

Strategie Zespołowe (SZ)

dr inż. Tomasz Białaszewski

Tematyka wykładu

- Algorytmy Inteligencji Roju (Swarm Intelligence, SI)
 - Optymalizacja kolonią mrówek
(Ant Colony Optimization, ACO)
 - Optymalizacja rojem robaczków świętojańskich
(Glowworm Swarm Optimization GSO)
(Firefly Algorithm, FA)
 - Algorytm pszczół
(Bees Algorithm, BA)

Tematyka wykładu

- Algorytm dynamiki formowania rzek
(River Formation Dynamics, RFO)
- Algorytm poszukiwań dyfuzją stochastyczną
(Stochastic Diffusion Search, SDS)
- Algorytm poszukiwań grawitacyjnych
(Gravitational Search Algorithm, GSA)
- Algorytm inteligencji kroplami wody
(Intelligent Water Drops, IWD)


Tematyka wykładów

- Algorytm poszukiwań naładowanymi cząstkami
(Charged System Search, CSS)
- Sztuczne Systemy Immunologiczne
(Artificial Immune Systems, AIS)
- Magnetyczny algorytm optymalizacji
(Magnetic Optimization Algorithm, MOA)

Inteligencja Roju (Swarm Intelligence)

- Koncepcja rozwinięta podczas prac nad sztuczną inteligencją


- Gerardo Beni & Jing Wang (1989) – automaty komórkowe



- Cechy systemów SI:
 - zdecentralizowane zbiorowe zachowanie, naturalnych lub sztucznych samoorganizujących się systemów
 - populacja prostych agentów lub sztucznych istot
 - agenci współpracujący ze sobą i ze swoim środowiskiem

Inteligencja Roju (Swarm Intelligence)

- Inspiracja pochodzi często z natury, w szczególności z systemów biologicznych
- Przykładowo:
 - kolonie mrówek
 - stada ptaków
 - stada zwierząt
 - wzrost bakterii
 - ławice ryb



Inteligencja Roju (Swarm Intelligence)

- Charakterystyka agentów:
 - proste reguły
 - brak scentralizowanej struktury kontroli zachowań lokalnych i do pewnego stopnia przypadkowych
- Wzajemne oddziaływanie \Rightarrow **inteligentnego globalnego zachowania (emergencja)** nieznanego dla pojedynczych agentów



Inteligencja Roju (Swarm Intelligence)

- **Swarm robotics** – zastosowanie zasad inteligencji roju dla grup współpracujących robotów
- **Swarm intelligence** – odnosi się do zbioru algorytmów
- **Swarm prediction** – problemy predykcji systemów

Optymalizacja kolonią mrówek (ACO)

- Inspiracje zachowaniem niektórych gatunków mrówek
- Mrówki pozostawiają **feromon** na terenach w celu oznaczenia pewnych faworyzowanych ścieżek którymi mogą podążać pozostali członkowie koloni
- Algorytm poszukiwań kolonią mrówek wykorzystuje podobny mechanizm rozwiązywania problemów optymalizacyjnych

Biologiczne tło ACO

- Pierre-Paul Grassé (1940-50)
 - pewne gatunki termitów reagują na tzw. istotne bodźce (ang. “significant stimuli”)



- Rezultatem tych reakcji mogą być nowe istotne bodźce zarówno dla owada generującego jak i dla pozostałych w kolonii

Biologiczne tło ACO

- **Stygmergia** – szczególny rodzaj komunikacji:

- Charakterystyka stygmergii:

– pośrednia forma komunikacji
za pomocą środowiska:



- Owady wymieniają się informacja poprzez modyfikację środowiska
- Informacja może być używana wyłącznie przez te owady, które można znaleźć w jej bezpośrednim sąsiedztwie



Biologiczne tło ACO

- Przykłady stygmergi można zaobserwować w koloniach mrówek
- W wiele gatunków mrówek poruszając się od gniazda do źródła pożywienia pozostawia na ścieżkach substancję zwaną ***feromonem***
- Inne mrówki zauważają obecność feromonu i podążają po ścieżkach gdzie jego stężenie jest największe

Biologiczne tło ACO

- J.-L. Deneubourg, S. Aron, S. Goss, and J.-M. Pasteels, “The self-organizing exploratory pattern of the Argentine ant” (1990)
 - badania dotyczące feromonu i zachowania mrówek
- “eksperyment z podwójnym mostem” – gniazdo kolonii mrówki Argentyńskiej połączono z źródłem pożywienia za pomocą dwóch ścieżek o jednakowej długości



Biologiczne tło ACO

- Mrówki rozpoczynają eksplorację terenu w otoczeniu gniazda i ewentualnie osiągają pożywienie
- Wzdłuż ich ścieżek pozostawiają, pomiędzy pożywieniem a gniazdem, feromon
- Początkowo każda mrówka wybiera losowo jedną z dwóch ze ścieżek

Biologiczne tło ACO

- Początkowo przypadkowe wybory co do trasy
- Po pewnym czasie jedna z dwóch ścieżek posiada wyższe stężenie feromonów niż druga (przyciąga więcej mrówek)
- Dalszy wzrost ilości feromonu na tej ścieżce czyniąc ją bardziej atrakcyjną
- W końcu cała kolonia mrówek korzysta tylko z jednego mostu

Biologiczne tło ACO

- Zachowanie o charakterze **autokatalizacji** (dodatniego sprzężenia zwrotnego)
- Używane przez mrówki do znalezienia najkrótszej ścieżki pomiędzy gniazdem a pożywieniem
- Wariant „eksperymentu z podwójnym mostem”, przy czym jedna z nich jest znacznie dłuższa (Goss i inni)

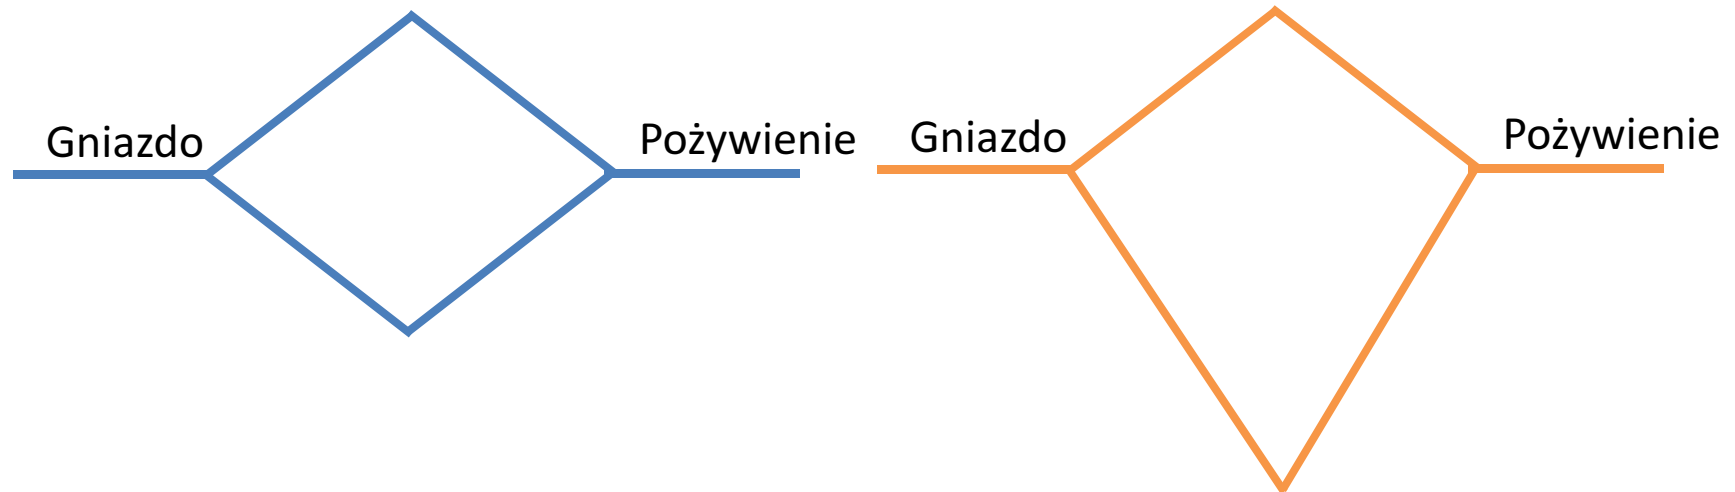
Biologiczne tło ACO

- Przypadkowy wybór ścieżki w początkowym stadium został zredukowany oraz
 - mrówki wybierały krótszą trasę do osiągnięcia źródła pożywienia

Biologiczne tło ACO

Eksperyment z podwójnym mostem

- jednakowe długości
- Różne długości



Biologiczne tło ACO

- Model zachowania mrówek (Goss i in. 1989):

$$p_1 = \frac{(t_1 + k)^h}{(t_1 + k)^h + (t_2 + k)^h} \quad p_2 = 1 - p_1$$

gdzie

$p_{1,2}$ - prawdopodobieństwo wyboru ścieżki

$t_{1,2}$ - chwila czasu (dla wyboru jednej ze ścieżek)

k, h - parametry strojone eksperymentalnie

Techniki optymalizacyjne ACO

- Model zaproponowany przez Deneubourg'a i współpracowników w celu wyjaśnienia zachowania mrówek głównym źródłem inspiracji dla rozwoju optymalizacji kolonią mrówek (ACO)
- Kolonia sztucznych mrówek konstruuje rozwiązanie rozważanego problemu optymalizacyjnego poprzez wymianę informacji o jakości tych rozwiązań za pomocą schematu komunikacji zadaptowanego z rzeczywistych koloni mrówek

Techniki optymalizacyjne ACO

ALGORYTM	AUTHORZY	ROK
ANT SYSTEM (AS)	DORGIO i in.	1991
ELITIST AS	DORGIO i in.	1992
ANT-Q	GAMBARDELLA & DORGIO	1995
ANT COLONY SYSTEM	DORGIO & GAMBARDELLA	1996
MAX-MIN AS	STUZLE & HOOS	1996
RANK BASED AS	BULLNHEIMER i in.	1997
ANTS	MANEZZIO	1999
BWAS	CORDON i in.	2000
HYPER-CUBE AS	BLUM i in.	2001

ACO i Problem Komiwożera (TSP)

- W problemie komiwożera dany jest zbiór miast i odległości pomiędzy nimi
- Rozwiązaniem problemu polega na znalezieniu najkrótszej trasy przechodzącej przez wszystkie miasta tylko raz
- Definiując formalnie: celem jest znalezienie minimalnej długości trasy Hamiltona dla pełnego cyklu grafu

ACO i Problem Komiwojżera (TSP)


- W ACO problem jest rozwiązywany poprzez symulację grupy sztucznych mrówek poruszających się po grafie w którym:
 - każdy wierzchołek reprezentuje miasto
 - każda krawędź reprezentuje połączenie pomiędzy dwoma miastami
- Zmienna zwana feromonem jest związana z każdą krawędzią i może być odczytywana i modyfikowana przez każdą mrówkę

ACO i Problem Komiwojażera (TSP)

- ACO algorytmem iteracyjnym
- W każdej iteracji rozpatrywane są wszystkie mrówki z kolonii
- Każda z mrówek konstruuje rozwiązanie poprzez poruszanie się od wierzchołka do wierzchołka na grafie z ograniczeniem dotyczącym przechodzenia przez wierzchołki już odwiedzone

ACO i Problem Komiwojażera (TSP)

- Na każdym etapie tworzenia ścieżki, mrówka wybiera wierzchołek według stochastycznego mechanizmu opartego na feromonie



ACO i Problem Komiwojażera (TSP)

- Pod koniec iteracji, w oparciu o jakość rozwiązań zbudowanych przez mrówki, wartości feromonu są modyfikowane w celu poprawy tworzonych rozwiązań w kolejnych ponownych krokach algorytmu

ACO i Problem Komiwojażera (TSP)

- TSP – trudne zadanie optymalizacyjne
- Liczba rozwiązań wynosi dla STSP $(n-1)!/2$

n miast	Liczba rozwiązań
10	181 000
20	10^{15}
50	10^{61}

- Na Ziemi znajduje się tylko 10^{21} litrów wody

Metaheurystyka ACO

- Optymalizacji kolonią mrówek została sformalizowana do postaci metaheurystyki dla problemów optymalizacji kombinatorycznej (Dorigo i in.)
- ***Metaheurystyka*** jest zbiorem algorytmicznych koncepcji, które mogą być użyte do zdefiniowania metod zastosowanych dla szerokiej klasy różnych problemów

Metaheurystyka ACO

- Metaheurystyka ma charakter algorytmicznych zasad ogólnego przeznaczenia stosowanych do różnych problemów optymalizacji z niewielkimi stosunkowo modyfikacjami
- Przykładowo metaheurystyka obejmuje:
 - Symulowane wyżarzanie
 - Poszukiwanie tabu
 - Iteracyjne lokalne poszukiwania
 - Obliczenia ewolucyjne
 - Optymalizacja kolonią mrówek

Metaheurystyka ACO

- Problem kombinatorycznej optymalizacji:
Niech dany jest model $P = (S, \Omega, f)$ złożony z:
 - *Przestrzeni poszukiwań S zdefiniowana przez skończony zbiór zmiennych decyzyjnych $X_i, i = 1, 2, \dots, n$*
 - *zbiór Ω zawierający ograniczenia na zmienne decyzyjne*
 - *funkcja celu $f : S \rightarrow R^+$*

Metaheurystyka ACO

- Zmienna X_i przyjmuje wartości $D_i = \{v_i^1, \dots, v_i^{|D_i|}\}$
- Możliwe rozwiązanie $s \in S$ jest kompletnym przypisaniem wartości do zmiennej, która spełnia wszystkie ograniczenia Ω
- Rozwiązanie $s^* \in S$ nazywane jest globalnym minimum wtedy i tylko wtedy gdy :

$$f(s^*) \leq \forall_{s \in S} f(s)$$

Metaheurystyka ACO

- Model kombinatorycznej optymalizacji jest używany do definiowania modelu feromonów ACO
- Wartość feromonów jest związane z każdym możliwym **cząstkowym rozwiązaniem**, to znaczy, z każdym możliwym przypisaniem wartości do zmiennej

Metaheurystyka ACO

- Formalnie wartość feromonu τ_{ij} jest związana z cząstkowym rozwiązaniem c_{ij} , który składa się z przypisania $X_i = v_i^j$
- Niech \mathbf{C} oznacza zbiór wszystkich możliwych cząstkowych rozwiązań

Metaheurystyka ACO

- Sztuczne mrówki budują rozwiązania przechodząc przez pełny połączony graf oznaczany jako

$$G_C = (V, E)$$

gdzie

V – zbiór wierzchołków

E - zbiór krawędzi

Metaheurystyka ACO

- Graf $\mathbf{G}_C = (\mathbf{V}, \mathbf{E})$ może być uzyskany ze zbioru cząstkowych rozwiązań \mathbf{C} dwoma metodami
- Rozwiązanie cząstkowe c_{ij} może być reprezentowane zarówno przez:
 - wierzchołki oraz
 - krawędzie

Metaheurystyka ACO

- Sztuczne mrówki przechodząc od wierzchołka do wierzchołka wzdłuż krawędzi grafu, stopniowo konstruują rozwiązanie z cząstkowych elementów
- Mrówka pozostawia pewną ilość feromonu na rozwiązaniach cząstkowych
- Wielkość pozostawionego feromonu τ zwykle zależy od jakości znalezionej rozwiązania

Metaheurystyka ACO

- Kolejne mrówki używają informacji o feromonie jako przewodnika do obiecujących regionów przestrzeni poszukiwań
- W problemie komiwojażera, rozwiązanie może być reprezentowane przez zbiór zmiennych n , gdzie n to liczba miast

Metaheurystyka ACO

- Każda zmienna jest związana z miastem
- Zmienna X_i wskazuje miasto przez jakie należy przejść po mieści i -tym
- Częstkowe rozwiązania są parami miast, które zamierza odwiedzić mrówka jeden po drugim, w podanej kolejności
- $c_{ij} = (i, j)$ miasto j powinno być bezpośrednio odwiedzone po mieście i

Metaheurystyka ACO


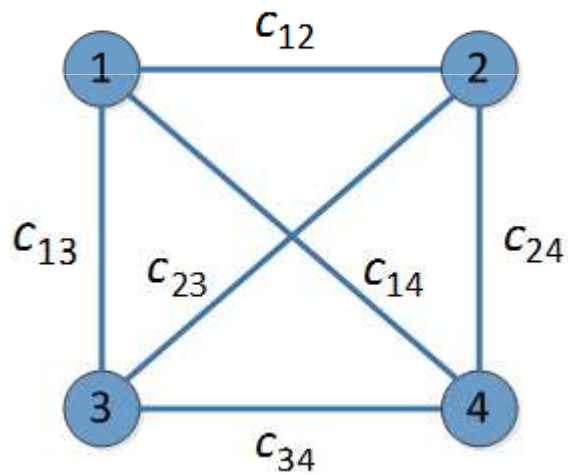
- W tym przypadku graf budowany jest za pomocą wierzchołków będących miastami pierwotnego problemu komiwojażera, a krawędzie są cząstkowymi rozwiązaniami
- W konsekwencji, mrówki oznaczają feromonem krawędzie konstruowanego grafu

Metaheurystyka ACO

- Można zauważyć, że budowa grafu może być przeprowadzana poprzez cząstkowe rozwiązania reprezentujące wierzchołki, na których osadza się feromony
- Chociaż ten drugi sposób uzyskania grafu wydaje się mniej naturalny dla problemu komiwojażera, to jednak jest właściwy

Metaheurystyka ACO

Przykład dwóch sposobów konstrukcji grafu dla 4 miast w zadaniu TSP



Metaheurystyka ACO

Schemat algorytmu ACO

Ustaw parametry oraz wartości feromonu

while warunek zakończenia nie jest spełniony

Utwórz rozwiązania za pomocą mrówek

Zastosuj procedurę lokalnego poszukiwania (opcja)

Zmodyfikuj feromony

end while

Metaheurystyka ACO

Tworzenie rozwiązań za pomocą mrówek:

- Zbiór m sztucznych mrówek tworzy rozwiązania z elementów zbioru $\mathbf{C} = \{c_{ij}\}$
- Wszystkie mrówki starują z pustym $s^p = \emptyset$ cząstkowym rozwiązaniem
- W każdym kroku tworzenia rozwiązania, cząstkowe rozwiązanie jest rozszerzane o nowe możliwe cząstkowe rozwiązanie s^p ze zbioru $\mathbf{N}(s^p) \subseteq \mathbf{C}$

Metaheurystyka ACO

- $N(s^p) \subseteq C$ jest zdefiniowany jako zbiór rozwiązań cząstkowych, które mogą zostać dodane do aktualnego rozwiązania s^p bez naruszania ograniczeń Ω
- Proces budowy rozwiązań można uznać za pewien „spacer” po grafie $G_C = (V, E)$

Metaheurystyka ACO

- Wybór cząstkowego rozwiązania z $\mathbf{N}(s^p)$ jest przeprowadzany za pomocą stochastycznego mechanizmu (na podstawie feromonu związanego z każdym elementem zbioru $\mathbf{N}(s^p)$)
- Reguła stochastycznego wyboru cząstkowego rozwiązania różni się w odmianach algorytmu ACO, ale w każdym z nich, jest inspiracja modelu zachowania prawdziwych mrówek

Metaheurystyka ACO

- ***Modyfikacja feromonów***
 - Zwykle jest osiągnięta poprzez:
 - Zmniejszenie wartości feromonu poprzez mechanizm wyparowywania
 - Zwiększanie wartości feromonu związanego z wyborem rozwiązania obiecującego doby kierunek poszukiwań

Podstawowe algorytmy ACO

- Kilka algorytmów ACO zostało zaproponowanych w literaturze
- Podstawowe trzy warianty ACO:
 - **Ant System (AS)**
 - **MAX-MIN Ant System (MMAS)**
 - **Ant Colony System (ACS)**

System mrówek (AS)

- Modyfikacja feromonu

gdzie
$$\tau_{ij} = (1 - \rho) \cdot \tau_{ij} + \sum_{k=1}^m \Delta\tau_{ij}^k$$

ρ – współczynnik wyparowywania,

m – liczba mrówek

$\Delta\tau_{ij}^k$ – wartość feromonu na krawędzi (i, j)
pozostawionej przez mrówkę k

System mrówek (AS)

- Ilość feromonu

$$\Delta\tau_{ij} = \begin{cases} Q/L_k, & \text{jeżeli mrówka } k \text{ używa } (i,j) \\ 0 & , \text{ w przeciwnym wypadku} \end{cases}$$

gdzie

Q – pewna stała

L_k – długość trasy skonstruowanej przez mrówkę k

System mrówek (AS)

- Prawdopodobieństwo przejścia do miasta j

$$p_{ij}^k = \begin{cases} \frac{\tau_{ij}^\alpha \cdot \eta_{ij}^\beta}{\sum_{c_{il} \in \mathbf{N}(s^p)} \tau_{ij}^\alpha \eta_{ij}^\beta}, & \text{jeżeli } c_{ij} \in \mathbf{N}(s^p) \\ 0, & \text{w przeciwnym wypadku} \end{cases}$$

$\mathbf{N}(s^p)$ – zbiór możliwych cząstkowych rozwiązań (krawędź (i, l) gdzie l jest miastem jeszcze nie odwiedzionym przez mrówkę k)

System mrówek (AS)

- Parametry α i β sterują relatywnie istotnością feromonu w stosunku do heurystycznej informacji η_{ij}

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

d_{ij} - odległość pomiędzy miastami i oraz j

System mrówek (AS)

Procedura AS

inicjuj

for $t=1$ **to** liczba cykli

for $k=1$ **to** m

repeat

 wybierz dla mrówki ant k następne miasto z

 prawdopodobieństwem p_{ij}^k dla j -tego miasta

until mrówka k nie ma skończonej trasy

 oblicz długość trasy L_k stworzonej przez mrówkę k

end

 zapamiętaj najlepsze rozwiązanie

 zmodyfikuj intensywność feromonu τ_{ij} dla wszystkich tras

end

System Mrówek MAX –MIN (MMAS)

- Udoskonalenie klasycznego algorytmu Systemu Mrówek (AS)
- Charakterystyczny element MMAS
 - aktualizacja feromonów tylko najlepiej przystosowanej mówki (najkrótszej przebytej trasy)
 - dodatkowo feromony są ograniczone

System Mrówek MAX –MIN (MMAS)

- Modyfikacja feromonu

$$\tau_{ij} = \left[(1 - \rho) \cdot \tau_{ij} + \Delta\tau_{ij}^{best} \right]_{\tau_{\min}}^{\tau_{\max}}$$

gdzie

$\tau_{\max, \min}$ - górne, dolne ograniczenie na feromony

$$[x]_b^a = \begin{cases} a, & \text{if } x > a \\ b, & \text{if } x < b \\ x, & \text{else} \end{cases}$$

System Mrówek MAX –MIN (MMAS)

- Ilość Feromonu

$$\Delta\tau_{ij}^{best} = \begin{cases} 1/L_{best}, & \text{jeżeli } (i,j) \text{ do najlepszej trasy} \\ 0, & \text{else} \end{cases}$$

L_{best} – długość trasy najlepszej mrówki

- Wybór wartości L_{best} może dotyczyć:
 - najlepszą trasą w aktualnej iteracji,
 - najlepszym do tej pory znalezionym rozwiązaniem
 - kombinacją obu podejść

System Mrówek MAX –MIN (MMAS)

- Wartości graniczne feromonów τ_{\min} i τ_{\max} są uzyskiwane na podstawie przeprowadzanych eksperymentów dla danego problemu optymalizacji
- Pewne wskazówki przy określeniu τ_{\min} i τ_{\max} można znaleźć w poniższej literaturze
 - T. Stützle and H.H. Hoos, “MAX–MIN Ant System,” *Future Generation Computer Systems*, vol. 16, no. 8, pp. 889–914, 2000
 - K. Socha, J. Knowles, and M. Sampels, “A MAX–MIN ant system for the university timetabling problem,” in *Proc. ANTS 2002*, ser. LNCS, M. Dorigo et al., Eds., vol. 2463, p. 1, Berlin, Germany: Springer Verlag, 2002

System Kolonii Mrówek (ACS)

- Lokalna aktualizacja feromonów jest wykonywana przez wszystkie mrówki po każdym etapie budowy trasy i stosowana tylko do ostatniej odwiedzanej krawędzi

$$\tau_{ij} = (1 - \varphi) \cdot \tau_{ij} + \varphi \cdot \tau_0$$

gdzie

$\varphi \in (0,1]$ - współczynnik rozkładu feromonu

τ_0 - początkowa wartość feromonu

System Kolonii Mrówek (ACS)

- Głównym celem lokalnej aktualizacji feromonu jest dywersyfikacja wyszukiwania przez kolejne mrówki kolonii poprzez zmniejszenie stężenia feromonów na przebieganych krawędziach
- Zachęca to mrówki do odwiedzania innych tras w celu stworzenia odmiennych rozwiązań
- Mniej prawdopodobne, że kilka mrówek utworzy identyczne rozwiązania podczas jednej iteracji

System Kolonii Mrówek (ACS)

- **Offline-owa modyfikacja feromonu**

Podobna do mechanizmu w MMAS stosowana na końcu każdej iteracji i przeprowadzana tylko dla **jednej mrówki**, która może być:

- najlepszą w aktualnej iteracji lub
- najlepszą dotychczas utworzoną

System Kolonii Mrówek (ACS)

- Formuła modyfikacji feromonu

$$\tau_{ij} = \begin{cases} (1 - \rho) \cdot \tau_{ij} + \Delta\tau_{ij} & , \text{ if } (i,j) \text{ do najlepszej trasy} \\ \tau_{ij} & , \text{ else} \end{cases}$$

gdzie (jak w MMAS) $\Delta\tau_{ij} = 1/L_{best}$

System Kolonii Mrówek (ACS)

- Reguła decyzji wykorzystywana przez mrówki w procesie tworzenia rozwiązania
- **Pseudolowaowa proporcjonalna reguła modyfikacji feromonu:**
 - Prawdopodobieństwo, że mrówka przesunie się z miasta i do miasta j zależy od losowej wartości q wybranej z rozkładem równomiernym z przedziału $[0, 1]$ oraz parametru q_0

System Kolonii Mrówek (ACS)

- Pseudolosowa proporcjonalna reguła

if $q \leq q_0$, then $j = \arg \max_{c_{ij} \in \mathbf{N}(s^p)} \{\tau_{ij}, \eta_{ij}^\beta\}$

else

$$p_{ij}^k = \begin{cases} \frac{\tau_{ij}^\alpha \cdot \eta_{ij}^\beta}{\sum_{c_{ij} \in \mathbf{N}(s^p)} \tau_{ij}^\alpha \eta_{ij}^\beta} \\ 0 \end{cases}$$

Zastosowania algorytmów optymalizacji kolonią mrówek (ACO)

- Obserwowany wzrost zainteresowania społeczności naukowej dotycząca ACO
- Kilka udanych zastosowań ACO do wielu różnych problemów optymalizacji dyskretnej (NP-trudne problemy)
- Algorytmy ACO mogą być przydatne do szybkiego znalezienia wysokiej jakości rozwiązań

Zastosowania algorytmów optymalizacji kolonią mrówek (ACO)

- Inne popularne aplikacje dotyczą dynamicznego doboru najkrótszej ścieżki dla problemów pojawiających się w sieciach telekomunikacyjnych
- Liczby pozytywnie rozwiązanych problemów naukowych udowadniają, że technika ACO jest również przydatna w rzeczywistych aplikacjach

Literatura

- **Strony WWW:**

- www.aco-metaheuristic.org: The official Web site of the ant colony metaheuristic

- www.metaheuristics.org: Web site of the “Metaheuristics Network” project. This European Union funded project was dedicated to the theoretical analysis and experimental comparison of metaheuristics.

- **Książki:**

- M. Dorigo and T. Stützle, Ant Colony Optimization. MIT Press, Cambridge, MA, 2004.

- E. Bonabeau, M. Dorigo, and G. Theraulaz, Swarm Intelligence: From Natural to Artificial Systems. Oxford University Press, 1999.