

8. CVIČENÍ Z DATOVÝCH STRUKTUR 1, ZS23/24

Hešování univerzální, nezávislé, tabulační a možná i perfektní

1. *Univerzální nezávislost.*

- Dokažte, že $(2, c)$ -nezávislost implikuje c -univerzalitu.
- Dokažte, že (k, c) -nezávislost implikuje $(k - 1, c)$ -nezávislost.

2. *Varianty lineární funkcí modulo p .* Na přednášce byl důkaz 2-nezávislosti systému $\mathcal{H}_{\text{lin}} := \{h_{a,b} \mid a, b \in [p]\}$ pro prvočíslo p , kde $h_{a,b}(x) := ((ax + b) \bmod p) \bmod m$.

- Zdůvodněte, že \mathcal{H}_{lin} není 3-nezávislá.
- Co kdybychom měli vždy $b = 0$, tedy volili náhodně jen a ? Bude výsledná rodina c -univerzální? Bude 2-nezávislá?

3. *Tabulační (tabulkové) hešování.*

- Ukažte, že tabulační hešování je 2-nezávislé.
- Ukažte, že tabulační hešování *není* 4-nezávislé, pokud používáme alespoň dvě tabulky.
- Bonus: ukažte 3-nezávislost.

4. *Perfektní hešování dle Fredmana, Komlóse a Szemerédiho (FKS)*. Máme dānu n -prvkovou množinu S jako podmnožinu nějakého (obrovského) univerza \mathcal{U} , např. 64-bitové integery. Cílem je navrhnout pro S datovou strukturu velikosti $O(n)$, která zvládne pro zadaný dotaz x zjistit, jestli x náleží v S , v konstantním čase vždy. (V čem klasická hešovací tabulka velikosti $O(n)$ nesplňuje požadavky?)

- a) Připomeňte si narozeninový paradox, tedy nejmenší počet lidí s rovnoměrně náhodnými narozeninami takový, aby s pravděpodobností alespoň 50% měli dva stejné narozeniny.
- b) Hešování s úplně náhodnou (nebo c -univerzální) hešovací funkcí funguje podobně. Jak zhruba musíme mít velkou tabulku, aby nastala kolize s pravděpodobností méně jak 50%?
- c) Perfektní hešování vybudujeme takto: Pořídíme si hešovací funkci $h : \mathcal{U} \rightarrow [m]$ pro $m = O(n)$, kterou vybereme náhodně z c -univerzální rodiny. Pro každou přihrádku $i \in [m]$ zavedeme tabulku druhé úrovně, která bude dost velká, aby tam nenastala kolize s pravděpodobností alespoň 50% (pokud by kolize nastala, změníme hešovací funkci).
- d) Teď už stačí jen omezit celkovou velikost tabulek druhé úrovně ve střední hodnotě.