

## Übungen zur Vorlesung Nichtglatte Optimierung und Anwendungen

### G4. Subgradienten und Abstiegsrichtungen

Sei  $f : X \rightarrow \mathbb{R}$  konvex auf der offenen konvexen Menge  $X \subset \mathbb{R}^n$  und  $x \in X$  beliebig. Sei  $H \subset \mathbb{R}^n$  eine Hyperebene durch 0 mit Normale  $s$ . Zeigen Sie:  $s$  ist genau dann eine Abstiegsrichtung von  $f$  in  $x$ , wenn  $\partial f(x) \cap H = \emptyset$  und zudem  $\partial f(x)$  vollständig auf der Seite von  $H$  liegt, in die  $-s$  zeigt. Zeigen Sie weiter, dass dann gilt

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

wobei  $d(H, \partial f(x))$  den Abstand zwischen  $H$  und  $\partial f(x)$  bezeichnet.

### G5. Anwendung des Subgradientenverfahrens

a) Betrachte das Problem

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

für  $f(x) = |x|$  mit Lösung  $\bar{x} = 0$ . Wenden Sie das Subgradientenverfahren aus Algorithmus 2 (wegen  $X = \mathbb{R}^n$  ist  $P_X = id$ ) an mit den Schrittweiten

- i)  $\sigma_k = \frac{1}{k+1}$ ,
- ii)  $\sigma_k = \frac{f(x^k) - f(\bar{x})}{|g^k|}$  (vgl. (2.12) aus der Vorlesung).

Berechnen Sie für  $x^0 = 2$  in beiden Fällen  $x^1, \dots, x^5$  (solange nicht  $g^k = 0$  auftritt).

b) Sei nun  $f(x) = (|x| + 1)^2$  mit Minimum  $\bar{x} = 0$ . Zeigen Sie, dass das Subgradientenverfahren mit Schrittweitenwahl ii) für alle Startpunkte  $x^0 \in \mathbb{R}$  Iterierte  $x^k$  liefert mit

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

### G6. Eigenwert-Optimierung

In zahlreichen Anwendungen tritt das Problem auf, den größten Eigenwert einer symmetrischen Matrix zu minimieren. Wir betrachten also die Funktion

$$\lambda_{\max} : A \in \mathcal{S}^{n,n} \mapsto \max_{\|v\|=1} v^T A v,$$

wobei  $\mathcal{S}^{n,n} = \{A \in \mathbb{R}^{n,n} : A = A^T\}$  die Menge aller symmetrischen  $n \times n$ -Matrizen bezeichne. Beachte hierbei, dass bei symmetrischen Matrizen die Eigenvektoren eine Orthogonalbasis bilden und daher tatsächlich  $\lambda_{\max}(A) = \max_{\|v\|=1} v^T A v$  ist.

Bitte wenden!

Wir versehen  $\mathcal{S}^{n,n}$  mit dem Skalarprodukt  $A \bullet B := \sum_{i,j=1}^n a_{ij}b_{ij}$ , wobei  $A = (a_{ij})$ ,  $B = (b_{ij})$  (also dem euklidischen Skalarprodukt, wenn wir Matrizen als  $n^2$ -Vektoren auffassen).

- a) Begründen Sie, dass die Funktion  $\lambda_{\max}$  konvex ist.  
 b) Zeigen Sie, dass für alle  $v \in \mathbb{R}^n$  und  $A \in \mathcal{S}^{n,n}$  gilt:

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

Zeigen Sie, dass Gleichheit in der rechten Ungleichung gilt, falls  $v$  ein Eigenvektor von  $A$  zu  $\lambda_{\max}(A)$  ist.

- c) Sei nun  $q$ ,  $\|q\| = 1$ , ein Eigenvektor zum maximalen Eigenwert von  $A \in \mathcal{S}^{n,n}$ .  
 Zeigen Sie, dass dann  $qq^T$  ein Subgradient von  $\lambda_{\max}$  im „Punkt“  $A$  ist, also:

$$\lambda_{\max}(B) - \lambda_{\max}(A) \geq (qq^T) \bullet (B - A) \quad \forall B \in \mathcal{S}^{n,n}.$$

**Beispielanwendung aus der Kontrolltheorie:** Betrachte das Anfangswertproblem

$$x'(t) = Ax(t) + Bu(t), \quad x(0) = x_0, \quad t > 0$$

mit  $A \in \mathbb{R}^{n,n}$ ,  $B \in \mathbb{R}^{n,m}$ ,  $m \leq n$ . Hierbei sei  $u : [0, \infty) \rightarrow \mathbb{R}^m$  eine *Steuerfunktion* und  $x : [0, \infty) \rightarrow \mathbb{R}^n$  der resultierende *Zustand* des Systems.

**Aufgabe:** Finde durch ein Eigenwertoptimierungsproblem eine Matrix  $K \in \mathbb{R}^{m,n}$ , so dass die Feedbacksteuerung  $u(t) := Kx(t)$  die euklidische Norm  $\|x(t)\| := \sqrt{x(t)^T x(t)}$  des Zustands möglichst schnell abdämpft, also  $\frac{d}{dt} \|x(t)\|^2$  möglichst negativ wird.

**Hausaufgaben:**

### H3. Oberhalbstetigkeit des Subdifferentials

Sei  $f : U \rightarrow \mathbb{R}$  konvex auf der offenen konvexen Menge  $U \subset \mathbb{R}^n$ .

- a) Verwenden Sie die Subgradienten-Ungleichung, um zu zeigen: Aus

$$x^k \in U, \quad g^k \in \partial f(x^k), \quad k \geq 0, \quad \lim_{k \rightarrow \infty} x^k = x \in U, \quad \lim_{k \rightarrow \infty} g^k = g \in \mathbb{R}^n$$

folgt  $g \in \partial f(x)$ .

- b) Zeigen Sie, dass  $\partial f$  oberhalbstetig ist, d.h.

$$\forall x \in U, \varepsilon > 0 \quad \exists \delta > 0 : \quad \bigcup_{y \in B_\delta(x)} \partial f(y) \subset \partial f(x) + B_\varepsilon(0).$$

Das heißt: Ist  $y$  nahe genug bei  $x$ , so liegt  $\partial f(y)$  in einer  $\varepsilon$ -Umgebung von  $\partial f(x)$ .

### H4. Kompaktheit der Optimallösungsmenge

Betrachte das Problem

$$\min_{x \in X} f(x) \tag{PX}$$

mit  $X \subset \mathbb{R}^n$  nichtleer, abgeschlossen, konvex und  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  konvex.

Zeigen Sie, dass folgende Aussagen äquivalent sind:

- i) Die Niveaumengen  $N(\nu) := \{x \in X : f(x) \leq \nu\}$  sind für jedes  $\nu \in \mathbb{R}$  kompakt.  
 ii) Die Menge  $X_{opt}$  der Optimallösungen von (PX) ist nichtleer und kompakt.