

# Předelna: Intervalové dotazy v pologrupách

$(X, \oplus)$ ,  $\oplus$  je asociativní  
 příklady: min, +, \*, násobení matic, ...

Chceme statickou DS, která pro  $x_1, \dots, x_n \in X$   
 umí rychle vyhodnocovat  $x_1 \oplus x_{i+1} \oplus \dots \oplus x_j$

Df:  $f_i(n)$  = kolik prostoru stačí, abychom uměli dotaz vyhodnocovat pomocí  $i$  operací  $\oplus$   
 čas na předvýpočet bude vycházet ~ stejný

$f_0(n) = \Theta(n^2)$  ... předpocítáme všechno

$f_1(n)$  ... rekurzivní konstrukce

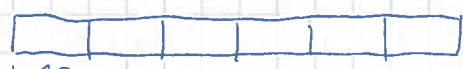
A	B
$n/2$	$n/2$

- dotazy přes střed:  $p_x + s_x$  součty  
 - ostatní: rekurze na A nebo B

$f_1(n) = n + 2 \cdot f_1(n/2)$   
 $f_1(1) = 0$   
 $f_1(n) = n \log n$  (čtevní: dotaz v  $O(1)$  [předpocítáme vhodné tabulky])

$f_2(n)$  ... nic zajímavého

$f_3(n)$  ... opět rekurzivně


  
 bloky velikosti  $b \rightarrow n/b$  bloků

- $p_x + s_x$  v každém bloku
- $f_3$  v každém bloku
- $f_1$  pro posloupnost součtů bloků


$f_3(n) = 2n + f_1(n/b) + \frac{n}{b} \cdot f_3(b)$

$\uparrow$   $p_x + s_x$  součty  
 $\uparrow$   $f_1$   $n/b$  bloků  
 $\uparrow$   $f_3$   $b$  bloků

volbou  $b = \log n$   
 bude  $f_1(n/b) \leq n$



tedy  $f_3(n) \leq 3n + \frac{n}{\log n} \cdot f_3(\log n)$   
 $f_3(1) = 0$



$f_3(n) \leq 3n \cdot \log^* n$

Obecně:  $f_{2k+1}(n) \leq (2k+1)n \log^{*k} n$

[doložíme indukci zobecněním postupu pro  $f_3$ ]

Optimum:

$\alpha(n) = \min \{ k \mid \log^{*k} n \leq 2 \}$

Pak pro  $k = \alpha(n)$  získáme:

Předpracování v  $O(n \cdot \alpha(n))$

Dotaz v  $O(\alpha(n))$

nutno domyslet, jak vše stihnout (zatím jsme dělali, že stačí tolikrát vyhodnotit  $\oplus$ )

příklady:

$g$	$g^*$
$n-1$	$n-1$
$n-2$	$n/k$
$n-3$	$n/b$
$n/k$	$\log n$
$n/c$	$\log_c n$
$\sqrt{n}$	$\log \log n$
$\log n$	$\log^* n$

Obecně: pokud pro  $i$  operací  $\oplus$  stačí prostor  $g^i(n) = k \cdot n \cdot g(n)$ , pak pro  $i+2$  operací  $\oplus$  použijeme  $b = g(n)$ , z čehož  $(n/b) \cdot g^i(n/b) \leq k \cdot n$ , takže:

$f(n) = kn + \frac{n}{g(n)} \cdot f(g(n))$

$k = k+2 \downarrow$

$f(n) = kn \cdot g^*(n)$

kde  $g^*(n) = 0$  pro  $n \leq 1$

$g^*(n) = 1 + g^*(g(n))$  pro  $n > 1$

tedy  $g^*(n) = \min \{ i \mid g^{(i)}(n) \leq 1 \}$

(def. pro  $g: \forall n, g(n) < n$ )

Speciální případy:

$\oplus = + \rightarrow$  prefixové součty

Build  $O(n)$  / Query  $O(1)$

(2)

$\oplus = \min \rightarrow$  RMQ

$O(n)$  /  $O(1)$

dynamické  $\rightarrow$  intervalové stromy

Query  $O(\log n)$  / Update  $O(\log n)$   
Build  $O(n)$

## Union-Find Problem [přev. Tarjan & van Leeuwen 1984, heur. analýza od Seidela 200x]


- udržujeme ekvivalenci na  $\{1 \dots n\}$ 
  - začínáme se samými / prázdnými třídami
  - Union(x,y) sloučí třídy obsahující x, y
  - Find(x) zjistí třídu obsahující x (vrátí reprezentanta)
- alternativně: udržujeme komponenty souvislosti grafu, Union přidává hranici

Reprezentace:  $\forall$  třídu reprezentujeme stromem orientovaným do kořene  
... vrchol si pamatuje svého otce.

Optimalizace: ① Union by rank ... kořeny si pamatují rank  $r(v)$   
Pokud  $r(u) < r(v)$ , převeďme u pod v,  
jinak libovolně, ale novému kořeni zvýšíme rank o 1

- Důsledky:
- rank = hloubka stromu
  - strom ranku r obsahuje aspoň  $2^r$  vrcholů
  - všechny ranky jsou  $\leq \log n$
  - stromy mají hloubku  $\leq \log n$
  - Union i Find trvají  $O(\log n)$

### ② Path Compression



kdykoli nějakou cestu  
projedeme,  
zkomprimujeme ji  
do hlavy

Postupně ukážeme, že Path Compression zaručuje sama o sobě čas  $O(\log n)$  a uvert.  
a) ① + ② společně budou daleko lepší.

Ceny operací měříme počtem přepojení / <sup>nepočítáme první přitřesení</sup> pointeri  $cost(op)$

Find trvá  $O(1 + \text{délka cesty}) = O(1 + cost)$

Union trvá  $O(1) + 2 \times \text{Find}$ , tedy také  $O(1 + cost)$ .

Trick: Nejprve provedeme všechna spojení stromů,


teprve pak všechny komprese cest (ale vždy se zastavíme ve vrcholu, kterým původně byl kořenem)

zde se pointer  
nepřepojuje  
(pouze definuje)  
vše podstatné  
se děje zde

Df: Rozklad ~~stromu~~ lesa na množině vrcholů  $V$  je  $(V_L, V_B)$  taková, že:

- ①  $V_L \cup V_B = V, V_L \cap V_B = \emptyset$  (rozklad v množinovém smyslu)
- ②  $V_L$  je "uzavřená nahoru" - tedy otec vrcholů z  $V_L$  patří zase ve  $V_L$ .

Nápad: Uvažíme nějaký rozklad a sledujeme, jak ho protínají jednotlivé komprese.



Notace:  $\mathcal{F}$  = les na množině vrcholů  $X$   
 $C$  = posloupnost kompresí  
 $\|C\|$  = #normálních kompresí v  $C$   
 $\text{cost}(C)$  = celková cena kompresí v  $C$

} obecně nás zajímá, kolik nejvyšší může být  $\text{cost}(C)$  vzhledem k  $|X|$  a  $\|C\|$ .

Lemma: Necht'  $C$  je posloupnost kompresí v lese  $\mathcal{F}$  na množině  $X$  a  $(X_L, X_B)$  je rozklad lesa  $\mathcal{F}$  indukující lesy  $\mathcal{F}_L$  a  $\mathcal{F}_B$ .

Potom  $\exists C_L, C_B$  posloupnosti kompresí pro  $\mathcal{F}_L$  a  $\mathcal{F}_B$  takové, že:

$$\|C_L\| + \|C_B\| \leq \|C\| \quad (*)$$

$$\& \text{cost}(C) \leq \text{cost}(C_L) + \text{cost}(C_B) + |X_B| + \|C_L\|. \quad (\#)$$

Důk:  $C_L, C_B$  získáme přímočarě:

- ① komprese leží celá uvnitř  $\mathcal{F}_L \rightarrow$  jde do  $C_L$
  - ② analogicky  $\mathcal{F}_B \rightarrow C_B$
  - ③ jde napříč  $\rightarrow$  speciální komprese uvnitř  $\mathcal{F}_B$ , normální uvnitř  $\mathcal{F}_L$
- } z toho  $\rightarrow (*)$   
 } doklady přispěje  $\ll \|C\| \cdot |X|$   
 } [silnější verze, která se bude hodit později]

Nyní dokážeme  $(\#)$ :


$\text{cost}(C)$ :

- $T$  změni otce na  $T$   $\rightarrow$  platíme z  $\text{cost}(C_L)$
- $B$  změni otce na  $B$   $\rightarrow$  platíme z  $\text{cost}(C_B)$
- $B$  změni otce na  $T$   $\rightarrow$  poprvé  $\rightarrow$  platíme z  $|X_B|$  ( $\leftarrow$  #roots( $\mathcal{F}_B$ )) pro silnější verzi
- $\rightarrow$  znem  $\rightarrow$  platíme z  $\|C_L\|$  (v každé  $T$ -kompresi to nastane max. 1x)

Df:  $f(m, n) = \max. \text{cost}$  libovolné posloupnosti kompresí  $C$  t.č.  $\|C\| = m$  na stromu s  $n$  vrcholy.

Věta:  $f(m, n) \leq (m+n) \log n$ .

Důk: Indukcí ... rozdělíme  $X$  na  $X_t, X_b$  velikosti  $n/2$



$\|C\| = m$   
z lemmatu:  $\exists C_t, C_b \quad \|C_t\| + \|C_b\| \leq \|C\|$   
 $m_t + m_b \leq m$

$\& \text{cost}(C) \leq \text{cost}(C_t) + \text{cost}(C_b) + |X_b| + \|C_t\|$

z indukce:  $\text{cost}(C) \leq (m_t + n/2) \log n/2 + (m_b + n/2) \log n/2 + n/2 + m_t$   
 $\leq m(\log n/2 + 1) + n(\log n/2 + 1) = (m+n) \log n.$

Důsledek: Union i Find provedení  $m$ -krát na  $n$ -prvkové množině trvá celkem  $O((m+n) \log n)$ .

Nyní přidáme Union by rank

Důk: Rankový les je les s funkcí  $r: V \rightarrow \mathbb{N}$  t.č.

①  $r(v)$  = výška podstromu s kořenem  $v$  (měřená v hranicích)

②  $\forall v \forall i = 0, \dots, r(v)-1 \exists u$  syn vrcholu  $v$  t.č.  $r(u) = i$ .

Union by rank bez komprese cest produkuje rankové lesy ... a kompresi provádíme až dodatečně, takže nepřekáží.

Vrchol ranku  $r$  má alespoň  $r$  synů, jeliko podstrom obsahuje alespoň  $2^r$  vrcholů.

Lemna: Necht  $F$  je rankový les s ~~rankem~~ ranku  $r$  s číslo  $s$  ( $0 \leq s < r$ ).

Pak množiny  $X_t := \{x \in X \mid r(x) > s\}$   
a  $X_b := \{x \in X \mid r(x) \leq s\}$

(na množině  $X$ )  
a indukované lesy  $F_t$   
 $F_b$

splňují:

- ①  $(X_t, X_b)$  je rozklad lesa  $F$ .
- ②  $F_b$  je rankový les s rankem  $\leq s$
- ③  $F_t$  je rankový les s rankem  $\leq r-s-1$

④  $|X_t| \leq |X| / 2$  <sup>nebudeme potřebovat</sup>


rankem lesa uvažujeme max. rank kořenů

Počkejme  $f(m, n, r) := \max$  cost posloupnosti m kompresí v lese ranku r s n vrcholy

i po (částečné) kompresi platí, že směrem nahoru ranky ostře rostou

$f(m, n, r) \leq (r-1)n \dots$  přepojením vrcholů vzroste rank otce  $\leq (r-1)m \dots$  cesta má max. r+1 vrcholů, takže přepojím max. m-1 z nich

z rozkladu stromu dostaneme:



Podle Lemmatu o rozkladu:  $n_t + n_b = n, m_t + m_b \leq m$

$$\& \text{cost}(c) \leq \text{cost}(C_t) + \text{cost}(C_b) + |X_b| - \#roots(\mathcal{F}_b) + \|C_t\|$$

$$\leq f(m_t, n_t, r-s-1) + f(m_b, n_b, s) + n - n_t - (s+1)n_t + m_t$$

Protož  $f(m, n, r) \leq f(m_t, n_t, r-s-1) + f(m_b, n_b, s) + n - (s+1)n_t + m_t$

Všechny má ~~nejméně~~ aspoň s+1 synů v  $X_b$  a jsou to navzájem různé koreny stromů v  $\mathcal{F}_b$

Zkusíme rekurzivní krok: Předpokládejme, že  $f(m, n, r) \leq km + v \cdot g(r)$

Potom:  $f(m, n, r) \leq k \cdot m_t + n_t \cdot g(r-s-1) + f(m_b, n_b, s) + n - (s+1)n_t + m_t$

$$\leq n_t \cdot g(r) \leq f(m_b, n_b, s) \leq -s \cdot n_t$$

volbou  $s = g(r)$ :  $f(m, n, r) \leq (k+1)m_t + f(m_b, n, g(r)) + n - (k+1)(m_b + m_t) \leq m$

$$f(m, n, r) - (k+1)m \leq f(m_b, n, g(r)) - (k+1)m_b + n$$

označíme  $\varphi(m, n, r)$  toto tedy je  $\varphi(m_b, n, g(r))$

Tedy:  $\varphi(m, n, r) \leq \varphi(m_b, n, g(r)) + n$

$$\varphi(m, n, r) \leq n \cdot g^*(r)$$

$$f(m, n, r) \leq n \cdot g^*(r) + (k+1)m$$

Posouvací lemma: Pokud  $f(m, n, r) \leq km + n \cdot g(r)$ , pak také  $f(m, n, r) \leq (k+1)m + n \cdot g^*(r)$

Důsledkem  $f(m, n, r) \leq (k+i)m + n \cdot g^{*i}(r)$

Kde ale začít? Z triv. odhadu máme  $f(m, n, r) \leq (r-1)n$

... tedy  $k=0, g(r)=r-1$  -- jmeně  $g^*(r)$  je také  $r-1$

První krok tedy uděláme trochu jinak. Vyjdeme z  $\otimes$  (dosadíme triv. uvr)

$$f(m, n, r) \leq n_t \cdot (r-s-2) + f(m_b, n_b, s) + n - (s+2)n_t + m_t$$

$$\leq n_t \cdot (r-2s-4) + f(m_b, n_b, s) + n + m_t$$

$s = \lfloor m/2 \rfloor$

$$\leq f(m_b, n_b, r/2) + n + m_t$$

Znovu:  $f(m, n, r) - m \leq f(m_b, n_b, r/2) - m_b + n$

Tedy:  $f(m, n, r) \leq m + n \cdot \log r$  ← to již můžeme iterovat

Iterováním:  $f(m, n, r) \leq (i+1)m + n \cdot \log^{*i} r$

Volba i: ①  $\alpha(r) := \min \{ i \mid \log^{*i}(r) \leq i \}$

$$\Rightarrow f(m, n) \leq (1 + \alpha(\log n)) (m+n)$$

②  $\alpha(m, n, r) := \min \{ i \mid \log^{*i}(r) \leq m/n \}$

$$\Rightarrow f(m, n) \leq (2 + \alpha(m, n, \log n)) m$$