

Zunächst zum Beweis des Theorems von Fan.

Wdh. Theorem (Fan):

Sei $C \in S^n$ sym. Matrix mit Eigenwerten $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_k$

Dann gilt: $\lambda_1 + \dots + \lambda_k = \max \{ \text{Tr}(CBB^T) : B \in \mathbb{R}^{n \times k}, B^T B = I_k \}$

$\stackrel{(*)}{=} \max \{ \text{Tr}(CY) : Y \in S^n, \text{Tr}(Y) = k, Y \geq 0, I - Y \geq 0 \}$

Wdh.: \rightarrow OR (2015)

Satz (Minkowski, Krein-Milman)

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

$D = \text{conv}(\text{ext}(D))$, wobei $\text{ext}(D) = \{x \in D : x \text{ sind Extrempunkte von } D\}$.

Lemma Definiere

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

$$K_2 := \{ BB^T : B \in \mathbb{R}^{n \times k}, B^T B = I_k \}$$

Dann gilt $\text{ext}(K_1) = K_2$, insbesondere $\text{conv}(K_2) = K_1$.

Beweis skizze:

Sei $P \in O(n)$ dann gilt

$$Y \in \text{ext}(K_1) \Leftrightarrow PYP^T \in \text{ext}(K_1).$$

Definiere nun das Polytop

$$Q := \{x \in [0,1]^n : e^T x = k\}, \text{ wobei } e = (1, \dots, 1)^T.$$

Mittels der Spektralzerlegung von $Y \in S^n$ folgt

$$Y = PDP^T \text{ mit } P \in O(n) \text{ und Diagonalmatrix } D = \begin{pmatrix} d_1 & & 0 \\ & \ddots & \\ 0 & & d_n \end{pmatrix}.$$

Dann gilt $Y \in \text{ext}(K_n) \Leftrightarrow D \in \text{ext}(K_n) \Leftrightarrow d \in \text{ext}(Q)$.

Außerdem, $\text{ext}(Q) = \{x \in \{0,1\}^n : e^T x = k\}$ und damit

$$|\{d_i : d_i = 1\}| = k, \quad |\{d_i : d_i = 0\}| = n - k.$$

Da die d_i die Eigenwerte von Y beschreiben gilt nun

$Y \in \text{ext}(K_n) \Leftrightarrow Y$ hat genau k Eigenwerte mit Wert 1
und $n-k$ Eigenwerte mit Wert 0.

Das bedeutet, dass Y eine Projektion auf einen k -dimensionalen Unterraum ist: $\exists B \in \mathbb{R}^{n \times k} : B^T B = I_k$ und $Y = BB^T$. \square

Dies nutzen wir nun um Fans Theorem zu beweisen.

Beweis skizze (Fan):

Aus DR folgt (*) $\hat{=} \max \{c^T x : x \in D\} = \max \{c^T x : x \in \text{ext}(D)\}$.

Sei p^* dieses Maximum.

$\lambda_1 + \dots + \lambda_k \leq p^*$: Sei $C = \sum_{i=1}^n \lambda_i m_i m_i^T$, dann ist $B = [m_1 \dots m_k] \in \mathbb{R}^{n \times k}$

und $BB^T \in K_2$, damit zulässig für das zugehörige SDP mit Zielwert $\text{Tr}(CBB^T) = \lambda_1 + \dots + \lambda_k$.

$\lambda_1 + \dots + \lambda_k \geq p^*$: Nutze erweiterte Spektralzerlegung von C :

$C = PDP^T$, $P \in O(n)$, D Diagonalmatrix, dann gilt für $BB^T \in K_2$:

$$\text{Tr}(CBB^T) = \dots = \text{Tr}(D \underbrace{P^T B (P^T B)^T}_{\in K_2})$$

Das bedeutet:

$$p^* = \max \left\{ \text{Tr}(DM) = \sum_{i=1}^n \lambda_i M_{ii} : M \in K_2 \right\}$$

Für $M \in K_2$ liegt $\text{diag}(M) = (M_{11}, \dots, M_{nn})$ in Q .

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

Aus letzter Vorlesung wissen wir, dass man mit Hilfe der Eigenwerte $\lambda_1, \dots, \lambda_D$ und der Eigenvektoren b_1, \dots, b_D von skalierten Varianten der Kovarianzmatrix Informationen über die Struktur der zugrundeliegenden Daten erhält.

Dass D gegebenenfalls sehr groß sein kann wird am folgendem Beispiel deutlich.

Bsp. Man betrachte einen Datensatz von $N=500$ Bildern der Größe 1000×1000 Pixel.

Diese kann man auffassen als Vektoren x_1, \dots, x_N der Größe $1000 \cdot 1000 = 10^6 = D$.

Die zugehörige (skalierte-) Kovarianzmatrix $XX^T \in \mathbb{R}^{D \times D}$ müsste nun in Eigenwerte / Eigenvektoren zerlegt werden, wofür moderne Algorithmen eine Laufzeit der Größenordnung $O(D^3) = O(10^{18})$ benötigen. \rightarrow Ansatz: Dimensionsreduktion

Wissen: $\text{rang}(XX^T) \leq N$, hier: $\text{rang}(XX^T) = N$, d.h. $\lambda_1, \dots, \lambda_N > 0$, (andernfalls betr. k.u. Teilmenge $\{x_i\}$)

$$XX^T \cdot (b_1, \dots, b_N) = \lambda_1 b_1 + \dots + \lambda_N b_N = B \cdot \Lambda \Rightarrow X^T X X^T B = X^T B \cdot \Lambda \quad (*)$$

Definiere $\tilde{B} = X^T B$, dann ist (*) äquivalent zu

$$X^T X (\tilde{b}_1, \dots, \tilde{b}_N) = X^T X \tilde{B} = \tilde{B} \Lambda = \lambda_1 \tilde{b}_1 + \dots + \lambda_N \tilde{b}_N, \text{ d.h. man kann}$$

mit Aufwand $O(N^3)$ die Eigenwerte λ_i und Eigenvektoren $\tilde{b}_i \in \mathbb{R}^N$ der Matrix $X^T X \in \mathbb{R}^{N \times N}$ berechnen.

Weiterhin löst $B = X \tilde{B} \Lambda^{-1}$ die Eigenwertproblemgleichung zu XX^T , da

$$XX^T B = XX^T X \tilde{B} \Lambda^{-1} = X \tilde{B} \Lambda \cdot \Lambda^{-1} = X \tilde{B} = B \Lambda.$$

Damit ergibt sich, dass man die Eigenwerte, mit Aufwand $O(N^3)$ und die zugehörigen Eigenvektoren b_i mit Aufwand $O(DN^2)$ berechnen kann (Die Berechnung von $X \tilde{B} \Lambda^{-1} \in O(DN^2)$).

$X \in \mathbb{R}^{D \times N}$ $\tilde{B} \in \mathbb{R}^{N \times N}$ $\Lambda^{-1} \in \mathbb{R}^{N \times N}$

Da $N \ll D$ ($500 \ll 10^6$) in unserem Beispiel ergibt sich eine Laufzeit, welche proportional zu $500^2 \cdot 10^6 = 25 \cdot 10^{11}$ ist, anstatt proportional zu 10^{18} .