

POROVNANIE POUŽITIA JEDNODUCHÉHO A PARALELNÉHO GENETICKÉHO ALGORITMU PRI OPTIMALIZÁCIÍ MODELU PRENOSU TEPLA

M. Oravec, S. Števo, I. Sekaj

Ústav riadenia a priemyselnej informatiky, Fakulta elektrotechniky a informatiky,
Slovenská technická univerzita v Bratislave, Slovenská republika

Abstrakt

Práca sa zaoberá porovnaním optimalizácie použitím jednoduchého a paralelného genetického algoritmu. Ako optimalizačné problémy boli vybraté nastavenie rozmerov tepelnej jednotky a kalibrácia modelu budovy. Keďže simulácia daných modelov je výpočtovo aj časovo náročná, je vhodné znížiť počet potrebných vyhodnotení účelovej funkcie (fitness funkcie). To možno dosiahnuť využitím paralelných genetických algoritmov. Genetické algoritmy a ich paralelizácia boli implementované v Matlabe a simulácia modelov prenosu tepla, ktoré sú súčasťou účelovej funkcie, bola prevedená v Comsol Multiphysics.

1 Úvod

Genetické algoritmy (GA) sú efektívnou stochastickou optimalizačnou metódou, ktorá napodobňuje prírodný proces evolúcie [1]. Napriek pokroku v oblasti genetických algoritmov sa stáva, že riešenie uviazne v lokálnom extréme a doba výpočtu je príliš dlhá. Zvlášť v prípade optimalizácie zložitejších systémov alebo modelov, ktorých simulácia trvá dlhý čas. V takýchto prípadoch je vhodné a niekedy aj potrebné zredukovať počet vyhodnotení účelovej funkcie (fitness funkcie) GA.


Existuje niekoľko spôsobov ako zlepšiť GA. Najbežnejším je vhodné nastavenie GA. Avšak zvoliť parametre GA tak, aby bol schopný rýchlo konvergovať ku globálnemu extrému, je náročné a niekedy až nemožné. Preto ďalšou možnosťou je použitie paralelizácie. Paralelné genetické algoritmy sú schopné zlepšiť výkon jednoduchých genetických algoritmov s jednou populáciou [2].

Tento článok prezentuje praktické porovnanie použitia jednoduchého genetického algoritmu (SGA) s jednou populáciou a paralelného genetického algoritmu (PGA) s populáciou rozdelenou do niekoľkých vzájomne prepojených subpopulácií.

2 Paralelné genetické algoritmy

V PGA je evolúcia rozdelená medzi niekoľko viac-menej izolovaných subpopulácií, kde prenos genetickej informácie medzi týmito subpopuláciami má dôležitý vplyv na priebeh a urýchlenie evolučného procesu. V našom prípade bola paralelizácia implementovaná na jednom procesore. Pri eventuálnej implementácii na viacerých procesoroch je predpoklad ďalšieho zvýšenia výpočtového výkonu a urýchlenia evolučného procesu.

Porovnávané boli SGA s 50-timi jedincami v populácii a PGA v 5-timi subpopuláciami o 10-tich jedincoch. Migrácia bola realizovaná nahradením náhodne (okrem najlepšieho) zvoleného jedinca v cieľovej subpopulácii kópiou najlepšieho jedinca zo zdrojovej subpopulácie (tzv. best-random stratégia) podľa zvolenej PGA štruktúry každú 5-tu generáciu. Štruktúra spomínaného PGA je znázornená na Obr.1. [3].




Obrázok 1: Použitá PGA štruktúra

Genetický algoritmus, ktorý bol použitý v každej subpopulácii PGA a v SGA bol nasledovný:


1. Náhodná inicializácia populácie a výpočet fitness funkcie.
2. Výber jedincov:
 - a. Najlepší jedinci sú bezo zmien skopírovaní do novej populácie – Pop1 (2 v PGA a 5 v SGA)
 - b. Náhodný výber skupiny jedincov, ktorí sú skopírovaní bezo zmien do novej populácie – Pop2 (4 v PGA a 30 v SGA).
 - c. Turnajový výber skupiny rodičov – Pop3 (4 v PGA a 15 v SGA).
3. Mutácia a kríženie v skupine rodičov (Pop3) s mierou globálnej mutácie 0.02, mierou lokálnej mutácie 0.02 a pravdepodobnosťou kríženia 0.75 – Pop3*
4. Zoskupenie Pop1, Pop2 and Pop3* do novej populácie.
5. Výpočet účelovej funkcie novej populácie.
6. Ak nie sú splnené ukončovacie podmienky, skok na krok 2.

3 Experimenty

V prvom experimente boli optimalizované rozmery tepelnej jednotky (radiátora) umiestneného v miestnosti. Simulácia modelu prenosu tepla v miestnosti bola realizovaná v Comsol Multiphysics použitím FEM štruktúr [4]. Model miestnosti je znázornený na Obr.2. SGA a PGA boli implementované v Matlabe.



Obrázok 2: Model miestnosti v Comsole.



Obrázok 3: Simulácia najlepšieho riešenia tepelnej jednotky.

Cieľom experimentu bolo porovnať výkonnosť SGA a PGA. Jediniec populácie predstavoval reťazec troch parametrov (výška, šírka, hĺbka) a fitness funkcia bola reprezentovaná ako rozdiel simulovanej a požadovanej teploty (294K alebo 21°C) [4]. Porovnávala sa konvergencia fitness funkcie - čiže priebeh hodnôt fitness funkcie najlepšieho jedinca v SGA populácii, resp. najlepšieho jedinca zo všetkých subpopulácií PGA.

Na Obr.4 je znázornený priebeh hodnôt v závislosti od počtu generácií, na Obr.5 v závislosti od počtu vyhodnotení fitness funkcie. Zobrazenie v závislosti od počtu vyhodnotení fitness funkcie nám presnejšie vykresľuje potrebný výpočtový výkon pre daný algoritmus. Každý graf reprezentuje priemer 5-tich behov evolučného algoritmu. Počty vyhodnotení fitness funkcie potrebných k nájdeniu

najlepšieho riešenia pre SGA a PGA sú uvedené v Tab.1. Na Obr.3 je znázornená simulácia optimalizácie rozmerov tepelnej jednotky najlepšie nájdeného jedinca.

Tabuľka 1: POČET VYHODNOTENÍ FITNESS FUNKCIE POTREBNÝCH K NÁJDENIU NAJLEPŠIEHO RIEŠENIA PRI OPTIMALIZÁCIÍ ROZMEROV TEPELNEJ JEDNOTKY

	SGA	PGA	PGA/SGA [%]
beh 1	480	476	99.2
beh 2	510	532	104.3
beh 3	450	448	99.5
beh 4	420	448	106.7
beh 5	540	504	93.4
priemer	480	481.6	100.4

Keďže v tomto prípade boli optimalizované iba 3 parametre, nie je použitie paralelizmu veľmi efektívne a počet vyhodnotení fitness funkcie, potrebných k nájdeniu najlepšieho riešenia, je približne rovnaký pre PGA, tak aj pre SGA.


Druhým experimentom bola kalibrácia modelu budovy. Cieľom bolo nastaviť 14 parametrov daného modelu, čiže jedinec populácie predstavoval reťazec 14-tich génov. Fitness funkcia bola reprezentovaná rozdielom medzi reálne nameranými a simulovanými dátami. S dobre nakalibrovaným modelom sme schopný redukovať maximálnu odchýlku simulácia z cca. 2.5°C na 0.3°C [5].

Konvergencia fitness funkcie v závislosti od počtu generácií je znázornená na Obr.6 a v závislosti od počtu vyhodnotení na Obr. 7. Každý graf predstavuje priemer 5-tich behov daného evolučného algoritmu. Počty vyhodnotení fitness funkcie potrebných k nájdeniu najlepšieho riešenia pre SGA a PGA sú uvedené v Tab.2. Kalibrovaný model budovy je zobrazený na Obr.8.


Tabuľka 2: POČET VYHODNOTENÍ FITNESS FUNKCIE POTREBNÝCH K NÁJDENIU NAJLEPŠIEHO RIEŠENIA PRI KALIBRÁCIÍ MODELU BUDOVY

	SGA	PGA	PGA/SGA [%]
beh 1	1980	1036	52.3
beh 2	2250	1288	57.2
beh 3	2430	1176	48.4
beh 4	2160	1232	57.0
beh 5	1710	952	55.7
priemer	2106	1140.8	54.2


Pri optimalizácii zložitejších úloh (14 parametrov) je konvergencia PGA rýchlejšia než konvergencia SGA. Použitím paralelizácie vieme ušetriť okolo 50% výpočtového času (potrebný je menší počet vyhodnotení fitness funkcie), čo v našom prípade predstavuje úsporu až desiatok hodín.




Obrázok 4: Optimalizácia rozmerov tepelnej jednotky podľa počtu generácií




Obrázok 5: Optimalizácia rozmerov tepelnej jednotky podľa počtu vyhodnotení fitness funkcie



Obrázok 6: Kalibrácia modelu budovy podľa počtu generácií



Obrázok 7: Kalibrácia modelu budovy podľa počtu vyhodnotení fitness funkcie



Obrázok 8: Kalibrovaný model budovy

4 Záver

V tejto práci sme sa venovali porovnaniu optimalizácie rôznych modelov prenosu tepla pomocou jednoduchého (SGA) a paralelného genetického algoritmu (PGA). Vhodná konfigurácia PGA vďaka komunikácii jednotlivých uzlov pôsobí vo výpočte synergicky a dovoľuje znížiť potrebný počet vyhodnotení účelovej funkcie v rámci celého evolučného procesu v porovnaní s prípadom, kedy by bola využitá iba jedna veľká populácia. A to hlavne pri optimalizácii resp. návrhu zložitejších alebo časovo náročných úloh. Taktiež dovoľuje PGA nachádzať lepšie riešenia optimalizačnej úlohy a zabrániť uviaznutiu riešenia v lokálnom extréme.

Literatúra

- [1] I. Sekaj. *Evolučné výpočty a ich využitie v praxi*, IRIS Bratislava, Bratislava, Slovak republic, 2005.
- [2] E. Cantú-Paz. *A summary of research on parallel genetic algorithms*, IlliGAL Report No. 95007, Illinois Genetic Algorithms Laboratory, University of Illinois at Urbana Champaign, 1995.
- [3] E. Cantú-Paz. *Migration polices, selection pressure, and parallel evolutionary algorithms*. Journal of heuristics 7(4), 2001.
- [4] S. Števo. *Optimalizácia vykurovania podľa vonkajších teplotných podmienok*, Technical Computing Prague '09, Prague, Czech Republic, 2009.
- [5] S. Števo, A. Šlezárová. *Heat transfer model of building calibrated by genetic algorithm*, Elitech '09, Bratislava, Slovak Republic, 2009.

Ing. Michal Oravec

Ústav riadenia a priemyselnej informatiky, FEI STU v Bratislave, E-mail: michal.oravec@stuba.sk

Ing. Stanislav Števo, PhD.

Ústav riadenia a priemyselnej informatiky, FEI STU v Bratislave, E-mail: stanislav.stevo@stuba.sk

doc. Ing. Ivan Sekaj, PhD.

Ústav riadenia a priemyselnej informatiky, FEI STU v Bratislave, E-mail: ivan.sekaj@stuba.sk