

Skript zur Vorlesung  
Knowledge Discovery in Databases II  
im Sommersemester 2007

# Kapitel 3: Projected, Corelation und Subspace Clustering

Skript übernommen aus KDD © 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>

---

## *Inhalt dieses Kapitels*

---

- 3.1 Einführung  
Clustering hochdimensionaler Daten
- 3.2 Projected Clustering  
Partitionierende Verfahren, dichte-basierte Verfahren
- 3.3 Correlation Clustering  
einfache Korrelations-Cluster, Hierarchische Korrelations-Cluster
- 3.4 Subspace Clustering  
Dichte-basierte Verfahren, Featureselektions-Verfahren

## 3.1 Einführung

---

### Lösung: Dimensionsreduktion

- Daten-Vorverarbeitung: Reduktion der Dimensionalität durch Selektion der (für das Clustering) relevanten Features
- Verwende Datensatz mit reduzierter Dimensionalität zum Clustern

### Allgemein:

- Gegeben:  $n$  Datenpunkte (Featurevektoren)  $DB = \{x_1, \dots, x_n\}$  mit Dimensionalität  $d$
- Gesucht: Transformation der Datenpunkte in  $(d-k)$ -dimensionale Featurevektoren, so dass der dabei gemachte Fehler möglichst klein ist

### Einfacher Ansatz:

- Abgeleitete Attribute (Summe, Durchschnitt, etc.) statt urspr. Attribute
  - erfordert Expertenwissen
  - kaum automatisierbar
- (+) teilweise gute Ergebnisse (hängt vom Experten ab)

70




## 3.1 Einführung

---

### 2. Grundproblem für das Clustering:

#### Cluster in verschiedenen Unterräumen

- Für zwei Klassen können zwei verschiedene Mengen an Attributen relevant/irrelevant sein


Clustering: Gruppierung der DB-Objekte in Teilmengen, so dass Intra-Cluster-Ähnlichkeit maximiert und Inter-Cluster-Ähnlichkeit minimiert wird	
Merkmals-Relevanz: Einzelne Merkmale unterliegen starkem Rauschen und verschlechtern das Clustering-Ergebnis	
Merkmals-Korrelation: Redundanz durch Korrelationen zwischen den einzelnen Merkmalen	

71

## 3.1 Einführung

---

- Charakteristik von Merkmals-Relevanz und Merkmals-Korrelation kann individuell für jeden Cluster sein
- Hinweis auf unterschiedliche stochastische Prozesse
- Ermittlung von Clustern mit einheitlicher Charakteristik



- Cluster mit Subspace-Präferenz
- Korrelations-Cluster
- Konventioneller Cluster
- Rausch-Objekte


72

## 3.1 Einführung


---

Anwendungen:


Modellierung



Kompression



Indexierung




73

## 3.1 Einführung

---

Erst Dimensionsreduktion, dann Cluster-Analyse




74

## 3.1 Einführung

---

Erst Dimensionsreduktion, dann Cluster-Analyse

Erst Cluster-Analyse, dann Dimensionsreduktion



Integriere Merkmalsanalyse in den Clustering-Prozess


75

## 3.1 Einführung

---

### 3. Grundproblem für das Clustering: Überlappende Cluster

- Bei manchen Anwendungen:  
*Objekte können in unterschiedlichen Teilräumen unterschiedlich clustern*



76

## 3.1 Einführung

---

### *Übersicht: Clustering hochdimensionaler Daten*

Dimensionsreduktion



Meist unbrauchbar bei  
lokaler Merkmalsrelevanz

3.1 Projected Clustering

3.2 Correlation-Clustering

3.3 Subspace Clustering

Integration von Varianz-  
und Kovarianz-Analyse in  
Clustering-Verfahren


77

## 3.2 Projected Clustering

---

### Projected Clustering:

- Integration von Varianzanalyse in den Clustering-Prozess
- Jeder Cluster enthält Punkte mit geringer Varianz in einer beliebigen Projektion des Datenraums
- Verfahren:
  - PROCLUS (basiert auf k-medoid Verfahren)
  - PreDeCon (basiert auf DBSCAN)



78

### 3.2.1 PROCLUS

---

#### *PROCLUS* [Aggarwal & Procopiuc 1999]

- Erweitert  $k$ -Medoid Verfahren CLARANS um Varianzanalyse für die gefundenen Cluster
- Verwendet Manhattan Distanz ( $L_1$ ) geteilt durch die Unterraumdimension, um Objekt-Distanzen aus verschiedenen Unterräumen „objektiv“ zu vergleichen
- Benötigt Anzahl der Cluster  $k$  und durchschnittliche Dimension der Cluster  $l$  als Eingabe

**Phase 1 Initialisierung:** Bestimmen der initialen Medoide durch „Greedy“-Methode auf DB-Sample

- Beginne mit einem zufälligen Medoid
- Wähle den weitest entfernten Punkt zu allen bisherigen Medoiden als neuen Medoid bis  $k$  Medoide ausgewählt sind.

79

## 3.2.1 PROCLUS

---

### Phase 2 Iteration: Optimierung der Medoide und der Cluster-Unterräume

- Medoid-Optimierung wie bei k-Medoid (PAM, CLARANS)
- Unterraumoptimierung (Varianzanalyse):
  - $d_i$  = minimale Distanz des Medoiden  $m_i$  zu allen anderen Medoiden
  - $L_i$  = {Punkte, die zu  $m_i$  einen kleineren Abstand als  $d_i$  haben}
  - $X_{i,j}$  = durchschnittliche Distanz aller Punkte aus  $L_i$  zu  $m_i$  in Dimension  $j$
  - Je kleiner  $X_{i,j}$ , desto näher liegen die Punkte in  $L_{i,j}$  entlang Dimension  $j$  bei  $m_i$
- Wähle Unterräume  $S_i$ , so dass insgesamt  $k \cdot l$  Dimensionen zu den Medoiden zugeordnet wurden (Greedy-Verfahren)
- Zuordnung der Punkte zu den  $m_i$  unter Berücksichtigung der ausgewählten  $S_i$

80

## 3.2.1 PROCLUS

---

### *Diskussion*

- Nachteile lokal optimierender Verfahren wie  $k$ -Medoids
  - Konvergiert evtl. nur gegen ein lokales Minimum
  - Eingabeparameter  $k$  schwer zu bestimmen
  - Anfällig gegen Rauschen
  - Berechnet nur konvexe Cluster
  - Inputparameter  $l$  schwer zu bestimmen
- Idee: Integration von Varianz- und Covarianz-Analyse in dichte-basierte Clustering-Verfahren
- Wie?
  - Ermittlung der Charakteristik von Merkmals-Relevanz und Merkmals-Korrelation aus der Nachbarschaft eines jeden Punktes
  - Vereinigung von Punkten mit ähnlicher Charakteristik zu einem Cluster


81

### 3.2.2 PreDeCon

#### PreDeCon [Böhm, Kailing, Kriegel, Kröger 2004]

Intuition: Wenn ein Punkt zu einem Subspace-Cluster gehört, ist das in der lokalen Nachbarschaft in der Varianz sichtbar.

- Euklidische Bereichsanfrage mit Radius  $\varepsilon$
- Ermittlung der Varianz in allen Dimensionen separat
- Ermittlung der Anzahl der Dimensionen mit Varianz  $\leq \delta$



Subspace preference dimensionality (PDIM):  
# Dimensionen mit  $\text{VAR} > \delta$

Parameter  $\lambda$ : Finde Cluster mit  $\text{PDIM} \leq \lambda$

82


### 3.2.2 PreDeCon

Verwende gewichtete Euklidische Distanz fürs Clustering:

$$\text{dist}_P(P, Q) = \sqrt{\sum_i w_i \cdot (p_i - q_i)^2}$$

Bestimmung des *subspace preference* Gewichts  $w_i$ :


$$w_i = \begin{cases} 1 & \text{if } \text{VAR}_i > \delta \\ \kappa & \text{if } \text{VAR}_i \leq \delta \end{cases}$$



$\kappa \gg 1$  kontrolliert die tolerierte Abweichung („thickness“) der  $\lambda$ -dimensional *subspace preference* Linie oder Ebene

83

### 3.2.2 PreDeCon



Subspace Preference  $\varepsilon$ -Nachbarschaft:

$$N_{\varepsilon}^{\bar{w}_P}(P) = \{X \in DB \mid \max \{dist_P(P, X), dist_X(X, P)\} \leq \varepsilon\}$$

→ Garantiert Reihenfolgeunabhängigkeit

84

### 3.2.2 PreDeCon

Preference weighted Kernpunkt:

$$CORE_{\varepsilon, \mu}^{\lambda, \delta}(O) \Leftrightarrow PDIM(N_{\varepsilon}(O)) \leq \lambda \wedge |N_{\varepsilon}^{\bar{w}_O}(O)| \geq \mu$$

Direkte Erreichbarkeit  
bzgl. subspace preference:

$$DIRREACH_{\varepsilon, \mu}^{\lambda, \delta}(Q, P) \Leftrightarrow$$

$$(1) CORE_{\varepsilon, \mu}^{\lambda, \delta}(Q)$$

$$(2) PDIM(N_{\varepsilon}(P)) \leq \lambda$$

$$(3) P \in N_{\varepsilon}^{\bar{w}_Q}(Q)$$

Subspace Preference Cluster:

C ist ein *Subspace Preference Cluster* wenn

(1) Alle Punkte in C verbunden bzgl. subspace preferences sind (symmetrisch-transitive Hülle der direkten Erreichbarkeit)

(2) C ist maximal bzgl. der Erreichbarkeit

85

### 3.2.2 PreDeCon

**Algorithmus PreDeCon** ( $\varepsilon, \mu, \lambda, \delta$ )

seedlist =  $\emptyset$

**while** unprocessed object exists **do**

**if** seedlist is empty **then**

    insert some unproc. object  $O$  with  $\text{PDIM}(O) \leq \lambda \wedge |N_{\varepsilon}^{\overline{w}_o}(O)| \geq \mu$

  take any element  $O$  out of seed list



**if**  $|N_{\varepsilon}^{\overline{w}_o}(O)| \geq \mu$  **then**

    insert all elements of  $N_{\varepsilon}^{\overline{w}_o}(O)$  into seed list

**Laufzeit:**      linear in  $d$       konstant in  $\lambda$       quadratisch in  $n$

86

### 3.2.2 PreDeCon



**Gene Expressions Daten:** [Tavazoie et al., Nature Genetics, 99]

- 2800 genes, 17 time slots, Aufgabe: Finde Cluster mit funktionell verwandten Genen
- PreDeCon findet 12 Cluster mit ca. 10-14 Genen, z.B.:
  - Mehrere Gene die in die Chromatin Modellierung und Instandsetzung involviert sind (z.B. NHP10, DPB4, IES3, TAF9); IES3 und NHP10 sind sogar direkte Interaktionspartner
  - >30 Gene die strukturelle Komponenten der Ribosomen codieren (z.B. CDC33, TEF4, EFB1, und NHP2)
  - Mehrere Gene der Glykolyse (z.B. CDC19, TPI1, TDH2, FBA1, and GPM1).

Vergleichspartner (**DBSCAN**, **PROCLUS**, **DOC**) fanden keine signifikanten funktionellen Zusammenhänge


87

## 3.3 Correlation Clustering

---

### Correlation Clustering

- Integration von Kovarianzanalyse in den Clustering-Prozess
- Jeder Cluster enthält Punkte einheitlicher, beliebig dimensionaler Korrelation (Covarianz)
- Verfahren:
  - ORCLUS (basiert auf k-medoid Verfahren)
  - 4C (basiert auf DBSCAN)
  - HICO (basiert auf OPTICS)



88

### 3.3.1 ORCLUS

---

#### *ORCLUS* [Aggarwal & Yu 2000]

- Ähnlich wie PROCLUS aber Kovarianzanalyse
- Berechnet Unterräume, die nicht achsenparallel sind
- Verwendet  $k$ -Means statt  $k$ -Medoid Ansatz
- Verwendet Korrelationsmatrix, um für jeden Cluster die Eigenvektoren mit den kleinsten Eigenwerten zu berechnen (Covarianz des Clusters)
- Eingabe:  $k$  Anzahl der Cluster,  $l$  durchschnittliche Dimensionalität der Cluster-Unterräume
- Ergebnis:  $k$  Cluster ( $C_i$ ) mit zugeordneten Eigenvektoren ( $S_i$ )
- Probleme:
  - Nachteile von  $k$ -Means
  - Input-Parameter  $l$
  - Laufzeit:  $O(l^3 + l \cdot n \cdot d + l^2 + d^3)$

89


### 3.3.2 4C

#### 4C [Böhm, Kailing, Kröger, Zimek 2004]

Intuition: Integration der Korrelationsanalyse in dichte-basiertes Clustering.  
4C = Computation Correlation Connected Clusters

#### Idee:

- Bestimmung der Nachbarschaftspunkte (euklidisch)
- Ermittlung und Zerlegung (PCA) der Kovarianz-Matrix



PCA zerlegt Kovarianzmatrix  $M_p$  in:

$$M_p = V E V^T$$

V: Eigenvektor-Matrix  
(Haupt-Ausdehnungs-Richtungen)

E: Eigenwert-Matrix (Varianzen)

90

### 3.3.2 4C

Quadratische Form als Distanzfunktion:


$$dist_{M_p}(P, Q) = \sqrt{(P - Q) * M_p * (P - Q)^T}$$

Korrelations Ähnlichkeits Matrix:

$$M'_p = V E' V^T$$

Anpassung der Eigenwerte:

$$e'_i = \begin{cases} 1 & \text{if } e_i > \delta \\ \kappa & \text{if } e_i \leq \delta \end{cases}$$





$\kappa$  steuert die tolerierte Abweichung („thickness“) der  $\lambda$ -dimensionalen Korrelations-Linie oder -Ebene)


91

### 3.3.2 4C

- Problem der Reihenfolge-Unabhängigkeit:
  - Punkte müssen sich gegenseitig finden
  - $P$  Element der Korrelations- $\varepsilon$ -Nachbarschaft von  $Q$   
gdw.  $\text{dist}_M(P, Q) \leq \varepsilon$  **und**  $\text{dist}_M(Q, P) \leq \varepsilon$



$P$  in Korrelations- $\varepsilon$ -Nachbarschaft von  $Q$



$P$  nicht in Korrelations- $\varepsilon$ -Nachbarschaft von  $Q$

- Definitionen zu:
  - Correlation Core Object
  - Direct Correlation Reachability
  - Correlation Reachability
  - Correlation-Connected Set
 analog wie DBSCAN/PreDeCon


92

### 3.3.2 4C

```

Algorithmus 4C ( $DB, \varepsilon, \mu, \lambda, \delta$ )
// assumption: each point in  $DB$  is marked
// as unclassified
for each unclassified  $O \in DB$  do
  compute  $N_\varepsilon(O)$ ;
  if  $|N_\varepsilon(O)| \geq \mu$  then
    if  $\text{CorDim}(N_\varepsilon(O)) \leq \lambda$  then
      if  $|N_\varepsilon^{M_o}(O)| \geq \mu$  then
        expand a new cluster;
  In all other cases: mark  $O$  as noise;
  
```


$\mu = 3$



93

### 3.3.2 4C


```
//expand cluster
generate new clusterID;
Insert all  $X$  with  $\text{DirCorReach}(O,X)$  into queue  $\Phi$ ;
while  $\Phi \neq \emptyset$  do
   $Q$  = first point in  $\Phi$ ;
  compute  $N_{\epsilon}^{M'_Q}(Q)$  ;
  for each  $X$  with  $\text{DirCorReach}(Q,X)$  do
    if  $X$  is unclassified or noise then
      assign current clusterID to  $X$ ;
    if  $X$  is unclassified then
      insert  $X$  into  $\Phi$ ;
  remove  $Q$  from  $\Phi$ ;
```



94

### 3.3.2 4C


#### Ergebnisse auf Metabolome Daten



95

### 3.3.2 4C


#### Vergleich mit DBSCAN




 Cluster found by DBSCAN       Clusters found by 4C

#### Vergleich mit ORCLUS

4C



ORCLUS



96

### 3.3.2 4C

#### Komplexität ohne Indexunterstützung:

- Für jeden (Kern-) Punkt ist das zugeordnete Ähnlichkeitsmaß (die modifizierte Kovarianzmatrix) zu ermitteln:
  - Ermittlung der Kovarianzmatrix:  $O(nd^2)$
  - Eigenwert-Zerlegung der Kovarianzmatrix:  $O(d^3)$
- DBSCAN wertet je eine Bereichsanfrage pro Punkt aus:
  - Auswertung mit modifizierter Kovarianzmatrix:  $O(nd^2)$
- Gesamtkomplexität:  $O(n^2d^2 + d^3n)$

#### Komplexität mit Indexunterstützung:

- Bereichsanfrage reduziert sich auf  $O(d^2 \log n)$
- Gesamt-Komplexität:  $O(d^2n \log n + d^3n)$

97

### 3.3.2 4C

---

#### Diskussion

- Finden lokaler Korrelations-Cluster
- Kritisch: Parameter  $\varepsilon$  bestimmt, wieviele und welche Punkte aus der Nachbarschaft für die Bestimmung der Kovarianzmatrix verwendet werden  
=> Kovarianzmatrix (und damit die PCA) nicht stabil



- Verbesserung [Achttert, Böhm, Kröger, Zimek 2006]
  - $k$ -nächste Nachbarn statt Range-Query
  - Dadurch zumindest Anzahl der Punkte festgelegt
  - z.B.  $k = 10d$

98

### 3.3.3 HICO



---

*HICO* [Achttert, Böhm, Kröger, Zimek 2006]

Motivation:

Korrelations-Cluster können Hierarchie bilden:

- Mehrere Cluster in je einem Korrelations-Subspace
- In diesem Teilraum können weitere Korrelations-Cluster mit noch niedrigerer Dimension sein



99

### 3.3.3 HICO

---

#### Idee von HICO (Hierarchical Correlation Clustering):

- Wieder Ermittlung von Eigenwerten und Eigenvektoren aus der Nachbarschaft eines Punktes (euklidische k-Nächste-Nachbarn)
- Integration in OPTICS durch ein geeignetes, korrelationsbasiertes Distanzmaß:
  - Distanz zwischen 2 Punkten soll niedrig sein, wenn sich die Punkte auf einer gemeinsamen Korrelationslinie befinden
  - Distanz soll höher sein, wenn es sich um eine 2d-Korrelationsebene handelt
  - usw.

Distanz: Dimension des „aufgespannten“ Raumes aus:


- Eigenvektoren, aus den Kovarianz-Matrizen der beiden Punkte
- Differenzvektor der beiden Punkte

100

### 3.3.3 HICO

---

Beispiel:



$$\text{dist}(P_1, P_2) = 1$$

$$\text{dist}(P_1, P_3) = 2$$

$$\text{dist}(P_1, P_4) = 3$$

Dimension des aufgespannten Raums:

- Nicht im algebraischen Sinn
- Sondern in dem Sinn:  
Hinreichende Anzahl von Dimensionen ist hinreichend „flach“, d.h. kleine Varianz

Distanz-Ermittlung mit Schmidt'scher Orthonormierung

101

### 3.3.3 HICO

---


#### Distanzermittlung:

- Sei  $M_p$  die Menge aller Eigenvektoren von  $P$  mit Eigenwerten  $> \delta$
- Für jeden Eigenvektor  $q$  von  $Q$  mit Eigenwert  $> \delta$ :
  - Teste, ob  $q$  von der durch  $M_p$  aufgespannten Hyper-Ebene einen Abstand  $> \delta$  hat
  - Wenn ja, nimm  $q$  zu  $M_p$  hinzu und orthonormiere  $M_p$
- Teste den Differenzvektor  $(P-Q)$ , ob er von  $M_p$  einen Abstand  $> \delta$  hat
- Korrelations-Distanzen sind ganzzahlig
- Deshalb haben viele Punkte exakt gleiche Distanz
- Beim Ordnen der Distanzen in der Seed-Liste deshalb zwei Ordnungs-Kriterien:
  - Korrelations-Distanz (erstes Ordnungs-Kriterium)
  - Euklidische Distanz (bei gleicher Korrelations-Distanz)
- Hierdurch innerhalb einer Korrelations-Linie:  
Ermittlung der konventionellen Cluster-Struktur


102

### 3.3.3 HICO


---




(a) Plot.




(b) Data set.




(c) Noise.



(d) Cluster 1.



(e) Cluster 3.



(f) Cluster 2.

103


### 3.3.3 HICO




(a) "NHL" data set ( $k = 30$ ).



(b) "Soccer" data set ( $k = 25$ ).



(c) "COIL" data set ( $k = 25$ ).





(d) "El Nino" data set ( $k = 40$ ).

## Projected Clustering und Correlation Clustering

### Überblick und Fazit:

- PROCLUS/PreDeCon:
  - Achsenparallele Subspace-Cluster
- ORCLUS/4C:
  - Beliebige orientierte Korrelations-Cluster
- HICO:
  - Hierarchien von Korrelations-Clustern
- Dichtebasierte Methoden effizienter und effektiver als partitionierende Verfahren (vgl. Clustering Kap. 2)
- Allgemeine Vorteile:
  - Determiniertes Ergebnis
  - Robust gegenüber Rauschen
  - Quadratisch in  $n$ , maximal kubisch in  $d$
  - Parametrisierung einfacher (besonders HICO)



## 3.4 Subspace Clustering

---

### Beobachtung:

- Projected Clustering Methoden finden Cluster in verschiedenen Unterräumen
- ABER: Punkte können in verschiedenen Unterräumen in verschiedenen Clustern liegen („überlappende Cluster“)

### Idee des Subspace Clusterings:

- Berechne Clustering für mehrere Unterräume
- Vollständige Suche ist nicht effizient ( $O(2^d)$  mögliche Unterräume)
- Daher: Finde alle (möglichst viele) Unterräume, in denen Cluster liegen

### Bemerkung:

Terminologie nicht immer einheitlich. Hier:

- Projected Clustering = keine überlappenden Cluster
- Subspace Clustering = überlappende Cluster

106

---

### 3.4.1 CLIQUE

---

*CLIQUE* [Agrawal, Gehrke, Gunopulos, Raghavan 1998]

1. Identifikation von Unterräumen mit Clustern

2. Identifikation von Clustern

- *Cluster*: „dichtes Gebiet“ im Datenraum
- Dichte-Grenzwert  $\tau$ 
  - Region ist *dicht*, wenn sie mehr als  $\tau$  Punkte enthält
  - Region = Gitterzelle
- Gitterbasierter Ansatz
  - jede Dimension wird in  $\xi$  Intervalle aufgeteilt
  - Cluster ist Vereinigung von verbundenen dichten Regionen

107

## 3.4.1 CLIQUE

---

### *Identifikation von Unterräumen mit Clustern*


- Aufgabe: Entdecken dichter Regionen
- Greedy-Algorithmus (Bottom-Up), ähnlich wie *Apriori*-Algorithmus bei der Warenkorbanalyse:
  - beginne mit der leeren Menge
  - nehme jeweils eine Dimension dazu
- Grundlage dieses Algorithmus: *Monotonie-Eigenschaft*  
wenn eine Region  $R$  im  $k$ -dimensionalen Raum dicht ist, dann ist auch jede Projektion von  $R$  in einen  $(k-1)$ -dimensionalen Unterraum dicht
- Umkehrung:  
Wenn eine  $(k-1)$ -dimensionale Region  $R$  nicht dicht ist, sind alle  $k$ -dimensionalen Regionen, die  $R$  als Projektion besitzen, nicht dicht.

108

## 3.4.1 CLIQUE

---

### *Beispiel*



- 2-dim. dichte Regionen
- 3-dim. Kandidaten-Region
- 2-dim. Region, die geprüft werden muß

- auch die Regionen, die in Unterräumen dicht sind, müssen noch auf der DB gezählt werden (enthalten sie wirklich mehr als  $\tau$  Punkte?)
- heuristische Reduktion der Anzahl der Kandidaten-Regionen

109

### 3.4.1 CLIQUE

---

#### *Identifikation von Clustern*



- Aufgabe: Finden maximaler Mengen verbundener dichter Regionen
- Gegeben: alle dichten Regionen in demselben  $k$ -dimensionalen Unterraum
- „depth-first“-Suche in folgendem Graphen (Suchraum)
  - Knoten: dichte Regionen
  - Kanten: gemeinsame Hyperflächen / Dimensionen der beiden dichten Regionen
- Laufzeitkomplexität
  - dichte Regionen im Hauptspeicher (z.B. Hashbaum)
  - für jede dichte Region  $2k$  Nachbarn zu prüfen
  - ⇒ Zahl der Zugriffe zur Datenstruktur:  $O(2 \cdot k \cdot n)$

110

### 3.4.1 CLIQUE

---

#### *Experimentelle Untersuchung*



Laufzeitkomplexität von CLIQUE

linear in  $n$ , superlinear in  $d$

111

### 3.4.1 CLIQUE

---

#### *Diskussion*

- + automatische Entdeckung von Unterräumen mit Clustern
- + automatische Entdeckung von Clustern
- + keine Annahme über die Verteilung der Daten
- + Unabhängigkeit von der Reihenfolge der Daten
- + gute Skalierbarkeit mit der Anzahl  $n$  der Datensätze
  
- Genauigkeit des Ergebnisses hängt vom Parameter  $\xi$  ab
- braucht eine Heuristik, um den Suchraum aller Teilmengen der Dimensionen einzuschränken
  - ⇒ findet u.U. nicht alle Unterräume mit Clustern

112

### 3.4.1 CLIQUE

---

#### *Erweiterungen von CLIQUE*

- *ENCLUS* [Cheng, Fu & Zhang 1999]
  - Unterschied zu CLIQUE:  
Anderes Dichtekriterium für Regionen: Entropie  $H(X)$  für Menge von Regionen  
$$H(X) = - \sum_{x \in X} d(x) \cdot \log d(x) \quad (d(x) \text{ Anteil der Datenpunkte in Region } x)$$
  - Entropie verhält sich ebenfalls monoton
  
- *MAFIA* [Goil, Nagesh & Choudhary 1999]
  - Adaptives Gitter ⇒ weniger Regionen variabler Größe
  - Finde Regionen, die um Faktor  $\alpha$  dichter sind als der erwartete Durchschnitt (relativ zum Volumen)
  - Keine Monotonie-Eigenschaft, daher Brute-Force Navigation durch den Suchraum aller möglichen Unterräume

113

## 3.4.2 SUBCLU

---

### *Dichte-verbundenes Subspace Clustering*

[Kailing, Kriegel, Kröger 2004]


Motivation:

- Nachteil der gitterbasierten Ansätze

Wahl von  $\xi$  und  $\tau$

Cluster für  $\tau = 4$   
(ist C2 Cluster?)

Für  $\tau > 4$ : keine Cluster  
(insb. C1 geht verloren!)



⇒ Verwende dichte-verbundenes Clustering (DBSCAN)

114

## 3.4.2 SUBCLU

---

### *SUBCLU*


- Berechne dichte-verbundene Subspace Cluster
- Vorteile:
  - Clusterbegriff mathematisch sauber formuliert
  - Zuordnung der (Kern-) Punkte zum Cluster eindeutig
  - Erkennen von Clustern unterschiedlicher Größe und Form
- Gesucht:
  - Effiziente Strategie, um die dichte-verbundenen Cluster in allen Unterräumen (bzgl.  $\varepsilon$  und *MinPts*) zu berechnen
  - Nutze Greedy-Ansatz wie bei CLIQUE: generiere bottom-up alle Subspace Cluster
  - Dazu notwendig: Monotoniekriterium für dichte-verbundene Cluster

115

### 3.4.2 SUBCLU

#### Monotonie dichte-verbundener Cluster

- Gilt leider nicht:
  - Sei  $C$  ein dichte-verbundener Cluster im Unterraum  $S$
  - Sei  $T \subset S$  ein Unterraum von  $S$
  - $C$  muss nicht mehr maximal bzgl. Dichte-Erreichbarkeit sein
  - Es kann Punkte geben, die nicht in  $C$  sind, aber im Unterraum  $T$  dichte-erreichbar von einem Objekt in  $C$  sind



$C$  ist ein dichte-verbundener Cluster im Unterraum  $\{A,B\}$


$p \notin C$  und  $q \in C$

Im Unterraum  $\{B\}$  ist  $p$  (direkt) dichte-erreichbar von  $q \in C$

### 3.4.2 SUBCLU

#### Monotonie dichte-verbundener Mengen


Wenn  $C$  eine dichte-verbundene Menge im Unterraum  $S$  ist, so ist  $C$  auch eine dichte-verbundene Menge in allen Teilräumen  $T \subset S$



$p$  und  $q$  dichte-verbunden in  $\{A,B\}$ ,  $\{A\}$  und  $\{B\}$

$MinPts = 4$

$\underline{\epsilon}$



$p$  und  $q$  nicht dichte-verbunden in  $\{B\}$  und  $\{A,B\}$


## 3.4.2 SUBCLU

### Algorithmus

- Generiere alle 1-dimensionalen dichte-verbundenen Cluster
- Für jeden  $k$ -dimensionalen Cluster muss nun geprüft werden, ob er in einem  $(k+1)$ -dimensionalen Oberraum noch vorhanden ist:
  - Gegeben:
    - $S_k$ : Menge der  $k$ -dimensionale Unterräume in denen Cluster existieren
    - $C_S$ : Menge der Cluster im Unterraum  $S$
    - $C_k$ : Menge aller Mengen von Cluster in  $k$ -dimensionalen Unterräumen  
 $C_k = \{C_S \mid S \text{ ist } k\text{-dimensionaler Unterraum}\}$
  - Vorgehen:
    - Bestimme  $(k+1)$ -dimensionale Kandidatenunterräume  $Cand$  aus  $S_k$
    - Für einen beliebigen  $k$ -dimensionalen Unterraum  $U \subset Cand$  :  
Bestimme für alle  $k$ -dimensionalen Cluster  $c$  in  $U$  ( $c \in C_U$ ) die  $(k+1)$ -dimensionalen Fortsetzungen durch die Funktion  $DBSCAN(c, U, \varepsilon, MinPts)$

118

## 3.4.2 SUBCLU



Funktion  $DBSCAN(D, U, \varepsilon, MinPts)$   
berechnet alle dichte-verbundenen  
Cluster bzgl.  $\varepsilon$  und  $MinPts$  einer  
Datenmenge  $D$  im Unterraum  $U$



$S_1 = \{\{A\}, \{B\}\}$   
 $C\{A\} = \{A_1, A_2\}$   
 $C\{B\} = \{B_1, B_2, B_3\}$   
 $C_1 = \{C\{A\}, C\{B\}\}$

- Heuristische Optimierungsmöglichkeit:
  - $DBSCAN(c, U, \varepsilon, MinPts)$  nicht für zufälligen  $U \subset Cand$  aufrufen, sondern für den Unterraum  $U$ , in dem die Gesamtanzahl der Punkte in den Clustern (also der Punkte in  $C_U$ ) am geringsten ist (im Beispiel:  $U = \{B\}$ )
  - Dadurch wird die Anzahl der Range-Queries beim DBSCAN-Lauf minimiert (im Beispiel um 2)

119

## 3.4.2 SUBCLU

### Experimente



Skalierbarkeit: superlinear in Anzahl der Dimensionen und Anzahl der Objekte



ABER: Findet mehr Cluster als CLIQUE





120

## 3.4.3 RIS

*RIS (Ranking Interesting Subspaces)* [Kailing, Kriegel, Kröger, Wanka 2003]

Probleme von SUBCLU:

- Verschiedene Cluster in einem Unterraum können verschieden dicht sein
- Cluster aus verschiedenen Unterräumen können verschieden dicht sein



121

### 3.4.3 RIS

---

#### Idee von RIS:

- Berechne nicht mehr direkt die Subspace Cluster
- Sondern: berechne nur die Unterräume, die interessante Cluster enthalten
  - Was sind interessante Cluster/Unterräume?
  - Qualitätskriterium für Unterräume
- RIS gibt eine Liste von Unterräumen aus, sortiert nach Qualität
- Die eigentlichen Cluster können durch ein beliebiges Cluster-Verfahren für die interessanten Unterräume erzeugt werden


122

### 3.4.3 RIS


---

#### Interessante Unterräume:

- Cluster enthalten mindestens einen Kernpunkt  
⇒ Unterraum, der keinen Kernpunkt enthält, kann nicht interessant sein
- Anzahl der Kernpunkte ist proportional zur
  - Anzahl der verschiedenen Cluster                      und/oder
  - Größe der Cluster    und/oder
  - Dichte der Cluster



Anzahl



size



density

123


#### Algorithmus RIS:

1. Berechne für jeden Punkt  $p$  der Datenbank die Unterräume, in denen  $p$  noch Kernpunkt ist  
⇒ Berechnet alle relevanten Unterräume
2. Sammle für jeden berechneten Unterraum statistische Informationen um über die „Interessantheit“ des Unterraumes entscheiden zu können  
⇒ Qualität der Unterräume (z.B. Anzahl der Kernpunkte)  
⇒ Sortierung der Unterräume nach „Interessantheit“ möglich
3. Entferne Unterräume, die redundante Informationen enthalten  
⇒ Cluster in einem Unterraum  $S$  sind in allen Unterräumen  $T \subseteq S$  enthalten

#### Schritt 1

#### Suche Unterräume, die mindestens einen Kernpunkt enthalten:

- Monotonie der Kernpunkteigenschaft:  
Wenn  $p$  ein Kernpunkt in Featureerraum  $S$  ist, dann ist  $p$  auch ein Kernpunkt in allen Unterräumen  $T \subseteq S$



- Wenn  $p$  in  $T$  kein Kernpunkt ist, kann  $p$  auch in allen  $S \supset T$  kein Kernpunkt sein.  
⇒ Suchstrategie von CLIQUE und SUBCLU wieder verwendbar

#### *Schritt 2*

#### Qualität der gefundenen Unterräume:

- $\text{count}[S]$  = Summe (der Anzahl) aller Punkte, die in der  $\varepsilon$ -Nachbarschaft aller Kernpunkte eines Unterraumes  $S$  liegen
- $\text{NaiveQuality}(S) = \text{count}[S] - \text{Kernpunkte}(S)$ 
  - Anzahl der erwarteten Punkte in einer  $\varepsilon$ -Nachbarschaft sinkt mit steigender Dimension
  - $\text{NaiveQuality}$  favorisiert niedrig dimensionale Unterräume
- Skalierung in Abhängigkeit der Dimensionalität:

$$\text{Quality}(S) = \frac{\text{count}[S] - \text{Kernpunkte}(S)}{n(n-1) \left(\frac{2\varepsilon}{\text{Attr.bereich}}\right)^{\text{dim}(S)}}$$

- Periodische Randbedingungen um Punkte, die am Rand des Datenraumes liegen, nicht zu benachteiligen


#### *Schritt 3*

#### Entfernen redundanter Unterräume:


- „Überflüssige“ Unterräume:
  - Cluster im Raum  $S$  haben eine Projektion in Unterräumen von  $S$
  - Durch die Hinzunahme von irrelevanten Dimensionen muss ein Cluster zunächst noch nicht verschwinden
- Pruning-Schritte:
  - Abwärts-Pruning:  
Wenn es einen  $(k-1)$ -dimensionalen Unterraum  $S$  mit einer höheren Qualität als ein  $k$ -dimensionaler Unterraum  $T$  ( $T \subset S$ ) gibt, lösche  $T$ .
  - Aufwärts-Pruning:  
Wenn der Count-Wert eines echten  $(k-1)$ -dimensionaler Unterraumes von  $S$  „besonders stark“ vom Mittelwert der Count-Werte aller echten  $(k-1)$ -dimensionalen Unterräume von  $S$  abweicht, lösche  $S$

## Experimentelle Untersuchung

Laufzeit in Abhängigkeit von  $n$



Laufzeit in Abhängigkeit von  $d$




Skaliert superlinear in  $n$  und  $d$

⇒ Random Sampling

auch bei kleinen Samplegrößen

hohe Qualität

Laufzeit in Abhängigkeit der Samplegröße



## Diskussion

Vorteile:

- Findet alle Unterräume, in denen interessante Cluster vorhanden sind
- Erzeugen von Subspace Clustern unterschiedlicher Dichte möglich (z.B. indem man in den gefundenen Unterräumen mit OPTICS „clustert“)

Nachteile:

- Problem, das Cluster in verschiedenen dimensional Unterräumen meist unterschiedlich dicht sind, ist immer noch nicht gelöst
- Trotz Dimensions-Anpassung des Qualitätskriteriums:  
 $\varepsilon$  begrenzt die Dimension der gefunden Unterräume nach oben:  
je kleiner  $\varepsilon$  desto niedriger dimensional die Unterräume, die gefunden werden

### 3.4.4 SURFING


*SURFING* (*Subspaces Relevant for Clustering*) [Baumgartner, Kailing, Kriegel, Kröger, Plant 2004]

Idee: Berechne interessante Unterräume

- Unabhängigkeit von einem globalen Dichteparameter für verschiedene Cluster und verschiedene Unterräume
- ohne die dichte-basierte Vorstellung von Clustern komplett aufzugeben
- OPTICS:
  - Unabhängig von einem globalen Dichteparameter
  - Dichte-basiertes Cluster-Modell
  - Kerndistanz (Distanz zum  $k$ -nächsten Nachbarn) und Erreichbarkeitsdistanz als Maß für lokale Dichte
  - Je kleiner Kerndistanz, desto dichter sind die Punkte lokal
  - Je größer Kerndistanz, desto weniger dicht sind die Punkte lokal



Kleine 10-nächste Nachbarn Distanz




Große 10-nächste Nachbarn Distanz



130

### 3.4.4 SURFING


- Die Qualität der hierarchischen Clusterstruktur eines Unterraumes kann anhand der  $k$ -nn-Distanzen aller Punkte vorhergesagt werden:
  - Viele unterschiedliche  $k$ -nn-Distanzen  $\Rightarrow$  signifikante (hierarchische) Clusterstrukturen
  - Viele ähnliche  $k$ -nn-Distanzen  $\Rightarrow$  kaum (hierarchische) Clusterstrukturen



Sortierte 3-nn-Distanzen



Sortierte 3-nn-Distanzen



131

### 3.4.4 SURFING

---

#### Qualitätskriterium für Unterräume

- Varianz der  $k$ -nn-Distanzen in einem Unterraum:
    - Nachteil: berücksichtigt die quadrierten Differenzen zum Mittelwert
  - Summe der Differenzen  $DIFF$  unterhalb des Mittelwertes  $\mu$ :
$$DIFF = \sum_{o \in DB} |\mu - nnDist_k(o)|$$
    - Nachteil: nicht unabhängig von der Dimension
  - Verhältnis aus  $DIFF$  zum Mittelwert  $\mu$ :
    - Nachteil: Mittelwert ist nicht vollständig robust gegenüber Ausreißern und kleinen sehr dichten Clustern
      - Mittelwert wird durch einige wenige Ausreißer nach oben verschoben  
 $\Rightarrow DIFF$  unverhältnismäßig hoch  $\Rightarrow DIFF/\mu$  unverhältnismäßig zu hoch
      - Mittelwert wird durch wenige kleine sehr dichte Cluster nach unten verschoben  
 $\Rightarrow DIFF$  unverhältnismäßig klein  $\Rightarrow DIFF/\mu$  unverhältnismäßig zu klein
- $\Rightarrow$  Skalierung mit der Anzahl der Punkte, deren  $k$ -nn-Distanz unterhalb des Mittelwertes liegt (bezeichnet als *Below*)

132

### 3.4.4 SURFING

---

Qualität eines Unterraums:

$$\text{quality}(S) = \begin{cases} 0 & \text{if } \text{Below}_S = \{\} \\ \frac{DIFF_S}{|\text{Below}_S| \mu_S} & \text{else.} \end{cases}$$

$DIFF_S$  = Summe der Differenzen der  $k$ -nn-Distanzen unterhalb von  $\mu$  zum Mittelwert (vgl. Folie 318) im Unterraum  $S$

$\mu_S$  = Mittelwert der  $k$ -nn-Distanzen im Unterraum  $S$


$\text{Below}_S$  = Anzahl der Punkte, die im Unterraum  $S$  eine  $k$ -nn-Distanz unterhalb von  $\mu_S$  haben

133


### 3.4.4 SURFING

#### Problem:

Interessante Unterräume mit Clustern gleicher Dichte und ohne Noise können nicht von irrelevanten Unterräumen mit gleichverteilten Daten unterschieden werden!



Interessanter Unterraum




Irrelevanter Unterraum


#### Lösung:

Füge zufällige eine kleine Menge an zusätzlichen Punkten ein bevor die Qualität berechnet wird

### 3.4.4 SURFING



data set A



data set B

eingefügte Punkte	quality(A)	quality(B)
0 %	0.13	0.15
0.1 %	0.15	0.15
0.5 %	0.31	0.15
1 %	0.38	0.15
5 %	0.57	0.15
10 %	0.57	0.15

#### Empirische Ergebnisse:

- 1% eingefügte Punkte reichen aus
- Einfügung nur wenn nötig:

Wenn Qualität eines  $l$ -dimensionalen Unterraums geringer ist als die quality einer  $l$ -dimensionalen Gauss-Verteilung

### 3.4.4 SURFING

---

#### Algorithmus SURFING

- Qualitätskriterium ist nicht monoton!!!
- ABER: Qualität steigt, wenn relevante Attribute hinzu kommen bzw. sinkt, wenn irrelevante Attribute hinzukommen
- Bottom-up Unterraum Generierung ähnlich wie *Apriori*, aber kein Pruning bei der Kandidatengenerierung  
⇒ mehr Kandidaten in jeder Iteration zu Testen
- Heuristisches Pruningkriterium um möglichst viele Unterräume zu löschen (dadurch wird Anzahl der Kandidaten reduziert)
- Komplexität:  $O(N^2 \cdot m)$      $m = \#$  generierter Unterräume


136

### 3.4.4 SURFING

---

#### Parameterwahl

- SURFING hängt nur noch von  $k$  ab!!!
- Wahl von  $k$  relativ einfach:



Durch zufälliges Einfügen wird die Wahl von  $k$  nocheinmal deutlich unkritischer!

137

### 3.4.4 SURFING

---

#### *Fazit*

- SURFING ist dank der Pruning-Heuristik sehr effizient (meist werden nur knapp 1% aller möglichen Unterräume erzeugt)
- SURFING ist mehr oder weniger parameterfrei (Wahl von  $k$  relativ einfach und bei großen, hochdimensionalen Daten typischerweise nicht kritisch)
- SURFING erzielt (in Zusammenarbeit mit OPTICS) bessere experimentelle Ergebnisse als CLIQUE, SUBCLU oder RIS, speziell wenn:
  - Cluster in stark verschiedenen dimensionalen Unterräumen existieren
  - Hierarchische und unterschiedlich dichte Cluster existieren

138

### 3.4.5 FIRES

---

#### *Filter-Refinement Subspace Clustering*

[Kriegel, Kröger, Renz, Wurst 2005]

#### Probleme bisheriger Ansätze

- Globales Dichte-/Clusterkriterium
  - Niedrig dimensionale Unterräume vs. höher dimensionale Unterräume
  - Unterschiedlich dichte Clusters in einem gemeinsamen Unterraum
- Skalierbarkeit (*Apriori*-basierte Algorithmen):
  - Exponentiell bzgl. Dimension des Datenraumes und/oder
  - Exponentiell bzgl. Dimension des Cluster-Teilraumes
- Unvollständigkeit (einfache Heuristiken zur Teilraumsuche)
  - Unvollständige Resultate
- Subspace Ranking  $\Leftrightarrow$  Subspace Clustering
  - Viele Anwendungen benötigen explizite Berechnung der Cluster (z.B. zur automatischen Weiterverarbeitung)


139

### 3.4.5 FIRES

---

#### Filter-Refinement Subspace Clustering (FIRES)

- Preclustering: berechne alle 1D Cluster („Basiscluster“)
- Approximiere Subspace Cluster: verschmelze Basiscluster
- Postprocessing: verfeinere Subspace Cluster Approximationen



140

### 3.4.5 FIRES

---

#### Preclustering

- Berechne alle Cluster in allen 1D Projektionen
- Verwende beliebigen Clusteringalgorithmus
- Resultat: „Basiscluster“

#### Approximation der Subspace Cluster

- Theoretisch:  $O(2^n)$
- Heuristik:
  - Finde Gruppen von „ähnlichen“ Basisclustern, d.h. clustere Basiscluster mit  
DBSCAN [Ester,Kriegel,Sander,Xu KDD'96]  
SNN [Ertöz,Steinbach,Kumar SIAM DM'03]
- Ähnlichkeit zwischen zwei Basisclustern  $c_1$  und  $c_2$  ???
  - Idee: Objekte im Teilraum  $S$  ähnlich  $\Rightarrow$  auch in allen Attributen, die  $S$  aufspannen, ähnlich  $\Rightarrow$  Maximiere Schnittmenge

$$\text{sim}(c_1, c_2) = |c_1 \cap c_2|$$

141


### 3.4.5 FIRES

---

- Theoretisch möglich: DBSCAN-Clustering der Basiscluster
  - ABER: *sim* bevorzugt große Cluster => niedrig dimensionale Teilräume
  - Gewünscht: viele Basiscluster verschmelzen => höher dimensionale Teilräume
  - Verwende daher ein SNN-Ansatz auf Basisclustern

#### *k*-most similar clusters (*k*MSC)

- *k*MSC(*c*<sub>1</sub>): die *k* ähnlichsten Basiscluster (bzgl. *sim*) zu *c*<sub>1</sub>
- Verschmelze die Basiscluster, die möglichst ähnliche *k*MSC haben
- Beispiel (*k* = 4):  
 $c_A \in kMSC(c_F)$   
 $c_F \notin kMSC(c_A)$   
=>  $c_F$  passt nicht zu  $kMSC(c_A)$



142

### 3.4.5 FIRES

---

#### Best Merge Candidates (BMC) eines Clusters *c*<sub>1</sub>

- $BMC(c_1) = \{c_2 \mid Card(kMSC(c_1) \cap kMSC(c_2)) \geq \mu\}$  wobei  $\mu < k$

#### Best Merge Cluster

- *c*<sub>1</sub> ist *Best Merge Cluster* wenn  $Card(BMC(c_1)) \geq minClu$

#### Algorithmus zum Verschmelzen von Basisclustern


- SNN Algorithmus auf Basisclustern
- Output: Menge von Cubspace Cluster Approximationen
- Schritte:
  - Berechne alle Best Merge Cluster
  - Verschmelze Best Merge Cluster, die sich gegenseitig in ihren BMC Mengen finden
  - Weise Basiscluster, die keine Best Merge Cluster, aber in den BMCs eines Best Merge Clusters sind den entsprechenden Approximationen zu

143

### 3.4.5 FIRES


#### Cluster Refinement

- Einfaches Verschmelzen der Basisclusters erzeugt typischerweise nur sehr grobe Approximationen der Subspace Cluster
- Wende einen beliebigen Clustering Algorithmus auf die Vereinigung der verschmolzenen Basiscluster an  
z.B. DBSCAN mit angepassten Parametern




### 3.4.5 FIRES



#### Evaluation Preprocessing





#### Evaluation Postprocessing



#### Evaluation Accuracy



### 3.4.5 FIRES



### 3.4.5 FIRES

Genexpressionsdaten von Hefe  
 Analysiere 4,000 Gene bzgl. 24  
 Zeitpunkten

*Beispiele gefundener Cluster:*

ORF	Gene	Annotation
Cluster 1		
YGL019W	CKB1	subunit of CK2
YOR061W	CKA2	subunit of CK2
YOR236W	DFR1	chorismate pathway
YDR127W	ARO1	chorismate pathway
Cluster 2		
YGR172C	YIP1	ER to Golgi transport
YLR026C	SED5	ER to Golgi transport
YDR299W	BFR2	ER to Golgi transport
YNL287W	SEC21	ER to Golgi transport
Cluster 3		
YDR418W	RPL12B	part of ribosome
YIL133C	RPL16A	part of ribosome
YKL006W	RPL14A	part of ribosome

Genexpressionsdaten von Menschen  
 Analysiere 72 Patienten bzgl. 7070  
 Genen

*Beispiele gefundener Cluster:*

- 27 von 32 Patienten mit Leukämie Typ ALL (sowohl B-cell als auch T-cell Leukämie-Subtypen)
- 15 von 16 Patienten mit Leukämie Typ ALL und zugleich B-cell Leukämie-Subtyp
- 18 von 21 männliche Patienten

# Zusammenfassung: Subspace Clustering

---

## CLIQUE, ENCLUS, MAFIA

- Grid-basiertes Clustermodell
- Direkte Berechnung der Cluster

## SUBCLU

- Dichte-verbundenes Clustermodell
- Direkte Berechnung der Cluster

## RIS

- Dichte-verbundenes Clustermodell
- Ranking der Unterräume (flaches Clustering)

## SURFING

- Dichte-verbundenes Clustermodell
- Ranking der Unterräume (hierarchisches Clustering)

## FIRES

- Beliebiges Clustermodell
- Direkte Berechnung der Cluster

Globaler Dichteparameter  
Subspacesuche:  
Apriori-basiert

Lokal adaptiver  
Dichteparameter  
Subspacesuche:  
Heuristik

Beliebiges Clustermodell  
Subspacesuche:  
Clustering der 1D-Cluster

148

---

## Literatur

---

- C. C. Aggarwal and C. Procopiuc. *Fast Algorithms for Projected Clustering*. Proc. ACM Int. Conf. on Management of Data (SIGMOD), Philadelphia, US, 1999.(PROCLUS)
- Böhm C., Kailing K., Kriegel H.-P., Kröger P.: *Density Connected Clustering with Local Subspace Preferences*, Proc. 4th IEEE Int. Conf. on Data Mining (ICDM'04), Brighton, UK, 2004 (PreDeCon)
- Aggarwal, C., Yu, P.: *Finding Generalized Projected Clusters in High Dimensional Spaces*. Proc. ACM Int. Conf. on Management of Data (SIGMOD), Philadelphia, Dallas, US, 2000 (ORCLUS)
- Böhm C., Kailing K., Kröger P., Zimek A.: *Computing Clusters of Correlation Connected Objects*, Proc. ACM Int. Conf. on Management of Data (SIGMOD), Paris, France, 2004 (4C)
- Achtert E., Böhm C., Kröger P., Zimek A.: *Mining Hierarchies of Correlation Clusters*, Proc. 18th Int. Conf. on Scientific and Statistical Database Management (SSDBM'06), Vienna, Austria, 2006 (HICO)
- R. Agrawal, J. Gehrke, D. Gunopulos, and P. Raghavan. *Automatic Subspace Clustering of High Dimensional Data for Data Mining Applications*. Proc. ACM Int. Conf. on Management of Data (SIGMOD), Seattle, US, 1998.
- Kröger P., Kriegel H.-P., Kailing K.: *Density-Connected Subspace Clustering for High-Dimensional Data*, Proc. SIAM Int. Conf. on Data Mining (SDM'04), Lake Buena Vista, FL, 2004, pp. 246-257.
- Kailing K., Kriegel H.-P., Kröger P., Wanka S.: *Ranking Interesting Subspaces for Clustering High Dimensional Data*, Proc. 7th European Conf. on Principles and Practice of Knowledge Discovery in Databases (PKDD'03), Cavtat-Dubrovnic, Croatia, 2003, (RIS)
- C. Baumgartner, K. Kailing, H.-P. Kriegel, P. Kröger, and C. Plant. *Subspace Selection for Clustering High-Dimensional Data*. Proc. 4th IEEE Int. Conf. on Data Mining (ICDM'04), Brighton, UK, 2004 (SURFING)
- Kriegel H.-P., Kröger P., Renz M., Wurst S.: *A Generic Framework for Efficient Subspace Clustering of High-Dimensional Data*, Proc. 5th IEEE Int. Conf. on Data Mining (ICDM'05), Houston, TX, 2005, pp. 250-257. (FIRES)

149