

$$E[x_i] = 1 \cdot \text{Prob}(P_i \text{ benutzt } e) + 0 \cdot \text{Prob}(P_i \text{ benutzt } e \text{ nicht}) =$$

$$= 1 \cdot \sum_{j: e \in P_{i,j}} \alpha_{i,j} \leq x_i(e) \rightarrow \text{erwartete Belastung über } e \text{ wegen } P_i$$

erwartete Belastung über e wegen $P_1, P_2, \dots, P_i, \dots, P_r$

$$E[X] \leq \sum_{i=1}^r x_i(e) \leq W_{\text{OPT}}^{\text{frac.}} \leq W_{\text{OPT}}$$

Die maximale erwartete Belastung über Kanten ist somit $\leq W_{\text{OPT}}$

Bemerkung: Die erwartete maximale Belastung über Kanten

könnte trotzdem groß werden. Aber: mit $\text{Prob} > 1 - \epsilon$

$$\text{ist die maximale Belastung} \leq W_{\text{OPT}} + \sqrt{3W_{\text{OPT}} \cdot \ln \frac{n^2}{\epsilon}}$$

6.) MAX-SAT

Beispiel: eine Formel in konjunktiver Normalform (CNF)

$$(x_1 \vee x_2) \wedge (x_1 \vee \neg x_2) \wedge (\neg x_1 \vee x_2) \wedge (\neg x_1 \vee \neg x_2)$$

gesucht wird eine Wahrheitsbelegung

$$\{x_1, x_2\} \rightarrow \{\text{TRUE}, \text{FALSE}\},$$

die eine maximale Anzahl von Klauseln erfüllt

Was ist das Optimum in unserem Beispiel?

(Variablen: x_1, x_2)

diterale: $x_1, \neg x_1, x_2, \neg x_2$

Klausel: $(x_1 \vee \neg x_2)$ usw.)

gewichtetes max-SAT

Eingabe: eine Menge K von Klauseln, wobei Klausel k

das Gewicht w_k besitzt

mit Literalen aus $\{x_1, \neg x_1, x_2, \neg x_2, \dots, x_n, \neg x_n\}$

Ausgabe: Eine Wahrheitsbelegung die eine Klauselmeng

von größtmöglichem Gesamtgewicht erfüllt.

LP 55.

Algorithmus 1. deterministische 2-Approximation \rightarrow ist einfach

siehe Übung

Algorithmus 2. Randomisierung für lange Klauseln

FOR $i=1$ to n DO:

setze $x_i=1$ mit Wahrscheinlichkeit $\frac{1}{2}$ und bzw.

$x_i=0$ mit Wahrscheinlichkeit $\frac{1}{2}$

Lange Klausel werden mit hoher Wahrscheinlichkeit erfüllt.
(z.B. $x_1 \vee x_2 \vee \neg x_4 \vee x_6 \vee \neg x_7$) $l=5$

Sei k eine Klausel der Länge l

$$\text{Prob}(k \text{ wird nicht erfüllt}) = \underbrace{\frac{1}{2} \cdot \frac{1}{2} \cdot \frac{1}{2} \cdot \dots \cdot \frac{1}{2}}_l = \left(\frac{1}{2}\right)^l$$

$$\text{Prob}(k \text{ wird erfüllt}) = 1 - \frac{1}{2^l}$$

Insbesondere: Wenn alle Klauseln mindestens l Literale besitzen,
dann ist das erwartete Gewicht erfüllter Klauseln

$$\text{mindestens } \sum_k \left(1 - \frac{1}{2^l}\right) \cdot w_k = \left(1 - \frac{1}{2^l}\right) \sum_k w_k \geq \left(1 - \frac{1}{2^l}\right) W_0$$

(Wann?)

Sei die Zufallsvariable $V_k = \begin{cases} 1 & \text{wenn Klausel } k \text{ erfüllt wird} \\ 0 & \text{sonst} \end{cases}$

Das Gewicht aller erfüllten Klauseln ist dann die Zufallsvariable

$$\sum_k w_k \cdot V_k, \text{ und das erwartete Gewicht}$$

$$E\left[\sum_k w_k V_k\right] = \sum_k w_k E[V_k] \text{ wobei } E[V_k] \geq \left(1 - \frac{1}{2^l}\right) \cdot 1 + \frac{1}{2^l} \cdot 0 = \left(1 - \frac{1}{2^l}\right)$$

IP-Formulierung

- eine Variable y_i wird definiert für jede SAT-Variable x_i
- es wird auch eine Variable z_k für jede Klausel k definiert

Bedeutung: y_i ist die Belegung von x_i (0 oder 1)

$$z_k = \begin{cases} 1 & \text{falls Klausel } k \text{ erfüllt wird} \\ 0 & \text{sonst} \end{cases}$$

maximiere $\sum_{k \in K} w_k \cdot z_k$

so dass

$$\sum_{x_i \in k} y_i + \sum_{\neg x_j \in k} (1 - y_j) \geq z_k \quad \forall k \in K$$

$$z_k, y_i \in \{0, 1\}$$

LP-Relaxierung $0 \leq z_k, y_i \leq 1$

Algorithmus 3: Randomisiertes Runden (für kurze Klauseln)

- löse die LP-Relaxierung;
sei (y^*, z^*) eine optimale fraktionale Lösung
- FOR $i=1$ to n DO
setze $x_i = \text{TRUE}$ zufällig mit Wahrscheinlichkeit y_i^*

Bemerkung:

- für Klausel der Größe ≥ 3 ist die einfache Randomisierung (Alg. 2) besser! Warum?
für die Klausel ~~$x_1 \vee x_2 \vee \dots \vee x_k$~~ $y_i = \frac{1}{2}$ kann schon optimal sein für das LP
- Wenn es nur Klausel der Größe 2 gibt, dann ist die fraktionale Lösung $y_i = \frac{1}{2}$, $z_k = 1$ optimal, und die zwei Algorithmen sind äquivalent.
- für Klausel der Größe 1 ist das randomisierte Runden (Alg. 3.) besser.

Algorithmus 4.

- bestimme eine Belegung mit Algorithmus 2.
- bestimme eine Belegung mit Algorithmus 3.
- gib die bessere Lösung aus!

Theorem: Das erwartete Gewicht belegter Klauseln ist mindestens

$$\frac{3}{4} \cdot \sum_{k \in K} w_k \cdot z_k^* \geq \frac{3}{4} \cdot \text{OPT}(I)$$

(ohne Beweis)

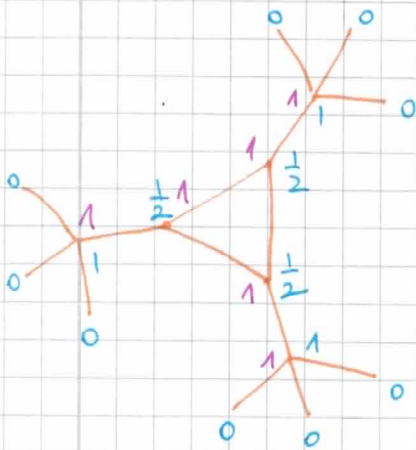
$$\frac{3}{4} \text{OPT}_{\text{frac}}(I)$$

Die Integralitätslücke (integrality gap)


Def: Die Integralitätslücke ist der schlechteste mögliche (größtmögliche) Quotient des ganzzahligen (also eigentlichen) und des fraktionalen Optimum-Wertes für ein gegebenes Problem (-Typ).

Die Integralitätslücke

Beispiel 1. Ein Minimierungsproblem: VERTEX COVER



alle Zielwerte $\sum_i x_i w_i$ der LP-Relaxierung



$$OPT_{\text{frac}} \leq OPT \quad \text{gilt für jede Instanz}$$

→ uns interessiert das (größt) mögliche

Verhältnis $\frac{OPT}{OPT_{\text{frac}}}$ über alle Eingaben

$$G(V, E), w_i \quad (i \in V)$$

→ Finden wir einfache Eingaben für VERTEX COVER, wo dieses Verhältnis ganz klein

$$\text{(d.h. } OPT_{\text{frac}} \approx OPT \text{)}$$

→ Wie groß kann das Verhältnis sein?

Wir wissen von der Analyse des deterministischen Rundens: das optimale fraktionale x^* aufgerundet ergibt eine ganzzahlige Lösung mit höchstens doppeltem Wert $2 \cdot OPT_{\text{frac}}$

↳ für VERTEX COVER das Verhältnis $\frac{OPT(I)}{OPT_{\text{frac}}(I)}$


→ ist höchstens 2

→ kann $2 - \frac{1}{n}$ sein → für einen vollständigen Graph

Für das VERTEX COVER Problem die Integralitätslücke

$\sup_I \frac{OPT(I)}{OPT_{\text{frac}}(I)}$ ist zwischen $2 - \frac{1}{n}$ und 2.

Beispiel 2. Ein Maximierungsproblem: INDEPENDENT SET
 $I = G(V, E)$ Graph (gewichtet/ungewichtet)




Wie groß kann das Verhältnis $\frac{OPT_{frac}(I)}{OPT(I)}$
über alle Eingabeinstanzen I werden?

→ Wir haben ein Beispiel I mit

$$\frac{OPT_{frac}(I)}{OPT(I)} = \frac{n}{2}$$

den vollständigen Graphen



↪ die Integrallücke für das INDEPENDENT SET Problem ist mindestens $\frac{n}{2}$
(auch höchstens - Warum?)

→ Sei P ein Minimierungsproblem.

Für gegebene Instanz I sei $\text{OPT}(I)$ der optimale (ganzzahlige) Wert, und $\text{OPT}_{\text{frac}}(I)$ der optimale (minimale) Wert einer über fraktionale Lösungen der LP-Relaxierung.

→ Generell gilt $\text{OPT}_{\text{frac}}(I) \leq \text{OPT}(I)$ da eine ganzzahlige Lösung auch immer eine fraktionale Lösung ist.

→ Die Integralitätslücke ist das "Worst-Case" Verhältnis

$$\sup_I \frac{\text{OPT}(I)}{\text{OPT}_{\text{frac}}(I)} \quad \text{für Minimierungsprobleme,}$$

$$\text{und} \quad \sup_I \frac{\text{OPT}_{\text{frac}}(I)}{\text{OPT}(I)} \quad \text{für Maximierungsprobleme}$$

Beispiel 1. Für VERTEX COVER ist die Integralitätslücke

- mindestens $\frac{n-1}{\frac{n}{2}} = 2 \left(1 - \frac{1}{n}\right)$

weil für den vollständigen Graphen mit n Knoten $n-1$ ist das Optimum, und $\frac{n}{2}$ (für $(\frac{1}{2}, \frac{1}{2}, \frac{1}{2}, \dots, \frac{1}{2})$) das fraktionale Optimum.

- aber auch höchstens 2 (für beliebige Instanz deterministisches Runden ergibt eine ganzzahlige Lösung mit $2 \cdot \text{OPT}_{\text{frac}}$ Wert).

Beispiel 2. Für INDEPENDENT SET ist die Integralitätslücke

mindestens $\frac{n}{2}$ weil für den vollständigen Graphen

Pelikan ☹️

$$\frac{\text{OPT}_{\text{frac}}}{\text{OPT}} = \frac{\frac{n}{2}}{1} = \frac{n}{2}$$

(auch höchstens $\frac{n}{2}$
Wann?)

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)

(\Rightarrow) ungerader Kreis:
 $\begin{bmatrix} 1 & 1 \\ 1 & 1 \\ & 1 & 1 \\ & & 1 & 1 \\ & & & 1 & 1 \\ & & & & 1 & 1 \\ & & & & & 1 & 1 \\ & & & & & & 1 & 1 \end{bmatrix}$
 hat $\det = 2$

Theorem 2. Falls A vollständig unimodular, und b ein 1 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 Graphen ist (auch) mit linearer Programmierung exakt lösbar. (Warum?)

Theorem 3. Die Inzidenzmatrix eines gerichteten Graphen ist immer vollständig

4.) SET COVER

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

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

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

(m Bedingungen)

$0 \leq x_j \leq 1$

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

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.

Die Approximierbarkeit von SET COVER Problem

Für SET COVER haben wir die folgenden Algorithmen gesehen:

m : Anzahl der zu überdeckenden Elemente

LP-basierte Algorithmen

mit deterministischem Runden:

l -approximativ WENN jedes Element in max. l Teilmengen enthalten

mit randomisiertem Runden:

erwarteter Approximationsfaktor für beliebige Instanzen $\leq lm + 1$

Primal-Dual Algorithmen:

l -approximativ WENN jedes Element in max l Teilmengen enthalten

Hier sehen wir noch einen einfachen Greedy Algorithmus:

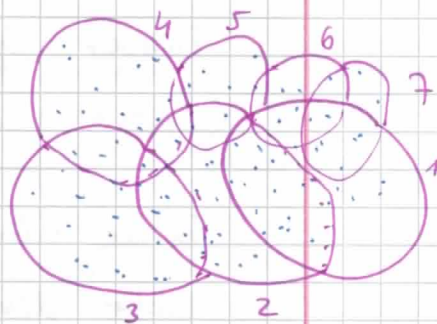
Greedy Algorithmus für SET COVER

Aufwärmung:

für ungeordnetes SET COVER

→ die Mengen S_j der Überdeckung werden iterativ gewählt;

→ in jeder Runde wird die gewählte S_j die meisten noch nicht überdeckten Elemente überdecken



22.

Greedy Algorithmus für SET COVER

$C := \emptyset$

WHILE nicht alle Elemente überdeckt DO

$C := C \cup \{j\}$ falls S_j die meisten noch nicht überdeckten Elemente überdeckt

Gewichtete Variante mit Gewichten w_1, w_2, \dots, w_n der Teilmengen

bezeichne U die Menge der aktuell überdeckten Elemente

→ setze $C = \emptyset$ $U = \emptyset$

→ WHILE $U \neq \{1, 2, \dots, m\}$ DO

→ bestimme eine Menge S_k so dass

$$\frac{|S_k \setminus U|}{w_k} \text{ größtmöglich}$$

(Skript: $\frac{w_k}{|S_k \setminus U|}$ minimal)

→ setze $U := U \cup S_k$; $C := C \cup \{k\}$

Theorem: Dieser Greedy Algorithmus für SET COVER ist $(\ln m + 1)$ -approximativ. (ohne Beweis)

Siehe Übung für Beispiele, dass der Approximationsfaktor dieses Algorithmus mindestens $\ln m$ ist.

(Es gibt sogar Beispiele mit $l=2$, d.h. VERTEX COVER Beispiele, sogar ohne Kostengewichte.)