



Hešovanie

kuko

20.10.2020

Vybrané partie z dátových štruktúr





priemerná čas. zlož.



očakávaná čas. zlož.

rodina hešovacích funkcií \mathcal{H}

$$h \in_R \mathcal{H}$$

\mathcal{H} je univerzálna ak

$$\forall x_1 \neq x_2 : \Pr_{h \in R^{\mathcal{H}}} [h(x_1) = h(x_2)] \leq 1/n$$

\mathcal{H} je 1-nezávislá, ak

$$\forall x, y : \Pr_{h \in R^{\mathcal{H}}} [h(x_1) = y] = 1/n$$

\mathcal{H} je 1-nezávislá, ak

$$\forall x, y : \Pr_{h \in R\mathcal{H}} [h(x_1) = y] = O(1/n)$$

\mathcal{H} je k -nezávislá, ak

$$\forall \underbrace{x_1, \dots, x_k}_{\text{rôzne}}, y_1, \dots, y_k : \Pr_{h \in R\mathcal{H}} [h(x_1) = y_1 \wedge \dots \wedge h(x_k) = y_k] = O(1/n^k)$$

$\forall x, y : \Pr_h[h(x) = y] = O(1/n)$ a pre rôzne x_1, \dots, x_k sú náhodné premenné $h(x_1), \dots, h(x_k)$ skoro nezávislé

\mathcal{H} je k -nezávislá, ak

$$\forall \underbrace{x_1, \dots, x_k}_{\text{rôzne}}, y_1, \dots, y_k : \Pr_{h \in R\mathcal{H}} [h(x_1) = y_1 \wedge \dots \wedge h(x_k) = y_k] = O(1/n^k)$$

$\forall x, y : \Pr_h[h(x) = y] = O(1/n)$ a pre rôzne x_1, \dots, x_k sú náhodné premenné $h(x_1), \dots, h(x_k)$ skoro nezávislé

- $x \mapsto (ax \bmod p) \bmod n$ je univerzálna
- $x \mapsto (ax) \gg (w - k)$ (ak $n = 2^k$ a register má w bitov) je univerzálna
- $x \mapsto ((ax + b) \bmod p) \bmod n$ sú 2-nezávislé ($a, b \in \mathbb{Z}_p$, $a \neq 0$)
- všeobecne $x \mapsto ((a_kx^k + \dots + a_1x + a_0) \bmod p) \bmod n$ sú k -nezávislé
- jednoduché tabuľné hešovanie je 3-nezávislé
 - vygenerujeme si tabuľky T_1, \dots, T_c veľkosti $u^{1/c}$ s úplne náhodnou hešovacou fn.;
 - na $x \in U$ sa pozeráme ako na vektor $x = x_1 \dots x_c$ a $h(x) = T_1(x_1) \oplus \dots \oplus T_c(x_c)$

- $x \mapsto (ax \bmod p) \bmod n$ je univerzálna
- $x \mapsto (ax) \gg (w - k)$ (ak $n = 2^k$ a register má w bitov) je univerzálna
- $x \mapsto ((ax + b) \bmod p) \bmod n$ sú 2-nezávislé ($a, b \in \mathbb{Z}_p$, $a \neq 0$)
- všeobecne $x \mapsto ((a_kx^k + \dots + a_1x + a_0) \bmod p) \bmod n$ sú k -nezávislé
- jednoduché tabuľné hešovanie je 3-nezávislé
 - vygenerujeme si tabuľky T_1, \dots, T_c veľkosti $u^{1/c}$ s úplne náhodnou hešovacou fn.;
 - na $x \in U$ sa pozeráme ako na vektor $x = x_1 \dots x_c$ a $h(x) = T_1(x_1) \oplus \dots \oplus T_c(x_c)$

- $x \mapsto (ax \bmod p) \bmod n$ je univerzálna
- $x \mapsto (ax) \gg (w - k)$ (ak $n = 2^k$ a register má w bitov) je univerzálna
- $x \mapsto ((ax + b) \bmod p) \bmod n$ sú 2-nezávislé ($a, b \in \mathbb{Z}_p$, $a \neq 0$)
- všeobecne $x \mapsto ((a_kx^k + \dots + a_1x + a_0) \bmod p) \bmod n$ sú k -nezávislé
- jednoduché tabuľné hešovanie je 3-nezávislé
 - vygenerujeme si tabuľky T_1, \dots, T_c veľkosti $u^{1/c}$ s úplne náhodnou hešovacou fn.;
 - na $x \in U$ sa pozeráme ako na vektor $x = x_1 \dots x_c$ a $h(x) = T_1(x_1) \oplus \dots \oplus T_c(x_c)$

- $x \mapsto (ax \bmod p) \bmod n$ je univerzálna
- $x \mapsto (ax) \gg (w - k)$ (ak $n = 2^k$ a register má w bitov) je univerzálna
- $x \mapsto ((ax + b) \bmod p) \bmod n$ sú 2-nezávislé ($a, b \in \mathbb{Z}_p$, $a \neq 0$)
- všeobecne $x \mapsto ((a_k x^k + \cdots + a_1 x + a_0) \bmod p) \bmod n$ sú k -nezávislé
- jednoduché tabuľné hešovanie je 3-nezávislé
 - vygenerujeme si tabuľky T_1, \dots, T_c veľkosti $u^{1/c}$ s úplne náhodnou hešovacou fn.;
 - na $x \in U$ sa pozeráme ako na vektor $x = x_1 \cdots x_c$ a $h(x) = T_1(x_1) \oplus \cdots \oplus T_c(x_c)$


- $x \mapsto (ax \bmod p) \bmod n$ je univerzálna
- $x \mapsto (ax) \gg (w - k)$ (ak $n = 2^k$ a register má w bitov) je univerzálna
- $x \mapsto ((ax + b) \bmod p) \bmod n$ sú 2-nezávislé ($a, b \in \mathbb{Z}_p$, $a \neq 0$)
- všeobecne $x \mapsto ((a_k x^k + \dots + a_1 x + a_0) \bmod p) \bmod n$ sú k -nezávislé
- jednoduché tabuľné hešovanie je 3-nezávislé
 - vygenerujeme si tabuľky T_1, \dots, T_c veľkosti $u^{1/c}$ s úplne náhodnou hešovacou fn.;
 - na $x \in U$ sa pozeráme ako na vektor $x = x_1 \cdots x_c$ a $h(x) = T_1(x_1) \oplus \dots \oplus T_c(x_c)$

hešovanie so zretežením	$O(1)$	univerzálna rodina \mathcal{H}
lineárne sondovanie	$O(1/\varepsilon^2)$	$n \geq (1 + \varepsilon)m$
	$O(1/\varepsilon^2)$	5-nezávislá rodina \mathcal{H}
	$O(1/\varepsilon^2)$	tabuľačné hešovanie

dá sa vyhľadávanie v $O(1)$ v najhoršom prípade?
čo keby sme vedeli všetky prvky dopredu?

Perfektné hešovanie

Narodeninový paradox



$$1 \times \left(1 - \frac{1}{365}\right) \times \left(1 - \frac{2}{365}\right) \times \cdots \times \left(1 - \frac{n-1}{365}\right)$$

$$e^x \approx 1 + x$$

$$\approx 1 \cdot e^{-1/365} \cdot e^{-2/365} \cdots e^{-(n-1)/365} = e^{-(n(n-1)/2)/365}$$

$$1 \times \left(1 - \frac{1}{365}\right) \times \left(1 - \frac{2}{365}\right) \times \cdots \times \left(1 - \frac{n-1}{365}\right)$$


$$e^x \approx 1 + x$$

$$\approx 1 \cdot e^{-1/365} \cdot e^{-2/365} \cdots e^{-(n-1)/365} = e^{-(n(n-1)/2)/365}$$

$$1 \times \left(1 - \frac{1}{365}\right) \times \left(1 - \frac{2}{365}\right) \times \cdots \times \left(1 - \frac{n-1}{365}\right)$$

$$e^x \approx 1 + x$$

$$\approx 1 \cdot e^{-1/365} \cdot e^{-2/365} \cdots e^{-(n-1)/365} = e^{-(n(n-1)/2)/365}$$



- (FKS'84) dve úrovne hešovania, namiesto zreťazenia tabuľku kvadratickej veľkosti

T	m_0	a_0	b_0	S_0
0	1	0	0	10
1	/			
2		m_2	a_2	b_2
3	/	4	10	18
4	/			
5		m_5	a_5	b_5
6	/	1	0	0
7	/	m_7	a_7	b_7
8	/	9	23	88

Diagram illustrating a two-level hashing scheme. The array T has 9 slots. Slots 0, 2, 4, 5, 6, and 8 contain pointers to external boxes labeled S_0 , S_2 , S_5 , and S_7 respectively. These boxes are 4x3 grids. S_0 contains values 10, 0, and 0. S_2 contains 60, 75, and three diagonal slashes. S_5 contains 70, 0, and 0. S_7 contains 40, 37, and 22, with indices 0 through 8 below it.

- $E[\#\text{kolízií}] = m^2 \cdot O(1/n) \leq 1/2$ pre dosť veľké $n = \Theta(m^2)$
- žiadna kolízia s pp. aspoň $1/2$ (Markov: $\Pr[X \geq k\mu] \leq 1/k$)
- $E[\sum_t C_t^2] = \sum_t E[C_t^2] = O(E[\#\text{kolízií}]) + O(n)$
- $= m^2 \cdot O(1/n) = O(n)$ pre $m = \Theta(n)$


- $E[\#\text{kolízií}] = m^2 \cdot O(1/n) \leq 1/2$ pre dosť veľké $n = \Theta(m^2)$
- žiadna kolízia s pp. aspoň $1/2$ (Markov: $\Pr[X \geq k\mu] \leq 1/k$)
- $E[\sum_t C_t^2] = \sum_t E[C_t^2] = O(E[\#\text{kolízií}]) + O(n)$
- $= m^2 \cdot O(1/n) = O(n)$ pre $m = \Theta(n)$

- $E[\#\text{kolízií}] = m^2 \cdot O(1/n) \leq 1/2$ pre dosť veľké $n = \Theta(m^2)$
- žiadna kolízia s pp. aspoň $1/2$ (Markov: $\Pr[X \geq k\mu] \leq 1/k$)
- $E[\sum_t C_t^2] = \sum_t E[C_t^2] = O(E[\#\text{kolízií}]) + O(n)$
- $= m^2 \cdot O(1/n) = O(n)$ pre $m = \Theta(n)$


- $E[\#\text{kolízií}] = m^2 \cdot O(1/n) \leq 1/2$ pre dosť veľké $n = \Theta(m^2)$
- žiadna kolízia s pp. aspoň $1/2$ (Markov: $\Pr[X \geq k\mu] \leq 1/k$)
- $E[\sum_t C_t^2] = \sum_t E[C_t^2] = O(E[\#\text{kolízií}]) + O(n)$
- $= m^2 \cdot O(1/n) = O(n)$ pre $m = \Theta(n)$


Kukučie hešovanie






- máme 2 tabuľky A , B dĺžky $2m$ a 2 hešovacie funkcie f, g
- hľadanie: prvok x je vždy v $A[f(x)]$ alebo $B[g(x)]$







Riešenie kolízií zretazením

Koľko prvkov sa zahešuje na tú „najvyťaženejšiu“ pozíciu?

$P_i = \#\text{prvkov, ktoré sa zahešujú na pozíciu } i$
koľko je $\max P_i$?

- nech $p = 1/n = \Pr[\text{prvok zahešujeme na konkrétnu pozíciu}]$
- nech $q = 1 - p = \Pr[\text{prvok zahešuje inde}]$

$$\Pr[P_i = k] = \binom{n}{k} p^k q^{n-k}$$

- nech $p = 1/n = \Pr[\text{prvok zahešujeme na konkrétnu pozíciu}]$
- nech $q = 1 - p = \Pr[\text{prvok zahešuje inde}]$

$$\Pr[P_i = k] = \binom{n}{k} p^k q^{n-k}$$

- nech $p = 1/n = \Pr[\text{prvok zahešujeme na konkrétnu pozíciu}]$
- nech $q = 1 - p = \Pr[\text{prvok zahešuje inde}]$

$$\Pr[P_i = k] = \binom{n}{k} p^k q^{n-k}$$

$$\Pr[P_i = k] = \binom{n}{k} \left(\frac{1}{n}\right)^k \left(1 - \frac{1}{n}\right)^{n-k}$$

$$\left(\frac{n}{k}\right)^k \leq \binom{n}{k} \leq \left(\frac{ne}{k}\right)^k$$

$$1/e \leq \left(1 - \frac{1}{n}\right)^{n-k} \leq 1$$

$$\Pr[P_i = k] = \binom{n}{k} \left(\frac{1}{n}\right)^k \left(1 - \frac{1}{n}\right)^{n-k}$$

$$\left(\frac{n}{k}\right)^k \leq \binom{n}{k} \leq \left(\frac{ne}{k}\right)^k$$

$$1/e \leq \left(1 - \frac{1}{n}\right)^{n-k} \leq 1$$

$$\Pr[P_i = k] = \binom{n}{k} \left(\frac{1}{n}\right)^k \left(1 - \frac{1}{n}\right)^{n-k}$$

$$\left(\frac{n}{k}\right)^k \leq \binom{n}{k} \leq \left(\frac{ne}{k}\right)^k$$

$$1/e \leq \left(1 - \frac{1}{n}\right)^{n-k} \leq 1$$

$$\Pr[P_i = k] = \underbrace{\binom{n}{k}}_{\leq (ne/k)^k} \left(\frac{1}{n}\right)^k \underbrace{\left(1 - \frac{1}{n}\right)^{n-k}}_{\leq 1} \leq \left(\frac{ne}{k}\right)^k \cdot \frac{1}{e^k} = \left(\frac{e}{k}\right)^k$$

$$\Pr[P_i = k] = \underbrace{\binom{n}{k}}_{\geq (n/k)^k} \left(\frac{1}{n}\right)^k \underbrace{\left(1 - \frac{1}{n}\right)^{n-k}}_{\geq 1/e} \geq \left(\frac{n}{k}\right)^k \cdot \frac{1}{e^k} \cdot (1/e) = \frac{1}{ek^k}$$

$$1/e k^k \leq \Pr[P_i = k] \leq (e/k)^k$$

$$\Pr[P_i = k] = \frac{1}{k^{\Theta(k)}} = \frac{1}{e^{\Theta(k \log k)}}$$

- pre $k = \ln n / 3 \ln \ln n$ je aspoň $1/e\sqrt[3]{n}$
- \implies očakávaný počet pozícií, ktoré prekročia k je $\Omega(n^{2/3})$

$$1/e k^k \leq \Pr[P_i = k] \leq (e/k)^k$$

$$\Pr[P_i = k] = \frac{1}{k^{\Theta(k)}} = \frac{1}{e^{\Theta(k \log k)}}$$

- pre $k = \ln n / 3 \ln \ln n$ je aspoň $1/e\sqrt[3]{n}$
- \implies očakávaný počet pozícií, ktoré prekročia k je $\Omega(n^{2/3})$

$$1/e k^k \leq \Pr[P_i = k] \leq (e/k)^k$$

$$\Pr[P_i = k] = \frac{1}{k^{\Theta(k)}} = \frac{1}{e^{\Theta(k \log k)}}$$

- pre $k = \ln n / 3 \ln \ln n$ je aspoň $1/e\sqrt[3]{n}$
- \implies očakávaný počet pozícií, ktoré prekročia k je $\Omega(n^{2/3})$

$$1/e k^k \leq \Pr[P_i = k] \leq (e/k)^k$$

$$\Pr[P_i = k] = \frac{1}{k^{\Theta(k)}} = \frac{1}{e^{\Theta(k \log k)}}$$

- pre $k = \ln n / 3 \ln \ln n$ je aspoň $1/e\sqrt[3]{n}$
- \implies očakávaný počet pozícií, ktoré prekročia k je $\Omega(n^{2/3})$

$$\Pr[P_i \geq \ell] = \sum_{k=\ell}^n \underbrace{(e/k)^k}_{\leq (e/\ell)^k} \leq (e/\ell)^\ell (1 + e/\ell + (e/\ell)^2 + \dots) = \Theta((e/\ell)^\ell)$$

$$\Pr[P_i \geq \ell] \leq (e/\ell)^\ell \cdot [1/(1 - e/\ell)]$$

- pre $\ell = \lceil (3 \ln n) / \ln \ln n \rceil$ dostaneme $\Pr \leq 1/n^2$

$$\sum_{k=1}^n p_k O(k^2)$$

$$p_k \sim 1/\exp(k)$$

$$\implies \sum p_k O(k^2) = O(1)$$

$$\Pr[P_i \geq \ell] \leq (e/\ell)^\ell \cdot [1/(1 - e/\ell)]$$

- pre $\ell = \lceil (3 \ln n) / \ln \ln n \rceil$ dostaneme $\Pr \leq 1/n^2$

$$\sum_{k=1}^n p_k O(k^2)$$

$$p_k \sim 1/\exp(k)$$

$$\implies \sum p_k O(k^2) = O(1)$$