

Хеширование



Семейство хеш-функций - $\mathcal{H} = \{h_i; h_i: A \rightarrow B\}$

$h_1, h_2, \dots, h_n(k) = y$

Пример $\mathcal{H} = \beta^A$ - все ф-ии из $A \rightarrow B$
 $\Pr\{h(x) = h(y)\} = \frac{1}{|B|}$ $\Pr\{h(x_1) = z_1, h(x_2) = z_2, \dots, h(x_n) = z_n\} = \frac{1}{|B|^n}$ $x_i \neq x_j \forall i \neq j$

В назале программы $h \in U(\mathcal{H})$. Даны константы h .

Пример $\mathcal{H} = \{h_{m,x}; x \in \mathbb{Z}_m\}$

$h_{m,x}(z) = (az + x^{m-1}) \bmod m$

Def. Универсальное сем. х-ф. - \mathcal{H} : $\forall x_1 \in A, x_2 \in A, x_1 \neq x_2 \Pr\{h(x_1) = h(x_2)\} \leq \frac{1}{|B|}$.

Th. Все операции в хеш-таблице с зап. адресацией и универс. хеш-функцией имеют макс. время работы $O(\frac{n}{m} + \frac{1}{\alpha})$, $|B| = m$ - размер х-таблицы, n - # запросов к таблице.

До-во k_1, k_2, \dots, k_n - различные значения

Итого элементов: k
 $E \{ \text{размера списка } \rightarrow \text{номер } h(k) \} = E \left[\sum_{i=1}^n \mathbb{1}_{\{h(k_i) = h(k_i)\}} \right] =$

$= \sum_{i=1}^n E \left[\sum_{j=1}^n \mathbb{1}_{\{h(k_i) = h(k_j)\}} \right] = \sum_{i=1}^n \left(\Pr\{h(k_i) = h(k_i)\} \cdot n \right)$

1). k отн. от всех $k_i \Rightarrow \leq \sum_{i=1}^n \frac{1}{m} = \frac{n}{m} = O(\frac{n}{m} + 1)$

2). $k = k_j, k \neq k_i \forall i \neq j \Rightarrow \leq \sum_{i=1}^n \frac{1}{m} + \Pr\{h(k_j) = h(k_j)\} = \frac{n-1}{m} + 1 = O(\frac{n}{m} + 1)$

Уч-во $\mathcal{H} = \{h_{a,b}; a \in \mathbb{Z}_p, b \in \mathbb{Z}_p\}$ $h_{a,b}(x) = (ax + b) \bmod p$
 $\mathcal{H}_{p,m}$ - универсальное сем. х-ф.

До-во $x_1, x_2 \in \mathbb{Z}_p, x_1 \neq x_2$
 1). $t(x) = (ax + b) \bmod p$
 $|\mathcal{H}_{p,m}| = p(p-1)$

$ax_1 + b \neq ax_2 + b$
 $\frac{a(x_1 - x_2)}{p} \neq 0$

Хеш-функция: $h_{a,b}(s) \rightarrow [am]$
 $h_{a,b}(s) \in \mathbb{Z}_m$
 $h_{a,b}(s) \bmod ht$

$m \sim 10^8$
 $ht \sim 2 \cdot 10^6$

$(a, b) \leftrightarrow (t(x_1), t(x_2))$ - функция в \mathbb{Z}_p^2 - $\{y_1, y_2\}$
 $(t(x_1), t(x_2)) \neq (y_1, y_2)$
 $\neq p(p-1)$

$\frac{y_1 - y_2}{p} = \frac{ax_1 + b - (ax_2 + b)}{p} = \frac{a(x_1 - x_2)}{p}$
 $x_2 y_1 - x_1 y_2 \equiv a x_1 x_2 + b x_2 - a x_2 x_1 - b x_1$
 $b(x_2 - x_1) \equiv x_2 y_1 - x_1 y_2$
 $b \equiv (x_2 y_1 - x_1 y_2) \cdot (x_2 - x_1)^{-1}$
 $\frac{y_1 - y_2}{p} = a(x_1 - x_2) \pmod{p}$

2). $h(x_1) = y_1 \bmod m$
 $h(x_2) = y_2 \bmod m$
 $y_1 = t(x_1)$
 $y_2 = t(x_2)$ (y, x) - N/A распределена на $\{(a, b) \in \mathbb{Z}_p^2 | a, b \neq 0\}$
 $\forall a, b \Pr\{y_1 = a, y_2 = b\} = \frac{1}{p(p-1)}$

Запрос $u = h(x) = y_1 \bmod m$
 $\Pr\{y_2 \bmod m = u\} = \frac{k}{p-1} \leq \frac{1}{m}$
 $\leq \frac{p-1}{m(p-1)} = \frac{1}{m}$

Хеш-таблица для хеширования строк попарно-хешом

$h_{m,x}(z) \bmod ht$
 Уч-во $h(s) = h_{m,ht}(h_{m,x}(s)) \bmod ht$ $m \in \mathbb{P}$
 $((a \cdot h_{m,x}(s) + b) \bmod m) \bmod ht$
 $\mathcal{H} = \{h_{m,x,ht}(a,b)\}$ - почти универсально
 До-во s, t
 $\Pr\{h(s) = h(t)\} = \Pr\{h_{m,x}(s) = h_{m,x}(t)\} + \Pr\{h_{m,ht}(y_1) = h_{m,ht}(y_2) | \frac{h_{m,x}(s) \neq h_{m,x}(t)}{y_1} \frac{h_{m,x}(t)}{y_2}\}$
 $\leq \frac{\max(|H_s|, |H_t|)}{m} + \frac{1}{ht-sz} \leq \frac{1}{ht-sz}$
 Максимум $m \Rightarrow$ грани строк
 $ht-sz = 10^8$
 $m \sim 10^8$
 $|H_s| \leq 10^6$
 $\frac{10^6}{10^8} + \frac{1}{10^6} = 10^{-2} + 10^{-6} \sim 10^{-2}$

Функция Блума

add(k)
 exist(s(k)) \rightarrow True/False
 $\geq \begin{bmatrix} | & | & | & | & | & | & | & | & | & | & | & | \\ \hline & & & & & & & & & & & \end{bmatrix}$
 $k \quad h_1(k) \quad h_2(k) \quad \dots \quad h_s(k)$

$m = m$ битов
 Time = s запросов х-ф
 Прогнозируем, что $\forall k_1, \dots, k_n: k_i \neq k_j \forall i \neq j$
 $h_i(k_i) \sim U\{0 \dots m-1\}$
 Независима в совокупности.
 (например, разные данные сугубо независимы)

$\Pr\{\text{ошибка}\} \leq$
 $k \rightarrow s$ значений окажется \neq
 $k \neq s$
 t_1, t_2, \dots, t_s
 $\Pr\{\exists t_i\} = 1 - \Pr\{\forall t_i \neq t_i\} = 1 - \Pr\{h_1(k) \neq t_1, \dots, h_s(k) \neq t_s\}$
 $\leq 1 - (1 - \frac{1}{m})^s$
 $\Pr\{\text{ошибка}\} = 1 - (1 - \frac{1}{m})^s \leq (1 - e^{-\frac{s}{m}})^s \leq (1 - \frac{1}{2})^{\frac{s}{m} \cdot 2} = (\frac{1}{2})^{\frac{2s}{m}}$
 $(1 - \frac{1}{m})^s = (\frac{m-1}{m})^s = (\frac{m-1}{m})^n = (1 + \frac{1}{m})^{-n} \leq e^{-\frac{sn}{(m-1)}} \leq 0.63^{\frac{sn}{m}}$
 $s = \frac{m}{n} \ln 2 \quad e^{-\frac{sn}{m}} = \frac{1}{2}$

Паросом в произв. графах (незвезда)

1) $\exists \text{ 4CN} \Leftrightarrow n/\cos \max$ (в произв. графе)
 Алгоритм сжатия совбери:

 $O(V^3), O(VE \cdot d)$
 2) d is the avg. degree
 перебираем $y \forall$ берем все ребра
 while 1
 for $i=1 \dots V$
 if i - ch: dfs(i)
 used = \emptyset
 dfs(i) shuffled(edges[i])
 3) Маршрут Тарра
 $M_{i,j} = \begin{cases} 0, \text{ ребра } (i,j) \text{ нет} \\ x_{i,j}, i > j, (i,j) \in E \\ -x_{i,j}, i < j, (i,j) \in E \end{cases}$ n^2 перебираем
 $\det M - \text{M.H. - за. от } n^2 \text{ элем.}$
 Th. $\det M \equiv 0 \Leftrightarrow \nexists$ совбери. n/\cos .
 Lm Уларца - Зуннар: $x_{i,j} \rightarrow \text{суг. } \mathbb{Z}_p$
 (если $\neq 0$) $\Pr\{\det M(x_{i,j}) = 0 \bmod p\} \leq \frac{\deg \det M}{p} = \frac{n}{p}$
 $p = 10^8 \quad n = 10^5$
 $\Pr \leq 10^{-3}$
 Rem G-группированный \rightarrow теорема для матрицы Тарра совбери.