

Vorlesung 19 PCA cont'd

Erinnerung: Wir haben Daten $z_1, \dots, z_n \in \mathbb{R}^M$ und $d < M$.

In PCA suchen wir einen linearen Raum $U \subset \mathbb{R}^M$ von Dim. d und $b \in \mathbb{R}^M$, s.d.

$$U + b \subset \mathbb{R}^M$$

"nah" an den Daten.

Unser erstes Konzept von "nah" war ein Raum von maximaler Varianz.

Dazu haben wir angenommen, dass z_1, \dots, z_n unabh. Samples eines ZV $z \in \mathbb{R}^M$. Dann war

$$U = \text{span}\{u_1, \dots, u_d\}, \quad b = \mu,$$

wobei $\mu = \mathbb{E}z$, u_1, \dots, u_d Eigenvektoren der Kovarianzmatrix Σ von z zu den größten Eigenwerten.

In der Praxis approximieren wir Σ durch die empirische Kovarianzmatrix S und μ durch den empirischen Mittelwert \bar{z} .


Bemerkung: u_1, \dots, u_d heißen Hauptkomponenten ("Principal Components")

Nun betrachten wir ein zweites Konzept von "nah".

Wir wählen U , s.d.

$$\text{(*)} \quad \sum_{i=1}^n \|(\bar{z} - \bar{z}) - P_U(z_i - \bar{z})\|^2$$

minimiert wird und $b = \bar{z}$.



Theorem 18.1

Seien $\lambda_1, \dots, \lambda_M \geq 0$ die Eigenwerte der emp. Kovarianzmatrix S .

Sei u_i Eigenvektor zu λ_i , s.d. $\langle u_i, u_j \rangle = \delta_{ij}$. Dann mindestens

$$U = \text{span}\{u_{d+1}, \dots, u_M\}$$

den Ausdruck in $(*)$. Falls $\lambda_d > \lambda_{d+1}$, ist U eindeutig bestimmt.

Beweis Sei u_{d+1}, \dots, u_M eine Orthonormal-Basis von \mathbb{R}^M , d.h. $\langle u_i, u_j \rangle = \delta_{ij}$.

Sei $w_i = z_i - \bar{z}$. Sei außerdem $A = [u_{d+1}, \dots, u_M] \in \mathbb{R}^{M \times d}$

und $W = [w_1, \dots, w_n] \in \mathbb{R}^{n \times M}$

Wir haben außerdem die Feature-Matrix $\Omega = [z_1, \dots, z_n]^T \in \mathbb{R}^{n \times M}$.

Dann gilt:

$$W = \Omega^T - \bar{z}e^T, \quad e = (1, \dots, 1) \in \mathbb{R}^n.$$

Dann gilt:

$$\begin{aligned} WW^T &= (\Omega^T - \bar{z}e^T)(\Omega^T - \bar{z}e^T)^T \\ &= nS. \end{aligned}$$

Außerdem: $AA^T = \sum_{i=1}^d u_i u_i^T$ und $1_M = \sum_{i=1}^M u_i u_i^T$

Dann gilt:

$$\begin{aligned} W - P_U W &= W - AA^T W \\ &= (1_M - AA^T) W \\ &= \left(\sum_{i=d+1}^M u_i u_i^T \right) W \end{aligned}$$

Außerdem, $W - P_U W = [w_1 - P_U(w_1), \dots, w_n - P_U(w_n)]$.

Es gilt:

$$\begin{aligned}
(x) &= \text{Trace} \left((\omega - P_{\text{lu}} \omega)^T (\omega - P_{\text{lu}} \omega) \right) \\
&= \text{Trace} \left(\omega^T \left(\sum_{i=d+1}^M u_i u_i^T \right) \left(\sum_{i=d+1}^M u_i u_i^T \right) \omega \right) \\
&= \text{Trace} \left(\omega^T \left(\sum_{i=d+1}^M u_i u_i^T \right) \omega \right), \quad \text{weil } \langle u_i, u_j \rangle = \delta_{ij} \\
&= \sum_{i=d+1}^M \text{Trace} (\omega^T u_i u_i^T \omega) \\
&= \sum_{i=d+1}^M \text{Trace} (u_i^T \omega \omega^T u_i) \\
&= n \cdot \sum_{i=d+1}^M u_i^T S u_i
\end{aligned}$$

Wie im Beweis von Thm. 18.4 erhalten wir:

u_{d+1}, \dots, u_M sind Eigenvektoren zu $\lambda_{d+1}, \dots, \lambda_M$.

Eindimensionalität folgt ebenfalls wie in Thm. 18.4. \square

In beiden Ansätzen müssen wir eine Eigenzerlegung von $S = \frac{1}{n} \omega \omega^T$ berechnen. Es ist $S \in \mathbb{R}^{M \times M}$. $\omega \in \mathbb{R}^{M \times n}$

Falls $n < M$, können wir wie folgt vorgehen. Wir nehmen an, dass $r(\omega) = n$. Dann sei

$$\omega = U D V^T$$

ein SVD von ω , d.h. $U \in \mathbb{R}^{M \times n}$, $D = \text{diag}(\sigma_1, \dots, \sigma_n)$, $V \in \mathbb{R}^{n \times n}$.

Dann gilt:

$$S = \frac{1}{n} \omega \omega^T = U D^2 U^T$$

und die Diagonaleinträge von D^2 = nicht-null Eigenwerte von S .

$$\text{Außerdem: } \mathbb{R}^{n \times n} \ni \omega^T \omega = V D^2 V^T$$

\Rightarrow eine Eigenzerlegung von $\frac{1}{n}W^T W$ gibt uns die gleichen Eigenwerte wie für S .

Außerdem $u_i = \frac{w_i}{\|w\|}$, so dass wir auch die Hauptkomponenten von S erhalten.

Insbesondere zeigt dies, dass PCA durch SVD verstanden werden kann.

Außerdem kann $W^T W$ durch die Kernel-Map $K(x_i, x_j) = \langle z_i, z_j \rangle = \langle \phi(x_i), \phi(x_j) \rangle$ berechnet werden.

Lemma 18.2

Sei $G = (K(x_i, x_j))_{i,j=1}^n$ für Daten $x_1, \dots, x_n \in \mathbb{R}^d$, $z_i = \phi(x_i)$.

Dann gilt für $W = [z_1 - \bar{z}, \dots, z_n - \bar{z}]$ wie oben, dass

$$W^T W = (1_n - \frac{1}{n}ee^T) G (1_n - \frac{1}{n}ee^T).$$

Beweis

Es ist $W = \Omega^T - \bar{z}e^T$ und $\bar{z} = \frac{1}{n}(z_1 + \dots + z_n) = \frac{1}{n}\Omega^T e$

$$\begin{aligned} \Rightarrow W^T W &= (\Omega^T - \frac{1}{n}\Omega^T ee^T)^T (\Omega^T - \frac{1}{n}\Omega^T ee^T) \\ &= (\Omega^T (1_n - \frac{1}{n}ee^T))^T (\Omega^T (1_n - \frac{1}{n}ee^T)) \\ &= (1_n - \frac{1}{n}ee^T) \Omega \Omega^T (1_n - \frac{1}{n}ee^T) \end{aligned}$$

Es ist: $\Omega = \begin{bmatrix} -z_1^T \\ \vdots \\ -z_n^T \end{bmatrix}$. D.h. $\Omega \Omega^T = (\langle z_i, z_j \rangle)_{i,j=1}^n = G$

$$\Rightarrow W^T W = (1_n - \frac{1}{n}ee^T) G (1_n - \frac{1}{n}ee^T).$$

□.

Als nächstes betrachten wir folgendes statistisches Setting für PCA.
Wir nehmen an, dass die Daten $x_1, x_n \in \mathbb{R}^D$ von folgender Zufallsvariable gesampled sind:

$$x = A\zeta + b + \varepsilon,$$


mit $A \in \mathbb{R}^{D \times d}$, $\zeta \sim N(0, I_d)$, $b \in \mathbb{R}^D$, $\varepsilon \sim N(0, \sigma^2 I_D)$.

In Folgenden arbeiten wir ohne Feature map.

D.h.

$$(x|\zeta) \sim N(A\zeta + b, \sigma^2 I_D).$$

Cartoon: $d=2, D=3$



Proposition 18.3

In obigen Setting haben wir

$$x \sim N(b, A A^T + \sigma^2 I_D).$$

Beweis

Es gilt, $P(x) = \int_{\mathbb{R}^d} P(x|\zeta) P(\zeta) d\zeta$

Es ist:

$$\log P(x|\zeta) + \log P(\zeta)$$

$$= -\frac{1}{2\sigma^2} \|x - (A\zeta + b)\|^2 - \frac{1}{2} \|\zeta\|^2 + C$$

$$= -\frac{1}{2} (x-\mu) \Sigma^{-1} (x-\mu) - \frac{1}{2} (\zeta-\nu) B^{-1} (\zeta-\nu) + C'$$

mit c, c' unabh. von x und ξ und $\mu \in \mathbb{R}^D$, $y \in \mathbb{R}^d$

$\Sigma \in \mathbb{R}^{D \times D}$, $B \in \mathbb{R}^{d \times d}$ und μ und Σ unabh. von ξ .

D.h., nachdem wir ξ aus integriert haben, bleibt ein Ausdruck der Form $e^{-\frac{1}{2}(x-\mu)^\top \Sigma^{-1}(x-\mu)} \frac{1}{\sqrt{(2\pi)^d \det(\Sigma)}}$.

$$\leadsto x \sim N(\mu, \Sigma).$$

$$\text{Es ist } \mu = \mathbb{E}_x x = \mathbb{E}_{\xi, \varepsilon} (A\xi + b + \varepsilon) = b$$

$$\Sigma = \mathbb{E}_x (x - b)(x - b)^\top$$

$$= \mathbb{E}_{\xi, \varepsilon} (A\xi + b + \varepsilon - b)(A\xi + b + \varepsilon - b)^\top$$

$$= \mathbb{E}_{\xi, \varepsilon} (A\xi + \varepsilon)(A\xi + \varepsilon)^\top$$

$$= \mathbb{E}_{\xi, \varepsilon} (A\xi \xi^\top A^\top + A\xi \varepsilon^\top + \varepsilon \xi^\top A^\top + \varepsilon \varepsilon^\top)$$

$$= \mathbb{E}_{\xi, \varepsilon} (A\xi \xi^\top A^\top + \varepsilon \varepsilon^\top).$$

$$= A \mathbb{E} \xi \xi^\top A^\top + \mathbb{E} \varepsilon \varepsilon^\top$$

$$= A A^\top + \sigma^2 I_D.$$

□.

Korollar 18.4

Annehmen wir haben den Prior $\xi \sim N(y, B)$. Dann erhalten wir

$$x \sim N(Ay + b, ABA^\top + \sigma^2 I_D).$$

Beweis

Es ist $\xi = R\xi' + \gamma$ mit $\xi' \sim N(0, I_D)$, und $RR^\top = B$.

Daher:

$$x = A\xi + b = AR\xi' + Ar + b.$$

Wir wenden Thm. 18.3 mit AR und $Ay + b$ an. □.

Mit Hilfe von Kor. 18.4 können wir jetzt MLE für die Parameter A, b bestimmen. Wir können auch die Verteilung von $(\boldsymbol{\eta} | \mathbf{x})$ ausrechnen, um den Prior von $\boldsymbol{\gamma}$ nach Sicht von \mathbf{x} anzupassen.

Theorem 18.5

Sei $\boldsymbol{\gamma} \sim N(\boldsymbol{\nu}, \mathbf{B})$ und $(\mathbf{x} | \boldsymbol{\gamma}) \sim N(A\boldsymbol{\gamma} + \mathbf{b}, \sigma^2 \mathbf{I}_D)$.

Dann gilt: $(\boldsymbol{\eta} | \mathbf{x}) \sim N(\mathbf{m}, \mathbf{C})$.

mit $\mathbf{C} = (\sigma^{-2} A^\top A + \mathbf{B}^{-1})^{-1}$ und $\mathbf{m} = \mathbf{C}(\sigma^{-2} A^\top (\mathbf{x} - \mathbf{b}) + \mathbf{B}^{-1} \boldsymbol{\nu})$

Beweis

Es gilt, nach Bayes' Theorem:

$$\log P(\boldsymbol{\eta} | \mathbf{x}) = \log P(\mathbf{x} | \boldsymbol{\eta}) + \log P(\boldsymbol{\eta}) + c$$

mit c unabh. von $\boldsymbol{\eta}$ und \mathbf{x} .

Es ist $(\mathbf{x} | \boldsymbol{\eta}) \sim N(A\boldsymbol{\eta} + \mathbf{b}, \sigma^2 \mathbf{I}_D)$ und $\boldsymbol{\eta} \sim N(\boldsymbol{\nu}, \mathbf{B})$, s.d.

$$\log P(\boldsymbol{\eta} | \mathbf{x}) = -\frac{1}{2\sigma^2} \|\mathbf{x} - (A\boldsymbol{\eta} + \mathbf{b})\|^2 - \frac{1}{2}(\boldsymbol{\eta} - \boldsymbol{\nu})^\top \mathbf{B}^{-1}(\boldsymbol{\eta} - \boldsymbol{\nu}) + c''$$

mit c'' unabh. von \mathbf{x} und $\boldsymbol{\eta}$.

$$= -\frac{1}{2\sigma^2} \|A\boldsymbol{\eta} - (\mathbf{x} - \mathbf{b})\|^2 - \frac{1}{2}(\boldsymbol{\eta} - \boldsymbol{\nu})^\top \mathbf{B}^{-1}(\boldsymbol{\eta} - \boldsymbol{\nu}).$$

Das wollen wir nun nach $\boldsymbol{\eta}$ auflösen. Wir gehen wie in Thm 14.2 vor und erhalten die Formeln für \mathbf{m} und \mathbf{C} . \square