

10. cvičení

Věta. Tabulkové hashování je 3-nezávislé.

Úloha 1 (Tuhle větu si dokážeme)

Dokažte předcházející větu s následujícím postupem. Mějme $a, b, c \in \mathbb{Z}_2^\ell, x \neq y \neq z \neq x \in \mathbb{Z}_2^w$, a používejme tabulkové hashování s d částmi. Pak chceme ukázat, že $\Pr_{h \in \mathcal{H}}[h(x) = a \wedge h(y) = b \wedge h(z) = c] \leq \frac{1}{m^3}$.

(a) Prvně si uvědomme, že pokud máme jen jednu část, a tedy jednu tabulku, tvrzení je triviální.

Dále mějme alespoň dvě části. Protože x, y, z jsou různé, musí se (po dvou) lišit alespoň v jedné části.

(b) Prvně prozkoumejme případ, kdy existuje část i , že x^i, y^i, z^i jsou všechny různé. Mějme jakkoliv zvolené ostatní tabulky, kromě tabulky T_i . S jakou pravděpodobností můžeme zvolit funkci pro tabulku T_i tak, že $h(x) = a, h(y) = b, h(z) = c$?

(c) Jinak existují (BÚNO) části i, j takové, že $z^i = x^i \neq y^i$ a $y^j = x^j \neq z^j$. Potom máme následující soustavu rovnic, kde v_x, v_y, v_z jsou vyXORované výsledky z ostatních tabulek:

$$\begin{aligned} T_i[x^i] \oplus T_j[x^j] &\oplus v_x = a \\ T_i[y^i] \oplus T_j[y^j] &\oplus v_y = b \\ T_i[z^i] \oplus T_j[z^j] &\oplus v_z = c \end{aligned}$$

Opět si představme, že v_x, v_y, v_z už známe. S jakou pravděpodobností budou náhodně volené tabulky T_i, T_j splňovat tuto soustavu rovnic?

(d) Uvědomte si, že toto stačí.

Lemma. Nechť \mathcal{F} je c -univerzální rodina funkcí $f : \mathcal{U} \rightarrow [r]$, \mathcal{G} je $(2, d)$ -nezávislá rodina funkcí $g : [r] \rightarrow [m]$. Pak $\mathcal{H} = \mathcal{F} \circ \mathcal{G} = \{f \circ g : f \in \mathcal{F}, g \in \mathcal{G}\}$ je $(2, c')$ -nezávislá, kde $c' = d \cdot (\frac{cm}{r} + 1)$.

Tvrzení. Pro prvočíslo p a délku vektoru d definujeme třídu hashovacích funkcí $\mathcal{R} = \{h_a : a \in \mathbb{Z}_p\}$, kde $h_a(x) = \sum_{i=0}^{d-1} x_{i+1} a^i$. (Bereme $x \in \mathbb{Z}_p^d$, indexujeme od jedničky.) Pak \mathcal{R} je d -univerzální, a $\mathcal{R} \circ \mathcal{L}$ je $(2, 5/2)$ -nezávislý systém, máme-li $p \geq 4dm$, kde $\mathcal{L} = \{h_{a,b}(x) = (ax + b \bmod p) \bmod m : a, b \in \mathbb{Z}_p\}$.

Úloha 2 (I tohle si dokážeme)

Dokažte předcházející tvrzení. Začneme s univerzalitou. Chceme tedy dokázat, že pro každá dvě slova $x \neq y \in \mathbb{Z}_p^d$ je $\Pr_a[\sum_{i=0}^{d-1} x_{i+1} a^i = \sum_{i=0}^{d-1} y_{i+1} a^i] \leq \frac{d}{p}$.

Hint: *ყავის შემთხვეულობრივობის გადასაცვლილობის გადასაცვლიليل*

Dále použijeme lemma, které jsme si dokázali společně na začátku hodiny, a fakt z přednášky, že \mathcal{L} je $(2, 2)$ -nezávislý systém pro $p \geq 4m$. Tím jsme už vše dokázali.

Úloha 3 (Univerzální modulo může rozbit univerzalitu)

Ukažte, že pokud máme univerzální systém hashovacích funkcí \mathcal{H} , pak systém \mathcal{H}' , kde ke každé fci navíc přidáme modulo m , už nemusí být univerzální. Formálně: Dokažte, že pro každé c a $m > 1$ existuje univerzum \mathcal{U} a systém \mathcal{H} z \mathcal{U} do \mathcal{U} tak, že \mathcal{H} je univerzální, ale \mathcal{H}' už není c -univerzální.

Úloha 4 (Vyhledávání jehly v textu)

Vymyslete algoritmus na nalezení všech výskytů podřetězce x délky n v textu T délky m pomocí hashování, který běží v průměrném čase (tj. ve střední hodnotě) $\mathcal{O}(n + m + k \cdot n)$, kde k je počet výskytů x v T .