

Umelé neurónové siete





Fig. 3.12. The interconnection pattern in the retina

Umelé neurónové siete


- Súbor jednotiek (**neurónov**) prepojených ohodnotenými spojmi (**synaptické váhy**), ktoré prenášajú signály
- neuróny
 - ◆ vstupné, výstupné a skryté
 - ◆ pracujú paralelne



Neurón


- Realizuje funkciu na váženom súčte jeho vstupov $x_1, x_2, \dots, x_N$
- w_{ij} je váha spoja z i -teho vstupného neurónu do neurónu y_j
- θ_j je tzv. prah neurónu
- Φ je prenosová funkcia

$$y_j = \Phi \left(\underbrace{\sum_{i=1}^N w_{ij} x_i - \theta_j}_{\xi_j \text{ potenciál}} \right)$$




Prenosové funkcie

■ λ je strmota




lineárna

$$\Phi(x) = kx$$



skoková

$$\Phi(x) = \begin{cases} 1 & \text{ak } x > 0 \\ 0 & \text{inak} \end{cases}$$



sigmoida

$$\Phi(x) = \frac{1}{1 + e^{-\lambda x}}$$

bipolárna

$$\Phi(x) = \begin{cases} 1 & \text{ak } x > 0 \\ -1 & \text{inak} \end{cases}$$

$$\Phi(x) = \tanh(\lambda x) \quad \text{do intervalu } (-1, 1)$$

Architektúra NS

- Množina neurónov a ich prepojenie – graf
- často vrstvy: vstupná, výstupná, skryté
- 2 typy:
 - ◆ **s dopredným šírením (feedforward)**
 - ◆ acyklický graf, signály sa šíria od vstupnej vrstvy k výstupnej
 - ◆ **rekurentné**
 - ◆ spoje aj z vyšších vrstiev do nižších, príp. slučky
- θ môže byť váha spoja z dodatočného neurónu s výstupom -1 ; typicky sa však používa virtuálny neurón s výstupom 1

$$y_j = \Phi \left(\underbrace{\sum_{i=1}^N w_{ij} x_i - \theta_j}_{\xi_j \text{ potenciál}} \right) \quad \longrightarrow \quad y_j = \Phi \left(\underbrace{\sum_{i=1}^{N+1} w_{ij} x_i}_{\xi_j \text{ potenciál}} \right)$$

Učenie NS

- výstup siete závisí na nastavení váh; nastavenie váh sa hľadá **učením** – opakovane sa sieti predkladajú vzory a sieť si podľa nich upravuje váhy
 - ◆ **s učiteľom** – podľa chyby na výstupe; s oneskoreným učením (až na základe celkového ohodnotenia siete, bez znalosti presného výstupu)
 - ◆ **bez učiteľa** – samo-organizácia; klasifikácia, kompresia dát
- { **spriahnuté** – (on-line) váhy sa upravujú po predložení každého vzoru
nespriahnuté – (off-line) váhy sa upravujú po predložení všetkých vzorov

zmena váhy

$$w_{ij}^{t+1} = w_{ij}^t + \Delta w_{ij}^{t+1} \quad t \text{ čas}$$

môžu nastať oscilácie, preto


$$w_{ij}^{t+1} = w_{ij}^t + \eta \Delta w_{ij}^{t+1} \quad 0 < \eta \leq 1 \quad \text{učiaca konštanta}$$

Učenie posilňovaním



- Reinforcement – posilňovanie; posilnenie odmenou za správnu reakciu; odmeňovanie
- vtedy, keď je spätná väzba
 - ◆ hrubá – napr. len 1 pre dobre a 0 pre zle
 - ◆ riedka – nie vždy, napr. až po dlhej postupnosti akcií
- cieľ – posilniť akcie, ktoré maximalizujú odmenu,
 1. Ktoré to sú?
 2. Ako medzi ne odmenu rozdeliť?
- agent (robot) musí vyskúšať mnoho dvojíc stav-akcia

Vrstevnaté neurónové siete – algoritmus spätného šírenia



⌘ Trénovacia množina

$$\{(x_1, d_1), (x_2, d_2), \dots, (x_n, d_n)\}$$

■ Postup

1. Predlož vstup x_i na vstupnú vrstvu.
2. Spočítaj výstup y_i .
3. porovnaj skutočný výstup y_i s požadovaným d_i .
4. Rozdiel použi na úpravu váh.

Trik: *Prahy sa nahradia vstupom z virtuálneho neurónu, ktorý dáva vždy výstup 1. Každá vrstva okrem výstupnej má práve jeden taký neurón.*

Algoritmus spätného šírenia (chyby)

- **Cieľ:** nájsť váhy také, aby pre všetky vstupné vzory z trénovacej množiny skutočný výstup siete bol rovnaký ako požadovaný výstup siete.
- Nie je špecifikovaná skutočná ani požadovaná aktivita na skrytých neurónoch
- Celková chyba siete – chybová funkcia siete – vyjadruje rozdiel medzi požadovaným a skutočným výstupom siete

$$E = \frac{1}{2} \sum_p \sum_j (y_{j,p} - d_{j,p})^2$$

p indexuje vzory z trénovacej množiny

$y_{j,p}$ skutočná aktivita výstupného neurónu j pri vstupe x_p

$d_{j,p}$ požadovaná aktivita výstupného neurónu j pri vstupe x_p

$$d_j = (d_{j1}, \dots, d_{jp})$$


Algoritmus spätného šírenia

- Aktualizácia synaptických váh $w_{ij}(t+1) = w_{ij}(t) + \Delta_E w_{ij}(t)$
- $\Delta_E w_{ij}(t)$... prírastok váhy w_{ij} prispievajúci k minimalizácii E
- Pre výstupnú vrstvu platí

$$\begin{aligned}\Delta_E w_{ij} &= -\frac{\partial E}{\partial w_{ij}} = -\frac{\partial E}{\partial \xi_j} \frac{\partial \xi_j}{\partial w_{ij}} = -\frac{\partial E}{\partial \xi_j} \frac{\partial}{\partial w_{ij}} \sum_k w_{kj} y_k = \\ &= -\frac{\partial E}{\partial \xi_j} y_i = -\frac{\partial E}{\partial y_j} \frac{\partial y_j}{\partial \xi_j} y_i = -(y_j - d_j) f'(\xi_j) y_i = \delta_j y_i\end{aligned}$$

$$\xi_j = \sum_{k=1}^N w_{kj} y_k \quad y_j = f(\xi_j) = \frac{1}{1 + e^{-\lambda \xi_j}}$$

$$E = \frac{1}{2} \sum_p \sum_j (y_{j,p} - d_{j,p})^2 \quad f'(\xi_j) = y_j(1 - y_j) \lambda$$




Algoritmus spätného šírenia

■ Pre skryté vrstvy

$$\xi_j = \sum_{k=1}^N w_{kj} y_k$$

$$\begin{aligned}\Delta_E w_{ij} &= \frac{\partial E}{\partial \xi_j} \frac{\partial \xi_j}{\partial w_{ij}} = - \sum_k \frac{\partial E}{\partial \xi_k} \frac{\partial \xi_k}{\partial y_j} \frac{\partial y_j}{\partial \xi_j} y_i = \\ &= - \left(\sum_k \frac{\partial E}{\partial \xi_k} \frac{\partial}{\partial y_j} \sum_j w_{jk} y_j \right) \cdot \frac{\partial y_j}{\partial \xi_j} \cdot y_i = - \left(\sum_k \frac{\partial E}{\partial \xi_k} w_{jk} \right) \cdot \frac{\partial y_j}{\partial \xi_j} \cdot y_i = \\ &= \left(\sum_k \delta_k w_{jk} \right) \cdot f'(\xi_j) \cdot y_i = \delta_j y_i\end{aligned}$$

$$E = \frac{1}{2} \sum_p \sum_j (y_{j,p} - d_{j,p})^2 \quad y_j = f(\xi_j) = \frac{1}{1 + e^{-\lambda \xi_j}}$$



Algoritmus spätného šírenia

- 1. krok:** zvol' náhodné hodnoty synaptických váh
- 2. krok:** predlož nový trénovací vzor $(\vec{x}, \vec{d})$ v tvare
(vstup, požadovaný výstup)
- 3. krok:** vypočítaj skutočný výstup siete; aktivita neurónu

$$y_j = f(\xi_j) = \frac{1}{1 + e^{-\lambda \xi_j}}, \text{ kde } \xi_j = \sum_i y_i w_{ij}$$

- 4. krok:** Aktualizuj váhy postupne smerom od výstupnej vrstvy k vstupnej vrstve. Váhy sa adaptujú podľa:

$$w_{ij}(t+1) = w_{ij}(t) + \alpha \delta_j y_i + \alpha_m (w_{ij}(t) - w_{ij}(t-1))$$

kde pre výstupné neuróny
a pre skryté neuróny

$$\begin{aligned} \delta_j &= (d_j - y_j) y_j (1 - y_j) \lambda \\ \delta_j &= \lambda y_j (1 - y_j) \sum_k \delta_k w_{jk} \end{aligned}$$

- 5. krok:** pokračuj **krokom 2**

Označenie

- $w_{ij}(t)$... váha z neurónu i do neurónu j v čase t
 - α ... parameter učenia $\in \langle 0, 1 \rangle$
 - α_m ... moment učenia $\in \langle 0, 1 \rangle$
 - k ... označuje neuróny z vrstvy nad neurónom j
 - ξ_j ... celkový vážený vstup neurónu j
 - λ ... strmosť prenosovej funkcie
-
- Je to teda gradientná metóda, ktorá minimalizuje strednú kvadratickú odchýlku medzi požadovanou a skutočnou aktivitou všetkých výstupných neurónov systému


Rekurentné neurónové siete

- detekcia časových závislostí v časovom rade
- okienko
 - ◆


2	13	22	5	32	14	7	81	2	28	24
---	----	----	---	----	----	---	----	---	----	----
- Neurónové siete s časovým posunom (time delay neural network)
 - ◆ aké veľké okienko? nárast počtu váh
- inak: rekurentné siete – spätné spoje,
 - ◆ s diskretným časom, alebo
 - ◆ so spojitým časom (rekurentné signály a vstupy sú kontinuálne integrované)

Rekurentné siete

■ Elman



Jordan



- **Elman** – pamäťové bunky uchovávajú stav skrytých neurónov z predchádzajúceho kroku
- **Jordan** – pamäťová bunka počíta svoj stav z výstupu siete a svojho stavu v predchádzajúcom kroku

Evolučný vývoj a NS



■ Prečo NS?

- relatívne hladký prehľadávaný priestor
- rôzne úrovne evolučnej granularity:
 - fylogenetická (evolučná) – iba GA
 - vývojová (dozrievanie) – sieť „dorastie“
 - ontogenetická (celoživotné vzdelávanie) – sieť sa učí
- môžu byť kombinované
- NS poskytujú priamočiare zobrazenie senzory → motory
- analógové vstupy na analógové alebo diskkrétne výstupy
- robustnosť voči šumu


■ biologicky motivovaný model adaptívneho chovania

Evolučný vývoj NS

Problémy s učením



Skupina 1

AB CD EF



Skupina 2

BA EF CD



■ súperiace skupiny

- ♦ veľmi odlišné genotypy zodpovedajú sieťam s veľmi podobným chovaním
⇒ viac maxím; kríženie vedie na slabých jedincov
- ♦ v praxi to väčšinou nevadí, ale často sa volí nižšia pravdepodobnosť kríženia

Evolúcia váh a parametrov učenia

■ Prečo

- ◆ A) GA skúšajú celú populáciu sietí, nie len jednu sieť
- ◆ B) bez obmedzení na architektúru, prenosovú funkciu, ...
- ◆ C) nepotrebuje detailne poznať výstup siete pre každý vzor

■ Kódovanie váh:

- ◆ reťazec reálnych čísel
- ◆ reťazec binárnych čísel – ako čísla s pevnou desatinnou čiarkou so zadanou presnosťou
 - ♦ Varianta: **dynamické kódovanie**
 - čísla v kóde na začiatku učenia najvýznamnejšie bity,
 - neskôr (keď je nájdené uchádzajúce riešenie) tie isté čísla kódujú menej významné bity

■ **príklad:** *analýza sonarových signálov – GA lepšie než BP*

■ iná stratégia: kombinácia evolúcie a učenia s učiteľom

- ◆ BP je citlivé na počiatočné nastavenie váh
- ◆ GA môže nájsť počiatočné nastavenie váh – fitness=chyba siete po doučení algoritmom BP (Darwinistická evolúcia)

■ gén môže kódovať i iné parametre učenia

Evolúcia architektúry

- Priestor možných architektúr je nekonečný a nie je derivovateľný (nedá sa prehľadávať gradientnými metódami)
- kódovanie:
 - ◆ typicky „**nepriame kódovanie**“: kódujú sa iba niektoré charakteristiky siete – počet neurónov, pravdepodobnosť ich spojenia, typ prenosovej funkcie, ...; váhy sa doladia učením
 - ◆ „priame kódovanie“
- **príklad 1:** *gen. kód obsahuje plán budovania siete – postupnosť segmentov zodpovedajúcich vrstvám; segment*
 - ◆ *vlastnosti uzlov (počet neurónov, prenosová funkcia, geometrické rozloženie)*
 - ◆ *vlastnosti vychádzajúcich spojov (hustota spojov, parametre učenia)*
 - ◆ *dekódovaná sieť sa učí BP*
 - ◆ *vo fitness sa dá penalizovať počet spojov alebo počet cyklov učenia*

Evolúcia architektúry

- **Príklad 2:** *genotyp kóduje prepisovacie pravidlá, výsledkom prepisovania je binárna matica spojov medzi neurónmi, váhy sa doučujú BP*

$$\varepsilon \rightarrow \begin{bmatrix} A & B \\ C & D \end{bmatrix}$$

$$A \rightarrow \begin{bmatrix} a & d \\ a & a \end{bmatrix} \quad B \rightarrow \begin{bmatrix} c & b \\ b & a \end{bmatrix} \quad C \rightarrow \begin{bmatrix} b & a \\ a & c \end{bmatrix} \quad D \rightarrow \begin{bmatrix} a & b \\ a & d \end{bmatrix}$$

$$a \rightarrow \begin{bmatrix} 0 & 0 \\ 0 & 1 \end{bmatrix} \quad b \rightarrow \begin{bmatrix} 1 & 0 \\ 0 & 0 \end{bmatrix} \quad c \rightarrow \begin{bmatrix} 0 & 0 \\ 1 & 0 \end{bmatrix} \quad d \rightarrow \begin{bmatrix} 0 & 1 \\ 0 & 0 \end{bmatrix}$$

$$\varepsilon \Rightarrow \begin{bmatrix} A & B \\ C & D \end{bmatrix} \Rightarrow \begin{bmatrix} a & d & c & b \\ a & a & b & a \\ b & a & a & b \\ a & c & a & d \end{bmatrix} \Rightarrow \begin{bmatrix} 0 & 0 & 0 & 1 & 0 & 0 & 1 & 0 \\ 0 & 1 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 1 & 0 & 0 & 0 & 1 \\ 1 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 1 & 1 & 0 & 0 & 1 & 0 & 0 \end{bmatrix}$$

Evolúcia architektúry



- **Príklad 3:** *„dozrievanie“ – sieť rastie v dobe, keď sa robot pohybuje vo svete*
 - ◆ *NS je 2D pletivo, genotyp kóduje*
 - ◆ *pozíciu neurónu v pletive*
 - ◆ *smer rastu axónov*
 - ◆ *dĺžku axónov, ...*
 - ◆ *axón, ktorý končí tam, kde nie sú žiadne neuróny, odumiera, inak vytvára synaptické spoje*
 - ◆ *rast závisí aj na aktivite robota*

Evolúcia pravidiel učenia

- **Pravidlo učenia (Heb):** *funkcia presynaptickej aktivity x_j , postsynaptickej aktivity y_i a aktuálnej váhy w_{ij}*

$$\Delta w_{ij} = \Phi(x_j, y_i, w_{ij})$$

- predpíše sa ako lineárna kombinácia súčinov premenných





$$\Delta w_{ij} = a_1(x_j x_j) + a_2(x_j y_i) + a_3(x_j w_{ij}) + a_4(y_i y_i) + a_5(y_i w_{ij}) + a_6(w_{ij} w_{ij})$$

- a_n buď diskrétna hodnota z $\{-1, 0, 1\}$ alebo spojitá hodnota z intervalu $<-1, 1>$; genotyp obsahuje hodnoty konštant
- fitness: váhy sa nastavujú náhodne a sieť sa trénuje dekodovaným pravidlom učenia a jej fitness je jej výkon

GENETICKÉ PROGRAMOVANIE

- Genetický reťazec nekóduje riešenie problému, ale program riešiaci problém
 - založené na LISPovskej reprezentácii programov
 - ◆ (f,a,b) ... f funkcia, a,b argumenty
 - ◆ $(+,2,5)$ zodpovedá výrazu $2+5$
 - ◆ $(+,2,(*,3,7))$... $2+(3*7)$
1. zvolí sa množina funkcií F a terminálov T . Napr.
 $F=\{+,-,*,\%,IFLTE\}$, $T=\{X,Y,Z,\mathfrak{R}\}$, kde $\%$ je bezpečné delenie (vracia 1 pri delení nulou), $IFLTE$ je „if-less-than-or-equal“, $\mathfrak{R}$ je náhodné číslo.
Funkcie musia byť uzavreté, tj. všade definované
 2. Náhodne sa vygeneruje počiatočná populácia programov
 3. Ďalej ako GA – selekcia, kríženie, mutácia.

Genetické programovanie



■ **Kríženie:** krížením 2 programov má vzniknúť zase funkčný (syntakticky správny) program – zámena podstromov medzi náhodne zvolenými uzlami

- ♦ dvoch rodičov alebo
- ♦ samotného jedinca

Genetické programovanie



- **Mutácia:** náhodne sa zvolí uzol a
 - ◆ buď sa zruší, alebo
 - ◆ na jeho mieste sa náhodne vytvorí nový podstrom
- mutácie sa nepoužívajú často, miesto toho sa pracuje s veľkými populáciami a veľkou pravdepodobnosťou kríženia
- **hypotéza:** *náhodné programy vyjadrené v LISPe majú vyššiu pravdepodobnosť, že sú správne, než iné reprezentácie*
- vylepšenie: *automaticky definované funkcie* – funkcia nahradzujúca celý podstrom

GRAMATICKÁ EVOLÚCIA

- Evolúcia programu v ľubovoľnom programovacom jazyku
- Používa lineárny genóm (GP stromy)
- Genóm = postupnosť kodónov (obyčajne 8 bitov)
- Zobrazenie genotyp → fenotyp konštruuje odvodenie programu podľa gramatiky:
 - ◆ Ak X je najľavejší neterminál v reťazci, tak číslo pravidla použitého na prepísanie X sa spočíta ako (*kodón* mod *počet pravidiel pre X*)
 - ◆ Kodóny sa aplikujú jeden za druhým, po poslednom kodóne sa pokračuje znova od prvého
 - ◆ Ak po dopredu zadanom počte „cyklov“ cez celý kodón reťazec stále obsahuje neterminály, tak jedinec je označený ako nepoužiteľný a dostáva minimálnu možnú hodnotu fitness

Príklad gramatickej evolúcie

Gramatika

```
<expr> ::= <expr><op><expr> (0)
          | <var>                (1)

<op> ::= + (0)
        | - (1)
        | * (2)

<var> ::= x (0)
        | y (1)
```

Genotyp $\rightarrow$ fenotyp

154: <expr>

Genotyp

154	37	211	92	254	79	143
-----	----	-----	----	-----	----	-----

EVOLÚCIA ROBOTOV



■ Okruhy problémov:


- ◆ mechanická odolnosť: nárazy do stien vo veľkej rýchlosti
- ◆ prívod energie: batérie nestačia
- ◆ analýza: vyvinuté riadiace systémy môžu byť veľmi zložité; na ich popis je možné využiť metódy z neuroetológie
- ◆ časová náročnosť: hodiny, dni i týždne
- ◆ návrh fitness funkcie

a) evolúcia fyzických robotov – Khepera

b) simulovaná evolúcia – minimalistická simulácia

c) priestor fitness

Khepera



- 1993:
- www: www.k-team.com
- simulátor: <http://diwww.epfl.ch/lami/team/michel/khep-sim/>
- parametre:
 - ◆ priemer 55 mm
 - ◆ hmotnosť 70 g
 - ◆ dve samostatne poháňané kolá s inkrementálnymi enkodérmi (600 pulzov/otáčka)
 - ◆ 8 aktívnych infračervených senzorov;
 - ♦ 2 režimy
 - „pasívny“ - meria infračervené svetlo z okolia; pozor na zdroje tepla
 - „aktívny“ - vysiela infra svetlo a meria odrazené svetlo – detekuje biely papier na 5 cm; distančný senzor – detektor prekážok
 - ♦ režimy sa prepínajú softwarovo a veľmi rýchle – je možné snímať oboje naraz

Khepera




- Parametre – pokračovanie
 - ◆ akumulátory – 30-40 min. samostatnej činnosti
 - ◆ CPU Motorola MC68331, 128 kB EEPROM, 256 kB statickej RAM
 - ◆ A/D prevodník, RS232
- miniaturizácia:
 - ◆ pracovný stôl 0,9 x 1,8 m je pre Kheperu priestor ekvivalentný tenisovému ihrisku pre robota s priemerom 55 cm
 - ◆ na malom priestore sa dá jednoduchšie (technicky) sledovať
 - ◆ náraz 55 mm Khepery pri rýchlosti 55 mm/s verzus náraz 1 m robota pri rýchlosti 1 m/s
- modularita: možnosti rozšírenia
 - ◆ nástavce: lineárne videnie – 64-pixelový riadok, uhol 36°
 - ◆ chápadlo s 2 stupňami voľnosti
 - ◆ rozširujúca doska

Khepera

- Pripojenie rotačnými kontaktmi

- ◆ spojenie s počítačom
- ◆ dlhodobá práca



- 2 režimy

- ◆ interaktívny – riadenie z počítača – častejšie
- ◆ autonómny – riadenie na robote

- Analýza vyvinutého riadiaceho systému nie je možná oddelene od jeho okolia, preto je užitočné mať možnosť presne merať polohu robota


Ďalšie roboty

■ **Koala:** príbuzný robot

- ◆ rozmery: d x š x v 32 x 32 x 20 cm, 3 kg
- ◆ 2 motory, 6 kôl, 16 infračervených senzorov
- ◆ softwarovo kompatibilná s Kheperou



■ **Koala II:** novšia verzia



■ Khepera II

- ◆ Motorola 68331, 25MHz
- ◆ priemer 70 mm

■ Hemison



Ďalšie roboty – pokračovanie

- Khepera III (Linux)



- e-Puck



Ďalšie roboty – pokračovanie

■ KiloBot

- ◆ <http://www.k-team.com/mobile-robotics-products/kilobot/introduction>
- ◆ Priemer 33 mm, výška 34 cm i s nohami
- ◆ Vibračné motory
- ◆ Komunikácia so susednými robotmi do vzdialenosti 7 cm (odrazom infračerveného svetla od podlahy)

