

Datové struktury I

11. přednáška: Geometrické datové struktury

Jirka Fink

<https://ktiml.mff.cuni.cz/~fink/>

Katedra teoretické informatiky a matematické logiky
Matematicko-fyzikální fakulta
Univerzita Karlova v Praze

Zimní semestr 2024/25

Licence: Creative Commons BY-NC-SA 4.0

Popis problému

- Máme dánu množinu S obsahující n bodů z \mathbb{R}^d
- Intervalem rozumíme d -dimenzionální obdélník, např.
 $\langle a_1, b_1 \rangle \times \cdots \times \langle a_d, b_d \rangle$
- Operace QUERY: Najít všechny body v daném intervalu
- Operace COUNT: Určit počet bodů v daném intervalu

Aplikace

- Počítačová grafika, výpočetní geometrie
- Databázové dotazy, např. určit zaměstnance ve věku 20-35 a platem 20-30 tisíc

Staticky

Body uložíme do pole

BUILD: $\mathcal{O}(n \log n)$

COUNT: $\mathcal{O}(\log n)$

QUERY: $\mathcal{O}(k + \log n)$

k je počet vyjmenovaných bodů

Dynamicky

Body uložíme do vyhledávacího stromu

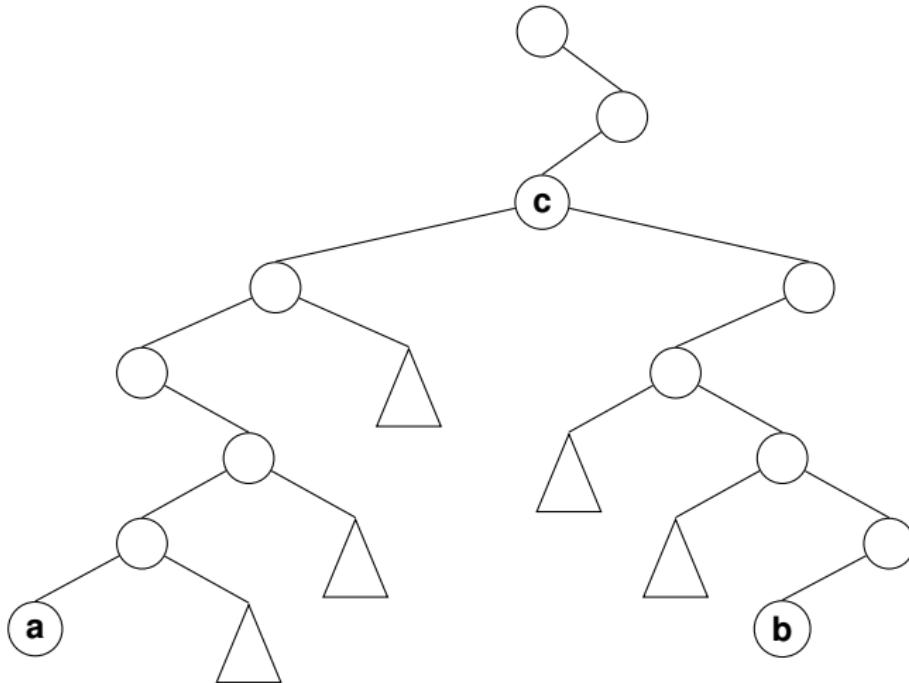
BUILD: $\mathcal{O}(n \log n)$

INSERT: $\mathcal{O}(\log n)$

DELETE: $\mathcal{O}(\log n)$

COUNT: $\mathcal{O}(\log n)$

QUERY: $\mathcal{O}(k + \log n)$

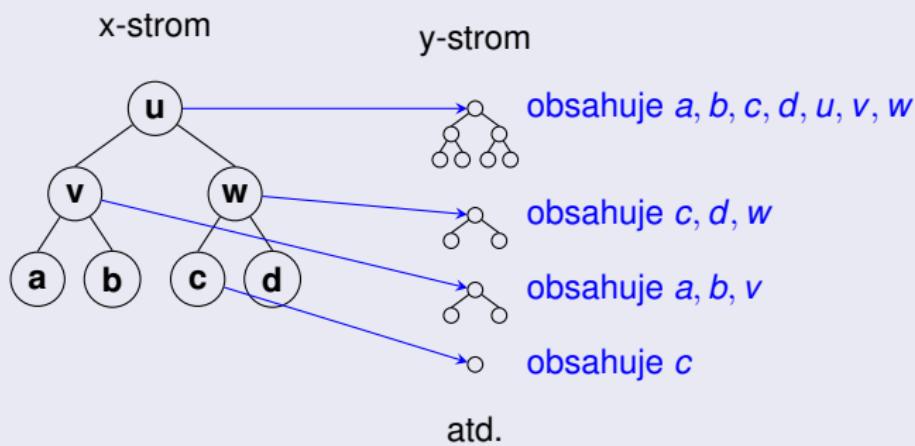


Vrchol *a* je nejmenší prvek v intervalu, *b* je největší prvek v intervalu a *c* je poslední společný vrchol na cestách z kořene do vrcholů *a* a *b*.

Konstrukce

- Vybudujeme binární vyhledávací strom podle x-ové souřadnice bodů (x-strom)
- Nechť S_u je množina bodů v podstromu vrcholu u
- Každý vrchol u vybudujeme jeden binární vyhledávací strom podle y-ové souřadnice obsahující S_u
- V každém vrcholu je uložen jeden bod ① ②

Příklad



- 1 Podobně jako ve vyhledávacích stromech můžeme uvažovat dvě varianty: prvky mohou být uloženy ve všech vrcholech nebo jen v listech. V intervalových stromech předpokládáme, že v každém vrcholu je uložen jeden bod.
- 2 Pozor! Každý bod je uložen v několika vrcholech, takže paměťová složitost není lineární.

Kde všude je uložený jeden vrchol?

Každý bod p je uložen v právě jednom vrcholu v x-stromu a dále je bod p uložen v každém y-stromu přiřazenému vrcholu na cestě z x-kořene do v .

Předpoklad

Předpokládejme, že binární vyhledávací strom použitý v intervalových stromech je vyvážený, a tedy jeho výška je $\Theta(\log n)$.

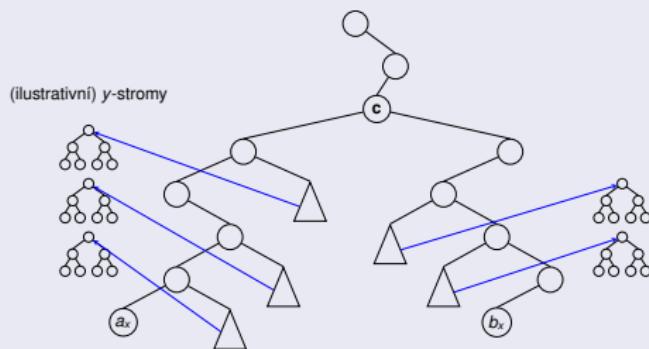
Paměťová složitost

Každý bod je uložen v $\mathcal{O}(\log n)$ y-stromech a celková paměťová složitost je $\mathcal{O}(n \log n)$.

Idea algoritmu vyhledávání

- ① Najít klíče a_x a b_x v x-stromu ①
- ② Určit vrcholy u x-stromu takové, že S_u obsahuje pouze body s x-ovou souřadnicí v intervalu $\langle a_x, b_x \rangle$ ②
- ③ V těchto vrcholech položme y-ový dotaz $\langle a_y, b_y \rangle$

Příklad



Složitost dotazu COUNT

$\mathcal{O}(\log^2 n)$ protože y-ový dotaz je volán v $\mathcal{O}(\log n)$ y-stromech ③ ④

- ① Přesněji: najít ze všech prvků v x-stromu dva body mající nejmenší a největší x-ovou souřadnic ležící intervalu $\langle a_x, b_x \rangle$.
- ② Je zřejmé, že když vrchol tuto podmínu splňuje, tak ji splňují i synové vrcholu. Proto nás zajímají nejvýše umístěné vrcholy s touto vlastností, tj. vrcholy splňující tuto podmínky, ale jejichž otec tuto podmínku nesplňuje.
- ③ Všimněme si, že prohledávané y-stromy obsahují po dvou disjunktní množiny prvků.
- ④ V dotazu QUERY je nutné vyjmenovat všechny body, a proto složitost je $\mathcal{O}(k + \log^2 n)$, kde k je počet bodů v obdélníku.

Popis

- i -strom je binární vyhledávací strom podle i -té souřadnice pro $i = 1, \dots, d$
- Pro $i < d$ má každý vrchol u i -stromu ukazatel na $(i+1)$ -strom obsahující S_u
- Intervalovým stromem rozumíme všechny výše popsané stromy

Reprezentace

Struktura vrcholu intervalového stromu obsahuje

key nadrovina rozdělující prostor mezi syny ①

left, right ukazatel na levého a pravého syna

tree ukazatel na kořen $(i+1)$ -stromu

size počet bodů v podstromu (pokud potřebujeme dotaz COUNT)

Poznámka

Nechť u je vrchol i -stromu a T jsou všechny vrcholy dosažitelné opakovaným přístupem k ukazatelům **left**, **right** a **tree** z vrcholu u . Pak T tvoří intervalový strom na vrcholech S_u a souřadnicích i, \dots, d .

- 1 Operace QUERY musí umět body ležící v obdélníku i vypsat, a proto potřebuje mít ve všech vrcholech uloženy všechny souřadnice bodu. Operaci QUERY stačí klíč, což v i-stromu je i-tá souřadnice bodu.

V kolika vrcholech je uložený bod b ?

- Existuje $\mathcal{O}(\log n)$ vrcholů u 1-stromu takových, že S_u obsahuje b
- Tedy počet 2-stromů obsahující b je $\mathcal{O}(\log n)$
- Uvažujme i -strom T obsahující bod b
- Pak v T je $\mathcal{O}(\log n)$ vrcholů w takových, že $b \in S_w$ ①
- Počet $(i + 1)$ -stromů přiřazených nějakému vrcholu T obsahujících b je $\mathcal{O}(\log n)$
- Každou dimenzí se počet stromů obsahujících b zvyšuje o multiplikativní faktor $\mathcal{O}(\log n)$
- Celkový počet stromů/listů obsahujících b je $\mathcal{O}(\log^{d-1} n)$
- Celková paměťová složitost je $\mathcal{O}(n \log^{d-1} n)$

Kolik má intervalový strom i -stromů?

- Počet vrcholů ve všech $(i - 1)$ -stromech je $\mathcal{O}(n \log^{i-2} n)$
- Každému vrcholu $(i - 1)$ -stromu je přiřazen jeden i -strom
- Počet i -stromů je $\mathcal{O}(n \log^{i-2} n)$ ②

- 1 Strom T nemusí obsahovat všechny prvky, a proto jeho výška nemusí být $\Omega(\log n)$. Dokonce většina stromů obsahuje celkem malý počet bodů.
- 2 Platí pro $i \geq 2$. Pro $i = 1$ máme jeden 1-strom.

Algoritmus (Body M jsou v poli setříděné podle poslední souřadnice)

```

1 Procedure BUILD (množina bodů M, dimenze stromu d, aktuální souřadnice i)
2   if  $|M| = 1$  then
3     return nový list obsahující jediný vrchol  $M$  ①
4   if  $i = d$  then
5     return kořen stromu vytvořený ze setříděného pole
6    $v \leftarrow$  nový vrchol
7    $v.\text{tree} \leftarrow \text{BUILD}(M, d, i + 1)$ 
8    $v.\text{key} \leftarrow$  medián  $i$ -tých souřadnic bodů  $M$ 
9    $M_l, M_r \leftarrow$  rozděl  $M$  na body mající  $i$ -tou souřadnici menší a větší než  $v.\text{key}$ 
10   $v.\text{left} \leftarrow \text{BUILD}(M_l, d, i)$ 
11   $v.\text{right} \leftarrow \text{BUILD}(M_r, d, i)$ 
12  return  $v$ 
```

Složitost jednoho volání funkce **BUILD** (bez rekurze)

- Pro $i = d$ je složitost $\mathcal{O}(1)$ ②
- Pro $i < d$ je složitost $\mathcal{O}(|S|)$ ③

- 1 Zde je otázka, zda list musí mít přiřazený (triviální) strom další dimenze. Je to implementační detail, intervalový strom může fungovat v obou verzích a asymptotické složitosti se nemění.
- 2 Předpokládáme, že množina stromů M předávaná v rekurzi se udržuje setříděná. Čas jednoho volání funkce `BUILD` je $\mathcal{O}(1)$ pro $i = d$, protože medián leží uprostřed pole M a rozdelení M na M_l a M_r je jen otázka předání správných ukazatelů.
- 3 Pro $i < d$ není pole M setříděné podle aktuální souřadnice i , a proto nalezení mediánu a rozdelení pole trvá $\mathcal{O}(n_T)$. Časovou složitost vytvoření i -stromu T lze popsát rekurentní formulí $f(n) = 2f(n/2) + \mathcal{O}(n)$, jejíž řešení je $\mathcal{O}(n_T \log n_T)$.

Vytvoření d -stromů

- d -stromy vytváříme v konstantním čas na vrchol
- Počet vrcholů ve všech d -stromech je $\mathcal{O}(n \log^{d-1} n)$
- Časová složitost vytvoření všech d -stromů je $\mathcal{O}(n \log^{d-1} n)$

Vytvoření všech i -stromů pro $i = 1, \dots, d-1$ (nepočítaje $(i+1)$ -stromy)

- Počet vrcholů ve všech i -stromech je $\mathcal{O}(n \log^{i-1} n)$
- Nechť n_T je počet vrcholů v i -stromu T
- Vybudování samotného stromu T trvá $\mathcal{O}(n_T \log n_T)$
- Vybudování všech i -stromů trvá

$$\sum_{i\text{-strom } T} n_T \log n_T \leq \log n \sum_{i\text{-strom } T} n_T = \log n \cdot n \log^{i-1} n = n \log^i n$$

Časová složitost operace BUILD

$$\mathcal{O}(n \log^{d-1} n)$$

```
1 Procedure Query (vrchol  $v$ , aktuální souřadnice  $i$ )
2   if  $v = NIL$  then
3     return
4   if  $v.key \leq a_i$  then
5     Query ( $v.right, i$ )
6   else if  $v.key \geq b_i$  then
7     Query ( $v.left, i$ )
8   else
9     if  $v.point$  leží v obdélníku then
10      Vypiš  $v.point$ 
11      Query_left ( $v.left, i$ )
12      Query_right ( $v.right, i$ )
```

```
1 Procedure Query_left (vrchol v, aktuální souřadnice i)
2   if v = NIL then
3     return
4   if v.key < ai then
5     Query_left (v.right, i)
6   else
7     if v.point leží v obdélníku then
8       Vypiš v.point
9     Query_left (v.left, i)
10    if i < d then
11      Query (v.right.tree, i + 1)
12    else
13      Vypiš všechny body v podstromu vrcholu v.right
```

Složitost operace COUNT

- V každém stromě přistoupíme k nejvýše dvěma vrcholům z každé vrstvy
- Z každého navštíveného i -stromu pokračujeme do $\mathcal{O}(\log n)$ $(i+1)$ -stromů
- Počet navštívených i -stromů je $\mathcal{O}(\log^{i-1} n)$
- Celková složitost je $\mathcal{O}(\log^d n)$

Složitost operace QUERY

- Vypsání všech bodů v podstromu trvá $\mathcal{O}(k)$, kde k je počet nalezených bodů
- Celková složitost je $\mathcal{O}(k + \log^d n)$

BB[α]-strom

- Binární vyhledávací strom
- Počet listů v podstromu vrcholu u označme s_u
- Podstromy obou synů každého vrcholu u mají nejvýše αs_u listů

Operace Insert (Delete je analogický)

- Najít list pro nový prvek a uložit do něho nový prvek (složitost: $\mathcal{O}(\log n)$)
- Jestliže některý vrchol u porušuje vyvažovací podmínku, tak celý jeho podstrom znova vytvoříme operací BUILD (složitost $\mathcal{O}(s_u)$)

Amortizovaná časová složitost operací Insert a Delete

- Jestliže podstrom vrcholu u po provedení operace BUILD má s_u listů, pak další porušení vyvažovací podmínky pro vrchol u nastane nejdříve po $\Omega(s_u)$ přidání/smažání prvků v podstromu vrcholu u
- Amortizovaný čas vyvažování jednoho vrcholu je $\mathcal{O}(1)$
- Při jedné operaci Insert/Delete se prvek přidá/smaže v $\mathcal{O}(\log n)$ podstromech
- Amortizovaný čas vyvažování při jedné operaci Insert nebo Delete je $\mathcal{O}(\log n)$

Použití BB[α]-stromů v intervalových stromech

- Binární vyhledávací stromy implementujeme pomocí BB[α]-stromů
- Vyžaduje-li BB[α]-strom vyvážení, pak přebudujeme všechny přiřazené stromy

Složitost operace Insert a Delete

- Navštívených i -stromů je $\mathcal{O}(\log^{i-1} n)$ a v každém navštívíme $\mathcal{O}(\log n)$ vrcholů
- Složitost bez přebudování je $\mathcal{O}(\log^d n)$; analyzujme přebudování
- Uvažujme libovolný vrchol u , který leží v i -stromu
- Přebudování vrcholu u trvá $\mathcal{O}(s_u \log^{d-i} s_u)$
- Přebudování vrcholu u může nastat po $\Omega(s_u)$ po přidání/smazání prvků v podstromu u
- Amortizovaná cena přidání/smazání do vrcholu u je $\mathcal{O}(\log^{d-i} s_u) \leq \mathcal{O}(\log^{d-i} n)$
- Amortizovaný čas operace Insert a Delete je

$$\sum_{i=1}^d \mathcal{O}(\log^{i-1} n) \mathcal{O}(\log n) \mathcal{O}(\log^{d-i} n) = \mathcal{O}(\log^d n)$$

Popsaný postup

QUERY: $\mathcal{O}(k + \log^d n)$

Paměť: $\mathcal{O}(n \log^{d-1} n)$

S použitím Fractional cascading

QUERY: $\mathcal{O}(k + \log^{d-1} n)$

Paměť: $\mathcal{O}(n \log^{d-1} n)$

Chazelle, 1990

QUERY: $\mathcal{O}(k + \log^{d-1} n)$

Paměť: $\mathcal{O}\left(n \left(\frac{\log n}{\log \log n}\right)^{d-1}\right)$

Chazelle, Guibas, 1986 (pro $d \geq 3$)

QUERY: $\mathcal{O}(k + \log^{d-2} n)$

Paměť: $\mathcal{O}(n \log^d n)$

Popis

- Body uložíme do binárního stromu
- Do kořene uložíme medián podle první souřadnice
- Do levého (pravého) podstromu uložíme body mající první souřadnice menší (větší) než medián
- Vrcholy v první vrstvě pod kořenem se body rozdělují podle druhé souřadnice
- V dalších vrstvách dělíme (cyklicky) podle dalších souřadnice
- Výška stromu je $\log_2 n + \Theta(1)$
- Operace BUILD v čase $\mathcal{O}(n \log n)$
- Body je též možné ukládat jen do listů a vrcholy pak obsahují jen rozdělující nadroviny

Algoritmus

```
1 Procedure QUERY (vrchol stromu v, interval R)
2   if v je list then
3     | Vypiš v, pokud leží v R
4   else if rozdělující nadrovina vrcholu v protíná R then
5     | QUERY (levý syn v, R)
6     | QUERY (pravý syn v, R)
7   else if R je „vlevo“ od rozdělující nadroviny vrcholu v then
8     | QUERY (levý syn v, R)
9   else
10    | QUERY (pravý syn v, R)
```

Příklad nejhoršího případu pro \mathbb{R}^2

- Máme množinu bodů $S = \{(x, y); x, y \in [m]\}$, kde $n = m^2$
- Chceme najít množinu všech bodů v intervalu $\langle 1, 2; 1, 8 \rangle \times \mathbb{R}$
- V každé vrstvě rozdělující podle y -ové souřadnice musíme prozkoumat oba podstromy
- Výška stromu je $\log_2 n + \Theta(1)$ a v polovině vrstev prozkoumáváme oba podstromy
- Celkem navštívíme $2^{\frac{1}{2} \log_2 n + \Theta(1)} = \Theta(\sqrt{n})$ listů

Příklad nejhoršího případu pro \mathbb{R}^d

- Mějme množinu bodů $S = [m]^d$, kde $n = m^d$
- Chceme najít množinu všech bodů v intervalu $\langle 1, 2; 1, 8 \rangle \times \mathbb{R}^{d-1}$
- V každé vrstvě nerozdělující podle první souřadnice musíme prozkoumat oba podstromy
- V $\frac{d-1}{d} \log_2 n + \Theta(1)$ vrstvách prozkoumáváme oba podstromy
- Celkem navštívíme $2^{\frac{d-1}{d} \log_2 n + \Theta(1)} = \Theta(n^{1 - \frac{1}{d}})$ listů

$[m]^d$ značí tzv. mřížové body, tj. body \mathbb{R}^d , jejichž každá souřadnice je celé číslo od 0 od $m - 1$.

kd-stromy jsou mají nejlepší možnou časovou složitost, pokud datová struktura smí používat pouze $\mathcal{O}(n)$ paměti. Intervalové stromy umí vyhodnotit intervalový dotaz v čase $\mathcal{O}(\log^d n)$, ale potřebují $\mathcal{O}(n \log^{d-1} n)$ paměti.

Paralelní programování bez zámků.