

I.1 Allgemeine unrestringierte Minimierungsverfahren

Sei $f: \mathbb{R}^n \rightarrow \mathbb{R}$ stetig differenzierbar.

(1.1) Minimierungsalgorithmus (Prototyp)

S0) Wähle Start-Iterierte $x^0 \in \mathbb{R}^n$, $\varepsilon > 0$, $C > 0$. Setze $k = 0$.

S1) Falls $\|Df(x^k)\| < \varepsilon$ STOP (x^k numerische Lösung)
 Falls $\|x^k\| > C$ STOP (Divergenz)

S2) Wähle Suchrichtung $d^k \in \mathbb{R}^n$

S3) Bestimme Schrittweite $t_k > 0$ mit

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

S4) Update: $x^{k+1} = x^k + t_k d^k$, $k := k + 1$. Gehe zu S1).

Beispiel: Gradienten-Verfahren $d^k = -Df(x^k)^T = -\nabla f(x^k)$

I.1 Allgemeine unrestringierte Minimierungsverfahren

(1.2) Der Minimierungsalgorithmus heißt

- a) *wohldefiniert*, wenn die Auswahlregeln zur Suchrichtung und zur Schrittweite immer durchführbar sind;
- b) *konsistent*, wenn das Verfahren stoppt, falls $x^k = x^*$ ein Minimum ist;
- c) *(lokal) konvergent*, wenn zu jedem Minimum x^* ein $\delta > 0$ existiert, sodass zu jedem $\varepsilon > 0$ ein $k_0 > 0$ existiert mit

$$\|x^0 - x^*\| < \delta \quad \Rightarrow \quad \|x^k - x^*\| < \varepsilon \text{ für } k > k_0;$$

- d) *global konvergent*, wenn für alle $x^0 \in \mathbb{R}^n$ und alle $\varepsilon > 0$ ein Minimum x^* und ein $k_0 > 0$ existiert mit

$$\|x^k - x^*\| < \varepsilon;$$

- e) *effizient*, wenn die Schrittweitenwahl eine echte Reduktion von f bewirkt und ein $\theta > 0$ existiert, sodass zu jedem $x^0 \in \mathbb{R}^n$ die Iterierten x^k , Suchrichtungen d^k und Schrittweiten t_k

$$f(x^k + t_k d^k) \leq f(x^k) - \theta \left(\frac{\nabla f(x^k)^T d^k}{\|d^k\|} \right)^2$$

erfüllen.

I.1 Allgemeine unrestringierte Minimierungsverfahren

(1.3) Für einen Minimierungsalgorithmus gelte:

- a) Winkelbedingung: Es existiert $\delta > 0$ mit $-\frac{\nabla f(x^k)^T d^k}{\|\nabla f(x^k)\| \|d^k\|} \geq \delta$;
 b) die Schrittweiten $t_k > 0$ sind effizient.

Dann ist jeder Häufungspunkt x^* der Folge $\{x^k\}_{k \in \mathbb{N}}$ ein stationärer Punkt (d.h. $\nabla f(x^*) = 0$).

(1.4) Für f gelte:

- i) Die Levelmenge $\mathcal{L}(x^0) = \{x \in \mathbb{R}^n : f(x) \leq f(x^0)\}$ sei konvex
 ii) f sei gleichmäßig konvex auf $\mathcal{L}(x^0)$, d.h. es existiert $c_0 > 0$ mit
- $$f(x) - f(y) \geq \nabla f(y)^T (x - y) + c_0 \|x - y\|^2, \quad x, y \in \mathcal{L}(x^0).$$

Für den Minimierungsalgorithmus gelte:

- a) Schwache Winkelbedingung: $\sum_{k=0}^{\infty} \delta_k = \infty$ für $\delta_k = \left(\frac{\nabla f(x^k)^T d^k}{\|\nabla f(x^k)\| \|d^k\|} \right)^2$
 b) Die Schrittweiten sind effizient.

Dann konvergiert $\{x^k\}_{k \in \mathbb{N}}$ gegen das eindeutige Minimum x^* .

I.1 Allgemeine unrestringierte Minimierungsverfahren

Schrittweisenregel: Wähle $\sigma \in (0, 1)$, $\rho \in (\sigma, 1)$.

1) Armijo-Regel: wähle $t > 0$ mit

$$f(x + td) \leq f(x) + t\sigma \nabla f(x)^T d$$

2) Wolfe-Powell-Regel: wähle $t > 0$ mit

$$f(x + td) \leq f(x) + t\sigma \nabla f(x)^T d \text{ und } \nabla f(x + td)^T d \geq \rho \nabla f(x)^T d$$

3) Strenge Wolfe-Powell-Regel: wähle $t > 0$ mit

$$f(x + td) \leq f(x) + t\sigma \nabla f(x)^T d \text{ und } |\nabla f(x + td)^T d| \leq -\rho \nabla f(x)^T d$$

(1.5) Sei $\nabla f(x)^T d < 0$.

a) Die Armijo-Regel ist wohldefiniert.

b) Falls f nach unten beschränkt ist, sind die Wolfe-Powell-Regeln wohldefiniert.

(1.6) ∇f sei Lipschitz-stetig auf $\mathcal{L}(x^0)$, d.h.

$$\|\nabla f(x) - \nabla f(y)\| \leq L \|x - y\| \quad x, y \in \mathcal{L}(x^0).$$

Dann sind die Wolfe-Powell-Regeln effizient.

I.1 Allgemeine unrestringierte Minimierungsverfahren

(1.7) Eine Folge $\{x^k\}$ konvergiert gegen x^* mindestens

a) *linear*, wenn $c \in (0, 1)$ und $k_0 > 0$ existiert mit

$$\|x^{k+1} - x^*\| \leq c \|x^k - x^*\| \quad \text{für } k \geq k_0$$

b) *superlinear*, wenn zu jedem $\varepsilon > 0$ ein $k_0 > 0$ existiert mit

$$\|x^{k+1} - x^*\| \leq \varepsilon \|x^k - x^*\| \quad \text{für } k \geq k_0$$

c) *quadratisch*, wenn $x^k \rightarrow x^*$ konvergiert, und wenn $C > 0$ und $k_0 > 0$ existieren mit

$$\|x^{k+1} - x^*\| \leq C \|x^k - x^*\|^2 \quad \text{für } k \geq k_0.$$

I.2 Newton-Verfahren

(2.1) Globalisiertes Newton-Verfahren

S0) wähle $x^0 \in \mathbb{R}^n, \rho > 0, \rho > 2, \beta \in (0, 1), \sigma \in (0, \frac{1}{2}), \varepsilon \geq 0$, setze $k = 0$

S1) falls $\|\nabla f(x^k)\| \leq \varepsilon$ STOP

S2) bestimme d^k mit $D^2 f(x^k) d^k = -\nabla f(x^k)$ falls d^k nicht berechenbar ist oder die Bedingung

$$\nabla f(x^k)^T d^k \leq -\rho \|d^k\|^\rho$$

verletzt ist, setze $d^k = -\nabla f(x^k)$

S3) bestimme $t_k \in \{\beta^j : j = 0, 1, 2, \dots\}$ maximal mit

$$f(x^k + t_k d^k) < f(x^k) + t_k \sigma \nabla f(x^k)^T d^k$$

S4) setze $x^{k+1} = x^k + t_k d^k$, $k := k + 1$, gehe zu S1).

(2.2) Jeder Häufungspunkt x^* von $\{x^k\}_{k \in \mathbb{N}}$ ist ein stationärer Punkt von f .

I.2 Newton-Verfahren

- (2.3) Wenn x^* ein isolierter Häufungspunkt von $\{x^k\}$ ist, dann konvergiert bereits die gesamte Folge $\{x^k\}_{k \in \mathbb{N}}$ gegen x^* .
- (2.4) Die Levelmenge $\mathcal{L}(x^0)$ sei konvex, ∇f sei Lipschitz-stetig und f sei gleichmäßig konvex auf $\mathcal{L}(x^0)$, d.h.

$$d^T D^2 f(x) d \geq 2c_0 \|d\|^2 \quad \text{für } x \in \mathcal{L}(x^0), \quad d \in \mathbb{R}^n.$$

Dann ist das gedämpfte Newton-Verfahren mit $d^k = -D^2 f(x^k)^{-1} \nabla f(x^k)$ und $t_k = \frac{c_0}{L - c_0}$ konvergent.

- (2.5) Sei x^* ein stationärer Punkt von f , und sei $D^2 f(x^*)$ positiv definit. Dann existiert ein $\delta > 0$, sodass gilt:

- $D^2 f(x)$ positiv definit für $\|x - x^*\| < \delta$
- für x^0 mit $\|x^0 - x^*\| < \delta$ konvergiert das Newton-Verfahren mit

$$d^k = -D^2 f(x^k)^{-1} \nabla f(x^k), \quad t_k = 1$$

superlinear.

- Falls $D^2 f$ Lipschitz stetig ist, d.h.

$$\|D^2 f(x) - D^2 f(y)\| \leq \gamma \|x - y\| \quad \text{für alle } \|x - x^*\| < \delta \quad \text{und} \quad \|y - x^*\| < \delta$$

ist die Konvergenz quadratisch.

I.2 Newton-Verfahren

(2.6) Satz von Newton-Kantorovich

Für $x^0 \in \mathbb{R}^n$ und $\alpha, \beta, \gamma > 0$ gelte:

a) $\|\nabla f(x^0)\| \leq \alpha$

b) $d^T D^2 f(x^0) d \geq \beta \|d\|^2 \quad d \in \mathbb{R}^n$

c) $\|D^2 f(x) - D^2 f(y)\| \leq \gamma \|x - y\|$ für $\|x - x^0\| \leq r_0, \|y - x^0\| \leq r_0, r_0 = \frac{2\alpha}{\beta}$

d) $2\alpha\gamma \leq \beta^2$.

Dann ist das ungedämpfte Newton-Verfahren mit $x^{k+1} = x^k - D^2 f(x^k) \nabla f(x^k)$ wohldefiniert, und $\{x^k\}$ konvergiert gegen x^* mit $\nabla f(x^*) = 0$,

$$\|x^* - x^0\| \leq r_1 := \frac{r_0}{1 + \sqrt{1 - \frac{2\alpha\gamma}{\beta^2}}} = \frac{2\alpha}{\beta + \sqrt{\beta^2 - 2\alpha\gamma}}$$

und

$$d^T D^2 f(x^*) d \geq (\beta - \gamma \|x^* - x^0\|) \|d\|^2 \quad d \in \mathbb{R}^n$$

Falls sogar $2\alpha\gamma < \beta^2$ ist x^* lokales Minimum.

3. Inexakte Newton-Verfahren

(3.1) Lokales inexakte Newton-Verfahren

S0) Wähle $x^0 \in \mathbb{R}^n$, $\varepsilon \geq 0$, setze $k = 0$

S1) falls $\|\nabla f(x^k)\| \leq \varepsilon$ STOP

S2) Wähle $\eta_k > 0$ und berechne $d^k \in \mathbb{R}^n$ mit

$$\|\nabla f(x^k) + D^2 f(x^k) d^k\| \leq \eta_k \|\nabla f(x^k)\|$$

S3) setze $x^{k+1} = x^k + d^k$, $k := k + 1$, gehe zu S1)

(3.2) Sei x^* ein strenges lokales Minimum.

Dann existiert $\delta > 0$, sodass für alle $\|x^0 - x^*\| < \delta$ gilt:

- Es existiert $\bar{\eta} \in (0, 1)$, sodass für $\eta_k \leq \bar{\eta}$ die Folge $\{x^k\}$ wohldefiniert ist und linear konvergiert.
- Für $\eta_k \rightarrow 0$ konvergiert $\{x^k\}$ superlinear.
- Falls $D^2 f$ lokal Lipschitz-stetig und $\eta_k = O(\|\nabla f(x^k)\|)$, so konvergiert $\{x^k\}$ quadratisch.

3. Inexakte Newton-Verfahren

(3.3) PCG-Algorithmus zur Lösung von $Hd = r$

Sei H symmetrisch positiv definit, und sei B ein symmetrisch positiv definites Vorkonditionierer.

S0) Wähle $\eta \geq 0$, setze $\varepsilon = \eta \|r\|$, $d_{cg}^0 = 0$, $r^0 = r - Hd_{cg}^0$, $p^0 = Br^0$, $m = 0$

S1) falls $\|r^m\| \leq \varepsilon$ STOP

S2) Setze

$$\begin{aligned}
 t_m &= \frac{(r^m)^T p^m}{(p^m)^T H p^m} \\
 d_{cg}^{m+1} &= d_{cg}^m + t_m p^m \\
 r^{m+1} &= r^m - t_m H p^m \\
 \beta_m &= \frac{(r^{m+1})^T B r^{m+1}}{(r^m)^T B r^m} \\
 p^{m+1} &= B r^{m+1} - \beta_m p^m
 \end{aligned}$$

Setze $m := m + 1$ und gehe zu S1)

3. Inexakte Newton-Verfahren

(3.4) Globalisiertes inexaktes Newton-Verfahren

S0) Wähle $x^0 \in \mathbb{R}^n, \rho > 0, \rho > 2, \beta \in (0, 1), \sigma \in (0, \frac{1}{2}), \varepsilon \geq 0$. Setze $k = 0$.

S1) Setze $H_k = D^2 f(x^k)$, wähle symmetrisch positiv definiten
Vorkonditionierer B_k
falls $\|B_k \nabla f(x^k)\| < \varepsilon$ STOP

S2) Wähle $\eta_k > 0$ und bestimme d^k mit $\|H_k d^k + \nabla f(x^k)\| < \eta_k \|\nabla f(x^k)\|$;
falls d^k nicht berechenbar ist oder $\nabla f(x^k)^T d^k \leq -\rho \|d^k\|^\rho$ nicht gilt,
setze $d^k = -B_k \nabla f(x^k)$

S3) Bestimme $t_k \in \{\beta^j : j = 0, 1, 2, \dots\}$ maximal mit

$$f(x^k + t_k d^k) < f(x^k) + t_k \sigma \nabla f(x^k)^T d^k$$

S4) Setze $x^{k+1} = x^k + t_k d^k, k := k + 1$, gehe zu S1)

4. Quasi-Newton-Verfahren

- (4.1) Sei $f: \mathbb{R}^n \rightarrow \mathbb{R}$ zweimal stetig differenzierbar. Dann gilt:
Für eine Folge $\{x^k\}$ mit $H_k(x^{k+1} - x^k) = -\nabla f(x^k)$ ist äquivalent:
- $x^k \rightarrow x^*$ konvergiert superlinear und $\nabla f(x^*) = 0$
 - $\|(H_k - D^2f(x^k))(x^{k+1} - x^k)\| = o(\|x^{k+1} - x^k\|)$
- (4.2) Sei H symmetrisch positiv definit und für $s, y \in \mathbb{R}^n$ gelte $s^T y > 0$.
Dann gilt für:

$$H_+ = H + \frac{1}{s^T y} y y^T - \frac{1}{s^T H s} (Hs)(Hs)^T$$

$$B_+ = B + \frac{1}{s^T y} (rs^T + sr^T) - \frac{r^T y}{(s^T y)^2} s s^T \quad r = s - By, \quad B = H^{-1}$$

(BFGS = Broyden-Fletcher-Goldfarb-Shanno-Formel)

- $H_+ s = y, B_+ y = s.$
- $H_+ B_+ = I$
- H_+, B_+ symmetrisch positiv definit.
- $\det H_+ = \frac{y^T s}{s^T H s} \det H.$

4. Quasi-Newton-Verfahren

(4.3) Globalisiertes BFGS-Verfahren

S0) Wähle $x^0 \in \mathbb{R}^n$, $B_0 \in \mathbb{R}^{n,n}$ symmetrisch positiv definit, $\sigma \in (0, \frac{1}{2})$,
 $\rho \in (\sigma, 1)$, $\varepsilon \geq 0$.

Setze $k := 0$.

S1) falls $\|\nabla f(x^k)\| \leq \varepsilon$ STOP

S2) $d^k = -B_k \nabla f(x^k)$

S3) bestimme $t_k > 0$ mit $f(x^k + t_k d^k) \leq f(x^k) + \sigma t_k \nabla f(x^k)^T d^k$ und
 $\nabla f(x^k + t_k d^k)^T d^k \geq \rho \nabla f(x^k)^T d^k$

S4) setze $x^{k+1} = x^k + t_k d^k$, $s^k = x^{k+1} - x^k$, $y^k = \nabla f(x^{k+1}) - \nabla f(x^k)$,
 $r^k = s^k - B_k y^k$ und

$$B_{k+1} = B_k + \frac{1}{(s^k)^T y^k} (r^k (s^k)^T + s^k (r^k)^T) - \frac{(r^k)^T y^k}{((r^k)^T y^k)^2} s^k (s^k)^T$$

S5) setze $k := k + 1$ und gehe zu S1)

(4.4) Sei $f: \mathbb{R}^n \rightarrow \mathbb{R}$ stetig differenzierbar und nach unten beschränkt. Dann gilt:

- $(s^k)^T y^k > 0$ für alle k
- B_k symmetrisch positiv definit für alle k
- Das Verfahren ist wohldefiniert.

4. Quasi-Newton-Verfahren

(4.5) Lokale Konvergenz des BFGS-Verfahrens

Sei $f \in C^2(\mathbb{R}^n, \mathbb{R})$, D^2f lokal Lipschitz-stetig und sei x^* striktes Minimum. Dann existiert $\delta > 0$ und $\varepsilon > 0$, sodass für $x^0 \in \mathbb{R}^n$ und B_0 symmetrisch positiv definit mit $\|x^0 - x^*\| \leq \delta$, $\|B_0 - D^2f(x^*)\| \leq \varepsilon$ das ungedämpfte BFGS-Verfahren superlinear konvergiert.

(4.6) Globale Konvergenz des BFGS-Verfahrens

Sei $f \in C^2(\mathbb{R}^n, \mathbb{R})$, die Levelmenge $\mathcal{L}(x^0)$ sei konvex und f sei auf $\mathcal{L}(x^0)$ gleichmäßig konvex. Dann konvergiert Algorithmus (4.3) für beliebige $x^0 \in \mathbb{R}^n$ und symmetrisch positiv definite B_0 gegen das Minimum x^* .

5. Nichtlineare cg-Verfahren

(5.1) Fletcher-Reeves-Verfahren

S0) Wähle $x^0 \in \mathbb{R}^n$, $\varepsilon \geq 0$, $0 < \sigma < \rho < \frac{1}{2}$, $d^0 = -\nabla f(x^0)$. Setze $k = 0$.

S1) falls $\|\nabla f(x^k)\| \leq \varepsilon$ STOP

S2) bestimme $t_k > 0$ mit

$$f(x^k + t_k d^k) \leq f(x^k) + \sigma t_k \nabla f(x^k)^T d^k$$

$$|\nabla f(x^k + t_k d^k)^T d^k| \leq -\rho \nabla f(x^k)^T d^k$$

S3) setze

$$\begin{aligned} x^{k+1} &= x^k + t_k d^k \\ \beta_k &= \frac{\|\nabla f(x^{k+1})\|^2}{\|\nabla f(x^k)\|^2} \\ d^{k+1} &= -\nabla f(x^{k+1}) + \beta_k d^k \end{aligned}$$

S4) setze $k := k + 1$, gehe zu S1)

Variante von Polak-Ribière:
$$\beta_k = \frac{(\nabla f(x^{k+1}) - \nabla f(x^k))^T \nabla f(x^{k+1})}{\|\nabla f(x^k)\|^2}$$

5. Nichtlineare cg-Verfahren

- (5.2) Sei $f: \mathbb{R}^n \rightarrow \mathbb{R}$ stetig differenzierbar, und sei f nach unten beschränkt. Dann ist Algorithmus (5.1) wohldefiniert, und es gilt:

$$-\frac{1}{1-\rho} \leq \frac{\nabla f(x^k)^T d^k}{\|\nabla f(x^k)\|^2} \leq -2 + \frac{1}{1-\rho}$$

- (5.3) Sei zusätzlich ∇f Lipschitz-stetig auf $\mathcal{L}(x^0)$.
Dann gilt: $\liminf_{k \rightarrow \infty} \|\nabla f(x^k)\| = 0$.
- (5.4) Sei f zweimal stetig differenzierbar, $\mathcal{L}(x^0)$ konvex und f gleichmäßig konvex auf $\mathcal{L}(x^0)$.
Dann konvergiert Algorithmus (5.1) gegen das eindeutige Minimum x^* .

6. Trust-Region-Verfahren

(6.1) $d^* \in \mathbb{R}^n$ ist genau dann eine Lösung von

$$(P) \quad \text{minimiere } q(d) = g^T d + \frac{1}{2} d^T H d \text{ unter der Bedingung } \|d\| \leq \Delta,$$

wenn $\lambda^* \in \mathbb{R}$ existiert mit

- a) $(H + 2\lambda^* I)d^* = -g$
- b) $\lambda^* \geq 0, \|d^*\| \leq \Delta, \lambda^*(\|d^*\| - \Delta) = 0$
- c) $H + 2\lambda^* I$ positiv semidefinit.

Zu einem Minimum d^* ist der Lagrangeparameter $\lambda^* = -\frac{(g + Hd^*)^T d^*}{2\Delta^2}$
eindeutig.

6. Trust-Region-Verfahren

(6.2) Trust-Region-Newton-Verfahren

S0) Wähle $x^0 \in \mathbb{R}^n$, $\Delta_0 > 0$, $\Delta_{\min} > 0$, $0 < \rho_1 < \rho_2 < 1$, $0 < \sigma_1 < 1 < \sigma_2$, $\varepsilon \geq 0$. Setze $k = 0$.

S1) falls $\|\nabla f(x^k)\| \leq \varepsilon$ STOP

S2) Bestimme ein Minimum d^k von

$$q_k(d) = f(x^k) + \nabla f(x^k)^T d + \frac{1}{2} d^T D^2 f(x^k) d \quad \text{unter} \quad \|d\| \leq \Delta_k$$

S3) berechne $r_k = \frac{f(x^k) - f(x^k + d^k)}{q_k(0) - q_k(d^k)}$ und setze

$$x^{k+1} = \begin{cases} x^k + d^k & \text{falls } r_k \geq \rho_1 \\ x^k & \text{sonst} \end{cases}$$

(Sprechweise: Im Fall $r_k \geq \rho_1$ heißt der k -te Iterationsschritt *erfolgreich*.)

S4)

$$\Delta_{k+1} = \begin{cases} \sigma_1 \Delta_k & \text{falls } r_k < \rho_1 \\ \max\{\Delta_{\min}, \Delta_k\} & \text{falls } r_k \in [\rho_1, \rho_2] \\ \max\{\Delta_{\min}, \sigma_2 \Delta_k\} & \text{falls } r_k > \rho_2 \end{cases}$$

S5) $k := k + 1$, gehe zu S1).

6. Trust-Region-Verfahren

- (6.3) Für $d^k \neq 0$ gilt $q_k(0) - q_k(d^k) \geq \frac{1}{2} \|\nabla f(x^k)\| \min \left\{ \Delta_k, \frac{\|\nabla f(x^k)\|}{\|H_k\|} \right\}$.
- (6.4) Sei $f: \mathbb{R}^n \rightarrow \mathbb{R}$ zweimal stetig differenzierbar und sei $\{x^k\}$ die Folge aus (6.2).
Sei $\{x^k\}_K$ eine gegen x^* konvergente Teilfolge.
Wenn x^* kein stationärer Punkt ist, dann gilt $\liminf_{k \in K} \Delta_k > 0$.
- (6.5) Es gibt unendlich viele erfolgreiche Iterationsschritte.
- (6.6) Jeder Häufungspunkt von $\{x^k\}$ ist stationärer Punkt von f .
- (6.7) Sei x^* Häufungspunkt von $\{x^k\}$, und sei $D^2 f(x^*)$ positiv definit. Dann gilt:
- Die gesamte Folge $\{x^k\}$ konvergiert gegen x^* .
 - Es existiert $k_0 > 0$, sodass alle Schritte $k \geq k_0$ erfolgreich sind.
 - Es existiert $\bar{\Delta} > 0$ mit $\Delta_k \geq \bar{\Delta}$ für alle $k \in \mathbb{N}$.
 - Die Konvergenzrate ist mindestens superlinear.
 - Falls $D^2 f$ lokal Lipschitz-stetig ist, ist die Konvergenz quadratisch.

7. Innere-Punkte-Verfahren

- (7.1) Seien $x \in \mathbb{R}^n$, $A \in \mathbb{R}^{m,n}$, $b \in \mathbb{R}^m$. Dann gilt:
 Wenn $(x, y, z) \in \mathbb{R}^n \times \mathbb{R}^m \times \mathbb{R}^n$ das KKT-System

$$\begin{aligned}
 (L) \quad 0 &= A^T y + z - c \\
 0 &= Ax - b \\
 0 &= x^T z, \quad x \geq 0, \quad z \geq 0 \quad (\text{also } x_j z_j = 0 \text{ für } j = 1, \dots, n)
 \end{aligned}$$

löst, dann löst $x \in \mathbb{R}^n$

$$(P) \quad \text{minimiere } c^T x \text{ unter } x \geq 0, Ax = b$$

und $y \in \mathbb{R}^m$ löst

$$(D) \quad \text{maximiere } b^T y \text{ unter } A^T y \leq c.$$

- (7.2) Sei $\text{rang } A = m$ und $\begin{pmatrix} x \\ z \end{pmatrix} > 0$. Betrachte $F \begin{pmatrix} x \\ y \\ z \end{pmatrix} = \begin{pmatrix} A^T y + z - c \\ Ax - b \\ \text{diag}(x_j z_j) \end{pmatrix}$.

Dann ist $DF \begin{pmatrix} x \\ y \\ z \end{pmatrix} = \begin{pmatrix} 0 & A^T & I \\ A & 0 & 0 \\ \text{diag}(z) & 0 & \text{diag}(x) \end{pmatrix}$ regulär.

7. Innere-Punkte-Verfahren

(7.3) Sei $\tau > 0$. Wenn $(x_\tau, y_\tau, z_\tau) \in \mathbb{R}^n \times \mathbb{R}^m \times \mathbb{R}^n$ das System

$$(L_\tau) \quad \begin{aligned} A^T y + z &= c \\ Ax &= b \\ x_j z_j &= \tau \quad (j = 1, \dots, n) \quad x > 0, \quad z > 0 \end{aligned}$$

löst, dann löst $x_\tau \in \mathbb{R}^n$ das primale Barriere-Problem

$$(P_\tau) \quad \text{minimiere } c^T x - \tau \sum_{j=1}^n \log x_j \text{ unter } Ax = b, x > 0$$

und $(y_\tau, z_\tau) \in \mathbb{R}^m \times \mathbb{R}^n$ löst das duale Barriere Problem

$$(D_\tau) \quad \text{maximiere } b^T y + \tau \sum_{i=1}^n \log z_i \text{ unter } A^T y + z = c, z > 0.$$

$$(7.4) \quad \mathcal{F} = \left\{ \begin{pmatrix} x \\ y \\ z \end{pmatrix} \in \mathbb{R}^n \times \mathbb{R}^m \times \mathbb{R}^n : Ax = b, A^T y + z = c, x \geq 0, z \geq 0 \right\}$$

(primal-dual) zulässige Menge

$$\mathcal{F}^0 = \left\{ \begin{pmatrix} x \\ y \\ z \end{pmatrix} \in \mathcal{F} : x > 0, z > 0 \right\} \text{ (primal-dual) strikt zulässige Menge}$$

7. Innere-Punkte-Verfahren

(7.5) Sei $\mathcal{F}^0 \neq \emptyset, \tau > 0$. Dann gilt:

a) (P_τ) ist lösbar

b) Es existiert eine Lösung $\begin{pmatrix} x_\tau \\ y_\tau \\ z_\tau \end{pmatrix}$ von (L_τ) .

Dabei ist x_z, z_τ eindeutig, und y_z eindeutig falls $\text{rang } A = m$.

(7.6) Die Abbildung $\tau \mapsto \begin{pmatrix} x_\tau \\ y_\tau \\ z_\tau \end{pmatrix}$ heißt *zentraler Pfad*.

(7.7) Es gilt: $\tau = \frac{1}{n} x_\tau^T z_\tau = \frac{1}{n} (c^T x_\tau - b^T y_\tau)$.
 $\frac{1}{n} x_\tau^T z_\tau$ heißt *gewichtete Dualitätslücke*.

7. Innere-Punkte-Verfahren

(7.8) Zulässiges Innere-Punkte-Verfahren

S0) Wähle $\gamma \in (0, 1), \sigma \in (0, 1), \varepsilon \in (0, 1)$

$$\begin{pmatrix} x^0 \\ y^0 \\ z^0 \end{pmatrix} \in \mathcal{N}(\gamma) := \left\{ \begin{pmatrix} x \\ y \\ z \end{pmatrix} \in \mathcal{F}^0 : x_j z_j \geq \gamma \frac{1}{n} x^T z \text{ für } j = 1, \dots, n \right\}$$

Setze $k = 0$.

S1) falls $\mu_k := \frac{1}{n} (x^k)^T z^k \leq \varepsilon$ STOP

S2) bestimme $\begin{pmatrix} \Delta x^k \\ \Delta y^k \\ \Delta z^k \end{pmatrix}$ als Lösung von

$$\begin{pmatrix} 0 & A^T & I \\ A & 0 & 0 \\ z^k & 0 & X^k \end{pmatrix} \begin{pmatrix} \Delta x^k \\ \Delta y^k \\ \Delta z^k \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \\ -X^k z^k e + \sigma \mu_k e \end{pmatrix}$$

mit $X^k = \text{diag}(x^k), Z^k = \text{diag}(z^k)$.

S3) wähle t_k als größte Schrittweite $t \in [0, 1]$ mit $\begin{pmatrix} x^k \\ y^k \\ z^k \end{pmatrix} + t \begin{pmatrix} \Delta x^k \\ \Delta y^k \\ \Delta z^k \end{pmatrix} \in \mathcal{N}(\gamma)$.

S4) setze $\begin{pmatrix} x^{k+1} \\ y^{k+1} \\ z^{k+1} \end{pmatrix} = \begin{pmatrix} x^k \\ y^k \\ z^k \end{pmatrix} + t_k \begin{pmatrix} \Delta x^k \\ \Delta y^k \\ \Delta z^k \end{pmatrix}$, setze $k := k + 1$ und gehe zu S1).

7. Innere-Punkte-Verfahren

(7.9) Es gilt $(\Delta x^k)^T \Delta z^k = 0$ und $\mu_k(t) = (1 - t(1 - \sigma))\mu_k$.

(7.10) Wenn $\delta > 0, \omega > 0$ existiert, sodass für die Schrittweite $t_k \in [0, 1]$

$$t_k \geq \frac{\delta}{n^\omega}$$

erfüllt ist, dann gilt für alle $\varepsilon \in (0, \min\{1, \mu_0\})$

$$\mu_k \leq \varepsilon \quad \text{für} \quad k \geq \log\left(\frac{\mu_0}{\varepsilon}\right) \frac{n^\omega}{\delta(1-\sigma)}.$$

(7.11) Es gilt $\begin{pmatrix} x^k(t) \\ y^k(t) \\ z^k(t) \end{pmatrix} = \begin{pmatrix} x^k \\ y^k \\ z^k \end{pmatrix} + t \begin{pmatrix} \Delta x^k \\ \Delta y^k \\ \Delta z^k \end{pmatrix} \in \mathcal{N}(\gamma)$ für alle $t \in [0, \bar{t}_k]$ mit

$$\bar{t}_k = 2^{3/2} \gamma \frac{\sigma}{n} \frac{1-\gamma}{1+\gamma}.$$

(7.12) Für $u, v \in \mathbb{R}^n$ mit $u^T v \geq 0$ gilt

$$\|Uv\| \leq 2^{-3/2} \|u + v\|^2 \quad (U = \text{diag}(u), V = \text{diag}(v)).$$

(7.13) Es gilt $\|\Delta X^k \Delta Z^k e\| \leq 2^{-3/2} \left(1 + \frac{1}{\gamma}\right) n \mu_k$.

7. Innere-Punkte-Verfahren

$$S^n = \{A \in \mathbb{R}^{n \times n} : A^T = A\}$$

$$S_+^n = \{A \in S^n : A \geq 0\}$$

$$S_{++}^n = \{A \in S_+^n : A > 0\}$$

symmetrisch positiv semidefinit

symmetrisch positiv definit

(7.14) Seien $C, A_1, \dots, A_m \in S^n$, $b \in \mathbb{R}^n$. Dann heißt

$$(P) \quad C : X \text{ unter } X \geq 0, A_i : X = b_i \quad (i = 1, \dots, m)$$

semidefinites Programm.

(7.15) a) $g(X) = -\lambda_{\min}(X)$ ist konvex auf S^n

b) $S_+^n \subset S^n$ ist konvex und abgeschlossen

c) für $X \in S^n$ gilt: $X \geq 0 \iff X : Y \geq 0 \quad \forall Y \in S_+^n$.

(7.16) Dualitätssatz für semidefinite Programme

a) Für alle zulässigen $X \in M$ und $b \in N$ gilt: $C : X \geq b^T y$.

b) Falls ein strikt zulässiges Tripel $(\hat{X}, \hat{y}, \hat{Z}) \in S_{++}^n \times \mathbb{R}^n \times S_{++}^n$

existiert mit $A_i : \hat{X} = b_i \quad (i = 1, \dots, m)$ und $\sum_{i=1}^m \hat{y}_i A_i + \hat{Z} = C$,

dann sind (P) und (D) lösbar mit $\min(P) = \max(D)$.

7. Innere-Punkte-Verfahren

Betrachte zu $\tau > 0$ die Barriereprobleme

(P_τ) minimiere $C : X + \tau \log \det X$ unter $A_i : X = b_i \quad (i = 1, \dots, m)$

(D_τ) maximiere $b^T y + \tau \log \det Z$ unter $\sum_{i=1}^m y_i A_i + Z = C$.

(7.17) Sei (X_τ, y_τ, Z_τ) Lösung des KKT-Systems

$$\begin{aligned} \sum_{i=1}^m y_i A_i + Z_\tau &= C \\ A_i : X_\tau - b_i &= 0 \\ X_\tau Z_\tau + Z_\tau X_\tau &= 2\tau I \end{aligned}$$

dann ist X_τ Lösung von (P_τ) und y_τ Lösung von (D_τ) .

7. Innere-Punkte-Verfahren

(7.18) Zulässiges Innere-Punkte-Verfahren für semidefinite Programme

S0) Wähle X^0, y^0, Z^0 mit $X^0, Z^0 > 0$, $\sum y_i A_i + Z^0 = C$
 $\tau_0 > 0, \varepsilon \geq 0$ $A_i: X^0 = b_i$

S1) Falls $\|XZ\|_F \leq \varepsilon$ STOP

S2) Bestimme $\Delta X^k, \Delta y^k, \Delta Z^k$ mit

$$\sum_{i=1}^m \Delta y_i^k A_i + \Delta Z^k = 0$$

$$A_i: \Delta X = 0 \quad (i = 1, \dots, m)$$

$$Z^k \Delta X^k + X^k \Delta Z^k + \Delta X^k Z^k + \Delta Z^k X^k = 2\tau_k I - X^k Z^k - Z^k X^k$$

S3) Bestimme $t_k > 0$ mit $X^k + t_k \Delta X^k > 0$ und $Z^k + t_k \Delta Z^k > 0$

S4) Setze $\begin{pmatrix} X^{k+1} \\ y^{k+1} \\ Z^{k+1} \end{pmatrix} = \begin{pmatrix} X^k \\ y^k \\ Z^k \end{pmatrix} + t_k \begin{pmatrix} \Delta X^k \\ \Delta y^k \\ \Delta Z^k \end{pmatrix}$

wähle $\tau_{k+1} \in (0, \tau_k)$; setze $k := k + 1$, gehe zu S1).



7. Innere-Punkte-Verfahren

(7.19) Seien A_1, \dots, A_m linear unabhängig in S^n , $X^k, Z^k \in S_{++}^n$.
Dann gilt für die Lösung von S2) aus (7.18):

- a) Die Matrix $M_k = (\text{Spur}(A_i(Z^k)^{-1} A_j X^k))_{ij} \in \mathbb{R}^{m,m}$ ist symmetrisch positiv definit.
- b) $M_k \Delta y^k = c^k$ mit $c^k = (\text{Spur}(A_i X^k - \tau A_i (Z^k)^{-1}))_{i=1 \dots m}$.
- c) $Z^k \Delta X^k + \Delta X^k Z^k = 2\tau I - X^k Z^k - Z^k X^k + \sum_{i=1}^m \Delta y_i^k (A_i X^k + X^k A_i)$.

(7.20) Sei $Z \in S_{++}^n$ und $B \in S^n$. Dann besitzt die Lyapunov-Gleichung

$$Z \Delta X + \Delta X Z = B$$

genau eine Lösung $\Delta X \in S^n$.

8. Penalty-Verfahren

Zu $f: \mathbb{R}^n \rightarrow \mathbb{R}$ und $h: \mathbb{R}^n \rightarrow \mathbb{R}^m$ betrachte

(P) Minimiere $f(x)$ auf $M = \{x \in \mathbb{R}^n: h(x) = 0\}$.

(8.1) S0) Wähle $\varepsilon \geq 0$, $\alpha_0 > 0$, setze $k = 0$.

S1) Bestimme eine Lösung $x^k \in \mathbb{R}^n$ der unrestringierten Aufgabe

(P_k) Minimiere $f_k(x) := f(x) + \frac{\alpha_k}{2} \|h(x)\|^2$

S2) falls $\|h(x^k)\| \leq \varepsilon$ STOP

S3) Wähle $\alpha_{k+1} > \alpha_k$, setze $k := k + 1$, gehe zu S1).

(8.2) Seien f, h stetig, α_k streng monoton steigend mit $\lim_{k \rightarrow \infty} \alpha_k = \infty$,

sei (P) zulässig (d.h. $M \neq \emptyset$) und (8.1) wohldefiniert

(d.h. in S1) existiert eine Lösung x^k). Dann gilt:

a) $\{f_k(x^k)\}$ ist monoton wachsend. d) $\lim_{k \rightarrow \infty} h(x^k) = 0$.

b) $\{\|h(x^k)\|\}$ ist monoton fallend. e) Jeder Häufungspunkt von $\{x^k\}$ löst (P).

c) $\{f(x^k)\}$ ist monoton wachsend.

(8.3) Die Folge $\{x^k\}$ aus (8.1) konvergiert gegen x^* und $Dh(x^*)$ habe maximalen Rang. Dann gilt:

$y^k := \alpha_k h(x^k)$ konvergiert gegen ein y^* , und (x^*, y^*) ist KKT-Punkt von (P).

8. Exakte Penalty-Verfahren

Nun betrachte zu $f: \mathbb{R}^n \rightarrow \mathbb{R}$, $y: \mathbb{R}^n \rightarrow \mathbb{R}^p$, $h: \mathbb{R}^n \rightarrow \mathbb{R}^m$

(P) Minimiere $f(x)$ auf $M = \{x \in \mathbb{R}^n: y(x) \leq 0 \text{ und } h(x) = 0\}$.

(8.4)

- a) Eine stetige Funktion $r: \mathbb{R}^n \rightarrow \mathbb{R}$ heißt *Penalty-Funktion* zu M , wenn $r(x) \geq 0$ für $x \in \mathbb{R}^n$ und
- $$r(x) = 0 \iff x \in M.$$
- b) Sei heißt *exakt* in einem Minimum $x^* \in M$ von (P), wenn $\bar{\alpha} > 0$ existiert, sodass für alle $\alpha \geq \bar{\alpha}$ gilt: x^* ist Minimum von
- (P $_{\alpha}$) Minimiere $f_{r,\alpha}(x) := f(x) + \alpha r(x)$.

(8.5) Sei x^* ein lokales Minimum von (P) mit $\nabla f(x^*) \neq 0$, und sei r exakt in x^* . Dann ist r nicht differenzierbar in x^* .

(8.6) Seien f, g stetig differenzierbar und konvex, $h(x) = Ax - b$, und sei (x^*, y^*, z^*) ein KKT-Punkt von (P). Dann ist die ℓ_1 -Penalty-Funktion

$$r_1(x) = \sum_{k=0}^p \max\{0, g_k(x)\} + \sum_{i=0}^m |h_i(x)|$$

exakt in x^* .

8. Multiplier-Penalty-Verfahren

(8.7) Sei (x^*, y^*) ein KKT-Punkt zur Minimierung von $f(x)$ unter $h(x) = 0$ mit

$$d^T D_x^2 L(x^*, y^*) d > 0 \text{ für } d \neq 0 \text{ mit } Dh(x^*)d = 0.$$

Dann existiert $\bar{\alpha} > 0$, sodass für $\alpha \geq \bar{\alpha}$ gilt:

x^* ist striktes lokales Minimum der *erweiterten Lagrange-Funktion*

$$L_\alpha(x, y^*) = f(x) + h(x)^T y^* + \frac{\alpha}{2} \|h(x)\|^2.$$

(8.8) Multiplier-Penalty-Verfahren

S0) Wähle $x^0 \in \mathbb{R}^n$, $y^0 \in \mathbb{R}^m$, $\alpha_0 > 0$, $\varepsilon \geq 0$, $c \in (0, 1)$, $\rho > 1$. Setze $k = 0$.

S1) Falls $\|\nabla_x L(x^k, y^k)\| \leq \varepsilon$, $\|h(x^k)\| \leq \varepsilon$ STOP

S2) Bestimme ein Minimum x^{k+1} von

$$(L_k) \text{ Minimiere } L_{\alpha_k}(x, y^k), \quad x \in \mathbb{R}^n$$

$$\text{und setze } y^{k+1} = y^k + \alpha_k h(x^{k+1}).$$

S3) Falls $\|h(x^{k+1})\| > c\|h(x^k)\|$, setze $\alpha_{k+1} = \rho\alpha_k$ sonst setze $\alpha_{k+1} = \alpha_k$.

S4) Setze $k := k + 1$ und gehe zu S1).

Erweiterte Lagrange-Funktion für Ungleichungsrestriktionen:

$$L_\alpha(x, y, z) = f(x) + y^T h(x) + \frac{\alpha}{2} \|h(x)\|^2 + \frac{1}{2\alpha} \sum_{k=1}^p \left(\max\{0, z_k + \alpha g_k(x)\}^2 - z_k^2 \right)$$

9. Aktive-Mengen Strategien

Sei $H \in \mathbb{R}^{n,n}$ symmetrisch positiv definit, $c \in \mathbb{R}^n$, $A \in \mathbb{R}^{m,n}$, $b \in \mathbb{R}^m$.
Betrachte das Quadratische Programm

$$(P) \quad \text{Minimiere } f(x) := \frac{1}{2}x^T Hx + c^T x \text{ unter } Ax \leq b.$$

(9.1) Primal-duales Aktive-Mengen-Verfahren

S0) Wähle $(x^0, y^0) \in \mathbb{R}^n \times \mathbb{R}^m$, $\alpha > 0$, $\varepsilon \geq 0$. Setze $k = 0$

S1) falls $\|Hx^k + c + A^T y^k\| \leq \varepsilon$ und $\|\max\{0, Ax^k - b\}\| \leq \varepsilon$ STOP

S2) setze

$$\mathcal{A}_k = \{i \in \{1, \dots, m\} : y_i^k + \alpha(Ax^k - b)_i > 0\},$$

$$\mathcal{I}_k = \{i \in \{1, \dots, m\} : y_i^k + \alpha(Ax^k - b)_i \leq 0\}.$$

Sei (x^{k+1}, y^{k+1}) Lösung von

$$(P_k) \quad Hx^{k+1} + c + A^T y^{k+1} = 0$$

$$(Ax^{k+1})_i = b_i \quad i \in \mathcal{A}_k$$

$$y_i^{k+1} = 0 \quad i \in \mathcal{I}_k$$

S3) setze $k := k + 1$ und gehe zu S1).

9. Aktive-Mengen Strategien

(9.2) $H = (h_{ij}) \in \mathbb{R}^{n,n}$ heißt *M-Matrix*, wenn gilt:

a) $h_{ii} > 0$

b) $h_{ij} \leq 0$ für $i \neq j$

c) $d \geq 0 \implies H^{-1}d \geq 0$

Dann gilt auch: $d_{\mathcal{A}} \geq 0 \implies H_{\mathcal{A},\mathcal{A}}^{-1}d_{\mathcal{A}} \geq 0$.

(9.3) Sei H eine *M-Matrix* und $A = I$. Dann gilt:

a) $x^* \leq x^{k+1} \leq x^k$ für $k \geq 1$

b) $x^k \leq b$ für $k \geq 2$

c) es existiert $k_0 > 0$ mit $y^k \geq 0$ für $k \geq k_0$.

d) $\lim_{k \rightarrow \infty} x^k = x^*$

(9.4) Eine Funktion $\varphi: \mathbb{R}^n \times \mathbb{R}^m \rightarrow \mathbb{R}^m$ heißt *Komplementaritätsfunktion* zu (P) , wenn gilt:

$$\varphi(x, y) = 0 \iff Ax \leq b, y \geq 0, (Ax - b)^T y = 0$$

(9.5) Zu $\alpha > 0$ ist $\varphi(x, y) = y - \max\{0, y + \alpha(Ax - b)\}$ Komplementaritätsfunktion zu (P) .

9. Verallgemeinertes Newton-Verfahren

- (9.7) Eine Abbildung $F: \mathbb{R}^n \rightarrow \mathbb{R}^m$ heißt *Newton-differenzierbar*, wenn eine Abbildung $G: \mathbb{R} \rightarrow \mathbb{R}^{m,n}$ (*Newton-Ableitung*) existiert, sodass gilt:

$$\lim_{d \rightarrow 0} \frac{1}{\|d\|} \|f(x+d) - F(x) - G(x+d)d\| = 0.$$

- (9.7) Sei $F: \mathbb{R}^n \rightarrow \mathbb{R}^m$ Newton-differenzierbar mit Newton-Ableitung $G: \mathbb{R} \rightarrow \mathbb{R}^{m,n}$, und sei $h: \mathbb{R}^k \rightarrow \mathbb{R}^n$ stetig differenzierbar. Dann ist $F \circ h$ Newton-differenzierbar mit Newton-Ableitung $y \mapsto F(h(y))Dh(y)$.

- (9.8) Sei x^* Nullstelle von F (d.h. $F(x^*) = 0$), und sei F Newton-differenzierbar mit Newton-Ableitung G .

Zu einem $\varepsilon > 0$ sei $G(x^* + d)$ invertierbar für alle d mit $\|d\| \leq \varepsilon$ und es existiere $C > 0$ mit $\|G(x^* + d)^{-1}\| \leq C$ für $\|d\| \leq \varepsilon$.

Dann existiert $\delta \in (0, \varepsilon)$, sodass für $x^0 \in \mathbb{R}^n$ mit $\|x^0 - x^*\| \leq \delta$ die Newton-Iteration

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

wohldefiniert ist und superlinear gegen x^* konvergiert.

10. SQP-Verfahren

Seien $f: \mathbb{R}^n \rightarrow \mathbb{R}$, $g: \mathbb{R}^n \rightarrow \mathbb{R}^p$ und $h: \mathbb{R}^n \rightarrow \mathbb{R}^m$ stetig differenzierbar.
 Betrachte

$$(P) \quad \text{Minimiere } f(x) \text{ unter } g(x) \leq 0 \text{ und } h(x) = 0.$$

Dann ist $(x^*, y^*, z^*) \in \mathbb{R}^n \times \mathbb{R}^m \times \mathbb{R}^p$ KKT-Punkt zu (P) , falls

$$F \begin{pmatrix} x^* \\ y^* \\ z^* \end{pmatrix} = 0 \text{ für } F \begin{pmatrix} x \\ y \\ z \end{pmatrix} = \begin{pmatrix} \nabla_x L(x, y, z) \\ h(x) \\ \varphi(x, z) \end{pmatrix} = \begin{pmatrix} \nabla f(x) + Dh(x)^T y + Dg(x)^T z \\ h(x) \\ (\min\{-g_i(x), z_i\}) \end{pmatrix}.$$

(10.1) S0) Wähle $(x^0, y^0, z^0) \in \mathbb{R}^n \times \mathbb{R}^m \times \mathbb{R}^p$ mit $z^0 \geq 0$, $H_0 \in \mathbb{R}^{n,n}$ symmetrisch, setze $k := 0$.

S1) Falls (x^k, y^k, z^k) KKT-Punkt von (P) STOP

S2) Berechne KKT-Punkt $(x^{k+1}, y^{k+1}, z^{k+1})$ von

$$(Q_k) \quad \begin{aligned} &\text{Minimiere } \nabla f(x^k)(x - x^k) + \frac{1}{2}(x - x^k)^T H_k(x - x^k) \\ &\text{unter } g(x^k) + Dg(x^k)(x - x^k) \leq 0 \\ &\text{und } h(x^k) + Dh(x^k)(x - x^k) = 0 \end{aligned}$$

S3) Wähle $H_{k+1} \in \mathbb{R}^{n,n}$ symmetrisch, setze $k := k + 1$ und gehe zu S1).

10. SQP-Verfahren

(10.2) In Algorithmus (10.1) wähle $H_k = D_x^2 L(x^k, y^k, z^k)$, und falls (Q_k) mehrere KKT-Punkte besitzt, wähle den KKT-Punkt $(x^{k+1}, y^{k+1}, z^{k+1})$ mit

$$\|(x^{k+1}, y^{k+1}, z^{k+1}) - (x^k, y^k, z^k)\| \quad (*)$$

minimal.

Sei (x^*, y^*, z^*) Lösung von (P) mit

1) strikte Komplementarität: $g_i(x^*) + z_i^* \neq 0 \quad (i = 1, \dots, p)$

2) (CQ2): $\{\nabla h_j(x^*), j = 1, \dots, m\} \cup \{\nabla g_i(x^*) : i \in I(x^*)\}$
 linear unabhängig mit $I(x^*) := \{i : g_i(x^*) = 0\}$

3) hinreichende Bedingung 2. Ordnung:

$$d^T D_x^2 L(x^*, y^*, z^*) d > 0 \text{ für } d \neq 0 \text{ mit} \\ Dh(x^*)d = 0, \nabla g(x^*)^T d = 0 \quad (i \in I(x^*))$$

Dann existiert $\varepsilon > 0$, sodass für alle (x^0, y^0, z^0) mit

$$\|(x^0, y^0, z^0) - (x^*, y^*, z^*)\| < \varepsilon \text{ gilt:}$$

- (Q_k) ist wohldefiniert und $\{(x^k, y^k, z^k)\}$ konvergiert gegen (x^*, y^*, z^*) .
- Die Konvergenz ist superlinear.
- Sind $D^2 f$, $D^2 h_j$, $D^2 g_i$ lokal Lipschitz-stetig, so ist die Konvergenz quadratisch.

10. SQP-Verfahren

Definiere $\mathcal{F}(\tau) = \{x \in \mathbb{R}^n : |h_j(x)| \leq \tau \ (j = 1, \dots, m), g_i(x) \leq \tau \ (i = 1, \dots, p)\}$.

(10.3) S0) Wähle (x^0, y^0, z^0) und $\tau > 0$ mit $x^0 \in F(\tau), z^0 \geq 0, \delta > 0, \rho \in (0, 1), \sigma \in (0, 1), H_0$ symmetrisch, $\beta_j^0 = \delta \ (j = 1, \dots, m), \alpha_i^0 = \delta \ (i = 1, \dots, p); k = 0$.

S1) Wenn (x^k, y^k, z^k) KKT-Punkt von (P) STOP

S2) Bestimme KKT-Punkt (d^k, y^{k+1}, z^{k+1}) von

$$(Q_k) \quad \begin{array}{ll} \text{minimiere} & \nabla f(x^k)^T d + \frac{1}{2} d^T H_k d \\ \text{unter} & h(x^k) + Dh(x^k)d = 0, \quad g(x^k) + Dg(x^k)d \leq 0 \end{array}$$

S3) Anpassen der Penalty-Parameter: setze

$$\alpha_i^{k+1} = \begin{cases} z_i^{k+1} + 2\delta, & \alpha_i^k \leq z_i^{k+1} + \delta, \\ \alpha_i^k, & \text{sonst,} \end{cases} \quad \beta_j^{k+1} = \begin{cases} |y_j^{k+1}| + 2\delta, & \beta_j^k \leq |y_j^{k+1}| + \delta, \\ \beta_j^k, & \text{sonst,} \end{cases}$$

und definiere $f_{k+1}(x) = f(x) + \sum_{i=1}^p \alpha_i^{k+1} \max\{0, g_i(x)\} + \sum_{j=1}^m \beta_j^{k+1} |h_j(x)|$

S4) Wähle Schrittweite $t_k \in \{\rho^\ell : \ell = 0, 1, 2, \dots\}$ maximal mit

$$f_{k+1}(x^k + t_k d^k) \leq f_{k+1}(x^k) - t_k \sigma \left((d^k)^T H_k d^k + \delta \sum_{i=1}^p \max\{0, g_i(x^k)\} + \delta \|h(x^k)\|_\infty \right)$$

und $x^k + t_k d^k \in \mathcal{F}(\tau)$. Setze $x^{k+1} = x^k + t_k d^k$, wähle H_{k+1} .

Setze $k := k + 1$ und gehe zu S1).

10. SQP-Verfahren

(10.4) Es gelte:

- a) f, g_i konvex, $h(x) = Ax - b$ linear affin.
- b) Die Slaterbedingung sei erfüllt.
- c) $\rho_1 \|d\|^2 \leq d^T H_k d \leq \rho_2 \|d\|^2$.
- d) $\mathcal{F}(\tau_0)$ kompakt für ein $\tau_0 > 0$.

Dann ist (Q_k) lösbar, der Algorithmus (10.3) ist wohldefiniert, und die Iterierten $\{d^k\}, \{y^k\}, \{z^k\}$ sind beschränkt.

(10.5) Unter den Voraussetzungen von (10.4) ist jeder Häufungspunkt von $\{x^k\}$ ein KKT-Punkt (und damit Lösung) von (P) .

Zu x^k, H_k , und Δ_k definiere $h_k(d) = h(x^k) + Dh(x^k)d$ und

$$(NP) \quad \text{Minimiere } \|h_k(d^n)\| \text{ unter } \|d^n\| \leq \Delta_k$$

und zu $q_k(d) = \nabla f(x^k)^T d + \frac{1}{2} d^T H_k d$

$$(TP) \quad \text{Minimiere } q_k(d^n + d^t) \text{ unter } Dh(x^k)d^t = 0 \text{ und } \|d^t\| \leq \Delta_k.$$

Setze $L_\alpha(x, y) = f(x) + h(x)^T y + \alpha \|h(x)\|^2$ und
 $L_{k,\alpha}(d, \Delta y) = q_k(x) + h_k(d)^T \Delta y + \alpha \|h_k(d)\|^2$

10. SQP-Verfahren

(10.6) Trust-Region-SQP-Verfahren

S0) Wähle $\Delta_{\min} > 0$, $0 < \underline{\rho} < \bar{\rho} < 1$, $0 < \sigma_1 < 1 < \sigma_2$,

$\varepsilon > 0$, $x^0 \in \mathbb{R}^n$, $\Delta_0 \geq \Delta_{\min}$, $\alpha_0 > 0$, $\beta > 1$; setze $k = 0$.

S1) Bestimme Z_k . Falls $\|Z_k^T \nabla f(x^k)\| + \|h(x^k)\| \leq \varepsilon$ STOP

S2) Wähle symmetrische Approximation H_k von $D_x^2 L(x^k, y^k)$, löse (NP) und (TP), setze $d = d^n + d^t$, berechne Δy .

S3) Solange $L_{k, \alpha_k}(0, 0) - L_{k, \alpha_k}(d, \Delta y) \geq \frac{1}{2} (q_k^L(d^n) - q_k^L(d)) + \frac{\alpha_k}{2} (\|h(x^k)\|^2 - \|h(x^k) - Dh(x^k)d\|^2)$. Setze $\alpha_k := \beta \cdot \alpha_k$.

S4) Berechne $\rho_k = \frac{L_{\alpha_k}(x^k, y^k) - L_{\alpha_k}(x^k + d, y^k + \Delta y)}{L_{k, \alpha_k}(0, 0) - L_{k, \alpha_k}(d, \Delta y)}$

S5) Falls $\rho_k \geq \underline{\rho}$, setze $x^{k+1} = x^k + d$, $y^{k+1} = y^k + \Delta y$
sonst $x^{k+1} = x^k$, $y^{k+1} = y^k$

$$\alpha_{k+1} = \alpha_k \text{ und } \Delta_{k+1} = \begin{cases} \sigma_1 \Delta_k & \rho_k < \underline{\rho} \\ \max\{\Delta_m, \Delta_k\} & \rho_k \in [\underline{\rho}, \bar{\rho}] \\ \max\{\Delta_{\min}, \sigma_2 \Delta_k\} & \rho_k > \bar{\rho} \end{cases}$$

setze $k := k + 1$ und gehe zu S1).

11. Nicht-glatte Optimierung

(11.1) Sei $M \subset \mathbb{R}^n$ konvex und sei $f: M \rightarrow \mathbb{R}$ konvex.

Damit ist f im Inneren von M lokal Lipschitz-stetig.

(11.2) Sei $M \subset \mathbb{R}^n$ offen und konvex, $f: M \rightarrow \mathbb{R}$ konvex, $d \in \mathbb{R}^n, x \in M$. Dann gilt:

a) $q(t) = \frac{1}{2}(f(x+td) - f(x))$ ist monoton fallend für $t \rightarrow 0+$.

b) Die Richtungsableitung von f in x nach d existiert, und es gilt

$$Df(x; d) = \inf_{t>0} \frac{1}{t} (f(x+td) - f(x)).$$

(11.3) Sei $M \subset \mathbb{R}^n$ offen, konvex, und $f: M \rightarrow \mathbb{R}^n$ konvex, $x \in M$. Dann heißt

$$\partial f(x) = \{s \in \mathbb{R}^n : f(y) \geq f(x) + s^T(y-x) \quad \forall y \in M\}$$

das (konvexe) *Subdifferenzial* und $s \in \partial f(x)$ heißt *Subgradient*.

(11.4) Sei $M \subset \mathbb{R}^n$ offen, konvex, $f: M \rightarrow \mathbb{R}^n$ konvex, $x \in M$. Dann gilt:

a) $\partial f(x)$ ist nicht-leer, konvex und kompakt

b) $\partial f(x) = \{s \in \mathbb{R}^n : s^T d \leq Df(x; d) \quad \forall d \in \mathbb{R}^n\}$

c) $Df(x; d) = \max_{s \in \partial f(x)} s^T d$ für alle $d \in \mathbb{R}^n$.

(11.5) Sei $M \subset \mathbb{R}^n$ offen, konvex, $f: M \rightarrow \mathbb{R}$ konvex, $x^* \in M$. Dann ist äquivalent:

a) f nimmt sein Minimum in M an, d.h. $f(x) \geq f(x^*)$ für alle $x \in M$.

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

c) $Df(x^*; d) \geq 0$ für alle $d \in \mathbb{R}^n$.

11. Nicht-glatte Optimierung

- (11.6) a) Eine Abb. $f: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{\infty\}$ *erweiterte Funktion*.
 b) $\text{dom}(f) = \{x \in \mathbb{R}^n: f(x) < \infty\}$ heißt der *wesentliche Definitionsbereich* f heißt *echt* (proper), wenn $\text{dom}(f) \neq \emptyset$.
 c) Eine erweiterte Funktion heißt *konvex*, wenn für $x, y \in \mathbb{R}^n$, $\lambda \in (0, 1)$ gilt:

$$f(1 - \lambda)x + \lambda y \leq (1 - \lambda)f(x) + \lambda f(y).$$
- (11.7) $f: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{\infty\}$ konvex $\implies \text{dom}(f) \subset \mathbb{R}^n$ konvex.
- (11.8) Sei $f: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{\infty\}$ eine echte erweiterte Funktion.
 Dann heißt f *nach unten halbstetig* in $x \in \mathbb{R}^n$, falls gilt: $\liminf_{y \rightarrow x} f(y) \geq f(x)$.
 f heißt *nach unten halbstetig* (l.s.c. = lower semi-continuous) in $X \subset \mathbb{R}^n$, wenn f l.s.c. in allen $x \in X$.
- (11.9) Sei $f: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{\infty\}$ eine echte erweiterte Funktion. Dann ist äquivalent:
 a) f l.s.c. in \mathbb{R}^n .
 b) $\mathcal{L}(c) := \{x \in \mathbb{R}^n: f(x) \leq c\}$ ist abgeschlossen für alle $c \in \mathbb{R}$.
 c) $\text{epi}(f) = \{(x, \alpha) \in \mathbb{R}^n \times \mathbb{R}: \alpha \geq f(x)\}$ ist abgeschlossen in $\mathbb{R}^n \times \mathbb{R}$.
- (11.10) Sei $f: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{\infty\}$ eine echte *erweiterte* konvexe Funktion. Dann heißt
 $\partial f(x) = \{s \in \mathbb{R}^n: f(y) \geq f(x) + s^T(y - x) \forall y \in \mathbb{R}^n\}$ das *Subdifferenzial* von f .

11. Nicht-glatte Optimierung

(11.11) Sei $f: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{\infty\}$ echt und konvex. Dann gilt:

x^* Minimum von $f \iff 0 \in \partial f(x^*)$.

(11.12) Sei $f: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{\infty\}$ echt, konvex, $x^1, x^2 \in \mathbb{R}^n$, $s^1 \in \partial f(x^1)$, $s^2 \in \partial f(x^2)$.

Dann gilt: $(x^1 - x^2)^T (s^1 - s^2) \geq 0$ (Monotonie).

(11.12) Sei $f: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{\infty\}$ echt, konvex. Betrachte

$$(P) \quad \min f(x) \text{ auf } \mathbb{R}^n.$$

Dann gilt:

- Die Lösungsmenge von (P) ist konvex.
- Ist f strikt konvex auf $\text{dom}(f)$, dann existiert höchstens eine Lösung.
- Ist f l.s.c. und gleichmäßig konvex auf $\text{dom}(f)$, dann existiert genau eine Lösung.

11. Nicht-glatte Optimierung: Regularisierungsverfahren

(11.13) Moreau-Yosida-Regularisierung

Sei $f: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{\infty\}$ echt, l.s.c., konvex. Wähle $\gamma > 0$. Dann heißt

$$f_\gamma(x) := \min_{y \in \mathbb{R}^n} \left(f(y) + \frac{1}{2\gamma} \|x - y\|^2 \right) \text{ die Moreau-Yosida-Regularisierung von } f.$$

Es gilt: Für festes x ist $g_{\gamma,x}(y) = f(y) + \frac{1}{2\gamma} \|x - y\|^2$ gleichmäßig konvex auf $\text{dom}(f)$, d.h. es existiert eine eindeutige Lösung $p_\gamma(x)$ mit

$$g_{\gamma,x}(p_\gamma(x)) = \min_{y \in \mathbb{R}^n} g_{\gamma,x}(y) \text{ und } f_\gamma(x) = f(p_\gamma(x)) + \frac{1}{2\gamma} \|p_\gamma(x) - x\|^2.$$

(11.14) Proximal-Punkt-Verfahren

S0) Wähle $x^0 \in \text{dom}(f)$, $\gamma > 0$. Setze $k := 0$.

S1) Ist x^* Minimum von f STOP

S2) Berechne Minimierung x^{k+1} von $g_k(x) = f(x) + \frac{1}{2\gamma} \|x - x^k\|^2$

S3) Setze $k := k + 1$, gehe zu S1).

(11.15) a) $s^k := \frac{1}{\gamma}(x^{k-1} - x^k) \in \partial f(x^k)$

b) $\|s^k\|$ monoton fallend

c) $f(x^k) - f(x) \leq \frac{2}{k\gamma} (\|x - x^0\|^2 - \|x - x^k\|^2) - \frac{k\gamma}{2} \|s^k\|^2$ für alle $x \in \mathbb{R}^n$

d) falls die Lösungsmenge $S = \{x \in \mathbb{R}^n : f(x) = \inf_{y \in \mathbb{R}^n} f(y)\} \neq \emptyset$,

dann konvergiert $\{x^k\}$ gegen ein $x^* \in S$.

11. Nicht-glatte Optimierung: Regularisierungsverfahren

(11.16) Tikhonov-Regularisierungs-Verfahren

- S0) Wähle $x^0 \in \text{dom}(f)$ setze $k := 0$.
S1) Falls x^k Minimum von f STOP
S2) Wähle $\varepsilon_k > 0$ und bestimme x^{k+1} als globales Minimum von

$$f_{\varepsilon_k}(x) := f(x) + \frac{\varepsilon_k}{2} \|x\|^2$$

- S3) setze $k := k + 1$ und gehe zu S1).

(11.17) Sei $\{\varepsilon_k\}$ monoton fallend und $\lim \varepsilon_k = 0$. Dann gilt:

- a) Jeder Häufungspunkt von $\{x^k\}$ in Minimum von f .
b) $s^k := -\varepsilon_{k-1} x^k \in \partial f(x^k)$.
c) Falls die Lösungsmenge $S = \{x \in \mathbb{R}^n : f(x) = \inf_{y \in \mathbb{R}^n} f(y)\} \neq \emptyset$,
dann konvergiert $\{x^k\}$ gegen ein $x^* \in S$.

11. Nicht-glatte Optimierung: Subgradienten-Verfahren

Sei $f: \mathbb{R}^n \rightarrow \mathbb{R}$ konvex und $M \subset \mathbb{R}^n$ konvex und abgeschlossen.
Sei $P_M: \mathbb{R}^n \rightarrow M$ die Orthogonalprojektion auf M .

(11.18) Subgradienten-Verfahren

S0) Wähle $x^0 \in M$, $m_0 := f(x^0)$, setze $k := 0$.

S1) Falls x^k Minimum von f STOP

S2) Berechne $s^k \in \partial f(x^k)$; setze $d^k := -\frac{1}{\|s^k\|} s^k$,

wähle $t_k > 0$ und $x^{k+1} = P_M(x^k + t_k d^k)$

S3) $m_{k+1} := \min\{f(x^{k+1}), m_k\}$, setze $k := k + 1$ und gehe zu S1).

(11.19) Es sei $f^* = \inf_{y \in M} f(y) > -\infty$, und die Lösungsmenge $S = \{x \in \mathbb{R}^n: f(x) = f^*\}$

sei nicht leer. Die Folge $\{t_k\}$ sei monoton fallend mit

$$\lim_{k \rightarrow \infty} t_k = 0 \text{ und } \sum_{k=0}^{\infty} t_k = \infty.$$

Dann konvergiert die Folge $\{m_k\}$ gegen f^* .