

Kapitel ML: IX

IX. Clusteranalyse

- ❑ Einordnung Data Mining
- ❑ Einführung in die Clusteranalyse
- ❑ Hierarchische Verfahren
- ❑ Iterative Verfahren
- ❑ Dichtebasierte Verfahren
- ❑ Cluster Evaluation
- ❑ Constrained Cluster Analysis

ML: IX-1 Cluster Analysis

©STEIN 2002-2012

Einordnung Data Mining

Definition 1 (Data Mining)

Unter Data Mining versteht man das systematische, in der Regel automatisierte oder halbautomatische Entdecken und Extrahieren bislang unbekannter Zusammenhänge aus großen Mengen von Daten.


Data Mining umfasst folgende Schritte:

1. Aufgabendefinition
2. Datenselektion
3. Datenvorbereitung und -transformation
4. Mustererkennung
5. Kommunikation, Präsentation

ML: IX-2 Cluster Analysis

©STEIN 2002-2012

Einordnung Data Mining



Definition 2 (Knowledge Discovery in Databases, KDD)

Wissensentdeckung in Datenbanken (*Knowledge Discovery in Databases*) ist der nichttriviale Prozess der Identifikation gültiger, neuer, potentiell nützlicher und schlussendlich verständlicher Muster in großen Datenbeständen.

[vgl. Fayyad 1996, Wrobel 1998]

ML: IX-3 Cluster Analysis

©STEIN 2002-2012


Bemerkungen:

- ❑ Data-Mining-Techniken werden der *explorativen Datenanalyse* zugeordnet. Ziel der explorativen Datenanalyse ist – über die Darstellung der Daten hinaus – die Suche nach Strukturen und Besonderheiten. Die explorative Datenanalyse wird eingesetzt, wenn die Fragestellung oder die Wahl eines geeigneten statistischen Modells unklar ist.
- ❑ In der Data-Mining-Definition wird auf den Begriff der Information verzichtet: Data Mining wird der sigmatischen Ebene der Semiotik zugeordnet. Die *Interpretation* der entdeckten Muster, also die im Rahmen der explorativen Datenanalyse stattfindende Auseinandersetzung mit Informationen im Sinne eines subjektiven Wissenszuwachses, die auf der pragmatischen Ebene abläuft, gehört in das Gebiet des Knowledge Discovery in Databases, KDD.
- ❑ Vor allem im kommerziellen Bereich wird der Begriff des Data Mining synonym zu Wissensentdeckung in Datenbanken (KDD) verwendet. Data Mining ist aber nur ein Teilschritt innerhalb des KDD-Prozesses, nämlich der Analyseschritt zur Mustererkennung.
- ❑ Unter Web Mining versteht man die Übertragung von Techniken des Data Mining zur (teil)automatischen Extraktion von Informationen aus dem Internet, speziell dem World Wide Web. Mit Text Mining wird die Entdeckung neuer und für den Benutzer relevanter Informationen aus Textdaten bezeichnet.

ML: IX-4 Cluster Analysis

©STEIN 2002-2012


Einordnung Data Mining



ML: IX-5 Cluster Analysis

©STEIN 2002-2012


Einordnung Data Mining



ML: IX-6 Cluster Analysis

©STEIN 2002-2012


Einordnung Data Mining



ML: IX-7 Cluster Analysis

©STEIN 2002-2012

Einordnung Data Mining



ML: IX-8 Cluster Analysis

©STEIN 2002-2012

Bemerkungen:

- Eine klare Abgrenzung von Machine Learning und Data Mining ist nicht immer möglich; ein wichtiger Unterschied resultiert aus der Größe der behandelten Datenmengen: Anwendungen des Machine Learning laufen typischerweise im Hauptspeicher ab; die Disziplin des Data Mining entstand aus der Notwendigkeit, maschinelle Analyseverfahren auf große Datenbanken anzuwenden.
- Ein Schwerpunkt des Machine Learning ist der eigentliche Lern- bzw. Deduktionsprozess wie die Theorie des analogen Schließens, das Lernen aus Beispielen, oder der Einfluss der Umwelt auf das Lernen. Hingegen ist die treibende Kraft hinter Data Mining die Industrie- und Geschäftswelt mit ihren großen Datenbanken.
- Zu den bekannten Aufgabenstellung des Data Mining gehören: ungerichtete Abhängigkeitsanalyse zur Identifikation signifikanter Abhängigkeiten zwischen den Attributen eines Informationsobjektes (Beispiel: Warenkorbanalyse), Gruppenbildung und Klassifikationsprobleme, Filtern von Prozessdaten, Prognoseaufgaben.

ML: IX-9 Cluster Analysis

©STEIN 2002-2012

Einordnung Data Mining

Methoden und Techniken

- Clusteranalyse
- propositionale (oder relative) Regellernverfahren
- assoziative Regellernverfahren
- Hauptkomponenten- und Faktoranalyse

ML: IX-10 Cluster Analysis

©STEIN 2002-2012

Kapitel ML: IX (Fortsetzung)

IX. Clusteranalyse

- Einordnung Data Mining
- Einführung in die Clusteranalyse
- Hierarchische Verfahren
- Iterative Verfahren
- Dichtebasierte Verfahren
- Cluster Evaluation
- Constrained Cluster Analysis

ML: IX-11 Cluster Analysis

©STEIN 2002-2012

Einführung in die Clusteranalyse

Clusteranalyse ist die **unüberwachte** Klassifikation einer Menge von Objekten in Gruppen; dabei wird folgendes Ziel verfolgt:

1. Ähnlichkeit innerhalb der Gruppen maximieren
2. Ähnlichkeit zwischen den Gruppen minimieren

ML: IX-12 Cluster Analysis

©STEIN 2002-2012

Einführung in die Clusteranalyse

Clusteranalyse ist die **unüberwachte** Klassifikation einer Menge von Objekten in Gruppen; dabei wird folgendes Ziel verfolgt:

1. Ähnlichkeit innerhalb der Gruppen maximieren
2. Ähnlichkeit zwischen den Gruppen minimieren

Anwendungen

- Identifikation gleichartiger Käufergruppen
- „höhere“ Bildverarbeitung, im Sinne von Objekterkennung
- Suche nach ähnlichen Genprofilen
- Spezifikation von Syndromen
- Analyse von Verkehrsdaten in Computernetzen
- Visualisierung komplexer Graphen
- Textkategorisierung im Information-Retrieval

ML: IX-13 Cluster Analysis

©STEIN 2002-2012

Bemerkungen:

- Die Problemstellung der Clusteranalyse ist umgekehrt zur Problemstellung der Varianzanalyse. Ziel der Varianzanalyse ist die Überprüfung, ob eine gegebene nominalskalierte Variable Gruppen definiert, deren Mitglieder sich in abhängigen (intervallskalierten) Variablen unterscheiden. Ziel der Clusteranalyse ist die Erzeugung einer solchen nominalskalierten Variable durch die Entdeckung der Ausprägungen dieser Variable. Jedes Cluster korrespondiert zu einer Variablenausprägung.
- Die Clusteranalyse ist ein Verfahren zur **Strukturerzeugung**: Man weiß quasi nichts über die zu entdeckende Variable, insbesondere nichts über die Anzahl ihrer Werteausprägungen. Die Varianzanalyse ist ein Verfahren zur **Strukturprüfung**.

ML: IX-14 Cluster Analysis

©STEIN 2002-2012

Einführung in die Clusteranalyse

$\mathbf{x}_1, \dots, \mathbf{x}_n$ sind die zu n Objekten gehörenden p -dimensionalen Merkmalsvektoren:

	Merkmal 1	Merkmal 2	...	Merkmal p
$\mathbf{x}_1$	x_{11}	x_{12}	...	x_{1p}
$\mathbf{x}_2$	x_{21}	x_{22}	...	x_{2p}
$\vdots$				
$\mathbf{x}_n$	x_{n1}	x_{n2}	...	x_{np}

ML: IX-15 Cluster Analysis

©STEIN 2002-2012

Einführung in die Clusteranalyse

$\mathbf{x}_1, \dots, \mathbf{x}_n$ sind die zu n Objekten gehörenden p -dimensionalen Merkmalsvektoren:

	Merkmal 1	Merkmal 2	...	Merkmal p	kein Zielkonzept
$\mathbf{x}_1$	x_{11}	x_{12}	...	x_{1p}	c_1
$\mathbf{x}_2$	x_{21}	x_{22}	...	x_{2p}	c_2
$\vdots$					$\vdots$
$\mathbf{x}_n$	x_{n1}	x_{n2}	...	x_{np}	c_n

ML: IX-16 Cluster Analysis


©STEIN 2002-2012

Einführung in die Clusteranalyse

$\mathbf{x}_1, \dots, \mathbf{x}_n$ sind die zu n Objekten gehörenden p -dimensionalen Merkmalsvektoren:

	Merkmal 1	Merkmal 2	...	Merkmal p	kein Zielkonzept
$\mathbf{x}_1$	x_{11}	x_{12}	...	x_{1p}	c_1
$\mathbf{x}_2$	x_{21}	x_{22}	...	x_{2p}	c_2
$\vdots$					$\vdots$
$\mathbf{x}_n$	x_{n1}	x_{n2}	...	x_{np}	c_n

30 zweidimensionale Merkmalsvektoren ($n = 30, p = 2$):



ML: IX-17 Cluster Analysis

©STEIN 2002-2012

Einführung in die Clusteranalyse

Definition 2 (exklusives Clustering [vgl. Splitting])

Sei X eine Menge von Merkmalsvektoren. Ein exklusives Clustering $\mathcal{C}$ von X , $\mathcal{C} = \{C_1, C_2, \dots, C_k\}$, $C_i \subseteq X$, ist eine Aufteilung von X in nichtleere und paarweise disjunkte Teilmengen C_i mit $\bigcup_{C_i \in \mathcal{C}} C_i = X$.

ML: IX-18 Cluster Analysis

©STEIN 2002-2012

Einführung in die Clusteranalyse

Definition 2 (exklusives Clustering [vgl. Splitting])

Sei X eine Menge von Merkmalsvektoren. Ein exklusives Clustering $\mathcal{C}$ von X , $\mathcal{C} = \{C_1, C_2, \dots, C_k\}$, $C_i \subseteq X$, ist eine Aufteilung von X in nichtleere und paarweise disjunkte Teilmengen C_i mit $\bigcup_{C_i \in \mathcal{C}} C_i = X$.

Algorithmen zur Clusteranalyse sind unüberwachte Lernverfahren:

- der Lernprozess ist selbstorganisiert
- es gibt keinen externen Lehrer
- es gibt ein aufgabenunabhängiges Optimierungskriterium

Einführung in die Clusteranalyse

Definition 2 (exklusives Clustering [vgl. Splitting])

Sei X eine Menge von Merkmalsvektoren. Ein exklusives Clustering $\mathcal{C}$ von X , $\mathcal{C} = \{C_1, C_2, \dots, C_k\}$, $C_i \subseteq X$, ist eine Aufteilung von X in nichtleere und paarweise disjunkte Teilmengen C_i mit $\bigcup_{C_i \in \mathcal{C}} C_i = X$.

Algorithmen zur Clusteranalyse sind unüberwachte Lernverfahren:


- der Lernprozess ist selbstorganisiert
- es gibt keinen externen Lehrer
- es gibt ein aufgabenunabhängiges Optimierungskriterium

Überwachtes Lernen:

- es gibt Lernziele: das Zielkonzept, gewünschte Reaktionen, etc.
- es gibt ein aufgabenabhängiges Optimierungskriterium
- es gibt Information darüber, wie eine Verbesserung im Optimierungskriterium zu erzielen ist. Stichwort: Instructive Feedback

Einführung in die Clusteranalyse

Grundschritte einer Clusteranalyse



Einführung in die Clusteranalyse

Merkmalextrahierung und -aufbereitung

Gesucht sind evtl. neue Merkmale mit hoher Varianz. Techniken:

- Analyse von Streuungsparametern
- Dimensionsreduktion: Faktoranalyse, multidimensionale Skalierung
- Visuelle Analyse: Scatter-Plots, Box-plots

Einführung in die Clusteranalyse

Merkmalextrahierung und -aufbereitung

Gesucht sind evtl. neue Merkmale mit hoher Varianz. Techniken:

- Analyse von Streuungsparametern
- Dimensionsreduktion: Faktoranalyse, multidimensionale Skalierung
- Visuelle Analyse: Scatter-Plots, Box-plots

Standardisierung von Variablen (Merkmalen) ist problematisch:



Einführung in die Clusteranalyse

Berechnung von Distanzen oder Ähnlichkeiten

	Merkmal 1	Merkmal 2	...	Merkmal p
$\mathbf{x}_1$	x_{11}	x_{12}	...	x_{1p}
$\mathbf{x}_2$	x_{21}	x_{22}	...	x_{2p}
$\vdots$				
$\mathbf{x}_n$	x_{n1}	x_{n2}	...	x_{np}

	$\mathbf{x}_1$	$\mathbf{x}_2$	...	$\mathbf{x}_n$
$\mathbf{x}_1$	0	$d(\mathbf{x}_1, \mathbf{x}_2)$	...	$d(\mathbf{x}_1, \mathbf{x}_n)$
$\mathbf{x}_2$	-	0	...	$d(\mathbf{x}_2, \mathbf{x}_n)$
$\vdots$				
$\mathbf{x}_n$	-	-	...	0

Bemerkungen:

- Die Distanzmatrix ist oft implizit durch eine Metrik auf dem Merkmalsraum definiert.
- Die Distanzmatrix kann als Adjazenzmatrix eines gewichteten, ungerichteten Graphen G , $G = \langle V, E, w \rangle$, interpretiert werden: Die Menge X der Merkmalsvektoren wird bijektiv auf eine Knotenmenge V abgebildet; eine Distanz $d(\mathbf{x}_i, \mathbf{x}_j)$ entspricht dem Gewicht $w(\{u, v\})$ der Kante $\{u, v\} \in E$ zwischen den mit $\mathbf{x}_i$ und $\mathbf{x}_j$ assoziierten Knoten u und v .

ML: IX-25 Cluster Analysis

©STEIN 2002-2012

Einführung in die Clusteranalyse

Berechnung von Distanzen oder Ähnlichkeiten (Fortsetzung)

Anforderungen an eine Distanzfunktion:

1. $d(\mathbf{x}_1, \mathbf{x}_2) \geq 0$
2. $d(\mathbf{x}_1, \mathbf{x}_1) = 0$
3. $d(\mathbf{x}_1, \mathbf{x}_2) = d(\mathbf{x}_2, \mathbf{x}_1)$
4. $d(\mathbf{x}_1, \mathbf{x}_3) \leq d(\mathbf{x}_1, \mathbf{x}_2) + d(\mathbf{x}_2, \mathbf{x}_3)$

ML: IX-26 Cluster Analysis

©STEIN 2002-2012

Einführung in die Clusteranalyse

Berechnung von Distanzen oder Ähnlichkeiten (Fortsetzung)

Anforderungen an eine Distanzfunktion:

1. $d(\mathbf{x}_1, \mathbf{x}_2) \geq 0$
2. $d(\mathbf{x}_1, \mathbf{x}_1) = 0$
3. $d(\mathbf{x}_1, \mathbf{x}_2) = d(\mathbf{x}_2, \mathbf{x}_1)$
4. $d(\mathbf{x}_1, \mathbf{x}_3) \leq d(\mathbf{x}_1, \mathbf{x}_2) + d(\mathbf{x}_2, \mathbf{x}_3)$

Bei intervallskalierten Variablen Verwendung der Minkowsky-Metrik:

$$d(\mathbf{x}_1, \mathbf{x}_2) = \left(\sum_{i=1}^p |x_{1i} - x_{2i}|^r \right)^{1/r}$$

mit

- $r = 1$. Manhattan- oder Hamming-Distanz, L_1 -Norm
- $r = 2$. Euklidische Distanz, L_2 -Norm
- $r = \infty$. Maximum-Distanz, L_∞ -Norm bzw. $L_{\max}$ -Norm

ML: IX-27 Cluster Analysis

©STEIN 2002-2012

Einführung in die Clusteranalyse

Berechnung von Distanzen oder Ähnlichkeiten (Fortsetzung)

Eine Clusteranalyse verlangt kein spezielles Skalenniveau der Merkmale.

- Verallgemeinerung der Distanzfunktion zur (Un)Ähnlichkeitsfunktion durch Verzicht auf die Dreiecksungleichung. (Un)Ähnlichkeiten lassen sich zwischen binären, nominalen und ordinalen Variablen quantifizieren.

ML: IX-28 Cluster Analysis

©STEIN 2002-2012

Einführung in die Clusteranalyse

Berechnung von Distanzen oder Ähnlichkeiten (Fortsetzung)

Eine Clusteranalyse verlangt kein spezielles Skalenniveau der Merkmale.

- Verallgemeinerung der Distanzfunktion zur (Un)Ähnlichkeitsfunktion durch Verzicht auf die Dreiecksungleichung. (Un)Ähnlichkeiten lassen sich zwischen binären, nominalen und ordinalen Variablen quantifizieren.

Ähnlichkeitskoeffizienten für zwei Vektoren, $\mathbf{x}_1, \mathbf{x}_2$, mit binären Merkmalen:

$$\text{Simple Matching Coefficient (SMC)} = \frac{f_{11} + f_{00}}{f_{11} + f_{00} + f_{01} + f_{10}}$$

$$\text{Jaccard-Koeffizient (J)} = \frac{f_{11}}{f_{11} + f_{01} + f_{10}}$$

mit

- f_{11} = Anzahl der Merkmale mit Ausprägung 1 sowohl in $\mathbf{x}_1$ als auch in $\mathbf{x}_2$
- f_{00} = Anzahl der Merkmale mit Ausprägung 0 sowohl in $\mathbf{x}_1$ als auch in $\mathbf{x}_2$
- f_{01} = Anzahl der Merkmale mit Ausprägung 0 in $\mathbf{x}_1$ und Ausprägung 1 in $\mathbf{x}_2$
- f_{10} = Anzahl der Merkmale mit Ausprägung 1 in $\mathbf{x}_1$ und Ausprägung 0 in $\mathbf{x}_2$

ML: IX-29 Cluster Analysis

©STEIN 2002-2012

Bemerkungen:


- Die Definition der Ähnlichkeitskoeffizienten lässt sich auf nominale Variablen erweitern.
- Heterogene Metriken wie HEOM und HVDM ermöglichen die kombinierte Verrechnung verschiedener Skalenniveaus.
- Die Berechnung von Korrelationskoeffizienten zwischen zwei Vektoren über alle Merkmale (also nicht zwischen zwei Merkmalen über alle Vektoren) ermöglicht den Vergleich von Profilen. Beispiel: Q-Korrelationskoeffizient
- Die Konstruktion eines geeigneten Ähnlichkeitsmaßes stellt oft die größte Herausforderung bei der Cluster-Analyse dar. Typische Problemfelder:
 - Normalisierung
 - Empfindlichkeit bei Ausreißern
 - Korrelationen zwischen Merkmalen
 - unterschiedliche Wichtigkeit der Merkmale
- Ähnlichkeitsmaße lassen sich kanonisch in Unähnlichkeitsmaße umrechnen – und umgekehrt.

ML: IX-30 Cluster Analysis

©STEIN 2002-2012

Einführung in die Clusteranalyse

Prinzipien der Fusionierung



ML: IX-31 Cluster Analysis

©STEIN 2002-2012

Kapitel ML: IX (Fortsetzung)

IX. Clusteranalyse


- Einordnung Data Mining
- Einführung in die Clusteranalyse
- Hierarchische Verfahren
- Iterative Verfahren
- Dichtebasierte Verfahren
- Cluster Evaluation
- Constrained Cluster Analysis

ML: IX-32 Cluster Analysis

©STEIN 2002-2012

Hierarchische Verfahren

Prinzipien der Fusionierung



ML: IX-33 Cluster Analysis

©STEIN 2002-2012

Hierarchische Verfahren

Algorithmus zur hierarchisch-agglomerativen Clusteranalyse

Input: $G = \langle V, E, w \rangle$. Weighted graph.
 d_C . Distance measure between two clusters.
Output: $T = \langle V_T, E_T \rangle$. Cluster hierarchy or dendrogram.

1. $\mathcal{C} = \{\{v\} \mid v \in V\}$ // initial clustering
- 2.
3. **WHILE** $|\mathcal{C}| > 1$ **DO**
4. $\text{update_distance_matrix}(\mathcal{C}, G, d_C)$
5. $\{C, C'\} = \underset{\{C_i, C_j\} \in \mathcal{C}: C_i \neq C_j}{\text{argmin}} d_C(C_i, C_j)$
6. $\mathcal{C} = (\mathcal{C} \setminus \{C, C'\}) \cup \{C \cup C'\}$ // merging
- 7.
8. **ENDDO**
9. **RETURN**(T)

Vergleiche hierzu den Algorithmus zur hierarchisch-divisiven Clusteranalyse.

ML: IX-34 Cluster Analysis

©STEIN 2002-2012

Hierarchische Verfahren

Algorithmus zur hierarchisch-agglomerativen Clusteranalyse

Input: $G = \langle V, E, w \rangle$. Weighted graph.
 d_C . Distance measure between two clusters.
Output: $T = \langle V_T, E_T \rangle$. Cluster hierarchy or dendrogram.

1. $\mathcal{C} = \{\{v\} \mid v \in V\}$ // initial clustering
2. $V_T = \{v_C \mid C \in \mathcal{C}\}$, $E_T = \emptyset$ // initial dendrogram
3. **WHILE** $|\mathcal{C}| > 1$ **DO**
4. $\text{update_distance_matrix}(\mathcal{C}, G, d_C)$
5. $\{C, C'\} = \underset{\{C_i, C_j\} \in \mathcal{C}: C_i \neq C_j}{\text{argmin}} d_C(C_i, C_j)$
6. $\mathcal{C} = (\mathcal{C} \setminus \{C, C'\}) \cup \{C \cup C'\}$ // merging
7. $V_T = V_T \cup \{v_{C, C'}\}$, $E_T = E_T \cup \{\{v_{C, C'}, v_C\}, \{v_{C, C'}, v_{C'}\}\}$ // dendrogram
8. **ENDDO**
9. **RETURN**(T)


Vergleiche hierzu den Algorithmus zur hierarchisch-divisiven Clusteranalyse.

ML: IX-35 Cluster Analysis

©STEIN 2002-2012

Hierarchische Verfahren

Single-Link: Cluster-Distanzmaß d_C = Nearest-Neighbor




ML: IX-36 Cluster Analysis

©STEIN 2002-2012


Hierarchische Verfahren

Single-Link: Cluster-Distanzmaß $d_C = \text{Nearest-Neighbor}$





Hierarchische Verfahren

Single-Link: Cluster-Distanzmaß $d_C = \text{Nearest-Neighbor}$





Hierarchische Verfahren

Single-Link: Cluster-Distanzmaß $d_C = \text{Nearest-Neighbor}$





Hierarchische Verfahren

Single-Link: Cluster-Distanzmaß $d_C = \text{Nearest-Neighbor}$





Hierarchische Verfahren

Single-Link: Cluster-Distanzmaß $d_C = \text{Nearest-Neighbor}$




Hierarchische Verfahren

Single-Link: Cluster-Distanzmaß $d_C = \text{Nearest-Neighbor}$



Hierarchische Verfahren

Single-Link: Cluster-Distanzmaß $d_C = \text{Nearest-Neighbor}$




ML: IX-43 Cluster Analysis

©STEIN 2002-2012

Hierarchische Verfahren

Single-Link: Cluster-Distanzmaß $d_C = \text{Nearest-Neighbor}$



ML: IX-44 Cluster Analysis

©STEIN 2002-2012

Hierarchische Verfahren

Distanzmaße hierarchisch-agglomerativer Verfahren [\[Eigenschaften\]](#)

$d_C(C, C') = \min_{\substack{u \in C \\ v \in C'}} d(u, v)$	Single-Link (Nearest-Neighbor)
$d_C(C, C') = \max_{\substack{u \in C \\ v \in C'}} d(u, v)$	Complete-Link (Furthest-Neighbor)
$d_C(C, C') = \frac{1}{ C \cdot C' } \sum_{\substack{u \in C \\ v \in C'}} d(u, v)$	(Group-)Average-Link
$d_C(C, C') = \sqrt{\frac{2 \cdot C \cdot C' }{ C + C' }} \cdot \ \bar{u} - \bar{v}\ $	Ward (Varianz)

Siehe Verwendung im Algorithmus:

- ☐ [hierarchisch-agglomerative Clusteranalyse](#)
- ☐ [hierarchisch-divisive Clusteranalyse](#)

ML: IX-45 Cluster Analysis

©STEIN 2002-2012

Hierarchische Verfahren

Ward-Kriterium

Ward ist ein Varianzkriterium; es entspricht der doppelten Zunahme der Wurzel aus der Fehlerquadratsumme, SSE , in dem neuen Cluster, der durch die Vereinigung der beiden Cluster C und C' entsteht. Herleitung:

$$SSE(C) = \sum_{u \in C} \|\bar{u} - u\|^2$$

ML: IX-46 Cluster Analysis

©STEIN 2002-2012

Hierarchische Verfahren

Ward-Kriterium

Ward ist ein Varianzkriterium; es entspricht der doppelten Zunahme der Wurzel aus der Fehlerquadratsumme, SSE , in dem neuen Cluster, der durch die Vereinigung der beiden Cluster C und C' entsteht. Herleitung:

$$\begin{aligned} SSE(C) &= \sum_{u \in C} \|\bar{u} - u\|^2 = \sum_{u \in C} (\|\bar{u}\|^2 - 2 \cdot \langle u, \bar{u} \rangle + \|u\|^2) \\ &= |C| \cdot \|\bar{u}\|^2 - 2|C| \cdot \|\bar{u}\|^2 + \sum_{u \in C} \|u\|^2 = \sum_{u \in C} \|u\|^2 - |C| \cdot \|\bar{u}\|^2 \end{aligned}$$

ML: IX-47 Cluster Analysis

©STEIN 2002-2012

Hierarchische Verfahren

Ward-Kriterium

Ward ist ein Varianzkriterium; es entspricht der doppelten Zunahme der Wurzel aus der Fehlerquadratsumme, SSE , in dem neuen Cluster, der durch die Vereinigung der beiden Cluster C und C' entsteht. Herleitung:

$$\begin{aligned} SSE(C) &= \sum_{u \in C} \|\bar{u} - u\|^2 = \sum_{u \in C} (\|\bar{u}\|^2 - 2 \cdot \langle u, \bar{u} \rangle + \|u\|^2) \\ &= |C| \cdot \|\bar{u}\|^2 - 2|C| \cdot \|\bar{u}\|^2 + \sum_{u \in C} \|u\|^2 = \sum_{u \in C} \|u\|^2 - |C| \cdot \|\bar{u}\|^2 \\ SSE(C') &= \sum_{v \in C'} \|\bar{v} - v\|^2 = \sum_{v \in C'} (\|\bar{v}\|^2 - 2 \cdot \langle v, \bar{v} \rangle + \|v\|^2) \\ &= |C'| \cdot \|\bar{v}\|^2 - 2|C'| \cdot \|\bar{v}\|^2 + \sum_{v \in C'} \|v\|^2 = \sum_{v \in C'} \|v\|^2 - |C'| \cdot \|\bar{v}\|^2 \\ SSE(C \cup C') &= \sum_{w \in (C \cup C')} \|w\|^2 - |C \cup C'| \cdot \|\bar{w}\|^2, \quad \text{mit } \bar{w} = \frac{|C| \cdot \bar{u} + |C'| \cdot \bar{v}}{|C| + |C'|} \end{aligned}$$

$$SSE(C \cup C') - SSE(C) - SSE(C') = \dots = \frac{|C| \cdot |C'|}{|C| + |C'|} \cdot \|\bar{u} - \bar{v}\|^2$$

$\bar{u}$ bzw. $\bar{v}$ bezeichnen den Mittelwert der Punkte $u \in C$ bzw. $v \in C'$.

ML: IX-48 Cluster Analysis

©STEIN 2002-2012

Hierarchische Verfahren

Update-Formel für Cluster-Distanzen

Nach Vereinigung der Cluster C und C' zu einem neuen Cluster sind dessen Distanzen, in Zeichen: $d_C(C \cup C', C_i)$, zu den anderen Clustern C_i zu berechnen.

Die folgende Update-Formel (Lance-Williams-Formel) ermöglicht eine effiziente Berechnung dieser Distanzen:

$$d_C(C \cup C', C_i) = \alpha \cdot d_C(C, C_i) + \beta \cdot d_C(C', C_i) + \gamma \cdot d_C(C, C') + \delta \cdot |d_C(C, C_i) - d_C(C', C_i)|$$


Die Konstanten $\alpha, \beta, \gamma, \delta$ sind spezifisch für Single-Link, Complete-Link, Average-Link und Ward, und lassen sich auf Basis der entsprechenden Berechnungsvorschriften für d_C herleiten.

Bemerkungen:

- ☐ Link-basierte Verfahren arbeiten sowohl mit beliebigen Distanz- als auch Ähnlichkeitsmaßen.
- ☐ Single-Link kann unmittelbar mit einem Minimum-Spanning-Tree-Algorithmus realisiert werden.
- ☐ Varianzbasierte Verfahren sind nur sinnvoll, falls alle Merkmale Intervallskalenniveau besitzen.
- ☐ Idee der Lance-Williams-Formel: Anstatt immer wieder alle Elemente von zwei Clustern zu betrachten, nimmt die Update-Formel Bezug auf die im vorherigen Schritt berechneten Distanzen.


Hierarchische Verfahren

Chaining-Problematik bei Single-Link ($d_C = \text{Nearest-Neighbor}$)




Hierarchische Verfahren

Chaining-Problematik bei Single-Link ($d_C = \text{Nearest-Neighbor}$)




Hierarchische Verfahren

Chaining-Problematik bei Single-Link ($d_C = \text{Nearest-Neighbor}$)




Hierarchische Verfahren

Chaining-Problematik bei Single-Link ($d_C = \text{Nearest-Neighbor}$)




Hierarchische Verfahren

Chaining-Problematik bei Single-Link ($d_C = \text{Nearest-Neighbor}$)




Hierarchische Verfahren

Chaining-Problematik bei Single-Link ($d_C = \text{Nearest-Neighbor}$)




Hierarchische Verfahren

Chaining-Problematik bei Single-Link ($d_C = \text{Nearest-Neighbor}$)





Hierarchische Verfahren

Chaining-Problematik bei Single-Link ($d_C = \text{Nearest-Neighbor}$)





Hierarchische Verfahren

Chaining-Problematik bei Single-Link ($d_C = \text{Nearest-Neighbor}$)



Hierarchische Verfahren

Chaining-Problematik bei Single-Link ($d_C = \text{Nearest-Neighbor}$)




Bemerkungen:

- Mit einer k -Nearest-Neighbor-Variante könnte man das Problem entschärfen.
- Bei k -Nearest-Neighbor werden größere Cluster bei der Agglomeration bevorzugt, da sie mehr und damit – statistisch gesehen – auch mehr nähere Nachbarn besitzen.


Hierarchische Verfahren

Chaining-Problematik bei Single-Link ($d_C = k$ -Nearest-Neighbor)




Hierarchische Verfahren

Chaining-Problematik bei Single-Link ($d_C = k$ -Nearest-Neighbor)




Hierarchische Verfahren

Chaining-Problematik bei Single-Link ($d_C = k$ -Nearest-Neighbor)




Hierarchische Verfahren

Chaining-Problematik bei Single-Link ($d_C = k$ -Nearest-Neighbor)




Hierarchische Verfahren

Chaining-Problematik bei Single-Link ($d_C = k$ -Nearest-Neighbor)



Hierarchische Verfahren

Chaining-Problematik bei Single-Link ($d_C = k$ -Nearest-Neighbor)




ML: IX-67 Cluster Analysis

©STEIN 2002-2012

Hierarchische Verfahren

Chaining-Problematik bei Single-Link ($d_C = k$ -Nearest-Neighbor)




ML: IX-68 Cluster Analysis

©STEIN 2002-2012

Hierarchische Verfahren

Chaining-Problematik bei Single-Link ($d_C = k$ -Nearest-Neighbor)




In speziellen Situationen kann auch k -Nearest-Neighbor versagen.

ML: IX-69 Cluster Analysis

©STEIN 2002-2012

Hierarchische Verfahren

Chaining-Problematik bei Single-Link ($d_C = k$ -Nearest-Neighbor)




In speziellen Situationen kann auch k -Nearest-Neighbor versagen.

ML: IX-70 Cluster Analysis

©STEIN 2002-2012

Hierarchische Verfahren

Chaining-Problematik bei Single-Link ($d_C = k$ -Nearest-Neighbor)




In speziellen Situationen kann auch k -Nearest-Neighbor versagen.

ML: IX-71 Cluster Analysis

©STEIN 2002-2012

Hierarchische Verfahren

Chaining-Problematik bei Single-Link ($d_C = k$ -Nearest-Neighbor)




In speziellen Situationen kann auch k -Nearest-Neighbor versagen.

ML: IX-72 Cluster Analysis

©STEIN 2002-2012


Hierarchische Verfahren

Überlappungsproblematik bei Complete-Link ($d_C = \text{Furthest-Neighbor}$)




Hierarchische Verfahren

Überlappungsproblematik bei Complete-Link ($d_C = \text{Furthest-Neighbor}$)




Hierarchische Verfahren

Überlappungsproblematik bei Complete-Link ($d_C = \text{Furthest-Neighbor}$)




Hierarchische Verfahren

Überlappungsproblematik bei Complete-Link ($d_C = \text{Furthest-Neighbor}$)




Hierarchische Verfahren

Überlappungsproblematik bei Complete-Link ($d_C = \text{Furthest-Neighbor}$)




Hierarchische Verfahren

Überlappungsproblematik bei Complete-Link ($d_C = \text{Furthest-Neighbor}$)



Hierarchische Verfahren

Überlappungsproblematik bei Complete-Link ($d_C = \text{Furthest-Neighbor}$)




ML: IX-79 Cluster Analysis


©STEIN 2002-2012

Hierarchische Verfahren

Überlappungsproblematik bei Complete-Link ($d_C = \text{Furthest-Neighbor}$)



Wirklichkeit



Wunsch

ML: IX-80 Cluster Analysis

©STEIN 2002-2012

Hierarchische Verfahren

Eigenschaften hierarchisch-agglomerativer Verfahren [\[Distanzmaße\]](#)

Geometrische Eigenschaften:

	Single-Link	Complete-Link	Average-Link	Ward
Charakteristik	kontrahierend:	dilatierend:	konservativ:	konservativ:
Cluster-Zahl	niedrig	hoch	mittel	mittel
Cluster-Form	ausgedehnt	klein	kompakt	sphärisch
Verkettungstendenz	stark	niedrig	niedrig	niedrig
Ausreißerentdeckung	sehr gut	schlecht	mittel	mittel

ML: IX-81 Cluster Analysis

©STEIN 2002-2012

Hierarchische Verfahren

Eigenschaften hierarchisch-agglomerativer Verfahren [\[Distanzmaße\]](#)

Geometrische Eigenschaften:

	Single-Link	Complete-Link	Average-Link	Ward
Charakteristik	kontrahierend:	dilatierend:	konservativ:	konservativ:
Cluster-Zahl	niedrig	hoch	mittel	mittel
Cluster-Form	ausgedehnt	klein	kompakt	sphärisch
Verkettungstendenz	stark	niedrig	niedrig	niedrig
Ausreißerentdeckung	sehr gut	schlecht	mittel	mittel

Datenbezogene Eigenschaften:

verrauschte Daten	empfindlich	empfindlich	unbeeinflusst	unbeeinflusst
Merkmaltransformation	invariant	invariant	–	–

ML: IX-82 Cluster Analysis

©STEIN 2002-2012

Hierarchische Verfahren

Eigenschaften hierarchisch-agglomerativer Verfahren [\[Distanzmaße\]](#)

Geometrische Eigenschaften:

	Single-Link	Complete-Link	Average-Link	Ward
Charakteristik	kontrahierend:	dilatierend:	konservativ:	konservativ:
Cluster-Zahl	niedrig	hoch	mittel	mittel
Cluster-Form	ausgedehnt	klein	kompakt	sphärisch
Verkettungstendenz	stark	niedrig	niedrig	niedrig
Ausreißerentdeckung	sehr gut	schlecht	mittel	mittel

Datenbezogene Eigenschaften:

verrauschte Daten	empfindlich	empfindlich	unbeeinflusst	unbeeinflusst
Merkmaltransformation	invariant	invariant	–	–

Eigenschaften des Cluster-Distanzmaßes:


d_C monoton	✓	✓	✓	✓
d_C reihenfolgeunabh.	✓	✓	✓	✓
d_C konsistent	→ 0	→ ∞	✓	→ ∞

ML: IX-83 Cluster Analysis

©STEIN 2002-2012

Hierarchische Verfahren

Prinzipien der Fusionierung



ML: IX-84 Cluster Analysis

©STEIN 2002-2012

Hierarchische Verfahren

Algorithmus zur hierarchisch-divisiven Clusteranalyse

Input: $G = \langle V, E, w \rangle$. Weighted graph.
 d_C . Distance measure between two clusters.
Output: $T = \langle V_T, E_T \rangle$. Cluster hierarchy or dendrogram.

```
1.  $\mathcal{C} = \{V\}$  // initial clustering
2.
3. WHILE  $\exists C_x : (C_x \in \mathcal{C} \wedge |C_x| > 1)$  DO
4.    $\{C, C'\} = \underset{\substack{\{C_i, C_j\}: \\ C_i \cup C_j = C_x \wedge C_i \cap C_j = \emptyset}}{\operatorname{argmax}} d_C(C_i, C_j)$ 
5.    $\mathcal{C} = (\mathcal{C} \setminus \{C_x\}) \cup \{C, C'\}$  // splitting
6.
7. ENDDO
8. RETURN( $T$ )
```

Vergleiche hierzu den Algorithmus zur hierarchisch-agglomerativen Clusteranalyse.

ML: IX-85 Cluster Analysis

©STEIN 2002-2012

Hierarchische Verfahren

Algorithmus zur hierarchisch-divisiven Clusteranalyse

Input: $G = \langle V, E, w \rangle$. Weighted graph.
 d_C . Distance measure between two clusters.
Output: $T = \langle V_T, E_T \rangle$. Cluster hierarchy or dendrogram.

```
1.  $\mathcal{C} = \{V\}$  // initial clustering
2.  $V_T = \{v_C \mid C \in \mathcal{C}\}, E_T = \emptyset$  // initial dendrogram
3. WHILE  $\exists C_x : (C_x \in \mathcal{C} \wedge |C_x| > 1)$  DO
4.    $\{C, C'\} = \underset{\substack{\{C_i, C_j\}: \\ C_i \cup C_j = C_x \wedge C_i \cap C_j = \emptyset}}{\operatorname{argmax}} d_C(C_i, C_j)$ 
5.    $\mathcal{C} = (\mathcal{C} \setminus \{C_x\}) \cup \{C, C'\}$  // splitting
6.    $V_T = V_T \cup \{v_C, v_{C'}\}, E_T = E_T \cup \{\{v_{C_x}, v_C\}, \{v_{C_x}, v_{C'}\}\}$  // dendrogram
7. ENDDO
8. RETURN( $T$ )
```

Vergleiche hierzu den Algorithmus zur hierarchisch-agglomerativen Clusteranalyse.

ML: IX-86 Cluster Analysis

©STEIN 2002-2012

Bemerkungen:

- Im Prinzip kann d_C wie bei den hierarchisch-agglomerativen Verfahren gewählt werden. Die Worst-Case-Komplexität ist exponentiell statt quadratisch.
- Hierarchisch-divisive Verfahren werden oft als *monothetische* Variante konstruiert: in jedem Entscheidungsschritt wird nur *eine* Variable betrachtet.
- Im Gegensatz zu hierarchisch-agglomerativen Verfahren darf ein hierarchisch-divisives Verfahren keinen „Fehler“ bei den ersten Schritten machen.
- Ein mächtiges hierarchisch-divisives Clusteranalyse-Verfahren entsteht mit

$$\operatorname{sim}_C(C, C') = \sum_{e \in \operatorname{cut}(\{C, C'\})} w(e) \quad \text{bzw.} \quad d_C(C, C') = \frac{1}{\operatorname{sim}_C(C, C')}$$

ML: IX-87 Cluster Analysis

©STEIN 2002-2012

Hierarchische Verfahren

MinCut-Clusteranalyse

Definition 3 (Cut, minimaler Cut)

Sei $G = \langle V, E, w \rangle$ ein Graph mit nicht-negativer Gewichtsfunction w ; weiterhin sei $U \subset V$ eine nichtleere Teilmenge der Knotenmenge V und $\bar{U} = V \setminus U$. Der Cut zwischen U und $\bar{U}$ ist wie folgt definiert:

$$\operatorname{cut}(\{U, \bar{U}\}) = \{\{u, v\} \mid \{u, v\} \in E, u \in U, v \in \bar{U}\}$$

ML: IX-88 Cluster Analysis

©STEIN 2002-2012

Hierarchische Verfahren

MinCut-Clusteranalyse

Definition 3 (Cut, minimaler Cut)

Sei $G = \langle V, E, w \rangle$ ein Graph mit nicht-negativer Gewichtsfunction w ; weiterhin sei $U \subset V$ eine nichtleere Teilmenge der Knotenmenge V und $\bar{U} = V \setminus U$. Der Cut zwischen U und $\bar{U}$ ist wie folgt definiert:

$$\operatorname{cut}(\{U, \bar{U}\}) = \{\{u, v\} \mid \{u, v\} \in E, u \in U, v \in \bar{U}\}$$

Weiterhin bezeichne $w(\{U, \bar{U}\})$ das Gewicht oder die Kapazität von $\operatorname{cut}(\{U, \bar{U}\})$:

$$w(\{U, \bar{U}\}) = \sum_{e \in \operatorname{cut}(\{U, \bar{U}\})} w(e)$$

$\operatorname{cut}(\{U, \bar{U}\})$ heißt minimaler Cut von G (*Minium Capacity Cut*), wenn für alle Zerlegungen $\{W, \bar{W}\}$, $W, \bar{W} \neq \emptyset$ gilt:


$$w(\{U, \bar{U}\}) \leq w(\{W, \bar{W}\})$$

ML: IX-89 Cluster Analysis

©STEIN 2002-2012

Hierarchische Verfahren

MinCut-Clusteranalyse




ML: IX-90 Cluster Analysis

©STEIN 2002-2012


Hierarchische Verfahren

MinCut-Clusteranalyse




Hierarchische Verfahren

MinCut-Clusteranalyse



Hierarchische Verfahren

MinCut-Clusteranalyse




Bemerkungen:

- Jede Aufteilung erfordert die Berechnung eines Cuts minimaler Kapazität (*Minimum-Capacity-Cut*). Beachte, dass kein Knoten als Quelle oder Senke vorgegeben ist.
- Die Laufzeitkomplexität des besten, bekannten Algorithmus zur Berechnung eines minimalen Cuts ist in $O(|V| \cdot |E| + |V|^2 \cdot \log |V|)$. [Nagamochi/Ono/Ibaraki 1994]
- Es sind $|V| - 1$ Berechnungen eines Minimum-Capacity-Cuts notwendig, um eine vollständige Zerlegung (= ein Knoten pro Cluster) herzustellen.
- Der Aufwand zur Berechnung eines Minimum- $s-t$ -Cuts, also eines Cuts bei vorgegebener Quelle s und Senke t , ist in $O(|V|^2 \log(|E|))$.
- Der Aufwand zur Berechnung eines Balanced Min-Cut (k -way, $k \geq 2$) ist NP-vollständig.


Hierarchische Verfahren

Splitting-Problematik bei MinCut-Clusteranalyse




Hierarchische Verfahren

Splitting-Problematik bei MinCut-Clusteranalyse



Hierarchische Verfahren

Splitting-Problematik bei MinCut-Clusteranalyse



Ausweg: Normalisierung der Cut-Kapazität bzgl. der Größe der Knotenmengen.

ML: IX-97 Cluster Analysis


©STEIN 2002-2012

Hierarchische Verfahren

Splitting-Problematik bei MinCut-Clusteranalyse

$$\text{Normalisierte Cut-Kapazität: } \bar{w}(\{U, \bar{U}\}) = \frac{w(\{U, \bar{U}\})}{w(\{U, V\})} + \frac{w(\{\bar{U}, V\})}{w(\{\bar{U}, V\})}$$

Illustration von $\bar{w}$:



ML: IX-98 Cluster Analysis

©STEIN 2002-2012

Bemerkungen:

- Die Bestimmung eines Cuts minimaler, normalisierter Kapazität ist NP-vollständig.
- Es gibt effiziente Näherungslösungen zur Berechnung von $\bar{w}(\{U, \bar{U}\})$. Das Verfahren wird angewandt im Bereich der Bildsegmentierung und der Gene-Expression-Cluster-Analyse. [Shi/Malik 2000]

ML: IX-99 Cluster Analysis

©STEIN 2002-2012

Hierarchische Verfahren

Kombination hierarchischer Verfahren

Das System Chameleon kombiniert die Schritte Graphausdünnung, Graphpartitionierung und hierarchische Cluster-Analyse [Karypis/Han/Kumar 2000] :


ML: IX-100 Cluster Analysis

©STEIN 2002-2012

Hierarchische Verfahren

Kombination hierarchischer Verfahren

Das System Chameleon kombiniert die Schritte Graphausdünnung, Graphpartitionierung und hierarchische Cluster-Analyse [Karypis/Han/Kumar 2000] :



Die Clusterdistanz $d_C(C, C')$ ist definiert als $d_C = \frac{1}{R_I(C, C') \cdot (R_C(C, C'))^\alpha}$


ML: IX-101 Cluster Analysis

©STEIN 2002-2012

Hierarchische Verfahren

Kombination hierarchischer Verfahren

Chameleon [Karypis/Han/Kumar 2000] :



Der Parameter α in d_C ist vom Anwender problemabhängig zu bestimmen.

ML: IX-102 Cluster Analysis

©STEIN 2002-2012

Kapitel ML: IX (Fortsetzung)

IX. Clusteranalyse


- Einordnung Data Mining
- Einführung in die Clusteranalyse
- Hierarchische Verfahren
- Iterative Verfahren
- Dichtebasierte Verfahren
- Cluster Evaluation
- Constrained Cluster Analysis

ML: IX-103 Cluster Analysis

©STEIN 2002-2012

Iterative Verfahren

Prinzipien der Fusionierung



ML: IX-104 Cluster Analysis

©STEIN 2002-2012

Iterative Verfahren

Algorithmus zur exemplarbasierten Clusteranalyse

Input: $G = \langle V, E, w \rangle$. Weighted graph.
 d . Distance function for nodes in V .
 e . Minimization criterion for cluster representatives, based on d .
 k . Number of desired clusters.

Output: $r_1, \dots, r_k$. Cluster representatives.

```
1.
2. FOR  $i = 1$  to  $k$  DO  $r_i(t) = \text{choose}(V)$  // init representatives
3.
4.
5.
6. FOREACH  $v \in V$  DO // find nearest representative (cluster)
7.    $i = \text{argmin}_{j: j \in \{1, \dots, k\}} d(r_j(t), v)$ ,  $C_i = C_i \cup \{v\}$ 
8. ENDDO
9. FOR  $i = 1$  to  $k$  DO  $r_i(t) = \text{minimize}(e(C_i))$  // update
10.
11.
```

ML: IX-105 Cluster Analysis

©STEIN 2002-2012

Iterative Verfahren

Algorithmus zur exemplarbasierten Clusteranalyse

Input: $G = \langle V, E, w \rangle$. Weighted graph.
 d . Distance function for nodes in V .
 e . Minimization criterion for cluster representatives, based on d .
 k . Number of desired clusters.

Output: $r_1, \dots, r_k$. Cluster representatives.

```
1.  $t = 0$ 
2. FOR  $i = 1$  to  $k$  DO  $r_i(t) = \text{choose}(V)$  // init representatives
3. REPEAT
4.    $t = t + 1$ 
5.   FOR  $i = 1$  to  $k$  DO  $C_i = \emptyset$ 
6.   FOREACH  $v \in V$  DO // find nearest representative (cluster)
7.      $i = \text{argmin}_{j: j \in \{1, \dots, k\}} d(r_j(t), v)$ ,  $C_i = C_i \cup \{v\}$ 
8.   ENDDO
9.   FOR  $i = 1$  to  $k$  DO  $r_i(t) = \text{minimize}(e(C_i))$  // update
10. UNTIL ( $\text{convergence}(r_1(t), \dots, r_k(t))$  OR  $t > t_{\max}$ )
11. RETURN( $\{r_1(t), \dots, r_k(t)\}$ )
```

ML: IX-106 Cluster Analysis

©STEIN 2002-2012

Bemerkungen:


- Die Cluster-Repräsentanten werden Centroiden bzw. allgemein Medoide genannt.
- Die Funktion $\text{choose}(V)$ realisiert eine zufällige Auswahl ohne Zurücklegen.
- Als Distanzfunktion d wird bei metrischen Daten meistens der euklidische Abstand zwischen zwei Punkten gewählt. Ein alternativer und allgemeiner Ansatz ist die Verwendung des kürzesten Weges in G .
- Als Minimierungskriterium e wird bei metrischen Daten meistens die Summe der quadrierten Abweichungen zum Cluster-Repräsentanten gewählt (Varianzkriterium). Sind die Punkte $v \in V$ Vektoren aus dem $\mathbb{R}^n$, lässt sich der optimale Cluster-Repräsentant durch komponentenweise Berechnung des arithmetischen Mittels ermitteln.

ML: IX-107 Cluster Analysis

©STEIN 2002-2012

Iterative Verfahren

k -Means mit Minimierungskriterium $e = \text{Varianz}$




ML: IX-108 Cluster Analysis

©STEIN 2002-2012


Iterative Verfahren

k -Means mit Minimierungskriterium $e = \text{Varianz}$




Iterative Verfahren

k -Means mit Minimierungskriterium $e = \text{Varianz}$




Iterative Verfahren

k -Means mit Minimierungskriterium $e = \text{Varianz}$




Iterative Verfahren

k -Means mit Minimierungskriterium $e = \text{Varianz}$




Iterative Verfahren

k -Means mit Minimierungskriterium $e = \text{Varianz}$




Iterative Verfahren

k -Means mit Minimierungskriterium $e = \text{Varianz}$



Iterative Verfahren

k -Means mit Minimierungskriterium $e = \text{Varianz}$



Iterative Verfahren

Minimierungskriterien exemplarbasierter Verfahren


$e(C_i) = \sum_{v \in C_i} (v - r_i)^2$	$r_i = \bar{v}_{C_i}$	Centroid-Berechnung mittels Varianzminimierung (k -Means)
$e(C_i) = \sum_{v \in C_i} v - r_i $	$r_i \in C_i$	Medoid-Berechnung (k -Medoid)
$e(C_i) = \max_{v \in C_i} v - r_i $	$r_i \in C_i$	k -Center
$e(C_i) = \sum_{v \in V} (\mu_i(v))^2 \cdot (v - r_i)^2$	$r_i = \frac{\sum_{v \in V} (\mu_i(v))^2 \cdot v}{\sum_{v \in V} (\mu_i(v))^2}$	Fuzzy- k -Means

Bemerkungen:

- $\bar{v}_{C_i}$ bezeichne den Mittelwert der Punkte $v \in C_i$.
- Der Cluster-Repräsentant ist abkürzend mit r_i anstatt mit $r_i(t)$ bezeichnet.
- Die Centroid-Berechnung bei k -Means als Mittelwert der Cluster-Elemente entspricht einer lokalen, also Cluster-spezifischen Varianzminimierung.
- Der Medoid (Zentralelement) eines Cluster ist dasjenige Element, für das die Summe aller Distanzen zu diesem Element minimal ist. Ein Vorteil bei Verwendung von Medoiden ist das robustere Verhalten gegenüber Ausreißern und damit eventuell eine in der Anzahl der Iterationen schnellere Konvergenz.
- Bei Fuzzy- k -Means bezeichnet $\mu_i(v)$ den Zugehörigkeitswert von $v \in V$ zu Cluster C_i .
- k -Medoid und k -Center arbeiten sowohl mit beliebigen Distanz- als auch mit Ähnlichkeitsmaßen.
- k -Means und Fuzzy- k -Means setzen intervallskalierte Merkmale voraus.
- k -Means kann unmittelbar als Kohonen Self-Organizing-Map, SOM, einem speziellen neuronalen Netz, umgesetzt werden:
 - Die Netztopologie besteht aus einer Eingangsschicht mit Knoten in der Anzahl der Merkmale und einer Verarbeitungsschicht (*Competitive Layer*) mit k Knoten.
 - Der Lernalgorithmus bestimmt für einen Merkmalsvektor auf Basis der Kantengewichte das *Winning Neuron*, dessen Gewichte gemäß des Lernparameters η erhöht werden.

Iterative Verfahren


k -Means versus Single-Link



Exemplarbasierte Verfahren versagen bei verschränkt liegenden Clustern.

Iterative Verfahren


k -Means versus Single-Link



Exemplarbasierte Verfahren versagen bei verschränkt liegenden Clustern.

Iterative Verfahren


k -Means versus Single-Link



Exemplarbasierte Verfahren versagen bei verschränkt liegenden Clustern.

Iterative Verfahren


k -Means versus Single-Link



Exemplarbasierte Verfahren versagen bei verschränkt liegenden Clustern.

Iterative Verfahren


k -Means versus Single-Link



Exemplarbasierte Verfahren versagen bei extremen Größendifferenzen.

Iterative Verfahren

k -Means versus Single-Link



Exemplarbasierte Verfahren versagen bei extremen Größendifferenzen.

Iterative Verfahren

Exklusive versus nicht-exklusive Clusteranalyse

Sei $\mathcal{C} = \{C_1, \dots, C_k\}$ eine Partitionierung einer Menge V mit $\bigcup_{i=1 \dots k} C_i = V$.


- exklusive Clusteranalyse: $\forall i, j \in \{1, \dots, k\} : i \neq j$ impliziert $C_i \cap C_j = \emptyset$
- nicht-exklusive Clusteranalyse erlaubt mehrfache Cluster-Zugehörigkeit

Iterative Verfahren

Exklusive versus nicht-exklusive Clusteranalyse

Sei $\mathcal{C} = \{C_1, \dots, C_k\}$ eine Partitionierung einer Menge V mit $\bigcup_{i=1 \dots k} C_i = V$.

- exklusive Clusteranalyse: $\forall i, j \in \{1, \dots, k\} : i \neq j$ impliziert $C_i \cap C_j = \emptyset$
- nicht-exklusive Clusteranalyse erlaubt mehrfache Cluster-Zugehörigkeit
- Fuzzy-Clusteranalyse quantifiziert die Cluster-Zugehörigkeit der $v \in V$ mit Zugehörigkeitsfunktionen $\mu_i(v)$, $i \in \{1, \dots, k\}$.




[Höppner/Klawonn/Kruse 1997]

Iterative Verfahren

Exklusive versus nicht-exklusive Clusteranalyse

Anwendung der Fuzzy-Clusteranalyse zur Darstellung von Gehirngewebe:



[Pham/Prince/Dagher/Xn 1996]

Bemerkungen:

- Die linguistische Variable bei der Fuzzy-Modellierung hat k Ausprägungen, entsprechend den Clustern $C_1, \dots, C_k$.
- Üblich ist eine Normalisierungsrestriktion für Zugehörigkeitsfunktionen: $\sum_{i=1..k} \mu_i(v) = 1$
- Varianten von Fuzzy- k -Means ohne die Normalisierungsrestriktion haben den Nachteil, dass Punkte mit kleinen Zugehörigkeitswerten zu einem Cluster wie Ausreißer behandelt werden, anstatt den Cluster in ihre Richtung zu bewegen. Deshalb ist es sinnvoll, das Iterationsverfahren in einer Initialisierungsphase zunächst mit der Restriktion anzuwenden.
- Eine Klassifikation durch eine unscharfe Cluster-Analyse ist vorteilhaft, wenn keine klar ausgebildete Klassenstruktur vorliegt bzw. wenn sich nicht alle Vektoren eindeutig einer Klasse zuordnen lassen.
- Ein Nachteil der Fuzzy-Clusteranalyse ist, dass keine Repräsentanten für Cluster ermittelt werden.


Kapitel ML: IX (Fortsetzung)

IX. Clusteranalyse

- Einordnung Data Mining
- Einführung in die Clusteranalyse
- Hierarchische Verfahren
- Iterative Verfahren
- Dichtebasierte Verfahren
- Cluster Evaluation
- Constrained Cluster Analysis

Dichtebasierte Verfahren

Prinzipien der Fusionierung



Dichtebasierte Verfahren

Dichtebasierte Verfahren versuchen, den Graphen $G = \langle V, E, w \rangle$ bzw. die Punktmenge V in Bereiche gleicher Dichte aufzuteilen.

Ansätze zur Dichteschätzung:

- parameterbasiert: die unterliegende Verteilung ist bekannt
- parameterlos: Histogramme (Konstruktion von Bar-Charts), Kerndichteschätzer (Überlagerung kontinuierlicher Funktionen)

Dichtebasierte Verfahren

Dichtebasierte Verfahren versuchen, den Graphen $G = \langle V, E, w \rangle$ bzw. die Punktmenge V in Bereiche gleicher Dichte aufzuteilen.

Ansätze zur Dichteschätzung:


- parameterbasiert: die unterliegende Verteilung ist bekannt
- parameterlos: Histogramme (Konstruktion von Bar-Charts), Kerndichteschätzer (Überlagerung kontinuierlicher Funktionen)

Beispiel (karibische Inseln):




Dichtebasierte Verfahren

Dichteschätzung mit Gauß'schem Kern für das Beispiel




Dichtebasierte Verfahren

Dichteschätzung mit Gauß'schem Kern für das Beispiel




Dichtebasierte Verfahren

Dichteschätzung mit Gauß'schem Kern für das Beispiel



Dichtebasierte Verfahren


Dichteschätzung mit Gauß'schem Kern für das Beispiel



Dichtebasierte Verfahren

DBSCAN: Prinzip der Dichteschätzung [Ester et al. 1996]

Sei $N_\epsilon(v)$ die ϵ -Nachbarschaft eines Punktes v . Unterscheidung von drei Punktypen:




1. v ist Kernpunkt (core point) $\Leftrightarrow |N_\epsilon(v)| \geq \text{MinPts}$
2. v ist Rauschen (noise point) $\Leftrightarrow$
 v ist von keinem Kernpunkt aus **dichteerreichbar** (density-reachable)
3. v ist Randpunkt (border point) in allen anderen Fällen

Dichtebasierte Verfahren

DBSCAN: Prinzip der Dichteschätzung

Ein Punkt u ist **dichteerreichbar** von einem Punkt v , falls gilt:

- (a) $u \in N_\epsilon(v)$, wobei v ein Kernpunkt ist, oder
- (b) es gibt eine Menge von Punkten $\{v_1, \dots, v_l\}$:
 $v_{i+1} \in N_\epsilon(v_i)$ und v_i ist Kernpunkt, $i = 1, \dots, l-1$, mit $v_1 = v$, $v_l = u$.




Bedingung (b) lässt sich als transitive Anwendung von Bedingung (a) auffassen.

Dichtebasierte Verfahren

DBSCAN: Cluster-Interpretation

Ein Cluster $C \subseteq V$ erfüllt folgende Bedingungen:

1. $\forall u, v$: Falls $v \in C$ und u dichteerreichbar von v , dann ist $u \in C$.




Dichtebasierte Verfahren


DBSCAN: Cluster-Interpretation

Ein Cluster $C \subseteq V$ erfüllt folgende Bedingungen:

1. $\forall u, v$: Falls $v \in C$ und u dichteerreichbar von v , dann ist $u \in C$.



2. $\forall u, v$: u ist **dichteverbunden** mit v , d.h., es existiert ein Punkt t von dem u und v dichteerreichbar sind.



Dichtebasierte Verfahren

DBSCAN: Algorithmus

Input: $G = \langle V, E, w \rangle$. Weighted graph.
 d . Distance function for nodes in V .
 ε . Neighborhood radius.
 $MinPts$. Lower bound for point number in ε -neighborhood.
Output: $\gamma : V \rightarrow \mathbb{Z}$. Cluster assignment function.

- 1.
- 2.
- 3.
4. $N_\varepsilon(v) = \text{neighborhood}(G, d, v, \varepsilon)$
5. **IF** $|N_\varepsilon(v)| \geq MinPts$ **THEN** // v is core point
6. $i = i + 1$
7. $C_i = \text{density_reachable_hull}(G, d, N_\varepsilon(v))$ // form a new cluster
8. **FOREACH** $v \in C_i$ **DO** $\gamma(v) = i$
9. **ELSE** $\gamma(v) = -1$ // v is preliminarily classified as noise
- 10.
- 11.

Dichtebasierte Verfahren


DBSCAN: Algorithmus

Input: $G = \langle V, E, w \rangle$. Weighted graph.
 d . Distance function for nodes in V .
 ε . Neighborhood radius.
 $MinPts$. Lower bound for point number in ε -neighborhood.
Output: $\gamma : V \rightarrow \mathbb{Z}$. Cluster assignment function.

1. $i = 0$
2. **WHILE** $\exists v : (v \in V \text{ AND } \gamma(v) = \perp)$ **DO** // $\perp$ = unclassified
3. $v = \text{choose_unclassified_point}(V)$
4. $N_\varepsilon(v) = \text{neighborhood}(G, d, v, \varepsilon)$
5. **IF** $|N_\varepsilon(v)| \geq MinPts$ **THEN** // v is core point
6. $i = i + 1$
7. $C_i = \text{density_reachable_hull}(G, d, N_\varepsilon(v))$ // form a new cluster
8. **FOREACH** $v \in C_i$ **DO** $\gamma(v) = i$
9. **ELSE** $\gamma(v) = -1$ // v is preliminarily classified as noise
10. **ENDDO**
11. **RETURN**(γ)


Dichtebasierte Verfahren

DBSCAN




Dichtebasierte Verfahren

DBSCAN




Dichtebasierte Verfahren

DBSCAN




Dichtebasierte Verfahren

DBSCAN




Dichtebasierte Verfahren

DBSCAN



Dichtebasierte Verfahren


DBSCAN



- Core point
- Border point

Dichtebasierte Verfahren


DBSCAN



- Core point
- Border point

Dichtebasierte Verfahren


DBSCAN



- Core point
- Border point
- Noise point

Dichtebasierte Verfahren


DBSCAN



- Core point
- Border point
- Noise point

Dichtebasierte Verfahren


DBSCAN



- Noise point

Dichtebasierte Verfahren

Prinzipien der Fusionierung



Dichtebasierte Verfahren

MajorClust: Prinzip der Dichteschätzung [Stein/Niggemann 1999]

Die gewichteten Kanten im Graph $G = \langle V, E, w \rangle$ werden als Kräfte interpretiert; Knoten desselben Clusters bündeln ihrer Kräfte. Illustration:

eindeutige Zugehörigkeitsentscheidung (mit Agglomeration):



Dichtebasierte Verfahren

MajorClust: Prinzip der Dichteschätzung [Stein/Niggemann 1999]

Die gewichteten Kanten im Graph $G = \langle V, E, w \rangle$ werden als Kräfte interpretiert; Knoten desselben Clusters bündeln ihrer Kräfte. Illustration:

eindeutige Zugehörigkeitsentscheidung (mit Agglomeration):



eindeutige Zugehörigkeitsentscheidung
(mit Cluster-Wechsel):



Dichtebasierte Verfahren

MajorClust: Prinzip der Dichteschätzung [Stein/Niggemann 1999]

Die gewichteten Kanten im Graph $G = \langle V, E, w \rangle$ werden als Kräfte interpretiert; Knoten desselben Clusters bündeln ihrer Kräfte. Illustration:


eindeutige Zugehörigkeitsentscheidung (mit Agglomeration):



eindeutige Zugehörigkeitsentscheidung
(mit Cluster-Wechsel):



mehrdeutige Zugehörigkeit:



Dichtebasierte Verfahren

MajorClust: Algorithmus

Input: $G = \langle V, E, w \rangle$. Weighted graph.
 d . Distance function for nodes in V .
Output: $\gamma : V \rightarrow \mathbb{N}$. Cluster assignment function.

- 1.
- 2.
- 3.
- 4.
5. **FOREACH** $v \in V$ **DO**
6. $\gamma^* = \underset{i: i \in \{1, \dots, |V|\}}{\operatorname{argmax}} \sum_{\{u, v\}: \{u, v\} \in E \wedge \gamma(u) = i} w(u, v)$
7. **IF** $\gamma(v) \neq \gamma^*$ **THEN** $\gamma(v) = \gamma^*$, $t = \text{False}$ **ENDIF** // relabeling
8. **ENDDO**
- 9.
- 10.

Dichtebasierte Verfahren


MajorClust: Algorithmus

Input: $G = \langle V, E, w \rangle$. Weighted graph.
 d . Distance function for nodes in V .
Output: $\gamma : V \rightarrow \mathbb{N}$. Cluster assignment function.

1. $i = 0$, $t = \text{False}$
2. **FOREACH** $v \in V$ **DO** $i = i + 1$, $\gamma(v) = i$ **ENDDO**
3. **UNLESS** t **DO**
4. $t = \text{True}$
5. **FOREACH** $v \in V$ **DO**
6. $\gamma^* = \underset{i: i \in \{1, \dots, |V|\}}{\operatorname{argmax}} \sum_{\{u, v\}: \{u, v\} \in E \wedge \gamma(u) = i} w(u, v)$
7. **IF** $\gamma(v) \neq \gamma^*$ **THEN** $\gamma(v) = \gamma^*$, $t = \text{False}$ **ENDIF** // relabeling
8. **ENDDO**
9. **ENDDO**
10. **RETURN**(γ)


Dichtebasierte Verfahren

MajorClust




Dichtebasierte Verfahren

MajorClust




Dichtebasierte Verfahren

MajorClust




Dichtebasierte Verfahren

MajorClust



Dichtebasierte Verfahren

MajorClust




ML: IX-163 Cluster Analysis

©STEIN 2002-2012

Dichtebasierte Verfahren

MajorClust




ML: IX-164 Cluster Analysis

©STEIN 2002-2012

Dichtebasierte Verfahren

MajorClust




ML: IX-165 Cluster Analysis

©STEIN 2002-2012

Dichtebasierte Verfahren

MajorClust




ML: IX-166 Cluster Analysis

©STEIN 2002-2012

Dichtebasierte Verfahren

MajorClust




ML: IX-167 Cluster Analysis

©STEIN 2002-2012

Dichtebasierte Verfahren

MajorClust




ML: IX-168 Cluster Analysis

©STEIN 2002-2012


Dichtebasierte Verfahren

MajorClust



Dichtebasierte Verfahren

MajorClust



Dichtebasierte Verfahren

MajorClust: Prinzip der Dichteschätzung (Fortsetzung)

Jedes $\mathcal{C} = \{C_1, \dots, C_k\}$ induziert k Teilgraphen. MajorClust ist eine Heuristik zur Maximierung des *gewichteten partiellen Kantenzusammenhangs*, $\Lambda(\mathcal{C})$.


$$\Lambda(\mathcal{C}) = \sum_{i=1}^k |C_i| \cdot \lambda_i$$

Dichtebasierte Verfahren

MajorClust: Prinzip der Dichteschätzung (Fortsetzung)

Jedes $\mathcal{C} = \{C_1, \dots, C_k\}$ induziert k Teilgraphen. MajorClust ist eine Heuristik zur Maximierung des *gewichteten partiellen Kantenzusammenhangs*, $\Lambda(\mathcal{C})$.

$$\Lambda(\mathcal{C}) = \sum_{i=1}^k |C_i| \cdot \lambda_i$$




Dichtebasierte Verfahren

MajorClust: Prinzip der Dichteschätzung (Fortsetzung)

Jedes $\mathcal{C} = \{C_1, \dots, C_k\}$ induziert k Teilgraphen. MajorClust ist eine Heuristik zur Maximierung des *gewichteten partiellen Kantenzusammenhangs*, $\Lambda(\mathcal{C})$.

$$\Lambda(\mathcal{C}) = \sum_{i=1}^k |C_i| \cdot \lambda_i$$




Dichtebasierte Verfahren

MajorClust: Prinzip der Dichteschätzung (Fortsetzung)


Jedes $\mathcal{C} = \{C_1, \dots, C_k\}$ induziert k Teilgraphen. MajorClust ist eine Heuristik zur Maximierung des *gewichteten partiellen Kantenzusammenhangs*, $\Lambda(\mathcal{C})$.

$$\Lambda(\mathcal{C}) = \sum_{i=1}^k |C_i| \cdot \lambda_i$$




Dichtebasierte Verfahren

MajorClust: Prinzip der Dichteschätzung (Fortsetzung)



Dichtebasierte Verfahren

MajorClust: Prinzip der Dichteschätzung (Fortsetzung)



Satz 1 (Strong Splitting Condition [Stein/Niggemann 1999])

Sei $\mathcal{C} = \{C_1, \dots, C_k\}$ eine Partitionierung eines Graphen $G = \langle V, E, w \rangle$; weiterhin bezeichne $\lambda(G)$ den Kantenzusammenhang von G und $\lambda_1, \dots, \lambda_k$ die Kantenzusammenhänge der von den $C_1, \dots, C_k$ induzierten Subgraphen.

Gilt $\lambda(G) < \min\{\lambda_1, \dots, \lambda_k\}$ (Strong Splitting Condition), so liefert Λ -Maximierung eine Aufteilung am minimalen Cut.

Dichtebasierte Verfahren

DBSCAN versus MajorClust: niedrigdimensionale Daten

Karte der karibischen Inseln, etwa 20.000 Punkte:




Dichtebasierte Verfahren

DBSCAN versus MajorClust: niedrigdimensionale Daten

Karte der karibischen Inseln, etwa 20.000 Punkte:




DBSCAN:



Dichtebasierte Verfahren

DBSCAN versus MajorClust: niedrigdimensionale Daten

Problematik geeigneter ϵ -Werte bei DBSCAN:



Dichtebasierte Verfahren

DBSCAN versus MajorClust: niedrigdimensionale Daten

Karte der karibischen Inseln, etwa 20.000 Punkte:




MajorClust:



Dichtebasierte Verfahren

DBSCAN versus MajorClust: niedrigdimensionale Daten

Problematik der globalen Analyse (keine Beschränkung auf eine ε -Nachbarschaft) bei MajorClust:



Dichtebasierte Verfahren

DBSCAN versus MajorClust: hochdimensionale Daten

Dokumentenkategorisierung mit dem Reuters-Korpus:

- 1000 Dokumente
- 10 Kategorien: Politik, Kultur, Wirtschaft, etc.
- die Dokumente sind gleichverteilt, gehören genau zu einer Kategorie
- Dimension des Merkmalsraums: **> 10.000**


DBSCAN:

- degeneriert mit steigender Zahl der Dimensionen
- Ursache ist die Bestimmung der ε -Nachbarschaft
- Ausweg ist eine Dimensionsreduktion, z. B. eine Einbettung der Daten mittels multidimensionaler Skalierung (MDS)

Dichtebasierte Verfahren

DBSCAN versus MajorClust: hochdimensionale Daten

Klassifikationsergebnisse (F -Measure), aufgetragen über Dimensionalität:



[Stein/Busch 2005]

Bemerkungen:

- Das Problem der Nachbarschaftssuche in hochdimensionalen Räumen ist meistens nicht effizient lösbar: Ab Dimensionen größer als 10-20 ist das lineare Durchsuchen aller Merkmalsvektoren effizienter als die Verwendung von hochentwickelten, raumpartitionierenden Datenstrukturen wie R -Tree, X -Tree, Quadtree, KD-Tree, etc. Einen Ausweg bieten die Ansätze wie Locality-Sensitive Hashing oder Fuzzy-Fingerprinting. Siehe auch: [Weber 99] [Gionis/Indyk/Motwani 99-04] [Stein 05] [Stein/SMZE 05]
- DBSCAN verwendet zur Bestimmung der ε -Nachbarschaft die R -Tree-Datenstruktur. Diese Datenstruktur leistet einen wesentlichen (wenn nicht den größten) Teil der Cluster-Analyse innerhalb von DBSCAN.
- Möchte man DBSCAN für hochdimensionale Daten verwenden, ist eine Einbettung der Daten in einen niedrigdimensionalen Raum unvermeidbar. Dabei ist zu bedenken, dass eine Dimensionsreduktion durch Einbettung rechenintensiv ist und das gute Laufzeitverhalten von DBSCAN zunichte macht.

Chapter ML: IX (continued)

IX. Clusteranalyse

- Einordnung Data Mining
- Einführung in die Clusteranalyse
- Hierarchische Verfahren
- Iterative Verfahren
- Dichtebasierte Verfahren
- **Cluster Evaluation**
- Constrained Cluster Analysis


Cluster Evaluation

Overview

"The validation of clustering structures is the most difficult and frustrating part of cluster analysis. Without a strong effort in this direction, cluster analysis will remain a black art accessible only to those true believers who have experience and great courage."


[Jain/Dubes 1990]

Cluster Evaluation [from Tan/Steinbach/Kumar 05]




Random points

Cluster Evaluation [from Tan/Steinbach/Kumar 05]




Random points




DBSCAN


Cluster Evaluation [from Tan/Steinbach/Kumar 05]



Random points




DBSCAN




k-means


Cluster Evaluation [from Tan/Steinbach/Kumar 05]




Random points



DBSCAN



k-means



Complete link

Cluster Evaluation

Overview

Cluster evaluation can address different issues:

- Provide evidence whether data contains non-random structures.
- Relate found structures in the data to externally provided class information.
- Rank alternative clusterings with regard to their quality.
- Determine the ideal number of clusters.
- Provide information to choose a suited clustering approach.

Cluster Evaluation

Overview

Cluster evaluation can address different issues:

- Provide evidence whether data contains non-random structures.
- Relate found structures in the data to externally provided class information.
- Rank alternative clusterings with regard to their quality.
- Determine the ideal number of clusters.
- Provide information to choose a suited clustering approach.

1. External validity measures:

Analyze how close is a clustering to a reference.

2. Internal validity measures:


Analyze intrinsic characteristics of a clustering.

3. Relative validity measures:

Analyze the sensitivity (of internal measures) during clustering generation.

Cluster Evaluation

Overview



F-Measure, Purity,
RAND statistics

Kullback-Leibler,
Entropy

Davies-Bouldin,
Dunn, ρ , λ

dilution analysis

elbow criterion,
GAP statistics

1. External validity measures:

Analyze how close is a clustering to a reference.

2. Internal validity measures:


Analyze intrinsic characteristics of a clustering.

3. Relative validity measures:

Analyze the sensitivity (of internal measures) during clustering generation.


Cluster Evaluation

External Validity Measures: *F*-Measure




Cluster Evaluation

External Validity Measures: *F*-Measure




Cluster Evaluation

External Validity Measures: *F*-Measure



Cluster Evaluation

External Validity Measures: *F*-Measure




(node-based analysis)

		Truth	
Hypothesis	P	P	N
	N		

Cluster Evaluation

External Validity Measures: *F*-Measure




(node-based analysis)

		Truth	
Hypothesis	P	P	N
	N	TP (a)	

Cluster Evaluation

External Validity Measures: F -Measure




(node-based analysis)

		Truth	
		P	N
Hypothesis	P	TP (a)	FP (b)
	N		

Cluster Evaluation

External Validity Measures: F -Measure




(node-based analysis)

		Truth	
		P	N
Hypothesis	P	TP (a)	FP (b)
	N	FN (c)	

Cluster Evaluation

External Validity Measures: F -Measure




(node-based analysis)

		Truth	
		P	N
Hypothesis	P	TP (a)	FP (b)
	N	FN (c)	TN (d)

Cluster Evaluation

External Validity Measures: F -Measure



(node-based analysis)

		Truth	
		P	N
Hypothesis	P	TP (a)	FP (b)
	N	FN (c)	TN (d)

Precision:


$$\frac{a}{a+b}$$

Recall:

$$\frac{a}{a+c}$$

Cluster Evaluation

External Validity Measures: F -Measure



(node-based analysis)

		Truth	
		P	N
Hypothesis	P	TP (a)	FP (b)
	N	FN (c)	TN (d)

Precision:

$$\frac{a}{a+b}$$

Recall:

$$\frac{a}{a+c}$$

F -measure:


$$F_{\alpha} = \frac{1 + \alpha}{\frac{1}{\text{precision}} + \frac{\alpha}{\text{recall}}}$$

$\alpha = 1$
 $\alpha \in (0; 1)$
 $\alpha > 1$

harmonic mean
 favor precision over recall
 favor recall over precision


Cluster Evaluation

External Validity Measures: F -Measure



Cluster Evaluation

External Validity Measures: F -Measure




High precision, low recall $\Rightarrow$ low F -measure.

ML: IX-205 Cluster Analysis

©STEIN 2002-2012

Cluster Evaluation

External Validity Measures: F -Measure




Low precision, low recall $\Rightarrow$ low F -measure.

ML: IX-206 Cluster Analysis

©STEIN 2002-2012

Cluster Evaluation

External Validity Measures: F -Measure




High precision, high recall $\Rightarrow$ high F -measure.

ML: IX-207 Cluster Analysis

©STEIN 2002-2012

Cluster Evaluation

External Validity Measures: F -Measure



(node-based analysis)

□ Clustering $\mathcal{C} = \{C_1, \dots, C_k\}$ and classification $\mathcal{C}^* = \{C_1^*, \dots, C_l^*\}$ of D .

□ $F_{i,j}$ is the F -measure of a cluster j computed *with respect to a class* i .

Recall of cluster j with respect to class i is $|C_j \cap C_i^*|/|C_i^*|$


Precision of cluster j with respect to class i is $|C_j \cap C_i^*|/|C_j|$

ML: IX-208 Cluster Analysis

©STEIN 2002-2012

Cluster Evaluation

External Validity Measures: F -Measure



(node-based analysis)

□ Clustering $\mathcal{C} = \{C_1, \dots, C_k\}$ and classification $\mathcal{C}^* = \{C_1^*, \dots, C_l^*\}$ of D .

□ $F_{i,j}$ is the F -measure of a cluster j computed *with respect to a class* i .

Recall of cluster j with respect to class i is $|C_j \cap C_i^*|/|C_i^*|$

Precision of cluster j with respect to class i is $|C_j \cap C_i^*|/|C_j|$

□ Micro-averaged F -measure for $\langle D, \mathcal{C}, \mathcal{C}^* \rangle$:


$$F = \sum_{i=1}^l \frac{|C_i^*|}{|D|} \cdot \max_{j=1, \dots, k} \{F_{i,j}\}$$

ML: IX-209 Cluster Analysis

©STEIN 2002-2012

Cluster Evaluation

External Validity Measures: F -Measure



(node-based analysis)

□ Clustering $\mathcal{C} = \{C_1, \dots, C_k\}$ and classification $\mathcal{C}^* = \{C_1^*, \dots, C_l^*\}$ of D .

□ $F_{i,j}$ is the F -measure of a cluster j computed *with respect to a class* i .

Recall of cluster j with respect to class i is $|C_j \cap C_i^*|/|C_i^*|$

Precision of cluster j with respect to class i is $|C_j \cap C_i^*|/|C_j|$

□ Macro-averaged F -measure for $\langle D, \mathcal{C}, \mathcal{C}^* \rangle$:


$$F = \frac{1}{l} \sum_{i=1}^l \max_{j=1, \dots, k} \{F_{i,j}\}$$

ML: IX-210 Cluster Analysis

©STEIN 2002-2012


Cluster Evaluation

External Validity Measures: Entropy



Cluster Evaluation


External Validity Measures: Entropy



- A cluster C acts as information source $\mathcal{L}$.
 $\mathcal{L}$ emits cluster labels $L_1, \dots, L_l$ with probabilities $P(L_1), \dots, P(L_l)$.

Cluster Evaluation


External Validity Measures: Entropy



- A cluster C acts as information source $\mathcal{L}$.
 $\mathcal{L}$ emits cluster labels $L_1, \dots, L_l$ with probabilities $P(L_1), \dots, P(L_l)$.
 $\hat{P}(\square) = 10/14, \quad \hat{P}(\blacksquare) = 4/14$

Cluster Evaluation


External Validity Measures: Entropy



- A cluster C acts as information source $\mathcal{L}$.
 $\mathcal{L}$ emits cluster labels $L_1, \dots, L_l$ with probabilities $P(L_1), \dots, P(L_l)$.
 $\hat{P}(\square) = 10/14, \quad \hat{P}(\blacksquare) = 4/14$
- Entropy of $\mathcal{L}$: $H(\mathcal{L}) = -\sum_{i=1}^l P(L_i) \cdot \log_2(P(L_i))$
Entropy of C_j wrt. $\mathcal{C}^*$: $H(C_j) = -\sum_{C_j \cap C_i^* \neq \emptyset} |C_j \cap C_i^*|/|C_j| \cdot \log_2(|C_j \cap C_i^*|/|C_j|)$

Cluster Evaluation


External Validity Measures: Entropy



- A cluster C acts as information source $\mathcal{L}$.
 $\mathcal{L}$ emits cluster labels $L_1, \dots, L_l$ with probabilities $P(L_1), \dots, P(L_l)$.
 $\hat{P}(\square) = 10/14, \quad \hat{P}(\blacksquare) = 4/14$
- Entropy of $\mathcal{L}$: $H(\mathcal{L}) = -\sum_{i=1}^l P(L_i) \cdot \log_2(P(L_i))$
Entropy of C_j wrt. $\mathcal{C}^*$: $H(C_j) = -\sum_{C_j \cap C_i^* \neq \emptyset} |C_j \cap C_i^*|/|C_j| \cdot \log_2(|C_j \cap C_i^*|/|C_j|)$
- Entropy of $\mathcal{C}$ wrt. $\mathcal{C}^*$: $H(\mathcal{C}) = \sum_{C_j \in \mathcal{C}} |C_j|/|D| \cdot H(C_j)$


Cluster Evaluation

External Validity Measures: Rand, Jaccard



Cluster Evaluation

External Validity Measures: Rand, Jaccard




$$R(\mathcal{C}) = \frac{|TP| + |TN|}{|TP| + |TN| + |FP| + |FN|} = \frac{|TP| + |TN|}{n(n-1)/2}, \quad \text{with } n = |D|$$

$$J(\mathcal{C}) = \frac{|TP|}{|TP| + |FP| + |FN|}$$


Cluster Evaluation

Internal Validity Measures: Link Correlation [from Tan/Steinbach/Kumar 05]



Cluster Evaluation


Internal Validity Measures: Link Correlation [from Tan/Steinbach/Kumar 05]



$$\begin{pmatrix} 1.0 & 0.2 & 0.1 & 0.3 & \dots & 0.1 & 0.0 \\ - & 1.0 & 0.1 & 0.0 & \dots & 0.0 & 0.2 \\ & & & & \vdots & & \\ - & - & - & - & - & 1.0 & 0.6 \\ - & - & - & - & - & - & 1.0 \end{pmatrix}$$

Cluster Evaluation


Internal Validity Measures: Link Correlation [from Tan/Steinbach/Kumar 05]



$$\begin{pmatrix} 1.0 & 0.2 & 0.1 & 0.3 & \dots & 0.1 & 0.0 \\ - & 1.0 & 0.1 & 0.0 & \dots & 0.0 & 0.2 \\ & & & & \vdots & & \\ - & - & - & - & - & 1.0 & 0.6 \\ - & - & - & - & - & - & 1.0 \end{pmatrix}$$

Cluster Evaluation

Internal Validity Measures: Link Correlation [from Tan/Steinbach/Kumar 05]




$$\begin{pmatrix} 1.0 & 0.2 & 0.1 & 0.3 & \dots & 0.1 & 0.0 \\ - & 1.0 & 0.1 & 0.0 & \dots & 0.0 & 0.2 \\ & & & & \vdots & & \\ - & - & - & - & - & 1.0 & 0.6 \\ - & - & - & - & - & - & 1.0 \end{pmatrix} \sim \begin{pmatrix} 1 & 0 & 0 & 1 & \dots & 0 & 0 \\ - & 1 & 0 & 0 & \dots & 0 & 1 \\ & & & & \vdots & & \\ - & - & - & - & - & 1 & 1 \\ - & - & - & - & - & - & 1 \end{pmatrix}$$


- Construct occurrence matrix based on cluster analysis.
- Compare similarity matrix to occurrence matrix: correlation τ

Cluster Evaluation

Internal Validity Measures: Link Correlation [from Tan/Steinbach/Kumar 05]



k-means
 $\tau = 0.5810$




k-means
 $\tau = 0.9235$

$$\begin{pmatrix} 1.0 & 0.2 & 0.1 & 0.3 & \dots & 0.1 & 0.0 \\ - & 1.0 & 0.1 & 0.0 & \dots & 0.0 & 0.2 \\ & & & & \vdots & & \\ - & - & - & - & - & 1.0 & 0.6 \\ - & - & - & - & - & - & 1.0 \end{pmatrix} \sim \begin{pmatrix} 1 & 0 & 0 & 1 & \dots & 0 & 0 \\ - & 1 & 0 & 0 & \dots & 0 & 1 \\ & & & & \vdots & & \\ - & - & - & - & - & 1 & 1 \\ - & - & - & - & - & - & 1 \end{pmatrix}$$


- Construct occurrence matrix based on cluster analysis.
- Compare similarity matrix to occurrence matrix: correlation τ

Cluster Evaluation

Internal Validity Measures: Link Correlation [from Tan/Steinbach/Kumar 05]



k-means at structured data.




Similarity matrix sorted by cluster label.

ML: IX-223 Cluster Analysis


©STEIN 2002-2012

Cluster Evaluation

Internal Validity Measures: Link Correlation [from Tan/Steinbach/Kumar 05]



DBSCAN at random data.




Similarity matrix sorted by cluster label.

ML: IX-224 Cluster Analysis


©STEIN 2002-2012

Cluster Evaluation

Internal Validity Measures: Link Correlation [from Tan/Steinbach/Kumar 05]



k-means at random data.




Similarity matrix sorted by cluster label.

ML: IX-225 Cluster Analysis


©STEIN 2002-2012

Cluster Evaluation

Internal Validity Measures: Link Correlation [from Tan/Steinbach/Kumar 05]



Complete link at random data.



Similarity matrix sorted by cluster label.

ML: IX-226 Cluster Analysis


©STEIN 2002-2012

Cluster Evaluation

Internal Validity Measures: Link Correlation [from Tan/Steinbach/Kumar 05]



DBSCAN at structured data.




Similarity matrix sorted by cluster label.

ML: IX-227 Cluster Analysis

©STEIN 2002-2012

Cluster Evaluation

Internal Validity Measures: Structural Analysis




- Distance between two clusters, $\delta(C_1, C_2)$.
- Diameter of a cluster, $\Delta(C)$.
- Scatter within a cluster, $\sigma^2(C)$, SSE.

ML: IX-228 Cluster Analysis

©STEIN 2002-2012

Cluster Evaluation

Internal Validity Measures: Structural Analysis




- Distance between two clusters, $\delta(C_1, C_2)$.
- Diameter of a cluster, $\Delta(C)$.
- Scatter within a cluster, $\sigma^2(C)$, SSE.

ML: IX-229 Cluster Analysis

©STEIN 2002-2012

Cluster Evaluation

Internal Validity Measures: Structural Analysis




- Distance between two clusters, $\delta(C_1, C_2)$.
- Diameter of a cluster, $\Delta(C)$.
- Scatter within a cluster, $\sigma^2(C)$, SSE.

ML: IX-230 Cluster Analysis

©STEIN 2002-2012

Cluster Evaluation

Internal Validity Measures: Structural Analysis




- Distance between two clusters, $\delta(C_1, C_2)$.
- Diameter of a cluster, $\Delta(C)$.
- Scatter within a cluster, $\sigma^2(C)$, SSE.

ML: IX-231 Cluster Analysis

©STEIN 2002-2012

Cluster Evaluation

Internal Validity Measures: Dunn Index



$$I(\mathcal{C}) = \frac{\min_{i \neq j} \{\delta(C_i, C_j)\}}{\max_{1 \leq l \leq k} \{\Delta(C_l)\}},$$


$$I(\mathcal{C}) \rightarrow \max$$

ML: IX-232 Cluster Analysis

©STEIN 2002-2012

Cluster Evaluation

Internal Validity Measures: Dunn Index



$$I(\mathcal{C}) = \frac{\min_{i \neq j} \{\delta(C_i, C_j)\}}{\max_{1 \leq l \leq k} \{\Delta(C_l)\}},$$


$$I(\mathcal{C}) \rightarrow \max$$

ML: IX-233 Cluster Analysis

©STEIN 2002-2012

Cluster Evaluation

Internal Validity Measures: Dunn Index



$$I(\mathcal{C}) = \frac{\min_{i \neq j} \{\delta(C_i, C_j)\}}{\max_{1 \leq l \leq k} \{\Delta(C_l)\}},$$


$$I(\mathcal{C}) \rightarrow \max$$

ML: IX-234 Cluster Analysis

©STEIN 2002-2012

Cluster Evaluation

Internal Validity Measures: Dunn Index



$$I(\mathcal{C}) = \frac{\min_{i \neq j} \{\delta(C_i, C_j)\}}{\max_{1 \leq l \leq k} \{\Delta(C_l)\}},$$

$$I(\mathcal{C}) \rightarrow \max$$


- Dunn is susceptible to noise.
- Dunn is biased towards the worst substructure in a clustering (cf. min)
- Dunn cannot put distances and diameters into relation.

ML: IX-235 Cluster Analysis

©STEIN 2002-2012

Cluster Evaluation

Internal Validity Measures: Dunn Index



$$I(\mathcal{C}) = \frac{\min_{i \neq j} \{\delta(C_i, C_j)\}}{\max_{1 \leq l \leq k} \{\Delta(C_l)\}},$$

$$I(\mathcal{C}) \rightarrow \max$$


- Dunn is susceptible to noise.
- Dunn is biased towards the worst substructure in a clustering (cf. min)
- Dunn cannot put distances and diameters into relation.

ML: IX-236 Cluster Analysis

©STEIN 2002-2012

Cluster Evaluation

Internal Validity Measures: Expected Density ρ [Stein/Meyer zu Eissen 2007]




ML: IX-237 Cluster Analysis

©STEIN 2002-2012

Cluster Evaluation

Internal Validity Measures: Expected Density ρ [Stein/Meyer zu Eissen 2007]




Different retrieval models yield different similarity graphs.

ML: IX-238 Cluster Analysis

©STEIN 2002-2012

Cluster Evaluation

Internal Validity Measures: Expected Density ρ [Stein/Meyer zu Eissen 2007]




Different retrieval models yield different similarity graphs.

ML: IX-239 Cluster Analysis

©STEIN 2002-2012

Cluster Evaluation

Internal Validity Measures: Expected Density ρ




Compare (for alternative clusterings) the similarity density within the clusters to the average similarity of the entire graph.

ML: IX-240 Cluster Analysis

©STEIN 2002-2012

Cluster Evaluation


Internal Validity Measures: Expected Density ρ



Compare (for alternative clusterings) the similarity density within the clusters to the average similarity of the entire graph.

Cluster Evaluation

Internal Validity Measures: Expected Density ρ



Compare (for alternative clusterings) the similarity density within the clusters to the average similarity of the entire graph.

Cluster Evaluation

Internal Validity Measures: Expected Density ρ

Graph $G = \langle V, E \rangle$

- G is called sparse [dense] if $|E| = O(|V|)$ [$O(|V|^2)$]
- the density θ computes from the equation $|E| = |V|^\theta$

Cluster Evaluation

Internal Validity Measures: Expected Density ρ

Graph $G = \langle V, E \rangle$

- G is called sparse [dense] if $|E| = O(|V|)$ [$O(|V|^2)$]
- the density θ computes from the equation $|E| = |V|^\theta$

Similarity graph $G = \langle V, E, w \rangle$, $|E| \sim w(G) := \sum_{e \in E} w(e)$

- the density θ computes from the equation $w(G) = |V|^\theta$

Cluster Evaluation

Internal Validity Measures: Expected Density ρ

Graph $G = \langle V, E \rangle$

- G is called sparse [dense] if $|E| = O(|V|)$ [$O(|V|^2)$]
- the density θ computes from the equation $|E| = |V|^\theta$

Similarity graph $G = \langle V, E, w \rangle$, $|E| \sim w(G) := \sum_{e \in E} w(e)$

- the density θ computes from the equation $w(G) = |V|^\theta$

Induced subgraph G_i for class C_i

- the **expected density** ρ compares class C_i to the density average in D

$$\rho(G_i) = \frac{w(G_i)}{|V_i|^\theta}$$

Cluster Evaluation


Relative Validity Measures: Elbow Criterion

1. Hyperparameters of a clustering algorithm: $p_1, \dots, p_m$
 - number of centroids for k -means
 - stopping level for hierarchical algorithms
 - neighborhood size for DBSCAN
2. Clusterings $\mathcal{C} = \{C_{p_1}, \dots, C_{p_m}\}$ associated with $p_1, \dots, p_m$.
3. Points of an error curve $\{(p_i, e(C_{p_i})) \mid i = 1, \dots, m\}$.

Cluster Evaluation

Relative Validity Measures: Elbow Criterion



1. Hyperparameters of a clustering algorithm: $p_1, \dots, p_m$
 - number of centroids for k -means
 - stopping level for hierarchical algorithms
 - neighborhood size for DBSCAN
2. Clusterings $\mathcal{C} = \{C_{p_1}, \dots, C_{p_m}\}$ associated with $p_1, \dots, p_m$.
3. Points of an error curve $\{(p_i, e(C_{p_i})) \mid i = 1, \dots, m\}$.



Cluster Evaluation

Relative Validity Measures: Elbow Criterion


1. Hyperparameters of a clustering algorithm: $p_1, \dots, p_m$
 - number of centroids for k -means
 - stopping level for hierarchical algorithms
 - neighborhood size for DBSCAN
2. Clusterings $\mathcal{C} = \{C_{p_1}, \dots, C_{p_m}\}$ associated with $p_1, \dots, p_m$.
3. Points of an error curve $\{(p_i, e(C_{p_i})) \mid i = 1, \dots, m\}$.



4. Find point that maximizes error drop with respect to its predecessor.

Cluster Evaluation

Relative Validity Measures: Elbow Criterion




d_C : Hamming distance
Merging: complete link

<http://cs.jhu.edu/~ravann/ta-expedition/2.6.x.html>

Relations between 1377 file systems for Linux Kernel 2.6.0. [Razvan Musaloiu-E. 2009]

Cluster Evaluation

Relative Validity Measures: Elbow Criterion



d_C : Hamming distance
Merging: group average link

<http://cs.jhu.edu/~ravann/ta-expedition/2.6.x.html>

Relations between 1377 file systems for Linux Kernel 2.6.0. [Razvan Musaloiu-E. 2009]

Cluster Evaluation

Correlation between External and Internal Measures

In the wild, we are not given a reference classification.

- An external evaluation is not possible.
(though many papers report on such experiments)
- Resort to an internal evaluation.
(connectivity, squared error sums, distance-diameter heuristics, etc.)

Cluster Evaluation

Correlation between External and Internal Measures

In the wild, we are not given a reference classification.

- An external evaluation is not possible.
(though many papers report on such experiments)
- Resort to an internal evaluation.
(connectivity, squared error sums, distance-diameter heuristics, etc.)


"To which extent can an internal evaluation be used to predict for a clustering its distance from the best reference classification—say, to predict the F -measure?"

$$\operatorname{argmax}_{\phi} \{ \tau(X, Y) \mid x = F(C), y = \phi(C), C \in \mathcal{C} \}$$

[Stein/Meyer zu Eissen 2007]

Cluster Evaluation

Correlation between External and Internal Measures




Perfect correlation (desired).

ML: IX-253 Cluster Analysis

©STEIN 2002-2012

Cluster Evaluation

Correlation between External and Internal Measures



$$\text{Davies-Bouldin: } \frac{1}{k} \cdot \sum_{i=1}^k \max_j \frac{s(C_i) + s(C_j)}{\delta(C_i, C_j)}$$


Prefers spherical clusters.

ML: IX-254 Cluster Analysis

©STEIN 2002-2012

Cluster Evaluation

Correlation between External and Internal Measures



$$\text{Dunn Index: } \frac{\min_{i \neq j} \{\delta(C_i, C_j)\}}{\max_{1 \leq l \leq k} \{\Delta(C_l)\}}$$


Maximizes dilatation = inter/intra-cluster-diameter.

ML: IX-255 Cluster Analysis

©STEIN 2002-2012

Cluster Evaluation

Correlation between External and Internal Measures



$$\text{Expected Density: } \bar{\rho} = \sum_{i=1}^k \frac{|V_i|}{|V|} \cdot \frac{w(G_i)}{|V_i|^\theta}$$

Independent of cluster forms and sizes.

ML: IX-256 Cluster Analysis

©STEIN 2002-2012

Chapter ML: IX (continued)

IX. Clusteranalyse

- ☐ Einordnung Data Mining
- ☐ Einführung in die Clusteranalyse
- ☐ Hierarchische Verfahren
- ☐ Iterative Verfahren
- ☐ Dichtebasierte Verfahren
- ☐ Cluster Evaluation
- ☐ Constrained Cluster Analysis

ML: IX-257 Cluster Analysis

©STEIN 2002-2012

Constrained Cluster Analysis

Person Resolution Task



ML: IX-258 Cluster Analysis

©STEIN 2002-2012

Constrained Cluster Analysis

Person Resolution Task



ML: IX-259 Cluster Analysis

©STEIN 2002-2012

Constrained Cluster Analysis

Person Resolution Task




ML: IX-260 Cluster Analysis

©STEIN 2002-2012

Constrained Cluster Analysis

Person Resolution Task




ML: IX-261 Cluster Analysis

©STEIN 2002-2012

Constrained Cluster Analysis

Person Resolution Task



Multi-document resolution task:


$$\begin{aligned} \text{Names, Target names: } & N = \{n_1, \dots, n_l\}, & T \subset N \\ \text{Referents: } & R = \{r_1, \dots, r_m\}, & \tau: R \rightarrow T, |R| \gg |T| \\ \text{Documents: } & D = \{d_1, \dots, d_n\}, & \nu: D \rightarrow \mathcal{P}(N), |\nu(d_i) \cap T| = 1 \\ \text{A solution: } & \gamma: D \rightarrow R, & \text{s.t. } \tau(\gamma(d_i)) \in \nu(d_i) \end{aligned}$$

ML: IX-262 Cluster Analysis

©STEIN 2002-2012

Constrained Cluster Analysis

Person Resolution Task



Facts about the Spock data mining challenge:


Target names: $|T| = 44$
 Referents: $|R| = 1101$
 Documents: $|D_{train}| = 27000$ (labeled $\approx 2.3\text{GB}$)
 $|D_{test}| = 75000$ (unlabeled $\approx 7.8\text{GB}$)

ML: IX-263 Cluster Analysis

©STEIN 2002-2012

Constrained Cluster Analysis

Person Resolution Task



- up to 105 referents for a single target name
- about 25 referents on average per target name

- about 23 documents on average per referent

Facts about the Spock data mining challenge:


Target names: $|T| = 44$
 Referents: $|R| = 1101$
 Documents: $|D_{train}| = 27000$ (labeled $\approx 2.3\text{GB}$)
 $|D_{test}| = 75000$ (unlabeled $\approx 7.8\text{GB}$)

ML: IX-264 Cluster Analysis

©STEIN 2002-2012

Constrained Cluster Analysis


Applied to Multi-Document Resolution



1. Model similarities → new and established retrieval models:
 - global and context-based vector space models
 - explicit semantic analysis
 - ontology alignment
2. Learn class memberships (supervised) → logistic regression
3. Find equivalence classes (unsupervised) → cluster analysis:
 - (a) adaptive graph thinning
 - (b) multiple, density-based cluster analysis
 - (c) clustering selection by expected density maximization

Constrained Cluster Analysis


Applied to Multi-Document Resolution



1. Model similarities → new and established retrieval models:
 - global and context-based vector space models
 - explicit semantic analysis
 - ontology alignment
2. Learn class memberships (supervised) → logistic regression
3. Find equivalence classes (unsupervised) → cluster analysis:
 - (a) adaptive graph thinning
 - (b) multiple, density-based cluster analysis
 - (c) clustering selection by expected density maximization

Constrained Cluster Analysis


Applied to Multi-Document Resolution



1. Model similarities → new and established retrieval models:
 - global and context-based vector space models
 - explicit semantic analysis
 - ontology alignment
2. Learn class memberships (supervised) → logistic regression
3. Find equivalence classes (unsupervised) → cluster analysis:
 - (a) adaptive graph thinning
 - (b) multiple, density-based cluster analysis
 - (c) clustering selection by expected density maximization

Constrained Cluster Analysis


Applied to Multi-Document Resolution



1. Model similarities → new and established retrieval models:
 - global and context-based vector space models
 - explicit semantic analysis
 - ontology alignment
2. Learn class memberships (supervised) → logistic regression
3. Find equivalence classes (unsupervised) → cluster analysis:
 - (a) adaptive graph thinning
 - (b) multiple, density-based cluster analysis
 - (c) clustering selection by expected density maximization

Constrained Cluster Analysis


Applied to Multi-Document Resolution



1. Model similarities → new and established retrieval models:
 - global and context-based vector space models
 - explicit semantic analysis
 - ontology alignment
2. Learn class memberships (supervised) → logistic regression
3. Find equivalence classes (unsupervised) → cluster analysis:
 - (a) adaptive graph thinning
 - (b) multiple, density-based cluster analysis
 - (c) clustering selection by expected density maximization

Constrained Cluster Analysis


Applied to Multi-Document Resolution



1. Model similarities → new and established retrieval models:
 - global and context-based vector space models
 - explicit semantic analysis
 - ontology alignment
2. Learn class memberships (supervised) → logistic regression
3. Find equivalence classes (unsupervised) → cluster analysis:
 - (a) adaptive graph thinning
 - (b) multiple, density-based cluster analysis
 - (c) clustering selection by expected density maximization

Constrained Cluster Analysis

Idealized Class Membership Distribution over Similarities



Similarity distributions for document pairs from **different referents** and **same referent**.

Logistic regression task:


- sample size: 400 000
- classes imbalance: **non-target class** : **target class** $\approx$ 25:1
- items are drawn uniformly distributed wrt. non-targets and targets
- items are uniformly distributed over the groups of target names

ML: IX-271 Cluster Analysis

©STEIN 2002-2012

Constrained Cluster Analysis

Membership Distribution under *tf-idf* Vector Space Model



Model details:


- corpus size: 25 000 documents
- dictionary size: 1,2 Mio terms
- stopwords number: 850
- stopwords volume: 36%

ML: IX-272 Cluster Analysis

©STEIN 2002-2012

Constrained Cluster Analysis

Membership Distribution under Context-Based Vector Space Model



Model details:


- corpus size: 25 000 documents
- dictionary size: 1,2 Mio terms
- stopwords number: 850
- stopwords volume: 36%

ML: IX-273 Cluster Analysis

©STEIN 2002-2012


Constrained Cluster Analysis

Membership Distribution under Ontology Alignment Model



Model details:

- DMOZ open directory project
- > 5 million documents
- 12 top-level categories
- 31 second level categories
- ML: hierarchical Bayes
- training set: 100 000 pages




ML: IX-274 Cluster Analysis

©STEIN 2002-2012

Constrained Cluster Analysis


In-Depth: Multi-Class Hierarchical Classification

Flat (big-bang) classification



- + simple realization
- loss of discriminative power with increasing number of categories

Hierarchical (top-down) classification



- + specialized classifiers (divide and conquer)
- misclassification at higher levels can never become repaired

ML: IX-275 Cluster Analysis

©STEIN 2002-2012

Constrained Cluster Analysis

In-Depth: Multi-Class Hierarchical Classification

State of the art of effectiveness analyses:

1. independence assumption between categories
2. neglect of both hierarchical structure and degree of misclassification



Improvements:

- Consider similarity $\varphi(C_i, C_j)$ between correct and wrong category.
- Consider graph distance $d(C_i, C_j)$ between correct and wrong category.

ML: IX-276 Cluster Analysis

©STEIN 2002-2012


Constrained Cluster Analysis

In-Depth: Multi-Class Hierarchical Classification


Improvements continued:

Multi-label (multi path) classification

Multi-classifier (ensemble) classification




- traverse more than one path and return all labels
- employ probabilistic classifiers with a threshold: split a path or not



- classification result is a majority decision
- employ different classifier (different types or differently parameterized)

Constrained Cluster Analysis


Membership Distribution under Optimized Retrieval Model Combination



Retrieval Model	$F_{1/3}$ -Measure
<i>tfidf</i> vector space	0.39
context-based vector space	0.32
ESA Wikipedia persons	0.30
phrase structure grammar	0.17
ontology alignment	0.15
optimized combination	0.42

Constrained Cluster Analysis

Membership Distribution under Optimized Retrieval Model Combination




Retrieval Model	$F_{1/3}$ -Measure
<i>tfidf</i> vector space	0.39
context-based vector space	0.32
ESA Wikipedia persons	0.30
phrase structure grammar	0.17
ontology alignment	0.15
optimized combination	0.42




Constrained Cluster Analysis

Membership Distribution under Optimized Retrieval Model Combination




Retrieval Model	$F_{1/3}$ -Measure
<i>tfidf</i> vector space	0.39
context-based vector space	0.32
ESA Wikipedia persons	0.30
phrase structure grammar	0.17
ontology alignment	0.15
optimized combination	0.42




Constrained Cluster Analysis

Membership Distribution under Optimized Retrieval Model Combination




Retrieval Model	$F_{1/3}$ -Measure
<i>tfidf</i> vector space	0.39
context-based vector space	0.32
ESA Wikipedia persons	0.30
phrase structure grammar	0.17
ontology alignment	0.15
optimized combination	0.42



Constrained Cluster Analysis


Membership Distribution under Optimized Retrieval Model Combination



In the example:


- precision = 0.4
- recall = 0.43
- $F_{1/3} = 0.41$

(if false negatives are uniformly distributed)




Constrained Cluster Analysis

In-Depth: Analysis of Classifier Effectiveness



Consideration of imbalance:



ML: IX-283 Cluster Analysis

©STEIN 2002-2012


Constrained Cluster Analysis

In-Depth: Analysis of Classifier Effectiveness

- class imbalance factor (CIF) of 25
- ⇒ precision in interval $[0.725; 1]$ for edges between same referents: ≈ 0.17

How can $F_{1/3} = 0.42$ be achieved via cluster analysis?

Consideration of imbalance:




ML: IX-284 Cluster Analysis

©STEIN 2002-2012

Constrained Cluster Analysis

In-Depth: Analysis of Classifier Effectiveness



Assumption: uniform distribution of referents over documents (here: 25 clusters with $|C| = 23$)

- ⇒ $|TP|$ true 1-similarities per cluster (here: 130 @ threshold 0.725)
- ⇒ $\frac{|TP|}{|C|}$ degree of true positives per node (here: 11)
- ⇒ $|TP|(\frac{1}{\text{precision}} - 1)$ false 1-similarities per cluster (here: 760)

Density-based cluster analysis: effective false positives, FP^* , connect to same cluster

- ⇒ analyze $P(|FP^*| > k \mid D, R_{iid})$ (here: $E(|FP^*|) = 2.7$)
- ⇒ edge tie factor (ETF) specifies the excess of true positives until tie (here: $3 \dots 5$)


$$ETF = \frac{|TP|}{|C| \cdot E(|FP^*|)}, \quad \text{effective precision} = \text{precision} \cdot \frac{CIF}{ETF}$$

ML: IX-285 Cluster Analysis

©STEIN 2002-2012

Constrained Cluster Analysis

In-Depth: Analysis of Classifier Effectiveness



Assumption: uniform distribution of referents over documents (here: 25 clusters with $|C| = 23$)

- ⇒ $|TP|$ true 1-similarities per cluster (here: 130 @ threshold 0.725)
- ⇒ $\frac{|TP|}{|C|}$ degree of true positives per node (here: 11)
- ⇒ $|TP|(\frac{1}{\text{precision}} - 1)$ false 1-similarities per cluster (here: 760)

Density-based cluster analysis: effective false positives, FP^* , connect to same cluster

- ⇒ analyze $P(|FP^*| > k \mid D, R_{iid})$ (here: $E(|FP^*|) = 2.7$)
- ⇒ edge tie factor (ETF) specifies the excess of true positives until tie (here: $3 \dots 5$)


$$ETF = \frac{|TP|}{|C| \cdot E(|FP^*|)}, \quad \text{effective precision} = \text{precision} \cdot \frac{CIF}{ETF}$$

ML: IX-286 Cluster Analysis

©STEIN 2002-2012

Constrained Cluster Analysis

In-Depth: Analysis of Classifier Effectiveness



Assumption: uniform distribution of referents over documents (here: 25 clusters with $|C| = 23$)

- ⇒ $|TP|$ true 1-similarities per cluster (here: 130 @ threshold 0.725)
- ⇒ $\frac{|TP|}{|C|}$ degree of true positives per node (here: 11)
- ⇒ $|TP|(\frac{1}{\text{precision}} - 1)$ false 1-similarities per cluster (here: 760)

Density-based cluster analysis: effective false positives, FP^* , connect to same cluster

- ⇒ analyze $P(|FP^*| > k \mid D, R_{iid})$ (here: $E(|FP^*|) = 2.7$)
- ⇒ edge tie factor (ETF) specifies the excess of true positives until tie (here: $3 \dots 5$)


$$ETF = \frac{|TP|}{|C| \cdot E(|FP^*|)}, \quad \text{effective precision} = \text{precision} \cdot \frac{CIF}{ETF}$$

ML: IX-287 Cluster Analysis

©STEIN 2002-2012

Constrained Cluster Analysis

In-Depth: Analysis of Classifier Effectiveness



Assumption: uniform distribution of referents over documents (here: 25 clusters with $|C| = 23$)

- ⇒ $|TP|$ true 1-similarities per cluster (here: 130 @ threshold 0.725)
- ⇒ $\frac{|TP|}{|C|}$ degree of true positives per node (here: 11)
- ⇒ $|TP|(\frac{1}{\text{precision}} - 1)$ false 1-similarities per cluster (here: 760)

Density-based cluster analysis: effective false positives, FP^* , connect to same cluster

- ⇒ analyze $P(|FP^*| > k \mid D, R_{iid})$ (here: $E(|FP^*|) = 2.7$)
- ⇒ edge tie factor (ETF) specifies the excess of true positives until tie (here: $3 \dots 5$)


$$ETF = \frac{|TP|}{|C| \cdot E(|FP^*|)}, \quad \text{effective precision} = \text{precision} \cdot \frac{CIF}{ETF}$$

ML: IX-288 Cluster Analysis

©STEIN 2002-2012

Constrained Cluster Analysis

In-Depth: Analysis of Classifier Effectiveness



Assumption: uniform distribution of referents over documents (here: 25 clusters with $|C| = 23$)

⇒ $|TP|$ true 1-similarities per cluster (here: 130 @ threshold 0.725)

⇒ $\frac{|TP|}{|C|}$ degree of true positives per node (here: 11)

⇒ $|TP|(\frac{1}{\text{precision}} - 1)$ false 1-similarities per cluster (here: 760)

Density-based cluster analysis: **effective false positives**, FP^* , connect to same cluster

⇒ analyze $P(|FP^*| > k \mid D, R_{iid})$ (here: $E(|FP^*|) = 2.7$)

⇒ edge tie factor (ETF) specifies the excess of true positives until tie (here: 3...5)


$$ETF = \frac{|TP|}{|C| \cdot E(|FP^*|)}, \quad \text{effective precision} = \text{precision} \cdot \frac{CIF}{ETF}$$

ML: IX-289 Cluster Analysis

©STEIN 2002-2012

Constrained Cluster Analysis

In-Depth: Analysis of Classifier Effectiveness



Density-based cluster analysis: **effective false positives**, FP^* , connect to same cluster

⇒ analyze $P(|FP^*| > k \mid D, R_{iid})$ (here: $E(|FP^*|) = 2.7$)

⇒ edge tie factor (ETF) specifies the excess of true positives until tie (here: 3...5)


$$ETF = \frac{|TP|}{|C| \cdot E(|FP^*|)}, \quad \text{effective precision} = \text{precision} \cdot \frac{CIF}{ETF}$$

ML: IX-290 Cluster Analysis

©STEIN 2002-2012

Constrained Cluster Analysis

In-Depth: Analysis of Classifier Effectiveness



Determine optimum similarity threshold for class-membership function:

$$\theta^* = \operatorname{argmax}_{\theta \in [0,1]} \left\{ \frac{1 + \alpha}{\frac{ETF}{\text{precision}_\theta \cdot CIF} + \frac{\alpha}{\text{recall}_\theta}} \right\}$$

θ^* considers co-variate shift, introduces model formation bias and sample selection bias.

ML: IX-291 Cluster Analysis

©STEIN 2002-2012

Constrained Cluster Analysis

Model Selection: Our Risk Minimization Strategy

Retrieval Model	$F_{1/3}$ -Measure
<i>tfidf</i> vector space	0.39
context-based vector space	0.32
ESA Wikipedia persons	0.30
phrase structure grammar	0.17
ontology alignment	0.15
optimized combination	0.42
Ensemble cluster analysis	0.40

Ensemble cluster analysis: higher bias, better generalization.

(1) Do we speculate on a better fit?

(2) Do we expect a significant covariate shift, more noise, etc.?

ML: IX-292 Cluster Analysis

©STEIN 2002-2012

Constrained Cluster Analysis

Recap

1. Multi-document resolution can be tackled with constrained cluster analysis.
2. Constraints are derived from labeled examples.
3. Class membership function ties constraints to multiple retrieval models.
4. Advanced density-based clustering technology is key.

ML: IX-293 Cluster Analysis

©STEIN 2002-2012

Constrained Cluster Analysis

References

- Disambiguating Web Appearances of People in a Social Network.
[R. Bekkerman, A. McCallum. WWW 2005]
- A Bayesian Model for Supervised Clustering with the Dirichlet Process Prior.
[H. Daumé III, D. Marcu. Journal MLR 2005]
- Computing Semantic Relatedness Using Wikipedia-based Explicit Semantic Analysis.
[E. Gabrilovich, S. Markovitch. IJCAI 2007]
- Unsupervised Discrimination of Person Names in Web Contexts.
[T. Pedersen, A. Kulkarni. CILing 2007]
- On Information Need and Categorizing Search.
[S. Meyer zu Eissen. Dissertation, Paderborn University, 2007]
- Weighted Experts: A Solution for the Spock Data Mining Challenge.
[B. Stein, S. Meyer zu Eissen. I-KNOW 2008]
- GRAPE: A System for Disambiguating and Tagging People Names in Web Search.
[L. Jiang, W. Shen, J. Wang, N. An]

ML: IX-294 Cluster Analysis

©STEIN 2002-2012