

- 1 Einführung
- 2 Unrestringierte Optimierung
- 3 Wichtige Verfahren der numerischen Optimierung**
 - Ableitungsfreie Verfahren
 - Abstiegsverfahren und Schrittweitensteuerung
 - Verfahren 1. Ordnung
 - Verfahren 2. Ordnung
- 4 Restringierte Optimierung
- 5 Zusammenfassung - Ausblick und Wiederholung

Einführung

Unrestringierte
Optimierung

**Wichtige Verfahren
der numerischen
Optimierung**

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

- Die bekannteste ableitungsfreie Methode ist das **Downhill-Simplex-Verfahren** von **Nelder und Mead** (auch Polyeder-Verfahren oder Simplexverfahren).
- Das Verfahren hat nichts mit dem Simplexverfahren für lineare Optimierungsprobleme zu tun.
- Grundprinzip des Verfahrens ist die Konstruktion von Simplicizes.
- 1965: Erste Version des Verfahrens von Nelder und Mead
1998: Modifikation des Verfahrens und Matlab-Implementierung von Lagarias u.a.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Downhill-Simplex-
Verfahren
(Nelder-Mead)

Weitere ableitungsfreie
Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Ein Simplex hat immer eine Ecke mehr als die Dimension, d.h. in 2D ist es ein Dreieck, in 3D ein Tetraeder, usw.

Definition (Simplex)

Zu $n + 1$ Punkten $x_0, x_1, \dots, x_n \in \mathbb{R}^n$ ($n \in \mathbb{N}$), wobei $\{x_i - x_0\}_{i=1, \dots, n}$ linear unabhängig, heißt die transitive Hülle

$$S = \left\{ \sum_{i=0}^n \lambda_i x_i \mid \lambda_i \geq 0, i = 0, 1, \dots, n, \sum_{i=0}^n \lambda_i = 1 \right\}$$

(n-dimensionales) **Simplex** mit den Ecken x_0, x_1, \dots, x_n .

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Downhill-Simplex-
Verfahren
(Nelder-Mead)Weitere ableitungsfreie
VerfahrenAbstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Restringierte
OptimierungZusammenfassung
- Ausblick und
Wiederholung

- Ziel: Bestimmung eines Minimums von $f(x)$
- Ausgehend von einem Startsimplex wird eine Folge von Simplexes konstruiert.
- Es wird immer derjenige Eckpunkt des Simplex mit dem größten Funktionswert durch einen besseren Punkt ersetzt.
- Die Folge bewegt sich in Richtung eines lokalen Minimums.
- In der Umgebung des Minimums werden die Simplexes immer kleiner und konvergieren schließlich gegen das Minimum.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Downhill-Simplex-
Verfahren
(Nelder-Mead)

Weitere ableitungsfreie
Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

1 Wähle einen Startpunkt $x^{[0,0]} \in \mathbb{R}^n$ und bestimme dazu mit Hilfe der Einheitsvektoren e_j für $j = 1, \dots, n$ die Ecken des Startsimplex $x^{[0,j]} = x^{[0,0]} + e_j$.
Setze $k = 0$.

2 Bestimme zum aktuellen Simplex den Eckpunkt $x^{[k,m]}$ mit dem größten Funktionswert

$$f(x^{[k,m]}) = \max\{f(x^{[k,0]}), \dots, f(x^{[k,n]})\}$$

3 Verbessere den schlechtesten Funktionswert durch eine Reflexion am Schwerpunkt der übrigen Punkte $s_k = \frac{1}{n} \sum_{i=0, i \neq m}^n x^{[k,i]}$, d.h. ersetze die Ecke $x^{[k,m]}$ im Simplex durch einen anderen Punkt mit niedrigerem Funktionswert. Dabei verwendet man das Verfahren auf den folgenden Folien mit $x_k = x^{[k,m]}$, beginnend mit Schritt a

4 Falls Abbruchbedingung nicht erfüllt, setze $k := k + 1$ und gehe zu 2.

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Downhill-Simplex-
Verfahren
(Nelder-Mead)Weitere ableitungsfreie
VerfahrenAbstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Restringierte
OptimierungZusammenfassung
- Ausblick und
Wiederholung

Durchführung von Schritt 3

- a Reflexion:** Berechnung einer Spiegelung von x_k an s_k :

$$\hat{x}_k = s_k + \gamma(s_k - x_k) \quad (0 < \gamma \leq 1)$$

Ist \hat{x}_k besser als der zweitschlechteste Punkt, aber schlechter als der beste, so nimmt man \hat{x}_k als neuen Wert für x_k ; ansonsten:

- b Expansion:** Ist \hat{x}_k besser als alle anderen Punkte, so versucht man, \hat{x}_k auf der Geraden weiter zu schieben:

$$\hat{x}_k^* = s_k + \beta(\hat{x}_k - s_k) \quad (\beta > 1)$$

Man wählt den "Besseren" von \hat{x}_k und \hat{x}_k^* als neues x_k .

- c Innere partielle Kontraktion:** Ist \hat{x}_k schlechter als x_k , so sucht man innerhalb des Simplex und geht auf der Geraden (durch x_k und s_k) nicht einmal bis s_k :

$$\hat{x}_k = s_k + \alpha(x_k - s_k) \quad (0 < \alpha < 1)$$

Ist \hat{x}_k besser als x_k , so nimmt man es als nächstes x_k , ansonsten nimmt man die Variante e.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Downhill-Simplex-
Verfahren
(Nelder-Mead)

Weitere ableitungsfreie
Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

- d **Äußere partielle Kontraktion:** Ist \hat{x}_k zwar besser als x_k , aber schlechter als alle anderen n Punkte, so sucht man näher am Simplex, d.h. man bestimmt:

$$\hat{x}_k^* = s_k + \alpha(\hat{x}_k - s_k) \quad (0 < \alpha < 1)$$

Ist \hat{x}_k^* besser als x_k , so nimmt man es als neuen Wert für x_k , ansonsten nimmt man die Variante e.

- e **Totale Kontraktion:** x_k bleibt unverändert und alle anderen Punkte bekommen den halben Abstand zu x_k :

$$\hat{x}_i = x_i + \frac{1}{2}(x_k - x_i) \quad (i = 0, 1, \dots, n \text{ mit } i \neq k)$$

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Downhill-Simplex-
Verfahren
(Nelder-Mead)

Weitere ableitungsfreie
Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Schritt 3 wird durchgeführt bis

- der Durchmesser des Simplex und der maximale Abstand der Funktionswerte kleiner als eine gegebene Toleranz ist
(Implementierung von `fminsearch` in Matlab)
oder
- die Standardabweichung der Funktionswerte an den Ecken des Simplex kleiner als eine vorgegebene Toleranz tol ist, d.h.

$$\sqrt{\frac{1}{n+1} \sum_{i=0}^n (f(x_i) - \bar{f})^2} < tol$$

mit dem Mittelwert \bar{f} der $n+1$ Funktionswerte
(Vorschlag von Nelder und Mead).

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Downhill-Simplex-
Verfahren
(Nelder-Mead)

Weitere ableitungsfreie
Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

- Folgende Werte für die Konstanten haben sich in der Praxis bewährt, müssen aber nicht immer optimale Ergebnisse liefern:
 - $\gamma = 1$ (Spiegelung)
 - $2 \leq \beta \leq 3$ (Expansion)
 - $0.4 \leq \alpha \leq 0.6$ (Kontraktion)
- Es gibt keinen allgemeinen Konvergenzbeweis (nur für einzelne niedrigdimensionale Funktionsklassen).
- Es gibt aber einzelne Beispiele für Konvergenz gegen nicht-stationäre Punkte (z.B. von McKinnon).
- Divergenz gegen Unendlich ist möglich.

Dennoch ist das Verfahren wegen seiner breiten Einsetzbarkeit und effizienten Implementierung sehr beliebt.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Downhill-Simplex-
Verfahren
(Nelder-Mead)

Weitere ableitungsfreie
Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

- Genetische Algorithmen,
z.B. Mutations-Selektions-Verfahren, Simulated
Annealing
- Interpolationsmethoden
- Verfahren mit Koordinaten- und Mustersuche
in 1D z.B. Bisektionsverfahren, Verfahren des
Goldenen Schnitts
- Verfahren der konjugierten Richtungen

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Downhill-Simplex-
Verfahren
(Nelder-Mead)

Weitere ableitungsfreie
Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Abstiegsverfahren und Schrittweitensteuerung

Definition (Abstiegsrichtung)

Seien $f : \mathbb{R}^n \rightarrow \mathbb{R}$ und $x \in \mathbb{R}^n$.

Eine Suchrichtung $d \in \mathbb{R}^n$ heißt **Abstiegsrichtung von f in x** , falls es ein $\bar{\alpha} > 0$ gibt mit

$$f(x + \alpha d) < f(x) \quad \text{für alle } 0 < \alpha \leq \bar{\alpha}.$$

Lemma (Kriterium für Abstiegsrichtung)

Sei $f : \mathbb{R} \rightarrow \mathbb{R}$ stetig differenzierbar in x .

Gilt $\nabla f(x)^\top d < 0$,
so ist d eine Abstiegsrichtung von f in x .

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Abstiegsverfahren
Schrittweiten

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Restringierte
Optimierung

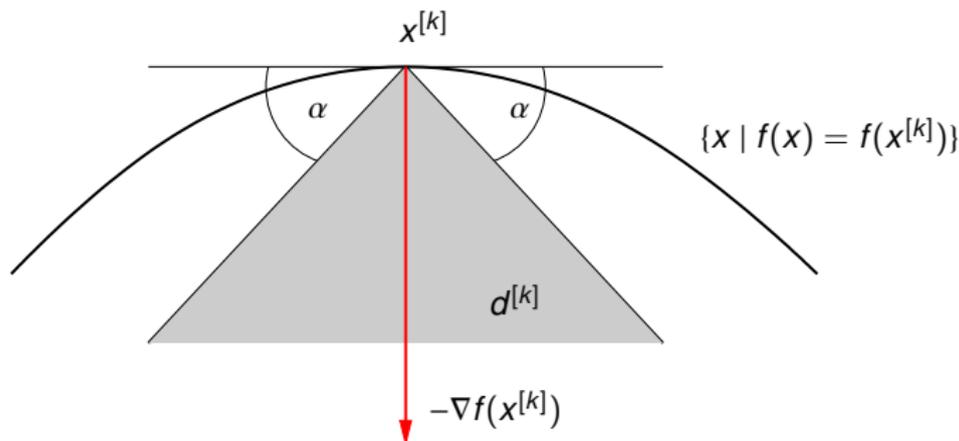
Zusammenfassung
- Ausblick und
Wiederholung

Geometrische Interpretation des Lemma:

Winkel zwischen Gradient und Abstiegsrichtung zwischen 90° und 270°

Winkelbedingung (gradientenbezogene Abstiegsrichtung):

Für effiziente Algorithmen kommt sogar nur ein geeigneter grauer Kegel um den Gradienten für $d^{[k]}$ (mit $\alpha \in (0, 90^\circ)$) in Frage, so dass man (unabhängig von k) von der Niveaulinie wegbleibt:



Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
SchrittweitensteuerungAbstiegsverfahren
Schrittweiten

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Restringierte
OptimierungZusammenfassung
- Ausblick und
Wiederholung

Ziel: Verfahren zur Minimierung von $f \in C^1(\mathbb{R}^n)$
Idee: Kombiniere Abstiegsrichtung mit einer
Schrittweitensteuerung

Algorithmus (*Allgemeines Abstiegsverfahren*)

- (i) Wähle Startpunkt $x^{[0]} \in \mathbb{R}^n$.
Setze $i = 0$.
- (ii) Falls Abbruchkriterium erfüllt, STOP.
- (iii) Berechne Abstiegsrichtung $d^{[i]}$ und
Schrittweite $\alpha^{[i]} > 0$, so dass

$$f(x^{[i]} + \alpha^{[i]} d^{[i]}) < f(x^{[i]}).$$

Setze $x^{[i+1]} = x^{[i]} + \alpha^{[i]} d^{[i]}$.

- (iv) Setze $i := i + 1$ und
gehe zu (ii).

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Abstiegsverfahren

Schrittweiten

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Restringierte
OptimierungZusammenfassung
- Ausblick und
Wiederholung

- Gradientenverfahren (Verfahren des steilsten Abstiegs):

$$d^{[i]} := -\nabla f(x^{[i]})$$

Abstiegsrichtung in nicht stationären Punkten.
Naheliegend, aber nicht die effizienteste Wahl.

- Newton-Verfahren:

$$d^{[i]} := -H_f(x^{[i]})^{-1} \nabla f(x^{[i]})$$

Falls $H_f(x^{[i]})$ positiv definit, dann $d^{[i]}$ Abstiegsrichtung in nicht stationären Punkten.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Abstiegsverfahren

Schrittweiten

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Liniensuche zur Schrittweitenbestimmung entlang Linie

$$\varphi(\alpha) := f(x + \alpha d)$$

Beispiel

Minimiere $f(x_1, x_2) := x_1^2 + 10x_2^2$.

Exakte Liniensuche zur Bestimmung der Schrittweite:

$$\alpha := \operatorname{argmin}\{\varphi(\alpha) \mid \alpha > 0\}$$

Abbruchkriterium $\|\nabla f(x)\|_2 \leq 10^{-5}$

Startvektor $x^{[0]} := (1, 0.1)^\top$

Gradientenverfahren benötigt (unskaliert) 63 Iterationen.

Newton-Verfahren benötigt 1 Iteration (und löst exakt).

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Abstiegsverfahren

Schrittweiten

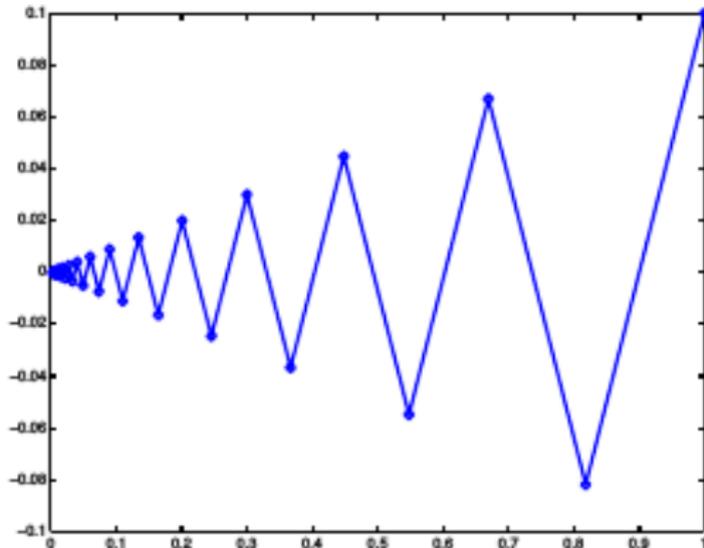
Verfahren 1. Ordnung

Verfahren 2. Ordnung

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Konvergenz des Gradientenverfahrens im Vergleich



Einführung

Unrestringierte Optimierung

Wichtige Verfahren der numerischen Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und Schrittweitensteuerung

Abstiegsverfahren

Schrittweiten

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Restringierte Optimierung

Zusammenfassung
- Ausblick und Wiederholung

Schrittweiten: Möglichkeiten zur Berechnung

Exakte Berechnung:

- bei quadratischen Problemen analytische Berechnung
- numerische Lösung des eindimensionalen Optimierungsproblems

Näherungsweise Berechnung:

- Armijo-Verfahren
- (Armijo-)Goldstein-Verfahren
- Wolfe-Powell-Verfahren

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Abstiegsverfahren

Schrittweiten

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Algorithmus (*Armijo-Regel*)

(i) Wähle $\beta \in (0, 1)$, $\sigma \in (0, 1)$.

Setze $\alpha := 1$.

(ii) Falls

$$\varphi(\alpha) \leq \varphi(0) + \sigma \alpha \varphi'(0) \quad (\text{Armijo-Bedingung}),$$

setze $\alpha^{[l]} := \alpha$ und STOP.

(iii) Setze $\alpha := \beta \alpha$.

Gehe zu (ii).

Die Armijo-Regel ist wohldefiniert, da $\varphi'(0) < 0$.

In der Praxis typischerweise: $\beta = 0.9$, $\sigma = 0.01$

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Abstiegsverfahren

Schrittweiten

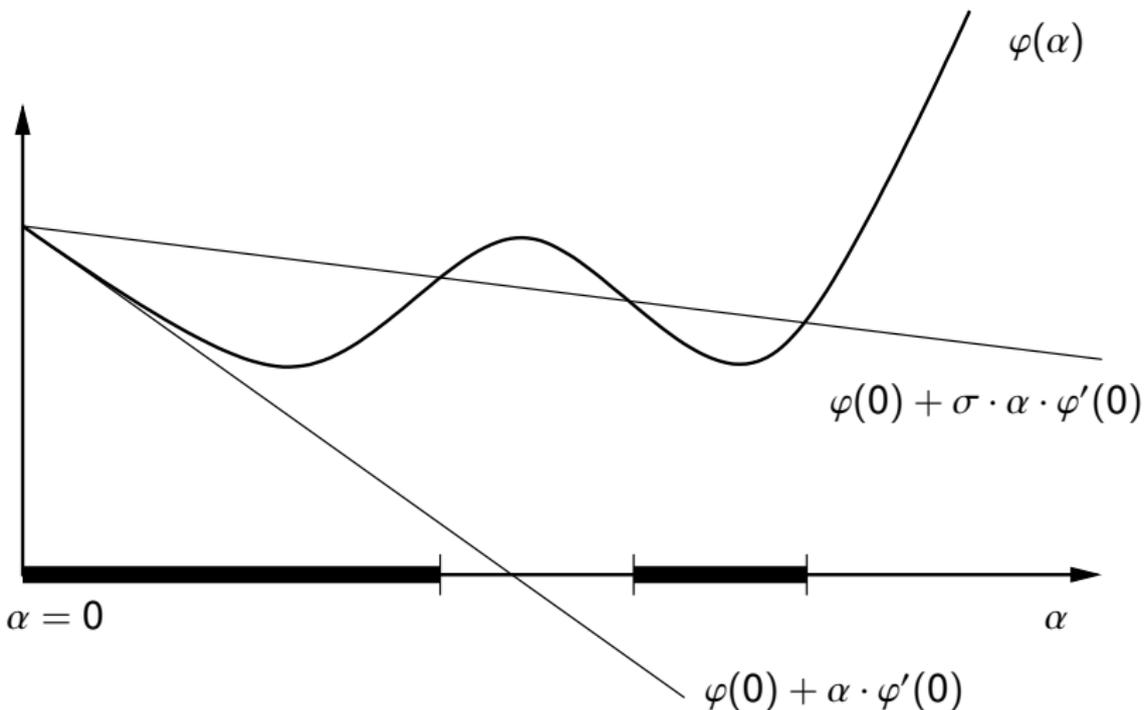
Verfahren 1. Ordnung

Verfahren 2. Ordnung

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Intervalle, die Armijo-Bedingung erfüllen



- Die Armijo-Regel führt häufig zu sehr kleinen Schrittweiten.
- Bessere Ergebnisse erhält man bei Verwendung der **Armijo-Regel mit Aufweitung**:
Falls $\alpha^{[j]} = 1$, so multipliziert man so lange mit $1/\beta$, bis die Armijo-Bedingung nicht mehr erfüllt ist.
Diese Regel wird in der Praxis eher selten verwendet.
- Stattdessen kombiniert man die Armijo-Regel häufig mit der **Wolfe-Powell-Regel** oder der **Goldstein-Bedingung**.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Abstiegsverfahren

Schrittweiten

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Wolfe-Powell-Regel:

Zu vorgegebenem $\sigma \in (0, \frac{1}{2})$ und $\rho \in [\sigma, 1)$ bestimme die Schrittweite $\alpha^{[l]}$, so dass

$$(A) \quad \varphi(\alpha^{[l]}) \leq \varphi(0) + \sigma \alpha^{[l]} \varphi'(0)$$

$$(W) \quad \varphi'(\alpha^{[l]}) \geq \rho \varphi'(0)$$

Strenge Wolfe-Powell-Regel:

Zu vorgegebenem $\sigma \in (0, \frac{1}{2})$ und $\rho \in [\sigma, 1)$ bestimme die Schrittweite $\alpha^{[l]}$, so dass

$$(A) \quad \varphi(\alpha^{[l]}) \leq \varphi(0) + \sigma \alpha^{[l]} \varphi'(0)$$

$$(W) \quad |\varphi'(\alpha^{[l]})| \leq -\rho \varphi'(0)$$

(A) ist die Armijo-, (W) die Wolfe-Powell Bedingung.

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Abstiegsverfahren

Schrittweiten

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Restringierte
OptimierungZusammenfassung
- Ausblick und
Wiederholung

Sei $\gamma > 1$ und $\alpha^{[j]}$ ein Startwert.

Expansionsphase: (Vergrößere $\alpha^{[j]}$, bis (A) nicht mehr gilt)

- Falls (A) und (W) für $\alpha^{[j]}$ erfüllt, dann STOP.
- Falls (A) für $\alpha^{[j]}$ erfüllt und (W) nicht, wiederhole die Expansionsphase mit $\alpha^{[j]} = \gamma \alpha^{[j]}$.
- Falls (A) für $\alpha^{[j]}$ nicht erfüllt, gehe zur Kontraktionsphase.

Setze $a = 0$ und $b = \alpha^{[j]}$

Kontraktionsphase: (Reduziere das Intervall, bis beide Bedingungen gelten) Bestimme $\alpha^{[j]} = \frac{a+b}{2}$:

- Falls (A) und (W) für $\alpha^{[j]}$ erfüllt, dann STOP.
- Falls (A) für $\alpha^{[j]}$ erfüllt und (W) nicht, wiederhole die Kontraktionsphase mit $a = \alpha^{[j]}$ und $b = b$.
- Falls (A) für $\alpha^{[j]}$ nicht erfüllt, wiederhole die Kontraktionsphase mit $a = a$ und $b = \alpha^{[j]}$.

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Abstiegsverfahren

Schrittweiten

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Restringierte
OptimierungZusammenfassung
- Ausblick und
Wiederholung

Zu vorgegebenem $\sigma \in (0, \frac{1}{2})$ und $\rho \in (\sigma, 1)$
bestimme die Schrittweite $\alpha^{[i]}$, so dass

$$\varphi(\alpha^{[i]}) \leq \varphi(0) + \sigma \alpha^{[i]} \varphi'(0)$$

$$\varphi(0) + (1 - \sigma)\alpha^{[i]} \varphi'(0) \leq \varphi(\alpha^{[i]})$$

Beachte: Die Armijo-Goldstein-Bedingung führt nicht
immer zu einer Schrittweite in der Nähe des Minimums.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Abstiegsverfahren

Schrittweiten

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

- Bei einer gradientenbezogenen Suchrichtung $d^{[k]}$ gilt für hinreichend kleine $\alpha^{[k]}$ immer $f(x^{[k]} + \alpha^{[k]}d^{[k]}) < f(x^{[k]})$.
Dies alleine reicht nicht für die Konvergenz von Abstiegsverfahren. Man benötigt zusätzlich eine effiziente Schrittweitenstrategie.
- Eine Schrittweitenstrategie heißt **effizient**, wenn es zu einem $x^{[0]}$ eine von x mit $f(x) \leq f(x^{[0]})$ und allen gradientenbezogenen Richtungen d unabhängige Konstante $c > 0$ gibt, so dass für die zu x und d berechnete Schrittweite α gilt:

$$f(x + \alpha d) \leq f(x) - c \left(\frac{\nabla f(x)^\top d}{\|d\|} \right)^2$$

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Abstiegsverfahren

Schrittweiten

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

- Die exakte Schrittweitenberechnung beim Gradientenverfahren und beim CG-Verfahren (siehe unten) ist effizient.
- Die Armijo-Regel ist im Allgemeinen nicht effizient.
- Sowohl die Schrittweitenstrategien nach Wolfe-Powell als auch nach Armijo-Goldstein sind effizient.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Abstiegsverfahren

Schrittweiten

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Theorem (Konvergenz von Abstiegsverfahren)

Sei $f(x)$ eine stetig differenzierbare Funktion. Angenommen, man verwendet zur lokalen Minimierung von f ein Abstiegsverfahren, das in jedem Iterationsschritt eine **gradientenbezogene** Abstiegsrichtung und eine **effiziente Regel** zur Schrittweitenbestimmung benutzt.

Dann **konvergiert** das Verfahren gegen ein lokales Minimum von f .

Folgerungen:

- Das Gradientenverfahren und das CG-Verfahren konvergieren für beliebige stetig differenzierbare Funktionen f , falls man die Armijo-Goldstein oder die strenge Wolfe-Powell Schrittweitenverfahren benutzt.
- Die Armijo-Regel alleine reicht nicht aus (→Gegenbeispiele).

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Abstiegsverfahren

Schrittweiten

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Vorgehensweise:

- Entwickle Verfahren zunächst für **quadratische** Probleme mit positiv definiten Matrix (exakte Schrittweitenbestimmung möglich, leichtere Konvergenzaussagen, viele praktische Probleme sind quadratisch)
- Erweitere Verfahren auf **allgemeinere** Probleme (genäherte Schrittweitenbestimmung, schwierigere Konvergenzaussagen)

Verfahren:

- Gradientenverfahren (Verfahrens des steilsten Abstiegs)
- Konjugierte-Gradienten-Verfahren (CG)
- (Quasi-)Newton-Verfahren

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Abstiegsverfahren

Schrittweiten

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Verfahren 1. Ordnung: Berechnung von Ableitungen

- **Symbolische Berechnung:**
Explizite Berechnung der Ableitungen als Funktion:
 - von Hand oder
 - mit Mathematica bzw. Symbolic Math Toolbox von Matlab (falls möglich, beste Variante)
- **Numerische Berechnung:**
Verwendung von Differenzenquotienten bzw. numerischen Ableitungsformeln (vgl. Numerik)
- **Automatisches Differenzieren:**
Berechnung der Ableitung von Funktionen, die als Prozedur gegeben sind (mit Hilfe der Kettenregel)

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Gradientenverfahren

CG-Verfahren

Verfahren 2. Ordnung

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

- Für jeden Punkt gilt: Der negative Gradient ist die Richtung des steilsten Abstiegs.
- Lokal betrachtet ist das also die beste Richtung bei der Suche nach einem Minimum.
- Die Größe des Schritts bestimmt man bei quadratischen Optimierungsproblemen exakt, bei allen anderen genähert.
- Dabei wird auf der Linie des Gradienten der minimale Funktionswert gesucht.
- Dieses Verfahren wiederholt man mit dem dabei gefundenen Punkt usw. ...

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Gradientenverfahren

CG-Verfahren

Verfahren 2. Ordnung

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Algorithmus (*Gradientenverfahren mit Liniensuche*)

(0) Wähle $x^{[0]} \in \mathbb{R}^n$.

Wähle *Schrittweiten(reduktions)faktor* $\beta \in (0, 1)$ und
einen Steigungsfaktor $\sigma \in (0, 1)$ z.B. für *Armijo-Regel*.
Setze $k := 0$.

(i) Falls

$$\|\nabla f(x^{[k]})\| \approx 0,$$

dann *STOP*.

(ii) Berechne *Suchrichtung* $d^{[k]} = -\nabla f(x^{[k]})$.

(iii) Bestimme *Schrittweite* $\alpha^{[k]}$, z.B. mit der *Armijo-Regel*.

(iv) Setze $x^{[k+1]} := x^{[k]} + \alpha^{[k]} d^{[k]}$,
setze $k := k + 1$ und
gehe zu (i).

Manchmal auch: $d^{[k]} = -\frac{\nabla f(x^{[k]})}{\|\nabla f(x^{[k]})\|}$

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Gradientenverfahren

CG-Verfahren

Verfahren 2. Ordnung

Restringierte
OptimierungZusammenfassung
- Ausblick und
Wiederholung

Die Abbruchbedingung $\nabla f(x^{[k]}) = 0$ kann man so nicht berechnen.

Je nach Problemstellung sind folgende Kriterien für eine gewünschte/mögliche Genauigkeit ϵ sinnvoll:

- 1 $f(x^{[k]}) - f(x^{[k+1]}) \leq \epsilon \cdot \max\{1, |f(x^{[k]})|\}$
(oft auch relativer statt absolutem Fehler verwendet)
- 2 $\|x^{[k+1]} - x^{[k]}\| \leq \sqrt{\epsilon} \cdot \max\{1, \|x^{[k]}\|\}$
(manchmal auch zusätzlich zu 1.)
- 3 $\|\nabla f(x^{[k]})\| \leq \sqrt[3]{\epsilon} \cdot \max\{1, \|x^{[k]}\|\}$
(als Ersatz für das theoretische Kriterium $\nabla f(x^{[k]}) = 0$)

Die theoretisch begründbare Wurzel $\sqrt{\epsilon}$ stellt sich in der Praxis als zu restriktiv heraus.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Gradientenverfahren

CG-Verfahren

Verfahren 2. Ordnung

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Theorem (Konvergenzsatz für Gradientenverfahren)

Wird durch das Gradientenverfahren mit Liniensuche für $f \in C^1(\mathbb{R}^n)$, $x^{[0]} \in \mathbb{R}^n$ eine nicht abbrechende Folge $\{x^{[k]}\}_{k \in \mathbb{N}}$ definiert, so gilt für jeden Häufungspunkt x^* dieser Folge $\nabla f(x^*) = 0$, d.h. x^* ist ein stationärer Punkt von f .

Vor-/Nachteile:

- Einfach zu implementieren
- Nur **lineare Konvergenz**:
Unter Annahmen gilt

$$f(x^{[k+1]}) - f(x^*) \leq \left(\frac{\kappa - 1}{\kappa + 1}\right)^2 (f(x^{[k]}) - f(x^*)),$$

wobei $\kappa := \lambda_{\max}/\lambda_{\min}$, der Quotient des größten durch den kleinsten Eigenwert von $H_f(x^*)$.

- Die **Backpropagation** im maschinellen Lernen basiert auf diesem Verfahren.

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung
Verfahren 1. Ordnung

Gradientenverfahren

CG-Verfahren

Verfahren 2. Ordnung

Restringierte
OptimierungZusammenfassung
- Ausblick und
Wiederholung

Definition ((Super-)Lineare und quadratische Konvergenz)

Eine Folge $\{x^{[l]}\}_{l \in \mathbb{N}}$ **konvergiert** (mindestens)

(a) **linear** gegen \hat{x} , falls es ein $c \in (0, 1)$ gibt, so dass

$$\|x^{[i+1]} - \hat{x}\| \leq c \|x^{[i]} - \hat{x}\|$$

für alle hinreichend großen i ,

(b) **superlinear** gegen \hat{x} , falls es eine Nullfolge $\{c_i\}_{i \in \mathbb{N}}$, $c_i \downarrow 0$ gibt, so dass

$$\|x^{[i+1]} - \hat{x}\| \leq c_i \|x^{[i]} - \hat{x}\| \quad \text{für alle } i \in \mathbb{N},$$

(c) **in Ordnung** $p \geq 2$ gegen \hat{x} , falls es ein $c > 0$ gibt, so dass

$$\|x^{[i+1]} - \hat{x}\| \leq c \|x^{[i]} - \hat{x}\|^p \quad \text{für alle } i \in \mathbb{N},$$

d.h.

$$\|x^{[i+1]} - \hat{x}\| = O(\|x^{[i+1]} - \hat{x}\|^p).$$

Im Fall $p = 2$ heißt die Folge quadratisch konvergent.

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung
Verfahren 1. Ordnung

Gradientenverfahren

CG-Verfahren

Verfahren 2. Ordnung

Restringierte
OptimierungZusammenfassung
- Ausblick und
Wiederholung

$$\min_{x \in \mathbb{R}^n} f(x) = \frac{1}{2} x^T Q x + q^T x$$

Algorithmus (*Gradientenverfahren für quadratische Optimierungsprobleme*)

(0) Wähle $x^{[0]} \in \mathbb{R}^n$.

Setze $k := 0$.

(i) Falls

$$\|\nabla f(x^{[k]})\| = \|Qx^{[k]} + q\| \approx 0,$$

dann STOP.

(ii) Berechne Suchrichtung $d^{[k]} = -\nabla f(x^{[k]})$.

(iii) Bestimme exakte Schrittweite

$$\alpha^{[k]} = \frac{(d^{[k]})^T d^{[k]}}{(d^{[k]})^T Q d^{[k]}}$$

(iv) Setze $x^{[k+1]} := x^{[k]} + \alpha^{[k]} d^{[k]}$,

setze $k := k + 1$ und

gehe zu (i).

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Gradientenverfahren

CG-Verfahren

Verfahren 2. Ordnung

Restringierte
OptimierungZusammenfassung
- Ausblick und
Wiederholung

Ideen zur Konstruktion des **CG-Verfahrens** (*conjugated gradients method*):

- Optimale Schrittweite beim Verfahren des steilsten Abstiegs ist global nicht ideal.
- Bei einem n -dimensionalen Problem kann man theoretisch bei richtiger Wahl der Richtung und der Länge immer in n Schritten fertig sein.
- n aufeinander senkrecht stehende Richtungen funktionieren, sind aber sehr schlecht zu berechnen.

Bessere Wahl: Q -konjugierte Richtungen $d^{[k]}$

- Vorgehen: Verändere den negativen Gradienten so, dass alle Abstiegsrichtungen $d^{[0]}$, $d^{[1]}$, $d^{[2]}$, ... Q -konjugiert sind, und bestimme die optimale Schrittweite.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Gradientenverfahren

CG-Verfahren

Verfahren 2. Ordnung

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Definition (Konjugierte Vektoren)

Sei $Q \in \mathbb{R}^{n \times n}$ eine symmetrische, positiv definite Matrix.

Dann heißen die Vektoren $d^{[0]}, d^{[1]}, \dots, d^{[k]} \in \mathbb{R}^n$ mit $k < n$ **zueinander konjugiert bezüglich** Q oder Q -konjugiert,

- wenn keiner von ihnen der Nullvektor ist und
- wenn folgendes gilt:

$$(d^{[i]})^\top Q d^{[j]} = \langle Q d^{[i]}, d^{[j]} \rangle = 0 \quad \text{für alle } i \neq j.$$

Man kann zeigen, dass Q -konjugierte Vektoren für symmetrisch, positiv definite Q linear unabhängig sind.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Gradientenverfahren

CG-Verfahren

Verfahren 2. Ordnung

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

- Im CG-Verfahren verwendet man die Richtungen $d^{[0]} = -\nabla f(x^{[0]})$ und

$$d^{[k+1]} = -\nabla f(x^{[k+1]}) + \frac{\|\nabla f(x^{[k+1]})\|^2}{\|\nabla f(x^{[k]})\|^2} d^{[k]}$$

- Lösung des eindimensionalen Optimierungsproblems für die optimale Schrittweite liefert

$$\alpha^{[k]} = -\frac{\nabla f(x^{[k]})^\top d^{[k]}}{(d^{[k]})^\top Q d^{[k]}}$$

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Gradientenverfahren

CG-Verfahren

Verfahren 2. Ordnung

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Algorithmus (Verfahren der konjugierten Gradienten)

- (0) Wähle $x^{[0]} \in \mathbb{R}^n$,
berechne $\nabla f(x^{[0]}) = Qx^{[0]} + q$ und $d^{[0]} = -\nabla f(x^{[0]})$.
Setze $k := 0$.
- (i) Falls $\|\nabla f(x^{[k]})\| \approx 0$, dann STOP.
- (ii) Bestimme zu $d^{[k]}$ die exakte Schrittweite

$$\alpha^{[k]} = -\frac{\nabla f(x^{[k]})^\top d^{[k]}}{(d^{[k]})^\top Qd^{[k]}}.$$

- (iii) Setze $x^{[k+1]} := x^{[k]} + \alpha^{[k]}d^{[k]}$.
Bestimme

$$\nabla f(x^{[k+1]}) = \nabla f(x^{[k]}) + \alpha^{[k]}Qd^{[k]}$$

$$\beta^{[k]} = \frac{\|\nabla f(x^{[k+1]})\|^2}{\|\nabla f(x^{[k]})\|^2}$$

$$d^{[k+1]} = -\nabla f(x^{[k+1]}) + \beta^{[k]}d^{[k]}$$

- (iv) Setze $k := k + 1$ und
gehe zu (i).

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Gradientenverfahren

CG-Verfahren

Verfahren 2. Ordnung

Restringierte
OptimierungZusammenfassung
- Ausblick und
Wiederholung

Theorem (Konvergenz des CG-Verfahrens)

*Ist Q symmetrisch, positiv definit,
so konvergiert das CG-Verfahren in höchstens n Iterationen gegen das Minimum des zugehörigen quadratischen Optimierungsproblems.*

Beweisidee: (vgl. W. Alt, Satz 4.9.2)

- Das Residuum $r_k = \nabla f(x^{[k]})^\top$ steht senkrecht auf allen bislang ermittelten Suchrichtungen $d^{[i]}$, d.h.

$$\nabla f(x^{[k]})^\top d^{[i]} = 0 \quad \text{für } 0 \leq i < k.$$

- Die Gradienten an allen Näherungswerten $x^{[k]}$ stehen senkrecht aufeinander, d.h.

$$\nabla f(x^{[k]})^\top \nabla f(x^{[i]}) = 0 \quad \text{für } 0 \leq i < k.$$

- Die Suchrichtungen sind Q -konjugiert.

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und

Schrittweitensteuerung

Verfahren 1. Ordnung

Gradientenverfahren

CG-Verfahren

Verfahren 2. Ordnung

Restringierte
OptimierungZusammenfassung
- Ausblick und
Wiederholung

- Ist Q positiv definit, so konvergiert das CG-Verfahren in höchstens n Iterationen gegen das Minimum des zugehörigen quadratischen Optimierungsproblems.
- Theoretisch ist das CG-Verfahren also ein direktes Verfahren, das die exakte Lösung berechnet. In der Praxis führen Rundungsfehler dazu, dass die Berechnung näherungsweise (numerisch) erfolgt.
- Wie beim Gradientenverfahren konvergiert das CG-Verfahren umso schneller, je kleiner $\frac{\lambda_{max}}{\lambda_{min}}$ ist.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Gradientenverfahren

CG-Verfahren

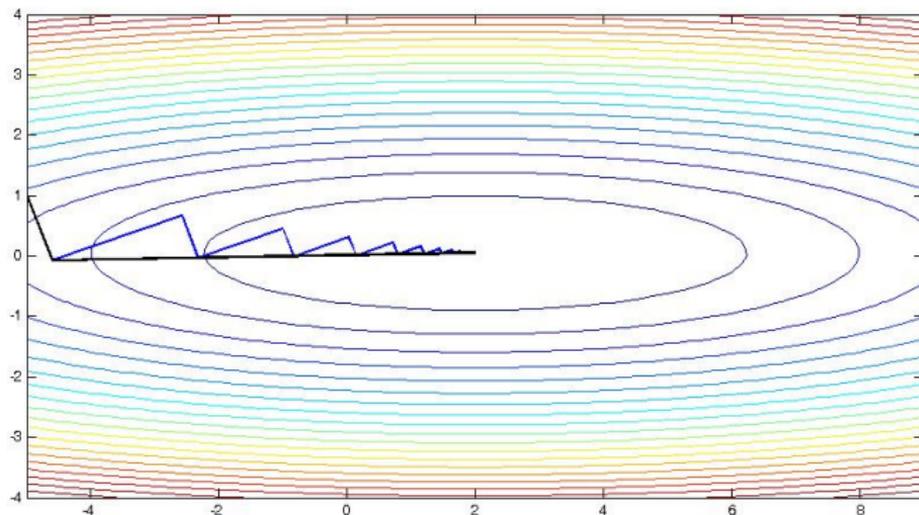
Verfahren 2. Ordnung

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Gradienten- und CG-Verfahren beim Beispiel

$$f(x_1, x_2) = x_1^2 + 20x_2^2 - 4x_1 - 2x_2$$



Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Gradientenverfahren

CG-Verfahren

Verfahren 2. Ordnung

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Algorithmus (Verfahren der konjugierten Gradienten nach Fletcher-Reeves)

- (0) Wähle $x^{[0]} \in \mathbb{R}^n$,
berechne $\nabla f(x^{[0]})$ und $d^{[0]} = -\nabla f(x^{[0]})$.
Setze $k := 0$.
- (i) Falls $\|\nabla f(x^{[k]})\| \approx 0$, dann STOP.
- (ii) Bestimme zu $d^{[k]}$ die **effiziente** Schrittweite $\alpha^{[k]}$, z.B. mit dem Verfahren von Wolfe-Powell.
- (iii) Setze $x^{[k+1]} := x^{[k]} + \alpha^{[k]} d^{[k]}$.
Bestimme

$$\nabla f(x^{[k+1]})$$

$$\beta^{[k]} = \frac{\|\nabla f(x^{[k+1]})\|^2}{\|\nabla f(x^{[k]})\|^2}$$

$$d^{[k+1]} = -\nabla f(x^{[k+1]}) + \beta^{[k]} d^{[k]}$$

- (iv) Setze $k := k + 1$ und
gehe zu (i).

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Gradientenverfahren

CG-Verfahren

Verfahren 2. Ordnung

Restringierte
OptimierungZusammenfassung
- Ausblick und
Wiederholung

Folgende CG-Verfahren unterscheiden sich nur in der Berechnung von β :

- **Fletcher-Reeves-Verfahren:**

$$\beta^{[k]} = \frac{\|\nabla f(x^{[k+1]})\|^2}{\|\nabla f(x^{[k]})\|^2}$$

- **Polak-Ribière-Verfahren:**

$$\beta^{[k]} = \frac{(\nabla f(x^{[k+1]}) - \nabla f(x^{[k]}))^\top \nabla f(x^{[k+1]})}{\|\nabla f(x^{[k]})\|^2}$$

- **Myers-Verfahren:**

$$\beta^{[k]} = \frac{\|\nabla f(x^{[k+1]})\|^2}{\nabla f(x^{[k]})^\top d^{[k]}}$$

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Gradientenverfahren

CG-Verfahren

Verfahren 2. Ordnung

Restringierte
OptimierungZusammenfassung
- Ausblick und
Wiederholung

- Wenige Rechenoperationen pro Iterationsschritt:
 - Keine Verwendung von Matrizen!
 - Funktions- und Gradientenauswertungen bei der Schrittweitenbestimmung
 - $O(n)$ für Vektoroperationen
- Häufig langsamere Konvergenz, d.h. mehr Iterationen als bei Newton-artigen Verfahren
- \Rightarrow Besonders geeignet für sehr große Optimierungsprobleme, d.h. viele Unbekannte
- Häufig Verbesserung durch “Restarts” möglich (d.h. Ersetzen der Suchrichtung durch negativen Gradienten)
- Bei (strengen) Wolfe-Powell-Schrittweiten kleines ρ wählen, also in der Nähe des Minimums suchen

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Gradientenverfahren

CG-Verfahren

Verfahren 2. Ordnung

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Zusammenhang Optimierung - Lineare Gleichungssysteme

Die Lösung eines quadratischen Optimierungsproblems
 $\min f(x)$ mit

$$f(x) = \frac{1}{2}x^T Qx + q^T x + c$$

ist wegen

$$\nabla f(x) = (Qx + q)^T$$

äquivalent zur Lösung des linearen Gleichungssystems

$$Qx = -q$$

Einige der Verfahren (insbesondere CG) werden häufig zur iterativen Lösung großer linearer Gleichungssysteme verwendet

⇒ Numerik 2

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Gradientenverfahren

CG-Verfahren

Verfahren 2. Ordnung

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

3 verschiedene Arten der Herleitung:

- **Approximation:**

Minimiere die lokale quadratische Approximation \hat{f} von f um $x^{[i]}$ exakt:

$$\hat{f}(y) = f(x) + \nabla f(x)^\top (y - x) + \frac{1}{2}(y - x)^\top H_f(x)(y - x)$$

Ist H_f pos. def., dann existiert genau ein Minimum \hat{y} von \hat{f} :

$$\begin{aligned}\nabla \hat{f}(y) &= \nabla f(x) + H_f(x)(y - x) \stackrel{!}{=} 0 \\ \Leftrightarrow d &= \hat{y} - x = -H_f(x)^{-1} \nabla f(x)\end{aligned}$$

- **Nullstellenverfahren:**

Löse die notw. Bedingung $\nabla f(\hat{x}) = 0$ als Nullstellenproblem.

- **Abstiegsverfahren:**

Man überprüft, dass d eine Abstiegsrichtung ist.

Die Voraussetzung $H_f(x)$ pos. def. ist durchaus eine Einschränkung! Diese ist nur in der Nähe des Minimums garantiert.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren

Anwendung: Nichtlineare
Ausgleichsrechnung mit
dem

Gauß-Newton-Verfahren

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Algorithmus (*Lokales Newton-Verfahren*)

- (i) Wähle $x^{[0]} \in \mathbb{R}^n$,
setze $i = 0$.
- (ii) Falls Abbruchkriterium erfüllt, dann STOP,
- (iii) Berechne (falls möglich) $d^{[i]}$ als Lösung des LGS

$$H_f(x^{[i]})d^{[i]} = -\nabla f(x^{[i]}).$$

Setze $x^{[i+1]} := x^{[i]} + d^{[i]}$,
 $i := i + 1$ und
gehe zu (ii).

Wenn H_f pos. def., lässt sich das lokale Newton-Verfahren als Abstiegsverfahren mit Schrittweite $\alpha^{[k]} = 1$ interpretieren.

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren

Anwendung: Nichtlineare
Ausgleichsrechnung mit
dem
Gauß-Newton-VerfahrenRestringierte
OptimierungZusammenfassung
- Ausblick und
Wiederholung

Für eine mehrdimensionale Funktion $g : \mathbb{R}^n \rightarrow \mathbb{R}^n$ bestimmt man die Linearisierung (Taylorreihe bis zum linearen Glied, "Tangentialhyperebene") an einer Stelle $x^{[i]} \in \mathbb{R}^n$:

$$g(x^{[i]}) + J_g(x^{[i]})(x - x^{[i]}) \approx \mathbf{0}.$$

Dabei bezeichnet $J_g(\xi) = J(g)(\xi)$ die Jacobi-Matrix von g an einer Stelle ξ .

Daraus ergibt sich für einen Startwert $x^{[0]} \in \mathbb{R}^n$ die Iterationsvorschrift des **Newton-Verfahrens**:

$$x^{[i+1]} = x^{[i]} - (J_g(x^{[i]}))^{-1} g(x^{[i]}) \quad i = 0, 1, 2, \dots$$

Ist die Jacobi-Matrix in der Umgebung von x^* regulär und Lipschitz-stetig, so konvergiert das Newton-Verfahren lokal quadratisch.

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

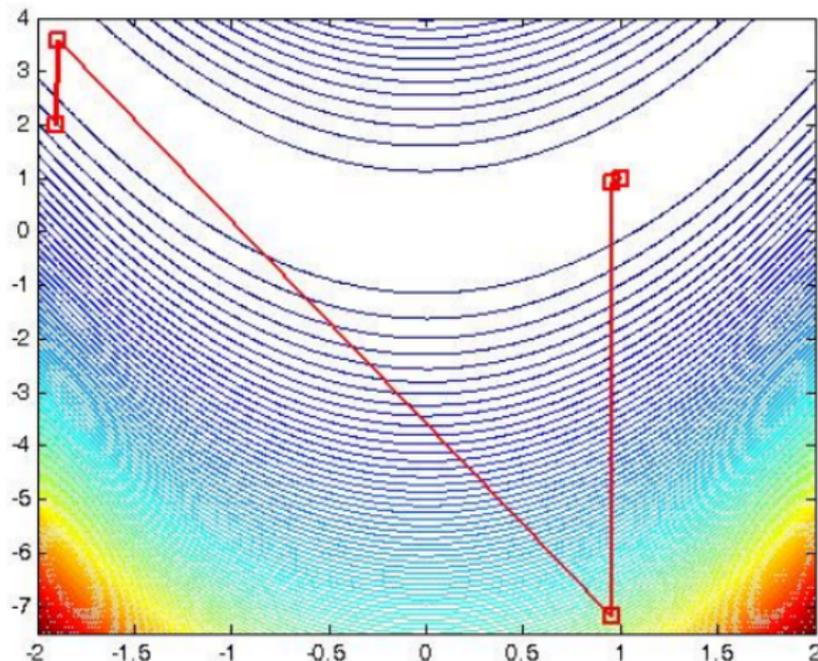
Trust-Region-Verfahren

Anwendung: Nichtlineare
Ausgleichsrechnung mit
dem
Gauß-Newton-VerfahrenRestringierte
OptimierungZusammenfassung
- Ausblick und
Wiederholung

Newton-Verfahren - Beispiel

Angewendet auf das Beispiel der Rosenbrock-Funktion

$$f(x_1, x_2) = 100(x_2 - x_1^2)^2 + (1 - x_1)^2$$



Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren

Anwendung: Nichtlineare
Ausgleichsrechnung mit
dem
Gauß-Newton-Verfahren

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Theorem (Konvergenzsatz für Newton-Verfahren)

Besitze f ein (lokales) Minimum $\hat{x} \in \mathbb{R}^n$.

Es gibt ein $r > 0$, so dass, wenn durch das lokale Newton-Verfahren für $f \in C^2(\mathbb{R}^n)$, $x^{[0]} \in U_r(\hat{x})$ eine nicht abbrechende Folge $\{x^{[k]}\}_{k \in \mathbb{N}}$ definiert wird,

- diese Folge superlinear konvergiert gegen \hat{x} .
- \hat{x} ist das einzige lokale Minimum in $U_r(\hat{x})$.
- Erfüllt H_f zusätzlich die Lipschitz-Bedingung

$$\|H_f(x) - H_f(y)\| \leq L \|x - y\| \quad \text{für alle } x, y \in \mathbb{R}^n,$$

so konvergiert diese Folge sogar quadratisch.

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren

Anwendung: Nichtlineare
Ausgleichsrechnung mit
dem
Gauß-Newton-VerfahrenRestringierte
OptimierungZusammenfassung
- Ausblick und
Wiederholung

Globalisiertes (oder globales) Newton-Verfahren:

- Was macht man, wenn Newton-LGS nicht lösbar?
- Kombination mit dem Gradientenverfahren
- Verwendung einer kleineren Schrittweite (d.h. Dämpfung)
- *Weitere Option: Verwendung einer Bewertungsfunktion (für Schrittweite)*

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren

Anwendung: Nichtlineare
Ausgleichsrechnung mit
dem

Gauß-Newton-Verfahren

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Algorithmus (*Global. Newton-Verfahren [GK99, S. 92]*)

- (i) Wähle $x^{[0]} \in \mathbb{R}^n$, $\sigma \in (0, 1/2)$, $\beta \in (0, 1)$, $\rho > 0$, $p > 2$,
setze $i = 0$.
- (ii) Falls Abbruchkriterium erfüllt, dann STOP,
- (iii) Berechne (falls möglich) $d^{[i]}$ als Lösung des LGS

$$H_f(x^{[i]})d^{[i]} = -\nabla f(x^{[i]}).$$

*Falls dieses LGS unlösbar oder $\nabla f(x^{[i]})^\top d^{[i]} > -\rho \|d^{[i]}\|^p$,
setze $d^{[i]} = -\nabla f(x^{[i]})$.*

- (iv) *Bestimme Schrittweite $\alpha^{[i]} > 0$ (z.B. nach Armijo).*
- (v) Setze $x^{[i+1]} := x^{[i]} + \alpha^{[i]}d^{[i]}$,
 $i := i + 1$ und
gehe zu (ii).

Im Endlichdimensionalen kann man globale, superlineare Konvergenz gegen einen stationären Punkt beweisen.

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren

Anwendung: Nichtlineare
Ausgleichsrechnung mit
dem
Gauß-Newton-VerfahrenRestringierte
OptimierungZusammenfassung
- Ausblick und
Wiederholung

- Lösen des linearen Gleichungssystems ist für kleine Gleichungssysteme mit dem Gauß-Algorithmus möglich, für große Systeme wird häufig das CG-Verfahren eingesetzt.
- Das Cholesky-Verfahren funktioniert nur für positiv definite Matrizen. Um mit evtl. nicht positiv definiten Matrizen rechnen zu können, kann eine modifizierte Version verwendet werden, die den Fall negativer Diagonalelemente berücksichtigt.
- Für Iterationen in der Nähe des Minimums ist die Schrittweite nach Armijo immer 1. Die lokal quadratische Konvergenz bleibt also erhalten.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren

Anwendung: Nichtlineare
Ausgleichsrechnung mit
dem
Gauß-Newton-Verfahren

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Vorteile:

- Lokal quadratische Konvergenz, damit eines der schnellsten Verfahren
- Durch Globalisierung auch hinreichend robust

Nachteile:

- Die Hessematrix H_f wird in analytischer Form benötigt. Sie ist häufig entweder unbekannt oder schwer (unmöglich) zu bestimmen.
Aufwand: $O(n^2)$ Ableitungen analytisch oder numerisch ausrechnen, Gleichungssystem lösen in $O(n^3)$ Operationen.
- Newton-Richtung ist i.A. keine Abstiegsrichtung, weil H_f nicht immer positiv definit ist.

Idee:

Ersetze H_f durch eine geeignete (z.B. positiv definite) und leichter zu bestimmende Matrix, in der Hoffnung, dass die Konvergenz immer noch superlinear ist.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren

Anwendung: Nichtlineare
Ausgleichsrechnung mit
dem

Gauß-Newton-Verfahren

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Hessematrix $H_f(x^{[i]})$ wird durch geeignete Matrix $A(x^{[i]})$ ersetzt, die in jeder Iteration durch “einfache” Rechenschritte bestimmt wird:

- Vereinfachtes Newton-Verfahren:

$A = A(x^{[i]}) := H_f(x^{[0]})$ wird einmalig berechnet, wird einmal faktorisiert zur schnellen Lösung des Newton-LGS

- Finite-Differenzen-Approximation:

Setze in Iteration i

$$A(x^{[i]})_{jk} = \frac{\nabla f_j(x + h^{[i]} e_k) - \nabla f_j(x)}{h^{[i]}}, \quad j, k = 1, \dots, n,$$

wobei $h^{[i]} \rightarrow 0$ für $i \rightarrow \infty$

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren

Anwendung: Nichtlineare
Ausgleichsrechnung mit
dem

Gauß-Newton-Verfahren

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

- **Quasi-Newton-Verfahren:**

Starte mit symm., pos. def. Matrix $A^{[0]}$

Berechne $A^{[i+1]}$ rekursiv aus $A^{[i]}$ durch sogenannte Updateformeln

- **Inverse Quasi-Newton-Verfahren:**

Wie Quasi-Newton-Verfahren, man approximiert aber $H_f^{-1}(x^{[i]})$

- **Variable-Metrik-Verfahren ...**

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren

Anwendung: Nichtlineare
Ausgleichsrechnung mit
dem

Gauß-Newton-Verfahren

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Berechne die Richtung $d^{[k]}$ im allgemeinen Abstiegsverfahren mit Hilfe einer positiv definiten Matrix $A^{[k]}$ folgendermaßen:

$$d^{[k]} = -(A^{[k]})^{-1} \nabla f(x^{[k]})$$

bzw. löse das lineare Gleichungssystem

$$A^{[k]} d^{[k]} = -\nabla f(x^{[k]}) .$$

Wähle $A^{[k]}$ in jedem Schritt so, dass

- $A^{[k]}$ eine Approximation für $H_f(x^{[k]})$ ist.
- $A^{[k+1]}$ effizient aus $A^{[k]}$ berechnet werden kann.

Bestimme die Schrittweite $\alpha^{[k]}$

- durch exakte Rechnung bei quadratischen Optimierungsproblemen,
- mit dem Verfahren von Armijo-Goldstein oder Wolfe-Powell bei allgemeinen Problemen.

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und

Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren

Anwendung: Nichtlineare

Ausgleichsrechnung mit

dem

Gauß-Newton-Verfahren

Restringierte
OptimierungZusammenfassung
- Ausblick und
Wiederholung

Im Eindimensionalen geht man vom Newton-Verfahren über zum Sekantenverfahren durch Approximieren des Differentialquotienten $f''(x^{[k+1]})$ durch den Differenzenquotienten $\frac{f'(x^{[k+1]}) - f'(x^{[k]})}{x^{[k+1]} - x^{[k]}}$.

Analog verwendet man im Mehrdimensionalen statt der 2. Ableitung, d.h. der Hesse-Matrix $H_f(x^{k+1})$ eine Matrix, die durch folgende Gleichung bestimmt ist:

$$A^{[k+1]}(x^{[k+1]} - x^{[k]}) = \nabla f(x^{[k+1]}) - \nabla f(x^{[k]})$$

Diese Gleichung heißt **Quasi-Newton-Gleichung** oder **Sekantenbedingung**. Sie bestimmt die Matrix $A^{[k+1]}$ aber nicht eindeutig, weil n Gleichungen $\frac{n(n+1)}{2}$ zu bestimmenden Matrix-Elementen gegenüberstehen.

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren
Anwendung: Nichtlineare
Ausgleichsrechnung mit
dem
Gauß-Newton-VerfahrenRestringierte
OptimierungZusammenfassung
- Ausblick und
Wiederholung

Idee zur Bestimmung von $A^{[k+1]}$:

- $A^{[k+1]}$ wird aus $A^{[k]}$ durch symmetrische Rang-1-Modifikationen berechnet, d.h.

$$A^{[k+1]} = A^{[k]} + c \cdot u \cdot u^T \quad (c \in \mathbb{R}, u \in \mathbb{R}^n)$$

- In jeder Iteration ist das Gleichungssystem $A^{[k]} d^{[k]} = -\nabla f(x^{[k]})$ zu lösen oder die Inverse von $A^{[k]}$ zu berechnen.
- Bei Rang-1-Modifikationen kann die Inverse von $A^{[k+1]}$ effizient, d.h. in $O(n^2)$ berechnet werden, und zwar mit der **Sherman-Morrison-Woodbury-Formel**

$$(A + uv^T)^{-1} = A^{-1} - \frac{A^{-1}uv^T A^{-1}}{1 + v^T A^{-1}u}$$

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren

Anwendung: Nichtlineare
Ausgleichsrechnung mit
dem
Gauß-Newton-Verfahren

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Bestimmung der Matrix $A^{[k+1]}$

Mit den Bezeichnungen

$$s^{[k]} = x^{[k+1]} - x^{[k]} \quad \text{und} \quad y^{[k]} = \nabla f(x^{[k+1]}) - \nabla f(x^{[k]})$$

erhält man $A^{[k+1]}$ durch zwei Rang-1-Modifikationen aus $A^{[k]}$:

$$A^{[k+1]} = A^{[k]} - \frac{A^{[k]}s^{[k]}(A^{[k]}s^{[k]})^\top}{(s^{[k]})^\top A^{[k]}s^{[k]}} + \frac{y^{[k]}(y^{[k]})^\top}{(y^{[k]})^\top s^{[k]}}$$

Die Matrix $A^{[k+1]}$

- ist symmetrisch und positiv definit,
- erfüllt die Quasi-Newton-Gleichung

$$A^{[k+1]}s^{[k]} = y^{[k]}.$$

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren

Anwendung: Nichtlineare
Ausgleichsrechnung mit
dem
Gauß-Newton-Verfahren

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Verfahren von **Broyden, Fletcher, Goldfarb, Shanno**:

- 1 Wähle einen Startpunkt $x^{[0]} \in \mathbb{R}^n$ und eine symmetrische, positiv definite Matrix $A^{[0]}$. Setze $k = 0$.
- 2 Falls $\nabla f(x^{[k]}) \approx \mathbf{0}$, STOP.
- 3 Bestimme $(A^{[k]})^{-1}$ durch 2malige Anwendung der Sherman-Morrison-Woodbury-Formel
- 4 Berechne $d^{[k]} = -(A^{[k]})^{-1} \nabla f(x^{[k]})$
- 5 Bei Verwendung einer Schrittweitensteuerung: Berechne die Schrittweite $\alpha^{[k]}$ exakt bei quadratischen Optimierungsproblemen oder durch Wolfe-Powell bei allgemeinen Problemen.
- 6 Erhöhe k um 1 und gehe zu 2.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren

Anwendung: Nichtlineare
Ausgleichsrechnung mit
dem
Gauß-Newton-Verfahren

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

- Wenn $A^{[k]}$ symmetrisch positiv definit ist, ist auch $A^{[k+1]}$ symmetrisch positiv definit.
- Mit einem Rang-1-Update erhält man zwar eine symmetrische, aber keine positiv definite Matrix, da

$$\left(A^{[k]} - \frac{A^{[k]} s^{[k]} (A^{[k]} s^{[k]})^\top}{(s^{[k]})^\top A^{[k]} s^{[k]}} \right) s^{[k]} = 0.$$

Sie erfüllt auch nicht die Quasi-Newton-Gleichung.

- Beim BFGS-Verfahren hat die Matrix $A^{[k+1]}$ die Eigenschaft

$$A^{[k+1]} = \min_A \|A - A^{[k]}\|$$

über alle symmetrisch, positiv definiten Matrizen, die die Quasi-Newton-Gleichung erfüllen.

- Das Quasi-Newton-Verfahren konvergiert superlinear, aber nicht quadratisch.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren

Anwendung: Nichtlineare
Ausgleichsrechnung mit
dem
Gauß-Newton-Verfahren

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

- Die Startmatrix $A^{[0]}$ muss positiv definit sein. Mögliche Matrizen sind
 - die Einheitsmatrix I_n (d.h. erster Schritt entlang negativem Gradienten)
 - die Matrix $\frac{(y^{[0]})^\top s^{[k]}}{(y^{[0]})^\top y^{[k]}} \cdot I_n$
- Typische Werte für die Schrittweitsuche nach Wolfe-Powell sind $\alpha^{[k]} = 1$, $\sigma = 10^{-4}$ und $\rho = 0.9$.
- Anstatt die Inverse mit der SMW-Formel auszurechnen, kann man das Gleichungssystem

$$A^{[k]}s^{[k]} = y^{[k]}$$

lösen, indem man aus der Cholesky-Zerlegung von $A^{[k-1]}$ direkt die Cholesky-Zerlegung von $A^{[k]}$ berechnet.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren

Anwendung: Nichtlineare
Ausgleichsrechnung mit
dem
Gauß-Newton-Verfahren

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

- Erhebliche Reduktion des Rechenaufwands im Vergleich zum Newton-Verfahren:
Keine Berechnung der Hessematrix und nur $O(n^2)$ Rechenoperationen pro Iterationsschritt
- Statt quadratischer Konvergenz immerhin noch superlineare Konvergenz
- Durch Rang-2 Updates bleibt Symmetrie und positive Definitheit der Matrizen $A^{[k]}$ erhalten. Damit erfolgt jeder Iterationsschritt entlang einer Abstiegsrichtung.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren

Anwendung: Nichtlineare
Ausgleichsrechnung mit
dem

Gauß-Newton-Verfahren

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

- **DFP-Methode:** (Davidon-Fletcher-Powell)
ebenfalls Rang-2-Modifikationen, die die
Sekantenbedingung erfüllen, allerdings wird hier die
Inverse von $H^{[k]}$ approximiert
- **SR1-Methode:** (Symmetrische Rang-1-Modifikation)
Matrizen erfüllen die Sekantenbedingung, sind aber
nicht immer positiv definit;
in vielen Fällen auch hiermit gute Ergebnisse
- **L-BFGS Methode:** (Limited memory BFGS)
nicht die gesamte Matrix $A^{[k]}$ wird gespeichert,
sondern nur einzelne Update-Vektoren;
geeignet für sehr große Matrizen

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren

Anwendung: Nichtlineare
Ausgleichsrechnung mit
dem

Gauß-Newton-Verfahren

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

- Betrachte einen Vertrauensbereich (**trust region**) $B(x^{[k]}, \rho^{[k]})$ mit Radius $\rho^{[k]} > 0$, in dem die Zielfunktion f durch eine Modellfunktion $f^{[k]}(d)$ (typischerweise eine quadratische Entwicklung in d) approximiert wird.
- Trust-Region-Verfahren sind “dual” zur Liniensuche: Es wird zuerst eine Schrittweite (Größe der Trust Region) und dann eine Richtung $d^{[k]}$ aus

$$\min_{\|d\| \leq \rho^{[k]}} f^{[k]}(d)$$

bestimmt,

bei einer Liniensuche ist dies umgekehrt.

- Ist die Approximation adäquat (Abstieg passt zum Modell), dann wird die Trust Region erweitert, andernfalls wird die Trust Region kontrahiert.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren

Anwendung: Nichtlineare
Ausgleichsrechnung mit
dem
Gauß-Newton-Verfahren

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

- Newton-artiges Verfahren, da Taylor-Approximation 2. Ordnung
- Trust-Region-Verfahren werden auch als *restricted-step methods* bezeichnet.
- Interessant für Probleme mit vielen Variablen
- Matlab-Befehl `fminunc`
- Verwandtes Verfahren:
Levenberg-Marquardt-Algorithmus

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren

Anwendung: Nichtlineare
Ausgleichsrechnung mit
dem
Gauß-Newton-Verfahren

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Gegeben:

- m Datenpunkte (t_i, y_i) , z.B. aus einer Messung
- lineare Funktion mit n zu bestimmenden Parametern (typischerweise $m > n$)

$$g(t, x_1, \dots, x_n) = g_1(t)x_1 + \dots + g_n(t)x_n$$

Aufgabe:

Minimiere das Residuum

$$r(x_1, \dots, x_n) = \begin{pmatrix} r_1(x_1, \dots, x_n) \\ \vdots \\ r_m(x_1, \dots, x_n) \end{pmatrix} = \begin{pmatrix} g_1(t_1)x_1 + \dots + g_n(t_1)x_n - y_1 \\ \vdots \\ g_1(t_m)x_1 + \dots + g_n(t_m)x_n - y_m \end{pmatrix},$$

bzw. bestimme x_1, \dots, x_n , so dass

$$f(x) = \sum_{i=1}^m r_i(x_1, \dots, x_n)^2 = \sum_{i=1}^m [g_1(t_i)x_1 + \dots + g_n(t_i)x_n - y_i]^2$$

minimal wird.

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren

Anwendung: Nichtlineare
Ausgleichsrechnung mit
dem
Gauß-Newton-VerfahrenRestringierte
OptimierungZusammenfassung
- Ausblick und
Wiederholung

Lineare Ausgleichsrechnung und Optimierung

Bedingung für ein Minimum: $\nabla f(x) = \mathbf{0}_n$

Mit

$$\nabla f(x) = 2 \cdot \begin{pmatrix} g_1(t_1)r_1 + g_1(t_2)r_2 + \dots + g_1(t_m)r_m \\ \vdots \\ g_n(t_1)r_1 + g_n(t_2)r_2 + \dots + g_n(t_m)r_m \end{pmatrix}$$

und

$$r'(x) = J_r(x) = \begin{pmatrix} g_1(t_1) & g_2(t_1) & \dots & g_n(t_1) \\ g_1(t_2) & g_2(t_2) & \dots & g_n(t_2) \\ \vdots & \vdots & \ddots & \vdots \\ g_1(t_m) & g_2(t_m) & \dots & g_n(t_m) \end{pmatrix}$$

ergibt dies die **Normal(en)gleichung**

$$r'(x)^T r'(x)x = r'(x)^T y.$$

Die Normalengleichung kann also auch mit Hilfe des Gradienten hergeleitet werden...

Einführung

Unrestringierte Optimierung

Wichtige Verfahren der numerischen Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren

Anwendung: Nichtlineare Ausgleichsrechnung mit dem Gauß-Newton-Verfahren

Restringierte Optimierung

Zusammenfassung - Ausblick und Wiederholung

(Nicht-)Lineare Ausgleichsrechnung: Ausfallzeiten u. Temperaturbelastung (Wh.)

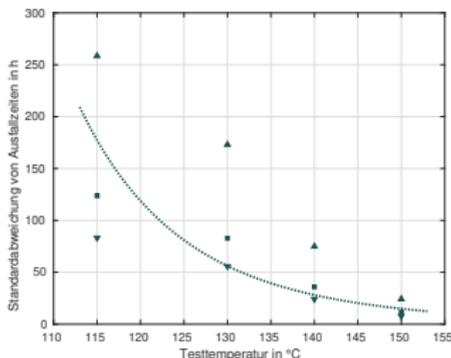
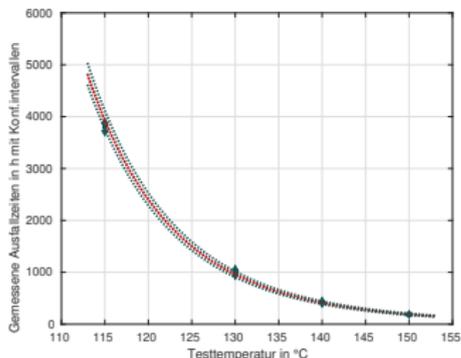


Abbildung: Ausgleichsrechnung über verschiedene Temperaturen T im Vergleich mit Messpunkten (Quadrate) samt Konfidenzintervallgrenzen zu $q = 90\%$ (Dreiecke). Links für $\mu_{krit}(T) \pm \sigma_{krit}(T)$, in Rot eine Referenzkurve. Rechts $\sigma_{krit}(T)$. [K., Dvorsky, Ließ 2018]

Modellbasierter Ansatz

$$f_{krit}(T) = t_{\Theta} + t_0 \exp\left(\left(\frac{T_a}{T - T_{\infty}}\right)^d\right)$$

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren

Anwendung: Nichtlineare
Ausgleichsrechnung mit
dem
Gauß-Newton-Verfahren

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Beispiel (Messung von Ausfallzeiten elektr. Bauteile)

T [°C]	115	130	140	155
μ_{krit} [h]	3791.62	987.74	439.66	189.94

Vermutung (modellbasierter Zugang): Arrhenius-Gesetz

$$\mu_{krit}(T) = t_0 \exp\left(\frac{T_a}{T - T_\infty}\right)$$

(μ_{krit} Ausfallzeit in h, t_0 reaktionskinetische Periodendauer in h, T Temperatur in K, T_a Aktivierungstemperatur in K, $T_\infty = 173.15$ Erstarrungstemperatur in K)

Lässt sich als affin-linearer Zusammenhang schreiben

$$\ln(\mu_{krit}(T)) = \ln(t_0) + \frac{T_a}{T - T_\infty} \quad \Leftrightarrow \quad y(t) = x_1 + x_2 t$$

Durch Einsetzen der Messwerte ergibt sich ein lineares Gleichungssystem (LGS)

$$y_i = x_1 + x_2 t_i, \quad i = 1, \dots, 4.$$

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren

Anwendung: Nichtlineare
Ausgleichsrechnung mit
dem
Gauß-Newton-VerfahrenRestringierte
OptimierungZusammenfassung
- Ausblick und
Wiederholung

Wir stellen fest:

- Im Allgemeinen mehr Messwerte (hier 4) als Parameter (hier 2)
- Messung eines Vorgangs fehlerbehaftet (auch ohne systematische Fehler)
- Überbestimmte LGS \rightsquigarrow i.A. existiert keine Lösung

Ziele:

- Bestimme x_1, x_2 aus den Messdaten “bestmöglich”
- Allgemeine Methode hierzu

Wir sprechen von **linearer Ausgleichsrechnung** oder ***curve fitting*** im Englischen bzw. **linearer Regression** (in der Statistik)

Spezialfall einer mathematischen Optimierungsmethode

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren

Anwendung: Nichtlineare
Ausgleichsrechnung mit
dem
Gauß-Newton-Verfahren

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Minimierungsproblem

Allgemein: $A \in \mathbb{R}^{m \times n}$, $x \in \mathbb{R}^n$, $y \in \mathbb{R}^m$

Idee: Bestimme $x = (x_1, \dots, x_n)^T$, so dass der Fehler im LGS

$$\|Ax - y\|_2 = \sqrt{\sum_{i=1}^m \left(\sum_{j=1}^n A_{ij}x_j - y_i \right)^2} \quad \text{bzw.} \quad \frac{1}{2} \|Ax - y\|_2^2$$

minimiert wird.

Das Minimum sei mit \hat{x} bezeichnet.

Das Minimierungsproblem heißt **lineares Ausgleichsproblem** oder **Least-Squares-Problem**.

Methode der kleinsten Quadrate eigentlich **Methode der kleinsten Fehlerquadratsumme**

nach **C. F. Gauß** bzw. **A.-M. Legendre (1805)**

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren

Anwendung: Nichtlineare
Ausgleichsrechnung mit
dem
Gauß-Newton-Verfahren

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Problem (★) (Lin. Ausgleich als Minimierungsproblem)

Gegeben seien eine Matrix $A \in \mathbb{R}^{m \times n}$ und ein Vektor $y \in \mathbb{R}^m$ mit $m, n \in \mathbb{N}$.

Gesucht ist die Lösung $\hat{x} \in \mathbb{R}^n$ des Minimierungsproblems

$$\frac{1}{2} \|A\hat{x} - y\|_2^2 = \min_{x \in \mathbb{R}^n} \frac{1}{2} \|Ax - y\|_2^2 \quad (\dagger).$$

- Falls $m = n$ und A invertierbar, dann hat (\dagger) eine eindeutige Lösung.
- Der Fall $m > n$ ist in Anwendungen besonders relevant.
- Im Fall $m < n$ ist das LGS unterbestimmt. Es kann unlösbar sein, falls $\text{Rang}(A) \neq \text{Rang}(A | b)$

Auch andere Normen anstatt $\|\cdot\|_2$ können verwendet werden. Dann gestaltet sich die Berechnung von Lösungen u.U. schwieriger, da i.A. keine Differenzierbarkeit mehr vorliegt.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren

Anwendung: Nichtlineare
Ausgleichsrechnung mit
dem
Gauß-Newton-Verfahren

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Satz (Gaußsche Normalgleichungen)

\hat{x} löst Problem (★) genau dann, wenn die
Normalgleichungen

$$A^T A \hat{x} = A^T y.$$

gelten.

$A^T A \in \mathbb{R}^{n \times n}$ ist symmetrisch und positiv semi-definit.

Satz (Eindeutigkeit)

Sei $m \geq n$. Habe $A \in \mathbb{R}^{m \times n}$ maximalen Rang,
d.h. $\text{Rang}(A) = n$.

Genau dann ist das Minimierungsproblem (†) bzw. sind
die Normalgleichungen eindeutig lösbar.

Dann ist $A^T A \in \mathbb{R}^{n \times n}$ invertierbar und positiv definit.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren

Anwendung: Nichtlineare
Ausgleichsrechnung mit
dem
Gauß-Newton-Verfahren

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Gegeben:

- m Datenpunkte (t_i, y_i) , z.B. aus einer Messung
- **nicht**lineare Funktion mit n zu bestimmenden Parametern (typischerweise $m > n$)

$$g(t, x_1, \dots, x_n)$$

Aufgabe:

Minimiere das Residuum

$$r(x_1, \dots, x_n) = \begin{pmatrix} r_1(x_1, \dots, x_n) \\ \vdots \\ r_m(x_1, \dots, x_n) \end{pmatrix} = \begin{pmatrix} g(t_1, x_1, \dots, x_n) - y_1 \\ \vdots \\ g(t_m, x_1, \dots, x_n) - y_m \end{pmatrix},$$

bzw. bestimme x_1, \dots, x_n so, dass

$$f(x) = \sum_{i=1}^m r_i(x_1, \dots, x_n)^2 = \sum_{i=1}^m [g(t_i, x_1, \dots, x_n) - y_i]^2$$

minimal wird.

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren

Anwendung: Nichtlineare
Ausgleichsrechnung mit
dem
Gauß-Newton-VerfahrenRestringierte
OptimierungZusammenfassung
- Ausblick und
Wiederholung

Bedingung für ein Minimum:

$$\nabla f(x) = 2 \cdot \begin{pmatrix} \frac{\partial g}{\partial x_1}(t_1)r_1 + \frac{\partial g}{\partial x_1}(t_2)r_2 + \dots + \frac{\partial g}{\partial x_1}(t_m)r_m \\ \frac{\partial g}{\partial x_2}(t_1)r_1 + \frac{\partial g}{\partial x_2}(t_2)r_2 + \dots + \frac{\partial g}{\partial x_2}(t_m)r_m \\ \vdots \\ \frac{\partial g}{\partial x_m}(t_1)r_1 + \frac{\partial g}{\partial x_m}(t_2)r_2 + \dots + \frac{\partial g}{\partial x_m}(t_m)r_m \end{pmatrix} = 2r'(x)^\top r(x) \stackrel{!}{=} \mathbf{0}_n$$

Ausrechnen der Hesse-Matrix ergibt:

$$H_f(x) = 2 \cdot r'(x)^\top r'(x) + 2 \cdot \sum_{i=1}^m r_i(x)r_i''(x)$$

Lösung mit dem Newton-Verfahren: In jedem Schritt

- Lösen des Gleichungssystems $H_f(x^{[k]})d^{[k]} = \nabla f(x^{[k]})$
- Berechnen der nächsten Näherung $x^{[k+1]} = x^{[k]} - d^{[k]}$ (Beachte hier Vz. vor d !)

Einführung

Unrestringierte Optimierung

Wichtige Verfahren der numerischen Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren

Anwendung: Nichtlineare Ausgleichsrechnung mit dem Gauß-Newton-Verfahren

Restringierte Optimierung

Zusammenfassung - Ausblick und Wiederholung

- Weil in der Nähe der Lösung das Residuum klein ist, vernachlässigt man bei der Hesse-Matrix den Summenanteil, d.h. man verwendet die Näherung

$$H_f(x) \approx 2r'(x)^\top r'(x).$$

- Im linearen Fall ist das die Normalengleichung.
- Im nichtlinearen Fall handelt es sich um die Normalengleichung eines linearen Ersatzproblems

$$\min_{d \in \mathbb{R}^n} \|r(x^{[k]}) + r'(x^{[k]})d\|^2$$

anstelle von $\min_{x \in \mathbb{R}^n} \|r(x)\|^2$

- Man löst also in jedem Schritt ein lineares Ausgleichsproblem, das durch Taylorreihen-Entwicklung bis zur Ordnung 1 entsteht. Dies kann auch durch QR-Zerlegung erfolgen.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren

Anwendung: Nichtlineare
Ausgleichsrechnung mit
dem
Gauß-Newton-Verfahren

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Gauß-Newton-Verfahren (Algorithmus)

- 1 Wähle einen Startpunkt $x^{(0)}$.
Setze $k = 0$.
- 2 Falls $\nabla f(x^{[k]}) = 2r'(x^{[k]})^\top r(x^{[k]}) = \mathbf{0}$, dann STOP.
- 3 Bestimme die Suchrichtung $d^{[k]}$ durch Lösen entweder von

$$r'(x^{[k]})^\top r'(x^{[k]})d^{[k]} = r'(x^{[k]})^\top r(x^{[k]})$$

oder des überbestimmten Systems

$$r'(x^{[k]})d^{[k]} = r(x^{[k]})$$

mit der QR-Zerlegung.

- 4 Falls gedämpftes Verfahren verwendet wird, bestimme eine effiziente Schrittweite $\alpha^{[k]}$ nach Armijo-Goldstein oder Wolfe-Powell (ansonsten $\alpha^{[k]} = 1$) und berechne damit

$$x^{[k+1]} = x^{[k]} - \alpha^{[k]}d^{[k]}$$

- 5 Setze $k = k + 1$ und
gehe zu 2.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren

Anwendung: Nichtlineare
Ausgleichsrechnung mit
dem
Gauß-Newton-Verfahren

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Algorithmus (Ein erster Algorithmus für Normalgleichungen)

- (1) Berechne $r'(x)^\top r'(x)$ und $r'(x)^\top r(x)$
- (2) Bestimme Cholesky-Zerlegung $r'(x)^\top r'(x) = L(x)L^\top(x)$
- (3) Vorwärts-Rückwärts-Einsetzen

$$L(x)z = r'(x)^\top r(x)$$

$$L(x)^\top d = z$$

Problem: $r'(x)^\top r'(x)$ kann sehr schlecht konditioniert sein:

$$\text{cond}_2(r'(x)^\top r'(x)) = (\text{cond}_2(r'(x)))^2$$

Alternative: QR-Zerlegung

QR-Zerlegung auch nützlich für Lösung von LGS (numerisch stabiler als LR-Zerlegung, aber doppelter Aufwand) und für numerische Rangbestimmung einer Matrix

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren

Anwendung: Nichtlineare
Ausgleichsrechnung mit
dem
Gauß-Newton-Verfahren

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

- Große Ersparnis an Rechenzeit gegenüber dem Newton-Verfahren:
Aufgrund der speziellen Struktur der Ausgleichsprobleme bekommt man den ersten Teil der Hesse-Matrix 'geschenkt'.
- Verfahren funktioniert meist gut, wenn das Residuum klein ist, weil dann die Näherung der Hesse-Matrix realistisch ist.
- Bei großen Residuen ist häufig das Levenberg-Marquardt-Verfahren besser geeignet.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Ableitungsfreie Verfahren

Abstiegsverfahren und
Schrittweitensteuerung

Verfahren 1. Ordnung

Verfahren 2. Ordnung

Newton-Verfahren

Quasi-Newton-Verfahren

Trust-Region-Verfahren

Anwendung: Nichtlineare
Ausgleichsrechnung mit
dem
Gauß-Newton-Verfahren

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

- 1 Einführung
- 2 Unrestringierte Optimierung
- 3 Wichtige Verfahren der numerischen Optimierung
- 4 Restringierte Optimierung**
 - Beispiele und theoretische Grundlagen
 - Lagrange-Newton-Verfahren
 - KKT-Bedingungen
 - SQP-Verfahren
 - Penalty- und Barriere-Methoden
 - Active-Set-Methoden
- 5 Zusammenfassung - Ausblick und Wiederholung

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

**Restringierte
Optimierung**

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

In diesem Abschnitt betrachten wir die schon eingeführte Problemklasse:

Problem (Standard-Optimierungsproblem (SOP))

Minimiere $f(\mathbf{x})$ u. d. N.

$$g_i(\mathbf{x}) \leq 0, \quad i = 1, \dots, m,$$

$$h_j(\mathbf{x}) = 0, \quad j = 1, \dots, p.$$

bzw. in Vektornotation

$$g(\mathbf{x}) \leq \mathbf{0},$$

$$h(\mathbf{x}) = \mathbf{0}.$$

Dabei seien $\mathbf{x} \in \mathbb{R}^n$ und die Funktionen

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

$$g = (g_1, \dots, g_m)^\top : \mathbb{R}^n \rightarrow \mathbb{R}^m \text{ und}$$

$$h = (h_1, \dots, h_p)^\top : \mathbb{R}^n \rightarrow \mathbb{R}^p.$$

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

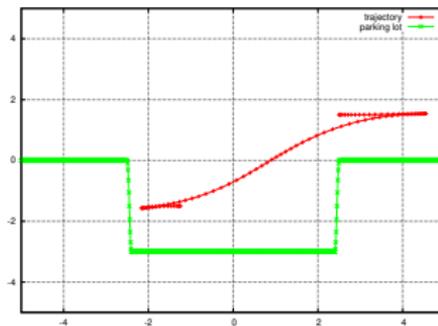
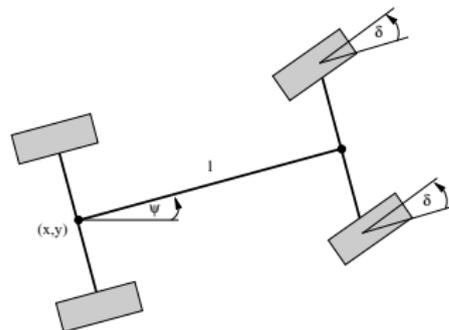
SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Beispiel: Optimales Fahren - Einparkmanöver :



$$f(\mathbf{y}, \mathbf{u}, t_f) = t_f \text{ (Gesamtfahrdauer)}$$

Hier Zustand \mathbf{y} und Steuerung \mathbf{u} zeitabhängige Funktionen

Ungleichungs-NB.:

Steuerungs- und Zustandsbeschränkungen

Gleichungs-NB.:

DGL für \mathbf{y} , mit Anfangs- **und** Endbedingungen

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

- Herstellung von zwei Produkten P_1 und P_2 , die einen Deckungsbeitrag von 10 bzw. 20 Euro pro Stück besitzen
- Zur Herstellung von einem Stück von P_1 oder P_2 ist jeweils eine Maschine nötig, von denen 100 vorhanden sind.
- Zur Herstellung von einem Stück P_1 werden 6 Einheiten des verwendeten Rohstoffs benötigt, bei P_2 sind es 9. Insgesamt sind 720 Einheiten vorhanden.
- In der Montageabteilung wird für P_1 niemand benötigt, für P_2 ein Arbeiter. Insgesamt arbeiten hier 60 Personen.
- Wie viele Stück von P_1 und P_2 muss man verkaufen, um den Deckungsbeitrag zu maximieren?

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Mathematische Formulierung als lineares
Optimierungsproblem:

$$\text{Maximiere } f(x_1, x_2) = 10x_1 + 20x_2$$

unter den Nebenbedingungen

$$x_1 + x_2 \leq 100 \quad (\text{Maschinen})$$

$$6x_1 + 9x_2 \leq 720 \quad (\text{Rohstoffe})$$

$$x_2 \leq 60 \quad (\text{Montage})$$

$$x_1, x_2 \geq 0$$

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

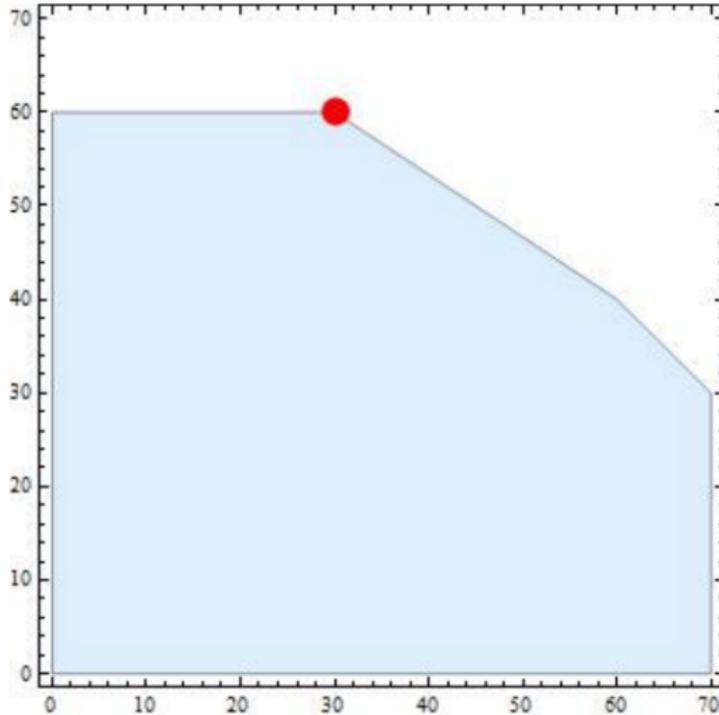
KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung



Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Annahme: Der Verkaufspreis und damit der Deckungsbeitrag von zwei Gütern ist jeweils von der Absatzmenge abhängig, z.B.

- Absatzzahlen x_1 und x_2
- Herstellungskosten 10
- Verkaufspreis (Preis-Absatz-Funktion) $30 - x_1$
bzw. $30 - x_2$

⇒ Deckungsbeitrag beschrieben durch folgende Funktion:

$$\begin{aligned} f(x_1, x_2) &= (30 - x_1)x_1 - 10x_1 + (30 - x_2)x_2 - 10x_2 \\ &= 20x_1 - x_1^2 + 20x_2 - x_2^2 \end{aligned}$$

unter linearen Nebenbedingungen für Maschinen, Rohstoffe, etc.

⇒ Quadratisches Optimierungsproblem mit linearen Nebenbedingungen

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Lineare Zielfunktion:

- Lineare Ungleichungs-Nebenbedingungen
- Nichtlineare Nebenbedingungen

Quadratische Zielfunktion:

- Lineare Gleichungs-Nebenbedingungen
- Lineare Ungleichungs-Nebenbedingungen
- Nichtlineare Gleichungs-Nebenbedingungen
- Nichtlineare Ungleichungs-Nebenbedingungen

Beliebige nichtlineare Zielfunktion:

- Lineare Gleichungs-Nebenbedingungen
- Lineare Ungleichungs-Nebenbedingungen
- Nichtlineare Gleichungs-Nebenbedingungen
- Nichtlineare Ungleichungs-Nebenbedingungen

Einführung

Unrestringierte Optimierung

Wichtige Verfahren der numerischen Optimierung

Restringierte Optimierung

Beispiele und theoretische Grundlagen

Lagrange-Newton-Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und Barriere-Methoden

Active-Set-Methoden

Zusammenfassung - Ausblick und Wiederholung

- Betrachte 2mal stetig differenzierbare $f : \mathbb{R}^n \rightarrow \mathbb{R}$.
- Maxima oder Minima der Zielfunktion $f(\mathbf{x})$ können im Inneren oder am Rand des zulässigen Bereichs auftreten.
- Bei **Extrema im Inneren** gelten die Optimalitätsbedingungen der unrestringierten Optimierung, also $\nabla f(\mathbf{x}) = 0$.
- Bei **Extrema am Rand** müssen Nebenbedingungen aktiv sein, d.h. mit Gleichheit gelten.
- Der **zulässige Bereich** X ist durch die Nebenbedingungen gegeben.
- Bei der Suche nach einem Minimum bewegt man sich von einem zulässigen Punkt in einer Suchrichtung weiter.
- Für jeden zulässigen Punkt $\mathbf{x} \in X$ ist \mathbf{d} eine **zulässige Richtung**, wenn es ein $r > 0$ gibt, so dass für alle $\alpha \in [0, r]$ gilt: $\mathbf{x} + \alpha \cdot \mathbf{d} \in X$

Aufgabe: Bestimme das Minimum der Funktion

$$f(\mathbf{x}) : \mathbb{R}^n \rightarrow \mathbb{R}$$

unter den Nebenbedingungen

$$h(\mathbf{x}) = \mathbf{0} \quad \text{mit} \quad h(\mathbf{x}) : \mathbb{R}^n \rightarrow \mathbb{R}^p$$

Dabei ist n die Dimension des Problems und p die Anzahl der Gleichungs-Nebenbedingungen.

Bedingung für ein Minimum $\hat{\mathbf{x}}$: Der negative Gradient von $f(\hat{\mathbf{x}})$ liegt im Raum, der senkrecht auf den Nebenbedingungen steht,

d.h. bei nur einer Nebenbedingung $h(\hat{\mathbf{x}}) = 0$ gilt

$$-\nabla f(\hat{\mathbf{x}}) = c \cdot \nabla h(\hat{\mathbf{x}}),$$

bei mehreren (mit $\boldsymbol{\mu} \in \mathbb{R}^p$):

$$-\nabla f(\hat{\mathbf{x}}) = J_h(\hat{\mathbf{x}})^\top \boldsymbol{\mu}$$

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
OptimierungRestringierte
OptimierungBeispiele und theoretische
GrundlagenLagrange-Newton-
Verfahren

KKT-Bedingungen

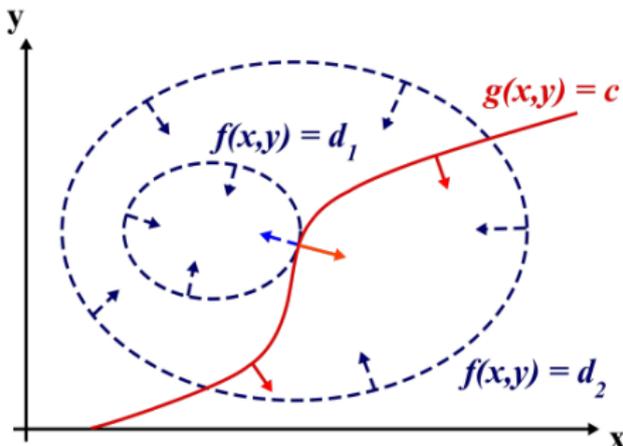
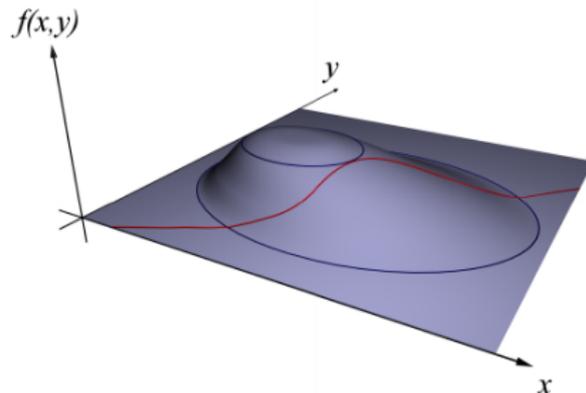
SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Funktion f und Gleichungs-NB. g



Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Notwendige Bedingungen 1. Ordnung

Man definiert für $\mathbf{x} = (x_1, \dots, x_n)^\top$ und $\boldsymbol{\mu} = (\mu_1, \dots, \mu_p)^\top$ die **Lagrange-Funktion** $L : \mathbb{R}^{n+p} \rightarrow \mathbb{R}$ mit

$$L(\mathbf{x}, \boldsymbol{\mu}) = f(\mathbf{x}) + \boldsymbol{\mu}^\top h(\mathbf{x}).$$

Mit Hilfe des Gradienten von L erhält man eine notwendige Bedingung für ein Minimum:

$$\nabla L(\mathbf{x}, \boldsymbol{\mu}) = \begin{pmatrix} \nabla_{\mathbf{x}} L(\mathbf{x}, \boldsymbol{\mu}) \\ \nabla_{\boldsymbol{\mu}} L(\mathbf{x}, \boldsymbol{\mu}) \end{pmatrix} = \begin{pmatrix} \nabla f(\mathbf{x}) + J_h(\mathbf{x})^\top \boldsymbol{\mu} \\ h(\mathbf{x}) \end{pmatrix} = \begin{pmatrix} \mathbf{0}_n \\ \mathbf{0}_p \end{pmatrix}$$

mit der Jacobi-Matrix

$$J_h(\mathbf{x}) = \begin{pmatrix} \frac{\partial h_1(x_1, \dots, x_n)}{\partial x_1} & \cdots & \frac{\partial h_1(x_1, \dots, x_n)}{\partial x_n} \\ \vdots & \ddots & \vdots \\ \frac{\partial h_p(x_1, \dots, x_n)}{\partial x_1} & \cdots & \frac{\partial h_p(x_1, \dots, x_n)}{\partial x_n} \end{pmatrix}$$

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Beispiel für $n = 2$ und $p = 1$

Aufgabe: Minimieren der Oberfläche eines Kreiszyinders bei gegebenem Volumen von einem Liter (d.h. 1000 cm^3)

Nichtlineare Minimierungsaufgabe: Minimiere

$$f(x_1, x_2) = 2\pi x_1(x_1 + x_2)$$

unter der Nebenbedingung

$$h(x_1, x_2) = \pi x_1^2 x_2 - V = 0.$$

Berechnung des Gradienten:

$$\nabla L(\mathbf{x}, \mu) = \begin{pmatrix} \nabla f(\mathbf{x}) + J_h(\mathbf{x})^T \mu \\ h(\mathbf{x}) \end{pmatrix} = \pi \cdot \begin{pmatrix} 2(2x_1 + x_2 + x_1 x_2 \mu) \\ 2x_1 + x_1^2 \mu \\ x_1^2 x_2 - V/\pi \end{pmatrix}$$

\Rightarrow Lösung: $x_1 = 5.42$, $x_2 = 10.84$, $\mu = -0.369$

Notwendige Bedingungen 2. Ordnung

Die Hesse-Matrix von $L(\mathbf{x}, \boldsymbol{\mu})$ ist

$$H_L(\mathbf{x}, \boldsymbol{\mu}) = \begin{pmatrix} B(\mathbf{x}, \boldsymbol{\mu}) & J_h^T(\mathbf{x}) \\ J_h(\mathbf{x}) & 0 \end{pmatrix}$$

mit

$$B(\mathbf{x}, \boldsymbol{\mu}) = \nabla_{\mathbf{xx}}^2 L(\mathbf{x}, \boldsymbol{\mu}) = H_f(\mathbf{x}) + \sum_{i=1}^p \mu_i H_{h_i}(\mathbf{x}).$$

An einem minimalen Punkt $\hat{\mathbf{x}}$ ist $H_L(\mathbf{x}, \boldsymbol{\mu})$ positiv definit für alle \mathbf{d} aus dem Nullraum von $J_h^T(\hat{\mathbf{x}})$, d.h. für alle Richtungen tangential zu den Nebenbedingungen, d.h.

$\mathbf{d}^T B(\mathbf{x}, \boldsymbol{\mu}) \mathbf{d} \geq 0$ für \mathbf{d} senkrecht auf allen Zeilen von $J_h^T(\hat{\mathbf{x}})$.

Das ist erfüllt, wenn die Matrix $Z^T B(\mathbf{x}, \boldsymbol{\mu}) Z$ positiv definit für $(\hat{\mathbf{x}}, \hat{\boldsymbol{\mu}})$ ist. Dabei sind die Spalten von Z eine Basis des Nullraums.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und

Barriere-Methoden

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Beispiel für $n = 2$ und $m = 1$

Berechnung der Hesse-Matrix:

$$H_f(\mathbf{x}) = 2\pi \begin{pmatrix} 2 & 1 \\ 1 & 0 \end{pmatrix} \quad \text{und} \quad H_h(\mathbf{x}) = 2\pi \begin{pmatrix} x_2 & x_1 \\ x_1 & 0 \end{pmatrix}$$

und damit

$$B(\hat{\mathbf{x}}, \hat{\mu}) = 2\pi \begin{pmatrix} 2 + x_2\mu & 1 + x_1\mu \\ 1 + x_1\mu & 0 \end{pmatrix} = \begin{pmatrix} -12.6 & -6.3 \\ -6.3 & 0 \end{pmatrix}$$

Berechnung der projizierten Hesse-Matrix:

Zu $J_h(\hat{\mathbf{x}}) = (369, 92.3)$ erhält man z.B. $Z = \begin{pmatrix} -0.243 \\ 0.970 \end{pmatrix}$ und

damit $Z^T B Z = 2.23$.

⇒ Minimum an der Stelle $\hat{\mathbf{x}}$ (mit $f(\hat{\mathbf{x}}) = 554 \text{ cm}^2$)

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Lagrange-Newton-Verfahren für gleichungsrestringierte Probleme

(SOP) ohne Ungleichungsrestriktionen ergibt

Problem (Nichtlineares Optimierungsproblem, rein gleichungsrestringiert)

Minimiere $f(\mathbf{x})$ u. d. N.

$$h_j(\mathbf{x}) = 0, \quad j = 1, \dots, p.$$

Dabei seien $\mathbf{x} \in \mathbb{R}^n$ und die Funktionen

$$f : \mathbb{R}^n \rightarrow \mathbb{R}, \\ h = (h_1, \dots, h_p)^\top : \mathbb{R}^n \rightarrow \mathbb{R}^p.$$

Hier kann man ggf. mithilfe des Satzes über implizite Funktionen auflösen, partitioniere dazu $\mathbf{x} = (\mathbf{y}, \mathbf{z})^\top \in \mathbb{R}^{n-p} \times \mathbb{R}^p$ und setze $h(\mathbf{y}, \mathbf{z}(\mathbf{y})) = \mathbf{0}$, somit

$$\boldsymbol{\mu}^\top := -\frac{\partial f}{\partial \mathbf{z}}(\hat{\mathbf{y}}, \hat{\mathbf{z}}) \left(\frac{\partial h}{\partial \mathbf{z}}(\hat{\mathbf{y}}, \hat{\mathbf{z}}) \right)^{-1}$$

und dann wie beim unrestringierten Optimierungsproblem vorgehen.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Theorem (Lagrangesche Multiplikatorenregel)

Seien $f : \mathbb{R}^n \rightarrow \mathbb{R}$ und $h : \mathbb{R}^n \rightarrow \mathbb{R}^p$, stetig differenzierbar und $\hat{\mathbf{x}}$ ein lokales Minimum von (SOP) für $m = 0$.

Des Weiteren gelte

$$\text{Rang}(h'(\hat{\mathbf{x}})) = p,$$

wobei $h'(\hat{\mathbf{x}})_{ij} = J_h(\hat{\mathbf{x}})_{ij} := \frac{\partial h_i}{\partial x_j}$ die Jacobi-Matrix von h in $\hat{\mathbf{x}}$.

Dann existiert ein $\mu \in \mathbb{R}^p$, so dass gilt

$$\nabla_x L(\hat{\mathbf{x}}, \mu) = \mathbf{0}, \quad (\text{Stationarität})$$

$$h(\hat{\mathbf{x}}) = \mathbf{0}. \quad (\text{Zulässigkeit})$$

Wh.:

Der Rang wird durch Gauß-Elimination bestimmt.

Für reelle Zahlen gilt Zeilenrang = Spaltenrang.

In 1D gilt $h' = \nabla h^\top$.

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
OptimierungRestringierte
OptimierungBeispiele und theoretische
GrundlagenLagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Anwendung des Newton-Verfahrens auf
 $F(\mathbf{x}, \boldsymbol{\mu})^\top := (\nabla_x L(\mathbf{x}, \boldsymbol{\mu}), h(\mathbf{x}))^\top = \mathbf{0}$ ergibt

Algorithmus (Lagrange-Newton-Verfahren)

(i) Wähle $\mathbf{x}^{[0]} \in \mathbb{R}^n$ und $\boldsymbol{\mu}^{[0]} \in \mathbb{R}^p$.

Setze $k := 0$.

(ii) Falls

$$\|F(\mathbf{x}^{[k]}, \boldsymbol{\mu}^{[k]})\| \approx 0,$$

dann STOP.

(iii) Löse das LGS

$$\begin{pmatrix} B(\mathbf{x}^{[k]}, \boldsymbol{\mu}^{[k]}) & h'(\mathbf{x}^{[k]})^\top \\ h'(\mathbf{x}^{[k]}) & 0 \end{pmatrix} \begin{pmatrix} \mathbf{d} \\ \mathbf{v} \end{pmatrix} = - \begin{pmatrix} \nabla_x L(\mathbf{x}^{[k]}, \boldsymbol{\mu}^{[k]}) \\ h(\mathbf{x}^{[k]}) \end{pmatrix}.$$

Setze $\mathbf{x}^{[k+1]} := \mathbf{x}^{[k]} + \mathbf{d}$ und $\boldsymbol{\mu}^{[k+1]} := \boldsymbol{\mu}^{[k]} + \mathbf{v}$.

(iv) Setze $k := k + 1$ und
gehe zu (ii).

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
OptimierungRestringierte
OptimierungBeispiele und theoretische
GrundlagenLagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Aus der Konvergenz des lokalen Newtonverfahrens folgt die lokale Konvergenz des Lagrange-Newtonverfahrens superlinear bzw. quadratisch

Hinreichende Kriterien für die Invertierbarkeit von

$$\begin{pmatrix} B(\mathbf{x}^{[k]}, \boldsymbol{\mu}^{[k]}) & h'(\mathbf{x}^{[k]})^\top \\ h'(\mathbf{x}^{[k]}) & \mathbf{0} \end{pmatrix}$$

sind:

- Es gilt (LICQ) und
- die hinreichende Optimalitätsbedingung 2. Ordnung, d.h. $T(\hat{\mathbf{x}}) = \{\mathbf{d} \mid h'(\hat{\mathbf{x}})\mathbf{d} = 0\}$.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Beispiel für Lagrange-Newton-Verfahren

Minimiere $2x_1^4 + x_2^4 + 4x_1^2 - x_1x_2 + 6x_2^2$
u.d.N. $2x_1 - x_2 = -4$, $x_1, x_2 \in \mathbb{R}$.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

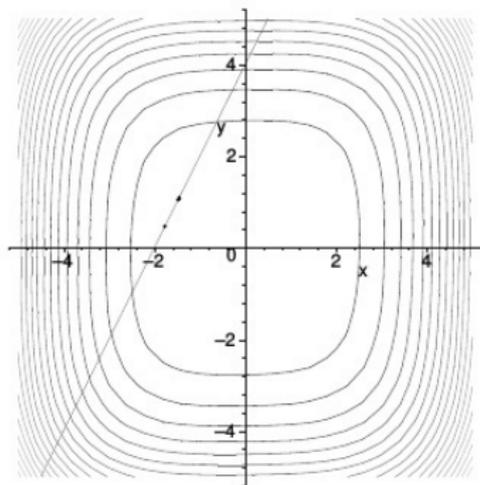
Penalty- und
Barriere-Methoden

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Beispiel für Lagrange-Newton-Verfahren

Minimiere $2x_1^4 + x_2^4 + 4x_1^2 - x_1x_2 + 6x_2^2$
u.d.N. $2x_1 - x_2 = -4$, $x_1, x_2 \in \mathbb{R}$.



```
ITERATION 0
ZIELFUNKTION = 0.000000000000000E+00
BESCHRAENKUNG = 0.400000000000000E+01
NORM KKT = 0.000000000000000E+00
X= 0.000000000000000E+00 0.000000000000000E+00
LAMBDA= 0.000000000000000E+00

ITERATION 1
ZIELFUNKTION = 0.3425678372606001E+02
BESCHRAENKUNG = 0.000000000000000E+00
NORM KKT = 0.4430579634007108E+02
X= -0.1769230769230769E+01 0.4615384615384616E+00
LAMBDA= 0.7307692307692307E+01

ITERATION 2
ZIELFUNKTION = 0.2756373273045131E+02
BESCHRAENKUNG = 0.000000000000000E+00
NORM KKT = 0.5155005942054521E+01
X= -0.1452391998833495E+01 0.1095216002333011E+01
LAMBDA= 0.1660806234685793E+02

ITERATION 3
ZIELFUNKTION = 0.2754452288430214E+02
BESCHRAENKUNG = 0.000000000000000E+00
NORM KKT = 0.1497798610217076E-01
X= -0.1467843643905216E+01 0.1064312712189567E+01
LAMBDA= 0.1904961295898514E+02

ITERATION 4
ZIELFUNKTION = 0.2754452202163215E+02
BESCHRAENKUNG = 0.000000000000000E+00
NORM KKT = 0.6772437517980240E-06
X= -0.1467948113419141E+01 0.1064103773161718E+01
LAMBDA= 0.1905680332151563E+02

ITERATION 5
ZIELFUNKTION = 0.2754452202163215E+02
BESCHRAENKUNG = 0.000000000000000E+00
NORM KKT = 0.3552713678800501E-14
X= -0.1467948118040920E+01 0.1064103763918160E+01
LAMBDA= 0.1905680364713604E+02
```

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
OptimierungRestringierte
OptimierungBeispiele und theoretische
GrundlagenLagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

- Das Verfahren ist schlecht zu verallgemeinern auf nichtlineare Optimierungsprobleme mit Ungleichungs-Nebenbedingungen. Ansätze mit sog. NCP-Funktionen scheitern meist an der Differenzierbarkeit.
- Im Lagrange-Newton-Verfahren wird nur ein KKT-Punkt, nicht zwangsläufig ein Minimum berechnet.

Zur Erinnerung: Im Newton-Verfahren wird in jedem Schritt ein quadratisches Hilfsproblem (die Taylor-Approximation 2. Ordnung) exakt gelöst.

Idee: Übertrage dies auf den restringierten Fall
⇒ Sequential Quadratic Programming (SQP-Verfahren)

- Eliminierung der Ungleichungsrestriktionen:
 - **Penalty- und Multiplikator-Verfahren:**
Ankopplung der NB. als **geeignet gewichteter Penalty-Term** an die Zielfunktion
dann wiederum Verfahren der unrestringierten Optimierung

Bsp. **Penalty-Verfahren,**
Multiplikator-Penalty-Verfahren
 - **Innere Punkte-Verfahren:**
Mithilfe von **Barrierefunktionen** wird die Annäherung an den Rand (“die Barriere”) des zulässigen Bereichs bestraft.
Daher können Ungleichungsnebenbedingungen eliminiert werden.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

- **Sequentielle quadratische Programmierung (SQP):**

(SOP) wird lokal approximiert durch (QOP), das Suchrichtung liefert

Erweiterung **Lagrange-Newton-Verfahren** auf Probleme mit Ungleichungs-NB.

- **Verfahren für Komplementaritätsprobleme:**

Z.B. semiglatte Newtonverfahren,
Variationsmethoden

Man versucht die notwendigen Bedingungen umzuschreiben und direkt zu lösen

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

- **Liniensuche**

Z.B. **Armijo-Verfahren**

- **Trust-Region-Verfahren**

Approximation auf einem Vertrauensbereich

- **Filterverfahren**

Versuche nicht-dominierte Iterierte zu erzeugen,
wobei Zielfunktionswert und Verletzung der
Restriktionen betrachtet werden

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Globalisierungsstrategien in der restringierten Optimierung

- **Liniensuche**

Z.B. Armijo-Verfahren

- **Trust-Region-Verfahren**

Approximation auf einem Vertrauensbereich

- **Filterverfahren**

Versuche nicht-dominierte Iterierte zu erzeugen, wobei Zielfunktionswert und Verletzung der Restriktionen betrachtet werden

Wie in der unrestringierten Optimierung suche notwendige & hinreichende Optimalitätsbedingungen

Einführung

Unrestringierte Optimierung

Wichtige Verfahren der numerischen Optimierung

Restringierte Optimierung

Beispiele und theoretische Grundlagen

Lagrange-Newton-Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und Barriere-Methoden

Active-Set-Methoden

Zusammenfassung - Ausblick und Wiederholung

Definition (Lagrange-Funktion)

$$L(\mathbf{x}, \lambda, \mu) := f(\mathbf{x}) + \sum_{i=1}^m \lambda_i g_i(\mathbf{x}) + \sum_{j=1}^p \mu_j h_j(\mathbf{x})$$

heißt **Lagrange-Funktion** für das Problem (SOP).

$\lambda = (\lambda_1, \dots, \lambda_m)^\top \in \mathbb{R}^m$ und $\mu = (\mu_1, \dots, \mu_p)^\top \in \mathbb{R}^p$ heißen
(Lagrangesche) Multiplikatoren.

Definition ((In)aktive Ungleichungsrestriktionen)

Sei \mathbf{x} zulässig für (SOP).

Die Beschränkung $g_i(\mathbf{x}) \leq \mathbf{0}$ heißt
aktiv in \mathbf{x} , wenn $g_i(\mathbf{x}) = \mathbf{0}$,
inaktiv in \mathbf{x} , wenn $g_i(\mathbf{x}) < \mathbf{0}$.

$\mathcal{A}(\mathbf{x}) := \{i \mid g_i(\mathbf{x}) = \mathbf{0}, 1 \leq i \leq m\}$

heißt **Indexmenge der in \mathbf{x} aktiven Ungleichungsrestriktionen**.

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
OptimierungRestringierte
OptimierungBeispiele und theoretische
GrundlagenLagrange-Newton-
Verfahren

KKT-Bedingungen

SOP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Theorem (Karush-Kuhn-Tucker-Bedingungen)

Seien $f, g_i, i = 1, \dots, m$, und $h_j, j = 1, \dots, p$, stetig differenzierbar und \hat{x} ein lokales Minimum von (SOP).

Des Weiteren gilt die Linear Independence Constraint Qualification (LICQ) in \hat{x} , d.h. $\nabla g_i(\hat{x}), i \in \mathcal{A}(\hat{x})$, und $\nabla h_j(\hat{x}), j = 1, \dots, p$, sind linear unabhängig.

Dann existieren eindeutige $\lambda \in \mathbb{R}^m$ und $\mu \in \mathbb{R}^p$, so dass gilt

$$\nabla_x L(\hat{x}, \lambda, \mu) = \quad (\text{Stationarität}) \quad (3.1)$$

$$\nabla f(\hat{x}) + \sum_{i=1}^m \lambda_i \nabla g_i(\hat{x}) + \sum_{j=1}^p \mu_j \nabla h_j(\hat{x}) = \mathbf{0}, \quad (3.2)$$

$$\lambda \geq \mathbf{0}, \quad \lambda^\top g(\hat{x}) = \mathbf{0}, \quad (\text{Komplementarität}) \quad (3.3)$$

$$g(\hat{x}) \leq \mathbf{0}, \quad h(\hat{x}) = \mathbf{0}. \quad (\text{Zulässigkeit}) \quad (3.4)$$

KKT-Punkte, d.h. Punkte (\hat{x}, λ, μ) , die (3.1) – (3.4) erfüllen, sind Kandidaten für Optimallösungen eines (SOP).

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
OptimierungRestringierte
OptimierungBeispiele und theoretische
GrundlagenLagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

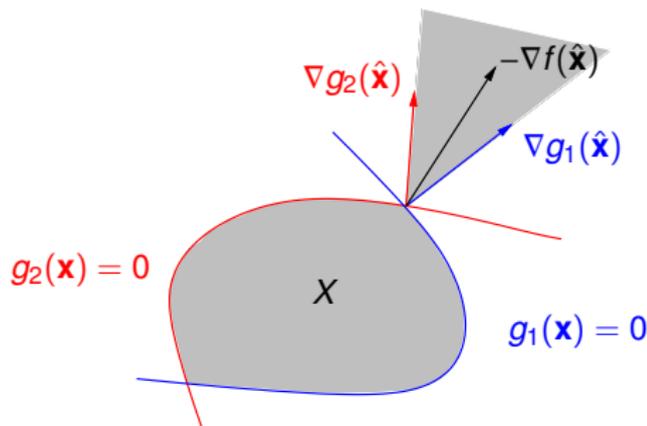
Penalty- und
Barriere-Methoden

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

KKT-Bedingungen: Geometrische Motivation

Bsp.: 2 Ungleichungsrestriktionen und keine Gleichungsrestriktionen



Falls in einem lokalen Minimum $\hat{\mathbf{x}}$ die Gradienten der aktiven Ungleichungsrestriktionen linear unabhängig sind, kann der negative Gradient der Zielfunktion als nicht-negative Linearkombination der Gradienten der aktiven Beschränkungen dargestellt werden.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Falls **Regularitätsbedingungen** (constraint qualifications (CQ)) wie (LICQ) erfüllt, sind die KKT-Bedingungen notwendig.

Weitere Regularitätsbedingungen: Mangasarian-Fromowitz, Robinson, Abadie, Slater (“Existenz eines inneren Punkts”), Constant-Rank-CQ ...

Falls keine (CQ) erfüllt ist, dann gelten die KKT-Bedingungen i.A. so nicht:

Vor f tritt ein weiterer Multiplikator auf (Fritz-John-Bedingungen), der evtl. Null wird.

Die (CQ) schließen isolierte Punkte bzw. Punkte, in die man nicht in hineinlaufen kann, aus.

Typischerweise hängen (CQ) von $\hat{\mathbf{x}}$ ab \rightsquigarrow schwierig *a priori* zu überprüfen

(LICQ) garantiert darüber hinaus die Eindeutigkeit der Multiplikatoren.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Sei $(\mathbf{x}, \lambda, \mu)$ ein KKT-Punkt von (SOP) und

$$I_0(\mathbf{x}) := \{i \in \{1, \dots, m\} \mid g_i(\mathbf{x}) = 0, \lambda_i = 0\},$$

$$I_{>}(\mathbf{x}) := \{i \in \{1, \dots, m\} \mid g_i(\mathbf{x}) = 0, \lambda_i > 0\},$$

d.h. strikte Komplementarität verletzt bzw. erfüllt.

Dann definiere den sogenannten **kritischen Kegel**

$$T(\mathbf{x}) := \{\mathbf{d} \in \mathbb{R}^n \mid \begin{array}{l} \nabla h_j(\mathbf{x})^\top d_j = 0, \quad j = 1, \dots, p, \\ \nabla g_i(\mathbf{x})^\top d_i = 0, \quad i \in I_{>}(\mathbf{x}), \\ \nabla g_i(\mathbf{x})^\top d_i \leq 0, \quad i \in I_0(\mathbf{x}) \end{array} \}.$$

Interpretation: T ist Menge der mehrdeutigen (kritischen) Richtungen

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
OptimierungRestringierte
OptimierungBeispiele und theoretische
GrundlagenLagrange-Newton-
Verfahren

KKT-Bedingungen

SOP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Theorem (Notwendige Optimalitätsbedingung 2. Ordnung)

Sei $L : \mathbb{R}^{n \times p \times m} \rightarrow \mathbb{R}$ 2mal stetig differenzierbar bzgl. \mathbf{x} .
Sei $\hat{\mathbf{x}}$ ein lokales Minimum von (SOP), so dass (LICQ) erfüllt ist.

Dann gilt

$$\mathbf{d}^T \nabla_{xx}^2 L(\hat{\mathbf{x}}, \boldsymbol{\lambda}, \boldsymbol{\mu}) \mathbf{d} \geq 0 \quad \text{für alle } \mathbf{d} \in T(\hat{\mathbf{x}}),$$

wobei $\boldsymbol{\lambda} \in \mathbb{R}^m$, $\boldsymbol{\mu} \in \mathbb{R}^p$ die eindeutig bestimmten Lagrangeschen Multiplikatoren aus den KKT-Bedingungen sind.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Theorem (Hinreichende Optimalitätsbedingung 2. Ordnung)

Sei $L : \mathbb{R}^{n \times p \times m} \rightarrow \mathbb{R}$ 2mal stetig differenzierbar bzgl. \mathbf{x} .

Sei $(\hat{\mathbf{x}}, \lambda, \mu)$ ein KKT-Punkt von (SOP) mit

$$\mathbf{d}^T \nabla_{\mathbf{xx}}^2 L(\hat{\mathbf{x}}, \lambda, \mu) \mathbf{d} > 0 \quad \text{für alle } \mathbf{d} \in T(\hat{\mathbf{x}}) \setminus \{\mathbf{0}\}.$$

Dann ist $\hat{\mathbf{x}}$ ein striktes lokales Minimum von (SOP).

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

SQP-Verfahren für gleichungsrestringierte Probleme

Setzt man $B_k := \nabla_{\mathbf{x}\mathbf{x}}^2 L(\mathbf{x}^{[k]}, \boldsymbol{\mu}^{[k]})$ im Gleichungssystem des Lagrange-Newton-Verfahrens, so erhält man

$$\begin{aligned} B_k \mathbf{d}^{[k]} + h'(\mathbf{x}^{[k]})^\top (\mathbf{v}^{[k]} + \boldsymbol{\mu}^{[k]}) &= -\nabla f(\mathbf{x}^{[k]}), \\ h'(\mathbf{x}^{[k]}) \mathbf{d} &= -h(\mathbf{x}^{[k]}). \end{aligned}$$

Dies sind genau die KKT-Bedingungen des quadratischen Problems

$$\begin{aligned} \min_{\mathbf{d}} \quad & \nabla f(\mathbf{x}^{[k]}) \mathbf{d} + \frac{1}{2} \mathbf{d}^\top B_k \mathbf{d} \\ \text{u.d.N.} \quad & h_j(\mathbf{x}^{[k]}) + h'_j(\mathbf{x}^{[k]}) \mathbf{d}_j = 0 \quad \text{für alle } j = 1, \dots, p. \end{aligned}$$

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden
Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Einschließlich Ungleichungen und
mit $B_k := \nabla_{xx}^2 L(\mathbf{x}^{[k]}, \lambda^{[k]}, \mu^{[k]})$ erhält man

$$\begin{aligned} \min_{\mathbf{d}} \quad & \nabla f(\mathbf{x}^{[k]})\mathbf{d} + \frac{1}{2}\mathbf{d}^\top B_k \mathbf{d} \\ \text{u.d.N.} \quad & g_i(\mathbf{x}^{[k]}) + g'_i(\mathbf{x}^{[k]})\mathbf{d} \leq 0 \quad \text{für alle } i = 1, \dots, m, \\ & h_j(\mathbf{x}^{[k]}) + h'_j(\mathbf{x}^{[k]})\mathbf{d} = 0 \quad \text{für alle } j = 1, \dots, p. \end{aligned}$$

Man löst also in jedem Iterationsschritt ein quadratisches Problem.

Dies ist das wichtige **SQP-Verfahren (sequential quadratic programming)**.

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
OptimierungRestringierte
OptimierungBeispiele und theoretische
GrundlagenLagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

- 1 Wähle $(\mathbf{x}^{[0]}, \lambda^{[0]}, \mu^{[0]})^\top \in \mathbb{R}^n \times \mathbb{R}^m \times \mathbb{R}^p$ und setze $k = 0$
- 2 Ist $(\mathbf{x}^{[k]}, \lambda^{[k]}, \mu^{[k]})^\top$ ein KKT-Punkt des Problems, dann STOP.
- 3 Berechne eine Lösung (oder zumindest einen KKT-Punkt) $\mathbf{d}^{[k]}$ des quadratischen Problems

$$\min_{\mathbf{d}} \nabla f(\mathbf{x}^{[k]})\mathbf{d} + \frac{1}{2}\mathbf{d}^\top B_k \mathbf{d}$$

unter den Nebenbedingungen

$$\begin{aligned} h(\mathbf{x}^{[k]}) + J_h(\mathbf{x}^{[k]})\mathbf{d} &= \mathbf{0}_m \\ g(\mathbf{x}^{[k]}) + J_g(\mathbf{x}^{[k]})\mathbf{d} &\leq \mathbf{0}_p \end{aligned}$$

Dabei wird häufig die Active-Set-Methode (später) verwendet.

- 4 Setze

$$\mathbf{x}^{[k+1]} = \mathbf{x}^{[k]} + \mathbf{d}^{[k]},$$

berechne B_{k+1} .

Setze $k := k + 1$ und gehe zu Schritt 2.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Satz: Es seien folgende Voraussetzungen erfüllt:

- $(\hat{\mathbf{x}}, \lambda, \mu)$ ist ein KKT-Punkt des Optimierungsproblems.
- Die Zeilen von $J_g(\hat{\mathbf{x}})$ und $J_h(\hat{\mathbf{x}})$ (d.h. die Gradienten $\nabla g_1(\hat{\mathbf{x}}), \dots, \nabla g_m(\hat{\mathbf{x}}), \nabla h_1(\hat{\mathbf{x}}), \dots, \nabla h_p(\hat{\mathbf{x}})$) sind linear unabhängig.
- Es gilt $\mathbf{d}^\top B(\hat{\mathbf{x}}, \lambda, \mu) \mathbf{d} > 0$ für alle $\mathbf{d} \neq \mathbf{0}_n$ mit $\nabla g_j(\hat{\mathbf{x}}) \mathbf{d} = 0$ und $\nabla h_j(\hat{\mathbf{x}}) \mathbf{d} = 0$.
(Zur Erinnerung: $B(\hat{\mathbf{x}}, \lambda, \mu) = \nabla_{\mathbf{xx}}^2 L(\hat{\mathbf{x}}, \lambda, \mu) = H_f(\hat{\mathbf{x}}) + \sum_{i=1}^m \lambda_i H_{g_i}(\hat{\mathbf{x}}) + \sum_{i=1}^p \mu_i H_{h_i}(\hat{\mathbf{x}})$)
- Es gilt strikte Komplementarität, d.h. $g_i(\hat{\mathbf{x}}) + \lambda_i \neq 0$ für $i = 1, \dots, m$.

Dann ist das SQP-Verfahren wohldefiniert und die Folge $\{(\mathbf{x}^{[k]}, \lambda^{[k]}, \mu^{[k]})\}$ konvergiert superlinear gegen den KKT-Punkt $(\hat{\mathbf{x}}, \lambda, \mu)$.

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
OptimierungRestringierte
OptimierungBeispiele und theoretische
GrundlagenLagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

- Lokal hat man zwar sehr schnelle Konvergenz, allerdings ist dieser Bereich häufig sehr klein.
- Eine Globalisierung, z.B. durch Armijo-ähnliche Schrittweitenstrategien und Updates der Form

$$\mathbf{x}^{[k+1]} = \mathbf{x}^{[k]} + t \mathbf{d}^{[k]}$$

ist im Allgemeinen notwendig. Allerdings ist es nicht möglich, t über einen Abstieg der Funktionswerte zu bestimmen.

- Stattdessen bestimmt man $t > 0$, so dass ein Abstieg einer Bewertungsfunktion (*merit function*) stattfindet. Als Bewertungsfunktion kann man z.B. eine Straffunktion betrachten:

$$P(\mathbf{x}; \eta) := f(\mathbf{x}) + \eta \sum_{j=1}^p |h_j(\mathbf{x})| + \eta \sum_{i=1}^m \max\{0, g_i(\mathbf{x})\}$$

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

- Im Befehl *fmincon* sind zwei Varianten der SQP-Methode implementiert.
- Wie im unrestringierten Fall kann die Berechnung der Hesse-Matrix durch Näherungen ersetzt werden. In Matlab wird eine BFGS-Formel verwendet.
- Die quadratischen Teilprobleme werden mit der Active-Set-Methode von Gill und Murray implementiert.
- Alternativ können auch für allgemeine nichtlineare Optimierungsprobleme Innere-Punkte-Verfahren verwendet werden.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Typen von Verfahren:

- **Penalty-Verfahren:**
Zielfunktionen der Hilfsprobleme bestrafen das Verlassen des zulässigen Bereichs (mit verschiedenen Typen von Straffunktionen)
- **Multiplikator-(Penalty-)Verfahren:**
Erweiterung der Penalty-Verfahren, durch erweiterte Lagrange-Funktion numerisch stabiler
- **Barriere-Verfahren:**
Verhindern, dass man sich zu schnell dem Rand des zulässigen Bereichs annähert (auch Innere Penalty-Verfahren genannt)

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Penalty-Verfahren

Multiplikator-Penalty-
Verfahren

Innere-Punkte-Verfahren

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Idee: Approximiere iterativ durch Lösung von unrestringierten Hilfsproblemen

Hilfsprobleme minimieren **Penalty-Funktion**

$$P(\mathbf{x}; \eta_k) := f(\mathbf{x}) + \frac{\eta_k}{2} \sum_{j=1}^p (h_j(\mathbf{x}))^2 + \frac{\eta_k}{2} \sum_{i=1}^m (\max\{0, g_i(\mathbf{x})\})^2$$

für geeignete $\eta_k > 0$

Nachteile:

- Gemäß Konvergenzresultat muss η_k gegen ∞ streben,
 \rightsquigarrow Algorithmus schlecht konditioniert
- P nicht exakt (exakt heißt es existiert $0 < \bar{\eta} < \infty$ so dass $\hat{\mathbf{x}}$ lokales Minimum von $P(\cdot, \eta)$ für alle $\eta \geq \bar{\eta}$)
- P i.A. nicht differenzierbar

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Penalty-Verfahren

Multiplikator-Penalty-
Verfahren

Innere-Punkte-Verfahren

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Mit quadratischer Penalty-Funktion, Optimierungsprobleme mit Gleichungs-NB.

Anstelle des Optimierungsproblems mit
Gleichungsnebenbedingungen

$$\min f(\mathbf{x}) \quad \text{u. d. N.} \quad h(\mathbf{x}) = \mathbf{0}_p$$

löst man eine Folge von unrestringierten Problemen der Art

$$P(\mathbf{x}; \eta) = f(\mathbf{x}) + \frac{\eta}{2} \|h(\mathbf{x})\|^2 \quad (\eta \geq 0).$$

Der **Penalty-Term** $\frac{\eta}{2} \|h(\mathbf{x})\|^2$ bestraft Verletzungen der
Nebenbedingungen.

η heißt **Penalty-Parameter** und $P(\mathbf{x}; \eta)$ **Penalty-Funktion**.

Je größer der Parameter η , desto stärker wird das Verletzen
von Nebenbedingungen bestraft. Für $\eta \rightarrow \infty$ erwartet man
also eine Lösung des restringierten Problems.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Penalty-Verfahren

Multiplikator-Penalty-
Verfahren

Innere-Punkte-Verfahren

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Das eindimensionale Beispiel

$$\min x^3 \quad \text{u. d. N.} \quad x^2 - 1 = 0$$

hat die Lösung $\hat{x} = -1$.

Die Penalty-Funktion

$$P(x; \eta) = x^3 + \frac{1}{2}\eta(x^2 - 1)^2$$

hat das globale Minimum

$$x(\eta) = -\frac{3}{4\eta} - \sqrt{1 + \frac{9}{16\eta^2}}$$

mit $\lim_{\eta \rightarrow \infty} x(\eta) = -1$.

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
OptimierungRestringierte
OptimierungBeispiele und theoretische
GrundlagenLagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Penalty-Verfahren

Multiplikator-Penalty-
Verfahren

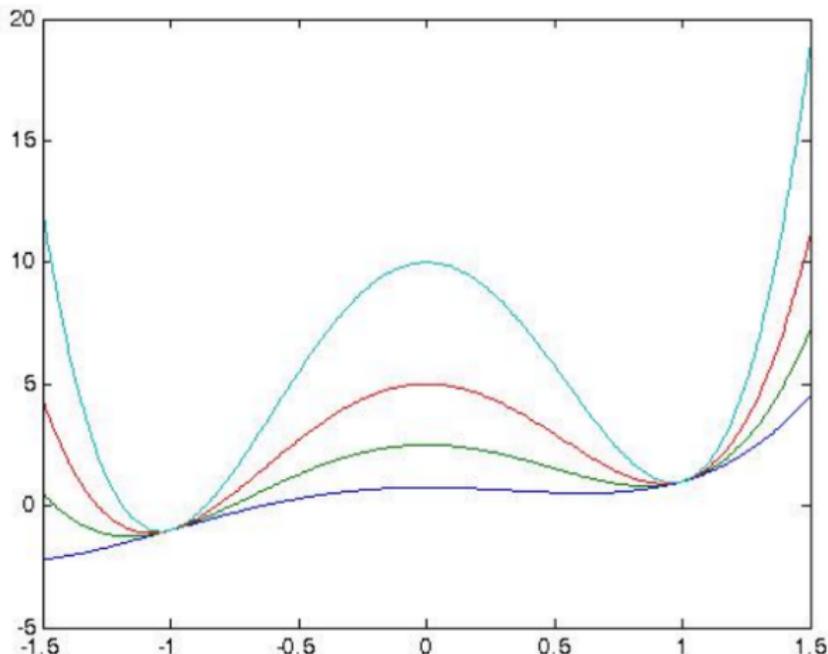
Innere-Punkte-Verfahren

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Penalty-Funktionen für wachsendes r

$P(x; \eta)$ mit $\eta = 1.5, 5, 10, 20$:



Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Penalty-Verfahren

Multiplikator-Penalty-
Verfahren

Innere-Punkte-Verfahren

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Algorithmus (*Penalty-Verfahren (rein gleichungsrestringiert)*)

(i) Wähle $\mathbf{x}^{[0]} \in \mathbb{R}^n$, $\eta_0 > 0$ und setze $k = 0$.

(ii) Bestimme $\mathbf{x}^{[k]}$ als Lösung von

$$\text{Minimiere } P(\mathbf{x}; \eta_k) \quad \text{u. d. N.} \quad \mathbf{x} \in \mathbb{R}^n.$$

(iii) Falls $h(\mathbf{x}^{[k]}) \approx 0$, STOP.

(iv) Bestimme $\eta_{k+1} > \eta_k$, setze $k := k + 1$ und gehe zu (ii).

Sind f und g 2mal stetig differenzierbar, verwendet man in (ii) meist ein globalisiertes Newton-Verfahren oder ein Quasi-Newton-Verfahren.

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
OptimierungRestringierte
OptimierungBeispiele und theoretische
GrundlagenLagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Penalty-Verfahren

Multiplikator-Penalty-
Verfahren

Innere-Punkte-Verfahren

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Für stetige Funktionen f und h , einen nichtleeren zulässigen Bereich $X = \{\mathbf{x} \in \mathbb{R}^n \mid h(\mathbf{x}) = 0\}$ und eine streng monoton wachsende Folge $\{\eta^{[k]}\}$ erzeugt das Penalty-Verfahren eine Folge von Näherungen $(\mathbf{x}^{[k]})_k$. Dann gilt:

- $P(\mathbf{x}^{[k+1]}; \eta^{[k+1]}) \geq P(\mathbf{x}^{[k]}; \eta^{[k]})$
- $f(\mathbf{x}^{[k+1]}) \geq f(\mathbf{x}^{[k]})$
- $\|h(\mathbf{x}^{[k+1]})\| \leq \|h(\mathbf{x}^{[k]})\|$
- $\lim_{k \rightarrow \infty} \|h(\mathbf{x}^{[k]})\| = 0$
- Jeder Häufungspunkt der Folge $\{\mathbf{x}^{[k]}\}$ ist eine Lösung des Optimierungsproblems.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Penalty-Verfahren

Multiplikator-Penalty-
Verfahren

Innere-Punkte-Verfahren

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Ziel:

Konstruktion einer Folge von Lagrange-Multiplikatoren $\{\boldsymbol{\mu}^{[k]}\}$, so dass die Paare $(\mathbf{x}^{[k]}, \boldsymbol{\mu}^{[k]})$ gegen einen KKT-Punkt des Minimierungsproblems konvergieren.

In einem KKT-Punkt $(\hat{\mathbf{x}}, \boldsymbol{\mu})$ muss gelten

$$\nabla f(\hat{\mathbf{x}}) + \sum_{i=1}^p \mu_i \nabla h_i(\hat{\mathbf{x}}) = \mathbf{0}_n .$$

Außerdem gilt für den Gradienten der Straffunktion

$$\nabla P(\mathbf{x}^{[k]}; \eta^{[k]}) = \nabla f(\mathbf{x}^{[k]}) + \eta^{[k]} \sum_{i=1}^p h_i(\mathbf{x}^{[k]}) \nabla h_i(\mathbf{x}^{[k]}) \approx \mathbf{0}_n$$

für große k . Daher vermutet man, dass

$$\mu_i^{[k]} := \eta^{[k]} h_i(\mathbf{x}^{[k]}), \quad i = 1, \dots, p,$$

eine gute Näherung für die Lagrange-Multiplikatoren sind.

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
OptimierungRestringierte
OptimierungBeispiele und theoretische
GrundlagenLagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Penalty-Verfahren

Multiplikator-Penalty-
Verfahren

Innere-Punkte-Verfahren

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Satz:

Angenommen, f und h sind stetig differenzierbar, $\{\mathbf{x}^{[k]}\}$ ist eine mit dem Penalty-Verfahren erzeugte Folge mit Grenzwert $\hat{\mathbf{x}}$ und die Gradienten $\nabla h_1(\hat{\mathbf{x}}), \dots, \nabla h_p(\hat{\mathbf{x}})$ sind linear unabhängig.

Dann gilt:

- Die Folge $\{\boldsymbol{\mu}^{[k]}\}$ konvergiert gegen einen Vektor $\boldsymbol{\mu} \in \mathbb{R}^p$.
- Das Paar $(\hat{\mathbf{x}}, \boldsymbol{\mu})$ ist ein KKT-Punkt des Optimierungsproblems.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Penalty-Verfahren

Multiplikator-Penalty-
Verfahren

Innere-Punkte-Verfahren

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Optimierungsprobleme mit Ungleichungsnebenbedingungen

Beim Optimierungsproblem

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

schreibt man die Ungleichungs-Nebenbedingungen um:

$$(\max\{0, g_1(\mathbf{x})\}, \dots, \max\{0, g_m(\mathbf{x})\})^T = \mathbf{0}_m$$

Damit erhält man die Penalty-Funktion

$$P(\mathbf{x}; \eta) = f(\mathbf{x}) + \frac{\eta}{2} \|h(\mathbf{x})\|^2 + \frac{\eta}{2} \sum_{i=1}^m (\max\{0, g_i(\mathbf{x})\})^2 \quad (\eta \geq 0).$$

Man kann zeigen, dass $P(\mathbf{x}; \eta)$ 1 mal stetig differenzierbar ist, falls f , g und h 2mal stetig differenzierbar sind.

Einführung

Unrestringierte Optimierung

Wichtige Verfahren der numerischen Optimierung

Restringierte Optimierung

Beispiele und theoretische Grundlagen

Lagrange-Newton-Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und Barriere-Methoden

Penalty-Verfahren

Multiplikator-Penalty-Verfahren

Innere-Punkte-Verfahren

Active-Set-Methoden

Zusammenfassung - Ausblick und Wiederholung

Mit der Jacobi-Matrix $J_h^{[k]}$ an der Stelle $\mathbf{x}^{[k]}$ erhält man die Hesse-Matrix für die Penalty-Funktion

$$H_P(\mathbf{x}^{[k]}, \eta^{[k]}) = H_f(\mathbf{x}^{[k]}) + \eta^{[k]} \left(\sum_{i=1}^p h_i(\mathbf{x}^{[k]}) H_{h_i}(\mathbf{x}^{[k]}) + (J_h^{[k]})^\top J_h^{[k]} \right).$$

Mit Hilfe von $\mu_i^{[k]} = \eta^{[k]} h_i(\mathbf{x}^{[k]})$ ergibt dies

$$\begin{aligned} H_P(\mathbf{x}^{[k]}; \eta^{[k]}) &= H_f(\mathbf{x}^{[k]}) + \sum_{i=1}^p \mu_i^{[k]} H_{h_i}(\mathbf{x}^{[k]}) + \eta^{[k]} (J_h^{[k]})^\top J_h^{[k]} \\ &= H_L(\mathbf{x}^{[k]}, \lambda^{[k]}) + \eta^{[k]} (J_h^{[k]})^\top J_h^{[k]} \end{aligned}$$

Wegen $\text{rang}((J_h^{[k]})^\top J_h^{[k]}) = p$ steigen p der Eigenwerte der Hessematrix an, wenn $k \rightarrow \infty$, und die Kondition wird beliebig schlecht.

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
OptimierungRestringierte
OptimierungBeispiele und theoretische
GrundlagenLagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Penalty-Verfahren

Multiplikator-Penalty-
Verfahren

Innere-Punkte-Verfahren

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Nachteile des quadratischen Penalty-Verfahrens:

- Der Penalty-Parameter η muss sehr hoch gewählt werden, damit man zu einer Lösung des ursprünglichen Optimierungsproblems gelangt und keine Nebenbedingung verletzt.
- Die Kondition der zu lösenden unrestringierten Hilfsprobleme ist dann sehr hoch und die Lösung ist schwierig.

Definition von exakten Penalty-Funktionen:

- Hier genügt ein fester, endlicher Penalty-Parameter für eine exakte Lösung des Minimierungsproblems, d.h. zu einem lokalen Minimum $\hat{\mathbf{x}}$ des restringierten Minimierungsproblems gibt es einen Parameter $\bar{\eta} > 0$, so dass $\hat{\mathbf{x}}$ für alle $\eta \geq \bar{\eta}$ auch ein lokales Minimum der Penalty-Funktion $P(\mathbf{x}; \eta)$ ist.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Penalty-Verfahren

Multiplikator-Penalty-
Verfahren

Innere-Punkte-Verfahren

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Satz:

Zu einem restringierten Optimierungsproblem sei

$$P(\mathbf{x}; \eta) = f(\mathbf{x}) + \eta \rho(\mathbf{x})$$

die Penalty-Funktion mit beliebigem Penalty-Term $\eta \rho(\mathbf{x})$.
Angenommen, $\hat{\mathbf{x}}$ ist ein lokales Minimum des
Optimierungsproblems mit $\nabla f(\hat{\mathbf{x}}) \neq \mathbf{0}$ und die
Penalty-Funktion ist exakt in $\hat{\mathbf{x}}$.

Dann ist die Funktion $P(\mathbf{x})$ in $\hat{\mathbf{x}}$ nicht differenzierbar.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Penalty-Verfahren

Multiplikator-Penalty-
Verfahren

Innere-Punkte-Verfahren

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Die bekannteste exakte Penalty-Funktion erhält man aus der quadratischen (durch Weglassen der Quadrate und des Faktors $1/2$):

Die l_1 -**Penalty-Funktion**. Sie ist definiert durch

$$P(\mathbf{x}; \gamma) = f(\mathbf{x}) + \gamma \sum_{i=1}^p |h_i(\mathbf{x})| .$$

Häufig verwendet man statt der Konstanten γ auch einen Vektor γ mit Komponenten γ_i .

Zu einer beliebigen l_p -Norm definiert man die entsprechende l_p -Penalty-Funktion

$$P(\mathbf{x}; \gamma) = f(\mathbf{x}) + \gamma \left(\sum_{i=1}^m |h_i(\mathbf{x})|^p \right)^{1/p} .$$

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
OptimierungRestringierte
OptimierungBeispiele und theoretische
GrundlagenLagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Penalty-Verfahren

Multiplikator-Penalty-
Verfahren

Innere-Punkte-Verfahren

Active-Set-Methoden

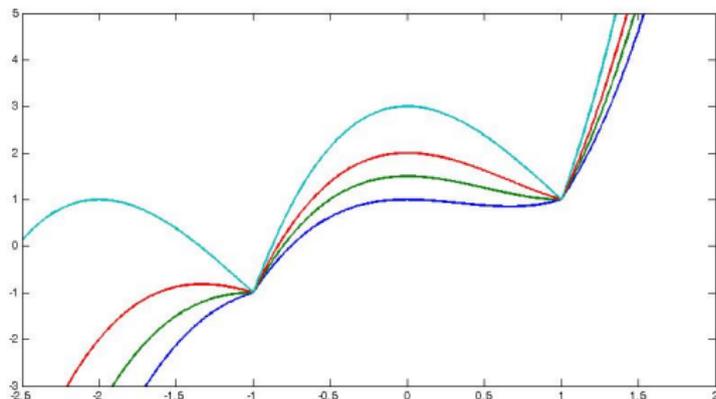
Zusammenfassung
- Ausblick und
Wiederholung

Wir betrachten noch einmal das Beispiel

$$\min x^3 \quad \text{u. d. N.} \quad x^2 - 1 = 0,$$

diesmal mit der l_1 -Penalty-Funktion

$$P(x; \gamma) = x^3 + \gamma|x^2 - 1|$$



Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Penalty-Verfahren

Multiplikator-Penalty-
Verfahren

Innere-Punkte-Verfahren

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

- Das Verfahren funktioniert prinzipiell genauso wie bei der quadratischen Penalty-Funktion. Der Hauptunterschied ist, dass das unrestringierte Hilfsproblem nur mit Verfahren für nicht differenzierbare Funktionen gelöst werden kann, z.B. Nelder-Mead.
- Ist $\hat{\mathbf{x}}$ ein lokales Minimum des gegebenen Optimierungsproblems und $\boldsymbol{\mu}$ der zugehörige Vektor der Lagrange-Multiplikatoren. Dann ist die Penalty-Funktion exakt, wenn $\gamma_i > |\mu_i|$ gewählt wird.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Penalty-Verfahren

Multiplikator-Penalty-
Verfahren

Innere-Punkte-Verfahren

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Betrachte hier nur Gleichungsrestriktionen

Betrachte anstatt Penalty-Funktion die **erweiterte Lagrange-Funktion** (Multiplikator-Penalty-Funktion)

$$L_a(\mathbf{x}, \boldsymbol{\mu}; \eta) := f(\mathbf{x}) + \boldsymbol{\mu}^\top h(\mathbf{x}) + \frac{\eta}{2} \|h(\mathbf{x})\|^2$$

für geeignete $\eta > 0$

Vorteile:

η muss nicht gegen ∞ streben.

L_a ist differenzierbar.

Nachteil:

Der optimale Lagrangeparameter $\boldsymbol{\mu}$ ist unbekannt.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Penalty-Verfahren

Multiplikator-Penalty-
Verfahren

Innere-Punkte-Verfahren

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Überlegung:

- Die quadratische Penalty-Funktion führt zu differenzierbaren Hilfsproblemen, aber nicht zu exakten Lösungen.
- Die exakte Penalty-Funktion führt zu nicht-differenzierbaren Hilfsproblemen, aber zur exakten Lösung für alle η , die größer als die Lagrange-Multiplikatoren sind.

Ansatz bei Multiplikator-Penalty-Verfahren:

- Kombiniere quadratischen Strafterm und Multiplikator-Term für Lagrange-Multiplikatoren, d.h. definiere

$$L_a(\mathbf{x}, \boldsymbol{\mu}; \eta) = f(\mathbf{x}) + \boldsymbol{\mu}^\top h(\mathbf{x}) + \frac{\eta}{2} \|h(\mathbf{x})\|^2 \quad (\eta \geq 0).$$

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Penalty-Verfahren

Multiplikator-Penalty-
Verfahren

Innere-Punkte-Verfahren

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

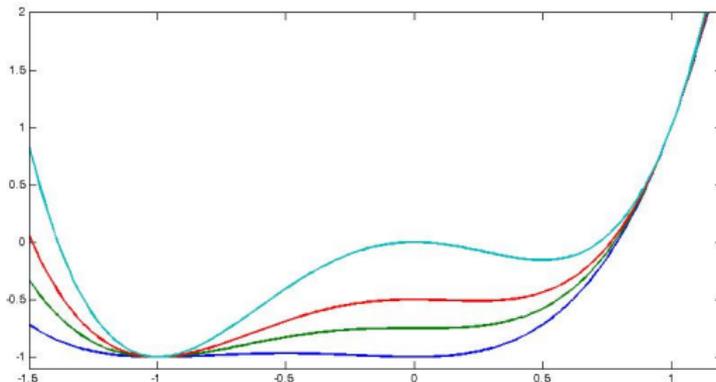
Und noch einmal das Beispiel

$$\min x^3 \quad \text{u. d. N.} \quad x^2 - 1 = 0,$$

diesmal mit der Multiplikator-Penalty-Funktion

$$L_a(x, \mu; \eta) = x^3 + \mu(x^2 - 1) + \eta(x^2 - 1)^2$$

Für $\eta > \mu = 3/2$ ist die Multiplikator-Penalty-Funktion exakt:



Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Penalty-Verfahren

Multiplikator-Penalty-
Verfahren

Innere-Punkte-Verfahren

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Hilfssatz:

Seien $Q \in \mathbb{R}^{n \times n}$ symmetrisch und $A \in \mathbb{R}^{m \times n}$ mit $m < n$ und vollem Zeilenrang m . Außerdem gilt für ein $\eta > 0$

$$\mathbf{d}^T Q \mathbf{d} \geq \eta \|\mathbf{d}\|^2 \quad \forall \mathbf{d} \in \text{kern}(A).$$

Dann ist für hinreichend großes η die Matrix $Q + \eta A^T A$ positiv definit.

Satz:

Seien $(\hat{\mathbf{x}}, \lambda)$ ein KKT-Punkt des Optimierungsproblems, $f(\mathbf{x})$ 2mal stetig differenzierbar und die Zeilen von $J_h(\mathbf{x})$ linear unabhängig. Es ist außerdem die Optimalitätsbedingung 2. Ordnung erfüllt, d.h.

$$\mathbf{d}^T L_{\mathbf{xx}}(\hat{\mathbf{x}}, \mu) \mathbf{d} \geq \bar{\eta} \|\mathbf{d}\|^2 \quad \forall \mathbf{d} \in \text{kern}(J_h(\hat{\mathbf{x}})).$$

Dann ist $\hat{\mathbf{x}}$ für $\eta > \bar{\eta}$ ein lokaler Minimalpunkt von $L_a(\mathbf{x}, \mu; \eta)$.

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
OptimierungRestringierte
OptimierungBeispiele und theoretische
GrundlagenLagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Penalty-Verfahren

Multiplikator-Penalty-
Verfahren

Innere-Punkte-Verfahren

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Algorithmus (Multiplikator-Penalty-Verfahren)

- (i) Wähle $\mathbf{x}^{[0]} \in \mathbb{R}^n$, $\boldsymbol{\mu}^{[0]} \in \mathbb{R}^p$, $\eta_0 > 0$, $\sigma \in (0, 1)$ und setze $k = 0$.
- (ii) Falls $(\mathbf{x}^{[k]}, \boldsymbol{\mu}^{[k]})$ KKT-Punkt, dann STOP.
- (iii) Bestimme $\mathbf{x}^{[k+1]}$ als Lösung von

$$\text{Minimiere } L_a(\mathbf{x}, \boldsymbol{\mu}^{[k]}; \eta_k) \quad \text{u. d. N.} \quad \mathbf{x} \in \mathbb{R}^n.$$

- (iv) Setze $\boldsymbol{\mu}^{[k+1]} := \boldsymbol{\mu}^{[k]} + \eta_k h(\mathbf{x}^{[k+1]})$.
- (v) Ist $\|h(\mathbf{x}^{[k+1]})\| \geq \sigma \|h(\mathbf{x}^{[k]})\|$,
dann $\eta_{k+1} := 10\eta_k$,
sonst $\eta_{k+1} := \eta_k$.
- (vi) Setze $k := k + 1$ und
gehe zu (ii).

Das Multiplikator-Penalty-Verfahren lässt sich auch auf Ungleichungs-Nebenbedingungen erweitern.

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
OptimierungRestringierte
OptimierungBeispiele und theoretische
GrundlagenLagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Penalty-Verfahren

Multiplikator-Penalty-
Verfahren

Innere-Punkte-Verfahren

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

- Zur Lösung (nicht)linearer konvexer Optimierungsprobleme
- Im Gegensatz zum Simplex-Verfahren wird das Innere des zulässigen Bereichs durchquert.
- Man kann polynomiale Komplexität beweisen.

Das Simplex-Verfahren (aus der linearen Optimierung) hat im worst case exponentielle Komplexität.

- Gängige IP-Verfahren können im average case mit dem Simplex-Verfahren konkurrieren.

Wir betrachten zu Demonstrationszwecken hier nur Ungleichungsnebenbedingungen:

$$\min f(\mathbf{x}) \quad u.d.N. \quad g(\mathbf{x}) \leq \mathbf{0}_m$$

zu $f : \mathbb{R}^n \rightarrow \mathbb{R}$, $g : \mathbb{R}^n \rightarrow \mathbb{R}^m$.

Die zugehörige logarithmische **Barrierefunktion** ist

$$B(\mathbf{x}, \eta) = f(\mathbf{x}) - \eta \sum_{i=1}^m \log(-g_i(\mathbf{x})),$$

wobei der **Barriereparameter** $\eta > 0$.

Idee: Minimum $B(\mathbf{x}, \eta)$ konvergiert gegen Optimallösung, wenn $\eta \rightarrow 0$.

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
OptimierungRestringierte
OptimierungBeispiele und theoretische
GrundlagenLagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Penalty-Verfahren

Multiplikator-Penalty-
Verfahren

Innere-Punkte-Verfahren

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Gradient der Barrierefunktion:

$$\nabla_{\mathbf{x}} B(\mathbf{x}, \eta) = \nabla f(\mathbf{x}) - \eta \sum_{i=1}^m \frac{\nabla g_i(\mathbf{x})}{g_i(\mathbf{x})}$$

Zur primalen Variable $\mathbf{x} \in \mathbb{R}^n$ führt man eine duale Variable $\lambda \in \mathbb{R}^m$ durch eine **Komplementaritätsbedingung mit Störung** ein:

$$-g_i(\mathbf{x})\lambda_i = \eta \quad \text{für alle } i = 1, \dots, m.$$

Man sucht (\mathbf{x}, λ) , so dass $\nabla_{\mathbf{x}} B(\mathbf{x}, \eta) = \mathbf{0}$:

$$\nabla f(\mathbf{x}) - J_g(\mathbf{x})\lambda = \mathbf{0}_n.$$

Interpretation:

- ∇f liegt im Unterraum, der durch die Gradienten der NB. aufgespannt wird.
- Die Komplementaritätsbedingung mit kleinem η heißt, dass das Minimum entweder am Rand liegt oder die Projektion von ∇f auf g_i nahe Null ist.

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
OptimierungRestringierte
OptimierungBeispiele und theoretische
GrundlagenLagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Penalty-Verfahren

Multiplikator-Penalty-
Verfahren

Innere-Punkte-Verfahren

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Anwendung des Newton-Verfahrens motiviert für das Update $(\mathbf{d}, \mathbf{u})^\top$ (zu (\mathbf{x}, λ)):

$$\begin{pmatrix} \nabla_{\mathbf{x}\mathbf{x}}^2 B(\mathbf{x}, \eta) & \mathbf{J}_g^\top \\ -\lambda \mathbf{I}_m \mathbf{J}_g & -g \mathbf{I}_m \end{pmatrix} \begin{pmatrix} \mathbf{d} \\ \mathbf{u} \end{pmatrix} = \begin{pmatrix} -\nabla f(\mathbf{x}) - \mathbf{J}_g^\top \lambda \\ \eta \mathbf{e} + g \mathbf{I}_m \lambda \end{pmatrix},$$

wobei $\mathbf{e} = (1, \dots, 1)^\top \in \mathbb{R}^m$.

Die Bedingung $\lambda \geq \mathbf{0}_m$ wird durch die Wahl der Schrittweite α garantiert:

$$\begin{pmatrix} \mathbf{x} \\ \lambda \end{pmatrix} \rightarrow \begin{pmatrix} \mathbf{x} + \alpha \mathbf{d} \\ \lambda + \alpha \mathbf{u} \end{pmatrix}.$$

η muss auch noch über die Iterationen hin geeignet verkleinert werden.

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
OptimierungRestringierte
OptimierungBeispiele und theoretische
GrundlagenLagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Penalty-Verfahren

Multiplikator-Penalty-
Verfahren

Innere-Punkte-Verfahren

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

Algorithmus für LP (primale Normalform)

Beachte duale Gleichungs-NB.: $A^T \mu + \lambda = \mathbf{c}$

Algorithmus (IP-Verfahren für Lineares Problem)

- (i) Wähle $\mathbf{x}^{[0]} \in \mathbb{R}^n$, $\mu^{[0]} \in \mathbb{R}^m$, $0 < \lambda^{[0]} \in \mathbb{R}^n$.
- (ii) Setze $\eta = \frac{1}{n} \mathbf{x}^T \lambda$.
- (iii) Falls Abbruchbedingung (z.B. $\|\nabla_{\mathbf{x}} B\|$ und $\eta \approx 0$) erfüllt, dann STOP.
- (iv) Reduziere η , so dass: $0 < \eta^+ < \eta$.
- (v) Berechne Suchrichtung durch Lösung des LGS:

$$\begin{pmatrix} 0_{n \times n} & -A^T & -I_n \\ -A & 0_{m \times m} & 0_{m \times n} \\ \lambda I_n & 0_{n \times m} & \mathbf{x} I_n \end{pmatrix} \begin{pmatrix} \mathbf{d} \\ \mathbf{v} \\ \mathbf{u} \end{pmatrix} = \begin{pmatrix} -\mathbf{c} + A^T \mu + \lambda \\ A\mathbf{x} - \mathbf{b} \\ \eta \mathbf{e} - \mathbf{x} I_n \lambda \end{pmatrix}$$

- (vi) Wähle Schrittweite $\alpha > 0$, so dass $\mathbf{x} + \alpha \mathbf{d} > \mathbf{0}_n$, $\lambda + \alpha \mathbf{v} > \mathbf{0}_n$
(einige Varianten stellen weitere Bedingungen an α)
- (vii) Update:

$$\mathbf{x}^+ = \mathbf{x} + \alpha \mathbf{d},$$

$$\mu^+ = \mu + \alpha \mathbf{v},$$

$$\lambda^+ = \lambda + \alpha \mathbf{u}.$$

- (viii) Gehe zu (ii).

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen
SQP-Verfahren

Penalty- und
Barriere-Methoden

Penalty-Verfahren
Multiplikator-Penalty-
Verfahren

Innere-Punkte-Verfahren

Active-Set-Methoden

Zusammenfassung
- Ausblick und
Wiederholung

- IP-Verfahren sind global konvergent.
- Gängige Varianten (insbesondere bzgl. der Wahl von η^+ und α) sind:
Kurzschrittverfahren,
Langschrittverfahren und
Predictor-Corrector-Verfahren.
- Der worst case der Kurzschrittvariante benötigt $O(\sqrt{n}/\varepsilon)$, um eine Lösung eines linearen Problems mit Genauigkeit ε zu finden.
- Praktisch beobachtet man $O(\log(n))$.

Lineare Optimierung: Wiederholung

Wir betrachten lineare Optimierungsprobleme, d.h. Zielfunktion und Nebenbedingung sind lineare Funktionen.

Definition (Lineare Funktion)

Eine Funktion $f : \mathbb{R}^n \rightarrow \mathbb{R}^m$ heißt **linear** genau dann, wenn für alle $x, y \in \mathbb{R}^n$ und alle $c \in \mathbb{R}$ gilt:

$$\begin{aligned}f(x + y) &= f(x) + f(y), \\f(cx) &= cf(x).\end{aligned}$$

Definition (Affin-lineare Funktion)

Eine Funktion $f : \mathbb{R}^n \rightarrow \mathbb{R}^m$ heißt **affin linear** genau dann, wenn es eine lineare Funktion $\tilde{f} : \mathbb{R}^n \rightarrow \mathbb{R}^m$ und einen konstanten Vektor $b \in \mathbb{R}^m$ gibt, so dass für alle $x \in \mathbb{R}^n$

$$f(x) = \tilde{f}(x) + b.$$

Jede lineare Funktion $f : \mathbb{R}^n \rightarrow \mathbb{R}^m$ hat die Darstellung $f(x) = Ax$ mit einer Matrix $A \in \mathbb{R}^{m \times n}$.

Jede affin-lineare Fn. $f : \mathbb{R}^n \rightarrow \mathbb{R}^m$ hat die Darstellung $f(x) = Ax + b$ mit einer Matrix $A \in \mathbb{R}^{m \times n}$ und einem Vektor $b \in \mathbb{R}^m$.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Wiederholung: Lineare
Optimierung

Active-Set-Methoden für
quadratische
Optimierungsprobleme

Zusammenfassung
- Ausblick und
Wiederholung

Definition (Lineares Programm (LP))

Minimiere $c^T x = \sum_{j=1}^n c_j x_j$ u.d.N.

$$\sum_{j=1}^n a_{ij} x_j \left\{ \begin{array}{l} \leq \\ \geq \\ = \end{array} \right\} b_i, \quad i = 1, \dots, m,$$
$$x_i \left\{ \begin{array}{l} \leq \\ \geq \end{array} \right\} 0, \quad i \in I,$$

wobei $I \subseteq \{1, \dots, n\}$ eine Indexmenge und $x, c \in \mathbb{R}^n$, $b \in \mathbb{R}^m$ und $A \in \mathbb{R}^{m \times n}$.

Variable x_i mit $i \notin I$ heißen **freie Variable**.

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
OptimierungRestringierte
OptimierungBeispiele und theoretische
GrundlagenLagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Wiederholung: Lineare
OptimierungActive-Set-Methoden für
quadratische
OptimierungsproblemeZusammenfassung
- Ausblick und
Wiederholung

Das LP ist in allgemeiner Form gegeben. Für eine systematische Behandlung betrachten wir LPs in primaler Normalform:

Problem (Lineares Optimierungsproblem (LOP) in **primaler Normalform**)

Minimiere $\mathbf{c}^T \mathbf{x}$ u. d. N.

$$\mathbf{x} \geq 0, \quad \mathbf{Ax} = \mathbf{b},$$

wobei $\mathbf{x}, \mathbf{c} \in \mathbb{R}^n$, $\mathbf{b} \in \mathbb{R}^m$ und $A \in \mathbb{R}^{m \times n}$.

Alle LP sind äquivalent zu Problem in primaler Normalform:

- Eliminiere freie Variable x_i , $i \notin I$, durch Aufspaltung:

$$x_i = x_i^+ - x_i^-, \quad x_i^+ \geq 0, \quad x_i^- \geq 0.$$

- Eliminiere Ungleichung $\sum_{j=1}^n a_{ij} x_j \begin{cases} \leq \\ \geq \end{cases} b_i$, $i = 1, \dots, m$, durch Einführung einer **Schlupfvariable** $s_i \geq 0$:

$$\sum_{j=1}^n a_{ij} x_j \pm s_i = b_i \quad (A \in \mathbb{R}^{m \times n}, \mathbf{b} \in \mathbb{R}^m).$$

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
OptimierungRestringierte
OptimierungBeispiele und theoretische
GrundlagenLagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Wiederholung: Lineare
OptimierungActive-Set-Methoden für
quadratische
OptimierungsproblemeZusammenfassung
- Ausblick und
Wiederholung

Lösbarkeit des LGS und Rang

Ein LGS $\mathbf{Ax} = \mathbf{b}$ ist lösbar $\iff \text{Rang}(A) = \text{Rang}(A | \mathbf{b})$.

Allgemein gilt für $A \in \mathbb{R}^{m \times n}$, dass $\text{Rang}(A) \leq \min\{m, n\}$.

Im Fall $m > n$ und $\text{Rang}(A) = n$ (nach Elimination linear abhängiger Spalten) gibt es höchstens eine Lösung¹.

Wenn im Fall $m = n$ die Matrix A invertierbar ist, dann gibt es eine eindeutige Lösung.

Bei einer Lösung gibt es nichts zu optimieren!

Der Fall $m < n$ ist von besonderem Interesse \rightsquigarrow
Annahme $m < n$.

Annahme $\text{Rang}(A) = m$ (durch Elimination linear abhängiger Zeilen)

¹noch abhängig von $\text{Rang}(A | \mathbf{b})$

Ein (SOP) heißt **konvexes Optimierungsproblem** genau dann, wenn f und g konvexe, stetig differenzierbare Funktionen sind und h affin-linear ist.

LOP sind konvexe Optimierungsprobleme!

Ein (SOP) heißt **konvexes Optimierungsproblem** genau dann, wenn f und g konvexe, stetig differenzierbare Funktionen sind und h affin-linear ist.

LOP sind konvexe Optimierungsprobleme!

Theorem (Globale Minimierer konvexer Zielfunktionen (Wh.!!))

Seien $f : \mathbb{R}^n \rightarrow \mathbb{R}$ und $M \subseteq \mathbb{R}^n$ konvex.

Ist \hat{x} ein stationärer Punkt von f auf M ,

dann ist \hat{x} ein globales Minimum von f auf M .

Der zulässige Bereich eines LOP kann noch beschränkt oder unbeschränkt sein.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

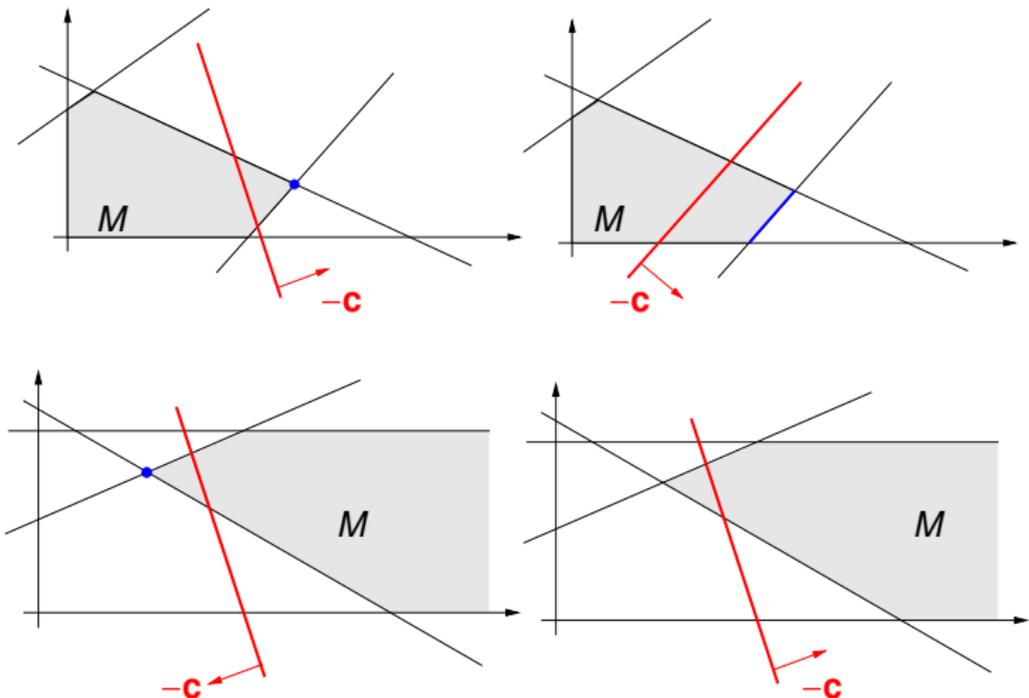
Active-Set-Methoden

Wiederholung: Lineare
Optimierung

Active-Set-Methoden für
quadratische
Optimierungsprobleme

Zusammenfassung
- Ausblick und
Wiederholung

Mögliche Konstellationen von M in der linearen Optimierung



Einführung

Unrestringierte Optimierung

Wichtige Verfahren der numerischen Optimierung

Restringierte Optimierung

Beispiele und theoretische Grundlagen

Lagrange-Newton-Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und Barriere-Methoden

Active-Set-Methoden

Wiederholung: Lineare Optimierung

Active-Set-Methoden für quadratische Optimierungsprobleme

Zusammenfassung - Ausblick und Wiederholung

Lagrange-Funktion:

$$L(\hat{\mathbf{x}}, \lambda, \mu) = \mathbf{c}^\top \mathbf{x} - \lambda^\top \mathbf{x} + \mu^\top (\mathbf{A}\mathbf{x} - \mathbf{b})$$

Gleichungs- und Ungleichungsbedingungen:

- $\mathbf{c} - \lambda + \mathbf{A}^\top \mu = \mathbf{0}_n$
- $\mathbf{A}\hat{\mathbf{x}} - \mathbf{b} = \mathbf{0}_m$
- $\hat{\mathbf{x}} \geq \mathbf{0}_n$
- $\lambda \geq \mathbf{0}_n$
- $\hat{x}_i \hat{\lambda}_i = 0$ für $i = 1, \dots, n$

Für eine Lösung des linearen Optimierungsproblems sind diese 5 Bedingungen notwendigerweise erfüllt.

Einführung

Unrestringierte Optimierung

Wichtige Verfahren der numerischen Optimierung

Restringierte Optimierung

Beispiele und theoretische Grundlagen

Lagrange-Newton-Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und Barriere-Methoden

Active-Set-Methoden

Wiederholung: Lineare Optimierung

Active-Set-Methoden für quadratische Optimierungsprobleme

Zusammenfassung - Ausblick und Wiederholung

Existenz und Eigenschaften der Optimallösung eines LOP

Theorem (Fundamentalsatz der linearen Programmierung)

Sei ein LOP in primaler Normalform,

$$\text{Minimiere } \mathbf{c}^T \mathbf{x} \quad \text{u.d.N. } \mathbf{x} \geq \mathbf{0}_n, \mathbf{A}\mathbf{x} = \mathbf{b},$$

gegeben mit $\mathbf{x}, \mathbf{c} \in \mathbb{R}^n$, $\mathbf{b} \in \mathbb{R}^m$ und $\mathbf{A} \in \mathbb{R}^{m \times n}$.

Des Weiteren sei der zulässige Bereich $M = \{\mathbf{x} \in \mathbb{R}^n \mid \mathbf{A}\mathbf{x} = \mathbf{b}, \mathbf{x} \geq \mathbf{0}_n\}$ nichtleer.

Dann gelten:

- Entweder ist die Zielfunktion auf M nach unten unbeschränkt oder es existiert mindestens eine Optimallösung, darunter ist mindestens ein Eckpunkt von M .
- Ist M beschränkt, dann existiert eine Optimallösung $\hat{\mathbf{x}} \in M$ und $\hat{\mathbf{x}}$ ist optimal genau dann, wenn

$$\hat{\mathbf{x}} = \sum_{i=1}^N \lambda_i \mathbf{x}^i \quad \text{mit} \quad \sum_{i=1}^N \lambda_i = 1, \lambda_i \geq 0, i = 1, \dots, N. \quad (\text{Konvexkombination})$$

Aussage (b) motiviert das Simplex-Verfahren.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Wiederholung: Lineare
Optimierung

Active-Set-Methoden für
quadratische
Optimierungsprobleme

Zusammenfassung
- Ausblick und
Wiederholung

Notation:

Gegeben sei eine Indexmenge B .

Sei $\mathbf{x} \in \mathbb{R}^n$.

Dann ist \mathbf{x}_B der (Sub-)Vektor mit den Komponenten x_j ,
 $j \in B$.

Sei $A = (\mathbf{a}^1, \dots, \mathbf{a}^j, \dots, \mathbf{a}^n) \in \mathbb{R}^{m \times n}$.

Dann ist A_B die (Sub-)Matrix mit Spalten \mathbf{a}^j , $j \in B$.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Wiederholung: Lineare
Optimierung

Active-Set-Methoden für
quadratische
Optimierungsprobleme

Zusammenfassung
- Ausblick und
Wiederholung

Definition (Ecke als zulässige Basislösung)

Seien $A \in \mathbb{R}^{m \times n}$ mit $\text{Rang}(A) = m$, $\mathbf{b} \in \mathbb{R}^m$ und $M = \{\mathbf{x} \in \mathbb{R}^n \mid A\mathbf{x} = \mathbf{b}, \mathbf{x} \geq \mathbf{0}_n\}$ gegeben.

$\mathbf{x} \in M$ heißt **zulässige Basislösung** (Ecke, Basisvektor) **von M**, falls die Spalten von $A_{\tilde{B}}$ zu einer **Basis von x** , $\tilde{B} = \{j = \{1, \dots, n\} \mid x_j > 0\}$, linear unabhängig sind.

Man kann zeigen, dass dies zur geometrischen Definition einer Ecke äquivalent ist.

Erweitere $A_{\tilde{B}}$ zu einer $m \times m$ -Matrix A_B , setze $N := \{1, \dots, n\} \setminus B$,

$$\mathbf{b} = A\mathbf{x} = A_B\mathbf{x}_B + A_N\mathbf{x}_N \implies \mathbf{x}_B := A_B^{-1}\mathbf{b} - A_B^{-1}A_N\mathbf{x}_N.$$

Setze $\mathbf{x}_N = \mathbf{0}_{n-m}$. Falls $\mathbf{x}_B \geq \mathbf{0}_m$, ist \mathbf{x} zulässige Basislösung, ansonsten wähle andere linear unabhängige Spalten mit Indexmenge B .

Einführung

Unrestringierte
OptimierungWichtige Verfahren
der numerischen
OptimierungRestringierte
OptimierungBeispiele und theoretische
GrundlagenLagrange-Newton-
Verfahren

KKT-Bedingungen

SOP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Wiederholung: Lineare
OptimierungActive-Set-Methoden für
quadratische
OptimierungsproblemeZusammenfassung
- Ausblick und
Wiederholung

- Eine Menge der Form

$$M = \{\mathbf{x} \in \mathbb{R}^n \mid \mathbf{Ax} = \mathbf{b}, \mathbf{x} \geq \mathbf{0}_n\}$$

mit $A \in \mathbb{R}^{m \times n}$, $\mathbf{x} \in \mathbb{R}^n$, $\mathbf{b} \in \mathbb{R}^m$ heißt **Polyeder in Normalform**.

- Ein zulässiger Punkt $\mathbf{x} \in M$ heißt **Basisvektor** oder **zulässige Basislösung** von M , wenn eine aus m Elementen bestehende Indexmenge existiert, so dass die Spaltenvektoren \mathbf{a}^i mit $i \in B$ linear unabhängig sind und $x_j = 0$ für alle $j \notin B$.
- Hat A den Rang m , so gilt:
 - Die Basisvektoren sind die **Ecken** des Polyeders.
 - M besitzt mindestens einen und höchstens endlich viele Basisvektoren.
 - Die Lösung des linearen Optimierungsproblems $\min \mathbf{c}^\top \mathbf{x}$ in M ist einer der Basisvektoren.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Wiederholung: Lineare
Optimierung

Active-Set-Methoden für
quadratische
Optimierungsprobleme

Zusammenfassung
- Ausblick und
Wiederholung

Eckpunkte sind algebraisch charakterisiert über linear unabhängige Spalten von A

↪ Simplexverfahren (George B. Dantzig 1947)

Idee:

Gehe von Eckpunkt des zulässigen Bereichs zu benachbartem Eckpunkt

Minimiere dabei Zielfunktionswert

Iteriere bis optimaler Eckpunkt erreicht

Phasen:

- 0) Transformiere das vorliegende LOP auf primale Normalform.
- 1) Bestimme zulässige Basislösung (Ecke) \mathbf{x} mit Basisindexmenge B , Nichtbasismenge N , Basisvariable $\mathbf{x}_B \geq \mathbf{0}_m$ und Nichtbasisvariable $\mathbf{x}_N = \mathbf{0}_{n-m}$.
- 2) Bestimme solange Ecken \mathbf{x}^+ mit Indexmengen B^+ und N^+ bis Optimum erreicht oder entschieden werden kann, dass Problem keine Lösung hat.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Wiederholung: Lineare
Optimierung

Active-Set-Methoden für
quadratische
Optimierungsprobleme

Zusammenfassung
- Ausblick und
Wiederholung

Das Simplexverfahren als Active-Set-Methode

- Die Lösung des Optimierungsproblems ist theoretisch einfach: Man bestimmt alle Basisvektoren (jeweils als Lösung eines linearen Gleichungssystems der Größe $m \times m$), jeweils ihren Funktionswert und davon das Minimum. (Das LOP kann aber auch unbeschränkt sein.)
- Allerdings kann es exponentiell viele Basisvektoren geben, z.B. hat der Einheitswürfel in \mathbb{R}^n bereits 2^n Ecken.
- Bei einem Basisvektor sind m der Ungleichungs-Nebenbedingungen inaktiv und die übrigen $n - m$ aktiv.
- Die Indexmengen N der aktiven und B der inaktiven Nebenbedingungen sollen in jedem Schritt so verändert werden, dass die Lösung nach wenigen Schritten gefunden wird. Dabei wird immer eine Bedingung aktiv und dafür eine andere inaktiv.
- Die Basismatrix A_B besteht aus den zu B gehörenden Spalten von A , die Nichtbasismatrix A_N aus den übrigen.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Wiederholung: Lineare
Optimierung

Active-Set-Methoden für
quadratische
Optimierungsprobleme

Zusammenfassung
- Ausblick und
Wiederholung

Herleitung eines Simplex-Schritts (1)

Sei \mathbf{x} eine Basislösung und $\mathbf{z} = (\mathbf{z}_B, \mathbf{z}_N)^\top$ ein beliebiger zulässiger Punkt. Es sollen

$$\mathbf{c}^\top \mathbf{x} \quad \text{und} \quad \mathbf{c}^\top \mathbf{z}$$

verglichen werden. Dazu erhält man aus $A\mathbf{z} = \mathbf{b}$ zunächst

$$A_B \mathbf{z}_B + A_N \mathbf{z}_N = \mathbf{b}$$

und daraus

$$\mathbf{z}_B = A_B^{-1} \mathbf{b} - A_B^{-1} A_N \mathbf{z}_N.$$

Daraus folgt:

$$\begin{aligned} \mathbf{c}^\top \mathbf{z} &= \mathbf{c}_B^\top \mathbf{z}_B + \mathbf{c}_N^\top \mathbf{z}_N \\ &= \mathbf{c}_B^\top (A_B^{-1} \mathbf{b} - A_B^{-1} A_N \mathbf{z}_N) + \mathbf{c}_N^\top \mathbf{z}_N \\ &= \mathbf{c}_B^\top \mathbf{x}_B + (\mathbf{c}_N^\top - \mathbf{c}_B^\top A_B^{-1} A_N) \mathbf{z}_N \\ &= \mathbf{c}^\top \mathbf{x} + \underbrace{(\mathbf{c}_N - A_N^\top (A_B^\top)^{-1} \mathbf{c}_B)^\top}_{\mathbf{u}_N} \mathbf{z}_N \end{aligned}$$

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Wiederholung: Lineare
Optimierung

Active-Set-Methoden für
quadratische
Optimierungsprobleme

Zusammenfassung
- Ausblick und
Wiederholung

Herleitung eines Simplex-Schritts (2)

Der Vektor \mathbf{u}_N (Kostenänderung) berechnet sich durch Lösen von

$$A_B^\top \mathbf{y} = \mathbf{c}_B$$

und dann (mit \mathbf{a}^j , der j -ten Spalte von A) durch

$$u_j = c_j - (\mathbf{a}^j)^\top \mathbf{y} \quad \text{für } j \in N.$$

Sind alle $u_j \geq 0$, so ist \mathbf{x} das gesuchte Minimum. Falls nicht, ersetzt man ein $q \in N$ mit $u_q < 0$ folgendermaßen:

$$x_q^+ = t \geq 0 \quad \text{und} \quad x_j^+ = 0 \quad \text{für alle } j \in N \setminus \{q\}.$$

Einsetzen in $A\mathbf{x}^+ = \mathbf{b}$ liefert $A_B \mathbf{x}_B^+ + t \mathbf{a}_q = \mathbf{b}$ und damit

$$\mathbf{x}_B^+ = \mathbf{x}_B - t A_B^{-1} \mathbf{a}^q$$

Dazu löst man zunächst $A_B \mathbf{d} = \mathbf{a}^q$.

Herleitung eines Simplex-Schritts (3)

Gilt $d_i \leq 0$ für alle $i \in I$, so ist das Problem nicht lösbar.
Ansonsten erfordert die Bedingung $\mathbf{x}^+ \geq \mathbf{0}_n$

$$x_i - t \cdot d_i \geq 0 \quad \text{für } i \in B \text{ mit } d_i > 0$$

und $t \geq 0$. Damit diese Bedingung erfüllt ist, wählt man

$$t = \min_{i \in B, d_i > 0} \frac{x_i}{d_i} = \frac{x_p}{d_p}.$$

Damit ist $x_p = 0$ und man entfernt q aus B und fügt es in N hinzu.

Wegen

$$\mathbf{c}^T \mathbf{x}^+ = \mathbf{c}^T \mathbf{x} + t \cdot u_q$$

ist

$$\mathbf{c}^T \mathbf{x}^+ \leq \mathbf{c}^T \mathbf{x}.$$

Falls \mathbf{x} nicht degeneriert ist, gilt sogar $<$.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen
SQP-Verfahren

Penalty- und
Barriere-Methoden

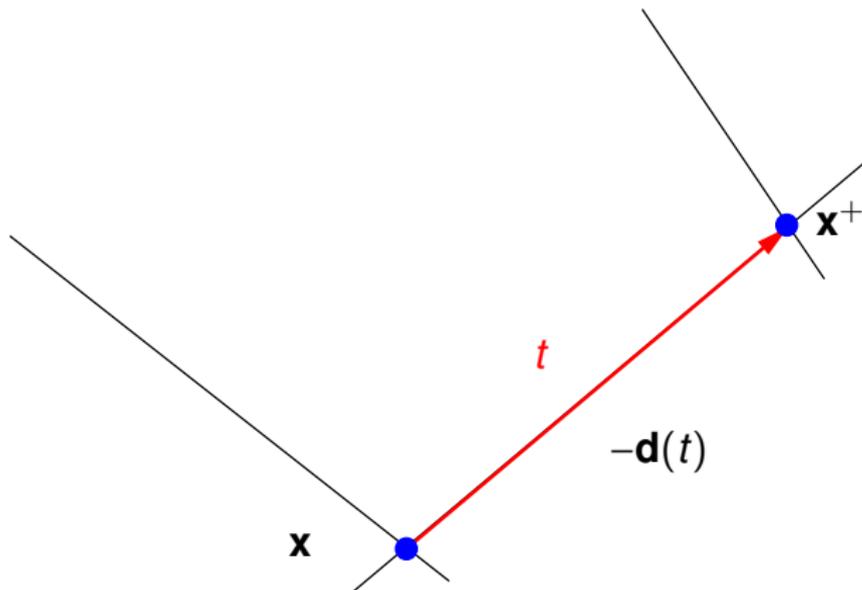
Active-Set-Methoden

Wiederholung: Lineare
Optimierung

Active-Set-Methoden für
quadratische
Optimierungsprobleme

Zusammenfassung
- Ausblick und
Wiederholung

Idee des Basiswechsels beim Simplex



Es wird entlang einer Kantenhalbgerade $\mathbf{z}(t) = \mathbf{x} - t\mathbf{d}$, mit Suchrichtung $-\mathbf{d}$ und Schrittweite $t \geq 0$ gesucht, so dass die Zielfunktion monoton fällt.

Simplex-Algorithmus (1)

- 1 Starte mit einem Basisvektor $\mathbf{x}^{[0]} \in M$ mit Indexmenge $B^{[0]}$,
 $N^{[0]} = \{1, \dots, n\} \setminus B^{[0]}$.
Setze $A_B^{[0]} = (\mathbf{a}^j)_{j \in B^{[0]}}$ und $k = 0$.
- 2 Löse das lineare Gleichungssystem $(A_B^{[k]})^\top \mathbf{y} = \mathbf{c}_{B^{[k]}}$.
- 3 Berechne $\zeta_j^{[k]} = -u_j^{[k]} = -c_j + (\mathbf{a}^j)^\top \mathbf{y}$, $j \in N^{[k]}$.
- 4 Falls $\zeta_j^{[k]} \leq 0$ für alle $j \in N^{[k]}$: Ende (Minimum gefunden)
- 5 Wähle $q^{[k]} \in N^{[k]}$ mit $\zeta_{q^{[k]}}^{[k]} > 0$. (q Index Pivotspalte)
- 6 Löse das lineare Gleichungssystem $A_B^{[k]} \mathbf{d}^{[k]} = \mathbf{a}^{q^{[k]}}$
- 7 Falls $d_i^{[k]} \leq 0$ für alle $i \in B^{[k]}$: Ende (kein Minimum)
- 8 Bestimme $t^{[k]}$ und $p^{[k]} \in B^{[k]}$ mit $d_{p^{[k]}}^{[k]} > 0$ aus:

$$t^{[k]} = \min_{i \in B^{[k]}, d_i^{[k]} > 0} \frac{x_i^{[k]}}{d_i^{[k]}} = \frac{x_{p^{[k]}}^{[k]}}{d_{p^{[k]}}^{[k]}}$$

(p Index Pivotzeile)

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Wiederholung: Lineare
Optimierung

Active-Set-Methoden für
quadratische
Optimierungsprobleme

Zusammenfassung
- Ausblick und
Wiederholung

9 Berechne

$$x_i^{[k+1]} = \begin{cases} x_i^{[k]} - t^{[k]} d_i^{[k]} & \text{falls } i \in B^{[k]}, i \neq p^{[k]} \\ t^{[k]} & \text{falls } i = q^{[k]} \\ 0 & \text{sonst} \end{cases}$$

und

$$B^{[k+1]} = (I^{[k]} \cup \{q^{[k]}\}) \setminus \{p^{[k]}\}$$

$$N^{[k+1]} = \{1, \dots, n\} \setminus B^{[k+1]}$$

$$A_B^{[k+1]} = (\mathbf{a}^i)_{i \in B^{[k+1]}}$$

10 Setze $k := k + 1$ und gehe zu 2.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Wiederholung: Lineare
Optimierung

Active-Set-Methoden für
quadratische
Optimierungsprobleme

Zusammenfassung
- Ausblick und
Wiederholung

- **Wahl des Start-Basisvektors:** Entweder durch Schlupfvariablen (bei vorheriger Transformation des Problems auf Standardform) oder durch Lösen des linearen Hilfsproblems $\min \sum_{i=1}^m z_i$ unter der Nebenbedingung

$$\mathbf{Ax} + \mathbf{z} = \mathbf{b} \quad , \quad x_1, \dots, x_n, z_1, \dots, z_m \geq 0$$

mit Startwert $(\mathbf{x}, \mathbf{z})^\top = (\mathbf{0}_n, \mathbf{b})^\top$ (oBdA: $\mathbf{b} \geq 0$).

- **Wahl von $\mathbf{q}^{[k]}$:** Entweder durch

$$\zeta_{\mathbf{q}^{[k]}}^{[k]} = \max_{j \in N^{[k]}} \zeta_j^{[k]}$$

oder (zur Vermeidung von Zyklen bei entarteten Basisvektoren) durch die Wahl des kleinstmöglichen $\mathbf{q}^{[k]} \in N^{[k]}$ in Schritt 5 sowie des kleinstmöglichen $\mathbf{p}^{[k]} \in B^{[k]}$ in Schritt 8.

- **Berechnen von $\mathbf{d}^{[k]}$ und $\mathbf{y}^{[k]}$:** Kein Lösen der Gleichungssysteme, sondern Rang-1-Updates mit der Sherman-Morrison-Woodbury-Formel.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Wiederholung: Lineare
Optimierung

Active-Set-Methoden für
quadratische
Optimierungsprobleme

Zusammenfassung
- Ausblick und
Wiederholung

Das primale Simplexverfahren - Algorithmus (für manuelle Rechnung)

Algorithmus (*Primales Simplexverfahren für Tableau*)

- (0) Phase 1:
Bestimme zulässige Basislösung x mit Indexmengen B , N , Basismatrix A_B , Nichtbasismatrix A_N , Basisvariable $x_B \geq 0$ und Nichtbasisvariable $x_N = 0$ der primalen Normalform.
- (1) Zwischenwerte:
Berechne $\Gamma_B^N := A_B^{-1} A_N$, $\beta_B := A_B^{-1} b$ und die negativen reduzierten Kosten $\zeta_N^T := c_B^T \Gamma_B^N - c_N^T$.
- (2) Überprüfung der Optimalität:
Falls $\zeta_j \leq 0$ für alle $j \in N$ gilt, so beende das Verfahren. Die aktuelle Basislösung $x_B = \beta_B$, $x_N = 0$ ist optimal. Der Zielfunktionswert ist $\delta = c_B^T \beta_B$.
- (3) Überprüfung auf Unbeschränktheit:
Gibt es einen Index q mit $\zeta_q > 0$ und $\gamma_{iq} \leq 0$ für alle $i \in B$, so besitzt das Problem keine Lösung, STOP.
- (4) Bestimmung des Pivotelements:
Wähle einen Index q (für Pivotspalte) mit $\zeta_q > 0$. ($d_j = \gamma_{iq}$, $i \in B$)
Wähle einen Index p (für Pivotzeile) mit $\frac{\beta_p}{\gamma_{pq}} = \min \left\{ \frac{\beta_i}{\gamma_{iq}} \mid \gamma_{iq} > 0, i \in B \right\}$.
- (5) Basiswechsel durchführen:
Setze $B := (B \setminus \{p\}) \cup \{q\}$, $N := (N \setminus \{q\}) \cup \{p\}$.
- (6) Gehe zu (1).

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Wiederholung: Lineare
Optimierung

Active-Set-Methoden für
quadratische
Optimierungsprobleme

Zusammenfassung
- Ausblick und
Wiederholung

Der Basiswechsel muss so erfolgen, dass zumindest:

$$Ax = b, x \geq 0 \Rightarrow Ax^+ = b, x^+ \geq 0 \quad (\text{Zulässigkeit}),$$

$$c^T x^+ \leq c^T x \quad (\text{Abstieg im Zielfunktionswert}).$$

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Wiederholung: Lineare
Optimierung

Active-Set-Methoden für
quadratische
Optimierungsprobleme

Zusammenfassung
- Ausblick und
Wiederholung

$$x_B = (A_B)^{-1}b - (A_B)^{-1}A_N x_N =: \beta_B - \Gamma_B^N x_N,$$

$$c^T x = c_B^T x_B + c_N^T x_N = c_B^T \beta_B - (c_B^T \Gamma_B^N - c_N^T) x_N =: \delta - \zeta_N^T x_N$$

fasst man zusammen in einem Tableau:

	x_N		
x_B	$\Gamma_B^N = (A_B)^{-1}A_N$	$\beta_B = (A_B)^{-1}b$	$\frac{\beta_B}{\Gamma_B^N}$
	$\zeta_N^T = c_B^T \Gamma_B^N - c_N^T$	$c_B^T x_B$	

Neuberechnung des Tableaus in jedem Schritt aufwendig

Der Tableaueinhalt für die neue Basis zur Indexmenge B^+ ergibt sich aus dem alten Tableaueinhalt (mit Daten γ_{ij} , β_i , ζ_j) nach folgendem Schema:

	$x_j, j \in N \setminus \{q\}$	x_p	
$x_i, i \in B \setminus \{p\}$	$\gamma_{ij} - \frac{\gamma_{iq}\gamma_{pj}}{\gamma_{pq}}$	$-\frac{\gamma_{iq}}{\gamma_{pq}}$	$\beta_i - \frac{\gamma_{iq}\beta_p}{\gamma_{pq}}$
x_q	$\frac{\gamma_{pj}}{\gamma_{pq}}$	$\frac{1}{\gamma_{pq}}$	$\frac{\beta_p}{\gamma_{pq}}$
	$\zeta_j - \frac{\zeta_q\gamma_{pj}}{\gamma_{pq}}$	$-\frac{\zeta_q}{\gamma_{pq}}$	$\delta - \frac{\zeta_q\beta_p}{\gamma_{pq}}$

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Wiederholung: Lineare
Optimierung

Active-Set-Methoden für
quadratische
Optimierungsprobleme

Zusammenfassung
- Ausblick und
Wiederholung

- Pro Iterationsschritt beträgt der Rechenaufwand $O(n^2)$.
- Eine obere Schranke für die Anzahl der Ecken und damit der Iterationen ist $\binom{n}{m}$, die Anzahl der m -elementigen Teilmengen von n .
- Das Simplex-Verfahren konvergiert meist sehr schnell (in $O(n)$ Iterationen), aber es gibt Beispiele (z.B. von Klee und Minty), in denen fast alle Ecken durchlaufen werden.
- 1984: Veröffentlichung der Interior Point Method von N. Karmakar mit polynomialem Rechenaufwand als Alternative zum Simplex-Verfahren

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Wiederholung: Lineare
Optimierung

Active-Set-Methoden für
quadratische
Optimierungsprobleme

Zusammenfassung
- Ausblick und
Wiederholung

Beispiel von Klee und Minty

3-dimensional:

$$\text{Maximiere} \quad 100x_1 + 10x_2 + x_3$$

unter den Nebenbedingungen

$$x_1 \leq 1$$

$$20x_1 + x_2 \leq 100$$

$$200x_1 + 20x_2 + x_3 \leq 10000$$

$$x_1, x_2, x_3 \geq 0$$

n-dimensional:

$$\text{Maximiere} \quad \sum_{j=1}^n 10^{n-j} x_j$$

unter den Nebenbedingungen

$$2 \sum_{j=1}^{i-1} 10^{i-j} x_j + x_i \leq 100^{i-1} \quad \text{für } 1 \leq i \leq n$$

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Wiederholung: Lineare
Optimierung

Active-Set-Methoden für
quadratische
Optimierungsprobleme

Zusammenfassung
- Ausblick und
Wiederholung

Active-Set-Methoden für quadratische Optimierungsprobleme

Quadratische nichtlineare Optimierung

Ein **quadratisches Optimierungsproblem** mit linearen Restriktionen hat die Form

$$\min_{\mathbf{x} \in \mathbb{R}^n} f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^T \mathbf{Q} \mathbf{x} + \mathbf{q}^T \mathbf{x} + c$$

unter den Nebenbedingungen

$$\mathbf{G} \mathbf{x} = \mathbf{b} \quad \text{und} \quad \mathbf{U} \mathbf{x} \leq \mathbf{r}.$$

Dabei ist $\mathbf{Q} \in \mathbb{R}^{n \times n}$ symmetrisch und

$$\mathbf{x}, \mathbf{q} \in \mathbb{R}^n, c \in \mathbb{R}, \mathbf{G} \in \mathbb{R}^{m \times n}, \mathbf{b} \in \mathbb{R}^m, \mathbf{U} \in \mathbb{R}^{p \times n}, \mathbf{r} \in \mathbb{R}^p.$$

Sind Nebenbedingungen der Form $\mathbf{U} \mathbf{x} \leq \mathbf{r}$ vorhanden, hat das restringierte quadratische Problem Gleichungs- und Ungleichungsnebenbedingungen, falls nicht, nur Gleichungsnebenbedingungen.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Wiederholung: Lineare
Optimierung

Active-Set-Methoden für
quadratische
Optimierungsprobleme

Zusammenfassung
- Ausblick und
Wiederholung

KKT-Bedingungen für quadratische Optimierungsprobleme

Lagrange-Funktion:

$$L(\mathbf{x}, \lambda, \mu) = \frac{1}{2} \mathbf{x}^T Q \mathbf{x} + \mathbf{q}^T \mathbf{x} + c + \lambda^T (U \mathbf{x} - \mathbf{r}) + \mu^T (G \mathbf{x} - \mathbf{b})$$

Gleichungsbedingungen:

- $Q \mathbf{x} + \mathbf{q} + G^T \mu = \mathbf{0}_n$
- $G \mathbf{x} = \mathbf{b}$

Gleichungs- und Ungleichungsbedingungen:

- $Q \mathbf{x} + \mathbf{q} + G^T \mu + U^T \lambda = \mathbf{0}_n$
- $G \mathbf{x} = \mathbf{b}$
- $U \mathbf{x} \leq \mathbf{r}$
- $\lambda_i \geq 0$ für $i = 1, \dots, p$
- $(\mathbf{u}_i \mathbf{x} - r_i) \lambda_i = 0$ für $i = 1, \dots, p$

(Dabei bezeichnet \mathbf{u}_i die i -te Zeile von U .)

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen
SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Wiederholung: Lineare
Optimierung

Active-Set-Methoden für
quadratische
Optimierungsprobleme

Zusammenfassung
- Ausblick und
Wiederholung

Minimierung unter linearen Gleichungsrestriktionen

Die Optimalitätsbedingungen 2. Ordnung besagen, dass eine Lösung des KKT-Systems ein globales Minimum von f ist, wenn Q positiv definit auf dem Kern von G ist und der Rang von G gleich m ist.

Die Lösung des KKT-Systems erhält man durch Lösen des linearen Gleichungssystems

$$\begin{pmatrix} Q & G^T \\ G & 0 \end{pmatrix} \begin{pmatrix} \mathbf{x} \\ \boldsymbol{\mu} \end{pmatrix} = \begin{pmatrix} -\mathbf{q} \\ \mathbf{b} \end{pmatrix}$$

Möglichkeiten der Lösung:

- Gauß-Algorithmus
- Nullraum-Methode
- Schur-Komplement-Methode

Einführung

Unrestringierte Optimierung

Wichtige Verfahren der numerischen Optimierung

Restringierte Optimierung

Beispiele und theoretische Grundlagen

Lagrange-Newton-Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und Barriere-Methoden

Active-Set-Methoden

Wiederholung: Lineare Optimierung

Active-Set-Methoden für quadratische Optimierungsprobleme

Zusammenfassung - Ausblick und Wiederholung

Beispiel (1)

Aufgabe: Minimiere die Funktion

$$f(\mathbf{x}) = 3x_1^2 + 2x_1x_2 + x_1x_3 + 2.5x_2^2 + 2x_2x_3 + 2x_3^2 - 8x_1 - 3x_2 - 3x_3$$

mit den Nebenbedingungen

$$x_1 + x_3 = 3,$$

$$x_2 + x_3 = 0.$$

Man erhält:

$$Q = \begin{pmatrix} 6 & 2 & 1 \\ 2 & 5 & 2 \\ 1 & 2 & 4 \end{pmatrix}, \quad \mathbf{q} = \begin{pmatrix} -8 \\ -3 \\ -3 \end{pmatrix}, \quad G = \begin{pmatrix} 1 & 0 & 1 \\ 0 & 1 & 1 \end{pmatrix}, \quad \mathbf{b} = \begin{pmatrix} 3 \\ 0 \end{pmatrix}$$

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Wiederholung: Lineare
Optimierung

Active-Set-Methoden für
quadratische
Optimierungsprobleme

Zusammenfassung
- Ausblick und
Wiederholung

Beispiel (2)

Die KKT-Bedingungen ergeben das Gleichungssystem:

$$\begin{pmatrix} 6 & 2 & 1 & 1 & 0 \\ 2 & 5 & 2 & 0 & 1 \\ 1 & 2 & 4 & 1 & 1 \\ 1 & 0 & 1 & 0 & 0 \\ 0 & 1 & 1 & 0 & 0 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ x_3 \\ \mu_1 \\ \mu_2 \end{pmatrix} = \begin{pmatrix} 8 \\ 3 \\ 3 \\ 3 \\ 0 \end{pmatrix}$$

Daraus erhält man die Lösungen:

$$\hat{\mathbf{x}} = (2, -1, 1)^T \quad \text{und} \quad \boldsymbol{\mu} = (-3, 2)^T$$

Nachteil des Gauß-Algorithmus:

- Kein Ausnutzen der Symmetrie (\Rightarrow symmetrische indefinite Zerlegung verwenden)
- Rechenaufwand: $O((n + m)^3)$

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Wiederholung: Lineare
Optimierung

Active-Set-Methoden für
quadratische
Optimierungsprobleme

Zusammenfassung
- Ausblick und
Wiederholung

Minimierung unter linearen Ungleichungsrestriktionen

Hauptschwierigkeit:

- Herausfinden, welche Ungleichungsbedingungen aktiv sind

Idee:

- Schätze eine Menge aktiver Bedingungen durch Bestimmung eines zulässigen Punktes
- Löse das zugehörige (Hilfs-)Optimierungsproblem mit Gleichungsnebenbedingungen
- Füge (abhängig von der Lösung) entweder eine inaktive Nebenbedingung zu den aktiven hinzu oder entferne eine aktive Nebenbedingung
- Wiederhole die beiden letzten Schritte, bis ein Minimum gefunden ist

Die *Active-Set-Methode* gehört zu den *Verfahren zulässiger Richtungen*, weil in jedem Schritt ein zulässiger Punkt und eine zulässige Abstiegsrichtung bestimmt werden.

Einführung

Unrestringierte Optimierung

Wichtige Verfahren der numerischen Optimierung

Restringierte Optimierung

Beispiele und theoretische Grundlagen

Lagrange-Newton-Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und Barriere-Methoden

Active-Set-Methoden

Wiederholung: Lineare Optimierung

Active-Set-Methoden für quadratische Optimierungsprobleme

Zusammenfassung
- Ausblick und Wiederholung

Minimiere die Funktion

$$f(\mathbf{x}) = \frac{1}{2}x_1^2 + \frac{1}{2}x_2^2 + x_1 + x_2$$

mit den Nebenbedingungen

$$-x_1 - x_2 \leq 0,$$

$$x_2 \leq 2,$$

$$x_1 + x_2 \leq 5,$$

$$-x_1 + x_2 \leq 2,$$

$$x_1 \leq 5,$$

$$-x_2 \leq 1.$$

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Wiederholung: Lineare
Optimierung

Active-Set-Methoden für
quadratische
Optimierungsprobleme

Zusammenfassung
- Ausblick und
Wiederholung

Bestimmung des Hilfsproblems

- Zu einem zulässigen Punkt $\mathbf{x}^{[k]}$ sucht man eine zulässige Abstiegsrichtung $\mathbf{d}^{[k]}$ durch Lösen eines quadratischen Hilfsproblems $\min f(\mathbf{x}^{[k]} + \mathbf{d})$ bzgl. $\mathbf{d} \in \mathbb{R}^n$ mit Gleichungs-Nebenbedingungen $G\mathbf{x} = \mathbf{b}$ und $U^{[k]}\mathbf{x} = \mathbf{r}^{[k]}$ (alle aktiven Ungleichungsnebenbedingungen).
- Dieses Problem löst man durch Umformen des KKT-Systems

$$\begin{pmatrix} Q & G^T & (U^{[k]})^T \\ G & 0 & 0 \\ U^{[k]} & 0 & 0 \end{pmatrix} \begin{pmatrix} \mathbf{x}^{[k]} + \mathbf{d}^{[k]} \\ \boldsymbol{\mu} \\ \boldsymbol{\lambda}^{[k]} \end{pmatrix} = \begin{pmatrix} -\mathbf{q} \\ \mathbf{b} \\ \mathbf{r}^{[k]} \end{pmatrix}$$

zu

$$\begin{pmatrix} Q & G^T & (U^{[k]})^T \\ G & 0 & 0 \\ U^{[k]} & 0 & 0 \end{pmatrix} \begin{pmatrix} \mathbf{d}^{[k]} \\ \boldsymbol{\mu} \\ \boldsymbol{\lambda}^{[k]} \end{pmatrix} = \begin{pmatrix} -\nabla f(\mathbf{x}^{[k]})^T \\ \mathbf{0} \\ \mathbf{0} \end{pmatrix}.$$

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Wiederholung: Lineare
Optimierung

Active-Set-Methoden für
quadratische
Optimierungsprobleme

Zusammenfassung
- Ausblick und
Wiederholung

Vier mögliche Ergebnisse des Hilfsproblems

- 1 $\mathbf{d}^{[k]} = \mathbf{0}_n$ und $\lambda^{[k]} \geq \mathbf{0}$:
KKT-Bedingungen des eigentlichen Problems erfüllt.
- 2 $\mathbf{d}^{[k]} = \mathbf{0}_n$ und $\lambda_m = \min_{i \in N} \lambda_i^{[k]} < 0$:
Kein KKT-Punkt des eigentlichen Problems, keine
weitere Minimierung mit diesen aktiven
Ungleichungen möglich.
 \Rightarrow Entferne eine aktive Nebenbedingung aus N .
- 3 $\mathbf{d}^{[k]} \neq \mathbf{0}_n$ und $\mathbf{x}^{[k]} + \mathbf{d}^{[k]}$ zulässig:
Akzeptieren des neuen Punktes und Beibehalten der
Indexmenge
- 4 $\mathbf{d}^{[k]} \neq \mathbf{0}_n$ und $\mathbf{x}^{[k]} + \mathbf{d}^{[k]}$ nicht zulässig:
Eine inaktive Ungleichung wird jetzt verletzt.
 \Rightarrow Reduziere die Schrittweite, so dass man einen
zulässigen Punkt erhält.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Wiederholung: Lineare
Optimierung

Active-Set-Methoden für
quadratische
Optimierungsprobleme

Zusammenfassung
- Ausblick und
Wiederholung

Active-Set-Methode für quadratische Probleme (1)

- 1 Berechne einen zulässigen Startpunkt $\mathbf{x}^{[0]}$ und bestimme die Matrix $U^{[0]}$, deren Zeilen \mathbf{u}_i die aktiven Ungleichungsnebenbedingungen sind.
Setze $N = \{i \mid \mathbf{u}_i \mathbf{x}^{[0]} = r_i^{[0]}\}$ und $k = 0$.
- 2 Löse das quadratische Hilfsproblem:

$$\begin{pmatrix} Q & G^T & (U^{[k]})^T \\ G & 0 & 0 \\ U^{[k]} & 0 & 0 \end{pmatrix} \begin{pmatrix} \mathbf{d}^{[k]} \\ \boldsymbol{\mu} \\ \boldsymbol{\lambda}^{[k]} \end{pmatrix} = \begin{pmatrix} -\nabla f(\mathbf{x}^{[k]})^T \\ 0 \\ 0 \end{pmatrix}$$

- 3 Falls $\mathbf{d}^{[k]} = \mathbf{0}_n$ und $\boldsymbol{\lambda}^{[k]} \geq \mathbf{0}$, Ende des Verfahrens.
- 4 Falls $\mathbf{d}^{[k]} = \mathbf{0}_n$ und $\lambda_q = \min_{i \in N} \lambda_i^{[k]} < 0$, setze $N = N \setminus \{q\}$ und bestimme $U^{[k+1]}$ aus $U^{[k]}$ durch Streichen der entsprechenden Zeile.
Setze $\mathbf{x}^{[k+1]} = \mathbf{x}^{[k]}$, $k = k + 1$ und gehe zu 2.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Wiederholung: Lineare
Optimierung

Active-Set-Methoden für
quadratische
Optimierungsprobleme

Zusammenfassung
- Ausblick und
Wiederholung

Active-Set-Methode für quadratische Probleme (2)

- 5 Falls $\mathbf{d}^{[k]} \neq \mathbf{0}_n$ und $\mathbf{x}^{[k]} + \mathbf{d}^{[k]}$ zulässig, setze $\mathbf{x}^{[k+1]} = \mathbf{x}^{[k]} + \mathbf{d}^{[k]}$, $U^{[k+1]} = U^{[k]}$, $k = k + 1$ und gehe zu 2.
- 6 Falls $\mathbf{d}^{[k]} \neq \mathbf{0}_n$ und $\mathbf{x}^{[k]} + \mathbf{d}^{[k]}$ nicht zulässig, berechne

$$t^{[k]} = \frac{r_p - \mathbf{u}_p \mathbf{x}^{[k]}}{\mathbf{u}_p \mathbf{d}^{[k]}} = \min_{i \in N \text{ mit } \mathbf{u}_i \mathbf{d}^{[k]} > 0} \frac{r_i - \mathbf{u}_i \mathbf{x}^{[k]}}{\mathbf{u}_i \mathbf{d}^{[k]}},$$
$$\mathbf{x}^{[k+1]} = \mathbf{x}^{[k]} + t^{[k]} \mathbf{d}^{[k]},$$
$$N = N \cup \{p\}.$$

Setze $k = k + 1$ und gehe zu 2.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Wiederholung: Lineare
Optimierung

Active-Set-Methoden für
quadratische
Optimierungsprobleme

Zusammenfassung
- Ausblick und
Wiederholung

- Unter der Voraussetzung, dass Q positiv definit für alle

$\mathbf{x} \in \text{Kern}(G)$ ist und dass alle Zeilen von $\begin{pmatrix} G \\ U \end{pmatrix}$ linear

unabhängig sind, bestimmt die Active-Set-Methode in endlich vielen Schritten die eindeutig bestimmte Lösung des Optimierungsproblems.

- Wie beim Simplex-Verfahren gibt es exponentiell in n viele Möglichkeiten, die aktiven Nebenbedingungen zu bestimmen (Worst-Case-Komplexität). In der Praxis erhält man jedoch meist ein sehr viel besseres Verhalten.
- Als zusätzliches Abbruchkriterium sollte aber in jedem Fall eine maximale Anzahl an Schritten vorgegeben werden.
- Den Startwert $\mathbf{x}^{[0]}$ berechnet man beispielsweise mit Phase 1 des Simplex-Verfahrens.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Wiederholung: Lineare
Optimierung

Active-Set-Methoden für
quadratische
Optimierungsprobleme

Zusammenfassung
- Ausblick und
Wiederholung

- Entwicklung der ersten Active-Set-Methode von Fletcher (1971)
- Implementierung der Methode von Gill und Murray (1978) in Matlab
- Innere-Punkt-Methoden besitzen polynomielle Worst-Case-Komplexität und sind daher für sehr große Probleme meist besser geeignet. In Matlab ist der Algorithmus von Gould und Toint (2004) implementiert.

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Beispiele und theoretische
Grundlagen

Lagrange-Newton-
Verfahren

KKT-Bedingungen

SQP-Verfahren

Penalty- und
Barriere-Methoden

Active-Set-Methoden

Wiederholung: Lineare
Optimierung

Active-Set-Methoden für
quadratische
Optimierungsprobleme

Zusammenfassung
- Ausblick und
Wiederholung

- 1 Einführung
- 2 Unrestringierte Optimierung
- 3 Wichtige Verfahren der numerischen Optimierung
- 4 Restringierte Optimierung
- 5 Zusammenfassung - Ausblick und Wiederholung
 - Aus- und Einblick: Maschinelles Lernen, Data Science
 - Aus- und Einblick: Optimalsteuerung
 - Weiterer Ausblick
 - Quellen

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

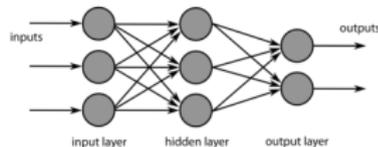
Aus- und Einblick:
Maschinelles Lernen, Data
Science

Aus- und Einblick:
Optimalsteuerung

Weiterer Ausblick
Quellen

Maschinelles Lernen, Data Science: Überblick

- **Machine Learning**
 - Unüberwachtes Lernen
erzeugt zu Daten statistisches Modell
Z.B. Hidden Markov Model (HMM), Hauptkomponentenanalyse
 - Überwachtes Lernen
Z.B. *Support Vector Machine*, *Reinforcement Learning*, *Active Learning*
(benutze Abfragen)
- **Data-mining (Statistical Learning):**
Auffinden neuer Gesetzmäßigkeiten
 - auch hier ML-Algorithmen
 - **Regression**
- **Deep learning**
 - Klasse "künstlicher neuronaler Netze"
 - **Hidden Layers** zwischen Ein- und Ausgabeschicht
 - zu unterscheiden von biologischen neuronalen Netzen und deren Simulation



Quelle: Wikipedia

Einführung

Unrestringierte
Optimierung

Wichtige Verfahren
der numerischen
Optimierung

Restringierte
Optimierung

Zusammenfassung
- Ausblick und
Wiederholung

Aus- und Einblick:
Maschinelles Lernen, Data
Science

Maschinelles Lernen

Lineare

Ausgleichsrechnung

Support Vector Machines

Neuronale Netze

Reinforcement Learning

Aus- und Einblick:
Optimalsteuerung

Weiterer Ausblick

Quellen