

**Maschinelles Lernen und Data Mining**  
Sommersemester 2008  
**Übungsblatt 8**

*Besprechung des Übungsblattes am 10.07.2008*

**Aufgabe 8-1**    PCA  
*schriftlich*

- Beschreiben Sie, unter welchen Umständen eine PCA sinnvoll ist bzw. welchen Zweck die PCA verfolgt.
- Welche möglichen negativen Auswirkungen nehmen Sie in Kauf, wenn Sie die PCA auf einen Datensatz unbekannter Struktur verwenden?

**Aufgabe 8-2**    PCA  
*schriftlich*

Eine PCA besteht im wesentlichen aus:

Mittelwertbereinigung der Daten, Kovarianzmatrix  $E[(X - E(X)) \cdot (X - E(X))^T]$  berechnen, Eigenwerte und Eigenvektoren berechnen, Entfernen der Eigenvektoren mit kleinem Einfluss, Transformation der Eingangsdaten.

Gegeben eine normalverteilte Zufallsvariable

$$X \sim N(\mu, \Sigma), \quad \mu = \begin{pmatrix} 0 \\ 3 \end{pmatrix}, \quad \Sigma = \begin{pmatrix} 2 & 0 \\ 0 & 1 \end{pmatrix}$$

wobei  $\Sigma$  die Kovarianzmatrix der mittelwertbereinigten Daten, und  $X$  die 2dimensionale Designmatrix darstellt.

- Berechnen Sie die Hauptkomponenten von  $\Sigma$  sowie die zugehörigen Eigenwerte und beschreiben Sie, welche Hauptkomponente bei einer Dimensionsreduktion entfallen würde.
- Berechnen Sie nun die Hauptkomponenten und Eigenwerte der unzentrierten Kovarianzmatrix  $E(XX^T)$  und vergleichen Sie das Ergebnis mit dem Ergebnis aus Teilaufgabe (a)  
Verwenden Sie dazu:  $X = (X - \mu) + \mu$  mit  $E(X - \mu) = 0$

**Anmerkungen:**

Ist eine Zufallsvariable  $X \sim N(0, \Sigma)$  verteilt, gilt  $E(XX^T) = \Sigma$ .

Der Erwartungswert  $E$  ist linear. D.h. es gilt:

$$E(aX + Y) = a \cdot E(x) + E(Y)$$

Damit gilt auch  $E(MX) = ME(X)$ , wenn  $M$  keine Zufallsvariable ist. Andernfalls gilt  $E(MX) = E(M)E(X)$ , wenn  $X$  und  $M$  voneinander unabhängig sind.

Eigenwerte und Eigenvektoren können mit gängigen Softwarepaketen (R, Octave, Maple) einfach berechnet werden, dürfen aber natürlich auch von Hand berechnet werden.

**Aufgabe 8-3**    PCA  
*schriftlich*

Gegeben ist die folgende Designmatrix X:

1	2	3	4	5	6
1	1	1	5	5	5

Führen Sie eine PCA auf den gegebenen Daten durch.

Geben Sie dabei die Eigenvektoren, Eigenwerte und die Kovarianzmatrix an und visualisieren Sie die Daten vor und nach der PCA.