

## Übungen zur Vorlesung Nichtglatte Optimierung und Anwendungen

### G1. Versagen der exakten Schrittweitsuche bei nichtglatten Problemen

Gegeben sei das Problem

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

mit  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  konvex und stetig differenzierbar. Wir betrachten das

#### Verfahren des steilsten Abstiegs mit exakter Schrittweitsuche:

Wähle  $x^0 \in \mathbb{R}^n$ . Für  $k = 0, 1, 2, \dots$ :

1. Setze  $s^k = -\nabla f(x^k)$  (Richtung des steilsten Abstiegs).

2. Ermittle die optimale Schrittweite  $\sigma_k \geq 0$  entlang  $s^k$ :

$$f(x^k + \sigma_k s^k) = \min_{\sigma \geq 0} f(x^k + \sigma s^k).$$

3. Setze  $x^{k+1} = x^k + \sigma_k s^k$ .

Zeigen Sie:

a) Das Verfahren erzeugt für die konvexe Funktion  $f_1(x) = x_1^2 + 2x_2^2$  zum Startpunkt  $x^0 = (2, 1)^T$  die Folge

$$x^{2k} = 9^{-k} x^0, \quad x^{2k+1} = 9^{-k} x^1,$$

konvergiert also gegen das Minimum von  $f_1$ . Skizzieren Sie die Höhenlinien von  $f_1$  und die Iterierten  $x^k$ .

b) Das Verfahren produziert für die nichtglatte konvexe Zielfunktion

$$f_2(x) := \sqrt{f_1(x)}$$

dieselbe Folge  $x^k$ , konvergiert also gegen das Minimum von  $f_2$ .

c) Das Verfahren erzeugt auch für die nichtglatte, stetige, konvexe (kein Nachweis!) Zielfunktion

$$f_3(x) := \begin{cases} f_2(x) & x_1 \geq |x_2|, \\ \frac{1}{\sqrt{3}}(x_1 + 2|x_2|) & x_1 < |x_2|, \end{cases}$$

dieselbe Folge  $x^k$ , aber  $x^k$  konvergiert nicht gegen ein Minimum von  $f_3$ . Skizzieren Sie die Höhenlinien von  $f_3$  und die Iterierten  $x^k$ .

d) Warum ist es also hoffnungslos, das Verfahren des steilsten Abstiegs mit exakter Schrittweitsuche auf nichtglatte Probleme erweitern zu wollen?

Bitte wenden!

**G2.** Berechnen Sie die folgenden Subdifferenziale:

a)  $\partial f(0)$  für  $f : \mathbb{R} \rightarrow \mathbb{R}$ ,  $f(x) = \begin{cases} x^2 & x < 0 \\ x & x \geq 0 \end{cases}$ .

Veranschaulichen Sie sich Ihr Ergebnis grafisch.

b)  $\partial f(0)$  für  $f : \mathbb{R}^n \rightarrow \mathbb{R}$ ,  $f(x) = \|x\|_2 = \sqrt{x^T x}$ .

**G3. Epigraph und Subgradienten**

Sei  $X \subset \mathbb{R}^n$  und  $f : X \rightarrow \mathbb{R}$  eine Funktion. Der Epigraph von  $f$  ist definiert gemäß

$$\text{epi}(f) = \left\{ \begin{pmatrix} x \\ \alpha \end{pmatrix} ; x \in X, \alpha \in \mathbb{R}, \alpha \geq f(x) \right\}.$$

- a) Zeigen Sie, dass  $X$  und  $f$  genau dann konvex sind, wenn  $\text{epi}(f)$  konvex ist.
- b) Sei  $X \subset \mathbb{R}^n$  konvex und offen und  $f : X \rightarrow \mathbb{R}$  sei konvex. Zeigen Sie, dass  $g \in \mathbb{R}^n$  genau dann ein Subgradient von  $f$  im Punkt  $x \in X$  ist, wenn der Vektor  $v = (g^T, -1)^T \in \mathbb{R}^{n+1}$  im Punkt  $(x^T, f(x))^T$  senkrecht aus  $\text{epi}(f)$  herauszeigt, genauer:

$$(g^T, -1) \left( z - \begin{pmatrix} x \\ f(x) \end{pmatrix} \right) \leq 0 \quad \forall z \in \text{epi}(f). \quad (*)$$

- c) Begründen Sie, dass man (\*) im folgenden Sinne interpretieren kann:  
Die Hyperebene

$$H = \{z \in \mathbb{R}^{n+1} : (g^T, -1)z = g^T x - f(x)\} \subset \mathbb{R}^{n+1}$$

durch den Punkt  $(x^T, f(x))^T$  mit Normale  $v = (g^T, -1)^T$  verläuft überall auf oder unter dem Graphen von  $f$  (man sagt:  $H$  stützt den Graphen von  $f$  (und gleichzeitig den Epigraphen von  $f$ ) im Punkt  $(x^T, f(x))^T$  von unten).

**Hausaufgaben:**

**H1. Negative Subgradienten sind nicht immer Abstiegsrichtungen**

Betrachte die Funktion

$$f(x) = \frac{x_1^2}{2} + 2|x_2|.$$

Zeige: Es gilt  $g = \begin{pmatrix} 1 \\ 2 \end{pmatrix} \in \partial f \begin{pmatrix} 1 \\ 0 \end{pmatrix}$ , aber  $s = -g$  ist keine Abstiegsrichtung von  $f$  in  $x = \begin{pmatrix} 1 \\ 0 \end{pmatrix}$ .

**H2. Richtungsableitung des Maximums von Funktionen**

Sei  $U \subset \mathbb{R}^n$  eine offene Menge und seien  $f_i : U \rightarrow \mathbb{R}$ ,  $i = 1, \dots, m$ , stetige Funktionen. Wir betrachten die Funktion  $f : U \rightarrow \mathbb{R}$ ,  $f(x) = \max_{1 \leq i \leq m} f_i(x)$ . Sei nun  $x \in U$  und  $I(x) = \{i ; f_i(x) = f(x)\}$ .

Zeigen Sie: Sind die Funktionen  $f_i$ ,  $i \in I(x)$ , richtungsdifferenzierbar in  $x$ , dann ist  $f$  ebenfalls richtungsdifferenzierbar in  $x$  und es gilt

$$f'(x, s) = \max_{i \in I(x)} f'_i(x, s) \quad \forall s \in \mathbb{R}^n.$$