

Siete Neural Gas pri navigácii v cestných sieťach (3)

V prvej a druhej časti seriálu uverejnených v číslach 11/2008 a 1/2009 sme sa venovali princípu sietí typu Neural Gas. V tejto časti si priblížime ich využitie.

2. Využitie a úprava siete NG pre potreby plánovania trás


Dáta pre cestné navigačné systémy sa ešte aj v súčasnosti vytvárajú prácnym spôsobom so značným podielom manuálnej práce buď spracovaním mapových podkladov, alebo fyzicky meraním orientačných bodov pomocou GPS. V našom prípade možno túto prácu skoro úplne automatizovať (až na zadávanie informácií o jednosmerných cestách alebo zákazoch vjazdu) tým, že sa pomocou farebného filtra na mape ponechajú iba komunikácie (obr. 3) a takáto informácia je už priamym podkladom (trénovacou množinou) na učenie siete NG. Pre naše ciele sme použili sieť RNG a experimenty sa vykonávali na mape mesta Košice.

Na obr. 3 sa nachádza výsek prvotne naučenej siete (sivá farba) spolu so skutočným stavom komunikácií (čierna farba), kde možno vidieť, že táto sieť čiastočne:


- chybne spája komunikácie bez prepojení,
- je redundandná, t. j. obsahuje príliš veľa bodov, ktoré možno vynechať a získať jednoduchšiu štruktúru siete.

Pri odstraňovaní chybných prepojení treba rozlišovať medzi skutočne nevyhovujúcimi prepojeniami, ako sú prepojenie *a*, *b* na obr. 4, a principiálne akceptovateľnými prepojeniami, ako *c*, *d*. Prijateľné prepojenia totiž vyjadrujú principiálnu existenciu cesty, len nedostatočne pres-

ne ju kopírujú, preto sa v prípade potreby iba povkladajú ďalšie body tak, aby mohla byť daná cesta lepšie vytvarovaná. Na rozlíšenie týchto dvoch prípadov bola v [12] navrhnutá modifikácia algoritmu Bug2 [7], kde sa vytvorí prehľadávací ovál s polomerom p nachádzajúcim sa nad koncovými bodmi skúmaného prepojenia (obr. 4). Ak sa v danom ová-



Obr.3 Výsek prvotne naučenej siete RNG



Obr.4 Identifikácia chybných prepojení

le nachádza súvislá komunikačná oblasť spájajúca tieto koncové body, je prepojenie principiálne akceptovateľné. V opačnom prípade sa také prepojenie zruší.

Ďalším krokom je odstránenie redundantnosti siete. Na obr. 3 vidieť, že aj rovný úsek cesty je opísaný nie pomocou dvoch prepojených bodov, ale pomocou viacerých, ktoré sú zbytočné, zťažujú pamäť a predlžujú čas hľadania cesty. Preto sa hľadá čo najdlhšia súvislá časť komunikácie a všetky medziláhle body sa zrušia. Spravidla sa takýmto spôsobom značne zjednoduší sieť.

Kedže sa v cestnej sieti nachádzajú obojsmerné aj jednosmerné komunikácie, sieť prepojení z obr. 3 sa v skutočnosti zdvojuje a prepojeniam sa pridáva orientácia. V tomto kroku sa zároveň v jednosmerných komunikáciách (vrátane kruhových objazdov) ruší zakázaný smer, ktorý však už treba vykonať ručne. Napokon sa jednotlivým prepojeniam pridáva ďalšia informácia o ich dĺžke, ktorá predstavuje cenu cesty. Posledné dva typy informácií, t. j. orientácia prepojenia a jej cena, sú podstatnými údajmi pre činnosť prehľadávacích algoritmov.

3. Navigácia v sieťach NG


Vytvorenie opisu cestnej siete vo forme stromovej štruktúry pomocou NG predstavuje však v úlohe navigácie iba prvú fázu. Druhú fázu vykonávajú stromové prehľadávacie algoritmy, ktoré štruktúru siete NG využívajú ako vhodný dátový zdroj, na ktorom riešia úlohu nájdenia najlepšej cesty medzi dvomi miestami. Na to bol využitý algoritmus A*, ktorý dokáže nájsť najkratšiu cestu s minimálnym počtom prehľadávania a v prípade jej nejstovovania dokáže dať o tom správu [7].

Pre potreby cestnej premávky však treba vykonať modifikácie tohto algoritmu [14], aby boli dodržané dopravné predpisy. Ide o:

- zákaz otočenia v uzle,
- tzv. problém P.

Kedže v obojsmerných komunikáciách je každé prepojenie zdvojené s opačnými orientáciami, naskytla by sa tým v najbližšom bode (uzle) možnosť otočenia (ak by napr. vodič chcel takto napraviť svoj omyl), čo je vlastne otočenie v ceste. Preto sa pri aktuálnom prepojení jeho opačne orientované prepojenie dočasne ruší.

Pri probléme P (vzhľadom na podobnosť s písmenom P) na obr. 5 vznikajú ťažkosti v tom, že ak sa vozidlo nachádza na hrane medzi bodmi 1 a 2 a chce sa znovu vrátiť do bodu 1, tak algoritmus nedokáže nájsť



Obr.5 Schéma problému P

cestu, aj keď tá je možná napr. v podobe 2→3→4→5→2→1. Ako riešenie toho sa zvolilo prekódovanie celej siete NG tak, že sa nebude hľadať cesta pomocou bodov, ale pomocou ich prepojení [14]. Inými slovami, neuróny siete NG nebudú predstavovať komunikačné body (križovatky a zákruty), ale samotné prepojenia medzi týmito bodmi. V našom prípade z obr. 5 pôjde o riešenie 23→34→45→52→21.

4. Experimenty a nastavovanie parametrov siete RNG

Pre sieť RNG treba spolu nastaviť 8 parametrov, a to:

- počet adaptačných krokov daných časom t_{max} ,
- maximálny počet neurónov (bodov) výstupnej vrstvy N ,
- interval vkladania nových bodov τ ,
- maximálny vek prepojenia T ,
- parametre učenia γ_{S1} a γ_{Si} ,
- parametre redukcie chyby kvantovania α a β .

Podľa [6] sa hodnota pre γ_{S1} volí podstatne menšia ako 0,3, v našom prípade $\gamma_{S1} = 0,05$ a pre γ_{Si} približne desaťkrát menej, v našom prípade $\gamma_{Si} = 0,005$ a $\gamma_{Si} = 0,0005$. Pre naše experimenty boli zvolené tieto ďalšie hodnoty: $T = 100$, $\alpha = 0,5$, $\beta = 0,0005$.

V našich experimentoch [12] sme sa zaoberali najmä voľbou parametrov t_{max} , N a τ , keďže majú zásadný vplyv na kvalitu vzniknutej siete a navzájom interagujú. Kombinovaním rôznych hodnôt týchto parametrov a porovnávaním takto vzniknutých sietí sme došli k týmto záverom:

1. Počet neurónov výstupnej vrstvy na opis zložitých tvarových štruktúr je asi jedna stotina z celkového počtu tréningových bodov.
2. Počet adaptačných krokov sa má voliť zhruba troj- až štvornásobne väčší, ako je tréningová množina.
3. Interval vkladania nových bodov sa má voliť tak, aby boli vložené v priebehu prvých dvoch tretín adaptácie, t. j.:

$$\tau \approx \frac{2 \cdot t_{max}}{3N} \quad (8)$$

Pri experimentoch sme predpokladali viac-menej rovnomerné rozloženie tréningových bodov opisujúcich danú cestnú sieť. Čím väčší sa volí počet adaptačných krokov, tým je samozrejme sieť presnejšia, ale za cenu väčšieho výpočtového nároku. Navrhnuté hodnoty parametrov sú preto volené ako kompromis medzi dostatočnou presnosťou a rýchlosťou výpočtu. Najväčší vplyv na výslednú polohu daného neurónu má síce samotný začiatkový krok jeho vloženia (6), avšak naň vplyva aj postupná adaptácia jeho polohy, ktorá je však vzhľadom na veľkosť parametrov γ_{S1} a γ_{Si} podstatne menšia. Preto je potrebné, aby bolo možné mnohonásobne adaptovať každý neurón. Preto ide o vysoké hodnoty t_{max} a tiež o to, aby mal vložený neurón ešte možnosť miernej korekcie svojej polohy aspoň počas zvyšnej tretiny celkového času adaptácie t_{max} .

Pre potreby návrhu siete RNG opisujúcej cestnú sieť mesta Košice s 242 470 tréningovými bodmi boli zvolené tieto hodnoty parametrov: $t_{max} = 900\,000$, $N = 2\,000$, $\tau = 300$, $T = 100$, $\alpha = 0,5$, $\beta = 0,0005$, $\gamma_{S1} = 0,05$, $\gamma_{Si} = 0,006$. Experimenty preukázali, že pomocou týchto parametrov bola sieť schopná učiť sa s rovnakou kvalitou na rôznych typoch cestnej siete bez ohľadu na jej tvar a hustotu (obr. 6).

Záver

Navrhnutá kombinácia sietí NG a exaktných grafových algoritmov poskytuje veľmi výhodné vlastnosti pri navigácii buď ako pomôcka pre vodičov, alebo ako priamy prostriedok presnej navigácie pre mobilné roboty, ktorý možno inkrementálne upravovať zabudovaním ďalších mechanizmov, ako napr. automatické rušenie prepojení medzi dvomi bodmi jednosmernej cesty alebo spájaním viacerých nezávisle vytvorených sietí, ktoré opisujú susediace územia. Z týchto sietí možno v prípade potreby vytvoriť aj siete s menej detailným popisom (väčšia mierka) pre účely približnej navigácie. Keďže koncept sietí NG je všeobecný pre priestory s ľubovoľným rozmerom, možno do popisu zahrnúť aj výškové údaje.



Obr.6 Opis cestnej siete mestskej časti Košice-Sever

Výhoda tohto prístupu spočíva najmä v jeho dvojfázovosti. V prvej fáze sa vytvorí popisná sieť, ktorá je síce výpočtovo náročná, ale tento popis stačí vytvoriť raz a bude sa už len príležitostne upravovať pomocou spomenutých mechanizmov. V každom prípade aj v tejto prvej fáze sú činnosti vo vysokej miere automatizované (na rozdiel od konvenčného prístupu tvorby takýchto popisov). V druhej fáze, ktorá sa bude využívať omnoho viac, sa použijú upravené vysoko efektívne algoritmy, ktorých činnosť v prípade Košíc nepresahovala 3 sekundy na nájdenie optimálnej cesty.

Literatúra

- [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, <citeseer.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].
- [5] HEINKE, D., HAMKER, F. H.: Comparing Neural Networks: A Benchmark on Growing Neural Gas, Growing Cell Structures, and Fuzzy ARTMAP. IEEE Transactions on Neural Networks, Vol. 9, No. 6, 1998, pp. 1279 – 1291.
- [6] HOLMSTRÖM, J.: Growing Neural Gas (dizertačná práca). Uppsala University – Department of Information Technology, pp. 42, 2002.
- [7] LAVALLE, Steven M.: Planning algorithms. Cambridge University, 2006, pp. 842, <http://planning.cs.uiuc.edu/> [cit. 22.7. 2008].
- [8] MARTINETZ, T. M., SCHULTE, K. J.: A neural gas network learns topologies. In: Artificial Neural Networks; North Holland Amsterdam, pp. 397 – 402, 1991.
- [9] MARTINETZ, T. M.: Selbstorganisierende neuronale Netzwerkmolelle zur Bewegungssteuerung. Infix Verlag, 1992.
- [10] MARTINETZ, T. M.: Competitive Hebbian learning rule forms perfectly topology preserving maps; In: ICANN – International Conference on Artificial Neural Networks, Amsterdam, Springer, pp. 427 – 434, 1993.
- [11] MILANO, M., KOUMOUTSAKOS, P., SCHMIDHUBER, J.: Self-Organizing Nets for Optimization. IEEE Transactions on Neural Networks, Vol. 15, No. 3, 2004, pp. 758 – 765.
- [12] RUTRICH, M.: Využitie sietí typu Neural Gas v navigácii (diplomová práca). TU v Košiciach, 2007, 67 s.
- [13] VAŠČÁK, J., SZÁSZI, T.: Navigácia mobilných robotov pomocou harmonických potenciálových polí (1) a (2). In: AT&P journal, č. 2 a 3, s. 58 – 60 a 74 – 75, 2007. ISSN 1335-2237.
- [14] VAŠČÁK, J., RUTRICH, M.: Path Planning in Dynamic Environment Using Fuzzy Cognitive Maps. In: SAMI – 6th International Symposium on Applied Machine Intelligence and Informatics, Herľany, Slovakia, January 21 – 22 2008, pp. 5 – 9. ISBN 978-1-4244-2106-0.
- [15] YEH, M. F., CHANG, K. Ch.: A Self-Organizing CMAC Network With Gray Credit Assignment. IEEE Transactions on Systems, Man, and Cybernetics – Part B: Cybernetics, Vol. 36, No. 3, 2006, pp. 623 – 635.

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

39