


Testing different evolutionary neural networks for autonomous robot control

S. Slušný, R. Neruda, P. Kudová



Ústav Informatiky
AV ČR

25. septembra 2007



- 1993 k-team: Khepera
- Priemer 70 mm, váha 80g
- Detekcia bielej prekážky do vzdialenosti 5 cm

Dopredné perceptrónové siete




Vnútorňý potenciál neurónu $\epsilon = \sum_{i=1}^n w_i x_i$

Výstup (stav) neurónu $y = \sigma(\epsilon - h)$

Logistická sigmolda $\sigma(\epsilon) = 1/(1 + e^{-\lambda\epsilon})$

Elmanove siete



- Spočítaj aktiváciu skrytých neurónov, na základe výstupov vstupných neurónov a uschovaných hodnôt z predchádzajúceho kroku
- Vypočítaj aktiváciu výstupných neurónov na základe skrytej vrstvy
- Uschovaj výstupy neurónov pre ďalší krok

RBF siete


- Jedna skrytá vrstva RBF jednotiek

$$y(\vec{x}) = \varphi\left(\frac{\|\vec{x} - \vec{c}\|}{b}\right)$$

- Lineárna výstupná vrstva

- Aktivačná funkcia

$$f_s(\vec{x}) = \sum_{j=1}^h w_{js} \varphi\left(\frac{\|\vec{x} - \vec{c}_j\|}{b_j}\right)$$




Genetický algoritmus

Schéma GA [Holland 1975]

- 1 Vytvor **počiatočnú populáciu**.
- 2 Ohodnot' jedincov **účelovou funkciou**.
- 3 Ak je $i =$ maximálny počet generácií, skonči a vráť riešenie odpovedajúce jedincovi s optimálnou hodnotou účelovej funkcie.
- 4 Vytvorenie novej populácie $P(i + 1)$ z populácie $P(i)$: Aplikuj operátory **selektie, kríženia a mutácie**.
- 5 $i = i + 1$, prejdi k bodu 2.

Schéma GA




Ohodnotenie jedinca

- Maximalizácia účelovej (fitness) funkcie

Algoritmus ohodnotenia

- Pre každý pokus:
 - Inicializuj prostredie
 - Vlož robota na náhodne zvolenú počiatočnú pozíciu
 - Spusti simuláciu (požadovaný počet krokov, kým robot nenarazí)
- Ohodnoť jedinca účelovou funkciou fitness (napr. priemer za jednotlivé pokusy)

- Prehľadaj prostredie - nájdi “zónu“
- Aréna 60x30cm
- Agent žije 250 simulačných krokov



Experiment: Bludisko

Ohodnotenie jedinca

- Pohyb a vyhýbanie prekážkam

$$T_{k,j} = V_{k,j}(1 - \sqrt{\Delta V_{k,j}})(1 - i_{k,j})$$

- Priemerné ohodnotenie za 1 simulačný krok

$$S_j = \sum_{k=1}^{250} \frac{T_{k,j}}{250}$$

- Odmeň, ak agent našiel zónu

$$Fitness = \sum_{j=1}^4 (S_j + \Delta_j)$$

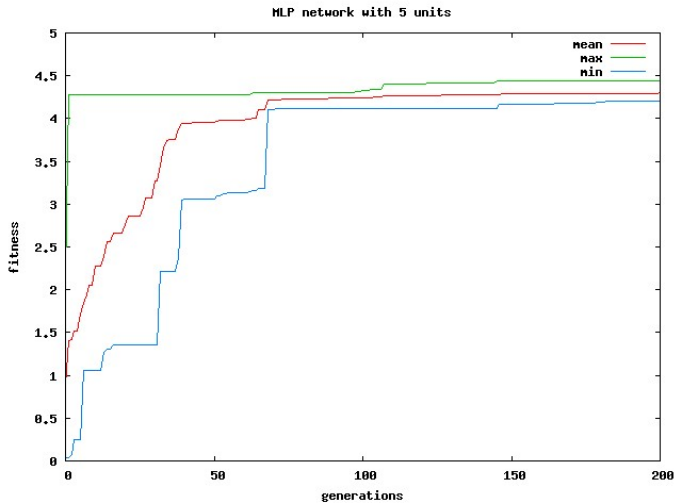
$V_{k,j}$: suma abs. rýchlostí motorov

($V_{k_j} = |v_l| + |v_r|$, $V_{k,j} \in \langle 0, 1 \rangle$)


$i_{k,j}$: hodnota najaktívnejšieho senzora ($i_{k,j} \in \langle 0, 1 \rangle$)

$$\Delta_j = \begin{cases} 1 & \text{agent navštívil zónu} \\ 0 & \text{inak} \end{cases}$$

Priebeh genetického algoritmu



Najlepší agent




Experiment: Steny a prekážky

- Nenarážaj do steny, ale zostaň v blízkosti prekážky
- Aréna 40x40 cm
- 500 krokov simulácie
- Úloha typu 2 [Nolfi 2000]
- Účelová funkcia:

$$T_{k,j} = \begin{cases} 1 & \text{ak je agent v blízkosti prekážky} \\ 0.5 & \text{inak} \end{cases}$$

Najlepší agent



Výsledky - 1. experiment

Typ siete	Bludisko			
	mean	std	min	max
MLP 5 neurónov	4.29	0.08	4.20	4.44
MLP 10 neurónov	4.32	0.07	4.24	4.46
ELM 5 neurónov	4.24	0.06	4.14	4.33
ELM 10 neurónov	3.97	0.70	2.24	4.34
RBF 5 neurónov	3.98	0.90	1.42	4.36
RBF 10 neurónov	4.00	0.97	1.23	4.38

Výsledky - 2. experiment

Typ siete	Steny a prekážky			
	mean	std	min	max
MLP 5 neurónov	2326.1	57.8	2185.5	2390.0
MLP 10 neurónov	2331.4	86.6	2089.0	2391.5
ELM 5 neurónov	2250.8	147.7	1954.5	2382.5
ELM 10 neurónov	2027.8	204.3	1609.5	2301.5
RBF 5 neurónov	1873.8	230.6	1530.0	2146.0
RBF 10 neurónov	2079.4	94.5	2077.5	2359.5

- Jednoduché úlohy
- Reaktívni agenti
- Kolektívne chovanie
- Problémy so zložitejšími neurónovými sieťami