

§ 2 Dünne Hauptkomponentenanalyse

(sparse PCA)

$X \in \mathbb{R}^{D \times N}$ Datenmatrix, M Zieldimension (klein)

vorgegeben.

PCA: Berechne Hauptkomponenten $b^1, \dots, b^M \in \mathbb{R}^D$.

Problem: Oft ist D groß, möchte aber Daten X erklären aber mit nur wenigen (k) Einträgen in den b^i 's.

Idee: Ersetze b^1 durch optimale Lösung des Optimierungsproblems (und berechne danach sukzessive b^2, \dots, b^M).

$$\max z^T \sum z$$

(*)

$$\|z\| = 1$$

$$\boxed{\|z\|_0 \leq k}$$

Wobei $\sum = XX^T$,

$$\|z\|_0 = |\{i \in \{1, \dots, D\} : z_i \neq 0\}|.$$

Nächstes Problem: (*) ist NP-schwer.

(→ Natarajan, 1995)

Ausweg: SDP-Relaxierung (nach d'Aspremont et al. 2007)

Satz

$$(*) = \max \langle \Sigma, Z \rangle \leq \max \langle \Sigma, Z \rangle$$

$$(\star\star) \quad Z \in S_{\geq 0}^D \quad (\star\star\star) \quad Z \in S_{\geq 0}^D$$

$$\text{Tr}(Z) = 1 \quad \text{Tr}(Z) = 1$$

$$\|Z\|_0 \leq k^2 \quad \langle J, |Z| \rangle \leq k,$$

$$\text{rang } Z = 1$$

dabei $J = \begin{bmatrix} 1 & \dots & 1 \\ \vdots & \ddots & \vdots \\ 1 & \dots & 1 \end{bmatrix}$ und das rechte Maximierungsproblem

heißt SDP-Relaxierung der sparse PCA.

Das kann effizient (in Theorie & Praxis) gelöst werden.
(siehe Link "Literatur / Software" der VL Convex Optimization).

Bew.: zum ersten " = ": Sei z optimal für (*),
dann ist $Z = z z^T$ optimal für ($\star\star$), und
umgekehrt.

Zum zweiten " \leq :

Sei $\mathcal{Z} = \mathbf{z}\mathbf{z}^T$ optimal für (**), dann ist $\|\mathbf{z}\|_0 \leq k$,

OBdA. $z_{k+1} = \dots = z_D = 0$. Dann ist

$$\begin{aligned} \langle \mathcal{Z}, \mathcal{Z} \rangle &= \sum_{i,j=1}^D |z_{ij}| \\ &= \sum_{i,j=1}^D |z_i z_j| \\ &= \sum_{i,j=1}^D |z_i| |z_j| \\ &= \left(\sum_{i=1}^k |z_i| \right)^2 \end{aligned}$$

Cauchy-Schwarz $\leq \|\mathbf{z}\| \cdot \left\| \begin{bmatrix} 1 \\ \vdots \\ 1 \end{bmatrix} \right\|$, $\|\mathbf{z}\| = 1$,

$$= k \quad \left[\begin{array}{c} 1 \\ \vdots \\ 1 \end{array} \right] \in \mathbb{R}^k.$$

□

Verwendung von (**): Zur Bestimmung einer sparsen PCA:

- 1) Bestimme optimale \mathcal{Z}
- 2) Bestimme Eigenvektor $\mathbf{z} \approx \lambda_{\max}(\mathcal{Z})$.
- 3) $\bar{\Sigma} \leftarrow \bar{\Sigma} - \mathbf{z}^T \bar{\Sigma} \mathbf{z} \mathbf{z}^T$.
- 4) Gehe zu 1). bis $\bar{\Sigma} \approx 0$.

Zur Modellierung von $\langle J, |z| \rangle \leq k$:

$$\langle J, |z| \rangle = \sum_{i=1}^D \sum_{j=1}^D |z_{ij}| \leq k.$$

$\underbrace{\quad}_{\ell_1\text{-Norm}}$

Für $x \in \mathbb{R}^n$ gilt

$$\|x\|_1 \leq k \iff x \in \text{conv} \left\{ \pm k e_i : i=1, \dots, n \right\}$$

$$\iff \exists \lambda_1, \dots, \lambda_n, \mu_1, \dots, \mu_n \geq 0 :$$

$$\sum_{i=1}^n \lambda_i + \sum_{i=1}^n \mu_i = 1$$

$$x = \sum_{i=1}^n \lambda_i k e_i + \sum_{i=1}^n \mu_i k (-e_i)$$

D.h. man kann die Bedingung $\|x\|_1 \leq k$ mit linear vielen linearen Ungleichungen modellieren.

Naiv brauchte man exponentiell viele:

$$\sum_{i=1}^n \pm x_i \leq k.$$