

## §2 Grundlagen des nichtlinearen (konvexen) Optimierung

## 2.1 Karush-Kuhn-Tucker Bedingungen

Basicproblem (NLO)

$$\min f(x)$$

$$\text{unter } g_i(x) \leq 0 \quad i=1, \dots, m$$

$$x \in \mathbb{R}^n, \quad f, g_i: \mathbb{R}^n \rightarrow \mathbb{R} \quad \text{stetig, diffbar}$$

$X := \{x \in \mathbb{R}^n \mid g_i(x) \leq 0 \quad \forall i\}$  heißt Menge der zulässigen Lösungen,

$X \neq \emptyset$  vorausgesetzt

Suchen Bedingungen für lokales Optimum

Idee:  $x^0$  ist lokales Optimum, wenn in  $\varepsilon$ -Umgebung kein besserer Punkt ist

Konkretisierung:



Entlang einer Kurve ausgehend von  $x^0$  kommt man nicht zu einem besseren Punkt

zulässige Kurve:  $\varphi: \mathbb{R}^1 \rightarrow \mathbb{R}^n$  stetig, diffbar

mit  $\varphi(0) = x^0$ ,  $\varphi(\theta) \in X$  für kleines  $\theta > 0$


zulässige Richtung in  $x^0$

= jede Tangente einer zulässigen Kurve  $\varphi$  in  $x^0$

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

$C_{\text{zul}}$  := Kegel (cone) aufgespannt durch alle zulässigen Richtungen in  $x^0$

$C_{zul}$  spielt wichtige Rolle für Optimalitätsbedingungen



zurück: notwendige Bedingungen dafür, dass  $y \in C_{ad}$

Sei  $I^0 := \{i = 1, \dots, m \mid g_i(x_0) = 0\}$  aktive Bedingungen in  $x_0$

Sei  $G := \{y \in \mathbb{R}^n \mid \nabla g_i^T(x_0) \cdot y \leq 0 \quad \forall i \in I^0\}$

$G$  ist ebenfalls ein Kegel

2.1 LEMMA: (Notwendige Bedingung für zulässige Richtung)

Sei  $y$  eine zulässige Richtung in  $x_0$ . Dann gilt

$$\nabla g_i^T(x_0) \cdot y \leq 0 \quad \forall i \in I^0$$

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

Beweis: Sei  $\varphi$  eine zulässige Kurve in  $x_0$  und  $y = \frac{d\varphi}{d\theta}(0)$

eine zulässige Richtung in  $x_0$

a)  $g_i(x_0) < 0$  für  $i \notin I^0 \Rightarrow g_i(\varphi(\theta)) < 0$  für kleines  $\theta$

$g_i(x_0) = 0$  für  $i \in I^0 \Rightarrow g_i(\varphi(\theta)) \leq 0$  für kleines  $\theta$


b) Taylor Entwicklung von  $g_i(\varphi(\theta))$  in Umgebung von  $\theta = 0$

$$\text{und } \theta \text{ ergibt } \underbrace{g_i(\varphi(0))}_{g_i(x_0)} + \theta \nabla g_i^T(x_0) \frac{d\varphi}{d\theta}(0) + \underbrace{A_i^2 R_2(\theta)}_{\rightarrow 0 \text{ für } \theta \rightarrow 0} \leq 0$$

$$[\text{Taylor: } f(x) = \sum_{v=0}^n \frac{f^{(v)}(x_0)}{v!} (x-x_0)^v + (x-x_0)^{n+1} \cdot R_n(x)]$$

$$g_i(x^0) = 0 \text{ für } i \in I^0 \Rightarrow \nabla g_i^T(x^0) \cdot y \leq 0 \text{ für } i \in I^0 \quad \square$$

Beachte: Die Umkehrung gilt i. d. nicht!



$$\nabla g_2(x^0) = \begin{pmatrix} 0 \\ -1 \end{pmatrix} \Big|_{x^0} = \begin{pmatrix} 0 \\ -1 \end{pmatrix}$$

$$\nabla g_3(x^0) = \begin{pmatrix} 3(1-x_1)^2 \\ 1 \end{pmatrix} \Big|_{x^0} = \begin{pmatrix} 0 \\ 1 \end{pmatrix}$$

$$\text{Also: } \nabla g_i^T(x^0) \cdot y \leq 0 \stackrel{\wedge}{=} \underbrace{\begin{pmatrix} 0 \\ -1 \end{pmatrix}^T \begin{pmatrix} y_1 \\ y_2 \end{pmatrix}}_{-y_2 \leq 0} \leq 0 \quad \text{und} \quad \underbrace{\begin{pmatrix} 0 \\ 1 \end{pmatrix}^T \begin{pmatrix} y_1 \\ y_2 \end{pmatrix}}_{y_2 \leq 0} \leq 0$$

erfüllt von  $y = \begin{pmatrix} 1 \\ 0 \end{pmatrix}$ , also  $x^0 + \theta \begin{pmatrix} 1 \\ 0 \end{pmatrix} \notin X$

Daher einschneidende Bedingungen an  $X$ :

$X$  erfüllt die constraint qualification Annahme (Kuhn & Tucker 51) (CQ)

$\Leftrightarrow$  abgeschlossene Hülle  $\bar{C}_{zul} = G$

ist sehr starke Bedingung, sichert Umkehrung in Lemma 2.1

(zumindest in dem Sinne, dass jedes  $y \in G$  Limes einer Folge von zulässigen Richtungen ist)

$(CQ)$  ist schwer zu überprüfen. Daher ist man an hinreichenden Bedingungen interessiert

Hinreichende Bedingungen für die Umkehrung:

2.2 LEMMA: Jede der folgenden Bedingungen ist hinreichend für die Gültigkeit von  $(CQ)$


- (a) alle Funktionen  $g_i$  sind linear (Karlin 59)
- (b) alle Funktionen  $g_i$  sind konvex und das Innere von  $X$  ist nicht leer (Slater 50)
- (c) die Gradienten  $\nabla g_i(x^0)$   $i \in I^0$  sind linear unabhängig (Fiacco & McCormick 68)

Bemerkung: da (a) und (b) unabhängig von  $x^0$  sind, sichern sie die Gültigkeit der Behauptung auf ganz  $X$ .


Beweis: zu (a): Sei  $g_i(x) = a_i^T x + b_i$ ,

$\Rightarrow X$  ist Durchschnitt von Halbräumen. O.B.d.A. sei  $x^0 = 0$

$\Rightarrow$  jede Gerade von  $x^0$  aus in  $X$  ist zulässige Richtung



$\nabla g_i(x^0) = a_i$  : Vektor senkrecht auf der Hyperebene  $a_i^T x + b_i = 0$   
(Normalenvektor)



$$\nabla g_i(x^0)^T y = a_i^T y \leq 0$$

erfüllt für alle  $y$ , die nicht-negative Projektion auf  $-a_i$  haben


$\Rightarrow$  alle  $y$  im Halbraum der durch  $a_i^T x + b_i = 0$  definiert wird und in dem  $x$  liegt

$$\Rightarrow G = C_{\text{zul}} = \bar{C}_{\text{zul}}$$

zu (b) und (c)

Sei  $R := \{y \mid \nabla g_i^T(x^0) \cdot y < 0\}$  Kegel der zulässigen Richtungen in  $x^0$   
(Def)

$$\text{klar: } R \subseteq C_{\text{zul}} \Rightarrow \bar{R} \subseteq \bar{C}_{\text{zul}}$$



Claim:  $R \neq \emptyset \Rightarrow \bar{R} = G$  (d.h. (CQ) erfüllt)

denn: Sei  $\bar{y} \in R$ , d.h.  $\nabla g_i^T(x^0) \cdot \bar{y} < 0 \quad \forall i \in I^0$

Sei  $y \in G$  beliebig, d.h.  $\nabla g_i^T(x^0) \cdot y \leq 0 \quad \forall i \in I^0$

$$\Rightarrow \lambda y + (1-\lambda)\bar{y} \in R \quad \text{für alle } \lambda \in (0,1)$$

Grenzübergang  $\lambda \nearrow 1$  erzeugt Folge zulässiger Richtungen  $y^\lambda \in R$

$$\text{mit } \lim_{\lambda \nearrow 1} y^\lambda = y \Rightarrow \bar{R} = G$$

zu (b):  $\text{int}(X) \neq \emptyset \Rightarrow \exists \bar{x}$  mit  $g_i(\bar{x}) < 0 \quad \forall i$

Konvexität der  $g_i \Rightarrow 0 > g_i(\bar{x}) \geq g_i(x^0) + \nabla g_i^T(x^0)(\bar{x} - x^0)$   
↑  
beliebiges  $x^0$

$$\geq \nabla g_i^T(x^0)(\bar{x} - x^0)$$

da  $g_i(x^0) = 0$  für  $i \in I^0$

$$\Rightarrow \bar{x} - x^0 \in R$$

$\Rightarrow$  Behauptung mit Claim

zu (c):  $\nabla g_i(x^0)$  für  $i \in I^0$  linear unabhängig

$\Leftrightarrow \sum_{i \in I^0} \lambda_i \nabla g_i(x^0) = 0$  hat nur die triviale Lösung  $\lambda = 0$

$\Rightarrow \lambda^T \begin{pmatrix} \nabla g_1^T(x^0) \\ \vdots \\ \nabla g_k^T(x^0) \end{pmatrix} = 0 \quad \lambda \geq 0, \lambda \neq 0$  hat keine Lösung

Farkas Variante  
 $\Rightarrow$   
 (\*)  $\exists y$  mit  $\begin{pmatrix} \nabla g_1^T(x^0) \\ \vdots \\ \nabla g_k^T(x^0) \end{pmatrix} \cdot y < 0$

$\Leftrightarrow \nabla g_i^T(x^0) \cdot y < 0 \quad \forall i \in I^0$

$\Leftrightarrow y \in R$

zu (\*): Sei  $A = \begin{pmatrix} \nabla g_1^T(x^0) \\ \vdots \\ \nabla g_k^T(x^0) \end{pmatrix}$ . Dann sagt (\*)

$$\underbrace{\lambda^T A = 0, \lambda \geq 0, \lambda \neq 0 \text{ hat keine Lösung}}_{(1)} \Leftrightarrow \underbrace{\exists y \text{ mit } Ay < 0}_{(2)}$$

(2)  $\Leftrightarrow Ay \leq -1$  (Skalierung)

Lemma 7.17 in ADM II:  $\{y \mid Ay \leq -1\} = \emptyset \Leftrightarrow \exists \lambda \geq 0 \quad \lambda^T A = 0, \underbrace{\lambda^T (-1)}_{=0} < 0$   
 $\Rightarrow \lambda \neq 0$

also: Lemma 7.17 selbst:  $\neg(2) \Rightarrow \neg(1)$ , Widerspruch  $\square$

Notwendige Bedingungen für Existenz eines lokalen Minimums:

2.3 SATZ (Karun & Tucker S1)

$f, g_i: \mathbb{R}^n \rightarrow \mathbb{R}$  stetig diffbar, (CQ) erfüllt in  $x^0 \in X$ .

Ist  $x^0$  lokales Minimum von (NLP): min  $f(x)$ ,  $x \in X = \{x \in \mathbb{R}^n \mid g_i(x) \leq 0 \forall i\}$

so existieren Zahlen  $\lambda_i \geq 0$  ( $i \in I$ ) (die Karun-Tucker Multiplikatoren)

mit

$$(KT) \begin{cases} \nabla f(x^0) + \sum_{i \in I} \lambda_i \nabla g_i(x^0) = 0 \\ \lambda_i g_i(x^0) = 0 \quad \text{für alle } i \end{cases}$$

Beweis:

$x^0$  lokales Minimum  $\Rightarrow f(\varphi(\theta)) \geq f(\varphi(0)) = f(x^0)$

für jede zulässige Kurve  $\varphi$  und kleines  $\theta > 0$

Taylor Entwicklung von  $f(\varphi(\theta))$  in  $\theta=0$  ergibt

$$f(\varphi(\theta)) = f(x^0) + \underbrace{\theta \nabla f^T(x^0)}_{=: y} \underbrace{\frac{d\varphi}{d\theta}(0)}_{\rightarrow 0 \text{ für } \theta \rightarrow 0} + \underbrace{\theta^2 R_2(\theta)}_{\rightarrow 0 \text{ für } \theta \rightarrow 0}$$

zulässige Richtung nach Def, d.h.  $y \in C_{\text{zul}}$

$x^0$  lokales Minimum  $\Rightarrow \nabla f^T(x^0) \cdot y \geq 0$  für alle  $y \in C_{\text{zul}}$

Stetigkeit der Fkt, Grenzübergang  $y^k \rightarrow y$  ergibt

$$\nabla f^T(x^0) \cdot y \geq 0 \quad \text{für alle } y \in \overline{C_{\text{zul}}}$$

Constraint Qualifikation (CQ) ergibt

$$\nabla f^T(x^0) \cdot y \geq 0 \quad \text{für alle } y \in G$$

Also: notwendig dafür, dass  $x^0$  ein lokales Minimum ist ist

$$\nabla f^T(x^0) \cdot y \geq 0 \quad \forall y \text{ mit } -\nabla g_i^T(x^0) \cdot y \geq 0$$

$\Leftrightarrow$  (Farkas Lemma)  $\nabla f(x_0) \in \underbrace{C(-\nabla g_i(x_0), i \in I^0)}_{\text{Kegel von den } -\nabla g_i(x_0) \text{ aufgespannt}}$


$\Leftrightarrow \exists \lambda_i \geq 0, i \in I^0$ , mit  $\nabla f(x_0) = \sum_{i \in I^0} \lambda_i \cdot (-\nabla g_i(x_0))$

$\Leftrightarrow$  (mit  $\lambda_i = 0$  für alle  $i \in I \setminus I^0$ )

$\exists \lambda_i \geq 0, i \in I$  mit  $\nabla f(x_0) = -\sum_{i \in I^0} \lambda_i \nabla g_i(x_0)$

$\Leftrightarrow \exists \lambda_i \geq 0$  mit  $\lambda_i g_i(x_0) = 0 \quad \forall i \in I$

und  $\nabla f(x_0) + \sum_{i \in I} \lambda_i \nabla g_i(x_0) = 0 \quad \square$



Bemerkung: Sind die  $\nabla g_i(x_0)$  linear unabhängig, so sind die  $\lambda_i$  eindeutig bestimmt

Verallgemeinerung auf " $\leq$ " und " $=$ " Restriktionen

(NLO<sup>+</sup>)  $\left\{ \begin{array}{l} \min f(x) \text{ unter} \\ g_i(x) \leq 0 \quad i \in I = \{1, \dots, m\} \\ h_\ell(x) = 0 \quad \ell \in L = \{1, \dots, p\} \\ x \in \mathbb{R}^n \end{array} \right. \quad \begin{array}{l} \text{alle Fkt} \\ \text{stetig diffbar} \end{array}$



Begriffe von NLO übertragen:

$$X = \{ x \mid g_i(x) \leq 0, i \in I, h_\ell(x) = 0 \ell \in L \}$$

zulässige Richtung analog definiert,  $C_{zul}$  ebenso

$$G = \{ y \in \mathbb{R}^n \mid \nabla g_i^T(x^0) \cdot y \leq 0, i \in I^0, \nabla h_\ell^T(x^0) \cdot y = 0 \ell \in L \}$$

$\uparrow$   
 $g_i(x^0) = 0$

$$\text{Constraint Qualifikation (CQ)} \quad \bar{C}_{zul} = G$$

2.4 SATZ (Kuhn & Tucker 1951)

Beladung (NLO<sup>+</sup>):  $x^0$  ist lokal optimal, (CQ) gilt in  $x^0 = 0$

$\exists$  Zahlen  $\lambda_i \geq 0$  ( $i \in I$ ) und  $\mu_\ell$  ( $\ell \in L$ ) nicht von Null verschieden

mit

$$\text{KT} \begin{cases} \nabla f(x^0) + \sum_{i \in I} \lambda_i \nabla g_i(x^0) + \sum_{\ell \in L} \mu_\ell \nabla h_\ell(x^0) = 0 \\ \lambda_i \cdot g_i(x^0) = 0 \quad i \in I \end{cases}$$

Beweis: Aufgabe 3

Bemerkung: (CQ) gilt in  $x^0$ , wenn eine der folgenden Bedingungen erfüllt ist:

(a)  $g_i$  sind konvex,  $h_\ell$  sind linear

$\exists \bar{x} \in X$  mit  $g_i(\bar{x}) < 0 \forall i$  und  $h_\ell(\bar{x}) = 0 \forall \ell$

(b) Die Gradienten  $\nabla g_i(x^0)$  und  $\nabla h_\ell(x^0)$  sind (zusammen)

linear unabhängig

## 2.2 Hinreichende Bedingungen für Optimalität: Sattelpunkte

Betrachte wieder (NLO):  $\min f(x)$   
 $g_i(x) \leq 0 \quad i \in I \quad \leftarrow$  keine Annahmen  
 $x \in S \subseteq \mathbb{R}^n \quad \leftarrow$  neue Bedingung  
 z.B.  $S = \mathbb{Z}^n$

Bringe Nebenbedingung durch Lagrange-Multiplikatoren in die Zielfunktion

$$L(x, \lambda) := f(x) + \sum_{i \in I} \lambda_i g_i(x) \quad \lambda_i \geq 0$$


↑

Lagrange-Funktion

$(\bar{x}, \bar{\lambda})$  mit  $\bar{x} \in S$  und  $\bar{\lambda} \geq 0$  heißt Sattelpunkt von  $L(x, \lambda)$

$$\Leftrightarrow L(\bar{x}, \bar{\lambda}) \leq L(x, \bar{\lambda}) \quad \forall x \in S$$

$$L(\bar{x}, \bar{\lambda}) \geq L(\bar{x}, \lambda) \quad \forall \lambda \geq 0$$



2.5 SATZ: (Charakteristische Eigenschaft von Sattelpunkten)

$(\bar{x}, \bar{\lambda})$  mit  $\bar{x} \in S$  und  $\bar{\lambda} \geq 0$  ist Sattelpunkt von  $L(x, \lambda) \Leftrightarrow$

(a)  $L(\bar{x}, \bar{\lambda}) = \min_{x \in S} L(x, \bar{\lambda})$

(b)  $g_i(\bar{x}) \leq 0 \quad \forall i \in I$

(c)  $\bar{\lambda}_i \cdot g_i(\bar{x}) = 0 \quad \forall i \in I$

Beweis: " $\Rightarrow$ "

(a) ist trivial

zu (b): Def  $\Rightarrow L(\bar{x}, \bar{\lambda}) \geq L(\bar{x}, \lambda) \quad \forall \lambda \geq 0$

$\stackrel{\text{Def } L}{\Leftrightarrow} f(\bar{x}) + \sum_i \bar{\lambda}_i g_i(\bar{x}) \geq f(\bar{x}) + \sum_i \lambda_i g_i(\bar{x}) \quad \forall \lambda \geq 0$

$\Leftrightarrow \sum_{i \in I} (\lambda_i - \bar{\lambda}_i) g_i(\bar{x}) \leq 0 \quad \forall \lambda \geq 0 \quad (*)$

Annahme: (b) gilt nicht für  $i_0$ , d.h.  $g_{i_0}(\bar{x}) > 0$

$\Rightarrow$  mache  $\lambda_{i_0}$  so groß, dass  $\sum_{i \in I} (\lambda_i - \bar{\lambda}_i) g_i(\bar{x}) > 0$

$\Rightarrow$  Widerspruch

zu (c)  $\lambda = 0 \stackrel{(*)}{\Rightarrow} \sum_i -\bar{\lambda}_i g_i(\bar{x}) \leq 0$   
 $\bar{\lambda} \geq 0, g_i(\bar{x}) \leq 0 \Rightarrow \sum_i \bar{\lambda}_i g_i(\bar{x}) \leq 0$   $\left. \begin{array}{l} \phantom{\sum_i \bar{\lambda}_i g_i(\bar{x}) \leq 0} \\ \phantom{\sum_i \bar{\lambda}_i g_i(\bar{x}) \leq 0} \end{array} \right\} \Rightarrow \underbrace{\sum_i \bar{\lambda}_i g_i(\bar{x})}_{\leq 0} = 0$

$\Rightarrow \bar{\lambda}_i g_i(\bar{x}) = 0 \quad \forall i$

" $\Leftarrow$ " (a), (b), (c) gelten

(a)  $\Rightarrow L(\bar{x}, \bar{\lambda}) \leq L(x, \bar{\lambda}) \quad \forall x \in S$

(c)  $\Rightarrow L(\bar{x}, \bar{\lambda}) = f(\bar{x})$

$L(\bar{x}, \lambda) \stackrel{\text{Def}}{=} f(\bar{x}) + \sum_i \lambda_i g_i(\bar{x}) \leq f(\bar{x}) = L(\bar{x}, \bar{\lambda}) \quad \forall \lambda \geq 0$   
 $\lambda_i \geq 0, g_i(\bar{x}) \leq 0$  nach (b)

$\Rightarrow L(\bar{x}, \lambda) \leq L(\bar{x}, \bar{\lambda}) \leq L(x, \bar{\lambda}) \quad \forall x \in S, \lambda \geq 0 \quad \square$

2.6 SATZ. Ist  $(\bar{x}, \bar{\lambda})$  ein Sattelpunkt von  $L(x, \lambda)$   
 so ist  $\bar{x}$  ein globales Optimum von (NLP)

Beweis: Nutze Satz 2.5. (a) = 0

$$f(\bar{x}) + \sum_i \bar{\lambda}_i g_i(\bar{x}) \leq f(x) + \sum_i \bar{\lambda}_i g_i(x) \quad \forall x \in S$$

$= 0 \text{ nach (c)}$

$$\Rightarrow f(\bar{x}) \leq f(x) + \sum_i \bar{\lambda}_i g_i(x) \quad \forall x \in S$$


$\begin{matrix} \geq 0 & \leq 0 \end{matrix}$

$$\Rightarrow f(\bar{x}) \leq f(x) \quad \forall x \in S \quad \square$$

Beachte: Dieses Satz gilt ohne Voraussetzungen an  $f$  und die  $g_i$   
also auch für  $g \geq 0$  Optimierung

ABER: Es kann Minima ohne Sattelpunkt geben.

Bsp: min  $f(x) = -x^2$  unter  $2x-1 \leq 0, 0 \leq x \leq 1$



Wähle  $S = [0, 1]$

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

↑  
Konkav in  $x$  für festes  $\lambda$

$\Rightarrow$  min  $L(x, \lambda)$  wird bei

$x = 0$  oder  $x = 1$  angenommen

also:  $x^0 = 1/2$  ist Minimum von  $f(x)$

kein  $\bar{\lambda}$  liefert Minimum von  $L(x, \bar{\lambda})$  bei  $1/2$

$\Rightarrow L(x, \lambda)$  hat keinen Sattelpunkt

2.3 Notwendige und hinreichende Bedingungen für die Existenz von Sattelpunkten: Stör-Funktionen

Idee: (NLP) einbetten in eine Familie von Problemen mit gestörten rechten Seite

$$(NLP_y): \quad \begin{array}{l} \min f(x) \\ \text{unter } g_i(x) \leq y_i \quad (i \in I) \\ x \in S \end{array} \left. \vphantom{\begin{array}{l} \min f(x) \\ \text{unter } g_i(x) \leq y_i \quad (i \in I) \\ x \in S \end{array}} \right\} X(y)$$

$$\Phi(y) := \min_{x \in X(y)} f(x)$$

"Störfunktion"

$$\Rightarrow \Phi(0) = \min_{x \in X} f(x)$$

Störfunktion  $\Phi$  ist aufsteigend, d.h.  $y' \leq y \Rightarrow \Phi(y') \geq \Phi(y)$

(klar, da  $X(y') \subseteq X(y)$ )

2.7 SATZ: (NLP) habe ein globales Minimum  $\bar{x}$  mit endlichem Wert  $f(\bar{x})$ . Dann gilt:

$(\bar{x}, \bar{\lambda})$  ist Sattelpunkt


$\Leftrightarrow$  die Hyperalebene  $z = \Phi(0) - \bar{\lambda}^T y$  ist Stützhyperebene des Graphen der Störfunktion  $\Phi$  zu  $y=0$

$\Leftrightarrow \forall y \in \mathbb{R}^k$  gilt  $\Phi(y) \geq \Phi(0) - \bar{\lambda}^T y$

Beispiel:  $\min x_1^2 + x_2^2$   
unter  $2x_1 + x_2 \leq -4$


Minimum  
in  $\bar{x} = \begin{pmatrix} -8/5 \\ -4/5 \end{pmatrix}$

Optimalwert ist  $16/5$



Gegebenes Problem (Störfunktion) ist eindimensional

$$\Phi(y) = \min x_1^2 + x_2^2 \quad \text{unter } 2x_1 + x_2 + 4 \leq y$$



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

$\bar{\lambda} = -8/5$  definiert Sattelpunkt  $(\bar{x}, \bar{\lambda})$

$$\text{und } \Phi(y) \geq \Phi(0) - \bar{\lambda}y = 16/5 - 8/5y =$$

Beweis: " $\Rightarrow$ "  $g(x) := \begin{pmatrix} g_1(x) \\ \vdots \\ g_m(x) \end{pmatrix}$

Sei  $(\bar{x}, \bar{\lambda})$  ein Sattelpunkt  $\Rightarrow \bar{\lambda} \geq 0$

$$f(x) + \bar{\lambda}^T g(x) \geq f(\bar{x}) + \bar{\lambda}^T g(\bar{x}) \quad \forall x \in S$$

$$\bar{\lambda} \cdot g(\bar{x}) = 0, \quad g(\bar{x}) \leq 0$$

$$\Rightarrow f(x) + \bar{\lambda}^T g(x) \geq f(\bar{x}) = \Phi(0) \quad (\text{da } \bar{x} \text{ min von } f)$$

$$\Rightarrow f(x) \geq \underbrace{\Phi(0) - \bar{\lambda}^T g(x)}_{\geq \Phi(0) - \bar{\lambda}^T y} \quad \forall x \in S$$

$\geq \Phi(0) - \bar{\lambda}^T y$  für jedes  $y$ , für das  $(NLO_y)$  eine Lösung hat

und für jedes  $x \in X(y)$

(da  $g_i(x) \leq y_i$  nach Def von  $\Phi$  und  $\bar{\lambda} \geq 0$ )

$$\Rightarrow \Phi(y) = \min_{x \in X(y)} f(x) \geq \Phi(0) - \bar{\lambda}^T y$$

Falls  $(NLO_y)$  keine Lösung hat, so ist  $\Phi(y) = \infty$  und

$$\Phi(y) \geq \Phi(0) - \bar{\lambda}^T y \text{ automatisch erfüllt}$$

$$\Leftarrow \text{ Sei } \Phi(y) \geq \Phi(0) - \bar{\lambda}^T y \quad \forall y \in \mathbb{R}^m \quad (*)$$

$$(a) \quad \underline{\bar{\lambda} \geq 0}$$

Falls  $\bar{\lambda}_i < 0$  so lasse  $y_i \rightarrow \infty$  gehen und  $y_j = 0$  sonst

$$\Rightarrow \Phi(0) - \bar{\lambda}^T y \rightarrow \infty \stackrel{(*)}{=} \Phi(y) \rightarrow \infty$$

$$\Rightarrow \text{Widerspruch zu } \Phi(y) \leq \Phi(0) \quad \forall y \geq 0 \quad (\text{Antitonic})$$

$$(b) \quad L(\bar{x}, \bar{\lambda}) = \min_{x \in S} L(x, \bar{\lambda})$$

$$y = g(x) \Rightarrow f(x) \geq \Phi(y) = \Phi(g(x)) \quad \forall x \in X(g(x)) = S$$

$\uparrow$   
 $g(x) \in g(x) \text{ auf } \mathbb{R}^n$

$$\Rightarrow f(x) \geq \Phi(g(x)) \stackrel{(*)}{\geq} \Phi(0) - \bar{\lambda}^T g(x) \quad \forall x \in S \quad (**)$$

Für  $x = \bar{x}$  erhält man

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

$$\bar{\lambda} \geq 0, \quad g(\bar{x}) \leq 0 \quad \Rightarrow \quad \bar{\lambda}^T g(\bar{x}) = 0$$

Nun gilt

$$\underbrace{f(x) + \bar{\lambda}^T g(x)}_{L(x, \bar{\lambda})} \stackrel{(**)}{\geq} f(\bar{x}) = \underbrace{f(\bar{x}) + \bar{\lambda}^T g(\bar{x})}_{L(\bar{x}, \bar{\lambda})} \quad \forall x \in S$$

$$\Rightarrow L(\bar{x}, \bar{\lambda}) = \min_{x \in S} L(x, \bar{\lambda})$$


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

folgt aus (b),  $\bar{\lambda}^T g(\bar{x}) = 0$  und Satz 2.5  $\square$


Satz 2.7 kann auf Gleichheitsbedingungen  $h_2(x) = 0$   
verallgemeinert werden (zufällige  $\mu_2$  sind dann nicht vorzeichen beschränkt)

Oft ist (NLO) nicht konvex und  $\Phi$  nicht konvex


und  $\nexists$  Stützhyperebene in  $\gamma=0 \Rightarrow$  kein Sattelpunkt




$\Phi$  kann nicht konvex sein, aber dennoch existiert eine  
Stützhyperebene in  $\gamma=0$  ( $=$  Sattelpunkt  $=$  Minimum)



$\Phi$  nicht diff'bar, nicht konvex, aber  $\exists$  Sattelpunkt



$\Phi$  konvex  $\Rightarrow \exists$  Stützhyperebene  $\Rightarrow \exists$  Sattelpunkt





## 2.4 Sattelpunkte bei konvexen Optimierungsproblemen

2.8 SATZ  $f, g_i$  seien konvex,  $S$  sei konvex

und es gelte  $x \in S$  mit  $g_i(x) < 0 \forall i$ .


Hat dann (NLO) eine minimale Lösung  $\bar{x}$ , so existiert ein  $\bar{\lambda} \geq 0$ , so dass  $(\bar{x}, \bar{\lambda})$  ein Sattelpunkt ist.

Also: Minima konvexer von Sattelpunkte.

Beweis.

(1)  $\Phi(y)$  ist konvex (2)  $\text{dom}(\Phi) := \{y \mid \Phi(y) < \infty\} \neq \emptyset$

(3)  $0 \in \text{interior}(\text{dom}(\Phi))$



(1) - (3)  $\Rightarrow 0$   $\Phi(y)$  hat einen Subgradienten  $\gamma$  in  $y=0$

$$\Rightarrow \Phi(y) \geq \Phi(0) + \gamma^T y \quad \forall y \in \mathbb{R}^m$$

[vgl. Def Subgradient aus ADM II für konvexe Fkt  
 Subgradient in  $u$  = Vektor  $\gamma$  mit  $f(v) - f(u) \leq \gamma^T (v - u) \forall v$   
 $\Rightarrow f(v) - f(u) \geq \gamma^T (v - u) \forall v$  für konvexe Fkt]

$\bar{\lambda} := -\gamma$  erfüllt dann die Bedingung für Sattelpunkt in Satz 2.7

$$\text{denn } \Phi(y) \geq \Phi(0) - \bar{\lambda}^T y \quad \forall y \geq 0$$

in (1) - (3): Aufgabe 4

2.9 FOLGERUNG Im konvexen Falle gilt:

$(\bar{x}, \bar{\lambda})$  ist Sattelpunkt  $\Leftrightarrow -\bar{\lambda}$  ist Subgradient der Störfunktion  $\Phi$  in  $y=0$

Eine entsprechende Aussage gilt für Gleichheitsbedingungen  $h_2(x) = 0$

2.5 Karu-Tucker Bedingungen für den konvexen differenzierbaren Fall

In diesem Fall erweisen sich die KT-Bedingungen als notwendig und hinreichend

2.10 SATZ Betrachte mit  $f(x)$   
 $u(x) = \{ g_i(x) \leq 0 \quad i \in I \}$ ,  
 $f, g_i$  konvex diffbar } NLP  
 mit  $\exists x \in \mathbb{R}^n$  mit  $g_i(x) < 0 \quad \forall i$

Dann gilt

$\bar{x}$  ist globales Minimum von NLP

$\Leftrightarrow$  die Karu-Tucker Bedingungen gelten in  $\bar{x}$ ,

d.h.  $\exists \bar{\lambda} \geq 0$  mit  $\nabla_x L(\bar{x}, \bar{\lambda}) = 0$

$\bar{\lambda}_i g_i(\bar{x}) = 0 \quad \forall i$

Beweis: Satz 2.7 sagt:  $\bar{x}$  globales Minimum  $\Leftrightarrow \exists \bar{\lambda} \geq 0$  und  $(\bar{x}, \bar{\lambda})$  ist Sattelpunkt

$\Leftrightarrow$  (a)  $\bar{x}$  minimiert  $L(x, \bar{\lambda})$  auf  $S$

(b)  $g_i(\bar{x}) \leq 0 \quad \forall i$

(c)  $\bar{\lambda}_i g_i(\bar{x}) = 0 \quad \forall i$

$f, g_i$  konvex, diffbar  $\Rightarrow L(x, \bar{\lambda})$  konvex, diffbar in  $x$


$\Rightarrow$  (a) ist äquivalent zu  $\nabla_x L(\bar{x}, \bar{\lambda}) = 0$

$$= \nabla f(\bar{x}) + \sum_i \bar{\lambda}_i \nabla g_i^T(\bar{x}) \quad (*)$$

(\*) und (c) entsprechen den KT-Bedingungen  $\square$


Berücksichtigung von Nichtnegativitätsbedingungen  $x_j \geq 0$

Betrachte 1-dim Fall mit  $f(x)$   $x \geq 0$



$$\frac{df}{dx}(x^*) = 0$$

sowie  $x^* \geq 0$



$$\frac{df}{dx}(x^*) \geq 0 \quad \text{und} \quad x^* = 0$$

zusammengefasste notwendige Bedingungen:

$$x^* \cdot \frac{df}{dx}(x^*) = 0 \quad \frac{df}{dx}(x^*) \geq 0 \quad x^* \geq 0$$

Entsprechend im mehrdimensionalen Fall  $f: \mathbb{R}^n \rightarrow \mathbb{R}^1$

mit  $f(x)$  unter  $x_j \geq 0$

wird entweder für  $x^* > 0$  angenommen  $\Rightarrow \nabla f(x^*) = 0$

oder an Rand mit  $x_j^* = 0$  für ein oder mehrere  $j$

$= 0$   notwendige Bedingungen sind (\*)

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

exakte Herleitung von (\*) aus den Karu-Tucker Bedingungen

mit  $g_j(x) = -x_j \leq 0$

$$(KT): \begin{cases} \nabla f(x^*) + \sum_j \lambda_j \nabla g_j(x^*) = 0 & (1) \\ \lambda_j \cdot g_j(x_j) = 0 \quad \forall j & (2) \\ \lambda_j \geq 0 \end{cases}$$

$$(1) \Rightarrow \frac{\partial f}{\partial x_j}(x^*) + \lambda_j(-1) = 0 \quad \forall j \Rightarrow \lambda_j = \frac{\partial f}{\partial x_j}(x^*)$$

$$(1), (2) \Rightarrow x_j^* \cdot \frac{\partial f}{\partial x_j}(x^*) = 0 \quad \forall j$$

$$\lambda_j \geq 0 \Rightarrow \frac{\partial f}{\partial x_j}(x^*) \geq 0 \quad \forall j$$

Kuhn-Tucker anwendbar, da konvexe Nebenbedingungen mit innerem Punkt  $\Rightarrow$  (CQ) gilt nach Lemma 2.2 □

### Berücksichtigung von linearen Gleichheitsbedingungen und Nichtnegativität

$$\min f(x) \quad \text{unter} \quad h_i(x) = -\sum_j h_{ij} x_j + b_i = 0$$

$$g_j(x) = -x_j \leq 0$$

(CQ) erfüllt, da Gleichheitsbed. linear und die  $\geq$  Bedingungen konvex mit innerem Punkt

$\Rightarrow$  die Techniken aus Beweis von Lemma 2.2 können übertragen werden

$\Rightarrow$  (KT) Bedingungen sind notwendig:

$$(KT): \left\{ \begin{array}{l} \exists \text{ Zahlen } \lambda_j \geq 0, \mu_i \text{ bel. mit} \\ \nabla f(x^*) + \sum_j \lambda_j \nabla g_j(x^*) + \sum_i \mu_i \nabla h_i(x^*) = 0 \quad (1) \\ \lambda_j \cdot g_j(x^*) = 0 \quad \forall j \quad (2) \end{array} \right.$$

$$(1) \Rightarrow \frac{\partial f}{\partial x_j}(x^*) - \lambda_j + \sum_i \mu_i (-h_{ij}) = 0 \quad \forall j=1, \dots, n$$

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

$\lambda_j$  in (2) eingesetzt ergibt

$$x_j \left( \frac{\partial f}{\partial x_j}(x^*) - \sum_i \mu_i h_{ij} \right) = 0 \quad (2.1)$$

$\lambda_j \geq 0$  ergibt

$$\frac{\partial f}{\partial x_j}(x^*) - \sum_i \mu_i h_{ij} \geq 0 \quad (2.2)$$

plus die Nebenbedingungen

$$\sum_i h_{ij} x_j^* = b_i \quad (2.3)$$

$$x_j^* \geq 0 \quad (2.4)$$

Also: notwendige Bedingungen für Optimalität von  $x^*$  ist die Existenz von Zahlen  $\mu_i$ ,  $i=1, \dots, m$  mit (2.1) - (2.4)

Bemerkung: in all diesen Fällen lässt sich über Sattelpunkte analog zu Satz 2.8 und (2.10) auch die Umkehrung zeigen (ohne Beweis)

## 2.6 Anwendung auf das Systemoptimum der Verkehrsplanung

$$\min C(x(f)) = \sum_{a \in A} x_a \cdot \tau_a(x_a) \quad \text{mit} \quad x_a = \sum_{P \ni a} f_P$$

$$\text{unter} \quad \sum_{P \in \mathcal{P}_k} f_P = d_k \quad k \in C$$

$$f_P \geq 0$$

(hier zur besseren Unterscheidung:  $f$  = Wegfluss

$x(f) = x$  = zugehöriger  
Kantenfluss

Kuhn-Tucker Bedingungen:

$$f_P \cdot \left( \frac{\partial C}{\partial f_P}(x(f)) - \mu_k \cdot 1 \right) = 0 \quad \forall k \in C, P \in \mathcal{P}_k \quad (1)$$

$$\frac{\partial C}{\partial f_P}(x(f)) - \mu_k \geq 0 \quad \forall k \in C, P \in \mathcal{P}_k \quad (2)$$

$$\sum_{P \in \mathcal{P}_k} f_P = d_k \quad \forall k \quad (3)$$

$$f_P \geq 0 \quad \forall k, P \in \mathcal{P}_k \quad (4)$$

Betrachte zunächst  $\frac{\partial C}{\partial f_P}(x(f))$

$$= \frac{\partial}{\partial f_P} \sum_{a \in A} x_a(f) \cdot \tau_a(x_a(f))$$

$$\underbrace{\quad \quad \quad}_{=: c_a(x_a(f))}$$

$$= \sum_{a \in A} \frac{\partial c_a(x_a)}{\partial x_a} \frac{\partial x_a}{\partial f_P}(f) \quad \text{Kettenregel}$$

$$= \sum_{a \in A} \frac{\partial c_a(x_a)}{\partial x_a} \cdot \delta_{a,P} \quad \text{mit} \quad \delta_{a,P} = \begin{cases} 1 & a \in P \\ 0 & \text{sonst} \end{cases}$$

$$\text{da} \quad x_a = \sum_{P \ni a} f_P$$

$$= \sum_{P \ni a} \frac{\partial C_a}{\partial x_a}(x_a) = \sum_{P \ni a} \left( x_a \cdot \frac{d}{dx_a} \tau_a(x_a) + \tau_a(x_a) \right)$$

$$= c'(x_a) \text{ aus § 1}$$

"modifiziert Faktorifkt",

"marginale Kosten"

$$=0 \quad (1) \text{ wird zu } f_P \cdot \left( \sum_{a \in P} c'(x_a) - \mu_k \right) = 0 \quad \forall k, P \in \mathcal{P}_k$$

$$(2) \text{ wird zu } \sum_{a \in P} c'(x_a) \geq \mu_k \quad \forall k, P \in \mathcal{P}_k$$

(1), (2) bedeuten

(1): Fluss führende Wege <sup>zu k</sup> haben dieselbe Länge  $\mu_k$  bzgl.

$c'(x_a)$

(2) jedes Weg <sup>zu k</sup> hat mindestens die Länge  $\mu_k$  bzgl.  $c'(x_a)$   
als Faktorifkt

$$=0 \quad SO = UE \text{ bzgl. } c'(x_a)$$