

# Modelovanie uchopovania objektov pomocou neurónových sietí v robotickom simulátore iCub



Bc. Lukáš Zdechovan  
Vedúci práce: doc. Ing. Igor Farkaš, PhD.


# Ciele diplomovej práce

- \* Navrhnuť neurálny model pre kvázi-prirodzené **uchopovanie objektov** (jednou rukou)
- \* Implementovať navrhnutý model v C++ a otestovať ho na rôznych objektoch v **robotickom simulátore iCub**



# iCub

- \* Humanoidná robotická platforma s otvoreným zdrojovým kódom
- \* Európsky projekt vedený konzorciom RobotCub
- \* Robot vo veľkosti 3-ročného dieťaťa
- \* Celkovo **53 rôznych stupňov voľnosti**  
4 rameno, 4 ruka, 8 prsty
- \* Dotykové/Tlakové senzory na rukách
- \* **Simulátor** (OpenGL, ODE)



# iCub Simulátor

- \* Verná softvérová simulácia robota iCub
- \* Špeciálny (YARP) port **world** umožňuje vytvárať a manipulovať objekty na scéne, získavať informácie o pozícii dlaní (efektorov)
- \* Vykonal som určité úpravy simulátora, ktoré mi pomohlo vyriešiť problémy, na ktoré som narazil
- \* Problém s prenosom sily na novej verzii simulátora


A baby with light skin and hair, wearing a blue long-sleeved shirt, is sitting on a white surface. The baby is looking down at a colorful toy in front of them. The toy consists of a red ring with white polka dots, a pink textured ring, and a purple ring with a green ring. The baby's right hand is raised and open, and their left hand is near the toy. A blue horizontal bar is overlaid across the middle of the image, containing the text "Teória uchopovania objektov" in white.

# Teória uchopovania objektov

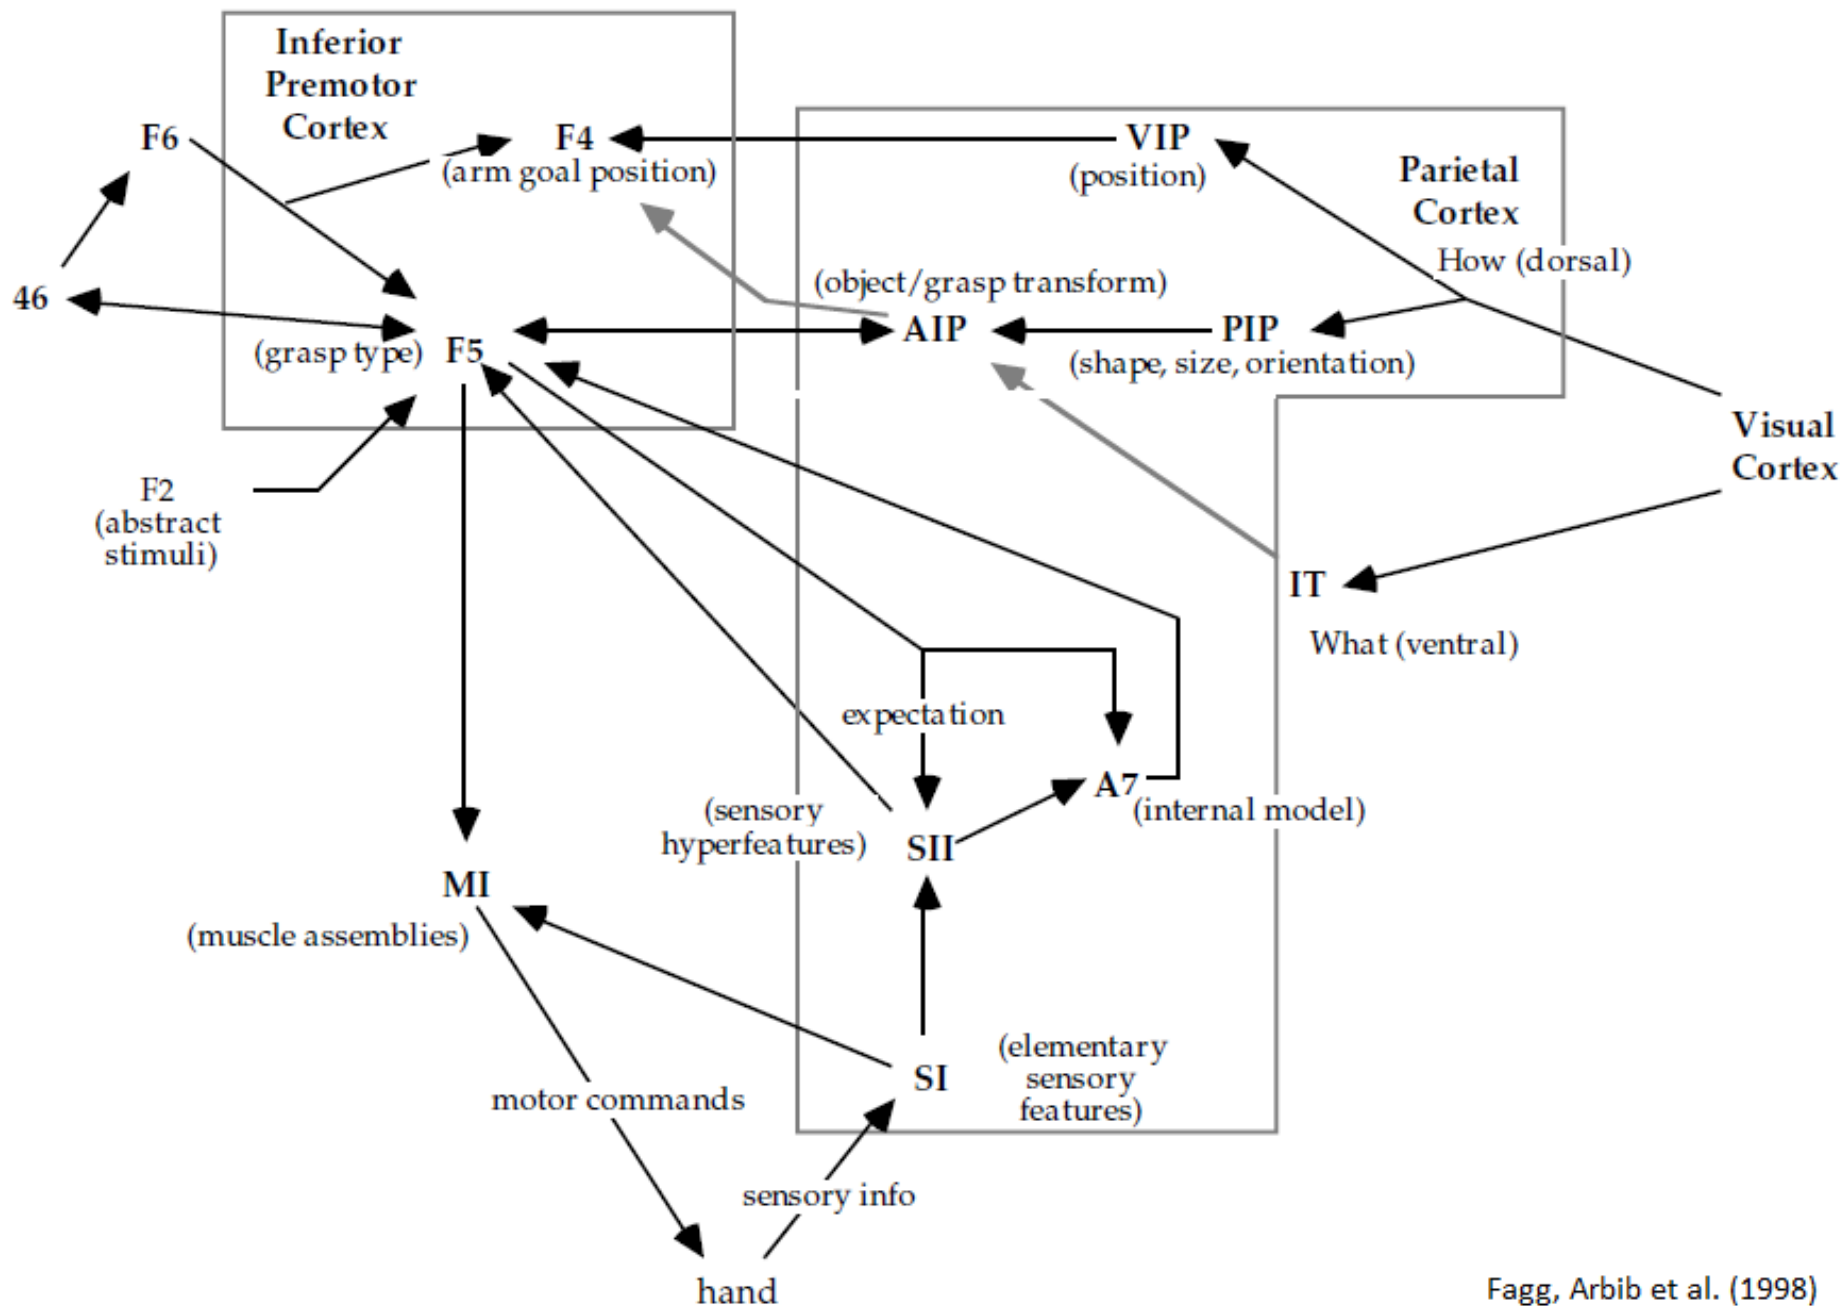
# FARS Model

Fagg, Arbib, Rizzolatti a Sakata (1998)

- \* Biologicky inšpirovaný model uchopovania objektov (výskum na makakských opiciach)
- \* Využitie AIP pre extrakciu afordancií pozorovaného objektu a následné určenie typu uchopenia v F5







# MNS Model II

Mirror Neuron System Model II (Bonaiuto, 2006)

- \* MNS Model 1 bol navrhnutý dvojicou Oztop, Arbib ako model pre rozpoznávanie akcií pomocou zrkadliacich neurónov
- \* V druhej verzii MNS zmenili architektúru siete na viac biologicky plauzibilnú (DNN -> RNN) s učením BPTT
- \* Umožňuje dočasne skryť objekt (rekurentné vstupy simulujú pracovnú pamäť)
- \* Audio-vizuálny vstup, výstupom je typ uchopenia:
  - \* Power grasp, Precision grasp, Side grasp







# **Strojové učenie**

neurálnych modelov pre reaching a grasping

# CACLA

## Continuous Actor-Critic Learning Automaton

- \* Učiaci algoritmus založený na učení s posilňovaním pre spojitý priestor stavov aj akcií
- \* Aktér – generuje akcie na základe stavov
- \* Kritik – ohodnocuje stav po vykonaní akcie
- \* Modelujú sa ako funkčné aproximátory (DNS)
- \* Vyskúšal som rôzne modifikácie aby som urýchlil tréning



---

**Algorithm 2** Modifikovaná CACLA - urýchlenie učenia

---

```
1:  $s_0 \leftarrow$  počiatočný stav
2:  $t_{uc\_odmenou} \leftarrow$  # epizód, ktoré budeme aktéra učiť na
3:  $p_{nahodna} \leftarrow$  pravdepodobnosť vygenerovania úplne náhodnej akcie
4: inicializuj váhy aktéra
5: inicializuj váhy kritika
6: for  $t = 0, 1, 2 \dots$  do
7:    $ac_t \leftarrow A_t(s_t)$ 
8:   if  $rand() \leq p_{nahodna}$  then
9:      $a_t \leftarrow$  vygeneruj náhodnú akciu
10:  else
11:     $a_t \leftarrow$  exploruj  $ac_t$ 
12:  end if
13:  vykonaj akciu  $a_t$  a prejdi do stavu  $s_{t+1}$ 
14:  vypočítaj potenciálny stav  $s_{t+1}$  v prípade vykonania akcie  $ac_t$ 
15:   $r_{t+1} \leftarrow$  odmena z prostredia
16:  if  $(t \leq t_{uc\_odmenou}$  and  $r_{t+1} > r_t)$  then
17:    aktualizuj váhy aktéra:  $A_{t+1}(s_t) \leftarrow a_t$ 
18:  else if  $(t > t_{uc\_odmenou}$  and  $V_t(s_{t+1}) > V_t(s'_{t+1}))$  then
19:    aktualizuj váhy aktéra:  $A_{t+1}(s_t) \leftarrow a_t$ 
20:  end if
21:  aktualizuj váhy kritika:  $V_{t+1}(s_t) \leftarrow r_{t+1} + \gamma V_t(s_{t+1})$ 
22: end for
```

---

# CACLA

## Continuous Actor-Critic Learning Automaton

- \* Naše skúsenosti s učením modelov:
- \* Reaching – pomerne veľký stavový priestor aj priestor akcií – problém s aproximáciou
- \* Grasping – v jednoduchšej forme (univerzálny typ uchopenia) sa iCub učí rýchlo (cca 500 epizód)

# Dosahovanie pozície (Reaching)

- \* Vyskúšali sme desiatky architektúr sietí a rôzne kombinácie parametrov
- \* Jediná cieľová pozícia – naučí sa rýchlo a spoľahlivo
- \* Viac cieľových pozícií – problém s aproximáciou



# Dosahovanie pozície (Reaching)

Zmeny uhlov 0-3 ramena



**W**

Vrstva skrytých neurónov (20-30)

**V**



Uhly 0-3 ramena

Cieľová pozícia

- Plánujeme doplniť neurón(y) určujúce požadované natočenie ruky
- V súčasnosti je dĺžka trajektórie 10-15 krokov
- Rýchlosť učenia 0,01 až 0,001
- Iniciálne váhy z (-0.1, 0.1)
- Aktivačná funkcia: tanh
- Škálovanie (-1.0, 1.0)

# Demo (Reaching)

# Uchopovanie (Grasping)

- \* Scéna s 3 objektami na rôznych miestach na stole
- \* Generujeme kocku, valec a guľu v rôznych veľkostiach
- \* Po cca 500 epizódach tréningovania sa iCub naučí jednoducho uchopovať všetky 3 typy objektov
- \* Zatiaľ umiestňujeme ruku nad objekt natvrdo naprogramovaným pohybom (neskôr by to mal vykonávať reaching modul)
- \* Odmena berie do úvahy vzdialenosť ruky od ťažiska objektu a haptickú informáciu o dotyku s objektom v pomere 1:3

# Uchopovanie (Grasping)

Nové uhly ramena a ruky



**W**

Vrstva skrytých neurónov (30-40)

**V**



Tlakové senzory

# Demo (Grasping)

# Doterajšie výsledky

- \* Implementácia infraštruktúry pre manipuláciu s iCubom a s prostredím simulátora.
- \* Implementácia CACLA algoritmu pre reaching aj grasping
- \* Pomerne dobré výsledky CACLA pre grasping
- \* Slabé výsledky u CACLA pre reaching (doplniť extra učenie)
- \* Pravidelné publikovanie príspevkov na webovom zázpisníku k diplomovej práci <http://masterthesis.zdechovan.com>



# Ďakujem za pozornosť



THESIS GOAL PRESENTATIONS GALLERY

Search

Controlling the iCub

Stanford Reinforcement Learning lectures

ABOUT

## Object reaching with Reinforcement Learning

by ADMIN on NOVEMBER 26, 2010 - 1 COMMENTS

The goal of this post is to capture my progress in learning of **object reaching** on my iCub.

Suppose iCub stands in the front of the object, which is placed on a table, so the robot can reach it without moving other joints than these on one arm.

iCub has to set its arm joint angles (DoF) so that the hand is as closer to the object as possible (it reaches the object).

We use the **Reinforcement Learning** method of Machine learning (actually its Actor-Critic Learning



Lukáš Zdechovan (Author)