

## Lösungsvorschlag zur Vorlesung Nichtglatte Optimierung und Anwendungen

**G4:**

$$H = \{x; s^T x = 0\}.$$

Liege nun  $\partial f(x)$  strikt auf der Seite von  $H$ , auf die  $s$  nicht zeigt:

$$s^T g < 0 \quad \forall g \in \partial f(x). \quad (1)$$

Aus (1) folgt:

$$f'(x, s) = \max_{g \in \partial f(x)} s^T g < 0$$

Die strikte Ungleichung folgt daraus, dass das Maximum angenommen wird. Damit ist  $s$  eine Abstiegsrichtung.

Gilt umgekehrt  $f'(x, s) < 0$ , dann folgt für alle  $g \in \partial f(x)$

$$s^T g = g^T s \leq f'(x, s) < 0,$$

also (1).

Nun gelte (1). Dann haben wir

$$d(H, \partial f(x)) = \min_{g \in \partial f(x)} \frac{|s^T g|}{\|s\|} = \min_{g \in \partial f(x)} \frac{-s^T g}{\|s\|} = \frac{-1}{\|s\|} \max_{g \in \partial f(x)} g^T s = \frac{-1}{\|s\|} f'(x, s).$$

Dies liefert

$$f'(x, s) = -\|s\| d(H, \partial f(x)).$$

**G5**

Das Subgradientenverfahren lautet

$$x^{k+1} = x^k + \sigma_k s^k, \quad s^k = -\frac{g^k}{\|g^k\|}, \quad g^k \in \partial f(x^k) \quad \text{solange } g^k \neq 0.$$

zu a): Für  $f(x) = |x|$  gilt offensichtlich

$$\partial f(x) = \begin{cases} \text{sgn}(x) & x \neq 0, \\ [-1, 1] & x = 0. \end{cases}$$

Begründung: Es gilt  $f(x) = \max(f_1(x), f_2(x))$ ,  $f_1(x) = x$ ,  $f_2(x) = -x$ . Satz 2.3.9 liefert

$$\partial f(x) = \text{conv}(\cup_{i: f_i(x)=|x|} \partial f_i(x)).$$

Wegen  $\partial f_1(x) = \{1\}$ ,  $\partial f_2(x) = \{-1\}$  folgt die Behauptung.

i): Sei  $x^k \neq 0$  beliebig. Dann gilt

$$s^k = -\frac{\operatorname{sgn}(x^k)}{|\operatorname{sgn}(x^k)|} = -\operatorname{sgn}(x^k).$$

Also gilt  $x^{k+1} = x^k - \frac{\operatorname{sgn}(x^k)}{k+1}$ . Wir erhalten für  $x^0 = 2$

$$\begin{aligned} x^0 &= 2, & x^1 &= 2 - 1 = 1, & x^2 &= 1 - \frac{1}{2} = \frac{1}{2}, \\ x^3 &= \frac{1}{2} - \frac{1}{3} = \frac{1}{6}, & x^4 &= \frac{1}{6} - \frac{1}{4} = -\frac{1}{12}, & x^5 &= -\frac{1}{12} + \frac{1}{5} = \frac{7}{60}. \end{aligned}$$

ii): Dann ist

$$\sigma_0 = \frac{|x^0| - 0}{1} = |x^0|,$$

also

$$x^1 = x^0 + |x^0|(-\operatorname{sgn}(x^0)) = x^0 - x^0 = 0.$$

Anschließend gilt  $g^k = 0$  (dann Abbruch), oder  $\sigma^k = 0$ . Wir haben Konvergenz nach einem Schritt!

zu b): Für  $x \neq 0$  gilt  $\partial f(x) = \{2(|x| + 1)\operatorname{sgn}(x)\}$ . In  $x^k \neq 0$  gilt also

$$s^k = -\frac{g^k}{|g^k|} = -\operatorname{sgn}(x^k)$$

und mit ii)

$$\sigma_k = \frac{(|x^k| + 1)^2 - 1}{2(|x^k| + 1)} = \frac{|x^k|^2 + 2|x^k|}{2(|x^k| + 1)} = \frac{|x^k|}{2} + \frac{|x^k|}{2(|x^k| + 1)}.$$

Dies ergibt

$$x^{k+1} = x^k + \left( \frac{|x^k|}{2} + \frac{|x^k|}{2(|x^k| + 1)} \right) (-\operatorname{sgn}(x^k)) = x^k - \frac{x^k}{2} - \frac{x^k}{2(|x^k| + 1)} = x^k \left( \frac{1}{2} - \frac{1}{2(|x^k| + 1)} \right),$$

also

$$|x^{k+1} - 0| \leq \frac{1}{2}|x^k|.$$

## G6

zu a):

$$\lambda_{\max}(A) = \max_{\|v\|=1} v^T A v$$

ist das Maximum der Familie linearer Funktionen  $l_v : A \mapsto v^T A v$  und somit konvex.

zu b):

$$(vv^T) \bullet A = \sum_{i,j=1}^n (vv^T)_{ij} a_{ij} = \sum_{i,j=1}^n v_i v_j a_{ij} = \sum_{i,j=1}^n v_i a_{ij} v_j = v^T A v.$$

Im Fall  $v \neq 0$  gilt weiter

$$v^T A v = \frac{v^T}{\|v\|} A \frac{v}{\|v\|} \|v\|^2 \leq \lambda_{\max}(A) \|v\|^2.$$

zu c):

Nach Definition von  $\lambda_{\max}$  und b) gilt für alle  $B \in \mathcal{S}^{n \times n}$

$$\lambda_{\max}(B) - \lambda_{\max}(A) = \lambda_{\max}(B) - q^T A q \geq q^T B q - q^T A q = (q q^T) \bullet (B - A).$$

Dies ist genau die Subgradienten-Ungleichung für  $\lambda_{\max}$  in  $A$ .

### **Beispielanwendung aus der Kontrolltheorie:**

Einsetzen der Feedbacksteuerung liefert

$$x'(t) = Ax(t) + BKx(t).$$

Multiplikation von links mit  $2x(t)^T$  ergibt

$$\frac{d}{dt} \|x(t)\|^2 = 2x(t)^T x'(t) = x(t)^T (A + BK)x(t) = x(t)^T \frac{1}{2} (A + A^T + BK + K^T B^T)x(t).$$

Möglichst starke Abdämpfung erhält man, wenn man  $K$  als Lösung des Eigenwertoptimierungsproblems wählt

$$\min_{K \in \mathbb{R}^{m,n}} \lambda_{\max}(A + A^T + BK + K^T B^T).$$