

§3 Der Algorithmus von Frank-Wolfe für die (konvexe)
Optimierung mit linearen Nebenbedingungen (1956)

3.1 Der allgemeine Fall:


$$\text{min } f(x) \text{ unter } Ax = b \quad x \geq 0$$

Algorithmus ist iterativ und erzeugt eine Folge von Punkten x^0, x^1, \dots wobei x^{k+1} wie folgt aus x^k berechnet wird

(1) Bestimme eine Optimallösung y^k des LP

$$\begin{aligned} \text{min } & Df^T(x^k) \cdot x \\ \text{unter } & Ax = b \\ & x \geq 0 \end{aligned}$$

(2) Wähle x^{k+1} als Minimumes von $f(x)$ auf dem
Intervalle $[x^k, y^k]$ "Line Search"



3.1 SATZ. Sei f stetig diffbar, konvex und sei

$$X := \{x \in \mathbb{R}^n \mid Ax = b, x \geq 0\} \text{ beschränkt}$$

Dann enthält die Folge x^0, x^1, \dots eine konvergente Teilfolge
und jede solche Teilfolge konvergiert gegen ein globales
Minimum von f auf X

Beweis der Konvergenz folgt einem sehr allgemeinen Prinzip, das
gleich für Varianten oder Familien von Algorithmen gültig ist

Sind A_1, \dots, A_p Iterationsalgorithmen, so erzeugen sie, angewandt
auf x^k die Menge $A(x^k) = \{A_1(x^k), A_2(x^k), \dots, A_p(x^k)\}$

Abstrakt: Eine Klasse A von Iterationsalgorithmen ist eine

mengenwertige Fkt $A: X \rightarrow 2^Y$

Schreibweise $A: X \xrightarrow{m} Y$ "point-to-set map"

Ein Algorithmus, der durch eine mengenwertige Funktion A gegeben ist
ist global konvergent, wenn für jeden Anfangspunkt $x^0 \in X$
jede Folge (x^k) mit $x^{k+1} \in A(x^k)$ eine Teilfolge enthält,
die gegen einen Punkt konvergiert, der notwendige Bedingungen
für Optimalität erfüllt (z.B. Karu-Tucker)

Stetigkeit von "normalen" Fkt wird durch Abgeschlossenheit von
mengenwertigen Funktionen verallgemeinert:

$A: X \xrightarrow{m} Y$ ist abgeschlossen in $x \in X$ \Leftrightarrow

$$\left. \begin{array}{l} x^k \rightarrow x \text{ in } X \\ y^k \rightarrow y \text{ in } Y \\ \text{mit } y^k \in A(x^k) \end{array} \right\} \Rightarrow y \in A(x)$$

A heißt abgeschlossen auf $S \subseteq X$ wenn A in jedem $x \in S$ abgeschlossen ^{ist}

$f: X \rightarrow Y$ stetig $\Rightarrow F: X \xrightarrow{m} Y$ mit $F(x) = \{f(x)\}$ abgeschlossen

Verkettung unzerlegbarer Funktionen

$$A: X \xrightarrow{m} Y, \quad B: Y \xrightarrow{m} Z$$

Die Verkettung C von A und B (bezeichnet als $B \circ A$) ist definiert als

$$C: A \xrightarrow{m} Z \quad \text{mit} \quad C(x) := \bigcup_{y \in A(x)} B(y)$$

Viele Algorithmen (Klassen) ergeben sich als solche Verkettung.

Auch der Frank-Wolfe Algorithmus:

$D \hat{=}$ Ermittlung von y (LP lösen)

$U \hat{=}$ Line Search

genauer: $D: X \xrightarrow{m} X \times \mathbb{R}^n$ mit $D(x^0) = \{(x^0, d) \mid d = y - x^0$ ↙ Richtungen
 und y ist optimale Lösung von
 $\min \nabla f(x^0)^T x$ unter $Ax = b, x \geq 0$

$U: X \times \mathbb{R}^n \xrightarrow{m} \mathbb{R}^n$ $U(x^0, d) = \{z \in [x^0, x^0 + d] \mid$
 z minimiert / approximiert f
 auf $[x^0, x^0 + d] = [x^0, y]$

3.2 PROPOSITION: Sei $A: X \xrightarrow{m} Y, B: Y \xrightarrow{m} Z$. Sei

(i) A abgeschlossen in $x \in A$ und B abgeschlossen auf $A(x)$

(ii) Y kompakt

Dann ist $C = B \circ A$ abgeschlossen in X

Beweis: Sei $x^k \rightarrow x$ in X , $z^k \rightarrow z$ in Z mit $z^k \in C(x^k)$

zeige: $z \in C(x)$

$z^k \in C(x^k) \Rightarrow \exists \underbrace{y^k \in A(x^k)}_{\subseteq Y}$ mit $z^k \in B(y^k)$

Y kompakt $\Rightarrow \exists$ konvergente Teilfolge $\{y^{\ell}\}$ von $\{y^k\}$
mit $y^{\ell} \rightarrow y$ in Y

A abgeschlossen in $X \Rightarrow y \in A(x)$

$z^k \rightarrow z$ in $Z \Rightarrow z^{\ell} \rightarrow z$ in Z

B abgeschlossen auf $A(x) \ni y \Rightarrow z \in B(y) \subseteq C(x) \quad \square$

Zw. Konvergenz:

Betrachte Optimierungsproblem in X .

Sei $\Omega := \{x \in X \mid \text{notwendige Bed. für Optimalität erfüllt}\}$

Sei A ein Algorithmus für dieses Problem (repräsentiert durch eine Mengenfunktion $A: X \rightrightarrows X$).

Globale Konvergenz von A (d.h. unabhängig vom Start x_0)

gegen ein $x \in \Omega$ hängt von 2 Sachen ab:

(1) Abgeschlossenheit von A auf $X \setminus \Omega$

(2) die Existenz einer Abschätzfunktion $z: X \rightarrow \mathbb{R}$

$z: X \rightarrow \mathbb{R}^n$ heißt Abschätzfunktion (relativ zu A) \Leftrightarrow

(1) z ist stetig

$$(i) \quad x \notin \Omega \Rightarrow z(y) < z(x) \quad \forall y \in A(x)$$

Algorithmus liefert: pro Iteration bessere Punkte bzgl. z

$$(ii) \quad x \in \Omega \Rightarrow z(y) \leq z(x) \quad \forall y \in A(x)$$

und auf Ω keine schlechteren als x bzgl. z

3.3 SATZ (Zangewill 69)

X, Ω wie oben. $A: X \rightrightarrows X$ ein Algorithmus dafür.

Sei $\{x^k\}$ eine von A erzeugte Folge, d.h. $x^{k+1} \in A(x^k)$

Es gelte:

(C1) Alle x^k liegen in einer kompakten Menge $K \subseteq X$

(C2) Es gibt relativ zu A eine Abstoßfunktion z

(C3) A ist abgeschlossen auf $X - \Omega$

$$A(x) \neq \emptyset \quad \text{für alle } x \in X - \Omega$$

Dann enthält $\{x^k\}$ eine konvergente Teilfolge, und der

Limes jeder konvergenten Teilfolge liegt in Ω

Beweis: $\{x^k\} \subseteq K$, K kompakt $\Rightarrow \exists$ konvergente Teilfolge $\{x^{\ell}\}$

$$\text{Sei } x = \lim_{\ell} x^{\ell}$$

$$z \text{ stetig} \Rightarrow z(x^{\ell}) \rightarrow z(x)$$

(a) $\{z(x^k)\}$ ist konvergent und $\lim z(x^k) = z(x)$

$$x^{k+1} \in A(x^k) \stackrel{\text{Df } z}{=} z(x^{k+1}) \leq z(x^k)$$

$$\Rightarrow \{z(x^k)\} \text{ und } \{z(x^{\ell})\} \text{ sind}$$

monoton fallende Folgen

$$z(x^l) \rightarrow z(x) \Rightarrow \forall \varepsilon > 0 \exists l_\varepsilon \text{ mit}$$

$$z(x^l) - z(x) < \varepsilon \quad \forall l \geq l_\varepsilon$$

$$\Rightarrow z(x^k) - z(x) = \underbrace{z(x^k) - z(x^{l_\varepsilon})}_{\leq 0 \text{ f\"ur } k \geq l_\varepsilon} + z(x^{l_\varepsilon}) - z(x)$$

$$\leq z(x^{l_\varepsilon}) - z(x) < \varepsilon \quad \text{f\"ur } k \geq l_\varepsilon$$

\Rightarrow (a) mit Standardziele

(b) $x \in \Omega$

Betrachte Folge $\{x^{l+1}\} \subseteq K$

K kompakt $\Rightarrow \exists$ konvergente Teilfolge $(x^{l+1})_{l \in L'}$

$$\text{mit } \lim_{l \in L'} x^{l+1} =: x'$$

$$\Rightarrow \left. \begin{array}{l} x^l \rightarrow x \\ x^{l+1} \rightarrow x' \\ x^{l+1} \in \underbrace{A(x^l)}_{\subseteq Y} \end{array} \right\} \text{ f\"ur } l \in L', l \rightarrow \infty \quad (*)$$

Falls $x \in \Omega \Rightarrow$ fertig

Falls $x \notin \Omega \stackrel{(C3)}{\Rightarrow} A$ abgeschlossen in $x \stackrel{(*)}{\Rightarrow} x' \in A(x)$

$$z(x^k) \rightarrow z(x) \Rightarrow z(x^{l+1}) \rightarrow z(x') = z(x)$$

Teilfolgen wandler Fallender konvergenter Folgen haben denselben Limes

$$\left. \begin{array}{l} \text{ABER } z \text{ Abst\"os\"s} \text{ fkt} \\ x \notin \Omega \\ x' \in A(x) \end{array} \right\} \Rightarrow z(x') < z(x) \text{ Widerspruch } \square$$

Bemerkungen:

(1) Die Bestwertfunktion φ ist i.A. gleich der zu minimierenden Funktion $f \Rightarrow f$ muss als stetig vorausgesetzt werden

(2) Um (C1) zu erfüllen wird oft vorausgesetzt, dass

$$X_\alpha := \{x \in X \mid f(x) \leq f(x^0) =: \alpha\}$$

beschränkt ist (*)

f stetig, (*) $\Rightarrow X_\alpha$ kompakt und ist Menge K , die alle $\{x^k\}$ der Folge enthält

(3) (C1) und (C2) gelten meistens bei Abhängigkeitsverfahren, also

(C3) ist kritisch und der Hauptgrund für fehlende Konvergenz

Beweis von Satz 3.1

Sei $\Omega := \{x \in X \mid x \text{ ist Minimalpunkt von } f\}$

X beschränkt, abgeschlossen $\Rightarrow X$ kompakt

$\{x^k\} \subset X \Rightarrow$ alle Punkte der Folge in kompakter Menge enthalten

\Rightarrow (C1) von Satz 3.3.

$x^k \notin \Omega$ \Rightarrow kein Minimalpunkt

\Rightarrow in jeder ε -Umgebung von x^k gibt es besseren Punkt x

Taylor Entwicklung in $x^k \Rightarrow$

$$f(x) = f(x^k) + \nabla f(x^k)^T (x - x^k) + \underbrace{R_2(x)}_{\rightarrow 0}$$

$$f(x) < f(x^k) \Rightarrow \nabla f(x^k)^T (x - x^k) < 0 \Rightarrow \nabla f(x^k)^T x < \nabla f(x^k)^T x^k$$

\Rightarrow für minimales y von $\min \nabla f(x^k)x$ gilt

$$\nabla f(x^k)^T y < \nabla f(x^k)^T x^k$$

$\Rightarrow y - x^k$ ist echt verbesserte Richtung

$\Rightarrow f(x^{k+1}) < f(x^k) \Rightarrow$ erste Bedingung aus (C2)

allgemein gilt $\nabla f(x^k)^T (y - x^k) \leq \nabla f(x^k)^T (x^k - x^k) = 0$
 \uparrow
 minimiert $\nabla f(x^k)x$

\Rightarrow Richtung $y - x^k$ ist nicht verschlechternd

$\Rightarrow f(x^{k+1}) \leq f(x^k) \Rightarrow$ zweite Bedingung aus (C2)

zu (C3):

Frank-Wolfe ist Komposition der mengenwertigen Funktionen

D und U

D liefert zu x^k die möglichen Richtungen d , also

Paare (x^k, d) mit $d = (y - x^k)$

y minimierendes von $\nabla f(x^k)^T x$ unter $Ax = b, x \geq 0$

U liefert zu (x^k, d) die möglichen Minimierer/Approximierer

von f auf der Strecke $x^k, x^k + d = y$

Zeige: a) D abgeschlossen in jedem $x \in X \setminus \Omega$

b) Bildbereich von U ist kompakt

c) U ist abgeschlossen in jedem (x, d)


zu b): Bildbereich von U ist $X \times \{\text{mögliche Richtungen } y - x\}$

$y \in X, x \in X, X$ kompakt

\Rightarrow Bildbereich $\subseteq X + X$ kompakt

$$\left. \begin{array}{l} \text{zu c) } (\bar{x}, d^l) \rightarrow (\bar{x}, d) \\ x^l \in U(\bar{x}, d^l) \\ x^l \rightarrow x \end{array} \right\} \begin{array}{l} \text{zu zeigen} \\ \Rightarrow x \in U(\bar{x}, d) \end{array}$$

folgt aus Stetigkeit von f



x^l minimiert bzgl. (\bar{x}, d^l) , $x^l \rightarrow x$, $d^l \rightarrow d$
 \Rightarrow für l groß genug ist $f(x^l) \approx f(x)$
 $d^l \approx d$

$\Rightarrow x$ minimiert bzgl. (\bar{x}, d)

[genauer mit Epsilonarbeit]

zu a) D ist abgeschlossen in $\bar{x} \in X - \Omega$

$$\left. \begin{array}{l} \text{Sei } x^k \rightarrow \bar{x} \\ y^k \rightarrow \bar{y} \text{ mit } (x^k, y^k - x^k) \in D(x^k) \end{array} \right\} \begin{array}{l} \text{zu zeigen} \\ \Rightarrow (\bar{x}, \bar{y}) \in D(\bar{x}) \end{array}$$

$(x^k, y^k - x^k) \in D(x^k) \Rightarrow y^k$ minimiert $\nabla f(x^k)^T x$ unter $Ax = b, x \geq 0$

$$\Rightarrow \nabla f(x^k)^T y^k \leq \nabla f(x^k)^T x \quad \forall x \in X$$

halte x fest und lasse $k \rightarrow \infty$

\Rightarrow (∇f stetig) $\nabla f(\bar{x})^T \bar{y} \leq \nabla f(\bar{x})^T x$ für jedes feste $x \in X$

$\Rightarrow \bar{y}$ ist minimierer von $\nabla f(\bar{x})^T x$ unter $x \in X$

$\Rightarrow (\bar{x}, \bar{y} - \bar{x}) \in D(\bar{x})$

(1)-(3) \Rightarrow Behauptung mit Satz (3.3). \square


Bleiben 2 Fragen:

(A) Wie macht man die Line Search?

(B) Wann bricht man die Folge der x^k ab?


zu (A) Line Search

eine zufällige Lineare Suche auf



= Minimierung eines 1-dimensionalen konvexen stetigen Fkt.

$$g(\theta) = f(x^k + \theta(y^k - x^k))$$



dazu muss zusätzlich die Ableitung

$$\frac{dg}{d\theta}(\theta) = \nabla f(x^k + \theta(y^k - x^k))^T (y^k - x^k)$$

ausgewertet werden

Ist sie > 0 so $\theta := \theta + \frac{1}{2}$ Ist sie < 0 so $\theta := \theta - \frac{1}{2}$ Ist sie 0 oder das verbleibende Intervall $(\frac{1}{2})^i \|x^k - y^k\|$ klein genug, so STOP \Rightarrow Abbruch nach i Iterationen mit $(\frac{1}{2})^i \|x^k - y^k\| < \varepsilon$ $\Rightarrow i \approx \log(\frac{1}{\varepsilon} \cdot \|x^k - y^k\|)$ viele Berechnungen von ∇f

↑

unter Umständen teuer (nicht bei SD)

daher auch andere Verfahren

betrachtet (z.B. Methode von Armijo,
Numerische Mathematik)

zu (B) Abbruchkriterium

$$f \text{ konvex} \Leftrightarrow f(z) \geq f(x) + \nabla f(x)^T (z-x) \quad \forall x, z$$

↑
diffbar

$$\begin{aligned}
 x^* \text{ optimal} & \stackrel{=0}{\substack{\uparrow \\ \text{mit } z=x^*}} f(x^*) \geq f(x^k) + \nabla f(x^k)^T (x^* - x^k) \quad \forall k \\
 & \quad \uparrow \{x^k\} \text{ Folge des Frank-Wolfe-Algorithmus} \\
 & \geq f(x^k) + \nabla f(x^k)^T (y^k - x^k) \quad \forall k \\
 & \quad \uparrow y^k \text{ minimiert } \nabla f(x^k)^T x
 \end{aligned}$$

$$\Rightarrow \underbrace{f(x^k) - f(x^*)}_{\text{verbleibende}} \leq \underbrace{|\nabla f(x^k)^T (y^k - x^k)|}_{\text{in Algorithmus bekannte Größen}}$$

verbleibende "Optimalitätslücke" in Algorithmus bekannte Größen

\Rightarrow Optimalitätslücke kann im Verfahren kontrolliert werden

3.2 Die Spezialisierung auf das Systemoptimum (SO) und das User-Equilibrium (UE)

In (SO) haben wir das Minimierungsproblem

$$\min C(x(f)) = \sum_{a \in A} x_a(f) \cdot \tau_a(x_a(f))$$

$$\text{mit } x_a(f) = \sum_{P \ni a} f_P \quad f \text{ Pfadfluss}$$

$$\sum_{P \in P_k} f_P = d_k \quad \forall k \in C;$$

$$f_P \geq 0$$

$$\frac{\partial C}{\partial f_P}(x(f)) = \frac{\partial}{\partial f_P} \sum_{a \in A} x_a(f) \cdot \tau_a(x_a(f))$$

↑
vgl. § 2.6

$$= \sum_{a \in A} \frac{\partial c_a}{\partial x_a}(x_a) \cdot \frac{\partial x_a}{\partial f_P}(f) \quad \text{Kettenregel}$$

$$= 1 \text{ wenn } a \in P \text{ und } 0 \text{ sonst}$$

$$= \sum_{a \in P} \frac{\partial c_a}{\partial x_a}(x_a)$$

$$= \sum_{a \in P} (x_a \cdot \tau'_a(x_a) + \tau_a(x_a))$$

$$c'_a(x_a) \text{ aus § 1}$$

$$= \text{Länge des Weges } P \text{ bzgl. } c'_a(x_a)$$

$$\text{Also ist } \nabla C(\bar{x})^T \cdot x = \sum_{a \in A} \frac{dc_a}{dx_a}(\bar{x}_a) \cdot x_a = \sum_{a \in A} \frac{dc_a}{dx_a}(\bar{x}_a) \sum_{P \ni a} f_P$$

$$= \sum_P \sum_{a \in P} \frac{dc_a}{dx_a}(\bar{x}_a) \cdot f_P = \sum_P \frac{\partial C}{\partial f_P}(\bar{f}) \cdot f_P$$

$$= \nabla C_1(x(\bar{f}))^T x(f)$$

$$\text{Also } \nabla C_1(\bar{f})^T f = \nabla C(x)^T \cdot x$$

↑
In Pford-
formulierung

↑
In Kanten-
formulierung

=0 das zu lösende LP im Frank-Wolfe Algorithmus kann in Kantenform gelöst werden (brauchen nicht exponentiell viele Wege in Formulierung) und die Bewertung des Kante ist $\frac{dc_a}{dx_a}(x_a^l) = x_a^l \cdot \tau'_a(x_a^l) + \tau_a(x_a^l)$ mit $x_a^l =$ Kantenfluss in momentaner Iteration $c'_a(x_a^k)$

$$\begin{aligned} =0 \quad & \min \nabla C_1(x^l)^T x \\ & \text{unter } \sum_{p \in \mathcal{P}_k} f_p = d_k \quad k \in C \\ & f_p \geq 0 \end{aligned}$$

 $\hat{=}$

Min Cost MultiCommodity
Fluss Problem mit
Kantenkosten $c'_a(x_a^l)$

da keine Kapazitäten

=0 zerfällt in kürzeste-Weg-Problem
für jede Commodity k

bzgl. Kantenkosten $c'_a(x_a^l)$

3.4 SATZ: Der erste Teil des Frank-Wolfe Algorithmus reduziert sich in jeder Iteration auf die Berechnung eines kürzesten Weges für jedes Quell-Senke Paar bzgl. der Kantenkosten $c'_a(x_a^l) = x_a^l \tau'_a(x_a^l) + \tau_a(x_a^l)$

Line-Search:

Sei y^l die optimale Lösung dieses ersten Teils

=> y^l besteht aus $|C|$ vielen Wegen Q_k , $k \in C$, mit $y_{Q_k} = d_k$

vorige Lösung f^l besteht bereits aus gewissen Wegen $P \in \mathcal{P}_k$

$$\text{mit } \sum_{P \in \mathcal{P}_k} f_P^l = d_k, k \in C$$

Neue Lösung f^{l+1} ergibt sich dann als

$$f^l + \Theta(y^l - f^l)$$

Fließt bereits Fluss auf Q_k , d.h. $f_{Q_k}^l > 0$

so ergibt sich für die entsprechende Komponente von f^{l+1} :

$$f_{Q_k}^{l+1} = f_{Q_k}^l + \Theta(d_k - f_{Q_k}^l) = \underbrace{(1-\Theta)f_{Q_k}^l + \Theta \cdot d_k}_{\text{Konvexkombination}}$$

alte und neue Lösung

Fließt noch kein Fluss auf Q_k ,

so ergibt sich die entsprechende Komponente von f^{l+1} als


$$f_{Q_k}^{l+1} = f_{Q_k}^l + \Theta(d_k - f_{Q_k}^l) = \Theta d_k$$

und für alle Komponenten $P \in \mathcal{P}_k$, $P \neq Q_k$ wird Fluss
weggenommen

$$f_P^{l+1} = f_P^l + \Theta(0 - f_P^l) = (1-\Theta)f_P^l$$

Beispiel:

$$d_k = 6$$




neuer Fluss für Commodity k ergibt
sich zu

$$\begin{pmatrix} 3 \\ 2 \\ 1 \end{pmatrix} (1-\Theta) + \Theta \begin{pmatrix} 0 \\ 6 \\ 0 \end{pmatrix} = \begin{pmatrix} 3-3\Theta \\ 2+4\Theta \\ 1-\Theta \end{pmatrix} \geq 0$$

Wert von θ ergibt sich durch die Line Search

begl. $\nabla C'_a(x^k + \theta(y^k - x^k))(y^k - x^k) \quad (*)$




$$\nabla C(x) = \begin{pmatrix} 4x \\ 3 \\ 2x \\ 3x^2 \\ 2x+1 \end{pmatrix} \quad \text{Wert von } (x) \quad \text{für } \theta: \begin{pmatrix} 4 \cdot (5 + \theta) \\ 3 \cdot (1 - \theta) \\ 2 \cdot (2 + 4\theta) \\ 3 \cdot (3 - 3\theta)^2 \\ 2(3 + 3\theta) + 1 \end{pmatrix}^T \cdot \begin{pmatrix} 6 - 5 \\ 0 - 1 \\ 6 - 2 \\ 0 - 3 \\ 6 - 3 \end{pmatrix}$$

↓

3.5 PROPOSITION Line Search benötigt nur die Wege die Fluss führen + die neu berechneten Wege in der laufenden Iteration (also nicht alle potentiell existierende Wege). Die Bestimmung von θ kann im Kantensraum erfolgen.

Abbruch entweder über die Optimalitätslücke (§ 3.1) oder über Beobachtungen der Weglängen bzgl. $C'_a(x^k)$ (Abbruch wenn sie ungefährlich sind, d.h. neu berechnete Wege unterscheiden sich kaum von den vorherigen, dies nutzt die UE Interpretation von θ)

Typischerweise ist der Gewinn groß in der ersten Iteration, später kleiner



Bemerkungen:

(1) Das Verfahren von Frank-Wolfe wird in diesem Zusammenhang auch als convex combination algorithm bezeichnet

(2) Es kann auch für die Berechnung des UE verwendet werden

$$C(x(t)) = \sum_{a \in A} \int_0^{x_a(t)} \tau_a(t) dt, \quad \text{Nebenbedingungen bleiben gleich}$$

$C_a(x_a)$

$$\Rightarrow C'_a(x_a) = \tau_a(x_a)$$

Inszenen bleibt alles gleich!


3.6 SATZ Bei der Berechnung des UE mit Frank-Wolfe reduziert sich im ersten Teil die Berechnung auf die Berechnung eines kürzesten Weges für jedes Quelle-Senke Paar, bzgl. der Kantenkosten $\tau_a(x_a^e)$

(3) Ein unbefugendes "Fixpunkt-Insatz" funktioniert i.A. nicht

$$f^{k+1} = \text{optimaler Fluss bzgl. der Faktoren } \tau_a(x_a^e(f^k))$$



aus der vorigen Iteration

da Oszillation auftreten kann



$$\tau_1(x) = 1 + \frac{2x}{2-x}$$

$$\tau_2(x) = 2 + \frac{x/2}{2-x}$$



Aufgabe 5

Starfluss $x_1=1, x_2=0$ Berechne Folge der Flüsse mit "Fixpunkt-Insatz" und mit dem Frank-Wolfe Algo

(4) Bei Frank-Wolfe kann Zickzack-Verhalten auftreten



Es gibt verschiedene Verbesserungen um dies zu vermeiden, z. B. die Postau Heuristik (LeBlanc, Helgason, Boyce 85)

/
intelligenter Line Search durch Annäherung der
zwei letzten Iterationen, d.h. x^l, y^l und x^{l-1}, y^{l-1}
 \Rightarrow 30% Verbesserung der Rechenzeit in unseren Rechnungen

Aufgabe 6: Was muss geändert werden, wenn zusätzlich
der Fluss pro Kante durch eine Kapazität
beschränkt ist, d.h. $x_a \leq u_a$?

3.3 Das eingeschränkte Systemoptimum

Motivation:Vermeide Preis des Marktes $\frac{UE}{SO}$

Vermeide Unfairness der SO (einzelne bekommen "lange" Raster)

$$\text{Unfairness einer Rasterzuweisung } f \\ = \max_k \frac{\max \{ \tau_p(f) \mid p \in P_k \}}{\text{Faktor } L_k(UE) \text{ in } UE}$$

Bemerkung: unfairness (UE) = 1

unfairness (SO) $\rightarrow \infty$ (§ 1)

Daher Idee (Jahn, M., Schulz, Stier 05)

Lasse uns Wege w , deren Faktor bzgl. UE-Faktoren nur wenig über $L_k(f)$ liegen.

$$\text{d.h. } P_k^\varepsilon = \{ p \in P_k \mid \sum_{a \in P} \tau_a(UE_a) \leq (1+\varepsilon)L_k(UE) \}$$

↓

Herleitung des Frank-Wolfe Algorithmus wie bisher, nur mit

Menge P_k^ε statt P_k ↑ hängt nicht vom aktuellen Fluss f ab

$$\text{d.h. Nebenbedingungen sind immer } \begin{cases} \sum_{p \in P_k^\varepsilon} f_p = d_k & k \in C \\ f_p \geq 0 \end{cases}$$

=0 Berechnung der Abstiegsrichtung führt auf die Aufgabe

Berechne pro Commodity $k \in C$ einen kürzesten Weg bzgl. $c'_a(x_a^k)$
aus P_k^E



Constrained shortest path Problem (CSP)

Gegeben: Digraph $G = (V, A)$, $s, t \in V$

2 Kantenbewertungen τ_a "Zeit"

l_a "Länge", Schranke L

Aufgabe: Berechne kürzesten s, t Weg P bzgl. τ_a

$$\text{mit } \ell(P) = \sum_{a \in P} l_a \leq L$$

Leider Komplexitätsprobleme: CSP ist (schwer) NP-schwer
genauerer Studium in § 4