

Kapitel 4 Dimensionsreduktion

§ 1 Hauptkomponentenanalyse (PCA)

PCA $\hat{=}$ principal component analysis

Gegeben: Dateneunkte $X = \begin{pmatrix} x^1 & x^2 & \dots & x^N \\ | & | & & | \\ | & | & & | \end{pmatrix} \in \mathbb{R}^{D \times N}$

Oft: D sehr groß.

Hoffnung: alle x^n liegen nahe zu einer niedrig-dimensionalen Mannigfaltigkeit, d. h. die Daten x^n haben Struktur.

einfaches Modell: alle x^n liegen nahe zu einem affinen Unterraum der Dimension M und $M \ll D$.

D.h.

$$x^n \approx c + \sum_{i=1}^M y_i^n b^i = \tilde{x}_n, \quad \text{wobei } b_1, \dots, b_M \in \mathbb{R}^D \text{ linear unabhängig.}$$

Ziel: Finde $c \in \mathbb{R}^D$, $Y = (y_i^n)_{i,n} \in \mathbb{R}^{M \times N}$, $B = \begin{bmatrix} b^1 & \dots & b^M \end{bmatrix} \in \mathbb{R}^{D \times M}$,

so dass

$$E[B, Y, c] = \sum_{n=1}^N \|x_n - \tilde{x}_n\|^2$$

minimal ist

Vereinfachung: Datenpunkte sind zentriert, d.h. es gilt

$$\frac{1}{N} \sum_{n=1}^N x^n = 0.$$

In diesem Fall kann man zeigen, dass $c=0$ sein muss
(→ Blatt 9).

Satz Ang. die Datenpunkte (x^n) sind zentriert.

Seien $\lambda_1, \dots, \lambda_D$ die Eigenwerte der Matrix $XX^T \in S_{\geq 0}^D$,
so sortiert, dass $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_D$ gilt. Sei

b_1, \dots, b_D eine Orthonormalbasis von \mathbb{R}^D bestehend aus
zugehörigen Eigenvektoren. Dann gilt

$$\min_{B, Y} E[B, Y] = \sum_{i=M+1}^D \lambda_i$$

und ein optimaler B ist $B = [b'_1 \dots b'_M]$ und $Y = B^T X$.

(Die Vektoren b_1, \dots, b_M heißen Hauptkomponenten des
Datensatz X .)

Bew.: Es gilt

$$E[B, Y] = \sum_{n=1}^N \|x^n - \tilde{x}^n\|^2 = \sum_{n=1}^N \sum_{i=1}^D (x_i^n - \tilde{x}_i^n)^2 = \dots$$

$$= \sum_{n=1}^N \sum_{i=1}^D \left(x_i^n - \sum_{j=1}^M y_j^n b_{ij}^j \right)^2$$

$$= \text{Tr} \left((X - BY)^T (X - BY) \right) \quad (*)$$

Wir können oBdA annehmen, dass B aus orthonormalen Vektoren besteht, d. h. dass $B^T B = \mathbb{I}_M$ gilt.

Für fixes B haben wir folgendes notwendiges Kriterium für die Optimalität von Y :

$$0 = \frac{\partial}{\partial y_{jk}^n} E[B, Y] = \frac{\partial}{\partial y_{jk}^n} \sum_{i=1}^D \left(x_i^n - \sum_{j=1}^M y_j^n b_{ij}^j \right)^2$$

$$= \sum_{i=1}^D \frac{\partial}{\partial y_{jk}^n} \left((x_i^n)^2 - 2x_i^n \sum_{j=1}^M y_j^n b_{ij}^j + \sum_{j, j'=1}^M y_j^n y_{j'}^n b_{ij}^j b_{ij'}^{j'} \right)$$

$$= \sum_{i=1}^D \left(-2x_i^n b_{ij}^j + 2 \sum_{j=1}^M y_j^n b_{ij}^j b_{ij}^j \right)$$

$$= -2 \sum_{i=1}^D x_i^n b_{ij}^j + 2 \sum_{j=1}^M y_j^n \underbrace{\sum_{i=1}^D b_{ij}^j b_{ij}^j}_{\delta_{jk}}$$

$$= -2 \sum_{i=1}^D x_i^n b_{ij}^j + 2 y_j^n$$

$$\Rightarrow \boxed{Y = B^T X} \quad (x, x)$$

Setze nun $(**)$ in $(*)$ ein:

$$\begin{aligned} E[B] &= \text{Tr} \left((X - BB^T X)^T (X - BB^T X) \right) \\ &= \text{Tr} \left((X^T - X^T BB^T) (X - BB^T X) \right) \\ &= \text{Tr} \left(X^T X - X^T BB^T X - X^T BB^T X \right. \\ &\quad \left. + \underbrace{X^T BB^T BB^T X}_{\frac{1}{n} I_n} \right) \\ &= \text{Tr} \left(X^T X - X^T BB^T X \right) \\ &= \text{Tr} \left(X^T (\mathbf{I} - BB^T) X \right) \\ &= \text{Tr} \left((\mathbf{I} - BB^T) X X^T \right) \\ &= \text{Tr} (X X^T) - \text{Tr} (BB^T X X^T) \rightarrow \min. \end{aligned}$$

D.R. $\text{Tr} (BB^T X X^T) \rightarrow \max.$, unter der Nebenbedingung $B^T B = \mathbf{I}$.

Aus der VL Konvexe Optimierung (Lecture 10)

Theorem (Fan)

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

Dann gilt

$$\begin{aligned} \lambda_1 + \dots + \lambda_k &= \max \left\{ \text{Tr} (C B B^T) : B \in \mathbb{R}^{n \times k}, B^T B = \mathbf{I}_k \right\} \\ &= \max \left\{ \text{Tr} (C Y) : Y \in S^n, \text{Tr} (Y) = k, Y \succeq 0, \right. \\ &\quad \left. \mathbf{I} - Y \succeq 0 \right\}. \end{aligned}$$

Wende dies auf $C = XX^T$ an. Dann

$$\begin{aligned} E[B] &= \text{Tr}(XX^T) - \text{Tr}(BB^TXX^T) \\ &= \sum_{i=1}^D \lambda_i - \sum_{i=1}^M \lambda_i = \sum_{i=M+1}^D \lambda_i. \end{aligned}$$

Dass B aus den zu $\lambda_1, \dots, \lambda_D$ gehörenden Eigenvektoren von XX^T besteht, folgt ebenfalls aus dem Beweis des Theorems von Fan. □

Bsp.: (für die Hauptkomponentenanalyse)

$X \in \mathbb{R}^{784 \times 892}$ Datenmatrix der handgeschriebenen 5 der MNIST-Datenbank

$N = 892$ Anzahl Beispiele

$D = 784 = 28 \times 28$ Pixel pro Buchstabe.



