

Unüberwachtes Lernen

Mustererkennung und Klassifikation, Vorlesung No. 12

M. O. Franz

17.01.2008


Übersicht

- 1 Hauptkomponentenanalyse
- 2 Nichtlineare Hauptkomponentenanalyse
- 3 K-Means-Clustering

Übersicht

- 1 Hauptkomponentenanalyse
- 2 Nichtlineare Hauptkomponentenanalyse
- 3 K-Means-Clustering

Unüberwachtes Lernen




Bei **unüberwachten** Lernproblemen ist die Klassenzugehörigkeit der Trainingsbeispiele unbekannt.

Anwendungsfälle:

- **Clusteranalyse:** Die Daten werden aufgrund bestimmter Kriterien (z.B. räumliche Nähe) in Klassen zusammengefaßt.
- **Dimensionsreduktion:** Suche nach niedrigdimensionalen Repräsentationen der Daten zur Interpretation oder für Lernaufgaben.

Hauptkomponentenanalyse



In der **Hauptkomponentenanalyse** wird nach Richtungen in den Daten gesucht, entlang derer die Daten extremale (d.h. maximale oder minimale) Varianz haben.

Anwendung: Dimensionsreduktion durch Weglassen der Richtungen mit der kleinsten Varianz.

Annahme: die Daten seien **zentriert**, d.h. der Schwerpunkt

$$m = \frac{1}{n} \sum_i x_i$$

liegt am Ursprung.

Varianz entlang einer Raumrichtung

Gesucht sind Richtungen mit extremaler Varianz. Eine beliebige Richtung im \mathbb{R}^d wird durch einen Einheitsvektor q dargestellt, auf die Datenpunkte x **projiziert** werden:

$$A = x^\top q = q^\top x \quad \text{mit} \quad \|q\| = \sqrt{q^\top q} = 1$$

Wir nehmen an, daß die Datenpunkte durch eine vektorwertige Zufallsvariable mit Erwartungswert $E[x] = 0$ erzeugt werden. Damit ist auch die Projektion A auf q eine Zufallsvariable mit

$$E[A] = q^\top E[x] = 0$$

Varianz in Richtung q :

$$\begin{aligned} \sigma^2(q) &= E[A^2] - E[A]^2 \\ &= E[(q^\top x)(x^\top q)] - 0 \\ &= q^\top E[xx^\top]q \\ &= q^\top Rq \quad \text{mit Korrelationsmatrix } R = E[xx^\top] \end{aligned}$$

Raumrichtungen extremer Varianz als Eigenwertproblem

An Richtungen extremer Varianz ist die Ableitung von $\sigma^2(q) = 0$, d.h. bei einer infinitesimalen Richtungsänderung δq gilt

$$\sigma^2(q + \delta q) = \sigma^2(q) + O(\delta q^2)$$

Mit Hilfe von $\sigma^2 = q^\top R q$ ergibt sich

$$\sigma^2(q + \delta q) = (q + \delta q)^\top R (q + \delta q) = q^\top R q + 2(\delta q)^\top R q + O(\delta q^2)$$

$$\text{und } \sigma^2(q + \delta q) = \sigma^2(q) + 2(\delta q)^\top R q$$

Damit beide Gleichungen gültig sind, muß $(\delta q)^\top R q = 0$ sein.

Weiterhin gilt $\|q + \delta q\| = 1$, d.h. $(q + \delta q)^\top (q + \delta q) = 1$ damit muß auch hier $(\delta q)^\top q = 0$ sein. Zusammen ergibt sich

$$(\delta q)^\top R q + \lambda (\delta q)^\top q = 0 \quad \text{bzw.} \quad (\delta q)^\top (R q - \lambda q) = 0$$

und damit die **Eigenwertgleichung**

$$R q = \lambda q \quad \text{mit} \quad \lambda = \sigma^2(q)$$

Hauptkomponenten

Die Lösungen der Eigenwertgleichung der Korrelationsmatrix R

$$Rq = \lambda q$$

sind also die Richtungen extremaler Varianz, die Eigenwerte geben die Varianz der Daten entlang dieser Richtungen an.

Die Eigenwertgleichung hat i.A. d verschiedene, zueinander orthogonale Richtungen q_i als Lösung. Diese Richtungsvektoren werden als neue Basis im \mathbb{R}^d gewählt. Die Projektionen eines Datenpunktes auf die q_i

$$a_i = q_i^\top x = x^\top q_i$$

heißen die **Hauptkomponenten** von x .


Die Darstellung eines Datenpunktes in diesem neuen Koordinatensystem entspricht also einer **Rotation**, nach der die Koordinatenachsen entlang der Richtungen extremaler Varianz zeigen.

Dimensionsreduktion


Prinzip: es werden nur die l Basisvektoren mit der größten Varianz beibehalten, Richtungen kleinerer Varianz werden verworfen. Der resultierende Vektor in \mathbb{R}^l ist

$$\hat{x} = \sum_{i=1}^l a_i q_i \quad \text{mit} \quad a_i = q_i^\top x.$$


Man kann zeigen, daß die so gewählte Basis den **kleinsten Rekonstruktionsfehler unter allen Basen von \mathbb{R}^l** hat (s. Haykin, 99).



2D-Beispiel





Beispiel: Eigengesichter



Übersicht

- 1 Hauptkomponentenanalyse
- 2 Nichtlineare Hauptkomponentenanalyse**
- 3 K-Means-Clustering

Hauptkomponentenanalyse auf 3 Clustern




Dimensionsreduktion mit linearen Methoden

Die Hauptkomponentenanalyse ist eine **lineare** Methode. Sie beschreibt **Unterräume** mit besonders hoher bzw. niedriger Varianz.

- Die Basisvektoren q_i dieser Unterräume sind Linearkombinationen der Trainingsdatenpunkte, d.h. lineare Superpositionen dieser Daten (s. z.B. Eigengesichter). Für Bilder führen solche Repräsentationen oft zu unerwünschten Artefakten (Geisterbilder).
- Oft befinden sich die Daten auf niedrigdimensionalen Untermannigfaltigkeiten, die keinem Unterraum entsprechen, sondern gekrümmten Hyperflächen.
- Die Hauptkomponentenanalyse fängt nur paarweise Korrelationen ein, keine komplexeren statistischen Abhängigkeiten.

Für solche Probleme müssen **nichtlineare Methoden zur Dimensionsreduktion** eingesetzt werden.

Nichtlineare Hauptkomponentenanalyse (1)




Grundidee: Nichtlineare Transformation der Daten in einen (oft höherdimensionalen) Merkmalsraum.

Hier: gleicher Ansatz wie bei nichtlinearer Klassifikation, d.h. wir (1) definieren eine Basis aus m nichtlinearen Funktionen $\varphi(x)$, (2) bilden darüber die Daten nichtlinear in einen erweiterten Merkmalsraum \mathbb{R}^m ab und machen (3) dort eine Hauptkomponentenanalyse.

Nichtlineare Hauptkomponentenanalyse (2)

Analog zur Klassifikation werden die Basisfunktionen in einen erweiterten Merkmalsvektor geschrieben, z.B für eine Basis aus

RBFs $\varphi_i(x) = e^{-\frac{\|x-x_i\|^2}{2}}$









ergibt sich dann eine Korrelationsmatrix

$$R = E[\Phi(x)\Phi(x)^\top] = \frac{1}{n} \sum_{i=1}^n \Phi(x_i)\Phi(x_i)^\top,$$

deren Eigenwertzerlegung eine nichtlineare Hauptkomponentenanalyse im \mathbb{R}^n darstellt.

Nichtlineare Hauptkomponentenanalyse auf 3 Clustern




Übersicht

- 1 Hauptkomponentenanalyse
- 2 Nichtlineare Hauptkomponentenanalyse
- 3 K-Means-Clustering**

Clustering

Situation:

Eine Menge von Objekten und ein Ähnlichkeitsmaß zwischen diesen Objekten. Die Objekte seien als Punkte in einem Raum darstellbar, ihre Ähnlichkeiten als Distanzen.



Clustern:

geg. eine Punktmenge, partitioniere sie so in *Cluster*, daß sich Punkte im selben Cluster nahe sind, Punkte in verschiedenen Clustern weit auseinanderliegen.

- Hierarchisches Clustern
- Zentroidbasiertes Clustern
- Single-Linkage Clustering
- Probabilistische generative Modelle
- ...

K-Means-Clustering

- 1 Initialisierung: geg. Datenpunkte $x_n, n = 1 \dots N$, setze K **Prototypen** auf Zufallswerte $m_k^{(0)}$
- 2 Zuweisungsschritt: weise jedem Datenpunkt x_n den nächsten Prototyp \hat{k}_n zu, d.h.

$$\hat{k}_n = \operatorname{argmin}_k \|x_n - m_k\|^2$$


- 3 Anpassungsschritt: Setze m_k auf den Mittelwert der ihm zugewiesenen Datenpunkte

$$m_k = \frac{\sum_n r_{kn} x_n}{\sum_n r_{kn}}$$

mit dem **Indikator** $r_{kn} = 1$ wenn $k = \hat{k}_n$, sonst $r_{kn} = 0$.

- 4 Wiederhole Zuweisungs- und Anpassungsschritt, bis sich die Zuordnung nicht mehr ändert.

Beispiel: K-means auf 2D-Daten



Run 1









Figure 20.4. K-means algorithm applied to a data set of 40 points. Two separate runs, both with $K = 4$ means, reach different solutions. Each frame shows a successive assignment step.

Run 2



Problematische Fälle



[McKay 2003]

Probleme bei K-Means

Ad-hoc-Merkmale

- Anzahl der Prototypen steht von vornherein fest.
- Wie soll im Falle von mehreren möglichen Clusterzuteilungen entschieden werden?
- Warum ist gerade der Mittelwert ein guter Repräsentant für den Cluster?
- Gibt es bessere Distanzfunktionen?

Algorithmische Probleme

- Nur die Distanz zählt, nicht die Clustergröße.
- Keine Repräsentation der Clusterform
- Sog. **harte Zuweisung**: jeder Punkt trägt nur zu einem Cluster bei und hat dort dasselbe Gewicht.

Soft K-Means

- 1 Initialisierung: geg. Datenpunkte $x_n, n = 1 \dots N$, setze K Prototypen auf Zufallswerte $m_k^{(0)}$
- 2 Zuweisungsschritt: Jeder Datenpunkt x_n erhält eine "weiche" Zuweisung zu **allen** Prototypen über die Indikatorfunktion

$$r_{kn} = \frac{\exp(-\beta \|m_k - x_n\|)}{\sum_i \exp(-\beta \|m_i - x_n\|)} \quad \text{mit} \quad \sum_k r_{kn} = 1$$

β beschreibt die Reichweite der Prototypen.

- 3 Anpassungsschritt: Setze m_k auf den Mittelwert der ihm zugewiesenen Datenpunkte

$$m_k = \frac{\sum_n r_{kn} x_n}{\sum_n r_{kn}}$$

- 4 Wiederhole Zuweisungs- und Anpassungsschritt, bis sich die Zuordnung nicht mehr ändert.

Beispiel: Soft K-Means example auf 2D-Daten

