

Optimierung

Einführung in Optimierungsprobleme

- Minima, Maxima, zulässige Mengen, äquivalente Umformulierungen

Kriterien für Optimalität

- differenzierbarer Fall; hinreichende & notwendige Bedingung

Dualität

- Lagrange Funktion, duales Problem

Konvexe Analysis und Optimierung

- konvexe Mengen, konvexe Funktionen, Optimalitätskriterien

Optimierungsalgorithmen

- Simplex-Methode
- primal-duale Methoden
- glatte Optimierung ohne Nebenbedingungen
- Optimierung mit Nebenbedingungen

Einleitung: Idee und Motivation

Optimierungsproblem

Beim Angeden von Optimierungsproblemen soll „min“ nicht implizieren, dass das Minimum angenommen wird, sondern es steht für „minimiere über x “; Ansonsten bedeutet „min“ immer im Gegensatz zu „inf“, dass das Minimum angenommen wird.

$$\min_x f(x), \quad x \in \mathbb{R}^n, \quad \text{sodass} \quad c_E(x) = b_E \quad \text{und} \quad c_I(x) \leq b_I$$

x

$$f: \mathbb{R}^n \rightarrow \mathbb{R}$$

$$c_E: \mathbb{R}^n \rightarrow \mathbb{R}^p$$

$$c_I: \mathbb{R}^n \rightarrow \mathbb{R}^m$$

$$b_E \in \mathbb{R}^p$$

$$b_I \in \mathbb{R}^m$$

Optimierungsvariable

Zielfunktion

Gleichungs-Nebenbedingungs-Funktion

Ungleichungs-Nebenbedingungs-Funktion

$c_I(x) \leq b_I$ ist komponentenweise gemeint

Typen von Optimierungsproblemen

- lineares Programm : f, C_E, C_I linear / affin
 - nichtlineares Programm : f, C_E, C_I nichtlinear
 - konvexes Optimierungsproblem : f, C_E linear, C_I konvex (komp.-weise)
- $g: \mathbb{R}^n \rightarrow \mathbb{R}^m$ linear $\Leftrightarrow g(ax + by) = ag(x) + bg(y) \forall x, y \in \mathbb{R}^n, a, b \in \mathbb{R}$
- $g: \mathbb{R}^n \rightarrow \mathbb{R}$ konvex $\Leftrightarrow g(ax + (1-a)y) \leq ag(x) + (1-a)g(y) \forall x, y \in \mathbb{R}^n, a \in [0, 1]$

Anderer Typen (vorerst nicht in dieser Vorlesung betrachtet) :

- diskretes Optimierungsproblem : f, C_E, C_I definiert auf \mathbb{Z}^n
- kombinatorisches Optimierungsproblem : f, C_E, C_I definiert auf $\{1, \dots, k\}^n$
- Optimierung in Banachräumen : f, C_E, C_I def. auf Banach-R.
- Optimierung auf Mannigfaltigkeiten : f, C_E, C_I def. auf Riemann. Mfkt

Einleitung: Idee und Motivation

Anwendungen

Portfolio-Optimierung

- investiere optimal Geld in n Aktien; x_i = Investment in Aktie i
- Nebenbedingungen an Gesamtbudget, Positivität, ...
- Zielfunktion: Gesamtrisiko, Varianz des Einkommens, ...

Prozess- oder Produktoptimierung


- x_i = Produktionsmenge von Produkt i
- Nebenbedingungen durch begrenzte Ressourcen, Produktionskapazität, ...
- Zielfunktion: Profit

Daten-Fitting

- x = Modellparameter
- Nebenbedingungen: A-priori-Information (Positivität etc.)
- Zielfunktion: Diskrepanz zu gemessenen Daten

Beispiel 1: Optimierung eines Hochdruck-Gasnetzwerks

- Netzwerk



q_i = Flüsse
 p_i = Drücke
 d_i = Verbrauch

- Massen Nebenbedingung in Knoten 3:

im Allg.

$$Aq - d = 0$$

dünnbesetzte Matrix

$$q_1 + q_2 - q_3 - q_4 - d_3 = 0$$

lineare Nebenbedingung

- Leitungs Nebenbedingung in Leitung 1:

im Allg.

$$p^T B p + g(q) = 0$$

$$p_3^2 - p_1^2 + h_1 q_1^\alpha = 0$$

quadratische / nichtlineare NB

- Kompressor Nebenbedingung:


im Allg.

$$Cq + z \cdot h(p, q) \geq 0$$

$$q_6 - q_7 + z \cdot h(p_6, q_6, p_7, q_7) \geq 0$$

diskrete / nichtlineare NB

- Schranken $p \leq p_{max}$



$$z = \begin{cases} 0 & \text{falls Kompr. an} \\ 1 & \text{falls aus} \end{cases}$$

- Ziel: minimiere Versorgungskosten / Kompressorkosten etc.

Einleitung: Idee und Motivation

Beispiel 2: Least squares fitting

$$\min \|Ax - b\|_2^2 = \sum_{i=1}^k (a_i^T x - b_i)^2, \quad A \in \mathbb{R}^{k \times n}, \quad b \in \mathbb{R}^k, \quad k \geq n$$

Zeilen von A

Finde Minimum durch Gleichsetzen der Ableitung mit 0

$$0 = A^T(Ax - b)$$

falls $A^T A$ invertierbar, gilt

$$x = (A^T A)^{-1} A^T b$$

Pseudoinverse $A^+ = (A^T A)^{-1} A^T$

Klassische Bildverarbeitungsanwendung: Unschärfe korrektur

x = Vektor der Grauwerte der korrekten Bildpixel

b = gemessene (unschärfe) Grauwerte

A = Unschärfematrix

Unterschied zur Variationsrechnung

- beide Felder sind eng verwandt
- Variationsrechnung untersucht Existenz von Minimierern und ihre Eigenschaften, typischerweise mit "Energimethoden"
- Optimierung versucht Minimierer zu finden
und leitet Kriterien für Optimalität her;
Betonung von numerischen Methoden

Fahrplan der Vorlesung

- Einführung in Optimierungsprobleme

(Minima, Maxima, zulässige Mengen, äquivalente Umformulierungen)

- Kriterien für Optimalität

(differenzierbarer Fall; hinreichende und notwendige Bedingungen)

- Dualität

(Lagrange-Funktion, duales Problem)

- Konvexe Optimierung

(konvexe Mengen, konvexe Funktionen, Optimalitätskriterien)

- Optimierungsalgorithmen

- Simplex-Methode

- primal-duale Methoden

- glatte Optimierung ohne Nebenbedingungen

- Optimierung mit Nebenbedingungen

Grundlegende Notation

min $f(x)$ sodass $c_E(x) = 0, c_I(x) \leq 0$ (pt-weise) $(*)$

$(*)$ beschreibt das Problem dasjenige $x \in \mathbb{R}^n$ zu finden, das f unter allen x minimiert, die die NB erfüllen.

Notation: $\cdot f \equiv f_0 : \mathbb{R}^n \rightarrow \mathbb{R} \cup \{\infty\}$

$\cdot c_I \equiv (f_1, \dots, f_m)^T : \mathbb{R}^n \rightarrow (\mathbb{R} \cup \{\infty\})^m$

$\cdot c_E \equiv (h_1, \dots, h_p)^T : \mathbb{R}^n \rightarrow (\mathbb{R} \cup \{\infty\})^p$

Def: Gebiet von $f : \mathbb{R}^n \rightarrow \mathbb{R} \cup \{\infty\}$: $\text{dom} f = \{x \in \mathbb{R}^n \mid f(x) < \infty\}$

Def: Gebiet des Optimierungsproblems $(*)$: $\mathcal{D} = \bigcap_{i=0}^m \text{dom} f_i \cap \bigcap_{i=1}^p \text{dom} h_i$

Einleitung: Optimierungsprobleme

Grundlegende Begriffe

Def: $x \in \mathcal{D}$ ist zulässig, wenn alle Nebenbedingungen $f_1(x), \dots, f_m(x) \leq 0$ und $h_1(x) = \dots = h_p(x) = 0$ erfüllt sind

$(*)$ ist zulässig, falls es ein zulässiges $x \in \mathcal{D}$ gibt

Def: $p^* = \inf \{ f_0(x) \mid x \in \mathcal{D} \text{ is feasible} \}$ heißt optimaler Wert

falls $(*)$ nicht zulässig ist, setzen wir $p^* := \infty$

falls $\exists x_k \in \mathcal{D}$ zulässig mit $f_0(x_k) \xrightarrow{k \rightarrow \infty} -\infty$, dann $p^* = -\infty$;

$(*)$ heißt dann unbeschränkt nach unten

Def: x^* heißt (global) optimaler Punkt falls x^* zulässig ist und $f(x^*) = p^*$

$X_{\text{opt}} = \{ x \in \mathcal{D} \mid x \text{ ist optimaler Punkt} \}$

Ein zulässiger Punkt x mit $f_0(x) \leq p^* + \varepsilon$ heißt ε -suboptimal

Ein zulässiger Punkt x heißt lokal optimal wenn $\exists R > 0$ s. d.

$$f_0(x) = \inf \{ f_0(z) \mid z \in \mathcal{D} \text{ ist zulässig, } \|z - x\| \leq R \}$$

Ein lokal/global optimaler Punkt x heißt strikt optimal, wenn $\exists R > 0$ s. d. $f_0(x) < f_0(y)$ für alle zulässigen $y \in \mathcal{D}$ mit $y \neq x, \|x - y\| \leq R$

Einleitung: Optimierungsprobleme

Beispiele

Optimierungsprobleme auf $\mathbb{R}_{++} := \{x \in \mathbb{R} \mid x > 0\}$

1) $f_0(x) = \frac{1}{x}$ $p^* = 0$, $X_{opt} = \emptyset$

2) $f_0(x) = -\log x$ $p^* = -\infty$, $X_{opt} = \emptyset$

3) $f_0(x) = x \log x$ $p^* = -\frac{1}{e}$, $x^* = \frac{1}{e}$, $X_{opt} = \{\frac{1}{e}\}$

Thm: Sei (X) ein konvexes Optimierungsproblem, d.h.

f_0, \dots, f_m sind konvex, h_1, \dots, h_p affin.

Dann gilt $(x^*$ lokal optimal) \Leftrightarrow $(x^*$ global optimal).

Bew: HA

Equivalent optimization problems

- (*) ist die Standardform eines Optimierungsproblems. Die meisten Optimierungsprobleme können so ausgedrückt werden.

Bspw. kann eine Gleichungs-NB $g_i(x) = \tilde{g}_i(x)$ äquivalent umgeformt werden zu $h_i(x) := g_i(x) - \tilde{g}_i(x) = 0$ oder eine Ungleichung $\tilde{f}_i(x) \geq 0$ mit verkehrter Richtung ist äquivalent zu $f_i(x) := -\tilde{f}_i(x) \leq 0$.
- Man nennt zwei Optimierungsprobleme äquivalent, wenn sich die Lösung des einen jeweils leicht aus der Lösung des anderen berechnen lässt.

Bsp.
$$\begin{aligned} & \min \tilde{f}_0(x) = \alpha_0 f_0(x) \\ & \text{sodass} \quad \tilde{f}_i(x) = \alpha_i f_i(x) \leq 0, \tilde{h}_j(x) = \beta_j h_j(x) = 0, i=1, \dots, m, j=1, \dots, p \end{aligned}$$

ist für $\alpha_i > 0, \beta_j \neq 0$ äquivalent zu

$$\min f_0(x) \quad \text{sodass} \quad f_i(x) \leq 0, h_j(x) = 0$$

Einleitung: Umformung von Optimierungsproblemen

Einfache Umformungen I

$$(P_1) \quad \min f_0(x) \quad \text{s. d.} \quad f_i(x) \leq 0, \quad i=1, \dots, m, \quad h_i(x) = 0, \quad i=1, \dots, p$$

$$(P_2) \quad \min \tilde{f}_0(x) \quad \text{s. d.} \quad \tilde{f}_i(x) \leq 0, \quad i=1, \dots, m, \quad \tilde{h}_i(x) = 0, \quad i=1, \dots, p$$

- Substitution von Variablen

Sei $\phi: \mathbb{R}^n \rightarrow \mathbb{R}^n$ bijektiv,

$$\tilde{f}_i = f_i \circ \phi \quad (i=0, \dots, m), \quad \tilde{h}_i = h_i \circ \phi \quad (i=1, \dots, p)$$

Löst x (P_1) , so löst $\phi^{-1}(x)$ (P_2) und umgekehrt.

• Transformation von Ziel- und Nebenbedingungs-Funktionen

Sei $\psi_0: \mathbb{R} \rightarrow \mathbb{R}$ strikt monoton wachsend

$$\psi_1, \dots, \psi_m: \mathbb{R} \rightarrow \mathbb{R} \quad \text{mit} \quad \psi_i(u) \leq 0 \Leftrightarrow u \leq 0$$

$$\phi_1, \dots, \phi_p: \mathbb{R} \rightarrow \mathbb{R} \quad \text{mit} \quad \phi_i(u) = 0 \Leftrightarrow u = 0$$

$$\tilde{f}_i = \psi_i \circ f_i, \quad i=0, \dots, m, \quad \tilde{h}_i = \phi_i \circ h_i, \quad i=1, \dots, p$$

$$\text{Es gilt} \quad X_{\text{opt}}^{(P_1)} = X_{\text{opt}}^{(P_2)}$$

Einfache Umformungen II

(P_1) $\min f_0(x)$ s. d. $f_i(x) \leq 0, i=1, \dots, m, h_i(x)=0, i=1, \dots, p$

• Slack-Variablen s_i : Nutze $f_i(x) \leq 0 \Leftrightarrow \exists s_i \geq 0 : f_i(x) + s_i = 0$

(P_2) $\min f_0(x)$ s. d. $s_i \geq 0, i=1, \dots, m, f_i(x) + s_i = 0, h_j(x) = 0, i=1, \dots, m, j=1, \dots, p$

(x, s) zulässig (optimal) für $(P_2) \Leftrightarrow x$ zulässig (optimal) für (P_1) & $s_i = -f_i(x)$

• Eliminierung von Gleichungs-Nebenbedingungen

Wenn $C = \{x \in \mathbb{R}^n \mid h_1(x) = \dots = h_p(x) = 0\}$ parametrisiert werden kann durch $\phi : \mathbb{R}^k \rightarrow \mathbb{R}^n$, d. h. $x \in C \Leftrightarrow \exists z \in \mathbb{R}^k : x = \phi(z) \dots$

$$\tilde{f}_i = f_i \circ \phi, \quad i=0, \dots, m$$

(P_2) $\min \tilde{f}_0(x)$ s. d. $\tilde{f}_1(x), \dots, \tilde{f}_m(x) \leq 0$

$$x_{opt}^{(P_1)} = \phi(x_{opt}^{(P_2)})$$

Bsp : $h_1(x) = \dots = h_p(x) = 0 \Leftrightarrow Ax = b$ (lineare NB)

Setze $\phi(z) = Fz + x_0$ für $F \in \mathbb{R}^{n \times k}$ mit $\text{range } F = \ker A, x_0$ zulässig

Einleitung: Umformung von Optimierungsproblemen

Einfache Umformungen III

$$(P_1) \quad \min f_0(x) \quad \text{s. d.} \quad f_i(x) \leq 0, \quad i=1, \dots, m, \quad h_i(x) = 0, \quad i=1, \dots, p$$

• implizite Nebenbedingungen

$$\text{Sei} \quad F(x) = \begin{cases} f_0(x) & \text{falls } f_1(x), \dots, f_m(x) \leq 0, \quad h_1(x) = \dots = h_p(x) = 0 \\ \infty & \text{sonst} \end{cases}$$

$$(P_2) \quad \min F(x)$$

$$X_{\text{opt}}^{(P_2)} = X_{\text{opt}}^{(P_1)}$$

$$\text{Bsp.} \quad \min \begin{cases} \|x\|^2 & \text{falls } Ax = b \\ \infty & \text{sonst} \end{cases} \Leftrightarrow \min \|x\|^2 \quad \text{s. d.} \quad Ax = b$$

• Optimierung über eine Variable

$$\text{Sei} \quad x = (x_1, x_2) \in \mathbb{R}^{n_1} \times \mathbb{R}^{n_2}, \quad \tilde{F}(x_1) = \inf \left\{ f_0(x_1, x_2) \mid f_1(x_1, x_2), \dots, f_m(x_1, x_2) \leq 0, h_1(x_1, x_2) = \dots, h_p(x_1, x_2) = 0 \right\}$$

$$(P_2) \quad \min \tilde{F}(x_1)$$

$$x_1 \in X_{\text{opt}}^{(P_2)} \quad \Leftrightarrow \quad \exists x_2 \in \mathbb{R}^{n_2} : (x_1, x_2) \in X_{\text{opt}}^{(P_1)}$$

hilfreich, wenn Minimierung über x_2 explizit durchgeführt werden kann

Einfache Umformungen IV

$$(P_1) \quad \min f_0(x) \quad \text{s. d.} \quad f_i(x) \leq 0, \quad i=1, \dots, m, \quad h_i(x) = 0, \quad i=1, \dots, p$$

• Epigraph - Formulierung

$$(P_2) \quad \min_{t, x} t \quad \text{s. d.} \quad f_0(x) - t \leq 0, \quad f_1(x), \dots, f_m(x) \leq 0, \quad h_1(x) = \dots = h_p(x) = 0$$

$$(x, t) \in X_{\text{opt}}^{(P_2)} \Leftrightarrow x \in X_{\text{opt}}^{(P_1)} \quad \text{und} \quad f_0(x) = t$$

• Verallgemeinerte Epigraph - Formulierung

$$\text{Sei} \quad f_0(x) = \sum_{j=1}^m g_j(x)$$

$$(P_2) \quad \min_{t_1, \dots, t_m, x} \sum_{j=1}^m t_j \quad \text{s. d.} \quad g_j(x) - t_j \leq 0, \quad j=1, \dots, m \quad \text{+ andere NB}$$

$$(x, t_1, \dots, t_m) \in X_{\text{opt}}^{(P_2)} \Leftrightarrow x \in X_{\text{opt}}^{(P_1)} \quad \text{und} \quad g_j(x) = t_j, \quad j=1, \dots, m$$

Motivation und Notation

Optimalitätsbedingungen

- zeigen an, wann ein Punkt optimal ist (notwendige Bedingung)
- garantieren, dass eine mögliche Lösung tatsächlich (lokal) optimal ist (hinreichende Bedingung)
- helfen beim Design von Algorithmen

Annahme & Notation

- Im Folgenden nehmen wir immer an, dass $f_0, \dots, f_m, h_1, \dots, h_p$ stetig differenzierbar sind bis zur Ordnung, die für ein Resultat benötigt wird (z.B. einmal für erste Ordnungs-Bedingungen)
- $Df = (\partial f / \partial x_1, \dots, \partial f / \partial x_n)$, $\nabla f = Df^T$
- $D^2f = \begin{pmatrix} \partial^2 f / \partial x_1^2 & \dots & \partial^2 f / \partial x_1 \partial x_n \\ \vdots & \ddots & \vdots \\ \partial^2 f / \partial x_n \partial x_1 & \dots & \partial^2 f / \partial x_n^2 \end{pmatrix}$

1. Ordnung notwendige Bedingung

Thm: Wenn x^* lokales Optimal für $(*)$ ist, dann gilt $Df_0(x^*) = 0$.

Bew : Per Widerspruch : Nimm an, $Df_0(x^*) \neq 0$.

Mit Taylors Satz gilt für $\alpha > 0$

$$\begin{aligned}
 f_0(x^* - \alpha \nabla f(x^*)) &= f_0(x^*) + Df_0(x^*)(-\alpha \nabla f_0(x^*)) + \underbrace{o(|\alpha \nabla f_0(x^*)|)}_{\text{"klein-o-Notation"}} \\
 &= f_0(x^*) - \underbrace{\alpha |\nabla f_0(x^*)|^2}_A + \underbrace{o(\alpha |\nabla f_0(x^*)|)}_B
 \end{aligned}$$

Für alle $\alpha > 0$ klein genug gilt $B < A$, sodass

$$f_0(x^* - \alpha \nabla f(x^*)) < f_0(x^*)$$

$\Rightarrow x^*$ kann nicht lokal optimal sein □

"klein-o-Notation": Wir schreiben $o(g(s))$, wenn wir uns auf eine Funktion $f(s)$ beziehen mit $\lim_{s \rightarrow 0} \frac{f(s)}{g(s)} = 0$.

Optimalitätskriterien: Optimierung ohne Nebenbedingungen

2. Ordnung notwendige Bedingung

Thm: Wenn x^* lokal optimal für $(*)$ ist, dann gilt $Df_0(x^*) = 0$,
und $D^2f_0(x^*)$ ist positiv semi-definit, d.h.
$$s^T D^2f_0(x^*) s \geq 0 \quad \forall s \in \mathbb{R}^n.$$

Bew: Per Widerspruch; Nimm an, $\exists s \in \mathbb{R}^n : s^T D^2f_0(x^*) s < 0$.

Wir wissen schon $Df_0(x^*) = 0$.

Mit Taylors Satz folgt für $\alpha > 0$

$$f_0(x^* + \alpha s) = f_0(x^*) + \underbrace{\frac{1}{2} (\alpha s)^T D^2f_0(x^*) (\alpha s)}_{A < 0} + \underbrace{o(|\alpha s|^2)}_B$$

Für alle $\alpha > 0$ kleingenug gilt $B < |A|$, sodass

$$f_0(x^* + \alpha s) < f_0(x^*)$$

$\Rightarrow x^*$ kann nicht lokal optimal sein

□

Optimalitätskriterien: Optimierung ohne Nebenbedingungen

2. Ordnung hinreichende Bedingung

Thm: Wenn $Df_0(x^*) = 0$ und $D^2f_0(x^*)$ positiv definit ist, d.h.

$$s^T D^2f_0(x^*) s > 0 \quad \forall s \in \mathbb{R}^n \setminus \{0\},$$

dann ist x^* ein strikt lokal optimaler Punkt.

Bew: Wegen Stetigkeit ist $D^2f_0(x)$ pos. def. für alle x in einem offenen Ball $B_r(x^*)$ um x^* .

Sei $x \in B_r(x^*)$, $x \neq x^*$. Mit Taylors Satz $\exists z$ zwischen x & x^* mit

$$f_0(x) = f_0(x^*) + \underbrace{Df_0(x^*) (x-x^*)}_0 + \underbrace{\frac{1}{2} (x-x^*)^T D^2f_0(z) (x-x^*)}_{>0}$$

$$> f_0(x^*)$$

□

Optimalitätskriterien: Optimierung ohne Nebenbedingungen

Beispiel in \mathbb{R}^2

Finde lokales Minimum von $f(x_1, x_2) = x_1^3 + 3x_1^2x_2 + 3x_1x_2^2 + x_2^3 - 2x_1^2 - 8x_1x_2 - 2x_2^2$

1. Ordn. notwendige Bed: $0 = \nabla f(x_1, x_2) = \begin{pmatrix} 3x_1^2 + 6x_1x_2 + 3x_2^2 - 4x_1 - 8x_2 \\ 3x_1^2 + 6x_1x_2 + 3x_2^2 - 4x_2 - 8x_1 \end{pmatrix}$

$\Rightarrow x = (0, 0) \quad \vee \quad x = (1, 1)$

2. Ordn. notwendige Bed: $D^2f(x_1, x_2) = \begin{pmatrix} 6x_1 + 6x_2 - 4 & 6x_1 + 6x_2 - 8 \\ 6x_1 + 6x_2 - 8 & 6x_1 + 6x_2 - 4 \end{pmatrix}$

~~Lokales Maximum oder Sattel?~~ $D^2f(0, 0) = \begin{pmatrix} -4 & -8 \\ -8 & -4 \end{pmatrix}$ nicht pos. semi-def.
(Determinante < 0)

2. Ordn. hinreichende Bed: $D^2f(1, 1) = \begin{pmatrix} 8 & 4 \\ 4 & 8 \end{pmatrix}$ pos def.
(alle Minoren pos.)




$\Rightarrow (1, 1)$ ist einziger lokal optimaler Punkt

Optimalitätskriterien: Gleichungs-Nebenbedingungen

Tangentialebene und reguläre Punkte

Ein Satz Gleichungs-Nebenbedingungen $0 = c_E(x) = \begin{pmatrix} h_1(x) \\ \vdots \\ h_p(x) \end{pmatrix}$ definiert eine niederdimensionale Menge $S \subset \mathbb{R}^n$ (typischerweise $(n-p)$ -dimensional).

Grob gesagt gilt: c_E glatt $\Rightarrow S$ glatt — doch was kann an nicht-regulären Punkten passieren?



Def: Eine Kurve auf S ist eine stetige Abbildung $x: [a, b] \rightarrow S$.

- x verläuft durch $x^* \in S$, wenn $\exists t^* \in [a, b]: x(t^*) = x^*$.

- Die Tangentialebene $T_{x^*}S$ an S in x^* ist die Menge

$$T_{x^*}S = \{ \dot{x}(t^*) \mid x \text{ ist differenzierbare Kurve auf } S \text{ mit } x(t^*) = x^* \}$$

Def: $x^* \in \mathbb{R}^n$ mit $c_E(x^*) = 0$ nicht regulär, falls

$\nabla h_1(x^*), \dots, \nabla h_p(x^*)$ linear unabhängig sind.

Optimalitätskriterien: Gleichungs-Nebenbedingungen

Tangentialebene an regulären Punkten

Thm: An einem regulären Punkt x^* der Menge $S = \{x \in \mathbb{R}^n \mid c_E(x) = 0\}$ gilt
 $T_{x^*} S = \{y \mid Dc_E(x^*)y = 0\}$.

Bew: „ \subset “: Sei $y \in T_{x^*} S$, d.h. $\exists x: [a, b] \rightarrow S, t^* \in [a, b], x(t^*) = x^*, \dot{x}(t^*) = y$.

$$c_E(x(t)) = 0 \Rightarrow 0 = [c_E(x(t))]'\Big|_{t=t^*} = Dc_E(x(t^*)) \dot{x}(t^*)$$

„ \supset “: Sei $Dc_E(x^*)y = 0$.

Idee: Finde Kurve $t \mapsto x^* + ty + Dc_E(x^*)^T u(t)$ auf S .

Betrachte $F: \mathbb{R}^{p+1} \rightarrow \mathbb{R}^p, F(t, u) = c_E(x^* + ty + Dc_E(x^*)^T u)$.

$F(0, 0) = 0, D_u F(0, 0) = Dc_E(x^*) Dc_E(x^*)^T$ ist invertierbar

Impl. Fkt. Thm. $\Rightarrow \exists$ stetiges $u: [-\alpha, \alpha] \rightarrow \mathbb{R}^p$ s. d. $F(t, u(t)) = 0$

$\Rightarrow x(t) = x^* + ty + Dc_E(x^*)^T u(t)$ ist Kurve auf S

$\Rightarrow 0 = \frac{d}{dt} c_E(x(t))\Big|_{t=0} = Dc_E(x^*)y + Dc_E(x^*) Dc_E(x^*)^T \dot{u}(0)$

$\Rightarrow \dot{u}(0) = 0 \Rightarrow \dot{x}(0) = y + Dc_E(x^*)^T \dot{u}(0) = y$

□

Optimalitätskriterien: Gleichungs-Nebenbedingungen ~~oder~~ $m=0$

1. Ordnung notwendige Bedingung I

Lemma: Wenn x^* lokal optimal für (X) und regulär bzgl. c_E ist, gilt

$$Df_0(x^*) y = 0$$

für alle $y \in \mathbb{R}^n$ mit $Dc_E(x^*) y = 0$.

Bew: Sei $Dc_E(x^*) y = 0$ $\xrightarrow{\text{vorheriges Thm}}$ $y \in T_{x^*} S$ für $S = \{x \in \mathbb{R}^n \mid c_E(x) = 0\}$
 $\Rightarrow \exists x: [-a, a] \rightarrow S$ differenzierbar, $\dot{x}(0) = y$, $x(0) = x^*$.

• x^* ist lokal optimal für (X)

$\Rightarrow t=0$ ist lokal optimal für $t \mapsto f_0(x(t))$

$$\Rightarrow 0 = [f_0(x(t))]'|_{t=0} = Df_0(x^*) y \quad \square$$

Interpretation: $\nabla f_0(x^*)$ ist orthogonal zu Tangentialebene

Optimalitätskriterien: Gleichungs-Nebenbedingungen

1. Ordnung notwendige Bedingung II

Thm: Ist x^* lokal optimal für $(*)$ und regulär bzgl. c_E , dann
 \exists Lagrange Multiplikator $\lambda \in \mathbb{R}^p$ s.d. $\nabla f_0(x^*) + \lambda^T \nabla c_E(x^*) = 0$.

Bew: Setze $A = \nabla c_E(x^*)$ und $g = \nabla f_0(x^*)$

Seien die Spalten von N eine Basis von $\ker A = (\text{range } A^T)^\perp$

$\Rightarrow g = -A^T \lambda + Nz$ für ein $\lambda \in \mathbb{R}^p$, $z \in \mathbb{R}^{n-p}$

Voriges Lemma impliziert $N^T g = 0$, d.h.

$$0 = -N^T A^T \lambda + N^T N z = N^T N z.$$

Doch N hat vollen Rang, sodass $z = 0$.

$$\Rightarrow g = -A^T \lambda$$

□

Interpretation: $\nabla f_0(x^*)$ ist Linearkomb. von $\nabla h_1(x^*), \dots, \nabla h_p(x^*)$

Optimalitätskriterien: Gleichungs-Nebenbedingungen

2. Ordnung notwendige Bedingung

Thm: Ist x^* lokal optimal für $(*)$ und regulär bzgl. C_E , dann

$$\exists \lambda \in \mathbb{R}^p \text{ mit } Df_0(x^*) + \lambda^T D C_E(x^*) = 0 \text{ und}$$

$$D^2 f_0(x^*) + \sum_{k=1}^p \lambda_k D^2 h_k(x^*)$$

ist positiv semidefinit auf $T_{x^*} S$ für $S = \{x \in \mathbb{R}^n \mid C_E(x) = 0\}$.

Bew: Sei $x(t)$ eine Kurve auf S mit $x(0) = x^*$.

Wegen der 2. Ordnung notwendigen Bedingung für Optimierung ohne NB gilt

$$0 \leq \frac{d^2}{dt^2} f_0(x(t)) \Big|_{t=0} = \dot{x}(0)^T D^2 f_0(x(0)) \dot{x}(0) + Df_0(x(0)) \ddot{x}(0).$$

Außerdem impliziert $0 = \lambda^T C_E(x(t))$

$$0 = \frac{d^2}{dt^2} \lambda^T C_E(x(t)) \Big|_{t=0} = \sum_{k=1}^p \lambda_k \dot{x}(0)^T D^2 h_k(x(0)) \dot{x}(0) + \lambda^T D C_E(x(0)) \ddot{x}(0)$$

Addition beider Gleichungen und Nutzung der 1. Ordn.-Bedingung

$$\Rightarrow 0 \leq \dot{x}(0)^T \left[D^2 f_0(x^*) + \sum_{k=1}^p \lambda_k D^2 h_k(x^*) \right] \dot{x}(0),$$

worin $\dot{x}(0) \in T_{x^*} S$ beliebig war. □

Optimalitätskriterien: Gleichungs-Nebenbedingungen

2. Ordnung hinreichende Bedingung

Thm: Wenn $x^* \in \mathbb{R}^n$, $\lambda \in \mathbb{R}^p$ existieren mit

$$c_E(x^*) = 0, \quad Df_0(x^*) + \lambda^T Dc_E(x^*) = 0,$$

$$D^2f_0(x^*) + \sum_{k=1}^p \lambda_k D^2h_k(x^*) \text{ pos. def. on } T_{x^*} S,$$

dann ist x^* strikt lokal optimal für $(*)$.

Bew: Nimm das Gegenteil an, d.h. \exists Folge $y_k = x^* + \delta_k s_k$ | $\delta_k > 0$,

$\delta_k \rightarrow 0$, $|s_k| = 1$ mit $c_E(y_k) = 0$ und $f_0(y_k) \leq f_0(x^*)$.

s_k beschränkt \Rightarrow Teilfolge konvergiert. O.B.d.A. $s_k \rightarrow s^*$.

$0 = c_E(y_k) - c_E(x^*)$; dividiere durch δ_k und lasse $k \rightarrow \infty \Rightarrow Dc_E(x^*)s^* = 0$.

Taylor's Satz: $0 \geq f_0(y_k) - f_0(x^*) = \delta_k Df_0(x^*)s_k + \frac{\delta_k^2}{2} s_k^T D^2f_0(\eta_0) s_k \quad (E_0)$

$0 = h_i(y_k) - h_i(x^*) = \delta_k Dh_i(x^*)s_k + \frac{\delta_k^2}{2} s_k^T D^2h_i(\eta_i) s_k \quad (E_i)$


für η_i zwischen x^* und y_k , $i = 1, \dots, p$

$$(E_0) + \sum_{i=1}^p \lambda_i (E_i) \Rightarrow 0 \geq \frac{\delta_k^2}{2} s_k^T \left[D^2f_0(\eta_0) + \sum_{i=1}^p \lambda_i D^2h_i(\eta_i) \right] s_k \quad \forall k \quad \square$$

Optimalitätskriterien: Gleichungs-Nebenbedingungen

Beispiel

Löse $\min_{x \in \mathbb{R}^3} |x - (0, 2, 0)|^2$ s. d. $h_1(x) = |x|^2 - 1 = 0$, $h_2(x) = x_1 = 0$



1. Ordnung notwendige Bed: $0 = \nabla f(x) + \lambda_1 \nabla h_1(x) + \lambda_2 \nabla h_2(x) = 2(x - \begin{pmatrix} 0 \\ 2 \\ 0 \end{pmatrix}) + 2\lambda_1 x + \lambda_2 \begin{pmatrix} 1 \\ 0 \\ 0 \end{pmatrix}$

$$0 = h_1(x)$$

$$0 = h_2(x)$$

$$\Rightarrow x_1 = 0, \quad x_3 = 0, \quad x_2 = \pm 1, \quad \lambda_2 = 0, \quad \lambda_1 = \begin{cases} 1 \\ -1 \end{cases}$$

2. Ordnung notwendige Bed: $D^2 f \begin{pmatrix} 0 \\ 0 \\ 0 \end{pmatrix} + \lambda_1 D^2 h_1 \begin{pmatrix} 0 \\ 0 \\ 0 \end{pmatrix} + \lambda_2 D^2 h_2 \begin{pmatrix} 0 \\ 0 \\ 0 \end{pmatrix} = 2I + 2\lambda_1 I \ll 0$

\Rightarrow kein lokales Minimum

2. Ordnung hinreichende Bed: $D^2 f \begin{pmatrix} 0 \\ 0 \\ 0 \end{pmatrix} + \lambda_1 D^2 h_1 \begin{pmatrix} 0 \\ 0 \\ 0 \end{pmatrix} + \lambda_2 D^2 h_2 \begin{pmatrix} 0 \\ 0 \\ 0 \end{pmatrix} = 2I + 2\lambda_1 I \gg 0$

\Rightarrow lokales Minimum

Optimalitätskriterien: Ungleichungs-Nebenbedingungen

Aktive Menge & reguläre Punkte

Def: Sei x^* zulässig, d. h. $h_1(x^*) = \dots = h_p(x^*) = 0$, $f_1(x^*), \dots, f_m(x^*) \leq 0$.

Sei J die Menge an Indizes j mit $f_j(x^*) = 0$.

Die Menge an Nebenbedingungen $f_j(x^*) = 0$, $j \in J$, heißt aktive Menge,

$f_j(x^*) < 0$, $j \notin J$, heißt inaktive Menge.

Manchmal zählen wir die Gleichungsnebenbedingungen mit zur aktiven Menge.

• x^* heißt regulärer Punkt wenn $\nabla h_1(x^*), \dots, \nabla h_p(x^*), \nabla f_j(x^*)$, $j \in J$,

linear unabhängig sind.

In einer Umgebung von x^* kann die inaktive Menge vollständig ignoriert werden!

Optimalitätskriterien: Ungleichungs-Nebenbedingungen

Karush-Kuhn-Tucker (KKT)-Bedingungen

Thm: Wenn x^* ein lokal optimaler Punkt für $(*)$ und regulär ist, dann gibt es

Lagrange-Multiplikatoren $\lambda \in \mathbb{R}^p$, $\mu \in \mathbb{R}^m$ mit Komplementaritätsbedingung

$$c_E(x^*) = 0, c_I(x^*) \leq 0, \mu \geq 0, \mu c_I(x^*) = 0 \quad (\text{Komp. - weise})$$

$$Df_0(x^*) + \lambda^T Dc_E(x^*) + \mu^T Dc_I(x^*) = 0$$

d.h. mindestens μ_i oder $(c_I(x^*))_i$ ist 0

Bew: • Komplementaritätsbedingung

$\Leftrightarrow \mu_i \neq 0$ nur dann wenn $i \in J$ für die aktive Menge J

• x^* ist lokal optimal

$\Rightarrow x^*$ ist auch lokal optimal für Nebenbedingungen $c_E(x) = 0, f_i(x) = 0, i \in J$

$\Rightarrow 0 = Df_0(x^*) + \lambda^T Dc_E(x^*) + \mu^T Dc_I(x^*)$ für $\lambda \in \mathbb{R}^p, \mu \in \mathbb{R}^m$ mit $\mu_i = 0$ falls $i \notin J$

• Annahme $\mu_k < 0$; Sei $S = \{x \in \mathbb{R}^n \mid c_E(x) = 0, f_i(x) = 0 \forall i \in J \setminus \{k\}\}$;

wegen Regularität $\exists y \in T_{x^*} S: Df_k(x^*) y < 0$; sei x eine Kurve S mit $x(0) = x^*, \dot{x}(0) = y$

$\Rightarrow x(t)$ ist zulässig für $t \geq 0$ klein genug und $\frac{d}{dt} f_0(x(t)) \Big|_{t=0} = Df_0(x^*) y = -\mu_k Df_k(x^*) y < 0$ □

Optimalitätskriterien: Ungleichungs-Nebenbedingungen

2. Ordnung notwendige Bedingung

Thm: Wenn x^* ein lokal optimaler Punkt für (X) und regulär ist, dann $\exists \lambda \in \mathbb{R}^p, \mu \in \mathbb{R}^m$ sodass zusätzlich zu den KKT-Bedingungen gilt, dass

$$D^2 f_0(x^*) + \sum_{k=1}^p \lambda_k D^2 h_k(x^*) + \sum_{k=1}^m \mu_k D^2 f_k(x^*)$$

pos. semi-definit auf dem Tangentialraum an alle aktiven Nebenbedingungen.

Bew: x^* ist lokal optimal

$\Rightarrow x^*$ ist auch lokal optimal für Nebenbedingungen $c_E(x)=0, f_i(x)=0, i \in J$

\Rightarrow benutze 2. Ordnung notwendige Bedingung für Gleichungsnebenbedingungen \square

Optimalitätskriterien: Ungleichungs-Nebenbedingungen

2. Ordnung hinreichende Bedingung

Thm: x^* ist ein strikt lokaler optimaler Punkt von $(*)$ wenn $\exists \lambda \in \mathbb{R}^p, \mu \in \mathbb{R}^m$ sodass

$$c_E(x^*) = 0, c_I(x^*) \leq 0, \mu \geq 0, \mu c_E(x^*) = 0 \quad (\text{komp.-weise})$$

$$Df_0(x^*) + \lambda^T Dc_E(x^*) + \mu^T Dc_I(x^*) = 0$$

$$\text{und} \quad D^2f_0(x^*) + \sum_{k=1}^p \lambda_k D^2h_k(x^*) + \sum_{k=1}^m \mu_k D^2f_k(x^*)$$

pos. definit auf $\{y \in \mathbb{R}^n \mid Dc_E(x^*)y = 0, Df_i(x^*)y = 0 \text{ für alle } i \text{ mit } \mu_i > 0\}$.

Bew.: Annahme: x^* ist nicht strikt optimal, aber die Bedingungen sind erfüllt.

Sei $y_k = x^* + \delta_k s_k$ zulässig mit $\delta_k > 0, |s_k| = 1, y_k \xrightarrow{k \rightarrow \infty} x^*$ sodass $f_0(y_k) \leq f_0(x^*)$

- oBda $\delta_k \rightarrow 0, s_k \rightarrow s^*, 0 \geq Df_0(x^*)s^*, 0 = Dc_E(x^*)s^* \leftarrow$ wie im Fall von Gleichungsnebenbedingungen
- für jede (aktive) Nebenbedingung f_j mit $\mu_j > 0, f_j(y_k) - f_j(x^*) \leq 0 \Rightarrow Df_j(x^*)s^* \leq 0$

\rightarrow wenn $Df_j(x^*)s^* < 0$ für ein j , dann $0 \geq Df_0(x^*)s^* = -\lambda^T Dc_E(x^*)s^* - \mu^T Dc_I(x^*)s^* > 0 \nabla$

\rightarrow wenn $Df_j(x^*)s^* = 0$ für alle aktiven Nebenbedingungen, benutze Beweis für

Gleichungsnebenbedingungen. \square

Optimalitätskriterien: Ungleichungs-Nebenbedingungen

Beispiel

Löse $\min_{x \in \mathbb{R}^3} |x - (0, 2, 0)|^2$ s.d. $f_1(x) = |x|^2 - 1 \leq 0$, $f_2(x) = x_1 - \frac{1}{2} \leq 0$

1. Ordnung notwendige Bed: $0 = \nabla f(x) + \mu_1 \nabla f_1(x) + \mu_2 \nabla f_2(x) = 2(x - \begin{pmatrix} 0 \\ 2 \\ 0 \end{pmatrix}) + 2\mu_1 x + \mu_2 \begin{pmatrix} 1 \\ 0 \\ 0 \end{pmatrix}$

$$0 \geq f_1(x), \quad 0 \leq \mu_1, \quad \mu_1 f_1(x) = 0$$

$$0 \geq f_2(x), \quad 0 \leq \mu_2, \quad \mu_2 f_2(x) = 0$$

$$\Rightarrow x_1 = 0, \quad x_2 = 1, \quad x_3 = 0, \quad \mu_1 = 1, \quad \mu_2 = 0$$

2. Ordnung hinreichende Bed: $D^2 f \begin{pmatrix} 0 \\ 2 \\ 0 \end{pmatrix} + \mu_1 D^2 f_1 \begin{pmatrix} 0 \\ 2 \\ 0 \end{pmatrix} + \mu_2 D^2 f_2 \begin{pmatrix} 0 \\ 2 \\ 0 \end{pmatrix} = 2I + 2\mu_1 I = 4I \gg 0$

\Rightarrow lokales Minimum

Lagrange-Dualität: Duale Funktion

Lagrange-duale Funktion

Erinnerung: (*) $\min_{x \in \mathbb{R}^n} f_0(x)$ s.d. $c_I(x) = \begin{pmatrix} f_1(x) \\ \vdots \\ f_m(x) \end{pmatrix} \leq 0$, $c_E(x) = \begin{pmatrix} h_1(x) \\ \vdots \\ h_p(x) \end{pmatrix} = 0$

mit Gebiet $\mathcal{D} = \bigcap_{i=1}^m \text{dom } f_i \cap \bigcap_{j=1}^p \text{dom } h_j$

Def: Die Lagrange-Funktion zu (*) ist $L: \mathbb{R}^n \times \mathbb{R}^m \times \mathbb{R}^p \rightarrow \mathbb{R} \cup \{\infty\}$, $\text{dom } L = \mathcal{D} \times \mathbb{R}^m \times \mathbb{R}^p$,

$$L(x, \mu, \lambda) = f_0(x) + \mu^T c_I(x) + \lambda^T c_E(x).$$

- μ, λ heißen duale Variablen oder Lagrange-Multiplikatoren von (*)
- x heißt primale Variable
- $g: \mathbb{R}^m \times \mathbb{R}^p \rightarrow \mathbb{R}$, $g(\mu, \lambda) = \inf_{x \in \mathcal{D}} L(x, \mu, \lambda)$ heißt (Lagrange-) duale Funktion

Thm: Die duale Funktion g ist konkav (d.h. $-g$ ist konvex).

Bew: $-g$ ist punktweises Supremum von affinen Funktionen \Rightarrow konvex □
siehe nächstes Kapitel

Lagrange-Dualität: Duale Funktion

Untere Schranke an optimalen Wert



Thm: Sei p^* der optimale Wert von (\mathcal{X}) . Für jedes $\mu \geq 0, \lambda$ gilt $g(\mu, \lambda) \leq p^*$.

Bew: Sei x zulässig, d. u. $c_I(x) \leq 0, c_E(x) = 0$, und sei $\mu \geq 0$.

$$\Rightarrow g(\mu, \lambda) = \inf_{\tilde{x} \in \mathcal{X}} L(\tilde{x}, \mu, \lambda) \leq L(x, \mu, \lambda) = f_0(x) + \underbrace{\mu^T c_I(x)}_{\leq 0} + \underbrace{\lambda^T c_E(x)}_{=0} \leq f_0(x).$$

Da x beliebig war, $g(\mu, \lambda) \leq \inf_{x \text{ zulässig}} f_0(x)$. □

Interpretation der dualen Funktion als „Approximation“:



$$\text{Es gilt } (\mathcal{X}) \Leftrightarrow \min_{x \in \mathbb{R}^n} \tilde{L}(x) = \min_{x \in \mathbb{R}^n} f_0(x) + \sum_{i=1}^m \chi_-(f_i(x)) + \sum_{j=1}^p \chi_0(h_j(x))$$

Ersetze $\chi_-(u_i) \rightsquigarrow \mu_i u_i$ mit $\mu_i \geq 0$, $\chi_0(u_i) \rightsquigarrow \lambda_i u_i$

(ersetze harte Nebenbedingungen durch weiche Bestrafung)

$$\Rightarrow p^* = \inf_{x \in \mathbb{R}^n} \tilde{L}(x) \geq \inf_{x \in \mathbb{R}^n} L(x, \mu, \lambda) = g(\mu, \lambda).$$

Lagrange-Dualität: Duale Funktion

Beispiel: Minimum-Norm-Lösung und LP

Bsp: $\min_x \|x\|^2 \text{ s.d. } Ax=b$

Lagrange-Funktion: $L(x, \lambda) = x^T x + \lambda^T (Ax - b)$ (konvex, quadratisch in x)

duale Funktion: $g(\lambda) = \inf_{x \in \mathcal{D}} L(x, \lambda) = -\frac{1}{4} \lambda^T A A^T \lambda - \lambda^T b$ (konkav, quadratisch in λ)
 $0 = 2x^T + \lambda^T A \Leftrightarrow x = -\frac{1}{2} A^T \lambda$

Eigenschaft der dualen Fkt impliziert $g(\lambda) = -\frac{1}{4} \lambda^T A A^T \lambda - \lambda^T b \leq \inf_{x \in \mathcal{D}} \{x^T x \mid Ax=b\} \forall \lambda$

$\Rightarrow b^T (A A^T)^{-1} b = g(-2(A A^T)^{-1} b) = \max_{\lambda} g(\lambda) \leq \inf_{x \in \mathcal{D}} \{x^T x \mid Ax=b\}$

wenn $A A^T$ invertierbar

Bsp: $\min_x c^T x \text{ s.d. } Ax=b, -x \leq 0$ (**)

$L(x, \mu, \lambda) = c^T x - \mu^T x + \lambda^T (Ax - b) = -\lambda^T b + (c + A^T \lambda - \mu)^T x$

$g(\mu, \lambda) = \inf_{x \in \mathcal{D}} L(x, \mu, \lambda) = \begin{cases} -\infty & \text{falls } \mu \neq c + A^T \lambda \\ -\lambda^T b & \text{sonst} \end{cases}$

$\Rightarrow -\lambda^T b$ für jedes λ mit $\mu := c + A^T \lambda \geq 0$ ist untere Schranke an (**)

Lagrange-Dualität: Duale Funktion

Duales Problem

Erinnerung: Jedes (μ, λ) mit $\mu \geq 0$ erfüllt $g(\mu, \lambda) \leq p^*$.

Def.: Das Lagrange- dual Problem zu (X) lautet

$$\max_{\mu \in \mathbb{R}^m, \lambda \in \mathbb{R}^p, \mu \geq 0} g(\mu, \lambda) \quad (\text{DP})$$

- Das ursprüngliche Optimierungsproblem (X) heißt primales Problem.
- (μ, λ) heißt dual-zulässig, wenn $\mu \geq 0$ (komp.-weise) & $g(\mu, \lambda) > -\infty$
- (μ^*, λ^*) heißen dual-optimal, wenn sie (DP) lösen.

Thm: (DP) ist konvexes Optimierungsproblem. (egal wie (X) aussah)

Bew: (DP) $\Leftrightarrow \min_{(\mu, \lambda) \in \mathbb{R}^m \times \mathbb{R}^p} -g(\mu, \lambda)$ s.d. $-\mu \leq 0$

und $-g, \mu \mapsto -\mu_i$ sind konvex. □

Lagrange-Dualität: Duale Funktion

Beispiel: Duales Problem für LP

Das duale Problem zu einem linearen Programm ist wieder ein LP:

$$\min_x c^T x \quad \text{s.d.} \quad Ax - b = 0, \quad Bx - v \leq 0$$

$$g(\mu, \lambda) = \inf_x c^T x + \mu^T (Bx - v) + \lambda^T (Ax - b) = \begin{cases} -\infty & \text{wenn } c + B^T \mu + A^T \lambda \neq 0 \\ -\mu^T v - \lambda^T b & \text{sonst} \end{cases}$$

$$\text{duales Problem:} \quad \max_{\lambda, \mu \geq 0} g(\mu, \lambda) = \max_{\substack{\lambda, \mu \geq 0 \\ c + B^T \mu + A^T \lambda = 0}} -\mu^T v - \lambda^T b$$

$$\Leftrightarrow \min_{(\mu, \lambda)} v^T \mu + b^T \lambda \quad \text{s.d.} \quad -\mu \leq 0, \quad A^T \lambda + B^T \mu + c = 0$$

Lagrange-Dualität: Starke Dualität

Starke versus schwache Dualität

Sei p^* der optimale Wert des primalen Problems (P) , d^* der des dualen Problems (DP) .

Wir wissen $d^* \leq p^*$, insbesondere:

- Wenn (P) nach unten unbeschränkt ist ($p^* = -\infty$), dann ist (DP) nicht zulässig ($d^* = -\infty$)
- Wenn (DP) nach oben unbeschränkt ist ($d^* = \infty$), dann ist (P) nicht zulässig ($p^* = \infty$)

Def. Die Eigenschaft $d^* \leq p^*$ heißt schwache Dualität.

• $p^* - d^* \geq 0$ heißt Dualitätslücke.

• Wenn $p^* = d^*$ gilt, sagt man, es gilt starke Dualität.

Typischerweise gilt nicht starke Dualität, allerdings gilt sie für viele konvexe (und einige nicht-konvexe) Optimierungsprobleme!

Später werden wir Kriterien herleiten, wenn starke Dualität gilt.

Falls starke Dualität gilt, sind (P) und (DP) äquivalent!

Lagrange-Dualität: Starke Dualität

Beispiele

Bsp: $\min_{x \in \mathbb{R}} -x^2$ s.d. $x-1 \leq 0$, $-x-1 \leq 0$

(f_0 konkav, f_0 nach unten unbeschr.)

$$L(x, \mu_1, \mu_2) = -x^2 + \mu_1(x-1) + \mu_2(-x-1)$$

$$g(\mu_1, \mu_2) = \inf_x L(x, \mu_1, \mu_2) = -\infty$$

$$\Rightarrow d^* = -\infty < -1 = p^*$$

(keine starke Dualität)

Bsp: $\min_{x, y \in \mathbb{R}} e^{-x}$ s.d. $\frac{x^2}{y} \leq 0$, $5-y \leq 0$

(konvexe Problem, degenerierte NB)

$$L(x, y, \mu_1, \mu_2) = e^{-x} + \mu_1 \frac{x^2}{y} + \mu_2(5-y)$$

$$g(\mu_1, \mu_2) = \inf_{x, y} L(x, y, \mu_1, \mu_2) = \begin{cases} 0 & \text{falls } \mu_1 = \mu_2 = 0 \\ -\infty & \text{sonst} \end{cases}$$

$$\Rightarrow d^* = 0 < 1 = p^*$$

(keine starke Dualität)

Bsp: $\min_{x, y \in \mathbb{R}} e^{-x}$ s.d. $x^2 \leq 0$, $5-y \leq 0$

$$L(x, y, \mu_1, \mu_2) = e^{-x} + \mu_1 x^2 + \mu_2(5-y)$$

$$g(\mu_1, \mu_2) = \inf_{x, y} L(x, y, \mu_1, \mu_2) = \begin{cases} -\infty & \text{wenn } \mu_2 \neq 0, \mu_1 < 0 \\ e^{-\hat{x}} + \mu_1 \hat{x}^2, & \text{wobei } e^{-\hat{x}} = 2\mu_1 \hat{x}, \text{ sonst} \end{cases}$$


$$\Rightarrow d^* = \sup_{\mu_1 \geq 0, \mu_2 \geq 0} g(\mu_1, \mu_2) = 1 = p^*$$

(starke Dualität)

Lagrange-Dualität: Starke Dualität


Geometrische Intuition und nichtkonvexe Probleme

Bsp: $\min_{x \in \mathbb{R}} f_0(x) \text{ s.t. } f_1(x) = 0$




primale Fkt: $\omega(u) = \inf \{ f_0(x) \mid f_1(x) = u \}$

duals Fkt: $g(\mu) = \inf_x f_0(x) + \mu f_1(x) = \inf_{(u,t) \in G} t + \mu u$ mit $G = \{ (f_1(x), f_0(x)) \mid x \in \mathbb{R} \}$



Wenn $g(\mu) = t^* + \mu u^*$, dann ist $g(\mu)$ der y-Achsen-Abschnitt der Geraden durch (u^*, t^*) mit Steigung $-\mu$



starke Dualität nur, wenn G auf einer Seite der hor. Tangente in $(f_1(x^*), f_0(x^*))$ liegt

Starke und schwache Dualität von Wertemengen

• Wie im vorigen Bsp., setze $G = \{ (f_0(x), f_1(x), \dots, f_m(x), h_1(x), \dots, h_p(x)) \mid x \in X \}$
 $\Rightarrow p^* = \inf \{ t \mid (t, u, v) \in G, u \leq 0, v = 0 \}$

• Betrachte $(1, \mu, \lambda)^T (t, u, v) = t + \mu^T u + \lambda^T v$

$$\Rightarrow g(\mu, \lambda) = \inf \{ (1, \mu, \lambda)^T (t, u, v) \mid (t, u, v) \in G \}$$

Wenn Infimum endlich ist, dann definiert die Gleichung $(t, u, v) \mapsto (1, \mu, \lambda)^T (t, u, v) = g(\mu, \lambda)$ eine Hyperfläche orthogonal zu $(1, \mu, \lambda)$, die tangential am G ist, sodass G auf einer Seite davon liegt.

$$\begin{aligned} d^* &= \sup_{\mu \geq 0, \lambda} g(\mu, \lambda) = \sup_{\mu \geq 0, \lambda} \inf \{ (1, \mu, \lambda)^T (t, u, v) \mid (t, u, v) \in G \} \\ &\leq \inf \{ t \mid (t, u, v) \in G, u \leq 0, v = 0 \} = p^* \end{aligned}$$

wenn $\mu \geq 0$ & $u \leq 0, v = 0$, dann $t \geq (1, \mu, \lambda)^T (t, u, v)$

\Rightarrow schwache Dualität, und starke Dualität gilt genau dann, wenn $\mu^T u = 0$ ist im Optimum

Lagrange-Dualität: Starke Dualität

Sattelpunkt-Interpretation

Def: Sei $f: W \times Z \rightarrow \mathbb{R}$. $(\bar{w}, \bar{z}) \in W \times Z$ heißt Sattelpunkt, wenn

$$f(\bar{w}, z) \leq f(\bar{w}, \bar{z}) \leq f(w, \bar{z}) \quad \forall (w, z) \in W \times Z, \text{ d.h.}$$

$$f(\bar{w}, \bar{z}) = \inf_{w \in W} f(w, \bar{z}) = \sup_{z \in Z} f(\bar{w}, z).$$


Thm: $\sup_{z \in Z} \inf_{w \in W} f(w, z) \leq \inf_{w \in W} \sup_{z \in Z} f(w, z)$

Bew: $\sup_{z \in Z} \inf_{w \in W} f(w, z) \leq \sup_{z \in Z} \inf_{w \in W} \sup_{\tilde{z} \in Z} f(w, \tilde{z}) = \inf_{w \in W} \sup_{\tilde{z} \in Z} f(w, \tilde{z}) \quad \square$

Def: f besitzt die Sattelpunkteigenschaft, wenn $\sup_z \inf_w f(w, z) = \inf_w \sup_z f(w, z)$.

Thm: Starke Dualität $\Leftrightarrow L$ erfüllt die Sattelpunkteigenschaft auf $\mathbb{R}^n \times \mathbb{R}_+^m \times \mathbb{R}^p$.

Bew: $p^* = \inf_{x, c_I(x) \leq 0, c_E(x) = 0} p_0(x) = \inf_x \sup_{\mu \geq 0, \lambda} L(x, \mu, \lambda)$

$d^* = \sup_{\mu \geq 0, \lambda} g(\mu, \lambda) = \sup_{\mu \geq 0, \lambda} \inf_x L(x, \mu, \lambda) \quad \square$

\Rightarrow Optimum ist Sattelpunkt von L !

Lagrange-Dualität: Optimalitätsbedingungen

Zertifikate

Beachte : Wenn x zulässig und (μ, λ) dual-zulässig sind, dann

$$f_0(x) - p^* \leq f_0(x) - g(\mu, \lambda) =: \varepsilon, \text{ d.h.}$$

x ist ε -suboptimal.

Insbesondere, wenn $f_0(x) = g(\mu, \lambda)$, dann ist x optimal.

Im Allgemeinen gilt $p^*, d^* \in [g(\mu, \lambda), f_0(x)]$ (denn $f_0(x) \geq p^* \geq d^* \geq g(\mu, \lambda)$)

Def: (μ, λ) nennt man ein (duals) Zertifikat dafür, dass x ε -suboptimal/optimal ist.

Dies kann als Abbruchkriterium für Optimierungsalgorithmen benutzt werden!

Lagrange-Dualität: Optimalitätsbedingungen

Komplementarität

Angenommen, es gilt starke Dualität. Sei x^* primal-optimal, (μ^*, λ^*) dual-optimal.

$$f_0(x^*) = p^* = d^* = g(\mu^*, \lambda^*) = \inf_x f_0(x) + \mu^{*\top} c_I(x) + \lambda^{*\top} c_E(x)$$
$$\stackrel{(A)}{\leq} f_0(x^*) + \mu^{*\top} c_I(x^*) + \lambda^{*\top} c_E(x^*) \stackrel{(B)}{\leq} f_0(x^*),$$

$\mu^* \geq 0, c_I(x^*) \leq 0, c_E(x^*) = 0$

Somit gilt Gleichheit in (A) und (B).

Gleichheit in (A) $\Rightarrow x \mapsto L(x, \mu^*, \lambda^*)$ wird minimiert durch x^*

Gleichheit in (B) $\Rightarrow (\mu, \lambda) \mapsto L(x^*, \mu, \lambda)$ wird maximiert durch (μ^*, λ^*)

} (Sattelpunkteigenschaft)

$$\Rightarrow \mu^{*\top} c_I(x^*) = 0 \Rightarrow \mu_i^* f_i(x^*) = 0, i = 1, \dots, m.$$
$$\Rightarrow \mu_i^* = 0 \text{ oder } f_i(x^*) = 0$$

(Komplementaritätsbedingung)

Lagrange-Dualität: Optimalitätsbedingungen

KKT-Bedingungen aus starker Dualität

Thm: Betrachte $\min_{x \in \mathbb{R}^n} f_0(x)$ s.d. $c_E(x) = 0$, $c_I(x) \leq 0$ mit f_0, c_E, c_I differenzierbar
(d.h. $\mathcal{D} = \bigcap_{i=0}^m \text{dom } f_i(x) \cap \bigcap_{i=1}^p \text{dom } h_i(x)$ ist offen).

Wenn starke Dualität gilt und x^* primal-, (μ^*, λ^*) dual-optimal sind, dann

zuvor:
 x^* ist regulär

$$\left. \begin{array}{l} c_I(x^*) \leq 0, c_E(x^*) = 0, \mu^* \geq 0, \mu^{*T} c_I(x^*) = 0 \\ Df_0(x^*) + \mu^{*T} Dc_I(x^*) + \lambda^{*T} Dc_E(x^*) = 0 \end{array} \right\} \text{ (KKT)}$$

Bew: Sattelpunkteigenschaft von $L \Rightarrow x^*$ minimiert $x \mapsto L(x, \mu^*, \lambda^*)$

$$\Rightarrow 0 = \frac{\partial}{\partial x} L(x, \mu^*, \lambda^*) = Df_0(x^*) + \mu^{*T} Dc_I(x^*) + \lambda^{*T} Dc_E(x^*)$$

\cdot Komplementaritätsbed. $\Rightarrow \mu^{*T} c_I(x^*) = 0$ □

Thm: Seien f_0, f_1, \dots, f_m konvex, h_1, \dots, h_p affin. Dann

(KKT) \Rightarrow starke Dualität, x^* ist primal-, (μ^*, λ^*) dual-optimal.

Bew: (KKT) implizieren Zulässigkeit von $x^*, (\mu^*, \lambda^*)$. Wegen $\mu^* \geq 0$ ist

$$x \mapsto \underbrace{f_0(x) + \mu^{*T} c_I(x) + \lambda^{*T} c_E(x)}_{L(x, \mu^*, \lambda^*)} \text{ konvex} \stackrel{\text{(KKT)}}{\Rightarrow} x^* \text{ minimiert } x \mapsto L(x, \mu^*, \lambda^*)$$



$$\Rightarrow g(\mu^*, \lambda^*) = L(x^*, \mu^*, \lambda^*) = f_0(x^*) \quad \square$$

Motivation


- viele praktische Optimierungsprobleme sind konvex
 - Bildverarbeitung / Inverse Probleme (L^1 -artige Optimierung)
 - Produktionsplanung: linearisierte Nebenbedingungen \Rightarrow LP
- Manchmal lässt sich die konvexe Relaxation (konvexe Hülle) eines nichtkonvexen Optimierungsproblems finden
- Konvexe Optimierungsprobleme sind einfacher zu lösen
(an jedem Punkt ist klar, wohin man als nächstes gehen sollte)
- Konvexe Optimierungsprobleme erfüllen viele schöne Eigenschaften
 - lokales Optimum = globales Optimum
 - oft gilt starke Dualität
- Konvexe Optimierungsprobleme tauchen natürlicherweise auf, z.B. als duales Problem

Definition & Beispiele konvexer Mengen

Def: Eine Menge $C \subset \mathbb{R}^n$ heißt konvex, wenn für alle $x, y \in C$ das Liniensegment dazwischen auch in C liegt, d.h. $\forall x, y \in C, \theta \in [0, 1]$



Bsp: - Gerade: gegeben $x, y \in \mathbb{R}^n$, $L = \{z \in \mathbb{R}^n \mid \exists \theta \in \mathbb{R} : z = \theta x + (1-\theta)y\}$ ist konvex



Affine Mengen: C heißt affin, wenn für alle $x, y \in C$ auch auch die Gerade durch x und y in C liegt. Wenn C affin ist und $x_0 \in C$, dann ist $V = \{z \mid z + x_0 \in C\}$ ein linearer Untervektorraum.

→ z.B. die Lösungsmenge einer linearen Gleichung, $C = \{x \mid Ax = b\}$, $A \in \mathbb{R}^{k \times n}$, $b \in \mathbb{R}^k$

→ affine Hülle von $C \subset \mathbb{R}^n$: $\text{aff}(C) = \{y = \theta_1 x_1 + \dots + \theta_k x_k \mid k \in \mathbb{N}, \theta_1 + \dots + \theta_k = 1, x_1, \dots, x_k \in C\}$

ist die kleinste affine Menge, die C enthält. (HA)

→ affine Dimension von $C = \dim(\text{aff}(C))$ (beachte: für S^1 ist dies 2!)

Konvexe Analysis: Konvexe Mengen

Beispiele II

Bsp: · Hyperebene: $H = \{x \mid a^T x = b\}$ für $a \in \mathbb{R}^n, b \in \mathbb{R}$ ist affin mit $\text{codim } H = 1$

· Halbraum: $H = \{x \mid a^T x \leq b\}, a \in \mathbb{R}^n, b \in \mathbb{R}$ ist konvex



· Kegel: C heißt Kegel, wenn für alle $x \in C$ und alle $\theta \geq 0$ auch $\theta x \in C$.

C heißt konvexer Kegel, wenn es zusätzlich konvex ist, d.h.

$\forall x, y \in C, \theta_1, \theta_2 \geq 0: \theta_1 x + \theta_2 y \in C$




Der positive Orthant $\mathbb{R}_+^n = \{x \in \mathbb{R}^n \mid x_1, \dots, x_n \geq 0\}$ ist ein konvexer Kegel.

· (Norm-) Bälle: Sei $\|\cdot\|$ eine Norm auf \mathbb{R}^n (siehe auch etwas später).

Der Normball $\{x \in \mathbb{R}^n \mid \|x\| \leq 1\}$ ist konvex.

· m-Ellipse: Sei $x_1, \dots, x_m \in \mathbb{R}^n$. Die m-Ellipse

$\{x \mid |x - x_1| + |x - x_2| + \dots + |x - x_m| \leq 1\}$ ist konvex.



Konvexe Analysis: Konvexe Mengen

Konvexkombinationen

Def: Seien $x_1, \dots, x_k \in \mathbb{R}^n$, $\theta_1, \dots, \theta_k \geq 0$ mit $\theta_1 + \dots + \theta_k = 1$. $y = \sum_{i=1}^k \theta_i x_i$ heißt
Konvexkombination der x_i .

Thm: $C \subset \mathbb{R}^n$ ist konvex \Leftrightarrow alle Konvexkombinationen jeglicher $x_1, \dots, x_k \in C$ liegen in C

Bew: " \Leftarrow " Das Liniensegment zwischen $x, y \in C$ ist genau alle Konvexkombinationen von x, y .

" \Rightarrow " Induktion in k : $k=2$ ist die Definition von Konvexität

Induktionsschritt: Betrachte $x_1, \dots, x_{k+1} \in C$, $\theta_1, \dots, \theta_{k+1} \geq 0$, $\theta_1 + \dots + \theta_{k+1} = 1$.

OBdA sei $\nu = \sum_{i=1}^k \theta_i > 0$ und setze $\theta'_i = \theta_i / \nu$, dann gilt $\sum_{i=1}^k \theta'_i = 1$.

$\Rightarrow y' = \sum_{i=1}^k \theta'_i x_i \in C$.

Außerdem gilt $\nu + \theta_{k+1} = 1$, d.h. $\sum_{i=1}^{k+1} \theta_i x_i = \nu y' + \theta_{k+1} x_{k+1} \in C$,

welches eine Konvexkombination zweier Punkte aus C ist. \square

Kurz gesagt: Konvexkombinationen von Konvexkombinationen sind wieder Konvexkombinationen.

Konvexe Analysis: Konvexe Mengen

Konvexe Hülle

Thm: Sei $\{C_i\}_{i \in I}$ eine Familie konvexer Mengen, dann ist $\bigcap_{i \in I} C_i$ konvex.

Bew: Sei $x, y \in \bigcap_{i \in I} C_i$, dann haben wir für alle $i \in I$, dass $x, y \in C_i$, somit $\theta x + (1-\theta)y \in C_i \forall \theta \in [0,1]$

$$\Rightarrow \forall \theta \in [0,1] : \theta x + (1-\theta)y \in \bigcap_{i \in I} C_i \quad \square$$

Def: Die konvexe Hülle $\text{conv } C$ einer Menge $C \subset \mathbb{R}^n$ ist der Schnitt aller konvexen Mengen, die C enthalten.

Thm: $\text{conv } C = \left\{ y = \sum_{i=1}^k \theta_i x_i \mid k \in \mathbb{N}, x_1, \dots, x_k \in C, \theta_1, \dots, \theta_k \geq 0, \theta_1 + \dots + \theta_k = 1 \right\} =: T$

Bew: „ \subset “: T ist konvex: jegliche $x, y \in T$ sind Konvexkombinationen von Punkten in C , somit ist auch jede Konvexkombination von x, y eine Konv.-komb. von Punkten in C
 \Rightarrow diese liegt in T .

Außerdem gilt $C \subset T$, somit $\text{conv } C \subset T$.

„ \supset “: Sei S konvex mit $C \subset S$.

Wegen der vorigen Folie enthält S alle seine Konvexkomb., somit auch alle Konvexkomb. von Punkten aus C . $\Rightarrow S \supset T \xRightarrow{\text{beliebig}} \text{conv } C \supset T$. \square

Konvexe Analysis: Konvexe Mengen

Caratheodorys Theorem

Thm (Caratheodory): Jedes $x \in \text{conv } C$, $C \subset \mathbb{R}^n$, kann geschrieben werden als Konvexkombination von $n+1$ Elementen aus C .

Bew: Betrachte eine beliebige Konvexkomb. $x = \sum_{i=1}^k \theta_i x_i$ für $k > n+1$.

Behauptung: Ohne x zu verändern, können wir die θ_i so abändern, dass ein $\theta_i = 0$ wird.

In der Tat: $\{x_2 - x_1, \dots, x_k - x_1\} \subset \mathbb{R}^n$ ist linear abhängig, da $k-1 > n$.

\Rightarrow Es gibt $(\beta_2, \dots, \beta_k) \in \mathbb{R}^{k-n} \setminus \{0\}$ mit $0 = \sum_{i=2}^k \beta_i (x_i - x_1) = \sum_{i=2}^k \beta_i x_i - \underbrace{\left(\sum_{i=2}^k \beta_i\right)}_{=: -\beta_1} x_1$.

Definiere $\theta_i' = \theta_i - t^* \beta_i$ für $t^* = \theta_{i^*} / \beta_{i^*}$, $i^* = \arg \min_{i=2, \dots, k} \theta_i / \beta_i$

$\Rightarrow \theta_i' \geq 0$ und $\theta_{i^*}' = 0$.

Außerdem gilt $\sum_{i=1}^k \theta_i' = \underbrace{\sum_{i=1}^k \theta_i}_{=1} - t^* \underbrace{\sum_{i=1}^k \beta_i}_{=0} = 1$

Und $\sum_{i=1}^k \theta_i' x_i = \underbrace{\sum_{i=1}^k \theta_i x_i}_{=x} - t^* \underbrace{\sum_{i=1}^k \beta_i x_i}_{= \sum_{i=2}^k \beta_i (x_i - x_1) = 0} = x$ □

\leadsto Eine ähnliche Technik benutzt die Simplex-Methode!

Konvexe Analysis: Konvexe Mengen

Beispiele III: Normbälle


Def: Eine Abbildung $\|\cdot\|: \mathbb{R}^n \rightarrow [0, \infty)$ heißt Norm, wenn für alle $x, y \in \mathbb{R}^n, \alpha \in \mathbb{R}$

(a) $\|x\| \geq 0$ (b) $\|x\| = 0 \Leftrightarrow x = 0$ (c) $\|\alpha x\| = |\alpha| \|x\|$ (d) $\|x+y\| \leq \|x\| + \|y\|$

Bsp: · Euklidische Norm $\|x\|_2 = |x| = \sqrt{x^T x} = \sqrt{\sum_{i=1}^n x_i^2}$

· l_1 -Norm $\|x\|_1 = \sum_{i=1}^n |x_i|$ „Manhattan-Norm“

· l_∞ -Norm $\|x\|_\infty = \max_{i=1, \dots, n} |x_i|$



Def: · Der Normball $B(r, x) = \{y \in \mathbb{R}^n \mid \|x-y\| \leq r\}$ ist konvex.

· Der Ellipsoid $B_P(r, x) = \{y \in \mathbb{R}^n \mid (y-x)^T P (y-x) \leq r^2\}$, P pos. def., ist konvex,

$\|x\|_P = \sqrt{x^T P x}$ definiert eine Norm

· Der Normkegel $C = \{(x, t) \in \mathbb{R}^n \times \mathbb{R} \mid \|x\| \leq t\}$ ist ein konvexer Kegel.


„2nd order cone“ für $\|\cdot\|_2$

Konvexe Analysis: Konvexe Mengen


Beispiele IV: Simplexes

Def: Der Polyeder $P = \{x \in \mathbb{R}^n \mid a_j^T x \leq b_j, j=1, \dots, m, c_j^T x = d_j, j=1, \dots, p\}$, $a_j, c_j \in \mathbb{R}^n, b_j, d_j \in \mathbb{R}$ ist der Schnitt aus m Halbräumen und p Hyperebenen und ist somit konvex.

Kompakte Notation: $P = \{x \mid Ax \leq b, cx = d\}$



- Ein Polytop ist ein beschränkter Polyeder.
- $k+1$ Punkte $x_0, \dots, x_k \in \mathbb{R}^n$ heißen affin unabhängig, wenn $x_1 - x_0, \dots, x_k - x_0$ linear unabhängig sind.
- Ein Simplex C ist die konvexe Hülle von $k+1$ affin unabhängigen Punkten, $C = \text{conv}\{x_0, \dots, x_k\}$.
- Der Wahrscheinlichkeitssimplex ist $\text{conv}\{e_1, \dots, e_n\} \subset \mathbb{R}^n$




Thm: Jeder Simplex ist ein Polytop.

Topologische Begriffe

- Def: · Die abgeschlossene konvexe Hülle $\overline{\text{conv}} S$ einer Menge $S \subset \mathbb{R}^n$ ist der Schnitt aus allen abgeschlossenen konvexen Mengen, die S enthalten.
- Sei $C \subset \mathbb{R}^n$ konvex & nichtleer. Wenn das Innere von C nichtleer ist, $\text{aff} C = \mathbb{R}^n$.
Das relative Innere von $C \subset \mathbb{R}^n$, $\text{relint} C$, ist das Innere von C bezgl. der Topologie von $\text{aff} C$.
- $$x \in \text{relint} C \iff x \in \text{aff} C \text{ \& \ } \exists \delta > 0: \text{aff} C \cap B(x, \delta) \subset C$$
- Der relative Rand von C , $\text{relbdy} C$, wird analog definiert.

- Bsp: $C = \{x \in \mathbb{R}^3 \mid x_3 = 0, x_1^2 + x_2^2 \leq 1\}$
- $\text{aff} C = \{x \in \mathbb{R}^3 \mid x_3 = 0\}$
- $\text{relint} C = \{x \in \mathbb{R}^3 \mid x_3 = 0, x_1^2 + x_2^2 < 1\}$
- $\text{relbdy} C = \{x \in \mathbb{R}^3 \mid x_3 = 0, x_1^2 + x_2^2 = 1\}$



Konvexitätserhaltende Operationen

Thm: Der Durchschnitt konvexer Mengen ist konvex (siehe frühere Folien)

Thm: Das kartesische Produkt $C = C_1 \times \dots \times C_k$ konvexer Mengen $C_i \subset \mathbb{R}^{n_i}$ ist konvex.

Bew: HA

Thm: Sei $A: \mathbb{R}^n \rightarrow \mathbb{R}^m$ affin, d.h. $A(x) = Bx + c$ für $B \in \mathbb{R}^{m \times n}$, $c \in \mathbb{R}^m$. Sei $C \subset \mathbb{R}^n$, $D \subset \mathbb{R}^m$ konvex. Dann sind auch $A(C)$ und $A^{-1}(D) = \{x \in \mathbb{R}^n \mid A(x) \in D\}$ konvex.

Bew: · Seien $x, y \in C$. Das Bild von $[x, y] = \{\theta x + (1-\theta)y \mid \theta \in [0, 1]\}$ ist $[A(x), A(y)] \Rightarrow A(C)$ konvex.

· Seien $x, y \in A^{-1}(D)$, dann $A([x, y]) = [A(x), A(y)] \subset D \Rightarrow [x, y] \subset A^{-1}(D) \Rightarrow A^{-1}(D)$ ist konvex. \square

Thm: $C \subset \mathbb{R}^n$ konvex \Rightarrow $\text{int } C$, $\text{relint } C$, \bar{C} sind konvex.


Bew: HA

Konvexe Analysis: Trennungssatz

Extremalpunkte

Def.: Sei $C \subset \mathbb{R}^n$ konvex, $C \neq \emptyset$. $x \in C$ heißt Extremalpunkt von C , wenn es keine Punkte $x_1, x_2 \in C$ gibt mit $x_1 \neq x_2$ und $x = \theta x_1 + (1-\theta)x_2$ für ein $\theta \in (0,1)$.

• Menge der Extremalpunkte von $C = \text{ext } C$



Kor.: In obiger Definition darf man sich auf $\theta = \frac{1}{2}$ (arithmetische Durchschnitte) beschränken.

• $x \in \text{ext } C \iff C \setminus \{x\}$ konvex

Bsp.: $C = B(0,1) = \{x \in \mathbb{R}^n \mid |x| \leq 1\} \Rightarrow$ alle $x \in \mathbb{R}^n$ mit $|x|=1$ sind Extremalpunkte:

Sei $x = \theta x_1 + (1-\theta)x_2$, $\theta = \frac{1}{2}$, $x_1 \neq x_2$, $x_1, x_2 \in C$.

$$1 = |x|^2 = |\theta x_1 + (1-\theta)x_2|^2 = 2 \underbrace{(\theta^2 |x_1|^2 + (1-\theta)^2 |x_2|^2)}_{\in \theta^2 + (1-\theta)^2 = \frac{1}{2}} - \underbrace{|\theta x_1 - (1-\theta)x_2|^2}_{=0 \text{ genau dann, wenn } x_1 = \frac{1-\theta}{\theta} x_2 = x_2} < 1.$$

• Der ℓ_1 -Ball hat endlich viele Extremalpunkte.



• $\text{ext } C = \{0\}$ für einen konvexen Kegel C , der kein Halbraum & keine affine Menge

• $\text{ext } C = \emptyset$ für affine Mengen oder Halbräume.

Konvexe Analysis: Trennungssatz

Eigenschaften von Extrempunkten


Thm: Wenn $C \neq \emptyset$ kompakt und konvex, dann $\text{ext} C \neq \emptyset$.

Bew: Wegen Kompaktheit nimmt $x \mapsto |x|^2$ ihr Maximum auf C in einem $\bar{x} \in C$ an.

Beh: $\bar{x} \in \text{ext} C$. Tatsächlich, sei $\bar{x} = \frac{x_1 + x_2}{2}$ für $x_1, x_2 \in C, x_1 \neq x_2$, dann

$$|\bar{x}|^2 = \left| \frac{x_1 + x_2}{2} \right|^2 = \frac{1}{2}(|x_1|^2 + |x_2|^2) - \left| \frac{x_1 - x_2}{2} \right|^2 < |\bar{x}|^2 \quad \text{⚡} \quad \square$$

Thm: $\text{ext} C \subset \text{relbd} C$



Thm (Minkowski): Wenn $C \neq \emptyset$ kompakt & konvex, dann $C = \text{conv}(\text{ext} C)$.

Bew: Später

Kor (siehe Satz von Caratheodory): Wenn zusätzlich $\text{affdim} C = k$, dann ist jeder Punkt in C die Konvexkombination von höchstens $k+1$ Extrempunkten.

Konvexe Analysis: Trennungssatz

Seiten

Def.: Eine nichtleere konvexe Teilmenge $F \subset C$ heißt Seite von C , wenn für alle $x_1, x_2 \in C$ gilt: $\text{relint}[x_1, x_2] \cap F \neq \emptyset \Rightarrow [x_1, x_2] \subset F$

Bsp.: $x \in \text{ext } C \Leftrightarrow \{x\}$ ist eine (0-dimensionale) Seite von C

• 1-dimensionale Seiten = Kanten

• Seitenflächen von Polyedern

• C selbst ist Seite von C für konvexe abgeschlossene Mengen C



Thm.: Sei F eine Seite der konvexen Menge $C \subset \mathbb{R}^n$. $\text{ext}(F) \subset \text{ext}(C)$


Bew.: Annahme: $x \in \text{ext } F \setminus \text{ext } C$, d.h. es gibt $x_1, x_2 \in C$, $x_1 \neq x_2$, $x = \frac{x_1 + x_2}{2}$.

Nach Definition einer Seite gilt somit $[x_1, x_2] \subset F$, somit $x_1, x_2 \in F \Rightarrow x \in \text{ext } F \nabla \square$

Exponierte Seiten

Def: - Eine Hyperebene $H_{s,r} = \{x \in \mathbb{R}^n \mid s^T x = r\}$ trägt $C \subset \mathbb{R}^n$, wenn C vollständig in einem der beiden Halbräume $\{x \in \mathbb{R}^n \mid s^T x \leq r\}$ und $\{x \in \mathbb{R}^n \mid s^T x \geq r\}$ liegt.

- $H_{s,r}$ trägt C in $x \in C$, wenn zusätzlich $x \in H_{s,r}$
- $F \subset C \subset \mathbb{R}^n$ heißt exponierte Seite, wenn es eine tragende Hyperebene H gibt mit $F = H \cap C$.
- Exponierter Punkt = 0-dimensionale exponierte Seite (Ecke)



Thm: Eine exponierte Seite einer konvexen Menge ist eine Seite.

Bew: Sei $F = C \cap H_{s,r}$ für eine tragende Hyperebene $H_{s,r}$ (oBdA, $C \subset \{x \in \mathbb{R}^n \mid s^T x \leq r\}$).

Seien $x_1, x_2 \in C$, $\theta \in (0,1)$ mit $x = \theta x_1 + (1-\theta)x_2 \in F \subset H_{s,r}$.

$\Rightarrow r = s^T(\theta x_1 + (1-\theta)x_2)$. oBdA sei $x_1 \notin F \subset H_{s,r}$, d.h. $s^T x_1 < r$.

$\Rightarrow s^T(\theta x_1 + (1-\theta)x_2) < r \wedge \Rightarrow x_1, x_2 \in F \Rightarrow [x_1, x_2] \subset F$. □

Kor: Für $C \subset \mathbb{R}^n$ konvex, F eine exponierte Seite, gilt $\text{ext } F \subset \text{ext } C$ (siehe vorige Folie).

Konvexe Analysis: Trennungssatz

Projektionen

Def: Eine lineare Abbildung $P: \mathbb{R}^n \rightarrow \mathbb{R}^n$ heißt Projektion, wenn $P^2 = P$ (Idempotenz).

Sei $V \subset \mathbb{R}^n$ ein Unterraum: $P_V: \mathbb{R}^n \rightarrow V$, $x \mapsto v$ mit $x = v + v^\perp \in V \oplus V^\perp$ heißt die orthogonale Projektion auf V .

Thm: P_V ist linear, idempotent, symmetrisch, positiv semidefinit, nicht expansiv ($\|P_V\|_2 \leq 1$),
 $x = P_V(x) + P_{V^\perp}(x)$.

Wie kann man die orthogonale Projektion auf abgeschlossene Mengen verallgemeinern?

Thm: $P_V(x) = \operatorname{argmin}_{y \in V} \frac{1}{2} \|y - x\|_2^2$.

Bew: Sei $x = v + v^\perp \in V \oplus V^\perp$, dann $\frac{1}{2} \|y - x\|_2^2 = \frac{1}{2} \|y - v\|_2^2 + \frac{1}{2} \|v^\perp\|_2^2 \Rightarrow y = v$ ist minimiert. \square

Thm: Sei $C \subset \mathbb{R}^n$ abgeschlossen, $x \in \mathbb{R}^n$, dann nimmt $y \mapsto f_x(y) = \frac{1}{2} \|y - x\|_2^2$ auf C ihr Minimum an.

Bew: Sei $c \in C$ und $S = \{y \in \mathbb{R}^n \mid f_x(y) \leq f_x(c)\}$. f_x ist stetig, $C \cap S$ ist kompakt
 \Rightarrow mit dem Satz von Weierstraß nimmt f_x ein Minimum auf $C \cap S$ und somit auf C an. \square

Konvexe Analysis: Trennungssatz

Orthogonale Projektionen

Def: Sei $C \subset \mathbb{R}^n$ abgeschlossen und konvex. Die (nichtlineare) Abbildung $P_C: \mathbb{R}^n \rightarrow C$,

$$P_C(x) = \underset{y \in C}{\operatorname{argmin}} \underbrace{\frac{1}{2} \|x-y\|_2^2}_{f_x(y)}, \text{ heißt } \underline{\text{orthogonale Projektion auf } C}.$$


Thm: P_C ist wohldefiniert.

Bew: Eindeutigkeit ist noch zu zeigen: Seien $y_1 \neq y_2$ Minimierer, $y_0 = \frac{y_1+y_2}{2} \in C$.

$$\begin{aligned} f_x(y_0) - \frac{1}{2}(f_x(y_1) + f_x(y_2)) &= \frac{\|x\|_2^2 - x \cdot y_0 - x \cdot y_2 + \|y_0\|_2^2}{2} - \frac{\|x\|_2^2 - 2x \cdot y_1 + \|y_1\|_2^2 + \|x\|_2^2 - 2x \cdot y_2 + \|y_2\|_2^2}{4} \\ &= \frac{1}{8} (-\|y_0\|_2^2 - \|y_2\|_2^2 + 2y_1 \cdot y_2) = -\frac{1}{8} \|y_1 - y_2\|_2^2 < 0 \quad \square \end{aligned}$$

Thm: $P_C \circ P_C = P_C$ & P_C linear $\Leftrightarrow C$ ist Unterraum von \mathbb{R}^n .

Thm: $y_x = P_C(x) \Leftrightarrow y_x \in C$ & $(x - y_x) \cdot (y - y_x) \leq 0 \quad \forall y \in C$.



Bew: " \Rightarrow ": für $y \in C$, $\alpha \in [0,1]$ beliebig, betrachte $y_\alpha = y_x + \alpha(y - y_x) \in C$.

$$\text{Es gilt } \frac{1}{2} \|y_x - x\|_2^2 = f_x(y_x) \leq f_x(y_\alpha) = \frac{1}{2} \|y_x - x + \alpha(y - y_x)\|_2^2$$

$$\Rightarrow 0 \leq \alpha(y_x - x) \cdot (y - y_x) + \alpha^2 \|y - y_x\|_2^2; \text{ nun dividieren durch } \alpha \text{ und lassen } \alpha \rightarrow 0.$$

$$\text{"} \Leftarrow \text{"}: \forall y \in C: 0 \geq (x - y_x) \cdot (y - y_x) = \|x - y_x\|_2^2 + (x - y_x) \cdot (y - x) \geq \|x - y_x\|_2^2 - \|x - y_x\|_2 \|y - x\|_2$$

\Rightarrow entweder $y_x = x$ oder $\|x - y_x\|_2 \leq \|y - x\|_2$ □


Konvexe Analysis: Trennungssatz

Trennung konvexer Mengen

Thm: Sei $C \subset \mathbb{R}^n$ konvex, abgeschlossen, $x \notin C$. Dann existiert $s \in \mathbb{R}^n$ sodass $s \cdot x > \sup_{y \in C} s \cdot y$.

Bew: Setzen $s := x - P_C(x)$. 

Für alle $y \in C$ gilt $0 \geq (x - P_C(x)) \cdot (y - P_C(x)) = s \cdot (y - x + s) = s \cdot y - s \cdot x + \|s\|^2 \Rightarrow s \cdot x > s \cdot y + \frac{\|s\|^2}{2} \square$

Kor: Seien $C_1, C_2 \subset \mathbb{R}^n$ konvex, abgeschlossen, nichtleer, disjunkt. Wenn C_2 beschränkt ist, existiert $s \in \mathbb{R}^n$ sodass $\sup_{y \in C_1} s \cdot y < \min_{y \in C_2} s \cdot y$. 

Bew: $C_1 - C_2 = \{y_1 - y_2 \mid y_1 \in C_1, y_2 \in C_2\}$ ist konvex:


$C_1 \times C_2$ ist konvex und $C_1 - C_2 = i(C_1 \times C_2)$ für die lineare Abb. $i: \mathbb{R}^n \times \mathbb{R}^n \rightarrow \mathbb{R}^n, (a, b) \mapsto a - b$.

$C_1 - C_2$ ist abgeschlossen, denn C_1 ist abgeschlossen und C_2 kompakt:

Sei $y_k = y_k^1 - y_k^2 \in C_1 - C_2$ mit $y_k \rightarrow y$. C_2 kompakt $\Rightarrow y_k^2 \rightarrow y_2 \in C_2$
für Teilfolge (Bolzano-Weierstraß)

$\Rightarrow y_k^1 = y_k + y_k^2 \rightarrow y + y_2 \in C_1$ (da C_1 abgeschlossen) $\Rightarrow y \in C_1 - C_2$

Vorheriges Theorem für $x = 0, C = C_1 - C_2 \Rightarrow \exists s \in \mathbb{R}^n: 0 = s \cdot x > \sup_{y \in C_1 - C_2} s \cdot y = \sup_{y_1 \in C_1} s \cdot y_1 - \min_{y_2 \in C_2} s \cdot y_2 \square$

Beachte: - Aussage kann falsch sein für C_2 unbeschränkt: 

Wenn C_1, C_2 nur konvex, nichtleer, disjunkt, erhält man noch $\sup_{C_1} s \cdot y \in \inf_{C_2} s \cdot y$ (HA)

Konvexe Analysis: Trennungssatz


Konsequ. der Trennungseigenschaft: Tragende Hyperebenen

Thm: (Existenz tragender Hyperebene) Sei $C \subset \mathbb{R}^n$ konvex, $x \in \partial C \cap C$. Dann existiert eine in x tragende Hyperebene zu C .

Bew: Betrachte eine Folge $x_k \notin \bar{C}$ mit $x_k \rightarrow x$. Für jedes x_k gibt es $s_k \in \mathbb{R}^n$ mit $s_k \cdot (x_k - y) > 0 \forall y \in C$.
O.B.d.A sei $\|s_k\| = 1 \Rightarrow$ für eine Teilfolge gilt $s_k \rightarrow s \in S^{n-1}$.

Wegen Stetigkeit gilt $s \cdot (x - y) \geq 0 \forall y \in C \Rightarrow H_{s,r} = \{y \mid s \cdot y = r\}$ mit $r = s \cdot x$ ist gesuchte Hyperebene □

Thm: Für $S \subset \mathbb{R}^n$ und Halbräume $H_{s,r}^- = \{y \in \mathbb{R}^n \mid s \cdot y \leq r\}$ setze
 $\Sigma_S = \{(s,r) \in \mathbb{R}^n \times \mathbb{R} \mid S \subset H_{s,r}^-\}$ und $C_S = \bigcap_{(s,r) \in \Sigma_S} H_{s,r}^-$.
Dann gilt entweder $C_S = \overline{\text{conv}} S$ oder $\overline{\text{conv}} S = \mathbb{R}^n$.



Bew: Angenommen $\overline{\text{conv}} S \neq \mathbb{R}^n$, dann $C_S \supset \overline{\text{conv}} S$.

• Nun sei $x \in \overline{\text{conv}} S$. Trenne $\{x\}$ und $\overline{\text{conv}} S$ durch eine Hyperebene H_{s_0, r_0} , d.h.

$s_0 \cdot x > \sup_{y \in S} s_0 \cdot y = r_0 \Rightarrow (s_0, r_0) \in \Sigma_S$, aber $x \notin H_{s_0, r_0}^- \Rightarrow x \notin C_S$. □

Konvexe Analysis: Trennungssatz

Konsequ. der Trennungseigenschaft: Halbräume & Extr.-Punkte

Kor: Sei $C \subseteq \mathbb{R}^n$ abgeschlossen und konvex, dann gilt $C = C_C$, d.h. C ist Schnitt von Halbräumen.

Spezialfall: Ein Polyeder ist Schnitt aus endlich vielen Halbräumen.

Thm: (Minkowski) Wenn $C \subseteq \mathbb{R}^n$ kompakt, konvex & nichtleer ist, dann gilt $C = \text{conv}(\text{ext} C)$.

Bew: Induktion in $k = \text{affdim} C$; Fall $k=0$ ist trivial. Induktionsschritt $k-1 \rightarrow k$:

Sei $x \in C$. Fall $x \in \text{relbdy} C$: Es gibt eine Hyperebene $H \not\subseteq C$, die C in x trägt.
 \ warum?

$\Rightarrow \text{affdim } C \cap H \leq k-1$

$\Rightarrow x$ ist Konvexkombination von Extrempunkten x_i in $C \cap H$

x_i sind auch Extrempunkte von C , da $C \cap H$ eine exponierte Seite ist.

• Fall $x \in \text{relint} C$: Wähle $x' \neq x, x' \in C$

\Rightarrow Gerade durch x & x' schneidet $\text{relbdy} C$ in zwei Punkten y, z .

\Rightarrow nach dem ersten Fall gilt $y, z \in \text{conv}(\text{ext} C)$

$\Rightarrow x \in \text{conv}(\text{ext} C)$


□

Konvexe Analysis: Konvexe Funktionen

Grundbegriffe

Def.: Sei $C \subset \mathbb{R}^n$ konvex. $f: C \rightarrow \mathbb{R} \cup \{\infty\}$ heißt konvex ($f \in \text{Conv } C$), wenn $\text{dom } f \neq \emptyset$ &

$$\forall x, y \in C, \theta \in (0, 1): f(\theta x + (1-\theta)y) \leq \theta f(x) + (1-\theta)f(y).$$




f heißt strikt konvex, wenn $\forall x, y \in C$ mit $x \neq y, \theta \in (0, 1): f(\theta x + (1-\theta)y) < \theta f(x) + (1-\theta)f(y)$.

f heißt konkav, wenn $-f$ konvex ist.

Der Graph von f ist die Menge $\{(x, f(x)) \in \mathbb{R}^{n+1} \mid x \in \text{dom } f\}$.

Der Epigraph von f ist $\text{epi } f = \{(x, r) \in \mathbb{R}^{n+1} \mid f(x) \leq r\}$.

Die Subniveau-Menge von f bzgl. $r \in \mathbb{R}$ ist $S_r(f) = \{x \in \mathbb{R}^n \mid f(x) \leq r\}$.



Thm.: f konvex \Rightarrow $\text{dom } f$ konvex

f konvex \Leftrightarrow $\text{epi } f$ konvex

$(x, r) \in \text{epi } f \Leftrightarrow x \in S_r(f)$

Konvexe Analysis: Konvexe Funktionen

Beispiele & Eigenschaften

Bsp: - Charakteristische Funktion / Indikatorfunktion einer konvexen Menge $C \subset \mathbb{R}^n$

$$I_C(x) = \begin{cases} 0 & \text{wenn } x \in C \\ \infty & \text{sonst} \end{cases}$$

anders als $\chi_C(x) = \begin{cases} 1 & \text{wenn } x \in C \\ 0 & \text{sonst} \end{cases}$

- Jede Norm auf \mathbb{R}^n ist konvex: $\forall x, y \in \mathbb{R}^n, \theta \in (0, 1): \|\theta x + (1-\theta)y\| \leq \|\theta x\| + \|(1-\theta)y\| = \theta\|x\| + (1-\theta)\|y\|$
- Die Maximumfunktion $f(x) = \max x_i$ ist konvex.
- Lineare & affine Funktionen sind konvex; ihr Epigraph ist ein Halbraum.

Thm: (Jensensche Ungleichung) $\forall f \in \text{Conv } \mathbb{R}^n, x_1, \dots, x_k \in \text{dom } f, \theta_1, \dots, \theta_k \geq 0, \sum_{i=1}^k \theta_i = 1:$
$$f\left(\sum_{i=1}^k \theta_i x_i\right) \leq \sum_{i=1}^k \theta_i f(x_i)$$

Bew: $(x_i, f(x_i)) \in \text{epi } f \xrightarrow{\text{epi } f \text{ konvex}} \sum_{i=1}^k \theta_i (x_i, f(x_i)) = \left(\sum_{i=1}^k \theta_i x_i, \sum_{i=1}^k \theta_i f(x_i)\right) \in \text{epi } f \quad \square$

Bem: Die Jensensche Ungleichung gilt auch für Integrale: Sei $f \in \text{Conv } \Omega$ und (Ω, Σ, P) ein Wahrscheinlichkeitsraum, dann gilt

$$f\left(\underbrace{\int_{\Omega} x \, dP}_{\text{Erwartungswert der Zufallsvariable}}\right) \leq \underbrace{\int_{\Omega} f(x) \, dP}_{\text{Erw.-wert von } f}$$

Konvexe Analysis: Konvexe Funktionen

Konvexität und Stetigkeit — warum?

Thm: Sei $f \in \text{Conv} \mathbb{R}^n$. f ist stetig auf $\text{int}(\text{dom} f)$.

Bew: Sei $\bar{x} \in \text{int} \text{dom} f$. f ist beschränkt in einer Umgebung von \bar{x} :

Es gibt einen Simplex $Q = \text{conv}\{x_0, \dots, x_n\} \subset \text{dom} f$ mit $\bar{x} \in \text{int} Q$.

Sei $x \in Q$, d.h. $x = \sum_{i=0}^n \theta_i x_i$, $\theta_i \in [0, 1]$, $\sum_{i=0}^n \theta_i = 1$, dann gilt $f(x) \leq \sum_{i=0}^n \theta_i f(x_i) \leq \max_i f(x_i) =: \tilde{M}$.

Weiter setze für $\alpha = \frac{\text{dist}(\bar{x}, \partial Q)}{2 \text{diam} Q} \in (0, \frac{1}{4})$ $\hat{x} = \bar{x} - \frac{\alpha}{1-\alpha}(x - \bar{x}) \in Q$ (also $\bar{x} = \alpha x + (1-\alpha)\hat{x}$)

$$\Rightarrow f(\bar{x}) \leq \alpha f(x) + (1-\alpha)f(\hat{x}) \Rightarrow f(x) \geq \frac{f(\bar{x}) - (1-\alpha)f(\hat{x})}{\alpha} \geq \min\{-\tilde{M}, \frac{f(\bar{x}) - \tilde{M}}{\alpha}\} =: M$$

• Sei $v \in \mathbb{R}^n$ sodass $\bar{x} + v \in Q$. Für $b \in [0, 1]$ gilt

$$f(\bar{x} + bv) - f(\bar{x}) \leq b f(\bar{x} + v) + (1-b)f(\bar{x}) - f(\bar{x}) \leq b(M - f(\bar{x}))$$

• Sei $v \in \mathbb{R}^n$ sodass $\bar{x} \pm v \in Q$. Für $b \in [0, 1]$ gilt

$$f(\bar{x} + bv) - f(\bar{x}) \geq f(\bar{x} + bv) - \left[\frac{b}{1+b} f(\bar{x} - v) + \frac{1}{1+b} f(\bar{x} + bv) \right] = \frac{b}{1+b} (f(\bar{x} + bv) - f(\bar{x} - v)) \geq \frac{2Mb}{1+b}$$

• Insgesamt ergibt sich $|f(\bar{x} + bv) - f(\bar{x})| \leq 2bM$ für alle v klein genug und $b \in [0, 1]$.

$\Rightarrow f$ ist lokal Lipschitz-stetig. □

Beachte: Gilt nicht in ∞ -dimensionalen Räumen:


Es gibt sogar auf Banachräumen unstetige lineare Funktionale.

Konvexe Analysis: Konvexe Funktionen

Konvexe und affine Funktionen

warum?

Thm: Sei $f \in \text{Conv } \mathbb{R}^n$. $\forall x_0 \in \text{relint dom } f \exists s \in \mathbb{R}^n: f(x) \geq f(x_0) + s \cdot (x - x_0) \forall x \in \mathbb{R}^n$.



Bew: • Es gilt $\text{aff epi } f = (\text{aff dom } f) \times \mathbb{R}$

und $\text{aff dom } f = x_0 + V$ für einen Unterraum $V \subset \mathbb{R}^n$.

- $(x_0, f(x_0)) \in \text{relint } (\text{epi } f) \Rightarrow \exists$ Hyperebene H , die $\text{epi } f$ in $(x_0, f(x_0))$ trägt,
d.h. $\exists \tilde{s} \in V, \alpha \in \mathbb{R}, (\tilde{s}, \alpha) \neq 0$ sodass $(\tilde{s}, \alpha) \cdot (x, r) \leq (\tilde{s}, \alpha) \cdot (x_0, f(x_0)) \forall (x, r) \in \text{epi } f$;
insbesondere gilt $-\alpha r \geq -\alpha f(x_0) + \tilde{s} \cdot (x - x_0)$ für alle $x \in \text{dom } f, r \geq f(x)$.
- $\alpha < 0$: Der Limes $r \rightarrow \infty$ zeigt $\alpha \leq 0$,
und $\alpha = 0$ impliziert $0 \geq \tilde{s} \cdot (x - x_0) \forall x \in \text{dom } f$, d.h. $\tilde{s} = 0$, ein Widerspruch.
- Dividiere durch $-\alpha \Rightarrow f(x) \geq f(x_0) + s \cdot (x - x_0)$ für $s = \frac{\tilde{s}}{-\alpha}$. □

Was ist s , wenn f differenzierbar in x_0 ist?

Konvexe Analysis: Konvexe Funktionen

Differenzierbare konvexe Funktionen

Thm: Sei $C \subset \mathbb{R}^h$ offen, konvex, $f: C \rightarrow \mathbb{R}$ differenzierbar.

f ist (strikt) konvex auf $C \iff f(x) \geq (>) f(x_0) + \nabla f(x_0) \cdot (x - x_0) \quad \forall x \neq x_0 \text{ aus } C$

Bew: " \Rightarrow ": Sei f (strikt) konvex, $\alpha \in (0, 1)$, dann gilt

$$f(x_0 + \alpha(x - x_0)) - f(x_0) \leq \alpha f(x) + (1 - \alpha)f(x_0) - f(x_0) = \alpha(f(x) - f(x_0)).$$

Dividiere durch α und lasse $\alpha \rightarrow 0 \Rightarrow \nabla f(x_0) \cdot (x - x_0) \leq f(x) - f(x_0)$.

Falls Gleichheit gilt und f strikt konvex ist, sei $z = \frac{1}{2}x_0 + \frac{1}{2}x$. Dann gilt

$$f(z) < \frac{1}{2}f(x_0) + \frac{1}{2}f(x) = \frac{1}{2}f(x_0) + \frac{1}{2}(f(x_0) + \nabla f(x_0) \cdot (x - x_0)) = f(x_0) + \nabla f(x_0) \cdot (z - x_0) \downarrow$$

" \Leftarrow ": Sei $x_1 \neq x_2$ aus C , $\alpha \in (0, 1)$, $x_0 = \alpha x_1 + (1 - \alpha)x_2 \in C$.

$$(E_i) \quad f(x_i) \geq f(x_0) + \nabla f(x_0) \cdot (x_i - x_0), \quad i = 1, 2$$

$$\alpha(E_1) + (1 - \alpha)E_2: \quad \alpha f(x_1) + (1 - \alpha)f(x_2) \geq f(x_0) + \nabla f(x_0) \cdot \underbrace{[\alpha(x_1 - x_0) + (1 - \alpha)(x_2 - x_0)]}_{x_0 - x_0 = 0}$$

$\Rightarrow f(\alpha x_1 + (1 - \alpha)x_2) \leq \alpha f(x_1) + (1 - \alpha)f(x_2) \quad \square$

Konvexität und Monotonie der ersten Ableitung

Thm: Sei $C \subset \mathbb{R}^n$ konvex, $f: C \rightarrow \mathbb{R}$ differenzierbar. Wenn Df (strikt) monoton ist, d. h.

$$(Df(x) - Df(y))(x - y) \geq (>) 0 \quad \forall x, y \in C, \text{ dann ist } f \text{ (strikt) konvex.}$$

Bew: Seien $x_1, x_2 \in C, \alpha \in (0, 1), x = (1 - \alpha)x_1 + \alpha x_2 = x_1 + \alpha(x_2 - x_1) \in C, x_s = x_1 + s(x_2 - x_1)$

$$f(x) = f(x_1) + \int_0^\alpha \underbrace{Df(x_s)}_{= \frac{d}{ds} f(x_s)} (x_2 - x_1) ds \quad (E_1) \quad f(x_2) = f(x) + \int_\alpha^1 Df(x_s) (x_2 - x_1) ds \quad (E_2)$$

$$(1 - \alpha)(E_1) - \alpha(E_2) \Rightarrow f(x) = (1 - \alpha)f(x_1) + \alpha f(x_2) + \underbrace{\left[(1 - \alpha) \int_0^\alpha Df(x_s) ds - \alpha \int_\alpha^1 Df(x_s) ds \right]}_A (x_2 - x_1)$$

$$A = \alpha(1 - \alpha) \int_0^1 Df(x_{\alpha s}) - Df(x_{\alpha + (1 - \alpha)s}) ds (x_2 - x_1) \leq (<) 0. \quad \square$$

Thm: Sei $C \subset \mathbb{R}^n$ konvex, $f: C \rightarrow \mathbb{R}$ differenzierbar. f (strikt) konvex $\Rightarrow Df$ (strikt) monoton.

$$\text{Bew: } f(x_1) \stackrel{\geq}{\geq} f(x_2) + Df(x_2)(x_1 - x_2) \quad \& \quad f(x_2) \stackrel{\geq}{\geq} f(x_1) + Df(x_1)(x_2 - x_1).$$

Nun addiere beide Ungleichungen. □

Kor: Sei $C \subset \mathbb{R}^n$ konvex, $f: C \rightarrow \mathbb{R}$ zweimal differenzierbar. Dann

$$(a) D^2f \text{ (strikt) positiv definit} \Rightarrow f \text{ (strikt) konvex} \quad (b) f \text{ konvex} \Rightarrow D^2f \text{ pos. semi-def.}$$

Bew: (strikte) positive Definitheit von $D^2f \iff$ (strikte) Monotonie von Df . □

Konvexitätserhaltende Operationen

Thm: i) Seien $f_1, \dots, f_n \in \text{Conv } \mathbb{R}^n$, $t_1, \dots, t_n > 0$, $x_0 \in \mathbb{R}^n$ mit $f_1(x_0), \dots, f_n(x_0) < \infty$.

Dann ist $\sum_{i=1}^n t_i f_i \in \text{Conv } \mathbb{R}^n$.

ii) Sei $f \in \text{Conv } \mathbb{R}^n$, $A: \mathbb{R}^n \rightarrow \mathbb{R}^n$ affin mit $\text{Bild } A \cap \text{dom } f \neq \emptyset$. Dann gilt $f \circ A \in \text{Conv } \mathbb{R}^n$.

iii) Seien $f_i \in \text{Conv } \mathbb{R}^n$, $i \in J$, $x_0 \in \mathbb{R}^n$ mit $f_i(x_0) < M < \infty \forall i \in J$.

Dann gilt $x \mapsto \sup_{i \in J} f_i(x) \in \text{Conv } \mathbb{R}^n$.

iv) Sei $f \in \text{Conv } \mathbb{R}^n$, $h \in \text{Conv } \mathbb{R}$ monoton wachsend, $x_0 \in \mathbb{R}^n$ mit $f(x_0) \in \text{dom } h$. $h \circ f \in \text{Conv } \mathbb{R}^n$.

v) Sei $f \in \text{Conv } \mathbb{R}^{n_1} \times \mathbb{R}^{n_2}$, $C \subset \mathbb{R}^{n_2}$ konvex, $g(x) = \inf_{y \in C} f(x, y)$. Wenn $g(x) > -\infty \forall x \in \mathbb{R}^{n_1}$, $g \in \text{Conv } \mathbb{R}^{n_1}$.

Bsp: Moreau-Yosida-Approximation für $f \in \text{Conv } \mathbb{R}^n$, $\lambda > 0$: $f_\lambda(x) = \inf_{y \in \mathbb{R}^n} f(y) + \frac{\lambda}{2} \|x - y\|_2^2$.

Bew: i), ii), iv) - HA

iii) Sei $f(x) = \sup_{i \in J} f_i(x)$. $\text{epi } f = \bigcap_{i \in J} \text{epi } f_i$ ist konvex und nichtleer, da $(x_0, M) \in \text{epi } f_i$.

v) Für eine Menge $A \subset \mathbb{R}^{n_1} \times \mathbb{R}$ sei $A_x = \{(t, \tau) \in A\}$ der vertikale Schnitt in x und $\text{cl}_v A = \bigcup_{x \in \mathbb{R}^{n_1}} \overline{A_x}$ der vertikale Abschluss. Es gilt $A \text{ konvex} \Rightarrow \text{cl}_v A \text{ konvex}$.



$\text{epi } g = \text{cl}_v \{(x, t) \mid \exists y \in C : (x, y, t) \in \text{epi } f\} = \text{cl}_v (\text{pr}_{\mathbb{R}^{n_1} \times \mathbb{R}} (\text{epi } f))$ ist konvex. \square

Konvexe Analysis: Konvexe Funktionen

Unterhalbstetigkeit

Def: $f: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{\infty\}$ heißt unterhalb-stetig, wenn $\liminf_{y \rightarrow x} f(y) \geq f(x) \quad \forall x \in \mathbb{R}^n$.

Bsp: $f(x) = \begin{cases} 1 & x < 0 \\ 0 & x \geq 0 \end{cases}$ ist unterhalbstetig, $f(x) = \begin{cases} 1 & x \leq 0 \\ 0 & x > 0 \end{cases}$ nicht.



Thm: Sei $f: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{\infty\}$. Dann sind die folgenden Eigenschaften äquivalent:

(a) f ist unterhalb-stetig

(b) $\text{epi} f$ ist abgeschlossen in $\mathbb{R}^n \times \mathbb{R}$


(c) Die Subniveau-Mengen $S_r(f)$ sind abgeschlossen für alle $r \in \mathbb{R}$.

Bew: (a) \Rightarrow (b): Sei $(y_k, r_k) \in \text{epi} f$, $(y, r) = \lim_{k \rightarrow \infty} (y_k, r_k)$.

$r = \lim_{k \rightarrow \infty} r_k \geq \liminf_{k \rightarrow \infty} f(y_k) \geq \liminf_{x \rightarrow y} f(x) \geq f(y)$, daher ist $(y, r) \in \text{epi} f$.

(b) \Rightarrow (c): Sei $A_r(x) = (x, r)$, $Q_r = \text{epi} f \cap (\mathbb{R}^n \times \{r\})$. Q_r ist abgeschlossen,

A_r stetig. $S_r(f) = \{x \in \mathbb{R}^n \mid f(x) \leq r\} = A_r^{-1}(Q_r)$ ist abgeschlossen.



(c) \Rightarrow (a): Angenommen, (a) sei falsch, d. h. $\exists y_k \rightarrow x$ mit $\rho = \lim_{k \rightarrow \infty} f(y_k) < f(x)$. Sei $r \in (\rho, f(x))$.

Für $k > k_0$ groß genug gilt $f(y_k) \leq r < f(x)$, d. h. $y_k \in S_r(f) \quad \forall k > k_0$, aber $x \notin S_r(f) \quad \square$

Konvexe Analysis: Konvexe Funktionen

Abgeschlossene konvexe Funktionen

Def.: Eine Funktion heißt abgeschlossen, wenn sie unterhalbstetig auf \mathbb{R}^n ist (d.h. $\text{epi } f$ abgeschlossen ist)

- Die Relaxation (oder unterhalbstetige Hülle) einer Funktion f ist definiert durch

$$\bar{f}(x) := \text{cl } f(x) := \liminf_{y \rightarrow x} f(y) \quad \text{oder} \quad \text{epi } \bar{f} = \overline{\text{epi } f}$$

Thm.: $f \in \text{Conv } \mathbb{R}^n \Rightarrow \bar{f} \in \text{Conv } \mathbb{R}^n$, und $f = \bar{f}$ auf $\text{relint dom } f$.

Bew.: f konvex $\Rightarrow \text{epi } f$ konvex $\Rightarrow \text{epi } \bar{f} = \overline{\text{epi } f}$ konvex $\Rightarrow \bar{f}$ konvex.

Außerdem gilt $\bar{f} \leq f \neq \infty$ und $\bar{f} > -\infty$ überall (wegen Minorisierung durch affine Fkt.)

• Kürze $D = \text{aff dom } f$ ab. $f|_D$ ist stetig auf $\text{relint dom } f$,

also $\bar{f}|_D = \overline{f|_D} = f|_D$ auf $\text{relint dom } f$


$\Rightarrow f = \bar{f}$ auf $\text{relint dom } f$

□

Die konjugierte Funktion

Def: Die konjugierte Funktion (Legendre-Fenchel-Duale) einer Funktion $f: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{\infty\}$ (nicht notwendigerweise konvex) ist definiert als

$$f^*(s) = \sup_{x \in \mathbb{R}^n} s \cdot x - f(x), \quad s \in \mathbb{R}^n$$



Die Abbildung $f \mapsto f^*$ heißt Legendre-Fenchel-Transformation

Thm: (Fenchel-Young-Ungleichung) $f^*(y) + f(x) \geq x \cdot y \quad \forall x, y \in \mathbb{R}^n$

Bsp: $f(x) = \begin{cases} x \log x - x & , x \geq 0 \\ \infty & \text{sonst} \end{cases}$, $f^*(y) = e^y$, Young-Ungleichung $x \cdot y \leq x \log x - x + e^y \quad \forall x \geq 0, y \in \mathbb{R}$

Thm: Sei $f: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{\infty\}$, $f \neq \infty$, $f \geq g$ für eine affine Funktion g . f^* ist abgeschlossen & konvex.

Bew: f^* ist Supremum von affinen Funktionen $y \mapsto f_x(y) = y \cdot x - f(x) \Rightarrow f^*$ ist konvex.

$\text{epi } f^* = \bigcap_{x \in \mathbb{R}^n} \text{epi } f_x$ ist abgeschlossen als Schnitt von Halbräumen $\Rightarrow f^*$ ist abgeschlossen.

$f^* \neq \infty$: Sei $g(x) = s_0 \cdot x + r_0$, dann ist $f^*(s_0) = \sup_x s_0 \cdot x - f(x) \leq \sup_x s_0 \cdot x - g(x) = -r_0 \quad \square$

Konvexe Analysis: Konjugierte Funktion

Die Bikonjugierte

Thm: Sei $f: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{\infty\}$, $f \not\equiv \infty$, $f(x) \geq s_0 \cdot x + r_0$ für ein $(s_0, r_0) \in \mathbb{R}^n \times \mathbb{R}$.

Es gilt $\operatorname{epi} f^{**} = \overline{\operatorname{conv} \operatorname{epi} f}$, d.h. f^{**} ist die größte abgeschlossene konvexe Funktion unterhalb f („konvexe Relaxation“, „konvexe, unterhalb-stetige Hülle“).

Kor: $f^{**} = f \iff f$ ist abgeschlossen & konvex



Bew: Sei $\Sigma = \{(s, r) \in \mathbb{R}^n \times \mathbb{R} \mid f(x) \geq s \cdot x - r \forall x\} =$ Parameter der tragenden Hyperebenen von $\operatorname{epi} f$
 $\setminus \begin{pmatrix} s \\ -r \end{pmatrix} \cdot \begin{pmatrix} x \\ f(x) \end{pmatrix} \leq r$

$f^{**} = \sup_{(s, r) \in \Sigma} (s \cdot x - r) =$ sup über alle tragenden Hyperebenen der vertikalen Komponente in x

In der Tat, $(s, r) \in \Sigma \iff r \geq \sup_{x \in \mathbb{R}^n} s \cdot x - f(x) = f^*(s)$.

Somit gilt $\sup_{(s, r) \in \Sigma} (s \cdot x - r) = \sup_{(s, r) \text{ mit } f^*(s) \leq r} (s \cdot x - r) = \sup_s s \cdot x - f^*(s) = f^{**}(x)$.

$\operatorname{epi} f^{**} = \{(x, t) \mid f^{**}(x) \leq t\} = \{(x, t) \mid \sup_{(s, r) \in \Sigma} (s \cdot x - r) \leq t\} = \bigcap_{(s, r) \in \Sigma} \{(x, t) \mid s \cdot x - r \leq t\}$

= Schnitt aus allen Halbräumen, die $\operatorname{epi} f$ enthalten = $\overline{\operatorname{conv} \operatorname{epi} f}$ □

Konvexe Analysis: Konjugierte Funktion

Beispiele

Bsp: Wenn f konvex & differenzierbar, dann $f: \mathbb{R}^n \rightarrow \mathbb{R}$:

$$x^* = \operatorname{argmax}_x y \cdot x - f(x) \Leftrightarrow y = \nabla f(x^*) \quad \Rightarrow \quad f^*(y) = \nabla f(x^*) \cdot x^* - f(x^*)$$

• Sei $Q \in \mathbb{R}^{n \times n}$ symmetrisch positiv definit, $b \in \mathbb{R}^n$, $f(x) = \frac{1}{2} x^T Q x + b^T x$.

$$f^*(y) = \max_x y^T x - \frac{1}{2} x^T Q x - b^T x$$

$$y = \nabla f(x^*) = Q x^* + b \Rightarrow x^* = Q^{-1}(y - b) \Rightarrow f^*(y) = \frac{1}{2} (y - b)^T Q^{-1} (y - b)$$

• Spezialfall $Q = I, b = 0$, d.h. $f(x) = \frac{1}{2} \|x\|_2^2 \Rightarrow f^*(y) = \frac{1}{2} \|y\|_2^2$

• Fenchel-Ungleichung: $x^T Q x + y^T Q^{-1} y \geq 2 x \cdot y$ (Fall $b=0$)

$$\|x\|_2^2 + \|y\|_2^2 \geq 2 x \cdot y \quad (\text{Fall } b=0, Q=I)$$

• $f(x) = I_C(x) = \begin{cases} 0 & \text{falls } x \in C \subset \mathbb{R}^n \\ \infty & \text{sonst} \end{cases} \Rightarrow I_C^*(y) = \sup_{x \in C} y \cdot x =: b_C(y)$

„Indikatorfunktion“

„Frägerfunktion“

• Spezialfall $C = \text{Unterraum von } \mathbb{R}^n$: $b_C(y) = I_C^\perp(y)$

• $C = \mathcal{B}(0,1) = \{x \in \mathbb{R}^n \mid \|x\| \leq 1\} \Rightarrow b_C(y) = \|y\|_*$ für die duale Norm $\|y\|_* = \sup_{\|x\| \leq 1} |x \cdot y|$

• $\|\cdot\|_p$ & $\|\cdot\|_q$ mit $\frac{1}{p} + \frac{1}{q} = 1$ sind duale Normen $\Rightarrow b_{\mathcal{B}(0,1), \|\cdot\|_p} = \|\cdot\|_q$

Konvexe Analysis: Konjugierte Funktion

Rechenregeln

Thm: Seien $f, f_i: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{\infty\}$, $f, f_i \neq \infty$, $f, f_i \geq g, g_i$ für affine Funktionen g, g_i

$h(x)$	$h^*(y)$	$h(x)$	$h^*(y)$
$f(x) + r$	$f^*(y) - r$	$f(x) + y_0 \cdot x$	$f^*(y - y_0)$
$t f(x), t > 0$	$t f^*(\frac{y}{t})$	$\sum_{j=1}^m f_j(x_j), x = (x_1, \dots, x_m), x_j \in \mathbb{R}^{n_j}$	$\sum_{j=1}^m f_j^*(y_j), y = (y_1, \dots, y_m)$
$f(tx), t \neq 0$	$f^*(\frac{y}{t})$	$\leq f(x)$	$\geq f^*(y)$
$f(Ax), A \in \mathbb{R}^{n \times m}$ invertierbar	$f^*(A^{-T}y)$	$\alpha f_1 + (1-\alpha) f_2, \alpha \in [0, 1]$	$\leq \alpha f_1^* + (1-\alpha) f_2^*$
$f(x - x_0)$	$f^*(y) + y \cdot x_0$	<u>„Konvexität der Konjugation“</u>	

Def: Gegeben $f, g: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{\infty\}$, ist ihre Infimalconvolution gegeben durch

$$(f \square g)(x) = \inf_{y \in \mathbb{R}^n} f(y) + g(x - y) = \inf_{y \in \mathbb{R}^n} f(x - y) + g(y)$$

Moreau-Yosida-Approximation $f_\lambda = f \square \frac{1}{2\lambda} \|\cdot\|_2^2$

Thm: $(f \square g)^* = f^* + g^*$ **Achtung!** Wenn $f, g, f \square g^*$ abgeschl. & konvex, dann $(f+g)^* = f^* \square g^*$, aber nicht generell

Bew: $(f \square g)^*(y) = \sup_x x \cdot y - \inf_{x_1 + x_2 = x} (f(x_1) + g(x_2)) = \sup_{x_1, x_2} (x_1 + x_2) \cdot y - f(x_1) - g(x_2) = f^*(y) + g^*(y)$ □

Konvexe Analysis: Konjugierte Funktion

Koerzivität und die Konjugierte

Def.: Eine Funktion f heißt koerziv oder 0-koerziv, wenn $\lim_{\|x\| \rightarrow \infty} f(x) = \infty$

• f heißt 1-koerziv, wenn $\lim_{\|x\| \rightarrow \infty} \frac{f(x)}{\|x\|} = \infty$

Thm.: Sei $f: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{\infty\}$, $f \neq \infty$, $f(x) \geq y_0 \cdot x + r_0$. f 1-koerziv $\Rightarrow f^* < \infty$

Bew.: Sei $y \in \mathbb{R}^n$. (a) $\exists R > 0: f(x) \geq \|y\|_2 \|x\|_2 \quad \forall \|x\|_2 \geq R$

\Rightarrow Cauchy-Schwarz $x \cdot y - f(x) \leq 0 \quad \forall \|x\|_2 \geq R \Rightarrow \sup_{\|x\|_2 \geq R} x \cdot y - f(x) \leq 0$

(b) $\sup_{\|x\|_2 < R} x \cdot y - f(x) \leq \sup_{\|x\|_2 < R} x \cdot y - y_0 \cdot x - r_0 \leq R \|y - y_0\|_2 - r_0$

(a) & (b) $\Rightarrow f^*(y) \leq \max(0, R \|y - y_0\|_2 - r_0)$ □

Thm.: $F_1 := \{\text{Trägerfunktionen konvexer Mengen}\} = \{\text{abgeschlossene konvexe positiv homogene Fkt}\} =: F_2$

Bew.: $z \in F_1 \Leftrightarrow z = I_C^*$ für ein konvexes $C \subset \mathbb{R}^n \Rightarrow z$ ist abgchr. konvex mit $z(\lambda x) = \lambda z(x)$ für $\lambda \geq 0 \Leftrightarrow z \in F_2$

$$z \in F_2 \Rightarrow z^*(y) = \sup_x x \cdot y - z(x) = \sup_{\lambda \geq 0, x} \lambda x \cdot y - z(\lambda x) = \sup_{\lambda \geq 0} \lambda z^*(y) = I_C(y)$$

für $C = \{y \in \mathbb{R}^n \mid z^*(y) = 0\}$; da z^* konvex, ist auch C konvex $\Rightarrow z \in F_1$ □

Kor.: $f \in \text{Conv} \mathbb{R}^n$ pos. homogen $\Rightarrow \text{cl } f = z_C$ für die abgeschl. konvexe Menge $C = \{x \in \mathbb{R}^n \mid x \cdot y \leq f(y) \forall y \in \mathbb{R}^n\}$

Bew.: $\text{cl } f \in F_2 \Rightarrow \text{cl } f \in F_1 \Rightarrow \text{cl } f = z_C$ für ein konvexes $C \subset \mathbb{R}^n$


$$f^*(x) = z_C^*(x) = I_C(x) = \begin{cases} \infty & \text{wenn } \exists y \in \mathbb{R}^n: x \cdot y > f(y) \\ 0 & \text{sonst} \end{cases}$$
 □

Konvexe Analysis: Das Subdifferential

Das Subdifferential

Def.: Das Subdifferential einer Funktion $f \in \text{Conv } \mathbb{R}^n$ ist $\partial f(x) = \{s \in \mathbb{R}^n \mid f(y) \geq f(x) + s \cdot (y-x) \forall y \in \mathbb{R}^n\}$

• Elemente von ∂f heißen Subgradienten



Kor.: $\partial f(x) \neq \emptyset$ für alle $x \in \text{rint dom } f$ (siehe früheren Beweis)

Thm.: $\partial f(x)$ ist abgeschlossen und konvex für alle $x \in \text{dom } f$ (für $x \notin \text{dom } f$, $\partial f(x) = \emptyset$)

Bew.: $\partial f(x) = \bigcap_{y \in \mathbb{R}^n} \{s \in \mathbb{R}^n \mid f(y) \geq f(x) + s \cdot (y-x)\}$ ist der Schnitt von Halbräumen. \square


Thm.: $\partial f(x)$ ist beschränkt für alle $x \in \text{int dom } f$. *notwendig?*

Bew.: Es gibt $\varepsilon > 0$ sodass f auf $B(x, \varepsilon)$ Lipschitz-stetig ist (Erinnerung: $f \in C_{loc}^{0,1}$!).

Sei $y = x + \frac{\delta s}{|s|}$ für $s \in \partial f(x)$, $\delta \in (0, \varepsilon)$, dann

$$f(x) + \underset{\uparrow}{L\delta} \geq f(y) \geq f(x) + s \cdot \frac{\delta s}{|s|} = f(x) + \delta |s| \Rightarrow |s| \leq L \quad \square$$

Lipschitz-Konstante $s \in \partial f(x)$



∂f ist:
• nicht leer
• kompakt
• konvex

Konvexe Analysis: Das Subdifferential

Subdifferential und Richtungsableitung

Def: Sei $f \in \text{Conv } \mathbb{R}^n$. Die Richtungsableitung in Richtung $v \in \mathbb{R}^n$ an $x \in \text{dom } f$ ist definiert als

$$\partial_v f(x) = \lim_{\lambda \downarrow 0} \frac{f(x+\lambda v) - f(x)}{\lambda} = \lim_{\lambda \rightarrow 0, \lambda > 0} \frac{f(x+\lambda v) - f(x)}{\lambda}$$

Bem: $\partial_{(\cdot)} f(x)$ für $f \in \text{Conv } \mathbb{R}^n$ ist konvex: $\partial_{\frac{v_1 + v_2}{2}} f(x) = \lim_{\lambda \rightarrow 0, \lambda > 0} \frac{f(x + \lambda \frac{v_1 + v_2}{2}) - f(x)}{\lambda} \subseteq \lim_{\lambda \rightarrow 0, \lambda > 0} \left(\frac{f(x + \lambda v_1) - f(x)}{\lambda} + \frac{f(x + \lambda v_2) - f(x)}{\lambda} \right) / 2$

Thm: Sei $f \in \text{Conv } \mathbb{R}^n, x \in \text{dom } f$. $s \in \partial f(x) \Leftrightarrow \partial_v f(x) \geq s \cdot v \quad \forall v \in \mathbb{R}^n$

$\cdot \text{cl}(\partial_{(\cdot)} f(x)) : \mathbb{R}^n \rightarrow \mathbb{R}$ ist die Trägerfunktion der abgeschlossenen konvexen Menge $\partial f(x), v \mapsto \sup_{s \in \partial f(x)} s \cdot v$

Bew: $s \in \partial f(x) \Leftrightarrow \frac{f(x+\lambda v) - f(x)}{\lambda} \geq s \cdot v \quad \forall v \in \mathbb{R}^n, \lambda > 0 \Leftrightarrow \partial_v f(x) \geq s \cdot v \quad \forall v \in \mathbb{R}^n$

$\cdot \partial_{(\cdot)} f(x)$ ist pos. homogen

$$\Leftrightarrow \text{cl}(\partial_{(\cdot)} f(x)) = \mathcal{C} \quad \text{für } \mathcal{C} = \{s \in \mathbb{R}^n \mid s \cdot v \leq \partial_v f(x) \quad \forall v \in \mathbb{R}^n\} = \partial f(x) \quad \square$$

Thm: Sei $f \in \text{Conv } \mathbb{R}^n$. $\partial f(x)$ ist nichtleer & beschränkt $\Leftrightarrow x \in \text{int dom } f$

Bew: $\partial f(x) \neq \emptyset$ & beschr. $\Leftrightarrow |\mathcal{C}_{\partial f(x)}| < \infty$ überall $\Leftrightarrow \text{cl}(\partial_{(\cdot)} f(x)) < \infty$

\Leftrightarrow
1
Konvexität von $\partial_{(\cdot)} f(x)$ $\partial_{(\cdot)} f(x) < \infty \Leftrightarrow x \in \text{int dom } f \quad \square$

Konvexe Analysis: Das Subdifferential

Beziehung zu Ableitung

Thm: Sei $f \in \text{Conv} \mathbb{R}^n$. f ist differenzierbar in x mit $\nabla f(x) = s \iff \partial f(x) = \{s\}$

Bew: " \Rightarrow ": Sei $\tilde{s} \in \partial f(x)$, $v \in \mathbb{R}^n$. Subdifferential: $f(x+v) \geq f(x) + \tilde{s} \cdot v$

$$\text{-- Taylor} \quad : \quad f(x+v) = f(x) + \nabla f(x) \cdot v + o(|v|)$$

$$0 \geq (\tilde{s} - \nabla f(x)) \cdot v + o(|v|) \quad \forall v \in \mathbb{R}^n$$

$$" \Leftarrow ": $(\text{cl } \partial_{(\cdot)} f(x))(v) = \partial_{\nabla f(x)}(v) = s \cdot v$$$

$\Rightarrow \partial_v f(x) = s \cdot v \quad \forall v \in \mathbb{R}^n$ (da für g konvex $\text{cl } g \neq g$ höchstens auf rel. l. bdy dom. g)

$$\Rightarrow \nabla f(x) = s$$

□

Thm: Sei $f \in \text{Conv} \mathbb{R}^n$ $x^* = \underset{x}{\text{argmin}} f(x) \iff 0 \in \partial f(x^*)$

Bew: $x^* = \underset{x}{\text{argmin}} f(x)$

$$\Leftrightarrow f(x) \geq f(x^*) \quad \forall x \in \mathbb{R}^n$$


$$\Leftrightarrow f(x) \geq f(x^*) + 0 \cdot (x - x^*) \quad \forall x \in \mathbb{R}^n$$

$$\Leftrightarrow 0 \in \partial f(x^*)$$

□

Konvexe Analysis: Das Subdifferential

Beispiele und Eigenschaften



Bsp: $f(x) = |x|, x \in \mathbb{R} \Rightarrow \partial f(x) = \begin{cases} \{\text{sign } x\}, & x \neq 0 \\ [-1, 1], & x = 0 \end{cases}$

$f(x) = |x| = \|x\|_2, x \in \mathbb{R}^n \Rightarrow \partial f(x) = \begin{cases} \{x/|x|\}, & x \neq 0 \\ \mathbb{B}_{\| \cdot \|_2}(0, 1), & x = 0 \end{cases}$

$f(x) = \|x\|, x \in \mathbb{R}^n \Rightarrow \partial f(0) = \{s \in \mathbb{R}^n \mid \|y\| \geq s \cdot y \ \forall y \in \mathbb{R}^n\} = \{s \in \mathbb{R}^n \mid \max_{\|y\|=1} s \cdot y \leq 1\} = \mathbb{B}_{\| \cdot \|_*}(0, 1)$

$f(x) = \|x\|_{\infty}, x \in \mathbb{R}^n \Rightarrow \partial f(0) = \mathbb{B}_{\| \cdot \|_{\infty}}(0, 1) = \text{conv}(\pm e_1, \dots, \pm e_n), \quad e_i = (0, \dots, 0, 1, 0, \dots, 0)$

Thm: Seien $f_1, \dots, f_m \in \text{Conv } \mathbb{R}^n, t_1, t_2 > 0$, dann gilt

(a) $\partial(t_1 f_1 + t_2 f_2)(x) = t_1 \partial f_1(x) + t_2 \partial f_2(x) = \{t_1 s_1 + t_2 s_2 \mid s_1 \in \partial f_1(x), s_2 \in \partial f_2(x)\}$

$\forall x \in \text{int}(\text{dom } f_1 \cap \text{dom } f_2)$ („Moreau-Rockafellar“) (int ist notwendig! z.B. $f_1 = I_{\{y \geq x^2\}}, f_2 = I_{\{y \leq 0\}}$)

(b) $\partial(\max_{i=1, \dots, m} f_i)(x) = \text{conv}(\cup_{j \in J_x} \partial f_j(x))$ mit $J_x = \{j \mid f_j(x) = \max_{i=1, \dots, m} f_i(x)\}$

Bew: (b) ohne Beweis (siehe z.B. Bauschke & Combettes)

(a) „ \supseteq “: Sei $s = t_1 s_1 + t_2 s_2$ mit $s_1 \in \partial f_1(x), s_2 \in \partial f_2(x)$

$$t_1 f_1(y) + t_2 f_2(y) \geq t_1 (f_1(x) + s_1 \cdot (y-x)) + t_2 (f_2(x) + s_2 \cdot (y-x))$$

$$= (t_1 f_1(x) + t_2 f_2(x)) + s \cdot (y-x) \quad \forall y \in \mathbb{R}^n$$


Konvexe Analysis: Das Subdifferential

Beispiele und Eigenschaften (Forts.)

„C“: Sei $s \in \partial(t_1 f_1 + t_2 f_2)(x)$, setze $g_1 = t_1 f_1 - t_1 f_1(x) - s(\cdot - x)$, $g_2 = t_2 f_2 - t_2 f_2(x)$
 $\Rightarrow 0 \in \partial(g_1 + g_2)(x)$, $0 = g_1(x) = g_2(x)$, $\begin{cases} \partial g_2(x) = \partial t_2 f_2(x) = t_2 \partial f_2(x) \\ \partial g_1(x) = \partial t_1 f_1(x) - s = t_1 \partial f_1(x) - s \end{cases}$
 \Rightarrow zu zeigen: $0 \in \partial g_1(x) + \partial g_2(x)$ warum?

- $\Lambda_1 = \text{epi } g_1$, $\Lambda_2 = -\text{epi } g_2$ sind beide konvex mit nichtleerem Inneren (warum?)
- $\text{int } \Lambda_1 \cap \Lambda_2 = \emptyset$ (da $g_1 + g_2 \geq 0$, somit $g_1 \geq -g_2$)

$\Rightarrow \exists 0 \neq \begin{pmatrix} q \\ a \end{pmatrix} \in \mathbb{R}^h \times \mathbb{R} : \sup_{(y,r) \in \Lambda_1} q \cdot y + ar \leq \inf_{(y,r) \in \Lambda_2} q \cdot y + ar$



- Wegen $(x, 0) \in \Lambda_1 \cap \Lambda_2$ gilt sogar $\max_{(y,r) \in \Lambda_1} q \cdot y + ar = q \cdot x = \min_{(y,r) \in \Lambda_2} q \cdot y + ar$
- $a < 0$: $(x, r) \in \Lambda_1 \forall r > 0 \Rightarrow a \leq 0$, und $a = 0$ würde implizieren $\sup_{y \in \text{dom } f_1} q \cdot y \leq \inf_{y \in \text{dom } f_2} q \cdot y$ und dies widerspricht $\text{int}(\text{dom } f_1 \cap \text{dom } f_2) \neq \emptyset$

Setze $p = -\frac{q}{a} \Rightarrow \underbrace{\max_{(y,r) \in \Lambda_1} p \cdot y - r = p \cdot x}_{\text{links}} = \underbrace{\min_{(y,r) \in \Lambda_2} p \cdot y - r}_{\text{rechts}}$

wähle $r = g_1(y) \Rightarrow p \in \partial g_1(x)$ wähle $r = -g_2(y) \Rightarrow -p \in \partial g_2(x)$ \square

Konvexe Analysis: Das Subdifferential Subdifferential und Konjugierte

Thm: Sei $f \in \text{Conv } \mathbb{R}^n$. $s \in \partial f(x) \Leftrightarrow f^*(s) + f(x) = s \cdot x$

Bew: $f^*(s) \geq s \cdot x - f(x)$ (Fenchel-Ungleichung)

$$s \in \partial f(x) \Leftrightarrow s \cdot y - f(y) \leq s \cdot x - f(x) \quad \forall y \in \mathbb{R}^n$$

$$\Leftrightarrow f^*(s) \leq s \cdot x - f(x)$$

□

Kor: Sei $f \in \text{Conv } \mathbb{R}^n$ abgeschlossen. $s \in \partial f(x) \Leftrightarrow x \in \partial f^*(s)$

Bew: $s \in \partial f(x) \Leftrightarrow f^*(s) + f(x) = s \cdot x \Leftrightarrow f^{**}(x) + f^*(s) = s \cdot x \Leftrightarrow x \in \partial f^*(s)$ □

Kor: Sei $f \in \text{Conv } \mathbb{R}^n$ abgeschlossen, dann gilt

$$x^* = \underset{x}{\text{argmin}} f(x) \Leftrightarrow 0 \in \partial f(x^*) \Leftrightarrow x^* \in \partial f^*(0).$$

Insbesondere gilt: Ist f^* differenzierbar in 0, ist der Minimierer eindeutig.

Slaters Bedingung („constraint qualification“)

Thm: (Slater) Betrachte $\min_{x \in \mathbb{R}^n} f_0(x)$ s.d. $f_1(x), \dots, f_m(x) \leq 0, h_1(x), \dots, h_p(x) = 0$ (P)

für f_0, \dots, f_m konvex, h_1, \dots, h_p affin (d.h. $h_1(x) = \dots = h_p(x) = 0 \Leftrightarrow Ax = b$), $\mathcal{D} = \bigcap_{i=0}^m \text{dom } f_i$.

Wenn (P) strikt zulässig ist, d.h. $\exists \tilde{x} \in \text{relint } \mathcal{D}$ mit $f_i(\tilde{x}) < 0, i=1, \dots, m, A\tilde{x} = b$,

dann gilt starke Dualität, d.h. $p^* = d^*$.

Beweis ohne diese Annahmen später

Bew: Vereinfachende Annahmen: $\text{relint } \mathcal{D} = \text{int } \mathcal{D}$, $\text{rank } A = p$

(Beides kann erreicht werden durch Übergang zu einem äquivalenten Problem:

streiche linear abhängigen Zeilen aus $Ax = b$ & schränke ein auf aff. \mathcal{D} .)

Beachte: das duale Problem ändert sich hierdurch!)

• \tilde{x} ist zulässig $\Rightarrow p^* < \infty$. OBdA $p^* > -\infty$ (sonst wäre $d^* = -\infty$ wegen schwacher Dualität)

• definiere $M = \{(u, v, t) \in \mathbb{R}^m \times \mathbb{R}^p \times \mathbb{R} \mid \exists x \in \mathcal{X}: f_i(x) \leq u_i, i=1, \dots, m, h_i(x) = v_i, i=1, \dots, p, f_0(x) \leq t\}$

$N = \{(0, 0, s) \in \mathbb{R}^m \times \mathbb{R}^p \times \mathbb{R} \mid s < p^*\}$

$\Rightarrow M, N$ konvex, nichtleer, disjunkt (sonst gäbe es ein zulässiges x mit $f_0(x) < p^*$)

Konvexe Analysis: (Starke) Dualität

Slaters Bedingung (Forts.)

• es existiert trennende Hyperebene, d.h. $(\mu, \lambda, \nu) \neq 0, \alpha \in \mathbb{R}$ sodass

$$(a) \quad \mu \cdot u + \lambda \cdot v + \nu t \geq \alpha \quad \forall (u, v, t) \in M$$

$$(b) \quad \mu \cdot u + \lambda \cdot v + \nu t \leq \alpha \quad \forall (u, v, t) \in N$$

• (a) $\Rightarrow \mu \geq 0$ (komp.-weise), $\nu \geq 0$ (sonst wäre $\mu \cdot u + \nu t$ nach unten unbeschränkt in M)

$$(b) \Rightarrow \forall p^* \leq \alpha$$

• Zusammen: $\sum_{i=1}^m \mu_i f_i(x) + \sum_{i=1}^p \lambda_i h_i(x) + \nu f_0(x) \geq \alpha \geq \nu p^* \quad \forall x \in \mathcal{D}$

$$\text{Fall } \nu > 0: \Rightarrow L(x, \frac{\mu}{\nu}, \frac{1}{\nu}) \geq p^* \quad \forall x \in \mathcal{D} \Rightarrow g(\mu/\nu, \lambda/\nu) \geq p^* \Rightarrow d^* \geq p^*$$

$$\text{Fall } \nu = 0: \Rightarrow \sum_{i=1}^m \mu_i f_i(\tilde{x}) \geq 0 \quad \Rightarrow \mu_i \geq 0, f_i(\tilde{x}) < 0 \quad \mu = 0$$

$$\Rightarrow \sum_{i=0}^p \lambda_i h_i(x) \geq 0 \quad \forall x \in \mathcal{D}$$

Dies ist nicht möglich, denn $\sum_{i=0}^p \lambda_i h_i(\tilde{x}) = 0 = \lambda^T (A \tilde{x} - b)$ zusammen mit

$\text{rank } A = p$ impliziert die Existenz eines $x \in \mathcal{D}$ mit $\sum_{i=0}^p \lambda_i h_i(x) < 0$ \hookrightarrow

$\Rightarrow \nu = 0$ ist nicht möglich □

Kor: $(\mu^*, \lambda^*) = (\mu/\nu, \lambda/\nu)$ sind dual optimal!


Konvexe Analysis: (Starke) Dualität

Slaters Bedingung - geometrische Intuition

$$\mathcal{G} = \{(u, v, t) \in \mathbb{R}^{m+p+n} \mid \exists x \in \mathcal{X}, f_i(x) = u_i, h_i(x) = v_i, f_0(x) = t\}$$

Erinnerung: $g(\mu, \lambda) = \inf_x f_0(x) + \sum_{i=1}^m \mu_i f_i(x) + \sum_{i=1}^p \lambda_i h_i(x) = \inf_{(u,v,t) \in \mathcal{G}} t + \mu^T u + \lambda^T v \quad ; \quad \mu \geq 0$


Bsp: $\min_x f_0(x)$ s.d. $f_n(x) \leq 0$




(Sei $h_c(u, v) = -\mu^T u - \lambda^T v + c$
 $\Rightarrow \inf\{c \mid \exists (u, v): (u, v, h_c(u, v)) \in \mathcal{G}\}$
 $= \inf\{t + \mu^T u + \lambda^T v \mid (u, v, t) \in \mathcal{G}\}$)

Slaters Bedingung gilt

Trennende Hyperebene zw. M & N mit Steigung $-\mu$




Slaters Bedingung gilt




M & N können nicht getrennt werden durch eine Hyperebene mit endlicher Steigung

nichtkonvexes Problem



kein strikt zulässiger Punkt



Konvexe Analysis: (Starke) Dualität

Folgerungen aus constraint qualifications

Thm: Starke Dualität gilt sogar, wenn es ein zulässiges $\bar{x} \in \text{relint } \mathcal{D}$ mit $f_i(\bar{x}) < 0$ nur für alle nichtaffinen f_i .

Bew: Rockafellar: Convex Analysis, Thm. 28.2 □

Insbesondere gilt immer starke Dualität, wenn alle Nebenbedingungen affin und f_0 konvex sind, also für alle LP & QP!

Thm: Wenn das duale Problem zulässig ist und eine constraint qualification gilt (d.h. eine Bedingung wie Slater, die starke Dualität impliziert), dann gelten die KKT-Bedingungen für ein konvexes Optimierungsproblem (P) an einem optimalen Punkt x , d.h. $\exists \mu, \lambda$ s.d.

$$f_1(x), \dots, f_m(x) \leq 0, h_1(x) = \dots = h_p(x) = 0, \mu \geq 0, \mu^T \begin{pmatrix} f_1(x) \\ \vdots \\ f_m(x) \end{pmatrix} = 0, \\ 0 \in \partial \left[f_0 + \sum_{i=1}^m \mu_i f_i + \sum_{i=1}^p \lambda_i h_i \right] (x)$$

Bew: starke Dualität \Rightarrow Sattelpunkteigenschaft von $L \xrightarrow{\gamma} x$ minimiert $L(\cdot, \mu, \lambda)$

wähle μ, λ dual optimal (möglich, wie zuvor gezeigt)

Konvexe Analysis: (Starke) Dualität

Fenchel-Rockafellar-Dualität

Thm: (Fenchel-Rockafellar) Seien $f, g \in \text{Conv } \mathbb{R}^n$. Wenn

(a) $\text{relint dom } f \cap \text{relint dom } g \neq \emptyset$ oder

(b) $\text{relint dom } f^* \cap \text{relint dom } g^* \neq \emptyset$ und f, g abgeschlossen,

$$\text{dann } \inf_{x \in \mathbb{R}^n} f(x) + g(x) = \sup_{y \in \mathbb{R}^n} -g^*(-y) - f^*(y)$$

Unter (a) wird Sup angenommen, unter (b) das inf.

$$\text{Bew.: } \forall x, y \in \mathbb{R}^n: f(x) + f^*(y) \geq x \cdot y \geq -g(x) - g^*(-y) \quad (\text{Fenchel-Ungl.})$$

$$\Rightarrow \inf_x (f(x) + g(x)) \geq \sup_y -g^*(-y) - f^*(y)$$

• wenn $\inf = -\infty$, dann auch $\sup = -\infty$; O.B.d.A. dürfen wir daher annehmen $-\infty < \alpha = \inf_x f(x) + g(x)$

• Wenn (a) gilt, reicht es, die Existenz eines $y \in \mathbb{R}^n$ zu zeigen mit $-g^*(-y) - f^*(y) \geq \alpha$

• Setze $C = \{(x, v) \in \mathbb{R}^n \times \mathbb{R} \mid v \geq f(x)\}$

$$D = \{(x, v) \in \mathbb{R}^n \times \mathbb{R} \mid v \leq -g(x) + \alpha\}$$

$\Rightarrow C, D$ konvex & $\text{relint } C = \{(x, v) \mid x \in \text{relint dom } f, f(x) < v\}$ ist disjunkt von D

Konvexe Analysis: (Starke) Dualität

Fenchel-Rockafellar-Dualität (Forts.)

• \exists trennende Hyperebene, d.h. $(s, t) \in \mathbb{R}^n \times \mathbb{R}$ mit $\sup_{(x,y) \in D} s \cdot x + t \leq \inf_{(x,y) \in C} s \cdot x + t$.



Beacht: $t \neq 0$ (sonst würden die Projektionen von D & C , $\text{dom} f$ & $\text{dom} g$, getrennt)

\Rightarrow trennende Hyperebene ist Graph einer affinen Funktion $h(x) = \tilde{s} \cdot x + \beta$
 $\tilde{s} = -s/t$

$\Rightarrow f(x) \geq \tilde{s} \cdot x + \beta \geq -g(x) + \alpha \quad \forall x \in \mathbb{R}^n$

linke Ungl. impliziert $-\beta \geq \sup_x \tilde{s} \cdot x - f(x) = f^*(\tilde{s})$
 rechte Ungl. impliziert $\alpha - \beta \leq \inf_x \tilde{s} \cdot x + g(x) = -g^*(-\tilde{s})$
 $\Rightarrow \alpha \leq -g^*(-\tilde{s}) - f^*(\tilde{s})$

• für (b) folgt alles aus (a) unter Benutzung von $f = f^{**}$, $g = g^{**}$. □



Fenchel-Rockafellar-Dualität: Erweiterungen

Das Resultat kann in verschiedene Richtungen verschärft & verallgemeinert werden, z.B.

- Wenn g stückweise affin ist, dürfen wir $\text{relint dom } g^{(*)}$ ersetzen durch $\text{dom } g^{(*)}$.

(Rockafellar, Thm. 31.1)

- Wenn $A: \mathbb{R}^n \rightarrow \mathbb{R}^m$ ein linearer Operator ist, gilt $\inf_{x \in \mathbb{R}^n} f(x) + g(Ax) = \sup_{y \in \mathbb{R}^m} -g^*(-y) - f^*(A^T y)$, sofern

(a) $\exists x \in \text{relint dom } f$ mit $Ax \in \text{relint dom } g$ oder

(b) $\exists y \in \text{relint dom } g^*$ mit $-A^T y \in \text{relint dom } f^*$ und f, g abgeschlossen.

Unter (a) wird das sup, unter (b) das inf angenommen.

(Rockafellar, Cor 31.2.1)

- Unter denselben Bedingungen gilt $\inf_{x \in \mathbb{R}^n} f(x) + g(Ax) = \inf_{x \in \mathbb{R}^n} \sup_{y \in \mathbb{R}^m} x^T A^T y + f(x) - g^*(y)$,

und man darf inf & sup vertauschen.

Bew: $\inf_{x \in \mathbb{R}^n} (f(x) + g(Ax)) \geq \inf_{x \in \mathbb{R}^n} (f(x) + g^{**}(Ax)) = \inf_{x \in \mathbb{R}^n} \sup_{y \in \mathbb{R}^m} f(x) + x^T A^T y - g^*(y)$

$$\geq \sup_{y \in \mathbb{R}^m} \inf_{x \in \mathbb{R}^n} f(x) + x^T A^T y - g^*(y) = \sup_{y \in \mathbb{R}^m} -f^*(-A^T y) - g^*(y) = \sup_{y \in \mathbb{R}^m} -f^*(A^T y) - g^*(-y)$$

\Rightarrow starke Dualität impliziert Gleichheit

□

Konvexe Analysis: (Starke) Dualität

Fenchel-Rockafellar-Dualität & Lagrange-Dualität

Bem: Für konvexe f_0 , C_I , affine C_E ist Lagrange-Dualität ein Spezialfall von Fenchel-Rockafellar-Dualität:

$$\text{Wähle } f((x, u, v)) = f_0(x) + I_{\{C_I(x) \leq u, C_E(x) = v\}}((x, u, v)), \quad h((u, v)) = I_{\{0\} \times [0, \infty)^m \times \{0\}}((u, v))$$

$$\Rightarrow f^*((y, \mu, \lambda)) = \sup_{x, u, v, u \geq C_I(x), v = C_E(x)} y \cdot x + \mu \cdot u + \lambda \cdot v - f_0(x), \quad h^*((y, \mu, \lambda)) = I_{\{0\} \times [0, \infty)^m}((y, \mu, \lambda))$$

Slater $\Rightarrow \exists x \in \text{relint } \mathcal{D}$ mit $f((x, -z, 0)) < \infty$ für $z > 0$ klein genug (komp.-weise)


$$\Rightarrow \underbrace{\text{relint dom } h}_{\mathbb{R}^n \times (-\infty, 0)^m \times \{0\}} \cap \text{relint dom } f \neq \emptyset$$

$$\Rightarrow p^* = \inf_{x, C_I(x) \leq 0, C_E(x) = 0} f_0(x) = \inf_{(x, u, v)} f((x, u, v)) + h((u, v)) \stackrel{\text{Fenchel-Rockafellar}}{=} \max_{(y, \tilde{\mu}, \tilde{\lambda})} -f^*((y, \tilde{\mu}, \tilde{\lambda})) - h^*(-(y, \tilde{\mu}, \tilde{\lambda}))$$

$$= \max_{\tilde{\mu} \leq 0, \tilde{\lambda}} \inf_{\substack{x, u, v \\ u \geq C_I(x), v = C_E(x)}} -\tilde{\mu} \cdot u - \tilde{\lambda} \cdot v + f_0(x) = \max_{\tilde{\mu} \leq 0, \tilde{\lambda}} \underbrace{\inf_x -\tilde{\mu} \cdot C_I(x) - \tilde{\lambda} \cdot C_E(x) + f_0(x)}_{= g(-\tilde{\mu}, -\tilde{\lambda})} = \max_{\mu \geq 0, \lambda} g(\mu, \lambda)$$

$$= d^*$$

Dies impliziert auch die Existenz eines dual optimalen Punktes (μ, λ) . □



Optimierungsalgorithmen: Simplex-Verfahren (lineare Optimierung)

Grundlagen lineare Programme

Def.: Ein lineares Programm (LP) in Standardform ist gegeben durch

*Die erhält man Standardform? Hinweis: - neue Variablen für Ungl. - NB
- $x = x_+ - x_-$*

$$\min_{x \in \mathbb{R}^n} c x \quad \text{s.d. } Ax = b, \quad x \geq 0 \text{ komponentenweise} \quad (\text{LP})$$

wobei $c \in \mathbb{R}^{1 \times n}$, $A \in \mathbb{R}^{p \times n}$ hat vollen Rang, $p < n$.

Es kann aufgefasst werden als Minimierung von $c x$ über dem konvexen Polyeder $K = \{x \geq 0 \mid Ax = b\}$.

• Sei $B \in \mathbb{R}^{p \times p}$ eine Matrix, die aus p linear unabhängigen Spalten $a_i, i \in J \subset \{1, \dots, n\}$ von A besteht.

Ein Punkt $x \in \mathbb{R}^n$ mit $x_i = 0 \forall i \notin J$ und $Ax = b$ heißt Basispunkt bzgl. Basis B .

• Ein zulässiger Punkt x erfüllt $Ax = b$ & $x \geq 0$.

Wir wollen annehmen, dass jeder zulässige Basispunkt $x_i \neq 0 \forall i \in J$ erfüllt.

Thm.: Wenn (LP) optimale Punkte besitzt, ist mindestens einer ein Extrempunkt von K .

Bew.: Sei $\text{ext } K = \{x_1, \dots, x_k\}$, dann $\forall x \in K \exists \alpha_1, \dots, \alpha_k \geq 0: \alpha_1 + \dots + \alpha_k = 1, x = \alpha_1 x_1 + \dots + \alpha_k x_k$.

Sei $z_0 = \min_{i=1, \dots, k} c x_i$, dann $c x = \alpha_1 (c x_1) + \dots + \alpha_k (c x_k) \geq \alpha_1 z_0 + \dots + \alpha_k z_0 = z_0 \Rightarrow z_0$ ist Min. \square

Beachte: Dies ist unabhängig von Standardform!




Optimierungsalgorithmen: Simplex-Verfahren (lineare Optimierung)

Beispiele

Bsp: $\min_{x \in \mathbb{R}^2}$

$$\underbrace{(1 \ 2)}_c x$$


s. d. $\underbrace{(1 \ 1)}_A x = \underbrace{2}_b, x \geq 0$



$\min_{x \in \mathbb{R}^3}$

$$(1 \ 2 \ 3)x$$


s. d. $(1 \ 1 \ 1)x = 3, x \geq 0$



$\min_{x \in \mathbb{R}^3}$

$$(1 \ 2 \ 3)x$$

s. d. $\begin{pmatrix} 1 & 1 & 1 \\ 2 & 1 & 1 \end{pmatrix} x = \begin{pmatrix} 3 \\ 4 \end{pmatrix}, x \geq 0$



Beachte: Extrempunkte von K haben n-rank A Nullen! Sind sie Basispunkte? Optimum?

Optimierungsalgorithmen: Simplex-Verfahren (lineare Optimierung)

Basispunkte & Extrempunkte

Thm: $x \in \text{ext } K \iff x$ ist zulässiger Basispunkt

Bew: " \Rightarrow ". OBdA seien die Nichtnull-Einträge von x gegeben durch x_1, \dots, x_k

$$\Rightarrow b = x_1 a_1 + \dots + x_k a_k \quad \text{mit } x_i > 0$$

Spalten von A

• Nimm an, a_1, \dots, a_k seien linear abhängig, d.h. $0 = y_1 a_1 + \dots + y_k a_k$ für y_i nicht alle = 0

• setze $y = (y_1, \dots, y_k, 0, \dots, 0) \in \mathbb{R}^n$. Es existiert $\varepsilon > 0$ mit $x + \varepsilon y \geq 0$, $x - \varepsilon y \geq 0$.

$$\Rightarrow x = \frac{1}{2}(x + \varepsilon y) + \frac{1}{2}(x - \varepsilon y), \text{ was } x \in \text{ext } K \text{ widerspricht } \downarrow$$

" \Leftarrow ". OBdA nimm $x = (x_1, \dots, x_p, 0, \dots, 0)$ an (d.h. a_1, \dots, a_p bilden eine Basis)

• Nimm an, es gibt $y, z \in K$, $\alpha \in (0, 1)$ mit $x = \alpha y + (1 - \alpha)z$

$$\Rightarrow y_{p+1} = \dots = y_n = 0 \ \& \ z_{p+1} = \dots = z_n = 0 \quad (\text{wegen } y, z \geq 0)$$

$$\Rightarrow y_1 a_1 + \dots + y_p a_p = b \ \& \ z_1 a_1 + \dots + z_p a_p = b$$

• Da a_1, \dots, a_p linear unabhängig sind, folgt $y = z$

$$\Rightarrow x \in \text{ext } K$$

□

Optimierungsalgorithmen: Simplex-Verfahren (lineare Optimierung)

Idee des Simplex-Verfahrens

Extk = # zulässige Basispunkte \leq # Möglichkeiten, p lin. unabh. Spalten aus A zu wählen
↑ Anzahl von
$$\leq \binom{n}{p} = \frac{n!}{p!(n-p)!}$$

Um einen optimalen Punkt zu finden, muss man nur höchstens $\binom{n}{p}$ Extrempunkte testen.

Das Simplex-Verfahren macht dies etwas effizienter, indem es eine Folge x^k von Extrempunkten erzeugt, wobei der Funktionswert in jedem Schritt abnimmt.

Algorithmus (Simplex-Verfahren)

0) (Initialisierung) wähle zulässigen Basispunkt / Extrempunkt

- wähle Spalten a_{i_1}, \dots, a_{i_p} , $i_j \in f^0$, von A als Basis
- setze $x_l^0 = 0$ für $l \notin f^0$ und löse $Ax^0 = b \Leftrightarrow a_{i_1} x_{i_1}^0 + \dots + a_{i_p} x_{i_p}^0 = b$ für $x_{i_1}^0, \dots, x_{i_p}^0$
- wenn der Basispunkt unzulässig ist, wähle andere Basis
- Beachte: Wir können $Ax=b$ mittels Gauß-Elimination transformieren, sodass $a_{ij} = e_j$
- Beachte: Superskriptum = Iteration; Subskriptum = Zeilen-/Spaltenindex

Optimierungsalgorithmen: Simplex-Verfahren (lineare Optimierung)

Algorithmus des Simplex-Verfahrens

iteriere:

1) wähle eine Abstiegsrichtung

• Sei x^{k+1} der zu findende Iterationspunkt

• $x_{i_1}^{k+1}, \dots, x_{i_p}^{k+1}$ für $i_1, \dots, i_p \in f^k$ kann man ausdrücken als Fkt. von x_e^{k+1} , $e \notin f^k$: $x_{i_j}^{k+1} = \alpha_{j_0} + \sum_{e \notin f^k} \alpha_{j_e} x_e^{k+1}$

leicht, wenn $a_{i_j} = e_j$

• $Cx^{k+1} = z_0 + \sum_{e \notin f^k} (c_e + z_e) x_e^{k+1}$ für $z_e = \sum_{j=1}^p c_{i_j} \alpha_{j_e}$

• wähle $e \notin f^k$ mit $c_e + z_e < 0$, dann verringert sich der Funktionswert, wenn x_e von 0 erhöht wird
↑ wenn es kein solches e gibt, ist x^k optimal

2) gehe zu benachbarten zulässigen Basispunkt / Extrempunkt

• wir möchten a_e zur Basis hinzunehmen; welche von a_{i_1}, \dots, a_{i_p} sollte durch a_e ersetzt werden?

• $a_e = y_1 a_{i_1} + \dots + y_p a_{i_p} \Rightarrow (x_{i_1}^k - \alpha y_1) a_{i_1} + \dots + (x_{i_p}^k - \alpha y_p) a_{i_p} + \alpha a_e = b \quad \forall \alpha \in \mathbb{R}$

• wähle $x_{i_j}^{k+1} = x_{i_j}^k - \alpha y_j$, $j = 1, \dots, p$, $x_e^{k+1} = \alpha$, alle anderen Einträge = 0

wenn $y_1, \dots, y_p \leq 0$: x^{k+1} kann kein zulässiger Basispunkt werden $\rho^* = -\infty$

sonst: Sei $q = \operatorname{argmin}_{s=1, \dots, p | y_s > 0} \frac{x_{i_s}^k}{y_s}$; setze $\alpha = \frac{x_{i_q}^k}{y_q}$, $i_q = l$, $f^{k+1} = \{i_1, \dots, i_p\}$

Man kann wieder $Ax = b$ transformieren, sodass $a_i = e_j$. einzige Wahl, die x^{k+1} zulässigen Basispunkt macht

Optimierungsalgorithmen: Simplex-Verfahren (lineare Optimierung)

Beispiele zum Simplex-Verfahren

Bsp: $\min_{x \in \mathbb{R}^3} (1 \ 2 \ 3) x$ s.d. $(1 \ 1 \ 1) x = 3$, $x \geq 0$

0) $f^0 = \{3\} \Rightarrow x^0 = \begin{pmatrix} 0 \\ 0 \\ 3 \end{pmatrix} \geq 0$

1) $(1 \ 1 \ 1) x = 3 \Rightarrow x_3^1 = 3 - x_1^1 - x_2^1 \Rightarrow (1 \ 2 \ 3) x^1 = x_1^1 + 2x_2^1 + 3(3 - x_1^1 - x_2^1)$
 $= \underset{c_1 - 2c_1}{-2x_1^1} + \underset{c_2 - 2c_2}{-1x_2^1} + 9 \Rightarrow$ wähle $l=2!$

2) trivial: $f^1 = \{2\} \Rightarrow x^1 = \begin{pmatrix} 0 \\ 3 \\ 0 \end{pmatrix}$

1) $x_2^2 = 3 - x_1^2 - x_3^2 \Rightarrow c x^2 = 6 - x_1^2 + x_3^2 \Rightarrow$ wähle $l=1!$

2) trivial: $f^2 = \{1\} \Rightarrow x^2 = \begin{pmatrix} 3 \\ 0 \\ 0 \end{pmatrix}$

1) $x_1^3 = 3 - x_2^3 - x_3^3 \Rightarrow c x^3 = 3 + x_2^3 + 2x_3^3 \Rightarrow x^3$ ist optimal!

Bsp: $\min_{x \in \mathbb{R}^3} (1 \ 2 \ 3) x$ s.d. $\begin{pmatrix} 1 & 1 & 1 \\ 2 & 1 & 1 \end{pmatrix} x = \begin{pmatrix} 3 \\ 4 \end{pmatrix}$, $x \geq 0$

0) $f^0 = \{1, 3\} \Rightarrow x^0 = \begin{pmatrix} 1 \\ 0 \\ 2 \end{pmatrix} \geq 0$

1) $A x^1 = b \Rightarrow \begin{pmatrix} 1 & 1 \\ 2 & 1 \end{pmatrix} \begin{pmatrix} x_1^1 \\ x_2^1 \end{pmatrix} = \begin{pmatrix} 3 \\ 4 \end{pmatrix} - \begin{pmatrix} 1 \\ 1 \end{pmatrix} x_3^1 \Rightarrow \begin{pmatrix} x_1^1 \\ x_2^1 \end{pmatrix} = \begin{pmatrix} 1 \\ 2 - x_2^1 \end{pmatrix}$
 $\Rightarrow c x^1 = 1 + 2x_2^1 + 3(2 - x_2^1) \Rightarrow$ wähle $l=2!$

2) $a_2 = 0 \cdot a_1 + 1 \cdot a_3 \Rightarrow (x_1^0 - \alpha \cdot 0) a_1 + (x_3^0 - \alpha \cdot 1) a_3 + \alpha a_2 = b$
 $\Rightarrow q = 3, \alpha = x_3^0 = 2 \Rightarrow f^1 = \{1, 2\}, x^1 = \begin{pmatrix} 1 \\ 2 \\ 0 \end{pmatrix}$

1) $\Rightarrow x^2$ ist optimal!

Optimierungsalgorithmen: Primal-duale Optimierungsverfahren

Anwendungsbeispiel: ROF-Modell

Viele konvexe Optimierungsprobleme lassen sich schreiben als $\min_{x \in \mathbb{R}^n} F(Ax) + g(x)$
mit $A: \mathbb{R}^n \rightarrow \mathbb{R}^m$ linear, $F: \mathbb{R}^m \rightarrow \mathbb{R} \cup \{\infty\}$ & $G: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{\infty\}$ konvex.

Bsp: (Rudin-Osher-Fatemi-Modell) Aus der Bildverarbeitung:

geg: verrauschtes Bild oder Signal $v: \Omega \rightarrow \mathbb{R}$ (z.B. $\Omega = [0,1]^d$)


ges: rauschfreies Signal $u: \Omega \rightarrow \mathbb{R}$

Bei weißem Rauschen (\cong unabhängig identisch normalverteilt in jedem Pixel)

und wenn u stückweise konstant sein soll, ist eine gute Schätzung

$$u = \operatorname{argmin}_u \alpha \|v - u\|_{L^2(\Omega)}^2 + \int_{\Omega} |Du|.$$

In 1D diskretisiert: Gitter $\frac{1}{2n}, \frac{2}{2n}, \dots, \frac{2n-1}{2n}$ auf $[0,1]$



$$\cdot v, u \in \mathbb{R}^n$$

$$\cdot (Du)_i = \frac{u_{i+1} - u_i}{1/n} \quad (+ \text{ggfs. Spezialbehandlung am Rand})$$

$$\cdot u = \operatorname{argmin}_u F(Du) + g(u)$$

$$\text{mit } F(w) = \sum_{i=1}^{n-1} \frac{1}{n} |w_i| = \frac{1}{n} \|w\|_1, \quad g(u) = \sum_{i=1}^n \frac{\alpha}{n} |v_i - u_i|^2 = \frac{\alpha}{n} \|v - u\|_2^2$$

Optimierungsalgorithmen: Primal-duale Optimierungsverfahren

Der Chambolle-Pock-Algorithmus


Sei F abgeschlossen & konvex, dann gilt

$$\min_{x \in \mathbb{R}^n} F(Ax) + G(x) = \min_{x \in \mathbb{R}^n} \sup_{y \in \mathbb{R}^m} \underbrace{y \cdot (Ax)}_{=(A^T y) \cdot x} - F^*(y) + G(x)$$

Man kann nun abwechselnd ein bisschen in x minimieren und in y maximieren.

Def: Der Proximaloperator zu abgeschlossenem $f \in \text{Conv } \mathbb{R}^n$ ist

$$\text{prox}_f(x) = \underset{z}{\text{argmin}} \frac{1}{2} \|z - x\|_2^2 + f(z) \quad = \text{Minimierer in Moreau-Yosida-Regularisierung ist wohldefiniert (warum?)}$$



Alg: (Chambolle-Pock) geg: Schrittweiten $\tau, \beta > 0$, Beschleunigungsparameter $\theta \in [0, 1]$, Schrittzahl N

Init: Wähle $x_0 \in \mathbb{R}^n, y_0 \in \mathbb{R}^m$, setze $\bar{x}_0 = x_0, x_{-1} = x_0$

for $n = 0$ to N

$$y_{n+1} = \text{prox}_{\beta F^*} \left(\underbrace{y_n + \beta A \bar{x}_n}_{\text{vergrößert } y \cdot (A \bar{x}_n)} \right)$$

$$x_{n+1} = \text{prox}_{\tau G} \left(\underbrace{x_n - \tau A^T y_{n+1}}_{\text{verkleinert } (A^T y_{n+1}) \cdot x} \right)$$

$$\bar{x}_{n+1} = x_{n+1} + \theta (x_{n+1} - x_n)$$

end

Breakout-Room 1: Berechne Formel für $\text{prox}_{\sigma F^*}(y)$

Breakout-Room 2: Berechne Formel für $\text{prox}_{\tau G}(x)$

Breakout-Room 3: Berechne Matrix D , Dx , $D^T y$

Implementiere Verfahren als python-jupyter-Notebook
unter <https://jupyterhub.wwu.de/>

Wähle $\tau < 1/n$, $\theta = 1$, $v(x) \sim \text{round}(\sin(4x)) + \text{round}(\cos(9x))$
+ Gauß-Rauschen

Der Chambolle-Pock-Algorithmus II

Thm: $\min_{x \in \mathbb{R}^n} \max_{y \in \mathbb{R}^m} y \cdot (Ax) - F^*(y) + G(x)$ habe einen Sattelpunkt (\hat{x}, \hat{y}) . Wähle $\theta = 1, \tau \beta \|A\|^2 < 1$.

$$(a) \quad \frac{\|y_n - \hat{y}\|_2^2}{2\beta} + \frac{\|x_n - \hat{x}\|_2^2}{2\tau} \leq \frac{1}{1 - \tau\beta\|A\|^2} \left(\frac{\|y_0 - \hat{y}\|_2^2}{2\beta} + \frac{\|x_0 - \hat{x}\|_2^2}{2\tau} \right) \quad \forall n$$

(b) Sei $x^N = \frac{1}{N} \sum_{i=1}^N x_n, y^N = \frac{1}{N} \sum_{i=1}^N y_n, B_1 \times B_2 \subset \mathbb{R}^n \times \mathbb{R}^m$ beschränkt. Die eingeschränkte Primal-Dual-Lücke $D_{B_1 \times B_2}(x, y) = \max_{y' \in B_2} (y' \cdot Ax - F^*(y') + G(x)) - \min_{x' \in B_1} (y \cdot Ax' - F^*(y) + G(x'))$ erfüllt $D_{B_1 \times B_2}(x^N, y^N) \leq \left(\sup_{(x, y) \in B_1 \times B_2} \frac{\|x - x_0\|_2^2}{2\tau} + \frac{\|y - y_0\|_2^2}{2\beta} \right) / N$.

(c) $x_n \rightarrow x^*, y_n \rightarrow y^*$ für einen Sattelpunkt (x^*, y^*) .

(Nur in endlichen Dimensionen; sonst sind nur schwache Häufungspunkte von (x^N, y^N) Sattelp.)

Bem: Wenn $(\hat{x}, \hat{y}) \in B_1 \times B_2$, dann $D_{B_1 \times B_2}(x, y) \geq (\hat{y} \cdot Ax - F^*(\hat{y}) + G(x)) - (y \cdot A\hat{x} - F^*(y) + G(\hat{x}))$
 $\geq (\hat{y} \cdot A\hat{x} - F^*(\hat{y}) + G(\hat{x})) - (\hat{y} \cdot A\hat{x} - F^*(\hat{y}) + G(\hat{x})) = 0$

mit Gleichheit genau dann, wenn (x, y) auch ein Sattelpunkt ist.

Bew: $\cdot p = \text{prox}_f q \Rightarrow q - p \in \partial f(p)$, somit $\begin{cases} y_n + \beta A\bar{x} - y_{n+1} \in \beta \partial F^*(y_{n+1}) & \text{mit } \bar{x} = \bar{x}_n \\ x_n - \tau A^T \bar{y} - x_{n+1} \in \tau \partial G(x_{n+1}) & \text{mit } \bar{y} = y_{n+1} \end{cases}$

$$\Rightarrow \begin{cases} F^*(y) \geq F^*(y_{n+1}) + \left\langle \frac{y_n - y_{n+1}}{\beta}, y - y_{n+1} \right\rangle + \langle A\bar{x}, y - y_{n+1} \rangle & \forall y \\ G(x) \geq G(x_{n+1}) + \left\langle \frac{x_n - x_{n+1}}{\tau}, x - x_{n+1} \right\rangle - \langle A^T \bar{y}, x - x_{n+1} \rangle & \forall x \end{cases}$$

Optimierungsalgorithmen: Primal-duale Optimierungsverfahren

Der Chambolle-Pock-Algorithmus III

$$\|\cdot\| \triangleq \|\cdot\|_2$$

$$\begin{aligned}
 \text{Summe} \Rightarrow \frac{|y - y_n|^2}{2b} + \frac{|x - x_n|^2}{2c} &\geq \underbrace{\left[\langle Ax_{n+1}, y \rangle - F^*(y) + G(x_{n+1}) \right]}_{\text{hat Struktur der primal-dualen Lücke}} - \underbrace{\left[\langle Ax_n, y_{n+1} \rangle - F^*(y_{n+1}) + G(x_n) \right]}_{\text{hat Struktur der primal-dualen Lücke}} \\
 &+ \frac{|y - y_{n+1}|^2}{2b} + \frac{|x - x_{n+1}|^2}{2c} + \underbrace{\frac{|y_n - y_{n+1}|^2}{2b} + \frac{|x_n - x_{n+1}|^2}{2c}}_{\geq 0} \\
 &+ \underbrace{\langle A(x_{n+1} - \bar{x}), y_{n+1} - y \rangle - \langle A(x_{n+1} - x), y_{n+1} - \bar{y} \rangle}_{=: B}
 \end{aligned}$$

$$\bar{y} = y_{n+1}, \bar{x} = 2x_n - x_{n-1}$$

$$B \stackrel{\downarrow}{=} \langle A((x_{n+1} - x_n) - (x_n - x_{n-1})), y_{n+1} - y \rangle$$

$$= \langle A(x_{n+1} - x_n), y_{n+1} - y \rangle - \langle A(x_n - x_{n-1}), y_n - y \rangle - \underbrace{\langle A(x_n - x_{n-1}), y_{n+1} - y_n \rangle}_{\geq 0}$$

$$\leq \|A\| |x_n - x_{n-1}| |y_{n+1} - y_n| \leq \|A\| \left(\frac{\alpha}{2} |x_n - x_{n-1}|^2 + \frac{\alpha}{2\alpha} |y_{n+1} - y_n|^2 \right)$$

$$\stackrel{\uparrow}{\geq} \langle A(x_{n+1} - x_n), y_{n+1} - y \rangle - \langle A(x_n - x_{n-1}), y_n - y \rangle - \sqrt{bc} \|A\| \left(\frac{|x_n - x_{n-1}|^2}{2c} + \frac{|y_{n+1} - y_n|^2}{2b} \right)$$

$$\alpha = \sqrt{2bc}$$

$$\begin{aligned}
 \text{insgesamt: } \frac{|y - y_n|^2}{2b} + \frac{|x - x_n|^2}{2c} &\geq \left[\langle Ax_{n+1}, y \rangle - F^*(y) + G(x_{n+1}) \right] - \left[\langle Ax_n, y_{n+1} \rangle - F^*(y_{n+1}) + G(x_n) \right] \\
 &+ \frac{|y - y_{n+1}|^2}{2b} + \frac{|x - x_{n+1}|^2}{2c} + (1 - \sqrt{bc} \|A\|) \frac{|y_n - y_{n+1}|^2}{2b} + \frac{|x_n - x_{n+1}|^2}{2c} - \sqrt{bc} \|A\| \frac{|x_{n+1} - x_n|^2}{2c} \\
 &+ \langle A(x_{n+1} - x_n), y_{n+1} - y \rangle - \langle A(x_n - x_{n-1}), y_n - y \rangle
 \end{aligned}$$

Optimierungsalgorithmen: Primal-duale Optimierungsverfahren

Der Chambolle-Pock-Algorithmus IV

Summiert von $n=l$ bis $N-1$:

$$\sum_{n=l+1}^N \left(\langle Ax_n, y \rangle - F^*(y) + G(x_n) \right) - \left[\langle Ax, y_N \rangle - F^*(y_N) + G(x) \right] + \frac{|y - y_N|^2}{2\tau} + \frac{|x - x_N|^2}{2\tau}$$

$$+ \underbrace{(1 - \sqrt{2\tau} \|A\|)}_{C(l)} \sum_{n=l+1}^N \frac{|y_n - y_{n-1}|^2}{2\beta} + (1 - \sqrt{2\tau} \|A\|) \sum_{n=l+1}^{N-1} \frac{|x_n - x_{n-1}|^2}{2\tau} + \frac{|x_N - x_{N-1}|^2}{2\tau} - \sqrt{2\tau} \|A\| \frac{|x_{l-1} - x_l|^2}{2\sigma} - \langle A(x_l - x_{l-1}), y_l - y \rangle$$

$$\leq \frac{|x - x_l|^2}{2\tau} + \frac{|y - y_l|^2}{2\beta} - \underbrace{\langle A(x_N - x_{N-1}), y_N - y \rangle}_{\geq 0}$$

$$\leq \|A\| |x_N - x_{N-1}| |y_N - y| \leq \|A\| \left(\frac{1}{2} |x_N - x_{N-1}|^2 + \frac{1}{2\beta^2} |y_N - y|^2 \right) \stackrel{\beta = \frac{1}{\|A\|}}{\leq} \frac{|x_N - x_{N-1}|^2}{2\tau} + \tau 2 \|A\|^2 \frac{|y_N - y|^2}{2\beta}$$

• Wähle $(x, y) = (x, \vec{y}) \Rightarrow C(l) \geq 0$; wähle nun $l=0 \Rightarrow (a)$

• Konvexität von $F^*, G \Rightarrow \left[\langle Ax^N, y \rangle - F^*(y) + G(x^N) \right] - \left[\langle Ax, y^N \rangle - F^*(y^N) + G(x) \right] \leq \frac{C(0)}{N}$
 $\leq \frac{1}{N} \left(\frac{|x - x_0|^2}{2\tau} + \frac{|y - y_0|^2}{2\beta} \right) \Rightarrow (b)$

• $(a) \Rightarrow (x_n, y_n)$ ist beschränkte Folge \Rightarrow Teilfolge $(x_{n_k}, y_{n_k}) \xrightarrow{k \rightarrow \infty} (x^*, y^*)$

• $(*) \Rightarrow |x_n - x_{n-1}|, |y_n - y_{n-1}| \rightarrow 0 \Rightarrow (x_{n_{k-1}}, y_{n_{k-1}}) \xrightarrow{k \rightarrow \infty} (x^*, y^*)$

$\Rightarrow (x^*, y^*)$ ist Fixpunkt des Algorithmus $\Rightarrow (x^*, y^*)$ ist Sattelpunkt

• Wähle $(x, y) = (x^*, y^*) \Rightarrow C(l) \geq 0$; mit $l = n_k$ folgt $(1 - \sqrt{2\tau} \|A\|) \frac{|y^* - y_N|^2}{2\beta} + \frac{|x^* - x_N|^2}{2\tau} \leq \frac{|x^* - x_{n_k}|^2}{2\beta} + \frac{|y^* - y_{n_k}|^2}{2\tau} + 0(|x_{n_k} - x_{n_k-1}|) \Rightarrow (c) \square$

Optimierungsalgorithmen: Liniensuch-Verfahren für Optimierung ohne NB

Struktur von Liniensuch-Verfahren

Im Folgenden nehmen wir $f: \mathbb{R}^n \rightarrow \mathbb{R}$ zweimal stetig differenzierbar und beschränkt von unten an.

Def: Eine Abstiegsrichtung für f an x ist ein $p \in \mathbb{R}^n$ mit $Df(x)p < 0$.
(Richtung, in die f abnimmt)

Alg. (Liniensuch-Verfahren)

geg.: $f: \mathbb{R}^n \rightarrow \mathbb{R}$, $x_0 \in \mathbb{R}^n$, $k=0$

repeat 1) wähle eine Abstiegsrichtung $p_k \in \mathbb{R}^n$

2) wähle eine Schrittweite $\alpha_k > 0$

3) $x_{k+1} = x_k + \alpha_k p_k$

4) $k \leftarrow k+1$

until x_{k+1} minimiert f ausreichend

Optimierungsalgorithmen: Liniensuch-Verfahren für Optimierung ohne NB


Schrittweisen-Kontrolle: Armijo-Bedingung

Def. $\alpha_k > 0$ erfüllt die Armijo-Bedingung für $0 < c_n < 1$, wenn


$$f(x_k + \alpha_k p_k) \leq f(x_k) + c_n \alpha_k Df(x_k) p_k \quad \text{erwarteter ABstieg!}$$

Kor. Wenn $f \in C^1(\mathbb{R}^n)$, $0 < c_n < 1$, dann existiert eine Schrittweite α , die die Armijo-Bedingung erfüllt.


Bew. Taylorsatz $\Rightarrow f(x + \alpha p) = f(x) + \alpha Df(x)p + o(\alpha) < f(x) + c_n \alpha Df(x)p$ für α klein genug □



zu große Schritte



zu kleine Schritte



Armijo-Backtracking-Schritt

Alg. (Backtracking, um eine gute Schrittweite zu finden)

$$\alpha = 1$$

if Armijo-Bedingung erfüllt

repeat $\alpha \leftarrow 2\alpha$ until Armijo-Bedingung verletzt

while Armijo-Bedingung verletzt

$$\alpha \leftarrow \alpha/2$$

Optimierungsalgorithmen: Liniensuch-Verfahren für Optimierung ohne NB


Schrittweisen-Kontrolle: Wolfe-Bedingung

Def: α_k erfüllt die starke Wolfe-Bedingung für $0 < c_1 < c_2 < 1$, wenn α_k die Armijo-Bed. erfüllt und

$$|Df(x_k + \alpha_k p_k) p_k| \leq -c_2 Df(x_k) p_k$$

Thm: Wenn $f \in C^1(\mathbb{R}^n)$ nach unten beschränkt ist, $0 < c_1 < c_2 < 1$, dann existiert ein α_k , das die starke Wolfe-Bedingung erfüllt.

Bew.: Sei $g(\alpha) = f(x_k + \alpha p_k)$



- $\alpha_0 := \max \{ \alpha \in \mathbb{R} \mid f(x_k + \alpha p_k) \leq f(x_k) + c_1 \alpha Df(x_k) p_k \}$
- wenn $g'(\alpha_0) \geq 0$, wähle $\alpha_k = \max \{ \alpha \leq \alpha_0 \mid g'(\alpha) = 0 \}$

beachte: Armijo-Bed. ist automatisch erfüllt

- sonst $|Df(x_k + \alpha_0 p_k) p_k| = -g'(\alpha_0) \leq \underbrace{-c_1 g'(0)}_{\text{Steigung der roten Linie}} < -c_2 g'(0) = -c_2 Df(x_k) p_k$ □

Steigung der roten Linie

Optimierungsalgorithmen: Liniensuch-Verfahren für Optimierung ohne NB

Globale Konvergenz

Thm (Zoutendijk): Wenn $\exists L > 0: \|Df(x) - Df(y)\|_2 \leq L \|x - y\|_2$, (Gradient ist Lipschitz)

$$\cos \theta_k = \frac{-Df(x_k) p_k}{\|Df(x_k)\|_2 \|p_k\|_2}, \text{ (Winkel zwischen } -Df(x_k) \text{ und Suchrichtung } p_k)$$

α_k erfüllen die starke Wolfe-Bedingung,

$$\text{dann } \sum_{k=0}^{\infty} \cos^2 \theta_k \|Df(x_k)\|_2^2 < \infty. \text{ (entweder } Df \rightarrow 0 \text{ oder Winkel degeneriert)}$$

Bew: 1) Nutze Wolfe-Bedingung & Tatsache, dass Df sich nicht zu schnell ändern kann,

um eine untere Schranke an die Schrittweite zu erhalten:

$$\alpha_k L \|p_k\|_2^2 \geq (Df(x_k + \alpha_k p_k) - Df(x_k)) p_k \geq (c_2 - 1) Df(x_k) p_k$$

$$\Rightarrow \alpha_k \geq \frac{c_2 - 1}{L \|p_k\|_2^2} Df(x_k) p_k$$

2) Nutze Armijo-Bedingung, um abzuschätzen, wie viel f im schlechtesten Fall abnimmt:

$$\Rightarrow f(x_{k+1}) \leq f(x_k) + c_1 \frac{c_2 - 1}{L} \frac{(Df(x_k) p_k)^2}{\|p_k\|_2^2} = f(x_k) + c_1 \frac{c_2 - 1}{L} \cos^2 \theta_k \|Df(x_k)\|_2^2$$

$$\Rightarrow -\infty < \text{diff} - f(x_0) \leq f(x_n) - f(x_0) = \sum_{k=0}^{n-1} f(x_{k+1}) - f(x_k) \leq c_1 \frac{c_2 - 1}{L} \sum_{k=0}^{n-1} \cos^2 \theta_k \|Df(x_k)\|_2^2 \quad \square$$

Bem: Wenn Df nur Hölder-stetig mit Exponent β ist, erhält man $\sum_{k=1}^{\infty} |\cos \theta_k \|Df(x_k)\|_2|^{1+\frac{1}{\beta}} < \infty$ (HA)

$\Rightarrow Df \rightarrow 0$ mit langsamerer Konvergenzrate!

die folgenden Konvergenzraten-Berechnungen starten von hier

Optimierungsalgorithmen: Liniensuch-Verfahren für Optimierung ohne NB

Gradientenabstieg, steilster Abstieg, Newton-Verfahren

Def.: Die Gradientenabstiegs-Richtung ist $p_k^g = -\nabla f(x_k)$

- Sei $\|\cdot\|$ eine Norm mit dualer Norm $\|\cdot\|_*$; die steilste Abstiegs-Richtung ist

$$p_k^s = \underset{\|v\|=1}{\operatorname{argmin}} \nabla f(x_k) \cdot v \quad (\text{Gradientenabstieg} = \text{steilster Abstieg mit } \|\cdot\|_*)$$

(Skalierung so, dass $-\nabla f(x_k) p_k^s = \|\nabla f(x_k)\|_*^2$)

- Der Newton-Schritt ist $p_k^N = -D^2 f(x_k)^{-1} \nabla f(x_k)$

Bem.: Wenn $D^2 f$ pos. definit ist, sind alle obigen Richtungen Abstiegsrichtungen. In der Tat,
 $\nabla f(x_k) p_k^g = -\|\nabla f(x_k)\|_2^2 < 0$, $\nabla f(x_k) p_k^s = -\|\nabla f(x_k)\|_*^2 < 0$, $\nabla f(x_k) p_k^N = -\|\nabla f(x_k)\|_{D^2 f(x_k)^{-1}}^2 < 0$.

Bem.: Das Newton-Verfahren findet das Minimum in einem einzigen Schritt, wenn f quadratisch & $\alpha_k = 1$ sind: $f(x) = \frac{1}{2} x^T A x + b^T x$ wird minimiert durch $x^* = -A^{-1} b$, und $x_k + \alpha_k p_k^N = x_k - A^{-1}(Ax_k + b) = x^*$
im Sinn quadratischer Formen, d.h. Eigenwerte $\in [m, M]$

Kor.: Wenn $mI \leq D^2 f(x) \leq MI \quad \forall x \in \mathbb{R}^n$ mit $m, M > 0$ & die α_k die starke Wolfe-Bed. erfüllen, dann gilt $\nabla f(x_k) \xrightarrow[k \rightarrow \infty]{} 0$ für Gradienten- / steilsten Abstieg / Newton-Verfahren.

Bew.: Folgt aus Zoutendijks Theorem mit $\cos \theta_k = 1$ für Gradientenabstieg, $\cos \theta_k \geq \frac{m}{M}$ für Newton-Verfahren, $\cos \theta_k \geq \frac{c}{C}$ mit $c \|\cdot\| \leq \|\cdot\|_2 \leq C \|\cdot\|_*$ für steilsten Abstieg. \square



Optimierungsalgorithmen: Liniensuch-Verfahren für Optimierung ohne NB

Optimalitäts-Schranken aus dem Gradienten

Konvexe Umgebung von opt. Punkt x^*

Thm: Wenn $m, M > 0$ existieren mit $mI \leq D^2f(x) \leq MI \quad \forall x \in U(x^*)$, dann $\forall x \in U(x^*)$

- $\frac{1}{2M} \|Df(x)\|_2^2 \leq f(x) - p^* \leq \frac{1}{2m} \|Df(x)\|_2^2$
- $\frac{1}{M} \|Df(x)\|_2 \leq \|x - x^*\|_2 \leq \frac{1}{m} \|Df(x)\|_2$



Bew.: Mit Taylor, $f(y) = f(x) + Df(x)(y-x) + \frac{1}{2} (y-x)^T D^2f(z)(y-x)$ für ein z zwischen x, y

$$\Rightarrow f(y) \begin{matrix} \leq \\ \geq \end{matrix} f(x) + Df(x)(y-x) + \frac{m}{2} \|y-x\|_2^2 \quad \forall x, y \in U(x^*)$$

minimiere beide Seiten nach y : links $y = x^*$

rechts $y = \tilde{y} = x - \frac{1}{M} \nabla f(x)$

$$\Rightarrow p^* = f(x^*) \begin{matrix} \leq \\ \geq \end{matrix} f(x) - \frac{1}{2M} \|Df(x)\|_2^2$$

Wie oben, $f(x) \begin{matrix} \leq \\ \geq \end{matrix} f(x^*) + Df(x^*)(x-x^*) + \frac{m}{2} \|x-x^*\|_2^2 = p^* + \frac{m}{2} \|x-x^*\|_2^2$

$$\Rightarrow \|x-x^*\|_2 \begin{matrix} \geq \\ \leq \end{matrix} \frac{2}{M} (f(x) - p^*) \begin{matrix} \geq \\ \leq \end{matrix} \frac{1}{m} \|Df(x)\|_2^2$$


□

Optimierungsalgorithmen: Liniensuch-Verfahren für Optimierung ohne NB


Experimentelle Konvergenzrate

```
octave:1> f = @(x) x.^4/4 - 5*x.^3/3 + 3*x.^2;  
octave:2> df = @(x) x^3 - 5*x^2 + 6*x; % = x*(x-2)*(x-3)  
octave:3> d2f = @(x) 3*x^2 - 10*x + 6;  
octave:4> fun = @(x) deal(f(x),df(x),d2f(x));
```

```
octave:5> x = -1:.01:4;  
octave:6> plot(x,f(x),'Linewidth',5);
```



```
octave:7> x0 = 1.3;  
octave:8> maxIter = 100;  
octave:9> [x,iterSteepest] = descendSteepest( fun, x0, maxIter, false );  
octave:10> [x,iterNewton] = newtonMethod( fun, x0, maxIter, 1e-26, false );  
octave:11> semilogy(1:length(iterSteepest),abs(iterSteepest),'r','Linewidth',5,...  
> 1:length(iterNewton), abs(iterNewton), 'g','Linewidth',5);
```



Optimierungsalgorithmen: Liniensuch-Verfahren für Optimierung ohne NB

Konvergenzrate Gradienten-/steilster Abstieg

Thm: Sei $S = \{x \in \mathbb{R}^n \mid f(x) \leq f(x_0)\}$, $mI \leq D^2 f(x) \leq MI \quad \forall x \in S$, $m, M > 0$,

$$\left\{ \begin{array}{l} \frac{1}{\delta} \| \cdot \| \geq \| \cdot \|_2 \geq \gamma \| \cdot \|_* \\ \frac{1}{\tilde{\gamma}} \| \cdot \|_* \geq \| \cdot \|_2 \geq \tilde{\delta} \| \cdot \| \end{array} \right\},$$

x_k seien die Schritte des steilsten Abstiegs mit Backtracking für $c, \epsilon \in (0, \frac{1}{2})$. Dann gilt

$$(f(x_k) - p^*) \leq \delta^k (f(x_0) - p^*) \quad \text{für } \delta = 1 - 2m c_1 \tilde{\gamma}^2 \min \left\{ 1, \frac{\tilde{\gamma}^2}{2M} \right\} < 1$$

↖ lineare Konvergenz
↖ hängt ab von Konditionszahl $\frac{M}{m}$ von $D^2 f$!



Bew.: $f(x_k + \alpha p_k) \leq f(x_k) + \alpha Df(x_k) p_k + \frac{M}{2} \alpha^2 \|p_k\|_2^2 \leq f(x_k) + \alpha \left(1 - \frac{M}{2\tilde{\gamma}^2} \alpha\right) Df(x_k) p_k$

$$\leq \|p_k\|_2^2 / \tilde{\gamma}^2 = \|\nabla f(x_k)\|_*^2 / \tilde{\gamma}^2 = -Df(x_k) p_k / \tilde{\gamma}^2$$

$$\Rightarrow \text{jedes } \alpha \in \left(0, \frac{2\tilde{\gamma}^2}{M} (1 - c_1)\right) \supset \left(0, \frac{\tilde{\gamma}^2}{M}\right) \text{ erfüllt die Armijo-Bed.} \Rightarrow \alpha_k \geq \min \left\{ 1, \frac{\tilde{\gamma}^2}{2M} \right\}$$

$$f(x_{k+1}) = f(x_k + \alpha_k p_k) \leq f(x_k) + c_1 \alpha_k Df(x_k) p_k \leq f(x_k) - c_1 \min \left\{ 1, \frac{\tilde{\gamma}^2}{2M} \right\} \|\nabla f(x_k)\|_*^2$$

$$\leq f(x_k) - c_1 \tilde{\gamma}^2 \min \left\{ 1, \frac{\tilde{\gamma}^2}{2M} \right\} \underbrace{\|\nabla f(x_k)\|_2^2}_{\geq 2m (f(x_k) - p^*)}$$

$$\Rightarrow f(x_{k+1}) - p^* \leq f(x_k) - p^* - 2m c_1 \tilde{\gamma}^2 \min \left\{ 1, \tilde{\gamma}^2 / 2M \right\} (f(x_k) - p^*) = \delta (f(x_k) - p^*) \quad \square$$

• Was bedeutet dies für $\|Df(x_k)\|_2$, $\|x_k - x^*\|_2$?

• Welche Rate erhält man aus Zoutendijks Theorem?

Optimierungsalgorithmen: Liniensuch-Verfahren für Optimierung ohne NB

Akzeptanz des Newton-Schritts

warum wichtig?

Thm: Wenn D^2f stetig $\cdot mI \leq D^2f(x) \leq MI \forall x; m, M > 0$ $\cdot c_1 < \frac{1}{2}$ $\cdot \lim_{k \rightarrow \infty} \|p_k\| = 0$ $\cdot \lim_{k \rightarrow \infty} \frac{\|p_k - p_k^N\|}{\|p_k\|} = 0$,
dann erfüllt $\alpha_k = 1$ für k groß genug die starke Wolfe-Bedingung.

Bew: 1) Armijo-Bed. ist erfüllt für k groß genug:

• Taylors Theorem: $f(x_k + p_k) = f(x_k) + Df(x_k)p_k + \frac{1}{2} p_k^T D^2f(x_k + q_k) p_k$ für ein $q_k \in [0, p_k]$

$$\begin{aligned} \cdot f(x_k + p_k) - f(x_k) - \frac{1}{2} Df(x_k)p_k &= \frac{1}{2} [Df(x_k)p_k + p_k^T D^2f(x_k + q_k) p_k] \\ &= \frac{1}{2} [\underbrace{(Df(x_k)p_k + p_k^T D^2f(x_k) p_k)}_{=0} + \underbrace{p_k^T D^2f(x_k) (p_k - p_k^N)}_{= M \cdot o(\|p_k\|_2^2)} + \underbrace{p_k^T (D^2f(x_k + q_k) - D^2f(x_k)) p_k}_{= o(\|p_k\|_2^2)}] = o\left[\left(c_1 - \frac{1}{2}\right) Df(x_k)p_k\right] \end{aligned}$$

$$2) \frac{Df(x_k)p_k}{\|p_k\|_2^2} + m \leq \frac{Df(x_k)p_k}{\|p_k\|_2^2} + \frac{p_k^T D^2f(x_k) p_k}{\|p_k\|_2^2} = \frac{p_k^T D^2f(x_k) (p_k - p_k^N)}{\|p_k\|_2^2} \leq M \frac{\|p_k - p_k^N\|_2}{\|p_k\|_2} \rightarrow 0$$

\Rightarrow für k groß genug ist $-Df(x_k)p_k \geq \frac{m}{2} \|p_k\|_2^2$

3) starke Wolfe-Bed. ist erfüllt für k groß genug:

$$\begin{aligned} |Df(x_k + p_k)p_k| &= \left| \underbrace{Df(x_k)p_k + p_k^T D^2f(x_k) p_k}_{= p_k^T D^2f(x_k) (p_k - p_k^N) = M \cdot o(\|p_k\|_2^2)} + \underbrace{\int_0^1 p_k^T (D^2f(x_k + t p_k) - D^2f(x_k)) p_k dt}_{= o(\|p_k\|_2^2)} \right|, \end{aligned}$$

während $-c_2 Df(x_k)p_k \geq c_2 \frac{m}{2} \|p_k\|_2^2$

□

Optimierungsalgorithmen: Liniensuch-Verfahren für Optimierung ohne NB

Konvergenzrate Newton-Verfahren

Thm: Sei D^2f Lipschitz-stetig mit Konstante L , $m, M > 0$, $mI \leq D^2f(x) \leq MI \quad \forall x$, $c_1 < \frac{1}{2}$, $p_k = \rho_k^N$,

$\alpha_k = 1$ sobald möglich. Dann gilt $\limsup_{k \rightarrow \infty} \frac{\|x_{k+1} - x^*\|_2}{\|x_k - x^*\|_2^2} \leq \frac{L}{m}$.
quadratische Konvergenz

Bew: \cdot Zentrendijk $\Rightarrow \|Df(x_k)\|_2 \rightarrow 0 \Rightarrow \|x_k - x^*\|_2 \rightarrow 0$ & $\rho_k \rightarrow 0$

\cdot aus vorherigem Thm folgt $\alpha_k = 1$ für k groß genug, d.h. $x_{k+1} = x_k + p_k$

$$\begin{aligned} \cdot D^2f(x_k)(x_{k+1} - x^*) &= D^2f(x_k)(p_k - (x^* - x_k)) = Df(x^*) - Df(x_k) - D^2f(x_k)(x^* - x_k) \\ &= \int_0^1 (D^2f(x_k + t(x^* - x_k)) - D^2f(x_k)) (x^* - x_k) dt \end{aligned}$$

\cdot nimm Norm auf beiden Seiten:

$$m \|x_{k+1} - x^*\|_2 \leq \|D^2f(x_k)(x_{k+1} - x^*)\|_2 \leq \left\| \int_0^1 (D^2f(x_k + t(x^* - x_k)) - D^2f(x_k)) (x^* - x_k) dt \right\|_2 \leq \frac{L}{2} \|x^* - x_k\|_2^2 \quad \square$$

Bem: \cdot Wenn $mI \leq D^2f(x^*) \leq MI$, dann gelten wegen Stetigkeit analoge Schranken in einer Umgebung.

\cdot Wenn das Verfahren zu einem Zeitpunkt diese Umgebung erreicht, erhält man quadratische Konvergenz.

\cdot Wenn D^2f nur Hölder-stetig mit Exponent $\alpha > 0$ ist?

\cdot Das Newton-Verfahren ist invariant unter linear Koordinatentransformation $x \mapsto Ax$ (prüfen!), jedoch nicht unsere Konvergenzratenanalyse \Rightarrow eigentlich braucht man nur $\|(Df(x))^{-1} D^2f(x + t(x^* - x)) - I_d)(x^* - x)\| \leq C \|x^* - x\|^\alpha$, d.h. kleine separate Lipschitz- & strikte Konvexitätsbedingung (Bezug zu „Selbstkonkordanz“)

Optimierungsalgorithmen: Liniensuch-Verfahren für Optimierung ohne NB

Komplexität des Newton-Verfahrens

$$\text{impliziert } \|x_k - x^*\|_2 \leq \min\left(\frac{1}{2} - c_1, \frac{c_2}{2}\right) \frac{m}{L}$$

Thm: Es gelten die gleichen Bedingungen wie zuvor. $\|Df(x_k)\|_2 \leq \min\left(\frac{1}{2} - c_1, \frac{c_2}{2}\right) \frac{m}{L}$ impliziert $\|x_{k+1} - x^*\|_2 \leq \frac{L}{m} \|x_k - x^*\|_2^2$.

Bew: selber Beweis, nur noch zu zeigen, dass $\alpha_k = 1$; hierfür wiederhole früheren Beweis & benutze

$$p_k^{NT} (D^2f(x_k + \alpha_k) - D^2f(x_k)) p_k^N \leq L \|p_k^N\|_2^3 \leq L \frac{\|Df(x_k)\|_2}{m} \|p_k^N\|_2^2 \leq \begin{cases} \left(\frac{1}{2} - c_1\right) m \|p_k^N\|_2^2 \leq (c_1 - \frac{1}{2}) Df(x_k) p_k^N \\ \frac{c_2}{2} m \|p_k^N\|_2^2 \end{cases} \quad \square$$

Thm: Es gelten die gleichen Bedingungen wie zuvor. α_k werde maximal bis auf einen Faktor $\beta \in (0, 1)$ gewählt.

Für jedes $\eta > 0$ existiert ein $\gamma > 0$ s.d. $\|Df(x_k)\|_2 \geq \eta$ impliziert $f(x_{k+1}) \leq f(x_k) - \gamma$.

Bew: $-Df(x_k) p_k^N = p_k^{NT} D^2f(x_k) p_k^N \geq m \|p_k^N\|_2^2$

$$f(x_k + \alpha p_k^N) = f(x_k) + \alpha Df(x_k) p_k^N + \frac{M}{2} \alpha^2 \|p_k^N\|_2^2 \leq f(x_k) + \alpha \left(1 - \frac{\alpha M}{2m}\right) Df(x_k) p_k^N$$

$$\Rightarrow \hat{\alpha} = 2 \frac{m}{M} (1 - c_1) \text{ erfüllt Armijo-Bedingung}$$

$$\text{Fall 1} (\hat{\alpha} \text{ erfüllt Wolfe-Bed.): } \alpha_k \geq \beta \hat{\alpha} \Rightarrow f(x_k + \alpha_k p_k^N) - f(x_k) \leq \beta \hat{\alpha} c_1 Df(x_k) p_k^N \leq -\gamma$$

$$\leq -\frac{\gamma}{M} \eta^2 \quad \gamma := \frac{\beta \hat{\alpha} c_1 \eta^2}{M}$$

$$\text{Fall 2} (Df(x_k + \hat{\alpha} p_k^N) p_k^N \text{ zu negativ}): \alpha_k \geq \hat{\alpha} \geq \beta \hat{\alpha}_1 \quad \text{--- " ---}$$

$$\text{Fall 3} (Df(x_k + \hat{\alpha} p_k^N) p_k^N \text{ zu positiv}): f(x_k + \alpha_k p_k^N) - f(x_k) \leq f(x_k + \hat{\alpha} p_k^N) - f(x_k) \leq -\gamma. \quad \square$$

Kor: Das Newton-Verfahren erreicht $\|x_k - x^*\|_2 < \varepsilon$ nach $\frac{f(x_0) - p^0}{\gamma} + \log_2 \left(\frac{\log 2}{\log \min\left(\frac{1}{2} - c_1, \frac{c_2}{2}\right)} \right)$ Iterationen.

Optimization algorithms: Interior point methods for ineq.-constrained optim.

Idea of interior point methods

$$\min f_0(x) \text{ s.t. } f_1(x), \dots, f_m(x) \leq 0, Ax = b, f_i \in C^2, \text{convex}, A \in \mathbb{R}^{p \times n}, \text{rank } A = p < n \quad (P)$$

assume: • optimal point x^* exists

• Slater's condition (strict feasibility) satisfied


⇒ strong duality, KKT conditions fulfilled

$$\left. \begin{aligned} Ax^* = b, f_i(x^*) \leq 0, \mu_i^* \geq 0, \mu_i^* f_i(x^*) = 0, i = 1, \dots, m \\ \nabla f_0(x^*) + \sum_{i=1}^m \mu_i^* \nabla f_i(x^*) + A^T \lambda^* = 0 \end{aligned} \right\} \quad (0)$$

idea: • Solve (P) or (0) by applying Newton's method to a sequence of modifications of (P) or (0) that only have equality constraints.

• E.g., replace $f_i(x) \leq 0$ by adding a "barrier function" to f_0

• interior point methods produce a sequence x_k with $Ax_k = b, f_i(x_k) < 0, x_k \rightarrow x^*$



Barrier methods: barrier functions

$$(P) \Leftrightarrow \min_x f_0(x) + \sum_{i=1}^m \chi_{-}(f_i(x)) \quad \text{s.t. } Ax = b \quad \text{for } \chi_{-}(s) = \begin{cases} 0 & \text{if } s \leq 0 \\ \infty & \text{else} \end{cases}$$

replace $\chi_{-}(u)$ by $I_{\epsilon}(u) = -\frac{1}{\epsilon} \ln(-u)$, $\text{dom } I_{\epsilon} = \{u \in \mathbb{R} \mid u < 0\}$

Thm: For $\epsilon > 0$, I_{ϵ} is convex, differentiable, non-decreasing

$$\cdot I_{\epsilon}(u) \xrightarrow{u \uparrow 0} \infty, I_{\epsilon}(u) = 0 \text{ for } u > 0$$

□

Def: The logarithmic barrier function ϕ to (P) is given by

$$\phi(x) = -\sum_{i=1}^m \ln(-f_i(x)), \quad \text{dom } \phi = \{x \in \mathbb{R}^n \mid f_1(x), \dots, f_m(x) < 0\}$$

$$\nabla \phi(x) = -\sum_{i=1}^m \frac{1}{f_i(x)} \nabla f_i(x), \quad \mathbb{D}^2 \phi(x) = \sum_{i=1}^m \frac{1}{f_i^2(x)} \nabla f_i(x) \nabla f_i(x)^T - \frac{1}{f_i(x)} \mathbb{D}^2 f_i(x)$$

ϕ is convex.

• The barrier problem to (P) is given by

$$\min_x t f_0(x) + \phi(x) \quad \text{s.t. } Ax = b \quad (P_{\epsilon})$$

• The central path is $\{x^*(t) \mid t > 0\}$, where $x^*(t)$ is the optimal point of (P_{ϵ}) ; it

$$\text{satisfies } \exists \lambda \in \mathbb{R}^r: 0 = t \nabla f_0 + \nabla \phi + A^T \lambda$$

Optimization algorithms: Interior point methods for ineq.-constrained optim.

Barrier methods: algorithm

Thm: Let (x^*, λ^*) be optimal primal dual pair for (P_ϵ) , then (μ^*, λ^*) is dually feasible for $\mu_i^* = \frac{-1}{\epsilon f_i(x^*)}$, and $f_0(x^*) - g(\mu^*, \lambda^*) = \frac{m}{\epsilon}$, i.e. x^* and (μ^*, λ^*) are $\frac{m}{\epsilon}$ -suboptimal.

proof: $\mu_i^* > 0$ due to $f_i(x^*) < 0$

• optimality condition for (P_ϵ) : $0 = \nabla f_0 + \frac{\nabla \phi}{\epsilon} + A^T \lambda^* = \nabla f_0(x^*) + \sum_{i=1}^m \mu_i^* \nabla f_i(x^*) + A^T \lambda^*$

$\Rightarrow x^* = \underset{x}{\operatorname{argmin}} (f_0(x) + \sum_{i=1}^m \mu_i^* f_i(x) + \lambda^{*T}(Ax - b)) = \underset{x}{\operatorname{argmin}} L(x, (\mu^*, \lambda^*))$

• $p^* \geq g(\mu^*, \lambda^*) = \underset{x}{\operatorname{min}} L(x, (\mu^*, \lambda^*)) = L(x^*, (\mu^*, \lambda^*)) = f_0(x^*) - \frac{1}{\epsilon} \sum_{i=1}^m \frac{f_i(x^*)}{f_i(x^*)}$ □

Alg (barrier method): given: strictly feasible x , $t = t_0 > 0$, $\beta > 1$, tolerance $\epsilon > 0$

iterate until $\frac{m}{t} < \epsilon$:

step 1: solve (P_t) via Newton's method with initial guess x

step 2: $x \leftarrow x^*(t)$, $t \leftarrow \beta t$

Rem: The previous theorem implies convergence $f_0(x^*(t)) \rightarrow p^*$.

Barrier methods: complexity

usually not fulfilled for barrier function
but can be relaxed to a "self-concordance"
assumption

Thm: Let $D^2 f_0 + \frac{1}{\epsilon} D^2 \phi$ Lipschitz with constant L , $\tilde{m} I \leq D^2 f_0(x) + \frac{1}{\epsilon} D^2 \phi \leq M I$
for some $\tilde{m}, M > 0$ and all $\epsilon > 0$, then the barrier method reaches an x with $\|x - x^*\|_2 < \epsilon$
after $N = \frac{\log \frac{\tilde{m}}{\epsilon_0 \epsilon}}{\log \beta} \left(\frac{m(\beta - 1 - \log \beta)}{\gamma} + C \log_2 \log \frac{1}{\epsilon} \right)$ steps for some $C, \gamma > 0$,
where $\tilde{\epsilon}$ is the accuracy of solving (P_ϵ) .

linear convergence

proof: every iteration takes $\frac{f(x) - p^*}{\gamma} + C \log_2 \log \frac{1}{\tilde{\epsilon}}$ Newton steps starting from x
where $f = \epsilon f_0 + \phi$, $x = x^*(\epsilon/\beta)$, $x^+ = x^*(\epsilon)$, $p^* = f(x^+)$

$\cdot \epsilon f_0(x) + \phi(x) - \epsilon f_0(x^+) - \phi(x^+) = \epsilon f_0(x) - \epsilon f_0(x^+) + \sum_{i=1}^m (-\log(-\mu_i(x)) + \log(-\mu_i(x^+)))$

$= \epsilon f_0(x) - \epsilon f_0(x^+) + \sum_{i=1}^m \underbrace{\log(-\mu_i(x^+))}_{\leq -\mu_i(x^+) - 1} - m \log \beta$

$\mu_i = \frac{\beta}{-\epsilon f_i(x)}$ (multiplier from previous iteration)

$\leq \epsilon f_0(x) - \epsilon \left(f_0(x^+) + \sum_{i=1}^m \mu_i f_i(x^+) + \lambda^T (A x^+ - b) \right) - m - m \log \beta \leq m(\beta - 1 - \log \beta)$
(similar to duality gap on previous slide!)

$\geq g(\mu, \lambda) = f_0(x) - \frac{m}{\epsilon} \beta$

\Rightarrow need less than $\frac{m(\beta - 1 - \log \beta)}{\gamma} + C \log_2 \log \frac{1}{\tilde{\epsilon}}$ Newton steps

\cdot in total $\log \frac{\tilde{m}}{\epsilon_0 \epsilon} / \log \beta$ outer iterations □

Optimierungsalgorithmen: Nicht-innere-Punkt-Methoden


Bestrafungs-Methode

$\min_{x \in \mathbb{R}^n} f_0(x)$ s.d. $c_I(x) = (f_1(x), \dots, f_m(x)) \leq 0$ *ersetze eventuelle Gleichungs-NB $g_i(x) = 0$ durch $g_i(x) \leq 0$ & $-g_i(x) \leq 0$* (P)

Def: Eine Straffunktion für die Nebenbedingungen $f_1(x), \dots, f_m(x) \leq 0$ ist eine Funktion $P(x) = \gamma(c_I^+(x))$ mit $c_I^+(x) = (\max\{0, f_1(x)\}, \dots, \max\{0, f_m(x)\})$ und $\gamma: [0, \infty)^m \rightarrow [0, \infty)$ sodass $\gamma(0) = 0$, $\gamma(p) > 0$ für $p \neq 0$, γ stetig

Bsp: $\gamma(p) = \frac{1}{2} p^T T p$ für ein positiv definites $T \in \mathbb{R}^{m \times m}$

• Fall $T = I$ liefert $P(x) = \frac{1}{2} \sum_{i=1}^m (\max\{0, f_i(x)\})^2$



Alg (Bestrafungsmethode): geg: $0 < c_1 < c_2 < \dots$, $\lim_{k \rightarrow \infty} c_k = \infty$
für $k = 1, 2, \dots$

$$x_k = \underset{x}{\operatorname{argmin}} q(c_k, x) = \underset{x}{\operatorname{argmin}} f_0(x) + c_k P(x)$$

Wir wollen annehmen, dass eine Lösung x_k in jedem Schritt k existiert.

Optimierungsalgorithmen: Nicht-innere-Punkt-Methoden

Bestrafungs-Methode: Konvergenz

Thm: Es gilt $q(c_k, x_k) \leq q(c_{k+1}, x_{k+1})$, $P(x_k) \geq P(x_{k+1})$, $f_0(x_k) \leq f_0(x_{k+1})$.

Bew: $q(c_{k+1}, x_{k+1}) = f_0(x_{k+1}) + c_{k+1} P(x_{k+1}) \geq f_0(x_{k+1}) + c_k P(x_{k+1}) \geq f_0(x_k) + c_k P(x_k) = q(c_k, x_k)$

$$f_0(x_k) + c_k P(x_k) \leq f_0(x_{k+1}) + c_k P(x_{k+1}) + f_0(x_{k+1}) + c_{k+1} P(x_{k+1}) \leq f_0(x_k) + c_{k+1} P(x_k) = (c_{k+1} - c_k) P(x_{k+1}) \leq (c_{k+1} - c_k) P(x_k)$$

$$f_0(x_{k+1}) + c_k P(x_{k+1}) \geq f_0(x_k) + c_k P(x_k) \geq f_0(x_k) + c_k P(x_{k+1}) \Rightarrow f_0(x_{k+1}) \geq f_0(x_k) \quad \square$$

Thm: x^* löse (P), dann gilt $f_0(x^*) \geq q(c_k, x_k) \geq f_0(x_k)$.

Bew: $f_0(x^*) = f_0(x^*) + c_k P(x^*) \geq f_0(x_k) + c_k P(x_k) \geq f_0(x_k) \quad \square$

Thm: x_1, x_2, \dots werde generiert durch die Bestrafungsmethode. Jeder Häufungspunkt löst (P).

Bew: Sei $k \in \mathbb{N}$ Indizes einer Teilfolge mit $\lim_{k \in K} x_k = x$ (somit $\lim_{k \in K} f_0(x_k) = f_0(x)$)

$q(c_k, x_k)$ ist monoton & beschränkt durch $f_0(x^*)$, somit $\lim_{k \in K} q(c_k, x_k) = q^* \leq f_0(x^*)$

$\lim_{k \in K} c_k P(x_k) = \lim_{k \in K} q(c_k, x_k) - f_0(x_k) = q^* - f_0(x) \Rightarrow P(x) = \lim_{k \in K} P(x_k) = 0 \Rightarrow x$ ist zulässig

$f_0(x) = \lim_{k \in K} f_0(x_k) \leq f_0(x^*)$ nach vorherigem Thm $\Rightarrow x$ ist optimal $\quad \square$

Optimierungsalgorithmen: Aktive-Mengen-Methoden für Ungleichungs-NB

Aktive-Mengen-Methode

$$\min_{x \in \mathbb{R}^n} f_0(x) \quad \text{s.d.} \quad f_1(x), \dots, f_m(x) \leq 0, \quad g_1(x), \dots, g_p(x) = 0 \quad (P)$$

Def: Gegeben den optimalen Punkt $x^* \in \mathbb{R}^n$, ist die aktive Menge definiert als $A = \{i \in \{1, \dots, m\} \mid f_i(x^*) = 0\}$.

Wäre A bekannt, würde (P) reduziert auf ein Problem mit Gleichungsnebenbedingungen.

Aktive-Mengen-Methoden raten & aktualisieren A (die aktuelle Vermutung heißt „Arbeitsmenge“ W)

Alg (Aktive-Mengen-Methode): geg: $f_0, \dots, f_m, g_1, \dots, g_p, W \subset \{1, \dots, m\}$

repeat

1) minimiere $f_0(x)$ s.d. $f_j(x) = g_j(x) = 0 \quad \forall j \in \{1, \dots, p\}, i \in W$ (P_W)
Nebenbedingung verletzt

wenn $f_i(x) > 0$ für ein $i \notin W$, füge i zu W hinzu und wiederhole Schritt 1)

2) aktualisiere Arbeitsmenge: $W = \{j \in \{1, \dots, m\} \mid \underbrace{f_j(x) = 0 \ \& \ \mu_j \geq 0}_{\text{Ungl.-Nebenbedingung ist aktiv}}\}$

until W ändert sich nicht

Lagrange-Multiplikatoren für NB $f_j = 0$

Optimierungsalgorithmen: Aktive-Mengen-Methoden für Ungleichungs-NB

Aktive-Mengen-Methode: Konvergenz

Bem.: Schritt 1) kann jede Methode für Optimierung unter Gleichungs-Nebenbedingungen nutzen.

• Wenn W sich nicht ändert, dann gibt es $\mu \in \mathbb{R}^m$, $\lambda \in \mathbb{R}^p$ mit

$$0 = Df_0(x) + \sum_{i=1}^m \mu_i Df_i(x) + \sum_{j=1}^p \lambda_j Dg_j(x) \quad , \quad g_1(x) = \dots = g_p(x) = 0,$$

$$f_i(x) < 0, \mu_i = 0, i \notin W \quad , \quad f_i(x) = 0, \mu_i \geq 0, i \in W,$$

d.h. $W = A$ und x erfüllt die KKT-Bedingungen.

Thm.: Angenommen, für jedes $W \subset \{1, \dots, m\}$ habe (P_W) eine eindeutige nichtdegenerierte Lösung (d.h. $\mu_i \neq 0 \forall i \in W$). Dann konvergiert die Aktive-Mengen-Methode gegen ein Optimum von (P) .

Bew.: Nachdem die Lösung für eine Arbeitsmenge W gefunden wurde, sinkt für die nächste Arbeitsmenge der Funktionswert im Optimum von $(P_W) \Rightarrow$ man kann nie zu einer alten Arbeitsmenge zurückkehren.

Prozess muss mit $W = A$ terminieren, da es nur endlich viele Arbeitsmengen gibt. \square

Bem.: Viele Optimierungen mit falschem W nötig.

• Um W zu aktualisieren, muss im Prinzip (P_W) exakt gelöst werden.

Man könnte W
unendlich oft ändern.

• In der Praxis stoppt man Optimierung von (P_W) vorzeitig (mithilfe von Heuristiken), aber Konvergenz unklar.

Lokale Konvexität

$$f_0, \dots, f_n, g_1, \dots, g_p \in C^2$$

$$\min_{x \in \mathbb{R}^n} f_0(x) \text{ s.d. } c_E(x) = (g_1, \dots, g_p)^T(x) = 0, \quad c_I(x) = (f_1, \dots, f_m)^T(x) \leq 0 \quad (P)$$

Sei x^* ein lokales Minimum von (P) & es sei regulär bzgl. der Nebenbedingungen.

$$\exists \lambda^* \in \mathbb{R}^p, \mu^* \in [0, \infty)^m: \quad Df_0(x^*) + \lambda^{*T} Dc_E(x^*) + \mu^{*T} Dc_I(x^*) = 0, \quad \mu_i^* f_i(x^*) = 0, \text{ und}$$

$$L_{xx}(x^*, \mu^*, \lambda^*) = D^2 f_0(x^*) + \sum_{i=0}^p \lambda_i^* D^2 g_i(x^*) + \sum_{i=1}^m \mu_i^* D^2 f_i(x^*) \text{ ist positiv semi-definit auf dem}$$

Tangentenraum $T_{x^*} S$ an die aktiven Nebenbedingungen (d.h. $c_E(x^*) = 0$ & $f_i(x^*) = 0$ für $i \in A = \{i \in \{1, \dots, m\} \mid f_i(x^*) = 0\}$)

Def: Die Bedingung „ $L_{xx}(x^*, \mu^*, \lambda^*)$ ist positiv definit auf \mathbb{R}^n “ (C)

heißt lokale Konvexitätsannahme.

Thm: Unter (C) ist x^* ein lokales Minimum des Problems ohne Nebenbedingungen mit $\min_{x \in \mathbb{R}^n} f_0(x) + \lambda^{*T} c_E(x) + \mu^{*T} c_I(x)$

Anforderung hat $\underbrace{f_0(x) + \lambda^{*T} c_E(x) + \mu^{*T} c_I(x)}_{L(x, \mu, \lambda)}$ für jedes (μ, λ) in einer Umgebung von (μ^*, λ^*) mit $\mu_i = 0$ für $i \notin A$ ein lokales Minimum x^* nahe bei x^* .

Bew.: x^* erfüllt die 2. Ordnung hinreichende Optimalitätsbedingung.

$$L_{xx}(x^*, \mu^*, \lambda^*) \text{ pos. def.} \xrightarrow{\text{impl. Funktionen thm.}} L_x(x, \mu, \lambda) = 0 \text{ hat eine lokale, differenzierbare Lsg. } x(\mu, \lambda)$$

außerdem ist $L_{xx}(x, \mu, \lambda)$ pos. def. \Rightarrow 2. Ordnung hinreichende Opt.-Bed. ist erfüllt. □

Optimierungsalgorithmen: Glatte primal-duale Methoden

Lokale Dualität

(wird zu globaler Dualität für konvexe Probleme)

Im Folgenden nehmen wir an, dass alle Nebenbedingungen aktiv sind (sonst ignoriere inaktive NB).

Def: Die (lokale) duale Funktion ist definiert für (μ, λ) nahe (μ^*, λ^*) als $g(\mu, \lambda) = \min_{x \text{ nahe } x^*} L(x, \mu, \lambda)$.

Unter (C) ist dies wohldefiniert. Den Minimierer bezeichnen wir mit $x(\mu, \lambda)$.

Thm: $Dg(\mu, \lambda) = (c_I(x(\mu, \lambda))^T \quad c_E(x(\mu, \lambda))^T)$

$$D^2g(\mu, \lambda) = - \begin{pmatrix} D c_I \\ D c_E \end{pmatrix} L_{xx}(x(\mu, \lambda), \mu, \lambda)^{-1} (\nabla c_I \quad \nabla c_E) \quad \text{ausgewertet an } x = x(\mu, \lambda).$$

Bew: Kürze ab $\bar{x} = x(\mu, \lambda)$, dann ist $g(\mu, \lambda) = \underbrace{f_0(\bar{x})}_{=0} + \mu^T c_I(\bar{x}) + \lambda^T c_E(\bar{x}) = L(\bar{x}, \mu, \lambda)$

$$\Rightarrow Dg(\mu, \lambda) = L_x(\bar{x}, \mu, \lambda) D_{(\mu, \lambda)} \bar{x} + (c_I(\bar{x})^T \quad c_E(\bar{x})^T) = (c_I(\bar{x})^T \quad c_E(\bar{x})^T)$$

$$\Rightarrow D^2g(\mu, \lambda) = \begin{pmatrix} D c_I(\bar{x}) \\ D c_E(\bar{x}) \end{pmatrix} D_{(\mu, \lambda)} \bar{x} \quad \leftarrow \text{löse nach } D_{(\mu, \lambda)} \bar{x} \text{ auf und setze ein}$$

Nun differenziere $0 = L_x(\bar{x}, \mu, \lambda)$ nach (μ, λ) : $0 = L_{xx}(\bar{x}, \mu, \lambda) D_{(\mu, \lambda)} \bar{x} + (\nabla c_I(\bar{x}) \quad \nabla c_E(\bar{x})) \quad \square$

Thm: (lokale Dualität) Sei x^* regulär & lokal optimal für (P) mit Lagrange-Multiplikatoren (μ^*, λ^*) . Unter (C)

hat das duale Problem $\max_{(\mu, \lambda) \in \mathbb{R}^{n \times p}, \mu \geq 0} g(\mu, \lambda)$ die lokale Lösung (μ^*, λ^*) mit $g(\mu^*, \lambda^*) = f_0(x^*)$ starke Dualität

Bew: Nach oben gezeigt ist $x(\mu^*, \lambda^*) = x^*$ & $Dg(\mu^*, \lambda^*) = (c_I(x^*)^T \quad c_E(x^*)^T) = 0$ & $D^2g(\mu^*, \lambda^*)$ ist neg. def.

$\Rightarrow (\mu^*, \lambda^*)$ ist lokales Maximum von g mit $g(\mu^*, \lambda^*) = \min_{x \text{ nahe } x^*} f_0(x) + \mu^{*T} c_I(x) + \lambda^{*T} c_E(x) = f_0(x^*) \quad \square$

Optimierungsalgorithmen: Glatte primal-duale Methoden

Duale Probleme und Straffunktionen

• Steilster Abstieg für (P) in x für feste (μ^*, λ^*) hat eine Konvergenzrate, die abhängt von der Konditionszahl κ von $L_{xx}(x^*, \mu^*, \lambda^*)$ eingeschränkt auf den Tangentialraum $T_{x^*}S$ an die aktiven Nebenbedingungen.

• Steilster Anstieg für das duale Problem in (μ, λ) hat eine Konvergenzrate, die abhängt von $\kappa(D^2g(\mu^*, \lambda^*))$ mit $D^2g(\mu^*, \lambda^*) = - \begin{pmatrix} Dc_I \\ Dc_E \end{pmatrix} L_{xx}^{-1} (Dc_I \ Dc_E)_{an}(x^*, \mu^*, \lambda^*)$, eine Restriktion von L_{xx}^{-1} auf $T_{x^*}S^+$!

Problem: $L_{xx}(x^*, \mu^*, \lambda^*)$ ist im. Allg. nicht pos. definit \Rightarrow lokale Dualität ist nicht anwendbar!

• Konvergenzrate des steilsten Abstiegs für ein Subproblem in der Bestrafungsmethode hängt von der Konditionszahl von $D^2q(c_k, x_k)$ ab, z.B. für $P(x_k) = \frac{1}{2} \|c_E(x_k)\|_2^2 + \frac{1}{2} \|c_I^+(x_k)\|_2^2$ ^{max q, c_I^+}

$$D^2q(c_k, x_k) = D^2f_0(x_k) + c_k \left[\sum_{i=1}^p q_i(x_k) D^2g_i(x_k) + \sum_{i=1}^m \beta_i(x_k) D^2\beta_i(x_k) + (Dc_I^+(x_k) \ Dc_E(x_k)) \begin{pmatrix} Dc_I^+(x_k) \\ Dc_E(x_k) \end{pmatrix} \right]$$
$$= L_{xx}(x_k, \mu_k, \lambda_k) + c_k (Dc_I^+(x_k) \ Dc_E(x_k)) \begin{pmatrix} Dc_I^+(x_k) \\ Dc_E^+(x_k) \end{pmatrix} \quad \text{für } (\mu_k, \lambda_k) = c_k (c_I^+(x_k), c_E(x_k))$$

Problem: Wenn $c_k \rightarrow \infty$, wird die Konditionszahl beliebig schlecht

(größter Eigenwert wächst wie c_k , kleinster Eigenwert bleibt ungefähr konstant).

Wenn Newton-Verfahren genutzt wird, dann hängt stattdessen die Effizienz der Lösung der Newton-Gleichungen von der Konditionszahl ab.

Augmentierte Lagrange-Methode: Motivation mittels Dualität

$$\min_{x \in \mathbb{R}^n} f_0(x) \text{ s.d. } c_E(x) = 0 \quad \Leftrightarrow \quad \min_{x \in \mathbb{R}^n} f_0(x) + \frac{c}{2} \|c_E(x)\|_2^2 \text{ s.d. } c_E(x) = 0$$

für jedes $c \in [c_0, \infty)$!

Lagrange-Funktion der ursprünglichen Formulierung

• Lagrange-Funktion der neuen Formulierung ist $L(x, \lambda) + \frac{c}{2} \|c_E(x)\|_2^2$.

• Man hat die gleichen 1. Ordnung - Opt. - Bed. & Lagrange-Multiplikatoren λ^* , aber die Hessesche am Optimum ist $L_{xx}(x^*, \lambda^*) + c \nabla c_E(x^*) \nabla c_E(x^*)^T \Rightarrow$ pos. def. für c groß genug!

\Rightarrow duale Methode ist nun anwendbar!

• Duale Funktion $g(\lambda) = \min_{x \text{ nahe } x^*} f_0(x) + \lambda^T c_E(x) + \frac{c}{2} \|c_E(x)\|_2^2$ hat am Optimum die Hessesche

$$D^2 g(\lambda^*) = - D c_E(x^*) \left[D^2 f_0(x^*) + \sum_{i=1}^p \lambda_i^* D^2 g_i(x^*) + c \nabla c_E(x^*) \nabla c_E(x^*)^T \right]^{-1} \nabla c_E(x^*)$$

$\Rightarrow D^2 g(\lambda^*)$ nähert sich $-\frac{1}{c} I$ für $c \rightarrow \infty$ mit Konditionszahl 1

\Rightarrow extrem schnelle Konvergenz des dualen Anstiegs / sehr effiziente Newton-Methode.

• Für das duale Problem nutzt modifiziertes Newton-Verfahren, indem Hessesche mit $-\frac{1}{c} I$ approximiert wird

$$\Rightarrow \lambda_{k+1} = \lambda_k + c \nabla g(\lambda_k) = \lambda_k + c c_E(x_k)^T$$

kann auch aufgefasst werden als Gradientenanstieg mit Schrittweite c

wobei x_k $f_0(x) + \lambda_k^T c_E(x) + \frac{c}{2} \|c_E(x)\|_2^2$ minimiert

Augmentierte Lagrange-Methode: Motivation mittels Bestrafung

$$\min_{x \in \mathbb{R}^n} f_0(x) \text{ s.d. } c_E(x) = 0 \quad (\Leftrightarrow) \quad \min_{x \in \mathbb{R}^n} f_0(x) + \lambda^T c_E(x) \quad \text{s.d. } c_E(x) = 0$$

- für bel. $\lambda \in \mathbb{R}^p$

- Bestrafungsmethode - Zielfunktional $q(c, x) = f_0(x) + \lambda^T c_E(x) + \frac{c}{2} \|c_E(x)\|_2^2$
- Wenn $\lambda = \lambda^*$ für den Lagrange-Multiplikator des ursprünglichen Problems, dann ist $Dq(c, x^*) = Df_0(x^*) + \lambda^{*T} Dc_E(x^*) + c c_E(x^*)^T Dc_E(x^*) = 0$
 \Rightarrow Bestrafungsmethode ist exakt für endlich großes c ! \Rightarrow Hessesche ist besser konditioniert
- optimaler Punkt x^* erfüllt $0 = Df_0(x^*) + \lambda^{*T} Dc_E(x^*)$
 Bestrafungsmethoden-Iterat erfüllt $0 = Df_0(x_k) + (\lambda_k + c c_E(x_k))^T Dc_E(x_k)$
 \Rightarrow wähle $\lambda_{k+1} \approx \lambda^* \approx \lambda_k + c c_E(x_k)$

Optimierungsalgorithmen: Glatte primal-duale Methoden

Augmentierte Lagrange-Methode: Algorithmus

Def: $L_c(x, \lambda) = f_0(x) + \lambda^T c_E(x) + \frac{c}{2} \|c_E(x)\|_2^2$ heißt augmentierte Lagrange-Funktion zu (P)

Alg: Geg: $f_0, c_E, \lambda_0, \varepsilon > 0$, monoton wachsende Folge $c_0, c_1, \dots \nearrow \infty, k=0$

repeat $x_{k+1} = \underset{x \in \mathbb{R}^n}{\text{argmin}} L_{c_k}(x, \lambda_k)$ (lokale Minimierung)

$$\lambda_{k+1} = \lambda_k + c_k c_E(x_{k+1})$$

$$k \leftarrow k+1$$

until $|c_E(x_k)| \leq \varepsilon$

Thm: Sei (x^*, λ^*) optimal für (P) & regulär bzgl. NB & erfülle die hinreichenden Opt.-Bed. 2. Ord.

Es gibt ein $c^* \in \mathbb{R}$ sodass $L_c(x, \lambda^*)$ ein lokales Minimum in x^* hat für alle $c > c^*$.

Bew: 1. Ord. Opt.-Bed. ist in x^* erfüllt, prüfe nur positive Definitheit von $D_x^2 L_c$

$$D_x^2 L_c(x^*, \lambda^*) = L_{xx}(x^*, \lambda^*) + c D c_E(x^*)^T D c_E(x^*) = A + c B$$

A ist pos. def. auf $T_{x^*} S = \ker B$
 B pos. def. auf $T_{x^*} S^\perp = \text{span}(\nabla c_E(x^*))$

angenommen, es gibt $c_k \nearrow \infty, p_k$ mit $\|p_k\|_2 = 1$ & $p_k^T (A + c_k B) p_k \leq 0$; für eine Teilfolge $p_k \rightarrow p$

$$p^T B p = \lim_k p_k^T B p_k \leq \limsup_k \frac{-p_k^T A p_k}{c_k} = 0 \Rightarrow p^T B p = 0 \Rightarrow B p = 0$$

$$0 \geq \limsup_k p_k^T (A + c_k B) p_k = p^T A p + \limsup_k c_k \underbrace{p_k^T B p_k}_{\geq 0} \geq p^T A p \Rightarrow \text{Widerspruch zu } p \in \ker B \quad \square$$

Bem: Wegen Stetigkeit gilt Obiges auch in Umgebung von $(x^*, \lambda^*) \Rightarrow$ Methode ist wohldefiniert.

Optimierungsalgorithmen: Glatte primal-duale Methoden

Augmentierte Lagrange-Methode: Beispiel

Bsp: $\min_{(x,y) \in \mathbb{R}^2} 2x^2 + 2xy + y^2 - 2y$ s.d. $x=0$

$$\cdot L_c(x, y, \lambda) = 2x^2 + 2xy + y^2 - 2y + \lambda x + \frac{c}{2} x^2$$

$$\cdot (x_{k+1}, y_{k+1}) = \underset{x,y}{\text{Argmin}} L_c(x, y, \lambda_k) = \left(-\frac{2+\lambda_k}{2+c_k}, \frac{4+c_k+\lambda_k}{2+c_k} \right)$$

$$\lambda_{k+1} = \lambda_k + c_k x_{k+1} = \frac{2\lambda_k + c_k \lambda_k}{2+c_k} + c_k \left(-\frac{2+\lambda_k}{2+c_k} \right) = \frac{2}{2+c_k} \lambda_k - \frac{2c_k}{2+c_k}$$

$$\cdot \lambda_k \xrightarrow[k \rightarrow \infty]{} -2 \text{ mit } (\lambda_{k+1} + 2) = \frac{2}{2+c_k} (\lambda_k - 2) \Rightarrow \text{lineare Konvergenz mit Konstante } \frac{2}{2+c_k}$$

Bsp: $\min_{(x,y) \in \mathbb{R}^2} 2x^2 + 2xy + y^2 - 2y$ s.d. $x=0, y \leq 0$

$$\cdot \text{ersetze durch } \min_{(x,y,z) \in \mathbb{R}^3} 2x^2 + 2xy + y^2 - 2y \text{ s.d. } x=0, y+z^2=0$$

$$\cdot L_c(x, y, z, \lambda, \nu) = 2x^2 + 2xy + y^2 - 2y + \lambda x + \nu(y+z^2) + \frac{c}{2} x^2 + \frac{c}{2} (y+z^2)^2$$

$$\cdot (x, y, z)_{k+1} = \left(\frac{2\lambda_k - 4 - 2\lambda_k - c_k \lambda_k}{(2+c_k)(4+c_k) - 4}, \frac{2-\nu_k}{2+c_k} + \frac{2\lambda_k - (4\nu_k - 8)/(2+c_k)}{(2+c_k)(4+c_k) - 4}, 0 \right)$$

$$(\lambda, \nu)_{k+1} = (\lambda_k, \nu_k) + c_k (x_{k+1}, y_{k+1}) \quad (= \text{Fixpunktiteration für lineare Kontraktion})$$

$$\cdot (\lambda_k, \nu_k) \xrightarrow[k \rightarrow \infty]{} (0, 2) \quad (\text{lineare Konvergenz für festes } c_k \text{ groß genug})$$

Augmentierte Lagrange-Methode: Konvergenzrate

Erinnerung: Update $\lambda_{k+1} = \lambda_k + c \nabla g(\lambda_k)$ ^{← nimmt festes c an} ist Gradientenanstieg für die
 duale Funktion g zu $\min_{x \in \mathbb{R}^n} f_0(x) + \frac{c}{2} \|c_E(x)\|_2^2$ s.d. $c_E(x) = 0$

⇒ Konvergenzrate hängt ab von Eigenwerten von

$$D^2 g(\lambda^*) = - \underbrace{D c_E(x^*)}_{\text{B}} \left[\underbrace{L_{xx}(x^*, \lambda^*)}_{\text{A}} + c D c_E(x^*)^T D c_E(x^*) \right]^{-1} D c_E(x^*)^T = -B(A + cB^T B)^{-1} B^T$$


Thm: Sei m Eigenwert von $BA^{-1}B^T$, dann ist $\frac{m}{1+cm}$ ^{Hessische der dualen Funktion zu (P)} ein Eigenwert von $B(A + cB^T B)^{-1} B^T$.

Bew: Mit Sherman-Morrison-Woodbury, $B(A + cB^T B)^{-1} B^T = F - c F(Z + cF)^{-1} F$ mit $F = BA^{-1}B^T$

• Sei $Fv = mv$, dann $B(A + cB^T B)^{-1} B^T v = \left(m - \frac{cm^2}{1+cm} \right) v = \frac{m}{1+cm} v$ □

Bem: Die Konvergenzrate des steilsten Anstiegs für das duale Problem zu

(P) hängt ab von der Konditionszahl $\kappa(BA^{-1}B^T) = \frac{M}{m}$ für den
 kleinsten/größten Eigenwert m/M von $BA^{-1}B^T$.



(Der Einfachheit halber nehmen wir lokale Konvexität an.)

• Konvergenzrate der augmentierten Lagrange-Methode hängt ab von $\kappa(B(A + cB^T B)^{-1} B) = \frac{c + \frac{1}{m}}{c + \frac{1}{M}}$.

• Man kann die Konvergenzrate mit einer (modifizierten) Newton-Methode für g noch verbessern.