

Rój cząsteczek

Particle Swarm Optimization

Adam Grycner

Instytut Informatyki Uniwersytetu Wrocławskiego

18 maja 2011

Praca Kennedy'ego i Eberhart'a

- W 1995 *James Kennedy* i *Russell Eberhart* opublikowali pracę o tytule *Particle Swarm Optimization*.
- Zaprezentowali oni nową metodę optymalizacji ciągłych nieliniowych funkcji.
- Opierała się ona na dwóch metodach
 - 1 Sztuczne życie [*artificial life*] (stada ptaków, ławice ryb, teoria roju)
 - 2 Ewolucja obliczeniowa [*evolutionary computation*] (algorytmy genetyczne, strategie ewolucyjne, programowanie genetyczne)

Obserwacja ławic, stad

- powracanie do miejsca, gdzie wcześniej znaleziono jedzenie
- przekazywanie informacji o pożywieniu wewnątrz stada/ławicy

Cechy stada

- bezpieczeństwo ruchu
zdolność do poruszania się bez ryzyka kolizji z przeszkodami znajdującymi się w przestrzeni, oraz z innymi osobnikami
- rozprzestrzenianie się
zdolność do rozprzestrzeniania się stada w celu ustalenia i zarządzania minimalnymi odległościami między osobnikami
- skupianie
zdolność do gromadzenia się osobników stada w celu ustalenia i zarządzania maksymalnymi odległościami między osobnikami
- orientacja
zdolność znajdowania określonych regionów lub punktów w przestrzeni

Cechy stada

- ~~bezpieczeństwo ruchu~~

W abstrakcyjnym środowisku jest nieistotne. Agenci mogą zajmować taką samą pozycję.

- ~~rozprzestrzenianie się~~

Przy optymalizacji pragniemy zbieżności

- skupianie

- orientacja

Rój

Po wyeliminowaniu dwóch cech stada okazało się, że ruch agentów bardziej przypomina zachowanie roju cząsteczek, a nie stada/ławicy.

Cechy inteligentnego roju

Cechy inteligentnego roju według Millonas'a

- **bliskość**
obsługa populacji powinna zajmować proste struktury i mało mocy obliczeniowej
- **jakość**
ocena jakości cząstek
- **różnorodność odpowiedzi**
populacja powinna nie popadać w ograniczony zbiór zachowań
- **stabilność**
populacja nie powinna zmieniać zachowania przy każdej najmniejszej zmianie środowiska
- **adaptacyjność**
populacja powinna umieć zmienić swoje zachowanie jeśli się to opłaca

Atrybuty cząsteczki

- położenie
- prędkość
- jakość
- najlepsze swoje położenie
- zbiór sąsiadów oraz najlepsze ich położenie

Wybory cząsteczki

Cząsteczka stara się poruszać zgodnie z trzema kierunkami

- zgodnie z poprzednim kierunkiem
- zgodnie z kierunkiem do najlepszej znalezionej pozycji
- zgodnie z kierunkiem do najlepszej pozycji znalezionej przez sąsiadów

Symulacja stada ptaków

Wzór 1

```
if presentx[] > pbestx[gbest] then vx[] = vx[] - rand()*g_increment  
if presentx[] < pbestx[gbest] then vx[] = vx[] + rand()*g_increment  
if presenty[] > pbesty[gbest] then vy[] = vy[] - rand()*g_increment  
if presenty[] < pbesty[gbest] then vy[] = vy[] + rand()*g_increment
```

Wzór 2 - dostosowanie prędkości w zależności od odległości od maksimum

$$vx[i][j] = vx[i][j] + rand() * p_increment * (pbestx[i][j] - presentx[i][j])$$

Wzór 3 - statystycznie przez połowę czasu cząsteczka będzie przelatywać przez maksimum

$$\begin{aligned} vx[i] &= vx[i] + \\ &\quad 2 * rand() * (pbestx[i] - presentx[i]) + \\ &\quad 2 * rand() * (pbestx[gbest] - presentx[i]) \end{aligned}$$

Wzór 4 - ostateczny wzór:


Wzór na ruch cząsteczki

$$v = c_1 r_1 v + c_2 r_2 (pbest - x) + c_3 r_3 (gbest - x)$$

$$x = x + v$$

gdzie

- v - prędkość cząsteczki
- x - położenie cząsteczki
- $pbest$ - najlepsze znalezione przez cząsteczkę położenie
- $gbest$ - najlepsze znalezione przez zbiór sąsiadów położenie
- c_1, c_2, c_3 - współczynniki określające wpływ poszczególnych elementów
- r_1, r_2, r_3 - wartości losowe z rozkładu jednostajnego $U(0, 1)$




Dla $c_1 = r_1 = 1$ cząsteczki wykonują *swarming movement* wokół:


$$\frac{1}{c_2 + c_3} (c_2 pbest + c_3 gbest)$$

```
Wylosuj początkowe położenia i prędkości roju
while kryterium_zatrzymania
  dla każdej cząsteczki i
    zaktualizuj prędkość według wzoru 4
    zaktualizuj pozycję według wzoru 4
    jeżeli  $f(\text{nowa\_pozycja}) < f(\text{pbest\_i})$ :
      pbest_i = nowa_pozycja
    jeżeli  $f(\text{nowa\_pozycja}) < f(\text{gbest\_i})$ :
      gbest_i = nowa_pozycja
```


Brak sąsiedztwa




Sąsiedztwo globalne



- łatwe w implementacji
- wymaga niskich kosztów obliczeniowych
- szybko zbiega

Sąsiedztwo według indeksu


Pierścień



- Sąsiadami są cząsteczki o indeksach $\langle i - l; i + l \rangle$ modulo liczba cząsteczek


Sąsiedztwo według indeksu

Koło




Sąsiedztwo według indeksu

Von Neumann



Sąsiedztwo przestrzenne



- Po każdej iteracji szukamy k najbliższych cząsteczek według ustalonej metryki

Sąsiedztwo przestrzenne

Szukanie k najbliższych sąsiadów według parametru

$$\psi_{ab} = \frac{|pos_a - pos_b|}{\max_{i,j \in S} |pos_i - pos_j|}$$

lub wykorzystanie dynamicznej wartości progowej

$$frac(k) = \frac{3k + 0.6k_{max}}{k_{max}}$$

gdzie

k_{max} - przewidywana maksymalna liczba iteracji

k - liczba iteracji

- kosztowne obliczeniowo
- lepiej przeszukuje przestrzeń przeszukiwań


Inne sąsiedztwa

- topologia gwiazdy
- topologia z “błędem” (zaburzenie poprzednich wersji)
- piramida

- Particle Swarm Optimization zostało zaprojektowane do optymalizacji rzeczywistych funkcji ciągłych.
- Jednak istnieją modyfikacje pozwalające optymalizować problemy, gdzie rozwiązaniami są wektory binarne lub wektory liczb całkowitych

Wersja binarna

- Wykorzystanie funkcji sigmoidalnej



Funkcja sigmoidalna

$$\text{sig}(v_{i,j}^t) = \frac{1}{1 + \exp(-v_{i,j}^t)}$$

Wersja binarna


- Wykorzystanie funkcji sigmoidalnej

Nowe współrzędne cząsteczki

$$x_{i,j}^{t+1} = \begin{cases} 0 & \text{jeżeli } r_{3,j}^t \geq \text{sig}(v_{i,j}^{t+1}) \\ 1 & \text{w.p.p.} \end{cases}$$

- $r_{3,j}^t = U(0, 1)$

Geometric PSO



- Wykorzystane krzyżowanie z trzema rodzicami
- z ppb. w_1 na pozycji x_j przepisujemy zawartość j -tej pozycji poprzedniego położenia
- z ppb. w_2 na pozycji x_j przepisujemy zawartość j -tej pozycji $pbest$
- z ppb. w_3 na pozycji x_j przepisujemy zawartość j -tej pozycji $gbest$

PSO dla problemów kombinatorycznych

Należy zdefiniować, czym jest:

- położenie cząsteczki
(np. permutacja)
- prędkość
(np. lista transpozycji)
- odejmowanie[pozycja, pozycja]
(wynik: wektor prędkości między x_1 , a x_2)
- mnożenie zewnętrzne[skalar, prędkość]
- dodawanie[wektor, wektor]
- zastępowanie[pozycja, wektor]
zaaplikowanie położenia do prędkości

Współczynnik inercji

Dodatkowy współczynnik do równania na prędkość cząsteczki

Wzór na prędkość

$$v = c_1 r_1 v + c_2 r_2 (pbest - x) + c_3 r_3 (gbest - x)$$

- c_1 maleje z czasem
- duża inercja - aktywna eksploracja całej dziedziny
- mała inercja - przeszukiwanie lokalnej

Limit prędkości

W celu uniknięcia zjawiska *eksplozji* (ucieczki cząsteczek w pierwszych iteracjach) często wprowadza się limit prędkości cząsteczki i -tej na pozycji k -tej.

$$v'_{i,k} = \begin{cases} v_{i,k} & \text{jeżeli } v_{i,k} \leq v_{max} \\ v_{max} & \text{jeżeli } v_{i,k} > v_{max} \end{cases}$$

lub

$$v'_{i,k} = \begin{cases} v_{i,k} & \text{jeżeli } v \leq v_{max} \\ \frac{v_{max}}{v} v_{i,k} & \text{jeżeli } v > v_{max} \end{cases}$$

gdzie $v = |v_i|$

Selekcja

- 1 wybierz połowę cząsteczek
 - selekcja turniejowa
 - lepsza połowa
- 2 skopiuj położenia lepszych cząsteczek w miejsce gorszych
- 3 pozostaw informację *pbest* oraz prędkości gorszych cząsteczek

Wzmocnienie przeszukiwania lokalnego kosztem globalnego.

Zbyt szybkie zbieganie do ekstremów lokalnych.

Hodowla cząsteczek

Reprodukcja i rekombinacja

- nadanie cząsteczkom ppb. wyboru, jako rodzica
- wylosowanie rodziców i skrzyżowanie arytmetyczne położeń oraz prędkości

$$\begin{cases} pos'_a &= rpos_a + (1-r)pos_b \\ pos'_b &= rpos_b + (1-r)pos_a \end{cases}$$

$$\begin{cases} v'_a &= \frac{v_a+v_b}{|v_a+v_b|} |v_a| \\ v'_b &= \frac{v_a+v_b}{|v_a+v_b|} |v_b| \end{cases}$$

$$r \in (0, 1)$$

Inne

- mutacja
- specjacja
- różnicowanie (*diversity*) - niszowanie, dzielenie funkcji przystosowania itd.

Adaptacja

Istnieją modyfikacje PSO, w którym w raz z upływem czasu zmienia się:

- rozmiar roju
- rozmiar sąsiedztwa cząsteczki
- współczynniki c_1 , c_2 , c_3

Multiswarm PSO

- Wprowadzamy kilka rojów, każdy o innym kolorze
- Cząsteczki o różnych kolorach odpychają się
- Wprowadzamy siłę odpychającą, którą dodamy do wyliczanej prędkości

$$\frac{\lambda}{|x-y|^2} \frac{x-y}{|x-y|} = \frac{\lambda}{|x-y|^3} (x-y)$$

$$\lambda = \begin{cases} 0 & \text{jeżeli cząsteczki są tego samego koloru} \\ 1 & \text{jeżeli cząsteczki są różnego koloru} \end{cases}$$

Dobre do optymalizacji wielomodalnej

Bibliografia



Maurice Clerc, *Particle Swarm Optimization*



J. Kennedy, R. Eberhart, *Particle Swarm Optimization*



K. Kameyama, *Particle Swarm Optimization – A Survey*



E. Talbi, *Metaheuristics : from design to implementation*



materiały dostarczone przez prowadzącego

Dziękuję za uwagę