

# Algorithmen und Datenstrukturen

## A5. Laufzeitanalyse: Einführung, Selection- und Mergesort

Marcel Lüthi and Gabriele Röger

Universität Basel

27. Februar 2019

# Algorithmen und Datenstrukturen

## 27. Februar 2019 — A5. Laufzeitanalyse: Einführung, Selection- und Mergesort

### A5.1 Laufzeitanalyse Allgemein

### A5.2 Beispiel: Selectionsort

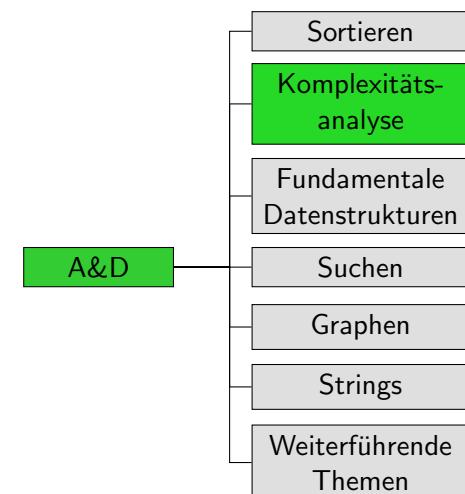
### A5.3 Exkurs: Logarithmus

### A5.4 Beispiel: Mergesort

### A5.5 Zusammenfassung

## A5.1 Laufzeitanalyse Allgemein

## Inhalt dieser Veranstaltung



## Exakte Laufzeitanalyse unrealistisch

- ▶ **Wäre schön:** Formel, die für konkrete Eingabe berechnet, wie lange das Programm läuft.
- ▶ **exakte Laufzeitprognose schwierig**, da zu viele Einflüsse:
  - ▶ Geschwindigkeit und Architektur des Computers
  - ▶ Programmiersprache
  - ▶ Compilerversion
  - ▶ aktuelle Auslastung (was sonst noch läuft)
  - ▶ Cacheverhalten

Wir können und wollen das nicht alles in die Formel aufnehmen.

## Laufzeitanalyse: Vereinfachung 1

**Zähle Anzahl der Operationen statt die Zeit zu messen!**

Was ist eine Operation?

- ▶ Idealerweise: eine Zeile Maschinencode oder – noch präziser – ein Prozessorzyklus
- ▶ Stattdessen: Anweisungen, die konstante Zeit benötigen
  - ▶ konstante Zeit: Laufzeit unabhängig von Eingabe
  - ▶ ignoriere Laufzeitunterschiede verschiedener Anweisungen
  - ▶ z.B. Addition, Zuweisung, Verzweigung, Funktionsaufruf
  - ▶ **grob:** Operation = eine Zeile Code
  - ▶ **aber:** auch beachten, was dahinter steht  
z.B. Schritte innerhalb einer aufgerufenen Funktion

**Wichtig: Laufzeit ungefähr proportional zu Anzahl Operationen**

## Laufzeitanalyse: Vereinfachung 2

**Schätze ab statt genau zu zählen!**

- ▶ Meistens Abschätzung nach oben („obere Schranke“)  
*Wie viele Schritte braucht das Programm höchstens?*
- ▶ Manchmal auch Abschätzung nach unten („untere Schranke“)  
*Wie viele Schritte werden mindestens ausgeführt?*
- ▶ „Laufzeit“ für Abschätzung der Anzahl ausgeführter Operationen

## Laufzeitanalyse: Vereinfachung 3

**Abschätzung nur abhängig von Eingabegröße**

- ▶  **$T(n)$ :** Laufzeit bei Eingabe der Grösse  $n$
- ▶ Bei adaptiven Verfahren unterscheiden wir
  - ▶ **Beste Laufzeit (best case)**  
Laufzeit bei günstigstmöglicher Eingabe
  - ▶ **Schlechteste Laufzeit (worst case)**  
Laufzeit bei schlechtestmöglicher Eingabe
  - ▶ **Mittlere Laufzeit (average case)**  
Durchschnitt der Laufzeit über alle Eingaben der Grösse  $n$

## Kostenmodelle

Auch: Analyse mit Kostenmodell

- ▶ Identifiziere grundlegende Operationen der Algorithmenklasse z.B. für vergleichsbasierte Sortierverfahren
  - ▶ Vergleich von Schlüsselpaaren
  - ▶ Tausch zweier Elemente oder Bewegung eines Elementes
- ▶ Schätze Anzahl dieser Operationen ab.

## Beispiel aus C++-Referenz

```
function template
std::sort <algorithm>
default (1) template <class RandomAccessIterator>
void sort (RandomAccessIterator first, RandomAccessIterator last);
custom (2) template <class RandomAccessIterator, class Compare>
void sort (RandomAccessIterator first, RandomAccessIterator last, Compare comp);
```

### Sort elements in range

Sorts the elements in the range [first, last) into ascending order.

The elements are compared using operator< for the first version, and comp for the second.

Equivalent elements are not guaranteed to keep their original relative order (see `stable_sort`).



### Complexity

On average, linearithmic in the distance between first and last: Performs approximately  $N \log_2(N)$  (where  $N$  is this distance) comparisons of elements, and up to that many element swaps (or moves).

<http://www.cplusplus.com/reference/algorithm/sort/>

## A5.2 Beispiel: Selectionsort

## Selectionsort: Algorithmus

```
1 def selection_sort(array):
2     n = len(array)
3     for i in range(n - 1): # i = 0, ..., n-2
4         # find index of minimum element at positions i, ..., n-1
5         min_index = i
6         for j in range(i + 1, n): # j = i+1, ..., n-1
7             if array[j] < array[min_index]:
8                 min_index = j
9         # swap element at position i with minimum element
10        array[i], array[min_index] = array[min_index], array[i]
```

## Selectionsort: Analyse I

Wir zeigen:  $T(n) \leq c' \cdot n^2$  für  $n \geq 1$  und irgendeine Konstante  $c'$

- ▶ Äussere Schleife (3-10) und innere Schleife (6-8)
- ▶ Anzahl Operationen für jede Iteration der äusseren Schleife:
  - ▶ Konstante  $a$  für Anzahl Operationen in Zeilen 7 und 8
  - ▶ Konstante  $b$  für Anzahl Operationen in Zeilen 5 und 10

i	# Operationen
0	$a(n - 1) + b$
1	$a(n - 2) + b$
...	
$n-2$	$a \cdot 1 + b$

- ▶ Insgesamt:  $T(n) = \sum_{i=0}^{n-2} (a(n - (i + 1)) + b)$

## Selectionsort: Analyse II

$$\begin{aligned}
 T(n) &= \sum_{i=0}^{n-2} (a(n - (i + 1)) + b) \\
 &= \sum_{i=1}^{n-1} (a(n - i) + b) \\
 &= a \sum_{i=1}^{n-1} (n - i) + b(n - 1) \\
 &= 0.5a(n - 1)n + b(n - 1) \\
 &\leq 0.5an^2 + b(n - 1) \\
 &\leq 0.5an^2 + b(n - 1)n \\
 &\leq 0.5an^2 + bn^2 \\
 &= 0.5(a + b)n^2
 \end{aligned}$$

⇒ mit  $c' = 0.5(a + b)$  gilt für  $n \geq 1$ , dass  $T(n) \leq c' \cdot n^2$

## Selectionsort: Analyse III

Zu grosszügig abgeschätzt?

Wir zeigen für  $n \geq 2$ :  $T(n) \geq c \cdot n^2$  für irgendeine Konstante  $c$

$$\begin{aligned}
 T(n) &= \dots = 0.5a(n - 1)n + b(n - 1) \\
 &\geq 0.5a(n - 1)n \\
 &\geq 0.25an^2 \quad (n - 1 \geq 0.5n \text{ für } n \geq 2)
 \end{aligned}$$

⇒ mit  $c = 0.25a$  gilt für  $n \geq 2$ , dass  $T(n) \geq c \cdot n^2$

### Theorem

Selectionsort hat **quadratische Laufzeit**, d.h. es gibt Konstanten  $c > 0, c' > 0, n_0 > 0$ , so dass für  $n \geq n_0$ :  $cn^2 \leq T(n) \leq c'n^2$ .

## Selectionsort: Analyse IV

### Quadratische Laufzeit:

doppelt so grosse Eingabe, ca. viermal so lange Laufzeit

Was bedeutet das in der Praxis?

- ▶ Annahme:  $c = 1$ , eine Operation dauert im Schnitt  $10^{-8}$  Sek.
- ▶ Bei 1 Tsd. Elementen warten wir  $10^{-8} \cdot (10^3)^2 = 10^{-8} \cdot 10^6 = 10^{-2} = 0.02$  Sekunden.
- ▶ Bei 10 Tsd. Elementen  $10^{-8} \cdot (10^4)^2 = 1$  Sekunde
- ▶ Bei 100 Tsd. Elementen  $10^{-8} \cdot (10^5)^2 = 100$  Sekunden
- ▶ Bei 1 Mio. Elementen  $10^{-8} \cdot (10^6)^2$  Sekunden = 2.77 Stunden
- ▶ Bei 1 Mrd. Elementen  $10^{-8} \cdot (10^9)^2$  Sekunden = 317 Jahre  
1 Mrd. Zahlen bei 4 Bytes/Zahl sind „nur“ 4 GB.

Quadratische Laufzeit problematisch für grosse Eingaben

## Selectionsort mit Kostenmodell

```

1 def selection_sort(array):
2     n = len(array)
3     for i in range(n - 1): # i = 0, ..., n-2
4         # find index of minimum element at positions i, ..., n-1
5         min_index = i
6         for j in range(i + 1, n): # j = i+1, ..., n-1
7             if array[j] < array[min_index]:
8                 min_index = j
9         # swap element at position i with minimum element
10        array[i], array[min_index] = array[min_index], array[i]

```

- n-1 mal Tausch zweier Elemente („linear“)
- $0.5(n-1)n$  Schlüsselvergleiche („quadratisch“)

## A5.3 Exkurs: Logarithmus

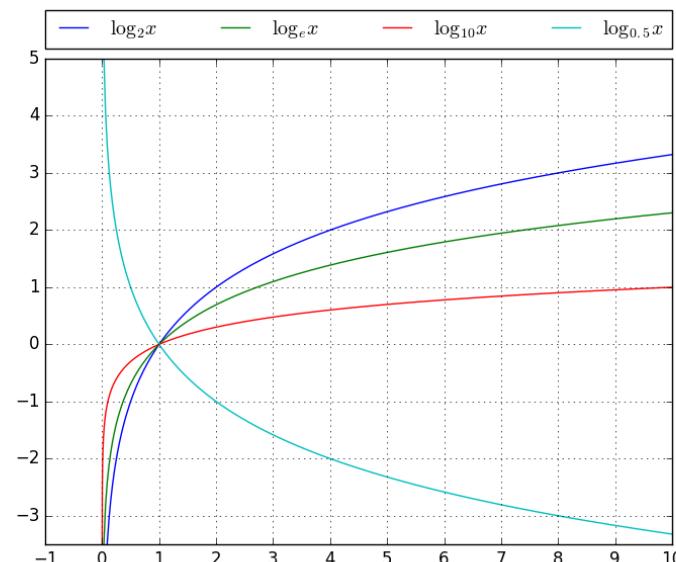
## Logarithmus

- ▶ In der Analyse von Mergesort werden wir eine **Logarithmusfunktion** verwendet.
- ▶ Dies ist bei der Analyse von Laufzeiten oft der Fall.
- ▶ Der Logarithmus zur Basis  $b$  ist invers zur Exponentialfunktion mit Basis  $b$ , also

$$\log_b x = y \text{ gdw. } b^y = x.$$

- ▶ Beispiele:  $\log_2 8 = 3$ , da  $2^3 = 8$   
Beispiele:  $\log_3 81 = 4$ , da  $3^4 = 81$
- ▶  $\log_b a$  intuitiv (wenn das glatt aufgeht):  
„Wie oft muss man  $a$  durch  $b$  teilen bis man bei 1 ist?“

## Logarithmus: Illustration



## Rechenregeln Logarithmus

Die Rechenregeln ergeben sich direkt aus den Regeln  
 $(a^x)^y = a^{xy} = (a^y)^x$  und  $a^x a^y = a^{x+y}$ :

Produktregel	$\log_b(xy) = \log_b x + \log_b y$
Potenzrechnung	$\log_b(x^r) = r \log_b x$
Basisumrechnung	$\log_b x = \log_a x / \log_a b$
Summenregel	$\log_b(x + y) = \log_b x + \log_b(1 + y/x)$

## Logarithmus: Beispielrechnung

Bei der Algorithmenanalyse begegnet man öfters Ausdrücken der Form  $a^{\log_b x}$ . Wie bekommt man da den Logarithmus aus dem Exponenten?

Beispiel:  $5^{\log_2 x}$

Wir verwenden  $5 = 2^{\log_2 5}$ .

$$\begin{aligned} 5^{\log_2 x} &= (2^{\log_2 5})^{\log_2 x} \\ &= 2^{\log_2 5 \log_2 x} \\ &= 2^{\log_2 x \log_2 5} \\ &= (2^{\log_2 x})^{\log_2 5} \\ &= x^{\log_2 5} \\ &\approx x^{2.32} \end{aligned}$$

## A5.4 Beispiel: Mergesort

## Merge-Schritt

---

```

1 def merge(array, tmp, lo, mid, hi):
2     i = lo
3     j = mid + 1
4     for k in range(lo, hi + 1): # k = lo, ..., hi
5         if j > hi or (i <= mid and array[i] <= array[j]):
6             tmp[k] = array[i]
7             i += 1
8         else:
9             tmp[k] = array[j]
10            j += 1
11     for k in range(lo, hi + 1): # k = lo, ..., hi
12         array[k] = tmp[k]

```

---

Wir analysieren Laufzeit für  $m := hi - lo + 1$

## Merge-Schritt: Analyse

$$\begin{aligned} T(m) &= c_1 + c_2 m + c_3 m \\ &\geq (c_2 + c_3)m \end{aligned}$$

Für  $m \geq 1$ :

$$\begin{aligned} T(m) &= c_1 + c_2 m + c_3 m \\ &\leq c_1 m + c_2 m + c_3 m \\ &= (c_1 + c_2 + c_3)m \end{aligned}$$

### Theorem

Der Merge-Schritt hat **lineare Laufzeit**, d.h. es gibt Konstanten  $c, c', n_0 > 0$ , so dass für alle  $n \geq n_0$ :  $cn \leq T(n) \leq c'n$ .

## Bottom-Up-Mergesort: Analyse I

Annahme:  $n = 2^k$  für ein  $k \in \mathbb{N}_{>0}$

Iterationen der äusseren Schleife ( $m$  für hi-lo+1):

- ▶ Iteration 1:  $n/2$  mal innere Schleife mit Merge für  $m = 2$   
 $c_2 + n/2(c_3 + 2c_4) = c_2 + 0.5c_3n + c_4n$
- ▶ Iteration 2:  $n/4$  mal innere Schleife mit Merge für  $m = 4$   
 $c_2 + n/4(c_3 + 4c_4) = c_2 + 0.25c_3n + c_4n$
- ▶ ...
- ▶ Äussere Schleife endet nach letzter Iteration  $\ell$ .
- ▶ Iteration  $\ell$ : 1 mal innere Schleife mit Merge für  $m = n$   
 $c_2 + n/n(c_3 + nc_4) = c_2 + c_3 + c_4n$

Insgesamt  $T(n) \leq c_1 + \ell(c_2 + c_3n + c_4n) \leq \ell(c_1 + c_2 + c_3 + c_4)n$

## Bottom-Up-Mergesort

```

1 def sort(array):
2     n = len(array)
3     tmp = list(array)
4     length = 1
5     while length < n:
6         lo = 0
7         while lo < n - length:
8             mid = lo + length - 1
9             hi = min(lo + 2 * length - 1, n - 1)
10            merge(array, tmp, lo, mid, hi)
11            lo += 2 * length
12            length *= 2

```

Wir verwenden für die Abschätzung:

- ▶ Zeilen 2–4
- ▶ Zeilen 6 und 12
- ▶ Zeilen 8,9,11

Annahme: merge benötigt  $c_4(\text{hi-lo}+1)$  Operationen.

## Bottom-Up-Mergesort: Analyse II

Wie gross ist  $\ell$ ?

- ▶ In Iteration  $i$  ist für den Merge-Schritt  $m = 2^i$
- ▶ In Iteration  $\ell$  hat Merge-Schritt  $m = 2^\ell = n$
- ▶ Da  $n = 2^k$  ist  $\ell = k = \log_2 n$ .

Mit  $c := c_1 + c_2 + c_3 + c_4$  erhalten wir  $T(n) \leq cn \log_2 n$ .

## Bottom-Up-Mergesort: Analyse III

Was, wenn  $n$  keine Zweierpotenz, also  $2^{k-1} < n < 2^k$ ?

- ▶ Trotzdem  $k$  Iterationen der äusseren Schleife.
- ▶ Innere Schleife verwendet nicht mehr Operationen.
- ▶  $T(n) \leq cnk = cn(\lfloor \log_2 n \rfloor + 1) \leq 2cn\log_2 n$  (für  $k > 2$ )

## Bottom-Up-Mergesort: Analyse IV

Ähnliche Abschätzung auch für untere Schranke möglich.

→ Übung

### Theorem

*Bottom-Up-Mergesort hat leicht überlineare Laufzeit, d.h. es gibt Konstanten  $c, c', n_0 > 0$ , so dass für alle  $n \geq n_0$  gilt  $cn\log_2 n \leq T(n) \leq c'n\log_2 n$ .*

## Leicht überlineare Laufzeit

**Leicht überlineare Laufzeit  $n \log_2 n$ :**

→ doppelt so grosse Eingabe, etwas mehr als doppelt so lange Laufzeit

Was bedeutet das in der Praxis?

- ▶ Annahme:  $c = 1$ , eine Operation dauert im Schnitt  $10^{-8}$  Sek.
- ▶ Bei 1 Tsd. Elementen warten wir  $10^{-8} \cdot 10^3 \log_2(10^3) \approx 0.0001$  Sekunden.
- ▶ Bei 10 Tsd. Elementen  $\approx 0.0013$  Sekunden
- ▶ Bei 100 Tsd. Elementen  $\approx 0.017$  Sekunden
- ▶ Bei 1 Mio. Elementen  $\approx 0.2$  Sekunden
- ▶ Bei 1 Mrd. Elementen  $\approx 299$  Sekunden

**Laufzeit  $n \log_2 n$  nicht viel schlechter als lineare Laufzeit**

## Mergesort mit Kostenmodell I

### Schlüsselvergleiche

- ▶ Werden nur in `merge` durchgeführt.
- ▶ Mergen zweier Teilfolgen der Länge  $m$  und  $n$  benötigt bestenfalls  $\min(m, n)$  und schlimmstenfalls  $n + m - 1$  Vergleiche.
- ▶ Bei zwei etwa gleich langen Teilfolgen sind das **linear** viele Vergleiche, d.h. es gibt  $c, c' > 0$ , so dass Anzahl Vergleiche zwischen  $cn$  und  $c'n$  liegt.
- Anzahl der zum Sortieren einer Sequenz notwendigen Schlüsselvergleiche ist **leicht überlinear** in der Länge der Sequenz (analog zu Laufzeitanalyse).

## Mergesort mit Kostenmodell II

### Elementbewegungen

- ▶ Werden nur in `merge` durchgeführt.
- ▶  $2n$  Bewegungen für Sequenz der Länge  $n$ .
- ▶ Insgesamt für Mergesort **leicht überlinear** (analog zu Schlüsselvergleichen)

## A5.5 Zusammenfassung

## Zusammenfassung

- ▶ Bei der Laufzeitanalyse **schätzen** wir die **Anzahl der ausgeführten Operationen** ab.
  - ▶ Wir zählen nicht exakt.
  - ▶ Wir ignorieren, wie lange eine Operation tatsächlich dauert.
  - ▶ Hauptsache: Laufzeit ungefähr proportional zu Anzahl Operationen.
- ▶ **Selectionsort** hat **quadratische Laufzeit** und benötigt linear viele Vertauschungen und quadratisch viele Schlüsselvergleiche.
- ▶ **Mergesort** hat **leicht überlineare Laufzeit**, **Schlüsselvergleiche** und **Elementbewegungen**.