

# 10 Optimalitätsbedingungen, Box-Beschränkungen

Nichtlineare Optimierung  
WS 2020/21

# Quizfrage

Wir betrachten die Optimierungsaufgabe

$$\begin{aligned} &\text{Minimiere} && x_1 + x_2, && x \in \mathbb{R}^2 \\ &\text{unter} && x_2^2 - x_1 \leq 0 \\ &\text{und} && x_1 \leq 10 \end{aligned}$$

Wie nennt man die Menge

$$X := \{x \in \mathbb{R}^2 \mid x_2^2 - x_1 \leq 0, x_1 \leq 10\} ?$$

A zufällige Menge

C aktive Menge

B Lösungsmenge

D zulässige Menge

# Quizfrage

Im welchem der folgenden Punkte ist die Nebenbedingung  $x_2^2 - x_1 \leq 0$  **aktiv**?

$$g(x) = 0$$

1  A  $x = (2, 1)^T$

0  C  $x = (1, 2)^T$

*inaktiv*  
↓

$$A: g(x) = 1^2 - 2 < 0$$

$$C: g(x) = 2^2 - 1 > 0$$

↑  
*aktiv*

2  B  $x = (4, 2)^T$

4  D  $x = (0, 0)^T$

$$B: g(x) = 2^2 - 4 = 0$$

$$D: g(x) = 0^2 - 0 = 0$$

# Quizfrage

Im welchem der folgenden Punkte ist die Nebenbedingung  $x_2^2 - x_1 \leq 0$  **inaktiv**?

**A**  $x = (2, 1)^T$

**B**  $x = (4, 2)^T$

**C**  $x = (1, 2)^T$

**D**  $x = (0, 0)^T$

# Quizfrage

Im welchem der folgenden Punkte ist die Nebenbedingung  $x_2^2 - x_1 \leq 0$  verletzt?

A  $x = (2, 1)^T$

C  $x = (1, 2)^T$

B  $x = (4, 2)^T$

D  $x = (0, 0)^T$

# Quizfrage

oft schwer handhabbar

6

Wozu braucht man den **Tangentenkegel** (an die zulässige Menge  $X$  im Punkt  $x$ )

$$\mathcal{T}_X(x) = \left\{ d \in \mathbb{R}^n \mid \text{es gibt } \{x_k\} \subset X, \underbrace{t_k \searrow 0}_{\text{pos. Nullfolge}}, \frac{x_k - x}{t_k} \rightarrow d \right\}$$

in der Optimierung?

*Handwritten notes:*  
Folge von  $x$  nach  $x_k$   
Richtung  
notwendigerweise:  $x_k \rightarrow x$

4 **A** Für lokale Minimierer  $x^*$  gilt:  $\nabla f(x^*)^T d \geq 0$  für alle  $d \in \mathcal{T}_X(x^*)$ .

1 **C** Für lokale Minimierer  $x^*$  gilt:  $\nabla f(x^*)^T d \leq 0$  für alle  $d \in \mathcal{T}_X(x^*)$ .

**B** Der Tangentenkegel beschreibt die Menge  $X$  lokal.

1 **D** Der Tangentenkegel enthält die lokalen Minimierer.

# Illustration des Tangentialkegels


an einer zulässigen Menge  $X$



im Punkt  $x$



$$T_x(x) = \mathbb{R}^2$$



$$T_x(x) = \text{Halbraum} \\ (\text{abgeschlossen}) \text{ in } \mathbb{R}^2$$



$$T_x(x) = \text{Sektor} \\ \text{in } \mathbb{R}^2$$

tangentiale Richtungen  $d$ :

$$(x_k) \subset X, t_k > 0, d = \lim_{k \rightarrow \infty} \frac{x_k - x}{t_k}$$

# Quizfrage

leicht handhabbar, berechenbar

Wozu braucht man den **Linearisierungskegel** (an die zulässige Menge  $X$  im Punkt  $x$ )

$$\mathcal{T}_X^{\text{lin}}(x) = \left\{ d \in \mathbb{R}^n \left| \begin{array}{l} \nabla g_i(x)^T d \leq 0 \text{ für alle } i \in \mathcal{A}(x), \\ \nabla h_j(x)^T d = 0 \text{ für alle } j = 1, \dots, p \end{array} \right. \right\}$$

in der Optimierung?

- A Für lokale Minimierer  $x^*$  gilt:  $\nabla f(x^*)^T d \geq 0$  für alle  $d \in \mathcal{T}_X^{\text{lin}}(x^*)$ . *Das sind ist zu viele Richtungen!*
- B Der Linearisierungskegel beschreibt die Menge  $X$  lokal. *Das hätte man gerne!*
- C Für lokale Minimierer  $x^*$  gilt:  $\nabla f(x^*)^T d \leq 0$  für alle  $d \in \mathcal{T}_X^{\text{lin}}(x^*)$ .
- D Der Linearisierungskegel enthält die lokalen Minimierer.

# Illustration des Linearisierungskegels

hängt von der Beschreibung der Menge  $X$  ab

$$X = \{0\} \subset \mathbb{R} \Rightarrow J_X(0) = \{0\}$$

$$h(x) = x$$

$$\nabla h(x) = 1$$

$$\nabla h(0) = 1$$

$$h(x) = x^2$$

$$\nabla h(x) = 2x$$

$$\nabla h(0) = 0$$

$$g(x) = x^2$$

$$\nabla g(x) = 2x$$

$$\nabla g(0) = 0$$

$$J_X^{\text{lin}}(0) = \{d \in \mathbb{R} :$$

$$1 \cdot d = 0\} = \{0\}$$

$$= J_X(0)$$

$$J_X^{\text{lin}}(0)^{\circ} = J_X(0)^{\circ} = \mathbb{R}$$

$$J_X^{\text{lin}}(0) = \{d \in \mathbb{R} :$$

$$0 \cdot d = 0\} = \mathbb{R}$$

$$\neq J_X(0)$$

$$J_X^{\text{lin}}(0)^{\circ} = \{0\}$$

$$J_X(0)^{\circ} = \mathbb{R}$$

$$J_X^{\text{lin}}(x) = \{d \in \mathbb{R} :$$

$$0 \cdot d = 0\} = \mathbb{R}$$

$$\neq J_X(0)$$

$\longleftrightarrow$  dito

# Notwendige Optimalitätsbedingung

Es sei  $x^*$  ein lokales Minimum von  
Minimiere  $f(x)$  unter  $g(x) = 0, h(x) = 0$ .

Dann gilt:  $\nabla f(x^*)^T d \geq 0$  für alle  $d \in J_x(x^*)$ .

$\Leftrightarrow$   $-\nabla f(x^*) \in J_x(x^*)^\circ$  „duale Beschreibung“

Da  $J_x(x^*)$  und damit auch  $J_x(x^*)^\circ$  i.A. schwer  
handhabbar sind, würde man lieber  $J_x^{lin}(x^*)$  bzw.  
 $J_x^{lin}(x^*)^\circ$  verwenden.

Aber:  $J_x(x^*) \subseteq J_x^{lin}(x^*) \Rightarrow J_x^{lin}(x^*)^\circ \subseteq J_x(x^*)^\circ$

Es ist daher i.H. (nicht zu  
erwarten, dass  $-\nabla f(x^*)$  auch  
in  $J_x^{lin}(x^*)^\circ$  liegt!

Gleichheit gilt  
unter einer  
constraint quali-  
fication bei  $x^*$

# Quizfrage

Wozu braucht man die Lagrange-Funktion

$$\mathcal{L}(x, \mu, \lambda) = f(x) + \overbrace{\mu^T g(x)} + \underbrace{\lambda^T h(x)} ?$$

A zur Darstellung von  $\mathcal{T}_X(x)^\circ$

C zur Darstellung von  $\mathcal{T}_X^{\text{lin}}(x)^\circ$

Beweis mit Farkas-Lemma

$$\mathcal{T}_X^{\text{lin}}(x)^\circ = \left\{ \begin{array}{l} \text{LK des } \nabla h_j(x) \text{ und nicht-neg. LK des } \nabla g_i(x), \\ \text{aber nur der ableitbar} \end{array} \right.$$
$$= \left\{ \underbrace{\sum_{j=1}^p \lambda_j \nabla h_j(x)} + \sum_{i=1}^m \underbrace{\mu_i \nabla g_i(x)} \right\}, \quad \begin{array}{l} \mu_i \geq 0 \text{ für } i \in A(x) \\ \text{und } \mu_i = 0 \text{ für } i \in I(x) \end{array}$$

B Man minimiert sie an Stelle der Zielfunktion.

D zur Darstellung der KKT-Bedingungen

# Zusammenfassung Optimalitätsbed.

In einem lokalen Minimum  $x^*$  gilt:

$$-\nabla f(x^*) \in J_x(x^*)^{\circ} = \overline{J_x^{\text{lin}}(x^*)^{\circ}}$$

↑ unter Annahme einer CQ

( $\Rightarrow$ ) die KKT-Bedingungen sind erfüllt

Algorithmen versuchen dies zu erfüllen!

↓

KKT-Bedingungen  $\left\{ \begin{array}{l} -\nabla f(x^*) \in \overline{J_x^{\text{lin}}(x^*)^{\circ}} \\ \nabla_x L(x^*, \lambda, \mu) = \nabla f(x^*) + g'(x^*)^T \mu + h'(x^*)^T \lambda = 0 \\ \mu \geq 0, \quad g(x^*) \leq 0, \quad \mu^T g(x^*) = 0 \\ h(x^*) = 0 \end{array} \right\}$

↳ Lagrange-Multiplikatoren

↳ Komplementarität

# Quizfrage

Warum sind Aufgaben mit **Ungleichungsnebenbedingungen** algorithmisch schwieriger als Aufgaben mit ausschließlich Gleichungsnebenbedingungen?

A Die Aussage stimmt nicht, denn Gleichungen  $h(x) = 0$  entsprechen ja sogar zwei Ungleichungen  $h(x) \leq 0$  und  $-h(x) \leq 0$ .

C Aufgaben mit Ungleichungen haben nicht unbedingt eine Lösung.

B Der Tangentialkegel bei Aufgaben mit Ungleichungsnebenbedingungen ist komplizierter.

D Man weiß vorher nicht, welche Ungleichungen in der Lösung aktiv sein werden.

$$\text{LICQ} \Rightarrow \text{MFCQ} \Rightarrow \text{ACQ} \Rightarrow \text{GCQ}$$

# Quizfrage

Welche Constraint Qualifications sind für Aufgaben mit ausschließlich Box-Beschränkungen in jedem zulässigen Punkt erfüllt?

Minimiere  $f(x)$

unter  $\underbrace{l}_{\in \mathbb{R}^n} \leq x \leq \underbrace{u}_{\in \mathbb{R}^n}$

A GCQ

B ACQ

C MFCQ, wenn  $l < u$  gilt

D LICQ, wenn  $l < u$  gilt

MFCQ: es ex.  $d \in \mathbb{R}^n$  mit  $\nabla g_i(x)^T d < 0$  für alle  $i \in A(x)$ .

$g(x) = \begin{pmatrix} l - x \\ x - u \end{pmatrix} \Rightarrow \nabla g_i(x)^T d = \pm d_i$  Est möglich, wenn  $l < u$ .

# Quizfrage

Was versteht man unter einem projizierten Gradientenverfahren?

- A Man verwendet als Suchrichtung  $d$  eine Abänderung des Gradienten, sodass  $x + \alpha d$  für alle  $\alpha \geq 0$  zulässig bleibt.
- B Man verwendet den üblichen Gradienten als Suchrichtung  $d$  und projiziert  $x + \alpha d$  innerhalb der Liniensuche auf  $[\ell, u]$ .
- C Das ist ein normales Gradientenverfahren, wobei man Verletzungen von  $\ell \leq x \leq u$  bestraft.
- D Das ist ein normales Gradientenverfahren, wobei man abwechselnd auf die Mengen  $\{x \in \mathbb{R}^n : \ell \leq x\}$  und  $\{x \in \mathbb{R}^n : x \leq u\}$  projiziert.

# Zeit für Ihre Fragen

Was sind Ihre Fragen zu den Themen der Woche?

→ Benutzen Sie den **Chat**.

# Fragen und Antworten 1

# Fragen und Antworten 2