

Skript zur Vorlesung
Knowledge Discovery in Databases
im Wintersemester 2007/2008

Kapitel 2: Merkmalsräume

Skript © 2003 Johannes Abfalg, Christian Böhm, Karsten Borgwardt, Martin Ester,
Eshref Januzaj, Karin Kailing, Peer Kröger, Jörg Sander und Matthias Schubert



<http://www.dbs.ifi.lmu.de/Lehre/KDD>

Merkmalsräume

- Motivation:

- Zentrales Konzept beim Data Mining: Ähnlichkeit von Datenbankobjekten
 - Clustering: Zusammenfassen *ähnlicher* Objekte in Gruppen
 - Klassifikation: Zuordnung von Objekten zu einer Klasse *ähnlicher* Objekte
- Definition einer geeigneten Distanzfunktion auf Datenbankobjekten nicht immer einfach (besonders in Nicht-Standard-Datenbanken)

- Bilder
- CAD-Objekte
- Proteine
- Textdokumente
- Polygonzüge (GIS)
- etc.




Merkmale

Merkmale („Features“ von Objekten)

- Oft sind die betrachteten Objekte komplex
- Eine Aufgabe des KDD-Experten ist dann, geeignete Merkmale (*Features*) zu definieren bzw. auszuwählen, die für die Unterscheidung (Klassifikation, Ähnlichkeit) der Objekte relevant sind.


Beispiel: CAD-Zeichnungen:



Mögliche Merkmale:

Merkmale


Beispiel: CAD-Zeichnungen (cont.)




- Im Kontext von statistischen Betrachtungen werden die Merkmale häufig auch als *Variablen* bezeichnet
- Die ausgewählten Merkmale werden zu Merkmals-Vektoren (*Feature Vector*) zusammengefasst
- Der Merkmalsraum ist häufig hochdimensional (im Beispiel 5-dim.)

Merkmale

Bilddatenbanken:
Farbhistogramme



Gen-Datenbanken:
Expressionslevel



Text-Datenbanken:
Begriffs-Häufigkeiten



| | |
|---------|----|
| Data | 25 |
| Mining | 15 |
| Feature | 12 |
| Object | 7 |
| ... | |

Der Feature-Ansatz ermöglicht einheitliche Behandlung von Objekten verschiedenster Anwendungsklassen

28

Merkmale

Skalen-Niveaus von Merkmalen

Nominal (kategorisch)

Charakteristik:

Nur feststellbar, ob der Wert gleich oder verschieden ist. Keine Richtung (besser, schlechter) und kein Abstand. Merkmale mit nur zwei Werten nennt man *dichotom*

Beispiele:

Geschlecht (dichotom)
Augenfarbe
Gesund/krank (dichotom)

Ordinal

Charakteristik:

Es existiert eine Ordnungsrelation (besser/schlechter) zwischen den Kategorien, aber kein einheitlicher Abstand

Beispiele:

Schulnote (metrisch?)
Gütekategorie
Altersklasse

Metrisch

Charakteristik:

Sowohl Differenzen als auch Verhältnisse zwischen den Werten sind aussagekräftig. Die Werte können diskret oder stetig sein.

Beispiele:


Gewicht (stetig)
Verkaufszahl (diskret)
Alter (stetig oder diskret)

29

Univariate Deskription von Merkmalen

Sei x_1, \dots, x_n eine Stichprobe eines Merkmals X .

- **Absolute Häufigkeit:** Für jeden Wert a ist $h(a)$ die Anzahl des Auftretens in der Stichprobe
- **Relative Häufigkeit:** $f(a) = h(a) / n$



Die folgenden Maße sind nur für metrische Merkmale sinnvoll:

- **Arithmetisches Mittel:** $\mu = \frac{1}{n} \cdot \sum_{i=1}^n x_i$
- **Median:** *Das mittlere Element bei aufst. Sortierung*
- **Varianz:** $VAR(X) = \frac{1}{n} \cdot \sum_{i=1}^n (x_i - \bar{x})^2$
- **Standardabweichung:** $\sigma = \sqrt{\frac{1}{n} \cdot \sum_{i=1}^n (x_i - \bar{x})^2}$

Multivariate Deskription von Merkmalen

• Kontingenztabelle

- für kategoriale Merkmale X und Y
- repräsentiert für zwei Merkmale X und Y die absolute Häufigkeit h_{ik} jeder Kombination (x_i, y_k) und alle Randhäufigkeiten $h_{.k}$ und $h_{i.}$ von X und Y

| | Mittelfristige Arbeitslosigkeit | Langfristige Arbeitslosigkeit | |
|------------------|---------------------------------|-------------------------------|-----|
| Keine Ausbildung | 19 | 18 | 37 |
| Lehre | 43 | 20 | 63 |
| | 62 | 38 | 100 |

- Wie sollten die relativen Häufigkeiten verteilt sein, wenn die beiden Merkmale keinerlei Abhängigkeit besitzen?

$$\frac{h_{ik}}{n} = \frac{h_{i.}}{n} \cdot \frac{h_{.k}}{n}$$

- χ^2 -Koeffizient

Differenz zwischen dem bei Unabhängigkeit erwarteten und dem tatsächlich beobachteten Wert von h_{ij} (Maß für die Stärke der Abhängigkeit)





Multivariate Deskription von Merkmalen

Korrelationskoeffizient

- für numerische Merkmale X und Y
- wie stark sind die Abweichungen vom jeweiligen Mittelwert korreliert?

$$r_{XY} = \frac{\sum_{i=1}^n (x_i - \bar{x}) \cdot (y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \cdot \sum_{i=1}^n (y_i - \bar{y})^2}}$$

- Beispiele



Räume und Distanzfunktionen

- Merkmalsraum (Featureraum)

- Intuitiv: ein Wertebereich/Domain mit Distanzfunktion

- Formal: Featureraum $\mathbf{F} = (Dom, dist)$

Dom ist eine (geordnete) Menge von Merkmalen (Features)

$dist : Dom \times Dom \rightarrow \mathbb{R}$ ist eine totale (Distanz)-Funktion mit den folgenden Eigenschaften

- $\forall p, q \in Dom, p \neq q : dist(p, q) > 0$
 - $\forall o \in Dom : dist(o, o) = 0$
 - $\forall p, q \in Dom : dist(p, q) = dist(q, p)$
- } Reflexivität
- Symmetrie

Räume und Distanzfunktionen

- **Metrischer Raum**
 - Formal: Metrischer Raum $\mathbf{M} = (Dom, dist)$ mit den folgenden Eigenschaften
 - \mathbf{M} ist ein Featureerraum
 - $\forall o, p, q \in Dom : dist(o, p) \leq dist(o, q) + dist(q, p)$ Dreiecksungleichung
- **Wichtigstes Beispiel: Euklidischer Vektorraum**
 - Formal: Euklidischer Vektorraum $\mathbf{E} = (Dom, dist)$ mit
 - $(Dom, dist)$ ist ein metrischer Raum
 - $Dom = \mathbb{R}^d$
- **Sprechweise:**
 - Euklidischer Vektorraum = „Featureerraum“
 - Vektoren (Objekte im Eulidischen Featureerraum) = „Featurevektoren“
 - Die d Dimensionen des Vektorraums = „Features“


34

Räume und Distanzfunktionen

- **Ähnlichkeit von Feature Vektoren (Euklidische Vektoren)**

Euklidische Norm (L_2):


$$dist_1 = ((p_1 - q_1)^2 + (p_2 - q_2)^2 + \dots)^{1/2}$$



Natürlichstes Distanzmaß

Manhattan-Norm (L_1):


$$dist_2 = |p_1 - q_1| + |p_2 - q_2| + \dots$$



Die Unähnlichkeiten der einzelnen Merkmale werden direkt addiert

Maximums-Norm (L_∞):

$$dist_\infty = \max \{|p_1 - q_1|, |p_2 - q_2|, \dots\}$$




Die Unähnlichkeit des am wenigsten ähnlichen Merkmals zählt

Verallgemeinerung L_p -Abstandsmaß: $dist_p = (|p_1 - q_1|^p + |p_2 - q_2|^p + \dots)^{1/p}$

35


Räume und Distanzfunktionen

Gewichtete Euklidische Norm:
 $dist = (w_1(p_1 - q_1)^2 + w_2(p_2 - q_2)^2 + \dots)^{1/2}$



Häufig sind die Wertebereiche der Merkmale deutlich unterschiedlich.
 Beispiel: Merkmal $M_1 \in [0.01 \dots 0.05]$
 Merkmal $M_2 \in [3.1 \dots 22.2]$
 Damit M_1 überhaupt berücksichtigt wird, muss es höher gewichtet werden

Quadratische Form:
 $dist = ((p - q) \mathbf{M} (p - q)^T)^{1/2}$




Bei den bisherigen Ähnlichkeitsmaßen werden die Merkmale nur getrennt gewichtet.
 Besonders bei Farbhistogrammen müssen auch *verschiedene* Merkmale gemeinsam gewichtet werden.

Statt mit Distanzmaßen, die die Unähnlichkeit zweier Objekte messen, arbeitet man manchmal auch mit positiven Ähnlichkeitsmaßen

Räume und Distanzfunktionen

- Spezifiziere Anfrage-Objekt $q \in DB$ und...
 - ... suche ähnliche Objekte – Range-Query (Radius ε)
 $RQ(q, \varepsilon) = \{ o \in DB \mid dist(q, o) \leq \varepsilon \}$
 - ... suche die k ähnlichsten Objekte – Nearest Neighbor
 $NN(q, k) \subseteq DB$ mit mind. k Objekten, sodass
 $\forall o \in NN(q, k), p \in DB - NN(q, k) : dist(q, o) < dist(q, p)$



Räume und Distanzfunktionen

- Deskription von Featurevektoren

- Gegeben: Menge DB von Featurevektoren

- Zentroid (Centroid, vgl. Arithmetisches Mittel):
$$\mu_{DB} = \frac{1}{|DB|} \cdot \sum_{o \in DB} o$$

- Achtung: bei allgem. Metrischen Räumen muss Centroid nicht notwendigerweise existieren!!!

- Medoid m_{DB} :

- Der Featurevektor, der am nächsten zum Centroiden gelegen ist (die kleinste Distanz zum Zentroiden hat)
- Bei allgem. Metrischen Räumen: Objekt mit dem kleinsten durchschnittlichen Abstand zu allen anderen Objekten aus DB

- Varianz (der Distanzen):
$$Var_{DB} = \frac{1}{|DB|} \cdot \sum_{o \in DB} dist(o, \mu_{DB})^2$$

- Standardabweichung analog

38

Räume und Distanzfunktionen

- Hauptachsenanalyse eine Menge DB von *Euklidischen Vektoren*


- Kovarianz-Matrix:
$$\Sigma_{DB} = \frac{1}{|DB|} \sum_{o \in DB} (o - \mu_{DB})(o - \mu_{DB})^T$$

- Die Matrix wird zerlegt in

- eine Orthonormalmatrix $V = [e_1, \dots, e_d]$ (Eigenvektoren)
- und eine Diagonalmatrix $\Lambda = \text{diag}(\lambda_1, \dots, \lambda_d)$ (Eigenwerte)
- so dass gilt: $\Sigma_{DB} = V \Lambda V^T$

- Interpretation:


- **Eigenvektoren:**
Hauptausrichtung der Datenpunkte in DB
- **Eigenwerte:**
Varianz der Datenpunkte in DB entlang der entspr. Eigenvektoren



39


Feature-Transformationen für räumliche Objekte

- Feature Transformation für räumliche Objekte (CAD-Daten, Proteine, ...)



– Invarianzen

- Gleichheit (oder Ähnlichkeit) von Formen unabhängig von Lage und Orientierung im Raum
- Beispiele gleicher Formen im 2D und im 3D:




• Erwünscht:

- Kanonische Darstellung, d.h. ohne Lage- und Orientierungsinformation
- Verallgemeinerung auf andere Objekteigenschaften


Feature-Transformationen für räumliche Objekte

– Die wichtigsten Invarianzen



Feature-Transformationen für räumliche Objekte

- Volume Model [Ankerst, Kastenmüller, Kriegel, Seidl 99]




– Applikationen: CAD, Protein 3D-Strukturen


– Idee: *Formhistogramme* für 3D Objekte

- Partitioniere den 3D-Raum in Zellen (Histogramm-Bins).
- Bestimme den Anteil an Punkten des Objektes pro Zelle (normiertes Histogramm).
- Durch die Normierung werden die Histogramme unabhängig von der Punktedichte.


– Partitionierungen



Schalenmodell




Sektorenmodell




kombiniertes Modell


– Beispiel



Schalenmodell
(120 Schalen)



Sektorenmodell
(122 Sektoren)



kombiniertes Modell
(20 Schalen, 6 Sektoren)

42

Feature-Transformationen für räumliche Objekte

– Formale Definition der Histogramme

- *Schalenmodell*: Definiere die Bins über den Abstand zum Mittelpunkt, d.h. Anzahl der Punkte auf der jeweiligen Schale.
- *Sektorenmodell*: Anzahl der Punkte im jeweiligen Sektor.
- *Kombiniertes Modell*: Synthese aus Schalen- und Sektorenmodell.

– Invarianzen


- Translationsinvarianz durch Lagenormierung:
Verschiebung des Schwerpunkts eines Objektes in den Ursprung.
- Rotationsinvarianz durch Hauptachsentransformation:
 - Drehung der Objekte, so dass die Hauptachsen auf den Koordinatenachsen liegen.
 - unnötig beim Schalenmodell, dieses ist inhärent rotationsinvariant.

43


Feature-Transformationen für räumliche Objekte

- Verbesserung der Formhistogramme [Abfalg, Kriegel, Kröger, Pötke 05]

– Proportionale Aufteilung



– Redundante Zuordnung zu den Bins



Feature-Transformationen für räumliche Objekte


- Eigenvalue Model [Kriegel, Kröger, Mashael, Pfeifle, Pötke, Seidl 03]

– Volumen-Diskretisierung durch Voxel (3dimensionale Pixel)



– Würfelförmige Partitionierung der Bounding Box


– Bestimmung der Eigenwerte des Voxelinhaltes jeder Zelle



Feature-Transformationen für räumliche Objekte

– Invarianzen

- Translationsinvarianz durch Lagenormierung:
Verschiebung des Schwerpunkts eines Objektes in den Ursprung.
- Skalierungsinvarianz durch Voxelisierung der Bounding Box/Bounding Cube des Objekts mit immer gleicher Voxelauflösung
- Rotationsinvarianz
 - Hauptachsentransformation (völlig rotationsinvariant, aber bei manchen Objekten sensitiv gegenüber kleinen Änderungen)
 - CAD Objekte oft in „vernünftiger“ Lage durch Konstrukteur abgespeichert, dann besser 90-Grad-Rotationsinvarianz: Zur Laufzeit werden die 24 Würfelpositionen durch Permutation der Merkmalsvektor-Elemente simuliert, die Distanz zweier Objekte ist das Minimum über 24 Distanzen



- Reflektionsinvarianz
 - Betrachte 48 statt 24 Permutationen zur Laufzeit (incl. Spiegelung des Würfels)


46

Feature-Transformationen für räumliche Objekte

- Protein Datenbanken [Borgwardt, Ong, Schönauer, Vishwanathan, Smola, Kriegel 05]

– Idee:

- Graphmodel für Protein 3D-Strukturen
- Knoten: Untereinheiten von Proteinen (secondary structure elements)
- Kanten: Nachbarschaft von Untereinheiten innerhalb der 3D-Struktur und entlang der Aminosäure Sequenz.



47