

# Informatik II

Vorlesung am D-BAUG der ETH Zürich

Felix Friedrich & Hermann Lehner

FS 2018

## 1. Einführung

Algorithmen und Datenstrukturen, erstes Beispiel

1

23

### Ziele der Vorlesung

- Verständnis des Entwurfs und der Analyse grundlegender Algorithmen und Datenstrukturen.
- Grundlagen für das Design und die Implementation von Datenbanken.

### Inhalte der Vorlesung

#### Datenstrukturen / Algorithmen

Begriff der Invariante, Kostenmodell, Landau Symbole

Algorithmenentwurf, Induktion

Suchen und Auswahl, Sortieren

Wörterbücher: Hashing und Suchbäume, AVL

Dynamic Programming

Graphen, Kürzeste Wege, Backtracking, Maximaler Fluss

#### Software Engineering

Files and Exceptions

Java Streams API

#### Datenbanken

ER-Modell, Relationales Modell, SQL

24

25

# Algorithmus

## 1.1 Algorithmen

[Cormen et al, Kap. 1; Ottman/Widmayer, Kap. 1.1]

Algorithmus: wohldefinierte Berechnungsvorschrift, welche aus Eingabedaten (*input*) Ausgabedaten (*output*) berechnet.

26

27

## Beispielproblem

**Input :** Eine Folge von  $n$  Zahlen  $(a_1, a_2, \dots, a_n)$   
**Output :** Eine Permutation  $(a'_1, a'_2, \dots, a'_n)$  der Folge  $(a_i)_{1 \leq i \leq n}$ , so dass  $a'_1 \leq a'_2 \leq \dots \leq a'_n$

### Mögliche Eingaben

$(1, 7, 3), (15, 13, 12, -0.5), (1) \dots$

Jedes Beispiel erzeugt eine *Probleminstanz*.

Die Performanz (Geschwindigkeit) des Algorithmus hängt üblicherweise ab von der Probleminstanz. Es gibt oft "gute" und "schlechte" Instanzen.

28

## Beispiele für Probleme in der Algorithmik

- **Tabellen und Statistiken:** Suchen, Auswählen und Sortieren
- **Routenplanung:** Kürzeste Wege Algorithmus, Heap Datenstruktur
- **DNA Matching:** Dynamic Programming
- **Fabrikationspipeline:** Topologische Sortierung
- **Autovervollständigung:** Wörterbücher/Bäume
- **Symboltabellen:** Hash-Tabellen
- **Der Handlungsreisende:** Dynamische Programmierung, Minimal aufspannender Baum, Simulated Annealing,
- **Zeichnen am Computer:** Linien und Kreise Digitalisieren, Füllen von Polygonen
- **PageRank:** (Markov-Chain) Monte Carlo ...

29

## Charakteristik

- Extrem grosse Anzahl potentieller Lösungen
- Praktische Anwendung

## Datenstrukturen

- Organisation der Daten, zugeschnitten auf die Algorithmen die auf den Daten operieren
- Programme = Algorithmen + Datenstrukturen.

30

31

## Ein Traum

- Wären Rechner unendlich schnell und hätten unendlich viel Speicher ...
- ... dann bräuchten wir die Theorie der Algorithmen (nur) für Aussagen über Korrektheit (incl. Terminierung).

## Die Realität

Ressourcen sind beschränkt und nicht umsonst:

- Rechenzeit → Effizienz
- Speicherplatz → Effizienz

32

33

## 1.2 Altägyptische Multiplikation

Altägyptische Multiplikation

## Altägyptische Multiplikation<sup>2</sup>

Berechnung von  $11 \cdot 9$

11		9		9		11
<del>22</del>		<del>4</del>		18		5
<del>44</del>		<del>2</del>		<del>36</del>		<del>2</del>
88		1		72		1
99		—		99		—

- 1 Links verdoppeln, rechts ganzzahlig halbieren.
- 2 Gerade Zahl rechts  $\Rightarrow$  Zeile streichen.
- 3 Übrige Zeilen links addieren.

<sup>2</sup>Auch bekannt als Russische Bauernmultiplikation

34

35

## Vorteile

- Kurze Beschreibung, einfach zu verstehen.
- Effizient für Computer im Dualsystem: Verdoppeln = Left Shift, Halbieren = Right Shift

### Beispiel

*left shift*  $9 = 01001_2 \rightarrow 10010_2 = 18$

*right shift*  $9 = 01001_2 \rightarrow 00100_2 = 4$

## Fragen

- Funktioniert das immer? (z.B. für negative Zahlen)
- Wenn nicht, wann?
- Wie beweist man die Korrektheit?
- Besser als die "Schulmethode"?
- Was heisst "gut"? Lässt sich Güte anordnen?
- Wie schreibt man das Verfahren unmissverständlich auf?

36

37

## Beobachtung

Wenn  $b > 1$ ,  $a \in \mathbb{Z}$ , dann:

$$a \cdot b = \begin{cases} 2a \cdot \frac{b}{2} & \text{falls } b \text{ gerade,} \\ a + 2a \cdot \frac{b-1}{2} & \text{falls } b \text{ ungerade.} \end{cases}$$

## Terminierung

$$a \cdot b = \begin{cases} a & \text{falls } b = 1, \\ 2a \cdot \frac{b}{2} & \text{falls } b \text{ gerade,} \\ a + 2a \cdot \frac{b-1}{2} & \text{falls } b \text{ ungerade.} \end{cases}$$

38

39

## Rekursiv funktional notiert

$$f(a, b) = \begin{cases} a & \text{falls } b = 1, \\ f(2a, \frac{b}{2}) & \text{falls } b \text{ gerade,} \\ a + f(2a, \frac{b-1}{2}) & \text{falls } b \text{ ungerade.} \end{cases}$$

## Funktion programmiert

```
// pre: b>0
// post: return a*b
int f(int a, int b){
    if(b==1)
        return a;
    else if (b%2 == 0)
        return f(2*a, b/2);
    else
        return a + f(2*a, (b-1)/2);
}
```

40

41

## Korrektheit

$$f(a, b) = \begin{cases} a & \text{falls } b = 1, \\ f(2a, \frac{b}{2}) & \text{falls } b \text{ gerade,} \\ a + f(2a \cdot \frac{b-1}{2}) & \text{falls } b \text{ ungerade.} \end{cases}$$

Zu zeigen:  $f(a, b) = a \cdot b$  für  $a \in \mathbb{Z}, b \in \mathbb{N}^+$ .

## Beweis per Induktion

Anfang:  $b = 1 \Rightarrow f(a, b) = a = a \cdot 1$ .

Hypothese:  $f(a, b') = a \cdot b'$  für  $0 < b' \leq b$

Schritt:  $f(a, b + 1) \stackrel{!}{=} a \cdot (b + 1)$

$$f(a, b + 1) = \begin{cases} f(2a, \overbrace{\frac{b+1}{2}}^{\leq b}) = a \cdot (b + 1) & \text{falls } b \text{ ungerade,} \\ a + f(2a, \underbrace{\frac{b}{2}}_{\leq b}) = a + a \cdot b & \text{falls } b \text{ gerade.} \end{cases}$$

42

43

## Rekursion vs. Iteration

```
// pre: b>0
// post: return a*b
int f(int a, int b){
    if(b==1)
        return a;
    else if (b%2 == 0)
        return f(2*a, b/2);
    else
        return a + f(2*a, (b-1)/2);
}
```



```
// pre: b>0
// post: return a*b
int f(int a, int b) {
    int res = 0;
    while (b > 0) {
        if (b % 2 != 0){
            res += a;
            --b;
        }
        a *= 2;
        b /= 2;
    }
    return res;
}
```

44

## Invarianten!

```
// pre: b>0
// post: return a*b
int f(int a, int b) {
    int res = 0;
    while (b > 0) {
        if (b % 2 != 0){
            res += a;
            --b;
        }
        a *= 2;
        b /= 2;
    }
    return res;
}
```

Sei  $x := a \cdot b$ .

Hier gilt  $x = a \cdot b + res$

Wenn hier  $x = a \cdot b + res \dots$

$\dots$  dann auch hier  $x = a \cdot b + res$   
 $b$  gerade

Hier gilt  $x = a \cdot b + res$

Hier gilt  $x = a \cdot b + res$  und  $b = 0$

Also  $res = x$ .

45

## Zusammenfassung

Der Ausdruck  $a \cdot b + res$  ist eine *Invariante*.

- Werte von  $a$ ,  $b$ ,  $res$  ändern sich, aber die Invariante bleibt "im Wesentlichen" unverändert:
- Invariante vorübergehend durch eine Anweisung zerstört, aber dann darauf wieder hergestellt.
- Betrachtet man solche Aktionsfolgen als atomar, bleibt der Wert tatsächlich invariant
- Insbesondere erhält die Schleife die Invariante (*Schleifeninvariante*), wirkt dort wie der Induktionsschritt bei der vollständigen Induktion
- Invarianten sind offenbar mächtige Beweishilfsmittel!

46

## Analyse

```
// pre: b>0
// post: return a*b
int f(int a, int b) {
    int res = 0;
    while (b > 0) {
        if (b % 2 != 0){
            res += a;
            --b;
        }
        a *= 2;
        b /= 2;
    }
    return res;
}
```

Altägyptische Multiplikation entspricht der Schulmethode zur Basis 2.

$$\begin{array}{r} 1\ 0\ 0\ 1 \times 1\ 0\ 1\ 1 \\ \hline \phantom{1\ 0\ 0\ 1} 1\ 0\ 0\ 1 \quad (9) \\ \phantom{1\ 0\ 0\ 1} 1\ 0\ 0\ 1 \quad (18) \\ \hline \phantom{1\ 0\ 0\ 1} 1\ 1\ 0\ 1\ 1 \\ \phantom{1\ 0\ 0\ 1} 1\ 0\ 0\ 1 \quad (72) \\ \hline 1\ 1\ 0\ 0\ 0\ 1\ 1 \quad (99) \end{array}$$

47

## Effizienz

Frage: Wie lange dauert eine Multiplikation von  $a$  und  $b$ ?

- Mass für die Effizienz
  - Gesamtzahl der elementaren Operationen: Verdoppeln, Halbieren, Test auf "gerade", Addition
  - Im rekursiven wie im iterativen Code: maximal 6 Operationen pro Aufruf bzw. Durchlauf
- Wesentliches Kriterium:
  - Anzahl rekursiver Aufrufe oder
  - Anzahl Schleifendurchläufe(im iterativen Fall)
- $\frac{b}{2^n} \leq 1$  gilt für  $n \geq \log_2 b$ . Also nicht mehr als  $6 \lceil \log_2 b \rceil$  elementare Operationen.

48

## 2. Effizienz von Algorithmen

Effizienz von Algorithmen, Random Access Machine Modell, Funktionenwachstum, Asymptotik [Cormen et al, Kap. 2.2,3,4.2-4.4 | Ottman/Widmayer, Kap. 1.1]

49

## Effizienz von Algorithmen

### Ziele

- Laufzeitverhalten eines Algorithmus maschinenunabhängig quantifizieren.
- Effizienz von Algorithmen vergleichen.
- Abhängigkeit von der Eingabegrösse verstehen.

50

## Asymptotisches Verhalten

Genauere Laufzeit lässt sich selbst für kleine Eingabedaten kaum voraussagen.

- Betrachten das asymptotische Verhalten eines Algorithmus.
- Ignorieren alle konstanten Faktoren.

### Beispiel

Eine Operation mit Kosten 20 ist genauso gut wie eine mit Kosten 1.  
Lineares Wachstum mit Steigung 5 ist genauso gut wie lineares Wachstum mit Steigung 1.

52

## Technologiemodell

### *Random Access Machine (RAM)*

- Ausführungsmodell: Instruktionen werden der Reihe nach (auf einem Prozessorkern) ausgeführt.
- Speichermodell: Konstante Zugriffszeit.
- Elementare Operationen: Rechenoperation (+, −, ·, ...) , Vergleichsoperationen, Zuweisung / Kopieroperation, Flusskontrolle (Sprünge)
- Einheitskostenmodell: elementare Operation hat Kosten 1.
- Datentypen: Fundamentaltypen wie grössenbeschränkte Ganzzahl oder Fließkommazahl.

51

## 2.2 Funktionenwachstum

$\mathcal{O}$ ,  $\Theta$ ,  $\Omega$  [Cormen et al, Kap. 3; Ottman/Widmayer, Kap. 1.1]

53



## Oberflächlich

Verwende die asymptotische Notation zur Kennzeichnung der Laufzeit von Algorithmen

Wir schreiben  $\Theta(n^2)$  und meinen, dass der Algorithmus sich für grosse  $n$  wie  $n^2$  verhält: verdoppelt sich die Problemgrösse, so vervierfacht sich die Laufzeit.

## Genauer: Asymptotische obere Schranke

Gegeben: Funktion  $g : \mathbb{N} \rightarrow \mathbb{R}$ .

Definition:

$$\mathcal{O}(g) = \{f : \mathbb{N} \rightarrow \mathbb{R} \mid \exists c > 0, n_0 \in \mathbb{N} : 0 \leq f(n) \leq c \cdot g(n) \forall n \geq n_0\}$$


Schreibweise:

$$\mathcal{O}(g(n)) := \mathcal{O}(g(\cdot)) = \mathcal{O}(g).$$

54

55

## Anschauung



56

## Beispiele

$$\mathcal{O}(g) = \{f : \mathbb{N} \rightarrow \mathbb{R} \mid \exists c > 0, n_0 \in \mathbb{N} : 0 \leq f(n) \leq c \cdot g(n) \forall n \geq n_0\}$$

$f(n)$	$f \in \mathcal{O}(?)$	Beispiel
$3n + 4$	$\mathcal{O}(n)$	$c = 4, n_0 = 4$
$2n$	$\mathcal{O}(n)$	$c = 2, n_0 = 0$
$n^2 + 100n$	$\mathcal{O}(n^2)$	$c = 2, n_0 = 100$
$n + \sqrt{n}$	$\mathcal{O}(n)$	$c = 2, n_0 = 1$

57

## Eigenschaft

$$f_1 \in \mathcal{O}(g), f_2 \in \mathcal{O}(g) \Rightarrow f_1 + f_2 \in \mathcal{O}(g)$$

## Umkehrung: Asymptotische untere Schranke

Gegeben: Funktion  $g : \mathbb{N} \rightarrow \mathbb{R}$ .


Definition:

$$\Omega(g) = \{f : \mathbb{N} \rightarrow \mathbb{R} \mid \exists c > 0, n_0 \in \mathbb{N} : 0 \leq c \cdot g(n) \leq f(n) \forall n \geq n_0\}$$

58

59

## Beispiel



## Asymptotisch scharfe Schranke

Gegeben Funktion  $g : \mathbb{N} \rightarrow \mathbb{R}$ .

Definition:


$$\Theta(g) := \Omega(g) \cap \mathcal{O}(g).$$

Einfache, geschlossene Form: Übung.

60

61

## Beispiel




## Wachstumsbezeichnungen

$\mathcal{O}(1)$	beschränkt	Array-Zugriff
$\mathcal{O}(\log \log n)$	doppelt logarithmisch	Binäre sortierte Suche interpoliert
$\mathcal{O}(\log n)$	logarithmisch	Binäre sortierte Suche
$\mathcal{O}(\sqrt{n})$	wie die Wurzelfunktion	Primzahltest (naiv)
$\mathcal{O}(n)$	linear	Unsortierte naive Suche
$\mathcal{O}(n \log n)$	superlinear / loglinear	Gute Sortieralgorithmen
$\mathcal{O}(n^2)$	quadratisch	Einfache Sortieralgorithmen
$\mathcal{O}(n^c)$	polynomial	Matrixmultiplikation
$\mathcal{O}(2^n)$	exponentiell	Travelling Salesman Dynamic Programming
$\mathcal{O}(n!)$	faktoriell	Travelling Salesman naiv


62

63

## Kleine $n$




## Grössere $n$



64


65

## “Grosse” $n$



66

## Logarithmen!



67

## Beispiele

- $n \in \mathcal{O}(n^2)$  korrekt, aber ungenau:  
 $n \in \mathcal{O}(n)$  und sogar  $n \in \Theta(n)$ .
- $3n^2 \in \mathcal{O}(2n^2)$  korrekt, aber unüblich:  
Konstanten weglassen:  $3n^2 \in \mathcal{O}(n^2)$ .
- $2n^2 \in \mathcal{O}(n)$  ist falsch:  $\frac{2n^2}{cn} = \frac{2}{c}n \rightarrow \infty$  !
- $\mathcal{O}(n) \subseteq \mathcal{O}(n^2)$  ist korrekt
- $\Theta(n) \subseteq \Theta(n^2)$  ist falsch:  $n \notin \Omega(n^2) \supset \Theta(n^2)$

68

## Nützliches

### Theorem

Seien  $f, g : \mathbb{N} \rightarrow \mathbb{R}^+$  zwei Funktionen. Dann gilt:

- 1  $\lim_{n \rightarrow \infty} \frac{f(n)}{g(n)} = 0 \Rightarrow f \in \mathcal{O}(g), \mathcal{O}(f) \subsetneq \mathcal{O}(g)$ .
- 2  $\lim_{n \rightarrow \infty} \frac{f(n)}{g(n)} = C > 0$  ( $C$  konstant)  $\Rightarrow f \in \Theta(g)$ .
- 3  $\frac{f(n)}{g(n)} \rightarrow \infty \Rightarrow g \in \mathcal{O}(f), \mathcal{O}(g) \subsetneq \mathcal{O}(f)$ .

69

## Zur Notation

Übliche Schreibweise

$$f = \mathcal{O}(g)$$

ist zu verstehen als  $f \in \mathcal{O}(g)$ .

Es gilt nämlich

$$f_1 = \mathcal{O}(g), f_2 = \mathcal{O}(g) \not\Rightarrow f_1 = f_2!$$

### Beispiel

$n = \mathcal{O}(n^2), n^2 = \mathcal{O}(n^2)$  aber natürlich  $n \neq n^2$ .

70

## Algorithmen, Programme und Laufzeit

Programm: Konkrete Implementation eines Algorithmus.

Laufzeit des Programmes: messbarer Wert auf einer konkreten Maschine. Kann sowohl nach oben, wie auch nach unten abgeschätzt werden.

### Beispiel

Rechner mit 3 GHz. Maximale Anzahl Operationen pro Taktzyklus (z.B. 8).  $\Rightarrow$  untere Schranke.

Einzelne Operation dauert mit Sicherheit nie länger als ein Tag  $\Rightarrow$  obere Schranke.

*Asymptotisch gesehen* stimmen die Schranken überein.

71