

WYKŁAD 8

Algorytmy zrandomizowane

PLAN WYKŁADU

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

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

SKŁAD WŹRÓDŁA 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): $x_n = (x_{n-5} + x_{n-1} + c) \bmod M$,
gdzie $c = 1$, jeżeli 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}

LICZBY LOSOWE O ZADANYM ROZKŁADZIE

- Metoda ogólna: **odwracanie dystrybuanty**.

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 zwikszać 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 "otoczenia" 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.

MONTE CARLO - PRZYKŁAD

Minimalne pokrycie kolumnowe macierzy zerojedynkowej A .

Algorytm:

- Losujemy permutację (kolejność) kolumn.
- Niech B będzie zbiorem wszystkich kolumn - założymy, że pokrywają one A .
- Usuwamy z B pierwszą kolumnę (według ustalonej kolejności).
- Sprawdzamy, czy wszystkie wiersze nadal są pokryte. Jeśli nie, przywracamy usuniętą ostatnią kolumnę.
- Powtarzamy operacje dla kolejnych kolumn.

Algorytm nie musi dać globalnie optymalnego wyniku - błąd może być dowolnie duży.


Istnieje jednak taka permutacja kolumn, że algorytm znajdzie rozwiązanie optymalne - a więc, czekając odpowiednio długo, zawsze je otrzymamy.

1	1	0	0	0
1	0	1	0	0
1	0	0	1	0
1	0	0	0	1

PRZESZUKIWANIE TABU

Schemat działania: przeglądamy przestrzeń stanów (rozwiązań), przechodząc zawsze do tego sąsiada, dla którego wartość funkcji oceny jest największa (jak w algorytmie wspinaczki), o ile nie znajduje się on na liście punktów zabronionych. Na liście tej przechowujemy k ostatnio odwiedzonych punktów (np. $k=1000$).

Przykład: maksymalizacja funkcji dwuwymiarowej (na siatce o ustalonej dokładności).



Wersja zrandomizowana:


Z prawdopodobieństwem $1/2$ wybieramy najlepszego (dozwolonego) sąsiada, z prawd. $1/4$ - drugiego z kolei, z prawd. $1/8$ - trzeciego itd.

METODA WYCHŁADZANIA

(Simulated annealing)

*Schemat działania: startujemy z losowego punktu, wybieramy **losowo** nowy punkt z sąsiedztwa aktualnego, jeśli ma większą wartość - idziemy tam, jeśli mniejszą - z pewnym prawdopodobieństwem albo tam idziemy, albo testujemy następnego sąsiada.*

```
x0 = Random(X)
do
  x=Random(N(x0))
  if (f(x)>f(x0)) x0=x
  else
    if (Random()<P(x0, x))
      x0=x
while(time_out)
```




TEMPERATURA W ALG. WYCHŁADZANIA

Prawdopodobieństwo akceptacji gorszego stanu:

$$P(x_0, x) = e^{-\frac{|f(x_0) - f(x)|}{T}}$$

gdzie T - pewien parametr ("temperatura")

Prawdopodobieństwo zależy od temperatury (im niższa, tym mniejsze), oraz od spadku wartości funkcji f .



Temperatura zwykle zmniejsza się w czasie.

- Zalety: odporność na maksima lokalne.
- Wady: wolniejsza zbieżność.