

WYKŁAD

4.05.2015

Algorytmy strumieniowe

Nagroda
z 2005 roku,
artykuł z 1999 roku.

Noga Alon, Yoosi Matias, Mario Szegedy

W dzisiejszych czasach jest coraz więcej danych.
Zdarza się, że dane te przychodzą w czasie rzeczywistym
i nie mamy szansy ich wszystkich zapisać na dysku.
Albo mamy, ale to byłoby bardzo drogie, albo nie chcemy.

Przykłady to: ruch w sieci, rezultaty eksperymentów naukowych (z
przebiegiem (dwudziestych procentów całego czasu) itd.

Stąd model strumienia i algorytm strumieniowy.

Zakładamy, że przychodzi do nas ciąg liczb a_1, a_2, \dots, a_m ,
w dane, każde $a_i \in \{1, 2, \dots, n\}$. Zakładamy często, że znamy m ,
ale czasami nie. Typowo chcemy się policytować. Wzrost
wielkości elementów, albo ile ich w ogóle jest, albo jak bardzo
wzrostają częstości.

Oznaczmy $m_i = |\{j : a_j = i\}|$, czyli ile razy wystąpił
element i w ciągu.

Mamy wtedy $m = \sum_{i=1}^n m_i$. Ogólniej interesuje nas

$$F_k = \sum_{i=1}^n m_i^k$$

$$N_p. \quad F_0 = \sum_{i=1}^n m_i^0 \quad \text{to}$$

liczba wszystkich elementów. $F_1 = \sum_{i=1}^n m_i = n.$

$$F_2 = \sum_{i=1}^n m_i^2 \quad \text{odpowiada temu jak}$$

bardzo rzadki jest częstotliwość wszystkich elementów,

to ma związek z tw. suprise index.

Polowyd F_k w pamięci $O(n)$ jest Tardos,

po prostu liczymy wszystkie m_i . Bzdurę się starał

Wczył to w mojej pamięci, bo n jest duże.

Algorytmy będą randomizowane oraz aproksymacyjne.

Artykuł Alona, Matiasa i Szegedy pokazał niektóre

bardzo ładne wyniki i pozwolił podzielić pod dziedzinę.

Teras wiadomo, że:

Tw.

Dla $p \in [0, 2]$ wystarczą $n^{1-\frac{2}{p}}$ pamięć

Dla $p > 2$ $n^{1-\frac{2}{p}}$ pamięć wystarczą i jest potrzebne

Nie wystarczy pokazać AMS, ale pokazać up.

bardzo ładny algorytm dla $p=2$.

Najpierw idea o prostego algorytmu znaczącego

F_0 , nie przez AMS.

Powiedzmy, że chcemy zrobić alg. randomizowany, który z prawd. $1-p$ oblicza F_0 z dokładnością do $(1+d)$.

Najpierw uprościmy problem: dane $T > 0$,

chcemy algorytm, który z prawd. $1-p$:

- odpowiada TAK jeśli $F_0 > (1+d)T$

- odpowiada NIE jeśli $F_0 < (1-d)T$

Jeśli mamy taki, to możemy zapisać wszystkie algorytmy

dla $T=1, 1+d, (1+d)^2, (1+d)^3, \dots, n$

i z danym prawd. dostawiamy obliczoną F_0 z dokładnością do $(1+d)$

Teraz ten algorytm robimy tak:

- losujemy zbiór S t, tzn $\forall i \in S, P(i \in S) = \frac{1}{T}$.

- teraz liczymy przez cały strumień i

liczymy $\sum_{j=1}^m a_j [a_j \in S] =: \text{SUM}$

$$Pr = P[\text{SUM} = 0] = \left(1 - \frac{1}{T}\right)^{F_0}$$

$$\text{Dla d.d. } T \quad \left(1 - \frac{1}{T}\right)^{F_0} = \left(1 - \frac{1}{T}\right)^{T \cdot \frac{F_0}{T}} \approx e^{-\frac{F_0}{T}}$$

Zatem jeśli $F_0 > (1+d)T$, to $\frac{F_0}{T} > 1+d$ (dla małych p może chaciej widać)

$$Pr \approx e^{-\frac{(1+d)T}{T}} = e^{-(1+d)} < \frac{1}{e} < \frac{d}{3}$$

Jeśli $F_0 < (1-d)T$, to

$$Pr \approx e^{-\frac{(1-d)T}{T}} = e^{-(1-d)} > \frac{1}{e} + \frac{d}{3}$$

Można teraz uzyskać odstęp między $\frac{1}{e} - \frac{d}{3}$ a $\frac{1}{e} + \frac{d}{3}$

przez zrobienie tego wiele razy i użycie dehalowacji.

Teraz bardziej konkretnie, pokażemy
oszacowanie w F_2 w $O(\log n)$ pamięci.

Tw.

Dla każdego $\lambda > 0$, $\varepsilon > 0$ istnieje algorytm randomizowany,
który dla ciągu a_1, a_2, \dots, a_m elementów $\{1, 2, \dots, n\}$
oblicza w jednym przebiegu i używając

$$O\left(\frac{\log\left(\frac{1}{\varepsilon}\right)}{\lambda^2} (\log n + \log m)\right)$$

pamięci losowy Y , że $P(|Y - F_2| > \lambda F_2) \leq \varepsilon$.

D-d

$$\text{Niech } \lambda_1 = \frac{16}{\lambda^2}, \lambda_2 = 2 \log\left(\frac{1}{\varepsilon}\right).$$

Idea jest taka.

Stworzymy zmienną losową X , którą będziemy uwiel
policzyć w jednym przebiegu t.j. $E X = F_2$ oraz

$\text{Var } X$ małe. Wtedy X będzie blisko F_2 .

Jednak aby poprawić dokładność zrobimy tak, że

Y to mediana zmiennych $Y_1, \dots, Y_{\lambda_2}$, a

zmienna Y_i to średnia zmiennych $X_{i1}, \dots, X_{i\lambda_1}$, gdzie

każda zmienna X_{ij} ma rozkład taki jak X .

Skupiamy się teraz na X .

Będziemy chcieli policzyć zmienną $Z = \sum_{i=1}^n \varepsilon_i m_i$, gdzie

$P(\varepsilon_i = 1) = P(\varepsilon_i = -1) = \frac{1}{2}$. Idea jest taka, że

ε_i są niezależne, ale nam tak naprawdę będzie zależało tylko,

by były niezależne niezależne.

Bzdurec $X = Z^2$.

Jak wyciagnąć Z ? Przelatujemy po całym

strumieniu i jak widać a_j , to dołączamy

$$Z := Z + \epsilon_{a_j}$$

Pewien problem polega na tym, że w związku z tym musimy

wystrzelać te ϵ_i gdzieś pamiętaąc, a jest ich n

(bo potem bzdurec chcąc ich może być jeszcze var).

Okazuje się, że pomaga nam to, że one mogą być

tylko ciwótkami niezależnymi, więc dany nasz pamiętaąc

je w $O(\log n)$ pamięci. ~~Można~~ ^{Pewnie} pokazujemy na dwuczennych

jak to zrobić.

OK, więc $Z = \sum_{i=1}^n \epsilon_i m_i$, $X = Z^2$. 2-wiel.

Policzmy $\mathbb{E}X$.

$$\mathbb{E}(\epsilon_i \epsilon_j) = 0$$

$$\begin{aligned} \mathbb{E}X &= \mathbb{E}\left(\left(\sum_{i=1}^n \epsilon_i m_i\right)^2\right) = \mathbb{E}\left(\sum_{i=1}^n m_i^2 \epsilon_i^2 + 2 \sum_{1 \leq i < j \leq n} m_i m_j \epsilon_i \epsilon_j\right) = \\ &= \sum_{i=1}^n m_i^2 = F_2. \end{aligned}$$

$\text{Var}(X) = \mathbb{E}X^2 - (\mathbb{E}X)^2$, wyciagnijmy więc $\mathbb{E}X^2$

$$\mathbb{E}X^2 = \mathbb{E}\left(\left(\sum_{i=1}^n \epsilon_i m_i\right)^4\right) = \sum_{i=1}^n m_i^4 + 6 \sum_{1 \leq i < j \leq n} m_i^2 m_j^2$$

A więc $\text{Var}(X) = \left(\sum_{i=1}^n m_i^4\right) + 6 \sum_{1 \leq i < j \leq n} m_i^2 m_j^2 - \left(\sum_{i=1}^n m_i^2\right)^2 = 4 \sum_{1 \leq i < j \leq n} m_i^2 m_j^2$

Wier. Czebyszewa to $P(|X - \mathbb{E}X| > t) \leq \frac{\text{Var} X}{t^2}$

$$\frac{\text{Var} X}{t^2}$$

$$\frac{n}{2 F_2^2}$$

(czyli $n \leq 2 F_2^2$)

A więc ~~Wzrost~~ $E(X_i) = F_2, \text{Var}(X_i) \leq \frac{2F_2^2}{\sigma_1}$

Z Czebyszewa mamy

$$P[|Y_0 - F_2| > \lambda F_2] \leq \frac{\text{Var}(Y_0)}{\lambda^2 F_2^2} \leq \frac{2F_2^2}{\sigma_1 \lambda^2 F_2^2} = \frac{2F_2^2}{\lambda^2 \sigma_1^2 F_2^2} = \frac{1}{\delta}$$

Jest tw. Chernoffa, która mówi (jedną z nich), że

Jeśli $p > \frac{1}{2}$ to pr. sukcesu, to prawd., że w n próbach uda się

będzie $\geq \frac{n}{2}$ sukcesów jest

$$\geq 1 - e^{-\frac{1}{2p} n(p - \frac{1}{2})^2}$$

Jeśli ustawić $p \geq \frac{7}{8}$ i $\sigma_2 = 16 \log(\frac{1}{\epsilon})$ (mówi więcej o $2 \log(\frac{1}{\epsilon})$),

to wystarczy, że

$$P(\geq \frac{7}{8} \text{ sukcesów}) \geq 1 - \epsilon.$$

Jeśli $\geq \frac{7}{8}$ razy bliżej F_2 , to możemy też, stać

$$P(|X - F_2| < \lambda F_2) \geq 1 - \epsilon.$$

c.n.d.

Teraz pokażemy ~~że~~ dwa dolne ograniczenia, bo są bardzo fajne. Bzdurimy konystad ze złożoności komunikacyjnej.

Powiedzmy, że ~~dwie osoby~~ dane f jest funkcją $f: \{0,1\}^n \times \{0,1\}^n \rightarrow \{0,1\}$.

Dwie osoby chcą polowyć $f(x,y), x,y \in \{0,1\}^n$, przy czym

A ma x , a B ma y . Oni mogą sobie przesyłać bity, mogą też

konystad z ~~komunikacją~~. Złożoność komunikacyjna $C_\epsilon(f)$ to

~~liczba~~ oczekiwana liczba bitów, którą muszą przesyłać w najgorszym

przypadku (przy użyciu najlepszego protokołu), tak, by się pomylili z

prawd. $\leq \epsilon$.

Rozważmy konkretną funkcję

$$DIS_n = \{0,1\}^n \times \{0,1\}^n \rightarrow \{0,1\} \text{ t.r.e.}$$

$$DIS_n(x,y) = 1 \text{ jeśli } \text{poprawny } \text{ i } \text{nie } \text{poprawny}$$

~~...~~ $x_i y_i = 1$ dla pierwszego bitu indeksu $i \in \{1, \dots, n\}$.

Jest wynik, że dla każdego $\epsilon < \frac{1}{2}$

$$C_\epsilon(DIS_n) \geq \Omega(n). \text{ Skorzystamy z tego.}$$

Tw.

Dowolny algorytm randomizowany, który dla danego ciągu \sqrt{n} co najwyżej $2n$ elementach ze zbioru $\{1, 2, \dots, n\}$, oblicza liczbę Y t.r.e. $IP(|Y - F_\infty^*| \geq \frac{F_\infty^*}{3}) < \epsilon$, dla $\epsilon < \frac{1}{2}$ musi używać $\Omega(n)$ bitów pamięci.

(F_∞^* to $\max_{1 \leq i \leq n} m_i$, ogólnie $F_p^* = \sqrt[p]{F_p}$, F_∞^* przez dążenie, tzn. $F_p^* \rightarrow F_\infty^*$ w pewnym sensie).

D-d

Przyjmując, że mamy algorytm j.w., który używa Ω bitów pamięci, pokazujemy protokół komunikacyjny, który używa Ω bitów komunikacji dla $DIS_n(x,y)$. Niech $|x|, |y|$ to dłg. ciągów x i y .

Niech A to ciąg $|x| + |y|$ bitów z $\{1, \dots, n\}$ t.r.e. na początku danych

Zauważmy, że elementy j.w. t.r.e. $x_j = 1$, a poza k t.r.e. $y_k = 1$.

$F_\infty^* = 1 \Leftrightarrow DIS(x,y)$ Główna A ma x , więc wartości alg. aproks. na pierwszym $|x|$ elementach

używa A . Ma ten stan w Ω komunikacji pamięci. Wyznacza to do B ,

który kontynuacja, to zna y . ~~...~~ Jeśli B

otrzyma coś $< \frac{4}{3}$ to można znać, że $F_\infty^* = 1$, więc znać $DIS(x,y)$,

jeśli otrzyma coś $> \frac{4}{3} = 2 - \frac{1}{3} \cdot 2$, to znaczy, że $F_\infty^* \geq 2$, więc znaczy $\neg DIS(x,y)$.

Uwaga: Ta technika działa też dla $m \geq 2n$.

Możemy rozważać wgg, w których każdy

wyraz występuje $O(\frac{m}{n})$ lub $\frac{2m}{n}$ razy,

wtedy wyrok przedstawi.

Pokażemy teraz drugie z dolnych ograniczeń.

Mianowicie, deterministyczne algorytmy

radzą sobie dużo gorzej.

Tw.

Dla dowolnego $k \neq 1$ dowolny deterministyczny algorytm, który dla ciągu $\frac{n}{2}$ elementów ze zbioru $\{1, 2, \dots, n\}$

zwraca liczbę Y t.je $|Y - F_k| \leq \frac{1}{10} F_k$

wyżyra $\Omega(n)$ bitów pamięci.

D-d

Niech G będzie rodzajem $t = 2^{\Omega(n)}$ podobnym $\{1, 2, \dots, n\}$,

każdy o mocy $\frac{n}{2}$ t.je precyzyjnie dowolnych dwóch $m \leq \frac{n}{8}$ elementów.

Da się pokazać istnienie takiego rodzaju, podobno standardową

techniką z teorii kodów.

Ustalony det. alg. przybliżający F_k dla $k \neq 1$.

Dla dowolnych $G_1, G_2 \in G$ wiel. $A(G_1, G_2)$ to wiel. $\frac{n}{2}$,

najpierw G_1 , potem G_2 . Algorytm po wczytaniu pierwszych

$\frac{n}{2}$ bitów ma stan pamięci zależny tylko od G_1 .

Jeśli pamięć jest $< \log t$, to z racji niezależności istnieją $G_1, G_2 \in G$

t.je jest one takie same, a więc $A(G_1, G_2) = A(G_2, G_1)$.

Policzmy jednak F_0 i F_k dla $k \geq 2$ dla $A(G_2, G_1)$ i $A(G_2, G_1)$.

$$F_0$$

$$F_k, k \geq 2$$

$$A(G_2, G_1)$$

$$\frac{n}{4}$$

$$2^k \frac{n}{4}$$

$$A(G_2, G_1)$$

$$\geq \frac{3n}{8}$$

$$\leq \frac{n}{2} + 2^k \frac{n}{8}$$

A więc ~~że~~ błąd względny jest $> \frac{1}{10}$ dla przynajmniej jednego z tych przypadków.

$$A \text{ zatem pamięć} \geq \log(t) = \Omega(n).$$

C.n.d.

Teraz kilka prostych ograniczeń dolnych, które może pokazać na dwulicewach.

• Pokazać, że algorytm ~~nie~~ randomizowany, ale dokładny

$$P(Y = F_k) \geq 1 - \epsilon \text{ musi użyć } \Omega(n) \text{ pamięci dla } k \neq 1$$

(dowód idzie tak jak dla przybliżenia F_{∞}^*)

• Pokazuje alg. ^{rand.} przybliżony F_0 z dokład. do $\frac{1}{10} F_0$

z prawd. $\frac{3}{4}$ musi użyć przynajmniej $\Omega(\log n)$ bitych

^{D-d} ^{rand.}

Wiadomo, że złożoność komunikacyjna ~~wszystkich~~ $f(x,y) = 1 \Leftrightarrow x=y$

jest $\Omega(\log n)$. Robimy tak jak w dowodzie powyżej, $A(G_2, G_2) = A(G_2, G_1)$

powinny być wszystkie.

• Pokaż, że ~~F_1~~ przybliżanie losowe F_1 wymaga ~~min~~ $\Omega(\log \log m)$ bitów

(jest min. $\log m$ wziętych odpowiedni, jest $\log \log m$ bitów na wie)

• Pokaż, że ~~przy~~ losowe przybliżanie F_2 wymaga $\Omega(\log n + \log \log m)$ bitów

($\log n$ jeśli dla F_0 , $\log \log m$ jeśli dla F_1)

Teraz zobaczymy jeszcze (jeśli starczy czasu, jeśli nie, to może próbujemy zrobić na dwóch częściach) jak przybliżyć F_k w pamięci $O(n^{1-\frac{1}{k}} \log(nm))$.

~~Tw.~~ Tw.

Dla każdego $k \geq 1$, $\lambda > 0$, $\varepsilon > 0$ istnieje algorytm randomizowany, który dla ciągu a_1, a_2, \dots, a_m elementów $\{1, 2, \dots, n\}$ wylicza jednego przebiegu

$$O\left(\frac{k \log\left(\frac{1}{\varepsilon}\right)}{\lambda^2} n^{1-\frac{1}{k}} (\log n + \log m)\right)$$

bitów pamięci oblicza $\forall t, \text{re}^t P(|Y - F_k| > \lambda F_k) \leq \varepsilon$.

Niech $s_1 = \frac{8kn^{1-k}}{2^2}$, $s_2 = 2 \log\left(\frac{1}{\epsilon}\right)$ (a może tak jak poprzednio $16 \log\left(\frac{1}{\epsilon}\right)$).

Podobnie jak wczesniej algorytm

obliczy Y_1, Y_2, \dots, Y_{s_1} i weźmie Y jako medianę.

Podobnie też Y_0 to średnia z $X_{01}, X_{02}, \dots, X_{0s_2}$,

gdzie wszystkie X_{0j} to niezależne zmienne losowe

o jednakowym rozkładzie, takim jak X .

Pokazujemy teraz jak obliczyć w pamięci $O(\log n + \log m)$

X tzn. $\mathbb{E}X = F_k$, $\text{Var} X$ małe.

Robimy tak: losujemy losowo p ze zbioru $\{1, 2, \dots, m\}$ (jeżeli nie znamy m , to też to się da zrobić).

Mamy więc $a_p = l \in \{1, 2, \dots, m\}$.

Niech $r = |\{q : q \geq p, a_q = l\}|$.

Definiujemy

$$X = m \cdot (r^k - (r-1)^k).$$

Wystarczy pamiętać l ($O(\log n)$ bitów) i r ($O(\log m)$ bitów).

$$\mathbb{E}X = \frac{1}{m} \cdot m \cdot$$

$$(1^k + (2^k - 1^k) + \dots + (m_1^k - (m_1 - 1)^k)) \cdot$$

$$(1^k + (2^k - 1^k) + \dots + (m_2^k - (m_2 - 1)^k)) \cdot$$

$$(1^k + (2^k - 1^k) + \dots + (m_n^k - (m_n - 1)^k)) =$$

$$= \sum_{i=1}^n m_i^k = F_k.$$

$$\text{Var}(X) = E(X^2) - (EX)^2, \text{ policamy wyśc } E(X^2).$$

$$E X^2 = \frac{m^2}{m} \left[(1^{2k} + (2^k - 1^k)^2 + \dots + (m_1^k - (m_1 - 1)^k)^2) + \right. \\ \left. + (1^{2k} + \dots + (m_2^k - (m_2 - 1)^k)^2) + \dots \right. \\ \left. + (1^{2k} + \dots + (m_n^k - (m_n - 1)^k)^2) \right] \leq$$

dla $a > b > 0$

$$a^k - b^k \leq (a-b) \cdot k \cdot a^{k-1}$$

$$(a-b)(a^{k-1} + a^{k-2}b + \dots + ab^{k-2} + b^{k-1})$$

$$\leq (a-b) \cdot k \cdot a^{k-1}$$

$$\leq m \left[(k 1^{2k-1} + k 2^{2k-1} (2^k - 1^k) + \dots + k m_1^{k-1} (m_1^k - (m_1 - 1)^k) + \dots \right] \leq$$

$$\leq m \left[k m_1^{2k-1} + k m_2^{2k-1} + \dots + k m_n^{2k-1} \right] =$$

$$= k m \cdot F_{2k-1} = k F_1 F_{2k-1}$$

Fakt

$$F_1 \cdot F_{2k-1} \leq n^{1-\frac{1}{k}} (F_k)^2$$

Down to 3 link przekształcen.

Zatem

$$\text{Var}(Y_i) = \frac{\text{Var}(X)}{n} \leq \frac{E(X^2)}{n} \leq \frac{k n^{1-\frac{1}{k}} F_k^2}{n}$$

Z Czebyszowa $P[|Y_i - F_k| > \lambda F_k] \leq \frac{\text{Var}(Y_i)}{\lambda^2 F_k^2} \leq$

$$\leq \frac{k n^{1-\frac{1}{k}} F_k^2}{\lambda^2 F_k^2 \cdot n} = \frac{1}{\lambda^2}$$

Poten z Chernoffa tak jak poprzednio.

~~reszta~~

Jesli w nic jest znane, to za
kaidym razem, przy ak z prawd. $\frac{1}{k}$
wybieramy to, zmierzamy do na ak i resetujemy r na 1.

c.n.d.