


### 3.) MATCHING LP-Relaxierung als (exakter Algorithmus)

Eingabe:  $G(V, E)$  mit Kantengewichten  $w_e$

Ausgabe: Ein Matching  $M \subseteq E$  mit maximalem Gesamtgewicht der Kanten in  $M$   
(die Kanten in  $M$  haben keine gemeinsame Endknoten)

#### LP-Relaxierung:

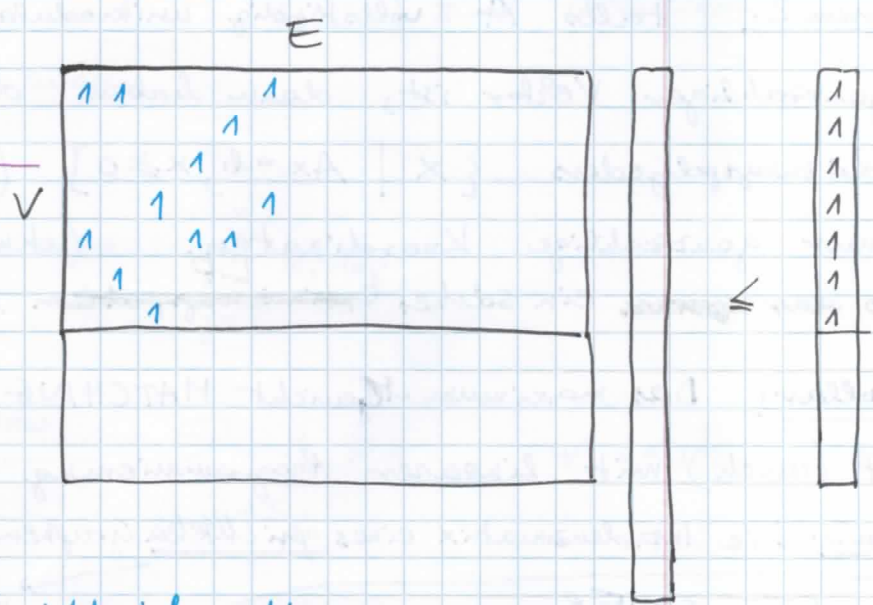


maximiere  $\sum_{e \in E} x_e \cdot w_e$

so dass  $\sum_{u: \{v, u\} \in E} x_{\{v, u\}} \leq 1 \quad \forall v \in V$

$0 \leq x_e \leq 1 \quad \forall e \in E$

die Matrix für diese Bedingungen ist die Knoten-Kanten-Inzidenzmatrix



(hier gibt es auch ~~ganzzahlige~~ nicht-informative fraktionale Lösungen, z.B. für einen vollständigen Graphen  $x_e = \frac{1}{n-1}$  ist eine gültige aber nicht verwertbare Lösung, mit Wert  $\frac{n(n-1)}{2} \cdot \frac{1}{n-1} = \frac{n}{2}$  aber:)



LP. 43.

# max-BIPARTITE MATCHING

Für bipartite Graphen hat die Inzidenzmatrix

eine wichtige Eigenschaft:

Definition: Eine Matrix  $A$  heißt vollständig unimodular, falls die Determinante  $\det B \in \{-1, 0, 1\}$  für jede quadratische Teilmatrix  $B$  von  $A$  gilt.

(Insbesondere sollen alle Einträge 1, 0 oder -1 sein)

Theorem 1. Die Inzidenzmatrix für einen ungerichteten Graphen

ist genau dann vollständig unimodular, wenn der Graph

bipartit ist. (ohne Beweis)  $\left[ \begin{array}{l} (\Rightarrow) \text{ ungerader Kreis: } \begin{matrix} 1 & 1 \\ & 1 & 1 \\ & & 1 & 1 \\ & & & 1 & 1 \\ & & & & 1 & 1 \\ & & & & & 1 & 1 \end{matrix} \\ \text{hat Det} = 2 \end{array} \right.$

Theorem 2. Falls  $A$  vollständig unimodular, und  $b$  ein

ganzzahliger Vektor ist, dann haben die Ecken des

Lösungspolyeders  $\{x \mid Ax = b, x \geq 0\}$  (bzw.  $\{x \mid Ax \geq b\}$ )

nur ganzzahlige Koordinaten. (ohne Beweis)

$\Rightarrow$  ~~das LP~~ ein solches LP besitzt eine ganzzahlige optimale Lösung

Korollar: Das maximum-Gewicht MATCHING Problem für bipartite Graph

ist (auch) mit linearer Programmierung exakt lösbar. (Warum?)

Theorem 3. Die Inzidenzmatrix eines gerichteten Graphen ist immer vollständig

4.) SET COVER

$\begin{matrix} (v,w) \\ v \\ w \end{matrix} \begin{matrix} 1 \\ -1 \end{matrix}$  ganzzahl. unimodular  $\Rightarrow$  Flussprobleme haben ganzzahl. Lösungen

Eingabe: Grundmenge  $\{1, 2, 3, \dots, m\}$

$n$  Teilmengen  $S_j \subseteq \{1, 2, \dots, m\}$   $j = 1, 2, \dots, n$

mit Gewichten  $w_j$

Ausgabe: Eine Überdeckung von  $\{1, 2, \dots, m\}$  mit einer leichtesten Auswahl ~~von~~ Teilmengen

$C \subseteq \{1, 2, \dots, n\}$




$C$  ist die Indexmenge der ausgewählten Teilmengen  $S_j$ .

$C$  ist eine Überdeckung der Grundmenge, wenn jedes Element  $1 \leq i \leq m$  ist Element von mindestens einer ausgewählten Teilmenge  $i \in S_j$  ( $j \in C$ )

Beispiel:

Grundmenge



$$S_1 = \{3, 4, 5, 8\}$$

$$S_2 = \{1\}$$

$$S_3 = \{1, 3, 5, 7, 9\}$$

$$S_4 = \{2, 4, 10\}$$

$$S_5 = \{2, 3, 4, 5, 6\}$$

$$S_6 = \{2, 6, 10\}$$

$\{S_1, S_3, S_4, S_5\}$  und  $\{S_1, S_3, S_6\}$  sind verschiedene Mengenüberdeckungen.

LP-Relaxierung:

minimiere  $\sum_{j=1}^n x_j \cdot w_j$

Element  $i$  überdeckt wird

so dass  $\leftarrow$

$$\sum_{j: i \in S_j} x_j \geq 1$$

$$\forall i = 1, 2, \dots, m$$

( $m$  Bedingungen)

$$0 \leq x_j \leq 1$$

beabsichtigte Bedeutung:  $x_j = \begin{cases} 1 & \text{falls } S_j \text{ in der Überdeckung} \\ 0 & \text{sonst.} \end{cases}$  ( $j \in C$ )

~~Das~~ SET COVER ist eine Verallgemeinerung des VERTEX COVER Problems

Kanten  $\leftrightarrow$  Elemente  $1, 2, \dots, m$

Knoten  $\leftrightarrow$  Teilmengen  $S_j$



Analog zur 2-Approximierung mit deterministischem Runden für VERTEX COVER wird folgendes gezeigt:

Thm: Falls jedes Element  $i$  der Grundmenge in höchstens  $l$  Teilmengen  $S_j$  enthalten ist, dann ergibt ein deterministisches Runden der optimalen fraktionalem Lösung eine  $l$ -approximative Lösung. (siehe Übung)

(beachte, dass im Spezialfall vom VERTEX COVER  $l=2$  gilt, da jede Kante (=Element) zwei Endknoten (=Teilmengen) hat.)

Für den allgemeinen Fall ohne solche  $l$ :

Ein Approximationsalgorithmus (randomisiertes Runden)

(die Idee: wir lösen die LP-Relaxierung. Die optimale fraktionale Lösung  $(x_1^* x_2^* \dots x_n^*)$  bestimmt die Wahrscheinlichkeiten  $x_j^*$ , dass die entsprechende Teilmenge  $S_j$  in die Mengenüberdeckung gewählt wird ( $\text{Prob}(j \in C) = x_j^*$ ). ABER: erhalten wir so tatsächlich eine Überdeckung aller Elemente der Grundmenge? **NEIN**)

$\Rightarrow$  mehrere ( $T$ ) solche zufällige "Überdeckungen" werden vereinigt:

- löse die LP-Relaxierung;

sei  $x^* = [x_1^* x_2^* \dots x_n^*]$  eine optimale fraktionale Lösung

- FOR  $t=1$  to  $T$  do  
 - setze  $C_t = \emptyset$   
 - FOR  $j=1$  to  $n$  do

sei  $j \in C_t$  mit Wahrscheinlichkeit  $x_j^*$

- gib die Vereinigung  $C = \bigcup_{t=1}^T C_t$  der  $T$  zufällig gewählten "Überdeckungen"  $C_t$  als Lösung aus.



Theorem 1. Mit der Wahl  $T = km + 1$  für die Anzahl der Runden erhalten wir eine vollständige Überdeckung der Grundmenge mit Wahrscheinlichkeit mindestens  $\frac{1}{2}$ . (Wann reicht das? Siehe bei Monte Carlo Algorithmen!)

{ Beweis:


Die Wahrscheinlichkeit dass ein konkretes Element  $i$  in einer Runde  $t$  nicht überdeckt wird (d.h. mit  $C_t$ ) ist höchstens  $\frac{1}{e}$ .

Wann? Sei o.B.d.A  $i$  in den ersten  $k$  Mengen  $S_1, S_2, \dots, S_k$  enthalten. Wegen der LP-Bedingungen, für die fraktionale Lösung  $[x_1^*, x_2^*, \dots, x_k^*]$  gilt  $x_1^* + x_2^* + \dots + x_k^* \geq 1$ . ( $\otimes$ )

Die Wahrscheinlichkeit, dass  $i$  in einer Runde nicht überdeckt wird, ist  $\rightarrow$  Prob. ( $i \notin C_t$ )

Prob ( $i$  wird nicht überdeckt) =  $(1-x_1^*) \cdot (1-x_2^*) \cdot \dots \cdot (1-x_k^*)$

$\leq \left(1 - \frac{1}{k}\right)^k \leq \left(e^{-\frac{1}{k}}\right)^k = \frac{1}{e}$



$\rightarrow$  geometrisches Mittel:  $\sqrt[k]{(1-x_1) \cdot (1-x_2) \cdot \dots \cdot (1-x_k)}$

arithmetisches Mittel:  $\frac{k - (x_1 + x_2 + \dots + x_k)}{k} \leq \frac{k-1}{k} = 1 - \frac{1}{k}$

geom  $\leq$  arithm.

$(1-x_1)(1-x_2) \dots (1-x_k) \leq \left(1 - \frac{1}{k}\right)^k$

( $\otimes$ )



- Die Wahrscheinlichkeit, dass  $i$  nach  $T$  Runden immer noch nicht überdeckt wird, ist höchstens

$$\left(\frac{1}{e}\right)^T$$

- Sei  $A_i$  das Ereignis, dass Element  $i$  nach  $T$  Runden nicht überdeckt wird. Dann ist  $A_1 \cup A_2 \cup \dots \cup A_m$  das Ereignis, dass die Grundmenge nicht vollständig überdeckt wird. Es gilt:  $\text{Prob}(A_i) \leq \left(\frac{1}{e}\right)^T$

$$\text{Prob}(A_1 \cup A_2 \cup \dots \cup A_m) \leq \text{Prob}(A_1) + \text{Prob}(A_2) + \dots + \text{Prob}(A_m)$$



$$\leq m \cdot \left(\frac{1}{e}\right)^T = \frac{m}{e^T} = \frac{m}{e^{\ln m + 1}} = \frac{m}{m \cdot e} \leq \frac{1}{2}$$

Theorem 2. Das erwartete Gewicht der Ausgabe  $C = \bigcup_t C_t$  ist höchstens  $(\ln m + 1) \cdot \text{OPT}_{\text{SET COVER}}$

Beweis:

Das erwartete Gewicht eines  $C_t$  ist  $\leq \text{OPT}_{\text{SET COVER}}$

und von allen  $C_t$  ist es  $\leq T \cdot \text{OPT}_{\text{SET COVER}} =$

$$= (\ln m + 1) \cdot \text{OPT}_{\text{SET COVER}}$$

Warum ist das erwartete Gewicht (Erwartung

über die zufällige ~~Wahl~~ <sup>Hinzunahme</sup> von  $j$  mit Prob  $x_j^*$  für

alle  $j = 1 \dots n$ ) von  $C_t \leq \text{OPT}$ ?

Sei die Zufallsvariable  $W_j$  das Gewicht von  $S_j$  in

der "Überdeckung"  $C_t$ . Dann ist  $W_j = \begin{cases} w_j & \text{mit Prob } x_j^* \\ 0 & \text{mit Prob } 1 - x_j^* \end{cases}$

$$E[W_j] = w_j \cdot x_j^* + 0 \cdot (1 - x_j^*)$$

das erwartete Gewicht von  $C_t$  ist  $E[W_1 + W_2 + W_3 + \dots + W_n] =$

$$= E[W_1] + E[W_2] + \dots + E[W_n] = \sum_j w_j \cdot x_j^* = \text{OPT}_{\text{FRAC}} \leq \text{OPT}_{\text{SET COVER}}$$

## Dualität in der linearen Programmierung

Illustration  
Beispiel:

(siehe Vazirani 12.1)

$$\text{minimiere } 7x_1 + x_2 + 5x_3$$

so dass

$$x_1 - x_2 + 3x_3 \geq 10$$

(P)


$$5x_1 + 2x_2 - x_3 \geq 6$$

$$x_1, x_2, x_3 \geq 0$$

(ein LP in kanonischer Form)

Statt dieses LP zu lösen, werden wir <sup>versuchen</sup> „schneller“  
(obere und) untere Schranken für  
den optimalen Wert OPT finden

alle  $c^T \cdot x = 7x_1 + x_2 + 5x_3$   
Zielwerte der Lösungen



- jede Lösung ergibt eine obere Schranke  
für OPT

$$\text{z.B. } x = (2, 1, 3)$$

→ erfüllt die Nebenbedingungen:

$$x_1, x_2, x_3 \geq 0 \quad \checkmark$$

$$2 - 1 + 3 \cdot 3 \geq 10 \quad \checkmark$$

$$5 \cdot 2 + 2 \cdot 1 - 3 = 9 \geq 6 \quad \checkmark$$

→ und hat Zielwert

$$\begin{aligned} 7x_1 + x_2 + 5x_3 &= \\ &= 7 \cdot 2 + 1 + 5 \cdot 3 = 30 \end{aligned}$$

---

Wie findet man gute untere Schranken  
für OPT?

1.) Eine einfache untere Schranke:

$$7 \cdot x_1 + x_2 + 5 \cdot x_3 \geq x_1 - x_2 + 3x_3 \geq \underline{10}$$

gilt Term  
für Term, weil  
 $x_1, x_2, x_3 \geq 0$

Nebenbedingung

10 ist untere Schranke für den Zielwert jeder  
Lösung, also auch für OPT



2.) eine bessere untere Schranke:

weil  $x_1, x_2, x_3 \geq 0$

$$6x_1 + x_2 + 2x_3$$

$$7x_1 + x_2 + 5x_3 \geq (x_1 - x_2 + 3x_3) + (5x_1 + 2x_2 - x_3) \geq$$

$$\geq 10 + 6 = \underline{16}$$

laut Nebenbedingungen

3.) eine noch bessere untere Schranke für OPT

Term für Term weil  $x_1, x_2, x_3 \geq 0$

$$7x_1 + x_2 + 5x_3 \geq 2 \cdot (x_1 - x_2 + 3x_3) + (5x_1 + 2x_2 - x_3)$$

$$\geq 2 \cdot 10 + 6 = \underline{26}$$

laut Nebenbedingungen

4.) Allgemeine Idee: finden wir

$$y_1 \geq 0 \text{ und } y_2 \geq 0$$

so dass

$c^T \cdot x$

$y^T \cdot A \cdot x$

$$7x_1 + x_2 + 5x_3 \geq y_1 (x_1 - x_2 + 3x_3) + y_2 (5x_1 + 2x_2 - x_3)$$

$$\geq y_1 \cdot 10 + y_2 \cdot 6 \rightarrow \text{untere Schranke für OPT}$$

gibt laut Nebenbedingungen, weil  $y_1, y_2 \geq 0$

Wir brauchen also:

$$(B) \quad y_1, y_2 \geq 0$$

Und, für die Koeffizienten von  $x_1, x_2, x_3$

$$7 \geq y_1 + 5y_2$$

$$1 \geq -y_1 + 2y_2 \quad (D)$$

$$5 \geq 3y_1 + (-y_2)$$

und  $10 \cdot y_1 + 6y_2$  so groß wie möglich.

(maximiere  $10 \cdot y_1 + 6y_2$  unter den  
obigen Bedingungen)

das ist ein anderes LP, ein  
Maximierungsprogramm

(D) ist das sog. duale LP von (P)

(und umgekehrt: (P) ist auch das duale  
LP von (D))