

Konvexe Analysis - Ein Beispiel

Entfernen von Bildrauschen & -störungen

Def. Bild $x \Leftrightarrow x \in (C_c^1 \cap BV)(\mathbb{R}^2, \mathbb{R}_{\geq 0})$
bzw. $x \in X$ Hilbertraum
und: $\Omega := \text{supp } x$

Problem:

geb. gestörtes Bild x_0

ges. Ursprungbild x_*

Ausatz: $x_* = \min_{x \in X} I(x) + \frac{1}{2\lambda} \|x - x_0\|^2$
Regularisierer Ähnlichkeitskriterium


(auswerten: $\min_{x \in X} I(x) = 0$; A)

I soll Glattheit der Lösung sicherstellen.

Möglichkeiten: (falls x diff'bar)

$I(x) = \int \|\nabla x\|^2 dt$ (Squared Gradient)

oder $I(x) = \int_{\Omega} \|\nabla x\| dt$ (Totale Variation)



$\lambda = 0.25$




$\lambda = 0.5$



$\lambda = 1.0$

$\|\nabla x\|$



$\lambda = 2.5$



$\lambda = 5.0$



$\lambda = 10.0$

$\|\nabla x\|^2$

Die "richtige" Def. der totalen Variation lautet

$$I_{TV}(x) = \sup_{\zeta} \left\{ \int_{\Omega} x(t) \operatorname{div} \zeta(t) dt : \zeta \in C_c^1(\Omega, \mathbb{R}^2), \|\zeta\|_{\infty} \leq 1 \right\}$$


Diese Def. ist äquivalent zu $I_{TV}(x) = \int_{\Omega} \|\nabla x\| dt$, wenn x diff'bar ist:

$$\begin{aligned} \int_{\Omega} x \operatorname{div} \zeta dt &= \int_{\partial \Omega} x \zeta \cdot \nu_{\epsilon} dt - \int_{\Omega} \nabla x \cdot \zeta dt \\ &= 0, \quad \leq \|\nabla x\| \|\zeta\| \leq \|\nabla x\| \\ &\quad \text{nach Def. von } \Omega \quad \uparrow \quad \uparrow \\ &\quad \text{Gleichheit: } \nabla x \parallel \zeta \quad \|\zeta\| = 1 \\ &\quad \text{insgesamt: } \zeta = - \frac{\nabla x}{\|\nabla x\|} \end{aligned}$$

Was hat das mit konvexer Analysis zu tun?

$$I_{TV}(x) + \frac{1}{2\lambda} \|x - x_0\|^2 \text{ ist konvex.}$$

Def: Eine Funktion $f: X \rightarrow \mathbb{R}$ ist konvex gdw. epi f konvex ist.
 $\text{epi } f = \{ (x, y) \in X \times \mathbb{R} : f(x) \leq y \}$



Satz: $f: X \rightarrow \mathbb{R}$ konvex
 $\Leftrightarrow \forall a, b \in \text{dom } f \ \forall \alpha, \beta \geq 0, \alpha + \beta = 1:$
 $f(\alpha a + \beta b) \leq \alpha f(a) + \beta f(b)$
Bew: $\Leftrightarrow \forall a, b \in \text{dom } f: [(\alpha a), (\beta b)] \subseteq \text{epi } f$

Satz: f, g konvexe Fkt $\rightarrow f+g$ auch konvex

Bew: linear (Ungl. aufaddieren)

Satz: f_y Schar konvexer Funktionen, dann:
 $f(x) := \sup_y f_y(x)$ ist konvex

Bew: $\forall a, b \in \text{dom } f \ \forall \alpha, \beta \geq 0, \alpha + \beta = 1:$
 $f(\alpha a + \beta b) = \sup_y f_y(\alpha a + \beta b) \leq \sup_y \alpha f_y(a) + \beta f_y(b)$
 $\leq \alpha \sup_y f_y(a) + \beta \sup_y f_y(b) = \alpha f(a) + \beta f(b)$ *

Fenchel Konjugiertes

f sei Fkt mit dom $f \subseteq X$, X reflexiver Banachraum
 dualen X^* und $\langle x^*, x \rangle = \langle x, x^* \rangle = x^*(x) \forall x \in X, x^* \in X^*$

Def: Das Fenchel Konjugierte f^* von f ist:

$$f^*: X^* \rightarrow \mathbb{R}, x^* \mapsto \sup_{x \in X} \langle x^*, x \rangle - f(x)$$

Satz: In beliebigem f ist f^* immer konvex.

Bew: $\langle x^*, x \rangle - f(x)$ ist affine Fkt, also auch konvex
 $\Rightarrow \sup_{x \in X}$ ist auch konvex. #


Satz: (Young-Ungl.) *beliebig naher wg. sup-Def!*

$$\langle x^*, x \rangle \leq f^*(x^*) + f(x) \quad \forall x \in X, x^* \in X^*$$

Bew: $\langle x^*, x \rangle - f(x) \leq \sup_{p \in X} \langle x^*, p \rangle - f(p) = f^*(x^*)$

Intuition für f^* :

$$h_{x^*, c}(x) := \langle x^*, x \rangle - c \Leftrightarrow \begin{pmatrix} x^* \\ -1 \end{pmatrix}^T \begin{pmatrix} x \\ h_{x^*, c}(x) \end{pmatrix} = c$$




Young: $h_{x^*, f^*(x^*)}(x) = \langle x^*, x \rangle - f^*(x^*) \leq f(x) \quad \forall x \in X$

Hyperebene mit Normalen x^* , die an $\text{epi } f$ anliegt.

Def: $M \subseteq X$, dann Indikatorfkt:

$$c_M(x) = \begin{cases} 0 & : x \in M \\ +\infty & : x \notin M \end{cases}$$



Auswertung:

$$c_K^*(x^*) = \sup_{x \in X} \langle x^*, x \rangle - c_K(x) = \sup_{x \in K} \langle x^*, x \rangle =: \sigma_K(x^*)$$

Folgerung:

$$I_{TV}(x) = \sup_{x^* \in K = \text{Ball}} \langle x^*, x \rangle = c_K^*(x) = \sigma_K(x)$$

Stützfunktion

$\exists \zeta \in C_c^1(\Omega, \mathbb{R}^2), \|\zeta\|_\infty = 1$


Subdifferential

Def: $f: X \rightarrow \mathbb{R}$ (lower), dann ist das Subdifferential:

$$\partial f(x) := \{x^* \in X^*, \forall p \in X: f(p) \geq f(x) + \langle x^*, p-x \rangle\}$$

$$= \{x^* \in X^*: \forall p \in X: \underbrace{\langle x^*, x \rangle - f(x)} \geq \underbrace{\langle x^*, p \rangle - f(p)}\}$$

Intuition:



$$\begin{pmatrix} x^* \\ -1 \end{pmatrix}^T \begin{pmatrix} x \\ f(x) \end{pmatrix} \geq \begin{pmatrix} x^* \\ -1 \end{pmatrix}^T \begin{pmatrix} p \\ f(p) \end{pmatrix}$$

Also: $x^* \in \partial f(x) \Rightarrow \text{epi } f \subseteq H \stackrel{\subseteq}{=} H_{x^*, \langle x^*, x \rangle - f(x)}$

$$H_{a^*, c} \stackrel{\subseteq}{=} \{(x, y) \in X \times \mathbb{R}: \langle a^*, x \rangle - y \leq c\}$$

Lemma: $f: X \rightarrow \mathbb{R}$ lower und Gâteaux-Ableitung $f'(x) \in X^*$

existiert bei $x \in X$, dann: $\langle f'(x), h \rangle = \lim_{t \rightarrow 0} \frac{f(x+th) - f(x)}{t}$

und damit: $\langle f'(x), h \rangle \leq \lim_{t > 0} \frac{f(x+th) - f(x)}{t}$

Bew:

$$\langle f'(x), h \rangle = \lim_{\epsilon \rightarrow 0} \underbrace{\frac{f(x+th) - f(x)}{\epsilon}}_{\text{monoton wachsend, denn:}} = \lim_{\epsilon > 0} \frac{f(x+th) - f(x)}{\epsilon}$$

monoton wachsend, denn:

$$\forall 0 < s < t: \frac{f(x+sh) - f(x)}{s} \leq \frac{f(x+th) - f(x)}{t}$$

$$\Leftrightarrow f(x+sh) \leq f(x) - \frac{s}{t} f(x) + \frac{s}{t} f(x+th)$$

$$= \frac{t-s}{t} f(x) + \frac{s}{t} f(x+th) \quad \frac{t-s}{t} f(x) \quad \text{mit } \frac{t-s}{t} + \frac{s}{t} = 1$$

$$\Leftrightarrow f \text{ lower} \quad \#$$

Satz: $f: X \rightarrow \mathbb{R}$, lower und Gâteaux-Ableitung $f'(x)$ existiert

an x , dann: $\partial f(x) = \{f'(x)\}$

Bew: \supseteq : Lemma $\Rightarrow \langle f'(x), p-x \rangle \leq f(p) - f(x) \forall p \in X$

$$\Leftrightarrow f'(x) \in \partial f(x)$$

\subseteq : $x^* \in \partial f(x) \Rightarrow \forall p \in X: \langle x^*, p-x \rangle \leq f(p) - f(x)$

$$\Leftrightarrow \forall h \in X \forall \lambda > 0: \lambda \langle x^*, h \rangle = \langle x^*, \lambda h \rangle \leq f(x+\lambda h) - f(x)$$

$$\Leftrightarrow \langle x^*, h \rangle \leq \frac{f(x+\lambda h) - f(x)}{\lambda}$$

$$\Rightarrow \forall h \in X: \langle x^*, h \rangle \leq \langle f'(x), h \rangle \stackrel{\lambda}{\Rightarrow} x^* = f'(x)$$

$$-h \text{ and } h \Rightarrow \langle x^*, h \rangle = \langle f'(x), h \rangle$$

Satz: $\partial(f+g)(x) \supseteq \partial f(x) + \partial g(x)$

(mit Gleichheit, wenn $\text{dom } f \cap \text{dom } g \neq \emptyset$)

Bew: \supseteq : Def. aufaddieren, \subseteq : nicht hier

Satz: f hat globales Minimum in \bar{x} , genau dann wenn $0 \in \partial f(\bar{x})$

Bew: $\forall x \in X: f(x) \geq f(\bar{x}) = f(\bar{x}) + \langle 0, x - \bar{x} \rangle \Leftrightarrow 0 \in \partial f(\bar{x})$

Lemma: $f: X \rightarrow \mathbb{R}$ konvex und stetig in x , dann $\partial f(x) \neq \emptyset \forall x \in X$.

Bew: mit Trennungssätzen (+ pathologische Fälle)

Satz (Young Uagl. - Gleichheit und Biconjugation):

Sei f konvex und stetig. Es gilt $\forall x \in X, x^* \in X^*$:

$$x^* \in \partial f(x) \Leftrightarrow f(x) + f^*(x^*) = \langle x^*, x \rangle = f^{**}(x) + f^*(x^*) \Leftrightarrow x \in \partial f^*(x^*)$$

Insb: $\forall f$ konvex: $f^{**} = f$ und $x^* \in \partial f(x) \Leftrightarrow x \in \partial f^*(x^*)$.

Vorbereitung:

$$f^{**}: X \rightarrow \mathbb{R}, x \mapsto \sup_{x^* \in X^*} \langle x^*, x \rangle - f^*(x^*)$$

Young-Uagl.: $\langle x^*, x \rangle \leq f(x) + f^*(x^*)$

und analog: $\langle x^*, x \rangle \leq f^{**}(x) + f^*(x^*)$

Bew:

$$x^* \in \partial f(x) \Leftrightarrow \forall p \in X: \langle x^*, x \rangle - f(x) \geq \langle x^*, p \rangle - f(p)$$

$$\Leftrightarrow \langle x^*, x \rangle - f(x) \geq \sup_{p \in X} \langle x^*, p \rangle - f(p) = f^*(x^*)$$

$$\Leftrightarrow \langle x^*, x \rangle \geq f(x) + f^*(x^*)$$

mit Young folgt \subseteq .

Analog zeigt man: $x \in \partial f^*(x^*) \Leftrightarrow \langle x^*, x \rangle = f^{**}(x) + f^*(x^*)$

$$f^{**}(x) = \sup_{x^* \in X^*} \langle x^*, x \rangle - f^*(x^*) \leq f(x)$$

Young: $\langle x^*, x \rangle - f^*(x^*) \leq f(x)$

$$f \text{ konvex} \Rightarrow \exists x^* \in \partial f(x) \neq \emptyset: \langle x^*, x \rangle - f^*(x^*) = f(x)$$


$$\Rightarrow f^{**}(x) = \sup_{x^* \in X^*} \langle x^*, x \rangle - f^*(x^*) = f(x) \Rightarrow f^{**}(x) = f(x) \quad \#$$

Satz (Normalkegel): $N_C(x)$

C konvexe Menge $\subseteq X$, dann $\partial C(x) := \begin{cases} \{x^* \in X^*: \forall p \in C: \langle x^*, p-x \rangle \leq 0\} & x \in C \\ \emptyset & x \notin C \end{cases}$

Bew: $x \notin C: \partial C(x) = \emptyset$ klar. Sei $x^* \in \partial C(x)$:

$$x \in C: \forall p \notin C: +\infty \geq 0 + \langle x^*, p-x \rangle \wedge \forall p \in C: 0 \geq 0 + \langle x^*, p-x \rangle \quad \#$$



Damit können wir die Bearbeitung der Fallstudie fortsetzen:

$$\bar{x} \text{ ist Lsg von } \min_{x \in X} \underbrace{I_{TV}(x) + \frac{1}{2\lambda} \|x - x_0\|}_{\text{Konvexer Term}}$$

$$\Leftrightarrow 0 \in \partial \left(I_{TV}(\cdot) + \frac{1}{2\lambda} \|\cdot - x_0\|^2 \right) (\bar{x})$$

$$\Leftrightarrow 0 \in \partial I_{TV}(\bar{x}) + \underbrace{\partial \left(\frac{1}{2\lambda} \|\cdot - x_0\|^2 \right)}_{\text{diff'barer Term: } \partial \cdot = \left\{ \frac{1}{\lambda} (x - x_0) \right\}} (\bar{x})$$

$$\Leftrightarrow 0 \in \partial I_{TV}(\bar{x}) + \frac{1}{\lambda} (\bar{x} - x_0)$$

$$\Leftrightarrow \frac{x_0 - \bar{x}}{\lambda} \in \partial I_{TV}(\bar{x}) \Leftrightarrow \frac{x_0 - \bar{x}}{\lambda} \in \partial c_{\lambda}^{\#}(\bar{x})$$

$$\Leftrightarrow \bar{x} \in \partial c_{\lambda} \left(\frac{x_0 - \bar{x}}{\lambda} \right) \Leftrightarrow 0 \in -\bar{x} + \partial c_{\lambda} \left(\frac{x_0 - \bar{x}}{\lambda} \right)$$

$$\Leftrightarrow \frac{x_0}{\lambda} \in \underbrace{\frac{x_0 - \bar{x}}{\lambda} + \partial c_{\lambda} \left(\frac{x_0 - \bar{x}}{\lambda} \right)}_{=: T} = \left(\text{id} + \partial c_{\lambda} \right) \left(\frac{x_0 - \bar{x}}{\lambda} \right)$$


$$\Leftrightarrow \frac{x_0 - \bar{x}}{\lambda} \in T^{-1} \left(\frac{x_0}{\lambda} \right) \Leftrightarrow \bar{x} \in x_0 - \lambda T^{-1} \left(\frac{x_0}{\lambda} \right)$$

$T = \text{id} + N_{\lambda} \Rightarrow T^{-1} = \Pi_{\lambda}$: orthogonale Projektion auf \mathcal{K}

$$\Rightarrow \bar{x} \in x_0 - \lambda \Pi_{\lambda} \left(\frac{x_0}{\lambda} \right)$$

$$T \circ T^{-1} = (\text{id} + N_{\lambda}) \circ \Pi_{\lambda} \Rightarrow T \circ T^{-1}(x) \supseteq x$$

$$T^{-1} \circ T = \Pi_{\lambda} \circ (\text{id} + N_{\lambda}) \Rightarrow T^{-1} \circ T(x) = x$$



Ausdruck ($\lambda=1$):

$$\bar{x} \in x_0 - \Pi_{\mathcal{K}}(x_0)$$

\mathcal{K} beschreibt die Menge aller Störungen.

$\Pi_{\mathcal{K}}(x_0) \in \mathcal{K}$ eliminiert die Störung aus x_0 und \bar{x} ist das

$$\text{störungsfreie Bild: } \Pi_{\mathcal{K}} \circ (\text{id} - \Pi_{\mathcal{K}}) = \Pi_{\mathcal{K}} - \Pi_{\mathcal{K}} \circ \Pi_{\mathcal{K}} = \Pi_{\mathcal{K}} - \Pi_{\mathcal{K}} = 0$$

Fragen

Friday, June 10, 2011

4:57 PM

- Was heißt support function auf Deutsch?
- Beweis für Subdiff $\neq \emptyset$ bei konvexen Funktionen


Anmerkungen:

- Darstellungssatz von Riesz eindeutig $H \rightarrow H^*$
- \Rightarrow jeder Hilbertraum ist reflexiv

Konvexe Analysis

Ein Beispiel

Totale Variation vs Squared Gradient




$\lambda = 0.25$




$\lambda = 0.5$



$\lambda = 1.0$



$\lambda = 2.5$




$\lambda = 5.0$




$\lambda = 10.0$

Konvexe Funktionen, Epigraph & analytische Konvexität




Hyperebenenfunktion

$$L_{x^*, c}(x) := \langle x^*, x \rangle - c \Leftrightarrow \begin{pmatrix} x^* \\ -1 \end{pmatrix}^T \begin{pmatrix} x \\ L_{x^*, c}(x) \end{pmatrix} = c$$



Fenchel Konjugiertes


Intuition für f^* :



Young:
$$h_{x^*, f^*(x^*)}(x) = \langle x^*, x \rangle - f^*(x^*) \leq f(x) \quad \forall x \in X$$

Gerade mit Normen x^* , die an $\text{epi } f$ aufliegt.


Indikatorfunktion



$$I_{TV}(x) = \sup \left\{ \int_{\Omega} x(t) \operatorname{div} \vec{z}(t) dt : \vec{z} \in C_c^1(\Omega, \mathbb{R}^2), \|\vec{z}\|_{\infty} \leq 1 \right\}$$

Subdifferential

Intuition:



Benutzte Sätze und Folgerungen

Satz: $\partial(f+g)(x) \supseteq \partial f(x) + \partial g(x)$

Satz: f hat globales Minimum in \bar{x} , genau dann wenn $0 \in \partial f(\bar{x})$

Satz (Young Ungle. - Gleichheit und Biconjugation):

Es gilt: $\forall x \in X, x^* \in X^*$:

$$x^* \in \partial f(x) \Leftrightarrow f(x) + f^*(x^*) = \langle x^*, x \rangle = f^{**}(x) + f^*(x^*) \Leftrightarrow x \in \partial f^*(x^*)$$

Insb: $\forall f$ konvex: $f^{**} = f$ und $x^* \in \partial f(x) \Leftrightarrow x \in \partial f^*(x^*)$.

Satz: $f: X \rightarrow \mathbb{R}$, konvex und Gâteaux-Ableitung $f'(x)$ existiert an x ,
dann: $\partial f(x) = \{f'(x)\}$

Folgerung:

$$I_{\text{rv}}(x) = \sup_{x^* \in K = \text{Ein} \{z \in C_c^1(\Omega, \mathbb{R}^2), \|z\|_{\infty} \leq 1\}} \langle x^*, x \rangle = c_K^*(x)$$

Literatur

- R. T. Rockafellar, Convex analysis, Princeton University Press, Princeton, NJ, 1970. Reprint: 1997
- Variational Methods and Convex Optimization in Computer Vision, Lecture by Dr Goldlücke, <http://www.cremers.in.tum.de/index.php?nav=teaching&target=ss2010/vmcv2010.html>
- Martin Brokate, Konvexe Analysis, Skript SS2008
- Antonin Chambolle, An Algorithm for Total Variation Minimization and Applications, Journal of Mathematical Imaging and Vision 20: 89–97, 2004
- A. Chambolle, V. Caselles, M. Novag, D. Cremers and T. Pock, An introduction to Total Variation for Image Analysis, Theoretical Foundations and Numerical Methods for Sparse Recovery, De Gruyter, 2010
- Jonathan M. Borwein, Jon D. Vanderwerff, Convex functions: constructions, characterizations and counterexamples, Cambridge University Press, 2010