


Datové struktury 1

5. přednáška

Pavel Veselý


Plán

- **cache-oblivious** transpozice
- Online algoritmy pro správu cache
 - Aneb: co když neznáte budoucnost?
- Hešování!!!



I/O složitost pro dvě úrovně



- Pomalá paměť: **disk, externí paměť**
 - Složena z **bloků** velikosti B
- Rychlá paměť: **cache, interní paměť**
 - Velikost M , také rozdělena na **bloky** velikosti B
- I/O složitost: # přesených bloků
 - Příklad sekvenční průchod polem délky N
 - I/O složitost $O(N/B + 1)$



Zdroj obrázku: Demaine: Cache-Oblivious Algorithms and Data Structures

Teoretické modely

- **I/O model**
a **cache-aware** algoritmy a DS
 - Známe parametry M a B
- **Cache-oblivious** algoritmy a DS
[Frigo, Leiserson, Prokop, Ramachandran, 1999]
 - Nepotřebují znát M a B
 - fungují na různých architekturách
a efektivně využívají celou paměťovou hierarchii



Předpoklady modelu (které lze odstranit)


1. Cache řízena algoritmem (optimálně)

- Algoritmus rozhoduje, která stránka je vyhozena z cache
- Optimální algoritmus na správu cache:
 - *Longest Forward Distance (LFD)*: vyhodí blok, který bude potřeba nejpozději v budoucnu
- Odstraníme pomocí *Least Recently Used (LRU)*

2. Tall cache assumption: $\frac{M}{B} \geq \Omega(B)$... tedy # bloků je $\Omega(B)$

- Není potřeba vždy

3. Plná asociativita: blok může být kdekoliv v cache



Matice $N \times N$

- Uložena po řádcích
 - Průchod po řádcích má I/O složitost $O(N^2/B + 1)$
 - Ale průchod po sloupcích $\Omega(N^2)$ (leďaže $M/B > N$)
- Transpozice
 - **cache-aware** – rozdělení na podmatice $B \times B$
 - transponujeme podmatice a prohazujeme přes diagonálu
 - I/O složitost $O(N^2/B + 1)$
 - **cache-oblivious** – rozděl a panuj!
 - I/O složitost $O(N^2/B + 1)$

Online správa cache



- Nemáme optimální algoritmus OPT pro správu cache

- **Online algoritmus**


- rozhoduje se bez znalosti budoucí části vstupu
- vs. klasický „offline“ algoritmus – zná celý vstup dopředu
- Online rozhodnutí: který blok vyhodit z cache?



- **Least Recently Used (LRU)**

- odstraní z cache blok, ke kterému bylo přistoupeno nejdále v minulosti

- Cena algoritmus = # výpadků, tedy načtení bloku (cache misses)



Definice: Algoritmus ALG je α -kompetitivní, pokud na libovolném vstupu platí:

$$\text{cena ALG} \leq \alpha \cdot (\text{cena OPT}) + \text{konstanta nezávislá na vstupu}$$

- Kompetitivní poměr $\text{ALG} = \inf \{ \alpha \mid \text{ALG je } \alpha\text{-kompetitivní} \}$

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

Aplikace:

- **Hešovací tabulka**
 - Vzorkování
 - Hledání duplikátů
 - Vyhledávání v textu
- **Bloom filtry**
 - Datové skeče
 - technika MinHash
 - CountSketch
 - ...

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
- **Otevřená adresace** – v přihrádce max. jeden klíč (přespříště)
- **Kukaččí hešování** (přespříště)

- ## 3. Dynamizace: udržujeme určité maximální (a minimální) zaplnění
- Přehéšujeme do nové tabulky – podobně jako dynamické pole

Hešovací tabulka se separovanými řetězci

- Prozatím: **plně náhodná hešovací funkce**
 - každý prvek z $\mathcal{U}$ zahešován uniformně a nezávisle na ostatních
- Find(x): projdeme řetězec v přihrádce $h(x)$
- Insert(x): vložíme na začátek řetězce $h(x)$
 - ale musíme ověřit, jestli už tam není
- Delete(x): projdeme řetězec na $h(x)$
- Vše tedy v $O(\text{délka řetězce na } h(x))$

Hešovací funkce

- **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
 - Cíle:
 - Malá pravděpodobnost kolizí
 - Dvojice prvků se hešují nezávisle

Příště

- Hešování 😊
 - Hešovací funkce univerzální, k -nezávislé, ...