

Lineare Optimierung

Bernhard Schmitt

Winter-Semester 2002

Inhaltsverzeichnis

1	Optimierungs-Probleme	1
1.1	Strukturen	1
1.2	Beispiele	3
	Produktionsplanung	3
	Transportprobleme	4
	Das Problem des Handlungsreisenden (TSP)	5
1.3	Lineare Programme	8
2	Konvexe Analysis	9
2.1	Bezeichnungen	9
2.2	Konvexe Mengen	11
2.3	Randflächen und Ecken	15
2.4	Polyeder, Polytope, Kegel	17
2.5	Der Dekompositionssatz für Polyeder	21
2.6	Existenzsätze für Ungleichungssysteme	22
3	Duale Programme	24
3.1	Optimalitätskriterien	24
3.2	Komplementarität, Schattenpreise	26

<i>INHALTSVERZEICHNIS</i>	2
4 Simplex – Verfahren	29
4.1 Matrix – Umformungen	29
4.2 Ecken und Nachbarn	33
4.3 Das revidierte Simplex-Verfahren	37
4.4 Tabellenform des Simplex-Verfahrens	39
4.5 Anlaufrechnung	41
Zwei-Phasen-Methode	41
Groß-M-Methode	42
4.6 Ausgeartete Ecken	43
5 Dualität beim Simplexverfahren	45
5.1 Duales Simplexverfahren	45
5.2 Problem-Modifikationen	48
6 Spezielle Anwendungen	51
6.1 Restringierte Ausgleichsprobleme	51
6.2 Zwei-Personen-Nullsummenspiele	54
6.3 Transportprobleme in Graphen	59
A Symbole, Abkürzungen	64
Index	65

1 Optimierung-Probleme

1.1 Strukturen

Die 'Optimierung' einer Situation oder eines Vorgehens erfordert, dass man dessen Qualität F quantitativ (als reelle Zahl) beschreiben kann und dass man sich über die die Qualität beeinflussenden Größen x im Klaren ist. Die in Frage kommenden Werte der Größen x werden zu einer Menge X zusammengefasst, dann ist das Qualitätsmaß $F : X \rightarrow \mathbb{R}$ eine reelle Funktion auf X . In der *Optimierungsaufgabe*

$$\max\{F(x) : x \in X\} \quad \text{bzw.} \quad \begin{cases} \max F(x) \\ x \in X \end{cases} \quad (\text{P})$$

wird eine Maximalstelle $\hat{x} \in X$ gesucht mit $F(\hat{x}) \geq F(x) \forall x \in X$.

Bezeichnung: F heißt *Zielfunktion*, X *zulässiger Bereich*, jedes $x \in X$ *zulässiger Vektor bzw. Element*, \hat{x} eine (*globale*) *Lösung* von (P) und $F(\hat{x})$ der *Wert* von (P).

Ein wesentlicher Teil der Problematik besteht in der Regel darin, dass zwar F explizit vorliegt, der Bereich X aber nur implizit gegeben ist, etwa durch Systeme von Gleichungen oder Ungleichungen. Daher zerfällt die Aufgabe (P) in mehrere Teile

1. Frage $X = \emptyset$?

2. für $X \neq \emptyset$:

(a) $F(x)$ beschränkt auf X ?

Wird für $\sup\{F(x) : x \in X\} < \infty$ das Supremum angenommen?

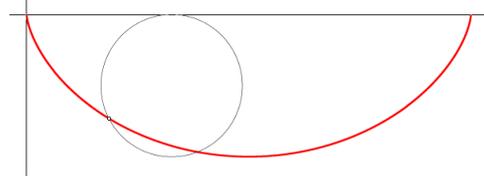
(b) Wenn ja: berechne ein $\hat{x} \in X$ mit $F(\hat{x}) \geq F(x) \forall x \in X$.

Die einsetzbaren Methoden unterscheiden sich auch nach der Art und Anzahl der 'Freiheitsgrade', die in der Menge X zu berücksichtigen sind.

Beispiel 1.1.1 a) Problem der *Brachistochrone* von Galilei.

Ein Körper soll nur durch den Einfluß der Schwerkraft zwischen zwei Punkten bewegt werden. Gesucht ist die Kurve, auf der der Körper am schnellsten vom höheren zum niederen Punkt kommt.

Johann Bernoulli: Lösung ist Zyklonide



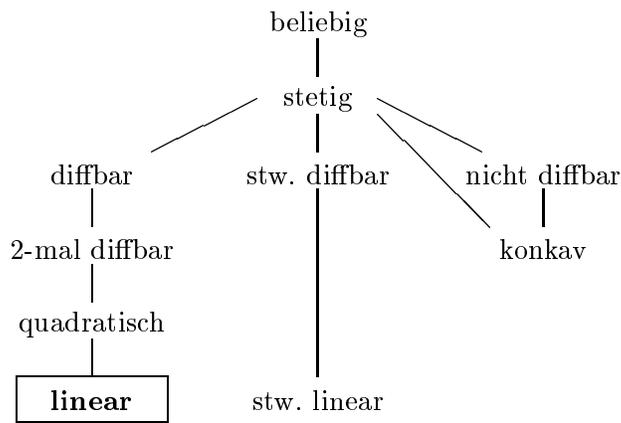
b) Transportproblem: *Ein Unternehmen mit mehreren Produktionsstandorten liefert seine Produkte (Massen-/Stückgut) an verschiedene Abnehmer. Gesucht ist ein Transportplan mit möglichst geringen Kosten*

Da die Weghöhe beim Brachistochronen-Problem an jeder Stelle unbekannt ist, hat man eine *unendliche Anzahl an Freiheitsgraden* (überabzählbar). Zur korrekten Beschreibung wäre

die Menge X als ein Raum geeigneter Funktionen zu wählen. Derartige Probleme werden in der Variationsrechnung und Steuerungstheorie behandelt. Beim Transportproblem sind dagegen die endlich vielen, vom Produktionsort P_i zum Kunden K_j zu liefernden Mengen unbekannt. Bei Massengütern können diese (nichtnegative) reelle Werte, bei Stückgütern ganzzahlige Werte annehmen. Die Grundmenge X ist also (ein Teil) eines geeigneten \mathbb{R}^n oder $\mathbb{Z}^n \subseteq \mathbb{R}^n$. In dieser Vorlesung wird nur der Fall $X \subseteq \mathbb{R}^n$ behandelt.

Eine weitere Klassifikation des Problems ergibt sich aus den

Eigenschaften der Zielfunktion F :



Die Gestalt des *zulässigen Bereichs* X ist in der Regel nicht explizit bekannt, sondern durch Einschränkungen an die Parameter x . Die Art dieser *Nebenbedingungen* schränkt die Auswahl möglicher Verfahren ein. Daher ist es zweckmäßig, die Nebenbedingungen aufzuteilen in funktionale und mengenmäßige. Ab jetzt sei also

$$X := \{x : f(x) \leq 0, g(x) = 0, x \in C\}, \quad (1.1.1)$$

mit $f : \mathbb{R}^n \rightarrow \mathbb{R}^p$, $g : \mathbb{R}^n \rightarrow \mathbb{R}^m$, $C \subseteq \mathbb{R}^n$, die Ungleichung in der Beschreibung ist dabei komponentenweise zu verstehen $f_i(x) \leq 0$, $i = 1, \dots, p$, für $f = (f_i)_{i=1}^p$. Auch die Eigenschaften der Funktionen f führen zu einer weiteren Klassifizierung von Optimierungsproblemen. Als Grundmengen C treten oft folgende Fälle auf

- $\mathbb{R}^n, \mathbb{R}_+^n, \mathbb{R}_+^{n_1} \times \mathbb{R}^{n_2}$ die Nichtnegativität ließe sich auch bei f unterbringen
- $B_r(y)$ Kugel um y vom Radius r , allgemeiner: Ellipsoid
- $\mathbb{Z}^n, \mathbb{R}^{n_1} \times \mathbb{Z}^{n_2}$ ganzzahlige, gemischt-ganzzahlige Probleme,
- $\mathbb{B}^n = \{0, 1\}^n$ boolesche Optimierungsprobleme.

In dieser Vorlesung werden nur *Lineare Programme* (LP) behandelt, das sind *kontinuierliche Optimierungsprobleme* ($C = \mathbb{R}^n$) mit Funktionen

$$F(x) = c^\top x + d, \quad f_i, g_j \text{ affin linear.}$$

Bei einer (in der Praxis üblichen) großen Anzahl von Unbekannten n ist oft eine Sonderbehandlung bei speziellen Strukturen sinnvoll, etwa bei linearen *Transport-* oder *Fluß-Problemen*. Verfahren zur Behandlung von Optimierungsproblemen haben offensichtlich im Unternehmensbereich (Kostenminimierung) eine erhebliche ökonomische Bedeutung. Aber auch in theoretischer Hinsicht (Komplexitätstheorie) sind sie eine große Herausforderung. Naheliegende Fragestellungen sind:

Theorie:

- Allgemeine, z.B. Struktur-Aussagen
- Existenz und Eindeutigkeit
- Kriterien für Optimalität
- Empfindlichkeit der Lösungen (Problem-Stabilität)
- Komplexität des Problems

Praxis:

- Algorithmenentwicklung
- Empfindlichkeit der berechneten Lösung (Stabilität des Algorithmus)
- Komplexität des Algorithmus

In die erste Kategorie fallen bei Linearen Programmen Erkenntnisse zur Geometrie des zulässigen Bereichs X . Diese hat zentrale Bedeutung, denn X ist ein konvexer Polyeder (Vielflächner). Daher werden in §2 Grundlagen der Konvexen Analysis behandelt.

1.2 Beispiele

Produktionsplanung

In einem Unternehmen können n verschiedene Produkte P_j erzeugt werden unter Nutzung m unterschiedlicher Ressourcen R_i (Arbeitszeit, Rohstoffe, Energie, ...). Der Gewinn bei Produktion einer Einheit von Produkt P_j sei c_j .

Die zu erzeugende Menge des Produkts P_j wird als Unbekannte x_j eingeführt. Eine erste Nebenbedingung ist offensichtlich $x_j \geq 0$, der erzielte Gewinn ist $\sum_{j=1}^n c_j x_j = F(x_1, \dots, x_n)$ und stellt die *Zielfunktion* des Problems dar. Nimmt man weiter an, dass zur Produktion von P_j jeweils a_{ij} Einheiten von beschränkten Ressourcen R_i , $i = 1, \dots, m$, verwendet werden, ist ausserdem die Restriktion

$$\sum_{j=1}^n a_{ij} x_j \leq b_i, \quad i = 1, \dots, m$$

einzuhalten. Insgesamt lautet das Problem somit

$$\begin{aligned} \max \quad & \sum_{j=1}^n c_j x_j \\ \sum_{j=1}^n a_{ij} x_j & \leq b_i, \quad i = 1, \dots, m \\ x_i & \geq 0, \quad i = 1, \dots, n \end{aligned}$$

Offensichtlich läßt sich dieses Problem in Vektor-/Matrix-Notation kompakter schreiben. Mit $x = (x_1, \dots, x_n)^\top$, $c := (c_1, \dots, c_n)^\top$, $b = (b_1, \dots, b_m)^\top$, $A = (a_{ij})_{i,j=1}^{m,n}$ ist $F(x) = c^\top x$ und man hat die äquivalente Schreibweise

$$\begin{aligned} \max \quad & c^\top x \\ & Ax \leq b \\ & x \geq 0. \end{aligned}$$

Die Ungleichungen bei Vektoren sind dabei komponentenweise zu verstehen. Da alle Restriktionen Ungleichungen sind, ist der zulässige Bereich $X := \{x \in \mathbb{R}^n : Ax \leq b, x \geq 0\}$.

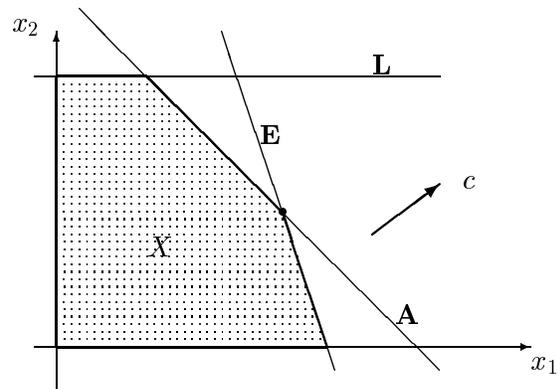
Beispiel 1.2.1 Fall $n = 2$, $m = 3$, die Produkte P_1 (Gewinn $c_1 = 4$ EUR) und P_2 (Gewinn $c_2 = 3$ EUR) sollen mit Hilfe der Ressourcen **A**rbeitszeit, **E**nergie, **L**agerkapazität produziert werden. Die Einschränkungen seien

$$\begin{aligned} \mathbf{A}: \quad & x_1 + x_2 = 16 \quad (\text{gleicher Arbeitsaufwand}) \\ \mathbf{L}: \quad & x_2 \leq 12 \quad (\text{Rohstoffe nur für } P_2 \text{ zu lagern}) \\ \mathbf{E}: \quad & 3x_1 + x_2 \leq 36 \quad (3\text{-facher Energiebedarf } P_1) \end{aligned}$$

Gesamtformulierung und zulässiger Bereich:

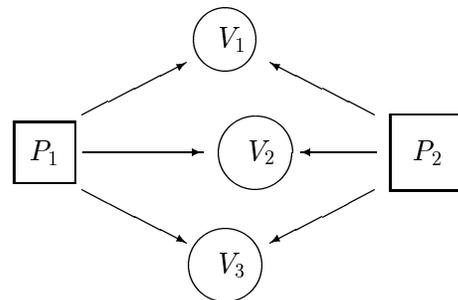
$$\begin{aligned} \max \quad & (4, 3)x \\ \begin{pmatrix} 1 & 1 \\ 0 & 1 \\ 3 & 1 \end{pmatrix} x & \leq \begin{pmatrix} 16 \\ 12 \\ 36 \end{pmatrix}, \\ & x \geq 0. \end{aligned}$$

Der Pfeil c ist der (konstante!) Gradient der Zielfunktion $F(x) = c^\top x = 4x_1 + 3x_2$, das Maximum wird im markierten **Randpunkt** $(\hat{x}_1, \hat{x}_2) = (10, 6)$ angenommen mit dem Wert $F(\hat{x}) = 58$.



Transportprobleme

Hier soll ein Massengut (beliebig teilbar) von m Produktions-/Lagerstätten P_i mit Kapazität s_i zu n Verbrauchern V_j mit Bedarf r_j transportiert werden. Die Gesamtmengen bei Produktion und Verbrauch sollen dabei gleich sein $\sum_{i=1}^m s_i = \sum_{j=1}^n r_j$ (oBdA).



Als Unbekannte werden die von P_i nach V_j transportierten Mengen $x_{ij} \geq 0$ eingeführt, der Transport einer Einheit auf dieser Strecke habe den Preis c_{ij} . Für den optimalen *Transportplan*,

der minimale Kosten verursacht, ergibt sich das Programm

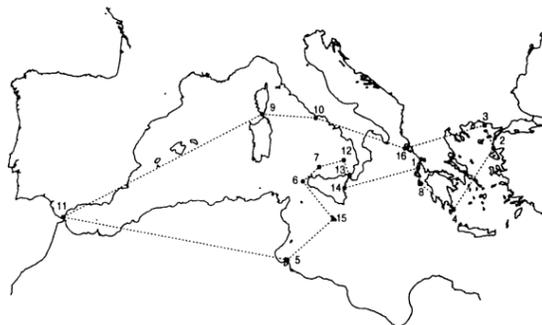
$$\begin{aligned} \min \quad & \sum_{i=1}^m \sum_{j=1}^n c_{ij} x_{ij} \\ & \sum_{j=1}^n x_{ij} = s_i, \quad i = 1, \dots, m \\ & \sum_{i=1}^m x_{ij} = r_j, \quad j = 1, \dots, n \\ & x_{ij} \geq 0 \quad \forall i, j \end{aligned}$$

Die Restriktionen sind hier einerseits lineare Gleichungen, andererseits Nichtnegativitäts-Bedingungen an alle Variable. Der zulässige Bereich X ist daher derjenige Teil des affinen Lösungsraums des LGS, der auch in \mathbb{R}_+^{mn} liegt. Diese Struktur wird bei dem Standard-Lösungsverfahren zugrunde gelegt. Wenn der Transport von Stückgut betrachtet wird, sind nur ganzzahlige Werte $x_{ij} \in \mathbb{Z}_+$ zulässig. Dann liegt ein ganzzahliges Optimierungsproblem vor.

Modifikation: Transport in Netzwerk (Graph), wenn nur ein Teil der Transportstrecken vorhanden ist. Hierbei können reine Umschlagknoten (ohne Produktion und Verbrauch) auftreten.

Das Problem des Handlungsreisenden (TSP)

Dieses Problem ('traveling salesman problem') hat in der Komplexitätstheorie die Bedeutung eines (sehr schweren) Referenz-Problems. In der Grundform soll ein Reisender eine Anzahl von n Orten je einmal besuchen und zum Ausgangspunkt zurückkehren. Dabei soll die zurückgelegte Gesamtstrecke minimal sein. Es ist also die moderne Form der klassischen *Odyssee* (rechts: eine optimale Lösung derselben).



Dazu sei $N = \{1, \dots, n\}$ die Menge der Orte und $w_{ij} \geq 0$ die Entfernung von i und j . Ist die Rundreise (*Tour*) gegeben durch die Liste $(p(1), \dots, p(n))$ der besuchten Orte, so können in der Gesamtstrecke $\sum_{j=1}^{n-1} w_{p(j)p(j+1)} + w_{p(n)p(1)}$ die Summanden w offensichtlich nach dem ersten Index umsortiert werden. Im zweiten Index steht dann eine *zyklische Permutation* $\pi \in S_n$ mit $\pi(p(j)) = p(j+1)$. Die Menge der zyklischen n -Permutationen $S_{zn} \subseteq S_n$ enthält alle, die aus einem einzigen Zyklus bestehen. Das Problem lautet daher

$$\min \left\{ \sum_{i=1}^n w_{i,\pi(i)} : \pi \in S_{zn} \right\} \quad (\text{TSP})$$

In der allgemeinen Form sind die Entfernungsangaben $w_{ij} \geq 0$ nicht weiter eingeschränkt. Sinnvolle Spezialfälle sind aber offensichtlich das

$$\begin{aligned} \text{symmetrische TSP:} \quad & w_{ij} = w_{ji} && (\text{z.B., keine Einbahnstraßen}) \\ \text{euklidische TSP:} \quad & w_{ij} \leq w_{ik} + w_{kj} \quad \forall i, j, k && (\text{Gültigkeit der Dreieckungleichung}) \end{aligned}$$

In der Form (TSP) liegt ein kombinatorisches Optimierungsproblem vor. Wegen $|S_{zn}| = (n-1)!$ ist eine reine Enumeration aller Möglichkeiten zur Lösung nur für kleine n möglich, denn, z.B., ist $5! = 120$, $10! = 368800$, $25! = 16 \cdot 10^{25}$. Der z.Z. schnellste Rechner (Earth Simulator mit 35 TeraFLOPS) packt 10^{21} Operationen im Jahr.

Eine alternative Formulierung als (LP) ist möglich durch Betrachtung des charakteristischen Vektors $x = (x_{ij}) \in \mathbb{R}^{n^2}$. Die Bedeutung der Komponenten ist

$$x_{ij} = \begin{cases} 1 & \text{der Weg von } i \text{ nach } j \text{ wird benutzt,} \\ 0 & \text{sonst.} \end{cases}$$

Damit dadurch eine Tour gegeben ist, darf in bzw. aus jedem Ort nur ein Weg führen, also

$$\sum_{j \in N, j \neq i} x_{ij} = 1 \quad \forall i \in N, \quad (1.2.1)$$

$$\sum_{i \in N, i \neq j} x_{ij} = 1 \quad \forall j \in N. \quad (1.2.2)$$

Allerdings sind dadurch Teiltouren noch nicht ausgeschlossen. Dazu kann man fordern, dass jede Teilmenge $U \subseteq N$ wieder verlassen wird,

$$\sum_{i \in U, j \notin U} x_{ij} \geq 1 \quad \forall U \subset N, 2 \leq |U| \leq n-2. \quad (1.2.3)$$

Diese Formulierung des (TSP) ist damit

$$\min \sum_{i,j=1}^n w_{ij} x_{ij} \quad (1.2.1), (1.2.2), (1.2.3) \text{ gelten} \quad (TSPB)$$

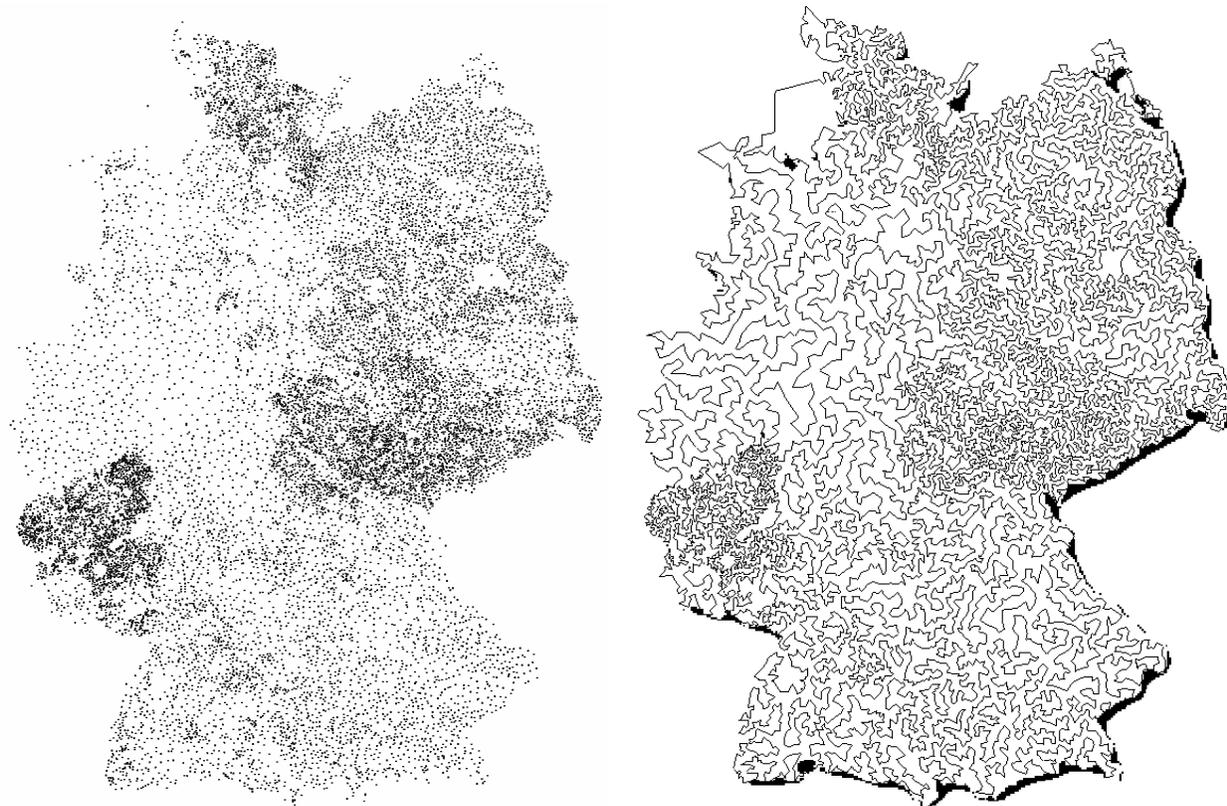
$$x \in X := \{x \in \mathbb{R}^{n^2} : (1.2.1), (1.2.2), (1.2.3) \text{ gelten}\}$$

(TSPB) ist ein boolesches lineares Programm mit $2n$ Gleichungen und $\sum_{k=2}^{n-2} \binom{n}{k} = 2^n - 2n - 2$ Ungleichungen. Wegen dieser vielen Bedingungen und der booleschen Variablen ist auch diese (und jede) Form des (TSP) schwierig zu lösen.

Daten zur Geschichte des Problems:

1930	Karl Menger	Formulierung des Problems, einzige Lösungsmöglichkeit
1934	Hasler Whitney	vollständige Enumeration
1954	G.B. Dantzig, D.R. Fulkerson, S.M. Johnson	Lösen 42-Städte-Problem mit Schnittebenen-Verfahren und linearen Programmen,
1972	R.M Karp	TSP ist NP-vollständig,
1979	Crowder, Padberg	318 Orte, Branch-and-Cut-Verfahren,
1995	Applegate, Bixby, Chvátal, Cook	7397-Städte-Problem, Parallelrechner
2001	dito	15112 Städte BRD

Der aktuelle Rekord berechnet die optimale Rundreise durch 15112 deutsche Städte (elib.zib.de, www.math.princeton.edu/tsp/):



Statt des Booleschen Problems (TSPB) kann man auch seine *stetige Relaxation* betrachten, mit dem zulässigen Bereich

$$X_1 := \{x \in \mathbb{R}^{n^2} : 0 \leq x \leq \mathbf{1}, \text{ und (1.2.1), (1.2.2), (1.2.3)}\} \supset X. \quad (1.2.4)$$

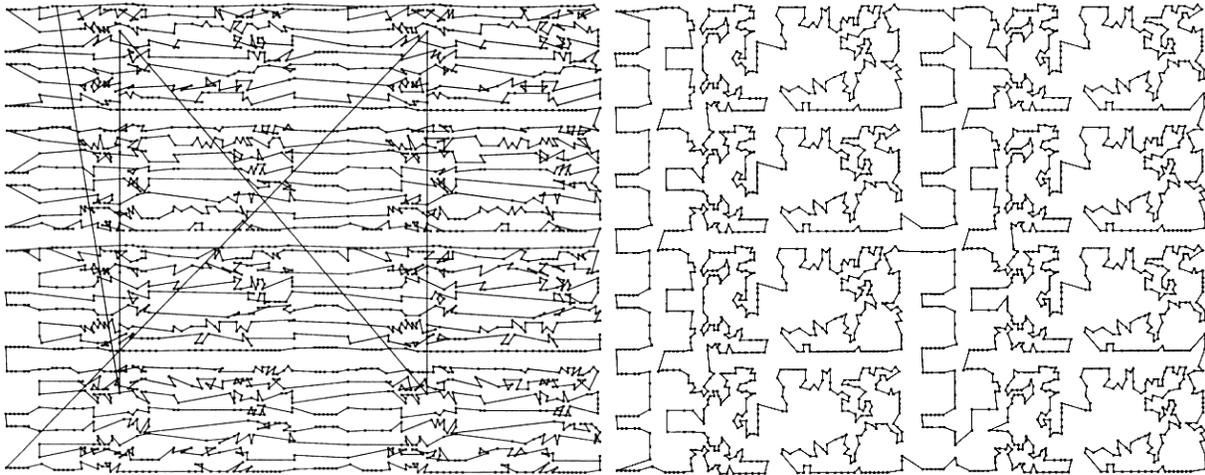
Hieraus erhält man zumindestens eine untere Schranke W_1 für den Wert W des (TSPB): $W \geq W_1$. Bei den erwähnten *Schnittebenen-Verfahren* legt man tatsächlich (1.2.4) zugrunde und eliminiert schrittweise unbrauchbare Lösungen durch Hinzunahme weiterer Nebenbedingungen, die nichtganzzahlige Lösungen *abschneiden*.

Anwendungen Viele praktische Fragen führen direkt auf das TSP oder können analog formuliert werden:

- Leiterplatten-Produktion, Computerverdrahtung
- Tourenplanung
- Ablaufplanung (job-shop scheduling)

Zur Bestückung von Platinen mit Bauteilen sind für deren Anschlußdrähte Bohrungen in den Leiterplatten anzubringen. Da die Zeit pro Bohrung konstant ist, wird die Gesamtzeit v.a. durch die Fahrzeit zwischen den Bohrpunkten bestimmt. Unter der Annahme, dass die Fahrzeit proportional zur Entfernung ist, entspricht c_{ij} dem euklidischen Abstand der Punkte. Die per Hand

geplante Tour ist um 90% länger als die optimale.



'manuelle' Lösung mit Länge 718876

Optimale Lösung der Länge 378032

1.3 Lineare Programme

Für Lineare Optimierungsprobleme hat sich der Begriff *Lineare Programme* eingebürgert. In dem allgemeinen Rahmen der Form (P) mit dem zulässigen Bereich (1.1.1) sind alle auftretenden Funktionen (affin) linear, es gelten also Darstellungen der Form

$$F(x) = c^\top x, \quad f_i(x) = a_i^\top x + \alpha_i, \quad g_j(x) = b_j^\top x + \beta_j,$$

$i = 1, \dots, p, j = 1, \dots, m$. Dabei wurde F oBdA als linear angenommen, da eine Konstante zwar den Wert des Problems, aber nicht die Lösung \hat{x} ändert. In den Beispielen traten Ungleichungsrestriktionen oft in sehr einfacher Form, als Vorzeichenbeschränkungen, auf. Wegen ihrer vielfältigen Sonderrolle werden diese im folgenden gesondert notiert, man teilt die Unbekannten auf in *freie* und *vorzeichenbeschränkte Variable*. Zusammen mit der Aufteilung in Ungleichungen und Gleichungen können die Restriktionen in einer Blockmatrix gesammelt werden. Die allgemeine Form eines linearen Programms lautet daher

$$\left. \begin{array}{l} \max c_1^\top x_1 + c_2^\top x_2 \\ A_{11}x_1 + A_{12}x_2 \leq b_1 \\ A_{21}x_1 + A_{22}x_2 = b_2 \\ x_2 \geq 0 \end{array} \right\} \begin{array}{l} x_1, c_1 \in \mathbb{R}^{n_1}, \quad x_2, c_2 \in \mathbb{R}^{n_2}, \quad n = n_1 + n_2, \\ b_1 \in \mathbb{R}^{m_1}, \quad b_2 \in \mathbb{R}^{m_2}, \quad m = m_1 + m_2, \\ A_{ij} \in \mathbb{R}^{m_i \times m_j}, \quad i, j = 1, 2. \end{array} \quad (\text{LP})$$

Allerdings kann durch elementare Umformungen daraus jedes der folgenden, einfacheren Standardprogramme erzeugt werden,

$$\max\{c^\top x : Ax \leq b\} \quad (\text{LP1})$$

$$\max\{c^\top x : Ax \leq b, x \geq 0\} \quad (\text{LP2})$$

$$\max\{c^\top x : Ax = b, x \geq 0\} \quad (\text{LP3})$$

Hierbei ist in der allgemeinen Form (LP) jeweils nur ein Matrixblock nichttrivial, nämlich $A_{11} \neq 0$ bei (LP1), $A_{12} \neq 0$ bei (LP2) und $A_{22} \neq 0$ bei (LP3). Folgende *elementare Umformungen* können eingesetzt werden, die auf äquivalente Probleme führen:

1. eine Gleichung $a^\top x = \alpha$ kann durch die beiden Ungleichungen $a^\top x \leq \alpha$, $-a^\top x \leq -\alpha$ ersetzt werden.
2. eine freie Variable ξ kann als Differenz $\xi = \xi^+ - \xi^-$ von zwei nichtnegativen Variablen $\xi^+, \xi^- \geq 0$ geschrieben werden.
3. Ungleichungen $a^\top x \leq \alpha$ können durch Einführung einer *Schlupfvariablen* $\eta \geq 0$ durch die Gleichung $a^\top x + \eta = \alpha$ ersetzt werden.
4. jede Vorzeichenbeschränkung $\xi \geq 0$ kann als Ungleichungsrestriktion $-\xi \leq 0$ einer freien Variablen ξ nach A_{11} verlagert werden.

Durch diese Umformungen können sich die Dimensionen m, n vergrößern, die wesentlichen Eigenschaften aus §1.1 ($X \neq \emptyset$? $\sup\{F(x) : x \in X\} < \infty$?) bleiben aber unverändert. Allerdings unterscheiden sich die geometrischen Eigenschaften der zulässigen Bereiche bei den 3 Standardformen. Dies eröffnet die Möglichkeit, bei verschiedenen Fragestellung die passende zu wählen.

(LP1) $X = \{x : Ax \leq b\} = \bigcap_{i=1}^m \{(e_i^\top A)x \leq b_i\}$. Da jede Ungleichung der Form $a^\top x \leq \beta$ einen abgeschlossenen Halbraum definiert, ist X als deren Durchschnitt ein *Polyeder*.

(LP2) $X = \{x : Ax \leq b, x \geq 0\}$ ist Durchschnitt des erwähnten Polyeders mit dem *positiven Kegel* $\{x : x \geq 0\} = \mathbb{R}_+^n$, also wieder ein *Polyeder*.

(LP3) $X = \{x : Ax = b, x \geq 0\}$, dies ist der Durchschnitt $\{x : Ax = b\} \cap \mathbb{R}_+^n$ des affinen Unterraums der Lösungen des Gleichungssystems $Ax = b$ mit dem positiven Kegel.

2 Konvexe Analysis

Da die Zielfunktion der linearen Programme (LP) linear ist, treten Maxima auf dem Rand der zulässigen Bereiche X auf. Das wichtigste Ziel dieses Kapitels ist es, die geometrische Struktur von Polyedern und, allgemeiner, von konvexen Mengen, aufzuklären. Dabei wird sich zeigen, dass bei der Suche des Maximums in (LP) tatsächlich nur endlich viele Punkte bzw. Richtungen von X zu prüfen sind.

2.1 Bezeichnungen

Es wird der n -dimensionale Vektorraum \mathbb{R}^n zugrundegelegt. Er wird auch als affiner Raum mit sich selbst als Standardvektorraum betrachtet. Elemente $x \in \mathbb{R}^n$ werden als *Spaltenvektoren*

geschrieben,

$$x = \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix} = (x_i)_{i=1}^n,$$

die Vektoren der Einheitsbasis heißen $e_i = (\delta_{ij})_{j=1}^n$ und es sei $\mathbf{1} := \sum_{i=1}^n e_i$. In der Regel wird die Euklidnorm $\|x\| = \|x\|_2 := \sqrt{\sum_{i=1}^n x_i^2}$ verwendet, eine andere interessante Norm ist die Maximumnorm $\|x\|_\infty := \max_{i=1}^n |x_i|$. Ungleichungen zwischen Vektoren sind komponentenweise zu verstehen. Eine solche wird in der Definition $\mathbb{R}_+^n := \{x : x \geq 0\}$ des *positiven Kegels* verwendet (s.o.). Die Menge der reellen $m \times n$ -Matrizen heißt $\mathbb{R}^{m \times n}$. Im folgenden ist es oft wichtig, Untermatrizen aus ausgewählten Spalten oder Zeilen einer Matrix zu betrachten. Zu $A \in \mathbb{R}^{m \times n}$ seien daher $a_i = Ae_i \in \mathbb{R}^m$ die Spalten und $a^{(i)} = A^\top e_i \in \mathbb{R}^n$ die Zeilen von A . Dann gelten folgende Schreibweisen

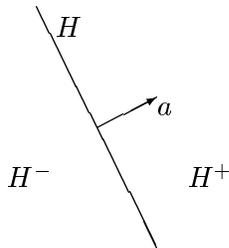
$$A = \begin{pmatrix} a_{11} & \cdots & a_{1n} \\ \vdots & & \vdots \\ a_{m1} & \cdots & a_{mn} \end{pmatrix} = (a_{ij}) = (a_1, \dots, a_m) = \begin{pmatrix} a^{(1)\top} \\ \vdots \\ a^{(m)\top} \end{pmatrix}.$$

Elemente einer Vektorfolge werden ebenfalls durch einen oberen Index unterschieden, $x^{(i)} = (x_1^{(i)}, \dots, x_n^{(i)})^\top$.

Die zulässigen Bereiche von (LP*) lassen sich als Durchschnitte einfacher Gebilde darstellen. Jeder $(n - 1)$ -dimensionale affine Unterraum $H \subseteq \mathbb{R}^n$ ist eine *Hyperebene*. Sie kann durch eine einzelne lineare Gleichung charakterisiert werden

$$H = \{x : a^\top(x - y) = 0\} = \{x : a^\top x = \alpha\}, \quad a \neq 0, \quad y \in H, \quad \alpha = a^\top y, \quad (2.1.1)$$

wobei a der (bis auf Skalierung eindeutige) *Normalenvektor* von H ist und $y \in H$ beliebig. Kompaktschreibweise $H = H(a, y) = H(a, \alpha)$. Modifikationen der Darstellung $H(a, \alpha)$ führen auf die *offenen Halbräume*



$$H^+(a, \alpha) := \{x : a^\top x > \alpha\}, \quad H^-(a, \alpha) := \{x : a^\top x < \alpha\}. \quad (2.1.2)$$

Die Zerlegung $\mathbb{R}^n = H^- \cup H \cup H^+$ ist damit disjunkt. Die entsprechenden *abgeschlossenen Halbräume* sind $H^\oplus := H^+ \cup H$, $H^\ominus := H^- \cup H$. Jeder r -dimensionale affine Unterraum, $r < n$, ist Durchschnitt von $n - r$ Hyperebenen.

Zu einer beliebigen Menge $M \subseteq \mathbb{R}^n$, $M \neq \emptyset$, wird die *affine Hülle* $\text{aff}(M)$ definiert als kleinster affiner Unterraum $U \subseteq \mathbb{R}^n$ mit $M \subseteq U$, also

$$\text{aff}(M) = \bigcap_{U \supseteq M} U \quad (U \subseteq \mathbb{R}^n \text{ affiner Unterraum}) \quad (2.1.3)$$

$$= \left\{ \sum_{i=1}^k \lambda_i x^{(i)} : x^{(i)} \in M, \lambda_i \in \mathbb{R}, \sum_{i=1}^k \lambda_i = 1, k \in \mathbb{N} \right\}. \quad (2.1.4)$$

Außerdem wird die (affine) *Dimension* $\dim M = \dim \text{aff}(M)$ gesetzt. Umgekehrt ist der größte, bei jeder Verschiebung, in M 'passende' Unterraum der *Linealraum* $L(M)$ von M :

$$x + L(M) \subseteq M \quad \forall x \in M. \quad (2.1.5)$$

Für $0 \in M$ ist offensichtlich $L(M) \subseteq M$, für beschränktes M ist $L(M) = \{0\}$ trivial.

Beispiel 2.1.1 Für eine Hyperebene $H = H(a, \alpha) \subseteq \mathbb{R}^n$, $\alpha \neq 0$, ist $\text{aff}(H \cup \{0\}) = \mathbb{R}^n$ und $L(H) = H(a, 0)$.

Die beiden Darstellungen (2.1.3, 2.1.4) können als Charakterisierungen der affinen Hülle von 'außen' bzw. 'innen' gesehen werden, wobei bei der zweiten affine Kombinationen von Vektoren verwendet. Da unterschiedliche Linearkombinationen auch im folgenden auftreten, werden sie gemeinsam eingeführt.

Definition 2.1.2 Zu Vektoren $x^{(1)}, \dots, x^{(k)}$ heißt die *Linearkombination* $z := \sum_{i=1}^k \lambda_i x^{(i)}$ mit $\lambda_i \in \mathbb{R}$, eine

- konische Kombination für $\lambda_i \geq 0$, $i = 1, \dots, k$,
- positive Kombination für $\lambda_i > 0$, $i = 1, \dots, k$,
- affine Kombination für $\sum_{i=1}^k \lambda_i = 1$,
- konvexe Kombination für $\lambda_i \geq 0$, $i = 1, \dots, k$, $\sum_{i=1}^k \lambda_i = 1$.

Die $k + 1$ Punkte $x^{(0)}, \dots, x^{(k)} \in \mathbb{R}^n$ heißen *affin linear unabhängig* bzw. in *allgemeiner Lage*, wenn die k Differenzen $x^{(1)} - x^{(0)}, \dots, x^{(k)} - x^{(0)}$ linear unabhängig sind. Andernfalls sind $x^{(0)}, \dots, x^{(k)}$ affin linear abhängig, was äquivalent zur Existenz eines nichttrivialen Tupels $(\lambda_0, \dots, \lambda_k) \neq 0$ ist mit

$$\sum_{i=0}^k \lambda_i = 0, \quad \sum_{i=0}^k \lambda_i x^{(i)} = 0. \quad (2.1.6)$$

2.2 Konvexe Mengen

Definition 2.2.1 Eine Menge $M \subseteq \mathbb{R}^n$ heißt *konvex*, wenn

$$[x, y] := \{\lambda x + (1 - \lambda)y, 0 \leq \lambda \leq 1\} \subseteq M \quad \forall x, y \in M.$$

Zu jedem Paar von Punkten $x, y \in M$ liegt hier die ganze Verbindungsstrecke $[x, y]$ in M . Die 'offene' Strecke wird mit $(x, y) = \{\lambda x + (1 - \lambda)y, 0 < \lambda < 1\}$ bezeichnet (enthält Endpunkte nicht für $x \neq y$). Die Konvexität hat für uns zentrale Bedeutung, vgl. c) im Beispiel.

Beispiel 2.2.2

- a) Jeder affine Unterraum $U \subseteq \mathbb{R}^n$ ist konvex, da mit $x, y \in U$ sogar $[x, y] \subseteq \text{aff}(x, y) \subseteq U$ gilt.

- b) Der Durchschnitt $\bigcap_{i \in I} M_i$ konvexer Mengen $M_i \subseteq \mathbb{R}^n$, $i \in I$, ist konvex.
 c) Halbräume H^\pm , H^\ominus , H^\oplus sind konvex. Die Menge der Lösungen

$$X := \{x \in \mathbb{R}^n : \sum_{j=1}^n a_{ij} x_j \leq b_i, i \in I\}$$

eines linearen Ungleichungssystems $Ax \leq b$ ist als Durchschnitt $\bigcap_{i \in I} H^\ominus(a^{(i)}, b_i)$, von Halbräumen konvex.

- d) Der *Einheitssimplex* $\Delta_n := \{x \in \mathbb{R}^n : \mathbf{1}^\top x = 1, x \geq 0\}$ ist ebenso konvex wie $\Delta'_n := \{x \in \mathbb{R}^n : \mathbf{1}^\top x \leq 1, x \geq 0\}$.
 e) Streckung und Addition erhalten die Konvexität. Mit $\lambda \in \mathbb{R}$ und konvexen Mengen $M, N \subseteq \mathbb{R}^n$ sind auch folgende Mengen konvex

$$\begin{aligned} \lambda M &:= \{\lambda x : x \in M\}, \\ M + N &:= \{x + y : x \in M, y \in N\}. \end{aligned}$$

Definition 2.2.3 Zu $M \subseteq \mathbb{R}^n$ heißt die kleinste konvexe Menge, die M enthält, die konvexe Hülle von M , bezeichnet mit $\text{konv}(M)$.

Offensichtlich gilt für Mengen $M \subseteq \mathbb{R}^n$: M konvex $\iff M = \text{konv}(M)$. Den Zusammenhang zwischen Konvexität und Konvex-Kombinationen präzisieren die folgenden Sätze.

Satz 2.2.4 $M \subseteq \mathbb{R}^n$ ist genau dann konvex, wenn jede konvexe Kombination von endlich vielen Punkten aus M wieder in M liegt.

Bew

Spezielle Charakterisierungen der konvexen Hülle von M sind auch:

- Durchschnitt aller konvexen Obermengen:

$$\text{konv}(M) = \bigcap_{M \subseteq N \subseteq \mathbb{R}^n} N \quad (N \text{ konvex})$$

- Menge aller konvexen Kombinationen von Punkten aus M :

$$\text{konv}(M) = \bigcup_{k \in \mathbb{N}} \left\{ \sum_{i=1}^k \lambda_i x^{(i)} : x^{(i)} \in M, \lambda \in \Delta_k \right\}. \quad (2.2.1)$$

Der Einheitssimplex ist die konvexe Hülle aller Einheitsvektoren $\Delta_n = \text{konv}(\{e_1, \dots, e_n\})$ und $\Delta'_n = \text{konv}(\Delta_n \cup \{0\})$. Dieses Beispiel läßt erwarten, dass in der Darstellung (2.2.1) nur eine Höchstanzahl von Summanden zu betrachten ist. Das bestätigt folgender Satz.

Satz 2.2.5 (Caratheodory) Die Menge $M \subseteq \mathbb{R}^n$, $M \neq \emptyset$, besitze Dimension m . Dann kann jeder Punkt $z \in \text{konv}(M)$ durch höchstens $m + 1$ Punkte konvex kombiniert werden, d.h., es existieren $x^{(1)}, \dots, x^{(k)} \in M$, $k \leq m + 1$, $\lambda \in \Delta_k$ so, dass $z = \sum_{i=1}^k \lambda_i x^{(i)}$ gilt.

Bew

Die Konvexität überträgt sich auf topologische Varianten von M .

Satz 2.2.6 Bei einer nichtleeren konvexen Menge $M \subseteq \mathbb{R}^n$ sind auch das Innere $\overset{\circ}{M}$ und der Abschluß \bar{M} konvex. Bew

Bei der Übertragung topologischer Eigenschaften auf die konvexe Hülle ist Vorsicht angebracht. Die Abgeschlossenheit von M überträgt sich nur bei beschränkten Mengen auf $\text{konv}(M)$.

Satz 2.2.7 Die Menge $M \subseteq \mathbb{R}^n$ sei

$$\left. \begin{array}{l} \text{offen} \\ \text{beschränkt} \\ \text{kompakt} \end{array} \right\} \Rightarrow \text{konv}(M) \text{ ist } \left\{ \begin{array}{l} \text{offen} \\ \text{beschränkt} \\ \text{kompakt} \end{array} \right.$$

Bew

Zu einem beliebigen Punkt $x \in \mathbb{R}^n$ gibt es in einer nichtleeren konvexen, abgeschlossenen Menge M einen *eindeutigen*, nächstgelegenen Punkt. Denn bei festem x ist $f_x(y) := \|y - x\|^2$ eine stetige Funktion, und muß mit einem beliebigen $y_0 \in M$ nur auf der Kugel $B_r(x)$, $r^2 = f_x(y_0)$, bzw. der kompakten Menge $M \cap B_r(x)$ betrachtet werden. Dieses Minimum ist eindeutig aufgrund der Parallelogrammgleichung

$$\left\| \frac{y+z}{2} \right\|^2 = \frac{1}{2} \|y\|^2 + \frac{1}{2} \|z\|^2 - \frac{1}{4} \|y-z\|^2. \quad (2.2.2)$$

Bei zwei Minimalstellen $y \neq z$ wäre f_x in $u := (y+z)/2$ echt kleiner: $f_x(u) < f_x(y) = f_x(z)$.

Satz 2.2.8 Die Menge $M \subseteq \mathbb{R}^n$, $M \neq \emptyset$, sei konvex und abgeschlossen. Dann gibt es zu jedem $x \in \mathbb{R}^n$ einen *eindeutigen*, nächstgelegenen Punkt

$$\hat{y} \in M : \hat{y} = \arg \min \{ f_x(y) : y \in M \}.$$

Die Zuordnung $p_M : \mathbb{R}^n \rightarrow M$, $x \mapsto \hat{y}$ wird die Projektion auf M genannt.

Fixpunkte dieser Projektion $p_M(x) = x$ sind genau die Punkte $x \in M$, daher ist die Abbildung p_M auch *idempotent*, $p_M \circ p_M = p_M$. Bei einem affinen Unterraum $U \subseteq \mathbb{R}^n$ ist p_U die orthogonale Projektion auf U , mit $\hat{y} = p_M(x)$ ist

$$x = \hat{y} + (x - \hat{y}), \quad \text{wobei } (x - \hat{y})^\top (y - \hat{y}) = 0 \quad \forall y \in U.$$

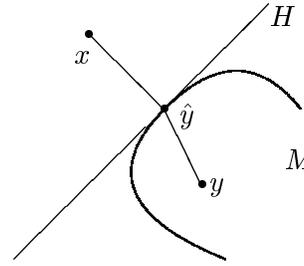
Bei einem linearen Unterraum ist auch p_U linear. Eine zur letzten Gleichung ähnliche Charakterisierung von $p_M(x)$ gilt im allgemeinen Fall.

Satz 2.2.9 Die nichtleere Menge $M \subseteq \mathbb{R}^n$ sei konvex und abgeschlossen und $\hat{y} \in M$. Dann gilt mit $x \in \mathbb{R}^n$

$$\hat{y} = p_M(x) \iff (x - \hat{y})^\top (y - \hat{y}) \leq 0 \quad \forall y \in M. \quad (2.2.3)$$

Bew

Für $x \notin M$ ist der nächstgelegene Punkt $\hat{y} = p_M(x)$ also dadurch charakterisiert, dass gilt $M \subseteq H^\ominus$, mit der Hyperebene $H = H(x - \hat{y}, \hat{y})$. Wie im linearen Fall ist die Abbildung p_M nicht-expandierend, aber keine Kontraktion, da alle Elemente von M Fixpunkte sind.



Satz 2.2.10 Die Menge $M \subseteq \mathbb{R}^n$, $M \neq \emptyset$, sei konvex und abgeschlossen. Dann gilt für $x, y \in \mathbb{R}^n$

$$\|p_M(x) - p_M(y)\| \leq \|x - y\|.$$

Hyperebenen der in Satz 2.2.9 auftretenden Art sind im folgenden ein wichtiges Hilfsmittel.

Definition 2.2.11 Ist $M \subseteq \mathbb{R}^n$ konvex, $M \neq \emptyset$, und $H = H(a, \alpha)$ eine Hyperebene mit $M \subseteq H^\ominus$, $H \cap \bar{M} \neq \emptyset$. Dann heißt H Stützebene für M und $a^\top x \leq \alpha$ zulässige Ungleichung für M . Wenn $B := H \cap M \neq \emptyset$ ist, heißt B Stützmenge.

In Satz 2.2.9 liegt also $p_M(x)$ für $x \notin M$ in der Stützmenge der dort zur abgeschlossenen(!) Menge M konstruierten Stützebene H . Diese trennt den Punkt x von der Menge M . Eine entsprechende Aussage gilt für beliebige disjunkte, konvexe Mengen.

Definition 2.2.12 Zur Lage einer Hyperebene $H = H(a, \alpha)$ relativ zu nichtleeren Mengen $M, N \subseteq \mathbb{R}^n$ verwendet man folgende Begriffe.

H trennt M und N , wenn $M \subseteq H^\ominus$, $N \subseteq H^\oplus$ (bzw. umgekehrt)
 H trennt M und N echt, wenn $M \subseteq H^\ominus$, $N \subseteq H^+$ (bzw. umgekehrt)
 H trennt M und N strikt, wenn $M \subseteq H^-$, $N \subseteq H^+$ (bzw. umgekehrt)
 H trennt M und N stark, wenn für ein $\epsilon > 0$ gilt

$$a^\top x \leq \alpha - \epsilon < \alpha + \epsilon \leq a^\top y \quad \forall x \in M, y \in N.$$

Mit Satz 2.2.9 kann direkt eine Hyperebene konstruiert werden, die einen Punkt $x \notin \bar{M}$ außerhalb einer konvexen Menge von dieser strikt trennt. Etwas schwieriger wird der Nachweis, wenn x auf dem Rand von M liegt, die trennende Ebene ist dann eine Stützebene.

Satz 2.2.13 Die nichtleere Menge $M \subseteq \mathbb{R}^n$ sei konvex.

a) Ist M abgeschlossen und $x \notin M$, dann existiert eine Hyperebene mit $M \subseteq H^-(a, \alpha)$, $x \in H^+(a, \alpha)$, d.h.,

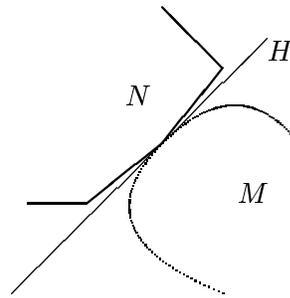
$$\forall y \in M : a^\top y < \alpha < a^\top x.$$

b) Ist x ein Randpunkt von M , $x \in \bar{M} \setminus \overset{\circ}{M}$, dann existiert eine Hyperebene H mit $x \in H$, $M \subseteq H^\ominus$.

Bew

Auch im Grenzfall sich berührender konvexer Mengen ist noch eine Trennung möglich.

Theorem 2.2.14 *Es seien $M, N \subseteq \mathbb{R}^n$ nichtleere, disjunkte, konvexe Mengen, $M \cap N = \emptyset$, und M offen. Dann existiert eine Hyperebene H , die M und N echt trennt, $M \subseteq H^-$, $N \subseteq H^+$.*



Bew

Bei ihrer Einführung wurde die konvexe Hülle als Durchschnitt allgemeiner konvexer Obermengen definiert. Mit den letzten Ergebnissen ist auch eine Charakterisierung nur mit Halbräumen (d.h. linearen Ungleichungen) möglich.

Satz 2.2.15 *$M \subseteq \mathbb{R}^n$ sei eine konvexe, abgeschlossene, echte Teilmenge des \mathbb{R}^n , $M \neq \emptyset$, $M \neq \mathbb{R}^n$. Bezeichnet \mathcal{H}_M die Menge der Stützebenen an M , dann gilt*

$$M = \bigcap_{H \in \mathcal{H}_M} H^\ominus.$$

Beispiel 2.2.16 Bei der Einheitskugel $M := B_1(0)$ ist diese Aussage sofort nachvollziehbar. Für jedes $a \in \mathbb{R}^n$, $a \neq 0$, ist $H(a, \|a\|)$ eine Stützebene an M . Man sieht hier auch sofort, dass in der Darstellung $\bigcap_{H \in \mathcal{H}_M} H^\ominus$ unendlich viele Halbräume auftreten.

2.3 Randflächen und Ecken

Bekanntlich sind bei der Suche nach Extrema von Funktionen die Ränder des zulässigen Bereichs gesondert zu prüfen, insbesondere bei linearen Zielfunktionen. Auch eine Stützebene berührt eine konvexe Menge in (mindestens einem) Randpunkt. Die Definition des Randes ist bei abgeschlossenen konvexen Mengen aber auch mit rein geometrischen Begriffen möglich.

Definition 2.3.1 *Sei $R \neq \emptyset$ und beide Mengen $R \subseteq M \subseteq \mathbb{R}^n$ konvex. Dann heißt R Randfläche von M , wenn*

$$\forall x, y \in M : (x, y) \cap R \neq \emptyset \Rightarrow x, y \in R.$$

Punkte einer Randfläche R können also nur aus Punkten von R selbst kombiniert werden. Abhängig von der Dimension einer Randfläche R verwendet man folgende Bezeichnungen:

- $\dim R = 0$: $R = \{y\}$ ist *Ecke* von M
- $\dim R = 1$: R ist *Kante* von M
- $\dim R = n - 1$: R ist *Facette* von $M \subseteq \mathbb{R}^n$.

Der wichtigste Begriff hier ist der der Ecke, die Menge aller Ecken von M heißt $E(M)$.

Satz 2.3.2 Sei $M \subseteq \mathbb{R}^n$ nichtleer und konvex. Dann sind folgende Bedingungen äquivalent:

Bew

- a) $z \in M$ ist Ecke von M ,
- b) $z \in (x, y), x, y \in M \Rightarrow x = y = z$,
- c) $z = \frac{1}{2}(x + y), x, y \in M \Rightarrow x = y = z$,
- d) $M \setminus \{z\}$ ist konvex.

Beispiel 2.3.3

- a) Die Eckenmenge der Einheitskugel $M = B_1(0) = \{x : \|x\| \leq 1\}$ ist die Sphäre $E(M) = \{x : \|x\| = 1\}$. Dies folgt direkt aus der Parallelogrammgleichung (2.2.2) und Satz 2.3.2b. Die offene Kugel hat keine Ecken $E(\overset{\circ}{M}) = \emptyset$.
- b) Auch Unterräume $U \subseteq \mathbb{R}^n$ haben keine Ecken, sind aber abgeschlossen.
- c) Im folgenden treten aber in der Regel Mengen mit endlich vielen Ecken auf. Dazu gilt etwa: für $M = \text{konv}\{x^{(1)}, \dots, x^{(m)}\}$ ist $E(M) \subseteq \{x^{(1)}, \dots, x^{(m)}\}$.

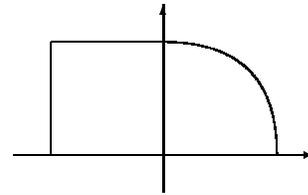
Jede nichtleere kompakte Menge M enthält mindestens eine Ecke (Satz, denn $\text{argmax}\{\|x\| : x \in M\}$ ist Ecke). $E(M)$ enthält dann sogar so viele Punkte, dass die ganze Menge M daraus rekonstruiert werden kann (Theorem 2.3.6). Zum Beweis wird benötigt:

Satz 2.3.4 Sei $M \neq \emptyset, M \subseteq \mathbb{R}^n$ konvex und kompakt und H eine Stützebene an M . Dann ist $R := H \cap M$ eine Randfläche von M und enthält eine Ecke von M .

Bew

Also ist jede Stützmenge auch Randfläche, aber i.a. nicht umgekehrt:

Beispiel 2.3.5 Bei der Vereinigung $M = ([-1, 0] \times [0, 1]) \cup (B_1(0) \cap \mathbb{R}_+^2)$ von Quadrat und Viertelkreis ist $e_2 = (0, 1)^T$ zwar eine Ecke, aber selbst nur Ecke einer Stützmenge.



Theorem 2.3.6 (Krein-Milman) Sei $M \neq \emptyset, M \subseteq \mathbb{R}^n$ konvex und kompakt. Dann gilt

Bew

$$M = \text{konv}(E(M)).$$

Konvexität und Randflächen-Eigenschaft sind 'monotone' bzw. transitive Eigenschaften.

Satz 2.3.7 a) $M \subseteq \mathbb{R}^n, M \neq \emptyset$ sei konvex und kompakt. Dann ist jede Randfläche von M konvex und kompakt.

b) Bei den konvexen Mengen $S \subseteq R \subseteq M \subseteq \mathbb{R}^n, S \neq \emptyset$, sei S Randfläche von R und R Randfläche von M . Dann ist auch S Randfläche von M und $E(R) \subseteq E(M)$.

Bew

2.4 Polyeder, Polytope, Kegel

Theorem 2.3.6 liefert für kompakte, konvexe Mengen eine vollständige, konstruktive Darstellung mit Hilfe der Ecken. Für unbeschränkte Mengen muß diese Darstellung aber ergänzt werden. Dazu konzentrieren wir uns jetzt auf *Polyeder*. Dieser Begriff wurde schon mehrfach informell für die Lösungsmengen von Ungleichungssystemen benutzt und wird nun zusammen mit einem verwandten Begriff eingeführt.

Definition 2.4.1 *Es sei $M \subseteq \mathbb{R}^n$ eine nichtleere Menge.*

a) *M heißt Polyeder, wenn eine Matrix $A \in \mathbb{R}^{m \times n}$ und ein Vektor $b \in \mathbb{R}^m$ existieren mit $M = \{x \in \mathbb{R}^n : Ax \leq b\}$.*

b) *M heißt Polytop, wenn (endlich viele) Punkte $x^{(0)}, \dots, x^{(k)} \in \mathbb{R}^n$ existieren mit $M = \text{konv}(x^{(0)}, \dots, x^{(k)})$. Wenn die Punkte $x^{(0)}, \dots, x^{(k)}$ dabei affin linear unabhängig sind, nennt man M einen k -Simplex.*

Polyeder und Polytope sind natürlich konvex. Beim Polyeder treten insbesondere in Satz 2.2.15 nur endlich viele (höchstens m) Halbräume auf. Ein Polytop $M = \text{konv}(x^{(0)}, \dots, x^{(k)})$ ist nach Satz 2.2.7 kompakt, da die Eckenmenge $E(M) \subseteq \{x^{(0)}, \dots, x^{(k)}\}$ kompakt ist. In einem k -Simplex S hat jeder Punkt $z \in S$ eine eindeutige Darstellung

$$z = \sum_{j=0}^k \lambda_j x^{(j)}, \quad (\lambda_j) \in \Delta_{k+1}.$$

Die zugehörigen λ_j sind die *baryzentrischen* Koordinaten von z in S , und $\bar{x} = \frac{1}{k+1} \sum_{j=0}^k x^{(j)}$ der *Schwerpunkt* von S .

Nach Theorem 2.3.6 ist ein Polytop durch seine Ecken explizit darstellbar. Im kompakten Fall gilt das auch für Polyeder, die zulässigen Bereiche von (LP):

Satz 2.4.2 *Ein nichtleeres, beschränktes Polyeder ist ein Polytop.*

Der Satz folgt direkt aus Theorem 2.3.6, wenn man weiß, dass jedes Polyeder nur endlich viele Ecken hat. Dieses Ergebnis wiederum ergibt sich elementar aus dem jetzt hergeleiteten Zusammenhang (Satz 2.4.3) zwischen den Ecken von $X = \{x : Ax \leq b\}$ und ihrer algebraischen Charakterisierung durch die *regulären $n \times n$ -Untermatrizen* von A . Da es überhaupt nur $\binom{m}{n}$ quadratische $n \times n$ -Untermatrizen gibt, ist diese Zahl auch eine obere Schranke für die der Ecken.

Formal wird zu einer Indexmenge $J = \{j_1, \dots, j_n\} \subseteq \{1, \dots, m\}$, $m \geq n$, der Größe $|J| = n$ die folgende Untermatrix $A^{(J)}$ gebildet. Analog geht man zur Bildung eines passenden Teilvektors $b_J \in \mathbb{R}^n$ vor:

$$A^{(J)} := \begin{pmatrix} a^{(j_1)} \\ \vdots \\ a^{(j_n)} \end{pmatrix} \in \mathbb{R}^{n \times n}, \quad b_J := \begin{pmatrix} b_{j_1} \\ \vdots \\ b_{j_n} \end{pmatrix} \in \mathbb{R}^n.$$

Satz 2.4.3 Das Polyeder $X = \{x : Ax \leq b\}$ sei durch $A \in \mathbb{R}^{m \times n}$, $b \in \mathbb{R}^m$, gegeben und es sei $z \in X$. Dann ist z genau dann Ecke, wenn es eine reguläre $n \times n$ -Untermatrix $A^{(J)}$, $J \subseteq \{1, \dots, m\}$, $|J| = n$, gibt mit $A^{(J)}z = b_J$. Bew

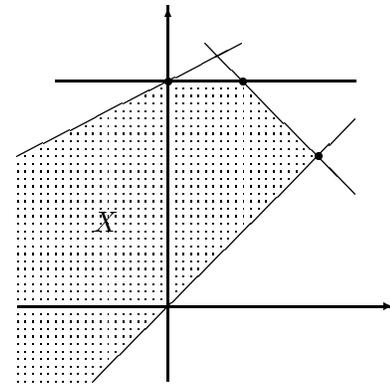
Bemerkung: a) Wenn die Matrix A nicht vollen Spaltenrang hat, also ein nichttrivialer Kern existiert, besitzt das Polyeder überhaupt keine Ecken, da mit $Ay = 0$, $y \neq 0$, und $x \in X$ auch $x + ty \in X \forall t \in \mathbb{R}$ gilt. Tatsächlich ist der Linealraum $L(X) = \text{kern}(A)$.

b) Das System $A^{(J)}z = b_J$ definiert den Schnittpunkt der n Hyperebenen $H(a^{(j)}, b_j)$, $j \in J$. Für eine Ecke z müssen aber auch die übrigen Zulässigkeitsbedingungen $A^{(K)}z \leq b_K$ mit $K = \{1, \dots, m\} \setminus J$ erfüllt sein.

Beispiel 2.4.4 Es sei $m = 4$, $n = 2$ und

$$A = \begin{pmatrix} 1 & -1 \\ 1 & 1 \\ 0 & 1 \\ -1 & 2 \end{pmatrix}, \quad b = \begin{pmatrix} 0 \\ 4 \\ 3 \\ 6 \end{pmatrix}$$

Es gibt $\binom{4}{2} = 6$ Indexmengen J mit $|J| = 2$, und da die zugehörigen Untermatrizen regulär sind, auch entsprechend viele Kreuzungspunkte von Hyperebenen (=Geraden). Allerdings sind nur drei davon zulässig, also Ecken von X :



$$\begin{aligned} 1) J = \{1, 2\} : \quad A^{(J)}x &= \begin{pmatrix} 1 & -1 \\ 1 & 1 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} 0 \\ 4 \end{pmatrix} = b_J : \quad x^{(1)} = \begin{pmatrix} 2 \\ 2 \end{pmatrix}, \\ 2) J = \{2, 3\} : \quad A^{(J)}x &= \begin{pmatrix} 1 & 1 \\ 0 & 1 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} 4 \\ 3 \end{pmatrix} = b_J : \quad x^{(2)} = \begin{pmatrix} 1 \\ 3 \end{pmatrix}, \\ 3) J = \{3, 4\} : \quad A^{(J)}x &= \begin{pmatrix} 0 & 1 \\ -1 & 2 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} 3 \\ 6 \end{pmatrix} = b_J : \quad x^{(3)} = \begin{pmatrix} 0 \\ 3 \end{pmatrix}. \end{aligned}$$

Das Beispiel zeigt, daß die Ecken hier nicht ausreichen, um die Menge X zu beschreiben. Die Menge enthält zusätzlich bestimmte Richtungen, in denen sie sich unendlich weit trichterförmig ausdehnt. Diese Gestalt läßt sich durch Kegel beschreiben, welche gegenüber konischen Kombinationen (vgl. Defin. 2.1.2) abgeschlossen sind.

Definition 2.4.5 a) Die nichtleere Menge $K \subseteq \mathbb{R}^n$ heißt konvexer Kegel, wenn $\lambda x + \mu y \in K$, $\forall x, y \in K$, $\lambda, \mu \in \mathbb{R}_+$.

b) Der konvexe Kegel $K \subseteq \mathbb{R}^n$, $K \neq \emptyset$, heißt spitz, wenn $K \cap (-K) = \{0\}$ ist.

c) Zu einer beliebigen Menge $M \subseteq \mathbb{R}^n$ ist

$$\text{konus}(M) := \bigcup_{k \in \mathbb{N}} \left\{ \sum_{i=1}^k \lambda_i x^{(i)} : x^{(i)} \in M, \lambda_i \in \mathbb{R}_+ \right\}$$

der von M erzeugte Kegel. Ein Kegel K heißt endlich erzeugt, wenn $K = \text{konus}(b_1, \dots, b_k)$ ist, $b_1, \dots, b_k \in \mathbb{R}^n$, d.h.,

$$K = B \cdot \mathbb{R}_+^k = \{By : y \in \mathbb{R}_+^k\} \quad \text{mit } B = (b_1, \dots, b_k) \in \mathbb{R}^{n \times k}. \quad (2.4.1)$$

Bemerkung: a) K konvexer Kegel $\iff K = \text{konus}(K)$.

b) Wenn M schon konvex war, gilt einfach $\text{konus}(M) = \mathbb{R}_+ \cdot M = \{\lambda x : x \in M, \lambda \geq 0\}$. Daher ist für beliebiges M auch $\text{konus}(M) = \mathbb{R}_+ \cdot \text{konv}(M)$.

c) Analog zur Situation bei konvexen Mengen sind nichtleere Durchschnitte und Linearkombinationen von konvexen Kegeln wieder welche.

d) Die Darstellung (2.4.1) besagt, dass K als lineares Bild des Standard-Kegels \mathbb{R}_+^k darstellbar ist (unter der zu B gehörigen linearen Abbildung).

e) Für einen konvexen Kegel K ist die affine Hülle $\text{aff}(K) = K - K$ und der Linealraum $L(K) = K \cap (-K)$. Spitze Kegeln haben also trivialen Linealraum.

Beispiel 2.4.6 a) \mathbb{R}_+^n ist natürlich ein endlich erzeugter konvexer Kegel.

b) Lineare Unterräume $U \subseteq \mathbb{R}^n$ sind endlich erzeugte konvexe Kegel. Mit einer Basismatrix $B \in \mathbb{R}^{n \times l}$, $U = B \cdot \mathbb{R}^l$, läßt sich U auch als Kegel schreiben, $U = (B, -B) \cdot \mathbb{R}_+^{2l}$ (vgl. §1.3, Umformung 3).

Das nächste Beispiel hat für die Behandlung von Polyedern zentrale Bedeutung.

Satz 2.4.7 Gegeben sei das Polyeder $X = \{x : Ax \leq b\}$, $A \in \mathbb{R}^{m \times n}$, $b \in \mathbb{R}^m$. Dann ist $O^+(X) := \{x : Ax \leq 0\}$ ein konvexer Kegel. Er wird Ausdehnungskegel von X genannt, es gilt Bew

$$O^+(X) = \{y : x + \lambda y \in X \ \forall x \in X, \lambda \in \mathbb{R}_+\}.$$

Der Kegel $O^+(X)$ enthält alle Richtungen, in die sich X nach unendlich ausdehnt, beim Polyeder ist $O^+(X)$ nach dem Satz also die Lösungsmenge des *homogenen* Ungleichungssystems analog zur Situation bei Linearen Gleichungssystemen.

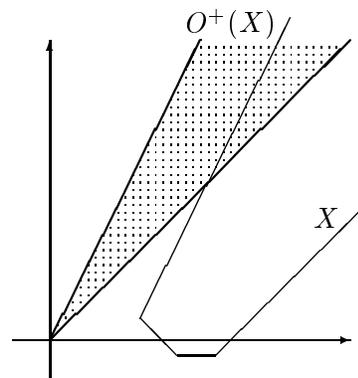
Bemerkung: Für Polyeder $X \neq \emptyset$ gilt offensichtlich

a) $X + O^+(X) = X$.

b) X kompakt $\iff O^+(X) = \{0\}$.

c) $O^+(X)$ ist spitz, wenn $L(X) = \text{kern}(A) = \{0\}$.

d) Bedeutung für (LP), $\max\{c^T x : x \in X\}$: Für nichttriviales $c \in O^+(X)$ ist (LP) unbeschränkt, denn da dann mit $\bar{x} \in X$ auch $x = \bar{x} + \lambda c \in X \ \forall \lambda \geq 0$, ist $\sup\{c^T(\bar{x} + \lambda c) : \lambda \geq 0\} = \infty$.



Beispiel 2.4.8 Zum Beispiel 2.4.4 ist der Ausdehnungskegel $O^+(X)$ durch das homogene System

$$\begin{pmatrix} 1 & -1 \\ 1 & 1 \\ 0 & 1 \\ -1 & 2 \end{pmatrix} x \leq 0$$

bestimmt. Dieses entspricht den Bedingungen $x_1 \leq x_2 \leq 0$, $x_2 \leq -x_1$, $x_2 \leq x_1/2$. Also kommt nur $x_1 \leq 0$ in Frage und es bleiben nur $x_1 \leq x_2 \leq \frac{1}{2}x_1$. Das sind die Bedingungen zu $A^{(J)}x \leq 0$ mit $J = \{1, 4\}$. Die beiden homogenen Lösungen zu $a^{(j)\top}x^{(j)} = 0$, $j \in J$, erzeugen diesen Kegel

$$O^+(X) = \text{konus}\{x^{(1)}, x^{(4)}\} = \text{konus}\left\{\begin{pmatrix} -1 \\ -1 \end{pmatrix}, \begin{pmatrix} -2 \\ -1 \end{pmatrix}\right\}.$$

Im zentralen Dekompositionssatz wird der Ausdehnungskegel benötigt, um Theorem 2.3.6 für unbeschränkte Polyeder zu ergänzen. Bisher ist aber nur die *implizite* Beschreibung von $O^+(X)$ aus Satz 2.4.7 durch das homogene Ungleichungssystem bekannt, unklar ist auch, ob eine endliche Erzeugermenge für ihn existiert.

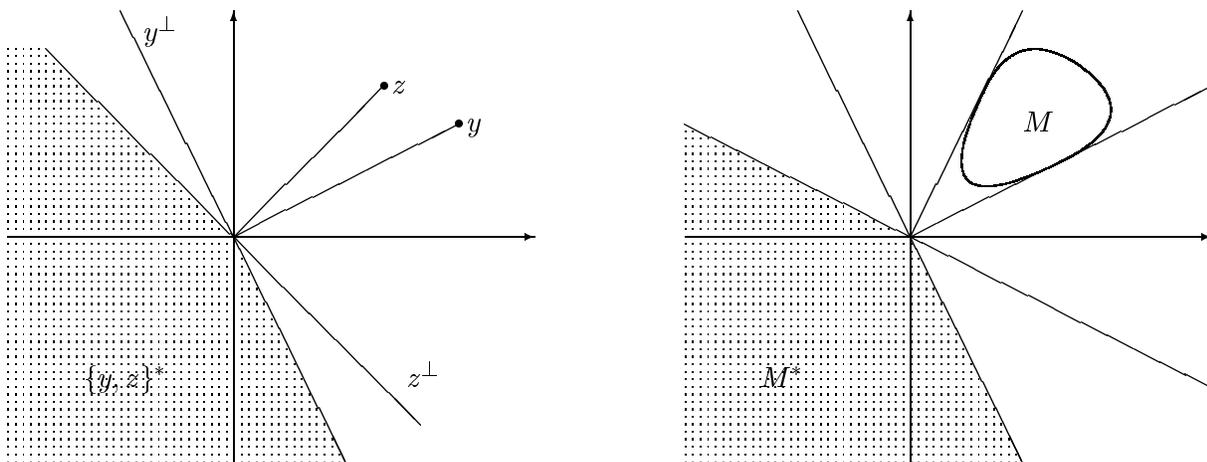
Satz 2.4.9 Der konvexe Kegel $K := \{x : Ax \leq 0\}$, $A \in \mathbb{R}^{m \times n}$, ist endlich erzeugt.

Bew

Bevor die Zerlegung von Polyedern weiter verfolgt wird, wird kurz ein abgeleiteter Kegel studiert, der die Interpretation einiger Ergebnisse erleichtert.

Definition 2.4.10 Der Polarkegel (duale Kegel) zu einer nichtleeren Menge $M \subseteq \mathbb{R}^n$ ist

$$M^* := \{x \in \mathbb{R}^n : y^\top x \leq 0 \forall y \in M\} = \bigcap_{y \in M} H^\ominus(y, 0).$$



Bemerkung: a) Für einen linearen Unterraum $U \subseteq \mathbb{R}^n$ ist $U^* = U^\perp$.

b) Für $M \neq \emptyset$ gilt $M^* = (\text{konus}(M))^*$ und $M \subseteq M^{**} := (M^*)^*$.

c) Der Definition nach entspricht der Polyeder-Kegel $K = \{x : Ax \leq 0\}$ gerade dem Polarkegel zu den Zeilen von A , $K = \{a^{(1)}, \dots, a^{(m)}\}^* = (A^\top \cdot \mathbb{R}_+^m)^*$.

Bemerkung b) kann für die hier interessierenden Kegel präzisiert werden (o.Bew.).

Satz 2.4.11 *Für einen endlich erzeugten konvexen Kegel K gilt $K^{**} = K$.*

Also ist für $K = \{x : Ax \leq 0\}$ der Polarkegel $K^* = A^\top \cdot \mathbb{R}_+^m$ und daher endlich erzeugt. Mit diesem Satz kann die obige Bemerkung d) zur Unbeschränktheit von (LP1) präzisiert werden. Für $\bar{x} \in X$, $y \in O^+(X)$ ist auf dem Strahl $\{x = \bar{x} + \lambda y : \lambda \geq 0\}$ der Wert der Zielfunktion $c^\top x = c^\top \bar{x} + \lambda c^\top y$ genau dann unbeschränkt, wenn $c^\top y > 0$ gilt. Also, gilt *nicht*: $c^\top v \leq 0 \forall v \in O^+(X)$. Dies heißt aber gerade, dass c *nicht* im Polarkegel $(O^+(X))^* = A^\top \cdot \mathbb{R}_+^m$ liegt. Dieses Ergebnis (LP1) *unbeschränkt* $\iff c \notin A^\top \cdot \mathbb{R}_+^m$ wird in der Dualitätstheorie wieder auftauchen.

2.5 Der Dekompositionssatz für Polyeder

Zur Ergänzung der Polyeder-Zerlegung muß auch der Ausdehnungskegel berücksichtigt werden. Bei der endlichen Darstellung von Polyeder-Kegeln, vgl. Satz 2.4.9, kann eine Minimalmenge erforderlicher Richtungen identifiziert werden, die Kanten des Kegels. Wir beschränken uns auf spitze Kegel, da sonst keine Ecken existieren. Eine wichtige Schlußweise in spitzen Kegeln K ist, dass für die Null nur die triviale konische Kombination möglich ist,

$$\sum_{i=1}^k \lambda_i y^{(i)} = 0, \text{ mit } y^{(i)} \in K, \lambda_i \geq 0 \quad \Rightarrow (\lambda_i) = 0.$$

Denn, für $\lambda_j > 0$ wäre mit $y^{(j)}$ auch $-y^{(j)} = \sum_{i \neq j} (\lambda_i / \lambda_j) y^{(i)} \in K$ und K hätte nichttrivialen Linealraum, da $\text{konus}(y^{(j)}, -y^{(j)}) = \text{span}(y^{(j)}) \subseteq L(K)$.

Satz 2.5.1 *Wenn der konvexe Kegel $K := \{x : Ax \leq 0\}$, $A \in \mathbb{R}^{m \times n}$, spitz ist, kann K durch die Richtungen seiner Kanten erzeugt werden.*

Bew

Ähnlich zu Satz 2.4.3 können auch die Kanten über $(n-1) \times n$ -Untermatrizen von A bestimmt werden. Zu $y \in \{x : Ax \leq 0\} \setminus \{0\}$ ist $\text{konus}(y)$ genau dann Kante, wenn eine Untermatrix $A^{(J)}$ maximalen Ranges $|J| = n-1$ existiert mit $A^{(J)}y = 0$. Für das folgende Theorem wird $\text{konus}(\emptyset) := \{0\}$ verabredet.

Theorem 2.5.2 *Es sei $X := \{x \in \mathbb{R}^n : Ax \leq b\} \neq \emptyset$ der durch $A \in \mathbb{R}^{m \times n}$, $b \in \mathbb{R}^m$ bestimmte Polyeder mit $L(X) = \{0\}$. Dann ist X die Summe eines Polytops und eines endlich erzeugten Kegels. Mit den Ecken $x^{(i)}$, $i = 1, \dots, k$, von X und Kantenrichtungen $y^{(j)}$, $j = 1, \dots, \ell$, von $O^+(X)$ gilt*

Bew

$$\begin{aligned} X &= \text{konv}(E(X)) + O^+(X) \\ &= \text{konv}(x^{(1)}, \dots, x^{(k)}) + \text{konus}(y^{(1)}, \dots, y^{(\ell)}). \end{aligned}$$

Dieses Theorem über die endliche Zerleg- bzw. Darstellbarkeit von Polyedern (er gilt auch allgemein, nach Einschränkung auf $L(X)^\perp$) liefert die Rechtfertigung für das Vorgehen bei den numerischen Verfahren, wo ausschließlich die Ecken und Kantenrichtungen von X inspiziert werden.

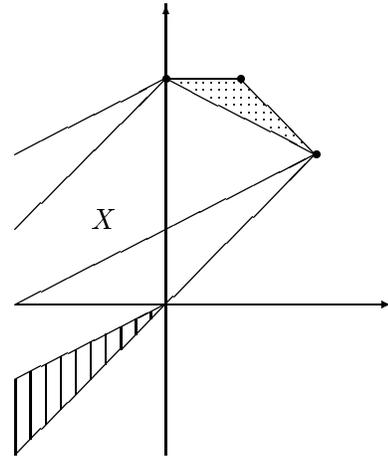
Beispiel 2.5.3 Zusammenfassung der Beispiele 2.4.6/8: das Polyeder $X := \{x : Ax \leq b\}$ mit

$$A = \begin{pmatrix} 1 & -1 \\ 1 & 1 \\ 0 & 1 \\ -1 & 2 \end{pmatrix}, \quad b = \begin{pmatrix} 0 \\ 4 \\ 3 \\ 6 \end{pmatrix}$$

läßt sich darstellen in der Form

$$X = \text{konv}\left\{\begin{pmatrix} 2 \\ 2 \end{pmatrix}, \begin{pmatrix} 1 \\ 3 \end{pmatrix}, \begin{pmatrix} 0 \\ 3 \end{pmatrix}\right\} + \text{konus}\left\{\begin{pmatrix} -1 \\ -1 \end{pmatrix}, \begin{pmatrix} -2 \\ -1 \end{pmatrix}\right\}.$$

Im Bild zeigt der punktierte Teil das Polytop $\text{konv}(E(X))$, unten ist schraffiert der Ausdehnungskegel $O^+(X)$ eingezeichnet, welcher im Theorem an jeden Punkt des Polytops 'angeheftet' wird. Die zwei extremalen verschobenen Kegel sind ebenfalls eingezeichnet.



2.6 Existenzsätze für Ungleichungssysteme

Die bisherigen Sätzen bezogen sich naturgemäß auf den Fall nichtleerer zulässiger Bereiche X . Kriterien für die Gültigkeit dieser Voraussetzung, d.h., die Lösbarkeit der Ungleichungssysteme, werden jetzt als weitere Anwendung der Trennungssätze aus §2.2 hergeleitet. Grundlage ist das folgende Lemma von Farkas, es bildet insbesondere auch die Basis für die Dualitätstheorie linearer Programme. Es orientiert sich klassisch an der Form (LP3):

Satz 2.6.1 (Farkas) Mit $A \in \mathbb{R}^{m \times n}$, $b \in \mathbb{R}^m$ gilt

Bew

$$\{x \in \mathbb{R}^n : Ax = b, x \geq 0\} \neq \emptyset \iff \left(y^\top A \geq 0^\top \Rightarrow y^\top b \geq 0 \forall y \in \mathbb{R}^m\right). \quad (2.6.1)$$

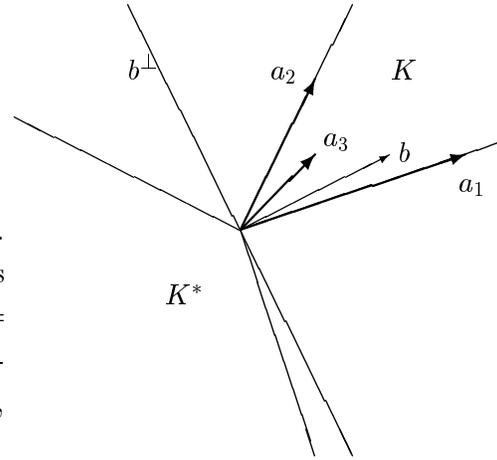
Geometrische Interpretation: Die Lösbarkeit des Systems auf der linken Seite bedeutet, dass b als konische Kombination der Spalten von A ausgedrückt werden kann, $b \in A\mathbb{R}_+^n =: K$. Die rechte Seite von (2.6.1) heißt, dass $-y \in H^\ominus(b, 0) = \{b\}^*$ für jeden Vektor $-y \in \{a_1, \dots, a_n\}^*$ im Polarkegel $K^* = (A\mathbb{R}_+^n)^*$. Also entspricht (2.6.1) der einfachen Aussage:

$$b \in A \cdot \mathbb{R}_+^n = \text{konus}(a_1, \dots, a_n) \iff \{a_1, \dots, a_n\}^* \subseteq \{b\}^* = H^\ominus(b, 0).$$

Beispiel 2.6.2 Bei

$$A = \begin{pmatrix} 3 & 1 & 1 \\ 1 & 2 & 1 \end{pmatrix}$$

ist $a_3 = \frac{1}{5}a_1 + \frac{2}{5}a_2$, also $K := A\mathbb{R}_+^3 = \text{konus}\{a_1, a_2\}$.
 Daher ist $K^* = \{y : 3y_1 + y_2 \leq 0, y_1 + 2y_2 \leq 0\}$ das darstellbar ist als $K^* = \text{konus}\{y^{(1)}, y^{(2)}\}$ mit $y^{(1)} = \begin{pmatrix} -2 \\ 1 \end{pmatrix}$, $y^{(2)} = \begin{pmatrix} 1 \\ -3 \end{pmatrix}$. Es liegt $K^* \subseteq \{b\}^*$, wenn alle Erzeugenden dies tun. Also gilt $b \in K \iff b^T y^{(i)} \leq 0$, $i = 1, 2$.



Analoge Lösbarkeitssätze gibt es auch für die allgemeine Standardform

Satz 2.6.3 Mit $A_{ij} \in \mathbb{R}^{m_i \times n_j}$, $b_i \in \mathbb{R}^{m_i}$, $i, j = 1, 2$, sind äquivalent:

Bew.

$$\exists x_1 \in \mathbb{R}^{n_1}, x_2 \in \mathbb{R}^{n_2} \text{ mit } \begin{cases} A_{11}x_1 + A_{12}x_2 \leq b_1 \\ A_{21}x_1 + A_{22}x_2 = b_2 \\ x_2 \geq 0 \end{cases}$$

und

$$\forall y_1 \in \mathbb{R}^{m_1}, y_2 \in \mathbb{R}^{m_2} \text{ mit } \begin{cases} y_1^T A_{11} + y_2^T A_{21} = 0^T \\ y_1^T A_{12} + y_2^T A_{22} \geq 0^T \\ y_1 \geq 0 \end{cases} \Rightarrow y_1^T b_1 + y_2^T b_2 \geq 0.$$

Die anderen Formen der Standardprogramme sind darin als Spezialfälle enthalten, als Übersicht:

$$\begin{aligned} \text{(LP1)} \quad \{x \in \mathbb{R}^n : Ax \leq b\} \neq \emptyset &\iff \{y^T A = 0^T \Rightarrow y^T b \geq 0 \forall y \in \mathbb{R}_+^m\} \\ \text{(LP2)} \quad \{x \in \mathbb{R}^n : Ax \leq b, x \geq 0\} \neq \emptyset &\iff \{y^T A \geq 0^T \Rightarrow y^T b \geq 0 \forall y \in \mathbb{R}_+^m\} \\ \text{(LP3)} \quad \{x \in \mathbb{R}^n : Ax = b, x \geq 0\} \neq \emptyset &\iff \{y^T A \geq 0^T \Rightarrow y^T b = 0 \forall y \in \mathbb{R}^m\} \\ \text{(LGS)} \quad \{x \in \mathbb{R}^n : Ax = b\} \neq \emptyset &\iff \{y^T A = 0^T \Rightarrow y^T b = 0 \forall y \in \mathbb{R}^m\} \end{aligned}$$

Als vierte Variante wurden Gleichungssysteme aufgenommen. Das Lösbarkeitskriterium dort ist bekanntlich $b \in (A \cdot \mathbb{R}^n) = \text{kern}(A^T)^\perp$ und wird oft als Fredholm-Alternative formuliert. Auch die obigen Kriterien können als Alternativsätze formuliert werden, z.B.:

$$\begin{aligned} \text{(LGS)} \quad \text{Entweder ist } Ax = b \text{ lösbar, oder } y^T A = 0^T, \quad y^T b = 1 \\ \text{(LP1)} \quad \text{Entweder ist } Ax \leq b \text{ lösbar, oder } y^T A = 0^T, y \geq 0, \quad y^T b = -1 \\ \text{(LP3)} \quad \text{Entweder ist } Ax = b, x \geq 0 \text{ lösbar, oder } y^T A \geq 0^T, \quad y^T b = -1 \end{aligned}$$

Die Merkgeln für den Zusammenhang zwischen den Alternativsystemen entsprechen denen bei der Dualität und werden dort formuliert.

3 Duale Programme

3.1 Optimalitätskriterien

Im letzten Abschnitt konnten wichtige Aussagen zur Lösbarkeit eines Ungleichungssystems mit Eigenschaften eines verwandten Systems in Beziehung gesetzt werden. Diese Zusammenhänge können auf vollständige Lineare Programme durch Betrachtung ihrer dualen Versionen erweitert werden. Als wichtiges Handwerkszeug für die Praxis werden dabei Kriterien für die *Optimalität* eines zulässigen Punktes x hergeleitet, die *effektiv nachprüfbar* sind, d.h., keine aufwendigen Berechnungen erfordern.

Der Vollständigkeit halber wird hier die duale Form (LP*) zum allgemeinen *primalem* Programm (LP) angegeben.

$$\begin{array}{l}
 \text{(LP)} \quad \left. \begin{array}{l} \max \quad c_1^\top x_1 + c_2^\top x_2 \\ A_{11}x_1 + A_{12}x_2 \leq b_1 \\ A_{21}x_1 + A_{22}x_2 = b_2 \\ x_2 \geq 0 \end{array} \right\} \left\{ \begin{array}{l} \min \quad b_1^\top y_1 + b_2^\top y_2 \\ A_{11}^\top y_1 + A_{21}^\top y_2 = c_1 \\ A_{12}^\top y_1 + A_{22}^\top y_2 \geq c_2 \\ y_1 \geq 0 \end{array} \right. \quad \text{(LP*)}
 \end{array}$$

Die Übergänge (LP) \rightarrow (LP*) und (LP*) \rightarrow (LP**)=(LP) sind symmetrisch und geschehen nach folgenden Merkgeln:

1. Die Koeffizientenmatrix wird transponiert,
2. der Gradientenvektor der Zielfunktion wird mit der rechten Seite des (Un-) Gleichungssystems getauscht mit den Entsprechungen "max \leftrightarrow \geq ", "min \leftrightarrow \leq ",
3. Ungleichungsrestriktionen werden ausgetauscht durch vorzeichenbeschränkte Variable, Gleichungen durch freie Variable und umgekehrt.

In der Regel betrachtet man eine der Standardformen (LP1..3), für diese ist insbesondere

(LP1)	$\begin{array}{l} \max \quad c^\top x \\ Ax \leq b \end{array}$	$\begin{array}{l} \min \quad b^\top y \\ A^\top y = c \\ y \geq 0 \end{array} \quad \text{(LP1*)}$
(LP2)	$\begin{array}{l} \max \quad c^\top x \\ Ax \leq b \\ x \geq 0 \end{array}$	$\begin{array}{l} \min \quad b^\top y \\ A^\top y \geq c \\ y \geq 0 \end{array} \quad \text{(LP2*)}$
(LP3)	$\begin{array}{l} \max \quad c^\top x \\ Ax = b \\ x \geq 0 \end{array}$	$\begin{array}{l} \min \quad y^\top b \\ A^\top y \geq c \end{array} \quad \text{(LP3*)}$

Diese Übersicht läßt den Grund für die Berücksichtigung der Form (LP2) erkennen, es ist diejenige, bei der das duale Programm i.w. die gleiche Gestalt hat. Für die Zielfunktionen in zulässigen Punkten von primalem und dualem Programm gibt es einen grundlegenden Zusammenhang:

Satz 3.1.1 Der Vektor $x^\top = (x_1^\top, x_2^\top)$ sei zulässig für (LP) und $y^\top = (y_1^\top, y_2^\top)^\top$ zulässig für (LP*). Dann gilt für die Zielfunktionen $c^\top x = c_1^\top x_1 + c_2^\top x_2$ und $b^\top y = b_1^\top y_1 + b_2^\top y_2$ die Beziehung

$$c^\top x \leq b^\top y.$$

Bei Gleichheit, $c^\top x = b^\top y$, ist x optimal für (LP) und y optimal für (LP*).

Bew

Anwendung Bei Kenntnis von zulässigen Punkten \hat{x}, \hat{y} ist die Prüfung auf Optimalität, $c^\top \hat{x} = b^\top \hat{y}$, trivial (z.B., für Auftraggeber). Und trivialerweise erhält man für jedes dual zulässige y aus $b^\top y$ eine obere Schranke für den Optimalwert bei (LP).

Einzelne Eigenschaften der Programme haben eine bestimmte Bedeutung für das dazu duale. Es sei daran erinnert, dass mit der *Lösung* eines Programms eine Optimallösung gemeint ist. Ein Problem mit nichtleerem zulässigem Bereich nennt man *konsistent*, ansonsten *inkonsistent*. Die folgenden Sätze werden jeweils nur für dasjenige Standardprogramm (LP i) bewiesen, dessen Form sich dazu anbietet. Sie gelten aber natürlich für (LP). In den folgenden Beweisen spielt das Lemma von Farkas eine zentrale Rolle.

Satz 3.1.2 Die Probleme (LP) und (LP*) seien beide konsistent. Dann existieren auch Lösungen für beide Programme.

Bew

Der folgende Satz nutzt die Tatsache aus, dass in einer Lösung von Problem (LP1) nur ein Teil der Restriktionen *straff* sind, vgl. Satz 2.4.3. Im Beweis wird ein Zusammenhang zwischen den Lösungen von Primal- und Dual-Problem konstruiert, der weitergehende Bedeutung hat.

Satz 3.1.3 Es sei $\hat{x} \in \mathbb{R}^n$ eine Lösung von (LP1) und $A \in \mathbb{R}^{m \times n}$, $b \in \mathbb{R}^m$.

a) Mit $J \subseteq \{1, \dots, m\}$, $K = \{1, \dots, m\} \setminus J$ gelte dabei

$$A^{(J)} \hat{x} = b_J, \quad A^{(K)} \hat{x} < b_K.$$

Dann ist \hat{x} auch Lösung des reduzierten Programms $\max\{c^\top x : A^{(J)} x \leq b_J\}$.

Bew

b) Dann hat das duale Programm (LP1*) eine Lösung.

Beweis für b) Für ein beliebiges zulässiges Element des reduzierten Programms gilt nach Teil

a) $A^{(J)} x \leq b_J = A^{(J)} \hat{x}$ und $c^\top x \leq c^\top \hat{x}$, also die Folgerung

$$A^{(J)}(\hat{x} - x) \geq 0 \Rightarrow c^\top(\hat{x} - x) \geq 0 \quad \forall x \in \mathbb{R}^n.$$

Nach Satz 2.6.3 (Farkas) ist daher die Menge $Y_J := \{y_J : y_J^\top A^{(J)} = c^\top, y_J \geq 0\} \neq \emptyset$. Daraus folgt aber sofort, dass der zulässige Bereich $Y := \{y \in \mathbb{R}^m : y^\top A = c^\top, y \geq 0\}$ von (LP1*) ebenfalls nicht leer ist. Denn mit $y_J \in Y_J$ liegt $y^\top := (y_J^\top, y_K^\top)$, $y_K := 0_K$ in Y , es gilt

$$y^\top A = y_J^\top A^{(J)} + 0_K^\top A^{(K)} = c^\top, \quad \text{sowie} \quad y^\top b = y_J^\top b_J + 0_K^\top b_K = y_J^\top A \hat{x} = c^\top \hat{x}. \quad (3.1.1)$$

Da die Zielfunktionen gleich sind, ist nach Satz 3.1.1 jedes solche y optimal bei (LP1*). ■

Wenn die Untermatrix $A^{(J)}$ im letzten Satz zu den straffen Restriktionen maximalen Rang hat, besteht Y_J aus genau einem Punkt y_J , der wie im Beweis zu einer Lösung $y^\top = (y_J^\top, 0_K^\top)$ von (LP1*) ergänzt werden kann.

Theorem 3.1.4 (Dualitätssatz) *Das Lineare Programm (LP) ist genau dann lösbar, wenn (LP*) lösbar ist.*

Bew

Wenn beide Probleme inkonsistent sind, ist die Situation klar. Andernfalls gilt:

Satz 3.1.5 *Wenn nur eines der Programme (LP) oder (LP*) zulässige Punkte hat, dann ist dessen Zielfunktion unbeschränkt.*

Bew

Die Unbeschränktheit von (LP1) wurde schon am Ende von §2.4 behandelt, das dortige, über Polarkegel hergeleitete, Kriterium $c \notin A^\top \mathbb{R}_+^m$ entspricht gerade der Unlösbarkeit des Systems $A^\top y = c, y \geq 0$. Insgesamt ergibt sich folgende Situation:

Zusammenfassung	(LP) hat zulässige Punkte	(LP) inkonsistent
(LP*) hat zulässige Punkte	(LP) und (LP*) lösbar	(LP*) unbeschränkt
(LP*) inkonsistent	(LP) unbeschränkt	keine Lösungen

3.2 Komplementarität, Schattenpreise

Zur Vorbereitung des Dualitätssatzes wurde in Satz 3.1.3 i.w. die Konstruktion einer dualen Optimallösung aus der primalen durchgeführt. Ansatzpunkt war die Erkenntnis, dass in Optimallösungen bestimmte Restriktionen *straff* sind, d.h., Gleichheit gilt. Eine analoge Formulierung bzw. Schlußweise verwendet dazu die folgende *strukturelle Orthogonalität* bei nicht-negativen Vektoren:

$$u, v \geq 0, u^\top v = 0 \Rightarrow \forall i: \{u_i = 0 \text{ oder } v_i = 0\}$$

Satz 3.2.1 (Komplementarität)

a) *Es sei x zulässig für (LP1), y für (LP1*). Beide Punkte sind genau dann optimal, wenn gilt*

$$y^\top (b - Ax) = 0, \quad \text{d.h., für } i = 1, \dots, m: \begin{cases} y_i > 0 \Rightarrow a^{(i)\top} x = b_i \\ a^{(i)\top} x < b_i \Rightarrow y_i = 0 \end{cases}.$$

b) *Es sei x zulässig für (LP) und y für (LP*). Beide Punkte sind genau dann optimal, wenn gilt*

Bew

$$y^\top (b - Ax) = 0 \quad \text{und} \quad (y^\top A - c^\top)x = 0. \quad (3.2.1)$$

Anmerkung: In Teil b) des Satzes wurde zur einfacheren Darstellung eine etwas verkürzte Schreibweise gewählt. Die Anteile der Gleichungsrestriktionen an den Innenprodukten verschwinden von vorneherein. In den restlichen bedeutet (3.2.1) ausführlich

$$y_1^\top (b_1 - A_{11}x_1 - A_{12}x_2) = 0, \quad (y_1^\top A_{12} + y_2^\top A_{22} - c_2^\top)x_2 = 0.$$

Damit markieren die nichtverschwindenden Komponenten von y_1 die straffen Restriktionen von (LP) und die nichttrivialen bei x_2 die straffen bei (LP*).

Man redet im Zusammenhang mit Satz 3.2.1 auch von *komplementärem Schlupf*. Denn die Ungleichungen in (LP) und (LP*) können durch Einführung von Schlupfvariablen $u_1 \geq 0, v_2 \geq 0$ zu Gleichungsrestriktionen gemacht werden, $A_{11}x_1 + A_{12}x_2 + u_1 = b_1, A_{12}^T y_1 + A_{22}^T y_2 - v_2 = c_2$. Damit entspricht die Bedingung (3.2.1) einfach der Aussage

$$y_1^T u_1 = 0, \quad v_2^T x_2 = 0,$$

dass je Komponente die Schlupfvariable im $\left\{ \begin{array}{l} \text{primalen} \\ \text{dualen} \end{array} \right.$ Problem oder die Variable im $\left\{ \begin{array}{l} \text{dualen} \\ \text{primalen} \end{array} \right.$ Problem verschwindet.

Außer den Existenzaussagen zu Lösungen können aus dem dualen Problem auch *quantitative* Angaben zum Primalproblem abgeleitet werden. Die Größe b enthält in (LP1) die oberen Schranken für die einzelnen Ressourcen (angelehnt an das Beispiel Produktionsplanung in §1.3), die einer Vergrößerung des Gewinns $c^T x$ im Wege stehen. In einem Lösungs-Paar \hat{x}, \hat{y} wird die Aufteilung der Restriktionen wie in Satz 3.1.3 benutzt,

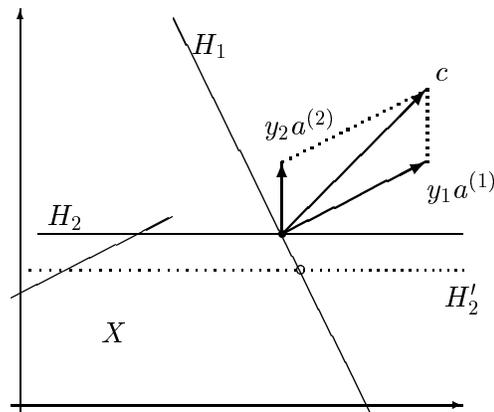
$$A^{(J)} \hat{x} = b_J, \quad A^{(K)} \hat{x} < b_K, \quad J \cup K = \{1, \dots, m\}.$$

Die Restriktionen zu J sind also straff, die zu K locker und aus dem Komplementaritätssatz folgt $\hat{y}_K = 0$. Für die Zielfunktion gilt nun $W := c^T \hat{x} = b^T \hat{y} = b_J^T \hat{y}_J$. Für eine Vergrößerung des Gewinns ist es sicher nicht sinnvoll, Restriktionen aus K weiter zu lockern. In dem dualen Wert $b^T \hat{y}$ kommt das dadurch zum Ausdruck, dass eine Vergrößerung von b_K wegen $\hat{y}_K = 0$ keine Auswirkung hätte. Dagegen stellen die straffen Restriktionen aus J *Flaschenhälse* dar. Bei einer kleinen Änderung $b_J \rightarrow b_J + \bar{b}_J$ ($\|\bar{b}_J\| \leq \epsilon$) bleibt die zugehörige Lösung $\hat{x} + \bar{x}$ in der Regel (z.B., im generischen Fall $|J| = n, A^{(J)}$ regulär) weiterhin zulässig mit $A^{(K)}(\hat{x} + \bar{x}) \leq b_K$, und die Zielfunktion verändert sich gemäß

$$c^T(\hat{x} + \bar{x}) = (b_J + \bar{b}_J)^T \hat{y}_J = W + \bar{b}_J^T \hat{y}_J.$$

Also gibt die Komponente \hat{y}_i an, welche direkte Auswirkung eine Vergrößerung der Schranke b_i auf den Zielwert hat.

Geometrische Interpretation Die nichttrivialen Werte \hat{y}_J der dualen Variablen erfüllen $\hat{y}_J^T A^{(J)} = c^T, y_J \geq 0$. Geometrisch bedeutet das, dass der Zielgradient c konische Kombination der J -Zeilen von A ist, also in dem davon erzeugten Kegel liegt, $c \in \text{konus}\{a^{(j)} : j \in J\}$. Dies ist auch geometrisch klar, denn da die $a^{(j)}$ die Normalen auf den Randflächen H_j des Polyeders X sind, würde andernfalls das Maximum überhaupt nicht in \hat{x} (schwarzer Punkt) angenommen. Verringert man im Bild ($J = \{1, 2\}$) den Wert b_2 etwas, entspricht



die neue Nebenbedingung der gestrichelten Ebene H'_2 und der Optimalpunkt bewegt sich mit (offener Kreis). Der Wert $c^\top x$ ändert sich aber nicht im gleichen Ausmaß, nur proportional zu y_2 , da $a^{(2)}$ im Bild nur einen kleineren Anteil an c hat.

Ökonomische Interpretation Man nennt die Komponenten \hat{y}_i der dualen Variablen auch *Schattenpreise*, da ihr Wert angibt, welchen Preis dem Nutzer eine Vergrößerung von b_i wert ist. Diese Interpretation läßt sich anhand der Beispiele aus §1.2 erläutern.

Beispiel 3.2.2 Die *Produktionsplanung* hat die Standardform (LP2), wobei c_j den Preis für das Produkt P_j und b_i den Umfang der begrenzten Resource R_i angibt. Mit einer Lösung y des dualen Programms

$$\min b^\top y, \quad \sum_{i=1}^m y_i a_{ij} \geq c_j, \quad j = 1, \dots, n, \quad y \geq 0,$$

kann y_i als innerer oder Schattenpreis der Resource R_i interpretiert werden. Nach der Vorüberlegung darf die (Vergrößerung der) Resource R_i höchstens diesen Preis y_i kosten, damit beim Verkauf ein Zugewinn bleibt. Das duale Programm bestimmt diese Preise so, dass der innere Gesamtpreis der verwendeten Ressourcen $\sum_i b_i y_i = c^\top x$ beim Verkauf der Produkte (x_j) erzielt wird. Dabei unterschreitet der innere Einzelpreis $\sum_i y_i a_{ij}$ von Produkt P_j nicht den beim Verkauf erzielten äußeren Preis c_j .

Die Folgerungen des Komplementaritätssatzes

$$\left\{ \sum_{j=1}^n a_{ij} x_j < b_i \Rightarrow y_i = 0 \right\}, \quad \left\{ \sum_{i=1}^m y_i a_{ij} > c_j \Rightarrow x_j = 0 \right\}$$

können so interpretiert werden:

- Eine Resource, die nicht ausgeschöpft wird, ist im Überfluß vorhanden und bekommt den inneren Preis null
- Ein Produkt, dessen innerer Preis höher als der erzielbare ist, wird nicht hergestellt.

Beispiel 3.2.3 Beim *Transportproblem* war s_i die Kapazität von Produzent P_i und r_j der Bedarf von Abnehmer V_j . Das duale Problem hat die Form

$$\max \left(\sum_{i=1}^m u_i s_i - \sum_{j=1}^n v_j r_j \right) : v_j - u_i \leq c_{ij}, \quad u_i, v_j \geq 0.$$

Interpretiert man u_i als Herstellungspreis bei P_i und v_j als Abnahmepreis bei V_j , bedeutet diese Form, dass zwar der Gesamtgewinn $\sum u_i s_i - \sum v_j r_j$ maximiert wird, aber die Gewinnspannen $v_j - u_i$ im Einzelfall nicht über den Transportkosten c_{ij} liegen.

4 Simplex – Verfahren

4.1 Matrix – Umformungen

In den beiden letzten Kapiteln wurde mehrfach ausgenutzt, dass Ecken bzw. optimale Punkte durch quadratische Gleichungssysteme bestimmt sind (straffe Restriktionen). Ein zentraler Bestandteil von Optimierungsverfahren ist daher die Lösung von Gleichungssystemen. Allerdings treten in aufeinanderfolgenden Schritten nur wenig geänderte Systeme auf. Für diese werden oft Aktualisierungs-Formeln ('matrix update') benutzt. Bei Änderung einer Matrix durch eine andere, welche Rang 1 besitzt, kann die Inverse explizit angegeben werden.

Satz 4.1.1 Die Matrix $B \in \mathbb{R}^{m \times m}$ sei regulär, mit Vektoren $u, v \in \mathbb{R}^m$ sei $\beta := 1 + v^\top B^{-1}u \neq 0$. Dann ist auch die Matrix $B + uv^\top$ regulär und ihre Inverse ist

$$(B + uv^\top)^{-1} = B^{-1} - \frac{1}{1 + v^\top B^{-1}u} B^{-1}uv^\top B^{-1}. \quad (4.1.1)$$

Wenn dabei nur in B die Spalte Nummer $s \in \{1, \dots, m\}$ durch einen anderen Vektor a ersetzt wird, d.h., $v = e_s$ und $u = a - b_s$ gilt, ist $\beta = e_s^\top B^{-1}a$ und die Zeilen der Inversen ergeben sich aus

$$e_i^\top (B + ue_s^\top)^{-1} = \begin{cases} \frac{1}{\beta} e_s^\top B^{-1}, & i = s, \\ e_i^\top B^{-1} - \frac{1}{\beta} e_i^\top B^{-1}a e_s^\top B^{-1}, & i \neq s. \end{cases} \quad (4.1.2)$$

Bew

Einfacher ist die Formel (4.1.1) für den Fall $B = I$ mit $(I + uw^\top)^{-1} = I - \frac{1}{\beta}uw^\top$, $\beta = 1 + w^\top u$. Aber auch hieraus folgt schon die allgemeine Version, denn mit $w^\top := v^\top B^{-1}$ ist

$$(B + uv^\top)^{-1} = \left((I + uw^\top)B \right)^{-1} = B^{-1} \left(I - \frac{1}{\beta}uw^\top \right) = B^{-1} - \frac{1}{\beta}B^{-1}uv^\top B^{-1}.$$

Die Formel (4.1.2) wird in der klassischen Tabellenform des Simplexverfahrens (Handrechnung) benutzt, da der Rechenaufwand bei $O(m^2)$ arithmetischen Operationen (FLOP: *F*L*O*ating *p*oint *O*Peration) liegt. Er aber den Nachteil, dass sich bei größeren Problemen und insbesondere für kleine Werte β *Rundungsfehler* ansammeln (vgl. Übungen).

Für große (Computer-) Anwendungen greift man zur Lösung auf den *Gauß-Algorithmus* oder verwandte Methoden zurück. Auch dieser läßt sich so anpassen, dass geringfügige Änderungen der Matrix mit geringem Aufwand berücksichtigt werden können. Dazu ist es nützlich, die Zeilenumformungen im Gauß-Algorithmus als Matrixmultiplikation zu interpretieren. Mit $z \in \mathbb{R}^m$ und $A = (a_{ij}) \in \mathbb{R}^{m \times n}$ betrachtet man

$$L_j(z) := \begin{pmatrix} 1 & & & & & \\ & \ddots & & & & \\ & & 1 & & & \\ & & -z_{j+1} & 1 & & \\ & & \vdots & & \ddots & \\ & & -z_m & & & 1 \end{pmatrix}, \quad L_j(z)A = \begin{pmatrix} a_{11} & \dots & a_{1n} \\ \vdots & & \vdots \\ a_{j1} & \dots & a_{jn} \\ a_{j+1,1} - z_{j+1}a_{j1} & \dots & a_{j+1,n} - z_{j+1}a_{jn} \\ \vdots & & \vdots \\ a_{m1} - z_m a_{j1} & \dots & a_{mn} - z_m a_{jn} \end{pmatrix}.$$

Die Matrix L_j beschreibt also den Effekt einer vollständigen Elimination in Spalte j und läßt sich auch kompakt in der Form $L_j = I - ze_j^\top$ schreiben. Ihre Inverse ist nach (4.1.1) gegeben durch $L_j^{-1} = I + ze_j$. Beim Gauß-Algorithmus werden der Reihe nach Umformungen $A \rightarrow L_1 A \rightarrow L_2 L_1 A$ etc. angewandt, um die Matrix auf *obere Dreiecksgestalt* (Stufenform) zu bringen. Da Produkte von unteren Dreiecksmatrizen wieder solche Dreiecksmatrizen sind, kann das Ergebnis des Gauß-Algorithmus folgendermaßen zusammengefaßt werden.

Satz 4.1.2 *Der einfache Gauß-Algorithmus, der die Matrix $A = A_1 \in \mathbb{R}^{m \times n}$, $m \leq n$, mit Zeilenumformungen $A_{j+1} = (a_{ik}^{(j+1)}) := L_j(z^{(j)})A_j$, $j = 1, \dots, m-1$, und*

$$z^{(j)} = \frac{1}{a_{jj}^{(j)}} \left(0, \dots, 0, a_{j+1,j}^{(j)}, \dots, a_{mj}^{(j)} \right)^\top,$$

in obere Dreiecksgestalt $R := A_m$ überführt, erzeugt eine LR-Zerlegung der Matrix als Produkt einer unteren Dreiecksmatrix $L = L_1^{-1} \dots L_{m-1}^{-1}$ und einer oberen $R = A_m$:

$$A = LR, \quad L = \begin{pmatrix} 1 & & & & \\ z_2^{(1)} & 1 & & & \\ \vdots & & \ddots & & \\ z_m^{(1)} & \dots & z_m^{(m-1)} & 1 & \end{pmatrix}, \quad R = \begin{pmatrix} r_{11} & r_{12} & \dots & \dots & \cdot & r_{1n} \\ & r_{22} & \dots & \dots & \cdot & r_{2n} \\ & & \ddots & & & \vdots \\ & & & r_{mm} & \cdot & r_{mn} \end{pmatrix}.$$

Die Berechnung der LR-Zerlegung hat einen Aufwand von i.w. $(n - \frac{1}{3}m)m^2$ arithmetischen Operationen, also $\frac{2}{3}m^3$ FLOP für $m = n$.

Im Satz wurde implizit vorausgesetzt, dass die *Pivot-Elemente* $a_{jj}^{(j)} = r_{jj}$, durch welche dividiert wird, von Null verschieden sind. Bei einer Rechnung mit Maschinenzahlen endlicher Genauigkeit muß aber nicht nur der Fall $a_{jj}^{(j)} = 0$ durch Zeilenumformungen vermieden werden, sondern auch die Verwendung kleiner Pivot-Werte $a_{jj}^{(j)} \cong 0$. Sonst zeigen sich die gleichen Probleme wie bei Verwendung der Rang-1-Formel (4.1.2).

Nach der Berechnung einer LR-Zerlegung kostet die Auflösung eines quadratischen linearen Gleichungssystem $Bx = c$ nur noch den Aufwand der Lösung von zwei gestaffelten (Dreieck-) Systemen:

$$x = B^{-1}c = R^{-1}L^{-1}c \iff Ly = c, \quad Rx = y.$$

Außerdem kann diese Auflösung ohne Zusatzvariable (am Platz) durchgeführt werden. Die folgenden Anweisungen überschreiben die rechte Seite $c = (c_i)$ zunächst mit der Zwischenlösung y , dann mit der Gesamtlösung x :

$$\text{löst } Ly = c, \quad c := y$$

für $i = 2$ bis m :

$$\text{für } j = 1 \text{ bis } i - 1: \quad c_i := c_i - l_{ij}c_j;$$

$$\text{löst } Rx = c, \quad c := x$$

für $i = m - 1$ abwärts bis 1:

$$\text{für } j = i + 1 \text{ bis } m: \quad c_i := c_i - r_{ij}c_j;$$

$$c_i := c_i / r_{ii};$$

Der Rechenaufwand beträgt pro Teilsystem i.w. m^2 Operationen. Damit ist der Gesamtaufwand

zur Lösung von $Bx = LRx = c$ mit $2m^2$ Operationen *nicht höher* als die reine Multiplikation $B^{-1}c$!

Zeilenvertauschungen bei einer $m \times n$ -Matrix A können mit Hilfe einer Permutationsmatrix $P \in \mathbb{B}^{m \times m}$ dargestellt werden. So wird etwa mit einer Permutation π die entsprechende Umordnung in $A = (a_{ij})$ folgendermaßen bewirkt (δ : Kronecker-Symbol):

$$A' = (a'_{kj}) = (a_{\pi(i),j}) \iff A' = PA, \quad P = \left(\delta_{\pi(i),j} \right)_{i,j=1}^m.$$

Permutationsmatrizen entstehen durch Vertauschungen bei der Einheitsmatrix und sind unitär, $P^{-1} = P^T$ bewirkt die inverse Permutation. In der praktischen Realisierung bestimmt man vor Elimination der j -ten Spalte das betragsmaximale Element unterhalb von a_{jj} und tauscht dessen Zeile mit der j -ten. Dann sind alle Elemente von L betragsmäßig durch eins beschränkt. Die Permutationen protokolliert man dabei in einem Indexfeld $P[1..m]$, in dem alle Zeilenvertauschungen der Matrix A synchron durchgeführt werden. Der obige Satz 4.1.2 kann damit in folgender Weise verallgemeinert werden:

Für jede reguläre Matrix $A \in \mathbb{R}^{m \times m}$ gibt es eine Permutationsmatrix P so, dass die LR-Zerlegung $PA = LR$ existiert.

Beispiel 4.1.3 Die folgende Matrix A besitzt offensichtlich keine LR-Zerlegung, da schon das erste Pivotelement verschwindet,

$$A = \begin{pmatrix} 0 & 1 & 2 \\ 1 & 0 & 1 \\ 2 & 1 & 1 \end{pmatrix}. \quad \text{Mit } P = \begin{pmatrix} 0 & 0 & 1 \\ 0 & 1 & 0 \\ 1 & 0 & 0 \end{pmatrix}$$

gilt aber

$$PA = \begin{pmatrix} 2 & 1 & 1 \\ 1 & 0 & 1 \\ 0 & 1 & 2 \end{pmatrix} = \begin{pmatrix} 1 & 0 & 0 \\ \frac{1}{2} & 1 & 0 \\ 0 & -2 & 1 \end{pmatrix} \begin{pmatrix} 2 & 1 & 1 \\ 0 & -\frac{1}{2} & \frac{1}{2} \\ 0 & 0 & 3 \end{pmatrix} = LR.$$

Bei Elimination der 2. Spalte wurde keine weitere Vertauschung durchgeführt. Da hier $a_{22}^{(2)} = -\frac{1}{2}$ und $a_{32}^{(2)} = 1$ gilt, wäre nach der Strategie des Spaltenmaximums eine Vertauschung der 2. und 3. Zeile günstig. Dann sind tatsächlich alle Beträge im L -Faktor nicht größer als eins.

Anpassung der LR-Zerlegung Der Aufwand bei einem Gauß-Eliminationsschritt, also der 'Multiplikation' mit einer Matrix $L_j(z^{(j)})$ ist proportional zur Zahl der nichttrivialen Elemente von $z^{(j)}$, also der Anzahl solcher Elemente in der j -ten Spalte von B_j . Tauscht man in der (quadratischen) Matrix B mit $B = LR$ wieder die Spalte s aus, $C := B + ue_s^T$, $u = a - b_s$, tritt in $L^{-1}C$ dort eine volle Spalte auf, deren Elimination (etwa bei $s = 1$) fast den vollen Aufwand einer Neuzerlegung verursacht. Denn bei Elimination in Spalte s füllt sich der vorher freie Bereich hinter dieser Spalte i.a. vollständig auf! Dies läßt sich dadurch vermeiden, dass

man die neue Spalte a am Ende einfügt, und die Spalten $s + 1$ bis m nach vorne schiebt:

$$B = \left(\begin{array}{c|c|c} & & \\ & b_{1s} & \\ & \vdots & \\ & b_{ms} & \end{array} \right) \mapsto C' = \left(\begin{array}{c|c|c} & & a_1 \\ & & \vdots \\ & & a_m \end{array} \right)$$

Der R -Faktor ändert sich dann folgendermaßen mit dem Vektor $c := L^{-1}a$ am Ende:

$$R = L^{-1}B = \left(\begin{array}{c|c|c} & & \\ & \begin{array}{c} s \\ \hline \end{array} & \\ & & \\ & & \\ & & \\ & & \end{array} \right) \mapsto L^{-1}C' = \left(\begin{array}{c|c|c} & & c_1 \\ & & \vdots \\ & & c_m \end{array} \right).$$

Jetzt tritt ab Spalte s nur je ein Element unter der Diagonale auf, welches mit Zeilenoperationen, die nur je eine Zeile betreffen (Aufwand $O(m)$ pro Elimination!) eliminiert werden kann, evtl. nach Zeilenvertauschung. Bei der Durchführung werden die Umformungen gleichzeitig auf L und $R' = L^{-1}C'$ angewandt, um nachher wieder eine gültige LR-Zerlegung von C' zu bekommen. Bei der Elimination von $r'_{s+1,s}$ mit $L_s(z)$ etwa, durch

$$C' = LR' = (LL_s^{-1})(L_sR') = \left(L(I + ze_s^T) \right) \left((I - ze_s^T)R' \right),$$

wird beim R -Faktor nur die Zeile $s + 1$ geändert, beim L -Faktor nur die Spalte $s + 1$. Daher ist der Gesamtaufwand für diese Anpassung der LR-Zerlegung in der Größenordnung $O(m^2)$.

Block-Elimination Den ersten Schritt im Gauß-Algorithmus kann man so interpretieren, dass man die Variable x_1 mit Hilfe der ersten Gleichung aus den restlichen eliminiert. Dieses Verfahren läßt sich auch auf einen Block von Variablen übertragen. Es sei jetzt $m_1 + m_2 = m$ und Matrizen $A_{ij} \in \mathbb{R}^{m_i, m_j}$, $i, j = 1, 2$ gegeben. Ein Block $x_1 \in \mathbb{R}^{m_1}$ von Variablen kann dann aus dem System $A_{11}x_1 + A_{12}x_2 = b_1$ eliminiert werden, wenn $\det(A_{11}) \neq 0$ gilt: $x_1 = A_{11}^{-1}(b_1 - A_{12}x_2)$. Unter dieser Voraussetzung existiert auch die Block-LR-Zerlegung der folgenden Matrix:

$$A = \begin{pmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{pmatrix} = \begin{pmatrix} I & 0 \\ A_{21}A_{11}^{-1} & I \end{pmatrix} \begin{pmatrix} A_{11} & A_{12} \\ 0 & A_{22} - A_{21}A_{11}^{-1}A_{12} \end{pmatrix} \quad (4.1.3)$$

Da die Determinante des linken Faktors eins ist, folgt

$$\det(A) = \det(A_{11}) \det(A_{22} - A_{21}A_{11}^{-1}A_{12}).$$

Die Regularität des sogenannten *Schur-Komplements* $A_{22} - A_{21}A_{11}^{-1}A_{12}$ und die von A_{11} sind also hinreichend für die Regularität der Gesamtmatrix.

4.2 Ecken und Nachbarn

Bei den numerischen Verfahren geht man vom Programm (LP3) aus

$$\max\{c^\top x : x \in X\}, \quad X := \{x \in \mathbb{R}^n : Ax = b, x \geq 0\},$$

und betrachtet ohne Einschränkung den Fall $A \in \mathbb{R}^{m \times n}$, $\text{Rang}(A) = m < n$. Denn für $\text{Rang}(A) < m$ wäre der affine Unterraum $U = \{x : Ax = b\}$ entweder leer, oder Gleichungen könnten entfernt werden. Das Simplexverfahren besucht nur die Ecken des Polyeders X , da ein Optimum auch in einer Ecke angenommen wird. Für kompaktes X folgt das aus Satz 2.3.4. Denn mit einer Maximalstelle $\hat{x} \in X$ wo $c^\top \hat{x} = \hat{W}$ gilt, ist die Hyperebene $H(c, W)$, auf der die Zielfunktion konstanten Wert hat, eine Stützhyperebene für X . Dann enthält die Randfläche $X \cap H(c, W)$ auch eine Ecke, die also ebenfalls Maximalstelle ist.

Der zulässige Bereich $X = \{x : Ax = b, x \geq 0\}$ ist der Schnitt von U mit dem Positivkegel \mathbb{R}_+^n . Ecken x von X liegen auf dem Rand des Positivkegels, wo also ein Teil der Komponenten von x null ist. In diesem Zusammenhang sind folgende Bezeichnungen nützlich. Zu $x \in \mathbb{R}^n$ sei

$$J^+(x) := \{i : x_i > 0\}, \quad J^-(x) := \{i : x_i < 0\}, \quad J(x) := J^-(x) \cup J^+(x)$$

die Menge der (positiven, negativen bzw. gesamten) *Stützindizes* von x . Für $x \geq 0$ ist $J(x) = J^+(x)$. Zu $J = \{j_1, \dots, j_\ell\} \subseteq \{1, \dots, n\}$, $|J| = \ell$, wird folgende Untermatrix aus *Spalten* $a_j = Ae_j$ von A eingeführt

$$A_J = (a_{j_1}, \dots, a_{j_\ell}) \in \mathbb{R}^{m \times \ell}.$$

Die verschwindenden Komponenten von x (und die betroffenen Matrixspalten) können aus dem Gleichungssystem $Ax = b$ entfernt werden. Denn mit $J = J(x)$ und $K = \{1, \dots, n\} \setminus J$ gilt (etwa nach geeigneter Umordnung) mit $A = (A_J, A_K)$, $x^\top = (x_J^\top, x_K^\top)$:

$$b = Ax = (A_J, A_K) \begin{pmatrix} x_J \\ x_K \end{pmatrix} = A_J x_J + A_K x_K \iff A_J x_J = b, \quad x_K = 0. \quad (4.2.1)$$

Daher ist die Charakterisierung von *Ecken* dual zu der beim Programm (LP1), vgl. Satz 2.4.3 und (3.1.1). Im Unterschied zu (LP1) besitzt ein konsistentes Problem (LP3) immer eine Ecke. Eine triviale, aber wichtige Schlußweise wird im folgenden häufig benutzt:

$$x, y, z \in \mathbb{R}_+^n, \quad x = \frac{1}{2}(y + z) \Rightarrow J(y), J(z) \subseteq J(x).$$

Satz 4.2.1 a) Ein Element $\bar{x} \in X = \{x : Ax = b, x \geq 0\}$ ist genau dann Ecke von X , wenn $\{a_i : i \in J(\bar{x})\}$ linear unabhängig ist, also $\text{rang}(A_{J(\bar{x})}) = |J(\bar{x})|$ gilt.

b) Wenn (LP3) eine Lösung besitzt, ist auch eine Ecke von X Lösung. Bew

Wenn A_J , $|J| = \ell$, maximalen Rang $\ell \leq m$ besitzt, läßt sich das System (4.2.1) in einer Ecke so erweitern, dass \bar{x} sogar die eindeutige Lösung wird:

$$\begin{pmatrix} A_J & A_K \\ 0 & I_{n-\ell} \end{pmatrix} \begin{pmatrix} \bar{x}_J \\ \bar{x}_K \end{pmatrix} = \begin{pmatrix} b \\ 0 \end{pmatrix}. \quad (4.2.2)$$

Der Rang der Gesamtmatrix mit Dimension $(m + n - \ell) \times n$ ist $\text{rang}(A_J) + n - \ell$, das System also eindeutig lösbar für $\text{Rang}(A_J) = \ell$.

Definition 4.2.2 *Ein $\bar{x} \in X$ heißt Basislösung, wenn $\text{Rang}(A_{J(\bar{x})}) = |J(\bar{x})| (\leq m)$ ist. Für $\text{rang}(A_{J(\bar{x})}) = |J(\bar{x})| < m$ nennt man \bar{x} ausgeartete Basislösung. Umgekehrt heißt jede reguläre $m \times m$ -Untermatrix $B = A_J$ mit $|J| = m$ Basis, wenn sie regulär ist, $\det(B) \neq 0$.*

Bei jeder ausgearteten Basislösung (Ecke) \bar{x} kann $A_{J(\bar{x})}$ mit geeigneten Spalten von A_K zu einer Basis $B = A_J$, $J \supseteq J(x)$, ergänzt werden. Daher gehören zu einer ausgearteten Ecke verschiedene Basen. Dies kann im Simplexverfahren zu Problemen führen, dieses Verfahren nicht durch die Orte \bar{x} sondern die zugehörigen Basen B gesteuert wird (\rightarrow läuft im Kreis). Zu jeder Basis $B = A_J$ gehört nach (4.2.1) eine Lösung $\bar{x}_J = A_J^{-1}b$, $\bar{x}_K = 0$, die aber nur für $A_J^{-1}b \geq 0$ auch zulässig, also 'Basislösung' ist.

Basisdarstellung von X : Zu jeder Ecke \bar{x} von X gibt es eine Basis $B = A_J$ mit $A_J \bar{x}_J = b$, $\bar{x}_K = 0$, $J \cup K = \{1, \dots, n\}$. Aber nicht nur dieser spezielle Punkt, sondern jeder Punkt $x \in X$ kann mit Hilfe dieser Basis dargestellt werden. Analog zu (4.2.1) wird von der Aufteilung der Gesamtmatrix $A = (A_J, A_K)$ ausgegangen. Da A_J^{-1} existiert, gilt also

$$Ax = A_J x_J + A_K x_K = b \iff x_J = A_J^{-1}b - A_J^{-1}A_K x_K = \bar{x}_J - A_J^{-1}A_K x_K. \quad (4.2.3)$$

Dies ist die aus der Linearen Algebra bekannte Parameterdarstellung des Lösungsraums U mit den Variablen $x_K \geq 0$ als 'freien' und den x_J als 'abhängigen' Variablen und der speziellen Lösung \bar{x} . Nach Einführung von $n - m = |K|$ echten Parametern $\lambda_K \geq 0$ heißt das also

$$Ax = b, x \geq 0 \iff x = \begin{pmatrix} x_J \\ x_K \end{pmatrix} = \begin{pmatrix} \bar{x}_J \\ 0_K \end{pmatrix} + \begin{pmatrix} -A_J^{-1}A_K \\ I_{n-m} \end{pmatrix} \lambda_K = \bar{x} + V_K \lambda_K \geq 0. \quad (4.2.4)$$

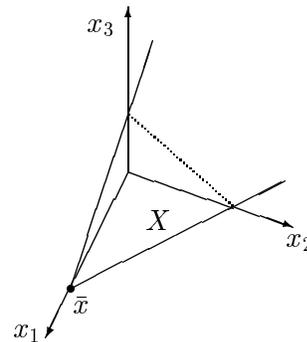
Im letzten Schritt wurde die Abkürzung

$$\begin{pmatrix} -A_J^{-1}A_K \\ I_{n-m} \end{pmatrix} =: \begin{pmatrix} V_K^{(J)} \\ V_K^{(K)} \end{pmatrix} = V_K = (v_{i,k_j}) \in \mathbb{R}^{n \times (n-m)}, \text{ mit } k_j \in K$$

benutzt. Die Spalten von V sind trivialerweise linear unabhängig und bilden eine Basis von $\text{kern}(A)$. In einer Umgebung der Ecke \bar{x} sieht das Polyeder X also aus wie ein verschobener Kegel, denn nach (4.2.4) liegt $x - \bar{x}$ im Kegel

$$x - \bar{x} \in V_K \cdot \mathbb{R}_+^{n-m} \quad \text{und } x \in \mathbb{R}_+^n.$$

Im Bild befindet sich, von \bar{x} aus gesehen, der Bereich X in dem durch die beiden Kanten gegebenen Kegel, der allerdings an der gepunkteten Linie den Positivkegel \mathbb{R}_+^3 verläßt.



Die Richtungen der von \bar{x} ausgehenden Kanten werden durch Spalten von V beschrieben. Dazu wird zu festem $\ell \in K$ der Strahl

$$x(t) := \bar{x} + tv_\ell \iff \begin{cases} x_J(t) = \bar{x}_J - tA_J^{-1}a_\ell \\ x_k(t) = t\delta_{k\ell}, \quad k \in K, \end{cases} \quad (4.2.5)$$

betrachtet. Da diese Vektoren die Gestalt (4.2.4) haben, ist $Ax(t) \equiv b$ automatisch erfüllt. Zu prüfen bleibt nur das Vorzeichen $x(t) \geq 0$ für kleine Werte $t > 0$. Der mögliche Fall ausgearteter Ecken ($J(\bar{x}) \neq J$) kompliziert die Voraussetzungen des folgenden Satzes.

Satz 4.2.3 *Es sei A_J Basis mit Basislösung \bar{x} . Für $\ell \in K$ und den Spaltenvektor v_ℓ der Matrix V_K aus (4.2.4) gelte*

$$J^-(v_\ell) \subseteq J(\bar{x}), \quad \text{d.h. } v_{i\ell} < 0 \Rightarrow x_i > 0 \quad \forall i \in J.$$

Dann ist $\{\bar{x} + tv_\ell : t \geq 0\} \cap X$ Kante von X .

Bew

Durch Einsetzen der Basisdarstellung (4.2.3) in die Zielfunktion und Berücksichtigung von Satz 4.2.3 können wichtige Aussagen zur Bedeutung einer Ecke getroffen werden. Mit einer Ecke \bar{x} und zugehöriger Basis A_J gilt für beliebige $x \in X$

$$\begin{aligned} c^\top x &= c_J^\top x_J + c_K^\top x_K \stackrel{(4.2.3)}{=} c_J^\top (\bar{x}_J - A_J^{-1}A_K x_K) + c_K^\top x_K \\ &= c_J^\top \bar{x}_J + \left(c_K^\top - c_J^\top A_J^{-1}A_K \right) x_K = c^\top \bar{x} + \gamma_K^\top x_K. \end{aligned}$$

Da $c^\top \bar{x}$ der Zielwert in der aktuellen Ecke ist, beschreibt der n -Vektor

$$\gamma^\top := c^\top - c_J^\top A_J^{-1}A \quad \text{mit} \quad \gamma_K^\top = c_K^\top - c_J^\top A_J^{-1}A_K = c^\top V_K \quad (4.2.6)$$

der sogenannten *reduzierten Gewinne*, wie sich die Zielfunktion bei Vergrößerung der Nichtbasis-Variablen x_K ändert. Es gilt $\gamma_J = 0$.

Satz 4.2.4 (Optimalität) *Gegeben sei eine Basis A_J mit Basislösung \bar{x} . Wenn alle reduzierten Gewinne nicht-positiv sind, $\gamma \leq 0$, dann ist \bar{x} (Maximal-) Lösung von (LP3).*

Bew

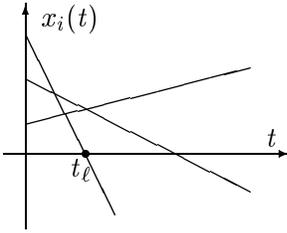
Bezogen auf die Ecke \bar{x} ist das Kriterium nur hinreichend, da zu einer ausgearteten Ecke verschiedene Basen existieren können, die nicht alle das Optimalitätskriterium erfüllen.

Wenn also positive Gewinne $\gamma_\ell > 0$ existieren, kann die Zielfunktion evtl. noch vergrößert werden, indem man auf einem Strahl (4.2.5) entlangläuft. Wenn dieser Strahl ganz in X liegt, d.h., $v_\ell \in O^+(X)$ gilt, existiert keine Lösung für (LP3).

Satz 4.2.5 (Unbeschränktheit) *Gegeben sei eine Basis A_J mit Basislösung \bar{x} . Wenn für ein $\ell \in K$ gilt $\gamma_\ell > 0$ und $v_\ell \geq 0$, ist (LP3) unbeschränkt.*

Bew

Wenn umgekehrt $v_\ell \not\geq 0$ gilt, kann man dem Strahl (4.2.5) nur ein endliches Stück weit folgen, ohne den zulässigen Bereich X zu verlassen. Der Grenzpunkt (vor dem Verlassen von X) ist wieder eine Ecke. Unter den Voraussetzungen von Satz 4.2.3 ist dieses eine *Nachbarecke*, welche mit der aktuellen durch eine Kante positiver Länge verbunden ist. Die Zulässigkeit von (4.2.5)



erfordert mit $t \geq 0$:

$$x_i(t) = \bar{x}_i + tv_{i\ell} \geq 0 \quad \forall i \in J.$$

Der hier bei t maximal zulässige Wert ergibt sich daher zu

$$t_\ell := \min\left\{\frac{\bar{x}_i}{-v_{i\ell}} : i \in J, v_{i\ell} < 0\right\} = \frac{\bar{x}_p}{-v_{p\ell}} \geq 0. \quad (4.2.7)$$

Dieser Wert wurde gerade so bestimmt, dass eine Komponente $x_p(t_\ell) = 0$ wird mit dem Index $p \in J$, in dem das Minimum angenommen wird. Für eine nicht ausgeartete Ecke ist $\bar{x}_p > 0$ und daher $t_\ell > 0$, im neuen Punkt ist nun die Komponente $x_\ell(t_\ell) > 0$, es gilt also $J(x(t_\ell)) = J \setminus \{p\} \cup \{\ell\}$. Dieser Punkt gehört somit zu einer neuen Basis.

Satz 4.2.6 (Basiswechsel) Gegeben sei eine Basis $B = A_J$ mit Basislösung \bar{x} . Für $\ell \notin J$ sei

$$\gamma_\ell = c^\top v_\ell > 0 \quad \text{und} \quad v_\ell \not\geq 0.$$

Es sei $p \in J$ ein Index, in dem das Minimum in (4.2.7) angenommen wird, und $J' := J \setminus \{p\} \cup \{\ell\}$. Dann ist $B' = A_{J'}$ neue Basis mit Basislösung $x' = x(t_\ell)$, d.h. $x'_{J'} = (B')^{-1}b \geq 0$, und neuem Zielfunktionswert $c^\top x' \geq c^\top \bar{x}$. Die echte Ungleichung ' $>$ ' gilt hier, wenn $t_\ell > 0$ ist in (4.2.7).

Beweis Es sei s die Position von a_p in B , $a_p = B e_s$. Die neue Spalte a_ℓ werde bei B' an dieser Stelle eingefügt, es gilt also $B' = B + (a_\ell - a_p)e_s^\top$ und $B' e_s = a_\ell$. Für die Anwendung der Rang-1-Formel (4.1.2) ist erforderlich

$$0 \neq \beta = e_s^\top B^{-1} a_\ell = e_p^\top A_J^{-1} a_\ell = -v_{p\ell} > 0.$$

Denn die Zeile p von A_J^{-1} steht bei B^{-1} in Zeile s , und $v_{p\ell} < 0$ ist das Element, das den Wert t_ℓ bestimmt. Also ist B' regulär. Die zu B' gehörige Basislösung x' kann ebenfalls mit (4.1.2) bestimmt werden, es gilt mit $A_J^{-1} a_\ell = -v_\ell$ und der Definition von t_ℓ :

$$\begin{aligned} x'_\ell &= e_s^\top (B')^{-1} b = \frac{1}{\beta} e_s^\top B^{-1} b = \frac{1}{\beta} \bar{x}_p = t_\ell, \\ x'_i &= e_i^\top A_J^{-1} b - \frac{1}{\beta} v_{i\ell} \bar{x}_p = \bar{x}_i + t_\ell v_{i\ell}, \quad i \in J. \end{aligned}$$

Insbesondere gilt $x'_p = 0$. Die Zielfunktion im neuen Punkt x' ergibt sich demnach zu

$$c^\top x' = c^\top \bar{x} + t_\ell (c_\ell + \sum_{i \in J} c_i v_{i\ell}) = c^\top \bar{x} + t_\ell \underbrace{c^\top v_\ell}_{\gamma_\ell > 0} \geq c^\top \bar{x}.$$

Für $t_\ell > 0$ (d.h. $\bar{x}_p > 0$) tritt hier ein positiver Zuwachs $t_\ell \gamma_\ell > 0$ auf. ■

4.3 Das revidierte Simplex-Verfahren

In der Ecke \bar{x} mit Basis A_J charakterisiert der Vektor γ der reduzierten Gewinne alle diejenigen Richtungen, in der die Zielfunktion wächst, für die nämlich $\gamma_K^\top x_K > 0$ und $x_K \geq 0$ gilt. Eine, aus Kostengründen, wichtige Einschränkung im Simplexverfahren ist aber, dass man in jedem Schritt nur eine einzige Komponente von $\bar{x}_K = 0$ vergrößert mit nicht fallender Zielfunktion. Daher besteht der Ablauf (ausgehend von einer Startecke) grob aus folgenden Schritten:

1. Berechne \bar{x}_J und γ_K zu $K = \{1, \dots, n\} \setminus J$,
2. suche $\gamma_\ell > 0$, $\ell \in K$,
3. wenn aber $\gamma_K \leq 0$, nach S. 4.2.4 _____: **OPTIMUM!**,
4. wenn $v_\ell \geq 0$, nach S. 4.2.5 _____: **UNBESCHRÄNKT!**
5. bestimme Minimalindex p , $v_{p\ell} < 0$, in (4.2.7),
6. Basiswechsel zu $J := J \setminus \{p\} \cup \{\ell\}$.

Aus Effizienzgründen ist darauf zu achten, dass die zur Durchführung erforderlichen Berechnungen nicht zu teuer sind. Benötigt werden dabei die Größen

$$\gamma_K = c_K^\top - (c_J^\top A_J^{-1}) A_K, \quad I^{(J)} v_\ell = -A_J^{-1} a_\ell, \quad \bar{x}_J = A_J^{-1} b.$$

Wenn die Berechnung von γ_K in der angegebenen Weise geklammert wird, mit $g^\top := c_J^\top A_J^{-1}$, kostet die Bestimmung der drei Lösungen

$$g^\top A_J = c_J^\top, \quad A_J v_\ell^{(J)} = -a_\ell, \quad A_J \bar{x}_J = b,$$

bei vorhandener LR-Zerlegung $A_J = LR$ nur einen Aufwand von höchstens $6m^2$ Operationen. Außerdem kann diese LR-Zerlegung mit der Technik aus §4.1 mit einem $O(m^2)$ -Aufwand zu einer Zerlegung von $A_{J'}$, $J' = J \setminus \{p\} \cup \{\ell\}$, korrigiert werden. Bei großen praktischen Problemen hat die Matrix A meist nur wenige nichttriviale Einträge. Bei solchen 'dünn besetzten' Matrizen können die genannten Auflösungen bzw. Anpassungen oft mit geringerem Aufwand durchgeführt werden. Die Dimension $n > m$ geht nur bei $\gamma_K = c_K^\top - g^\top A_K$ in Schritt 2 ein, der Aufwand wäre hier $2m(n - m)$ Operationen, wenn alle Komponenten bestimmt würden. Man muss aber nur einen Teil der γ_j berechnen, wenn man das *erste* $\gamma_\ell > 0$ akzeptiert.

Simplex-Algorithmus

Eingabe:	Zulässige Basis A_J , $J \subseteq \{1, \dots, n\}$
Schritt 1	$x_J := A_J^{-1} b$, $g^\top := c_J^\top A_J^{-1}$, $K := \{1, \dots, n\} \setminus J$,
2	suche $\gamma_\ell > 0$ unter $\gamma_j := c_j - g^\top a_j$, $j \in K$.
3	wenn $\gamma_j \leq 0 \forall j \in K$: _____ STOP , Optimum!
4	$v_\ell^{(J)} := -A_J^{-1} a_\ell$, wenn $v_{i\ell} \geq 0 \forall i \in J$: _____ STOP , unbeschränkt!
5	Bestimme $p \in J$: $-x_p/v_{p\ell} = \min\{-x_i/v_{i\ell} : v_{i\ell} < 0, i \in J\} = t_\ell$
6	$J := J \setminus \{p\} \cup \{\ell\}$, weiter mit 1

Beispiel 4.3.1 Simplexverfahren mit $m = 3$, $n = 6$ bei (LP3) mit $c^T = (9, 6, 7, 0, 0, 0)$,

$$A = \begin{pmatrix} 3 & 1 & 2 & 1 & 0 & 0 \\ 1 & 1 & 1 & 0 & 1 & 0 \\ 4 & 3 & 4 & 0 & 0 & 1 \end{pmatrix}, \quad b = \begin{pmatrix} 20 \\ 11 \\ 40 \end{pmatrix}.$$

Das Problem ist aus einem (LP2) durch Einführung von Schlupfvariablen entstanden. Hier bekommt man mit $J = \{4, 5, 6\}$ eine Startbasis $A_J = I_3$ mit Basislösung $\bar{x}_J = b$. Simplex-Basen:

B-1 1. $J = \{4, 5, 6\}$, $A_J = I$, $\bar{x}_J = \begin{pmatrix} 20 \\ 11 \\ 40 \end{pmatrix}$, $g^T = 0^T$, $\gamma_K^T = (\gamma_1, \gamma_2, \gamma_3) = (9, \underline{6}, 7)$.

2+4. wähle $\ell = 2$: $v_2^{(J)} = \begin{pmatrix} v_{42} \\ v_{52} \\ v_{62} \end{pmatrix} = -Ia_2 = \begin{pmatrix} -1 \\ -1 \\ -3 \end{pmatrix}$,

5. (4.2.7): $\left. \begin{array}{l} x_4(t) = 20 - t \geq 0 \\ x_5(t) = \underline{11 - t} \geq 0 \\ x_6(t) = 40 - 3t \geq 0 \end{array} \right\} \Rightarrow t_2 = 11, p = 5.$

B-2 1. $J = \{2, 4, 6\}$, $A_J = \begin{pmatrix} 1 & 1 & 0 \\ 1 & 0 & 0 \\ 3 & 0 & 1 \end{pmatrix}$, $A_J^{-1} = \begin{pmatrix} 0 & 1 & 0 \\ 1 & -1 & 0 \\ 0 & -3 & 1 \end{pmatrix}$, $\bar{x}_J = \begin{pmatrix} 11 \\ 9 \\ 7 \end{pmatrix}$,

$g^T = (c_2, c_4, c_6)A_J^{-1} = (0, 6, 0)$, $\gamma_K^T = (c_1, c_3, c_5) - (0, 6, 0) \begin{pmatrix} 3 & 2 & 0 \\ 1 & 1 & 1 \\ 4 & 4 & 0 \end{pmatrix} = (\underline{3}, 1, -6)$.

2+4. wähle $\ell = 1$: $v_1^{(J)} = \begin{pmatrix} v_{21} \\ v_{41} \\ v_{61} \end{pmatrix} = -A_J^{-1}a_1 = \begin{pmatrix} -1 \\ -2 \\ -1 \end{pmatrix}$,

5. (4.2.7): $\left. \begin{array}{l} x_2(t) = 11 - t \geq 0 \\ x_4(t) = \underline{9 - 2t} \geq 0 \\ x_6(t) = 7 - t \geq 0 \end{array} \right\} \Rightarrow t_1 = \frac{9}{2}, p = 4.$

B-3 1. $J = \{1, 2, 6\}$, $A_J = \begin{pmatrix} 3 & 1 & 0 \\ 1 & 1 & 0 \\ 4 & 3 & 1 \end{pmatrix}$, $A_J^{-1} = \frac{1}{2} \begin{pmatrix} 1 & -1 & 0 \\ -1 & 3 & 0 \\ -1 & -5 & 2 \end{pmatrix}$, $\bar{x}_J = \frac{1}{2} \begin{pmatrix} 9 \\ 13 \\ 5 \end{pmatrix}$,

$g^T = (c_1, c_2, c_6)A_J^{-1} = \frac{1}{2}(3, 9, 0)$, $\gamma_K^T = (c_3, c_4, c_5) - \frac{1}{2}(3, 9, 0) \begin{pmatrix} 2 & 1 & 0 \\ 1 & 0 & 1 \\ 4 & 0 & 0 \end{pmatrix} = (-\frac{1}{2}, -\frac{3}{2}, -\frac{9}{2})$.

3. $\gamma_K < 0$, $\bar{x}_J > 0$: eindeutiges Maximum!

Beim Simplex-Algorithmus gibt es noch zwei offene Fragen, die später behandelt werden:

- Bestimmung einer Start-Basis bzw. -Ecke (Anlaufrechnung, vgl. §4.5)
- Der Algorithmus ist endlich, wenn Basen *nicht* wiederholt auftreten.

Da nach Satz (4.2.1) nur endlich viele Ecken (Basen) existieren, ist nur beim 'Kreisen' des Simplex-Verfahrens, d.h., zyklischer Wiederholung von Basen, dessen Beendigung nicht garantiert. Dieses Problem tritt aber nur in ausgearteten Ecken auf, in normalen Ecken \bar{x} mit $|J(\bar{x})| = m$ gibt es beim Basiswechsel nach Satz 4.2.6 dagegen einen echten Zuwachs der Zielfunktion, was eine Rückkehr zu \bar{x} ausschließt. Ausgeartete Ecken \bar{x} treten selten auf (nicht-generischer Fall), wenn \bar{x} 'zufälligerweise' auf mehr als $n - m$ Hyperebenen $H(a^{(i)}, b_i)$ bzw. $\{x : x_j = 0\}$ liegt. Das Kreisen kann durch Zusatzmaßnahmen verhindert werden (s.u.).

Gesamtaufwand des Simplex-Verfahrens Der einzelne Simplex-Schritt, der im Algorithmus formuliert wurde, ist zwar effizient durchführbar mit einem Aufwand $O(m(m+n))$. Der Gesamtaufwand hängt aber von der Anzahl untersuchter Ecken ab und kann durch Änderungen bei den Auswahlentscheidungen in Schritt 2 und 5 im Einzelfall verbessert werden. Unglücklicherweise fallen aber generelle Aussagen zur Anzahl der zu untersuchenden Basen eher negativ aus.

Beispiel 4.3.2 (Klee-Minty) Zu $n \in \mathbb{N}$, $\epsilon \in (0, \frac{1}{2})$ betrachte man

$$\begin{aligned} & \max\{e_n^\top x : x \in X\}, \\ & X := \{x : 0 \leq x_1 \leq 1, \epsilon x_i \leq x_{i+1} \leq 1 - \epsilon x_i, i = 1, \dots, n-1\}. \end{aligned}$$

Es läßt sich zeigen, dass das Polyeder X genau 2^n Ecken besitzt, und einen Simplexpfad, der alle besucht. Dieses Problem kann auch nicht durch verbesserte Auswahlstrategien umgangen werden, auch dafür gibt es meist Gegenbeispiele mit exponentiellem Aufwand. In der Praxis arbeitet das Simplexverfahren aber sehr effizient, bei genügend allgemeiner Verteilung der Restriktionen ist beim Problem (LP1) im Mittel mit $O(n\sqrt{m} \cdot n^3)$ Schritten zu rechnen.

4.4 Tabellenform des Simplex-Verfahrens

Beim revidierten Simplexverfahren werden nur die für die Durchführung der einzelnen Schritte erforderlichen Größen berechnet. Der dafür erforderliche Verwaltungsaufwand (Indexmenge J) ist nur gering, für Handrechnung aber irritierend. In der Tabellenform des Simplexverfahrens wird immer das gesamte System umgeformt und notiert in der ursprünglichen Reihenfolge der Spalten, $H := A_J^{-1}A$. Dieses System $Hx \doteq A_J^{-1}Ax = A_J^{-1}b = \bar{x}_J$ wird ergänzt durch $W = c^\top \bar{x}$, $\gamma^\top = c^\top - c_J^\top A_J^{-1}A$ und als Tableau geschrieben in der Form

$$\left(\begin{array}{c|c} -c^\top \bar{x} & c^\top - c_J^\top A_J^{-1}A \\ \hline A_J^{-1}b & A_J^{-1}A \end{array} \right) = \left(\begin{array}{cc} -W & \gamma^\top \\ \bar{x}_J & H \end{array} \right) =: \bar{H} = (h_{ij})_{i,j=0}^{m,n}. \quad (4.4.1)$$

Die zusätzlichen Daten werden also als nullte Zeile und Spalte des Tableaus geführt. Wegen $H_J \doteq A_J^{-1}A_J = I$ stehen in den Spalten zu Basisindizes $j \in J$ Einheitsvektoren, dort gilt $\gamma_j = 0$

und $He_j \in \{e_1, \dots, e_m\} \subseteq \mathbb{R}^m$. Zur Vereinfachung der folgenden Regeln wird zur Indizierung der Zeilen von H die Position i und nicht der Basisindex j_i aus $J = \{j_1, \dots, j_m\}$ verwendet. Die Zugehörigkeit der Komponenten aus der nullten Spalte $(h_{i0}) = \bar{x}_J$ (Steuer­spalte) wird durch die Position der Einheitsvektoren hergestellt, es gilt $h_{i0} = x_{j_i}$ und e_i steht in Spalte j_i von H . In der nullten 'Steuerzeile' stehen die reduzierten Gewinne $h_{0j} = \gamma_j, j \geq 1$. Der aktuelle Zielfunktionswert wird negativ in $h_{00} = -c_J^T \bar{x}_J$ notiert, dann gilt mit $c_0 := 0$ in der nullten Zeile die einheitliche Vorschrift $h_{0j} = c_j - \sum_i c_j h_{ij}, j = 0, \dots, n$. So kann nämlich ein Basiswechsel zu dem Tableau, das zur Basis $A_{J'}$ mit $J' = J \setminus \{p\} \cup \{\ell\}$ gehört, durch Anwendung der Rang-1-Formel (4.1.2) auf das *Gesamtttableau* \bar{H} durchgeführt werden. Für $p = j_s$ entspricht das 'Pivot-Element' $h_{s\ell} = -v_{p\ell}$. Die Formeln für den Basiswechsel lauten einheitlich für alle Daten:

$$\left. \begin{aligned} h'_{sj} &= \frac{h_{sj}}{h_{s\ell}}, \\ h'_{ij} &= h_{ij} - h_{i\ell} \frac{h_{sj}}{h_{s\ell}}, \quad i \in \{0, \dots, m\} \setminus \{s\}, \end{aligned} \right\} j = 0, \dots, n. \tag{4.4.2}$$

Satz 4.4.1 *Es sei \bar{H} das Simplex-Tableau (4.4.1) zur zulässigen Basis A_J . Dann wird der Übergang zum Tableau \bar{H}' , das zur Basis $A_{J'}$ mit $J' = J \setminus \{j_s\} \cup \{\ell\}, h_{s\ell} \neq 0$, gehört, durch (4.4.2) hergestellt.*

Bew

Damit bekommt das Tableau-Verfahren folgende Form (Numerierung wie in §4.3):

Simplex-Tableau-Verfahren

Eingabe:	Zulässiges Tableau \bar{H}
2	suche $h_{0\ell} > 0, 1 \leq \ell \leq n$,
3	wenn $h_{0j} \leq 0 \forall 1 \leq j \leq n$: _____ STOP , Optimum!
4	wenn $h_{i\ell} \leq 0 \forall 1 \leq i \leq m$: _____ STOP , unbeschränkt!
5	Bestimme s : $h_{s0}/h_{s\ell} = \min\{h_{i0}/h_{i\ell} : h_{i\ell} > 0, 1 \leq i \leq m\}$
6	Basiswechsel nach (4.4.2), weiter mit 2

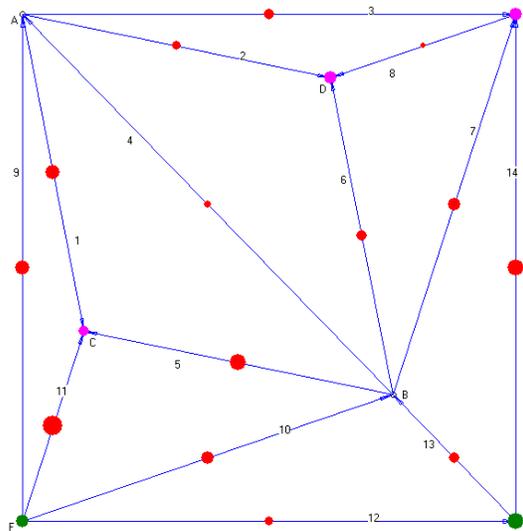
Beispiel 4.4.2 Mit dem Ablauf aus Beispiel 4.3.1 bekommt man beim Tableauverfahren folgende Tabellen. In den Steuer-Zeilen und -Spalten ist jeweils das ausgewählte Element $h_{0\ell} = \gamma_\ell$ bzw. $h_{0s} = \bar{x}_p, p = j_s$, unterstrichen, außerdem wurde das Pivotelement für den Basiswechsel eingerahmt. Unter den Tabellen wurde die Position der Basisindizes angegeben. Das erste Tableau ist zulässig, das dritte Tableau optimal, da keine positiven Gewinne mehr auftreten.

0	9	<u>6</u>	7	0	0	0	-66	<u>3</u>	0	1	0	-6	0	<u>$-\frac{159}{2}$</u>	0	0	$-\frac{1}{2}$	$-\frac{3}{2}$	$-\frac{9}{2}$	0
20	3	1	2	1	0	0	<u>9</u>	2	0	1	1	-1	0	$\frac{9}{2}$	1	0	$\frac{1}{2}$	$\frac{1}{2}$	$-\frac{1}{2}$	0
<u>11</u>	1	1	1	0	1	0	11	1	1	1	0	1	0	$\frac{13}{2}$	0	1	$\frac{1}{2}$	$-\frac{1}{2}$	$\frac{1}{2}$	0
40	4	3	4	0	0	1	7	1	0	1	0	-3	1	$\frac{5}{2}$	0	0	$\frac{1}{2}$	$-\frac{1}{2}$	$-\frac{5}{2}$	1
$J :$			j_1	j_2	j_3			j_2	j_1	j_3				j_1	j_2					j_3

Das Tabellenverfahren hat den vordergründigen Vorteil (für Handrechnung), dass der Basiswechsel mit einer einheitlichen Vorschrift für alle Daten des Linearen Programms durchgeführt

werden kann. Für große Probleme besteht aber der wesentliche Nachteil, dass immer wieder die ganze Matrix umgeformt wird und sich die Pivotwahl nicht nach der Größe von $h_{s\ell}$ richtet. Daher besteht die Gefahr des Ansammelns von Rundungsfehlern, und der Aufwand für einen Schritt ist immer $(2m + 1)(n + 1)$ Operationen.

Beispiel 4.4.3 (Rechner-Demo) In dem gezeigten Transportnetz soll ein Produkt von den Produzenten F und G zu den Abnehmern C,D,E geliefert werden, die Knoten A und B sind reine Umschlagplätze mit Bedarf 0. Transporte verlaufen nur längs der nummerierten Kanten j in der angezeigten Richtung (Menge $x_j \geq 0$). Das zugehörige (LP3) ist in der folgenden Tabelle beschrieben, die Transportkosten der Kanten in der nullten Zeile, der Bedarf in den Knoten in der nullten Spalte. Die Restriktionen sind Bilanzgleichungen in den einzelnen Knoten, die Differenz aller eingehenden und ausgehenden Mengen entspricht dem Bedarf des Knotens.



Die Zeile zu Knoten G fehlt, da sie redundant ist (Bedarf= -15), vgl. §1.2.2.

		53	18	29	8	60	28	37	5	44	38	98	14	23	59
A :	0	-1	-1	-1	1					1					
B :	0				-1	-1	-1	-1			1			1	
C :	6	1				1						1			
D :	10		1				1		1						
E :	8			1				1	-1						1
F :	-9									-1	-1	-1	-1		

4.5 Anlaufrechnung

Das Simplexverfahren setzt die Kenntnis einer Ecke des zulässigen Bereichs voraus. Man konstruiert eine solche durch Betrachtung von Hilfsproblemen, welche eine neue, geeignete Zielfunktion verwenden.

Zwei-Phasen-Methode

Diese basiert auf der Beobachtung, dass man beim Übergang von einem Problem (LP2) mit $b \geq 0$ zur Form (LP3) durch Einführung von Schlupfvariablen direkt eine Startbasis angeben kann (vgl. Beispiel 4.3.1). Diese Kenntnis nutzt man beim Problem (LP3)

$$\max\{c^T x : Ax = b, x \geq 0\}, \quad b \geq 0 \text{ (oBdA)}.$$

Da b die rechte Seite eines Gleichungssystems ist, ist die Vorzeichenbedingung an die b_i keine Einschränkung. Zu (LP3) wird nun das Hilfsproblem (Phase I)

$$\max(-\mathbf{1}^\top y) : Ax + y = b, \quad x \geq 0, \quad y \geq 0, \quad (4.5.1)$$

mit der Matrix $D := (A, I_m) \in \mathbb{R}^{m \times (n+m)}$ betrachtet. Die Variablen können zu einem Vektor $z^\top = (x^\top, y^\top)$ zusammengefaßt werden. Mit $J = \{n+1, \dots, n+m\}$ ist $D_J = I_m$ eine Basis und die Basislösung $\bar{z}_J = \bar{y} = b \geq 0$ zulässig. Die neue Zielfunktion $-\mathbf{1}^\top y = -\sum_{i=1}^m y_i \leq 0$ ist eine *Straffunktion*, sie 'bestraft' die künstlichen Schlupfvariablen und ist nach oben beschränkt, das Hilfsproblem also lösbar. Nun sei $\hat{z}^\top = (\hat{x}^\top, \hat{y}^\top)$ eine Lösung, die das Verfahren mit der Indexmenge $J \subseteq \{1, \dots, n+m\}$ bestimmt hat. Dann sind folgende Fälle möglich:

- a) $\hat{y} \neq 0$: Das Ausgangsproblem (LP3) ist inkonsistent.
- b) $\hat{y} = 0$: \hat{x} ist zulässig bei (LP3), dabei
 - b1) $J \subseteq \{1, \dots, n\}$: A_J bildet eine zulässige Basis für (LP3).
 - b2) $J \not\subseteq \{1, \dots, n\}$: $P := J \cap \{n+1, \dots, n+m\} \neq \emptyset$, für $p = j_s \in P$ ist $\hat{z}_p = \hat{y}_{p-n} = h_{s0} = 0$ und ein Austauschschritt mit Pivot $h_{s\ell} = v_{p\ell} \neq 0$, $\ell \in \{1, \dots, n\} \setminus J$ ändert nicht die Ecke \hat{z} , verkleinert aber P . Wenn bei $P \neq \emptyset$ kein Austausch mehr möglich ist, gilt also $h_{sj} = v_{pj} = 0$, $j = 1, \dots, n$ und die Matrix $D_J^{-1}A$ hat eine Nullzeile, A also einen Rangdefekt. Dann kann Zeile $p-n$ (zur Schlupfvariable z_p) aus A entfernt werden, da deren Koeffizient in der Linearkombination dieser Nullzeile 1 ist.

Im Fall b) kann die Rechnung mit dem Simplex-Verfahren aus §4.3 fortgesetzt werden, für das Tabellenverfahren aus §4.4 ist dazu die Steuerzeile aus c neu zu berechnen.

Wenn das Ausgangsproblem (LP3) selbst schon Schlupfvariable enthält in Gleichungen mit $b_i \geq 0$, muß an dieser Stelle nicht noch eine weitere eingeführt werden. \rightarrow

Groß-M-Methode

Das Umschalten von Phase I auf Phase II (Originalproblem) erspart man sich, wenn man in (4.5.1) die gemischte Zielfunktion

$$c^\top x - M\mathbf{1}^\top y = (c^\top, -M\mathbf{1}^\top)z$$

mit einer 'genügend großen' Konstanten M betrachtet. Diese muß die künstlichen Variablen y so stark bestrafen, dass sie im Optimum nicht mehr auftreten. Allerdings ist eine geeignete Wahl von M nicht einfach zu treffen, insbesondere, wenn (LP3) inkonsistent ist.

Wenn allerdings ursprünglich das Problem (LP2) mit $b \not\geq 0$ vorliegt, hat die Methode den Vorteil, dass nur eine überflüssige Variable benötigt wird. Dazu sei $b_q = \min\{b_i : 1 \leq i \leq m\} < 0$. Im erweiterten System $Ax + y = b$ wird nun die Zeile q von allen anderen subtrahiert und macht deren rechte Seite dadurch nichtnegativ. Die Zeile q selbst wird mit -1 multipliziert und

bestimmt, in mehreren Indizes p_1, p_2, \dots angenommen wird. Dann gilt also $x_{p_1}(t_\ell) = x_{p_2}(t_\ell) = \dots = 0$ und $x(t_\ell)$ ist wegen $|J(x(t_\ell))| < m$ also ausgeartet. Eine einfache Abhilfe gegen das Kreisen besteht darin, dass man die Auswahl unter diesen Indizes durch Zusatzregeln wieder eindeutig macht. In der Literatur gibt es dazu unterschiedliche Strategien.

Die folgenden beiden *kleinste Index*-Regeln wählen jeweils den in Frage kommenden kleinsten Original-Index bezogen auf die ursprüngliche Reihenfolge der Komponenten (im \mathbb{R}^n) und verhindert dadurch ein Kreisen. Die Schritte 2 und 5 des Simplexverfahrens aus §4.3 sind dazu folgendermaßen zu präzisieren:

2	bestimme $\ell \in K$: $\ell = \min\{j \in K : \gamma_j > 0\}$
5	bestimme $p \in J$: $p = \min\{i \in J : -\bar{x}_i/v_{i\ell} = t_\ell\}$

Die Durchführung dieser Regel erfordert beim Tabellenverfahren und auch beim revidierten Verfahren (abhängig von der Indexverwaltung dort) einen geringen Organisationsaufwand (Index-Sortierung), da die zugehörigen Daten im Verfahren oft den Platz wechseln.

5 Dualität beim Simplexverfahren

Bisher wurden die Dualitätsaussagen aus §3, die wichtige Hintergrundinformation zu den Eigenschaften eines linearen Programms liefern, nicht erwähnt. Tatsächlich ist es so, dass zwischen den Daten des Simplexverfahrens zum Primalproblem (LP3) und dessen Dualprogramm (LP3*) ein direkter Zusammenhang hergestellt werden kann, der zusätzliche Möglichkeiten bei der Implementierung von Simplexverfahren eröffnet. Die beiden Programme

$$\max\{c^\top x : Ax = b, x \geq 0\}, \quad \min\{y^\top b : y^\top A \geq c^\top\}$$

sind zueinander dual. Wenn im Simplexverfahren aus §4.3 eine optimale Basis A_J bestimmt wurde, gilt dort mit dem Hilfsvektor $g^\top = c_J^\top A_J^{-1}$ für den Vektor γ der reduzierten Gewinne die Ungleichung

$$0 \geq \gamma^\top = c^\top - c_J^\top A_J^{-1} A = c^\top - g^\top A, \quad \text{d.h.} \quad g^\top A \geq c^\top, \quad (5.0.1)$$

also ist g eine dual zulässige Lösung. Wegen $\gamma_J = 0$ sind die J -Ungleichungen straff, $g^\top A_J = c_J^\top$, was der Aussage des Komplementaritätssatzes $0 = (g^\top A - c^\top)\bar{x} = 0$ entspricht. Damit stimmen auch die Zielfunktionen $g^\top b = c_J^\top A_J^{-1} b = c^\top \bar{x}$ überein und der Vektor g ist sogar (Optimal-) Lösung von (LP3*).

5.1 Duales Simplexverfahren

Vollkommen unabhängig von der Zulässigkeit des primalen Vektors $A_J^{-1}b$ gehört zu jeder Basis, die (5.0.1) erfüllt, ein dual zulässiger Vektor g .

Definition 5.1.1 *Eine Basis A_J heißt dual zulässig, wenn (5.0.1) gilt, sie heißt primal zulässig, wenn $\bar{x}_J = A_J^{-1}b \geq 0$, und optimal, wenn sie primal und dual zulässig ist.*

Beim dualen Simplexverfahren arbeitet man mit den gleichen Basen A_J wie in §4.3, startet aber mit einer dual zulässigen Basis. In Bezug auf das Primal-Problem ist der zugehörige Vektor $\bar{x}_J = A_J^{-1}b$ zwar 'optimal', aber nicht zulässig. Beim Basisaustausch werden daher negative Komponenten $\bar{x}_p < 0$ eliminiert.

Mit dieser Variante gewinnt man zusätzliche Wahlmöglichkeiten der Verfahrensgestaltung. Z.B. gilt beim Problem (LP2),

$$\max\{c^\top x : Ax + z = b, x \geq 0, z \geq 0\},$$

das hier durch Schlupfvariablen ergänzt wurde, mit $D = (A, I)$, $J = \{n+1, \dots, n+m\}$:

$$\text{die Basis } D_J = I_m \text{ ist } \begin{cases} \text{primal} & \text{zulässig für } b \geq 0, \\ \text{dual} & \text{zulässig für } c \leq 0. \end{cases}$$

Im zweiten Fall läßt sich die Anlaufrechnung also durch Verwendung des dualen Simplexverfahrens einsparen.

Zur Herleitung sei jetzt also A_J eine dual zulässige Basis, $g^\top = c_J^\top A_J^{-1}$, $\gamma^\top = c^\top - g^\top A \leq 0$, $\bar{x}_J = A_J^{-1}b$, $K = \{1, \dots, n\} \setminus J$. Ist nun $\bar{x}_p < 0$, $p \in J$, so ist die duale Zielfunktion $g^\top b = c_J^\top A_J^{-1}b = c_J^\top \bar{x}_J$ noch nicht minimal. Der negative 'duale Schattenpreis' $x_p < 0$ zeigt an, dass durch 'Vergrößerung' von c_p , $p \in J$, eine Verminderung dieser Zielfunktion erfolgen kann. Analog zu (4.2.5) betrachtet man daher den Strahl

$$g(\lambda) := (c + \lambda e_p)^\top A_J^{-1} = g^\top + \lambda (e_p)^\top A_J^{-1}, \quad \lambda \geq 0. \quad (5.1.1)$$

Für die duale Zielfunktion gilt dort tatsächlich

$$g(\lambda)^\top b = g^\top b + \lambda (e_p)^\top A_J^{-1}b = g^\top b + \lambda \bar{x}_p < g^\top b \quad \text{für } \lambda > 0.$$

Allerdings muß dabei, wieder analog zu (4.2.7), die duale Zulässigkeit von $g(\lambda)$ geprüft werden. Es ist zu fordern

$$0^\top \geq c^\top - g(\lambda)^\top A = c^\top - g^\top A - \lambda (e_p)^\top A_J^{-1}A = \gamma^\top - \lambda u_p^\top, \quad u_p^\top := (e_p)^\top A_J^{-1}A.$$

Wegen $\gamma_J = 0$ ist diese Bedingung für Indizes aus J automatisch erfüllt, $\gamma_J^\top - \lambda (e_p)^\top A_J^{-1}A_J = -\lambda (\delta_{pj})_{j \in J} \leq 0^\top$. Auch ist für $u_p \geq 0$ zu erkennen, dass λ beliebig vergrößert werden kann. In diesem Fall ist (LP3*) unbeschränkt und (LP3) inkonsistent, vgl. §3.1. Nur für negative Komponenten von $u_p = (u_{pj})_j$ ergeben sich Einschränkungen und führen zum maximal zulässigen Wert

$$\lambda_p := \min \left\{ \frac{\gamma_j}{u_{pj}} : u_{pj} < 0, j \in K \right\} = \frac{\gamma_\ell}{u_{p\ell}}. \quad (5.1.2)$$

Wenn das Minimum, wie angegeben, im Index $\ell \in K$ angenommen wird, wird die entsprechende Ungleichung *straff*, $0 = c_\ell - g(\lambda_p)^\top a_\ell$. Umgekehrt ist für $\lambda_p > 0$ in der Ungleichung zu $p \in J$ nach Konstruktion das Gegenteil der Fall, $0 > c_p - g(\lambda_p)^\top a_p = -\lambda_p$. Daher ist $g(\lambda_p)$ die duale Basislösung zur Basis

$$A_{J'}, \quad J' = J \setminus \{p\} \cup \{\ell\}.$$

Analog zu Satz 4.2.6 läßt sich zeigen, dass $A_{J'}$ wegen $u_{p\ell} < 0$ tatsächlich regulär ist. Die obigen Überlegungen werden zusammengefaßt:

Duales Simplex-Verfahren

Eingabe:	Dual zulässige Basis A_J , $J \subseteq \{1, \dots, n\}$
Schritt 1	$x_J := A_J^{-1}b$, $g^\top := c_J^\top A_J^{-1}$, $K := \{1, \dots, n\} \setminus J$,
2	suche $x_p < 0$ unter x_i , $i \in J$.
3	wenn $x_i \geq 0 \forall i \in J$: _____ STOP , Optimum!
4	$u_{pj} := (e_p)^\top A_J^{-1}a_j$, $j \in K$, wenn $u_{pj} \geq 0 \forall j \in K$: STOP , (LP3) inkonsistent!
5	$\gamma_j := c_j - g^\top a_j$, $j \in K$, suche $\ell \in K$: $\gamma_\ell / u_{p\ell} = \min \{ \gamma_j / u_{pj} : u_{pj} < 0, j \in K \} = \lambda_p$
6	$J := J \setminus \{p\} \cup \{\ell\}$, weiter mit 1

Zur Durchführung sind wie beim Primalverfahren drei Gleichungssysteme zu lösen, etwa mit einer fortlaufend angepaßten LR-Zerlegung von A_J . Dies sind zunächst wieder die beiden Systeme $A_J x_J = b$ und $g^\top A_J = c_J^\top$, sowie $f^\top A_J = (e_p)_J$. Der Aufwand dafür liegt wieder bei $O(m^2)$ einschließlich der LR-Anpassung. Dann sind folgende Innenprodukte zu berechnen

$$u_{pj} = f^\top a_j, \quad j \in K, \quad \text{sowie } c_j - g^\top a_j, \quad \text{für } u_{pj} < 0.$$

Hierfür sind zwischen $2m(n-m)$ und $4m(n-m)$ Operationen nötig, dieser Anteil ist also etwa doppelt so groß wie beim primalen Verfahren aus §4.3. Bei vorhandener Wahlmöglichkeit hat das Primalverfahren also einen Effizienzvorteil.

Beispiel 5.1.2 Für das Problem

$$\left. \begin{array}{l} \min 2x_1 + x_2 + 3x_3 \\ x_1 + x_2 + x_3 \geq 1 \\ 2x_1 - x_2 + 2x_3 \leq -2 \\ x_1 + 2x_2 - 2x_3 \geq 1 \\ x_i \geq 0 \end{array} \right\} \iff \left\{ \begin{array}{l} \max -2x_1 - x_2 - 3x_3 \\ -x_1 - x_2 - x_3 + x_4 = -1 \\ 2x_1 - x_2 + 2x_3 + x_5 = -2 \\ -x_1 - 2x_2 + 2x_3 + x_6 = -1 \\ x_i \geq 0 \end{array} \right.$$

gehört zu $J = \{4, 5, 6\}$ eine dual, aber nicht primal zulässige Basis. Das duale Simplexverfahren führt hier mit den folgenden Daten in 2 Schritten zum Ziel:

B-1 **1.** $J = \{4, 5, 6\}$, $A_J = I$, $\bar{x}_J^\top = (-1, -2, -1)$, $g = 0$, $c^\top \bar{x} = 0$.

2. wähle $p = 4$, $u^\top = (e_4)_J^\top A_J^{-1} A = e_1^\top A = (-1, -1, -1, 1, 0, 0)$, $(\gamma_1, \gamma_2, \gamma_3) = (-2, -1, -3)$; $\lambda_p = \min\{2, 1, 3\} = 1$ angenommen in $\ell = 2$.

B-2 **1.** $J = \{2, 5, 6\}$, $A_J^{-1} = \begin{pmatrix} -1 & 0 & 0 \\ -1 & 1 & 0 \\ -2 & 0 & 1 \end{pmatrix} = B$, $x_J^\top = (A_J^{-1}b)^\top = (1, -1, 1)$. $c^\top \bar{x} = -1$,

$g^\top = (1, 0, 0)$.

2. wähle $p = 5$, $u^\top = (e_5)_J^\top A_J^{-1} A = e_2^\top B A = (3, 0, 3, -1, 1, 0)$, $\gamma_4 = -1$, $\lambda_p = \gamma_4/u_{p4} = 1$ mit $\ell = 4$.

B-3 **1.** $J = \{2, 4, 6\}$, $A_J^{-1} = \begin{pmatrix} 0 & -1 & 0 \\ 1 & -1 & 0 \\ 0 & -2 & 1 \end{pmatrix}$, $\bar{x}_J^\top = (A_J^{-1}b)^\top = (2, 1, 3)$ **optimal**, $c^\top \bar{x} = -2$.

Auch beim dualen Verfahren besteht die Gefahr des Kreisens, wenn das Minimum bei (5.1.2) nicht in einem einzigen Index ℓ angenommen wird. Diese Gefahr läßt sich auch hier wieder durch *kleinste Index-Regeln* ausschalten. Diese lauten in Schritt 2 und 5:

2	bestimme $p \in J$: $p = \min\{i \in J : x_i < 0\}$
5	bestimme $\ell \in K$: $\ell = \min\{j \in K : \gamma_j/u_{pj} = \lambda_p\}$

5.2 Problem-Modifikationen

In die Formulierung praktischer Probleme gehen oft Daten ein, deren Wert nicht genau bekannt oder vorhersehbar ist (z.B., die Preis- oder Zinsentwicklung bei einer Produktions- oder Finanzplanung). Dann ist es klug, auch Varianten des Ausgangsproblems zu lösen ('was passiert, wenn der Euro über 1.10 Dollar steigt?'), etwa in Abhängigkeit von einem künstlichen Parameter $t \in \mathbb{R}$ ('parametrische Optimierung'). Oft will man auch unerwünschte Lösungen nachträglich durch weitere Restriktionen ausschließen, etwa nicht-ganzzahlige in der ganzzahligen Optimierung. In diesen Fällen kann man durch eine geschickte Kombination aus primalem und dualem Simplexverfahren eine bekannte Lösung dem veränderten Problem anpassen. Wir betrachten vier Situationen, Ausgangspunkt sei jeweils eine bekannte (Optimal-) Lösung \hat{x} mit Basis A_J .

- Änderung der Zielfunktion c . Die Untersuchung einer parametrischen Änderung $c(t) = c + t\tilde{c}$, $t \geq 0$, (zur Vereinfachung) ist vorteilhaft, da Änderungen der Ausgangssituation dann schrittweise eintreten. Es sei daher

$$W(t) := \max\{(c + t\tilde{c})^\top x : Ax = b, x \geq 0\}.$$

Die Lösung \hat{x} zu $t = 0$ ist auch zulässig für $t \neq 0$. Der Gewinnvektor ist allerdings

$$\gamma(t)^\top = c(t)^\top - c_J(t)^\top A_J^{-1}A = \gamma(0)^\top + t\tilde{\gamma}^\top, \quad \tilde{\gamma} = \tilde{c}^\top - \tilde{c}_J^\top A_J^{-1}A.$$

Da \hat{x} optimal in $t = 0$ war, ist $\gamma(0) \leq 0$ und \hat{x} bleibt solange optimal, wie

$$\gamma(t) = \gamma(0) + t\tilde{\gamma} \leq 0 \iff t \leq \min\left\{-\frac{\gamma_j(0)}{\tilde{\gamma}_j} : \tilde{\gamma}_j > 0, j \in K\right\} =: t_{\max},$$

($\gamma_J(t) \equiv 0$ gilt weiterhin). Wenn $t_{\max} > 0$ ist, ist \hat{x} für $t \in [0, t_{\max}]$ optimal und daher $W(t) = W(0) + t\tilde{c}^\top \hat{x}$ dort linear (insgesamt ist $W(t)$ stückweise linear). Bei Vergrößerung von t über t_{\max} hinaus verliert \hat{x} seine Optimalität und im reduzierten Gewinnvektor tauchen positive Komponenten auf. Ausgehend von der primal zulässigen Basis A_J kann mit dem *primalem* Verfahren aus §4.3 nachoptimiert werden.

- Änderung des (Ressourcen-) Vektors $b(t) = b + t\tilde{b}$, wieder parametrisiert mit $t \geq 0$. Also sei

$$W(t) := \max\{c^\top x : Ax = b + t\tilde{b}, x \geq 0\}.$$

Dann ist $x(t)$ mit

$$x_K(t) = 0, \quad x_J(t) = A_J^{-1}(b + t\tilde{b}) = \hat{x}_J + t\xi_J, \quad \xi_J := A_J^{-1}\tilde{b},$$

eine Lösung des Gleichungssystems $Ax = b + t\tilde{b}$. Wenn \hat{x} nicht ausgeartet ist, ist $x(t)$ zulässig, solange

$$\hat{x}_J + t\xi_J \geq 0 \iff t \leq \min\left\{-\frac{\hat{x}_i}{\xi_i} : \xi_i < 0, i \in J\right\} =: t_{\max}.$$

Die Zielfunktion $W(t) = W(0) + tc_J^\top \xi_J$ ist in diesem Intervall also wieder linear. Der Gewinnvektor γ ist hier unabhängig von t , da er nur von c und A abhängt. Wenn jetzt also t über t_{\max} hinaus vergrößert wird, bleibt $x(t)$ immer noch optimal, verliert aber seine Zulässigkeit. Ausgehend von der dual zulässigen Basis A_J kann jetzt mit dem *dualen* Simplexverfahren aus §5.1 nachoptimiert werden.

- Einführung einer zusätzlichen Variablen x_{n+1} . Es sei $\tilde{A} = (A, a_{n+1})$, $\tilde{c}^\top = (c^\top, c_{n+1})$. Der Vektor $(\hat{x}^\top, 0)$ ist dann auch zulässig beim erweiterten Problem. In Bezug auf Optimalität ist mit der dualen Lösung $g^\top = c_J^\top A_J^{-1}$ nur der Wert γ_{n+1} zu prüfen. Für $\gamma_{n+1} \leq 0$ bleibt der erweiterte Punkt optimal. Für

$$\gamma_{n+1} = c_{n+1} - g^\top a_{n+1} > 0$$

kann wieder das *primale* Verfahren aus §4.3 mit der primal zulässigen Basis $\tilde{A}_J = A_J$ angewendet werden.

Beispiel 5.2.1 Das Einführungsbeispiel 1.2.1 zur Produktionsplanung hatte die Form

$$\begin{aligned} \max \quad & 4x_1 + 3x_2 \\ \mathbf{A} : \quad & x_1 + x_2 + x_3 = 16, \\ \mathbf{L} : \quad & x_2 + x_4 = 12, \\ \mathbf{E} : \quad & 3x_1 + x_2 + x_5 = 36, \quad x_i \geq 0, \end{aligned}$$

und die Lösung $\hat{x}^\top = (10, 6, 0, 6, 0)$ zu $J = \{1, 2, 4\}$ mit $c^\top \hat{x} = 58$. Die Ungleichungen zu Arbeitsaufwand ($\hat{x}_3 = 0$) und Energiebedarf ($\hat{x}_5 = 0$) sind straff, die Schattenpreise der dualen Lösung $g^\top = (\frac{5}{2}, 0, \frac{1}{2})$ zeigen, dass der Gewinn gesteigert werden kann, wenn eine Erhöhung von Arbeitsleistung nicht mehr als $g_1 = \frac{5}{2}$ bzw. der Energiekosten um mehr als $g_3 = \frac{1}{2}$ pro Einheit kostet. Nun werde angenommen, dass zusätzliche Energie zu einem Preis von $c_6 < 0$ erhältlich ist. Am besten kauft man zusätzliche Energie nicht blind, sondern erweitert das Problem um den zusätzlichen Energieanteil $x_6 \geq 0$. Die geänderte Bedingung **E**: $3x_1 + x_2 \leq 36 + x_6$ führt zur Restriktion

$$\mathbf{E} : 3x_1 + x_2 + x_5 - x_6 = 36, \text{ sowie } c^\top x = 4x_1 + 3x_2 + c_6 x_6.$$

Also ist $a_6 = -e_3$ und $\gamma_6 = c_6 - g^\top a_6 = c_6 + \frac{1}{2}$. Für $c_6 > -\frac{1}{2}$ ist der Gewinn positiv und ein Austauschschritt mit $\ell = 6$, $v_\ell^{(J)} = -A_J^{-1} a_6 = A_J^{-1} e_3 = \frac{1}{2}(1, -1, 1)^\top$ ergibt $p = j_2 = 2$ und führt zur neuen Lösung $(16, 0, 0, 12, 0, 4)^\top$ mit $J' = \{1, 5, 6\}$ und Zielfunktionswert $64 + 4c_6$.

- Einführung zusätzlicher Ungleichungen, etwa $a^{(m+1)\top} x \leq b_{m+1}$. Das Programm (LP3) wird also erweitert um die Gleichung $a^{(m+1)\top} x + x_{n+1} = b_{m+1}$, $x_{n+1} \geq 0$, in der Zielfunktion ist $c_{n+1} = 0$. Mit der entsprechend erweiterten Matrix \tilde{A} und $J' := J \cup \{n+1\}$ ist

$$\tilde{A}_{J'} = \begin{pmatrix} A_J & 0 \\ a_J^{(m+1)\top} & 1 \end{pmatrix} \Rightarrow (\tilde{A}_{J'})^{-1} = \begin{pmatrix} A_J^{-1} & 0 \\ -a_J^{(m+1)\top} A_J^{-1} & 1 \end{pmatrix}. \quad (5.2.1)$$

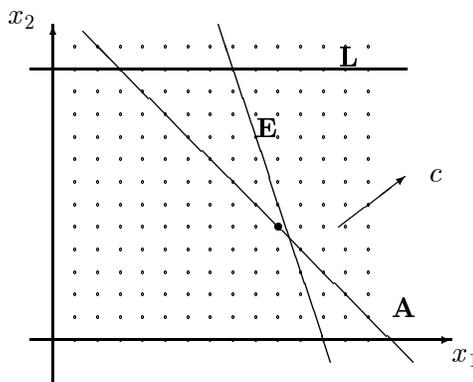
Wegen $c_{n+1} = 0$ liefert die letzte Zeile keinen Beitrag zum erweiterten Gewinnvektor $(c^T, 0) - c_J^T A_J^{-1}(A, 0) = (\gamma^T, 0) \leq 0$ und der ergänzte Vektor $(\hat{x}^T, \bar{x}_{n+1})^T$ bleibt weiterhin optimal, allerdings nicht mehr zulässig für

$$\bar{x}_{n+1} = b_{m+1} - a^{(m+1)T} \hat{x} < 0.$$

Dies ist also mit $p = n + 1$ wieder ein Fall für das *duale* Simplexverfahren aus §5.1.

Dieser Fall hat eine große Bedeutung in der ganzzahligen und nichtlinearen Optimierung. Dort werden lineare (Hilfs-) Programme gelöst und schrittweise unerwünschte Lösungen durch *Schnittebenen*, d.h. zusätzliche Ungleichungen eliminiert.

Beispiel 5.2.2 Im Beispiel 1.2.1 sei die Schranke für Resource **A** auf $b_1 = 15$ geändert, mit $J = \{1, 2, 4\}$ lautet die Lösung dann $\hat{x}_J^T = (10.5, 4.5, 7.5)$, $W = 55.5$. Wenn nur ganze Einheiten produziert werden, ist diese Lösung unbrauchbar. Eine Rundung dieser Werte ist auch keine Hilfe, da die Zulässigkeit dann nicht gesichert ist. Mit Hilfe der zusätzlichen Ungleichung $2x_1 + x_2 \leq 25$ kann diese Ecke des zulässigen Bereichs abgeschnitten werden (die Konstruktion solcher Ungleichungen wird in der ganzzahligen Optimierung behandelt).



Im erweiterten Problem ist jetzt $\hat{x}_6 = 25 - 2\hat{x}_1 - \hat{x}_2 = -1/2 < 0$, $J' = \{1, 2, 4, 6\}$. Mit A_J^{-1} aus Beisp. 5.2.1 wird u_p zu $p = 6$ aus der letzten Zeile von (5.2.1) berechnet $u_p^T = (-a_J^{(6)T} A_J^{-1}, 1) \bar{A} = (0, 0, -\frac{1}{2}, 0, -\frac{1}{2}, 1)$. Der (alte) Gewinnvektor ist $\gamma^T = (0, 0, -\frac{5}{2}, 0, -\frac{1}{2})$ und führt auf $\lambda_6 = 1$ bei $\ell = 5$. Zu den neuen Basisindizes $J'' = \{1, 2, 4, 5\}$ gehört die ganzzahlige Lösung $x^T = (10, 5, 0, 7, 1, 0)$.

Ausblick

Professionelle Computerprogramme ('Dynamische Simplex-Verfahren') bringen beim allgemeinen Problem (LP) beide Varianten adaptiv zum Einsatz, teilweise auch als Ersatz für eine Anlaufrechnung. Ansatzweise sei das am Programm (LP) ohne freie Variable erläutert, d.h. bei

$$\max\{c^T x : Ax = b, Mx \leq d\}. \quad (\text{LP})$$

Dabei seien $A \in \mathbb{R}^{m \times n}$ und $M \in \mathbb{R}^{\mu \times n}$ sehr große Matrizen. Um dennoch mit annehmbarem Aufwand arbeiten zu können, betrachtet man Teilprobleme, wo nur ein Teil der Variablen und ein Teil der Ungleichungen aktiviert ist ([Padberg]). Mit $P \subseteq \{1, \dots, n\}$, $L \subseteq \{1, \dots, \mu\}$ sind das Probleme der Form

$$\max\{c_P^T x_P : A_P x_P = b, M_P^{(L)} x_P \leq d_L\}, \quad (\text{LP}_P^L)$$

nur die Gleichungsrestriktionen werden also alle berücksichtigt. Schrittweise werden nun solche Teilprobleme gelöst und danach durch Suche nach positiven Gewinnen $\gamma_j > 0$ neue Variable $j \notin P$, oder verletzte Ungleichungen $\notin L$ aktiviert. Die Anpassung der Lösung der neuen Teilprobleme kann mit primalem bzw. dualem Verfahren durchgeführt werden (s.o.). Umgekehrt können Variable zu $j \in P$ (für $\gamma_j \ll 0$) bzw. Ungleichungen aus L auch wieder deaktiviert werden, wenn Gewinn oder Schlupfvariable bestimmte Schwellenwerte unter- bzw. überschreiten. Sehr große Probleme können insbesondere dann so gelöst werden, wenn die Suche zur Aktivierung *algorithmisch* erfolgen kann. Dies ist bei Schnittebenenverfahren der Fall.

Ähnliches gilt beim TSP, wo die $\cong 2^n$ Ungleichungen (1.2.3) sicherstellen, dass die Tour zusammenhängend ist. Für eine vorliegende Näherungslösung x ist die Überprüfung des Zusammenhangs ($O(n)$ -Aufwand bei n Orten) und die Konstruktion einer verletzten Ungleichung aber trivial.

6 Spezielle Anwendungen

Im folgenden werden einige Anwendungen der Verfahren aus §4-5 und der theoretischen Ergebnisse aus §2-3 auf verschiedene Problembereiche behandelt.

6.1 Restringierte Ausgleichsprobleme

In den (Natur-) Wissenschaften ist die Standardmethode zur Auswertung von Messungen die Kleinste-Quadrate-Methode von Gauß (Regression). Dabei werden Messungen w_i , $i = 1, \dots, m$, einer Größe w , die von Parametern α, β, \dots (Zeit, Temperatur,..) abhängen, zur Anpassung eines gegebenen Modells $w = f(a, b, \dots)$ verwendet, indem man die Quadrat-Abweichung

$$\sum_{i=1}^m \left(f(\alpha_i, \beta_i, \dots) - w_i \right)^2 \text{ minimiert.} \quad (6.1.1)$$

Wenn f dabei Linearkombination $f(\alpha, \beta, \dots) = \sum_{j=1}^n x_j \varphi_j(\alpha, \beta, \dots)$ von gegebenen Basisfunktionen φ_j ist, stellt (6.1.1) ein quadratisches Minimierungsproblem der Form

$$\min \{ \|Gx - w\|_2^2 : x \in \mathbb{R}^n \}$$

dar, wobei $G = (\varphi_j(\alpha_i, \beta_i, \dots))_{i,j}$ gilt. Dieses Problem läßt sich standardmäßig (u.a.) durch Lösung des linearen Gleichungssystems $G^T Gx = G^T w$ (Normalengleichung) lösen. Leider liefert dieses System manchmal (physikalisch) unsinnige Lösungen, etwa negative Massenanteile. Diese Fälle könnte man durch zusätzliche Restriktionen, etwa $Gx \geq 0$ ausschließen. Da $\|Gx - w\|^2 = \|w\|^2 - 2w^T Gx + x^T G^T Gx$ gilt, lautet ein entsprechendes Problem, mit $C \in \mathbb{R}^{n \times n}$, $A \in \mathbb{R}^{m \times n}$,

$$\min \frac{1}{2} x^T Cx - d^T x, \quad Ax \leq b, \quad x \geq 0, \quad (6.1.2)$$

etwa mit $C = G^T G$, $d = G^T w$, $A = -G$, $b = 0$. Dieses Problem ist zwar kein lineares, sondern ein quadratisches Optimierungsproblem, läßt sich aber mit Hilfe des Farkas-Lemmas durch ein leicht modifiziertes Simplexverfahren lösen.

Zunächst werden notwendige Bedingungen für die Minimalität eines Punktes \hat{x} hergeleitet. Ein Nachbarpunkt $\hat{x} + \epsilon \xi$, $\epsilon > 0$, liegt in $X := \{x : Ax \leq b, x \geq 0\}$, sofern

$$\xi_j \geq 0, \text{ wenn } \hat{x}_j = 0, \quad \text{und} \quad a^{(i)T} \xi \leq 0, \text{ wenn } a^{(i)T} \hat{x} = b_i. \tag{6.1.3}$$

Mit den Indexmengen $K := \{1, \dots, n\} \setminus J$, $J := J^+(\hat{x})$, $L := \{1, \dots, m\} \setminus J^+(b - A\hat{x})$ der bei \hat{x} straffen Restriktionen heißt dies kurz $\xi_K \geq 0$, $A^{(L)} \xi \leq 0$. Die Entwicklung der quadratischen Zielfunktion $F(x) = \frac{1}{2} x^T C x - d^T x$ liefert

$$F(\hat{x} + \epsilon \xi) - F(\hat{x}) = \epsilon (C\hat{x} - d)^T \xi + \epsilon^2 \frac{1}{2} \xi^T C \xi. \tag{6.1.4}$$

Der Punkt ist dann ein Minimalpunkt, wenn diese Differenz für alle nach (6.1.3) in Frage kommenden ξ nicht negativ wird. Für kleine $\epsilon > 0$ erfordert das, dass die Folgerung

$$(6.1.3) \quad \Rightarrow \quad (C\hat{x} - d)^T \xi \geq 0$$

richtig ist. Diese entspricht der 'rechten Seite' des Farkas-Lemmas (2.6.1) mit Matrix $(I_K, -A^{(L)T})$ und dem Vektor $C\hat{x} - d$. Damit äquivalent ist daher die Lösbarkeit des Systems

$$u_K - A^{(L)T} v_L = C\hat{x} - d, \quad u_K \geq 0, v_L \geq 0.$$

Denkt man sich u_K als Teil eines Vektors $u \in \mathbb{R}_+^n$ mit $u_J = 0$, gilt insbesondere $u^T \hat{x} = 0$.

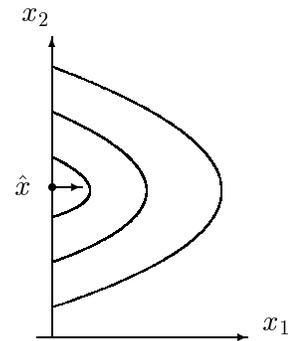
Satz 6.1.1 (Kuhn-Tucker) Die Matrix C in (6.1.2) sei positiv definit. Ein $\hat{x} \in R^n$ ist Lösung von (6.1.1) genau dann, wenn $y, v \in \mathbb{R}^m$, $u \in \mathbb{R}^n$ existieren als Lösung von

Bew

$$\begin{aligned} A\hat{x} + y &= b \\ C\hat{x} - u + A^T v &= d \\ \hat{x}, y, u, v &\geq 0, \quad u^T \hat{x} + v^T y = 0. \end{aligned} \tag{6.1.5}$$

Außer der Komplementaritätsbedingung $u^T \hat{x} = v^T y = 0$ sind hier also alle Bedingungen linear!

Geometrische Interpretation: Bei positiv definiten Matrix C sind die Niveauflächen (Höhenlinien) der quadratischen Funktion $F(x) = \frac{1}{2} x^T C x - d^T x$ Ellipsoide. Das eindeutige globale Minimum wird im Punkt $\bar{x} = C^{-1}d$ angenommen, wo der Gradient $\text{grad } F(x) = Cx - d$ verschwindet. Bei einer Nebenbedingung $x_1 \geq 0$ wird das Minimum \hat{x} dagegen auf dem Rand ($x_1 = 0$) angenommen, wenn $\bar{x}_1 < 0$ ist. Das Minimum liegt dort auf dem Rand, wo der Gradient senkrecht auf der Randfläche nach innen zeigt (=Anstieg), also in Richtung e_1 . Dann existiert also ein $u_1 \geq 0$ mit $C\hat{x} - d = u_1 e_1$ und $u_1 \hat{x}_1 = 0$. Dagegen wäre $u_2 = 0$ wegen $\hat{x}_2 \neq 0$ in (6.1.5). Analog dazu repräsentieren die Größen $v_i a^{(i)}$ Anteile der Normalen der kritischen Rand-Hyperebenen von $\{x : Ax \leq b\}$.



Zur Bestimmung einer Lösung des Ungleichungssystems (6.1.5) beginnt man mit einer Lösung der Nebenbedingungen in (6.1.2) $Ax^{(0)} + y^{(0)} = b$, $x^{(0)}, y^{(0)} \geq 0$, die man mit einer Anlaufrechnung aus §4.5 bestimmen kann. Um auch einen Ausgangspunkt zu bekommen, der die zweite Gleichung in (6.1.5) mit der Wahl $u = 0, v = 0$, erfüllt (dann sind die Komplementbedingungen $u^\top x^{(0)} = v^\top y^{(0)} = 0$ eingehalten), geht man ebenfalls wie bei Phase I vor. Man führt künstliche Variablen $z \geq 0$ ein und macht eine Vorzeichenanpassung mit Hilfe einer festen Vorzeichenmatrix $Q = \text{diag}(q_i)$, $q_i = \pm 1$, mit

$$Qz^{(0)} := d - Cx^{(0)}, \quad \text{d.h. } q_i = \text{sign}(d_i - e^{(i)\top} Cx^{(0)}).$$

Die Zusatzvariablen z bestraft man mit der Zielfunktion $-\mathbf{1}^\top z$ und erhält das Problem

$$\begin{aligned} \max \quad & -\mathbf{1}^\top z \\ Ax \quad +y & & & = b \\ Cx \quad & -u \quad +A^\top v \quad +Qz & = d \\ x, y, u, v, z & \geq 0. \end{aligned} \tag{6.1.6}$$

Eine zulässige Startbasis erhält man aus der Basislösung

$$x = x^{(0)}, \quad y = y^{(0)}, \quad u = 0, \quad v = 0, \quad z = z^{(0)},$$

welche trivialerweise auch die Komplementbedingungen erfüllt. Wenn die Ausgangslösung $x^{(0)}, y^{(0)}$ mit einer Anlaufrechnung bestimmt wurde, gilt $|J_x| + |J_y| = m$, wobei $J_x = J(x^{(0)})$, $J_y := J(y^{(0)})$ ist. Dann ist die Matrix

$$\left(\begin{array}{cc|c} A_{J_x} & I_{J_y} & 0 \\ C_{J_x} & 0 & Q \end{array} \right) \in \mathbb{R}^{(m+n) \times (m+1)}$$

die Basismatrix zur Startlösung und regulär, da die Hauptdiagonalblöcke (A_{J_x}, I_{J_y}) und Q regulär sind. Das Problem (6.1.6) enthält $m+n$ Gleichungen für $2m+3n$ Unbekannte. Im Interesse der Übersichtlichkeit werden diese nicht durchnummeriert, im folgenden wird die Zugehörigkeit zu den Basisvariablen (zu J) durch Nennung der Variablen beschrieben.

Dieses Problem kann nun einfach mit dem primalen Simplexverfahren gelöst werden, wenn man im Schritt 2 (Wahl von $\gamma_\ell > 0$) folgende *Ausschlußregel* anwendet:

$$\begin{array}{ccc} x_j & & u_j \\ \text{wenn Variable } u_j & \text{zur Basis gehört, darf } x_j & \text{nicht zur Aufnahme gewählt werden} \\ y_j & & v_j \\ v_j & & y_j \end{array}$$

(Verfahren von Wolfe). Für eine positiv definite Matrix C läßt sich zeigen, dass dieses Verfahren tatsächlich zum Erfolg führt, mit Lösung $\hat{z} = 0$.

Beispiel 6.1.2 Das Verfahren soll zur Modellierung einer reellen Funktion $f(t)$ anhand vieler Meßwerte $w_i \in \mathbb{R}$ erläutert werden. Als Ansatz wird ein Polynom $f(t)$ vom Grad 2 verwendet, das Ziel ist die Approximation

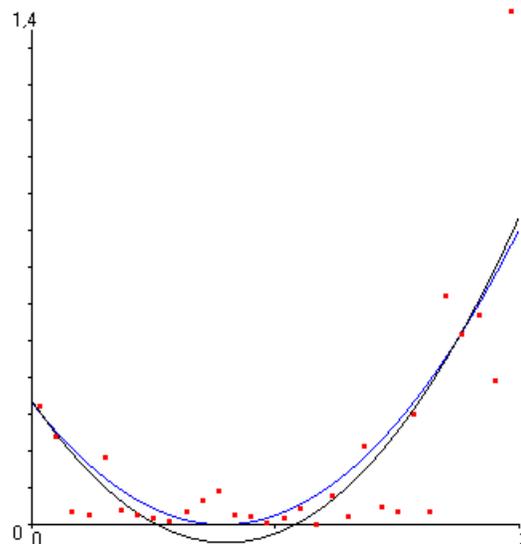
$$f(t_i) = \sum_{j=1}^3 \varphi_j(t_i) = (\varphi_1(t_i), \varphi_2(t_i), \varphi_3(t_i)) x \cong w_i, \quad i = 1, \dots, m \gg 3.$$

Dabei sollen aber nur nichtnegative Werte $f(t_i) \geq 0$ akzeptabel sein. Da im Problem (6.1.5) auch $x_i \geq 0$ gefordert wird, sind als Basisfunktionen Kardinalbasen zu wählen (der Ansatz $x_1 + x_2 t + x_3 t^2$ würde nur monotone Funktionen liefern). Ein Beispiel sind die sog. Lagrange-Polynome $\varphi_1(t) = (2t - 1)(t - 1)$, $\varphi_2(t) = 4t(1 - t)$, $\varphi_3(t) = 2t(t - 1)$. Im Optimierungsproblem (6.1.2) ist also $n = 3$,

$$G = (\varphi_1(t_i), \varphi_2(t_i), \varphi_3(t_i))_{i=1}^m, \quad C = G^T G, \quad d = G^T w, \quad A = -G, \quad b = 0.$$

Die Startbasis kann wegen $b = 0$ jetzt sogar nur aus den Spalten zu y, z gewählt werden ($J_x = \emptyset$) mit einer ausgearteten Basislösung ($y^{(0)} = 0$).

Im Beispiel sind 31 Werte zu $t_i \in [0, 2]$ gegeben, die Abweichung der Bestapproximation (6.1.1) beträgt 0.893, sie besitzt aber negative Funktionswerte. Das Verfahren von Wolfe bestimmt die nichtnegative Approximation in 17 Schritten, deren Abweichung ist mit 0.912 nur wenig größer.



6.2 Zwei-Personen-Nullsummenspiele

Die jetzt behandelte Theorie behandelt Situationen, in denen wiederholt eine Entscheidung unter mehreren möglichen zu treffen ist, wobei das Ergebnis aber auch von den unbekanntem Aktionen eines 'Gegenspielers' abhängt. Dieser kann eine andere Person, aber auch 'der Markt' oder 'die Natur' sein ('Nehme ich heute einen Regenschirm mit?'). Man betrachtet dies als Spiel, das in vielen Runden gespielt wird. In jeder Runde treffen beide Spieler gleichzeitig ihre Entscheidung, und nach jeder Runde wird ein Gewinn ausgezahlt oder ein Verlust kassiert.

Beispiel 6.2.1 Betrachtet wird das Spiel:

Spieler P_1 wählt eine der Zahlen 1, 3 oder 5.
 Spieler P_2 wählt eine der Zahlen 0 oder 6

Nach jeder Runde bekommt Spieler P_2 von Spieler P_1 den Betrag der Differenz der beiden Zahlen zurück. Der Gewinn von Spieler 2 in Abhängigkeit von den genannten Zahlen ist also

$$\begin{array}{c|ccc} P_2 \backslash P_1 & 1 & 3 & 5 \\ \hline 0 & 1 & 3 & 5 \\ 6 & 5 & 3 & 1 \end{array}, \quad A := \begin{pmatrix} 1 & 3 & 5 \\ 5 & 3 & 1 \end{pmatrix}.$$

Die Auszahlungsmatrix A heißt auch Spielmatrix. Da der Gewinn des einen Spielers der Verlust des anderen ist, redet man von einem *Nullsummenspiel* oder *Matrixspiel*. Das Spiel ist natürlich

nicht *fair*, da nur Spieler P_2 gewinnt. Durch einen Einsatz von 3 Euro, den P_2 vor jeder Runde zahlen muß, läßt sich das aber ausgleichen. Die korrekte Höhe des erforderlichen Einsatzes ist ein wesentliches Resultat der Theorie. Die nennbaren Zahlen sind die möglichen *Aktionen* der Spieler. In der Regel macht eine *reine Strategie*, d.h. die feste Wahl einer Aktion, keinen Sinn, da der Gegner sich darauf einstellen und seinen eigenen Gewinn erhöhen kann. Interessant wird das Spiel bei einem zufälligen Wechsel der Aktionen, bei der Spieler P_1 die Aktion s_{1j} mit einer Wahrscheinlichkeit $x_j \geq 0$ und Spieler P_2 die Aktion s_{2i} mit Wahrscheinlichkeit $y_i \geq 0$ wählt.

Definition 6.2.2 *Ein Matrixspiel zwischen zwei Spielern P_1, P_2 besteht aus zwei Mengen von Aktionen $S_1 = \{s_{11}, \dots, s_{1n}\}$ für P_1 und $S_2 = \{s_{21}, \dots, s_{2m}\}$ für P_2 . Die Matrix $A \in \mathbb{R}^{m \times n}$ gibt den Gewinn an, wobei nach einer Spielrunde mit Aktionen s_{1i}, s_{2j} der Wert a_{ij} die Auszahlung an P_2 und $-a_{ij}$ die an P_1 ist. Ein Vektor $x \in \Delta_n$ bzw. $y \in \Delta_m$ heißt Strategie des Spielers P_1 bzw. P_2 .*

Arbeitet P_1 mit Strategie x und P_2 mit y , so ist der folgende Ausdruck der Erwartungswert

$$W = \sum_{i=1}^m \sum_{j=1}^n a_{ij} y_i x_j = y^\top A x, \quad \text{für den } \begin{cases} \text{Gewinn von } P_2, \\ \text{Verlust von } P_1. \end{cases}$$

Wählt P_1 eine Strategie $x \in \Delta_n$, dann hat er mit einer maximalen Attacke von P_2 zu rechnen, d.h., dem Verlust

$$\varphi(x) := \max\{y^\top A x : y \in \Delta_m\} = \max_{i=1}^m \sum_{j=1}^n a_{ij} x_j. \quad (6.2.1)$$

Die rechte Identität folgt aus der Ungleichung $\sum_i y_i v_i \leq (\sum_i y_i) \max_i v_i$, für $y_i \geq 0$. Umgekehrt müßte P_2 bei Wahl von $y \in \Delta_m$ mit einer Gegenstrategie rechnen, die ihm nur minimalen Gewinn

$$\psi(y) = \min\{y^\top A x : x \in \Delta_n\} = \min_{j=1}^n \sum_{i=1}^m y_i a_{ij} \quad (6.2.2)$$

erlaubt. Optimale Strategien \hat{x} für P_1 und \hat{y} für P_2 sind daher solche mit

$$\begin{aligned} v_1 &:= \varphi(\hat{x}) = \min\{\varphi(x) : x \in \Delta_n\} = \min_x \max_y y^\top A x, \\ v_2 &:= \psi(\hat{y}) = \max\{\psi(y) : y \in \Delta_m\} = \max_y \min_x y^\top A x. \end{aligned} \quad (6.2.3)$$

Die Existenz solcher Strategien ist aufgrund der Kompaktheit von Δ klar. Es folgt direkt $v_2 \leq v_1$, da mit $x \in \Delta_n, y \in \Delta_m$ gilt

$$v_2 = \psi(\hat{y}) = \min_x \hat{y}^\top A x \leq \hat{y}^\top A \hat{x} \leq \max_y y^\top A \hat{x} = \varphi(\hat{x}) = v_1.$$

In den Definitionen von φ und ψ (6.2.1), (6.2.2) wurden die Extrema in einem Einheitsvektor (Ecke von Δ) angenommen. Analog dazu kann man bei der globalen Betrachtung nach Extrema in Einheitsvektoren (reinen Strategien) suchen. An Stelle von (6.2.3) wird also betrachtet

$$\begin{aligned} w_1 &:= \min\{\varphi(x) : x \in E(\Delta_n)\} = \min_{j=1}^n \max_{i=1}^m a_{ij}, \\ w_2 &:= \max\{\psi(y) : y \in E(\Delta_m)\} = \max_{i=1}^m \min_{j=1}^n a_{ij}. \end{aligned} \quad (6.2.4)$$

Da hier bei der Extremwertbildung weniger Elemente berücksichtigt werden als in (6.2.3), gilt natürlich

$$w_2 \leq v_2 = v_1 \leq w_1.$$

Für Spiele, bei denen nun $w_2 = w_1$ gilt, sind daher alle Werte identisch, $w_2 = v_2 = v_1 = w_1$. Das Optimum für beide Spieler ist daher eine reine Strategie. Solche (recht uninteressanten Spiele) nennt man *Sattelpunktspiele*.

Beispiel 6.2.3 Beim Spiel mit

$$A = \begin{pmatrix} 3 & 1 & 4 \\ 2 & 0 & 1 \\ -1 & -2 & -2 \end{pmatrix}$$

ist $w_1 = \min_{j=1}^3 \max_{i=1}^3 a_{ij} = \min\{3, 1, 4\} = 1$ und $w_2 = \max_{i=1}^3 \min_{j=1}^3 a_{ij} = \max\{1, 0, -2\} = 1$. Es liegt ein Sattelpunktspiel vor und die optimale Strategie für Spieler P_1 ist $x^\top = (0, 1, 0)$, für P_2 ist sie $y^\top = (1, 0, 0)$.

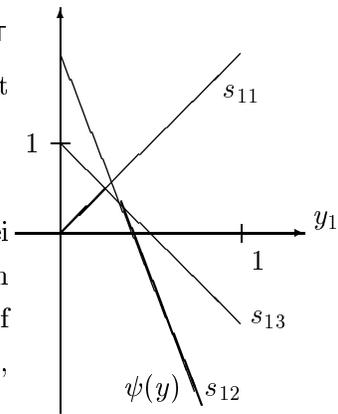
Beispiel 6.2.4 Beim Spiel

$P_2 \setminus P_1$	s_{11}	s_{12}	s_{13}
s_{21}	2	-3	-1
s_{22}	0	2	1

ist die Situation komplexer. Wenn P_2 mit der Strategie $(y_1, 1 - y_1)^\top$ arbeitet und P_1 mit der reinen Strategie s_{1k} , ist der Erwartungswert für P_2

$$W = y_1 a_{1k} + (1 - y_1) a_{2k}.$$

Dies entspricht den drei Geraden im Bild, das Minimum der drei entspricht $\psi(y)$. Für $y_1 = \frac{1}{2}$ etwa, könnte P_1 mit Wahl der Aktion s_{12} (auf Dauer) einen Gewinn erzielen $(-\frac{3}{2} + \frac{2}{2} = -0.5$ bezogen auf P_2). Bei $y_1 = 1/4$, am Schnitt der zu s_{11} und s_{13} gehörigen Geraden, ist dagegen der Gewinn für P_2 maximal, $v_2 = 1/2$.



Da diese beiden Aktionen P_2 am stärksten fordern, sollte P_1 eine Strategie der Form $x^\top = (x_1, 0, 1 - x_1)$ verwenden. Eine analoge Überlegung liefert $\hat{x}^\top = (\frac{1}{2}, 0, \frac{1}{2})$ mit $v_1 = \frac{1}{2} = v_2$.

Bei Sattelpunktspielen und im Beispiel stimmen der Erwartungswert für Verlust von P_1 und Gewinn von P_2 überein. Der folgende Hauptsatz der Matrixspiele besagt, dass dies allgemein der Fall ist.

Satz 6.2.5 Bei einem Matrixspiel sind die beiden Werte in (6.2.3) gleich, $v_1 = v_2$, diese Zahl

$$v := \min_x \max_y y^\top A x = \max_y \min_x y^\top A x, \quad (y \in \Delta_m, x \in \Delta_n).$$

heißt Wert des Spiels.

Beweis Die Behauptung folgt direkt aus dem Dualitätssatz 3.1.1, denn mit (6.2.1), (6.2.2) gehören zur Aussage die beiden Linearen Programme

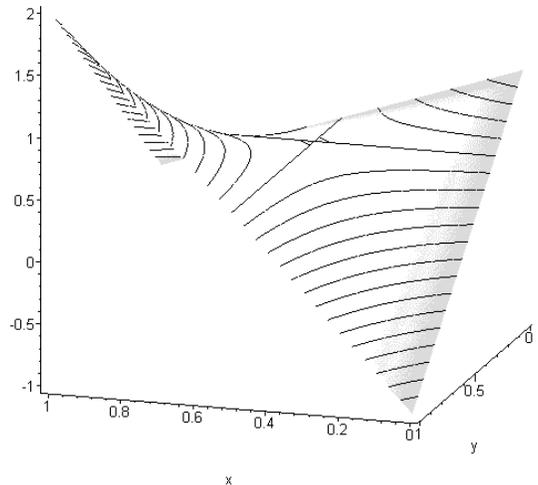
$$\begin{aligned} v_1 = \min \xi : & & v_2 = \max \eta : \\ \sum_{j=1}^n a_{ij} x_j - \xi \leq 0, \quad i = 1, \dots, m, & & \sum_{i=1}^n y_i a_{ij} - \eta \geq 0, \quad j = 1, \dots, n, \\ x \in \Delta_n & & y \in \Delta_m \end{aligned}$$

Die Variablen ξ, η sind freie Variable. Da die Programme zueinander dual sind (!) stimmen die Werte überein, $v_1 = v_2$. ■

Die Minimax-Charakterisierung der optimalen Strategien \hat{x}, \hat{y} kann mit der Funktion $F(x, y) = y^T A x$ auch folgendermaßen ausgedrückt werden:

$$F(\hat{x}, y) \leq F(\hat{x}, \hat{y}) = v \leq F(x, \hat{y}).$$

Dies bedeutet geometrisch, dass der Punkt (\hat{x}, \hat{y}) ein *Sattelpunkt* der Funktion F ist, wo es in x -Richtung aufwärts und in y -Richtung abwärts geht. Das Bild zeigt diese Funktion für die Matrix aus Beispiel 6.2.4 bei Strategien der Form $(y_1, 1 - y_1), (x_1, 0, 1 - x_1)$.



Mit dem Hauptresultat läßt sich der Begriff *Fairness* präzisieren, der die Bevorzugung eines Spielers ausschließt. Ein Spezialfall sind Spiele, bei denen beide Spiel-Seiten austauschbar sind.

Definition 6.2.6 Ein Matrixspiel heißt fair, wenn sein Wert $v = 0$ ist. Ein Spiel heißt symmetrisch, wenn $S_1 = S_2$ gilt und $A = -A^T$ schiefsymmetrisch ist.

Ein unfaires Spiel kann durch den Einsatz v des begünstigten Spielers fair gemacht werden, alle Matrixeinträge werden dann um $-v$ geändert. Ein symmetrisches Spiel ist fair, beide Spieler haben die gleiche Optimalstrategie. Die Schiefsymmetrie von A bedeutet u.a., dass es bei einem Patt ($s_{1i} = s_{2j}$) keine Auszahlung gibt, $a_{ii} = 0$.

Bei unsymmetrischen Spielen ist die Fairness dagegen nicht offensichtlich und muss durch Lösen eines Linearen Programms geprüft werden. Hier kann der erste Eindruck sogar irreführend sein.

Beispiel 6.2.7 (Skin-Spiel) Spieler P_1 bekommt die Karten Herz As, Kreuz As, Kreuz 2, $S_1 = \{H1, K1, K2\}$, Spieler P_2 die Karten Herz As, Kreuz As, Herz 2, $S_2 = \{H1, K1, H2\}$. Pro Runde wird eine Karte gelegt und es gewinnt P_2 den eigenen Kartenwert wenn die Farben gleich sind, ansonsten P_1 den seinen. Die Auszahlungsmatrix des Spiels ist also

$$\begin{array}{c|ccc} P_2 \backslash P_1 & H1 & K1 & K2 \\ \hline H1 & 1 & -1 & -2 \\ K1 & -1 & 1 & 1 \\ H2 & 2 & -1 & -2 \end{array} \quad (6.2.5)$$

Da die Zahl der negativen Einträge (und ihre Betragssumme) größer ist als die der positiven, erhebt sich der Verdacht, dass das Spiel unfair ist. Diese Schieflage kann durch Streichen des Eintrags bei H2-K2 mit der Matrix

$$A = \begin{pmatrix} 1 & -1 & -2 \\ -1 & 1 & 1 \\ 2 & -1 & 0 \end{pmatrix}$$

beseitigt werden. Allerdings zeigt die Analyse das Gegenteil: das ursprüngliche Spiel (6.2.5) ist fair, das 'nachgebesserte' dagegen nicht.

Zur Bestimmung von Spielwert und optimaler Strategie können die Programme aus dem Beweis von Satz 6.2.5 vereinfacht werden. Die Zusatzvariablen ξ, η lassen sich unter der Annahme eliminieren, dass der Spielwert v positiv ist. Letzteres läßt sich durch Addition einer konstanten Auszahlung zu allen Matrixelementen erreichen, z.B. so, dass gilt

$$\min_{i,j} a_{ij} > 0.$$

Durch Übergang zu den Variablen $u := x/\xi, z := y/\eta$ bekommt man etwa die Bedingung $Au = (Ax)/\xi \leq \mathbf{1}$ und $\mathbf{1}^T u = 1/\xi$. Dies führt auf die beiden Programme

$$\max \mathbf{1}^T u, \quad Au \leq \mathbf{1}, \quad u \geq 0, \quad (6.2.6)$$

$$\min \mathbf{1}^T z, \quad A^T z \geq \mathbf{1}, \quad z \geq 0, \quad (6.2.7)$$

die wieder ein duales Paar bilden. Das erste, (6.2.6) ist in Standardform (LP2), nach Einführung von Schlupfvariablen hat man wegen $b = \mathbf{1} \geq 0$ auch eine primale Startbasis.

Im **Beispiel 6.2.7** hat man nach Addition des Wertes 3 in allen Einträgen das Tableau

$$\begin{array}{c|cccccc} 0 & 1 & 1 & 1 & 0 & 0 & 0 \\ \hline 1 & 4 & 2 & 1 & 1 & 0 & 0 \\ 1 & 2 & 4 & 4 & 0 & 1 & 0 \\ 1 & 5 & 2 & a & 0 & 0 & 1 \end{array}$$

wobei $a = 1$ im ursprünglichen Spiel (6.2.5) ist und $a = 3$ mit Zusatzregel. Im ersten Fall liefert das Simplexverfahren nach 3 Schritten das Optimum $u^T = (\frac{1}{6}, 0, \frac{1}{6})$ mit Wert $\mathbf{1}^T u = \frac{1}{3} = 1/\xi$. Da das Spiel gerade um diesen Wert $\xi = 3$ geändert wurde, ist das ursprüngliche Spiel (6.2.5) fair mit Strategie $\hat{x}^T = (\frac{1}{2}, 0, \frac{1}{2})$ für Spieler P_1 . Für $a = 3$ bekommt man $u^T = (\frac{1}{8}, \frac{3}{16}, 0)$ mit Wert $\mathbf{1}^T u = \frac{5}{16} = 1/\xi$. Hier ist der Wert des Ausgangsspiels $v = \xi - 3 = \frac{1}{5} > 0$, die optimale Strategie für P_1 ist $x^T = \xi u^T = (\frac{2}{5}, \frac{3}{5}, 0)$, aber P_2 kann mit Strategie $y^T = (0, \frac{3}{5}, \frac{2}{5})$ auf Dauer einen Gewinn erwarten.

Abschließende Bemerkungen: Matrix-Spiele gehören zur Klasse der reinen Konfrontationsspiele. Für diese ist also eine geschlossene Analyse und die Bestimmung der optimalen Strategien möglich. Verblüffend ist dabei insbesondere, dass die Spieler selbst bei Kenntnis der gegnerischen

Strategie das Optimum nicht ändern können. Wenn mehrere Spieler teilnehmen oder beide Spieler durch Teilnahme einen Aktions-abhängigen Gewinn erzielen können, steigt der Anreiz zur Kooperation. In unterschiedlichen Varianten werden kooperative Spiele zur Modellierung des Handel(n)s in der Ökonomie verwendet.

6.3 Transportprobleme in Graphen

Da diese Probleme gelegentlich als Beispiele diskutiert wurden, wird noch kurz auf einige der speziellen Strukturen eingegangen die sich im Zusammenhang mit Graphen ergeben. Von allgemeinerem Interesse, über die Optimierung hinaus, sind Querverbindungen zwischen Graphentheorie und Linearer Algebra.

Definition 6.3.1 Ein Graph $G = G(P, L)$ besteht aus einer Menge $P = P(G) \neq \emptyset$ von Ecken (Punkten) und einer von Kanten (Linien) $L = L(G)$. Kanten eines allgemeinen Graphen sind ungeordnete Paare $\{u, v\}$, $u, v \in P$. In einem gerichteten Graphen (Digraph) betrachtet man Kanten als Paare $k = (u, v)$ mit dem Anfangsknoten u und Endknoten v von k .

Die Bezeichnungen P, L sind etwas unüblich, die am Englischen angelehnten Bezeichnungen führen aber leicht zu Verwechslungen (Ecken/edges, Kanten/knots). Der Zusammenhang zwischen Kanten und Ecken kann auch durch eine *Inzidenz*-Abbildung

$$\delta : L \rightarrow P \times P, \quad k \mapsto \delta(k) = \{u, v\},$$

beschrieben werden. Im Digraph bezieht sich das auch auf Anfangs- und Endpunkte:

$$\alpha : \left\{ \begin{array}{l} L \rightarrow P \\ k = (u, v) \mapsto u \end{array} \right., \quad \omega : \left\{ \begin{array}{l} L \rightarrow P \\ k = (u, v) \mapsto v \end{array} \right., \quad \delta : \left\{ \begin{array}{l} L \rightarrow P \times P \\ k \mapsto (\alpha(k), \omega(k)) \end{array} \right. .$$

Es werden nur endliche Graphen betrachtet mit $P = \{p_1, \dots, p_m\}$ (z.B. $p_i = i \in \mathbb{N}$) und $L = \{k_1, \dots, k_n\}$. Da gerichtete Graphen den allgemeineren Fall darstellen, wird dieser in den Vordergrund gestellt. In der allgemeinen Form sind in einem Graphen auch parallele Kanten $k, l \in L$ mit $\alpha(k) = \alpha(l)$, $\omega(k) = \omega(l)$ und *Schlingen* k mit $\alpha(k) = \omega(k)$ zugelassen. Ein Graph heißt *schlicht*, wenn er keine Schlingen oder parallelen Kanten enthält, dann kann man insbesondere $L \subseteq P \times P$ betrachten und die Kanten durch ihre Ecken bezeichnen.

Bezogen auf die Ecken sind die aus- und eingehenden Kanten interessant, für $u \in P$ sei

$$\begin{aligned} L^+(u) &:= \{k \in L : \alpha(k) = u\}, & g^+(u) &:= |L^+(u)|, \\ L^-(u) &:= \{k \in L : \omega(k) = u\}, & g^-(u) &:= |L^-(u)|, \end{aligned}$$

sowie $L(u) = L^-(u) \cup L^+(u)$, $g(u) = g^-(u) + g^+(u)$. Die Zahl $g^+(u)$ der auslaufenden Kanten aus $L^+(u)$ heißt Außengrad der Ecke u , $g^-(u)$ der Innengrad, die Summe $g(u)$ der Grad von u .

Eine Ecke vom Grad $g(u) = 0$ heißt isoliert. Bei schlichten Graphen können statt der Menge $L(u)$ direkt die *Nachbarn* einer Ecke u betrachtet werden,

$$N^+(u) = \{\omega(k) : \alpha(k) = u\}, \quad N^-(u) = \{\alpha(k) : \omega(k) = u\},$$

$N(u) = N^-(u) \cup N^+(u)$. Der Grad beschreibt die Stärke der 'Vernetzung' einer einzelnen Ecke. Um die Vernetzung des Gesamt-Graphen untersuchen zu können, betrachtet man Wege und Kantenzüge im Graphen. Die Begriffe unterscheiden sich darin, ob dabei Kanten nur längs ihrer Richtung benutzt werden dürfen. In einem ungerichteten Graphen sind beide Begriffe gleich. Ein *Weg* w ist eine alternierende Folge von Ecken und Kanten:

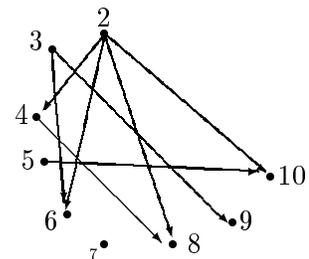
$$w = (p_{i_0}, k_{j_1}, p_{i_1}, \dots, k_{j_r}, p_{i_r}), \quad \text{mit } \delta(k_{j_\ell}) = (p_{i_{\ell-1}}, p_{i_\ell}).$$

Dabei ist r die Länge, p_{i_0} Anfangs- und p_{i_r} Endecke von w . Ein geschlossener Weg mit $p_{i_0} = p_{i_r}$ heißt *Kreis*. In einem schlichten Graphen genügt es, die Ecken des Weges anzugeben. Ein *Kantenzug* z (Kette) unterscheidet sich dadurch vom Weg, dass beliebig orientierte Kanten auftreten können,

$$z = (p_{i_0}, k_{j_1}, p_{i_1}, \dots, k_{j_r}, p_{i_r}), \quad \text{mit } \delta(k_{j_\ell}) \in \{(p_{i_{\ell-1}}, p_{i_\ell}), (p_{i_\ell}, p_{i_{\ell-1}})\}.$$

Ein geschlossener Kantenzug, bei dem alle Kanten verschieden sind, heißt *Zyklus*. Ein Graph heißt *zusammenhängend*, wenn zwischen je zwei Ecken $u, v \in P$ ein sie verbindender Kantenzug existiert. Wenn der Graph dies in Bezug auf Wege erfüllt, heißt er *stark zusammenhängend*.

Beispiel 6.3.2 Der nebenstehende Digraph mit $m = 9$ Ecken und $n = 8$ Kanten beschreibt die Teilbarkeitsrelation der natürlichen Zahlen bis 10. Er ist schlicht (daher keine Kantenbezeichner nötig), aber offensichtlich nicht zusammenhängend, da 7 isoliert ist. Ohne die Ecke 7 ist er zusammenhängend, aber nicht stark zusammenhängend. Denn der einzige nichttriviale Weg geht über die Ecken (2, 4, 8). Zur Eckenfolge (2, 4, 8, 2) gehört ein geschlossener Kantenzug, der der einzige Zyklus des Graphen ist.



Ein *Baum* ist ein zusammenhängender, zyklenfreier Graph. Von besonderem Interesse in der Informatik und hier sind Bäume, da sie die 'sparsamste' Form von (Teil-) Graphen darstellen und Grundlage vieler Algorithmen sind. Ein Graph $G(P, M)$ mit $M \subseteq L$ heißt *Teilgraph* von $G(P, L)$, enthält also alle Ecken, aber nur einen Teil der Kanten.

Satz 6.3.3 a) Ist $G(P, L)$ ein Baum, dann gilt $|L| = |P| - 1$.

b) Jeder zusammenhängende Graph $G(P, L)$ besitzt einen aufspannenden Baum, d.h. einen Teilgraphen $G(P, M)$, $M \subseteq L$, der ein Baum ist.

Im Teilbarkeitsgraphen (ohne 7) bekommt man durch Streichung einer Kante des Zyklus (2, 4, 8, 2) einen aufspannenden Baum mit $|M| = 7 = |P| - 1$. Wichtige Zusammenhänge zur Linearen Algebra ergeben sich durch Betrachtung bestimmter, den Graphen zugeordneter Matrizen.

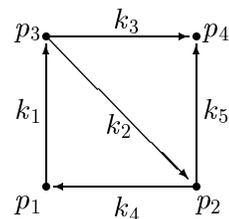
Die *Inzidenzmatrix* $A = A(G) \in \mathbb{R}^{m \times n}$ eines schlingenfreien Graphen mit $P = \{p_1, \dots, p_m\}$, $L = \{k_1, \dots, k_n\}$ ist definiert durch

$$A = (a_{ij}), \quad a_{ij} = \begin{cases} 1 & \text{für } p_i = \alpha(k_j), \\ -1 & \text{für } p_i = \omega(k_j), \\ 0 & \text{sonst.} \end{cases}$$

Auf ähnliche Weise kann auch eine quadratische *Adjazenzmatrix* (Nachbarschaftsmatrix) im $\mathbb{R}^{m \times m}$ definiert werden. Diese spielt beim Transportproblem aber keine Rolle.

Beispiel 6.3.4 Die Inzidenzmatrix zum gezeigten Graphen ist

$$A = \begin{pmatrix} 1 & 0 & 0 & -1 & 0 \\ 0 & -1 & 0 & 1 & 1 \\ -1 & 1 & 1 & 0 & 0 \\ 0 & 0 & -1 & 0 & -1 \end{pmatrix}.$$



Offensichtlich hat jede Spalte genau zwei nichttriviale Einträge, für eine Kante mit $\delta(k_j) = (p_\alpha, p_\omega)$ ist $a_j = e_\alpha - e_\omega$. Daher sind alle Spaltensummen null, $\mathbb{1}^\top A = 0^\top$ und der Rang von A ist daher höchstens $|P| - 1$. In Zeile i sind die bei der Ecke p_i aus- und einlaufenden Kanten markiert. Die Inzidenzmatrix hat aber noch mehr interessante Eigenschaften.

Satz 6.3.5 Bei einem schlingenfreien, gerichteten Graph G ist die Inzidenzmatrix $A(G)$ total unimodular, d.h., für jede quadratischen Untermatrix hat die Determinante einen Wert aus $\{-1, 0, 1\}$.

Als Folge der Cramerschen Regel ist bei einer total unimodularen Matrix die Inverse einer jeden regulären Untermatrix ganzzahlig.

Satz 6.3.6 Es sei $G(P, L)$ ein schlichter Digraph mit Inzidenzmatrix $A = (a_1, \dots, a_n)$. Zu einem Teilgraph $G(P, M)$, $M \subseteq L$, sei $B = \{a_j : k_j \in M\}$ die entsprechende Untermatrix. B hat maximalen Rang genau dann, wenn der Teilgraph $G(P, M)$ keine Zyklen enthält. Insbesondere hat B Rang $|P| - 1$ genau dann, wenn $G(P, M)$ ein aufspannender Baum ist. Bew

Die zu einem Teilgraphen gehörige Untermatrix hat wegen $\mathbb{1}^\top B = 0^\top$ linear abhängige Zeilen. Durch Streichen einer beliebigen Zeile von B ergibt sich bei einem aufspannenden Baum aber eine reguläre, quadratische Matrix der Größe $|P| - 1$.

Im Beispiel 6.3.4 erhält man mit $M = \{k_2, k_3, k_4\}$ einen aufspannenden Baum. Die zugehörige Matrix B hat vollen Rang drei. Denn nach Streichen ihrer letzten Zeile bekommt man eine reguläre Matrix mit Determinante 1.

$$B = \begin{pmatrix} 0 & 0 & -1 \\ -1 & 0 & 1 \\ 1 & 1 & 0 \\ 0 & -1 & 0 \end{pmatrix}.$$

Transportproblem Der Graph $G(P, L)$ besitze zusätzlich eine Bewertung $b \in \mathbb{R}^m$ der Ecken und $c \in \mathbb{R}^n$ der Kanten. Die Ecke p_i nennt man für $b_i > 0$ eine Quelle, für $b_i < 0$ eine Senke und für $b_i = 0$ ein Umschlagplatz. Es wird (ohne wesentl. Einschränkung) $\sum_{i=1}^m b_i = 0$ vorausgesetzt. Die Zielkoeffizienten $c_j \leq 0$ werden als Kosten für den Transport längs Kante k_j negativ notiert. Für den Vektor x der kostenminimalen Transporte $x_j \geq 0$ längs Kante k_j können das primale und duale Programm direkt angegeben werden:

$$\max\{c^\top x : Ax = b, x \geq 0\} \quad \text{und} \quad \min\{b^\top y : A^\top y \geq c\}.$$

Dabei ist $A \in \mathbb{R}^{m \times n}$ die *Inzidenzmatrix* von G . Denn in Zeile i bedeutet die Restriktion $Ax = b$ gerade, dass die Summe der aus Ecke p_i herausgehenden und hineinfließenden Mengen der Bewertung b_i (Bedarf) entspricht (Kirchhoffsche Regel). Die dualen Variablen y_i sind den Ecken zugeordnet.

Aufgrund von Satz 6.3.6 sind die Basen A_J von A gerade durch aufspannende Bäume des Graphen gegeben, insbesondere ist auch der optimale Transportplan ein Baum. Der Basiswechsel entspricht dem Übergang zu einem anderen Baum. Das Simplexverfahren kann daher direkt mit diesen Bäumen arbeiten, wenn sich die dabei benötigten Hilfsgrößen leicht bestimmen lassen. Dies gilt insbesondere bei ganzzahligem Bedarf $b \in \mathbb{Z}^m$ ($\Rightarrow x \in \mathbb{Z}^n$).

- Die Basislösung \bar{x} zu einem Baum kann von den Blättern (Ecken vom Grad $g(u) = 1$) her bestimmt werden, da die Versorgung eines Blattes vollständig durch die hin-/herlaufende Kante erfolgen muß vgl. Beisp. 6.3.7.
- Der Gewinnvektor ist $\gamma^\top = c^\top - y^\top A$. Seine J -Komponenten verschwinden, $\gamma_J = 0$, und definieren die duale Lösung y , vgl. (5.0.1). Der Wert y_i ist der Schattenpreise des Bedarfs im Knoten p_i . Für eine Kante mit $\delta(k_j) = (p_\alpha, p_\omega)$ ist nach Def. $a_j = e_\alpha - e_\omega$ und daher

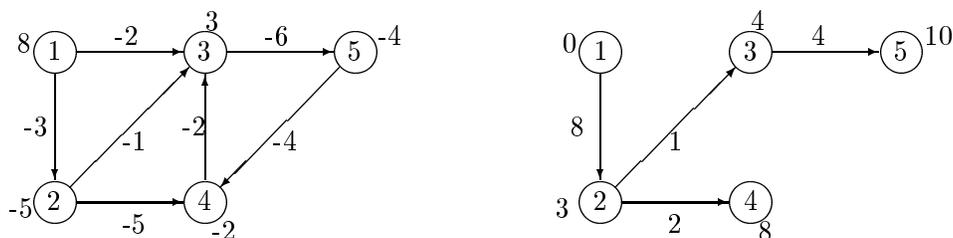
$$\gamma_j = c_j - y_\alpha + y_\omega.$$

Für Indizes in $j \in J$ (Kanten im Baum) dienen diese Gleichungen $\gamma_j = 0$ zur Berechnung der dualen Lösung. Da $\mathbb{1}$ den Kern von A^\top aufspannt, kann eine Komponente von y auf null gesetzt werden, etwa $y_1 = 0$. Von der zugehörigen Ecke p_1 aus werden dann mit den Kanten des Baums $G(P, M)$ die y -Werte aller Ecken bestimmt. Mit diesem y sucht man dann einen positiven Wert $\gamma_\ell > 0$, $\ell \in K = \{1, \dots, n\} \setminus J$ auf den Kanten $\notin M$. Für $\gamma_K \leq 0$ liegt natürlich ein Optimum vor.

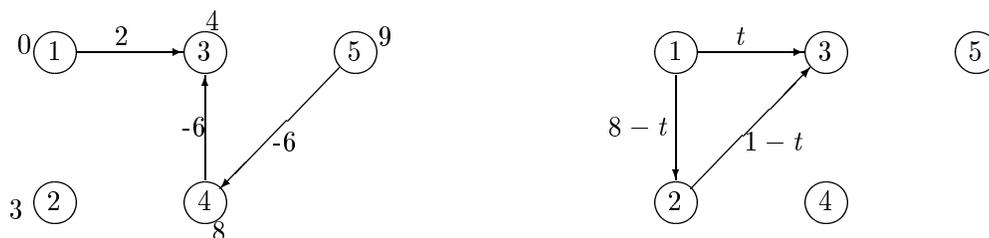
- Durch Aufnahme der Kante k_ℓ in den Baum entsteht ein eindeutiger Zyklus. Erhöht man analog zu (4.2.5) den Transport längs k_ℓ auf $x_\ell = t > 0$, ändern sich der Transport auf allen Kanten dieses Zyklus ebenfalls um den Betrag t (um $+t$ auf Kanten in Richtung k_ℓ , um $-t$ bei gegenläufigen Kanten). Der maximal einsetzbare Wert t_ℓ ist daher der minimale Wert \bar{x}_i aller *gegenläufigen* Kanten.

Probleme wie Anlaufrechnung oder ausgeartete Ecken lassen sich ebenfalls analog zum allgemeinen Fall lösen.

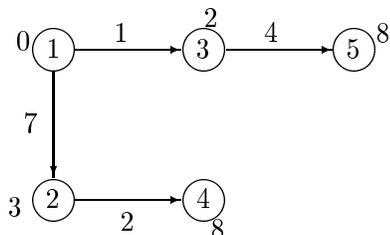
Beispiel 6.3.7 Das erste Bild zeigt das betrachtete Transportproblem mit 5 Ecken und 7 Kanten, wobei die Werte von b bei den Ecken und die von c bei den Kanten notiert sind. Rechts ist ein aufspannender Baum gezeigt. Bei ihm sind an den Kanten die Transporte x_j und an den Ecken die Schattenpreise y_i (duale Variable) angegeben.



Mit den Schattenpreisen werden die reduzierten Gewinne an den restlichen Kanten bestimmt (unten linkes Bild). Dabei ist nur $\gamma_{13} = c_{13} - y_1 + y_3 = 2$ an Kante 1-3 positiv (die Kante wird hier durch Doppelindex bezeichnet). Nimmt man diese Kante dazu mit einem Transport $x_{13} = t > 0$, entsteht ein Zyklus (2,3,1,2), in dem die anderen Transporte um t geändert werden müssen, damit der Bedarf überall erfüllt bleibt.



Offensichtlich ist $t \leq 1$ zu wählen, weil dann der Transport x_{23} verschwindet. Die Kante 2-3 kann daher entfernt werden, der folgende neue Baum (mit Transporten und Schattenpreisen) ergibt den optimalen Transportplan.



Schlußbemerkung: Über lange Jahre war das Simplex-Verfahren konkurrenzlos und in der Praxis sehr erfolgreich, obwohl die Frage der Laufzeit nicht geklärt war (vgl. §4.3). Die zum Beweis von Laufzeit-Aussagen dienenden Ellipsoid-Verfahren sind bisher keine überzeugende Alternative. Dagegen sind Innere-Punkte-Verfahren im Kommen, erfordern aber weitergehende Hilfsmittel aus der Numerik (Lösung nichtlinearer Gleichungssysteme).

A Symbole, Abkürzungen

Symbole

		Seite
$\mathbf{1}$	Vektor von Einsen $\mathbf{1} = (1, \dots, 1)^\top$	10
$\text{aff}(M)$	affine Hülle einer Menge M	10
arg min	Argumentwert in einer Minimalstelle	13
\mathbb{B}	boolesche Menge $\mathbb{B} = \{0, 1\}$	2
$B_r(z)$	Kugel um z mit Radius r	2
Δ_n	Standardsimplex $\Delta_n = \{x \in \mathbb{R}^n : \mathbf{1}^\top x = 1, x \geq 0\}$	12
$E(M)$	Menge der Ecken einer konvexen Menge M	15
e_i	Einheitsvektoren	10
$\text{konus}(M)$	konische Hülle einer Menge M , von M erzeugter Kegel	18
$\text{konv}(M)$	konvexe Hülle einer Menge M	12
$H(a, \alpha)$	Hyperebene mit Normalenrichtung $a \neq 0$	10
H^+, H^-	offener Halbraum in (bzw. entgegen) Normalenrichtung	10
H^\oplus, H^\ominus	entsprechende abgeschlossene Halbräume	10
$L(M)$	Linealraum einer Menge M	11
(LP1)..(LP3)	Standardformen linearer Programme	8
(LP*), (LP i^*)	duale Programme	24
$O^+(M)$	Ausdehnungskegel einer konvexen Menge M	19
p_M	Projektion $p_M : \mathbb{R}^n \rightarrow M$ auf eine konvexe Menge M	13
\mathbb{R}_+^n	positiver Kegel $\mathbb{R}_+^n = \{x \in \mathbb{R}^n : x \geq 0\}$	10

Bezeichnungen

Zu Mengen $M \subseteq \mathbb{R}^n$, Matrizen $A \in \mathbb{R}^{m \times n}$, Vektoren $x, y \in \mathbb{R}^n$ wurden eingeführt:

$\bar{M}, \overset{\circ}{M}$	Abschluß und Inneres	
M^*	Polarkegel	20
$[x, y]$	Verbindungsstrecke von Punkten	11
$J(x), J^\pm(x)$	Stützindizes von x : der x_i , die nicht null, bzw. positiv/negativ	33
x_J	Teilvektor $x_J = (x_{j_1}, \dots, x_{j_k})^\top$ zu Indexmenge $J = \{j_1, \dots, j_k\} \subseteq \{1, \dots, n\}$	17
$A^{(J)}$	Untermatrix aus Zeilenvektoren $a^{(j)\top} = e_j^\top A$ zu Indexmenge $J \subseteq \{1, \dots, m\}$	17
A_J	Untermatrix aus Spaltenvektoren $a_j = A e_j$ zu Indexmenge $J \subseteq \{1, \dots, n\}$	33
H, \bar{H}	einfaches und erweitertes Simplex-Tableau, H und $A_J^{-1}A$ enthalten die gleichen Elemente, die Zeilenindizes von H sind aber $1, \dots, m$	39

Index

- Ausdehnungskegel, 19–22, 35
- ausgeartet, 34, 35, 39
- Ausschlußregel, 53

- baryzentrisch, 17
- Basis, 34
 - Darstellung, 34
 - Lösung, 34
- Baum, 60
 - aufspannend, 60, 61
- Block-Elimination, 32
- Brachistochrone, 1

- Digraph, 59

- Ecke, 15–18, 21, 33
- Einheitssimplex, 12
- elementare Umformungen, 9
- Ellipsoid, 52

- Facette, 15
- Farkas - Lemma, 22, 25, 52

- ganzzahlig, 2, 5, 7, 50
- Gauß-Algorithmus, 29, 30
- Graph, 59

- Hülle
 - affine, 10, 19
 - konische, 18
 - konvexe, 12
- Halbraum, 10
- Handlungsreisender (TSP), 5
- Hyperebene, 10

- inkonsistent, 25, 26, 42
- Inzidenzmatrix, 61, 62

- Kante, 15, 21, 35
- Kegel, 9, 10, 34
 - erzeugter, 19–21, 27
 - konvex, 18
 - Polar-, 20
 - spitz, 18, 19, 21
- kleinste-Index-Regel, 44, 47
- Kombination
 - konisch, 11, 18, 27
 - konvex, 11
- konvex
 - Hülle, 12
 - Kombination, 11
 - Menge, 11
- Kreisen, Simplex-Verfahren, 39, 43
- Kuhn-Tucker, Satz, 52

- Linealraum, 11, 18, 19
- LR-Zerlegung, 30, 31, 37, 47
 - Anpassung, 31

- Matrix-Spiel, 54

- Nachbarecke, 36
- Normalenvektor, 10

- Optimalität, 25
- Optimierungsaufgabe, 1
 - quadratische, 52
- orthogonal
 - strukturell, 26

- parametrische Optimierung, 48
- Permutation, 5, 31
- Permutations-Matrix, 31
- Pivot-Element, 30
- Polarkegel, 20–22
- Polyeder, 9, 17, 21
- Polytop, 17, 21
- Produktionsplanung, 3, 28
- Programm
 - duales, 24
 - lineares, 8, 24

- primales, 24
- Projektion, 13
- Randfläche, 15, 16
- Rang-1-Änderung, 29, 36, 40
- reduzierte Gewinne, 35, 45
- Regression, 51
- Relaxation, 7
- Rundungsfehler, 29
- Sattelpunkt, 57
- Schattenpreis, 28
- Schlupf
 - Variable, 9
 - komplementär, 27
- Schnittebene, 50
- Schur-Komplement, 32
- Schwerpunkt, 17
- Simplex, 17
- Simplex-Verfahren
 - duales, 46, 49, 50
 - primales, 37, 48, 49
 - revidiertes, 37
 - Tableau-, 40
- Spiel
 - Matrix, 54
 - Wert, 56
 - fair, 57
- Stütz-
 - Ebene, 14
 - Indizes, 33
 - Menge, 14
- Strafffunktion, 42
- Strahl, 35, 46
- Strategie, 55
 - optimale, 58
- Tour, 5
- Transportproblem, 5, 28, 41, 62
- TSP, 5, 51
- Ungleichung
 - zulässige, 14
- Variable
 - freie, 8, 24
 - vorzeichenbeschränkte, 8, 24
- Zeilenvertauschungen, 31
- Zielfunktion, 1–4, 21, 25–27, 35, 36, 39, 42,
 - 46, 48, 49, 52
- Zyklus, 60, 62