

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

Kapitel 2: Merkmalsräume




Skript © 2003 Johannes Aßfalg, 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>

23

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.




24

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:


25

Beispiel: CAD-Zeichnungen (cont.)

Objekt-Raum




Merkmals-Raum



- 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.)

26


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

27

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?)
Güteklafe
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)

28

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: $f(a) = h(a) / n$

Histogramm:



Die folgenden Maße sind nur für metrische Merkmale sinnvoll:

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

Kontingenztabelle

- für kategorische 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?
- χ^2 -Koeffizient
Differenz zwischen dem bei Unabhängigkeit erwarteten und dem tatsächlich beobachteten Wert von h_{ij} (Maß für die Stärke der Abhängigkeit)





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

Korrelationskoeffizient

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

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

- Beispiele



31

Merkmalsraum (Featureraum)

- Intuitiv: ein Wertebereich/Domain mit Distanzfunktion
- Formal: Featureraum $\mathbf{F} = (\text{Dom}, \text{dist})$
- Dom ist eine (geordnete) Menge von Merkmalen (Features)
- $\text{dist} : \text{Dom} \times \text{Dom} \rightarrow \mathbb{R}$ ist eine totale (Distanz)-Funktion mit den folgenden Eigenschaften
 - $\forall p, q \in \text{Dom}, p \neq q : \text{dist}(p, q) > 0$
 - $\forall o \in \text{Dom} : \text{dist}(o, o) = 0$
 - $\forall p, q \in \text{Dom} : \text{dist}(p, q) = \text{dist}(q, p)$

Reflexivität

Symmetrie

32


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

33

- Ähnlichkeit von Feature Vektoren (Euklidische Vektoren)

Euklidische Norm (L_2):


$$\text{dist}_1 = ((p_1 - q_1)^2 + (p_2 - q_2)^2 + \dots)^{1/2}$$



Natürlichstes Distanzmaß

Manhattan-Norm (L_1):


$$\text{dist}_2 = |p_1 - q_1| + |p_2 - q_2| + \dots$$



Die Unähnlichkeiten der einzelnen Merkmale werden direkt addiert

Maximums-Norm (L_∞):

$$\text{dist}_\infty = \max \{|p_1 - q_1|, |p_2 - q_2|, \dots\}$$




Die Unähnlichkeit des am wenigsten ähnlichen Merkmals zählt

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

34

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 $M_1 \in [0.01 .. 0.05]$

Merkmal $M_2 \in [3.1 .. 22.2]$

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


35

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

$$\forall o \in NN(q, k), p \in DB - NN(q, k) : dist(q, o) < dist(q, p)$$



36


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): $Var_{DB} = \frac{1}{|DB|} \cdot \sum_{o \in DB} dist(o, \mu_{DB})$
- Standardabweichung analog

37

Hauptachsenanalyse einer 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





38

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


39

Die wichtigsten Invarianzen


Translation




Skalierung



Rotation





Spiegelung




40

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
- Beispiel



Schalenmodell




Sektorenmodell




kombiniertes Modell




Seryl-tRNA
Synthetase



Schalenmodell
(120 Schalen)



Sektorenmodell
(122 Sektoren)




kombiniertes Modell
(20 Schalen, 6 Sektoren)

41


- 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.

42

- Verbesserung der Formhistogramme [Aßfalg, Kriegel, Kröger, Pötke 05]
 - Proportionale Aufteilung




- Redundante Zuordnung zu den Bins



43


Eigenvalue Model [Kriegel, Kröger, Mashaal, Pfeifle, Pötke , Seidl 03]

- Volumen-Diskretisierung durch Voxel (3dimensionale Pixel)



- Würzelförmige Partitionierung der Bounding Box

- Bestimmung der Eigenwerte des Voxelinhaltes jeder Zelle



44

Invarianzen


- Translationsinvarianz durch Lagenormierung:
Verschiebung des Schwerpunkts eines Objektes in den Ursprung.
- Skalierungsinvarianz durch Voxellisierung 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)

45

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.



46