

# WYKŁAD

20.05.2015

## ~~Pro~~ Analiza smoothed

Daniel Spielman, Shuanghua Teng

Nagroda w 2008 roku, artykuł z 2004 roku (JACM), STOC 2001.

Nagroda jest za wprowadzenie nowego typu złożoności algorytmu, czegoś pomiędzy złożonością pesymistyczną, a złożonością średnią - złożonością smoothed oraz pokazanie, że złożoność algorytmu sympleks jest wielomianowa.

Algorytm sympleks to praktycznie stosowany alg. rozwiązyujący programowanie liniowe. Jego złożoność pesymistyczna jest wykładnicza, ale w praktyce działa bardzo dobrze.

Ludwie od dawna zastanawiali się dlaczego tak jest, wydaje się, że analiza smoothed udzieliła właściwej odpowiedzi.

Zacznijmy wykład od początku. Będziemy dużo

mówić o algorytmie sympleks, a o analizie smoothed

nieco więcej na końcu.

2008. Problem programowania liniowego:

Zmaksymalizuj:  $b^T x$

dla:  $Ax \leq y, x \geq 0$

Przykład (problem diety)

	ciukry	białka	tłuszcze	witamina	koszt
krakersy chleba	30	5	1,5	10	30
jogurt	10	9	2,5	0	80
tyczka masła orzechowego	6	8	18	6	20
minimalna wymagane	300	50	70	100	

Zmaksymalizuj:

$$30x_1 + 80x_2 + 20x_3$$

dla

$$30x_1 + 10x_2 + 6x_3 \geq 300$$

$$5x_1 + 9x_2 + 8x_3 \geq 50$$

$$1,5x_1 + 2,5x_2 + 18x_3 \geq 70$$

$$10x_1 + 0x_2 + 6x_3 \geq 100$$


$$x_1, x_2, x_3 \geq 0$$

Ogólnie to jest problem bardzo powolny w praktyce.

Ts instancje można przerobić na problem maksymalizacji.

W 1947 roku Dantzig zaproponował algorytm sympleks.

On działa w następujący sposób. Obszar ograniczony nierównościami to pewna wielościan.



Łatwo pokazać, że ~~ma~~ jeśli ~~niektóra~~ jest ~~to~~ maksymalizujemy funkcję liniową, to wówczas maksimum jest przyjmowane w pewnym wierzchołku.

Ponadto nasz wielościan jest wypukły. Jeśli ~~nie~~ ~~niektóry~~ w danym wierzchołku nie jest przyjmowane maksimum globalne, to ma jakiegoś sąsiada, który ma większą wartość funkcji celu. A zatem możemy postąpić w następujący sposób. Zaczynamy w jakimś wierzchołku, jeśli któryś sąsiad ma ~~lepszy~~ większą wartość funkcji celu, to idź tam, a jeśli nie, to już jesteś w maksimum. Pozostaje jeszcze jedno pytanie do doprecyzowania algorytmu: jeśli wielu sąsiadów ma większą wartość funkcji celu, to do którego iść dalej?

Tu mogą być różne taktyki, one są nazywane po angielsku pivoting rules, po polsku nie wiem, ponieważ w reguła pivotowania. Dantzig zaproponował regułę: idź po krawędzi, która idzie najbardziej w kierunku celu.

Można jednak proponować inne reguły. Np. celi ~~z~~  
do zgrania, który ma wartość największą, wartość ~~z~~ funkcji celu.  
Jest też sporo innych.

Tu pojawiają się pewne szczegóły techniczne. Jak znaleźć  
choćby jeden punkt wielościana? W naszej sytuacji to  
jest proste  $(0, 0, \dots, 0)$ , ale ogólnie ~~nie~~ odpowiedź, czy  
wielościan jest niepusty jest ~~ważną~~  $\approx$  równoważną wymaganiom  
programowania liniowego.

Możemy bowiem odpowiedzieć przedmiot: pokazać to!  $\nabla$

Inne techniczne pytanie to: jak znaleźć wierzchołek zgrania?

To już chyba robił poprzedni wykład, ale to chyba nie jest  
ale tu też mogą być szczegóły techniczne.

Albo: jak wielu jest zgraniów.

Mamy więc pytanie: jak długo działa algorytm sympleks w  
pejnym przypadku? Pierwsze pytanie brzmi:  
ile może być wierzchołków w wielościanie w  $\mathbb{R}^d$  danym przez  
 $n$  liniowych ograniczeń?

Pokazać, że może być ich wykładniczo wiele.

Przykładem hiperkocki w  $\mathbb{R}^d$  ma  $2d$  ograniczeń i  $2^d$   
wierzchołków. A jakie jest ograniczenie górne?

Każdy wierzchołek jest wyznaczony przez pewne  $d$  ograniczeń,  
czyli maksymalnie  $\binom{n}{d}$ .

Przez wiele lat ludzie próbowali pokazać, że sympleks działa w czarnie wielomianowym aż wreszcie w 1972 roku Klee i Minty pokazali przykład, w którym działa wykładniczo długo.

Najpierw przeanalizujmy sympleks na szóstymie.  
On robi co najwyżej 3 (logitme d) ruchy więc, że wielkość jest  $2^3 (2^d)$ .



Okazuje się jednak, że jak się nieco zwiększą koszty w d wymiarach, to już jest OK.

Przykład Klee i Minty  
maksymalizuj  $\sum_{j=1}^d 10^{d-j} x_j$

przy ograniczeniach:  $2 \sum_{j=1}^{i-1} 10^{i-j} x_j + x_i \leq 100^{i-1}$  dla  $1 \leq i \leq d$   
 $x_i \geq 0$  dla  $1 \leq i \leq d$


Przeanalizujmy to najpierw dla  $d=2$ .

Mamy:

maks.  $10x_1 + x_2$

przy  $x_1 \leq 1$

$20x_1 + x_2 \leq 100$



Teraz dla  $d=3$

Mamy:


$$\text{maks. } 100x_1 + 10x_2 + x_3$$

przy:

$$x_1 \leq 1$$

$$20x_1 + x_2 \leq 100$$

$$200x_1 + 20x_2 + x_3 \leq 10000$$



chyba

Ogólnie: on robi (czyli 5)

$$2^d - 1 \text{ krawędzi}$$

Można zauważyć Tworo, że gdybyśmy zastosowali inną pivotną, to porównanie od ram do maksimum.

Jednak dla wygody znowu pivotną określane zostają ~~przebiegi~~ w stylu Klee i Minty. Do tej

porównanie otwartym - jest, czy istnieje jakiś deterministyczny reguła pivotowania, przy której algorytm działa w czasie wielomianowym.

To nie znaczy, że nie jest zwany wielomianowy algorytm dla programowania liniowego.

Są znane, przynajmniej dwa.

W 1979 roku Khachiyan wywnioskował tw.

ellipsoid method. Bardziej z grubsza opiera się

ona na tym, że istnieje wielomianowy algorytm znajdowania minimalnej elipsoidy (o min. objętości chyba) zawierającej dany wielokąt. Robimy tak:

- znajdujemy tę minimalną elipsoidę
- tworzymy ją na pot równoległe do funkcji celu
- znajdujemy się tę lepszą potęgę

Okazuje się, że to sensownie działa, ten w każdym kroku polepsza objętość o ileś (chyba).

W 1984 roku Karmarkar wywnioskował tw. interior point method.

To polega bardziej z grubsza na tym, że zamykasz się w kierunku do środka wielokąta. Dodajemy pewną funkcję, która przy brzegu jest bardzo duża, a trochę dalej bardzo mała i odznaczamy wektorem gradientu (jak w metodzie Newtona). Robimy wiele iteracji.

To jest mniej moje wyobrażenie, może to działa nieco inaczej.

Tak, czy inaczej algorytm sympleks okazuje się najlepszy w praktyce.

Luźno mówiąc myślałem o tym. Pokazuje, że w przypadku średnim algorytm działa dobrze (oczekiwana złożoność), ale to nie było traktowane jako dobre wytłumaczenie. Przypadki średni to niekoniecznie przypadki typowy (patrz np. telewizor). Np. Bergwardt mał wyniki

$$O(m^3 d^{\frac{1}{2}-1}).$$


Badano też zwrócić uwagę na regularność i pólnotowanda.

Pokazano cos w stylu ograniczenia  $e^{C\sqrt{d}}$

Była też hipoteza Hirsch'a: maksymalna odległość

~~W~~ ~~post~~ między wierzchołkami to  $n-d$ , ale zostają one  
ofabryfikowane niedawno. Przy czym nawet jej  
poprawność nie tłumaczyłoby wiele.

Temat podjęcie smooth analysis. Idea to: zaburzenie liczo  
wzrost i lekkość średniej.


$$C_{\text{worst}}(n) = \max_{x \in X_n} T(x)$$

$$C_{\text{avg}}(n) = \mathbb{E}_{x \in X_n} T(x)$$

$$C_{\text{smooth}}(n) = \max_{x \in X_n} \mathbb{E}_{\delta \in \Gamma} T(x+\delta)$$

Dla analizy smoothed na algorytmie sympleks uwyto

~~W~~ rozkład gaussowski o średniej 0 i wariancji

$\sigma = \|x\|$ , gdzie  $\sigma$  jest parametrem. Przyjmujemy gęstość tego

WR to jest

$$\frac{1}{\sqrt{2\pi} \cdot \sigma} \cdot e^{-\frac{x^2}{2\sigma^2}}$$


WR<sup>d</sup> to jest

$$\frac{1}{(\sqrt{2\pi} \cdot \sigma)^d} e^{-\frac{\|x\|^2}{2\sigma^2}}$$

Oryginalna praca na 94 stronie, dużo rachunków itd.



W oryginalnej pracy zostało to za rezultatem piętosiannik  
 tzw. shadow vertex. Myśl jest taka:




Idź jakos w kierunku wierz. W  $\mathbb{R}^2$  jest tylko 1 taki kierunek  
 dobry.

Tu bierz jakos wierz i idź tam.

Okazuje się, że wierzchołek w kierunku  
 to prawdziwe wierzchołek.

~~Każdy z takich~~

MS



Pokaż, że złożoność alg. sympleksu przy (czyli) tej regule  
 pinotowania jest wielomianowa od  $n, d, \frac{1}{\sigma}$ .

Intuicja dlaczego to może być prawdziwe jest następująca.

Żeby ten algorytm działał długo, to kąty muszą powoli być duże,  
 wtedy  $\sigma$  może zaskoczyć. Jeśli zrobimy losowe perturbacje, to  
 te kąty nie będą wykładniczo małe.

Spielman i Teng udowodnili następującą

Tw.

Niech  $d \geq 3, n \geq d$ ,  $c, t$  są niezależnymi wektorami w  $\mathbb{R}^d$ ,

$a_1, \dots, a_n$  to gausowskie wektory w  $\mathbb{R}^d$  o wariancji  $\sigma \leq \frac{1}{d \log n}$

o środkach w punktach o normie  $\leq 1$ . Wtedy oczekiwana liczba

wierzchołków w wektora wzdłuż:  $\{x: x^T a_i \leq 1\}$  na  $\text{Span}(t, c)$  to

$$\leq 58888678 n d^3$$

To jeszcze nie daje wystarczającego, bo ~~to jest~~  
~~problem~~. tu  $t$  i  $c$  są ustalone, a potem losujemy  $a_i$ ,  
podczas gdy ~~losujemy~~ u nas jest odwrotnie.

Nie mniej jednak udało im się to doprowadzić do końca.

Zauważaj, że ~~analiza~~ analiza smooth rzeczywiście  
mówi dlaczego to jest praktyczne, dlaczego w praktyce  
działa dobrze. W praktyce dane są nieco zaburzone,  
pewnie o coś w stylu gaussowskiego.

Analiza smoothed była też potęgowana do innych  
rzeczy jak: losowe chodzenie po losowym grafie,  
losowy problem plecakowy, losowe BST (w tym losowe problemy).