

EXTERNÍ TRIDĚNÍ

Tridění na počítačích (50. a 60. lety):

sekvenční přístup k datům

algoritmy na principu Mergesortu (rekurenci)

Tridění na diskech:

primární přístup k blokům dat

Míra časové složitosti:

vstupní a výstupní operace (čtení a zápis dat)

operace v interní paměti jsou zanedbatelné

TRÍ'DĚNI' NA PAŠKA'CH - MERGESORT

Přímý MERGESORT - dvojfažové merjení

používá 3 pošky T1, T2, T3

nenařočný na vnitřní paměť (staci 2 pošky)

Příklad:

0) T1: 44, 55, 12, 42, 94, 18, 6, 67 vstup

T2:

T3:

1a) T1: 44, 55, 12, 42 vstup se rozděl,

T2: 94, 18, 6, 67

T3:

1b) T1:

T2: menguji' se dvojice

T3: 44, 94 | 18, 55 | 6, 12 | 42, 67

2a) T1: 44, 94 | 18, 55

T2: 6, 12 | 42, 67 rozděl' se

T3:

2b) : T1: menguji' se otevřice

T2:

T3: 6, 12, 44, 94 | 18, 42, 55, 67

3a) T1: 6, 12, 44, 94

rozdělí se

T2: 18, 42, 55, 67

T3:

3b) T1:

T2:

T3: 6, 12, 18, 42, 44, 55, 67, 94

Výpočet má 3 stupně (obecně $\log n$)

V každém stupni 2 fáze : a) rozdělení (kopírování)

b) srovnání

V každé fázi pro každý prvek 1 čtení

1 kapis

Složitost: $O(n \log n)$

Fáze a) je z hlediska trvání reproduktivní

(neprůsporádatka prvky)

spotřebuje polovinu operací

4

Jednofázové' měření'

používá' 4 pásky

výsledek měření' se hned rozděluje na 2 pásky

vývozene' měření' - na každé' pašce stejný' počet běhu

Příklad:

0a) T1: 44, 55, 12, 42, 94, 18, 6, 67

T2:

T3:

T4:

0b): T1: 44, 55, 12, 42

T2: 94, 18, 6, 67

rozdělení'

T3:

T4:

1) T1:

T2: měření' + rozdělení'

T3: 44 | 6, 12

T4: 18, 55 | 42, 67

2) T1: 18, 44, 55, 94

T2: 6, 12, 42, 67

T3:

T4:

3) T1:

T2:

T3: 6, 12, 18, 42, 44, 55, 67, 94

T4:

Přirozený MERGESORT

pro soukromy, které obsahují delší uspořádání výsledků
(běhy)

merguji' se dvojice běhu'

rozdělování' se provádí' podle počtu běhu', ne podle
počtu prvků'

Příklad:

0a) T1: 44, 55, 12, 42, 94, 18, 6, 67

T2:

T3:

T4:

0b) T1 : 44, 55 | 18

T2: 12, 42, 94 | 6, 67

T3:

T4:

rozdělení'

1) T1:

T2: *mengoveni' + rozdelen.'*

T3: 12, 42, 44, 55, 94

T4: 6, 18, 67

2) T1: 6, 12, 18, 42, 44, 55, 67, 94

72.

73:

Ts:

Složitost: $O(n \log r)$

kde r je počet běhu ve vstupu

Mergesort s ryūzitím interní paměti.

$m = \text{opacità interna} / \text{parametri}$

1) vytvoření běhu delay m.

že vstupní pošty se načtem provku, setřídí se,
vypisou se na pošty T1

2) *mengoroni*, *bē-hu*^o

Složitost: krok 1) $O(n)$

krok 2) - $\log \frac{n}{m}$ průchodu

celkem $O(n \log \frac{n}{m})$

Technické vylepšení:

když se dá' pošek ořít oběma směry, střídá se
vzestupně a sestupně merovali'
ušetří se převijení pošek na začátek po každém
průchodu

Příklad:

main T1: 44, 94 | 6, 12

T2: 18, 55 | 42, 64

T3:

T4:

jsem na konci pošek T1, T2

jdou odzadu

meruju sestupně

na T3 a T4 zapisuji od předu

71:

72:

T3: 67, 42, 12, 6

T4: 94, 55, 44, 18

jsem na konec T3, T4

jdou odzadu

mengují vzestupně

na T1 a T2 zapisují odpředu

T1: 6, 12, 18, 42, 44, 55, 67, 94

T2:

T3:

T4:

Poznámka - název se stáčí, že výsledek bude
setříděny obráceně
(poté se ještě jednou přehopíruje)

Zobecnění - vicecestné mergování:

máme $2N$ posek, $r = \frac{n}{m}$ běhu

běhy se rozdělí na N posek

merguje se současně N běhu ze vstupních posek

zmergování běhy se rozděluji na N výstupních posek

vývážené mergování - na každou poseku stejný počet běhu

Složitost: $O(n \log_N (\frac{n}{m}))$

nevýhoda - velké množství posek

Vicefázové mergování

máme N vstupních posek, 1 výstupní

běhy se na pošky rozdělí nevýváženě

Příklad:

1) T1: 13 běhu

T2: 8 běhu zmerguje se T1, T2 na T3

T3: 0

2) T1: 5 bēhu°

T2: 0

xmerguji' se T1, T3 na T2

T3: 8 bēhu°

3) T1: 0

T2: 5 bēhu°

xmerguji' se T2, T3 na T1

T3: 3 bēhy

4) T1: 3 bēhy

T2: 2 bēhy

atd.

T3: 0

5) T1: 1 bēh

T2: 0

T3: 2 bēhy

6) T1: 0

T2: 1 bēh

T3: 1 bēh

7) T1: 1 bēh

T2: 0

konec

T3: 0

Příklad:

T1	T2	T3	T4	T5	T6	pôšky
16	15	14	12	8	0	pôčty běhu
8	7	6	4	0	8	
4	3	2	0	3	3	
2	1	0	2	2	2	
1	0	1	1	1	1	
0	1	0	0	0	0	konec

Podstatné je počáteční rozdělení běhu na pôšky

1. příklad - jsou to dvě po sobě jdoucí Fibonacciho čísla

obecně - Fibonacciho čísla odpovídajícího řady :

$$F_{i+1} = F_i + F_{i-1} + \dots + F_{i-k}$$


Když se počáteční počet běhu nedá takto rozdělit,
doplň se hypotetickymi prázdnými běhy.

Současné' mimořádní' ruce běhu'


výběr minima probíhá' v interní' paměti;
použije turnajový strom nebo halda

Turnajový strom:

máme běhy:




dalsí' krok:




atd.

neboli:



atd.

Hin - halda :



Počítání / vytvoření běhu

- 1) naložit do interní paměti maximální množství prvků
interně je setřídit
vznikají běhy stejné délky m
- 2) metoda Replacement selection
mohou vznikat běhy delší než m , v průměru $2m$
princip: jakmile zapisu první prvek z interní paměti na pásku, uvolní se tam místo a může se hned naložit další,

Postup:

násťu m prvků do paměti, vytvořím min-haldy
procedu **DELETEMIN**

minimum zapisu na výstupní poslu

násťu další prvek ze vstupní posly -

je-li větší než odebrane minimum, přijde do
téže haldy (a tohož běhu)

je-li menší, dojde ho stranou

procedu další **DELETEMIN**

atd.

az vymazáním celou haldy, postavím novou
z prvků, které jsem oddělila
(můžu ji stavět průběžně)

Příklad:

trídím 11, 94, 81, 96, 12, 35, 17, 99, 28, 58, 61, 75

$m = 3$

1) násťu 11, 94, 81

vytvorím haldy 11



2) vypíšu 11, načtu 96

výprostím haldy 81
/ \
94 96

3) vypíšu 81, načtu 12

haldy: 94 12 tam nepatří'
/
96

4) vypíšu 94, načtu 35

1. haldy: 96 2. haldy: 12
/
35

5) vypíšu 96, načtu 17

hotový běh: 11, 81, 94, 96

nová haldy: 12

/ \
35 17

6) vypíšu 12 - začátek nového běhu

načtu 99

haldy: 17
/ \
35 99

old.

výskedek - běhy : 11, 81, 94, 96

12, 17, 28, 35, 41, 58, 99

45

PŘÍHRA'DKOVÉ TRÍDĚNÍ NA PAŠRA'CH

17

Příklad:

trídím 0, 1, 2, 3, 7, 6, 5, 4

tj. v binárním zápisu:

000, 001, 010, 011, 111, 110, 101, 100

použijí se 4 pošty - 2 pro vstup

2 pro výstup

0) T1: 000, 001, 010, 011, 111, 110, 101, 100 vstup

T2:

T3:

T4:

1) T1:

T2: rozdělení podle poslední cifry

T3: 000, 010, 110, 100

T4: 001, 011, 111, 101

2) T1: 000, 100, 001, 101

T2: 010, 110, 011, 111

T3: rozdělení podle prostřední cifry

T4: v pořadí T3, T4

3) $T_1:$ rozdělení podle 1. cifry
 $T_2:$

$T_3: 000, 001, 010, 011$

$T_4: 100, 101, 110, 111$

4) $T_1: 000, 001, 010, 011, 100, 101, 110, 111$

$T_2:$

$T_3:$ spojení T_3, T_4

$T_4:$

Složitost: k průchodu pro čísla v rozsahu
 $0, \dots, 2^k - 1$

V každém průchodu se každé číslo 1x kópiruje

celkem: $O(k \cdot n)$

QUICKSORT NA 2 PÁSKAČCH

mám pásky 0 a 1 - funguje jeho zařazení
jsou obousměrné

vstupní soubor je na pozici 0

(vejde-li se do vnitřní paměti, seřídí se interně
a vrátí na pásku)

pivot = poslední prvek souboru = k

pásek 0 se očte odzadu -

prvky $> k$ se kopírují na pásek 1

pásek 0 se očte od předu -

prvky $= k$ se kopírují na pásek 1

pásek 0 se očte odzadu -

prvky $< k$ se kopírují na pásek 1

výsledek: T1: prvky $> k$, prvky $= k$, prvky $< k$

T0: prázdná

rekurze:

zpracuj se prvky $< k$ a seřídíme se zapísí na T0

prvky $= k$ se překopírují na T0

zpracuj se prvky $> k$ a seřídíme se zapísí na T0

Poznámka: Při rozdělování se střídají posky, ale taky nerovnosti -

tj. když rozdělají soubor (část) z T1 na T0,
zapisuji ho na T0 v pořadí:

prvky $< k$, prvky = k , prvky $> k$

Složitost: nejhorská $O(n^2)$

očekávaná $O(n \log n)$

Příklad:

T0: 11, 94, 81, 96, 12, 35, 17, 99, 28, 58, 41, 75

T1:

rozdělim podle 75

T0:

T1: $\underbrace{99, 96, 81, 94}_{> 75}, \underbrace{75, 41, 58, 28, 17, 35, 12, 11}_{< 75}$

Zpracuji prvky < 75 , rozdělim podle 11

T0: 11, 12, 35, 17, 28, 58, 41
 $\underbrace{\quad\quad\quad}_{> 11}$

T1: $\underbrace{99, 96, 81, 94, 75}_{< 11}$

Σ pracují prvky > 11, rozdělim podle 41

T0: 11

T1: $\underbrace{99, 96, 81, 94, 45,}_{>41} \underbrace{58, 41, 28, 17, 35, 12}_{<41}$

prvky < 41 rozdělim podle 12

T0: 11, 12, $\underbrace{35, 17, 28}_{>12}$

T1: $\underbrace{99, 96, 81, 94, 45,}_{<12} \underbrace{58, 41}_{>12}$

prvky > 12 rozdělim podle 28

T0: 11, 12

T1: $\underbrace{99, 96, 81, 94, 45,}_{>28} \underbrace{58, 41, 35,}_{<28} \underbrace{28, 17}_{<28}$

Σ kopíruji 12 na T1

Σ pracují prvky < 12 (Σ čeština nejsou)

Σ kopíruji 11 na T1

Σ pracují prvky < 11 (Σ čeština nejsou)

T0:

T1: $\underbrace{99, 96, 81, 94, 45,}_{>45} \underbrace{58, 41, 35, 28, 17, 12, 11}_{<45}$

22.

kopíruji na T0: prvky < 41

$$= 11$$

$$< 12$$

$$= 12$$

$$< 28$$

$$= 28$$

$$< 41$$

$$= 41$$

$$< 45$$

$$= 45$$

T0: 11, 12, 17, 28, 35, 41, 58, 45

T1: 99, 96, 81, 94

dělím prvky > 45, rozdělim podle 94

T0: 11, ..., 45, $\underbrace{81, 94, 96, 99}_{< 94}$, $\underbrace{99}_{> 94}$

T1:

zpracuji prvky > 94, rozdělim podle 99

T0: 11, ..., 45, 81, 94

T1: 99, $\underbrace{96}_{< 99}$

\checkmark kopíruji 94 na T1

zpracuji průkly < 94 (tj. 81)

T0: 11, ..., 95

T1: 99, 96, 94, 81

kopíruji na T0: průkly < 94

= 94

< 99

= 99

> 99 (žádne nejsou)

výsledek:

T0: 11, 12, 14, 28, 35, 41, 58, 75, 81, 94, 96, 99

T1:

TRÍDĚNÍ NA DISCÍCH

na páskách: průkly se přenášejí po jednom

na disky: -11- po blocích

xnačení: N počet průklu^v v souboru

M počet bloků, které se vejdou do interní paměti

B počet průklu^v v jednom bloku

P počet bloků, které se dají přenášet současně (pro naš $P=1$)

platí: $1 \leq B \leq M \leq N, 1 \leq P \leq \lfloor \frac{M}{B} \rfloor$

složitost (počet I/O operací):

$$\Omega\left(\frac{N}{PB} \cdot \frac{\log(1 + \frac{N}{B})}{\log(1 + \frac{M}{B})}\right)$$

v nejhorším i průměrném případě

Aggarwal, Vitter (1988)

MERGESORT

$\frac{N}{B}$ bloků se postupně načte do interní paměti.

(vejde se jich $\frac{N}{B}$)

obsah interní paměti se setřídí

vytroni se $\frac{N}{M}$ běhu

běhy se po bločích uloží zpět na disk

složitost: $\frac{N}{B}$ čtení, $\frac{N}{B}$ zápis

další fáze: řady $\frac{N}{B}$ běhu se merguje do jednoho

(z každého běhu se načte 1 blok, když se
pri mersování vysvěrpa, načte se další blok
z téhož běhu)

pocet fází: $\log_{\frac{N}{B}} \frac{N}{B}$

v každou se přečte a zapiše $\frac{N}{B}$ bloků

celkem: $2 \cdot \frac{N}{B} + 2 \cdot \frac{N}{B} \log \frac{N}{B} \frac{N}{B} = O\left(\frac{N}{B} \cdot \frac{\log \frac{N}{B}}{\log \frac{N}{B}}\right)$

vylepšení použitím Replacement selection

nevýhoda - netřídí na místě

EXQUISIT (Six, Wegner 1986)

externí variant Quicksortu
staci' M=2

Algoritmus:


- 1) načte se první a poslední blok vstupního souboru F
z jejich prvků se vypočte pivot H
- 2) F se rozdělí na část F_1 (prvky menší než H) a F_2 (prvky větší než H)

pointer L jde od 1 do B v levoším bloku
- " - R - " - B do 1 v pravém - " -
prvky se porovnávají s H a případně se prohodí,
když pointer dosáhne hranice bloku, blok se
zopře na disk a načte se sousední

- 3) když se pointery setkají, třidi se rekurezivně
 F_1 a F_2

Příklad:

disk:



interní paměť:

A D začátek

B D L přesec hranici mezi A a B

B C R —"— D a C

B A La R se setkaly v B

dohrádá se F_1 (dokončí se A)

B D začíná se trhát F_2

C D L přesec z B do C

C B La R se setkaly v C

dohrádá se F_{21} (dokončí se B)

C D dohrádá se F_{22} (dokončí se C, D)

Složitost

průměrný případ - řeší se rekurrence

$$T(N) = \lfloor \frac{N}{B} \rfloor + 1 + \frac{1}{N-1} \sum_{k=1}^{N-1} T(k) + T(N-k), \quad N > B+1$$

$$T(N) = 0 \text{ pro } N \leq B+1$$

řešení:

$$T(N) \leq 2 \frac{N}{B} \log\left(\frac{N}{B+1}\right) + \frac{3N}{B} + 1 - \frac{N}{B(B+1)}$$

nejhorší případ:

$$\text{nem}' O\left(\left(\frac{N}{B}\right)^2\right), \text{ ale } O\left(\frac{N^2}{B}\right)$$

tj. když se při rozdělení rozdělenu odděl, 1 první volba pivota

je ještě významnější než v interním Quicksortu

množnosti je menší (počítá se jen ze 2 bloků)

doporučení: $H = \left\lfloor \frac{F(L) + F(R)}{2} \right\rfloor$ fiktivní pivot

výhoda - nem' třeba ho po rozdělení umístit na správnou pozici

Poznámky:

- 1) Blok se neuklada na disk, dokud není nutné uvolnit místo v interní paměti
- 2) Blok se nepřepisuje (na disk), pokud v něm neproběhla žádna výměna
(tj. např. u seříděného souboru není žádny zapis na disk, pouze čtení)
- 3) Pořadí volání rekurze - funkce se dřív vezme část
- 4) Rekurz se zastaví, když se příslušná část souboru nejde do interní paměti.
- 5) Je-li $M > 2$, může se pracovat s logickými bloky místo fyzických
- 6) Jiný způsob rozdělování v interní paměti - pomocí dvoukonecovej holdy
(operace MIN a MAX v konstantním čase, ostatní v logaritmickém)

HEAPSORT

Wiedermann (1983)

Wiedermann, Šíma, Neruda (1997)

používá se k -regularní holda bloků

a) každý uzel v obsahuje M záznamů
 (logický blok S_v velikosti M)

b) $k \approx \frac{M}{B}$ (tj. počet fyzických bloků, které se
 vejdu do interní paměti)

c) holdova podmínka:

tedyž v je synem u v holdě T , pak pro všechna
 $x \in S_u, y \in S_v$ platí $x \leq y$

záznamy v uzlech jsou vzestupně seřiděny

Dá se reprezentovat polem.

Budování' haldy

soubor se rozdělí' na logické bloky velikosti M
 haldy' se nacte do interní' paměti:

tam se setřebí'

zapisí se způsoby na disk

úprava haldy - podle Floydova ("hora dolu"):


$$q = \text{počet vrcholů v haldě}$$

$$i := \frac{q-1}{k}$$

while $i \geq 1$ do $\text{restore}(i, k)$; $i := i-1$ enddo

$\text{restore}(i, k)$ - obnoví' haldovou podmínku v haldě
 s kořenem i

Příklad: máme T



T_1, T_2, T_3 už jsou správně vytrouzené 3-regulární haldy

Není-li splněna haldova podmínka pro horu v , pak:

- 1) pro $i=0, 1, \dots, k$ označím $s_i = \min \{S_i\}$
posloupnost S_0, S_1, \dots, S_k seřídíme vzestupně
tj. najdu permuci π , že $S_{\pi(0)} \leq S_{\pi(1)} \leq \dots \leq S_{\pi(k)}$
(tomu odpovídá poradí hald $T_{\pi(0)}, T_{\pi(1)}, \dots, T_{\pi(k)}$)
- 2) vytroužim $U = S_0 \cup S_1 \cup \dots \cup S_k$
seřídíme U vzestupně pomocí $(k+1)$ -cestného
mergování - výsledek bude Σ
- 3) Σ rozdělíme na úseky G_0, G_1, \dots, G_k délky M

4) protože $s_{\bar{n}(i)} \leq t_i = \min \{\bar{G}_i\}$ pro všechna i , můžu
přiřadit: \bar{G}_i koření $\bar{T}_{\bar{n}(i)}$ pro $i=1, \dots, k$
 \bar{G}_0 koření \bar{T}

halořova' podmínka bude splněna v T_1, \dots, T_k

5) není-li halořova' podmínka splněna v koření \bar{T} ,
vyměním \bar{G}_0 a \bar{G}_k (je v koření $\bar{T}_{\bar{n}(k)}$)
rekurzivně obnovim halořovou podmínku v $\bar{T}_{\bar{n}(k)}$

Složitost:

při vhodné implementaci $O\left(\frac{N}{B}\right)$ pro každou $k \geq 2$

Heapsort

- a) vybudovat haldy
- b) opakovat `DELETEMAX`

Složitost Heapsortu:

$$O\left(k \cdot \frac{N}{B} \cdot \frac{\log \frac{N}{B}}{\log k}\right) \text{ pro každou } k \geq 2$$

Pro $k \geq 2$ se fáze b) provádí jinak a tím zmizí multiplikativní konstanta k .


Příklad: řešidm posloupnost

21, 1, 2, 38, 53, 50, 57, 59, 55, 52, 11, 17, 8, 10, 63, 66, 4, 37,
13, 49, 61, 62, 70, 68

$$N = 24$$

nechť $B = 1$, $M = 4$, použiji binární haldu

- 1) seřídím usedy odélky 4
- 2) nahrázím je do haldy



- 3) upravím haldu

a) prohodím uzly N_2 a N_5

b) uzel n_1 nelze prohodit s žádým z jeho synů

$$\text{nejdu } s_1 = \min \{n_1\} = 50$$

$$s_2 = \min \{n_3\} = 8$$

$$s_3 = \min \{n_4\} = 4$$

platí $s_3 < s_2 < s_1$,

vytroním $V = \{n_1\} \cup \{n_3\} \cup \{n_5\}$

setřídím V pomocí 3-cestného mergoráni:

$\overbrace{7, 8, 10, 13}^{G_0}, \overbrace{37, 49, 50, 53}^{G_1}, \overbrace{57, 59, 63, 66}^{G_2}$


G_0 přijde do n_1

G_1 —!!— n_2

G_2 —!!— n_3

probudím užly n_1 a n_3

dostanu:



c) n netze prohodit $s n_1$, ani $s n_3$

$$\text{najdu } s_1 = \min \{n\} = 1$$

$$s_2 = \min \{n_1\} = 54$$

$$s_3 = \min \{n_2\} = 61$$

platí $s_1 < s_2 < s_3$

vytvoríme $U = \{n\} \cup \{n_1\} \cup \{n_2\}$, setřídíme:

$$\underbrace{1, 2, 21, 38,}_{G_0} \underbrace{54, 59, 61, 62,}_{G_1} \underbrace{63, 66, 68, 70}_{G_2}$$


G_0 přijde do n

$$G_1 \quad -\text{--}\quad n_1$$

$$G_2 \quad -\text{--}\quad n_2$$

prohodím n a n_2

cestami:




d) upraví se haldy s kořenem n_2

$$\text{setřídíme } U = \{n_2\} \cup \{n_5\}$$

rozdělíme na 2 části:

menší prvky přijdou do n_2 , větší do n_5
prohodi' se n_2 a n_5

Výsledná' haldy:




Třídění:

a) odeberu n_2 , nahradím ho n_5 , upravím haldy atd.

hodi' se pro binární haldy, ne pro víceřezlovní


b) odeberu n

do kořene namerguji 4 největší prvky z n_1 a n_2



do n , namerguji 4 největší prvky z n_3 a n_4 (f. n_5)
odeberu kořen

namerguji do něj 4 největší prvky z n_3 a n_5



doplňím uzly n_1 a n_2
 odeberu kořen
 atd.

Pozor! Když se vyprázdní nějaký uzel a chceme ho doplnit z jeho synů, musíme nejdřív vycistit interní paměť (mohlo v ní něco zůstat z předešlého mergování - to se musí vrátit na disk).

Prostorová složitost

Algoritmus se da implementovat tak, aby trídil na místě, ale je to technicky složité.

Poznámky:

- 1) Existují externí verze i dalších interních tridacích algoritmů
- 2) Prvky externího trídění se uplatňují i v interních algoritmech, pokud vnitřní paměť je hierarchická!
 Míra složitosti: počet operací (porovnání, výměny,...)
 + počet výpadků z cache