

Хеши

Асатрян Георгий

4 января 2023 г.

# Модульная арифметика

## Определение

$$a \equiv b \pmod{N} \Leftrightarrow \exists k \in \mathbb{Z} | a = b + kN$$

## Св-ва

$$\begin{cases} a \equiv b \\ c \equiv d \end{cases} \Rightarrow \begin{cases} a + c \equiv b + d \\ ac \equiv bd \end{cases}$$

$$a^b \equiv c^d$$

$$\frac{a}{b} \equiv \frac{c}{d}$$

# Сравнение строк

## Лексикографический порядок строк

aaba  
abacaba  
abada  
abadaba  
baba

## Определение

Строка лексикографически меньше другой, если она в нее строго вложена, либо если первый отличающийся символ раньше встречается в алфавите, чем ему соответствующий.

## Как сравнивать?

Искать первый отличающийся символ долго, в худшем случае работает за  $O(|s|)$  - длину строки.

# Хеш-функция

Различных строк много - строк длины 10 -  $26^{10}$ . Длины 1000 - ... Хотим уменьшить множество рассматриваемых значений, например до чисел от 1 до  $m$ .

## Определение

Хеш-функция - это *какая-то* функция, которая по данной строке получает число. Причем для одной и той же строки всегда одно и то же число. Например - длина строки.

## Какая?

Обладает свойствами:

- Необратимости
- Лавинообразности
- Стойкости к коллизиям первого рода? (см. Википедия)
- Стойкости к коллизиям второго рода

## Парадокс дней рождения

Если мы сгенерируем  $k$  различных строк и посчитаем их хеш функции, которые все принимают значения от 1 до  $m$ , какова вероятность, что все хеши различны?

$$\left(1 - \frac{1}{m}\right)^{k \cdot (k-1)} \sim 1 - k \cdot (k-1) \frac{1}{m} \sim 1 - \frac{k^2}{m}$$

В некоторых задачах,  $k$  может достигать  $1e7$ , а то и  $1e8$ , при этом у задачи может быть скажем 100 тестов, и мы хотим, чтобы задача заходила с вероятностью 99%.

$$\left(1 - \frac{k^2}{m}\right)^{100} \geq 1 - \frac{1}{100} \sim \frac{100k^2}{m} \leq \frac{1}{100} \Leftrightarrow m \geq 1e4k^2$$

# Полиномиальные хеши

Зафиксируем  $p, m$  - простые числа (на самом деле не обязательно).  
При этом  $p$  больше размера алфавита (а лучше сильно больше).

## Определение 1

$$h_1(s) = s_0 + p \cdot s_1 + \dots + p^{n-1} \cdot s_{n-1} \mod m$$

## Определение 2 $\leftarrow$ пользуемся им

$$h_2(s) = p^{n-1} \cdot s_0 + p^{n-2} \cdot s_1 + \dots + s_{n-1} \mod m$$

## Св-ва

$$h_2(s|t) = p^{|t|} \cdot h_2(s) + h_2(t) \mod m$$

$$h_2(s[a; b]) = h_2(s[0; b]) - p^{b-a} \cdot h_2(s[0; a]) \mod m$$

## Сравнение строк, маленький модуль

Равны ли две строки? Сравним их хеши, если хеши равны, то будем надеяться что и строки равны (это не гарантируется). Если не равны (в частности мы точно знаем, что они не равны, если их длины различны) и мы хотим найти какая из них меньше, то совершим двоичный поиск(где здесь монотонность?).

Мы выяснили, что  $m = 1e9$  не достаточно, а как лучше? Делать больший модуль сложно из-за ограничений языков (про переполнение далее), поэтому лучшее, что мы можем сделать, это посчитать несколько хешей (можно взять тот же  $p$  но другое  $m$  и мы  $\sim$  возвели в квадрат количество различных значений, когда совсем все плохо, можно еще и по третьему модулю посчитать)

# Хорошие и плохие практики

- Модуль  $1e9 + 7$ ,  $1e9 + 9$  - плохой модуль. Модуль  $2^{64}$  - плохой модуль. Любой другой простой модуль  $\sim 1e9$  обычно хороший модуль.
- Когда ты хочешь заменить хеш на двойной(тройной) хеш, идти по всему коду и добавлять вторую строчку - очень плохо, вынести подсчет хешей в отдельный класс/ функции - хорошо.

# Плюсы, переполнение, взятие по модулю

