

Datové struktury 1

8. Přednáška 25.11.

Pavel Veselý


Plán: Naposledy hešování

- Bloomův filtr
 - Pravděpodobnostní DS pro přibližnou reprezentaci množiny
- Hešování vektorů a řetězců
 - + jak udělat z univerzální funkce 2-nezávislou

Proudové (streaming) algoritmy a datové skeče



- Jeden průchod přes data
- S malou pamětí
 - menší než data
- Skeč dat
 - = obsah paměti algoritmu
- Cena: ztratíme přesnost
 - Povolíme si „malé“ chyby
- Triviální: počet prvků, součet čísel
- Zajímavější: počet *různých* prvků
- Často založené na hešování...



Paměť a rychlost vs. chyba

Bloomův filtr pro přibližnou reprezentaci množiny [Bloom '70]

- Pro daný prvek řekne, jestli už byl přidán nebo ne
 - Pokud odpoví **NE**, tak jsme prvek neviděli
 - Pokud odpoví **ANO**, tak nevíme...
 - „False positive“ (FP) – prvek jsme neviděli, ale Bloom filtr řekl **ANO**
- Jak vypadá Bloom filtr?
 - Parametr m = prostor v počtu bitů
 - Pole m bitů
 - k hešovacích funkcí $h_1, \dots, h_k$
 - Např. $k = 5$
- Insert(x): **Nastavíme** buňky $h_1(x), \dots, h_k(x)$ na 1
- Query(x): Viděli jsme prvek x ?
 - **NE**, pokud je jedna z buněk $h_1(x), \dots, h_k(x)$ rovna 0
 - Jinak **ANO**
 - může se splést

Viděli jsme někdy
toto číslo?

Bloomův filtr: varianty

- **1-pásmový**: jedno pole m bitů, ale k hešovacích funkcí
 - Stejné garance, ale těžší analýza
- **Počítací Bloomův filtr** – umí i mazání
 - V buňkách b -bitová počítadla
 - Např. $b = 4$
 - Insert zvýší k počítadel, Delete sníží
 - Query vrátí **NE**, pokud je jedno z k počítadel nulové
 - Pokud $B_i[j] = 2^b - 1$, pak počítadlo zamrzne

Přehledka rodin hešovacích funkcí

Pro čísla:

- **Lineární kongruence:** $\mathcal{L} := \{h_{a,b} | a, b \in \mathbb{Z}_p\}$
 - $h_{a,b}(x) = (a \cdot x + b) \bmod p \bmod m$
 - 2-nezávislé
- **Náhodný polynom stupně $k - 1$ nad $\mathbb{Z}_p$**
 - $h_{a_0, \dots, a_{k-1}}(x) = (\sum_{i=1}^k a_i \cdot x^{i-1}) \bmod p \bmod m$
 - k -nezávislé
- **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)
- **Tabulkové hešování (tabelace)**
 - 3-nezávislé a má jiné zajímavé vlastnosti

Pro vektory a řetězce:

- **Skalární součin**
- **Rolling hash** – polynom s koeficienty ze vstupního vektoru vyhodnocený v náhodném bodě

Vskuvka: zrychlení operace modulo

- Např. $(a \cdot x + b) \bmod p \bmod m$
- **Modulo 10 krát nebo víc pomalejší než násobení**
- Co s tím?
 - p známé při kompilaci
 - $\bmod 2^k$ rychlé (AND)
 - Mersennovo prvočíslo $p = 2^q - 1$
 - Příklad: 3, 7, 31, 127, $2^{13} - 1$, $2^{17} - 1$, $2^{19} - 1$, $2^{31} - 1$, $2^{61} - 1$, $2^{89} - 1$
 - Pro $x \leq 2^{2q} - 1$:
 - $a = (x \& p) + (x \gg q)$
 - If $a \geq p$ then return $a - p$
 - Else return a

Příště

- Už nebude hešování 😊
- DS pro řetězce: sufixové pole a stromy