

Универсальное семейство хеш-функций

← семейство хеш-функций \mathcal{H}

$$\forall h \in \mathcal{H}, h: K \rightarrow \{0, 1, \dots, m-1\}$$

$$\forall k_1, k_2 \substack{D_2 \\ k_1 \neq k_2} \left\{ h(k_1) = h(k_2) \right\} \leq \frac{1}{m}$$

n/m
||

Утв 1: Сложность неучтенного слова $O(1+d)$

▷ $\exists X_{ke}$ - случайная величина $h(k) = h(e)$

$E\left[\sum_k X_{ke}\right]$ - граница вероятности

$$\sum_k E[X_{ke}] \leq \sum_k \frac{1}{m} = \frac{n}{m} = d \quad \triangleleft$$

Утв 2: Сложность угарного слова $O(1+d)$

▷ $\exists X_{ke}$ - — " —

$E[X_{ke}]$
||

$$E\left[\sum_k X_{ke}\right] = \sum_k E[X_{ke}] = 1 + \sum_{k \neq e} E[X_{ke}] = 1 + \frac{n-1}{m} \approx 1 + d$$

Th. $\mathcal{H} = \{ (ak + b) \bmod p \bmod m \}$ ▷

p - простое, $p > m$, $a \in \{1, 2, \dots, p-1\}$

$b \in \{0, 1, \dots, p-1\}$

\mathcal{H} - универсальное семейство хеш-функций

▷ $\forall k_1 \neq k_2 \bmod p$

$$|\mathcal{H}| = p \cdot (p-1)$$

$$t_1 = ak_1 + b \bmod p$$

$$t_2 = ak_2 + b \bmod p$$

$$k_1 \neq k_2 \bmod p \Rightarrow t_1 \neq t_2$$

$$t_1 = t_2 \Leftrightarrow a \underbrace{(k_2 - k_1)}_{\neq 0} = 0 \bmod p$$

$$\# \{(a, b)\} = p \cdot (p-1) \iff \# \{(t_1, t_2)\}$$

(a, b) распределены равномерно на $\{1, \dots, p-1\} \times \{0, \dots, p-1\}$

$\Rightarrow (t_1, t_2)$ распределены равномерно на $\{0, \dots, p-1\}^2 \setminus \{(i, i)\}$

$$P \{t_1 = t_2 \text{ mod } m\} = \frac{1}{m}$$

Зафиксируем t_1

$$\# [t_2, t_2 = t_1 \text{ mod } m] \leq \left\lceil \frac{p}{m} \right\rceil - 1 \leq$$

$$\leq \frac{p+m-1}{m} - 1 = \frac{p-1}{m}$$

$$P_{t_1 \neq t_2} [t_1 = t_2 \text{ mod } m] = \frac{1}{p} \cdot \frac{p-1}{m} \leq \frac{1}{m} \quad \triangle$$

Совершенное хеширование

← случайную постановку

у нас дано n ключей

Посчитаем $E \left[\# \text{ коллизий в таблице} \right]$
размером n^2

$$\text{у } m = n^2$$

Возьмём УСХФ

$$E[X] = \sum_{k_1 \neq k_2} E[h(k_1) = h(k_2)] = \frac{1}{m} \cdot C_n^2 =$$

$$= \frac{1}{n^2} \cdot \frac{n \cdot (n-1)}{2} \leq \frac{1}{2}$$

Неравенство Маркова

$$P[X \geq d] \leq E[X] / d$$

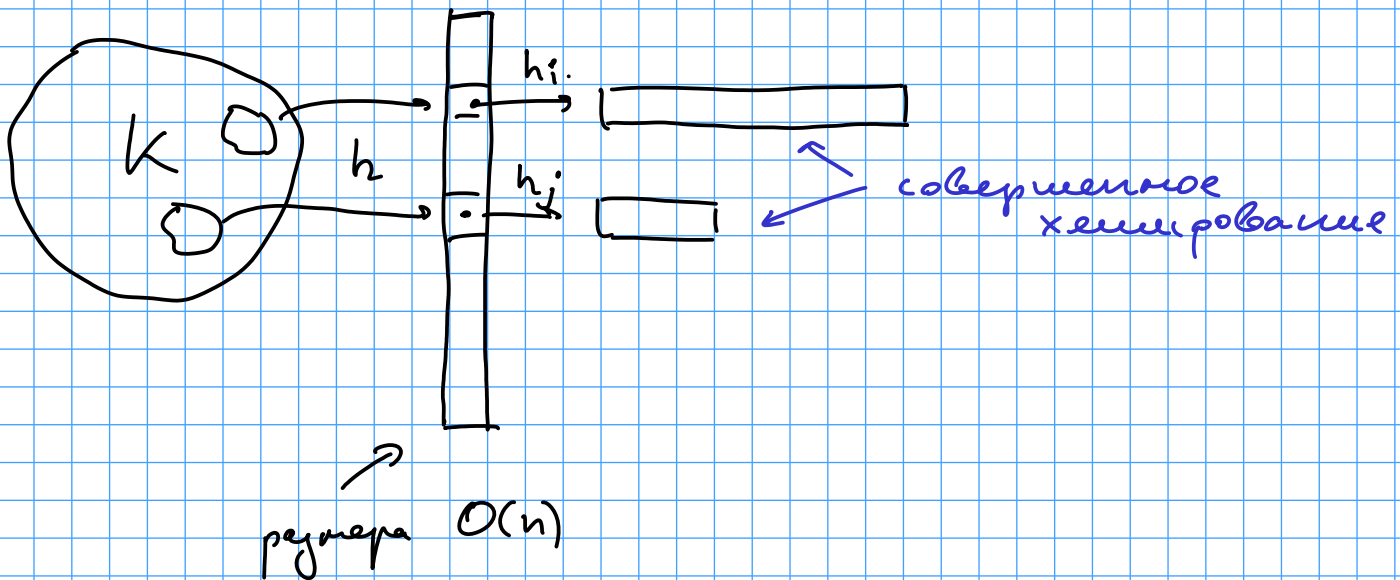
$$\begin{aligned} \triangleright E[X] &= \sum_{x_i} x_i \cdot P[X=x_i] = \sum_{x_i < d} x_i \cdot P[X=x_i] + \\ &+ \sum_{x_i \geq d} x_i \cdot P[X=x_i] \geq \sum_{x_i \geq d} x_i \cdot P[X=x_i] \geq \sum_{x_i \geq d} d \cdot P[X=x_i] = \\ &= d \cdot P[X \geq d] \\ E[X] &\geq d \cdot P[X \geq d] \quad \triangleleft \end{aligned}$$

Применим Нер-во Маркова где X :

$$P[X \geq 1] \leq \frac{1}{2} / 1 \Rightarrow \text{с вер-тью} \leq \frac{1}{2} \text{ будет комп.}$$

Проблема: $O(n^2)$ памяти

Решение: двух уровней хеширование



$\exists n_i$ - количество сл-ов в ячейке i
первой ячейке

$$\text{кол-во памяти: } \sum_i n_i^2 + O(n)$$

$$\sum n_i^2 \leq (\sum n_i)^2 = n^2$$

$$\text{Хитрость: } n_i^2 = n_i + 2 \cdot \frac{n_i(n_i-1)}{2} = n_i + 2 C_{n_i}^2$$

$$\begin{aligned}
 E\left[\sum_i n_i^2\right] &= E\left[\sum_i n_i + 2C_{n_i}^2\right] = \\
 &= n + 2 E\left[\sum_i C_{n_i}^2\right] = n + 2 \cdot \underbrace{\left(\frac{1}{n} \cdot C_n^2\right)}_{E[\# \text{коммун}] } = \\
 &= n + \frac{2}{n} \cdot \frac{n \cdot (n-1)}{2} = 2n - 1 \leq 2n
 \end{aligned}$$

$$E[\text{намерь} \geq 4n] \leq \frac{2n}{4n} \leq \frac{1}{2}$$

Доступ в таблице я $O(1)$ в хэш-таблице

Фильтр Блума

Способ хранения множества, если разрешены ошибки вида false positive

Возьмём набор хеш-функций из УСХФ.

h_1, h_2, \dots, h_k

Add(k):

Поставим 1 в ячейки $T[h_1(k)], T[h_2(k)] \dots$

Find(k):

Проверим, что $T[h_i(k)] = 1$ для всех i

] это и 71 -ов

Вероятность false positive:

$\neq h_1$

Вероятность отсутствия коллизии $ch_i = \left(1 - \frac{1}{m}\right)^n$

Вероятность отсутствия коллизии со всеми h_i
 $\left(1 - \frac{1}{m}\right)^{nk}$ (в одной ячейке)

По формуле по всем l единицам

$$\left(1 - \left(1 - \frac{1}{m}\right)^{ne}\right)^l = \left(1 - e^{-ne/m}\right)^l$$