

OVPLYVNĽOVANIE CHOVANIA GENETICKÝCH ALGORITMOV VSTUPNÝMI PARAMETRAMI

THE MANIPULATION OF THE GENETIC ALGORITHMS BEHAVIOR BY INPUT PARAMETERS

Peter SCHREIBER - Oliver MORAVČÍK - Pavol VÁŽAN

Autori: Doc. Ing. Peter Schreiber, CSc., Prof. Dr.-Ing. Oliver Moravčík, Ing. Pavol Vážan, PhD.

Pracovisko: Katedra aplikovanej informatiky a automatizácie, Materiálovotechnologická fakulta STU

Adresa: Hajdóczyho 1, 917 24 Trnava

Tel.: 00421 33 544 77 34

E-mail: schreibe@mf.stuba.sk, moravcik@mf.stuba.sk, vazan@mf.stuba.sk

Abstract

Genetic algorithms are very often used in optimisation tasks. The effectiveness of the algorithms depends on input parameters. The domain literature looks for the optimal input parameters values (the chromosome number, the choice of the chromosomes into the next generation as well as into the work set, the gene mutation probability and others).

The influence of these factors on the effectiveness of the optimising genetic algorithms is discussed and evaluated in this paper. The achieved behaviour of the basic genetic algorithm and the recommended theoretical results from the domain bibliography are compared.

V optimalizačných úlohách sa stále častejšie presadzujú genetické algoritmy. Chovanie (konvergencia k optimu) algoritmu závisí od jeho vstupných parametrov, ktorými sú napr. počet chromozómov v populácii, spôsob výberu chromozómov do ďalšej generácie ako aj do pracovnej množiny, pravdepodobnosť kríženia a mutácie a iné.

V tomto článku opisujeme vplyv vybraných vstupných parametrov na konvergenciu základného genetického algoritmu. Hodnoty dosiahnuté pri simulačných behoch porovnávame s hodnotami odporúčanými v literatúre.

Key words

genetic algorithms, gene, chromosome, convergence, optimisation

algoritmy genetické, gén, chromozóm, konvergencia optimalizácia

Úvod

V prípadoch, keď zlyhávajú analytické optimalizačné metódy, hľadajú sa iné spôsoby riešenia optimalizačných úloh. Jedným z takýchto prístupov sú genetické algoritmy. Genetické algoritmy napodobňujú procesy prirodzenej evolúcie a využívajú ich pri riešení problémov. Princíp spočíva v tom, že jedince (predstavujú riešenia), ktoré sú úspešnejšie od ostatných, postupujú do ďalšej generácie (iterácie výpočtu), kde sa môžu v rámci populácie ďalej vyvíjať (krížiť a mutovať). Možnosti využitia genetických algoritmov sú veľmi rôznorodé, najčastejšie sa však používajú na optimalizáciu. Genetické optimalizačné algoritmy sú jednoduché, pritom však univerzálne, veľmi robustné, využívajú stochastické procesy, neviaznu v lokálnom extréme, ale nájdu globálny, nie sú obmedzené počtom parametrov, riešia aj úlohy s mnohými obmedzujúcimi podmienkami, prípadne úlohy s kombinatoricky rastúcou zložitou a pod.

Predtým, ako budeme hovoriť o genetickom algoritme a možnosti ovplyvňovania jeho efektívnosti, uvedieme v tabuľkovej forme základné pojmy.

ZÁKLADNÉ POJMY

Tabuľka 1

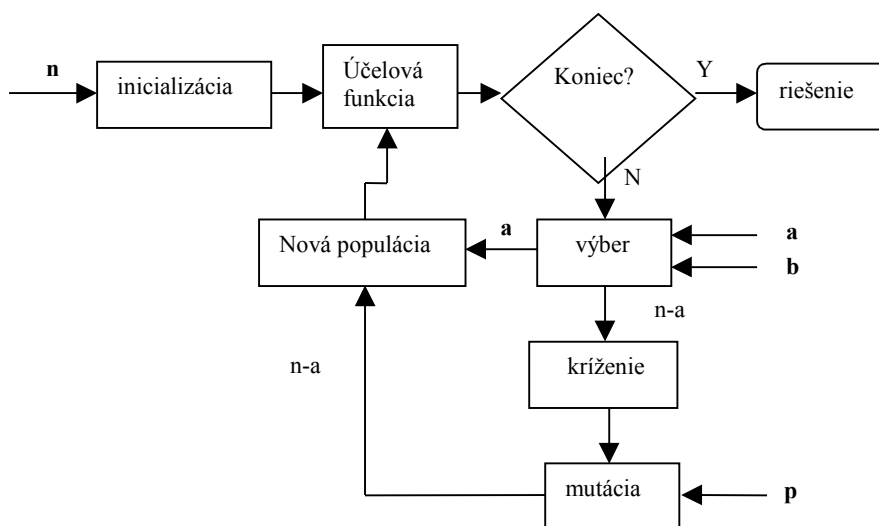
Pojem	Explanation
Populácia	Skupina zvoleného počtu jedincov, na ktorej prebieha iteratívny výpočet. Iterácia = generácia
Chromozóm	Zodpovedá jedincovi v populácii, t.j. jednému riešeniu. Usporiadaná množina binárnych, číselných alebo symbolických hodnôt, ktoré reprezentujú zvolené vlastnosti jedinca.
Gén	Jeden prvok chromozómu.
Účelová funkcia	Funkcia, ktorá ohodnocuje chromozómy.
Kríženie	Operácia, kde sa dva rodičovské chromozómy rozdelia na tej istej náhodne zvolenej pozícii a vymenia si jednu z dvoch častí.
Mutácia	Operácia, pri ktorej sa zmení hodnota niektorého génu na novú náhodnú prípustnú hodnotu.

Princíp genetického algoritmu

Genetický algoritmus pozostáva vo všeobecnosti z nasledujúcich krokov (podľa [2]):

1. Vygeneruje sa počiatočná populácia n jedincov. Generovanie môže byť náhodné, ak sú však k dispozícii poznatky o riešení, použijú sa na usmernenie počiatočného generovania.
2. Vyhodnotí sa účelová funkcia každého chromozómu.
3. Otestuje sa splnenie ukončovacích podmienok (dosiahnutie požadovanej hodnoty účelovej funkcie, prípadne stanoveného počtu generácií). Ak sú ukončovacie podmienky splnené, hľadaným riešením je najúspešnejší chromozóm.
4. Ak podmienky ukončenia nie sú splnené, nasleduje výber 2 skupín chromozómov do ďalšej generácie. V prvej skupine je a chromozómov, ktoré prejdú priamo do nasledujúcej generácie. Ak vyberieme do tejto skupiny aj najlepší chromozóm, nové

- riešenie nemôže byť horšie, ako doteraz dosiahnuté. Druhú, tzv. pracovnú skupinu tvorí $n-a$ chromozómov, s ktorými sa budú robiť genetické operácie.
5. S pracovnou skupinou sa vykonajú operácie kríženia a mutácie.
 6. Spojením a chromozómov prvej skupiny s modifikovanou pracovnou skupinou vznikne nová generácia. Pokračuje sa krokom 2.



Obr. 1 Genetický algoritmus (podľa [2]), tučne sú vyznačené vstupy, vplyv ktorých skúmame

V literatúre je opísaných niekoľko modifikácií tohto algoritmu. Sú taktiež uvádzané a odporúčané vstupné hodnoty, pre ktoré algoritmus konverguje. My sme v ďalšom použili tzv. štandardný (klasický) genetický algoritmus, pričom sme prijali nasledovné predpoklady:

1. Chromozómy sú celočíselné, tvorené 10 génmi. Dovoľené hodnoty sú 0 – 9. Počiatočná populácia n chromozómov je generovaná náhodne.
2. Účelová funkcia je lineárna (netypické použitie GA, ale výhodné pre posúdenie rýchlosti konvergenzie k optimu). Hodnota účelovej funkcie je daná sumou hodnôt génov.
3. Do nasledujúcej generácie priamo prechádza a najlepších chromozómov.
4. Do pracovnej skupiny prechádza b najlepších chromozómov. Ostatných $n-a-b$ chromozómov je vybraných náhodne. Poradie chromozómov v pracovnej skupine je náhodné.
5. Kríženie sa robí s pravdepodobnosťou 1, t.j. kríži sa každá dvojica v pracovnej skupine.

Experimenty a výsledky

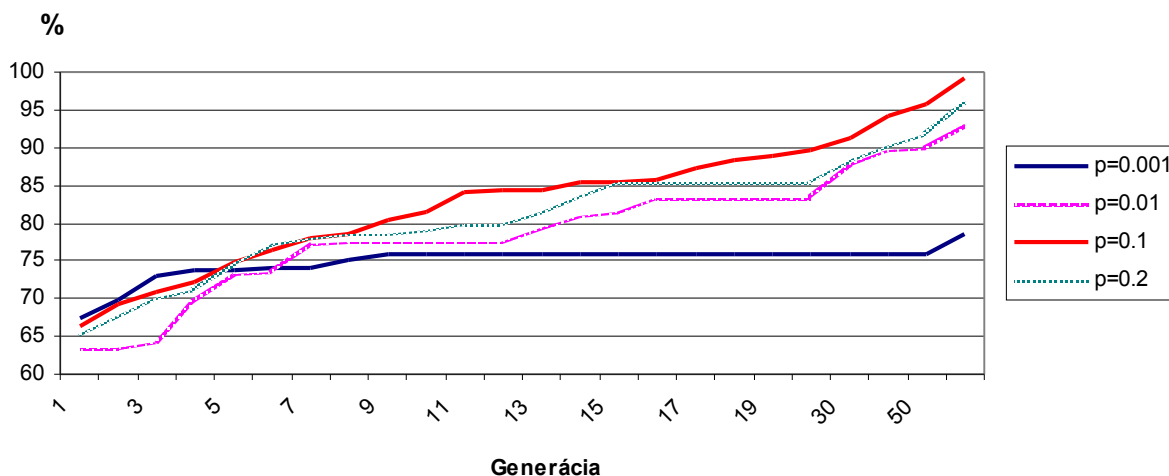
Na preverenie správania sa uvedeného algoritmu sme vyvinuli jednoduchý simulátor v jazyku Tspascal. Sledovali sme vplyv týchto vstupných parametrov na rýchlosť konvergenzie algoritmu:

1. n - Počet chromozómov v populácii. V literatúre sa hovorí, že vhodný počet je 10 – 100. Menší počet neumožňuje diverzitu genetických informácií, väčší počet predlžuje proces riešenia bez dosahovania lepších výsledkov.
2. a - Počet najlepších chromozómov, ktoré priamo prechádzajú do nasledujúcej generácie. Odporúčania v literatúre ohľadne tohto parametra sme nenašli.

3. b - Počet najlepších chromozómov, ktoré prechádzajú do pracovnej skupiny. Ani tu sme nenašli referenčné odporúčania.
4. p - Pravdepodobnosť mutácie génov v chromozómoch pracovnej skupiny. Literárne zdroje odporúčajú hodnoty 0.001 – 0.1.

Pravdepodobnosť mutácie génov

Pre stredné odporúčané alebo odhadnuté hodnoty (počet chromozómov = 50, do nasledujúcej generácie priamo prechádza 10 najlepších, t.j. 20 % chromozómov, do pracovnej skupiny prechádza 10 najlepších, t.j. 20 % chromozómov) sme experimentovali s pravdepodobnosťou mutácie génov v pracovnej skupine. Pretože vo výpočtoch vystupujú viaceré náhodné procesy, experimenty sme opakovali pre každú hodnotu 10 krát. Na nasledujúcom obrázku sú znázornené priebehy priemerov najlepšieho riešenia v každej generácii pre hodnoty pravdepodobnosti mutácie 0.001, 0.01, 0.1 a 0.2. Na vodorovnej osi sú vynášané iterácie výpočtu (generácie), zvislá os udáva dosiahnuté priemerné percentá optimálneho riešenia v generácii.



Obr. 2 Vplyv parametra p (pravdepodobnosti mutácie génov)

Riešenie ani v jednom prípade (s výnimkou 1 behu pri $p = 0.1$) nedosiahlo ani po 100 iteráciách optimálnu hodnotu. Priemer najlepších riešení po 100 generáciách je 78.44% pre $p = 0.001$, 92.89% pre $p = 0.01$, 99.33 pre $p = 0.1$ a 96.00 pre $p = 0.2$. Z priebehov je zrejmé, že algoritmus konverguje najlepšie pre hodnotu 0.1. Je to krajná hodnota y intervalu udávaného v literatúre. Túto hodnotu sme použili ako východiskovú pre ďalšie experimenty.


Počet chromozómov v populácii

V druhej sérii experimentov sme sledovali vplyv celkového počtu n chromozómov v populácii na konvergenciu algoritmu. Túto hodnotu sme menili v intervale $10 \div 100$ s krokom 10. Pre pravdepodobnosť mutácie p sme použili optimálnu hodnotu získanú v prvej sérii, ostatné dva parametre sa voči prvej sérii nemenili, t.j. do nasledujúcej generácie priamo prechádza najlepších 20 % chromozómov, do pracovnej skupiny prechádza najlepších 20 % chromozómov. Aj tu sme experimenty opakovali pre každú hodnotu 10 krát. Priebehy sa s rastúcim n zlepšovali až po hodnotu $n = 80$. Pre $n = 90$ a $n = 100$ priebeh zostal voči

hodnote $n = 80$ prakticky nezmenený. Algoritmus pre $n > 40$ pri všetkých meraniach našiel optimum skôr ako v 100. generácii. Pre $n = 80$ skonvergoval algoritmus do optima raz v 15. a raz v 16. generácii, nikdy však nie neskôr ako v 42. generácii.

Aj tu teda experimenty potvrdili, že je možné prijať tvrdenia z literatúry ($n = 10 \div 100$). Pre ďalšiu sériu sme použili hodnotu 80.

Výsledky pre $n = 50, 80$ a 100 sú na obr. 3.



Obr. 3 Vplyv parametra n (počet chromozómov)

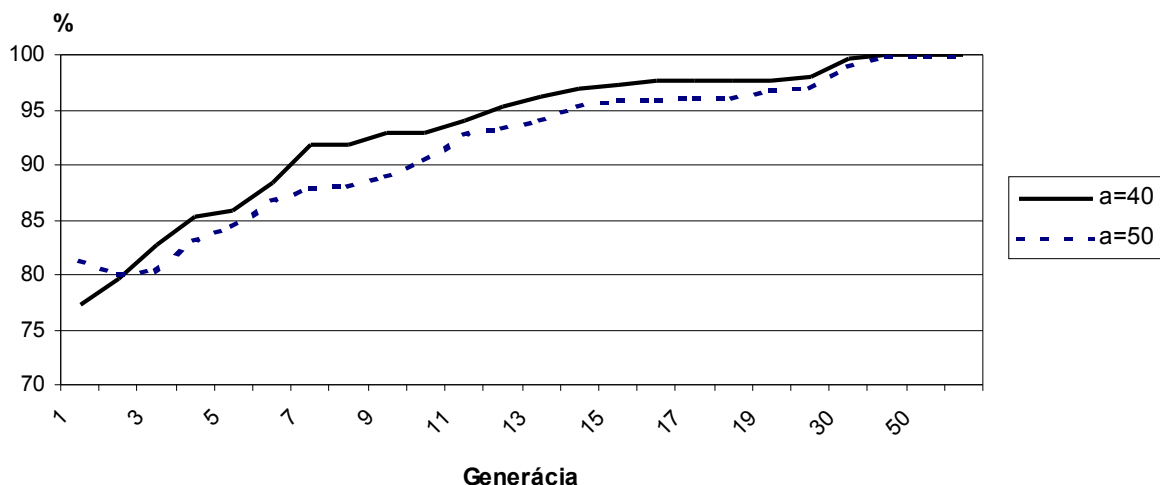
Počet najlepších chromozómov, ktoré priamo prechádzajú do nasledujúcej generácie

Tretí v poradí sme vyhodnocovali vplyv parametra a , ktorý udáva počet najlepších chromozómov, ktoré priamo prechádzajú do nasledujúcej generácie. Parameter sme vyjadrili ako percentá z celkového počtu chromozómov.

Tým, že do nasledujúcej generácie prechádza aj najlepší chromozóm aktuálnej generácie je zaručené, že najlepšie riešenie v novej generácii nie je horšie, ako predchádzajúce najlepšie riešenie. So zvyšujúcim sa počtom preberaných najlepších chromozómov môže kvalita novej generácie rásť, ale súčasne sa znižuje počet chromozómov v pracovnej skupine a obmedzuje sa tým priestor pre genetické operácie. Preto nie je možné preberať najlepšie chromozómy neobmedzene, ale len do istej miery.

Na obr. 4 sú nakreslené priebehy priemerov najlepších hodnôt riešenia pre $a = 10 \div 50$ % z celkového počtu chromozómov. Merania sme robili pre optimálne hodnoty získané v predchádzajúcich experimentoch ($p = 0.1, n = 80$), pričom $b = 20$ (percento najlepších chromozómov, ktoré prechádzajú do pracovnej množiny).

Tento parameter sa neprejavuje výrazne. Priebeh pre $a = 20 \div 40$ je podobný, výsledok pre $a = 10$ alebo 50 je o niečo horší. Algoritmus okrem jedného prípadu pre $a = 10$ skonvergoval do optima skôr ako v 50. generácii. Priemerný počet iterácií pre $a = 10, 20, 30, 40$ a 50 je po rade 39.1, 32.4, 32.6, 25.2 a 32.7. Pre ďalšie experimenty sme prevzali hodnotu $a = 40$.



Obr. 4 Vplyv parametra a (percentuálny podiel chromozómov, ktoré priamo prechádzajú do novej generácie)

Počet najlepších chromozómov, ktoré prechádzajú do pracovnej množiny

Posledný sledovaný vstupný parameter je percentuálny podiel najlepších chromozómov, ktoré prechádzajú do pracovnej množiny. Ostatné parametre sú nastavené na hodnotu určenú predchádzajúcimi experimentami ($p = 0.1$, $n = 80$, $a = 40\%$).

Tento parameter už pri ostatných „vyladených“ parametroch nemá veľký vplyv na konvergenciu algoritmu. Pre hodnoty $b = 20 \div 40\%$ z n sú priebehy podobné. Algoritmus vo všetkých prípadoch s výnimkou 1 behu pri $b = 10$ skončil v optime skôr ako v 50. iterácii. Priemerný počet iterácií pre $b = 10, 20, 30, 40$ a 50 je po rade $38.8, 30.6, 25.2, 27.0$ a 32.5 . Priebehy priemerov najlepších jedincov v generácii pre rôzne hodnoty b sú znázornené na obr. 5. Za optimálnu považujeme hodnotu $b = 30\%$.

Záver

Pretože sa jedná o systém s mnohými vstupmi, nájsť jednoznačné optimum pre všetky parametre nie je jednoduché. Neskúmali sme súčasné zmeny viacerých parametrov, ani sme neexperimentovali s poradím skúmania parametrov. Predpokladáme ale, že výsledky by boli podobné.

V článku sme ukázali, že už jednoduchý genetický algoritmus v základnom tvare je citlivý na vstupné parametre a oplatí sa tieto parametre voliť rozumne. Rozdiely v kvalite generácií môžu byť veľmi veľké. Na obr. 6 je pre porovnanie znázornený prvý meraný priebeh s východiskovými hodnotami $p = 0.001$, $n = 10$, $a = 20\%$, $b = 20\%$ a posledný (vyladený) priebeh pre $p = 0.1$, $n = 80$, $a = 40\%$, $b = 30\%$.

