

Algorithmen und Datenstrukturen (ESE)  
Entwurf, Analyse und Umsetzung von  
Algorithmen (IEMS)  
WS 2014 / 2015

Vorlesung 2, Donnerstag 30. Oktober 2014  
(Laufzeitanalyse MinSort / HeapSort, Induktion)

Junior-Prof. Dr. Olaf Ronneberger  
Image Analysis Lab  
Institut für Informatik  
Universität Freiburg

# Überblick über die Vorlesung heute

---

## ■ Organisatorisches

- Rückmeldungen zur Ü1 (HeapSort + Programmieren)

## ■ Laufzeitanalyse

- MinSort ... "quadratische" Laufzeit
- HeapSort ... besser, aber trotzdem nicht ganz "linear"
- Tiefe eines Baumes
- Vollständige Induktion
- Rechnen mit dem Logarithmus

# Rückmeldungen


---

## ■ Übung

- einfacher Einstieg, keine wesentlichen Probleme, hat Spaß gemacht
- Einrichtung Entwicklungsumgebung, etc. hat z.T. sehr viel Zeit gekostet (vor allem unter Windows)
- Zeitbedarf sehr unterschiedlich (30 Minuten bis kompletter Tag), meistens im Rahmen der 4 vorgesehenen Stunden
- Code „gegoogelt“, „Wikipedia“, „Musterlösung vom letzten Jahr“? **(nicht Sinn der Sache!)**

## ■ Vorlesung

- interessant, gut verständlich
- etwas langsamer sprechen
- Vorlesungs-PDF mit 1 Folie pro Blatt



- Wie lange läuft unser Programm?
  - In der letzten Vorlesung hatten wir dazu ein Schaubild
  - **Beobachtung:** es wird "unproportional" langsamer, je mehr Zahlen sortiert werden
  - Wie können wir präziser fassen, was da passiert?

- Wie analysieren wir die Laufzeit?
  - Idealerweise hätten wir gerne eine Formel, die uns für eine bestimmte Eingabe sagt, wie lange das Programm dann läuft
  - **Problem:** Laufzeit hängt auch noch von vielen anderen Umständen ab, insbesondere
    - auf was für einem Rechner wir den Code ausführen
    - was sonst gerade noch auf dem Rechner läuft
    - welchen Compiler wir benutzt haben
    - und natürlich von der Mondphase
  - **Abstraktion 1:** Deshalb analysieren wir nicht die Laufzeit, sondern die Anzahl der (Grund-)Operationen

# Grundoperationen

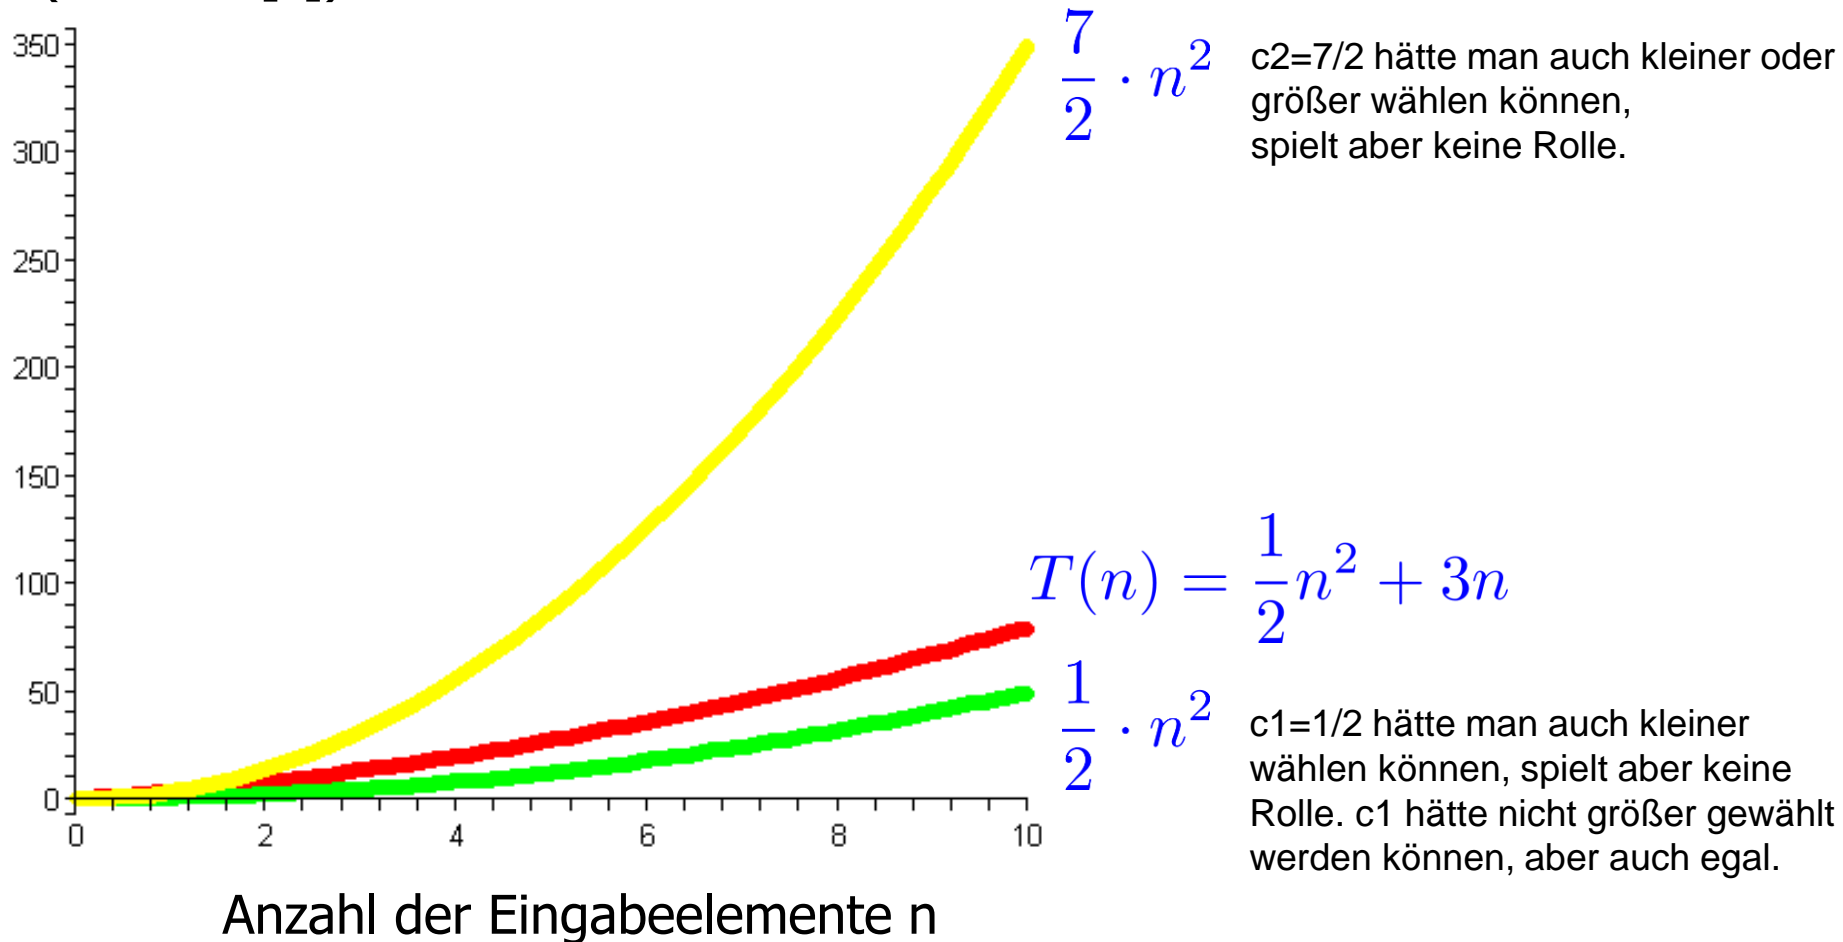
---

- Unvollständige Liste von Grundoperationen
  - Eine arithmetische Operation, z.B.  $a + b$
  - Variablenzuweisung, z.B.  $x = y$
  - Funktionsaufruf, z.B. `Sorter.minSort(array)`
    - das meint natürlich nur das Springen zu der Funktion
  - **Intuitiv:** eine Zeile Code
  - **Genauer wäre:** eine Zeile Maschinencode
  - **Noch genauer wäre:** ein Prozessorzyklus
  - Wir sehen später noch, dass es nicht so wichtig ist, wie genau wir die Grundoperationen definieren
    - Wichtig ist nur, dass die tatsächliche Laufzeit ungefähr **proportional** zur Anzahl Operationen ist

- Wieviele Operationen braucht MinSort?
  - **Abstraktion 2:** Wir zählen die Operationen nicht genau, sondern berechnen obere (und selten auch untere) Schranken  
Grund: das erleichtert die Sache und wir haben ja eh abstrahiert von exakter Laufzeit zu Anzahl Operationen
  - Sei  $n$  die Größe der Eingabe (= des Eingabearrays)
  - **Beobachtung:** Die Anzahl Operationen hängt nur von  $n$  ab, nicht davon, welche  $n$  Zahlen das sind ... das ist häufig so!
  - Sei  $T(n)$  die Anzahl der Operationen bei Eingabegröße  $n$
  - **Behauptung:** Es gilt  $C_1 \cdot n^2 \leq T(n) \leq C_2 \cdot n^2$   
wobei  $C_1$  und  $C_2$  irgendwelche Konstanten sind
  - Das nennt man "quadratische Laufzeit" (wegen dem  $n^2$ )

# Beispiel quadratische Laufzeit

Zahl der Schritte  
(Laufzeit [s])






# MinSort — Laufzeit 4/7

## ■ Analyse der Anzahl der Operationen:

Sei  $n$  die Anzahl der zu sortierenden Elemente und  $T_i$  die Anzahl der Operationen in Runde  $i$ , dann ist



Beispiel: In Runde 4 müssen wir  $n-3$  Elemente durchsuchen, um das Minimum zu finden

$$T_1 \leq C'_2 \cdot n$$

$$T_2 \leq C'_2 \cdot (n - 1)$$

$$T_3 \leq C'_2 \cdot (n - 2)$$

$$T_4 \leq C'_2 \cdot (n - 3)$$

$\vdots$

$$T_{n-1} \leq C'_2 \cdot 2$$

$$T_n \leq C'_2 \cdot 1$$

$$T(n) = T_1 + T_2 + \dots + T_n \leq \sum_{i=1}^n C'_2 \cdot i$$

# MinSort — Laufzeit 5/7

## ■ Alternativ: Analyse des Codes:

```
public static void minSort(int[] array) {  
    int n = array.length;  
    for (int i = 0; i < n - 1; i++) {  
        int min = array[i];  
        int minIndex = i;  
        for (int j = i + 1; j < n; j++) {  
            if (array[j] < min) {  
                min = array[j];  
                minIndex = j;  
            }  
        }  
        int tmp = array[i];  
        array[i] = array[minIndex];  
        array[minIndex] = tmp;  
    }  
}
```

Diagramm zur Laufzeitanalyse des Codes:

- Das innere `for`-Schleifenpaar (mit `j`) ist als **konst. Laufzeit** markiert.
- Das gesamte innere `for`-Schleifenpaar (mit `j`) wird **n-i-1 mal** wiederholt.
- Das gesamte äußere `for`-Schleifenpaar (mit `i`) wird **n-1 mal** wiederholt.

$$T(n) \leq \sum_{i=0}^{n-2} \sum_{j=i+1}^{n-1} C'_2 = \sum_{i=0}^{n-2} (n-i-1) \cdot C'_2 = \sum_{i=1}^{n-1} (n-i) \cdot C'_2 \leq \sum_{i=1}^n C'_2 \cdot i$$

- Beweis der Behauptung  $T(n) \leq C_2 \cdot n^2$

$$T(n) \leq \sum_{i=1}^n C'_2 \cdot i$$

$$= C'_2 \cdot \sum_{i=1}^n i$$

Wie weiter vereinfachen?

$$= C'_2 \cdot \frac{n(n+1)}{2}$$

Gaußsche Summenformel

$$\leq C'_2 \cdot \frac{n(n+n)}{2}$$

$1 \leq n$

$$= C'_2 \cdot \frac{2n^2}{2}$$

$$= C'_2 \cdot n^2$$

# MinSort — Laufzeit 7/7

## ■ Beweis der Behauptung $C_1 \cdot n^2 \leq T(n)$

- Analog zur oberen Schranke können wir auch für die untere Schranke zeigen, dass es ein  $C_1'$  gibt, für das gilt:

$$T(n) \geq \sum_{i=1}^{n-1} (n-i) \cdot C_1' = \sum_{i=1}^{n-1} C_1' \cdot i$$

$$T(n) \geq C_1' \cdot \frac{(n-1) \cdot n}{2} \quad \text{Wie kommen wir hier auf } n^2 ?$$

$$> C_1' \cdot \frac{n \cdot n}{2 \cdot 2} \quad \left. \begin{array}{l} \curvearrowright \\ \end{array} \right\} n-1 > \frac{n}{2} \text{ für } n > 2$$

$$= \frac{C_1'}{4} \cdot n^2$$

Alles zusammen:  $\frac{C_1'}{4} \cdot n^2 \leq T(n) \leq C_2' \cdot n^2$

Quadratische Laufzeit bewiesen:  $C_1 \cdot n^2 \leq T(n) \leq C_2 \cdot n^2$  12

# Quadratische Laufzeit in der Praxis

## ■ Definition

- Die Laufzeit  $T$  hängt von der Eingabegröße  $n$  ab
- Es gibt Konstanten  $C_1$  und  $C_2$  mit  $C_1 \cdot n^2 \leq T(n) \leq C_2 \cdot n^2$

## ■ Betrachtungen dazu

- Doppelt so große Eingabe  $\rightarrow$  viermal so große Laufzeit
- Unabhängig von den Konstanten wird das schnell sehr teuer

- $C = 1 \text{ ns}$  (1 einfache Anweisung  $\approx$  1 Nanosekunde)
- $n = 10^6$  (1 Millionen Zahlen = 4 MB) [bei 4 Bytes/Zahl]
  - $C \cdot n^2 = 10^{-9} \cdot 10^{12} = 10^3 \text{ s} = 16.7 \text{ Minuten}$
- $n = 10^9$  (1 Milliarde Zahlen = 4 GB)
  - $C \cdot n^2 = 10^{-9} \cdot 10^{18} = 10^9 \text{ s} = 31.7 \text{ Jahre}$

$$C_2 \cdot (2 \cdot n)^2 = C_2 \cdot 4 \cdot n^2$$


**Quadr. Laufzeit = "große" Probleme unlösbar**

## ■ Intuitiv

- Zur Bestimmung des Minimums musste man bei **MinSort** in jeder Runde die ganzen übrigen Elemente durchgehen
- Bei **HeapSort** ist es einfach immer die Wurzel vom **Heap**
- Um den **Heap** zu reparieren, müssen wir aber nur einen Teil des Baumes durchgehen, nicht alle Element darin

## ■ Formal

- Sei  $T(n)$  die Laufzeit von HeapSort für  $n$  Elemente
- Auf den nächsten Folien zeigen wir  $T(n) \leq C \cdot n \cdot \log_2 n$



## ■ Tiefe eines Baumes:

- Die Tiefe  $d$  eines Baumes ist definiert als die maximale Anzahl Knoten auf einem Pfad Wurzel  $\rightarrow$  Blatt
- Ein vollst. binärer Baum der Tiefe  $d$  hat  $n = 2^d - 1$  Knoten
- Das wollen wir auf den nächsten Folien beweisen
- Im Beispiel hier:

$$d = 4 \quad \Rightarrow \quad n = 2^4 - 1 = 15$$

# Einschub: Induktionsbeweis

---


## ■ Prinzip

- Man möchte beweisen, dass eine Aussage für alle natürlichen Zahlen gilt, also:  $A(n)$  gilt für alle  $n \in \mathbb{N}$
- Dann hat ein Induktionsbeweis zwei Schritte
- Wir zeigen, dass  $A(1)$  gilt (Induktionsanfang)
- Wir nehmen an, dass  $A(1), \dots, A(n-1)$  gelten, für  $n > 1$ , und zeigen, dass dann auch  $A(n)$  gilt (Induktionsschritt)
- Wenn wir die beiden Sachen gezeigt haben, haben wir nach dem Prinzip der **vollständigen Induktion** gezeigt, dass  $A(n)$  für alle natürlichen Zahlen  $n$  gilt



# Beweis durch vollständige Induktion

**Behauptung:** Ein vollständiger Binärbaum der Tiefe  $d$  hat  $n(d) = 2^d - 1$  Knoten




- **Induktionsanfang:** Formel gilt für  $d=1$



$$n(1) = 2^1 - 1 = 1 \quad \text{Stimmt!}$$

# Beweis durch vollständige Induktion

- **Induktionsschritt:** Wenn die Formel für  $\{1, \dots, d-1\}$  gilt, dann gilt sie auch für  $d$



Ein vollst. Binärbaum der Tiefe  $d$  besteht aus 2 vollst. Binärbäumen der Tiefe  $d-1$  und einem zusätzlichen Knoten

$$n(d) = 1 + 2 \cdot n(d-1)$$

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


$$2^d - 1 = 1 + 2 \cdot 2^{d-1} - 2$$

$$2^d - 1 = 2^d - 1$$

Behauptung einsetzen

Stimmt! Per vollständiger Induktion folgt, dass  $n(d) = 2^d - 1$  für alle  $d \in \mathbb{N}$  gilt.

# HeapSort — Laufzeit 3/6



Allgemein: Tiefe  $d \rightarrow 2^{d-1}$  Knoten

## ■ Laufzeit von dem **heapify** am Anfang: Sei $d$ die Tiefe des Heaps

- in Tiefe  $d$  gibt es  $2^{d-1}$  (oder weniger) Knoten aber keine Kosten
- in Tiefe  $d - 1$  gibt es  $2^{d-2}$  Knoten. An jedem Knoten Kosten für Durchsickern auf einem Pfad der Länge  $1$ , also Kosten  $\leq C \leq C \cdot 2$   
( $2$  statt  $1$ , um nachher eine Standardformel zu benutzen)
- Tiefe  $d - 1$ ;  $2^{d-2}$  Knoten; Pfadlänge  $1$ ; Kosten pro Knoten  $\leq C \cdot 2$
- Tiefe  $d - 2$ ;  $2^{d-3}$  Knoten; Pfadlänge  $2$ ; Kosten pro Knoten  $\leq C \cdot 3$
- Tiefe  $d - 3$ ;  $2^{d-4}$  Knoten; Pfadlänge  $3$ ; Kosten pro Knoten  $\leq C \cdot 4$
- usw.

– Gesamtkosten: 
$$T(d) \leq \sum_{i=2}^d C \cdot i \cdot 2^{d-i} \leq \sum_{i=1}^d C \cdot i \cdot 2^{d-1}$$

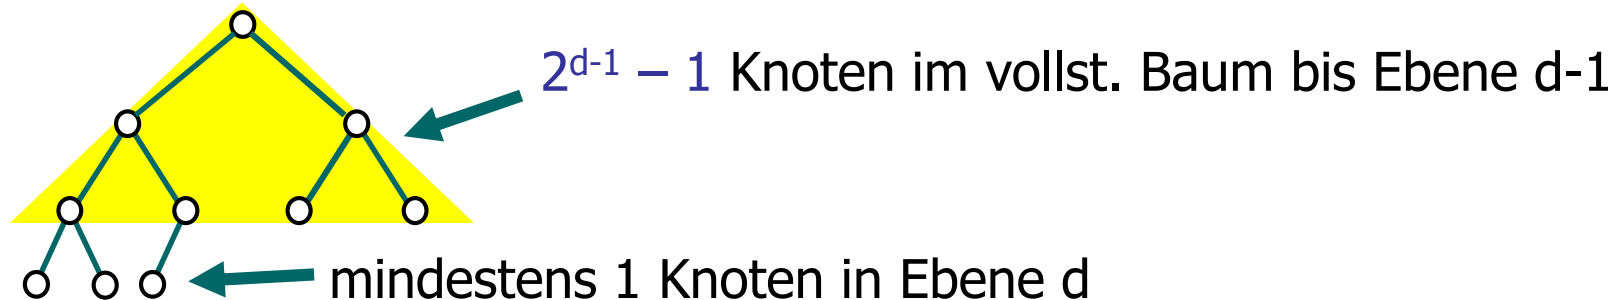
## ■ Laufzeit von dem **heapify** am Anfang (Forts.)

– Es gilt  $\sum_{i=1}^d i \cdot 2^{d-i} \leq 2^{d+1}$  (siehe nächste Folie)

– Also sind die Kosten für heapify:  $T(d) \leq C \cdot 2^{d+1}$

– Wir wollen die Kosten aber in Abhängigkeit von  $n$

– Ein Binärbaum der Tiefe  $d$  hat  $n \geq 2^{d-1}$  Knoten ...warum?



– (Gleichung mal 4)  $\rightarrow 4 \cdot n \geq 2^{d+1}$ , also Kosten für heapify:

$$T(n) \leq C \cdot 4 \cdot n$$

# Induktionsbeweis

Wir wollen beweisen:  $\sum_{i=1}^d i \cdot 2^{d-i} \leq 2^{d+1}$

$$A(d) \leq B(d)$$

Die linke Seite nennen wir  $A(d)$ , die rechte Seite  $B(d)$

**Induktionsanfang** ( $d=1$ ):  $A(1) \leq B(1)$

$$\sum_{i=1}^1 i \cdot 2^{1-i} \leq 2^{1+1}$$

$$2^0 \leq 2^2 \quad \square$$

# Induktionsbeweis $\sum_{i=1}^d i \cdot 2^{d-i} \leq 2^{d+1}$

**Induktionsschritt:** wir wollen zeigen: Wenn die Behauptung für  $\{1, \dots, d\}$  gilt, dann gilt sie auch für  $d+1$

$$A(d) \leq B(d) \quad \Rightarrow \quad A(d+1) \leq B(d+1)$$

Rechte Formel ausschreiben  
und versuchen,  $A(d)$  und  
 $B(d)$  herauszuziehen:

$$\sum_{i=1}^{d+1} i \cdot 2^{d+1-i} \leq 2^{d+1+1}$$

$$\sum_{i=1}^{d+1} i \cdot 2 \cdot 2^{d-i} \leq 2 \cdot 2^{d+1}$$

$$2 \cdot \sum_{i=1}^{d+1} i \cdot 2^{d-i} \leq 2 \cdot B(d)$$

$$2 \cdot \sum_{i=1}^d i \cdot 2^{d-i} + 2 \cdot (d+1) \cdot 2^{d-(d+1)} \leq 2 \cdot B(d)$$

$$2 \cdot A(d) + d + 1 \leq 2 \cdot B(d)$$

Geht so nicht! Mist!

Die Behauptung stimmt aber trotzdem! <sup>22</sup>


# Induktionsbeweis $\sum_{i=1}^d i \cdot 2^{d-i} \leq 2^{d+1}$

- **Funktionierender Beweis:** Wir zeigen eine etwas stärkere Behauptung!

$$\sum_{i=1}^d i \cdot 2^{d-i} \leq 2^{d+1} - d - 2 \leq 2^{d+1}$$

**Vorteil:** dann hat man auch eine stärkere Induktionsvoraussetzung

→ Übungsaufgabe



## ■ Laufzeit für den Rest

- $n$  mal Maximum herausnehmen: jeweils konstante Kosten
- $n$  mal Heap reparieren („Durchsickern“): jeweils maximal  $d$  Schritte
- Die Tiefe des Heaps am Anfang ist  $d \leq 1 + \log_2 n$  ...warum?
- $\rightarrow$  Aus  $n \geq 2^{d-1} \rightarrow \log_2 n \geq d - 1 \rightarrow d \leq 1 + \log_2 n$
- Die Tiefe wird im Laufe der Zeit höchstens weniger
- Also  $T(n) \leq C \cdot n \cdot (1 + \log_2 n)$  Operationen
- Das Plus ist hässlich, also:  $T(n) \leq C \cdot n \cdot 2 \cdot \log_2 n$  (gilt ab  $n > 2$ )



## ■ Gesamtlaufzeit

- Laufzeit heapify:  $T(n) \leq 4 \cdot C \cdot n$
- Laufzeit Rest:  $T(n) \leq 2 \cdot C \cdot n \cdot \log_2 n$
- Gesamtlaufzeit hätte wieder ein hässliches Plus, also erweitern wir die Schranke bei heapify noch etwas:  
 $T(n) \leq 4 \cdot C \cdot n \leq 4 \cdot C \cdot n \cdot \log_2 n$
- ... Und erhalten insgesamt:  
 $T(n) \leq 6C \cdot n \cdot \log_2 n$
- Für die untere Schranke gilt das auch (Beweis heute nicht), also:  
 $C_1 \cdot n \cdot \log_2 n \leq T(n) \leq C_2 \cdot n \cdot \log_2 n$   
für irgendwelche Konstanten  $C_1$  und  $C_2$  und  $n \geq 2$

# Einschub: Basis des Logarithmus

---

- Logarithmen zu verschiedenen Basen
  - Es gilt  $\log_b n = \log_2 n / \log_2 b$
  - Das heißt, für zwei verschiedene Basen  $b$  und  $c$  unterscheiden sich  $\log_b n$  und  $\log_c n$  nur durch einen konstanten Faktor nämlich  $\log_b c$  bzw.  $\log_c b$
  - Zum Beispiel  $\log_2 10 = 3.321928\dots$

# Laufzeit proportional zu $n \cdot \log n$ in der Praxis

---

- Schauen wir uns wieder Zahlenbeispiele an
  - Nehmen wir also an, es gibt Konstanten  $C_1$  und  $C_2$  mit
$$C_1 \cdot n \cdot \log_2 n \leq T(n) \leq C_2 \cdot n \cdot \log_2 n \quad \text{für } n \geq 2$$
  - Dann dauert es bei doppelt so großer Eingabe nur geringfügig mehr als doppelt so lange
  - $C = 1 \text{ ns}$  (1 einfache Anweisung  $\approx$  1 Nanosekunde)
  - $n = 2^{20}$  ( $\approx$  1 Millionen Zahlen = 4 MB) [bei 4 Bytes/Zahl]
    - $C \cdot n \cdot \log_2 n = 10^{-9} \cdot 2^{20} \cdot 20 \text{ s} = 21 \text{ Millisekunden}$
  - $n = 2^{30}$  ( $\approx$  1 Milliarde Zahlen = 4 GB)
    - $C \cdot n \cdot \log_2 n = 10^{-9} \cdot 2^{30} \cdot 30 \text{ s} = 32 \text{ Sekunden}$

**Laufzeit  $n \cdot \log n$  ist also fast so gut wie linear!**

# Literatur / Links

---

- Analyse von HeapSort

  - In Mehlhorn/Sanders: 5. Sorting and Selection

  - In Cormen/Leiserson/Rivest: II.7.1 HeapSort

  - Wikipedia Artikel zu [MinSort](#) und [HeapSort](#)

- Vollständige Induktion

  - [http://de.wikipedia.org/wiki/Vollständige\\_Induktion](http://de.wikipedia.org/wiki/Vollständige_Induktion)

# Neues Übungsblatt:

---

- Diesmal 2 einfache Beweise und eine Programmieraufgabe