


Übungen zur Vorlesung

Variationsmethoden in der Biomedizinischen Bildgebung

WS 2012/13 — Blatt 10, Abgabe: Di. 15.01.2013, 12 Uhr, BK 39



Aufgabe 1 (Karush-Kuhn-Tucker Bedingungen)

(5 Punkte)

Sei $F : \mathbb{R}^n \rightarrow \mathbb{R}$ konvex und $A \in \mathbb{R}^{m \times n}$ eine Matrix mit vollem Rang ($m < n$). Wir betrachten das beschränkte Optimierungsproblem

$$F(u) \rightarrow \min_u$$

unter den Nebenbedingungen

$$\begin{aligned} u_i &\geq 0 \quad i = 1, \dots, n \\ Au &= b . \end{aligned}$$

Berechnen Sie für die äquivalente Formulierung

$$J(u) = F(u) + \chi_+(u) + \chi_b(Au)$$

mit

$$\chi_+(u) = \begin{cases} 0 & \text{falls } u_i \geq 0, i = 1, \dots, n \\ +\infty & \text{sonst} \end{cases} \quad \chi_b(Au) = \begin{cases} 0 & \text{falls } Au = b \\ +\infty & \text{sonst} \end{cases}$$

die Optimalitätsbedingung und folgern Sie daraus die sogenannten Karush-Kuhn-Tucker Bedingungen: Es existieren Lagrange-Multiplikatoren $\lambda_i \leq 0$ ($\lambda \in \mathbb{R}^n$ sei Vektor der λ_i) und $\mu \in \mathbb{R}^m$ frei, sodass

$$\begin{aligned} F'(u) + \lambda + A^T \mu &= 0 \\ \lambda_i u_i &= 0 . \end{aligned}$$

Aufgabe 2 (Lineare Optimierung)

(5 Punkte)

Wir betrachten ein lineares Optimierungsproblem

$$c^T u \rightarrow \min_u$$

unter den Nebenbedingungen

$$\begin{aligned} u_i &\geq 0 \quad i = 1, \dots, n \\ Au &= b . \end{aligned}$$

mit $c \in \mathbb{R}^n$, $b \in \mathbb{R}^m$ und $A \in \mathbb{R}^{m \times n}$ eine Matrix mit vollem Rang ($m < n$). Formulieren Sie dieses Problem analog zu Aufgabe 1 und leiten Sie das Fenchel-duale Problem her. Schreiben Sie dieses wieder als lineares Optimierungsproblem mit linearen Nebenbedingungen.

Aufgabe 3 (First optimize then discretize vs. First discretize then optimize)(5 Punkte)

Für $\Omega = [0, 1]$ betrachten wir das inverse Problem $Ku = f$ mit

$$(Ku)(x) := \int_{\Omega} k(x, y)u(y) dy ,$$

Kern $k(x, y) := e^{x-y}$ und gegebenen Daten f . Gegeben sei nun ein einfaches Variationsproblem zur Rekonstruktion bzgl. $u \in L^2(\Omega)$,

$$\frac{1}{2} \|(Ku)(x) - f(x)\|_{L^2(\Omega)}^2 + \frac{\alpha}{2} \|u\|_{L^2(\Omega)}^2 \rightarrow \min_{u \in L^2(\Omega)} .$$

Behandeln Sie das Problem einmal gemäß der Strategie „First optimize then discretize“ und einmal gemäß der Strategie „First discretize then optimize“. Leiten Sie in beiden Fällen ein diskretisiertes Gradientenverfahren her (der Einfachheit halber mit konstanter Zeit-Schrittweite σ). Für eine Diskretisierung im Ort nehmen Sie an, dass Ω in n Intervalle mit Orts-Schrittweite h äquidistant unterteilt wird. Diskretisieren Sie Integrale mit Hilfe der Trapezregel.

Wie unterscheiden sich die beiden resultierenden diskreten Algorithmen?

Aufgabe 4 (Gradientenverfahren, Funktionenräume)

(5 Punkte)

Gegeben sei ein allgemeines Variationsproblem der Form

$$J(u) := \int_{\Omega} G(u, \nabla u) dx \rightarrow \min_{u \in \mathcal{U}(\Omega)}$$

auf einem Hilbertraum $\mathcal{U}(\Omega)$. Ziel dieser Aufgabe ist die Auswirkung der Wahl von Funktionenräumen bei der Strategie „First optimize then discretize“ am Beispiel des Gradientenverfahrens zu studieren.

- (a) Wenn man der Lösungsstrategie „First optimize then discretize“ folgt, erhält man für $\mathcal{U}(\Omega) = L^2(\Omega)$ typischerweise ein Gradientenverfahren bzgl. euklidischer Distanz. Zum Vergleich folgen Sie dieser Strategie sowohl für $\mathcal{U}(\Omega) = L^2(\Omega)$ als auch für $\mathcal{U}(\Omega) = H^1(\Omega)$. Wie äußert sich der Unterschied der Funktionenräume im resultierenden (diskreten) Gradientenverfahren? (Hinweis: Gradientenfluss in \mathcal{U} und schwache Formulierung)
- (b) Konkretisieren Sie die allgemeine Betrachtung aus (a) an dem Beispiel

$$G(u, \nabla u) := u^2 + |\nabla u|^2 .$$