

## Wykład 4 Taksonomia metaheurystyk - notatki

### Serializacja przestrzeni

Przebieg algorytmu serializującego przestrzeń rozpoczyna się od inicjacji loga (w notacji zapisywany jako: 'H' - historia), który jest zapisem dotychczas odwiedzonych elementów przestrzeni przeszukiwań. Zatem log jest wynikiem serializacji przestrzeni. Po inicjacji loga wybierane są kolejne elementy z loga (przy pomocy pewnych dodatkowych informacji) i generowane następane elementy. Algorytm kończy się gdy zostanie spełnione kryterium zatrzymania

### Operator zagregowany

Składa się z trzech elementów funkcyjnych i pamięci. Pamięć (nazywana dalej modelem) to stan wewnętrzny operatora zagregowanego. Elementy funkcyjne:

- operator selekcji - procedura, która polega na udostępnieniu pewnych punktów z przestrzeni przeszukiwań, które wcześniej już były w logu. Jest operacją, która nie dodaje żadnych nowych punktów a jedynie filtruje punkty z loga, wg. reguł metody metaheurystycznej i zawartości modelu.
- operator wariacji - generuje nowe punkty, które później zostaną zapisane do loga i ocenione, a w następnym kroku staną się częścią historii. Punkty są generowane w kontekście zbioru udostępnionego w selekcji oraz zawartości modelu. Przez wariację przetwarzane są jedynie punkty pobrane z historii przez selekcję.
- adaptacja modelu - model jest uwarunkowany tym co się wydarzyło w historii i obecnie. Jest potrzebny po to, aby w wygodny sposób reprezentować informacje, które i tak są dostępne w historii. Nie jest elementem niezbędnym, jednak wprowadza się go ze względów praktycznych. Jest pewnym rodzajem pamięci, można w nim zapisać jakiś punkt, np. najlepszy dotychczas, aby w selekcji i wariacji łatwo do niego sięgnąć zamiast przeglądać od nowa cały log. W momencie wygenerowania nowego punktu, który będzie lepszy od zapisanego następuje zmiana w modelu.

Operator zagregowany jest wykonywany iteracyjnie (pętla, która kręci się i generuje nowe punkty), do momentu aż zadziała kryterium zatrzymania, które jest kombinacją kryterium zewnętrznego (wynika z dodatkowych warunków zadania) i wewnętrznego (wynikające z

istoty metody heurystycznej). Na wykładzie najczęściej nie będziemy się zajmować kryterium zatrzymania, chyba że jest ono wewnętrzne.

Dla zewnętrznego obserwatora metoda przeszukiwania to proces iteracyjny, który wydłuża zbiór punktów, które zostały przejrane, pochodzących z przestrzeni przeszukiwań.

Na podstawie przejranych punktów z historii operator zagregowany generuje nowe punkty, które będą poddane ocenie poprzez metodę ewaluacji.

Na startcie musimy zasilić operator zagregowany początkową sekwencją (początkowy zbiór punktów umieścić w logu tak żeby operator zagregowany miał na podstawie czego wnioskować).

### **Stan przeszukiwania**

Na stan przeszukiwania składa się wewnętrzny stan operatora zagregowanego (model) i stan kolejki (loga).

### **Cechy metod przeszukiwania**

Wprowadzane po to, by móc charakteryzować metody metaheurystyczne pod względem organizacji poszczególnych elementów operatora zagregowanego.

- Poinformowanie -
  - jeżeli, którykolwiek element operatora zagregowanego uwzględni fakt zdefiniowania funkcji celu, to cały operator zagregowany jest poinformowany. Metoda poinformowana działa "zawsze tak samo".
- Determinizm -
  - na działanie operatora zagregowanego mogą mieć wpływ dodatkowe czynniki pseudolosowe. Jeżeli ustalimy dwa razy taką samą f.celu i takie same punkty w historii i włączymy operator zagregowany dwukrotnie to jeśli za jednym razem będzie inna sekwencja punktów, niż za drugim to metoda jest niedeterministyczna.
- Typ modelu - Wyróżniamy model pamięciowy i model zagregowany.
  - Model pamięciowy - zawiera indeksy/wskaźniki do punktów z historii. Wpływa na szerokość okna historii, bo jeśli wiemy, że w pamięci mogą być punkty z jakiejś przeszłości, to znaczy że co najmniej takiej będzie wielkości okno historii.
  - Model zagregowany - może zawierać nie tylko indeksy punktów z historii, ale również parametry, które wpływają na działanie metod i mogą być zmienne w

zależności od tego jak się rozwija przeszukiwanie (np. w metodzie symulowanego wyżarzania, w której prawdopodobieństwo akceptacji punktu gorszego zmienia się w czasie i aby móc wyrazić jakoś tę zmienność w czasie, wrzucamy dodatkowy parametr do modelu)

- Rozmiar okna historii (pamiętliwość) -
  - Minimalna liczba punktów historycznych, które trzeba znać, żeby można było z pewnością przewidzieć jakie punkty będą generowane w przyszłości. Np. dla błędzenia przypadkowego rozmiar okna historii jest równy 1, ponieważ wystarczy znać jeden punkt do tyłu, aby móc wyznaczyć następny. Natomiast np. dla stochastycznego algorytmu wspinaczkowego nigdy nie mamy gwarancji, że wygenerujemy wszystkie punkty z sąsiedztwa w związku z tym nie ma naturalnej granicy okna historii (jest nieskończone- nieograniczone). W przypadku klasycznego algorytmu wspinaczkowego (z pełnym sąsiedztwem) rozmiar okna historii wynosi: *liczba sąsiadów + 1*.
- Lokalność przeszukiwań -
  - cecha, która opisuje to w jaki sposób nowe punkty są generowane przez operator zagregowany na podstawie punktów z historii. Oznacza tyle, że nowo generowane punkty nie będą zanadto oddalały się od punktów, które dotychczas zostały obejrzone. Ta właściwość może być dobrze zdefiniowana w odniesieniu do metod deterministycznych (bo dla takich metod możemy coś zagwarantować). Natomiast nie zawsze lokalność cechuje metody niedeterministyczne - zazwyczaj generowane są punkty w pobliżu punktów, które były dotychczas, ale czasem się może zdarzyć że nie (możemy mówić o oddaleniu o jakąś odległość z pewnym prawdopodobieństwem). Lokalność operatora zagregowanego może wynikać z wariacji, stąd możemy się skupić na lokalności jako cesze wariacji. Należy pamiętać jednak że to, że operator zagregowany jest lokalny, nie oznacza, że wariacja też musi być lokalna.
- Miękkość selekcji
  - Szansa tego, że każdy punkt z historii może zostać wybrany przez selekcję. W przypadku metod deterministycznych szansę rozumiemy jako gwarancję, a w przypadku stochastycznych - że dla każdego punkty z historii można wskazać co najmniej jedną sekwencję losową, która zapewni punktowi przejście przez selekcję. Np. metoda błędzenia przypadkowego jest metodą z miękką selekcją. Metoda stochastycznego wzrostu jest metodą z twardą selekcją.

## **Zupełność**

Zupełność - Metoda zupełna to taka, która dowolnie wystartowana kończy się w poszukiwanym ekstremum globalnym. Jeżeli dla danej metody możemy zagwarantować, że wszystkie punkty przestrzeni przeszukiwań zostaną umieszczone w historii wygenerowanych punktów (metoda może zserializować dokładnie całą przestrzeń) to ta metoda jest zupełna. By metoda była zupełna przestrzeń przeszukiwań musi mieć skończoną liczbę elementów. Przykładem metody zupełnej jest  $A^*$ . Często w przypadku metod niedeterministycznej, albo w odniesieniu do zadań scharakteryzowanych w przestrzeniach ciągłych nie da się w ogóle przejrzeć całej przestrzeni, bo jest za duża. W takim przypadku nie można mówić o zupełności, ale można zrobić rozróżnienie na dwa rodzaje metod, które nie są zupełne - o zupełności asymptotycznej lub jej braku.

Asymptotycznie zupełna to taka, w której jeśli odpowiednio długo poczekamy to z coraz większym prawdopodobieństwem dojdziemy z jednego miejsca w dowolne inne (gdy liczba kroków wzrasta do nieskończoności to prawdopodobieństwo nieprzejrzenia jakiegoś zbioru dziedziny dąży do zera). Jeśli rozwiązanie jest reprezentowane za pomocą liczb rzeczywistych (optymalizujemy za pomocą parametrów ciągłych) to prawdopodobieństwo trafienia w punkt wynosi 0. W związku z tym w przypadku takiej reprezentacji rozwiązania interesują nas zbiory punktów przestrzeni przeszukiwań i mówimy o prawdopodobieństwie trafienia w dowolny zbiór.

Każda metoda zupełna jest jednocześnie asymptotycznie zupełna. Jeśli metoda nie jest zupełna ani asymptotycznie zupełna to jest metodą cząstkową.