

Velké otázky

1. Definujte Splay strom. Popište, jak na něm probíhají operace Splay, Find, Insert a Delete. Popište výhody a nevýhody oproti jiným datovým strukturám, zejména vyváženým vyhledávacím stromům. Vyslovte a dokažte větu o amortizované složitosti operace Splay.

- strom, ve kterém všechny operace vykonáváme pomocí Splay
- neřešíme vyváženost, ale dokážeme, že Splay se vždy uamortizuje na log
- **Splay**: vybraný vrchol přesunu do kořene pomocí rotací, přičemž preferuji dvojrotace
 - každý Splay použije nejvýše jednu jedno-rotaci
- **Find**: Najdu vrchol jako v BVS, vysplayuji nalezený nebo poslední navštívený do vrcholu
- **Insert**: Insert jako do normálního BVS, vysplayuji nalezený/vložený vrchol do kořene
 - **přidání listu může být drahé**

- zvýším rank všem vrcholům na cestě do kořene

-

$$\Delta\Phi = r'(v_{t+1}) + \sum_{i=1}^t r'(v_i) - r(v_i)$$

- jejich rank se zvýší o 1, což se dá odhadnout zhora původním rankem jejich rodiče –
 $r'(v_i) \leq r(v_{i-1})$

- $r'(v_{t+1}) = 0$ (je to list)

-

$$\Delta\Phi \leq r'(v_1) - r(v_t)$$

- **Delete**: Najdu vrchol k odstranění, vysplayuji do vrcholu, odstráním, vysplayuji nejpravější vrchol levého podstromu, spojím dohromady

- výhody

- sequential access

- working set

- $\Rightarrow$ vyhledání m prvků z podmnožiny velikosti s je $\mathcal{O}(n \log n + m + m \log s)$

- **složitost Splay**:

- zavedeme $r(x)$ (rank vrcholu) jako $\log(s(x))$

- potenciál je $\Phi = \sum_{x_i \in V} r(x_i)$

- dvojrotace mají amortizovanou cenu $A = 3r'(x_i) - 3r(x_i)$, jednorotace $A = 3r'(x_i) - 3r(x_i) + 1$ (r je před rotací, r' je po)

- celá Splay je pak posloupnost rotací jednoho vrcholu, $A = \left(\sum_i 3r_i(x) - 3r_{i-1}(x)\right) + 1$, všechny až na poslední rotaci jsou dvojrotace, teleskopická suma se počítá na

$$A = 3r_n(x) - 3r_0(x) + 1$$

(kde +1 je z poslední rotace)

- **zig-zag**:

- $A = 2 + r'(x) + r'(w) + r'(y) - r(x) - r(w) - r(y)$

- $s'(w) + s'(y) \leq s'(x)$

- $r'(w) + r'(y) \leq 2 \log(s'(w) + s'(y)) - 2 \leq 2r'(x) - 2$

- $A \leq 3r'(x) - r(x) - r(w) - r(y)$

- $r(x) \leq r(w), r(x) \leq r(y)$

- $A \leq 3r'(x) - 3r(x)$

- **zig-zig**:

- $A = 2 + r'(x) + r'(y) + r'(z) - r(x) - r(y) - r(z)$

- $s(x) + s'(z) \leq s'(x)$

- $r(x) + r'(z) \leq 2 \log(s(x) + s'(z)) - 2 \leq 2r'(x) - 2$

- $A \leq 3r'(x) + r'(y) - 2r(x) - r(y) - r(z)$

- $r'(x) \geq r'(y), r(x) \leq r(y), r(z) = r'(x)$

- $A \leq 3r'(x) + r'(x) - 2r(x) - r(x) - r'(x)$
- $A \leq 3r'(x) - 3r(x)$

► **zig:**

- $A = 1 + r'(x) + r'(y) - r(x) - r(y)$
- $r(x) \leq r(y), r'(x) \geq r'(y)$
- $A \leq 1 + 2r'(x) - 2r(x)$
- $r'(x) - r(x) \geq 0$
- $A \leq 1 + 3r'(x) - 3r(x)$

2. Definujte (a,b)-strom. Popište, jak na něm probíhají operace Find, Insert a Delete. Vyslovte a dokažte větu o amortizovaném počtu změn uzlů pro operace Insert a Delete a (a,2a)-stromech. Jak se to liší pro (a,2a-1)-stromy? Popište výhody a nevýhody oproti jiným datovým strukturám, zejména vyváženým binárním vyhledávacím stromům.

- stromy, kde počet potomků každého vrcholu je mezi a a b , kde $b \geq 2a - 1$
- **hloubka:** $\Theta(\log_b n), \mathcal{O}(\log_a n)$
- **Find:** musíme projít $\mathcal{O}(h) = \mathcal{O}(\log_a n) = \mathcal{O}(\log n / \log a)$ vrcholů, v každém vrcholu vrchol najdeme binárním vyhledáváním v $\mathcal{O}(\log b)$, celkově $\mathcal{O}(\log n \cdot \log b / \log a)$
- **Insert:** přidáme klíč do nejnižšího vrcholu, splitujeme, je-li třeba, split trvá $\mathcal{O}(b)$, celkově $\mathcal{O}(b \cdot \log n / \log a)$
- **Delete:** odstraníme klíč a nahradíme maximem levého podstromu, buď se mergem se sousedem, nebo z něj půjčíme klíč (soused $\rightarrow$ rodič $\rightarrow$ my)
- m po sobě jdoucích insertů do prázdného stromu je v $\mathcal{O}(m)$
 - každý split zvýší množství vrcholů, merge neděláme, vrcholů je $\mathcal{O}(m)$
- **věta:** pro (a,2a)-stromy taky m po sobě jdoucích insertů a deletů do prázdného stromu je v $\mathcal{O}(m)$

► určíme si potenciál podle počtu klíčů ve vrcholu $(a, 2a) \rightarrow (a - 1, 2a - 1)$

k	$a - 2$	$a - 1$	a	...	$2a - 2$	$2a - 1$	$2a$
$f(k)$	2	1	0	0	0	2	4

► přidání/odebrání vrcholu - $|f(i) - f(i + 1)| \leq c$

► split:

- $f(2a) \rightarrow f(a) + f(a - 1) + \underbrace{c}_{\text{přidání vrcholu do rodiče}} + \underbrace{1}_{\text{skutečná cena}}$
- $4 \geq 0 + 1 + 2 + 1$

► merge:

- $f(a - 2) + f(a - 1) \rightarrow f(2a - 2) + \underbrace{c}_{\text{ubrání vrcholu z rodiče}} + \underbrace{1}_{\text{skutečná cena}}$
- $2 + 1 \geq 0 + 2 + 1$

► **důsledek:** Libovolná posloupnost m Insertů a Deletů je $\mathcal{O}(n + m)$ (můžu postavit posloupnost n Insertů do prázdného stromu)

- výhody:
 - cache-aware
 - amort. konstantní složitost operací
- nevýhody??

3. Definujte I/O model pro správu cache a srovnajte cache-aware a cache-oblivious algoritmy. Vyslovte a dokažte Sleatorovu-Tarjanovu větu o kompetitivnosti LRU. Popište přínos této věty pro analýzu cache-oblivious algoritmů.

- externí a interní paměť
 - interní má omezenou velikost M

- externí je neomezená, ale lze číst a zapisovat pouze načtením bloku velikosti B do interní paměti
- I/O složitost se obvykle určuje jen ve čteních z externí paměti, protože zápisy jsou většinou čteními zhora omezené
- algoritmus neovládá, které bloky se vyhodí z keše, je použit nějaký online algoritmus
- algoritmus OPT vyhazuje vždy ten blok, který bude potřeba nejdále v budoucnosti – optimum
- algoritmus LRU vyhazuje ten blok, který byl použit nejdále v minulosti
 - umíme dokázat, že to není tak špatné:

$$C_{\text{LRU}} \leq \frac{M_{\text{LRU}}}{M_{\text{LRU}} - M_{\text{OPT}}} \cdot C_{\text{OPT}} + M_{\text{OPT}}$$

tedy, pokud $M_{\text{LRU}} = 2 \cdot M_{\text{OPT}}$:

$$C_{\text{LRU}} \leq 2C_{\text{OPT}} + M_{\text{OPT}}$$

• **důkaz**

- rozdělme posloupnost přístupů k blokům do *epoch* $e_0, \dots, e_n$, tak, aby pro každou epochu kromě e_0 platilo $C_{\text{LRU}}(e_i) = M_{\text{LRU}}$, pro e_0 : $C_{\text{LRU}}(e_0) \leq M_{\text{LRU}}$
- pro každou epochu kromě e_0 platí jedna z možností:
 - všechny missnuté prvky jsou různé, takže $C_{\text{OPT}}(e_i) \geq M_{\text{LRU}} - M_{\text{OPT}}$
 - některý prvek byl missnut vícekrát, takže mezi jeho načteními muselo být přistoupeno ke všem ostatním prvkům keše, takže opět $C_{\text{OPT}}(e_i) \geq M_{\text{LRU}} - M_{\text{OPT}}$
- tedy $C_{\text{LRU}}(e_i) = M_{\text{LRU}}$ a $C_{\text{OPT}}(e_i) \geq M_{\text{LRU}} - M_{\text{OPT}}$:

$$\frac{C_{\text{LRU}}(e_i)}{C_{\text{OPT}}(e_i)} \leq \frac{M_{\text{LRU}}}{M_{\text{LRU}} - M_{\text{OPT}}}$$

- pro e_0 pak platí:
 - pokud keše začínají prázdné, všechny missy LRU jsou různé a OPT je všechny musí načíst taky, proto $C_{\text{OPT}}(e_0) \geq C_{\text{LRU}}(e_0)$
 - pokud LRU obsahuje bloky, nějaký miss se může proměnit v hit, ale výsledný LRU seznam se nezmění
 - pokud OPT obsahuje bloky, budou to přesně ty, které bude v e_0 potřebovat, tedy $C_{\text{OPT}}(e_0) \geq C_{\text{LRU}}(e_0) - M_{\text{OPT}}$
- po zprůměrování přes epochy $e_1 \dots e_n$ a M_{OPT} z e_0 získáme chtěný vztah
- **důsledek:** ve většině zkoumaných algoritmů je závislost na M taková, že vynásobení konstantou cM (v tomto případě $c = 2$) se asymptotika nezmění, takže lze předpokládat OPT, i když se použije LRU

4. Definujte c -univerzální a k -nezávislé rodiny hešovacích funkcí. Uveďte příklady, kde nestačí c -univerzální rodina hešovacích funkcí, ale musíme použít k -nezávislou rodinu. Formulujte a dokažte větu o střední délce řetězce v hešování s řetězcí. Ukažte příklady c -univerzálních a k -nezávislých rodin pro hešování přirozených čísel. Pro jeden příklad dokažte c -universalitu nebo k -nezávislost, pro $k \geq 2$.

- pro danou konstantu c , je rodina hashovacích funkcí $\mathcal{H} : \mathcal{U} \rightarrow [m]$ c -univerzální, pokud pro všechny různé dvojice $x, y \in \mathcal{U}$:

$$\Pr_{h \in \mathcal{H}} [h(x) = h(y)] \leq \frac{c}{m}$$

- pro dané k a konstantu c , je rodina hashovacích funkcí $\mathcal{H} : \mathcal{U} \rightarrow [m]$ (k, c) -nezávislá, pokud pro každou k -tici různých $x_1 \dots x_k \in \mathcal{U}$ a $y_1 \dots y_k \in [m]$:

$$\Pr_{h \in \mathcal{H}} [h(x_1) = y_1 \wedge \dots \wedge h(x_k) = y_k] \leq \frac{c}{m^k}$$

- právě lineární adresování potřebuje 5-nezávislost pro konstantní čas, případně kukačky, also [T] se odkazuje na QuickSort

- **délka řetězce:**

- věta: pro c -univerzální rodinu $\mathcal{H} : \mathcal{U} \rightarrow [m]$, $X = \{x_1, \dots, x_n\}$ prvky v ní uložené, a y prvek neuložený:

$$\mathbb{E}_{h \in \mathcal{H}} [\#i : h(x_i) = h(y)] \leq \frac{cn}{m}$$

- dk: necht' A_i je indikátorová veličina, že $h(x_i) = h(y)$, $\mathbb{E} A_i \leq \frac{c}{m}$ z c -univerzality, $\mathbb{E} \sum_i A_i = \sum_i \mathbb{E} A_i \leq \frac{cn}{m}$
- důsledek:
 - neúspěšné vyhledávání projede celý řetízek s $h(y)$, takže $\leq \frac{cn}{m}$
 - úspěšný insert nejdřív provede neúspěšné vyhledávání, $\leq \frac{cn}{m}$
 - úspěšné vyhledávání projde nejvýše tolik prvků, kolik prošlo přidání daného prvku $\leq \frac{cn}{m}$
 - neúspěšný insert odpovídá úspěšnému vyhledávání, $\leq \frac{cn}{m}$
 - delete odpovídá úspěšnému/neúspěšnému vyhledávání $\leq \frac{cn}{m}$
- tedy, pokud je $m \in \Omega(n)$ jsou operace na řetízkové hashovací tabulce konstantní
- příklady:
 - **Lineární kongruence:** pro prvočíslo p a $m < p$,

$$\mathcal{L} : [p] \rightarrow [m] : \{h_{a,b} \mid a, b \in \mathbb{Z}_p\}$$

$$h_{a,b}(x) = ((ax + b) \bmod p) \bmod m$$

- v $\mathbb{Z}_p$ existuje pro dané různé x, y a soustavu:

$$r = (ax + b) \bmod p$$

$$s = (ay + b) \bmod p$$

bijekce mezi páry (r, s) a (a, b)

- $\Pr[h_{a,b}(x) = r \wedge h_{a,b}(y) = s] = \frac{1}{p^2}$ pro rovnoměrně náhodně vybrané a, b
- bez druhého mod m je tedy rodina 2-nezávislá, lemma o modulu říká, že s ním to bude jen $2c$ horší

- **Polynomiální hashování:**

$$\mathcal{P}_k : [p] \rightarrow [p] : \{h_t(x) \mid t \in \mathbb{Z}_p^k\}$$

$$h_t(x) = \sum_{i=0}^{k-1} t_i x^i \bmod p$$

- je k -nezávislé, neboť pro $x_1 \dots x_k$ a $a_1 \dots a_k$ existuje právě jeden polynom stupně nejvýše k takový, že platí: $\forall i : p(x_i) = a_i$
- takových polynomů je p^k , máme $(k, 1)$ -nezávislost
- pro $[p] \rightarrow [m]$, kde $p > 2km$ dává modulí lemma $(k, 2)$ -nezávislost

- Multiply-shift
- Tabulkové hashování

5. Popište a analyzujte hešování s lineárním přidáváním s plně náhodnou hešovací funkcí a např. třetinovým zaplněním. Popište výhody a nevýhody oproti jiným datovým strukturám, zejména založeným na hešování.

- do každého kyblíku hashujeme pouze jeden prvek, v případě kolize hledáme $h(x) + i \bmod m$
- pro zaplněnost $\leq \frac{1}{3}$ (tedy $m \geq 3n$) a plně náhodnou hashovací funkci dokážeme konstantní délku „běhů“
 - nechť $n = \frac{m}{3}$ (horší už to být nemůže)
 - kyblíky $[m]$ rozdělíme postupně na po sobě jdoucí bloky velikosti 2^t (jako úplný binární strom)
 - blok je *kritický*, pokud se do něj **zahashuje** $\frac{2}{3} \cdot 2^t$ prvků
 - **Černovova nerovnost**: Pro nezávislé náhodné veličiny s hodnotami $\{0, 1\}$, jejich součet $X = X_1 + \dots + X_k$, $\mu = \mathbb{E}[X]$ a $c > 1$:

$$\Pr[X \geq c\mu] = \left(\frac{e^{c-1}}{c^c} \right)^\mu$$

- Pravděpodobnost, že blok B velikosti 2^t je kritický je $\left(\frac{e}{4}\right)^{\left(\frac{1}{3}\right)2^t} = q^{2^t}$, $q \doteq 0.879$

$$\mathbb{E}[X] = 2^t \cdot \frac{1}{3}$$

– Černov: $c = 2$,

$$\Pr\left[X \geq 2^t \cdot \frac{1}{3} \cdot 2\right] = \left(\frac{e}{2^2}\right)^{2^t \cdot \frac{1}{3}}$$

- Každý běh R , $|R| \geq 2^{l+2}$ obsahuje alespoň jeden kritický blok délky 2^l
 - Běh R zasahuje do 4 nebo 5 bloků velikosti 2^l .
 - První blok B_0 obsahuje alespoň 1 prvek z R , $B_1 \dots B_3$ obsahují 2^l prvků
 - Před B_0 je prázdko, takže všechny prvky v $L = B_0 \dots B_3 \cap R$ se sem i zahashovaly (nepřetekly sem)
 - Do L musí být zahashovaných alespoň $1 + 3 \cdot 2^t$, ale čtyři nekritické bloky obsahují nejvýše $4 \cdot \frac{2}{3} \cdot 2^t$.
- Nechť R je běh obsahující $h(x)$ a $|R| \in [2^{l+2}, 2^{l+3})$, pak jeden z 12 okolních bloků je kritický, 8 před $h(x)$, 3 po
 - R je 4 až 8 bloků dlouhý, ale nemusí být aligned, takže zasáhne 4 až 9 bloků
 - pokud končí blokem s $h(x)$, zabírá až 8 bloků před $h(x)$
 - pokud začíná blokem s $h(x)$, zabírá až 8 bloků za $h(x)$, ale kritický je jeden z prvních 4
- Aby běh R obsahující $h(x)$ byl dlouhý $[2^{l+2}, 2^{l+3})$, musí z okolních 12 bloků být alespoň jeden kritický
 - Union bound – pravděpodobnost, že libovolný z 12 jevů nastane je nejvýše $12 \cdot p$
- Tedy pro R běh obsahující $h(x)$,

$$\Pr[|R| \in [2^{l+2}, 2^{l+3})] \leq 12 \cdot \Pr[\text{blok velikosti } 2^l \text{ je kritický}] = 12 \cdot q^{2^l}$$

- Pro běh R obsahující $h(x)$:

$$\mathbb{E}[|R|] \leq 3 \cdot \Pr[|R| \leq 3] + \sum_{l \geq 0} 2^{l+3} \cdot 12 \cdot q^{2^l}$$

$$\mathbb{E}[|R|] \leq 3 \cdot 1 + 12 \cdot 8 \cdot \sum_{l \geq 0} 2^l \cdot q^{2^l}$$

$$\mathbb{E}[|R|] \leq 3 \cdot 1 + 96 \cdot \sum_{i \geq 1} i \cdot q^i$$

- poslední úprava – suma před úpravou dosazuje za i jen mocniny dvojky, suma po úpravě dosazuje všechna přirozená čísla, což je určité horní odhad
- Gabrielovo schodiště konverguje pro libovolné q

6. Definujte vícerozměrné intervalové stromy (range trees). Rozeberte prostorovou složitost datové struktury a časovou složitost konstrukce a obdélníkových dotazů (bonus: včetně zrychlení zlomkovým kaskádováním).
 - Intervalové stromy jsou identické s BVS, jen při hledání pamatujeme interval vrcholů, které daný podstrom může obsahovat
 - **Vyhledávání intervalu I :** Rekurzí,
 - pokud je $v \in I$, reportuju v
 - pokud je $\text{inv}(v) \subseteq I$, reportuju celý podstrom a končím
 - rekurzím do potomků, které zasahují do I , pokud zasahují oba, v každém mi zůstane jen jeden konec intervalu a už budu rekurzit vždy jednou
 - 2-d intervalové stromy
 - v každém vrcholu x -stromu je y -strom pro daný podstrom
 - každý vrchol je v $\mathcal{O}(\log n)$ sekundárních stromech (jeden za každý vrchol na cestě do kořene)
 - paměť $\mathcal{O}(n \log n)$
 - vyhledávání:
 - pro každý nalezený vrchol z x -stromu se ptám daného y -stromu – $\mathcal{O}(n \log^2 n)$
 - dynamizace - weight-balanced přestavení celého nevyváženého podstromu $\mathcal{O}(n \log^2 n)$
 - d -d intervalové stromy
 - v každém vrcholu primárního stromu je $(d - 1)$ -d strom
 - paměť $\mathcal{O}(n \log^{d-1} n)$
 - vyhledávání v $\mathcal{O}(n \log^d n)$
 - zlomkové kaskádování ve 2-d
 - místo y -stromů udržuji seřazená pole a odkazy do podseznamů pod každým z x -potomků, pro pokračování vyhledávání
 - $\mathcal{O}(\log n)$
7. Definujte sufixové pole a LCP pole. Popište a analyzujte algoritmy na jejich konstrukci (pro sufixové pole stačí ve skoro lineárním čase). Popište příklad úlohy, kterou umí tato pole efektivně řešit.
8. Popište zámky a atomické operace CAS a LL/SC. Navrhněte a analyzujte bezzámkovou implementaci zásobníku. Vysvětlete problém ABA a navrhněte jeho řešení. Porovnejte paralelizaci datových struktur za použití zámků a za použití atomických operací (tzv. bezzámkové datové struktury), přičemž v obou případech vysvětlete, jaké mohou nastat problémy.

Malé otázky

1. Popište dynamické pole, tedy „nafukovací pole“, se zvětšováním a zmenšováním. Analyzujte jeho amortizovanou složitost.
 - když dojde místo, realokuju na dvojnásobek
 - po každé realokaci $2 \times$ tolik prvků, kolik jsem od poslední realokace přidal
2. Popište vyhledávací stromy s líným vyvažováním (BB[α]-stromy). Analyzujte jejich amortizovanou složitost. Uveďte příklad jejich použití.
 - začínám s plně vyváženým stromem, v každém vrcholu si počítám množství vrcholů v podstromu
 - za vyvážený ho považuji, pokud $\frac{1}{3}m(v) \leq m(\ell(v)) \leq \frac{2}{3}m(v)$
 - to udrží log hloubku (délka cesty je omezená $\log_{\frac{3}{2}}(n)$)
 - postavit nový podstrom trvá n času, ale od jeho poslední přestavby z tohoto vrcholu jsem musel přidat $\frac{1}{3}n$ vrcholů $\Rightarrow$ amort
 - potenciál je součet přes všechny vrcholy $|m(\ell(v)) - m(p(v))|$
 - pokud je strom vyvážený, je potenciál 0, ne 1

- použití: k-d stromy, k-d intervaláče? prostě BVS?
3. Navrhněte operace Find, Insert a Delete na Splay stromu. Analyzujte jejich amortizovanou složitost. Větu o složitosti operace Splay stačí vyslovit, nemusíte ji dokazovat.
- **složitost Splay:** $3 \cdot (r'(v) - r(v)) + 1$, kde $r(v)$ je log mohutnosti vrcholu v před Splay a $r'(v)$ je po Splay
 - mohutnosti jsou $\mathcal{O}(\log n)$
 - všechny operace můžou naučtovat Splayi, který je $\mathcal{O}(\log n)$
 - **Find:** Najdu jako v BVS a vysplayuju do kořene
 - **Insert:** Insetrnu jako v BVS a vysplayuju do kořene
 - přidáním listu zvýším rank celé cesty a tím i potenciál, ale jen o $\mathcal{O}(\log n)$
 - **Delete:** Vysplayuju do kořene, deletenu, vysplayuju pravého syna levého podstromu
4. Analyzujte hloubku (a,b)-stromů.
- pro hloubku h platí $h \in \Theta(\log n)$
5. Analyzujte k-cestný Mergesort v cache-aware modelu. Jaká je optimální volba k ?
- $\log_k n = \frac{\log n}{\log k}$ průchodů
 - každá vrstva je $\mathcal{O}(n \log k)$ (používáme haldy)
 - složitost $\Theta\left(\frac{n \cdot \log k \cdot \log n}{\log k}\right) = \Theta(n \log n)$
 - potřebujeme K bloků na jednotlivé průchody a dalších K na udržení haldy, takže $M \geq 2BK$, $K \in \mathcal{O}\left(\frac{M}{B}\right)$
 - IO složitost $\mathcal{O}\left(\frac{n}{B} \cdot \frac{\log n}{\log k}\right) = \mathcal{O}\left(\frac{n}{B} \cdot \frac{\log n}{\log\left(\frac{M}{B}\right)}\right)$
6. Formulujte cache-oblivious algoritmus pro transpozici čtvercové matice. Rozeberte časovou složitost a I/O složitost.
- rekurzivní, rozdělíme transpozici na dvě transpozice a dvě kombinované transpozice a prohození
 - transpozice a prohození se dále rozdělují na čtyři transpozice a prohození
 - k reálnému swapování dochází pouze na nejnižší úrovni rekurze, každý prvek se swapne jednou, $\mathcal{O}(n^2)$
 - IO složitost, v určitou chvíli swapujeme a transponujeme dva bloky velikosti $B \times B$, pokud je keš velká alespoň $2 \cdot B^2$ (tall cache assumption, pak se celé takové bločky vejdu do keše a transponuje se dobře, každý blok načteme jen jednou, $\mathcal{O}\left(\frac{N^2}{B}\right)$)
7. Popište systém hešovacích funkcí odvozený ze skalárního součinu. Dokažte, že je to 1-univerzální systém ze $\mathbb{Z}_p^k$ do $\mathbb{Z}_p$.
- $h_v(x) = xv$, vektor v je náhodně generovaný a parametrizuje hashovací funkci
 - c -universálnost: $P_{h \in \mathcal{H}}[h(x) = h(y)] \leq \frac{c}{p}$
 - nechť se x a y liší v d -tém prvku, $P[xv = yv] = P[(x - y)v = 0]$, bude platit pro právě jednu volbu $v_d \Rightarrow \frac{1}{p}$
8. Popište systém hešovacích funkcí založených na lineární kongruenci. Dokažte, že je to 2-nezávislý systém ze $\mathbb{Z}_p$ do $[m]$ (můžete využít lemma o modulení, které zformulujete, ale nemusíte dokazovat).
- $h_{a,b}(x) = ((ax + b) \bmod p) \bmod m$
 - k, c -nezávislost: $P_{h \in \mathcal{H}}[h(x_1) = y_1 \wedge \dots \wedge h(x_k) = y_k] = \frac{c}{m^k}$
 - **lemma o modulení:** pokud $\mathcal{H}$ je k, c -nezávislý systém z $\mathcal{U}$ do $[r]$, pak pro $2km \leq r$, $\mathcal{H} \bmod m$ je $k, 2c$ -nezávislý
 - výběr

$$r = (ax + b) \bmod p$$

$$s = (ay + b) \bmod p$$

je bijektivní na výběr a, b , tedy je i 2-nezávislý

9. Sestrojte k -nezávislý systém hešovacích funkcí ze $\mathbb{Z}_p$ do $[m]$. Zdůvodněte k -nezávislost (můžete využít lemma o modulu, které zformulujete, ale nemusíte dokazovat).
 - $\mathcal{P}_k = \{h_t \mid t \in \mathbb{Z}_p^k\}$, $h_t = \sum_{i=0}^{k-1} t_i x^i$
 - existuje právě jeden polynom takový, že pro $x_1 \dots x_k$ a $y_1 \dots y_k$ tž $h(x_i) = y_i$ pro každé i , tzn. pravděpodobnost je $\frac{1}{p^k}$
 - přes lemma o modulu, pokud $p \geq 2km$, máme po vymodulu k , 2-nezávislý systém
10. Sestrojte 2-nezávislý systém hešující řetězce délky nejvýše L nad abecedou $[a]$ do $[m]$ založený na polynomech, tedy „rolling hash“. Popište výhodu použití tohoto systému oproti jiným hešovacím funkcím.
 - $\mathcal{R} = \{h_a \mid a \in \mathbb{Z}_p\}$, $h_{a(x)} = \sum_{i=0}^{L-1} x_{i+1} a^i$
 - dá se posouvat v konstantním čase – vynásobím a , přičtu příchozí znak, odečtu odchozí znak $\cdot a^L$ (musím předpočítat a^L)
11. Popište a analyzujte Bloomův filtr. Uveďte příklad jeho praktického použití.
 - pomocí hashe indexujeme v poli bitů a flipujeme bity nahoru pro prvky, které jsme viděli
 - pak se můžeme ptát „viděli jsme tenhle prvek?“, na což dostaneme buď korektní NE, nebo possibly false positive ANO
 - typicky k hashovacích funkcí
 - také lze mít všechny hashe v jednom poli
 - s počítadly lze i delete
12. Definujte k -d stromy a ukažte, že 2-d intervalové dotazy trvají $\Omega(\sqrt{n})$.
 - pro data z $\mathbb{R}^k$ vytváříme strom, kde na l -té úrovni mám medián daných podstromů v dimenzi $l \bmod k$
 - pro $\{0\} \times \mathbb{R}$ to suckuje, pro x jdu furt doleva, ale pro y furt rekurzím do všech
13. Ukažte, jak dynamizovat dvou dimenzionální intervalové stromy (tedy Range trees), stačí Insert.
 - pomocí BB[α] stromů, $\mathcal{O}(\log^2 n)$
14. Ukažte, jak použít sufixové pole a LCP pole na nalezení nejdelšího společného podřetězce dvou řetězců.
 - concatnu za sebe s pomocí oddělovacího znaku, najdu max v LCP t.ž. jeden je před a jeden je za oddělovačem
15. Ukažte, jak paralelizovat (a,b)-strom pomocí zámků.
 - pomocí top-down strategie – preemptivně rozdělujeme/spojujeme už při cestě dolů, abychom vždy mohli udělat Insert nebo Delete
 - zamykáme vždy dva vrcholy za sebou
 - při deletu může dávat smysl vždy zamykat nejdřív levého sourozence – pro případ, že s ním budeme slučovat nebo půjčovat
 - pokud odstraňujeme klíč, který není v nejnižší vrstvě, je možné, že budeme muset dlouho hledat následníka, kdyžtak se dá vrchol označit hrobečkem