

Informatik II - SS 2016

(Algorithmen & Datenstrukturen)

Vorlesung 5 (4.5.2016)

Sortieren V, Abstrakte Datentypen



**UNI
FREIBURG**

Fabian Kuhn

Algorithmen und Komplexität

- **Selection Sort & Bubble Sort**
worst case & best case: $\Theta(n^2)$
- **Insertion Sort**
worst case (& avg. case): $\Theta(n^2)$, best case: $\Theta(n)$
- **Merge Sort**
worst case (and best case): $\Theta(n \log n)$
- **Quick Sort**
worst case (fixed pivot): $\Theta(n^2)$, average case: $O(n \log n)$
worst case, randomized: $O(n \log n)$
 - Erwartungswert, hohe Wahrscheinlichkeit
- **Lower Bound**
“comparison-based” Algorithmen: $\Omega(n \log n)$

- Mit Vergleichs-basierten Algorithmen nicht möglich
 - Untere Schranke gilt auch mit Randomisierung...
- Manchmal geht's schneller
 - wenn wir etwas über die Art der Eingabe wissen und ausnützen können
- Beispiel: Sortiere n Zahlen $a_i \in \{0,1\}$:
 1. Zähle Anzahl Nullen und Einsen in $O(n)$ Zeit
 2. Schreibe Lösung in Array in $O(n)$ Zeit

Aufgabe:

- Sortiere Integer-Array A der Länge n
- Wir wissen, dass für alle $i \in \{0, \dots, n\}$, $A[i] \in \{0, \dots, k\}$

Algorithmus:

```
1: counts = new int[k+1] // new int array of length k
2: for i = 0 to k do counts[i] = 0
3: for i = 0 to n-1 do counts[A[i]]++
4: i = 0;
5: for j = 0 to k do
6:   for l = 1 to counts[j] do
7:     A[i] = j; i++
```

Analyse Counting Sort

A : Länge n, k: Werte $\in \{0, \dots, k\}$

1: counts = new int[k+1]

$\leftarrow O(1), O(k)$

2: for i = 0 to k do counts[i] = 0

$\leftarrow O(k)$

3: for i = 0 to n-1 do counts[A[i]]++

$\leftarrow O(n)$

4: i = 0;

5: for j = 0 to k do

6: { for l = 0 to counts[j] do

7: { A[i] = j; i++

$\leq c \cdot (\text{counts}[j] + 1)$

$$\left. \begin{array}{l} \text{ } \\ \text{ } \\ \text{ } \\ \text{ } \end{array} \right\} k \cdot n \left. \vphantom{\begin{array}{l} \text{ } \\ \text{ } \\ \text{ } \\ \text{ } \end{array}} \right\} \leq \sum_{j=0}^k c(\text{counts}[j] + 1)$$

$$= c(k+1) + c \underbrace{\sum_{j=0}^k \text{counts}[j]}_n$$

$\in O(k+n)$

Laufzeit: $O(k+n)$

Counting Sort Implementierung

- Schauen wir das doch gleich mal in Python an...

Um's ein bisschen interessanter zu machen:

- Anstatt einfach Integers zu sortieren, versuchen wir Elemente der folgenden Form nach Ihrem *key* zu sortieren:

```
class DataItem:
```

```
    def __init__(self, key = 0, data = None):  
        self.key = key ←  
        self.data = data ←
```

counts[0], counts[1], counts[2],
= 3 = 4 = 1
3 7 8

- Einfach nur zählen und dann die entsprechende Anzahl Werte einzufüllen funktioniert hier nicht...

counts[1] - 1

Definition: Ein Sortieralgorithmus ist stabil, falls Elemente mit gleichem Schlüssel in der gleichen Reihenfolge bleiben.

Beispiel:

Sortiere folgende Strings **stabil** nach Anfangsbuchstabe:

“tuv”, “adr”, “bbc”, “tag”, “taa”, “abc”, “sru”, “bcb”

adr, abc, bbc, bcb, sru, tuv, tag, taa

Stabiles Sortieren

Welche der in der Vorlesung behandelten Sortieralgorithmen sind (so, wie wir sie besprochen haben) stabil?

~~ins.~~ selection sort ~~✓~~ ✗
ins. sort ✓
bubble sort ✓
merge sort ✓
quicksort ✗
counting sort so, wie zuerst nicht, nachher schon

Counting Sort:

- sortiert ganze Zahlen zwischen 0 und $O(n)$ in Linearzeit

Was, wenn die Zahlen aus einem grösseren Bereich sind?

- z.B.: ganze Zahlen zwischen 0 und $n^2 - 1$?

$$x = \underline{a \cdot n + b}, \text{ so dass } a, b \in \{0, \dots, u-1\}$$

$$x = a_0 \cdot 1 + a_1 \cdot 10 + a_2 \cdot 10^2 + a_3 \cdot 10^3$$

$$x_1 = a_1 u + b_1$$

$$x_2 = a_2 u + b_2$$

Sortiere Werte zwischen 0 und $n^2 - 1$:

Ziel: Sortiere $x_0, x_1, x_2, \dots, x_{n-1}$, wobei $x_i \in \{0, \dots, n^2 - 1\}$

Algorithmus:

1. Schreibe alle Zahlen als $x_i = a_i \cdot n + b_i$ für $a_i, b_i \in \{0, \dots, n - 1\}$
2. Sortiere Zahlen mit Counting Sort nach b_i
3. Sortiere Zahlen **stabil** mit Counting Sort nach a_i

Verallgemeinerung der Idee

$$a_{i,j} \in \{0, \dots, u-1\}$$

- **Ziel:** sortiere (nichtnegative) ganze Zahlen x_0, \dots, x_{n-1}
- Schreibe Zahlen als $x_i = \underbrace{a_{i,0}} + \underbrace{a_{i,1}} \cdot \underbrace{n} + \underbrace{a_{i,2}} \cdot \underbrace{n^2} + \dots + \underbrace{a_{i,k}} \cdot \underbrace{n^k}$

Algorithmus:

1. Sortiere mit Counting Sort nach $a_{i,0}$
2. Sortiere mit Counting Sort stabil nach $a_{i,1}$
3. Sortiere mit Counting Sort stabil nach $a_{i,2}$
4. ...
5. Sortiere mit Counting Sort stabil nach $a_{i,k}$



Sortiere x_0, \dots, x_{n-1} , mit $x_i = a_{i,0} + a_{i,1}n + a_{i,2}n^2 + \dots + a_{i,k}n^k$

Algorithmus:

1. Sortiere mit Counting Sort nach $a_{i,0}$
2. Sortiere mit Counting Sort stabil nach $a_{i,1}$
3. ...
4. Sortiere mit Counting Sort stabil nach $a_{i,k}$

max. Wert:

x_{\max}

Laufzeit $O(kn)$, $k = \lceil \log_n x_{\max} \rceil$

$$\hookrightarrow O\left(n \cdot \frac{\log x_{\max}}{\log n}\right) = O(n \log_n x_{\max})$$

- **Selection Sort, Insertion Sort, Bubble Sort**
worst case: $\Theta(n^2)$
- **Merge Sort**
worst case (and best case): $\Theta(n \log n)$
- **Quick Sort**
worst case (fixed pivot): $\Theta(n^2)$, average case: $O(n \log n)$
worst case, randomized: $O(n \log n)$
- **Radix Sort** (for sorting positive integers)
worst case: $O(n \log_n M)$, where M is the largest value
- **Lower Bound**
“comparison-based” Algorithmen: $\Omega(n \log n)$

Algorithmen

- Wie löst man ein gegebenes Problem effizient
- Ziel: möglichst geringe Komplexität
 - kurze Laufzeit / kleiner Speicherverbrauch
 - asymptotisch, abhängig von der Problemgröße

Datenstrukturen

- Wie können Daten so abgespeichert werden, dass der Zugriff möglichst effizient ist
- Hängt von den Operationen ab, welche unterstützt werden sollen!
- Ermöglicht schnelle Algorithmen
- Benötigt schnelle Algorithmen, um die Operationen optimal auszuführen

Abstrakter Datentyp:

- Spezifikation, welche Art von Daten verwaltet werden können
- Spezifikation der Operationen, um auf die Daten zuzugreifen
 - inkl. der Semantik der Operation

Datenstruktur:

- Bestimmte Art, einen abstrakten Datentypen zu implementieren
- Je nach Implementierung können die gleichen Operationen verschiedene Laufzeiten (Komplexität) haben.

Array:

- Verwaltet eine Menge von Elementen (des gleichen Typs)

Operationen:

- $create(n)$: erzeugt ein Array der Länge n
- $A.get(i)$: gibt das Element an Position i zurück $A[i] = x$
- $A.set(x, i)$: schreibt Element x an Position i
- $A.size()$: gibt die Länge des Arrays zurück (nicht immer dabei) $len(A)$

Bei dynamischen Arrays (können Grösse verändern):

- $A.append(x)$: hängt Element x hinten an
- $A.deleteLast()$: löscht letztes Element

Dictionary: (auch: Maps, assoziative Arrays)

- Verwaltet eine Menge von Elementen, wo bei jedes Element durch einen eindeutigen Schlüssel (key) repräsentiert wird

Operationen:

- create : erzeugt einen leeren Dictionary
- D.insert(key, value) : fügt neues (key,value)-Paar hinzu
 - falls schon ein Eintrag für *key* besteht, wird er ersetzt
- D.find(key) : gibt Eintrag zu Schlüssel *key* zurück
 - falls ein Eintrag vorhanden (gibt sonst einen Default-Wert zurück)
- D.delete(key) : löscht Eintrag zu Schlüssel *key*

Dictionary:

Weitere mögliche Operationen:

- *D.minimum()* : gibt kleinsten *key* in der Datenstruktur zurück
- *D.maximum()* : gibt grössten *key* in der Datenstruktur zurück
- *D.successor(key)* : gibt nächstgrösseren *key* zurück
- *D.predecessor(key)* : gibt nächstkleineren *key* zurück
- *D.getRange(k1, k2)* : gibt alle Einträge mit Schlüsseln im Intervall $[k1, k2]$ zurück

Queue (Warteschlange):

- Verwaltet eine Menge (“Sequenz”) von Werten



Operationen:

- create : erzeugt eine leere Queue
- Q.enqueue(x) : hängt Element x hinten an
- Q.dequeue() : gibt vorderstes Element zurück und löscht es
- Q.isEmpty() : Ist die Queue leer?

Heisst auch FIFO Queue (FIFO = first in first out)

Stack (Stapel):


- Verwaltet eine Menge (“Sequenz”) von Werten

Operationen:

- *create* : erzeugt einen leeren Stack
- *S.push(x)* : legt Element x auf den Stack
- *S.pop()* : gibt oberstes Element zurück und löscht es
- *S.isEmpty()* : Ist der Stack leer?



Heisst auch LIFO Queue (LIFO = last in first out)



Heap / Priority Queue (Prioritätswarteschlange):

- Verwaltet eine Menge von (key,value)-Paaren


↳ nicht eindeutig

Operationen:

- *create* : erzeugt einen leeren Heap
- *H.insert(x, key)* : fügt Element *x* mit Schlüssel *key* ein
- *H.getMin()* : gibt Element mit kleinstem Schlüssel zurück
- *H.deleteMin()* : löscht Element mit kleinstem Schlüssel
- *H.decreaseKey(x, newkey)* : Falls *newkey* kleiner als der aktuelle Schlüssel von *x* ist, wird der Schlüssel von *x* auf *newkey* gesetzt


Union-Find / Disjoint Sets:

- Verwaltet eine Partition von Elementen



Operationen:


- *create* : erzeugt eine leere Union-Find-DS
- *U.makeSet(x)* : fügt Menge $\{x\}$ zur Partition hinzu
- *U.find(x)* : gibt Menge mit Element x zurück
- *U.union(S1, S2)* : vereinigt die Mengen $S1$ und $S2$



Array-Implementierung Stack

Versuchen wir den Stack-Datentyp zu implementieren

- **Operationen:** *create*, *push*, *pop*, *isEmpty*
- **Annahme:** Stack muss nur für *NMAX* Elemente Platz bieten



Variablen, um den Zustand des Stack zu speichern:

- *stack* : Array der Länge *NMAX*
- *size* : Aktuelle Anzahl Elemente im Stack

create:


stack = new array of length *NMAX*

size = 0

Array-Implementierung Stack

isEmpty:

```
return (size == 0)
```



S.push(x):

```
if (size < NMAX)
```

```
    stack[size] = x
```

```
    size += 1
```

S.pop():

```
if (size == 0)
```

```
    report error (or return default value)
```

```
else
```

```
    size -= 1
```

```
    return stack[size]
```


Laufzeit (Zeitkomplexität) der Operationen:

- create: $O(1)$
 - falls man davon ausgeht, dass Speicher in $O(1)$ Zeit alloziert werden kann
 - push: $O(1)$
 - pop: $O(1)$
 - isEmpty: $O(1)$
- } sehr schnell

Nachteile der Implementierung:

- Speicherverbrauch (space complexity) : $O(NMAX)$
 - man braucht immer gleich viel Speicher, egal wie viele Elemente im Stack gespeichert sind!
- Der Stack kann nur $NMAX$ Elemente aufnehmen...
- Wir werden sehen, wie man beides beheben kann...

Stack : Anwendungen

- Umdrehen einer Sequenz: 1, 2, 3
push(1), push(2), push(3), pop()=3, pop()=2, pop()=1
- Undo-Funktion bei Editoren
 - lege Beschreibung von (umkehrbaren) Operationen auf Stack ab
- Programmstack für Funktionen/Methoden-Aufrufe
 - Bemerkung: Mit einem Stack kann man Rekursion explizit aufschreiben

