

# Algorithmen und Datenstrukturen

## A7. Sortieren III

Marcel Lüthi and Gabriele Röger

Universität Basel

11. März 2020

# Algorithmen und Datenstrukturen

11. März 2020 — A7. Sortieren III

A7.1 Untere Schranke

A7.2 Quicksort

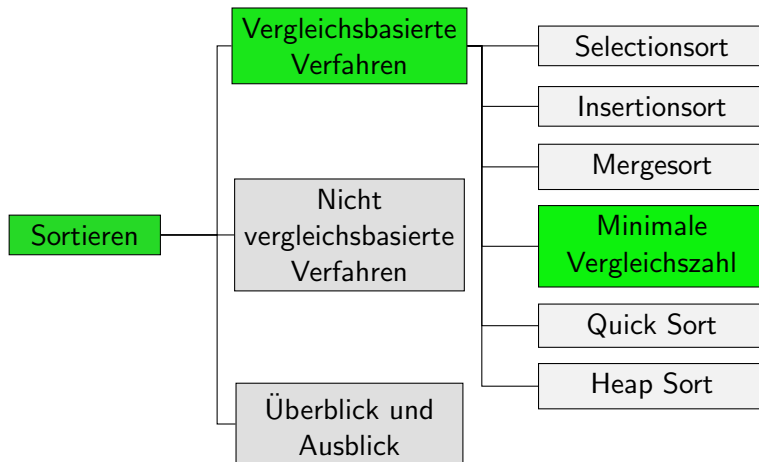
A7.3 Heapsort

A7.4 Nicht vergleichsbasierte Verfahren

A7.5 Zusammenfassung

# A7.1 Untere Schranke

# Sortierverfahren




# Untere Schranke I

- ▶ Mergesort hatte bisher mit  $O(n \log_2 n)$  die beste (Worstcase-)Laufzeit.
- ▶ Geht es noch besser?
- ▶ **Wir zeigen:** Nicht mit vergleichsbasierten Verfahren!


## Untere Schranke II

Betrachte beliebigen vergleichsbasierten Sortieralgorithmus  $A$ .

- ▶ Verhalten hängt nur vom Ergebnis der Schlüsselvergleiche ab.
- ▶ Bei jedem Schlüsselvergleich gibt es zwei Möglichkeiten, wie der Algorithmus weiter macht.
- ▶ Wir können das graphisch als Baum darstellen.



## Untere Schranke III



- ▶ **Binärbaum**: jeder Knoten hat höchstens zwei Nachfolger
- ▶ Knoten ohne Nachfolger heissen **Blätter** (Bild: eckige Knoten).
- ▶ Der Knoten ganz oben ist die **Wurzel**.
- ▶ Die **Tiefe** eines Blattes entspricht der Anzahl von Kanten von der Wurzel zu dem Blatt.

Die maximale Tiefe eines Blattes in einem Binärbaum mit  $k$  Blättern ist mindestens  $\log_2 k$ .

## Untere Schranke IV

Was muss der Algorithmus können?

- ▶ **Annahme:** alle Elemente unterschiedlich
- ▶ Muss **alle Eingaben** der Grösse  $n$  **korrekt** sortieren.
- ▶ Wir können alle Algorithmen so anpassen, dass sie verfolgen, von welcher Position zu welcher Position die Elemente bewegt werden müssen.
- ▶ Das Ergebnis ist dann nicht das sortierte Array, sondern die entsprechende **Permutation**.  
Beispiel:  $\text{pos0} \mapsto \text{pos2}$ ,  $\text{pos1} \mapsto \text{pos1}$ ,  $\text{pos2} \mapsto \text{pos0}$
- ▶ Da alle möglichen Eingaben der Grösse  $n$  korrekt gelöst werden müssen, muss der Algorithmus **alle  $n!$  möglichen Permutationen** erzeugen können.



## Untere Schranke $V$

- ▶ Jedes Blatt in der Baumdarstellung entspricht einer Permutation.
- ▶ Bei Eingabegrösse  $n$  muss der Baum also mindestens  $n!$  Blätter haben.
- ▶ Die maximale Tiefe des entsprechenden Baumes ist demnach  $\geq \log_2(n!)$ .
- ▶ Es gibt also eine Eingabe der Grösse  $n$  mit  $\geq \log_2(n!)$  Schlüsselvergleichen.

# Untere Schranke VI

Abschätzung von  $\log_2(n!)$

- ▶ Es gilt  $n! \geq \left(\frac{n}{2}\right)^{\frac{n}{2}}$

$$4! = 1 \cdot 2 \cdot \underset{\geq 2}{3} \cdot \underset{\geq 2}{4} \geq 2^2$$

- ▶  $\log_2(n!) \geq \log_2\left(\left(\frac{n}{2}\right)^{\frac{n}{2}}\right) = \frac{n}{2} \log_2\left(\frac{n}{2}\right)$   
 $= \frac{n}{2}(\log_2 n + \log_2 \frac{1}{2}) = \frac{n}{2}(\log_2 n - \log_2 2)$   
 $= \frac{n}{2}(\log_2 n - 1)$


## Theorem

Jeder *vergleichsbasierte Sortieralgorithmus* benötigt  $\Omega(n \log n)$  viele Schlüsselvergleiche. Damit liegt auch die *Laufzeit* in  $\Omega(n \log n)$ .

Mergesort ist asymptotisch optimal.

## A7.2 Quicksort

# Sortierverfahren



## Quicksort: Idee

- ▶ Wie Merge-Sort ein **Divide-and-Conquer-Verfahren**
- ▶ Die Sequenz wird nicht wie bei Mergesort nach Positionen aufgeteilt, sondern nach Werten.
- ▶ Hierfür wird ein Element  $P$  gewählt (das sogenannte **Pivotelement**).
- ▶ Dann wird so umsortiert, dass  $P$  an die endgültige Position kommt, vor  $P$  nur Elemente  $\leq P$  stehen, und hinten nur Elemente  $\geq P$ .



- ▶ Macht man das rekursiv für den vorderen und den hinteren Teil, ist die Sequenz am Ende sortiert.

# Quicksort: Algorithmus

---

```
1 def sort(array):
2     sort_aux(array, 0, len(array)-1)
3
4 def sort_aux(array, lo, hi):
5     if hi <= lo:
6         return
7     choose_pivot_and_swap_it_to_lo(array, lo, hi)
8     pivot_pos = partition(array, lo, hi)
9     sort_aux(array, lo, pivot_pos - 1)
10    sort_aux(array, pivot_pos + 1, hi)
```

---

## Wie wählt man das Pivot-Element?

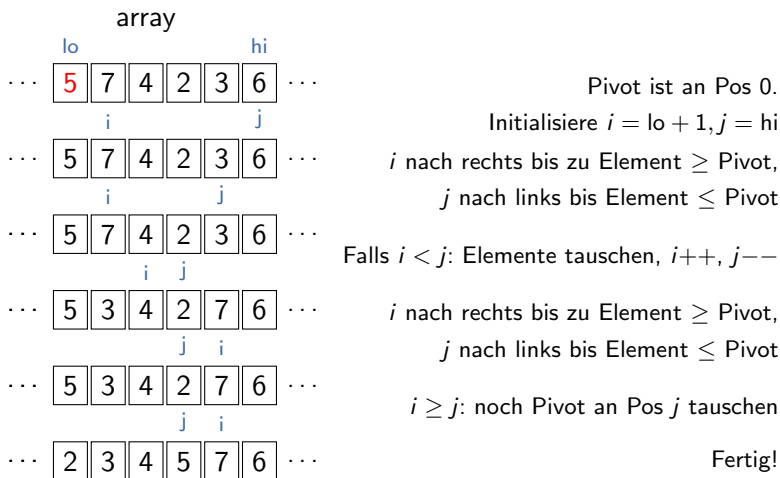
Für die Korrektheit des Verfahrens ist das egal. (Warum?)

Wir können zum Bsp. folgende Strategien wählen:

- ▶ **Naiv:** Nimm immer erstes Element
- ▶ **Median of Three:** Verwende Median aus erstem, mittlerem und letztem Element
- ▶ **Randomisiert:** Wähle zufällig ein Element aus

Gute Pivot-Elemente teilen Sequenz in etwa gleich grosse Bereiche.

# Wie macht man die Umsortierung?





# Quicksort: Partitionierung

---

```
1 def partition(array, lo, hi):
2     pivot = array[lo]
3     i = lo + 1
4     j = hi
5     while (True):
6         while i < hi and array[i] < pivot:
7             i += 1
8         while array[j] > pivot:
9             j -= 1
10        if i >= j:
11            break
12
13        array[i], array[j] = array[j], array[i]
14        i, j = i + 1, j - 1
15    array[lo], array[j] = array[j], array[lo]
16    return j
```

---

## Quicksort: Laufzeit I

**Best case:** Pivot-Element teilt in gleich grosse Bereiche

- ▶  $O(\log_2 n)$  rekursive Aufrufe
- ▶ jeweils hi-lo Schlüsselvergleiche in Partitionierung
- ▶ auf einer Rekursionsebene insgesamt  $O(n)$  Vergleiche in Partitionierung

→  $O(n \log n)$

**Worst case:** Pivot-Element immer kleinstes oder grösstes Element

- ▶ insgesamt  $n-1$  (nichttriviale) rekursive Aufrufe für Länge  $n, n-1, \dots, 2$ .
- ▶ jeweils hi-lo Schlüsselvergleiche in Partitionierung

→  $\Theta(n^2)$

## Quicksort: Laufzeit II

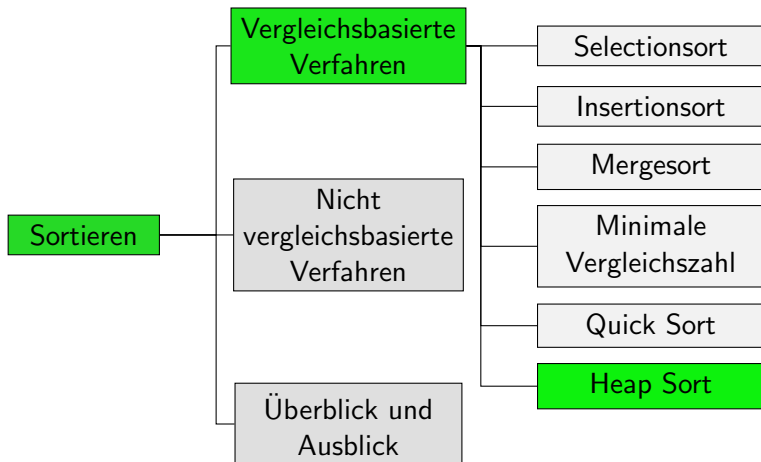
### Average case:

- ▶ Annahme:  $n$  verschiedene Elemente, jede der  $n!$  Permutationen gleich wahrscheinlich, Pivotelement zufällig gewählt
- ▶  $O(\log n)$  rekursive Aufrufe
- ▶ insgesamt  $O(n \log n)$
- ▶ etwa 39% langsamer als best case

Bei randomisierter Pivotwahl tritt worst-case quasi nicht auf. Quicksort wird daher oft als  $O(n \log n)$ -Verfahren betrachtet.

## A7.3 Heapsort

# Sortierverfahren

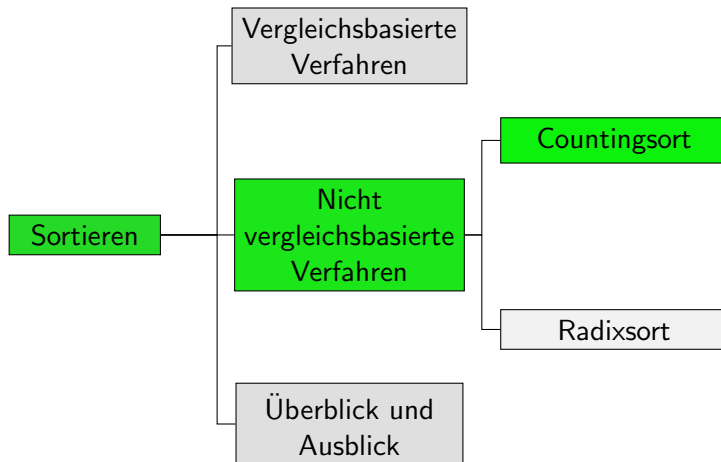


# Heapsort

- ▶ **Heap:** Datenstruktur, die das Finden und Entnehmen des **grössten** Elements besonders effizient unterstützt  
Finden:  $\Theta(1)$ , Entnehmen:  $\Theta(\log n)$
- ▶ **Grundidee analog zu Selectionsort:** Setze sukzessive das grösste Element an das Ende des unsortierten Bereichs.
- ▶ Kann den **Heap direkt in der Eingabesequenz repräsentieren**, so dass Heapsort nur konstanten zusätzlichen Speicherplatz benötigt.
- ▶ Die Laufzeit von Heapsort ist leicht überlinear.
- ▶ Wir besprechen die Details später, wenn wir Heaps genauer kennengelernt haben.

# A7.4 Nicht vergleichsbasierte Verfahren

# Sortierverfahren





# Countingsort: Idee

## „Sortieren durch Zählen“

- ▶ **Annahme:** Elemente sind aus Bereich  $0, \dots, k - 1$ .
- ▶ Laufe einmal über die Eingabesequenz und zähle dabei, wie oft jedes Element vorkommt.
- ▶ Sei  $\#i$  die Anzahl der Vorkommen von Element  $i$ .
- ▶ Iteriere  $i = 0, \dots, k - 1$  und schreibe jeweils  $\#i$ -mal Element  $i$  in die Sequenz.

# Countingsort: Algorithmus


---

```
1 def sort(array, k):
2     counts = [0] * k # list of k zeros
3     for elem in array:
4         counts[elem] += 1
5
6     pos = 0
7     for i in range(k):
8         occurrences_of_i = counts[i]
9         for j in range(occurrences_of_i):
10            array[pos + j] = i
11            pos += occurrences_of_i
```

---

Laufzeit:  $O(n + k)$  ( $n$  Grösse der Eingabesequenz)  
→ Für festes  $k$  linear

# Sortierverfahren



# Radixsort: Idee

„Sortieren durch Fachverteilen“

- ▶ Annahme: Schlüssel sind Zahlen im Dezimalsystem

z.B. 763, 983, 96, 286, 462

- ▶ Teile Zahlen nach **letzter** Stelle auf:

0	1	2	3	4	5	6	7	8	9
		462	763			96			
			983			286			

- ▶ Sammle Zahlen von vorne nach hinten/oben nach unten auf  
462, 763, 983, 96, 286
- ▶ Teile Zahlen nach **vorletzter** Stelle auf, sammle sie auf.
- ▶ Teile Zahlen nach **drittletzter** Stelle auf, sammle sie auf.
- ▶ usw. bis alle Stellen betrachtet wurden.

## Radixsort: Beispiel

► **Eingabe:** 263, 983, 96, 462, 286

► **Aufteilung nach letzter Stelle:**

0	1	2	3	4	5	6	7	8	9
		462	263			96			
			983			286			

**Aufsammeln ergibt:** 462, 263, 983, 96, 286

► **Aufteilung nach vorletzter Stelle:**

0	1	2	3	4	5	6	7	8	9
						462		983	96
						263		286	

**Aufsammeln ergibt:** 462, 263, 983, 286, 96

► **Aufteilung nach drittletzter Stelle:**

0	1	2	3	4	5	6	7	8	9
096		263		462					983
		286							

**Aufsammeln ergibt:** 96, 263, 286, 462, 983

# Jupyter-Notebook



Jupyter-Notebook: `radix_sort.ipynb`

# Radixsort: Algorithmus (für beliebige Basis)

---

```
1 def sort(array, base=10):
2     if not array: # array is empty
3         return
4     iteration = 0
5     max_val = max(array) # identify largest element
6     while base ** iteration <= max_val:
7         buckets = [[] for num in range(base)]
8         for elem in array:
9             digit = (elem // (base ** iteration)) % base
10            buckets[digit].append(elem)
11        pos = 0
12        for bucket in buckets:
13            for elem in bucket:
14                array[pos] = elem
15                pos += 1
16        iteration += 1
```

---

## Radixsort: Laufzeit

- ▶  $m$ : Maximale Anzahl Stellen in Repräsentation mit gegebener Basis  $b$ .
- ▶  $n$ : Länge der Eingabesequenz
- ▶ Laufzeit in  $O(m \cdot (n + b))$

Für festes  $m$  und  $b$  hat Radixsort lineare Laufzeit.



# A7.5 Zusammenfassung

# Zusammenfassung

- ▶ Jedes **vergleichsbasierte Sortierverfahren** hat **mindestens leicht überlineare Laufzeit**.
- ▶ **Quicksort** ist ein **Divide-and-Conquer**-Verfahren, das die Elemente relativ zu einem **Pivotelement** aufteilt.
- ▶ **Countingsort** und **Radixsort** sind **nicht vergleichsbasiert** und erlauben (unter bestimmten Restriktionen) ein Sortieren in **linearer Zeit**.
- ▶ Sie machen jedoch zusätzliche Einschränkungen an die verwendeten Schlüssel.