

Dynamizace datových struktur

Velmi obecně: Máme nějakou DS a chceme, aby se chovala "dynamičtěji"
(treba úplně statická → dynamická s Insertem a Deletem)

- Úplný rebuild (přestavba):
- jednou za čas přebudujeme celou strukturu
 - tím řešíme omezenou kapacitu (pole, intervalové stromy, vEB, ...)
 - nebo třeba změny parametrů (bloky velikosti ~ log n u indirekce) či "zanášení" struktury smazávajícími prvky
 - strukturu velikosti n přebudujeme za $\Theta(n)$ operací
→ $T(n)/n$ na prvek amort., kde $T(n)$ je složitost přebudování.
[předpokládáme ~~$T(n)$~~ $T(O(n)) = O(T(n))$]

Částečný rebuild ... příklad: vyhledávací stromy - dokonale vyvážený strom umíme postavit v $O(n)$ ze seřazené posl., ale nelze ho dynamicky udržovat

Df: $BB-\alpha$ strom \equiv BVS, v každém vrcholu v :

$$|T(l(v))| \leq \alpha \cdot |T(v)|$$

$$|T(p(v))| \leq \alpha \cdot |T(v)| \quad \text{pro } \frac{1}{2} < \alpha < 1$$

👁 Vede na hloubku $\leq \log_{\frac{1}{1-\alpha}} n$... kontrola: udržují počítadla $|T(v)|$ ve vrcholech

Strategie: Po Ins/Del přepočítám počítadla na cestě do kořene & kontroluji vyváženost
Pokud \exists nevyvážený vrchol, v něm nejvyšší, vše pod ním norebnu a postavím znovu dokonale vyvážené.

Intuice: Rebuild stojí $\Theta(k)$ pro podstrom velikosti k , než nastane znovu, musí v podstromu nastat $\Omega(k)$ operací } $O(1)$ /op.
... & prvek si předplatí rebuild všech nadřazených úrovní → $O(\log n)$ /op.

Analýza: $\varphi(v) := \begin{cases} |T(l(v))| - |T(p(v))| & \text{pokud vyjde } \geq 2 \\ 0 & \text{jinak} \end{cases}$ } v dokonale vyváženém stromu všude 0

$$\Phi = \sum_v \varphi(v)$$

Ins/Del mění $\varphi(v)$ o $O(1)$ v $O(\log n)$ vrcholech ⇒ stojí $O(\log n)$

vyvážení podstromu $T(v)$ o k prvcích ... $\varphi(v) \geq \Omega(k) \Rightarrow \Phi$ klesne o $\Omega(k)$
→ vyvážení zaplatíme z potenciálu

Věta: V $BB-\alpha$ stromu o n vrcholech trvá Find $O(\log n)$ u.c., Ins/Del $O(\log n)$ amort.

Dynamizace 2D intervalových stromů

- primární i sekundární stromy jsou $BB-\alpha$
 - rebuild primárního stojí $\Theta(k \log k)$ → musím spočít $\Omega(\log k)$ /prvek
 - rebuild sekundárního stojí $\Theta(k)$, → také $\Omega(\log k)$ /prvek ale & prvek leží v $O(\log k)$ takových
- ⇒ amort. složitost Ins/Del je $O(\log^2 n)$
- } pro d-dim. vyjde $O(\log^d n)$ amort. Ins/Del & Find zůstává

Obecná (semi) dynamizace
 ↑ jen Insert

spis (U_x, U_y) ... jen konečné!

Df: Vyhledávací problém je $f: U_Q \times U_P \rightarrow U_R$
 ↑ universum dotazů ↑ universum prvků ↑ universum výsledků

Df: Vop. f je rozložitelný $\equiv \exists \sqcup: U_R \times U_R \rightarrow U_R$ ~~...~~ vyčísitelný v čase $O(1)$ tož.

$\forall A, B \subseteq U_x, A \cap B = \emptyset \quad \forall q \in U_Q \quad f(q, A \cup B) = f(q, A) \sqcup f(q, B)$

Příklady "q ∈ X"
 ... nejblíže bod X ke q v \mathbb{R}^d } jsou rozložitelné ... $U_x = \mathbb{Z}, U_Q = \mathbb{Z}, U_R = \{0,1\}$
 ... $q \in \text{centr}(X)$ } není! } ... $U_x = U_Q = \mathbb{R}^2, U_R = \mathbb{R}^2$
 ... $U_x = U_Q = \mathbb{R}^2, U_R = \{0,1\}$

Mějme statickou strukturu pro f ... $B_S(n)$ - čas na build
 $Q_S(n)$ - čas na dotaz
 $S_S(n)$ - prostor } předpokládáme, že
 $Q_S(n), \frac{B_S(n)}{n}, \frac{S_S(n)}{n}$
 jsou malé

Chceme semidynamickou ... $Q_D(n), S_D(n)$... čas na dotaz, prostor
 $I_D(n), D_D(n)$... amort. čas na Insert, Delete

Konstrukce: Množinu rozložíme na bloky B_0, B_1, \dots takové, že $|B_i| \in \{0, 2^i\}$ } # bloků $\leq \log n$
 ⇒ velikost $n = |X|$ nám jednoznačně určuje, jaké bloky jsou neprázdné (bin. zápis)

Dotaz: Položíme dotaz všem blokům, odpovědi skombinujeme

Trvá $\sum_{i \in I} Q_S(2^i) \in O(Q_S(n) \cdot \log n)$
 indexy tj. $B_i \neq \emptyset$

Prostor: $\sum_{i \in I} S_S(2^i) = \sum_i \underbrace{\left(\frac{S_S(2^i)}{2^i}\right)}_{\leq \frac{S_S(n)}{n}} \cdot 2^i \leq n \cdot \frac{S_S(n)}{n} = S_S(n)$

Insert: Jako přičítání ve dvojkové soustavě ... nechť j je um. takové, že $B_j = \emptyset$

Rozoberu $B_0 \dots B_{j-1}$, přidám nový prvek, vytvořím novou B_j
 $2^0 + \dots + 2^{j-1} + 1 = 2^j$

B_j přebudováváme ^{nejvíce} jednou za 2^j loků } \forall prvek předplatí
 \Rightarrow amort. cena vyjde $\leq B_S(2^j) / 2^j \leq \frac{B_S(n)}{n}$ } $O\left(\frac{B_S(n)}{n} \cdot \log n\right)$

Věta ... existuje semidynamická struktura s parametry

$Q_D(n) = O(Q_S(n) \cdot \log n)$

$S_D(n) = O(S_S(n))$... kodi se udržovat lepší prvky (nemusíme rozkládat)

$I_D(n) = O\left(\frac{B_S(n)}{n} \cdot \log n\right)$

Příklady:

- binární vyhledávání → obecná možnost
 Build $\Theta(n \log n)$ dotaz $\Theta(\log^2 n)$
 dotaz $\Theta(\log n)$ prostor $\Theta(n)$
 Insert $\Theta(\log^2 n)$ ← lze zrychlit a místo rebuildu Merge $\sqrt{\Theta(n)}$
 → $O(\log n)$ amort.
- tzn. není přesné, pokud $B_S(n) = O(n^E)$... tedy log zruší a $I_D(n) = O(n^E)$
- pro 2D intervalové stromy: build $\Theta(n \log n)$ dotaz $\Theta(\log^2 n)$ prostor $\Theta(n \log n)$ → Insert $\Theta(\log^2 n)$ dotaz $\Theta(\log^2 n)$ prostor $\Theta(n \log n)$

Worst-case semi-dynamizace:

Myslenka: rebuild rozložíme mezi více operací, pokud provedeme kousek ... ale měření musí původní struktury stále existovat a odpovídat na dotazy

Pro každý řád bloku povolíme až 4 bloky: B_i^1, \dots, B_i^3 hotové (odpovídají na dotazy) B_i^4 rozdělována (sjednocení největších dvou B_{i-1}^3, B_{i-1}^3)

- jakmile se sejdou 2 hotové bloky téhož řádu, spustíme build B_{i+1}^1 , pokusí 2ⁱⁿⁿ kroky. Až dojdeme, původní bloky zrušíme.
- nikdy nevzniknou víc než 3 bloky téhož řádu

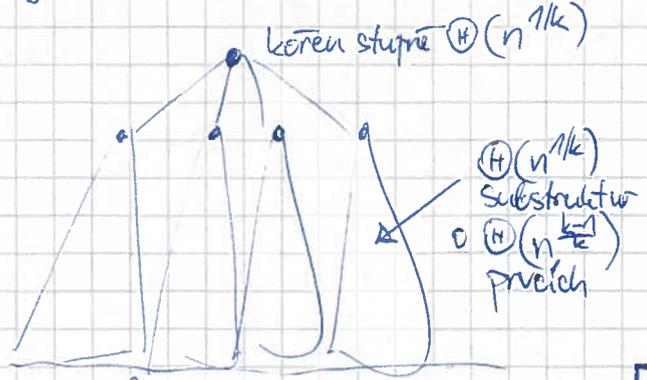
⇒ Insert v $O(B_S(n)/n \cdot \log n)$ kódo dotaz ani paměť se asymptoticky nehorší

Dále se učí:

- plná dynamizace - statická struktura musí umět "skrotat prvky"
 - jednou za čas úplný rebuild
 - pomocná struktura, která si pamatuje prvek → blok (řeba B_S)
- worst-case plná dynamizace

Exponenciální stromy:

- technika vhodná k dynamizaci Fusion Trees a spol.
- máme statickou strukturu pro hledání následníka s $B_S(n) \in O(n^{k-1})$ a největším $B_S(n)$ pro největší $k \geq 2$ v prostoru $S_S(n) \in O(n^{k-1})$
- vyrobíme násl. strom



↑ v listech jsou data
 + spoj. seznam všech listů

- každý vrchol si pamatuje oddělováč



V_i má oddělováč S_i
 V_{i+1} S_{i+1}
 Listy v $X_i \in [S_i, S_{i+1})$
 a oddělováče

↳ oddělováč vrcholu = oddělováč jeho levého syna (vnitř.)

[prvek, v listech nemusi být oddělováč = prvek?]

- vrchol si pamatuje oddělováče synů ve statické struktuře

Dotaz: Řídíme se podle oddělovačů, prodráťujeme sloupa delů, v listu ≠ 1 spojkeem

$$Q_D(n) \leq \cancel{O(n^k)} O(Q_S(O(n^{1/k}))) + Q_D(O(n^{\frac{k-1}{k}}))$$

chceme se zbavit 0-ček
umístit → jedničky dosadíme
do sebe sama

$$\leq \underbrace{O(Q_S(O(n^{1/k})))}_{\leq n \text{ pro dost velké } n} + \underbrace{O(Q_S(O(n^{\frac{k-1}{k}})))}_{\text{taky } O(Q_S(n))} + \underbrace{Q_D(O(n^{(\frac{k-1}{k})^2}))}_{\text{pro dost velké } n \text{ je } O(n^{\frac{(k-1)^2}{k}}) \leq n^{\frac{k-1}{k}}}$$

$$\leq O(Q_S(n)) + Q_D(n^{\frac{k-1}{k}})$$

Pauza: $S_D(n) \leq O((n^{\frac{k-1}{k}})^{k-1}) + \sum_1 S_D(n_i)$

$\sum_1 n_i = n, \forall n_i \in \Theta(n^{\frac{k-1}{k}})$

⇒ $S_D(n) \in O(n)$... na každé úrovni $\Theta(n^{\frac{k-1}{k}})$, úroveň je jisté $O(n^{\frac{1}{k}})$

... čas na kompletní konstrukci vyjde stejně

↑ tohle není tak trivialní, ale čas na vkladnou strukturu doloží exponenciálně roste ⇒ dominují listy a těch je $O(n)$.

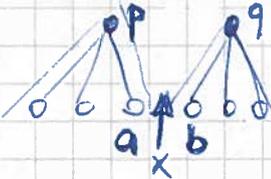
Delete: prvek smažeme ... problém:



můžeme 1. syna → museli bychom změnit oddělovač v otci ... tak ho předejme 2o synovi

+ # synů může vyřít z povoleného rozsahu → poroží

Insert: najdeme předchůdce & následníka ...



p, q mohou být stejné

- buď $x < odd(b)$ ⇒ přidám pod p za a, $odd(x) < x$
 - nebo $x \geq odd(b)$ ⇒ přidám pod q za b, $odd(x) < odd(b)$ a $odd(b) < b$
- (ale $x < b$)

↑ přebudují stat. strukturu v otci, ale ta je stejně nad listy konstantně velká

}

nikdy nemění oddělovač v otci

Rebalance: Velikost podstromu může opustit povolený rozsah $\Theta(n)$ → řeším rozdělením/přerodělením/slitím (à la indirekce)

- v daném místě (struktura velikosti t , substruktury velikosti $\Theta(t^{\frac{k-1}{k}})$)
 - to nastane za $\Omega(t^{\frac{k-1}{k}})$ operací Ins/Del
 - a rebuild stojí $O(t^{\frac{k-1}{k}})$ za podstrukturu + $O((t^{\frac{k-1}{k}})^{k-1})$ za stat. strukturu v kórci
- $$= O(t^{\frac{k-1}{k}})$$

• + Ins/Del si předplatí toto na všech úrovních ⇒ omezeno stejnou rekurencí jako $Q_D(n)$

Důsledek: Exponenciální strom zabere prostor $S_D(n) = \Theta(n)$,
hledá v čase dle rekurence $Q_D(n) = O(Q_S(n)) + Q_D(n^{\frac{k-1}{k}})$ u_0, c_0
Vkládá/máže v $Q_D(n)$ amort.,
sestrojit jde v $\Theta(n)$.

(5)

Použití: • Pro Fusion Tree $B_S(n) = O(n^k) \Rightarrow k=5$
 $Q_S(n) = O\left(\frac{\log n}{\log W}\right)$

$$\Rightarrow Q_D(n) = O\left(\frac{\log n}{\log W}\right) + Q_D\left(n^{\frac{k}{5}}\right)$$

$$\Rightarrow Q_D(n) = \sum_{i=0}^{\infty} \frac{\log\left(n^{\left(\frac{k}{5}\right)^i}\right)}{\log W} = \sum_{i=0}^{\infty} \frac{\left(\frac{k}{5}\right)^i \log n}{\log W} = O\left(\frac{\log n}{\log W}\right)$$

umí se i worst-case verze, je (jako obvykle) výrazně složitější

pro seřazené pole s bin. searchem vyjde $O(\log n)$ ☺

• Pro VEB-like strukturu $k=2$, $Q_S = O(\log \log n) \Rightarrow Q_D(n) = O(\log^2 \log n)$

Persistence

- Možnosti:
- efemérní (používá) struktura - pokaždé nezávisle má svůj stav
 - semipersistentní - pamatuje si historii
 - update vytvoří novou verzi
 - dotaz pokládáme libovolné verzi
 - plně persistentní - máme dovoleno upravovat historické verze
 - historie tvoří strom
 - funkcionální (bez side-efektů) - co jsme zapsali, nikdy neupravujeme
 - to je i vhodné i při paralelním programování

Příklady

- srušovací seznamy s přidáváním na začátek → funkcionální, $O(1)$ paměti na verzi
- vyhledávací stromy s kopírováním cesty → funkcionální
 - $O(\log n)$ času na dotaz i úpravu
 - $O(\log n)$ prostoru na verzi (rozmyslet vyvažování)
 - ↳ kopírujeme cestu do kořene
 - ↳ rotace "blízko" cesty → navíc zkopírujeme $O(\log n)$ vrcholů

Aplikace: Lokalizace bodu v rovině via zametání

Model: Pointerové datové struktury

- tvořené krabičkami, v každé $O(1)$ dat + $O(1)$ ukazatelů → orient. graf
- "držátka" - $O(1)$ ukazatelů, zvenku
- dotaz - začneme držátkem, chodíme po pointerech do dalších krabiček
- update - jako dotaz + modifikace některých navštívených krabiček + zavádění nových krabiček

Pro semi-persistenci • stačí ~~se~~ ~~z~~ ~~u~~ ~~v~~ ~~e~~ ~~r~~ ~~e~~ ~~v~~ ~~a~~ ~~t~~ ~~j~~ ~~e~~ ~~n~~ ~~o~~, ~~co~~ ~~je~~ ~~t~~ ~~r~~ ~~e~~ ~~b~~ ~~a~~ ~~k~~ ~~h~~ ~~l~~ ~~e~~ ~~d~~ ~~a~~ ~~n~~ ~~í~~
 ... např. u AVL-stromů ukazatele a klíče, } → strukturálních změn
 ale už ne znamená

• ukážeme, jak 1 strukt. změnu uložit v čase a prostoru $O(1)$ amortiz., přičemž dotazy zpomalíme jen $O(1)$ -krát

• Příklad: (2,4)-strom provede amort. $O(1)$ strukt. změnu na update
 → persist. strom s časem $O(\log n)$ n.e. na dotaz
 $O(\log n)$ amort. na update
 a prostorem $O(1)$ amort. na verzi

potenciál vrcholu = $\begin{matrix} 0 & \text{klíčů} & \rightarrow & 2 \\ 1 & & \rightarrow & 1 \\ 2 & & \rightarrow & 0 \\ 3 & & \rightarrow & 2 \\ 4 & & \rightarrow & 4 \end{matrix}$ $\left. \begin{matrix} \text{Ins/Del stojí přímo } O(1) \\ \text{štepění: } 4 \text{ klíče} \rightarrow 2+1+1 \text{ nahoru (} \Phi: 4 \rightarrow 0+1+\max.2) \\ \text{sloučení: } 0 \text{ klíčů} + 1 \text{ klíč} + 1 \text{ slouba} \rightarrow 2 \text{ (} \Phi: 2+1 \rightarrow 0+\max.2) \\ \text{přijetí s tím sloučením, takže můžeme platit } O(1) \end{matrix} \right\}$

"Tlusté" vrcholy

- každý vrchol si pamatuje všechny změny ukazatelů i dat
 → vyhledávací strom indexovaný verzí (to bude číslo)
- verze stojí $O(1)$ prostoru, ale operace jsou zpomalily $O(\log h)$ -krát pro historii délky h
 ↳ můžeme přejít na $\log \log h$ pomocí VEB (alespoň nardominované)

Zkrácení tlustých vrcholů s kopírováním [Driscoll, Sarnak, Sleator, Tarjan 1986]

- funguje, pokud $\forall v \text{ deg}^m(v) \leq p \in O(1)$
- vrchol si pamatuje základní verzi (celou) + $e \geq p$ extra pointerů (slotů) (trojice (index, verze, kam))
- kdykoli měníme pointer a je volný extra slot, využijeme ho [pointer této verze můžeme přepsat přímo]
- jinak (došlo místo nebo měníme data) zkopírujeme vrchol → update až p pointerů v předchůdcích (proraz, musíme je zjistit → zpětné pointerů)

Amortizace $\varphi(v) = \#$ využitých slotů [může být $e+1$, pokud vrchol právě přetečel]
 $\Phi = \sum_v \varphi(v)$ přes všechna v dosažitelná v aktuální verzi

- změna hodnoty dat či pointeru stojí $O(1)$
- kopírování při přetečení: $\varphi(v)$ byl $e+1 \geq p+1 \Rightarrow 1$ spotřebuji, dalších $\leq p$ dám předchůdcům + starý vrchol přestane být dosažitelný

Details

- verze číslováme přir. čísly
- krabíčka:
 - počáteční verze
 - počáteční stav dat i pointerů
 - pointer na nejbližší novější instanci
 - pointer na předchůdce (zpětné) - řádné spec. pořadí, p ks.
 - e slotů na novější verze pointerů
- pro \forall verzi hodnoty "dráček" ... $O(1)$ prostoru na verzi

všechny instance tvoří spoják seřazený dle verzí
 • při update se nám může stát, že upravíme pointer ve vrcholu, který už byl zkopírován [nikdy nekopírujeme tenže vrchol 2x za update]

Invariant • Pointerů verze v vedou na instance vrcholů, které obsahují verzi v . } dočasně navšeno

Důsledek • $O(1)$ amort. času i prostoru na verzi, $O(1)$ n.e. na 1 krocí hledání

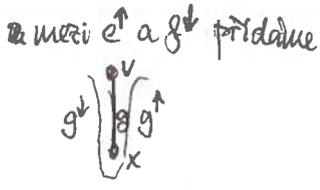
Stručně o plné persistenci

- Problémy**
- ① musíme vyjít z worst-case struktury (jinak rozbijeme amortizaci)
 - ② musíme verzovat vše \dots u \bar{C} -stromů Barry \rightarrow zavedeme rozdílové $\rightarrow O(1)$ usc, změna/op. lektorování
 - ③ přestane existovat len. uspoř. na verzích \dots místo toho strom verzí (částečné uspoř.)

\rightarrow "obejdeme strom po obvodu" - zadanou průchodu DFS po hranách
 - směrem dolů provedeme změnu
 - směrem nahoru provedeme opačnou



nová verze sem



mezi e^{\uparrow} a g^{\downarrow} přidáme

potřebujeme reprezentovat seznam, umět vkládat a porovnávat položky
 - obojí se umí v $O(1)$, dokonce u.c. (viz předejí)

List Order Problem

Tlusté vrcholy \rightarrow opět strom verzí, ale klíče jsou implicitní (via List Order)
 stále $O(1)$ prostoru na verzi a zpomalení $O(\log h)$.

Struktura se sloty: [tj Driscoll et al. 1986]

- předchůdce musíme verzovat
 - pokud vrcholy mají $\leq p$ předchůdců a $\leq d$ následníků, volume # slotů $e \geq 2d + dp$
 - $\varphi(v) = \min(0, \# \text{ slotů} - e/2)$, $\Phi = \sum \varphi(v)$ testovat přes všechny vrcholy
 - po přetečení vrchol delíme na 2 části (volbou vhodné hraniční verze)
 - oba nové vrcholy mají $\varphi = 0$
 - předtím bylo $\varphi \geq e$, $+1 - e/2 \geq d + p + 1$
 \hookrightarrow 1 spotřebujeme, $d + p$ předáme okolním vrcholům
 - detaily značně trikové
- \rightarrow opět $O(1)$ času a prostoru amort. na verzi, zpomalení $O(1)$ u.c.
 \rightarrow umí se i u.c. verze se vším $O(1)$

Další persist. struktury:

\swarrow to je optimální!

- pole s $O(\log \log h)$ času na operaci, $O(1)$ prostoru na verzi (vše amort., random.)
 - y-fast strom verzí v $\#$ polořecí pole
 - semipersistently snadné,
s plnou persistencí se musí vyřešit přecíslováním v List Orderu

[viz disertace Milana Straky]