

Problemstellung: Was ist endlichdimensionale stetige Optimierung?

Problemstellung: Was ist endlichdimensionale stetige Optimierung?

Aufgabenstellung:

- Minimierung einer *stetigen* Zielfunktion $f : X \rightarrow \mathbb{R}$ auf dem nichtleeren zulässigen Bereich $X \subset \mathbb{R}^n$

Problemstellung: Was ist endlichdimensionale stetige Optimierung?

Aufgabenstellung:

- Minimierung einer *stetigen* Zielfunktion $f : X \rightarrow \mathbb{R}$ auf dem nichtleeren zulässigen Bereich $X \subset \mathbb{R}^n$
- Kurzschreibweise:

$$\min f(x) \quad \text{u.d.N.} \quad x \in X \quad (1)$$

Problemstellung: Was ist endlichdimensionale stetige Optimierung?

Aufgabenstellung:

- Minimierung einer *stetigen* Zielfunktion $f : X \rightarrow \mathbb{R}$ auf dem nichtleeren zulässigen Bereich $X \subset \mathbb{R}^n$
- Kurzschreibweise:

$$\min f(x) \quad \text{u.d.N.} \quad x \in X \quad (1)$$

Alternativ:

- Maximierungsprobleme der Form:

$$\max g(x) \quad \text{u.d.N.} \quad x \in X$$

Problemstellung: Was ist endlichdimensionale stetige Optimierung?

Aufgabenstellung:

- Minimierung einer *stetigen* Zielfunktion $f : X \rightarrow \mathbb{R}$ auf dem nichtleeren zulässigen Bereich $X \subset \mathbb{R}^n$
- Kurzschreibweise:

$$\min f(x) \quad \text{u.d.N.} \quad x \in X \quad (1)$$

Alternativ:

- Maximierungsprobleme der Form:

$$\max g(x) \quad \text{u.d.N.} \quad x \in X$$

- Äquivalent zum Minimierungsproblem mit Zielfunktion $f = -g$

Problemstellung: Was ist endlichdimensionale stetige Optimierung?

Aufgabenstellung:

- Minimierung einer *stetigen* Zielfunktion $f : X \rightarrow \mathbb{R}$ auf dem nichtleeren zulässigen Bereich $X \subset \mathbb{R}^n$
- Kurzschreibweise:

$$\min f(x) \quad \text{u.d.N.} \quad x \in X \quad (1)$$

Alternativ:

- Maximierungsprobleme der Form:

$$\max g(x) \quad \text{u.d.N.} \quad x \in X$$

- Äquivalent zum Minimierungsproblem mit Zielfunktion $f = -g$

⇒ Betrachtung von Minimierungsproblemen

Klassifikation (endlichdimensionaler stetiger Optimierung)

Klassifikation (endlichdimensionaler stetiger Optimierung)

- Allgemeine Form: Hat das Optimierungsproblem Nebenbedingungen?
 - $X = \mathbb{R}^n$: unrestringiertes Optimierungsproblem
 - $X \neq \mathbb{R}^n$: restringiertes Optimierungsproblem hierbei kann X durch ein System von Gleichungen, Ungleichungen oder beidem gegeben sein:

$$X = \{x \in \mathbb{R}^n; h(x) = 0, g(x) \leq 0\}$$

Klassifikation (endlichdimensionaler stetiger Optimierung)

- Allgemeine Form: Hat das Optimierungsproblem Nebenbedingungen?
 - $X = \mathbb{R}^n$: unrestringiertes Optimierungsproblem
 - $X \neq \mathbb{R}^n$: restringiertes Optimierungsproblem hierbei kann X durch ein System von Gleichungen, Ungleichungen oder beidem gegeben sein:

$$X = \{x \in \mathbb{R}^n; h(x) = 0, g(x) \leq 0\}$$

- Algebraische Form des Zielfunktional und der Nebenbedingungen

Klassifikation (endlichdimensionaler stetiger Optimierung)

- Allgemeine Form: Hat das Optimierungsproblem Nebenbedingungen?
 - $X = \mathbb{R}^n$: unrestringiertes Optimierungsproblem
 - $X \neq \mathbb{R}^n$: restringiertes Optimierungsproblem hierbei kann X durch ein System von Gleichungen, Ungleichungen oder beidem gegeben sein:

$$X = \{x \in \mathbb{R}^n; h(x) = 0, g(x) \leq 0\}$$

- Algebraische Form des Zielfunktional und der Nebenbedingungen
- Glattheitseigenschaften
 - $f, g, h \in C^k(\mathbb{R}^n)$, $k \geq 1$: glatte Optimierung
 - sonst: nichtglatte Optimierung

Klassifikation (endlichdimensionaler stetiger Optimierung)

- Allgemeine Form: Hat das Optimierungsproblem Nebenbedingungen?
 - $X = \mathbb{R}^n$: unrestringiertes Optimierungsproblem
 - $X \neq \mathbb{R}^n$: restringiertes Optimierungsproblem hierbei kann X durch ein System von Gleichungen, Ungleichungen oder beidem gegeben sein:

$$X = \{x \in \mathbb{R}^n; h(x) = 0, g(x) \leq 0\}$$

- Algebraische Form des Zielfunktional und der Nebenbedingungen
- Glattheitseigenschaften
 - $f, g, h \in C^k(\mathbb{R}^n)$, $k \geq 1$: glatte Optimierung
 - sonst: nichtglatte Optimierung
- Dimension bzw. Besetzungsstruktur des Problems

Klassifikation nach algebraischer Form

Klassifikation nach algebraischer Form

- Lineare Optimierung

$$\min c^T x \quad \text{u.d.N.} \quad Ax = b, x \geq 0$$

- mit $A \in \mathbb{R}^{p \times n}, c \in \mathbb{R}^n, b \in \mathbb{R}^p$

Klassifikation nach algebraischer Form

- Lineare Optimierung
- Quadratische Optimierung

$$\min \frac{1}{2} x^T Q x + c^T x + \gamma \quad \text{u.d.N.} \quad Ax = b, x \geq 0$$

- mit $Q \in \mathbb{R}^{n \times n}$, $A \in \mathbb{R}^{p \times n}$, $c \in \mathbb{R}^n$, $b \in \mathbb{R}^p$, $\gamma \in \mathbb{R}$

Klassifikation nach algebraischer Form

- Lineare Optimierung
- Quadratische Optimierung
- Lineare restringierte Optimierung: f nichtlinear, NBn linear

$$\min f(x) \quad \text{u.d.N.} \quad Ax = b, x \geq 0$$

- mit $f : \mathbb{R}^n \rightarrow \mathbb{R}$, $A \in \mathbb{R}^{p \times n}$, $b \in \mathbb{R}^p$

Klassifikation nach algebraischer Form

- Lineare Optimierung
- Quadratische Optimierung
- Lineare restringierte Optimierung
- Konvexe Optimierung: f konvex, h affin-linear, g_i konvex

$$\min f(x) \quad \text{u.d.N.} \quad h(x) = 0, g(x) \leq 0$$

- mit $f, g_i : \mathbb{R}^n \rightarrow \mathbb{R}$ konvex ($i = 1, \dots, m$), $A \in \mathbb{R}^{p \times n}$, $b \in \mathbb{R}^p$

Klassifikation nach algebraischer Form

- Lineare Optimierung
- Quadratische Optimierung
- Lineare restringierte Optimierung
- Konvexe Optimierung
- Nichtlineare Optimierung: f, g, h beliebig nichtlinear

Lokale und globale Lösungen

Ein Vektor bzw. Punkt $x^* \in \mathbb{R}^n$ heißt

- *lokales Minimum*, falls $x^* \in X$ gilt und $\epsilon > 0$ existiert mit

$$f(x) \geq f(x^*) \quad \forall x \in X \cap B_\epsilon(x^*)$$

mit $B_\epsilon(x^*) := \{x \in \mathbb{R}^n; \|x - x^*\| \leq \epsilon\}$ der ϵ -Kugel um x^* und $\|x\| = \sqrt{x^T x}$ der Euklidischen Norm.

Lokale und globale Lösungen

Ein Vektor bzw. Punkt $x^* \in \mathbb{R}^n$ heißt

- *lokales Minimum*, falls $x^* \in X$ gilt und $\epsilon > 0$ existiert mit

$$f(x) \geq f(x^*) \quad \forall x \in X \cap B_\epsilon(x^*)$$

mit $B_\epsilon(x^*) := \{x \in \mathbb{R}^n; \|x - x^*\| \leq \epsilon\}$ der ϵ -Kugel um x^* und $\|x\| = \sqrt{x^T x}$ der Euklidischen Norm.

- *strikes lokales Minimum*, falls $x^* \in X$ gilt und $\epsilon > 0$ existiert mit

$$f(x) > f(x^*) \quad \forall x \in (X \cap B_\epsilon(x^*)) \setminus \{x^*\}$$

Lokale und globale Lösungen

Ein Vektor bzw. Punkt $x^* \in \mathbb{R}^n$ heißt

- *lokales Minimum*, falls $x^* \in X$ gilt und $\epsilon > 0$ existiert mit

$$f(x) \geq f(x^*) \quad \forall x \in X \cap B_\epsilon(x^*)$$

mit $B_\epsilon(x^*) := \{x \in \mathbb{R}^n; \|x - x^*\| \leq \epsilon\}$ der ϵ -Kugel um x^* und $\|x\| = \sqrt{x^T x}$ der Euklidischen Norm.

- *globales Minimum*, falls $x^* \in X$ gilt und

$$f(x) \geq f(x^*) \quad \forall x \in X$$

Lokale und globale Lösungen

Ein Vektor bzw. Punkt $x^* \in \mathbb{R}^n$ heißt

- *lokales Minimum*, falls $x^* \in X$ gilt und $\epsilon > 0$ existiert mit

$$f(x) \geq f(x^*) \quad \forall x \in X \cap B_\epsilon(x^*)$$

mit $B_\epsilon(x^*) := \{x \in \mathbb{R}^n; \|x - x^*\| \leq \epsilon\}$ der ϵ -Kugel um x^* und $\|x\| = \sqrt{x^T x}$ der Euklidischen Norm.

- *globales Minimum*, falls $x^* \in X$ gilt und

$$f(x) \geq f(x^*) \quad \forall x \in X$$

- *striktes globales Minimum*, falls $x^* \in X$ gilt und

$$f(x) > f(x^*) \quad \forall x \in X \setminus \{x^*\}$$

Lokale und globale Lösungen

Ein Vektor bzw. Punkt $x^* \in \mathbb{R}^n$ heißt


- *lokales Minimum*, falls $x^* \in X$ gilt und $\epsilon > 0$ existiert mit

$$f(x) \geq f(x^*) \quad \forall x \in X \cap B_\epsilon(x^*)$$

mit $B_\epsilon(x^*) := \{x \in \mathbb{R}^n; \|x - x^*\| \leq \epsilon\}$ der ϵ -Kugel um x^* und $\|x\| = \sqrt{x^T x}$ der Euklidischen Norm.

- *globales Minimum*, falls $x^* \in X$ gilt und

$$f(x) \geq f(x^*) \quad \forall x \in X$$



Existenz eines globalen Minimums

Satz

Sei die Funktion $f : X \rightarrow \mathbb{R}$ stetig und es gebe $x_0 \in X$, so dass die Niveaumenge

$$N_f(x_0) = \{x \in X; f(x) \leq f(x_0)\}$$

kompakt ist. Dann besitzt das Problem

$$\min_{x \in X} f(x)$$

ein globales Minimum.

Notwendige und hinreichende Optimalitätskriterien - unrestringierter Fall

Satz

1. Sei $f : U \subset \mathbb{R}^n \rightarrow \mathbb{R}$ stetig differenzierbar auf der offenen Menge $U \subset \mathbb{R}^n$ und $x^* \in U$ ein lokales Minimum von f . Dann ist x^* ein stationärer Punkt, d. h. es gilt

$$\nabla f(x^*) = 0.$$

Ist f zweimal stetig differenzierbar, so ist die Hessematrix $\nabla^2 f(x^*)$ positiv semidefinit.

2. Ist x^* ein stationärer Punkt der zweimal stetig differenzierbaren Funktion f und die Hessematrix $\nabla^2 f(x^*)$ positiv definit, so ist x^* ein isoliertes lokales Minimum.

Notwendige Optimalitätsbedingungen 1. Ordnung - restringierter Fall

Annahmen: f, g, h

- stetig differenzierbar
- erfüllen eine **Constraint Qualification (CQ)** in der Lösung x^*

⇒ Folgende Optimalitätsbedingung 1. Ordnung gilt für alle Lösungen x^* :

Es existieren Lagrange-Multiplikatoren $\lambda^* \in \mathbb{R}^m, \mu^* \in \mathbb{R}^p$, so dass das Tripel (x^*, λ^*, μ^*) das folgende **Karush-Kuhn-Tucker-System** löst:


$$\begin{aligned}\nabla f(x^*) + g(x^*)\lambda^* + h(x^*)\mu^* &= 0, \\ h(x^*) &= 0, \\ g(x^*) \leq 0, \quad \lambda^* \geq 0, \quad \lambda^{*T}g(x^*) &= 0.\end{aligned}$$

mit

- $\nabla f(x) = \left(\frac{\partial f}{\partial x_1} \dots \frac{\partial f}{\partial x_n} \right)^T \in \mathbb{R}^n$ Gradient von f
- $\nabla g(x) \in \mathbb{R}^{n \times m}, \nabla h(x) \in \mathbb{R}^{n \times p}$ transponierte Jacobi-Matrizen von g und h

Visualisierung der Multiplikatorbedingung

$$\nabla f(x^*) + \nabla g(x^*)\lambda^* + h(x^*)\mu^* = 0$$



- Negativer Gradient der Zielfunktion lässt sich als Linearkombination der Jacobi-Matrizen der Nebenbedingungen im KKT-Punkt darstellen (liegt im rot schraffierten Bereich)
- Abstieg ist nur ausserhalb des zulässigen Bereichs möglich

Bemerkung zur globalen Optimierung

Problem:

- Viele Algorithmen suchen stationäre Punkte der Zielfunktion bzw. KKT-Punkte
- Stationarität ist notwendig für lokale Minimalität, aber nicht hinreichend und bedeutet insbesondere nicht notwendig globale Minimalität!
- Eventuell viele lokale Minima
- Algorithmisches Auffinden globaler Minima aufwendig

Bausteine globale Optimierungsalgorithmen:

- Heuristik
- Stochastik
- Deterministik


Nichtglatte Optimierung

Aufgabenstellung:

- Minimiere eine Funktion $f : X \rightarrow \mathbb{R}$ auf dem abgeschlossenen nichtleeren zulässigen Bereich $X \subset \mathbb{R}^n$, d. h.

$$\min_{x \in X} f(x),$$

wobei f lokal Lipschitz-stetig, aber i. a. nicht überall differenzierbar sei.



Idee: Verallgemeinerung

- bekannter Konzepte (\implies mengenwertige Analysis)
- bekannter Verfahren (z.B. steilster Abstieg, Newton, etc.)

Nichtglatte Optimierungsprobleme...

...entstehen durch:

- Aufgabenstellung/Funktionsformulierung
 - l_1 -, l_∞ -Normen, Chebychev Abständen, Maximum einer konvexen Funktion...
- mathematische Transformationen
 - Reformulierung restringierter Optimierungsprobleme in unrestringierte via exakter Penalty-Funktionen
 - Dekomposition in ein master und Teilprobleme (Lagrange Relaxation, Benders Dekomposition, Danzig-Wolfe Dekomposition)

...können z. B. gelöst werden durch:

- Subgradienten Methoden
- Abstiebsmethoden mit ϵ -Subdifferential
- Schnittebenen-Verfahren
 - Kelley's klassisches Schnittebenen-Verfahren
 - Analytic Center Cutting Plane Method
 - Bundle Methoden


Konvexe Funktionen und Subdifferentiale

Konvexe Funktionen und Subdifferenziale

Sei $f : X \rightarrow \mathbb{R}$ konvex auf der konvexen offenen Menge $X \subset \mathbb{R}^n$.

- Der Vektor $g \in \mathbb{R}^n$ heißt *Subgradient* von f im Punkt $x \in X$, wenn gilt

$$f(y) - f(x) \geq g^T (y - x) \quad \forall y \in X.$$



Konvexe Funktionen und Subdifferenziale

Sei $f : X \rightarrow \mathbb{R}$ konvex auf der konvexen offenen Menge $X \subset \mathbb{R}^n$.

- Der Vektor $g \in \mathbb{R}^n$ heißt *Subgradient* von f im Punkt $x \in X$, wenn gilt



$$f(y) - f(x) \geq g^T (y - x) \quad \forall y \in X.$$

- Die Menge $\partial f(x) \subset \mathbb{R}^n$,

$$\partial f(x) = \{g \in \mathbb{R}^n; g \text{ ist Subgradient von } f \text{ in } x\}$$

heißt *Subdifferential* von f im Punkt x . Dies ist eine mengenwertige Abbildung von X in die Potenzmenge des \mathbb{R}^n . Man schreibt hierfür

$$\partial f : X \rightrightarrows \mathbb{R}^n.$$



Variationsungleichungen (kurz: $VI(F, X)$)

- Bestimme $x^* \in \mathbb{R}^n$ mit

$$x \in X, \quad F(x^*)^T(x - x^*) \geq 0 \quad \forall x \in X$$

für $F : U \rightarrow \mathbb{R}^n$ stetig differenzierbar auf einer offenen Umgebung $U \in \mathbb{R}^n$ des (nichtleeren, abgeschlossenen) zulässigen Bereichs $X \in \mathbb{R}^n$.

Variationsungleichungen (kurz: $VI(F, X)$)

- Bestimme $x^* \in \mathbb{R}^n$ mit

$$x \in X, \quad F(x^*)^T(x - x^*) \geq 0 \quad \forall x \in X$$

für $F : U \rightarrow \mathbb{R}^n$ stetig differenzierbar auf einer offenen Umgebung $U \in \mathbb{R}^n$ des (nichtleeren, abgeschlossenen) zulässigen Bereichs $X \in \mathbb{R}^n$.

- Anschaulich: Winkelbedingung


$$\begin{aligned} \cos \angle (F(x^*), x - x^*) &= \frac{F(x^*)^T(x - x^*)}{\|F(x^*)\| \|x - x^*\|} \geq 0 \\ \iff \angle (F(x^*), x - x^*) &\leq 90^\circ \\ \iff \angle (-F(x^*), x - x^*) &\geq 90^\circ \end{aligned}$$

Variationsungleichungen (kurz: $VI(F, X)$)

- Bestimme $x^* \in \mathbb{R}^n$ mit

$$x \in X, \quad F(x^*)^T(x - x^*) \geq 0 \quad \forall x \in X$$

für $F : U \rightarrow \mathbb{R}^n$ stetig differenzierbar auf einer offenen Umgebung $U \in \mathbb{R}^n$ des (nichtleeren, abgeschlossenen) zulässigen Bereichs $X \in \mathbb{R}^n$.



Seminarthemen I

Numerische Optimierung und Anwendungen

- Quasi-Newton-Verfahren
- Klassische Verfahren der nichtlinearen restringierten Optimierung: Penalty-, Barriere- und Augmented-Lagrange-Verfahren
- Trust-Region SQP-Verfahren
- Themen zu Innere-Punkte Verfahren
 - Innere-Punkte-Verfahren und die Optimierungssoftware Ipopt (KBS)
 - Fachwerk/Material-Optimierung via Innere Punkte Verfahren
- Data Mining via Support Vector Machines

Seminarthemen II

Nichtglatte Optimierung/Variationsungleichungen

- Grundlegende Methoden für nichtglatte konvexe Probleme: Subgradienten-/Schnittebenenmethode
- ACCP-Methoden angewandt auf Mehrgüterfluss-Probleme (z. B. Verkehrsstromverteilung)
 - ACCPM with nonlinear constraint and an active set strategy to solve nonlinear multicommodity flow problems
 - An effective method to compute traffic assignment problems with elastic demands
- ϵ -Subdifferenziale und Bundle-Methoden
- Verteilte Optimierung via Dekomposition
 - Distributed Estimation via Dual Decomposition
 - Parallel implementation of a central decomposition method for solving large-scale planning problems
- Robustes Gradient Sampling für nichtglatte nichtkonvexe Optimierung
- Variationsungleichungen am Beispiel von Nash-Gleichgewichten sowie Fixpunkt- und Josephy-Newton-Verfahren

Seminarthemen III

Globale Optimierung

- Tunneling Algorithmus (Guntram Seitz)
- Evolutionäre Algorithmen:
 - Überblick über Evolutions Strategien (ES)
 - Destochastisiertes ES (CMA-ES)
 - Genetische Algorithmen
- Controlled Random Search
- Deterministische globale Optimierung:
 - Piecewise-Linear Underestimation
 - Convex Global Underestimation
- Vergleich dreier globaler Optimierungstechniken am Beispiel von zivilen Hochgeschwindigkeitstransportsystemen

Nichtlineare Optimierung

Quasi-Newton-Methoden (Nocedal/Wright 2000, S.192-219, 222–226, Ulbrich 2003, S.57-64)

- Themenbereich: Nichtlineare Gleichungen, Nichtlineare Optimierung
- Idee: Iterative Approximation der Jacobi-Matrix in Quasi-Newton-Gleichung
- Aufdatierungsformeln:
 - BFGS
 - SR1
 - Broyden Klasse
 - Large-Scale Quasi-Newton: Limited-Memory BFGS
- Zusammenhang zum CG-Verfahren

Klassische Verfahren der nichtlinearen Optimierung: Penalty und Barriere-Verfahren sowie Augmended-Lagrange-Verfahren (Ulbrich S. 90-110)

- Themenbereich: Nichtlineare restringierte Optimierung
- Verfahren überführen restringierte Optimierungsprobleme in Folgen von unrestringierten Teilproblemen. Teilprobleme müssen dann mit externen Lösern gelöst werden.
- **Penalty-Verfahren:**
 - Idee: Hinzunahme von gewichteten Straftermen (engl. penalty = Strafe) zur Zielfunktion ausserhalb des zulässigen Bereichs
 - Problem: Je größer der Penalty-Parameter (das Gewicht), desto genauer ist zwar die Lösung, aber desto schwieriger auch die numerische Behandlung
- **Barriere-Verfahren:**
 - Idee: Barriere innerhalb des zulässigen Bereichs, bestraft das zu Nahe kommen an den Rand des zulässigen Bereichs
- **Augmended-Lagrange-Verfahren (Penalty-Multiplier-Methode):**
 - Weiterentwicklung des quadratischen Penalty-Verfahrens
 - Vorteil: Penalty-Parameter muss nicht gegen unendlich streben, um globale Konvergenz zu erhalten

Innere-Punkte Verfahren und Ipopt

Analysis of Inexact Trust-Region SQP Algorithms (Heinkenschloss/Vicente 2002, Nocedal/Wright 2000, S. 553-563)

- Verfahren erlaubt inexacte Problem Information (z. B. durch Approximation der ersten Ableitung)
- Global konvergent

Data Mining via Support Vector Machines (Mangasarian 2001)

- Klassifizierung von Daten
- Idee: aus statistischer Lerntheorie, Trennung der Eingabe einer gegebenen Mustermenge durch eine Hyperebene
- Anwendungen: Spam-Filter, Handschriften-Erkennung, Identifikation von Tumormerkmalen
- Überblick:
 - verallgemeinerte SVM
 - glatte SVM (Lösbar mit schnellem Newton-Armijo-Algorithmus)
 - Lagrange SVM
 - reduzierte SVM

Nichtglatte Optimierung

Grundlegende Methoden für nichtglatte konvexe Probleme: Subgradienten-/Schnittebenenmethode (Geiger/Kanzow 2000, S. 314-348, 365-374, Ulbrich, 2004, S. 36-47)

- Themenbereich: Nichtglatte konvexe Optimierung
- Theoretische Grundlagen:
 - Lagrange-Dualität
 - Konvexes Subdifferential
- **Subgradienten-Verfahren**
- (Kellys klassisches) **Schnittebenen-Verfahren**

Analytic Center Cutting Plane Method (ACCPM)

- Themenbereich: Konvexe nichtglatte Optimierung
- **ACCPM with nonlinear constraint and an active set strategy to solve nonlinear multicommodity flow problems (Babonneau/Vial 2005)**
 - Modifiziertes ACCPM für sehr große nichtlineare Mehrgüter-Fluss-Probleme mit NBn
- **An effective method to compute traffic assignment problems with elastic demands (Babonneau/Vial 2007)**
 - Konvexes Mehrgüterfluss-Problem
 - Basiert auf Lagrange Relaxion

ϵ -Subdifferential und Bundle-Verfahren (Geiger/Kanzow 2000, S. 385-401, Ulbrich, 2004 S. 47-63)

- Themenbereich: Nichtglatte Optimierung
- Konzept und Eigenschaften des ϵ -Subdifferentials
- Bundle-Verfahren: Zwei duale Sichtweisen (regularisiertes Schnittebenen-Verfahren/Innere Approximation des ϵ -Subdifferentials)
- Globale Konvergenz

Verteilte Optimierung via dualer Dekomposition (Bonnans/Gilbert/Lemaréchet/Sagastizábal 2003, S. 137-148, Samar/Boyd/Gorinevsky 2007)

- Themenbereich: Nichtglatte Optimierung, hochdimensionale oder komplexe Probleme
- Idee: Aufteilen, d. h. Lösen einer Folge von reduziert-dimensionalen oder einfacheren *lokalen* Problemen, verbunden bzw. koordiniert durch ein *master* Programm.
- **Samar/Boyd/Gorinevsky 2007:**
 - Anwendung: Netzwerk komplexer Sensorteilsysteme
 - Sensorteilsysteme lösen lokale Maximum-Likelihood Abschätzungsprobleme (Maximierung strikt konkaver log-Likelihood-Funktionen mit konvexen NBn)
 - Interaktion der Teilsysteme durch konvexe Kopplungsnebenbedingungen (*consistency constraints*)
 - Seiberabel bis auf consistency constraints \implies duale Dekomposition
 - Unabhängige Optimierung konkaver Teilsysteme
 - Lösungsalgorithmus für das duale master Problem: projiziertes Subgradientenverfahren

Alternative Verteilte Optimierung: Parallel implementation of a central decomposition method for solving large-scale planning problems (Bonnans/Gilbert/Lemaréchet/Sagastizábal 2003, S. 137-148, Gondzio/Sarkissian/Vial 1999)

- Lösungsalgorithmus für das duale master Problem: ACCPM

A Robust Gradient Sampling Algorithm for Nonsmooth, Nonconvex Optimization (Burke/Lewis/Overton 2003)

- Lokale Minimierung nichtglatter (sogar nicht L-stetiger), nichtkonvexer Funktionen basiert auf Gradient Sampling
- Idee des Gradient Sampling:
 - Abstiegsrichtung: Auswertung des Gradienten in gegenwärtiger Iterierter und zusätzlichen Nachbarpunkten, Vektor aus der konvexe Hülle dieser Gradienten mit kleinster Norm
 - Schrittweite: Art Armijo-Regel für nichtglatte Probleme
 - Stabilisierung: Sampling-Radius für die Sample-Gradienten (praktisch: sukzessives Verkleinern)
- Bestimmung von Clark- ϵ -stationären Punkten
- Konvergenzresultate (ohne Beweise!)
- Numerische Resultate für diverse Beispiele, z. B.:
 - Chebyshev Approximation
 - Minimierung des größten Eigenwertes von Hadamard Matrixprodukten (komponentenweise)

Variationsungleichungen am Beispiel von Nash-Gleichgewichten sowie Fixpunkt- und Josephy-Newton-Verfahren (Ulbrich 2004, S. 95-105, Geiger/Kanzow 2000, S. 428-457, Outrata/Kočvara/Zowe 1998, S. 226-235)

- Charakterisierung von Nash-Gleichgewichten durch Variationsungleichungen
- Fixpunkt-Verfahren
- Josephy-Newton-Verfahren
- Globalisierung des Josephy-Newton-Verfahrens mittels Gap-Funktionen

Globale Optimierung

Tunneling Algorithmus zur globalen Optimierung (Levy/Montalvo 1985)

- Heuristisches Verfahren zur globalen Optimierung
- Idee: Modifikation des Zielfunktional

A Survey of Evolution Strategies (Bäck/Hoffmeister/Schwefel)

- Themenbereich: stochastische globale Optimierung, Schwarmoptimierung
- Übersicht:
 - $(1 + 1)$ -ES (ein Elter, ein Nachkomme durch Dublikation und anschließende normalverteilte Mutation mit Varianz σ , Selektion „survival of the fittest“ bei den Nachkommen, externe deterministische Heuristik zur Anpassung der Mutationsschrittweite σ , probabilistic gradient search technique, selektiert Schritte die in Gradientenrichtung liegen)
 - $(\mu + 1)$ -ES ($\mu > 1$ Eltern, ein Nachkomme durch diskrete Rekombination, d. h. gleichwahrscheinliche Dublikation einer der Eltern, Rest wie bei $(1 + 1)$ -ES)
 - $(\mu + \nu)$ -ES (μ Eltern, ν Nachkommen, Selektion der Eltern und der Kinder zu neuer Elterngeneration, theoretisch unendliches Leben, Elite-Selektion birgt Gefahr in lokalen Minima zu stagnieren)
 - (μ, λ) -ES (Lebenszeit jedes Individuums auf eine Generation begrenzt, σ interner Strategieparameter, Teil der genetischen Information und unterliegt ebenfalls Rekombination u. Mutation)

CMA (Covariance Matrix Adaption)-Evolution Strategy (Hansen)

- Evolutionärer Algorithmus für schwierige nichtlineare nichtkonvexe Optimierungsprobleme
- Anwendung:
 - falls ableitungsbasierte Methoden wie Quasi-Newton BFGS fehlschlagen (z.B. wg. vieler lokaler Minima), sonst sind diese schneller
 - 3-100 Variablen
- Entstochastisiertes Verfahren zur Adaption der Kovarianzmatrix der Gausschen Mutationsverteilung.
 - Verfahren zweiter Ordnung
 - Kovarianzmatrix beschreibt paarweise Abhängigkeit zwischen Variablen
 - Analog zum BFGS wird eine positiv definite Matrix in einem iterativen Prozess approximiert

Genetic Algorithms: Concepts and Applications (Man/Tang/Kwong 1996)

- Themenereich: stochastische globale Optimierung, Schwarmalgorithmen
- Unterschiede zu ES:
 - Individuen als binäre Vektoren
 - Selektion „survival of the fittest“ bereits bei der Elterngeneration
 - Kreuzung der Chromosome an einem Punkt und anschließende Mutation

Varianten des Controlled Random Search (Price 1976, Ali/Törn/Vitanen 1997)

- Themenbereich: stochastische globale Optimierung
- Direktes Verfahren (d. h. nur Zielfunktionsauswertungen an ausgewählten Punkten), rein heuristisch
- **A controlled random search procedure for global optimization:** original CRS, CRS1
- **A numerical comparison of some modified Controlled Random Search Algorithms:** Vergleich der neuen Version CRS6 mit den anderen CRS-Versionen

Global Minimization via Piecewise-Linear Underestimation (Mangasarian/Rosen/Thompson, 2004)

- Themenbereich: deterministische globale Optimierung
- Reformulierung des konkaves Minimierungsproblem via nichtlinearer Störungstheorie für lineare Programme als konkaves Minimierungsproblem über einem Polyeder (Mangasarian/Meyer, 1979)
- Stückweiser linearer Approximation \implies nichtglattes approximiertes Optimierungsproblem
- Lösungsalgorithmus: Frank-Wolf Algorithmus

Convex Global Underestimation for Molecular Structure Prediction (Phillips/Rosen/Dill, 2001)

- Themenbereich: deterministische globale Optimierung mit biologischer Anwendung
- Verfahren im Bereich biologischer Anwendungen Genetischen Algorithmen, Simulated Annealing etc, deutlich überlegen

A Comparison of Global Optimization Methods for Design of a High-speed Civil Transport (Cox/Haftka/Baker/Grossman/Manson/Watson 2001)

- Hochgeschwindigkeitstransport als großes Anwendungsbeispiel mit 26 Design Variablen und 68 NBn
- \implies nichtkonvexe zulässige Menge, viele lokale Minima
- Vergleich dreier globaler Optimierungstechniken
 - Multistart lokale Optimierung mit SQP
 - Multistart lokale Optimierung mit Syman's Dynamic Search Methode
 - Jones DIRECT globaler Optimierungsalgorithmus