

Informatik II - SS 2014

(Algorithmen & Datenstrukturen)

Vorlesung 3 (6.5.2014)

O-Notation, Asymptotische Analyse,
Sortieren III

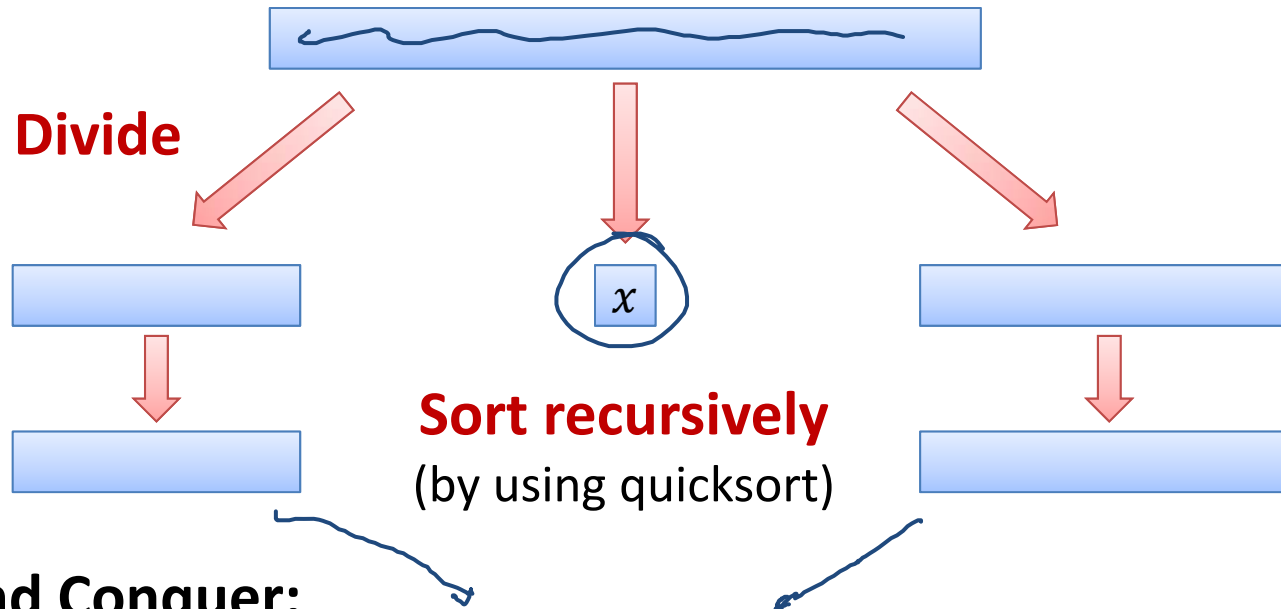
Fabian Kuhn
Algorithmen und Komplexität



**UNI
FREIBURG**

Divide and Conquer

Übersicht QuickSort:




Divide and Conquer:

- Verbreitetes Prinzip für den Algorithmenentwurf
1. Teile Eingabe in 2 oder mehrere kleinere Teilprobleme
 2. Löse die Teilprobleme rekursiv
 3. Kombiniere die Teillösungen zur Gesamtlösung

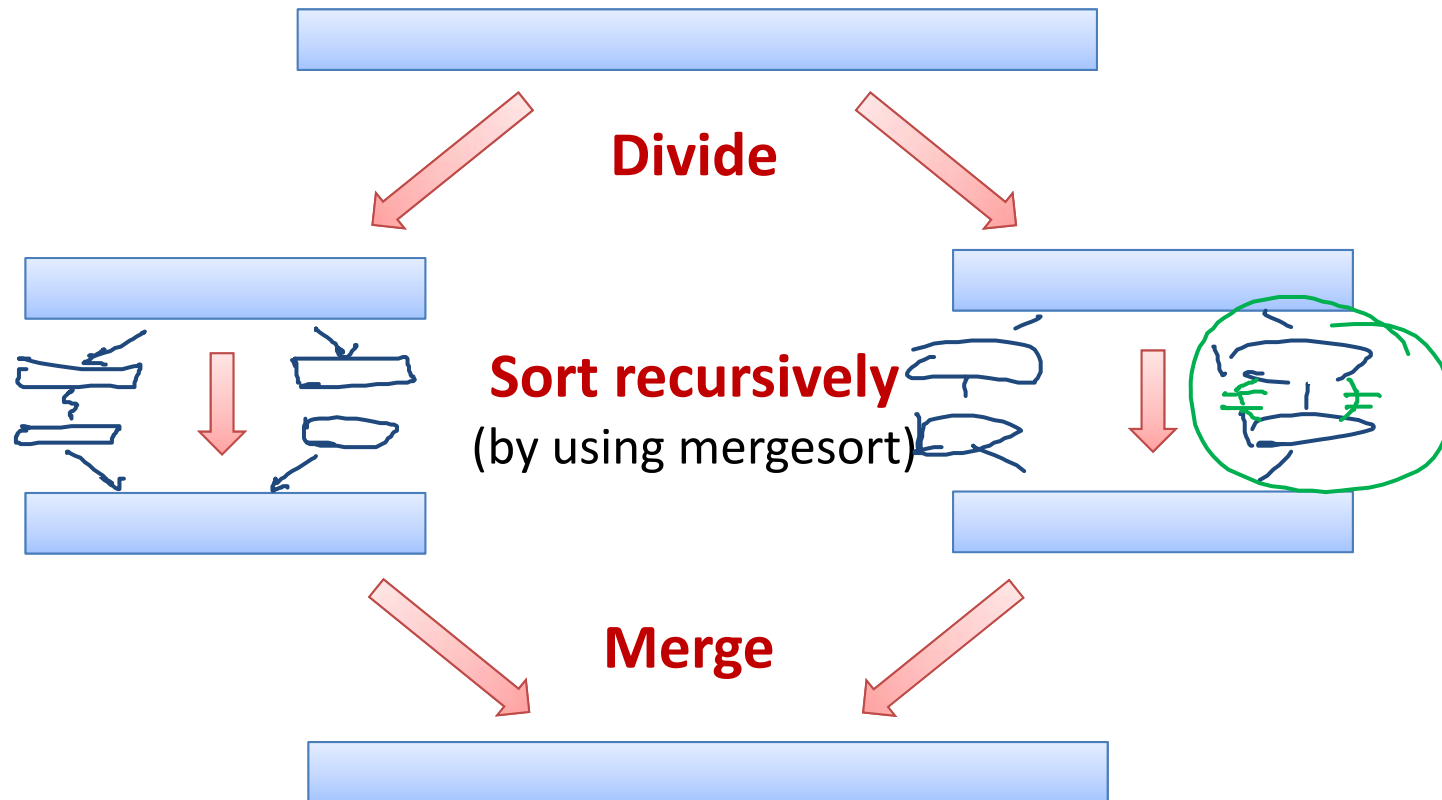
MergeSort

- Ein weiterer Sortieralgorithmus, welcher auf dem Divide-and-Conquer Prinzip basiert

Beispiel: $A = [15, 17, 3, 22, 27, 49, 9, 23, 18, 6, 1, 31]$




Übersicht MergeSort



- Divide ist bei MergeSort trivial
- Merge (kombinieren der Lösungen) benötigt dafür Arbeit...





MergeSort: Merge-Schritt



Verschmelzen (merge) von zwei sortierten Arrays:

- Gegeben: sortierte Arrays A und B der Länge n und m
- Ausgabe: sortiertes Array C mit den Elementen von A und B

Vorgehen:



MergeSort: Pseudocode

Eingabe: Array A der Grösse n

$$\text{start} + \left\lfloor \frac{\text{end} - \text{start}}{2} \right\rfloor$$

MergeSort(A):

1: allocate array tmp to store intermediate results

2: MergeSortRecursive(A, 0, n, tmp)

MergeSortRecursive(A, start, end, tmp)

// sort A[start..end-1]

1: if (end - start > 1) then

2: middle = start + (end - start) / 2

// int. division

3: MergeSortRecursive(A, start, middle, tmp)

4: MergeSortRecursive(A, middle, end, tmp)

5: pos = start; i = start; j = middle

6: while (pos < end) do

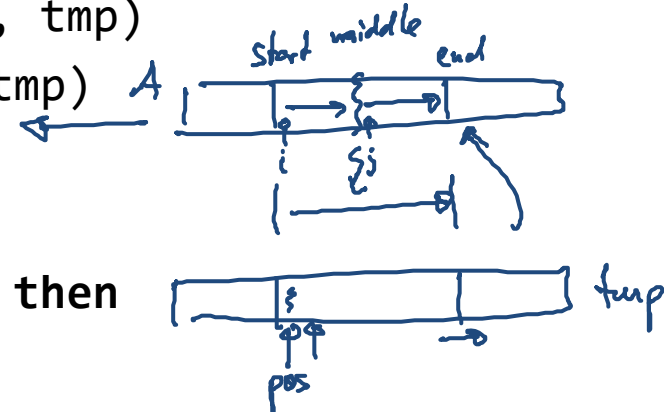
7: if (i < middle) and (A[i] < A[j]) then

8: tmp[pos] = A[i]; pos++; i++


9: else

10: tmp[pos] = A[j]; pos++; j++


11: for i = start to end-1 do A[i] = tmp[i]




Zeitmessung SelectionSort



Zeitmessung SelectionSort



Zeitmessung SelectionSort



- Wie können wir die Laufzeit des Algorithmus analysieren?
 - Ist auf jedem Computer unterschiedlich...
 - Hängt vom Compiler, Programmiersprache, etc. ab
- Wir benötigen ein **abstraktes Mass**, um die Laufzeit zu messen
- **Idee: Zähle Anzahl (Grund-)Operationen**
 - anstatt direkt die Zeit zu messen
 - ist unabhängig von Computer, Compiler
 - ein gutes Mass für die Laufzeit, falls alle Grundoperationen etwa gleich lange brauchen

Was ist eine Grundoperation?

- Einfache arithmetische Operationen *(auf Integers)*
 - +, -, *, /, % (mod), ...
- Ein Speicherzugriff
 - Variable auslesen, Variablenzuweisung
 - Ist das wirklich eine Grundoperation?
- Ein Funktionsaufruf
 - Natürlich nur, das Springen in die Funktion
- **Intuitiv:** eine Zeile Programmcode
- **Besser:** eine Zeile Maschinencode
- **Noch besser (?):** ein Prozessorzyklus
- **Wir werden sehen:** Es ist nur wichtig, dass die Anzahl Grundoperation ungefähr proportional zur Laufzeit ist.

$$x = 7$$
$$y = 2 \cdot x$$



RAM = Random Access Machine

- **Standardmodell**(e), um Algorithmen zu analysieren!
- **Grundoperationen** (wie “definiert”) benötigen alle **eine Zeiteinheit**
- Insbesondere sind alle Speicherzugriffe gleich teuer:

Jede Speicherzelle (1 Maschinenwort) kann in 1 Zeiteinheit gelesen, bzw. beschrieben werden

- ignoriert insbesondere Speicherhierarchien
 - Ist aber in den meisten Fällen eine vernünftige Annahme
- Alternative abstrakte Modelle existieren:
 - um Speicherhierarchien explizit abzubilden
 - bei riesigen Datenmengen (vgl. «Buzzword» Big Data)
 - z.B.: Streaming-Modelle: Speicher muss sequentiell gelesen werden
 - für verteilte/parallele Architekturen
 - Speicherzugriff kann lokal oder über’s Netzwerk sein...

Bisher: Anzahl Grundoperationen ist proportional zur Laufzeit

- Das können wir auch erreichen, ohne die Anzahl Grundoperationen genau zu zählen!

Vereinfachung 1: Wir berechnen nur eine obere Schranke (bzw. eine untere Schranke) an die Anzahl Grundoperationen

- So, dass die ob/untere Schranke immer noch proportional ist...
- Anz. Grundop. kann von div. Eigenschaften der Eingabe abhängen
 - Länge der Eingabe, aber auch z.B. bei Sortieren: zufällig, vorsortiert, ...

Vereinfachung 2: Wichtigster Parameter ist Grösse der Eingabe n
Wir betrachten daher die **Laufzeit $T(n)$ als Funktion von n** .

- Und ignorieren weitere Eigenschaften der Eingabe

Selection Sort: Analyse

SelectionSort(A):

```
1: for i=0 to n-2 do
2:   minIdx = i
3:   for j=i to n-1 do *
4:     if A[j] < A[minIdx] then } ≤ c1
5:     minIdx = j
6:   swap(A[i], A[minIdx]) ←
```

Konstante $c > 0$

$\#op. \leq c \cdot \underbrace{\#(\text{Schleifendurchläufe } *)}_{x(n)}$

$\#op \leq c \cdot n^2$

$$x(n) = \sum_{i=0}^{n-2} (n-i) = \sum_{j=2}^n j \leq \sum_{j=1}^n j = \frac{n(n+1)}{2} \leq n^2$$

Selection Sort: Obere Schranke

$T(n)$: Anzahl Grundop. von Selection Sort bei Arrays der Länge n

Lemma: Es gibt eine **Konstante** $c_U > 0$, so dass $T(n) \leq c_U \cdot n^2$

Beweis:

$$X(u) = \sum_{j=2}^u j = \left(\sum_{j=1}^u j \right) - 1 = \frac{u(u+1)}{2} - 1 \geq \frac{u^2}{2}$$

Selection Sort: Untere Schranke

$T(n)$: Anzahl Grundop. von Selection Sort bei Arrays der Länge n

Lemma: Es gibt eine **Konstante c_L** , so dass $T(n) \geq c_L \cdot n^2$

Beweis:

$$T(n) = \#op \geq \underbrace{\#(\text{Schleifendurchläufe})}_{X(n)}$$

$$X(n) \geq \frac{n^2}{2}$$

$$\underline{c_L \cdot n^2 \leq T(n) \leq c_U \cdot n^2}$$

Zusammenfassung

- Wir können nur eine Grösse berechnen, welche proportional zur Laufzeit ist
- Wir wollen auch gar nichts anderes berechnen:
 - Analyse sollte unabhängig von Computer / Compiler / etc. sein
 - Wir wollen Aussagen, welche auch in 10/100/... Jahren noch Gültigkeit haben
- Wir werden immer Aussagen der folgenden Art haben:
Es gibt eine Konstante C , so dass
$$\underline{T(n) \leq C \cdot f(n)} \quad \text{oder} \quad \underline{T(n) \geq C \cdot f(n)}$$
- Um dies zu vereinfachen / verallgemeinern gibt's die O-Notation...

Landau-Symbole (“O-Notation”)

- Formalismus, um das asymptotische Wachstum von Funktionen zu beschreiben.
 - Formale Definitionen: siehe nächste Folie...

- Es gibt eine Konst. C , so dass $T(n) \leq C \cdot f(n)$ wird zu:

$$\underline{T(n) \in O(f(n))}$$

- Es gibt eine Konst. C , so dass $T(n) \geq C \cdot g(n)$ wird zu:

$$\underline{T(n) \in \Omega(g(n))}$$

- Bei Selection Sort:

$$T(n) \in O(n^2) , T(n) \in \Omega(n^2) \implies T(n) = \Theta(n^2)$$

Landau-Symbole : Definitionen $g: \mathbb{N} \rightarrow \mathbb{R}^+$

$$\underline{O(g(n))} := \{ \underline{f(n)} \mid \underline{\exists c, n_0 > 0} \forall n \geq n_0 : \underline{f(n) \leq c \cdot g(n)} \}$$

- Funktion $f(n) \in O(g(n))$, falls es Konstanten c und n_0 gibt, so dass $f(n) \leq c \cdot g(n)$ für alle $n \geq n_0$

$$\underline{\Omega(g(n))} := \{ \underline{f(n)} \mid \underline{\exists c, n_0 > 0} \forall n \geq n_0 : \underline{f(n) \geq c \cdot g(n)} \}$$

- Funktion $f(n) \in \Omega(g(n))$, falls es Konstanten c und n_0 gibt, so dass $f(n) \geq c \cdot g(n)$ für alle $n \geq n_0$

$$\Theta(g(n)) := O(g(n)) \cap \Omega(g(n))$$

- Funktion $f(n) \in \Theta(g(n))$, falls es Konstanten c_1, c_2 und n_0 gibt, so dass $c_1 \cdot g(n) \leq f(n) \leq c_2 \cdot g(n)$ für alle $n \geq n_0$, resp. falls $f(n) \in O(n)$ und $f(n) \in \Omega(n)$

Landau-Symbole : Definitionen

$$o(g(n)) := \{f(n) \mid \forall c > 0 \exists n_0 > 0 \forall n \geq n_0 : \underline{f(n) \leq c \cdot g(n)}\}$$

- Funktion $f(n) \in o(g(n))$, falls für alle Konstanten $c > 0$ gilt, dass $f(n) \leq c \cdot g(n)$ (für genug grosse n , abhängig von c)

$$\omega(g(n)) := \{f(n) \mid \forall c > 0 \exists n_0 > 0 \forall n \geq n_0 : f(n) \geq c \cdot g(n)\}$$

- Funktion $f(n) \in \omega(g(n))$, falls für alle Konstanten $c > 0$ gilt, dass $f(n) \geq c \cdot g(n)$ (für genug grosse n , abhängig von c)

Insbesondere gilt:

$$f(n) \in o(g(n)) \implies f(n) \in O(g(n))$$

$$\underline{f(n)} \in \underline{\omega(g(n))} \implies \underline{f(n)} \in \underline{\Omega(g(n))}$$

Landau-Symbole : Intuitiv

$f(n) \in O(g(n))$:

- $f(n) \leq g(n)$, asymptotisch gesehen...
- $f(n)$ wächst asymptotisch nicht schneller als $g(n)$

$f(n) \in \Omega(g(n))$:

- $f(n) \geq g(n)$, asymptotisch gesehen...
- $f(n)$ wächst asymptotisch mindestens so schnell, wie $g(n)$

$f(n) \in \Theta(g(n))$:

- $f(n) = g(n)$, asymptotisch gesehen...
- $f(n)$ wächst asymptotisch gleich schnell, wie $g(n)$

Landau-Symbole : Intuitiv

$f(n) \in o(g(n))$:

- $f(n) \underline{<} g(n)$, asymptotisch gesehen...
- $f(n)$ wächst asymptotisch langsamer als $g(n)$

$f(n) \in \omega(g(n))$:

- $f(n) \underline{\underline{>}} g(n)$, asymptotisch gesehen...
- $f(n)$ wächst asymptotisch schneller als $g(n)$

Falls $f(n)$ und $g(n)$ monoton wachsen, gilt:

$$\underline{f(n+1) \geq f(n)}$$

$$\underline{f(n) \in o(g(n))} \iff \underline{f(n) \notin \Omega(g(n))}$$
$$\underline{f(n) \in \omega(g(n))} \iff \underline{f(n) \notin O(g(n))}$$

Definition über Grenzwerte (vereinfacht)

Folgende Definitionen gelten für monoton wachsende Funktionen

$$T(n) \in O(n^2)$$

$$\underline{f(n) \in O(g(n))}, \iff \lim_{n \rightarrow \infty} \frac{f(n)}{g(n)} < \infty$$

$$\underline{f(n) \in \Omega(g(n))}, \quad \lim_{n \rightarrow \infty} \frac{f(n)}{g(n)} > 0$$

$$f(n) \in \Theta(g(n)), \quad \underline{0 < \lim_{n \rightarrow \infty} \frac{f(n)}{g(n)} < \infty}$$

$$\underline{f(n) \in o(g(n))}, \quad \lim_{n \rightarrow \infty} \frac{f(n)}{g(n)} = 0$$

$$\underline{f(n) \in \omega(g(n))}, \quad \underline{\lim_{n \rightarrow \infty} \frac{f(n)}{g(n)} \stackrel{\downarrow}{=} \infty}$$

Landau-Notation : Bemerkungen

$$T(n) \not\subseteq O(n^3)$$

Schreibweise:

$$T(n) \in O(n) \subseteq O(n^2)$$

- $O(g(n)), \Omega(g(n)), \dots$ sind Mengen (von Funktionen)
- Korrekte Schreibweise ist deshalb eigentlich: $f(n) \in O(g(n))$
- Sehr verbreitete Schreibweise: $f(n) = O(g(n))$

Asymptotisches Verhalten für allgemeine Grenzwerte:

- gleiche Schreibweise auch für Verhalten von z.B. $f(x)$ für $x \rightarrow 0$
- z.B. Taylor-Reihen: $e^x = 1 + x + O(x^2)$, bzw. $e^x = 1 + x + o(x)$

Alternative Definition für $\Omega(g(n))$:

$$f(n) \notin \Omega(g(n)) \leftarrow$$

$$f(n) \in \Omega(g(n))$$

$$\rightarrow \Omega(g(n)) := \{f(n) \mid \exists c, n_0 > 0 \forall n \geq n_0 : f(n) \geq c \cdot g(n)\} \leftarrow$$

$$\Omega(g(n)) := \{f(n) \mid \exists c > 0 \forall n_0 > 0 \exists n \geq n_0 : f(n) \geq c \cdot g(n)\} \rightarrow$$

– Wir verwenden die 1. Definition

$$g(n) = n^2 \quad f(n) = \begin{cases} n^2, & n \text{ even} \\ 1, & n \text{ odd} \end{cases}$$

– Macht nur bei nicht-monotonen Funktionen einen Unterschied

Landau-Notation : Beispiele

$O(\log n)$

Selection Sort:

- Laufzeit $T(n)$, es gibt Konstanten $c_1, c_2 : c_1 n^2 \leq T(n) \leq c_2 n^2$

$$\underline{T(n) \in O(n^2)}, \quad \underline{T(n) \in \Omega(n^2)}, \quad \underline{T(n) \in \Theta(n^2)}$$

- $T(n)$ wächst schneller als linear: $T(n) \in \underline{\omega(n)}$ $T(n) = o(n^3)$

Weitere Beispiele:

$$\log_a b = \frac{\log_2 b}{\log_2 a}$$

- $f(n) = \underline{10n^3}$, $g(n) = n^3 / \underline{1000}$: $10n^3 \in \Theta(n^3/1000)$

- $f(n) = e^n$, $g(n) = n^{100}$: $f(n) \in \omega(g(n))$

- $f(n) = n / \log_2 n$, $g(n) = \sqrt{n}$: $\frac{f(n)}{g(n)} = \frac{\sqrt{n}}{\log_2 n} = \frac{2^{x/2}}{x}$ $f(n) \in \omega(g(n))$

- $f(n) = n^{1/256}$, $g(n) = 10 \ln n$: $f(n) \in \omega(g(n))$

- $f(n) = \log_{10} n$, $g(n) = \log_2 n$: $f(n) \in \Theta(g(n))$ $\log_{10} n = \frac{\ln n}{\ln 10}$

- $f(n) = n^{\sqrt{n}}$, $g(n) = 2^n$:
 $\sqrt{n} \cdot \log_2 n$ $\frac{\sqrt{n}}{n}$