


Siete Neural Gas pri navigácii v cestných sieťach (2)

V prvej časti seriálu uverejneného v čísle 11/2008 AT&P journalu sme sa venovali princípu sietí typu Neural Gas. V tejto časti v nej budeme pokračovať.

Na obr. 1 je podľa jednotlivých adaptačných krokov zobrazený postup učenia siete NG na opis medzikružia (sivá plocha) [4], kde možno pozorovať aj vplyv parametrov ($\lambda_p = 10$, $\lambda_z = 0,01$, $\gamma_p = 0,5$, $\gamma_z = 0,005$, $t_{max} = 40\,000$, $T_p = 20$, $T_z = 200$) s postupujúcim časom adaptácie. Pre prehľadnosť zobrazenia v obr. 1b) – 1e) nie sú vyznačené prepojenia medzi neurónmi.

V prvých fázach učenia dochádza k adaptácii bodov v značne rozsiahlom okolí vstupu ξ , čo sa prejavuje na globálnej úrovni masívnym preskupovaním veľkého počtu bodov do tvaru podobného danému priestoru. Neskoršie vplyv adaptačných parametrov $h(t, k)$ a $g(t)$ slabne, takže adaptácia sa prejavuje iba v blízkom okolí vstupu ξ , t. j. na lokálnej úrovni sa jednotlivé referenčné vektory snažia rovnomerne pokryť daný priestor. Tento jav je typický pre rôzne tvary opisovaného priestoru [3].



Obr.1 Pribeh učenia siete NG s konkurenčným Hebbovým učením na medzikruží

1.1 Rastúca sieť Neural Gas

Značným obmedzením predošlého prístupu je fakt, že treba vopred zadať pevný počet bodov neurónov výstupnej siete, ktorého odhad môže byť veľmi problematický. Okrem toho ďalšou vítanou vlastnosťou by bola možnosť zabudovania kritéria kvality priamo ako ukončovacej podmienky učenia. Tieto požiadavky viedli k návrhu modifikovaného prístupu sietí NG s inkrementálnym učením pod názvom rastúca sieť NG (RNG) [2], ktorý však využíva zmienené algoritmy.

RNG začína svoje učenie s dvomi štartovacími neurónmi. Na rozšírovanie ich počtu a samotné umiestnenie využíva jednak heuristiku a jednak tzv. chybu kvantovania E_c jednotlivých neurónov c_i , v ktorej sa akumulujú kvadratické chyby vektora w_S daného neurónu vzhľadom na vstup ξ , t. j.:

$$E_c = \sum \|\xi - w_S\|^2 \quad (5)$$

v prípade, ak je víťazom, t. j. neurónom s najväčšou chybou zo všetkých ostatných (v ďalšom bod $S1$). Úlohou učenia je vykonať kvantovanie daného priestoru takým spôsobom, aby celková chyba kvantovania E , čiže $\sum E_{c_i}$ pre $i = 1, \dots, N$ bola minimálna. Zo skúsenosti (heuristika) sa dá pre väčšinu prípadov predpokladať, že vloženie ďalšieho neurónu sa E môže iba zmenšiť a že najlepší účinok sa dosiahne, ak sa nový bod r bude nachádzať v „blízkosti“ $S1$. Na určenie „blízkosti“ slúži ďalšia heuristika, keď sa použije bod $S2$, ktorý má zo všetkých priamo prepojených susedov $S1$ najväčšiu E_c . Nový referenčný vektor w_r sa potom umiestni uprostred medzi $S1$ a $S2$:

$$w_r = (w_{S1} + w_{S2})/2 \quad (6)$$


Následne sa zruší prepojenie medzi $S1$ a $S2$ a vytvoria sa nové dve medzi $S1$ a r , ako aj $S2$ a r . Zároveň sa zredukujú chyby bodov $S1$ a $S2$ o hodnoty $\alpha \cdot E_{c1}$ a $\alpha \cdot E_{c2}$, kde α je parameter redukcie chyby kvantovania. Keďže je zjavné, že ani bod r úplne neodstráni celkovú chybu kvantovania, je mu priradená analogicky ako v (6) istá začiatočná chyba $E_r = (E_{c1} + E_{c2})/2$.

Na rozdiel od sietí NG sa adaptujú iba referenčné vektory $S1$ a jeho priamych susedov, takže môžeme hovoriť iba o lokálnej adaptácii s rovnomerným narastaním výstupných neurónov, ako to možno vidieť na obr. 2, čo je tiež určitou výhodou z hľadiska jednoduchšej analýzy procesu učenia. Keďže adaptácia referenčných vektorov je iteratívny proces, tak vkladanie nového bodu sa bude vykonávať iba v adaptačných krokoch, ktoré sú celým násobkom parametra τ . Ďalšími rozdielmi oproti sieti NG sú časovo konštantné parametre učenia pre $S1$ a jeho všetkých priamych susedov S_i , t. j. γ_{S1} a γ_{S_i} , ako aj maximálny vek prepojenia T . V každom adaptačnom kroku sa predpokladá isté zlepšenie presnosti siete, preto sa chyba kvantovania E_{c_i} pri každom neuróne c_i vždy zmenší o hodnotu $\beta \cdot E_{c_i}$.

Postup učenia siete RNG možno opísať takto:

1. V rámci inicializácie sa náhodne zvolia dva štartovacie neuróny z oblasti, ktorú chceme opísať. Množina prepojení bude zatiaľ prázdna.
 2. Vygeneruje sa vstupný signál ξ a zistí sa bod $S1$ s najväčšou chybou E_{c1} zo všetkých bodov $c_i \in A$. Následne sa určí bod $S2$ ako priamy sused k $S1$, tiež s najväčšou chybou E_{c2} zo všetkých priamych susedov k $S1$. Body $S1$ a $S2$ sa prepoja a vek tohto prepojenia sa nastaví na 0. Ak už prepojenie je, vynuluje sa vek.
 3. Pre c_1 sa aplikuje (5) a adaptujú sa referenčné vektory $S1$, ako aj jeho všetkých priamych susedov podľa:
- $$\Delta w_{S_i} = \gamma_i (\xi - w_{S_i}) \quad (7)$$
- pre $i = 1, 2, \dots$, pričom sa zároveň inkrementuje vek týchto prepojení.
4. Ak nejaké prepojenia dosiahnu vek T , tak sa odstránia, ako aj všetky body bez prepojení.
 5. Ak adaptačný krok dosiahne celočíselný násobok τ (ak nie, tak bod č. 6), vloží sa nový bod r (6), upraví sa prepojenia a chyby pre $S1$, $S2$ a r .
 6. Pre každý neurón c_i sa chyba kvantovania E_{c_i} zmenší o hodnotu $\beta \cdot E_{c_i}$.
 7. Ak nie je splnená ukončovacia podmienka (napr. maximálna veľkosť siete či minimálna chyba), výpočet bude pokračovať ďalším adaptačným krokom v bode 2.

Na obr. 2 je znázornený pribeh učenia sa siete RNG podľa jednotlivých adaptačných krokov na príklade medzikružia ($\tau = 300$, $\gamma_{S1} = 0,05$, $\gamma_{S_i} = 0,0006$, $\alpha = 0,5$, $\beta = 0,0005$, $T = 88$, $N = 100$) [4]. Porovnaním



Obr.2 Pribeh učenia siete RNG na medzikruží

obr. 1 a obr. 2 možno vidieť rozdiely v spôsobe učenia sa klasických sie-
tí NG a RNG, avšak získané výsledky (obr. 2h) sú takmer totožné.

Literatúra

(vybrané tituly)

[1] DUDEK, G., JENKIN M.: Computational Principles of Mobile Robotics. Cambridge University Press, Cambridge, ISBN 0-521-56021-7, 2000.

[2] FRITZKE, B.: A growing neural gas network learns topologies. In: Advances in Neural Information Processing Systems 7; MIT Press Cambridge, USA, 1995, pp. 625 – 632.

[3] FRITZKE, B.: Some competitive learning methods. 1997, pp. 45, <cite-seer.ist.psu.edu/fritzke97some.html> [cit. 22.7. 2008].

[4] FRITZKE, B.: Vektorbasierte Neuronale Netze (habilitačná práca). Shaker Verlag, 1998, pp. 157,

<<http://www.ki.inf.tu-dresden.de/~fritzke/>> [cit. 22.7. 2008].

Pokračovanie v budúcom čísle.

Dr. Ing. Ján Vaščák

Ing. Martin Rutrich

Technická univerzita v Košiciach
Fakulta elektrotechniky a informatiky
Katedra kybernetiky a umelej inteligencie
Letná 9, 042 00 Košice
e-mail: Jan.Vascak@tuke.sk

26