


Skript zur Vorlesung

# Optimierung



gelesen von

Prof. Dr. S. Volkwein

Konstanz, Sommersemester 2009

# Inhaltsverzeichnis

<b>1</b>	<b>Einleitung</b>	<b>3</b>
<b>2</b>	<b>Optimalitätskriterien</b>	<b>4</b>
2.1	Allgemeiner Fall . . . . .	4
2.2	Konvexe Funktionen . . . . .	7
<b>3</b>	<b>Allgemeine Abstiegsverfahren und Schrittweitenstrategien</b>	<b>9</b>
3.1	Global konvergente Abstiegsverfahren . . . . .	10
3.2	Schrittweitenstrategien und -algorithmen . . . . .	11
3.2.1	Die Armijo-Regel . . . . .	11
3.2.2	Die Wolfe-Powell-Regel . . . . .	12
3.2.3	Strenge Wolfe-Powell-Regel . . . . .	14
3.3	Praktische Aspekte . . . . .	15
<b>4</b>	<b>Gradientenverfahren</b>	<b>16</b>
<b>5</b>	<b>Das Newton-Verfahren</b>	<b>18</b>
5.1	Das lokale Verfahren . . . . .	18
5.2	Inexakte Newton-Verfahren . . . . .	21
5.3	Globale Konvergenz . . . . .	22
5.3.1	Trust-Region-Methoden . . . . .	22
5.3.2	Globale Konvergenz des Trust-Region-Verfahrens . . . . .	24
<b>6</b>	<b>Quasi-Newton-Verfahren</b>	<b>26</b>
	<b>Index</b>	<b>29</b>
	<b>Literatur</b>	<b>30</b>

# 1 Einleitung

Unter einem *endlichdimensionalen Optimierungsproblem* verstehen wir folgende Aufgabe:

$$\begin{cases} \text{Gegeben seien eine Menge } X \subseteq \mathbb{R}^n \text{ und eine stetige Funktion } f : X \rightarrow \mathbb{R}. \\ \text{Gesucht wird ein } x^* \in X \text{ mit } \forall x \in X : f(x^*) \leq f(x) \end{cases} . \quad (1.1)$$

In Kurznotation:

$$\min f(x) \text{ u.d.N. } x \in X \quad \text{bzw.} \quad \min_{x \in X} f(x). \quad (1.2)$$

Ist  $X = \mathbb{R}^n$ , so heißt (1.1) bzw. (1.2) *unrestringiert*, andernfalls *restringiert*.

Im Allgemeinen nennt man  $X$  den *Zulässigkeitsbereich* und  $f$  die *Zielfunktion*.

## BEMERKUNG 1.1

Soll  $f$  maximiert werden für  $x \in X$ , so ist dies gleichbedeutend damit, dass  $-f$  minimiert wird u.d.N.  $x \in X$ .  $\blacklozenge$

Die Aufgabenstellung (1.1) erhält ihre Bedeutung dadurch, dass sie ein mathematisches Modell für viele Probleme zum Beispiel in der Physik, Medizin, Ökonomie und den Ingenieurwissenschaften ist.

Für den Fall, dass  $X \neq \mathbb{R}^n$ , lässt sich der Zulässigkeitsbereich sehr häufig in der Form

$$X = \{x \in \mathbb{R}^n \mid c_i(x) = 0, i \in I_1\} \cap \{x \in \mathbb{R}^n \mid c_i(x) \leq 0, i \in I_2\} \cap \{x \in \mathbb{R}^n \mid x_i \in \mathbb{Z}, i \in I_3\} =: \Omega_1 \cap \Omega_2 \cap \Omega_3$$

schreiben für gewisse Indexmengen  $I_1, I_2, I_3$  und Abbildungen  $c_i : \mathbb{R}^n \rightarrow \mathbb{R}$ ,  $i \in I_1, I_2$ . Die Mengen  $\Omega_1, \Omega_2, \Omega_3$  werden als *Gleichungs-, Ungleichungs-* bzw. *Ganzzahligkeitsrestriktionen* bezeichnet.

Ist  $X$  eine Menge von diskreten Punkten, so spricht man von einem *diskreten* oder *kombinatorischen* Optimierungsproblem, andernfalls von einem *stetigen* Optimierungsproblem.

Ist  $f$  nicht differenzierbar, so spricht man von einem *nicht-differenzierbaren* Optimierungsproblem.

## DEFINITION 1.2

Sei  $f : X \rightarrow \mathbb{R}$  mit  $X \subseteq \mathbb{R}^n$ . Ein Punkt  $x^* \in X$  heißt ...

- (1) ... *globale Minimalstelle* von  $f$  (auf  $X$ ), wenn  $f(x^*) \leq f(x)$  für alle  $x \in X$ .  $f(x^*)$  heißt dann *globales Minimum*.
- (2) ... *strikte globale Minimalstelle* von  $f$  (auf  $X$ ), wenn  $f(x^*) < f(x)$  für alle  $x \in X$ .  $f(x^*)$  heißt dann *striktes globales Minimum*.
- (3) ... *lokale Minimalstelle* von  $f$  (auf  $X$ ), wenn es eine Umgebung  $U$  von  $x^*$  gibt, so dass  $f(x^*) \leq f(x)$  für alle  $x \in X \cap U$ ;  $f(x^*)$  heißt dann *lokales Minimum*;
- (4) ... *strikte lokale Minimalstelle* von  $f$  (auf  $X$ ), wenn es eine Umgebung  $U$  von  $x^*$  gibt, so dass  $f(x^*) < f(x)$  für alle  $x \in U \cap X$ .  $f(x^*)$  heißt dann *striktes lokales Minimum*.

## BEMERKUNG 1.3

Ein Punkt  $x^* \in X$  ist genau dann (*globale, strikte globale, lokale, strikte lokale*) *Maximalstelle* von  $f$  auf  $X$ , wenn  $x^*$  (*globale, strikte globale, lokale, strikte lokale*) *Minimalstelle* von  $-f$  auf  $X$  ist.  $\blacklozenge$

Im Folgenden bezeichne  $\nabla f(x) := \left( \frac{\partial f}{\partial x_1}(x), \dots, \frac{\partial f}{\partial x_n}(x) \right)^T$  den Gradienten von  $f$  in  $x$ .

## DEFINITION 1.4

Seien  $X \subseteq \mathbb{R}^n$  eine offene Menge und  $f : X \rightarrow \mathbb{R}$  eine stetig differenzierbare Funktion.

Ein Punkt  $x^* \in X$  heißt *stationärer Punkt* von  $f$ , wenn  $\nabla f(x^*) = 0$  gilt.

## 2 Optimalitätskriterien

### 2.1 Allgemeiner Fall

Wir behandeln unter geeigneten Differenzierbarkeitsannahmen notwendige und hinreichende Bedingungen für lokale Minimalstellen.

#### SATZ 2.1

Seien  $X \subseteq \mathbb{R}^n$  offen und  $f : X \rightarrow \mathbb{R}$  stetig differenzierbar.

Ist  $x^* \in X$  eine lokale Minimalstelle von  $f$  (auf  $X$ ), so gilt

$$\nabla f(x^*) = 0, \quad (2.1)$$

d.h.  $x^*$  ist ein stationärer Punkt.

#### BEWEIS (Analysis II)

Sei  $x^* \in X$  lokale Minimalstelle von  $f$ , aber  $\nabla f(x^*) \neq 0$ . Dann existiert  $d \in \mathbb{R}^n$  mit  $\nabla f(x^*)^T d < 0$  (z.B.  $d := -\nabla f(x^*)$ ). Da nach Voraussetzung  $f$  stetig differenzierbar ist, existiert die Richtungsableitung  $f'(x^*; d)$  von  $f$  in  $x^*$  in Richtung  $d$ . Es gilt

$$f'(x^*; d) = \lim_{t \searrow 0} \frac{f(x^* + td) - f(x^*)}{t} = \nabla f(x^*)^T d < 0.$$

Folglich existiert  $\bar{t} > 0$  mit  $x^* + td \in X$  und  $\frac{f(x^* + td) - f(x^*)}{t} < 0$  für alle  $t \in (0, \bar{t}]$ . Somit ist auch  $f(x^* + td) < f(x^*)$  für alle  $t \in (0, \bar{t}]$ , was einen Widerspruch zur Voraussetzung ergibt. ■

#### BEMERKUNG 2.2

- (a) Da Satz 2.1 nur Ableitungen bis zur ersten Ordnung verwendet, gibt er eine **notwendige Bedingung erster Ordnung** an.
- (b) Die Bedingung  $\nabla f(x^*) = 0$  ist nicht hinreichend dafür, dass  $x^*$  eine lokale Minimalstelle von  $f$  (auf  $X$ ) ist (betrachte z.B.  $f(x) = x^3$ ). ◆

Wir zitieren folgendes Resultat:

#### LEMMA 2.3

Sei  $\mathcal{S}_n$  der Vektorraum der symmetrischen  $(n \times n)$ -Matrizen. Für  $A \in \mathcal{S}_n$  sei  $\lambda(A)$  der kleinste Eigenwert von  $A$ .

Dann gilt

$$|\lambda(A) - \lambda(B)| \leq \|A - B\|_2 \quad \text{für alle } A, B \in \mathcal{S}_n,$$

wobei  $\|\cdot\|_2$  hier die Spektralnorm symmetrischer Matrizen bezeichnet, d.h.

$$\|A\|_2 := \max\{|\lambda| \mid \lambda \text{ ist Eigenwert von } A\}.$$

Mit Hilfe von Lemma 2.3 folgt aus der Stetigkeit der Hessematrix  $\nabla^2 f$  von  $f$ , dass  $\nabla^2 f(x)$  positiv definit ist in einer Umgebung von  $x^*$ , falls  $\nabla^2 f(x^*)$  positiv definit ist.

Eine analoge Folgerung gilt für den Fall, dass  $\nabla^2 f(x^*)$  negativ definit ist.

#### SATZ 2.4

Seien  $X \subseteq \mathbb{R}^n$  offen und  $f : X \rightarrow \mathbb{R}$  zweimal stetig differenzierbar.

Ist  $x^* \in X$  eine lokale Minimalstelle von  $f$  auf  $X$ , so sind  $\nabla f(x^*) = 0$  und  $\nabla^2 f(x^*)$  positiv semidefinit.

**BEWEIS**

Die Bedingung  $\nabla f(x^*) = 0$  folgt aus Satz 2.1. Sei  $x^*$  eine lokale Minimalstelle von  $f$ , jedoch  $\nabla^2 f(x^*)$  nicht positiv semidefinit. Dann existiert ein  $d \in \mathbb{R}^n$  mit

$$d^T \nabla^2 f(x^*) d < 0.$$

Mit Hilfe des Satzes von Taylor ergibt sich

$$f(x^* + td) = f(x^*) + \underbrace{t \nabla f(x^*)^T d}_{=0} + \frac{1}{2} t^2 d^T \nabla^2 f(\xi_t) d$$

für kleines  $t > 0$ . Dabei ist  $\xi_t = x^* + \vartheta_t td$  für  $\vartheta_t \in (0, 1)$ .

Aus Lemma 2.3 und der Stetigkeit der zweiten Ableitung von  $f$  folgt die Existenz von  $\bar{t} > 0$  mit

$$d^T \nabla^2 f(\xi_t) d < 0 \quad \text{für alle } t \in (0, \bar{t}];$$

wegen  $\nabla f(x^*) = 0$  also

$$f(x^* + td) < f(x^*) \quad \text{für alle } t \in (0, \bar{t}],$$

was einen Widerspruch zur Voraussetzung ergibt. ■


**BEMERKUNG 2.5**

Die Bedingungen aus Satz 2.4 (und Satz 2.1) sind nicht hinreichend dafür, dass  $x^*$  eine lokale Minimalstelle ist.

Betrachte z.B.  $f(x) = x_1^2 - x_2^4$  mit  $x^* = (0, 0)$ , dann

$$\nabla f(x^*) = \begin{pmatrix} 0 \\ 0 \end{pmatrix}, \quad \nabla^2 f(x^*) = \begin{pmatrix} 2 & 0 \\ 0 & 0 \end{pmatrix}.$$

Da Satz 2.4 Ableitungen bis zur zweiten Ordnung verwendet, gibt er **notwendige Bedingungen zweiter Ordnung** an.♦



Nun kommen wir zu hinreichenden Bedingungen.

**SATZ 2.6**

Seien  $X \subseteq \mathbb{R}^n$  offen und  $f : X \rightarrow \mathbb{R}$  zweimal stetig differenzierbar.

Gelten

- (a)  $\nabla f(x^*) = 0$  und
- (b)  $\nabla^2 f(x^*)$  ist positiv definit,

dann ist  $x^*$  eine strikte lokale Minimalstelle von  $f$  auf  $X$ .

**BEWEIS**

Aus (b) folgt die Existenz einer Konstanten  $\mu > 0$  mit

$$d^T \nabla^2 f(x^*) d \geq \mu d^T d \quad \text{für alle } d \in \mathbb{R}^n$$

(z.B.  $\mu := \min\{\lambda \mid \lambda \text{ ist Eigenwert von } \nabla^2 f(x^*)\}$ ).

Nach dem Satz von Taylor gilt für alle  $d \in \mathbb{R}^n$ , die hinreichend nahe bei 0 sind, dass

$$\begin{aligned} f(x^* + d) &= f(x^*) + \nabla f(x^*)^T d + \frac{1}{2} d^T \nabla^2 f(\xi_d) d \\ &\stackrel{(a)}{=} f(x^*) + \frac{1}{2} d^T \nabla^2 f(\xi_d) d \end{aligned}$$

mit  $\xi_d := x^* + \vartheta_d d$  für  $\vartheta_d \in (0, 1)$ .

Man erhält so unter Verwendung der Cauchy-Schwarzschen Ungleichung

$$\begin{aligned} f(x^* + d) &= f(x^*) + \frac{1}{2}d^T \nabla^2 f(x^*)d + \frac{1}{2}d^T (\nabla^2 f(\xi_d) - \nabla^2 f(x^*))d \\ &\geq f(x^*) + \frac{1}{2}(\mu - \|\nabla^2 f(\xi_d) - \nabla^2 f(x^*)\|_2)\|d\|_2^2 \\ &> f(x^*), \end{aligned}$$

falls  $\|\nabla^2 f(\xi_d) - \nabla^2 f(x^*)\|_2$  klein ( $< \mu$ ) und  $\|d\|_2$  klein ( $d \neq 0$ ).


Damit ist  $x^*$  strikte lokale Minimalstelle. ■

### BEMERKUNG 2.7

Die Bedingungen aus Satz 2.6 sind nicht notwendig dafür, dass  $x^*$  strikte lokale Minimalstelle von  $f$  (auf  $X$ ) ist.

Betrachte z.B.  $f(x) = x_1^2 + x_2^4$  mit  $x^* = (0, 0)$ .

Ist  $\nabla^2 f(x^*)$  indefinit, so spricht man von einem *Sattelpunkt*.♦



## 2.2 Konvexe Funktionen

### DEFINITION 2.8

(1) Eine Menge  $X \subseteq \mathbb{R}^n$  heißt *konvex*, wenn für alle  $x, y \in X$  und alle  $\lambda \in (0, 1)$  auch  $\lambda x + (1 - \lambda)y$  in  $X$  liegt.

(2) Sei  $X \subseteq \mathbb{R}^n$  eine konvexe Menge. Eine Funktion  $f : X \rightarrow \mathbb{R}$  heißt ...

(a) ... *strikt konvex* bzw. *konvex*, wenn für alle  $x, y \in X$ ,  $x \neq y$  und alle  $\lambda \in (0, 1)$  gilt

$$f(\lambda x + (1 - \lambda)y) < \lambda f(x) + (1 - \lambda)f(y) \quad \text{bzw.} \quad f(\lambda x + (1 - \lambda)y) \leq \lambda f(x) + (1 - \lambda)f(y).$$

(b) ... *gleichmäßig konvex*, falls es ein  $\mu > 0$  gibt, so dass für alle  $x, y \in X$ ,  $\lambda \in (0, 1)$  gilt:

$$f(\lambda x + (1 - \lambda)y) + \mu\lambda(1 - \lambda)\|x - y\|^2 \leq \lambda f(x) + (1 - \lambda)f(y).$$

Man sagt dazu auch:  $f$  ist gleichmäßig konvex mit *Modul*  $\mu > 0$ .

Aus der Definition folgt, dass jede gleichmäßig konvexe Funktion auch strikt konvex ist und jede strikt konvexe Funktion konvex ist. Die Umkehrungen gelten i.A. nicht.

### BEMERKUNG 2.9

$f : \mathbb{R}^n \rightarrow \mathbb{R}$  sei eine quadratische Funktion, d.h.

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

mit  $Q \in \mathcal{S}_n$ ,  $c \in \mathbb{R}^n$ ,  $\gamma \in \mathbb{R}$ . Dann gelten:

(a)  $f$  ist konvex  $\Leftrightarrow Q$  ist positiv semidefinit.

(b)  $f$  ist strikt konvex  $\Leftrightarrow f$  ist gleichmäßig konvex  $\Leftrightarrow Q$  ist positiv definit.  $\blacklozenge$

Ohne Beweis geben wir folgende Charakterisierungen zweimal stetig differenzierbarer, strikt gleichmäßig konvexer Funktionen an.

### SATZ 2.10

Seien  $X \subseteq \mathbb{R}^n$  eine offene und konvexe Menge sowie  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  zweimal stetig differenzierbar.

Dann gelten:

(a)  $f$  ist konvex auf  $X \Leftrightarrow \nabla^2 f(x)$  ist für alle  $x \in X$  positiv semidefinit.

(b) Ist  $\nabla^2 f(x)$  für alle  $x \in X$  positiv definit, so ist  $f$  strikt konvex (auf  $X$ ).

(c)  $f$  ist genau dann gleichmäßig konvex (auf  $X$ ), wenn  $\nabla^2 f(x)$  gleichmäßig positiv definit ist, d.h. wenn es ein  $\mu > 0$  gibt, so dass für alle  $x \in X$  und alle  $d \in \mathbb{R}^n$  gilt:

$$d^T \nabla^2 f(x) d \geq \mu \|d\|^2.$$

### BEMERKUNG 2.11

Aussage (b) von Satz 2.10 lässt sich i.A. nicht umkehren. Betrachte z.B.  $f(x) = x^4$  mit  $X = \mathbb{R}$ .  $\blacklozenge$

Der folgende Hilfssatz beschäftigt sich mit Niveaumengen gleichmäßig konvexer Funktionen.

### LEMMA 2.12

Seien  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  stetig differenzierbar,  $x^0 \in \mathbb{R}^n$  beliebig gegeben, die Niveaumenge

$$\mathcal{L}(x^0) := \{x \in \mathbb{R}^n \mid f(x) \leq f(x^0)\}$$

konvex und  $f$  gleichmäßig konvex auf  $\mathcal{L}(x^0)$ . Dann ist  $\mathcal{L}(x^0)$  kompakt.

**SATZ 2.13**

Seien  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  stetig differenzierbar und  $X \subseteq \mathbb{R}^n$  konvex. Betrachtet man das Optimierungsproblem

$$\min f(x) \text{ u.d.N. } x \in X, \quad (2.2)$$

dann gelten:

- (a) Ist  $f$  konvex auf  $X$ , so ist die Lösungsmenge von (2.2) konvex (evtl. leer).
- (b) Ist  $f$  strikt konvex auf  $X$ , so besitzt (2.2) höchstens eine Lösung.
- (c) Sind  $f$  gleichmäßig konvex auf  $X$ ,  $X \neq \emptyset$  und abgeschlossen, so besitzt (2.2) genau eine Lösung.

**BEWEIS**

- (a) Seien  $x^1, x^2$  Lösungen von (2.2), also  $f(x^1) = f(x^2) = \min_{x \in X} f(x)$ .

Für  $\lambda \in (0, 1)$  ist dann auch  $\lambda x^1 + (1 - \lambda)x^2 \in X$ . Weiter

$$f(\lambda x^1 + (1 - \lambda)x^2) \leq \lambda f(x^1) + (1 - \lambda)f(x^2) = \min_{x \in X} f(x).$$

Also nimmt  $f$  auch an  $\lambda x^1 + (1 - \lambda)x^2$  sein Minimum an.

- (b) Angenommen, (2.2) hat zwei verschiedene Lösungen  $x^1, x^2$ . Für  $\lambda \in (0, 1)$  gelten  $\lambda x^1 + (1 - \lambda)x^2 \in X$  und

$$f(\lambda x^1 + (1 - \lambda)x^2) < \lambda f(x^1) + (1 - \lambda)f(x^2) = \min_{x \in X} f(x),$$

was einen Widerspruch ergibt.

- (c) Sei  $x^0 \in X$  beliebig gewählt. Dann ist wegen

$$f(\lambda x + (1 - \lambda)y) \leq \lambda f(x) + (1 - \lambda)f(y) \leq f(x^0) \quad \text{für alle } x, y \in \mathcal{L}(x^0)$$

die Menge  $\mathcal{L}(x^0)$  konvex und nach Lemma 2.11 kompakt. Dann ist  $X \cap \mathcal{L}(x^0)$  kompakt und nichtleer. Daher nimmt die stetige Funktion  $f$  ihr globales Minimum in  $X \cap \mathcal{L}(x^0)$  an, welches natürlich auch ein Minimum von (2.2) ist. ■

**BEMERKUNG 2.14**

- (a) Das Problem (2.2) muss selbst für strikt konvexes  $f$  keine Lösung besitzen. Betrachte dazu z.B.  $f(x) = \exp(x)$  auf  $X = \mathbb{R}$ .
- (b) Auf die Forderung nach Abgeschlossenheit von  $X$  in Satz 2.12 (c) kann nicht verzichtet werden, betrachte z.B.  $f(x) = x^2$  für  $x \in (0, 1]$ . ◆

Das zentrale Resultat dieses Abschnitts wird in Satz 2.15 angegeben. Man kann daraus sehen, dass  $\nabla f(x^*) = 0$  auch hinreichend ist dafür, dass  $x^*$  globale Minimalstelle ist.

**SATZ 2.15**

Seien  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  stetig differenzierbar und konvex und  $x^* \in \mathbb{R}^n$  ein stationärer Punkt von  $f$ .

Dann ist  $x^*$  globale Minimalstelle von  $f$  auf  $\mathbb{R}^n$ .

**BEWEIS**

Mit Taylor folgt

$$f(x) = f(x^*) + \nabla f(x^*)(x - x^*) + \frac{1}{2}(x - x^*)^T \nabla^2 f(\xi)(x - x^*)$$

mit  $\xi := x^* + \vartheta(x - x^*)$ ,  $\vartheta \in (0, 1)$ . Nach Satz 2.9 (a) ist  $\nabla^2 f(\xi)$  positiv semidefinit. Ferner gilt  $\nabla f(x^*) = 0$ , daher  $f(x) \geq f(x^*)$ , was zu zeigen war. ■



### 3 Allgemeine Abstiegsverfahren und Schrittweitenstrategien

Wir betrachten ein *Abstiegsverfahren* zur Lösung von  $\min_{x \in \mathbb{R}^n} f(x)$  ( $f : \mathbb{R}^n \rightarrow \mathbb{R}$  stetig differenzierbar).

Die zentrale Idee der Verfahren in diesem Abschnitt ist wie folgt:

- Ist man in einem Punkt  $x \in \mathbb{R}^n$ , so sucht man eine Richtung  $d \in \mathbb{R}^n$  aus, in welcher der Funktionswert fällt („Abstiegsverfahren“).
- Entlang dieser Richtung  $d$  geht man so lange, bis man den Funktionswert von  $f$  hinreichend verkleinert hat („Schrittweitenstrategie“).

Diese Schritte wollen wir formalisieren.

#### DEFINITION 3.1

Seien  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  und  $x \in \mathbb{R}^n$ . Ein Vektor  $d \in \mathbb{R}^n$  heißt *Abstiegsrichtung* von  $f$  im Punkt  $x$ , wenn es ein  $\bar{t} > 0$  gibt mit

$$f(x + td) < f(x) \quad \text{für alle } t \in (0, \bar{t}].$$

Ist  $f$  stetig differenzierbar, dann ist

$$\nabla f(x)^T d < 0 \tag{3.1}$$

hinreichend dafür, dass  $d \in \mathbb{R}^n$  eine Abstiegsrichtung von  $f$  in  $x$  ist.

Um dies einzusehen, definieren wir  $\varphi(t) := f(x + td)$ . Aus  $f \in \mathcal{C}^1$  folgt

$$\varphi(t) = \varphi(0) + t\varphi'(0) + r(t), \tag{3.2}$$

wobei  $\frac{r(t)}{t} \rightarrow 0$  für  $t \searrow 0$  ( $r(t) = o(t)$ ). Es gelten

$$\varphi(0) = f(x), \quad \varphi'(0) = \nabla f(x)^T d.$$

Umformen von (3.2) und Division durch  $t > 0$  liefert

$$\frac{\varphi(t) - \varphi(0)}{t} = \nabla f(x)^T d + \frac{r(t)}{t}.$$

Aus  $r(t) = o(t)$  und (3.1) folgt, dass ein  $\bar{t} > 0$  existiert mit

$$\frac{\varphi(t) - \varphi(0)}{t} < 0 \quad \text{für alle } t \in (0, \bar{t}],$$

d.h.  $f(x + td) < f(x)$  und  $d$  ist Abstiegsrichtung von  $f$  in  $x$ .

#### BEMERKUNG 3.2

- Die Bedingung (3.1) bedeutet, dass der Winkel zwischen  $d$  und dem negativen Gradienten von  $f$  in  $x$  kleiner als  $90^\circ$  ist.
- Das Kriterium (3.1) ist nicht notwendig. Ist  $x$  z.B. eine strikte lokale Maximalstelle, so sind alle  $d \in \mathbb{R}^n$  Abstiegsrichtungen, aber (3.1) gilt nicht.  $\blacklozenge$

#### BEISPIEL 3.3

Mögliche Kandidaten für  $d$  sind ...

- ...  $d = -\nabla f(x)$ , die Richtung des steilsten Abstiegs:

$$\nabla f(x)^T d = -\|\nabla f(x)\|^2;$$

- ...  $d = -M\nabla f(x)$ ,  $M \in \mathcal{S}_n$  positiv definit („gradientenähnliche Verfahren“):

$$\nabla f(x)^T d = -\nabla f(x)^T M \nabla f(x) < 0.$$

### 3.1 Global konvergente Abstiegsverfahren

Wir wollen ein allgemeines Abstiegsverfahren angeben:

**ALGORITHMUS 3.4 (Allgemeines Abstiegsverfahren)**

Input:  $f : \mathbb{R}^n \rightarrow \mathbb{R}$ , Startpunkt  $x^0 \in \mathbb{R}^n$

Begin

$k := 1$

While Konvergenzkriterium nicht erfüllt Do

bestimme Abstiegsrichtung  $d^k$  von  $f$  in  $x^k$ ;

bestimme eine Schrittweite  $t_k > 0$  mit

$$f(x^k + t_k d^k) < f(x^k)$$

setze  $x^{k+1} := x^k + t_k d^k$ ,  $k := k + 1$ ;

End(While)

End

In theoretischen Konvergenzuntersuchungen betrachten wir kein Konvergenzkriterium, d.h. wir nehmen an, dass eine unendliche Folge  $(x^k)_{k \in \mathbb{N}}$  erzeugt wird.

**SATZ 3.5**

Seien  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  stetig differenzierbar und  $(x^k)_{k \in \mathbb{N}}$  eine durch den Algorithmus 3.4 erzeugte Folge so, dass

(a) ... eine Konstante  $\theta_1 > 0$  existiert mit

$$-\nabla f(x^k)^T d^k \geq \theta_1 \|\nabla f(x^k)\| \|d^k\| \quad \text{für alle } k \in \mathbb{N}; \quad \text{(Winkelbedingung)}$$

(b) ... eine von  $(x^k)_{k \in \mathbb{N}}$  und  $(d^k)_{k \in \mathbb{N}}$  unabhängige Konstante  $\theta_2 > 0$  existiert mit

$$f(x^k + t_k d^k) \leq f(x^k) - \theta_2 \left( \frac{\nabla f(x^k)^T d^k}{\|d^k\|} \right)^2 \quad \text{mit } t_k > 0 \text{ für alle } k \in \mathbb{N}.$$

Dann ist jeder Häufungspunkt der Folge  $(x^k)_{k \in \mathbb{N}}$  ein stationärer Punkt von  $f$ .

**BEWEIS**

Da jedes  $t_k$  die Bedingung (b) erfüllt, folgt mit (a), dass

$$f(x^{k+1}) - f(x^k) \leq -\theta_2 \left( \frac{\nabla f(x^k)^T d^k}{\|d^k\|} \right)^2 \leq -\theta_1^2 \theta_2 \|\nabla f(x^k)\|^2 \leq 0. \quad (3.3)$$

Sei nun  $x^*$  ein Häufungspunkt von  $(x^k)_{k \in \mathbb{N}}$ . Da  $(f(x^k))_{k \in \mathbb{N}}$  wegen (3.3) monoton fällt und auf einer Teilfolge  $(x^{k_\nu})_{\nu \in \mathbb{N}}$  mit  $x^{k_\nu} \xrightarrow{\nu \rightarrow \infty} x^*$  gegen  $f(x^*)$  konvergiert, folgt daraus, dass die gesamte Folge der Funktionswerte gegen  $f(x^*)$  konvergiert.

Insbesondere:  $f(x^{k+1}) - f(x^k) \xrightarrow{k \rightarrow \infty} 0$  und mit (3.3) folgt  $\lim_{k \rightarrow \infty} \|\nabla f(x^k)\| = 0$ .

Damit ist jeder Häufungspunkt stationärer Punkt:

$$\|\nabla f(x^*)\| = \lim_{\nu \rightarrow \infty} \|\nabla f(x^{k_\nu})\| = 0. \quad \blacksquare$$

**BEMERKUNG 3.6**

Bezeichne  $\eta_k$  den Winkel zwischen  $d^k$  und  $-\nabla f(x^k)$ , dann bedeutet die Forderung (a) aus Satz 3.5, dass

$$\cos(\eta_k) = \frac{-\nabla f(x^k)^T d^k}{\|\nabla f(x^k)\| \|d^k\|}$$

gleichmäßig größer als 0 ist. Ein wichtiges Beispiel ist  $d^k := -\nabla f(x^k)$ .  $\blacklozenge$

## 3.2 Schrittweitenstrategien und -algorithmen

Das allgemeine Abstiegsverfahren (Algorithmus 3.4) besitzt in der Wahl der Abstiegsrichtung  $d^k$  und der Schrittweite  $t_k > 0$  große Freiheitsgrade.

Die nahe liegende Minimierungsregel  $t_k := t_k^{\min}$  mit

$$f(x^k + t_k d^k) = \min_{t \geq 0} f(x^k + t d^k)$$

ist unter der Annahme, dass  $\mathcal{L}(x^0)$  kompakt ist und  $\nabla f$  Lipschitz-stetig ist auf  $\mathcal{L}(x^0)$ , wohldefiniert. Allerdings ist diese Regel i.A. nicht praktikabel (Aufwand!).


### 3.2.1 Die Armijo-Regel

Wir behandeln *gradientenähnliche Richtungen* d.h.

$$d := -M \nabla f(x), \quad M \in \mathcal{S}_n \text{ positiv definit.}$$

Sei  $\alpha \in [0, 1]$  fest vorgegeben. Die *Armijo-Regel* ist eine Bedingung, die einen hinreichenden Abstieg sichert, und lautet

$$f(x + td) \leq f(x) + \alpha t \nabla f(x)^T d \quad (3.4)$$



Zur tatsächlichen Berechnung von  $t$  überprüft man (3.4) sequenziell z.B. für

$$t = \beta^l, \quad l = 0, 1, 2, \dots \quad (3.5)$$

mit  $\beta \in (0, 1)$  fest vorgegeben, z.B.  $\beta = \frac{1}{2}$ . Bei erstmaliger Gültigkeit von (3.4) bricht man ab. Die Größe  $t$  nennt man *Schrittweite*.

Im Folgenden ist (3.5) verallgemeinert, d.h. falls (3.4) für ein  $t = t_c$  nicht erfüllt ist, dann wird  $t_+$  so konstruiert, dass

$$t_+ \in [\underline{\nu} t_c, \bar{\nu} t_c] \quad \text{mit } 0 < \underline{\nu} \leq \bar{\nu} < 1 \text{ fest.}$$

#### ALGORITHMUS 3.7 (Armijo-Schrittweitenalgorithmus)

Input: Abstiegsrichtung  $d$

Begin

$l := 0; t^{(0)} := 1;$

While (3.4) ist nicht erfüllt Do

bestimme  $t^{(l+1)} \in [\underline{\nu} t^{(l)}, \bar{\nu} t^{(l)}];$

setze  $l := l + 1;$

End(While)

$t_k := t^{(l)};$

End

Im folgenden Satz ist eine Konvergenzaussage für Algorithmus 3.4 mit der Schrittweitenwahl gemäß Algorithmus 3.7 formuliert.

**SATZ 3.8**

Sei  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  stetig differenzierbar mit  $\nabla f$  Lipschitz-stetig. Seien  $(x^k)_{k \in \mathbb{N}}$  die von Algorithmus 3.4 mit Algorithmus 3.7 erzeugte Iterationsfolge und  $(M^k)_{k \in \mathbb{N}}$  eine Folge symmetrischer, positiv definiter Matrizen mit

$$0 < \underline{\lambda} \leq \lambda_s^k \leq \lambda_l^k \leq \bar{\lambda} < \infty \quad \text{für alle } k \in \mathbb{N},$$

wobei  $\lambda_s^k$  und  $\lambda_l^k$  den kleinsten bzw. größten Eigenwert von  $M^k$  bezeichnen.  $L > 0$  bezeichne die Lipschitz-Konstante von  $\nabla f$ .

Dann erfüllen die Schritte

$$s^k := x^{k+1} - x^k = t_k d^k = -t_k M^k \nabla f(x^k)$$

die Bedingung

$$t_k \geq \underline{t} = \frac{2\nu \underline{\lambda}(1-\alpha)}{L\bar{\kappa}} \quad \text{mit } \bar{\kappa} := \frac{\bar{\lambda}}{\underline{\lambda}} \geq \kappa_2(M^k) \geq 1. \quad (\text{vgl. Kap. 4})$$

Ferner ist entweder  $(f(x^k))_{k \in \mathbb{N}}$  nach unten unbeschränkt oder  $\lim_{k \rightarrow \infty} \nabla f(x^k) = 0$ .

Somit ist jeder Häufungspunkt von  $(x^k)_{k \in \mathbb{N}}$  stationärer Punkt von  $f$  in  $\mathbb{R}^n$ .

Insbesondere: Sind  $(f(x^k))_{k \in \mathbb{N}}$  nach unten beschränkt und existiert eine Teilfolge  $(x^{k(l)})_{l \in \mathbb{N}}$  von  $(x^k)_{k \in \mathbb{N}}$  mit  $\lim_{l \rightarrow \infty} x^{k(l)} = x^*$ , dann ist  $\nabla f(x^*) = 0$ .

**BEMERKUNG 3.9**

- (a) Im Allgemeinen gibt es keine Garantie, dass ein (eindeutiger) Häufungspunkt existiert.  
 (b) Die folgende Variation der Armijo-Regel führt ebenfalls zu einem im Sinne von Satz 3.8 konvergenten Verfahren:

Seien  $r > 0$  ein Skalierungsverfahren und  $\beta \in (0, 1)$ . Bestimme

$$t = \max\{r\beta^l\}, \quad l = 0, 1, 2, \dots \quad (3.6)$$

so, dass (3.4) erfüllt ist.

Die Bestimmung der Schrittweite  $t$  gemäß (3.5) oder (3.6) wird in der englischsprachigen Literatur „Backtracking“ genannt.

- (c) Weitere Strategien basieren auf Polynommodellen, die  $\varphi(t) = f(x + td)$  durch ein quadratisches oder kubisches *Modell* ersetzen und dann dieses Modell minimieren.  $\blacklozenge$

**3.2.2 Die Wolfe-Powell-Regel**

Seien  $\alpha \in (0, \frac{1}{2})$  und  $\rho \in [\alpha, 1]$  gegeben. Die *Wolfe-Powell-Regel* lautet:

Zu  $x, d \in \mathbb{R}^n$  mit  $\nabla f(x)^T d < 0$  bestimme eine Schrittweite  $t > 0$  mit

$$f(x + td) \leq f(x) + \alpha t \nabla f(x)^T d \quad (\text{oder: } \varphi(t) \leq \varphi(0) + \alpha t \varphi'(0)) \quad (3.7a)$$

$$\nabla f(x + td)^T d \geq \rho \nabla f(x)^T d \quad (\text{oder: } \varphi'(t) \geq \rho \varphi'(0)) \quad (3.7b)$$

Graphik einfügen

Ohne Beweis geben wir den folgenden Satz an.

**SATZ 3.10**

Seien  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  stetig differenzierbar und  $\alpha \in (0, \frac{1}{2})$ ,  $\rho \in [\alpha, 1)$ ,  $x^0 \in \mathbb{R}^n$  fest vorgegeben.  
Zu  $x \in \mathcal{L}(x^0)$  und einer Richtung  $d \in \mathbb{R}^n$  mit  $\nabla f(x)^T d < 0$  sei

$$\mathcal{T}_{\text{WP}}(x, d) := \{t > 0 \mid (3.7) \text{ ist erfüllt}\}.$$

Dann gelten:

- (a) Ist  $f$  nach unten beschränkt, so ist  $\mathcal{T}_{\text{WP}}(x, d) \neq \emptyset$ , d.h. die Wolfe-Powell-Schrittweitenstrategie ist wohldefiniert.  
(b) Ist weiter  $\nabla f$  auf  $\mathcal{L}(x^0)$  Lipschitz-stetig, dann existiert eine Konstante  $\theta > 0$  (unabhängig von  $x$  und  $d$ ) mit

$$f(x + td) \leq f(x) - \theta \left( \frac{\nabla f(x)^T d}{\|d\|} \right)^2 \quad \text{für alle } x \in \mathcal{T}_{\text{WP}}(x, d).$$

**ALGORITHMUS 3.11 (Wolfe-Powell-Liniensuche)**

Input: Abstiegsrichtung  $d \in \mathbb{R}^n$

Begin

Wähle  $t^{(0)} > 0$ ,  $\gamma > 1$  (z.B.  $\gamma = \frac{3}{2}$  oder  $\gamma = 2$ ),  $i := 0$

If  $\varphi(t^{(i)}) \geq \varphi(0) + \alpha t^{(i)} \varphi'(0)$  (A.1)

$a := 0$ ;  $b := t^{(i)}$ ; Goto (B.0)

Else

If  $\varphi'(t^{(i)}) \geq \rho \varphi'(0)$

$t := t^{(i)}$ ; Return 1 (Ausgabe der Schrittweite  $t$ )

Else

$t^{(i+1)} := t^{(i)}$ ;  $i := i + 1$ ; Goto (A.1)

End(If)

End(If)

Wähle  $\tau_1, \tau_2 \in (0, \frac{1}{2}]$ ;  $j := 0$ ;  $t_1^{(0)} := a$ ;  $t_2^{(0)} := b$ ;  $\Delta^{(0)} := t_2^{(0)} - t_1^{(0)}$  (B.0)

Wähle  $t^{(j)} \in [t_1^{(j)} + \tau_1 \Delta^{(j)}, t_2^{(j)} - \tau_2 \Delta^{(j)}]$  (B.1)

If  $\varphi(t^{(j)}) \geq \varphi(0) + \alpha t^{(j)} \varphi'(0)$

$b_1^{(j+1)} := t_1^{(j)}$ ;  $t_2^{(j+1)} := t^{(j)}$ ;  $j := j + 1$ ; Goto (B.1)

Else

If  $\varphi'(t^{(j)}) \geq \rho \varphi'(0)$

$t := t^{(j)}$ ; Return 2 (Ausgabe der Schrittweite  $t$ )

Else

$t_2^{(j+1)} := t^{(j)}$ ;  $t_1^{(j+1)} := t^{(j)}$ ;  $j := j + 1$ ; Goto (B.1)

End(If)

End(If)

End

Das folgende Lemma motiviert teilweise den Algorithmus 3.8.

**LEMMA 3.12**

Seien  $\alpha < \rho$  und  $\varphi'(0) < 0$ . Ist  $[a, b]$  mit  $0 \leq a < b$  ein Intervall mit

$$\varphi(a) \leq \varphi(0) + \alpha a \varphi'(0); \quad \varphi(b) \geq \varphi(0) + \alpha b \varphi'(0) \quad \varphi'(a) < \rho \varphi'(0),$$

so enthält  $[a, b]$  einen Punkt  $\bar{t}$  mit

$$\varphi(\bar{t}) < \varphi(0) + \alpha \bar{t} \varphi'(0); \quad \varphi'(\bar{t}) = \alpha \varphi'(0) > \rho \varphi'(0).$$

Der Punkt  $\bar{t}$  ist ein innerer Punkt eines Intervalls  $I$ , so dass für alle  $t \in I$  gilt

$$\varphi(t) \leq \varphi(0) + \alpha t \varphi'(0); \quad \varphi'(t) \geq \rho \varphi'(0),$$

d.h.  $I \subseteq \mathcal{T}_{\text{WP}}(x, d)$ .

**SATZ 3.13**

Seien  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  stetig differenzierbar und nach unten beschränkt und  $\alpha \in (0, \frac{1}{2})$ ,  $\rho \in (\frac{1}{2}, 1)$ .

Dann bricht Algorithmus 3.11 nach endlich vielen Schritten entweder bei **Return 1** oder bei **Return 2** mit einer Schrittweite  $t \in \mathcal{T}_{\text{WP}}(x, d)$  ab.

**3.2.3 Strenge Wolfe-Powell-Regel**

Seien  $\alpha \in (0, \frac{1}{2})$  und  $\rho \in [\frac{1}{2}, 1)$  fest vorgegeben. Die *Strenge Wolfe-Powell-Regel* lautet:

Zu  $x, d \in \mathbb{R}^n$  mit  $\nabla f(x)^T d < 0$  bestimme eine Schrittweite  $t > 0$  mit

$$f(x + td) \leq f(x) + \alpha t \nabla f(x)^T d \tag{3.8a}$$

$$|\nabla f(x + td)^T d| \leq -\rho \nabla f(x)^T d \tag{3.8b}$$

Graphik einfügen

Der Graph von  $\varphi$  fällt also nicht zu steil ab, steigt aber auch nicht zu steil.

Für sehr kleines  $\rho$  (und damit auch kleines  $\alpha$ ) ist eine Schrittweite, die (3.8) erfüllt, nahe an einem stationären Punkt von  $\varphi$ .

### 3.3 Praktische Aspekte

Die Algorithmen in Abschnitt 3.2 sind idealisiert. In der Praxis sind  $f$  und  $\nabla f$  maschinen- und/oder problemabhängig genau. Werden diese Ungenauigkeiten nicht berücksichtigt, fährt dies schnell zu Endlosschleifen.

Ideal wäre, wenn mit den Funktionswerten  $\varphi(t), \varphi(0)$  und Ableitungen  $\varphi'(t), \varphi'(0)$  Fehlerschranken mit geliefert würden:  $\varepsilon(t), \varepsilon(0)$  und  $\hat{\varepsilon}(t), \hat{\varepsilon}(0)$ . Dann wird

$$\varphi(t) \leq \varphi(0) + \alpha t \varphi'(0)$$

ersetzt durch

$$\varphi(t) \leq \varphi(0) + \alpha t (\varphi'(0) + \hat{\varepsilon}(0)) + \varepsilon(0) + \varepsilon(t)$$

und

$$\varphi'(t) \geq \rho \varphi'(0)$$

wird ersetzt durch

$$\varphi'(t) \geq \rho(\varphi'(0) - \hat{\varepsilon}(0)) - \hat{\varepsilon}(t).$$

Weiter ist abzubrechen, wenn  $[t_1^{(j)}, t_2^{(j)}]$  „zu klein“ wird, d.h. wenn  $t_2^{(j)} - t_1^{(j)}$  klein wird.

Ferner sollte man eine untere Schranke für  $f$  mitführen.

## 4 Gradientenverfahren

Das allgemeine Abstiegsverfahren lässt noch einige Freiheiten in der Wahl der Abstiegsrichtung  $d^k$ .

Eine nahe liegende Wahl für  $d$  (auch in Hinblick auf die Winkelbedingung aus Satz 3.5 (a)) ergibt sich als Lösung von

$$\min \nabla f(x)^T d \text{ u.d.N. } \|d\| = 1. \quad (4.1)$$

Das Ziel ist also,  $d$  als jene Richtung zu bestimmen, in welche  $f$  in  $x$  am steilsten fällt. Offensichtlich gilt

$$0 \leq |\nabla f(x)^T d| \stackrel{\|d\|=1}{\leq} \|\nabla f(x)\|.$$

Die Wahl

$$d := -\frac{\nabla f(x)}{\|\nabla f(x)\|}$$

liefert

$$\nabla f(x)^T d = -\|\nabla f(x)\|$$

und löst somit (4.1).

Verwenden wir die Wolfe-Powell-Schrittweitenstrategie, dann folgt sofort aus den Sätzen 3.5 und 3.10, dass jeder Häufungspunkt der Folge  $(x^k)_{k \in \mathbb{N}}$  ein stationärer Punkt von  $f$  ist.

Eine analoge Aussage gilt auch für die strenge Wolfe-Powell-Regel.

Da die Armijo-Bedingung die Forderung (b) aus Satz 3.5 nicht notwendigerweise erfüllt, geben wir folgenden Satz an.

### SATZ 4.1

Ist  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  stetig differenzierbar, so ist jeder Häufungspunkt einer durch Algorithmus 3.4 konstruierten Folge  $(x^k)_{k \in \mathbb{N}}$  mit

$$d^k = \frac{-\nabla f(x^k)}{\|\nabla f(x^k)\|}$$

und der Armijo-Schrittweitenstrategie ein stationärer Punkt.

Das Konvergenzverhalten des steilsten Abstiegs kann sehr schlecht sein. Für

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

mit  $Q \in \mathcal{S}_n$  positiv definit,  $c \in \mathbb{R}^n$ ,  $\gamma \in \mathbb{R}$  lässt sich zeigen, dass

$$\|x^k - x^*\| \leq \sqrt{\kappa} \left( \frac{\kappa - 1}{\kappa + 1} \right)^k \|x^0 - x^*\|,$$

wobei  $\kappa := \kappa_2(Q)$  die spektrale Konditionszahl von  $Q$  bezeichnet, d.h.  $\kappa := \frac{\lambda_{\max}}{\lambda_{\min}}$  mit

$$\begin{aligned} \lambda_{\max} &:= \max\{\lambda \mid \lambda \text{ ist Eigenwert von } Q\}; \\ \lambda_{\min} &:= \min\{\lambda \mid \lambda \text{ ist Eigenwert von } Q\}. \end{aligned}$$

Eine mögliche Abhilfe für die langsame Konvergenz des Verfahrens des steilsten Abstiegs besteht darin,

$$d^k := -H^{-1} \nabla f(x^k) \quad \text{mit } H \in \mathcal{S}_n \text{ positiv definit}$$

zu setzen.  $H$  soll überdies so sein, dass

$$0 < \frac{\lambda_{\max}(H^{-1}Q)}{\lambda_{\min}(H^{-1}Q)} = \kappa_2(H^{-1}Q) < \frac{\lambda_{\max}(Q)}{\lambda_{\min}(Q)} = \kappa_2(Q).$$



**DEFINITION 4.2**

Seien  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  stetig differenzierbar und  $(x^k)_{k \in \mathbb{N}} \subseteq \mathbb{R}^n$ . Dann heißt  $(d^k)_{k \in \mathbb{N}} \subseteq \mathbb{R}^n$  *gradientenähnlich* bzgl.  $f$  und  $(x^k)_{k \in \mathbb{N}}$ , wenn für jede gegen einen nichtstationären Punkt von  $f$  konvergierende Teilfolge Konstanten  $c > 0, \varepsilon > 0$  existieren, so dass

- (a)  $\forall l \in \mathbb{N} : \|d^{k(l)}\| \leq c$  und  
 (b)  $\forall l \in \mathbb{N}$  hinreichend groß:  $\nabla f(x^{k(l)})^T d^{k(l)} \leq -\varepsilon$ .

**BEMERKUNG 4.3**

- (a) Sei  $(H^k)_{k \in \mathbb{N}} \subseteq \mathcal{S}_n$  eine Folge positiv definiter Matrizen, welche

$$\forall x \in \mathbb{R}^n, \forall k \in \mathbb{N} : c_1 \|x\|^2 \leq x^T H^k x \leq c_2 \|x\|^2$$

erfüllen ( $c_1, c_2 > 0$  konstant). Dann ist  $(d^k)_{k \in \mathbb{N}}$ , gegeben durch

$$\forall k \in \mathbb{N} : H^k d^k = -\nabla f(x^k),$$

gradientenähnlich. Denn:

$$\|d^{k(l)}\| = \|-(H^{k(l)})^{-1} \nabla f(x^{k(l)})\| \leq \|(H^{k(l)})^{-1}\| \|\nabla f(x^{k(l)})\| \leq \frac{1}{c_1} \|\nabla f(x^{k(l)})\| \leq C,$$

da  $x^{k(l)}$  konvergente Teilfolge, und außerdem

$$-\nabla f(x^{k(l)})^T (H^{k(l)})^{-1} \nabla f(x^{k(l)}) \stackrel{(*)}{\leq} -\frac{1}{c_2} \underbrace{\|\nabla f(x^{k(l)})\|}_{\neq 0} \leq -\varepsilon,$$

wobei (\*) erfüllt ist wegen  $\frac{1}{c_2} \|x\|^2 \leq x^T (H^{k(l)})^{-1} x \leq \frac{1}{c_1} \|x\|^2$ .

- (b) Für Algorithmus 3.4 mit gradientenähnlichen Suchrichtungen und der Armijo-Schrittweitenstrategie gilt eine analoge Aussage zu Satz 4.1.  
 (c) Manchmal bringt die Wahl  $H^k := \text{diag}(h_{ii}^k)$  mit

$$h_{ii}^k := \frac{\partial^2 f(x^k)}{\partial x_i^2}, \quad 1 \leq i \leq n,$$

eine deutliche Verbesserung. ◆

## 5 Das Newton-Verfahren

### 5.1 Das lokale Verfahren

Wir setzen ab nun voraus, dass  $f$  und die lokale Minimalstelle  $x^*$  (von  $f$ ) folgende Voraussetzungen erfüllen:

$$\left\{ \begin{array}{l} 1. f \text{ ist zweimal stetig differenzierbar mit } \|\nabla^2 f(x) - \nabla^2 f(y)\| \leq \gamma \|x - y\| \text{ für ein } \gamma > 0 \\ 2. \nabla f(x^*) = 0 \\ 3. \nabla^2 f(x^*) \text{ ist positiv definit} \end{array} \right. \quad (\text{A})$$

Zur Vereinfachung der Schreibweise bezeichne  $x_a$  den aktuellen Iterationspunkt und  $x_+$  die neue Iterierte. Wir betrachten ein quadratisches Modell von  $f$  um  $x_a$ :

$$m_a(x) = f(x_a) + \nabla f(x_a)^T(x - x_a) + \frac{1}{2}(x - x_a)^T \nabla^2 f(x_a)(x - x_a).$$

Wenn  $\nabla^2 f(x_a)$  positiv definit ist, dann definieren wir  $x_+$  als die (eindeutige) Minimalstelle unseres Modells. Es gilt

$$0 = \nabla m_a(x_+) = \nabla f(x_a) + \nabla^2 f(x_a)(x_+ - x_a).$$

Umformen liefert die Iterationsvorschrift des *Newton-Verfahrens*, d.h.

$$x_+ = x_a - \nabla^2 f(x_a)^{-1} \nabla f(x_a).$$

Natürlich wird nicht  $\nabla^2 f(x_a)^{-1}$  berechnet, sondern es wird

$$\nabla^2 f(x_a)d = -\nabla f(x_a)$$

gelöst und  $x_+ := x_a + d$  gesetzt.

Falls  $x_a$  weit von einer lokalen Minimalstelle  $x^*$ , die (A) erfüllt, entfernt ist, dann kann  $\nabla^2 f(x_a)$  negative Eigenwerte haben. Also kann  $x_+$  lokale Minimalstelle oder ein Sattelpunkt sein.

Um dies zu vermeiden, müssen geeignete Modifikationen eingeführt werden. Zunächst sei aber vorausgesetzt, dass  $x_a$  hinreichend nahe an  $x^*$  ist.

#### SATZ 5.1

Sei (A) erfüllt. Dann existieren Konstanten  $K > 0$  und  $\delta > 0$  derart, dass für alle  $x_a$  aus der Menge  $B(x^*, \delta) = \{x \in \mathbb{R}^n \mid \|x - x^*\| < \delta\}$  der Newton-Schritt

$$x_+ = x_a - \nabla^2 f(x_a)^{-1} \nabla f(x_a)$$

folgende Abschätzung erfüllt:

$$\|x_+ - x^*\| \leq K \|x_a - x^*\|^2.$$

#### SATZ 5.2

Es sei (A) erfüllt. Dann existiert  $\delta > 0$ , so dass das Newton-Verfahren

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

für  $x^0 \in B(\delta) := B(0, \delta)$  gegen  $x^*$  konvergiert mit

$$\|x^{k+1} - x^*\| \leq C \|x^k - x^*\|^2$$

mit  $C > 0$  (quadratische Konvergenzordnung).

Ein natürliches Abbruchkriterium für das Newton-Verfahren (wie auch für die Gradientenverfahren aus Abschnitt 4) setzt sich aus einer relativen und einer absoluten Fehlerschranke zusammen.

Sei  $\tau_r \in (0, 1)$  eine erwünschte Reduktion in der Gradientennorm und  $\tau_a$  mit  $1 \gg \tau_a > 0$  eine absolute Fehlerschranke, dann stoppt man das Verfahren, wenn

$$\|\nabla f(x^k)\| \leq \tau_r \|\nabla f(x^0)\| + \tau_a$$

gilt. Ist  $\|\nabla f(x^0)\|$  groß, so ist  $\tau_r \|\nabla f(x^0)\|$  der dominante Term. Ist hingegen  $\|\nabla f(x^0)\|$  klein, dann ist  $\tau_a$  der dominante Term.

Wir nehmen nun an, dass  $n = 1$  ist und  $f$  nur approximativ ausgewertet werden kann, d.h.

$$\tilde{f}(x) = f(x) + \tilde{\varepsilon}_f(x) \quad \text{mit } \tilde{\varepsilon}_f(x) \geq 0 \text{ und } |\tilde{\varepsilon}_f(x)| \leq \varepsilon_f \text{ für ein } \varepsilon_f > 0.$$

Bestimmen wir nun die Ableitungen numerisch, z.B. durch Vorwärtsdifferenzen, so ergibt sich

$$D_h^+ f(x) = \frac{\tilde{f}(x+h) - \tilde{f}(x)}{h}.$$

Also:

$$\begin{aligned} \|D_h^+ f(x) - f'(x)\| &= \left\| \frac{\tilde{f}(x+h) - \tilde{f}(x)}{h} - f'(x) \right\| \\ &= \left\| \frac{f(x+h) + \tilde{\varepsilon}_f(x+h) - f(x) - \tilde{\varepsilon}_f(x)}{h} - f'(x) \right\| \\ &\leq \left\| \frac{f(x+h) - f(x)}{h} - f'(x) \right\| + \frac{2\varepsilon_f}{h} \\ &\stackrel{\xi \in (x, x+h)}{=} \left\| \frac{f(x) + f'(x)h + \frac{1}{2}f''(\xi)h^2 - f(x)}{h} - f'(x) \right\| + \frac{2\varepsilon_f}{h} \\ &= \frac{h}{2} \|f''(\xi)\| + \frac{2\varepsilon_f}{h} \\ &= \mathcal{O}\left(h + \frac{\varepsilon_f}{h}\right). \end{aligned}$$

Die Minimalstelle  $h^*$  der Fehlerfunktion  $\text{err}_+(h) = h + \frac{\varepsilon_f}{h}$  erfüllt

$$\text{err}'_+(h^*) = 1 - \frac{\varepsilon_f}{(h^*)^2} = 0,$$

d.h.  $h^* = \sqrt{\varepsilon_f}$ . Der Fehler im Gradienten ist also  $\varepsilon_g = \mathcal{O}(h^*) = \mathcal{O}(\sqrt{\varepsilon_f})$ .

Verwenden wir nun abermals Vorwärtsdifferenzen zur Approximation der Hessematrix, so ergibt sich offensichtlich für den Fehler  $\varepsilon_H$  die Größenordnung

$$\varepsilon_H = \mathcal{O}(\sqrt{\varepsilon_g}) = \mathcal{O}(\varepsilon_f^{\frac{1}{4}}).$$

Dies impliziert, dass Hessematrizen, basierend auf zweifacher numerischer Differenzierung, relativ ungenau sind – selbst wenn  $\varepsilon_f = 10^{-16}$  (Maschinen-Epsilon) ist, folgt  $\varepsilon_H \approx 10^{-4}$ .

Im Falle zentraler Differenzenapproximationen ergibt sich ein besseres Ergebnis:

$$\varepsilon_H = \mathcal{O}(\varepsilon_f^{\frac{4}{9}}).$$

Bei  $\varepsilon_f = 10^{-16}$  erhalten wir  $\varepsilon_H \approx 10^{-7,1}$ .

Konvergenz des Newton-Verfahrens ist nur zu erwarten, wenn  $\varepsilon_g \rightarrow 0$  im Laufe der Iteration.

**SATZ 5.3**

Es sei (A) erfüllt. Dann existieren Konstanten  $\bar{K} > 0$ ,  $\delta > 0$  und ein  $\varepsilon > 0$ , so dass für  $x_a \in B(x^*, \delta)$  und  $\|\varepsilon_H(x_a)\| < \varepsilon$  gilt:

$$x_+ = x_a - (\nabla^2 f(x_a) + \varepsilon_H(x_a))^{-1}(\nabla f(x_a) + \varepsilon_g(x_a))$$

ist wohldefiniert, d.h.  $(\nabla^2 f(x_a) + \varepsilon_H(x_a))$  ist regulär, und erfüllt

$$\|x_+ - x^*\| \leq \bar{K}(\|x_a - x^*\|^2 + \underbrace{\|\varepsilon_H(x_a)\|}_{\text{beeinflusst Konv.geschw.}} \|x_a - x^*\| + \underbrace{\|\varepsilon_g(x_a)\|}_{\text{Genauigkeit!}}).$$

Wir betrachten das Verfahren

$$x^{k+1} = x^k - \nabla^2 f(x^0)^{-1} \nabla f(x^k), \quad x^0 \text{ Startwert, } k = 0, 1, \dots \quad (5.1)$$

Es gilt

$$\begin{cases} \varepsilon_H(x^k) &= \nabla^2 f(x^0) - \nabla^2 f(x^k), \quad \|\varepsilon_H(x^k)\| \leq \varepsilon_H \\ \|\varepsilon_H(x^k)\| &= \|\nabla^2 f(x^0) - \nabla^2 f(x^k)\| \leq \gamma \|x^0 - x^k\| \leq \gamma(\|x^0 - x^*\| + \|x^* - x^k\|) \end{cases} \quad (5.2)$$

Die Konvergenz des Verfahrens (5.1) folgt aus Satz 5.3 mit  $\varepsilon_g = 0$  und  $\varepsilon_H = \mathcal{O}(\|x^0 - x^*\|)$ .

**SATZ 5.4**

Es sei (A) erfüllt. Dann existieren  $K \in (0, 1)$  und  $\delta > 0$ , so dass für  $x^0 \in B(x^*, \delta)$  gilt: Die Folge der Iterierten  $(x^k)_{k \in \mathbb{N}}$ , erzeugt durch (5.1), konvergiert linear gegen  $x^*$  und

$$\|x^{k+1} - x^*\| \leq K \|x^* - x^k\|.$$

**BEWEIS**

Sei  $\delta > 0$  so gewählt, dass Satz 5.2 gilt. Mit (5.2) folgt:

$$\begin{aligned} \|x^{k+1} - x^*\| &\leq \bar{K}(\|x^k - x^*\|^2 + \gamma(\|x^0 - x^*\| + \|x^* - x^k\|))\|x^k - x^*\| \\ &= \bar{K}(\underbrace{\|x^k - x^*\|}_{\leq \delta}(1 + \gamma) + \gamma \underbrace{\|x^0 - x^*\|}_{\leq \delta})\|x^k - x^*\| \\ &\leq \bar{K}(1 + 2\gamma)\delta \|x^k - x^*\|. \end{aligned}$$

Um Konvergenz zu garantieren, verkleinere  $\delta$ , so dass  $\bar{K}(1 + 2\gamma)\delta < 1$ . ■

## 5.2 Inexakte Newton-Verfahren

Betrachte für  $k = 0, 1, \dots$ :

$$\begin{cases} \nabla^2 f(x^k) d^k &= -\nabla f(x^k) \\ x^{k+1} &= x^k + d^k \end{cases} .$$

Inexakte Newton-Verfahren verwenden einen approximativen Schritt  $\tilde{d}$ , welcher für ein  $\eta_a > 0$

$$\|\nabla^2 f(x_a) \tilde{d} + \nabla f(x_a)\| \leq \eta_a \|\nabla f(x_a)\| \quad (5.3)$$

erfüllt. Wir wissen, dass  $\nabla^2 f(x_a)$  positiv definit ist für  $x_a$  nahe  $x^*$ . Daher eignet sich z.B. das „CG-Verfahren“ (Verfahren der konjugierten Gradienten) zur iterativen Lösung von

$$\nabla^2 f(x_a) \tilde{d} = -\nabla f(x_a).$$

Man spricht dann vom *Newton-CG-Verfahren*.

### SATZ 5.5

Sei (A) erfüllt. Dann existieren  $K_I \geq 0$ ,  $\delta > 0$ , so dass für  $x_a \in B(\delta)$ ,  $\tilde{d}$  aus (5.3) und  $x_+ = x_a + \tilde{d}$  gilt:

$$\|x_+ - x^*\| \leq K_I (\|x_a - x^*\| + \eta_a) \|x_a - x^*\|.$$

Für das gesamte Verfahren erhalten wir

### SATZ 5.6

Sei (A) erfüllt. Dann existieren  $\delta > 0$  und  $\bar{\eta} \geq 0$ , so dass für  $x^0 \in B(x^*, \delta)$  eine Folge  $(\eta_k)_{k \in \mathbb{N}} \subseteq [0, \bar{\eta}]$ , so dass

$$x^{k+1} := x^k + \tilde{d}^k \quad (\text{inexakte Newton-Iteration})$$

mit

$$\|\nabla^2 f(x^k) \tilde{d}^k + \nabla f(x^k)\| \leq \eta_k \|\nabla f(x^k)\|$$

linear gegen  $x^*$  konvergiert.

Ferner: Falls  $\eta_k \xrightarrow{k \rightarrow \infty} 0$ , dann ist die Konvergenz *superlinear*, d.h.

$$\lim_{k \rightarrow \infty} \frac{\|x^{k+1} - x^*\|}{\|x^k - x^*\|} = 0.$$

Falls  $\eta_k \leq K_\eta \|\nabla f(x^k)\|$  für ein  $K_\eta > 0$ , so ist die Konvergenz sogar quadratisch.

### 5.3 Globale Konvergenz

Bisher im Zusammenhang mit dem Newton-Verfahren lokale Konvergenzaussagen, d.h. „ $x^0$  hinreichend nahe an  $x^*$ “.

Jetzt: Globalisierungen, die die Startpunktwahl relaxieren.

Kann man sicherstellen, dass die *Newton-Iterationsmatrix*  $\nabla^2 f(x^k)$  oder eine entsprechende Approximation

$$\forall k \in \mathbb{N}, \forall d \in \mathbb{R}^n : c_1 \|d\|^2 \leq d^T \nabla^2 f(x^k) d \leq c_2 \|d\|^2 \quad (0 < c_1 \leq c_2)$$

erfüllt, so ist  $d^k$  als Lösung von  $\nabla^2 f(x^k) d^k = -\nabla f(x^k)$  eine gradientenähnliche Abstiegsrichtung.

Eingesetzt in das allgemeine Abstiegsverfahren folgt dann aus Abschnitt 4 die globale Konvergenz des *globalisierten Newton-Verfahrens* ( $x^0$  kann beliebig gewählt werden).

#### 5.3.1 Trust-Region-Methoden

Schrittweisen + Newton (Algorithmus 3.4): Problem  $(\nabla^2 f(x^k))_{k \in \mathbb{N}}$  positiv definit.

Zu prüfen: Ist  $(d^k)^T \nabla^2 f(x^k) d^k \geq \varepsilon \|d^k\|^2$ , dann ersetze  $\nabla^2 f(x^k)$  durch  $H^k \in \mathcal{S}_n$  positiv definit mit  $H^k d^k = -\nabla f(x^k)$ .

Idee der *Trust-Region-Methoden*:

- (a) Globale Konvergenzeigenschaften von gradientenähnlichen Verfahren ausnützen;
- (b) glatter Übergang zur Newton-Richtung.

Wir verwenden dabei eine Umgebung, in der wir einem Modell von  $f$  trauen können.

Sei  $m_a$  ein quadratisches Modell von  $f$  um  $x_0$ , gegeben durch

$$m_a(x) := f(x_a) + \nabla f(x_a)^T (x - x_a) + \frac{1}{2} (x - x_a)^T \nabla^2 f(x_a) (x - x_a).$$

Weiter sei  $\Delta$  ein Radius einer Kugel um  $x_a$ , in welcher wir dem Modell von  $f$  vertrauen.  $\Delta$  nennt man *Trust-Region-Radius* und die Kugel  $\mathcal{T}(\Delta) := \{x \in \mathbb{R}^n \mid \|x - x_a\| \leq \Delta\}$  *Trust-Region*.

Die nächste Iterierte wird als approximative Minimalstelle von  $m_a$  in  $\mathcal{T}(A)$  gewählt.

Das zugehörige Trust-Region-Hilfsproblem lautet daher

$$\min m_a(x + d) \text{ u.d.N. } \|d\| \leq \Delta. \quad (5.4)$$

Wir bezeichnen die Lösung von (5.4) mit  $d_V$  (*Versuchslösung*) und setzen  $x_V := x_a + d_V$ .

Im Wesentlichen überprüft man, ob das quadratische Modell eine „gute“ Approximation von  $f$  in  $\mathcal{T}(\Delta)$  ist. Dazu definiere

$$\begin{aligned} \text{ared}_a &:= f(x_a) - f(x_V) && \text{(tatsächliche Reduktion)} \\ \text{pred}_a &:= m_a(x_a) - m_a(x_V) && \text{(erwartete Reduktion)}. \end{aligned}$$

Es gilt (mit  $H_a := \nabla^2 f(x_a)$ ):

$$\begin{aligned} \text{pred}_a &= m_a(x_a) - m_a(x_V) \\ &= f(x_a) - f(x_a) - \nabla f(x_a)^T (x_V - x_a) - \frac{1}{2} (x_V - x_a)^T H_a (x_V - x_a) \\ &= -\nabla f(x_a)^T (x_V - x_a) - \frac{1}{2} (x_V - x_a)^T H_a (x_V - x_a). \end{aligned}$$

Im folgenden Algorithmus benötigen wir die Parameter

$$0 < \mu_0 \leq \underline{\mu} < \bar{\mu},$$

um zu entscheiden, ob der Versuchsschritt verworfen wird ( $\frac{\text{ared}_a}{\text{pred}_a} < \mu_0$ ) und/oder ob der Trust-Region verkleinert ( $\frac{\text{ared}_a}{\text{pred}_a} < \underline{\mu}$ ), vergrößert ( $\frac{\text{ared}_a}{\text{pred}_a} > \bar{\mu}$ ) oder unverändert belassen werden soll.

Die Änderung von  $\Delta$  wird mit Hilfe von  $0 < \underline{\omega} < 1 < \bar{\omega}$  durchgeführt. Weiter sei  $C > 1$ .

**ALGORITHMUS 5.7**

**Input:**  $x_a \in \mathbb{R}^n$ ,  $x_V \in \mathbb{R}^n$ ,  $\Delta \in \mathbb{R}^+$

**Begin**

$z^0 := x_a$ ;  $z_V^0 := x_V$ ;  $\hat{\Delta}^{(0)} := \Delta$ ;  $l := 0$

**While**  $z^l = x_a$

$\text{ared}^{(l)} := f(x_a) - f(z_V^l)$ ;  $d_V^l := z_V^l - x_a$ ;

$\text{pred}^{(l)} := -\nabla f(x_a)^T d_V^l - \frac{1}{2}(d_V^l)^T H_a d_V^l$

**If**  $\frac{\text{ared}^{(l)}}{\text{pred}^{(l)}} < \mu_0$

$z^{l+1} := x_a$ ,  $\hat{\Delta}^{(l+1)} := \underline{\omega} \hat{\Delta}^{(l)}$

**If**  $l > 1$  &  $\hat{\Delta}^{(l)} > \hat{\Delta}^{(l-1)}$

$z^{l+1} := z_V^l$

**Else**

berechne die Lösung  $d_V^{l+1}$  des T.-R.-Hilfsproblems mit Radius  $\hat{\Delta}^{(l+1)}$

$z_V^{l+1} := x_a + d_V^{l+1}$

**End(If)**

**Elseif**  $\mu_0 \leq \frac{\text{ared}^{(l)}}{\text{pred}^{(l)}} \leq \underline{\mu}$

$z^{l+1} := z_V^l$ ;  $\hat{\Delta}^{(l+1)} := \underline{\omega} \hat{\Delta}^{(l)}$

**Elseif**  $\underline{\mu} \leq \frac{\text{ared}^{(l)}}{\text{pred}^{(l)}} \leq \bar{\mu}$

$z^{l+1} := z_V^l$

**Elseif**  $\bar{\mu} \leq \frac{\text{ared}^{(l)}}{\text{pred}^{(l)}}$

**If**  $\|d_V^l\| = \hat{\Delta}^{(l)} \leq C \|\nabla f(x_a)\|$

$z^{l+1} := z_V^l$ ;  $\hat{\Delta}^{(l+1)} := \bar{\omega} \hat{\Delta}^{(l)}$

berechne die Lösung  $d_V^{l+1}$  des T.-R.-Hilfsproblems mit Radius  $\hat{\Delta}^{(l+1)}$

$z^{l+1} := x_a + d_V^{l+1}$

**Else**

$z^{l+1} := z_V^l$

**End(If)**

**End(If)**

$l := l + 1$

**End(While)**

$x_+ := z^l$ ;  $\Delta_+ := \hat{\Delta}^{(l)}$

**End**

In Algorithmus 5.6 ist der Trust-Region nach oben durch  $C \|\nabla f(x_a)\|$  beschränkt. Die **While**-Schleife sollte nach endlich vielen Schritten terminieren.

**ALGORITHMUS 5.8 (Trust-Region-Framework)**

**Input:**  $x^0 \in \mathbb{R}^n$ ;  $\Delta_0 \in \mathbb{R}_+$

**Begin**

$k := 0$ ;  $\tau_0 := \|\nabla f(x^0)\|$

**While**  $\|\nabla f(x^k)\| > \tau_r \tau_0 + \tau_a$

berechne eine Approximation  $H^k$  der Hessematrix  $\nabla^2 f(x^k)$   
 berechne  $d_V^k$  als Lösung von

$$\min f(x^k) + \nabla f(x^k)d + \frac{1}{2}d^T H^k d \text{ u.d.N. } \|d\| \leq \Delta_k$$

berechne  $(x^{k+1}, \Delta_{k+1})$  mit Algorithmus 5.6 mit **Input**  $x^k$ ;  $x_V^k := x^k + d_V^k$ ;  $\Delta_k$   
 $k := k + 1$

**End(While)**

**End**

**5.3.2 Globale Konvergenz des Trust-Region-Verfahrens****ANNAHME 5.9**

(a) Es existiere ein  $\sigma > 0$ , so dass

$$\text{pred}_a = m_a(x_a) - m_a(x_V) = f(x_a) - m_a(x_V) \geq \sigma \|\nabla f(x_a)\| \min\{\|d_V\|, \|\nabla f(x_a)\|\} \quad (5.5)$$

(b) Es existiere  $M > 0$ , so dass

$$\|d_V\| \geq \frac{\|\nabla f(x_a)\|}{M} \quad \text{oder} \quad \|d_V\| = \Delta_a. \quad \blacklozenge$$

**SATZ 5.10**

Sei  $\nabla f$  Lipschitz-stetig mit Konstante  $L > 0$ . Sei die Folge  $(x_n)_{n \in \mathbb{N}}$  erzeugt von Algorithmus 5.7 und es sei angenommen, dass die Lösungen des Trust-Region-Hilfsproblems Annahme 5.8 erfüllen. Ferner seien die Matrizen  $(H^k)_{k \in \mathbb{N}}$  beschränkt.

Dann ist entweder  $f$  nach unten unbeschränkt,  $\nabla f(x^k) = 0$  für ein  $k$  oder  $\lim_{k \rightarrow \infty} \|\nabla f(x^k)\| = 0$ .

Eine einfache Idee zur Lösung des Hilfsproblems beruht auf Fixieren der Richtung gemäß des Verfahrens des steilsten Abstiegs unter Berücksichtigung des Trust-Regions.

Seien  $x_a$  die aktuelle Iterierte und  $\Delta_a$  der aktuelle Trust-Region-Radius. Der Versuchspunkt  $x_V = x_V(t)$  ist dann definiert über die Minimalstelle  $t_a$  von

$$\begin{cases} \min_{t \geq 0} \psi_a(t) := m_a(x_a - t\nabla f(x_a)) \\ \text{u.d.N. } x_V(t) - x_a = x_a - t\nabla f(x_a) - x_a = -t\nabla f(x_a) \in \mathcal{T}(\Delta_a) \end{cases}$$

Es gelten

$$\begin{aligned} \psi(t) &= m_a(x_a - t\nabla f(x_a)) \\ &= f(x_a) - t\|\nabla f(x_a)\|^2 + \frac{t^2}{2} \nabla f(x_a)^T H_a \nabla f(x_a) \end{aligned}$$

und

$$\psi'(t) = -\|\nabla f(x_a)\|^2 + \frac{t}{2} \nabla f(x_a)^T H_a \nabla f(x_a).$$



Fallunterscheidung zur Bestimmung von  $t_a$ :

(a)  $\nabla f(x_a)^T H_a \nabla f(x_a) \leq 0$ : Offensichtlich wird die Trust-Region-Restriktion aktiv, d.h.

$$\|x_V(t_a) - x_a\| = t_a \|\nabla f(x_a)\| = \Delta_a \Rightarrow t_a = \frac{\Delta_a}{\|\nabla f(x_a)\|}.$$

(b)  $\nabla f(x_a)^T H_a \nabla f(x_a) > 0$ : Dann impliziert  $\psi'(\hat{t}_a) \stackrel{!}{=} 0$

$$\hat{t}_a = \frac{\|\nabla f(x_a)\|^2}{\nabla f(x_a)^T H_a \nabla f(x_a)}.$$

Falls  $\|x_V(\hat{t}_a) - x_a\| \leq \Delta_a \Rightarrow t_a := \hat{t}_a$ . Andernfalls ist die Trust-Region-Restriktion aktiv, d.h.

$$t_a = \frac{\Delta_a}{\|\nabla f(x_a)\|}.$$

Zusammenfassend:

$$t_a = \begin{cases} \frac{\Delta_a}{\|\nabla f(x_a)\|} & \text{falls } \nabla f(x_a)^T H_a \nabla f(x_a) \leq 0 \\ \min\left\{ \frac{\Delta_a}{\|\nabla f(x_a)\|}, \frac{\|\nabla f(x_a)\|^2}{\nabla f(x_a)^T H_a \nabla f(x_a)} \right\} & \text{sonst} \end{cases}.$$

Die Minimalstelle  $x_V(t_a)$  ( $:= x_a - t_a \nabla f(x_a)$ ) des quadratischen Modells  $m_a$  in Richtung des negativen Gradienten heißt **Cauchy-Punkt** (Bezeichnung:  $x_a^{\text{CP}}$ ). Man kann zeigen, dass der Cauchy-Punkt Annahme 5.8 erfüllt.

#### BEMERKUNG 5.11

- (a) Die Verwendung des Cauchy-Punktes führt zwar zu globaler Konvergenz, aber unter Umständen ist die Konvergenzgeschwindigkeit lokal nur linear.
- (b) „*dogleg-Technik*“ leistet einen „glatten“ Übergang von der Richtung des steilsten Abstiegs zur Newton-Richtung.

Lokal liegt dann quadratische Konvergenz vor, wenn  $H^k = \nabla^2 f(x^k)$ ,  $k \in \mathbb{N}$ , gilt. ◆

## 6 Quasi-Newton-Verfahren

Nachteile des Newton-Verfahrens:

- zweite Ableitungen benötigt
- positive Definitheit
- $\mathcal{O}(n^3)$  Multiplikationen (Lösung des linearen Systems mit direktem Verfahren).

**QN-Verfahren:**

- approximieren zweite Ableitungen durch erste Ableitungen
- positive Definitheit bleibt erhalten (bei einigen QN-Verfahren)
- $\mathcal{O}(n^2)$  Multiplikationen (bei einigen QN-Varianten)

$H^k$  wird von Iteration zu Iteration aufdatiert.

Allgemeine Grundstruktur:

- Setze  $d^k := -(H^k)^{-1} \nabla f(x^k)$ .
- Bestimme  $x^{k+1} := x^k + t_k d^k$  mit Schrittweitenstrategie.
- Verwende  $x^k, x^{k+1}, H^k$ , um  $H^k$  zu  $H^{k+1}$  aufzudatieren.

Der letzte Punkt der QN-Vorteile gilt für Varianten, die direkt  $\nabla f(x^k)^T$  approximieren und somit die Lösung des Gleichungssystems ersparen.

Die positive Definitheit der Matrix  $H^k$  ist nicht bei allen QN-Verfahren gegeben.

Aufdatierungsformeln für  $H$ :

Seien  $s_a := t_a d_a (= -t_a H_a^{-1} \nabla f(x_a))$ ,  $y_a := \nabla f(x_+) - \nabla f(x_a)$ ,  $x_+ := x_a + s_a$ .

Es gilt

$$\begin{aligned} y_a &= \nabla f(x_+) - \nabla f(x_a) \\ &= \nabla f(x_a) + \nabla^2 f(x_a)(x_+ - x_a) + \mathcal{O}(\|x_+ - x_a\|) - \nabla f(x_a) \\ &= \nabla^2 f(x_a) s_a + \mathcal{O}(\|x_+ - x_a\|) + \mathcal{O}(\|s_a\|). \end{aligned}$$

Nahe liegende Forderung für  $H_+$  (Update von  $H_a$ ):

$$H_+ s_a = y_a. \quad (\text{QN-Bedingung oder Sekantenbedingung}) \quad (6.1)$$

Ein einfacher Ansatz für  $H_+$  in (6.1) ist

$$H_+ := H_a + \alpha u u^T. \quad (\text{symmetrische Rang 1-Korrektur})$$

Einsetzen in (6.1) liefert

$$\begin{aligned} H_+ s_a &= H_a s_a + \alpha \underbrace{u u^T}_{\in \mathbb{R}} s_a = y_a \\ \Rightarrow u &\text{ proportional zu } y_a - H_a s_a \\ \Rightarrow u &= y_a - H_a s_a \text{ (die Länge in } \alpha \text{ berücksichtigt)} \\ \alpha(u^T s_a) &= 1, \text{ d.h. } \alpha = \frac{1}{y_a^T s_a - s_a^T H_a s_a}. \end{aligned}$$

Also:

$$H_+ = H_a + \frac{(y_a - H_a s_a)(y_a - H_a s_a)^T}{(y_a - H_a s_a)^T s_a}.$$

Nachteile:

- positive Definitheit geht meist verloren
- $y_a - H_a s_a$  nahe bei 0.

Flexibler sind Rang 2-Korrekturen:

$$H_+ := H_a + \alpha u u^T + \beta v v^T. \quad (6.2)$$

Einsetzen in (6.1):

$$H_+ s_a = H_a s_a + \alpha u (u^T s_a) + \beta v (v^T s_a) = y_a.$$

Die Vektoren  $u$  und  $v$  sind nicht mehr eindeutig bestimmt.

Es bietet sich an,

$$u := y_a \quad \text{und} \quad v := H_a s_a$$

zu wählen.

$$\begin{aligned} H_a s_a + \alpha y_a y_a^T s_a + \beta (H_a s_a) (H_a s_a)^T s_a &= y_a \\ \Leftrightarrow \alpha y_a (y_a^T s_a) + \beta H_a s_a (s_a^T H_a s_a) &= y_a - H_a s_a \\ \Rightarrow \alpha (y_a^T s_a) = 1 \quad \text{und} \quad \beta (s_a^T H_a s_a) &= -1 \\ \Rightarrow \alpha = \frac{1}{y_a^T s_a} \quad \text{und} \quad \beta = \frac{-1}{s_a^T H_a s_a}. \end{aligned}$$

Also (*Broyden/Fletcher/Goldfarb/Shanno*)

$$H_+ = H_a + \frac{y_a y_a^T}{y_a^T s_a} - \frac{H_a s_a (H_a s_a)^T}{s_a^T H_a s_a} \quad \text{(BFGS-Formel)} \quad (6.3)$$

Man kann auch  $\nabla^2 f(x^k)^{-1}$  approximieren durch  $B^k$ . Die QN-Bedingung lautet dann

$$B_+ y_a = s_a. \quad (6.4)$$

Verwenden wir die symmetrische Rang 2-Korrektur analog zu (6.4) mit  $u := s_a$  und  $v := B_a y_a$ , dann erhalten wir

$$B_+ = B_a + \frac{s_a s_a^T}{s_a^T y_a} - \frac{(B_a y_a) (B_a y_a)^T}{y_a^T B_a y_a} \quad \text{(DFP-Formel)} \quad (6.5)$$

nach *Davidon/Fletcher/Powell*.

#### LEMMA 6.1

Seien  $H_a \in \mathcal{S}_n$  positiv definit,  $y_a^T s_a > 0$  und  $H_+$  gemäß (6.3) bestimmt.

Dann ist  $H_+$  symmetrisch und positiv definit.

#### BEWEIS

$H_a$  positiv definit und  $y_a^T s_a \neq 0$  liefern für alle  $z \neq 0$

$$\begin{aligned} z^T H_+ z &= z^T H_a z + \frac{z^T y_a y_a^T z}{y_a^T s_a} - \frac{z^T (H_a s_a) (H_a s_a)^T z}{s_a^T H_a s_a} \\ &= \frac{(z^T y_a)^2}{y_a^T s_a} + z^T H_a z - \frac{(z^T H_a s_a)^2}{s_a^T H_a s_a}. \end{aligned}$$

Da  $H_a$  symmetrisch und positiv definit ist, existiert  $H_a^{\frac{1}{2}}$  mit  $H_a = H_a^{\frac{1}{2}} H_a^{\frac{1}{2}}$ . Damit gilt

$$z^T H_a s_a = z^T H_a^{\frac{1}{2}} H_a^{\frac{1}{2}} s_a \leq \|H_a^{\frac{1}{2}} z\| \|H_a^{\frac{1}{2}} s_a\|$$

bzw.

$$(z^T H_a s_a)^2 \leq \underbrace{\|H_a^{\frac{1}{2}} z\|^2}_{z^T H_a z} \underbrace{\|H_a^{\frac{1}{2}} s_a\|^2}_{s_a^T H_a s_a},$$

d.h.

$$z^T H_a z - \frac{(z^T H_a s_a)^2}{s_a^T H_a s_a} \geq z^T H_a z - z^T H_a z = 0.$$

Ferner

$$z^T H_a z - \frac{(z^T H_a s_a)^2}{s_a^T H_a s_a} = 0,$$

wenn  $H_a^{\frac{1}{2}}z$  und  $H_a^{\frac{1}{2}}s_a$  linear abhängig sind. Da  $H_a^{\frac{1}{2}}$  regulär ist, gilt zu diesem Fall  $z = \lambda s_a \neq 0$ , d.h.  $\lambda \neq 0$ . Also

$$z^T y_a = \lambda s_a^T y_a \neq 0$$

und somit

$$z^T H_a z \begin{cases} \geq \frac{(z^T y_a)^2}{y_a^T s_a} > 0 & \text{für } H_a^{\frac{1}{2}}z = \lambda H_a^{\frac{1}{2}}s_a \\ > \frac{(z^T y_a)^2}{y_a^T s_a} \geq 0 & \text{sonst} \end{cases} . \quad \blacksquare$$

Die Bedingung  $y_a^T s_a > 0$  ist realistisch. Für quadratische Probleme, d.h. von der Form

$$f(x) = \frac{1}{2}x^T Gx + g^T x + b$$

mit symmetrischer, positiv definiter Hessematrix  $G$ , gilt die Beziehung

$$y_a^T s_a = (\nabla f(x_+) - \nabla f(x_a))^T (x_+ - x_a) = (x_+ - x_a)^T G(x_+ - x_a) > 0 \quad \text{für } x_+ \neq x_a.$$

Für allgemeine Probleme wird  $y_a^T s_a > 0$  durch Verwendung von Schrittweitenstrategien (Wolfe-Powell) sicher gestellt.

**SATZ 6.2 (lokale Konvergenz)**

Es sei Annahme (A) erfüllt. Dann existiert ein  $\delta > 0$ , so dass für

$$\|x^0 - x^*\| \leq \delta \quad \text{und} \quad \|H^0 - \nabla^2 f(x^*)\| \leq \delta$$

die BFGS-Methode wohldefiniert ist und superlinear gegen ein  $x^*$  konvergiert, d.h.

$$\lim_{k \rightarrow \infty} \frac{\|x^{k+1} - x^*\|}{\|x^k - x^*\|} = 0.$$

# Index

Abstiegsrichtung .....	9
Abstiegsverfahren	
allgemeines .....	10
global konvergentes .....	10
Algorithmus	
Allgemeines Abstiegsverfahren .....	10
Armijo-Schrittweitenstrategie .....	11
Trust-Region-Framework .....	24
Trust-Region-Methode .....	23
Wolfe-Powell-Algorithmus .....	13
Armijo-Regel .....	11
Backtracking .....	12
Bedingung	
erster Ordnung .....	4
zweiter Ordnung .....	5
BFGS-Formel .....	27
Cauchy-Punkt .....	25
CG-Verfahren .....	21
Definitheit der Hessematrix .....	4
DFP-Regel .....	27
dogleg-Technik .....	25
Fehlerfunktion .....	19
globalisiertes Newton-Verfahren .....	22
Gradient .....	3
gradientenähnlich .....	17
gradientenähnliche Richtungen .....	11
Gradientenverfahren .....	16
Hessematrix .....	4
inexakte Newton-Iteration .....	21
inexaktes Newton-Verfahren .....	21
konvex	
gleichmässig .....	7
strikt .....	7
konvexe Funktion .....	7
konvexe Menge .....	7
Maschinen-Epsilon .....	19
Maximalstelle	
globale .....	3
lokale .....	3
strikte globale .....	3
strikte lokale .....	3
Minimalstelle	
globale .....	3
lokale .....	3
strikte globale .....	3
strikte lokale .....	3
Minimum	
globales .....	3
lokales .....	3
striktes globales .....	3
striktes lokales .....	3
Modell .....	12
Modul .....	7
Nebenbedingung .....	3
Newton-Iterationsmatrix .....	22
Newton-Schritt .....	18
Newton-Verfahren .....	18
Niveaumenge .....	7
Optimalitätskriterien .....	4
Optimierungsproblem	
diskretes .....	3
endlichdimensionales .....	3
kombinatorisches .....	3
nicht-differenzierbares .....	3
restringiertes .....	3
stetiges .....	3
unrestringiertes .....	3
QN-Bedingung .....	26
QN-Verfahren .....	26
Reduktion	
erwartete .....	22
tatsächliche .....	22
Restriktion	
Ganzzahligkeits- .....	3
Gleichungs- .....	3
Ungleichungs- .....	3
Sattelpunkt .....	6
Schrittweite .....	11
Schrittweitenstrategie .....	9
spektrale Konditionszahl .....	16
Spektralnorm .....	4
stationärer Punkt .....	3
steilster Abstieg .....	9
superlinear .....	21
symmetrische Rang 1-Korrektur .....	26
TR-Methoden .....	22
Trust-Region-Radius .....	22
Trust-Region .....	22
Versuchslösung .....	22
Vorwärtsdifferenz .....	19
Winkelbedingung .....	10
Wolfe-Powell-Regel, strenge .....	14
Wolfe-Powell-Regel .....	12
zentrale Differenz .....	19
Zielfunktion .....	3
Zulässigkeitsbereich .....	3

## Literatur

- [1] C. T. Kelley: *Iterative Methods for Optimization*. SIAM Frontiers in Applied Mathematics, Philadelphia, 1999  
[http://www.siam.org/books/textbooks/fr18\\_book.pdf](http://www.siam.org/books/textbooks/fr18_book.pdf)
- [2] J. Nocedal und S. J. Wright: *Numerical Optimization*. Springer-Verlag, 2006
- [3] S. Volkwein: *Numerische Verfahren der restringierten Optimierung*. Vorlesungsscript, 2009.  
<http://www.math.uni-konstanz.de/numerik/personen/volkwein/teaching/Optimierung2.pdf>