

PŘIHRÁDKOVÉ TRÍDĚNÍ

Binsort, Bucket sort, Radix sort

nepoužívají porovnávání prvků
trídí v lineárním čase
netřídí na místě

1) třídím permutaci $\{1, \dots, n\}$

A... původní pole

B... výsledné pole

for $i := 1$ to n do

$B(A(i)) := A(i)$

enddo

složitost: čas $O(n)$

prostor $O(n)$

2) třídím n navzájem různých čísel (celých) :

vypočtu min a max (porovnáním, čas $O(n)$)

vytvořím pole $B[\text{min}.. \text{max}]$

dosažuji $B(A(i)) := A(i)$

předosadím neprázdné položky z pole B do A

(nebo pole B zkomprimuji)

složitost :

$O(n)$, je-li max-min řádu $O(n)$

$O(n^2)$, — n — $O(n^2)$

může být i horší

Doporučení :

spočítat ještě druhou nejmenší a druhou největší

hodnoty

3) třídím n čísel, která nabývají hodnot $1, \dots, m$
 předpoklad: $m \leq n$

a) vytvořím m prázdných seznamů

b) for $i := 1$ to n do

vloším $A(i)$ do seznamu $k = A(i)$

enddo

e) spojím seznamy $1, \dots, m$

složitost: a) $O(m)$

b) $O(n)$

c) $O(m)$ pokud udržuji ukazatel na začátek a konec seznamu

celkem: $O(n+m) = O(n)$

Pro $m > n$ se to nevyplácí.

4) Třídění probíhá v cyklu přes jednotlivé cifry, nejméně významnou počínaje.

Příklad: 26, 9, 0, 251, 1, 49, 640, 16, 81, 4

1. fáze - podle jednotek:

0: 0, 640
 1: 251, 1, 81
 2:
 3:
 4: 4
 5:
 6: 26, 16
 7:
 8:
 9: 9, 49

2. fáze - podle desítek:

0: 0, 1, 4, 9
 1: 16
 2: 26
 3:
 4: 640, 49
 5: 251
 6:
 7:
 8: 81
 9:

3. fáze - pro stovky:

0: 0, 1, 4, 9, 16, 26, 49, 81
 1:
 2: 251
 3:
 4:
 5:
 6: 640
 7:
 8:
 9:

Výsledek: 0, 1, 4, 9, 16, 26, 49, 81, 251, 640

Po 1. fázi je posloupnost setříděna podle posledních cifer

Po 2.  posledních 2 cifer

Po 3.  podle všech

Kratší čísla se dají postupně vynechávat.

Důležité: prvky přidávat na konec seznamu

v každé fázi rozdělovat posloupnost přesně v tom pořadí, do kterého ji uspořádala fáze předchozí

Složitost: $O(k \cdot (n + m))$

k = maximální počet cifer, m = rozsah hodnot cifer

$O(n)$ pokud chápeme k a m jako konstanty

$O(n \log n)$ když třídíme permutaci čísel $\{1, \dots, n\}$

v binárním zápise

($m = 0, 1$; $k = \log n$)

HYBRIDSORT

Meijer, Akl (1980)

kombinuje prvky přihrádkového a porovnávacího třídění

Příklad: třídím maximálně třiciferná čísla
rovnoměrně rozdělená

rozdělím je do přihrádek po stovkách

$\lfloor \frac{x_i}{100} \rfloor \dots$ číslo přihrádky pro x_i

každou přihrádku setřídím - Quicksortem, Heapsortem ...

spojím setříděné přihrádky

Složitost: $O(m)$ vytvoření přihrádek (předp. konstantní)

$O(b_i^2)$ nebo $O(b_i \log b_i)$ setřídění přihrádky
(b_i prvků)

$O(m)$ spojení přihrádek

celkem: $O(m + \sum_{i=1}^m b_i^2)$ nebo $O(m + \sum_{i=1}^m b_i \log b_i)$

tj. $O(n^2)$ nebo $O(n \log n)$

průměrný případ: $O(n \log n)$

může být $O(n)$ při vhodně volených přihrádkách

Předpoklady:

trídíme reálná čísla $z \in \langle 0, 1 \rangle$

rovnoměrně rozdělena

rozdělíme je do k bucketů, kde $k = \alpha n$, $0 < \alpha < 1$

x_i přijde do bucketu $\lceil x_i \cdot k \rceil$

Příklad: 0,1; 0,85; 0,6; 0,34; 0,2; 0,3; 0,15;
0,42; 0,25; 0,7; 0,11; 0,35; 0,17; 0,29; 0,66;
0,9; 0,37; 0,19; 0,87; 0,5

$n = 20$, $\alpha = 0,2$, $k = 4$

buckety:

1: 0,1; 0,2; 0,15; 0,25; 0,11; 0,17; 0,19

2: 0,34; 0,3; 0,42; 0,35; 0,29; 0,37; 0,5

3: 0,6; 0,7; 0,66

4: 0,85; 0,9; 0,87

Každý bucket setřídíme Heapsortem

buckety pospojujeme

Očekávaný čas

$$\begin{array}{l}
 \text{vytvoření bucketů : } O(k) = O(dn) \\
 \text{rozdělení prvků : } O(n) \\
 \text{spojení bucketů : } O(k) = O(dn) \\
 \text{trídění : } E\left(\sum_{j=1}^k b_j \log b_j\right)
 \end{array} \left. \vphantom{\begin{array}{l} O(k) = O(dn) \\ O(n) \\ O(k) = O(dn) \end{array}} \right\} O(n)$$

$$P(b_j = i) = \binom{n}{i} \left(\frac{1}{k}\right)^i \left(1 - \frac{1}{k}\right)^{n-i} \text{ pro všechna } j$$

$$E\left(\sum_{j=1}^k b_j \log b_j\right) = \sum_{j=1}^k E b_j \log b_j = \sum_{j=1}^k \sum_{i=2}^n i \log i P(b_j = i)$$

$$= k \sum_{i=2}^n i \log i \binom{n}{i} \left(\frac{1}{k}\right)^i \left(1 - \frac{1}{k}\right)^{n-i} \leq$$

$$(*) \leq k \sum_{i=2}^n i^2 \binom{n}{i} \left(\frac{1}{k}\right)^i \left(1 - \frac{1}{k}\right)^{n-i} =$$

$$= k \left(\frac{n(n-1)}{k^2} + \frac{n}{k} \right) = \frac{n(n-1)}{k} + n =$$

$$= \frac{n(n-1)}{dn} + n = \frac{n-1}{d} + n = O(n)$$

(*) \Rightarrow k trídění bucketů lze použít algoritmus s kvadratickou složitostí

$$\sum_{i=1}^n i^2 \binom{n}{i} \left(\frac{1}{k}\right)^i \left(1 - \frac{1}{k}\right)^{n-i} = \sum_{i=1}^n i(i-1) \binom{n}{i} \left(\frac{1}{k}\right)^i \left(1 - \frac{1}{k}\right)^{n-i} + \sum_{i=1}^n i \binom{n}{i} \left(\frac{1}{k}\right)^i \left(1 - \frac{1}{k}\right)^{n-i}$$

$$2. \text{ součet} = \sum_{i=1}^n i \frac{n!}{i!(n-i)!} \left(\frac{1}{k}\right)^i \left(1 - \frac{1}{k}\right)^{n-i} =$$

$$= \frac{n}{k} \sum_{i=1}^n \frac{(n-1)!}{(i-1)!(n-i)!} \left(\frac{1}{k}\right)^{i-1} \left(1 - \frac{1}{k}\right)^{n-i} =$$

$$= \frac{n}{k} \sum_{i=0}^{n-1} \binom{n-1}{i} \left(\frac{1}{k}\right)^i \left(1 - \frac{1}{k}\right)^{n-1-i} =$$

$$= \frac{n}{k} \left(\frac{1}{k} + 1 - \frac{1}{k}\right)^{n-1} = \frac{n}{k}$$

$$1. \text{ součet} = \frac{n(n-1)}{k^2} \sum_{i=0}^{n-2} \binom{n-2}{i} \left(\frac{1}{k}\right)^i \left(1 - \frac{1}{k}\right)^{n-2-i} =$$

$$= \frac{n(n-1)}{k^2}$$

Modifikace pro nerovnoměrná rozdělení:

Plati: Když náhodná veličina X má distribuční funkci F , pak $Y = F(X)$ má rozdělení $\mathcal{R}(0,1)$.

$$\begin{aligned} \underline{\text{Dů}}: P(Y < y) &= P(F(X) < y) = P(X < F^{-1}(y)) = \\ &= F(F^{-1}(y)) = y \end{aligned}$$

x_i přijde do bucketu $[F(x_i) \cdot L]$

Nefunguje to pro úplně všechna rozdělení.

podmínky: rozdělení musí být soustředěno na konečném intervalu

(tj: $P(|X| > M) = 0$ pro nějaké M)

$F(x_i)$ se musí dařit rychle spočítat

DISTRIBUTIVE PARTITIONING

Dobosiewicz (1978)

trídím n prvků (ne nutně permutace $\{1, \dots, n\}$)

najdu: \min , \max , medián - čas $O(n)$

$\langle \min, \text{medián} \rangle$ rozdělím na $\frac{n}{2}$ stejně dlouhých intervalů

$\langle \text{medián}, \max \rangle$ — " —

pro $x \leq \text{medián}$: x přijde do intervalu

$$j = \left\lfloor \frac{x - \min}{\text{med} - \min} \cdot \frac{n-2}{2} + 1 \right\rfloor$$

pro $x > \text{medián}$: $j = \left\lceil \frac{x - \text{med}}{\max - \text{med}} \cdot \frac{n-1}{2} + \frac{n+1}{2} \right\rceil$

spočtu prvky v každém intervalu, pokud je jich víc než 1, postup se pro tento interval opakuje

časová složitost

nejhorší případ: $O(n \log n)$

nejhorší případ: v každé fázi $\frac{n}{2}$ prvků padne do jednoho bucketu

$$T(n) = cn + 2T\left(\frac{n}{2}\right)$$

$$T(n) = O(n \log n)$$

průměrný případ:

$$T(n) = cn + n \sum_{i=1}^n P_i T(i)$$

$$P_i = P(\text{bucket obsahuje } i \text{ prvků}) =$$

$$= \binom{n}{i} \left(\frac{1}{n}\right)^i \left(1 - \frac{1}{n}\right)^{n-i}$$

$$\sum_i P_i T(i) = \text{očekávaný čas na seřazení bucketu}$$

$$\text{řešení: } T(n) = O(n)$$

ověření: dosadím $T(i) = i$

$$T(n) = cn + n \sum_{i=1}^n \underbrace{i \binom{n}{i} \left(\frac{1}{n}\right)^i \left(1 - \frac{1}{n}\right)^{n-i}}_{n \cdot \frac{1}{n}} = O(n)$$

LINEAR PROBING SORT

Gonnet-Munro (1981), Dobosiewicz (1951)

trídím n -prvkové pole A

vytvořím pole B délky $m > n$

$\forall x \in A$ spočtu pomocí nějaké interpolační fce
jeho přibližnou polohu v poli B

je-li toto místo v poli B volné, dosadím tam x
není-li volné (je tam y):

pokud $x < y$, dosadím x a y posunu doprava -
tak dlouho, až se narazí na volné místo

($x > y$ symetricky)

je to podobné hašování s lineárním přidáváním
(včetně analýzy)

poslední krok: komprese pole B

Problémy

- 1) volba m (velikost pole B)
- 2) volba interpolační fee
- 3) kolik se provede porovnáni, než se prvek definitivně umístí
- 4) pole B může přetéct

Řešení

- 2) za předpokladu rovnoměrného rozdělení
lineární interpolace, tj. $j = 1 + \lfloor m \frac{x - \min}{\max - \min} \rfloor$

- 1) m se volí v závislosti na n

a na tom, čeho chceme dosáhnout:

minimalizovat počet dodatečných porovnáni,
-11- paměťovou náročnost,
atd.

při rovnoměrném rozdělení platí:

- a) pro $\frac{n}{m} < 0,8$ je pravděpodobnost přetčení
o 36 prvků (a více) menší než 10^{-7}

b) pro $\frac{n}{m} = 2 - \sqrt{2} \approx 0,5857$ je očekávaný počet operací (přístupů, porovnání, dosazení) roven $(2 + \sqrt{2})n + O(1)$

e) součin prostor \times čas je minimální pro

$$\frac{n}{m} = \sqrt{3} - 1 \approx 0,732$$

jeho očekávaná hodnota je $\frac{3\sqrt{3} + 5}{2} n^2 + O(n) =$
 $\approx 5,098 n^2 + O(n)$

d) doporučení: $m = \lfloor 1,25n \rfloor$

4) pole B se navíc rozšíří o 40 pozic

3) výsledky jsou podobné jako v hašování s

lineárním přidáváním (liši se jen o konstantu)

časová složitost

nejhorší případ $O(n^2)$

průměrný případ $O(n)$

GROUPSORT - Bucketsort na místě

Agarwal a spol. (1997)

Algoritmus:

- 1) obor hodnot min - max se rozdělí na k stejně dlouhých intervalů
- 2) pole se jednou projde
podle hodnot prvků se napočítá, kolik jich bude patřit do každého bucketu
výsledky se uloží do pomocného pole velikosti k
- 3) prvky se přemístí do svých bucketů
buckety jsou přímo v tříděném poli
hranice jsou uloženy v pomocném poli
celkový čas na přemístění - lineární
- 4) každý bucket se setřídí quicksortem

Počet bucketů :

konstantní - třídí se na místě

čas není lineární (ani očekávaný)

$k = dn$, $0 < d < 1$ - za předpokladu rovnoměrného rozdělení bude očekávaný čas $O(n)$

prostorová složitost není konstantní

Implementace bodu 2.):

do pole k uložíme navíc průběžnou pozici v jednotlivých bucketech

pole začnu procházet odleva :

posouvám průběžnou pozici v 1. bucketu, dokud nenarazím na prvek, který tam nepatří

patří-li tento prvek do j -tého bucketu, začnu prohledávat j -tý bucket (od průběžné pozice), dokud nenarazím na prvek, který tam nepatří

(patří do bucketu k)

dosadím na jeho místo prvek z 1. bucketu

prohledáme bucket k

atd.

Příklad: 75, 32, 199, 98, 1, 125, 137, 88, 170, 25, 165, 188

obor hodnot: 1 - 199

rozdělím na 4 intervaly:

1. 1 - 49 velikost: 3

2. 50 - 99 3

3. 100 - 149 2

4. 150 - 199 4

označím: zdola konce bucketů

shora přibližně pozice

↓ ↓ ↓ ↓

75, 32, 199, 98, 1, 125, 137, 88, 170, 25, 165, 188

↑ ↑ ↑

xleva: 75 nepatří do bucketu 1, patří do 2

98 patří do 2

1 nepatří do 2 (patří do 1) ⇒ 75 půjde
na místo 1

zařadím 1 - půjde na místo 1

↓ ↓ ↓ ↓

1, 32, 199, 98, 75, 125, 137, 88, 170, 25, 165, 188

↑ ↑ ↑

pokračuji od 32 - patří do bucketu 1

199 - nepatří (patří do 4)

170 patří do 4

25 nepatří do 4 (patří do 1) \Rightarrow

199 půjde na místo 25

zařadím 25 - půjde na místo 199

↓ ↓ ↓

1, 32, 25, 98, 75, 125, 137, 88, 170, 199, 165, 188

↑ ↑ ↑

průběžná pozice v 1. bucketu přešla hranici

pokračuje se od 125 - nepatří do 2 (patří do 3)

137 patří do 3

88 nepatří do 3 (patří do 2) \Rightarrow 125 půjde
na místo 88

zařadím 88 - půjde na místo 125

↓

1, 32, 25, 98, 75, 88, 137, 125, 170, 199, 165, 188

↑ ↑ ↑

doplnění posledního bucketu

celková složitost - lineární