

Approximationsalgorithmen

4. Vorlesung: Lineare Programmierung und LP-Dualität

– Folien von Joachim Spoerhase –

Einführung Lineare Programmierung

Ein Großteil bekannter Approximationsalgorithmen basiert auf linearer Programmierung.

- **Lineare Programmierung (LP) und LP-Dualität**
- Min-Max-Beziehungen
- Techniken LP-basierten Algorithmendesigns

Motivation: Obere und untere Schranken

- Betrachte schweres NP-Minimierungsproblem.
- Entscheidungsproblem:
Ist gegebenes S **obere Schranke** für OPT?
- Leicht verifizierbare „Ja“-Zertifikate (nach Def. von NP)
- **Untere Schranken** / „Nein“-Zertifikate?
↪ wahrscheinlich nicht! (Vermutung: $NP \neq coNP$)
- Brauchen untere Schranken $S \geq OPT/\alpha$ (approximative „Nein“-Zertifikate) für Approximationsalgorithmen!
- Beispiele
 - Vertex Cover: Untere Schranke durch Matchings
 - TSP: Untere Schranke durch MST oder Cycle Cover

Lineare Programmierung

Optimiere (d.h. minimiere oder maximiere) eine lineare Funktion unter Anwesenheit linearer Ungleichungsbedingungen.

$$\begin{array}{rllllll}
 \text{minimize} & 7x_1 & + & x_2 & + & 5x_3 & & \\
 \text{subject to} & x_1 & - & x_2 & + & 3x_3 & \geq & 10 \\
 & 5x_1 & + & 2x_2 & - & x_3 & \geq & 6 \\
 & & & & & x_1, x_2, x_3 & \geq & 0
 \end{array}$$

- Standardform (ÜA)

Lineare Programmierung – Obere Schranken

Optimiere (d.h. minimiere oder maximiere) eine lineare Funktion unter Anwesenheit linearer Ungleichungsbedingungen.

$$\begin{array}{rllllll}
 \text{minimize} & 7x_1 & + & x_2 & + & 5x_3 & & \\
 \text{subject to} & x_1 & - & x_2 & + & 3x_3 & \geq & 10 \\
 & 5x_1 & + & 2x_2 & - & x_3 & \geq & 6 \\
 & & & & & x_1, x_2, x_3 & \geq & 0
 \end{array}$$

- $\mathbf{x} = (2, 1, 3)$ ist zulässige Lösung
 $\Rightarrow S = 30$ ist obere Schranke für OPT

Lineare Programmierung - Untere Schranken

$$\begin{array}{rcll}
 \text{minimize} & 7x_1 & + & x_2 & + & 5x_3 & & & & \\
 \text{subject to} & y_1(x_1 & - & x_2 & + & 3x_3) & \geq & 10 & y_1 & \\
 & y_2(5x_1 & + & 2x_2 & - & x_3) & \geq & 6 & y_2 & \\
 & & & & & & & & & x_1, x_2, x_3 \geq 0
 \end{array}$$

$$\begin{array}{rcll}
 \text{maximize} & 10y_1 & + & 6y_2 & & & & & \\
 \text{subject to} & y_1 & + & 5y_2 & \leq & 7 & & & \\
 & -y_1 & + & 2y_2 & \leq & 1 & & & \\
 & 3y_1 & - & y_2 & \leq & 5 & & & \\
 & & & & & & & & y_1, y_2 \geq 0
 \end{array}$$

- Jede zulässige Lösung für das **duale** Programm liefert untere Schranke für Optimum des **primalen** Programms.
- $\mathbf{x} = (7/4, 0, 11/4)$ und $\mathbf{y} = (2, 1)$ liefern beide den jeweiligen Zielfunktionswert 26. \Rightarrow Beide Lösungen sind jeweils optimal.

LP – Standardform

Primales Programm:

$$\begin{aligned}
 &\text{minimize} && \sum_{j=1}^n c_j x_j \\
 &\text{subject to} && \sum_{j=1}^n a_{ij} x_j \geq b_i && i = 1, \dots, m \\
 &&& x_j \geq 0 && j = 1, \dots, n
 \end{aligned}$$

Duales Programm:

$$\begin{aligned}
 &\text{maximize} && \sum_{i=1}^m b_i y_i \\
 &\text{subject to} && \sum_{i=1}^m a_{ij} y_i \leq c_j && j = 1, \dots, n \\
 &&& y_i \geq 0 && i = 1, \dots, m
 \end{aligned}$$

Duale Programme für Max-Probleme

- Durch analoge Überlegungen – Beispiel später.
- Das duale Programm eines dualen Programms ergibt das Ausgangsprogramm.

LP-Dualität

Primal: minimize $\sum_{j=1}^n c_j x_j$
 subject to $\sum_{j=1}^n a_{ij} x_j \geq b_i \quad i = 1, \dots, m$
 $x_j \geq 0 \quad j = 1, \dots, n$

Dual: maximize $\sum_{i=1}^m b_i y_i$
 subject to $\sum_{i=1}^m a_{ij} y_i \leq c_j \quad j = 1, \dots, n$
 $y_i \geq 0 \quad i = 1, \dots, m$

Satz. Das primale Programm hat ein endliches Optimum.
 \Leftrightarrow Das duale Programm hat ein endliches Optimum.
 Sind dann $\mathbf{x}^* = (x_1^*, \dots, x_n^*)$ und $\mathbf{y}^* = (y_1^*, \dots, y_m^*)$
 optimale Lösungen für das primale bzw. duale Programm,
 so gilt

$$\sum_{j=1}^n c_j x_j^* = \sum_{i=1}^m b_i y_i^* .$$

Schwache LP-Dualität

$$\begin{array}{l} \text{Minimize} \quad \sum_{j=1}^n c_j x_j \\ \text{subject to} \quad \sum_{j=1}^n a_{ij} x_j \geq b_i \\ \quad \quad \quad x_j \geq 0 \end{array}$$

$$\begin{array}{l} \text{Maximize} \quad \sum_{i=1}^m b_i y_i \\ \text{subject to} \quad \sum_{i=1}^m a_{ij} y_i \leq c_j \\ \quad \quad \quad y_i \geq 0 \end{array}$$

Satz. Sind $\mathbf{x} = (x_1, \dots, x_n)$ und $\mathbf{y} = (y_1, \dots, y_m)$ zulässige Lösungen für das primale bzw. duale Programm, so gilt

$$\sum_{j=1}^n c_j x_j \geq \sum_{i=1}^m b_i y_i .$$

Beweis

$$\sum_{j=1}^n c_j x_j \geq \sum_{j=1}^n \left(\sum_{i=1}^m a_{ij} y_i \right) x_j = \sum_{i=1}^m \left(\sum_{j=1}^n a_{ij} x_j \right) y_i \geq \sum_{i=1}^m b_i y_i .$$

Komplementärer Schlupf (*complementary slackness*)

Minimize $\sum_{j=1}^n c_j x_j$
 subject to $\sum_{j=1}^n a_{ij} x_j \geq b_i$
 $x_j \geq 0$

Maximize $\sum_{i=1}^m b_i y_i$
 subject to $\sum_{i=1}^m a_{ij} y_i \leq c_j$
 $y_i \geq 0$

Satz. Seien $\mathbf{x} = (x_1, \dots, x_n)$ und $\mathbf{y} = (y_1, \dots, y_m)$ zulässige Lösungen für das primale bzw. duale Programm. Die Lösungen \mathbf{x} und \mathbf{y} sind genau dann optimal, wenn die folgenden Bedingungen erfüllt sind:

Primärer KS:

Für jedes $j = 1, \dots, n$: Entweder $x_j = 0$ oder $\sum_{i=1}^m a_{ij} y_i = c_j$

Dualer KS:


Für jedes $i = 1, \dots, m$: Entweder $y_i = 0$ oder $\sum_{j=1}^n a_{ij} x_j = b_i$

Beweis. Folgt aus LP-Dualität:

$$\sum_{j=1}^n c_j x_j = \sum_{j=1}^n \left(\sum_{i=1}^m a_{ij} y_i \right) x_j = \sum_{i=1}^m \left(\sum_{j=1}^n a_{ij} x_j \right) y_i = \sum_{i=1}^m b_i y_i$$

LP und konvexe Polytope

- Menge der zulässigen Lösungen eines LPs mit n Variablen bilden **konvexes Polytop** im \mathbb{R}^n (Schnitt von Halbräumen).
- Ecken des Polytops heißen **Extrempunkt-Lösungen** \Leftrightarrow n linear unabhängige Ungleichungen sind mit Gleichheit erfüllt.
- Wenn optimale Lösung existiert, dann auch eine solche, die Extrempunkt ist.



Ganzzahlige lineare Programme

$$\begin{array}{ll}
 \text{Minimize} & \sum_{j=1}^n c_j x_j \\
 \text{subject to} & \sum_{j=1}^n a_{ij} x_j \geq b_i \quad i = 1, \dots, m \\
 & \cancel{x_j \geq 0} \quad x_j \in \mathbb{N} \quad j = 1, \dots, n
 \end{array}$$

- Eine Vielzahl von NP-Optimierungsproblemen lässt sich als ILP formulieren; Lösung ist daher NP-schwer.
- LP-Relaxierung liefert untere Schranke: $\text{OPT}_{\text{LP}} \leq \text{OPT}_{\text{ILP}}$

Einführung Lineare Programmierung

Ein Großteil bekannter Approximationsalgorithmen basiert auf linearer Programmierung.

- Lineare Programmierung (LP) und LP-Dualität
- **Min-Max-Beziehungen**
- Techniken LP-basierten Algorithmendesigns


Max-Flow-Problem

Gegeben: Ein gerichteter Graph $G = (V, E)$ mit Kantenkapazitäten $c: E \rightarrow \mathbb{Q}_+$ und zwei ausgezeichnete Knoten Quelle s und Senke t .

Gesucht: Ein maximaler s – t -Fluss (nicht-negative Kantengewichte f), so dass

- $f(u, v) \leq c(u, v)$ für jede Kante $(u, v) \in E$
- $\sum_{(u,v) \in E} f(u, v) = \sum_{(v,z) \in E} f(v, z)$ für alle $v \in V - \{s, t\}$


Wert des Flusses hierbei Zufluss zu t minus Abfluss aus t



Min-Cut-Problem

Gegeben: Ein gerichteter Graph $G = (V, E)$ mit Kantenkapazitäten $c: E \rightarrow \mathbb{Q}_+$ und zwei ausgezeichnete Knoten Quelle s und Senke t .

Gesucht: Ein s - t -Schnitt, d.h. eine Knotenmenge X mit $s \in X$ und $t \in \bar{X}$, so dass das Gesamtgewicht $c(X, \bar{X})$ der Kanten von X nach \bar{X} minimal ist.



Max-Flow-Min-Cut-Theorem

Satz. Der Wert eines maximalen s - t -Flusses und die Kapazität eines minimalen s - t -Schnitts sind gleich.

Beweis. Spezialfall des LP-Dualitätssatzes. . .


Max-Flow als LP

Maximize f_{ts}

subject to $f_{uv} \leq c_{uv}$ for every $(u, v) \in E$

$$\sum_{u: (u,v) \in E} f_{uv} - \sum_{z: (v,z) \in E} f_{vz} \leq 0 \quad \text{for every } v \in V$$

$f_{uv} \geq 0$ for every $(u, v) \in E$



Duales LP

Maximize f_{ts}

subject to $f_{uv} \leq c_{uv}$

$$\sum_{u: (u,v) \in E} f_{uv} - \sum_{z: (v,z) \in E} f_{vz} \leq 0$$

$$f_{uv} \geq 0$$

Primales Programm

for every $(u, v) \in E$ d_{uv}

for every $v \in V$ p_v

for every $(u, v) \in E$

Minimize $\sum_{(u,v) \in E} c_{uv} d_{uv}$

subject to $d_{uv} - p_u + p_v \geq 0$ for every $(u, v) \in E$

$$p_s - p_t \geq 1$$

$d_{uv} \geq 0$ for every $(u, v) \in E$

$p_u \geq 0$ for every $u \in V$

Duales Programm

Duales LP – Interpretation als ILP

$$\text{Minimize } \sum_{(u,v) \in E} c_{uv} d_{uv}$$


$$\text{subject to } d_{uv} - p_u + p_v \geq 0 \quad (u, v) \in E$$

$$p_s - p_t \geq 1$$

äquivalent zu Min-Cut!!

~~$$d_{uv} \geq 0 \quad d_{uv} \in \{0, 1\} \quad (u, v) \in E$$~~

~~$$p_u \geq 0 \quad p_u \in \{0, 1\} \quad u \in V$$~~



Duales LP – Fraktionale Schnitte

$$\text{Minimize } \sum_{(u,v) \in E} c_{uv} d_{uv}$$

≡ LP-Relaxierung des ILPs

$$\text{subject to } d_{uv} - p_u + p_v \geq 0 \quad (u, v) \in E$$

$$p_s - p_t \geq 1$$

$$d_{uv} \geq 0 \quad (u, v) \in E$$

$$p_u \geq 0 \quad u \in V$$


Jede Extrempunkt-Lösung ist hier **ganzzahlig!** (ÜA)

Jeder $s-t$ -Weg

$s = v_0, \dots, v_k = t$ hat Länge ≥ 1 bezüglich d :

$$\sum_{i=0}^{k-1} d_{i,i+1} \geq \sum_{i=0}^{k-1} (p_i - p_{i+1})$$

$$= p_s - p_t$$




Duales LP – Komplementärer Schlupf

$$\begin{array}{ll}
 \text{Maximize} & f_{ts} \\
 \text{subject to} & f_{uv} \leq c_{uv} \quad (u, v) \in E \\
 & \sum_{u: (u,v) \in E} f_{uv} - \sum_{z: (v,z) \in E} f_{vz} \leq 0 \quad v \in V \\
 & f_{uv} \geq 0 \quad (u, v) \in E
 \end{array}$$

$$\begin{array}{ll}
 \text{Minimize} & \sum_{(u,v) \in E} c_{uv} d_{uv} \\
 \text{subject to} & d_{uv} - p_u + p_v \geq 0 \quad (u, v) \in E \\
 & p_s - p_t \geq 1 \\
 & d_{uv} \geq 0 \quad (u, v) \in E \\
 & p_u \geq 0 \quad u \in V
 \end{array}$$

Für einen maximalen Fluss und minimalen Schnitt gilt:

- Für Vorwärtskanten (u, v) des Schnitts gilt $f_{uv} = c_{uv}$.
($d_{uv} = 1$, also nach dualem KS: $f_{uv} = c_{uv}$.)
- Für Rückwärtskanten (u, v) des Schnitts gilt $f_{uv} = 0$.
(Sonst wäre nach primalem KS: $d_{uv} - 0 + 1 = 0$.)




Einführung Lineare Programmierung

Ein Großteil bekannter Approximationsalgorithmen basiert auf linearer Programmierung.

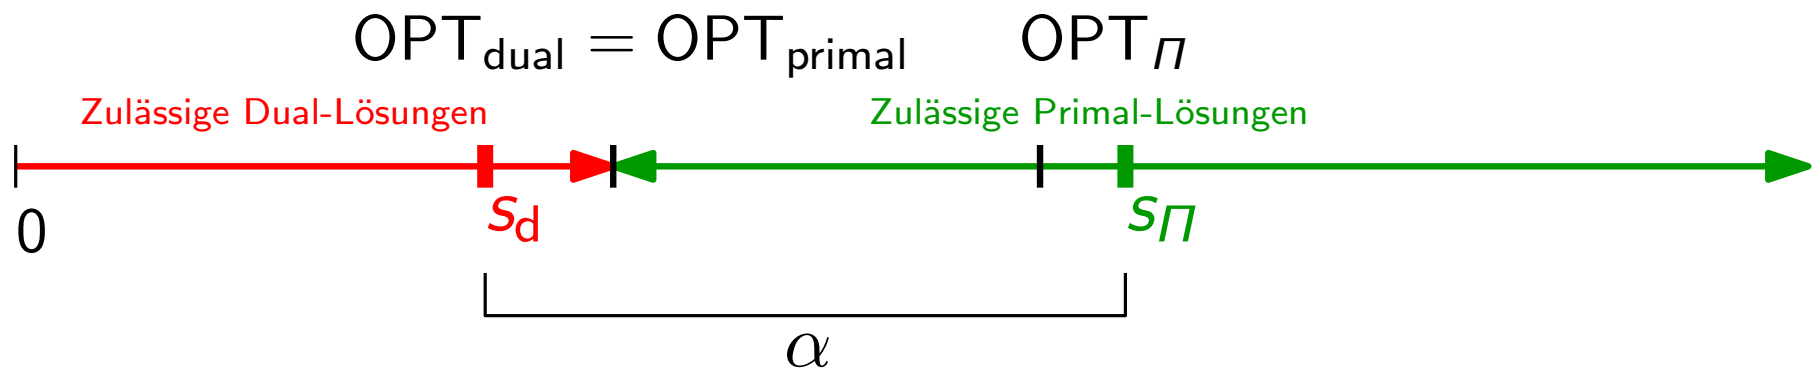
- Lineare Programmierung (LP) und LP-Dualität
- Min-Max-Beziehungen
- Techniken LP-basierten Algorithmendesigns

I) LP-Runden



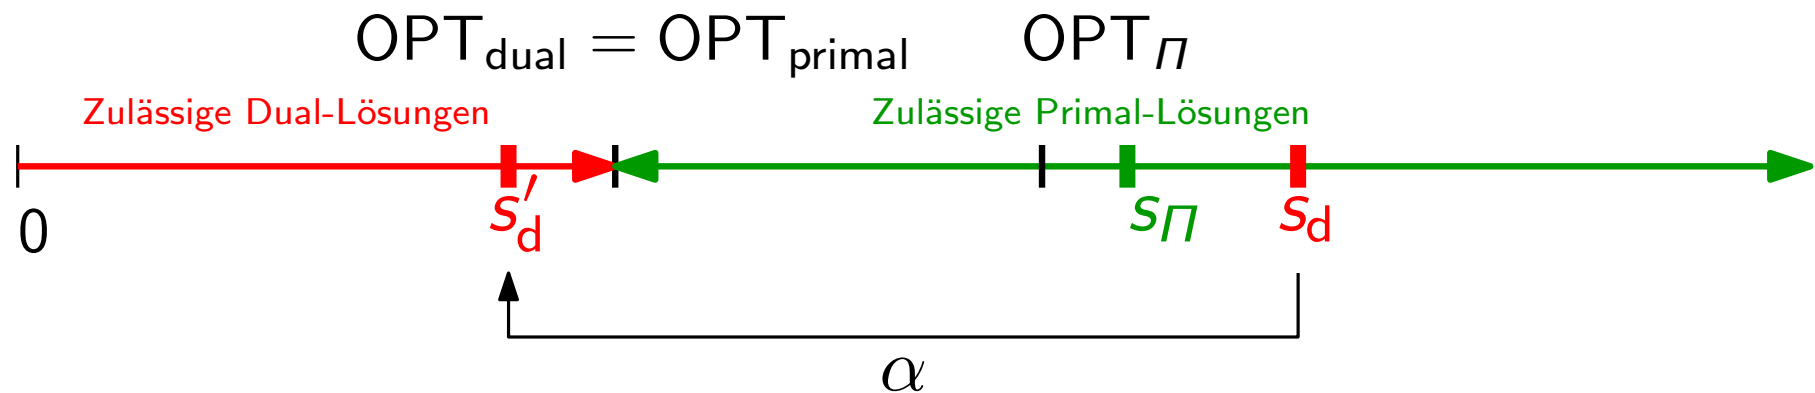
- Betrachte Minimierungsproblem Π in ILP-Form
- Berechne Lösung der LP-Relaxierung
- Runde zu ganzzahliger Lösung für Π
- Schwierigkeit: **Zulässige** Lösung für Π
- Approximationsgüte $\leq ALG / OPT_{\text{relax}} \leq \alpha$

II) Primal-Dual-Ansatz



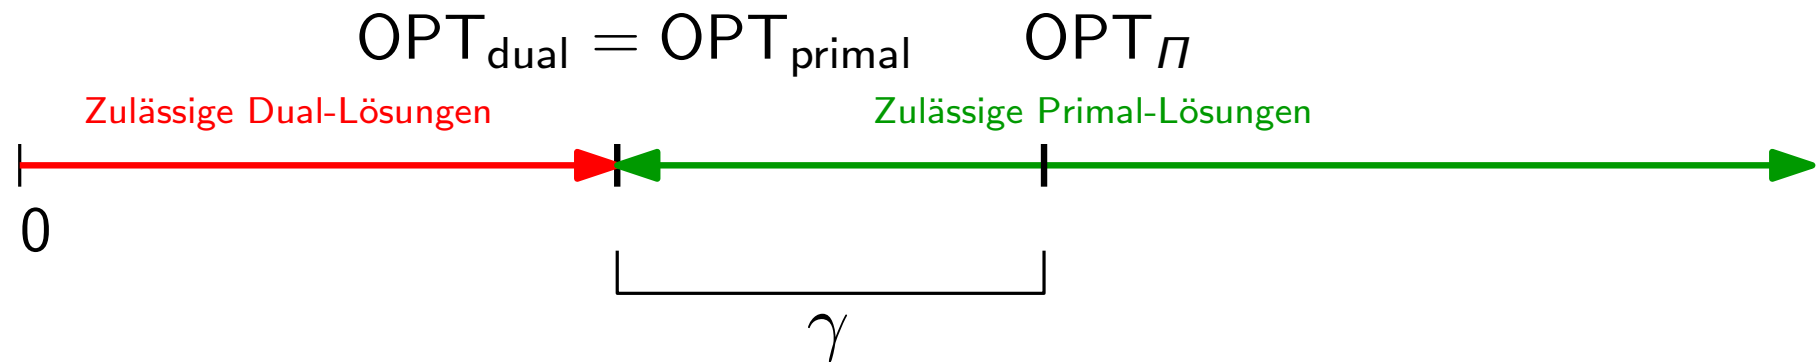
- Betrachte Minimierungsproblem Π in ILP-Form.
- Starte mit (trivialer) zulässiger Duallösung und unzulässiger Primallösung (z.B. alle Variable = 0).
- Berechne **duale** Lösung s_d und ganzzahlige Lösung s_Π für Π iterativ: erhöhe s_d entspr. KS und mache s_Π „ganzzahliger“.
- Approximationsgüte $\leq \text{obj}(s_\Pi)/\text{obj}(s_d)$
- Vorteil:
Kommt ohne LP-„Maschinerie“ aus; ggf. schneller, flexibler.

III) Dual Fitting



- Betrachte Minimierungsproblem Π in ILP-Form.
- Kombinatorischer Algorithmus berechnet zul. Lösung s_Π und „unzulässige“ Duallösung s_d , die s_Π „voll auszahlt“, d.h. $\text{obj}(s_\Pi) \leq \text{obj}(s_d)$.
- Skalieren Dualvariablen, so dass neue Duallösung s'_d zulässig.
 $\Rightarrow \text{obj}(s_\Pi)/\alpha = \text{obj}(s'_d) \leq \text{OPT}_{\text{dual}} \leq \text{OPT}_\Pi$
 \Rightarrow Skalierungsfaktor α ist Approximationsfaktor.

Wichtig: Integrality Gap



- Betrachte Minimierungsproblem Π in ILP-Form.
- Ohne Ausnutzung weiterer Eigenschaften sind alle diese Methoden höchstens so gut wie das *Integrality Gap* der LP-Relaxierung:

$$\sup_I \frac{\text{OPT}(I)}{\text{OPT}_{\text{primal}}(I)}$$