Wydział Zarządzania AGH
Katedra Informatyki Biznesowej i Inżynierii Zarządzania

Inteligencja obliczeniowa

Adam Stawowy
Radosław Puka

Cele i efekty

- Podstawowym celem zajęć jest zapoznanie studentów z algorytmami ewolucyjnymi, innymi metaheurystykami i sztucznymi sieciami neuronowymi oraz pokazanie obszarów ich zastosowań w rozwiązywaniu problemów zarządzania i ekonomii.
- Student kończący kurs powinien:
  - umieć napisać program komputerowy realizujący algorytm ewolucyjny,
  - posługiwać się systemem komputerowym do realizacji prostych problemów optymalizacji,
  - rozumieć zachowanie się SSN,
  - umieć rozpoznać, czy SSN może być narzędziem do rozwiązania postawionego problemu,
  - umieć zastosować SSN do różnorodnych zagadnień.
- Wymagana jest podstawowa umiejętność programowania.

Inteligencja obliczeniowa – metoda

- **Rodzaj:**
  - Przedmiot obligatoryjny, informacje na stronie *Syllabus* oraz Katedry (**www.pi.zarz.agh.edu.pl**)
- **Zajęcia:**
  - Wykłady – 8/15h, laboratorium – 8/15h, praca poza zajęciami – 59/43h.
  - Zasady obowiązujące na zajęciach.
  - Co robimy.
- **Zaliczenie:**
  - Sprawozdania, projekt, aktywność na zajęciach.
- **Egzamin:**
  - 4-5 pytań, nie jest to test wyboru, ale....
- **Ocena końcowa (3 punkty ECTS):**
  - Średnia arytmetyczna z zaliczenia i egzaminu.

Metaheurystyki – treści zajęć

- Wprowadzenie
- Metaheurystyki i algorytmy heurystyczne
- Podstawy algorytmów ewolucyjnych
- Inne metaheurystyki inspirowane naturą
- Sztuczne sieci neuronowe MLP
- Zastosowania

Metaheurystyki, heurystyki

- Wprowadzenie, podstawowe pojęcia
- Proste techniki przeszukiwania
- Symulowane wyżarzanie
- Tabu search
- Algorytm mrówkowy
- Inteligencja roju
- Metody badania algorytmów

Wprowadzenie, podstawowe pojęcia

- Inteligencja obliczeniowa (Computational Intelligence, CI)
  - Dziedzina nauki zajmująca się rozwiązywaniem problemów, które nie są efektywnie algorytmizowane.
  - Computational intelligence to inteligencja zbudowana przy użyciu systemu komputerowego.
  - CI z reguły próbuje naśladować inteligencję człowieka, aczkolwiek nie jest to ani ograniczenie, ani wymaganie.
  - Synonim inteligencji maszynowej.
  - Synonim sztucznej inteligencji.

Wprowadzenie, podstawowe pojęcia

- Organizacje (przede wszystkim gospodarcze i rządowe) są głównie zainteresowane dwoma zadaniami:
  1. przewidywaniem tego, co się ma wydarzyć (predykcja),
  2. podejmowaniem najlepszych decyzji w warunkach ryzyka i niepewności (optymalizacja).
- Zadaniem CI jest dostarczyć narzędzia do modelowania, symulacji i optymalizacji zaspokajające te potrzeby.

Klasyczne metody prognozowania, i:

1. Sieci neuronowe,
2. Systemy rozmyte,
3. Programowanie genetyczne,
4. Systemy agentowe,
5. Techniki DM.

Klasyczne metody OR, i:

1. Algorytmy ewolucyjne,
2. Inteligencja roju,
3. Symulowane wyżarzanie,
4. Tabu search,
5. Algorytmy mrówkowe.

Źródło: Z. Michalewicz, Adaptive business intelligence.

Wprowadzenie, podstawowe pojęcia

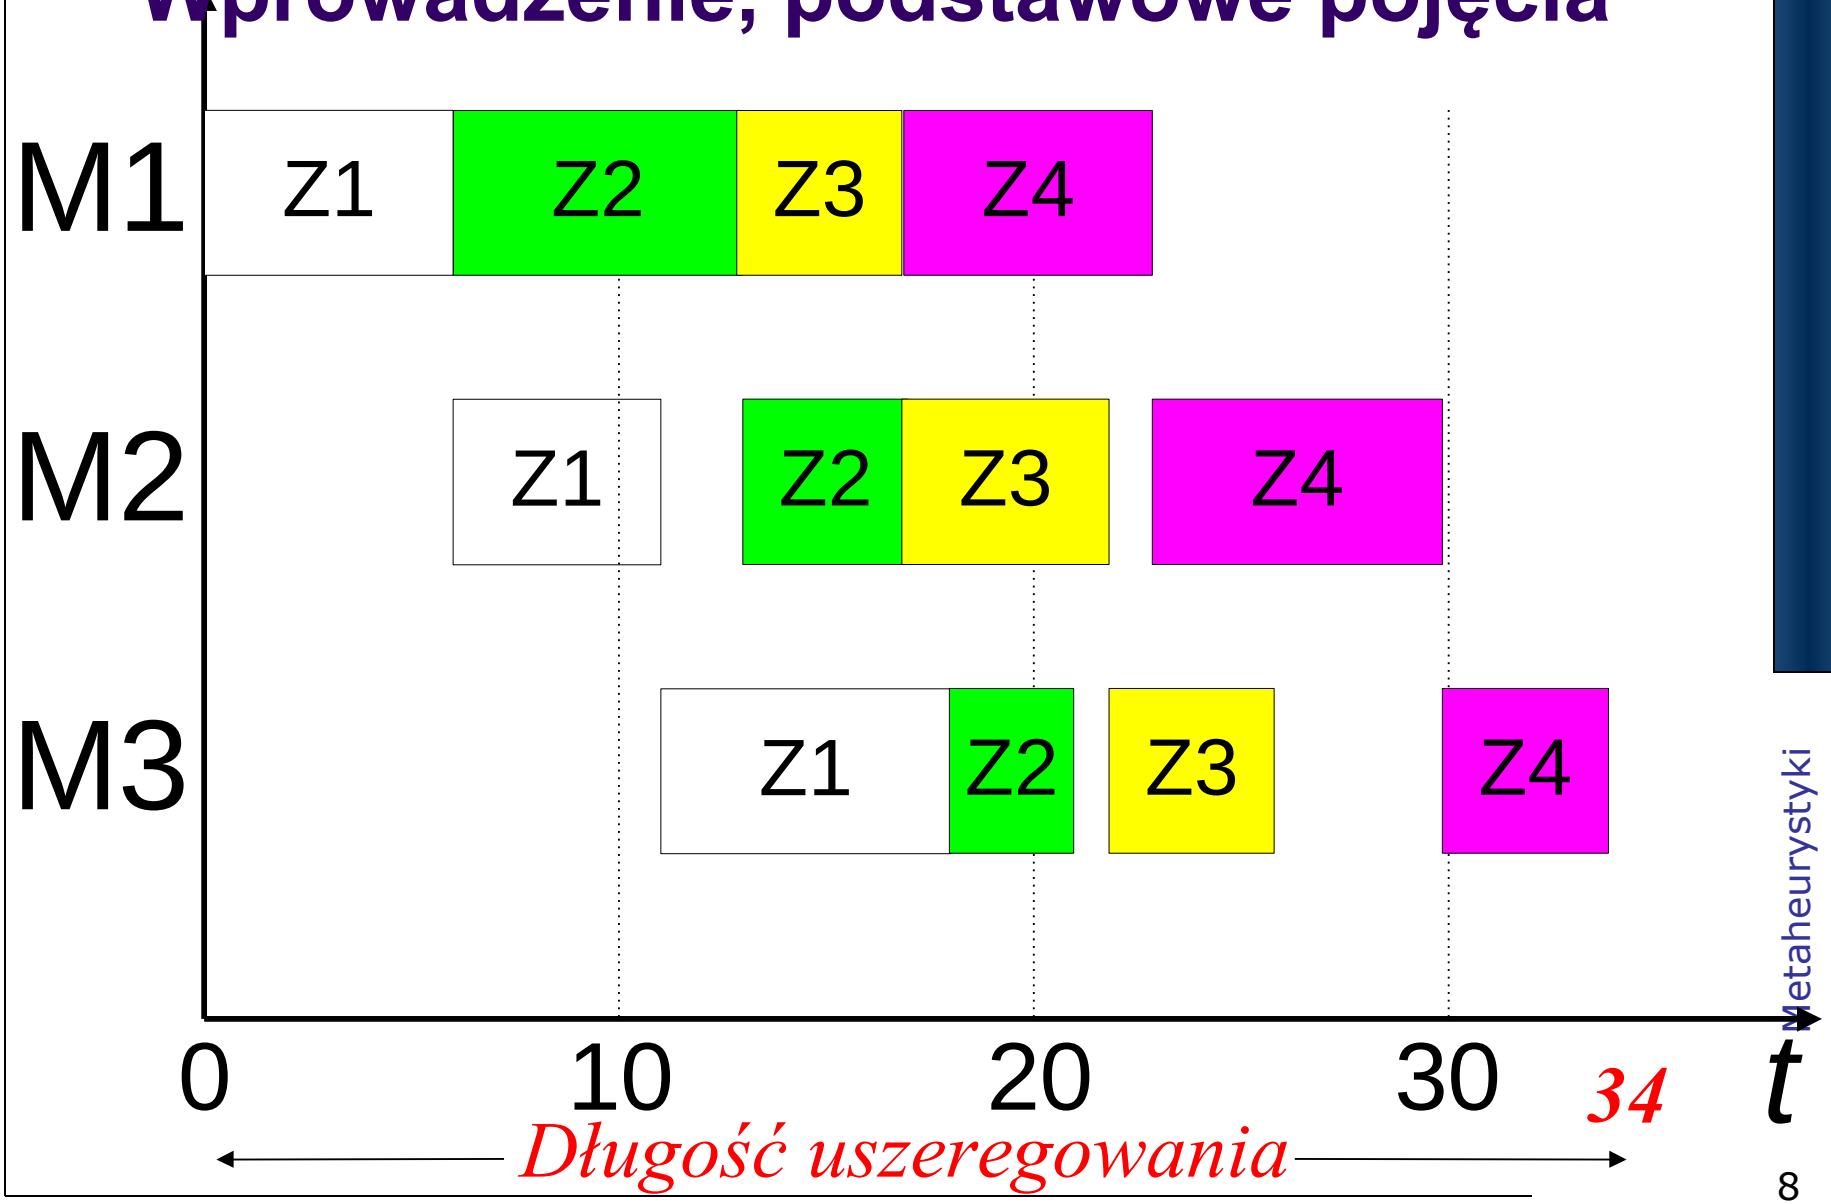

Wprowadzenie, podstawowe pojęcia

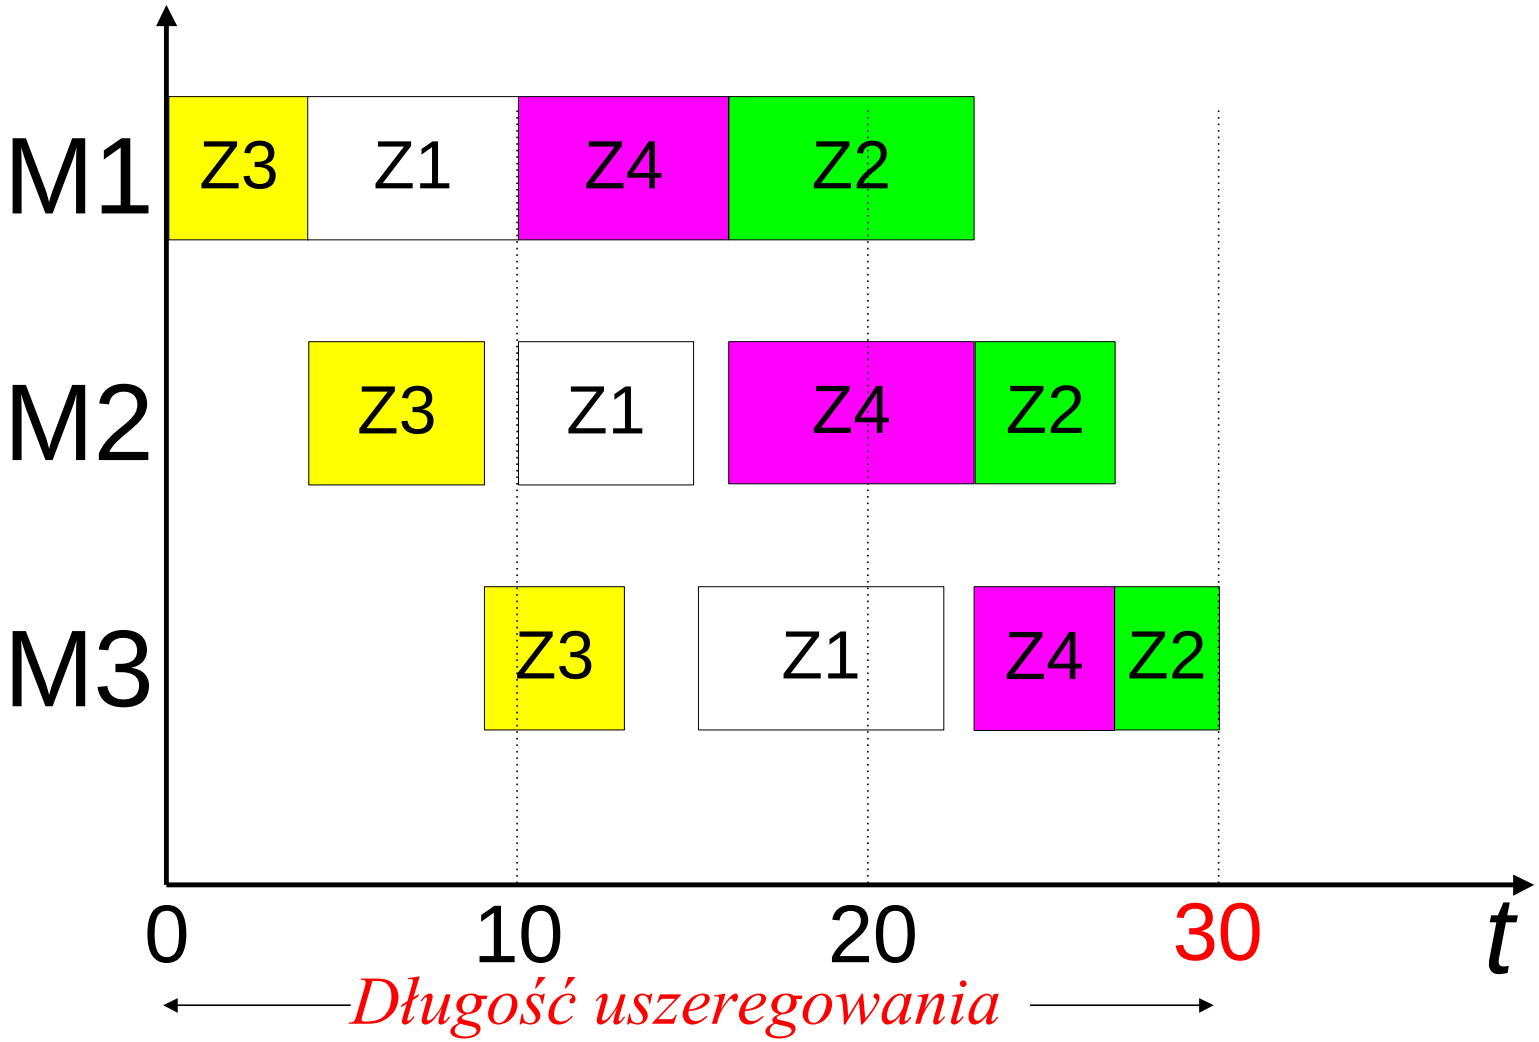

Wprowadzenie, podstawowe pojęcia

- GM sprzedawał rocznie 1,2 mln poleasingowych samochodów na różnych aukcjach. Codziennie decydowano, gdzie dostarczyć 4000-7000 aut.

Na problem wpływają:

- popyt,
- stan samochodów,
- trasy transportowe,
- koszt kapitału,
- ryzyko handlowe,
- efekt skali.

Źródło: Z. Michalewicz, Adaptive business intelligence.

Wprowadzenie, podstawowe pojęcia

- **Przypadek Libbey-Owens-Ford (LOF)**
  LOF jest wielkim koncernem produkującym szkło okienne, zatrudniającym 9000 pracowników. Na początku lat 90. LOP zbudował i wdrożył wielki model LP produkcji i dystrybucji szkła.
- Model programowania liniowego FLAGPOL (FLAt Glass Products Optmization Model) służy do rocznego planowania produkcji ponad 200 wyrobów w 4 zakładach i ich dystrybucji do 40 odbiorców hurtowych. Prace trwały 2 lata i przyniosły roczne oszczędności ponad 2 mln USD.

Wprowadzenie, podstawowe pojęcia

- **Przypadek Timken Steel**
  System planowania produkcji opracowany przez amerykańską firmę **i2 Technologies** o nazwie **RYTHM** dostarcza inteligentne rozwiązania dla planowania i harmonogramowania w przedsiębiorstwach. Integrują się one z systemami typu ***ERP*** i z transakcyjnymi systemami baz danych.
- W **Timken Steel**, produkującej pręty ze stali stopowej i rury bez szwu, realizowanych jest równocześnie od 8 do 15 tys. zamówień. Dzięki zastosowaniu systemu cykl produkcyjny w Timken został skrócony o 30 – 40%, zapasy zostały zredukowane o 25% i znacznie poprawiono terminowość realizacji zamówień. Ponieważ wyroby przepływają szybciej przez wydziały/oddziały, Timken zredukował wydatki operacyjne.

Heurystyka, metaheurystyka

- *Heuriskein* – szukam, sztuka znajdowania rozwiązań problemów.
- Heurystyka:
  - niepewność wyniku,
  - niekompletność dostępnej wiedzy,
  - poprawianie rozwiązania,
  - doświadczenie, intuicja.
- W inteligencji obliczeniowej termin *heurystyka* oznacza właściwie przeciwieństwo metody dającej optymalne rozwiązanie. Początek – lata 60.

Heurystyka, metaheurystyka

Heurystyka jest specjalizowaną metodą rozwiązywania konkretnego problemu, która znajduje dobre rozwiązania przy akceptowalnych nakładach obliczeniowych, ale bez gwarancji osiągnięcia optymalności celu, czy nawet - w wielu przypadkach – jak blisko optymalnego jest otrzymane rozwiązanie.

Metaheurystyka - ogólna metoda służąca za szkielet do konstrukcji heurystyki rozwiązującej dowolny problem, który można opisać za pomocą pewnych definiowanych przez tę metodę pojęć.
Metody takie nie służą do rozwiązywania konkretnych problemów, a jedynie podają sposób na utworzenie odpowiedniego algorytmu heurystycznego.

Cechy metaheurystyk

- strategie określające sposób przeszukiwania przestrzeni dopuszczalnych rozwiązań problemu
- celem działania jest efektywne przeszukiwanie przestrzeni
  - znajdowanie dobrych rozwiązań w określonym regionie (**eksploatacja**)
  - przeglądanie możliwie najszerszego obszaru przestrzeni problemu (**eksploracja**)
- metody przybliżone i przeważnie niedeterministyczne
- stosują różne techniki: od prostego przeszukiwania lokalnego do skomplikowanych procesów ewolucyjnych
- wykorzystują mechanizmy zapobiegające utknięciu metody w ograniczonym obszarze przestrzeni problemu
- nie są specjalizowane dla żadnego specyficznego problemu
- wykorzystują wiedzę o problemie i/lub doświadczenie zgromadzone w procesie przeszukiwania przestrzeni

Heurystyka, metaheurystyka

Argumenty za:

- Akceptowalna złożoność obliczeniowa,
- Elastyczność.

Podstawowe heurystyki:

- Losowe przeszukiwanie
- Algorytmy zachłanne

Podstawowe metaheurystyki:

- Metoda wspinaczki (hill climbing)
- Symulowane wyżarzanie
- Tabu Search
- Iterated Local Search
- Algorytmy ewolucyjne
- Algorytmy mrówkowe
- Inteligencja roju

1. Szczegółowe informacje na temat omawianych tu metod są łatwe do znalezienia.
2. Jeśli znasz inne metody, które mogą być interesujące dla uczestników tego kursu, daj znać – podyskutujemy.

Proste metody heurystyczne

- Pełny przegląd przestrzeni poszukiwań.
- Przeszukiwanie losowe
  Obecnie rzadko stosowane podejście: polega na losowym lub dokonywanym wg przyjętych reguł wyborze punktów w przestrzeni dopuszczalnych rozwiązań i obliczaniu dlań funkcji celu. Najlepsze rozwiązanie jest uznawane za rozwiązanie problemu.
- Algorytm zachłanny (greedy algorithm)
  algorytm, który w celu wyznaczenia rozwiązania w każdym kroku dokonuje zachłannego, tj. najlepiej rokującego w danym momencie wyboru **rozwiązania częściowego**. Algorytm zachłanny nie bada, jaki jest skutek danego działania w kolejnych krokach, ale dokonuje decyzji lokalnie optymalnej, kontynuując rozwiązanie podproblemu wynikającego z podjętej decyzji.
- Przykład: NN dal TSP, NEH dla FP, wydawanie reszty.

Proste metody heurystyczne

- Metoda wspinaczki (hill climbing)

1. Wybierz rozwiązanie początkowe (najczęściej losowo).
2. Przeanalizuj sąsiadów rozwiązania i określ ich jakość.
3. Wybierz najlepsze rozwiązanie jako początkowe do następnej iteracji.
4. Powtarzaj 2-4, aż znalezienie rozwiązania lepszego nie będzie możliwe.
5. Wyprowadź rozwiązanie aktualne jako rozwiązanie problemu.

Przykłady.

Proste metody heurystyczne

Metoda wspinaczki (hill climbing)

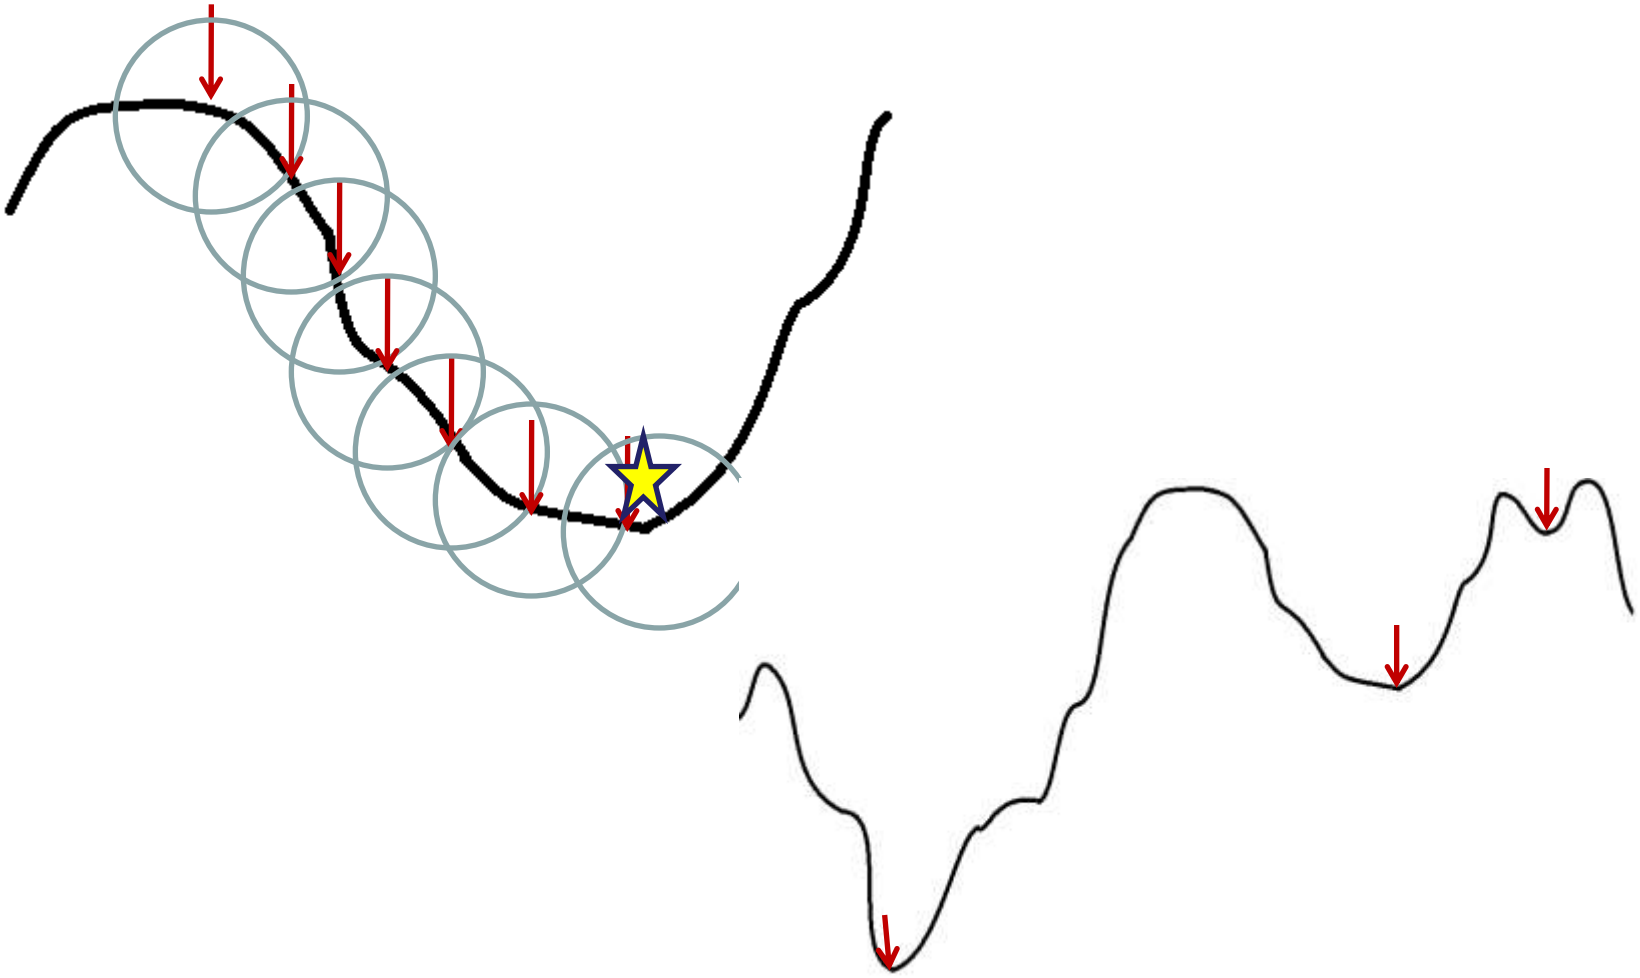

Proste metody heurystyczne

- Przeszukiwanie iteracyjne
  Połączenie przeszukiwania losowego i wspinaczki daje ciekawą metodę przeszukiwania iteracyjnego. Po znalezieniu optimum lokalnego, procedura przeszukiwania jest wznawiana w nowym, losowo wybranym, punkcie startowym. Jest to bardzo prosta metoda i bardzo efektywna dla problemów z niewielką liczbą optimów lokalnych.
  Każde przeszukiwanie jest samodzielnym procesem wykonywanym niezależnie od pozostałych, stąd nie wykorzystuje się wiedzy o poprzednich rozwiązaniach. Tak więc przeszukiwanie jest równie prawdopodobne dla obszarów o zróżnicowanych wartościach funkcji celu.

Rodzaje metaheurystyk

Inspirowane przyrodą (naturą)

Zjawiska biologiczne i społeczne:

- Algorytmy ewolucyjne,
- Algorytmy mrówkowe,
- Sztuczne systemy immunologiczne,
- Inteligencja roju (owady, ptaki),
- Ewolucja kulturalna,
- Tabu search.

Zjawiska fizyczne i chemiczne: symulowane wyżarzanie.

Inspirowane pozaprzyrodniczo: ILS, VNS

Populacyjne vs. niepopulacyjne (pojedyncze rozwiązanie)

Symulowane wyżarzanie

Simulated annealing (SA)

Podstawy działania

Ogólnie ujmując proces odprężania (wyżarzania) polega na powolnym obniżaniu temperatury tak, by w każdej temperaturze materiał mógł osiągnąć stan równowagi. Takie postępowanie zapobiega powstawaniu wewnętrznych naprężeń i pozwala na osiągnięcie globalnego minimum energii, odpowiadające idealnemu kryształowi. Wyznaczenie stanu najniższej energii jest problemem optymalizacyjnym, stąd fizyczny proces odprężania posłużył jako wzór do opracowania metody optymalizacji globalnej SA.

Symulowane wyżarzanie

Podstawy działania

Pomysł działania opracował Metropolis z zespołem w 1953 roku. Punktem wyjścia były prace M. z dziedziny termodynamiki statystycznej, gdzie obowiązuje:

$$p(E)=\exp(-dE/kt)$$

Stała Bolzmana

- Kirkpatrick z zespołem wykazali, że podejście to może być zastosowane do rozwiązywania problemów optymalizacyjnych drogą analogii do procesów fizycznych.

Symulowane wyżarzanie

Podstawy działania

Wyżarzanie	Optymalizacja
stany systemu	dopuszczalne rozwiązania
energia	koszt
zmiana stanu	rozwiązanie sąsiednie
temperatura	parametr sterujący
stan zamrożony	rozwiązanie heurystyczne

Symulowane wyżarzanie

- SA należy do metod przeszukiwania sąsiedztwa.
- Sąsiedztwo N(x,m) rozwiązania x jest zbiorem rozwiązań, które mogą być osiągnięte z x drogą prostej operacji m, zwanej ruchem. Jeśli rozwiązanie y jest lepsze od dowolnego z jego sąsiedztwa N(y,m), wtedy y jest optimum lokalnym.
- Wymagania odnośnie sąsiedztwa:
  - niewielki rozmiar - liczba rozwiązań sąsiednich,
  - możliwość osiągnięcia każdego rozwiązania z dowolnego rozwiązania początkowego,
  - rozwiązania sąsiednie muszą być podobne.

Symulowane wyżarzanie

```
BEGIN
    R := R0 {rozwiazanie poczatkowe};
    T := T0
      wybie
    WHILE
    BEGIN
      WHIL
      BEGI
       R' :=

         dE:
         IF (
        ELS
      END;
      T:= c
    END;
END.
```

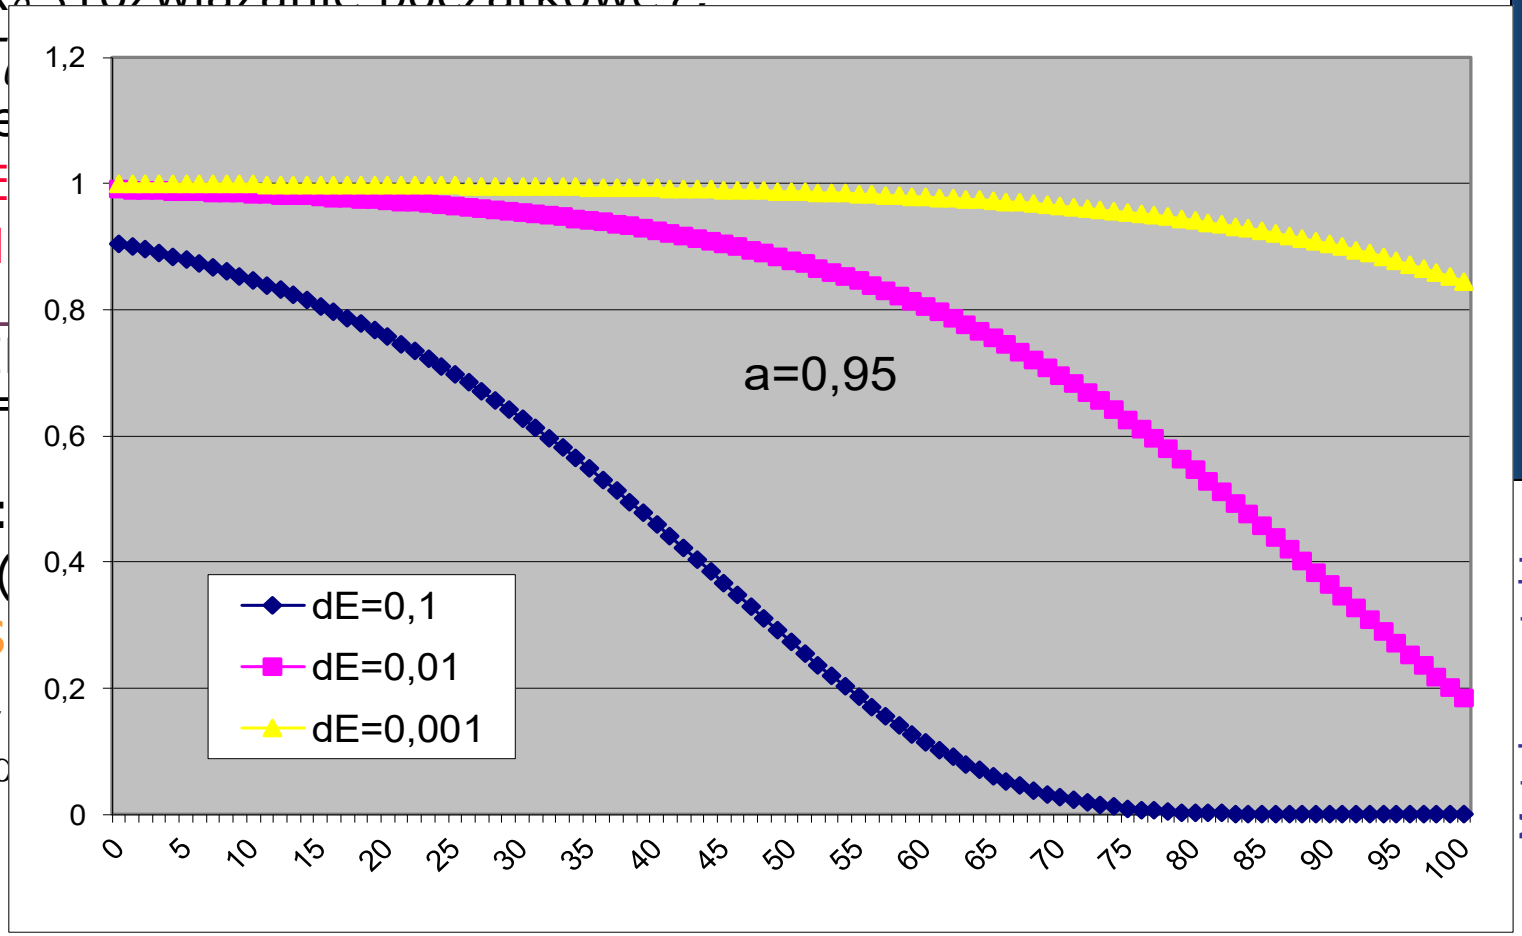

Symulowane wyżarzanie

Warunkiem poprawnego działania przedstawionej metody jest prawidłowy dobór dwóch grup czynników:

- warunek zatrzymania obliczeń,
- prawdopodobieństwo akceptacji "gorszego" rozwiązania,
- liczba generowanych rozwiązań dla danej temperatury,
- sposób generowania sąsiednich rozwiązań,
- postać funkcji kosztowej.

Kluczowym czynnikiem jest szybkość (sposób) redukcji temperatury. Najczęściej stosuje się dwa sposoby:

- redukcja geometryczna
  $\alpha(T)=a*T, \quad a<1$
  w danej temperaturze testowanych jest wiele rozwiązań,
- powolny spadek
  $\alpha(T)=T/(1+b*T), \quad b<<1$
  w danej temperaturze testowane jest jedno rozwiązanie.

Symulowane wyżarzanie - przykład

- Udane implementacje schematu Metropolisa dla problemu szeregowania zadań w systemie przepływowym podali Ogbu i Smith, Osman i Pots oraz Gangadharan i Rajendran.

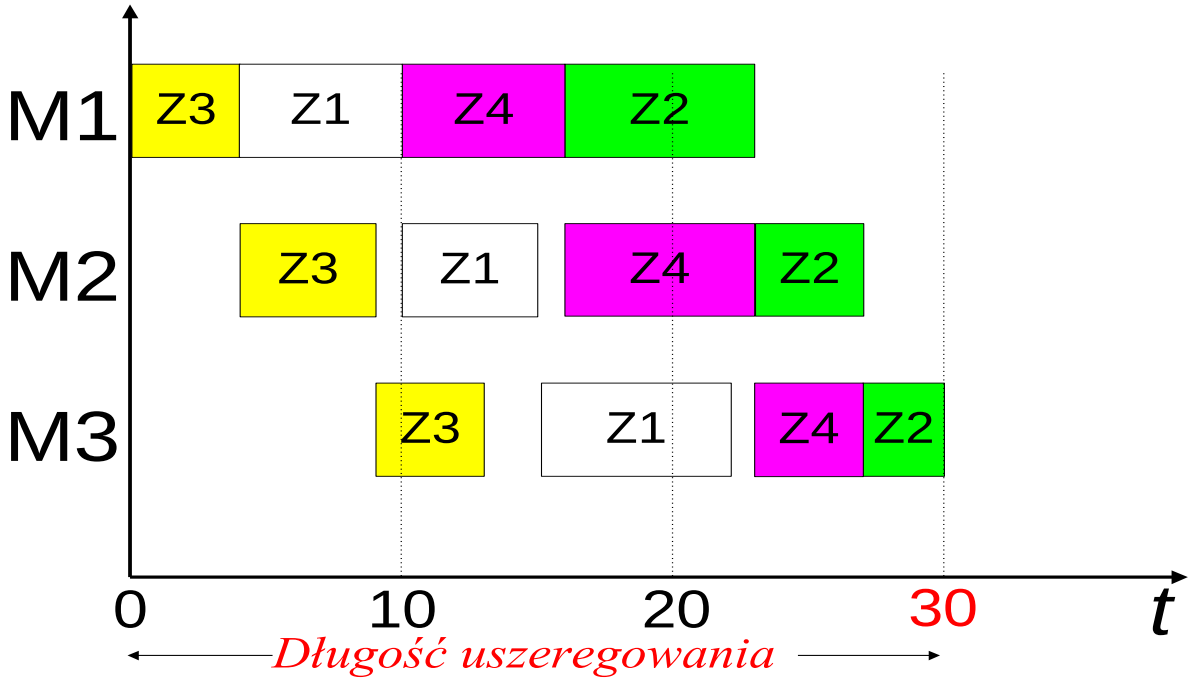

Symulowane wyżarzanie - przykład

- Ogbu i Smith przyjęli, że działanie algorytmu przebiega w *LE* = 15 etapach, liczba sprawdzanych rozwiązań na każdym etapie jest funkcją liczby zadań *n* i równa się $5*(n-1)^2$ dla $n<15$ oraz $7*(n-1)^2$ dla $n>=15$, natomiast prawdopodobieństwo akceptacji *AP(k)* dla $k=1,...,LE$ jest dane wzorem:

Prawd. bazowe = 0,2

$$AP(k) = \begin{cases} AP(1) \bullet (a)^{k-1} & \text{jeżeli } du(R') > du(R) \\ 1 & \text{jeżeli } du(R') \leq du(R) \end{cases}$$

Czynnik redukujący = 0,75

Symulowane wyżarzanie - przykład

- Nowe, sąsiednie rozwiązania generowane są przy użyciu schematu nazywanego *insertion*. Polega on na tym, że po wylosowaniu dwóch liczb *i, j* (*i*<>*j*), zadanie nr *i* jest wstawiane na pozycję nr *j* sekwencji wejściowej.

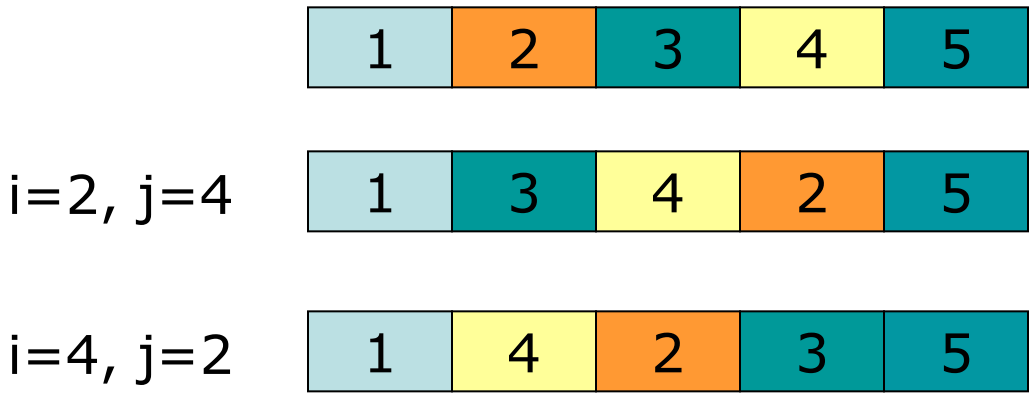

- Po wygenerowaniu na danym etapie wszystkich sekwencji wybierana jest ostatnia zaakceptowana jako bazowa dla następnego etapu.

Metaheurystyka ILS (CLO)

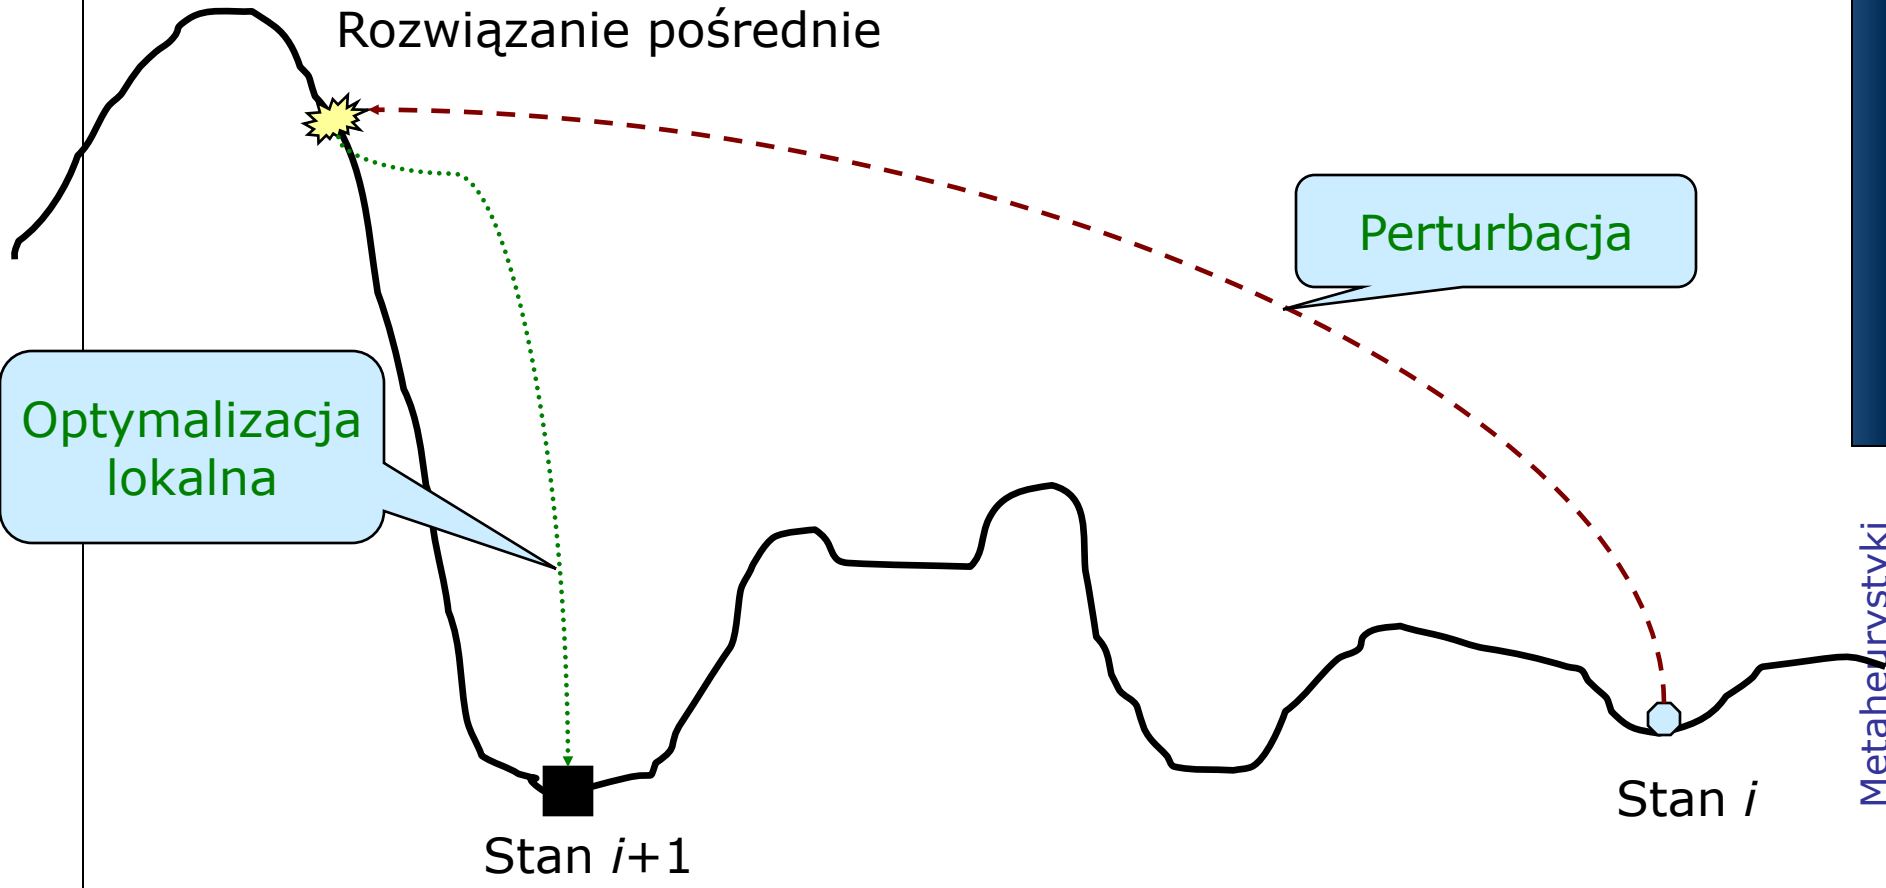

Metaheurystyka ILS (CLO)

```
s0 = GenerateInitialSolution
s* = LocalSearch(s0)
REPEAT
    s' = Perturbation(s*,history)
    s*' = LocalSearch(s')
    s* = AcceptanceCriterion(s*,s*',history)
UNTIL termination condition met
```

Metaheurystyka ILS (CLO)

Klasyczne podejście *ILS* do *TSP* składa się z następujących elementów:

- sąsiedztwo: *zamiana* dwóch miast;
- perturbacja: *double-bridge* move;

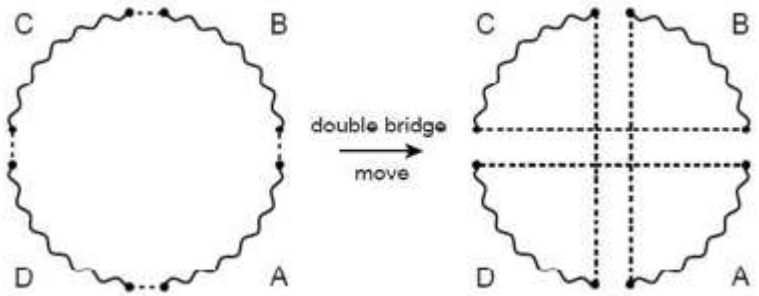

- kryterium akceptacji: “Czy nastąpiła poprawa najlepszego rozwiązania?”

$$s'^* < s^*$$

Tabu search

Tabu (ang. Taboo) (z polinezyjskiego tapu)

1) w religiach ludów pierwotnych zakaz podejmowania różnych działań w stosunku do osób, miejsc, zwierząt, rzeczy bądź stanów rzeczy lub też wypowiadania pewnych słów. Przekonanie o wartości i celowości takich zachowań wynika z wiary, że są one święte lub nieczyste w sensie rytualnym. Wskutek złamania tabu następuje stan skażenia związany z odpowiednimi sankcjami, głównie ze strony sił nadprzyrodzonych. Instytucja tabu została odkryta przez J. Cooka w 1771 wśród tubylców wyspy Tonga.

2) przedmiot, osoba, zwierzę, słowo, miejsce lub czynność objęte zakazem.

3) w psychoanalizie zakaz ograniczający realizację dążeń seksualnych, którego konsekwencją jest stłumienie i ukrycie w podświadomości tendencji do zachowań objętych zakazem.

4) w szerokim sensie tabu oznacza jakikolwiek zakaz.

- Początek dały prace Glovera z lat 70.
- TS rozumie się jako nakładanie ograniczeń; tu jednak chodzi raczej o wykorzystanie ograniczeń do kierowania przeszukiwania w obiecujące rejony przestrzeni dopuszczalnych rozwiązań.

Tabu search

- Podstawy działania
  Ruch jest funkcją transformującą dane rozwiązanie w inne rozwiązania. Podzbiór ruchów generuje dla danego rozwiązania podzbiór rozwiązań zwany *sąsiedztwem*. Na każdym stopniu iteracji przeszukiwane jest sąsiedztwo w celu wyboru najlepszego rozwiązania, które staje się bazowym dla następnego kroku. Ostatnio wykonany ruch jest wprowadzany na *listę zabronionych ruchów*, które nie mogą być wykonane w ciągu najbliższych *s* iteracji. Mechanizm ten umożliwia wyjście z lokalnego minimum i chroni przed cyklicznością ruchów. Niekiedy możliwe jest wykonanie zabronionego ruchu, o ile zdefiniowana *funkcja aspiracji* określi zyskowność takiego ruchu. Koniec obliczeń następuje w momencie przekroczenia limitu czasu, po wykonaniu dopuszczalnej liczby iteracji albo po wykonaniu dopuszczalnej liczby ruchów bez poprawy wartości funkcji kryterium.

Tabu search - przykład

- Sytuacja wejściowa

  Długość uszeregowania = 60

- Ruch typu wymiana (ang. swap, exchange)

i=5, j=6

Długość uszeregowania = 62

Tabu search - przykład

- Lista tabu (ruchów zabronionych)
  Lista wskazuje jakie ruchy i jak długo są zabronione
  s=3

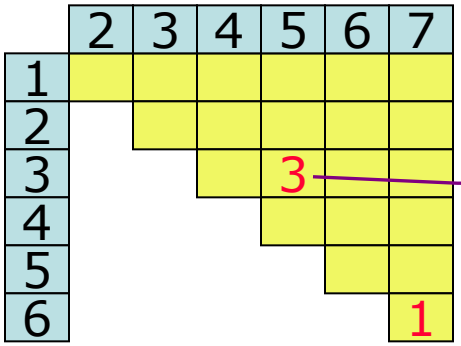

zamiana (3,5) jest zabroniona w ciągu trzech kolejnych iteracji

zamiana (6,7) jest zabroniona przez jeszcze jedną iterację

- Funkcja aspiracji określa warunki akceptacji zabronionego ruchu np. kryterium *najlepsze rozwiązanie*

Tabu search - przykład

Iteracja 0

Długość uszeregowania = 60

Lista tabu

	2	3	4	5	6	7
1						
2						
3						
4						
5						
6						

Top 5

Ruch	Z
5,4	-6
7,4	-4
3,6	-2
2,3	0
4,1	-1

Tabu search - przykład

Iteracja 1 - ruch (5,4)

2	4	7	3	5	6	1

Długość uszeregowania = 60-6=54

Lista tabu

	2	3	4	5	6	7
1						
2						
3						
4				3		
5						
6						

Top 5

Ruch	Z
3,1	-2
2,3	-1
3,6	1
7,1	2
6,1	4

Tabu search - przykład

Iteracja 2 - ruch (3,1)

2	4	7	1	5	6	3

Długość uszeregowania = 54-2=52

Lista tabu

	2	3	4	5	6	7
1		3				
2						
3						
4				2		
5						
6						

Top 5

Ruch	Z
1,3	2
2,4	4
7,6	6
4,5	7
5,3	9

Tabu search - przykład

Iteracja 3 - ruch (2,4)

4	2	7	1	5	6	3

Długość uszeregowania = 54+4=58

Lista tabu

	2	3	4	5	6	7
1		2				
2			3			
3						
4				1		
5						
6						

Top 5

Ruch	Z
4,5	-6
5,3	-2
7,1	0
1,3	3
2,6	6

Tabu search - przykład

Iteracja 4 - ruch (4,5)

5	2	7	1	4	6	3

Długość uszeregowania = 58-6=52

Lista tabu

	2	3	4	5	6	7
1		1				
2			2			
3						
4				3		
5						
6						

Top 5

Ruch	Z
7,1	0
4,3	3
6,3	5
5,4	6
2,6	8

Tabu search

```
BEGIN
  R := R_0 {rozwiązanie początkowe};
  TL := empty {lista tabu jest pusta};
  R* := R_0; C* := C(R_0) {najlepsze rozwiązanie i funkcja celu};
  WHILE (nie spełniony warunek zatrzymania) DO
  BEGIN
        C := MAX;
        WHILE (nie przetestowane sąsiedztwo rozwiązania R) DO
        BEGIN
          IF m(R) NOT tabu THEN R' := m(R) {nowe rozwiązanie po
                                            wykonaniu ruchu m};
          IF C(R') < C THEN  BEGIN  C := C(R'); R'' := R'  END;
        END;
        IF C < C* THEN  BEGIN C* := C;  R* := R" END;
        R := R";
        aktualizacja TL;
  END;
END.
```

Algorytm mrówkowy

Ant Colony Optimization (ACO)

- zaproponowany przez Marco Dorigo, jest probabilistyczną metodą rozwiązywania problemów poprzez szukanie dobrych dróg w grafach; zainspirowany zachowaniem mrówek szukających pożywienia dla swojej kolonii.
- Mrówki poruszają się w sposób losowy; gdy znajdują pożywienie, wracają do swojej kolonii pozostawiając ślad składający się z feromonów. Gdy inna mrówka natknie się na ten ślad, przestaje poruszać się w sposób losowy i podąża za śladem w kierunku pożywienia.
- Po pewnym czasie feromony wyparowują, a więc siła ich działania maleje. Im dłuższa jest trasa od pożywienia do kolonii, tym więcej feromonu wyparuje. Krótsze trasy zapewniają, iż siła działania feromonów jest większa. Parowanie feromonów jest efektem pożądanym, bowiem pozwala to na odnajdywanie optymalnej trasy do pożywienia. Gdyby feromony nie wyparowywały, każda kolejna trasa miałaby taką samą siłę jak poprzednia, więc nie dochodziłoby do odnalezienia optymalnej trasy.
- Gdy jedna mrówka odnajdzie dobrą (krótką) drogę, inne mrówki będą podążać tą właśnie drogą również zostawiając feromony, tym samym zwiększając ich natężenie. Ostatecznie wszystkie mrówki będą poruszać się tą samą, najlepszą drogą, a pozostałe drogi zostaną zapomniane (wyparują).

Algorytm mrówkowy

- Kilka podstawowych podobieństw między biologicznymi sztucznymi mrówkami:
  - Sztuczne mrówki są populacją współpracujących osobników poszukujących wspólnie dobrego rozwiązania problemu.
  - Sztuczne mrówki używają (sztucznego) śladu feromonowego jako metody komunikacji lokalnej. Tylko mrówki które przebywają w pobliżu miejsca złożenia feromonu mogą uzyskać informację od poprzednio tam będących osobników.
  - Sztuczne mrówki poszukują najkrótszej (o najmniejszym koszcie) drogi z punktu wyjścia (mrowisko) do punktu docelowego (źródło pożywienia).
  - Sztuczne mrówki poruszają się po sąsiadujących ze sobą miejscach krocząc z jednego punktu do drugiego (nie wykonują skoków).
  - Sztuczne mrówki odkrywają rozwiązanie podejmując lokalne decyzje stochastyczne. Nie znają one przyszłości i nie próbują przewidzieć przyszłych stanów.

Algorytm mrówkowy

- Kilka możliwych różnic między biologicznymi sztucznymi mrówkami:
  - Sztuczne mrówki żyją w dyskretnym świecie i ich ruchy mają także charakter dyskretny.
  - Sztuczne mrówki mają pamięć przechowującą historię przeszłych dokonań osobnika.
  - Sztuczne mrówki pozostawiają ilość feromonu będącą funkcją jakości ich dokonań (jakości znalezionego rozwiązania).
  - Możliwe jest, aby sztuczne mrówki pozostawiały feromon dopiero po dotarciu do celu (wyznaczeniu rozwiązania).
  - Sztuczne mrówki mogą być wyposażone w dodatkowe cechy, możliwości i mechanizmy zależne od rodzaju rozważanego problemu.

Algorytm mrówkowy

- Inicjalizacja (losowa) depozytu feromonów na wszystkich krawędziach (i,j): $\tau_{ij}(0)=U(0,max)$
- Umieszczenie mrówek w punkcie startowym
- T^+ najkrótsza trasa, L^+ jej długość
- For $t=1$ to t_{max}
  - dla każdej mrówki zbuduj trasę $T_k(t)$ wybierając $(n-1)$ razy następne miasto z prawd. $\Phi_{ij,k}(t)$
  - oblicz długość trasy $L_k(t)$
  - jeśli najkrótsza, to ustaw T^+ oraz L^+
  - zaktualizuj depozyt feromonów na każdej krawędzi (*)
- Koniec: zwróć T^+

$$\Phi_{ij,k}(t)=\begin{cases}\dfrac{\tau_{ij}(t)^{\alpha}\eta_{ij}^{\beta}}{\sum_{c\in C_{i,k}}\tau_{ic}(t)^{\alpha}\eta_{ic}^{\beta}} & , j\in C_{i,k}\\ 0 & , wpp\end{cases} \qquad \eta_{ij}=\frac{1}{d_{ij}}$$

$$\tau_{ij}(t+1)=(1-\rho)\tau_{ij}(t)+\Delta\tau_{ij}(t) \quad (*)$$

$$\Delta\tau_{ij}(t)=\sum_{k=1}^{m}\Delta\tau_{ij,k}(t)$$

$$\Delta\tau_{ij,k}(t)=\begin{cases}\dfrac{Q}{L_k(t)} & , (i,j)\in T_k(t)\\ 0 & , wpp\end{cases}$$

Źródło: K. Grzesiak-Kopeć, Inteligencja obliczeniowa, wykład.

Inteligencja roju

Particle Swarm Optimization (PSO)

Inteligencja roju

Particle Swarm Optimization (PSO)

- zaproponowana przez Kennedy'ego i Eberharta, jest probabilistyczną metodą optymalizacji zainspirowaną zachowaniem stada zwierząt (owadów, ptaków, ryb); punktem wyjścia jest obserwacja, że o sile gatunku stanowi społeczność złożona z pojedynczych osobników, których zachowanie można opisać w bardzo prosty sposób.
- PSO operuje na zbiorze prostych osobników, wykonujących określone czynności, osobniki te komunikują się ze sobą (dzielą się wiedzą) w ustalony sposób. Algorytmy są zwykle zaprojektowane w taki sposób, że nie występuje narzucone z góry sterowanie pracą wszystkich osobników, jednak dzięki założonym regułom całość osiąga założony cel.
- Kilka prostych zasad zachowania, które są wykorzystywane w meta-heurystyce Swarm Intelligence to:
  1. Jednorodność - każdy element ma z góry określony model zachowania, każda cząstka może zostać liderem,
  2. Lokalność - tylko najbliższe elementy mają wpływ na zachowanie pojedynczego elementu,
  3. Unikanie kolizji z elementami w okolicy,
  4. Dostosowanie prędkości do cząsteczek, które są w okolicy,
  5. Centrowanie stada - próba trzymania się w odpowiedniej bliskości w stosunku do innych elementów.

Inteligencja roju

- Zmiana pozycji osobnika $\vec{x}_i(t) = \vec{x}_i(t-1) + \vec{v}_i(t)$
- Podstawowe wersje PSO: individual best, global best, local best.
- Schemat PSO w wersji **individual best**:

Inicjalizacja (losowa) pozycji cząstek, t=0
For t=1 to t_{max}
    dla każdego osobnika i
        oblicz $F_i(t)$
        If $F_i(t)$<pbest$_i$ then
            pbest$_i$=$F_i(t)$
            $x_{pbest,i}$=$x_i(t)$
        End if
        oblicz wektor przyspieszenia $v_i(t)=w_i*v_i(t-1)+c*R*(x_{pbest,i}-x_i(t))$
        wyznacz nową pozycję cząstki
Koniec: zwróć najlepsze rozwiązanie

Inteligencja roju

- Schemat PSO w wersji **local best**:

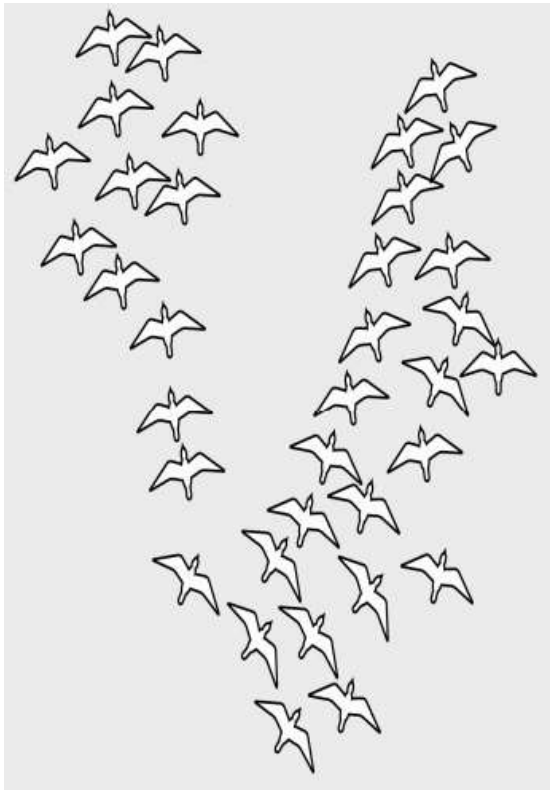

Inicjalizacja (losowa) pozycji cząstek, t=0
For t=1 to t_{max}
  dla każdego osobnika
    oblicz $F_i(t)$
    If $F_i(t)<pbest_i$ then
      $pbest_i=F_i(t)$
      $x_{pbest,i}=x_i(t)$
    End if
    If $F_i(t)<lbest_i$ then
      $lbest_i=F_i(t)$
      $x_{pbest,i}=x_i(t)$
    End if
    oblicz wektor przyspieszenia
    $v_i(t)=w_i*v_i(t-1)+c_1*R_1*(x_{pbest,i}-x_i(t))+c_2*R_2*(x_{lbest}-x_i(t))$
    wyznacz nową pozycję cząstki
Koniec: zwróć najlepsze rozwiązanie

Metody badania algorytmów

- Dokładność algorytmu określa oddalenie otrzymywanego rozwiązania od optymalnego. Ocena dokładności ma podstawowe znaczenie w przypadku algorytmów heurystycznych, gdyż algorytmy te nie dają rozwiązań o takiej samej dokładności dla problemów o różnych rozmiarach, co więcej – nie dają rozwiązań powtarzalnych. Powszechnie stosowane są trzy metody:
  1. oszacowanie zachowania się w najgorszym przypadku,
  2. ocena probabilistyczna,
  3. ocena eksperymentalna (wykorzystywana najczęściej).

Metody badania algorytmów

- Oszacowanie zachowania się w najgorszym przypadku jest metodą skomplikowaną, a przy tym nie oddającą w pełni najgorszego zachowania się algorytmu dla przeciętnych danych. Dlatego nadaje się jedynie dla stosunkowo prostych algorytmów.
- Analiza probabilistyczna algorytmów przybliżonych dostarcza informacji dotyczących ich średniego zachowania. Jest bardzo złożona z uwagi na konieczność analitycznego wyznaczenia względnego i bezwzględnego błędu algorytmu, stąd do tej pory przeanalizowano tą metodą niewiele algorytmów.
- Niedogodności dwóch pierwszych metod decydują o tym, że najchętniej stosuje się metodę eksperymentalną oceny algorytmów przybliżonych. Ocena eksperymentalna służy do badania przeciętnego zachowania się rozwiązań tworzonych przez algorytmy przybliżone. Polega ona na porównaniu rozwiązań generowanych przez dany algorytm z innymi rozwiązaniami (najlepiej - optymalnymi) dla reprezentatywnej próby rozważanego problemu.