

THE INFLUENCE OF GENETIC OPERATORS ON THE EVOLUTION OF IMAGE FILTERS

Karel SLANÝ, Master Degree Programme (5)
Dept. of Computer Systems, FIT, BUT
E-mail: xslany00@stud.fit.vutbr.cz

Supervised by: Dr. Lukáš Sekanina

ABSTRACT

Evolutionary algorithms are used in various applications. However, they often need a lot of time to get a really good solution. This work deals with studying fitness landscapes in order to optimize the genetic algorithm in the task of image filter design.

1 ÚVOD


Pro návrh obrazových filtrů lze, stejně jako u jiných logických obvodů, využít kartézského genetického programování (CGP) [1] [2] [4]. V tomto přístupu je chromozóm reprezentován grafem, kde jednotlivé uzly sestávají z funkčních bloků, jejichž vzájemné propojení určují hrany grafu. Evoluční algoritmus pak hledá nejvýhodnější řešení v prostoru možných řešení.

Rychlost, s jakou se najde kvalitní řešení, je závislá na mnoha parametrech evolučního algoritmu, jako jsou pravděpodobnost mutace nebo počet jedinců v populaci. Použitý genetický operátor hraje také významnou roli. V praktických pokusech s vývojem obvodů pomocí CGP se ukazuje, že evoluce probíhá nejrychleji při použití mutace bez možnosti křížení jedinců. Zatím ale nebylo provedeno měření, které by tuto domněnku statisticky potvrdilo.

Cílem této práce je zkoumat rychlost evoluce v závislosti na použitém genetickém operátoru, popřípadě navrhnout lepší genetický operátor.

2 KARTÉZSKÉ GENETICKÉ PROGRAMOVÁNÍ A NÁVRHY OBRAZOVÝCH FILTRŮ

Každý jedinec populace je reprezentován chromozómem, který určuje zapojení jednotlivých funkčních bloků a zapojení vstupů a výstupů celého obvodu. Každý funkční blok je označen hodnotou, která určuje jeho vlastní funkci v obvodu.



Obrázek 1: Výstupy některých funkčních bloků se nevyužívají, bloky jsou redundantní.

Celý obvod je zapojen na vstupní masku 3×3 pixelů, která postupně prochází filtrovaný obraz. Výsledná nová hodnota pixelu je pak porovnána s hodnotou odpovídajícího referenčního pixelu. (Obr. 1) Součet všech odchylek od požadovaného výsledného obrazu se pak odečte od maximální možné odchylky. Výsledná hodnota pak reprezentuje kvalitu filtru.

3 EXPERIMENTÁLNÍ VÝSLEDKY

Byl vytvořen program, který na funkcionální úrovni simuluje evoluci obrazových filtrů pomocí CGP. Ten zapisuje průběh evoluce do souborů, které obsahují fitness nejlepšího jedince aktuální populace, fitness a chromozóm nejlepšího dosaženého řešení. Tyto hodnoty slouží k výpočtu informačních charakteristik [5], které slouží jako porovnávací metody ke zjištění kvality evolučního algoritmu. Z teorie je známo, že evoluční algoritmy s hladším průběhem povrchu fitness funkce rychleji konvergují ke kvalitním řešením.

Pro všechny pokusy bylo použito nastavení, kde chromozóm obsahoval 4×7 funkčních bloků, které mohly reprezentovat kteroukoli z funkcí : bitový OR, bitový AND, bitový XOR, součet, satureovaný součet, průměrná hodnota, maximum a minimum. Velikost populace byla nastavena na osm jedinců. Pravděpodobnost mutace byla nastavena na 3%.

Byly provedeny celkem tři sady pokusů, které využívají následující operátory:

1. Mutace, kde je nejprve vybrán nejlepší jedinec ze staré populace, který je zmutován. Pak se znovu vybere nejlepší jedinec, který je nakopírován do nové populace. Takhle se pokračuje do zaplnění nové populace.
2. Mutace, kde je vybrán nejlepší jedinec staré populace, ze kterého je mutací vytvořena celá nová populace.
3. Křížení s mutací, kde jsou vybráni dva nejlepší jedinci ze staré populace. Na těch je prováděno jednobodové křížení. Jeden potomek je zmutován a nakopírován do nové populace.

Každá sada sestávala ze čtyřech pokusů, kde každý trval 100000 generací a sto padesáti kratších pokusů o 1000 generací. Entropické míry udávají kvalitativní ohodnocení

metoda	ϕ počet generací pro získání 95% maximální fitness	entropická míra nerovnosti	entropická míra hladkosti
0	38998	0,086	0,273
1	277	0,074	0,061
2	240	0,1	0,058

Tabulka 1: Rychlost evoluce a informační charakteristiky pro dané případy.

evolučního algoritmu v závislosti na vlastnostech povrchu fitness. Obě tyto hodnoty se získají pomocí náhodného průchodu po povrchu fitness, kterému odpovídá daný průběh evoluce. Entropická míra nerovnosti

$$H = -p_{neq} \log_6 p_{neq} \quad (1)$$

se snaží ohodnotit nerovnost povrchu zatímco entropická míra hladkosti

$$h = -p_{eq} \log_3 p_{eq} \quad (2)$$

spíše hladkost. Obě hodnoty slouží k porovnávání evolučních algoritmů. Hodnoty p_{neq} respektive p_{eq} jsou pravděpodobnosti jevu, že v daném konkrétním průběhu evoluce dojde respektive nedojde ke změně hodnoty fitness.

4 ZÁVĚR

Informace získané studováním povrchu fitness je možné využít k optimalizaci evolučních algoritmů vzhledem k jejich povrchu fitness a díky tomu získat kvalitnější postupy. Zatím se jako nejkvalitnější jeví druhý operátor, protože má nejnižší entropickou míru nerovnosti a nejvyšší míru hladkosti, rychlost je v porovnání s třetím operátorem téměř stejná.

REFERENCE

- [1] Sekanina, L.: Evolvable Components, Springer, Berlin, 2004.
- [2] Sekanina, L., Martínek, T.: Evolving Image Operators Directly in Hardware, 2005. (dosud nepublikováno)
- [3] Kvasnička, V., Pospíchal, J., Tiňo, P.: Evolučné algoritmy, STU, Bratislava, 2000.
- [4] Miller, J. F., Job, D., Vassilev, V. K.: Principles in the Evolutionary Design of Digital Circuits - Part I, In: Genetic Programming and Evolvable Machines, roč. 2000, s. 7-35.
- [5] Miller, J. F., Job, D., Vassilev, V. K.: Principles in the Evolutionary Design of Digital Circuits - Part II, In: Genetic Programming and Evolvable Machines, roč. 2000, s. 259-288.