

Evolúcia herných agentov v reálnom čase

Lukáš Zemčák

lukas.zemcak@gmail.com

1 Úvod

Umelé postavy (agenti) väčšiny súčasných hier sú často obmedzené svojimi skriptami a nepružnými rozhodovacími algoritmi. To zásadne limituje možnosti ich zasahovania do deja a z veľkej časti vylučuje ich rozumné správanie na neštandardné, respektíve vývojármi neočakávané situácie. Navyše ak hráč raz objaví slabosť alebo chybu v rozhodovaní agenta, môže ju dookola zneužívať, čo rapídne znižuje znovuhrateľnosť hier. Schopnosť agentov učiť sa, a teda zlepšovať počas hrania, zvyšuje zábavnosť hry.

V tejto eseji načrtujeme možnosti použitia evolúcie neurónových sietí na riadenie agentov v reálnom čase prostredníctvom modernej neuroevolučnej metódy NEAT (NeuroEvolution of Augmenting Topologies) [1]. Ďalej predstavíme hru NERO (NeuroEvolving Robot Operatives) [2,3] využívajúcu metódu rtNEAT(real-time NEAT) [3] odvodenú od NEAT.

2 NeuroEvolving Robot Operatives(NERO)

Hra NERO navonok pripomína real-time strategickú hru, avšak jej hranie je rozdelené na dve fázy. Prvá fáza je tréningová. Hráč umiestni svojich agentov-robotov do cvičného prostredia, kde ich učí reagovať na rôzne situácie. Roboti sú riadení neurónovými sieťami a keďže sa na učenie používa evolúcia, je potrebné agentov učiť inkrementálne. Najprv sa agenti naučia jednoduchšie, až neskôr zložitejšie úlohy. Hráč si môže vycvičiť viac druhov agentov špecializovaných na rôzne úlohy ako napríklad defenzívnych alebo ofenzívnych agentov. Keď si už hráč myslí, že je jeho armáda pripravená, nastáva druhá fáza. V nej si zmerajú sily armády dvoch hráčov a ukáže sa, koho tréning bol lepší.

Z hľadiska umelej inteligencie je zaujímavá prvá fáza, ktoré demonštruje a sčasti rieši problémy vytvárania umelých bytostí ako napríklad veľký priestor stavov a akcií agentov alebo schopnosť pamätať. Zároveň poukazuje na silu a adaptabilnosť metódy NEAT a jej dcérskej metódy rtNEAT.

3 NeuroEvolution of Augmenting Topologies(NEAT)

Dôležitou otázkou evolúcie neurónových sietí je, či vyvíjať váhy spojov pevnej architektúry, alebo nechať evolúciu aj štruktúru siete. Metóda NEAT je ukázkou

toho, ako vývoj architektúry spolu s váhami siete dokáže v štandardných porovnávacích skúškach predbehnúť, podľa autorov, ľubovoľnú inú neuroevolučnú metódu. Pravdepodobnou príčinou týchto vlastností je elegantné riešenie základných evolučných otázok akými sú: Ako zmysluplne krížiť jedince tak, aby nevznikali degenerovaný potomkovia? Ako ochrániť nádejné inovácie tak, aby mali šancu rozvinúť sa? Ako čo najviac obmedziť prehľadávaný priestor tak, aby bola sieť stále schopná interpretovať daný problém? V nasledujúcej kapitole si ukážeme ako NEAT rieši tieto problémy.

Avšak najprv musíme ozrejmiť spôsob mutácií a spôsob kódovania genotypu neurónovej siete použité v NEAT. Kódovanie je relatívne jednoduché a pozostáva z kódovania neurónov a spojov. Neuróny počiatočnej siete sú očíslované unikátnymi číslami a nové neuróny pridané mutáciou sú očíslované podľa času ich vzniku. Spoje sú kódované číslami neurónov, ktoré spájajú a taktiež unikátnym číslom vzniku. To dovoľuje jednoduché spárovanie neurónov a spojov pri krížení. Mutácie sa rozdeľujú na štandardné ovplyvňujúce váhy spojov, na štrukturálne mutácie ako je pridanie neurónu a pridanie spoja. Spoj sa jednoducho pridá medzi dva neuróny. Neurón sa pridáva tak, že sa jeden spoj deaktivuje a miesto neho sa pridajú dva nové spoje a nový neurón. Pozrime sa ako také kódovanie pomôže vyriešiť vyššie zmienené otázky.

3.1 Kríženie jedincov

Hlavným problémom kríženia neurónových sietí je problém protichodných konvencií (v angličtine Competing Convention Problem, alebo Permutation problem). Problém nastáva ak majú neuróny s rovnakým účelom rôznu pozíciu vo vnútorných vrstvách topologicky podobných sietí. To znamená, že siete majú rôzne genotypy a zároveň môžu kódovať rovnaké funkcie (fenotypy). Vlastný problém nastane až pri krížení takýchto sietí, kedy je veľmi pravdepodobné, že sa stratia užitočné informácie a nový jedinec bude degenerovaný. NEAT tento problém rieši svojím kódovaním. To umožňuje jednoducho zoradiť neuróny a spoje podľa čísla ich vzniku a tak krížiť medzi sebou odpovedajúce časti siete.

3.2 Ochrana nových jedincov

Jedným zo stálych príznakov mutácií je pokles fitness. Ten zabraňuje mladým potenciálnym jedincov zkonvergovať k lepším výkonom, pretože ich momentálne silnejší jedinci vytlačujú z populácie. NEAT však vďaka svojmu kódovaniu dokáže určiť podobnosť jedincov (podľa počtu zhôd čísel neurónov a spojov). To mu dovoľuje rozdeliť populáciu do druhov. Pre selekciu potom používa rozšírená fitness funkcia, ktorá znižuje pôvodnú fitness početne väčším druhom. Čo mimo iné znamená, že žiaden druh nedokáže ovládnuť populáciu, a tak majú malé druhy zvýšenú šancu na prežitie.

3.3 Obmedzenie prehľadávaného priestoru

Neuroevolúcia metódou NEAT začína z jednoduchej plne prepojenej siete bez vnútorných neurónov a postupne sa pridávajú neuróny, ktoré zväčšujú možnosti siete, a tak lepšie aproximujú žiadané správanie. Preto stačí evolúcii prehľadávať priestory od najmenšieho k väčším. To stačí na to, aby sa priestor rádovo zmenšil oproti vyvíjaniu siete s veľkou pevnou štruktúrou, v ktorej sa prehľadáva veľký priestor od začiatku evolúcie. Navyše vďaka mutáciám sa dokáže prispôsobiť špecifickým potrebám reagovania, ktoré by sa pevná sieť nedokázala prispôsobiť.

4 Real time Neuroevolution of Augmenting Topologies(rtNEAT)

Tieto vlastnosti NEATu poskytujú veľa možností ďalšieho výskumu a použitia. Jedným z nich je aj jeho použitie v počítačových hrách a umelej inteligencii. Jedným z prvých, stále však len experimentálnych využití je rtNEAT.

NEAT je, ako väčšina evolučných algoritmov, prispôbený na beh bez zásahov človeka počas evolúcie. Preto bolo pre potreby hry NERO modifikovať NEAT pre beh v reálnom čase. Aplikuje sa v tréningovej fáze hry, kde sa jedinca-roboti, pohybujú po bojisku. Roboti sú obdobne ako v NEAT rozdelení do druhov, a používa sa rozšírená fitness ako v NEAT. Algoritmus rtNEAT opakuje každých n-tikov hry tieto činnosti:

1. Nájde najhoršieho robota, ktorý je v aréne dosť dlho a odstráni ho. Vek robota je na rozdiel od NEATu, kde sa všetky siete vyvíjajú rovnako dlho, dôležitý. Bolo by na škodu odstraňovať robotov, ktorý sú v aréne príliš krátko, pretože ich chovanie by sa nestihlo premietnuť do ich fitness.
2. Vyberie rodičovské druhy, skríži dvoch jedincov a vytvorí nového robota.
3. Dynamicky zmení parametre príslušnosti jedincov k druhu, pretože sa snaží zachovávať vopred stanovený počet druhov.
4. Vloženie nového robota naspäť do prostredia.

Problémom zostáva už len vybranie správneho intervalu opakovania a správneho veku umierania robotov.

Táto metóda rieši niektoré základné problémy vývoja umelých bytostí. Veľký prehľadávací priestor stavov a akcií je redukovaný vďaka minimalizácii siete na začiatku, a komplexnosť vďaka neobmedzenosti siete a možnosti inkrementálnej evolúcie. Pre pamäť agentov sa môžu vyvinúť spätné spoje v sieti. Populácia nezkonverguje nikdy k jednému správaniu, pretože sa používa rozšírená fitness funkcia. A nakoniec rýchlosť evolúcie je daná špecifickými vlastnosťami metódy, najviac pravdepodobne za to môže zmysluplné kríženie jedincov.

5 Hranie NERO

Jednoduché správanie sa vďaka použitým metódam dajú vyvinúť v pomerne krátkom čase. Napríklad najjednoduchšie bojové správanie – vrhnúť sa čo najskôr na

nepriateľa, sa podarilo naučiť 90% populácie priemerne za 100 sekúnd. Podľa účastníkov prvého NERO turnaja bola hra zábavná a strhujúca.

6 Zhrnutie

Vznik hry NERO je priamo podmienený výbornými vlastnosťami metódy NEAT, hlavne jej rýchlosti nájdenia vhodného správania siete. NERO posúva neuroevolúciu umelých bytostí počas hrania o krok ďalej, avšak stále je ešte od komerčného využitia ďaleko. Napriek tomu, že evolúcia neurónových sietí je výpočtovo drahá, treba s ňou v budúcnosti počítačových hier počítať. Ešte dlho nebude využiteľná na komplexné riadenie plnohodnotného agenta, avšak stále sa bude môcť využívať na rôzne časti pri rozhodovaní. Dôsledok toho bude zvýšená nedeterministickosť, znovuhrateľnosť a komplexnosť hier, čo podľa môjho názoru zvýši ich úspešnosť.

References

1. Kenneth O. Stanley, Risto Mikkulainen: Evolving Neural Networks through Augmenting Topologies, Department of Computer Sciences, The University of Texas at Austin, Austin, USA (2002), stiahnuté na <http://nn.cs.utexas.edu/>
2. Neuro-Evolving Robotic Operatives, <http://z.cs.utexas.edu/users/nn/nero/>
3. Kenneth O. Stanley, Bobby D. Bryant, Risto Mikkulainen: Evolving Neural Network Agents in the NERO Video Game, Department of Computer Sciences, The University of Texas at Austin, Austin, USA (2005), stiahnuté na <http://nn.cs.utexas.edu/>