

# Approximationsalgorithmen

Wintersemester 2019/20

Annamaria Kovacs R.305, Mahyar Behdju R.311

Conrad Schecker Do. 14 Uhr SR 11

**Webseite:** <https://ae.cs.uni-frankfurt.de/>  
→ teaching  
→ Approximationsalgorithmen  
(→ Skript)

# die Themen

- Entwurfsmethoden I
    - Greedy Algorithmen I
    - Dynamische Programmierung I
    - Lokale suche
  - Lineare Programmierung (Grundlagen)
- 
- Lineare Programmierung (Dualität)
  - Entwurfsmethoden II
    - Greedy Algorithmen II: Matroide, Sequenzierung
    - Dynamische Programmierung II: Arora's PTAS
    - Branch & Bound

## Lineare Programmierung Beispiel

Minimiere  $2x_1 - x_2 + 4x_3$  (*lineare Zielfunktion*)

so dass

$$x_1 + x_2 + x_4 \leq 2$$

$$3x_2 - x_3 = 5$$

$$x_3 + x_4 \geq 3 \quad (\textit{lineare Nebenbedingungen})$$

$$x_1 \geq 0$$

$$x_3 \leq 0$$

Gesucht wird eine Belegung der Variablen  $x_1, x_2, x_3, x_4$  die die Nebenbedingungen erfüllt, und die Zielfunktion minimiert.

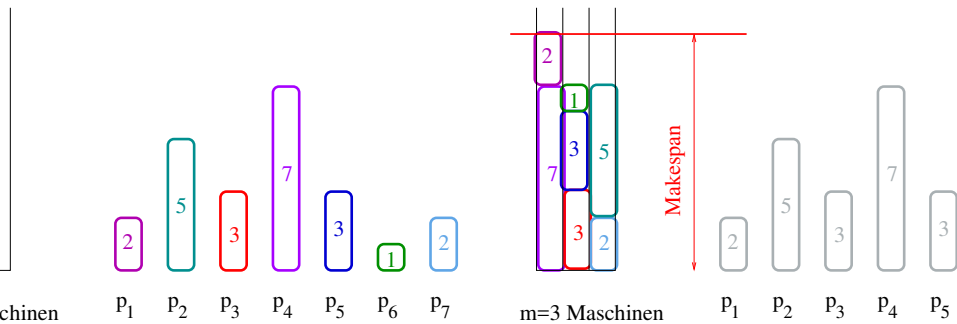
(*Linear Program, LP*)

## Bücher:

1. Vazirani: Approximation algorithms
2. Shmoys, Williamson: The design of approximation algorithms
3. Bertsimas, Tsitsiklis: Introduction to linear optimization
4. Moore, Mertens: The nature of computation, Chapter 9.  
(unbedingt reinschauen!)
5. Jansen, Margraf: Approximative Algorithmen und Nichtapproximierbarkeit
6. Wanka: Approximationsalgorithmen, Eine Einführung

# EINFÜHRUNG

# Beispiel 1: Scheduling auf identischen Maschinen




## min-SCHEDULING

**Eingabe:**  $n$  Job-Laufzeiten  $p_1, p_2, \dots, p_n$ , und Maschinentzahl  $m$

**Ausgabe:** Teile jeden Job genau einer Maschine zu so dass der Makespan minimiert wird

(Makespan = maximale Fertigstellungszeit)

# Beispiel 1: Scheduling auf identischen Maschinen



## min-SCHEDULING


**Eingabe:**  $n$  Job-Laufzeiten  $p_1, p_2, \dots, p_n$ , und Maschinentzahl  $m$

**Ausgabe:** Teile jeden Job genau einer Maschine zu so dass der Makespan minimiert wird

(Makespan = maximale Fertigstellungszeit)

# Der (greedy) LIST-Scheduling Algorithmus

- ▶ Weise die Jobs nacheinander der Maschinen zu:
- ▶ gib  $p_i$  der Maschine die bisher die kleinste Gesamtlaufzeit von Jobs hat





# Approximationsfaktor von LIST

Theorem 1: Der Approximationsfaktor von LIST ist mindestens

$$2 - \frac{1}{m}.$$

Theorem 2: Für beliebige Eingabe-Instanz  $I$  gilt dass

$$LIST(I) \leq \left(2 - \frac{1}{m}\right)OPT(I).$$

Der Approximationsfaktor von LIST ist somit auch höchstens (also genau)  $2 - \frac{1}{m}$ .

$OPT(I)$  : der minimale Makespan

$LIST(I)$  : der Makespan ausgegeben von LIST

# Approximationsfaktor (Minimierungsproblem)

$I$  : Eingabe-Instanz

$\text{OPT}(I)$  : minimaler Zielwert über Lösungen für  $I$

$\text{ALG}(I)$  : Zielwert der Lösung von ALG

sei  $\alpha \geq 1$

–  $\alpha$ -approximative Lösung:

Lösung mit Zielwert  $\leq \alpha \cdot \text{OPT}(I)$

– Approximationsfaktor von ALG ist höchstens  $\alpha$  wenn für *jede* Eingabe  $I$

$$\text{ALG}(I) \leq \alpha \cdot \text{OPT}(I)$$

– Approximationsfaktor von ALG ist mindestens  $\alpha$  wenn für jede  $\epsilon > 0$  gibt es *mind. eine* Eingabe  $I$  so dass

$$\text{ALG}(I) \geq (\alpha - \epsilon) \cdot \text{OPT}(I)$$

## Beispiel 2: max-CLIQUE:

### max-CLIQUE

Eingabe: ein Graph  $G(V, E)$

Ausgabe: Finde in  $G$  eine Clique maximaler Größe als Teilgraph.

Clique: vollständiger (Teil-)Graph

- Es gibt überhaupt keine Konstante  $c$  s.d. max-CLIQUE effizient  $c$ -approximierbar ist (falls  $\mathcal{P} \neq \mathcal{NP}$ ).
- Es gibt sogar keinen effizienten Algorithmus mit Approx.-Faktor  $n^{(1-\delta)}$  für  $\delta > 0$  (wobei  $n = |V|$ )

# Approximationsfaktor (Maximierungsproblem)

$I$  : Eingabe-Instanz

$\text{OPT}(I)$  : maximaler Zielwert über Lösungen für  $I$

$\text{ALG}(I)$  : Zielwert der Lösung von ALG

$\alpha \geq 1$

- $\alpha$ -approximative Lösung:

Lösung mit Zielwert  $\geq \text{OPT}(I)/\alpha$

- Approximationsfaktor von ALG ist höchstens  $\alpha$  wenn für *jede* Eingabe  $I$

$$\text{ALG}(I) \geq \frac{\text{OPT}(I)}{\alpha}$$

- Approximationsfaktor von ALG ist mindestens  $\alpha$  wenn für jede  $\epsilon > 0$  gibt es *mind. eine* Eingabe  $I$  so dass

$$\text{ALG}(I) \leq \frac{\text{OPT}(I)}{(\alpha - \epsilon)}$$

## Beispiel 3: min-VERTEX COVER

### min-VERTEX COVER

Eingabe: ein Graph  $G(V, E)$

Ausgabe: Finde eine Knotenüberdeckung  $C \subseteq V$  minimaler Grösse  $|C|$

Knotenüberdeckung: Teilmenge der Knoten so dass jede Kante mind. einen Endpunkt in  $C$  hat

### Der Algorithmus Greedy Vertex Cover

Eingabe:  $G(V, E)$

Setze  $C = \emptyset$

REPEAT

- für eine beliebige Kante  $\{u, v\} \in E$  füge  $u$  und  $v$  zu  $C$  hinzu;
- entferne  $\{u, v\}$  und alle Kanten adjazent zu  $\{u, v\}$  aus  $E$ ;

UNTIL  $E = \emptyset$ .

return  $C$  als Vertex Cover.

## Beispiel 3: min-VERTEX COVER

Behauptung: Greedy-VC ist 2-approximativ.

Approximierbarkeit von min-VERTEX COVER allgemein:

- min-VERTEX COVER ist 2-approximierbar (wie gesehen)
- Es ist nicht bekannt ob min-VC  $c$ -approximierbar ist für ein  $c < 2$ .
- min-VC ist nicht  $c$ -approximierbar für  $c < 10\sqrt{5} - 21 \approx 1.36$ .  
(ohne beweis)

## Definition: die Klasse $\mathcal{APX}$

$\mathcal{APX}$  ist die Klasse aller NP-Optimierungsprobleme die effiziente  $c$ -approximative Algorithmen für irgendeine Konstante  $c$  besitzen.

# Beispiele für *Optimierungsprobleme*

- 1 min-SCHEDULING
- 2 max-CLIQUE
- 3 min-VERTEX COVER
- 4 max-MATCHING



# Entscheidungsversion(en) von Optimierungsproblemen

## CLIQUE

**Eingabe:** ein Graph  $G(V, E)$  und eine Zahl  $q \in \mathbb{N}$

**Ausgabe:** Entscheide ob der Graph eine Clique der Grösse  $q$  als Teilgraphen besitzt

## SCHEDULING

**Eingabe:**  $n$  Job-Laufzeiten  $p_1, p_2, \dots, p_n$ , Maschinenzahl  $m$ , und eine Zahl  $M$

**Ausgabe:** Entscheide ob ein Schedule auf  $m$  Maschinen mit Makespan  $\leq M$  für diese Jobs existiert

## MATCHING

**Eingabe:** ein Graph  $G(V, E)$

**Ausgabe:** Entscheide ob ein perfektes Matching existiert, eine unabhängige Kantenmenge die alle Knoten überdeckt

## Weitere *Entscheidungsprobleme*

### PARTITION

**Eingabe:**  $n$  Zahlen  $z_1, z_2, \dots, z_n$  ( $z_i \in \mathbb{N}$ )

**Ausgabe:** Entscheide ob es eine Teilmenge der Zahlen gibt (also eine Indexmenge  $S \subseteq \{1, 2, \dots, n\}$ ), so dass

$$\sum_{i \in S} z_i = \frac{\sum_{i=1}^n z_i}{2}$$

### HAMILTONSCHER KREIS

**Eingabe:** ein ungerichteter Graph  $G(V, E)$

**Ausgabe:** Entscheide ob ein Kreis in  $G$  existiert, der jeden Knoten genau einmal durchläuft

## Zur Erinnerung: Die Problem-Klasse $\mathcal{NP}$

ein Entscheidungsproblem gehört zur Klasse  $\mathcal{NP}$



für jede **JA-Instanz** des Problems gibt es eine 'Lösung'  
polynomieller Länge (diese 'Lösung' heißt **Zeuge (witness)** und ist  
allgemein einfach ein polynomiell langer Beweis).

**Anhand eines Zeugen** (falls durch ein Wunder erraten) ist in  
Polynomialzeit nachweisbar dass die Instanz eine JA-Instanz ist!



es gibt eine Nicht-deterministische Turingmaschine mit  
polynomieller Laufzeit die genau die JA-Instanzen von  $P$  akzeptiert  
(Bemerkung: Eine erfolgreiche Berechnung der ND-Turingmaschine  
entspricht einem Zeugen.)

## Wir betrachten $\mathcal{NP}$ -Optimierungsprobleme (die Klasse $\mathcal{NPO}$ )

Ein Optimierungsproblem ist ein  $\mathcal{NP}$ -Optimierungsproblem



Die Entscheidungsversion des Problems liegt in  $\mathcal{NP}$



Die JA-Instanzen der Entscheidungsversion des Problems haben eine polynomiell *verifizierbare* Lösung (sog. Zeugen),  
*die aber nicht effizient gefunden werden soll!*



Eine Lösung mit gutem Zielwert, falls vorhanden, ist polynomiell *verifizierbar* (nachweisbar).

*Die Klasse aller NP-Optimierungsprobleme heißt  $\mathcal{NPO}$ .*

# NP-schwere Optimierungsprobleme

Es ist nicht möglich NP-schwere Optimierungsprobleme *effizient, exakt* zu lösen.

Ein Algorithmus kann nicht gleichzeitig

1. optimale Lösungen bestimmen
2. in polynomieller Zeit laufen
3. dies für jede Instanz tun

Auswege:

1+3 → wir lassen nicht-effiziente Algorithmen zu

1+2 → vielleicht entspricht unsere Instanz einem *Spezialfall*,  
der in Polynomialzeit lösbar ist...

2+3 → wir sind mit *approximativen Lösungen zufrieden*

## (Notation im Skript)

Die folgende Notation wird im Skript allgemein für beliebiges (unspezifiziertes) Optimierungsproblem verwendet:

- Optimierungsproblem:  $P = (\text{opt}, f, L)$
- (Eingabe-)Instanz:  $x_0$
- $x$  ist eine *Lösung* zu  $x_0$ , falls  $L(x_0, x) = \text{YES}$ ;  
 $L()$  heißt Lösungsprädikat
- eine *Zielfunktion*  $f(x_0, x)$  muss minimiert oder maximiert werden:
- $\text{opt} = \text{min}$  oder  $\text{opt} = \text{max}$ ;
- $x^*$  heißt eine *optimale Lösung* zur Instanz  $x_0$ , falls der Zielwert  $f(x_0, x^*)$  unter allen Lösungen  $x$  optimal (maximal bzw. minimal) ist.

# Definition: Polynomielles Approximationsschema (PTAS)

## *PTAS – Polynomial Time Approximation Scheme*

Ein *Polynomielles Approximationsschema (PTAS)* für ein Optimierungsproblem  $P$  ist eine Familie  $(A_\varepsilon)_{\varepsilon>0}$  von Approximationsalgorithmen für  $P$ , so dass für jedes  $\varepsilon$  der zugehörige Algorithmus  $A_\varepsilon$   $(1 + \varepsilon)$ -approximativ ist.

Die Laufzeit von jedem  $A_\varepsilon$  muss in der Eingabelänge (aber nicht in  $1/\varepsilon$ ) polynomiell sein.

## min-SCHEDULING- $m$

Eingabe:  $n$  Jobs mit Laufzeiten  $p_1, p_2, \dots, p_n$

Ausgabe: Ein Schedule der Jobs auf  $m$  Maschinen so dass der Makespan minimal ist.



## ein PTAS für min-SCHEDULING-m

Sei  $\varepsilon$  gegeben, wir definieren den Algorithmus  $A_\varepsilon$

Eingabe:  $n$  Job-Laufzeiten

1. Sortiere die Jobs nach absteigenden Laufzeiten;
2. bestimme einen optimalen Schedule *der größten  $k$  Jobs*;
3. ergänze diesen Schedule mit LIST für die übrigen  $n - k$  jobs!

Für welches  $k$  erhalten wir gleichzeitig

- a.  $(1 + \varepsilon)$ -Approximation?
- b. polynomielle Laufzeit?

für  $m$  Maschinen  $k = m/\varepsilon$  funktioniert!

Laufzeit:  $\mathcal{O}(n \log n + m^{\frac{m}{\varepsilon}})$

(sogar  $k = (m - 1)/\varepsilon$  ist gut;

Laufzeit:  $\mathcal{O}(n \log n + m^{\frac{m-1}{\varepsilon}})$ )

# Was könnte besser sein als ein PTAS?

(für NP-schwere Optimierungsprobleme, wenn  $\mathcal{P} \neq \mathcal{NP}$ )

- Bzgl. der Approximation → NICHTS
- Bzgl. der Laufzeit?

Manche PTAS sind besser als andere...

## Definition: Volles Polynomielles Approximationsschema (FPTAS)

FPTAS: *Fully Polynomial Time Approximation Scheme*

Ein *Volles Polynomielles Approximationsschema (FPTAS)* für ein Optimierungsproblem  $P$  ist ein polynomielles Approximationsschema  $(A_\epsilon)_{\epsilon>0}$  so dass die Laufzeit jedes Algorithmus  $A_\epsilon$  polynomiell ist in der Eingabelänge und in  $1/\epsilon$ .

*PTAS* ist die Klasse aller NP-Optimierungsprobleme mit einem PTAS.

*FPTAS* ist die Klasse aller NP-Optimierungsprobleme mit einem FPTAS.

## kein FPTAS

1. SCHEDULING-m besitzt sogar ein FPTAS;  
SCHEDULING besitzt ein PTAS, aber kein FPTAS
2. Oft ist die Suche nach einem FPTAS von vornherein hoffnungslos!  
min-VERTEX COVER oder max-CLIQUE sind triviale Beispiele ohne FPTAS

# Polynomiell beschränkte Probleme

## Theorem:

Ein NP-vollständiges Optimierungsproblem besitzt *kein* FPTAS, wenn ein Polynom  $q()$  existiert so dass für jede Instanz  $I$  und für jede Lösung von  $I$  der Zielwert *ganzzahlig und höchstens*  $q(|I|)$  ist.

(d.h. Der Zielwert ist polynomiell in der Eingabelänge)

## Warum?

Sonst gäbe es bei  $\varepsilon = 1/q(|I|)$  optimalen effizienten Algorithmus!

## Literatur

Zu den Scheduling-Algorithmen siehe auch

Jansen– Margraf: S. 106, 151

Vazirani: Chapter 10.1

Shmoys– Williamson: Kapitel 2.3, und 3.2

Zur Klasse NP

Moore–Mertens: Chapter 4.1, 4.3

Siehe außerdem

Shmoys– Williamson: Kapitel 1.1

Moore–Mertens: Chapter 9.2