

# Siete Neural Gas pri navigácii v cestných sieťach (1)

Kvalita metód navigácie mobilných prostriedkov závisí v prvom rade od presnosti popisu oblasti pohybu týchto prostriedkov. Článok sa zaoberá sieťami typu Neural Gas (NG), ktorých úlohou je vytváranie topológie zložitých objektov, ako sú napr. cestné siete mestských komunikácií, pri ktorej realizácii treba vytvoriť aj vzťahy (prepojenia) medzi prvkami danej oblasti, v našom prípade sieť navzájom prepojených komunikačných uzlov. Navrhnutý prístup kombinuje okrem sietí NG aj stromové prehľadávacie algoritmy, konkrétne A\*, pomocou ktorých možno zahrnúť rôzne obmedzovacie podmienky, napr. dopravné predpisy. Činnosť navrhnutého algoritmu je ukázaná na cestnej sieti mesta Košice.

## Úvod

V súčasnosti možno rozlíšiť tri základné skupiny metód navigácie mobilných prostriedkov: heuristické, mriežkové a exaktné algoritmy [1]. Typickým reprezentantom prvej skupiny sú Bug algoritmy, ktoré sú jednoduché, ale vhodné väčšinou iba na obchádzanie menšieho počtu prekážok, najmä v úlohách na odstraňovanie bezprostredných kolízií. Najznámejším predstaviteľom mriežkových algoritmov sú potenciálové polia opísané napr. v [13]. Avšak tie vyžadujú nielen vytvorenie celého potenciálového poľa vopred, ale v prípade zmeny prostredia (napr. pri vzniku novej prekážky) treba opäť nanovo vytvoriť celé pole, pričom výpočtové nároky sú značne vysoké. Exaktné algoritmy, ako grafy viditeľnosti a Voronoiove diagramy, umožňujú matematicky korektným spôsobom nájsť najlepšiu (v tomto zmysle najkratšiu) trajektóriu. V prípade nemožnosti nájsť riešenie sú dokonca schopné výpočtový proces ukončiť, a tak predísť zacykleniu algoritmu. V prípade zmeny prostredia reprezentovaného týmito grafmi stačí vykonať potrebné úpravy iba v danej konkrétnej časti. Ich problémom je však to, že vyžadujú veľmi presné údaje o prekážkach, čo v praktických aplikáciách môže byť vážny problém.

Siete NG sú vo svojej podstate grafy, pomocou ktorých možno modelovať tvar daných obrazcov, podobne ako Kohonenove siete, avšak na rozdiel od nich nemajú pevnú topológiu prepojení výstupnej vrstvy, čo sa ukazuje výhodným najmä v prípade nehomogénnych oblastí. Ich schopnosť presného opisu daného obrazca sa porovnávala vzhľadom na iné typy neurónových sietí a potvrdila sa aj v prácach, napr. [5], [11], [15]. Preto sa javí veľmi výhodným ich použitie práve pri opise cestnej siete s rôzne tvarovanými a veľkými komunikáciami. Okrem toho možno s využitím modifikácie prehľadávacieho algoritmu zabudovať do opisu rôzne obmedzujúce podmienky, ako sú dopravné predpisy alebo po istej úprave aj hustota premávky. Vhodná grafová štruktúra sietí NG umožňuje navyše veľmi efektívnu činnosť prehľadávania pomocou modifikovaných prehľadávacích algoritmov.

Tento článok sa v úvodnej časti zaoberá opisom princípov sietí NG, na to nadväzuje opis problému dopravných sietí a modifikácia použitého algoritmu A\*. V záverečnej časti budú opísané niektoré experimenty vykonané v reálnej dopravnej sieti mesta Košice.

## 1. Princíp sietí typu Neural Gas

Siete NG vychádzajú vo svojej podstate z Kohonenových sietí, kde sa pri určovaní zmeny polohy výstupných neurónov využíva tiež princíp susednosti, ktorá sa však mení v každom adaptačnom kroku v závislosti od daného vstupu [8]. Táto zvýšená miera adaptácie umožňuje, aby sa mohli neuróny navzájom relatívne voľne presúvať v prostredí, ktoré majú opísať svojim vhodným rozložením, čo evokuje dojem šírenia plynu v uzatvorenom priestore. Učenie sietí NG vzájomne kombinuje dve paradigmy učenia, a to vlastné učenie NG a konkurenčné Hebbovo učenie.

Predpokladajme, že máme vopred zadaný vhodný počet  $N$  bodov, pomocou ktorých máme opísať istý priestor. Tie budeme označovať ako referenčné vektory  $w$ , ktorých zložky sú ich súradnice v priestore. V našom prípade pôjde o dvojzložkové vektory. Referenčné vektory  $w$  nám zároveň rozdelujú opísaný priestor na  $N$  častí a v každej z nich sú tieto vektory ich centrami. Tento postup sa nazýva vektorové kvantovanie a predstavuje istú formu úsporného kódovania, pomocou ktorého môžeme dostatočne presne opísať daný priestor, čo je úlohou sietí NG. Úspešnosť tejto úlohy závisí práve od vhodného rozmiestnenia referenčných vektorov. Preto podobne ako pri Kohonenovej sieti budeme v jednotlivých cykloch vyberať body  $\xi$ , ktoré patria do tohto priestoru a pomocou nich adaptovať pozície referenčných vektorov, zároveň definujúcich pozície neurónov  $c_i$  výstupnej vrstvy  $A$ , t. j.  $A = \{c_1, c_2, \dots, c_N\}$ .

Predmetom vlastného učenia NG je adaptácia referenčných vektorov, t. j. výpočet ich zmeny  $\Delta w_i(t)$  v čase  $t$ . Ide o učenie viacnásobných víťazov, t. j. najviac sa mení tzv. „víťazný“ vektor  $w_{S1}$ , avšak v závislosti danej tzv. rozsahom susednosti  $h(t, k)$  aj ostatní  $k$  susedia, hoci v menšej miere, pričom vektor  $w_{S1}$  je taký, ktorý sa nachádza čo najbližšie k vstupu  $\xi$ , t. j.  $\arg(\min(\|\xi - w_{S1}\|))$ . Snahou je, aby na začiatku bolo učenie silnejšie s väčším dosahom na širšie okolie, čo by sa s rastúcim časom zmenšovalo až po záverečný čas ukončenia adaptácie  $t_{\max}$ . Z tohto dôvodu sa definujú parametre  $\lambda_p$  a  $\lambda_z$  – začiatkový a záverečný, pričom  $\lambda_p \gg \lambda_z$ . Parameter  $\lambda$  pre daný čas  $t$  je potom v tvare:

$$\lambda(t) = \lambda_p \left( \lambda_z / \lambda_p \right)^{t/t_{\max}} \quad (1)$$

a rozsah susednosti  $h(t, k)$  pre  $k$ -teho suseda sa počíta ako:

$$h(t, k) = \exp\left(\frac{1-k}{\lambda(t)}\right) \quad (2)$$

Na proces adaptácie má vplyv aj samotný parameter učenia  $\gamma$ , ktorého veľkosť sa tiež časom mení v závislosti od  $\gamma_p$  a  $\gamma_z$  s rovnakým významom symbolov ako pre  $\lambda$  a podobným výpočtom ako v (1).

Celkový postup adaptácie v jednotlivých časových krokoch až po  $t_{\max}$  bude teda takýto:

1. Zorad' všetky referenčné vektory podľa ich vzdialenosti ku  $\xi$  do postupnosti:

$$\|\xi - w_{S1}\| \leq \|\xi - w_{S2}\| \leq \dots \leq \|\xi - w_{SN}\| \quad (3)$$

2. Adaptuj všetky referenčné vektory podľa:

$$\Delta w_{Si}(t) = \gamma(t) \cdot h(t, k) \cdot (\xi - w_{Si}) \quad (4)$$

3. Inkrementuj počítadlo času  $t = t + 1$  a pokiaľ  $t < t_{\max}$ , choď na krok 1, ináč ukonči adaptáciu.

Dá sa dokázať [9], že tento spôsob adaptácie v podstate zodpovedá gradientu nákladovej funkcie, ktorá pri Kohonenových sieťach neexistuje, inými slovami, adaptácia je v prípade sietí NG spravidla rýchlejšia.

Konkurenčné Hebbovo učenie [8] slúži na vybudovanie topologickej štruktúry medzi neurónmi výstupnej vrstvy. Vychádza síce zo základnej myšlienky Hebbovho učenia, že sa posilňuje váha prepojenia medzi tými neurónmi, ktoré sa aktivujú v rovnakom čase (jej zmena korešponduje so súčinom aktivácií týchto neurónov), ale zároveň je zabudovaný prvok konkurencie tým, že sa v jednom adaptačnom kroku vytvorí iba jedno prepojenie, a to medzi dvomi najbližšími bodmi siete k danému vstupu  $\xi$ , t. j. medzi referenčnými vektormi  $w_{S1}$  a  $w_{S2}$  bodov  $S1$  a  $S2$  (neuróny  $c_1$  a  $c_2$ ). Vzdialenosť medzi bodmi sa spravidla počíta pomocou Euklidovskej normy. V [10] bolo ukázané, že takto vytvorená topológia zodpovedá Delaunayho triangulácii, a tým po prepočítaní aj rozdeleniu na Voronoiove regióny, ktoré zabezpečujú prehľadavacím algoritmom nájdenie optimálnej cesty.

Najjednoduchší spôsob aplikácie učenia siete NG je dvojstupňový, keď sa najprv vytvorí vhodné rozmiestnenie vopred stanoveného počtu bodov a tie sa pomocou konkurenčného Hebbovho učenia navzájom pospájajú. Tento prístup je však možný iba pri vopred pevnom stanovení  $t_{\max}$ , čo je značne obmedzujúcim činiteľom. Druhá možnosť je paralelná činnosť obidvoch spôsobov učenia, kde však neustálou zmenou referenčných vektorov môže dôjsť k narušeniu Delaunayho triangulácie. Preto treba zabudovať mechanizmus odstraňovania nežiaducich prepojení. Na to sa využíva proces starnutia prepojení, kde každému pre-

pojeniu medzi neurónmi  $c_1$  a  $c_2$  je priradený jej vek  $v(c_1, c_2)$ . Pri vytvorení nového prepojenia je táto hodnota nastavená na nulu, ako aj v prípade, ak by sa algoritmus neskoršie znovu snažil vytvoriť to isté prepojenie, tzn. „omladenie prepojenia“. Vek sa inkrementuje o hodnotu 1 pri všetkých prepojeniach spájajúcich priame susedné neuróny s neurónom  $c_1$ , ak sa ten stane znovu víťazom. Ak vek nejakého prepojenia dosiahne hodnotu  $T(t)$ , bude toto zrušené. Takýmto spôsobom sa minimalizuje riziko existencie neplatných prepojení. Keďže na začiatku adaptácie dochádza k veľkým zmenám, je potrebné, aby sa  $T(t)$  časom menilo od malých po väčšie časy. Určuje sa podobným spôsobom ako v (1), pričom platí  $T_p \ll T_z$ .

*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**

44