

OPTIMALIZÁCIA POMOCOU GENETICKÝCH ALGORITMOV

OPTIMALIZATION USING GENETIC ALGORITHMS

Pavol BEZÁK, Miriam IRINGOVÁ

Autori: **Ing. Pavol Bezák, Ing. Miriam Iringová**
Pracovisko: **Ústav aplikovanej informatiky, automatizácie a matematiky,**
 Materiálovotechnologická fakulta STU
Adresa: **Paulínska 16, 917 24 Trnava**
Email: **pavol.bezak@stuba.sk, miriam.iringova@stuba.sk**

Abstract

V príspevku je popísaný proces riešenia optimalizačného problému pomocou evolučných výpočtových techník. Obsahuje návrh riešenia využitím genetických algoritmov.

This contribution contains description of optimization problem solving using evolution computational techniques. It contains design of solution using genetic algorithms.

Key words

optimalizácia, evolučný algoritmus, genetický algoritmus

optimization, evolution algorithm, genetic algorithm

Úvod

Optimalizačné problémy sa vyskytujú v každej oblasti ľudskej činnosti. Denne riešime problémy, ako niečo urobiť čo najlepšie. Optimalizačný problém vznikne v situácii, keď je nutné vybrať nejaké riešenie. Pochopiteľne sa snažíme vybrať to riešenie, ktoré je pre nás najvýhodnejšie. Zvyčajne postupujeme optimalizačnými metódami. Aby sme mohli optimalizačný problém matematicky formulovať, je treba zostaviť matematický model situácie. Model reálnej situácie je vždy zjednodušený, t.j. matematicky spracovateľný model situácie nepopisuje verne realitu a naopak, skutočností blízky model nebude matematicky spracovateľný.

Analýza problémovej oblasti

Výber najlepšieho riešenia prináša určité úskalia. Pre matematickú formuláciu optimalizačného problému volíme kritérium, podľa ktorého vyberáme najlepší variant riešenia. Výber kritéria optima je problematický a v mnohých aplikáciách podlieha často subjektívnym požiadavkám. Na vyriešenie reálneho optimalizačného problému, pomocou jeho matematického modelu, je často nutné postupne podľa výsledkov upresňovať model a modifikovať kritérium optima. Treba opakovane riešiť rôzne verzie optimalizačného

problému a overovať ich na základe simulácie a porovnania s realitou. Prechod od reálneho optimalizačného problému k jeho matematickému modelu je veľmi dôležitý a podstatne ovplyvňuje využiteľnosť výsledkov.

Hľadanie optimálneho riešenia pomocou matematického modelovania je vlastne hľadanie extrému funkcie, ktorou je systém matematicky popísaný. Konkrétne sa jedná o hľadanie lokálnych extrémov, ktoré buď sú alebo nie sú súčasne extrémami globálnymi.


Zvyšujúci sa výkon počítačov by nás pri vytváraní matematického modelu nemal zvädzať k zanedbaniu objemu výpočtov potrebných na riešenie optimalizačného problému. Niektoré systémy sú tak zložité, že pri pokuse o vystihnúť všetky podstatné vlastnosti systému nakoniec získame model, ktorý nie je možné použiť ani s využitím najlepšej výpočtovej techniky [5].

Evolučné algoritmy v súčasnosti patria medzi základné nástroje modernej informatiky v prípadoch hľadania riešení v extrémne zložitých situáciách, kedy použitie štandardných deterministických metód založených na technikách úplného prehľadávania nemožno aplikovať [2].

Návrh riešenia

Evolučné algoritmy patria medzi moderné metódy optimalizácie systémov. Evolučné mechanizmy, ktoré príroda preverila dlhodobým vývojom, je možné veľmi úspešne aplikovať i na technické problémy, a to hlavne také, ktoré sú zložité alebo ťažko opisateľné matematickými metódami. Evolučné algoritmy (EA) sú veľmi účinné optimalizačné algoritmy, ktoré vychádzajú zo znalosti prírodnej genetiky a jej zákonov. Evolučné algoritmy sa zvyčajne delia na genetické algoritmy, genetické programovanie a evolučné stratégie.

Klasické genetické algoritmy (GA) používajú operácie výberu, kríženia a mutácie na simuláciu procesu reprodukcie (obr. 1). Vzhľadom na rozmanitosť riešených optimalizačných problémov, neexistuje všeobecne použiteľný optimalizačný algoritmus. Jedná sa vždy o algoritmus, ktorý je problémovo závislý, t.j. viac či menej vhodný pre danú účelovú funkciu. Evolučné optimalizačné algoritmy nie sú vhodné pre aplikácie, kde sa dá jednoducho zistiť gradient účelovej funkcie alebo účelová funkcia je výpočtovo veľmi náročná. Kombináciou neevolučných optimalizačných metód (napr. simulované žihanie, metóda zakázaného hľadania, horolezecký algoritmus atď.) a evolučných optimalizácií vzniknú hybridné algoritmy. Jedinec (agent) s najlepším dosiahnutým ohodnotením (fitness) je považovaný za riešenie problému.




Obr. 1. Bloková schéma genetického algoritmu [1]

Evolučný proces prehľadávania priestoru potenciálnych riešení vyžaduje nájsť kompromis (rovnováhu) na dosiahnutie dvoch nasledujúcich cieľov:

- čo najrýchlejšie nájsť najbližšie (väčšinou lokálne) riešenie v malom okolí východzieho bodu,
- čo najrýchlejšie prehľadať priestor všetkých možných riešení [4].

Jednotlivé metódy sa líšia podľa toho, ktorý cieľ uprednostňujú. Ak by sme mali zoradiť metódy podľa smerovania od lokálneho riešenia až k metódam prehľadávajúcich celý priestor riešení, poradie by bolo nasledovné: „horolezecký“ algoritmus, tabu search, simulované žihanie, evolučné stratégie, genetické algoritmy. S ohľadom na nami riešený problém sa ďalej zameriame na genetické algoritmy.

Pri aplikácii genetického algoritmu na riešenie zložitejších problémov je treba riešiť napr. problém veľkých požiadaviek na pamäť, dobu výpočtu. Podstatne zlepšiť sa podarilo genetické algoritmy zavedením viac paralelne sa vyvíjajúcich populácií, z ktorých najlepší jedinci sú zahrnutí do jednej spoločnej populácie (obr. 2). Túto metódu, ktorú príroda už dávno používa, poznáme pod pojmom migrácia. Preto je v genetických algoritmoch použitá ako štvrtá operácia. Pod migráciou rozumieme vnesenie nového typu do populácie prostredníctvom jedincov, ktorí boli pôvodne členovia iných populácií.



Obr. 2. Bloková schéma paralelného genetického algoritmu [1]

V prípade, keď je účelová funkcia separovateľná na dve alebo viacero nezávislých častí, operácia kríženia zavádza do evolučného procesu vnútorný paralelizmus. V populácii chromozómov (agentov) môže prebiehať mnoho nezávislých optimalizácií, ktoré sú zamerané len na jednu časť účelovej funkcie. Operácia kríženia môže spájať tieto nezávislé čiastočné riešenia do nového lepšieho riešenia optimalizovaného problému a potom urýchliť evolúciu, t.j. proces hľadania globálneho extrému. V opačnom prípade, keď gény v chromozóme nie je možné rozdeliť na dve susedné nezávislé časti, potom kríženie nemá taký veľký význam, lebo zásadne neurýchľuje evolúciu a môžeme ho považovať za gigantickú mutáciu. Význam kríženia teda silne závisí na vlastnostiach účelovej funkcie [3].

Záver

Optimalizačné problémy boli skúmané počítačovými vedcami, inžiniermi a matematikmi. Teoretické práce viedli k určitým všeobecným riešeniam tohto problému, ktoré by vyžadovali ohromné množstvo výpočtov. Boli vyvinuté aj prakticky využiteľné algoritmy, avšak všetky sú viac alebo menej úspešné v určitých situáciách. Zatiaľ sa nepodarilo vytvoriť univerzálne použiteľný algoritmus a to je predmetom ďalšieho skúmania.

Zoznam bibliografických odkazov:

- [1] SEKAJ, I. *Evolučné výpočty a ich využitie v praxi*. Bratislava: IRIS, 2005. 157 s. ISBN 80-89018-87-4
- [2] KVASNIČKA V. a kol. *Evolučné algoritmy*. Bratislava: STU, 2000. ISBN 80-227-1377-5
- [3] GOLDBERG, D. E. *Genetic Algorithms in Search, Optimisation and Machine Learning*. Addison-Wesley, 1989.
- [4] SCHREIBER, P. , TANUŠKA, P. Detection of the shortest robot trajectory by genetic algorithms. In *DAAAM International Scientific Book*. - ISSN 1726-9687. - DAAAM International Scientific Book 2007. - Vienna: DAAAM International Vienna, 2007, s. 191-198. ISBN 3-901509-60-7
- [5] SCHREIBER, P. – VAŽAN, P. The influence of input parameters on the efficiency of genetic algorithms. In *CIM: Computer Integrated Manufacturing : Advanced Design and Management*. Warszawa: Wydawnictwa Naukowo-Techniczne, 2003, s. 472-477. ISBN 83-204-2830-5