

## 2. GRUNDLAGEN DER NICHT-LINEAREN KONVEXEN OPTIMIERUNG

**2.1. Die Karush-Kuhn-Tucker Bedingungen.** Unser Basisproblem (NLO) sei gegeben durch

$$\text{NLO} \begin{cases} \min f(x) \\ g_i(x) \leq 0, \quad i \in I = \{1, \dots, m\} \\ x \in \mathbb{R}^n \quad f, g_i \text{ stetig differenzierbar.} \end{cases}$$

Die Menge  $X := \{x \in \mathbb{R}^n \mid g_i(x) \leq 0 \forall i\}$  heißt Menge der *zulässigen Lösungen*. und wir setzen  $X \neq \emptyset$  voraus.

Wir wollen nun Bedingungen für lokale Optima suchen. Unsere erste Idee könnte dabei sein, dass  $x^0$  ein lokales Minimum ist, wenn in einer  $\epsilon$ -Umgebung geschnitten mit  $X$  kein besserer Punkt liegt. Die nicht-linearen Optimierer führen dafür eine Konkretisierung ein. Der Punkt  $x^0$  ist nicht lokal optimal, wenn man entlang einer Kurve, die von  $x^0$  ausgeht, zu einem besseren Punkt kommt. Eine stetig differenzierbare Kurve  $\varphi : \mathbb{R}^1 \rightarrow \mathbb{R}^n$  heißt *zulässig*, wenn  $\varphi(0) = x^0$  und  $\varphi(\theta) \in X$  für kleines  $\theta > 0$  gilt.

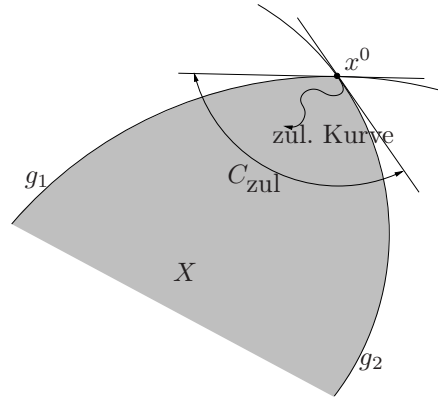


ABBILDUNG 11. Zulässige Kurve in  $x^0$ .

Eine Tangente an einer zulässigen Kurve im Punkt 0 heißt *zulässige Richtung*  $y$ . Formaler ausgedrückt gilt

$$y = \frac{d\varphi}{d\theta}(0) = \begin{pmatrix} \frac{d\varphi_1}{d\theta}(0) \\ \vdots \\ \frac{d\varphi_n}{d\theta}(0) \end{pmatrix}.$$

Der Kegel, der von den zulässigen Richtungen in  $x_0$  aufgespannt wird, bezeichnen wir mit  $C_{zul}$ . (Abb. 11). Dieser Kegel spielt später eine wichtige Rolle für Optimalitätsbedingungen.

Betrachten wir zunächst notwendige Bedingungen dafür, dass  $y \in C_{zul}$  eine zulässige Richtung ist. Dazu definieren wir den Kegel

$$G := \{y \in \mathbb{R}^n \mid \nabla g_i^\top(x^0)y \leq 0 \quad \forall i \in I^0\}$$

mit  $I^0 = \{i \in I \mid g_i(x^0) = 0\}$ . Die Menge  $I^0$  beschreibt die Indexmenge der *scharfen Nebenbedingungen* in  $x^0$ .

**Lemma 2.1.** [notwendige Bedingungen für zulässige Richtungen] Sei  $y$  eine zulässige Richtung von  $x^0$ . Dann gilt

$$\nabla g_i^\top(x^0)y \leq 0 \quad \forall i \in I^0,$$

d.h.  $C_{zul} \subset G$ .

*Beweis.* Sei  $\varphi$  eine zulässige Kurve in  $x^0$  und  $y = \frac{d\varphi}{d\theta}(0)$ . Dann gilt entweder  $g_i(x^0) < 0$  für alle  $i \notin I^0$ , und daraus folgt  $g_i(\varphi(\theta)) < 0$  für kleine  $\theta$ . Oder es gilt  $g_i(x^0) = 0$  für  $i \in I^0$  und es folgt  $g_i(\varphi(\theta)) \leq 0$  für kleines  $\theta$ .

Betrachten wir nun die Taylorentwicklung von  $g_i(\varphi(\theta))$ . Die Taylorentwicklung von  $f$  in  $x^0$  hat die Form

$$f(x) = \sum_{v=0}^n \frac{f^{(v)}(x^0)}{v!} (x - x^0)^v + (x - x^0)^{n+1} R_{n+1}.$$

Diese auf  $g_i(\varphi(\theta))$  angewandt mit  $x^0 = 0$ , erhalten wir

$$g_i(\varphi(\theta)) = g_i(\varphi(0)) + \theta \nabla g_i^\top(\varphi(0)) \frac{d\varphi}{d\theta}(0) + \theta^2 R_2(\theta),$$

wobei  $R_2(\theta) \rightarrow 0$  für  $\theta \rightarrow 0$ . Da  $g_i(\varphi(0)) = g_i(x^0) = 0$  und  $g_i(\varphi(\theta)) \leq 0$  gilt, muss  $\theta \nabla g_i^\top(\varphi(0)) \frac{d\varphi}{d\theta}(0) \leq 0$  sein. Damit ist  $\nabla g_i^\top(\varphi(0)) y \leq 0$  für  $i \in I^0$ . Diese Bedingung nennt man auch *Bedingung erster Ordnung*.  $\square$

**Example 2.2.** Leider sind die notwendigen Bedingungen noch nicht hinreichend und die Umkehrung gilt nicht. Betrachte das folgende Gebiet mit  $g_1 : -x_1 \leq 0$ ,  $g_2 : -x_2 \leq 0$  und  $g_3 : -(1 - x_1)^3 + x_2 \leq 0$ .




ABBILDUNG 12. Gegenbeispiel zur Umkehrung von Lemma 2.1

Es gilt  $\nabla g_2(x^0) = \begin{pmatrix} 0 \\ -1 \end{pmatrix} |_{x^0} = \begin{pmatrix} 0 \\ -1 \end{pmatrix}$  und  $\nabla g_3(x^0) = \begin{pmatrix} 3(1-x_1)^2 \\ x_2 \end{pmatrix} |_{x^0} = \begin{pmatrix} 0 \\ 1 \end{pmatrix}$  mit  $x^0 = (1, 0)$ . Für die Bedingungen erster Ordnung erhalten wir  $-y_2 \leq 0$  und  $y_2 \leq 0$ , ohne dass eine Bedingung an  $y_1$  gestellt wird. Daraus folgt, dass  $y = \begin{pmatrix} 1 \\ 0 \end{pmatrix}$  in  $G$  ist. Die Richtung  $y$  ist aber keine zulässige Richtung, da  $x^0 + \theta \begin{pmatrix} 1 \\ 0 \end{pmatrix} \notin X$  für beliebig kleines  $\theta$  gilt.

Nach diesem Beispiel liegt es nahe noch einschränkende Bedingungen an  $X$  zu stellen. Wir fordern, dass  $X$  die constraint qualification Annahme (CQ) von Kuhn, Tucker '51 erfüllt. Die *constraint qualification Annahme* ist erfüllt, falls  $\overline{C}_{\text{zul.}} = G$  für  $x^0$  gilt. Diese Bedingung ist sehr stark und sichert die Umkehrung des Lemmas 2.1. Die CQ Bedingung ist allgemein schwer nachzuprüfen. Daher interessiert man sich für weitere hinreichende Bedingungen.

**Lemma 2.3.** Jede der folgenden Bedingungen ist hinreichend für die Gültigkeit von (CQ):

- (1) die Funktionen  $g_i$  sind linear (Korlin '59)
- (2) alle Funktionen  $g_i$  sind konvex und das Innere von  $X$  ist nicht leer. (Slater '50)
- (3) die Gradienten  $\nabla g_i(x^0)$  mit  $i \in I^0$  sind linear unabhängig.

*Note 2.4.* Da die ersten beiden Bedingungen unabhängig von  $x^0$  sind, sichern sie die Gültigkeit der Behauptung auf ganz  $X$ .

*Beweis.* zu (1): Sei  $g_i(x) = a_i^\top x + b_i$ . Dann ist  $X$  ein Durchschnitt von Halbräumen und jede Gerade von  $x^0$  aus nach  $X$  ist eine zulässige Richtung. Es gilt  $\nabla g_i(x^0) = a_i$ . Damit entspricht  $\nabla g_i(x^0)$  dem Vektor, der senkrecht auf der Hyperebene  $a_i^\top x + b_i = 0$  steht. Die Gleichung  $\nabla g_i(x^0)^\top y = a_i^\top y \leq 0$  wird von allen  $y$  erfüllt, die eine nicht-negative Projektion auf  $-a_i$  haben. Diese  $y$  liegen im Halbraum, der durch  $a_i^\top x + b_i = 0$  definiert wird und in dem  $X$  liegt. Also gilt  $G = C_{\text{zul}} = \overline{C}_{\text{zul}}$ .

Noch mal anders: Für ein  $y \in G$  gilt  $-a_i y \geq 0$ , da  $\nabla g_i^\top(x^0) = a_i$ . Der Punkt  $x^0$  ist zulässig, also ist  $g_i(x^0) \leq 0$ . Betrachten wir jetzt  $g_i^\top(x^0 + \theta y) = a_i(x^0 + \theta y) + b_i = \underbrace{a_i x^0 + b_i}_{\leq 0} + \underbrace{a_i \theta y}_{\leq 0} \leq 0$ , also ist  $x + \theta y \in X$ . Somit gilt  $\varphi(\theta) = x^0 + y \cdot \theta$  ist eine zulässige

Kurve und  $y = \frac{d\varphi}{dx}(0)$  eine zulässige Richtung.

zu (2) und (3): Sei  $R := \{y \in \mathbb{R}^n \mid \nabla g_i^\top(x^0)y < 0, \forall i \in I^0\}$  der Kegel der zulässigen Richtungen in  $x^0$ . Für jedes  $y \in R$  gilt,  $\varphi(\theta) = x^0 + y\theta$  ist eine zulässige Kurve, weil  $g_i(x^0 + y\theta) = \underbrace{g_i(x^0)}_{=0} + \theta \underbrace{\nabla g_i(x^0)y}_{<0} + \underbrace{R_2(\theta)}_{\approx 0} \leq 0$  gilt. Also ist  $R \subset C_{\text{zul}}$ .

und damit  $\overline{R} \subset \overline{C}_{\text{zul}}$ .

Betrachten wir nun folgende Behauptung:

*Claim 2.5.* Falls  $R \neq \emptyset$ , dann gilt  $\overline{R} = G$ , d.h. die (CQ) ist erfüllt.

*Beweis.* Zeige  $G \subset \overline{R}$ . Sei  $y \in G$  d.h.  $\nabla g_i^\top(x^0)y \leq 0$  für alle  $i \in I^0$  und  $\bar{y} \in R$ , d.h.  $\nabla g_i^\top(x^0)\bar{y} < 0$  für  $i \in I^0$ . Dann gilt  $\lambda y + (1 - \lambda)\bar{y} \in R$  für  $0 \leq \lambda < 1$ . Betrachte den Grenzübergang von  $\lambda \uparrow 1$ . Dies erzeugt eine Folge zulässiger Richtungen  $y^\lambda$  mit  $\lim_{\lambda \uparrow 1} y^\lambda = y$ . Also ist  $y \in \overline{R}$ . Da  $\overline{R} \subset G$  nach der Definition von  $R$  und  $G$  gilt, folgt sofort  $\overline{R} = G$ .  $\square$

zu (2): Die Voraussetzung war, dass das Innere von  $X$  nicht leer ist. Daraus folgt, dass ein  $\bar{x}$  mit  $g_i(\bar{x}) < 0 \forall i$  existiert. Da alle  $g_i$  konvex sind, gilt

$$0 > g_i(\bar{x}) \geq g_i(x^0) + \nabla g_i^\top(x^0)(\bar{x} - x^0).$$

Für  $i \in I^0$  gilt  $g_i(x^0) = 0$  und somit  $0 > g_i(\bar{x}) \geq \nabla g_i^\top(\bar{x} - x^0) \forall i \in I^0$ . Also ist  $(\bar{x} - x^0) \in R$  und damit ist  $R \neq \emptyset$ . Die Behauptung erhalten wir durch die Anwendung des Claim 2.5.

zu (3): Hier galt: die Vektoren  $\nabla g_i(x^0)$   $i \in I^0$  sind linear unabhängig. Das ist äquivalent dazu, dass  $\sum_{i \in I^0} \lambda_i \nabla g_i(x^0) = 0$  nur die triviale Lösung  $\lambda_i = 0$  hat. Daraus folgt, dass  $\lambda^\top \nabla g(x^0) = 0$  mit  $g(x) = (g_1(x), \dots, g_k(x))^\top$  für  $\lambda \geq 0$  und  $\lambda \neq 0$  keine Lösung hat.

Der Satz von Gordan 1873, eine Variante des Farkas-Lemmas, sagt aus: Sei  $A \in \mathbb{R}^{n \times m}$ . Dann gilt  $\lambda^\top A = 0$  mit  $\lambda \geq 0$  und  $\lambda \neq 0$  hat genau dann keine Lösung, wenn ein  $y$  mit  $Ay < 0$  existiert. Setzen wir  $A = (\nabla g_1^\top(x^0), \dots, \nabla g_k^\top(x^0))^\top$  erhalten wir, dass ein  $y$  mit  $(\nabla g_1^\top(x^0), \dots, \nabla g_k^\top(x^0)) \cdot y < 0$  existiert. Komponentenweise betrachtet bedeutet dies, dass  $\nabla g_i(x^0)y < 0$  für alle  $i \in I^0$ . Somit ist dieses  $y \in R$  und wir erhalten die Behauptung mit Hilfe von Claim 2.5.  $\square$

Betrachten wir nun notwendige Bedingungen für die Existenz eines lokalen Minimums:

**Theorem 2.6.** [notwendige Bedingungen für lokales Minimum, Kuhn-Tucker '51] Seien  $f, g_i : \mathbb{R}^n \rightarrow \mathbb{R}$  stetig differenzierbare Funktionen. Außerdem sei die (CQ) in  $x^0 \in X$  erfüllt. Ist  $x^0$  ein lokales Minimum von NLO, so existieren Zahlen  $\lambda_i \geq 0$  ( $i \in I$ ), die so genannten Kuhn-Tucker-Multiplikatoren, mit

$$KT \begin{cases} \nabla f(x^0) + \sum_{i \in I} \lambda_i \nabla g_i(x^0) & = 0 \\ \lambda_i g_i(x^0) & = 0 \forall i. \end{cases}$$

Die beiden Bedingungen werden auch als Kuhn-Tucker Bedingungen bezeichnet.

*Beweis.* Sei  $x^0$  ein lokales Minimum. Dann gilt  $f(\varphi(\theta)) \geq f(\varphi(0)) = f(x^0)$  für kleine  $\theta$  und jede zulässige Kurve  $\varphi$ . Die Taylor Entwicklung von  $f(\varphi(\theta))$  in  $\theta = 0$  ergibt

$$f(\varphi(\theta)) = f(\varphi(0)) + \theta \nabla f^\top(x^0) \frac{d\varphi}{d\theta}(0) + \underbrace{\theta^2 R_2(\theta)}_{\xrightarrow{\theta \rightarrow 0} 0}.$$

Mit  $y := \frac{d\varphi}{d\theta}(0)$  erhalten wir dann nach Definition eine zulässige Richtung. Da  $x^0$  ein lokales Minimum ist, gilt  $\nabla f^\top(x^0)y \geq 0$  für alle zulässigen Richtungen  $y \in C_{\text{zul}}$ .

Betrachten wir den Grenzübergang von  $y^k \rightarrow y$ . Dann erhalten wir aus der Stetigkeit der Funktionen, dass  $\nabla f^\top(x^0)y \geq 0$  für alle  $y \in \overline{C_{\text{zul}}}$  gilt. Mit der Constraint Qualification (CQ) ergibt sich  $\nabla f(x^0)^\top y \geq 0$  für alle  $y \in G = \{y | \nabla g_i^\top(x^0)y \leq 0\}$ .




ABBILDUNG 13. Der negative Gradient von  $f$  liegt im Kegel, der von  $\nabla g_i(x^0)$  mit  $i \in I_0$  aufgespannt wird.

Also ist notwendig dafür, dass  $x^0$  ein lokales Minimum ist, dass  $\nabla f^\top(x^0)y \geq 0$  für alle  $y$  mit  $-\nabla g_i^\top(x^0)y \geq 0$  gilt. Dies hat wieder Ähnlichkeit mit dem Farkas Lemma [Sei  $a_i \in \mathbb{R}^n$ ,  $i = 1, \dots, m$  und  $c \in \mathbb{R}^n$ . Folgt aus  $y^\top a_i \geq 0$  für alle  $i$ , dass  $y^\top c \geq 0$  ist, dann ist dieses äquivalent dazu, dass  $c \in C(a_1, \dots, a_m)$ ] und wir erhalten  $\nabla f^\top(x^0)$  ist ein Element des Kegels, der von den Vektoren  $-\nabla g_i(x^0)$  mit  $i \in I^0$  aufgespannt wird. Dies ist gleichbedeutend damit, dass  $\lambda_i \geq 0$  für  $i \in I^0$  mit  $\nabla f(x^0) = \sum_{i \in I^0} \lambda_i (-\nabla g_i(x^0))$  existieren. Äquivalent dazu gilt mit  $\lambda_i = 0$  für alle  $i \in I \setminus I^0$ , dass  $\lambda_i \geq 0$  für  $i \in I$  existieren, für die  $\nabla f(x^0) + \sum_{i \in I} \lambda_i \nabla g_i(x^0) = 0$  gilt. Das kann man umformen zu:  $\exists \lambda_i \geq 0$  mit  $\lambda_i g_i(x^0) = 0$  für alle  $i \in I$  und  $\nabla f(x^0) + \sum_{i \in I} \lambda_i \nabla g_i(x^0) = 0$ , die KT- Bedingungen.  $\square$

*Note 2.7.* Die  $\lambda_i$  sind eindeutig bestimmt, wenn die  $\nabla g_i(x^0)$  linear unabhängig sind.

Betrachten wir nun die Verallgemeinerung auf "  $\leq$  " und „=" Restriktionen. Dazu erhalten wir das neue Problem (NLO<sup>+</sup>)

$$\text{NLO}^+ \begin{cases} \min f(x) \\ g_i(x) & \leq 0 \quad i \in I \\ h_l(x) & = 0 \quad l \in L \\ x & \in \mathbb{R}^n, \end{cases}$$

wobei  $f, g_i, h_l : \mathbb{R}^n \rightarrow \mathbb{R}$  stetig differenzierbar sind. Die Begriffe Lösungsmenge, zulässige Richtungen und  $C_{\text{zul}}$  des NLO Problems lassen sich auf das NLO<sup>+</sup> übertragen. Die Menge  $G$  definieren wir jetzt als  $G = \{y \in \mathbb{R}^n | \nabla g_i^\top(x^0)y \leq$

0 für alle  $i \in I^0$ ,  $\nabla h_l^\top(x^0)y = 0$  für alle  $l \in L$ }. Die CQ- Bedingung bedeutet weiterhin  $\overline{C}_{\text{zul.}} = G$ . Für die Bedingungen  $g_i(x) \leq x$  mit  $g_i$  stetig, gilt  $C_{\text{zul.}} = \overline{C}_{\text{zul.}}$ .

**Theorem 2.8.** [Kuhn- Tucker '51] Seien  $f, g_i, h_l : \mathbb{R}^n \rightarrow \mathbb{R}$  stetig differenzierbare Funktionen. Außerdem sei die (CQ) in  $x^0 \in X$  erfüllt. Sei  $x^0$  ein lokales Minimum. Dann gibt es Zahlen  $\lambda_i \geq 0$  mit  $i \in I$  und  $\mu_l$  mit  $l \in L$ , so dass

$$KT \begin{cases} \nabla f(x^0) + \sum_{i \in I} \lambda_i \nabla g_i(x^0) + \sum_{l \in L} \mu_l \nabla h_l(x^0) & = 0 \\ \lambda_i g_i(x^0) & = 0 \quad \forall i \in I \end{cases}$$

gilt.

*Beweis.* Das Problem läßt sich auf den Fall aus Satz 2.6 zurückführen, indem man für  $h(x) = 0$  die Bedingungen  $h(x) \leq 0$  und  $-h(x) \leq 0$  einführt.  $\square$

*Note 2.9.* Die (CQ) gilt in  $x^0$ , wenn eine der folgenden Bedingungen erfüllt sind:

- (1) die Funktionen  $g_i$  sind konvex, die Funktionen  $h_l$  sind linear und es gibt ein  $\bar{x} \in X$  mit  $g_i(\bar{x}) < 0$  für alle  $i$  und  $h_l(\bar{x}) = 0$  für alle  $l$ .
- (2) Die Gradienten  $\nabla g_i(x^0)$  und  $\nabla h_l(x^0)$  sind (zusammen) linear unabhängig.

Wir wollen aber nicht nur notwendige sondern auch hinreichende Bedingungen für lokale Minima.

**2.2. Hinreichende Bedingungen für Optimalität: Sattelpunkte.** Betrachte wieder das nichtlineare Optimierungsproblem (NLO) mit

$$\text{NLO} \begin{cases} \min f(x) \\ g_i(x) & \leq 0 \\ x \in & S \subset \mathbb{R}^n. \end{cases}$$

An die Funktionen  $f, g_i : \mathbb{R}^n \rightarrow \mathbb{R}$  werden ansonsten keine Bedingung gestellt. Wir bringen die Nebenbedingungen  $g_i(x) \leq 0$  mit den Lagrange-Multiplikatoren in die Zielfunktion und erhalten die *Lagrange-Funktion*

$$L(x, \lambda) := f(x) + \sum_{i \in I} \lambda_i g_i(x)$$

mit  $\lambda_i \geq 0$ . Der Punkt  $(\bar{x}, \bar{\lambda})$  mit  $\bar{x} \in S$  und  $\bar{\lambda} \geq 0$  heißt *Sattelpunkt* (Abb. 14) von  $L(x, \lambda)$ , wenn

$$\begin{aligned} L(\bar{x}, \bar{\lambda}) &\leq L(x, \bar{\lambda}) \text{ für alle } x \in S \\ L(\bar{x}, \bar{\lambda}) &\geq L(\bar{x}, \lambda) \text{ für alle } \lambda \geq 0. \end{aligned}$$




ABBILDUNG 14. Sattelpunkt der Funktion  $L(x, \lambda)$ .

Wir werden zeigen, dass ein Sattelpunkt  $(\bar{x}, \bar{\lambda})$  von  $L(x, \lambda)$  ein globales Minimum  $\bar{x}$  von  $f$  darstellt.

**Theorem 2.10.** [*charakteristische Eigenschaften von Sattelpunkten*]

Der Punkt  $(\bar{x}, \bar{\lambda})$  mit  $\bar{x} \in S$  und  $\bar{\lambda} \geq 0$  ist genau dann ein Sattelpunkt von  $L(x, \lambda)$  wenn

- (1)  $L(\bar{x}, \bar{\lambda}) = \min_{x \in S} L(x, \bar{\lambda})$
- (2)  $g_i(\bar{x}) \leq 0$  für alle  $i \in I$
- (3)  $\bar{\lambda}_i g_i(\bar{x}) = 0$  für alle  $i \in I$

gilt.

*Beweis.* "  $\Rightarrow$  " zu (1): ist klar nach Definition.

zu (2): Es gilt  $L(\bar{x}, \bar{\lambda}) \geq L(\bar{x}, \lambda)$  für alle  $\lambda \geq 0$ . Nach der Definition von  $L(x, \lambda)$  erhalten wir  $f(\bar{x}) + \sum_i \bar{\lambda}_i g_i(\bar{x}) \geq f(\bar{x}) + \sum_i \lambda_i g_i(\bar{x})$  für alle  $\lambda \geq 0$ . Umgeformt ergibt sich dann

$$(1) \quad \sum (\lambda_i - \bar{\lambda}_i) g_i(\bar{x}) \leq 0$$

für alle  $\lambda \geq 0$ .

Annahme: (2) gilt nicht für  $i_0$ , d.h.  $g_{i_0}(\bar{x}) > 0$ . Dann kann  $\lambda_{i_0}$  so groß gewählt werden, dass  $\sum_{i \in I} (\lambda_i - \bar{\lambda}_i) g_i(\bar{x}) > 0$ . Dies ist ein Widerspruch zu (1).

zu (3): Betrachte den Vektor  $\lambda = 0$ . Für diesen muss auch (1) gelten. Damit gilt  $\sum_{i \in I} -\bar{\lambda}_i g_i(\bar{x}) \leq 0$ . Da für alle  $\bar{\lambda} \geq 0$  und  $g_i(\bar{x}) \leq 0$  die Ungleichung  $\sum_{i \in I} \bar{\lambda}_i g_i(\bar{x}) \leq 0$  gilt (das haben wir gerade gezeigt), folgt nun, dass  $\sum_{i \in I} \bar{\lambda}_i g_i(\bar{x}) = 0$  ergibt. Da  $\lambda_i \geq 0$  ist und  $g_i(\bar{x}) \leq 0$  muss für die einzelnen Summanden  $\bar{\lambda}_i g_i(\bar{x}) = 0$  gelten.

"  $\Leftarrow$  " (1),(2) und (3) gelten. Aus (1) folgt sofort, dass  $L(\bar{x}, \bar{\lambda}) \leq L(x, \bar{\lambda})$  für alle  $x \in S$  ist. Aus (3) erhalten wir

$$L(\bar{x}, \bar{\lambda}) = f(\bar{x}) + \sum \bar{\lambda}_i g_i(\bar{x}) = f(\bar{x}).$$

Außerdem wissen wir, dass

$$L(\bar{x}, \lambda) = f(\bar{x}) + \sum_i \lambda_i \underbrace{g_i(\bar{x})}_{\text{nach (2) } g_i(\bar{x}) \leq 0} \leq f(\bar{x}) = L(\bar{x}, \bar{\lambda})$$

für  $\lambda \geq 0$  gilt. Die Bedingungen für eine Sattelpunkt sind also erfüllt.  $\square$

**Theorem 2.11.** Ist  $(\bar{x}, \bar{\lambda})$  einen Sattelpunkt von  $L(x, \lambda)$  so ist  $\bar{x}$  ein globales Optimum von (NLO).

*Beweis.* Nutze die drei Bedingungen von Satz 2.10. Für alle  $x \in S \cap X$  gilt

$$\Leftrightarrow \begin{array}{l} L(\bar{x}, \bar{\lambda}) \\ f(\bar{x}) + \sum \underbrace{\bar{\lambda}_i g_i(\bar{x})}_{=0 \text{ nach (3)}} \end{array} \leq \begin{array}{l} L(x, \bar{\lambda}) \\ f(x) + \sum \bar{\lambda}_i \underbrace{g_i(x)}_{\leq 0 \text{ für } x \in S \cap X} \end{array} \leq f(x)$$

Also ist  $\bar{x}$  ein globales Minimum auf  $S \cap X$ , und  $\bar{x} \in X$  wegen (2).  $\square$

*Note 2.12.* Dieser Satz gilt ohne Voraussetzungen an  $f$ ,  $g_i$  und  $S$ , also insbesondere auch für die ganzzahlige Optimierung.

Es stellt sich sofort die Frage, ob jedes globale Minimum von einem Sattelpunkt kommt? Dies muss im Allgemeinen nicht so sein.

**Example 2.13.** Wir wollen folgendes Problem betrachten:

$$\begin{aligned} \min f(x) &= -x^2 \\ 2x - 1 &\leq 0 \\ -x &\leq 0 \\ x &\leq 1. \end{aligned}$$

Die letzten beiden Bedingungen definieren unsere Menge  $S$  (Abb. ??).




ABBILDUNG 15. Globales Minimum ohne Sattelpunkt.

Das Minimum wird bei  $x = \frac{1}{2}$  mit  $f(x) = -\frac{1}{4}$  angenommen. Die Lagrange-Funktion hat die Form

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

Diese Funktion ist konkav in  $x$  für ein festes  $\lambda$ . Das bedeutet, dass  $\min_{x \in S} L(x, \lambda)$  für ein festes  $\lambda$  an einem der beiden Endpunkte angenommen wird. Also liegt das Minimum in  $x = 0$  oder in  $x = 1$ . Kein  $\bar{\lambda}$  liefert ein Minimum von  $L(x, \bar{\lambda})$  bei  $\frac{1}{2}$ . Die Lagrangefunktion hat also keinen Sattelpunkt. Trotzdem existiert ein Minimum der Funktion  $f$ .

**2.3. Notwendige und hinreichende Bedingungen für die Existenz von Sattelpunkten: Stör-Funktionen.** Die Idee ist, das NLO in eine Familie von Problemen mit gestörter rechter Seite einzubetten. Wir betrachten also das  $\text{NLO}_y$ -Problem mit einem zusätzlichen Parameter:

$$\text{NLO}_y \begin{cases} \min f(x) \\ g_i(x) \leq y_i, i \in I \\ x \in S. \end{cases}$$

Die beiden Nebenbedingungen beschreiben die Menge  $X(y)$  der zulässigen Lösungen. Die *Störfunktion* definieren wir als  $\Phi(y) := \min_{x \in X(y)} f(x)$ . Sie misst den Wert des Optimalwertes von  $f$  bei einer Variation von  $y$ . Es gilt  $\Phi(0) = \min_{x \in X} f(x)$ . Die Störfunktion ist antiton, d.h. für  $y' \leq y$  gilt  $\Phi(y') \geq \Phi(y)$ , da der Zulässigkeitsbereich von  $y'$  eine Teilmenge des Zulässigkeitsbereichs von  $y$  ist.

**Theorem 2.14.** *Das NLO habe ein globales Minimum  $\bar{x}$  mit endlichem Wert  $f(\bar{x})$ . Dann gilt: der Punkt  $(\bar{x}, \bar{\lambda})$  ist genau dann ein Sattelpunkt, wenn die Hyperebene  $z = \Phi(0) - \bar{\lambda}^\top y$  eine Stützhyperebene des Graphen der Störfunktion im Punkt  $y = 0$  ist, d.h.  $\forall y \in \mathbb{R}^m$  gilt  $\Phi(y) \geq \Phi(0) - \bar{\lambda}^\top y$ .*

**Example 2.15.** Wir wollen das Problem  $\min x_1^2 + x_2^2$  unter  $2x_1 + x_2 \leq -4$  lösen. Die Niveaumengen der Zielfunktion sind Kreise um den Nullpunkt. Der Berührungspunkt mit der Gerade  $2x_1 + x_2 = -4$  liefert dann das Optimum bei  $\bar{x} = \begin{pmatrix} -\frac{8}{5} \\ -\frac{4}{5} \end{pmatrix}$  mit dem Optimalwert  $\frac{16}{5}$  (Abb. 16)




ABBILDUNG 16. Das Optimum von  $\min(x_1^2 + x_2^2)$  unter  $2x_1 + x_2 \leq -4$  liegt bei  $\bar{x} = (-\frac{8}{5}, -\frac{4}{5})$

Für das gestörte Problem gilt  $\Phi(y) = \min(x_1^2 + x_2^2)$  unter  $2x_1 + x_2 + 4 \leq y$ . Damit erhalten wir mit  $x_1 = \frac{2y-8}{5}$  und  $x_2 = \frac{y-4}{5}$  für  $y \leq 4$  und  $x_1 = 0 = x_2$  für  $y > 4$  das Optimum von  $\text{NPO}_y$ . Also gilt

$$\Phi(y) = \begin{cases} 0 & \text{für } y \geq 4 \\ \left(\frac{2y-8}{5}\right)^2 + \left(\frac{y-4}{5}\right)^2 = \frac{1}{5}y^2 - \frac{8}{5}y + \frac{16}{5} & \text{sonst} \end{cases}$$

Die Lagrangefunktion dieses Problemes hat die Form

$$L(x, \lambda) = x_1^2 + x_2^2 + \lambda(2x_1 + x_2 + 4).$$

Der Punkt  $\bar{\lambda} = -\frac{8}{5}$  definiert den Sattelpunkt  $(\bar{x}, \bar{\lambda})$  von  $L(x, \lambda)$  und außerdem gilt  $\Phi(y) \geq \Phi(0) - \bar{\lambda}y = \frac{16}{5} - \frac{8}{5}y$  (Abb. 17).




ABBILDUNG 17. Die Funktion  $\Phi(y)$  mit Stützhyperebene  $z$  in  $y = 0$ .

*Beweis.* „ $\Rightarrow$ “ Sei  $g(x) := (g_1(x), \dots, g_2(x))^T$  und  $(\bar{x}, \bar{\lambda})$  ein Sattelpunkt. Dann ist  $f(x) + \bar{\lambda}^T g(x) \geq f(\bar{x}) + \bar{\lambda}^T g(\bar{x})$  für alle  $x \in S \supset X(y)$  und  $\bar{\lambda} \geq 0$ . Aus den Bedingungen für eine Stattelpunkt erhalten wir  $\bar{\lambda}^T g(\bar{x}) = 0$  und  $g(\bar{x}) \leq 0$ . Also gilt

$$f(x) + \bar{\lambda}^T g(x) \geq f(\bar{x}) = \Phi(0).$$

Betrachten wir ein  $y$  mit  $X(y) \neq \emptyset$ . Für ein solches  $y$  wissen wir aber, das  $g(x) \leq y$  ist und  $\bar{\lambda} \geq 0$ . Also ist  $\bar{\lambda}g(x) \leq \bar{\lambda} \cdot y$  und daraus folgt

$$f(x) \geq \Phi(0) - \bar{\lambda}^T g(x) \geq \Phi(0) - \bar{\lambda}^T y.$$

Diese Gleichung gilt nun für jedes  $y$ , für das  $(\text{NLO}_y)$  einen Lösung hat und für alle  $x \in X(y)$ . Daraus folgt  $\Phi(y) = \min_{x \in X(y)} f(x) \geq \Phi(0) - \bar{\lambda}^T y$



Falls das  $(\text{NLO}_y)$  keine Lösung hat, so ist  $\Phi(y) = \infty$  und  $\Phi(y) \geq \Phi(0) - \lambda^\top y$  automatisch erfüllt.

„ $\Leftarrow$ “: Es gibt ein  $\bar{\lambda}$  mit  $\Phi(y) \geq \Phi(0) - \bar{\lambda}^\top y$  für alle  $y$ . Wir wollen zeigen, dass  $(\bar{x}, \bar{\lambda})$  ein Sattelpunkt ist.

(a): Wir zeigen, dass  $\bar{\lambda}_i \geq 0$  gilt. Dazu nehmen wir an, dass ein  $i \in I$  mit  $\bar{\lambda}_i < 0$  existiert. Betrachte den Vektor  $y$  mit  $y_i \rightarrow \infty$  und  $y_j = 0$  für  $j \in I \setminus i$ . Dann gilt  $\Phi(0) - \bar{\lambda}^\top y \rightarrow \infty$ . Dann muss nach Voraussetzung auch  $\Phi(y)$  gegen  $\infty$  gehen. Aber  $\Phi$  ist antiton, d.h. für  $y \geq 0$  gilt  $\Phi(y) \leq \Phi(0)$ . Damit kann  $\Phi$  nicht beliebig wachsen und wir erhalten einen Widerspruch.

Wir wissen jetzt, dass die erste Bedingung für einen Sattelpunkt erfüllt ist.

(b): Wir wollen jetzt zeigen, dass  $L(\bar{x}, \bar{\lambda}) \leq L(x, \bar{\lambda})$  für alle  $x \in S$  gilt.

Sei  $x \in S$ . Es gilt  $x \in X(g(x))$ , da  $g(x) \leq g(x)$  gilt. Dann erhalten wir  $f(x) \geq \min_{x' \in X(g(x))} f(x') = \Phi(g(x))$ . Mit  $\Phi(y) \geq \Phi(0) - \bar{\lambda}^\top y$  für alle  $y$ , ergibt sich

$$f(x) \geq \Phi(g(x)) \geq \Phi(0) - \bar{\lambda}^\top g(x).$$

Umgeformt gilt also

$$f(x) + \bar{\lambda}^\top g(x) \geq \Phi(0).$$

Betrachte nun  $x = \bar{x}$ . Dann erhält man

$$f(\bar{x}) + \bar{\lambda}^\top g(\bar{x}) \geq \Phi(0) = f(\bar{x}).$$

Daraus folgt, dass  $\bar{\lambda}^\top g(\bar{x}) \geq 0$  ist. In Teil (a) hatten wir jedoch schon gezeigt, dass  $\bar{\lambda} \geq 0$  ist und da  $\bar{x}$  eine zulässige Lösung ist, gilt  $g(\bar{x}) \leq 0$ . Damit erhalten wir  $\bar{\lambda}^\top g(\bar{x}) = 0$ .

Da allgemein galt  $f(x) + \bar{\lambda}^\top g(x) \geq \Phi(0)$ , folgt

$$L(x, \bar{\lambda}) = f(x) + \bar{\lambda}^\top g(x) \geq f(\bar{x}) = f(\bar{x}) + \bar{\lambda}^\top g(\bar{x}) = L(\bar{x}, \bar{\lambda}).$$

Damit ist (b) bewiesen.

(c):  $(\bar{x}, \bar{\lambda})$  ist ein Sattelpunkt.

Mit (b),  $\bar{\lambda}^\top g(\bar{x}) = 0$  und  $g(\bar{x}) \leq 0$  sind die Bedingungen von Satz 2.10 erfüllt. Also ist  $(\bar{x}, \bar{\lambda})$  ein Sattelpunkt.  $\square$

Der Satz 2.14 kann auf das Problem  $(\text{NLO}^+)$  mit Gleichheitsbedingungen  $h_l(x) = 0$  erweitert werden, wobei die zugehörigen  $\mu_l$  dann nicht vorzeichenbeschränkt sind.

Im Beispiel 2.15 war  $\Phi(y)$  konvex. Oft ist das NLO nicht konvex und  $\Phi$  nicht konvex. Betrachten wir kurz vier unterschiedliche Fälle (Abb. 18)




ABBILDUNG 18. 1. Fall: Die Störfunktion ist nicht konvex und hat keine Stützhyperplane in  $y = 0$ . 2. Fall: Die Störfunktion ist nicht konvex, aber es existiert eine Stützhyperplane in  $y = 0$ . 3. Fall: Es existiert eine Stützhyperplane in  $y = 0$ . 4. Fall: Die Störfunktion ist konvex.

1. Fall: Es gibt keine Stützhyperebene in  $y = 0$ . Damit gibt es auch keinen Sattelpunkt.

2. Fall: Die Störfunktion  $\Phi$  ist nicht konvex, aber dennoch existiert eine Stützhyperebene in  $y = 0$ . Dann gibt es auch einen Sattelpunkt und wir erhalten sofort ein Minimum von  $f(x)$ .

3. Fall: Die Störfunktion ist nicht differenzierbar und nicht konvex, aber es existiert ein Sattelpunkt. Dann gibt es auch eine Stützhyperebene.

4. Fall: Die Störfunktion ist konvex. Dann gibt es eine Stützhyperebene und damit auch einen Sattelpunkt.

#### 2.4. Sattelpunkte bei konvexen Optimierungsproblemen.

**Theorem 2.16.** *Seien die Funktionen  $f, g_i$  konvex, sei  $S$  konvex und es gebe ein  $x \in S$  mit  $g_i(x) < 0$  für alle  $i$ . Hat dann das (NLO) ein Minimum bei  $\bar{x}$ , so existiert ein  $\bar{\lambda} \geq 0$  mit  $(\bar{x}, \bar{\lambda})$  ist ein Sattelpunkt. D.h. bei konvexen Problemen kommen die Minima von einem Sattelpunkt.*

*Beweis.* Um den Satz zu beweisen, brauchen wir drei Eigenschaften:

(1): Die Störfunktion  $\Phi(y)$  ist konvex.

Sei  $\lambda \in [0, 1]$  und  $y_1, y_2 \in \mathbb{R}$ . Die Störfunktion ist definiert durch  $\Phi(y) := \min\{f(x) | g(x) \leq y\}$ . Sei  $x_1 \in S$  mit  $f(x_1) = \Phi(y_1)$  und  $x_2 \in S$  mit  $f(x_2) = \Phi(y_2)$ . Dann gilt

$$\begin{aligned} (1 - \lambda)\Phi(y_1) + \lambda\Phi(y_2) &= (1 - \lambda)f(x_1) + \lambda f(x_2) \\ &\geq f((1 - \lambda)x_1 + \lambda x_2), \end{aligned}$$

da  $f$  konvex ist. Der Punkt  $x_3 := (1 - \lambda)x_1 + \lambda x_2 \in S$ , da  $S$  konvex ist. Außerdem gilt  $g(x_3) \leq (1 - \lambda)g(x_1) + \lambda g(x_2) \leq (1 - \lambda)y_1 + \lambda y_2$ , da auch  $g$  konvex ist. Also gilt  $x_3 \in X((1 - \lambda)y_1 + \lambda y_2)$  und wir können die Abschätzung von oben fortführen mit:

$$\begin{aligned} (1 - \lambda)\Phi(y_1) + \lambda\Phi(y_2) &\geq f(x_3) \\ &\geq \min\{f(x) | g(x) \leq (1 - \lambda)y_1 + \lambda y_2\} \\ &= \Phi((1 - \lambda)y_1 + \lambda y_2). \end{aligned}$$

(2):  $\text{dom}(\Phi) := \{y | \Phi(y) < \infty\} \neq \emptyset$

Da das NLO sein Optimum bei  $\bar{x}$  annimmt, gilt  $f(\bar{x}) < \infty$  und  $g(\bar{x}) \leq 0$ . Daraus folgt  $0 \in \text{dom}(\Phi)$ .

(3): 0 ist aus dem Inneren von  $\text{dom}(\Phi)$ .

Sei  $y \geq 0$ . Dann gilt  $g_i(\bar{x}) \leq 0 < y$ . Weiter erhalten wir  $\Phi(y) \leq f(\bar{x}) < \infty$  und somit ist  $y \in \text{dom}(\Phi)$ .

Sei jetzt  $y < 0$ . Nach Voraussetzung existiert ein  $\tilde{x}$  mit  $g_i(\tilde{x}) = y_i < 0$ . Da immer noch  $f(\tilde{x}) = \infty$  gelten kann, betrachten wir die nicht leere, offene Umgebung  $U_{\tilde{x}}$  von  $\tilde{x}$  mit  $U_{\tilde{x}} := \{x | g_i(x) < 0 \text{ für alle } i \in I\}$ . Eine solche Umgebung muss existieren, da  $g_i$  entweder stetig in  $\tilde{x}$  sind (dann liegt  $\tilde{x}$  im Inneren von  $S$ ) oder die  $g_i$  machen an der Stelle  $\tilde{x}$  einen Sprung nach unten, da die  $g_i$  konvex sind (dann liegt  $\tilde{x}$  auf dem Rand von  $S$ ). Da  $f(\bar{x}) < \infty$  ist, muss auch aus der Umgebung  $U_{\tilde{x}}$  ein  $x^*$  existieren, mit  $f(x^*) < \infty$ . Wähle  $y = \max_{i \in I} g_i(x^*) < 0$ . Dann gilt  $\Phi(y) \leq f(x^*) < \infty$ . Also ist  $y < 0 \in \text{dom}(\Phi)$ . Damit liegt 0 im Inneren von  $\text{dom}(\Phi)$ .

Ein Vektor  $\gamma$  für eine konvexe Funktion  $f$  heißt Subgradient in  $u$ , wenn  $f(v) - f(u) \geq \gamma^\top(v - u)$  für alle  $v$  gilt. Da  $y = 0$  im Inneren liegt, ist die konvexe Funktion  $\Phi$  an der Stelle stetig. Daraus folgt, dass  $\Phi(y)$  einen Subgradienten  $\gamma$  in  $y = 0$  hat. Wenden wir die Definition des Subgradienten an, erhalten wir:  $\exists \gamma$  mit  $\Phi(y) - \Phi(0) \geq \gamma^\top(y - 0)$ . Umgeformt gilt:  $\Phi(y) \geq \Phi(0) + \gamma^\top y$ . Diese ist äquivalent zu:  $\Phi(y) \geq \Phi(0) - \bar{\lambda}^\top y$  mit  $\bar{\lambda} = -\gamma$ . Nach Theorem 2.14 ist dann  $(\bar{x}, \bar{\lambda})$  ein Sattelpunkt.  $\square$

*Conclusion 2.17.* Im Fall, dass  $g_i$  und  $f$  konvex sind, gilt: Der Punkt  $(\bar{x}, \bar{\lambda})$  ist genau dann ein Sattelpunkt, wenn  $-\bar{\lambda}$  ein Subgradient der Störfunktion im Punkt  $y = 0$  ist.

Eine entsprechende Aussage gilt für Gleichheitsbedingungen  $h_l(x) = 0$ .

## 2.5. Kuhn-Tucker Bed. für den konvexen differenzierbaren Fall.

**Theorem 2.18.** Betrachte das nichtlineare Optimierungsproblem (NLO)

$$NLO \begin{cases} \min f(x) \\ g_i(x) \leq 0 \quad \forall i \\ f, g_i \quad \text{konvex, differenzierbar} \end{cases}$$

Außerdem existiert ein  $x \in \mathbb{R}^n$  mit  $g_i(x) < 0$  für alle  $i$ . Dann ist  $\bar{x} \in X$  genau dann ein globales Minimum von NLO, wenn die Kuhn-Tucker-Bedingungen in  $\bar{x}$  erfüllt sind. D.h.  $\exists \bar{\lambda} \geq 0$  mit  $\nabla_x L(\bar{x}, \bar{\lambda}) = 0$  und  $\bar{\lambda}_i g_i(\bar{x}) = 0$  für alle  $i$ .

*Beweis.* „ $\Rightarrow$ “ folgt aus Satz 2.6.

„ $\Leftarrow$ “ Aus der ersten KT-Bedingung  $\nabla_x L(\bar{x}, \bar{\lambda}) = 0$  und da  $L(x, \bar{\lambda})$  als Summe konvexer Funktionen konvex ist, folgt, dass  $\bar{x}$  ein Minimum von  $L(x, \bar{\lambda})$  ist. Da  $\bar{x}$  zulässig ist, gilt  $g_i(\bar{x}) \leq 0$ . Zusammen mit der letzten KT-Bedingung, dass  $\bar{\lambda} \geq 0$  und  $\bar{\lambda}_i g_i(\bar{x}) = 0$ , sind die Bedingungen für Satz 2.10 erfüllt. Damit ist  $(\bar{x}, \bar{\lambda})$  ein Sattelpunkt und Satz 2.11 sagt aus, dass  $\bar{x}$  dann ein globales Minimum ist.  $\square$

Wir machen jetzt noch eine Spezialisierung auf Nichtnegativitätsbedingungen und lineare Gleichungsbedingungen.

Betrachten wir als erstes die Nichtnegativitätsbedingungen  $x_j \geq 0$ .

1. Fall: Sei  $n = 1$ :




ABBILDUNG 19. Nichtnegativitätsbedingungen in Dimension 1

Dann erhalten wir für das Problem  $\min f(x)$  unter  $x \geq 0$  die Bedingung  $\frac{df}{dx}(x^0) = 0$  für ein Optimales  $x^0$  im ersten Fall (Abb. 19 links) und im zweiten Fall  $\frac{df}{dx}(x^0) \geq 0$  und  $x^0 = 0$  (Abb. 19 rechts). Also erhalten wir zusammengefasst die notwendigen Bedingung  $x^0 \frac{df}{dx}(x^0) = 0$  und  $\frac{df}{dx}(x^0) \geq 0$  für  $x^0 \geq 0$ . Entsprechend erhält man im mehrdimensionalen Fall  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  mit  $\min f(x)$  unter  $x \geq 0$ , dass entweder für  $x^0 > 0$  die Bedingung  $\nabla f(x^0) = 0$  erfüllt sein muss, oder  $x^0$  am Rand mit  $x_j^0 = 0$  für ein oder mehrere  $j$  gilt. Komponentenweise ergeben sich die notwendigen Bedingungen:

$$x_j^0 \frac{\partial f}{\partial x_j}(x^0) = 0 \quad \frac{\partial f}{\partial x_j}(x^0) \geq 0 \quad x_j^0 \geq 0.$$

Diese Herleitung war jetzt sehr anschaulich. Man kann dies auch exakt aus den Kuhn-Tucker Bedingungen ablesen. Die Nebenbedingung hat die Form  $g_j(x) =$

$-x_j \leq 0$ . Kuhn-Tucker ist anwendbar, da die Nebenbedingungen konvex mit innerem Punkt sind und somit nach Lemma 2.3 die (CQ) erfüllt ist. Die KT-Bedingungen sagen jetzt aus, dass ein  $\lambda_j \geq 0$  mit

$$(2) \quad \nabla f(x^0) + \sum_j \lambda_j \nabla g_j(x^0) = 0$$

und

$$(3) \quad \lambda_j g_j(x^0) = 0 \quad \forall j$$

existiert. Aus (2) erhalten wir

$$\frac{\partial f}{\partial x_j}(x^0) + \lambda_j(-1) = 0$$

für  $j = 1, \dots, n$ . Also folgt  $\lambda_j = \frac{\partial f}{\partial x_j}(x^0)$  und damit  $\frac{\partial f}{\partial x_j}(x^0) \geq 0$ , die zweite Bedingung. In (3) eingesetzt ergibt dies gerade

$$-x_j^0 \cdot \frac{\partial f}{\partial x_j}(x_0) = 0,$$

unsere erste Bedingung.

Betrachten wir nun lineare Gleichheitsbedingungen und Nichtnegativitätsbedingungen. Wir haben jetzt das Problem: minimiere  $f(x)$  unter  $h_i(x) = -\sum_j h_{ij}x_j + b_i = 0$  und  $g_j(x) = -x_j \leq 0$ . Die CQ ist erfüllt, da die Gleichheitsbedingungen linear und die Ungleichungsbedingungen konvex mit einem inneren Punkt sind. Also sind die KT-Bedingungen notwendig und wir erhalten: es gibt  $\lambda_j \geq 0$  und  $\mu_i$  beliebig mit

$$(4) \quad \nabla f(x^0) + \sum_j \lambda_j \nabla g_j(x^0) + \sum_i \mu_i \nabla h_i(x^0) = 0$$

und

$$(5) \quad \lambda_j g_j(x^0) = 0 \quad \forall j.$$

Betrachten wir Bedingungen (4) komponentenweise, erhalten wir

$$\frac{\partial f}{\partial x_j}(x^0) - \lambda_j - \sum_i \mu_i h_{ij} = 0$$

und damit

$$\lambda_j = \frac{\partial f}{\partial x_j}(x^0) - \sum_i \mu_i h_{ij}.$$

Da  $\lambda_j \geq 0$  ist, erhalten wir

$$(6) \quad \frac{\partial f}{\partial x_j}(x^0) - \sum_i \mu_i h_{ij} \geq 0.$$

Setzen wir dieses in die Bedingung (5) ein, erhalten wir

$$(7) \quad x_j^0 \left( \frac{df}{dx_j}(x^0) + \sum_i \mu_i h_{ij} \right) = 0$$

und wir erhalten für die Nebenbedingungen

$$(8) \quad \sum_j h_{ij} x_j = b_i \quad \forall i$$

und

$$(9) \quad x_j \geq 0 \quad \forall j.$$

Also: notwendige Bedingungen für Optimalität von  $x^0$  ist die Existenz von Zahlen  $\mu_i$ ,  $i = 1, \dots, m$  mit (6)-(9).

*Note 2.19.* In beiden Fällen lässt sich über Sattelpunkte analog zu Satz 2.16 und 2.18 auch die Umkehrung zeigen.

**2.6. Anwendung auf das SO der Verkehrsoptimierung.** Das Verkehrsoptimierungsproblem hatte die folgende Form:

$$\begin{aligned} \min C(x(f)) &= \sum_{a \in A} x_a \tau_a(x_a) \\ \sum_{p \in \mathcal{P}_k} f_p &= d_k \quad k \in C \\ f_p &\geq 0 \quad \forall p \in \mathcal{P} \end{aligned}$$

wobei  $x$  der Kantенfluss und  $f$  der Pfadfluss ist, und  $x_a = \sum_{p \ni a} f_p$  gilt. Betrachten wir die Kuhn-Tucker Bedingungen (6)-(9). Bedingung (7) sagt aus, dass

$$f_p \left( \frac{\partial C}{\partial f_p}(f) - \mu_k \right) = 0$$

für alle  $k$  und  $p \in \mathcal{P}_k$  ist. Aus der Bedingung (6) ergibt sich dann

$$\frac{\partial C}{\partial f_p}(f) - \mu_k \geq 0.$$

Wir betrachten zunächst

$$\begin{aligned} \frac{\partial C}{\partial f_p}(x(f)) &= \frac{\partial}{\partial f_p} \left( \sum_{a \in A} \underbrace{x_a(f) \tau_a(x_a(f))}_{=: c_a(x_a(f))} \right) \\ &= \sum_{a \in A} \frac{\partial}{\partial f_p} c_a(x_a(f)) \\ &= \sum_{a \in A} \frac{\partial c_a}{\partial x_a}(x_a) \underbrace{\frac{\partial x_a(f)}{\partial f_p}(f)}_{=: \delta_{p,a}} \\ &= \left[ \underbrace{\sum_{a \in p} \tau_a(x_a) + x_a \frac{d}{dx_a} \tau(x_a)}_{\text{marginale Kosten der Kante } a, \text{ modifizierte Fahrzeitfkt.}} \right] \end{aligned}$$

da  $x_a = \sum_{p \ni a} f_p$  mit  $\delta_{p,a} = \begin{cases} 1 & \text{falls } a \in p \\ 0 & \text{sonst} \end{cases}$ . Die zwei Bedingungen sagen dann aus:

$$(10) \quad f_p \left( \sum_{a \in P} c'_a(x_a) - \mu_k \right) = 0 \quad \forall k, \quad \forall p \in \mathcal{P}_k$$

und

$$(11) \quad \sum_{a \in P} c'_a(x_a) - \mu_k \geq 0 \quad \forall k, \quad \forall p \in \mathcal{P}_k.$$

Man erhält also genau die Wardrop Bedingungen für das UE bzgl.  $c'_a(x_a)$  als Fahrzeitfunktionen.

Weiter können wir aus der Gleichung (10) ableiten, dass alle Fluss führenden Wege zu Commodity  $k$  die selbe Länge bzgl.  $c'_a(x_a)$  nämlich  $\mu_k$  haben und (11) besagt, dass alle anderen Wege mindestens die Länge  $\mu_k$  haben. Daraus können wir wieder folgern, dass das SO gleich dem UE bzgl.  $c'(x_a)$  ist.