

9. cvičení

Datové struktury I, 2. 12. 2024

<https://iuuk.mff.cuni.cz/~chmel/2425/ds1/>

Úloha 1 (Špatná verze kukačky)

Proč je následující implementace insertu pro kukačkové hashování problematická? (Implementaci a podmínky pro rehashování pro tento příklad meteme pod koberec.)

```
for i=1 to n
  if T[h1(x)] je prázdné
    T[h1(x)] = x
    return
  swap(T[h1(x)], x)
  if T[h2(x)] je prázdné
    T[h2(x)] = x
    return
  swap(T[h2(x)], x)
```

Úloha 2 (4-nezávislost tabulkového hashování)

Ukažte, že tabulkové hashování není 4-nezávislé (pokud používáme aspoň dvě tabulky).

Hint: *опыт показывает, что для доказательства достаточно рассмотреть три первые ячейки таблицы*

Věta. Tabulkové hashování je 3-nezávislé.

Úloha 3 (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 použijeme tabulkové hashování s d částmi. Pak chceme ukázat, že $\Pr_{h \in \mathcal{H}}[h(x) = a \wedge h(y) = b \wedge h(z) = c] \leq \frac{1}{m^3}$.

- 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.
- Začneme s případem, 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 $h(x) = a, h(y) = b, h(z) = c$?
- 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:

$$T_i[x^i] \oplus T_j[x^j] \oplus v_x = a$$

$$T_i[y^i] \oplus T_j[y^j] \oplus v_y = b$$

$$T_i[z^i] \oplus T_j[z^j] \oplus v_z = c$$

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?

- Uvědomte si, že toto stačí.

Úloha 4 (Rehashujeme)

Jednoduchá implementace rehashe u kukačkového hashování je, že si všechny hodnoty vložíme do pomocného pole, a potom je po jednom insertujeme. Vymyslete implementaci rehashe, která pomocné pole nepotřebuje. (Pozor na to, že během rehashe můžeme znovu začít s rehashem.)

Užitečné definice

Definice (k -nezávislý systém fcí). Systém $\mathcal{H}$ funkcí $h : \mathcal{U} \rightarrow [m]$ je (k, c) -nezávislý pro nějaká $k \geq 1, c > 0$, pokud $\Pr_{h \in \mathcal{H}}[h(x_1) = a_1 \wedge \dots \wedge h(x_k) = a_k] \leq \frac{c}{m^k}$ pro libovolná $x_1, \dots, x_k$ různá, $a_1, \dots, a_k$ ne nutně různá. Systém $\mathcal{H}$ je k -nezávislý, pokud je (k, c) -nezávislý pro nějakou nezávislou konstantu c .

Definice (Tabulkové hashování). Představme si, že chceme zahashovat n -bitové řetízky do m -bitových řetízků, kde $n = k \cdot \ell$. Řetízek $x \in \{0, 1\}^n$ pak rozložíme do k částí délky ℓ , které značíme x^i . Můžeme tedy psát $x = x^1 x^2 \dots x^k$. Pak generování naší hashovací funkce $h : \{0, 1\}^n \rightarrow \{0, 1\}^m$ vypadá tak, že vybereme uniformně náhodně k funkcí $T_i : \{0, 1\}^\ell \rightarrow \{0, 1\}^m$ (tyto reprezentujeme tabulkou, proto tabulkové hashování). Vyhodnocujeme pak $h(x) = \bigoplus_{i=1}^k T_i(x^i) = T_1(x^1) \oplus T_2(x^2) \oplus \dots \oplus T_k(x^k)$, kde $\oplus$ značí XOR (po jednotlivých bitech).

Definice (Kukačkové hashování). V každém okamžiku máme dvě hashovací funkce $f, g : \mathcal{U} \rightarrow [m]$ volené uniformně náhodně z nějakého systému hashovacích funkcí a jedno pole velikosti m . Naším cílem je, že každý prvek x , který je zahashovaný, se vyskytuje v jednom ze dvou „hnízd“ $f(x)$ nebo $g(x)$.

Lookup se podívá na tato dvě místa, a podle výsledku buď řekne, zda se tam prvek nachází, nebo ne.

Insert probíhá následovně: pokud je jedno z hnízd $f(x)$ nebo $g(x)$ volné, usadíme x do volného místa. Jinak vybereme jedno z plných míst (řekněme $f(x)$), x do něj vložíme, a vyjmeme prvek x_1 , který byl v tomto hnízdě původně uložený. Teď musíme uložit x_1 , a to vložíme do toho hnízda $f(x_1), g(x_1)$, ze kterého jsme jej *nevyjmul* – takže jej dáme do druhého hnízda než bylo $f(x)$. Takhle můžeme nějakou dobu pokračovat, dokud nenajdeme prázdné místo, nebo dokud nedojde k tomu, že už takhle přesouváme prvky příliš dlouho (řekněme $6 \log(m)$ nebo $6 \log(n)$, kde m je počet hnízd/příhrádek a n je počet uskládňovaných prvků). Potom se na tento pokus o vložení vykašleme, a začneme znovu s tím, že si vygenerujeme nové funkce f a g , a všechny prvky v našem poli přehashujeme.

Úloha 1 (Špatná verze kukačky)

Proč je následující implementace insertu pro kukačkové hashování problematická? (Implementaci a podmínky pro rehashování pro tento příklad meteme pod koberec.)


```
for i=1 to n
  if T[h1(x)] je prázdné
    T[h1(x)] = x
    return
  swap(T[h1(x)], x)
  if T[h2(x)] je prázdné
    T[h2(x)] = x
    return
  swap(T[h2(x)], x)
```

→ tedy jsem uhlíhl "y"

→ tedy chci T[h2(y)]

→ není tam T[h2(y)], když tam rehash,

◊ Nemůžu rovnou zhaset h2(x), protože pokud na stejné pozici prvek "y" byl zhaseným prvkem právě h2, takže bych zase nahradil y a x, tak šanci tam kde jsem začal.



Úloha 2 (4-nezávislost tabulkového hashování)

Ukažte, že tabulkové hashování není 4-nezávislé (pokud používáme aspoň dvě tabulky).

Hint: najít nějakou čtveřici vstupů takových, že hashe první tři jednoznačně určují hash čtvrtého.

~~$$\begin{aligned}
 x \oplus x &\sim 0^l \\
 x \oplus \neg x &\sim 1^l \\
 x \oplus 1^l &\sim \neg x \\
 x \oplus 0^l &\sim x
 \end{aligned}$$~~

a	0	0	1	1
b	0	1	0	1
⊕	0	1	1	0

→ když máme všechno 2 XOR ym, musím dostat 0.

0 0

0 1

1 0

1 1

$T_1[0] \oplus T_2[0]$

$T_1[0] \oplus T_2[1]$

$T_1[1] \oplus T_2[0]$

$T_1[1] \oplus T_2[1]$

Pokud bych měl výsledky hashů první tři prvků, vím jak musí vypadat 4. hash, aby celkem dal XOR do 0.

Úloha 3 (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 použijeme tabulkové hashování s d částmi. Pak chceme ukázat, že $\Pr_{h \in \mathcal{H}}[h(x) = a \wedge h(y) = b \wedge h(z) = c] \leq \frac{1}{m^3}$.

- 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.
- Začneme s případem, 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 $h(x) = a, h(y) = b, h(z) = c$?
- 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?

- Uvědomte si, že toto stačí.

a) Když mám jen jednu tabulku, tak rozdělení výstupů (do ℓ bitů) je uniformně náhodné.

Proto pokud $h(x) \neq h(y) \neq h(z) \neq h(x)$, tak $P(\text{holice tři prvky}) \leq \frac{1}{m^3}$

$$= \frac{1}{2^\ell} \cdot \frac{1}{2^\ell} \cdot \frac{1}{2^\ell} = \frac{1}{2^{3\ell}} = \frac{1}{m^3}$$


b)

$$\begin{array}{ccccc} & & T_i & & \\ x & & x_i & & a \\ y & \cdots \oplus & y_i & \oplus \cdots = & b \\ z & & z_i & & c \end{array}$$

— můžeme XORy přesunout tak, že T_i bude poslední tabulka.

T_i hashuje do $2^{\frac{w}{d}-3}$ bitů. Můžeme mít celkem $2^{\frac{w}{d}-3}$, které mohou splňovat tu poslední XOR operaci.

$$P[T_i \text{ je správná}] = \frac{(2^\ell)^{2^{\frac{w}{d}-3}}}{(2^\ell)^{2^{\frac{w}{d}}}} = 2^{\ell^{-3}} = \frac{1}{(2^\ell)^3} = \frac{1}{m^3}$$



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:

$$T_i[x^i] \oplus T_j[x^j] \oplus v_x = a$$

$$T_i[y^i] \oplus T_j[y^j] \oplus v_y = b$$

$$T_i[z^i] \oplus T_j[z^j] \oplus v_z = c$$

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?

Handwritten notes on a green chalkboard:

$$\begin{aligned} T_i[x^i] &= T_i[z^i] \\ T_j[x^j] &= T_j[y^j] \\ T_i[z^i] &= W = T_i[x^i] \\ X &= T_i[y^i] \\ Y &= T_j[x^j] = T_j[y^j] \\ Z &= T_j[z^j] \end{aligned}$$

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

$$\begin{aligned} W \oplus Y &= a \oplus v_x \\ X \oplus Y &= b \oplus v_y \\ W \oplus Z &= c \oplus v_z \end{aligned}$$

Annotations on the chalkboard:

- $W \oplus Y = a \oplus v_x$ is circled in blue.
- $X \oplus Y = b \oplus v_y$ is circled in red.
- $W \oplus Z = c \oplus v_z$ is circled in blue.
- Below the equations, it is written: $\frac{1}{m^3} = \frac{m}{m^4}$.

po dvou různých

→ Sahneme zafixují jednu proměnnou, čímž jednodušeji uvažujeme Y . Pak ale máme uvažované i W . Tuhle pak i Z .

Tudíž celkem máme $\frac{1}{m^4}$ hodnotování proměnných X, Y, W, Z , ale pouze m^2 z nich správných. Proto ta prav. je $\frac{m}{m^4} = \frac{1}{m^3}$

tedy 3-nezávislost