

Sztuczna inteligencja w grach



Krzysztof Grąbczewski

Katedra Informatyki Stosowanej
Uniwersytet Mikołaja Kopernika
Toruń

3 czerwca 2020

<http://www.is.umk.pl/~kg/zajecia/SIwG/SIwG.pdf>

- ▶ slajdy,
- ▶ Brian Schwab – *AI game engine programming* (2004, Charles River Media; drugie wydanie 2009, Course Technology/Cengage Learning)
- ▶ Ian Millington, John Funge – *Artificial intelligence for games*, 2009, Elsevier,
- ▶ Steve Rabin (edytor) – *Game AI Pro* (2014, CRC Press) & *Game AI Pro 2* (2015, CRC Press) – <http://www.gameaipro.com/>,
- ▶ Stuart Russell, Peter Norvig, *Artificial Intelligence. A Modern Approach.*, 2nd Edition 2003, 3rd Edition 2010, <http://aima.cs.berkeley.edu/index.html>,
- ▶ Patrick H. Winston, *Artificial Intelligence*, 3rd Edition, Addison Wesley 1992.


- ▶ metody szukania,
 - szukanie dróg, również optymalnych (best-first, A*, algorytmy grafowe)
 - szukanie z przeciwnikiem (min-max, obcięcie alfa-beta, ...)
- ▶ proceduralne generowanie elementów światów gier,
 - losowe kształtowanie terenu, szum Perlina,
 - labirynty - tworzenie, szukanie dróg,
 - automaty komórkowe,
- ▶ systemy decyzyjne (drzewa zachowań, systemy regułowe),
- ▶ automaty stanów skończonych, również rozmyte, łańcuchy Markowa,
- ▶ algorytmy inteligencji zbiorowej (genetyczne, rojowe),
- ▶ systemy rozmyte,
- ▶ wszystko bardzo praktycznie.

Cel: Biblioteka różnych ogólnych narzędzi przydatnych do programowania SI w grach oraz programy demonstracyjne.


- ▶ szukanie dróg na planszy 2D (różne kształty, różne sąsiedztwa pól, wagi połączeń?, przeszkody),
- ▶ szukanie z przeciwnikiem (gra w kółko i krzyżyk, warcaby, „oddawane” warcaby),
- ▶ generowanie labiryntów i szukanie dróg,
- ▶ generowanie ukształtowania terenu,
- ▶ wielu agentów na planszy (rywalizujących i współpracujących),

Wszystko z wizualizacją.

- ▶ **Agent** – ktoś kto (lub coś co) postrzega **środowisko** za pomocą **czujników** i wpływa na środowisko (działa) poprzez **urządzenia wykonawcze** (ang. *agent, environment, sensor, actuator*).
- ▶ **Spostrzeżenie** (ang. *percept*) – stan wejść agenta w danej chwili.
- ▶ Agent może analizować **ciąg spostrzeżeń** (ang. *percept sequence*) – całą historię stanów wejść.



- ▶ Funkcja agenta – mapowanie ciągów spostrzeżeń na działania=akcje (wejść na wyjścia)
 - tabela działań,
 - program agenta.
- ▶ Prosty przykład środowiska dla agenta:



- ▶ Tabela działań:

Ciąg spostrzeżeń		Działanie
[A, czysto]	→	w prawo
[A, brudno]	→	odkurzaj
[A, czysto], [A, czysto]	→	w prawo
[A, czysto], [A, brudno]	→	odkurzaj
...		

- ▶ Agent **racjonalny**
- ▶ Miary jakości działań – zależne od celu, jakiemu agent ma służyć
 - **Racjonalność** = maksymalizacja miary jakości działań.
- ▶ Przykład odkurzacza – agent „**odkurzaj gdy brudno przejdź do drugiego pomieszczenia, gdy czysto**” – racjonalny, czy nie?
 - ilość zebranego kurzu,
 - ocena czystości pomieszczeń,
 - kary za zużywanie energii, ...
- ▶ **Warunki środowiska** istotnie wpływają na racjonalność działań
 - znajomość geografii – z pomieszczenia A nie ma sensu próbować iść w lewo,
 - ocena prawdopodobieństwa wystąpienia kurzu.
- ▶ Cechy zaawansowanych agentów:
 - gromadzenie informacji,
 - uczenie się,
 - autonomiczność.

► Specyfikacja zadania dla agenta:

- Jakość działania (ang. *Performance*)
- Środowisko (ang. *Environment*)
- Urządzenia wykonawcze (ang. *Actuators*)
- Czujniki (ang. *Sensors*)


► Przykład: **taksówkarz**

- Miara jakości: bezpieczeństwo, czas dojazdu, przestrzeganie przepisów, wygoda podróży, maksymalizacja zysku
- Środowisko: drogi, inne pojazdy, piesi, klienci
- Urz. wykonawcze: kierownica, pedał gazu, pedał hamulca, przełączniki, klakson, wyświetlacz dla klientów
- Czujniki: kamery, sonar, prędkościomierz, GPS, licznik, miernik przyspieszenia, czujniki silnika, klawiatura


- ▶ w pełni i częściowo obserwowalne (ang. *fully/partially observable*)
- ▶ deterministyczne i stochastyczne (ang. *deterministic/stochastic*)
- ▶ epizodyczne i sekwencyjne (ang. *episodic/sequential*)
- ▶ statyczne i dynamiczne (ang. *static/dynamic*)
- ▶ dyskretne i ciągłe (ang. *discrete/continuous*)
- ▶ jedno- i wieloagentowe (ang. *single/multiagent*)
- ▶ współpracy i współzawodnictwa (ang. *cooperative/competitive*)

- ▶ Agent = architektura + program
- ▶ Architektura: czujniki i urządzenia wykonawcze
- ▶ Programy zapisywane różnymi językami
 - meta-kod,
 - schematy blokowe,
 - zestawy reguł warunek-działanie, ...
- ▶ Podstawowe typy agentów:
 - działania jako proste odruchy (ang. *simple reflex*),
 - działanie oparte na modelach (ang. *model-based*),
 - ukierunkowanie na cele (ang. *goal-based*),
 - użyteczność działań (ang. *utility-based*).

- Programy odpowiadają wprost tabelom działań bądź zestawom reguł warunek–działanie




- ▶ Wewnętrzna **pamięć (stan)** pozwala uwzględniać aspekty nieobserwowalne w bieżącym wejściu.
- ▶ **Model świata** uwzględniający wpływ działania agenta.




Agenty ukierunkowane na cele




- Ocena na ile działanie agenta zbliży go **do celu**.
- Bardziej złożone procedury maksymalizacji funkcji celu, **procesy szukania, planowanie**.



- Funkcje użyteczności oceniają jakość decyzji (poziom satysfakcji z danego działania)



- ▶ Uczenie się może wzbogacić **każdy z typów** agentów.
- ▶ **Część wykonawcza** korzysta z wyników **procesów uczenia się**.
- ▶ Uczenie się **ze wzmocnieniem** (z nagrodą lub karą).



Definicja problemu:

- ▶ **zbiór stanów** $\mathcal{S}$ (przestrzeń),
- ▶ stan początkowy $s_0 \in \mathcal{S}$,
- ▶ **cel** (podzbiór zbioru stanów $\mathcal{G} \in \mathcal{S}$, funkcja-test osiągnięcia celu $G : \mathcal{S} \rightarrow \{0, 1\}$),
- ▶ **zbiór** możliwych **działań** agenta $\mathcal{A}$ i ich skutków w danym kontekście, często funkcja następnika (ang. *successor*) $\text{succ} : \mathcal{S} \rightarrow 2^{\mathcal{A} \times \mathcal{S}}$,
- ▶ funkcja kosztu (koszt ścieżki, koszt kroku).

Rozwiązanie = **ścieżka** od stanu początkowego do celu.

Proces szukania

- ▶ To proces wyznaczający sekwencję działań prowadzących do celu.
- ▶ Algorytm szukania otrzymuje na wejściu definicję problemu i zwraca ciąg działań (**rozwiązanie**).

Środowisko agenta stosującego problemy szukania:

- ▶ obserwowalne (przynajmniej znany stan początkowy),
- ▶ deterministyczne,
- ▶ statyczne (założenie dynamiczności istotnie zmienia problem),
- ▶ dyskretne,
- ▶ jednoagentowe.

Różne cele

- ▶ znalezienie **jakiegokolwiek** drogi,
- ▶ znalezienie **optymalnej** drogi,
- ▶ znalezienie **stanu** celu,
- ▶ działanie **w czasie rzeczywistym, z oponentem** itp.

Stany:

$\mathcal{S} = \{L, P\} \times \{\text{czysto}, \text{brudno}\}^2$ – pozycja odkurzacza i stan pomieszczeń ($2 \cdot 2^2 = 8$ stanów).

Stan początkowy:

Dowolny z możliwych.

Test celu:

Cel osiągnięty gdy w obu pomieszczeniach czysto.

Działania:


$\{\text{w lewo}, \text{w prawo}, \text{odkurzaj}\}$.

Koszt ścieżki:

Liczba kroków (fragmentów ścieżki).

Ogólniej: dla n pomieszczeń mamy $n \cdot 2^n$ stanów.

Przykład – odkurzacz



Popularna zabawka polegająca na ustawianiu w kolejności ośmiu ponumerowanych kostek poprzez przesuwanie ich w zamkniętej kwadratowej tabliczce 9 pól.

7	2	4
5		6
8	3	1

Start State

	1	2
3	4	5
6	7	8

Goal State

Stany:

opis położenia wszystkich kostek w tabliczce (9! możliwości).

Stan początkowy:

Dowolny z możliwych. Każdy cel jest osiągalny z połowy stanów początkowych.

Test celu:

Kostki ułożone w kolejności, puste miejsce w lewym górnym rogu (oczywiście można inaczej).

Działania:

{w lewo, w prawo, w górę, w dół}.

Koszt ścieżki:

Liczba kroków (fragmentów ścieżki).

Osiągnięcie celu jest dość łatwe, ale **znalezienie optymalnej ścieżki NP-zupełne**.

Zadanie: ustawić 8 hetmanów na szachownicy tak by się żadna para nie szachowała.

Możliwe podejścia:

- ▶ inkrementacyjne/przyrostowe – dostawianie po jednym,
- ▶ całkowite – rozmieszczenie 8 od razu i ich przestawianie.

Stany:

Pozycje $k \in \{0, 1, \dots, 8\}$ hetmanów.

Stan początkowy:

$k = 0$.

Test celu:

8 hetmanów poprawnie rozmieszczonych.

Działania:

Dostawienie kolejnego hetmana.

Koszt ścieżki:

nieistotny/stały.

Liczba sekwencji: $64 \cdot 63 \cdots 57 \approx 1.8 \times 10^{14}$.

Efektywniejsze podejście:

Stany:

Pozycje $k \in \{0, 1, \dots, 8\}$ hetmanów w kolejnych kolumnach.

Działania:

Dostawienie kolejnego hetmana w kolejnej kolumnie.

Liczba sekwencji: $8^8 = 16 \times 10^6$

Jeszcze inne możliwości:

- ▶ sprawdzanie permutacji ($8! = 40320$ stanów),
- ▶ dostawianie hetmanów tylko na pozycjach nieszachowanych (2057 stanów, ale kosztowniejsze ich odnajdywanie).

Ogólnie, problem N hetmanów dla szachownicy $N \times N$, dla większych N , daje przestrzeń stanów niemożliwą do przeiterowania.

Stany:

Aktualna lokalizacja i bieżący czas.

Stan początkowy i test celu:

definiowane indywidualnie dla problemu – miejsce startu, miejsce docelowe i pożądany czas dotarcia.

Działania:

Skorzystanie z dostępnego lotu.

Koszt ścieżki:

Różnie: koszt finansowy, czas lotu, czas oczekiwania, konieczność odpraw celnych i imigracyjnych, jakość miejsc, typ samolotu, pora dnia itp.

- ▶ Problemy objazdowe – odwiedzić wszystkie miejsca i wrócić do źródła
 - komiwojażera,
 - podróży dookoła świata,
 - skoczka szachowego.
- ▶ Lis, gęś i ziarno lub podobny problem kanibali i misjonarzy.
- ▶ Problem układów VLSI – rozkład elementów i trasowanie ścieżek.
- ▶ Nawigacja robotem w ciągłym świecie.
- ▶ Automatyczny montaż – kolejność montażu wielu komponentów w przestrzeni 3D.
- ▶ Projektowanie białek.
- ▶ „Inteligentne” wyszukiwanie informacji w internecie.
- ▶ Gry planszowe, gry komputerowe, strategiczne.
- ▶ Dowodzenie twierdzeń matematycznych.


Struktura **drzewa**

- ▶ Stan początkowy to **korzeń**.
- ▶ W kolejnym kroku **rozwija się bieżący węzeł** według aktualnych możliwości działania.
- ▶ Różne **strategie szukania** – kolejność rozwijania wygenerowanych dotąd węzłów.
 - (ang. *fringe*) – zestaw węzłów-kandydatów do rozwijania.

Węzeł drzewa

- ▶ bieżący **stan**,
- ▶ węzeł nadrzędny (**rodzic**),
- ▶ **działanie**, które doprowadziło do bieżącego stanu,
- ▶ **koszt** ścieżki,
- ▶ **głębokość**.


Przykład – fragment Rumunii




Przykład – fragment Rumunii




(a) The initial state



(b) After expanding Arad



(c) After expanding Sibiu



Prototype: *TreeSearch(problem, strategy)*

Input: Problem definition, search strategy.

Output: A solution or failure.

- ① initialize the tree with the node of initial state
 - ② **while** exist candidates for expansion **do**
 - ① use the strategy to select the node to examine/expand
 - ② **if** a goal state reached **then return** the solution
 - ③ expand the node (grow the tree)
 - ③ **return** failure
-

Prototype: *TreeSearchWithQueue(problem, fringe)*

Input: Problem definition, fringe interface.

Output: A solution or failure.

- ① fringe $\leftarrow$ one-element collection with the initial state
 - ② **while** fringe is not empty **do**
 - ① node $\leftarrow$ remove first node from the fringe
 - ② **if** a goal state reached **then return** the solution
 - ③ expand the node – add new nodes to the fringe
 - ③ **return** failure
-

Najważniejsze aspekty:

- ▶ **Zupełność** – czy metoda gwarantuje dotarcie do celu, jeśli taki istnieje.
- ▶ **Optymalność** – czy znajdziemy optymalne rozwiązanie.
- ▶ **Złożoność czasowa.**
- ▶ **Złożoność pamięciowa.**

Podstawowe oznaczenia:


- ▶ b – czynnik rozgałęzień (ang. *branching factor*),
- ▶ d – minimalna głębokość drzewa, na której można znaleźć cel,
- ▶ m – maksymalna długość ścieżki.

Szukanie **na ślepo** (ang. *blind, uninformed*) i **heurystyczne** (ang. *heuristic, informed*).

Szukanie wszerek (ang. *breadth-first search*)



Szukanie w kolejności **od najpłytszych węzłów do coraz głębszych**



- ▶ Algorytm realizowany przez procedurę `TreeSearchWithQueue` i **zwykłą kolejkę** (FIFO).
- ▶ Liczba generowanych węzłów:


$$b + b^2 + \dots + b^d + b^{d+1} - b \propto O(b^{d+1}) \quad (1)$$

- ▶ Takie same: **złożoność czasowa i pamięciowa**, jednak pamięciowa doskwiera bardziej.
- ▶ Metoda **zupełna i optymalna**.

Tak jak wszerek, ale najpierw nie najkrótsze ścieżki, a te z **najniższym kosztem**.

- ▶ Zerowy koszt kroku może zapętlić metodę.
- ▶ Algorytm realizowany przez procedurę `TreeSearchWithQueue` i **kolejkę priorytetową**.
- ▶ **Zupełność i optymalność** zachowana.
- ▶ **Złożoność czasowa i pamięciowa**: $O(b^{1+\lceil C^*/\epsilon \rceil})$, gdzie C^* to koszt optymalnego rozwiązania, a ϵ to dolne ograniczenie kosztu pojedynczego kroku.

Szukanie w głąb (ang. *depth-first search*)



Szukanie w kolejności **od najgłębszych węzłów**.

- ▶ Algorytm realizowany przez procedurę `TreeSearchWithQueue` i **stos** („kolejkę” LIFO).
- ▶ Możliwość utknięcia w nieskończonej gałęzi – metoda **niezupełna**.
- ▶ Metoda **nieoptymalna**.
- ▶ Złożoność pamięciowa $O(bm)$.
- ▶ **Szukanie z nawrotami** (ang. *backtracking search*) pozwala zredukować złożoność pamięciową do $O(m)$.
- ▶ Łatwiejsza i bardziej naturalna **implementacja rekurencyjna**.

Funkcje rekurencyjne w bardzo prosty sposób wykonują złożone operacje na danych o rekurencyjnej naturze.

Definicje rekurencyjne:

► Liczby naturalne N

- $0 \in N$,
- $n \in N \Rightarrow \text{succ}(n) \in N$.

► Silnia liczby $n \in N$

- $0! \in N$,
- $n \in N \Rightarrow \text{succ}(n)! = \text{succ}(n) \cdot n!$.

► Listy elementów zbioru X jako złożenie głowy i ogona (pierwszy element i reszta)

- $() \in L$,
- $x \in X \wedge M \in L \Rightarrow x.M \in L$ ($[x|M] \in L$ w notacji prologowej).

► Drzewa binarne z etykietami ze zbioru X

- $() \in D$,
- $x \in X \wedge d_1, d_2 \in D \Rightarrow \begin{array}{c} x \\ / \quad \backslash \\ d_1 \quad d_2 \end{array} \in D$.

Długość listy

$$dl(L) = \begin{cases} 0 & \text{jeśli } L = (), \\ 1 + dl(M) & \text{jeśli } L = x.M. \end{cases} \quad (2)$$

Suma wartości z węzłów drzewa

$$suma(d) = \begin{cases} 0 & \text{jeśli } d = (), \\ x + suma(d_1) + suma(d_2) & \text{jeśli } d = \begin{array}{c} x \\ / \quad \backslash \\ d_1 \quad d_2 \end{array}. \end{cases} \quad (3)$$

Prototype: *RecursiveDFS(problem, node)*

Input: Problem definition, current node.

Output: A solution or failure.

- ① **if** node reached the goal **then return** the solution
- ② **for each** subnode sn **do**
 - ① result $\leftarrow$ RecursiveDFS(problem, sn)
 - ② **if** result is a solution **then return** the solution
- ③ **return** failure

Prototype: *RecursiveDFS(problem)*

- ① **return** RecursiveDFS(problem, the root node)
-

Szukanie z ograniczeniem głębokości (ang. *depth-limited search*).

Jak w głąb, ale **nie rozwijamy** gałęzi po uzyskaniu zadanej **głębokości l** .

- ▶ Dodatkowe ograniczenie łatwe do wprowadzenia.
- ▶ Złożoność **czasowa** $O(b^l)$.
- ▶ Złożoność **pamięciowa** $O(bl)$.
- ▶ Brak **zupełności** i **optymalności**.

Iteracyjne pogłębianie szukania w głąb (ang. *iterative deepening depth-first search*).

Prototype: *IDDFS(problem)*

Input: Problem definition.

Output: A solution or failure.

- ① **for** depth $\leftarrow 0$ **to** ∞ **do**
 - ① result $\leftarrow$ DepthLimitedSearch(problem, depth)
 - ② **if** result $\neq$ cutoff **then return** result
-

Właściwości:



- ▶ Złożoność pamięciowa $O(bd)$.
- ▶ Złożoność czasowa $O(b^d)$ – powtórki nie kosztują tak dużo jakby się wydawało.
- ▶ Metoda zupełna i optymalna.

Iteracyjne pogłębianie



Limit = 0











Limit = 1




Limit = 2



Limit = 3



Dwa równoległe szukania – od startu do celu i odwrotnie:



Znacznie szybciej, bo $2 \cdot b^{d/2} \ll b^d$.

Problematyczne, gdy cel obejmuje wiele stanów (być może nawet nieskończenie wiele).

Ponowne odwiedzanie tych samych stanów

- ▶ znacznie **spowalnia** szukanie
- ▶ może być wyeliminowane przez **oznaczanie sprawdzonych stanów** (flaga w obiekcie stanu lub tablica haszująca)

Brak pełnej informacji o bieżącym stanie

- ▶ **nieznany stan początkowy**,
- ▶ sytuacja niekoniecznie beznadziejna – przykład odkurzacza – sekwencja (w prawo, odkurzaj, w lewo, odkurzaj) zapewni **osiągnięcie celu niezależnie od stanu początkowego**,
- ▶ trudno oceniać **optymalność** rozwiązań,
- ▶ gotowość na **niespodzianki**,
- ▶ **gry z adversarzem**.

Ogólny schemat – **generuj i sprawdzaj** (ang. *generate and test*)

Prototype: *GenerateAndTest(P,G,SC)*

Input: Problem P definition, state generator G, stop condition SC.

Output: A solution or failure.

- ❶ **while** SC not satisfied **do**
 - ❶ $S \leftarrow$ generate next state with G
 - ❷ **if** S is a goal state **then return** the solution
 - ❷ **return** failure
-

Najbardziej prymitywne podejścia:

- ▶ Monte Carlo – losuj aż trafisz,
- ▶ brytyjskie muzeum – sprawdź wszystko i wybierz.



Rozwijaj i ograniczaj (ang. *branch and bound*) – ogólna technika polegająca na rozwijaniu kolejnych węzłów i ograniczaniu się do tych najbardziej obiecujących.

Najprostsze ujęcie:

- ▶ Badanie węzłów **w kolejności rosnących kosztów**.
- ▶ Rozwijane węzły do **kolejki priorytetowej**.
- ▶ **Początek: korzeń** do kolejki
- ▶ Potem pobieramy z kolejki ścieżkę **o najniższym koszcie** i ją rozwijamy. Następnie dodajemy **do kolejki**.
- ▶ Jeśli wiemy, że istnieje droga długości ≤ 420 , to wszystkie dłuższe możemy odrzucać.

Podstawowe definicje:

- **Graf skierowany (digraf)** – para (V, E) , gdzie V to dowolny zbiór (zbiór **wierzchołków**) a E to zbiór **krawędzi** (par wierzchołków, $E \subseteq V \times V$).
- **Graf nieskierowany** – jak skierowany, ale w krawędziach nieistotna jest kolejność wierzchołków.
- **Graf ważony** – graf, w którym dodatkowo każdej krawędzi przypisana jest wartość rzeczywista zwana **wagą**: (V, E, w) , $w : E \rightarrow R$.



Ważony graf skierowany $G = (V, E, w)$ najczęściej reprezentujemy **tablicą W** (**macierzą przyległości**, ang. adjacency matrix) taką, że:

$$W[i, j] = \begin{cases} 0 & \text{jeśli } i = j, \\ w(v_i, v_j) & \text{jeśli } (v_i, v_j) \in E \text{ (w } G \text{ istnieje krawędź } (v_i, v_j)), \\ \infty & \text{jeśli } (v_i, v_j) \notin E. \end{cases}$$

Graf nieskierowany można traktować jako skierowany o symetrycznych połączeniach.

Tablice dla grafów z poprzedniego slajdu:

	1	2	3	4	5
1	0	4	∞	∞	∞
2	3	0	2	∞	∞
3	∞	∞	0	2	5
4	∞	∞	4	0	7
5	3	∞	∞	6	0

	1	2	3	4	5
1	0	3	∞	∞	2
2	3	0	3	2	5
3	∞	3	0	1	∞
4	∞	2	1	0	7
5	2	5	∞	7	0

- ▶ **Droga** – ciąg wierzchołków taki, że istnieje krawędź z każdego wierzchołka do jego następnika, **droga prosta** – droga, która nie przechodzi dwa razy przez ten sam wierzchołek.
- ▶ **Długość drogi** – suma wag krawędzi, z których składa się droga. Dla grafów nieważonych – liczba krawędzi.
- ▶ **Cykl** – droga, w której wierzchołek początkowy jest również końcowym, **cykl prosty** – cykl będący drogą prostą.
- ▶ **Graf cykliczny/acykliczny** – graf, w którym istnieje/nie istnieje cykl.
- ▶ Graf nieskierowany jest **spójny**, gdy między każdymi dwoma wierzchołkami istnieje droga.
- ▶ **Drzewo** – graf nieskierowany, acykliczny i spójny.
- ▶ **Drzewo rozpinające** graf (ang. spanning tree) – drzewo, które zawiera wszystkie wierzchołki grafu.
- ▶ **Minimalne drzewo rozpinające** – drzewo rozpinające o minimalnej sumie wag krawędzi.

Najpopularniejsze problemy:

- ▶ Szukanie drogi o minimalnej długości.
- ▶ Wyznaczanie minimalnego drzewa rozpinającego:
 - jak najmniej asfaltu, by połączyć określone miasta,
 - jak najmniej kabli w sieci komputerowej, itp.

Podstawowe algorytmy:

- ▶ Szukanie dróg:
 - Dijkstry,
 - Floyda (alg. programowania dynamicznego).
- ▶ Wyznaczanie minimalnego drzewa rozpinającego:
 - Prima,
 - Kruskala.






Dane: Graf nieskierowany $G = (V, E, w)$.

Wynik: Minimalne drzewo rozpinające $D = (V, F, w|F)$ grafu G .

- ▶ $Y \leftarrow \{v_1\}$
- ▶ $F \leftarrow \emptyset$
- ▶ Aż do uzyskania drzewa rozpinającego ($Y = V$):
 - wyznaczamy wierzchołek y z $V - Y$ o minimalnej odległości do Y (jednocześnie zapamiętujemy krawędź f , która dała minimalną odległość),
 - $Y \leftarrow Y \cup \{y\}$ tzn. dodajemy wierzchołek y do zbioru Y ,
 - $F \leftarrow F \cup \{f\}$ tzn. dodajemy krawędź f do zbioru F ,
- ▶ Wynik: drzewo $D = (V, F, w|F)$.

Złożoność czasowa: $O(n^2)$ (n to liczba wierzchołków).

Algorytm Prima – przykład



Dane: Graf nieskierowany $G = (V, E, w)$.

Wynik: Minimalne drzewo rozpinające $D = (V, F, w|_F)$ grafu G .

- ▶ $V_i \leftarrow \{v_i\}$ – rozłączne jednoelementowe zbiory (dla każdego wierzchołka),
- ▶ $F \leftarrow \emptyset$
- ▶ Sortujemy krawędzie ze zbioru E niemalejąco względem wag,
- ▶ Aż do uzyskania drzewa rozpinającego (wszystkie podzbiory V zostały scalone):
 - bierzemy kolejną krawędź $f \in E$ wg. ustalonego porządku,
 - jeśli krawędź f łączy wierzchołki z różnych podzbiorów to:
 - scalamy podzbiory zawierające wierzchołki,
 - $F \leftarrow F \cup \{f\}$ tzn. dodajemy krawędź f do zbioru F ,
- ▶ Wynik: drzewo $D = (V, F, w|_F)$.


Złożoność czasowa: (n – liczba wierzchołków, m – liczba krawędzi)

Inicjowanie zbiorów: $O(n)$, sortowanie: $O(m \log m)$, pętla w najgorszym przypadku $O(m \log m)$ (każda krawędź).


W najgorszym przypadku $m \approx n^2$, więc

$m \log m = n^2 \log n^2 = n^2 2 \log n$, czyli $O(n^2 \log n)$.

Algorytm Kruskala – przykład



1	(v_3, v_4)	1
2	(v_1, v_5)	2
3	(v_2, v_4)	2
4	(v_2, v_3)	3
5	(v_1, v_2)	3
6	(v_2, v_5)	5
7	(v_4, v_5)	7




Algorytm Kruskala – przykład c.d.




1	(v_3, v_4)	1
2	(v_1, v_5)	2
3	(v_2, v_4)	2
4	(v_2, v_3)	3
5	(v_1, v_2)	3
6	(v_2, v_5)	5
7	(v_4, v_5)	7


1. Dodajemy (v_3, v_4) .




2. Dodajemy (v_1, v_5) .




3. Dodajemy (v_2, v_4) .



4. Nie dodajemy (v_2, v_3) .



5. Dodajemy (v_1, v_2) .




Dane: Graf $G = (V, E, w)$.

Wynik: Najkrótsze (dokładniej: minimalnej długości) drogi z wierzchołka $v \in V$ do wszystkich pozostałych, długości dróg; drzewo rozpinające zawierające najkrótsze drogi z wierzchołka v .

- ▶ $Y \leftarrow \{v\}$
- ▶ $F \leftarrow \emptyset$
- ▶ Tak długo jak $Y \neq V$:
 - wyznaczamy wierzchołek $y \in V - Y$, o minimalnej długości najkrótszej drogi z v poprzez wierzchołki z Y .
 - $Y \leftarrow Y \cup \{y\}$,
 - $F \leftarrow F \cup \{f\}$.

Złożoność czasowa: $O(n^2)$ (n to liczba wierzchołków).


Algorytm Dijkstry – przykład






$$Y = \{v_1\}$$



$$v_2 \rightarrow Y, d(v_1, v_2) = 4$$



$$v_3 \rightarrow Y, d(v_1, v_3) = 6 \quad v_4 \rightarrow Y, d(v_1, v_4) = 8 \quad v_5 \rightarrow Y, d(v_1, v_5) = 11$$



Idea: Najkrótsza droga z v_i do v_j wiodąca przez v_k składa się z najkrótszej drogi z v_i do v_k oraz najkrótszej drogi z v_k do v_j .

Dane: Graf $G = (V, E, w)$.

Wynik: Długości najkrótszych (dokładniej: minimalnej długości) dróg pomiędzy każdą parą wierzchołków.

```
1 Floyd(Array2D W, Array2D D)
2 {
3   D.CopyFrom(W);
4   for (int k = 1; k <= n; k++)
5     for (int i = 1; i <= n; i++)
6       for (int j = 1; j <= n; j++)
7         D[i,j] := minimum(D[i,j], D[i,k] + D[k,j]);
8   return D;
9 }
```

Złożoność czasowa: $O(n^3)$ (n to liczba wierzchołków).

Uwaga na indeksy!

Ważna własność: W k -tym kroku wartość $D[i, j]$ to długość najkrótszej drogi z v_i do v_j o wierzchołkach pośrednich ze zbioru $\{v_1, \dots, v_k\}$.

Przykład:

D^0	1	2	3	4	5
1	0	4	∞	∞	∞
2	3	0	2	∞	∞
3	∞	∞	0	2	5
4	∞	∞	4	0	7
5	3	∞	∞	6	0

D^1	1	2	3	4	5
1	0	4	∞	∞	∞
2	3	0	2	∞	∞
3	∞	∞	0	2	5
4	∞	∞	4	0	7
5	3	7	∞	6	0

D^2	1	2	3	4	5
1	0	4	6	∞	∞
2	3	0	2	∞	∞
3	∞	∞	0	2	5
4	∞	∞	4	0	7
5	3	7	9	6	0

D^3	1	2	3	4	5
1	0	4	6	8	11
2	3	0	2	4	7
3	∞	∞	0	2	5
4	∞	∞	4	0	7
5	3	7	9	6	0

D^4	1	2	3	4	5
1	0	4	6	8	11
2	3	0	2	4	7
3	∞	∞	0	2	5
4	∞	∞	4	0	7
5	3	7	9	6	0

D^5	1	2	3	4	5
1	0	4	6	8	11
2	3	0	2	4	7
3	8	12	0	2	5
4	10	14	4	0	7
5	3	7	9	6	0

W przeciwieństwie do szukania na ślepo – **informacja zwrotna**, możliwość użycia funkcji oceny do oszacowania „jakości” bieżącego stanu.

Heurystyki – cenne wskazówki, oparte na doświadczeniu, które dają często, choć nie zawsze, pozytywne skutki. Zwykle to funkcje z przestrzeni stanów do zbioru liczb rzeczywistych

$$h : S \rightarrow R, \quad (4)$$

takie, że

$$\forall_{s \in G} h(s) = 0. \quad (5)$$

Dla wygody, dla wężła n , $h(n) \stackrel{\text{ozn}}{=} h(s_n)$.

Proste **wykorzystanie heurystyk w szukaniu**:

- ▶ rozwijaj węzły drzewa w kolejności rosnącej heurystyki,
- ▶ kolejka priorytetowa.

- ▶ Wykorzystanie funkcji heurystycznych – nowa rodzina metod „**najpierw najlepszy**” (ang. *best-first search*).
- ▶ Podejście **zachłanne** (ang. *greedy best-first search*)

$$f(n) = h(s_n). \quad (6)$$

- ▶ Przykład dróg do Bukaresztu (str. 27) – dobra heurystyka: **jak daleko do celu w linii prostej**.

Arad	366	Mehadia	241
Bucharest	0	Neamt	234
Craiova	160	Oradea	380
Drobeta	242	Pitesti	100
Eforie	161	Rimnicu Vilcea	193
Fagaras	176	Sibiu	253
Giurgiu	77	Timisoara	329
Hirsova	151	Urziceni	80
Iasi	226	Vaslui	199
Lugoj	244	Zerind	374

- Cel: **minimalizacja łącznego estymowanego kosztu** rozwiązania:

$$f(n) = g(n) + h(n). \quad (7)$$

- **Własność:** A* jest optymalna, gdy heurystyka h nigdy nie przeszacowuje rzeczywistego kosztu. Mówimy wtedy, że h jest **dopuszczalna** (ang. *admissible*).

Dowód: Niech n będzie nieoptymalnym węzłem ze stanem końcowym oraz C^* kosztem optymalnego rozwiązania.

Oczywiście $f(n) = g(n) > C^*$. Jeśli n_0 jest węzłem z optymalną ścieżką, to $f(n_0) = g(n_0) + h(n_0) \leq C^* < f(n)$, bo h (a więc również f) nie przeszacowuje kosztu. Stąd węzeł n nie zostanie nigdy rozwinięty, a rozwiązaniem będzie węzeł optymalny. $\square$

- Heurystyka jest **monotoniczna** (ang. *monotonic, consistent*) jeśli dla każdego wężła n oraz jego wężła potomnego n' zachodzi

$$h(n) \leq c(n, a, n') + h(n'), \quad (8)$$

gdzie $c(n, a, n')$ jest kosztem działania a skutkującego zmianą stanu z s_n do $s_{n'}$.

- Jeśli h jest monotoniczna, to f jest **niemalejąca na danej ścieżce**.
- Monotoniczność heurystyki gwarantuje **optymalność** szukania z **odrzucaaniem odwiedzonych** stanów.

- ▶ Rozwija wszystkie węzły n , dla których $f(n) < C^*$.
- ▶ Nie rozwija węzłów n , dla których $f(n) > C^*$.
- ▶ Jest **zupełna**, jeśli zbiór węzłów n , dla których $f(n) < C^*$ jest skończony, w szczególności, jeśli koszt pojedynczego działania jest zawsze $\geq \epsilon > 0$ oraz b jest skończone.
- ▶ Jest **optymalnie efektywna** tzn. żaden inny algorytm optymalny nie rozwija mniej węzłów (chyba, że węzłów, dla których $f(n) = C^*$).

Dowód: Algorytm, który nie rozwinie wszystkich węzłów o $f(n) < C^*$ nie jest optymalny. □

- ▶ Cel: ograniczenie zapotrzebowania na **pamięć**.
- ▶ IDA*- zwykły ID dla A*, ale **z limitem kosztów** $f = g + h$ **zamiast głębokości**.
- ▶ Próg f -kosztów – najmniejszy koszt węzła, przekraczający poprzedni próg odcięcia.


Prototype: *RecursiveBestFS(P, node, fLimit)*

Input: Problem P, current node, f limit.


Output: A solution or failure and a new f -cost.

- ① **if** node reached the goal **then return** the solution
- ② successors $\leftarrow$ subnodes of the node
- ③ **if** successors is empty **then return** failure, ∞
- ④ **for each** s in successors **do** $f[s] \leftarrow \max(g(s) + h(s), f[node])$
- ⑤ **repeat**
 - ① best $\leftarrow \arg \min_{s \in \text{successors}} f(s)$
 - ② **if** $f[\text{best}] > fLimit$ **then return** failure, $f[\text{best}]$
 - ③ $fAlt \leftarrow$ second best $f(s)$ among successors
 - ④ result, $f[\text{best}] \leftarrow \text{RecursiveBestFS}(P, \text{best}, \min(fLimit, fAlt))$
 - ⑤ **if** result $\neq$ failure **then return** result


(a) After expanding Arad, Sibiu, and Rimnicu Vilcea



(b) After unwinding back to Sibiu and expanding Fagaras



(c) After switching back to Rimnicu Vilcea and expanding Pitesti



- ▶ Niebezpieczeństwo częstych „**zmian zdania**” (zmian ścieżki szukania).
- ▶ **Złożoność czasowa** trudna do określenia.
- ▶ **Optymalny**, jeśli heurystyka h jest dopuszczalna.
- ▶ **Złożoność pamięciowa liniowa** względem głębokości najgłębszego rozwiązania optymalnego.
- ▶ Jak w IDA* **niebezpieczeństwo wielokrotnego badania** tych samych stanów.
- ▶ **Nadmierna oszczędność pamięci**.
- ▶ Algorytmy wykorzystujące dostępną pamięć: **MA***, **SMA***.
 - SMA* – rozwija węzły aż do wypełnienia pamięci – wówczas **wyrzuca z pamięci najgorszy węzeł** (największe $f(n)$), zapamiętując jego jakość w węźle-rodzicu.
 - Na wypadek równych $f(n)$ – usuwany **najstarszy**, rozwijany **najmłodszy**.

- ▶ Cel: **ograniczenie ilości pamięci**.
- ▶ Jak w szukaniu wszerek, ale po każdej iteracji ograniczanie zajętości pamięci do k **stanów**.
- ▶ k to **szerokość wiązki**.
- ▶ Porzucanie części stanów skutkuje brakiem **zupełności i optymalności**.
- ▶ Atrakcyjna złożoność **pamięciowa**.
- ▶ Złożoność **czasowa** trudna do określenia – w szczególności brak gwarancji zakończenia procesu sukcesem.
- ▶ Niebezpieczeństwo **degeneracji wiązki** – różne techniki dbania o **różnorodność wiązki**.

Przykłady dla problemu 8-ki:

- ▶ h_1 – **liczba elementów** nie na swoim miejscu,
- ▶ h_2 – suma **odległości Manhattan** elementów od swoich pozycji docelowych.
- ▶ Dla przykładu obok:
 $h_1(n) = 8$, $h_2(n) = 18$.
- ▶ h_1 i h_2 są **dopuszczalne**.
- ▶ Miara jakości heurystyki: **efektywny czynnik rozgałęzień** b^* – liczba rzeczywista spełniająca:

7	2	4
5		6
8	3	1

Start State

	1	2
3	4	5
6	7	8

Goal State

$$N + 1 = 1 + b^* + (b^*)^2 + \dots + (b^*)^d, \quad (9)$$

gdzie N to liczba węzłów w procesie szukania, a d to głębokość rozwiązania.

- ▶ Im b^* jest bliższe 1, tym lepsza heurystyka.

- ▶ h_2 **dominuje** nad h_1 , tzn. dla dowolnego wężła n ,
 $h_2(n) \geq h_1(n)$.
- ▶ Konsekwencja: każdy węzeł, rozwinięty przez h_2 będzie również rozwinięty przez h_1 (w A^* , bo to metoda optymalna).
- ▶ Wniosek: im wyższe wartości heurystyki, tym lepiej!
- ▶ Zadania: porównać liczby węzłów rozwijanych heurystykami h_1 i h_2 .

Poszukiwanie dopuszczalnych heurystyk


- ▶ **Problem uproszczony** (ang. *relaxed problem*) – problem ze zredukowaną liczbą ograniczeń.
- ▶ Ważna własność: **koszt optymalnego rozwiązania problemu uproszczonego jest dopuszczalną heurystyką problemu wyjściowego.**

Dowód: Rozwiązanie problemu wyjściowego jest też rozwiązaniem problemu uproszczonego więc jest co najmniej tak kosztowne jak jego rozwiązanie optymalne. □

- ▶ Wyrażenie ograniczeń w języku formalnym i ich **upraszczanie**:
Element można przesunąć:
 - *poziomo lub pionowo o jedno pole,*
 - *pod warunkiem, że pole docelowe jest puste.*
- ▶ **Maksimum** heurystyk dopuszczalnych **jest heurystyką dopuszczalną.**
- ▶ Koszt rozwiązania podproblemu **jest heurystyką dopuszczalną.**
- ▶ **Bazy wzorców** – zapamiętanie rozwiązań wszystkich podproblemów i odnajdywanie kosztów dla konkretnych konfiguracji zgodnych z danym stanem.
 - dla 15-tki i maksimum kosztów dla 4 wybranych kostek – 1000 razy szybciej niż Manhattan.
- ▶ **Bazy rozłącznych wzorców** – liczymy tylko ruchy dla wybranych elementów i sumujemy dla różnych (rozłącznych) wzorców.
 - dla 15-tki i wzorców dla 4 kostek – 10000 razy szybciej niż Manhattan.

- ▶ Nie zawsze istotna jest **ścieżka dojścia** do rozwiązania (drzewa niepotrzebne).
- ▶ **Lokalne szukanie** operuje **tylko bieżącym stanem** zamiast ścieżki.
- ▶ Metody szukania mogą również rozwiązywać problemy optymalizacyjne (zadana jest funkcja do minimalizacji).
- ▶ Założenie „ciągłości” problemu w sensie, że podobne stany są podobnie oceniane.

- ▶ Optima globalne i lokalne.
- ▶ Ramię, płaskie maksimum, grzbiet, plateaux.



- ▶ Zachłanne podążanie zawsze w kierunku rosnących wartości maksymalizowanej funkcji.
- ▶ Analizowane tylko bezpośrednie sąsiedztwo bieżącego stanu.

Prototype: *HillClimbing(P)*

Input: Problem P, w tym funkcja maksymalizowana F.

Output: Stan lokalnego maksimum.


- ① current $\leftarrow$ initial state
- ② **repeat**
 - ① neighbor $\leftarrow$ the highest-valued successor of current
 - ② **if** $F(\text{neighbor}) \leq F(\text{current})$ **then return** current
 - ③ current $\leftarrow$ neighbor

Przykład: problem 8 hetmanów



- ▶ Sformułowanie „pełnego stanu” (wszystkie hetmany na szachownicy, każdy ma jedną kolumnę).
- ▶ Funkcja następnika: **jeden hetman przestawiony** w inne miejsce.
- ▶ Heurystyka: **liczba szachujących się par** (do minimalizacji).

18	12	14	13	13	12	14	14
14	16	13	15	12	14	12	16
14	12	18	13	15	12	14	14
15	14	14	♔	13	16	13	16
♔	14	17	15	♔	14	16	16
17	♔	16	18	15	♔	15	♔
18	14	♔	15	15	14	♔	16
14	14	13	17	12	14	12	18



- ▶ Lokalne maksima/minima, grzbiety, plateaux...
- ▶ Przyzwolenie na **odejście w bok** z minimum lokalnego – przyzwolenie na 100 kolejnych ruchów w bok podnosi współczynnik sukcesu z 14% do 94%.
- ▶ **Stochastyczna metoda wspinaczki** – losuje kolejny stan spośród tych idących w górę.
- ▶ **Wspinaczka pierwszego wyboru** (ang. *first-choice hill climbing*) – losuje spośród następników aż wylosuje lepszy stan niż bieżący.
- ▶ Problem niezupełności – **losowe restarty**.

Symulowanie fizycznych procesów wyżarzania (ang. *simulated annealing*).

Prototype: *SimulatedAnnealing(P,H)*

Input: Problem P w tym funkcja maksymalizowana F, harmonogram schładzania H.

Output: Stan lokalnego minimum.

- ❶ current $\leftarrow$ initial state
 - ❷ **for** $t = 1$ **to** ∞ **do**
 - ❶ $T \leftarrow H(t)$
 - ❷ **if** $T = 0$ **then return** current
 - ❸ next $\leftarrow$ random successor of current
 - ❹ $\Delta E \leftarrow F(\text{next}) - F(\text{current})$
 - ❺ **if** $\Delta E > 0$ **then** current $\leftarrow$ next
else current $\leftarrow$ next with probability $e^{\Delta E/T}$
-

- ▶ Lokalne szukanie wiązką (ang. *local beam search*) działa jak szukanie wiązką, tyle, że nie utrzymuje pełnych ścieżek, a **same stany bieżące**.
- ▶ Ograniczenie pamięci do k **stanów**.
- ▶ Start: k **losowo** wybranych stanów.
- ▶ Niebezpieczeństwo **degeneracji** wiązki – wszystkie stany z jednego rodzica.
- ▶ Podejście **stochastyczne** – wybór wiązki losowy, prawdopodobieństwa proporcjonalne do wartości maksymalizowanej funkcji.



Inspiracje biologiczne

- ▶ kodowanie stanów (**osobników**) przez **chromosomy**,
- ▶ **naturalna selekcja** (funkcja **przystosowania**),
- ▶ **krzyżowanie**,
- ▶ **mutacje**.


Schemat algorytmu:

- ▶ Ustalamy **zasady kodowania** osobników.
- ▶ Wybieramy **losowo** pierwszą populację k osobników.
- ▶ Dla kolejnych populacji:
 - mierzymy **przystosowanie** (ang. *fitness*) osobników,
 - losujemy **pary osobników** do krzyżowania,
 - losujemy **punkt krzyżowania** (ang. *crossover point*),
 - krzyżujemy,
 - pozwalamy na **mutacje** z określonym p-stwem,
 - nowe osobniki to nowa populacja.


Algoritmy genetyczne – 8 hetmanów



+



=



Szukanie na boku (**offline**) spisuje się dobrze w środowiskach **statycznych** i **deterministycznych**.

Środowiska **dynamiczne**, **semidynamiczne** (kary za opieszałość) i **stochastyczne** wymagają reakcji w trakcie szukania (**online**).

Szukanie online

- ▶ Wynik akcji poznajemy **po jej podjęciu**.
- ▶ **Przeskoki** do odległych punktów w przestrzeni **nie są możliwe** – metody typu „najpierw najlepszy” czy A^* nie są odpowiednie.
- ▶ Właściwe są metody szukające w sposób „**zlokalizowany**” – szukanie w głąb, metoda wspinaczki itp.

Potrzebujemy dodatkowo:

- ▶ **rejestracji skutków** naszych akcji (przy założeniu deterministyczności),
- ▶ umiejętności **rozróżniania odwiedzonych i nie odwiedzonych** miejsc,
- ▶ rejestracji **możliwości powrotów**.

Rekurencja może pomóc w realizacji tych zadań. Wersje nierekurencyjne są zwykle trudniejsze.

Random walk


- ▶ wybieramy losowo dostępne akcje,
- ▶ preferencje dla akcji wcześniej nie próbowanych,
- ▶ dość powolny proces,
- ▶ niebezpieczeństwo pułapek odwodzących od celu.

Metoda wspinaczki. Jak uciekać z minimów lokalnych?

- ▶ Przeskoki losowe nie są możliwe.
- ▶ Losowe kierunki w minimach lokalnych.
- ▶ Wspinaczka z pamięcią – LRTA*.

LRTA* – learning real-time A*

- ▶ używamy **heurystyki i doświadczenia** – jak w A*, koszt jest sumą, tego co wiemy na pewno i oceny heurystyką,
- ▶ wybieramy akcję o najlepszym przewidywanym skutku,
- ▶ optymistycznie oceniamy nie próbowane akcje,
- ▶ aktualizujemy na bieżąco wiedzę o stanie, który opuszczamy.




Problemy z **ograniczeniami, więzami** (ang. *Constraint satisfaction problems*)

Wiedza o **wewnętrznej strukturze problemu** może pomóc w jego rozwiązywaniu.

Problem z ograniczeniami definiuje stany oraz cele przy użyciu **zbioru zmiennych** $X_1, X_2, \dots, X_n$ oraz **zbioru ograniczeń** $C_1, C_2, \dots, C_m$:

- ▶ stan – **przypisanie wartości podzbiorowi zmiennych**, np. $\{X_i = v_i, X_j = v_j, \dots\}$,
- ▶ **stan zgodny** – stan nie naruszający żadnego ograniczenia,
- ▶ **stan pełny** – określający wartości wszystkich zmiennych,
- ▶ **cel** – stan pełny i zgodny,
- ▶ dodatkowo, możliwa **maksymalizacja** funkcji celu.

- ▶ Mapa i graf ograniczeń:



- ▶ Stany, ograniczenia, cel, koszt ścieżki...
- ▶ Naturalne podejście inkrementacyjne.

- ▶ Dziedziny skończone i nieskończone, dyskretne i ciągłe.
- ▶ Języki dla ograniczeń.
- ▶ Ograniczenia liniowe, programowanie liniowe.
- ▶ Ograniczenia nieliniowe – znacznie trudniejsze.
- ▶ Liczba zmiennych objętych ograniczeniem: 1, 2, więcej (wszystkie różne, N spośród M, kryptarytmy, sudoku).
- ▶ Kryptarytmy (ten pierwszy z 1924 r.):

$$\begin{array}{r} \text{S E N D} \\ + \text{M O R E} \\ \hline \text{M O N E Y} \end{array}$$

$$\begin{array}{r} \text{U S A} \\ + \text{U S S R} \\ \hline \text{P E A C E} \end{array}$$

$$\begin{array}{r} \text{S E R C E} \\ + \text{S E R C E} \\ \hline \text{M I Ł O Ś Ć} \end{array}$$

- ▶ Zadania typu: pięć osób pochodzących z pięciu różnych krajów interesuje się pięcioma różnymi dyscyplinami sportu i uwielbia pięć różnych potraw itd.
- ▶ Ograniczenia–preferencje, np. przy układaniu planów zajęć.

- ▶ Problemy z ograniczeniami są **przemienne** – kolejność wiązania zmiennych jest bez znaczenia.
- ▶ Podejście inkrementacyjne.
- ▶ Idea: w danym węźle drzewa (albo i na danej głębokości) wiążemy **jedną zmienną**.
- ▶ Szukanie z nawrotami to szukanie **w głąb** w takim drzewie, z kontrolą ograniczeń.
- ▶ Szukanie „**na ślepo**” – mało efektywne.
- ▶ Możliwość usprawnień **heurystycznych**:
 - kolejność zmiennych i ich wartości,
 - konsekwencje przypisań dla innych zmiennych,
 - unikanie takich samych niepowodzeń.

- ▶ Przykład Australii – po przypisaniu WA=red oraz NT=green lepiej zająć się SA niż Q.
- ▶ Heurystyka **MRV** (ang. *minimum remaining values*) – wybieraj zmienną **z minimalną liczbą dozwolonych wartości**.
- ▶ **Stopień zmiennej** – liczba ograniczeń, w których zmienna występuje (z innymi, nie przypisanymi jeszcze zmiennymi) – najpierw zmienne o maksymalnym stopniu.
- ▶ Heurystyka **najmniej ograniczającej wartości** (ang. *least-constraining value*) – najpierw wartości, które eliminują najmniej możliwości innym zmiennym.

Problem	Nawroty	N.+MRV	FC	FC+MRV	MC
USA	(>1M)	(>1M)	2K	60	64
n-hetmanów	(>40M)	13,5M	(>40M)	817K	4K
Zebra	3859K	1K	35K	0,5K	2K

- ▶ Testowanie możliwości eliminacji z wyprzedzeniem (ang. *forward checking*).

	WA	NT	Q	NSW	V	SA	T
Initial domains	R G B	R G B	R G B	R G B	R G B	R G B	R G B
After $WA=red$	Ⓡ	G B	R G B	R G B	R G B	G B	R G B
After $Q=green$	Ⓡ	B	Ⓢ	R B	R G B	B	R G B
After $V=blue$	Ⓡ	B	Ⓢ	R	Ⓟ		R G B

- ▶ Niektóre gałęzie można wcześniej odciąć
- ▶ Zależności wyższych rzędów
 - $WA=R$, $Q=G$ pozostawia $NT=SA=B$,
 - parami różne.
- ▶ niesprzeczność połączeń (ang. *arc consistency*) – trzeba uważać na złożoność!
- ▶ Kontrola niesprzeczności na początku procesu i w trakcie.

- ▶ **Pełna reprezentacja i zmiany** by spełniać ograniczenia
 - zmiana wartości **pojedynczych** zmiennych,
 - zamiana wartości **dwóch** zmiennych, itp.
- ▶ Naturalna heurystyka: wybór **wartości o jak najmniejszej liczbie konfliktów** (ang. *min-conflicts*).




Prototype: *MinConflicts(CSP, H, N)*

Input: Problem CSP, miara min-conflicts H, liczba N iteracji.

Output: Stan lokalnego minimum.

- ① $\text{stan} \leftarrow$ (losowy pełny) stan początkowy
- ② **for** $t = 1$ **to** N **do**
 - ① **if** stan jest rozwiązaniem **then return** stan
 - ② $X \leftarrow$ wylosowana zmienna z konfliktem
 - ③ $Z \leftarrow$ zmiana X minimalizująca miarę H
 - ④ $\text{stan} \leftarrow$ stan po zmianie Z
- ③ **return** porażka

- ▶ Dla hetmanów niemal niezależność od rozmiaru – nawet **milion hetmanów w 50 krokach**.
- ▶ Planowanie tygodnia obserwacji teleskopu Hubble’a – **redukcja czasu obliczeń z 3 tygodni do 10 minut**.




- ▶ Odpowiednie **w planowaniu**, gdy dochodzą drobne zmiany.

- ▶ Środowiska **wieloagentowe ze współzawodnictwem**.
- ▶ Szukanie z **przeciwnikiem**/oponentem/adwersarzem (ang. *adversarial search*).
- ▶ **Deterministyczne, w pełni obserwowalne środowisko**, w którym agenty/agenci działają naprzemiennie.
- ▶ Gry z **zerowym bilansem** - ktoś wygrywa, ktoś przegrywa.
- ▶ **Definicja** problemu gry z przeciwnikiem:
 - stan początkowy,
 - funkcja następnika,
 - test zakończenia gry,
 - funkcja użyteczności.
- ▶ Optymalna strategia – wartość minimax (MM):

$$MM(n) = \begin{cases} \text{użyteczność}(n) & \text{jeśli } n \text{ jest końcowy} \\ \max_{s \in \text{Następniki}(n)} MM(s) & \text{jeśli } n \text{ jest typu MAX} \\ \min_{s \in \text{Następniki}(n)} MM(s) & \text{jeśli } n \text{ jest typu MIN} \end{cases}$$

Drzewo gry:



- Złożoność $O(b^m)$, gdzie m to maksymalna głębokość rozwijanych węzłów.

Drzewo gry dla 3 graczy:


to move

A







B

C

A



- ▶ Możliwość **współpracy** dwóch graczy **przeciwko** trzeciemu.
- ▶ Możliwość współpracy w grach dla dwóch graczy, gdy **niezerowy bilans**.



► Parametry:

- α – maksymalna wartość zaobserwowana na ścieżce dla MAX,
- β – minimalna wartość zaobserwowana na ścieżce dla MIN.

► Parametry są **aktualizowane** w trakcie szukania.

► **Kolejność analizy następników** wpływa na efektywność metody.

► Przy **optymalnej** kolejności rozwijanych jest $O(b^{\frac{m}{2}})$ węzłów – czynnik rozgałęzień $\sqrt{b}$ zamiast b .

► Przy **losowej** kolejności – ok. $O(b^{\frac{3m}{4}})$ węzłów.



► Dla szachów, **proste heurystyki porządkujące** (najpierw bicia, potem zagrożenia, ruchy naprzód, ruchy wstecz) osiągają wynik 2 razy optymalne $O(b^{\frac{m}{2}})$, dodatkowe techniki jeszcze bardziej zbliżają wynik do optymalnego.

- ▶ Nawet z obcinaniem $\alpha - \beta$, **koszty szukania są zwykle zbyt duże**, by szukać głęboko.
- ▶ **Obcinanie poddrzew** – test obcięcia zamiast testu stanu końcowego.
- ▶ **Miary oceny stanu gry** – generowanie cech i ich kombinacje liniowe i nieliniowe
 - przykład **szachów**: punkty dla figur (pion 1, koń i goniec po 3, wieża 5, hetman 9), – nie zawsze prawdziwe relacje, np. pion za chwilę zostanie zmieniony w hetmana,
 - **brydż**: punkty w kartach ściśle determinują reguły licytacji.
- ▶ Ocena nie powinna być kończona w pozycji **o dużej aktywności/zmienności**.
- ▶ **Efekt horyzontu** – gracz może odsunąć w czasie przykre konsekwencje (poza horyzont szukania), prowadząc do niewłaściwej oceny
 - przykład **szachów**: można bronić się przed stratą wielokrotnym szachowaniem.

Gry z elementami losowymi



- **Losowość** niezależna od graczy (np. rzut kostką).
- **Tryktrak** (ang. *backgammon*) – najpierw rzut dwiema kostkami, potem ruch zależny od wyniku losowania.
- Drzewa szukania wzbogacone o **poziomy losowe**.
- **Wartość oczekiwana** kryterium *minimax* (*expectiminimax*).



- Modyfikacje obcinania $\alpha - \beta$.

Labirynt można postrzegać jako graf:

- ▶ węzły to pomieszczenia/komórki labiryntu,
- ▶ krawędzie to połączenia między komórkami (brak ścian)

Wówczas:

labirynt = drzewo rozpinające grafu

Wystarczy użyć znanych algorytmów:

- ▶ zrandomizowane szukanie w głąb
- ▶ zrandomizowany algorytm Kruskala
- ▶ zrandomizowany algorytm Prima
- ▶ algorytm Wilsona
 - dodajemy jedną losowo wybraną komórkę do labiryntu
 - dopóki istnieje komórka poza labiryntem
 - losujemy komórkę spoza labiryntu
 - generujemy losową ścieżkę aż do napotkania komórki labiryntu (usuwamy ewentualne pętle)
 - dodajemy ścieżkę do labiryntu

- ▶ metoda rekurencyjnych podziałów
 - dzielimy prostokątny obszar cięciem poziomym i pionowym
 - losowe 3 z 4 powstałych (z krzyżowania się) odcinków przerywamy (robimy przejścia)
- ▶ wykorzystanie automatów komórkowych

Obciążenie (bias) metod

- ▶ w głąb – długie korytarze
- ▶ Prima i Kruskala – przeciwnie
- ▶ Wilsona – brak obciążenia

- ▶ Proceduralne generowanie zawartości - *ang. procedural content generation* (PCG)
- ▶ Szum Perlina
 - https://en.wikipedia.org/wiki/Perlin_noise
 - <https://mrl.nyu.edu/~perlin/noise/>
 - <https://pierpaololucarelli.com/2018/02/09/java-perlin-noise-visualisation/>
 - <https://www.ronja-tutorials.com/2018/09/15/perlin-noise.html>
 - <https://flafla2.github.io/2014/08/09/perlinnoise.html>
 - <https://medium.com/100-days-of-algorithms/day-88-perlin-noise-96d23158a44c>
 - <https://www.youtube.com/watch?v=MJ3bvCkHJtE>

- ▶ <https://natureofcode.com/book/chapter-7-cellular-automata/>
- ▶ https://en.wikipedia.org/wiki/Conway's_Game_of_Life
- ▶ https://en.wikipedia.org/wiki/Life-like_cellular_automaton
- ▶ <https://gamedevelopment.tutsplus.com/tutorials/generate-random-cave-levels-using-cellular-automata--game>
- ▶ <https://blog.jrheard.com/procedural-dungeon-generation-cellular-automata>

Inspiracje biologiczne

- ▶ **mrówki** – oznaczanie dróg **feromonami**;
- ▶ **pszczoły** – zwiadowcy i ich **tańce** (ang. *waggle dance*);
- ▶ **bakterie** – **chemotaksja** dodatnia i ujemna (poruszanie się w kierunku rosnącego/malejącego gradientu stężeń bodźców chemicznych);
- ▶ **ptaki, ryby** – **synchronizacja** poruszania się stada/ławicy;
- ▶ **termity** – wyrafinowane **struktury** termitier (liczne komory, w tym komnata królewska, kanały wentylacyjne), **sortowanie** larw według wieku/rozmiaru.

Popularne algorytmy:

- ▶ Optymalizacja **rojem cząstek** (ang. *Particle Swarm Optimization*)
- ▶ Systemy **mrówkowe**
- ▶ Algorytmy **pszczele**
- ▶ Optymalizacja na wzór **kolonii bakterii** (ang. *Bacterial Foraging Optimization Algorithm*)
- ▶ Algorytmy stada – Reynolds' boids

Idea PSO

- ▶ Pewna liczba cząstek **poszukuje** atrakcyjnych rozwiązań w przestrzeni.
- ▶ **Położenie cząstki** w przestrzeni to jedno z możliwych rozwiązań.
- ▶ Na początku **losowe** pozycje.
- ▶ **Pozycja** w kolejnej iteracji zależy od:
 - Wektora **prędkości** tej cząstki,
 - **Najlepszego rozwiązania** znalezionego przez **tę cząstkę**,
 - **Najlepszego rozwiązania globalnie**, tj. znalezionego przez którąkolwiek cząstkę.
- ▶ Z czasem cząstki **zbiegają** do optimów funkcji oceny rozwiązań.

```
1  $p^{best} \leftarrow \text{null};$ 
2 for  $i = 1..size$ 
3    $v_i \leftarrow \text{RandomV}()$ 
4    $p_i^{best} \leftarrow p_i \leftarrow \text{RandomP}()$ 
5   if  $p^{best} = \text{null}$  or  $\text{Cost}(p_i^{best}) < \text{Cost}(p^{best})$ 
6      $p^{best} \leftarrow p_i^{best}$ 
7 while  $\text{!ShouldStop}()$ 
8   for  $i = 1..size$ 
9      $v_i \leftarrow v_i + c_1 * r_1 * (p_i^{best} - p_i) + c_2 * r_2 * (p^{best} - p_i)$ 
10     $p_i \leftarrow p_i + v_i$ 
11    if  $\text{Cost}(p_i) \leq \text{Cost}(p_i^{best})$ 
12       $p_i^{best} \leftarrow p_i$ 
13      if  $\text{Cost}(p_i) \leq \text{Cost}(p^{best})$ 
14         $p^{best} \leftarrow p_i$ 
15 return  $p^{best}$ 
```

c_1 i c_2 to zadane współczynniki,

r_1 i r_2 to losowe wartości z rozkładu jednostajnego na $[0, 1]$.

Uwagi

- ▶ Zwykle **mała liczba cząstek** (20–40).
- ▶ Wartości c_1 i c_2 zwykle w zakresie $[0, 4]$.
- ▶ Różne **kryteria stopu**:
 - liczba **iteracji**,
 - liczba ostatnich **iteracji bez poprawy**.
 - ...
- ▶ Ograniczenia **prędkości** (nominalne, bezwładność).
- ▶ Ograniczenia **przestrzeni**.

Idea systemów mrówkowych

- ▶ Na początku mrówki chodzą **po losowych ścieżkach**.
- ▶ Mrówka, która znajduje **pożywienie**, wraca do mrowiska **znacząc teren feromonami**.
- ▶ Feromony z czasem **wyparowują**.
- ▶ Mrówki **wyczuwają feromony** i **preferują** chodzenie oznaczonymi ścieżkami.

Uogólnienie na użytek rozwiązywania zadań

- ▶ **Minimalizacja kosztu rozwiązania** uwzględniającego informacje **heurystyczne** (strategia podążania do celu) i **historyczne** (preferowanie ścieżek, które w przeszłości okazywały się dobre).
- ▶ Rozwiązania są konstruowane z **komponentów** narastająco.
- ▶ Dane historyczne są **aktualizowane** w każdym kroku, **proporcjonalnie** do jakości rozwiązań, w których występują oceniane komponenty.

► Pseudokod algorytmu:

```
1  $S_0 \leftarrow \text{RozwiązanieHeurystyczne}()$ 
2  $S^{best} \leftarrow S_0$ 
3 feromony  $\leftarrow \text{Feromony}(S_0)$ 
4 while !ShouldStop()
5     for  $i = 1..size$ 
6          $S_i \leftarrow \text{RozwiązanieProbabilistyczne}(\text{feromony}, \alpha, \beta)$ 
7         if  $\text{Cost}(S_i) \leq \text{Cost}(S^{best})$ 
8              $S^{best} \leftarrow S_i$ 
9         feromony  $\leftarrow \text{ZanikFeromonów}(\text{feromony}, \rho)$ 
10    for  $i = 1..size$ 
11        feromony  $+= \text{Feromony}(S_i)$ 
12 return  $S^{best}$ 
```

- ▶ α i β to współczynniki sterujące wpływem przesłanek heurystycznych i historycznych na prawdopodobieństwo wyboru danego składnika:

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

gdzie $\tau_{i,j}$ to ilość feromonów krawędzi (i,j) , a $\eta_{i,j}$ to ocena heurystyczna tej krawędzi (np. odwrotność odległości pomiędzy miastami w problemie komiwojażera).

- ▶ $\rho \in (0,1)$ to współczynnik zaniku feromonów:

$$\tau_{i,j} \leftarrow (1 - \rho)\tau_{i,j}.$$

- ▶ Dla zróżnicowania zbioru rozwiązań można dodatkowo zmniejszać ilość feromonów dla ścieżek wybranych w kolejnych rozwiązaniach probabilistycznych.

Idea algorytmów pszczelich

- ▶ Pszczoły-zwiadowcy
 - szukają bogatych w nektar obszarów (nawet ponad 10km od ula),
 - gdy znajdą, wracają do ula i specyficznym tańcem (ang. *waggle dance*) zachęcają pszczoły-robotnice do podążenia za nimi w znalezione miejsce.
- ▶ Pszczoły-robotnice oceniają tańce zwiadowców i podążają za najatrakcyjniejszymi tancerzami.
- ▶ Tańce muszą być „proporcjonalne” do atrakcyjności odnalezionych zasobów.

Algorytmy pszczele dla minimalizacji funkcji

- ▶ Poszukiwanie atrakcyjnych obszarów (ang. *exploration*) – funkcja zwiadowców.
- ▶ Szczegółowe eksplorowanie znalezionych jako atrakcyjne obszarów (ang. *exploitation*) – funkcja robotnic.
- ▶ Pewna liczba pszczół/agentów cały czas poszukuje nowych obszarów, reszta je eksploruje.

Pseudokod algorytmu:

```
1 populacja ← PopulacjaPoczątkowa()
2 while !ShouldStop()
3   Oceń(populacja)
4   najlepszy ← Najlepszy(populacja)
5   następnaGeneracja ←  $\emptyset$ 
6   foreach Obszar  $\in$  NajlepszeObszary(populacja, ileObszarów)
7     sąsiedztwo ← rozwiązania w sąsiedztwie Obszaru
8     następnaGeneracja ← następnaGeneracja  $\cup$  {Najlepszy(sąsiedztwo)}
9   następnaGeneracja ← następnaGeneracja  $\cup$  Losowe()
10  populacja ← następnaGeneracja
11 return najlepszy
```

Idee Bacterial Foraging Optimization Algorithm (BFOA)

- ▶ Naśladowanie poszukiwania żywności przez bakterie *escherichia coli* i *myxococcus xanthus*.
- ▶ **Chemotaksja** – poruszanie się w kierunku rosnącego/malejącego gradientu stężeń bodźców chemicznych.
- ▶ Bakterie wydzielają do środowiska **wabiące** lub **odpychające** substancje chemiczne.
- ▶ Witki umożliwiają poruszanie się **chaotyczne** lub **płynne, ukierunkowane**.
- ▶ Interakcje między komórkami pozwalają im gromadzić się przy pożywieniu lub odpychać się nawzajem.

Idee algorytmu

- ▶ Komórki poruszają się stochastycznie lub zbiorowo w kierunku optimum.
- ▶ Podstawowe zasady:
 - chemotaksja,
 - reprodukcja (z naturalną selekcją),
 - eliminacja i rozpraszanie się – niektóre komórki giną, inne się pojawiają w losowych miejscach
- ▶ Miara interakcji komórki:

$$g(cell_k) = \sum_{i=1}^S d_{attr} \times e^{-w_{attr} \times \sum_{m=1}^P (cell_{k,m} - cell_{i,m})^2} \\ + \sum_{i=1}^S h_{repel} \times e^{-w_{repel} \times \sum_{m=1}^P (cell_{k,m} - cell_{i,m})^2}$$


niższy koszt komórki (rozwiązania).

Pseudokod algorytmu:

```
1  populacja  $\leftarrow$  PopulacjaPoczątkowa()
2  for  $i = 1..N_{ed}$ 
3      for  $j = 1..N_{re}$ 
4          for  $k = 1..N_{ch}$ 
5              ChemotaksjaPływanie(populacja)
6              foreach kom  $\in$  populacja
7                  if Cost(kom)  $\leq$  Cost(najlepsza)
8                      najlepsza  $\leftarrow$  kom
9              wybrane  $\leftarrow$  ZdrowszaPołowa(populacja)
10             populacja  $\leftarrow$  2 $\times$ wybrane
11         foreach kom  $\in$  populacja
12             if Rand()  $\leq p_{ed}$ 
13                 kom  $\leftarrow$  LosowaKomórka()
14 return najlepsza
```

- ▶ Oba systemy:
 - *opisują niepewność liczbami z zakresu $[0, 1]$*
 - *działają na zbiorach i formułach logicznych z zachowaniem zasad łączności, przemienności i rozdzielności*
- ▶ Rozmycie zaczyna się, gdy $A \cap A^c \neq \emptyset$
- ▶ Czy w lodówce jest jabłko?
 - *z prawdopodobieństwem 50%*
 - *jest pół jabłka*
- ▶ Niedokładny owal to
 - *prawdopodobnie elipsa czy rozmyta elipsa?*
- ▶ Łysy czy nie łysy?
- ▶ Biedny, bogaty, bardzo bogaty?

- ▶ Zbiory rozmyte jako funkcje: $A \equiv m_A : X \rightarrow [0, 1]$
- ▶ Zbiór rozmytych podzbiorów zbioru $X = \{x_1, \dots, x_n\}$ to kostka $F(2^X) = I^n$



- ▶ Środek jest maksymalnie rozmyty:
 $M = M \cap M =$
 $M \cup M = M^c$
- ▶ Przykład:
 $X = \{x_1, x_2\}$
 $A = (\frac{1}{3}, \frac{3}{4})$


Operacje na zbiorach rozmytych:

$$m_{A \cap B} \stackrel{\text{def}}{=} \min(m_A, m_B)$$

$$m_{A \cup B} \stackrel{\text{def}}{=} \max(m_A, m_B)$$

$$m_{A^c} \stackrel{\text{def}}{=} 1 - m_A$$

$$A \subseteq B \stackrel{\text{def}}{\Leftrightarrow} \forall_{x \in X} m_A(x) \leq m_B(x)$$



Często używana notacja zbiorów rozmytych ($\sum$, $\int$ i $/$ to tylko symbole, nie oznaczają znanych matematycznych operacji!):

$$A = \begin{cases} \sum_X m_A(x_i)/x_i & \text{dla dyskretnego zbioru } X \\ \int_X m_A(x)/x & \text{dla ciągłego zbioru } X \end{cases}$$

Dla zbiorów dyskretnych:

$$A = \{0.3/a, 0.5/b, 0.9/c\}$$


$$B = \{0/a, 0.5/b, 1/c\}$$

$$A \cap B = \{0/a, 0.5/b, 0.9/c\}$$

$$A \cup B = \{0.3/a, 0.5/b, 1/c\}$$

$$A^c = \{0.7/a, 0.5/b, 0.1/c\}$$

Dla zbiorów ciągłych:




Popularne funkcje przynależności




trójkątna

$$\max \left(\min \left(\frac{x-a}{b-a}, \frac{c-x}{c-b} \right), 0 \right)$$




trapezowa

$$\max \left(\min \left(\frac{x-a}{b-a}, 1, \frac{d-x}{d-c} \right), 0 \right)$$




sinusoidalna

$$\begin{cases} \sin(ax - b), & \frac{b}{a} \leq x \leq \frac{\pi + b}{a} \\ 0, & \text{w przec. wyp.} \end{cases}$$




gausowska

$$e^{-\left(\frac{x-c}{\sigma}\right)^2}$$




dzwonowa

$$\frac{1}{1 + \left| \frac{x-c}{a} \right|^{2b}}$$



sigmoidalna

$$\frac{1}{1 + e^{-a(x-c)}}$$



- ▶ Systemy rozmyte (rozmyte pamięci asocjacyjne, ang. fuzzy associative memories, FAM) to transformacje $S : I^n \rightarrow I^p$.
- ▶ Równoległe przetwarzanie m reguł rozmytych $(A_1, B_1), \dots, (A_m, B_m)$.
- ▶ Reguły rozmyte (A, B) to pary zbiorów rozmytych, które można czytać jako:
Jeżeli X jest A to Y jest B .
- ▶ Wejście aktywuje odpowiednio każdą regułę (A_i, B_i) i jest mapowane na wyjście B'_i (częściowo aktywowane B).
- ▶ Ostateczne wyjście jest ważoną sumą

$$B = w_1 B'_1 + \dots + w_m B'_m,$$


gdzie w_i to wagi odpowiadające wiarygodności reguły, jej sile asocjacji itp.

- Wyjście jest zwykle „wyostrzane” do pojedynczej wartości rzeczywistej y_j .


- najprostsze wyostrzanie – wybór $y_{\max}$ t. że

$$m_B(y_{\max}) = \max_{1 \leq j \leq m} m_B(y_j)$$

- wyostrzanie jako środek masy: $y_j^c = \frac{\sum_{j=1}^p y_j m_B(y_j)}{\sum_{j=1}^p m_B(y_j)}$



- Kwantyzacja wejść i wyjść – przykład sterowania sygnalizacją świetlną:



- Proste reguły asocjacyjne: (Heavy, Longer)

► Zmienne rozmyte:

θ - odchylenie

$\Delta\theta$ - prędkość kątowa

v - prąd silnika

► Kwantyzacja wejść i wyjścia:

NL - negative large

NM - negative medium

NS - negative small

ZE - zero

PS - positive small

PM - positive medium

PL - positive large

► Reguły to trójki zmiennych: (NM, ZE; PM), (ZE, ZE; ZE).

		θ						
$\Delta\theta \backslash \theta$		NL	NM	NS	ZE	PS	PM	PL
$\Delta\theta$	NL				PL			
	NM				PM			
	NS				PS	NS		
	ZE	PL	PM	PS	ZE	NS	NM	NL
	PS			PS	NS			
	PM				NM			
	PL				NL			

Przykład odwróconego wahadła

