


Datové struktury 1

6. Přednáška 11.11.

Pavel Veselý

Plán: Hešování

- Házení míčků do košů
- Narozeninový paradox
- Hešovací funkce:
 - Univerzální = malá pravděpodobnost kolize dvou prvků
 - k -nezávislé = k prvků se hešuje nezávisle
- Příště: řešení kolizí



Hešování

- Prvkům z univerza $\mathcal{U}$ přiřadíme „náhodná“ čísla
 - Nebo alespoň „náhodně vypadající“

Hešovací funkce: $h: \mathcal{U} \rightarrow [m]$

- Příklad:
 - $h(x) = a \cdot x \bmod m$, kde a je nesoudělné s m

```
int getRandomNumber()  
{  
    return 4; // chosen by fair dice roll.  
              // guaranteed to be random.  
}
```

Autor: Randall Munroe, <https://xkcd.com/221/>, Creative Commons Attribution-NonCommercial 2.5 License.

Aplikace:

- Hešovací tabulka
- Bloom filtry
- Vzorkování
-

Hešovací tabulka

- Reprezentace množiny klíčů (nebo slovníku)
 - Operace Find, Insert, Delete
- Tabulka $\approx$ pole přihrádek velikosti m
- **Kolize** = dva prvky skončí ve stejné přihrádce

Hlavní části hešovací tabulky:

1. Hešovací funkce


2. Řešení kolizí

- **Separované řetězce** – spojový seznam (či dynamické pole) v každé buňce
- Příště lepší...

3. Dynamizace: udržujeme určité maximální (a minimální) zaplnění

- Přehéšujeme do nové tabulky – podobně jako dynamické pole

Hešování jako házení míčků do košů



- n míčků a m košů
 - Každý míček nezávisle hozen do koše
 - Jak to souvisí s hešováním?
- Opakování pravděpodobnosti:
 - Co jsou elementární jevy Ω ?
 - Co je náhodná veličina? Co je její střední hodnota?
- Pro házení míčků:
 - Střední hodnota # míčků v libovolném koši je $\frac{n}{m}$
 - S velkou pravděpodobností bude mít nejplněší koš $\Theta\left(\frac{\log(n)}{\log \log(n)}\right)$ míčků
 - Důkaz Černovovou nerovností vynechán

Kdy nenastanou žádné kolize?

- n míčků a m košů
- Pokud $m \gg n$, nastane kolize?
 - Pro jaký poměr m/n už kolize nenastane s pstí. $\geq 50\%$?
 - Odpověď: potřebujeme $m = \Omega(n^2)$ a zároveň to stačí
 - Tedy pro $m \gg n^2$ žádná kolize s velkou pstí
a **pro $m \ll n^2$ nastane kolize s velkou pstí**
- Narozeninový „paradox“:
 - Pokud je v místnosti ≥ 23 lidí,
mají dva stejné narozeniny s pstí. $\geq 50\%$



n	$p(n)$
1	0.0%
5	2.7%
10	11.7%
20	41.1%
23	50.7%
30	70.6%
40	89.1%
50	97.0%
60	99.4%
70	99.9%
75	99.97%
100	99.999 97%
200	$(100 - 2 \times 10^{-28})\%$
300	$(100 - 6 \times 10^{-80})\%$
350	$(100 - 3 \times 10^{-129})\%$
365	$(100 - 1.45 \times 10^{-155})\%$
≥ 366	100%

Hešovací funkce (aneb jak implementujeme házení)

- **Plně náhodná** (každý prvek z $\mathcal{U}$ zahešován uniformně a nezávisle na ostatních)
 - Potřebuje prostor $\Omega(\mathcal{U})$ na uložení ☹
- **Pevná funkce**
 - Lze na ní zaútočit – způsobit velký počet kolizí ☹
- **Náhodný výběr z množiny funkcí**
 - Např. funkce má několik parametrů volených náhodně
- Pro srovnání: **kryptografické hešovací funkce**
 - Např. MD5, rodina SHA, ...
 - Mnohem silnější požadavky:
 - Těžké najít kolizi nebo funkci invertovat
 - ... ale pomalejší

Input data is *not* random!
So good hash functions *must be* random!

Autor: Jeff Erickson

Co chceme od rodiny hešovacích funkcí $\mathcal{H}$?

- Rychlé vyhodnocení + málo prostoru
 - Typicky výpočet v $O(1)$ z parametrů, které vygenerujeme náhodně na začátku
- Uniformita: $\forall x \in \mathcal{U} \forall y \in [m]: \Pr_{h \in \mathcal{H}}[h(x) = y] \leq c/m$
- Univerzalita: malá pravděpodobnost kolize
 - $\forall x_1, x_2 \in \mathcal{U}, x_1 \neq x_2: \Pr_{h \in \mathcal{H}}[h(x_1) = h(x_2)] \leq c/m$
 - Příklad: multiply-shift: w -bitová čísla na ℓ -bitová
 - $h_a(x) = \frac{a \cdot x \bmod 2^w}{2^{w-\ell}}$, kde a je liché
 - 2-univerzální (bez důkazu)

$c > 0$ je konstanta

```
#include <stdint.h> //defines uint64_t as unsigned 64-bit integer.
uint64_t hash(uint64_t x, uint64_t l, uint64_t a) {
    // hashes x universally into l<=64 bits using random odd seed a.
    return (a*x) >> (64-l);
}
```

Co chceme od rodiny hešovacích funkcí $\mathcal{H}$?

- Rychlé vyhodnocení + málo prostoru
 - Typicky výpočet v $O(1)$ z parametrů, které vygenerujeme náhodně na začátku
- Uniformita: $\forall x \in \mathcal{U} \forall y \in [m]: \Pr_{h \in \mathcal{H}}[h(x) = y] \leq c/m$
- Univerzalita: malá pravděpodobnost kolize
 - $\forall x_1, x_2 \in \mathcal{U}, x_1 \neq x_2: \Pr_{h \in \mathcal{H}}[h(x_1) = h(x_2)] \leq c/m$
- 2-nezávislost: každé dva prvky se hešují (skoro) nezávisle
 - $\forall x_1, x_2 \in \mathcal{U}, x_1 \neq x_2, \forall y_1, y_2 \in [m]:$
 $\Pr_{h \in \mathcal{H}}[h(x_1) = y_1 \& h(x_2) = y_2] \leq c/m^2$
- Obecněji: k -nezávislost pro $k \geq 1$
- Příklad 2-nezávislé rodiny: lineární kongruence
- Cvičení:
 - 2-nezávislost implikuje univerzalitu (ale ne obráceně)
 - k -nezávislost implikuje $(k - 1)$ -nezávislost (ale ne obráceně)

Tabelace (tabulkové hešování, Zobristovo)

- $[2^w] \rightarrow [2^\ell]$ pro $w = k \cdot t$
- Rozdělíme klíč na k částí $x^{(1)}, x^{(2)}, \dots, x^{(k)}$ o t bitech
 - Každá část hešována plně náhodnou fcí
 - Tedy máme k tabulek T_i pro funkce $[2^t] \rightarrow [2^\ell]$
 - Prostor celkově $k \cdot 2^t \cdot \ell$ bitů
 - Heše pro jednotlivé části vyxorujeme, tedy
$$T_1(x^{(1)}) \oplus T_2(x^{(2)}) \oplus \dots \oplus T_k(x^{(k)})$$
- Tabelace je 3-nezávislá
 - ale ne 4-nezávislá, pokud máme alespoň dvě tabulky

Příště

- Zase hešování 😊
 - Řešení kolizí – tedy jak vypadají ty „koše“
 - S kukačkou
 - Lineárním přidáváním
 - Navíc také: *The power of two choices*

