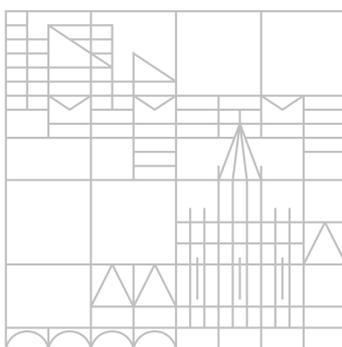


# SKRIPT ZUR VORLESUNG

## GEOMETRIE LINEARER MATRIXUNGLEICHUNGEN



Universität Konstanz

Sommersemester 2024

Fachbereich Mathematik und Statistik

© PROF. DR. CLAUS SCHEIDERER

geTeXt von

Tobias Retzlaff

Stand: 1. November 2024

## Inhaltsverzeichnis

1.	Allgemeine Fakten zu hyperbolischen Formen . . . . .	1
2.	Beweis der (Ex-)Lax-Vermutung . . . . .	6
3.	Spektraederschatten: Die Sätze von Helton-Nie . . . . .	11
4.	Glatte Hyperbolizitätskegel . . . . .	18
5.	Interlacer . . . . .	21
6.	Gegenbeispiele zur Helton-Nie-Vermutung . . . . .	26
	<b>Literatur</b>	<b>31</b>

## §1 Allgemeine Fakten zu hyperbolischen Formen

**1.1 Wiederholung** (siehe Konvexität, II.6). Sei  $e \in \mathbb{R}^n$ . Eine Form  $f \in \mathbb{R}[\mathbf{x}] = \mathbb{R}[x_1, \dots, x_n]$  heißt *hyperbolisch bzgl.  $e$* , falls  $f(e) \neq 0$  gilt und für jedes  $u \in \mathbb{R}^n$  das univariate Polynom  $f(te - u) \in \mathbb{R}[t]$  nur reelle Nullstellen besitzt. Sind für alle  $u \in \mathbb{R}^n \setminus \mathbb{R}e$  die Nullstellen von  $f(te - u)$  sogar reell und einfach, so heißt  $f$  *strikt hyperbolisch bzgl.  $e$* . (Beachte, dass man  $u \notin \mathbb{R}e$  fordern muss, denn für  $u = ce$  mit  $c \in \mathbb{R}$  gilt  $f(te - u) = f((t - c)e) = (t - c)^{\deg(f)} f(e)$ .) Schreibe  $\mathcal{H}_d(e)$  (bzw.  $\mathcal{H}_{sd}(e)$ ) für die Menge aller bzgl.  $e$  hyperbolischen Formen (bzw. strikt hyperbolischen Formen)  $f \in \mathbb{R}[\mathbf{x}]_d$ . Es heißen

$$U_e(f) := \{u \in \mathbb{R}^n : \forall x \in [e, u] : f(x) \neq 0\}$$

der *offene Hyperbolizitätskegel* von  $f \in \mathcal{H}_d(e)$  bzgl.  $e$  und

$$C_e(f) := \overline{U_e(f)} = \{u \in \mathbb{R}^n : \forall x \in [e, u] : f(x) \neq 0\}$$

der *abgeschlossene Hyperbolizitätskegel* (oder schlicht *Hyperbolizitätskegel*) von  $f$  bzgl.  $e$ . Es gelten

$$\begin{aligned} U_e(f) &= \{u \in \mathbb{R}^n : \text{Alle Nullstellen von } f(te - u) \in \mathbb{R}[t] \text{ sind } > 0\} \quad \text{und} \\ C_e(f) &= \{u \in \mathbb{R}^n : \text{Alle Nullstellen von } f(te - u) \in \mathbb{R}[t] \text{ sind } \geq 0\}. \end{aligned}$$

Weiter ist  $U_e(f)$  auch die Zusammenhangskomponente von  $e$  in  $\{u \in \mathbb{R}^n : f(u) \neq 0\}$ .

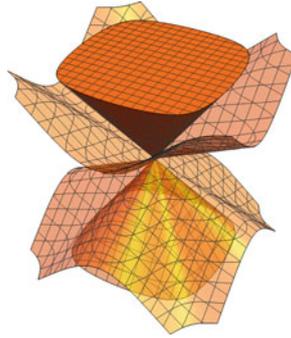


Abbildung 1: Der Hyperbolizitätskegel eines quartischen Polynoms (Quelle: [1], Fig. 2.6)

Verwende die Notationen  $(\partial_e f)(x) = \frac{d}{dt} f(x + te)|_{t=0}$  und  $\partial_e = \sum_{i=1}^n e_i \frac{\partial}{\partial x_i}$ , dann gelten

$$\begin{aligned} U_e(f) &= \{u \in \mathbb{R}^n : \forall k \in [d] : (\partial_e^k f)(u) > 0\} \quad \text{und} \\ C_e(f) &= \{u \in \mathbb{R}^n : \forall k \in [d] : (\partial_e^k f)(u) \geq 0\} \end{aligned}$$

mit  $d := \deg(f)$ . Ist  $f$  hyperbolisch bzgl.  $e$ , so auch  $\partial_e f$  und es gelten  $U_e(f) \subseteq U_e(\partial_e f)$ , sowie  $C_e(f) \subseteq C_e(\partial_e f)$ . Weiter ist  $f$  in diesem Fall hyperbolisch bzgl. jedem  $u \in U_e(f)$ .

**1.2 Standardbeispiel.** Seien  $A_1, \dots, A_n \in \mathbf{S}^d = \text{Sym}_d(\mathbb{R})$  und

$$f(x) := \det A(x) \quad \text{mit} \quad A(x) := x_1 A_1 + \dots + x_n A_n.$$

Die Form  $f$  hat den Grad  $d$  und ist hyperbolisch bzgl. jedem  $e \in \mathbb{R}^n$  mit  $A(e) = \sum_{i=1}^n e_i A_i \succ 0$ , denn nach einem Basiswechsel kann man  $A(e) = I_d$  annehmen, woraus

$$f(te - u) = \det A(te - u) = \det(tI_d - A(u)) = \text{charpol}_{A(u)}(t)$$

für alle  $u \in \mathbb{R}^n$  folgt und dieses Polynom besitzt (aufgrund der Symmetrie der  $A_i$ ) nur reelle

Nullstellen. Der Hyperbolizitätskegel von  $f$  ist  $C_e(f) = \{u \in \mathbb{R}^n : A(u) \succeq 0\}$ .

Wir sagen, dass eine Form  $f \in \mathbb{R}[\mathbf{x}]_d$  eine *definite Determinantendarstellung* bzgl.  $e \in \mathbb{R}^n$  besitzt, falls ein lineares (symmetrisches) Matrixpolynom  $A(x) = \sum_{i=1}^n x_i A_i$  mit  $A_i \in \mathbf{S}^d$ ,  $f(x) = \det A(x)$  und  $A(e) \succ 0$  existiert. In diesem Fall ist  $f$  hyperbolisch bzgl.  $e$  und für den Hyperbolizitätskegel gilt  $C_e(f) = \{u \in \mathbb{R}^n : A(u) \succeq 0\}$ .

Die Lax<sup>1</sup>-Vermutung (1958) fragt nach der Umkehrung für  $n = 3$ :

**1.3 Theorem** (Helton<sup>2</sup>-Vinnikov<sup>3</sup> 2006). Sei  $f \in \mathbb{R}[x_1, x_2, x_3]$  hyperbolisch bzgl.  $e \in \mathbb{R}^3$  mit  $f(e) > 0$  und sei  $d := \deg(f)$ . Dann gibt es  $A_1, A_2, A_3 \in \mathbf{S}^d$  mit  $f(x) = \det(x_1 A_1 + x_2 A_2 + x_3 A_3)$  und  $e_1 A_1 + e_2 A_2 + e_3 A_3 \succ 0$ .

**1.4** Für  $n \geq 4$  kann diese Aussage im Allgemeinen nicht gelten. Beispielsweise ist die quadratische Form  $f(x) := x_1^2 - x_2^2 - \dots - x_n^2$  für jedes  $n \in \mathbb{N}$  hyperbolisch bzgl.  $e_1 = (1, 0, \dots, 0)^\top \in \mathbb{R}^n$  und hat Rang  $n \geq 4$ . Aber für beliebige Linearformen  $\ell_1, \ell_2, \ell_3$  hat das Polynom

$$\det \begin{pmatrix} \ell_1(x) & \ell_2(x) \\ \ell_2(x) & \ell_3(x) \end{pmatrix} = \ell_1(x)\ell_3(x) - \ell_2(x)^2$$

in jedem Fall höchstens Rang 3.

**1.5 Verallgemeinerte Lax-Vermutung.** Ist  $f \in \mathbb{R}[\mathbf{x}]_d$  hyperbolisch bzgl.  $e \in \mathbb{R}^n$ , so ist  $C_e(f)$  ein Spektraederkegel (vgl. Aufgabe 4).

**1.6 Lokale Vielfachheiten von Hyperflächen.** Sei  $k$  ein Körper mit  $\text{char}(k) = 0$ , sei  $0 \neq f \in k[\mathbf{x}]$  und sei  $X := \mathcal{V}(f) \subseteq \mathbb{A}^n$  (eine Hyperfläche). Für  $u \in k^n$  heißt

$$\mu(f, u) := \mu(X, u) := \max \{i \in \mathbb{N}_0 : f \in \mathfrak{m}_u^i\} \geq 0$$

die *Multiplizität* (oder *Vielfachheit*) von  $f$  (oder  $X$ ) in  $u$ . Dabei sei  $\mathfrak{m}_u := \langle x_1 - u_1, \dots, x_n - u_n \rangle$  (ein maximales Ideal in  $k[\mathbf{x}]$ ). Ist

$$f(u + x) = f_m(x) + f_{m+1}(x) + \dots \tag{T}$$

mit homogenen  $f_i(x)$  vom Grad  $i$  und  $f_m(x) \not\equiv 0$ , so ist  $m = \mu(f, u)$ . Wir sehen also

$$\begin{aligned} \mu(f, u) = 0 &\iff f(u) \neq 0 \iff u \notin X, \\ \mu(f, u) = 1 &\iff f(u) = 0 \wedge \nabla f(u) \neq 0 \iff u \text{ ist ein glatter Punkt von } X. \end{aligned}$$

Jede Gerade durch  $u$  schneidet  $X$  in  $u$  mindestens mit Vielfachheit  $m = \mu(f, u)$ , d.h. für  $0 \neq v \in \mathbb{R}^n$  ist  $\text{ord}_{t=0} f(tv + u) \geq m$ , denn aus (T) folgt

$$f(tv + u) = f_m(tv) + f_{m+1}(tv) + \dots = t^m f_m(v) + t^{m+1} f_{m+1}(v) + \dots$$

Für alle  $v$  in einer Zariski-offenen (dichten) Menge ist  $\text{ord}_{t=0} f(tv + u) = m = \mu(f, u)$ .

**1.7 Beispiel.** Für  $f := x_1^2 - x_2^2 - x_3^2$  und  $u := 0 \in \mathbb{R}^2$  ist  $\mu(f, u) = 2$  und  $f(tv) = t^2(v_1^2 - v_2^2) - t^3 v_1^3$ .

**1.8 Satz.** Sei  $f \in \mathbb{R}[\mathbf{x}]$  eine bzgl.  $e \in \mathbb{R}^n$  hyperbolische Form. Dann ist  $\mu(f, u) = \text{ord}_{t=0} f(te - u)$  für jeden Punkt  $u \in \mathbb{R}^n$ .

---

<sup>1</sup>Peter LAX (\*1926)

<sup>2</sup>John William "Bill" HELTON (\*1945)

<sup>3</sup>Victor VINNIKOV (\*1967)

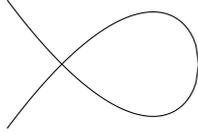


Abbildung 2: Die Hyperfläche  $\mathcal{V}(f) \cap \mathbb{R}^2$  aus Beispiel 1.7 (Quelle: [2], 6.3.16)

*Beweis.* Wir verwenden Theorem 1.3. Man kann  $f(e) = 1$  annehmen. Sei  $d := \deg(f)$ , fixiere  $0 \neq u \in \mathbb{R}^n$  und wähle ein  $v \in U_e(f)$  mit  $\mu(f, u) = \text{ord}_{t=0} f(tv - u)$  (ein solches existiert, da  $U_e(f) \neq \emptyset$  offen ist). Das Polynom  $F(r, s, t) := f(re + su + tv)$  erfüllt  $\deg(F) = d$  und ist hyperbolisch bzgl.  $e_1 \in \mathbb{R}^3$ : Für  $w \in \mathbb{R}^3$  ist  $F(te_1 + w) = F(t + w_1, w_2, w_3) = f(te + \tilde{w})$  mit  $\tilde{w} := w_1e + w_2u + w_3v \in \mathbb{R}^3$ . Nach Theorem 1.3 gibt es Matrizen  $U, V \in \mathbb{S}^d$  mit

$$F(r, s, t) = \det \left( \underbrace{rI_d + sU + tV}_{=: A(r, s, t)} \right).$$

Wegen  $v \in U_e(f)$  ist  $f \neq 0$  auf  $[e, v]$ , also  $F \neq 0$  auf  $[e_1, e_3] \subseteq \mathbb{R}^3$ . Da  $A(r, s, t)$  auf  $[e_1, e_3]$  nirgends singularär ist, folgt mit einem Stetigkeitsargument  $V \succ 0$ . Nach Aufgabe 3 ist

$$\text{ord}_{t=0} f(tv - u) = \text{ord}_{t=0} \det(tV - U) \stackrel{A3}{=} \dim \ker(U).$$

Andererseits ist ebenfalls  $\text{ord}_{t=0} f(te - u) = \text{ord}_{t=0} (tI_d - U) = \dim \ker(U)$ . Also gilt nach Wahl von  $v$  bereits  $\mu(f, u) = \text{ord}_{t=0} f(tv - u) = \text{ord}_{t=0} f(te - u)$ .  $\square$

**1.9 Korollar.** Sei  $f \in \mathbb{R}[\mathbf{x}]$  hyperbolisch bzgl.  $e \in \mathbb{R}^n$  und sei  $u \in \mathbb{R}^n$  mit  $f(u) = 0$ . Dann ist  $u$  genau dann ein glatter Punkt von  $\mathcal{V}(f)$ , wenn  $\text{ord}_{t=0} f(te - u) = 1$  gilt.

*Beweis.* Es gilt  $u$  ist glatt  $\stackrel{1.6}{\iff} \mu(f, u) = 1 \stackrel{1.8}{\iff} \text{ord}_{t=0} f(te - u) = 1$ .  $\square$

**1.10 Korollar.** Sei  $f \in \mathbb{R}[\mathbf{x}]$  hyperbolisch bzgl.  $e \in \mathbb{R}^n$ . Dann sind äquivalent:

- (i)  $f$  ist strikt hyperbolisch bzgl.  $e$ .
- (ii)  $f$  ist strikt hyperbolisch bzgl. jedem  $u \in U_e(f)$ .
- (iii) Die Hyperfläche  $\mathcal{V}(f) \subseteq \mathbb{A}^n$  hat keine reellen singularären Punkte  $\neq 0$ .

*Beweis.* (i) besagt, dass die Nullstellen von  $f(te - v) \in \mathbb{R}[t]$  für alle  $v \in \mathbb{R}^n \setminus \mathbb{R}e$  reell und einfach sind. Daraus folgt (iii), denn ist  $f(v) = 0$  mit  $v \neq 0$ , so ist  $\mu(f, v) = \text{ord}_{t=0} f(te - v) = 1$ . Der Beweis von (iii)  $\Rightarrow$  (ii) erfolgt analog und (ii)  $\Rightarrow$  (i) ist trivial.  $\square$

**1.11 Theorem** (Nuij<sup>4</sup>). Seien  $d \geq 1$  und  $0 \neq e \in \mathbb{R}^n$  und setze  $\mathcal{H}_d^1(e) := \{f \in \mathcal{H}_d(e) : f(e) = 1\}$ .

- (a)  $\mathcal{H}_{s_d}(e)$  ist offen in  $\mathbb{R}[\mathbf{x}]_d$  und dicht in  $\mathcal{H}_d(e)$  und  $\mathcal{H}_d^1(e)$  ist abgeschlossen in  $\mathbb{R}[\mathbf{x}]_d$ .
- (b) Die Räume  $\mathcal{H}_d^+(e) := \{f \in \mathcal{H}_d(e) : f(e) > 0\}$  und  $\mathcal{H}_{s_d}^+(e) := \mathcal{H}_{s_d}(e) \cap \mathcal{H}_d^+(e)$  sind kontrahierbar, also insbesondere zusammenhängend und einfach zusammenhängend.

Dabei heißt ein topologischer Raum  $X$  *kontrahierbar*, falls es eine *Deformationsretraktion* von  $X$  auf einen Punkt  $x_0 \in X$  gibt, d.h. eine stetige Abbildung  $h: X \times [0, 1] \rightarrow X$  mit  $h(x, 0) = x$  und  $h(x, 1) = x_0$  für alle  $x \in X$ . Alle Homotopiegruppen (insbesondere die Fundamentalgruppe) eines solchen Raums sind trivial.

**1.12 Lemma.**  $p \in \mathbb{R}[t]$  habe nur reelle Nullstellen. Sei  $s \in \mathbb{R}$  und  $g(t) := p(t) + sp'(t)$ .

<sup>4</sup>Wim NUIJ (\*19??)

- (a) Alle Nullstellen von  $g$  sind reell.
- (b) Ist  $s \neq 0$  und ist  $k \geq 1$  die maximale Vielfachheit einer Nullstelle von  $p(t)$ , so ist  $\max\{k-1, 1\}$  die maximale Vielfachheit einer Nullstelle von  $g(t)$ .

*Beweis.* Seien  $\alpha_1 < \dots < \alpha_n$  die verschiedenen Nullstellen von  $p$  und sei  $m_i \geq 1$  die Vielfachheit von  $\alpha_i$ , dann ist  $\deg(p) = \sum_{i=1}^n m_i =: m$ , also  $\deg(g) = m$ . Jedes  $\alpha_i$  ist eine Nullstelle von  $g$  der Vielfachheit  $m_i - 1$ . Für  $i \in [n]$  springt  $\frac{p'(t)}{p(t)}$  an der Stelle  $t = \alpha_i$  von  $-\infty$  nach  $+\infty$  (RAG, 1.3.7). Es ist

$$\frac{g(t)}{p(t)} = 1 + s \cdot \frac{p'(t)}{p(t)},$$

also hat  $g(t)$  für alle  $i \in [n-1]$  im Intervall  $(\alpha_i, \alpha_{i+1})$  (mindestens) eine reelle Nullstelle  $\beta_i$ . Die  $\alpha_i$  und  $\beta_i$  sind schon  $m-1$  reelle Nullstellen von  $g(t)$ , es fehlt nur noch eine Nullstelle. Zeige, dass eine solche stets existiert und nicht im Intervall  $[\alpha_1, \alpha_n]$  liegt. Für  $t \rightarrow \pm\infty$  gilt  $\frac{g(t)}{p(t)} \rightarrow 1$ . Ist  $s > 0$ , so gibt es also eine Nullstelle  $\beta < \alpha_1$ . Ist  $s < 0$ , so gibt es eine Nullstelle  $\beta > \alpha_n$ .  $\square$

**1.13** Zeige zunächst die letzte Aussage in (a). Sei  $f \in \mathbb{R}[\mathbf{x}]_d \setminus \mathcal{H}_d^1(e)$ . Ist  $f(e) \neq 1$ , so gilt das auch in einer Umgebung von  $f$ . Ist  $f(e) = 1$ , so ist also  $f \notin \mathcal{H}_d(e)$  (und  $f(e) \neq 0$ ), d.h. es gibt ein  $u \in \mathbb{R}^n$ , sodass  $f(te - u)$  eine nichtreelle Nullstelle besitzt. Nach RAG I, Aufgabe 52 gilt dasselbe in einer Umgebung von  $f$ . Somit ist  $\mathbb{R}[\mathbf{x}]_d \setminus \mathcal{H}_d^1(e)$  offen in  $\mathbb{R}[\mathbf{x}]_d$ , d.h.  $\mathcal{H}_d^1(e)$  ist abgeschlossen in  $\mathbb{R}[\mathbf{x}]_d$ . Zeige nun, dass  $\mathcal{H}_{s_d}(e)$  offen ist. Wähle einen Unterraum  $L \subseteq \mathbb{R}^n$  mit  $\dim(L) = n-1$  und  $e \notin L$  (d.h.  $\mathbb{R}^n = L \oplus \mathbb{R}e$ ). Sei  $S_L := \{u \in L : |u| = 1\}$  und betrachte die stetige Abbildung

$$\phi: \mathbb{R}[\mathbf{x}]_d \times \mathbb{R}^n \rightarrow \mathbb{R}[t]_{\leq d}, \quad (g, v) \mapsto g(te - v).$$

Sei  $H_d \subseteq \mathbb{R}[t]_{\leq d}$  die Menge aller  $p \in \mathbb{R}[t]$  mit  $\deg(p) = d$ , die nur reelle und einfache Nullstellen haben. Erneut nach RAG I, Aufgabe 52 ist  $H_d$  offen in  $\mathbb{R}[t]_{\leq d}$ . Nach Definition ist ein  $g \in \mathbb{R}[\mathbf{x}]_d$  genau dann strikt hyperbolisch bzgl.  $e$ , wenn  $\phi(\{g\} \times (\mathbb{R}^n \setminus \mathbb{R}e)) \subseteq H_d$  gilt. Dafür ist die Bedingung  $\phi(\{g\} \times S_L) \subseteq H_d$  hinreichend (und notwendig), denn jedes  $u \in \mathbb{R}^n \setminus \mathbb{R}e$  hat die Form  $u = ae + bv$  mit  $v \in S_L$ ,  $a, b \in \mathbb{R}$  und  $b \neq 0$  und es folgt

$$g(te - u) = g(te - (ae + bv)) = b^d \cdot g\left(\frac{t-a}{b}e - v\right).$$

Hat also  $g(te - v)$  die Nullstellen  $\lambda_1, \dots, \lambda_d$ , so hat  $g(te - u)$  die Nullstellen  $\mu_i = a + b\lambda_i$ . Sind die  $\lambda_i$  reell und paarweise verschieden, so gilt dies auch für die  $\mu_i$ . Sind  $X, K$  topologische Räume, ist  $K$  kompakt und  $W \subseteq X \times K$  offen, so ist die Menge  $\{x \in X : \{x\} \times K \subseteq W\}$  offen in  $X$ . Daher ist die Menge

$$\mathcal{H}_{s_d}(e) = \{g \in \mathbb{R}[\mathbf{x}]_d : \phi(\{g\} \times S_L) \subseteq H_d\} = \{g \in \mathbb{R}[\mathbf{x}]_d : \{g\} \times S_L \subseteq \underbrace{\phi^{-1}(H_d)}_{\text{offen}}\}$$

offen in  $\mathbb{R}[\mathbf{x}]_d$ .

**1.14** Für  $s \in \mathbb{R}$  und  $u \in \mathbb{R}^n$  mit  $\langle u, e \rangle = 0$  sei  $T_{u,s}: \mathbb{R}[\mathbf{x}]_d \rightarrow \mathbb{R}[\mathbf{x}]_d$  der durch

$$T_{u,s}f(x) := f(x) + s \cdot \langle x, u \rangle \cdot \partial_e f(x)$$

definierte lineare Operator. Für alle  $f \in \mathbb{R}[\mathbf{x}]_d$  und  $s \in \mathbb{R}$  ist  $T_{u,0}f = f$  und es gilt  $T_{u,s}f(e) = f(e)$ . Weiter gilt:

- (1)  $T_{u,s}$  bildet  $\mathcal{H}_d(e)$  und  $\mathcal{H}_{s_d}(e)$  in sich ab. Denn sei  $f \in \mathcal{H}_d(e)$ , sei  $g := T_{u,s}f$  und sei  $v \in \mathbb{R}^n$ .

Wir zeigen, dass alle Nullstellen von  $g(te - v)$  reell sind. Es gilt

$$g(te - v) = \underbrace{f(te - v)}_{=: p(t)} - s \cdot \langle u, v \rangle \cdot \underbrace{(\partial_e f)(te - v)}_{=: p'(t)} = p(t) + cp'(t)$$

mit  $c := -s \cdot \langle u, v \rangle \in \mathbb{R}$ . Nach Lemma 1.12(a) hat  $g(te - v)$  also reelle Nullstellen, d.h. es folgt  $g \in \mathcal{H}_d(e)$ . Analog zeigt man  $g \in \mathcal{H}_{sd}(e)$ , falls  $f \in \mathcal{H}_{sd}(e)$ .

- (2) Ist  $\alpha$  eine Nullstelle von  $p(t) = f(te - v)$  der Vielfachheit  $m \geq 1$ , so ist die Vielfachheit von  $\alpha$  als Nullstelle von  $g(te - v)$  nach Lemma 1.12(b) genau  $m - 1$ , außer im Fall  $s \cdot \langle u, v \rangle = 0$ .
- (3) Sei  $u_1, \dots, u_{n-1}$  eine Basis von  $e^\perp := (\mathbb{R}e)^\perp \subsetneq \mathbb{R}^n$  (beachte  $e \neq 0$ ). Für  $s \in \mathbb{R}$  betrachte den Operator

$$F_s := (T_{u_1, s})^d \circ \dots \circ (T_{u_{n-1}, s})^d$$

auf  $\mathbb{R}[\mathbf{x}]_d$ . Für  $s \rightarrow 0$  konvergiert  $F_s$  gegen  $F_0 = \text{id}_{\mathbb{R}[\mathbf{x}]_d}$ . Für  $s \neq 0$  gilt  $F_s(\mathcal{H}_d(e)) \subseteq \mathcal{H}_{sd}(e)$ , denn ist  $v \in \mathbb{R}^n \setminus \mathbb{R}e$ , so gibt es ein  $i \in [n - 1]$  mit  $\langle v, u_i \rangle \neq 0$ . Für  $g \in \mathcal{H}_d(e)$  ist

$$(T_{u_i, s}g)(te - v) = g(te - v) + s \cdot \langle te - v, u_i \rangle \cdot (\partial_e g)(te - v) = g(te - v) + s' \cdot (\partial_e g)(te - v)$$

mit  $s' \neq 0$ . Nach Lemma 1.12 verringert  $T_{u_i, s}$  die Vielfachheiten der Nullstellen um 1, während alle neuen Nullstellen Vielfachheit 1 haben und reell sind. Nach  $d$ -maligem Anwenden sind also alle Nullstellen (reell und) einfach. Für alle  $j \neq i$  ist weiter  $T_{u_j, s}f = f$ , denn es gilt  $\langle v, u_j \rangle = 0$ . Für  $f \in \mathcal{H}_d(e)$  und alle  $s \neq 0$  gilt damit  $F_s f \in \mathcal{H}_{sd}(e)$  und  $F_s f \rightarrow f$  für  $s \rightarrow 0$ . Insbesondere ist  $\mathcal{H}_{sd}(e)$  dicht in  $\mathcal{H}_d(e)$ .

**1.15** Noch zu zeigen ist 1.11(b). Ohne Einschränkung sei  $e = e_1$ . Betrachte die Homotopie

$$\mathbb{R}[\mathbf{x}]_d \times [0, 1] \rightarrow \mathbb{R}[\mathbf{x}]_d, (f, s) \mapsto H_s f \quad \text{mit} \quad H_s f(x_1, \dots, x_n) := f(x_1, sx_2, \dots, sx_n).$$

Es gilt  $H_1 f = f$  und  $H_0 f = x_1^d \cdot f(e)$ . Ist  $f$  hyperbolisch bzw. strikt hyperbolisch bzgl.  $e$ , so gilt dasselbe für  $H_s f$ , denn es gilt

$$(H_s f)(te - u) = f(t - u_1, -su_2, \dots, -su_n) = f(te - u')$$

mit  $u' := (u_1, su_2, \dots, su_n)$ . Ist  $f$  hyperbolisch bzgl.  $e$  mit  $f(e) > 0$ , so ist

$$h_s f := \left( (1 - s) + \frac{s}{f(e)} \right) \cdot F_s H_{1-s} f \quad (s \in [0, 1])$$

ein Pfad von  $h_0 f = f$  nach

$$h_1 f = \frac{1}{f(e)} F_1 H_0 f = F_1(x_1^d) =: g.$$

Dieser verläuft ganz innerhalb  $\mathcal{H}_d(e)$ , denn für alle  $s \in [0, 1]$  ist  $(1 - s) + \frac{s}{f(e)} > 0$  (beachte auch 1.14(1)). Außerdem ist  $h_s f$  strikt hyperbolisch für alle  $s > 0$  nach 1.14(3). Damit ist

$$h: \mathcal{H}_d^+(e) \times [0, 1] \rightarrow \mathcal{H}_d^+(e), \quad (f, s) \mapsto h_s f$$

eine Deformationsretraktion von  $\mathcal{H}_d^+(e)$  (bzw.  $\mathcal{H}_{sd}^+(e)$ ) auf  $g = h_1 f \in \mathcal{H}_{sd}^+(e)$ . □

Damit ist Theorem 1.11 vollständig bewiesen.

**Bemerkung.** Ursprünglich wurde in der Vorlesung  $\mathcal{H}_d(e) \cup \{0\} = \overline{\mathcal{H}_{sd}(e)}$  behauptet. Das ist falsch, betrachte beispielsweise  $f_t := tx_1^2 - x_2^2 - x_3^2$ . Für  $t > 0$  ist diese Form hyperbolisch bzgl.  $e_1$ , dagegen ist  $f_0$  bzgl. keinem Punkt hyperbolisch (d.h.  $\mathcal{H}_2(e_1) \cup \{0\}$  ist nicht abgeschlossen).

**1.16 Bemerkung.** Es ist  $\mathcal{H}_d(e) = \mathcal{H}_d^+(e) \cup \mathcal{H}_d^-(e)$  und die beiden Mengen  $\mathcal{H}_d^\pm(e)$  sind kontrahierbar. Typische Beispiele von kontrahierbaren Mengen sind sternförmige Mengen.  $\mathcal{H}_d(e)$  ist für  $d \geq 2$  jedoch nicht sternförmig (Aufgabe 5). Die Formen

$$f_\pm := x^2 \pm 2axy + y^2 = (x \pm ay)^2 - (a^2 - 1)y^2 \in \mathbb{R}[x, y]$$

sind für  $a > 1$  strikt hyperbolisch bzgl.  $e_1$ , jedoch ist  $\frac{1}{2}f_+ + \frac{1}{2}f_- = x^2 + y^2$  nicht hyperbolisch bzgl.  $e_1$ . (Das zeigt (die schwächere Aussage), dass  $\mathcal{H}_2(e_1)$  nicht konvex ist.)

## §2 Beweis der (Ex-)Lax-Vermutung

**2.1 Theorem** (Helton-Vinnikov 2006). Sei  $f \in \mathbb{R}[x, y, z]$  eine bzgl.  $e \in \mathbb{R}^3$  hyperbolische Form mit  $\deg(f) = d$  und  $f(e) > 0$ . Dann gibt es Matrizen  $A, B, C \in \mathbb{S}^d$  mit

$$f(x, y, z) = \det(xA + yB + zC)$$

und  $e_1A + e_2B + e_3C \succ 0$  (siehe Theorem 1.3).

Wir diskutieren den algebraischen Beweis von Hanselka<sup>5</sup> (2015).

**2.2** Ein Polynom  $f \in \mathbb{R}[\mathbf{x}]$  heißt ein *RZ-Polynom* („real zero“) bzgl.  $u \in \mathbb{R}^n$ , falls  $f(u) \neq 0$  gilt und das Polynom  $f(u + tv) \in \mathbb{R}[t]$  für alle  $v \in \mathbb{R}^n$  nur reelle Nullstellen hat. Ist  $f \in \mathbb{R}[\mathbf{x}]$  RZ bzgl.  $u \in \mathbb{R}^n$ , so ist die Form

$$f^h := x_0^{\deg(f)} f\left(\frac{x_1}{x_0}, \dots, \frac{x_n}{x_0}\right) \in \mathbb{R}[x_0, \mathbf{x}]$$

hyperbolisch bzgl.  $(1, u) \in \mathbb{R}^{n+1}$ . Ist umgekehrt  $f \in \mathbb{R}[x_0, \mathbf{x}]$  eine bzgl.  $(1, u)$  hyperbolische Form, so ist  $f(1, x_1, \dots, x_n) \in \mathbb{R}[\mathbf{x}]$  RZ bzgl.  $u \in \mathbb{R}^n$ . Das Analogon des Hyperbolizitätskegels für ein RZ-Polynom  $f$  (bzgl.  $u \in \mathbb{R}^n$ ) ist die starr konvexe Menge  $S_u(f) := \{v \in \mathbb{R}^n : \forall x \in [u, v] : f(x) \neq 0\}$ .

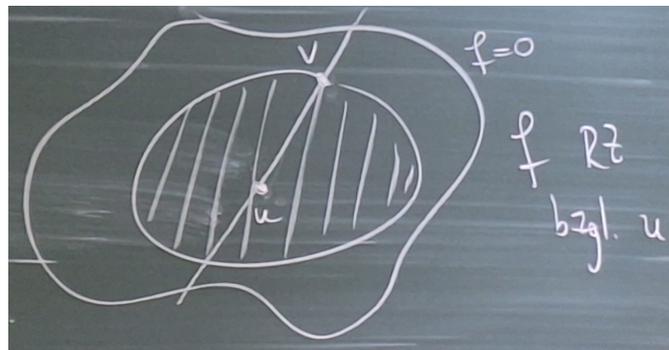


Abbildung 3: Der „Hyperbolizitätskegel“ eines RZ-Polynoms

Für  $v \in \mathbb{R}^n$  (und  $f$  RZ bzgl.  $u$ ) ist  $\mu(f, v) = \text{ord}_{t=0} f(tu + (1-t)v)$  (Satz 1.8).

Sind beispielsweise  $A_0, \dots, A_n \in \mathbb{S}^d$ ,  $A(x) := A_0 + \sum_{i=1}^n x_i A_i$  und ist  $u \in \mathbb{R}^n$  mit  $A(u) \succ 0$ , so ist  $f(x) := \det A(x)$  RZ bzgl.  $u$  (das folgt aus 1.2, denn es gilt  $f(x) = g(1, x_1, \dots, x_n)$  mit  $g(x_0, \dots, x_n) := \det(x_0 A_0 + \dots + x_n A_n) \in \mathbb{R}[x_0, \mathbf{x}]$ ). Die zugehörige starr konvexe Menge ist (ebenfalls nach 1.2)  $S_u(f) = \{v \in \mathbb{R}^n : A(v) \succeq 0\}$ .

Wie betrachten die folgende Umformulierung von Theorem 2.1:

**2.3 Theorem.** Sei  $f \in \mathbb{R}[x, y]$  RZ bzgl.  $0$  mit  $f(0) = 1$  und sei  $d = \deg(f)$ . Dann gibt es Matrizen  $A, B \in \mathbb{S}^d$  mit  $f(x, y) = \det(I_d + xA + yB)$ .

<sup>5</sup>Christoph HANSELKA (\*19??)

**Lemma.** Die Aussagen der beiden Theoreme 2.1 und 2.3 sind äquivalent.

*Beweis.* Gelte zunächst 2.1 und sei  $f$  gegeben wie in 2.3. Die Form  $f^h(x, y, z)$  ist hyperbolisch bzgl.  $e_3$ , nach 2.1 gibt es also  $A, B, C \in \mathbb{S}^d$  mit  $C \succ 0$  und  $f^h(x, y, z) = \det(xA + yB + zC)$ . Wähle ein  $S \in \text{GL}_d(\mathbb{R})$  mit  $C = SS^\top$ , dann ist  $xA + yB + zC = S(xA' + yB' + zI)S^\top$  für  $A' := S^{-1}AS^{-\top}$  und  $B' := S^{-1}BS^{-\top}$ . Wegen  $\det(SS^\top) = \det(C) = f^h(e_3) = f(0) = 1$  folgt  $f(x, y) = f^h(x, y, 1) = \det(xA' + yB' + I_d)$ .

Gelte nun 2.3 und sei  $f$  gegeben wie in 2.1. Wähle entsprechende Koordinaten mit  $e = e_3$ , dann ist  $g(x, y) := \frac{1}{f(e)}f(x, y, 1)$  RZ bzgl. 0 mit  $g(0) = 1$ . Nach 2.3 ist also  $g(x, y) = \det(I_d + xA + yB)$  für geeignete  $A, B \in \mathbb{S}^d$ , d.h.  $f(x, y, 1) = \det(\alpha I_d + x\alpha A + y\alpha B)$  für ein  $\alpha \in \mathbb{R}$  mit  $\alpha^d = f(e)$ .  $\square$

**2.4** Sei  $h(x, y, z) \in \mathbb{R}[x, y, z]$  eine bzgl.  $e_3$  hyperbolische Form mit  $\deg(h) = d$  und  $h(e_3) = 1$ . Nach Aufgabe 4(a) kann man annehmen, dass  $h$  irreduzibel ist. Dann ist  $f(x, t) := h(x, 1, t) \in \mathbb{R}[x, t]$  irreduzibel und normiert vom Grad  $d$  in der Variable  $t$ . Wir suchen Matrizen  $A, B \in \mathbb{S}^d$  mit  $f(x, t) = \det(tI_d + xA + B)$ . Das Polynom  $f(x, t)$  hat die folgende Eigenschaft: Für jedes  $\xi \in \mathbb{R}$  hat das Polynom  $f_\xi(t) := f(\xi, t) \in \mathbb{R}[t]$  nur reelle Nullstellen und ist normiert vom Grad  $d$ . Denn es gilt  $f_\xi(t) = h(te_3 - u)$  für  $u := (-\xi, -1, 0)$ .

Für den Beweis nehmen wir an, dass die affine Kurve  $C := \mathcal{V}(f) \subseteq \mathbb{A}^2$  nichtsingulär ist (d.h. sie besitzt keine singulären  $\mathbb{C}$ -Punkte (Punkte  $(a, b) \in \mathbb{C}^2$  mit  $f(a, b) = \frac{\partial f}{\partial x}(a, b) = \frac{\partial f}{\partial t}(a, b) = 0$ )). Aus 1.8 folgt daher, dass für jedes  $\xi \in \mathbb{R}$  alle (reellen) Nullstellen von  $f_\xi(t) = f(\xi, t)$  einfach sind.

**2.5** Setze  $A := \mathbb{R}[x]$ . Die  $A$ -Algebra  $B := \mathbb{R}[x, t]/\langle f \rangle = \mathbb{R}[C]$  ist als  $A$ -Modul frei vom Rang  $d$  mit  $A$ -Basis  $1, t, \dots, t^{d-1}$ . Sei  $f(x, t) = t^d + a_1(x)t^{d-1} + \dots + a_d(x)$  mit  $a_i = a_i(x) \in A$ . Dabei ist  $\deg(a_i(x)) \leq i$  für alle  $i \in [d]$ . Die Multiplikation  $\mu_t: B \rightarrow B, p \mapsto tp$  wird (bzgl. obiger  $A$ -Basis) durch die Matrix

$$\begin{pmatrix} 0 & \cdots & 0 & -a_d(x) \\ 1 & & & \vdots \\ & \ddots & & \vdots \\ & & 1 & -a_1(x) \end{pmatrix} \in A^{d \times d}$$

beschrieben. Das charakteristische Polynom ist  $\det(t \text{id} - \mu_t) = f(x, t)$ , wie man per Induktion sieht. Auf dem  $A$ -Modul  $B$  betrachten wir die symmetrische Bilinearform

$$b: B \times B \rightarrow A, \quad b(p, q) := \text{tr}_{B/A}(pq) = \text{tr} \begin{pmatrix} B \rightarrow B \\ b \mapsto pqb \end{pmatrix}.$$

Weiter betrachten wir für  $\xi \in \mathbb{R}$  das folgende Tensorprodukt:

$$\begin{array}{ccc} B & \longrightarrow & B_\xi := B \otimes_{A, \xi} \mathbb{R} = \mathbb{R}[t]/\langle f_\xi \rangle \\ \uparrow & & \uparrow \\ \mathbb{R}[x] = A & \xrightarrow{\xi} & \mathbb{R} \end{array}$$

Für die zugehörige Spurform  $b_\xi: B_\xi \times B_\xi \rightarrow \mathbb{R}$  gilt explizit (siehe RAG, 1.3.30)

$$b_\xi(t^i, t^j) = \text{tr}_{B_\xi/\mathbb{R}}(t^{i+j}) = \sum_{k=1}^d \alpha_k^{i+j},$$

wobei  $\alpha_1, \dots, \alpha_d \in \mathbb{R}$  die Nullstellen von  $f_\xi(t)$  seien (d.h.  $b_\xi(t^i, t^j)$  ist gerade die  $(i+j)$ -te Newtonsumme von  $f_\xi(t)$ ). Die Matrix der symmetrischen Bilinearform  $b_\xi$  ist also genau die Hermitematrix  $H(f_\xi)$ . Da alle Nullstellen von  $f_\xi(t)$  reell und einfach sind, ist  $b_\xi \succ 0$  (siehe RAG, 1.3.26).

**Was bisher geschah.** Wir haben  $f \in \mathbb{R}[x, t]$ ,  $f = t^d + a_1(x)t^{d-1} + \dots + a_d(x)$  mit  $a_i(x) \in \mathbb{R}[x]$  und  $\deg(a_i) \leq i$  für alle  $i$ . Die affine Kurve  $C = \mathcal{V}(f) \subseteq \mathbb{A}^2$  ist glatt. Für  $\xi \in \mathbb{R}$  hat  $f(\xi, t) = f_\xi(t)$  genau  $d$  verschiedene reelle Nullstellen. Das Ziel ist es, Matrizen  $M, N \in \mathcal{S}^d$  mit

$$f(x, t) = \det(tI_d + xM + N)$$

zu finden. Es ist  $A = \mathbb{R}[x]$  und  $B = \mathbb{R}[C] = \mathbb{R}[x, t]/\langle f \rangle$  (ein freier  $A$ -Modul mit Basis  $1, t, \dots, t^{d-1}$ ). Wir betrachten die symmetrische Bilinearform  $b: B \times B \rightarrow A$ ,  $(p, q) \mapsto \text{tr}(pq) = \text{tr}_{B/A}(pq)$ . Für  $\xi \in \mathbb{R}$  und  $B_\xi = \mathbb{R}[t]/\langle f_\xi \rangle$  ist  $b_\xi: B_\xi \times B_\xi \rightarrow \mathbb{R}$  die Hermiteform von  $f_\xi(t)$ . Es gilt  $b_\xi \succ 0$ .

**2.6** Sei  $R$  ein Ring und sei  $M$  ein endlich erzeugter freier  $R$ -Modul. Eine symmetrische Bilinearform  $b: M \times M \rightarrow R$  heißt *unimodular*, falls die induzierte lineare Abbildung

$$\varphi: M \rightarrow M^\vee := \text{Hom}_R(M, R), \quad x \mapsto b(x, \cdot)$$

bijektiv ist. Ist  $v_1, \dots, v_n$  eine  $R$ -Basis von  $M$  mit dualer Basis  $v_1^\vee, \dots, v_n^\vee$  von  $M^\vee$ , so wird  $\varphi$  durch die Matrix  $T := (b(v_i, v_j))_{i,j}$  beschrieben.  $b$  ist also genau dann unimodular, wenn  $\det(T) \in R^*$  ist. In unserer Situation 2.5 wird  $b: B \times B \rightarrow A$  im Allgemeinen **nicht** unimodular sein (denn es kann ein  $\xi \in \mathbb{C}$  geben, sodass  $f(\xi, t)$  eine mehrfache  $\mathbb{C}$ -Nullstelle hat und in diesem Fall ist  $\text{rk}(b_\xi) < d$ , also ist  $b$  nicht unimodular). Zunächst nehmen wir aber an, dass  $b$  unimodular ist.

**2.7 Theorem** (Harder<sup>6</sup>). Sei  $k$  ein Körper mit  $\text{char}(k) \neq 2$  und sei  $T \in \text{Sym}_n(k[x])$  mit  $\det(T) \in k^*$ . Dann existiert ein  $S \in \text{GL}_n(k[x])$ , sodass  $S^\top T S$  eine Diagonalmatrix (mit Einträgen in  $k^*$ ) ist.

*Beweis.* Siehe [3], Chapter 6, Theorem 3.3. □

**2.8** In 2.5 sei  $b$  also unimodular. Wegen  $b_\xi \succ 0$  für  $\xi \in \mathbb{R}$  hat der  $A$ -Modul  $B$  nach Theorem 2.7 eine Orthonormalbasis  $p_1, \dots, p_d$  (d.h. es gilt  $b(p_i, p_j) = \delta_{ij}$  für alle  $i, j$ ). Die  $A$ -lineare Abbildung  $\mu_t: B \rightarrow B$ ,  $p \mapsto tp$  ist selbstadjungiert bzgl.  $b$ , denn es gilt  $b(tp, q) = \text{tr}((tp)q) = b(p, tq)$ . Bzgl. der obigen Orthonormalbasis wird  $\mu_t$  also durch eine symmetrische Matrix  $M(x) \in \text{Sym}_d(A)$  beschrieben. Es ist  $f(x, t) = \det(t \text{id} - \mu_t) = \det(tI_d - M(x))$ . Diese symmetrische Determinantendarstellung von  $f(x, t)$  ist automatisch linear, d.h. es gilt  $M(x) = xM_1 + M_2$  für geeignete  $M_1, M_2 \in \mathcal{S}^d$ : Es ist  $f = t^d + \sum_{i=1}^d a_i(x)t^{d-i}$  mit  $a_i \in A$  und  $\deg(a_i) \leq i$ . Wende Aufgabe 7 auf  $K := \text{Quot}(A) = \mathbb{R}(x)$  und die diskrete Bewertung

$$v\left(\frac{p(x)}{q(x)}\right) = \deg(q) - \deg(p)$$

auf  $K$  mit Restklassenkörper  $\mathbb{R}$  (betrachte  $\frac{p}{q} \mapsto \frac{p_m}{\text{LC}(q)}$  für  $p = \sum_{i=0}^{\deg(p)} p_i x^i$  und  $m = \deg(q)$ ) an. Es folgt

$$v(M(x)) = \min_{i \in [d]} \frac{v(a_i(x))}{i} \geq -1,$$

denn es ist  $\deg(a_i) \leq i$ , also  $v(a_i) \geq -i$  bzw.  $\frac{v(a_i)}{i} \geq -1$ .

**2.9 Satz** (Eulers<sup>7</sup> Lemma). Sei  $L/K$  eine endliche separable Körpererweiterung mit Körpergrad  $n := [L : K] < \infty$ , sei  $u \in L$  mit  $L = K(u)$  und sei  $f(t) := \text{MinPol}(u/K) \in K[t]$ . Dann gelten

$$\text{tr}_{L/K}\left(\frac{u^{n-1}}{f'(u)}\right) = 1 \quad \text{und} \quad \text{tr}_{L/K}\left(\frac{u^i}{f'(u)}\right) = 0$$

für alle  $i \in \{0, \dots, n-2\}$ .

<sup>6</sup>Günter HARDER (\*1938)

<sup>7</sup>Leonhard EULER (1707–1783)

*Beweis.* Sei  $f(t) = \prod_{j=1}^n (t - u_j)$  mit  $u_j \in \overline{K}$ . Da  $f$  separabel ist, ist  $f'(u_j) \neq 0$  für alle  $j$ . Es gilt

$$\sum_{j=1}^n \frac{1}{f'(u_j)} \prod_{k \neq j} (t - u_k) = 1, \quad (*)$$

denn die linke Seite in (\*) hat Grad  $\leq n - 1$  und setzt man  $t = u_\ell$  ein, erhält man für jedes  $\ell$  den Wert 1 (beachte  $f'(t) = \sum_{j=1}^n \prod_{k \neq j} (t - u_k)$ ). Dividiere (\*) durch  $f(t)$  und erhalte

$$\sum_{j=1}^n \frac{1}{f'(u_j)(t - u_j)} = \frac{1}{f(t)}.$$

Schreibe beide Seiten als Polynom in  $\frac{1}{t}$  (Taylorentwicklung um  $t = \infty$ ). Die rechte Seite ist

$$\frac{1}{f(t)} = \left(\frac{1}{t}\right)^n \prod_{j=1}^n \left(\frac{t}{t - u_j}\right) = \left(\frac{1}{t}\right)^n + \left(\text{höhere Potenzen von } \frac{1}{t}\right).$$

Betrachte andererseits die linke Seite: Mit  $s := \frac{1}{t}$  ist

$$\frac{1}{t - u} = \frac{1}{s^{-1} - u} = \frac{s}{1 - su} = s + s^2 u + s^3 u^2 + \dots,$$

also ist die linke Seite

$$\sum_{j=1}^n \frac{1}{f'(u_j)} \left( \frac{1}{t} + \frac{u_j}{t^2} + \frac{u_j^2}{t^3} + \dots \right).$$

Der Koeffizient von  $\left(\frac{1}{t}\right)^i$  in dieser Reihe ist

$$\sum_{j=1}^n \frac{u_j^{i-1}}{f'(u_j)} = \text{tr}_{L/K} \left( \frac{u^{i-1}}{f'(u)} \right)$$

(siehe erneut RAG, 1.3.30), das liefert per Koeffizientenvergleich die Behauptung.  $\square$

Sei jetzt wieder  $f(x, t) \in \mathbb{R}[x, t]$ ,  $A = \mathbb{R}[x]$ ,  $B = A[t]/\langle f \rangle$ ,  $K := \text{Quot}(A)$  und  $L := \text{Quot}(B)$ .

**2.10 Korollar.** Sei  $\delta := \frac{\partial f}{\partial t}$  (als Element in  $B$ ). Die skalierte Spurform

$$\tau: B \times B \rightarrow A, \quad \tau(p, q) := \text{tr}(pq\delta^{-1}) = \text{tr}_{L/K}(pq\delta^{-1})$$

ist (wohldefiniert und) unimodular.

*Beweis.* Es ist  $\delta \neq 0$  (als Element in  $B$ ). Nach Eulers Lemma 2.9 ist  $\text{tr}(t^i \delta^{-1}) \in A$  für alle  $i \in \{0, \dots, d-1\}$  (nämlich 0 für  $i = 0, \dots, d-2$  und 1 für  $i = d-1$ ), also folgt  $\text{tr}(\delta^{-1}B) \subseteq A$ , denn es ist  $B = \bigoplus_{i=0}^{d-1} At^i$ . Daher ist  $\tau$  wohldefiniert als Bilinearform  $B \times B \rightarrow A$ . Die Matrix von  $\tau$  bzgl.  $1, t, \dots, t^{d-1}$  ist

$$\begin{pmatrix} 0 & & 1 \\ & \ddots & \\ 1 & & * \end{pmatrix}, \quad \text{denn es gilt } \tau(t^i, t^j) = \text{tr}(t^{i+j}\delta^{-1}) = \begin{cases} 0, & \text{falls } i+j < d-1, \\ 1, & \text{falls } i+j = d-1. \end{cases}$$

Somit ist  $\det(\tau) = \pm 1 \in A^*$ , d.h.  $\tau$  ist unimodular.  $\square$

Durch den Übergang von  $b$  zu  $\tau$  haben wir leider die positive Definitheit verloren (vgl. Aufgabe 8).

**2.11 Satz.** Sei  $C$  eine nichtsinguläre irreduzible affine Kurve über einem vollkommenen Körper  $k$ . Dann ist  $k[C]$  ein Dedekindring. Ist  $k = \mathbb{C}$ , so ist die Divisorenklassengruppe  $\text{Cl}(C)$  dividierbar.

**Erklärung.** Ein *Dedekindring* ist ein eindimensionaler integrierter noetherscher Ring  $R$ , der ganz abgeschlossen ist (äquivalent: für alle  $\mathfrak{m} \in \text{Max}(R)$  ist  $R_{\mathfrak{m}}$  ein diskreter Bewertungsring). Sei  $k = \mathbb{C}$  und setze  $\text{Div}(C) := \bigoplus_{\xi \in C} \mathbb{Z}[\xi]$ . Zu  $f \in k(C)^*$  ist  $\text{div}(f) := \sum_{\xi \in C} v_{\xi}(f) \cdot [\xi] \in \text{Div}(C)$ . Die Sequenz

$$k(C)^* \xrightarrow[f \mapsto \text{div}(f)]{\text{div}} \text{Div}(C) \longrightarrow \text{Cl}(C) \longrightarrow 0$$

ist exakt. Die *gebrochenen Ideale* von  $k[C]$  bilden eine zu  $\text{Div}(C)$  isomorphe abelsche Gruppe. In einem Dedekindring  $R$  hat jedes gebrochene Ideal  $I$  eine eindeutige Darstellung

$$I = \prod_{\mathfrak{p} \in \text{Max}(R)} \mathfrak{p}^{n(\mathfrak{p})}$$

mit  $n(\mathfrak{p}) \in \mathbb{Z}$  und  $n(\mathfrak{p}) = 0$  für fast alle  $\mathfrak{p} \in \text{Max}(R)$ . Dabei ist  $\mathfrak{p}^{-1} := \text{Hom}(\mathfrak{p}, R)$ . Die Gruppe

$$\text{Cl}(C) := \text{Cl}(k[C]) := \frac{\{\text{gebrochene Ideale von } k[C]\}}{\{\text{gebrochene Hauptideale von } k[C]\}}$$

heißt die *Idealklassengruppe* (oder *Divisorenklassengruppe*) von  $k[C]$ . Eine abelsche Gruppe  $(G, +)$  heißt *dividierbar*, falls  $\forall n \in \mathbb{N}: \forall x \in G: \exists y \in G: x = ny$  gilt. Die Dividierbarkeit von  $\text{Cl}(C)$  (in 2.11) bedeutet, dass es für jedes gebrochene Ideal  $I$  von  $k[C]$  und jedes  $n \in \mathbb{N}$  ein gebrochenes Ideal  $J$  und ein  $f \in k(C)^*$  mit  $I = fJ^n$  gibt. Wir werden dies nur für  $n = 2$  verwenden.

**2.12 Lemma.** Es gibt ein gebrochenes Ideal  $I$  von  $B$  und eine Quadratsumme  $c \neq 0$  in  $L$  mit  $I^2 = \langle \frac{c}{\delta} \rangle$  (ein gebrochenes Hauptideal).

*Beweis.* Sei  $B_{\mathbb{C}} := B \otimes_{\mathbb{R}} \mathbb{C} = \mathbb{C}[C]$  und sei  $\mathcal{I}(B_{\mathbb{C}})$  die Gruppe der gebrochenen Ideale von  $B_{\mathbb{C}}$ . Es ist  $\text{Quot}(B_{\mathbb{C}}) = \mathbb{C}(C) = L(\sqrt{-1})$ . Das Hauptideal  $\langle \delta \rangle = B\delta$  in  $B = \mathbb{R}[C]$  hat keine  $\mathbb{R}$ -Punkte, d.h. für  $(\xi, s) \in \mathbb{R}^2$  mit  $f(\xi, s) = 0$  ist  $\delta(\xi, s) \neq 0$  (da  $f_{\xi}(t)$  nur einfache Nullstellen hat). Das Hauptideal  $\langle \delta \rangle_{\mathbb{C}} := B_{\mathbb{C}}\delta$  ist deshalb ein Produkt von Primidealen und ihren Konjugierten. Also gilt  $\langle \delta \rangle_{\mathbb{C}} = J_0 \bar{J}_0$  für ein Ideal  $J_0 \subseteq B_{\mathbb{C}}$ . Da  $\text{Cl}(B_{\mathbb{C}})$  2-dividierbar ist, ist  $J_0 = qJ_1^2$  mit  $J_1 \in \mathcal{I}(B_{\mathbb{C}})$  und  $q \in \mathbb{C}(C)^*$ . Es folgt  $\langle \delta \rangle_{\mathbb{C}} = c(J_1 \bar{J}_1)^2$ . Dabei ist  $c := q\bar{q} \in L^*$  eine Summe von zwei Quadraten in  $L$  (wegen  $(a + ib)(a - ib) = a^2 + b^2$ ). Es folgt  $\langle \delta \rangle = cJ^2$  (in  $\mathcal{I}(B)$ ) mit dem gebrochenen Ideal  $J := J_1 \bar{J}_1 \cap L$  von  $B$ . Für das gebrochene Ideal  $I := J^{-1}$  von  $B$  ist also  $I^2 = \langle \frac{c}{\delta} \rangle$  (in  $\mathcal{I}(B)$ ).  $\square$

Seien nun ein gebrochenes Ideal  $I$  und eine Quadratsumme  $c$  wie in Lemma 2.12 fixiert.

**2.13 Lemma.** Die symmetrische Bilinearform

$$\beta: I \times I \rightarrow A, \quad (p, q) \mapsto \text{tr} \left( \frac{pq}{c} \right)$$

über  $A$  ist unimodular und der  $A$ -Modul  $I$  besitzt eine Orthonormalbasis bzgl.  $\beta$ .

*Beweis.* Der  $A$ -Modul  $I$  ist frei vom Rang  $d$ . Es gilt

$$\beta(p, q) = \text{tr} \left( \frac{pq}{c} \right) \in \text{tr} \left( \frac{1}{c} I^2 \right) = \text{tr} \left( \frac{1}{\delta} B \right) \subseteq A$$

nach 2.9. Lokalisieren in einem Primideal von  $B$ : Lokal ist  $I = B'g$  (ein gebrochenes Hauptideal der Lokalisierung  $B'$  von  $B$ ). Es ist  $I^2 = \langle \frac{c}{\delta} \rangle$ , also  $g^2 = u \cdot \frac{c}{\delta}$  mit  $u \in (B')^*$ . Lokal ist  $\beta$  die Abbildung

$$B' \times B' \rightarrow A', \quad (p, q) \mapsto \beta(pq, pq) = \text{tr} \left( \frac{pqg^2}{c} \right) = \text{tr} \left( \frac{upq}{\delta} \right)$$

und diese ist nach 2.10 unimodular.

Sei  $0 \neq p \in L$ . Es gibt ein  $\xi \in \mathbb{R}$  so, dass  $p$  und  $c$  weder Null- noch Polstellen in einem Punkt  $(\xi, s)$  für  $s \in \mathbb{C}$  haben. Da  $c$  eine Quadratsumme ist, gilt für jedes solche  $\xi$

$$\beta(p, p)(\xi) = \text{tr} \left( \frac{p^2}{c} \right) (\xi) = \sum_{j=1}^d \frac{p(\xi, s_j)^2}{c(\xi, s_j)} > 0,$$

wobei  $s_1, \dots, s_d$  die Nullstellen von  $f_\xi(t) = f(\xi, t)$  seien. Nach dem Satz von Harder hat  $I$  also eine  $A$ -Basis  $p_1, \dots, p_d$  mit  $\beta(p_i, p_j) = \delta_{ij} a_i$  und  $a_i > 0$ , d.h.  $I$  besitzt eine Orthonormalbasis.  $\square$

**2.14 Beweisende.** Verfahre wie in 2.8 (mit  $\beta$  statt  $b$ ): Die  $A$ -lineare Abbildung  $\mu_t: I \rightarrow I$  ist selbstadjungiert bzgl.  $\beta$  und hat das charakteristische Polynom  $\det(t \text{id} - \mu_t) = f(x, t)$ . Die Matrix  $M(x)$  von  $\mu_t$  bzgl.  $p_1, \dots, p_d$  ist symmetrisch. Nach Aufgabe 7 haben alle Einträge von  $M(x)$  Grad  $\leq 1$ , also erhalten wir eine Darstellung  $f(x, t) = \det(tI_d + xA + B)$ . Im Fall, dass  $f$  strikt hyperbolisch ist, ist damit die Lax-Vermutung bewiesen.

**2.15 Allgemeiner Fall.** Sei  $f \in \mathbb{R}[x, y, z]_d$  hyperbolisch bzgl.  $e = e_1$  mit  $f(e) = 1$ . Nach dem Theorem von Nuij existiert eine Folge  $(f_j)_{j \geq 1} \subseteq \mathcal{H}S_d(e)$  mit  $f_j(e) = 1$  für alle  $j \in \mathbb{N}$ , die gegen  $f$  konvergiert. Es existiert sogar eine solche Folge, dass alle  $\mathcal{V}(f_j)$  glatt sind. Der Grund hierfür ist, dass sich jedes  $f_j$  durch glatte Formen approximieren lässt und diese sind automatisch strikt hyperbolisch, falls sie nahe bei  $f_j$  liegen. Für alle  $j$  ist also  $f_j(x, y, z) = \det(xA_j + yB_j + zI_d)$  und die Abbildung  $\phi: S^d \times S^d \rightarrow \mathbb{R}[x, y, z]_d$ ,  $(A, B) \mapsto \det(xA + yB + zI_d)$  ist eigentlich (Aufgabe 6).

$$\begin{array}{ccc} S^d \times S^d & & \{(A, B)\} \xleftarrow[\text{Teilfolge}]{\text{konvergente}} \{(A_j, B_j)\} \\ \downarrow \phi \text{ eigentlich} & & \downarrow \qquad \qquad \qquad \downarrow \\ \mathbb{R}[x, y, z]_d & & f \longleftarrow \{f_j\} \end{array}$$

### §3 Spektraederschatten: Die Sätze von Helton-Nie

**Erinnerung.** Ein *Spektraeder* ist eine Menge  $\{\xi \in \mathbb{R}^n: A(\xi) \succeq 0\}$  mit  $A_i \in S^d$  und  $A(x) = A_0 + \sum_{i=1}^n x_i A_i$ . Spektraeder sind basisch abgeschlossen, semialgebraisch, konvex und sogar starr konvex (für  $n = 2$  ist (nach §2) auch jede Menge mit diesen Eigenschaften ein Spektraeder, für  $n > 2$  ist die Frage noch offen). Ein *Spektraederschatten* ist eine Menge  $\{\xi \in \mathbb{R}^n: \exists \eta \in \mathbb{R}^m: A(\xi, \eta) \succeq 0\}$  mit  $A_i, B_j \in S^d$  und

$$A(x, y) = A_0 + \sum_{i=1}^n x_i A_i + \sum_{j=1}^m y_j B_j.$$

Spektraederschatten sind konvex und semialgebraisch. Die Sätze von Helton-Nie<sup>8</sup> besagen, dass eine Menge  $K \subseteq \mathbb{R}^n$  ein Spektraederschatten ist, falls  $K$  kompakt, konvex und semialgebraisch ist und  $\partial K$  „gutartig“ ist (Krümmung, Singularitäten, ...).

**3.1** Sei  $\mathbf{g} = (g_1, \dots, g_r)$  ein Tupel in  $\mathbb{R}[\mathbf{x}]^r$ , sei  $S := \mathcal{S}(\mathbf{g}) = \{\xi \in \mathbb{R}^n: \forall i \in [r]: g_i(\xi) \geq 0\}$  und sei  $M := QM(\mathbf{g}) = \{s_0 + s_1 g_1 + \dots + s_r g_r \mid s_0, \dots, s_r \in \Sigma \mathbb{R}[\mathbf{x}]^2\}$ . Setze  $g_0 := 1$  und betrachte

$$M_k := \left\{ \sum_{i=0}^r s_i g_i \mid \forall i \in \{0, \dots, r\}: s_i \in \Sigma \mathbb{R}[\mathbf{x}]^2 \wedge \deg(s_i g_i) \leq k \right\} \subseteq M \cap \mathbb{R}[\mathbf{x}]_{\leq k}$$

(die trunkierten quadratischen Moduln) für  $k \in \mathbb{N}_0$ .  $M_k$  ist eine semialgebraische Menge in  $\mathbb{R}[\mathbf{x}]_{\leq k}$ . Für  $f \in \mathbb{R}[\mathbf{x}]$ , etwa  $f = \sum_{\alpha} c_{\alpha} \mathbf{x}^{\alpha}$  mit  $c_{\alpha} \in \mathbb{R}$  sei  $\|f\| := \max_{\alpha} |c_{\alpha}|$  (die  $L^{\infty}$ -Norm).

<sup>8</sup>Jiawang NIE (\*19??)

**3.2 Theorem.** Seien  $\mathbf{g}$ ,  $S$  und  $M$  gegeben wie in 3.1 und sei  $M$  archimedisch. Für jedes  $d \geq 1$  und jedes  $c \in (0, \infty)$  gibt es ein  $k = k(\mathbf{g}, d, c) \in \mathbb{N}$  so, dass  $M_k$  jedes  $f \in \mathbb{R}[\mathbf{x}]_{\leq d}$  mit  $f \geq \frac{1}{c}$  auf  $S$  und  $\|f\| \leq c$  enthält.

**3.3** Formuliere Theorem 3.2 zunächst koordinatenfrei: Sei  $A$  eine endlich erzeugte  $\mathbb{R}$ -Algebra, sei  $M := QM(\mathbf{g}) \subseteq A$  ein archimedischer quadratischer Modul mit  $\mathbf{g} = (g_1, \dots, g_r) \in A^r$  und sei  $S := X_M = \{\alpha \in \text{Hom}(A, \mathbb{R}) : \forall i \in [r]: \alpha(g_i) \geq 0\}$ .

Wir zeigen: Für jeden linearen Teilraum  $U \subseteq A$  mit  $\dim(U) < \infty$  und jedes  $c > 0$  existiert ein linearer Teilraum  $V \subseteq A$  mit  $\dim(V) < \infty$ , sodass gilt: Zu jedem  $f \in U$  mit  $f \geq \frac{1}{c}$  auf  $S$  und  $\|f\| \leq c$  (bzgl. einer fixierten Basis von  $U$ ) gibt es  $s_0, \dots, s_r \in \Sigma V^2$  mit  $f = s_0 + s_1 g_1 + \dots + s_r g_r$ .

**3.4** Ein *Matrixpolynom* vom Format  $r \times s$  ist eine Matrix  $T = (t_{ij}) \in \mathbb{R}[\mathbf{x}]^{r \times s}$ . Für ein solches  $T$  setzen wir  $\deg(T) := \max_{i,j} \deg(t_{ij})$  und  $\|T\| := \max_{i,j} \|t_{ij}\|$ . Ist  $T \in \text{Sym}_m(\mathbb{R}[\mathbf{x}])$ , so heißt  $T$  (*matrix-)*sos, falls es  $m \times m$ -Matrixpolynome  $T_\nu$  mit  $T = \sum_\nu T_\nu T_\nu^\top$  gibt oder äquivalent, falls  $T = UU^\top$  für ein Matrixpolynom  $U$  mit  $m$  Zeilen gilt.

**3.5 Theorem.** Sei  $\mathbf{g} = (g_1, \dots, g_r) \in \mathbb{R}[\mathbf{x}]^r$ , sei der Modul  $M = QM(\mathbf{g})$  archimedisch und sei  $S = \mathcal{S}(\mathbf{g}) \subseteq \mathbb{R}^n$ . Für alle  $d, m \geq 1$  und alle  $0 < c \in \mathbb{R}$  gibt es ein  $k = k(\mathbf{g}, d, m, c) \in \mathbb{N}$ , sodass gilt: Ist  $T \in \text{Sym}_m(\mathbb{R}[\mathbf{x}])$  mit  $\deg(T) \leq d$ ,  $\|T\| \leq c$  und  $T \succeq \frac{1}{c} I_m$  auf  $S$  (d.h.  $T(\xi) - \frac{1}{c} I_m \succeq 0$  für alle  $\xi \in S$ ), so gibt es sos Matrixpolynome  $T_0, \dots, T_r \in \text{Sym}_m(\mathbb{R}[\mathbf{x}])$  mit  $\deg(T_i) \leq k$  und  $T = T_0 + g_1 T_1 + \dots + g_r T_r$ .

**3.6** Für den Beweis von 3.5 genügt es, Satz 3.2 zu zeigen: Betrachte den kommutativen Teilring  $B := \mathbb{R}[\mathbf{x}, T]$  von  $\mathbb{R}[\mathbf{x}]^{m \times m}$  (aus symmetrischen Matrizen). Die Ringerweiterung  $\mathbb{R}[\mathbf{x}] \subseteq B$  ist endlich, der von  $M \subseteq \mathbb{R}[\mathbf{x}]$  in  $B$  erzeugte quadratische Modul  $M^B$  ist also archimedisch. Aus der Voraussetzung  $T \succ \frac{1}{c} I$  auf  $S$  folgt  $T > \frac{1}{c}$  auf

$$X_{M^B} = \{\beta: B \rightarrow \mathbb{R} \mid \forall i \in [r]: \beta(g_i) \geq 0\}$$

(siehe RAG, 5.5.21, der Grund war, dass  $\beta(T)$  für ein solches  $\beta$  ein Eigenwert von  $T(u)$  ist ( $\beta|_{\mathbb{R}[\mathbf{x}]}$  korrespondiert zu einer Auswertung in  $u \in S$ )). Angenommen Theorem 3.2 ist bewiesen (und damit auch 3.3), dann kann man 3.3 auf den quadratischen Modul  $M^B \subseteq B$  und auf  $T$  anwenden, das liefert Theorem 3.5. (Die Matrizen  $T_i$  kann man also sogar als sos in  $B$  finden.)  $\square$

**3.7 Beweis von Theorem 3.2.** Für  $\mathbf{g}$ ,  $S$  und  $M$  wie in der Voraussetzung,  $d \geq 1$  und  $c > 0$  sei

$$P_{d,c} := \left\{ f \in \mathbb{R}[\mathbf{x}]_{\leq d} : f|_S \geq \frac{1}{c}, \|f\| \leq c \right\} \subseteq M \cap \mathbb{R}[\mathbf{x}]_{\leq d},$$

also

$$P_{d,c} \subseteq \bigcup_{k \geq 1} (M_k \cap \mathbb{R}[\mathbf{x}]_{\leq d}) \quad (*)$$

(eine Vereinigung von semialgebraischen Mengen). Dabei sei  $M_k$  wie in 3.1. Wir wollen  $P_{d,c} \subseteq M_k$  für ein  $k \geq 1$  zeigen. Nach RAG I, Aufgabe 43 ist das äquivalent dazu, dass (\*) nach beliebiger reell abgeschlossener Grundkörpererweiterung gilt. Zu zeigen ist also: Ist  $R \supseteq \mathbb{R}$  reell abgeschlossen, so gilt

$$(P_{d,c})_R \subseteq \bigcup_{k \geq 1} \left( (M^{R[\mathbf{x}]})_k \cap R[\mathbf{x}]_{\leq d} \right).$$

Daher ist zu zeigen: Für  $f \in R[\mathbf{x}]_{\leq d}$  mit  $f|_{S_R} \geq \frac{1}{c}$  und  $\|f\| \leq c$  ist  $f \in M^{R[\mathbf{x}]} := QM_{R[\mathbf{x}]}(\mathbf{g})$ . Sei  $\mathcal{O}$  die konvexe Hülle von  $\mathbb{R}$  in  $R$ , sei  $M^\mathcal{O} := QM_{\mathcal{O}[\mathbf{x}]}(\mathbf{g}) \subseteq \mathcal{O}[\mathbf{x}]$  und behaupte, dass  $M^\mathcal{O}$  ein archimedischer quadratischer Modul in  $\mathcal{O}[\mathbf{x}]$  ist.  $O(M^\mathcal{O}) := \{f \in \mathcal{O}[\mathbf{x}]: \exists n \in \mathbb{N}: n \pm f \in M^\mathcal{O}\}$  ist ein Teilring von  $\mathcal{O}[\mathbf{x}]$  und es gilt  $\mathbb{R}[\mathbf{x}] \subseteq O(M^\mathcal{O})$ , sowie  $\mathcal{O} \subseteq O(M^\mathcal{O})$ , also folgt  $O(M^\mathcal{O}) = \mathcal{O}[\mathbf{x}]$ ,

d.h.  $M^{\mathcal{O}}$  ist archimedisch. Jedes  $f \in R[\mathbf{x}]$  mit  $f|_{S_R} \geq \frac{1}{c}$  und  $\|f\| \leq c$  liegt in  $\mathcal{O}[\mathbf{x}]$ . Aus  $f|_{S_R} \geq \frac{1}{c}$  und  $S_R = \{\xi \in \mathbb{R}^n : \forall i \in [r] : g_i(\xi) \geq 0\}$  folgt  $f \geq \frac{1}{c}$  auf

$$X_{M^{\mathcal{O}}} = \{\alpha : \mathcal{O}[\mathbf{x}] \rightarrow \mathbb{R} \mid \forall i \in [r] : \alpha(g_i) \geq 0\},$$

denn jedes  $\alpha \in X_{M^{\mathcal{O}}}$  faktorisiert als  $\mathcal{O}[\mathbf{x}] \rightarrow \mathbb{R}[\mathbf{x}] \xrightarrow{u} \mathbb{R}$  mit  $u \in X_M = S$ , d.h.  $\alpha(f) = \overline{f(u)} \geq \frac{1}{c} > 0$ . Somit ist  $f > 0$  auf  $X_{M^{\mathcal{O}}}$ , d.h.  $f \in M^{\mathcal{O}}$  nach dem archimedischen Positivstellensatz (für  $M^{\mathcal{O}}$ ). Insbesondere ist  $f \in M^{R[\mathbf{x}]}$ .  $\square$

**3.8** Sei  $K \subseteq \mathbb{R}^n$  eine konvexe Menge. Eine Funktion  $f: K \rightarrow \mathbb{R}$  heißt *konvex*, falls

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

für alle  $x, y \in K$  und alle  $t \in [0, 1]$  gilt. Gilt für alle  $t \in (0, 1)$  und  $x \neq y$  sogar stets ' $<$ ', so heißt  $f$  *strikt konvex*.  $f$  heißt *(strikt) konkav*, falls  $-f$  (strikt) konvex ist.

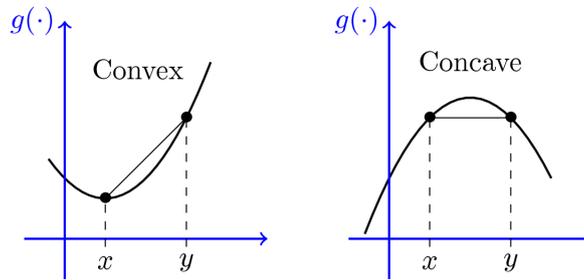


Abbildung 4: (Quelle: [https://www.probabilitycourse.com/chapter6/6\\_2\\_5\\_jensen%27s\\_inequality.php](https://www.probabilitycourse.com/chapter6/6_2_5_jensen%27s_inequality.php))

Sei  $K \subseteq \mathbb{R}^n$  konvex und offen. Ist  $f: K \rightarrow \mathbb{R}$  eine  $C^1$ -Funktion, so ist  $f$  genau dann konvex, wenn  $\langle \nabla f(u), v - u \rangle \leq f(v) - f(u)$  für alle  $u, v \in K$  gilt. Ist  $f$  sogar eine  $C^2$ -Funktion, so ist  $f$  genau dann konvex, wenn  $D^2 f(u) \succeq 0$  für alle  $u \in K$  gilt. Ist  $D^2 f(u) \succ 0$  für alle  $u \in K$ , so ist  $f$  strikt konvex, die Umkehrung ist jedoch im Allgemeinen falsch (z.B.  $f(x) = x^4$ ). Ist  $f$  konvex, so ist  $\{u \in K : f(u) \leq c\}$  eine konvexe Menge.

**3.9 Definition.** Ein Polynom  $f \in \mathbb{R}[\mathbf{x}]$  heißt *sos-konvex*, falls das Matrixpolynom  $D^2 f$  matrix-sos ist. Klar ist, dass jedes sos-konvexe Polynom konvex (auf  $\mathbb{R}^n$ ) ist.

**3.10 Lemma.** Ist  $K \subseteq \mathbb{R}^n$  kompakt und konvex und ist  $f: K \rightarrow \mathbb{R}$  konkav, so nimmt  $f$  sein Minimum auf  $K$  in einem Extrempunkt von  $K$  an.

*Beweis.* Sei  $u \in K$  mit  $f(u) = \min f(K)$ , etwa  $u = \sum_{i=0}^r a_i u_i$  mit  $u_i \in \text{Ex}(K)$ ,  $a_i \geq 0$  und  $\sum_{i=0}^r a_i = 1$  (nach dem Satz von Krein-Milman gilt  $K = \text{conv}(\text{Ex}(K))$ ). Da  $f$  konkav ist, folgt  $f(u) \geq \sum_{i=0}^r a_i f(u_i) \geq f(u_j)$  für alle  $j \in [r]$  mit  $a_j \neq 0$ , d.h.  $f(u_j) = f(u)$  für diese  $j$ .  $\square$

**3.11 Lemma** (Lagrange<sup>9</sup>-Multiplikatoren). Sei  $K = \mathcal{S}(g_1, \dots, g_r) \subseteq \mathbb{R}^n$  kompakt und konvex mit  $\text{int}(K) \neq \emptyset$ . Die Polynome  $g_1, \dots, g_r$  seien konkav auf  $K$  und es seien  $f \in \mathbb{R}[\mathbf{x}]$  und  $u \in K$  mit  $f(u) = \min f(K)$ . Dann ist  $\nabla f(u) = \sum_{i=1}^r b_i \nabla g_i(u)$  mit  $b_i \geq 0$  und  $b_i g_i(u) = 0$  für alle  $i \in [r]$ .

*Beweis.* Wähle ein  $v \in K$  mit  $g_i(v) > 0$  für alle  $i \in [r]$  und setze  $w := v - u$ . Für jedes  $i$  mit  $g_i(u) = 0$  gilt

$$0 < g_i(v) \leq g_i(u) + \langle \nabla g_i(u), w \rangle = \langle \nabla g_i(u), w \rangle,$$

denn  $g_i|_K$  ist konkav. Ohne Einschränkung sei  $g_i(u) = 0$  für  $i \in [p]$  und  $g_j(u) > 0$  für  $j \in [r] \setminus [p]$ . Zu zeigen ist  $\nabla f(u) \in \text{cone}(\nabla g_1(u), \dots, \nabla g_p(u)) =: C$  (ein endlich erzeugter und damit

<sup>9</sup>Joseph-Louis LAGRANGE (1736–1813)

abgeschlossener Kegel (Konvexität, I.6.7)). Angenommen  $\nabla f(u) \notin C$ , dann existiert ein  $z \in C^* \subseteq \mathbb{R}^n$  mit  $\langle z, \nabla f(u) \rangle < 0$ . Wähle ein  $s > 0$  so klein, dass  $\langle z + sw, \nabla f(u) \rangle < 0$  ist. Für hinreichend kleine  $t > 0$  ist dann  $u + t(z + sw) \in K$ , denn für  $i \in [p]$  und  $j \in [r] \setminus [p]$  ist  $\langle \nabla g_i(u), z + sw \rangle > 0$  und  $g_j(u + t(z + sw)) > 0$ . Andererseits ist

$$f(u + t(z + sw)) = f(u) + t \cdot \underbrace{\langle \nabla f(u), z + sw \rangle}_{< 0} + (\text{höhere Potenzen von } t),$$

im Widerspruch zu  $f(u) = \min f(K)$ . □

**3.12 Lemma.** Sei  $F \in \text{Sym}_m(\mathbb{R}[\mathbf{x}])$  matrix-sos und sei  $u \in \mathbb{R}^n$ . Dann ist auch das Matrixpolynom

$$G_u(x) := \int_0^1 \int_0^t F(u + s(x - u)) ds dt$$

matrix-sos und es gilt  $\deg G_u(x) = \deg F(x) =: d$ .

*Beweis.* Zeige zunächst die Grad-Aussage: Für jedes Monom  $\mathbf{x}^\alpha$  ist

$$\begin{aligned} \int_0^1 \int_0^t \underbrace{(u + s(x - u))^\alpha}_{= \prod_{i=1}^n (u_i + s(x_i - u_i))^{\alpha_i}} ds dt &= \int_0^1 \int_0^t (s^{|\alpha|} \mathbf{x}^\alpha + h_1) ds dt \\ &= \int_0^1 \left( \frac{t^{|\alpha|+1}}{|\alpha|+1} \mathbf{x}^\alpha + h_2 \right) dt = \frac{\mathbf{x}^\alpha}{(|\alpha|+1)(|\alpha|+2)} + (\dots) \end{aligned}$$

mit zwei Polynomen  $h_1, h_2$  (in  $(u, x)$ ) und  $\deg_x(h_i) < |\alpha|$ . Ohne Einschränkung sei  $F(x) = v(x)v(x)^\top$  mit  $v(x) = (v_1(x), \dots, v_m(x))^\top$  und  $v_i(x) \in \mathbb{R}[x]$  (für  $x = (x_1, \dots, x_n)$  und  $y = (y_1, \dots, y_m)$ ). Nach Aufgabe 13 ist zu zeigen, dass das Polynom  $g(x, y) := y^\top G_u(x)y$  sos in  $\mathbb{R}[x, y]$  ist. Es gilt  $y^\top F(x)y = (\sum_{i=1}^m y_i v_i(x))^2$  und damit

$$g(x, y) = \int_0^1 \int_0^t \left( \sum_{i=1}^m y_i v_i(u + s(x - u)) \right)^2 ds dt.$$

Sei  $v_i(u + s(x - u)) = \sum_{k=0}^d p_{ik}(x, u) s^k$  mit  $p_{ik} \in \mathbb{R}[x, u]$ , dann gilt

$$g(x, y) = \sum_{i=1}^m \sum_{j=1}^m \sum_{k=0}^d \sum_{\ell=0}^d y_i y_j p_{ik}(x, u) p_{j\ell}(x, u) \underbrace{\int_0^1 \int_0^t s^{k+\ell} ds dt}_{=: a_{k\ell}}.$$

Die symmetrische reelle  $(d+1) \times (d+1)$ -Matrix  $A_d := (a_{k\ell})_{k, \ell=0, \dots, d}$  ist positiv definit, denn für  $z = (z_0, \dots, z_d)^\top \in \mathbb{R}^{d+1}$  mit  $z \neq 0$  ist

$$z^\top A_d z = \int_0^1 \int_0^t (z_0 + z_1 s + \dots + z_d s^d)^2 ds dt > 0.$$

Damit gilt  $A_d = BB^\top$  für eine Matrix  $B \in \mathbb{R}^{(d+1) \times (d+1)}$ , d.h.

$$\int_0^1 \int_0^t s^{k+\ell} ds dt = \sum_r b_{kr} b_{\ell r}.$$

Es ist

$$\int_0^1 \int_0^t s^{k+\ell} ds dt = \int_0^1 \left[ \frac{s^{k+\ell+1}}{k+\ell+1} \right]_0^t dt = \int_0^1 \frac{t^{k+\ell+1}}{k+\ell+1} dt = \frac{1}{(k+\ell+1)(k+\ell+2)}$$

und daher

$$g(x, y) = \sum_{i,j} \sum_{k,\ell} y_i y_j p_{ik} p_{j\ell} \sum_r b_{kr} b_{\ell r} = \sum_r \left( \sum_i \sum_k y_i p_{ik} b_{kr} \right)^2. \quad \square$$

**3.13 Theorem.** Sei  $K = \mathcal{S}(\mathbf{g}) \subseteq \mathbb{R}^n$  eine kompakte und konvexe Menge (mit  $\mathbf{g} = (g_1, \dots, g_r)$ ) und sei  $M := QM(\mathbf{g})$  archimedisch. Für jedes  $i \in [r]$  gelte eine der beiden folgenden Bedingungen:

- (1)  $g_i$  ist sos-konkav (d.h.  $-D^2 g_i$  ist matrix-sos).
- (2)  $g_i$  ist konkav auf  $K$  und es gilt  $D^2 g_i(u) \prec 0$  für alle  $u \in \overline{\mathcal{Z}(g_i) \cap \text{Ex}(K)}$ .

Dann hat  $K$  eine exakte Momentenrelaxierung bzgl.  $\mathbf{g}$ . Insbesondere ist  $K$  ein Spektraederschatten.

**3.14 Lemma.** Seien die Voraussetzungen von Theorem 3.13 erfüllt. Für jedes  $i \in [r]$  gibt es ein  $N_i \geq 1$  so, dass für alle  $u \in \text{Ex}(K)$  gilt: Das Matrixpolynom

$$G_{i,u}(x) := - \int_0^1 \int_0^t D^2 g_i(u + s(x-u)) ds dt$$

hat die Form

$$G_{i,u}(x) = \sum_{j=0}^r g_j(x) S_{i,u,j}(x)$$

mit  $g_0 := 1$  und Matrixpolynomen  $S_{i,u,j}$  (für  $j \in \{0, \dots, r\}$ ), die matrix-sos vom Grad  $\leq N_i$  sind.

**3.15 Beweis von Theorem 3.13 unter Verwendung von Lemma 3.14.** Man muss ein  $d \geq 0$  so finden, dass der trunkierte quadratische Modul  $M_d$  jedes lineare  $f \in \mathbb{R}[\mathbf{x}]$  mit  $f|_K \geq 0$  enthält (RAG, 8.5.14). Ein solches  $f$  nimmt sein Minimum auf  $K$  in einem Punkt  $u \in \text{Ex}(K)$  an (Lemma 3.10). Da  $g_i|_K$  konkav ist, ist  $\nabla f(u) = \sum_{i=1}^r b_i \nabla g_i(u)$  mit  $b_i \geq 0$  und  $b_i g_i(u) = 0$  (Lemma 3.11). Das Polynom  $h_u(x) := f(x) - f(u) - \sum_{i=1}^r b_i g_i(x)$  erfüllt  $h_u(u) = 0$ ,  $\nabla h_u(u) = 0$  und  $D^2 h_u(u) = - \sum_{i=1}^r b_i D^2 g_i(u)$ . Für das Matrixpolynom

$$H_u(x) := \int_0^1 \int_0^t D^2 h_u(u + s(x-u)) ds dt$$

gilt  $h_u(x) = (x-u)^\top H_u(x)(x-u)$  (Aufgabe 9). Aus 3.14 folgt also

$$H_u(x) = \sum_{i=1}^r b_i G_{i,u}(x) = \sum_{i=1}^r \sum_{j=0}^r b_i g_j(x) S_{i,u,j}(x)$$

mit Matrixpolynomen  $S_{i,u,j}$ , die matrix-sos vom Grad  $\leq \max\{N_1, \dots, N_r\} =: N$  sind. Damit ist

$$f(x) = f(u) + \sum_{i=1}^r b_i g_i(x) + (x-u)^\top H_u(x)(x-u),$$

mit  $f(u) > 0$  und  $b_i \geq 0$ , d.h.  $f$  liegt in  $M_{\delta+N+2}$  mit  $\delta := \max_i \deg(g_i)$  (Lemma 3.12).  $\square$

**3.16 Beweis von Lemma 3.14.** Sei  $i \in [r]$  und gelte zunächst (1) für  $g_i$ . Dann ist  $-D^2 g_i$  matrix-sos mit  $\deg(D^2 g_i) = \deg(g_i) - 2$ . Nach Lemma 3.12 gilt dasselbe für  $G_{i,u}(x)$  (für alle  $u \in \mathbb{R}^n$ ). Gelte jetzt (2) für  $g_i$  und sei  $Z_i := \overline{\mathcal{Z}(g_i) \cap \text{Ex}(K)}$ . Das Matrixpolynom  $G_{i,u}(x)$  hat Grad  $\deg(g_i) - 2$  und ist polynomial in  $(x, u)$ . Für  $u \in K$  gelten  $D^2 g_i(u) \preceq 0$  und  $D^2 g_i(u) \prec 0$  für  $u \in Z_i$ . Für  $u \in Z_i$  und  $v \in K$  folgt  $G_{i,u}(v) \succ 0$ , denn für  $0 \neq w \in \mathbb{R}^n$  ist

$$w^\top G_{i,u}(v) w = \int_0^1 \int_0^t \underbrace{w^\top (-D^2 g_i)(u + s(x-u)) w}_{\substack{> 0 \text{ für } s=0 \\ \geq 0 \text{ für alle } 0 \leq s \leq t}} ds dt > 0.$$

Da  $K$  und  $Z_i$  kompakt sind, gibt es ein  $\varepsilon > 0$  mit  $G_{i,u}(v) \succeq \varepsilon I$  für alle  $(u, v) \in Z_i \times K$ . Nach Theorem 3.5 gibt es für jedes  $u \in Z_i$  eine gewichtete sos-Matrixdarstellung

$$G_{i,u}(x) = \sum_{j=0}^r g_j(x) S_{i,u,j}(x)$$

mit Matrixpolynomen  $S_{i,u,j}$ , die matrix-sos vom Grad

$$\deg(S_{i,u,j}) \leq k(\mathbf{g}, \deg(g_i) - 2, n, \max\{\varepsilon^{-1}, \|G_{i,u}\|\})$$

sind. Da  $Z_i$  kompakt ist, ist  $\|G_i\| := \max_{u \in Z_i} \|G_{i,u}\| < \infty$ , d.h. man hat die uniforme Schranke

$$\deg(S_{i,u,j}) \leq k(\mathbf{g}, \deg(g_i) - 2, n, \max\{\varepsilon^{-1}, \|G_i\|\}). \quad \square$$

**3.17 Definition.** Sei  $U \subseteq \mathbb{R}^n$  offen. Eine  $C^2$ -Funktion  $f: U \rightarrow \mathbb{R}$  heißt *strikt quasikonkav* in  $u \in U$ , falls  $v^\top D^2 f(u) v < 0$  für alle  $0 \neq v \in \mathbb{R}^n$  mit  $\langle v, \nabla f(u) \rangle = 0$  gilt.  $f$  heißt *strikt quasikonkav*, falls  $f$  in jedem  $u \in U$  strikt quasikonkav ist. Ist  $U$  konvex, so heißt  $f$  *quasikonkav*, falls die „superlevel sets“  $\{u \in U: f(u) \geq c\}$  für alle  $c \in \mathbb{R}$  konvex sind. Ist  $f$  eine quasikonkave  $C^2$ -Funktion, so gilt  $v^\top D^2 f(u) v \leq 0$  für alle  $u \in U$  und alle  $v \in \mathbb{R}^n$  mit  $\langle v, \nabla f(u) \rangle = 0$ .

**3.18 Lemma.** Sei  $\mathcal{S}(g_1, \dots, g_r)$  eine *archimedische Beschreibung* der konvexen Menge  $K \subseteq \mathbb{R}^n$  (d.h. es gilt  $K = \mathcal{S}(g_1, \dots, g_r)$  und der quadratische Modul  $M := \mathcal{QM}(g_1, \dots, g_r)$  ist archimedisch). Jedes  $g_i$  sei strikt quasikonkav in jedem Punkt von  $K$ . Dann gibt es eine andere archimedische Beschreibung  $K = \mathcal{S}(h_0, \dots, h_r)$  mit  $h_i \in M$  und  $D^2 h_i \prec 0$  auf  $K$  für alle  $i \in \{0, \dots, r\}$ .

*Beweis.* Da  $M$  archimedisch ist, gibt es ein  $b > 0$  in  $\mathbb{R}$  mit  $h_0 := b^2 - \sum_{i=1}^n x_i^2 \in M$ . Skalieren die  $g_i$  so, dass  $|g_i(u)| \leq 1$  für  $|u| \leq b$  und alle  $i \in [r]$  gilt und sei  $c > 0$  (groß). Nach Aufgabe 12 gibt es ein sos-Polynom  $h \in \mathbb{R}[t]$  mit

$$(1) \ h(t) > 0, \quad (2) \ h(t) + th'(t) > 0, \quad (3) \ \frac{2h'(t) + th''(t)}{h(t) + th'(t)} \leq -c$$

für  $|t| \leq 1$ . Setze  $h_i(t) := g_i(t) \cdot h(g_i(t))$  für  $i \in [r]$  und schreibe  $\mathbf{h} := (h_0, h_1, \dots, h_r)$ . Es sind  $h_0, \dots, h_r \in M$ , d.h.  $K \subseteq \mathcal{S}(\mathbf{h})$ . Umgekehrt sei  $u \in \mathbb{R}^n \setminus K$ . Ist  $|u| > b$ , so ist  $h_0(u) < 0$ . Ist  $|u| \leq b$ , so ist  $-1 \leq g_i(u) < 0$  für ein  $i \in [r]$ , d.h.  $h_i(t) < 0$ . Somit ist  $K = \mathcal{S}(\mathbf{h})$ . Es ist  $D^2 h_0 = -2I_n \prec 0$ . Für  $i \in [r]$  zeigen wir, dass  $D^2 h_i \prec 0$  auf  $K$  ist, falls  $c > 0$  hinreichend groß gewählt war. Es gilt

$$D^2 h_i = (h \circ g_i) \cdot D^2(g_i) + (\nabla(g_i) \cdot \nabla(h \circ g_i)^\top)^{\text{sym}} + g_i \cdot D^2(h \circ g_i)$$

mit  $M^{\text{sym}} := M + M^\top$  für  $M \in \mathbb{R}^{n \times n}$ . Wegen  $\nabla(h \circ g_i) = (h' \circ g_i) \cdot \nabla(g_i)$  und

$$D^2(h \circ g_i) = (h'' \circ g_i) \cdot (\nabla g_i)(\nabla g_i)^\top + (h' \circ g_i) \cdot D^2(g_i)$$

ist also

$$D^2(h_i) = p_i \cdot D^2(g_i) + q_i \cdot (\nabla g_i)(\nabla g_i)^\top$$

mit  $p_i := (h \circ g_i) + g_i \cdot (h' \circ g_i)$  und  $q_i := 2(h' \circ g_i) + g_i \cdot (h'' \circ g_i)$ . Dabei ist  $p_i|_K > 0$  nach (2). Da  $g_i$  strikt quasikonkav auf  $K$  ist, gibt es nach Aufgabe 11 eine Konstante  $\kappa_i > 0$  mit  $D^2(g_i) \prec \kappa_i \cdot (\nabla g_i)(\nabla g_i)^\top$  in allen Punkten aus  $K$ . Sei  $c > 0$  in  $\mathbb{R}$  mit  $c > \max\{\kappa_1, \dots, \kappa_r\}$ . Nach (3) gilt  $\frac{q_i}{p_i} \leq -c < -\kappa_i$  auf  $K$  für alle  $i \in [r]$ , also ist  $\kappa_i p_i + q_i < 0$  auf  $K$ . Daher gilt

$$D^2(h_i) = p_i \cdot D^2(g_i) + q_i \cdot (\nabla g_i)(\nabla g_i)^\top \prec (\kappa_i p_i + q_i) \cdot (\nabla g_i)(\nabla g_i)^\top \preceq 0$$

auf  $K$ , also ist  $D^2(h_i) \prec 0$  auf  $K$  für alle  $i \in [r]$ .  $\square$

**3.19 Theorem.** Die Aussage von Theorem 3.13 bleibt richtig, wenn man neben (1) und (2) für die  $g_i$  auch die Bedingung (3) zulässt:

(3)  $g_i$  ist strikt quasikonkav auf  $K$ .

*Beweis.* Sei (3) erfüllt für  $g_1, \dots, g_s$  und sei (1) oder (2) erfüllt für  $g_{s+1}, \dots, g_r$ . Wähle ein  $b \in \mathbb{R}$  mit  $b^2 - \sum_{i=1}^n x_i^2 \in QM(\mathbf{g})$ . Nach Lemma 3.18 kann man die Folge  $b^2 - \sum_i x_i^2, g_1, \dots, g_s$  durch eine andere Folge in  $QM(\mathbf{g})$  so ersetzen, dass jedes der neuen Polynom auf  $K$  eine negativ definite Hesse-Matrix hat. Jedes Element der neuen Gesamtfolge für  $K$  erfüllt (1) oder (2), also folgt die Behauptung aus Theorem 3.13.  $\square$

**Zusammenfassung.** Nach den Theoremen 3.13 und 3.19 gilt also: Sei  $K = \mathcal{S}(g_1, \dots, g_r)$  eine archimedische Beschreibung und sei  $K$  konvex. Für jedes  $i \in [r]$  gelte eine dieser Bedingungen:

- (1)  $-D^2(g_i)$  ist matrix-sos.
- (2)  $g_i$  ist konkav auf  $K$  und für alle  $u \in \overline{\mathcal{Z}(g_i) \cap \text{Ex}(K)}$  gilt  $D^2g_i(u) \prec 0$ .
- (3)  $g_i$  ist strikt quasikonkav auf  $K$ .

Dann besitzt  $K$  eine exakte Momentenrelaxierung (bzgl.  $\mathbf{g}$ ), d.h.  $K$  ist ein Spektraederschatten.

**3.20 Beispiel.** 1. Sei  $K := \{(x, y) \in \mathbb{R}^2 : g(x, y) \geq 0\}$  mit  $g := 1 - x^m - y^n$  und geraden Zahlen  $m, n \geq 4$  (der „TV-hyperscreen“). Nach (1) ist  $K$  ein Spektraederschatten, denn es gilt

$$-D^2(g) = \begin{pmatrix} m(m-1)x^{m-2} & 0 \\ 0 & n(n-1)y^{n-2} \end{pmatrix}.$$

Jedoch sind (2) und (3) verletzt in den Punkten  $u \in \{(\pm 1, 0), (0, \pm 1)\}$ : Dass (2) verletzt ist, ist klar. (3) verlangt  $w^\top D^2g(u)w < 0$  für alle  $0 \neq w \in \mathbb{R}^2$  mit  $w \perp \nabla g(u)$ , aber für  $u = (1, 0)^\top$  ist  $\nabla g(u) = (-m, 0)^\top$ , d.h. die Bedingung ist für  $w = (0, 1)^\top$  nicht erfüllt.

- 2. Sei  $g := x^a y^b - 1 \in \mathbb{R}[x, y]$  mit  $a, b \geq 1$ . Auf  $(0, \infty)^2$  ist  $g$  strikt quasikonkav, aber nicht konkav, denn für  $(x, y) \neq 0$  gilt  $u = (-bx, ay)^\top \perp \nabla g(x, y)$ , aber die Determinante der Hessematrix ist negativ, sie ist also indefinit, d.h.  $g$  ist nicht konkav. Für  $h := 1 - (x-1)^2 - (y-1)^2$  ist  $K := \mathcal{S}(g, h)$  ein Spektraederschatten nach (3), aber (1) und (2) sind verletzt.

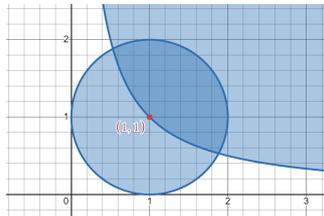


Abbildung 5: Der Spektraederschatten (die dunkelblaue Menge) aus Beispiel 3.20.2

- 3. Zu einer konvexen archimedischen Beschreibung  $K = \mathcal{S}(\mathbf{g})$  kann es eine exakte Relaxierung geben, obwohl (1), (2) und (3) nicht anwendbar sind. Für ein Beispiel siehe Aufgabe 15.
- 4. Im Allgemeinen kann  $K = \mathcal{S}(\mathbf{g})$  eine archimedische Beschreibung einer konvexen Menge sein, für die keine Relaxierung exakt ist, die aber dennoch ein Spektraederschatten ist. Betrachte beispielsweise  $M := QM(\mathbf{g}) \subseteq \mathbb{R}[x, y]$  mit  $\mathbf{g} := (y - x^3, y, 1 - y, x + 1)$ . Nach Aufgabe 16 ist  $M$  archimedisch und  $K := \mathcal{S}(\mathbf{g})$  ein Spektraederschatten.

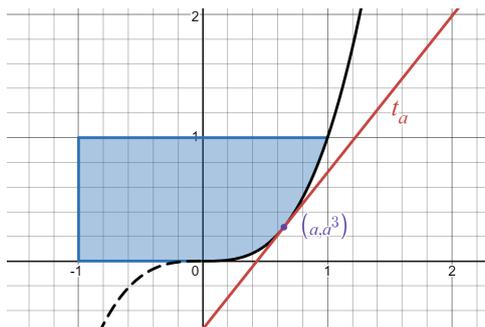


Abbildung 6: Der Spektraederschatten aus Beispiel 3.20.4

Angenommen die Relaxierung ist exakt in Grad  $d$ , d.h. nach RAG, 8.5.14 enthält  $M_d$  jedes lineare  $f \in \mathbb{R}[x, y]$  mit  $f|_K \geq 0$ . Zu  $a \in (0, 1]$  seien  $g := y - x^3$  und

$$t_a := \frac{\partial g}{\partial x}(a, a^3) \cdot (x - a) + \frac{\partial g}{\partial y}(a, a^3) \cdot (y - a^3) = -3a^2(x - a) + (y - a^3) = 2a^3 + 3a^2x + y,$$

dann ist  $t_a \in M_d$ . Sei  $\varphi: \mathbb{R}[x, y] \rightarrow \mathbb{R}[x]$ ,  $f \mapsto f(x, 0)$  und sei  $M' := \varphi(M) \subseteq \mathbb{R}[x]$ . Es gilt  $\varphi(M_d) \subseteq (M')_d$  und es ist  $\varphi(t_a) = 2a^3 - 3a^2x = a^2(2a - 3x)$ , also folgt  $c - x \in (M')_d$  für alle  $c > 0$ . Nach RAG, 8.5.11 ist  $(M')_d$  abgeschlossen (in  $\mathbb{R}[x]_{\leq d}$ ), d.h. es ist auch  $-x \in (M')_d$ . Daher gilt  $-x = s_0 - s_1 \cdot x^3 + s_2 \cdot (x + 1)$  mit  $s_0, s_1, s_2 \in \mathbb{R}[x]$ , aber es ist  $s_0(0) = s_2(0) = 0$ , d.h. die rechte Seite hat keinen linearen Term, Widerspruch.

## §4 Glatte Hyperbolizitätskegel

**Erinnerung:** Die (offene) verallgemeinerte Lax-Vermutung besagt, dass für jede bzgl.  $e \in \mathbb{R}^n$  hyperbolische Form  $f \in \mathbb{R}[\mathbf{x}]$  der Hyperbolizitätskegel  $C_e(f)$  ein Spektraederkegel ist.

**4.1 Theorem** (Netzer<sup>10</sup>-Sanyal<sup>11</sup>). Die Form  $f \in \mathbb{R}[\mathbf{x}]$  sei strikt hyperbolisch bzgl.  $e \in \mathbb{R}^n$ . Dann ist  $C_e(f)$  ein Spektraederschatten.

Nach Korollar 1.10 ist die Voraussetzung äquivalent dazu, dass  $f$  hyperbolisch bzgl.  $e$  ist und die Menge  $\mathcal{V}(f)(\mathbb{R}) = \{u \in \mathbb{R}^n : f(u) = 0\}$  keine singulären Punkte  $\neq 0$  besitzt.

**4.2 Satz.** Sei  $f \in \mathbb{R}[\mathbf{x}]$  ein RZ-Polynom bzgl.  $e \in \mathbb{R}^n$  (siehe 2.2).

- (a) Enthält  $S_e(f)$  keine Gerade, so ist  $f$  strikt quasikonkav in jedem inneren Punkt von  $S_e(f)$ .
- (b) Ist  $u \in \partial S_e(f)$  ein glatter Punkt von  $\mathcal{V}(f)$  und verschwindet  $f$  auf keiner Gerade durch  $u$ , so ist  $f$  strikt quasikonkav in  $u$ .

*Beweis.* (a) Sei  $u \in \text{int } S_e(f)$ . Ohne Einschränkung sei  $f(u) = 1$ . Die Taylorentwicklung von  $f$  um  $u$  sei  $f(u + x) = 1 + f_1(x) + f_2(x) + \dots$  mit homogenen  $f_i$  von Grad  $i$ , explizit ist dann  $f_1(x) = \langle x, \nabla f(u) \rangle$  und  $f_2(x) = \frac{1}{2}x^\top D^2 f(u)x$ . Für  $u \neq v \in \mathbb{R}^n$  hat  $f(u + tv) \in \mathbb{R}[t]$  nur reelle Nullstellen und ist nicht konstant (sonst wäre  $u + \mathbb{R}v \subseteq S_e(f)$ ). Es gilt also

$$f(u + tv) = 1 + \sum_{i \geq 1} f_i(v)t^i = \prod_{i=1}^k (1 + \lambda_i t)$$

<sup>10</sup>Tim NETZER (\*1980)

<sup>11</sup>Raman SANYAL (\*1978)

mit  $k \geq 1$  und  $0 \neq \lambda_1, \dots, \lambda_k \in \mathbb{R}$  (sind  $0 \neq \alpha_1, \dots, \alpha_k \in \mathbb{R}$  die Nullstellen von  $f(u + tv)$ , so ist  $\lambda_i = -1/\alpha_i$ ). Es folgt  $f_1(v) = \sum_{i=1}^k \lambda_i$  und

$$f_2(v) = \sum_{1 \leq i < j \leq k} \lambda_i \lambda_j = \frac{1}{2} \left( f_1(v)^2 - \sum_{i=1}^k \lambda_i^2 \right).$$

Ist also  $f_1(v) = 0$ , so ist  $f_2(v) < 0$ .

- (b) Man kann  $e = 0$  und  $f(e) = 1$  annehmen. Sei  $u$  wie in in der Voraussetzung gegeben und sei  $0 \neq v \in \mathbb{R}^n$  mit  $\langle v, \nabla f(u) \rangle = 0$ . Nach der Lax-Vermutung (Theorem 2.3) gibt es  $U, V \in \mathbb{S}^k$  mit  $f(su + tv) = \det(I_k + sU + tV)$  (denn  $f|_{\mathbb{R}u + \mathbb{R}v}$  ist ein RZ-Polynom bzgl.  $e = 0$ ). Es gilt  $(\mathbb{R}u + \mathbb{R}v) \cap S_e(f) = \{su + tv \mid I_k + sU + tV \succeq 0\}$ . Wegen  $u \in \partial S_e(f)$  ist  $I_k + U \succeq 0$  und  $\det(I_k + U) = 0$ . Da  $u$  ein glatter Randpunkt ist, hat das Polynom

$$f(e + su) = \det(I_k + sU) = (-s)^k \cdot \det\left(-\frac{1}{s}I_k - U\right) = (-s)^k \cdot p_U\left(-\frac{1}{s}\right)$$

für  $s = 1$  eine einfache Nullstelle, d.h.  $\dim \ker(I_k + U) = 1$ . Wegen  $p_U(x) = \det(xI_k - U)$  folgt  $I_k + U = \text{diag}(0, 1, \dots, 1)$  bzgl. einer geeigneten Orthonormalbasis von  $\mathbb{R}^n$ . Ist  $V = (v_{ij})$ , so folgt

$$f(u + tv) = \det(I_k + U + tV) = \det \begin{pmatrix} tv_{11} & tv_{12} & \cdots & tv_{1k} \\ tv_{12} & 1 + tv_{22} & \cdots & tv_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ tv_{1k} & tv_{2k} & \cdots & 1 + tv_{kk} \end{pmatrix}.$$

Die Leibnizformel liefert  $f(u + tv) = f_1(v)t + f_2(v)t^2 + \cdots$  mit  $f_1(v) = v_{11} = \langle v, \nabla f(u) \rangle$  und

$$f_2(v) = v_{11} \sum_{i=2}^n v_{ii} - \sum_{i=2}^n v_{1i}^2.$$

$\langle v, \nabla f(u) \rangle = 0$  bedeutet  $v_{11} = 0$ , d.h.  $f_2(v) = -\sum_{i=2}^n v_{1i}^2$ . Wäre  $v_{11} = \cdots = v_{1n} = 0$ , so wäre  $f(u + tv) = \det(U + tV) = 0$  für alle  $t \in \mathbb{R}$ , d.h.  $f$  verschwindet auf  $u + \mathbb{R}v$ . Das ist nach Voraussetzung nicht der Fall, also folgt  $f_2(v) < 0$ .  $\square$

**4.3 Beispiel.** 1. Zu 4.2(a): Das Polynom

$$f := \det \begin{pmatrix} x & y \\ y & 1 \end{pmatrix} = x - y^2 \in \mathbb{R}[x, y, z]$$

ist ein RZ-Polynom bzgl.  $e = e_1$ . Jedoch ist  $f$  nicht strikt quasikonkav in  $u = e_1$ , denn  $f(e_1 + te_3) = f(e_1)$  ist konstant.

2. Zu 4.2(b): Verschwindet  $f$  auf einer Gerade  $u + \mathbb{R}v$  durch  $u \in \partial S_e(f)$ , so ist  $f(u + tv) \equiv 0$ , also ist  $f$  nicht strikt quasikonkav.

**4.4 Theorem.** Sei  $f \in \mathbb{R}[\mathbf{x}]$  ein RZ-Polynom bzgl.  $e \in \mathbb{R}^n$  und sei  $S_e(f)$  kompakt. Ist jeder Randpunkt von  $S_e(f)$  ein glatter Punkt von  $\mathcal{V}(f)$ , so ist  $S_e(f)$  ein Spektraederschatten.

**4.5 Lemma.** Sei  $f \in \mathbb{R}[\mathbf{x}]$  ein RZ-Polynom bzgl.  $e \in \mathbb{R}^n$  mit  $f(e) > 0$  und sei  $u \in \partial S_e(f)$  ein glatter Punkt von  $\mathcal{V}(f)$ . Dann existiert eine Umgebung  $U$  von  $u$  in  $\mathbb{R}^n$  mit  $U \cap S_e(f) = \{v \in U : f(v) \geq 0\}$ .

*Beweis.* Es ist  $\nabla f(u) \neq 0$ , nach dem Satz über implizite Funktionen existieren also eine offene Umgebung  $U$  von  $u$  und ein Diffeomorphismus  $\phi: U \rightarrow B := B_\varepsilon(0) \subseteq \mathbb{R}^n$  für ein  $\varepsilon > 0$ , sodass  $(U, U \cap \{f = 0\})$  unter  $\phi$  diffeomorph auf  $(B, B \cap \{x_1 = 0\})$  abgebildet wird:



Weiter ist  $S_e(f)$  der Abschluss einer Zusammenhangskomponente von  $\{f > 0\}$  in  $\mathbb{R}^n$ .  $\square$

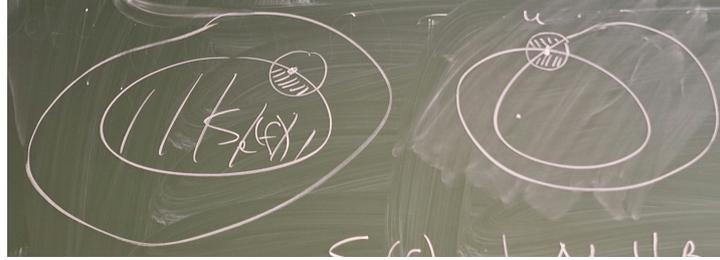


Abbildung 7: Für glatte Punkte (links) ist Lemma 4.5 richtig, für singuläre Punkte (rechts) ist die Aussage jedoch im Allgemeinen falsch, wie das Bild illustriert.

**4.6 Lemma.** Sei  $f \in \mathbb{R}[x]$  ein RZ-Polynom bzgl.  $e \in \mathbb{R}^n$  und sei  $S_e(f)$  kompakt. Besteht  $\partial S_e(f)$  aus glatten Punkten von  $\mathcal{V}(f)$ , so verschwindet  $f$  auf keiner Gerade durch einen Punkt aus  $\partial S_e(f)$ .

*Beweis.* Angenommen  $L$  ist eine Gerade durch  $u \in \partial S_e(f)$  mit  $f|_L \equiv 0$ . Nach Lemma 4.5 existiert dann eine Umgebung  $U$  von  $u$  mit  $U \cap \partial S_e(f) = U \cap \{f = 0\}$ . Somit enthält  $\partial S_e(f)$  eine Umgebung von  $u$  in  $L$ . Daher ist  $\emptyset \neq L \cap \partial S_e(f)$  relativ offen in  $L$  und ist auch abgeschlossen, d.h.  $L \cap \partial S_e(f) = L$ . Daraus folgt  $L \subseteq \partial S_e(f)$ , im Widerspruch zur Kompaktheit von  $S_e(f)$ .  $\square$

**4.7 Theorem.** Sei  $f \in \mathbb{R}[x]$  ein RZ-Polynom bzgl.  $e \in \mathbb{R}^n$  und sei  $S_e(f)$  kompakt. Für jeden Randpunkt  $u \in \partial S_e(f)$  und jeden irreduziblen Faktor  $g$  von  $f$  mit  $g(u) = 0$  sei  $u$  ein glatter Punkt von  $\mathcal{V}(g)$  und  $g$  verschwinde auf keiner Gerade durch  $u$ . Dann ist  $S_e(f)$  ein Spektraederschatten.

*Beweis von Theorem 4.4 unter Verwendung von Theorem 4.7.* Sei  $u \in \partial S_e(f)$  (ein glatter Punkt von  $f$ ). Ist  $g$  ein irreduzibler Faktor von  $f$  mit  $g(u) = 0$ , so gilt  $g|_L \not\equiv 0$  für jede Gerade  $L$  durch  $u$  (Lemma 4.6). Damit folgt die Behauptung aus Theorem 4.7.  $\square$

*Beweis von Theorem 4.7.* Sei  $f = f_1 \cdots f_m$  mit irreduziblen Polynomen  $f_i$ . Jedes  $f_i$  ist RZ bzgl.  $e$  und es gilt

$$S_e(f) = \bigcap_{i=1}^m S_e(f_i).$$

Seien  $f_1, \dots, f_k$  diejenigen  $f_i$  mit  $f_i(u) = 0$ . Es genügt, für jedes  $u \in \partial S_e(f)$  und jedes  $i \in [k]$  zu zeigen, dass  $\overline{B}_{r_i}(u) \cap S_e(f_i)$  für ein  $r_i > 0$  ein Spektraederschatten ist, denn dann gibt es für jedes  $u \in \partial S_e(f)$  ein  $r > 0$ , sodass  $\overline{B}_r(u) \cap S_e(f)$  ein Spektraederschatten ist (wähle  $r \leq \min\{r_1, \dots, r_k\}$  so klein, dass  $f_i > 0$  auf  $\overline{B}_r(u)$  für alle  $i \in \{k+1, \dots, m\}$  gilt). Überdeckt man  $\partial S_e(f)$  nun durch endlich viele dieser  $\overline{B}_r(u)$  ( $\partial S_e(f)$  ist kompakt), so folgt mit Satz II.4.5 (Konvexität), dass auch  $S_e(f) = \text{conv}(\partial S_e(f))$  ein Spektraederschatten ist.

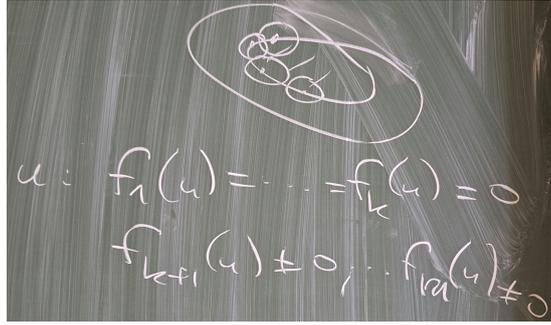
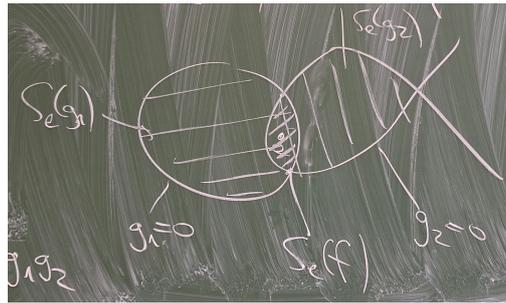


Abbildung 8: Zerlegung von  $S_e(f)$  in kleinere Spektraederschatten

Sei  $f$  also nun ohne Einschränkung ein irreduzibles RZ-Polynom mit  $f(e) > 0$  und sei  $u \in \partial S_e(f)$  ein glatter Punkt von  $f$  mit  $f \neq 0$  auf jeder Gerade durch  $u$ . Es reicht zu zeigen, dass ein  $r > 0$  existiert, sodass  $\overline{B}_r(u) \cap S_e(f)$  ein Spektraederschatten ist. Nach Satz 4.2(b) ist  $f$  strikt quasikonkav in  $u$ , nach Aufgabe 17 ist  $f$  also auch strikt quasikonkav auf  $\overline{B}_r(u)$  für ein kleines  $r > 0$ . Das Polynom  $r^2 - |x - u|^2$  ist überall strikt quasikonkav. Daher folgt mit Theorem 3.13/3.19, dass die konvexe Menge  $\overline{B}_r(u) \cap S_e(f) = \mathcal{S}(f, r^2 - |x - u|^2)$  ein Spektraederschatten ist.  $\square$

**4.8 Bemerkung.**  $\partial S_e(f)$  in Theorem 4.7 muss im Allgemeinen **nicht** aus glatten Punkten von  $f$  bestehen, z.B. für  $g_1 := (3/2)^2 - (x + 2)^2 - y^2$ ,  $g_2 := (x - 1)^2(x + 1) - y^2$  und  $S_e(f) = \mathcal{S}(g_1, g_2)$ :



#### 4.9 –

Mithilfe von Theorem 4.4 können wir nun folgende Verallgemeinerung von Theorem 4.1 beweisen:

**4.10 Theorem.** Sei  $f \in \mathbb{R}[\mathbf{x}]$  eine bzgl.  $e \in \mathbb{R}^n$  hyperbolische Form. Jeder Punkt  $\neq 0$  von  $\partial C_e(f)$  sei ein glatter Punkt von  $\mathcal{V}(f)$ . Dann ist  $C_e(f)$  ein Spektraederschatten.

*Beweis.* Sei  $C := C_e(f)$ , sei  $L := C \cap (-C)$  und sei  $\mathbb{R}^n = L \oplus W$  mit einem linearen Unterraum  $W \subseteq \mathbb{R}^n$  mit  $e \in W$ . Dann gilt  $C = L \oplus (C \cap W)$ , es genügt also zu zeigen, dass  $C \cap W$  ein Spektraederschatten ist. Da  $f|_W$  hyperbolisch bzgl.  $e$  mit Hyperbolizitätskegel  $C \cap W$  ist, kann man  $C$  durch  $C \cap W$  ersetzen. Alle  $u \in \partial(C \cap W)$  sind glatte Punkte von  $f$ . Ohne Einschränkung sei  $C$  daher spitz. Nach Satz I.5.12 (Konvexität) gibt es also eine affine Hyperebene  $H \subseteq \mathbb{R}^n$  mit  $e \in H$ , sodass  $K := C \cap H$  kompakt ist.  $f|_H$  ist ein RZ-Polynom bzgl.  $e$  mit  $S_e(f|_H) = C \cap H = K$  und glatten Randpunkten. Nach Theorem 4.4 ist  $K$  daher ein Spektraederschatten. Wegen  $C = K^h$  ist damit auch  $C$  ein Spektraederschatten (Konvexität, II.4.8).  $\square$

## §5 Interlacer

**5.1 Definition.** (a) Ein Polynom  $0 \neq f \in \mathbb{R}[t]$  heißt *real-rooted*, falls alle Nullstellen von  $f$  (in  $\mathbb{C}$ ) reell sind. Sind zusätzlich alle Nullstellen von  $f$  einfach, so heißt  $f$  *strictly real-rooted*.

- (b) Sei  $f \in \mathbb{R}[t]$  real-rooted mit  $d = \deg(f) \geq 1$ . Ein Polynom  $g \in \mathbb{R}[t]$  heißt ein *interlacer* von  $f$ , falls  $g = 0$  gilt, oder  $g$  real-rooted ist mit  $\deg(g) = d - 1$ , sodass gilt: Sind  $\alpha_1 \leq \dots \leq \alpha_d$  die Nullstellen von  $f$  und sind  $\beta_1 \leq \dots \leq \beta_{d-1}$  die Nullstellen von  $g$ , so gilt

$$\alpha_1 \leq \beta_1 \leq \alpha_2 \leq \beta_2 \leq \dots \leq \alpha_{d-1} \leq \beta_{d-1} \leq \alpha_d. \quad (*)$$

Sind alle Ungleichungen in  $(*)$  strikt, so heißt  $g$  ein *strikt interlacer* von  $f$ . Schreibe  $\text{Int}(f)$  für die Menge aller interlacer von  $f$ .

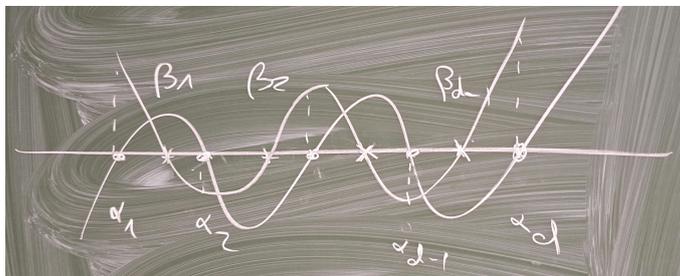
**5.2 Bemerkung.** Ist  $f$  real-rooted, so ist  $f' = \frac{\partial f}{\partial t}$  nach dem Satz von Rolle ein interlacer von  $f$ . Dieser ist genau dann strikt, wenn  $f$  strictly real-rooted ist. Ist  $g := \text{ggT}(f, f')$  und ist  $f = f_1 g$ , so hat  $f_1$  nur einfache Nullstellen und es gilt  $\text{Int}(f) = g \cdot \text{Int}(f_1)$ . Die Menge  $\text{Int}(f)$  ist abgeschlossen in  $\mathbb{R}[t]_{\leq d-1}$  und ihr Inneres besteht aus den strikten interlacern von  $f$ .

**5.3 Satz.** Seien  $f, g \in \mathbb{R}[t]$  mit  $\deg(f) = d$  und  $\deg(g) = d - 1$  und sei  $f$  strictly real-rooted. Dann sind die folgenden Bedingungen äquivalent:

- (i)  $g$  ist ein strikter interlacer von  $f$ .
- (ii)  $f'g$  ist strikt definit auf  $\mathcal{V}(f) := \{\alpha \in \mathbb{R} : f(\alpha) = 0\}$ .
- (iii) Das *Wronski<sup>12</sup>-Polynom*  $W(f, g) := f'g - fg'$  besitzt keine reellen Nullstellen (d.h. ist definit).

Die nicht-strikten Versionen von (i)–(iii) sind ebenfalls äquivalent.

*Beweis.* Zeige die Äquivalenz der strikten Versionen. Ohne Einschränkung haben  $f$  und  $g$  positive Leitkoeffizienten (sonst ersetze  $f$  durch  $-f$  bzw.  $g$  durch  $-g$ ). Sei  $\mathcal{V}(f) = \{\alpha_1 < \dots < \alpha_d\}$ . Die Vorzeichen  $\text{sign } f'(\alpha_i) = (-1)^{d-i} \neq 0$  alternieren:



Gilt (i), so gilt  $f'(\alpha_i)g(\alpha_i) > 0$  für alle  $i$ , also (ii). (ii)  $\Rightarrow$  (i) ist klar nach dem Zwischenwertsatz. (iii)  $\Rightarrow$  (ii) ist ebenfalls klar. (ii)  $\Rightarrow$  (iii): Für  $j \in [d]$  gilt

$$\frac{g}{f} = \sum_{j=1}^d \frac{c_j}{t - \alpha_j} \quad \text{mit} \quad c_j := \frac{g(\alpha_j)}{f'(\alpha_j)}, \quad (*)$$

denn nach Multiplikation mit  $f$  sind beide Seiten Polynome vom Grad  $\leq d - 1$ , die in  $\alpha_1, \dots, \alpha_d$  denselben Wert haben (aus  $f = (t - \alpha_j)h$  mit  $h \in \mathbb{R}[t]$  folgt mit der Produktregel  $f'(\alpha_j) = h(\alpha_j)$ , d.h. es gilt  $(f/(t - \alpha_j))(\alpha_j) = f'(\alpha_j)$ ). Aus (ii) folgt  $c_j \neq 0$  für alle  $j \in [d]$  und dass alle  $c_j$  dasselbe Vorzeichen haben. Ableiten von  $(*)$  liefert

$$\frac{g'f - gf'}{f^2} = - \sum_{j=1}^d \frac{c_j}{(t - \alpha_j)^2},$$

<sup>12</sup>Jósef Maria HOËNÉ-WROŃSKI (1776–1853)

also hat

$$W(f, g) = f'g - fg' = f^2 \sum_{j=1}^d \frac{c_j}{(t - \alpha_j)^2}$$

keine Nullstelle in  $\mathbb{R}$ , d.h. es gilt (iii). Die Äquivalenz der nicht-strikten Versionen folgt durch Grenzübergang.  $\square$

**Bemerkung.** Ist  $f$  real-rooted mit einer mehrfachen Nullstelle, so gilt noch (i)  $\Rightarrow$  (ii)  $\wedge$  (iii) für die nicht-strikten Versionen, aber im Allgemeinen nicht umgekehrt. Beispielsweise für  $f = t^3$  und  $g = t^2 + t + 1$  gilt

$$W(f, g) = f'g - fg' = 3t^2(t^2 + t + 1) - t^3(2t + 1) = t^2 \underbrace{(t^2 + 2t + 3)}_{> 0 \text{ auf } \mathbb{R}}.$$

Hier sind (ii) und (iii) erfüllt, aber (i) nicht.

**5.4 Definition.** Seien  $f, g \in \mathbb{R}[\mathbf{x}]$  homogen mit  $\deg(f) = d$  und  $\deg(g) = d-1$  und sei  $f$  hyperbolisch bzgl.  $e \in \mathbb{R}^n$ .  $g$  heißt ein *interlacer* von  $f$  bzgl.  $e$ , falls das univariate Polynom  $g(te + u) \in \mathbb{R}[t]$  für jedes  $u \in \mathbb{R}^n$  ein interlacer von  $f(te + u) \in \mathbb{R}[t]$  ist. Ein interlacer  $g$  von  $f$  heißt ein *strikt interlacer* von  $f$  bzgl.  $e$ , falls  $g(te + u)$  für ein (sic!)  $u \in \mathbb{R}^n$  ein strikter interlacer von  $f(te + u)$  ist. Sei

$$\text{Int}_e(f) := \{0\} \cup \{g \in \mathbb{R}[\mathbf{x}]_{d-1} : f(e)g(e) > 0, g \text{ ist ein interlacer von } f \text{ bzgl. } e\}.$$

**5.5 Bemerkung.** Sei  $f \in \mathcal{H}_d(e)$ .

1. Ist  $0 \neq g \in \text{Int}_e(f)$ , so ist  $g \in \mathcal{H}_{d-1}(e)$ . Es ist  $\partial_e f \in \text{Int}_e(f)$  und es gilt  $f(e) \cdot (\partial_e f)(e) > 0$ .  $\partial_e f$  ist genau dann ein strikter interlacer von  $f$ , wenn  $f$  quadratfrei ist: Ist  $f$  quadratfrei, so hat  $V := \mathcal{V}(f)$  glatte  $\mathbb{R}$ -Punkte ( $V_{\text{reg}}$  ist offen-dicht in  $V$  und  $V(\mathbb{R})$  ist Zariski-dicht in  $V$ ). Es folgt die Existenz eines  $u \in V(\mathbb{R})$ , sodass  $f(te + u)$  nur einfache Nullstellen hat. Die Abbildung

$$V(\mathbb{R}) \rightarrow \mathcal{S}^{n-1}, \quad u \mapsto \frac{u - e}{|u - e|}$$

ist surjektiv, also gibt es eine Richtung  $u \in \mathbb{R}^n$ , in der kein singulärer Punkt von  $V$  liegt (es ist  $\dim(V(\mathbb{R})) = \dim(\mathcal{S}^{n-1}) = n - 1$  und  $\dim(V_{\text{sing}, \mathbb{R}}) \leq n - 2$ ).

2. Jeder interlacer von  $f$  verschwindet in  $V_{\text{sing}, \mathbb{R}}(f) = \{u \in \mathbb{R}^n : f(u) = 0, \nabla f(u) = 0\}$ .
3. Ist  $g$  ein strikter interlacer von  $f$ , so ist die Menge

$$\{u \in \mathbb{R}^n : g(te + u) \text{ ist ein strikter interlacer von } f(te + u)\}$$

Zariski-offen in  $\mathbb{R}^n$ , denn das ist die Menge  $\{u \in \mathbb{R}^n : \text{Res}(g(te + u), f(te + u)) \neq 0\}$ .

4. Für  $g \in \mathbb{R}[\mathbf{x}]_{d-1}$  ist die Menge  $\{u \in \mathbb{R}^n : g(te + u) \text{ ist ein interlacer von } f(te + u)\}$  abgeschlossen. Ist diese Menge also dicht in  $\mathbb{R}^n$ , so ist  $g$  ein interlacer von  $f$ .
5. Ist  $f = f_1 h$  mit  $h \mid f_1$ ,  $f \in \mathcal{H}_d(e)$  und  $h(e) > 0$ , so ist  $\text{Int}_e(f) = h \cdot \text{Int}_e(f_1)$ .

**5.6 Theorem.** Sei  $f \in \mathcal{H}_d(e)$  quadratfrei. Für  $g \in \mathbb{R}[\mathbf{x}]_{d-1}$  sind äquivalent:

- (i) Es gilt  $g \in \text{Int}_e(f)$ .
- (ii) Für alle  $u \in U_e(f)$  gilt  $g \in \text{Int}_u(f)$ .
- (iii) Es gilt  $(\partial_e f) \cdot g \geq 0$  auf  $\mathcal{V}_{\mathbb{R}}(f)$ .

(iv) Es gilt  $(\partial_e f) \cdot g - f \cdot (\partial_e g) \geq 0$  auf  $\mathbb{R}^n$ .

*Beweis.* Ohne Einschränkung sei  $f(e) > 0$ .  $g := \partial_e f$  ist ein strikter interlacer von  $f$ , da  $f$  quadratfrei ist (5.5.1). Die Menge  $U := \{u \in \mathbb{R}^n : f(te + u) \text{ hat nur einfache Nullstellen}\}$  ist offen-dicht (Aufgabe 21). Für  $u \in U$  kann man also Satz 5.3 auf  $f(te + u)$  und  $g(te + u)$  anwenden, das liefert (i)  $\Leftrightarrow$  (iii)  $\Leftrightarrow$  (iv). (ii)  $\Rightarrow$  (i) ist klar. (i)  $\Rightarrow$  (ii): Sei  $g \in \text{Int}_e(f)$  und sei  $u \in U_e(f)$ . Um  $g \in \text{Int}_u(f)$  zu zeigen, zeige  $(\partial_u f) \cdot g \geq 0$  auf  $\mathcal{V}_{\mathbb{R}}(f)$ . Sei also  $v \in \mathcal{V}_{\mathbb{R}}(f)$ . Ohne Einschränkung sei  $g(v) \neq 0$  und sei  $v$  ein nichtsingulärer Punkt von  $f$  (sonst ist  $(\partial_u f)(v) = 0$ ). Für alle  $w \in [e, u]$  ist  $f$  hyperbolisch bzgl.  $w$  und da  $v$  glatt ist, gilt auch  $(\partial_w f)(v) \neq 0$ . Die Abbildung  $w \mapsto (\partial_w f)(v)$  hat daher keine Nullstellen, also ist  $(\partial_e f)(v) \cdot (\partial_u f)(v) > 0$  (denn  $(\partial_u f)(v)$  hat das gleiche Vorzeichen wie  $(\partial_e f)(v)$ ). Wegen  $(\partial_e f)(v) \cdot g(v) > 0$  (nach (iii)) folgt  $(\partial_u f)(v) \cdot g(v) > 0$ .  $\square$

**5.7 Korollar.** Sei  $f \in \mathcal{H}_d(e)$  quadratfrei. Für  $g_1, g_2 \in \text{Int}_e(f)$  gilt dann  $g_1 g_2 \geq 0$  auf  $\mathcal{V}_{\mathbb{R}}(f)$ .

*Beweis.* Sei  $v \in \mathcal{V}_{\mathbb{R}}(f)$ . Ist  $v$  singulär, so ist  $g_1(v) = g_2(v) = 0$ . Andernfalls ist  $(\partial_e f)(v) \neq 0$ , d.h.  $(g_1 g_2)(v) \geq 0$  folgt aus Theorem 5.6 (i)  $\Rightarrow$  (iii) (angewendet auf  $g_1$  bzw.  $g_2$ ).  $\square$

**5.8 Korollar.** Sei  $f \in \mathcal{H}_d(e)$ . Dann ist  $\text{Int}_e(f)$  ein abgeschlossener konvexer Kegel in  $\mathbb{R}[\mathbf{x}]_{d-1}$  und für alle  $u \in U_e(f)$  gilt  $\text{Int}_e(f) = \text{Int}_u(f)$ . Ist  $f$  quadratfrei, so ist

$$\text{Int}_e(f) = \{g \in \mathbb{R}[\mathbf{x}]_{d-1} : (\partial_e f) \cdot g - f \cdot (\partial_e g) \geq 0 \text{ auf } \mathbb{R}^n\}.$$

Insbesondere ist  $\text{Int}_e(f)$  in diesem Fall ein linearer Schnitt von  $P_{n,2d-2}$ .

*Beweis.* Nach Bemerkung 5.5.5 kann man annehmen, dass  $f$  quadratfrei ist, d.h. alle Aussagen bis auf die letzte folgen aus Theorem 5.6. Die Abbildung  $\phi : \mathbb{R}[\mathbf{x}]_{d-1} \rightarrow \mathbb{R}[\mathbf{x}]_{2d-2}$ ,  $g \mapsto (\partial_e f) \cdot g - f \cdot (\partial_e g)$  ist linear und (für quadratfreies  $f$ ) ist  $\text{Int}_e(f)$  das Urbild von  $P_{n,2d-2}$  unter  $\phi$ .  $\phi$  ist injektiv, denn für quadratfreies  $f$  gibt es einen irreduziblen Faktor von  $f$  der  $(\partial_e f) \cdot g$  nicht teilt.  $\square$

**5.9 Definition.** Für  $f \in \mathbb{R}[\mathbf{x}]_d$  und  $u, v \in \mathbb{R}^n$  sei  $\Delta_{u,v} f := (\partial_u f) \cdot (\partial_v f) - f \cdot (\partial_u \partial_v f) \in \mathbb{R}[\mathbf{x}]_{2d-2}$ . Die Abbildung

$$\mathbb{R}^n \times \mathbb{R}^n \rightarrow \mathbb{R}[\mathbf{x}]_{2d-2}, \quad (u, v) \mapsto \Delta_{u,v} f$$

ist bilinear und symmetrisch. Für  $g \in \mathbb{R}[\mathbf{x}]_d$  gilt  $\Delta_{u,v}(fg) = f^2 \cdot \Delta_{u,v} g + g^2 \cdot \Delta_{u,v} f$ .

**5.10 Theorem.** Sei  $f \in \mathcal{H}_d(e)$  quadratfrei. Dann ist

$$C_e(f) = \{u \in \mathbb{R}^n : \partial_u f \in \text{Int}_e(f)\} = \{u \in \mathbb{R}^n : \Delta_{e,u} f \geq 0 \text{ auf } \mathbb{R}^n\}$$

(ein linearer Schnitt von  $P_{n,2d-2}$ ).

*Beweis.* Die Abbildung  $\mathbb{R}^n \rightarrow \mathbb{R}[\mathbf{x}]_{2d-2}$ ,  $u \mapsto \Delta_{e,u} f$  ist linear und injektiv. Die zweite Gleichheit folgt mit Theorem 5.6 angewandt auf  $g = \partial_u f$ . Um die erste Gleichheit zu zeigen, kann man ohne Einschränkung  $f(e) > 0$  annehmen. ' $\subseteq$ ': Für  $u \in U_e(f)$  ist  $\partial_u f \in \text{Int}_u(f) = \text{Int}_e(f)$  (5.6). Da  $\text{Int}_e(f)$  abgeschlossen ist, gilt das auch für  $u \in C_e(f)$ . Außerdem ist  $\{u \in \mathbb{R}^n : \partial_u f \in \text{Int}_e(f)\}$  ein abgeschlossener konvexer Kegel in  $\mathbb{R}^n$  (das Urbild von  $\text{Int}_e(f)$  unter  $u \mapsto \partial_u f$ ) mit nichtleerem Inneren (enthält  $U_e(f)$ ). ' $\supseteq$ ': Angenommen es gibt ein  $u \notin C_e(f)$  mit  $\partial_e f \in \text{Int}_e(f)$ , dann gibt es auch ein solches  $u$  mit  $f(u) \neq 0$ . Weiter gilt auch  $-u \notin C_e(f)$ , denn sonst wäre  $\partial_{-u} f = -\partial_u f \in \text{Int}_e(f)$  (' $\subseteq$ ' schon gezeigt), also  $(\partial_u f)(e) > 0$  und  $(-\partial_u f)(e) > 0$ , Widerspruch. Wegen  $f(u) \neq 0$  hat das univariate Polynom  $f(e + su) \in \mathbb{R}[s]$  Grad  $d$  und ist real-rooted, die Ableitung  $(\partial_u f)(e + su)$  ist also ein interlacer davon. Seien  $b_1 \leq \dots \leq b_{d-1}$  die Nullstellen von  $(\partial_u f)(e + su)$ . Diese sind alle von Null verschieden. Die Nullstellen von  $(\partial_u f)(te + u)$  sind  $b_1^{-1}, \dots, b_{d-1}^{-1}$ . Seien  $a_1 \leq \dots \leq a_d$  die

Nullstellen von  $f(te + u)$ , diese sind ebenfalls von Null verschieden. Wegen  $\pm u \notin C_e(f)$  ist  $a_1 < 0$  und  $a_d > 0$ :  $f$  hat eine Nullstelle in  $(e, u)$  und eine in  $(e, -u)$ , denn

$$f(se + (1-s)u) = 0 = f(s'e - (1-s')u) \quad \text{mit } 0 < s, s' < 1$$

ist äquivalent zu

$$f\left(\underbrace{\frac{s}{1-s}}_{>0}e + u\right) = 0 = f\left(\underbrace{\frac{-s'}{1-s'}}_{<0}e + u\right).$$

Sei  $k \in [d]$  mit  $a_k < 0 < a_{k+1}$ . Die Nullstellen von  $f(e + su)$  sind  $a_1^{-1}, \dots, a_d^{-1}$ . Wegen interlacing gilt

$$\underbrace{\frac{1}{a_k} \leq b_1 \leq \frac{1}{a_{k-1}} \leq b_2 \leq \dots \leq \frac{1}{a_1} \leq b_k}_{<0} \leq \underbrace{\frac{1}{a_d} \leq b_{k+1} \leq \dots \leq b_{d-1} \leq \frac{1}{a_{k+1}}}_{>0}.$$

Für  $b_k \neq 0$  gibt es zwei Möglichkeiten, beide ergeben einen Widerspruch:

- Ist  $b_k < 0$ , so ist  $b_k^{-1}$  die kleinste Nullstelle von  $(\partial_u f)(te + u)$  und  $b_1^{-1}$  ist die  $k$ -te Nullstelle:

$$a_1 \geq \frac{1}{b_k} \geq a_2 \geq \frac{1}{b_{k-1}} \geq \dots \geq a_k \geq \frac{1}{b_1} < 0$$

Es folgt  $a_1 = b_k^{-1}$ , also ( $a_1$  ist eine mehrfache Nullstelle von  $f(te + u)$ )  $a_1 = a_2 = b_k^{-1}$ . Induktiv folgt  $a_1 = \dots = a_k = b_1^{-1} = \dots = b_k^{-1} < 0$  und diese Zahl ist eine genau  $k$ -fache Nullstelle sowohl von  $f(te + u)$ , als auch von seiner Ableitung, Widerspruch.

- Ist  $b_k > 0$ , so erhält man analog einen Widerspruch. □

**5.11 Korollar.** Ist  $f \in \mathcal{H}_d(e)$  und sind  $u, v \in C_e(f)$ , so ist  $\Delta_{u,v}f \in \mathbb{R}[\mathbf{x}]_{2d-2}$  psd auf  $\mathbb{R}^n$ .

*Beweis.* Sei  $X = (x_{ij})$  die allgemeine symmetrische  $d \times d$ -Matrix (d.h. die  $x_{ij} = x_{ji}$  sind Variablen) über  $\mathbb{R}[X]$ . Die Form  $\det(X) \in \mathbb{R}[X]_d$  ist hyperbolisch bzgl.  $I_d$  mit  $C_{I_d}(\det(X)) = S_+^d$ . Für jedes  $A \in S_+^d$  ist  $\partial_A \det(X)$  ein interlacer von  $\det(X)$ . Nach Aufgabe 24 gilt  $\partial_A \det(X) = \text{tr}(A \cdot X^{\text{adj}})$ . □

**5.12 Korollar.** Ist  $e \in \mathbb{R}^n$  und  $A(x) = \sum_{i=1}^n x_i A_i$  mit  $A_i \in S^d$  und  $A(e) \succ 0$ , so ist  $\text{tr}(B \cdot A(x)^{\text{adj}})$  für jedes  $B \in S_+^d$  ein interlacer von  $\det A(x)$  bzgl.  $e$ . □

**5.13 Satz.** Sei  $X$  die allgemeine symmetrische  $d \times d$ -Matrix wie im Beweis von Korollar 5.11. Für  $U, V \in S_+^d$  ist das Polynom  $\Delta_{U,V} \det(X) \in \mathbb{R}[X]_{2d-2}$  sos.

*Beweis.* Es genügt,  $U = uu^\top$  und  $V = vv^\top$  mit  $u, v \in \mathbb{R}^n$  zu betrachten. Es gilt

$$\partial_U \det(X) = - \begin{vmatrix} X & u \\ u^\top & 0 \end{vmatrix},$$

anwenden von Aufgabe 24 auf

$$\begin{pmatrix} X & u \\ u^\top & 0 \end{pmatrix} \quad \text{und} \quad \begin{pmatrix} v \\ 0 \end{pmatrix} \quad \text{liefert also} \quad \partial_U \partial_V \det(X) = \begin{vmatrix} X & u & v \\ u^\top & 0 & 0 \\ v^\top & 0 & 0 \end{vmatrix}.$$

Nun gilt

$$\Delta_{u,v} \det(X) = (\partial_U \det(X)) \cdot (\partial_V \det(X)) - \det(X) \cdot \partial_U \partial_V \det(X)$$

$$= \begin{vmatrix} X & u \\ u^\top & 0 \end{vmatrix} \cdot \begin{vmatrix} X & v \\ v^\top & 0 \end{vmatrix} - |X| \cdot \begin{vmatrix} X & u & v \\ u^\top & 0 & 0 \\ v^\top & 0 & 0 \end{vmatrix} \stackrel{5.14}{=} \begin{vmatrix} X & v \\ u^\top & 0 \end{vmatrix} \cdot \begin{vmatrix} X & u \\ v^\top & 0 \end{vmatrix} = \begin{vmatrix} X & v \\ u^\top & 0 \end{vmatrix}^2. \quad \square$$

**5.14 Lemma.** Seien  $X \in \mathbb{R}^{n \times n}$  und  $a, b, c, d \in \mathbb{R}^n$ . Dann gilt

$$\begin{vmatrix} X & b \\ a^\top & 0 \end{vmatrix} \cdot \begin{vmatrix} X & d \\ c^\top & 0 \end{vmatrix} - \begin{vmatrix} X & d \\ a^\top & 0 \end{vmatrix} \cdot \begin{vmatrix} X & b \\ c^\top & 0 \end{vmatrix} = |X| \cdot \begin{vmatrix} X & b & d \\ a^\top & 0 & 0 \\ c^\top & 0 & 0 \end{vmatrix}.$$

*Beweis.* Durch Anwendung des Schur-Komplements (B1, Aufgabe 40) auf die rechte Seite folgt

$$\begin{aligned} D &:= \begin{vmatrix} X & b & d \\ a^\top & 0 & 0 \\ c^\top & 0 & 0 \end{vmatrix} = |X| \cdot \det \left( - \begin{pmatrix} a^\top \\ c^\top \end{pmatrix} X^{-1} \begin{pmatrix} b & d \end{pmatrix} \right) \\ &= |X|^{-1} \cdot \det \left( - \begin{pmatrix} a^\top \\ c^\top \end{pmatrix} X^{\text{adj}} \begin{pmatrix} b & d \end{pmatrix} \right) = |X|^{-1} \cdot \begin{vmatrix} a^\top X^{\text{adj}} b & a^\top X^{\text{adj}} d \\ c^\top X^{\text{adj}} b & c^\top X^{\text{adj}} d \end{vmatrix}. \end{aligned}$$

Nach Aufgabe 24 ist  $a^\top X^{\text{adj}} b = - \begin{vmatrix} X & b \\ a^\top & 0 \end{vmatrix}$ , also folgt

$$D = |X|^{-1} \cdot \left( \begin{vmatrix} X & b \\ a^\top & 0 \end{vmatrix} \cdot \begin{vmatrix} X & d \\ c^\top & 0 \end{vmatrix} - \begin{vmatrix} X & d \\ a^\top & 0 \end{vmatrix} \cdot \begin{vmatrix} X & b \\ c^\top & 0 \end{vmatrix} \right). \quad \square$$

**5.15 Theorem.** Sei  $f \in \mathcal{H}_d(e)$ . Hat  $f^r$  eine definite Determinantendarstellung für ein  $r \geq 1$ , so ist  $\Delta_{u,v} f$  sos für beliebige  $u, v \in C_e(f)$ .

*Beweis.* Nach Voraussetzung ist  $f = \det A(x)$  mit  $A(e) \succ 0$ . Sei zunächst  $r = 1$  und argumentiere wie im Beweis von Korollar 5.12. Die Abbildung  $\phi: \mathbb{R}[X] \rightarrow \mathbb{R}[x_1, \dots, x_n]$ ,  $x_{ij} \mapsto A(x)_{ij}$  erfüllt

$$\phi(\det(X)) = \det A(x) = f, \quad \phi(\partial_{A(w)} \det(X)) = \partial_w f \quad \text{und} \quad \phi(\Delta_{A(u), A(v)} \det(X)) = \Delta_{u,v} f.$$

Sind  $U, V \succeq 0$ , so ist  $\Delta_{U,V} \det(X)$  nach Satz 5.13 sos. Seien  $u, v \in C_e(f)$ , dann gilt  $A(u) \succeq 0$  und  $A(v) \succeq 0$ , denn  $\phi$  bildet  $\Delta_{U,V} \det(X)$  auf  $\Delta_{u,v} f$  ab. Sei nun  $r \geq 1$ . Nach 5.9 ist

$$\Delta_{u,v}(fg) = f^2 \Delta_{u,v}(g) + g^2 \Delta_{u,v}(f), \quad \text{d.h.} \quad \Delta_{u,v}(f^2) = 2f^2 \Delta_{u,v}(f).$$

Zeige induktiv  $\Delta_{u,v}(f^r) = r f^{2r-2} \Delta_{u,v}(f)$  für alle  $r$ . Sei  $f^r = \det A(x)$  mit  $A(e) \succ 0$ . Wegen  $u, v \in C_e(f) = C_e(f^r)$  folgt aus den Fall  $r = 1$ , dass  $\Delta_{u,v}(f^r) = r f^{2r-2} \Delta_{u,v}(f)$  sos ist, also ist  $\Delta_{u,v} f$  sos, denn jeder irreduzible Faktor von  $f$  ist reell.  $\square$

## §6 Gegenbeispiele zur Helton-Nie-Vermutung

**6.1 Notation.** Für  $S \subseteq \mathbb{R}^n$  schreibe

$$\begin{aligned} P_S &:= \{f \in \mathbb{R}[\mathbf{x}]_{\leq 1} : f|_S \geq 0\} = \mathbb{R}[\mathbf{x}]_{\leq 1} \cap \mathcal{P}(S) \quad \text{und} \\ P_{S,0} &:= \{f \in P_S : f(0) = 0\}, \end{aligned}$$

dann gilt  $\overline{\text{conv}(S)} = \{u \in \mathbb{R}^n : \forall f \in P_S : f(u) \geq 0\}$  und  $\overline{\text{cone}(S)} = \{u \in \mathbb{R}^n : \forall f \in P_{S,0} : f(u) \geq 0\}$ .

**6.2 Lemma.** Seien  $S \subseteq \mathbb{R}^n$ ,  $K := \overline{\text{conv}(S)}$  und  $C := \overline{\text{cone}(S)}$ .

(a)  $K$  ist ein affin-linearer Schnitt von  $(P_S)^*$  und  $K$  ist genau dann ein Spektraederschatten, wenn  $P_S$  einer ist.

(b) Es gilt  $C = (P_{S,0})^*$  und  $C$  ist genau dann ein Spektraederschatten, wenn  $P_{S,0}$  einer ist.

*Beweis.* Es ist  $(P_S)^* = \{(v_0, \dots, v_n) \in \mathbb{R}^{n+1} : \forall f \in P_S: \tilde{f}(v) \geq 0\}$  (mit  $\tilde{f} := \sum_{i=0}^n a_i x_i \in \mathbb{R}[x_0, \mathbf{x}]$  für  $f = a_0 + \sum_{i=1}^n a_i x_i$ ) und damit  $K = \{u \in \mathbb{R}^n : (1, u_1, \dots, u_n) \in P_S^*\}$ . Wegen  $P_S = P_K = (K_h)^*$  folgt die Äquivalenz in (a) aus Konvexität. (b) folgt analog.  $\square$

**6.3 Definition.** Sei  $V$  eine affine  $\mathbb{R}$ -Varietät, sei  $S \subseteq V(\mathbb{R})$  und sei  $L \subseteq \mathbb{R}[V]$  ein Untervektorraum mit  $\dim(L) < \infty$ .  $S$  hat *uniforme sos-Darstellungen* für  $L$ , falls eine affine  $\mathbb{R}$ -Varietät  $X$ , ein Morphismus  $\phi: X \rightarrow V$  von affinen  $\mathbb{R}$ -Varietäten und ein Untervektorraum  $U \subseteq \mathbb{R}[X]$  mit

$$(1) \dim(U) < \infty, \quad (2) S \subseteq \phi(X(\mathbb{R})), \quad (3) \phi^*(L \cap \mathcal{P}(S)) \subseteq \Sigma U^2$$

existieren. Dabei ist  $\phi^*: \mathbb{R}[V] \rightarrow \mathbb{R}[X]$  der zu  $\phi$  gehörige duale Ringhomomorphismus.

**6.4 Bemerkung.** Für eine semialgebraische Menge  $S \subseteq V(\mathbb{R})$  sei  $\mathcal{A}_0(S)$  der Ring der definierbaren Funktionen  $S \rightarrow \mathbb{R}$ . Dann sind die Bedingungen aus Definition 6.3 für  $S$  und  $L$  genau dann erfüllt, wenn es  $h_1, \dots, h_N \in \mathcal{A}_0(S)$  gibt, sodass  $f|_S$  für jedes  $f \in L \cap \mathcal{P}(S)$  eine Summe von Quadraten von Linearkombinationen von  $h_1, \dots, h_N$  ist.

*Beweis.* '⇒': Gelte 6.3 mit  $\phi: X \rightarrow V$  und  $U \subseteq \mathbb{R}[X]$  ( $\dim(U) < \infty$ ). Wegen  $S \subseteq \phi(X(\mathbb{R}))$  gibt es nach RAG I einen definierbaren Schnitt  $\sigma: S \rightarrow X(\mathbb{R})$  von  $\pi$  über  $S$  (d.h.  $\pi \circ \sigma = \text{id}_S$ ). Ist  $g_1, \dots, g_N$  eine Basis von  $U$ , so gilt 6.4 für  $h_i := g_i \circ \sigma: S \rightarrow \mathbb{R}$ .

'⇐': Gelte 6.4 mit  $h_1, \dots, h_N: S \rightarrow \mathbb{R}$  und wähle  $X := \overline{\text{graph}(h_1, \dots, h_N)} \subseteq V \times \mathbb{A}^N$  (Zariski-Abschluss). Es gilt

$$\text{graph}(h_1, \dots, h_N) = \{(s, h_1(s), \dots, h_N(s)) \mid s \in S\} \subseteq S \times \mathbb{R}^N \subseteq (V \times \mathbb{A}^N)(\mathbb{R}).$$

Ist  $\phi: X \rightarrow V$  kanonisch, so ist 6.3 erfüllt für  $U := \text{span}(g_1, \dots, g_N)$ , wobei  $g_i: X \rightarrow \mathbb{A}^i$  die Projektion auf die  $i$ -te Komponente ist. (Ist  $f|_S \geq 0$  und  $f = \sum_{i,j} (a_{ij} h_i)^2$ , so ist  $\phi^* = \sum_{i,j} (a_{ij} g_i)^2$  mit  $a_{ij} g_i \in U$ .)  $\square$

**6.5 Theorem.** Sei  $S \subseteq \mathbb{R}^n$  eine semialgebraische Menge und sei  $K := \overline{\text{conv}(S)}$ . Dann sind äquivalent:

- (i)  $K$  ist ein Spektraederschatten.
- (ii)  $S$  hat uniforme sos-Darstellungen für  $L := \mathbb{R}[\mathbf{x}]_{\leq 1}$ .

Die analoge Äquivalenz gilt für  $C := \overline{\text{cone}(S)}$  und  $L_1 := \mathbb{R}[\mathbf{x}]_1$  (Linearformen).

**6.6 Satz.** In Theorem 6.5 gilt (ii) ⇒ (i).

*Beweis.* Sei  $\phi: X \rightarrow \mathbb{A}^n$  mit  $S \subseteq \phi(X(\mathbb{R}))$  und sei  $U \subseteq \mathbb{R}[X]$  mit  $\dim(U) < \infty$  und  $\phi^*(P_S) \subseteq \Sigma U^2$ . Setze  $W := UU + \phi^*(L_1) \subseteq \mathbb{R}[X]$  und weiter  $\varphi := \phi^*|_{L_1}: L_1 \rightarrow W$ . Wegen  $\varphi(P_S) \subseteq \Sigma U^2$  ist  $P_S \subseteq \varphi^{-1}(\Sigma U^2)$ . Umgekehrt gilt '⊇' wegen  $S \subseteq \phi(X(\mathbb{R}))$ . Da  $\Sigma U^2$  ein Spektraederschatten ist (Konvexität), ist auch  $P_S = \varphi^{-1}(\Sigma U^2)$  einer, d.h. nach 6.2 ist  $K$  ein Spektraederschatten.  $\square$

Für den Beweis von (i) ⇒ (ii) in Theorem 6.5 starten wir mit der homogenen Version:

**6.7 Satz.** Sei  $S \subseteq \mathbb{R}^n$  semialgebraisch und sei  $C := \overline{\text{cone}(S)}$  ein Spektraederschatten. Dann hat  $S$  (und  $C$ ) uniforme sos-Darstellungen für  $L := \text{span}(x_1, \dots, x_n)$ .

*Beweis.* Ohne Einschränkung sei  $\text{aff}(S) = \mathbb{R}^n$ . Nach Voraussetzung gibt es eine lineare Abbildung  $\pi: \mathbb{R}^p \rightarrow \mathbb{R}^n$  und einen Spektraederkegel  $T \subseteq \mathbb{R}^p$  mit  $C = \pi(T)$ . Man kann  $\text{int}(T) \neq \emptyset$  annehmen und dass  $T$  eine Beschreibung durch eine **strikt** lösbare LMI hat, etwa

$$T = \{(\xi, \eta) \in \mathbb{R}^n \times \mathbb{R}^m : M(\xi) + N(\eta) \succeq 0\}$$

mit  $M(x) = \sum_i x_i M_i$ ,  $N(y) = \sum_j y_j N_j$  und  $M(\xi) + N(\eta) \succ 0$  für ein  $(\xi, \eta) \in T$ . Betrachte die folgende Untervarietät  $X$  von  $\mathbb{A}^n \times \mathbb{A}^m \times \text{Sym}_d$ : Die  $\mathbb{C}$ -Punkte von  $X$  seien die Tupel  $(\xi, \eta, A) \in \mathbb{C}^n \times \mathbb{C}^m \times \text{Sym}_d(\mathbb{C})$  mit  $A^2 = M(\xi) + N(\eta)$  und die Koordinatenfunktionen auf  $X$  seien  $(x_1, \dots, x_n, y_1, \dots, y_m; z_{\mu\nu} = z_{\nu\mu} \ (\mu, \nu \in [d]))$ . Definiere  $\phi: X \rightarrow \mathbb{A}^n$ ,  $(\xi, \eta, A) \mapsto \xi$ , dann gilt  $\phi(X(\mathbb{R})) = \pi(T) = C$ . Setze  $U := \text{span}(z_{\mu\nu} \mid \mu, \nu \in [d]) \subseteq \mathbb{R}[X]$  und behaupte, (3) aus Definition 6.3 ist erfüllt. Sei  $f = \sum_{i=1}^n a_i x_i$  mit  $f|_S \geq 0$  (d.h.  $f|_C \geq 0$ ), dann liegt der Punkt  $(a, 0) = (a_1, \dots, a_n, 0, \dots, 0) \in \mathbb{R}^n \times \mathbb{R}^m$  in  $T^*$ : Aus  $(\xi, \eta) \in T$  folgt  $\xi \in C$ , d.h.  $0 \leq f(\xi) = \langle \xi, a \rangle = \langle (\xi, \eta), (a, 0) \rangle$ . Nach Konvexität existiert ein  $B \in \mathbb{S}_+^d$  mit  $a_i = \langle B, M_i \rangle$  und  $0 = \langle B, N_j \rangle$  für alle  $j \in [m]$ . Sei  $W = (w_{k\ell}) \in \mathbb{S}^d$  mit  $W^2 = B$ . Dann ist  $\phi^*(f)$  gleich

$$\sum_{i=1}^n \langle B, M_i \rangle x_i + \sum_{j=1}^m \langle B, N_j \rangle y_j = \langle B, M(x) + N(y) \rangle = \langle W^2, Z^2 \rangle = \langle ZW, ZW \rangle$$

(wegen  $\langle W^2, Z^2 \rangle = \text{tr}(W^2 Z^2) = \text{tr}((ZW)(ZW)^\top) = \langle ZW, ZW \rangle$ ). Als Element in  $\mathbb{R}[X]$  ist das

$$\phi^*(f) = \sum_{\mu, \nu=1}^d ((ZW)_{\mu, \nu})^2 = \sum_{\mu, \nu=1}^d \left( \sum_k z_{\mu k} w_{k \nu} \right)^2. \quad \square$$

Jetzt können wir auch die inhomogene Version beweisen:

**6.8 Satz.** Sei  $S \subseteq \mathbb{R}^n$  semialgebraisch und sei  $K := \text{conv}(S)$  ein Spektraederschatten. Dann hat  $S$  (und  $K$ ) uniforme sos-Darstellungen für  $L := \text{span}(1, x_1, \dots, x_n)$ .

*Beweis.* Das lässt sich leicht aus Satz 6.7 herleiten. □

**6.9 Satz.** Sei  $S \subseteq \mathbb{R}^n$  eine semialgebraische Menge und sei  $L \subseteq \mathbb{R}[\mathbf{x}]$  ein Untervektorraum mit  $m := \dim(L) < \infty$ . Sei  $p_1, \dots, p_m$  eine Basis von  $L$  und setze

$$\varphi_L: \mathbb{R}^n \rightarrow \mathbb{R}^m, \quad u \mapsto (p_1(u), \dots, p_m(u)).$$

Dann ist  $\overline{\text{conv}(\varphi_L(S))}$  genau dann ein Spektraederschatten, wenn  $S$  uniforme sos-Darstellungen für  $L_1 := \text{span}(1, p_1, \dots, p_m)$  hat.

*Beweis.* Übung. □

**Definition.** Für eine offene und semialgebraische Menge  $U \subseteq \mathbb{R}^n$  sei  $\mathcal{N}(U)$  der Ring der *Nashfunktionen*<sup>13</sup> auf  $U$ . Für  $u \in U$  sei  $\mathcal{O}_u := \mathbb{R}[\mathbf{x}]_{\mathfrak{m}_u}$ , d.h.  $\widehat{\mathcal{O}}_u = \mathbb{R}[[x_1 - u_1, \dots, x_n - u_n]] = \mathbb{R}[[\mathbf{x} - u]]$ . Taylorentwicklung von  $f \in \mathcal{N}$  in  $u$  liefert den Ringhomomorphismus

$$\mathcal{N} \rightarrow \widehat{\mathcal{O}}_u, \quad f \mapsto \tau_u(f).$$

Betrachte weiter die Veroneseabbildung<sup>14</sup>  $\varphi_{n,d}: \mathbb{R}^n \rightarrow \mathbb{R}^N$ ,  $u \mapsto (u^\alpha)_{1 \leq |\alpha| \leq d}$  mit  $N := \binom{n+d}{d} - 1$ .

**6.10 Theorem.** Sei  $S \subseteq \mathbb{R}^n$  eine semialgebraische Menge mit  $\text{int}(S) \neq \emptyset$ . Ist  $n \geq 3$  und  $d \geq 6$  oder  $n \geq 4$  und  $d \geq 4$ , so ist  $\overline{\text{conv}(\varphi_{n,d}(S))}$  kein Spektraederschatten.

<sup>13</sup>John Forbes NASH (1928–2015)

<sup>14</sup>Giuseppe VERONESE (1854–1917)

*Beweis.* Angenommen doch, dann existiert ein Unterraum  $U \subseteq \mathcal{A}_0(S)$  mit  $\dim(U) < \infty$  so, dass für jedes  $f \in \mathbb{R}[\mathbf{x}]_{\leq d}$  mit  $f|_S \geq 0$  die Funktion  $f|_S$  in  $\Sigma U^2$  liegt. Jedes  $h \in U$  ist Nash auf einer offen-dichten Teilmenge von  $\text{int}(S)$  (RAG, 4.5.7). Daher existiert eine offene Menge  $\emptyset \neq W \subseteq S$ , sodass  $h|_W$  für alle  $h \in U$  Nash ist. Fixiere ein  $u \in U$  und sei  $p \in \mathbb{R}[\mathbf{x}]$  eine psd Form mit  $\deg(p) \leq d$ , welche nicht sos ist. Dann ist  $f := p(y_1, \dots, y_n)$  mit  $y_i := x_i - u_i$  eine Summe von Quadraten in  $\widehat{\mathcal{O}}_u = \mathbb{R}[\mathbf{x} - u] = \mathbb{R}[\mathbf{y}]$ , d.h.  $f$  ist sos von Formen in  $(y_1, \dots, y_n)$  (ist  $f(y) = h_1^2 + \dots + h_N^2$  mit  $\deg(f) = 2d$  und  $h_i = h_{id}(y) + h_{i,d+1}(y) + \dots$ , so ist  $f = \sum_i h_{id}(y)^2$ ), Widerspruch.  $\square$

**Bemerkung.** Für  $(n, d) = (3, 6)$  bzw.  $(n, d) = (4, 4)$  liefert das Theorem also konvexe semialgebraische Mengen, die keine Spektraederschatten sind (nämlich abgeschlossene konvexe Hüllen von semialgebraischen Mengen von Dimension  $\geq 3$ ) in  $\mathbb{R}^{\binom{9}{3}-1} = \mathbb{R}^{83}$  bzw.  $\mathbb{R}^{\binom{8}{4}-1} = \mathbb{R}^{69}$ .

Fixiere einen reell abgeschlossenen Körper  $R \supseteq \mathbb{R}$  und sei  $B \subseteq R$  die konvexe Hülle von  $\mathbb{R}$  in  $R$ .

**6.11 Lemma.** Sei  $A$  eine reell reduzierte  $\mathbb{R}$ -Algebra. Sind  $f_1, \dots, f_m \in A \otimes R = A \otimes_{\mathbb{R}} R =: A_R$  mit  $\sum_{i=1}^r f_i^2 \in A_B := A \otimes B$ , so gilt  $f_i \in A_B$  für alle  $i \in [r]$ .

*Beweis.* Wähle linear unabhängige  $g_1, \dots, g_S \in A$  und  $c_{ij} \in R$  mit  $f_i = \sum_j c_{ij} g_j$ . Angenommen  $c_{ij} \notin B$  für ein Paar  $(i, j)$ , dann ist  $c := \max_{ij} |c_{ij}| \notin B$ , d.h.  $h_i := \frac{1}{c} f_i \in A_B$  für alle  $i \in [r]$  und  $\frac{1}{c^2} f = \sum_i h_i^2$  hat Koeffizienten in  $\mathfrak{m}_B$ . Reduktion modulo  $\mathfrak{m}_B$  liefert  $0 = \sum_i \bar{h}_i^2$  in  $A_B/\mathfrak{m}_B A_B = A$  und  $\bar{h}_i \neq 0$  für mindestens ein  $i \in [r]$ , im Widerspruch dazu, dass  $A$  reell reduziert ist.  $\square$

**6.12 Satz.** Sei  $f \in \mathbb{R}[t, \mathbf{x}]$  homogen vom Grad  $d$  in  $(t, \mathbf{x})$  und sei  $f$  nicht sos in  $\mathbb{R}[t, \mathbf{x}]$ . Für alle  $0 < \varepsilon \in \mathfrak{m}_B$  ist  $f(\varepsilon, x) \in B[\mathbf{x}]$  nicht sos modulo  $\langle \mathbf{x} \rangle^{d+1} := \langle x_1, \dots, x_n \rangle^{d+1}$ .

*Beweis.* Angenommen  $f(\varepsilon, x) + g(x) = \sum_j p_j(x)^2$  mit  $p_j(x) \in B[\mathbf{x}]$  und  $g(x) \in \langle \mathbf{x} \rangle^{d+1} B[\mathbf{x}]$ . Sei

$$g_1(x) := \frac{1}{\varepsilon^{d+1}} g(\varepsilon x) \in B[\mathbf{x}].$$

Es folgt  $\varepsilon^d f(1, x) + g(\varepsilon x) = f(\varepsilon, \varepsilon x) + g(\varepsilon x) = \sum_j p_j(\varepsilon x)^2$ , Division durch  $\varepsilon^d$  liefert also

$$f(1, x) + \underbrace{\varepsilon g_1(x)}_{\in \varepsilon B[\mathbf{x}]} = f(1, x) + \frac{g(\varepsilon x)}{\varepsilon^d} = \sum_j \varepsilon^{-d} p_j(\varepsilon x)^2 = \sum_j \left( (\sqrt{\varepsilon})^{-d} p_j(\varepsilon x) \right)^2. \quad (*)$$

Nach Lemma 6.11 liegen alle Summanden der rechten Seite von  $(*)$  in  $B[\mathbf{x}]$ . Reduziert man beide Seiten modulo  $\mathfrak{m}_B$ , so folgt, dass  $f(1, x)$  sos in  $\mathbb{R}[\mathbf{x}]$  ist, im Widerspruch dazu, dass  $f(t, x)$  nicht sos ist.  $\square$

**6.13 Theorem.** Sei  $p(t, x) \in \mathbb{R}[t, \mathbf{x}]$  eine psd Form, die nicht sos ist und sei  $L \subseteq \mathbb{R}[\mathbf{x}]$  ein Unterraum mit  $m := \dim(L) < \infty$  und  $p(c, x - u) \in L$  für alle  $c \in \mathbb{R}$  und  $u \in \mathbb{R}^n$ . Für jede semialgebraische Menge  $S \subseteq \mathbb{R}^n$  mit  $\text{int}(S) \neq \emptyset$  ist  $\overline{\text{conv}(\varphi_L(S))} \subseteq \mathbb{R}^m$  kein Spektraederschatten.

*Beweis.* Angenommen doch, dann gibt es wie im Beweis von Theorem 6.10 eine offene semialgebraische Menge  $\emptyset \neq W \subseteq S$  und einen Unterraum  $U \subseteq \mathcal{N}(W)$  mit  $\dim(U) < \infty$  und  $f|_W \in \Sigma U^2$  für jedes  $f \in L + \mathbb{R} \cdot 1$  mit  $f|_S \geq 0$ . Seien  $R \supseteq \mathbb{R}$  und  $B \subseteq R$  wie zuvor und sei  $0 < \varepsilon \in \mathfrak{m}_B$ . Für jedes  $f \in L_R \subseteq R[\mathbf{x}]$  mit  $f|_{S_R} \geq 0$  ist  $f|_{W_R}$  sos von Elementen aus  $U_R$ . Sei  $d := \deg(p)$  und sei  $u \in W$ . Das Polynom  $f := p(\varepsilon, x_1 - u_1, \dots, x_n - u_n) \in B[\mathbf{x}]$  liegt in  $L_R + R \cdot 1$  und ist  $\geq 0$  auf  $R^n$ . Damit ist  $f|_W \in \Sigma(U_R)^2$ , d.h.  $f$  ist sos in  $\widehat{\mathcal{O}}_u \otimes R$ . Nach Lemma 6.11 ist  $f$  daher sos in  $\widehat{\mathcal{O}}_u \otimes B$ , also auch modulo  $\langle \mathbf{x} - u \rangle^{d+1}$ . Damit ist  $f$  sos in  $B[\mathbf{x}]/\langle \mathbf{x} - u \rangle^{d+1}$ , im Widerspruch zu Satz 6.12.  $\square$

**6.14 Bemerkung.** Sei  $L := \text{span}(\mathbf{x}^\alpha \mid 1 \leq |\alpha| \leq d) \subseteq \mathbb{R}[\mathbf{x}]$  mit  $n = 2$  und  $d \geq 6$  oder  $n \geq 3$  und  $d \geq 4$ . Dann erhalten wir erneut Beispiele von konvexen semialgebraischen Mengen, die keine Spektraederschatten sind, jetzt jedoch in Dimension  $\binom{8}{2} - 1 = 27$  oder  $\binom{7}{3} - 1 = 34$ .

**6.15 Theorem.** Der Kegel  $P_{n,2d} \subseteq \mathbb{R}[\mathbf{x}]$  ist genau dann ein Spektraederschatten, wenn  $P_{n,2d} = \Sigma_{n,2d}$  gilt und das ist genau dann der Fall, wenn  $n \leq 2$  oder  $2d = 2$  oder  $(n, 2d) = (3, 4)$ .

*Beweis.* Das folgt direkt aus Bemerkung 6.14, zusammen mit Hilbert 1888. □

**Bemerkung.** Es sind noch kleinere Dimensionen von Gegenbeispielen möglich: In Dimension 12 betrachte  $\varphi_L: \mathbb{R}^2 \rightarrow \mathbb{R}^{12}$  mit

$$L = \text{span} (x, x^2, x^3, x^4, x^5, x^6, y, y^2, xy, xy^2, 3x^2y - 2y^3, 3x^2y^2 - y^4)$$

und nimm  $f(t, x, y) = x^6 + t^2x^4 + t^4y^2 - 3t^2x^2y^2$ . Auch in Dimension 11 gibt es noch Beispiele, siehe z.B. [2], Exercise 8.7.4.

Eine offene Frage ist, ob es in  $\mathbb{R}^d$  für  $3 \leq d \leq 10$  auch konvexe semialgebraische Mengen gibt, die keine Spektraederschatten sind.

## Literatur

- [1] Tim NETZER, Daniel PLAUMANN: *Geometry of Linear Matrix Inequalities*. Birkhäuser, 2023.
- [2] Claus SCHEIDERER: *A Course in Real Algebraic Geometry*. Springer, 2024.
- [3] Winfried SCHARLAU: *Quadratic and Hermitian Forms*. Springer, 1985.