

# Optimierung

---

## Vorlesung 5 Optimierung mit Nebenbedingungen

Gegeben: Funktion  $f, h_1, h_2, \dots, h_m: \mathbb{R}^n \rightarrow \mathbb{R}$

Ziel:

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

$$\text{wobei } h_1(x) = 0, h_2(x) = 0, \dots, h_m(x) = 0$$

**Unrestringierter Fall:** Notwendige Bedingung für lokales Minimum  $x^*$

- keine Abstiegsrichtung bei  $x^*$ :  $\nabla f(x^*) = 0$

**Restringierter Fall:** Notwendige Bedingung für lokales Minimum  $x^*$

- $x^*$  ist zulässig:  $\forall i: h_i(x^*) = 0$
- keine zulässige Abstiegsrichtung  $s$  bei  $x^*$

**Restringierter Fall:** Notwendige Bedingung für lokales Minimum  $x^*$

- $x^*$  ist **zulässig**:  $\forall i: h_i(x^*) = 0$
- keine **zulässige** Abstiegsrichtung  $s$

Zulässiger inkrementeller Schritt  $\delta$ .

$$\underline{h_i(x^* + \delta)} = \underline{h_i(x^*)} = 0$$

Taylor-Entwicklung bei  $x^*$ :

$$0 = h_i(x^* + \delta) = \underbrace{h_i(x^*)}_{=0} + \underbrace{\delta^T \nabla h_i(x^*)}_{(=0)} + \cancel{o(\|\delta\|)}$$

Zulässige Richtungen  $s$  sind orthogonal zu  $\nabla h_i(x^*)$ :  $\underline{s^T \nabla h_i(x^*)} = 0$


**Zulässige Abstiegsrichtung  $s$ :**

$$\underline{\forall i: s^T \nabla h_i(x^*) = 0}, \quad \underline{s^T \nabla f(x^*) < 0}$$




**Zulässige Abstiegsrichtung  $s$ :**

$$\forall i: \underline{s^\top \nabla h_i(x^*) = 0}, \quad \underline{s^\top \nabla f(x^*) < 0}$$



Keine zulässige Abstiegsrichtung  $s$ :

$$\forall s: \text{ Falls } \forall i: \underline{s^\top \nabla h_i(x^*) = 0}, \quad \text{dann } \underline{s^\top \nabla f(x^*) = 0}$$



Keine zulässige Abstiegsrichtung  $s$ :

$$\underline{\forall s:} \quad \text{Falls } \forall i: \underline{s^T \nabla h_i(x^*) = 0}, \quad \text{dann } \underline{s^T \nabla f(x^*) = 0} \quad (**)$$

**Satz (Lagrange Multiplikatoren):** Unter Annahme von Regularität, gibt es bei  $x^*$  keine zulässige Abstiegsrichtung genau dann, wenn  $\underline{\lambda_i^*}$  existieren, so dass

$$\rightarrow \underline{\nabla f(x^*)} + \sum_{i=1}^m \underline{\lambda_i^*} \cdot \nabla h_i(x^*) = 0. \quad \leftarrow (**)$$

Beweis:  $-s^T \nabla f(x^*) = \sum \lambda_i^* \underbrace{s^T \nabla h_i(x^*)}_{=0} \implies s^T \nabla f(x^*) = 0$

Annahme: keine zul. Abs.-richtung und keine  $\lambda_i^*$ , so dass  $(**)$  gilt

$$-\nabla f(x^*) = \sum_{i=1}^m \lambda_i \nabla h_i(x^*) + \mu$$

$s = \mu \quad \Rightarrow \text{zulässig}$

$\mu^T \nabla h_i(x^*) = 0 \quad (\forall i)$   
 $\mu \neq 0$

$$-s^T \nabla f(x^*) = + \underbrace{s^T s}_{>0} \implies \underline{s^T \nabla f(x^*) < 0}$$

**Satz (Lagrange Multiplikatoren):** Unter Annahme von Regularität, gibt es bei  $x^*$  keine zulässige Abstiegsrichtung genau dann, wenn  $\lambda_i^*$  existieren, so dass

$$\nabla f(x^*) + \sum_{i=1}^m \lambda_i^* \cdot \nabla h_i(x^*) = 0. \quad \text{und } h_i(x^*) = 0 \quad \forall i$$

**Regularität:** Insbesondere müssen  $\nabla h_i(x^*)$  linear unabhängig sein

### Methode von Lagrange:

Finde Vektoren  $x^*$  und  $\lambda^*$ , für welche

$$\nabla f(x^*) + \sum_{i=1}^m \lambda_i^* \cdot \nabla h_i(x^*) = \mathbf{0}$$

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

- $n + m$  Unbekannte,  $n + m$  Gleichungen

$$\text{Lagrange: } \nabla f(x^*) + \sum_i \lambda_i^* \cdot \nabla h_i(x^*) = 0, \quad \underline{h_i(x^*) = 0} \quad (i = 1, \dots, m)$$

**Beispiel:**

$$\min f(x) = x_1 + x_2$$

$$\text{unter } \underline{h(x) = x_1^2 - x_2 = 0}$$

$$\nabla f(x) = \begin{pmatrix} 1 \\ 1 \end{pmatrix}, \quad \nabla h(x) = \begin{pmatrix} 2x_1 \\ -1 \end{pmatrix}$$

$$\begin{pmatrix} 1 \\ 1 \end{pmatrix} + \lambda \begin{pmatrix} 2x_1 \\ -1 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$$

$$1 + 2x_1 = 0$$

$$\frac{1}{4} - x_2 = 0$$

$$\begin{aligned} \implies \lambda^* &= 1 \\ \implies x_1^* &= -\frac{1}{2} \\ \implies x_2^* &= \frac{1}{4} \end{aligned}$$

Lagrange Funktion:

$$\underline{L(x, \lambda)} := \underline{f(x)} + \sum_{i=1}^m \underline{\lambda_i \cdot h_i(x)}$$

## Gradient:

$$\frac{\partial}{\partial x_j} L(x, \lambda) = \frac{\partial}{\partial x_j} f(x) + \sum_{i=1}^m \lambda_i \cdot \frac{\partial}{\partial x_j} h_i(x)$$

$$\frac{\partial}{\partial \lambda_j} L(x, \lambda) = \underline{h_j(x)}$$

## Lagrange Methode:

$$\underline{\nabla L(x, \lambda) = 0}$$

$$\underline{\nabla f(x^*) + \sum_{i=1}^m \lambda_i^* \cdot \underline{\nabla h_i(x^*)} = 0, \quad \underline{h_i(x^*)} = 0 \quad (i = 1, \dots, m)}$$

**Lagrange Funktion:**

$$\underline{L(x, \lambda)} := f(x) + \sum_{i=1}^m \lambda_i \cdot h_i(x)$$

**Lagrange Methode:**

Notwendige Bedingung für lokales Minimum bei regulärem Punkt  $x^*$ :

$$\underline{\nabla L(x^*, \lambda^*) = 0}$$

- Reduziert das Problem auf das Finden eines stationären Punktes eines unrestringierten Problems!
- Methoden: (konj.) Gradientenmethode, Newton, Quasi-Newton, ...

Gegeben: Funktion  $f, h_1, h_2, \dots, h_m: \mathbb{R}^n \rightarrow \mathbb{R}$

Ziel:

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

$$\text{wobei } g_1(x) \leq 0, g_2(x) \leq 0, \dots, g_p(x) \leq 0$$

Notwendige Bedingung für lokales Minimum  $x^*$ :

- $x^*$  ist zulässig:  $\forall i: \underline{g_i(x^*)} \leq 0$
- keine zulässige Abstiegsrichtung  $s$  bei  $x^*$

$$\underline{g_i(x^*) < 0}$$

Aktive Nebenbedingungen:

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

- Nur aktive Nebenbedingungen beschränken die gültigen Richtungen

**Aktive Nebenbedingung  $g_i$  an Punkt  $x^*$ :**

$$g_i(x^*) = 0$$

**Zulässige Richtung  $s$  and Punkt  $x^*$ :**

- Für genug kleines  $\delta > 0$  gilt:

$$g_i(x^* + \delta \cdot s) \leq 0$$

- Taylor-Approximation:

$$\underbrace{g_i(x^* + \delta \cdot s)}_{\leq 0} \approx \underbrace{g_i(x^*)}_{=0} + \underbrace{\delta \cdot s^T \nabla g_i(x^*)}_{\leq 0} \leq 0$$

- Zulässige Richtung  $s$  bei  $x^*$  (notwendige Bedingung):

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

**Zulässige Abstiegsrichtung  $s$  bei  $x^*$ :**

$$\underline{s^T \nabla f(x^*) < 0} \quad \text{und} \quad \forall i \in I^*: \underline{s^T \nabla g_i(x^*) \leq 0}$$

Bei **regulärem lokalem Minimum**  $x^*$  hat folgendes System keine Lösung:

$$\begin{aligned} \rightarrow & \begin{cases} s^T \nabla g_i(x^*) \leq 0, & \forall i \in I^* \\ s^T \nabla f(x^*) < 0 \end{cases} \quad \text{(A)} \end{aligned}$$

**Hinreichende Bedingung**, damit (A) keine Lösung hat:

$$-\nabla f(x^*) = \sum_{i \in I^*} \lambda_i \cdot \nabla g_i(x^*), \quad \text{mit } \underline{\lambda_i \geq 0} \text{ für } i \in I^* \quad \text{(B)}$$

$$-s^T \nabla f(x^*) = \sum_{i \in I^*} \lambda_i \underbrace{s^T \nabla g_i(x^*)}_{\leq 0} \leq 0 \quad s^T \nabla f(x^*) \geq 0$$

Lemma von Farkas:

- (B) ist auch eine notwendige Bedingung, damit (A) keine Lösung hat

**Satz (Lemma von Farkas):** Für beliebige Vektoren  $\underline{a_1}, \dots, \underline{a_k}$  und  $\underline{g}$  ist die Menge

$$S = \{s \mid \underline{s^T g} < 0 \text{ und } \underline{s^T a_i} \leq 0 \text{ for all } i = 1, \dots, k\}$$

genau dann leer, falls  $\underline{\lambda_i} \geq 0$  existieren, so dass

$$\underline{-g} = \sum_{i=1}^k \lambda_i a_i.$$

$$a_i = \nabla g_i(x^*)$$

$$g = \nabla f(x^*)$$

- Äquivalent zum **Dualitätssatz** der **linearen Programmierung**

**Anwendung hier:** System

$$\underline{s^T \nabla f(x^*)} < 0, \quad \underline{s^T \nabla g_i(x^*)} \leq 0, \quad \underline{\forall i \in I^*}$$

hat genau dann keine Lösung, wenn

$$\underline{-\nabla f(x^*)} = \sum_{i \in I^*} \lambda_i \cdot \nabla g_i(x^*), \quad \text{mit } \underline{\lambda_i} \geq 0 \text{ für } i \in \underline{I^*}$$

Notwendige Bedingung für (reguläres) lokales Minimum bei  $x^*$ :

$$-\nabla f(x^*) = \sum_{i \in I^*} \lambda_i \cdot \nabla g_i(x^*), \quad \text{mit } \lambda_i \geq 0 \text{ für } i \in I^*$$

**Karush-Kuhn-Tucker Satz**: Sei  $x^*$  ein reguläres, lokales Minimum. Dann existieren Multiplikatoren  $\lambda_i^*$ , derart dass

$$\nabla f(x^*) + \sum_{i=1}^p \lambda_i^* \nabla g_i(x^*) = 0$$

$$\lambda_i^* \geq 0, \quad i = 1, \dots, p$$

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


$$i \notin I^* : g_i(x^*) \neq 0 \implies \lambda_i^* = 0$$

Karush-Kuhn-Tucker Punkt  $x^*$

Zur Erinnerung:


- Funktion  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  heisst konvex, falls für alle  $x, y \in \mathbb{R}^n$  und  $\lambda \in [0,1]$ :

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



- Eine Menge  $S \subseteq \mathbb{R}^n$  heisst, falls für alle  $x, y \in S$  und  $\lambda \in [0,1]$ :

$$\lambda x + (1 - \lambda)y \in S$$



Der Schnitt zweier konvexer Mengen ist konvex:

$$S_1, S_2 \text{ konvex} \implies S_1 \cap S_2 \text{ konvex} \quad \leftarrow$$

**Konvexe Nebenbedingung:**

$$\text{Funktion } g_i(x) \text{ konvex} \implies \underline{\{x : g_i(x) \leq 0\} \text{ ist konvex}}$$

$$g_i(x) \leq 0 \quad g_i(y) \leq 0 \implies g_i(\lambda x + (1-\lambda)y) \leq 0$$


$$g_i(\lambda x + (1-\lambda)y) \leq \lambda g_i(x) + (1-\lambda)g_i(y) \leq 0$$

**Konvexe Minimierung:**

$$\min_{x \in S} f(x), \quad \text{wobei Fkt. } f(x) \text{ und Menge } S \text{ konvex sind}$$

Konvexe Minimierung: **lokales Minimum**  $\underline{x'} \in S$  ist auch **globales Minimum**:

- Globales Minimum  $x^* \in S$
- Konvexität von  $S$ : Verbindungslinie in  $S$
- Konvexität von  $f$ : Betrachte  $z = \lambda x' + (1-\lambda)x^*$  auf Verbindungslinie:



$$f(z) = f(\lambda x' + (1-\lambda)x^*) \leq \lambda f(x') + (1-\lambda)f(x^*) < \underline{\underline{f(x')}}$$

(falls  $f(x') > f(x^*)$ )

**Karush-Kuhn-Tucker Satz:** Sei  $x^*$  ein reguläres, lokales Minimum. Dann existieren Multiplikatoren  $\lambda_i^*$ , derart dass

$$\nabla f(x^*) + \sum_{i=1}^p \lambda_i^* \nabla g_i(x^*) = 0$$

$$\lambda_i^* \geq 0, \quad i = 1, \dots, p$$

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


### Hinreichende Karush-Kuhn-Tucker Bedingungen

**Satz:** Falls  $f(x)$ ,  $g_1(x)$ ,  $\dots$ ,  $g_p(x)$  **konvex** sind, dann ist jeder Punkt  $x^*$ , welcher die Karush-Kuhn-Tucker Bedingungen erfüllt, ein globales Minimum.

**Satz:** Falls  $f(x), g_1(x), \dots, g_p(x)$  **konvex** sind, dann ist jeder Punkt  $x^*$ , welcher die Karush-Kuhn-Tucker Bedingungen erfüllt, ein globales Minimum.

**Eigenschaft konvexer Funktionen:**

$$\forall x', x^*: \underline{f(x') \geq f(x^*) + \nabla f(x^*)^T (x' - x^*)}$$



**Satz:** Falls  $f(x), g_1(x), \dots, g_p(x)$  **konvex** sind, dann ist jeder Punkt  $x^*$ , welcher die Karush-Kuhn-Tucker Bedingungen erfüllt, ein globales Minimum.

Betrachte Karush-Kuhn-Tucker Punkt  $x^*$  und ein beliebiges  $x' \neq x^*$ :

Konvexität:

$$f(x') \geq f(x^*) + \nabla f(x^*)^T (x' - x^*) \quad \leftarrow$$

$$\forall i: g_i(x') \geq g_i(x^*) + \nabla g_i(x^*)^T (x' - x^*) \quad \leftarrow$$

zulässig

$$f(x') \geq f(x^*) + \sum_{i=1}^p \lambda_i^* g_i(x')$$

$$g_i(x') \leq 0, \quad \lambda_i^* \geq 0$$

$$\geq f(x^*) + \nabla f(x^*)^T (x' - x^*) + \sum_{i=1}^p \lambda_i^* (g_i(x^*) + \nabla g_i(x^*)^T (x' - x^*))$$

$$= f(x^*) + \left[ \nabla f(x^*) + \sum_{i=1}^p \lambda_i^* \nabla g_i(x^*) \right]^T (x' - x^*) + \sum_{i=1}^p \lambda_i^* g_i(x^*)$$

**Satz:** Falls  $f(x), g_1(x), \dots, g_p(x)$  **konvex** sind, dann ist jeder Punkt  $x^*$ , welcher die Karush-Kuhn-Tucker Bedingungen erfüllt, ein globales Minimum.

Betrachte Karush-Kuhn-Tucker Punkt  $x^*$  und ein beliebiges  $x' \neq x^*$ :

$$f(x') \geq f(x^*) + \underbrace{\left[ \nabla f(x^*) + \sum_{i=1}^p \lambda_i^* \nabla g_i(x^*) \right]^T}_{=0} (x' - x^*) + \sum_{i=1}^p \underbrace{\lambda_i^* g_i(x^*)}_{=0}$$

$= f(x^*)$ 
 $f(x') \geq f(x^*)$

Punkt  $x^*$  erfüllt Karush-Kuhn-Tucker Bedingungen:

$$\nabla f(x^*) + \sum_{i=1}^p \lambda_i^* \nabla g_i(x^*) = 0 \quad \leftarrow$$

$$\lambda_i^* \geq 0 \quad \text{und} \quad \lambda_i^* g_i(x^*) = 0, \quad i = 1, \dots, p$$

Ist  $x^* = \begin{pmatrix} 1/\sqrt{2} \\ 1/\sqrt{2} \end{pmatrix}$  Optimallösung des folgenden Minimierungsproblems?

$$\min f(x) = -x_1 - x_2$$

$$g_1(x) = x_1^2 - x_2 \leq 0$$

$$g_2(x) = x_1^2 + x_2^2 - 1 \leq 0$$

Gegeben: Funktion  $f, h_1, h_2, \dots, h_m: \mathbb{R}^n \rightarrow \mathbb{R}$

Ziel:

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

$$\text{wobei } h_1(x) = 0, h_2(x) = 0, \dots, h_m(x) = 0 \leftarrow$$

$$g_1(x) \leq 0, g_2(x) \leq 0, \dots, g_p(x) \leq 0 \leftarrow$$

**Notwendige Bedingung für (reguläres) lokales Minimum  $x^*$ :**

Falls  $s^T \nabla h_i(x^*) = 0$  für  $i = 1, \dots, m$  und  $s^T \nabla g_i(x^*) \leq 0$  für  $i \in I^*$ , dann gilt

$$\underline{s^T \nabla f(x^*) \geq 0.}$$

Farkas-Lemma: Es gibt Multiplikatoren  $\lambda_i^*$  ( $i = 1, \dots, m$ ) und  $\mu_i^* \geq 0$  ( $i \in I^*$ ),

$$\nabla f(x^*) + \sum_i^m \lambda_i^* \nabla h_i(x^*) + \sum_{i \in I^*} \mu_i^* \nabla g_i(x^*) = 0.$$