

5. Optimierungsprobleme

- Betrachten hier nur endlichdimensionale Optimierungsprobleme (OP) der Form:

Finde $\underline{x}^* \in \mathbb{R}^n$:

(1) $f(\underline{x}^*) = \min_{\underline{x} \in \Omega_{ad}} f(\underline{x})$ bzw. $\max_{\underline{x} \in \Omega_{ad}} (-f(\underline{x}))$

wobei

$\Omega = \Omega_{ad} \subset \mathbb{R}^n$ - Zulässigkeitsmenge / ~ bereich,
 $\underline{x} = (x_1, x_2, \dots, x_n)^T \in \Omega_{ad}$ zulässiger Punkt,
 $f: \mathbb{R}^n \rightarrow \mathbb{R}$ - Zielfunktion = Kostenfunktional,

- Großdimensionale Optimierungsprobleme der Form (1) entstehen z.B. bei der FEM-Diskretisierung
 - des Optimalsteuerproblems (optimal control) bzw.
 - des Formoptimierungsproblems (optimal design)
 (= unendlichdimensionale Optimierungsprobleme)
 aus Kapitel 1, z.B. Optimalsteuerproblem aus Kapitel 1 nach FEM-Diskretisierung (\rightarrow 39b)

$$\min_{\underline{x} = (\underline{y}, \underline{u}) \in \mathbb{R}^{n_s + n_c}} \overbrace{\frac{1}{2} (M \underline{y}, \underline{y}) - (\underline{y}_d, \underline{y}) + \frac{1}{2} \int_{\Omega} \cancel{y^2(x)} dx}^{f(\underline{x})} + \frac{\alpha}{2} (M_c \underline{u}, \underline{u})$$

$= const$

s.t. $K \underline{y} = M_c \underline{u}$ $c_i(\underline{x}) = (K \underline{y} - M_c \underline{u})_i = 0, i = 1, \dots, n_s = m_1$

$$\left. \begin{array}{l} \underline{y}_i \leq y_i \leq \bar{y}_i \\ \underline{u}_i \leq u_i \leq \bar{u}_i \end{array} \right\} \begin{array}{l} \underline{y}_i - y_i \leq 0 \\ y_i - \bar{y}_i \leq 0 \\ \underline{u}_i - u_i \leq 0 \\ u_i - \bar{u}_i \leq 0 \end{array} \quad \left. \begin{array}{l} c_i(\underline{x}) \leq 0, i = \overline{m_1 + 1, m_2 + m_1} \\ m_2 = 2n_s + 2n_c \end{array} \right\}$$

wobei $K = \left[\int_{\Omega} A(x) \nabla \varphi_j \cdot \nabla \varphi_i dx \right]_{i,j=1:n_s}$ - Steifigkeitsmatrix,
 $M_c = \left[\int_{\Omega} \varphi_j \cdot \varphi_i dx \right]_{i=1:n_s, j=1:n_c}$ - Massematrix, $\underline{y}_d = \dots$

■ Beispiel aus Kapitel 1: Optimalsteuerproblem

$$\min_{y \in Y, u \in U} J(y, u) := \frac{1}{2} \int_{\Omega} (y(x) - y_d(x))^2 dx + \frac{\alpha}{2} \int_{\Omega} (u(x))^2 dx$$

$$\text{s.t. } \left. \begin{array}{l} -\operatorname{div}(A(x) \nabla y(x)) = u(x), \quad x \in \Omega \\ + \text{BC: } y(x) = g(x) := 0, \quad x \in \Gamma \end{array} \right\} \text{(PDE const.)}$$

$$\text{State constraints: } \underline{y}(x) \leq y(x) \leq \bar{y}(x), \quad x \in \Omega$$

$$\text{Control constr.: } \underline{u}(x) \leq u(x) \leq \bar{u}(x), \quad x \in \Omega$$

Die Variationsformulierung der PDE ergibt schließlich das folgende unendlichdim. restr. OP:

$$\min_{y \in \tilde{H}^1(\Omega), u \in L_2(\Omega)} \frac{1}{2} \int_{\Omega} (y(x) - y_d(x))^2 dx + \frac{\alpha}{2} \int_{\Omega} (u(x))^2 dx$$

$$\text{s.t. } \int_{\Omega} A(x) \nabla y(x) \cdot \nabla v(x) dx = \int_{\Omega} u(x) v(x) dx \quad \forall v \in \tilde{H}^1(\Omega)$$

$$\underline{y}(x) \leq y(x) \leq \bar{y}(x), \quad x \in \Omega$$

$$\underline{u}(x) \leq u(x) \leq \bar{u}(x), \quad x \in \Omega$$

Dre FEM - Diskretisierung

$$y \in \tilde{H}^1(\Omega) \approx y_h(x) = \sum_{i=1}^{n_s} y_i \varphi_i(x) \in Y_h, \quad \dim Y_h = n_s$$

$$u \in L_2(\Omega) \approx u_h(x) = \sum_{i=1}^{n_c} u_i \varphi_i(x) \in \tilde{U}_h, \quad \dim \tilde{U}_h = n_c$$

ergibt das endlichdimensionale restringierte OP:

$$\min_{x = (\underline{y}_h, \underline{u}_h) \in \mathbb{R}^n} \frac{1}{2} (M_s \underline{y}, \underline{y}) - (\underline{y}_d, \underline{y}) + \frac{1}{2} \int_{\Omega} (y(x))^2 dx + \frac{\alpha}{2} (M_c \underline{u}, \underline{u})$$

$$\text{s.t. } K_h \underline{y}_h = M_{sch} \underline{u}_h$$

$$\underline{y}_i \leq y_i \leq \bar{y}_i, \quad i = \overline{1, n_s}$$

$$\underline{u}_j \leq u_j \leq \bar{u}_j, \quad j = \overline{1, n_c}$$

K - Steifigkeitsmatrix
 M_s, M_c, M_{sch} -
 Massenmatrizen

Zwei große Klassen von Optimierungsproblemen:

1. Frei (unrestringierte) Optimierung: $\Omega_{\text{ad}} = \mathbb{R}^n$

2. Optimierung mit Nebenbedingungen (restringierte OP):

Wir beschränken uns auf den Fall, daß sich

Ω_{ad} durch m_1 Gleichungsrestriktionen und
 m_2 Ungleichungsrestriktionen

beschreiben lässt, d.h.

$$\Omega_{\text{ad}} = \left\{ x \in \mathbb{R}^n : \begin{array}{l} c_i(x) = 0, \quad i = \overline{1, m_1} \text{ (Gleichungsrestr.)}, \\ c_i(x) \leq 0, \quad i = \overline{m_1+1, m_1+m_2} \text{ (Ungleichungsrestr.)} \end{array} \right\}$$

mit gegebenen Funktionen $c_i: \mathbb{R}^n \rightarrow \mathbb{R}$, $i = 1, 2, \dots, m_1+m_2$:

$\underline{x} \mapsto x$

(1) _{POP}

$$\min_{x \in \mathbb{R}^n} f(x)$$

$$\text{s.t. } c_i(x) = 0, \quad i = 1, 2, \dots, m_1$$

$$c_i(x) \leq 0, \quad i = m_1+1, \dots, m_1+m_2$$

(equality const.)

(ineq. constraints)

Je nach Komplexität der beteiligten FKten $f(\cdot)$ und $c_i(\cdot)$ unterscheidet man genauer folgende OP nach aufsteigender Schwierigkeit:

- 1) Lineare Optimierung: $f(\cdot)$ und $c_i(\cdot)$ affine linear.
- 2) Quadratische Opt.: f quadratisch, c_i linear.
- 3) Nichtlineare Optimierung mit linearen NB:
 f - nichtlinear, c_i - linear.
- 4) Nichtlineare Optimierung mit nichtlinearen NB:
 f - nichtlinear, c_i - nichtlinear.

wobei $g: \mathbb{R}^n \rightarrow \mathbb{R}$ heißt

- linear, falls $g(x) = g_0 + c^T x$ mit geg. $g_0 \in \mathbb{R}$, $c \in \mathbb{R}^n$,
- quadratisch, falls $g(x) = g_0 + c^T x + \frac{1}{2} x^T H x$, $H \in \mathbb{R}^{n \times n}$.

Simplex
Alg.

affine

■ Bem. 5.1: $\Omega_{adj} = \{z_1, z_2, \dots, z_N\}$

1. Ω_{adj} -endlich: Kombinatorische Optimierung
2. $\Omega_{adj} \subset \mathbb{Z}^N$: Ganzzahlige Optimierung

■ Def. 5.2: globales und lokales Minimum (Maximum)

1. Ein Pkt. $x^* \in \Omega_{adj}$ heißt (strikt) globales Min., falls
 $f(x^*) \leq f(x)$ ($f(x^*) < f(x)$) $\forall x \in \Omega_{adj}; x \neq x^*$.

2. Ein Pkt. $x^* \in \Omega$ heißt (strikt) lokales Minimum, falls $\exists \varepsilon > 0$:

$$f(x^*) \leq f(x) \quad (f(x^*) < f(x)) \quad \forall x \in U_\varepsilon(x^*); x \neq x^*,$$

wobei $U_\varepsilon(x^*) := \{x \in \Omega_{adj}; \|x - x^*\| < \varepsilon\}$.
 ε -Umgebung von x^*

Bem.: • $\max f(x) \iff \min(-f(x))$

- In den meisten Fällen ist man an einem globalen Min. interessiert.
- Viele Alg. garantieren aber nur die Konst. von lok. Min. !!!

■ Bem. 5.3: Konvexe Optimierungsprobleme

Für OP mit konvexer Zielfunktion f und konvexem Zulässigkeitsbereich Ω_{adj} ist jedes lokale Minimum auch ein globales Minimum.

Wh: Konvexität für f und Ω_{adj} :

$\Omega \subset \mathbb{R}^n = \text{Konvex}$ gdw. $\forall x, y \in \Omega_{adj} \wedge \forall \alpha \in [0, 1]:$

$$\alpha x + (1-\alpha)y \in \Omega_{adj}.$$

$f: \mathbb{R}^n \rightarrow \mathbb{R} = \text{Konvex}$ gdw. $\forall x, y \in \mathbb{R}^n \wedge \forall \alpha \in [0, 1]:$

$$f(\alpha x + (1-\alpha)y) \leq \alpha f(x) + (1-\alpha)f(y)$$



5.1. Freie Optimierungsprobleme

- In diesem Abs. betr. wir das frei (unrestringierte) OP

$$(1)_{\text{fop}} \quad \boxed{\text{Finde } x^* \in \Omega_{\text{ad}} = \mathbb{R}^n : f(x^*) = \min_{x \in \mathbb{R}^n} f(x)}$$

- Im Kapitel 3 haben wir schon das quadratische freie OP

$$(3.13) \quad f(x) := E(x) := \frac{1}{2} (\overset{\text{SPD}}{\downarrow} A x, x) - (b, x) \longrightarrow \min_{x \in \mathbb{R}^n} !$$

Kennengelernt und gezeigt, daß

$$f(x^*) = \min_{x \in \mathbb{R}^n} f(x) \iff A x^* = b$$

5.1.1. Theoretische Grundlagen

- Sei $f: \mathbb{R}^n \rightarrow \mathbb{R}$ eine zumindest zweimal stetig partiell differenzierbare Fkt, d.h. $f \in C^2$.

Dann ist $g = \text{grad } f = \nabla f: \mathbb{R}^n \rightarrow \mathbb{R}^n$ durch

$$g(x) = \nabla f(x) = f'(x)^T = \begin{bmatrix} \frac{\partial f}{\partial x_1}(x) \\ \frac{\partial f}{\partial x_2}(x) \\ \vdots \\ \frac{\partial f}{\partial x_n}(x) \end{bmatrix} = \left[\frac{\partial f}{\partial x_i}(x) \right]_{i=1, \dots, n}$$

gegeben. $g(x)$ heißt Gradient der Funktion f an der Stelle x .

Der Hessian $H: \mathbb{R}^n \rightarrow \mathbb{R}^{n \times n}$ ist durch

$$H(x) = \nabla^2 f(x) = \begin{bmatrix} \frac{\partial^2 f}{\partial x_1^2}(x) & \dots & \frac{\partial^2 f}{\partial x_1 \partial x_n}(x) \\ \vdots & & \vdots \\ \frac{\partial^2 f}{\partial x_n \partial x_1}(x) & \dots & \frac{\partial^2 f}{\partial x_n^2}(x) \end{bmatrix} = H^T(x)$$

↑ Satz von Schwarz

gegeben. $H(x)$ nennt man die Hesse-Matrix von f an der Stelle x . Die Hesse-Matrix ist symmetrisch

Aus der Taylor-Darstellung

f-quadr.

= 0

$$\begin{aligned} n=1 & \quad f(x) = f(x^*) + f'(x^*)(x-x^*) + \frac{1}{2}(x-x^*)f''(x^*)(x-x^*) + o(\|x-x^*\|^2) \\ n \geq 1 & \quad (2) \quad f(x) = f(x^*) + \nabla^T f(x^*)(x-x^*) + \frac{1}{2}(x-x^*)^T H(x^*)(x-x^*) + o(\|x-x^*\|^2) \\ f(x) & \geq f(x^*) \quad \begin{matrix} \parallel \\ 0 \\ \text{notwendig} \end{matrix} \quad \begin{matrix} \geq 0 \\ \parallel \\ \text{hinreichend} \end{matrix} \end{aligned}$$

folgen sofort **notwendige** und **hinreichende** Bedingungen für ein lokales Minimum von f :

• Satz 5.4: (notwendige Bedingung)

Sei $x^* \in \mathbb{R}^n$ ein lokales Minimum (Maximum) von f . Dann gilt:

$$(3) \quad \nabla f(x^*) = 0 \quad (= \text{nichtl. GS } \boxed{F(x)=0} \text{ in } \mathbb{R}^n)$$

• Satz 5.5: (hinreichende Bedingung)

Falls $x^* \in \mathbb{R}^n$ ein kritischer Punkt von f ist, d.h. eine Lösung des nichtlinearen GS (3) ist, und $H(x^*)$ positiv (definit) ist, dann ist $x^* \in \mathbb{R}^n$ ein (striktes) lokales Minimum.

• Bem. 5, 6:

1. Ein Pkt. $x^* \in \mathbb{R}^n$: $\nabla f(x^*) = 0$ wird stationär oder Kritischer Pkt. genannt.
2. Nach Satz 5.5 ist ein Kritischer Pkt. $x^* \in \mathbb{R}^n$ mit p.d. Hesse-Matrix $H(x^*)$ ein striktes lokales Minimum.
3. Offenbar ist dann ein Kritischer Pkt. $x^* \in \mathbb{R}^n$ mit n.d. Hesse-Matrix (d.h. $-H(x^*)$ ist p.d.) ein striktes lokales Maximum.
4. Ein Kritischer Pkt. $x^* \in \mathbb{R}^n$ mit indefinit Hesse-Matrix $H(x^*)$, d.h. $H(x^*)$ ist weder positiv noch negativ definit, heißt Sattelpkt.
5. Idee für numerische Lösungsverfahren:
 - 1) Löse nichtlineares GS

$$(4) \quad F(x) := \nabla f(x) = 0 \text{ in } \mathbb{R}^n,$$

z.B. mit Newton-Verfahren (\downarrow),
um Kritische Punkte x^* zu finden!

2) Check Definitheit der Hesse-Matrix:

$\oplus \neq H(x^*)$	> 0 (SPD)	\Rightarrow striktes lok. Min.
	≥ 0	\Rightarrow (lokales Minimum)
	< 0	\Rightarrow striktes lok. Max
	≤ 0	\Rightarrow (lokales Maximum)
	indefinit	\Rightarrow Sattelpunkt
	$= 0$	\Rightarrow Check höhere Terme in der Taylorentw. (2)
	im Punkt x^* !	

6. Umgekehrt kann man Lösungen des nichtlin. GS (4) finden, indem man das OP (1) fop $\min f(x)$ bzw. $\max f(x)$ löst.

5.1.2. Abstiegsverfahren

- Ein typischer Iterationsschritt eines Abstiegsverfahren zur Lösung freier OP

(1) f_{OP} Finde $x^* \in \mathbb{R}^n : f(x^*) = \min_{x \in \mathbb{R}^n} f(x)$

hat im Allgemeinen die Form:

(5) $\left\{ \begin{array}{l} 1. \text{ Bestimme, ausgehend von einer Naherung } x^{(k)} \in \mathbb{R}^n, \\ \text{eine Suchrichtung } s^{(k)} \in \mathbb{R}^n \text{ (} \rightarrow \text{Abstiegsrichtung).} \\ 2. \text{ Bestimme eine Schrittweite } \alpha^{(k+1)} > 0 \text{ mit} \\ f(x^{(k)} + \alpha^{(k+1)} s^{(k)}) < f(x^{(k)}) \text{ (} \rightarrow \text{Linienuche)} \\ 3. \text{ Setze } x^{(k+1)} = x^{(k)} + \alpha^{(k+1)} s^{(k)}. \end{array} \right.$

- Bemerkung: Das Gradienten-Verfahren und das CG-Verfahren sowie ihre prakonditionierten Versionen aus Abs. 3.3.2 sind Verfahren der Form (5).

- Anforderungen an die Suchrichtung (} \rightarrow \text{Abstiegsricht.):

Aus der Taylor-Entwicklung (vgl. auch (2))

$$f(x^{(k)} + \alpha s^{(k)}) = f(x^{(k)}) + \alpha \nabla^T f(x^{(k)}) s^{(k)} + o(\alpha)$$

$$\approx f(x^{(k)}) + \alpha \nabla^T f(x^{(k)}) s^{(k)}$$

folgt fur hinreichend kleine Werte von $\alpha > 0$ sofort

$$f(x^{(k)} + \alpha s^{(k)}) < f(x^{(k)})$$

falls

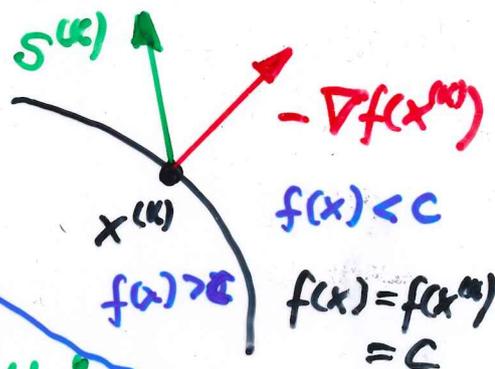
(6)

$$\nabla^T f(x^{(k)}) s^{(k)} < 0$$

$$-\nabla^T f(x) \cdot s^{(k)} > 0$$

Eine Suchrichtung $s^{(k)} \in \mathbb{R}^n$, die die Bd. (6) erfullt, heit Abstiegsricht.!

Das entsprechende Verfahren heit Abstiegsverfahren!



■ Anforderungen an die Schrittweite:

● Exakte Liniensuche:

$$\alpha^{(k+1)} > 0 : f(x^{(k)} + \alpha^{(k+1)} s^{(k)}) = \min_{\alpha > 0} f(x^{(k)} + \alpha s^{(k)})$$

Allerdings ist diese Schrittweitenwahl außer in einigen Spezialfällen (z.B. bei einer quadratischen Zielfkt. $f(x)$: siehe Abs. 3.2.2) zu aufwendig!

● Praktikable Liniensuchstrategie (→ Bisektion): z.B. $\alpha^{(k+1)} = 1, 2^{-1}, 2^{-2}, \dots$

$$(7) \alpha^{(k+1)} > 0 : f(x^{(k)} + \alpha^{(k+1)} s^{(k)}) \leq f(x^{(k)}) + \mu \alpha^{(k+1)} \nabla^T f(x^{(k)}) s^{(k)}$$

für ein fix vorgegebenes $\mu \in (0, 1)$ (→ Taylor) \wedge

$$(8) \nabla^T f(x^{(k)} + \alpha^{(k+1)} s^{(k)}) s^{(k)} \geq \sigma \nabla^T f(x^{(k)}) s^{(k)}$$

für ein fix vorgegebenes $\sigma \in (\mu, 1)$.

→ keine zu kleine Schrittweite!

■ Satz 5.7: Falls

1. die Näherungen $x^{(k)}$ eine beschränkte Folge bilden,
 2. die Schrittweiten $\alpha^{(k)}$ die Bd. (7) und (8) erfüllen, und
 3. $\exists \varepsilon > 0 : \nabla^T f(x^{(k)}) s^{(k)} \leq -\varepsilon \|\nabla f(x^{(k)})\|_2 \|s^{(k)}\|_2 < 0$,
- dann gilt: $\lim_{k \rightarrow \infty} \nabla f(x^{(k)}) = 0$.

■ Bem. 5.8:

1. $s^{(k)} = -\nabla f(x^{(k)}) \rightarrow$ GV = Verf. d. steilsten Abst.
Vor. 3 von Satz 5.7 ist mit $\varepsilon = 1$ erfüllt!
2. GV mit Liniensuche (7)-(8) konvergiert auf der Basis von Satz 5.7 unter schwachen Vor. global!
3. Allerdings konvergiert das GV nur sehr langsam!

5.1.3. Das Newton-Verfahren

- Idee: Sei $x^{(k)} \in \mathbb{R}^n$ eine Näherung an ein lok. Min. v. f .
Aus der Taylor-Entwicklung (vgl. auch (2))

$$(9) \quad f(x) = \underbrace{f(x^{(k)}) + \nabla^T f(x^{(k)})(x - x^{(k)}) + \frac{1}{2}(x - x^{(k)})^T H(x^{(k)})(x - x^{(k)})}_{=: q_k(x)} + \text{HOT} \quad \text{HOT} = o(\|x - x^{(k)}\|^2)$$

folgt, daß sich $f(x)$ in einer Umgebung $U_\varepsilon(x^{(k)})$ von $x^{(k)}$ durch die quadratische Fkt.

$$(10) \quad q_k(x) := f(x^{(k)}) + \nabla^T f(x^{(k)})(x - x^{(k)}) + \frac{1}{2}(x - x^{(k)})^T H(x^{(k)})(x - x^{(k)}) \approx f(x)$$

gut approximieren läßt!

Die nächste Iteration $x^{(k+1)}$ des Newton-Verfahrens in der Optimierung wird als Minimum der quadratischen Funktion $q_k(x)$ definiert:

$$q_k(x^{(k+1)}) = \min_{x \in \mathbb{R}^n} q_k(x). \quad \text{SQP}$$

Unter der Annahme, daß (vgl. Satz 5.5)

$$\nabla^2 q_k(x^{(k)}) = H(x^{(k)}) \quad \text{positiv definit ist,}$$

ist $x^{(k+1)}$ nach Satz 5.4 durch die Bedingung

$$\nabla q_k(x^{(k+1)}) = \nabla f(x^{(k)}) + H(x^{(k)})(x^{(k+1)} - x^{(k)}) = 0$$

eindeutig definiert, d.h.

$$(11) \quad \begin{aligned} x^{(k+1)} &= x^{(k)} - H(x^{(k)})^{-1} \nabla f(x^{(k)}) \\ &= x^{(k)} + \alpha^{(k+1)} s^{(k)} \end{aligned}$$

mit der Schrittweite $\alpha^{(k+1)} = 1$ und der Suchrichtung

$$(12) \quad s^{(k)} = -H(x^{(k)})^{-1} \nabla f(x^{(k)}) \quad \text{(Newton-Richtung)}$$

■ NEWTON-Verfahren zur Lösung von

freie OP

nichtlineare GS

$$\boxed{\min_{x \in \mathbb{R}^n} f(x)}$$

$$\implies \nabla f(x) = 0 \text{ in } \mathbb{R}^n$$

$$\boxed{F(x) = 0 \text{ in } \mathbb{R}^n}$$

SGP

in $x^{(k)}$

$$\min_{x \in \mathbb{R}^n} q_k(x)$$

in $U(x^{(k)})$

$$F(x^{(k)}) + \nabla F(x^{(k)})(x - x^{(k)}) = 0$$

$$(11)_{\nabla f} \quad x^{(k+1)} = x^{(k)} - H_f(x^{(k)})^{-1} \nabla f(x^{(k)})$$

↑
Hesse-Matrix von f

$$x^{(k+1)} = x^{(k)} - J_F(x^{(k)})^{-1} F(x^{(k)})$$

↑
Jacobi-Matrix von F

$$J_F(x) = \left[\frac{\partial F_i}{\partial x_j}(x) \right]_{i,j=1,\dots,n} \stackrel{\text{falls } F = \nabla f}{=} \left[\frac{\partial^2 f}{\partial x_i \partial x_j}(x) \right]_{i,j=1,\dots,n} = H_f(x)$$

■ Satz 5.9: (11)_{∇f} "bzw. 2x + H Lip"
Vor.: Sei $f: \mathbb{R}^n \rightarrow \mathbb{R}$ "dreimal" stetig partiell diffbar, $x^* \in \mathbb{R}^n$ sei ein lokales Minimum von f und $H(x^*)$ sei SPD.

Bh.: Dann ist das NEWTON-Verfahren für hinreichend gute Startwerte $x^{(0)}$, d.h. $\|x^* - x^{(0)}\|$ hinreichend klein, wohldefiniert und es konvergiert q-quadratisch gegen x^* , d.h. $\exists c = \text{const} > 0$:

$$(13) \quad \|x^* - x^{(k+1)}\| \leq c \|x^* - x^{(k)}\|^2$$

Beweis: siehe Beweis von Satz 5.10 mit $F = \nabla f$.
 (↓)

■ Satz 5.10: $(11)_F \rightarrow F(x) = 0$ in \mathbb{R}^n

Vor.: Sei $F: \mathbb{R}^n \rightarrow \mathbb{R}^n$ einmal stetig partiell diffbar
 $x^* \in \mathbb{R}^n$ sei Nullstelle von F , d.h. $F(x^*) = 0$,
 $\nabla F(x^*) =: J(x^*)$ sei regulär und $\beta = \|J(x^*)^{-1}\|$

Bh.: Dann ist das NEWTON-Verfahren $(11)_F$
 für hinreichend gute Startwerte wohldefiniert
 und es konvergiert q -superlinear gegen x^* , d.h.

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

$$\|x^* - x^{(k+1)}\| \leq q_k \|x^* - x^{(k)}\|$$

Falls ∇F in x^* Lipschitz-stetig ist, d.h. $\exists L = \text{const} > 0$

$$\|\nabla F(x) - \nabla F(x^*)\| \leq L \|x - x^*\| \quad \forall x \in \tilde{U}(x^*)$$

dann konvergiert das Newton-Verfahren
 q -quadratisch, d.h. es gilt (13).

Beweis: $x = x^{(k)}$, $F' = \nabla F = J$ - Jacobi-Matrix

$$\|x^{(k+1)} - x^*\| = \|x - F'(x)^{-1} F(x) - x^*\|$$

$$= \|F'(x)^{-1} [F(x^*) - F(x) - F'(x)(x - x^*)]\|$$

$$\leq \|F'(x)^{-1}\| \|F(x^*) - F(x) - F'(x)(x - x^*)\|$$

ZWS: $\exists \xi \in (0,1)$

$$\leq \|F'(x)^{-1}\| \| [F'(x + \xi(x^* - x)) - F'(x^*) + F'(x^*) - F'(x)](x - x^*) \|$$

$$O(\|x - x^*\|) \quad \text{1x stetig diffbar}$$

$$O(\|x - x^*\|^2) \quad F' \text{ Lip in } x$$

$$\leq \frac{2\beta L}{1 - \beta L} \|x^{(k)} - x^*\|^2 \leq C \|x^{(k)} - x^*\|^2$$

z.z. $\exists \epsilon > 0$ $\forall k \geq N$ q.e.d.

■ Satz 5.10: $(11)_F \rightarrow F(x) = 0$ in \mathbb{R}^n

Vor.: Sei $F: \mathbb{R}^n \rightarrow \mathbb{R}^n$ einmal stetig partiell diffbar,
 $x^* \in \mathbb{R}^n$ sei Nullstelle von F , d.h. $F(x^*) = 0$.

$\nabla F(x^*) =: J(x^*)$ sei regulär und $\beta = \|J(x^*)^{-1}\| > 0$

Bh.: Dann ist das NEWTON-Verfahren $(11)_F$ für hinreichend gute Startwerte wohldefiniert und es konvergiert q-superlinear gegen x^* , d.h.

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

$$\|x^* - x^{(k+1)}\| \leq q_k \|x^* - x^{(k)}\|$$

Falls ∇F in x^* Lipschitz-stetig ist, d.h. $\exists L = \text{const} > 0$:

$$(*) \quad \|\nabla F(x) - \nabla F(x^*)\| \leq L \|x - x^*\| \quad \forall x \in \tilde{U}(x^*),$$

dann konvergiert das NEWTON-Verfahren q-quadratisch, d.h. es gilt (13).

Beweis: $x = x^{(k)}$, $F' = \nabla F = J = J_F = \text{Jacobi-Matrix}$

$$x^{(k+1)} - x^* = \underbrace{x^{(k)} - F'(x^{(k)})^{-1} F(x^{(k)})}_{x^{(k+1)}} - x^*$$

$$= F'(x)^{-1} [0 - F(x) - F'(x)(x^* - x)]$$

$$= F'(x)^{-1} [F''(x^*) - (F(x) + F'(x)(x^* - x))]$$

$$\|x^{(k+1)} - x^*\| \leq \|F'(x)^{-1}\| \underbrace{\|F(x^*) - (F(x) + F'(x)(x^* - x))\|}_{o(\|x - x^*\|) \quad F \in C^2!}$$

$$\leq \|F'(x)^{-1}\| \|F(x^*) - F(x) - F'(x)(x^* - x)\|$$

$$\exists \xi \in (0,1) \leq \|F'(x)^{-1}\| \|(F'(x + \xi(x^* - x)) - F'(x))(x^* - x)\|$$

$$\leq \|F'(x)^{-1}\| \| \underbrace{F'(x + \xi(x^* - x)) - F'(x^*)}_{\text{Lipschitz}} + \underbrace{F'(x^*) - F'(x)}_{\text{Lipschitz}} \| \|x^* - x\|$$

$$\leq \|F'(x)^{-1}\| (L \|x + \xi(x^* - x) - x^*\| + L \|x^* - x\|) \|x^* - x\|$$

$$(*) \quad F' \text{ Lip} \leq \frac{2\beta L}{1 - \beta L \|x^* - x\|} \|x^* - x\|^2 \leq C \|x^* - x\|^2 \quad \text{q.e.d.}$$

• Bemerkung:

- ⊕ Im Gegensatz zum GV (q-linear) konvergiert das Newton-Verfahren sehr schnell (q-quadratisch)!
- ⊖ Nur lokale Konvergenz, d.h. $x^{(0)} \in U(x^*)$!
 \rightsquigarrow gedämpftes Newton mit Liniensuche!
- ⊖ $H_f(x^{(k)})$ bzw. $J_F(x^{(k)})$ wird benötigt und in jedem Newton-Schritt ist lineares GS zu lösen!
 $J_F(x^{(k)}) s^{(k)} = d^{(k)}$
 \rightsquigarrow BFGS

• Algorithmus 5.11: $F(x) = 0$ bzw. $|\nabla f(x)| = 0$

Startnäherung: $x^{(0)} \in \mathbb{R}^n$, $B^{(0)}$, $\varepsilon = 10^{-L}$ ges

Iteration: $k = 0, 1, \dots, k_{\text{stop}}$

$$d^{(k)} = -F(x^{(k)})$$

$$\|d^{(k)}\| \leq \varepsilon \|d^{(0)}\| \implies \text{STOP}$$

$$B^{(k)} s^{(k)} = d^{(k)} \quad (\text{Lin. GS lösen})$$

$\alpha^{(k+1)}$ = Schrittweitenwahl (Liniensuche)

$$x^{(k+1)} = x^{(k)} + \alpha^{(k+1)} s^{(k)}$$

$$B^{(k+1)} = \text{Newton, BFGS, ... } (?)$$

$$B^{(k)} = J_F(x^{(k)}) = H_f(x^{(k)})$$

$\alpha^{(k+1)} = 1$ - Newton, $\alpha^{(k+1)} < 1$ gedämpftes Neo.

$$B^{(k+1)} = B^{(k)} + \dots \quad (14) \quad \text{BFGS} \rightarrow \text{Pkt. 5.1.4.}$$

5.1.4. Quasi-Newton-Verfahren

■ Idee: ⁱⁿ

1. Ersetzen $q_k(x)$ die Hesse-Matrix $H(x^{(k)})$ durch eine Approximation $B^{(k)}$.

Dann erhält man anstelle der Newton-Richtung die Suchrichtung

$$s^{(k)} = -B^{(k)-1} \nabla f(x^{(k)}) = -B^{(k)-1} F(x^{(k)}).$$

2. Wähle $B^{(0)}$ z.B. $B^{(0)} = H(x^{(0)})$ oder $B^{(0)} = I$.

Für geg. $B^{(k)}$ berechnen neue Approximation $B^{(k+1)}$ der Hesse-Matrix im nächsten Iterationsptkt so, daß die folgenden 3 Bedingungen erfüllt werden:

1) Quasi-Newton-Bd.: (Sekundenbed.)

$$B^{(k+1)} \underbrace{(x^{(k+1)} - x^{(k)})}_{=: w^{(k)}} = \underbrace{F(x^{(k+1)}) - F(x^{(k)})}_{=: y^{(k)}}$$

Bem.: Für $n=1$ ist das die Sekundenbed.:

$$B^{(k+1)} = \frac{F(x^{(k+1)}) - F(x^{(k)})}{x^{(k+1)} - x^{(k)}}$$

→ Sekundenverfahren:

$$x^{(k+2)} = x^{(k+1)} - \frac{x^{(k+1)} - x^{(k)}}{F(x^{(k+1)}) - F(x^{(k)})} F(x^{(k+1)})$$

2) $B^{(k+1)}$ ist SPD. Diese Bedingung sichert,

daß die nächste Suchrichtung $s^{(k+1)} = -(B^{(k+1)})^{-1} \nabla f(x^{(k+1)})$

eine Abstiegsrichtung ist. Tatsächlich

$$\nabla f(x^{(k+1)})^T s^{(k+1)} = -\nabla f(x^{(k+1)})^T (B^{(k+1)})^{-1} \nabla f(x^{(k+1)}) < 0$$

3) $B^{(k+1)} = B^{(k)} + \text{Niedrigrangmatrix}$

Rang-1 oder Rang-2

■ Broyden - Fletcher - Goldfarb - Shanno - Verfahren

- Eines der wichtigsten Verfahren dieser Klasse ist das **BFGS-Verfahren** (= Rang-2-Verfahren),

$$(14) \quad B^{(k+1)} = B^{(k)} + \underbrace{\frac{1}{y^{(k)T} w^{(k)}} y^{(k)} y^{(k)T} + \frac{1}{w^{(k)T} B^{(k)} w^{(k)}} B^{(k)} y^{(k)} y^{(k)T} B^{(k)}}_{\text{Rang-2-Matrix}}$$

Rang-2-Matrix

• Satz 5.12:

Falls $B^{(k)}$ SPD ist und falls $y^{(k)T} w^{(k)} > 0$, dann ist auch $B^{(k+1)}$ SPD.

Beweis: Klar!

• Bem. 5.13:

1. Erfüllt die Schrittweite $\alpha^{(k+1)}$ die Bed. (8), dann gilt $y^{(k)T} w^{(k)} > 0$.
2. Unter geeigneten Voraussetzung läßt sich für das BFGS-Verfahren mit Liniensuche, die den Kriterien (7) und (8) genügt, zeigen, daß es global und superlinear konvergiert!

5.2. Optimierungsprobleme (OP) mit Nebenbedingungen (NB)

- In diesem Abschnitt betrachten wir **restringierte Optimierungsprobleme (rOP)** mit Gleichungs- und Ungleichungsnebenbedingungen der Form

(1)_{rOP} Finde $x^* \in \mathbb{R}^n$:

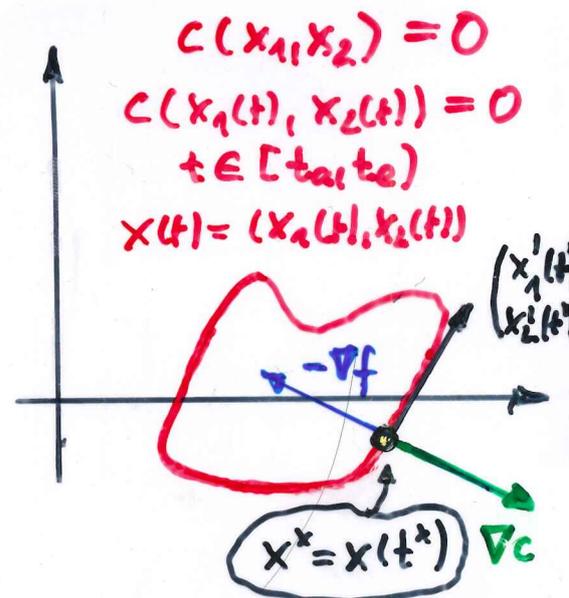
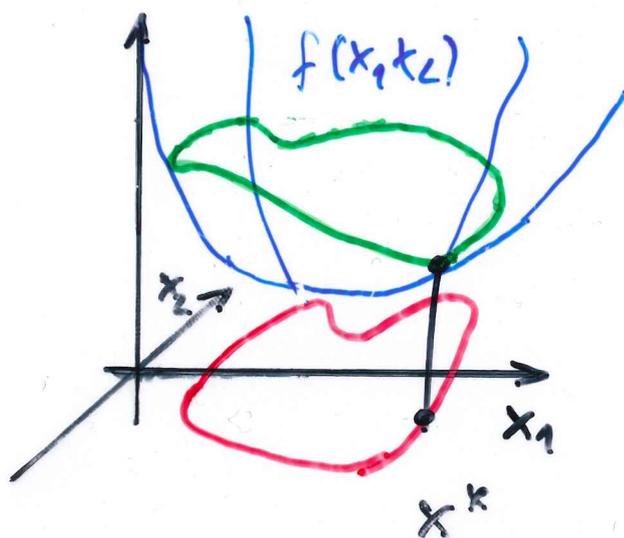
$$f(x^*) = \min_{x \in \mathbb{R}^n} f(x)$$

s.t. $c_i(x) = 0, i \in I_1 = \{1, 2, \dots, m_1\}$
 $c_i(x) \leq 0, i \in I_2 = \{m_1+1, \dots, m_1+m_2\}$

5.2.1. Lagrange's Idee (1788)

- Ges. ist ein lokales Extremum (= Min. oder Max.) der Funktion $f(x_1, x_2)$ unter der Nebenbedingung $c(x_1, x_2) = 0$ (d.h. $n=2, m_1=1, m_2=0$),

wobei die Fkten $f, c: \mathbb{R}^2 \rightarrow \mathbb{R}$ als stetig diffbar vorausgesetzt werden:



- Angenommen es existiert eine Parameterisierung der Lösung der NB, d.h.

$$\exists x = x(t) = (x_1(t), x_2(t)) : c(x_1(t), x_2(t)) = 0, t \in [t_{\text{start}}, t_{\text{end}}]$$

Durch Differenzieren der NB nach t erhalten wir:

$$0 = \frac{d}{dt} c(x_1(t), x_2(t)) = \frac{\partial c}{\partial x_1} x_1' + \frac{\partial c}{\partial x_2} x_2' = (\nabla c, \begin{pmatrix} x_1' \\ x_2' \end{pmatrix})$$

Offbar gilt:

$$\nabla c \perp \begin{pmatrix} x_1' \\ x_2' \end{pmatrix}$$

lok. Extr. $f(x_1, x_2)$
unter NB $c(x_1, x_2) = 0$



freies lok. Extr.
von $F(t) := f(x_1(t), x_2(t))$

Sei nun $(x_1^*, x_2^*) = (x_1(t^*), x_2(t^*))$ ein lok. Extr., d.h.

$$F'(t^*) = \frac{\partial f}{\partial x_1}(x_1^*, x_2^*) x_1'(t^*) + \frac{\partial f}{\partial x_2}(x_1^*, x_2^*) x_2'(t^*) = 0, \text{ d.h.}$$

$$\nabla f(x_1^*, x_2^*) \perp \begin{pmatrix} x_1'(t^*) \\ x_2'(t^*) \end{pmatrix}$$

$$\exists \lambda^* \in \mathbb{R} : \nabla f(x_1^*, x_2^*) = -\lambda^* \nabla c(x_1^*, x_2^*)$$

λ^* heißt Lagrange-Multiplikator.

- Resultat: Wir erhalten also für Extremalwertprobleme

$$\begin{array}{l} f(x_1, x_2) \longrightarrow \text{extr. (min/max)} \\ \text{s.t. } c(x_1, x_2) = 0 \end{array}$$

die notwendige Extremalbedingung

$$\begin{array}{l} \nabla_x L(x^*, \lambda^*) = \\ \nabla_\lambda L(x^*, \lambda^*) = \end{array} \begin{array}{l} \nabla f(x_1^*, x_2^*) + \lambda^* \nabla c(x_1^*, x_2^*) = 0 \\ c(x_1^*, x_2^*) = 0 \end{array} = \text{nGS,}$$

die wir mit Hilfe der sogenannten Lagrange-Fkt.

$$L(x, \lambda) = L(x_1, x_2, \lambda) := f(x_1, x_2) + \lambda c(x_1, x_2)$$

auch kompakt in der Form $\nabla L(x^*, \lambda^*) = 0$ schreiben können.

5.2.2. Theoretische Grundlagen

Optimierungsprobleme mit Gleichungsnebenbed.:

- Btr. (1)_{rop} mit $m = m_1 < n$ und $m_2 = 0$, d.h.

$$(15) \quad \min_{x \in \mathbb{R}^n} f(x_1, x_2, \dots, x_n)$$

$$\min_{x \in \mathbb{R}^n} f(x)$$

$$\text{s.t. } c_1(x_1, \dots, x_m, x_{m+1}, \dots, x_n) = 0$$

$$\text{s.t. } c(x) = 0$$

⋮

⋮

$$c_m(x_1, \dots, x_m, x_{m+1}, \dots, x_n) = 0$$

$m_1 = m$
 $m_2 = 0$

Bem.: Satz über implizite Fkten: (15) \Rightarrow fOP

T \rightarrow

- Def. 5.15: (Lagrange-Fkt., Lagrange-Multipl.)

Die zu $(f, c) = (\text{Zielfkt.}, \text{NB})$ gehörige

Lagrange-Funktion ist definiert als:

$$(16) \quad L(x, \lambda) = L(x_1, \dots, x_n, \lambda_1, \dots, \lambda_m) := f(x) + \sum_{i=1}^m \lambda_i c_i(x_1, \dots, x_n)$$

Die $\lambda = (\lambda_1, \dots, \lambda_m) \in \mathbb{R}^m$ heißen Lagrange-Multiplik.

- Satz 5.16: (Notwendige Extremalbed.)

Vor.: 1. Seien $f: \mathbb{R}^n \rightarrow \mathbb{R}$ und $c: \mathbb{R}^n \rightarrow \mathbb{R}^m$ stetig diffbar und sei $m \leq n$.

2. x^* sei Stelle eines lokalen Extremums von f unter der NB $c(x^*) = 0$:

CQ

$$\text{rang } c'(x^*) = \text{rang} \left[\frac{\partial c}{\partial x} \right] = \text{rang} \left[\frac{\partial c_i}{\partial x_j} \right]_{\substack{i=1, \dots, m \\ j=1, \dots, n}} = m.$$

Bh.: Dann $\exists! \lambda^* = (\lambda_1^*, \dots, \lambda_m^*) \in \mathbb{R}^m$:

$$(18)$$

$$\nabla L(x^*, \lambda^*) = 0$$

NGS in \mathbb{R}^{n+m}

T

\rightarrow Kscr.: Hot Spot

• Bem. 5.17:

1. Ist x Stelle eines lokalen Extremums von f unter den Nebenbedingungen

$$c_1(x) = 0, \dots, c_m(x) = 0,$$

so gilt unter den Voraussetzungen von Satz 4.16

$$\exists \lambda_1^*, \dots, \lambda_m^* \in \mathbb{R}:$$

$$\nabla L(x^*, \lambda^*) = 0 \quad (18)$$

in \mathbb{R}^{n+m}

$$\frac{\partial f}{\partial x_j}(x^*) + \sum_{i=1}^m \lambda_i^* \frac{\partial c_i}{\partial x_j}(x^*) = 0, \quad j=1, 2, \dots, n$$

$$c_i(x^*) = 0, \quad i=1, 2, \dots, m$$

Das ist ein nichtlineares Gleichungssystem von $(n+m)$ nichtlinearen Gleichungen zur Bestimmung der $(n+m)$ Unbekannten $(x^*, \lambda^*) = (x_1^*, \dots, x_n^*, \lambda_1^*, \dots, \lambda_m^*)$.

- Die Gleichungen (18) sind nur notwendige Bedingungen für das Vorliegen eines lokalen Extr.!
- Außerdem erhalten wir nur lokale Extrema, in denen die Bedingung $\text{rang } c'(x^*) = m$ erfüllt ist!
- Die Lagrange-Multiplikatoren $(-\lambda_i)$ sind ein Maß für die Empfindlichkeit auf die Verletzung der i -ten Nebenbedingung, d.h.

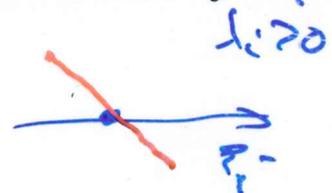
$$\left. \frac{\partial f}{\partial \xi_i}(x^*(\xi_1, \dots, \xi_m)) \right|_{\xi = (\xi_1, \dots, \xi_m) = 0} \stackrel{(uns)}{=} -\lambda_i,$$

wobei $x^*(\xi_1, \dots, \xi_m)$ ein lokales Extremum von f unter den Nebenbedingungen $c(x) = \xi$ ist, d.h.

$$c_1(x_1^*, \dots, x_n^*) = \xi_1$$

$$\vdots$$

$$c_m(x_1^*, \dots, x_n^*) = \xi_m.$$



OP mit Gleichungs- und Ungleichungsnebenbedingungen:

- Analog zur Def. 4.15 ordnen wir auch dem OP (1)_{OP} die Lagrange-Fkt. $L: \mathbb{R}^n \times \mathbb{R}^m \rightarrow \mathbb{R}$ mit

$$(1b) \quad L(x, \lambda) = f(x) + \sum_{i=1}^m \lambda_i c_i(x) = f(x) + (\lambda, c(x))$$

$\cong u$, wobei $m = m_1 + m_2$ und $\lambda = (\lambda_1, \dots, \lambda_m)^T \in \mathbb{R}^m$ -Lag. Mult.

Bezeichnungen:

1) Gradient der Lagrange-Fkt. bzgl. x :

$$\nabla_x L(x, \lambda) = \nabla f(x) + \sum_{i=1}^m \lambda_i \nabla c_i(x).$$

2) Hesse-Matrix der Lagrange-Fkt. bzgl. x :

$$\nabla_{xx} L(x, \lambda) = \nabla^2 f(x) + \sum_{i=1}^m \lambda_i \nabla^2 c_i(x) \quad (\text{sym.})$$

3) Menge der Indizes der in x aktiven NB:

$$A(x) := \{ i \in I_1 \cup I_2 = \{1, 2, \dots, m\} : c_i(x) = 0 \}.$$

Satz 5.18: (notwendige Optimalitätsbedingung)

Seien $f: \mathbb{R}^n \rightarrow \mathbb{R}$ und $c: \mathbb{R}^n \rightarrow \mathbb{R}^m$ stetig diffbar

und sei $x^* \in \mathbb{R}^n$ ein lokales Min. des restr. OP (1)_{OP}.

Falls $\{ \nabla c_i(x^*) : i \in A(x^*) \}$ linear unabhängig sind

(Linear Independence Constraint Qualification = LICQ),

$(x^*, \lambda^*) \in \mathbb{R}^n \times \mathbb{R}^m$: dann existiert genau ein Vektor $\lambda^* \in \mathbb{R}^m$:

KKT-Pkt.

(19)

$$\begin{aligned} \nabla_x L(x^*, \lambda^*) &= \nabla f(x^*) + \sum_{i=1}^m \lambda_i^* \nabla c_i(x^*) = 0 \\ c_i(x^*) &= 0 \text{ für } i \in I_1 \\ c_i(x^*) &\leq 0, \lambda_i^* \geq 0, \lambda_i^* c_i(x^*) = 0, i \in I_2 \end{aligned}$$

= KKT-Bd.
Karush
Kuhn
Tucker

Satz 5.19: (hinreichende Bedingungen)

Falls $x^* \in \mathbb{R}^n$ und $\lambda^* \in \mathbb{R}^m$ die KKT-Bed. (19) erfüllen

und $\nabla_{xx} L(x^*, \lambda^*)$ p.d. ist, dann ist x^* ein striktes lok. Min.

• Bem.: $s^T \nabla_{xx} L(x^*, \lambda^*) s > 0 \quad \forall s \in \mathbb{R}^n \quad \downarrow \quad \forall s \in C(x^*, \lambda^*), s \neq 0$
Cone of Critical Directions

5.2.3. Das SQP-Verfahren

- Beim NEWTON-Verfahren (vgl. Abs. 5.1.3) bzw. bei Quasi-NEWTON-Verfahren (vgl. Abs. 5.1.4) der freien Optimierung wurde die Suchrichtung $s^{(k)}$ im Iterationspkt. $x^{(k)}$ als Lösung des freien quadratischen Optimierungsproblems (QOP)

$$f(x^{(k)} + s) \stackrel{(20)}{f_{QOP}} \approx \cancel{f(x^{(k)})} + \nabla^T f(x^{(k)}) s + \frac{1}{2} s^T \underset{SPD}{B^{(k)}} s \longrightarrow \min_{s \in \mathbb{R}^n}$$

$$\Leftrightarrow B^{(k)} s = -\nabla f(x^{(k)})$$

wobei $B^{(k)} := H(x^{(k)}) = \nabla_{xx} f(x^{(k)}) = \nabla^2 f(x^{(k)}) = \text{NEWTON}$

$x^{(k+1)} = x^{(k)} + \alpha^{(k+1)} s^{(k)}$

$$B^{(k)} := (14) = \text{BFGS}$$

- Analog werden das NEWTON-Verfahren und die Quasi-Newton-Verfahren für restringierte OP der Form (1)_{rop} formuliert:

Zu geg. Näherungen $x^{(k)} \approx x^*$ und $\lambda^{(k)} \approx \lambda^*$ wird die nächste Suchrichtung $s^{(k)} \in \mathbb{R}^n$ als Lösung des folgenden quadratischen OP mit "Linearisierten" NB bestimmt:

$$(20)_{rQOP} \quad \boxed{\begin{aligned} &\cancel{f(x^{(k)})} + \nabla^T f(x^{(k)}) s + \frac{1}{2} s^T B^{(k)} s \rightarrow \min_{s \in \mathbb{R}^n} \\ &\text{s.t. } c_i(x^{(k)}) + \nabla^T c_i(x^{(k)}) \cdot s = 0, \quad i \in I_1 \\ &\quad c_i(x^{(k)}) + \nabla^T c_i(x^{(k)}) s \leq 0, \quad i \in I_2 \end{aligned}}$$

Die nächste Näherung ergibt sich dann zu:

$$x^{(k+1)} = x^{(k)} + \alpha^{(k+1)} s^{(k)}, \quad \text{z.B. } \alpha^{(k+1)} = 1$$

$\lambda^{(k+1)}$ = der zu $s^{(k)}$ gehörende Lagrange-Parameter des rQOP (20)_{rQOP}.

Zur Wahl von $B^{(k)}$:

1. $B^{(k)} = L_{xx}(x^{(k)}, \lambda^{(k)}) = \text{Wilson-Verfahren}$
 \uparrow
 $f_{xx} = \nabla^2 f$ (fOP) \cong **Newton-Verfahren**

2. $B^{(k)} = \text{Quasi-Newton z. B. BFGS}$

Zur Bestimmung der Schrittweite $\alpha^{(k+1)}$:
 \rightarrow Linien suche nach den Kriterien (7) und (8)!

■ Algorithmus 5.20: SQP-Verfahren: Wilson

Start: Wähle Anfangsnäherung $(x^{(0)}, \lambda^{(0)}) \in \mathbb{R}^n \times \mathbb{R}^m$.

Iteration: $k = 0, 1, 2, \dots, k_{\text{stop}}$ KKT-Test.

Ist $(x^{(k)}, \lambda^{(k)})$ eine KKT-Pkt, d.h. Lsg. von (15): STOP!

Berechne einen KKT-Pkt. $(x^{(k+1)}, \lambda^{(k+1)}) \in \mathbb{R}^n \times \mathbb{R}^m$
 des quadratischen QP = QPO:

$$\begin{aligned} \min_{x \in \mathbb{R}^n} & \nabla f(x^{(k)})^T (x - x^{(k)}) + \frac{1}{2} (x - x^{(k)})^T L_{xx}(x^{(k)}, \lambda^{(k)}) (x - x^{(k)}) \\ \text{s.t.} & c_i(x^{(k)}) + \nabla c_i^T(x^{(k)}) (x - x^{(k)}) = 0, \quad i \in I_1 \\ & c_i(x^{(k)}) + \nabla c_i^T(x^{(k)}) (x - x^{(k)}) \leq 0, \quad i \in I_2 \end{aligned}$$

Besitzt dieses QP mehrere KKT-Punkte,
 so wählt man den KKT-Punkt $(x^{(k+1)}, \lambda^{(k+1)}) \in \mathbb{R}^n \times \mathbb{R}^m$:

$$\| (x^{(k+1)}, \lambda^{(k+1)}) - (x^{(k)}, \lambda^{(k)}) \| \rightarrow \min.$$

- Unter geeigneten Bedingungen kann lokale superlineare bzw. sogar quadratische Konvergenz gezeigt werden.
 (siehe z.B. Satz 5.31 in Geiger / Kanzov [12]).

5.2.4. Quadratische Optimierungsprobleme

- Btr. das allgemeine restringierte quadratische Optimierungsproblem (rq OP = QP = Quadratic Programming)

(21) Ges. $x^* \in \mathbb{R}^n$:

(QP) $q(x^*) = \min_{x \in \mathbb{R}^n} q(x) := \cancel{f} + g^T \cdot x + \frac{1}{2} x^T B x$ quadratisch =

s.t. $c_i + a_i^T x = 0, i \in I_1 = \{1, \dots, m_1\} =$

$c_i + a_i^T x \leq 0, i \in I_2 = \{m_1+1, \dots, m_1+m_2\}$ =

(affine) Linear = m

mit geg. $f, c_i \in \mathbb{R}$ und $g, a_i \in \mathbb{R}^n$ sowie geg. Matrix $B \in \mathbb{R}^{n \times n}$ SPD

- Bem.: (QP) mit reinen Gleichungsnebenbed., d.h. $I_2 = \emptyset$,
= führt nach Satz 5.16 / Bem. 5.17 auf die Lösung des ~~quadratischen~~ linearen GS

(22) = (18)_{QP} $\nabla L(x, \lambda) = 0$ KKT-System

mit der Lagrange-Fkt. ($m = m_1$)

$$L(x, \lambda) = q(x) + \sum_{i=1}^m \lambda_i (c_i + a_i^T x),$$

d.h. (22) ergibt sich zu

(22) $\frac{\partial q}{\partial x_j}(x) + \sum_{i=1}^m \lambda_i \frac{\partial}{\partial x_j} (c_i + a_i^T x) = 0, j=1, \dots, n$

$c_i + a_i^T x = 0, i=1, \dots, m$



(22) $g_j + (Bx)_j + \sum_{i=1}^m \lambda_i a_{ij} = 0, j=1, \dots, n$

$c_i + a_i^T x = 0, i=1, \dots, m$



KKT (22) $\begin{bmatrix} B & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} x \\ \lambda \end{bmatrix} = \begin{bmatrix} -g \\ -c \end{bmatrix}$ mit $A = \begin{bmatrix} a_1^T \\ \vdots \\ a_m^T \end{bmatrix} = \begin{bmatrix} a_{11} & \dots & a_{1n} \\ \vdots & & \vdots \\ a_{m1} & \dots & a_{mn} \end{bmatrix}$

(m x n) - Matrix

$\frac{\partial L}{\partial x_j} =$
 $\frac{\partial L}{\partial \lambda_i} =$

Sei $x^{(k)}$ ein zulässiger Pkt. des (QP) mit reinen Gleichungsnebenbed., d.h.

NB: $Ax^{(k)} = -c$ bzw. $a_i^T x = -c_i, i = \overline{1, m=m_1}$

Dann gilt für die Korrektur Δx in der Darstellung

$$x^{(k+1)} = x^{(k)} + \Delta x$$

wegen (22) die folgende Beziehung

$$\begin{bmatrix} B & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} x \\ \lambda \end{bmatrix} = \begin{bmatrix} -g \\ -c \end{bmatrix} \quad \text{KKT-System}$$

$$\Leftrightarrow \begin{bmatrix} B & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} x^{(k)} + \Delta x \\ \lambda \end{bmatrix} = \begin{bmatrix} -g \\ -c \end{bmatrix}$$

$$\Leftrightarrow \begin{bmatrix} B & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} \Delta x \\ \lambda \end{bmatrix} = \begin{bmatrix} -g \\ -c \end{bmatrix} - \begin{bmatrix} B & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} x^{(k)} \\ 0 \end{bmatrix}$$

$$= \begin{bmatrix} -g - Bx^{(k)} \\ -c - Ax^{(k)} \end{bmatrix}$$

$$= \begin{bmatrix} -\nabla q(x^{(k)}) \\ 0 \end{bmatrix}$$

$$\begin{aligned} B \Delta x + A^T \lambda &= -\nabla q(x^{(k)}) \\ A \Delta x &= 0 \end{aligned}$$

Algorithmus 5.21: Strategie der aktiven Mengen \rightarrow (QP)

Start: Bestimme ein für (21) = (QP) zulässige Startnäherung $x^{(0)} \in \mathbb{R}^n$ sowie einen zugehörigen Lagrange-Multiplikator $\lambda^{(0)} \in \mathbb{R}^n$.

Setze $\mathcal{A}_0 := \mathcal{A}(x^{(0)}) := \{i \in I_1 \cup I_2 : c_i + a_i^T x^{(0)} = 0\}$.

Schritte: $k = 0, 1, 2, \dots, k_{\text{stop}} (= \text{STOP})$

(S1) Ist $(x^{(k)}, \lambda^{(k)})$ ein KKT-Pkt. von (21): **STOP!**

(S2) Setze $\lambda_i^{(k+1)} = 0$ für $i \notin \mathcal{A}_k$ und bestimme $(\Delta x^{(k)}, \lambda_{\mathcal{A}_k}^{(k+1)}) \in \mathbb{R}^n \times \mathbb{R}^{|\mathcal{A}_k|}$:

$$\begin{bmatrix} B & A_k^T \\ A_k & 0 \end{bmatrix} \begin{bmatrix} \Delta x^{(k)} \\ \lambda_{\mathcal{A}_k}^{(k+1)} \end{bmatrix} = \begin{bmatrix} -\nabla q(x^{(k)}) \\ 0 \end{bmatrix},$$

wobei $\lambda_{\mathcal{A}_k} := [\lambda_i]_{i \in \mathcal{A}_k} \in \mathbb{R}^{|\mathcal{A}_k|}$, $A_k = [a_i^T]_{i \in \mathcal{A}_k}$.

(S3) Unterscheide die folgenden Fälle:

1) Ist $\Delta x^{(k)} = 0$ und $\lambda_i^{(k+1)} \geq 0 \forall i \in \mathcal{A}_k \cap I_2$: **STOP!**

2) Ist $\Delta x^{(k)} = 0$ und $\min \{\lambda_i^{(k+1)} : i \in \mathcal{A}_k \cap I_2\} < 0$,

so bestimme einen Index $r \in \mathcal{A}_k \cap I_2$:

$$\lambda_r^{(k+1)} = \min \{\lambda_i^{(k+1)} : i \in \mathcal{A}_k \cap I_2\}.$$

Setze $x^{(k+1)} = x^{(k)}$ und $\mathcal{A}_{k+1} := \mathcal{A}_k \setminus \{r\}$: **GOTO (S1)**

3) Ist $\Delta x^{(k)} \neq 0$ und $x^{(k)} + \Delta x^{(k)}$ zulässig für (21),

so setze $x^{(k+1)} := x^{(k)} + \Delta x^{(k)}$ und $\mathcal{A}_{k+1} = \mathcal{A}_k$: **GOTO (S1)**

4) Ist $\Delta x^{(k)} \neq 0$ und $x^{(k)} + \Delta x^{(k)}$ nicht zulässig für (21)

so bestimme einen Index r mit

$$\alpha^{(k+1)} := -\frac{c_r + a_r^T x^{(k)}}{a_r^T \Delta x^{(k)}} = \min \left\{ -\frac{c_i + a_i^T x^{(k)}}{a_i^T \Delta x^{(k)}} : i \notin \mathcal{A}_k \wedge a_i^T \Delta x^{(k)} > 0 \right\}$$

Setze $x^{(k+1)} = x^{(k)} + \alpha^{(k+1)} \Delta x^{(k)}$ und $\mathcal{A}_{k+1} := \mathcal{A}_k \cup \{r\}$:

GOTO (S1)

GOTO (S1) means GOTO (S1) $\wedge k \leftarrow k+1$

5.2.5. Weitere Verfahren zur Lösung von rOP mit NB in Gleichungs- und Ungleichungsform

(1)_{rOP}

$$\text{Ges. } x^* \in \mathbb{R}^n : f(x^*) = \min_{x \in \mathbb{R}^n} f(x)$$

$$\text{s.t. } c_i(x) = 0, i \in I_1 = \{1, \dots, m_1\}$$

$$c_i(x) \leq 0, i \in I_2 = \{m_1+1, \dots, m_1+m_2\}$$

■ Penalty-Methoden:

- Idee: 1. Ersetze (1)_{rOP} durch eine r.OP mit Gleichungsnebenbed.:

$$(23) \quad \min_{x \in \mathbb{R}^n} f(x)$$

$$\text{s.t. } \bar{c}_i(x) := c_i(x) = 0, i \in I_1$$

$$\bar{c}_i(x) := \max\{0, c_i(x)\} = 0, i \in I_2$$

Semi-Smooth
Newton

- 2. Ersetze (23) durch eine Folge von fOPs mit Strafparameter $\alpha_k \rightarrow \infty$

$$\min_{x \in \mathbb{R}^n} P(x, \alpha_k)$$

mit der Straffkt. (z.B.)

$$P(x, \alpha) := f(x) + \frac{\alpha}{2} \sum_{i=1}^m (\bar{c}_i(x))^2.$$

■ Barriere-Methoden:

$$(1)_{\text{rOP}} \mapsto (24) \quad \min_{x \in \mathbb{R}^n} B(x, \alpha_k)$$

$$(\alpha_k \gg 0)$$

$$\text{s.t. } c_i(x) = 0, i \in I_1$$

$$\text{mit } B(x, \alpha) := f(x) - \alpha \sum_{i=m_1+1}^{m_2} \ln(-c_i(x)) \text{ oder } := f(x) - \alpha \sum_{i=m_1+1}^{m_2} \frac{1}{c_i(x)}$$

••• siehe lit z.B. [12] Gerd / Kanžov