

# Algorytmy genetyczne jako metoda wyszukiwania wzorców

Seminarium Metod  
Inteligencji Obliczeniowej  
Warszawa 26 X 2005  
mgr inż. Marcin Borkowski

# Krótko i na temat:

- Cel pracy
- Opis modyfikacji AG
- Zastosowania testowe i planowane
- Wyniki testów
- Uwagi i komentarze

# Cel pracy:

- Pełniejsze wykorzystanie możliwości Algorytmu Genetycznego [AG]
  - Szybsze działanie
  - Wyszukiwanie wielu rozwiązań naraz
  - Interakcja rozwiązań
    - Wykluczanie sprzeczności
    - Rozłączne pokrycie przestrzeni rozwiązań
  - Unika się kłopotliwego integrowania wyników pochodzących z wielokrotnego użycia klasycznego AG

# Cel prac:

- Znalezienie praktycznych zastosowań zmodyfikowanego AG [MAG]
- Publikacje
  - ISDA2005
  - CORES2005
- Doktorat :-)

# AG vs MAG

- Jako odnośnik użyty zostanie prosty AG z klasycznymi operatorami i kodowaniem
- Następne slajdy prezentują nie tylko różnice w budowie obu algorytmów ale również różnice w efektach działania

# AG vs MAG

- Stała populacja
  - Kodowanie binarne
  - Nabór ruletkowy
  - Stała populacja
  - Kodowanie binarne
  - Nabór:
- 

Osobniki w populacji są sortowane względem ich przystosowania. Osobniki najslabsze są następnie zastępowane przez wyniki operatorów genetycznych.

Pozwala to najlepszym osobnikom unikać “śmierci” tak długo aż zostaną wyparte przez osobniki jeszcze lepsze.

Wyniki operatorów są umieszczane w tymczasowej kopii populacji co daje równe szanse także osobnikom spisanym na straty

# AG vs MAG

- Klasyczna mutacja zależna od  $pm$ .
  - Mutacja sterowana dwoma parametrami:
- 

Każdy osobnik podlega mutacji z zadany  
prawdopodobieństwem mutacji struktury  $pms$ .

Każdy bit osobnika wylosowanego do mutacji podlega mutacji  
(inwersja) z prawdopodobieństwem  $pm$ .

$Pm$  maleje w kolejnych generacjach aż do granicy jednej mutacji  
na osobnika

Wynik mutacji wypiera z populacji osobnika najslabszego z  
jeszcze niepodmienionych

# AG vs MAG

- Krzyżowanie jedno punktowe
  - Krzyżowanie jednopunktowe:
- 

Wyniki krzyżowania, podobnie jak mutacji, zastępują najsłabsze osobniki w kopii populacji

---

- Nabór powoduje namnażanie się osobników lepszych co zwiększa ich szanse na przetrwanie
- Nabór nie namnaża super osobników, dłuższe przetrwanie w populacji gwarantuje ich pozycję w rankingu



# AG vs MAG

- Klonowanie jest powszechne i pożądane - zwiększa zbieżność
- Rozwiązaniem jest jedno z optimów w przeszukiwanej przestrzeni
- Nie ma klonowania, unika się wielu osobników tej samej postaci
- Rozwiązań jest kilka, są to najlepsze optima w przeszukiwanej przestrzeni. Ilość tych optimów zależy od rozmiaru populacji

# AG vs MAG

- Funkcja oceny uwzględnia wiedzę tylko o jednym osobniku
- Funkcja oceny:

---

Ocena rozbita jest na dwa etapy, poza zwyczajową ewaluacją osobnika następuje redukcja oceny na skutek działania czynnika ścisku.

Ścisk wyznaczany jest dopiero gdy znane są wszystkie funkcje oceny

Dla problemów reprezentowanych seriami wylicza się serię ocen cząstkowych. Do oceny końcowej brana jest wartość uśredniona

# AG vs MAG

- Brak czynnika ścisku
  - Ścisk:
- 

W zamyśle ma działać jako narzędzie limitujące ilość podobnych do siebie osobników zamieszkujących tą samą niszę poprzez redukcję ich wartości dopasowania.

Nie wszystkie osobniki w niszy będą tak samo zredukowane - redukcja jest proporcjonalna do dotychczasowej wartości dopasowania.

Poza numeryczną wartością dopasowania pod uwagę brane są także inne czynniki np.: skuteczność rozwiązania, długość itp

Osobniki są podobne wtedy, gdy dla tych samych zadanych problemów dają podobne wyniki ( podobna fizyczna budowa nie wystarcza)

# AG vs MAG

- Rozłączne pokrycie przestrzeni rozwiązań – brak
- Rozwiązania niesprzeczne – zawsze :-)
- Ściśk zapewnia rozłączne pokrycie, osobniki należące do więcej niż jednej niszy “cierpią” na większy ścisk.
- Sprzeczności występują tylko w problemach prezentowanych seriami

# AG vs MAG

- Działa teza o cegiełkach
  - Populacja ma zbiegać do optimum
  - Za różnorodność populacji odpowiada mutacja
- Działa teza o cegiełkach, wymaga modyfikacji “dowodu”
  - Populacja ma nieustannie poszukiwać lepszego zestawu optimów
  - Za różnorodność populacji odpowiada mutacja i ścisk

# AG vs MGA

- Algorytm wychodzi od losowej populacji
  - Po osiągnięciu zbieżności dalsze działanie nie ma sensu
- Algorytm wychodzi od losowej populacji
  - Po osiągnięciu pierwszych wyników zawsze można oczekiwać lepszych lub zmienić problem i pozwolić populacji przemigrować do nowych nisz

# AG vs MAG

- W jednym przebiegu można rozwiązać jeden problem naraz
- W jednym przebiegu można szukać rozwiązania (rozwiązań) wspólnego dla serii problemów

# Aplikacje MAG

- Testowane:
  - Predykcja szeregów czasowych
  - Uzupełnianie braków w szeregach czasowych
  - Drugie zastosowanie obejmuje pierwsze
- Planowane
  - Wyszukiwanie powtarzalnych sekwencji (okresowość)
  - Wyszukiwanie zbioru reguł opisujących sieć neuronową
  - Heurystyki do gier oparte na regułach



# Data Fitting

- Postać zadania:
  - Szereg czasowy pozbawiony części danych
  - Szereg taki jest traktowany jako zbiór zadań, dla których poszukiwane są wspólne rozwiązania – tutaj wzorce.
  - Wzorce nie mogą być sprzeczne
  - Wzorce mają odwzorowywać możliwie największą część szeregu
  - Wzorce będą użyte do odtworzenia braków w szeregu

# Data Fitting

- Postać rozwiązania:
  - Wzorzec ma postać:  
 $(v_1, 0)(v_2, o_2) \dots (v_n, o_n)$
  - Odstęp pomiędzy węzłami jest limitowany
  - Dane wejściowe i wartości  $v_i$  są skalowane do przedziału  $\langle -1, 1 \rangle$
  - Uzupełnianie wzorca nie jest częścią MGA, ale oba procesy można przeplatać dość swobodnie

# Data Fitting

- Każdy wzorzec/osobnik sprawdza się tylko w pewnych określonych warunkach, stopień zgodności jest reprezentowany współczynnikiem zaufania
- Do zadania można włączyć liniowe skalowanie wzorców co rozszerza ich użyteczność
- Do rozwiązania są brane tylko wzorce o dużym współczynniku zaufania i wysokiej wartości dopasowania
- Możliwe jest kilka alternatywnych rozwiązań lub też kompletny brak rozwiązania

# Data Fitting

- Oceny dopasowania (fitness)
  - Do wyszukania wzorców wykorzystuje się dane uczące (znaną część szeregu).
  - Jedna znana dana jest z szeregu usuwana, a następnie uzupełniana przez wzorce
  - Jeśli predykcja jest zgodna z przewidywaniem - ocena cząstkowa jest wysoka, jeśli nie i jednocześnie współczynnik zaufania jest wysoki – ocena cząstkowa jest niska
  - Proces ten jest powtarzany dla wszystkich znanych danych w szeregu
  - Finalna ocena jest średnią z najlepszych ocen cząstkowych


# Data Fitting

## Parametry procesu MAG

- ilość bitów wartości w węźle 12
- maksymalny dystans między węzłami 4
- ilość węzłów we wzorcu  $\langle 3,4 \rangle$
- prawdopodobieństwo krzyżowania 45%
- prawdopodobieństwo mutacji struktury 50%
- rozmiar populacji 70
- Początkowe generacje MAG  $\langle 300,3000 \rangle$
- Wtórne kroki MAG  $\langle 100,300 \rangle$
- Oczekiwany minimalny poziom zaufania  $\langle 75,95 \rangle$


# Data Fitting Wyniki:

- Odtwarzanie prostego szeregu (52% braków - kwadraty)
- Najlepsze wzorce bez skalowania:
  - $(1.00,0)(0.00,1)(-1.00,2)(1.00,4)$
  - $(-1.00,0)(0.00,1)(1.00,2)(-1.00,4)$
- Najlepsze wzorce ze skalowaniem:
  - $(0.768,0)(0.768,4)(0.768,8)$



# Data Fitting Wyniki:

- Sinus – 26 % braków
- Najlepsze wzorce ze skalowaniem:  
(-0.75,0)(-0.55,1)(-0.35,2)  
( 0.86,0)( 0.72,1)( 0.59,2)  
( 0.89,0)(-0.07,1)(-0.99,2)  
(-1.00,0)( 0.03,1)( 0.99,2)



To już wszystko!

Dziękuję za uwagę,  
proszę o pytania i komentarze.

Marcin Borkowski  
marcinbo@mini.pw.edu.pl