

Obliczenia inspirowane Naturą

Wykład 10 - Mrówki w labiryntach

Jarosław Miszczak

IITiS PAN Gliwice

05/05/2016

Na poprzednim wykładzie

1 ...

2 ...

3 ...

- 1 Wprowadzenie
 - Motywacja biologiczna
 - Podstawowe mechanizmy
- 2 Metaheurystyka oparta na koloni mrówek
 - Model zachowania mrówek
 - Wyszukiwanie ścieżki w grafie
 - Algorytm S-ACO
- 3 Zastosowanie w optymalizacji
 - Wprowadzenie
 - Reprezentacja
 - Problem komiwojażera
 - Dyskretny problem plecakowy
- 4 Podsumowanie

Wprowadzenie

Motywacja biologiczna

- Marco Dorigo, 1991 – algorytmy mrówkowe zostały zaproponowane w jego pracy doktorskiej.
- Pomysł opiera się na obserwacji mrówek szukających pożywienia dla swojej koloni i stąd nazwa *ant colony optimization algorithm* (ACO).
- Algorytmy oparte na zasadach ACO stały się bardzo popularne do rozwiązywania problemów związanych z optymalizacją dyskretną, szczególnie związanych z wyszukiwaniem ścieżek w grafach.

Wprowadzenie

Motywacja biologiczna

- Społeczeństwa mrówek (i innych owadów) stanowią przykłady bardzo złożonych systemów.
- Pomimo, iż możliwości pojedynczej mrówki są bardzo ograniczone, dzięki współpracy potrafią one na tworzenie bardzo skomplikowanych zachowań i struktur.

Społeczne zachowania owadów

- Około 2% wszystkich owadów wykazuje zachowania społeczne.
- Połowa owadów które tworzą struktury społeczne to mrówki.
- Mrówki kolonizują Ziemię od 100 milionów lat.

Wprowadzenie

Motywacja biologiczna



Inside the ant colony - Deborah M. Gordon

(<http://ed.ted.com/lessons/inside-the-ant-colony-deborah-m-gordon>)

Wprowadzenie

Podstawowe mechanizmy

Przy budowaniu modelu zachowania mrówek ważne jest zauważenie, iż:

- owady są niemal całkowicie ślepe;
- komunikacja między mrówkami odbywa się na zasadzie *stygmergi* (*ang.* stigmergy), czyli modyfikowania swojego środowiska/otoczenia;
- praca wykonywana przez kolonię mrówek znacznie przekracza możliwości każdego osobnika z osobna.

Wprowadzenie

Podstawowe mechanizmy

Stygmergia

Sposób porozumiewania się poprzez wprowadzanie zmian w środowisku, np. poprzez pozostawianie feromonów przez mrówki, tworzenie przez zwierzęta ścieżek do wodopoju lub wyznaczania drogi na skróty.

Pierre-Paul Grassé, 1959

Stimulation of workers by the performance they have achieved.

Wprowadzenie

Podstawowe mechanizmy



(Zdjęcie: J.A. Miszczak)

Na poprzednim wykładzie

Wprowadzenie

Metaheurystyka oparta na koloni mrówek

Zastosowanie w optymalizacji

Podsumowanie

Motywacja biologiczna

Podstawowe mechanizmy

Wprowadzenie

Podstawowe mechanizmy

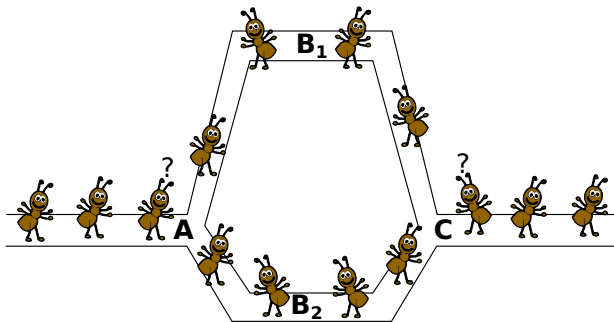


(Zdjęcie: J.A. Miszczak)

Metaheurystyka oparta na koloni mrówek

Model zachowania mrówek

Mrówki wyszukujące drogi między punktami **A** (punkt decyzyjny 1) i **C** (punkt decyzyjny 2).



(Rysunek mrówki: <https://openclipart.org/user-detail/Firkin>)

Metaheurystyka oparta na koloni mrówek

Model zachowania mrówek

- Każda mrówka ma do wyboru drogi B_1 (dłuższa) i B_2 (krótsza).
- Wybór drogi działa na zasadzie dodatniego sprzężenia zwrotnego.
 - Jeżeli mrówka wybierze krótszą drogę, to jej ślad feromonowy przyczyni się do zwiększenia atrakcyjności tej ścieżki (krótsza droga = częstsze odświeżanie śladu).
 - Jeżeli mrówka wybierze dłuższą, to jej ślad feromonowy zdąży bardziej wyparować.

Metaheurystyka oparta na koloni mrówek

Model zachowania mrówek

- Zasada działania algorytmów mrówkowych opiera się na odtworzeniu średniego zachowania owadów.
- Ilość feromonu jest proporcjonalna do ilości mrówek.
- Ilość feromonu na ścieżce w chwili t w punkcie i zależy od wybrania tej ścieżki w chwili $t - t_s$ w punkcie j oraz od wybrania tej ścieżki w chwili t w punkcie i .

Metaheurystyka oparta na koloni mrówek

Model zachowania mrówek

- Oznaczamy przez p_{ia} prawdopodobieństwo, że mrówka przybywająca do punktu decyzyjnego $i \in \{1, 2\}$ wybierze drogę $a \in \{s, l\}$.
- Dłuższa ścieżka ma długość r -razy większą niż ścieżka krótsza.
- W ciągu sekundy trasę przebywa ψ mrówek – stały przepływ.

Metaheurystyka oparta na koloni mrówek

Model zachowania mrówek

Prawdopodobieństwo wybrania krótszej drogi wynosi

$$p_{is}(t) = \frac{(k + \phi_{is}(t))^{\alpha}}{(k + \phi_{is}(t))^{\alpha} + (k + \phi_{il}(t))^{\alpha}}$$

gdzie zarówno wartości $\alpha = 2$ oraz $k = 20$, jaki i postać równania zostały dobrane na podstawie eksperymentów.

(J.-L. Deneubourg et al., *The self-organizing exploratory pattern of the Argentine ant*. J. Insect Behav., 3:159–168, 1990. DOI: 10.1007/BF01417909.)

Metaheurystyka oparta na koloni mrówek

Model zachowania mrówek

Równania różniczkowe opisujące ewolucję systemu mają postać

$$\frac{d\phi_{is}(t)}{dt} = \psi p_{js}(t - t_s) + \psi p_{is}(t) \quad (i = 1, j = 2; i = 2, j = 1)$$

$$\frac{d\phi_{il}(t)}{dt} = \psi p_{jl}(t - rt_s) + \psi p_{il}(t) \quad (i = 1, j = 2; i = 2, j = 1)$$

gdzie ψ to przepływ mrówek, przyjmowany jako stały, a $r = l_l/l_s$ wprowadza opóźnienie wynikające z długości dłuższej ścieżki.

Metaheurystyka oparta na koloni mrówek

Model zachowania mrówek

W modelu dyskretnym

- interesuje nas średnie zachowanie mrówek;
- liczba mrówek jest liczbą naturalną;
- system jest opisany równaniami różnicowymi.

Metaheurystyka oparta na koloni mrówek

Model zachowania mrówek

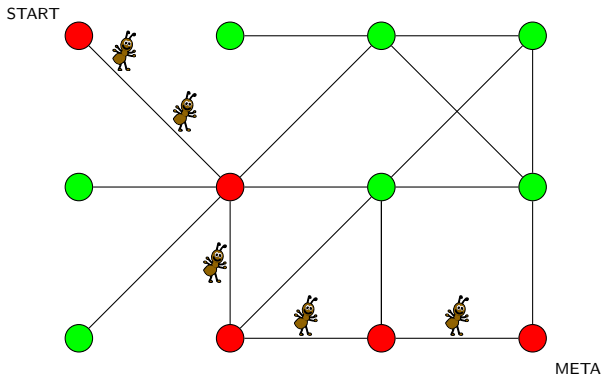
Prawdopodobieństwa wyboru ścieżki, $p_{is}(t)$ oraz $p_{il}(t)$, są funkcjami ilości zdeponowanego feromonu.

$$p_{is}(t) = \frac{(\phi_{is}(t))^\alpha}{(\phi_{is}(t))^\alpha + (\phi_{il}(t))^\alpha}, \quad p_{il}(t) = 1 - p_{is}(t),$$

$$i = 1, 2.$$

Metaheurystyka oparta na koloni mrówek

Wyszukiwanie ścieżki w grafie



Metaheurystyka oparta na koloni mrówek

Wyszukiwanie ścieżki w grafie

- W realnych zastosowaniach grafy które chcemy przeszukiwać są o wiele bardziej złożone niż graf ilustrujący zachowanie prawdziwych mrówek.
- Algorytmy mrówkowe to *metaheurystyka* – zachowanie mrówek daje tylko ogólne wytyczne, które służą do konstrukcji algorytmów.

Metaheurystyka oparta na koloni mrówek

Wyszukiwanie ścieżki w grafie

Realne problemy

- W grafach o złożonej strukturze mrówki są podatne na wpadanie w pętle.
- Poprzez dodatnie sprzężenie zwrotne pętle stają się coraz bardziej atrakcyjne.
- Eliminacja śladu dla jednego kierunku nie jest rozwiązaniem.

Metaheurystyka oparta na koloni mrówek

Algorytm S-ACO

Algorytm S-ACO (Simple Ant Colony Optimization)

- Zwiększenie możliwości mrówek (agentów) poprzez dodanie pamięci.
- Wykorzystanie parowania śladu feromonowego do eliminacji słabych rozwiązań.

Metaheurystyka oparta na koloni mrówek

Algorytm S-ACO

W S-ACO:

- rozwiązanie budowane jest losowo;
- aktualizacja śladu odbywa się deterministycznie.

Metaheurystyka oparta na koloni mrówek

Algorytm S-ACO

- S-ACO działa na grafie (N, A) gdzie N to wierzchołki, a A to krawędzie.
- Z każdą krawędzią powiązana jest wielkość τ_{ij} śladu feromonowego.
- Mrówki mogą odczytywać i zapisywać τ_{ij} .

Metaheurystyka oparta na koloni mrówek

Algorytm S-ACO

Pierwszym etapem jest budowanie rozwiązań:

- W S-ACO każdy z agentów (czyli mrówek) jest w jednym z dwóch stanów: *poszukiwania* (inaczej *forward*) lub *powrotu* (inaczej *backward*).
- W trybie *poszukiwania* mrówka:
 - porusza się od startu do mety;
 - nie pozostawia śladu feromonowego.
- Ścieżka jest wybierana poprzez losowy wybór następnego wężła z uwzględnieniem śladu feromonowego.
- Mrówka przechodzi do stanu *powrotu* po dotarciu do wężła końcowego.

Metaheurystyka oparta na koloni mrówek

Algorytm S-ACO

- Początkowe wartości śladu feromonowego są ustalane jako $\tau_{ij} = 1$.
- W węźle i mrówka wybiera następny węzeł jako j z prawdopodobieństwem

$$p_{ij}^{(k)} = \frac{\tau_{ij}^{\alpha}}{\sum_{l \in N_i^{(k)}} \tau_{il}^{\alpha}},$$

gdzie $N_i^{(k)}$ to sąsiedztwo węzła i , z wyłączeniem węzła poprzednio odwiedzonego przez mrówkę.

Metaheurystyka oparta na koloni mrówek

Algorytm S-ACO

W drugim etapie mrówka aktualizuje ślad feromonu:

- Mrówka wraca po **zapamiętanej** ścieżce – przechodzi do trybu *powrotu* (backward).
- Trasa powrotna jest tworzona po wyeliminowaniu pętli.
- W trybie *powrotu* mrówka aktualizuje ślad feromonowy.
- Ilość pozostawionego feromonu jest zależna od jakości rozwiązania – im krótsza ścieżka, tym więcej feromonu.

Metaheurystyka oparta na koloni mrówek

Algorytm S-ACO

Podczas powrotu k -ta mrówka zmienia stan śladu feromonowego według zależności

$$\tau_{ij} = \tau_{ij} + \Delta\tau^{(k)}.$$

Sposób wyboru $\Delta\tau^{(k)}$ jest ważny dla działania algorytmu.

Metaheurystyka oparta na koloni mrówek

Algorytm S-ACO

W S-ACO dochodzi do parowania pozostawionego śladu feromonowego.

- Parowanie może być ustalone jako stały zanik w czasie.
- Zanikanie śladu pozwala na uniknięcie zbyt szybkiej zbieżności i eliminację słabych rozwiązań.

Zanik śladu nie jest kluczowy dla działania prawdziwych mrówek.

Metaheurystyka oparta na koloni mrówek

Algorytm S-ACO

W każdej iteracji algorytmu ślad feromonowy jest zmniejszany zgodnie z regułą

$$\tau_{ij} = (1 - \rho)\tau_{ij}$$

dla wszystkich krawędzi grafu, $(i, j) \in A$, z $\rho \in (0, 1]$.

Zastosowanie w optymalizacji

Wprowadzenie

Algorytmy ACO mogą być stosowane do wielu zagadnień *optymalizacji kombinatorycznej*.

- Zadaniem optymalizacji kombinatorycznej jest znalezienie w zbiorze skończonym obiektu *optymalnego*.
- Zadania takie są często łatwe do sformułowania ale okazują się trudne do rozwiązania.
- Kluczowe w zastosowaniu ACO jest znalezienie odpowiedniej reprezentacji problemu.

Zastosowanie w optymalizacji

Wprowadzenie

Przykłady

- Znalezienie najkrótszego cyklu Hamiltona w grafie – tzw. problem komiwojażera (ang. *Traveling Salesman Problem* (TSP)). (optymalizacja jest **NP**-trudna, problem decyzyjny jest **NP**-zupełny)
- Problem pakowania plecaka (ang. *knapsack problem*) – mając skończony zbiór obiektów, zapakuj plecak o zadanej objętości tak, żeby zmaksymalizować wartość pakunku. (**NP**-trudny)

Zastosowanie w optymalizacji

Wprowadzenie

Instancją problemu optymalizacji kombinatorycznej nazywamy trójkę (\mathcal{S}, f, Ω) , gdzie

- \mathcal{S} to zbiór rozwiązań,
- $f : \mathcal{S} \mapsto \mathbb{R}$ to funkcja celu,
- Ω to zbiór ograniczeń.

Zadaniem **minimalizacji** jest znalezienie $s^* \in \mathcal{S}$ takiego, że $f(s^*) \leq f(s)$ dla $s \in \mathcal{S}$.

Zastosowanie w optymalizacji

Wprowadzenie

Każdy problem optymalizacji dyskretnej ma wersję decyzyjną.

Wersja decyzyjna

Czy dla zadanego parametru ρ istnieje rozwiązanie s takie że $f(s) \leq \rho$?

Zastosowanie w optymalizacji

Wprowadzenie

- Algorytm dokładny – gwarantuje znalezienie optymalnego rozwiązania.
- Algorytm przybliżony – rezygnujemy z optymalności na rzecz wydajności.

Zastosowanie w optymalizacji

Reprezentacja

Problem

Przedstawienie problemu w sposób przystosowany do zasad działania mrówek.

Zastosowanie w optymalizacji

Reprezentacja

Reprezentacja na potrzeby ACO ma następujące składniki:

- Skończony zbiór *komponentów* $C = \{c_1, c_2, \dots, c_{N_c}\}$.
- *Stany* określone jako skończone ciągi elementów zbioru C .
Zbiór wszystkich stanów oznaczamy przez \mathcal{X} .
- Zbiór rozwiązań $\mathcal{S} \subseteq \mathcal{X}$ i zbiór dopuszczalnych rozwiązań $\tilde{\mathcal{X}} \subseteq \mathcal{X}$, czyli takich które spełniają warunki Ω .
- Niepusty zbiór rozwiązań optymalnych $\mathcal{S}^* \subseteq \tilde{\mathcal{X}}$.
- Funkcja kosztu zdefiniowana dla każdego $s \in \mathcal{S}$.

Zastosowanie w optymalizacji

Reprezentacja

W algorytmach ACO, mrówki to procedury, które probabilistycznie budują rozwiązania problemu poruszając się po grafie pełnym $G_C = (C, E)$, gdzie E to krawędzie łączące wszystkie wierzchołki.

Informacja heurystyczna

W wielu wypadkach oprócz śladu feromonowego mrówki korzystają z *informacji heurystycznej*, η_{ij} , która wpływa na wybór ścieżki.

Czasem pozwala się, żeby mrówki budowały *niedopuszczalne* rozwiązania.

Zastosowanie w optymalizacji

Problem komiwojażera

Problem komiwojażera

Znalezienie minimalnego cyklu Hamiltona w pełnym grafie ważonym $G = (N, E)$ dla zbioru miast N oraz krawędzi E .

- Waga jest tu interpretowana jako odległość między miastami.
- Wagi są wykorzystywane do konstrukcji rozwiązań – mrówki chętniej wybierają bliższe miasta.

Zastosowanie w optymalizacji

Problem komiwojażera

- Każdy z $n = |G|$ węzłów grafu ma być odwiedzony tylko raz.
- Funkcja

$$f(\pi) = \sum_{i=1}^{n-1} d_{\pi(i)\pi(i+1)} + d_{\pi(n)\pi(1)}$$

ma być minimalizowana.

Zastosowanie w optymalizacji

Problem komiwojażera

- Graf dla problemu jest grafem pełnym.
- Komponentami są węzły grafu.
- Stanem jest ciąg odwiedzanych miast.

Zastosowanie w optymalizacji

Problem komiwojażera

- Ograniczenia na zbiór dozwolonych rozwiązań: każdy węzeł ma być odwiedzony dokładnie raz.
- W węźle i mrówka wybiera następny węzeł jako j z prawdopodobieństwem

$$p_{ij}^{(k)} = \frac{\tau_{ij}^{\alpha} \eta_{ij}^{\beta}}{\sum_{l \in N_i^{(k)}} \tau_{il}^{\alpha} \eta_{il}^{\beta}},$$

gdzie $\eta_{ij} = \frac{1}{d_{ij}}$.

Zastosowanie w optymalizacji

Problem komiwojażera

- Warunek jednokrotnego odwiedzenia miast jest zachowany poprzez przechowywanie listy odwiedzonych miast – *lista tabu*.
- Po odwiedzeniu wszystkich miast lista jest czyszczona.

Zastosowanie w optymalizacji

Problem komiwojażera

Aktualizacja śladu feromonowego może być wykonywana na różne sposoby:

- model gęstościowy – każda mrówka pozostawia stałą ilość feromonu, $\tau_{ij} \mapsto \tau_{ij} + Q_1$.
- model ilościowy – ilość pozostawionego feromonu zależy jest odwrotnie proporcjonalna do długości krawędzi, $\tau_{ij} \mapsto \tau_{ij} + \frac{Q_2}{d_{ij}}$;
- model cykliczny – ilość feromonu jest odwrotnie proporcjonalna od długości trasy przebytej do tej pory przez mrówkę.

Zastosowanie w optymalizacji

Dyskretny problem plecakowy

- Mamy do dyspozycji zbiór obiektów $\{x_1, x_2, \dots, x_N\}$ oraz plecak o pojemności B .
- Każdy obiekt ma swoją wielkość w_i oraz wartość c_i .
- Zadaniem jest maksymalizacja

$$\sum_i c_i x_i$$

przy założeniu

$$\sum_i w_i p(x_i) \leq B,$$

gdzie $p(x_i) \in \{0, 1\}$ (czyli każdy obiekt może być spakowany najwyżej raz).

Zastosowanie w optymalizacji

Dyskretny problem plecakowy

- Komponentami są pakowane przedmioty,
- Graf konstrukcyjny to graf zupełny.
- Prawdopodobieństwa przejścia są postaci

$$p_{ij} = \frac{\mu_{ij}^{\alpha} \tau_{ij}^{\beta}}{\sum_{j \in N_i} \mu_{ij}^{\alpha} \tau_{ij}^{\beta}}$$

Zastosowanie w optymalizacji

Dyskretny problem plecakowy

Informacja heurystyczna może być określona na różne sposoby

- $\mu_i = \frac{z_j}{w_j/B_c}$, gdzie B_c to dostępna objętość plecaka,
- $\mu_i = \frac{z_j}{w_j/B}$,
- $\mu_i = \frac{z_j}{w_j^2}$

(K. Schiff, *Ant colony optimization algorithm for the 0-1 knapsack problem*,
Czasopismo Techniczne. Automatyka — 2013 tom R. 110, z. 3-AC 39–52)

Podsumowanie

- Oprogramowanie i inne zasoby związane z ACO:
<http://www.aco-metaheuristic.org/>
- Wykład Paweła Paducha, Obliczenia Naturalne, Politechnika Świętokrzyska, 2014 (<http://achilles.tu.kielce.pl/Members/ppaduch/wyk142ady/obliczenia-naturalne/>)
- Marco Dorigo, Thomas Stützle, *Ant Colony Optimization*, MIT Press, 2003.