

Třídění

Implementace databázových systémů

Pavel Rychlý

pary@fi.muni.cz

26. září 2008

Obsah

- 1 Třídění v paměti**
- 2 Proveditelné algoritmy**
- 3 Třídění na disku**
- 4 Sublineární třídění**

Rychlosť operačnéj pamäti

Zpracovanie matic

```
int i, j;
for (i = 0; i < size; i++)
    for (j = 0; j < size; j++)
        matrix[size * j + i] = cnt++;
```

Třídění ►

3 / 27

Obsah

1 Třídění v paměti

2 Proveditelné algoritmy

3 Třídění na disku

4 Sublineárne třídění

Třídění v paměti

Pro třídění v paměti známe celou řadu algoritmů:

- QuickSort

(Pěkná analýza je na <http://video.google.com/videoplay?docid=-1031789501179533828>)

- BubbleSort, InsertSort
- HeapSort, MergeSort
- RadixSort, CountSort

Některé mají asymptotickou časovou složitost $O(n \log n)$, jiné $O(n^2)$ nebo $O(n)$.

CountSort, RadixSort

Potřebujeme seřadit 100 známk (A-F).

- spočítáme počty jednotlivých známek
- zapíšeme výsledek

RadixSort

- rekurzivní třídění po jednotlivých bajtech
- první průchod zjistí počty
- druhý průchod umístí data na správné místo

Vlastnosti třídicích algoritmů

- předpokládají data v operační paměti
- většinou třídí na místě (in-place)
- potřebují málo ($\log n$) další paměti

Třídění v praxi

Které algoritmy používáte ve svých programech?

- 1 QuickSort
- 2 BubleSort, InsertSort
- 3 HeapSort, MergeSort
- 4 jiný
- 5 ani nevím, co v té knihovně mají

”Pozorování“ o složitosti třídění:

- Teorie říká (a máme takové algoritmy), že je $O(n \log n)$.
- Ve většině praktických případů je $O(n)$.
- Mnoho programátorů používá algoritmy s $O(n^2)$.

Obsah

1 Třídění v paměti

2 Proveditelné algoritmy

3 Třídění na disku

4 Sublineární třídění

Jaká časová složitost je únosná?

Jaká (v jakých řádech) musí být časová složitost, abychom mohli algoritmus použít v praxi? Co nám říka teorie?

- třídy P a NP
- polynomiální
- n^{10} – určitě ne
- n^3 – někdy
- $n \log n$ – $\log n$ je pro většinu případů *malá konstanta*
- n – ideální

Jak to je v praxi?

- Dokonce některé exponenciální algoritmy mohou být použitelné, protože je vždy potřebujeme pouze pro malá n .
- Existují lineární algoritmy (dále ukážeme), které nejsou použitelné.
- Nezajímá nás asymptotická složitost ale **čas** (v sekundách).
- Budeme tedy počítat, kolik "přesně" (drahých) operací algoritmus potřebuje.

Které operace počítat

Nemůžeme (a ani nemusíme) počítat všechny operace.
Člověk má malou rozlišovací schopnost.

1:2 rozlišíme dvojnásobek od čtyřnásobku

1:5 někdy rozlišíme pětinásobek od desetinásobku

1:50 špatně rozlišíme padesátnásobek od stonásobku

1:1000 nerozlišíme tisícinásobek od dvoutisícinásobku

Stačí jen ty důležité/drahé/pomalé operace. Musíme vědět, jaký model použít, které operace jsou drahé.

Obsah

1 Třídění v paměti

2 Proveditelné algoritmy

3 Třídění na disku

4 Sublineární třídění

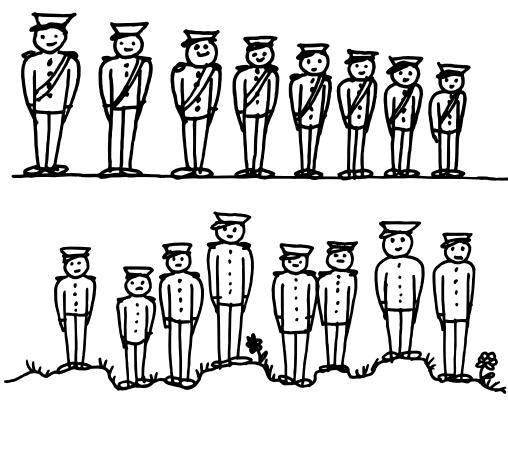
Třídění ► Třídění na disku

13 / 27

Model třídění na disku

Mooreův zákon nám říká: důležité jsou náhodné přístupy na disk.

Pro názornost použijeme model vojenské jednotky.



- Vojáci mají nastoupit seřazení podle velikosti (od nejmenšího).
- Velitel jedním pohledem zjistí chybu.
- Připravit se musí mimo rovnou plochu. Mají jen prkno pro 10 vojáků.

Třídění ► Třídění na disku

14 / 27

TPMMS

Two-Phase, Multiway Merge-Sort
Dvoufázové třídění vícecestným sléváním

1. fáze

třídění "bloků" v op. paměti

2. fáze

slévání všech proudů

Dvoufázové třídění - 1. fáze

Opakovaně provádíme:

- naplnění "celé" paměti daty
(sekvenční čtení)
- třídění v paměti
- zápis celého proudu na disk
sekvenční zápis
- 1 čtení + 1 zápis pro každý blok dat

Vojáci po 10 naběhnou na prkno a seřadí se.

Dvoufázové třídění - 2. fáze

- 1 blok paměti pro každý proud
- blok(y) paměti pro výstup
- načtení vstupních bufferů
- *na prvně stojí vždy první z každé skupiny*
- opakované
 - nalezení nejmenší hodnoty ze všech proudů
 - přesun do výstupního bloku
 - *odchází vždy nejmenší voják*
 - aktualizace čela použitého proudu
 - plný výst. buffer → zápis
 - prázdný vstupní buffer → čtení
 - *odešlého nahradí další ze stejné skupiny*
- 1 čtení + 1 zápis pro každý blok dat

Dvoufázové třídění - analýza

- B = počet bloků s tříděnými daty
- 1. fáze: $B * (1 \text{ čtení} + 1 \text{ zápis})$
- 2. fáze: $B * (1 \text{ čtení} + 1 \text{ zápis})$
- celkem: $\max 4 * B$ náhodných přístupů na disk
- Složitost TMPPS je $O(n)$, n je počet bloků na disku.
- Přesněji: maximálně $4B$, může být méně minimálně B .

Dvoufázové třídění-omezení

- parametry (v bajtech)
 - K = velikost bloku
 - M = velikost dostupné paměti
 - R = velikost záznamu
- max počet bufferů: M/K
- max počet proudů: $M/K - 1$
- počet záznamů v každém kroku 1. fáze: M/R
- max počet tříděných záznamů
 $(M/R)(M/K - 1) = M^2/RK$
- max velikost tříděných dat: M^2/K

Dvoufázové třídění-omezení

- max velikost tříděných dat: MM/K
- M (paměť) = 128MB = 2^{27}
- K (blok) = 128kB = 2^{17}
- $MM/K = 2^{27*2-17} = 2^{37} = 128\text{GB}$
- pokud to nestáčí
→ třífázové třídění

Třífázové třídění

1. fáze stejně jako u dvoufázové třídění
2. fáze třídíme pouze tolik proudů, kolik se vejde do paměti
každý běh vytvoří nový větší proud
3. fáze třídíme všechny "velké" proudy z 2. fáze

DÚ: Jaké jsou limity třífázového třídění?

Obecně (v praxi asi ne) pro větší n nemusí stačit 3 fáze, musíme tedy přidat další. Celkově $\log_{M/B} B$ fází.

Vylepšení TPMMS

- Jak setřídíte vojáky?
 - každého změříme, setřídíme na papíře, vyvoláme seřazené
 - nefunguje
 - náhodný přístup pro každého vojáka (záznam)
- komprese dat
 - funguje, až pro větší data (100 MB)
 - komprese na disku
 - komprese v paměti

Nepoužitelný lineární algoritmus

Vytváření invertovaného souboru (reverzního indexu) rozsáhlého textu.

- pro každé slovo zaznamenáme všechny pozice výskytu
- víme, kam máme zapisovat, můžeme zapisovat přímo
- nepoužitelné

Obsah

1 Třídění v paměti

2 Proveditelné algoritmy

3 Třídění na disku

4 Sublineární třídění

Mužeme třídit v méně než lineárním čase?

- na běžných počítačích **NE**
- změna modelu: masivní paralelizace
- máme dostatek počítačů pro libovolně velká data

Google MapReduce

Obecný systém pro zpracování velkých dat.

Příklad třídění

- 10^{10} 100bytových záznamů
- 10^{12} B = 1TB
- 840 sekund = 14 minut
- 10^9 B/s = 1GB/s
- třídíme rychleji, než dokážeme číst z disku

Závěry

- Pro praktickou proveditelnost algoritmů není důležitá asymptotická složitost, ale počet drahých operací (náhodných přístupů na disk).
- V "databázích" umíme pomocí TPMMS třídit v lineárním čase.
- Na paralelních systémech lze třídit i v sublineárním čase.