

3. Clustering

Inhalt dieses Kapitels

3.1 Einleitung

Ziel des Clustering, Distanzfunktionen, Anwendungen, Typen von Algorithmen

3.2 Partitionierende Verfahren

k-means, k-medoid, Expectation Maximization, Initialisierung und Parameterwahl, Probleme optimierender Verfahren, dichte-basierte Verfahren

3.3 Hierarchische Verfahren

Single-Link und Varianten, dichte-basiertes hierarchisches Clustering

3. Clustering

Inhalt dieses Kapitels

3.4 Begriffliches Clustern

Formale Begriffsanalyse, Begriffsverbände

3.5 Datenbanktechniken zur Leistungssteigerung

Indexunterstütztes Sampling, Indexunterstützte Anfragebearbeitung,
Datenkompression mit BIRCH


3.6 Besondere Anforderungen und Verfahren

k-modes, verallgemeinertes dichtebasiertes Clustering,
inkrementelles Clustering, Subspace Clustering

3.1 Einleitung

Ziel des Clustering

- Identifikation einer endlichen Menge von Kategorien, Klassen oder Gruppen (*Cluster*) in den Daten
- Objekte im *gleichen* Cluster sollen möglichst ähnlich sein
- Objekte aus *verschiedenen* Clustern sollen möglichst unähnlich zueinander sein



Cluster unterschiedlicher Größe, Form und Dichte
hierarchische Cluster

3.1 Distanzfunktionen

Grundbegriffe

Formalisierung der Ähnlichkeit

- manchmal: Ähnlichkeitsfunktion
- meist: Distanzfunktion $dist(o_1, o_2)$ für Paare von Objekten o_1 und o_2
- kleine Distanz \approx ähnliche Objekte
- große Distanz \approx unähnliche Objekte

Anforderungen an Distanzfunktionen

- (1) $dist(o_1, o_2) = d \in \mathbb{R}^{\geq 0}$
- (2) $dist(o_1, o_2) = 0$ genau dann wenn $o_1 = o_2$
- (3) $dist(o_1, o_2) = dist(o_2, o_1)$ (Symmetrie)
- (4) zusätzlich für Metriken (Dreiecksungleichung)
 $dist(o_1, o_3) \leq dist(o_1, o_2) + dist(o_2, o_3).$

3.1 Distanzfunktionen

Distanzfunktionen für numerische Attribute

Objekte $x = (x_1, \dots, x_d)$ und $y = (y_1, \dots, y_d)$

Allgemeine L_p -Metrik (Minkowski-Distanz) $dist(x, y) = \sqrt[p]{\sum_{i=1}^d |x_i - y_i|^p}$

Euklidische Distanz ($p = 2$) $dist(x, y) = \sqrt{\sum_{i=1}^d (x_i - y_i)^2}$

Manhattan-Distanz ($p = 1$) $dist(x, y) = \sum_{i=1}^d |x_i - y_i|$

Maximums-Metrik ($p = \infty$) $dist(x, y) = \max\{|x_i - y_i| \mid 1 \leq i \leq d\}$

eine populäre Ähnlichkeitsfunktion: Korrelationskoeffizient $\in [-1, +1]$

3.1 Distanzfunktionen

Andere Distanzfunktionen

- für kategoriale Attribute $dist(x, y) = \sum_{i=1}^d \delta(x_i, y_i)$ mit $\delta(x_i, y_i) = \begin{cases} 0 & \text{falls } x_i = y_i \\ 1 & \text{sonst} \end{cases}$
(Hamming-Distanz)
- für Textdokumente D (Vektoren der Häufigkeit der Terme aus T)

$$d = \{g(f(t_i, D)) \mid t_i \in T\}$$

$f(t_i, D)$: Häufigkeit des Terms t_i in Dokument D

g : monotone *Dämpfungsfunktion* (z.B. *Mult. mit inverser Dok.-Häufigkeit*)

$$dist(x, y) = 1 - \frac{\langle x, y \rangle}{|x| \cdot |y|} \text{ mit } \langle \cdot, \cdot \rangle \text{ Skalarprodukt und } |\cdot| \text{ Länge des Vektors}$$



Adäquatheit der Distanzfunktion ist wichtig für Qualität des Clustering

3.1 Typische Anwendungen

Überblick

- Kundensegmentierung
Clustering der Kundentransaktionen
- Bestimmung von Benutzergruppen auf dem Web
Clustering der Web-Logs
- Strukturierung von großen Mengen von Textdokumenten
Hierarchisches Clustering der Textdokumente
- Erstellung von thematischen Karten aus Satellitenbildern
Clustering der aus den Rasterbildern gewonnenen Featurevektoren

3.1 Typische Anwendungen

Bestimmung von Benutzergruppen auf dem Web

Einträge eines Web-Logs

```
romblon.informatik.uni-muenchen.de lopa - [04/Mar/1997:01:44:50 +0100] "GET /~lopa/ HTTP/1.0" 200 1364
romblon.informatik.uni-muenchen.de lopa - [04/Mar/1997:01:45:11 +0100] "GET /~lopa/x/ HTTP/1.0" 200 712
fixer.sega.co.jp unknown - [04/Mar/1997:01:58:49 +0100] "GET /dbs/porada.html HTTP/1.0" 200 1229
scooter.pa-x.dec.com unknown - [04/Mar/1997:02:08:23 +0100] "GET /dbs/kriegel_e.html HTTP/1.0" 200 1241
```

Generierung von Sessions

Session ::= $\langle \text{IP-Adresse, Benutzer-Id, } [URL_1, \dots, URL_k] \rangle$



 welche Einträge bilden eine Session?

Distanzfunktion für Sessions

$$d(x, y) = \frac{|x \cup y| - |x \cap y|}{|x \cup y|}$$

3.1 Typische Anwendungen

Erstellung von thematischen Karten aus Satellitenbildern



Grundlage

verschiedene Oberflächenbeschaffenheiten der Erde besitzen jeweils ein charakteristisches Reflexions- und Emissionsverhalten

3.1 Typen von Clustering-Verfahren

Partitionierende Verfahren

- Parameter: Anzahl k der Cluster, Distanzfunktion
- sucht ein „flaches“ Clustering in k Cluster mit minimalen Kosten

Hierarchische Verfahren

- Parameter: Distanzfunktion für Punkte und für Cluster
- bestimmt Hierarchie von Clustern, mischt jeweils die ähnlichsten Cluster

Dichtebasierte Verfahren

- Parameter: minimale Dichte in einem Cluster, Distanzfunktion
- erweitert Punkte um ihre Nachbarn solange Dichte groß genug

Andere Clustering-Verfahren

- Fuzzy Clustering
- Graph-theoretische Verfahren
- neuronale Netze

3.2 Partitionierende Verfahren

Grundlagen

Ziel

eine Partitionierung in k Cluster mit minimalen Kosten

Lokal optimierendes Verfahren

- wähle k initiale Cluster-Repräsentanten
- optimiere diese Repräsentanten iterativ
- ordne jedes Objekt seinem ähnlichsten Repräsentanten zu


Typen von Cluster-Repräsentanten

- Mittelwert des Clusters (*Konstruktion zentraler Punkte*)
- Element des Clusters (*Auswahl repräsentativer Punkte*)
- Wahrscheinlichkeitsverteilung des Clusters (*Erwartungsmaximierung*)


3.2 Konstruktion zentraler Punkte

Beispiel



schlechtes Clustering



Cluster-Repräsentanten



optimales Clustering



3.2 Konstruktion zentraler Punkte

Grundbegriffe [Forgy 1965]

- Objekte sind Punkte $p=(x^p_1, \dots, x^p_d)$ in einem euklidischen Vektorraum
- euklidische Distanz
- *Centroid* μ_C : Mittelwert aller Punkte im Cluster C
- *Maß für die Kosten* (Kompaktheit) *eines Clusters* C

$$TD^2(C) = \sum_{p \in C} dist(p, \mu_C)^2$$

- *Maß für die Kosten* (Kompaktheit) *eines Clustering*

$$TD^2 = \sum_{i=1}^k TD^2(C_i)$$

3.2 Konstruktion zentraler Punkte

Algorithmus

ClusteringDurchVarianzMinimierung(Punktmenge D ,
Integer k)

Erzeuge eine „initiale“ Zerlegung der Punktmenge D
in k Klassen;

Berechne die Menge $C' = \{C'_1, \dots, C'_k\}$ der Centroide
für die k Klassen;

$C = \{\}$;

repeat until $C = C'$

$C = C'$;


Bilde k Klassen durch Zuordnung jedes Punktes
zum nächstliegenden Centroid aus C ;

Berechne die Menge $C' = \{C'_1, \dots, C'_k\}$ der
Centroide für die neu bestimmten Klassen;


return C ;

3.2 Konstruktion zentraler Punkte


Beispiel




Berechnung der
neuen Centroide



Zuordnung zum nächsten Centroid ↓



Berechnung der
neuen Centroide



3.2 Konstruktion zentraler Punkte

Varianten des Basis-Algorithmus

k-means [MacQueen 67]

- Idee: die betroffenen Centroide werden direkt aktualisiert, wenn ein Punkt seine Clusterzugehörigkeit ändert
- *K-means* hat im wesentlichen die Eigenschaften des Basis-Algorithmus
- *K-means* ist aber reihenfolgeabhängig

ISODATA

- basiert auf *k-means*
- Verbesserung des Ergebnisses durch Operationen wie
 - Elimination sehr kleiner Cluster
 - Verschmelzung und Aufspalten von Clustern
- Benutzer muß viele zusätzliche Parameter angeben

3.2 Konstruktion zentraler Punkte

Diskussion

+ Effizienz

Aufwand: $O(n)$ für eine Iteration,

Anzahl der Iterationen ist im allgemeinen klein ($\sim 5 - 10$).

+ einfache Implementierung

➡ *K*-means ist das populärste partitionierende Clustering-Verfahren

- Anfälligkeit gegenüber Rauschen und Ausreißern
alle Objekte gehen ein in die Berechnung des Centroids
- Cluster müssen konvexe Form haben
- die Anzahl *k* der Cluster ist oft schwer zu bestimmen
- starke Abhängigkeit von der initialen Zerlegung
sowohl Ergebnis als auch Laufzeit

3.2 Auswahl repräsentativer Punkte

Grundbegriffe [Kaufman & Rousseeuw 1990]

- setze nur Distanzfunktion für Paare von Objekten voraus
- *Medoid*: ein zentrales Element des Clusters (repräsentativer Punkt)
- *Maß für die Kosten* (Kompaktheit) *eines Clusters* C

$$TD(C) = \sum_{p \in C} dist(p, mc)$$

- *Maß für die Kosten* (Kompaktheit) *eines Clustering*

$$TD = \sum_{i=1}^k TD(C_i)$$

- Suchraum für den Clustering-Algorithmus: alle k -elementigen Partitionen der Datenbank D mit $|D| = n$



die Laufzeitkomplexität der erschöpfenden Suche ist $O(n^k)$

3.2 Auswahl repräsentativer Punkte

Überblick über die Algorithmen

PAM [Kaufman & Rousseeuw 1990]

- Greedy-Algorithmus:
in jedem Schritt wird nur ein Medoid mit einem Nicht-Medoid vertauscht
- vertauscht in jedem Schritt das Paar (Medoid, Nicht-Medoid), das die größte Reduktion der Kosten TD bewirkt

CLARANS [Ng & Han 1994]

zwei zusätzliche Parameter: *maxneighbor* und *numlocal*

- höchstens *maxneighbor* viele von zufällig ausgewählten Paaren (Medoid, Nicht-Medoid) werden betrachtet
- die erste Ersetzung, die überhaupt eine Reduzierung des TD -Wertes bewirkt, wird auch durchgeführt
- die Suche nach k „optimalen“ Medoiden wird *numlocal* mal wiederholt

3.2 Auswahl repräsentativer Punkte

Algorithmus PAM

```
PAM(Objektmenge D, Integer k, Float dist)
  Initialisiere die k Medoide;
  TD_Änderung :=  $-\infty$ ;
  while TD_Änderung < 0 do
    Berechne für jedes Paar (Medoid M, Nicht-Medoid N)
      den Wert  $TD_{N \leftrightarrow M}$ ;
    Wähle das Paar (M, N), für das der Wert
       $TD\_Änderung := TD_{N \leftrightarrow M} - TD$  minimal ist;
    if TD_Änderung < 0 then
      ersetze den Medoid M durch den Nicht-Medoid N;
      Speichere die aktuellen Medoide als die bisher
        beste Partitionierung;
  return Medoide;
```

3.2 Auswahl repräsentativer Punkte

Algorithmus CLARANS

```
CLARANS(Objektmenge D, Integer k, Real dist,  
         Integer numlocal, Integer maxneighbor)  
for r from 1 to numlocal do  
  wähle zufällig k Objekte als Medoide; i := 0;  
  while i < maxneighbor do  
    Wähle zufällig (Medoid M, Nicht-Medoid N);  
    Berechne TD_Änderung :=  $TD_{N \leftrightarrow M} - TD$ ;  
    if TD_Änderung < 0 then  
      ersetze M durch N;  
      TD :=  $TD_{N \leftrightarrow M}$ ; i := 0;  
    else i := i + 1;  
  if TD < TD_best then  
    TD_best := TD; Merke die aktuellen Medoide;  
return Medoide;
```

3.2 Auswahl repräsentativer Punkte


Vergleich von PAM und CLARANS

Laufzeitkomplexitäten

- PAM: $O(n^3 + k(n-k)^2 * \#Iterationen)$
- CLARANS $O(numlocal * maxneighbor * \#Ersetzungen * n)$
praktisch $O(n^2)$

Experimentelle Untersuchung


Qualität



TD(CLARANS)

TD(PAM)

Laufzeit



3.2 Erwartungsmaximierung

Grundbegriffe [Dempster, Laird & Rubin 1977]

- Objekte sind Punkte $p=(x^p_1, \dots, x^p_d)$ in einem euklidischen Vektorraum
- ein Cluster wird durch eine Wahrscheinlichkeitsverteilung beschrieben
- typischerweise: Gaußverteilung (Normalverteilung)
- Repräsentation eines Clusters C
 - Mittelwert μ_C aller Punkte des Clusters
 - $d \times d$ Kovarianzmatrix Σ_C für die Punkte im Cluster C
- Wahrscheinlichkeitsdichte eines Clusters C

$$P(x|C) = \frac{1}{\sqrt{(2\pi)^d |\Sigma_C|}} e^{-\frac{1}{2} \cdot (x-\mu_C)^T \cdot (\Sigma_C)^{-1} \cdot (x-\mu_C)}$$

3.2 Erwartungsmaximierung

Grundbegriffe

- Wahrscheinlichkeitsdichte eines Clusterings $M = \{C_1, \dots, C_k\}$

$$P(x) = \sum_{i=1}^k W_i \cdot P(x|C_i)$$

mit W_i Anteil der Punkte aus D in C_i

- Zuordnung von Punkten zu Clustern

$$P(C_i|x) = W_i \cdot \frac{P(x|C_i)}{P(x)}$$



Punkt gehört zu mehreren Clustern mit unterschiedlicher Wahrscheinlichkeit

- Maß für die Güte (Wahrscheinlichkeit) eines Clustering M

$$E(M) = \sum_{x \in D} \log(P(x))$$

➔ je größer der Wert E ist, desto wahrscheinlicher sind die gegebenen Daten D , geg. die berechnete Verteilung

$E(M)$ soll maximiert werden

3.2 Erwartungsmaximierung

Algorithmus

ClusteringDurchErwartungsmaximierung

(Punktmenge D , Integer k)

Erzeuge ein „initiales“ Modell $M' = (C_1', \dots, C_k')$;

repeat // „Neuzuordnung“

Berechne $P(x|C_i)$, $P(x)$ und $P(C_i|x)$ für jedes Objekt aus D und jede Gaußverteilung/jeden Cluster C_i ;

// „Neuberechnung des Modells“

Berechne ein neues Modell $M = \{C_1, \dots, C_k\}$ durch Neuberechnung von W_i , μ_C und Σ_C für jedes i ;

$M' := M$;

until $|E(M) - E(M')| < \varepsilon$;

return M ;

Neuberechnung der Parameter

$$W_i = \frac{1}{n} \sum_{x \in D} P(C_i | x)$$

$$\mu_i = \frac{\sum_{x \in D} x \cdot P(C_i | x)}{\sum_{x \in D} P(C_i | x)}$$

$$\Sigma_i = \frac{\sum_{x \in D} P(C_i | x) (x - \mu_i)(x + \mu_i)^T}{\sum_{x \in D} P(C_i | x)}$$

3.2 Erwartungsmaximierung

Diskussion

- Konvergiert gegen ein (möglicherweise nur *lokales*) Minimum
- Aufwand:
 -  $O(n * |M| * \#Iterationen)$
Anzahl der benötigten Iterationen im allgemeinen sehr hoch
- Ergebnis und Laufzeit hängen stark ab
 - von der initialen Zuordnung
 - von der „richtigen“ Wahl des Parameters k
- Modifikation für Partitionierung der Daten in k *disjunkte* Cluster:
jedes Objekt nur demjenigen Cluster zuordnen,
zu dem es am wahrscheinlichsten gehört.

3.2 Wahl des initialen Clustering

Idee

- Clustering einer kleinen Stichprobe liefert im allgemeinen gute initiale Cluster
- einzelne Stichproben sind evtl. deutlich anders verteilt als die Grundgesamtheit

Methode [Fayyad, Reina & Bradley 1998]

- ziehe unabhängig voneinander m verschiedene Stichproben
- clustere jede der Stichproben


➡ m verschiedene Schätzungen für k Clusterzentren

$$A = (A_1, A_2, \dots, A_k), B = (B_1, \dots, B_k), C = (C_1, \dots, C_k), \dots$$

- Clustere nun die Menge $DB = A \cup B \cup C \cup \dots$
mit m verschiedenen Initialisierungen A, B, C, \dots
- Wähle von den m Clusterings dasjenige mit dem besten Wert
bezüglich des zugehörigen Maßes für die Güte eines Clustering


3.2 Wahl des initialen Clustering

Beispiel



Grundgesamtheit

$k = 3$ Gauß-Cluster



DB

von $m = 4$ Stichproben

x wahre Clusterzentren

3.2 Wahl des Parameters k

Methode

- Bestimme für $k = 2, \dots, n-1$ jeweils ein Clustering
- Wähle aus der Menge der Ergebnisse das „beste“ Clustering aus

Maß für die Güte eines Clusterings

- muß unabhängig von der Anzahl k sein
- bei k -means und k -medoid:

TD^2 und TD sinken monoton mit steigendem k

- bei EM:

E sinkt monoton mit steigendem k

3.2 Wahl des Parameters k

Silhouetten-Koeffizient [Kaufman & Rousseeuw 1990]

- ein von k unabhängiges Gütemaß für die k -means- und k -medoid-Verfahren
- sei $a(o)$ der Abstand eines Objekts o zum Repräsentanten seines Clusters und $b(o)$ der Abstand zum Repräsentanten des „zweitnächsten“ Clusters

- Silhouette $s(o)$ von o

$$s(o) = \frac{b(o) - a(o)}{\max\{a(o), b(o)\}}$$

$s(o) = -1 / 0 / +1$: schlechte / indifferente / gute Zuordnung

- Silhouettenkoeffizient s_C eines Clustering
durchschnittliche Silhouette aller Objekte
- Interpretation des Silhouettenkoeffizients
 - $s_C > 0,7$: starke Struktur,
 - $s_C > 0,5$: brauchbare Struktur, . . .

3.2 Dichtebasiertes Clustering

Grundlagen

Idee

- Cluster als Gebiete im d -dimensionalen Raum, in denen die Objekte dicht beieinander liegen
- getrennt durch Gebiete, in denen die Objekte weniger dicht liegen

Anforderungen an dichtebasierte Cluster


- für jedes Objekt eines Clusters überschreitet die lokale Punktdichte einen gegebenen Grenzwert
- die Menge von Objekten, die den Cluster ausmacht, ist räumlich zusammenhängend

3.2 Dichtebasiertes Clustering


Grundbegriffe [Ester, Kriegel, Sander & Xu 1996]

- Ein Objekt $o \in O$ heißt *Kernobjekt*, wenn gilt:

$$|N_\varepsilon(o)| \geq \text{MinPts}, \text{ wobei } N_\varepsilon(o) = \{o' \in O \mid \text{dist}(o, o') \leq \varepsilon\}.$$




- Ein Objekt $p \in O$ ist *direkt dichte-erreichbar* von $q \in O$ bzgl. ε und MinPts , wenn gilt: $p \in N_\varepsilon(q)$ und q ist ein Kernobjekt in O .
- Ein Objekt p ist *dichte-erreichbar* von q , wenn es eine Kette von direkt erreichbaren Objekten zwischen q und p gibt.



3.2 Dichtebasiertes Clustering

Grundbegriffe

- Zwei Objekte p und q sind *dichte-verbunden*, wenn sie beide von einem dritten Objekt o aus dichte-erreichbar sind.



- Ein *Cluster* C bzgl. ε und $MinPts$ ist eine nicht-leere Teilmenge von O , für die die folgenden Bedingungen erfüllt sind:
 - *Maximalität*: $\forall p, q \in O$: wenn $p \in C$ und q dichte-erreichbar von p ist, dann ist auch $q \in C$.
 - *Verbundenheit*: $\forall p, q \in C$: p ist dichte-verbunden mit q .

3.2 Dichtebasiertes Clustering

Grundbegriffe

- Definition Clustering

Ein *dichte-basiertes Clustering* CL der Menge O bzgl. ε und $MinPts$ ist eine „vollständige“ Menge von dichte-basierten Clustern bzgl. ε und $MinPts$ in O .

- Dann ist die Menge $Noise_{CL}$ („Rauschen“) definiert als die Menge aller Objekte aus O , die nicht zu einem der dichte-basierten Cluster C_i gehören.

- Grundlegende Eigenschaft

Sei C ein dichte-basierter Cluster und sei $p \in C$ ein Kernobjekt. Dann gilt:
 $C = \{o \in O \mid o \text{ dichte-erreichbar von } p \text{ bzgl. } \varepsilon \text{ und } MinPts\}$.

3.2 Dichtebasiertes Clustering

Algorithmus DBSCAN


```
DBSCAN(Objektmenge D, Real  $\varepsilon$ , Integer MinPts)
// Zu Beginn sind alle Objekte unklassifiziert,
// o.ClId = UNKLASSIFIZIERT für alle o  $\in$  Objektmenge

ClusterId := nextId(NOISE);
for i from 1 to |D| do
    Objekt := D.get(i);
    if Objekt.ClId = UNKLASSIFIZIERT then
        if ExpandiereCluster(D, Objekt, ClusterId,  $\varepsilon$ ,
            MinPts)
        then ClusterId:=nextId(ClusterId);
```

3.2 Dichtebasiertes Clustering

Parameterbestimmung

- Cluster: Dichte größer als die durch ε und $MinPts$ spezifizierte „Grenzdichte“
- Gesucht: der am wenigsten dichte Cluster in der Datenmenge
- Heuristische Methode: betrachte die Distanzen zum k -nächsten Nachbarn.




- Funktion k -Distanz: Distanz eines Objekts zu seinem k -nächsten Nachbarn
- k -Distanz-Diagramm: die k -Distanzen aller Objekte absteigend sortiert

3.2 Dichtebasiertes Clustering

Parameterbestimmung

Beispiel eines k -Distanz-Diagramms





Heuristische Methode

- Benutzer gibt einen Wert für k vor (Default ist $k = 2 * d - 1$), $MinPts := k + 1$.
- System berechnet das k -Distanz-Diagramm und zeigt das Diagramm an.
- Der Benutzer wählt ein Objekt o im k -Distanz-Diagramm als Grenzobjekt aus, $\varepsilon := k\text{-Distanz}(o)$.

3.2 Dichtebasiertes Clustering

Probleme der Parameterbestimmung

- hierarchische Cluster
- stark unterschiedliche Dichte in verschiedenen Bereichen des Raumes
- Cluster und Rauschen sind nicht gut getrennt



3.3 Hierarchische Verfahren

Grundlagen

Ziel

Konstruktion einer Hierarchie von Clustern (*Dendrogramm*), so daß immer die Cluster mit minimaler Distanz verschmolzen werden

Dendrogramm


ein Baum, dessen Knoten jeweils ein Cluster repräsentieren, mit folgenden Eigenschaften:

- die Wurzel repräsentiert die ganze DB
- die Blätter repräsentieren einzelne Objekte
- ein innerer Knoten repräsentiert die Vereinigung aller Objekte, die im darunterliegenden Teilbaum repräsentiert werden

3.3 Hierarchische Verfahren

Grundlagen

Beispiel eines Dendrogramms



Typen von hierarchischen Verfahren

- Bottom-Up Konstruktion des Dendrogramms (*agglomerative*)
- Top-Down Konstruktion des Dendrogramms (*divisive*)

3.3 Single-Link und Varianten

Algorithmus Single-Link [Jain & Dubes 1988]

Agglomeratives hierarchisches Clustering

1. Bilde initiale Cluster, die jeweils aus einem Objekt bestehen, und bestimme die Distanzen zwischen allen Paaren dieser Cluster.
2. Bilde einen neuen Cluster aus den zwei Clustern, welche die geringste Distanz zueinander haben.
3. Bestimme die Distanz zwischen dem neuen Cluster und allen anderen Clustern.
4. Wenn alle Objekte sich in einem einzigen Cluster befinden: Fertig, andernfalls wiederhole ab Schritt 2.

3.3 Single-Link und Varianten

Distanzfunktionen für Cluster

- Sei eine Distanzfunktion $dist(x,y)$ für Paare von Objekten gegeben.
- Seien X, Y Cluster, d.h. Mengen von Objekten.

$$\textit{Single-Link} \quad dist - sl(X, Y) = \min_{x \in X, y \in Y} dist(x, y)$$

$$\textit{Complete-Link} \quad dist - cl(X, Y) = \max_{x \in X, y \in Y} dist(x, y)$$

$$\textit{Average-Link} \quad dist - al(X, Y) = \frac{1}{|X| \cdot |Y|} \cdot \sum_{x \in X, y \in Y} dist(x, y)$$

3.3 Single-Link und Varianten

Diskussion


- + erfordert keine Kenntnis der Anzahl k der Cluster
- + findet nicht nur ein flaches Clustering, sondern eine ganze Hierarchie
- + ein einzelnes Clustering kann aus dem Dendrogramm gewonnen werden, z.B. mit Hilfe eines horizontalen Schnitts durch das Dendrogramm
(erfordert aber wieder Anwendungswissen)

- Entscheidungen können nicht zurückgenommen werden
- Anfälligkeit gegenüber Rauschen (Single-Link)
eine „Linie“ von Objekten kann zwei Cluster verbinden
- Ineffizienz
Laufzeitkomplexität von mindestens $O(n^2)$ für n Objekte

3.3 Single-Link und Varianten

CURE [Guha, Rastogi & Shim 1998]

- Repräsentation eines Clusters
 - partitionierende Verfahren: ein Punkt
 - hierarchische Verfahren: alle Punkte
- CURE: Repräsentation eines Clusters durch c Repräsentanten
- die Repräsentanten werden um den Faktor α zum Centroid gestreckt




Entdecken nicht-konvexer Cluster
Vermeidung des Single-Link Effekts

3.3 Dichte-basiertes hierarchisches Clustering

Grundlagen [Ankerst, Breunig, Kriegel & Sander 1999]

- für einen konstanten *MinPts*-Wert sind dichte-basierte Cluster bzgl. eines kleineren ε vollständig in Clustern bzgl. eines größeren ε enthalten



- in einem DBSCAN-ähnlichen Durchlauf gleichzeitig das Clustering für verschiedene Dichte-Parameter bestimmen
 - zuerst den dichteren Teil-Cluster, dann den dünneren Rest-Cluster
- kein Dendrogramm, sondern eine auch noch bei sehr großen Datenmengen übersichtliche Darstellung der Cluster-Hierarchie

3.3 Dichte-basiertes hierarchisches Clustering


Grundbegriffe

Kerndistanz eines Objekts p bzgl. ε und $MinPts$

$$\text{Kerndistanz } z_{\varepsilon, MinPts}(o) = \begin{cases} UNDEFINIERT, & \text{wenn } |N_{\varepsilon}(o)| < MinPts \\ \text{Min} - \text{Pts} - \text{Distanz } z(o), & \text{sonst} \end{cases}$$

Erreichbarkeitsdistanz eines Objekts p relativ zu einem Objekt o


$$\text{Erreichbarkeitsdistanz } z_{\varepsilon, MinPts}(p, o) = \begin{cases} UNDEFINIERT, & \text{wenn } |N_{\varepsilon}(o)| < MinPts \\ \max\{\text{Kerndistanz } z(o), \text{dist}(o, p)\}, & \text{sonst} \end{cases}$$



3.3 Dichte-basiertes hierarchisches Clustering

Clusterordnung



- OPTICS liefert nicht direkt ein (hierarchisches) Clustering, sondern eine „Clusterordnung“ bzgl. ϵ und $MinPts$
- Clusterordnung bzgl. ϵ und $MinPts$
 - beginnt mit einem beliebigen Objekt
 - als nächstes wird das Objekt besucht, das zur Menge der bisher besuchten Objekte die minimale Erreichbarkeitsdistanz besitzt



3.3 Dichte-basiertes hierarchisches Clustering


Erreichbarkeits-Diagramm

- Zeigt die Erreichbarkeitsdistanzen (bzgl. ϵ und $MinPts$) der Objekte als senkrechte, nebeneinander liegende Balken
- in der durch die Clusterordnung der Objekte gegebenen Reihenfolge.




3.3 Dichte-basiertes hierarchisches Clustering

Parameter-Sensitivität



$MinPts = 10, \epsilon = 10$



optimale Parameter

$MinPts = 10, \epsilon = 5$



kleineres ϵ

$MinPts = 2, \epsilon = 10$



kleineres $MinPts$



Clusterordnung ist robust gegenüber den Parameterwerten
gute Resultate wenn Parameterwerte „groß genug“

3.3 Dichte-basiertes hierarchisches Clustering


Heuristische Parameter-Bestimmung

ε

- wähle größte *MinPts*-Distanz aus einem Sample oder
- berechne durchschnittliche *MinPts*-Distanz für gleichverteilte Daten

MinPts

- glätte Erreichbarkeits-Diagramm
- vermeide “single-” bzw. “*MinPts*-link” Effekt



3.3 Dichte-basiertes hierarchisches Clustering

Manuelle Analyse der Cluster


Mit Erreichbarkeits-Diagramm

- gibt es Cluster?
- wieviele Cluster?
- sind die Cluster hierarchisch geschachtelt?
- wie groß sind die Cluster?

Mit Attributs-Diagramm

- warum existieren die Cluster?
- worin unterscheiden sich die Cluster?

Erreichbarkeits-Diagramm



Attributs-Diagramm

3.3 Dichte-basiertes hierarchisches Clustering

Automatisches Entdecken von Clustern

ξ -Cluster

- Teilsequenz der Clusterordnung
- beginnt in einem Gebiet ξ -steil *abfallender* Erreichbarkeitsdistanzen
- endet in einem Gebiet ξ -steil *steigender* Erreichbarkeitsdistanzen bei etwa demselben absoluten Wert
- enthält mindestens *MinPts* Punkte



Algorithmus

- bestimmt alle ξ -Cluster
- markiert die gefundenen Cluster im Erreichbarkeits-Diagramm
- Laufzeitaufwand $O(n)$

