


# Lineare und Nichtlineare Optimierung

Skript: Dipl.-Math. Petra Schuster-Gentes

UNIV.-PROF. DR. THOMAS SCHUSTER



Universität des Saarlandes

2022



---

## Inhaltsverzeichnis

<b>1</b>	<b>Anwendungen und Einteilung von Optimierungsaufgaben</b> . . . . .	<b>3</b>
<b>2</b>	<b>Lineare Optimierung, 1. Teil: Das Simplexverfahren</b> . . . . .	<b>7</b>
2.1	Lineare Programme und geometrische Grundlagen . . . . .	7
2.2	Der Simplex – Algorithmus . . . . .	15
<b>3</b>	<b>Optimalität und Dualität</b> . . . . .	<b>23</b>
3.1	Optimalitätsbedingungen . . . . .	23
3.2	Dualität . . . . .	33
<b>4</b>	<b>Lineare Optimierung II: Innere – Punkte – Methoden</b> . . . . .	<b>39</b>
<b>5</b>	<b>Nichtlineare Optimierung I: Nichtrestringierte Probleme</b> . . . . .	<b>45</b>
5.1	Abstiegsmethoden . . . . .	45
5.2	Trust – Region – Verfahren . . . . .	48
5.3	Nichtlineare Ausgleichsprobleme: Gauß– Newton – Verfahren . . . . .	50
<b>6</b>	<b>Nichtlineare Optimierung II: Restringierte Optimierungsaufgaben:</b> . . . . .	<b>53</b>
6.1	Penalty – Methoden . . . . .	53
6.2	Barriere – Methoden . . . . .	55
6.3	Multiplier – Penalty – Methoden . . . . .	56
6.4	SQP-Verfahren . . . . .	58
6.4.1	Das Newton-Verfahren (reloaded) . . . . .	58
6.4.2	Lagrange-Newton-Iteration . . . . .	62
6.4.3	Das (lokale) SQP-Verfahren . . . . .	65
<b>7</b>	<b>Nichtglatte Optimierung</b> . . . . .	<b>69</b>
7.1	Lagrange – Dualität . . . . .	69
7.2	Das konvexe Subdifferential . . . . .	73
7.3	Die Subgradientenmethode . . . . .	79
7.4	Schnittebenenmethoden . . . . .	83
7.5	Bundle-Methoden . . . . .	86



---

## Literatur

F.Jarre, J.Stoer: *Optimierung*, Springer, 2004

C.Geiger, C.Kanzow: *Theorie und Numerik restringierter Optimierungsaufgaben*, Springer, 2002

Ch.Großmann, J.Terno: *Numerik der Optimierung*, Teubner, 2. Auflage, 1997

P.Spellucci: *Numerische Verfahren der nichtlinearen Optimierung*, Birkhäuser, 1993

J.Nocedal, S.J.Wright: *Numerical Optimization*, 2nd Edition, Springer, 2006

M.Papageorgiou, M.Leibold, M.Buss: *Optimierung*, 3.Auflage, Springer, 2012

J.M.Borwein, A.S.Lewis: *Convex Analysis and Nonlinear Optimization*, 2nd Edition, Springer, 2010

R.T.Rockafellar: *Convex Analysis*, Princeton University Press, 1970



## Anwendungen und Einteilung von Optimierungsaufgaben

### Beispiele für Optimierungsaufgaben:

a) (Schulmathematik)

Finde das Rechteck mit maximalem Flächeninhalt, so dass der Umfang  $U = 10m$  beträgt.

Also:

$$\max f(x, y) = x \cdot y$$

unter der Nebenbedingung

$$U(x, y) = 2x + 2y = 10.$$

b) (Analysis II) Lagrange – Multiplikator

Bestimme die lokalen Extrema der Funktion  $f(x, y) = 4x^2 - 3xy$  auf dem Einheitskreis.

Das heißt:

$$\min(\max)f(x, y)$$

unter der Nebenbedingung

$$g(x, y) = x^2 + y^2 - 1 = 0.$$

**Lösung:** Für eine Lösung  $(x^*, y^*)$  gilt:

$$\nabla f(x^*, y^*) = \lambda \nabla g(x^*, y^*)$$

wobei  $\lambda \in \mathbb{R}$  ein Lagrange – Multiplikator ist.

Zu lösen ist also

$$\left\{ \begin{array}{l} 8x^* - 3y^* = \lambda 2x^* \\ -3x^* = \lambda 2y^* \\ (x^*)^2 + (y^*)^2 - 1 = 0 \end{array} \right\}$$

Ergebnis:  $\lambda = -\frac{1}{2}$  oder  $\lambda = \frac{9}{2}$ .

i) Zu  $\lambda = -\frac{1}{2}$  ergeben sich die Lösungen

$$(x^*, y^*) = \left( \pm \frac{1}{\sqrt{10}}, \pm \frac{3}{\sqrt{10}} \right).$$

ii) Zu  $\lambda = \frac{9}{2}$  erhalten wir

$$(x^*, y^*) = \left( \mp \frac{3}{\sqrt{10}}, \pm \frac{1}{\sqrt{10}} \right).$$

Im Falle  $i$ ) ist

$$f(x^*, y^*) = -\frac{1}{2} \Rightarrow \text{lokales Minima auf dem Einheitskreis}$$

Im Falle  $ii$ ) ist

$$f(x^*, y^*) = \frac{9}{2} \Rightarrow \text{lokales Maxima auf dem Einheitskreis}$$

c) Angebotsauswertung

Ein Unternehmen will eine bestimmte Menge  $M$  eines Gutes einkaufen und holt Angebote von  $n$  Lieferfirmen ein, von denen keine die gewünschte Gesamtmenge liefern kann.

Annahme: Anbieter  $i$  liefert  $x_i$  Stück zum Preis  $f_i(x_i)$  wobei  $x_i$  die bestellte Stückzahl ist.


Die zu lösende Aufgabe ist demnach

$$\min f(x) := \sum_{i=1}^n f_i(x_i)$$

$$\text{u.d.N.} \quad \sum_{i=1}^n x_i = M, \quad 0 \leq x_i \leq \max_i, \quad i = 1, \dots, n$$

d) Design der Nase eines Flugzeugs

Zu entwerfen ist die Nase eines Flugzeuges mit dem Ziel, den Luftwiderstand bei einer vorgesehenen Reisegeschwindigkeit zu minimieren.



Die Flugzeugnase ist bei vorgegebenen Endradius  $R$  durch die Radien  $r_1, r_2, r_3$ , die Winkel  $\alpha_1, \alpha_2, \alpha_3$  und dem Kugelradius  $r_0$  vollständig festgelegt.

Die Aufgabe läßt sich nun formulieren durch

$$\min LW(r_0, r_1, r_2, r_3, \alpha_1, \alpha_2, \alpha_3)$$

$$\begin{aligned} \text{u.d.N.} \quad & (i) \text{ Volumen}(r_0, r_1, \dots, \alpha_3) \geq V_0 \\ & (ii) \text{ Länge}(r_0, \dots, \alpha_3) \leq L_0 \\ & (iii) 0 \leq r_i \leq R, \quad i = 0, 1, \dots, 3 \\ & (iv) 0 \leq \alpha_3 \leq \alpha_2 \leq \alpha_1 \leq \frac{\pi}{2} \end{aligned}$$



e) Tikhonov – Phillips – Regularisierung

Sind  $X, Y$  Hilberträume und  $A \in L(X, Y)$  kompakt, so definiert

$$\inf_{x \in X} J_\gamma(x) = \inf_{x \in X} \|Af - g\|_X^2 + \gamma^2 \|f\|_X^2 \tag{1.1}$$

eine Regularisierung der Operatorgleichung

$$Af = g.$$

Die Lösung  $f_\gamma$  von (1.1) löst auch

$$(A^*A + \gamma I) f_\gamma = A^*g$$

und es gilt

$$f_\gamma \rightarrow A^+g \quad , \quad g \in D(A^+) , \gamma \rightarrow 0.$$

Alle Probleme a) - e) lassen sich in der Form schreiben

$$\begin{cases} \inf/\min f(x) \\ \text{u.d.N} \quad i) \quad g_i(x) \leq 0 \quad , \quad i = 1, \dots, p \\ \quad \quad ii) \quad h_j(x) = 0 \quad , \quad j = p + 1, \dots, m \\ \quad \quad iii) \quad x \in \mathcal{B} \end{cases} \tag{1.2}$$

Dabei sind  $f : X \rightarrow \mathbb{R}, g : X \rightarrow \mathbb{R}^p, h : X \rightarrow \mathbb{R}^{m-p}$  gegebene Funktionen und  $\mathcal{B} \subset X$ .  $X$  ist ein Vektorraum.

Wir nennen (1.2) ein nichtlineares (Optimierungs-) Problem (NLP). Die Menge  $\{x \in X : x \text{ erfüllt } i) - iii)\}$  ist die Menge der zulässigen Vektoren.

**Einteilung von Optimierungsproblemen:**

- 1) Nichtrestringiertes Optimierungsproblem:  
 $p = m = 0, \mathcal{B} = X$ .
- 2) Lineares Optimierungsproblem:  
 $f, g_1, \dots, g_p, h_{p+1}, \dots, h_m$  sind affin linear,  $\mathcal{B} = \mathbb{R}^n = X$ .
- 3) Quadratisches Optimierungsproblem:  
 $f$  ist quadratisch (z.B:  $f(x) = \frac{1}{2}x^T Qx + c^T x + b, Q \in \mathbb{R}^{n \times n}$  symmetrisch,  $c \in \mathbb{R}^n, b \in \mathbb{R}$ ),  $\mathcal{B} = \mathbb{R}^n = X, g_1, \dots, g_p, h_{p+1}, \dots, h_m$  affin linear.
- 4) Konvexes Optimierungsproblem:  
 $f, g_1, \dots, g_p$  sind konvexe Funktionen,  $h_{p+1}, \dots, h_m$  affin linear,  $\mathcal{B} = \mathbb{R}^n = X$ .
- 5) Glatte, nichtlineare Optimierung:  
 $f, g_1, \dots, g_p, h_{p+1}, \dots, h_m$  sind (zumindest einmal) differenzierbar,  $\mathcal{B} = \mathbb{R}^n = X$ .
- 6) Diskrete Optimierung:  
 Lineare Optimierung mit  $\mathcal{B} \subset \mathbb{Z}^n$  oder  $\mathcal{B} \subset \{0, 1\}^n$ .

**Bemerkung:**

a) Wegen

$$\inf\{f(x)\} = -\sup\{-f(x)\}$$

können wir uns auf Minimierungsprobleme beschränken.

b) Ist  $\dim X = \infty$ , so spricht man von semi-infiniten Problemen.  
In dieser Vorlesung ist stets  $X = \mathbb{R}^n$ .




$$\begin{aligned} \min \quad & c^T x \\ x \in \mathbb{R}^2, \quad & Ax \geq \underline{b} \\ & x \geq 0 \end{aligned}$$

mit

$$A = \begin{pmatrix} 20 & 20 \\ 15 & 3 \\ 5 & 10 \end{pmatrix}, \quad \underline{b} = (60, 15, 20)^T, \quad c = (10, 7)$$

*Graphische Lösung: Jede Nebenbedingung definiert eine Halbebene, der Schnitt der 3 Halbebenen mit dem 1. Quadranten ist der zulässige Bereich.*



*Wir verschieben die Geraden  $c^T x = \text{const.}$  mit dem Normalenvektor  $c$  ohne den zulässigen Bereich zu verlassen in Richtung  $-c$ . Wir treffen so auf den Punkt  $p = (0.5, 2.5)$ , der das Minimierungsproblem löst.*

**Definition 2.2.** Eine Teilmenge  $\mathbb{R}^n$  der Form  $\{x \in \mathbb{R}^n : Ax \leq b\}$  mit  $A \in \mathbb{R}^{m \times n}, b \in \mathbb{R}^m$  heißt Polyeder. Eine Menge der Gestalt


$$\mathcal{P} := \{x \in \mathbb{R}^n : Ax = b, x \geq 0\}$$

nennen wir Polyeder in Normalform.

**Beispiel 2.3** Zum Beispiel ist mit  $A = \begin{pmatrix} -1 & 0 \\ 0 & -1 \\ -1 & -1 \end{pmatrix}$  und  $b = (0, 0, -1)^T$  die Menge

$$\begin{aligned} & \{ (x_1, x_2)^T \in \mathbb{R}^2 : Ax \leq b \} \\ & = \{ (x_1, x_2)^T \in \mathbb{R}^2 : -x_1 \leq 0, -x_2 \leq 0, -x_1 - x_2 \leq -1 \} \end{aligned}$$

ein Polyeder.



Der zulässige Bereich ist in (P) also ein Polyeder in Normalform.

**Lemma 2.4.** *Jedes lineare Programm der Form (LP) läßt sich in Normalform darstellen, also in der Form:*

$$(P) \begin{cases} \min c^T x \\ \text{u.d.N: } Ax = b, x \geq 0. \end{cases}$$

**Beweis:** In (LP) sind die Restriktionen in der Gestalt  $\underline{b} \leq Ax \leq \bar{b}, l \leq x \leq u$  gegeben.

Betrachte die  $j$ -te Komponente von  $Ax \leq \bar{b}$  also:

$$a_j^T x \leq \bar{b}_j$$

Diese Restriktion läßt sich durch Einführen einer nichtnegativen *Schlupfvariablen*  $s_j$  umformulieren zu:

$$a_j^T x + s_j = \bar{b}_j, \quad s_j \geq 0.$$

Ebenso ist eine Restriktion der Form

$$a_j^T x \geq \underline{b}_j$$

wegen

$$-a_j^T x \leq -\underline{b}_j$$

zu behandeln.

Alle Variablen  $x_i$ , die nicht vorzeichenbeschränkt sind (diese heißen *freie Variablen*) behandelt man folgendermaßen:

Es gilt:

$$x_i = x_i^+ - x_i^- \quad \text{mit} \quad x_i^+ \geq 0, x_i^- \leq 0.$$

Definiere dazu  $x_i^+ = \max\{x_i, 0\}, x_i^- = -\min\{x_i, 0\}$ .

Die Nebenbedingungen transformieren sich demnach zu

$$\tilde{A}\tilde{x} = \tilde{b}, \quad \tilde{x} \geq 0.$$

Zu minimieren ist die Größe  $\tilde{c}^T \tilde{x}$  mit einem entsprechenden Vektor  $\tilde{c}$ . □

**Beispiel 2.5** *Die Nebenbedingungen eines linearen Programmes lauten*

$$\begin{aligned}x_1 + 2x_2 &\leq 0 \\x_1 + x_2 + x_3 &\geq 0 \\2x_1 + x_3 &= 1 \\x_1 \geq 0, \quad x_2 &\geq 0\end{aligned}$$

Für die ersten beiden Ungleichungen führen wir Schlupfvariablen ein und die freie Variable  $x_3$  splitten wir auf. Wir gelangen so zu der Darstellung in Normalform:

$$\begin{aligned}x_1 + 2x_2 + s_1 &= 0 \\-x_1 - x_2 - x_3^+ + x_3^- + s_2 &= 0 \\2x_1 + x_3^+ - x_3^- &= 1 \\x_1 \geq 0, \quad x_2 \geq 0, \quad x_3^+ \geq 0, \quad x_3^- \geq 0, \quad s_1 \geq 0, \quad s_2 \geq 0\end{aligned}$$

Beide Systeme sind äquivalent zueinander.

**Nachteil:** Die Anzahl der Variablen wurde verdoppelt.

**Definition 2.6.** Sei  $\mathcal{P} = \{x \in \mathbb{R}^n : Ax = b, x \geq 0\}$  ein Polyeder in Normalform,  $A \in \mathbb{R}^{m \times n}$ ,  $b \in \mathbb{R}^m$ . Ein Vektor  $x \in \mathcal{P}$  heißt Ecke (Extremalpunkt) von  $\mathcal{P}$ , wenn aus

$$x = \lambda x^1 + (1 - \lambda)x^2$$

für  $x^1, x^2 \in \mathcal{P}$ ,  $\lambda \in (0, 1)$  bereits  $x = x^1 = x^2$  folgt.

$x$  läßt sich also nicht als echte Konvexkombination von Punkten aus  $\mathcal{P}$  darstellen.

**Beispiel 2.7** a) Die Punkte  $(0, 1), (1, 0)$  aus dem vorherigen Beispiel sind Extremalpunkte.

b) Alle Randpunkte eines Kreises sind Extremalpunkte.

Charakterisierung der Ecken eines Polyeders ?

**Satz 2.8** Sei  $\mathcal{P} = \{x \in \mathbb{R}^n : Ax = b, x \geq 0\}$  ein Polyeder in Normalform mit  $A \in \mathbb{R}^{m \times n}$ ,  $b \in \mathbb{R}^m$ . Dann ist  $x \in \mathcal{P}$  genau dann eine Ecke von  $\mathcal{P}$ , wenn die zu den positiven Komponenten von  $x$  zugehörigen Spalten von  $A$  linear unabhängig sind, wenn also die Spalten  $a_i$  von  $A$  mit  $i \in \bar{I}(x) := \{i : x_i > 0\}$  linear unabhängig sind.

**Beweis:** Sei  $x \in \mathcal{P}$  eine Ecke.

Annahme: Die Spaltenvektoren  $a_i, i \in \bar{I}(x)$ , sind linear abhängig.

Dann gibt es  $\gamma_i \in \mathbb{R}$  mit

$$\sum_{i \in \bar{I}(x)} \gamma_i a_i = 0$$

und  $\gamma_i \neq 0$  für mindestens einen Index  $i \in \bar{I}(x)$ . Wegen  $x_i > 0$  für alle  $i \in \bar{I}(x)$  existiert ein  $\delta > 0$  mit  $x_i \pm \delta \gamma_i \geq 0$  für alle  $i \in \bar{I}(x)$ .

Es sei nun

$$x_i^1 := \begin{cases} x_i + \delta \gamma_i, & i \in \bar{I}(x) \\ 0 & \text{sonst} \end{cases}$$

und

$$x_i^2 := \begin{cases} x_i - \delta \gamma_i, & i \in \bar{I}(x) \\ 0 & \text{sonst} \end{cases}$$

Es gilt  $x^1 \geq 0, x^2 \geq 0$  und

$$\begin{aligned} Ax^1 &= \sum_{i=1}^n x_i^1 a_i = \sum_{i \in \bar{I}(x)} (x_i + \delta \gamma_i) a_i \\ &= b + \delta \underbrace{\sum_{i \in \bar{I}(x)} \gamma_i a_i}_{=0} = 0 \end{aligned}$$

sowie  $Ax^2 = b$ .

Hieraus ersehen wir, dass  $x^1, x^2 \in \mathcal{P}$  sind. Offenbar ist aber

$$x = \frac{1}{2}x^1 + \frac{1}{2}x^2$$

Wegen  $x^1 \neq x^2$  kann dann  $x$  keine Ecke sein (Widerspruch!). Die Annahme war also falsch.

Es seien nun die Spaltenvektoren  $a_i, i \in \bar{I}(x)$  linear unabhängig.

Weiter gelte

$$x = \lambda x^1 + (1 - \lambda)x^2$$

für gewisse  $x^1, x^2 \in \mathcal{P}$  und ein  $\lambda \in (0, 1)$ .

Aus  $x^1 \geq 0, x^2 \geq 0$  und  $x_j = 0, j \notin \bar{I}(x)$  folgt wegen  $\lambda \in (0, 1)$  sofort

$$x_j^1 = x_j^2 = 0, \quad j \notin \bar{I}(x).$$

Also gilt

$$\begin{aligned} 0 &= b - b = Ax^1 - Ax^2 = A(x^1 - x^2) \\ &= \sum_{i \in \bar{I}(x)} (x_i^1 - x_i^2) a_i \end{aligned}$$

und daher auch  $x_i^1 = x_i^2, i \in \bar{I}(x)$ , da die  $a_i, i \in \bar{I}(x)$  linear unabhängig sind. Folglich ist  $x^1 = x^2$  und damit  $x \in \mathcal{P}$  eine Ecke. □

**Beispiel 2.9** Der Polyeder  $\mathcal{P} = \{x \in \mathbb{R}^n : Ax = b, x \geq 0\}$  mit

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

hat den Vektor  $x = (1, 2, 0)^T$  als Ecke.

**Definition 2.10.** Sei  $\mathcal{P} := \{x \in \mathbb{R}^n : Ax = b, x \geq 0\}$  ein Polyeder in Normalform mit  $A \in \mathbb{R}^{m \times n}, b \in \mathbb{R}^m$ . Ein zulässiger Punkt  $x \in \mathcal{P}$  heißt Basisvektor von  $\mathcal{P}$ , wenn eine aus genau  $m$  Elementen bestehende Indexmenge  $I$  existiert mit  $x_j = 0$  für alle  $j \notin I$ , so dass die Spaltenvektoren  $a_i, i \in I$ , linear unabhängig sind.

**Beispiel 2.11** In dem vorangegangenen Beispiel ist  $x = (1, 2, 0)^T$  auch Basisvektor und  $I = \{1, 2\}$ .

**Achtung!** Unter Umständen ist  $I \neq \bar{I}(x)$ , da wir in Definition 2.10 nicht vorausgesetzt haben, dass  $x_i > 0$  für alle  $i \in I$  gilt.

Annahme: O.B.d.A:  $\text{Rang}(A) = m$

**Satz 2.12** Sei  $\mathcal{P} = \{x \in \mathbb{R}^n : Ax = b, x \geq 0\}$  ein Polyeder in Normalform mit  $A \in \mathbb{R}^{m \times n}$ ,  $b \in \mathbb{R}^m$  und  $\text{Rang}(A) = m$ . Dann ist  $x$  genau dann eine Ecke von  $\mathcal{P}$ , wenn  $x$  ein Basisvektor von  $\mathcal{P}$  ist.

**Beweis:** " $\Leftarrow$ " Ist  $x$  ein Basisvektor, so ist nach Satz 2.8  $x$  auch eine Ecke von  $\mathcal{P}$ .  
" $\Rightarrow$ " Sei  $x \in \mathcal{P}$  eine Ecke und  $\bar{I}(x) = \{i : x_i > 0\}$ .

Aus Satz 2.8 folgt, dass die Spaltenvektoren  $a_i, i \in \bar{I}(x)$  linear unabhängig sind. Somit gilt  $|\bar{I}(x)| \leq m$ .

Ist  $|\bar{I}(x)| = m$  so setzen wir  $I := \bar{I}(x)$  und sind fertig.

Ist  $|\bar{I}(x)| < m$ , so können wir wegen  $\text{Rang}(A) = m$  die Menge  $\{a_i, i \in \bar{I}(x)\}$  zu einer  $m$ -elementigen Menge  $\{a_i, i \in I\}$  mit  $\bar{I}(x) \subset I$  ergänzen, die aus linear unabhängigen Vektoren  $a_i$  besteht. Somit ist  $x$  ein Basisvektor. □

Das folgende Resultat zeigt die große Bedeutung der Basisvektoren.

**Satz 2.13** (Hauptsatz der linearen Optimierung)

Sei  $\mathcal{P} = \{x \in \mathbb{R}^n : Ax = b, x \geq 0\}$  ein Polyeder in Normalform mit  $A \in \mathbb{R}^{m \times n}$ ,  $b \in \mathbb{R}^m$  und  $\text{Rang}(A) = m$ . Dann gelten:

- Ist  $\mathcal{P} \neq \emptyset$ , so besitzt  $\mathcal{P}$  mindestens einen Basisvektor.
- $\mathcal{P}$  hat höchstens endlich viele Basisvektoren.
- Besitzt das lineare Programm

$$\min c^T x \quad \text{u.d.N.} \quad x \in \mathcal{P} \tag{2.1}$$

eine Lösung, so ist auch einer der Basisvektoren von  $\mathcal{P}$  Lösung von (2.1).

**Beweis:** a) Ist  $0 \in \mathcal{P}$ , so ist  $x = 0$  ein Basisvektor.

Sonst: Sei  $x^* \in \mathcal{P}$  ein Vektor mit einer minimalen Anzahl positiver Komponenten.

Es ist dann  $\bar{I}(x^*) = \{i : x_i^* > 0\} \neq \emptyset$ .

Behauptung: Die Menge  $\{a_i, i \in \bar{I}(x^*)\}$  ist linear unabhängig.

Ansonsten gibt es  $\gamma_i, i \in \bar{I}(x^*)$  mit

$$\sum_{i \in \bar{I}(x^*)} \gamma_i a_i = 0$$

und  $\gamma_i \neq 0$  für ein  $i \in \bar{I}(x^*)$ .

$$\text{O.B.d.A: } \gamma_i < 0 \quad \text{für ein } i \in \bar{I}(x^*).$$

Dann existiert ein minimales  $\bar{\delta} > 0$  mit  $x_i(\bar{\delta}) = x_i^* + \bar{\delta}\gamma_i \geq 0$  für alle  $i \in \bar{I}(x^*)$  und  $x_i(\bar{\delta}) = 0$  für ein  $i \in \bar{I}(x^*)$ .

Der durch

$$\bar{x}_i = \begin{cases} x_i(\bar{\delta}), & i \in \bar{I}(x^*) \\ 0, & \text{sonst} \end{cases}$$

festgelegte Vektor ist in  $\mathcal{P}$  (Beweis wie in Satz 2.8), hat also weniger positive Komponenten wie  $x^*$  ( $\Rightarrow$  Widerspruch!).

Also ist  $\{a_i, i \in \bar{I}(x^*)\}$  linear unabhängig und damit  $x^* \in \mathcal{P}$  eine Ecke (Satz 2.8) und nach Satz 2.12 ein Basisvektor.

b) Da es nur  $\binom{n}{m}$  Möglichkeiten  $m$  linear unabhängige Spalten aus  $n$  Stück auszuwählen, kann  $\mathcal{P}$  nur endlich viele Basisvektoren haben, die durch  $Ax = b$  jeweils eindeutig bestimmt sind.

c) Nach Voraussetzung ist



$$f^* := \min\{c^T x : x \in \mathcal{P}\}$$

endlich. Betrachte nun das lineare Programm

$$\min c^T x \quad \text{u.d.N} \quad x \in \overline{\mathcal{P}}$$

mit

$$\overline{\mathcal{P}} = \{x \in \mathbb{R}^n : Ax = b, \quad c^T x = f^*, \quad x \geq 0\},$$

$\overline{\mathcal{P}}$  ist ein Polyeder in Normalform und nach Voraussetzung nichtleer. Nach Teil a) besitzt  $\overline{\mathcal{P}}$  einen Basisvektor  $x^*$ , der nach Satz 2.12 eine Ecke ist.

Wir zeigen:  $x^*$  ist eine Ecke von  $\mathcal{P}$ .

Annahme:  $x^*$  ist keine Ecke von  $\mathcal{P}$ .

Dann gibt es  $x^1, x^2 \in \mathcal{P}$ ,  $x^1 \neq x^2$  mit

$$x^* = \lambda x^1 + (1 - \lambda)x^2$$

für ein  $\lambda \in (0, 1)$ .

Wegen  $x^1, x^2 \in \mathcal{P}$  ist

$$f^* \leq c^T x^1 \quad , \quad f^* \leq c^T x^2$$

Wegen  $x^* \in \overline{\mathcal{P}}$  ist  $f^* = c^T x^*$  und damit

$$f^* = c^T x^1 \quad , \quad f^* = c^T x^2$$

also  $x^1, x^2 \in \overline{\mathcal{P}}$ .

Da  $x^* \in \overline{\mathcal{P}}$  eine Ecke ist folgt  $x^1 = x^2$  ( $\Rightarrow$  Widerspruch!) Also ist  $x^* \in \mathcal{P}$  eine Ecke und damit Basisvektor von  $\mathcal{P}$ . Wegen  $x^* \in \overline{\mathcal{P}}$  ist  $x^*$  auch Lösung von (2.1). □

**Anmerkung:** Satz 2.13 besagt, dass wir zur Lösung von (2.1) 'nur' alle Ecken des zulässigen Bereiches  $\mathcal{P}$  durchlaufen müssen.

( $\rightarrow$  Simplex-Algorithmus)

Problem: Der Einheitswürfel im  $\mathbb{R}^n$ ,

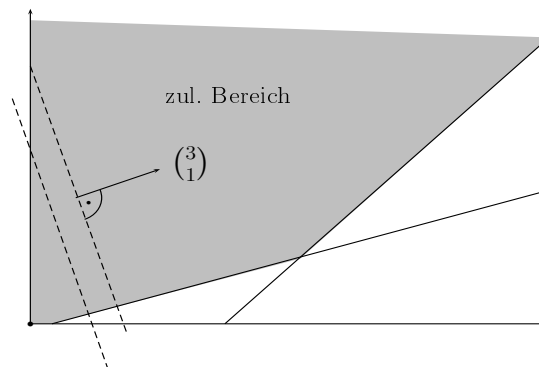
$$\{(x_1, \dots, x_n)^T \in \mathbb{R}^n : 0 \leq x_i \leq 1, i = 1, \dots, n\}$$

besitzt  $2^n$  Ecken.

$\Rightarrow$  enorm zeitaufwändig

**Beispiel 2.14** Betrachte das lineare Programm

$$\begin{cases} \min 3x_1 + x_2 \\ \text{u.d.N} \quad x_1 - x_2 \leq 3, \quad x_1 - 3x_2 \leq 1 \\ \quad \quad \quad x_1 \geq 0, \quad x_2 \geq 0 \end{cases} \quad (2.2)$$



optimale Lösung:  $x^* = (0, 0)$   
 In Normalform sieht das Problem so aus:

$$\begin{aligned} & \min 3x_1 + x_2 \\ \text{u.d.N} \quad & x_1 - x_2 + s_1 = 3, \quad x_1 - 3x_2 + s_2 = 1 \\ & x_1, x_2, s_1, s_2 \geq 0 \end{aligned}$$

$\tilde{\mathcal{P}} = \{\tilde{A}\tilde{x} = b, \tilde{x} \geq 0\}$  mit

$$\tilde{A} = \begin{pmatrix} 1 & -1 & 1 & 0 \\ 1 & -3 & 0 & 1 \end{pmatrix}, \quad \tilde{x} = (x_1, x_2, s_1, s_2)^T, \quad b = \begin{pmatrix} 3 \\ 1 \end{pmatrix}.$$

Also:  $\min \tilde{c}^T \tilde{x}, \tilde{c} = (3, 1, 0, 0)$  u.d.N.  $\tilde{x} \in \tilde{\mathcal{P}}$   
 Es gibt maximal  $\binom{4}{2} = 6$  Basisvektoren in  $\tilde{\mathcal{P}}$ , da  $\text{Rang}(\tilde{A}) = 2$ .

Es muß gelten  $|I| = \text{Rang}(\tilde{A}) = 2$

$I$	Basisvektor $\bar{x}$	$\tilde{c}^T x$
$\{1, 2\}$	$\bar{x} = (4, 1, 0, 0)^T$	13
$\{1, 3\}$	$\bar{x} = (1, 0, 2, 0)^T$	3
$\{1, 4\}$	existiert nicht	/
$\{2, 3\}$	existiert nicht	/
$\{2, 4\}$	existiert nicht	/
$\{3, 4\}$	$\bar{x} = (0, 0, 3, 1)^T$	0

Nach Satz 2.13 ist  $\bar{x} = (0, 0, 3, 1)$  eine Lösung des Problems in Normalform. Dieser Lösung entspricht die Lösung  $x = (0, 0)$  des Ausgangsproblems.

ACHTUNG:

- 1) Der Polyeder  $\tilde{\mathcal{P}}$  ist ungleich dem zulässigen Bereich des Ausgangsproblems.
- 2) Satz 2.13 ist *nicht* auf beliebiger Polyeder übertragbar. Der Polyeder

$$\{x \in \mathbb{R}^2 : -x_1 \leq 0\}$$

z.B besitzt keine Ecke.



## 2.2 Der Simplex – Algorithmus

Sei ein lineares Programm in Normalform gegeben, d.h.

$$\min c^T x \quad \text{u.d.N.} \quad Ax = b, \quad x \geq 0 \quad (2.3)$$

mit  $c, x \in \mathbb{R}^n, A \in \mathbb{R}^{m \times n}, b \in \mathbb{R}^m$  und sei  $\text{Rang}(A) = m$ .

**Idee:** Nutze Satz 2.13 aus: Gehe von einem Basisvektor zum nächsten und zwar so, dass der Wert der Zielfunktion  $c^T x$  beim Übergang abnimmt.

Sei  $x \in \mathcal{P} = \{x \in \mathbb{R}^n, Ax = b, x \geq 0\}$  ein Basisvektor und  $I$  die zugehörige Indexmenge mit  $|I| = m, x_j = 0, j \notin I$  und  $\{a_i, i \in I\}$  linear unabhängig.

Sei  $J := \{1, \dots, n\} \setminus I$ . Wir definieren die Basismatrix

$$B := (a_i)_{i \in I} \in \mathbb{R}^{m \times m}$$

und die Nichtbasismatrix

$$N := (a_j)_{j \in J} \in \mathbb{R}^{m \times (n-m)}$$

$I$  und  $J$  seien geordnet!

Weiter bezeichne für  $z \in \mathbb{R}^n$

$$z_I := (z_i)_{i \in I} \in \mathbb{R}^m, \quad z_J := (z_j)_{j \in J} \in \mathbb{R}^{n-m}.$$

Dann gilt

$$\begin{aligned} Az &= \sum_{i=1}^n z_i a_i = \sum_{i \in I} z_i a_i + \sum_{j \in J} z_j a_j \\ &= Bz_I + Nz_J. \end{aligned}$$

Für den Basisvektor  $x \in \mathcal{P}$  gilt

$$Bx_I = b, \quad x_J = 0. \quad (2.4)$$

Es sei nun  $z \in \mathcal{P}$  ein beliebiger zulässiger Vektor (nicht unbedingt Basisvektor).

**Ziel:** Wähle  $z$  so, dass  $c^T z < c^T x$ .

Wegen  $Az = b$  gilt

$$Bz_I + Nz_J = b$$

und somit:

$$z_I = B^{-1}b - B^{-1}Nz_J$$

Aus (2.4) und  $(B^{-1})^T = (B^T)^{-1}$  folgt dann

$$\begin{cases} c^T z = c_I^T z_I + c_J^T z_J \\ \quad = c_I^T (B^{-1}b - B^{-1}Nz_J) + c_J^T z_J \\ \quad = c_I^T x_I + (c_J^T - c_I^T B^{-1}N)z_J \\ \quad = c^T x + (c_J - N^T (B^T)^{-1} c_I)^T z_J \end{cases} \quad (2.5)$$

Definiere:

$$y := (B^T)^{-1} c_I \in \mathbb{R}^m$$

Dann ist  $y$  (eindeutige) Lösung von

$$B^T y = c_I. \quad (2.6)$$

Definieren wir weiter:

$$u_j := c_j - a_j^T y, \quad j \in J, \quad (2.7)$$

so nimmt (2.5) die Gestalt

$$c^T z = c^T x + \sum_{j \in J} u_j z_j \quad (2.8)$$

an.

**Lemma 2.15.** (*Späteres Abbruchkriterium*)

Gilt für die durch (2.6), (2.7) definierten Zahlen  $u_j$

$$u_j \geq 0 \quad \text{für alle } j \in J, \quad (2.9)$$

so ist der Basisvektor  $x$  eine Lösung des linearen Programmes (2.3).

**Beweis:** Da (2.8) für alle  $z \in \mathcal{P}$  gilt, folgt wegen  $z_j \geq 0$  für alle  $j \in J$  die Behauptung. □

Gilt also (2.9), so sind wir fertig.

Sei nun (2.3) nicht erfüllt:

Es sei also

$$u_j < 0 \quad \text{für mindestens ein } j \in J \quad (2.10)$$

Wähle ein  $r \in J$  mit  $u_r < 0$  und definiere  $z = z(t)$  durch

$$\begin{cases} z_r(t) := t > 0 \\ z_j(t) := 0, \quad j \in J \setminus \{r\} \\ z_i(t), \quad i \in I \text{ wird noch festgelegt} \end{cases} \quad (2.11)$$

Aus (2.8) erhalten wir dann

$$c^T z(t) = c^T x + t u_r < c^T x. \quad (2.12)$$

**Forderung:**  $z(t) \in \mathcal{P}$ , also  $z(t)$  muß zulässig sein.

⇒ Es muß gelten:  $Az(t) = b$ ,  $z(t) \geq 0$  also:

$$1) \quad Az(t) = Bz_I(t) + t a_r = b$$

und somit

$$z_I(t) = B^{-1}(b - t a_r) = x_I - t B^{-1} a_r.$$

Wir legen also fest:

$$z_I(t) = x_I - t d, \quad (2.13)$$

wobei  $d \in \mathbb{R}^m$  das Gleichungssystem

$$Bd = a_r \quad (2.14)$$

löst.

Durch (2.11), (2.13) wird ein  $z(t) \in \mathbb{R}^n$  mit  $Az(t) = b$  konstruiert und  $c^T z(t) < c^T x$ .

2) Nun ist noch  $z(t) \geq 0$  zu realisieren.

**Lemma 2.16.** *Gilt für den durch (2.14) definierten Vektor  $d$*

$$d_i \leq 0 \quad \text{für alle } i \in I, \tag{2.15}$$

so ist das lineare Programm (2.3) nicht lösbar.

**Beweis:** Aus (2.11), (2.13) folgt  $z(t) \geq 0$  für alle  $t \geq 0$ , da  $z(t) \geq 0$  und wegen  $x_I \geq 0$  auch  $z_I(t) \geq 0$  gilt.

Folglich ist  $z(t) \in \mathcal{P}$  für alle  $t \geq 0$ .

(2.12) besagt

$$c^T z(t) = c^T x + t u_r, \quad t \geq 0$$

wobei  $u_r < 0$  ist.

Also ist  $\inf_{t \geq 0} c^T z(t) = -\infty$  und somit (2.3) nicht lösbar. □

Sei nun (2.15) **nicht** erfüllt:

Es sei also

$$d_i > 0 \quad \text{für mindestens ein } i \in I.$$

Es gilt  $z(t) \geq 0$  genau dann, wenn  $t \geq 0$  und  $x_i - t d_i \geq 0$  gilt für alle  $i \in I$  mit  $d_i > 0$ .

Also:

$$0 \leq t \leq \frac{x_i}{d_i} \quad \text{für alle } i \in I \text{ mit } d_i > 0. \tag{2.16}$$

FAZIT : Durch (2.11), (2.13), (2.16) wird ein  $z(t) \in \mathcal{P}$  festgelegt mit

$$c^T z(t) < c^T x.$$

**Problem:**  $z(t)$  ist kein Basisvektor mehr, da  $z(t)$  i.a. eine Nullkomponente weniger als  $x$  hat ( $z_r(t) = t$ ).

Idee: Erzwingen das Auftreten einer neuen Nullkomponente durch die Festlegung

$$\hat{t} := \min_{i \in I, d_i > 0} \frac{x_i}{d_i} = \frac{x_s}{d_s} \quad \text{mit } s \in I, d_s > 0. \tag{2.17}$$

Es ist dann  $\hat{t} \geq 0$  und

$$z_s(\hat{t}) = x_s - \hat{t} d_s = 0$$

Desweiteren ist  $x^{neu} := z(\hat{t})$  ein Basisvektor.

**Satz 2.17** *Sei  $x$  ein Basisvektor mit Indexmenge  $I$  und  $J = \{1, \dots, n\} \setminus I$  sowie  $B = (a_i)_{i \in I}$ . Für die aus (2.6), (2.7) berechneten Zahlen  $u_j$  sei*

$$u_j < 0 \quad \text{für mindestens ein } j \in J.$$

Für den zu einem  $r$  mit  $u_r < 0$  aus (2.14) berechneten Vektor  $d \in \mathbb{R}^n$  sei

$$d_i > 0 \quad \text{für mindestens ein } i \in I.$$

Werden  $\hat{t} \geq 0$  und ein  $s \in I$  nach (2.17) bestimmt, so gilt für  $x^{neu} \in \mathbb{R}^n$  mit

$$x_i^{neu} := \begin{cases} x_i - \hat{t} d_i, & i \in I, i \neq s \\ \hat{t}, & i = r \\ 0 & \text{sonst} \end{cases}$$

folgendes:

a)  $x^{neu} \in \mathcal{P}$  ist ein Basisvektor mit Indexmenge  $I^{neu} = (I \cup \{r\}) \setminus \{s\}$ ,

b)  $c^T x^{neu} \leq c^T x$ ,

**Beweis:** b) ist klar, ebenso wie  $x^{neu} \in \mathcal{P}$  nach Konstruktion ( $\hat{t} = 0$  möglich !)  
Zu zeigen:  $x^{neu}$  ist ein Basisvektor.

Es ist

$$x_i^{neu} = 0 \quad \text{für alle } i \notin I^{neu}$$

klar nach Definition.

Es bleibt zu zeigen:  $a_i, i \in I^{neu}$  linear unabhängig.

Sei

$$\sum_{i \in I^{neu}} \gamma_i a_i = \sum_{i \in I, i \neq s} \gamma_i a_i + \gamma_r a_r = 0 \quad \text{mit } \gamma_i \in \mathbb{R}.$$

Es gilt

$$\begin{aligned} 0 &= \sum_{i \in I, i \neq s} \gamma_i a_i + \gamma_r a_r \\ &= \sum_{i \in I, i \neq s} \gamma_i a_i + \gamma_r B d \\ &= \sum_{i \in I, i \neq s} \gamma_i a_i + \gamma_r \left( \sum_{i \in I} d_i a_i \right) \\ &= \sum_{i \in I, i \neq s} (\gamma_i + \gamma_r d_i) a_i + \gamma_r d_s a_s. \end{aligned}$$

Da  $x$  ein Basisvektor mit Indexmenge  $I$  ist, gilt

$$\gamma_i + \gamma_r d_i = 0 \quad \text{für alle } i \in I, i \neq s \quad \text{und} \quad \gamma_r d_s = 0.$$

Wegen  $d_s > 0$  gilt  $\gamma_r = 0$  und somit

$$\gamma_i = 0 \quad \text{für alle } i \in I, i \neq s,$$

also

$$\gamma_i = 0 \quad \text{für alle } i \in I^{neu},$$

das heißt  $(a_i)_{i \in I^{neu}}$  sind linear unabhängig. □

**Bemerkung:** In (2.17) kann passieren, dass  $\hat{t} = 0$  ist, falls  $x_i = 0$  für ein  $i \in I$  gilt. In diesem Fall wäre  $c^T x^{neu} = c^T x$ . Ein Basisvektor  $x \in \mathcal{P}$  mit  $x_i = 0$  für ein  $i \in I$  heißt *entartet*.

**Korollar 2.18** *Ist  $x$  ein nichtentarteter Basisvektor, so gilt sogar*

$$c^T x^{neu} < c^T x.$$

**Beispiel 2.19** *Seien*

$$A = \begin{pmatrix} 1 & 1 & 1 & 1 & 0 & 0 & 0 \\ 0 & 3 & 1 & 0 & 1 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 1 \end{pmatrix}, \quad b = \begin{pmatrix} 4 \\ 6 \\ 2 \\ 3 \end{pmatrix}, \quad c = (-2, -3, -4, 0, 0, 0, 0)^T.$$

Der Vektor  $x = (2, 0, 0, 2, 6, 0, 3)^T$  ist ein Basisvektor mit Indexmenge

$$I = \{1, 4, 5, 7\}, \quad \text{also} \quad J = \{2, 3, 6\},$$

und somit

$$B = \begin{pmatrix} 1 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix}, \quad c^T x = -4,$$

$$x_I = (2, 2, 6, 3) \quad , \quad c_I = (-2, 0, 0, 0)^T.$$

Die Lösung von  $B^T y = c_I$  lautet  $y = (0, 0, -2, 0)^T$ , woraus sich  $u_2 = c_2 - a_2^T y = -3$ ,  $u_3 = -4$ ,  $u_6 = 2$  ergibt.

Wähle  $r = 3$  ( $u_3 < 0$ ).

Die Lösung von  $Bd = a_3$  ist  $d = (0, 1, 1, 1)^T$ .

Weiter ist

$$\begin{aligned} \min_{i \in I, d_i > 0} \frac{x_i}{d_i} &= \min \left\{ \frac{x_4}{d_4}, \frac{x_5}{d_5}, \frac{x_7}{d_7} \right\} \\ &= \min\{2, 6, 3\} = 2 =: \hat{t} \end{aligned}$$

und somit  $s = 4$ .

Damit wird

$$I^{neu} = \{1, \underline{3}, 5, 7\} \quad , \quad x^{neu} = (2, 0, 2, 0, 4, 0, 1)^T$$

und

$$c^T x^{neu} = -12 < -4 = c^T x.$$

#### ALGORITHMUS: (Simplex-Verfahren)

- (S.0) Wähle einen Basisvektor  $x^0$  von  $\mathcal{P} = \{x \in \mathbb{R}^n : Ax = b, x \geq 0\}$  mit Indexmenge  $I_0$ ,  $|I_0| = m$ , setze  $J_0 = \{1, \dots, n\} \setminus I_0$ .  
Definiere

$$B_0 = (a_i)_{i \in I_0}$$

und  $k := 0$ .

- (S.1) Berechne die Lösung  $y^k \in \mathbb{R}^m$  von

$$B_k^T y = c_{I_k}.$$

- (S.2) Berechne

$$u_j^k := c_j - a_j^T y^k \quad , \quad j \in J_k.$$

- (S.3) Ist  $u_j^k \geq 0$  für alle  $j \in J_k \implies$  STOP (Lemma 2.15)

- (S.4) Wähle  $r_k \in J_k$  mit  $u_{r_k}^k < 0$ .

- (S.5) Berechne die Lösung  $d^k \in \mathbb{R}^m$  von

$$B_k d^k = a_{r_k}.$$

- (S.6) Ist  $d_i^k \leq 0$  für alle  $i \in I_k \implies$  STOP (Lemma 2.16)

- (S.7) Bestimme  $t_k \geq 0$  und  $s_k \in I_k$  mit  $d_{s_k}^k > 0$  aus

$$t_k := \min_{i \in I_k, d_i^k > 0} \frac{x_i^k}{d_i^k} = \frac{x_{s_k}^k}{d_{s_k}^k}$$

und setze

$$x_i^{k+1} = \begin{cases} x_i^k - t_k d_i^k, & i \in I_k, i \neq s_k \\ t_k & i = r_k \\ 0 & \text{sonst} \end{cases}$$

$$I_{k+1} := (I_k \cup \{r_k\}) \setminus \{s_k\}$$

$$J_{k+1} := \{1, \dots, n\} \setminus I_{k+1}$$

$$B_{k+1} := (a_i)_{i \in I_{k+1}}$$

Setze  $k \leftarrow k + 1$  und gehe zu (S.1).

**Satz 2.20** a) Die vom Simplex-Verfahren erzeugten Vektoren  $x^k$  sind Basisvektoren von  $\mathcal{P}$  und es gilt

$$c^T x^{k+1} \leq c^T x^k, \quad k = 0, 1, 2, \dots$$

b) Bricht das Verfahren in (S.3) ab, so ist  $x^k$  eine Lösung von (2.3).

c) Bricht das Verfahren in (S.6) ab, so ist (2.3) nicht lösbar.

d) Sind alle im Simplex-Verfahren auftretenden Basisvektoren  $x^k$  nicht entartet, so bricht das Verfahren nach endlich vielen Iterationen ab und zwar mit einer der Entscheidungen in b) oder c).

**Beweis:** Es bleibt nur d) zu zeigen.

Nach Korollar 2.18 ist

$$c^T x^{k+1} < c^T x^k, \quad k = 0, 1, \dots$$

Ein Basisvektor  $x^k$  taucht folglich nicht zweimal auf. Nach Satz 2.13 gibt es jedoch nur endlich viele Basisvektoren. Also muß das Verfahren abbrechen. □

**Bemerkung:** a) Bei der Durchführung des Simplex-Algorithmus können sogenannte Zyklen auftauchen, d.h. der Fall

$$x^k = x^{k+1} = \dots = x^{k+p}, \quad p \geq 2$$

und

$$I_k \rightarrow I_{k+1} \rightarrow \dots \rightarrow I_{k+p} = I_k.$$

In diesem Fall bricht das Verfahren nicht ab. Durch folgende Zusatzforderungen können Zyklen vermieden werden:

(S.4') Wähle  $r_k$  als den kleinsten Index  $j \in J_k$  mit  $u_j^k < 0$ .

(S.7') Bestimme  $t_k \geq 0$  und  $s_k$  als den kleinsten Index  $s_k \in I_k$  mit  $d_i^k > 0$  aus

$$t_k = \min_{i \in I_k, d_i^k > 0} \frac{x_i^k}{d_i^k} = \frac{x_{s_k}^k}{d_{s_k}^k}$$

(Zusatzregel von Bland)

b) Die Komplexität des Simplex-Verfahrens ist schlimmstenfalls exponentiell in  $n$  (Beispiel von Klee und Minty).

Viele Beispiele haben jedoch gezeigt, dass die Anzahl der Simplex-Schritte eher polynomial mit  $n$  und  $m$  wächst.

c) Ein Start-Basisvektor  $x^0$  zu finden ist nicht trivial. Oft wird in einem ersten Schritt (Phase I) das Simplex-Verfahren auf ein Hilfsproblem angewendet, um  $x^0$  zu bekommen.



**Satz 2.21** In (2.3) sei  $b \geq 0$ . Dann gilt für das lineare Programm

$$\min e^T z \quad \text{u.d.N.} \quad Ax + z = b, \quad x, z \geq 0 \quad (2.18)$$

mit  $e = (1, 1, \dots, 1)^T \in \mathbb{R}^m$  folgendes:

- a) Der Vektor  $\begin{pmatrix} x \\ z \end{pmatrix} = \begin{pmatrix} 0 \\ b \end{pmatrix}$  ist ein Basisvektor für (2.18) mit  $I = \{n+1, n+2, \dots, n+m\}$ .
- b) Sei  $\begin{pmatrix} x^* \\ z^* \end{pmatrix} \in \mathbb{R}^{n+m}$  ein optimaler Basisvektor für (2.18). Ist  $z^* \neq 0$ , so besitzt (2.3) keinen zulässigen Punkt. Ist  $z^* = 0$  und  $\text{Rang}(A) = m$ , so ist  $x^* \in \mathbb{R}^n$  ein Basisvektor für (2.3).

**Beweis:** als Übung

**Anmerkung:** Man kann beweisen, dass das lineare Programm (2.18) stets lösbar ist.



## Optimalität und Dualität

### 3.1 Optimalitätsbedingungen

**Definition 3.1.** Eine Teilmenge  $X \subseteq \mathbb{R}^n$  ist ein Kegel (cone), falls  $\lambda x \in X$  gilt für alle  $x \in X$  und  $\lambda > 0$ .

Sind  $a_1, \dots, a_m \in \mathbb{R}^n$ , so ist

$$\text{cone} \{a_1, \dots, a_m\} := \{x_1 a_1 + \dots + x_m a_m, x_i \geq 0, i = 1, \dots, m\}$$

der durch  $a_1, \dots, a_m$  erzeugte (konvexe) Kegel.


**Definition 3.2.** Sei  $\emptyset \neq X \subseteq \mathbb{R}^n$ . Eine Vektor  $d \in \mathbb{R}^n$  heißt tangential zu  $X$  im Punkt  $x \in X$ , wenn Folgen  $\{x^k\} \subseteq X$  und  $\{t_k\} \subseteq \mathbb{R}$  existieren mit

$$x^k \rightarrow x, \quad t_k \searrow 0 \quad \text{und} \quad \frac{x^k - x}{t_k} \rightarrow d \quad \text{für} \quad k \rightarrow \infty, \quad (3.1)$$

Die Menge all dieser Richtungen

$$\mathcal{T}_X(x) = \{d \in \mathbb{R}^n : \exists \{x^k\} \subseteq X, \{t_k\} \subseteq \mathbb{R} \text{ mit (3.1)}\}$$

heißt Tangentialkegel von  $X$  in  $x \in X$ .



**Lemma 3.3.** Seien  $\emptyset \neq X \subseteq \mathbb{R}^n$  und  $x \in X$ . Dann ist  $\mathcal{T}_X(x)$  ein abgeschlossener Kegel.

**Beweis:** als Übung.

**Lemma 3.4.** Seien  $\emptyset \neq X \subseteq \mathbb{R}^n$ ,  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  stetig differenzierbar und  $x^*$  ein lokales Minimum des Optimierungsproblems

$$\min f(x) \quad \text{u.d.N.} \quad x \in X. \quad (3.2)$$

Dann gilt  $\nabla f(x^*)^T d \geq 0$  für alle  $d \in \mathcal{T}_X(x^*)$ .

**Beweis:** Sei  $d \in \mathcal{T}_X(x^*)$  beliebig und  $\{x^k\} \subseteq X$ ,  $\{t_k\} \subseteq \mathbb{R}$  Folgen, die (3.1) erfüllen. Da  $f \in \mathcal{C}'(\mathbb{R}^n)$  gilt mit dem MWS:

$$f(x^k) - f(x^*) = \nabla f(\xi^k)^T (x^k - x^*)$$

für alle  $k \in \mathbb{N}$ , wobei  $\xi^k$  auf der Verbindungsstrecke von  $x^k$  und  $x^*$  liegt.

Also gilt:

$$\xi^k \rightarrow x^* \quad \text{für } k \rightarrow \infty.$$

Da  $x^*$  ein lokales Minimum von (3.2) ist, gilt außerdem

$$f(x^k) - f(x^*) \geq 0 \quad , \quad k \geq k_0$$

und somit

$$\nabla f(\xi^k)^T (x^k - x^*) \geq 0$$

für  $k$  hinreichend groß.

Somit gilt

$$\lim_{k \rightarrow \infty} \frac{\nabla f(\xi^k)^T (x^k - x^*)}{t_k} = \nabla f(x^*)^T d \geq 0.$$

□

Ein Vektor  $x^* \in X$  mit

$$\nabla f(x^*)^T d \geq 0 \quad \text{für alle } d \in \mathcal{T}_X(x^*) \quad (3.3)$$

heißt *stationärer Punkt* von (3.2).

Im Falle  $X = \mathbb{R}^n$  ist (3.3) äquivalent zu  $\nabla f(x^*) = 0$ .

Das Problem (3.2) habe von nun an die Gestalt

$$\begin{cases} \min f(x) \\ \text{u.d.N. } g_i(x) \leq 0 \quad , \quad i = 1, \dots, m \\ h_j(x) = 0 \quad , \quad j = 1, \dots, p. \end{cases} \quad (3.4)$$

Generell gelte  $f \in \mathcal{C}^1(\mathbb{R}^n)$ ,  $g_i, h_j \in \mathcal{C}^1(\mathbb{R}^n)$ ,  $i = 1, \dots, m$ ,  $j = 1, \dots, p$ .

Es ist also

$$X = \{x \in \mathbb{R}^n : g_i(x) \leq 0, i = 1, \dots, m, h_j(x) = 0, j = 1, \dots, p\}$$

**Problem:** Die Bedingung (3.3) ist schwer zu handhaben, denn  $\mathcal{T}_X(x)$  kann eine komplizierte Struktur haben.

**Definition 3.5.** Sei  $x \in X$  ein zulässiger Punkt von (3.4). Dann heißt

$$\mathcal{T}_{lin}(x) := \{d \in \mathbb{R}^n : \nabla g_i(x)^T d \leq 0, i \in I(x), \nabla h_j(x)^T d = 0, j = 1, \dots, p\}$$

lineartisierter Tangentialkegel von  $X$  in  $x$ , wobei

$$I(x) := \{i \in \{1, \dots, m\} : g_i(x) = 0\}$$

die Menge der aktiven Ungleichungsrestriktionen in  $x$  ist.

**Lemma 3.6.** Sei  $x \in X$  ein zulässiger Punkt von (3.4). Dann gilt

$$\mathcal{T}_X(x) \subseteq \mathcal{T}_{lin}(x).$$


**Beweis:** als Übung mit Hinweis:

Zeige:  $\nabla g_i(x^k)^T d \leq 0$ ,  $i \in I(x)$  und verwende Lemma 3.4.

□

**Beispiel 3.7**

$$\begin{aligned} \min -x_1 \quad \text{u.d.N.} \quad & x_2 + x_1^3 \leq 0 \\ & -x_2 \leq 0 \end{aligned}$$



$x^* = (0, 0)^T$  ist das eindeutige Minimum.

Mit  $g_1(x) = x_2 + x_1^3$ ,  $g_2(x) = -x_2$  ist  $I(x^*) = \{1, 2\}$ ,  $\nabla g_1(x) = (3x_1^2, 1)$ ,  $\nabla g_2(x) = (0, -1)$

Daher ist

$$\begin{aligned} \mathcal{T}_{lin}(x^*) &= \{d \in \mathbb{R}^2 : \nabla g_1(x^*)^T d \leq 0, \nabla g_2(x^*)^T d \leq 0\} \\ &= \{(d_1, d_2)^T \in \mathbb{R}^2, d_2 = 0\} \end{aligned}$$

Aber:

$$\mathcal{T}_X(x^*) = \{(d_1, 0) : d_1 \in \mathbb{R}, d_1 \leq 0\},$$

also

$$\mathcal{T}_X(x^*) \subsetneq \mathcal{T}_{lin}(x^*).$$

**Definition 3.8.** Ein zulässiger Punkt  $x \in X$  von (3.4) erfüllt die Regularitätsbedingung von Abadie (Abadie Constraint Qualification ACQ), falls  $\mathcal{T}_X(x) = \mathcal{T}_{lin}(x)$  gilt.

**Definition 3.9.** a) Die durch

$$L(x, \lambda, \mu) := f(x) + \sum_{i=1}^m \lambda_i g_i(x) + \sum_{j=1}^p \mu_j h_j(x) \tag{3.5}$$

definierte Abbildung

$$L : \mathbb{R}^n \times \mathbb{R}^m \times \mathbb{R}^p \rightarrow \mathbb{R}$$

heißt Lagrange-Funktion des Problems (3.4).

b) Die Bedingungen

$$\begin{cases} \nabla_x L(x, \lambda, \mu) = 0 \\ h(x) = 0 \\ \lambda \geq 0, g(x) \leq 0, \lambda^T g(x) = 0 \end{cases} \quad (3.6)$$

heißen Karusch - Kuhn - Tucker - (KKT-) Bedingungen des Problems (3.4) mit

$$\nabla_x L(x, \lambda, \mu) = \nabla f(x) + \sum_{i=1}^m \lambda_i \nabla g_i(x) + \sum_{j=1}^p \mu_j \nabla h_j(x). \quad (3.7)$$

c) Genügt der Vektor  $(x^*, \lambda^*, \mu^*) \in \mathbb{R}^n \times \mathbb{R}^m \times \mathbb{R}^p$  den KKT - Bedingungen, so nennen wir  $(x^*, \lambda^*, \mu^*)$  einen KKT-Punkt. Ist zusätzlich

$$\lambda_i^* + g_i(x^*) \neq 0 \quad \forall i = 1, \dots, m$$

so genügt der KKT - Punkt  $(x^*, \lambda^*, \mu^*)$  der strikten Komplementarität.

**Bemerkung:** a) Zu c): Wegen (3.6) gilt für einen KKT-Punkt  $(x^*, \lambda^*, \mu^*)$  stets  $\lambda_i^* g_i(x^*) = 0$  für alle  $i = 1, \dots, m$ , also  $\lambda_i^* = 0$  oder  $g_i(x^*) = 0$ ,  $i = 1, \dots, m$ .

b) Ist  $m = p = 0$ , so lauten die KKT-Bedingungen ganz einfach:

$$\nabla f(x^*) = 0.$$

c) Aus (3.7) ist zu ersehen, dass im Falle  $p = 0$  für einen KKT-Punkt gilt

$$-\nabla f(x^*) \in \text{cone} \{ \nabla g_i(x^*) : i \in I(x^*) \},$$

wobei  $I(x^*) = \{i : g_i(x^*) = 0\}$  ist. Für  $i \notin I(x^*)$  gilt  $\lambda_i^* = 0$ .

**Lemma 3.10.** (Lemma von Farkas)

Seien  $A \in \mathbb{R}^{m \times n}$ ,  $b \in \mathbb{R}^m$  gegeben. Dann sind die folgenden Aussagen äquivalent.

a) Das System  $A^T x = b$ ,  $x \geq 0$  besitzt eine Lösung.

b) Die Ungleichung  $b^T d \geq 0$  gilt für alle  $d \in \mathbb{R}^n$  mit  $Ad \geq 0$ .

**Satz 3.11** (KKT - Bedingungen unter ACQ)

Sei  $x^* \in \mathbb{R}^n$  ein lokales Minimum des Optimierungsproblems (3.4), welches der ACQ genüge. Dann existieren Lagrange-Multiplikatoren  $\lambda^* \in \mathbb{R}^m$ ,  $\mu^* \in \mathbb{R}^p$ , so dass  $(x^*, \lambda^*, \mu^*)$  ein KKT-Punkt von (3.4) ist.

**Beweis:** Lemma 3.4 besagt, dass

$$\nabla f(x^*)^T d \geq 0 \quad \text{für alle } d \in \mathcal{T}_X(x^*)$$

ist. Wegen  $\mathcal{T}_X(x^*) = \mathcal{T}_{in}(x^*)$  (ACQ) ist dann

$$-\nabla f(x^*)^T d \leq 0$$

für alle  $d \in \mathbb{R}^n$  mit  $Ad \leq 0$ , wobei die Zeilen von  $A$  mit  $A \in \mathbb{R}^{(|I(x^*)|+2p) \times n}$  gegeben sind durch

$$\begin{aligned} \nabla g_i(x^*)^T &, \quad i \in I(x^*), \\ \nabla h_j(x^*)^T &, \quad j = 1, \dots, p, \\ -\nabla h_j(x^*)^T &, \quad j = 1, \dots, p. \end{aligned}$$

( $Ad \leq 0 \Leftrightarrow d \in \mathcal{T}_{lin}(x^*)$ .)

Das Lemma von Farkas garantiert die Existenz einer Lösung des Systems

$$A^T y = -\nabla f(x^*) \quad , \quad y \geq 0.$$

Definieren wir nun

$$\lambda_i^* = \begin{cases} y_i & , \quad i \in I(x^*) \\ 0 & , \quad i \notin I(x^*) \end{cases}$$

sowie

$$\begin{aligned} \mu_i^+ &:= y_{i+|I(x^*)|} & , \quad i = 1, \dots, p \\ \mu_i^- &:= y_{i+p+|I(x^*)|} & , \quad i = 1, \dots, p \end{aligned}$$

und

$$\mu_i^* = \mu_i^+ - \mu_i^- \quad , \quad i = 1, \dots, p$$

so ist  $(x^*, \lambda^*, \mu^*)$  ein KKT-Punkt. □

### Optimalitätsbedingungen für lineare Restriktionen:

Betrachte

$$\begin{cases} \min f(x) \\ \text{u.d.N. } a_i^T x \leq \alpha_i & i = 1, \dots, m \\ b_j^T x = \beta_j & j = 1, \dots, p \end{cases} \quad (3.8)$$

$$f \in \mathcal{C}^1(\mathbb{R}^n) \quad , \quad a_i, b_j \in \mathbb{R}^n \quad , \quad \alpha_i, \beta_j \in \mathbb{R}.$$

In diesem Falle sind die KKT-Bedingungen notwendige Bedingungen für ein lokales Minimum.

#### Satz 3.12 (KKT-Bedingungen für lineare Restriktionen)

Sei  $x^*$  ein lokales Minimum von (3.8). Dann existieren Lagrange-Multiplikatoren  $\lambda^* \in \mathbb{R}^m$ ,  $\mu^* \in \mathbb{R}^p$ , so dass  $(x^*, \lambda^*, \mu^*)$  den KKT-Bedingungen

$$\begin{cases} \nabla f(x^*) + \sum_{i=1}^m \lambda_i^* a_i + \sum_{j=1}^p \mu_j^* b_j = 0 \\ b_j^T x^* = \beta_j & , \quad j = 1, \dots, p \\ a_i^T x^* \leq \alpha_i & , \quad i = 1, \dots, m \\ \lambda_i^* (a_i^T x^* - \alpha_i) = 0 & , \quad i = 1, \dots, m \\ \lambda_i^* \geq 0 & , \quad i = 1, \dots, m \end{cases} \quad (3.9)$$

von (3.8) genügt.

**Beweis:** Mit  $g_i(x) := a_i^T x - \alpha_i$ ,  $h_j(x) := b_j^T x - \beta_j$  sind (3.9) in der Tat die KKT-Bedingungen für (3.8).

Wir zeigen, dass die ACQ für (3.8) erfüllt ist, dass also  $\mathcal{T}_X(x^*) = \mathcal{T}_{lin}(x^*)$  gilt. Mit Satz 3.11 folgt dann die Behauptung. Wegen Lemma 3.6 genügt es zu zeigen:

$$\mathcal{T}_{lin}(x^*) \subseteq \mathcal{T}_X(x^*).$$

Sei  $d \in \mathcal{T}_{lin}(x^*)$ .

$$\begin{aligned} \Rightarrow a_i^T d &\leq 0, \quad i \in I(x^*) \\ b_j^T d &= 0, \quad j = 1, \dots, p \end{aligned}$$

Es sei  $\{t_k\}$  eine beliebige Folge mit  $t_k \searrow 0$ . Setze

$$x^k := x^* + t_k d.$$

Für  $k$  hinreichend groß gilt dann:

$$\begin{aligned} a_i^T x^k &= a_i^T (x^* + t_k d) = \alpha_i + t_k a_i^T d \leq \alpha_i, \quad \forall i \in I(x^*) \\ a_i^T x^k &= a_i^T (x^* + t_k d) = a_i^T x^* + t_k a_i^T d < \alpha_i, \quad \forall i \notin I(x^*), \quad k \geq k_0 \\ b_j^T x^k &= b_j^T (x^* + t_k d) = b_j^T x^* + t_k b_j^T d = \beta_j, \quad \forall j = 1, \dots, p \end{aligned}$$

Das heißt:  $\{x^k\}$  ist zulässig und  $x^k \rightarrow x^*$ ,  $k \rightarrow \infty$ . Wegen

$$\frac{x^k - x^*}{t^k} = d \rightarrow d$$

folgt  $d \in \mathcal{T}_X(x^*)$ . □

**Bemerkung:** Die Aussage von Satz 3.12 ist nicht erstaunlich, da  $\mathcal{T}_{lin}(x^*)$  durch Linearisierung von  $\mathcal{T}_X(x^*)$  entstanden ist.

### Optimalitätsbedingungen für konvexe Restriktionen:

Wir betrachten das Problem

$$\begin{cases} \min f(x) \\ \text{u.d.N. } g_i(x) \leq 0 & i = 1, \dots, m \\ b_j^T x = \beta_j & j = 1, \dots, p \end{cases} \quad (3.10)$$

wobei  $f, g_i \in \mathcal{C}^1(\mathbb{R}^n)$  konvexe Funktionen sind,  $b_j \in \mathbb{R}^n, \beta_j \in \mathbb{R}$ .

Dabei heißt eine Funktion  $f: X \subseteq \mathbb{R}^n \rightarrow \mathbb{R}$  konvex, falls  $X$  konvex ist und

$$f(\lambda x + (1 - \lambda)y) \leq \lambda f(x) + (1 - \lambda)f(y)$$

für alle  $x, y \in X$  und alle  $\lambda \in (0, 1)$  gilt.

**Lemma 3.13.** Sei  $\emptyset \neq X \subseteq \mathbb{R}^n$  konvex.

a) Eine Funktion  $f \in \mathcal{C}^1(X)$  ist genau dann konvex, wenn für alle  $x, y \in X$

$$f(x) - f(y) \geq \nabla f(y)^T (x - y) \quad (3.11)$$

gilt.

b) Ist  $f: X \rightarrow \mathbb{R}$  konvex, so ist jedes lokale Minimum des Optimierungsproblems

$$\min f(x) \quad \text{u.d.N.} \quad x \in X$$

bereits ein globales Minimum.



**Beweis:** als Übung.

**Definition 3.14.** Das Problem (3.10) genügt der Regularitätsbedingung von Slater, wenn es ein  $\hat{x} \in \mathbb{R}^n$  gibt mit

$$\begin{cases} g_i(\hat{x}) < 0, & i = 1, \dots, m \text{ und} \\ b_j^T \hat{x} = \beta_j, & j = 1, \dots, p \end{cases} \quad (3.12)$$

d.h.  $\hat{x}$  ist strikt zulässig bzgl. der Ungleichungsrestriktionen und zulässig bzgl. der Gleichheitsrestriktionen.

**Satz 3.15** (KKT-Bedingungen unter Slater-Bedingungen)

Sei  $x^* \in \mathbb{R}^n$  ein (lokales=globales) Minimum des Problems (3.10) und es gelte die Slater-Bedingung. Dann existieren Multiplikatoren  $\lambda^* \in \mathbb{R}^m$ ,  $\mu^* \in \mathbb{R}^p$ , so dass  $(x^*, \lambda^*, \mu^*)$  den KKT-Bedingungen genügt:

$$\begin{cases} \nabla f(x^*) + \sum_{i=1}^m \lambda_i^* \nabla g_i(x^*) + \sum_{j=1}^p \mu_j^* b_j = 0 \\ b_j^T x^* = \beta_j & , j = 1, \dots, p \\ g_i(x^*) \leq 0 & , i = 1, \dots, m \\ \lambda_i^* \geq 0, \lambda_i^* g_i(x^*) = 0 & , i = 1, \dots, m \end{cases} \quad (3.13)$$

**Beweis:** Aufgrund von Satz 3.11 (ACQ) genügt es wieder  $\mathcal{T}_{lin}(x^*) \subseteq \mathcal{T}_X(x^*)$  zu zeigen. ( $X$  ist die zulässige Menge von (3.10) und damit konvex.) Sei

$$\mathcal{T}_{strict}(x^*) = \{d \in \mathbb{R}^n : \nabla g_i(x^*)^T d < 0, i \in I(x^*), b_j^T d = 0, j = 1, \dots, p\},$$

$$I(x^*) = \{i : g_i(x^*) = 0\}.$$

Es gilt:

$$\mathcal{T}_{strict}(x^*) \subseteq \mathcal{T}_X(x^*)$$

(Als Übung mit Aufgabe 2.22 Kanzow/Geiger)

Aus Lemma 3.3 folgt

$$\text{cl}(\mathcal{T}_{strict}(x^*)) \subseteq \mathcal{T}_X(x^*)$$

Es ist nun zu zeigen:

$$\mathcal{T}_{lin}(x^*) \subseteq \text{cl}(\mathcal{T}_{strict}(x^*)).$$

Sei  $d \in \mathcal{T}_{lin}(x^*)$  beliebig. Sei weiter  $\hat{x} \in \mathbb{R}^n$  ein Vektor gemäß (3.12).

Wir setzen

$$\hat{d} := \hat{x} - x^*$$

Da  $g_i$  konvex ist,  $i = 1, \dots, m$ , gilt mit (3.11):

$$\nabla g_i(x^*)^T \hat{d} \leq g_i(\hat{x}) - g_i(x^*) < 0 \quad , \quad i \in I(x^*).$$

Und:

$$\nabla h_j(x^*)^T \hat{d} = h_j(\hat{x}) - h_j(x^*) = 0 \quad , \quad j = 1, \dots, p$$

$$(\nabla h_j(x) = b_j).$$

Setzen wir  $d(\delta) := d + \delta \hat{d}$  für  $\delta > 0$ , so folgt

$$\nabla g_i(x^*)^T d(\delta) < 0 \quad , \quad i \in I(x^*)$$

$$\nabla h_j(x^*)^T d(\delta) = 0 \quad , \quad j = 1, \dots, p$$

Daraus schließen wir:

$$d(\delta) \in \mathcal{T}_{strict}(x^*) \quad \text{für alle } \delta > 0.$$

Und mit  $\delta \searrow 0$  sehen wir:  $d \in \text{cl}(\mathcal{T}_{strict}(x^*))$ .

Also:

$$\mathcal{T}_{lin}(x^*) \subseteq \mathcal{T}_X(x^*)$$

und damit

$$\mathcal{T}_{lin}(x^*) = \mathcal{T}_X(x^*).$$

□

Für konvexe Probleme sind die KKT-Bedingungen sogar hinreichend !

**Satz 3.16** Sei  $(x^*, \lambda^*, \mu^*)$  ein KKT-Punkt für das Problem (3.10). Dann ist  $x^*$  (lokales=globales) Minimum von (3.10).

**Beweis:** Sei  $x \in \mathbb{R}^n$  ein zulässiger Vektor für das konvexe Problem (3.10). Aus den KKT-Bedingungen sowie (3.11) folgern wir:

$$\begin{aligned} f(x) &\geq f(x^*) + \nabla f(x^*)^T(x - x^*) \\ &= f(x^*) - \sum_{i=1}^m \lambda_i^* \nabla g_i(x^*)^T(x - x^*) - \sum_{j=1}^p \mu_j^* b_j^T(x - x^*) \\ &= f(x^*) - \sum_{i \in I(x^*)} \lambda_i^* \nabla g_i(x^*)^T(x - x^*) \quad (\text{sonst } \lambda_i^* = 0) \\ &\geq f(x^*) \end{aligned}$$

wegen  $\lambda_i^* \geq 0$  und

$$\nabla g_i(x^*)^T(x - x^*) \leq g_i(x) - g_i(x^*) \leq 0$$

für alle  $i \in I(x^*)$  wegen (3.11).

$\Rightarrow x^*$  ist ein Minimum von (3.10).

□

**Korollar 3.17** Gegeben sei das Problem (3.10), wobei jetzt auch die  $g_i : \mathbb{R}^n \rightarrow \mathbb{R}$  linear seien. Dann ist  $x^* \in \mathbb{R}^n$  genau dann ein (lokales=globales) Minimum von (3.10), wenn es Lagrange-Multiplikatoren  $\lambda^* \in \mathbb{R}^m$ ,  $\mu^* \in \mathbb{R}^p$  gibt, so dass das Tripel  $(x^*, \lambda^*, \mu^*)$  ein KKT-Punkt von (3.10) ist.

**Beweis:** Satz 3.12 und Satz 3.16

□

**Anmerkung:** In Satz (3.16) kamen wir ohne Slater-Bedingungen aus!

### Alternative Charakterisierung von KKT-Punkten:

**Definition 3.18.** Ein Vektor  $(x^*, \lambda^*, \mu^*) \in \mathbb{R}^n \times \mathbb{R}^m \times \mathbb{R}^p$  mit  $\lambda^* \geq 0$  heißt Sattelpunkt der Lagrange-Funktion  $\mathcal{L}$ , wenn die Ungleichungen

$$\mathcal{L}(x^*, \lambda, \mu) \leq \mathcal{L}(x^*, \lambda^*, \mu^*) \leq \mathcal{L}(x, \lambda^*, \mu^*) \quad (3.14)$$

gelten für alle  $(x, \lambda, \mu) \in \mathbb{R}^n \times \mathbb{R}_+^m \times \mathbb{R}^p$ .

**Bemerkung:** (3.14) besagt, dass  $x^*$  ein Minimum von  $\mathcal{L}(\cdot, \lambda^*, \mu^*)$  auf  $\mathbb{R}^n$  ist, und  $(\lambda^*, \mu^*)$  ein Maximum von  $\mathcal{L}(x^*, \cdot, \cdot)$  auf  $\mathbb{R}_+^m \times \mathbb{R}^p$  darstellt.  $\rightarrow$  "Sattelpunkt".

**Satz 3.19** (Sattelpunkt-Theorem)

Gegeben sei das Problem (3.10). Das Tripel  $(x^*, \lambda^*, \mu^*) \in \mathbb{R}^n \times \mathbb{R}^m \times \mathbb{R}^p$  ist genau dann ein Sattelpunkt der Lagrange-Funktion  $\mathcal{L}$ , wenn  $(x^*, \lambda^*, \mu^*)$  ein KKT-Punkt von (3.10) ist.

**Beweis:** " $\Rightarrow$ " Sei  $(x^*, \lambda^*, \mu^*)$  ein Sattelpunkt von  $\mathcal{L}$ . Aus (3.14) folgt, dass  $x^*$  globales Minimum von  $\mathcal{L}(\cdot, \lambda^*, \mu^*)$  ist und somit

$$\nabla_x \mathcal{L}(x^*, \lambda^*, \mu^*) = 0$$

gilt. (3.14) liefert außerdem

$$\sum_{i=1}^m \lambda_i g_i(x^*) + \sum_{j=1}^p \mu_j h_j(x^*) \leq \sum_{i=1}^m \lambda_i^* g_i(x^*) + \sum_{j=1}^p \mu_j^* h_j(x^*) \quad (3.15)$$

für alle  $\lambda \in \mathbb{R}_+^m$ ,  $\mu \in \mathbb{R}^p$  mit  $h_j(x) := b_j^T x - \beta_j$ .

Aus (3.15) folgt  $g(x^*) \leq 0$  und  $h(x^*) = 0$ , da sonst für  $\lambda_i \rightarrow \infty$ ,  $|\mu_j| \rightarrow \infty$  (3.15) verletzt werden kann.

Wähle nun  $\lambda = 0$  und  $\mu = \mu^*$  in (3.15)

$$\Rightarrow \sum_{j=1}^p \mu_j^* h_j(x^*) \leq \sum_{i=1}^m \lambda_i^* g_i(x^*) + \sum_{j=1}^p \mu_j^* h_j(x^*)$$

Also gilt

$$\sum_{i=1}^m \lambda_i^* g_i(x^*) \geq 0$$

und daher:

$$\lambda_i^* g_i(x^*) = 0 \quad , \quad i = 1, \dots, m$$

wegen  $\lambda_i^* \geq 0$ ,  $g_i(x^*) \leq 0$ .

$\Rightarrow$   $(x^*, \lambda^*, \mu^*)$  ist ein KKT-Punkt von (3.10).

" $\Leftarrow$ " Sei  $(x^*, \lambda^*, \mu^*)$  ein KKT-Punkt (3.10).

$$\Rightarrow \nabla_x \mathcal{L}(x^*, \lambda^*, \mu^*) = 0 \quad (1. \text{ KKT-Bed.})$$

$\Rightarrow$  ist ein stationärer Punkt von  $\mathcal{L}(\cdot, \lambda^*, \mu^*)$ .

Da  $\mathcal{L}(\cdot, \lambda^*, \mu^*)$  konvex ist, ist  $x^*$  ein globales Minimum von  $\mathcal{L}(\cdot, \lambda^*, \mu^*)$ .

Also gilt

$$\mathcal{L}(x^*, \lambda^*, \mu^*) \leq \mathcal{L}(x, \lambda^*, \mu^*) \quad , \quad x \in \mathbb{R}^n$$

Unter Ausnutzung von  $g_i(x^*) \leq 0$ ,  $h(x^*) = 0$  und  $\lambda_i^* g_i(x^*) = 0$  folgt:

$$\begin{aligned} \mathcal{L}(x^*, \lambda^*, \mu^*) &= f(x^*) + \sum_{i=1}^m \lambda_i^* g_i(x^*) + \sum_{j=1}^p \mu_j^* h_j(x^*) \\ &= f(x^*) \\ &\geq f(x^*) + \sum_{i=1}^m \lambda_i g_i(x^*) + \sum_{j=1}^p \mu_j h_j(x^*) \\ &= \mathcal{L}(x^*, \lambda, \mu) \end{aligned}$$

für alle  $\lambda \geq 0$ ,  $\mu \in \mathbb{R}^p$ .

$\implies (x^*, \lambda^*, \mu^*)$  ist ein Sattelpunkt von  $\mathcal{L}$ .

□

### Zusammenfassung:

**Korollar 3.20** Gegeben sei das konvexe Problem (3.10).

(a) Ist  $(x^*, \lambda^*, \mu^*) \in \mathbb{R}^n \times \mathbb{R}_+^m \times \mathbb{R}^p$  ein Sattelpunkt der Lagrange-Funktion  $\mathcal{L}$ , so ist  $x^*$  ein globales Minimum von (3.10).

(b) Ist  $x^*$  ein (lokales=globales) Minimum von (3.10) und ist die Slater-Bedingung erfüllt, so gibt es  $\lambda^* \in \mathbb{R}^m$  und  $\mu^* \in \mathbb{R}^p$ , so dass  $(x^*, \lambda^*, \mu^*)$  ein Sattelpunkt von  $\mathcal{L}$  ist.

(c) Sind die Funktionen  $g_i, h_j$  in (3.10) alle linear, so ist  $x^*$  genau dann ein (lokales=globales) Minimum von (3.10), wenn es Vektoren  $\lambda^* \in \mathbb{R}^m$  und  $\mu^* \in \mathbb{R}^p$  gibt, so dass  $(x^*, \lambda^*, \mu^*)$  ein Sattelpunkt der Lagrange-Funktion ist.

### Weitere Optimalitätskriterien

Erinnerung: (3.4)

$$\begin{cases} \min f(x) \\ \text{u.d.N. } g_i(x) \leq 0, \quad i = 1, \dots, m \\ h_j(x) = 0, \quad j = 1, \dots, p \end{cases}$$

**Definition 3.21.** Seien  $x \in \mathbb{R}^n$  ein zulässiger Punkt von (3.4) und  $I(x) = \{i : g_i(x) = 0\}$ .

a) Dann genügt  $x$  der Regularitätsbedingung der linearen Unabhängigkeit (*linear independence constraint qualification, LICQ*), wenn die Gradienten

$$\nabla g_i(x), \quad i \in I(x)$$

$$\nabla h_j(x), \quad j = 1, \dots, p$$

linear unabhängig sind.

b) Der Vektor  $x$  genügt der Regularitätsbedingung von Mangasarian-Fromovitz (*MFCQ*), wenn gilt:

i) Die Gradienten

$$\nabla h_j(x), \quad j = 1, \dots, p$$

sind linear unabhängig.

ii) Es existiert ein Vektor  $d \in \mathbb{R}^n$  mit

$$\nabla g_i(x)^T d < 0, \quad i \in I(x) \quad \text{und}$$

$$\nabla h_j(x)^T d = 0, \quad j = 1, \dots, p.$$

**Satz 3.22** Sei  $x^* \in \mathbb{R}^n$  ein lokales Minimum von (3.4), welches der LICQ oder der MFCQ genügt. Dann existieren Lagrange-Multiplikatoren  $\lambda^* \in \mathbb{R}^m$ ,  $\mu^* \in \mathbb{R}^p$  derart, dass das Tripel  $(x^*, \lambda^*, \mu^*)$  ein KKT-Punkt von (3.4) ist. Die Multiplikatoren  $\lambda^*, \mu^*$  sind im Falle der LICQ sogar eindeutig bestimmt.

**Beweis:** Teile als Übung.

### Optimalitätsbedingungen 2.Ordnung:

Es sei weiterhin (3.4) gegeben, wobei die Funktionen  $f : \mathbb{R}^n \rightarrow \mathbb{R}$ ,  $h : \mathbb{R}^n \rightarrow \mathbb{R}^p$ ,  $g : \mathbb{R}^n \rightarrow \mathbb{R}^m$  zweimal stetig differenzierbar seien.

Weiter sei  $(x^*, \lambda^*, \mu^*)$  ein KKT-Punkt von (3.4) und

$$I(x^*) = \{i : g_i(x^*) = 0\}$$

Es gilt dann

$$I(x^*) = I_0(x^*) \cup I_{>}(x^*)$$

mit

$$\begin{aligned} I_0(x^*) &:= \{i \in I(x^*) : \lambda_i^* = 0\}, \\ I_{>}(x^*) &:= \{i \in I(x^*) : \lambda_i^* > 0\}. \end{aligned}$$

Schließlich definieren wir noch

$$\mathcal{T}(x^*) := \begin{cases} \nabla g_i(x^*)^T d = 0 & , i \in I_{>}(x^*) \\ d \in \mathbb{R}^n : \nabla g_i(x^*)^T d \leq 0 & , i \in I_0(x^*) \\ \nabla h_j(x^*)^T d = 0 & , j = 1, \dots, p \end{cases}$$

#### Satz 3.23 (Notwendiges Kriterium 2. Ordnung)

Sei  $x^* \in X$  ein lokales Minimum von (3.4) welches der LICQ-Bedingung genüge. ( $I_0(x^*), I_{>}(x^*)$  hängen dann nicht von  $\lambda^*$  ab, da eindeutig.)

Dann ist

$$d^T \nabla_{xx}^2 \mathcal{L}(x^*, \lambda^*, \mu^*) d \geq 0 \quad \forall d \in \mathcal{T}(x^*),$$

wobei  $\lambda^* \in \mathbb{R}^m$  und  $\mu^* \in \mathbb{R}^p$  die gemäß Satz 3.22 eindeutig bestimmten Lagrange-Multiplikatoren sind.

#### Satz 3.24 (Hinreichendes Kriterium 2. Ordnung)

Sei  $(x^*, \lambda^*, \mu^*)$  ein KKT-Punkt von (3.4) mit

$$d^T \nabla_{xx}^2 \mathcal{L}(x^*, \lambda^*, \mu^*) d > 0 \quad \forall d \in \mathcal{T}(x^*), d \neq 0$$

Dann ist  $x^*$  ein striktes Minimum von (3.4) (d.h.  $\exists$  Umgebung  $U$  von  $x^*$  mit  $f(x^*) < f(x) \forall x \in U$  zulässig,  $x \neq x^*$ ).

$\nabla_{xx}^2$  bezeichnet stets die Hesse-Matrix von  $\mathcal{L}$  bzgl.  $x$  !

**Bemerkung:** Im Falle eines unrestringierten Problems

$$\min_{x \in \mathbb{R}^n} f(x)$$

stimmen die Kriterien in Satz 3.23 und Satz 3.24 wegen  $\mathcal{T}(x^*) = \mathbb{R}^n$  mit den aus der Analysis bekannten Kriterien für lokale Minima überein.

### 3.2 Dualität

Wir betrachten wieder das lineare Programm

$$\min c^T x \quad \text{u.d.N.} \quad Ax = b, \quad x \geq 0 \quad (3.16)$$

mit  $A \in \mathbb{R}^{m \times n}$ ,  $c \in \mathbb{R}^n$ ,  $b \in \mathbb{R}^m$ .

**Definition 3.25.** *Das Maximierungsproblem*

$$\max b^T \lambda \quad \text{u.d.N.} \quad A^T \lambda \leq c \quad (3.17)$$

nennen wir das zu (3.16) duale lineare Programm. Wir bezeichnen (3.16) als primales lineares Programm.

Durch Einführung einer nichtnegativen Schlupfvariablen geht (3.17) über in

$$\max b^T \lambda \quad \text{u.d.N.} \quad A^T \lambda + s = c, \quad s \geq 0. \quad (3.18)$$

**Satz 3.26** *Die folgenden Aussagen sind äquivalent*

- (a) *Das primale Problem (3.16) besitzt eine Lösung  $x^*$ .*
- (b) *Das duale Problem (3.18) besitzt eine Lösung  $(\lambda^*, \mu^*)$ .*
- (c) *Die Optimalitätsbedingungen*

$$\begin{aligned} A^T \lambda + s &= c \\ Ax &= b \\ x_i s_i &= 0, \quad i = 1, \dots, n \\ x, s &\geq 0 \end{aligned}$$

besitzen eine Lösung  $(x^*, \lambda^*, \mu^*)$ .

**Beweis:** "(a)  $\Leftrightarrow$  (c)"

Das primale Problem (3.16) ist ein konvexes Optimierungsproblem mit linearen Nebenbedingungen. Korollar 3.17 besagt, dass  $x^* \in \mathbb{R}^n$  genau dann Lösung von (3.16) ist, wenn es einen KKT-Punkt für (3.16) gibt.

KKT-Bedingungen für (3.16):

$$(3.16) \iff \min f(x) \quad \text{u.d.N.} \quad g(x) \leq 0, \quad h(x) = 0$$

mit

$$\begin{aligned} f: \mathbb{R}^n &\rightarrow \mathbb{R}, \quad f(x) = c^T x, \quad \nabla f(x) = c \\ g: \mathbb{R}^n &\rightarrow \mathbb{R}^n, \quad g(x) = -x, \quad \nabla g(x) = -I \\ h: \mathbb{R}^n &\rightarrow \mathbb{R}^m, \quad h(x) = Ax - b, \quad \nabla h(x) = A \end{aligned}$$

$$\text{i) } \nabla_x \mathcal{L}(x, \tilde{\lambda}, \tilde{\mu}) \stackrel{!}{=} 0$$

$$\begin{aligned} \Leftrightarrow \nabla f(x) + \sum_{i=1}^n \tilde{\lambda}_i \nabla g_i(x) + \sum_{j=1}^m \tilde{\mu}_j \nabla h_j(x) &= 0, \quad \tilde{\lambda} \in \mathbb{R}^n, \quad \tilde{\mu} \in \mathbb{R}^m \\ \Leftrightarrow c + \sum_{i=1}^n \tilde{\lambda}_i (-e_i) + \sum_{j=1}^m \tilde{\mu}_j a_j &= 0 \end{aligned}$$

mit  $e_i = (0, \dots, 0, 1, 0, \dots, 0)^T \in \mathbb{R}^n$  und  $a_j \in \mathbb{R}^n = j$ -te Zeile von  $A$ .

$$\Leftrightarrow A^T \tilde{\mu} - \tilde{\lambda} + c = 0 \Leftrightarrow \tilde{\lambda} - A^T \tilde{\mu} = c$$

ii)  $h(x) = 0 \Leftrightarrow Ax = b$

iii)

$$\begin{aligned} \tilde{\lambda} &\geq 0 \quad , \quad g(x) \leq 0 \quad , \quad \tilde{\lambda}^T g(x) = 0 \\ \Leftrightarrow \tilde{\lambda} &\geq 0 \quad , \quad x \geq 0 \quad , \quad \sum_{i=1}^n \tilde{\lambda}_i x_i = 0 \\ \Leftrightarrow \tilde{\lambda}_i x_i &= 0 \quad , \quad i = 1, \dots, n \end{aligned}$$

Definiere nun  $\lambda := -\tilde{\mu} \in \mathbb{R}^m$  und  $s := \tilde{\lambda} \in \mathbb{R}^n$ , so ergibt i)-iii) die Bedingungen (c).

"(b)  $\Leftrightarrow$  (c)" Analog als Übung.

Beachte: (3.18) ist ein Maximierungsproblem !

□

**Bemerkung:** Satz 3.26 sagt nichts über die Existenz von Lösungen aus !

### Beispiel 3.27

$$\min x_1 + x_2 \quad \text{u.d.N.} \quad x_1 + x_2 = -1 \quad , \quad x_1, x_2 \geq 0$$

hat keinen zulässigen Punkt und daher keine Lösung.

**Frage:** Wann hat ein lineares Programm eine Lösung ?

$\leftrightarrow$  Dualitätssätze

### Satz 3.28 (Schwache Dualität)

Sei  $x \in \mathbb{R}^n$  ein zulässiger Punkt des primalen Problems (3.16) und  $(\lambda, s) \in \mathbb{R}^m \times \mathbb{R}^n$  ein zulässiger Punkt des dualen Problems (3.18). Dann gilt:

$$b^T \lambda \leq c^T x.$$

**Beweis:** Da  $x$  und  $(\lambda, s)$  zulässig sind ergibt sich

$$b^T \lambda = (Ax)^T \lambda = x^T (A^T \lambda) = x^T (c - s) \leq c^T x$$

denn es ist  $x^T s \geq 0$  wegen  $x, s \geq 0$ .

□

Satz 3.28 liefert eine untere Schranke für den Wert der Zielfunktion  $f(x) = c^T x$ . Sei

$$\inf(P) := \inf \{ c^T x : Ax = b, x \geq 0 \}$$

und

$$\sup(D) := \sup \{ b^T \lambda : A^T \lambda + s = c, s \geq 0 \},$$

so gilt also

$$\sup(D) \leq \inf(P).$$

Wir setzen  $\inf(P) := \infty$  bzw.  $\sup(D) := -\infty$ , falls (3.16) bzw. (3.18) keine zulässigen Punkte besitzt.

**Korollar 3.29** Seien  $x \in \mathbb{R}^n$  ein zulässiger Punkt für (3.16) und  $(\lambda, s) \in \mathbb{R}^m \times \mathbb{R}^n$  zulässig für (3.18). Weiter gelte

$$c^T x = b^T \lambda.$$

Dann ist  $x$  Lösung von (3.16) und  $(\lambda, s)$  Lösung von (3.18).

**Beweis:** Sei  $\xi \in \mathbb{R}^n$  ein beliebiger zulässiger Vektor von (3.16). Dann gilt mit Satz 3.28

$$c^T x = b^T \lambda \leq c^T \xi$$

Beweis für  $(\lambda, s)$  analog. □

**Zwischenfazit:** Die schwache Dualität besagt:  $c^T x - b^T \lambda \geq 0$ . und Korollar 3.29:  $c^T x - b^T \lambda = 0 \Rightarrow x$  ist Lösung von (3.16) und  $(\lambda, s)$  von (3.18), wobei  $s \in \mathbb{R}^n$  so gewählt wurde, dass  $(\lambda, s)$  zulässig ist. Es ist dann  $\inf(P) = \sup(D)$ . Gilt  $\inf(P) > \sup(D)$ , so spricht man von einer *Dualitätslücke*.

**Satz 3.30** (*Starke Dualität*)

Besitzt (3.16) eine Lösung  $x$  oder hat das duale Problem (3.16) eine Lösung  $(\lambda, s)$ , so gilt  $\inf(P) = \sup(D)$ , d.h. es existiert keine Dualitätslücke.

**Beweis:** Sei  $x$  eine Lösung von (3.16). Satz 3.26 (Optimalitätsbedingungen) garantiert die Existenz von  $(x, \lambda, s) \in \mathbb{R}^n \times \mathbb{R}^m \times \mathbb{R}^n$  mit

$$0 = s^T x = (c - A^T \lambda)^T x = c^T x - \lambda^T (Ax) = c^T x - b^T \lambda$$

Mit Korollar 3.29 folgt die Behauptung.

Analog argumentiert man für das duale Problem. □

**Satz 3.31** (*Existenzsatz*)

a) Ist  $\inf(P) \in \mathbb{R}$ , so besitzt das primale Programm (3.16) eine Lösung.

b) Ist  $\sup(D) \in \mathbb{R}$ , so besitzt das duale Programm (3.18) eine Lösung.

**Beweis:** a) Sei  $f^* := \inf(P) \in \mathbb{R}$

Annahme: Es gibt kein primal zulässiges  $x \in \mathbb{R}^n$  mit  $f^* = c^T x$ , also es gelte

$$c^T x > f^* \quad \text{für alle } x \geq 0, Ax = b. \quad (3.19)$$

Also besitzt das System

$$B^T x := \begin{pmatrix} c^T \\ -A \end{pmatrix} x = \begin{pmatrix} f^* \\ -b \end{pmatrix} =: h \in \mathbb{R}^{m+1}$$

keine Lösung  $x \geq 0$ ,  $B^T \in \mathbb{R}^{(m+1) \times n}$ .

Lemma von Farkas  $\Rightarrow$

Es gibt ein  $d \in \mathbb{R}^{m+1}$  mit  $h^T d < 0$  und  $Bd \geq 0$ .

Sei  $d = (\alpha, \lambda)$ ,  $d \in \mathbb{R}$ ,  $\lambda \in \mathbb{R}^m$ , so folgern wir

$$\alpha f^* - b^T \lambda < 0 \quad (3.20)$$

sowie



$$\alpha c - A^T \lambda \geq 0. \quad (3.21)$$

Ist  $x$  ein primal zulässiger Vektor (der wegen  $\inf(P) \in \mathbb{R}$  existiert), so folgt aus (3.21)

$$\begin{aligned} \alpha c^T x - x^T A^T \lambda &= \alpha c^T x - (Ax)^T \lambda \\ &= \alpha c^T x - b^T \lambda \geq 0 \end{aligned}$$

und aus (3.20) dann

$$\alpha c^T x \geq b^T \lambda > \alpha f^*,$$

woraus wir  $\alpha > 0$  schließen (vgl.(3.19)).

Man erhält also

$$f^* < b^T \bar{\lambda} \quad \text{und} \quad A^T \bar{\lambda} \leq c$$

mit  $\bar{\lambda} := \lambda/\alpha$ .

Mit  $\bar{s} := c - A^T \bar{\lambda}$  ist  $(\bar{\lambda}, \bar{s})$  dual zulässig mit  $b^T \bar{\lambda} > \inf(P)$

Widerspruch zu Satz 3.28 !

b) analog.

□

**Korollar 3.32** *Sind das primale und das duale Programm beide zulässig, so haben beide Programme eine optimale Lösung.*

**Beweis:** Aus der schwachen Dualität und der Zulässigkeit folgt

$$-\infty < \sup(D) \leq \inf(P) < +\infty$$

und mit Satz 3.31 die Behauptung.

□

**ACHTUNG:** Der Existenzsatz 3.31 gilt nur für lineare Probleme !

Der optimale Wert des Problems

$$\min f(x) = e^x \quad , \quad x \in \mathbb{R}$$

ist 0 und wird von keinem  $x \in \mathbb{R}$  angenommen.

Die Konstruktion von Innere-Punkte-Verfahren beruht auf dem Prinzip der Dualität.



## Lineare Optimierung II: Innere – Punkte – Methoden

**Ziel:** Alternative zum Simplex-Verfahren für große lineare Programme.

Betrachte das primale Programm

$$\min c^T x \quad \text{u.d.N.} \quad Ax = b, \quad x \geq 0 \quad (4.1)$$

und das zugehörige duale Programm

$$\max b^T \lambda \quad \text{u.d.N.} \quad A^T \lambda + s = c, \quad s \geq 0 \quad (4.2)$$

$A \in \mathbb{R}^{m \times n}$ ,  $b \in \mathbb{R}^m$ ,  $c \in \mathbb{R}^n$ .

Satz 3.26 besagt, dass (4.1) und (4.2) äquivalent sind zu den Optimalitätsbedingungen

$$\left\{ \begin{array}{l} A^T \lambda + s = c \\ Ax = b \\ x_i s_i = 0, \quad i = 1, \dots, n \\ x, s \geq 0 \end{array} \right. \quad (4.3)$$

**Idee:** Wir stören (4.3) durch ein  $\tau > 0$  gemäß

$$\left\{ \begin{array}{l} A^T \lambda + s = c \\ Ax = b \\ x_i s_i = \tau, \quad i = 1, \dots, n \\ x, s \geq 0, \end{array} \right. \quad (4.4)$$

lösen (4.4) und lassen  $\tau \rightarrow 0$  konvergieren.

Die Abbildung  $\tau \mapsto (x_\tau, \lambda_\tau, s_\tau)$  heißt der *zentrale Pfad*, wobei  $(x_\tau, \lambda_\tau, s_\tau)$  eine Lösung von (4.4) ist.

**Problem:** Sind die zentralen Pfad-Bedingungen (4.4) überhaupt lösbar ?

Gegenbeispiel: Das lineare Programm

$$\min x_1 + x_2 \quad \text{u.d.N.} \quad x_1 + x_2 = 0, \quad x_1, x_2 \geq 0$$

hat eine Lösung, die zugehörigen zentralen Pfad-Bedingungen (4.4) nicht.

**Ausweg:** Definiere zu (4.1) bzw. (4.2) logarithmische Barriere-Probleme

$$\min c^T x - \tau \sum_{i=1}^n \log(x_i) \quad \text{u.d.N.} \quad Ax = b, \quad x > 0 \quad (4.5)$$

$$\max b^T \lambda + \tau \sum_{i=1}^n \log(s_i) \quad \text{u.d.N} \quad A^T \lambda + s = c, \quad s > 0 \quad (4.6)$$

und zeige:

Hat (4.5) oder (4.6) eine Lösung, so auch die zentralen Pfad-Bedingungen.

**Satz 4.1** Sei  $\tau > 0$  gegeben. Dann sind äquivalent:

- (a) Das primale Barriere-Problem (4.5) hat eine Lösung  $x_\tau$ .
- (b) Das duale Barriere-Problem (4.6) hat eine Lösung  $(\lambda_\tau, s_\tau)$ .
- (c) Die zentralen Pfad-Bedingungen (4.4) besitzen eine Lösung  $(x_\tau, \lambda_\tau, s_\tau)$ .

**Beweis:** Die Funktion  $f : \{x \in \mathbb{R}^n : x > 0\} \rightarrow \mathbb{R}$ ,  $f(x) = c^T x - \tau \sum_{i=1}^n \log x_i$  ist konvex und  $\nabla f(x) = c - \tau X^{-1} e$  mit  $X = \text{diag}(x_1, \dots, x_n)$  und  $e = (1, 1, \dots, 1)^T \in \mathbb{R}^n$ . Das Problem (4.5) ist damit ein konvexes Problem mit linearen Nebenbedingungen.

Korollar 3.17  $\Rightarrow$   $x_\tau$  ist genau dann eine Lösung von (4.5), wenn die KKT-Bedingungen erfüllt sind:

$$\begin{aligned} \nabla f(x_\tau) + \sum_{j=1}^m \tilde{\lambda}_j \nabla h_j(x_\tau) + \sum_{i=1}^n \tilde{\mu}_i \nabla g_i(x_\tau) &= 0 \\ \Leftrightarrow c - \tau X_\tau^{-1} e + A^T \tilde{\lambda} &= 0 \end{aligned}$$

da wegen  $-x < 0$ ,  $g_i(x)$  stets inaktiv ist und damit  $\tilde{\mu}_i = 0$ ,  $i = 1, \dots, n$  gilt. Außerdem ist

$$h(x) = 0 \Leftrightarrow Ax = b, \quad x > 0.$$

Definiere  $s_\tau := \tau X_\tau^{-1} e > 0$ ,  $\lambda_\tau := -\tilde{\lambda}$ .

So erhalten wir insgesamt

$$A^T \lambda_\tau + s_\tau = c, \quad Ax_\tau = b, \quad (x_\tau)_i (s_\tau)_i = \tau, \quad s_\tau, x_\tau > 0.$$

Das sind die zentralen Pfad-Bedingungen (4.4) für  $(x_\tau, \lambda_\tau, s_\tau)$ .

(b)  $\Leftrightarrow$  (c) ähnlich !

□

**Fazit:** Um die Existenz einer Lösung von (4.4) zu beweisen, genügt es die Existenz einer Lösung von (4.5) nachzuweisen.

Wir benötigen dazu noch zwei weitere Bezeichnungen.

Wir nennen

$$\mathcal{F} := \{(x, \lambda, s) : Ax = b, A^T \lambda + s = c, x, s \geq 0\}$$

die *primal-dual zulässige Menge* und

$$\mathcal{F}^0 := \{(x, \lambda, s) \in \mathcal{F} : x > 0, s > 0\}$$

die *primal-dual strickt zulässige Menge*.

**Bemerkung:**  $\mathcal{F}^0 \neq \emptyset$  ist eine notwendige Bedingung dafür, dass das primale Barriere-Problem eine Lösung hat. Denn ist  $(x_\tau, \lambda_\tau, s_\tau)$  eine Lösung von (4.4), so gilt offenbar  $(x_\tau, \lambda_\tau, s_\tau) \in \mathcal{F}^0$ . Wäre  $\mathcal{F}^0 = \emptyset$  kann (4.5) nach Satz 4.1 keine Lösung haben.

Diese Bedingung ist auch hinreichend !

**Satz 4.2** Sei  $\mathcal{F}^0 \neq \emptyset$ . Dann besitzt das primale Barriere-Problem (4.5) für jedes  $\tau > 0$  eine Lösung.

**Beweis:** Sei  $\tau > 0$  und  $(\hat{x}, \hat{\lambda}, \hat{s}) \in \mathcal{F}^0$  gegeben, d.h.

$$\begin{cases} A^T \hat{\lambda} + \hat{s} = c \\ A \hat{x} = b \\ \hat{x}, \hat{s} > 0. \end{cases} \quad (4.7)$$

Sei weiter

$$B_\tau(x) := c^T x - \tau \sum_{i=1}^n \log(x_i),$$

$$\mathcal{L}_\tau := \{x \in \mathbb{R}^n : Ax = b, x \geq 0, B_\tau(x) \leq B_\tau(\hat{x})\}.$$

Es zeigt sich, dass aus  $B_\tau(x) \leq B_\tau(\hat{x})$  schon  $x > 0$  folgt.

Wir wollen zeigen:  $\mathcal{L}_\tau$  ist kompakt.

Offenbar:  $\mathcal{L}_\tau$  ist abgeschlossen.

Noch zu zeigen:  $\mathcal{L}_\tau$  ist beschränkt.

Für  $x \in \mathcal{L}_\tau$  gilt mit (4.7):

$$\begin{aligned} B_\tau &= c^T x - \tau \sum_{i=1}^n \log(x_i) \\ &= c^T x - \hat{\lambda}^T (Ax - b) - \tau \sum_{i=1}^n \log(x_i) \\ &= c^T x - x^T A^T \hat{\lambda} + b^T \hat{\lambda} - \tau \sum_{i=1}^n \log(x_i) \\ &= c^T x - x^T (c - \hat{s}) + b^T \hat{\lambda} - \tau \sum_{i=1}^n \log(x_i) \\ &= x^T \hat{s} + b^T \hat{\lambda} - \tau \sum_{i=1}^n \log(x_i) \\ &\leq B_\tau(\hat{x}) \end{aligned}$$

Also:

$$\sum_{i=1}^n (\hat{s}_i x_i - \tau \log(x_i)) \leq B_\tau(\hat{x}) - b^T \hat{\lambda} := k$$

wobei  $k$  eine Konstante ist.

Die Funktionen  $k_i(x_i) := \hat{s}_i x_i - \tau \log(x_i)$  erfüllen

$$\lim_{x_i \rightarrow +\infty} k_i(x_i) = \lim_{x_i \rightarrow 0^+} k_i(x_i) = +\infty$$

und sind stetig und konvex (also nach unten beschränkt).

Also ist  $\mathcal{L}_\tau$  beschränkt und damit kompakt.

$$\Rightarrow \min B_\tau \quad \text{u.d.N.} \quad x \in \mathcal{L}_\tau$$

hat eine Lösung  $x_\tau > 0$ . Wegen  $x_\tau \in \mathcal{L}_\tau$  ist dies auch eine Lösung von (4.5).  $\square$

**Satz 4.3** Es sei  $\mathcal{F}^0 \neq \emptyset$ . Dann besitzen die Bedingungen (4.4) für jedes  $\tau > 0$  eine Lösung  $(x_\tau, \lambda_\tau, s_\tau)$ , wobei  $x_\tau$  und  $s_\tau$  eindeutig bestimmt sind. Besitzt  $A$  vollen Rang, so ist auch  $\lambda_\tau$  eindeutig bestimmt.

**Beweis:** Da  $\mathcal{F}^0 \neq \emptyset$  folgt mit Satz 4.2, dass (4.5) eine Lösung  $x_\tau$  besitzt für alle  $\tau > 0$ . Daraus folgt wiederum, dass die Bedingungen (4.4) eine Lösung  $(x_\tau, \lambda_\tau, s_\tau)$  besitzen für alle  $\tau > 0$  (Satz 4.1).

Da  $B_\tau(x) = c^T x - \tau \sum_{i=1}^n \log(x_i)$  strikt konvex ist, ist  $x_\tau$  eindeutig bestimmt.

$\Rightarrow s_\tau$  eindeutig bestimmt wegen  $(x_\tau)_i (s_\tau)_i = \tau$ ,  $i = 1, \dots, n$ .

Besitzt  $A$  vollen Rang, so ist auch  $\lambda_\tau$  eindeutig bestimmt aus  $A^T \lambda_\tau + s_\tau = c$  und zwar ist  $\lambda_\tau = (AA^T)^{-1} A(c - s_\tau)$ .

□

**Ziel:** Anwendung des Newton-Verfahrens auf die zentralen Pfad- Bedingungen (4.4).

**Newton-Verfahren:** Sei  $F \in \mathcal{C}^1(\mathbb{R}^p, \mathbb{R}^p)$  gegeben.

Zu lösen:  $F(\omega) = 0$  durch Iterationsverfahren. Ist  $\omega^k$  gegeben so verwendet man die Linearisierung  $F_k(\omega)$  von  $F$  um  $\omega^k$ , d.h

$$F_k(\omega) := F(\omega^k) + F'(\omega^k)(\omega - \omega^k).$$

Die Forderung  $F_k(\omega^{k+1}) = 0$  führt zu:

$$\omega^{k+1} := \omega^k - F'(\omega^k)^{-1} F(\omega^k).$$

Also: Ist  $\omega^0$  gegeben, so berechne  $\omega^{k+1} := \omega^k + \Delta \omega^k$  mit

$$F'(\omega^k) \Delta \omega^k = -F(\omega^k).$$

Häufig setzt man

$$\omega^{k+1} = \omega^k + t_k \Delta \omega^k$$

mit  $t_k > 0$ .

**Hier:**

$$F_\tau(\omega) := F_\tau(x, \lambda, s) := \begin{pmatrix} A^T \lambda + s - c \\ Ax - b \\ X S e - \tau e \end{pmatrix},$$

mit  $X = \text{diag}(x_1, \dots, x_n)$ ,  $S = \text{diag}(s_1, \dots, s_n)$ ,  $e = (1, \dots, 1)^T$ .

Also:  $F_\tau(x, \lambda, s) = 0 \Leftrightarrow (x, \lambda, s)$  genügt den Bedingungen (4.4) (bis auf  $x, s > 0$ )

Es ist dann

$$F'_\tau(x, \lambda, s) = \begin{pmatrix} 0 & A^T & I \\ A & 0 & 0 \\ S & 0 & X \end{pmatrix} \in \mathbb{R}^{(2n+m) \times (2n+m)}. \quad (4.8)$$

**Frage:** Wann existiert  $F'_\tau(x, \lambda, s)^{-1}$  ?

**Satz 4.4** Sei  $\omega := (x, \lambda, s) \in \mathbb{R}^n \times \mathbb{R}^m \times \mathbb{R}^n$  ein gegebener Vektor mit  $x, s > 0$ . Die Matrix  $A \in \mathbb{R}^{m \times n}$  habe vollen Rang. Dann ist  $F'_\tau(\omega)$  für jedes  $\tau > 0$  regulär.

**Beweis:** Sei  $p = (p^{(1)}, p^{(2)}, p^{(3)}) \in \mathbb{R}^n \times \mathbb{R}^m \times \mathbb{R}^n$  gegeben mit

$$F'_\tau(x, \lambda, s)p = 0.$$

Aus (4.8) lesen wir ab:

$$A^T p^{(2)} + p^{(3)} = 0, \quad (4.9)$$

$$A p^{(1)} = 0, \quad (4.10)$$

$$S p^{(1)} + X p^{(3)} = 0. \quad (4.11)$$

Aus (4.9) und (4.10) erhalten wir

$$0 = p^{(1)T} A^T p^{(2)} + p^{(1)T} p^{(3)} = p^{(1)T} p^{(3)}.$$

Aus (4.11) leiten wir ab:

$$p^{(3)} = -X^{-1} S p^{(1)} \quad (4.12)$$

und somit

$$p^{(1)T} X^{-1} S p^{(1)} = 0.$$

Da  $X^{-1} S$  positiv definit ist, gilt dann

$$p^{(1)} = 0$$

und aus (4.12) folgt  $p^{(3)} = 0$ .

Da  $A$  vollen Rang hat, erhalten wir aus (4.9) schließlich  $p^{(2)} = 0$ , also  $p = 0$ .  $\square$

**Bemerkung:** Die Iterierten  $(x^k, \lambda^k, s^k)$  werden stets so bestimmt, dass  $x^k, s^k > 0$  gilt.

**Innere Punkte-Methode:** (vorläufige Version)

Zu gegebenen  $\omega^k = (x^k, \lambda^k, s^k)$  und  $\tau_k > 0$  löse

$$F'_{\tau_k}(\omega^k) \triangle \omega^k = -F_{\tau_k}(\omega^k),$$

also

$$\begin{pmatrix} 0 & A^T & I \\ A & 0 & 0 \\ S^k & 0 & X^k \end{pmatrix} \begin{pmatrix} \Delta x^k \\ \Delta \lambda^k \\ \Delta s^k \end{pmatrix} = \begin{pmatrix} -A^T \lambda^k - s^k + c \\ -Ax^k + b \\ -X^k S^k e + \tau_k e \end{pmatrix} \quad (4.13)$$

mit

$$\begin{aligned} X^k &= \text{diag}(x_1^k, \dots, x_n^k), \\ S^k &= \text{diag}(s_1^k, \dots, s_n^k), \\ \omega^{k+1} &:= \omega^k + t_k \triangle \omega^k \quad \text{für ein } t_k > 0. \end{aligned} \quad (4.14)$$

**Lemma 4.5.** Gelten für  $\omega^0 = (x^0, \lambda^0, s^0)$  die Beziehungen  $A^T \lambda^0 + s^0 = c$ ,  $Ax^0 = b$ , so folgt schon für alle aus (4.13), (4.14) gewonnenen  $\omega^k = (x^k, \lambda^k, s^k)$ , dass

$$A^T \lambda^k + s^k = c \quad , \quad Ax^k = b.$$

**Beweis:** Die Behauptung gelte für ein  $k \geq 0$ .

Aus (4.13), 1. Zeile, folgt dann

$$A^T \triangle \lambda^k + \triangle s^k = 0.$$

(4.14) garantiert dann:

$$\begin{aligned} A^T \lambda^{k+1} + s^{k+1} - c &= A^T (\lambda^k + t_k \triangle \lambda^k) + (s^k + t_k \triangle s^k) - c \\ &= A^T \lambda^k + s^k - c + t_k (A^T \triangle \lambda^k + \triangle s^k) \\ &= 0. \end{aligned}$$

Unter Verwendung der 2. Zeile von (4.13) erhält man analog:

$$Ax^{k+1} = Ax^k + t_k A \triangle x^k = b.$$

$\square$

Wählen wir also ein  $\omega^0 = (x^0, \lambda^0, s^0)$  aus

$$\mathcal{F}^0 := \{ (x, \lambda, s) : Ax = b, A^T \lambda + s = c, x, s > 0 \}$$

so können wir die rechte Seite von (4.13) durch  $(0, 0, -X^k S^k e + \tau_k e)$  ersetzen.

**ALGORITHMUS:** (allgemeine Innere Punkte-Methode)

(S.0) Wähle  $\omega^0 := (x^0, \lambda^0, s^0) \in \mathcal{F}^0$ ,  $\varepsilon \in (0, 1)$  und setze  $k := 0$ .

(S.1) Ist  $\mu_k := (x^k)^T s^k / n \leq \varepsilon \rightarrow$  STOP

(S.2) Wähle  $\sigma_k \in [0, 1]$  und bestimme die Lösung  $\Delta \omega^k := (\Delta x^k, \Delta \lambda^k, \Delta s^k)$  von

$$\begin{pmatrix} 0 & A^T & I \\ A & 0 & 0 \\ S^k & 0 & X^k \end{pmatrix} \begin{pmatrix} \Delta x^k \\ \Delta \lambda^k \\ \Delta s^k \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \\ -X^k S^k e + \sigma_k \mu_k e \end{pmatrix}.$$

(S.3) Setze

$$\omega^{k+1} := \omega^k + t_k \Delta \omega^k, \quad k \leftarrow k + 1$$

und gehe zu (S.1).

$t_k$  bezeichne eine Schrittweite, die  $x^{k+1} > 0$ ,  $s^{k+1} > 0$  garantiert.

### Bemerkungen:

a) Aufgrund von Lemma 4.5 und (S.3) ist nur noch die Bedingung

$$(x^k)^T s^k \rightarrow 0 \quad \text{für } k \rightarrow \infty$$

zu garantieren, um alle Optimalitätsbedingungen (4.3) zu erfüllen.

Da  $\omega^k \in \mathcal{F}^0$  für alle  $k$  gilt, haben wir

$$\begin{aligned} (x^k)^T s^k &= (x^k)^T (c - A^T \lambda^k) \\ &= c^T x^k - (Ax^k)^T \lambda^k \\ &= c^T x^k - b^T \lambda^k. \end{aligned}$$

Der Ausdruck  $(x^k)^T s^k$  ist also die Dualitätslücke,  $\mu^k = (x^k)^T s^k / n$  somit die gewichtete Dualitätslücke.

b) Die Wohldefiniertheit des Algorithmus, wenn  $A$  vollen Rang hat, wird durch die Existenz eines  $t_k$  wie in (S.3) und durch Satz 4.4 garantiert.

c) Der Algorithmus beinhaltet 2 Freiheitsgrade. Die Wahl von  $t_k$  und von  $\sigma_k$ . Dabei bedeutet  $\sigma_k = 0$  ein Newtonschritt für die Optimalitätsbedingungen (4.3), führt aber zu kleinen Schrittweiten  $t_k$ .

$\sigma_k = 1$  bringt uns weiter von (4.3) weg, läßt aber größere Schrittweiten  $t_k$  zu. Das Produkt  $\mu_k \sigma_k$  spielt die Rolle von  $\tau_k$ .

Spezielle Wahlen von  $t_k, \sigma_k$  führen zu *Pfad-Verfolgungs-Verfahren*.



## Nichtlineare Optimierung I: Nichtrestringierte Probleme

### 5.1 Abstiegsmethoden

Wir betrachten das Problem

$$\min f(x) \tag{5.1}$$

mit  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  stetig differenzierbar.

Wir nennen (5.1) ein *nichtrestringiertes Minimierungsproblem*.

Sei

$$g(x) := \nabla f(x).$$

Betrachte für eine Richtung  $d \in \mathbb{R}^n$ ,  $\|d\| = 1$ , die differenzierbare Funktion  $\varphi : \mathbb{R} \rightarrow \mathbb{R}$  mit

$$\varphi(t) := f(x + td).$$

Dann ist  $\varphi'(0) = \nabla f(x)^T d = g(x)^T d$  und  $|\varphi'(0)| \leq \|g(x)\|$ . Demnach wird  $\varphi'(0)$  für  $d := \frac{g(x)}{\|g(x)\|}$  maximal und für  $d := \frac{-g(x)}{\|g(x)\|}$  minimal, falls  $g(x) \neq 0$  ist.

Da  $\varphi'(0)$  die Änderung von  $f$  in  $x$  beschreibt, ist  $g(x)$  die Richtung des steilsten Auf- und  $-g(x)$  die Richtung des steilsten Abstiegs.

Ist  $g(x) = 0$ , so ist  $x$  stationärer Punkt und nach Lemma 3.4 ein Kandidat für ein Minimum.

**1. Idee:** Sei  $x^0$  gegeben.

Löse

$$x'(t) = -g(x(t)) \quad , \quad x(0) = x^0.$$

Längs der Kurve  $x(t)$  nehmen die Funktionswerte streng monoton mit wachsenden  $t$  ab.

Beweis: Ist  $\varphi(t) = f(x(t))$ , so gilt

$$\varphi'(t) = g(x(t))x'(t) = -\langle g(x), g(x) \rangle \leq 0.$$

Problem:  $\lim_{t \rightarrow \infty} x(t)$  muß nicht existieren.

**2. Idee:** Sei  $x^0 \in \mathbb{R}^n$  gegeben sowie eine Suchrichtung  $s^0 \in \mathbb{R}^n$ ,  $\|s^0\| = 1$ .

Bezeichne

$$\varphi(t) := f(x^0 + ts^0)$$

und untersuche das Verhalten von  $\varphi$  für  $t \geq 0$ . Ziel ist es ein  $\lambda_0 > 0$  zu finden, so dass

$$\varphi(\lambda_0) = f(x^0 + \lambda_0 s^0) < f(x^0) = \varphi(0)$$

gilt. Dabei soll garantiert werden, dass  $\lambda_0$  nicht "zu klein" ist ( $\rightarrow$  sonst zu aufwendig).

Iteriere so lang bis  $g(x^k) = 0$  für ein  $x^k \in \mathbb{R}^n$  gilt.

Da nur die Gerade  $x^k + ts^k$  in Betracht gezogen wird, spricht man von *line search*.

#### ALGORITHMUS: (line search)

Wähle  $0 < c_2 \leq c_1 < 1$  (in der Regel  $c_1 \leq \frac{1}{2}$ ) und  $0 < \gamma \leq 1$ .

Gegeben sei  $x^0 \in \mathbb{R}^n$ .

Für  $k = 0, 1, \dots$

- 1) Ist  $g_k := g(x^k) = 0 \rightarrow$  STOP
- 2) Sonst wähle Suchrichtung  $s^k \in \mathbb{R}^n$ ,  $\|s^k\| = 1$  und  $-g_k^T s^k \geq \gamma \|g_k\|_2$
- 3) Bestimme eine Schrittweite  $\lambda_k > 0$  und  $x^{k+1} := x^k + \lambda_k s^k$  so, dass

$$\begin{cases} f(x^{k+1}) \leq f(x^k) + \lambda_k c_1 g_k^T s^k \\ g_{k+1}^T s^k \geq c_2 g_k^T s^k \end{cases} \quad (5.2)$$

#### Bemerkungen:

a) Schritt 2 verlangt, dass der Winkel zwischen  $s^k$  und der steilsten Abstiegsrichtung  $< 90^\circ$  ist. Für  $\gamma = 1$  kommt nur  $s^k = -g(x^k)/\|g(x^k)\|$  in Frage.

b) Der erste Teil von (5.2) garantiert wegen  $\lambda_k c_1 g_k^T s^k < 0$ , dass

$$f(x^{k+1}) < f(x^k)$$

gilt. Wegen

$$g_{k+1}^T s^k \geq c_2 g_k^T s^k \geq c_1 g_k^T s^k \geq \frac{f(x^{k+1}) - f(x^k)}{\lambda_k} \xrightarrow{\lambda_k \searrow 0} g_k^T s^k$$

ist der zweite Teil in (5.2) für sehr kleine  $\lambda_k > 0$  nicht mehr erfüllt  $\rightarrow \lambda_k$  nicht "zu klein".

c) Es wurde offengelassen, wie man  $\lambda_k$  findet.

Eine Möglichkeit ist die *exakte line search*.

$$\lambda_k := \operatorname{argmin} \{ f(x^k + \lambda s^k) : \lambda > 0 \}.$$

**Satz 5.1** Sei  $f \in \mathcal{C}^2(\mathbb{R}^n)$ ,  $x^0 \in \mathbb{R}^n$  und  $K := \{x : f(x) \leq f(x^0)\}$  kompakt. Dann läßt sich der Algorithmus anwenden und bricht entweder nach endlich vielen Schritten mit einem  $x^k$  mit  $g(x^k) = 0$  ab, wobei

$$f(x^k) < f(x^{k-1}) < \dots < f(x^0)$$

ist oder erzeugt eine unendliche Folge  $\{x^k\}_k$  mit

- 1)  $f(x^{k+1}) < f(x^k)$ ,  $k \geq 0$ ,
- 2)  $\{x^k\}_k$  besitzt mindestens einen Häufungspunkt  $x^*$ ,
- 3) jeder Häufungspunkt  $x^*$  erfüllt  $g(x^*) = 0$ .

Die Menge  $K$  heißt Niveaumenge.

### CG-Verfahren

**Ziel:** Abstiegsverfahren "mit Gedächtnis" für konvexe quadratische Funktionen.

Also sei

$$f(x) = \frac{1}{2}x^T A x + b^T x + c$$

mit  $A \in \mathbb{R}^{n \times n}$  symmetrisch positiv definit. Dann ist  $f$  konvex (Übung).

**Definition 5.2.** Sei  $A \in \mathbb{R}^{n \times n}$  symmetrisch positiv definit. Die Vektoren  $s_1, \dots, s_m \in \mathbb{R}^n$  heißen  $A$ -konjugiert, falls  $s_i \neq 0$  für  $1 \leq i \leq m$  und  $s_i^T A s_j = 0$  für  $i \neq j$  gilt.

**Bemerkung:**  $A$ -konjugierte Vektoren  $s_i, i = 1, \dots, m$ , sind stets linear unabhängig. Denn aus  $\sum_{i=1}^m \alpha_i s_i = 0$  folgt

$$0 = s_k A^T \left( \sum_{i=1}^m \alpha_i s_i \right) = \alpha_k \underbrace{s_k^T A s_k}_{>0}$$

und damit  $\alpha_k = 0, k = 1, \dots, m$ .

**Satz 5.3** Die Vektoren  $s_0, \dots, s_{n-1}$  seien  $A$ -konjugiert und  $x^0 \in \mathbb{R}^n$  beliebig. Für  $k = 0, 1, \dots, n-1$  sei  $x^{k+1} := x^k + \lambda_k s_k$  mit

$$\lambda_k := \operatorname{argmin}_{\lambda \in \mathbb{R}} f(x^k + \lambda s_k).$$

Dann gilt

$$f(x^n) = \min_{x \in \mathbb{R}^n} f(x)$$

**Beweis:** Übung.

Also:  $x^n$  ist Optimallösung.

**Idee:** Verwende  $A$ -konjugierte Suchrichtungen.

### ALGORITHMUS: (CG-Verfahren)

Es bezeichne  $g(x) := \nabla f(x) = Ax + b$  den Gradienten von  $f$ .

Start: Wähle  $x^0 \in \mathbb{R}^n$ , setze  $g_0 := g(x^0), s^0 := -g_0$ .

Für  $i = 0, 1, \dots$

- 1) Ist  $g_i = g(x^i) = 0 \rightarrow$  STOP  
 $x^i$  ist Minimum von  $f$ .
- 2) Sonst setze  $x^{i+1} := x^i + \lambda_i s^i$ , wobei gilt

$$\lambda_i := \operatorname{argmin}_{\lambda \geq 0} f(x^i + \lambda s^i) = -\frac{g_i^T s_i}{s_i^T A s_i}$$

- 3) Berechne  $\gamma_{i+1} := g_{i+1}^T g_{i+1} / g_i^T g_i$  und setze  $s_{i+1} := -g_{i+1} + \gamma_{i+1} s_i$ .

- Bemerkung:** a)  $\lambda_i$  ist wohldefiniert, da  $s_i^T A s_i > 0$  gilt für  $g_i \neq 0$ .  
 b)  $\gamma_{i+1}$  wurde gerade so gewählt, dass die Richtungen  $s_i, i = 0, 1, \dots$   $A$ -konjugiert sind. Nach Satz 5.3 stoppt das Verfahren daher nach endlich vielen Iterationen mit der exakten Lösung (wenn Rundungsfehler unberücksichtigt bleiben).  
 c) Man kann zeigen, dass

$$\frac{\|x^k - x^*\|_A}{\|x^0 - x^*\|_A} \leq 2 \left( 1 - \frac{2}{\sqrt{\kappa} + 1} \right)^k$$

gilt mit  $\|x\|_A = \sqrt{\langle x, Ax \rangle}$  und  $\kappa = \|A\|_2 \|A^{-1}\|_2$ .

## 5.2 Trust – Region – Verfahren

Wir betrachten wieder das Optimierungsproblem

$$\min_{x \in \mathbb{R}^n} f(x)$$

für ein  $f \in \mathcal{C}^2(\mathbb{R}^n)$ . Es sei stets

$$g(x) := \nabla f(x) \quad , \quad H(x) := \nabla^2 f(x) \in \mathbb{R}^{n \times n} .$$

Es sei weiter eine Iterierte  $x^k$  gegeben und wieder  $g_k = g(x^k), f_k = f(x^k)$ .

Es gilt (Taylor-Entwicklung)

$$\begin{aligned} f(x^k + d) &= f(x^k) + g(x^k)^T d + \frac{1}{2} d^T H(x^k) d + O(\|d\|^3) \\ &\approx f_k + g_k^T d + \frac{1}{2} d^T B_k d =: \phi_k(d) \end{aligned}$$

wobei  $\|d\|$  "klein" ist und  $B_k = B_k^T \approx H(x^k)$  eine Approximation an die Hesse-Matrix.

Um  $f$  in einer Umgebung von  $x^k$  zu minimieren, lösen wir jetzt

$$\min_{\|d\|_2 \leq \Delta_k} \Phi_k(d) \tag{5.3}$$

für  $\Delta_k > 0$ . Ist  $\Delta_k$  klein, so approximiert  $\phi_k(d)$  den Wert  $f(x^k + d)$  sehr gut und die Lösung von (5.3) ist eine gute Näherung für

$$\min_{\|z\|_2 \leq \Delta_k} f(x^k + z)$$

Der Bereich  $\{z : \|z\| \leq \Delta_k\}$  heißt Vertrauensbereich (*trust region*), das Problem (5.3) ist das *Trust-Region Problem*.

### Idee des Algorithmus:

- $s_k$  sei die Optimallösung von (5.3).
- $\text{pred}_k := \Phi_k(0) - \Phi_k(s_k) =$  vorhergesagte Verkleinerung beim Übergang von  $x^k$  zu  $x^k + s_k$ .
- $\text{ared}_k := f(x^k) - f(x^{k+1}), x^{k+1} = x^k + s_k$ , tatsächliche Verkleinerung

- $r_k := \text{ared}_k / \text{pred}_k$  Maß für die Übereinstimmung.
- Berechne  $s^k$
- Ist  $r_k$  "klein", mache Nullschritt und setze  $x^{k+1} := x^k$ , verkleinere  $\Delta_k$ .
- Ist  $r_k$  "groß", gehe über zu  $x^{k+1} = x^k + s_k$  und vergrößere  $\Delta_k$ .

**ALGORITHMUS: (Trust-Region-Verfahren)**

Gegeben seien Konstanten  $0 < c_3 < c_4 < 1 < c_1$ ,  $0 \leq c_0 \leq c_2 < 1$  mit  $c_2 > 0$  sowie  $\varepsilon > 0$ .

- 1) Wähle  $x^0 \in \mathbb{R}^n$ ,  $B_0 = B_0^T$ ,  $\Delta_0 > 0$ , setze  $k := 0$ .
- 2) Ist  $\|g_k\| \leq \varepsilon \rightarrow \text{STOP}$   $x^k$  (näherungsweise stationär)
- 3) Bestimme eine Näherungslösung  $s_k$  von (5.3).
- 4) Berechne  $r_k := \text{ared}_k / \text{pred}_k$  und setze

$$x^{k+1} := \begin{cases} x^k & , \text{ falls } r_k \leq c_0 \quad (\text{Nullschritt}) \\ x^k + s_k & , \text{ sonst} \end{cases} .$$

Wähle  $B_{k+1} = B_{k+1}^T$  und  $\Delta_{k+1} > 0$  mit

$$\Delta_{k+1} \in \begin{cases} [c_3 \|s_k\|_2, c_4 \Delta_k] & , \text{ falls } r_k \leq c_2 \\ [\Delta_k, c_1 \Delta_k] & , \text{ sonst} \end{cases} .$$

Setze  $k \rightarrow k + 1$ .

GOTO 2.

**Bemerkungen:**

- a) Typische Konstanten sind  $c_0 = 0$ ,  $c_1 = 2$ ,  $c_2 = c_3 = \frac{1}{4}$ ,  $c_4 = \frac{1}{2}$ .
- b) Man wird versuchen  $B_{k+1}$  durch eine (möglichst einfache) Vorschrift aus  $B_k$  zu bestimmen. Hierzu gibt es sogenannte "Update-Verfahren".

**Satz 5.4** (Schulz, Schnabel, Byrd, 1985)

Sei  $f \in \mathcal{C}^2(\mathbb{R}^n)$  und  $\|\nabla^2 f(x)\| \leq M$  für alle  $x \in \mathbb{R}^n$ . Sei weiter  $c_0 > 0$  und  $\varepsilon = 0$  im Algorithmus. Die Näherungslösungen  $s_k$  von (5.3) mögen zusätzlich

$$\phi_k(0) - \phi_k(s_k) \geq \tau \|s_k\| \min \left\{ \Delta_k, \frac{\|g_k\|}{\|B_k\|} \right\}$$

für ein  $\tau > 0$  erfüllen. Weiter seien auch die  $B_k = B_k^T$ ,  $k \geq 0$ , beschränkt mit  $\|B_k\| \leq M$  für alle  $k$ . Schließlich sei  $\inf_k f(x^k) > -\infty$ . Dann gilt

$$\lim_{k \rightarrow \infty} g(x^k) = 0 ,$$

es ist also jeder Häufungspunkt  $x^k$  von  $\{x^k\}_k$  stationärer Punkt von  $f$ .

### 5.3 Nichtlineare Ausgleichsprobleme: Gauß–Newton – Verfahren

Es sei jetzt  $f \in \mathcal{C}^2(\mathbb{R}^n, \mathbb{R}^m)$ ,

$$f(x) = \begin{pmatrix} f_1(x) \\ \vdots \\ f_m(x) \end{pmatrix}$$

mit  $m \geq n$ .

Für  $m > n$  ist die Gleichung  $f(x) = 0$  überbestimmt und braucht keine Lösung zu haben.

**Idee:** Definiere

$$\phi(x) := \frac{1}{2} \|f(x)\|_2^2 = \frac{1}{2} \sum_{i=1}^m f_i(x)^2$$

und suche ein  $x^*$  mit

$$x^* := \operatorname{argmin}_{x \in \mathbb{R}^n} \phi(x). \quad (5.4)$$

(5.4) ist ein nichtlineares Ausgleichsproblem, "least-squares-Problem".

Notwendige Bedingung für ein Minimum  $x^*$

$$\nabla \phi(x^*) = 0 \quad , \quad \nabla^2 \phi(x^*) \geq 0$$

mit

$$\nabla \phi(x) = J(x)^T f(x) \quad , \quad J(x) = Df(x),$$

wobei  $J(x) \in \mathbb{R}^{m \times n}$  die Jacobi-Matrix von  $f$  ist.

Die Hesse-Matrix hat die Gestalt

$$\nabla^2 \phi(x) = J(x)^T J(x) + B(x) \quad \in \mathbb{R}^{n \times n}$$

mit

$$B(x) = \sum_{i=1}^m f_i(x) \nabla^2 f_i(x) \quad \in \mathbb{R}^{n \times n}.$$

Gesucht ist demnach eine Lösung  $x^*$  von

$$\nabla \phi(x^*) = J(x^*)^T f(x^*) = 0. \quad (5.5)$$

Die Gleichungen (5.5) heißen *Normalgleichungen* von (5.4).

**Bemerkung:** Ist  $f$  affin linear, also  $f(x) = Ax - b$ ,  $A \in \mathbb{R}^{m \times n}$  so ist  $Df(x) = A$  und die Normalgleichungen (5.5) haben die Gestalt

$$A^T(Ax - b) = 0 \quad \Leftrightarrow \quad A^T A x = A^T b. \quad (5.6)$$

Ist  $\operatorname{Rang}(A) = n$ , so ist  $A^T A$  positiv definit und die Lösung von (5.6) ein Minimum von  $\phi(x) = \frac{1}{2} \|Ax - b\|_2^2$  (da  $A^T A = \nabla^2 \phi(x)$ ).

**Idee zur Lösung von (5.5):**

Wende das Newton-Verfahren an mit *line search*

$$x^{k+1} = x^k + \lambda_k d_k$$

mit

$$d_k := -\nabla^2 \phi(x^k)^{-1} \nabla \phi(x^k).$$

Dabei wird die Schrittweite  $\lambda_k > 0$  so bestimmt, dass

$$\phi(x^{k+1}) \approx \min\{\phi(x^k) + \lambda d_k : \lambda > 0\}$$

gilt.

**Nachteil:** Berechnung von  $B(x)$  in  $\nabla^2 \phi(x)$  sehr aufwendig!

Ausweg: Ersetze  $\nabla^2 \phi(x)$  durch  $J(x)^T J(x)$  (und lasse  $B(x)$  weg)!

Dies entspricht der Linearisierung von  $f$  um  $x^k$ , d.h. wir ersetzen  $f$  durch

$$F(x) \approx f(x^k) + J(x^k)(x - x^k) \quad (\text{Taylor}).$$

Denn mit  $f_k := f(x^k)$ ,  $J_k := J(x^k)$  und

$$\phi_k(x) := \frac{1}{2} \|f_k + J_k(x - x^k)\|^2$$

erhält man

$$\begin{aligned} \nabla \phi_k(x) &= J_k^T (f_k + J_k(x - x^k)), \\ \nabla^2 \phi_k(x) &= J_k^T J_k. \end{aligned}$$

Das Minimum von  $\phi_k$  wird angenommen, falls

$$\nabla \phi_k(x^*) = 0 \quad \Leftrightarrow \quad J_k^T J_k (x^* - x^k) = -J_k^T f_k$$

gilt, also:

$$x^* = x^k + d_k \quad \text{mit} \quad d_k = -(J_k^T J_k)^{-1} J_k^T f_k.$$

Folglich ist

$$J_k^T J_k d_k = -J_k^T f_k$$

und damit die Lösung von

$$\min_d \frac{1}{2} \|f_k + J_k d\|_2^2.$$

Das legt folgendes Verfahren nahe:

$$x^{k+1} := x^k + \lambda_k d_k \quad , \quad d_k := -(J_k^T J_k)^{-1} J_k^T f_k$$

mit  $\lambda_k > 0$ , so dass

$$\phi(x^{k+1}) \approx \min_{\lambda > 0} \phi(x^k + \lambda d_k).$$

Das ist das *Gauß-Newton-Verfahren mit line search*. Für  $\lambda_k = 1$ ,  $k = 0, 1, \dots$  erhält man das klassische Gauß-Newton-Verfahren.

### ALGORITHMUS: (Gauß-Newton-Verfahren mit line search)

Sei  $x^0 \in \mathbb{R}$  beliebig.

Für  $k = 0, 1, \dots$

1) Berechne  $d_k := -(J_k^T J_k)^{-1} J_k^T f_k$  mit  $J_k = J(x^k)$ ,  $f_k = f(x^k)$ .

2) Bestimme  $x^{k+1} := x^k + \lambda_k d_k$ ,  $\lambda_k > 0$ , so dass

$$\phi(x^{k+1}) \approx \min_{\lambda > 0} \phi(x^k + \lambda d_k)$$

ist.

**Satz 5.5** Wird  $\lambda_k$  wie in Satz 5.1 (Abstiegsverfahren) bestimmt, ist  $K := \{x : \phi(x) \leq \phi(x^0)\}$  kompakt und  $J(x)^T J(x)$  auf  $K$  positiv definit, so erzeugt der Algorithmus eine Folge  $\{x^k\}_k$ , deren Häufungspunkte stationäre Punkte von  $\phi$  sind.

**Anmerkung:**

Definiert man  $\varphi(\lambda) := \phi(x^k + \lambda d_k)$ , so ist

$$\varphi'(0) = d_k^T (J_k^T f_k) = -d_k^T J_k^T J_k d_k = -\|J_k d_k\|^2 < 0$$

da

$$J_k d_k = J_k (J_k^T J_k)^{-1} J_k^T f_k = 0 \Leftrightarrow J_k^T f_k = 0 \Leftrightarrow x^k \text{ stationärer Punkt von } \phi.$$

$\Rightarrow d_k$  ist eine Abstiegsrichtung für  $\phi$ .



## Nichtlineare Optimierung II: Restringierte Optimierungsaufgaben:

### 6.1 Penalty – Methoden

**Idee:** Behandle ein restringiertes Problem durch Folge unrestringierter Probleme.

Betrachte

$$\min f(x) \quad \text{u.d.N.} \quad h_j(x) = 0, j = 1, \dots, p \quad (6.1)$$


mit  $f : \mathbb{R}^n \rightarrow \mathbb{R}$ ,  $h : \mathbb{R}^n \rightarrow \mathbb{R}^p$  stetig.

Definiere eine Penalty-Funktion

$$P(x; \alpha) := f(x) + \frac{\alpha}{2} \|h(x)\|^2.$$

Offenbar:  $x$  zulässig  $\Rightarrow P(x; \alpha) = f(x)$

**Beispiel 6.1**  $\min x^2$  u.d.N.  $x - 1 = 0 \Rightarrow x^* = 1$  ist Lösung.



$$\begin{aligned} \alpha \text{ klein} &\Rightarrow \min P(x; \alpha) \text{ weit weg von } \min f(x) = 1 \\ \alpha \text{ groß} &\Rightarrow \min P(x; \alpha) \approx 1 \end{aligned}$$

Daher: Konstruiere  $\{\alpha_k\}$  streng monoton wachsend und dazu

$$x_k := \operatorname{argmin}_{x \in \mathbb{R}^n} P(x; \alpha_k),$$

**ALGORITHMUS: (Penalty-Verfahren)**

- 1) Wähle  $\alpha_0 > 0$  und setze  $k := 0$ .
- 2) Definiere  $x_k := \operatorname{argmin}_{x \in \mathbb{R}^n} P(x; \alpha_k)$ .
- 3)  $h(x_k) = 0 \rightarrow$  STOP
- 4) Bestimme  $\alpha_{k+1} > \alpha_k$ , setze  $k \rightarrow k + 1$  und gehe zu 1).

**Satz 6.2** Seien  $f, h$  stetig,  $\{\alpha_k\}$  streng monoton wachsend mit  $\alpha_k \rightarrow \infty$ , die zulässige Menge  $X := \{x \in \mathbb{R}^n : h(x) = 0\}$  nicht leer und  $\{x_k\}$  die durch das Penalty-Verfahren definierte Folge.

- a) Die Folgen  $\{P(x^k; \alpha_k)\}, \{f(x_k)\}$  sind monoton wachsend.
- b) Die Folge  $\{|h(x_k)|\}$  ist monoton fallend mit  $\lim_{k \rightarrow \infty} h(x_k) = 0$ .
- c) Jeder Häufungspunkt der Folge  $\{x_k\}$  ist eine Lösung von (6.1).

Es gilt offenbar, falls  $X \neq \emptyset$  ist:

$$P(x^k; \alpha_k) \leq \inf_{x \in X} P(x; \alpha_k) = \inf_{x \in X} f(x) =: f^* < +\infty \tag{6.2}$$

und damit

$$f(x^k) \leq P(x^k; \alpha_k) \leq f^* .$$

Ist  $x^k$  zulässig, so gilt natürlich auch

$$f(x^k) \geq f^* \text{ also } f(x^k) = f^*$$

und somit ist  $x^k$  eine Lösung.

Dies rechtfertigt das Abbruchkriterium in 3).

Seien nun  $f, h_j \in C^1(\mathbb{R}^n), j = 1, \dots, p$ . Offenbar gilt

$$0 = \nabla P(x^k; \alpha_k) = \nabla f(x^k) + \alpha_k \sum_{j=1}^p h_j(x^k) \nabla h_j(x^k) \tag{6.3}$$

da  $x^k$  globales Minimum ist.

Ist  $(x^*, \mu^*) \in \mathbb{R}^n \times \mathbb{R}^p$  ein KKT-Punkt von (6.1), so gilt

$$0 = \nabla f(x^*) + \sum_{j=1}^p \mu_j^* \nabla h_j(x^*)$$

Frage: Konvergiert

$$\mu_j^k := \alpha_k h_j(x^k), \quad j = 1, \dots, p, \tag{6.4}$$

gegen  $\mu_j^*$  ?

**Satz 6.3** Seien  $f : \mathbb{R}^n \rightarrow \mathbb{R}$ ,  $h : \mathbb{R}^n \rightarrow \mathbb{R}$  stetig differenzierbar,  $\{x^k\}$  eine durch das Penalty-Verfahren erzeugte Folge mit  $\lim_{k \rightarrow \infty} x^k = x^*$ ,  $\{\nabla h_1(x^*), \dots, \nabla h_p(x^*)\}$  seien linear unabhängig und  $\{\mu^k\}$  gemäß (6.4) definiert. Dann gilt

a)  $\{\mu^k\}$  konvergiert gegen ein  $\mu^* \in \mathbb{R}^p$ .

b)  $(x^*, \mu^*)$  mit  $\mu^*$  aus a) ist ein KKT-Punkt von (6.1), d.h.  $\mu^*$  ist der wegen Satz 3.22 eindeutig bestimmte Lagrange-Multiplikator zur Lösung  $x^*$  von (6.1)

**Bemerkungen:**

a) Die Probleme

$$x^k = \operatorname{argmin}_{x \in \mathbb{R}^n} P(x; \alpha_k)$$

sind im allgemeinen nicht exakt lösbar.

Außerdem gilt für die Hesse-Matrix  $\nabla_{xx}^2 P(x^k; \alpha_k)$ , daß für  $\lim_k \alpha_k = +\infty$  auch

$$\lim_{k \rightarrow \infty} \|\nabla_{xx}^2 P(x^k; \alpha_k)\|_2 = +\infty$$

ist.  $\Rightarrow$  Problem schlecht konditioniert

b) Ein allgemeines Problem

$$\min f(x) \quad \text{u.d.N.} \quad h(x) = 0, g(x) \leq 0$$

läßt sich umformulieren in der Gestalt

$$\min f(x) \quad \text{u.d.N.} \quad h(x) = 0, \max\{0, g(x)\} = 0$$

mit

$$\max\{0, g(x)\} := (\max\{0, g_1(x)\}, \dots, \max\{0, g_m(x)\})^T \in \mathbb{R}^m.$$

Die zugehörige Penalty-Funktion lautet

$$P(x, \alpha) := f(x) + \frac{\alpha}{2} \|h(x)\|^2 + \frac{\alpha}{2} \sum_{i=1}^m \max^2\{0, g_i(x)\}.$$

## 6.2 Barriere – Methoden

**Problem:** Bei Penalty-Verfahren sind die iterierten  $\{x^k\}$  i.a. nicht zulässig.

Betrachte

$$\min f(x) \quad \text{u.d.N.} \quad g(x) \leq 0$$

mit  $f : \mathbb{R}^n \rightarrow \mathbb{R}$ ,  $g : \mathbb{R}^n \rightarrow \mathbb{R}^m$ .

Die logarithmische Barriere-Funktion

$$B(x; \alpha) := f(x) - \alpha \sum_{i=1}^m \ln(-g_i(x))$$

und die inverse Barriere-Funktion

$$B(x; \alpha) := f(x) - \alpha \sum_{i=1}^m \frac{1}{g_i(x)}$$

führen zu den Barriere-Verfahren:

1) Wähle eine Folge  $\{\alpha_k\}$  mit  $\lim_{k \rightarrow \infty} \alpha_k = 0$ .

2) Definiere  $x^k := \operatorname{argmin}_{x \in \mathbb{R}^n} B(x; \alpha_k)$ .

Hier gilt wegen

$$\lim_{z \rightarrow 0^-} (-\ln(-z)) = \lim_{z \rightarrow 0^-} \left(-\frac{1}{z}\right) = +\infty$$

stets

$$x^k \text{ ist zulässig } (\Leftrightarrow g(x^k) \leq 0).$$

### 6.3 Multiplier – Penalty – Methoden

Wir betrachten das Optimierungsproblem

$$\min f(x) \quad \text{u.d.N.} \quad h(x) = 0 \tag{6.5}$$

mit gegebenen Funktionen  $f \in \mathcal{C}^2(\mathbb{R}^n)$ ,  $h \in \mathcal{C}^2(\mathbb{R}^n, \mathbb{R}^p)$ .

Jedes lokale Minimum  $x^* \in \mathbb{R}^n$  von (6.5) ist auch lokales Minimum von

$$\min \left\{ f(x) + \frac{\alpha}{2} \|h(x)\|^2 \right\} \quad \text{u.d.N.} \quad h(x) = 0 \tag{6.6}$$

für  $\alpha > 0$  beliebig. Die Lagrange-Funktionen

$$L_\alpha(x, \mu; \alpha) := f(x) + \frac{\alpha}{2} \|h(x)\|^2 + \mu^T h(x)$$

von (6.6) heißt *erweiterte Lagrange-Funktion (augmented Lagrangian, Multiplier-Penalty-Funktion)*.

**Lemma 6.4.** *Es sei  $Q^T = Q \in \mathbb{R}^{n \times n}$  positiv semidefinit und  $P \in \mathbb{R}^{n \times n}$  symmetrisch positiv definit auf  $N(Q)$ , d.h.*

$$x^T P x > 0 \quad \text{für alle} \quad x \in \mathbb{R}^n \setminus \{0\}$$

mit  $x \in N(Q)$ . Dann existiert ein endliches  $\bar{\alpha} > 0$ , so dass  $P + \alpha Q$  symmetrisch positiv definit ist für alle  $\alpha \geq \bar{\alpha}$ .

**Beweis:** Annahme: Zu jedem  $k \in \mathbb{N}$  existiert ein  $x_k \in \mathbb{R}^n$  mit  $x_k \neq 0$  und

$$x_k^T P x_k + k x_k^T Q x_k \leq 0.$$

Wir können dabei  $\|x_k\| = 1$  annehmen.

Dann existiert eine Teilfolge  $\{x_{k_j}\}_j$  mit  $\lim_{j \rightarrow \infty} x_{k_j} = x_*$  und  $\|x_*\| = 1$ .

$$\begin{aligned} &\Rightarrow x_*^T P x_* + \lim_{j \rightarrow \infty} \sup k_j x_{k_j}^T Q x_{k_j} \\ &= \lim_{j \rightarrow \infty} \sup (x_{k_j}^T P x_{k_j} + k_j x_{k_j}^T Q x_{k_j}) \leq 0. \end{aligned} \tag{6.7}$$

Wegen  $x_{k_j}^T Q x_{k_j} \geq 0$  folgt hieraus

$$x_*^T Q x_* = \lim_{j \rightarrow \infty} x_{k_j}^T Q x_{k_j} = 0.$$

- $\Rightarrow x_*$  ist lokales Minimum der Funktion  $q(x) = \frac{1}{2} x^T Q x$
- $\Rightarrow \nabla q(x_*) = 0$
- $\Rightarrow Q x_* = 0 \Leftrightarrow x_* \in N(Q)$
- $\Rightarrow x_*^T P x_* > 0$  nach Voraussetzung
- $\Rightarrow$  Widerspruch zu (6.7) □

**Satz 6.5** *Es sei  $(x^*, \mu^*)$  ein KKT-Punkt von (6.5), so dass die hinreichende Optimalitätsbedingung 2.Ordnung aus Satz 3.24 erfüllt ist. Dann existiert ein endliches  $\bar{\alpha} > 0$ , so dass  $x^*$  für jedes  $\alpha \geq \bar{\alpha}$  ein striktes lokales Minimum der Funktion  $L_\alpha(\cdot, \mu^*; \alpha)$  ist.*

**Beweis:** Mit  $L(x, \mu) := f(x) + \mu^T h(x)$  gilt

$$\nabla_x L_\alpha(x, \mu; \alpha) = \nabla_x L(x, \mu) + \alpha \sum_{j=1}^p h_j(x) \nabla h_j(x),$$

$$\nabla_{xx}^2 L_\alpha(x, \mu; \alpha) = \nabla_{xx}^2 L(x, \mu) + \alpha \sum_{j=1}^p (h_j(x) \nabla^2 h_j(x) + \nabla h_j(x) \nabla h_j(x)).$$

Definieren wir  $B_* := \nabla h(x_*)^T$ , so gilt

$$\nabla_{xx}^2 L_\alpha(x^*, \mu^*; \alpha) = \nabla_{xx}^2 L(x^*, \mu^*) + \alpha B_*^T B_*.$$

Nach Voraussetzung gilt

$$d^T \nabla_{xx}^2 L(x^*, \mu^*) d > 0 \quad \forall d \neq 0 \quad \text{mit} \quad \nabla h_j(x^*)^T d = 0.$$

$\Rightarrow \nabla_{xx}^2 L(x^*, \mu^*)$  ist symmetrisch positiv definit auf  $N(B_*) = N(B_*^T B_*)$ .

Nach Lemma 6.4 existiert ein endliches  $\bar{\alpha} > 0$ , so dass  $\nabla_{xx}^2 L(x^*, \mu^*; \alpha)$  symmetrisch positiv definit ist für alle  $\alpha \geq \bar{\alpha}$ .

Da  $(x^*, \mu^*)$  ein KKT-Punkt von (6.5) ist, gilt zudem

$$\nabla_x L_\alpha(x^*, \mu^*, \alpha) = \nabla_x L(x^*, \mu^*) + \alpha \sum_{j=1}^p h_j(x^*) \nabla h_j(x^*) = 0.$$

$\Rightarrow x^*$  ist striktes, lokales Minimum von  $L_\alpha(\cdot, \mu^*, \alpha) \quad \forall \alpha \geq \bar{\alpha}$ . □

**Idee:** Löse an Stelle von (6.5) das unrestringierte Problem

$$\min_{x \in \mathbb{R}^n} L_\alpha(x, \mu^*; \alpha).$$

Im Gegensatz zu den Penalty-Verfahren muss gemäß Satz 6.4 nun nicht mehr  $\alpha \rightarrow \infty$  gelten, um ein exaktes Minimum  $x^*$  zu erhalten.

**Problem:** Die Werte  $\mu^*$  und  $\bar{\alpha}$  sind im Allgemeinen nicht bekannt!

**Ausweg:** Annahme:  $\alpha$  sei hinreichend groß, so dass Satz 6.5 anwendbar ist. Gesucht ist eine Approximation  $\mu^k$  an  $\mu^*$ .

Sei dazu  $x^{k+1}$  Lösung von

$$\min_{x \in \mathbb{R}^n} L_\alpha(x, \mu^k; \alpha).$$

Dann gilt

$$\begin{aligned} 0 &= \nabla_x L_\alpha(x^{k+1}, \mu^k; \alpha) \\ &= \nabla f(x^{k+1}) + \sum_{j=1}^p (\mu_j^k + \alpha h_j(x^{k+1})) \nabla h_j(x^{k+1}). \end{aligned}$$

Ist  $(x^*, \mu^*)$  ein KKT-Punkt von (6.5) ist, so gilt

$$0 = \nabla_x L(x^*, \mu^*) = \nabla f(x^*) + \sum_{j=1}^p \mu_j^* \nabla h_j(x^*).$$

Ein Vergleich legt nahe, die Aufdatierung

$$\mu^{k+1} := \mu^k + \alpha h(x^{k+1})$$

zu verwenden (Hestenes-Powell-Vorschrift). Wir erhalten so das Multiplier-Penalty-Verfahren:

### Algorithmus: Multiplier-Penalty-Methode

(S.0) Wähle  $x^0 \in \mathbb{R}^n$ ,  $\mu^0 \in \mathbb{R}^p$ ,  $\alpha_0 > 0$ ,  $c \in (0, 1)$  und setze  $k := 0$ .

(S.1) Ist  $(x^k, \mu^k)$  KKT-Punkt von (6.5)  $\rightarrow$  STOP

(S.2) Bestimme  $x^{k+1}$  als Lösung von:  $\min_{x \in \mathbb{R}^n} L_\alpha(x, \mu^k; \alpha_k)$ .

(S.3) Setze  $\mu^{k+1} := \mu^k + \alpha_k h(x^{k+1})$ .

(S.4) Ist  $\|h(x^{k+1})\| \geq c \|h(x^k)\|$ ,  
so setze  $\alpha_{k+1} := 10\alpha_k$  ansonsten setze  $\alpha_{k+1} := \alpha_k$ .

(S.5) Setze  $k \leftarrow k + 1$  und gehe zu (S.1).

## 6.4 SQP-Verfahren

Die SQP (= Sequentielle Quadratische Programmierung) -Verfahren gehören zu den wichtigsten Verfahren der nichtlinearen Optimierung.

### 6.4.1 Das Newton-Verfahren (reloaded)

Sei  $F : \mathbb{R}^n \rightarrow \mathbb{R}^n$  stetig differenzierbar. Gesucht ist eine Lösung  $x^* \in \mathbb{R}^n$  von

$$F(x) = 0.$$

Es sei bereits  $x^k \approx x^*$  gegeben. Betrachte die lineare Approximation

$$F_k(x) := F(x^k) + F'(x^k)(x - x^k) \approx F(x)$$

mit  $F'(x^k) = J_F(x^k) \in \mathbb{R}^{n \times n}$  und bestimme  $x^{k+1}$  durch

$$\begin{aligned} F_k(x^{k+1}) &= 0 \\ \Leftrightarrow F(x^k) + F'(x^k)(x^{k+1} - x^k) &= 0 \\ \Leftrightarrow F'(x^k)(x^{k+1} - x^k) &= -F(x^k). \end{aligned}$$

So ergibt sich die Newton-Iteration

$$x^{k+1} = x^k + d^k, \quad k = 0, 1, \dots$$

Mit  $F'(x^k)d^k = -F(x^k)$ .

### Algorithmus: Newton-Verfahren

- (S.0) Wähle  $x^0 \in \mathbb{R}^n$ , setze  $k := 0$ .
- (S.1) Ist  $F(x^k) = 0 \rightarrow$  STOP
- (S.2) Bestimme  $d^k \in \mathbb{R}^n$  als Lösung des linearen Gleichungssystems

$$F'(x^k) d^k = -F(x^k).$$

- (S.3) Setze  $x^{k+1} := x^k + d^k$   $k \leftarrow k + 1$ ; gehe zu (S.1).

**Bemerkung:** Im Allgemeinen bricht das Newton-Verfahren nicht nach endlich vielen Schritten ab. Auf Grund der linearen Approximation ist die Konvergenz im Allgemeinen lokal.

Wie sieht es mit der Konvergenzgeschwindigkeit aus ?

#### Lemma 6.6. (Störungslemma)

Seien  $A, B \in \mathbb{R}^{n \times n}$  mit  $\|I - BA\| < 1$ . Dann sind  $A$  und  $B$  regulär und es gilt

$$\|B^{-1}\| \leq \frac{\|A\|}{1 - \|I - BA\|}.$$

**Lemma 6.7.** Seien  $F : \mathbb{R}^n \rightarrow \mathbb{R}^n$  stetig differenzierbar,  $x^* \in \mathbb{R}^n$  und  $F'(x^*)$  regulär. Dann existiert ein  $\varepsilon > 0$ , so dass  $F'(x)$  für alle  $x \in U_\varepsilon(x^*) = \{x \in \mathbb{R}^n : \|x - x^*\| < \varepsilon\}$  regulär ist. Ferner gibt es eine Konstante  $c > 0$ , so dass

$$\|F'(x)^{-1}\| \leq c$$

gilt für alle  $x \in U_\varepsilon(x^*)$ .

**Beweis:** Da  $F'$  stetig in  $x^*$  ist, existiert ein  $\varepsilon > 0$  mit

$$\|F'(x^*) - F'(x)\| \leq \frac{1}{2\|F'(x^*)^{-1}\|}$$

für alle  $x \in U_\varepsilon(x^*)$ .

$$\Rightarrow \|I - F'(x^*)^{-1}F'(x)\| \leq \|F'(x^*)^{-1}\| \|F'(x^*) - F'(x)\| \leq \frac{1}{2}$$

für alle  $x \in U_\varepsilon(x^*)$ .

Nach Lemma 6.6 ist  $F'(x)$  regulär für alle  $x \in U_\varepsilon(x^*)$  und

$$\begin{aligned} \|F'(x)^{-1}\| &\leq \frac{\|F'(x^*)^{-1}\|}{1 - \|I - F'(x^*)^{-1}F'(x)\|} \\ &\leq 2\|F'(x^*)^{-1}\| =: c \end{aligned}$$

□

**Lemma 6.8.** Seien  $F : \mathbb{R}^n \rightarrow \mathbb{R}^n$  und eine Folge  $\{x^k\} \subseteq \mathbb{R}^n$  mit  $\lim_{k \rightarrow \infty} x^k = x^*$  gegeben. Dann gilt

a) Ist  $F$  stetig differenzierbar, so ist

$$\|F(x^k) - F(x^*) - F'(x^k)(x^k - x^*)\| = o(\|x^k - x^*\|)$$

für  $k \rightarrow \infty$ .

b) Ist  $F$  stetig differenzierbar und  $F'$  lokal Lipschitz-stetig, so gilt

$$\|F(x^k) - F(x^*) - F'(x^k)(x^k - x^*)\| = O(\|x^k - x^*\|^2)$$

für  $k \rightarrow \infty$ .

**Beweis:** a) Es gilt

$$\begin{aligned} \|F(x^k) - F(x^*) - F'(x^k)(x^k - x^*)\| &\leq \|F(x^k) - F(x^*) - F'(x^*)(x^k - x^*)\| \\ &\quad + \|F'(x^*) - F'(x^k)\| \|x^k - x^*\|. \end{aligned}$$

Da  $F$  in  $x^*$  differenzierbar ist, gilt

$$\|F(x^k) - F(x^*) - F'(x^*)(x^k - x^*)\| = o(\|x^k - x^*\|)$$

für alle  $k \rightarrow \infty$ .

Da  $F'$  in  $x^*$  auch stetig ist gilt zudem  $\lim_{k \rightarrow \infty} \|F'(x^*) - F'(x^k)\| = 0$ .

b) Aus dem Mittelwertsatz der Integralrechnung folgt

$$\begin{aligned} &F(x^k) - F(x^*) - F'(x^k)(x^k - x^*) \\ &= \int_0^1 F'(x^* + t(x^k - x^*))(x^k - x^*) dt - F'(x^k)(x^k - x^*) \\ &= \int_0^1 [F'(x^* + t(x^k - x^*)) - F'(x^k)] (x^k - x^*) dt. \end{aligned}$$

Für  $k$  hinreichend groß folgt aus der lokalen Lipschitz-Stetigkeit von  $F'$



$$\begin{aligned}
& \|F(x^k) - F(x^*) - F'(x^k)(x^k - x^*)\| \\
& \leq \int_0^1 \|F'(x^* + t(x^k - x^*)) - F'(x^k)\| dt \|x^k - x^*\| \\
& \leq L \|x^k - x^*\| \int_0^1 \|(t-1)(x^k - x^*)\| dt \\
& = \frac{L}{2} \|x^k - x^*\|^2 = O(\|x^k - x^*\|^2)
\end{aligned}$$

für  $k \rightarrow \infty$ .

□

**Satz 6.9** (Konvergenz des Newton-Verfahrens)

Seien  $F : \mathbb{R}^n \rightarrow \mathbb{R}^n$  stetig differenzierbar,  $x^* \in \mathbb{R}^n$  mit  $F(x^*) = 0$  und  $F'(x^*)$  regulär. Dann existiert ein  $\varepsilon > 0$ , so dass für jedes  $x^0 \in U_\varepsilon(x^*)$  gilt:

a) Das Newton-Verfahren

$$x^{k+1} = x^k - F'(x^k)^{-1}F(x^k) \quad k = 0, 1, \dots$$

ist wohldefiniert und es gilt  $\lim_{k \rightarrow \infty} x^k = x^*$ .

b) Die Konvergenzrate ist superlinear, d.h.

$$\lim_{k \rightarrow \infty} \frac{\|x^{k+1} - x^*\|}{\|x^k - x^*\|} = 0.$$

c) Ist  $F'$  sogar lokal Lipschitz-stetig, so ist die Konvergenzrate quadratisch, d.h.

$$\|x^{k+1} - x^*\| = O(\|x^k - x^*\|^2)$$

für  $k \rightarrow \infty$ .

**Beweis:** Nach Lemma 6.7 existiert ein  $\varepsilon_1 > 0$ , so dass  $F'(x)$  für alle  $x \in U_{\varepsilon_1}(x^*)$  regulär ist mit

$$\|F'(x)^{-1}\| \leq c \quad \forall x \in U_{\varepsilon_1}(x^*)$$

für ein  $c > 0$ .

Nach Lemma 6.8 a) existiert ein  $\varepsilon_2 > 0$  mit

$$\|F(x) - F(x^*) - F'(x)(x - x^*)\| \leq \frac{1}{2c} \|x - x^*\|$$

für alle  $x \in U_{\varepsilon_2}(x^*)$ .

Wähle nun  $\varepsilon := \min\{\varepsilon_1, \varepsilon_2\}$  und ein  $x^0 \in U_\varepsilon(x^*)$ . Dann ist  $x^1$  wohldefiniert und

$$\begin{aligned}
\|x^1 - x^*\| &= \|x^0 - x^* - F'(x^0)^{-1}F(x^0)\| \\
&\leq \|F'(x^0)^{-1}\| \|F(x^0) - F(x^*) - F'(x^0)(x^0 - x^*)\| \\
&\leq c \frac{1}{2c} \|x^0 - x^*\| = \frac{1}{2} \|x^0 - x^*\|.
\end{aligned}$$

$\Rightarrow x^1 \in U_\varepsilon(x^*)$ .

Induktiv folgt:  $x^k$  ist wohldefiniert und

$$\|x^k - x^*\| \leq \left(\frac{1}{2}\right)^k \|x^0 - x^*\| \quad \forall k \in \mathbb{N}$$

$\Rightarrow \lim_{k \rightarrow \infty} x^k = x^*$ .

b) Analog zum Beweis von a) erhält man

$$\begin{aligned}\|x^{k+1} - x^*\| &= \|x^k - x^* - F'(x^k)^{-1}F(x^k)\| \\ &\leq \|F'(x^k)^{-1}\| \|F(x^k) - F(x^*) - F'(x^k)(x^k - x^*)\| \\ &\leq c \|F(x^k) - F(x^*) - F'(x^k)(x^k - x^*)\|.\end{aligned}$$

Aus Lemma 6.8 folgt dann die Behauptung b) und ebenso c). □

**Bemerkung:** Mit Hilfe des Newton-Verfahrens lassen sich auch unrestringierte Probleme der Form

$$\min f(x) \quad , \quad x \in \mathbb{R}^n$$

lösen, indem man das Verfahren auf die notwendige Bedingung

$$F(x^*) := \nabla f(x^*) = 0$$

anwendet.

### 6.4.2 Lagrange-Newton-Iteration

Wir betrachten die Minimierung mit Gleichungsrestriktionen

$$\min f(x) \quad \text{u.d.N} \quad h(x) = 0,$$

wobei  $f : \mathbb{R}^n \rightarrow \mathbb{R}$ ,  $h : \mathbb{R}^n \rightarrow \mathbb{R}^p$  zweimal stetig differenzierbar seien.

Die Lagrange-Funktion ist gegeben durch

$$L(x, \mu) = f(x) + \sum_{j=1}^p \mu_j h_j(x).$$

Die KKT-Bedingungen sind dann gegeben durch

$$\Phi(x, \mu) = 0$$

mit  $\Phi : \mathbb{R}^n \times \mathbb{R}^p \rightarrow \mathbb{R}^n \times \mathbb{R}^p$ .

$$\Phi(x, \mu) = \begin{pmatrix} \nabla_x L(x, \mu) \\ h(x) \end{pmatrix}$$

und

$$\nabla_x L(x, \mu) = \nabla f(x) + \sum_{j=1}^p \mu_j \nabla h_j(x).$$

Zu lösen ist also ein nichtlineares Gleichungssystem in  $(n+p)$  Variablen  $(x, \mu)$ . Die entsprechende Newton-Iteration lautet

$$(x^{k+1}, \mu^{k+1}) = (x^k, \mu^k) - \Phi'(x^k, \mu^k)^{-1} \Phi(x^k, \mu^k) \quad k = 0, 1, \dots$$

(Lagrange-Newton-Iteration).

**Algorithmus: Lagrange-Newton-Verfahren**

(S.0) Wähle  $(x^0, \mu^0) \in \mathbb{R}^n \times \mathbb{R}^p$ , setze  $k := 0$ .

(S.1) Ist  $\Phi(x^k, \mu^k) = 0 \rightarrow$  STOP

(S.2) Berechne  $(\Delta x^k, \Delta \mu^k)$  als Lösung des linearen Gleichungssystems

$$\Phi'(x^k, \mu^k) \begin{pmatrix} \Delta x \\ \Delta \mu \end{pmatrix} = -\Phi(x^k, \mu^k).$$

(S.3) Setze  $(x^{k+1}, \mu^{k+1}) := (x^k, \mu^k) + (\Delta x^k, \Delta \mu^k) \quad k \leftarrow k + 1$ ; gehe zu (S.1).

Wann ist  $\Phi'(x^k, \mu^k)$  regulär?

**Satz 6.10** *Es sei  $(x^*, \mu^*) \in \mathbb{R}^n \times \mathbb{R}^p$  ein KKT-Punkt des Minimierungsproblems und es gelte*

a) *Die Gradienten  $\nabla h_1(x^*), \dots, \nabla h_p(x^*)$  sind linear unabhängig (LICQ-Bedingung).*

b) *Es ist  $d^T \nabla_{xx}^2 L(x^*, \mu^*) d > 0$  für alle  $d \neq 0$  mit  $\nabla h_j(x^*)^T d = 0$  für  $j = 1, \dots, p$  (hinreichende Bedingung 2. Ordnung).*

*Dann ist die Jacobi-Matrix  $\Phi'(x^*, \mu^*)$  regulär.*

**Beweis:** Annahme:  $\Phi'(x^*, \mu^*)q = 0$  für ein  $q = (q^{(1)}, q^{(2)}) \in \mathbb{R}^n \times \mathbb{R}^p$ .

Wegen

$$\Phi'(x^*, \mu^*) = \begin{pmatrix} \nabla_{xx}^2 L(x^*, \mu^*) & h'(x^*)^T \\ h'(x^*) & 0 \end{pmatrix}$$

gilt dann

$$\nabla_{xx}^2 L(x^*, \mu^*)q^{(1)} + \sum_{j=1}^p q_j^{(2)} \nabla h_j(x^*) = 0 \quad \text{und} \quad \nabla h_j(x^*)^T q^{(1)} = 0 \quad j = 1, \dots, p$$

$$\Rightarrow \quad q^{(1)T} \nabla_{xx} L(x^*, \mu^*)q^{(1)} + \sum_{j=1}^p q_j^{(2)} \nabla h_j(x^*)^T q^{(1)} = q^{(1)T} \nabla_{xx} L(x^*, \mu^*)q^{(1)} = 0$$

$$\stackrel{b)}{\Rightarrow} \quad q^{(1)} = 0.$$

Hieraus ergibt sich aber auch

$$\sum_{j=1}^p q_j^{(2)} \nabla h_j(x^*) = 0$$

$$\stackrel{a)}{\Rightarrow} \quad q_j^{(2)} = 0 \quad , \quad j = 1, \dots, p$$

$$\Rightarrow \quad q = 0 \quad \Rightarrow \quad \Phi'(x^*, \mu^*) \text{ regulär.}$$

□

Nach Satz 6.9 konvergiert somit die Lagrange-Newton Iteration für  $(x^0, \mu^0) \in U_\epsilon(x^*, \mu^*)$  für ein  $\epsilon > 0$ .

Wie werden zusätzliche Ungleichungsrestriktionen behandelt?

Es sei nun

$$\min f(x) \quad \text{u.d.N.} \quad h(x) = 0, g(x) \leq 0$$

zu lösen, wobei  $f : \mathbb{R}^n \rightarrow \mathbb{R}$ ,  $h : \mathbb{R}^n \rightarrow \mathbb{R}^p$  und  $g : \mathbb{R}^n \rightarrow \mathbb{R}^m$  zweimal stetig differenzierbar seien.

Die KKT-Bedingungen lauten nun

$$\begin{aligned} \nabla_x L(x, \lambda, \mu) &= 0 \\ h(x) &= 0 \\ g_i(x) \leq 0, \lambda_i \geq 0, \lambda_i g_i(x) &= 0, \quad i = 1, \dots, m \end{aligned}$$

mit

$$L(x, \lambda, \mu) = f(x) + \sum_{i=1}^m \lambda_i g_i(x) + \sum_{j=1}^p \mu_j h_j(x).$$

Um die KKT-Bedingungen wieder als Nullstellenproblem zu interpretieren benötigen wir die

**Definition 6.11.** Eine Funktion  $\varphi : \mathbb{R}^2 \rightarrow \mathbb{R}$  heißt NCP-Funktion (Nonlinear Complementary Problem), falls

$$\varphi(a, b) = 0 \Leftrightarrow a \geq 0, b \geq 0 \text{ und } ab = 0$$

gilt.

**Beispiele:**

a)  $\varphi(a, b) = 2 \min\{a, b\}$ ,

b) Fischer-Burmeister-Funktion  $\varphi(a, b) = a + b - \sqrt{a^2 + b^2}$ .

Die KKT-Bedingungen können mit Hilfe einer NCP-Funktion  $\varphi$  umformuliert werden zu

$$\begin{aligned} \nabla_x L(x, \lambda, \mu) &= 0 \\ h(x) &= 0 \\ \varphi(-g_i(x), \lambda_i) &= 0, \quad i = 1, \dots, m. \end{aligned}$$

Wir erhalten so das nichtlineare Gleichungssystem

$$\Phi(x, \lambda, \mu) = 0$$

mit

$$\Phi(x, \lambda, \mu) = \begin{pmatrix} \nabla_x L(x, \lambda, \mu) \\ h(x) \\ \phi(-g(x), \lambda) \end{pmatrix}$$

und

$$\phi(-g(x), \lambda) = (\varphi(-g_1(x), \lambda_1), \dots, \varphi(-g_m(x), \lambda_m))^T \in \mathbb{R}^m.$$

**Probleme:** a) Viele NCP-Funktionen  $\varphi$  sind nicht überall differenzierbar. Zur iterativen Lösung von  $\Phi(x, \lambda, \mu) = 0$  werden daher im Allgemeinen nicht glatte Newton-Verfahren verwendet.

b) Das Lagrange-Newton-Verfahren zieht generell auf die Berechnung eines KKT-Punktes ab, die Funktion  $f(x)$  taucht nur indirekt über  $\nabla f(x)$  auf. Daher ist das

Verfahren sinnvollerweise nur auf konvexe Probleme anwendbar. Einen Ausweg liefern die SQP-Verfahren.

### 6.4.3 Das (lokale) SQP-Verfahren

Wir betrachten wieder

$$\min f(x) \quad \text{u.d.N.} \quad h(x) = 0,$$

$f: \mathbb{R}^n \rightarrow \mathbb{R}$ ,  $h: \mathbb{R}^n \rightarrow \mathbb{R}^p$  zweimal stetig differenzierbar.

Beim Lagrange-Newton-Verfahren berechneten wir

$$x^{k+1} := x^k + \Delta x^k, \quad \mu^{k+1} := \mu^k + \Delta \mu^k,$$

wobei  $(\Delta x^k, \Delta \mu^k)$  Lösung von

$$\Phi'(x^k, \mu^k) \begin{pmatrix} \Delta x \\ \Delta \mu \end{pmatrix} = -\Phi(x^k, \mu^k)$$

ist. Ausformuliert bedeutet dies

$$\begin{aligned} H_k \Delta x + h'(x^k)^T \Delta \mu &= -\nabla_x L(x^k, \mu^k) \\ \nabla h_j(x^k)^T \Delta x &= -h_j(x^k), \quad j = 1, \dots, p \end{aligned}$$

mit  $H_k := \nabla_{xx}^2 L(x^k, \mu^k)$ .

Es sei nun auch  $H_k \approx \nabla_{xx}^2 L(x^k, \mu^k)$  zugelassen.

Setzen wir  $\mu^+ := \mu^k + \Delta \mu$ , so folgt

$$\begin{aligned} H_k \Delta x + h'(x^k)^T \mu^+ &= -\nabla f(x^k) \\ \nabla h_j(x^k)^T \Delta x &= -h_j(x^k) \quad j = 1, \dots, p. \end{aligned} \quad (6.8)$$

Dies sind die KKT-Bedingungen des quadratischen Optimierungsproblems

$$\min_{\Delta x} \left\{ \nabla f(x^k)^T \Delta x + \frac{1}{2} \Delta x^T H_k \Delta x \right\}$$

$$\text{u.d.N.} \quad h_j(x^k) + \nabla h_j(x^k)^T \Delta x = 0 \quad j = 1, \dots, p.$$

In der Tat sind mit  $y := \Delta x$ ,  $F(y) := \nabla f(x^k)^T y + \frac{1}{2} y^T H_k y$ ,  $H(y) := h(x^k) + \nabla h(x^k)^T y$  die KKT-Bedingungen von

$$\min_y F(y) \quad \text{u.d.N.} \quad H(y) = 0$$

gegeben durch

$$\begin{cases} \nabla F(y) + \sum_{j=1}^p \mu_j \nabla H_j(y) = 0 \\ H(y) = 0 \end{cases},$$

was wegen  $\nabla F(y) = \nabla f(x^k) + H_k y$  und  $\nabla H_j(y) = \nabla h_j(x^k)$  gerade (6.8) entspricht. Diese Beobachtung motiviert nun für das allgemeine Optimierungsproblem

$$\min f(x) \quad \text{u.d.N.} \quad g(x) \leq 0, \quad h(x) = 0$$

das quadratische Teilproblem

$$\begin{cases} \min_{\Delta x} \nabla f(x^k)^T \Delta x + \frac{1}{2} \Delta x^T H_k \Delta x \\ \text{u.d.N. } g_i(x^k) + \nabla g_i(x^k)^T \Delta x \leq 0 \\ \quad h_j(x^k) + \nabla h_j(x^k)^T \Delta x = 0 \\ \quad i = 1, \dots, m, j = 1, \dots, p \end{cases} \quad (6.9)$$

für die Berechnung von  $\Delta x^k$  zu betrachten, um dann

$$x^{k+1} := x^k + \Delta x^k$$

zu iterieren.

**Bemerkung:** Das Optimierungsproblem (6.9) entspricht einer quadratischen Approximation der Zielfunktion  $f(x)$  und linearisierten Restriktionen bei  $x = x^k$  (vgl. Newton-Verfahren!)  $\rightsquigarrow$  Sequential Quadratic Programming (SQP).

### Algorithmus: SQP-Verfahren

(S.0) Wähle  $(x^0, \lambda^0, \mu^0) \in \mathbb{R}^n \times \mathbb{R}^m \times \mathbb{R}^p$ ,  $H_0 \in \mathbb{R}^{n \times n}$  symmetrisch, setze  $k := 0$ .

(S.1) Ist  $(x^k, \lambda^k, \mu^k)$  KKT-Punkt  $\rightarrow$  STOP

(S.2) Berechne eine Lösung  $\Delta x^k \in \mathbb{R}^n$  von

$$\min \nabla f(x^k)^T \Delta x + \frac{1}{2} \Delta x^T H_k \Delta x$$

$$\text{u.d.N. } g_i(x^k) + \nabla g_i(x^k)^T \Delta x \leq 0$$

$$h_j(x^k) + \nabla h_j(x^k)^T \Delta x = 0$$

$$i = 1, \dots, m, j = 1, \dots, p$$

mit zugehörigem Lagrange-Multiplikatoren  $\lambda^{k+1}, \mu^{k+1}$ .

(S.3) Setze  $x^{k+1} := x^k + \Delta x^k$

Wähle  $H_{k+1} \in \mathbb{R}^{n \times n}$  symmetrisch.

Setze  $k \leftarrow k + 1$ ; gehe zu (S.1).

Falls  $H_k = \nabla_{xx}^2 L(x^k, \lambda^k, \mu^k)$  ist, so sind im Sinne der Lagrange-Newton-Iteration bessere Konvergenzergebnisse zu erwarten. Allerdings muss  $H_k$  nicht auf ganz  $\mathbb{R}^n$  positiv definit sein; es kann also mehrere KKT-Punkte von (6.9) geben.

### Algorithmus: SQP-Verfahren mit $H_k = \nabla_{xx}^2 L(x^k, \lambda^k, \mu^k)$

(S.0) Wähle  $(x^0, \lambda^0, \mu^0) \in \mathbb{R}^n \times \mathbb{R}^m \times \mathbb{R}^p$ . Setze  $k := 0$ .

(S.1) Ist  $(x^k, \lambda^k, \mu^k)$  KKT-Punkt  $\rightarrow$  STOP

(S.2) Berechne mit  $H_k = \nabla_{xx}^2 L(x^k, \lambda^k, \mu^k)$  einen KKT-Punkt  $(x^{k+1}, \lambda^{k+1}, \mu^{k+1})$  von

$$\left\{ \begin{array}{l} \min \nabla f(x^k)^T(x - x^k) + \frac{1}{2}(x - x^k)^T H_k(x - x^k) \\ \text{u.d.N. } g_i(x^k) + \nabla g_i(x^k)^T(x - x^k) \leq 0 \\ \quad h_j(x^k) + \nabla h_j(x^k)^T(x - x^k) = 0 \\ \quad i = 1, \dots, m, j = 1, \dots, p \end{array} \right. \quad (6.10)$$

Besitzt (6.10) mehrere KKT-Punkte, so wähle  $(x^{k+1}, \lambda^{k+1}, \mu^{k+1})$ , so dass

$$\|(x^{k+1}, \lambda^{k+1}, \mu^{k+1}) - (x^k, \lambda^k, \mu^k)\|$$

minimal ist.

(S.3) Setze  $k \leftarrow k + 1$  und gehe zu (S.1).

**Satz 6.12** Sei  $(x^*, \lambda^*, \mu^*)$  ein KKT-Punkt von

$$\min_x f(x) \quad \text{u.d.N.} \quad g(x) \leq 0, h(x) = 0$$

mit

i)  $g_i(x^*) + \lambda_i^* \neq 0$  für alle  $i = 1, \dots, m$

ii) Die Gradienten  $\nabla g_i(x^*)$ ,  $i \in I(x^*) = \{i : g_i(x^*) = 0\}$  und  $\nabla h_j(x^*)$ ,  $j = 1, \dots, p$  sind linear unabhängig (LICQ-Bedingung).

iii) Es ist  $d^T \nabla_{xx} L(x^*, \lambda^*, \mu^*) d > 0$  für alle  $d \neq 0$  mit  $\nabla h_j(x^*)^T d = 0$ ,  $j = 1, \dots, p$  und  $\nabla g_i(x^*)^T d = 0$ ,  $i \in I(x^*)$ .

Dann existiert ein  $\varepsilon > 0$ , so dass für  $(x^0, \lambda^0, \mu^0) \in U_\varepsilon(x^*, \lambda^*, \mu^*)$  gilt:

a) Das SQP-Verfahren ist wohldefiniert und  $\lim_{k \rightarrow \infty} (x^k, \lambda^k, \mu^k) = (x^*, \lambda^*, \mu^*)$ .

b) Die Konvergenzrate ist superlinear.

c) Sind  $\nabla^2 f$ ,  $\nabla^2 g_i$  ( $i = 1, \dots, m$ ) und  $\nabla^2 h_j$  ( $j = 1, \dots, p$ ) lokal Lipschitz-stetig, so ist die Konvergenzrate quadratisch.

**Bemerkung:** a) Die Behauptungen werden plausibel, wenn man folgendes bedenkt: Durch die Forderung i) kann man die in  $x^*$  inaktiven Restriktionen vernachlässigen. Das SQP-Verfahren ist daher lokal (mehr oder weniger) äquivalent zum Lagrange-Newton-Verfahren für

$$\min f(x) \quad \text{u.d.N.} \quad h(x) = 0, g_i(x) = 0, i \in I(x^*).$$

Unter den Bedingungen ii) iii) erbt dieses das Konvergenzverhalten des Newton-Verfahrens.

b) In der vorliegenden Form ist das SQP-Verfahren nur lokal konvergent (siehe Satz 6.12). Ein global konvergentes SQP-Verfahren erhält man mit Hilfe der  $l_1$ -Penalty-Funktion

$$P_1(x; \alpha) = f(x) + \alpha \left( \sum_{i=1}^m \max\{0, g_i(x)\} + \sum_{j=1}^p |h_j(x)| \right),$$

da sich die Lösung  $\Delta x^k$  des quadratischen Problems (6.9) mit einer positiv definiten Matrix  $H_k$  unter bestimmten Voraussetzungen als Abstiegsrichtung von  $P_1(x; \alpha)$  interpretieren lässt.





## Nichtglatte Optimierung

---

**Ziel:** Lösungsverfahren für Optimierungsprobleme mit nicht differenzierbaren Zielfunktionen und Nebenbedingungen.

### 7.1 Lagrange – Dualität

Wir betrachten das Optimierungsproblem

$$\min f(x) \quad \text{u.d.N.} \quad x \in X, g(x) \leq 0, h(x) = 0 \quad (7.1)$$

mit gegebenen  $f : \mathbb{R}^n \rightarrow \mathbb{R}$ ,  $h : \mathbb{R}^n \rightarrow \mathbb{R}^p$ ,  $g : \mathbb{R}^n \rightarrow \mathbb{R}^m$  und  $X \subset \mathbb{R}^n$ ,  $X \neq \emptyset$ .

Es sei weiter

$$L(x, \lambda, \mu) := f(x) + \sum_{i=1}^m \lambda_i g_i(x) + \sum_{j=1}^p \mu_j h_j(x)$$

die zu (7.1) gehörende Lagrange-Funktion. (Die Restriktion  $x \in X$  wurde dabei nicht aufgenommen.)

Der Sattelpunktsatz 3.18 besagt, dass, falls

$$L(x^*, \lambda, \mu) \leq L(x^*, \lambda^*, \mu^*) \leq L(x, \lambda^*, \mu^*)$$

für alle  $(x, \lambda, \mu) \in \mathbb{R}^n \times \mathbb{R}^m \times \mathbb{R}^p$  mit  $\lambda \geq 0$  gilt für ein  $(x^*, \lambda^*, \mu^*) \in \mathbb{R}^n \times \mathbb{R}^m \times \mathbb{R}^p$  mit  $\lambda^* \geq 0$ ,  $x^*$  unter bestimmten Bedingungen (siehe Korollar 3.19) eine Lösung von (7.1) mit  $X = \mathbb{R}^n$  ist.


**Beispiel:** Seien  $X = \mathbb{R}$ ,  $f(x) = x^2$ ,  $m = 1$ ,  $p = 0$ ,  $g(x) = 1 - x$ . (7.1) hat also die Form

$$\min x^2 \quad \text{u.d.N.} \quad 1 - x \leq 0,$$

Lagrange-Funktion

$$L(x, \lambda) = x^2 + \lambda(1 - x).$$

Was ist ein Sattelpunkt von  $L$  ?



Sei  $\lambda \in \mathbb{R}$  fest. Minimiere  $L(\cdot, \lambda)$ :

$$\frac{\partial}{\partial x} L(x, \lambda) = 2x - \lambda \stackrel{!}{=} 0 \Rightarrow x(\lambda) = \frac{\lambda}{2}$$

Maximiere  $L(x(\lambda), \lambda)$ :

$$\begin{aligned} \frac{\partial}{\partial \lambda} \left\{ L(x(\lambda), \lambda) \right\} &= \frac{\partial}{\partial \lambda} \left\{ \left( \frac{\lambda}{2} \right)^2 + \lambda \left( 1 - \frac{\lambda}{2} \right) \right\} = \frac{\partial}{\partial \lambda} \left\{ -\frac{\lambda^2}{4} + \lambda \right\} \\ &= -\frac{\lambda}{2} + 1 \stackrel{!}{=} 0 \Rightarrow \lambda = 2 \end{aligned}$$

$\Rightarrow (x^*, \lambda^*) = (1, 2)$  ist ein Sattelpunkt von  $L$ .

Diese Betrachtungsweise führt zu

**Definition 7.1.** Die Funktion

$$q(\lambda, \mu) := \inf_{x \in X} L(x, \lambda, \mu)$$

heißt die duale Funktion von (7.1); das Optimierungsproblem

$$\max q(\lambda, \mu) \quad \text{u.d.N.} \quad \lambda \geq 0, \mu \in \mathbb{R}^p \quad (7.2)$$

heißt das duale Problem (D) zu (7.1). (Lagrange-Dualität)

**Bemerkung:** Die Restriktionen von (D) sind sehr einfach. Dafür ist jedoch  $q$  unter Umständen aufwändig zu berechnen und im Allgemeinen nicht differenzierbar. Es kann vorkommen, dass

$$q(\lambda, \mu) = \inf_{x \in X} L(x, \lambda, \mu) = -\infty$$

ist. Wir definieren daher

$$\text{dom}(q) := \{ (\lambda, \mu) \in \mathbb{R}^m \times \mathbb{R}^p : \lambda \geq 0, q(\lambda, \mu) > -\infty \}.$$

**Beispiele:** a)  $X = \mathbb{R}^2$  und

$$\min f(x) := x_1^2 - x_2^2 \quad \text{u.d.N.} \quad g(x) := x_1^2 + x_2^2 - 1 \leq 0$$

$$\begin{aligned} \Rightarrow q(\lambda) &= \inf_{x \in X} L(x, \lambda) \\ &= \inf_{x \in \mathbb{R}^2} \{ x_1^2 - x_2^2 + \lambda(x_1^2 + x_2^2 - 1) \} \\ &= \inf_{x \in \mathbb{R}^2} \{ (1 + \lambda)x_1^2 + (-1 + \lambda)x_2^2 - \lambda \} \\ &= \begin{cases} -\infty & , \text{ falls } 0 \leq \lambda < 1 \\ -\lambda & , \text{ falls } \lambda \geq 1 \end{cases} \end{aligned}$$

$$\Rightarrow \text{dom}(q) = [1, +\infty)$$

Duales Problem:

$$\begin{aligned} \max q(\lambda) \quad \text{u.d.N.} \quad \lambda \geq 0 \\ \Rightarrow \lambda^* = 1 \quad , \quad q(\lambda^*) = -1 \end{aligned}$$

Lösung des primalen Problems:

$$x^* = (0, \pm 1) \quad , \quad f(x^*) = -1$$

b) Das zum linearen Programm

$$\min c^T x \quad \text{u.d.N.} \quad Ax = b, x \geq 0$$

gehörende duale Programm ist

$$\max b^T \mu \quad \text{u.d.N.} \quad A^T \mu \leq c.$$

Beweis als Übung (vergleiche auch Abschnitt 3.2).

Die Ergebnisse in diesem Abschnitt verallgemeinern also die Ergebnisse aus Abschnitt 3.2.

**Satz 7.2** (*Schwache Dualität*)

Ist  $x \in \mathbb{R}^n$  zulässig für das primale Problem (P) (7.1) und  $(\lambda, \mu) \in \mathbb{R}^m \times \mathbb{R}^p$  zulässig für das duale Problem (D) (7.2), so ist

$$q(\lambda, \mu) \leq f(x).$$

Definieren wir weiter

$$\inf(P) := \inf \{ f(x) : x \in X, g(x) \leq 0, h(x) = 0 \}$$

$$\sup(D) := \sup \{ q(\lambda, \mu) : \lambda \geq 0, \mu \in \mathbb{R}^p \}$$

so gilt

$$\sup(D) \leq \inf(P).$$

**Beweis:** Nach Voraussetzung gilt

$$\begin{aligned}
q(\lambda, \mu) &= \inf_{z \in X} L(z, \lambda, \mu) \\
&\leq L(x, \lambda, \mu) \\
&= f(x) + \sum_{i=1}^m \lambda_i g_i(x) + \sum_{j=1}^p \mu_j h_j(x) \\
&\leq f(x).
\end{aligned}$$

□

Im Gegensatz zu linearen Programmen (vgl. Satz 3.28) können - wie in der Übung gezeigt- durchaus Dualitätslücken auftauchen.

**Lemma 7.3.** Die duale Funktion  $q$  und der Bereich  $\text{dom}(q)$  besitzen folgende Eigenschaften

a)  $\text{dom}(q)$  ist konvex.

b) Die Funktion  $q : \text{dom}(q) \rightarrow \mathbb{R}$  ist konkav.

**Beweis:** Für  $x \in X$ ,  $(\lambda^1, \mu^1) \in \text{dom}(q)$ ,  $(\lambda^2, \mu^2) \in \text{dom}(q)$ ,  $\alpha \in (0, 1)$  gilt

$$\begin{aligned}
L(x, \alpha\lambda^1 + (1-\alpha)\lambda^2, \alpha\mu^1 + (1-\alpha)\mu^2) &= f(x) + \sum_{i=1}^m [\alpha\lambda_i^1 + (1-\alpha)\lambda_i^2] g_i(x) \\
&\quad + \sum_{j=1}^p [\alpha\mu_j^1 + (1-\alpha)\mu_j^2] h_j(x) \\
&= \alpha L(x, \lambda^1, \mu^1) + (1-\alpha) L(x, \lambda^2, \mu^2)
\end{aligned}$$

Hieraus folgt

$$\begin{aligned}
&\inf_{x \in X} L(x, \alpha\lambda^1 + (1-\alpha)\lambda^2, \alpha\mu^1 + (1-\alpha)\mu^2) \\
&\geq \alpha \inf_{x \in X} L(x, \lambda^1, \mu^1) + (1-\alpha) \inf_{x \in X} L(x, \lambda^2, \mu^2) \\
&\Rightarrow q(\alpha\lambda^1 + (1-\alpha)\lambda^2, \alpha\mu^1 + (1-\alpha)\mu^2) \\
&\geq \alpha q(\lambda^1, \mu^1) + (1-\alpha) q(\lambda^2, \mu^2)
\end{aligned}$$

Also ist mit  $(\lambda^1, \mu^1), (\lambda^2, \mu^2) \in \text{dom}(q)$  auch  $(\alpha\lambda^1 + (1-\alpha)\lambda^2, \alpha\mu^1 + (1-\alpha)\mu^2) \in \text{dom}(q)$ . Also ist  $\text{dom}(q)$  konvex und  $q$  ist auf  $\text{dom}(q)$  konkav.

□

Lemma 7.3 besagt, dass das duale Problem

$$(D) \quad \max q(\lambda, \mu) \quad \text{u.d.N.} \quad \lambda \geq 0$$

ein konkaves Maximierungsproblem und somit

$$\min -q(\lambda, \mu) \quad \text{u.d.N.} \quad \lambda \geq 0$$

ein konvexes Minimierungsproblem ist ! Jede lokale Lösung von (D) ist also schon globale Lösung. Dies gilt, auch wenn (P) nicht konvex ist !

**Definition 7.4.** Wir bezeichnen mit

$$\text{aff}(X) := \bigcap_{V \in U(X)} V, \quad X \subseteq \mathbb{R}^n,$$

wobei  $U(X) = \{V \subseteq \mathbb{R}^n : X \subseteq V, V \text{ ist affiner Unterraum}\}$  die affine Hülle von  $X$  und mit

$$\text{rel } \overset{\circ}{X} := \{x \in X : \exists \varepsilon > 0 \text{ mit } U_\varepsilon(x) \cap \text{aff}(X) \subseteq X\}$$

das relative Innere von  $X$ .

**Satz 7.5** (Starke Dualität)

Es seien  $X \subseteq \mathbb{R}^n$  konvex,  $X \neq \emptyset$ ,  $f : \mathbb{R}^n \rightarrow \mathbb{R}$ ,  $g_i : \mathbb{R}^n \rightarrow \mathbb{R}$ ,  $i = 1, \dots, m$  konvex und  $h : \mathbb{R}^n \rightarrow \mathbb{R}^p$  sei affin linear, d.h.  $h_j(x) = b_j^T x - \beta_j$ , für  $b_j \in \mathbb{R}^n$ ,  $\beta_j \in \mathbb{R}$ ,  $j = 1, \dots, p$ . Ist  $\inf(P) < \infty$  und gibt es ein  $\hat{x} \in \text{rel } \overset{\circ}{X}$  mit

$$g_i(\hat{x}) < 0 \text{ für } i = 1, \dots, m$$

und  $h(\hat{x}) = 0$  (Slater-Bedingung), so ist das duale Problem lösbar und es gilt die starke Dualität

$$\sup(D) = \inf(P).$$

## 7.2 Das konvexe Subdifferential

**Ziel:** Verallgemeinerter Ableitungsbegriff

**Bezeichnung:** Für  $X \subseteq \mathbb{R}^n$  ist die Menge

$$\overset{\circ}{X} = \{x \in X : \exists \varepsilon > 0 \text{ mit } U_\varepsilon(x) \subset X\}$$

das Innere von  $X$ .

**Satz 7.6** Seien  $X \subseteq \mathbb{R}^n$  konvex und  $f : X \rightarrow \mathbb{R}$  eine konvexe Funktion. Dann ist  $f$  lokal Lipschitzstetig auf  $\overset{\circ}{X}$ , d.h. zu jedem  $x \in \overset{\circ}{X}$  existiert ein  $\delta = \delta(x) > 0$  und ein  $L = L(x) > 0$  mit

$$\|f(y_1) - f(y_2)\| \leq L \|y_1 - y_2\|$$

$\forall y_1, y_2 \in U_\delta(x)$ .

Wir beweisen nun, dass für jedes konvexe  $f : X \subseteq \mathbb{R}^n \rightarrow \mathbb{R}$  die Richtungsableitung existiert. Dabei ist die Richtungsableitung von  $f$  im Punkt  $x \in X$  in Richtung  $d \in \mathbb{R}^n$  definiert durch

$$f'(x; d) = \lim_{t \rightarrow 0^+} \frac{f(x + td) - f(x)}{t}.$$

**Lemma 7.7.** Es seien  $X \subseteq \mathbb{R}^n$  offen und konvex und  $f : X \rightarrow \mathbb{R}$  eine konvexe Funktion und  $x \in X$ ,  $d \in \mathbb{R}^n$ . Dann gilt

a) Der Differenzenquotient

$$q(t) := \frac{f(x+td) - f(x)}{t}$$

ist monoton fallend für  $t \rightarrow 0^+$ , also  $q(t_1) \leq q(t_2) \forall 0 < t_1 < t_2$  mit  $x+t_2d \in X$ .

b) Die Richtungsableitung von  $f$  in  $x$  in Richtung  $d$  existiert und es gilt

$$f'(x; d) = \inf_{t>0} \frac{f(x+td) - f(x)}{t}.$$

**Beweis:** a) Seien  $0 < t_1 < t_2$  und  $x+t_2d \in X$  ( $\Rightarrow x+t_1d \in X$ ).

Aus der Konvexität von  $f$  folgt

$$\begin{aligned} f(x+t_1d) &= f\left(\frac{t_1}{t_2}(x+t_2d) + \left(1 - \frac{t_1}{t_2}\right)x\right) \leq \frac{t_1}{t_2}f(x+t_2d) + \left(1 - \frac{t_1}{t_2}\right)f(x) \\ \Rightarrow q(t_1) &= \frac{f(x+t_1d) - f(x)}{t_1} \leq \frac{f(x+t_2d) - f(x)}{t_2} = q(t_2) \end{aligned}$$

$\Rightarrow$  a).

b) Seien  $t, \tau > 0$  mit  $x - \tau d \in X$  und  $x + td \in X$  gegeben. Aus der Konvexität von  $f$  folgt nun

$$\begin{aligned} f(x) &= f\left(\frac{t}{t+\tau}(x - \tau d) + \frac{\tau}{t+\tau}(x + td)\right) \\ &\leq \frac{t}{t+\tau}f(x - \tau d) + \frac{\tau}{t+\tau}f(x + td) \\ \Rightarrow q(t) &= \frac{f(x+td) - f(x)}{t} \geq \frac{f(x) - f(x - \tau d)}{\tau} \\ \Rightarrow q(t) &\geq \frac{1}{\tau}(f(x) - f(x - \tau d)) \end{aligned}$$

für  $t \rightarrow 0^+$  und nach Teil a) gilt, dass  $q(t)$  für  $t \rightarrow 0^+$  monoton fallend ist. Also existiert  $\lim_{t \rightarrow 0^+} q(t) = f'(x; d)$  und

$$f'(x; d) = \lim_{t \rightarrow 0^+} q(t) = \inf_{t>0} \frac{f(x+td) - f(x)}{t}$$

□


Für konvexe, stetig differenzierbare Funktionen  $f : X \subseteq \mathbb{R}^n \rightarrow \mathbb{R}$  gilt nach Lemma 3.13 a)

$$f(y) \geq f(x) + \nabla f(x)^T(y - x) \quad \forall y \in X.$$

Das bedeutet, dass die Tangentialhyperebene durch den Punkt  $(x, f(x))$

$$E = \{(y, x) \in \mathbb{R}^n \times \mathbb{R} : z = f(x) + \nabla f(x)^T(y - x)\}$$

unterhalb des Graphen von  $f$  liegt und es gibt nur diese eine Hyperebene mit dieser Eigenschaft. Ist  $f$  in  $X$  nicht differenzierbar, kann es unendlich vieler solcher Hyperebenen geben.



Das motiviert die folgende

**Definition 7.8.** Seien  $X \subseteq \mathbb{R}^n$  offen und konvex,  $f : X \rightarrow \mathbb{R}$  konvex und  $x \in X$ . Ein Vektor  $s \in \mathbb{R}^n$  heißt Subgradient von  $f$  in  $x$ , wenn

$$f(y) \geq f(x) + s^T(y - x) \quad \forall y \in X \tag{7.3}$$

gilt. Die Menge


$$\partial f(x) := \{ s \in \mathbb{R}^n : s \text{ erfüllt (7.3)} \}$$

heißt (konvexes) Subdifferential von  $f$  in  $x$ .

**Beispiel 7.9**  $X = \mathbb{R}$ ,  $f(x) = |x|$ .

Dann ist

$$\partial f(0) = \{ s \in \mathbb{R} : |y| \geq sy \quad \forall y \in \mathbb{R} \} = [-1, 1].$$



**Lemma 7.10.** *Ist  $f$  in  $x$  differenzierbar, so gilt*

$$\partial f(x) = \{\nabla f(x)\}.$$

**Beweis:** Ist  $s \in \partial f(x)$ , so gilt

$$f(x + td) - f(x) \geq ts^T d \quad \forall d \in \mathbb{R}^n$$

und für alle  $t > 0$  mit  $x + td \in X$ . Daraus folgt

$$\lim_{t \rightarrow 0^+} \frac{f(x + td) - f(x)}{t} = \nabla f(x)^T d \geq s^T d$$

für alle  $d \in \mathbb{R}^n$ .

Setzen wir  $d = s - \nabla f(x)$ , so ergibt dies

$$\begin{aligned} \nabla f(x)^T (s - \nabla f(x)) &\geq s^T (s - \nabla f(x)) \\ \Leftrightarrow 0 &\geq \|s\|^2 - 2s^T \nabla f(x) + \|\nabla f(x)\|^2 \\ \Leftrightarrow \|s - \nabla f(x)\|^2 &= 0 \\ \Leftrightarrow s &= \nabla f(x). \end{aligned}$$

Da  $\partial f(x) \neq \emptyset$  (Satz 7.11 a) ) folgt die Behauptung. □

**Satz 7.11** (*Eigenschaften des Subdifferentials*)

Seien  $X \subseteq \mathbb{R}^n$  offen und konvex,  $f : X \rightarrow \mathbb{R}$  konvex und  $x \in X$ .

Dann gilt:

a)  $\partial f(x)$  ist eine nichtleere, konvexe und kompakte Menge.

b)  $\partial f(x) = \{s \in \mathbb{R}^n : s^T d \leq f'(x; d) \quad \forall d \in \mathbb{R}^n\}$ .

c)  $f'(x; d) = \max_{s \in \partial f(x)} s^T d \quad \forall d \in \mathbb{R}^n$ .

**Beweis:** (nur Teile)

b) Nach Lemma 7.7 b) existiert  $f'(x; d) \quad \forall d \in \mathbb{R}^n$  und aus dem Beweis von Lemma 7.10 folgt direkt  $f'(x; d) \geq s^T d \quad \forall d \in \mathbb{R}^n$ .

a) Ist für  $x \in X$ ,  $d \in \mathbb{R}^n$ ,  $H_x(d) := \{s \in \mathbb{R}^n : s^T d \leq f'(x; d)\}$  ein abgeschlossener, konvexer Halbraum, so ist wegen

$$\partial f(x) = \bigcap_{d \in \mathbb{R}^n} H_x(d)$$

ebenfalls abgeschlossen und konvex.

Aus b) folgt auch, dass

$$\|s\|_\infty \leq \max_{i=1, \dots, n} f'(x; \pm e_i)$$

gilt  $\forall s \in \partial f(x)$  (wobei  $e_i \in \mathbb{R}^n$  der  $i$ -te Standard Einheitsvektor ist). Demnach ist  $\partial f(x)$  auch beschränkt und somit kompakt. □

**Satz 7.12** (*Optimalitätsbedingung*)

Seien  $X \subseteq \mathbb{R}^n$  offen und konvex,  $f : X \rightarrow \mathbb{R}$  konvex und  $x^* \in X$ . Dann sind die folgenden Aussagen äquivalent:

a)  $f(x) \geq f(x^*) \quad \forall x \in X$ ,



- b)  $0 \in \partial f(x^*)$ ,
- c)  $f(x^*; d) \geq 0 \quad \forall d \in \mathbb{R}^n$ .

**Beweis:** a)  $\Rightarrow$  c): Ist  $x^*$  ein globales Minimum von  $f$ , so gilt

$$f'(x^*; d) = \lim_{t \rightarrow 0^+} \frac{f(x^* + td) - f(x^*)}{t} \geq 0 \quad \forall d \in \mathbb{R}^n$$

- c)  $\Rightarrow$  b) folgt aus Satz 7.11 b).
- b)  $\Rightarrow$  a) folgt aus der Definition von  $\partial f(x)$ .

□

**Lemma 7.13.** Seien  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  konvex und  $B \subseteq \mathbb{R}^n$  beschränkt. Dann ist die Bildmenge

$$\partial f(B) := \{ s \in \mathbb{R}^n : \exists x \in B \text{ mit } s \in \partial f(x) \}$$

ebenfalls beschränkt.

**Beweis:** Zu  $s \in \partial f(B)$  existiert ein  $x_s \in B$  mit

$$f(y) \geq f(x_s) + s^T(y - x_s) \quad \forall y \in \mathbb{R}^n.$$

Wählen wir  $y = x_s + \frac{s}{\|s\|}$ , so folgt

$$\|s\| \leq f\left(x_s + \frac{s}{\|s\|}\right) - f(x_s)$$

Ist  $Q_r := \{ u \in \mathbb{R}^n : \|u\|_\infty \leq r \}$  ein Quader mit  $\{ x \in \mathbb{R}^n : \text{dist}(x, B) \leq 1 \} \subset Q_r$ , so folgt die Behauptung, da  $f$  nach Satz 7.6 auf jedem  $Q_r$  stetig und damit beschränkt ist.

□

**Satz 7.14** Seien  $X \subseteq \mathbb{R}^n$  offen und konvex,  $f_1, \dots, f_r : X \rightarrow \mathbb{R}$  konvex und  $\alpha_1, \dots, \alpha_r > 0$ . Dann gilt

$$\partial \left( \sum_{i=1}^r \alpha_i f_i \right) (x) = \sum_{i=1}^r \alpha_i \partial f_i(x) \quad \forall x \in X.$$

**Lemma 7.15.** Es sei  $g : \mathbb{R}^m \rightarrow \mathbb{R}$  definiert durch  $g(u) = \max_{i=1, \dots, m} u_i$ . Dann gilt

$$g'(u; p) = \max_{i \in I(u)} p_i,$$

wobei  $I(u) := \{ i \in \{1, \dots, m\} : u_i = g(u) \}$  ist.

**Beweis:** Seien  $u, p \in \mathbb{R}^m$ . Ist  $i \notin I(u)$ , so ist  $u_i < g(u)$  und somit  $u_i + tp_i < g(u + tp)$  für  $t \rightarrow 0$  hinreichend klein, da  $g$  stetig ist. Hieraus folgt

$$g(u + tp) = \max_{i \in I(u)} (u_i + tp_i)$$

und damit

$$\begin{aligned}
\frac{g(u+tp) - g(u)}{t} &= \frac{\max_{i \in I(u)} (u_i + tp_i) - g(u)}{t} \\
&= \max_{i \in I(u)} \frac{(u_i + tp_i) - g(u)}{t} \\
&= \max_{i \in I(u)} \frac{(u_i + tp_i) - u_i}{t} = \max_{i \in I(u)} p_i.
\end{aligned}$$

□

**Bezeichnung:** Es ist für  $a_1, \dots, a_k \in \mathbb{R}^n$

$$\text{conv}\{a_1, \dots, a_k\} := \left\{ s \in \mathbb{R}^n : s = \sum_{i=1}^k \lambda_i a_i \text{ mit } \lambda_i \geq 0 \ \forall i, \sum_{i=1}^k \lambda_i = 1 \right\}$$

die *konvexe* Hülle der Vektoren  $a_1, \dots, a_k$ .

**Satz 7.16** Seien  $X \subseteq \mathbb{R}^n$  offen und konvex,  $F_i : X \rightarrow \mathbb{R}$ ,  $i = 1, \dots, m$  konvexe, stetig differenzierbare Funktionen und

$$f(x) := \max_{i=1, \dots, m} F_i(x) \quad , \quad x \in X$$

sowie  $I(x) := \{i \in \{1, \dots, m\} : F_i(x) = f(x)\}$

Dann gilt:

a)  $f'(x; d) = \max_{i \in I(x)} \nabla F_i(x)^T d$ ,

b)  $\partial f(x) = \text{conv}\{\nabla F_i(x) : i \in I(x)\}$ .

Lemma 7.15 und Satz 7.16 sind hilfreich, um Subdifferenziale von Funktionen zu berechnen, die sich als Maximum konvexer oder affin-linearer Funktionen schreiben lassen. Zum Beispiel gilt für  $f(x) = \|Ax - b\|_\infty$ ,  $A \in \mathbb{R}^{m \times n}$ ,  $b \in \mathbb{R}^m$ :

$$\partial f(x) = \text{conv}\{\text{sgn}(a_j^T x - b_j) a_j : j \in J(x)\},$$

$$J(x) = \{j \in \{1, \dots, m\} : |a_j^T x - b_j| = f(x)\}.$$

Für die duale Funktion

$$q(\lambda, \mu) = \inf_{x \in X} L(x, \lambda, \mu) = \inf_{x \in X} (f(x) + \lambda^T g(x) + \mu^T h(x))$$

gilt, dass  $-q$  konvex ist auf  $\text{dom}(q)$  (Lemma 7.3). Wir können daher den Subgradienten von  $-q$  im Punkt  $(\lambda, \mu)$  berechnen.

**Lemma 7.17.** Seien  $f : \mathbb{R}^n \rightarrow \mathbb{R}$ ,  $g : \mathbb{R}^n \rightarrow \mathbb{R}^m$  und  $h : \mathbb{R}^n \rightarrow \mathbb{R}^p$  Funktionen,  $X \subseteq \mathbb{R}^n$  und  $x = x(\lambda, \mu)$  eine Lösung von

$$\min (f(x) + \lambda^T g(x) + \mu^T h(x)) \quad \text{u.d.N.} \quad x \in X$$

(bei festem  $\lambda, \mu$ ), so ist

$$(-g(x), -h(x)) \in \partial(-q)(\lambda, \mu).$$

**Beweis:** Nach Voraussetzung gilt  $q(\lambda, \mu) = f(x) + \lambda^T g(x) + \mu^T h(x)$ . Außerdem gilt für alle  $\alpha \in \mathbb{R}^n$ ,  $\beta \in \mathbb{R}^p$

$$q(\alpha, \beta) \leq f(x) + \alpha^T g(x) + \beta^T h(x).$$

Demnach gilt für alle  $(\alpha, \beta) \in \mathbb{R}^m \times \mathbb{R}^p$

$$\begin{aligned} -q(\alpha, \beta) &\geq -f(x) - \alpha^T g(x) - \beta^T h(x) \\ &= -q(\lambda, \mu) + f(x) + \lambda^T g(x) + \mu^T h(x) - f(x) - \alpha^T g(x) - \beta^T h(x) \\ &= -q(\lambda, \mu) + \begin{pmatrix} -g(x) \\ -h(x) \end{pmatrix}^T \left[ \begin{pmatrix} \alpha \\ \beta \end{pmatrix} - \begin{pmatrix} \lambda \\ \mu \end{pmatrix} \right]. \end{aligned}$$

Also  $(-g(x), -h(x)) \in \partial(-q)(\lambda, \mu)$ .

□

### 7.3 Die Subgradientenmethode

Gegeben sei

$$\min f(x) \quad \text{u.d.N.} \quad x \in X \quad (7.4)$$

mit  $f : X \subseteq \mathbb{R}^n \rightarrow \mathbb{R}$  konvex und  $\emptyset \neq X \subseteq \mathbb{R}^n$  abgeschlossen und konvex. Dann ist die metrische Projektion  $\mathcal{P}_X : \mathbb{R}^n \rightarrow X$  mit

$$\|x - \mathcal{P}_X(x)\|_2 = \min_{y \in X} \|x - y\|_2$$

wohldefiniert und

$$\|\mathcal{P}_X(x) - \mathcal{P}_X(y)\| \leq \|x - y\| \quad \forall x, y \in \mathbb{R}^n.$$

Ist  $f$  differenzierbar, so ist ein mögliches Verfahren zur Lösung von (7.4) das projizierte Abstiegsverfahren

$$x^{k+1} := \mathcal{P}_X(x^k - t_k \nabla f(x^k)) \quad k = 0, 1, \dots$$

mit Schrittweite  $t_k > 0$ .

Für nichtglattes, konvexes  $f$  ist daher die Subgradientenmethode definiert durch

$$x^{k+1} := \mathcal{P}_X(x^k + t_k d^k) \quad k = 0, 1, \dots$$

mit  $d^k = -s^k / \|s^k\|$  und einem  $s^k \in \partial f(x^k)$ .

**Problem:** Die Richtung  $d^k$  ist im Allgemeinen keine Abstiegsrichtung!

**Beispiel 7.18**  $X = \mathbb{R}^2$ ,  $f(x) = \max\{-x_1, x_1 + 2x_2, x_1 - 2x_2\}$ ,  $x^k = (1, 0)^T$   
Nach Satz 7.16 gilt

$$\partial f(x^k) = \text{conv}\{\nabla F_i(x^k), i \in I(x^k)\},$$

$$F_1(x) = -x_1, \quad F_2(x) = x_1 + 2x_2, \quad F_3(x) = x_1 - 2x_2,$$

$$I(x) = \{i = \{1, 2, 3\} : F_i(x) = f(x)\}.$$

$$\begin{aligned} f(x^k) &= \max\{-1, 1, 1\} = 1 \\ \Rightarrow I(x^k) &= \{2, 3\} \\ \Rightarrow \partial f(x^k) &= \text{conv} \left\{ \begin{pmatrix} 1 \\ 2 \end{pmatrix}, \begin{pmatrix} 1 \\ -2 \end{pmatrix} \right\} \\ \Rightarrow s^k &= \begin{pmatrix} 1 \\ 2 \end{pmatrix} \in \partial f(x^k) \end{aligned}$$

$$\begin{aligned} \text{Wähle } d &= -\frac{s^k}{\|s^k\|} = -\frac{1}{\sqrt{5}} \begin{pmatrix} 1 \\ 2 \end{pmatrix} \\ \Rightarrow f(x^k + t_k d) &= f \left( \begin{pmatrix} 1 \\ 0 \end{pmatrix} - t_k \begin{pmatrix} 1/\sqrt{5} \\ 2/\sqrt{5} \end{pmatrix} \right) \\ &= \max \left\{ -1 + t_k \frac{1}{\sqrt{5}}, 1 - \frac{5}{\sqrt{5}} t_k, 1 + \frac{3}{\sqrt{5}} t_k \right\} \\ &= 1 + \frac{3}{\sqrt{5}} t_k > 1 = f(x) \quad \forall t_k > 0 \end{aligned}$$

Für das Subgradientenverfahren wird daher eine Hilfsfolge eingeführt.

#### ALGORITHMUS: (Subgradientenverfahren)

- (S.0) Wähle  $x^0 \in X$ , berechne  $m_0 := f(x^0)$ , setze  $k := 0$ .  
 (S.1) Genügt  $x^k$  einem geeigneten Abbruchkriterium  $\Rightarrow STOP$   
 (S.2) Berechne  $s^k \in \partial f(x^k)$ , setze

$$\begin{aligned} d^k &:= -\frac{s^k}{\|s^k\|} \quad \text{und} \\ x^{k+1} &:= \mathcal{P}_X(x^k + t_k d^k) \end{aligned}$$

für eine Schrittweite  $t_k > 0$ .

- (S.3) Berechne  $m_{k+1} := \min\{f(x^{k+1}), m_k\}$ .  
 (S.4) Setze  $k \leftarrow k + 1$  und gehe zu (S.1).

**Bemerkung:** a) Wir dürfen  $s^k \neq 0$  annehmen, da  $0 \in \partial f(x^k)$  bedeuten würde, dass  $x^k$  ein globales Minimum wäre (Satz(7.12)).  
 b) Das Subgradientenverfahren ist einfach zu implementieren, falls  $s^k$  und  $\mathcal{P}_X$  einfach zu bestimmen sind.

**Satz 7.19** *Das konvexe Optimierungsproblem besitze eine nichtleere Lösungsmenge und es sei*

$$f^* := \min \{ f(x) : x \in X \}.$$

Seien  $\{x^k\}$  und  $\{m_k\}$  die vom Subgradientenverfahren erzeugten Folgen und möge für  $t_k > 0$  die Bedingungen

$$t_k \searrow 0 \quad \text{und} \quad \sum_{k=0}^{\infty} t_k = +\infty$$

gelten. Dann gilt

$$\lim_{k \rightarrow \infty} m_k = f^*.$$

**Beweis:** Nach Konstruktion und Voraussetzung gilt

$$m_{k+1} \leq m_k \quad , \quad m_k \geq f^* \quad \forall k \in \mathbb{N}_0$$

$\Rightarrow \{m_k\}$  ist konvergent.

Sei  $m_* := \lim_{k \rightarrow \infty} m_k$ . Offenbar ist  $m_* \geq f^*$ .

Annahme:  $m_* > f^*$ .

Es seien  $\alpha \in \mathbb{R}$  mit  $f^* < \alpha < m_*$  und  $\mathcal{L}_\alpha := \{x \in \mathbb{R}^n : f(x) \leq \alpha\}$ .

Sei nun  $\hat{x} \in X$  mit  $f(\hat{x}) < \alpha$  beliebig.

Da  $f : X \rightarrow \mathbb{R}$  konvex ist, ist  $\hat{x} \in \mathcal{L}_\alpha$  (vgl. Satz 7.6).

$\Rightarrow$  Es gibt ein  $\delta > 0$  mit  $x \in \mathcal{L}_\alpha$  für alle  $x \in \mathbb{R}^n$  mit  $\|x - \hat{x}\| \leq \delta$ .

Definiere

$$z^k := \hat{x} + \delta \frac{s^k}{\|s^k\|}$$

$\Rightarrow z^k \in \mathcal{L}_\alpha \quad \forall k \in \mathbb{N}$ .

Aus  $s^k \in \partial f(x^k)$  folgt andererseits

$$f(z^k) \geq f(x^k) + (s^k)^T (z^k - x^k).$$

Wegen  $f(x^k) \geq m_k > \alpha$  folgt daraus

$$(z^k - x^k)^T s^k \leq f(z^k) - f(x^k) \leq \alpha - m_k < 0.$$

Mit  $d^k = -\frac{s^k}{\|s^k\|}$  und  $z^k = \hat{x} - \delta d^k$  ergibt dies

$$\begin{aligned} & -(x^k - z^k)^T \frac{s^k}{\|s^k\|} < 0 \\ \Leftrightarrow & (x^k - \hat{x} + \delta d^k)^T d^k < 0 \\ \Leftrightarrow & (x^k - \hat{x})^T d^k < -\delta. \end{aligned}$$

Wegen  $\|\mathcal{P}_X(x) - \mathcal{P}_X(y)\| \leq \|x - y\| \quad \forall x, y \in X$  gilt

$$\begin{aligned} \|x^{k+1} - \hat{x}\|^2 &= \|\mathcal{P}_X(x^k + t_k d^k) - \mathcal{P}_X(\hat{x})\|^2 \\ &\leq \|x^k + t_k d^k - \hat{x}\|^2 \\ &= \|x^k - \hat{x}\|^2 + t_k^2 + 2t_k(x^k - \hat{x})^T d^k \\ &< \|x^k - \hat{x}\|^2 + t_k(t_k - 2\delta). \end{aligned}$$

Wegen  $t_k \searrow 0$  gibt es ein  $k_0 \in \mathbb{N}$  mit  $t_k \leq \delta \quad \forall k \geq k_0$ .

$$\Rightarrow \|x^{k+1} - \hat{x}\|^2 \leq \|x^k - \hat{x}\|^2 - \delta t_k \quad \forall k \geq k_0.$$

⇒ Aufsummieren ergibt

$$\begin{aligned} \delta \sum_{j=k_0}^r t_j &\leq \sum_{j=k_0}^r (\|x^j - \hat{x}\|^2 - \|x^{j+1} - \hat{x}\|^2) \\ &= \|x^{k_0} - \hat{x}\|^2 - \|x^{r+1} - \hat{x}\|^2 \\ &\leq \|x^{k_0} - \hat{x}\|^2 \quad \forall r \geq k_0. \end{aligned}$$

Aber:

$$\lim_{r \rightarrow \infty} \sum_{j=k_0}^r t_j = +\infty \quad \text{Widerspruch !}$$

Die Annahme war also falsch. □

**Problem:** Eine mögliche Wahl der Schrittweite ist

$$t_k = \frac{1}{k+1}.$$

Dies führt jedoch im Allgemeinen zu einer sehr langsamen Konvergenz. Ziel ist es daher, eine praktisch brauchbare Wahl von  $t_k$  zu finden.

**Lemma 7.20.** *Es sei  $x^*$  eine Lösung von (7.4) und  $\{x^k\}$  durch das Subgradientenverfahren erzeugt, wobei die Schrittweite  $t_k$  die Bedingung*

$$0 < t_k < \frac{2(f(x^k) - f(x^*))}{\|s^k\|}$$

erfüllen möge. Dann gilt

$$\|x^{k+1} - x^*\| < \|x^k - x^*\| \quad \forall k \in \mathbb{N}.$$

**Bemerkung:** Die Folge  $\{f(x^k)\}$  ist nicht notwendigerweise monoton fallend !

**Beweis:** von Lemma 7.20

Sei wieder  $d^k = -\frac{s^k}{\|s^k\|}$

$$\begin{aligned} &\Rightarrow \|x^k + t_k d^k - x^*\|^2 \\ &= \|x^k - x^*\|^2 - 2t_k (x^* - x^k)^T d^k + t_k^2 \|d^k\|^2 \\ &= \|x^k - x^*\|^2 + 2t_k (x^* - x^k)^T \frac{s^k}{\|s^k\|} + t_k^2 \quad \forall k \in \mathbb{N}. \end{aligned}$$

Aus  $s^k \in \partial f(x^k)$  folgt

$$\begin{aligned} (x^* - x^k)^T s^k &\leq f(x^*) - f(x^k) \\ \Rightarrow \|x^k + t_k d^k - x^*\|^2 &\leq \|x^k - x^*\|^2 + 2t_k \frac{f(x^*) - f(x^k)}{\|s^k\|} + t_k^2 \\ &= \|x^k - x^*\|^2 + t_k \left( -2 \frac{f(x^k) - f(x^*)}{\|s^k\|} + t_k \right) \quad \forall k \in \mathbb{N}. \end{aligned}$$

Für  $t_k < \frac{1}{\|s^k\|} 2(f(x^k) - f(x^*))$  gilt

$$t_k \left( -2 \frac{f(x^k) - f(x^*)}{\|s^k\|} + t_k \right) < 0.$$

$$\begin{aligned} \Rightarrow \|x^k + t_k d^k - x^*\| &< \|x^k - x^*\| \\ \Rightarrow \|x^{k+1} - x^*\| &= \|\mathcal{P}_X(x^k + t_k d^k) - \mathcal{P}_X(x^*)\| \\ &\leq \|x^k + t_k d^k - x^*\| < \|x^k - x^*\|. \end{aligned}$$

□

**Bemerkung:** Die Bedingung

$$t_k = \frac{f(x^k) - f^*}{\|s^k\|}$$

ist in der Regel nicht implementierbar, da  $f^* = f(x^*)$  im Allgemeinen nicht bekannt ist. Kennt man  $f^*$ , so ist diese Wahl von  $t_k$  oft besser als  $t_k = \frac{1}{k+1}$ . Die Konvergenz der Subgradientenmethode ist unter den Bedingungen von Satz 7.19 langsamer als  $R$ -linear.

$$(x^k \rightarrow x^* \text{ } R\text{-linear} : \Leftrightarrow \exists q \in (0, 1), c > 0 \text{ mit } \|x^k - x^*\| \leq cq^k \text{ f\"ur } k \rightarrow \infty.)$$

Ein weiteres Problem besteht darin, ein geeignetes Abbruchkriterium zu finden.

## 7.4 Schnittebenenmethoden

Wir betrachten wieder das Optimierungsproblem (7.4)

$$\min f(x) \quad \text{u.d.N.} \quad x \in X,$$

$f : X \subseteq \mathbb{R}^n \rightarrow \mathbb{R}$  konvex,  $X \subseteq \mathbb{R}^n$  abgeschlossen, konvex,  $X \neq \emptyset$ .

**Annahme:** Es sind bereits iterierte  $x^j \in X$ ,  $j = 1, \dots, k$  mit  $s^j \in \partial f(x^j)$ ,  $j = 1, \dots, k$  vorhanden.

Es gilt also

$$f(x) \geq f(x^j) + (s^j)^T(x - x^j) \quad \forall j = 1, \dots, k$$

und damit

$$f(x) \geq \max_{j=1, \dots, k} \{ f(x^j) + (s^j)^T(x - x^j) \}$$

$\Rightarrow$  die stückweise lineare Funktion

$$f_k^{SE}(x) := \max_{j=1, \dots, k} \{ f(x^j) + (s^j)^T(x - x^j) \}$$

kann als untere Approximation an  $f(x)$  angesehen werden.

**Idee:** Ersetze (7.4) durch das Teilproblem

$$\min f_k^{SE}(x) \quad \text{u.d.N.} \quad x \in X$$

und bestimme dadurch  $x^{k+1}$ .

**ALGORITHMUS: (Schnittebenenverfahren, cutting plane method)**(S.0) Wähle  $x^0 \in X$ , setze  $k := 0$ .(S.1) Genügt  $x^k$  einem geeigneten Abbruchkriterium  $\Rightarrow STOP$ (S.2) Berechne  $s^k \in \partial f(x^k)$  und setze

$$f_k^{SE}(x) := \max_{j=1, \dots, k} \{ f(x^j) + (s^j)^T(x - x^j) \}$$

(S.3) Berechne eine Lösung  $x^{k+1}$  von

$$\min f_k^{SE}(x) \quad \text{u.d.N.} \quad x \in X. \quad (7.5)$$

(S.4) Setze  $k \leftarrow k + 1$  und gehe zu (S.1).

**Bemerkung:** Die Funktionen  $f_k^{SE}$  sind konvex, aber nicht differenzierbar. Es stellt sich also die Frage, ob die Probleme (7.5) einfacher als (7.4) zu lösen sind.

**Lemma 7.21.** Ein Vektor  $x^{k+1} \in \mathbb{R}^n$  löst (7.5) genau dann, wenn  $(x^{k+1}, \xi^{k+1}) \in \mathbb{R}^n \times \mathbb{R}$  mit  $\xi^{k+1} := f_k^{SE}(x^{k+1})$  eine Lösung des Problems

$$\min \xi \quad \text{u.d.N.} \quad f(x^j) + (s^j)^T(x - x^j) \leq \xi, \quad j = 1, \dots, k \quad (7.6)$$

ist.

**Beweis:** " $\Rightarrow$ " Sei  $x^{k+1}$  Lösung von (7.5) und  $\xi^{k+1} = f_k^{SE}(x^{k+1})$ .

$\Rightarrow (x^{k+1}, \xi^{k+1})$  ist zulässig für (7.6).

Annahme:  $(x^{k+1}, \xi^{k+1})$  ist nicht optimal für (7.6).

Dann gibt es einen zulässigen Vektor  $(\tilde{x}, \tilde{\xi}) \in \mathbb{R}^n \times \mathbb{R}$  für (7.6) mit  $\tilde{\xi} < \xi^{k+1}$ . Daraus folgt

$$f_k^{SE}(\tilde{x}) = \max_{j=1, \dots, k} \{ f(x^j) + (s^j)^T(\tilde{x} - x^j) \} \leq \tilde{\xi} < \xi^{k+1} = f_k^{SE}(x^{k+1}).$$

Wegen  $\tilde{x} \in X$  ist das ein Widerspruch dazu, dass  $x^{k+1}$  eine Lösung von (7.5) ist.

" $\Leftarrow$ " Sei  $(x^{k+1}, \xi^{k+1}) \in \mathbb{R}^n \times \mathbb{R}$  eine Lösung von (7.6) mit  $\xi^{k+1} = f_k^{SE}(x^{k+1})$ .

Dann ist  $x^{k+1}$  zulässig für (7.5).

Annahme: es gibt ein  $\tilde{x} \in X$  mit  $f_k^{SE}(\tilde{x}) < f_k^{SE}(x^{k+1})$ . Dann gilt für  $\tilde{\xi} := f_k^{SE}(\tilde{x})$ , dass  $(\tilde{x}, \tilde{\xi})$  zulässig für (7.6) ist mit

$$\tilde{\xi} = f_k^{SE}(\tilde{x}) < f_k^{SE}(x^{k+1}) = \xi^{k+1},$$

was einen Widerspruch zur Optimalität von  $(x^{k+1}, \xi^{k+1})$  darstellt. □

**Bemerkung:** a) Wird  $X$  durch lineare Ungleichungen beschrieben, wie z.B. bei dem dualen Problem

$$\max q(\lambda, \mu) \quad \text{u.d.N.} \quad \lambda \geq 0, \mu \in \mathbb{R}^p,$$

so ist (7.6) ein lineares Optimierungsproblem und daher viel einfacher zu lösen als (7.4).



b) Zur Veranschaulichung der Schnittebenenmethode: In der Iteration  $k + 1$  wird die Restriktion

$$\xi \geq f(x^{k+1}) + (s^{k+1})^T(x - x^{k+1})$$

zu (7.6) hinzugefügt. Würde der aktuelle Punkt  $(x^{k+1}, \xi^{k+1})$  mit  $\xi^{k+1} = f_k^{SE}(x^{k+1})$  diese Restriktion erfüllen, so ergäbe dies

$$f(x) \geq f_k^{SE}(x) \geq f_k^{SE}(x^{k+1}) = \xi^{k+1} \geq f(x^{k+1})$$

und  $x^{k+1}$  wäre Lösung von (7.4). Durch die neue Restriktion wird demnach vom zulässigen Bereich von (7.6) ein bestimmter Teil abgeschnitten.

**Satz 7.22** *Jeder Häufungspunkt einer von der Schnittebenenmethode erzeugten Folge  $\{x^k\}$  ist eine Lösung des konvexen Optimierungsproblems (7.4).*

**Beweis:** Sei  $x^*$  ein Häufungspunkt von  $\{x^k\}$  und  $\{x^{k_i+1}\}_i$  eine Teilfolge mit  $\lim_{i \rightarrow \infty} x^{k_i+1} = x^*$ . Wegen  $x^k \in X \forall k \in \mathbb{N}$  gilt  $x^* \in X$ , da  $X$  abgeschlossen ist.

$\Rightarrow x^*$  ist zulässig für (7.4). Ferner gilt nach Konstruktion für alle  $x \in X$  und  $j \in \{0, 1, 2, \dots, k\}$ :

$$\begin{aligned} f(x) &\geq f_k^{SE}(x) \geq f_k^{SE}(x^{k+1}) \\ &= \max_{j=0, \dots, k} \{ f(x^j) + (s^j)^T(x^{k+1} - x^j) \} \\ &\geq f(x^j) + (s^j)^T(x^{k+1} - x^j). \end{aligned}$$

Ersetzen wir  $k$  durch  $k_i$  und bilden  $i \rightarrow \infty$ , so erhalten wir

$$f(x) \geq f(x^j) + (s^j)^T(x^* - x^j)$$

für alle  $x \in X$  und  $j = 0, 1, 2, \dots$ . Ist  $\{x^{j_i}\}_i$  eine Teilfolge mit  $\lim_{i \rightarrow \infty} x^{j_i} = x^*$  und bilden wir  $i \rightarrow \infty$ , so folgt schließlich

$$f(x) \geq f(x^*) \quad \forall x \in X,$$

da die Teilfolge der Subgradienten  $\{s^{j_i}\}_i$  nach Lemma 7.13 beschränkt ist (da  $\{x^{j_i}\}_i$  konvergent und somit beschränkt ist). □

Wie sieht eigentlich ein geeignetes Abbruchkriterium aus ?

**Lemma 7.23.** *Das Problem (7.4) besitze mindestens eine Lösung. Seien  $\{x^k\}$  die vom Schnittebenenverfahren erzeugte Folge und  $\xi^{k+1} := f_k^{SE}(x^{k+1})$*

*Gilt für ein  $\varepsilon > 0$*

$$f(x^{k+1}) - \xi^{k+1} \leq \varepsilon$$

*so folgt*

$$f(x^{k+1}) - f^* \leq \varepsilon$$

*wobei  $f^* = \inf \{ f(x) : x \in X \}$  ist.*

**Beweis:** Sei  $x^* \in X$  eine Lösung von (7.4). Dann ist  $f^* = f(x^*)$ . Wegen  $s^j \in \partial f(x^j)$  gilt außerdem

$$f(x^j) + (s^j)^T(x^* - x^j) \leq f(x^*) \quad \forall j \in \{0, \dots, k\}.$$

$\Rightarrow (x^*, f^*)$  ist zulässig für (7.6).

Nach Lemma 7.21 ist aber  $(x^{k+1}, \xi^{k+1})$  Lösung von (7.6)

$\Rightarrow \xi^{k+1} \leq f^*$

$\Rightarrow f(x^{k+1}) - f^* \leq f(x^{k+1}) - \xi^{k+1} \leq \varepsilon$

□

Lemma 7.23 legt das Abbruchkriterium

$$f(x^{k+1}) - \xi^{k+1} \leq \varepsilon$$

mit  $\xi^{k+1} = f_k^{SE}(x^{k+1})$  nahe (bzw.  $(x^{k+1}, \xi^{k+1})$  Lösung von (7.6)).

### Nachteile der Schnittebenenmethode:

a) Die Teilprobleme (7.5) können unlösbar sein.

Ausweg: Ersetze die Zielfunktion durch

$$f_k^{SE}(x) + \frac{1}{2\gamma_k} \|x - x^k\|^2.$$

So gibt es immer eine eindeutig bestimmte Lösung.

$\Rightarrow$  Proximal-Cutting-Plane-Methode

b) Nach jeder Iteration wird in (7.6) eine Restriktion hinzugefügt.

$\Rightarrow$  Probleme werden immer komplexer.

## 7.5 Bundle-Methoden

Ein Problem der Subgradientenmethode besteht darin, dass

$$d^k = -\frac{s^k}{\|s^k\|} \quad \text{mit} \quad s^k \in \partial f(x^k)$$

keine Abstiegsrichtung zu sein braucht. Außerdem ist unter Umständen

$$f(x^k + t_k d^k) < f(x^k)$$

nur für sehr kleine  $t_k > 0$ .

$\Rightarrow$  Lockerung des Subdifferentialbegriffs

**Definition 7.24.** Seien  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  konvex,  $x \in \mathbb{R}^n$  und  $\varepsilon \geq 0$ . Die Menge

$$\partial_\varepsilon f(x) := \{s \in \mathbb{R}^n : f(y) \geq f(x) + s^T(y - x) - \varepsilon \quad \forall y \in \mathbb{R}^n\}$$

heißt  $\varepsilon$ -Subdifferential von  $f$  in  $x$ .

Offenbar gilt:

$$\begin{aligned} \partial f(x) &= \partial_0 f(x), \\ \partial f(x) &\subset \partial_\varepsilon f(x) \quad \forall \varepsilon \geq 0. \end{aligned}$$

**Beispiel:**  $f(x) = |x| \Rightarrow$

$$\partial_\varepsilon f(x) = \begin{cases} [-1, 1] & , |x| \leq \frac{\varepsilon}{2} \\ [1 - \frac{\varepsilon}{x}, 1] & , x > \frac{\varepsilon}{2} \\ [-1, -1 - \frac{\varepsilon}{x}] & , x < -\frac{\varepsilon}{2} \end{cases}$$

**Definition 7.25.** Seien  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  konvex,  $x, d \in \mathbb{R}^n$ ,  $\varepsilon \geq 0$ .  
Dann heißt

$$f'_\varepsilon(x; d) := \inf_{t>0} \frac{f(x+td) - f(x) + \varepsilon}{t}$$

die  $\varepsilon$ -Richtungsableitung von  $f$  in  $x$  in Richtung  $d$ .

**Bemerkung:** Man beachte, dass in Definition 7.25  $\inf$  nicht durch  $\lim$  ersetzt werden darf.

**Lemma 7.26.** Seien  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  konvex,  $x, d \in \mathbb{R}^n$ .  
Dann gilt:

- a)  $f'(x; d) = f'_0(x; d)$ ,
- b)  $f'(x; d) \leq f'_\varepsilon(x; d) \quad \forall \varepsilon \geq 0$ .  
Insbesondere ist  $f'_\varepsilon(x; d)$  endlich für alle  $\varepsilon \geq 0$ .

**Beweis:** Teil a) folgt direkt aus Lemma 7.7. Außerdem gilt

$$f'(x; d) \leq \frac{f(x+td) - f(x)}{t} \leq \frac{f(x+td) - f(x) + \varepsilon}{t}$$

für alle  $t > 0$  und  $\varepsilon \geq 0 \Rightarrow$  b).

□

**Satz 7.27** Seien  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  konvex und  $x \in \mathbb{R}^n$ . Dann gilt

- a)  $\partial_\varepsilon f(x)$  ist eine nichtleere, konvexe und kompakte Menge.
- b)  $\partial_\varepsilon f(x) = \{s \in \mathbb{R}^n : s^T d \leq f'_\varepsilon(x; d) \quad \forall d \in \mathbb{R}^n\}$ .
- c)  $f'_\varepsilon(x; d) = \max_{s \in \partial_\varepsilon f(x)} s^T d \quad \forall d \in \mathbb{R}^n$ .

**Satz 7.28** ( $\varepsilon$ -optimale Punkte)

Seien  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  konvex und  $x^* \in \mathbb{R}^n$ .

Dann sind äquivalent:

- a)  $f(x^*) \leq \inf_{x \in \mathbb{R}^n} f(x) + \varepsilon$ , d.h.  $x^*$  ist ein  $\varepsilon$ -optimaler Punkt.
- b)  $0 \in \partial_\varepsilon f(x^*)$ .

$$c) f'_\varepsilon(x^*; d) \geq 0 \quad \forall d \in \mathbb{R}^n.$$

Das  $\varepsilon$ -Subdifferential  $\partial_\varepsilon f(x)$  enthält Informationen des Subdifferentials  $\partial f(y)$  für Punkte  $y$  aus einer Umgebung von  $x$ .

**Satz 7.29** Seien  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  konvex,  $x \in \mathbb{R}^n$  und  $\rho > 0$ . Dann gibt es ein von  $x$  unabhängiges  $\varepsilon > 0$  mit

$$\bigcup_{y \in \overline{U_\rho(x)}} \partial f(y) \subseteq \partial_\varepsilon f(x)$$

Dabei ist  $\overline{U_\rho(x)} = \{y \in \mathbb{R}^n : \|x - y\| \leq \rho\}$ .

**Beweis:** Da  $f$  nach Satz 7.6 lokal Lipschitz-stetig und  $\overline{U_\rho(x)}$  kompakt ist, gibt es ein  $L > 0$  mit

$$|f(x^1) - f(x^2)| \leq L \|x^1 - x^2\| \quad \forall x^1, x^2 \in \overline{U_\rho(x)}.$$

Nach Lemma 7.13 ist  $\partial f(\overline{U_\rho(x)})$  zudem beschränkt, also gibt es ein  $\eta > 0$  mit

$$\bigcup_{y \in \overline{U_\rho(x)}} \partial f(y) \subseteq \overline{U_\eta(0)}.$$

Sei nun  $\varepsilon := (L + \eta)\rho$ . Dann gilt für alle  $y \in \overline{U_\rho(x)}$ ,  $s \in \partial f(y)$ ,  $z \in \mathbb{R}^n$ :

$$\begin{aligned} s^T(z - x) &= s^T(z - y) + s^T(y - x) \\ &\leq f(z) - f(y) + s^T(y - x) \\ &= f(z) - f(x) + f(x) - f(y) + s^T(y - x) \\ &\leq f(z) - f(x) + L\|x - y\| + \|s\|\|y - x\| \\ &\leq f(z) - f(x) + (L + \eta)\rho \\ &= f(z) - f(x) + \varepsilon \end{aligned}$$

$$\Rightarrow s \in \partial_\varepsilon f(x).$$

□

Wir betrachten nun das Problem

$$\min f(x) \quad , \quad x \in \mathbb{R}^n \tag{7.7}$$

für  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  konvex.

Für die Suchrichtung  $d^k \in \mathbb{R}^n$  in

$$x^{k+1} := x^k + t_k d^k$$

gilt bei differenzierbarem  $f(x)$  idealerweise  $\nabla f(x^k)^T d^k < 0$ . Z.B. kann

$$\min \nabla f(x^k)^T d \quad \text{u.d.N.} \quad \|d\| \leq 1$$

als Bestimmung für die ideale Suchrichtung dienen. Die Lösung ist

$$d^k = - \frac{\nabla f(x^k)}{\|\nabla f(x^k)\|}.$$

Wegen  $\nabla f(x^k)^T d = f'(x^k; d)$  liegt es nahe für nichtglatte  $f$

$$\min f'(x^k; d) \quad \text{u.d.N.} \quad \|d\| \leq 1 \quad (7.8)$$

als Suchrichtungsproblem zu verwenden.

Satz 7.11 besagt

$$f'(x^k; d) = \max_{s \in \partial f(x^k)} s^T d,$$

wodurch (7.8) übergeht in

$$\min_{\|d\| \leq 1} \max_{s \in \partial f(x^k)} s^T d.$$

Da die Mengen  $\{d : \|d\| \leq 1\}$ ,  $\{s : s \in \partial f(x^k)\}$  nichtleer, konvex und kompakt sind, gilt die Äquivalenz hiervon zu

$$\max_{s \in \partial f(x^k)} \min_{\|d\| \leq 1} s^T d. \quad (7.9)$$

Für gegebenes  $s \in \partial f(x^k)$  wird  $\min\{s^T d : \|d\| \leq 1\}$  durch

$$d = -\frac{s}{\|s\|}$$

gelöst. So reduziert sich 7.9 auf

$$\max_{s \in \partial f(x^k)} (-\|s\|) \Leftrightarrow -\min_{s \in \partial f(x^k)} \|s\|.$$

$\Rightarrow$  Zu finden ist also ein Element aus  $\partial f(x^k)$  mit minimaler Norm.

Als Suchrichtung wäre also  $d^k$  geeignet mit

$$d^k := -g^k \quad , \quad g^k := P_{\partial f(x^k)}(0).$$

Bei der Subgradientenmethode war hingegen  $d^k \in -\partial f(x^k)$  beliebig! Da das Subdifferential keine Information aus der Nachbarschaft von  $x^k$  verwendet, setzen wir

$$g^k := P_{\partial_\varepsilon f(x^k)}(0)$$

( $\partial_\varepsilon f(x^k)$  ist nach Satz 7.27 nichtleer, konvex und kompakt).

**Lemma 7.30.** Seien  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  konvex,  $x^k \in \mathbb{R}^n$  und  $\varepsilon \geq 0$ . Ist  $0 \notin \partial_\varepsilon f(x^k)$ , so gilt für die Suchrichtung  $d^k := -g^k$  mit

$$g^k := P_{\partial_\varepsilon f(x^k)}(0)$$

die Ungleichung

$$\inf_{t>0} f(x^k + t d^k) < f(x^k) - \varepsilon.$$

**Beweis:** Die metrische Projektion  $P_X : \mathbb{R}^n \rightarrow X$  lässt sich äquivalent auch durch

$$(P_X(x) - x)^T (y - P_X(x)) \geq 0 \quad \forall y \in X$$

ausdrücken. Demnach gilt

$$\begin{aligned} (g^k - 0)^T (s - g^k) &\geq 0 \quad \forall s \in \partial_\varepsilon f(x^k), \\ \Leftrightarrow (g^k)^T g^k &\leq s^T g^k \quad \forall s \in \partial_\varepsilon f(x^k). \end{aligned}$$

Aus  $d^k = -g^k$  folgt dann

$$(g^k)^T d^k \geq s^T d^k \quad \forall s \in \partial_\varepsilon f(x^k).$$

Mit Satz 7.27 erhält man

$$f'_\varepsilon(x^k; d^k) = \max_{s \in \partial_\varepsilon f(x^k)} s^T d^k \leq (g^k)^T d^k = -\|g^k\|^2 < 0,$$

da nach Voraussetzung  $0 \notin \partial_\varepsilon f(x^k)$ . Also gibt es ein  $t_k > 0$  mit

$$\begin{aligned} \frac{f(x^k + t_k d^k) - f(x^k) + \varepsilon}{t_k} &< 0 \\ \Rightarrow \inf_{t > 0} f(x^k + t d^k) &\leq f(x^k + t_k d^k) < f(x^k) - \varepsilon. \end{aligned}$$

□

### ALGORITHMUS: ( $\varepsilon$ -Subdifferential-Verfahren)

- (S.0) Wähle  $x^0 \in \mathbb{R}^n$ ,  $\varepsilon > 0$ , setze  $k := 0$ .
- (S.1) Genügt  $x^k$  einem Abbruchkriterium  $\Rightarrow$  STOP
- (S.2) Berechne  $g^k := P_{\partial_\varepsilon f(x^k)}(0)$  und setze  $d^k := -g^k$ .
- (S.3) Berechne  $t_k > 0$  mit  
 $f(x^k + t_k d^k) = \min_{t > 0} f(x^k + t d^k)$ .
- (S.4) Setze  $x^{k+1} := x^k + t_k d^k$ ,  $k \leftarrow k + 1$  und gehe zu (S.1).

### Satz 7.31 (Konvergenzeigenschaft)

Sei  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  konvex und  $f^* := \inf_{x \in \mathbb{R}^n} f(x)$  endlich. Dann gibt es ein  $k_0 \in \mathbb{N}_0$  mit

$$f(x^{k_0}) \leq \inf_{x \in \mathbb{R}^n} f(x) + \varepsilon,$$

$x^{k_0}$  ist also ein  $\varepsilon$ -optimaler Punkt.

**Beweis:** Da  $f(x) \geq f^* > -\infty$  (nach Voraussetzung) und nach Lemma 7.30

$$f(x^{k+1}) < f(x^k) - \varepsilon$$

gilt, muss das Verfahren nach endlich vielen Schritten abbrechen.

□

**Problem:** Das  $\varepsilon$ -Subdifferential  $\partial_\varepsilon f(x^k)$  muss vollständig bekannt sein. Dies ist nicht der Fall und die Berechnung von  $g^k$  im Allgemeinen sehr aufwändig.

**Gesucht:** Geeignete Approximation von  $\partial_\varepsilon f(x^k)$ .

Gemäß Satz 7.29 kann  $\partial_\varepsilon f(x^k)$  durch  $s \in \partial f(y)$  für  $y \in \overline{U_\rho(x^k)}$  approximiert werden.

**Idee:** Verwende den neu zu berechnenden Subgradienten  $s^k \in \partial f(x^k)$  und die bereits vorhandenen  $s^j \in \partial f(x^j)$ ,  $j = 0, 1, \dots, k-1$ , um  $\partial_\varepsilon f(x^k)$  mit diesem Bündel (engl. bundle) an Informationen zu approximieren.

Seien hierzu  $\lambda_j$  Zahlen mit  $\lambda_j \geq 0$ ,  $j = 0, \dots, k$ , und  $\sum_{j=0}^k \lambda_j = 1$ . Wegen  $s^j \in \partial f(x^j)$  gilt für den Linearisierungsfehler

$$\alpha_j^k := f(x^k) - f(x^j) - (s^j)^T(x^k - x^j)$$

für  $j = 0, \dots, k$  offenbar

$$\alpha_j^k \geq 0, \quad j = 0, \dots, k, \quad \text{und} \quad \alpha_k^k = 0.$$

Für  $x \in \mathbb{R}^n$  und  $j = 0, \dots, k$  gilt

$$\begin{aligned} (s^j)^T(x - x^k) &= (s^j)^T(x - x^j) - (s^j)^T(x^k - x^j) \\ &\leq f(x) - f(x^j) - (s^j)^T(x^k - x^j) \\ &= f(x) - f(x^k) + \alpha_j^k \\ \Rightarrow \sum_{j=0}^k \lambda_j (s^j)^T(x - x^k) &\leq f(x) - f(x^k) + \sum_{j=0}^k \lambda_j \alpha_j^k \quad \forall x \in \mathbb{R}^n \\ \Rightarrow \sum_{j=0}^k \lambda_j s^j &\in \partial_\varepsilon f(x^k), \quad \text{falls} \quad \sum_{j=0}^k \lambda_j \alpha_j^k \leq \varepsilon \text{ ist.} \end{aligned}$$

Sei daher

$$G_\varepsilon^k := \left\{ \sum_{j=0}^k \lambda_j s^j : \sum_{j=0}^k \lambda_j \alpha_j^k \leq \varepsilon, \lambda_j \geq 0, \sum_{j=0}^k \lambda_j = 1, j = 0, \dots, k \right\}$$

Es ist  $G_\varepsilon^k \neq \emptyset$  konvex und kompakt. Wir haben bewiesen, dass

$$G_\varepsilon^k \subseteq \partial_\varepsilon f(x^k)$$

gilt.  $G_\varepsilon^k$  kann daher als innere Approximation an  $\partial_\varepsilon f(x^k)$  angesehen werden. Es liegt daher nahe

$$g^k := P_{G_\varepsilon^k}(0)$$

zu setzen.

Den Vektor  $(\lambda_0^k, \dots, \lambda_k^k) \in \mathbb{R}^{k+1}$ , der

$$g^k = \sum_{j=0}^k \lambda_j^k s^j$$

festlegt, kann mit dem folgenden quadratischen Problem berechnet werden.

$$\left\{ \min \left\{ \frac{1}{2} \left\| \sum_{j=0}^k \lambda_j s^j \right\|^2 + \sum_{j=0}^k \lambda_j \alpha_j^k \right\} \text{ u.d.N. } \sum_{j=0}^k \lambda_j = 1, \lambda_j \geq 0, j = 0, \dots, k \right\}$$

#### ALGORITHMUS: ( $\varepsilon$ -Bundle-Verfahren)

(S.0) Wähle  $x^1 \in \mathbb{R}^n$ ,  $s^1 \in \partial f(x^1)$ ,  $\sigma \in (0, 1)$ .

Setze  $y^1 := x^1$ ,  $g^0 := s^1$ ,  $\alpha_1^1 := \varepsilon_0 := 0$ ,  $k := 1$ ,  $K := \emptyset$ ,  $J_k = \{1\}$

(S.1) Berechne  $\lambda_j^k, j \in J_k$  durch

$$\left\{ \min \left\{ \frac{1}{2} \left\| \sum_{j \in J_k} \lambda_j s^j \right\|^2 + \sum_{j \in J_k} \lambda_j \alpha_j^k \right\} \text{ u.d.N. } \sum_{j \in J_k} \lambda_j = 1, \lambda_j \geq 0, j \in J_k \right\}$$

(S.2) Setze

$$\begin{aligned} g^k &:= \sum_{j \in J_k} \lambda_j^k s^j, \\ \varepsilon_k &:= \sum_{j \in J_k} \lambda_j^k \alpha_j^k, \\ d^k &:= -g^k, \\ \xi^k &:= -\|g^k\|^2 - \varepsilon_k. \end{aligned}$$

(S.3) Ist  $\xi^k = 0 \Rightarrow \text{STOP}$ (S.4) Setze  $y^{k+1} := x^k + d^k$  und berechne  $s^{k+1} \in \partial f(y^{k+1})$ .Falls  $f(x^k + d^k) \leq f(x^k) + \sigma \xi^k$ ,  
so setze

$$\begin{aligned} t_k &:= 1 \\ x^{k+1} &:= x^k + d^k \\ K &\leftarrow K \cup \{k\} \end{aligned}$$

andernfalls setze  $t_k := 0$ ,  $x^{k+1} := x^k$ .

(S.5) Setze

$$\begin{aligned} J_k^p &:= \{j \in J_k : \lambda_j^k > 0\}, \\ J_{k+1} &:= J_k^p \cup \{k+1\}, \\ \alpha_j^{k+1} &:= f(x^{k+1}) - f(y^j) - (s^j)^T (x^{k+1} - y^j) \quad \text{für } j \in J_{k+1}. \end{aligned}$$

(S.6) Setze  $k \leftarrow k + 1$ , gehe zu (S.1).