

## 9. Dekompozice stromů

---

V této kapitole ukážeme několik datových struktur založených na myšlence dekompozice problému na dostatečně malé podproblémy, které už umíme (obvykle vhodným kódováním čísla) řešit v konstantním čase.

### Union-Find Problem

**Problém:** Udržování tříd ekvivalence: na počátku máme  $N$  jednoprvkových ekvivalenčních tříd, provádíme operace *Find* (zjištění, zda dva prvky jsou ekvivalentní) a *Union* (sloučení dvou tříd do jedné). Také na to lze pohlížet jako na inkrementální udržování komponent souvislosti neorientovaného grafu: *Union* je přidání hrany, *Find* test, zda dva vrcholy leží v téže komponentě. To se hodí v mnoha algoritmech, kupříkladu v Kruskalově algoritmu pro hledání minimální kostry.

**Triviální řešení:** Prvky každé třídy obarvíme unikátní barvou (identifikátorem třídy). Operace *Find* porovnává barvy, *Union* prvky jedné ze sjednocovaných tříd přebarvuje.

Operace *Find* tak pracuje v konstantním čase, *Union* může zabrat až lineární čas. Můžeme si pomoci tím, že vždy přebarvíme *menší* ze slučovaných ekvivalenčních tříd (budeme si pro každou třídu pamatovat seznam jejích prvků a velikost). Tehdy může být každý prvek přebarven jen  $\mathcal{O}(\log n)$ -krát, jelikož každým přebarvením se alespoň zdvojnásobí velikost třídy, ve které prvek leží. Posloupnost operací *Union*, kterou vznikla třída velikosti  $k$ , tak trvá  $\mathcal{O}(k \log k)$ , takže můžeme bezpečně prohlásit, že amortizovaná složitost operace *Union* je  $\mathcal{O}(\log n)$ .

**Chytřejší řešení:** Každou třídu budeme reprezentovat zakořeněným stromem s hranami orientovanými směrem ke kořeni (jinými slovy pro každý prvek si pamatujeme jeho otce nebo že je to kořen). *Find* nalezne kořeny stromů a porovná je, *Union* připojí kořen jedné třídy pod kořen druhé. Aby stromy nedegenerovaly, přidáme dvě pravidla:

- *Union dle ranku:* každý kořen  $v$  si bude pamatuje svůj rank  $r(v)$ , což je nějaké přirozené číslo. Na počátku jsou všechny ranky nulové. Pokud spojujeme dva stromy s kořeny  $v$ ,  $w$  a  $r(v) < r(w)$ , připojíme  $v$  pod  $w$  a rank zachováme. Pokud  $r(v) = r(w)$ , připojíme libovolně a nový kořen bude mít rank  $r(v) + 1$ .<sup>(1)</sup>
- *Kompresa cest:* pokud z vrcholu vystoupíme do kořene (například během operace *Find*), přepojíme všechny vrcholy na cestě, po které jsme prošli, rovnou pod kořen.

Pro účely analýzy struktury budeme uvažovat také ranky ostatních vrcholů – každý vrchol si ponese svůj rank z doby, kdy byl naposledy kořenem. Struktura se ovšem podle ranků vnitřních vrcholů nijak neřídí a nemusí si je ani pamatovat. Stromu s kořenem ranku  $r$  budeme zkráceně říkat *strom ranku  $r$* .

---

<sup>(1)</sup> Stejně by fungovalo pravidlo *Union dle velikosti*, které připojuje menší strom pod větší, ale ranky máme raději, neb jsou skladnější a snáze se analyzují.

**Invariant C:** Na každé cestě z vrcholu do kořene příslušného stromu ranky ostře rostou. Jinými slovy rank vrcholu, který není kořen, je menší, než je rank jeho otce.

*Důkaz:* Na počátku (pro jednovrcholové stromy) tvrzení jistě platí. Nechť provedeme *Union*, který připojí vrchol  $v$  pod  $w$ . Cesty do kořene z vrcholů, které ležely pod  $w$ , zůstanou zachovány, pouze se vrcholu  $w$  případně zvýší rank. Cesty z vrcholů pod  $v$  se rozšíří o hranu  $vw$ , na které rank  $v$  v každém případě roste. Kompresi cest nahrazuje otce vrcholu jeho vzdálenějším předkem, takže se rank otce může jedinečně zvýšit. ♡

**Invariant R:** Strom ranku  $r$  obsahuje alespoň  $2^r$  vrcholů.

*Důkaz:* Indukcí podle času. Pro jednovrcholové stromy o nulovém ranku tvrzení platí. Nechť připojíme vrchol  $v$  pod vrchol  $w$ . Je-li  $r(v) < r(w)$ , rank stromu zůstane zachován a strom se ještě zvětší. Je-li  $r(v) = r(w)$ , rank stromu se zvětší o 1, ale z indukce víme, že oba spojované stromy měly alespoň  $2^{r(v)}$  vrcholů, takže jejich spojením vznikne strom o alespoň  $2^{r(v)+1}$  vrcholech. Kompresi cest zasahuje pouze do vnitřní struktury stromu, ranky ani velikosti stromů nemění. ♡

**Důsledek:** Rank každého stromu je  $\mathcal{O}(\log n)$ , takže rank každého vnitřního vrcholu taktéž. Díky invariantu C strávíme výstupem z každého vrcholu do kořene také čas  $\mathcal{O}(\log n)$ , takže logaritmická je i složitost operací *Union* a *Find*.

K tomu nám ovšem stačilo samotné pravidlo *Union* podle ranku, o kompresi cest jsme zatím dokázali pouze to, že složitost v nejhorsím případě nezhoršuje.<sup>(2)</sup> Kombinace obou metod se ve skutečnosti chová mnohem lépe:

**Věta:** (Tarjan, van Leeuwen [7]) Posloupnost  $m$  operací *Union* a *Find* provedená na prázdné struktuře s  $n$  vrcholy trvá  $\mathcal{O}(n + m\alpha(m, n))$ , kde  $\alpha$  je inverzní Ackermannova funkce.<sup>(3)</sup>

Důkaz této věty neuvádíme, jelikož je technicky dosti náročný. Místo toho podobnou metodou ukážeme trochu slabší výsledek s iterovaným logaritmem:

**Věta':** Ve struktuře s  $n$  prvky trvá provedení posloupnosti  $m$  operací *Union* a *Find*  $\mathcal{O}((n + m) \cdot \log^* n)$ .

**Definice:** *Věžovou funkci*  $2 \uparrow k$  definujeme následovně:  $2 \uparrow 0 = 1$ ,  $2 \uparrow (k + 1) = 2^{2 \uparrow k}$ .

Funkce  $2 \uparrow k$  je tedy  $k$ -krát iterovaná mocnina dvojky a  $\log^*$  je funkce  $k$  této funkci inverzní.

Vrcholy ve struktuře si nyní rozdělíme podle jejich ranků:  $k$ -tá skupina bude tvořena těmi vrcholy, jejichž rank je od  $2 \uparrow (k - 1) + 1$  do  $2 \uparrow k$ . Vrcholy jsou tedy rozděleny do  $1 + \log^* \log n$  skupin. Odhadněme nyní shora počet vrcholů v  $k$ -té skupině.

---

<sup>(2)</sup> Mimochodem, Kompresi cest samotná by také na složitost  $\mathcal{O}(\log n)$  amortizovaně stačila [7].

<sup>(3)</sup> Je známo [6], že asymptoticky lepší složitosti nelze dosáhnout, a to ani v modelu silnějším než RAM. Námí uváděný algoritmus si téměř vystačí s Pointer Machine, jen porovnávání ranků z tohoto modelu vybočuje. Složitost operací v nejhorsím případě je obecně horší, je znám dolní odhad  $\Omega(\log n / \log \log n)$ ; více viz Alstrup [1].

**Invariant S:** V  $k$ -té skupině leží nejvýše  $n/(2 \uparrow k)$  vrcholů.

*Důkaz:* Nejprve ukážeme, že vrcholů s rankem  $r$  je nejvýše  $n/2^r$ . Kdybychom nekomprimovali cesty, snadno to plyne z invariantů C a R: každému vrcholu ranku  $r$  přiřadíme všech jeho alespoň  $2^r$  potomků. Jelikož ranky na cestách směrem ke kořeni rostou, žádného potomka jsme nemohli přiřadit více vrcholům. Kompresi cest ovšem nemůže invariant porušit, protože nemění ranky ani rozhodnutí, jak proběhne který *Union*.

Ted' už stačí odhad  $n/2^r$  sečíst přes všechny ranky ve skupině:

$$\frac{n}{2^{2 \uparrow (k-1)+1}} + \frac{n}{2^{2 \uparrow (k-1)+2}} + \cdots + \frac{n}{2^{2 \uparrow k}} \leq \frac{n}{2^{2 \uparrow (k-1)}} \cdot \sum_{i=1}^{\infty} \frac{1}{2^i} = \frac{n}{2^{2 \uparrow (k-1)}} \cdot 1 = \frac{n}{2 \uparrow k}.$$

♡

*Důkaz věty:* Operace *Union* a *Find* potřebují nekonstantní čas pouze na vystoupení po cestě ze zadaného vrcholu  $v$  do kořene stromu. Čas strávený na této cestě je přímo úměrný počtu hran cesty. Celá cesta je přitom rozpojena a všechny vrcholy ležící na ní jsou přepojeny přímo pod kořen stromu.

Hrany cesty, které spojují vrcholy z různých skupin (takových je  $\mathcal{O}(\log^* n)$ ), naučtujeme právě prováděné operaci. Celkem jimi tedy strávíme čas  $\mathcal{O}(m \log^* n)$ . Zbylé hrany budeme počítat přes celou dobu běhu algoritmu a účtovat je vrcholům.

Uvažme vrchol  $v$  v  $k$ -té skupině, jehož rodič leží také v  $k$ -té skupině. Jelikož hrany na cestách do kořene ostře rostou, každým přepojením vrcholu  $v$  rank jeho rodiče vzroste. Proto po nejvýše  $2 \uparrow k$  přepojeních se bude rodič vrcholu  $v$  nacházet v některé z vyšších skupin. Jelikož rank vrcholu  $v$  se už nikdy nezmění, bude hrana z  $v$  do jeho otce již navždy hranou mezi skupinami. Každému vrcholu v  $k$ -té skupině tedy naučtujeme nejvýše  $2 \uparrow k$  přepojení a jelikož, jak už víme, jeho skupina obsahuje nejvýše  $n/(2 \uparrow k)$  vrcholů, naučtujeme celé skupině čas  $\mathcal{O}(n)$  a všem skupinám dohromady  $\mathcal{O}(n \log^* n)$ .

♡

## Union-Find s předem známými Uniony

Dále nás bude zajímat speciální varianta Union-Find problému, v níž dopředu známe posloupnost Unionů, čili strom, který spojováním komponent vznikne.<sup>(4)</sup> Jiná interpretace téhož (jen pozpátku) je dekrementální udržování komponent souvislosti lesa: na počátku je dán les, umíme smazat hranu a otestovat, zda jsou dva vrcholy v témže stromu.

Popíšeme algoritmus, který po počátečním předzpracování v čase  $\mathcal{O}(n)$  zvládne *Union* i *Find* v amortizovaně konstantním čase. Tento algoritmus je kombinací dekompozic popsanych Alstrupem [3, 2].

<sup>(4)</sup> Kdy se to hodí? Třeba v Thorupově lineárním algoritmu [8] na nejkratší cesty nebo ve Weiheho taktéž lineárním algoritmu [9] na hledání hranově disjunktních cest v rovinných grafech.


**Definice:** (*Microtree/Macrotree dekompozice*) Pro zakořeněný strom  $T$  o  $n$  vrcholech definujeme:

- *Kořeny mikrostromů* budou nejvyšší vrcholy v  $T$ , pod nimiž je nejvýše  $\log n$  listů a které nejsou kořenem celého  $T$ .
- *Mikrostromy* leží v  $T$  od těchto kořenů níže.
- *Spojovací hrany* vedou z kořenů mikrostromů do jejich otců.
- *Makrostrom* je tvořen zbývajícími vrcholy a hranami stromu  $T$ .

**Pozorování:** Každý mikrostrom má nejvýše  $\log n$  listů. Pod každým listem makrostromu leží alespoň jeden mikrostrom (může jich být i více, viz dekompozice hvězdy na obrázku), takže listů makrostromu je nejvýše  $n/\log n$ .

Vnitřních vrcholů makro- i mikrostromů ale může být nešikovně mnoho, protože se ve stromech mohou vyskytovat dlouhé cesty. Pomůžeme si snadno: každou cestu si budeme pamatovat zvlášť a ve stromu ji nahradíme hranou, která bude vložena právě tehdy, když budou přítomny všechny hrany cesty.

**Příklad:** Následující obrázek ukazuje dekompozici několika stromů za předpokladu, že  $\log n = 4$ . Vrcholy mikrostromů jsou černé, makrostromu bílé. Spojovací hrany kreslíme tečkovaně, hrany komprimovaných cest tučně.



**Algoritmus pro cesty:** Cestu délky  $l$  rozdělíme na úseky délky  $\log n$ , pro něž si uložíme množiny již přítomných hran (po bitech jako čísla). Pak si ještě pamatujeme zkomprimovanou cestu (hrany odpovídají úsekům a jsou přítomny právě tehdy, jsou-li přítomny všechny hrany příslušného úseku) délky  $l/\log n$  a pro ni „přebarvovací“ strukturu pro Union-Find.

$Union(x, y)$  (přidání hrany  $e = xy$  do cesty):

1. Přidáme  $e$  do množiny hran přítomných v příslušném úseku.
2. Pokud se tím úsek naplnil, přidáme odpovídající hranu do zkomprimované cesty.

$Find(x, y)$  :

1. Pokud  $x$  a  $y$  jsou v témže úseku, otestujeme bitovými operacemi, zda jsou všechny hrany mezi  $x$  a  $y$  přítomny.
2. Pokud jsou v různých úsecích, rozdělíme cestu z  $x$  do  $y$  na posloupnost celých úseků, na které nám odpoví zkomprimovaná cesta, a dva dotazy v krajních částečných úsecích.

Operace uvnitř úseků pracují v čase  $\mathcal{O}(1)$ , operace na zkomprimované cestě v  $\mathcal{O}(\log l)$  amortizovaně, ale za dobu života struktury je jich  $\mathcal{O}(l/\log n) = \mathcal{O}(l/\log l)$ , takže celkově zaberou lineární čas.

**Kompresce cest:** Operace na mikro/makro-stromech budeme následujícím způsobem převádět na operace s jejich cestově komprimovanými podobami a na operace s cestovými strukturami:

*Union*( $x, y$ ):

1. Pokud  $e = xy$  leží uvnitř nějaké cesty, přidáme ji do cesty, což buďto způsobí přidávání jiné hrany, a nebo už jsme hotovi.
2. Provedeme *Union* v komprimovaném stromu.

*Find*( $x, y$ ):

1. Pokud  $x$  a  $y$  leží uvnitř jedné cesty, zeptáme se cestové struktury a končíme.
2. Pokud  $x$  leží uvnitř nějaké cesty, zjistíme dotazem na cestovou strukturu, ke kterému krajnímu vrcholu cesty je připojen, a  $x$  nahradíme tímto vrcholem. Není-li připojen k žádnému, je evidentně odpověď na celý *Find* negativní; pokud k oběma, vybereme si libovolný, protože jsou stejně v cestově komprimovaném stromu spojeny hranou. Analogicky pro  $y$ .
3. Zeptáme se struktury pro komprimovaný strom.

**Algoritmus pro mikrostromy:** Po kompresi cest má každý mikrostrom nejvýše  $2 \log n$  vrcholů, čili také nejvýše tolik hran. Hrany si očíslováme přirozenými čísly, každou množinu hran pak můžeme reprezentovat  $(2 \log n)$ -bitovým číslem a množinové operace provádět pomocí bitových v konstantním čase.

Pro každý mikrostrom si předpočítáme pro všechny jeho vrcholy  $v$  množiny  $P_v$  hran ležících na cestě z kořene mikrostromu do  $v$ . Navíc si budeme pro celý mikrostrom pamatovat množinu přítomných hran  $F$ .

*Union*( $x, y$ ) :

1. Najdeme pořadové číslo  $i$  hrany  $xy$  (máme předpočítané).
2.  $F \leftarrow F \cup \{i\}$ .

*Find*( $x, y$ ) :

1.  $P \leftarrow P_x \Delta P_y$  (množina hran ležících na cestě z  $x$  do  $y$ ).
2. Pokud  $P \setminus F = \emptyset$ , leží  $x$  a  $y$  ve stejné komponentě, jinak ne.

**Algoritmus pro celý problém:** Strom rozložíme na mikrostromy, makrostrom a spojovací hrany. V mikrostromech i makrostromu zkomprimujeme cesty. Pro cesty a mikrostromy použijeme výše popsané struktury, pro každou spojovací hranu si budeme pamatovat jen značku, zda je přítomna, a pro makrostrom přebarvovací strukturu.

*Union*( $x, y$ ):

1. Pokud  $e = xy$  je spojovací, poznamenáme si, že je přítomna, a končíme.

2. Nyní víme, že  $e$  leží uvnitř mikrostromu nebo makrostromu, a tak provedeme *Union* na příslušné struktuře.

*Find*( $x, y$ ):

1. Leží-li  $x$  a  $y$  v jednom mikrostromu, zeptáme se struktury pro mikrostrom.
2. Je-li  $x$  uvnitř mikrostromu, zeptáme se mikrostruktury na spojení s kořenem mikrostromu. Není-li, odpovíme NE, stejně jako když není přítomna příslušná spojovací hrana. Jinak  $x$  nahradíme listem makrostromu, do kterého spojovací hrana vede. Podobně pro  $y$ .
3. Odpovíme podle struktury pro makrostrom.

**Analýza:** Operace *Find* trvá konstantní čas, protože se rozloží na  $\mathcal{O}(1)$  *Find*ů v dílčích strukturách a každý z nich trvá konstantně dlouho. Všech  $n$  operací *Union* trvá  $\mathcal{O}(n)$ , jelikož způsobí  $\mathcal{O}(n)$  amortizovaně konstantních operací s mikrostromy, spojovacími hranami a cestami a  $\mathcal{O}(n/\log n)$  operací s makrostromem, které trvají  $\mathcal{O}(\log n)$  amortizovaně každá.<sup>(5)</sup>

**Cvičení:** Zkuste pomocí dekompozice vyřešit následující problém: je dán strom, jehož každý vrchol může být označený. Navrhněte datovou strukturu, která bude umět v čase  $\mathcal{O}(\log \log n)$  označit nebo odznačit vrchol a v čase  $\mathcal{O}(\log n / \log \log n)$  najít nejbližšího označeného předchůdce.

## Fredericksonova clusterizace

Mikro/makro-stromová dekompozice není jediný způsob, jak stromy rozkládat. Někdy se více hodí následující myšlenka:

**Definice:** (*Fredericksonova clusterizace*) Nechť  $k \geq 1$  je přirozené číslo a  $T$  strom s maximálním stupněm nejvýše 3. Pak  $k$ -clusterizací stromu  $T$  nazveme libovolný rozklad  $V_1 \cup \dots \cup V_k$  množiny  $V(T)$ , pro který platí:

- Podgrafy stromu  $T$  indukované jednotlivými  $V_i$  jsou souvislé. Těmto podgrafům budeme říkat *clustery* a značit je  $C_i$ .
- Z každého clusteru vedou nejvýše 3 hrany do sousedních clusterů. Takovým hranám říkáme *vnější*, jejich počet je *vnější stupeň* clusteru  $ed(C_i)$ . Hrany uvnitř clusterů nazveme *vnitřní*.
- Nechť  $|C_i|$  značí počet vrcholů clusteru  $C_i$ . Pak pro všechny clustery platí  $|C_i| \leq k$  a pro clustery vnějšího stupně 3 dokonce  $|C_i| = 1$ .
- Žádné dva sousední clustery není možné sloučit.

**Umluva:** Clustery vnějšího stupně 0 se nazývají *izolované*, stupně 1 *listové*, stupně 2 *cestové* a stupně 3 *větvivé*.

---

<sup>(5)</sup> To je v průměru  $\mathcal{O}(1)$  na operaci a dokonce i amortizovaně, pokud necháme inicializaci struktury, která je lineární, naspořit potenciál  $\mathcal{O}(n)$ , ze kterého budeme průběžně platit slučování v makrostromu.

**Pozorování:** Necht  $C$  a  $D$  jsou sousední clustery (bez újmy na obecnosti  $ed(C) \geq ed(D)$ ). Kdy je lze sloučit? Především  $|C| + |D|$  musí být nejvýše rovno  $k$ . Pak mohou nastat následující případy:

- Pokud  $C$  i  $D$  jsou listové, lze je sloučit do jednoho izolovaného clusteru.
- Pokud  $C$  je cestový a  $D$  listový, lze je sloučit do listového clusteru.
- Pokud  $C$  i  $D$  jsou cestové, lze je sloučit do cestového clusteru.
- Pokud  $C$  je větvičí a  $D$  listový, lze je sloučit do cestového clusteru.
- V ostatních případech slučovat nelze, neboť by vznikl cluster vnějšího stupně 4 nebo stupně 3 s více než jedním vrcholem.

**Věta:** (Frederickson [5]) Každá  $k$ -clusterizace stromu  $T$  na  $n$  vrcholech obsahuje  $\mathcal{O}(n/k)$  clusterů.

*Důkaz:* Pokud clusterizace obsahuje pouze izolované nebo listové clustery, pak je konstantně velká a tvrzení triviálně platí.

Pokud navíc obsahuje cestové clustery, musí být clustery propojeny do jedné cesty, která začíná a končí listovými clustery a ostatní clustery jsou cestové. Cestové clustery rozdělíme na velké (alespoň  $k/2$  vrcholů) a malé (ostatní). Všimneme si, že malé spolu nemohou sousedit. Velkých je přitom nejvýše  $n/k$ , takže malých nejvýše  $n/k + 1$ .

Zbývá obecný případ, v němž jsou i větvičí clustery. Uvažme clusterizační strom  $S$ : jeho vrcholy odpovídají clusterům, hrany externím hranám mezi nimi. Tento strom zakořeňme v libovolném větvičím clusteru.

Pokud ve stromu  $S$  nahradíme každou nevětvičí se cestu hranou, vznikne nějaký komprimovaný strom  $S'$ . V něm už jsou pouze listové clustery (coby listy) a větvičí clustery (jako vnitřní vrcholy).

Nyní si všimneme, že pro každý list  $\ell$  stromu  $S$  platí, že tento cluster spolu s cestovými clustery nad ním (které se schovaly do hrany mezi  $\ell$  a jeho otcem) musí mít velikost alespoň  $k$ . V opačném případě by totiž bylo možné tyto clustery společně s větvičím clusterem nad nimi sloučit do jediného clusteru, což by porušilo poslední podmínku z definice clusterizace.

Proto strom  $S'$  obsahuje nejvýše  $n/k$  listů. A jelikož všechny jeho vnitřní vrcholy mají alespoň 2 syny, musí být vnitřních vrcholů také nanejvýš  $n/k$ .

Zbývá započítat cestové clustery. Uvažme hranu  $e$  stromu  $S'$  a cestové clustery, které se do ní zkomprimovaly. Už víme, že je-li celková velikost těchto clusterů  $r$ , může jich být nanejvýš  $2r/k + 1$ . A jelikož clustery jsou disjunktní, v součtu přes všechny hrany  $e$  dostaneme  $2n/k + \text{počet hran stromu } S' = \mathcal{O}(n/k)$ .

Clusterů všech typů je tedy dohromady  $\mathcal{O}(n/k)$ . ♥

**Věta:** (Frederickson [5]) Pro každé  $k$  lze  $k$ -clusterizaci stromu o  $n$  vrcholech najít v čase  $\mathcal{O}(n)$ .

*Důkaz:* Clusterizaci lze najít upraveným hledáním do hloubky, ale při tom je nutné řešit mnoho různých případů slučování clusterů. Místo toho použijeme následující hladový algoritmus.

Nejprve vytvoříme z každého vrcholu triviální cluster. Taková clusterizace splňuje všechny podmínky kromě poslední. Budeme tedy clustery hladově slučovat.

Pořídíme si frontu clusterů, u nichž jsme ještě nezkontrolovali slučitelnost. Na počátku do ní umístíme všechny clustery. Pak vždy odebereme cluster, prozkoumáme jeho sousedy a pokud mezi nimi je nějaký, s nímž lze slučovat, tak to provedeme. Nový cluster uložíme do fronty, oba staré z fronty odstraníme.

Všimneme si, že při každé kontrole poklesne velikost fronty o 1 – buďto jsme neslučovali a zmizel pouze kontrolovaný cluster, anebo slučovali, ale pak zmizely dva clustery a přibyl jeden. Jelikož kontrolu i sloučení zvládneme v konstantním čase, celý algoritmus doběhne v čase  $\mathcal{O}(n)$ .  $\heartsuit$

**Použití:** Předchozí variantu Union-Find problému bychom také mohli vyřešit nahrazením vrcholů stupně většího než 3 „kruhovými objezdy bez jedné hrany“, nalezením  $(\log n)$ -clusterizace, použitím bitové reprezentace množin uvnitř clusterů a přebarvovací struktury na hrany mezi clustery.

## Stromová předchůdci

**Problém:** (*Least Common Ancestor alias LCA*) Chceme si předzpracovat zakoreněný strom  $T$  tak, abychom dokázali pro libovolné dva vrcholy  $x, y$  najít co nejrychleji jejich nejbližší společného předchůdce.

### Triviální řešení LCA:

- Vystoupáme z  $x$  i  $y$  do kořene, označíme vrcholy na cestách a kde se poprvé potkají, tam je hledaný předchůdce. To je lineární s hloubkou a nepotřebuje předzpracování.
- Vylepšení: Budeme stoupat z  $x$  a  $y$  střídavě. Tak potřebujeme jen lineárně mnoho kroků vzhledem ke vzdálenosti společného předchůdce.
- Předpočítáme všechny možnosti: předzpracování  $\mathcal{O}(n^2)$ , dotaz  $\mathcal{O}(1)$ .
- ... co dál?

Věrní vtipům o matfyzácích a článku [4] převedeme raději tento problém na jiný.

**Problém:** (*Range Minimum Query alias RMQ*) Chceme předzpracovat posloupnost čísel  $a_1, \dots, a_n$  tak, abychom uměli rychle počítat  $\min_{x \leq i \leq y} a_i$ .<sup>(6)</sup>

**Lemma:** LCA lze převést na RMQ s lineárním časem na předzpracování a konstantním časem na převod dotazu.

*Důkaz:* Strom projdeme do hloubky a pokaždé, když vstoupíme do vrcholu (ať již poprvé nebo se do něj vrátíme), zapíšeme jeho hloubku. LCA( $x, y$ ) pak bude nejvyšší vrchol mezi libovolnou návštěvou  $x$  a libovolnou návštěvou  $y$ .  $\heartsuit$

### Triviální řešení RMQ:

- Předpočítáme všechny možné dotazy: předzpracování  $\mathcal{O}(n^2)$ , dotaz  $\mathcal{O}(1)$ .
- Pro každé  $i$  a  $j \leq \log n$  předpočítáme  $m_{ij} = \min\{a_i, a_{i+1}, \dots, a_{i+2^j-1}\}$ , čili minima všech bloků velkých jako nějaká mocnina dvojky. Když se

---

<sup>(6)</sup> Všimněte si, že pro sumu místo minima je tento problém velmi snadný.



poté někdo zeptá na minimum bloku  $a_i, a_{i+1}, \dots, a_{j-1}$ , najdeme největší  $k$  takové, že  $2^k < j - i$  a vrátíme:

$$\min(\min\{a_i, \dots, a_{i+2^k-1}\}, \min\{a_{j-2^k}, \dots, a_{j-1}\}).$$

Tak zvládneme dotazy v čase  $\mathcal{O}(1)$  po předzpracování v čase  $\mathcal{O}(n \log n)$ .

My si ovšem všimneme, že náš převod z LCA vytváří dosti speciální instance problému RMQ, totiž takové, v nichž je  $|a_i - a_{i+1}| = 1$ . Takovým instancím budeme říkat  $\text{RMQ}\pm 1$  a budeme je umět řešit šikovnou dekompozicí.

**Dekompozice** pro  $\text{RMQ}\pm 1$ : Vstupní posloupnost rozdělíme na bloky velikosti  $b = 1/2 \cdot \log n$ , každý dotaz umíme rozdělit na část týkající se celých bloků a maximálně dva dotazy na části bloků.

Všimneme si, že ačkoliv bloků je mnoho, jejich možných typů (tj. posloupností klesání a stoupání) je pouze  $2^{b-1} \leq \sqrt{n}$  a bloky téhož typu se liší pouze posunutím o konstantu. Vybudujeme proto kvadratickou strukturu pro jednotlivé typy a pro každý blok si zapamatujeme, jakého je typu a jaké má posunutí. Celkem strávíme čas  $\mathcal{O}(n + \sqrt{n} \cdot \log^2 n) = \mathcal{O}(n)$  předzpracováním a  $\mathcal{O}(1)$  dotazem.

Mimo to ještě vytvoříme komprimovanou posloupnost, v níž každý blok nahradíme jeho minimem. Tuto posloupnost délky  $n/b$  budeme používat pro části dotazů týkající se celých bloků a připravíme si pro ni „logaritmicou“ variantu triviální struktury. To nás bude stát  $\mathcal{O}(n/b \cdot \log(n/b)) = \mathcal{O}(n/\log n \cdot \log n) = \mathcal{O}(n)$  na předzpracování a  $\mathcal{O}(1)$  na dotaz.

Tak jsme získali algoritmus pro  $\text{RMQ}\pm 1$  s konstantním časem na dotaz po lineárním předzpracování a výše zmíněným převodem i algoritmus na LCA se stejnými parametry. Ještě ukážeme, že převod může fungovat i v opačném směru, a tak můžeme získat i konstantní/lineární algoritmus pro obecné RMQ.

**Definice:** *Kartézský strom* pro posloupnost  $a_1, \dots, a_n$  je strom, jehož kořenem je minimum posloupnosti, tj. nějaké  $a_j = \min_i a_i$ , jeho levý podstrom je kartézský strom pro  $a_1, \dots, a_{j-1}$  a pravý podstrom kartézský strom pro  $a_{j+1}, \dots, a_n$ .

**Lemma:** Kartézský strom je možné zkonstruovat v lineárním čase.

*Důkaz:* Použijeme inkrementální algoritmus. Vždy si budeme pamatovat kartézský strom pro již zpracované prvky a pozici posledního zpracovaného prvku v tomto stromu. Když přidáváme další prvek, hledáme místo, kam ho připojit, od tohoto označeného prvku nahoru. Povšimněme si, že vzhledem k potenciálu rovnému hloubce označeného prvku je časová složitost přidání prvku amortizovaně konstantní. ♥

**Lemma:** RMQ lze převést na LCA s lineárním časem na předzpracování a konstantním časem na převod dotazu.

*Důkaz:* Sestrojíme kartézský strom a RMQ převedeme na LCA v tomto stromu. ♥

Výsledky této podkapitoly můžeme shrnout do následující věty:

**Věta:** Problémy LCA i RMQ je možné řešit v konstantním čase na dotaz po předzpracování v lineárním čase.

**Cvičení:** Vymyslete jednodušší strukturu pro RMQ, víte-li, že všechny dotazy budou na intervaly stejné délky.

## Literatura

- [1] S. Alstrup, A. Ben-Amram, and T. Rauhe. Worst-case and amortised optimality in union-find. In *Proceedings of the 31st annual ACM symposium on Theory of computing*, pages 499–506. ACM, 1999.
- [2] S. Alstrup, T. Husfeldt, and T. Rauhe. Marked ancestor problems. In *IEEE Symposium on Foundations of Computer Science*, pages 534–544, 1998.
- [3] S. Alstrup, J. P. Secher, and M. Spork. Optimal on-line decremental connectivity in trees. *Information Processing Letters*, 64(4):161–164, 1997.
- [4] M. A. Bender and M. Farach-Colton. The LCA problem revisited. In *Latin American Theoretical INformatics*, pages 88–94, 2000.
- [5] G. N. Frederickson. Ambivalent data structures for dynamic 2-edge-connectivity and  $k$  smallest spanning trees. In *IEEE Symposium on Foundations of Computer Science*, pages 632–641, 1991.
- [6] M. Fredman and M. Saks. The cell probe complexity of dynamic data structures. In *STOC '89: Proceedings of the 21st annual ACM Symposium on Theory of Computing*, pages 345–354, 1989.
- [7] R. E. Tarjan and J. van Leeuwen. Worst-case analysis of set union algorithms. *J. ACM*, 31(2):245–281, 1984.
- [8] M. Thorup. Undirected single-source shortest paths with positive integer weights in linear time. *Journal of the ACM (JACM)*, 46(3):362–394, 1999.
- [9] K. Weihe. Edge-Disjoint  $(s, t)$ -Paths in Undirected Planar Graphs in Linear Time. *Journal of Algorithms*, 23(1):121–138, 1997.