

Vorlesung
Kombinatorische Optimierung
(Wintersemester 2018/19)

Kapitel 7: Relaxierungen und duale Schranken

Volker Kaibel

Otto-von-Guericke Universität Magdeburg

(Version vom 17. Januar 2019)

Das TSP-Polytope

Definition 7.1

Für $n \geq 3$ heißt

$$\text{TSP}(n) = \text{conv} \{ \mathcal{X}(H) \mid H \subseteq E_n \text{ Hamilton-Kreis} \}$$

des **(symmetrische) Traveling-Salesman Polytop**

($K_n = (V_n, E_n)$ mit $V_n = [n]$ sei der vollständige Graph auf n Knoten).

“Unmöglichkeit” einer vollständigen Beschreibung

Satz 7.2

Falls es für jedes $n \geq 3$ eine Matrix $A^{(n)} \in \mathbb{Q}^{M(n) \times E_n}$ und einen Vektor $b^{(n)} \in \mathbb{Q}^{M(n)}$ mit Einträgen, deren Kodierungslängen polynomial in n beschränkt sind, mit

$$\text{TSP}(n) = \{x \in \mathbb{R}^n \mid A^{(n)}x \leq b^{(n)}\}$$

gibt, so dass das Entscheidungsproblem

Gegeben $a \in \mathbb{Q}^{E_n}, \beta \in \mathbb{Q}$; ist (a, β) eine Zeile von $(A^{(n)}, b^{(n)})$?

in NP ist, so ist $\text{NP} = \text{coNP}$.

Bemerkungen

- ▶ Wir können also keine vollständige Beschreibung von $TSP(n)$ erwarten.
- ▶ Partielle Beschreibungen (und effiziente Separationsalgorithmen) helfen jedoch entscheidend, die dualen Schranken in Branch-and-Cut Algorithmen zu verbessern.
- ▶ Besonders interessant: Ungleichungen, die Facetten (d. h. Seiten der Dimension $\dim(TSP(n)) - 1$) von $TSP(n)$ definieren.

Grundlegendes zum TSP-Polytop

Satz 7.3

Für $n \geq 3$ gilt:

$$\text{aff}(\text{TSP}(n)) = \{x \in \mathbb{R}^{E_n} \mid x(\delta(v)) = 2 \text{ für alle } v \in V_n\}$$

Insbesondere:

$$\dim(\text{TSP}(n)) = |E_n| - n = \frac{n(n-3)}{2}$$

Bemerkung 7.4

Für $x \in \text{aff}(\text{TSP}(n))$ und $\emptyset \neq S \subsetneq V_n$ gilt:

$$x(\delta(S)) \geq 2 \Leftrightarrow x(E_n[S]) \leq |S| - 1$$

(Subtour-Eliminationsbedingungen)

Das Subtour-Polytop

Definition 7.5

Das Polytop $\text{SUB}(n)$ aller $x \in \mathbb{R}^{E_n}$ mit

$$\begin{aligned} x(\delta(v)) &= 2 && \text{für alle } v \in V_n \\ (*) \quad x(E_N[S]) &\leq |S| - 1 && \text{für alle } S \subseteq V_n, 3 \leq |S| \leq n - 3 \\ x &\leq \mathbb{1}_{E_n} \\ x &\geq \mathbb{0}_{E_n} \end{aligned}$$

heißt das **Subtour-Polytop**.

Satz 7.6

Es gilt

$$\text{TSP}(n) \subseteq \text{SUB}(n)$$

Die ganzzahligen Vektoren in $\text{SUB}(n)$ sind genau die charakteristischen Vektoren von Hamilton-Kreisen in K_n , also die Ecken von $\text{TSP}(n)$. Die Ungleichungen in der Definition von $\text{SUB}(n)$ definieren (paarweise verschiedene) Facetten von $\text{TSP}(n)$.


Die Kamm-Ungleichungen

Satz 7.7

Seien $T_1, \dots, T_S \subseteq V_n$ paarweise disjunkt ($S \geq 3$ ungerade) und $S \subseteq V_n$ so, dass $S \cap T_i \neq \emptyset$ und $T_i \setminus S \neq \emptyset$ für alle $i \in [S]$. Dann gilt für jedes $x \in \text{TSP}(n)$ die **Kamm-Ungleichung**

$$x(\delta(S)) + \sum_{i=1}^S x(\delta(T_i)) \geq 3s + 1.$$

Alle diese Ungleichungen definieren Facetten von $\text{TSP}(n)$.




Bemerkungen

- ▶ Es ist kein polynomialer Separationsalgorithmus für die Kamm-Ungleichungen bekannt.
- ▶ Spezialfall $|T_i| = 2$ für alle $i \in [S]$: **2-Matching Ungleichungen** (polynomialer Separationsalgorithmus bekannt).
- ▶ **Cliquen-Baum Ungleichungen**: Verallgemeinerung der Kamm-Ungleichungen; ebenfalls Facetten-definierend
- ▶ Zahlreiche weitere Klassen Facetten-definierender Ungleichungen sind bekannt (viele sind nützlich in der Praxis)

Kamm-Ungleichung in Aktion...

Sei $x^* \in \mathbb{R}^{E_{12}}$ der in folgendem Bild dargestellte Punkt, wobei gestrichelte Kanten den Wert $\frac{1}{2}$ und durchgezogene Kanten den Wert 1 repräsentieren.



... Kamm-Ungleichung in Aktion

- ▶ Es ist $x^* \in \text{SUB}(12)$.
- ▶ x^* erfüllt alle 2-Matching-Ungleichungen.
- ▶ Aber er verletzt die Kamm-Ungleichung mit
 - ▶ $S = \{1, 2, 3, 4, 5, 6\}$
 - ▶ $T_1 = \{1, 11\}$
 - ▶ $T_2 = \{2, 12\}$
 - ▶ $T_3 = \{5, 6, 7, 8\}$,

denn:

$$x(\delta(S)) = 1 + 1 + \frac{1}{2} + \frac{1}{2} = 3$$

$$x(\delta(T_1)) = \frac{1}{2} + \frac{1}{2} + \frac{1}{2} + \frac{1}{2} = 2$$

$$x(\delta(T_2)) = \frac{1}{2} + \frac{1}{2} + \frac{1}{2} + \frac{1}{2} = 2$$

$$x(\delta(T_3)) = \frac{1}{2} + \frac{1}{2} + \frac{1}{2} + \frac{1}{2} = 2$$

Die Subtour-Schranke für das TSP(n)

- Wegen

$$x(\delta(S)) = x(\delta(V_n \setminus S))$$

und

$$x(E_n[S]) \leq |S| - 1 \Leftrightarrow x(\delta(S)) \geq 2$$

(für $x \in \text{aff}(\text{TSP}(n))$ ist $\min\{\langle c, x \rangle \mid x \in \text{SUB}(n)\}$ gleich

$$\begin{array}{ll}
 \min & \langle c, x \rangle \\
 \text{s.t.} & x(\delta(v)) = 2 \quad \forall v \in V_n \\
 & x(E_n) = n \\
 & x(E_n[S]) \leq |S| - 1 \quad \forall \emptyset \neq S \subseteq \{2, \dots, n\} \\
 & x \leq \mathbb{1}_{E_n} \\
 & x \geq \mathbb{0}_{E_n}
 \end{array}$$

Das 1-Baum-Polytop

Satz 7.8

$$\{x \in [0, 1]^{E_n} : x(E_n) = n, x(\delta(1)) = 2, \\ x(E_n[S]) \leq |S| - 1 \text{ für alle } \emptyset \neq S \subseteq \{2, \dots, n\}\}$$

=

$$\text{conv} \{ \mathcal{X}(T) \mid T \subseteq E_n \text{ 1-Baum} \} =: 1B(n)$$

Folgerung

$$\min \{ \langle c, x \rangle \mid x \in \text{SUB}(n) \}$$

=

$$\min \{ \langle c, x \rangle \mid x(\delta(v)) = 2 \forall v \in \{2, \dots, n\}, x \in 1B(n) \}$$

Lagrange-Relaxierung (Kap. 4 *Lineare Optimierung*)

- ▶ Seien $X^{(0)} \subseteq \mathbb{R}^k$ konvex und abgeschlossen,
 $A \in \mathbb{R}^{m \times k}$, $b \in \mathbb{R}^m$,
 $C \in \mathbb{R}^{p \times k}$, $d \in \mathbb{R}^p$
- ▶ Die Lagrange-Funktion zu

$$\min \left\{ \langle c, x \rangle : Ax \leq b, Cx = d, x \in X^{(0)} \right\}$$

ist dann $L_D : \mathbb{R}_+^m \times \mathbb{R}^p \rightarrow \mathbb{R}$ mit

$$L_D(\lambda, \mu) = \min \{ \langle c, x \rangle + \lambda^T (Ax - b) + \mu^T (Cx - d) \mid x \in X^{(0)} \}$$

- ▶ Es gilt die starke Lagrange-Dualität:

$$\min \{ \langle c, x \rangle \mid Ax \leq b, Cx = d, x \in X^{(0)} \}$$

=

$$\max \{ L_D(\lambda, \mu) \mid \lambda \in \mathbb{R}_+^m, \mu \in \mathbb{R}^p \}$$

Subgradienten-Verfahren

- ▶ L_D ist eine konkave Funktion.
- ▶ Maximierung von L_D (bzw. Minimierung der konvexen Funktion $-L_D$) z. B. mittels **Subgradienten-Verfahrens**
- ▶ Starte mit beliebigen $\lambda^{(0)} \in \mathbb{R}_+^m, \mu \in \mathbb{R}^P$.
- ▶ In der i -ten Iteration:
 - ▶ Finde Optimallösung $x^{(i)} \in X^{(0)}$ mit

$$L_D(\lambda^{(i-1)}, \mu^{(i-1)}) = \min\{\langle c, x \rangle + (\lambda^{(i-1)})^T (Ax - b) + (\mu^{(i-1)})^T (Cx - d) \mid x \in X^{(0)}\}$$

(Lösung des **Lagrange-Subproblems**)

- ▶ Der Vektor

$$(\tilde{\lambda}, \tilde{\mu}) = -(Ax^{(i-1)} - b, Cx^{(i-1)} - d) \in \mathbb{R}^m \times \mathbb{R}^P$$

ist ein **Subgradient** der konvexen Funktion

$f(\lambda, \mu) = -L_D(\lambda, \mu)$ im Punkt $(\lambda^{(i-1)}, \mu^{(i-1)})$, d. h.

$$f(\lambda, \mu) - f(\lambda^{(i-1)}, \mu^{(i-1)}) \geq \langle (\tilde{\lambda}, \tilde{\mu}), (\lambda - \lambda^{(i-1)}, \mu - \mu^{(i-1)}) \rangle$$

für alle $(\lambda, \mu) \in \mathbb{R}^m \times \mathbb{R}^P$.

Subgradienten-Verfahren

- ▶ ... in der i -ten Iteration:

- ▶ Bestimmung von $(\lambda^{(i)}, \mu^{(i)})$: Wähle einen Multiplikator $\alpha_i > 0$ und setze $\lambda^{(i)}$ auf das komponentenweise Maximum von \mathbb{O}_m und

$$\lambda^{(i-1)} - \alpha_i \tilde{\alpha} = \alpha^{(i-1)} + \alpha_i (Ax^{(i-1)} - b)$$

sowie $\mu^{(i)}$ auf

$$\mu^{(i-1)} + \alpha_i (Cx^{(i-1)} - d).$$

- ▶ Für geeignete Wahl der α_i (z.B. so, dass $\alpha_i \rightarrow 0$, $\sum_{i=1}^{\infty} \alpha_i = \infty$) konvergiert $(\lambda^{(i)}, \mu^{(i)})$ gegen eine Optimallösung von

$$\max\{L_D(\lambda, \mu) \mid \lambda \in \mathbb{R}_+^m, \mu \in \mathbb{R}^p\}.$$

Bemerkungen zu Subgradienten

Ein Subgradient. . .

- ▶ ... $v \in \mathbb{R}^n$ einer konvexen Funktion $g : \mathbb{R}^n \rightarrow \mathbb{R}$ in $x^* \in \mathbb{R}^n$ ist der Gradient einer affinen Funktion, die g überall unterschätzt und in x^* mit g übereinstimmt (d.h. $g(x) \geq g(x^*) + \langle v, x - x^* \rangle$ für alle $x \in \mathbb{R}^n$).
- ▶ Konvexe Funktionen haben stets Subgradienten (i. A. nicht eindeutig).
- ▶ Ist g in x^* sogar differenzierbar, so ist der Gradient von g im Punkt x^* der einzige Subgradient von g in x^* .

Held-Karp-Schranken für das TSP

- ▶ Wähle $X^{(0)} = 1B(n)$ und löse

$$\min\{\langle c, x \rangle \mid x(\delta(v)) = 2 \text{ für alle } v \in \{2, \dots, n\}, x \in X^{(0)}\}$$

mit Lagrange-Relaxierung.

- ▶ Lösen der Lagrange-Subprobleme: Sehr effiziente Bestimmung kostenminimaler 1-Bäume (mit von $\mu^{(i-1)}$ abhängigen Gewichten).
- ▶ In der Praxis erhält man oft sehr gute Schranken schon nach relativ wenigen Iterationen; bei sehr großen Instanzen ($n > 100000$) wesentlich schneller als LP-Algorithmen.