



Pokročilá algoritmizace


dynamické datové struktury,
garbage collector,
haldy

Jiří Vyskočil, Marko Genyg-Berezovskyj

2009

Dynamické datové struktury

Reprezentace datové paměti programu:




Dynamické datové struktury

- cíle alokátoru dynamické paměti
 - Minimalizovat čas alokace a dealokace (případně ještě realokace).
 - Minimalizovat prostor, včetně minimalizace fragmentace.
 - Maximalizovat lokalitu – alokovat objekty, které se užívají často společně, blízko u sebe. To snižuje počet přestránkování a výpadků na cache paměti.

Dynamické datové struktury

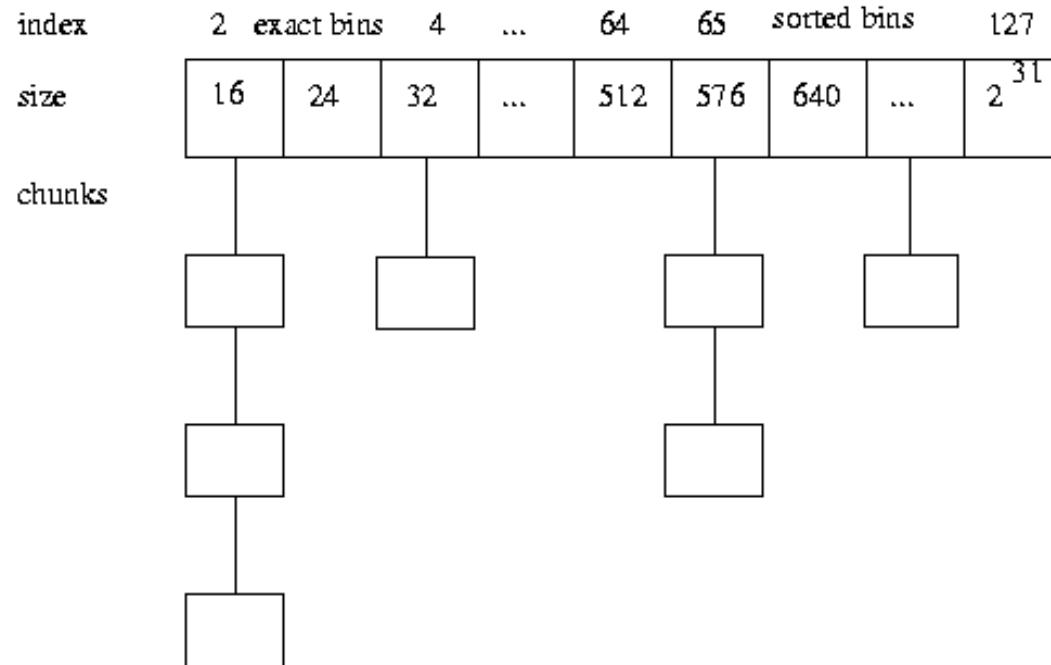
- reprezentace dynamické paměti

- Dva bloky vedle sebe volných *bloků paměti* (chunk) mohou být spojeny do jednoho.
- Jednotlivé bloky paměti mohou být procházeny oběma směry.
- Volné bloky paměti jsou mezi sebou propojeny (viz dále).



Dynamické datové struktury

- Volné bloky paměti jsou rozděleny do skupin (bins) podle velikosti.
- Velikost bloků je zarovnaná (některé architektury to přímo vynucují).
- Do určité velikosti jsou skupiny zastoupeny pro každou velikost.
- Při alokaci objektu se začne hledat ve skupině s nejbližší stejnou nebo vyšší velikostí (tzv. best-fit order).



Dynamické datové struktury

- dealokace probíhá následovně:
 - Podíváme se před a za dealokovaný blok. Pokud před ním nebo za ním existuje volný blok, spojíme takové bloky do jednoho. (nejdříve samozřejmě odpojíme tyto krajní volné bloky z příslušné skupiny). Tato operace zamezuje fragmentaci bloků.
 - Výsledný blok přeznačujeme na volný blok a připojíme do skupiny odpovídající velikosti tohoto bloku.
- Díky mnoha potřebným informacím ve volném bloku je jeho minimální velikost poměrně velká.
- Lokalitu alokace lze řešit procházením vedlejších volných bloků (nearest-fit) často aproximovaná nalézáním dalšího volného bloku (next-fit). Tyto strategie vedou často k vysoké fragmentaci.
- Fragmentaci lze obecně obejít alokací paměti přímo přes operační systém (pokud implementuje stránkování). Je to ovšem pomalejší a minimální velikost bloku je stejná jako velikost stránky. Tyto techniky se často používají při ladění (např. knihovna efence) přidáním volných stránek před nebo za alokované bloky.

Garbage collector

■ garbage collector (GC)

- je označení pro metodu automatické správy paměti programu.

■ základní princip

1. V programu se vyhledají takové datové objekty, které již nebudou v budoucnu použity.
2. Navrátí se zdroje tam, kde se nalezené objekty vyskytovaly.

■ Výhody

- programátor se nemusí starat o rušení objektů
- zabraňuje chybám ukazatelů
 - přístup k objektu, který byl již zrušen
 - dvojité zrušení již zrušeného objektu
 - zapomínání rušení již nepotřebných objektů

■ Nevýhody

- GC vyžaduje pro svou práci další výpočetní prostředky
- během své činnosti vytváří v programu různé dlouhé běhové prodlevy, takže není vhodný pro nasazení v real-time systémech.
- přídatné informace, které GC potřebuje pro svůj běh zvyšují nároky na paměť
- sémantický GC je neřešitelný problém (většina současných GC pracuje na syntaktické úrovni)

Garbage collector - počítání referencí


■ algoritmus počítání referencí

- Vůbec první algoritmus pro GC se jmenoval *počítání referencí* (reference counting) :
 - Ke každému objektu je přiřazen čítač referencí.
 - Když je objekt vytvořen, jeho čítači je nastavena hodnota 1.
 - V okamžiku, kdy si nějaký jiný objekt nebo kořen programu (kořeny jsou hledány v programových registrech, v lokálních proměnných uložených v zásobnících jednotlivých vláken a ve statických proměnných) uloží referenci na tento objekt, hodnota čítače je zvětšena o 1.
 - Ve chvíli, kdy je reference mimo rozsah platnosti (např. po opuštění funkce, která si referenci uložila), nebo když je referenci přiřazena nová hodnota, čítač je snížen o 1.
 - Jestliže je hodnota čítače některého objektu nulová, může být tento objekt uvolněn z paměti.
 - Když je uvolňován z paměti, všem objektům, na něž má objekt referenci, se sníží hodnota o 1 - tedy uvolnění jednoho objektu může vést k uvolnění dalších objektů.

Garbage collector - počítání referencí

■ algoritmus počítání referencí

- Nevýhoda této metody spočívá ve faktu, že neumí detekovat cykly. Cyklus nastává v okamžiku, kdy dva a více objektů ukazují samy na sebe. Takové dva objekty nebudou mít nikdy čítač roven nule, přestože jsou nedosažitelné z kořene programu.



- Další nevýhoda spočívá v režii, která je nutná pro zvyšování a snižování čítačů u každého objektu.
- Kvůli těmto nedostatkům se reference counting v dnešní době nepoužívá jako univerzální GC.

Garbage collector - Mark & Sweep

■ algoritmus Mark & Sweep

- Patří mezi *trasovací algoritmy*. Ty fungují tak, že tzv. „zastaví svět“ (v tomto smyslu tedy běh programu) a začnou vyhledávat objekty. Začínají v kořenové množině programu a pokračují po referencích, dokud neprozkoumají všechny dosažitelné objekty. Algoritmy, založené na tomto principu, se používají téměř výlučně pro implementaci GC v dnešních programovacích jazycích.

■ popis

- Algoritmus nejdříve nastaví všem objektům, které jsou v paměti, speciální příznak *navštíven* na hodnotu *ne*.
- Poté projde všechny objekty, ke kterým se lze dostat. Těm, které takto navštívil, nastaví příznak na hodnotu *ano*.
- V okamžiku, kdy se už nemůže dostat k žádnému dalšímu objektu, znamená to, že všechny objekty s příznakem *navštíven* majícím hodnotu *ne* jsou odpad - a mohou být tedy uvolněny z paměti.

■ nevýhody

- Největší nevýhodou je, že při GC je přerušen běh programu. To znamená, že se programy pravidelně na předem neznámou dobu „zmrazí“. Tato nevýhoda lze řešit inkrementální verzí s třemi stavy u každého objektu tzv. Tri-color Marking algoritmem.

■ výhody

- Lze realizovat s konstantní paměťovou složitostí.

Garbage collector - kopírovací

■ kopírovací algoritmus

- Tento algoritmus nejprve rozdělí prostor na haldě na dvě části, kdy jedna je aktivní a s druhou se nepracuje.
- Vždy můžeme alokovat objekty v celkové velikosti, která je poloviční velikost haldy.
- Pokud se při alokaci nevejdeme do místa na části haldy, je potřeba provést úklid.
- Úklid spočívá v prohození aktivní a neaktivní části.
- Do nově aktivní části se překopírují živé objekty ze staré, již neaktivní, části.
- Mrtvé objekty nekopírujeme, ale při dalším prohození aktivní a neaktivní části je jednoduše přepíšeme.

■ nevýhody

- Kopírovací algoritmus probíhá zdlouhavě, protože se objekty musí přesouvat z částí haldy. Kvůli náročnosti celého přesunu tedy mohou být prodlevy ještě znatelnější než při použití mark & sweep.

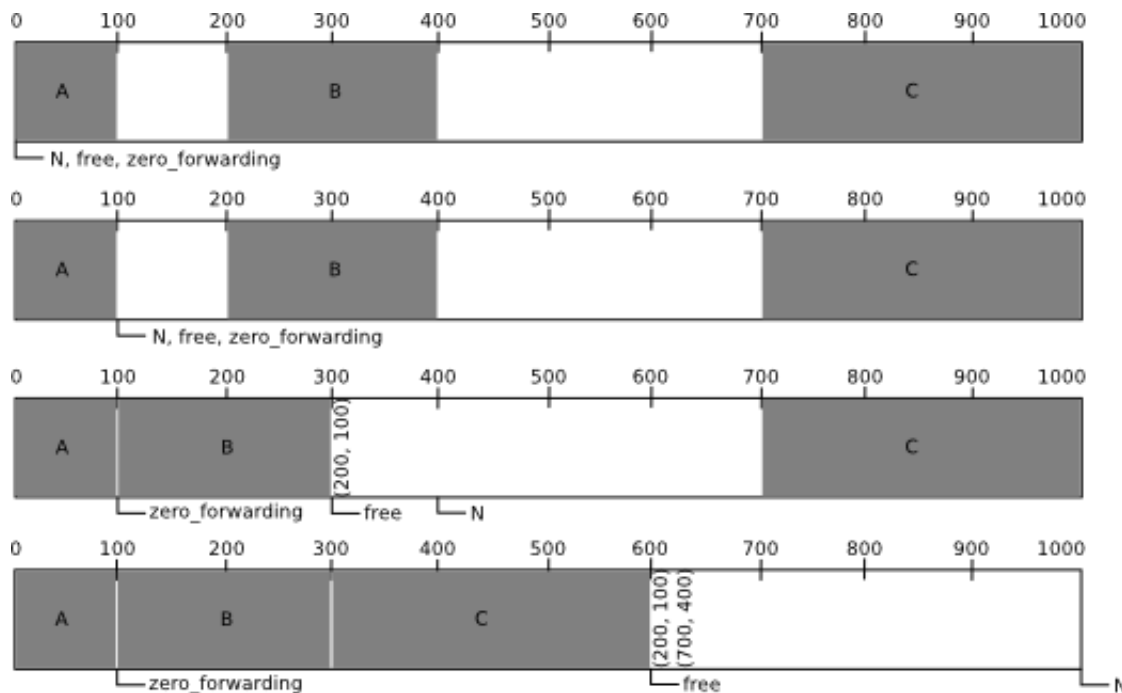
■ výhody

- Nenastává fragmentace jako u Mark & Sweep. Objekty jsou totiž udržovány na spodku právě používaného prostoru, proto stačí k jejich adresování mnohem menší rozptyl adres.
- Alokoace nových objektů je výrazně jednodušší a rychlejší než u standardních alokátoru (ve srovnání například s C/C++).

Garbage collector – Mark & Compact

■ algoritmus Mark & Compact

- Odstraňuje problém fragmentace Mark & Sweep algoritmu.
- Odstraňuje problém dvojnásobné potřeby paměti u kopírovacího algoritmu.
- Odstraňuje problém zbytečného kopírování velkých dlouhodobých objektů u kopírovacího algoritmu.
- 1. fáze je stejná jako u Mark & Sweep, ale v druhé provede při odstraňování objektu navíc defragmentaci.



Garbage collector - generační

■ generační algoritmus

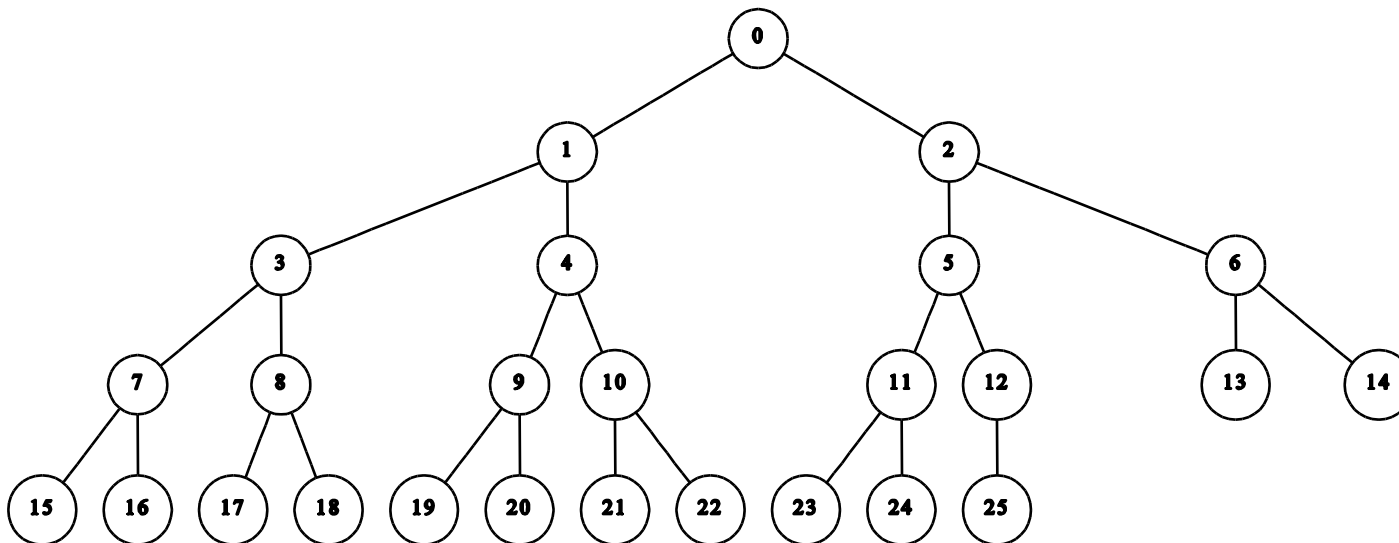
- Při použití GC se dají empiricky vypožorovat dva důležité fakty.
 - mnoho objektů se stane odpadem krátce po svém vzniku.
 - malé procento referencí ve „starších“ objektech ukazuje na objekty mladší.
- U trasovacích algoritmů, kde se využívá celá halda, musel GC při každém spuštění procházet mezi objekty a všechny živé objekty buďto překopírovat do jiné části haldy, nebo je označit a dále projít celou haldu a uvolnit mrtvé. A právě z důvodu brzkého *úmrťi* většiny objektů je tato metoda velice neefektivní.
- *Generační* GC využívá těchto skutečností a rozděluje si paměť programu do několika částí, tzv. *generací*.
- Objekty jsou vytvářeny ve spodní (nejmladší) generaci a po splnění určité podmínky, obvykle stárí, jsou přeřazeny do starší generace.
- Pro každou generaci může být úklid prováděn v rozdílných časových intervalech (obvykle nejkratší intervaly budou pro nejmladší generaci) a dokonce pro rozdílné generace mohou být použity rozdílné algoritmy úklidu.
- V okamžiku, kdy se prostor pro spodní generaci zaplní, všechny dosažitelné objekty v nejmladší generaci jsou zkopírovány do starší generace. I tak bude množství kopírovaných objektů pouze zlomkem z celkového množství mladších objektů, jelikož většina z nich se již stala odpadem.

- halda (anglicky heap)
 - datová struktura (obvykle stromová struktura s vlastností: Pokud A je potomek B , potom $B \leq A$), která je specializovaná na provádění následujících operací (vhodná pro reprezentaci prioritní fronty):
 - **Insert** (x)
 - Vloží prvek x do haldy.
 - **AccessMin**
 - Vrátí nejmenší prvek haldy.
 - **DeleteMin**
 - Odstraní z haldy nejmenší prvek (obvykle kořen).
 - **DecreaseKey** (x, d)
 - Zmenší hodnotu prvku x o d .
 - **Merge** (H_1, H_2)
 - Sloučí haldy H_1 a H_2 do jedné, kterou vrátí.
 - **Delete** (x)
 - Odstraní prvek x z haldy.

Binární halda

■ binární halda

- Je binární strom s následujícími vlastnostmi:
 - Je vyvážený až do předposledního patra. Poslední patro je postupně zaplněno zleva doprava.
 - Každý vrchol je menší nebo roven všem svým potomkům.

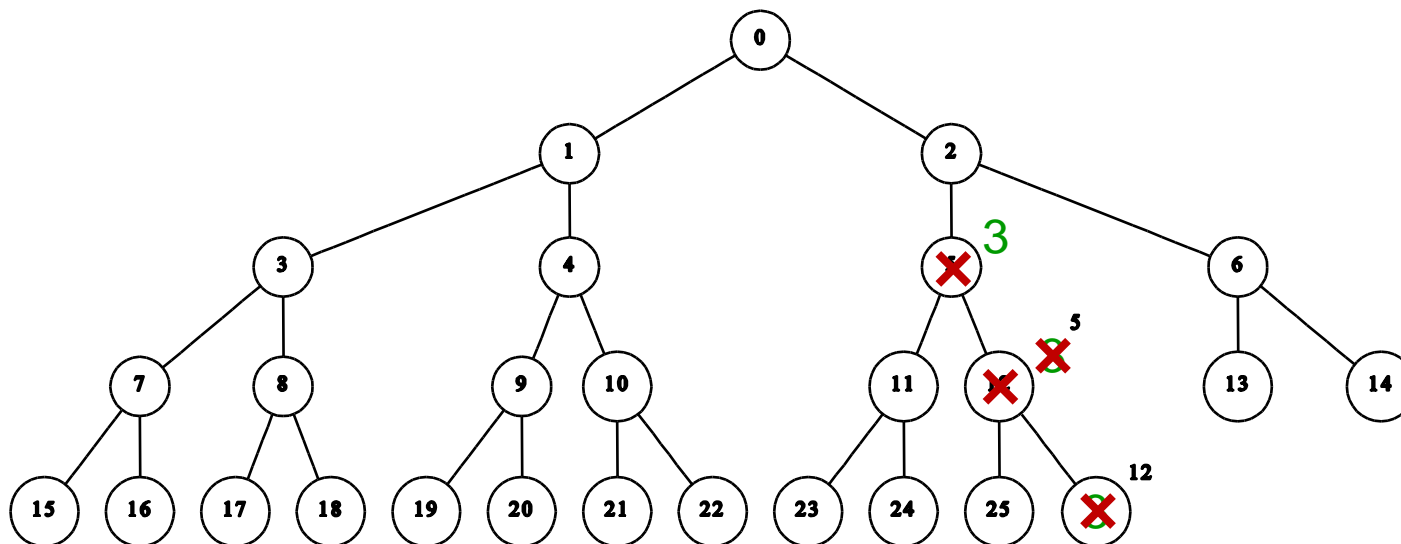


Binární halda - Insert

■ Insert (x)

1. Přidáme prvek x na konec haldy;
2. **while** ($\text{parent}(x)^\dagger > x$) {
3. Prohodíme umístění prvku x s prvkem $\text{parent}(x)$;
4. }

$^\dagger\text{parent}(x)$ vrací rodiče x . Pro prvek x , který nemá rodiče vrací $\text{parent}(x)$ x .



■ AccessMin

- Je kořen binárního stromu haldy.

■ DeleteMin

1. $\&x$ = umístění kořene haldy;
2. $x = +\infty$;
3. $\&y$ = umístění posledního prvku haldy;
4. **do** {
5. Prohodíme umístění prvku x s prvkem y ;
6. $\&x = \&y$;
7. **for each** $z \in \text{descendants}(x)^\dagger$ **do**
8. **if** $(y > z)$ **then** $\&y = \&z$;
9. }
10. Odstraníme poslední prvek haldy.

$^\dagger \text{descendants}(x)$ vrací všechny potomky x .

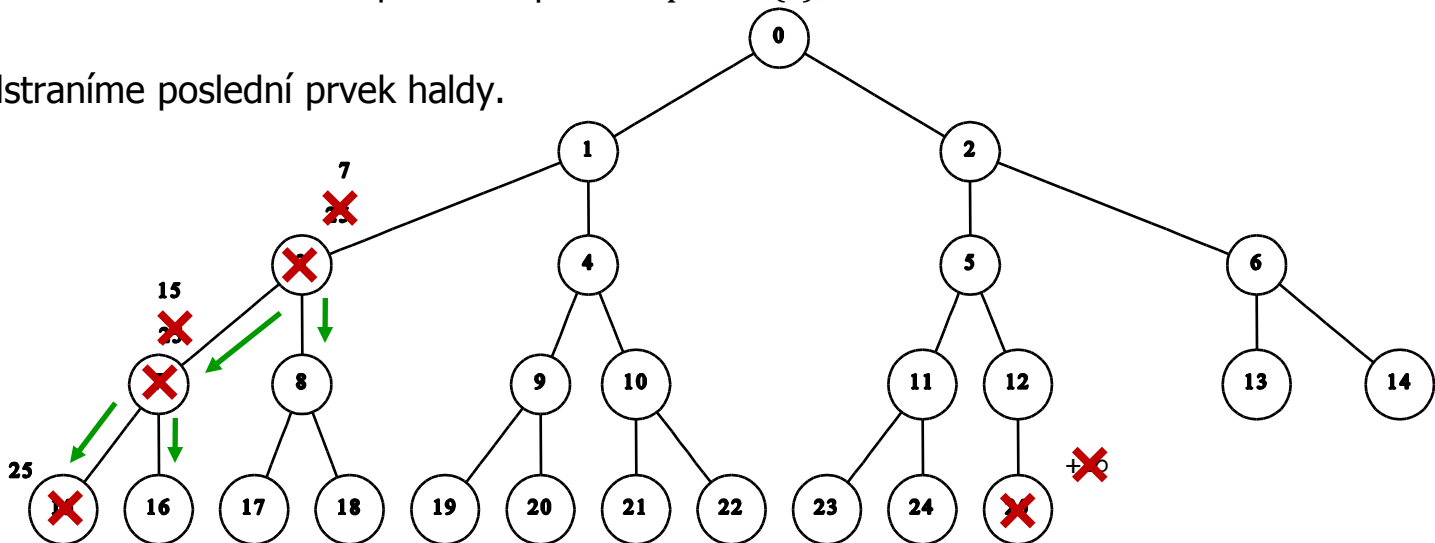
■ DecreaseKey (x, d)

- Zmenšíme hodnotu prvku x o d a pak aplikujeme analogický postup jako u operace Insert.

Binární halda - Delete

■ Delete (&x)

1. $x = +\infty$; $\&y =$ umístění posledního prvku haldy;
2. **do** {
3. Prohodíme umístění prvku x s prvkem y ;
4. $\&x = \&y$;
5. **for each** $z \in \text{descendants}(x)$ **do**
6. **if** ($y > z$) **then** $\&y = \&z$;
7. **} while** ($x \neq y$);
8. **while** ($\text{parent}(x) > x$) {
9. Prohodíme umístění prvku x s prvkem $\text{parent}(x)$;
10. **}**
11. Odstraníme poslední prvek haldy.



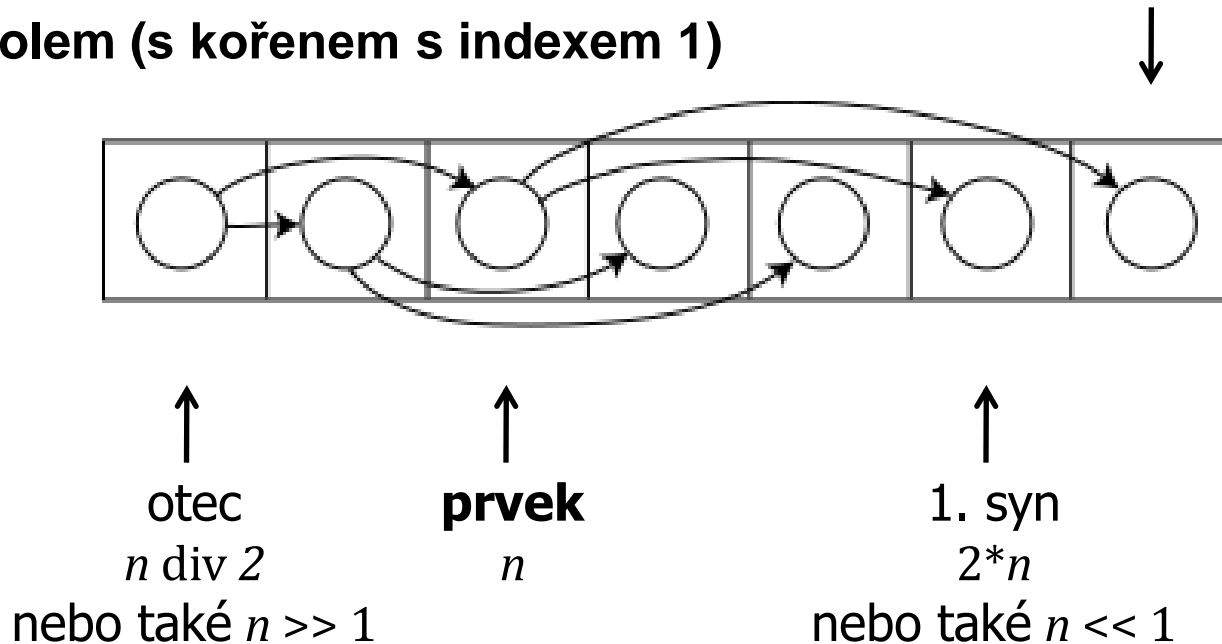
Binární halda - reprezentace

■ reprezentace v paměti

- stromovou dynamickou datovou strukturou s ukazateli v obou směrech

2. syn
 $(2*n)+1$
nebo také $(n \ll 1) + 1$

- polem (s kořenem s indexem 1)



Binární halda - složitost

- **Insert**
 - $O(\log(n))$
- **Delete**
 - $O(\log(n))$
- **AccessMin**
 - $O(1)$
- **DeleteMin**
 - $O(\log(n))$
- **DecreaseKey**
 - $O(\log(n))$
- **Merge**
 - Lze provést v $O(n)$ novým vybudováním haldy.

d-regulární halda

- Pro $d=2$ je d-regulární halda právě binární halda.
- Parametr d udává stupeň štěpení stromu haldy.
- Operace nad d-regulární haldou jsou analogické jako v případě binární haldy.
- Asymptotická složitost je stejná jako u binární haldy.
- Přesná složitost se liší základem logaritmu (základ je d) a pro operaci Delete navíc ještě s násobkem d .
- Pro rychlou implementaci je výhodné za d volit mocniny 2. Pak lze použít reprezentaci polem s bitovými posuny.


Binomiální halda

■ binomiální halda

- Binomiální halda reprezentující množinu S , kde $|S| = n$ je množina tzv. *binomiálních stromů* řádů $i=1, \dots, \lfloor \log(n) \rfloor$. Každý řád je přitom zastoupen nejvýše jedním stromem.

■ binomiální stromy se konstruují následujícím způsobem:

- strom řádu 0 je samostatný vrchol
- strom řádu i (pro $i \geq 1$) se skládá z kořene a i synů, což jsou binomiální stromy řádu 0 až $i-1$.



Binomiální halda – binomiální stromy

- Pro binomiální strom řádu i platí
 - každý vrchol je menší nebo roven všem svým potomkům
 - má 2^i vrcholů
 - jeho hloubka je i
 - jeho kořen má i synů
 - pro $\forall j \leq i$ existuje syn kořene, který je binomiálním stromem řádu j
- Binomiální stromy lze definovat i jiným způsobem:
 - Strom řádu i vznikne ze dvou stromů řádu $i - 1$ tak, že ke stromu, jehož kořen reprezentuje menší prvek se jako další syn připojí strom s větším kořenem. Tak je zachována lokální podmínka na uspořádání haldy.

Binomiální halda – reprezentace

- Binomiální halda se standardně implementuje pomocí pole ukazatelů, v němž i -tý ukazatel je buď null nebo ukazuje na kořen stromu řádu i .
- Kromě ukazatelů na jednotlivé stromy existuje v haldě ještě zvláštní ukazatel na strom, v jehož kořeni je uložen nejmenší prvek z celé haldy. Tento tzv. *MIN ukazatel* se aktualizuje při každé operaci.

Binomiální halda – Insert, AccessMin, Merge

■ **Insert** (x)

- Vytvoří se strom řádu 0, tedy jediný vrchol reprezentující přidávaný prvek x . Tento strom je vlastně velmi jednoduchá binomiální halda.
- Poté se zavolá **Merge** na obě haldy.


■ **AccessMin**

- Vrátí prvek reprezentovaný kořenem stromu, na nějž ukazuje *MIN ukazatel*.

■ **Merge** (H_1, H_2)

- Tato operace probíhá analogicky ke sčítání binárních čísel. Obě haldy se prochází podle řádu stromů od nejmenšího. Pokud je příslušný řád zastoupen pouze v jedné haldě, překopíruje se do výsledné haldy. Pokud je zastoupen v obou, spojí se do jednoho stromu vyššího řádu a ten se umístí do „přenosového stromu“ (analogie přenosového bitu). Ten se případně spojuje s dalšími stromy z původních hald. Do výsledné haldy se přidá *MIN ukazatel*, jehož hodnota odpovídá minimu z obou vstupních hald.

Binomiální halda - Merge



Binomiální halda - DeleteMin

1. **procedure** DeleteMin(binomial_heap H)
2. tree_with_minimum = H.MIN;
3. **for each** tree \in tree_with_minimum.subTrees **do** {
4. tmp.addTree(tree);
5. }
6. H.removeTree(tree_with_minimum)[†];
7. H = **Merge**(H, tmp);

[†] Technicky tato operace smaže pouze kořen stromu. Všichni potomci kořene se dále používají v tmp haldě, která se následně sloučí operací Merge.

Binomiální halda – DecreaseKey, Delete

■ DecreaseKey

- Funguje analogicky jako v případě binární haldy.

■ Delete (x)

- Nejprve pomocí operace DecreaseKey snížíme hodnotu prvku x na $-\infty$.
- Potom odstraníme tento prvek pomocí operace DeleteMin.

Binomiální halda – složitost

- **Merge**

- $O(\log(n))$

- **Insert**

- $O(\log(n))$

- Amortizovaná složitost je konstantní. Operace je analogická k inkrementaci binárního čítače.

- **AccessMin**

- $O(1)$

- **DeleteMin**

- $O(\log(n))$

- **DecreaseKey**

- $O(\log(n))$

- **Delete**

- $O(\log(n))$

Fibonacciho halda

- **Fibonacciho halda** je druh haldy, který Principiálně vychází z binomiální haldy.
- Hlavní výhodou Fibonacciho haldy je nízká asymptotická složitost prováděných algoritmů.
- Operace Insert, AccessMin a Merge probíhají v $O(1)$.
- Operace DecreaseKey probíhá v amortizovaném konstantním čase.
- Operace Delete a DeleteMin pracují s amortizovanou časovou složitostí $O(\log(n))$.
- Užití Fibonacciho haldy není vhodné pro real-time systémy, protože některé operace mohou mít v nejhorším případě lineární složitost.

Fibonacciho halda

- Fibonacciho haldu tvoří skupina stromů vyhovující lokální podmínce na uspořádání haldy, která vyžaduje, aby pro každý uzel stromu platilo, že prvek, který reprezentuje, je menší než prvek reprezentovaný jeho potomky. Z této podmínky vyplývá, že minimálním prvkem je vždy kořen jednoho ze stromů.
- Vnitřní struktura Fibonacciho haldy je v porovnání s binomiální haldou daleko více flexibilní. Jednotlivé stromy nemají pevně daný tvar a v extrémním případě může každý prvek haldy tvořit izolovaný strom nebo naopak všechny prvky mohou být součástí jediného stromu hloubky N . Tato flexibilní struktura umožňuje velmi jednoduchou implementaci operací s haldou.
- Operace, které nejsou potřebné, odkládáme a vykonáváme je až v okamžiku, kdy je to nevyhnutelné, například spojení nebo vložení nového prvku se jednoduše provede spojením kořenových seznamů (s konstantní náročností) a jednotlivé stromy spojíme až při operaci snížení hodnoty klíče.