


g.) Dualität in der linearen Programmierung

i.) Einführung

Beispiel: Sei das folgende LP gegeben (wir nennen ihn (P)):

$$(P) \quad \text{minimiere } c^T \cdot x \quad \text{so dass } A \cdot x \geq b \text{ und } x \geq 0$$



I.

Für beliebigen nichtnegativen m-dimensionalen Vektor $y \geq 0$

$$y^T = (y_1, y_2, \dots, y_m) \quad (y_i \geq 0 \forall i)$$

und jede Lösung x gilt dann

$$b \leq A \cdot x$$

(denke an y_i und x_j als an Zahlen)

$$y^T \cdot b \leq y^T \cdot A \cdot x$$

($b \leq A \cdot x$ ist die kurze Form der Ungleichungen

$$b_1 \leq a_1^T \cdot x = \sum_{j=1}^n a_{1j} \cdot x_j$$

$$b_2 \leq a_2^T \cdot x$$

⋮

$$b_m \leq a_m^T \cdot x$$

Wenn die i-te Ungleichung durch $y_i \geq 0$ multipliziert wird, erhalten wir $y_i \cdot b_i \leq y_i \cdot (a_i^T \cdot x)$

Wenn die letzteren m Ungleichungen dann summiert werden:

$$y^T \cdot b = \sum_{i=1}^m y_i \cdot b_i \leq \sum_{i=1}^m y_i \cdot (a_i^T \cdot x) = y^T \cdot A \cdot x \quad)$$

II. Für jede Lösung x von (P) gilt $x \geq 0$.

Wenn noch für ein $y \geq 0$ auch $y^T \cdot A \leq c^T$ gilt,
dann

$$y^T \cdot A \cdot x \leq c^T \cdot x$$

Also, für alle $y \in \mathbb{R}^m$ so dass $y \geq 0$ und $y^T \cdot A \leq c^T$

$$y^T \cdot b \leq y^T \cdot A \cdot x \leq c^T \cdot x$$

d.h. $y^T \cdot b$ ist eine untere Schranke für jeden
(auch für den optimalen) Zielpunkt von (P)

Suchen wir eine beste (höchste) solche untere
Schranke, dann müssen wir das folgende Problem
lösen:

maximiere $y^T \cdot b$

(D) so dass $y^T \cdot A \leq c^T$
und $y \geq 0$

Das ist auch ein LP, wir nennen ihn (D)
(P) steht für 'Primal', (D) steht für 'Dual'

(Statt $y^T \cdot b$ hätten wir auch $b^T \cdot y$ und
statt $y^T \cdot A \leq c^T$ $A^T \cdot y \leq c$ schreiben können,
da y die Variablen von (D) enthält. Es wird bequemer
jedoch mit der Notation y^T zu bleiben.)

Was hätte sich im obigen Argument geändert, wenn wir weiterhin $y^T \cdot b \leq c^T \cdot x$ gewollt hätten,
aber im (P)...

(statt $Ax \geq b$)

in (D)

$\rightarrow Ax \leq b$ steht \rightarrow dann sollte $y \leq 0$ sein, so gilt
 $y^T \cdot b \leq y^T \cdot A \cdot x$ in I.

$\rightarrow Ax = b$ steht \rightarrow dann hätte y keine Vorzeichenbedingung, und in I wäre

$$b = A \cdot x$$

$$y^T \cdot b = y^T \cdot A \cdot x$$

(statt $x \geq 0$)

$\rightarrow x \leq 0$ steht \rightarrow dann in II. würde man
 $y^T \cdot A \geq c^T$ fordern, und so
 $y^T \cdot A \cdot x \leq c^T \cdot x$ würde gelten

$\rightarrow x$ ohne

\rightarrow dann würde man in II

Vorzeichen-
bedingung.

$y^T \cdot A = c^T$ fordern, und

$y^T \cdot A \cdot x = c^T \cdot x$ würde gelten

Wir sehen: lineare Programme treten in Paaren auf!

Zu jedem LP Minimierungsproblem gehört ein Maximierungsproblem mit der transponierten (gespiegelten) Matrix, so dass jede Lösung y des Maximierungsproblems hat einen Zielpunkt \leq als jede Lösung des Minimierungsproblems; es gilt sogar: die optimalen Zielpunkte sind gleich
↓
nicht trivial, siehe später

Zielpunkte $y^T \cdot b$
des Maximierungsproblems

Zielpunkte $c^T \cdot x$ des Minimierungsproblems

$$\begin{array}{c} n \\ \vdots \\ m \end{array} \xrightarrow{\text{A}} \begin{array}{c} m \\ \vdots \\ n \end{array} A^T$$

ii.) Das duale LP zu einem LP in Standardform

(Sei $A \in \mathbb{R}^{m \times n}$ c, x n -dimensional b m -dimensional)

zu dem primären LP

(P) minimiere $c^T \cdot x$ s.d. $Ax = b \quad x \geq 0$

gehört das duale LP

(D) maximiere $y^T \cdot b$ s.d. $y^T \cdot A \leq c^T$

mit $y^T = (y_1, y_2, \dots, y_m)$

(Statt A zu transponieren, wird y^T von links mit A multipliziert)

Beispiel 1: Minimiere $13x_1 + 10x_2 + 6x_3$

$$\text{so dass } 5x_1 + x_2 + 3x_3 = 8$$

$$3x_1 + x_2 = 3$$

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

$$(P) \quad \begin{bmatrix} 5 & 1 & 3 \\ 3 & 1 & 0 \end{bmatrix} \cdot \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} = \begin{bmatrix} 8 \\ 3 \end{bmatrix}$$

$$c^T = [13 \ 10 \ 6]$$

$$(D) \quad \text{maximiere } [y_1 \ y_2] \cdot \begin{bmatrix} 8 \\ 3 \end{bmatrix}$$

$$\text{s.d. } [y_1 \ y_2] \cdot \begin{bmatrix} 5 & 1 & 3 \\ 3 & 1 & 0 \end{bmatrix} \leq [13 \ 10 \ 6]$$

↓

$$\text{maximiere } 8y_1 + 3y_2$$

$$\text{so dass } 5y_1 + 3y_2 \leq 13$$

$$y_1 + y_2 \leq 10$$

$$3y_1 \leq 6$$

y_1, y_2 frei

Beachte: Jede Bedingung $a_i^T \cdot x = b_i$ im (P) entspricht einer Variable y_i in (D); (die m Zeilen von A) jede Variable $x_j \geq 0$ in (P) entspricht einer Bedingung $y^T \cdot a^j \leq c_j$ (die n Spalten von A)

Bemerkung: (P) und (D) (in der Standardform)

können in der folgenden kompakten Form ausgedrückt werden:

$$(D) \text{ bestimme } \max_y \min_{x \geq 0} (c^T \cdot x + y^T \cdot b - y^T \cdot A \cdot x)$$

$$(P) \text{ bestimme } \min_{x \geq 0} \max_y (c^T \cdot x + y^T \cdot b - y^T \cdot A \cdot x)$$

(Übrigens: dasselbe gilt für beliebiges (P) und (D) Paar mit den nötigen Einschränkungen für x und y in min und max)

Wir zeigen für die Standardform:

für (D)

$$\textcircled{*} \quad \min_{x \geq 0} (c^T \cdot x + y^T \cdot b - y^T \cdot A \cdot x) = y^T \cdot b + \min_{x \geq 0} (c^T - y^T \cdot A) \cdot x$$

$$\min_{x \geq 0} (c^T - y^T \cdot A) \cdot x = \begin{cases} 0 & \text{falls } c^T - y^T \cdot A \geq 0 \\ & \text{d.h. } c_j - y^T \cdot a_j^T \geq 0 \forall j \\ -\infty & \text{sonst} \\ & \text{d.h. wenn } c_j - y^T \cdot a_j^T < 0 \text{ für mind. eine } j \end{cases}$$

$$\text{Deshalb } \textcircled{*} = \begin{cases} y^T \cdot b & \text{falls } c^T - y^T \cdot A \geq 0 \\ -\infty & \text{sonst} \end{cases}$$

Das Maximieren von $\textcircled{*}$ über alle y bedeutet somit:

"maximiere $y^T \cdot b$ unter allen y so dass
 $c^T \geq y^T \cdot A$."

Also: Für eine optimale duale Lösung y^*

$$y^{*T} \cdot b = \max_y \min_{x \geq 0} (y^T \cdot b + c^T \cdot x - y^T \cdot A \cdot x)$$

Analog gilt: Für eine optimale private Lösung x^*

$$c^T \cdot x^* = \min_{x \geq 0} \max_y (y^T \cdot b + c^T \cdot x - y^T \cdot A \cdot x)$$

(überlege den analogen Beweis für $c^T \cdot x^*$)

iii.) Zusammenfassung, die allgemeine Form von (P) und (D)

Wir haben in der Einführung gesehen, wie die Ungleichungen in den Bedingungen den dualen Vorzeichenbedingungen entsprechen, und umgedreht. Diese Regel können sogar Zeile für Zeile bzw. Spalte für Spalte verwendet werden. Als Konvention, nehmen wir ^(hier) an, dass (P) ein Minimierungsproblem, und (D) ein Maximierungsproblem ist (nicht wesentlich), dann gilt die allgemeine Definition in folgender Form:

(P)

(D)

minimiere $c^T \cdot x$ maximiere $y^T \cdot b$ so dass $a_i^T \cdot x \geq b_i$ so dass $y_i \geq 0$ Zeilen $a_i^T \cdot x \leq b_i$ $y_i \leq 0$ $a_i^T \cdot x = b_i$ y_i : frei

Spalten

 $x_j \geq 0$ $y^T \cdot a_j^T \leq c_j$ $x_j \leq 0$ $y^T \cdot a_j^T \geq c_j$ x_j : frei $y^T \cdot a_j^T = c_j$

Jede Variable y_i in (D) entspricht einer Bedingung in (P), und jede Bedingung in (D) entspricht einer Variable x_j . Weiterhin werden die Bedingungen so definiert, dass

$$(c_j - y^T \cdot a_j^T) \cdot x_j \geq 0 \quad \text{für } j=1, 2, \dots, n$$

und

$$y_i \cdot (a_i^T \cdot x - b_i) \geq 0 \quad \text{für } i=1, 2, \dots, m$$

Als die Summe dieser Terme über alle j bzw.

über alle i erhalten wir jeweils

$$\sum_{j=1}^n (c_j - y^T \alpha^j) \cdot x_j =$$

(✿)

$$\sum_{i=1}^m y_i \cdot (a_i^T \cdot x - b_i) =$$

$$(c^T - y^T \cdot A) \cdot x \geq 0$$

$$y^T \cdot (A \cdot x - b) \geq 0$$

für beliebige
Lösungen x für (P)
und y für (D)

Die beiden Ungleichungen ergeben den schwachen
Dualitätssatz $c^T x \geq y^T b$ (siehe später)

Beobachtungen:

1. Das duale LP des dualen LP (D) ist das primitive LP (P).
2. Wenn wir das primitive LP (P) in ein äquivalentes LP transformieren (z.B. durch die Einführung von Slackvariablen, die Eliminierung von linear abhängigen Gleichungen, usw.), dann ist das duale LP des so erhaltenen LP äquivalent mit dem dualen von (P).

Beispiel 2.

Bestimme das Duale (D) von

$$\text{Minimiere } -5x_1 - 6x_2 - 4x_3$$

(P)

$$\text{so dass } x_1 - 2x_2 \geq -1$$

$$-3x_1 + x_2 \leq -2$$

$$-3x_2 - x_3 = -3$$

$$x_1 \text{ frei}$$

$$x_2 \geq 0$$

$$x_3 \leq 0$$

	0	0	
frei	A	V	b
x ₁	x ₂	x ₃	
y ₁ ≥ 0	1	-2	0
y ₂ ≤ 0	-3	1	0
y ₃ frei	0	-3	-1
	A	V	
C	-5	-6	-4

$$\text{Maximiere } -y_1 - 2y_2 - 3y_3$$

$$\text{so dass } y_1 - 3y_2 = -5$$

(D)

$$-2y_1 + y_2 - 3y_3 \leq -6$$

$$-y_3 \geq -4$$

$$y_1 \geq 0$$

$$y_2 \leq 0$$

$$y_3 \text{ frei}$$

IV.) DualitätsätzeSchwache Dualität:

Theorem: Wenn x eine Lösung des primalen LP, und y eine Lösung des dualen LP ist, dann gilt

$$y^T \cdot b \leq c^T \cdot x$$

Beweis: Laut Definition von (D) gelten die Ungleichungen

(~~BB~~), deshalb $c^T \cdot x \geq y^T \cdot A \cdot x \geq y^T \cdot b$ für beliebige Lösungen x und y von (P) bzw. (D) □

Korollar 1: Wenn für die Lösungen x und y von (P) bzw. (D) $y^T \cdot b = c^T \cdot x$ gilt, dann sind x und y optimale Lösungen von (P) bzw. von (D).

Warum? Laut schwache Dualität ist $y^T \cdot b$ ~~die~~ eine untere Schranke für den Zielpunkt für alle x in der Lösungsmenge von (P), also wenn $y^T \cdot b = c^T \cdot x$, dann ist $c^T \cdot x$ minimal. Analog: $y^T \cdot b$ ist maximal.

Korollar 2: Wenn das Minimum im primalen LP $-\infty$ ist, dann ist das duale LP unlösbar; wenn das Maximum des dualen LP ∞ ist, dann ist das primitive LP unlösbar.

Starke Dualität:

Theorem: Wenn ein lineares Programm eine (endliche) optimale Lösung x^* hat, dann hat sein duales Programm auch eine optimale Lösung y^* , und

$$y^{*T} \cdot b = c^T \cdot x^*$$

(P) ist dabei ein Minimierungsproblem oder ein Maximierungsproblem alles ist symmetrisch

Der Vollständigkeit halber wird der Beweis hier später aufgeführt. Statt Beweis, zeigen wir zunächst zwei Illustrationen zum starken Dualitätsatz.

Illustration 1: → In der Bemerkung haben wir gesehen, dass für (P) in Standardform, das Optimum $y^T \cdot b$ von (D) ist

$$y^T \cdot b = \max_y \min_{x \geq 0} (c^T \cdot x + y^T \cdot b - y^T \cdot A \cdot x)$$

und das Optimum $c^T \cdot x^*$ von (P) ist

$$c^T \cdot x^* = \min_{x \geq 0} \max_y (c^T \cdot x + y^T \cdot b - y^T \cdot A \cdot x)$$

→ (Seien $S \subseteq \mathbb{R}^n$ und $T \subseteq \mathbb{R}^m$) Für beliebige Funktion

$f: S \times T \rightarrow \mathbb{R}$ gilt trivial (siehe Übung)

$$\max_{y \in T} \min_{x \in S} f(x, y) \leq \min_{x \in S} \max_{y \in T} f(x, y)$$

(dies würde bei unserem Fall also $y^T \cdot b \leq c^T \cdot x^*$ ergeben)

→ Für eine lineare Funktion f und gut gewählte S und T

gilt aber sogar

$$\max_{y \in T} \min_{x \in S} f(x, y) = \min_{x \in S} \max_{y \in T} f(x, y)$$

Siehe die 3D Fläche (Graph) einer bivariaten

linearen Funktion $g(x, y) = c \cdot x + b \cdot y + a \cdot x \cdot y$ die

dem Fall $n=m=1$ entspricht, und seien $S \subseteq \mathbb{R}$ und $T \subseteq \mathbb{R}$ Intervalle

Zusammenfassung:

schwache u.

Der starke Dualitätssatz lässt die folgenden Möglichkeiten zu:

(P)	endliches OPT =	unlösbar
(D)	OPT	-∞
endliches OPT	+	
OPT = ∞		+
unlösbar	+	+

(Ein Beispiel in dem (P) und (D) beide unlösbar sind.)

(P)

$$\text{minimiere } x_1 + 2x_2$$

$$\text{s.d. } x_1 + x_2 = 1$$

$$2x_1 + 2x_2 = 3$$

(D)

$$\text{maximiere } y_1 + 3y_2$$

$$\text{s.d. } y_1 + 2y_2 = 1$$

$$y_1 + 2y_2 = 2$$

)

V.) Komplementäre Slackness

Wir betrachten wieder die Ungleichungen die für jedes (P) - (D) Paar gelten sollen für jede Lösung x von (P) und jede Lösung y von (D):

$$(c_j - y^T \cdot a^j) \cdot x_j \geq 0 \quad \text{für } j = 1, 2, \dots, n$$

und

$$y_i \cdot (a_i^T \cdot x - b_i) \geq 0 \quad \text{für } i = 1, 2, \dots, m$$

Der Beweis der schwachen Dualität war im Grunde genommen

$$c^T \cdot x - y^T \cdot b = \sum_{j=1}^n (c_j - y^T \cdot a^j) \cdot x_j + \sum_{i=1}^m y_i \cdot (a_i^T \cdot x - b_i) \geq 0$$

Hier gilt also ≥ 0 für jeden der $n+m$ Summanden

einzelnen! Dies impliziert, dass x und y genau dann beide optimal sind, d.h. $c^T \cdot x = y^T \cdot b$ genau dann gilt, wenn

$$(c_j - y^T \cdot a^j) \cdot x_j = 0 \quad \text{für alle } j$$

$$\text{und } y_i \cdot (a_i^T \cdot x - b_i) = 0 \quad \text{für alle } i$$

↔

PKS

{ Für alle j : entweder $x_j = 0$ oder die entsprechende duale Ungleichung $c_j \geq y^T \cdot a^j$ exakt erfüllt wird $c_j = y^T \cdot a^j$

DKS

{ und analog für alle i : entweder $y_i = 0$ oder $a_i^T \cdot x = b_i$

Diese Bedingungen nennt man Komplementäre Slackness Bedingungen

(complementary slackness)
conditions

Für beliebige Lösungen x und y , die Dualitätslücke

ist $c^T \cdot x - y^T \cdot b$ (duality gap)

$y^T \cdot b$

$c^T \cdot x$

duality gap

Vi.) Primal-duale Algorithmen

(siehe Vazirani)

LPD 17.

Diese Beobachtungen werden in den sogenannten primal-dualen Algorithmen benutzt. In diesen Heuristiken werden iterativ y und x Vertoren definiert, so dass die Dualitätslücke letztendlich möglichst klein wird, und die letzten x und y Lösungen von (P) bzw. von (D) sind. Wenn am Ende solche x und y gefunden werden, dass x ganzahlig (also "echte" Lösung für das ursprüngliche kombinatorische Problem) ist, und

$$c^T \cdot x \leq \alpha \cdot y^T \cdot b \quad \text{für irgendein } \alpha,$$

dann ist x eine α -approximative ~~Lösung~~ Lösung

des IP, weil $c^T \cdot x \leq \alpha \cdot y^T \cdot b \leq \alpha \cdot \text{OPT}_{(P)} \leq \kappa \cdot \text{OPT}_{(P)}$

- diese Algorithmen sind relativ schnell und einfach
- oft versucht der Algorithmus eine ganzähnliche x Lösung Schritt für Schritt so zu definieren, dass $x_j = 0$ nur dann gilt, wenn für die aktuelle y $(c_j - y^T \cdot a^j) = 0$ gilt. So werden zumindest die primären komplementären Slackness Bedingungen $(c_j - y^T \cdot a^j) \cdot x_j = 0$ die ganze Zeit gelten (die dualen nicht, x wird kein Optimum des LP werden können) und man kann hoffen, dass $y^T \cdot b$ und $c^T \cdot x$ nah aneinander bleiben
- das LP wird dabei typischerweise gar nicht gelöst

Beispiel 1: Primal-dualer Algorithmus für SET COVER

Die Elemente $\{1, 2, \dots, m\}$ sind zu überdecken,

das Gewicht der Teilmenge S_j ist w_j :

Gesucht wird der charakteristische Vektor x der Überdeckung
 $x_j = 1 \Leftrightarrow S_j$ ist in der Mengenüberdeckung ($j \in C$)

(P)


$$\text{minimiere } \sum_j w_j x_j$$

„covering problem“

$$\text{so dass } \sum_{j: i \in S_j} x_j \geq 1 \quad \text{für jede } i = 1, 2, \dots, m$$

$$x_j \geq 0 \quad (x_j \leq 1 \text{ wird in einer optimalen Lösung sowieso erfüllt})$$

Was sind A , b und c ?



- für jedes Element i die Bedingung in (P) „überdeckt“ entspricht einer dualen Variable $y_i \geq 0$
- maximiere $\sum_{i=1}^m y_i \cdot 1$
- jede Teilmenge S_j (x_j) entspricht der dualen Bedingung

„packing problem“ (D)

↓
die w_j werden

„vollgepackt“ mit y_i :

$$\sum_{i \in S_j} y_i \leq w_j \quad j = 1, 2, \dots, n$$

Die Interpretation von y_i : „mindestens so viel kostet noch im Zielpunkt $\sum x_j \cdot w_j$ das Überdecken vom Element i “

Unterschiedliche $y = (y_1, y_2, \dots, y_m)$ entsprechen unterschiedlicher Aufteilung der Kosten über die Elemente (keine genaue Aufteilung, nur untere Schranke)

Die primale komplementäre Slackness Bedingung sagt:


$\forall j: x_j = 0$ oder $\sum_{i \in S_j} y_i = w_j \rightarrow S_j$ gewählt und w_j aufgefüllt mit Preisen
 \leftarrow
Sj nicht gewählt

in unserem primal-dualen Algorithmus wird dies stets erfüllt. Wir starten mit $x = 0$ $y = 0$

Wir illustrieren zunächst durch zwei Beispiele, wie der P-D Algorithmus funktioniert. ACHTUNG!


Generell wird eine Lösung y von (D) nicht iterativ gewählt, nur in diesem einfachen Algorithmus: für ein nicht-überdecktes Element i , wird y_i hochgesetzt bis ein w_j aufgefüllt wird. Anschließend wird S_j gewählt ($x_j = 1$ gesetzt) um i zu überdecken.

Beispiel 1. Die Elemente i werden durch y_i beschriftet
für eine (optimale) Lösung y von (D).



eine (optimale) Lösung y , die der P-D Alg. finden kann, ist schwarz


Beispiel 2.



nicht-optimales y gefunden vom P-D Algorithmus

(aber die Überdeckung oh. das IP wird hier optimal gelöst)

Beispiel 3.



Der P-D Alg. kann hier kein optimales y finden, aber die (ganzzahlige) Überdeckung die er findet (\geq zwei Mengen) ist natürlich optimal.

Primal-Dualer Algorithmus für SET COVER

- starte mit $y = 0 \quad x = 0$

es gelten die primalen kopp. Slack-Bedingungen

$$(w_j - y^T \cdot a_j) \cdot x_j = 0 \quad (*)$$

$$\sum_{i \in S_j} y_i$$

y ist Lösung von (D) aber x keine Lösung von (P)

d.h. noch keine Mengenüberdeckung

$\rightarrow \exists k \in \{1, 2, \dots, m\}$ noch nicht überdeckt

\rightarrow wir müssen x_j erhöhen für eine j mit $k \in S_j$

\rightarrow da $x_j \neq 0$, soll $w_j - y^T \cdot a^k = 0$ werden damit

$(*)$ weiter gilt ABER: x_j zuerst, und dann y erhöhen wird schief gehen bei schlechter Wahl von x_j !

\rightarrow wir machen umgekehrt: wir erhöhen y_k für

das unbedeckte Element k , und beim ersten j

wo $w_j - y^T \cdot a^k = 0$ wird, setzen wir $x_j = 1$

(dies kann nur für j mit $k \in S_j$ vorkommen)

WHILE es gibt $k \in \{1, 2, \dots, m\}$ nicht überdeckt

- erhöhe y_k so hoch wie die Bedingungen in (D)

erlauben, d.h. bis eine Bedingung $j: \sum_{i: i \in S_j} y_i \leq w_j$ exakt erfüllt wird.

(Dann gilt $k \in S_j$ für diese j .)

die Erhöhung von y_k beeinflusst nur die Bedingungen j für $k \in S_j$.

- setze $x_j = 1$ (wir nehmen S_j in die Überdeckung)

$(w_j - y^T \cdot a^k) \cdot x_j = 0$ gilt weiterhin: „ $y^T \cdot b$ ist nicht weit von $c^T \cdot x$ “

- gib x als Überdeckung aus

$$C := \{j \mid x_j = 1\}$$

Laufzeit: $\leq m$ Iterationen, da jede Iteration mindestens ein Element der Grundmenge überdeckt.

Analyse der Approximation:

Thm: Wenn jedes Element in höchstens l Teilmengen enthalten ist, dann ist die primal-duale Lösung l -approximativ.

Beweis: Für jede S_j in der Mengenüberdeckung bezahlen wir w_j in der Zielfunktion.

Idee: Zählen wir (summieren wir) nicht alle diese w_j , sondern die $\sum_{i:i \in S_j} y_i$ für die Elemente in S_j .

Dann wird jedes y_i maximal l -mal in der Summe auftreten, weil i in höchstens l Teilmengen enthalten ist. Wir nutzen aus, dass für alle Teilmengen S_j für die $x_j = 1$ gesetzt wurde, $\sum_{i:i \in S_j} y_i = w_j$ gilt.

(diese y_i Werte werden später im Algorithmus nicht modifiziert, da diese Elemente von S_j schon überdeckt wurden, bzw. erhöhen dürfte man sie eh nicht)

$$\sum_{j=1}^n w_j \cdot x_j = \sum_{j \in C} w_j = \sum_{j \in C} \sum_{i:i \in S_j} y_i = \underbrace{\sum_{i=1}^m \sum_{j:j \in S_i} y_i}_{\substack{j \in C \\ i \in S_j}} \leq \sum_{i=1}^m l \cdot y_i =$$

$$= l \sum_{i=1}^m y_i = l \cdot y^T \cdot b \leq l \cdot \text{OPT}_{\text{frac}} \neq l \cdot \text{OPT}_{\text{ganz}}$$

die y_i Preise werden spaltenweise summiert

die y_i werden zeilenweise summiert (für jede $a_{ij}=1$ in A)