

Akvizícia proprioceptívno-dotykových reprezentácií tela u humanoidného robota

Bc. Martin Pecen


Školiteľ: **prof. Ing. Igor Farkaš, Dr.**

Fakulta matematiky fyziky a informatiky
Univerzita Komenského v Bratislave

- Nemluvňatá sa učia o svojom tele samodotýkaním (Rochat, 1998), bez použitia zraku
- Dotyky rúk na dlani a predlaktí
- Cieľ: prepojenie modalít pomocou umelej inteligencie
 - propiocepcia – vnímanie polohy častí tela v priestore
 - dotyk – pozícia dotyku na koži


- Získanie dostatočného počtu dotykových a nedotykových konfigurácií na natrénovanie modelu
- Použili sme simulátor robota iCub

Simulátor robota iCub



- asi 1 meter vysoký, hmotnosť 24kg
- open-source humanoidný robot
- zostrojený v Italian Institute of Technology v Janove
- vybavený umelou kožou
- programovaný vo frameworku YARP

Získavané konfigurácie zo simulátora robota




- Výstupom modulu umelej kože sú vektory pre každú časť tela robota
- 2×16 stupňov voľnosti


Algoritmus na zber konfigurácií

- Potrebujeme počiatočnú pozíciu rúk, smerový vektor na pohyb vpred a pohyb vzad
- iCub sa nastaví na počiatočnú pozíciu
- V cykle
 - Vykoná sa pohyb vpred
 - ak nastal dotyk, zaznamená sa
 - ak nie, prehľadá sa blízke okolie
 - Vykoná sa pohyb vzad
- Cyklus sa vykoná n -krát
- Video

- **Bidirectional Activation-based Learning** (Farkaš and Rebrová, 2013)
 - bez spätného šírenia chyby
 - trénuje sa lokálne prechodom “tam a späť”
 - $\Delta w_{pq} = \alpha a_p^F (b_q^B - b_q^F)$
 - kde a_p^F je presynaptická aktivita smerom dopredu,
 b_q^F je postsynaptická aktivita smerom dopredu
a b_q^B je postsynaptická aktivita smerom dozadu
- Univerzálny BAL (Malinovská et al., 2018) – zložitejšia verzia modelu BAL




Použitie modelu BAL na asociáciu polohy rúk s dotykmi




- BAL ani UBAL sa nedokáže naučiť asociovať proprioceptívne a dotykové vstupy
- Viacvrstvový perceptron zvláda asociovanie
- BAL sa dobre učí sadu zloženú z riedkych binárnych vektorov

Predspracovanie proprioceptívnych vstupov pomocou SOM




- Inšpirovali sme sa biológiou
- Senzorický homonculus (Penfield and Rasmussen, 1950)
- Samoorganizujúce sa mapy




- Maximálne receptívne polia (MRF) (Hoffmann et al., 2017)
- Samoorganizujúce sa mapy
- Maska – určuje RF neurónu

Reprezentácie dotykov na predlaktí natrénovanej MRF-SOM



Reprezentácie dotykov na dlani natrénovanej MRF-SOM





Reprezentácie polohy ľavej ruky na natrénovanej SOM



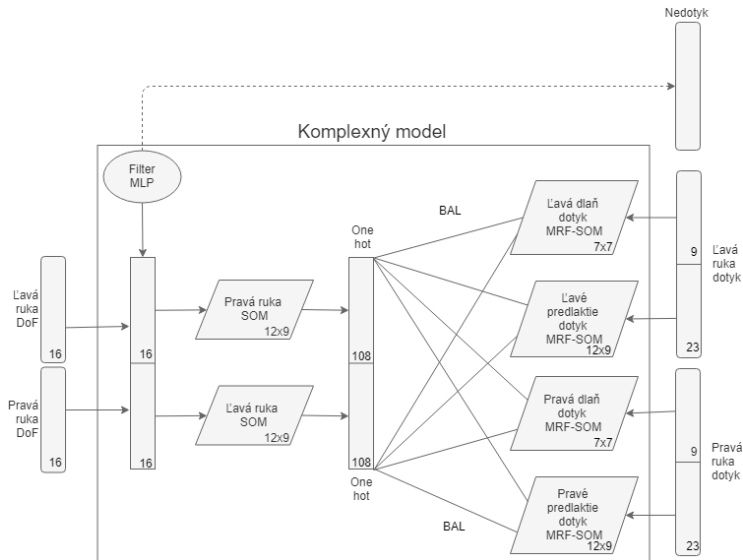
- Upravené vstupné a výstupné dáta sú len binárne vektory s jednou jednotkou
- BAL dokáže asociovať transformované konfigurácie a dotyky
- Úprava dát však spôsobila nepresnosti v dotykoch

Trénovanie BALu na transformovaných dátach



- Veľký počet nedotykových konfigurácií vo vstupných dátach
- Dochádza k nestabilnosti modelu BAL
- Použitie filtra na včasné odstránenie nedotykových konfigurácií zabráni znepresneniu dotykov

Výsledný model



- Filter – 94%
- Filter dokáže správne klasifikovať aj “ďaleké” konfigurácie rúk
- Mapy – Preukazujú schopnosť organizácie vstupných konfigurácií
- Asociátor – 92%

- 50 konfigurácií (30 nedotykových a 20 dotykových konfigurácií)
- Filter nesprávne klasifikoval 2 dotyky a 1 nedotyk
- Asociátor zle klasifikoval 3 dotykové konfigurácie
- 88% úspešnosť

Ďakujem za pozornosť

1. Otázka

Na spracovanie proprioceptívnych informácií bol použitý model SOM, pre každú ruku bola natrénovaná jedna mapa. Tu bola využitá len proprioceptívna časť dát získaných z robota iCub. Na spracovanie dotykových informácií bol použitý model MRF-SOM, pre každú ruku jedna sieť. Sú tieto modely nejakým spôsobom v danom použití závislé (napríklad na dátach)? Je nutné, aby boli použité oba modely?

- Mapy SOM na spracovanie propriocepce boli použité z dôvodu lepšej aproximácie Brodmannovej oblasti 3
- Dáta, ktoré sa majú asociovať sú po mapovaní binárne vektory s jednou jednotkou
- Model MRF-SOM je špecifickou verziou SOM máp pracujúcich na binárnych dátach

2. Otázka

Ako boli stanovené veľkosti SOM (12×9) a MRF-SOM sietí (10×8)? Sú to pomerne malé siete, ale pre ohraničenú oblasť dotykov by mohli stačiť.

- Veľkosti máp sa odvíjali od veľkosti trénovanej množiny
- SOM (12×9 = 108 neurónov) sme použili na mapovanie cca 300 konfigurácií
- MRF-SOM pre dlaň (7×7 = 49 neurónov) sme zvolili tak, aby pokryla všetky jednoduché dotyky
- Na veľkosť MRF-SOM pre predlaktie (12×9 = 108 neurónov) sme prišli empirickým skúšaním

- Farkaš, I. and Rebrová, K. (2013). Bidirectional activation-based neural network learning algorithm. In *International Conference on Artificial Neural Networks*, pages 154–161. Springer.
- Hoffmann, M., Straka, Z., Farkaš, I., Vavrečka, M., and Metta, G. (2017). Robotic homunculus: Learning of artificial skin representation in a humanoid robot motivated by primary somatosensory cortex. *IEEE Transactions on Cognitive and Developmental Systems*, 10(2):163–176.
- Malinovská, K., Malinovský, L., and Farkaš, I. (2018). Towards more biologically plausible error-driven learning for artificial neural networks. In *International Conference on Artificial Neural Networks*, pages 228–231. Springer.
- Penfield, W. and Rasmussen, T. (1950). The cerebral cortex of man; a clinical study of localization of function.
- Rochat, P. (1998). Self-perception and action in infancy. *Experimental Brain Research*, 123(1-2):102–109.