


Evolution of obstacle avoidance with spiking neural networks

Bc. Martin Vyšňovský (martinvysnovsky@gmail.com), **Bc. Jozef Šnelcer** (jsnelcer@aol.com)

Naším zadaním bolo vytvoriť program pre robota *Khepera* pomocou spikeovacej neurónovej siete a evolučného algoritmu. Robot sa mal pohybovať po priestore bez toho aby narážal do prekážok. Pre toto zadanie sme sa inšpirovali článkom od Daria Floreana a Francesca Mondada - *Evolution of Plastic Neurocontrollers for Situated Agents*.

Neurónová sieť

V zadaní sme použili malú neurónovú sieť, ktorá obsahovala 9 vstupných neurónov (8 zo sensorov a jeden pre bias), jeden skrytý neurón a 2 výstupné neuróny. V sieti boli použité spikeovacie neuróny podľa článku Eugena M. Izhikevicha - *Simple Model of Spiking Neurons*. Do neurónov na skrytej a výstupnej vrstve boli pripojené spojenia zo vstupnej vrstvy a neurón v skrytej vrstve navyše obsahoval rekurentné spojenie na samého seba.

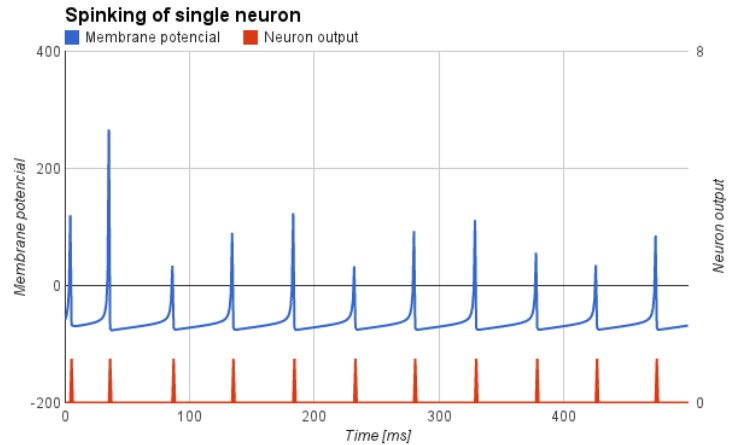



Obr. 1. - Prepojenie neurónov v sieti



Otestovanie činnosti spikeovacieho neurónu

Pri tomto pokuse bolo na vstup neurónu privedené konštantne napätie a zaznamenávaný bol potenciál membrány a výstup neurónu. Výsledné grafické priebehy pre vybrané typy neurónov sú znázornené na nasledujúcich obrázkoch. Vľavo je zobrazený priebeh na reálnom neuróne a vpravo na vytvorenom neuróne (modrou je znázornený potenciál na membráne a červenou výstup neurónu).

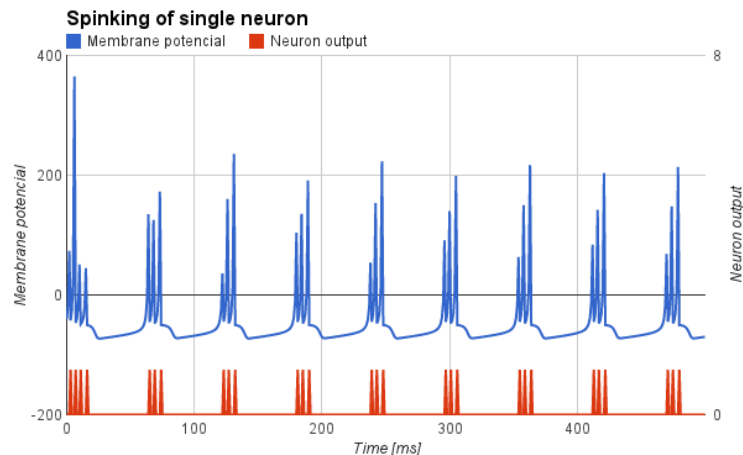

regular spiking (RS)



intrinsically bursting (IB)



chattering (CH)



Evolučný algoritmus

Každý jedinec v evolučnom algoritme bol tvorený 42 premennými:


- 4 premenné pre každý neurón zo skrytej a výstupnej vrstvy (4 * 3)
- 30 váh neurónovej siete

Každá populácia obsahovala 80 jedincov. Na výber rodičov sme využili univerzálnu ruletovú metódu. Kríženie jedincov bolo realizované ako priemer rodičov s pravdepodobnosťou kríženia 0,5 pre každú ich premennú. Následne boli premenné vytvorených potomkov náhodne zmutované s pravdepodobnosťou 0,2. Maximálna veľkosť mutácie bola 5% z celého intervalu. Pre uchovávanie najlepších jedincov sme využili elitizmus, čiže 5 najlepších jedincov je automaticky presunutých do nasledujúcej generácie.

Fitness každého jedinca bol vypočítavaný rovnako ako ho počítal Floreano pri svojich experimentoch - suma čiastkových fitnessov zisťovaných každých 300ms. Čiastkové fitnessy sme počítali podľa vzorca $\phi = V(1 - \sqrt{\Delta v})(1 - i)$. Kde V je priemer absolútnych rýchlostí na oboch kolesách, $\Delta v = (v_{left} + 0.5) - (v_{right} + 0.5)$ je absolútna hodnota rozdielu rýchlostí na oboch kolesách a i je hodnota maximálne aktivovaného senzora.

Vizualizácia


Tento projekt sme vytvorili ako webovú stránku, čiže všetky zdrojové kódy sú napísané v *JavaScripte*. Na vizualizáciu pohybu robota sme vytvorili jednoduchý simulátor, ktorý využíva HTML element *canvas*. Výsledná aplikácia je publikovaná na webovej stránke <http://www.vysnovsky.sk/studium/vyhybanie-sa-prekazkam>.



Obr. 2. - Simulátor pre robota Khepera

Výsledky

Vytvorený program sme nechali prebehnúť cez 30 generácií. Po uplnutí 20 generácií sa postupne začali objavovať jedinci, ktorý sa pri priblížení k prekážke od nej úspešne odklonili a nevrazili do nej. Väčšinou to však dokáli len do jedného smeru. Video najlepšieho jedinca z tejto generácie je zverejnené na adrese <http://youtu.be/je23lEj7o4E>. Graf vývoja fitnessu je znázornený na obrázku 3.



Obr. 3. - Graf maximálneho, priemerného a minimálneho fitnessu v každej generácii.