

Kolmogorovská zložitost

21.11.2013

kompresia jazykov

- $\Sigma = \{0, 1\}$. $f : \Sigma^* \rightarrow \Sigma^*$ je **kompresia jazyka** $L \subseteq \Sigma^*$ ak je one-to-one na L a až na konečne veľa $x \in L$ platí $l(f(x)) < l(x)$
- Funkcia $f, f^{-1} : f(L) \rightarrow L$ pričom $\forall x \in L f^{-1}(f(x)) = x$. Jazyk je **komprimovateľný** v čase $T(n)$, ak existuje kompresia f pre L počítateľná v čase $T(n)$ ktorej inverzná f^{-1} je tiež počítateľná v $T(n)$
- Kompresia f **optimálne komprimuje** L ak $\forall x \in L$ dĺžky n ,

$$l(f(x)) \leq \lceil \log \sum_{i=0}^n d(L^i) \rceil$$

- prirodzená kompresia — **ranking**

$$r_L : L \rightarrow \mathbb{N} \quad \forall x \in L : r_L(x) = \text{index } x \text{ v } L$$

Theorem

Nech A množina. Potom existuje konštanta c a polynóm p tak, že

$$\forall x \in A^{=n} \quad CD^p(x|A^{=n}) \leq 2 \log d(A^{=n}) + 2 \log n + c$$

$$A, d = d(A^{=n})$$

Lemma

Nech $S = \{x_1, \dots, x_d\} \subseteq \{0, \dots, 2^n - 1\}$. Potom $\forall x_i \in S$ existuje prvočíslo $p_i \leq 2dn$ tak, že $\forall j \neq i \quad x_i \not\equiv x_j \pmod{p_i}$. ↪

- $A = S$, $\forall x \in A$ máme p_x

- CD program p pre x

vstup y

if $y \notin A^{=n}$ reject y else if $y = x \pmod{p_x}$ then accept y else reject y

$$l(p) = l(p_x) + l(x \pmod{p_x}) + O(1)$$

$$p \leq 2 \log d(A^{=n}) + 2 \log n + O(1)$$

rovnať dlhé $p_x, x \pmod{p_x}$

akceptuje len x

Thm.

Dôsledok

$A \in P$. Potom existuje polynóm $p \forall x \in A^{=n}$

$$CD^p(x|n) \leq 2 \log d(A^{=n}) + 2 \log n + O(1)$$

$S = \{x_1, \dots, x_d\} \subseteq \{0, \dots, 2^n - 1\}$. $\forall x_i \in S$ existuje prvočíslo $p_i \leq 2dn$ tak, že $\forall j \neq i$
 $x_i \not\equiv x_j \pmod{p_i}$.

- $N = 2^n$
- $\forall x_i \neq x_j \in S$ existuje najvyššie $\log_c N = \log N / \log c$ rôznych prvočísel p takých, že $c \leq p \leq 2c$ a $x_i \equiv x_j \pmod{p}$
- len $d - 1$ dvojíc obsahuje x_i , preto medzi $\frac{(d-1) \log N}{\log c} + 1$ prvočíslami $\exists p_i$, že $\forall j, i \neq j, x_i \not\equiv x_j \pmod{p_i}$
- PrimesNumberThm: $\pi(n) \sim \frac{n}{\ln n}$,
 resp. $\pi(n) = \frac{n}{\ln n} + \frac{n}{(\ln n)^2} + \frac{2!n}{(\ln n)^3} + \frac{3!n}{(\ln n)^4} + O\left(\frac{n}{(\ln n)^5}\right)$
 \hookrightarrow medzi $c, 2c$ je aspoň $\frac{c}{\log c}$ prvočísel
 \hookrightarrow ak $c > (d - 1) \log N$ tak $p_i \leq 2d \log N = 2dn$ □

Theorem

\exists polynóm $p(n)$ taký, že $\forall A$ a dostatočne veľké $n \in \mathbb{N}$, ak $x \in A^{=n}$, tak

$$CD^p(x|A^{=n}, s) \leq \log d(A^{=n}) + \log \log d(A^{=n}) + O(1)$$

pričom $A^{=n}$ je dané ako orákulum, dĺžka $s \sim n \log d(A^{=n})$



$h : \Sigma^n \rightarrow \Sigma^m$ lineárna transformácia daná náhodnou binárnou maticou $R = \{r_{i,j}\}$

$\forall x \in \Sigma^n \quad Rx = y \in \Sigma^m : y_i \equiv (\sum_j r_{i,j}x_j) \pmod 2$

H ..množina kódovacích funkcií.

- Nech $B, C \subseteq \Sigma^n, x \in \Sigma^n$. h separuje x v B ak $\forall y \in B, y \neq x, h(y) \neq h(x)$
- h separuje C v B ak $\forall y \in C$ h separuje y v B
- H separuje C v B ak $\forall x \in C \exists h \in H$ tak, že h separuje x v B .

Lemma (o kódovaní)

$B \subseteq \Sigma^n, d(B) = k, m = 1 + \lceil \log k \rceil$. Existuje množina H m náhodných lineárnych transformácií $\Sigma^n \rightarrow \Sigma^m$ takých, že H separuje B v B .

$B \subseteq \Sigma^n$, $d(B) = k$, $m = 1 + \lceil \log k \rceil$. Existuje množina H m náhodných lineárnych transformácií $\Sigma^n \rightarrow \Sigma^m$ takých, že H separuje B v B

fixneme náhodný reťazec s dĺžky nm^2 : $C(s|B, P, m, n) \geq I(s)$,
 P program na popis s ;

// s reprezentuje H


H separuje B v B SPOROM:

$\exists x \in B$ že žiadne $h \in H$ neseparuje x v B :

$\exists y_1, \dots, y_m \in B$ $h_i(x) = h_i(y_i) \Rightarrow h_i(x - y_i) = 0$

krátky popis s

- index x v B $\log k$
- indexy y_1, \dots, y_m $m \lceil \log k \rceil$
- h_1, \dots, h_m bez "redundantných" stĺpcov $nm^2 - m^2$



$$C(s|B, P, m, n) \leq m^2 n - m^2 + m \lceil \log k \rceil + \lceil \log k \rceil \leq m^2 n - 1$$

\exists polynóm $p(n)$ taký, že $\forall A$ a dostatočne veľké $n \in \mathbb{N}$, ak $x \in A^{=n}$, tak

$$CD^P(x|A^{=n}, s) \leq \log d(A^{=n}) + \log \log d(A^{=n}) + O(1)$$

pričom $A^{=n}$ je dané ako orákulum, dĺžka $s \sim n \log d(A^{=n})$

— H z kódovacej lemy, s popisuje H ; $m = 1 + \lceil \log d(A^{=n}) \rceil$

— $\forall z \in A^{=n} \exists h_i \in H$ separujúce z v $A^{=n}$

— program, kt. z $ih_i(z)$ akceptuje z

$A^{=n}$, s poznáme

■ over, či $x \in A^{=n}$

■ ak $x \in A^{=n}$, $ih_i(z) \rightsquigarrow i, h_i(z)$, nájde h_i

■ vypočíta $h_i(x)$

■ akceptuje z $\Leftrightarrow h_i(x) = h_i(z)$

$$CD^P(z|A^{=n}, s) \leq m + \log m + O(1) = \log d(A^{=n}) + \log \log d(A^{=n}) + O(1)$$



Theorem

Existuje polynóm p , že $\forall A$ a dostatočne veľké n ak $x \in A^{=n}$, tak

$$1 \quad C^P(x|A^{=n}, s, NP^A) \leq \log d(A^{=n}) + \log \log d(A^{=n}) + O(1)$$

$$2 \quad C^P(x|A^{=n}, \Sigma_2^{P,A}) \leq \log d(A^{=n}) + \log \log d(A^{=n}) + O(1)$$

keď $A^{=n}$, NP^A -úplná mn., $\Sigma_2^{P,A}$ -úplná mn. sú orákulá, s je reťazec dĺžky $\sim n \log d(A^{=n})$

$$\Sigma_2^P = NP^{NP} \begin{cases} \Sigma_1^P = NP \\ \Sigma_{i+1}^P = NP^{\Sigma_i^P} \end{cases}$$

$$(1.) \quad C^P(x|A^{=n}, s, NP^A) \leq \begin{cases} CD^q(x) + O(1) \\ CD^P(x|A^{=n}, s) \leq \log d(A^{=n}) + \log \log d(A^{=n}) + O(1) \end{cases}$$

(2.) pomocou orákula **generujeme s**

je $s_1 \dots s_i 1$ prefix H kt. separuje $A^{=n} \vee A^{=n}$?



riedka množina A — $d(A^{\leq n}) \leq n^c + c$

Theorem

Existuje riedky jazyk L taký, že ak L skomprimujeme pomocou pravdepodobnostného polynomiálneho stroja s orákulom pre L , tak kompresná funkcia mapuje reťazce dĺžky n na reťazce dĺžky $n - O(\log n)$.

- L obsahuje jediné nestlačiteľné slovo dĺžky $2^{2^{\dots^2}}$, $I(x) \leq C(x)$
- T pravdepodobnostný orákulový stroj, kt. rozpoznáva L v čase n^k
- kvôli SPORu: existuje kompresia $f : I(f(x)) \leq n - c_1 - (k + c_1) \log n$. Ukážeme, že T nemôže zrekonštruovať x z $f(x)$ s pravdep. aspoň $1/2$

Ak áno:

– R je množina rozhodnutí korektnej odpovede

– $r \in R$ s $C(r|x) \geq I(r) - 1$

– $C(x) \geq I(x)$, $C(r) \leq I(r) + O(1)$, symetria KZ $C(x|r) \geq n - c_2 \log n$

$1/2$ z 2^{n^k}
existuje!

krátky popis $x|r$

informácia potrebná pre odpovede orákula keď T počíta pri vstupe $f(x)$
 $(k + 2) \log n + c_1$

simulácia T so vstupom $f(x)$ pri znalosti výsledkov hádzania r

- diskusia
- $2 \log n$ bitov pre slová dĺžky $< n$
- T sa pýta $?x \in L?$ - $k \log n$ bitov na určenie času, keď sa to pýta

$$C(x|r) \leq c_1 + 2 \log n + k \log n + I(f(x))$$

pre $c_1 > c_2 + 2$ dostaneme spor $// I(f(x)) \leq n - c_1 - (k + c_1) \log n$



Theorem

Ak $L \in 1DLOG$, potom r_L môžeme vypočítať v P .

- T rozpoznáva L
 - $L_x = \{y \in L : y \leq x\}$; zrejme $r_L(x) = d(L_x)$
 - x do vnútornej pamäte a rozpoznávame L_x jednosmerne v DLOG s polynomiálnym počtom stavov — T_x
 - $G_x = (V_x, E_x)$ — graf konfigurácií pre T_x ;
 $V_x = \{[hlava, stav, paska]\}$
 E_x — zachytáva možné prechody
- $\hookrightarrow r_L(x)$ je počet akceptujúcich ciest v G_x

Nech $L \subseteq \Sigma^*$ je regulárny, $L_x = \{y \mid xy \in L\}$. Potom existuje konštanta c , že $\forall x$: ak y je n -té slovo v L_x , tak $C(y) \leq C(n) + c$

- stav DKA po dočítaní x
- n
- diskusia



$\Sigma^* = \{y_1, y_2, \dots\}$;

pre $L \subseteq \Sigma^*$, $x \in \Sigma^*$ je $\mathbb{X} = X_1 X_2 \dots$ charakteristická postup. $L_x: X_i = 1 \Leftrightarrow xy_i \in L$.

Theorem

Nech $L \subseteq \Sigma^*$. Existuje konštanta c_L , že nasledujúce podmienky sú ekvivalentné

- 1 L je regulárny
- 2 $\forall x \in \Sigma^* \forall n \in \mathbb{N} : C(\mathbb{X}_{1..n} | n) \leq c_L$
- 3 $\forall x \in \Sigma^* \forall n \in \mathbb{N} : C(\mathbb{X}_{1..n}) \leq c_L + C(n)$
- 4 $\forall x \in \Sigma^* \forall n \in \mathbb{N} : C(\mathbb{X}_{1..n}) \leq \log n + c_L$

Ak $\forall x \in \Sigma^* \forall n \in \mathbb{N} : C(\mathbb{X}_{1..n}) \leq \log n + c_L$ tak L je regulárny

Lemma

$\forall c$ existuje konečne veľa postupností $w \in \{0,1\}^*$ takých, že
 $\forall n C(w_{1..n}) \leq \log n + c$

\hookrightarrow pravá kongruencia konečného indexu $\sim \quad x \sim x' \Leftrightarrow \mathbb{X} = \mathbb{X}'$
 \hookrightarrow konečný automat □

k dôkazu lemy:

- $A_n = \{x \in \{0,1\}^n : C(x) \leq \log n + c\};$
 $A = \{w \in \{0,1\}^\infty : \forall n C(w_{1..n}) \leq \log n + c\}$
- ak $d(A_n) \leq c'$ pre nekonečne veľa n , tak $d(A) \leq c'$
- fixnime $\ell \in \mathbb{N} : y$ dĺžky $2\ell + c + 1$, $C(y) \geq 2\ell + c + 1$
- vezmime i maximálne také, že $y = mn$, $l(m) = i$, $m \leq d(A_n)$
 nech $y = sr$, $l(s) = i + 1$
- pomocou programov $l(p) \leq \log n$ vymenovávanie A_n ; y_0 - m -tý v A_n ;
 rekonštrukcia $y = mn$ z $y_0 \hookrightarrow n = l(y_m)$, $m : y_0 = y_m$

$$l(n) + l(m) = 2\ell + c + 1 \leq C(y) \leq C(y_0) + O(1) \leq \log n + c + O(1)$$

on-line TS - pred pohybom hlavy na vstupe akcept/reject na príslušný prefix

$$L = \{y \# x_1 * x_2 * \dots * x_k : \exists i y = ux_i^R v\}$$

Theorem

Viacpáskový TS akceptuje L online v čase $\Omega(n^2 / \log n)$

Lemma

Nech $n = I(x)$, p program. Ak $C(x|n, p) \geq n$, potom žiaden podreťazec dĺžky $> 2 \log n$ sa v x nevyskytuje viac ako raz.

Lemma

Ak sa v reťazci neopakuje reťazec dĺžky m , tak je jednoznačne určený množinou svojich podreťazcov dĺžky $m + 1$.

$$\hookrightarrow m = 3 \log n \quad I(x_j) = m$$

- \hookrightarrow pre y , $I(y) = n$, $C(y) \geq n$ vyrobíme vstup taký, že žiadne x_j nie je reverzom podreťazca v y ale jeho spracovanie vyžaduje $n \in$ krokov;
pre $k = \Omega(n / \log n)$ vynútime $\Omega(n^2 / \log n)$ krokov

Nech $n = l(x)$, p program. Ak $C(x|n, p) \geq n$, potom žiaden podreťazec dĺžky $> 2 \log n$ sa v x nevyskytuje viac ako raz.

- $x = uvw$, $l(v) > \log n$, v sa v uv vyskytuje presne dvakrát
- povieme i, j – indexy začiatku v v x
- povieme uw // $l(v) = n - l(uw)$ //

 $2 \log n$ $l(uw)$

$$C(x|p, n) \leq n - 2 \log n + \log n(n - 1) < n$$

Ak sa v reťazci neopakuje reťazec dĺžky m , tak je jednoznačne určený množinou $S_{x, m+1}$ svojich podreťazcov dĺžky $m + 1$.

$a, b \in \{0, 1\}$, $u, v, w \in \{0, 1\}^*$

- prefix ua je jednoznačne určený podmienkou $\forall b, bu \notin S_{x, m+1}$
- \forall prefix vw , $l(w) = m$ existuje **práve jedno** $b \in \{0, 1\}$: $wb \in S_{x, m+1}$ a vwb je prefix x

\leftrightarrow rekonštrukcia x zo znalosti $S_{x, m+1}$

$m = 3 \log n$ $l(x_i) = m$; pre y , $l(y) = n$, $C(y) \geq n$ vyrobíme vstup taký, že žiadne x_i nie je reverzom podreťazca v y ale jeho spracovanie vyžaduje $n\epsilon$ krokov

majme to po $y\#x_1 * \dots * x_{i-1}$ *

1 ak $i - 1 = k$ ✓

2 ak také x_i neexistuje, vyrobíme krátky popis na generovanie $S_{y,m+1}$ //a teda y

■ diskusia $O(1)$

■ obsah pracovných pásov do vzdialenosti $n\epsilon$ od hláv v čase t_0 , keď T ukončil spracovanie prefixu $y\#x_1 * \dots * x_{i-1}$ * $O(n\epsilon)$

■ polohy hláv v čase t_0 $O(\log n\epsilon)$

■ popis T , n , stav v čase t_0 $O(1) + \log n$

$$C(y) \leq O(1) + O(n\epsilon) + O(\log n\epsilon) + \log n < n$$

□

Pre FA je $(k + 1)$ hláv viac ako k

$$L_b = \{w_1\# \cdots \# w_b\#\# w_b\# \cdots \# w_1 \mid w_i \in \{0, 1\}^*\}, b = \binom{k}{2} + 1$$

1. $L_b \in (k + 1)DFA$

2. $L_n \notin (k)NFA$ SPOROM:

- vezmeme nestlačiteľné w , $C(w) \geq I(w)$, $I(w) \gg \log I(w)$
- $w = w_1 \dots w_b \rightsquigarrow$ korektný vstup I
- NKA kontroluje w_i ak súčasne jedna hlava na ľavej a jedna na pravej kópii w_i

Lemma

M musí skontrolovať každé w_i

- $[q, p(h_1), \dots, p(h_k)]$ — postupnosť hlavových konfigurácií v okamihoch, keď jedna z hláv prvýkrát prichádza na p $O(k \log(I)) + I(M) = O(\log I(w))$
- r_l, r_r -L a R pozícia pravej kópie w_i , $p(r_l), p(r_r)$ príslušné prechodové postupnosti

↪ rekonštrukcia w_i z

- popis $w - w_i$
- popis $p(r_l), p(r_r)$

$$C(w_i | w - w_i) \leq O(\log I(w))$$

$$C(w) \leq I(w) - I(w_i) + O(\log I(w)) < I(w)$$