

## Übungen zur Vorlesung Nichtglatte Optimierung und Anwendungen

### G10. Duales Problem des regularisierten Schnittebenenmodells

Zeigen Sie:

a)  $(s^k, \xi^k)$  ist genau dann Lösung von

$$\min_{s \in \mathbb{R}^n, \xi \in \mathbb{R}} \xi + \frac{1}{2\gamma_k} \|s\|^2 \quad \text{u.d.N.} \quad g^{jT} s - \alpha_j^k - \xi \leq 0, \quad j \in J_k, \quad (1)$$

wenn die KKT-Bedingungen gelten, d.h. wenn es  $\lambda_j^k \in \mathbb{R}, j \in J_k$ , gibt mit

$$\begin{aligned} \frac{1}{\gamma_k} s^k + \sum_{j \in J_k} \lambda_j^k g^j &= 0, \\ \sum_{j \in J_k} \lambda_j^k &= 1, \\ g^{jT} s^k - \alpha_j^k - \xi^k &\leq 0, \quad \lambda_j^k \geq 0, \quad \lambda_j^k (g^{jT} s^k - \alpha_j^k - \xi^k) = 0, \quad j \in J_k. \end{aligned} \quad (2)$$

b) Der Vektor  $\lambda^k$  ist genau dann Lösung des Problems

$$\begin{aligned} \min_{\lambda} \quad & \frac{\gamma_k}{2} \left\| \sum_{j \in J_k} \lambda_j g^j \right\|^2 + \sum_{j \in J_k} \lambda_j \alpha_j^k \\ \text{u.d.N.} \quad & \sum_{j \in J_k} \lambda_j = 1, \quad \lambda_j \geq 0, \quad j \in J_k, \end{aligned} \quad (3)$$

wenn die KKT-Bedingungen gelten. Weiter ist  $(\lambda^k, \mu^k, \xi^k) \in \mathbb{R}^{|J_k|} \times \mathbb{R}^{|J_k|} \times \mathbb{R}$  genau dann ein KKT-Tupel von (3), wenn (2) für

$$s^k = -\gamma_k \sum_{j \in J_k} \lambda_j^k g^j, \quad (4)$$

erfüllt ist und zusätzlich gilt:

$$\mu_j^k = -g^{jT} s^k + \alpha_j^k + \xi^k, \quad j \in J_k. \quad (5)$$

gilt.

c) Sei  $\lambda^k$  eine Lösung von (3). Dann ist  $\lambda^k$  auch Lösung des folgenden Problems:

$$\begin{aligned} \min_{\lambda} \quad & \frac{\gamma_k}{2} \left\| \sum_{j \in J_k} \lambda_j g^j \right\|^2 \\ \text{u.d.N.} \quad & \sum_{j \in J_k} \lambda_j = 1, \lambda_j \geq 0, j \in J_k, \sum_{j \in J_k} \lambda_j \alpha_j^k \leq \varepsilon_k \end{aligned} \quad (6)$$

mit

$$\varepsilon_k = \sum_{j \in J_k} \lambda_j^k \alpha_j^k. \quad (7)$$

d) Sei  $\lambda^k$  eine Lösung von (3) und  $s^k = -\gamma_k \sum_{j \in J_k} \lambda_j^k g^j =: -\gamma_k v^k$ . Dann gilt

$$v^k = P_{G_{\varepsilon_k}^k}(0),$$

wobei  $\varepsilon_k = \sum_{j \in J_k} \lambda_j^k \alpha_j^k$  und

$$G_{\varepsilon}^k = \left\{ \sum_{j \in J_k} \lambda_j g^j : \sum_{j \in J_k} \lambda_j \alpha_j^k \leq \varepsilon, \sum_{j \in J_k} \lambda_j = 1, \lambda_j \geq 0, j \in J_k \right\}. \quad (8)$$

### G11. Lagrange-Duales nichtlinearer Optimierungsprobleme

Betrachte das nichtlineare Optimierungsproblem

$$\min f(x) \quad \text{u.d. NB} \quad c(x) \leq 0. \quad (\text{NLP})$$

Die zugehörige Lagrange-Funktion ist

$$L(x, \lambda) = f(x) + \lambda^T c(x).$$

Das *Lagrange-Duale Problem* zu (NLP) ist

$$\max_{\lambda} d(\lambda) \quad \text{u.d. NB} \quad \lambda \geq 0. \quad (\text{DP})$$

mit  $d(\lambda) = \inf_{x \in \mathbb{R}^n} L(x, \lambda)$ . Die Probleme (NLP) und (DP) haben denselben Optimalwert genau dann, wenn die Lagrange-Funktion einen Sattelpunkt besitzt.

- Zeigen Sie, dass (DP) als konvexes nichtglattes Optimierungsproblem schreiben kann.
- Wie kann man einen Subgradienten für Ihr Problem aus a) berechnen?

### G12. Bundle-Verfahren

Wenden Sie das Bundle-Verfahren mit  $\eta = 0, 1$ ,  $\gamma = 1$  und  $\varepsilon = 0$  auf das folgende Problem an und veranschaulichen Sie sich den Lauf grafisch:

$$\min f(x) \quad \text{u.d.N.} \quad 0 \leq x \leq 8$$

mit  $f(x) = \max\{4 - x, 3 - x/2, x - 3\}$  und  $x^0 = 0$ .

\*\*\*\*\* Frohe Weihnachten und Alles Gute für das Neue Jahr! \*\*\*\*\*