -tom riadku a i -tom stĺpci počtu, koľkokrát stimul S_j vyvolal odpoveď R_i .

E1	R₁	R₂
S₁	32	166
S₂	8	197

E2	R₁	R₂
S₁	97	101
S₂	25	180

E3	R₁	R₂
S₁	152	48
S₂	84	119

E4	R₁	R₂
S₁	188	17
S₂	174	24

3a. Vykreslite štyri body na ROC krivke, ktoré zodpovedajú týmto dátam.

3b. Vypočítajte hodnoty P_D a P_F , Z_D a Z_F , ako aj hodnoty indexu citlivosti d' a strannosti β . Uvažujte, že v každom experimente bol subjektom iný človek. Ktorý z poslucháčov bol najcitlivejší? A ktorý bol najnestrannejší?

Literatúra

- Durlach, N. I. (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, The UMAP Journal, Vol 3, No 1.
- Grossberg, S. (1983). The quantized geometry of visual space: The coherent computation of depth, form, and lightness. Behavioral and Brain Sciences, 6, 625-692.
- Macmillan, N. A. and C. D. Creelman (1991). Detection theory : a user's guide. Cambridge England ; New York, Cambridge University Press.
- Wessel, R., 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)