

Genetické algoritmy

Algoritmus pro matchování hvězd

Filip Hroch

ÚTFA, MU, Brno

29. říjen 2007

Co to jsou GA?

Genetické algoritmy (GA)

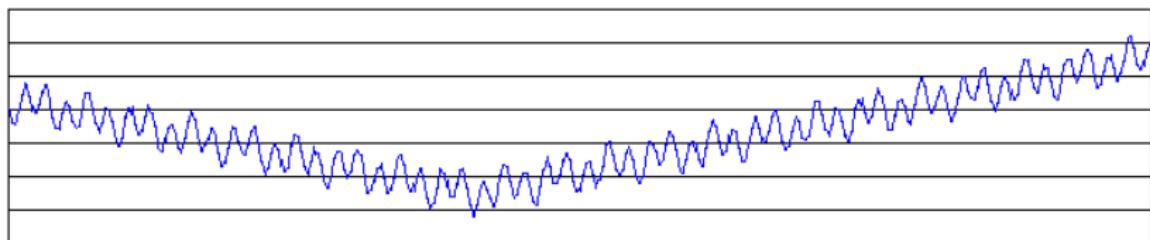
- ▶ řeší problémy na základě principů evoluce
- ▶ nejsou deterministické
- ▶ obvykle hledají extrémy vhodných funkcí

Historie

- ▶ I. Rechenberg (1960) — uvedl na svět ideu GA,
- ▶ J. Holland (1975) — rozpracování GA
- ▶ J. Koza (1992) — nazval svou metodu GA

Příklad použití GA

Hledání globálního minima



- ▶ pravděpodobnost nalezení minima Newtonovou metodou, zlatým řezem apod. je malá ...

Biologické pozadí

Genetická informace v biologii

- ▶ v buňkách živých organismů nesou genetickou informaci chromosomy
- ▶ chromosomy jsou makromolekuly obsahující DNA
- ▶ DNA je dvojšroubovice z mnoha proteinu reprezentujících geny
- ▶ všechny chromozomy v buňce tvoří dohromady genom

Rozmnožování při dělení probíhá

- ▶ rekombinace (crossover), dvě DNA se rozpletou a spojí
- ▶ mutace, při rekombinaci se občas některé geny změní

Algoritmus GA

- ▶ Vytvoření náhodné populace (množina chromosomů, každý obsahuje několik genů, reprezentace 2D polem).
- ▶ Necháme populaci žít:
 1. Náhodně vybíráme chromosomy podle schopnosti žít.
 2. Křížíme je.
 3. Občas je zmutujeme.
 4. Počítáme vhodnost populace pro naše účely (fitness funkce).
 5. Pokud nám vlastnosti populace vyhovují, tak skončíme. Jinak opakujeme od 1.

Vlastnosti GA

Jak fungují?

- ▶ křížení hledá cestu k minimu
- ▶ mutace vyvádí z lokálního minima
- ▶ jde o velmi obecný algoritmus
- ▶ volba fitness funkce a pravděpodobností křížení a mutací
- ▶ vyhledají globální extrém a neskončí v lokálním
- ▶ extrém není obvykle přesně lokalizován (v porovnání s Newtonem)
- ▶ nevadí měnící se podmínky během minimalizace
- ▶ není jasné, proč vlastně fungují (důkaz od J.Hollanda)

Parametry pro GA

Fitness funkce

- ▶ reprezentuje problém (hledáme extrém této funkce)

Pravděpodobnost křížení

- ▶ volíme kolem 80%, ovlivňuje rychlosť vývoje (konvergencie)

Pravděpodobnost mutací

- ▶ zabraňuje sklouznutí do lokálního minima
- ▶ obvykle volíme kolem pár procent

Velikost populace

- ▶ pokud zvolíme malou tak prohledáváme jen část prostoru
- ▶ pokud větší než je hranice, pak zbytečně ztrácíme čas

Křížení a mutace

Křížení

- ▶ náhodně rozdělujeme jednotlivé křížené chromosomy a pak spojujeme do nových
- ▶ ruská ruleta, náhodný výběr s ohledem na vhodnost ke křížení
- ▶ podle hodnosti, selekce se bere podle vhodnosti k dalšímu vývoji
- ▶ vyhození looseru, nejhorší chromozomy se nahrazují novými kříženci
- ▶ elita, přednost mají elitní chromosomy

Mutace

- ▶ náhodně zvolené geny v chromozomu prohodíme

Užitečné použití

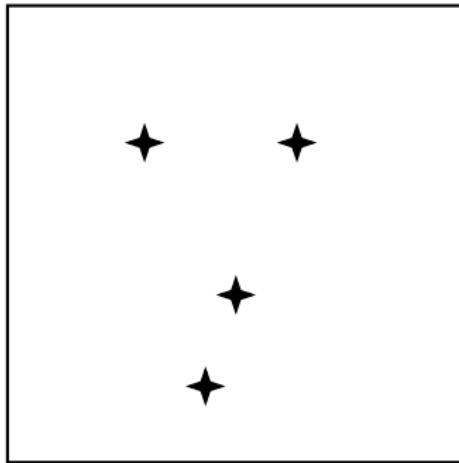
Použití při minimalizaci funkcí

- ▶ volíme řešení v určitém intervalu $a \dots b$
- ▶ ten rozdělíme na díly a přiřadíme jím pořadová čísla
- ▶ jako chromosomy pak použijeme jejich 8-bit nebo 16-bit reprezentace
- ▶ po lokalizování extrému můžeme výsledek zpřesnit obvyklou minimalizační metodou

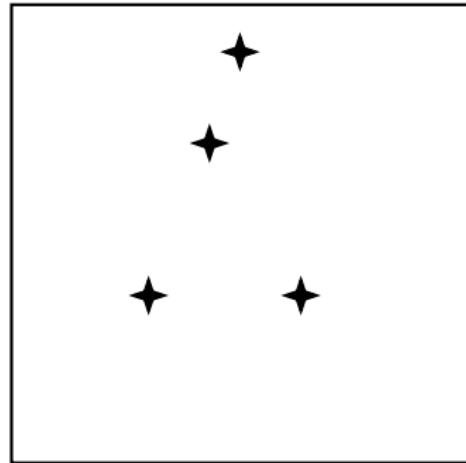
Řešení astronomických problémů

- ▶ počáteční parametry pro světelné křivky: FOTEL, WD, ...
- ▶ hledání parametrů profilů galaxií
- ▶ testování modelů hvězdných atmosfér

Hledání hvězd



no.	x_1	y_1
1	7	3
2	8	6
3	5	10
4	10	10



no.	x_2	y_2
4	5	5
3	10	5
2	7	10
1	8	13

Match problém

- ▶ hledání takového uspořádání jedné množiny vůči druhé, aby byly ekvivalentní prvky na stejné pozici
- ▶ princip řešení je prostý: stačí najít všechny možné permutace jedné množiny a funkci, která pozná správnou permutaci
- ▶ problémem je počet všech možných permutací:

$$n \quad n!$$

$$5 \quad 120$$

$$10 \quad 3628800$$

$$15 \quad 1307674368000$$

$$20 \quad 2432902008176640000$$

$$25 \quad 15511210043330985984000000$$

$$30 \quad 265252859812191058636308480000000$$

- ▶ potřebný počet hvězd běžné počítače v reálném čase nezvládají
- ▶ GA umožňují podstatným způsobem redukovat počet permutací, protože zahazují předem ztracené možnosti

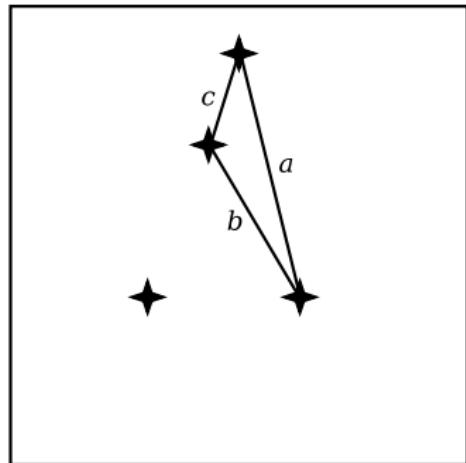
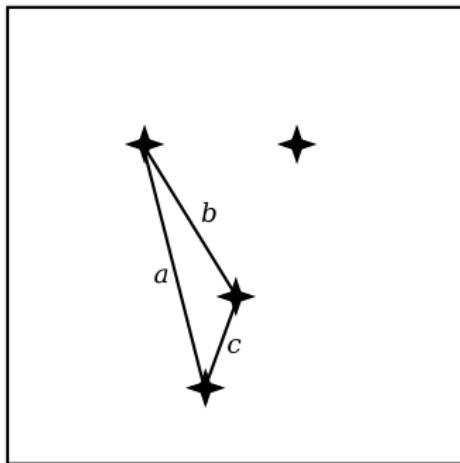
Geometrické transformace

Uvažujeme následující:

- ▶ posunutí
- ▶ otočení
- ▶ změna měřítka
- ▶ zrcadlové převrácení

$$\mathbf{r}_2 = c(\mathbf{r}_0 + \mathbf{M}_{\pm} \mathbf{r}_1)$$

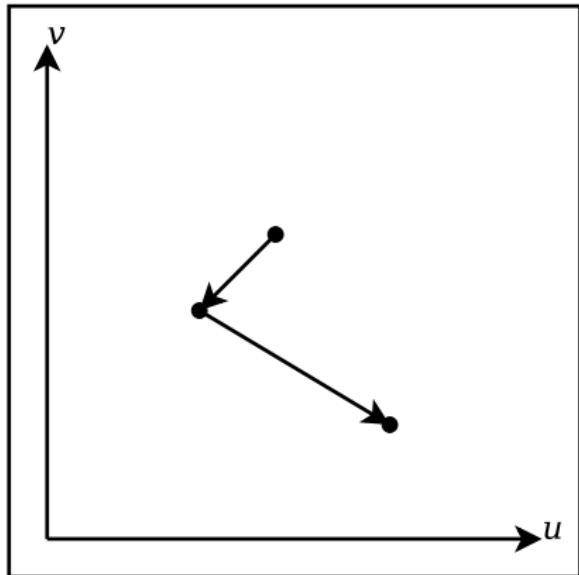
Trojúhelníková podobnost



$$u = \frac{b}{a}, \quad v = \frac{c}{a}$$

$$a \geq b \geq c$$

Fitness funkce



- ▶ součet rezidui mezi dvěma cestami $v - u$ v prostoru

$$S = \sum [(u_1 - u_2)^2 + (v_1 - v_2)^2]$$

$$\text{fitness} \sim e^{-S/T}$$

Zdrojový kód

```
!integer, dimension(...,size(iorder)) :: pop,newpop
...
call createpop(pop)
do j = 1, 50000
    ! statistics, compute fitness ss(i), sss
    do k = 1, npop, 2
        ! selection
        n1 = selection(ss,sss); n2 = selection(ss,sss)
        ! crossover
        ! call the Oracle to get harvest
        if( harvest < crossprob ) then
            ...
            call crossover(pop(n1,:),pop(n2,:),c1,c2,newpop(k,:),newpop(k+1,:))
        else
            newpop(k,:) = pop(k,:); newpop(k+1,:) = pop(k+1,:)
        end if
    end do
    ! mutation
    call mutation(newpop,mutprob)
    ! new generation
    pop = newpop
    ! write output or exit
end do
write(*,*) j,minpath,iorder,s
...
```

Srovnání s dalšími matchovacími programy

Utility

- ▶ FOCAS (IRAF), (<http://adsabs.harvard.edu/abs/1995PASP..107.1119V>,
FOCAS Automatic Catalog Matching Algorithms)
- ▶ match: (<http://spiff.rit.edu/match/>)
- ▶ SExtractor (<http://sextractor.sourceforge.net/>)
- ▶ munimatch (<http://munipack.astronomy.cz/>)

Principy: trojúhelníková podobnost, srovnávání přes cykly, $\sim n^6$

Matchování versus registrace¹

Výhody

- ▶ nepotřebuje obrázek
- ▶ může srovnávat katalog a polohy hvězd z obrázku
- ▶ lépe funguje na málo hvězd
- ▶ je mnohem přesnější
- ▶ lze ošetřit složitější geometrické transformace

Nevýhody

- ▶ je třeba detektovat "hvězdy"
- ▶ nefunguje na komplexní obrázky
- ▶ může být pomalejší

¹ Registrace odvozuje geometrické transformace na základě srovnání Fourierových obrazů

Řídí se i reálné události GA?

- ▶ vědecké články se skládají jako geny z jednotlivých myšlenek?
- ▶ vývoj společnosti (lze "vybočit z řady")?
- ▶ Řídí se vývoj technologií (aut, počítačů, ...) evolucí?
- ▶ jak a proč jsou nastavené fitness funkce?
- ▶ jak a proč jsou nastavené hodnoty mutací a křížení?
- ▶ genetické programování

Reference

- ▶ Marek Obitko: Introduction to Genetic Algorithms,
<http://cs.felk.cvut.cz/~xobitko/ga/>
- ▶ David Coley: An Introduction to Genetic Algorithms for
Scientists and Engineers, World Scientific, 1999
- ▶ Press, Flannery, Teukolsky, Vetterling: Numerical recipes
(Salesman problem, Simulated annealing)
- ▶ [http://www.scienceworld.cz/sw.nsf/0/
AF36833D48EA0D2FC1256E9700489AF0?
OpenDocument&cast=1](http://www.scienceworld.cz/sw.nsf/0/AF36833D48EA0D2FC1256E9700489AF0?OpenDocument&cast=1)
- ▶ wikipedia rulez!