

Algorithmen & Datenstrukturen

Herbst 2020

Vorlesung 5


Problem: Sortieren eines Arrays $A[1], \dots, A[n]$

Algorithmen bisher: $\uparrow$
keys (Schlüssel)

	Vergleiche	Bewegungen
Bubble Sort	$O(n^2)$	$O(n^2)$
Selection Sort	$O(n^2)$	$O(n)$
Insertion Sort	$O(n \log n)$	$O(n^2)$

Alle diese sind "inplace", d.h. brauchen keinen Extraspeicher: Resultat ist in A .

Selection Sort noch einmal, diesmal von rechts nach links:



Selection Sort (A)

for $i = n \dots 2$


→ $j = \text{Index des Maximum in } A[1 \dots i]$
Tausche $A[i]$ und $A[j]$

das kostet $O(n^2)$ da jedes Max $O(i)$ kostet


Gesucht: Datenstruktur die das Finden des Max billiger macht.

Hoffnung: Max in $O(\log i) \Rightarrow$ Algorithmen $O(n \log n)$!

Lösung: Max-Heap




Visualisierung als Baum: (Beispiel $i=12$)



Heapbedingung:
Für alle Knoten:
Schlüssel Knoten
 $\geq$ Schlüssel Kinder
Bsp: $85 \geq 80, 3$

$\Rightarrow$ Maximum ist Wurzel

Gespeichert im Array: keine Kinder



Max-Heap: $O(1)$!

Heapbedingung (Array)


$$\forall k \in \{1, \dots, n\}: \quad 2k \leq n \Rightarrow A[2k] \leq A[k]$$

$$2k+1 \leq n \Rightarrow A[2k+1] \leq A[k]$$



Weitere Eigenschaften des Heaps:

- grösste Tiefe: $\lfloor \log_2(n) \rfloor$
- Anzahl Blätter: $\lceil n/2 \rceil$ (die Hälfte)


$\Rightarrow$ Voller Binarbaum



Zurück zum Sortieren, Iteration i :



Also: stelle Heap Bedingung wieder her
 "versichere neue Wurzel durch Tauschen
 mit grösserem Kind, bis Kinder kleiner"



Versickern: $O(\log(i))$ Vergleiche
 $O(\log(i))$ Bewegungen


also gesamt $\sum_{i=1}^n c \cdot \log(i) \leq O(n \log n)$

↑
hätten wir letztes
Mal schon

Pseudocode:

RestoreHeapCondition(A, n, i) // versichere Element n
im Skript in $A[1..i]$

Was noch fehlt: A am Anfang in Heap verwandeln



Diese muss man versichern $\lfloor \frac{n}{2} \rfloor$ Blöcke $\Rightarrow$ verletzen dann keine Heapbedingung

HeapSort(A)

for $i = \lfloor \frac{n}{2} \rfloor \dots 1$

RestoreHeapCondition(A, i, n)

for $i = n \dots 2$

Vertausche $A[1]$ und $A[i]$

RestoreHeapCondition($A, 1, i-1$)

} Erzeuge Heap


} $O(n \log n)$ s.o.

Analyse Erzeuge Heap:

$n/2$ Aufrufe, jeder $\leq O(\log n) \Rightarrow O(n \log n)$

Es gilt sogar $O(n)$: siehe Skript oder
nächste Seite (nicht
in Vorlesung)

Wir nehmen an $n = 2^d - 1$ und haben A als Baum



Anzahl Vergleiche für "Erzeuge Heap" höchstens

$$0 \cdot 2^d + 2 \cdot 2^{d-1} + 4 \cdot 2^{d-2} + 6 \cdot 2^{d-3} + \dots + 2d \cdot 2^{d-d}$$

$$= 2 \sum_{i=0}^{d-1} i \cdot 2^i = 2d(2^d - 1) - 2 \sum_{i=0}^{d-1} i \cdot 2^i$$

Das folgende habe ich nicht gezeigt:

Benutze: $\sum_{i=0}^{d-1} i x^i = \frac{x - dx^d + (d-1)x^{d+1}}{(1-x)^2}, x \neq 1$

woher kommt das?

Nimm $\sum_{i=0}^{d-1} x^i = (1-x^d)/(1-x)$ und leite auf beiden Seiten ab

$$= 2d(2^d - 1) - 2(2 - d2^d + (d-1)2^{d+1})$$


$$= 4 \cdot 2^d - 2d - 4 \leq O(n)$$

Pro 2 Vergleiche ≤ 1 Vertauschung $\Rightarrow O(n)$ Vertauschungen

Heapsort: $+ O(n \log n)$
 gut $\rightarrow +$ Inplace (Extraplatz $O(1)$)
 schlecht $\rightarrow -$ schlechte Lokalität
 (= es wird viel hin- und her gehüpft)

Algorithmus 5: Mergesort

Idee: Divide-and-Conquer



Mergesort (A , left, right) // Anfang: left=1, right= n
 if left < right

middle = $\lfloor (left + right) / 2 \rfloor$

Mergesort (A , left, middle)

Mergesort (A , middle+1, right)

Merge (A , left, middle, right)

Den Algorithmus
 kann man
 iterativ
 implementieren:
 Straight
 Merge Sort
 im Skript

Beispiel:
 3 7 3 2 1 8 4 6 merge
 7 3 2 3 1 8 4 6 merge
 2 3 7 9 1 4 6 8 merge
 1 2 3 4 6 7 8 9

Merge (A, l, m, r)

$i = l$ // Index in A links

$j = m+1$ // Index in A rechts

$k = l$ // Index in B

while $i \leq m$ and $j \leq r$

if $A[i] < A[j]$

$B[k] = A[i]$

$i = i+1$

$k = k+1$

else

$B[k] = A[j]$


$j = j+1$

$k = k+1$

übriges in Rest links

" " rechts

Kopiere B zurück nach A




braucht Hilfsarray

Laufzeit: Vergleiche $T(n) = 2T(\frac{n}{2}) + cn \leq O(n \log n)$
 (Mergesort) Bewegungen " $O(n \log n)$
 Extraplatz $O(n)$

Variante: Natural Mergesort (siehe Skript)

1.) Finde sortierte Teilstücke:



2.) Merge

usw.

schon sortiert

Algorithmus 6: Quicksort

Mergesort

teile Array
sortiere links
sortiere rechts
verschmelze

↪ Ansatz + Extraplate ist hier


Invariante:

l	m	r
sortierte		sortierte
linke		rechte
Hälfte		Hälfte

Idee: schiebe die Array ins Aufteilen

- 1.) Aufteilen und Array
- 2.) Rekursion links und rechts
- 3.) Verschmelzen nicht notwendig

Invariante: an richtiger Stelle



Quick Sort (A, l, r)

if $l < r$

$k = \text{Aufteilen}(A, l, r)$ // wählt ein Element p




Quick Sort ($A, l, k-1$)

Quick Sort ($A, k+1, r$)


hat es an richtiger Stelle k indem es INV herstellt

$p = \text{Pivotelement, z.B. } p = A[r]$

Aufteilen:



stop wenn
 not > grün:



Aufteilen(A, l, r) // $l < r$

$i = l$

$j = r - 1$

$p = A[r]$

repeat

while $i < r$ and $A[i] < p$: $i = i + 1$

while $j > l$ and $A[j] > p$: $j = j - 1$

if $i < j$: tausche $A[i], A[j]$


until $i \geq j$


tausche $A[i], A[r]$

return i

// jetzt ist Pivot am richtigen Platz

Laufzeit: hängt davon ab wo Pivot landet

gut: 

schlecht: 

$$\text{gut: } T(n) = 2T\left(\frac{n}{2}\right) + cn \leq O(n \log n)$$

$$\text{schlecht: } T(n) = T(n-1) + cn \leq O(n^2)$$

Trotzdem wird Quicksort viel verwendet
Warum?

Worst-case ist selten!

z.B. best/worst case alternierend $\Rightarrow O(n \log n)$

Quicksort ist $O(n \log n)$ im average case
(neue Analyse, machen wir nicht)

Unglücklicherweise: schon sortiert ist worst case

Häufig wird das Pivotelement zufällig gewählt (randomisiertes Quicksort)

Randomisierte Algorithmen: nächstes Semester


Komplexität vergleichsbasierendes Sortieren

geht es mit weniger als $\Theta(n \log n)$ Vergleichen?

Idee: Jeder Algorithmus entspricht einem Entscheidungsbaum (ähnlich Suche)

Höhe (oder Tiefe)

0



1

2

...

was i und j ist hängt von Algorithmus ab, aber jeder fängt irgendwo an

Blätter $\leftrightarrow$ mögliche Sortierungen ($n!$ viele)

Laufzeit (worst case) $\leftrightarrow$ Höhe Baum h

Baum der Höhe h hat $\leq 2^h$ Blätter, also muss

$$2^h \geq n! \\ \Leftrightarrow h \geq \log_2(n!) \geq \Omega(n \log n)$$

haben wir letztes Mal

↑ wenn: untere

Schranke

Also Komplexität vergleichsbasierendes Sortieren ist $\Theta(n \log n)$.

Bäume: Manchmal sagt man Höhe, manchmal Tiefe
Tiefe der Wurzel definiert man $= 0$ oder $= 1$, was grade besser passt

Θ-Notation: $\mathcal{O}, \Omega, \Theta$

wie immer $f: \mathbb{N} \rightarrow \mathbb{R}^+$ (positive reelle Zahlen
 $0 \notin \mathbb{R}^+$)

wir schreiben oft $f(n)$ statt f

1.) $\mathcal{O}(f(n)) = \{g(n) \mid \text{es gibt } c > 0 \text{ so da\ss } g(n) \leq c f(n) \text{ f\"ur alle } n \in \mathbb{N}\}$

$g(n) \in \mathcal{O}(f(n))$, Schreibweise $g(n) \leq \mathcal{O}(f(n))$

" $f(n)$ ist asymptotisch eine obere Schranke f\"ur $g(n)$ "

2.) $\Omega(f(n)) = \{g(n) \mid \text{es gibt } c > 0 \text{ so da\ss } g(n) \geq c f(n) \text{ f\"ur alle } n \in \mathbb{N}\}$

$g(n) \in \Omega(f(n))$, Schreibweise $g(n) \geq \Omega(f(n))$

" $f(n)$ ist asymptotisch eine untere Schranke f\"ur $g(n)$ "

3.) $\Theta(f(n)) = \mathcal{O}(f(n)) \cap \Omega(f(n))$

$g(n) \in \Theta(n)$, Schreibweise $g(n) = \Theta(f(n))$

" $g(n)$ w\"achst asymptotisch wie $f(n)$ "