

Algorytmy zrandomizowane


www.qed.pl/ai/nai2003

PLAN WYKŁADU

- Inne zadania optymalizacyjne
 - grupowanie
- Generowanie liczb losowych
- Metody Monte Carlo i Las Vegas
 - przykłady zastosowań
- Przeszukiwanie losowe
 - metoda tabu
 - wychładzanie

INNE ZADANIA OPTYMALIZACYJNE - GRUPOWANIE

Algorytmy łączące obiekty w większe grupy na podstawie ich wzajemnego podobieństwa (uczenie bez nadzoru).




Kryterium „podobieństwa” obiektów oparte jest na ich wzajemnej odległości.

Zadanie optymalizacyjne: znaleźć taki podział, żeby odległości między obiektami w jednej klasie były jak najmniejsze, a między klasami - jak największe.

Algorytmy grupujące - przykład zastosowania

Zadanie kwantyzacji kolorów: znaleźć takich 16 kolorów, by za ich pomocą jak najwierniej odtworzyć oryginalny, 24-bitowy obrazek.




Zwykle stosowane algorytmy: zbliżone do zachłannych (np. k-means) lub wspinaczki (np. alg. centroidów).

GRUPOWANIE - K-MEANS (PRZYKŁAD ALGORYTMU)


Założenia: mamy podzielić zbiór obiektów na K rozłącznych grup.

1. Znajdujemy K najdalszych punktów i zakładamy tam grupy.
2. Znajdujemy obiekt najbliższy centrum jednej z grup i dołączamy go (**strategia zachłanna**).
3. Powtarzamy czynność 2 do momentu wyczerpania się obiektów.



GRUPOWANIE - ALG. CENTROIDÓW (PRZYKŁAD ALGORYTMU)

- Dzielimy zbiór na K grup w sposób losowy.
- Liczymy środek (centroid) każdej grupy.
- Dokonujemy ponownego podziału obiektów, przypisując je do tej grupy, której środek leży najbliżej.
- Powtarzamy od drugiego kroku póki następują zmiany przyporządkowania.



ALGORYTMY ZRANDOMIZOWANE

Algorytmy, których działanie uzależnione jest od czynników losowych.

- Algorytmy typu **Monte Carlo**: dają (po pewnym czasie) wynik optymalny z prawdopodobieństwem bliskim 1

np. algorytm szukania pokrycia macierzy przez wielokrotny losowy wybór kolejnych kolumn (o ile pokrywają nowe wiersze macierzy)

- Algorytmy typu **Las Vegas**: dają zawsze wynik optymalny, a randomizacja służy jedynie poprawie szybkości działania.

np. zrandomizowany QuickSort

SKĄD WZIAĆ LICZBY LOSOWE

Źródła „prawdziwej” losowości:

- zegar systemowy
- użytkownik (np. czas naciśnięcia klawisza, ruch myszki)
- przyrządy pomiarowe (np. szum wzmacniacza, licznik Geigera obok próbki promieniotwórczej)

W praktyce te źródła losowości służą do inicjowania ciągów liczb pseudolosowych w generatorach programowych.

Przykład:

generator Marsaglii (1991): $x_n = (x_{n-s} + x_{n-r} + c) \bmod M$,
gdzie $c = 1$, jeśli poprzednia suma przekroczyła M , $c = 0$ w p.p.

Np: $x_n = (x_{n-2} + x_{n-21} + c) \bmod 6$, okres: 10^{16}

Np: $x_n = (x_{n-22} - x_{n-43} - c) \bmod 2^{32}-5$, okres: 10^{414}

Generator z niektórych kompilatorów C/C++ (np. GCC):

$x_n = (1103515245 x_{n-1} + 12345) \bmod 2^{32}$

$\text{rand}() = (x_n / 2^{16}) \bmod 2^{15}$

LICZBY LOSOWE O ZADANYM ROZKŁADZIE

- Metoda ogólna: **odwracanie dystrybucyjny**.

Mamy wygenerować zmienną losową z rozkładu o znanej gęstości $f(x)$.

Niech $F(x)$ - dystrybuanta tego rozkładu. Wtedy:


$wynik = F^{-1}(u)$

jest szukaną zmienną losową, o ile u - wartość losowa z przedziału $[0,1)$.


- **Metoda eliminacji:**

Znamy gęstość $f(x)$ na pewnej dziedzinie D , jednak nie znamy F^{-1} . Niech M - ograniczenie górne $f(x)$.

```
repeat
  u1=random(D)
  u2=random(0,M)
until u2<f(u1)
```




PRZYKŁAD - LOSOWANIE PUNKTÓW Z KOŁA



Metoda "biegunowa"

Losujemy współrzędne w układzie biegunowym (kąt i promień) z rozkładu jednostajnego.



Metoda eliminacji

Losujemy punkty z kwadratu i eliminujemy te, które leżą poza kołem.

LAS VEGAS - PRZYKŁADY


RandomQuickSort:

1. Mamy posortować zbiór S . Wybieramy z S losowy x .
2. Dzielimy S na zbiory S_1 - elementów mniejszych, niż x i S_2 - większych.
3. Rekurencyjnie sortujemy S_1 i S_2 .

Średnia złożoność jest taka sama, jak w przypadku deterministycznym. Losowanie zapobiega zbyt częstemu pojawianiu się "złośliwych" danych.

Przykład pokrewny: budowa drzewa binarnego

Przed budową drzewa mieszamy losowo dane wejściowe.



MONTE CARLO

- Metody, które dają z pewnym prawdopodobieństwem dobry wynik
- Prawdopodobieństwo można zwiększać powtarzając obliczenia wielokrotnie
(tej cechy nie mają alg. deterministyczne)
- Algorytmy numeryczne
 - całkowanie
(liczymy średnią wartość funkcji w losowych punktach)
 - sprawdzanie, czy $AB=C$ dla macierzy A, B, C
(zamiast mnożyć A i B , co jest kosztowne, losujemy wektor x i badamy, czy $A(Bx) = Cx$, dla wielu różnych x)

PRZESZUKIWANIE LOSOWE

Najprostsza metoda: z przestrzeni stanów S losujemy wiele obiektów x i wybieramy ten, dla którego $f(x)$ ma wartość największą.

Metoda bardziej złożona: po wylosowaniu np. 1000 obiektów zapamiętujemy 100 najlepszych i kolejnych losowań dokonujemy z “sąsiedztwa” tych 100.

(Przykład - problem komiwojażera: losujemy 1000 dróg, wybieramy 100 najkrótszych, następnie losowo je modyfikujemy, otrzymując kolejne 1000 przykładów itd.)

Metoda hybrydowa: wybieramy 100 najlepszych z 1000 losowych, następnie dla każdego z nich uruchamiamy algorytm wspinaczki.

Metody (często) oparte na sąsiedztwie.