

Lösungsvorschlag zur Vorlesung Nichtglatte Optimierung und Anwendungen

G1. Versagen der exakten Schrittweitsuche bei nichtglatten Problemen

a): Es gilt

$$\nabla f_1(x) = \begin{pmatrix} 2x_1 \\ 4x_2 \end{pmatrix}.$$

Die Richtung des steilsten Abstiegs in x ist $s = -\nabla f_1(x)$.

$$\frac{d}{dt} f_1(x+ts) = -\nabla f_1(x+ts)^T s = \begin{pmatrix} 2(x_1 - 2tx_1) \\ 4(x_2 - 4tx_2) \end{pmatrix}^T \begin{pmatrix} -2x_1 \\ -4x_2 \end{pmatrix} = -4x_1^2 - 16x_2^2 + t(8x_1^2 + 64x_2^2).$$

Die optimale Schrittweite ist daher

$$\sigma = \frac{x_1^2 + 4x_2^2}{2x_1^2 + 16x_2^2}. \quad (1)$$

Starten wir das Verfahren des steilsten Abstiegs in $x^0 = (2, 1)^T$, so gilt

$$s^0 = \begin{pmatrix} -4 \\ -4 \end{pmatrix}, \quad \sigma_0 = \frac{8}{24} = \frac{1}{3}, \quad x^1 = \begin{pmatrix} 2 \\ 1 \end{pmatrix} + \frac{1}{3} \begin{pmatrix} -4 \\ -4 \end{pmatrix} = \frac{1}{3} \begin{pmatrix} 2 \\ -1 \end{pmatrix},$$
$$s^1 = \frac{1}{3} \begin{pmatrix} -4 \\ 4 \end{pmatrix}, \quad \sigma_1 = \frac{8}{24} = \frac{1}{3}, \quad x^2 = \frac{1}{3} \begin{pmatrix} 2 \\ -1 \end{pmatrix} + \frac{1}{9} \begin{pmatrix} -4 \\ 4 \end{pmatrix} = \frac{1}{9} \begin{pmatrix} 2 \\ 1 \end{pmatrix} = \frac{1}{9} x^0.$$

Wir zeigen durch vollständige Induktion, dass

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

Für x^0, x^1, x^2 ist die Formel nachgewiesen.

Induktionsschritt $k \rightarrow k + 1$:

Wir haben nach Induktionsannahme $x^{2k+1} = 9^{-k} x^1$ und damit (∇f ist linear in x)

$$\nabla f(x^{2k+1}) = 9^{-k} \nabla f(x^1)$$

und wegen (1)

$$\sigma_{2k+1} = \frac{9^{-2k}}{9^{-2k}} \sigma_1 = \sigma_1 = \frac{1}{3}.$$

Dies ergibt

$$x^{2k+2} = x^{2k+1} - \sigma_{2k+1} \nabla f(x^{2k+1}) = 9^{-k} (x^1 - \sigma_1 \nabla f(x^1)) = 9^{-k} x^2 = 9^{-(k+1)} x^0.$$




Abbildung 1: Niveaulinien von f_1 und die Iterierten

Völlig analog gilt nun

$$x^{2k+3} = x^{2k+2} - \sigma_{2k+2} \nabla f(x^{2k+2}) = 9^{-(k+1)}(x^0 - \sigma_0 \nabla f(x^0)) = 9^{-(k+1)}x^1.$$

Insbesondere also $x^k \rightarrow 0$. Weiter gilt

$$\nabla f_1(x^{2k}) = 9^{-k} \begin{pmatrix} 4 \\ 4 \end{pmatrix} \rightarrow 0, \quad \nabla f_1(x^{2k+1}) = \frac{1}{3} 9^{-k} \begin{pmatrix} 4 \\ -4 \end{pmatrix} \rightarrow 0$$

Abb. 1 zeigt die Niveaulinien von f_1 und die Iterierten:

b): Sei nun $f_2(x) = \sqrt{f_1(x)}$. Für $x \neq 0$ ist $f_1(x) \neq 0$ und daher f_2 stetig differenzierbar bei x mit

$$\nabla f_2(x) = \frac{1}{2f_2(x)} \nabla f_1(x),$$

d.h. die Richtung des steilsten Abstiegs von f_2 stimmt in allen $x \neq 0$ mit denen von f_1 (bis auf die Länge) überein. Minimierung von f_2 auf $\{x - \sigma \nabla f_2(x) : \sigma \geq 0\}$ liefert denselben Minimalpunkt wie die Minimierung von f_1 auf $\{x - \sigma \nabla f_1(x) : \sigma \geq 0\}$, da $\sqrt{\cdot}$ streng monoton wachsend auf $[0, \infty)$ ist. Das Verfahren des steilsten Abstiegs, gestartet in $x^0 = (2, 1)^T$, erzeugt daher für f_2 dieselbe Punktefolge wie für f_1 .

Da $(0, 0)$ das Minimum von f_2 ist, konvergiert also das Verfahren.

c) Man prüft leicht, dass f_3 stetig und konvex ist.

Das Verfahren verhält sich genau wie für f_2 : Vollständige Induktion: Natürlich stimmt x^0 überein. Induktionsannahme: x^k stimmt überein. In x^k gilt $f_3(x^k) = f_2(x^k)$ und $\nabla f_3(x^k) = \nabla f_2(x^k)$. Auf dem Strahl $S_k = \{x^k - \sigma \nabla f_3(x^k) : \sigma \geq 0\}$ stimmen f_3 und f_2 auf der Strecke von x^k bis x^{k+1} und ein Stück darüber hinaus überein. Die konvexe Funktion f_3 hat also wie f_2 auf S_k in x^{k+1} ein globales Minimum und dieses ist wie bei f_2 eindeutig. Also stimmt auch die nächste Iterierte x^{k+1} überein.




Abbildung 2: Niveaulinien von f_3 und die Iterierten

Abb. 2 zeigt die Niveaulinien von f_3 und die Iterierten:

d): Das Beispiel zeigt, dass sich das Verfahren nur im glatten Teil aufhalt und gegen den falschen Punkt konvergiert. Eine Erweiterung des Verfahrens auf nichtglatte Funktionen wurde aber das Verhalten im glatten Teil nicht andern.

G2.

zu a): Es gilt $g \in \partial f(0)$ genau dann, wenn

$$f(y) \geq f(0) + g(y - 0) \quad \forall y \in \mathbb{R}.$$

Nach Definition von f ergibt dies

$$y \geq g y \quad \forall y \geq 0, \quad y^2 \geq g y \quad \forall y < 0$$

und dies ist aquivalent zu

$$g \leq 1 \quad \text{und} \quad g \geq 0,$$

also $g \in [0, 1]$.

zu b): Es gilt $g \in \partial f(0)$ genau dann, wenn

$$f(y) \geq f(0) + g^T(y - 0) \quad \forall y \in \mathbb{R}^n.$$

Wegen $f(x) = \|x\| = \sqrt{x^T x}$ ergibt sich

$$\|y\| \geq g^T y \quad \forall y \in \mathbb{R}^n. \quad (2)$$

Nach der Cauchy-Schwarzschen Ungleichung ist $g^T y \leq \|g\| \|y\|$ fur alle $y \in \mathbb{R}^n$ und diese Ungleichung ist scharf fur $y = g$. Daher ist (2) nur erfullt fur g mit $\|g\| \leq 1$, also $\partial f(0) = \{g \in \mathbb{R}^n : \|g\| \leq 1\}$.

G3. Epigraph und Subgradienten

zu a):

Seien X und f konvex.

Für $(x_i^T, \alpha_i)^T \in \text{epi}(f)$, $i = 0, 1$, $\lambda \in [0, 1]$ sowie $x_\lambda = (1 - \lambda)x_0 + \lambda x_1$ und $\alpha_\lambda = (1 - \lambda)\alpha_0 + \lambda\alpha_1$ ergibt sich

$$x_\lambda \in X \quad (\text{da } X \text{ konvex ist}), \alpha_\lambda \geq (1 - \lambda)f(x_0) + \lambda f(x_1) \geq f(x_\lambda).$$

Damit gilt $(x_\lambda^T, \alpha_\lambda)^T \in \text{epi}(f)$.

Sei nun $\text{epi}(f)$ konvex.

Für $x_i \in X$, $i = 0, 1$, $\lambda \in [0, 1]$ und $\alpha_i = f(x_i)$ gilt dann mit $x_\lambda, \alpha_\lambda$ wie oben:

$$\begin{pmatrix} x_\lambda \\ \alpha_\lambda \end{pmatrix} \in \text{epi}(f),$$

also

$$x_\lambda \in X, \quad f(x_\lambda) \leq \alpha_\lambda = (1 - \lambda)f(x_0) + \lambda f(x_1).$$

Somit sind X und f konvex.

zu b):

Sei $g \in \partial f(x)$. Dann gilt für alle $(y^T, \alpha)^T \in \text{epi}(f)$

$$(g^T, -1) \left(\begin{pmatrix} y \\ \alpha \end{pmatrix} - \begin{pmatrix} x \\ f(x) \end{pmatrix} \right) = g^T(y - x) - \alpha + f(x) \leq g^T(y - x) - f(y) + f(x) \leq 0.$$

Es gelte umgekehrt (*). Dann haben wir $(y^T, f(y))^T \in \text{epi}(f)$ für alle $y \in X$ und somit

$$0 \geq (g^T, -1) \left(\begin{pmatrix} y \\ f(y) \end{pmatrix} - \begin{pmatrix} x \\ f(x) \end{pmatrix} \right) = g^T(y - x) - f(y) + f(x),$$

d.h. $g \in \partial f(x)$.

zu c):

Aus (*) und der Tatsache, dass die letzte Koordinate in der Normale von H negativ ist, folgt, dass der Epigraph von f auf oder oberhalb der Ebene H liegt (die $n + 1$ -te Koordinatenachse sei nach oben angetragen). Des weiteren liegt der Punkt $(x^T, f(x))^T$ auf H . Es ist daher gerechtfertigt, zu sagen, dass H den Epigraphen in $(x^T, f(x))^T$ von unten stützt.