



Politechnika Wrocławska

Metody Systemowe i Decyzyjne w Informatyce

Wykład 6a. Algorytmy Inspirowane Naturą




Agenda

- Wprowadzenie
- Algorytm Wspinaczkowy - Stochastyczny
- Symulowane Wyżarzanie
- Algorytm Mrówkowy
- Algorytm Pszczeli
- Algorytm Roju Cząstek


Wprowadzenie

- Heurystyka to odgadywanie rozwiązania.
- Stosowana tam, gdzie pełne przeszukiwanie rozwiązań jest niemożliwe / nieopłacalne.
- Nie zawsze zwraca optymalne rozwiązanie.
- Może być wejściem dla innego algorytmu.
- Sami stosujemy ją na co dzień.




Wprowadzenie - Algorytm losowy

1. Zaczyna w losowym punkcie.
2. Losuje nowy punkt z rozkładem jednostajnym, na całej przestrzeni.
3. Jeśli nowy jest lepszy od obecnego kandydata - zastępuje.



Wprowadzenie - Algorytm losowy


```
Input: NumIterations, ProblemSize, SearchSpace  
Output: Best  
Best  $\leftarrow \emptyset$   
For ( $iter_i \in \text{NumIterations}$ )  
     $candidate_i \leftarrow \text{RandomSolution}(\text{ProblemSize}, \text{SearchSpace})$   
    If ( $\text{Cost}(candidate_i) < \text{Cost}(\text{Best})$ )  
        Best  $\leftarrow candidate_i$   
    End  
End  
Return (Best)
```



Algorytm losowy

Zalety i wady

- ☑ Zwraca stosunkowo dobre rozwiązanie w krótkim czasie.
- ☑ Dobry do wstępnego przeszukania przestrzeni rozwiązań.
 - ! Losowy wybór może być problematyczny, w zależności od dziedziny.
 - ! Nie jest skalowalny (rozmiar/wymiary).





Algorytmy inspirowane naturą

- wykorzystują analogię do procesów zachodzących w naturze w procesie przeszukiwania przestrzeni rozwiązań między innymi:
 - **błądzenie losowe** (*random walk*)
 - symulowane wyżarzanie (*simulated annealing*)
 - algorytmy genetyczne
 - strategie ewolucyjne
 - **algorytmy mrówkowy** (*ant colony optimization*)
 - **algorytm pszczele** (*artificial bee colony*)
 - algorytm roju cząsteczek (*particle swarm optimization*)
 - algorytm świetlika (*firefly algorithm*)
 - algorytm kukułki (*cuckoo search*)
 - algorytm nietoperza (*bat algorithms*)
 - algorytm zapylania kwiatów (*flower pollination algorithms*)



Poszukiwania losowe - Down Hill methods

Dane: $F(x), x_0, D_x, N$

Krok 0: $n=0, x^* = x_n$

Krok 1: Generujemy punkt x_{n+1} zbiorze D_x wg rozkładu jednostajnego

Krok 2: Jeżeli $F(x_{n+1}) < F(x^*)$ podstaw $x^* = x_{n+1}$

Krok 3: Jeżeli $n < N$ podstaw $n = n + 1$ idź do kroku 1

Krok 4: $x^* = x_N$

Algorytm Wspinaczkowy Stochastyczny

1. Zaczyna w losowym punkcie.

2. Losuje sąsiadującą wartość.

(Wariant: prawdopodobieństwo wyboru sąsiada zależy od wartości).

3. Porównuje ją z obecną i akceptuje, jeśli jest lepsza.





Algorytm Wspinaczkowy Stochastyczny



```
Input:  $Iter_{max}$ , ProblemSize  
Output: Current  
Current  $\leftarrow$  RandomSolution(ProblemSize)  
For ( $iter_i \in Iter_{max}$ )  
    Candidate  $\leftarrow$  RandomNeighbor(Current)  
    If (Cost(Candidate)  $\geq$  Cost(Current))  
        Current  $\leftarrow$  Candidate  
    End  
End  
Return (Current)
```

Algorytm Wspinaczkowy Stochastyczny - zalety i wady



- ! Podatny na lokalne optima.
- ! Optymalny jedynie dla funkcji wypukłych.
- ✓ W celu naprawy może być uruchamiany wielokrotnie, w sposób zrównoleglony.

Symulowane wyżarzanie



1. Losowo wybiera sąsiadującą wartość.
 2. Zmniejsza temperaturę (symuluje upływ czasu).
 3. Gdy wylosowana wartość jest lepsza, zastępuje aktualną.
 4. Jeśli nie jest lepsza oblicza $P(e, e', T) = \exp\left(\frac{e - e'}{T}\right)$, gdzie:
e - energia systemu w obecnym stanie (*)
e' - energia systemu w stanie wylosowanym
T - temperatura
- * energia systemu = wartość funkcji celu

Symulowane wyżarzanie



...

5. Obecna wartość jest zastępowana kandydującą, jeśli

$P(e, e', T) > x$, gdzie:

x - liczba losowa z przedziału $(0, 1)$

Symulowane wyżarzanie



```
Input: ProblemSize,  $iterations_{max}$ ,  $temp_{max}$   
Output:  $S_{best}$   
 $S_{current} \leftarrow \text{CreateInitialSolution}(\text{ProblemSize})$   
 $S_{best} \leftarrow S_{current}$   
For ( $i = 1$  To  $iterations_{max}$ )  
     $S_i \leftarrow \text{CreateNeighborSolution}(S_{current})$   
     $temp_{curr} \leftarrow \text{CalculateTemperature}(i, temp_{max})$   
    If ( $\text{Cost}(S_i) \leq \text{Cost}(S_{current})$ )  
         $S_{current} \leftarrow S_i$   
        If ( $\text{Cost}(S_i) \leq \text{Cost}(S_{best})$ )  
             $S_{best} \leftarrow S_i$   
    End  
    ElseIf ( $\text{Exp}(\frac{\text{Cost}S_{current} - \text{Cost}S_i}{temp_{curr}}) > \text{Rand}()$ )  
         $S_{current} \leftarrow S_i$   
    End  
End  
Return ( $S_{best}$ )
```

Symulowane wyżarzanie - informacje

- Przy współczynniku $T = 0$ algorytm staje się zachłannym.
- Początkowo chętniej akceptuje gorsze wartości.
- Wraz z wygaszaniem $T \rightarrow 0$ algorytm staje się wymagający, częściej akceptuje lepsze wartości.
- Opcjonalnie można resetować algorytm, by cyklicznie powracał do aktualnie najlepszego punktu.
- Zakres sąsiadujących próbek warto zmniejszać z czasem.



Symulowane wyżarzanie - zalety i wady

- ☑ Istnieje wariant algorytmu dla optymalizacji funkcji ciągłych.
- ☑ Istnieje wiele ulepszeń m.in. zrównoleglone wyżarzanie lub resetowanie temperatury z zapamiętaniem najlepszego rozwiązania.
- ! W najgorszym przypadku algorytm gorszy niż pełne przeszukanie.
- ! Problem z oszacowaniem okresu wyżarzania T .



Algorytm mrówkowy



1. Mrówki przeszukują przestrzeń losowo.
2. Jeśli natrafiają na „pożywienie”, tj. rozwiązanie - wracają do punktu startu zostawiając ślad feromonu.
3. Natrafiając na ślad feromonu podążają wyznaczoną ścieżką tym samym zwiększając ilość feromonu.
4. Feromon z czasem ulatnia się. Długie dystanse szybciej tracą intensywność feromonu.

Algorytm mrówkowy



$$P_{i,j} \leftarrow \frac{\tau_{i,j}^{\alpha} \times \eta_{i,j}^{\beta}}{\sum_{k=1}^c \tau_{i,k}^{\alpha} \times \eta_{i,k}^{\beta}}$$

,gdzie:

$\tau_{i,j}^{\alpha}$ - wartość feromonu dla ścieżki i - j

α - współczynnik wpływu wartości feromonu ~ 1

$\eta_{i,j}^{\beta}$ - np. $1 / \text{długość ścieżki}$ (dla problemu komiwojażera)

β - współczynnik heurystyki $\in (2, 5)$

c - rozmiar zbioru rozwiązań



Algorytm mrówkowy

Zanikanie ilości feromonu na ścieżkach:

Aktualizacja lokalna:

$$\tau_{i,j} \leftarrow (1 - \sigma) \times \tau_{i,j} + \sigma \times \tau_{i,j}^0, \text{ gdzie:}$$

σ - współczynnik historyczny ~ 0.1


$\tau_{i,j}^0$ - poprzednia wartość feromonu

Aktualizacja globalna:

$$\tau_{i,j} \leftarrow (1 - \rho) \times \tau_{i,j} + \rho \times \Delta\tau_{i,j}$$

ρ - współczynnik zanikania ~ 0.1

$\Delta\tau_{i,j}$ - nagroda za bycie częścią najlepszej ścieżki globalnej
(=0 dla pozostałych ścieżek)



Algorytm mrówkowy

```
Input: ProblemSize,  $Population_{size}$ ,  $m$ ,  $\rho$ ,  $\beta$ ,  $\sigma$ ,  $q_0$   
Output:  $P_{best}$   
 $P_{best} \leftarrow \text{CreateHeuristicSolution}(\text{ProblemSize})$   
 $P_{best\_cost} \leftarrow \text{Cost}(S_h)$   
 $\text{Pheromone}_{init} \leftarrow \frac{1.0}{\text{ProblemSize} \times P_{best\_cost}}$   
 $\text{Pheromone} \leftarrow \text{InitializePheromone}(\text{Pheromone}_{init})$   
While ( $\neg \text{StopCondition}()$ )  
  For ( $i = 1$  To  $m$ )  
     $S_i \leftarrow \text{ConstructSolution}(\text{Pheromone}, \text{ProblemSize}, \beta, q_0)$   
     $S_{i\_cost} \leftarrow \text{Cost}(S_i)$   
    if ( $S_{i\_cost} \leq P_{best\_cost}$ )  
       $P_{best\_cost} \leftarrow S_{i\_cost}$   
       $P_{best} \leftarrow S_i$   
    End  
     $\text{LocalUpdateAndDecayPheromone}(\text{Pheromone}, S_i, S_{i\_cost}, \sigma)$   
  End  
   $\text{GlobalUpdateAndDecayPheromone}(\text{Pheromone}, P_{best}, P_{best\_cost}, \rho)$   
End  
Return ( $P_{best}$ )
```



Algorytm mrówkowy - zalety i wady

Stosowany do rozwiązywania problemów plecakowych, grafowych, wykrywania krawędzi na obrazie.

! Duża liczba parametrów, które są zależne od problemu.

✓ Dla problemu komiwojażera lepszy niż alg. genetyczny, ewolucyjny czy symulowane wyżarzanie¹.

¹<https://www.assembla.com/spaces/easytsp/documents/duKXyk6n8r379GeJe5cbLr/download/duKXyk6n8r379GeJe5cbLr>

Algorytm pszczele



1. Zwiadowcy wysyłani są w losowe miejsca.
2. W okolicy znalezionych, dobrych wartości wysyłanych jest więcej osobników, w celu zbadania lokalnego optimum.
3. W każdej iteracji wysyłani są zwiadowcy w celu dalszej eksploracji przestrzeni rozwiązań.



Algorytm pszczele - I

Wyróżniamy grupy:

- *Zwiadowców*
- *Obserwatorów*
- *Zatrudnionych*



Algorytm pszczele - II

Zwiadowcy - przeszukują rozwiązania w sposób losowy

Zatrudnieni - przynoszą informacje o jakości rozwiązań do których są obecnie przypisani.

Obserwatorzy - wybierają następne miejsce na podstawie informacji od *zatrudnionych*.



Algorytm pszczele - III

Wyznaczanie źródeł pożywienia:

$x_{ij} = x_{\min j} + rand[0,1](x_{\max j} - x_{\min j})$, gdzie

x_{ij} - źródło pożywienia

$i = 1, \dots, P$ (P - liczba źródeł pożywienia)

$j = 1, \dots, D$ (D - rozmiar przestrzeni rozwiązań)



Algorytm pszczele - IV

Poszukiwanie pożywienia (pszczoły pracujące):

$$x'_{ij} = x_{ij} + \text{rand}[-1, 1](x_{ij} - x_{kj}), i=1, \dots, P, k \neq i$$

, gdzie:

$k \in \{1, 2, \dots, P\}$ oraz $j \in \{1, 2, \dots, D\}$

są dwoma losowo wyznaczonymi indeksami

Jeśli $F(x'_i) > F(x_i)$ to i -ta pszczoła zmienia źródło pożywienia



Algorytm pszczele - V

Poszukiwanie pożywienia (obserwatorzy):

$$p_i = \frac{F(x_i)}{\sum_{i=1}^P F(x_i)}, \quad i = 1, \dots, P$$

Obserwatorzy wybierają swój cel na podstawie informacji od pszczół pracujących, a następnie przeprowadzają lokalne przeszukiwanie w jego sąsiedztwie.

Analogicznie do symulowanego wyżarzania- sąsiedztwo jest zawężane wraz z czasem działania algorytmu.

Algorytm pszczele



```
Input: ProblemSize,  $iterations_{max}$ ,  $temp_{max}$   
Output:  $S_{best}$   
 $S_{current} \leftarrow \text{CreateInitialSolution}(\text{ProblemSize})$   
 $S_{best} \leftarrow S_{current}$   
For ( $i = 1$  To  $iterations_{max}$ )  
     $S_i \leftarrow \text{CreateNeighborSolution}(S_{current})$   
     $temp_{curr} \leftarrow \text{CalculateTemperature}(i, temp_{max})$   
    If ( $\text{Cost}(S_i) \leq \text{Cost}(S_{current})$ )  
         $S_{current} \leftarrow S_i$   
        If ( $\text{Cost}(S_i) \leq \text{Cost}(S_{best})$ )  
             $S_{best} \leftarrow S_i$   
    End  
    ElseIf ( $\text{Exp}(\frac{\text{Cost}S_{current} - \text{Cost}S_i}{temp_{curr}}) > \text{Rand}()$ )  
         $S_{current} \leftarrow S_i$   
    End  
End  
Return ( $S_{best}$ )
```



Algorytm pszczeli


Stosowany w Data Miningu - Analiza Skupień (Clustering Methods), optymalizacji sieci neuronowych oraz kwantyzacji wektorowej.

☒ Szybszy niż algorytmy genetyczny czy mrówkowy dla wielu wymiarów.

! Stworzony dla funkcji ciągłych

! Podobieństwo do zrównoległego algorytmu losowego - ryzyko wielokrotnego sprawdzania tego samego rozwiązania.

Algorytm Roju Cząstek



Celem algorytmu jest zgromadzenie wszystkich cząstek wokół optimum wielowymiarowej hiperprzestrzeni.

- Cząsteczkom przypisuje się losowe położenie i niską prędkość początkową.
- Symulowany jest ruch cząsteczek na podstawie jej prędkości, położenia, najlepszego znanego rozwiązania oraz optimum globalnego.
- Cząsteczki zbiegają do optimum/optimów.

Algorytm Roju Cząstek



Aktualizacja prędkości cząsteczki:

$$v_i(t+1) = v_i(t) + (c_1 \times rand() \times (p_i^{best} - p_i(t))) + (c_2 \times rand() \times (p_{gbest} - p_i(t)))$$

Aktualizacja położenia cząsteczki:

$$p_i(t+1) = p_i(t) + v_i(t)$$

, gdzie:

$v(t)$ - aktualna prędkość

$p_i(t)$ - aktualne położenie i-tej cząsteczki

P_i^{best} - najlepsze rozwiązanie znane i-tej cząsteczce

P_{gbest} - najlepsze rozwiązanie globalne

$rand()$ - wartość losowa z przedziału (0,1)

c_1, c_2 - współczynniki wag odpowiednio dla lokalnego i globalnego optimum (wartości z przedziału (0,4), zwykle = 2).



Algorytm Roju Cząstek

```
Input: ProblemSize,  $Population_{size}$   
Output:  $P_{g\_best}$   
 $Population \leftarrow \emptyset$   
 $P_{g\_best} \leftarrow \emptyset$   
For ( $i = 1$  To  $Population_{size}$ )  
     $P_{velocity} \leftarrow \text{RandomVelocity}()$   
     $P_{position} \leftarrow \text{RandomPosition}(Population_{size})$   
     $P_{p\_best} \leftarrow P_{position}$   
    If ( $\text{Cost}(P_{p\_best}) \leq \text{Cost}(P_{g\_best})$ )  
         $P_{g\_best} \leftarrow P_{p\_best}$   
    End  
End  
While ( $\neg \text{StopCondition}()$ )  
    For ( $P \in Population$ )  
         $P_{velocity} \leftarrow \text{UpdateVelocity}(P_{velocity}, P_{g\_best}, P_{p\_best})$   
         $P_{position} \leftarrow \text{UpdatePosition}(P_{position}, P_{velocity})$   
        If ( $\text{Cost}(P_{position}) \leq \text{Cost}(P_{p\_best})$ )  
             $P_{p\_best} \leftarrow P_{position}$   
            If ( $\text{Cost}(P_{p\_best}) \leq \text{Cost}(P_{g\_best})$ )  
                 $P_{g\_best} \leftarrow P_{p\_best}$   
            End  
        End  
    End  
End  
Return ( $P_{g\_best}$ )
```

Algorytm Roju Cząstek - informacje



- Liczba cząstek zazwyczaj wynosi 20-40
- Należy ustawić limit prędkości cząsteczki (% względem rozmiaru przestrzeni)
- Należy ustalić czy cząsteczki mogą wybiegać poza przestrzeń rozwiązań oraz ustalić kary, sposób powrotu (nowe położenie, kierunek, prędkość), ewentualnie zastosować pętle.
- Można uwzględnić zasadę pędu (niechęci do zmiany wektora prędkości).



Algorytm Roju Cząstek

Stosowany z powodzeniem w sieciach rozproszonych, przetwarzaniu obrazu i wideo, sterowaniu czy dziedzinie optymalizacji wielokryterialnej.

- ✓ Algorytm łatwo adaptuje się do różnych dziedzin
- ✓ Mała liczba parametrów
- ✓ Może być uruchamiany w sposób zrównoleglony (Multi-Swarm Optimization)

⚠ Aplikacja dla dyskretnej dziedziny wymaga mapowania na liczby rzeczywiste

! Możliwe przedwczesne zbieganie cząstek do lokalnych optimów



Bibliografia

- *Clever Algorithms: Nature-Inspired Programming Recipes*, Jason Brownlee
- *Population-Based Incremental Learning: A Method for Integrating Genetic Search Based Function Optimization and Competitive Learning*, Shumeet Baluja, School of Computer Science Carnegie Mellon University Pittsburgh, 1994
- The Bees Algorithm - A Novel Tool for Complex Optimisation Problems, D.T. Pham, A. Ghanbarzadeh, E. Koç et. al, Cardiff University, 2006
- Zastosowanie Algorytmów Rojowych do Optymalizacji Parametrów w Modelach Układów Regulacji, Mirosław Tomera, Zeszyty Naukowe Wydziału Elektrotechniki i Automatyki Politechniki Gdańskiej Nr 46, 2015
- Automatic Tuning of a Retina Model for a Cortical Visual Neuroprosthesis Using a Multi-Objective Optimization Genetic Algorithm, Antonio Martínez-Álvarez, Rubén Crespo-Cano, Ariadna Díaz-Tahoces et. al., International Journal of Neural Systems 26/7, 2016