

1 Einführung

(1.1) Sei $\mathcal{M} \subset \mathbb{R}^N$ und $f: \mathcal{M} \rightarrow \mathbb{R}$. Betrachte

(P) Minimiere $f(x)$ unter der Bedingung $x \in \mathcal{M}$.

- a) \mathcal{M} heißt die Menge der *zulässigen Punkte*.
- b) (P) heißt *zulässig*, falls $\mathcal{M} \neq \emptyset$.
- c) $x^* \in \mathbb{R}^N$ heißt *Lösung* von (P), wenn
 - i) x^* *zulässig* ist, d.h. $x^* \in \mathcal{M}$, und
 - ii) x^* *optimal* ist, d.h. $f(x^*) \leq f(x)$ für alle $x \in \mathcal{M}$.

In diesem Fall heißt (P) *lösbar*, und wir setzen

$$\min(\text{P}) = \min_{x \in \mathcal{M}} f(x) = f(x^*).$$

Falls die Lösung eindeutig ist, definieren wir

$$x^* = \arg \min_{x \in \mathcal{M}} f(x).$$

- d) Im Allgemeinen definieren wir

$$\inf(\text{P}) = \begin{cases} \inf_{x \in \mathcal{M}} f(x) & \text{falls } \mathcal{M} \neq \emptyset \\ +\infty & \text{falls } \mathcal{M} = \emptyset. \end{cases}$$

2.1 Konvexe Mengen und Polyeder – Konvexe Mengen

(2.1) a) Eine Menge $\mathcal{V} \subset \mathbb{R}^N$ heißt *linearer Teilraum / Unterraum*, wenn

$$x, y \in \mathcal{V}, \quad \lambda, \mu \in \mathbb{R} \quad \Rightarrow \quad \lambda x + \mu y \in \mathcal{V}.$$

b) Eine Menge $\mathcal{V} \subset \mathbb{R}^N$ heißt *affiner Teilraum*, wenn

$$x, y \in \mathcal{V}, \quad \lambda \in \mathbb{R} \quad \Rightarrow \quad (1 - \lambda)x + \lambda y \in \mathcal{V}.$$

c) Eine Menge $\mathcal{K} \subset \mathbb{R}^N$ heißt *konvex*, wenn

$$x, y \in \mathcal{K}, \quad \lambda \in [0, 1] \quad \Rightarrow \quad (1 - \lambda)x + \lambda y \in \mathcal{K}.$$

d) Eine Menge $\mathcal{C} \subset \mathbb{R}^N$ heißt *Kegel*, wenn

$$x \in \mathcal{C}, \quad \lambda \geq 0 \quad \Rightarrow \quad \lambda x \in \mathcal{C}.$$

(2.2) a) $\mathcal{V} \subset \mathbb{R}^N$ ist genau dann ein linearer Teilraum, wenn

$$x^k \in \mathcal{V}, \quad \lambda_k \in \mathbb{R}, \quad k = 1, \dots, K, \quad K \in \mathbb{N} \quad \Rightarrow \quad \sum_{k=1}^K \lambda_k x^k \in \mathcal{V}.$$

b) $\mathcal{V} \subset \mathbb{R}^N$ ist genau dann ein affiner Teilraum, wenn

$$x^k \in \mathcal{V}, \quad \lambda_k \in \mathbb{R}, \quad k = 1, \dots, K, \quad K \in \mathbb{N}, \quad \sum_{k=1}^K \lambda_k = 1 \quad \Rightarrow \quad \sum_{k=1}^K \lambda_k x^k \in \mathcal{V}.$$

c) $\mathcal{K} \subset \mathbb{R}^N$ ist genau dann konvex, wenn

$$x^k \in \mathcal{K}, \quad \lambda_k \geq 0, \quad k = 1, \dots, K, \quad K \in \mathbb{N}, \quad \sum_{k=1}^K \lambda_k = 1 \quad \Rightarrow \quad \sum_{k=1}^K \lambda_k x^k \in \mathcal{K}.$$

d) $\mathcal{C} \subset \mathbb{R}^N$ ist genau dann ein *konvexer Kegel*, wenn

$$x^k \in \mathcal{C}, \quad \lambda_k \geq 0, \quad k = 1, \dots, K, \quad K \in \mathbb{N} \quad \Rightarrow \quad \sum_{k=1}^K \lambda_k x^k \in \mathcal{C}.$$

2.1 Konvexe Mengen und Polyeder – Konvexe Mengen

- (2.5) a) Ein konvexer Kegel $\mathcal{C} \subset \mathbb{R}^N$ heißt *endlich erzeugt*, wenn eine endliche Teilmenge $\mathcal{S} = \{u^1, \dots, u^K\} \subset \mathbb{R}^N$ existiert mit

$$\mathcal{C} = \text{cone}(\mathcal{S}) = \left\{ \sum_{k=1}^K \lambda_k u^k : \lambda_k \geq 0 \right\} = \{U\lambda : \lambda \geq 0\}.$$

Dabei ist $U = (u^1 | \dots | u^K) \in \mathbb{R}^{N \times K}$.

- b) Eine Menge $\mathcal{E} = \{x \in \mathbb{R}^N : a^\top x = \gamma\}$ mit $a \in \mathbb{R}^N$, $a \neq 0$, und $\gamma \in \mathbb{R}$ heißt *(Hyper-)Ebene* im \mathbb{R}^N .
- c) Eine Menge $\mathcal{H} = \{x \in \mathbb{R}^N : a^\top x \leq \gamma\}$ mit $a \in \mathbb{R}^N$, $a \neq 0$, und $\gamma \in \mathbb{R}$ heißt *abgeschlossener Halbraum*.
- d) Eine Menge $\mathcal{M} \subset \mathbb{R}^N$ heißt *polyedral* (oder auch *Polyeder*), wenn sie als Durchschnitt von endlich vielen abgeschlossenen Halbräumen darstellbar ist, d. h. wenn eine Matrix $A \in \mathbb{R}^{K \times N}$ und ein Vektor $b \in \mathbb{R}^K$ existiert mit
- $$\mathcal{M} = \{x \in \mathbb{R}^N : Ax \leq b\}.$$
- e) Beschränkte Polyeder $\mathcal{M} \subset \mathbb{R}^N$ heißen *Polytope*.

2.2 Konvexe Mengen – Satz von Weyl / Farkas Lemma

(2.6) Satz von Weyl

Jeder endlich erzeugte konvexe Kegel $C = \{U\lambda : \lambda \geq 0\}$ ist polyedral und von der Form $C = \{x \in \mathbb{R}^N : Ax \leq 0\}$.

Insbesondere sind endlich erzeugte konvexe Kegel abgeschlossen.

(2.7) Sei $\mathcal{K} \subset \mathbb{R}^N$ eine konvexe, abgeschlossene Menge, $\mathcal{K} \neq \emptyset$.

Dann existiert zu jedem $x \in \mathbb{R}^N$ genau ein $x^* \in \mathcal{K}$ mit $\|x - x^*\| \leq \|x - z\|$ für alle $z \in \mathcal{K}$, und x^* ist eindeutig durch $(x - x^*)^\top (z - x^*) \leq 0$ für alle $z \in \mathcal{K}$ charakterisiert.

(2.8) Trennungssatz

Sei $\mathcal{K} \subset \mathbb{R}^N$ eine konvexe und abgeschlossene Menge, $\mathcal{K} \neq \emptyset$, und $x \notin \mathcal{K}$.

Dann existiert eine Hyperebene, die x und \mathcal{K} trennt, d. h.

es existiert $a \in \mathbb{R}^N$, $a \neq 0$, und $\gamma \in \mathbb{R}$ mit

$$a^\top z \leq \gamma < a^\top x \quad \text{für alle } z \in \mathcal{K}.$$

Ist \mathcal{K} sogar ein konvexer Kegel, so kann $\gamma = 0$ gewählt werden.

Wenn $\mathcal{K} \subset \mathbb{R}^N$ konvex, $\mathcal{K} \neq \emptyset$, und $x \in \partial\mathcal{K}$ ist, dann existiert $a \in \mathbb{R}^N$, $a \neq 0$, mit

$$a^\top z \leq a^\top x \quad \text{für alle } z \in \mathcal{K}.$$

(2.9) Lemma von Farkas

Seien $A \in \mathbb{R}^{K \times N}$ und $b \in \mathbb{R}^K$ gegeben.

Dann gilt genau eine der beiden folgenden Aussagen:

(i) $\{x \in \mathbb{R}^N : Ax = b, x \geq 0\} \neq \emptyset$

(ii) $\{y \in \mathbb{R}^K : A^\top y \leq 0, b^\top y > 0\} \neq \emptyset$

2.3 Konvexe Mengen – Hauptsatz der Polyedertheorie

(2.10) $\mathcal{M} \subset \mathbb{R}^N$ sei beliebige konvexe Menge.

a) $x \in \mathcal{M}$ heißt *Ecke* / *Extremalpunkt* von \mathcal{M} , wenn sich x nicht als echte Konvexkombination zweier verschiedener Punkte von \mathcal{M} darstellen lässt, d. h., wenn gilt:

$$y, z \in \mathcal{M}, \quad \lambda \in (0, 1), \quad x = \lambda y + (1 - \lambda)z \quad \Rightarrow \quad y = z.$$

b) Ein Vektor $u \in \mathbb{R}^N$, $u \neq 0$, heißt *freie Richtung* von \mathcal{M} , wenn es $x \in \mathcal{M}$ gibt, so dass der ganze Strahl $\{x + tu : t \geq 0\}$ zu \mathcal{M} gehört.

c) Eine freie Richtung $u \in \mathbb{R}^N$, $u \neq 0$, heißt *extremale Richtung* von \mathcal{M} , wenn sie sich nicht als echte Konvexkombination zweier linear unabhängiger freier Richtungen schreiben lässt, d. h., wenn gilt:

$$v, w \text{ freie Richtungen, } \lambda \in (0, 1), \quad u = \lambda v + (1 - \lambda)w \quad \Rightarrow \quad v, w \text{ linear abhängig.}$$

Strahlen der Form

$$S = \{x + tu : t \geq 0\} \subset \mathcal{M}$$

mit Ecke $x \in \mathcal{M}$ und extremaler Richtung u heißen *Extremalstrahlen*.

Mit $\text{extrP}(\mathcal{M})$ bezeichnen wir die Menge aller Extremalpunkte von \mathcal{M} .

Mit $\text{extrS}(\mathcal{M})$ bezeichnen wir die Vereinigung aller Extremalstrahlen von \mathcal{M} .

2.3 Konvexe Mengen – Hauptsatz der Polyedertheorie

(2.11) Ein Polyeder $\mathcal{M} = \{x \in \mathbb{R}^N : Ax \leq b\}$ hat nur endlich viele Ecken.

(2.12) Sei $\mathcal{J} \subset \{1, \dots, K\}$, $\mathcal{J} \neq \emptyset$.

Dann heißt $\mathcal{M}_{\mathcal{J}} = \{x \in \mathcal{M} : (Ax)_k = b_k \text{ für } k \in \mathcal{J}\}$ eine Seite von \mathcal{M} .

(2.13) Es gilt $\text{extrP}(\mathcal{M}_{\mathcal{J}}) \subset \text{extrP}(\mathcal{M})$ und $\text{extrS}(\mathcal{M}_{\mathcal{J}}) \subset \text{extrS}(\mathcal{M})$.

(2.15) Für den *relativen Rand*

$$\partial_{\text{rel}}\mathcal{M} = \{x \in \mathbb{R}^N : \mathcal{B}_{\varepsilon}(x) \cap \mathcal{M} \neq \emptyset \text{ und } \mathcal{B}_{\varepsilon}(x) \cap (\text{affine } \mathcal{M} \setminus \mathcal{M}) \neq \emptyset \text{ für alle } \varepsilon > 0\}$$

eines Polyeders gilt

$$\partial_{\text{rel}}\mathcal{M} \subset \bigcup \left\{ \mathcal{M}_{\mathcal{J}} : \mathcal{J} \subset \{1, \dots, K\}, \dim \mathcal{M}_{\mathcal{J}} < \dim \mathcal{M} \right\}.$$

(2.16) Sei $\mathcal{M} \subset \mathbb{R}^N$ konvex, $\mathcal{M} \neq \emptyset$. Dann ist das *relative Innere*

$$\text{int}_{\text{rel}}\mathcal{M} = \{x \in \mathcal{M} : \text{es existiert ein } \varepsilon > 0 \text{ mit } \mathcal{B}_{\varepsilon}(x) \cap \text{affine } \mathcal{M} \subset \mathcal{M}\}$$

nicht leer.

(2.18) Sei $\mathcal{M} \subset \mathbb{R}^N$ konvex, $\mathcal{M} \neq \emptyset$ und \mathcal{M} geradenfrei. Dann gilt $\mathcal{M} \subset \text{conv } \partial_{\text{rel}}\mathcal{M}$.

(2.19) Sei $\mathcal{M} \subset \mathbb{R}^N$ ein geradenfreies Polyeder. Dann ist $\mathcal{M} = \text{conv}\{\text{extrP}(\mathcal{M}) \cup \text{extrS}(\mathcal{M})\}$.

(2.20) Jedes (nichtleere) Polytop \mathcal{M} ist die konvexe Hülle seiner Ecken.

(2.21) Ein (nichtleerer) Polyeder \mathcal{M} ist genau dann geradenfrei, wenn er Ecken besitzt.

3 Existenz- und Dualitätstheorie für Lineare Programme

(3.1) Seien $A \in \mathbb{R}^{K \times N}$, $b \in \mathbb{R}^K$ und $c \in \mathbb{R}^N$ gegeben. Betrachte

$$(P) \quad \text{Minimiere } c^\top x \text{ auf } \mathcal{M} = \{x \in \mathbb{R}^N : Ax = b, x \geq 0\}.$$

Wenn $\mu^* := \inf\{c^\top x : x \in \mathcal{M}\} > -\infty$, dann gilt:

- a) Wenn (P) zulässig ist (d.h. $\mathcal{M} \neq \emptyset$), dann ist (P) auch lösbar.
- b) Falls (P) lösbar ist, so existiert auch eine Ecke als Lösung.

Das duale Problem zu (P) lautet

$$(D) \quad \text{Maximiere } b^\top y \text{ auf } \mathcal{M}^* = \{y \in \mathbb{R}^K : A^\top y \leq c\}.$$

(3.4) Sei $x \in \mathcal{M}$ und $y \in \mathcal{M}^*$. Dann gilt $b^\top y \leq c^\top x$.

(3.6) Dualitätssatz

- a) (P) und (D) zulässig \Rightarrow (P) und (D) lösbar und $\min(P) = \max(D)$
- b) (P) zulässig und (D) nicht zulässig $\Rightarrow \inf(P) = -\infty$.
- c) (D) zulässig und (P) nicht zulässig $\Rightarrow \sup(D) = \infty$

(3.7) Primale Lösungen x^* und duale Lösungen y^* sind komplementär:

$$x_n^* = 0 \text{ oder } (A^\top y^* - c)_n = 0 \text{ für } n = 1, \dots, N.$$

4.1 Anwendungen: Netzwerkflussprobleme

(4.1) a) Eine Kapazitätsmatrix $C = (c_{kn}) \in \mathbb{R}^{N \times N}$ mit $c_{kn} \geq 0$ beschreibt einen Graphen mit Knoten $1, \dots, N$ und Kanten $\{(k, n) : c_{kn} > 0\}$ mit den Eigenschaften

1) $c_{kn}c_{nk} = 0, c_{nn} = 0$

2) $c_{k1} = 0, c_{Nn} = 0$

3) $\sum_{k=1}^N c_{kn} > 0, n = 2, \dots, N$ und $\sum_{n=1}^N c_{kn} > 0, k = 1, \dots, N - 1$

b) Ein Fluss $X = (x_{kn}) \in \mathbb{R}^{N \times N}$ zu C ist eine Matrix mit $0 \leq x_{kn} \leq c_{kn}$ und

$$\sum_{k=1}^N x_{kn} = \sum_{k=1}^N x_{nk} \quad \text{für alle } n = 2, \dots, N - 1.$$

c) $W(X) = \sum_{n=1}^N x_{1n}$ heißt *Wert* des Flusses.

(4.2) Für einen Fluss gilt $\sum_{n=1}^N x_{1n} = \sum_{k=1}^N x_{kN}$.

Netzwerkflussoptimierungsproblem

Maximiere $W(X) = \sum_{k=1}^N x_{kN}$ unter $0 \leq x_{kn} \leq c_{kn}$ und $\sum_{k=1}^N x_{kn} = \sum_{k=1}^N x_{nk}$ für alle $n = 2, \dots, N - 1$.

4.1 Anwendungen: Netzwerkflussprobleme

(4.3) Ein *Schnitt* (J^-, J^+) ist eine Zerlegung $J^+ \cup J^- = \{1, \dots, N\}$ mit $J^+ \cap J^- = \emptyset$, $1 \in J^-$, $N \in J^+$. Die *Kapazität* eines Schnittes ist $K(J^-, J^+) := \sum_{(k,n) \in J^- \times J^+} c_{kn}$.

(4.4) Für jeden Schnitt (J^-, J^+) und jeden Fluss X gilt

$$W(X) = \sum_{(k,n) \in J^- \times J^+} x_{kn} - \sum_{(k,n) \in J^- \times J^+} x_{nk} \leq K(J^-, J^+).$$

(4.5) Max-Flow-Min-Cut-Theorem

$$\max\{W(X) : X \text{ Fluss}\} = \min\{K(J^-, J^+) : (J^-, J^+) \text{ Schnitt}\}$$

(4.6) Ein *ungesättigter Pfad vom Knoten j zum Knoten k* ist ein Indexvektor (p_1, \dots, p_R) mit $p_r \in \{1, \dots, N\}$, $r = 1, \dots, R$, $p_1 = j$, $p_R = k$, und für jedes $r = 1, \dots, R - 1$ gilt:

- a) $x_{p_r p_{r+1}} < c_{p_r p_{r+1}}$ falls $c_{p_r p_{r+1}} > 0$
- b) $x_{p_{r+1} p_r} > 0$ falls $c_{p_r p_{r+1}} = 0$

(4.7) Sei X ein maximaler Fluss, und setze

$$J^- := \{1\} \cup \{k \in \{2, \dots, N\} : \text{es gibt einen ungesättigten Pfad von } 1 \text{ nach } k\}.$$

Dann gilt: $N \notin J^-$, (J^-, J^+) mit $J^+ = \{1, \dots, N\} \setminus J^-$ ist ein Schnitt, und $W(X) = K(J^-, J^+)$.

4.1 Anwendungen: Netzwerkflussprobleme

Algorithmus von Ford-Fulkerson

S0) Wähle Fluss X (z. B. $X = 0$)

S1) $J^- = \{1\}$

S2) Wähle (j, k) mit $j \in J^-$, $k \notin J^-$
 mit $x_{jk} < c_{jk}$ falls $c_{jk} > 0$ oder $x_{kj} > 0$ falls $c_{jk} = 0$
 falls kein solches (j, k) existiert: STOP (X maximal)

S3) Setze $J^- := J^- \cup \{k\}$ und falls $N \notin J^-$ gehe zu S2).

S4) Erzeuge ungesättigten Pfad (p_1, \dots, p_R) mit $p_1 = 1$, $p_R = N$, $p_r \in J^-$ und bestimme $d > 0$ mit

$$d = \min \left(\left\{ c_{p_r p_{r+1}} - x_{p_r p_{r+1}} : c_{p_r p_{r+1}} > 0 \right\} \cup \left\{ x_{p_{r+1} p_r} : c_{p_r p_{r+1}} = 0 \right\} \right)$$

S5) Setze

$$x_{p_r p_{r+1}} := x_{p_r p_{r+1}} + d \text{ für } c_{p_r p_{r+1}} > 0$$

$$x_{p_{r+1} p_r} := x_{p_{r+1} p_r} - d \text{ für } c_{p_r p_{r+1}} = 0$$

und gehe zu S1).

4.2 Anwendungen: Matrix-Spiele

(4.8) Ein Matrix-Spiel zweier Personen P_1 und P_2 wird durch $A \in \mathbb{R}^{K \times N}$ bestimmt, wobei a_{kn} ausgezahlt wird, falls P_1 den Spielzug n und P_2 den Spielzug k ausführt. Seien $x \in \mathcal{M}_1 = \{x \in \mathbb{R}^N : e^\top x = 1, x \geq 0\}$ und $y \in \mathcal{M}_2 = \{y \in \mathbb{R}^K : e^\top y = 1, y \geq 0\}$ zulässige Strategien. Dann ist $\Phi(x, y) = y^\top Ax$ die erwartete mittlere Auszahlung.

(4.9) Es gilt $\max_{y \in \mathcal{M}_2} \Phi(x, y) = \max_{k=1, \dots, K} (Ax)_k$ für festes $x \in \mathbb{R}^N$.
 Es gilt $\min_{x \in \mathcal{M}_1} \Phi(x, y) = \min_{n=1, \dots, N} (A^\top y)_n$ für festes $y \in \mathbb{R}^K$.

(4.10) Es gibt optimale Strategien $x^* \in \mathcal{M}_1$ und $y^* \in \mathcal{M}_2$ mit

$$\Phi(x^*, y) \leq \Phi(x^*, y^*) \leq \Phi(x, y^*) \quad \text{für alle } x \in \mathcal{M}_1 \text{ und } y \in \mathcal{M}_2,$$

und es gilt

$$\Phi(x^*, y^*) = \min_{x \in \mathcal{M}_1} \max_{y \in \mathcal{M}_2} \Phi(x, y) = \max_{y \in \mathcal{M}_2} \min_{x \in \mathcal{M}_1} \Phi(x, y).$$

Falls der Wert des Spiels $\Phi(x^*, y^*) = 0$ ist, heißt das Spiel *fair*.

(4.11) Falls $A = -A^\top$ schiefsymmetrisch, so ist der Wert der Spiels $\Phi(x^*, y^*) = 0$.

(4.12) Das Spiel heißt *Sattelpunkt-Spiel*, falls

$$\min_{n=1, \dots, N} \max_{k=1, \dots, K} a_{kn} = \max_{k=1, \dots, K} \min_{n=1, \dots, N} a_{kn}.$$

(4.13) Sattelpunkt-Spiele besitzen eine optimale reine Strategie $x^* = e^s$ und $y^* = e^r$ mit

$$a_{rs} = \min_{n=1, \dots, N} \max_{k=1, \dots, K} a_{kn}.$$

5 Das Simplex-Verfahren

Seien $A \in \mathbb{R}^{K \times N}$, $b \in \mathbb{R}^K$ und $c \in \mathbb{R}^N$ gegeben. Betrachte

$$(P) \quad \text{Minimiere } c^\top x \text{ auf } \mathcal{M} = \{x \in \mathbb{R}^N : Ax = b, x \geq 0\}.$$

(5.1) Zu $J \subset \{1, \dots, N\}$ definiere $A_J = (a_{*j})_{j \in J}$. Sei A_J invertierbar.

Dann heißt $x \in \mathbb{R}^N$ mit $x_J = A_J^{-1}b$ und $x_k = 0$ für $k \notin J$ eine *Basislösung*.

Wenn $x \in \mathcal{M}$ ist, heißt x *zulässige Basislösung*. Sie heißt *nicht entartet*, wenn $x_J > 0$ ist.

(5.2) Sei (P) zulässig und beschränkt.

Dann ist (P) lösbar, und es existiert eine zulässige Basislösung als Lösung von (P).

Jede zulässige Basislösung $z \in \mathcal{M}$ ist Ecke des Polyeders \mathcal{M} .

Sei $\underline{j} = (j_1, \dots, j_K)$ ein Pivotvektor, d. h. $j_k \in \{1, \dots, N\}$ und $j_i \neq j_k$ für $i \neq k$.

(5.3) Sei $\text{Rang } A = K$. Dann existiert eine Darstellung

$$\{x \in \mathbb{R}^N : Ax = b\} = \{x \in \mathbb{R}^N : \hat{A}x = \hat{b}\}$$

mit $\hat{A}(\underline{j}) = I_K$.

Gauß-Jordan-Verfahren: für $k = 1, \dots, K$

S1) Wähle $j = j_k \notin \{j_1, \dots, j_{k-1}\}$ mit $a_{kj} \neq 0$.

S2) Für $i \neq k$ eliminiere Spalte j durch $a_{in} := a_{in} - (a_{ij}/a_{kj})a_{kn}$ für $n = 1, \dots, N$;

für $i \neq k$ setze $b_i := b_i - (a_{ij}/a_{kj})b_k$;

normiere die Zeile k durch $a_{kn} := a_{kn}/a_{kj}$ für $n = 1, \dots, N$ und $b_k := b_k/a_{kj}$.

5 Das Simplex-Verfahren

Phase I

Konstruiere einen Pivotvektor \hat{j} zu $Ax = b$ mit Basislösung \hat{z} , einen Vektor $\hat{c} \in \mathbb{R}^N$ und eine Darstellung $\mathcal{M} = \{x \in \mathbb{R}^N : \hat{A}x = \hat{b}, x \geq 0\}$ von \mathcal{M} mit

- i) Ist $\hat{j} = (j_1, \dots, j_K)$, so ist $\hat{a}_{*j_k} = e^k$ für $k = 1, \dots, K$,
- ii) $\hat{c}_{j_k} = 0$ für alle $k = 1, \dots, K$ (also auch $\hat{c}^\top \hat{z} = 0$), und $\hat{b} \geq 0$,
- iii) $f(x) = \hat{c}^\top x + f(\hat{z})$ für alle x mit $Ax = b$ und $f(x) = c^\top x$. Setze $\hat{\gamma} = f(\hat{z})$.

Phase II

- S1) Falls $\hat{c} \geq 0$ STOP (\hat{z} optimal)
- S2) Wähle $s \notin J(\hat{j})$ mit $\hat{c}_s < 0$.
- S3) Falls $\hat{a}_{*s} \leq 0$ STOP ($\inf(P) = -\infty$)
- S4) Wähle r mit $\hat{a}_{rs} > 0$ und $\hat{b}_r / \hat{a}_{rs} \leq \hat{b}_i / \hat{a}_{is}$ für $i \in \{1, \dots, K\}$ mit $\hat{a}_{is} > 0$.
- S5) Definiere \tilde{j} mit $\tilde{j}_k = \hat{j}_k$ für $k \neq r$ und $\tilde{j}_r = s$
- S6) Gauß-Jordan-Schritt: setze $\tilde{a}_{rn} = \hat{a}_{rn} / \hat{a}_{rs}$ für $n = 1, \dots, N$ und $\tilde{b}_r = \hat{b}_r / \hat{a}_{rs}$,
für $i \neq r$ setze $\tilde{a}_{in} = \hat{a}_{in} - \hat{a}_{is} \tilde{a}_{rn}$, $\tilde{b}_i = \hat{b}_i - \hat{a}_{is} \tilde{b}_r$, $\tilde{c}_n = \hat{c}_n - \hat{c}_s \tilde{a}_{rn}$ für $n = 1, \dots, N$,
 $\tilde{z}_{j_k} = \tilde{b}_k$ für $k = 1, \dots, K$ und $\tilde{z}_n = 0$ für $n \notin J(\tilde{j})$, und setze $-\tilde{\gamma} = -\hat{\gamma} - \hat{c}_s \tilde{b}_r$.
- S7) $\hat{A} = \tilde{A}$, $\hat{b} = \tilde{b}$, $\hat{c} = \tilde{c}$, $\hat{z} = \tilde{z}$, $\hat{\gamma} = \tilde{\gamma}$, gehe zu S1)

5 Das Simplex-Verfahren

(5.4)

- a) Für jedes x gilt: $\tilde{A}x = \tilde{b} \iff \hat{A}x = \hat{b} \iff Ax = b$.
- b) $\hat{c}^\top x + \hat{\gamma} = \tilde{c}^\top x + \tilde{\gamma}$ für alle $x \in \mathbb{R}^N$ mit $Ax = b$.
- c) (\tilde{z}, \tilde{j}) ist zulässige Basislösung zu $\tilde{A}x = \tilde{b}$, für die i), ii), iii) erfüllt sind.
 Es ist $\tilde{a}_{rs} = 1$ und $\tilde{\gamma} = c^\top \tilde{z} = f(\tilde{z})$. Insbesondere ist (P) äquivalent zu
- $$(\hat{P}) \quad \text{Minimiere} \quad \hat{c}^\top x + \hat{\gamma} \quad \text{auf} \quad \mathcal{M} = \{x \in \mathbb{R}^N : \hat{A}x = \hat{b}, x \geq 0\},$$
- und dies äquivalent zu
- $$(\tilde{P}) \quad \text{Minimiere} \quad \tilde{c}^\top x + \tilde{\gamma} \quad \text{auf} \quad \mathcal{M} = \{x \in \mathbb{R}^N : \tilde{A}x = \tilde{b}, x \geq 0\}.$$
- d) $f(\tilde{z}) = c^\top \tilde{z} = \tilde{\gamma} = \hat{c}_j \hat{b}_i / \hat{a}_{ij} + \hat{\gamma} \leq \hat{\gamma} = c^\top \hat{z} = f(\hat{z})$.
- e) Ist $\hat{c} \geq 0$, so ist $c^\top x \geq c^\top \hat{z}$ für alle $x \in \mathcal{M}$, d.h. \hat{z} ist optimal.
- f) Ist $\hat{c}_s < 0$ und $\hat{a}_{*s} \leq 0$, so ist $\hat{c}^\top x$ auf \mathcal{M} nicht beschränkt, d.h. $\inf(P) = -\infty$.

5 Das Simplex-Verfahren

Pivot-Regel von Bland

- i) Pivot-Spalte ist die Spalte $s = \min\{n: \hat{c}_n < 0\}$.
 Sei $q_s = \min\{\hat{b}_k / \hat{a}_{ks} : \hat{a}_{ks} > 0\}$.
- ii) Pivot-Zeile ist die Zeile r mit $j_r = \min\{j_k : \hat{a}_{ks} > 0 \text{ und } \hat{b}_k / \hat{a}_{ks} = q_s\}$.

(5.5) Das Simplex-Verfahren mit der Pivot-Regel von Bland wiederholt kein Tableau.

Phase I Sei $e = (1, 1, \dots, 1)^T \in \mathbb{R}^K$, und sei o.E. $b \geq 0$. Betrachte:

$$(P_1) \quad \text{Minimiere } e^T(b - Ax) \quad \text{unter} \quad Ax \leq b, \quad x \geq 0.$$

(5.6) (P_1) ist zulässig, und (P) ist genau dann zulässig, wenn $\min(P_1) = 0$.

$$\begin{array}{ccccccc|c}
 -\sum_{k=1}^K a_{k1} & -\sum_{k=1}^K a_{k2} & \cdots & -\sum_{k=1}^K a_{kN} & 0 & \cdots & 0 & -\sum_{k=1}^K b_k \\
 \hline
 c_1 & c_2 & \cdots & c_N & 0 & \cdots & 0 & 0 \\
 a_{11} & a_{12} & \cdots & a_{1N} & 1 & \cdots & 0 & b_1 \\
 \vdots & \vdots & & \vdots & \vdots & \ddots & \vdots & \vdots \\
 a_{K1} & a_{K2} & \cdots & a_{KN} & 0 & \cdots & 1 & b_K
 \end{array}$$

5 Das revidierte Simplex-Verfahren

(5.7) Sei \hat{z} Basislösung zum Pivot-Vektor \underline{j} , und sei $\underline{k} = (k_1, \dots, k_{N-K})$ ein Komplement von \underline{j} , d. h. $\{j_1, \dots, j_K\} \cup \{k_1, \dots, k_{N-K}\} = \{1, \dots, N\}$. Dann gilt:

- a) $A(\underline{j}) \in \mathbb{R}^{K \times K}$ ist regulär, $\hat{z}(\underline{j}) = A(\underline{j})^{-1}b$, $\hat{z}(\underline{k}) = 0$, $\hat{A} = A(\underline{j})^{-1}A$.
- b) $\hat{c}(\underline{k}) = c(\underline{k}) - (A(\underline{j})^{-1}A(\underline{k}))^\top c(\underline{j})$.

Phase II

S0) Starte mit $\hat{z}(\hat{j}) = A(\hat{j})^{-1}b$, $\hat{\gamma} = c(\hat{j})^\top A(\hat{j})^{-1}b$. Speichere $A(\hat{j})^{-1} \in \mathbb{R}^{K \times K}$.

S1) Setze $y := A(\hat{j})^{-\top}c(\hat{j})$, $d = A(\hat{k})^\top y$. Falls $d \leq c(\hat{k})$ STOP (\hat{z} optimal)

S2) Bestimme Index $k_s \in \{k_1, \dots, k_{N-K}\}$ mit $d_s > c_{k_s}$.

S3) Berechne $w = A(\hat{j})^{-1}a_{*k_s}$. Falls $w \leq 0$ STOP ($\inf(P) = -\infty$)

S4) Bestimme $r \in \{1, \dots, K\}$ mit $\hat{z}_{j_r}/w_r = \min\{\hat{z}_{j_l}/w_l : w_l > 0\}$.

S5) Setze $\tilde{j} = (j_1, \dots, j_{r-1}, s, j_{r+1}, \dots, j_K)$, bestimme Komplement \tilde{k} von \tilde{j} , setze

$$A(\tilde{j})^{-1} = \left(I - \frac{(w - e^r)(e^r)^\top}{w_r} \right) A(\hat{j})^{-1}, \quad \tilde{z}(\tilde{j}) = A(\tilde{j})^{-1}b, \quad \tilde{\gamma} = \hat{\gamma} + \frac{\hat{z}_{j_r}}{w_r} (c_{k_s} - d_s)$$

S6) Update $\hat{j} = \tilde{j}$ gehe zu S1).

6.1 Konvexe Optimierung – Konvexe Funktionen

(6.1) Sei $\mathcal{D} \subset \mathbb{R}^N$ konvex.

- Eine Funktion $f: \mathcal{D} \rightarrow \mathbb{R}$ heißt *konvex*, wenn für alle $x, y \in \mathcal{D}$, $\lambda \in [0, 1]$ gilt

$$f((1 - \lambda)x + \lambda y) \leq (1 - \lambda)f(x) + \lambda f(y).$$
 - f heißt *strikt konvex*, wenn für alle $x, y \in \mathcal{D}$, $x \neq y$ und alle $\lambda \in (0, 1)$ gilt:

$$f((1 - \lambda)x + \lambda y) < (1 - \lambda)f(x) + \lambda f(y).$$
 - f heißt *gleichmäßig konvex*, wenn es $c_0 > 0$ gibt, so dass für alle $x, y \in \mathcal{D}$, $\lambda \in [0, 1]$ gilt

$$f((1 - \lambda)x + \lambda y) + c_0(1 - \lambda)\lambda \|x - y\|^2 < (1 - \lambda)f(x) + \lambda f(y).$$
- $g: \mathcal{K} \rightarrow \mathbb{R}^P$ heißt konvex, wenn jede Komponente g_p für $p = 1, \dots, P$ konvex ist.

(6.2) Sei $\mathcal{D} \subset \mathbb{R}^N$ offen und konvex, $f: \mathcal{D} \rightarrow \mathbb{R}$ zweimal stetig differenzierbar.

Dann ist äquivalent:

- f ist gleichmäßig konvex auf \mathcal{D} .
- Es existiert $c_0 > 0$ mit

$$f(x) - f(y) \geq Df(y)(x - y) + c_0 \|x - y\|^2 \quad \forall x, y \in \mathcal{D}.$$
- Es existiert $c_0 > 0$ mit

$$(Df(x) - Df(y))(x - y) \geq 2c_0 \|x - y\|^2 \quad \forall x, y \in \mathcal{D}.$$
- Es existiert $c_0 > 0$ mit

$$z^\top D^2 f(x) z \geq 2c_0 \|z\|^2 \quad \forall x \in \mathcal{D}, z \in \mathbb{R}^N.$$

(6.3) Sei $\mathcal{D} \subset \mathbb{R}^N$ offen und konvex, und sei $f: \mathcal{D} \rightarrow \mathbb{R}$ konvex. Dann ist f stetig.

6.2 Konvexe Optimierung – Existenz und Eindeutigkeit

Seien $\mathcal{K} \subset \mathbb{R}^N$ konvex, $f: \mathcal{K} \rightarrow \mathbb{R}$, $g: \mathcal{K} \rightarrow \mathbb{R}^P$ konvex, $A \in \mathbb{R}^{K \times N}$, $b \in \mathbb{R}^K$. Betrachte

$$(P) \quad \text{Minimiere } f(x) \text{ auf } \mathcal{M} = \{x \in \mathcal{K}, g(x) \leq 0, Ax = b\}.$$

- (6.4) Sei $\mathcal{M} \subset \mathbb{R}^N$ konvex, $f: \mathcal{M} \rightarrow \mathbb{R}$ konvex und x^* ein lokales Minimum von f auf \mathcal{M} , d.h. es existiert $\varepsilon > 0$ mit $f(x^*) \leq f(x)$ für alle $x \in \mathcal{M}$ mit $\|x - x^*\| \leq \varepsilon$. Dann ist x^* sogar globales Minimum, d.h. $f(x^*) \leq f(x)$ für alle $x \in \mathcal{M}$.

- (6.5) Es sei $\mathcal{M} \neq \emptyset$, $\inf(P) > -\infty$ und

$$\Lambda = \left\{ \begin{pmatrix} f(x) + r \\ g(x) + z \\ Ax - b \end{pmatrix} \in \mathbb{R} \times \mathbb{R}^P \times \mathbb{R}^K : r \geq 0, z \geq 0, x \in \mathcal{K} \right\}$$

sei abgeschlossen. Dann besitzt (P) eine Lösung.

- (6.6) Ist $\mathcal{M} \neq \emptyset$ und f strikt konvex, so besitzt (P) höchstens eine Lösung.

- (6.7) Sei $\mathcal{M} \neq \emptyset$, \mathcal{M} abgeschlossen, und sei f gleichmäßig konvex. Dann ist (P) eindeutig lösbar.

6.3 Konvexe Optimierung – Das duale Problem

Seien $\mathcal{K} \subset \mathbb{R}^N$ konvex, $f: \mathcal{K} \rightarrow \mathbb{R}$, $g: \mathcal{K} \rightarrow \mathbb{R}^P$ konvex, $A \in \mathbb{R}^{K \times N}$, $b \in \mathbb{R}^K$.

(P) Minimiere $f(x)$ auf $\mathcal{M} = \{x \in \mathcal{K}: g(x) \leq 0, Ax = b\}$.

Definiere $\Lambda = \left\{ \begin{pmatrix} f(x) + r \\ g(x) + z \\ Ax - b \end{pmatrix} \in \mathbb{R} \times \mathbb{R}^P \times \mathbb{R}^K : r \geq 0, z \geq 0, x \in \mathcal{K} \right\}$.

(P̃) Minimiere $\phi(\beta, u, v) = \beta$ unter $(\beta, u, v) \in \Lambda \cap (\mathbb{R} \times \{0_P\} \times \{0_K\})$.

Definiere den Halbraum $H(\gamma, u, v) = \{(t, w, z) \in \mathbb{R} \times \mathbb{R}^P \times \mathbb{R}^K : t + u^\top w + v^\top z \geq \gamma\}$.

(D̃) Maximiere $\psi(\gamma, u, v) = \gamma$ unter $\Lambda \subset H(\gamma, u, v)$.

Setze $f^*(u, v) = \inf_{x \in \mathcal{K}} (f(x) + u^\top g(x) + v^\top (Ax - b))$.

(D) Maximiere $f^*(u, v)$ auf $\mathcal{M}^* = \{(u, v) \in \mathbb{R}^P \times \mathbb{R}^K : u \geq 0, f^*(u, v) > -\infty\}$.

6.4 Konvexe Optimierung – Dualitätssätze

(6.12) Für alle $x \in \mathcal{M}$ und $(u, v) \in \mathcal{M}^*$ gilt $f(x) \geq f^*(u, v)$.

Ist $f(x^*) = f^*(u^*, v^*)$ für $x^* \in \mathcal{M}$, $(u^*, v^*) \in \mathcal{M}^*$, so sind x^* und (u^*, v^*) optimal.

(6.13) Es sei $\mathcal{K} = \mathbb{R}^N$ und es gelte die Slaterbedingung (SB):

(SB1) $\text{Rang } A = K \leq N$,

(SB2) es existiert $\hat{x} \in \mathbb{R}^N$ mit $A\hat{x} = b$ und $g_p(\hat{x}) < 0$ für $p = 1, \dots, P$.

Das Problem (P) sei lösbar durch $x^* \in \mathcal{M}$. Dann gibt es auch eine Lösung $(u^*, v^*) \in \mathcal{M}^*$ von (D) mit $f(x^*) = f^*(u^*, v^*)$ und $u_p^* g_p(x^*) = 0$ für $p = 1, \dots, P$.

(6.14) Wir definieren die Lagrangefunktion $L(x, u, v) = f(x) + u^\top g(x) + v^\top (Ax - b)$.

a) Sei $x^* \in \mathcal{M}$ optimal für (P) und die Slaterbedingung (SB) sei erfüllt.

Dann existieren $u^* \in \mathbb{R}_{\geq 0}^P$, $v^* \in \mathbb{R}^N$ mit $u^{*\top} g(x^*) = 0$ und

$$L(x^*, u, v) \leq L(x^*, u^*, v^*) \leq L(x, u^*, v^*) \quad \text{für alle } (x, u, v) \in \mathbb{R}^N \times \mathbb{R}_{\geq 0}^P \times \mathbb{R}^K.$$

b) Falls $(x^*, u^*, v^*) \in \mathbb{R}^N \times \mathbb{R}_{\geq 0}^P \times \mathbb{R}^K$ ein Sattelpunkt von L ist,

so ist x^* Lösung von (P) und (u^*, v^*) Lösung von (D).

(6.15) Es seien $f: \mathbb{R}^N \rightarrow \mathbb{R}$, $g: \mathbb{R}^N \rightarrow \mathbb{R}^P$ konvex und differenzierbar, und die Slaterbedingung (SB) sei erfüllt. Dann gilt:

$x^* \in \mathcal{M}$ ist genau dann eine Lösung von (P), wenn es $u^* \in \mathbb{R}_{\geq 0}^P$ und $v^* \in \mathbb{R}^K$ gibt mit

$$Df(x^*) + u^{*\top} Dg(x^*) + v^{*\top} A = 0, \quad Ax^* = b, \quad g(x^*) \leq 0, \quad u_k^* g_k(x^*) = 0, \quad k = 1, \dots, p.$$

7 Differenzierbare Optimierung

(7.2) Sei $h: \mathbb{R}^N \rightarrow \mathbb{R}^K$ stetig differenzierbar und $h(\hat{x}) = 0$.

Die Jacobi-Matrix $Dh(\hat{x}) \in \mathbb{R}^{K \times N}$ habe den Rang K (also insbesondere $K \leq N$).

Sei ferner $z \in \mathbb{R}^N$ mit $Dh(\hat{x})z = 0$.

Dann existiert $\delta > 0$ und eine stetig differenzierbare Funktion

$$r: (-\delta, \delta) \rightarrow \mathbb{R}^N$$

mit $r(0) = 0$, $r'(0) = 0$ und $h(\hat{x} + tz + r(t)) = 0$ für alle $t \in (-\delta, \delta)$.

(7.4) Sei $\mathcal{D} \subset \mathbb{R}^N$ offen, $f: \mathcal{D} \rightarrow \mathbb{R}$, $g: \mathcal{D} \rightarrow \mathbb{R}^P$, $h: \mathcal{D} \rightarrow \mathbb{R}^K$ stetig differenzierbar.

Sei x^* ein (lokales) Minimum von f auf der Menge

$$\mathcal{M} = \{x \in \mathcal{D}: g(x) \leq 0, h(x) = 0\}.$$

Es gelte die *constraint qualification*

$$\text{(CQ1)} \quad \begin{array}{l} \text{(i)} \quad \text{Rang } Dh(x^*) = K, \\ \text{(ii)} \quad \text{es gibt } \hat{z} \in \mathbb{R}^N \text{ mit } g(x^*) + Dg(x^*)\hat{z} < 0 \text{ und } Dh(x^*)\hat{z} = 0. \end{array}$$

Dann existiert $(u^*, v^*) \in \mathbb{R}^P \times \mathbb{R}^K$, so dass (x^*, u^*, v^*) ein KKT-Punkt ist, d. h.

$$\text{a)} \quad \nabla_x L(x^*, u^*, v^*) = \nabla f(x^*) + Dg(x^*)^\top u^* + Dh(x^*)^\top v^* = 0,$$

$$\text{b)} \quad g(x^*) \leq 0, \quad u^* \geq 0, \quad g(x^*)^\top u^* = 0,$$

$$\text{c)} \quad h(x^*) = 0.$$

7 Differenzierbare Optimierung

- (7.6) Sei $x^* \in \mathcal{M}$ optimal, und sei $\mathcal{I}(x^*) = \{p \in \{1, \dots, P\} : g_p(x^*) = 0\}$ die Menge der aktiven Indizes mit $q = |\mathcal{I}|$. Dann folgt (CQ1) aus

$$(CQ2) \quad \text{Rang} \begin{pmatrix} Dg_{\mathcal{I}}(x^*) \\ Dh(x^*) \end{pmatrix} = q + K.$$

- (7.7) Optimalitätsbedingung 2. Ordnung

Sei x^* lokales Minimum von f auf \mathcal{M} , und sei (CQ2) erfüllt.

Es seien zusätzlich f , g und h zweimal stetig differenzierbar in x^* .

Dann existiert $(u^*, v^*) \in \mathbb{R}^P \times \mathbb{R}^K$, so dass (x^*, u^*, v^*) ein KKT-Punkt ist, und auf dem Unterraum $V = \{z \in \mathbb{R}^N : Dh(x^*)z = 0, Dg_p(x^*)z = 0 \text{ für alle } p \in \mathcal{I}(x^*)\}$ gilt

$$z^\top D_x^2 L(x^*, u^*, v^*) z \geq 0 \quad \text{für alle } z \in V.$$

- (7.8) Hinreichende Optimalitätsbedingung 2. Ordnung

(x^*, u^*, v^*) sei ein KKT-Punkt, und zu $\mathcal{I}^+ = \{p \in \mathcal{I}(x^*) : u_p^* > 0\}$ definiere den Kegel $\mathcal{C} = \{z \in \mathbb{R}^N : Dh(x^*)z = 0, Dg_p(x^*)z = 0 \text{ für } p \in \mathcal{I}^+, Dg_p(x^*)z \leq 0 \text{ für } p \in \mathcal{I} \setminus \mathcal{I}^+\}$. Zusätzlich gelte

$$z^\top D_x^2 L(x^*, u^*, v^*) z > 0 \quad \text{für alle } z \in \mathcal{C}, z \neq 0.$$

Dann ist x^* striktes lokales Minimum von f auf \mathcal{M} .

8.1 Quadratische Optimierung – Existenz und Dualität

Seien $Q \in \mathbb{R}^{N \times N}$, $A \in \mathbb{R}^{K \times N}$, $c \in \mathbb{R}^N$, $b \in \mathbb{R}^K$. Betrachte

$$(P) \quad \text{Minimiere } f(x) = \frac{1}{2}x^\top Qx + c^\top x \quad \text{auf } \mathcal{M} = \{x \in \mathbb{R}^N: x \geq 0, Ax = b\}.$$

(8.1) Sei (P) zulässig und $\inf(P) > -\infty$. Dann ist (P) lösbar.

(8.2) Betrachte das lineare Optimierungsproblem (mit $Q = 0$). Dann existiert $y^* \in \mathbb{R}^K$ mit

$$\text{i) } c + A^\top y^* \geq 0, \quad \text{ii) } (c + A^\top y^*)^\top x^* = 0.$$

(8.3) a) Sei $x^* \in \mathcal{M}$ Lösung von (P). Dann existiert $y^* \in \mathbb{R}^K$ mit

$$\text{i) } Qx^* + c + A^\top y^* \geq 0 \quad \text{ii) } (Qx^* + c + A^\top y^*)^\top x^* = 0.$$

b) Sei Q symmetrisch und positiv semidefinit, $x^* \in \mathcal{M}$, und es gebe $y^* \in \mathbb{R}^K$ mit i), ii). Dann ist x^* Lösung von (P).

(8.4) Betrachte

$$(P_2) \quad \text{Minimiere } f(x) = \frac{1}{2}x^\top Qx + c^\top x \quad \text{auf } \mathcal{M} = \{x \in \mathbb{R}^N: Ax \leq b\}.$$

a) Sei $x^* \in \mathcal{M}$ Lösung von (P_2) . Dann existiert $u^* \in \mathbb{R}^K$ mit $u^* \geq 0$ und

$$\text{i) } Qx^* + c + A^\top u^* = 0 \quad \text{ii) } (b - Ax^*)^\top u^* = 0.$$

b) Sei Q symmetrisch und positiv semidefinit, $x^* \in \mathcal{M}$, und es gebe $u^* \in \mathbb{R}^K$ mit $u^* \geq 0$. i) und ii) sei erfüllt. Dann ist x^* Lösung von (P_2) .

8.2 Der Algorithmus von Goldfarb-Ildnani

Seien $Q \in \mathbb{R}^{N \times N}$ sym. pos. def., $A \in \mathbb{R}^{K \times N}$, $c \in \mathbb{R}^N$, $b \in \mathbb{R}^K$, $\mathcal{I} \subset \{1, \dots, K\}$. Betrachte

$$(P_{\mathcal{I}}) \quad \text{Minimiere} \quad f(x) := \frac{1}{2}x^T Qx + c^T x \quad \text{auf} \quad \mathcal{M} = \{x \in \mathbb{R}^N : (Ax)_k \leq b_k, k \in \mathcal{I}\}.$$

Voraussetzung **(V)**: $x^m \in \mathcal{M}_{\mathcal{I}^m}$ sei optimal für $(P_{\mathcal{I}^m})$ mit zugehörigem Multiplikator $u^m \geq 0$, für $a := a^p$ und $\beta := b_p$ gelte $a^T x^m > \beta$, und $\{a^k : k \in \mathcal{I}^m\}$ seien linear unabhängig.

(A0) Setze $\theta := 0$, $f := f(x^m)$, $x := x^m$, $\mathcal{I} := \mathcal{I}^m$, $u := u^m \in \mathbb{R}^{|\mathcal{I}^m|}$.

(A1) $A_{\mathcal{I}}^T := (a^{k_1}, \dots, a^{k_q})$ für $\mathcal{I} = \{k_1, \dots, k_q\}$.

(A2) Berechne $d := (A_{\mathcal{I}} Q^{-1} A_{\mathcal{I}}^T)^{-1} A_{\mathcal{I}} Q^{-1} a$ (falls $\mathcal{I} \neq \emptyset$, sonst $d := 0$), $z := Q^{-1}(a - A_{\mathcal{I}}^T d)$ und (falls $z \neq 0$) setze $t_1 := (a^T x - \beta)/(a^T z)$.

(A3) Falls $u - t_1 d \geq 0$ oder $\mathcal{I} = \emptyset$, so setze

$$\begin{aligned} x^{m+1} &:= x - t_1 z, & u^{m+1} &:= \begin{bmatrix} u - t_1 d \\ \theta + t_1 \end{bmatrix} \in \mathbb{R}^{|\mathcal{I}|+1}, \\ \mathcal{I}^{m+1} &:= \mathcal{I} \cup \{p\}, & f^{m+1} &:= f + t_1(\theta + t_1/2) a^T z. \end{aligned}$$

(A4) Falls $u - t_1 d \not\geq 0$ und $\mathcal{I} \neq \emptyset$, setze $t_2 := \min\{u_k/d_k : d_k > 0, k \in \mathcal{I}\} = u_\ell/d_\ell$ mit $\ell \in \mathcal{I}$ und

$$\begin{aligned} x &:= x - t_2 z, & \mathcal{I} &:= \mathcal{I} \setminus \{\ell\}, \\ u_k &:= u_k - t_2 d_k \text{ für } k \in \mathcal{I}, & f &:= f + t_2(\theta + t_2/2) a^T z, \\ \theta &:= \theta + t_2. \end{aligned}$$