

Robotický model systému zrkadliacich neurónov: experimentálna analýza

Kristína Rebrová a Igor Farkaš

Centrum pre kognitívnu vedu, KAI FMFI UK, Univerzita Komenského v Bratislave
Mlynská dolina, 84248 Bratislava

Email: {kristina.rebrova,farkas}@fmph.uniba.sk

Abstrakt


V príspevku predstavujeme model systému zrkadliacich neurónov vyvinutý v rámci kognitívnej robotiky použitím simulátora robota iCub. Pri formovaní modulárnej architektúry nášho modelu sme navrhli algoritmus obojsmerného učenia odvodený od biologicky plauzibilného modelu GeneRec. V článku prezentujeme výsledky testov zameraných na vlastnosti nášho algoritmu a jeho úspešnosť na rôznych dátových množinách. Náš model narozdiel od klasických modelov systému zrkadliacich neurónov, neuvážuje predspracované, pozične invariantné informácie. Naopak, cieľom nášho modelu je vysvetliť a realizovať vznik invariantných reprezentácií vo vyšších motorických a perceptuálnych mozgových oblastiach. V príspevku uvádzame predbežné výsledky z nášho modelu, konkrétne vznik asociácie medzi vizuálnymi a motorickými reprezentáciami z vlastnej perspektívy.

1 Úvod

V tomto príspevku priamo nadväzujeme na príspevok [16], v ktorom sme načrtli problematiku variantných a invariantných zrkadliacich neurónov. Naším cieľom je navrhovať a testovať konceptuálny model systému zrkadliacich neurónov v rámci paradigmy kognitívnej robotiky. V nasledujúcom texte zhrnieme podstatné východiská a návrh nášho modelu. Ďalej sa bližšie poverujeme použitým algoritmom, konkrétne obojsmernému učeniu na báze aktivačných fáz (bidirectional activation-based learning, BAL) [15].

Zrkadliace neuróny pália nielen pri vykonávaní, ale aj pri pozorovaní akcií (cielených motorických úkonov). Predpokladá sa, že pri porozumení pozorovanej akcie sa zapája *systém zrkadliacich neurónov* (mirror neuron system, MNS)[18], fronto-parietálny neurálny okruh zodpovedný za párovanie pozorovaných akcií a vlastného motorického repertoára. Základom MNS u makakov sú tri mozgové oblasti: F5 v premotorickej kôre, PF a AIP v temenom laloku, vid' Obr. 1. Unikátnu úlohu v MNS hrá horná spánková brázda (superior temporal sulcus, STS), ktorá podobne ako F5, reaguje na biologické pohyby, ale len v prí-

pade vizuálnej stimulácie. Tým, že oblasť STS nemá multimodálne vlastnosti, nemôže byť považovaná za skutočnú súčasť MNS. Na druhej strane, STS slúži MNS ako hlavný zdroj informácií.



Obr. 1: Náčrt systému zrkadliacich neurónov u makakov. Prepojenia medzi kľúčovými oblasťami sú farebne označené.

STS má samo o sebe zaujímavú štruktúru a vlastnosti. Ako uvádzajú rôzne výskumy Perreta a kolegov [14] či [5], STS obsahuje neuróny rôznych typov, medzi nimi množstvo takých, ktoré reagujú na vizuálny vnem objektu (tváre), či deja (pohybu) len z určitej perspektívy. Obsahuje ale aj neuróny, ktoré sú vzhľadom na perspektívu invariantné (reagujú na rôzne uhly pohľadu), čo znamená, že kódujú širšiu, všeobecnejšiu kategóriu. V STS sa takéto neuróny nachádzajú anatomicky najbližšie k frontálnej časti kôry, ktorá kóduje koncepty na najvyššej úrovni a považuje sa za racionálnu časť mozgu. Nedávny výskum [2] ukázal, že podobné vizuálne vlastnosti ako variantné neuróny v STS vykazujú aj zrkadliace neuróny v oblasti F5, a to väčšina z nich (asi tri štvrtiny). Caggiano a kolegovia skúmali tri druhy pohľadov, a to spredu (otočenie subjektu o 180° voči agentovi), z boku (90°) a z vlastnej perspektívy a objavili variantné rovnako ako invariantné zrkadliace neuróny. Prítomnosť vizuálne invariantných zrkadliacich neurónov v F5 naznačuje, že v F5, rovnako ako v STS, dochádza k hierarchickému usporiadaniu neurónov ústiacemu do abstraktného spracovania pozorovanej akcie, čo pravde-

podobne uľahčuje porozumenie pozorovanému deju.

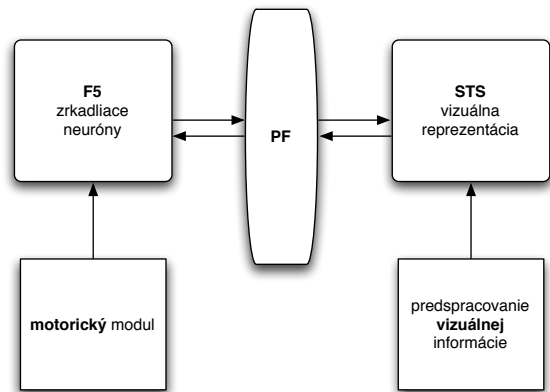
Spolu s objavom zrkadliacich neurónov a ich vlastností vzniklo množstvo výpočtových modelov systému zrkadliacich neurónov. Tieto modely zväčša modelujú presné časti mozgu opíc (či ľuď) a slúžia na konceptuálnu podporu teórií o motorickom porozumení pozorovanému deju. Najznámejšie z nich pochádzajú z dielne Arbiba, Oztopy a ďalších, napríklad FARS [3], MNS1 [10], MSI [12], MNS2 [1] a iné (pozri [11]). Oztop a kolegovia [13] tvrdia, že práve výpočtové modely nám ponúkajú silný nástroj na skúmanie teórií o zrkadliacich neurónoch. Niektoré výpočtové modely MNS možno zaradiť aj do oblasti kognitívnej robotiky. Takéto modely využívajú vlastnosti zrkadliacich neurónov aby obohatili správanie robotického agenta o nové funkcie. Vhodným príkladom je RNNPB [20]. Náš model patrí do tejto skupiny.

Mnohé klasické modely MNS čiastočne či úplne obchádzajú problém transformácie perspektívy, z ktorej agent pozoruje dej. Model Tessitoreho a kolegov [21] priamo rieši problém interpretácie variantných vstupov. Základom modelu je premisa, že motorické akcie možno popísať na základe malého množstva parametrov popisujúcich natočenia kĺbov ruky pri vykonávaní konkrétneho typu uchopenia predmetu. Na rozdiel od tradičných modelov predpokladá, že tok informácie medzi zrkadliacimi neurónmi a oblasťou STS je obojsmerný, a že informácia z motorickej modalít obohacuje a urýchľuje interpretáciu vstupov vo vizuálnych oblastiach. V našom modeli zdôrazňujeme obojsmerný tok informácie medzi motorickými (F5) a vizuálnymi (STS) oblasťami. Naším cieľom je tiež obsiahnuť potenciál pre vytvorenie variantných a invariantných reprezentácií. V súčasnom stave nášho výskumu však prezentujeme výsledky z fungovania nášho modelu len pre jednu perspektívu, konkrétne pre vlastnú perspektívu (0°).

2 Model systému zrkadliacich neurónov

Náš robotický model systému zrkadliacich neurónov (Obr. 2) pozostáva z niekoľkých hierarchicky zapojených modulov. Na najvyššej úrovni sa nachádza abstrakcia neurálneho okruhu STS–PF–F5, ktorý obojsmerne spája sekundárnu perceptuálnu (vizuálnu) a motorickú informáciu. Vizuálna a motorická informácia sa do modelu dostáva z exekutívnych modulov, konkrétne modulu pre uchopovanie a vizuálneho modulu, ktorý nie je tvorený neurálnou architektúrou, iba poskytuje systému predspracované vizuálne dáta. Nosné moduly F5 a STS reprezentujú motorické a vizuálne aspekty akcií a sú tvorené samoorganizujúcimi sa mapami. Možno ich považovať za paralelu asociatívnych oblastí v mozgu. Pre implementáciu okruhu STS–PF–F5 sme navrhli algoritmus obojsmerného učenia na báze aktivačných fáz (bidirectional activation-based learning, BAL),


ktorý je modifikáciou biologicky plausibilného učenia šírením chyby GeneRec [9].



Obr. 2: Schéma robotického modelu zrkadliacich neurónov.

Pre realizáciu modelu sme použili dáta zo simulovaného robota iCub [8, 22] natrénovaného na uchopovanie predmetov tromi rôznymi spôsobmi podľa tvaru a veľkosti objektu [25] zobrazenými na Obr. 3. Akcie, ktoré robot vykonával boli silový úchop (power grasp), bočný úchop (side grasp) a jemný úchop (precision grip). Neurálny model pre uchopovanie sa učil na báze biologicky plausibilného učenia s posilňovaním, konkrétne jeho spojitou variantou CACLA [23]. Podobnú neurálnu architektúru trénovanou pomocou CACLA popisujeme napríklad aj v [4]. tejto metodológii sa venuje aj článok *Konekcionistický model uchopovania: experimenty v reálnom prostredí* v tomto zborníku. Pre účely trénovania vyšších častí našej modulárnej architektúry sme zaznamenali a preškálovali hodnoty 16 kĺbov používaných pri natáčaní sa a uchopovaní. Vizuálne dáta pre STS modul sme vytvorili pomocou projekcie vybraných stupňov voľnosti a pozícií (spolu 40 hodnôt) na pravú kameru robota. Ďalšie tri perspektívy (90° , 180° , and 270°) sme vytvorili rotáciou motorických dát pre prvú perspektívu a následným premietnutím do 2D a preškálovaním.

Moduly STS a F5 predstavujú zjednodušenú funkčnú aproximáciu vizuálnej oblasti STS a motorickej oblasti F5 (u makakov) a k nej homologickým oblastiam ľudskeho mozgu. Modelujeme ich samoorganizujúcimi sa mapami s rekurentným kontextom, konkrétne MSOM [19]. MSOM alebo Merge SOM, čiže zlučovacia samoorganizujúca sa mapa, je klasická Kohonenova sieť [7], ktorá má navyše kontextovú vrstvu ako tradičná rekurentná sieť. Na rozdiel od ďalších rekurentných SOM modelov (napr. RecSOM či SOMSD, pozri porovnanie v [24]), má MSOM kontextovú vrstvu iba o veľkosti vstupu. Do tejto vrstvy



Obr. 3: Príklady troch typov úchopov zobrazené z perspektívy pozorovateľa. Z ľava do prava: silový úchop (power grasp), bočný úchop (side grasp) a jemný úchop (precision grip).

sa teda vkladá menšie množstvo informácie, konkrétne ide o lineárnu kombináciu váhy a kontextu aktuálneho (teda posledného) víťazného neurónu. Kvôli priestorovým nárokom nechávame na čitateľa, aby sa s matematickou definíciou MSOM zoznámil pri čítaní nášho predošlého článku [16] alebo [17] (pre detailnejšie informácie o vlastnostiach a optimálnych parametroch pre tento typ siete pozri [24]).

Obidva MSOM moduly sme trénovali na dátach zo simulovaného iCub-a. Motorický modul F5 dostával motorické vstupy, konkrétne 18 inštancií každého z troch pohybov ilustrovaných na Obr. 3. Vzhľadom na to, že vo finálnej podobe má náš model reagovať na 4 rôzne perspektívy, vizuálny modul STS sme trénovali na všetkých 12 kategóriách dát (4 perspektívy pre 3 úchopy) a to pre korešpondujúce motorické inštancie. V prvom rade sme hľadali optimálne parametre pre siete na základe [24], viac informácií sa nachádza v [17]. Výsledky experimentov s MSOM naznačujú, že pri vizuálnych dátach je perspektíva vplyvnejšia než typ úchopu. Výsledky z optimálnych máp sme zaznamenali a pripravili ako vstup pre najvyšší modul.


Vzhľadom na charakter a výpočtovú náročnosť našej úlohy sme sa rozhodli výstupy z MSOM pred použitím „zbinarizovať“ a to tak, aby výsledné reprezentácie tvorili takzvané riedke (sparse) neurálne kódy. Riedke distribuované reprezentácie (tiež známe pod termínom „population coding“) sú charakteristické robustnými odpoveďami na rozne podnety a okrem toho dávajú priestor na zovšeobecňovanie (keďže podobné vstupy vyvolávajú podobné riedke reprezentácie). V našom prípade majú reprezentácie vďaka samoorganizujúcim sa mapám tiež topografické usporiadanie, čo je často využívaný princíp organizácie v mozgu. Riedke reprezentácie vznikajú v biologických sieťach na základe laterálnej inhibície. My sme ako výpočtovú skratku použili algoritmus k -WTA (k -winner-take-all), ktorý priradí hodnotu 1.0 k neurónom s najmenšou vzdialenosťou od vstupu a ostatné neuróny zresetuje na 0.0.

V súčasnom stave sme naimplementovali BAL pre asociáciu motorických a perceptuálnych reprezentácií pri

tom, ako agent sám vykonáva akciu a pozoruje sám seba. V nasledujúcej kapitole popíšeme náš algoritmus, ďalej popíšeme jeho vlastnosti a výsledky zo všeobecných testov a nakoniec odprezentujeme aktuálne výsledky z nášho robotického modelu.

3 Algoritmus BAL

Pri výbere učiaceho algoritmu pre asociáciu vyšších motorických a vizuálnych oblastí sme dbali na biologickú plauzibilitu. Algoritmus BAL je založený na zovšeobecnenej recirkulácii (Generalized Recirculation, GeneRec) [9]. Tento učiaci algoritmus síce spadá do kategórie učenia s učiteľom, no na rozdiel od štandardného šírenia chyby funguje na báze rozdielu medzi dvoma aktivačnými stavmi siete, plusovou a mínusovou. V mínusovej fáze sa sieť šíri aktivácia od vstupov k výstupom a zaznamenáva sa odhad siete na výstupe. Tento proces je schematicky zobrazený na Obr. 4. V druhej, plusovej fáze, sa na výstup sa „zafixuje“ (angl. clamp) želaný vzor (target) a aktivácia sa šíri naopak (od vstupu k výstupu). O’Reillyho model, pôvodne určený na jednosmernú asociáciu vstupov a výstupov, sme adaptovali tak, aby mohol slúžiť na obojsmernú asociáciu. Viac o GeneRec modeli a BAL v [15].



Obr. 4: Schéma obojsmerného učenia na báze aktivačných fáz.

Keďže v našom prípade figurujú vstupné dáta a výstupné odhady siete na oboch vstupno-výstupných vrstvách, nazveme tieto v , teda vizuálna vrstva (STS) a m teda motorická vrstva (F5). Skrytá vrstva h figuruje v našom modeli ako oblasť, ktorá prepája STS a F5, teda PF. Napriek tomu, že na tejto vrstve nutne neočakávame vznik neurálneho kódovania, zaujíma nás, ako sa bude jej aktivita vyvíjať (na túto aktiváciu totiž nemáme žiaden priamy vplyv, reprezentácie na tejto vrstve sú teda úplne samoorganizované).

Náš algoritmus pre obojsmernú asociáciu sa odvíja od GeneRec modelu, no tiež sa od neho líši. Náš model je perceptrón so 4 maticami váh, 2 pre každý smer toku aktivácie. Výpočet aktivácie na jednotlivých vrstvách v dvoch aktivačných fázach zobrazuje Tabuľka 1. Najprv aktivujeme vstupy na vizuálnej vrstve v smere $v^F \rightarrow h^F \rightarrow m^F$ a získavame aktivácie na vrstvách v tomto smere, ktorý my označujeme písmenom F (zodpovedá mínusovej fáze)¹. V

¹V našom prípade máme vstupy aj výstupy na oboch stranách. Rozli-

Tabuľka 1: Aktivačné fázy a stavy v modeli BAL. Obe aktivačné fázy sa skladajú z dvoch krokov, pričom vždy na začiatku aktivujeme vzor na vstupe a dostávame odhad siete na výstupe. Vrstvy **v** a **m** si navzájom striedajú úlohu vstupnej a výstupnej vrstvy.

Vrstva	Fáza	Vstup (net)	Aktivácia
v	F	-	v_i^F (vstup)
h	F	$\eta_j^F = \sum_i w_{ij}^{vh} x_i^F$	$h_j^F = \sigma(\eta_j^F)$
m	F	$\eta_k^F = \sum_j w_{jk}^{hm} h_j^F$	$m_k^F = \sigma(\eta_k^F)$
m	B	-	m_k^B (vstup)
h	B	$\eta_j^B = \sum_k w_{kj}^{mh} y_k^B$	$h_j^B = \sigma(\eta_j^B)$
v	B	$\eta_i^B = \sum_j w_{ji}^{hv} h_j^B$	$v_i^B = \sigma(\eta_i^B)$

nasledujúcej fáze zafixujeme na vstup želaný výstup, ktorý sieť odhadovala v prvej fáze. V tomto prípade už o ňom uvažujeme ako o vstupe pre spätný smer, teda $\mathbf{m}^B \rightarrow \mathbf{h}^B \rightarrow \mathbf{v}^B$ označený písmenom B (plusová fáza). Výstup zo spätného smeru reprezentuje odhad siete o vstupe \mathbf{v}^F .

Na základe rozdielov v aktivačných fázach upravujeme váhové matice v sieti. Všeobecný predpis pre úpravu váh v doprednom F smere popisuje rovnica 1 a úpravu váh v spätnom smere rovnica 2, kde λ je rýchlosť učenia. Všetky vrstvy obsahujú trénovateľné biasové neuróny, ktorých váhy sa upravujú analogicky k ostatným neurónom a ako vstup dostávajú konštantne hodnotu 1.0.

$$\Delta w_{ij}^F = \lambda \cdot a_i^F (a_j^B - a_j^F) \quad (1)$$

$$\Delta w_{ij}^B = \lambda \cdot a_i^B (a_j^F - a_j^B) \quad (2)$$

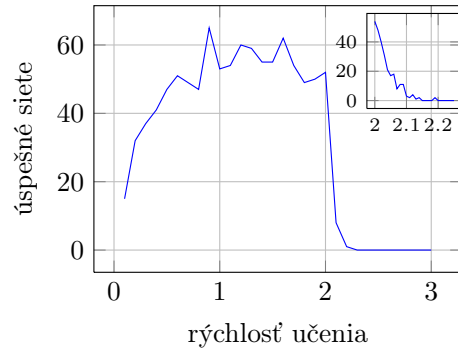
4 Experimenty s algoritmom BAL

Pri skúmaní vlastností nášho algoritmu sme sa venovali viacerým testom na rôznych typoch umelých dát. Pre vyhodnotenie úspešnosti nášho učiaceho algoritmu sme zvolili tri kvantitatívne miery. Konkrétne sme vyhodnocovali: (1) bitovú úspešnosť (označenie „bity“), čiže percento bitov, v ktorých sa výstup siete a želaná hodnota zhodujú (priemer zo všetkých bitov všetkých vzorov), (2) vzorovú úspešnosť (označenie „vzory“), teda percento vzorov, v ktorých mala sieť 100% bitovú úspešnosť, (3) strednú kvadratickú chybu (mse). Miery úspešnosti siete sme vyhodnocovali zvlášť pre smer F a pre smer B. Vo všetkých experimentoch sme inicializovali váhy na malé náhodné hodnoty z normálnej distribúcie.

4.1 Kódovač 4-2-4

Pre porovnanie s pôvodným GeneRec modelom sme náš model testovali pomocou známej úlohy „kódovača“ 4-2-4,

šujeme preto medzi smermi aktivácie, nie medzi odhadovacou mínusovou a zabezpenou plusovou fázou ako O'Reilly.



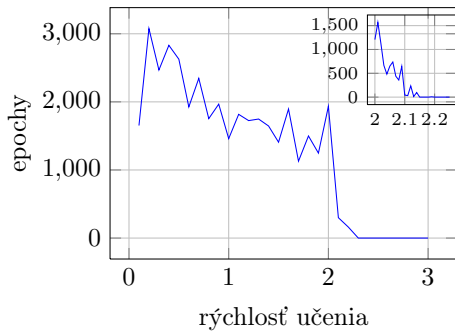
Obr. 5: Kódovanie 4-2-4: počet úspešných sietí ako funkcia rýchlosti učenia. Zaujímavé je, že napriek tomu, že sa náš model sa učí pre rôzne rýchlosti učenia, konvergencia algoritmu pre $\lambda > 2.0$ prudko poklesne na nulu. Ak teda zvolíme príliš veľkú rýchlosť učenia, algoritmus neskoverguje vôbec. Výsledky pre detailnejší interval okolo kritického hodnoty zobrazuje vnorený graf.

ktorý sa učí asociovať 4-bitové vstupy cez 2 skryté neuróny (kompresia). V našom prípade sa sieť učí rovnaké zobrazenie z oboch strán. Pri testovaní sme zistili, že sieť trénovaná pomocou BAL pri tejto úlohe niekedy vôbec neskoverguje k 100% úspešnosti. Pri testovaní parametrov, konkrétne rýchlosti učenia (λ), sme teda vyhodnocovali počet sietí, ktoré skonvergujú (zo 100) a priemerný počet trénovacích epoch, ktoré sieť potrebujú pre dosiahnutie 100% úspešnosti. Výsledky uvádzame na Obr. 5 a Obr. 6. Zaujímavé je, že úspešnosť sietí veľmi prudko poklesne po prekročení $\lambda = 2.0$. Tomuto fenoménu sa venuje vnorený graf s detailnejším intervalom λ od kritického hodnoty 2.0.

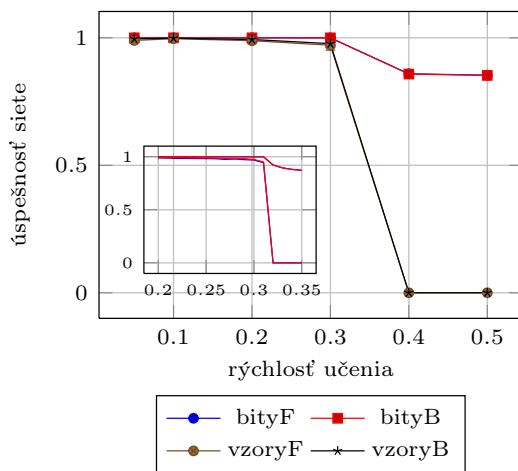
Podobné kritéria ako my mal pri zhodnotení svojho algoritmu a jeho variácií aj O'Reilly [9], ktorý zaznamenal konvergenciu 90%. Pri najúspešnejšej rýchlosti učenia $\lambda = 0.9$ konvergoval BAL v 65% prípadov, čo je porovnateľné so symetrickou verziou GeneRec aproximujúcov kontrastné Hebovské učenie (Contrastive Hebbian Learning, CHL). Tento a ďalšie experimenty detailnejšie popisujeme v [15].

4.2 Párovanie riedkych binárnych vzorov

V snahe skúmať algoritmus BAL pomocou dát, ktoré sa ponášajú na riedke (sparse) binárne reprezentácie, aké v našom robotickom modeli párujeme (pozri časť 2) sme vytvorili dátové množiny z náhodných binárnych čísel. Naše binárne vstupné vektory obsahujú vždy presný počet k pozitívnych bitov. V tomto prípade sme použili 100 rôznych párov vektorov veľkosti 144 bitov s $k = 12$ pozitívnymi bitmi. Tak, ako v predošlom experimente, sme tes-

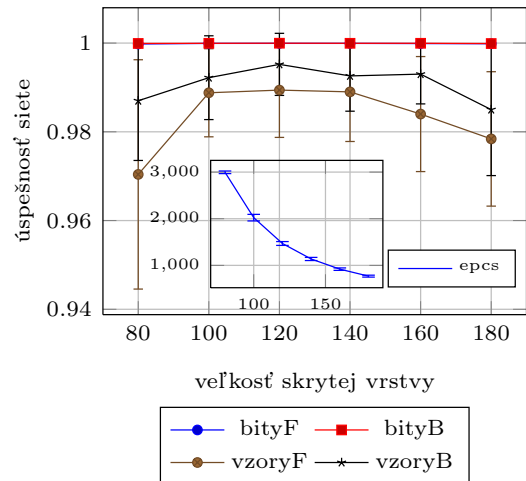


Obr. 6: Kódovanie 4-2-4: priemerný počet tréningových epoch ako funkcia rýchlosti učenia pre úspešne konvergujúce siete.




Obr. 7: Párovanie binárnych vzorov: úspešnosť siete ako funkcia λ .

tovali rôzne λ a tiež rôzne veľkosti skrytej vrstvy n_H . V tomto prípade sa k určitej úspešnosti dostanú všetky sledované siete (50 pre každú sledovanú hodnotu parametrov). Z priestorových dôvodov zaznamenávame len 2 miery úspešnosti, a to vzorovú a bitovú. Výsledky zobrazuje Obr. 7 a Obr. 8. Ukázalo sa, že v tomto prípade stačí oveľa nižšia λ a to okolo hodnoty 0.2. Tiež sa tu vyskytuje prudký pokles úspešnosti sietí (pozri vnorený náhľad na detailný interval v oblasti kritických hodnôt). Čo sa týka n_H , zistili sme, že má vplyv viac menej len na počet epoch potrebných na skonvergovanie siete k úspešnosti (pozri vnútorný graf na Obr. 8). Pri tomto experimente uvádzame taktiež ilustráciu priebehu učenia na Obr. 9. Pri skúmaní vlastností nášho modelu sme sa zaoberali aj aktiváciami na skrytej vrstve. Zistili sme, že \mathbf{h}^F a \mathbf{h}^B majú tendenciu bližieť sa k sebe až sú nakoniec takmer totožné. Čo sa týka charakteru reprezentácií na \mathbf{h} , hodnoty aktivácií neurónov sa pohybujú



Obr. 8: Párovanie binárnych vzorov: úspešnosť siete ako funkcia n_H .

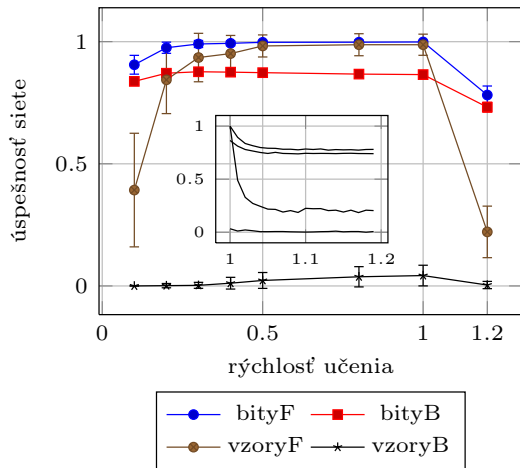
okolo 0.5, čiže nedochádza k binarizácii. Vlastnosti aktivácií na skrytej vrstve sú vhodným subjektom pre ďalšie skúmanie algoritmu BAL.




Obr. 9: Párovanie binárnych vzorov: vývoj sietí v čase (priemer a štand. odchýlka pre 50 sietí).

4.3 Komplexné asociácie

Vzhľadom na to, že v budúcnosti očakávame od nášho modelu netriviálne párovanie dátových vzorov, konkrétne nie len unikátne kombinácie 1:1, ale mapovanie jedného pohybu na 4 rôzne vizuálne reprezentácie (podľa perspektívy), rozhodli sme sa otestovať BAL na obdobných komplexne pospájaných dátach. Pre zjednodušenie sme vytvorili tréningovú množinu len o 16 dátových pároch dĺžky 16 bitov, z ktorých bolo $k = 3$ pozitívnych, pričom 1 vzor na jednej strane je vždy asociovaný so štyrmi inými na druhej strane. Tak ako v ostatných dvoch prípadoch sme zistovali optimálne hodnoty λ a n_H . Na Obr. 10 ilustrujeme úspešnosť siete pre rôzne hodnoty λ , manipulovanie s n_H neukázalo žiadne významné rozdiely, preto ho neilustrujeme.




Obr. 10: Komplexné asociácie: úspešnosť siete ako funkcia λ .



Obr. 11: Komplexné asociácie: vývoj sietí v čase (priemer a štand. odchýlka pre 50 sietí).


trujeme. Zo skúmaných parametrov sa najlepšie osvedčili $\lambda = 1.0$ a $n_H = 14$. S týmito sme opäť monitorovali priebeh učenia siete. Priemerné hodnoty z 50 sietí zobrazuje Obr. 11. V prípade komplexných asociácií, kde sme v smere F asociovali štyri rôzne vzory s jedným a naopak v smere B, sme zaznamenali značne menšiu úspešnosť pre nejednoznačný smer B, konkrétne bitovú úspešnosť $\approx 86\%$ a vzorovú úspešnosť len $\approx 4\%$. Z takýchto výsledkov môžeme predpokladať, že sieť úspešne reprodukuje smer F a vo smere B nevie určiť, ktorý zo 4 asociovaných vzorov vybrať, a teda zvolí ich prienik. Takéto správanie je u neuronových sietí očakávané. Odozvy siete bližšie ilustruje Obr. 12 vpravo. Ofarbené pixely indikujú aktiváciu nad 0.5. Ak p^d je želaný vzor a p^o je vzor na výstupe siete, potom pixel x bude označený čiernou farbou v prípade, že sú pozitívne obe hodnoty, teda $p_x^d = p_x^o$, šedou farbou ak sa pozitívna hodnota nachádza iba v p^d a šedou farbou a krížikom v prípade, že ide o falošnú pozitívnu aktiváciu na výstupe siete p^o .



Obr. 12: Odozvy jednej siete po natrénovaní na náhodných komplexných dátach.


5 Experimenty s robotickým modelom MNS

Prvým krokom vo vývoji agenta v našom modeli je sformovanie asociácie medzi vizuálnymi a motorickými reprezentáciami seba samého. V tejto časti prezentujeme výsledky z najvyššieho modulu nášho MNS modelu pre vlastnú perspektívu. Ako vstupy nám slúžili odozvy z dvoch MSOM sietí, modulov F5 a STS, ktoré sme trénovali na robotických dátach pomocou optimalizovaných parametrov (viac v [17]). Experimentovali sme tiež s veľkosťou oboch máp a parametrom k , teda počtom pozitívnych bitov v jednom vzore. Podľa výsledkov systematických testov rôznych dátových množín vzhľadom na priestorovú separáciu a jednoznačnosť vzorov a tiež podľa testov s BAL algoritmom sme zvolili veľkosť vizuálnej mapy 14×14 s $k_v = 16$ a veľkosť motorickej mapy 12×12 s $k_m = 8$. Na Obr. 13 ilustrujeme víťazné aktivácie neurónov, tvoriace vzory štyroch perspektív, pre každý z troch pohybov (vyfarbené pixely znamenajú, že sa na danej pozícii nachádzal aspoň jeden víťaz v aspoň jednom vzore) a víťazné aktivácie pre všetky motorické kategórie v jednom obrázku (každý pohyb je zakreslený iným odtieňom šedej).




Obr. 13: Víťazné vizuálne neuróny na mape 14×14 s $k_v = 16$ pre tri typy úchopov a štyri perspektívy (vľavo) a motorické neuróny na mape 12×12 s $k_m = 8$ pre tri typy úchopov (vpravo).

Priebeh učenia siete ilustrujeme pre 20 sietí s architektúrou 196–170–144, náhodnými malými váhami a rýchlosťou učenia $\lambda = 0.2$ trénovaných počas 1500 epoch. Obr. 15 zobrazuje dve miery úspešnosti siete, bitovú a vzorovú. Obr. 14 zobrazuje strednú kvadratickú chybu a ďalšiu kvantitatívnu mieru, ktorú sme nazvali vzdialenosť vzorov (vzdialenosť) a vystihuje vzdialenosť ťažiska želaného




Obr. 14: Robotický model: bitová a vzorová úspešnosť v čase (20 sietí). Relatívne vysoká bitová úspešnosť naznačuje, že sieť reprodukuje vzory pomerne dobre, no často robí chyby (skoro v každom vzore), čo reflektuje malá vzorová úspešnosť.



Obr. 15: Robotický model: mse a vzdialenosť vzorov v čase (20 sietí). Klesajúca úspešnosť vzorov indikuje, že sa želaný a skutočný výstup siete nachádzajú v rovnakom klastrí.

vzoru a vzoru, ktorý dala ako výstup sieť na 2D mriežke. Vývoj úspešnosti sietí počas testovania naznačuje, že napriek tomu, že sa model evidentne učí, jeho úspešnosť nedosiahne vysoké hodnoty, hlavne pri vzorovej úspešnosti (smer F 15% a smer B 36%). Bitová úspešnosť je pomerne vysoká v oboch smeroch ($\approx 96\%$) a vzdialenosť ťažísk je nízka. Môžeme teda predpokladať, že sieť robí veľa malých chýb. Na základe úspešnosti a klesajúcej vzdialenosti vzorov usudzujeme, že sieť nerobí chyby medzi kategóriami, ale mýli si vzory v rámci kategórie (vd'aka topografickej organizácii vstupných vzorov). Na Obr. 16 ilustrujeme vybrané odozvy siete. Podobne ako v predošlej kapitole, farebné pozitívne pixely sú rozdelené na zhodné (čierna), neúspešné ciele (šedá) a falošné pozitíva (šedá s krížikom). Nedostatky v úspešnosti siete možno vysvetliť aj na základe vlastností vstupných dát. Napriek tomu, že ide o mapovanie jednej vizuálnej reprezentácie na jednu motorickú, vzory v rámci kategórií pohybov sa zvyknú podobat' a opakovať. V prípade, že model dostáva určité vzory v n-m priradeniach, má tendenciu reprodukovat' jeden z asociovaných vzorov, najmä ten, ktorý sa vyskytuje najpočet-



Obr. 16: Odozvy jednej siete po natrénovaní na robotických dátach. Čierna farba symbolizuje zhodu, šedá želaný vzor, ktorý sieť nezreprodukovala a šedá s krížikom indikuje vzor, ktorý dala na výstupe sieť mimo želaného vzoru (false-positives).

nejšie alebo bol nedávno aktivovaný. Ak by sme brali do úvahy čisto kategorické odozvy, teda jeden z troch druhov pohybu, bola by úspešnosť modelu značne vyššia.

6 Záver

Predstavili sme návrh nášho robotického modelu systému zrkadliacich neurónov. Pre potreby nášho modelu sme vytvorili algoritmus obojmerného učenia na báze aktivačných fáz BAL odvodený od biologickej plauzibilného modelu GeneRec. V článku sme sa bližšie povenovali vlastnostiam BAL pomocou testov s umelými dátami, a nakoniec sme načrtli prvé výsledky z nášho robotického modelu. Ukazuje sa, že napriek tomu, že si náš model „mýli“ inštancie pohybov v rámci kategórie, možno ho považovať za úspešný, minimálne na požadovanej vyššej úrovni reprezentácií (rozoznanie typu pohybu). Náš model možno porovnať s Hebbovským modelom [6], ktorý tiež popisuje vznik okruhu STS-PF-F5. Narozdiel od tohto prístupu sú u nás reprezentácie na PF (teda skrytej vrstve) vlastné sieti. Je možné, že reprezentácie, ktoré si vytvára BAL na skrytej vrstve nemajú charakter reprezentácií v PF a pre lepšie vystihnutie neurálneho okruhu zrkadliacich neurónov bude potrebné priamo modelovať aj reprezentácie na tejto vrstve.

V neposlednom rade nám stále ostáva otvorená otázka variantných a invariantných reprezentácií v F5 a STS. Naše poznatky o MSOM nám zatiaľ naznačujú, že bude potrebné vyvinúť špeciálny mechanizmus pre invariantné reprezentácie, napríklad v podobe hierarchicky vyššej vrstvy nad modulom STS a F5. O hierarchickom vzťahu a anatomickej odlišnosti medzi variantnými a invariantnými neurónmi v STS svedčia aj poznatky z neurovedy [5]. Predpokladáme, že mechanizmus obojsmerného informačného toku medzi zrkadliacimi neurónmi a vizuálnymi reprezentáciami by mohol napomáhať aj pri formovaní invariantných kategorických reprezentácií.

Pod'akovanie

Tento príspevok vznikol v Centre pre kognitívnu vedu na KAI FMFI UK v Bratislave, za podpory grantov VEGA 1/0439/11 a 1/0503/13 a UK/631/2013. Ďakujeme L. Zdechovanovi za výstupy z natrénovaného iCub robota a M. Pecháčovi za výstupy z natrénovaných MSOM sietí.

Literatúra

- [1] J. Bonaiuto, E. Rosta, a M. Arbib. Extending the mirror neuron system model, I: Audible actions and invisible grasps. *Biological Cybernetics*, 96:9–38, 2007.
- [2] V. Caggiano, L. Fogassi, G. Rizzolatti, P. Thier, a A. Casile. Mirror neurons differentially encode the peripersonal and extrapersonal space of monkeys. *Science*, 324(5925):403–406, 2009.
- [3] A.H. Fagg a M. Arbib. Modeling parietal-premotor interactions in primate control of grasping. *Neural Networks*, 11:1277–1303, 1998.
- [4] I. Farkaš, T. Malík, a K. Rebrová. Grounding the meanings in sensorimotor behavior using reinforcement learning. *Frontiers in Neurobotics*, 6(1), 2012.
- [5] T. Jellema a D. Perrett. Neural representations of perceived bodily actions using a categorical frame of reference. *Neuropsychologia*, 44:1535–1546, 2006.
- [6] C. Keysers a D.I. Perrett. Demystifying social cognition: a hebbian perspective. *Trends in Cognitive Sciences*, 8(11):501–507, 2004.
- [7] T. Kohonen. *Self-organizing Maps*. Springer, 1997.
- [8] G. Metta, G. Sandini, D. Vernon, L. Natale, a F. Nori. The iCub humanoid robot: an open platform for research in embodied cognition. In *Proc. of 8th Workshop on Perf. Metrics for Intel. Systems*, 50–56, 2008.
- [9] R.C. O'Reilly. Biologically plausible error-driven learning using local activation differences: The generalized recirculation algorithm. *Neural Computation*, 8(5):895–938, 1996.
- [10] E. Oztop a M. Arbib. Schema design and implementation of the grasp-related mirror neuron system. *Biological Cybernetics*, 87:116–140, 2002.
- [11] E. Oztop, M. Kawato, a M. Arbib. Mirror neurons and imitation: A computationally guided review. *Neural Networks*, 19(3):254–271, 2006.
- [12] E. Oztop, D. Wolpert, a M. Kawato. Mental state inference using visual control parameters. *Cognitive Brain Research*, 22:129–151, 2005.
- [13] E. Oztop, M. Kawato, a M.A. Arbib. Mirror neurons: Functions, mechanisms and models. *Neuroscience Letters*, 2012.
- [14] D. Perrett et al. Viewer-centred and object-centred coding of heads in the macaque temporal cortex. *Experimental Brain Research*, 86(1):159–173, 1991.
- [15] K. Rebrová and I. Farkaš. Bidirectional Activation-based Neural Network Learning Algorithm. Zasláné.
- [16] K. Rebrová a I. Farkaš. Robotický model systému zrkadliacich neurónov. In Nahodil P. Kelemen J., editor, *Kognice a umělý život XII*, 231–238. Slezská univerzita, Opava, 2012.
- [17] K. Rebrová, M. Pecháč, a I. Farkaš. Towards a robotic model of the mirror neuron system. Zasláné.
- [18] G. Rizzolatti a C. Sinigaglia. The functional role of the parieto-frontal mirror circuit: interpretations and misinterpretations. *Nature Reviews Neuroscience*, 11(4):264–74, 2010.
- [19] M. Strickert a B. Hammer. Merge SOM for temporal data. *Neurocomputing*, 64:39–71, 2005.
- [20] J. Tani, M. Ito, a Y. Sugita. Self-organization of distributedly represented multiple behavior schemata in a mirror system: reviews of robot experiments using RNNPB. *Neural Networks*, 17(8-9):1273–1289, 2004.
- [21] G. Tessitore, R. Prevede, E. Catanzariti, a G. Tamburini. From motor to sensory processing in mirror neuron computational modelling. *Biological cybernetics*, 103(6):471–485, 2010.
- [22] V. Tikhonoff, A. Cangelosi, P. Fitzpatrick, G. Metta, L. Natale, a F. Nori. An open-source simulator for cognitive robotics research: The prototype of the iCub humanoid robot simulator. In *Proc. of 8th Workshop on Perf. Metrics for Intel. Systems*, 57–61, 2008.
- [23] H. van Hasselt. Reinforcement learning in continuous state and action spaces. In *Reinforcement Learning*, pages 207–251. Springer, 2012.
- [24] P. Vančo a I. Farkaš. Experimental comparison of recursive self-organizing maps for processing tree-structured data. *Neurocomputing*, 73(7-9):1362–1375, 2010.
- [25] L. Zdechovan. Modeling the object grasping using the neural networks and iCub robotic simulator (in Slovak). Master's thesis, Comenius University in Bratislava, 2012.