

# Konekcionistický model epizodickej pracovnej pamäti

Martin Takáč

Centrum kognitívnych vied KAI FMFI UK  
Mlynská dolina, 842 48 Bratislava  
Email: takac@ii.fmph.uniba.sk

Alistair Knott

Dept. of Computer Science, University of Otago  
PO Box 56, Dunedin 9054, New Zealand  
Email: alik@cs.otago.ac.nz

## Abstrakt

V príspevku predstavíme nový výpočtový model uchovávaní epizód v pracovnej pamäti implementujúci Baddeleyho predstavu epizodického zásobníka a konzistentný s myšlienkou, že epizódy sa uchovávajú ako pripravené sekvencie pozornostných a motorických operácií (Knott). Model pozostáva z viacerých prepojených samoorganizujúcich sa máp (SOM). Technickou inováciou modelu je, že umožňuje transformácie medzi časovou a priestorovou reprezentáciou sekvencií a obsahuje médium, kde môžu byť jednotlivé sekvencie reprezentované viaceré naraz, takže môžu medzi sebou súťažiť, resp. je možné reprezentovať ich rozdelenie pravdepodobnosti. To sa využíva pri predikcii pokračovania epizódy (tendencia zhora nadol pri pozorovaní epizódy) alebo na rozhodovanie o ďalšom kroku pri aktívnom vykonávaní epizódy. Model taktiež reprodukuje niektoré experimentálne zistenia o reprezentácii pripravených sekvencií v prefrontálnej kôre.

## 1 Úvod

Klasický model pracovnej pamäti [4] pozostáva z fonologickej slučky, vizuálno-priestorového náčrtníka a centrálnej riadiacej zložky. Alan Baddeley [3] neskôr rozšíril tento model o médium na uchovávanie sémantických reprezentácií epizód resp. udalostí – tzv. epizodický zásobník. V tomto článku prezentujeme výpočtový model epizodického zásobníka.

V našom prístupe predpokladáme, že epizódy sú reprezentované v pracovnej pamäti ako pripravené senzomotorické rutiny resp. plány, t.j. ako sekvencie pozornostných a motorických operácií. Motivácií pre takúto sekvencnú organizáciu je viacero. Podľa súčasných simulačných teórií porozumenia jazyka (napr. [7]) reprezentácia epizódy by mala odrážať proces, ktorým skúsenosť epizódy vznikla, a umožniť jeho neskoršie znovuprehratie resp. simuláciu. Senzomotorické procesy prítomné pri prežívaní epizódy majú pri vhodne zvolenej časovej škále sekvencnú štruktúru. Podľa [5] senzomotorické spracovanie prebieha pomocou sekvencne štruktúrovaných *deiktických rutín*, ktorých atomickými elementami sú senzorické alebo moto-

rické akcie, tzv. *deiktické operácie*. Podrobnejšia argumentácia o sekvencnej štruktúre senzomotorických procesov participujúcich na prežívaní konkrétnych epizód je uvedená v [9]. Ďalší argument sa týka mechanizmu, pomocou ktorého sú epizódy ukladané v dlhodobej pamäti. Na tomto procese sa zúčastňuje hipokampus. Podľa [11] úloha hipokampu spočíva v aktívnom znovuprehrávaní sekvencií reprezentácií evokovaných počas pôvodnej senzomotorickej skúsenosti. Ešte ďalší argument pochádza z produkcie reči: predpokladá sa, že počas generovania vety je význam, ktorý má byť vyjadrený, uložený/aktívovaný v pracovnej pamäti. V [9] zdôvodňujeme sekvencnú reprezentáciu vetných významov a v [14] uvádzame výpočtový model generovania viet založený na takejto reprezentácii.

V nasledujúcej časti uvádzame požiadavky, ktoré by dizajn nášho modelu mal spĺňať, potom nasleduje popis architektúry modelu a simulačných experimentov zameraných na okamžité vybavovanie z pamäti, predikciu pokračovania sekvencie a riadenie rozhodovania.

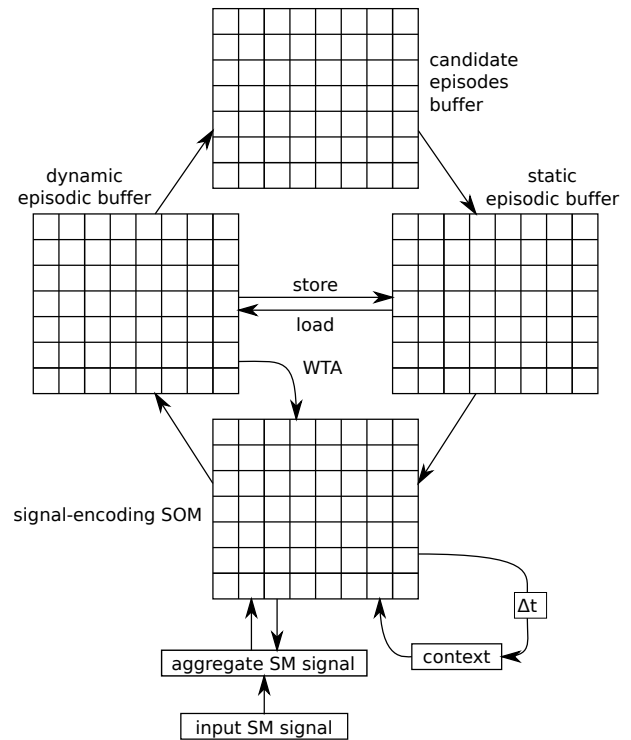
## 2 Požiadavky na model

V prvom rade, model by mal byť schopný registrovať, ukladať a neskôr prehrať v senzomotorických oblastiach sekvenciu signálov v čase. Ďalej by sa mal byť schopný naučiť často sa vyskytujúce sekvencie a vedieť predikovať pokračovanie sekvencie. Ten istý model epizodickej pracovnej pamäti by mal fungovať pre prežívanie epizódy z perspektívy jej aktívneho vykonávateľa, ako aj pasívneho pozorovateľa. V prvom prípade agent aktívne riadi vykonávanie epizódy, preto potrebuje predikovať, ktoré akcie sú výhodné, t.j. ktoré akcie participujú v zapamätaných epizódach asociovaných s kladnou odmenou. V druhom prípade anticipuje, ako sa bude pozorovaná epizóda ďalej vyvíjať. V oboch prípadoch si potrebuje vybrať z konkurenčných alternatív. Preto potrebujeme dva druhy konkurencie: jednu na úrovni viacerých alternatív jednotlivých akcií v každom kroku časovej sekvencie, druhú na úrovni celých zapamätaných sekvencií/epizód. To však predstavuje technický problém: potrebujeme médium, v ktorom by mohlo byť reprezentovaných viacero časových sekvencií naraz, s rôznou úrovňou

aktivity a tak umožniť ich vzájomnú konkurenciu (rôzne úrovne aktivity možno interpretovať ako rozdelenie pravdepodobnosti možných víťazov). Tento problém sme vyriešili transformáciou časových sekvencií na lokalistické/bodové reprezentácie.

Kľúčovým rozhodnutím v návrhu modelu bolo použitie samoorganizujúcich sa máp (SOM) [10]. SOM je (obvykle dvojrozmerná) mapa neurónov s topografickým usporiadaním, ktoré sú plne prepojené s vrstvou vstupných neurónov. Po prezentácii tréningového vzoru na vstupnej vrstve každý neurón mapy reaguje priamo úmerne vzdialenosti (napr. euklidovskej) medzi vstupným vektorom a vektorom svojich vlastných váh. Váhy neurónu s najsilnejšou odpoveďou a jeho susedov na mape sa následne adaptívne posunú smerom k vstupnému vektoru. SOM majú niekoľko veľmi dobrých vlastností, vďaka čomu sú vhodné na modelovanie pamäťových funkcií [12]:

1. Sú kombináciou distribuovanej a lokalistickej reprezentácie: distribuovaná informácia je uchovávaná vo váhach spojení medzi vstupnou vrstvou a mapou, lokalistická informácia je reprezentovaná pozíciou neurónu v mape.
2. Kvôli veľkému množstvu parametrov je reprezentácia v SOM robustná voči neúplnému a zašumenému vstupu. SOM funguje ako (odšumovací) autoasociátor: po rozpoznaní zašumeného vstupu je možné zrekonštruovať jeho zapamätanú podobu z váh víťazného (najsilnejšie odpovedajúceho) neurónu.
3. Mapa obsahuje aj tzv. neobsadené neuróny, ktoré nereprezentujú žiaden jeden konkrétny vstup, ale skôr kombináciu viacerých, čo umožňuje modelovať zmiešanie spomienok.
4. V mape môže byť aktívnych viacero neurónov súčasne, čo umožňuje reprezentovať viaceré konkurujúce si alternatívy a ich rozdelenie pravdepodobnosti (vyjadrené aktivitou neurónov reprezentujúcich jednotlivé alternatívy).
5. Mapa má vlastnosť „magnifikácie“, t.j. najčastejšie vstupy sú reprezentované väčšími oblasťami mapy a preto sú medzi nimi možné jemnejšie rozlíšenia ako medzi zriedkavými vstupmi.
6. Mapa zachováva vzťahy podobnosti: podobné vstupy sú reprezentované neurónmi, ktoré sú blízko seba.
7. Tréningový proces – samoorganizácia je biologicky plauzibilná a nepotrebuje učiteľa.



Obr. 1: Architektúra modelu

### 3 Architektúra modelu

Náš model pozostáva z viacerých navzájom prepojených samoorganizujúcich sa máp. Najprv popíšeme ich funkciu, potom technické detaily.

Architektúra modelu je na obr. 1. Sieť dostáva na vstupe sekvenciu senzomotorických (SM) signálov postupne tak, že v každom okamihu je vo vstupnej SM oblasti aktívny signál zodpovedajúci jednej senzorickej alebo motorickej operácii (*input SM signal*). Vstupné SM signály reprezentujú alebo agentove vlastné akcie (pozornostné alebo motorické), alebo vonkajšie podnety (objekty, alebo pozorované akcie). Vstupné SM signály prechádzajú cez oblasť agregovaného SM signálu (*aggregate SM signal*), kde sa kombinujú s očakávaniami/predikciami šírenými zhora z vyšších oblastí, do oblasti kódovania signálu (*signal-encoding SOM*). Táto oblasť je implementovaná architektúrou typu MSOM [13], čo je variant SOM s rekurentnými spojeniami, ktoré reprezentujú časový kontext vstupu: táto sieť má ako ďalší vstup tzv. kontextový vektor, ktorý je kombináciou váh a kontextového vektora víťazného neurónu z minulého časového kroku. Oblasť kódovania signálu je médium, kde nastáva konkurencia medzi kandidátmi na reprezentáciu fragmentov sekvencie: táto sieť sa trénuje sám organizuje tak, že jej jednotlivé neuróny kódujú vstupné signály v rôznych sekvenčných kontextoch,

podobne, ako sa to deje v prefrontálnej kôre [6].

Vítazný neurón sa v každom kroku skopíruje do oblasti izomorfnnej s oblasťou kódovania signálu – tzv. dynamického epizodického zásobníka (*dynamic episodic buffer*), kde sa temporálna sekvencia transformuje na distribuovaný priestorový vzor: v každom kroku sekvencie víťaz z oblasti kódovania signálu zanechá stopu v dynamickom epizodickom zásobníku tým, že aktivuje príslušný izomorfný neurón. Prvý signál v sekvencii má najvyššiu aktivitu, ostatné sú postupne zapamätané s klesajúcou aktiváciou, takže na konci sekvencie dokážeme podľa veľkosti aktivít zrekonštruovať poradie, v akom boli neuróny aktivované. Ako ukázal Averbeck v štúdiu makakov [1], podobne sa to deje aj v prefrontálnej kôre. Vstupnú sekvenciu zakódovanú v dynamickom epizodickom zásobníku možno prehrať, teda spätne transformovať na časovú sekvenciu mechanizmom podobným na kompetitívne zaradovanie (*competitive queuing*, napr. [8]): najaktívnejší neurón v dynamickom epizodickom zásobníku vyšle signál do oblasti kódovania signálu (cez spojenie označené na obr. 1 ako WTA), potom svoju aktivitu inhibuje a celý proces sa iteratívne opakuje, pokiaľ v dynamickom epizodickom zásobníku existujú nadprahovo aktívne neuróny. Signál z dynamického epizodického zásobníka aktivuje príslušný neurón v oblasti kódovania signálu, ktorý môže premietnuť svoj váhový vektor do oblasti agregovaného SM signálu.

Aby bolo možné takúto sekvenciu vykonať opakovane, uchováva sa v tzv. statickom epizodickom zásobníku (*static episodic buffer*), ktorý má rovnakú štruktúru ako dynamický, avšak neaktualizuje sa deštruktívne počas prehrávania sekvencie. Priestorový vzor uchovávaný v statickom epizodickom zásobníku sa skopíruje do dynamického, odkiaľ sa potom vyššie opísaným mechanizmom prehráva.

Teraz zameriame pozornosť na médium, v ktorom môžu byť súčasne aktívne reprezentácie viacerých celých sekvencií. Statický ani dynamický epizodický zásobník nemajú túto vlastnosť, pretože distribuované priestorové vzory by mohli pri súčasnej aktivácii navzájom interferovať. V tzv. epizodickom zásobníku kandidátov (*candidate episodes buffer*) je to možné, pretože priestorové vzory z dynamického zásobníka sa tu transformujú na lokalistické reprezentácie. Epizodický zásobník kandidátov je implementovaný ako klasická SOM, ktorej neuróny sú plne prepojené na vstupy prichádzajúce z dynamického epizodického zásobníka. Počas tréningu sa táto SOM naučí reprezentovať epizódy s podobným priestorovým vzorom blízko seba. Tu využívame robustnosť SOM voči neúplnému vstupu: v každom okamihu počas prezentácie sekvencie (kým sa prvok po prvku postupne vytvára distribuovaná priestorová reprezentácia v dynamickom epizodickom zásobníku) vyjadruje profil aktivít v epizodickom zásobníku kandidátov rozdelenie pravdepodobnosti úplných epizód zapamätaných vo

váhach jeho neurónov. Toto rozdelenie možno interpretovať ako predikciu možného pokračovania momentálne pozorovanej epizódy, alebo ako tendencia (*bias*), ktorá ovplyvňuje výber ďalšej operácie v prospech tých, ktoré boli v minulosti odmenené (pozri časť 4.4).

Po určení víťazného neurónu v epizodickom zásobníku kandidátov sa aktivita spätne šíri do nižších vrstiev procesom rekonštrukcie zhora nadol. Počas rekonštrukcie sa váhy víťazného neurónu z epizodického zásobníka kandidátov skopírujú do statického a následne aj dynamického epizodického zásobníka. Deštruktívna iteratívna aktualizácia v dynamickom epizodickom zásobníku spôsobí sekvenciu aktivácií neurónov v oblasti kódovania signálu: projekcia váh týchto neurónov nadol do oblasti agregovaného SM signálu vytvorí očakávania zhora nadol, ktoré možno skombinovať so vstupným signálom prichádzajúcim zdola nahor.

Teraz predstavíme niektoré technické detaily navrhnutej architektúry. Oblasť vstupného SM signálu používa lokalistické (*one hot*) kódovanie, t.j. každá možná SM operácia je reprezentovaná iným neurónom.<sup>1</sup> Oblasť agregovaného SM signálu je izomorfná s oblasťou vstupného SM signálu. Oblasť kódovania signálu je dvojrozmerná MSOM [13] so 400 neurónmi ( $\alpha = 0,4$ ,  $\beta = 0,5$ , rýchlosť učenia 0,1 a gausovské okolie zmenšujúce sa lineárne z 10 na 0,5). Pôvodný algoritmus MSOM sme zmodifikovali tak, že pri hľadaní víťaza v oblasti kódovania signálu sú zo súťaže vylúčené neuróny, ktoré už boli víťazmi v predchádzajúcich krokoch tejto sekvencie. Aj keby časová sekvencia prehrávaná v oblasti vstupného SM signálu obsahovala opakujúce sa prvky, ich lokalistická reprezentácia v oblasti kódovania signálu bude rôzna. To je nutné preto, že víťazné neuróny postupne vytvárajú priestorovú stopu v dynamickom epizodickom zásobníku: aktivity rovnakých víťazných neurónov by sa naskladali na seba a informácia o opakovaní by sa stratila.

Statický aj dynamický epizodický zásobník sú izomorfné s oblasťou kódovania signálu, teda každý z nich má 400 neurónov (akurát bez váhových spojení). Časová postupnosť víťazov v oblasti kódovania signálu sa zaznamenáva v dynamickom epizodickom zásobníku ako priestorová stopa izomorfnie prislúchajúcich neurónov s exponenciálne klesajúcou aktivitou:  $n$ -tý neurón v postupnosti má aktivitu  $\delta^{n-1}$ , kde  $\delta = 0,8$  a všetky nepoužité neuróny majú nulovú aktivitu. 400-rozmerný vektor reprezentujúci úplný priestorový vzor v dynamickom epizodickom zásobníku sa pošle ako tréningový vstup do epizodického zásobníka kandidátov až po skončení celej epizódy. Epizodický zásobník kandidátov je klasická SOM s 900 neurónmi, konštantnou rýchlosťou učenia 0,9 a Gausovským okolím zmenšujúcim

<sup>1</sup>V experimente opísanom ďalej používame 35 SM operácií a teda 35 vstupných neurónov.

sa lineárne z 10 na 0,5.

## 4 Experimenty a výsledky

Experimenty sme zamerali na overenie, či má model želanú funkcionálnosť, konkrétne či umožňuje okamžité vybavenie práve prežitej epizódy, predikciu možného pokračovania pozorovanej sekvencie, a riadenie rozhodovania počas aktívneho vykonávania epizódy. Ďalej sme skúmali podobu vytvorených reprezentácií a kapacitu epizodického zásobníka kandidátov.

### 4.1 Trénovanie

Model sme trénovali na sekvenciách predstavujúcich päť rôznych typov senzomotorických rutín, pomocou ktorých sú epizódy prežívané. Konkrétna sekvencná štruktúra jednotlivých typov rutín má kognitívnu motiváciu a je podrobne zdôvodnená v [9]. Sú to rutiny pre netranzitívne akcie (napr. MUŽ KÝCHNUŤ<sup>2</sup>), tranzitívne akcie (napr. MUŽ POHÁR UCHOPÍŤ), lokomočné akcie s lokatívnym cieľom (napr. MUŽ KRÁČAŤ DOM DO), jednoduché kauzatívne akcie (napr. MUŽ POHÁR SPŔSOBIŤ ROZBIŤ) a kauzatívne akcie, ktorých výsledkom je pohyb (napr. PES KOSŤ SPŔSOBIL SKOTŮLAŤ STŔL POD). Všetky SM sekvencie boli vystavané z 35 SM operácií.

Každú simuláciu sme opakovali 10 krát s rôznymi náhodne inicializovanými hodnotami váh v sieti a rôznymi tréningovými množinami stochasticky vygenerovanými tou istou sadou prepisovacích pravidiel. Výsledky 10 behov boli sprimerované. Každá tréningová množina pozostávala z 500 sekvencií, z ktorých v priemere 13 malo dĺžku dva, 86 dĺžku tri, 126 dĺžku štyri a 274 dĺžku šesť. Sekvencie mohli obsahovať viac rovnakých prvkov – 19,1% sekvencií obsahovalo dva rovnaké signály a 0,9% obsahovalo tri. Trénovanie trvalo 200 epoch – v každej epoche boli tréningové sekvencie prezentované sieti v náhodnom poradí a kontext MSOM bol po každej sekvencii resetovaný.

### 4.2 Okamžité vybavenie z pamäti

Najprv sme testovali schopnosť modelu uložiť a okamžite prehrať SM sekvencie. Táto schopnosť spočíva v interakcii medzi oblasťou kódovania signálu a dynamickým epizodickým zásobníkom. Časová postupnosť SM operácií vo vstupnej SM oblasti vytvorí priestorový vzor v dynamickom epizodickom zásobníku, potom sa zresetuje kontext MSOM v oblasti kódovania signálu a víťazný (najaktívnejší) neurón v dynamickom epizodickom zásobníku iteratívne aktivuje zodpovedajúci neurón v oblasti kódovania

<sup>2</sup>Zápis rutín pozostáva z označení SM operácií resp. „významov“, nie slov nejakého jazyka.

signálu a následne sa inhibuje. Váhy aktivovaného neurónu sa skopírujú do oblasti agregovaného SM signálu a výsledná časová sekvencia v oblasti agregovaného signálu sa porovná s pôvodnou vstupnou. Natrénovanej sieti sme prezentovali 200 testovacích sekvencií: 100 náhodne vybraných z tréningovej množiny a 100 nových, ktoré sa v tréningovej množine nevyskytovali. Model bol schopný korektné prehrať 99,4% (SD=0,49%) sekvencií z tréningovej množiny a 98,6% (SD=0,92%) nových sekvencií.

### 4.3 Predikcia pokračovania sekvencií

Ďalej sme testovali schopnosť modelu generovať očakávania/predikcie o sekvenciách pomocou aktivít v epizodickom zásobníku kandidátov. Predikcia je vlastne vyvolanie najpodobnejšej minulej epizódy zapamätanej vo váhach neurónov tejto SOM. Váhy víťazného neurónu sa skopírujú do statického epizodického zásobníka a pomocou dynamického epizodického zásobníka sa prehrávajú ako sekvencia v oblasti kódovania signálu, odkiaľ generujú očakávania zhora nadol pre SM operácie. Natrénovanej sieti sme prezentovali 500 sekvencií z tréningovej množiny a počas prehrávania sme po každom prvku skúmali očakávania generované sieťou. Doplnenie epizódy na základe jej fragmentu je nejednoznačná úloha: ten istý fragment môže mať viacero pokračovaní, ktoré sieť videla počas tréningovania. Preto sme vyhodnocovali iba to, nakoľko je sekvencia vyvolaná z pamäti kompatibilná s aktuálnym fragmentom vstupnej sekvencie. Napríklad s fragmentom PES MAČKA . . . je kompatibilná epizóda PES MAČKA NAHÁŇAŤ, ale nie epizóda PES MYŠ NAHÁŇAŤ. Z 2936 predikcií (jedna po každom fragmente) bolo kompatibilných 97,1% (SD=1,4%). Aby sme overili schopnosť siete robiť spätnú rekonštrukciu, vyhodnotili sme aj kompatibilitu pre 500 predikcií z úplných epizód. Na týchto sekvenciách sme dosiahli 95,2% (SD=2,7%) korektnú rekonštrukciu.

### 4.4 Riadenie rozhodovania

Taktiež sme skúmali, ako je možné použiť náš model pre riadenie rozhodovania počas aktívne generovaného správania. V tomto prípade sekvencia SM signálov vo vstupnej SM oblasti zodpovedá vykonávanej (nie iba pozorovanej) behaviorálnej sekvencii. Top-down očakávania generované v oblasti agregovaného SM signálu možno interpretovať ako ovplyvňovanie rozhodovania o ďalšom kroku. Počas vykonávania sekvencie dynamický epizodický zásobník obsahuje čiastočný, resp. postupne vytváraný priestorový vzor, ktorý sa porovnáva so zapamätanými sekvenciami v epizodickom zásobníku kandidátov rovnako ako pri predikcii pokračovania pozorovanej epizódy. Rozdiel je v tom, že teraz je súťaženie zapamätaných sekvencií v epizodickom

**Tabuľka 1:** Postupné dopĺňanie epizódy MAČKA SEDIETĚ MUŽ ZA z fragmentov, ovplyvnené zapamätanými odmenami ( $\rho = 0,5$ ). Epizóda vyvolaná v kroku 1 je zmiešanina, ktorá je výsledkom projekcie váh neobsadeného neurónu v epizodickom zásobníku kandidátov. Ostatné vyvolané epizódy sú korektné. Vo všetkých krokoch okrem posledného môžeme pozorovať dominanciu správania obsahujúcich interakcie s kreslom. V poslednom kroku bola aktuálna situácia silnejšia ako odmenou ovplyvnené spomienky a bola zrekonštruovaná korektné. Epizódy vyvolané v krokoch 3 a 4 nie sú kompatibilné s aktuálne vnímaným fragmentom. Bodka (.) označuje signál konca epizódy.

Por. č.	Vstupný fragment	Vyvolaná epizóda
1	MAČKA . . .	MAČKA DRŽAŤ . KRESLO KRESLO
2	MAČKA SEDIETĚ . . .	MAČKA SEDIETĚ KRESLO BLÍZKO .
3	MAČKA SEDIETĚ MUŽ . . .	MAČKA SEDIETĚ KRESLO BLÍZKO .
4	MAČKA SEDIETĚ MUŽ ZA . . .	MAČKA KRESLO SPŔSOBIŤ ÍŠŤ LOPTA ZA .
5	MAČKA SEDIETĚ MUŽ ZA .	MAČKA SEDIETĚ MUŽ ZA .

zásobníku kandidátov ovplyvnené odmenami/úspešnosťou asociovanou s minulými epizódami tak, že v minulosti úspešné epizódy majú vyššiu pravdepodobnosť stať sa víťazom, čo dosiahneme modifikáciou epizodického zásobníka kandidátov nasledujúcim spôsobom.

**Trénovanie.** Každému neurónu v mape epizodického zásobníka kandidátov pridáme ďalšiu (skalárnu) váhu, tzv. *odmenovú váhu*, ktorá slúži na zapamätanie odmeny asociovej s epizódou (pôvodné váhy, ktoré slúžia na zapamätanie epizódy, budeme nazývať *epizodické váhy*). Zopakujme, že epizodický zásobník kandidátov je trénovaný iba kompletnými priestorovými vzormi z dynamického epizodického zásobníka, teda po ukončení epizódy. V prípade, že po ukončení epizódy dostal agent nejakú odmenu, táto slúži ako učiaci signál pre odmenovú váhu. Najprv sa štandardným spôsobom nájde neurón, ktorý má epizodické váhy najbližšie k vstupnému vektoru. Potom sa štandardným spôsobom aktualizujú jeho epizodické váhy a epizodické váhy jeho susedov, a tiež sa aktualizuje jeho odmenová váha pomocou odmenového signálu (ak je k dispozícii) tak, aby odmenová váha tvorila kľzavý priemer všetkých minulých odmien asociovaných s týmto neurónom.

**Výber víťazného kandidáta.** Aktivity neurónov pre výber kandidáta sa počítajú ako

$$a_i = (1 - \rho) \exp(-d_i) + \rho r_i, \quad (1)$$

kde  $a_i$  je aktivita  $i$ -teho neurónu,  $d_i$  je euklidovská vzdialenosť medzi vektorom epizodických váh  $i$ -teho neurónu a vstupným vektorom,  $r_i$  je odmenová váha  $i$ -teho neurónu, and  $\rho$  je zmiešavací koeficient odmeny. Experimentovali sme s hodnotami  $\rho = 0,25$  a  $\rho = 0,5$ . Ak nastavíme  $\rho = 0$ , modifikovaný model sa zredukuje

na pôvodný, takže jeho dva operačné režimy (pozorovanie, riadenie správania) môžeme chápať ako prepínanie medzi nulovou a nenulovou hodnotou  $\rho$ .

Riadenie správania sme testovali tak, že sme nechali zbehnúť znovu pôvodné experimenty s tým, že sme poskytli ako trénovací signál spolu s epizódami aj odmenu: všetky sekvencie/epizódy, ktoré obsahovali SM signál KRESLO boli asociované s odmenou 1 a všetky ostatné epizódy s odmenou 0 (žiadna odmena). To zodpovedá hypotetickému scenáru, v ktorom sú všetky interakcie s kreslami pre agenta nejakým spôsobom výhodné. Počas testovania sme rekonštruovali sekvencie z epizodického zásobníka kandidátov rovnakým spôsobom ako pri predikcii pokračovania epizód. Potom sme porovnali počty zrekonštruovaných epizód obsahujúcich SM signál KRESLO v pôvodných a súčasných experimentoch. V prípade  $\rho = 0,25$  počet stúpol v priemere o 14,2% (SD=6,3%) a v prípade  $\rho = 0,5$  dokonca o 61% (SD=5,0%), čo sa dá interpretovať ako jasná preferencia správania obsahujúcich interakcie s kreslami (pozri Tab. 1). Ďalej sme vyhodnotili kompatibilitu epizód vyvolaných zo zásobníka kandidátov s dosiaľ vygenerovaným fragmentom epizódy. Kompatibilita bola 94,5% (SD=1,2%) pre  $\rho = 0,25$ , ale klesla na 63,7% (SD=3,2%) pre  $\rho = 0,5$ . Tieto výsledky napovedajú, že hodnota  $\rho$  by mala vyjadrovať rozumný kompromis medzi atraktivnosťou zapamätaných epizód a ich podobnosťou aktuálne vnímanej/vykonávanej epizóde.

#### 4.5 Súvislosť s neurálnymi dátami

V tejto časti popíšeme ako vlastnosti reprezentácií, ktoré vytvára náš model pri trénovaní, korešpondujú s reprezentáciami identifikovanými v prefrontálnej kôre (PFC) makakov.

Niektoré PFC neuróny kódujú jednotlivé operácie v plánovanej sekvencii berúc do úvahy sekvenčný kon-

		MUŽ3			
MUŽ1					
	MUŽ5				
MUŽ4		MUŽ2	MUŽ6		

**Obr. 2:** Pozície víťazných neurónov v mape natrénovanej oblasti kódovania signálu pre výskyty SM signálu MUŽ v rôznych sekvenčných kontextoch: MUŽ1 LOPTA SPŔSOBIŤ SCHOVAŤ MUŽ2 POD, MUŽ1 PES OBJAŤ, PES MUŽ3 SPŔSOBIŤ ÍŠŤ MUŽ4 POD, MUŽ1 SEDIETŤ MUŽ5 BLÍZKO, PES PES SPŔSOBIŤ SCHOVAŤ MUŽ6 BLÍZKO. Na obrázku je zobrazená iba (ľavá dolná) časť oblasti kódovania signálu s 20x20 neurónmi.

text, v ktorom sa vyskytujú [6]. V našom modeli majú túto vlastnosti neuróny v oblasti kódovania signálu. Obr. 2 znázorňuje pozíciu víťazných neurónov v mape natrénovanej oblasti kódovania signálu pre výskyty SM signálu MUŽ v rôznych sekvenčných kontextoch.

Iné neuróny v PFC kódujú jednotlivé operácie v plánovanej sekvencii tak, že relatívne úrovne aktivácie určujú poradie vykonania operácií [1]. Aktivita niektorých z týchto neurónov sa dynamicky mení počas vykonávania sekvencie tak, že je maximálna pred vykonaním príslušnej operácie a inhibovaná po nej (v našom modeli im zodpovedajú neuróny v dynamickom epizodickom zásobníku). Iné neuróny majú aktivitu invariantnú počas vykonávania celej sekvencie (v našom modeli im zodpovedajú neuróny v statickom epizodickom zásobníku).

Niektoré oblasti PFC sú médiom, kde rôzne konkurenčné alternatívy sekvencií medzi sebou súťažia ([2]). V našom modeli je takýmto médiom epizodický zásobník kandidátov.

#### 4.6 Kapacita epizodického zásobníka kandidátov

Schopnosť správnej spätnej rekonštrukcie závisí na dostatočnej kapacite epizodického zásobníka kandidátov (Tab. 2). Pri príliš malej kapacite sú viaceré epizódy (najmä tie, ktoré sú si podobné) reprezentované vo váhach toho istého neurónu, a preto pri rekonštrukcii dochádza k zmiešaniu spomienok, ktoré sa vyskytuje aj v ľudskej pamäti.

## 5 Záver

V tomto článku sme navrhli konekcionistickú architektúru schopnú uchovávať a prehrávať časové sekvencie. Zamerali sme sa najmä na zaujímavé technické vlastnosti ako sú transformácie medzi časovými a priestorovými reprezentáciami a schopnosť reprezentovať viacero súťažiacich

**Tabuľka 2:** Závislosť obsadenosti pamäti a rekonštrukčnej schopnosti od veľkosti epizodického zásobníka kandidátov. Čísla v zátvorkách vyjadrujú smerodajnú odchýlku (SD). Položka „Zmiešané neuróny“ označuje podiel neurónov v mape, ktoré reprezentujú viac ako jednu epizódu, položka „Rekonštrukcia“ označuje úspešnosť spätnej rekonštrukcie (kompatibilitu predikcie z úplných epizód, pozri časť 4.3).

Veľkosť SOM	Zmiešané neuróny	Rekonštrukcia
10 x 10	83,0% (2,4%)	15,5% (1,5%)
20 x 20	16,6% (1,4%)	74,2% (2,2%)
30 x 30	1,3% (0,5%)	95,2% (2,7%)

alternatív súčasne. Naš model je implementáciou Baddeleyho epizodického zásobníka. Presentovaná sieť je len prvým krokom k úplnému modelu epizodickej reprezentácie v pracovnej pamäti, avšak už teraz možno vidieť niekoľko jej zaujímavých aplikácií. V [14] sme opísali detailný model generovania viet, ktorý je založený na myšlienke sekvenčnej reprezentácie sémantiky viet, t.j. epizód. Model prezentovaný v tomto článku rozpracúva túto myšlienku v omnoho väčšej úrovni detailu a je ho možné priamo zapracovať do modelu generovania viet. Takisto vidíme zaujímavú oblasť aplikácie prezentovaného modelu v interpretácii viet. Pravdepodobnostné modely interpretácie viet majú na vstupe sekvencie slov a na výstupe produkujú rozdelenie pravdepodobnosti možných významov – sémantických reprezentácií. Neurálna implementácia takéhoto modelu by mohla generovať epizodické reprezentácie priamo v epizodickom zásobníku kandidátov, ktorý explicitne kóduje rozdelenie pravdepodobnosti možných kandidátskych epizód. Porozumenie významu vety by potom zahŕňalo prehranie SM sekvencie reprezentovanej víťazným kandidátom, v súlade s modernými simulačnými teóriami významu.

## PodĎakovanie

Ďakujeme Ľubici Beňušovej za podnetné diskusie o architektúre modelu. Tento výskum bol financovaný grantami VEGA 1/0439/11 a KEGA 076UK-4/2013.

## Literatúra

- [1] Averbeck, B., Chafee, M., Crowe, D., Georgopoulos, A.: Parallel processing of serial movements in prefrontal cortex. PNAS 99(20), 13172–13177 (2002)
- [2] Averbeck, B., Sohn, J., Lee, D.: Activity in prefrontal cortex during dynamic selection of action sequences. Nature Neuroscience 9(2), 276–282 (2006)

- [3] Baddeley, A.: The episodic buffer: A new component of working memory? *Trends in Cognitive Sciences* 4(11), 417–423 (2000)
- [4] Baddeley, A., Hitch, G.: Working memory. In: Bower, G. (ed.) *The psychology of Learning and Motivation*, pp. 48–79. Academic Press (1974)
- [5] Ballard, D., Hayhoe, M., Pook, P., Rao, R.: Deictic codes for the embodiment of cognition. *Behavioral and Brain Sciences* 20(4), 723–767 (1997)
- [6] Barone, P., Joseph, J.P.: Prefrontal cortex and spatial sequencing in macaque monkey. *Experimental Brain Research* 78, 447–464 (1989)
- [7] Barsalou, L.: Grounded cognition. *Annual Review of Psychology* 59, 617–645 (2008)
- [8] Bullock, D., Rhodes, B.: Competitive queuing for serial planning and performance. In: Arbib, M. (ed.) *Handbook of brain theory and neural networks*, 2ed., pp. 241–244. MIT Press, Cambridge, MA (1996)
- [9] Knott, A.: *Sensorimotor Cognition and Natural Language Syntax*. MIT Press, Cambridge, MA (2012)
- [10] Kohonen, T.: Self-organized formation of topologically correct feature maps. *Biological Cybernetics* 43, 59–69 (1982)
- [11] Lee, A., Wilson, M.: Memory of sequential experience in the hippocampus during slow wave sleep. *Neuron* 36, 1183–1194 (2002)
- [12] Miiikkulainen, R.: Trace feature map: A model of episodic associative memory. *Biological Cybernetics* 67, 273–282 (1992)
- [13] Strickert, M., Hammer, B.: Merge SOM for temporal data. *Neurocomputing* 64, 39–71 (2005)
- [14] Takac, M., Benuskova, L., Knott, A.: Mapping sensorimotor sequences to word sequences: A connectionist model of language acquisition and sentence generation. *Cognition* 125, 288–308 (2012)