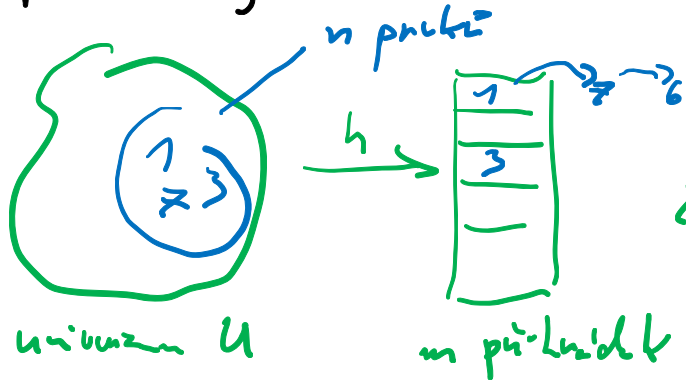


Hashování (s řetězy)

DS pro množiny (slovník) s operacemi: FIND, INSERT, DELETE - $O(1)$ očekávaně čas a $O(1)$ paměť.



$$h: U \rightarrow [m]$$
$$\{0, \dots, U-1\} \quad \{0, \dots, m-1\}$$
$$h(x) = h(y) \text{ kolize}$$


$d = U/m \dots$ faktor naplnění (kustota)
(odhadujeme délku větvičky pokud h zcela náhodná)

Př:
• lineární kongruence

$$h(x) = ax \text{ mod } m \quad \text{pro } a, m \text{ nesoudělné}$$

• vyšší bitový součin

$$h(x) = \lfloor (ax \text{ mod } 2^w) / 2^{w-l} \rfloor \quad \text{pro } a \text{ lide, } w > l \geq 1$$



• skalární součin

$$h(x_1, \dots, x_d) = \sum_i a_i x_i \text{ mod } m \quad \text{pro } a \in \mathbb{Z}_m^d, m \text{ prvočíslo}$$

$x \in \mathbb{Z}_m^d$

• polynom

$$h(x_1, \dots, x_d) = \sum_i x_i a^i \text{ mod } m \quad \text{pro } a \in \mathbb{Z}_m, m \text{ prvočíslo}$$

☺ x náh. rovn. rozdělení $\Rightarrow h(x)$ rovnoměrné rozdělení \Rightarrow n/m oábkování
dílna čísla

Problem: pevná h. fa je snadno neproveditelná

\Rightarrow zvol h vhodně z \mathcal{R} (se stejnou prahou)

Př. $\mathcal{R} =$ všechny fa $h: U \rightarrow [m]$ (zcela náh. fa)

$$P_{h \in \mathcal{R}} [h(x) = h(y)] = 1/m \quad \text{pro } x \neq y$$

Ale: potřebujeme $O(n \log m)$ bitů (n bitů stačí přiznatové pole)

Co je "dobry" systém \mathcal{R} ?

• parametrizovaný - $O(1)$ prostor pro h

• $O(1)$ čas pro výpočet ($O(l)$ pro řetězec délky l)

• "chovat" stejně jako zcela náh. fa

Def: • System \mathcal{H} je f a $h: \mathcal{U} \rightarrow [m]$ je **c-univerzál** pro $c > 0$ pokud

$$P_h[h(x) = h(y)] \leq \frac{c}{m} \quad \text{pro lib. } x \neq y.$$

• \mathcal{H} je **uni-univerzál** pokud je c -univ. pro $\forall j, c > 0$.

Věta: \mathcal{H} c-univ. system $h: \mathcal{U} \rightarrow [m]$, $x_1 \dots x_n, y$ navzájem různé. Pak

$$E_h[\underbrace{\sum_i 1_{A_i}}_A \mid h(x_i) = h(y)] \leq \frac{cn}{m}.$$

Dz: $A = \sum A_i$ kde $A_i = \begin{cases} 1 & \text{pokud } h(x_i) = h(y) \\ 0 & \text{jinak} \end{cases}$ (indikator)

$$E[A_i] = P[A_i = 0] \cdot 0 + P[A_i = 1] \cdot 1 = P[A_i = 1] \leq \frac{c}{m}$$

$$E[A] = E[\sum A_i] = \sum E[A_i] \leq \frac{cn}{m} \quad \square$$

↑
lineární střední hodnota

Stožitost hledání sítě

U c-univ. $x_1 \dots x_n$ v tabulce, očekávaný čas:

FIND(x) ... $O(\frac{cn}{m})$ neúspěšný, $O(\frac{cn'}{m})$ úspěšný, $n' = \#$ prvků v tabulce po uložení x

INSERT(x) ... $O(\frac{cn}{m})$ (když není, zůstal není)

DELETE(x) ... $O(\frac{cn'}{m})$



$\Rightarrow O(1)$ očekávaný čas pokud $m = \Omega(n)$.

Co když dopředu nevíme n ?

if $\alpha = n/m > 1$ then $m' = 2m$ + přehodování

if $\alpha < 1/4$ then $m' = m/2$ + přehodování (pokud potřeba)

$\Rightarrow \alpha \in [1/4, 1]$ (flexibilní pole)

\Rightarrow amortizovaně $O(1)$ očekávaný čas

Co když m není prvočíslo?

$$h_{a,b}(x) = ((ax + b) \bmod p) \bmod m \quad p \text{ prvočíslo, } p \geq m, a, b \in \mathbb{Z}_p$$

Věta: Systém $\mathcal{L} = \{h_{a,b} \mid a, b \in \mathbb{Z}_p\}$ je 2-univ. pro lib. prvočíslo $p \geq m$.

Dů: $x \neq y$ pevné. Pro $a, b \in \mathbb{Z}_p$

$$r = (ax + b) \bmod p$$


$$s = (ay + b) \bmod p$$

$(a, b) \mapsto (r, s)$ bijektivní

$\Rightarrow (r, s)$ rovnoměrně rozdělené

kolika $h_{a,b}(x) = h_{a,b}(y) \Leftrightarrow r = s \bmod m$

$(r, s) \dots$ "špatné" dvojice



pro dané r je $\leq \lceil p/m \rceil$ špatných s

$$Pr[h_{a,b}(x) = h_{a,b}(y)] \leq \frac{p \lceil p/m \rceil}{p^2} \leq \frac{p+m-1}{p \cdot m} \leq \frac{2p-1}{pm} \leq \frac{2}{m}$$

$$\lceil p/m \rceil \leq \frac{p+m-1}{m}$$

pozor, (1+ε)-univ. pro dost. velké p .

Věta: Systém $\mathcal{L} = \{h_{a,b} \mid a, b \in \mathbb{Z}_p, a \neq 0\}$ je 1-univ. pro lib. prvočíslu $p \geq 11$.

Dů: podobně $(a, b) \mapsto (r, s)$ bij. (r, s) je spjaté: $r \equiv s \pmod{m}$
 $a \neq 0$ $r \neq s$ $m \neq s$

pro dané r je $\leq \lceil p/m \rceil - 1$ spjatých s

$$P_{\mathcal{L}}[h_{a,b}(x) = h_{a,b}(y)] \leq \frac{p(\lceil p/m \rceil - 1)}{p(p-1)} \leq \frac{(p-1)/m}{p-1} = \frac{1}{m} \quad \square$$

Pří: $\mathcal{L} = \{h_0, h_1\}$ $h_i(x_0, x_1) = x_i$

x	00	01	p	π
$\rightarrow h_0(x)$	0	0	1	1
$\rightarrow h_1(x)$	0	1	0	1

$$P_{\mathcal{L}}[h(x) = h(y)] = \begin{cases} 0 & x = y \\ 1/2 & x \neq y \end{cases} \Rightarrow \mathcal{L} \text{ je 1-univ.}$$

$$\text{Ale: } P_{\mathcal{L}}[h(00) = 0] = 1 \quad \#(h(00)) = 0$$

$$P_{\mathcal{L}}[h(01) = 0 \wedge h(10) = 1] = 1 < \begin{matrix} 1 \\ 0 \end{matrix} \quad \forall y \neq 01 \\ a, b \in \{0, 1\}$$

Def : System \mathcal{X} fci $h: \mathcal{X} \rightarrow [m]$ je (k, c) -measurable pro m ; $k \geq 1, c > 0$

$$P_{\mu} \left[h(x_1) = a_1 \wedge \dots \wedge h(x_k) = a_k \right] \leq \frac{c}{m^k} \quad \text{pro lib. } x_1 \dots x_k \text{ i.i.d.}$$

l: b $a_1 \dots a_k$ (ac m \times \dots \times m)