

Nicht lineare Optimierung

(mit Schwerpunkt: semidefinite Optimierung)

Mathematisches Programm:

gegeben: Funktionen $f_0, f_1, \dots, f_m : \mathbb{R}^n \rightarrow \mathbb{R} \cup \{\infty\}$
Konstanten $b_1, \dots, b_m \in \mathbb{R}$

gesucht: minimiere $f_0(x)$
so dass $x \in \mathbb{R}^n$
 $f_i(x) \leq b_i, \quad i = 1, \dots, m.$ (MP)

f_0 : Zielfkt.; f_1, \dots, f_m : Nebenbedingungs fkt.

x : Optimierungsvariable; $x \in \mathbb{R}^n$ mit $f_i(x) \leq b_i$: gültige

Lösung; x gültige Lösung mit $f_0(x) \leq f_0(x')$ für alle
gültigen Lösungen x' : optimale Lösung

Lineares Programm (LP): Alle Fkt. f_0, \dots, f_m sind linear.

- Theorie und Praxis von LP, ist sehr gut verstanden

(\rightarrow Vorlesung OR).

Nichtlineares Programm (NLP): Eine der Fkt. f_0, \dots, f_m ist nicht linear
- Hoffnungslos! Viel zu allgemein.

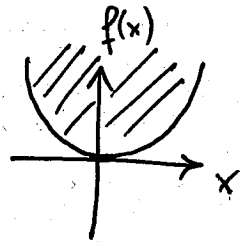
Spezieller (aber immer noch zu allg.) : Konvexe Programme

Alle f_0, \dots, f_m sind konvexe Funktionen

Def.: Fkt. $f: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{\infty\}$ heißt konvex, falls ihr Epigraph

$$\text{epi}(f) = \{ (x, \alpha) \in \mathbb{R}^{n+1} : \alpha \geq f(x) \}$$

eine konvexe Menge ist.

Bsp.: $f(x) = x^2$, $\text{epi}(f) =$ 

Ungleichung von Jensen: Ist $f: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{\infty\}$ konvex, dann

$$f(tx + (1-t)y) \leq tf(x) + (1-t)f(y)$$

für alle $t \in [0, 1]$, $x, y \in \mathbb{R}^n$.

Bew.: Es ist $\tilde{x} = (x, f(x)) \in \text{epi}(f)$, $\tilde{y} = (y, f(y)) \in \text{epi}(f)$.
Also $t\tilde{x} + (1-t)\tilde{y} \in \text{epi}(f)$.

D.h.

$$(tx + (1-t)y, tf(x) + (1-t)f(y)) \in \text{epi}(f),$$

also

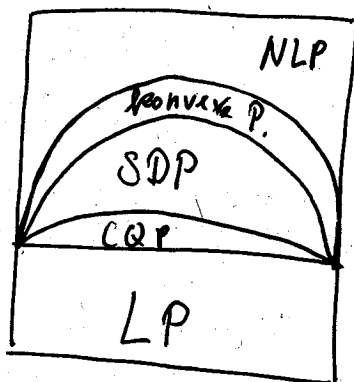
$$f(tx + (1-t)y) \leq tf(x) + (1-t)f(y).$$

□

Fundamentale Eigenschaften konvexer Programme:

- Die Menge der gültigen Lösungen ist konvex.
[folgt unmittelbar aus der Ungleichung von Jensen]
- Jedes lokale Minimum ist eine optimale Lösung
[→ Übung].
- Immer noch zu allgemein: Die meisten NLPs können konvexifiziert werden [→ Ende der Vorlesung].

Übersicht:



SDP = semidefinite Programme

CQP = konische quadratische Programme

(„conic quadratic p.“)

Kapitel I Konische Optimierung

§ 1 Konvexe Kegel

- Def. 1
- a) $K \subseteq \mathbb{R}^n$, $K \neq \emptyset$ heißt (konvexer) Kegel, falls $\forall \alpha, \beta \in \mathbb{R}_{\geq 0} \forall x, y \in K: \alpha x + \beta y \in K$.
- b) Ein konvexer Kegel K heißt spitz, falls aus $x, -x \in K$ stets $x = 0$ folgt.
- c) Ein konvexer Kegel K heißt ordentlich, falls er spitz, abgeschlossen und volldimensional ist.

Ordentliche Kegel definieren Positivitätsbereiche und eine partielle Ordnung auf \mathbb{R}^n :

$$x \geq_K y \iff x - y \in K$$

- Falls $K = [0, \infty) \subseteq \mathbb{R}$, dann ist $x \geq_K y$ nichts anderes als $x \geq y$.
- Es kann passieren, dass $x, y \in \mathbb{R}^n$ nicht vergleichbar sind, d.h. es ist weder $x \geq_K y$ noch $y \geq_K x$. [\rightarrow partielle Ordnung]

Proposition 2 Sei $K \subseteq \mathbb{R}^n$ ein spitzer, konvexer Kegel.

Dann gilt $\forall x, y, z, x', y' \in \mathbb{R}^n \quad \alpha \in \mathbb{R}_{\geq 0}$:

a) Reflexivität $x \geq_K x$

b) Antisymmetrie $x \geq_K y, y \geq_K x \Rightarrow x = y$

c) Transitivität $x \geq_K y, y \geq_K z \Rightarrow x \geq_K z$

d) Homogenität $x \geq_K y \Rightarrow \alpha x \geq_K \alpha y$

e) Additivität $x \geq_K y, x' \geq_K y' \Rightarrow x+x' \geq_K y+y'$.

Bew.: z.B. b) Aus $x \geq_K y, y \geq_K x$ folgt $x-y, -(x-y) \in K$.
Da K spitz, muss $x-y=0$ sein. \square

Falls K voll-dimensional ist, dann ist sein Inneres („interior“)

$$\text{int } K = \{x \in \mathbb{R}^n : \exists \varepsilon > 0 : B(x, \varepsilon) \subseteq K\} \neq \emptyset,$$

wobei $B(x, \varepsilon) = \{y \in \mathbb{R}^n : \|y-x\| \leq \varepsilon\}$. Dann kann man die strikte Ungleichung $x \succ_K y \Leftrightarrow x-y \in \text{int } K$ def.

Falls K abgeschlossen ist, ist folgender Grenzübergang erlaubt:

$$\lim_{i \rightarrow \infty} x_i = x, \quad \lim_{i \rightarrow \infty} y_i = y, \quad x_i \geq_K y_i \Rightarrow x \geq_K y.$$

§ 2 Konstruktionen und Beispiele

Konstruktionen

Def. 1 a) Sei $A \subseteq \mathbb{R}^n$ eine Menge. Die konische Hülle von A ist

$$\text{cone } A = \left\{ y : N \in \mathbb{N}, a_1, \dots, a_N \in A, \alpha_1, \dots, \alpha_N \in \mathbb{R}_{\geq 0} : \right. \\ \left. y = \sum_{i=1}^N \alpha_i a_i \right\}$$

b) Falls $|A| < \infty$, dann heißt $\text{cone } A$ endlich erzeugt.

Satz 2 Sei $A \subseteq \mathbb{R}^n$.

a) Es gilt $\text{cone } A = \bigcap_{\substack{K \supseteq A \\ K \text{ konvexe Kegel}}} K$.

b) (Minkowski-Weyl)

Falls $A = \{a_1, \dots, a_N\}$, dann gibt es eine Matrix

$B \in \mathbb{R}^{M \times n}$ mit

$$\text{cone } A = \{x \in \mathbb{R}^n : Bx \leq 0\}.$$

Bew.: \rightarrow Vorlesung OR.

Def. 3 Seien $K_1 \subseteq \mathbb{R}^{n_1}$, $K_2 \subseteq \mathbb{R}^{n_2}$ konvexe Kegel.

Ihr direktes Produkt ist

$$K_1 \times K_2 = \{ (x_1, x_2) : x_1 \in K_1, x_2 \in K_2 \} \subseteq \mathbb{R}^{n_1+n_2}$$

Offensichtlich: $K_1 \times K_2$ ist konvexer Kegel.

Def. 4 Sei $K \subseteq \mathbb{R}^n$ ein konvexer Kegel. Dann ist sein

dualer Kegel definiert als

$$K^* = \{ y \in \mathbb{R}^n : x^T y \geq 0 \text{ für alle } x \in K \}.$$

Satz 5 Sei $K \subseteq \mathbb{R}^n$ ein konvexer Kegel. Dann:

a) $K \subseteq (K^*)^*$

b) Falls K abgeschlossen, dann $K = (K^*)^*$.

Bew.: a) klar


für b) benötigt man

Satz 6 Sei K ein konvexer, abgeschlossener Kegel,

sei $z \notin K$. Dann gibt es ein $c \in \mathbb{R}^n$ mit

$$c^T z < 0 \text{ und } c^T x \geq 0 \text{ für alle } x \in K.$$

D.h. die Hyperebene $H = \{y : c^T y = 0\}$ ist Trennhyperebene von $\{z\}$ und K . Sie trennt z strikt und ist Stützhyperebene an K .



Bew.: Satz 5 b)

zu zeigen $K \subseteq (K^*)^*$.

Sei $z \in \mathbb{R}^n \setminus K$. Dann gibt es nach Satz 6 ein $c \in \mathbb{R}^n$ mit

$$c^T z < 0 \text{ und } c^T x \geq 0 \text{ für alle } x \in K.$$

D.h. $c \in K^*$ und $z \notin (K^*)^*$.


zum Beweis von Satz 6:

Wdh OR: Metrische Projektion

Sei $C \subseteq \mathbb{R}^n$ abgeschlossen und konvex, $C \neq \emptyset$. Sei $z \notin C$.


Dann $\exists!$ $y \in C$ mit $\|y - z\| = \inf_{x \in C} \|x - z\|$.

Notation: $\pi_C(z) = y$



Zusatz: $(z-y)^T(x-y) \leq 0$ für alle $x \in C$.

Bew.: Sei $\alpha \in [0, 1]$. Dann ist



$$\begin{aligned}\|z-y\|^2 &\leq \|z - ((1-\alpha)y + \alpha x)\|^2 \\ &= \|z - y + \alpha(y-x)\|^2 \\ &= \|z-y\|^2 + 2\alpha(z-y)^T(y-x) + \alpha^2\|y-x\|^2\end{aligned}$$

Demnach für $\alpha \in (0, 1]$:

$$(z-y)^T(x-y) \leq \frac{\alpha}{2}\|y-x\|^2$$

und die Beh. folgt, da die rechte Seite beliebig klein ≥ 0 werden kann.

Bew.: (Satz 6)

Setze $c = y - z$.

Beh.: $c^T y = 0$

Bew.: Ang. $c^T y \neq 0$.

1. Fall: $c^T y > 0$.

Dann ist $(1-\varepsilon)y \in K$ für kleinen $\varepsilon > 0$ und

$$\begin{aligned}\|(1-\varepsilon)y - z\|^2 &= \|y - z - \varepsilon y\|^2 \\ &= \|y - z\|^2 - 2\varepsilon(y-z)^T y + \varepsilon^2\|y\|^2\end{aligned}$$

Für $\varepsilon < \frac{2 c^T y}{\|y\|^2}$ ist

$$-2\varepsilon (y-z)^T y + \varepsilon^2 \|y\|^2 < 0,$$

was ein Widerspruch zur Minimalität von $\|y-z\|^2$ ist.

2. Fall $c^T y < 0$

genauso: mit $(1+\varepsilon)y \in K$ und $\varepsilon \in (0, \frac{-2c^T y}{\|y\|^2})$.

Nun ist

$$0 < c^T c = c^T (y-z) = c^T y - c^T z = -c^T z,$$

also $0 > c^T z$.

Andererseits für $x \in K$ nach dem Zusatz

$$0 \geq (z-y)^T (x-y) = -c^T (x-y) = -c^T x,$$

also $c^T x \geq 0$.

Beispiele

Bsp. 7 Sei $U \subseteq \mathbb{R}^n$ ein Untervektorraum. Dann ist U ein konvexer Kegel.


Dualer Kegel: $U^* = U^\perp$.

Bsp. 8 Nichtnegativer Orthant

$$\mathbb{R}_{\geq 0}^n = \{x \in \mathbb{R}^n : x_1 \geq 0, \dots, x_n \geq 0\}$$

$$= \mathbb{R}_{\geq 0} \times \dots \times \mathbb{R}_{\geq 0}$$

$$= \text{cone} \{e_1, \dots, e_n\}.$$



$$\text{Dualer Kegel: } (\mathbb{R}_{\geq 0}^n)^* = \mathbb{R}_{\geq 0}^n.$$


$$[\text{Allgemein gilt: } (K_1 \times K_2)^* = K_1^* \times K_2^*]$$

Bew.: leichte Übung].

Bsp. 9 Lorentzkegel („ice cream cone“)

$$\mathcal{L}^{n+1} = \left\{ (x, t) \in \mathbb{R}^{n+1} : \|x\|_2 = \sqrt{\sum_{i=1}^n x_i^2} \leq t \right\}$$

ist ein ordentlicher konvexer Kegel



Dualer Kegel:

$$(\mathcal{L}^{n+1})^* = \mathcal{L}^{n+1}.$$

→ Aufgabe 1.4.

Bsp. 10 Menge der positiv semidefiniten Matrizen

$$S^n = \{ X \in \mathbb{R}^{n \times n} : X \text{ symmetrisch, d.h. } X_{ij} = X_{ji} \}.$$

$\frac{n(n+1)}{2}$ - dimensionaler Vektorraum der symmetrischen Matrizen.

Skalarprodukt : $\langle X, Y \rangle = \text{Tr}(Y^T X)$
 $= \sum_{i=1}^n \sum_{j=1}^n X_{ij} Y_{ij}$,

wobei $\text{Tr}(X) = \sum_{i=1}^n X_{ii}$ die Spur („trace“) von X ist.

$(S^n, \langle \cdot, \cdot \rangle)$ ist isometrisch zum Raum $(\mathbb{R}^{\frac{n(n+1)}{2}}, (x, y) \mapsto x^T y)$

mittels der Abbildung

$$T : S^n \rightarrow \mathbb{R}^{\frac{n(n+1)}{2}}$$

$$X \mapsto (X_{11}, \sqrt{2} X_{12}, \sqrt{2} X_{13}, \dots, \sqrt{2} X_{1n}, \\ X_{22}, \sqrt{2} X_{23}, \dots, \sqrt{2} X_{2n}, \\ \dots \\ X_{nn})$$

↑
obere Dreiecksmatrix.

$X \in S^n$ heißt positiv semidefinit, falls

$$\forall x \in \mathbb{R}^n, \quad x^T X x \geq 0.$$

Notation: $X \geq 0$
 \uparrow $\$ \setminus \text{succ} \$$

$S_{\geq 0}^n = \{X \in S^n : X \geq 0\}$ ist der Kegel der positiv semidefiniten Matrizen („PSD-Kegel“)

Theorem („Spektralzerlegung“)

Sei $X \in S^n$. Dann gibt es eine Orthonormalbasis $u_1, \dots, u_n \in \mathbb{R}^n$ und $\lambda_1, \dots, \lambda_n \in \mathbb{R}$, so dass

$$X = \sum_{i=1}^n \lambda_i u_i u_i^T. \quad (\text{eine Spektralzerlegung von } X)$$

Dabei sind $\lambda_1, \dots, \lambda_n$ die Eigenwerte von X und u_1, \dots, u_n zugehörige Eigenvektoren.

In Matrixform: $X = P D P^T$, wobei $P \in O(n)$ eine orthogonale Matrix und $D = \begin{bmatrix} \lambda_1 & & \\ & \ddots & \\ & & \lambda_n \end{bmatrix} = \text{diag}(\lambda_1, \dots, \lambda_n)$ eine Diagonalmatrix.

Bew.: \rightarrow Vorlesung Lineare Algebra 2.

Korollar a) $X \in S_{\geq 0}^n \iff \lambda_1, \dots, \lambda_n \geq 0$.

b) $(S_{\geq 0}^n)^* = S_{\geq 0}^n$.

Bew.: a) " \implies " Spektralzerlegung $X = \sum_{i=1}^n \lambda_i \mu_i \mu_i^T$.

Dann gilt für $j=1, \dots, n$:

$$= \underbrace{\begin{cases} 1 & i=j \\ 0 & i \neq j \end{cases}}$$

$$0 \leq \mu_j^T X \mu_j = \mu_j^T \sum_{i=1}^n \lambda_i \mu_i \mu_i^T \mu_j = \sum_{i=1}^n \lambda_i (\mu_i^T \mu_j)^2 = \lambda_j.$$

" \impliedby " Sei $x \in \mathbb{R}^n$. Dann

$$x^T X x = x^T \sum_{i=1}^n \lambda_i \mu_i \mu_i^T x = \sum_{i=1}^n \lambda_i \underbrace{(\mu_i^T x)}_{\geq 0}^2 \geq 0.$$

b) " \subseteq " Für $x \in \mathbb{R}^n$ ist $xx^T \in S_{\geq 0}^n$. Sei $Y \in (S_{\geq 0}^n)^*$.

Dann $0 \leq \langle xx^T, Y \rangle = x^T Y x \implies Y \in S_{\geq 0}^n$.

" \supseteq " Sei $X \in S_{\geq 0}^n$. Dann gilt für $Y \in S_{\geq 0}^n$ mit Spektralzerlegung $Y = \sum_{i=1}^n \lambda_i \mu_i \mu_i^T$ nach a) $\lambda_1, \dots, \lambda_n \geq 0$.

Deshalb

$$\langle X, Y \rangle = \sum_{i=1}^n \lambda_i \underbrace{\mu_i^T X \mu_i}_{\geq 0} \geq 0 \implies X \in (S_{\geq 0}^n)^*.$$

□

Mehr zu $S_{\geq 0}^n$: \rightarrow Kapitel I.

Bsp. 11 Endlich erzeugte Kegel

$$K = \text{cone} \{ a_1, \dots, a_N \} \subseteq \mathbb{R}^n.$$

Nach dem Theorem von Minkowski - Weyl gibt es $B \in \mathbb{R}^{M \times n}$ mit $K = \{ x \in \mathbb{R}^n : Bx \leq 0 \}$.

Dualer Kegel: $K^* = \text{cone} \{ -b_1, \dots, -b_M \},$

wobei b_1^T, \dots, b_M^T die Zeilen von B sind.

Bew.: " \supseteq ": Sei $y = \sum_{j=1}^M \beta_j (-b_j)$ mit $\beta_1, \dots, \beta_M \geq 0$.

Dann gilt für $x \in K$:

$$x^T y = - \sum_{j=1}^M \beta_j \underbrace{b_j^T x}_{\leq 0} \geq 0. \Rightarrow y \in K^*.$$

" \subseteq ": Ang. $y \in K^* \setminus \text{cone} \{ -b_1, \dots, -b_M \}$. Dann gibt es nach Satz 6 ein $c \in \mathbb{R}^n$ mit

$$c^T y < 0 \quad \text{und} \quad c^T x \geq 0 \quad \forall x \in \text{cone} \{ -b_1, \dots, -b_M \}.$$

Also $Bx \leq 0$, d. h. $c \in K$. Dann kann aber nicht $y \in K^*$

sein.

Bem. 12 Koecher - Vinberg Klassifikation

Sei $K \subseteq \mathbb{R}^n$ ein ordentlicher, selbst-dualer ($K = K^{**}$), konvexer Kegel. Er heißt homogen, wenn die Menge der Kegelautomorphismen, $\Gamma \subseteq GL_n(\mathbb{R})$ mit $\Gamma K = K$, eine abgeschlossene Untergruppe ist, die transitiv operiert (d.h. $\forall x, y \in K \exists \gamma \in \Gamma: \gamma x = y$).

Solche Kegel sind direkte Produkte von

(i) \mathbb{L}^{n+1}

(ii) $S_{\geq 0}^n$

(iii) Kegel der pos. semidefiniten hermiteschen Matrizen über \mathbb{C}

(iv) " " über \mathbb{H} , den Quaternionen

(v) einem speziellen 27-dim. Kegel von 3×3 hermiteschen Matrizen über \mathbb{O} , den Oktaven (oder Oktotonen).

→ Stichwort: Euklidische Jordanalgebren.

§ 3 Konische Programme

Def. 1 Sei $K \subseteq \mathbb{R}^n$ ein ordentlicher Keil.


Gegeben seien $c, a_1, \dots, a_m \in \mathbb{R}^n$, $b_1, \dots, b_m \in \mathbb{R}$. Ein primales konisches Programm (in Standardform) ist

das folgende Maximierungsproblem:

$$(P) \quad \begin{aligned} \sup \quad & c^T x \\ & x \in \mathbb{R}^n \\ & a_j^T x = b_j \quad \text{für } j \in [m] = \{1, \dots, m\} \\ & x \in K. \end{aligned}$$

Das zugehörige duale konische Programm ist das folgende Minimierungsproblem:

$$(D) \quad \begin{aligned} \inf \quad & \sum_{j=1}^m b_j y_j = b^T y \\ & y \in \mathbb{R}^m \\ & \sum_{j=1}^m y_j a_j - c \in K^*. \end{aligned}$$



* primales konisches Programm: Maximieren eine lineare Fkt über Durchschnitt eines Kegels mit einem affinen Unterraum.

* Anstatt $a_j^T x = b_j$ für $j \in [m]$ schreibt man
auch oft $Ax = b$ mit $A = \begin{bmatrix} a_1^T \\ \vdots \\ a_m^T \end{bmatrix} \in \mathbb{R}^{m \times n}$, $b \in \mathbb{R}^m$.

Genauso: $A^T y = c$ für $\sum_{j=1}^m y_j a_j = c$.

* $x \in \mathbb{R}^n$ heißt zulässige Lösung von (P), falls $Ax = b$
und $x \in K$ gilt. x heißt strikt zulässig, falls x
zulässig und $x \in \text{int } K$.

Genauso: $y \in \mathbb{R}^m$ heißt zulässig für (D), falls

$A^T y = c \in K^*$, und strikt zulässig, falls $A^T y = c \in \text{int } K^*$.

Geometrische Interpretation von (P) und (D)

Definiere die Untervektorräume

$$L = \{x \in \mathbb{R}^n : Ax = 0\}$$

$$L^\perp = \{y \in \mathbb{R}^m : x^T y = 0 \text{ für alle } x \in L\}$$

$$= \{y^T A : y \in \mathbb{R}^m\}.$$

Ang. es gibt kein $x_0 \in \mathbb{R}^n$ mit $Ax_0 = b$. [Ansonsten
hätte (P) keine zulässige Lösung].

Dann ist

$$b^T y = (Ax_0)^T y = x_0^T A^T y = x_0^T (A^T y - c) + x_0^T c.$$

D.h.

$$(P) = \sup \{ c^T x : x \in K \cap (x_0 + L) \}$$

$$(D) = c^T x_0 + \inf \{ x_0^T z : z \in K^* \cap (-c + L^\perp) \}.$$

Wenn man nun (D) in primaler Form schreibt

$$c^T x_0 - \sup \{ -x_0^T z : z \in K^* \cap (-c + L^\perp) \}$$

und dann das Dual bildet, erhält man (P) zurück,


Weil nach Satz 2.5 gilt $(K^*)^* = K$.

Beispiele

Bsp. 2 $K = \mathbb{R}_{\geq 0}^n$. Lineare Programme (LP)

$$(P) \quad \begin{array}{l} \sup \quad c^T x \\ x \in \mathbb{R}^n \\ Ax = b \\ x \geq 0 \quad (x \in \mathbb{R}_{\geq 0}^n) \\ \uparrow \\ \text{Komponentenweise} \end{array}$$

$$(D) \quad \begin{array}{l} \inf \quad b^T y \\ y \in \mathbb{R}^m \\ A^T y - c \geq 0 \end{array}$$



Bsp. 3 $K = \mathcal{L}^{n_1+1} \times \mathcal{L}^{n_2+1} \times \dots \times \mathcal{L}^{n_r+1}$

Konische quadratische Programmierung (CQP)

(P) $\sup (c_1, \sigma_1), \dots, (c_r, \sigma_r)^T ((x_1, t_1), \dots, (x_r, t_r))$

$((x_1, t_1), \dots, (x_r, t_r)) \in \mathbb{R}^{n_1+1} \times \dots \times \mathbb{R}^{n_r+1}$

$((a_{j1}, d_{j1}), \dots, (a_{jr}, d_{jr}))^T ((x_1, t_1), \dots, (x_r, t_r)) = b_j,$
 $j \in [m]$

$((x_1, t_1), \dots, (x_r, t_r)) \in \mathcal{L}^{n_1+1} \times \dots \times \mathcal{L}^{n_r+1}$

(D) $\inf b^T y$

$y \in \mathbb{R}^m$

$\sum_{j=1}^m y_j ((a_{j1}, d_{j1}), \dots, (a_{jr}, d_{jr})) - (c_1, \sigma_1), \dots, (c_r, \sigma_r)$

$\in \mathcal{L}^{n_1+1} \times \dots \times \mathcal{L}^{n_r+1}$

Die letzte Bedingung kann schöner / intuitiver aufgeschrieben werden: Definiere die Matrizen

$A_i = [a_{1i} \dots a_{mi}] \in \mathbb{R}^{n_i \times m}, \quad i = 1, \dots, r$

Und die Vektoren $d_i = (\alpha_{i1}, \dots, \alpha_{im})^T$, $i = 1, \dots, r$.

Dann ist die letzte Bed. äquivalent zu

$$\|A_i y - c_i\| \leq d_i^T y - \gamma_i, \quad i = 1, \dots, r.$$

Insbesondere sieht man, dass LP ein Spezialfall von CQP ist (setze $A_i = 0$, $c_i = 0$).

Bsp. 4 $K = S_{\geq 0}^n$ Semidefinite Programmierung (SDP).

$$(P) \quad \sup \langle C, X \rangle$$
$$X \in S^n$$

$$\langle A_j, X \rangle = b_j, \quad j = 1, \dots, m$$

$$X \geq 0$$

$$(D) \quad \inf b^T y$$
$$y \in \mathbb{R}^m$$

$$\sum_{j=1}^m y_j A_j - C \geq 0$$

Ungleichungen der Form $\sum_{j=1}^m y_j A_j - C \geq 0$ heißen

linear Matrixungleichungen (LMI = linear matrix inequality).

Lemma 5 (Schurkomplement)

Sei $X \in S^n$ eine Matrix mit Blockgestalt

$$X = \begin{bmatrix} A & B \\ B^T & C \end{bmatrix} \text{ mit } A \in S^p, C \in S^{n-p}, B \in \mathbb{R}^{p \times (n-p)}$$

Falls A invertierbar ist gilt

$$X \geq 0 \iff A \geq 0 \text{ und } C - B^T A^{-1} B \geq 0.$$

[Die Matrix $C - B^T A^{-1} B$ heißt das Schurkomplement von A in X .]

Bew.: Durch Nachrechnen:

$$X = P^T \begin{bmatrix} A & 0 \\ 0 & C - B^T A^{-1} B \end{bmatrix} P \quad \text{mit } P = \begin{bmatrix} I & A^{-1} B \\ 0 & I \end{bmatrix} \quad \square$$

Korollar 6

$$\begin{aligned} \mathcal{L}^{n+1} &= \{ (x, t) \in \mathbb{R}^{n+1} : \|x\| \leq t \} \\ &= \left\{ (x, t) \in \mathbb{R}^{n+1} : \begin{bmatrix} t I_n & x \\ x^T & t \end{bmatrix} \geq 0 \right\}. \end{aligned}$$

Bew.: Falls $t = 0$ ist, muß $x = 0$ sein..

Falls $t > 0$ ist, ist $t I_n > 0$.

Betrachte Schurkomplement tI_n in $\begin{bmatrix} tI_n & x \\ x^T & t \end{bmatrix}$.

Die letztere Matrix ist nach Lemma 5 psd gdw

$$t - x^T \frac{1}{t} I_n x \geq 0 \Leftrightarrow t^2 \geq x^T x \Leftrightarrow \|x\| \leq t \quad \square$$

Somit ist CQP ein Spezialfall von SDP.

§ 4 Alternativsätze

Erinnerung: Farkas Lemma für LPs

Lemma 1 Sei $A \in \mathbb{R}^{m \times n}$, $b \in \mathbb{R}^m$. Dann gilt

entweder i) $\exists x \geq 0 : Ax = b$

oder ii) $\exists y : A^T y \geq 0, b^T y < 0$.

Verallgemeinerungsversuch auf konische Programme:

Es gilt entweder

i) $\exists x \in K : Ax = b$

oder ii) $\exists y \in \mathbb{R}^m : A^T y \in K^\circ, b^T y < 0$.

Beweisversuch:

i) \Rightarrow \neg ii): Ang. x ist zulässig für i) und y ist zulässig für ii). Dann

$$0 \leq (A^T y)^T x = y^T A x = y^T b < 0 \quad \curvearrowright$$

\neg ii) \Rightarrow i): Ang. i) hat keine zulässige Lösung. Dann ist $b \notin \{Ax : x \in K\}$ und $\{Ax : x \in K\}$ ist ein konvexer Kegel. Dann gibt es nach Satz 2.6 ein $y \in \mathbb{R}^m$ mit $y^T b < 0$ und $y^T A x \geq 0$ für alle $x \in K$. D. h. $(y^T A)^T = A^T y \in K^*$, also folgt ii).

Bsp 2 Definiere für $i \leq j$ die Matrix

$$E_{ij} = \frac{1}{2} (e_i e_j^T + e_j e_i).$$

und betrachte die Systeme

$$i) \quad \langle E_{11}, X \rangle = 0, \quad \langle E_{12}, X \rangle = 1, \quad X \geq 0, \quad X \in S^2$$


$$ii) \quad y_1 E_{11} + y_2 E_{12} \geq 0 \quad y_2 < 0.$$

Beide haben keine zulässige Lösung!

? Wo ist das Problem?

Der konvexe Kegel

$$A S_{\geq 0}^2 = \left\{ \begin{bmatrix} \langle E_{11}, X \rangle \\ \langle E_{12}, X \rangle \end{bmatrix} : X \in S_{\geq 0}^2 \right\}$$



$$= \left\{ \begin{bmatrix} x_{11} \\ x_{12} \end{bmatrix} : x_{11} > 0, x_{12} \in \mathbb{R} \right\} \cup \left\{ \begin{bmatrix} 0 \\ 0 \end{bmatrix} \right\}$$

ist nicht abgeschlossen.

Def. 3 Sei $A \in \mathbb{R}^{m \times n}$, $b \in \mathbb{R}^m$. Das System

$$Ax = b, x \in K$$

heißt schwach zulässig, falls

$$\forall \varepsilon > 0 \exists x \in K : \|Ax - b\| \leq \varepsilon.$$

Satz 4 Sei $A \in \mathbb{R}^{m \times n}$, $b \in \mathbb{R}^m$. Dann gilt

entweder i) Das System $Ax = b, x \in K$ ist schwach zulässig.

oder ii) $\exists \eta \in \mathbb{R}^m : A^T \eta \in K^*, b^T \eta < 0$.

Bew.: wie oben, nur verwende den Abschluss $\overline{\{Ax : x \in K\}}$.

Zurück zu Bsp. 2: Das System $\langle E_{11}, X \rangle = 0, \langle E_{12}, X \rangle = 1,$
 $X \geq 0$ ist schwach zulässig.

Korollar 5 Sei $A \in \mathbb{R}^{m \times n}, c \in \mathbb{R}^n$. Dann gilt

entweder i) $\exists x \in K: Ax = 0$ und $c^T x > 0$

oder ii) Das System $A^T y - c \in K^*$ ist schwach
zulässig, d.h. $\forall \varepsilon > 0 \exists y \in \mathbb{R}^m$ und $z \in K^*$
mit $\|A^T y - c - z\| \leq \varepsilon$.

Bew.: \rightarrow Aufgabe 3.1.

Satz 6 Sei $A \in \mathbb{R}^{m \times n}, b \in \mathbb{R}^m$. Ang. $Ax = b$ hat

Lösung x_0 . Dann gilt entweder

i) $\exists x \in \text{int } K: Ax = b$ (strikt zulässige Lösung)

oder


ii) $\exists y \in \mathbb{R}^m: A^T y \in K^* \setminus \{0\}$ und $b^T y \leq 0$.

Zurück zu Bsp. 2: Hier Bed. ii) ist erfüllt.

Für den Beweis von Satz 6 ist die folgende Variante des Satzes über die Existenz von Trennhyperebenen erforderlich.

Satz 7 Seien $C, D \subseteq \mathbb{R}^n$ nichtleere konvexe Mengen mit $C \cap D = \emptyset$. Dann gibt es ein $a \in \mathbb{R}^n \setminus \{0\}$ mit

$$\sup_{x \in C} a^T x \leq \inf_{x \in D} a^T x$$



Bew. skizze: Betrachte die konv.

Menge $C - D = \{c - d : c \in C, d \in D\}$.

Nach Vor. ist $0 \notin C - D$. Falls $0 \notin \overline{C - D}$, verwende metrische Projektion zur Def. von a . Falls $0 \in \overline{C - D}$, dann konstruiere Stützhyperebene H durch 0 an $\overline{C - D}$ und verwende einen zu H orthogonal stehenden Vektor als a .

Details: siehe Skript „semidefinite opt.“ Kapitel 1.1.3.

Bew. (Satz 6)

i) \Rightarrow ii) Ang. $\exists x \in \text{int } K : Ax = b$ und

$\exists \eta : A^T \eta \in K^* \setminus \{0\}$ mit $b^T \eta \leq 0$.

Dann

$$0 \leq (A^T y)^T x = y^T A x = y^T b \leq 0.$$

D.h. $(A^T y)^T x = 0$. \hookrightarrow zu A2.1 $[x \in \text{int } K \Leftrightarrow y^T x > 0 \ \forall y \in K^* \setminus \{0\}]$

ii) \Rightarrow i) Ang. i) hat keine Lösung. Betrachte

$$L = \{x : Ax = 0\}.$$

Dann ist $x_0 + L \cap \text{int } K = \emptyset$. Nach Satz 7 gibt es ein $a \in \mathbb{R}^n \setminus \{0\}$ und $\alpha \in \mathbb{R}$ mit

$$a^T x \geq \alpha \quad \forall x \in K \quad \text{und} \quad a^T x \leq \alpha \quad \forall x \in x_0 + L.$$

Dann ist $0 \geq \alpha$, ~~weil~~ weil $0 \in K$.

Anßerdem $a \in K^*$, weil $a^T(tx) \geq \alpha \quad \forall t > 0, x \in K$.

Gleichzeitig $a \in L^\perp$, weil $a^T(tx + x_0) \leq \alpha \quad \forall t \in \mathbb{R}, x \in L$,
d.h. $a^T x = 0 \quad \forall x \in L$.

Also ist $a = A^T y$ für ein $y \in \mathbb{R}^m$, weil $L^\perp = \{A^T y : y \in \mathbb{R}^m\}$

Somit $A^T y \in K^* \setminus \{0\}$. Desweiteren

$$y^T b = y^T A x_0 = a^T x_0 \leq \alpha \leq 0.$$

□

§ 5 Dualitätstheorie

$$(P) \quad p^* = \sup_{\substack{Ax=b \\ x \in K}} c^T x$$

$$(D) \quad d^* = \inf_{\substack{A^T y - c \in K^*}} y^T b$$

Def. 1 Die Differenz $d^* - p^*$ heißt Dualitätslücke
(duality gap)

Theorem 2 a) (Schwache Dualität)

Sei x zulässig für (P) und y zulässig für (D). Dann
 $c^T x \leq y^T b$. Insbesondere $p^* \leq d^*$.

b) (komplementärer Schlupf)

Sei x optimal für (P) und y optimal für (D). Dann

$$(A^T y)^T x = 0.$$

c) (Optimalitätsbedingung)

Sei x zulässig für (P), y zulässig für (D). Dann sind x, y
optimal, falls $(A^T y)^T x = 0$.

d) (starke Dualität).

Falls $d^* > -\infty$ und (D) strikt zulässig. Dann gibt es

eine zulässige Lösung x von (P) mit $p^* = c^T x$ und es ist $p^* = d^*$.

Falls $p^* < \infty$ und (P) strikt zulässig, dann gibt es eine zulässige Lösung y von (D) mit $d^* = y^T b$ und es ist $p^* = d^*$.

Bem.: c) heißt oft auch KKT-Bedingung
(KKT = Karush-Kuhn-Tucker)

d) heißt oft Slater-Bedingung.

Bew.:

a) - c) $y^T b - c^T x = y^T A x - c^T x = (A^T y - c)^T x \geq 0.$

d) Ang. $d^* > -\infty$ und (D) ist strikt zulässig

z.z.: ~~$\exists x^* \in \mathbb{R}^n$~~ : $\exists x^* \in \mathbb{R}^n: A x^* = b, c^T x^* \geq d^*$.

Falls $b = 0$, dann ist $d^* = 0$. Setze $x^* = 0$ und fertig.

Sei also $b \neq 0$ von nun an.

Betrachte die nicht-leere Menge

$$M = \{ A^T y - c : y \in \mathbb{R}^m, b^T y \leq d^* \}.$$

Es ist

$$M \cap \text{int } K^* = \emptyset.$$

[Ansonsten gäbe es ein $y \in \text{int } K^*$ mit $y^T b = d^*$.

Deshalb ein $\varepsilon > 0$ mit $B(y, \varepsilon) \subseteq K^*$. Für $y - \varepsilon b \in K^*$

$$\text{wäre dann } (y - \varepsilon b)^T b = y^T b - \varepsilon b^T b < d^*. \quad \curvearrowright]$$

Da M und $\text{int } K^*$ konvex sind, gibt es nach Satz 4.7

ein $x \in \mathbb{R}^n \setminus \{0\}$ mit

$$\sup_{z \in M} x^T z \leq \inf_{z \in \text{int } K^*} x^T z = \inf_{z \in K^*} x^T z. \quad (*)$$

Beh.: 1) $x \in K$

2) $\exists \mu > 0 : Ax = \mu b$ und $c^T x \geq \mu d^*$

3) $x^* = \frac{x}{\mu}$ ist optimal für (?) [folgt sofort

aus 1), 2)
und schwacher D.]

1) z.z.: $\inf_{z \in K^*} x^T z \geq 0$. Dann $x \in K^{**} = K$.

Ang. $\exists z \in K^*$ mit $x^T z < 0$. Dann $x^T t z \rightarrow -\infty$
für $t \rightarrow +\infty$. Widerspruch zu (*) und $d^* > -\infty$.

2) Weil $0 \in K^*$ folgt aus 1) : $\inf_{z \in K^*} x^T z = 0$.

Also in (*) $\sup_{z \in M} x^T z \leq 0$.

Also

$$b^T y \leq d^* \Rightarrow x^T (A^T y - c) \leq 0$$

$$\Leftrightarrow x^T A^T y \leq x^T c.$$

D.h. der Halbraum

$$\{y : b^T y \leq d^*\}$$

ist in dem Halbraum

$$\{y : (Ax)^T y \leq x^T c\}$$

enthalten. D.h. die Vektoren b und Ax sind lin. abh. und zeigen in die gleiche Richtung. Somit $\exists \mu \geq 0 : Ax = \mu b$ und $\mu d^* \leq x^T c$. Ang. $\mu = 0$. Da (D) strikt zulässig,

$\exists y' : A^T y' - c \in \text{int } K^*$. Nach A.2.1 ist

$$0 < (A^T y' - c)^T x = (y')^T Ax - c^T x = \cancel{\mu} (y')^T \mu b - c^T x = -c^T x$$

Also $c^T x < 0$. \searrow

□

Die 2. Beh. in d) folgt aus der 1. Beh. durch Dualität.

Kapitel II Semidefinite Optimierung

§ 1 Grundlagen

$$(P) \quad p^* = \sup_{X \in S_{\geq 0}^n} \langle C, X \rangle$$
$$\langle A_j, X \rangle = b_j, \quad j \in [m]$$

$$(D) \quad d^* = \inf_{y \in \mathbb{R}^m} y^T b$$
$$\sum_{j=1}^m y_j A_j - C \geq 0$$

wobei $C, A_1, \dots, A_m \in S^m$, $b_1, \dots, b_m \in \mathbb{R}$ gegeben.

Bem. 1 Lösungsverfahren für SDPs

- * SDPs sind i.A. effizient (in polynomieller Zeit) lösbar.
Durch Anwendung der Ellipsoidmethode und dem Theorem von Grötschel - Lovász - Schrijver (\rightarrow später mehr)
- * In der Praxis löst man SDPs mit Inneren Punkte Verfahren
Komplexität davon gut, aber nicht vollständig verstanden
(\rightarrow Seminar SoSe 2014).

* Online SDP Löser

google: neos sdp csdp

Dateiformat: sparse sdpa

↑ dünn besetzt, nur Matrixeinträge $\neq 0$ werden angegeben

Bsp.:

2 $\leftarrow m=2$

2 \leftarrow direktes Produkt von 2 PSD-Regeln

2 2 $\leftarrow S_{\geq 0}^2 \times S_{\geq 0}^2$

10.0 20.0 $\leftarrow b = (10.0, 20.0)$

$$\left. \begin{array}{l} 0 \ 1 \ 1 \ 1 \ 1.0 \\ 0 \ 1 \ 2 \ 2 \ 2.0 \\ 0 \ 2 \ 1 \ 1 \ 3.0 \\ 0 \ 2 \ 2 \ 2 \ 4.0 \\ 1 \ 1 \ 1 \ 1 \ 1.0 \\ 1 \ 1 \ 2 \ 2 \ 1.0 \\ 2 \ 1 \ 2 \ 2 \ 1.0 \\ 2 \ 2 \ 1 \ 1 \ 5.0 \\ 2 \ 2 \ 1 \ 2 \ 2.0 \\ 2 \ 2 \ 2 \ 2 \ 6.0 \end{array} \right\} \begin{array}{l} C = \begin{bmatrix} 1.0 & & & \\ & 2.0 & & \\ & & 3.0 & \\ & & & 4.0 \end{bmatrix} \\ A_1 = \begin{bmatrix} 1.0 & & & \\ & 1.0 & & \\ & & & \\ & & & \end{bmatrix} \\ A_2 = \begin{bmatrix} & & & \\ & 1.0 & & \\ & & 5.0 & 2.0 \\ & & 2.0 & 6.0 \end{bmatrix} \end{array}$$

(Pathologische) Beispiele

Bsp. 2 d^* nicht angenommen

$$p^* = \sup \langle E_{12}, X \rangle$$

$$X \in S_{\geq 0}^2$$

$$\langle E_{11}, X \rangle = 1, \langle E_{22}, X \rangle = 0$$

$$d^* = \inf y_1$$

$$y_1 E_{11} + y_2 E_{22} - E_{12} \geq 0$$

$$= \begin{bmatrix} y_1 & -\frac{1}{2} \\ -\frac{1}{2} & y_2 \end{bmatrix}$$

Hier ist $p^* = d^* = 0$, aber d^* wird nicht angenommen.

Problem: (P) nicht strikt zulässig.

Bsp. 3 positive Dualitätslücke

$$p^* = \sup \langle -E_{11} - E_{22}, X \rangle$$

$$X \in S_{\geq 0}^3$$

$$\langle E_{11}, X \rangle = 0,$$

$$\langle E_{22} + 2E_{13}, X \rangle = 1$$

$$d^* = \inf y_2$$

$$y_1 E_{11} + y_2 (E_{22} + 2E_{13}) -$$

$$(-E_{11} - E_{22}) \geq 0$$

"

$$\begin{bmatrix} y_1 + 1 & 0 & y_2 \\ 0 & y_2 + 1 & 0 \\ y_2 & 0 & 0 \end{bmatrix} \geq 0$$

Jede zulässige Lösung von (P) erfüllt $X_{11} = 0 = X_{13}$, $X_{22} = 1$.

Also $p^* = -1$. Jede zulässige Lösung von (D) erfüllt $y_2 = 0$, also

$$d^* = 0.$$

§ 2 Eigenwertoptimierung

Rayley-Ritz-Prinzip Sei $C \in S^n$ und seien $\lambda_{\max}(C)$,

$\lambda_{\min}(C)$ der größte, bzw. kleinste Eigenwert von C . Dann ist

$$\lambda_{\max}(C) = \max_{x \in \mathbb{R}^n, \{0\}} \frac{x^T C x}{x^T x} = \max_{x \in S^{n-1}} x^T C x,$$

$$\lambda_{\min}(C) = \min_{x \in \mathbb{R}^n, \{0\}} \frac{x^T C x}{x^T x} = \min_{x \in S^{n-1}} x^T C x, \text{ mit } S^{n-1} = \{x: x^T x = 1\}$$

Das sieht man leicht mit Hilfe von Lagrange-Multiplikatoren.

Berechnung der Gradienten: $\nabla x^T C x = 2 C x$, $\nabla x^T x = 2 x$.

Falls x^* den Wert $x^T C x$ unter der Nebenbedingung $x^T x = 1$ maximiert, dann gibt es ein λ mit

$$2 C x^* + \lambda 2 x^* = 0,$$

d. h. x^* ist Eigenvektor von C .

Satz 1 Sei $C \in S^n$. Dann gilt

$$\lambda_{\max}(C) = \max_{X \in S_{\geq 0}^n} \langle C, X \rangle = \min_y y \quad \begin{array}{l} y I_n - C \geq 0 \\ \langle I, X \rangle = 1 \end{array}$$

Entsprechendes für $\lambda_{\min}(C)$ durch Vertauschung von max & min.

Bew.: Es ist $d^* = \lambda_{\max}(C)$, weil für $x \in \mathbb{R}^n \setminus \{0\}$ gilt

$$0 \leq x^T (y I_n - C) x = y x^T x - x^T C x \Rightarrow y \geq \frac{x^T C x}{x^T x}.$$

Das primale SDP ist strikt zulässig: $\frac{1}{n} I_n$. Es ist $p^* < \infty$, weil die Einträge von zulässiger Matrix X im Intervall $[-1, +1]$ liegen. Nach Theorem I.5.2 d) folgt $p^* = d^*$ und d^* wird angenommen.

Nachtrag zu II.1 Grundlagen

Satz 3 Sei $X \in S^n$. Die folgenden Aussagen sind äquivalent:

- X ist positiv semidefinit.
- Der kleinste Eigenwert von X ist ≥ 0 .
- $\exists L \in \mathbb{R}^{n \times k}$ mit $X = LL^T$, eine Cholesky-Zerlegung von X .
- $\exists v_1, \dots, v_n \in \mathbb{R}^k$ mit $X_{ij} = v_i^T v_j$, eine Gram-Darstellung von X .
- Alle Hauptminoren von X sind ≥ 0 .

Bew.: \rightarrow Lineare Algebra.

Zusatz: Falls X positiv definit, dann ist in: b) kl. EW > 0

- $L \in \mathbb{R}^{n \times n}$ mit $\text{Rank } L = n$, d) v_1, \dots, v_n sind lin. unabh.,
- die führenden Hauptminoren sind > 0 .

Zurück zur Eigenwertoptimierung

Def. 2 Sei $C \subseteq \mathbb{R}^n$ eine konvexe Menge. Ein Punkt $x \in C$ heißt Extrempunkt, falls für alle $y, z \in C$, $\alpha \in (0, 1)$ mit $x = \alpha y + (1 - \alpha)z$ folgt $x = y = z$.

Notation: $\text{ext}(C) = \{x : x \in C \text{ Extrempunkt von } C\}$.

Satz 3 (Minkowski; Krein-Milman)

Sei $C \subseteq \mathbb{R}^n$ eine kompakte und konvexe Menge. Dann

$$C = \text{conv}(\text{ext}(C)).$$

Bew.: " \supseteq " ✓

" \subseteq ": per Induktion nach $\dim C$.

$\dim C = 0$: Dann $C = \{x\}$. ✓


$\dim C > 0$: 1. Fall $x \in \partial C$

Dann \exists nach Satz I.4.7 eine Stützhyperebene H an C durch x . Betrachte $F = H \cap C$. Dies ist konvex u. kompakt, $\dim F < \dim C$. Nach I.V. ist $x \in \text{conv}(\text{ext}(F))$. Da $\text{ext}(F) \subseteq \text{ext}(C)$, folgt die Beh.

2. Fall $x \notin \partial C$.

Dann ist der Schnitt einer Geraden durch x mit C ein Liniensegment $[y, z]$ mit $y, z \in \partial C$. Nach 1.

sind $y, z \in \text{conv}(\text{ext}(C))$, also auch $x \in \text{conv}(\text{ext}(C))$.



Satz 4 (Fan)

Sei $C \in S^n$ mit Eigenwerten $\lambda_1 \geq \dots \geq \lambda_n$. Dann ist

$$\lambda_1 + \dots + \lambda_k = \max \left\{ \langle C, X \rangle : X \in S^n, \text{Tr}(X) = k, \right. \\ \left. I_n \geq X \geq 0 \right\}$$

$$= \max \left\{ \langle C, YY^T \rangle : Y \in \mathbb{R}^{n \times k}, Y^T Y = I_k \right\}.$$

Lemma 5 Definieren

$$K_1 = \left\{ X \in S^n : \text{Tr}(X) = k, I_n \geq X \geq 0 \right\},$$

$$K_2 = \left\{ YY^T : Y \in \mathbb{R}^{n \times k}, Y^T Y = I_k \right\}.$$

Es ist $\text{ext}(K_1) = K_2$. Also $\text{conv}(K_2) = K_1$.

Bew.: Sei $P \in O(n)$. Dann ist $X \in K_1 \iff PXP^T \in K_1$ und

$$X \in \text{ext}(K_1) \iff PXP^T \in \text{ext}(K_1).$$

Definiere das Polytop $Q = \{x \in [0, 1]^n : e^T x = k\}$, wobei

$e^T = [1, \dots, 1]^T$. Schreibe $X \in S^n$ als $X = PDP^T$, mit $P \in O(n)$

und D Diagonalmatrix. Dann ist $X \in K_1 \iff D \in Q$ und

$X \in \text{ext}(K_1) \iff D \in \text{ext}(Q)$. Nun ist $\text{ext}(Q) = \{x \in \{0, 1\}^n :$

$e^T x = k\}$, also ist $X_1 \in \text{ext}(K_1) \iff X$ hat genau k Eigenwerte,
die gleich 1 sind und $n-k$ Eigenwerte, die gleich 0 sind, d.h.

X ist eine Projektion auf einen k -dim. UVR. □

Bew.: (von Satz 4)

Die beiden Maxima stimmen überein: Folgt unmittelbar aus

A 4.3: Sei $C \subseteq \mathbb{R}^n$, $C \neq \emptyset$, konvex u. kompakt, sei $c \in \mathbb{R}^n$,

$$\text{dann } \max \{ c^T x : x \in C \} = \max \{ c^T x : x \in \text{ext } C \}.$$

Sei p^* das Maximum.

$$\underline{\lambda_1 + \dots + \lambda_k \leq p^*}: \quad C = \sum_{i=1}^n \lambda_i u_i u_i^T \text{ Spektralzerlegung von } C.$$

Definiere $Y = [u_1, \dots, u_k] \in \mathbb{R}^{n \times k}$. Dann ist $YY^T \in K_2$ und

$$\langle C, YY^T \rangle = \lambda_1 + \dots + \lambda_k.$$

$$\underline{\lambda_1 + \dots + \lambda_k \geq p^*}: \quad C = PDPT^T, \quad P \in O(n), \quad D = \text{diag}(\lambda_1, \dots, \lambda_n)$$

Spektralzerlegung von C . Dann ist für $YY^T \in K_2$

$$\begin{aligned} \langle C, YY^T \rangle &= \text{Tr}(CYY^T) = \text{Tr}(PDPT^TYY^T) = \text{Tr}(DPT^TYY^TP) \\ &= \langle D, P^T Y (P^T Y)^T \rangle, \end{aligned}$$

wobei $P^T Y (P^T Y)^T \in K_2$. Also

$$p^* = \max \left\{ \langle D, M \rangle = \sum_{i=1}^n \lambda_i M_{ii} : M \in K_2 \right\}.$$

Nun ist für $M \in K_2$ die Diagonale (M_{11}, \dots, M_{nn}) im Polytop Q ,

$$Q = \{ x \in [0, 1]^n : e^T x \leq k \}, \text{ d.h.}$$

$$p^* \leq \max \left\{ \sum_{i=1}^n \lambda_i x_i : x \in Q \right\} = \lambda_1 + \dots + \lambda_k. \quad \square$$

§ 3 Relaxierung quadratischer Programme

Def. 1 Ein quadratisches Programm (QP) ist von der Form

$$\begin{aligned} \max \quad & x^T Q_0 x + b_0^T x + d_0 \\ & x \in \mathbb{R}^n \\ & x^T Q_j x + b_j^T x + d_j = 0 \quad \text{für } j \in [m], \end{aligned}$$

wobei $Q_0, Q_1, \dots, Q_m \in S^m$, $b_0, \dots, b_m \in \mathbb{R}^n$, $d_0, \dots, d_m \in \mathbb{R}$ gegeben sind.

Mit quadratischen Programmen kann man sehr viele Optimierungsprobleme modellieren, z. B. 0/1 - Bedingungen:

$$x_j^2 - x_j = 0$$

oder -1/+1 - Bedingungen

$$x_j^2 - 1 = 0.$$

Im allgemeinen sind QP keine konvexen Programme und es ist NP-schwer eine optimale Lösung zu finden.

Bsp. 2 (MAX CUT)

Sei $G = (V, E)$ ein ungerichteter Graph und $w = (w_{ij}) \in \mathbb{R}_{\geq 0}^E$ eine Gewichtsfnkt.

Eine Teilmenge $S \subseteq V$ definiert einen Schnitt $\delta_G(S) \subseteq E$:


$$\delta_G(S) = \{ \{i,j\} \in E : |\{i,j\} \cap S| = 1 \}.$$

Das Gewicht des Schnittes $\delta_G(S)$ ist

$$w(\delta_G(S)) = \sum_{\{i,j\} \in \delta_G(S)} w_{ij},$$

und das MAX CUT-Problem fragt nach einem Schnitt mit maximalem Gewicht

$$mc(G, w) = \max_{S \subseteq V} w(\delta_G(S)).$$



$$mc(G, w) = 4$$

Formulierung von MAX CUT als QP:

$$\max \frac{1}{2} \sum_{\{i,j\} \in E} w_{ij} (1 - x_i x_j) = mc(G, w)$$

$$x \in \mathbb{R}^V$$

$$x_i^2 - 1 = 0 \quad \text{für } i \in V.$$

Wir werden später sehen, dass MAX CUT NP-schwer ist, also auch QP.


Bsp. 3 (Unabhängigkeitssatz)

$G = (V, E)$. $S \subseteq V$ heißt unabhängig, falls für alle $i, j \in S$

stets $\{i, j\} \notin E$ gilt. Die Unabhängigkeitszahl von G ist definiert als

$$\alpha(G) = \max \{ |S| : S \subseteq V \text{ unabhängig} \}$$

Berechnung von α ist auch NP-schwer.



$$\alpha(G) = 4$$

Formulierungen von α als QP.

$$\alpha(G) = \max \sum_{i \in V} x_i$$

$$x \in \mathbb{R}^V, s \in \mathbb{R}^E$$

$$x_i^2 - x_i = 0 \quad \text{für } i \in V$$

$$s_{ij}^2 + x_i + x_j - 1 = 0 \quad \text{für } \{i, j\} \in E.$$

$$= \max \sum_{i \in V} x_i^2$$

$$x \in \mathbb{R}^V$$

$$x_i^2 - x_i = 0 \quad \text{für } i \in V$$

$$x_i x_j = 0 \quad \text{für } \{i, j\} \in E.$$

Satz 4 (SDP-Relaxierung von QP).

Es ist $q_p \leq sdp$, wobei

$$q_p = \max_{x \in \mathbb{R}^n} x^T A_0 x + b_0^T x + \alpha_0$$

$$x^T A_j x + b_j^T x + \alpha_j = 0 \quad \text{für } j \in [m]$$

und

$$\text{sdp} = \inf_{\gamma_0, \dots, \gamma_m} \gamma_0$$

$$\gamma_0, \dots, \gamma_m \in \mathbb{R}$$

$$\gamma_0 \begin{bmatrix} 1 & 0 \\ 0 & 0 \end{bmatrix} + \sum_{j=1}^m \gamma_j \begin{bmatrix} \alpha_j & \frac{1}{2} b_j^T \\ \frac{1}{2} b_j & Q_j \end{bmatrix} - \begin{bmatrix} \alpha_0 & \frac{1}{2} b_0^T \\ \frac{1}{2} b_0 & Q_0 \end{bmatrix} \in S_{\geq 0}^{n+1}.$$

Bew.: Es gilt

$$x^T Q_j x + b_j^T x + \alpha_j = \left\langle \begin{bmatrix} \alpha_j & \frac{1}{2} b_j^T \\ \frac{1}{2} b_j & Q_j \end{bmatrix}, \begin{bmatrix} 1 & x^T \\ x & x x^T \end{bmatrix} \right\rangle$$

und $\begin{bmatrix} 1 & x^T \\ x & x x^T \end{bmatrix} \in S_{\geq 0}^{n+1}$, da $\begin{bmatrix} 1 & x \\ x & x x^T \end{bmatrix} \begin{bmatrix} 1 \\ x \end{bmatrix} = \begin{bmatrix} 1 & x^T \\ x & x x^T \end{bmatrix}$.

Also

$$q_p \leq \sup_{X \in S_{\geq 0}^{n+1}} \left\langle \begin{bmatrix} \alpha_0 & \frac{1}{2} b_0^T \\ \frac{1}{2} b_0 & Q_0 \end{bmatrix}, X \right\rangle$$

$$X \in S_{\geq 0}^{n+1}$$

$$\left\langle \begin{bmatrix} \alpha_j & \frac{1}{2} b_j^T \\ \frac{1}{2} b_j & Q_j \end{bmatrix}, X \right\rangle = 0 \quad \text{für } j \in [m].$$

Dualisieren liefert nun die Beh. (zusammen mit schwacher Dualität). □

Bem. - Falls man im Maximierungsproblem zusätzlich fordert, dass $\text{rank } X = 1$ ist, hätte man $q_p = \text{sup}$. Man "relaxiert" diese Bedingung in Satz 4.

- Vorteile von sdP:
 - effizient berechenbar
 - einfache Methode, um obere Schranken für q_p zu finden.

Zur Komplexität von MAX CUT

Def. 5 MAX CUT als Entscheidungsproblem

Gegeben: $G = (V, E)$ Graph, $w \in \mathbb{Z}_{\geq 0}^E$, $k \in \mathbb{N}$.

Entscheide: Gibt es einen Schnitt $S_G(s)$ mit $w(S_G(s)) \geq k$.

Def. 6 PARTITION

Gegeben: $a_1, \dots, a_n \in \mathbb{N}$

Entscheide: Gibt es ein $S \subseteq [n]$ mit

$$\sum_{i \in S} a_i = \sum_{i \notin S} a_i.$$

Es ist bekannt (siehe Klamiker Garey - Johnson), dass PARTITION NP-vollständig ist.

Satz 7 MAX CUT ist NP-vollständig.

Bew.: Klar: MAX CUT \in NP. [Angabe von $S \subseteq V$ genügt, um in polynomieller Zeit zu verifizieren, dass $S_G(s) \geq k$].

zu zeigen: ~~MAX CUT \leq_p PARTITION, d.h.~~

PARTITION \leq_p MAX CUT, d.h. falls MAX CUT \in P, dann auch PARTITION \in P. Gegeben seien $a_1, \dots, a_n \in \mathbb{N}$.

Betrachte $G = K_n$ den vollständigen Graph auf n Knoten mit $w_{ij} = a_i a_j$, $\{i, j\} \in E$.

Definiere $\sigma = \sum_{i=1}^n a_i$ und $k = \sigma^2/4$. Für $S \subseteq [n]$

definiere $a(S) = \sum_{i \in S} a_i$. Dann gilt

$$w(\mathcal{G}_G(S)) = \sum_{i \in S, j \notin S} w_{ij} = \sum_{i \in S, j \notin S} a_i a_j = \left(\sum_{i \in S} a_i \right) \left(\sum_{j \notin S} a_j \right)$$

$$= a(S) (\sigma - a(S)) \leq \sigma^2/4 = k$$

mit Gleichheit gdw. $a(S) = \frac{\sigma}{2}$, d.h. $a(S) = a([n] \setminus S)$.

Es gibt also einen Schnitt mit Gewicht $\geq k$ gdw.

a_1, \dots, a_n partitioniert werden kann. \square

Approximationen von MAXCUT:

Wdh:

• MAXCUT: Sei $G=(V,E)$ ein Graph mit Gewichten $w \in \mathbb{Z}_+^E$.
Für festes $k \in \mathbb{N}$, entscheide ob es einen Schnitt mit Gewicht $\geq k$ gibt.

• Formulierung als quadratisches Programm:

$$\boxed{\text{mc}(G,w)} = \max \frac{1}{2} \sum_{\{i,j\} \in E} w_{ij} (1 - x_i x_j)$$
$$x \in \mathbb{R}^V \quad (n := |V|)$$
$$x_i^2 = 1 \quad \forall i \in [n]$$

• $X := xx^T \Rightarrow X_{ij} = x_i x_j$ und $X \in S_{\geq 0}^n$.

$$\Rightarrow \boxed{\text{sdp}(G,w)} = \max \frac{1}{2} \sum_{\{i,j\} \in E} w_{ij} (1 - X_{ij})$$
$$X_{ii} = 1$$
$$X \in S_{\geq 0}^n \quad (\text{relaxiere rank}(x))$$

$$\Rightarrow \text{mc}(G,w) \leq \text{sdp}(G,w)$$

Wieviel verlieren wir durch die Relaxierung?

Satz 8 (Goemans, Williamson - 1995)

Sei $G = (V, E)$ Graph mit nicht-negativen Gewichten
 $w \in \mathbb{R}_+^{|E|}$, dann gilt:

$$\text{Sdp}(G, w) \geq \text{mc}(G, w) \geq 0.878... \cdot \text{Sdp}(G, w).$$

Der Beweis liefert einen randomisierten Algorithmus
mit Approximationsfaktor $\geq 0.878... :$

1. Löse $\text{Sdp}(G, w)$. Sei X eine optimale Lösung.
2. Finde eine Cholesky-Zerlegung von X mit
Einheitsvektoren $v_i \in \mathbb{R}^n$, $i \in [n]$, so dass
 $X_{ij} = v_i^T v_j$, $i, j \in [n]$.
3. Wähle $r \in \mathbb{R}^n$, $\|r\|=1$, gemäß einer Zufallsverteilung auf
der Einheitskugel, die invariant unter Rotationen
ist.
4. Definiere einen Schnitt \mathcal{S} durch
$$i \in \mathcal{S} \Leftrightarrow \text{sign}(v_i^T r) \geq 0 \quad \forall i \in [n]$$

(also $x_i := \text{sign}(v_i^T r)$)
5. Teste ob $w(\mathcal{S}) \geq 0.878... \cdot \text{Sdp}(G, w)$.
Falls nicht, gehe zurück zu Schritt 3.

Schritte 3. und 4. werden auch als Methode des randomisierten Rundens (randomized rounding procedure) bezeichnet.

Wirden zeigen: $\mathbb{E}[w(S_n(s))] \geq 0.878 \dots \cdot \text{sdp}(G, w)$

\Rightarrow keine Endlos-Schleife.

Allgemeiner: Mit hoher W'keit finden wir schnell einen ausreichend großen Schnitt.

Lemma 9 (Grothendieck-Identität)

Seien $u, v \in \mathbb{R}^d$ Einheitsvektoren, und sei $r \in \mathbb{R}^d$, $\|r\|=1$, gemäß einer Zufallsverteilung gewählt, die invariant unter Rotationen ist.

Dann gilt:

$$1. \mathbb{P}[\text{sign}(u^T r) \neq \text{sign}(v^T r)] = \frac{\arccos(u^T v)}{\pi}$$

$$2. \mathbb{E}[\text{sign}(u^T r) \text{sign}(v^T r)] = \frac{2}{\pi} \arcsin(u^T v)$$


Beweis:

1. Wähle r so, dass u, v und r auf einer Ebene liegen (Eig. der ZV).

$\Rightarrow r$ kann mit der Gleichverteilung auf dem Kreis definiert werden.

\Rightarrow W'keit für $\text{sign}(u^T r) \neq \text{sign}(v^T r)$ hängt nur

Vom Winkel zwischen u und v ab:



$$\Rightarrow P[\text{Sign}(u^T r) \neq \text{Sign}(v^T r)] = 2 \cdot \frac{\arccos(u^T v)}{2\pi} = \frac{\arccos(u^T v)}{\pi}$$

$$2. \quad E[\text{Sign}(u^T r) \text{Sign}(v^T r)] = (+1) P[\text{Sign}(u^T r) = \text{Sign}(v^T r)] + (-1) P[\text{Sign}(u^T r) \neq \text{Sign}(v^T r)]$$

$$= 1 - 2 P[\text{Sign}(u^T r) \neq \text{Sign}(v^T r)] = 1 - 2 \frac{\arccos(u^T v)}{\pi}$$

$$\arcsin t + \arccos t = \frac{\pi}{2} \quad \downarrow = \quad \frac{\pi - 2(\frac{\pi}{2} - \arcsin(u^T v))}{\pi} = \frac{2}{\pi} \arcsin(u^T v) \quad \square$$

Woher kommt die Konstante in Satz 8?

Lemma 10: Für alle $t \in [-1, 1)$ gilt

$$\frac{2}{\pi} \frac{\arccos t}{1-t} \geq 0,878\dots$$

"Sieht man" am Graph der Funktion: Konvex auf dem Intervall, und minimal ungefähr bei $-0,69$

Beweis von Satz 8: Sei X eine optimale Lösung von

$$\text{sdp}(G, w) \text{ und } v_1, \dots, v_n \text{ Einheitsvektoren mit } X_{ij} = v_i^T v_j.$$

Sei $\delta_n(S)$ der Schnitt, der in den Schritten 3. und 4. konstruiert wurde.

Dann gilt:

$$\mathbb{E}[w(\delta_a(S))] = \sum_{\{i,j\} \in E} w_{ij} P[\{i,j\} \text{ ist im Schnitt}]$$

$$= \sum_{\{i,j\} \in E} w_{ij} P[\text{Sign}(v_i^T r) \neq \text{Sign}(v_j^T r)]$$

$$= \sum_{\{i,j\} \in E} w_{ij} \frac{\arccos(v_i^T v_j)}{\pi}$$

$$= \sum_{\{i,j\} \in E} w_{ij} \left(\frac{1 - v_i^T v_j}{2} \right) \cdot \left(\frac{2}{\pi} \frac{\arccos(v_i^T v_j)}{1 - v_i^T v_j} \right)$$

$$v_i^T v_j = 1 \Rightarrow \arccos(v_i^T v_j) = 0 \quad v_i^T v_j \neq 1$$

$$\geq \sum_{\{i,j\} \in E} w_{ij} \left(\frac{1 - v_i^T v_j}{2} \right) \cdot 0,878\dots$$

$$= 0,878\dots \cdot \text{sdp}(G, w).$$

Da $\text{mc}(G, w) \geq \mathbb{E}[w(\delta_a(S))]$, sind wir fertig. \square

Bemerkungen:

- Eine unter Rotationen invariante Verteilung kann wie folgt definiert werden:

$$N(0,1) \text{ mit Dichte } f(x) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2}$$

Wähle x_1, \dots, x_n unabh. nach $N(0,1)$

$$\Rightarrow r = \frac{1}{\sqrt{x_1^2 + \dots + x_n^2}} \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix} \in S^{n-1} \text{ ist invariant unter Rotationen gewählt.}$$

- Der Algorithmus kann modifiziert werden, so dass er deterministisch ist und den gleichen Approximationsfaktor liefert.

Nesterovs Approximationsalgorithmus

Sei $G = (V, E)$ Graph mit Gewichten w .

Wir definieren die Laplace-Matrix zu G und w durch

$$(L_w)_{ij} = \begin{cases} \sum_{k: \{i,k\} \in E} w_{ik} & \text{falls } i=j \\ -w_{ij} & \text{falls } \{i,j\} \in E \\ 0 & \text{sonst} \end{cases}$$

Dann ist $L_w \in S^n$.

Lemma 11:

(a) Für $x \in \{-1, 1\}^n$ gilt

$$\frac{1}{4} x^T L_w x = \frac{1}{2} \sum_{\{i,j\} \in E} w_{ij} (1 - x_i x_j)$$

(b) Falls $w \geq 0$, dann ist $L_w \succeq 0$

Beweis: (a): Ausrechnen;

(b) folgt aus (a). □

Dann gilt:

$$mc(G, w) = \max_{\substack{x \in \mathbb{R}^n \\ x_i^2 = 1}} \frac{1}{4} x^T L_w x$$

und

$$Solp(G, w) = \max_{\substack{X \in S_{\succeq 0}^n \\ X_{ii} = 1}} \frac{1}{4} \langle L_w, X \rangle$$

Für $w \geq 0$ taucht in beiden Formulierungen die pos. semidefinite Matrix $\frac{1}{4}Lw$ auf.

→ Verallgemeinerung:

Für $A \in S^n$ definieren wir

$$\boxed{qp(A)} = \max \sum_{i,j=1}^n A_{ij} x_i x_j$$
$$x \in \mathbb{R}^n$$
$$x_i^2 = 1 \quad \forall i \in [n]$$

und

$$\boxed{sdp(A)} = \max \langle A, X \rangle$$
$$X_{ii} = 1$$
$$X \in S_{\geq 0}^n$$

$$\Rightarrow qp\left(\frac{1}{4}Lw\right) = mc(b, w).$$

Wie zuvor: $qp(A) \leq sdp(A)$ (Relative Relaxierung von X)

Bekommen wir immer noch eine untere Schranke mit konstantem Faktor?

Wieder: Randomisiertes Runden.

Lemma 12: Sei $X \in S^n$ und definiere \tilde{X} durch

$$\tilde{X}_{ij} = \arcsin X_{ij} - X_{ij}$$

Dann gilt:

$$X \succeq 0 \Rightarrow \tilde{X} \succeq 0$$

Beweis: Falls $X \succeq 0$, dann für $k \in \mathbb{Z}_+$ auch die Matrix mit den Einträgen X_{ij}^k (Aufgabe)

$$\arcsin t = t + \left(\frac{1}{2}\right) \frac{t^3}{3} + \left(\frac{1 \cdot 3}{2 \cdot 4}\right) \frac{t^5}{5} + \dots$$

Alle Koeffizienten sind nicht-negativ

\Rightarrow Limesbildung liefert die Aussage \square

Satz 13: Für $A \in S_{\geq 0}^n$ gilt

$$\text{sdp}(A) \geq \text{qp}(A) \geq \frac{2}{\pi} \text{sdp}(A)$$

$$\left(\frac{2}{\pi} = 0,636\dots\right)$$

Beweis: Sei X eine optimale Lösung von $\text{sdp}(A)$ und

v_1, \dots, v_n Einheitsvektoren mit $X_{ij} = v_i^T v_j$. Wähle

wie zuvor $r \in \mathbb{R}^n$, $\|r\|=1$ und setze $x_i = \text{sign}(v_i^T r)$

$$\Rightarrow \mathbb{E} \left[\sum_{i,j=1}^n A_{ij} x_i x_j \right] = \left\langle A, \left(\mathbb{E} [x_i x_j] \right)_{i,j=1}^n \right\rangle$$

$$\begin{aligned}
\text{Lemma 9(2)} & \searrow = \frac{2}{\pi} \langle A, (\arcsin(v_i^\top v_j))_{i,j=1}^n \rangle \\
& = \frac{2}{\pi} \langle A, (\arcsin X_{ij})_{i,j=1}^n \rangle \\
& = \frac{2}{\pi} \langle A, X \rangle + \underbrace{\frac{2}{\pi} \langle A, (\arcsin X_{ij} - X_{ij})_{i,j=1}^n \rangle}_{\geq 0} \\
& \geq \frac{2}{\pi} \langle A, X \rangle = \frac{2}{\pi} \text{sdp}(A). \quad \square
\end{aligned}$$

II.4 Goethendieck - Ungleichung

(Original-Kontext von Lemma 9)

Für $A \in \mathbb{R}^{m \times n}$ definiere das quadratische Programm

$$\begin{aligned}
\|A\|_{\infty \rightarrow 1} & := \max \sum_{i=1}^m \sum_{j=1}^n A_{ij} x_i y_j \\
& x \in \mathbb{R}^m, y \in \mathbb{R}^n \\
& x_i^2 = 1 \quad \forall i \in [m] \\
& y_j^2 = 1 \quad \forall j \in [n]
\end{aligned}$$

(Notation wegen Operatornorm für Operatoren $A: \ell_\infty^n \rightarrow \ell_1^m$)

Dann ist die semidefinite Relaxierung gegeben durch

$$\begin{aligned}
\text{sdp}_{\infty \rightarrow 1}(A) & := \max \sum_{i=1}^m \sum_{j=1}^n A_{ij} u_i^\top v_j \\
& u_i \in \mathbb{R}^{m+n}, v_j \in \mathbb{R}^{m+n} \\
& \|u_i\| = 1 \quad \forall i \in [m] \\
& \|v_j\| = 1 \quad \forall j \in [n]
\end{aligned}$$

Satz 1 (Grothendieck-Ungleichung)

Es gibt eine Konstante K , so dass für alle $A \in \mathbb{R}^{m \times n}$ gilt:

$$\|A\|_{\infty \rightarrow 1} \leq \text{Sdp}_{\infty \rightarrow 1}(A) \leq K \cdot \|A\|_{\infty \rightarrow 1}.$$

Eine fundamentale Ungleichung in der Theorie der Banach-Räume, und seit einigen Jahren auch immer wichtiger ausserhalb der Funktionalanalysis.

Bekannt: Das kleinstmögliche K (Grothendieck-Konstante K_G) ist zwischen 1,676... und 1,782...

Wenden hier die obere Schranke

$$K_G \leq \frac{\pi}{2 \ln(1+\sqrt{2})} = 1,782\dots$$

Zeigen.

§ 4 Grothendieck - Ungleichung

$$A \in \mathbb{R}^{m \times n}$$

$$\|A\|_{\infty \rightarrow 1} = \max \sum_{i=1}^m \sum_{j=1}^n A_{ij} x_i y_j$$

$$x \in \mathbb{R}^m, y \in \mathbb{R}^n$$

$$x_i^2 = 1 \quad i \in [m]$$

$$y_j^2 = 1 \quad j \in [n]$$

ist ein quadratisches Programm.

[Aufgabe 6.3 : $\|A\|_{\infty \rightarrow 1} = mc(b, w)$ für passendes b, w
→ Berechnung von $\|A\|_{\infty \rightarrow 1}$ ist NP-schwer].

Semidefinite Relaxierung:

$$\text{sdp}_{\infty \rightarrow 1}(A) = \max \sum_{i=1}^m \sum_{j=1}^n A_{ij} u_i^T v_j$$

$$u_i \in \mathbb{R}^{m+n}, v_j \in \mathbb{R}^{m+n}$$

$$\|u_i\| = 1 \quad i \in [m]$$

$$\|v_j\| = 1 \quad j \in [n]$$

Satz 1 (Grothendieck - Ungleichung)

∃ Konstante K : $\forall A \in \mathbb{R}^{m \times n}$:

$$\|A\|_{\infty \rightarrow 1} \leq \text{sdp}_{\infty \rightarrow 1}(A) \leq K \|A\|_{\infty \rightarrow 1}$$

Kleinstmögliche K heißt Grothendieck Konstante K_G . Man weiß z. Zt. nur, dass $K_G \in (1,676\dots, 1,782\dots)$.

Wir zeigen $K_G \leq \frac{\pi}{2 \ln(1+\sqrt{2})} = 1,782\dots$

Bew. (nach Krivine 1979)

Wieder: Approximationsalg. mit randomisiertem Runden.

1. Löse $\text{sdp}_{\infty \rightarrow 1}(A)$. Seien $\mu_1, \dots, \mu_m, \nu_1, \dots, \nu_n \in S^{m+n-1}$ optimale Einheitsvektoren.

2. Krivines Trick (Lemma 2): Verwende diese Vektoren, um neue Einheitsvektoren $\mu'_1, \dots, \mu'_m, \nu'_1, \dots, \nu'_n \in S^{m+n-1}$ zu konstruieren.

3. Wähle $\pi \in S^{m+n-1}$ zufällig.

4. Runden: $x_i = \text{sign}(\pi^T \mu'_i) \quad i \in [m]$
 $y_j = \text{sign}(\pi^T \nu'_j) \quad j \in [n].$

Erwartete Qualität der Lösung:

$$\begin{aligned} \|A\|_{\infty \rightarrow 1} &\geq \mathbb{E} \left[\sum_{i=1}^m \sum_{j=1}^n A_{ij} x_i y_j \right] \\ &= \sum_{i=1}^m \sum_{j=1}^n A_{ij} \mathbb{E} \left[\text{sign}(\pi^T \mu'_i) \text{sign}(\pi^T \nu'_j) \right] \end{aligned}$$

$$\stackrel{\text{Lemma 2}}{=} \sum_{i=1}^m \sum_{j=1}^n A_{ij} \beta \mu_i^T \nu_j = \beta \text{sdp}_{\infty \rightarrow 1}(A)$$

wobei $\beta = \frac{2 \ln(1+\sqrt{2})}{\pi}$, also $k_0 \leq \beta^{-1}$.

Lemma 2 (Krivins Trick)

Seien $u_1, \dots, u_m, v_1, \dots, v_n \in S^{m+n-1}$. Dann gibt es $u'_1, \dots, u'_m, v'_1, \dots, v'_n \in S^{m+n-1}$, so dass

$$E[\text{sign}(u_i^T u'_j) \text{sign}(v_i^T v'_j)] = \beta u_i^T v_j,$$

wobei $\beta = \frac{2}{\pi} \ln(1+\sqrt{2}) = 0,561\dots$

Kurzer Exkurs: Tensorprodukte

\mathbb{R}^n ist n -dim. euklidischer Vektorraum mit Skalarprodukt $x^T y$ und Orthonormalbasis e_1, \dots, e_n .

Das k -fache Tensorprodukt $(\mathbb{R}^n)^{\otimes k}$ ist n^k -dim. eukl. VR mit ONB $e_{i_1} \otimes \dots \otimes e_{i_k}$, $i_j \in \{1, \dots, n\}$ mit Skalarprodukt

$$(e_{i_1} \otimes \dots \otimes e_{i_k})^T (e_{j_1} \otimes \dots \otimes e_{j_k}) = \prod_{r=1}^k e_{i_r}^T e_{j_r}.$$

Sei $v \in \mathbb{R}^n$ durch $v = v_1 e_1 + v_2 e_2 + \dots + v_n e_n$ gegeben.

Dann $v^{\otimes k} \in (\mathbb{R}^n)^{\otimes k}$ mit

$$v^{\otimes k} = (v_1 e_1 + \dots + v_n e_n) \otimes \dots \otimes (v_1 e_1 + \dots + v_n e_n)$$

$$\stackrel{\text{distributiv ausrechnen}}{=} \sum_{i_1, \dots, i_k} v_{i_1} \dots v_{i_k} e_{i_1} \otimes \dots \otimes e_{i_k}.$$

Für $v, w \in \mathbb{R}^n$ gilt dann

$$(v^{\otimes k})^T w^{\otimes k} = (v^T w)^k.$$

Bew. (Lemma 2)

Definiere die Fkt. $E: [-1, +1] \rightarrow [-1, +1]$ durch

$E(t) = \frac{2}{\pi} \arcsin t$. Nach der Identität von Grothendieck

(Lemma 3.9) ist

$$E((u_i')^T v_j') = \mathbb{E}[\text{sign}(r^T u_i) \text{sign}(r^T v_j')] \stackrel{!}{=} \beta u_i'^T v_j'.$$

Idee: Um u_i', v_j' und β zu finden, invertiere die Fkt. E :

$$(u_i')^T v_j' = E^{-1}(\beta u_i'^T v_j')$$

und benutze dazu die Reihenentwicklung

$$E^{-1}(t) = \sum_{r=0}^{\infty} g_{2r+1} t^{2r+1},$$

die für alle $t \in [-1, +1]$ gilt. [Da E eine ungerade Fkt.

ist, $E(-t) = -E(t)$, ist

E^{-1} ebenfalls ungerade].

Dazu definiere den unendlich-dimensionalen Hilbertraum

$$H = \bigoplus_{r=0}^{\infty} (\mathbb{R}^{m+1})^{\otimes 2r+1}.$$

Definiere $u_i', v_j' \in \mathbb{H}$ komponentenweise

$$(u_i')_\tau = \text{sign}(g_{2\tau+1}) \sqrt{|g_{2\tau+1}| \beta^{2\tau+1}} u_i^{\otimes 2\tau+1}$$

$$(v_j')_\tau = \sqrt{|g_{2\tau+1}| \beta^{2\tau+1}} v_j^{\otimes 2\tau+1}$$

Dann

$$(u_i')^T v_j' = \sum_{\tau=0}^{\infty} g_{2\tau+1} \beta^{2\tau+1} (u_i^T v_j)^{2\tau+1} = E^{-1}(\beta u_i^T v_j)$$

und

$$1 = (u_i')^T u_i = (v_j')^T v_j = \sum_{\tau=0}^{\infty} |g_{2\tau+1}| \beta^{2\tau+1},$$

was β definiert.

Bestimmung von β :

$$E(t) = \frac{2}{\pi} \arcsin t$$

$$E^{-1}(t) = \sin\left(\frac{\pi}{2} t\right) = \sum_{\tau=0}^{\infty} \underbrace{\frac{(-1)^{2\tau+1}}{(2\tau+1)!} \left(\frac{\pi}{2}\right)^{2\tau+1}}_{g_{2\tau+1}} t^{2\tau+1}$$

Also

$$1 = \sum_{\tau=0}^{\infty} \left| \frac{(-1)^{2\tau+1}}{(2\tau+1)!} \left(\frac{\pi}{2}\right)^{2\tau+1} \right| \beta^{2\tau+1} = \sinh\left(\frac{\pi}{2} \beta\right)$$

D.h.

$$\beta = \frac{2}{\pi} \text{arsinh } 1 = \frac{2}{\pi} \ln(1 + \sqrt{2}), \text{ weil } \text{arsinh } t = \ln(t + \sqrt{t^2 + 1}).$$

Verwendung der Grotthendieck - Ungleichung in der statistischen Physik

Ising - Modell / Spingläser zur Beschreibung von Ferro - magnetismen


$$V = [0, N]^d \cap \mathbb{Z}^d \quad \text{mit } N \in \mathbb{N} \quad \underline{d\text{-dim. Raster}}$$

bestehend aus $(N+1)^d$ Knoten.

Knoten $i \in V$ entsprechen Atomen.

Zwei Knoten $i, j \in V$ interagieren, falls sie im Raster benachbart sind,

d.h. falls $\|i-j\| = 1$ gilt.



$J_{ij} \in \mathbb{R}$ Kopplungskonstante, $J_{ij} > 0$: ferromagnetische Kop.
 $J_{ij} < 0$: antiferromagnetische K.

Jeder Knoten hat entweder Zustand $+1$ ("spin up") oder Zustand -1 ("spin down").

$x_i^2 = 1$, x_i Variable für gerade Knoten $i_1 + \dots + i_d = 0 \pmod{2}$

$y_j^2 = 1$, y_j Variable für ungerade Knoten $j_1 + \dots + j_d = 1 \pmod{2}$

Energie des Systems wird durch Hamiltonfkt. beschrieben

$$H = -\frac{1}{2} \sum_{\substack{i, j \in V \\ \|i-j\|=1}} J_{ij} x_i y_j$$

i gerade, j ungerade - 63 -

Ziel: Finde Grundzustand, d.h. Spin, die H minimieren.

Dies ist äquivalent zur Berechnung von $\|J\|_{\infty \rightarrow 1}$ und das ist NP-schwer für $d \geq 3$ (Barahona 1982).

$\text{sdp}_{\infty \rightarrow 1}(J)$ gibt eine 0,561... Approximation.

§ 5 Approximation von MAX-2-SAT

Seien $a = (a_{ij}), b = (b_{ij}) \geq 0$ gegeben. Definiere quadratische

Programm

$$q_p(a, b) = \max \sum_{\{i, j\} \in E_1} a_{ij} (1 - x_i x_j) + \sum_{\{i, j\} \in E_2} b_{ij} (1 + x_i x_j)$$

$$x_i^2 = 1 \quad \text{für } i \in [n]$$

und die semidefinite Relaxierung

$$\text{sdp}(a, b) = \max \sum_{\{i, j\} \in E_1} a_{ij} (1 - X_{ij}) + \sum_{\{i, j\} \in E_2} b_{ij} (1 + X_{ij})$$

$$X \in S_{\geq 0}^m$$

$$X_{ii} = 1 \quad \text{für } i \in [n].$$

Satz 1 $\text{sdp}(a, b) \geq q_p(a, b) \geq 0,878 \cdot \text{sdp}(a, b)$

Bew.: Aufgabe 6.4, Hinweis: $\arccos(-t) = \pi - \arccos(t)$.

Def. 2 (SAT = satisfiability problem) Erfüllbarkeitsproblem
gegeben: Aussagenlogische Formel in Konjunktiver Normalform,
d.h. eine Konjunktion von Klauseln C_1, \dots, C_m

$$F = C_1 \wedge C_2 \wedge \dots \wedge C_m,$$

Wobei jede Klausel aus Disjunktion von Literalen besteht

$$C_i = (l_{i1} \vee \dots \vee l_{ij})$$

und ein Literal ist eine Variable z_1, \dots, z_n oder deren
Negation $\neg z_1, \dots, \neg z_n$.

gesucht: Belegung der Variablen mit "wahr" oder "falsch",
so dass F wahr ist.

Bsp. $F = (z_1 \vee z_2 \vee z_3) \wedge (\neg z_1 \vee z_4)$

Erfüllende Belegung z.B. $z_1 = w, z_2 = f, z_3 = f, z_4 = w$

Theorem (Cook-Levine ~ 1970)

Das Entscheidungsproblem SAT ist NP-vollständig.

Bew.: \rightarrow Informatik

Optimierungsvariante MAX-2-SAT

Def. 3 (MAX-2-SAT)

geg.: $F = C_1 \wedge \dots \wedge C_m$

jedes C_i besteht aus Disjunktion von ≤ 2 Literalen

$w_1, \dots, w_m \geq 0$ Gewichte

ges.: Belegung der Variablen, so dass Gewicht der erfüllten Klauseln maximiert wird.

Theorem (Håstad 2001) Falls $P \neq NP$, dann \nexists polynomialzeit -
Algorithmen, die MAX-2-SAT bis auf einen Faktor von $21/22 = 0,954\dots$
berechnen.

Satz 4 Man kann MAX-2-SAT in polynomialer Zeit mit
einem Faktor von $0,878\dots$ berechnen.

[sogar $0,943\dots$ möglich].

Bew.: Modellierung von MAX-2-SAT als $q_p(a,b)$ und
Anwendung von Satz 1.

Für jede Variable z_i der Formel F benutze Variable x_i
mit $x_i^2 = 1$. Extravariablen x_0 mit $x_0^2 = 1$ mit folgender
Interpretation z_i ist wahr $\Leftrightarrow x_i = x_0$.

Sei C eine Klausel, dann ist der Wert $v(C)$ definiert als

$$v(C) = \begin{cases} 1, & \text{falls } C \text{ erfüllt} \\ 0, & \text{sonst.} \end{cases}$$

Also

$$v(z_i) = \frac{1 + x_0 x_i}{2}, \quad v(\neg z_i) = 1 - v(z_i) = \frac{1 - x_0 x_i}{2}$$

$$v(z_i \vee z_j) = 1 - v(\neg z_i \wedge \neg z_j) = \cancel{1 - v(\neg z_i) \cdot v(\neg z_j)} = 1 - v(\neg z_i) v(\neg z_j)$$

$$= 1 - \frac{1 - x_0 x_i}{2} \cdot \frac{1 - x_0 x_j}{2}$$

$$= 1 - \frac{1}{4} (1 - x_0 x_j - x_0 x_i + x_0^2 x_i x_j)$$

$$= \frac{1 + x_0 x_i}{4} + \frac{1 + x_0 x_j}{4} + \frac{1 - x_i x_j}{4}$$

genauer

$$v(z_i \vee \neg z_j) \quad \text{und} \quad v(\neg z_i \vee \neg z_j)$$

D.h. MAX-2-SAT ist äquivalent zu

$$\max \left\{ \sum_{j=1}^m w_j v(C_j) : x_1^2 = \dots = x_n^2 = x_0^2 = 1 \right\}$$

und das kann in der Form $qp(a, b)$ geschrieben werden.

□

Kapitel III Packungen und Färbungen in Graphen

§ 1 Definitionen

Sei $G = (V, E)$ ein ungerichteter Graph.

$\bar{G} = (V, \bar{E})$ ist der zu G komplementäre Graph,

wobei $\bar{E} = \{ \{i, j\} \in \binom{V}{2} : \{i, j\} \notin E \}$.

$S \subseteq V$ heißt unabhängig, falls für alle $i, j \in S$ stets $\{i, j\} \notin E$ gilt.

$C \subseteq V$ heißt eine Clique, falls für alle $i, j \in C$ stets $\{i, j\} \in E$ gilt.

$\alpha(G) = \max \{ |S| : S \subseteq V \text{ unabhängig} \}$ ist die Unabhängigkeitszahl von G (oder auch Stabilitätszahl)

$\omega(G) = \alpha(\bar{G})$ ist die Cliquenzahl von G
 $= \max \{ |C| : C \subseteq V \text{ Clique} \}.$

Sei $k \in \mathbb{N}$. Eine k -Färbung von G ist eine Abbildung $\varphi: \{1, \dots, k\} \rightarrow V$ mit $\varphi(i) \neq \varphi(j)$ für alle $\{i, j\} \in E$. I. a. W. eine k -Färbung ist eine Partition von $V = S_1 \cup \dots \cup S_k$ in k unabh. Mengen S_1, \dots, S_k . Die chromatische Zahl von G ist

$$\chi(G) = \min \{ k : \exists k\text{-Färbung von } G \}$$

Die Entscheidungsprobleme

- $\alpha(G) \geq k$?
- $\omega(G) \geq k$?
- $\chi(G) \leq k$?

sind alle NP-vollständig.

Es ist sogar „ $\chi(G) \leq 3$?“ für planare Graphen NP-vollständig.


[Dagegen ist jeder planare Graph 4-färbbar (\rightarrow 4-Farben Satz von Appel und Haken (1976))]

Außerdem „ $\chi(G) \leq 2$?“ effizient entscheidbar. Dies ist die Frage nach Bipartitheit.

Klarerweise gilt $\omega(G) \leq \chi(G)$.

Im allgemeinen $\omega(G) < \chi(G)$, zum Bsp.: Kreisgraph

C_{2n+1} ungerader Länge:



$$\omega(C_{2n+1}) = 2$$

$$\chi(C_{2n+1}) = 3.$$

Komplementärgraph $\overline{C_{2n+1}}$: $\omega(\overline{C_{2n+1}}) = n$
 $\chi(\overline{C_{2n+1}}) = n+1.$

§ 2 Semidefinite Programmierungsschranken

Def. 1 Sei $G = (V, E)$. Definiere das semidefinite Programm

$$\nu(G) = \max \langle J, X \rangle$$

$$X \geq 0$$

$$\text{Tr}(X) = 1$$

$$X_{ij} = 0 \quad \text{für } \{i, j\} \in E.$$

\mathcal{J} heißt die Lovász \mathcal{J} -Zahl.

Bem.: $\mathcal{J}(G) =$ semidefinite Relaxierung des quadratischen Programms, das $\alpha(G)$ beschreibt und in Bsp. II.3.3 gegeben wurde.

Beweis davon \rightarrow Aufgabenblatt 8.

Satz 2 (Lovász Sandwich Theorem)

$$\alpha(G) \leq \mathcal{J}(G) \leq \chi(\overline{G}).$$

Bew.: $\alpha(G) \leq \mathcal{J}(G)$

Sei $S \subseteq V$ eine unabhängige Menge mit $|S| = \alpha(G)$.

Definiere den charakteristischen Vektor $\chi^S \in \mathbb{R}^V$ durch

$$(\chi^S)_v = \begin{cases} 1 & \text{falls } v \in S \\ 0 & \text{sonst.} \end{cases}$$

Definiere die Matrix

$$X = \frac{1}{|S|} \chi^S (\chi^S)^T \in S^V.$$

Dann ist X eine zulässige Lösung von $\mathcal{J}(G)$ mit $\langle J, X \rangle = |S|$.

Also $\alpha(G) \leq \mathcal{J}(G)$.

$\mathcal{J}(G) \subseteq \mathcal{X}(\bar{G})$. Es sei X eine zulässige Lösung von $\mathcal{J}(G)$. Sei $V = C_1 \cup \dots \cup C_k$ eine Partition von V in k Cliques.

Beh.: $\langle J, X \rangle \leq k \quad (\Rightarrow \mathcal{J}(G) \subseteq \mathcal{X}(\bar{G}))$.

Bew.: Es ist

$$\sum_{i=1}^k \chi^{C_i} = e = (1, \dots, 1)^T.$$

und

$$\begin{aligned} Y &:= \sum_{i=1}^k (k \chi^{C_i} - e) (k \chi^{C_i} - e)^T \\ &= k^2 \sum_{i=1}^k \chi^{C_i} (\chi^{C_i})^T - \underbrace{e \left(\sum_{i=1}^k k \chi^{C_i} \right)^T}_{k e^T} - \underbrace{\sum_{i=1}^k k \chi^{C_i} e^T}_{k e} \\ &= k^2 \sum_{i=1}^k \chi^{C_i} (\chi^{C_i})^T - k J, \quad \text{wobei } J = e e^T. \\ &\geq 0. \end{aligned}$$

Deshalb

$$\begin{aligned} 0 \leq \langle X, Y \rangle &= k^2 \langle X, \sum_{i=1}^k \chi^{C_i} (\chi^{C_i})^T \rangle - k \langle J, X \rangle \\ &= k^2 \underbrace{\text{Tr}(X)}_{=1} - k \langle J, X \rangle \\ \Rightarrow \langle J, X \rangle &\leq k. \end{aligned}$$

□

§ 3 Perfekte Graphen

Def. 1 Sei $G = (V, E)$ ein Graph und $S \subseteq V$.

$$G[S] = (S, \{\{i, j\} \in E : i \in S, j \in S\})$$

ist der durch S induzierte Teilgraph von G .

Ein Graph H heißt induzierter Teilgraph von G , falls es ein $S \subseteq V$ mit $H = G[S]$ gibt. Notation: $H \subseteq G$

Def. 2 Ein Graph heißt perfekt, falls für alle induzierten Teilgraphen H stets $\omega(H) = \chi(H)$ gilt.

Bsp 3 a) bipartite Graphen sind perfekt ($\omega(H) = \chi(H)$ klar)
 $= 2$

b) $C_{2n+1}, \overline{C_{2n+1}}$ nicht perfekt.

c) Kantengraphen $L(G)$ von bipartiten Graphen G sind perfekt (\rightarrow Blatt 8), dabei

$$L(G) = (E, \{\{e_1, e_2\} : e_1 \cap e_2 \neq \emptyset\}).$$

"Strong perfect graph theorem"

(Chudnovsky, Robertson, Seymour, Thomas 2006)

Ein Graph ist perfekt genau dann, wenn weder C_{2n+1} noch

$\overline{C_{2n+1}}$ induzierte Teilgraphen sind.

Bew.: ist ca. 180 Seiten lang.

Theorem 4 ("perfect graph theorem", Lovász 1972)

G ist perfekt $\Leftrightarrow \overline{G}$ ist perfekt.

Bew.: Zeigen: G ist perfekt \Leftrightarrow für jeden induzierten Teilgraphen $H \subseteq G$ gilt $|V(H)| \leq \omega(H) \alpha(H)$.

[Da $\omega(H) = \alpha(\overline{H})$ und $\alpha(H) = \omega(\overline{H})$ folgt Theorem 4.]

" \Rightarrow ": Sei G perfekt und $H \subseteq G$. Dann $\chi(H) = \omega(H)$,

d. h. $V(H)$ kann von $\omega(H)$ vielen unabhängigen Mengen überdeckt werden. Also

$$|V(H)| \leq \omega(H) \alpha(H).$$

" \Leftarrow " Ang. G erfüllt die Ungleichungen

$|V(H)| \leq \omega(H)\chi(H)$, aber G ist nicht perfekt.

Wähle G mit $|V(G)|$ minimal. D.h.

$\omega(G) < \chi(G)$ und für jeden induzierten Teilgraphen

$H \subseteq G$ mit $H \neq G$ gilt $\omega(H) = \chi(H)$.

1. Beh.: $\exists \alpha(G)\omega(G)+1$ unabh. Mengen $S_0, \dots, S_{\alpha(G)\omega(G)}$,
so dass jeder Knoten in G von exakt $\alpha(G)$ dieser Mengen
überdeckt wird.

Bew.: Sei S_0 eine unabh. Menge mit $|S_0| = \alpha(G)$.

$\forall v \in S_0$: $G[v, \{v_0\}]$ ist perfekt (wg. der Minimalität
von G).

Dann

$$\chi(G[v, \{v_0\}]) = \omega(G[v, \{v_0\}]) \leq \omega(G).$$

Also kann $V \setminus \{v_0\}$ in $\omega(G)$ unabh. Mengen partitioniert werden.

Dies machen wir für jeden der $\alpha(G)$ Knoten in S_0 und
bekommen $\alpha(G)\omega(G)$ unabh. Mengen $S_1, \dots, S_{\alpha(G)\omega(G)}$, die
zusammen mit S_0 die Beh. erfüllen.

2. Beh.: $\forall i = 0, \dots, \alpha(G)\omega(G) \exists K_i$ Clique, $|K_i| = \omega(G)$
 mit $K_i \cap S_i = \emptyset$ und $K_i \cap S_j \neq \emptyset$ für $j \neq i$.

Bew.: Da $G[V \setminus S_i]$ perfekt ist gilt

$$\chi(G[V \setminus S_i]) = \omega(G[V \setminus S_i]) \leq \omega(G).$$

Dann muss $\chi(G[V \setminus S_i]) = \omega(G)$ sein, denn falls

$\chi(G[V \setminus S_i]) \leq \omega(G) - 1$ wäre, könnte man G mit

$\omega(G)$ Farben färben. Also $\omega(G[V \setminus S_i]) = \omega(G)$ und

somit gibt es eine Clique K_i mit $K_i \cap S_i = \emptyset$ und $|K_i| = \omega(G)$.

Außerdem gilt $K_i \cap S_j \neq \emptyset$ für $j \neq i$, weil jedes der $\omega(G)$
 Elemente von K_i gehört zu $\alpha(G)$ unabh. Mengen S_j ^(Beh. 1) und

$|K_i \cap S_j| \leq 1$, also $|K_i \cap S_j| = 1$.

Definiere Matrizen $M, N \in \mathbb{R}^{|V| \times (\alpha(G)\omega(G)+1)}$ durch

$$M = \begin{bmatrix} \chi^{S_0} & \dots & \chi^{S_{\alpha(G)\omega(G)+1}} \end{bmatrix}$$

$$N = \begin{bmatrix} \chi^{K_0} & \dots & \chi^{K_{\alpha(G)\omega(G)+1}} \end{bmatrix}.$$

Dann gilt $M^T N = J - I$ wegen Beh. 2.

Nun ist $J-I$ eine reguläre Matrix, d.h.

$$\text{rank}(M^T N) = \text{rank}(J-I) = \alpha(G)\omega(G) + 1.$$

Andererseits

$$\text{rank}(M^T N) \leq \text{rank}(N) \leq |V(G)|.$$

Also $\alpha(G)\omega(G) < |V(G)|$. ↗

Korollar 5 Sei G perfekt. Dann gilt

$$\alpha(G) = \nu(G) = \chi(\bar{G}).$$

Bew.: Nach Satz III.2.2 und Theorem 4 folgt

$$\alpha(G) \leq \nu(G) \leq \chi(\bar{G}) = \omega(\bar{G}) = \alpha(G),$$

also Gleichheit überall.

D.h. man kann α, ω, χ in perfektem Graphen effizient bestimmen.

Ziel: Finde $S \subseteq V$ mit $|S| = \alpha(G)$ bzw.

Partition $V = S_1 \cup \dots \cup S_k$ mit $k = \chi(G)$.

Satz 6 Sei $G = (V, E)$ perfekt. Man kann ein $S \subseteq V$ mit $|S| = \alpha(G)$ effizient bestimmen.

Bew.: geg.: $G = (V, E)$ mit $V = \{i_1, \dots, i_n\}$.

ges.: $S \subseteq V$ mit $|S| = \alpha(G)$

$$G_0 = G$$

for $j = 1$ to n

Berechne $\alpha(G_{j-1} \setminus i_j)$

if $\alpha(G_{j-1} \setminus i_j) = \alpha(G)$

$$G_j = G_{j-1} \setminus i_j$$

else

$$G_j = G_{j-1}$$

$$S = G_n$$

Falls G perfekt ist, kann man $\alpha(G)$ mit $\mathcal{J}(G)$ berechnen.

Insgesamt werden $n+1$ Berechnungen von \mathcal{J} benötigt.

Beh.: $|S| = \alpha(G)$ und S ist unabh.

Bew.: klar: $\alpha(G) = |S|$.

Ang. S ist nicht unabh. Dann $\exists i_j$ mit $\alpha(G_n \setminus i_j) = \alpha(G)$.

Aber G_n ist induzierter Teilgraph von G_{j-1} , also

$$\alpha(G_n \setminus ij) \leq \alpha(G_{j-1} \setminus ij) = \alpha(G),$$


so dass der Knoten ij schon im j -ten Schritt gelöscht werden würde.

Zur effizienten Bestimmung einer $\chi(G)$ -Färbung:

Def. 7 $G = (V, E)$ Graph, $v \in V$.

$$H = (V \cup \{v'\}, E \cup \{\{v', w\} : \{v, w\} \in E\})$$

ist der Graph, der durch Duplikation des Knoten v aus G entsteht.



Satz 8 Sei G perfekt und H entstehe aus G durch Duplikation eines Knoten. Dann ist H perfekt.

Bew.: Zeige: \bar{H} ist perfekt (und wende das perfekte Graphentheorem III.3.4 an).

$$1. \alpha(H) = \chi(\bar{H}).$$

Nach Konstruktion ist

$$\alpha(H) = \alpha(\mathcal{G}) = \chi(\bar{G})$$

\uparrow
 \mathcal{G} perfekt

Sei $V = C_1 \dot{\cup} \dots \dot{\cup} C_t$ eine Partition von V in Cliquen.

Ang. $v \in C_1$. Dann ist $V \cup \{v'\} = (C_1 \cup \{v'\}) \dot{\cup} \dots \dot{\cup} C_t$

eine Partition von $V \cup \{v'\}$ in Cliquen. Also $\chi(\bar{H}) = \chi(\bar{G})$
und somit $\alpha(H) = \chi(\bar{H})$.

$$2. \alpha(H') = \chi(\bar{H}') \text{ f\u00fcr } H' \subseteq H.$$

geht genauso, falls $v' \in V(H')$. Falls $v' \notin V(H')$, dann

ist $H' \subseteq \mathcal{G}$ und $\alpha(H') = \chi(\bar{H}')$ wegen der Perfektheit
von \mathcal{G} . \(\square\)

Def. 9 Sei $G = (V, E)$ und $w: V \rightarrow \mathbb{Z}_{\geq 0}$ eine

Gewichtsfkt. Die gewichtete Unabhängigkeitszahl ist

$$\alpha_w(\mathcal{G}) = \max \left\{ \sum_{v \in S} w(v) : S \subseteq V \text{ unabh. in } \mathcal{G} \right\}.$$

Es gilt $\alpha_w(G) = \alpha(\overline{\mathcal{G}}_w)$, wobei $(\overline{\mathcal{G}}_w)$ aus \mathcal{G} entsteht,

indem jeder Knoten $v \in V$ $w(v)$ -fach dupliziert wird, und alle
Kanten, die einen Knoten zu seiner Duplikat verbinden wurden geteilt werden.

Lemma 10 Es gibt eine unabh. Menge S in einem perfekten Graph G , die mit allen Cliquen C in G mit $|C| = \omega(G)$ einen nicht-leeren Schnitt hat.

Bew.: Sei $V = S_1 \cup \dots \cup S_{\omega(G)}$ eine optimale Färbung von G . Dann gilt für jeden S_i :

$$\omega(G[V \setminus S_i]) = \chi(G[V \setminus S_i]) = \omega(G) - 1.$$

Idee für Algorithmen: Finde eine solche unabh. Menge S und färbe $G[V \setminus S]$ rekursiv mit $\omega(G[V \setminus S]) = \omega(G) - 1$ Farben.

Satz 11 Sei $G = (V, E)$ perfekt. Man kann eine Partition $V = S_1 \cup \dots \cup S_{\chi(G)}$ bestehend aus unabh. Mengen S_i effizient bestimmen.

Bew.: Algorithmus 1 input: $G = (V, E)$ perfekter Graph
output: $\chi(G)$ -Färbung $V = S_1 \cup \dots \cup S_{\chi(G)}$

$i = 1$
 while $V \neq \emptyset$ do
 $S_i =$ Ergebnis von Algp. 2 (Lemma 10)
 $i = i + 1, G = G[V \setminus S_i]$

Algorithmus 2

input: $G = (V, E)$ perfekter Graph

output: unabh. Menge S mit

$\forall C \subseteq V$ Clique in G , $|C| = \omega(G)$:

$$|C \cap S| = 1.$$

$$k = 0$$

repeat

$$w = \sum_{i=1}^k \chi^{C_i}$$

Finde mit Algo von Satz 6 unabh. Menge $S \subseteq V$ (*)

mit $\sum_{v \in S} w(v) = \alpha_w(G)$. [Wende Satz 6 auf
perfekten Graph G_w an].

if $\omega(G[V \setminus S]) = \omega(G)$

$$k = k + 1$$

Berechne eine Clique C_k in $G[V \setminus S]$ mit $|C_k| = \omega(G)$.
[Satz 6]

until $\omega(G[V \setminus S]) < \omega(G)$

output S .

Der Schritt (*) stellt sicher, dass S alle Cliques C_1, \dots, C_k schneidet.

Falls $\omega(G[V \setminus S]) < \omega(G)$, dann schneidet S jede Clique C in G mit $|C| = \omega(G)$.

Die Anzahl der Iterationen ist $\leq |V|$:

Betrachte den affinen Unterraum


$$L_t = \left\{ x \in \mathbb{R}^V : \sum_{i \in C_j} x_i = 1, \quad j = 1, \dots, k \right\}.$$

Es gilt $L_t \supsetneq L_{t+1}$, da $X^s \in L_t \setminus L_{t+1}$ für die im t -ten Schritt konstruierte unabh. Menge S .

D.h. $\dim L_{t+1} < \dim L_t$, also $t \leq \dim \mathbb{R}^V = |V|$.

§ 4 Shannon-Kapazität


Informationstheorie



Nachricht: Folge von Symbolen aus V

Problem: Man kann Symbole verwechseln

Verwechslungsgraph: $G = (V, E)$




Ziel: Fehlerfreie Kommunikation; verwende nur Symbole, die nicht verwechselt werden können.

Informationsrate: $\alpha(G)$ (hier $\alpha(C_5) = 2$)

Trick zur Verbesserung der Informationsrate: Sende mehrere Symbole gleichzeitig.

Def. 1 Seien $G = (V, E)$, $H = (W, F)$. Das starke Graphenprodukt $G \times H$ ist

$$G \times H = (V \times W, \{ \{ (v_1, w_1), (v_2, w_2) \} : \begin{array}{l} v_1 = v_2 \text{ u. } \{w_1, w_2\} \in F, \\ w_1 = w_2 \text{ u. } \{v_1, v_2\} \in E, \\ \{v_1, v_2\} \in E, \{w_1, w_2\} \in F \} \end{array})$$



Notation: $G^k = \underbrace{G \times \dots \times G}_{k\text{-mal}}$

Lemma 2 $\alpha(G \times H) \geq \alpha(G) \alpha(H)$.

Inbesondere $\sqrt[k]{\alpha(G^k)} \geq \alpha(G)$.

Bew.: Sei $S \subseteq V$ unabh. in G mit $\alpha(G) = |S|$,
 $T \subseteq W$ unabh. in H mit $\alpha(H) = |T|$.

Dann ist $S \times T$ unabh. in $G \times H$.

Def. 3: $\Theta(G) = \sup_{k \in \mathbb{N}} \sqrt[k]{\alpha(G^k)}$ heißt Shannon-Kapazität von G .

Bsp.: $\Theta(C_5) \geq \sqrt{5} (\geq 2)$

Da $\alpha(C_5^2) \geq 5$, denn $\{(1,1), (2,3), (3,5), (4,2), (5,4)\}$
ist unabh. in C_5^2 .

Shannon (1956) : 1) Ist $\Theta(C_5) = \sqrt{5}$?

2) Wie berechnet man $\Theta(G)$?

1) Lovász (1979) : ja

2) Keine Ahnung, selbst $\Theta(C_7)$ ist unbekannt.

Exkurs: Kroneckerprodukt von Matrizen.

Def. 4 Seien $A = (A_{ij}) \in \mathbb{R}^{m \times n}$, $B = (B_{hk}) \in \mathbb{R}^{p \times q}$.

Das Kroneckerprodukt $A \otimes B \in \mathbb{R}^{mp \times nq}$ ist definiert als

$$A_{ih, jk} = A_{ij} B_{hk}.$$

$A \otimes B$ ist eine $m \times n$ Blockmatrix mit Blöcken der Größe $p \times q$.

$$A \otimes B = \begin{bmatrix} A_{11} B & A_{12} B & \dots & A_{1n} B \\ \dots & \dots & \dots & \dots \\ A_{m1} B & A_{m2} B & \dots & A_{mn} B \end{bmatrix}$$

Lemma 5 a) $(A \otimes B)(C \otimes D) = (AC) \otimes (BD)$.

b) $A \in S^m$, $B \in S^n$ mit Eigenwerten $\alpha_1, \dots, \alpha_m$,
bzw. β_1, \dots, β_n . Dann sind die Eigenwerte von
 $A \otimes B$ gleich $\alpha_i \beta_j$ $i \in [m], j \in [n]$.

Bew.: direktes Nachrechnen.

Satz 6 $\mathcal{J}(G \times H) = \mathcal{J}(G) \mathcal{J}(H)$.

Bew.: 1) $\mathcal{J}(G \times H) \geq \mathcal{J}(G) \mathcal{J}(H)$

Betrachte das primale SDP, das \mathcal{J} definiert

$$\max \langle J, X \rangle$$

$$\text{Tr}(X) = 1, X \geq 0$$

$$X_{ij} = 0 \text{ für } \{i, j\} \in E.$$

Sei X eine zulässige Lösung für $\mathcal{J}(G)$ und Y eine für $\mathcal{J}(H)$.

Dann ist $X \otimes Y$ eine zulässige Lösung für $\mathcal{J}(G \times H)$ mit

$$\langle J, X \otimes Y \rangle = \langle J, X \rangle \langle J, Y \rangle,$$

was man durch direktes Nachrechnen verifiziert.

2) $\mathcal{J}(G \times H) \leq \mathcal{J}(G) \mathcal{J}(H)$: \rightarrow Blatt 9.

Korollar 7 $\Theta(G) \leq \mathcal{D}(G)$

Bew.: $\sqrt[k]{\alpha(G^k)} \leq \sqrt[k]{\mathcal{D}(G^k)} = \sqrt[k]{\mathcal{D}(G)^k} = \mathcal{D}(G)$.

Satz 8 $\mathcal{D}(C_5) = \sqrt{5}$

Bew.: Aufgabe 3.4 und Aufgabe 7.3.

In § 5 werden wir zwei weitere Beweise dafür sehen.

§ 5 Berechnung von \mathcal{D} für symmetrische Graphen

Def. 1 $G = (V, E)$ Graph.

a) Die Automorphismengruppe von G ist

$$\text{Aut}(G) = \left\{ \sigma : V \rightarrow V : \sigma \text{ Permutation und} \right. \\ \left. \{i, j\} \in E \Leftrightarrow \{\sigma(i), \sigma(j)\} \in E \right\}.$$

b) G heißt homogen (knoten transitiv), falls

$$\forall i, j \in V \exists \sigma \in \text{Aut}(G) : \sigma(i) = j.$$

Entscheidungsproblem: „ $\text{Aut}(G) = \emptyset$?“ ist Komplexitätstheoretisch interessant. Wissen nicht, ob es in P liegt.

Andererseits liegt es wahrscheinlich nicht in NPC.

Sei $\sigma: V \rightarrow V$ eine Permutation. Betrachte die Permutationsmatrix $P^\sigma \in \mathbb{R}^{V \times V}$, die durch

$$P_{ij}^\sigma = \begin{cases} 1 & , \text{ falls } i = \sigma(j) \\ 0 & , \text{ sonst} \end{cases}$$

bestimmt ist.

Sei $X \in S^V$ eine symmetrische Matrix. Definiere die Linksoperation

$$\sigma(X) = P^\sigma X (P^\sigma)^T = (X_{\sigma^{-1}(i), \sigma^{-1}(j)})_{i, j \in V}.$$

Lemma 2 Sei $G = (V, E)$ ein Graph. Betrachte

$$\mathcal{J}(G) = \max \{ \langle J, X \rangle : X \in S_{\geq 0}^V, \text{Tr}(X) = 1, \\ X_{ij} = 0, \{i, j\} \in E \}.$$

Dann gibt es eine optimale Lösung X^* von $\mathcal{J}(G)$, die invariant unter der Operation von $\text{Aut}(G)$ ist, d.h.

$$\sigma(X^*) = X^* \quad \forall \sigma \in \text{Aut}(G).$$

Bew.: Sei X eine optimale Lösung von $\mathcal{J}(G)$. Dann ist $\sigma(X)$ ebenfalls optimal für jedes $\sigma \in \text{Aut}(G)$.

Definiere $X^* = \frac{1}{|\text{Aut}(G)|} \sum_{\sigma \in \text{Aut}(G)} \sigma(X)$.

Da die Menge der optimalen Lösungen von $\mathcal{J}(G)$ konvex ist, ist X^* optimal. Nach Konstruktion ist $\sigma(X^*) = X^* \quad \forall \sigma \in \text{Aut}(G)$.

Satz 3 Sei G knotentransitiv. Dann gibt es eine optimale

Lösung von $\mathcal{J}(G)$ mit $X_{ii}^* = \frac{1}{n}$ für alle $i \in V$ und

$$X^* \mathbf{e} = \frac{\mathcal{J}(G)}{n} \mathbf{e}$$

Bew.: Nach Lemma 2 $\exists X^*$ optimal mit $\sigma(X^*) = X^*$

$\forall \sigma \in \text{Aut}(G)$. Da G knotentransitiv ist, sind alle Diagonalelemente von X^* gleich: Sei $i, j \in V$ und $\sigma \in \text{Aut}(G)$ mit $\sigma(i) = j$. Dann ist

$$X_{jj}^* = X_{\sigma^{-1}(i), \sigma^{-1}(i)}^* = \sigma(X^*)_{ii} = X_{ii}^*.$$

Weil $\text{Tr}(X^*) = 1$, folgt $X_{ii}^* = \frac{1}{n}$.

Mit dem gleichen Argument zeigt man, dass die Zeilensummen von X^* alle übereinstimmen, somit

$$X^* \mathbf{e} = \lambda \mathbf{e}. \quad \text{Da } \mathcal{J}(G) = \langle \mathcal{J}, X^* \rangle = \mathbf{e}^T X^* \mathbf{e} = \mathbf{e}^T \lambda \mathbf{e} = \lambda n$$

folgt die Beh.

Satz 4 Sei G knotentransitiv, dann ist $\mathcal{J}(g) \mathcal{J}(\bar{g}) = |V|$.

Bew.: $\mathcal{J}(g) \mathcal{J}(\bar{g}) \geq |V|$: Aufgabe 7.4

$\mathcal{J}(g) \mathcal{J}(\bar{g}) \leq |V|$:

$$\mathcal{J}(\bar{g}) = \min t$$

$$Y - \bar{f} \geq 0$$

$$Y_{ii} = t \quad \forall i \in V$$

$$Y_{ij} = 0 \quad \forall \{i, j\} \in E$$

[Aufgabe 7.3].

Verwende optimale Lösung X^* aus Satz 3, um

$$Y = \frac{n^2}{\mathcal{J}(g)} X^*, \quad t = \frac{n}{\mathcal{J}(g)} \quad \text{zu definieren.}$$

Überprüfe, dass (Y, t) gültige Lösung von $\mathcal{J}(\bar{g})$ ist : Dann

$$\frac{n^2}{\mathcal{J}(g)} X^* - \bar{f} \geq 0, \quad \text{weil} \quad \frac{n^2}{\mathcal{J}(g)} X^* e - \bar{f} e$$

$$= \frac{n^2}{\mathcal{J}(g)} \frac{\mathcal{J}(g)}{n} e - n e = 0.$$

Also ist $\mathcal{J}(\bar{g}) \leq \frac{n}{\mathcal{J}(g)}$, und die Beh. folgt. \square

Korollar 5 $\mathcal{J}(C_n) \mathcal{J}(\bar{C}_n) = n$, insbesondere $\mathcal{J}(C_5) = \sqrt{5}$.

§ 6 \mathcal{I} für Cayley-Graphen endlicher, abelscher

Gruppen

Sei $(G, +)$ eine endliche abelsche Gruppe. Nach dem Hauptsatz über endliche abelsche Gruppen ist

$$G \cong \mathbb{Z}/n_1\mathbb{Z} \times \dots \times \mathbb{Z}/n_r\mathbb{Z}.$$


[Stichwort: Moduln über Hauptidealringen; Elementarteiler]

Def. 1 Sei $\Sigma \subseteq G$, mit $\Sigma = -\Sigma$.

$$\text{Cayley}(G, \Sigma) = (G, \{\{x, y\} : x - y \in \Sigma\})$$

heißt der Cayley-Graph von G und Σ .

Bsp.: $C_n = \text{Cayley}(\mathbb{Z}/n\mathbb{Z}, \{1, -1\})$



Beobachtung: $G \subseteq \text{Aut}(\text{Cayley}(G, \Sigma))$

ist eine Untergruppe, da für $a \in G$ gilt

$$x - y \in \Sigma \Leftrightarrow (a+x) - (a+y) \in \Sigma$$

Ziel: Berechnung von $\mathcal{I}(\text{Cayley}(G, \Sigma))$.

Def. 2 a) $(\mathbb{T} = \{z \in \mathbb{C} : |z| = 1\}, \cdot)$ ist der Torus von \mathbb{C}

b) Ein Gruppenhomomorphismus $\chi: (G, +) \rightarrow (\mathbb{T}, \cdot)$ heißt Charakter von G , d.h. $\chi(x+y) = \chi(x)\chi(y)$.

Bsp.: Sei $a \in \mathbb{Z}/n\mathbb{Z}$. Dann

$$\text{ist } \chi_a(x) = e^{\frac{2\pi i a x}{n}}$$

ein Charakter von $\mathbb{Z}/n\mathbb{Z}$, weil

$$\begin{aligned} \chi_a(x+y) &= e^{\frac{2\pi i a (x+y)}{n}} = e^{2\pi i a x/n} e^{2\pi i a y/n} \\ &= \chi_a(x) \chi_a(y). \end{aligned}$$

Wir betrachten Charaktere $\chi: G \rightarrow \mathbb{T}$ als Elemente $\chi \in \mathbb{C}^G$ des unitären Vektorraum \mathbb{C}^G mit Skalarprodukt

$$\langle f, g \rangle = \frac{1}{|G|} \sum_{x \in G} \overline{f(x)} g(x).$$

Lemma 3 (Orthogonalitätsrelation)

Seien χ, ψ Charaktere von G , dann gilt

$$\langle \chi, \psi \rangle = \begin{cases} 1, & \chi = \psi \\ 0, & \text{sonst.} \end{cases}$$

Bew.:

Falls ψ ein Charakter von G ist, dann ist ψ^{-1} auch einer.

Es gilt

$$\begin{aligned}\langle \chi, \psi \rangle &= \frac{1}{|G|} \sum_{x \in G} \chi(x) \overline{\psi(x)} = \frac{1}{|G|} \sum_{x \in G} \chi(x) \psi^{-1}(x) \cdot \overline{1(x)} \\ &= \langle \chi \psi^{-1}, 1 \rangle,\end{aligned}$$

Wobei $1: G \rightarrow \mathbb{C}$ der triviale Charakter (mit $1(x)=1$) ist.

Außerdem ist das Produkt zweier Charaktere wieder ein Charakter, d. h. wir können uns auf die Situation „ $\langle \chi, 1 \rangle = ?$ “

zurückziehen.

Falls $\chi = 1$, dann ist $\langle \chi, 1 \rangle = 1$.

Falls $\chi \neq 1$, dann gibt es ein $y \in G$ mit $\chi(y) \neq 1$.

Es gilt

$$\begin{aligned}\chi(y) \langle \chi, 1 \rangle &= \chi(y) \frac{1}{|G|} \sum_{x \in G} \chi(x) = \frac{1}{|G|} \sum_{x \in G} \chi(y+x) \\ &= \frac{1}{|G|} \sum_{x \in G} \chi(x) = \langle \chi, 1 \rangle,\end{aligned}$$

also $\langle \chi, 1 \rangle = 0$, da $\chi(y) \neq 0$.

□

Korollar 4 Sei $G = \mathbb{Z}/n_1\mathbb{Z} \times \dots \times \mathbb{Z}/n_r\mathbb{Z}$. Dann

bilden die Charaktere

$$\chi_{a_1, \dots, a_r}(x_1, \dots, x_r) = \prod_{j=1}^r e^{\frac{2\pi i a_j x_j}{m_j}}$$

mit $(a_1, \dots, a_r), (x_1, \dots, x_r) \in G$ [beachte, dass χ wohl-
definiert ist]
eine Orthonormalbasis von \mathbb{C}^G .

Def. 5 $(\hat{G} = \{ \chi : \chi \text{ ist Charakter von } G \}, \cdot)$

heißt die zu G duale Gruppe.

Nach Korollar 4 ist $(G, +) \cong (\hat{G}, \cdot)$

Lemma 6 Sei Cayley (G, Σ) gegeben.

Sei $X \in S^G$ mit $g(X) = X$ für alle $g \in G$. Dann

gilt $X_{x,y} = X_{x',y'}$ für alle x, x', y, y' mit

$x-y = x'-y'$, oder $-(x-y) = x'-y'$.

Bsp: $\mathbb{Z}/5\mathbb{Z} = \{0, 1, -1, 2, -2\}$, $\Sigma = \{\pm 1\}$

$$X = \begin{matrix} & \begin{matrix} 0 & 1 & 2 & 3 & 4 \end{matrix} \\ \begin{matrix} 0 \\ 1 \\ 2 \\ 3 \\ 4 \end{matrix} & \begin{bmatrix} x_0 & x_1 & x_2 & x_2 & x_1 \\ x_1 & x_0 & x_1 & x_2 & x_2 \\ x_2 & x_1 & x_0 & x_1 & x_2 \\ x_2 & x_2 & x_1 & x_0 & x_1 \\ x_1 & x_2 & x_2 & x_1 & x_0 \end{bmatrix} \end{matrix}$$

Bew.: Es ist

$$g(X)_{x,y} = X_{x-g, y-g} = X_{x,y}.$$

Wähle $g = x - x'$. Dann ist

$$x - g = x - (x - x') = x',$$

$$y - g = y - (x - x') = -(x - y) + x' = -(x' - y') + x' = y'.$$

Außerdem ist wegen der Symmetrie von X

$$X_{x,y} = X_{y-g, x-g}.$$

Wähle $g = y - x'$. Dann ist

$$y - g = y - (y - x') = x',$$

$$x - g = x - (y - x') = -(x' - y') + x' = y'. \quad \square$$

Satz 7 Sei $f \in \mathcal{C}^G$ mit $f(x) = \sum_{\kappa \in \hat{G}} f_{\kappa} X(x)$.

Definiere die Matrix $F \in \mathcal{C}^{G \times G}$ durch

$$F_{xy} = f(x - y), \quad x, y \in G.$$

a) F ist hermitisch ($F = \overline{F^T} = F^*$) $\Leftrightarrow f_{\kappa} \in \mathbb{R} \quad \forall \kappa \in \hat{G}$.

b) F ist herm. positiv semidefinit ($z^* F z \geq 0 \quad \forall z \in \mathcal{C}^G$)

$$\Leftrightarrow f_{\kappa} \geq 0 \quad \forall \kappa \in \hat{G}.$$

c) $F \in \mathbb{R}^{G \times G} \Leftrightarrow f_{\kappa} = f_{\bar{\kappa}} \quad \forall \kappa \in \hat{G}$.

Bew.:

$$a) F = F^* \Leftrightarrow f(x-y) = \overline{f(y-x)}$$

$$\Leftrightarrow \sum_x f_x \chi(x-y) = \sum_x \overline{f_x} \overline{\chi(y-x)}$$

$$\Leftrightarrow \sum_x f_x \chi(x) \overline{\chi(y)} = \sum_x \overline{f_x} \chi(x) \overline{\chi(y)}$$

$$\Leftrightarrow f_x = \overline{f_x}.$$

b) " \Leftarrow ": Sei $z \in \mathbb{C}^G$. Dann

$$z^* F z = \sum_x \sum_y \overline{z_x} \sum_x f_x \chi(x-y) z_y$$

$$= \sum_x f_x (z^* \chi)^2 \geq 0.$$

" \Rightarrow ": Sei $\psi \in \hat{G}$. Dann

$$0 \leq \psi^* F \psi = \sum_x f_x (\psi^* \chi)^2 = f_\psi (\psi^* \psi)^2$$

Orthogonalität-
relation (Lemma 3).

$$\text{Also } f_\psi \geq 0.$$

c) selbst.

Satz 8

$$J(\text{Cayley}(G, \Sigma)) = \max f_0 \cdot |G|$$

$$f_x \geq 0, \quad f_x = f_{\bar{x}}, \quad x \in \hat{G}$$

$$\sum_x f_x = 1$$

$$\sum_x f_x X(x) = 0, \quad x \in \Sigma$$

Das SDP vereinfacht sich zu einem LP.

Bew.: Nach Lemma 5.2, Lemma 6.6, Satz 6.7 können

Wir annehmen, dass eine optimale Lösung X^* für J

die Form

$$X_{xy}^* = \sum_x f_x X(x-y) \quad \text{mit} \quad f_x \geq 0, \quad f_x = f_{\bar{x}}$$

hat.

$$\text{Es gilt} \quad \text{Tr}(X^*) = \sum_{x \in G} \sum_x \cancel{f_x} f_x X(x-x) = |G| \sum_x f_x$$

$$\text{Außerdem} \quad \langle J, X^* \rangle = \sum_{x,y \in G} \sum_x f_x X(x-y)$$

$$= \sum_x f_x \sum_x X(x) \sum_y \overline{X(y)}$$

$$= f_0 |G|^2$$

Wegen der Orthogonalitätsrelation (angewendet auf den trivialen Charakter).

Dividieren durch $|G|$ liefert die Beh.

□

Korollar 9 $\chi(C_n) = \frac{n \cos(\frac{\pi}{n})}{1 + \cos(\frac{\pi}{n})}$ für n ungerade

Bew.: $C_n = \text{Cayley}(\mathbb{Z}/n\mathbb{Z}, \{\pm 1\})$.

Nach Satz 8

$$\chi(C_n) = \max f_0$$

$$f_a \geq 0, f_a = f_{-a}, a \in \mathbb{Z}/n\mathbb{Z}$$

$$\sum_a f_a = 1,$$

$$\sum_a f_a e^{\frac{2\pi i a \cdot 1}{n}} = 0,$$

$$\sum_a f_a e^{\frac{2\pi i a \cdot (-1)}{n}} = 0.$$

Weil $f_a = f_{-a}$ ist

$$\sum_a f_a e^{\frac{2\pi i a \cdot 1}{n}} = f_0 + \sum_{a=1}^{(n-1)/2} f_a \left(e^{\frac{2\pi i a \cdot 1}{n}} + e^{\frac{2\pi i (-a) \cdot 1}{n}} \right)$$

$$= f_0 + \sum_{a=1}^{(n-1)/2} 2 f_a \cos \frac{2\pi a}{n}.$$

und $1 = f_0 + 2 \sum_{a=1}^{(n-1)/2} f_a.$

Um f_0 maximal zu wählen, muss

$$\sum_{a=1}^{(n-1)/2} 2 f_a \cos \frac{2\pi a}{n}$$

minimal sein unter der Nebenbedingung $f_a \geq 0$, $f_0 + 2 \sum_{a=1}^{(n-1)/2} f_a = 1$.

Es ist

$$\min_{a=1, \dots, \frac{(n-1)}{2}} \cos \frac{2\pi a}{n} = \cos \frac{2\pi (n-1)}{n} = -\cos \frac{\pi}{n}.$$

Also

$$1 = f_0 + 2 f_{(n-1)/2}$$

$$0 = f_0 + 2 f_{(n-1)/2} \left(-\cos \frac{\pi}{n}\right)$$

$$= f_0 + (-1 + f_0) \cos \frac{\pi}{n}$$

$$\Rightarrow f_0 = \frac{\cos \frac{\pi}{n}}{1 + \cos \frac{\pi}{n}}. \quad \square$$

Kapitel IV: Das Kusszahlproblem



$$\tau_2 = 6$$



$$\tau_3 \geq 12$$

Anno MDCXCIV



12

Isaac Newton



13

David Gregory

Seitdem viele Alternativbeweise: Leech (1956)

Anstreicher (2004), Musin (2006), Maehara (2007),

Bachoc, V. (2008)

Alle sind ziemlich rechenintensiv.


145.5146532u⁸v⁸ + 988.2590039u⁸v⁷ + 363.0801883u⁸v⁶ - 672.8504875u⁸v⁵ - 225.3291719u⁸v⁴ +
 191.5409281u⁸v³ + 59.48900200u⁸v² - 19.01121967u⁸v - 6.236063758u⁸ + 988.2590039u⁷v⁸ +
 2884.321650u⁷v⁷t + 2098.660249u⁷v⁷ + 3568.090777u⁷v⁶t + 18.16433328u⁷v⁶ + 344.9966795u⁷v⁵t -
 1553.436106u⁷v⁵ - 1392.615104u⁷v⁴t - 147.6093630u⁷v⁴ - 437.8480785u⁷v³t + 446.8628584u⁷v³ +
 123.8174512u⁷v²t + 71.67183278u⁷v² + 62.08524794u⁷vt - 49.22376389u⁷v - 6.539547051u⁷t -
 6.216856357u⁷ + 363.0801883u⁶v⁸ + 3568.090777u⁶v⁷t + 18.16433328u⁶v⁷ - 1165.053624u⁶v⁶t² +
 5312.362070u⁶v⁶t - 1024.256466u⁶v⁶ - 71.15855319u⁶v⁵t² + 196.7871602u⁶v⁵t - 471.6846248u⁶v⁵ +
 110.7356966u⁶v⁴t² - 2163.927390u⁶v⁴t + 464.1969368u⁶v⁴ - 78.18545046u⁶v³t² -
 505.3867129u⁶v³t + 203.1645374u⁶v³ + 41.35985267u⁶v²t² + 199.8129603u⁶v²t - 54.08669500u⁶v²
 - 17.33067199u⁶vt² + 77.24220247u⁶vt - 21.52580028u⁶v + 16.53555569u⁶t² - 10.78477271u⁶t +
 0.8926140522u⁶ - 672.8504875u⁵v⁸ + 344.9966795u⁵v⁷t - 1553.436106u⁵v⁷ - 71.15855319u⁵v⁶t² +
 196.7871602u⁵v⁶t - 471.6846248u⁵v⁶ + 1168.212790u⁵v⁵t³ + 134.9381447u⁵v⁵t² -
 599.4393672u⁵v⁵t + 752.0835370u⁵v⁵ + 386.8314957u⁵v⁴t³ + 37.58791494u⁵v⁴t² -
 219.0874465u⁵v⁴t + 274.0310180u⁵v⁴ - 377.6693697u⁵v³t³ - 116.2455138u⁵v³t² +
 135.0094523u⁵v³t - 132.6882963u⁵v³ - 29.72556641u⁵v²t³ - 35.53845637u⁵v²t² +
 37.13287924u⁵v²t - 50.62106262u⁵v² - 55.38456003u⁵vt³ - 6.687980644u⁵vt² + 13.24127784u⁵vt +
 16.77621554u⁵v + 47.57727922u⁵t³ + 37.98428531u⁵t² - 14.5446445u⁵t - 3.453914175u⁵ -
 225.3291719u⁴v⁸ - 1492.615104u⁴v⁷t - 147.6093630u⁴v⁷ + 110.7356966u⁴v⁶t² - 2163.927390u⁴v⁶t
 + 464.1969368u⁴v⁶ + 386.8314957u⁴v⁵t³ + 37.58791494u⁴v⁵t² - 219.0874465u⁴v⁵t +
 274.0310180u⁴v⁵ - 73.36820000u⁴v⁴t⁴ + 392.6271541u⁴v⁴t³ + 222.2882726u⁴v⁴t² +
 735.4659250u⁴v⁴t - 207.3205267u⁴v⁴ + 83.02988588u⁴v³t⁴ - 118.0842510u⁴v³t³ -
 77.09075609u⁴v³t² + 244.0885057u⁴v³t - 88.19709904u⁴v³ - 37.62483034u⁴v²t⁴ -
 113.7068820u⁴v²t³ - 8.326854722u⁴v²t² - 45.23470569u⁴v²t + 12.09797900u⁴v² -
 77.65166209u⁴vt⁴ - 55.08896234u⁴vt³ + 31.85022557u⁴vt² - 17.02325455u⁴vt + 10.36532594u⁴v +
 28.47777799u⁴t⁴ + 46.28598839u⁴t³ - 2.917811290u⁴t² - 7.358099446u⁴t - 1.944166441u⁴ +
 191.5409281u³v⁸ + 2098.660249u³v⁷t + 3568.090777u³v⁶t + 18.16433328u³v⁶ + 344.9966795u³v⁵t -
 1553.436106u³v⁵ - 1392.615104u³v⁴t - 147.6093630u³v⁴ - 437.8480785u³v³t + 446.8628584u³v³ +
 123.8174512u³v²t + 71.67183278u³v² + 62.08524794u³vt - 49.22376389u³v - 6.539547051u³t -
 6.216856357u³ + 363.0801883u²v⁸ + 3568.090777u²v⁷t + 18.16433328u²v⁷ - 1165.053624u²v⁶t² +
 5312.362070u²v⁶t - 1024.256466u²v⁶ - 71.15855319u²v⁵t² + 196.7871602u²v⁵t - 471.6846248u²v⁵ +
 110.7356966u²v⁴t² - 2163.927390u²v⁴t + 464.1969368u²v⁴ - 78.18545046u²v³t² -
 505.3867129u²v³t + 203.1645374u²v³ + 41.35985267u²v²t² + 199.8129603u²v²t - 54.08669500u²v²
 - 17.33067199u²vt² + 77.24220247u²vt - 21.52580028u²v + 16.53555569u²t² - 10.78477271u²t +
 0.8926140522u² - 672.8504875u¹v⁸ + 344.9966795u¹v⁷t - 1553.436106u¹v⁷ - 71.15855319u¹v⁶t² +
 196.7871602u¹v⁶t - 471.6846248u¹v⁶ + 1168.212790u¹v⁵t³ + 134.9381447u¹v⁵t² -
 599.4393672u¹v⁵t + 752.0835370u¹v⁵ + 386.8314957u¹v⁴t³ + 37.58791494u¹v⁴t² -
 219.0874465u¹v⁴t + 274.0310180u¹v⁴ - 377.6693697u¹v³t³ - 116.2455138u¹v³t² +
 135.0094523u¹v³t - 132.6882963u¹v³ - 29.72556641u¹v²t³ - 35.53845637u¹v²t² +
 37.13287924u¹v²t - 50.62106262u¹v² - 55.38456003u¹vt³ - 6.687980644u¹vt² + 13.24127784u¹vt +
 16.77621554u¹v + 47.57727922u¹t³ + 37.98428531u¹t² - 14.5446445u¹t - 3.453914175u¹ -
 225.3291719u⁰v⁸ - 1492.615104u⁰v⁷t - 147.6093630u⁰v⁷ + 110.7356966u⁰v⁶t² - 2163.927390u⁰v⁶t
 + 464.1969368u⁰v⁶ + 386.8314957u⁰v⁵t³ + 37.58791494u⁰v⁵t² - 219.0874465u⁰v⁵t +
 274.0310180u⁰v⁵ - 73.36820000u⁰v⁴t⁴ + 392.6271541u⁰v⁴t³ + 222.2882726u⁰v⁴t² +
 735.4659250u⁰v⁴t - 207.3205267u⁰v⁴ + 83.02988588u⁰v³t⁴ - 118.0842510u⁰v³t³ -
 77.09075609u⁰v³t² + 244.0885057u⁰v³t - 88.19709904u⁰v³ - 37.62483034u⁰v²t⁴ -
 113.7068820u⁰v²t³ - 8.326854722u⁰v²t² - 45.23470569u⁰v²t + 12.09797900u⁰v² -
 77.65166209u⁰vt⁴ - 55.08896234u⁰vt³ + 31.85022557u⁰vt² - 17.02325455u⁰vt + 10.36532594u⁰v +
 28.47777799u⁰t⁴ + 46.28598839u⁰t³ - 2.917811290u⁰t² - 7.358099446u⁰t - 1.944166441u⁰ +
 191.5409281u⁰ + 2098.660249u⁰t + 3568.090777u⁰t + 18.16433328u⁰ + 344.9966795u⁰t -
 1553.436106u⁰ - 1392.615104u⁰t - 147.6093630u⁰ - 437.8480785u⁰t + 446.8628584u⁰ +
 123.8174512u⁰t + 71.67183278u⁰ + 62.08524794u⁰t - 49.22376389u⁰ - 6.539547051u⁰t -
 6.216856357u⁰ + 363.0801883u⁰t + 3568.090777u⁰t + 18.16433328u⁰ - 1165.053624u⁰t² +
 5312.362070u⁰t - 1024.256466u⁰ - 71.15855319u⁰t² + 196.7871602u⁰t - 471.6846248u⁰ +
 110.7356966u⁰t² - 2163.927390u⁰t + 464.1969368u⁰ - 78.18545046u⁰t² -
 505.3867129u⁰t + 203.1645374u⁰ + 41.35985267u⁰t² + 199.8129603u⁰t - 54.08669500u⁰
 - 17.33067199u⁰t² + 77.24220247u⁰t - 21.52580028u⁰ + 16.53555569u⁰t² - 10.78477271u⁰t +
 0.8926140522u⁰ - 672.8504875u⁰ + 344.9966795u⁰t - 1553.436106u⁰ - 71.15855319u⁰t² +
 196.7871602u⁰t - 471.6846248u⁰ + 1168.212790u⁰t³ + 134.9381447u⁰t² -
 599.4393672u⁰t + 752.0835370u⁰ + 386.8314957u⁰t³ + 37.58791494u⁰t² -
 219.0874465u⁰t + 274.0310180u⁰ - 377.6693697u⁰t³ - 116.2455138u⁰t² +
 135.0094523u⁰t - 132.6882963u⁰ - 29.72556641u⁰t³ - 35.53845637u⁰t² +
 37.13287924u⁰t - 50.62106262u⁰ - 55.38456003u⁰t³ - 6.687980644u⁰t² + 13.24127784u⁰t +
 16.77621554u⁰ + 47.57727922u⁰t³ + 37.98428531u⁰t² - 14.5446445u⁰t - 3.453914175u⁰ -
 225.3291719u⁰ - 1492.615104u⁰t - 147.6093630u⁰ + 110.7356966u⁰t² - 2163.927390u⁰t
 + 464.1969368u⁰ + 386.8314957u⁰t³ + 37.58791494u⁰t² - 219.0874465u⁰t +
 274.0310180u⁰ - 73.36820000u⁰t⁴ + 392.6271541u⁰t³ + 222.2882726u⁰t² +
 735.4659250u⁰t - 207.3205267u⁰ + 83.02988588u⁰t⁴ - 118.0842510u⁰t³ -
 77.09075609u⁰t² + 244.0885057u⁰t - 88.19709904u⁰ - 37.62483034u⁰t⁴ -
 113.7068820u⁰t³ - 8.326854722u⁰t² - 45.23470569u⁰t + 12.09797900u⁰ -
 77.65166209u⁰t⁴ - 55.08896234u⁰t³ + 31.85022557u⁰t² - 17.02325455u⁰t + 10.36532594u⁰ +
 28.47777799u⁰t⁴ + 46.28598839u⁰t³ - 2.917811290u⁰t² - 7.358099446u⁰t - 1.944166441u⁰ +
 191.5409281u⁰ + 2098.660249u⁰t + 3568.090777u⁰t + 18.16433328u⁰ + 344.9966795u⁰t -
 1553.436106u⁰ - 1392.615104u⁰t - 147.6093630u⁰ - 437.8480785u⁰t + 446.8628584u⁰ +
 123.8174512u⁰t + 71.67183278u⁰ + 62.08524794u⁰t - 49.22376389u⁰ - 6.539547051u⁰t -
 6.216856357u⁰ + 363.0801883u⁰t + 3568.090777u⁰t + 18.16433328u⁰ - 1165.053624u⁰t² +
 5312.362070u⁰t - 1024.256466u⁰ - 71.15855319u⁰t² + 196.7871602u⁰t - 471.6846248u⁰ +
 110.7356966u⁰t² - 2163.927390u⁰t + 464.1969368u⁰ - 78.18545046u⁰t² -
 505.3867129u⁰t + 203.1645374u⁰ + 41.35985267u⁰t² + 199.8129603u⁰t - 54.08669500u⁰
 - 17.33067199u⁰t² + 77.24220247u⁰t - 21.52580028u⁰ + 16.53555569u⁰t² - 10.78477271u⁰t +
 0.8926140522u⁰ - 672.8504875u⁰ + 344.9966795u⁰t - 1553.436106u⁰ - 71.15855319u⁰t² +
 196.7871602u⁰t - 471.6846248u⁰ + 1168.212790u⁰t³ + 134.9381447u⁰t² -
 599.4393672u⁰t + 752.0835370u⁰ + 386.8314957u⁰t³ + 37.58791494u⁰t² -
 219.0874465u⁰t + 274.0310180u⁰ - 377.6693697u⁰t³ - 116.2455138u⁰t² +
 135.0094523u⁰t - 132.6882963u⁰ - 29.72556641u⁰t³ - 35.53845637u⁰t² +
 37.13287924u⁰t - 50.62106262u⁰ - 55.38456003u⁰t³ - 6.687980644u⁰t² + 13.24127784u⁰t +
 16.77621554u⁰ + 47.57727922u⁰t³ + 37.98428531u⁰t² - 14.5446445u⁰t - 3.453914175u⁰ -
 225.3291719u⁰ - 1492.615104u⁰t - 147.6093630u⁰ + 110.7356966u⁰t² - 2163.927390u⁰t
 + 464.1969368u⁰ + 386.8314957u⁰t³ + 37.58791494u⁰t² - 219.0874465u⁰t +
 274.0310180u⁰ - 73.36820000u⁰t⁴ + 392.6271541u⁰t³ + 222.2882726u⁰t² +
 735.4659250u⁰t - 207.3205267u⁰ + 83.02988588u⁰t⁴ - 118.0842510u⁰t³ -
 77.09075609u⁰t² + 244.0885057u⁰t - 88.19709904u⁰ - 37.62483034u⁰t⁴ -
 113.7068820u⁰t³ - 8.326854722u⁰t² - 45.23470569u⁰t + 12.09797900u⁰ -
 77.65166209u⁰t⁴ - 55.08896234u⁰t³ + 31.85022557u⁰t² - 17.02325455u⁰t + 10.36532594u⁰ +
 28.47777799u⁰t⁴ + 46.28598839u⁰t³ - 2.917811290u⁰t² - 7.358099446u⁰t - 1.944166441u⁰ +
 191.5409281u⁰ + 2098.660249u⁰t + 3568.090777u⁰t + 18.16433328u⁰ + 344.9966795u⁰t -
 1553.436106u⁰ - 1392.615104u⁰t - 147.6093630u⁰ - 437.8480785u⁰t + 446.8628584u⁰ +
 123.8174512u⁰t + 71.67183278u⁰ + 62.08524794u⁰t - 49.22376389u⁰ - 6.539547051u⁰t -
 6.216856357u⁰ + 363.0801883u⁰t + 3568.090777u⁰t + 18.16433328u⁰ - 1165.053624u⁰t² +
 5312.362070u⁰t - 1024.256466u⁰ - 71.15855319u⁰t² + 196.7871602u⁰t - 471.6846248u⁰ +
 110.7356966u⁰t² - 2163.927390u⁰t + 464.1969368u⁰ - 78.185

Bekannte Kusszahlen



$$\tau_8 = 240$$
$$\tau_{24} = 196560$$


Odlyzko, Sloane und Levenshtein (1979)
mit linearer Programmierung
(relativ leicht, sehr elegant)



$$\tau_4 = 24$$

Musin (2008)
mit linearer Programmierung und Tricks
(nicht so leicht)

IV.1 Das Kusszahlproblem in Dimension 8




Packungsgraph

$$G(n, (t, 1)) = (V, E)$$

$$V = S^{n-1} = \{x \in \mathbb{R}^n : x^T x = 1\}$$

$$\{x, y\} \in E \iff x^T y \in (t, 1)$$



unabhängige Mengen in $G(n, (t, 1))$
= mögliche Berührungspunkte

$$\text{Also: } \tau_n = \alpha(G(n, (t, 1)))$$

Berechnen von α ist i.A. schwierig

Die ϑ -Funktion ...

- ★ wurde 1979 von Lovász in der berühmten Arbeit
“On the Shannon capacity of a graph” eingeführt

Strategie: Verallgemeinere ϑ auf unendliche Graphen

- ★ kann durch eine Hierarchie von größer werdenden SDPs,
die gegen α konvergieren, verbessert werden.
(Lovász-Schrijver 1991, Lasserre 2001)

Das Original: für $|V| < \infty$

$$\begin{aligned} \vartheta'(G) = \min \quad & t \\ & Y \in \mathcal{S}_{\succeq 0}^V \\ & Y_{x,x} = t - 1 \text{ für } x \in V \\ & Y_{x,y} \leq -1 \text{ für } \{x, y\} \notin E \end{aligned}$$

Verallgemeinerung: für $|V| = \infty$

$$\begin{aligned} \vartheta'(G) = \inf \quad & t \\ & Y \in \mathcal{C}(V \times V)_{\succeq 0} \\ & Y(x, x) = t - 1 \text{ für } x \in V \\ & Y(x, y) \leq -1 \text{ für } \{x, y\} \notin E \end{aligned}$$

positiv semidefinite, stetige Hilbert-Schmidt Kerne

$$\alpha(G) \leq \vartheta'(G) = \inf \quad t$$

$$Y \in \mathcal{C}(V \times V)_{\geq 0}$$

$$Y(x, x) = t - 1 \text{ für } x \in V$$

$$Y(x, y) \leq -1 \text{ für } \{x, y\} \notin E$$

Sei $C \subseteq V$ unabhängig

und Y, t eine zulässige Lösung von $\vartheta'(G)$

$$0 \leq \sum_{x \in C} \sum_{y \in C} Y(x, y)$$

$$= \underbrace{\sum_{x \in C} Y(x, x)}_{=|C|(t-1)} + \underbrace{\sum_{x \neq y} Y(x, y)}_{\leq (-1)(|C|^2 - |C|)}$$

$$\leq |C|(t-1) - (|C|^2 - |C|) \quad \implies |C| \leq t$$

Frage: Wie berechnet man $\vartheta'(G)$?

Antwort: Verwende Symmetrie von G !

$\text{Aut}(G(n, (t, 1)))$: orthogonale Gruppe $O(n)$

$$O(n) = \{A \in \mathbb{R}^{n \times n} : A^T A = I_n\}$$

Falls $Y \in \mathcal{C}(S^{n-1} \times S^{n-1})_{\geq 0}$ zulässig, dann auch \bar{Y} :

$$\bar{Y}(x, y) = \int_{A \in O(n)} Y(Ax, Ay) d\mu(A).$$

Also: Können uns auf $O(n)$ -invariante Kerne beschränken.


$$\forall A \in O(n) \forall x, y \in S^{n-1} : Y(Ax, Ay) = Y(x, y)$$

Theorem von Schoenberg (1942)

$Y \in \mathcal{C}(S^{n-1} \times S^{n-1})$ ist $O(n)$ -invariant g.d.w.

$$Y(x, y) = \sum_{k=0}^{\infty} f_k P_k^{((n-3)/2, (n-3)/2)}(x^T y) \quad f_k \geq 0$$

Jacobi Polynome



ϑ' als semi-infinites lineares Programm

$$\begin{aligned}\vartheta'(G(n, (t, 1))) &= \inf \quad t \\ &f_0 \geq 0, f_1 \geq 0, \dots \\ &\sum_{k=0}^{\infty} f_k P^{((n-3)/2, (n-3)/2)}(1) = t - 1 \\ &\sum_{k=0}^{\infty} f_k P^{((n-3)/2, (n-3)/2)}(u) \leq -1 \text{ für } u \in [-1, t]\end{aligned}$$

$$\vartheta'(G(8, (1/2, 1))) = 240 = \tau_8$$

$$\vartheta'(G(24, (1/2, 1))) = 196560 = \tau_{24}$$

ABER

$$\vartheta'(G(3, (1/2, 1))) > 13$$

$$\vartheta'(G(4, (1/2, 1))) > 24$$

Normalisierte Jacobi Polynome mit (α, α) , $\alpha = (n - 3)/2$

$$P_0^n(t) = P_0^{(\alpha, \alpha)}(t) = 1,$$

$$P_1^n(t) = P_1^{(\alpha, \alpha)}(t) = t,$$

$$P_2^n(t) = P_2^{(\alpha, \alpha)}(t) = \frac{n}{n-1}t^2 - \frac{1}{n-1}.$$

```
sage: x = PolynomialRing(QQ, 'x').gen()
sage: n = 4
sage: a = (n-3)/2
sage: for k in range(0,5):
sage:     print(jacobi_P(k,a,a,x)/jacobi_P(k,a,a,1))
```

1

x

$4/3*x^2 - 1/3$

$2*x^3 - x$

$16/5*x^4 - 12/5*x^2 + 1/5$

$$\tau_8 \geq 240$$

alle $\binom{8}{2} 2^2 = 112$ Permutationen und Vorzeichenwechsel von

$$\left(\frac{1}{\sqrt{2}}, \frac{1}{\sqrt{2}}, 0, 0, 0, 0, 0 \right)^T$$

alle $2^7 = 128$ geraden Vorzeichenwechsel von

$$\left(\frac{1}{\sqrt{8}}, \frac{1}{\sqrt{8}}, \frac{1}{\sqrt{8}}, \frac{1}{\sqrt{8}}, \frac{1}{\sqrt{8}}, \frac{1}{\sqrt{8}}, \frac{1}{\sqrt{8}} \right)^T$$

Mögliche Skalarprodukte:

$$\left\{ -1, -\frac{1}{2}, 0, \frac{1}{2}, 1 \right\}.$$

$$\tau_8 \leq 240$$

“Glücklicher” Ansatz

$$F(t) = -1 + \beta(t+1) \left(t + \frac{1}{2}\right)^2 t^2 \left(t - \frac{1}{2}\right)$$

Eigenschaften von F :

$$F(-1) = F(-1/2) = F(0) = F(1/2) = -1$$

$$F(u) \leq -1 \text{ für } u \in [-1, 1/2]$$

$$\text{Mit } \beta = \frac{320}{3}: F(1) = t - 1 = 240 - 1 = 239$$

$$\text{Überprüfe: } F(u) = \sum_{k=0}^6 f_k P_k^8(u) \text{ mit } f_k \geq 0$$

$$\implies Y(x, y) = F(x^\top y) \text{ zulässig für } \vartheta'$$

$$\implies \tau_8 \leq \vartheta'(G(8, (1/2, 1))) \leq 240$$

Kapitel V Determinantenmaximierung

§ 1 Minkowskis Determinantenungleichung

Satz 1 Die Fkt.

$$F: S_{>0}^m \rightarrow \mathbb{R}, \quad X \mapsto -(\det X)^{1/n}$$

ist konvex. Zusätzlich gilt

$$F(\alpha X + (1-\alpha)Y) \leq \alpha F(X) + (1-\alpha)F(Y), \quad \alpha \in (0,1),$$

falls X, Y lin. unabh. sind.

Korollar 2 (Minkowski, 1905)

Für $X, Y \in S_{>0}^m$ gilt

$$(\det(X+Y))^{1/n} \geq (\det X)^{1/n} + (\det Y)^{1/n}.$$

Bew.: Verwende Satz 1 mit $\alpha = \frac{1}{2}$.

Zum Beweis von Satz 1 benötigen wir zwei Lemmata:

Lemma 3 Seien $X \in S_{>0}^m$, $Y \in S^m$ gegeben. Dann gibt es eine Matrix $S \in GL_n(\mathbb{R})$, so dass

$$S^T X S \quad \text{und} \quad S^T Y S$$

beide Diagonalmatrizen sind.

Bew.: Spektralzerlegung von X :

$$\exists A \in O(n) : A^T X A = \text{diag}(\lambda_1, \dots, \lambda_n).$$

Dann ist

$$\begin{bmatrix} 1/\sqrt{\lambda_1} & & \\ & \dots & \\ & & 1/\sqrt{\lambda_n} \end{bmatrix}^T \underbrace{A^T X A}_{T \in GL_n(\mathbb{R})} \begin{bmatrix} 1/\sqrt{\lambda_1} & & \\ & \dots & \\ & & 1/\sqrt{\lambda_n} \end{bmatrix} = I_n.$$

Spektralzerlegung von $T^T Y T$:

$$\exists B \in O(n) : B^T T^T Y T B = \text{diag}(\mu_1, \dots, \mu_n).$$

Definiere $S = TB$.

Lemma 4 (AM-GM-Ungleichung)

a) Für $x_1, \dots, x_n \geq 0$ gilt

$$\left(\prod_{i=1}^n x_i \right)^{1/n} \leq \frac{1}{n} \sum_{i=1}^n x_i,$$

wobei Gleichheit gilt gdw. $x_1 = \dots = x_n$.

[Das Volumen eines Parallelepipeds mit Kantenlängensumme $\sum_{i=1}^n x_i = S$ ist maximal gdw. $x_1 = \dots = x_n = \frac{S}{n}$ gilt.]

b) Für $x_1, \dots, x_n > 0, y_1, \dots, y_n > 0$ gilt

$$\left(\prod_{i=1}^n x_i \right)^{1/n} + \left(\prod_{i=1}^n y_i \right)^{1/n} \leq \left(\prod_{i=1}^n (x_i + y_i) \right)^{1/n},$$

wobei Gleichheit gilt gdw. $(x_1, \dots, x_n), (y_1, \dots, y_n)$ linear abhängig sind.

Bew.: b) folgt aus a): Aufgabe 11.2.

a) George Pólya (1887-1985) bester mathematischer Traum:

Es ist $1 + y \leq e^y$ für alle $y \in \mathbb{R}$. Also $y \leq e^{y-1}$ und

$$y^{\frac{1}{n}} \leq (e^{y-1})^{\frac{1}{n}} = e^{\frac{y}{n} - \frac{1}{n}}. \text{ Setze } y_i = \frac{x_i}{\frac{1}{n} \sum_j x_j}. \text{ Dann}$$

$$\left(\prod_{i=1}^n y_i \right)^{1/n} \leq e^{\frac{1}{n} \sum_{i=1}^n y_i - 1} = e^0 = 1.$$

Somit folgt die Beh., wobei $1 + y = e^y$ gdw. $y = 0$.

Bew.: (Satz 1)

Seien $X, Y \in S_{>0}^m$, $\alpha \in (0, 1)$ gegeben. Falls X, Y lin. abh. sind, gilt

$$F(\alpha X + (1-\alpha)Y) = \alpha F(X) + (1-\alpha)F(Y),$$

Wie man durch direktes Nachrechnen überprüft. Seien also X, Y lin. unabh. Nach Lemma 3 gibt es $S \in GL_n(\mathbb{R})$ mit

$$S^T X S = \text{diag}(x_1, \dots, x_n), \quad S^T Y S = \text{diag}(y_1, \dots, y_n).$$

Definiere $T = S^{-1}$. Dann ist

$$F(\alpha X + (1-\alpha)Y) = - \det \left(\alpha T^T \text{diag}(x_1, \dots, x_n) T + (1-\alpha) T^T \text{diag}(y_1, \dots, y_n) T \right)^{1/n}$$

$$= - (\det T^T T)^{1/n} \left(\prod_{i=1}^n (\alpha x_i + (1-\alpha) y_i) \right)^{1/n}$$

AMGM

$$< - (\det T^T T)^{1/n} \left(\left(\prod_{i=1}^n \alpha x_i \right)^{1/n} + \left(\prod_{i=1}^n (1-\alpha) y_i \right)^{1/n} \right)$$

$$= \alpha (- \det (T^T \text{diag}(x_1, \dots, x_n) T)^{1/n}) + (1-\alpha) (- \det (T^T \text{diag}(y_1, \dots, y_n) T)^{1/n})$$

$$= \alpha F(X) + (1-\alpha)F(Y).$$

□

§ 2 Konvexe, spektrale Funktionen

Die Fkt. $F(X) = -(\det X)^{1/n}$ ist konvex und hängt nur von den Eigenwerten von X ab (d.h. $F(A^T X A) = F(X) \forall A \in O(n)$).

Ziel: Charakterisierung all solcher Fkt.


Def. 1: a) Das Schur-Horn Orbitop von $X \in S^m$ ist

$$SH(X) = \text{conv} \{ A X A^T : A \in O(n) \} \subseteq S^m.$$

b) Das Permutaeder von $(x_1, \dots, x_n) \in \mathbb{R}^n$ ist

$$TT(x_1, \dots, x_n) = \text{conv} \{ (x_{\sigma(1)}, \dots, x_{\sigma(n)}) : \sigma \in S_n \}.$$

Bsp.: $TT(1, 2, 3)$ ist ein Sechseck.



Satz 2 Sei $X \in S^n$ mit Eigenwerten $\lambda_1, \dots, \lambda_n$. Betrachte

Projektion $\text{Diag} : S^n \rightarrow \mathbb{R}^n$, $\text{Diag}(Y) = (Y_{11}, \dots, Y_{nn})$.

Dann gilt

$$\text{Diag}(SH(X)) = TT(\lambda_1, \dots, \lambda_n).$$

Bew.: " \supseteq ": Das Bild $\text{Diag}(SH(X))$ ist konvex, weil Diag linear ist. Außerdem enthält das Bild die Vektoren $(\lambda_{\sigma(1)}, \dots, \lambda_{\sigma(n)})$, $\sigma \in S_n$ (Warum?). Da das Permutaxeder $\Pi(\lambda_1, \dots, \lambda_n)$ die kleinste konvexe Menge ist, die diese Vektoren enthält, folgt die Inklusion.

" \subseteq ": Spektralzerlegung $X = \sum_{j=1}^n \lambda_j \mu_j \mu_j^T$.

Sei $A \in \mathcal{O}(n)$. Setze $Y = AXA^T$. Dann ist

$$\begin{aligned} Y_{ii} &= e_i^T Y e_i = e_i^T \sum_{j=1}^n \lambda_j A \mu_j \mu_j^T A^T e_i \\ &= \sum_{j=1}^n \lambda_j \underbrace{(e_i^T A \mu_j)^2}_{=: S_{ij}} \end{aligned}$$

Beh.: Die Matrix $(S_{ij})_{1 \leq i, j \leq n}$ ist doppelt stochastisch.

Bew.: - $S_{ij} \geq 0$: \checkmark

- $\sum_{i=1}^n S_{ij} = 1$: $\sum_{i=1}^n (e_i^T A \mu_j)^2 = \|A \mu_j\|^2 = 1$.

- $\sum_{j=1}^n S_{ij} = 1$: genauso.

Nach dem Theorem von Birkhoff und von Neumann
 (Matchingpolytop des vollständigen bipartiten Graphen $K_{n,n}$) gilt:

$$\{S \in \mathbb{R}^{n \times n} : S \text{ doppelt-stochastisch}\} = \text{conv} \{P^\sigma, \sigma \in S_n\},$$

$$P^\sigma \text{ Permutationsmatrix, } P_{ij}^\sigma = \begin{cases} 1, & \text{falls } i = \sigma(j) \\ 0, & \text{sonst.} \end{cases}$$

Also gibt es Koeffizienten $\alpha_\sigma \geq 0$, $\sum_{\sigma \in S_n} \alpha_\sigma = 1$ mit

$$S = \sum_{\sigma} \alpha_\sigma P^\sigma. \text{ Einsetzen liefert:}$$

$$Y_{ii} = \sum_{j=1}^n \lambda_j \sum_{\sigma \in S_n} \alpha_\sigma (P^\sigma)_{ij}$$

$$= \sum_{\sigma \in S_n} \alpha_\sigma \sum_{j=1}^n \lambda_j (P^\sigma)_{ij}$$

$$= \sum_{\sigma \in S_n} \alpha_\sigma \lambda_{\sigma^{-1}(i)},$$

$$\text{also } (Y_{11}, \dots, Y_{nn}) \in \Pi(\lambda_1, \dots, \lambda_n).$$

□

Def. 3 Eine Fkt. $F: S^n \rightarrow \mathbb{R} \cup \{\infty\}$ heißt spektral,
falls $F(X)$ nur von den Eigenwerten $\lambda_1, \dots, \lambda_n$ von X abhängt.
D.h. $F(X) = F(AXA^T)$ für alle $A \in O(n)$ gilt.

Eine spektrale Fkt. F definiert eine symmetrische Fkt.
 $f: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{\infty\}$ durch $F(X) = f(\lambda_1, \dots, \lambda_n)$, wobei
 f invariant unter Permutation der Koordinaten ist.

Satz 4 (Davis 1957)

$F: S^n \rightarrow \mathbb{R} \cup \{\infty\}$ ist konvex und spektral \iff
 $f: \mathbb{R}^n \rightarrow \mathbb{R} \cup \{\infty\}$ ist konvex und symmetrisch.

Bew.: " \implies " f symmetrisch: \checkmark

f konvex: Sei $X = \text{diag}(x_1, \dots, x_n)$, $Y = \text{diag}(y_1, \dots, y_n)$,
 $\alpha \in [0, 1]$. Dann

$$\begin{aligned} & f(\alpha(x_1, \dots, x_n) + (1-\alpha)(y_1, \dots, y_n)) \\ &= F(\alpha X + (1-\alpha)Y) \\ &\leq \alpha F(X) + (1-\alpha)F(Y) \\ &= \alpha f(x_1, \dots, x_n) + (1-\alpha)f(y_1, \dots, y_n). \end{aligned}$$

" \Leftarrow ": Zeige, dass

$$F(X) = \max_{A \in \mathcal{O}(n)} f(\text{Diag}(AXA^T)) \quad (*)$$

gilt. Dann ist F konvex, weil es das Maximum der Familie von konvexen Fkt.

$$g_A: S^n \rightarrow \mathbb{R}, \quad g_A(X) = f(\text{Diag}(AXA^T))$$

ist.

" \leq ": in (*). Spektralzerlegung $X = \sum_i \lambda_i \mu_i \mu_i^T$.

Definiere $A = \begin{bmatrix} -\mu_1 & & \\ & \ddots & \\ -\mu_n & & \end{bmatrix} \in \mathcal{O}(n)$. Dann ist

$$F(X) = f(\lambda_1, \dots, \lambda_n) = f(\text{Diag}(AXA^T)).$$

$$\underline{\text{"} \geq \text{"}}: \text{ in } (*) \quad \max_{A \in \mathcal{O}(n)} f(\text{Diag}(AXA^T)) \leq \max_{Y \in \text{SH}(X)} f(\text{Diag}(Y))$$

$$\stackrel{\text{Satz 2}}{=} \max_{(x_1, \dots, x_n) \in \Pi(\lambda_1, \dots, \lambda_n)} f(x_1, \dots, x_n)$$

$$\begin{aligned} & \stackrel{f \text{ sym. + konv.}}{=} f(\lambda_1, \dots, \lambda_n) \\ & = F(X). \end{aligned}$$

□

Korollar 5 $F(X) = \begin{cases} -(\det X)^{1/n}, & \text{falls } X \geq 0 \\ \infty & , \text{sonst} \end{cases}$

ist konvex und spektral.

Bew.: Es genügt z.z., dass $f(x_1, \dots, x_n) = -\left(\prod_{i=1}^n x_i\right)^{1/n}$

symmetrisch und konvex ist.

Symmetrie: ✓

Konvexität: AM-GM-Ungleichung.

§3 MAXDET Probleme

Satz 1 Die Menge

$$D^n = \left\{ (X, s) \in S^n \times \mathbb{R} : X \geq 0, (\det X)^{1/n} \geq s \right\}$$

ist ein ordentlicher konvexer Kegel.

Bew.: * D^n ist konvexer Kegel:

Seien $\alpha \geq 0$, $(X, s), (Y, t) \in D^n$. Dann

$$\begin{aligned} (\alpha X, \alpha s) &\in D^n, \text{ weil } \alpha X \geq 0 \text{ und } (\det \alpha X)^{1/n} = \\ &= \alpha (\det X)^{1/n} \geq \alpha s. \end{aligned}$$

$(X+Y, s+t) \in \mathcal{D}^n$, weil

$$(\det(X+Y))^{1/n} \stackrel{\text{Minkowski}}{\geq} (\det X)^{1/n} + (\det Y)^{1/n} \geq s+t.$$

* \mathcal{D}^n ist spitz: Ang. $(X, s), (-X, -s) \in \mathcal{D}^n$.

Weil $S_{\geq 0}^n$ spitz ist, ist $X=0$. Desweiteren

$$0 = (\det X)^{1/n} \geq s \quad \text{und} \quad 0 = (\det(-X))^{1/n} \geq -s.$$

Also $s=0$.

* \mathcal{D}^n hat nicht-leeren Inneren: Betrachte eine offene Umgebung von $(I_n, 1)$.

* \mathcal{D}^n ist abgeschlossen: \checkmark weil \det stetig. □

Def. 2 primales MAXDET Problem

$$p^* = \sup \langle (C, c), (X, s) \rangle$$

$$(X, s) \in \mathcal{D}^n$$

$$\langle (A_j, a_j), (X, s) \rangle = b_j, \quad j \in [m].$$

Falls $(C, c) = (0, 1)$ vereinfacht sich das zu:

$$\text{und } a_j = 0$$

$$\begin{aligned} \sup_s \quad & X \geq 0, \quad (\det X)^{1/n} \geq s \quad \Leftrightarrow \quad \sup (\det X)^{1/n} \\ & \langle A_j, X \rangle = b_j, \quad j \in [m] \quad \quad \quad X \geq 0 \\ & \quad \quad \quad \quad \quad \quad \quad \quad \quad \quad \quad \quad \langle A_j, X \rangle = b_j. \end{aligned}$$

Satz 3

$$(\mathcal{D}^n)^* = \left\{ (Y, t) \in S^n \times \mathbb{R} : Y \geq 0, \quad (\det Y)^{1/n} \geq -\frac{t}{n} \right\}.$$

Lemma 4 Sei $X \in S_{\geq 0}^n$. Dann

$$(*) \quad \text{Tr}(X) - n (\det X)^{1/n} \geq 0,$$

mit Gleichheit gdw. X ein Vielfaches von I_n .

Bew.: O.B.d.A. $X = \text{diag}(x_1, \dots, x_n)$. Dann

$$(*) \Leftrightarrow \sum_{i=1}^n x_i - n \left(\prod_{i=1}^n x_i \right)^{1/n} \geq 0 \quad (\text{AM-GM Ungleichung}).$$

Bew.: (Satz 3)

" \sup ": Sei (Y, t) mit $Y \in S_{\geq 0}^n$ und $(\det Y)^{1/n} \geq -\frac{t}{n}$.

Sei $(X, s) \in \mathcal{D}^n$. Dann ist

$$\langle (X, s), (Y, t) \rangle = \text{Tr}(XY) + st.$$

Möchte Lemma 4 anwenden. Problem: XY soll nicht symmetrisch. Ausweg: Cholesky-Zerlegung $X = LL^T$.

Dann $\text{Tr}(XY) = \text{Tr}(LL^TY) = \text{Tr}(L^TYL)$ und $L^TYL \geq 0$.

Also

$$\begin{aligned} \text{Tr}(XY) + st &= \text{Tr}(L^TYL) + st \\ &\geq n \det(L^TYL)^{1/n} + st \\ &= n \det(L^TL)^{1/n} \det(Y)^{1/n} + st \\ &\geq n \left(-\frac{t}{n}\right) s + st \\ &= 0. \end{aligned}$$

⇐: Sei $(Y, t) \in (\mathcal{D}^n)^*$. Dann ist für $(X, 0) \in \mathcal{D}^n$:

$$0 \leq \langle X, Y \rangle + t \cdot 0 = \langle X, Y \rangle.$$

Weil $(S_{\geq 0}^n)^* = S_{\geq 0}^n$ folgt $Y \geq 0$.

Nun sei $(X, s) \in \mathcal{D}^n$ beliebig. Dann, mit $s = (\det X)^{1/n}$ und $X \succ 0$

$$0 \leq \text{Tr}(XY) + (\det X)^{1/n} \cdot t \Rightarrow -t \leq \frac{\text{Tr}(XY)}{(\det X)^{1/n}}.$$

Minimiere die rechte Seite $\frac{\text{Tr}(XY)}{(\det X)^{1/n}}$ (in Abhängigkeit von X)

Falls Y positiv semidefinit, aber nicht definit, dann ist das Infimum 0. (Warum?)

Falls Y pos. definit, dann ist das Minimum $(\det Y)^{1/n} \cdot n$, und wird bei $X = Y^{-1}$ angenommen (AM-GM-Ungleichung).

Also $-t \leq n (\det Y)^{1/n}$.

Wie gewünscht. □

Def. 5 duales MAXDET Problem

$$d^* = \inf \sum_{j=1}^m y_j b_j$$

$$\sum_{j=1}^m y_j (A_j, a_j) - (c, c) \in (\mathcal{D}^n)^*$$

Das Dualitätstheorem I.5.2 gilt auch hier.

Besonders hilfreich: Optimalitätskriterium für MAXDET.

Satz 6 Ang. $p^* = d^*$ und ang. (X, s) ist zulässige Lösung für primale MAXDET und (y_1, \dots, y_m) ist zulässig für duale MAXDET.

$(X, s), (y_1, \dots, y_m)$ sind beide optimal \Leftrightarrow

i) $(\sum y_j A_j - c)^{-1} = X$

ii) $s = (\det X)^{1/n}$

iii) $-\frac{\sum y_j a_j - c}{n} = (\det Y)^{1/n}$.

Bew.: folgt aus Gleichheitbed. von Lemma 4. & Thm. I.5.2

$$\begin{aligned} 0 &= \langle (X, s), (\sum y_j A_j - c, \sum y_j a_j - c) \rangle \\ &= \text{Tr}(X (\sum y_j A_j - c)) + s (\sum y_j a_j - c) \\ &\geq n (\det X)^{1/n} (\det (\sum y_j A_j - c))^{1/n} + s (\sum y_j a_j - c) \\ &\geq n s \left(- \left(\frac{\sum y_j a_j - c}{n} \right) \right) + s (\sum y_j a_j - c) \\ &= 0. \end{aligned}$$

□

§ 4 Approximation von Polytopen durch Ellipsoide


Def. 1 $A \in S_{>0}^m$, $x \in \mathbb{R}^n$ definieren das Ellipsoid

$$\mathcal{E}(A, x) = \{y \in \mathbb{R}^n : (y-x)^T A^{-1} (y-x) \leq 1\}.$$

Bsp.: $\mathcal{E}(\pi^2 I_n, 0) = \pi B_n$, $B_n = \{y \in \mathbb{R}^n : \|y\| \leq 1\}$

n -dim. Einheitskugel.

Eigenschaften: Spektralzerlegung $A = \sum_{i=1}^n \lambda_i \mu_i \mu_i^T$



μ_i = Hauptachsenrichtungen

$$\begin{aligned} \text{vol } \mathcal{E}(A, x) &= \sqrt{\det A} \text{ vol } B_n \\ &= \frac{\pi^{n/2}}{\Gamma(\frac{n}{2} + 1)} \end{aligned}$$

Ellipsoid als affin lineares Bild der Einheitskugel:

$$\mathcal{E}(A^2, x) = \{Ay + x : y \in B_n\}.$$

Satz 2 (innere Approximation)

Das Ellipsoid $\mathcal{E}(A^2, x)$ ist in dem Polytop

$$P = \{ y \in \mathbb{R}^n : a_1^T y \leq b_1, \dots, a_m^T y \leq b_m \}$$

enthalten (d.h. $\mathcal{E}(A^2, x) \subseteq P$) gdw.

$$\|Aa_j\| \leq b_j - a_j^T x \quad \forall j \in [m].$$

Bew.:

$$\forall y : \|y\| \leq 1 \quad a_j^T (Ay + x) \leq b_j \quad j = 1, \dots, m$$

$$\Leftrightarrow \max_{\substack{y \in \mathbb{R}^n \\ \|y\| \leq 1}} a_j^T Ay \leq b_j - a_j^T x, \quad j = 1, \dots, m.$$

Nach Cauchy-Schwarz ist das Maximum gleich

$$\max_{\|y\| \leq 1} (Aa_j)^T y = (Aa_j)^T \frac{Aa_j}{\|Aa_j\|} = \|Aa_j\|,$$

und die Beh. folgt.

Satz 3 (äußere Approximation)

Das Ellipsoid $\mathcal{E}(A, x)$ enthält das Polytop

$$P = \text{conv}\{x_1, \dots, x_N\} \quad (\text{d.h. } P \subseteq \mathcal{E}(A, x)).$$

gdw. die Matrix $\begin{pmatrix} s & d^T \\ d & A^{-1} \end{pmatrix} \in S_{\geq 0}^{m+1}$ mit $d = A^{-1}x$

und $x_i^T A^{-1} x_i - 2 x_i^T d + s \leq 1 \quad \forall i \in [N].$

Bew.: $x_i \in \mathcal{E}(A, x)$

$$\Leftrightarrow (x_i - x)^T A^{-1} (x_i - x) \leq 1$$

$$\Leftrightarrow x_i^T A^{-1} x_i - 2 x_i^T A^{-1} x + x^T A^{-1} x \leq 1 \quad [d = A^{-1}x]$$

$$\Leftrightarrow x_i^T A^{-1} x_i - 2 x_i^T d + d^T A d \leq 1$$

$$\Leftrightarrow x_i^T A^{-1} x_i - 2 x_i^T d + s \leq 1 \quad \text{mit } s \geq d^T A d.$$

Weil A pos. def. ist die Bed. $s \geq d^T A d$ nach dem

Schurkomplement äquivalent zu $\begin{bmatrix} s & d^T \\ d & A^{-1} \end{bmatrix} \succeq 0$, und

die Beh. folgt.

Beste innere Approximation:

Problem (I): geg.: Polytop $P = \{y \in \mathbb{R}^n : a_1^T y \leq b_1, \dots, a_m^T y \leq b_m\}$.

ges.: Ellipsoid $\mathcal{E}(A^2, x)$ mit
 $P \subseteq \mathcal{E}(A^2, x)$ und $\text{vol } \mathcal{E}(A^2, x)$
maximal.

Formulierung als konisches Programm:

$$\begin{aligned} \max s \\ (A, s) \in \mathcal{D}^m, x \in \mathbb{R}^n \\ \|Aa_j\| \leq b_j - a_j^T x, \quad j \in [m] \end{aligned}$$

$$\begin{aligned} = \max s \\ (A, s) \in \mathcal{D}^m, x \in \mathbb{R}^n, (y_j, t_j) \in \mathcal{L}^{m+1}, j \in [m] \\ y_j = Aa_j, t_j = b_j - a_j^T x, \quad j \in [m] \end{aligned}$$

Problem (I) hat eindeutige Lösung, weil die Fkt.

$F(x) = -(\det x)^{1/n}$ strikt konkav ist entlang von Strecken

$[X, Y]$ mit $X \neq \alpha Y$. (siehe Satz 1.1).

Somit ist auch das Ellipsoid eindeutig bestimmt.

Def. 4 a) Sei P ein Polytop. Das Ellipsoid E mit $E \subseteq P$, das das größte Volumen mit dieser Eigenschaft hat, heißt Loewner-John-Ellipsoid $E_{in}(P)$.

b) Ellipsoid E mit $P \subseteq E$ und minimalem Volumen heißt Loewner-John Ellipsoid $E_{out}(P)$.

Beste äußere Approximation

Problem (Ä): geg.: Polytop $P = \text{conv}\{x_1, \dots, x_N\}$.

ges.: Ellipsoid $E(A, x)$ mit $P \subseteq E(A, x)$ und $\text{vol}(E(A, x))$ minimal.

Formulierung als konisches Programm:

$$\max (\det A^{-1})^{1/n}$$

$$\begin{pmatrix} s & d^T \\ d & A^{-1} \end{pmatrix} \in S_{\geq 0}^{m+1}$$

$$\cancel{x_i^T A^{-1} x_i} \quad x_i^T A^{-1} x_i - 2 x_i^T d + s \leq 1, \quad i \in [N].$$

$$= \max t$$

$$(B, t) \in \mathcal{D}^n, \begin{pmatrix} s & d^T \\ d & B \end{pmatrix} \in \mathcal{S}_{\geq 0}^{n+1}$$

$$s_1, \dots, s_N \geq 0$$

$$x_i^T B x - 2 x_i^T d + s + s_i = 1, \quad i \in [N]$$

$$= \max t$$

$$(B, t) \in \mathcal{D}^n, Y \in \mathcal{S}_{\geq 0}^{n+1}, s \in \mathbb{R}_{\geq 0}^N$$

$$\langle E_{ij}, B \rangle + \langle -E_{i+1, j+1}, Y \rangle = 0 \quad 1 \leq i \leq j \leq n$$

$$\langle \begin{bmatrix} 1 & -x_i^T \\ -x_i & x_i x_i^T \end{bmatrix}, Y \rangle + s_i = 1, \quad i \in [N].$$

Duale MAXDET Programm:

$$\min \sum_{i=1}^N \gamma_i$$

$$\left(\sum z_{ij} E_{ij}, -1 \right) \in (\mathcal{D}^n)^*$$

$$- \sum z_{ij} E_{i+1, j+1} + \sum \gamma_i \begin{bmatrix} 1 & -x_i^T \\ x_i & x_i x_i^T \end{bmatrix} \geq 0,$$

$$\gamma_i \geq 0, \quad i \in [N].$$

Beide Programme strikt zulässig \Rightarrow starke Dualität.

Satz 5 (Johns Optimalitätskriterium (1948))

[Historisch die erste Optimalitätsbed. eines nichtlinearen Optimierungsproblems].

Sei $P \subseteq \mathbb{R}^n$ ein Polytop. Es gilt

$$a) \quad \mathcal{E}_{\text{out}}(P) = B_n \iff P \subseteq B_n,$$

$\exists \lambda_1, \dots, \lambda_M > 0, x_1, \dots, x_M$ Ecken von P :

$$(i) \quad \|x_i\| = 1, \quad i \in [M]$$

$$(ii) \quad \sum_{i=1}^M \lambda_i x_i = 0$$


$$(iii) \quad \sum_{i=1}^M \lambda_i x_i x_i^T = I_n$$

$$b) \quad \mathcal{E}_{\text{in}}(P) = B_n \iff B_n \subseteq P,$$

$\exists \lambda_1, \dots, \lambda_M > 0, x_1, \dots, x_M \in \partial P$:

(i) - (iii) wie oben.

Bem.: * Dass das Loewner-John Ellipsoid gleich B_n ist, kann man immer durch eine affine Transformation von P erreichen.

* Bed. (ii): Nicht alle Vektoren x_1, \dots, x_M liegen auf einer Seite von S^{n-1} , z. B.  ist nicht möglich.

* Bed. (iii): x_1, \dots, x_M verhalten sich wie eine Orthogonalbasis.

$$x^T y = x^T I_n y = \sum_{i=1}^M \lambda_i (x^T x_i) (x_i^T y).$$

* Bed. (ii) & (iii): $M \geq n+1$.

Bew.: b) folgt aus a) durch Übergang zum polaren Polytop.

$$P^* = \{ y \in \mathbb{R}^n : x^T y \leq 1 \quad \forall x \in P \}$$

a) " \Leftarrow " Anwendung schwacher Dualität

$$\text{Es ist } (y_1, \dots, y_M, y_{M+1}, \dots, y_N) = \left(\frac{\lambda_1}{n}, \dots, \frac{\lambda_M}{n}, 0, \dots, 0 \right),$$

$$\sum z_{ij} E_{ij} = \frac{1}{n} I_n$$

eine zulässige Lösung des dualen Programms.

$$\text{Weil } B_n \supseteq P \text{ ist } (B, b) = (I_n, 1), \quad y = \begin{bmatrix} 0 & 0 \\ 0 & I_n \end{bmatrix}$$

eine zulässige Lösung des primalen Programms. Nach Satz 3.6

folgt nun die Beh.

" \Rightarrow " Anwendung starker Dualität.

Klar: $P \subseteq B_n$

Sei y_1^*, \dots, y_N^* optimale Lösung vom Dualen.

O.B.d.A. $y_1^* > 0, \dots, y_M^* > 0, y_{M+1}^* = 0, \dots, y_N^* = 0$.

Dann ist wegen der komplementären Schlupfs

$$\left\langle \begin{bmatrix} 1 & -x_i^T \\ -x_i^* & x_i x_i^T \end{bmatrix}, \begin{bmatrix} 0 & 0 \\ 0 & I_n \end{bmatrix} \right\rangle = 1 \quad \text{für } i \in [M],$$

d.h. $\|x_i\| = 1$ und (i) folgt.

Sei $Z^* = \sum z_{ij}^* E_{ij}$ optimale Lösung des Dualen. Dann ist $I_n Z^* = d I_n$ für ein $d > 0$, also $Z^* = \frac{1}{n} I_n$.

Sei Y^* optimal für das Primal. Dann

$$Y^* \left(- \sum z_{ij}^* E_{i+1, j+1} + \sum y_i^* \begin{bmatrix} 1 & -x_i^T \\ -x_i & x_i x_i^T \end{bmatrix} \right) = 0$$
$$\Leftrightarrow \sum y_i^* \begin{bmatrix} 1 & -x_i^T \\ -x_i & x_i x_i^T \end{bmatrix} = \begin{bmatrix} 0 & 0 \\ 0 & \frac{1}{n} I_n \end{bmatrix}$$

Definiere $\lambda_i = n y_i^*$ und (ii) & (iii) folgen aus der obigen Gleichung.

□

Korollar 6 Sei $P \subseteq \mathbb{R}^n$ ein Polytop.

(a) Falls $\text{Cent}(P) = B_n$, dann $\frac{1}{n} B_n \subseteq P \subseteq B_n$.

(b) Falls $\text{Ein}(P) = B_n$, dann $B_n \subseteq P \subseteq n B_n$.


[Beide Inklusionen sind bestmöglich \rightarrow Blatt 12].

Bew.: (a) folgt aus (b) durch Polarität.

(b) Anwendung von Johns Opt.-bed.

$$\sum_{i=1}^m \lambda_i x_i = 0, \quad \sum_{i=1}^m \lambda_i x_i x_i^T = I_n, \quad \lambda_i > 0.$$

Die stützenden Hyperebenen durch $x_i \in B_n \cap \partial P$ sind orthogonal zu x_i :



Also $B_n \subseteq P \subseteq Q = \left\{ x \in \mathbb{R}^n : x_i^T x \leq 1, \right.$
 $\left. i \in [n] \right\}$.

Falls $x \in Q$, dann $x^T x_i \in [-\|x\|, 1]$. Also

$$\begin{aligned} 0 &\leq \sum_{i=1}^m \lambda_i (1 - x^T x_i) (\|x\| + x^T x_i) \\ &= \|x\| \sum_{i=1}^m \lambda_i + (1 - \|x\|) \sum_{i=1}^m \lambda_i x^T x_i - \sum_{i=1}^m \lambda_i (x^T x_i)^2 \end{aligned}$$

$$\begin{aligned} &= \|x\| n + 0 - \|x\|^2 \quad \left(\text{weil } \sum \lambda_i = \sum \lambda_i x_i^T x_i \right. \\ &\quad \left. = \text{Tr} \left(\sum \lambda_i x_i x_i^T \right) = \text{Tr}(I_n) = n \right) \end{aligned}$$

$$\Rightarrow \|x\| \leq n.$$

□

Kapitel VI Polynomielle Optimierung

§ 1 Nichtnegative Polynome und SOS

SOS = sum of squares („Quadratsummen“)

Notation Polynome in n Unbestimmten x_1, \dots, x_n .

- $x_1^{\alpha_1} \cdot x_2^{\alpha_2} \dots x_n^{\alpha_n}$, $\alpha_1, \dots, \alpha_n \in \mathbb{N}$ heißt Monom.
 - Kurzschreibweise: x^α , $\alpha = (\alpha_1, \dots, \alpha_n)$
 - Grad von x^α : $|\alpha| = \sum_{i=1}^n \alpha_i$
 - $p = \sum_{\alpha} p_{\alpha} x^{\alpha}$ endl. Linearkomb. von Monomen x^{α} mit Koeffizienten $p_{\alpha} \in \mathbb{R}$ heißt Polynom
 - $\mathbb{R}[x_1, \dots, x_n] = \mathbb{R}[x] = \{p : p \text{ Polynom}\}$ Polynomring
 - $\deg p = \max \{|\alpha| : p_{\alpha} \neq 0\}$ Grad von p
 - $\mathbb{R}[x]_{=d} = \{p \in \mathbb{R}[x] : \deg p = d, p \text{ homogen}\} \cup \{0\}$
 p homogen: falls $p_{\alpha} \neq 0$, dann $|\alpha| = d$.
[oder $p(\beta x) = \beta^d p(x) \quad \forall \beta \in \mathbb{R} \quad \forall x \in \mathbb{R}^n$]
- Monome vom Grad d sind Basis von $\mathbb{R}[x]_{=d}$.

$$\dim \mathbb{R}[x]_{=d} = \binom{n+d-1}{n-1} = \binom{n+d-1}{d}$$

Z.B. $m=3, d=4$ $\binom{n+d-1}{n-1} = \binom{6}{2}$

• • * • * • Monom $x_1^2 x_2 x_3$
 x_1 x_1 x_2 x_3

$$\begin{aligned} - \mathbb{R}[x]_d &= \{ p : p \text{ Polynom, } \deg p \leq d \} \\ &= \mathbb{R}[x]_{=0} \oplus \mathbb{R}[x]_{=1} \oplus \dots \oplus \mathbb{R}[x]_{=d}. \end{aligned}$$

$$\dim \mathbb{R}[x]_d = \sum_{k=0}^d \binom{n+k-1}{k} = \binom{n+d}{d}$$

Def. 1 a) $p \in \mathbb{R}[x]$ heißt SOS, falls es $q_1, \dots, q_m \in \mathbb{R}[x]$ gibt mit $p = q_1^2 + \dots + q_m^2$.

b) $\Sigma_{m,d} = \{ p \in \mathbb{R}[x]_d : p \text{ ist SOS} \}$ SOS-Kezel
 (→ Aufgabe 4.2)

c) $P_{n,d} = \{ p \in \mathbb{R}[x] : p(x) \geq 0 \forall x \in \mathbb{R}^n \}$ Kezel der nicht-negativen Polynome (→ Aufgabe 1.2)

Klar: $\sum_{m, 2d+1} = \sum_{n, 2d}$, $P_{n, 2d+1} = P_{m, 2d}$

$$\sum_{m, d} \subseteq P_{m, d}.$$

Satz 2 $\sum_{m, 2d} = \left\{ p \in \mathbb{R}[x]_{2d} : \exists Q \in S_{\geq 0}^{\binom{m+d}{d}} : p = [x]_d^T Q [x]_d \right\}$,

wobei $[x]_d$ der Vektor aller Monome x^α in $\mathbb{R}[x]_d$ ist.

Bsp: $m=2, d=2$ $[x]_2 = \begin{bmatrix} 1 \\ x_1 \\ x_2 \\ x_1 x_2 \\ x_1^2 \\ x_2^2 \end{bmatrix}$

Bew.: " \subseteq ": Sei $p = q_1^2 + \dots + q_m^2$.

Schreibe $q_i = \sum_{\alpha} q_{i\alpha} x^\alpha = \underline{q}_i^T [x]_d$,

wobei $\underline{q}_i = (q_{i\alpha})_{\alpha} \in \mathbb{R}^{\binom{n+d}{d}}$

Dann $q_i^2 = (\underline{q}_i^T [x]_d)^2$ und

$$p = \sum_{i=1}^m [x]_d^T \underline{q}_i \underline{q}_i^T [x]_d = [x]_d^T Q [x]_d,$$

wobei $Q = \sum_{i=1}^m \overbrace{\underline{q}_i \underline{q}_i^T}^{\in S_{\geq 0}^{\binom{n+d}{d}}} \in S_{\geq 0}^{\binom{n+d}{d}}$.

≥: Sei $p = [x]_d^T Q [x]_d$ mit $Q \geq 0$.

Spektralzerlegung: $Q = \sum_{i=1}^{\binom{n+d}{d}} \lambda_i \mu_i \mu_i^T$.

Dann $p = \sum_{i=1}^{\binom{n+d}{d}} \underbrace{(\sqrt{\lambda_i} \mu_i)^T [x]_d}_{= q_i}^2$ □

Bem.: a) Entscheidungsproblem „ $p \in \Sigma_{n,2d}$?“ ist algorithmisch einfach (\rightarrow SDP Zulässigkeit).

b) Rang von Q gibt an, wie viele Summanden in SOS-Darstellung mind. gebraucht werden.

Bsp.: $p(x) = x^4 + 4x^3 + 6x^2 + 4x + 5 \in \Sigma_{1,4}$

$$= \begin{bmatrix} 1 \\ x \\ x^2 \end{bmatrix}^T \begin{bmatrix} q_{00} & q_{01} & q_{02} \\ q_{01} & q_{11} & q_{12} \\ q_{02} & q_{12} & q_{22} \end{bmatrix} \begin{bmatrix} 1 \\ x \\ x^2 \end{bmatrix}.$$

$$= q_{22}x^4 + 2q_{12}x^3 + (q_{11} + 2q_{02})x^2 + 2q_{01}x + q_{00}$$

$$\Rightarrow 4 = q_{22}, \quad q_{12} = 3, \quad q_{11} + 2q_{02} = 6, \quad q_{01} = 2, \quad q_{00} = 5$$

$$\text{Matrix } Q = \begin{bmatrix} 5 & 2 & 0 \\ 2 & 6 & 3 \\ 0 & 3 & 1 \end{bmatrix} \geq 0 \Rightarrow p \in \Sigma_{1,4}.$$

Frage: Verhältnis zwischen $\Sigma_{n,2d}$ und $P_{n,2d}$?

Satz 3 $\sum_{1,2d} = P_{1,2d}$.

Bew.: Sei $p \in P_{1,2d}$ mit $\deg p = 2d$.

Fundamentalsatz der Algebra:

$$p(x) = c \prod_{i=1}^r (x - \alpha_i)^2 \prod_{i=1}^s (x - \beta_i)(x - \bar{\beta}_i)$$

α_i : reelle Nullstellen,

$\beta_i, \bar{\beta}_i$: Paare komplexer Nullstellen

$c > 0$ Koeffizient von Monom x^{2d} .

Falls (*) $\prod_{i=1}^s (x - \beta_i)(x - \bar{\beta}_i) = \sum_{j=1}^m (q_j(x))^2$, dann

$$p(x) = \sum_{j=1}^m \left(\sqrt{c} \prod_{i=1}^r (x - \alpha_i) q_j \right)^2.$$

Nun ist

$$\begin{aligned} (x - \beta_i)(x - \bar{\beta}_i) &= x^2 - (\beta_i + \bar{\beta}_i)x + \beta_i \bar{\beta}_i \\ &= x^2 - (2 \operatorname{Re} \beta_i)x + (\operatorname{Re} \beta_i)^2 + (\operatorname{Im} \beta_i)^2 \\ &= (x - \operatorname{Re} \beta_i)^2 + (\operatorname{Im} \beta_i)^2 \end{aligned}$$

und die Existenz der Darstellung (*) folgt. \square

Zusatz: Kann jeder $p \in \sum_{1,d}$ als Summe von 2 Quadraten schreiben.

Bsp. 4 Das Motkinpolynom

$$M(x, y) = x^2 y^2 (x^2 + y^2 - 3) + 1 \in \mathcal{P}_{2,6} \setminus \Sigma_{2,6}.$$

Bew.:

$M \in \mathcal{P}_{2,6}$: Falls $x^2 + y^2 - 3 \geq 0$, dann $M(x, y) \geq 0$.

Falls $x^2 + y^2 - 3 < 0$, dann def. $z^2 = 3 - x^2 - y^2$. (> 0).

AM-GM-Ungleichung:

$$(x^2 y^2 z^2)^{1/3} \leq \frac{x^2 + y^2 + z^2}{3} = 1$$

"

$$(-M(x, y) + 1)^{1/3} \Rightarrow M(x, y) \geq 0.$$

$M \notin \Sigma_{2,6}$: Ang. $M = \sum_{k=1}^m q_k^2$.

$\deg q_k \leq 3$. Koeffizienten von q_k :

x^3	:	0
y^3	:	0
x^2	:	0
y^2	:	0
x	:	0
y	:	0.

Also: $q_k = a_k x y^2 + b_k x^2 y + c_k x y + d_k$.

Koeffizient von $x^2 y^2$ in M ist -3 . D.h. $-3 = \sum_{k=1}^m c_k^2$. \hookrightarrow

Satz 5 (Hilbert 1888)

$$\sum_{n, 2d} = P_{m, 2d} \iff \begin{array}{l} n=1 \text{ oder} \\ d=1 \text{ oder} \\ m=2, d=2. \end{array}$$

Bew.: $m=1$: Satz 3

$d=1$: Choleskyzerlegung

$m=2, d=2$: recht schwierig (nicht hier)

alle anderen Fälle: Varianten des Motzkin-Polynom.

Bem.: • Entscheidungsproblem „ $p \in P_{m, 4}$?“ ist NP-schwer.

• Blekherman (2006): Im allg. ist $P_{m, 2d}$ viel größer als $\sum_{m, 2d}$.

§ 2 Globale Optimierung mit Polynomen

Polynomiales Optimierungsproblem (POP)

geg.: Polynome $f, g_1, \dots, g_m \in \mathbb{R}[x]$

$K = \{x \in \mathbb{R}^n : g_1(x) \geq 0, \dots, g_m(x) \geq 0\}$ Menge der
zulässigen Lösungen

f Zielwert.

ges.: $p_{\min} = \inf_{x \in K} f(x)$

Bem.: a) POP ist sehr allgemein.
b) POP ist sehr schwer.

Dualer Ansatz

$\mathcal{P}(K) = \{p \in \mathbb{R}[x] : p(x) \geq 0 \forall x \in K\}$ konvexe Kegel.

Dann $p_{\min} = \sup \{ \lambda : p - \lambda \in \mathcal{P}(K) \}$.

Klar: Optimieren über $\mathcal{P}(K)$ ist schwer.

Relaxierung (Parrilo; Lasserre 2001)

Finde Sequenz von Kegeln $C_1 \subseteq C_2 \subseteq \dots \subseteq \mathcal{P}(K)$
für die $\sup \{ \lambda : p - \lambda \in C_i \}$ einfacher zu lösen ist.

→ gibt Sequenz

$$p_1 \leq p_2 \leq \dots \leq p_{\min}$$

von unteren Schranken, die p_{\min} approximieren.

→ Optimieren über C_i ist leichter als Optimieren über C_{i+1}, \dots

SOS-Relaxierung

$$p_{\text{SOS}, i} = \sup \left\{ \lambda : p - \lambda \in \sum_{m, 2i} + g_1 \sum_{m, 2i} + \dots + g_m \sum_{n, 2i} \right\}$$

Dann

$$p_{\text{SOS}, 1} \leq p_{\text{SOS}, 2} \leq \dots \leq p_{\min}.$$

Theorem von Putinar: Falls K kompakt (und K „schön“ durch g_1, \dots, g_m dargestellt), dann $p_{\min} = \lim_{i \rightarrow \infty} p_{\text{SOS}, i}$.

- * Wichtiges theoretisches Resultat mit praktischem Nutzen
- * oft ist $p_{\text{SOS}, i} = p_{\min}$ für kleines i .
- * Ausgangspunkt aktueller Forschung.

Def. 1 a) $M \subseteq \mathbb{R}[x]$ heißt quadratisches Modul,
falls $1 \in M$, $M+M \subseteq M$, $\Sigma M \subseteq M$.

b) Seien $g_1, \dots, g_m \in \mathbb{R}[x]$.

$$M(g_1, \dots, g_m) = \left\{ \mu_0 + \sum_{j=1}^m \mu_j g_j : \mu_j \in \Sigma, j=0, \dots, m \right\}$$

ist der von g_1, \dots, g_m erzeugte q. M.

c) $M(g_1, \dots, g_m)$ heißt Archimedisch, falls

$$\forall f \in \mathbb{R}[x] \exists N \in \mathbb{N} : N \pm f \in M(g)$$

[Kann zeigen : $M(g_1, \dots, g_m)$ ist archimedisch \Leftrightarrow

$$\exists N \in \mathbb{N} : N - \sum_{i=1}^n x_i^2 \in M(g)]$$

Insbesondere : Falls $M(g_1, \dots, g_m)$ archimedisch, dann K kompakt.

Theorem 2 (Putinar 1993) „Putinar's Positivstellensatz“

Angenommen $M(g_1, \dots, g_m)$ ist archimedisch. Dann gilt

$$p(x) > 0 \quad \forall x \in K \Rightarrow p \in M(g_1, \dots, g_m).$$

[„Umkehrung“ : $p \in M(g_1, \dots, g_m) \Rightarrow p(x) \geq 0 \quad \forall x \in K$]
ist klar.

§ 3 Beweis von Putinar Positivstellensatz

Def. 1 a) $I \subseteq \mathbb{R}[x]$ heißt Ideal, falls $I + I \subseteq I$
und $\mathbb{R}[x] I \subseteq I$.

b) $(g_1, \dots, g_m) = \left\{ \sum_{j=1}^m \mu_j g_j : \mu_j \in \mathbb{R}[x] \right\}$ ist das von g_1, \dots, g_m
erzeugte Ideal

Lemma 2 Sei $M \subseteq \mathbb{R}[x]$ ein quadratischer Modul. Dann
ist $I = M \cap (-M)$ ein Ideal.

Lemma 3 Sei $M \subseteq \mathbb{R}[x]$ ein ^{maximaler} echter ~~g.~~ q. M. (d.h. $-1 \notin M$).

Dann ist $M \cup (-M) = \mathbb{R}[x]$.

Lemma 4 Sei $M \subseteq \mathbb{R}[x]$ ein ^{maximaler} echter, archimedischer q. M.

Dann: $\forall f \in \mathbb{R}[x] \exists! a \in \mathbb{R} : f - a \in I$, mit $I = M \cap (-M)$.

Lemma 5 Ang. $p(x) > 0 \forall x \in K$. Dann: $\exists s \in \Sigma : sp^{-1} \in M(g_1, \dots, g_m)$

Lemma 6 Ang. $p(x) > 0 \forall x \in K$. Dann:

$\exists N \in \mathbb{N}, h \in M(g_1, \dots, g_m) : N - h \in \Sigma, hp^{-1} \in M(g_1, \dots, g_m)$.

Bew. (Putinar Positivstellensatz)

Seien N, h wie in Lemma 6. Da $M(g_1, \dots, g_m)$ archimedisch

$\exists k \in \mathbb{N} : k + p \in M(g_1, \dots, g_m)$.

Können annehmen: $N > 0, k > 0$

Es ist

$$\left(k - \frac{1}{N}\right) + p = \frac{1}{N} \underbrace{\left(\underbrace{(N-k)}_{\in \Sigma} \underbrace{(k+p)}_{\in M(g)} + \underbrace{(kp-1)}_{\in M(g)} + \underbrace{kh}_{\in M(g)} \right)}_{\in M(g)}$$

P. h. wir haben gezeigt: $k+p \in M(g_1, \dots, g_m) \Rightarrow \left(k - \frac{1}{N}\right) + p \in M(g_1, \dots, g_m)$

hN -fache Iteration liefert $\underbrace{\left(k - \frac{hN}{N}\right) + p}_{=p} \in M(g_1, \dots, g_m)$. \square

Bew.: (Lemma 2)

$I+I \subseteq I$: \checkmark

$\mathbb{R}[x] I \subseteq I$: Seien $f \in \mathbb{R}[x], g \in I$. Dann

$$\underbrace{\left(\frac{f+1}{2}\right)^2 g + \left(\frac{f-1}{2}\right)^2 (-g)}_{\in I} = fg \quad \square$$

$$\in I = M \cap (-M).$$

Bew.: (Lemma 3)

Ang. $\exists f \notin M \cup (-M)$. Definiere die q. M.

$$M' = \sum f + M, \quad M'' = \sum (-f) + M.$$

M', M'' erhalten M strikt. Weil M maximal echt ist:

$\exists g_1, g_2 \in M, s_1, s_2 \in \Sigma :$

$$-1 = s_1 f + g_1, \quad -1 = s_2(-f) + g_2.$$

$$\begin{aligned} \Rightarrow -s_2 - s_1 &= s_2(s_1 f + g_1) + s_1(s_2(-f) + g_2) \\ &= \underbrace{s_2 g_1 + s_1 g_2}_{\in M} \end{aligned}$$

$$\Rightarrow -s_1 \in M$$

$$= s_2 g_1 + s_1 g_2 + s_2 \in M$$

$$\Rightarrow s_1, s_2 \in -M.$$

Andererseits: $s_1, s_2 \in \Sigma \subseteq M$.

Also $s_1, s_2 \in I = M \cap (-M)$ (nach Lemma 2 ein Ideal).

$$\Rightarrow s_1 f \in I \subseteq M \Rightarrow -1 = s_1 f + g_1 \in M \quad \checkmark \quad \square.$$

Bew.: (Lemma 4)

Definieren

$$A = \{a \in R : f - a \in M\}, \quad B = \{b \in R : b - f \in M\}.$$

Weil M archimedisch: $A, B \neq \emptyset$.

Zu zeigen: $|A \cap B| = 1$. [Dann $f - a \in M, a - f \in M$,
d.h. $f - a \in M \cap (-M) = \{f\}$].

1) Es ist $a \leq b \quad \forall a \in A, b \in B$.

Ang. $a > b$. Dann $b - a = \underbrace{(f - a) + (b - f)}_{\in M} < 0$. \hookrightarrow zu $-1 \notin M$.

2) $a_0 = \sup A$, $b_0 = \inf B$. Dann $a_0 = b_0$.

Ang. $\exists c : a_0 < c < b_0$. Dann $f - c \notin M \cup (-M) \stackrel{\text{Lemma 3}}{=} \mathbb{R}(x)$.

3) $a_0 = b_0 \in A \cap B$.

Ang. $f - a_0 \notin M$. Definiere g.M. $M' = M + (f - a_0)\Sigma$.

Weil M max. echt:

$$\exists g \in M, s \in \Sigma : -1 = g + (f - a_0)s.$$

Da M archimedisch: $\exists N \in \mathbb{N} : N - s \in M$.

Sei ε , so dass $0 < \varepsilon < 1/N$.

Dann $a_0 - \varepsilon \in A$, $f - (a_0 - \varepsilon) = (f - a_0) + \varepsilon \in M$.

Also $-1 + \varepsilon s = g + (f - a_0 + \varepsilon)s \in M$.

Weiter

$$-1 + \varepsilon s + \underbrace{\varepsilon(N - s)}_{\in M} = \underbrace{-1 + \varepsilon N}_{< 0} \in M. \quad \hookrightarrow$$

Bew.: (Lemma 5)

Z.z.: $M_0 = M(g_1, \dots, g_n) - p \Sigma$ ist nicht echt.

Ang. M_0 ist echt. Ziel: Finde $a \in K$ mit $p(a) < 0$.

Sei M ein maximaler echter q.M., der M_0 enthält
(gibt es nach dem Lemma von Zorn). M ist archimedisch,

Weil $M \supseteq M(g_1, \dots, g_n)$. Nach Lemma 4 $\exists a_i \in \mathbb{R}$:

$$x_i - a_i \in I = M \cap (-M) \quad i = 1, \dots, n.$$

Definieren $a = (a_1, \dots, a_n)$.

Beh.: $\forall f \in \mathbb{R}[x]: f - f(a) \in I$.

Wende Beh. auf g_j an. Dann

$$g_j(a) = g_j - (g_j - g_j(a)) \in M.$$

Weil M echt, muss $g_j(a) \geq 0$ sein. Also $a \in K$.

Desweiteren

$$-p(a) = (p - p(a)) - p \in M.$$

Weil M echt: $-p(a) \geq 0$. \checkmark

Bew. (der Beh.)

Sei $f = \sum_{\alpha} f_{\alpha} x^{\alpha}$. Dann $\sum_{\alpha} f_{\alpha} (x^{\alpha} - a^{\alpha}) = f - f(a)$

z.z.: $x^{\alpha} - a^{\alpha} \in \mathcal{I}$.

Induktion nach $|\alpha|$

$|\alpha| = 0$: \checkmark

$|\alpha| > 0$: Ang. $\alpha_1 \geq 1$. $\beta = \alpha - e_1$.

$$x^{\alpha} - a^{\alpha} = x_1 \underbrace{(x^{\beta} - a^{\beta})}_{\substack{\in \mathcal{I} \\ \text{i.v.}}} + a^{\beta} \underbrace{(x_1 - a_1)}_{\in \mathcal{I}} \in \mathcal{I}. \quad \square$$

Bew. (Lemma 6)

Wähle $s \in \Sigma$ wie in Lemma 5.

Da $M(g_1, \dots, g_m)$ archimedisch: $\exists k \in \mathbb{N}$: $2k - s, 2k - s^2 p - 1$

Def. $h = s(2k - s)$, $N = h^2$. $\in M(g_1, \dots, g_m)$

Dann $h \in M(g_1, \dots, g_m)$ und

$N - h = (k - s)^2 \in \Sigma$ und

$$h^{p-1} = s(2k - s)^{p-1} = \underbrace{2k(s)^{p-1}}_{\in M(g)} + \underbrace{(2k - s^2)^{p-1}}_{\in M(g)} \in M(g). \quad \square$$