

Universität Potsdam
Institut für Informatik
Lehrstuhl Maschinelles Lernen



Maschinelles Lernen II

PCA

Christoph Sawade/Niels Landwehr
Tobias Scheffer

Überblick

- Principal Component Analysis
 - ◆ Optimierungsproblem
 - ◆ Adaption für hochdimensionale Daten
 - ◆ Kernel-PCA


PCA

Motivation


- Datenkompression
- Preprocessing (Feature Selection / Noisy Feature)
- Datenvisualisierung

PCA

Beispiel



- Repräsentation von Digits als $m \times m$ -Pixelmatrix
 - ◆ Viele Feature
 - ★ sind aussageelos
 - ★ ergeben sich aus anderen (weniger Freiheitsgrade)
- Ziel: Reduktion auf d -dimensionalen Hauptunterraum




PCA

Beispiel




- Repräsentation von Gesichtern als $m \times m$ -Pixelmatrix
 - ◆ Viele Feature
 - ★ sind aussageelos
 - ★ ergeben sich aus anderen (weniger Freiheitsgrade)
- Ziel: Reduktion auf d -dimensionalen Hauptunterraum



PCA

Projektion

- Eine Projektion ist eine idempotente lineare Abbildung




PCA

Projektion

- Eine Projektion ist eine idempotente lineare Abbildung

- Sei $\mathbf{u}_1 \in \mathbb{R}^m$ mit $\mathbf{u}_1^T \mathbf{u}_1 = 1$
- $y_1(\mathbf{x}) = \mathbf{u}_1^T \mathbf{x}$ stellt Projektion in einen eindimensionalen Unterraum dar



- Für Daten im Projektionsraum gilt:
 - ◆ Mittelpunkt: $y_1(\bar{\mathbf{x}}) = \mathbf{u}_1^T \bar{\mathbf{x}}$

- ◆ Varianz: $\frac{1}{n} \sum_{i=1}^n \left(\mathbf{u}_1^T \mathbf{x}_i - \mathbf{u}_1^T \bar{\mathbf{x}} \right)^2 = \mathbf{u}_1^T \Sigma \mathbf{u}_1$

PCA

Optimierungsproblem

- Ziel: Varianz der projizierten Daten $u_1^T \Sigma u_1$ soll nicht verloren gehen
- Maximiere $u_1^T \Sigma u_1$ bzgl. u_1 , wobei $u_1^T u_1 = 1$
 - ◆ Lagrangian: $u_1^T \Sigma u_1 + \lambda_1 (1 - u_1^T u_1)$

PCA

Optimierungsproblem

- Ziel: Varianz der projizierten Daten $u_1^T \Sigma u_1$ soll nicht verloren gehen
- Maximiere $u_1^T \Sigma u_1$ bzgl. u_1 , wobei $u_1^T u_1 = 1$
 - ◆ Lagrangian: $u_1^T \Sigma u_1 + \lambda_1 (1 - u_1^T u_1)$
- Ableiten, Nullsetzen:
 - ◆ $\Sigma u_1 = \lambda_1 u_1 \dots$ Lösung muss Eigenvektor sein
 - ◆ $u_1^T \Sigma u_1 = \lambda_1 \dots$ Varianz ist entsprechender Eigenwert
 - Bestimmung des größten Eigenwert
- Größter Eigenvektor ist erste Hauptkomponente

PCA

- Projektion von \mathbf{x} in den Eigenraum

$$y_1(\mathbf{x}) = \mathbf{u}_1^T \mathbf{x} \quad \longrightarrow \quad \mathbf{y}(\mathbf{x}) = \mathbf{U}^T \mathbf{x} \quad \text{mit} \quad \mathbf{U} = \begin{pmatrix} - & \mathbf{u}_1 & - \\ & \vdots & \\ - & \mathbf{u}_d & - \end{pmatrix}$$

- Größter Eigenvektor ist erste Hauptkomponente
- Folgende Hauptkomponenten sind orthogonale Richtungen die (Rest-) Varianz maximieren
- d Hauptkomponenten... Vektoren der d größten Eigenwerte

PCA

Rückprojektion

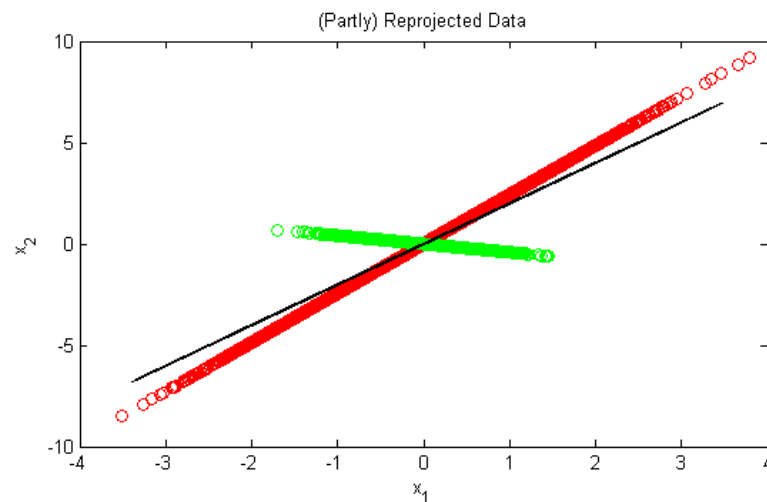
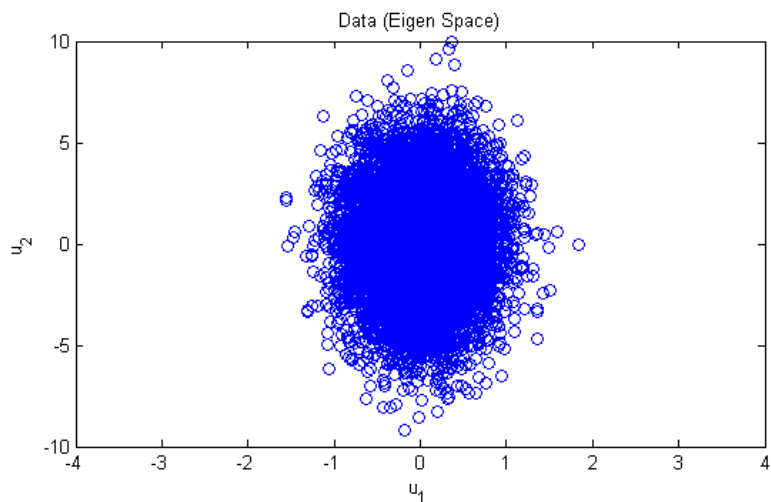
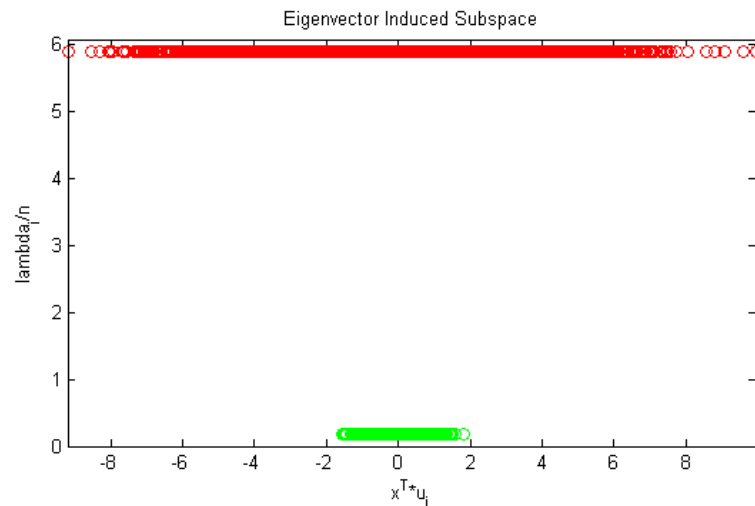
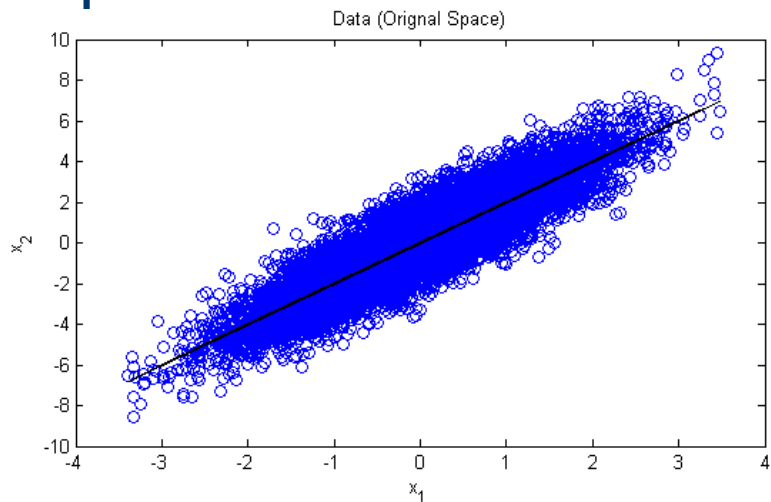
- Beobachtung:

$$\mathbf{x}_i = \sum_{j=1}^n (\mathbf{x}_i^T \mathbf{u}_j) \mathbf{u}_j \quad (\mathbf{X}^T = \mathbf{X}^T \mathbf{U} \mathbf{U})$$

- Reduktion auf d Hauptkomponenten:

$$\mathbf{x}_i = \sum_{j=1}^d (\mathbf{x}_i^T \mathbf{u}_j) \mathbf{u}_j \quad (\mathbf{X}^T = \mathbf{X}^T \mathbf{V} \mathbf{V}, \forall k \geq d: \mathbf{v}_k = \mathbf{0}^T)$$

PCA Beispiel



PCA

hochdimensionale Daten

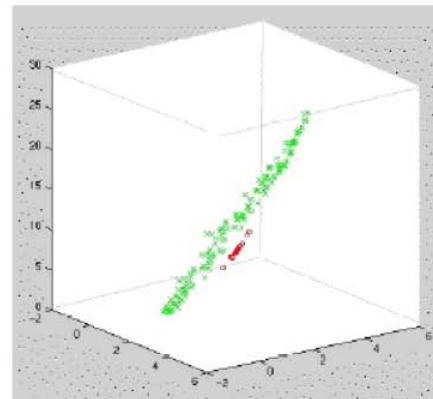

- Berechnung von d Eigenvektoren für m -dimensionale Daten ist $\mathcal{O}(dm^2)$
 - ◆ Nicht berechenbar für große m
- Idee: Beispiele spannen einen linearen Unterraum mit höchstens $n-1$ Dimensionen auf
- Sei $\bar{\mathbf{x}} = 0$, dann gilt mit Hilfe der Datenmatrix $\mathbf{X} \in \mathbb{R}^{n \times m}$

$$\Sigma \mathbf{u}_1 = \lambda_1 \mathbf{u}_1 \quad \longrightarrow \quad \underbrace{(\mathbf{n}^{-1} \mathbf{X} \mathbf{X}^T) \mathbf{v}_1 = \lambda_1 \mathbf{v}_1, \quad \mathbf{v}_1 = \mathbf{X} \mathbf{u}_1}_{\text{Eigenwertproblem}}$$


- Berechnung in $\mathcal{O}(dn^2)$
- Lösung hat gleiche $n-1$ Eigenwerte $\mathbf{u}_i = (\mathbf{n} \lambda_i)^{-1/2} \mathbf{X}^T \mathbf{v}_i$
 - ◆ bis auf Eigenwerte 0

Kernel-PCA

- Im Merkmalsraum nichtlineare Dimensionen.



$$\Phi : \mathcal{X} = \mathbb{R}^2 \rightarrow \mathcal{H} = \mathbb{R}^3$$
$$(x_1, x_2) \mapsto (x_1, x_2, x_1^2 + x_2^2)$$





- Voraussetzung: Daten gehen nur als inneres Produkt ein

Kernel-PCA

Wiederholung: Kerne

- Lineare Klassifikatoren:
 - ◆ Oft adäquat, aber nicht immer.
- Idee: Beispiele in anderen Raum abbilden, in dem sie linear klassifizierbar sind.
- Abbildung
 - ◆ $\mathbf{x} \mapsto \phi(\mathbf{x})$
- Zugehöriger Kernel
 - ◆ $k(\mathbf{x}_i, \mathbf{x}_j) = \phi(\mathbf{x}_i)^T \phi(\mathbf{x}_j)$
- Kernel = Inneres Produkt = Ähnlichkeit der Beispiele.



Kernel-PCA

- Für $\sum_{i=1}^n \phi(\mathbf{x}_i) = 0$, lässt sich Eigenvektorproblem äquivalent umformen:

$$\Sigma \mathbf{u}_i = \lambda_i \mathbf{u}_i \quad \longrightarrow \quad \mathbf{K} \boldsymbol{\alpha}_i = \lambda_i \mathbf{n} \boldsymbol{\alpha}_i$$

- Projektion: $y_i(\mathbf{x}) = \phi(\mathbf{x})^T \mathbf{v}_i = \sum_{j=1}^n \alpha_{i,j} k(\mathbf{x}, \mathbf{x}_j)$

Zusammenfassung

- Ziel: Reduktion / Kompression von Daten auf wesentliche Komponenten
- Maximierung der Varianz führt zu Eigenwertproblem
- Hoch für hochdimensionale anwendbar
- Nicht-lineare Varianzkomponenten: Kernel-PCA
- Klassenabhängige Varianzminimierung führt zur Kernel Fisher Diskriminante