

Třídění a vyhledávání

Přednáška 7

Motivace

- velké soubory dat
 - častý požadavek je získat určitá data
 - jak je obtížné vyhledat určitá data
 - v neseřazeném souboru dat?
 - v seřazeném souboru dat?
 - dokážete stanovit obtížnost přístupu?
- pro vyhledávání je lepší mít data seřazená
- různé metody řazení
- rozdílný přístup pro
 - řazení neseřazeného pole
 - a pro přidávání dalších prvků do seřazených dat

Motivace

- kolik operací je potřeba pro seřazení čtyř prvků?
 - počítáme nejhorší variantu
 - 6 porovnání ($N \cdot (N-1) / 2$)
 - 0-6 přesunů (výměn) hodnot
- průměrný čas přístupu je cca $N/2$.
- u setříděného pole je to půlení intervalu
 - tj maximálně $\log_2 N$
 - pro 4 prvky = max 2 pokusy, ale pro polovinu prvků to bude rychlejší
- N mohou být ve skutečnosti tisíce, miliony položek

Motivace

- pro vložení do seřazeného pole
 - bude záležet na směru řazení
 - v našem případě až 4 porovnání
 - k tomu až N výměn
- čím méně porovnání (prvek je více vlevo)
- tím více přesunů
- počet operací je „konstantní“

Složitost algoritmů

- slouží například k
 - hodnocení
 - porovnání vhodnosti algoritmů
- rozlišujeme
 - časovou
 - paměťovou
- někdy lze určit přesně
 - přístup k x-tému prvku v poli nebo lineárním seznamu
- někdy pouze statisticky
 - střední doba
 - řazení dat může trvat pro různé datové sady různě
 - Často se však uvádí nejhorší možný výsledek složitosti

Složitost algoritmů

- kolik kroků je potřeba k získání x-tého prvku v poli?
 - 1 kroků
- kolik kroků je potřeba pro získání x-tého prvku v lineárním seznamu?
 - N kroků
- dosažení cíle pro půlení intervalu
 - $\log_2 N$
 - $\log_2 8 = 3$

Časová složitost

- Big O notation
 - O – Order, řád funkce
- může se udávat v počtu kroků
 - záleží na počtu dat (základních + pracovních)
- může se lišit pro různé operace
 - seřazení
 - vyhledání
 - zjištění hodnoty
- pro složitý vzorec
 - bere se nejvýrazněji rostoucí část součtu
 - například:
 - pro $10N^2+3N+50$
 - můžeme uvést $O(N^2)$

Časová složitost

- $O(1)$
 - konstantní složitost
 - vyhledání prvku v poli pomocí indexu
- $O(N)$
 - lineární složitost
 - vyhledání prvku v lineárním seznamu
 - suma N čísel v poli
- $O(N^2)$
 - kvadratická
 - vyhledání maxima ve čtvercové matici
- $O(\log_2 N)$
 - logaritmická
 - vyhledání pozice v seřazeném poli půlením intervalu

Vyhledávání

- náročnost
 - podle polohy hledané položky
- uhodněte číslo na které myslím
- normální vyhledávání
 - až N
- binární vyhledávání
 - využívá půlení intervalu
 - složitost $\log_2 N$

Vyhledávání

- realizace
 - polem
 - lineárním seznamem
 - binárním stromem
- výhody realizací
 - pro vyhledávání
 - pro vkládání

Vyhledávání v poli


- hledání extrému
 - maximum / minimum
 - v setříděném poli na kraji
 - v neseříděném musíme projít celé pole
- více stejných hodnot v poli
 - která z nich je ta požadovaná?
- nejhorší případ
 - hledáme hodnotu, která v poli není
- co když není přesná hodnota?
 - hledat menší
 - hledat větší
 - zahlásit chybu?

Vyhledávání sekvenční

- hledání pozice hodnoty v neseřazeném poli dat
 - postupně projít všechny prvky
- vhodný pro malé vzorky dat
 - maximální $O(n)$
 - průměrná $O(n/2)$
- algoritmus má dvě porovnání
 - konce pole
 - nalezení hodnoty
 - zjednodušení?
 - Na konec pole se dá hledaná hodnota
 - záložka (sequential search sentinel)

Vyhledávání binární

- vyžaduje setříděné pole
- nejhorší $O(\log_2 n)$
- vyhledávání pomocí metody půlení intervalu



Vyhledávání interpolační

- vyžaduje setříděné pole
- podobné binárnímu
- pomáháme si znalostí
 - odhadem pozice
 - na základě znalosti rozložení hodnot
- $O(\log(\log n))$
- hledání jmen
 - určíme si četnost zastoupení jednotlivých písmen
 - z rozložení určíme počátek, krok
 - pomocná tabulka – pozice prvních jmen dle písmena
- hledání výšek osob

Řazení

- data
 - jednoduchá (int, float...)
 - složitá (záznamy v databázi, vektor, komplexní číslo)
- směr řazení
 - sestupně
 - vzestupně
- stanovení porovnávací funkce
 - vrací
 - -1 – první je před druhým
 - 0 – parametry stejné/nezáleží na pořadí
 - $+1$ – první je za druhým

Řazení

- dvojce hodnota – klíč
 - řazení pomocí klíčů
 - stabilní řazení
 - zachovává pořadí položek se stejným klíčem
 - hodnota 0 porovnávací fce
 - nechat prvky jak jsou
 - prostor pro řazení
 - stejný
 - pomocný
- paměťová náročnost

Řazení

- testy pro ověření kvality a času řazení
 - správně seřazená data
 - opačně seřazená data
 - téměř seřazená data správně
 - téměř seřazená data opačně
 - náhodná data
- přirozený algoritmus
 - vyšší rychlost pro částečně seřazená data

Bubble sort

- řazení probubláním
- princip
 - porovnáváme sousedy a jejich případná výměna
- složitost $O(n^2)$
- u téměř seřazeného pole se blížíme k $O(n)$
- velké hodnoty zleva probublají rychle
 - maximum se na konec dostane v jednom cyklu
- malé hodnoty se doleva posunují pomalu
 - v jednom cyklu posun maximálně o jednu pozici

Bubble sort

5 1 12 -5 16

Nesetříděná řada

5 1 12 -5 16

$5 > 1$ Výměna prvků

1 5 12 -5 16

$5 < 12$ Pořadí zůstává

1 5 12 -5 16

$12 > -5$ Výměna prvků

1 5 -5 12 16

$12 < 16$ Pořadí zůstává

1 5 -5 12 16

$1 < 5$ Pořadí zůstává

1 5 -5 12 16

$5 > -5$ Výměna prvků

1 -5 5 12 16

$5 < 12$ Pořadí zůstává

1 -5 5 12 16

$1 > -5$ Výměna prvků

-5 1 5 12 16

$1 < 5$ Pořadí zůstává

-5 1 5 12 16

$-5 < 1$ Pořadí zůstává

-5 1 5 12 16

Setříděná řada

4 průchody

Shaker sort

- vychází z bubble sortu
- princip
 - netřídí jen jedním směrem
 - směr průchodu se po každém cyklu mění
 - obousměrný bubble sort
- složitost $O(n^2)$
- z praktického hlediska neefektivní
 - odstraňuje některé nedostatky bubble sortu
 - nedojde k výraznému zlepšení

Comb sort

- vychází z bubble sortu
- princip
 - zavádí se snižující přírůstek
 - volí se různá vzdálenost mezi porovnávanými prvky
 - začne se velkou vzdáleností (půl intervalu)
 - postupně se vzdálenost zkracuje (faktor 1.3) až k jedné
 - v poslední fázi degraduje na klasický bubble sort
- složitost: $O(n)$ až $O(n^2)$

Select sort

- řazení výběrem
- pole rozdělíme
 - seřazená část
 - neseřazená část
- princip
 - vybíráme extrém z neseřazené části
 - vyměníme s prvním prvkem v neseřazené části
 - zmenšíme neseřazenou část
- složitost $O(n^2)$
- konstantní paměťová složitost

Select sort

Nesetříděná část

Prvky se vybírají postupně

15	4	28	9	51	21	14
4	15	28	9	51	21	14
4	9	28	15	51	21	14
4	9	14	15	51	21	28
4	9	14	15	51	21	28
4	9	14	15	21	51	28
4	9	14	15	21	28	51
4	9	14	15	21	28	51

Setříděná část

Prvky vkládané na místo
podle velikosti

Double select sort

- vylepšení algoritmu select sort
- současně hledáme oba extrémy
- setříděné části vznikají na obou stranách

Insert sort

- řazení vkládáním
- pole rozdělíme
 - seřazená část
 - neseřazená část
- princip
 - bereme prvky z neseřazené části
 - vkládáme je na místo v seřazené části
- složitost $O(n^2)$
- u téměř seřazeného pole se blížíme k $O(n)$

Insert sort

Nesetříděná část

Prvky se vybírají postupně

15	4	28	9	51	21	14
4	15	28	9	51	21	14
4	15	28	9	51	21	14
4	9	15	28	51	21	14
4	9	15	28	51	21	14
4	9	15	21	28	51	14
4	9	14	15	21	28	51


Setříděná část

Prvky vkládané na místo
podle velikosti

Quick sort

- Maximální složitost: $O(n^2)$
- Ve většině případů se ale blížíme k: $O(n \log n)$
- nejrychlejší mezi běžnými algoritmy
- pokud v datech hodně stejných hodnot, horší vlastnosti
- princip
 - vyber pivot
 - ideálně rozděl data na 2 stejné části
 - např. první prvek
 - poslední prvek
 - medián (nejlepší), nutná apriorní znalost
 - rozděl hodnoty na menší a větší jak pivot
 - menší přemístí vlevo od pivotu
 - větší přemístí vpravo od pivotu
 - obě části - rekurze

Quick sort




Merge sort

- složitost $O(n \cdot \log n)$
- potřebuje pomocnou paměť
- vhodný k paralelizaci
- princip
 - pokud jsou dva (nebo jeden) prvky
 - seřad' je
 - vrať se o úroveň výše
 - rozděl data na polovinu
 - na každou polovinu zavolej tuto funkci
 - spoj obě poloviny
 - poloviny jsou setříděné
 - jejich spojení je tedy rychlé

Merge sort

- spojování seznamu
 - máme 2 setříděné seznamy
 - máme výstupní seznam
- porovnáváme první hodnoty z obou seznamů
- menší vložíme na první pozici výstupního seznamu
- po vyprázdnění jednoho seznamu
 - kopírujeme zbytek dat z druhého

Merge sort




Shell sort

- složitost $O(n^{1.5})$
- Modifikace Insert sortu
 - menší nároky na kód
 - menší nároky na zásobník
- algoritmus:
 - zvolí se původní vzdálenost (např. 4)
 - začne se na prvním prvku
 - vezmou se prvky s danou vzdáleností
 - seřadí se pomocí insert sortu
 - posunujeme se o jeden prvek
 - předchozí krok se opakuje
 - provedeme řazení vybraných prvků jako v minulém bodě
 - snížíme vzdálenost
 - opakujeme celý postup
 - poslední iterace -> klasický insert sort

Shell sort

- krok
 - celočíselné násobky čísla 2.2
 - začínáme od největšího možného kroku
- výhoda
 - extrémy velmi rychle přemístěny na odpovídající stranu pole
 - poslední iterace algoritmu
 - přesouváme naprosté minimum prvků

Shell sort



Bucket sort

- podle klíče se rozřadí do sekcí
 - například podle hodnoty v nejvyšším řádu
- hodnoty v sekci se seřadí nějakým z řadících algoritmů
 - podle charakteru dat možno pro každou sekci jiný algoritmus
- hodnoty se nakopírují do výsledného pole
- musíme dále řadit?
 - každá sekce pokrývala určitý rozsah
 - rozsahy se nepřekrývaly
 - není nutné další zpracování
- vhodné pro paralelní zpracování
 - co bucket to vlákno
- Složitost $O(m * C(n/m))$
 - $C(n)$ – složitost vnitřního třídícího algoritmu

Counting sort

- $O(n+k)$
 - n - počet prvků
 - k - počet různých prvků
- vhodný pro velká pole s opakujícími se hodnotami
- dají se řadit jen diskrétní hodnoty
- algoritmus:
 - nejprve se zjistí četnost jednotlivých hodnot v poli
 - vytvoří se pole posledních indexů
 - tj. hodnota značí poslední index s danou hodnotou
 - pole četností a výskytů se použije pro vytvoření seřazeného pole

Counting sort

Vstupní pole	9	6	6	3	2	0	4	2	9	3
Výčet prvků	0	1	2	3	4	5	6	7	8	9
Pole četností	1	0	2	2	1	0	2	0	0	2
Pole výskytů	0	0	2	4	5	5	7	7	7	9
Seřazené pole	0	2	2	3	3	4	6	6	9	9

Radix sort

- řazení řetězců totožné délky
- přímo z definice stabilního řazení
 - postupně jdeme znak po znaku a řadíme
- algoritmus
 - vezmi první znaky všech řetězců
 - řetězce seřaď podle tohoto znaku
 - volá jiný stabilní algoritmus
 - často Counting sort
 - na řetězce se stejným prvním znakem zavolej tento algoritmus
- $O(m.C(n))$

Intro sort

- v knihovních funkcích C++
- kombinace více metod
 - kombinace quick a heap sort
 - insert sort – použitý na úseky kratší jak 16 prvků
- princip
 - ke třídění se používá quick sort
 - je-li při kontrole zjištěn nevhodný případ dat pro quicksort, vyřeší se daná množina pomocí heap sortu
 - je-li hloubka rekurze větší než doporučená mez (stanovená podle počtu dat), zbývající data seřadíme pomocí heapsort.

Heap sort

- jeden z nejlepších algoritmů
- využívá současně reprezentace dat pomocí
 - pole
 - stromu/binární haldy
- popis fungování v příští přednášce

Děkuji za pozornost

zdroj obrázků a další materiály: <https://algoritmy.net>