Text Clustern

Clustern

- Teile nicht kategorisierte Beispiele in disjunkte Untermengen, so genannte *Cluster*, ein, so daß:
  - Beispiele innerhalb eines Clusters sich sehr ähnlich
  - Beispiele in verschiedenen Clustern möglichst sehr unterschiedlich sind.
- Entdecke neue Kategorien in einer *unüberwachten* Art
- es werden keine Schlagwort für die Kategorien vorab zur Verfügung gestellt

Einführung Clustern

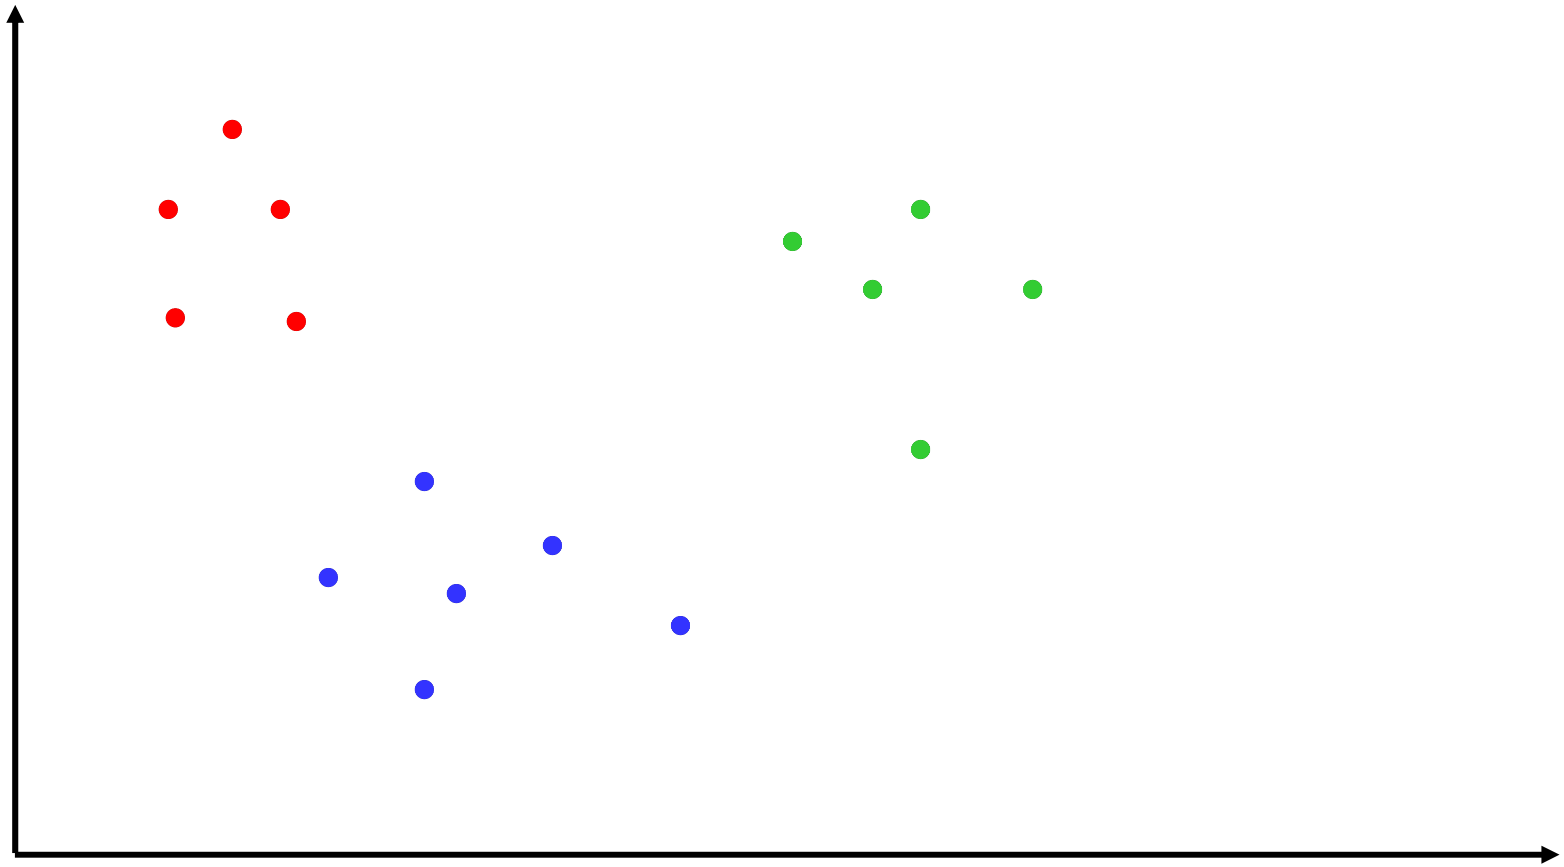

Einführung Clustern

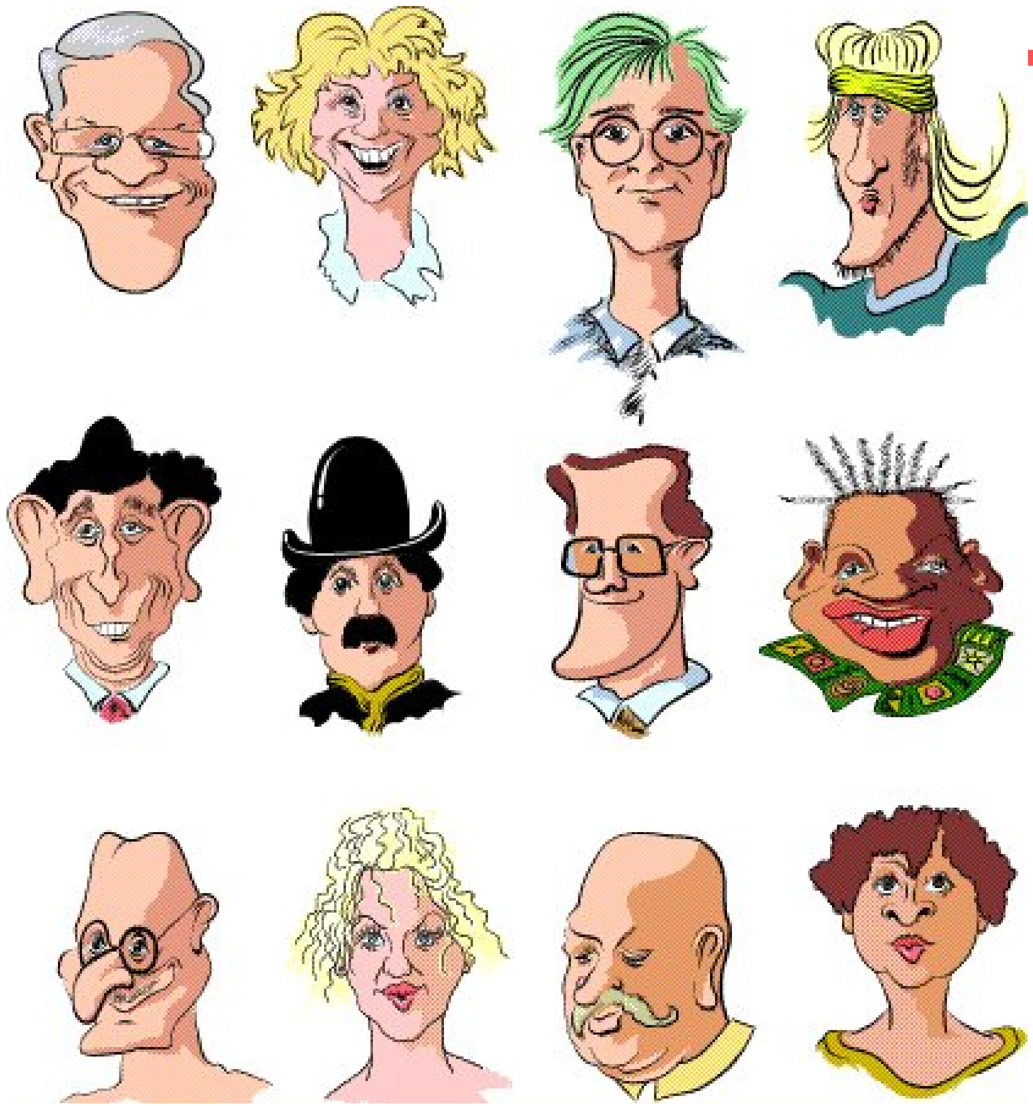

case	sex	glasses	moustache	smile	hat
1	m	y	n	y	n
2	f	n	n	y	n
3	m	y	n	n	n
4	m	n	n	n	n
5	m	n	n	y?	n
6	m	n	y	n	y
7	m	y	n	y	n
8	m	n	n	y	n
9	m	y	y	y	n
10	f	n	n	n	n
11	m	n	y	n	n
12	f	n	n	n	n

Einführung Clustern

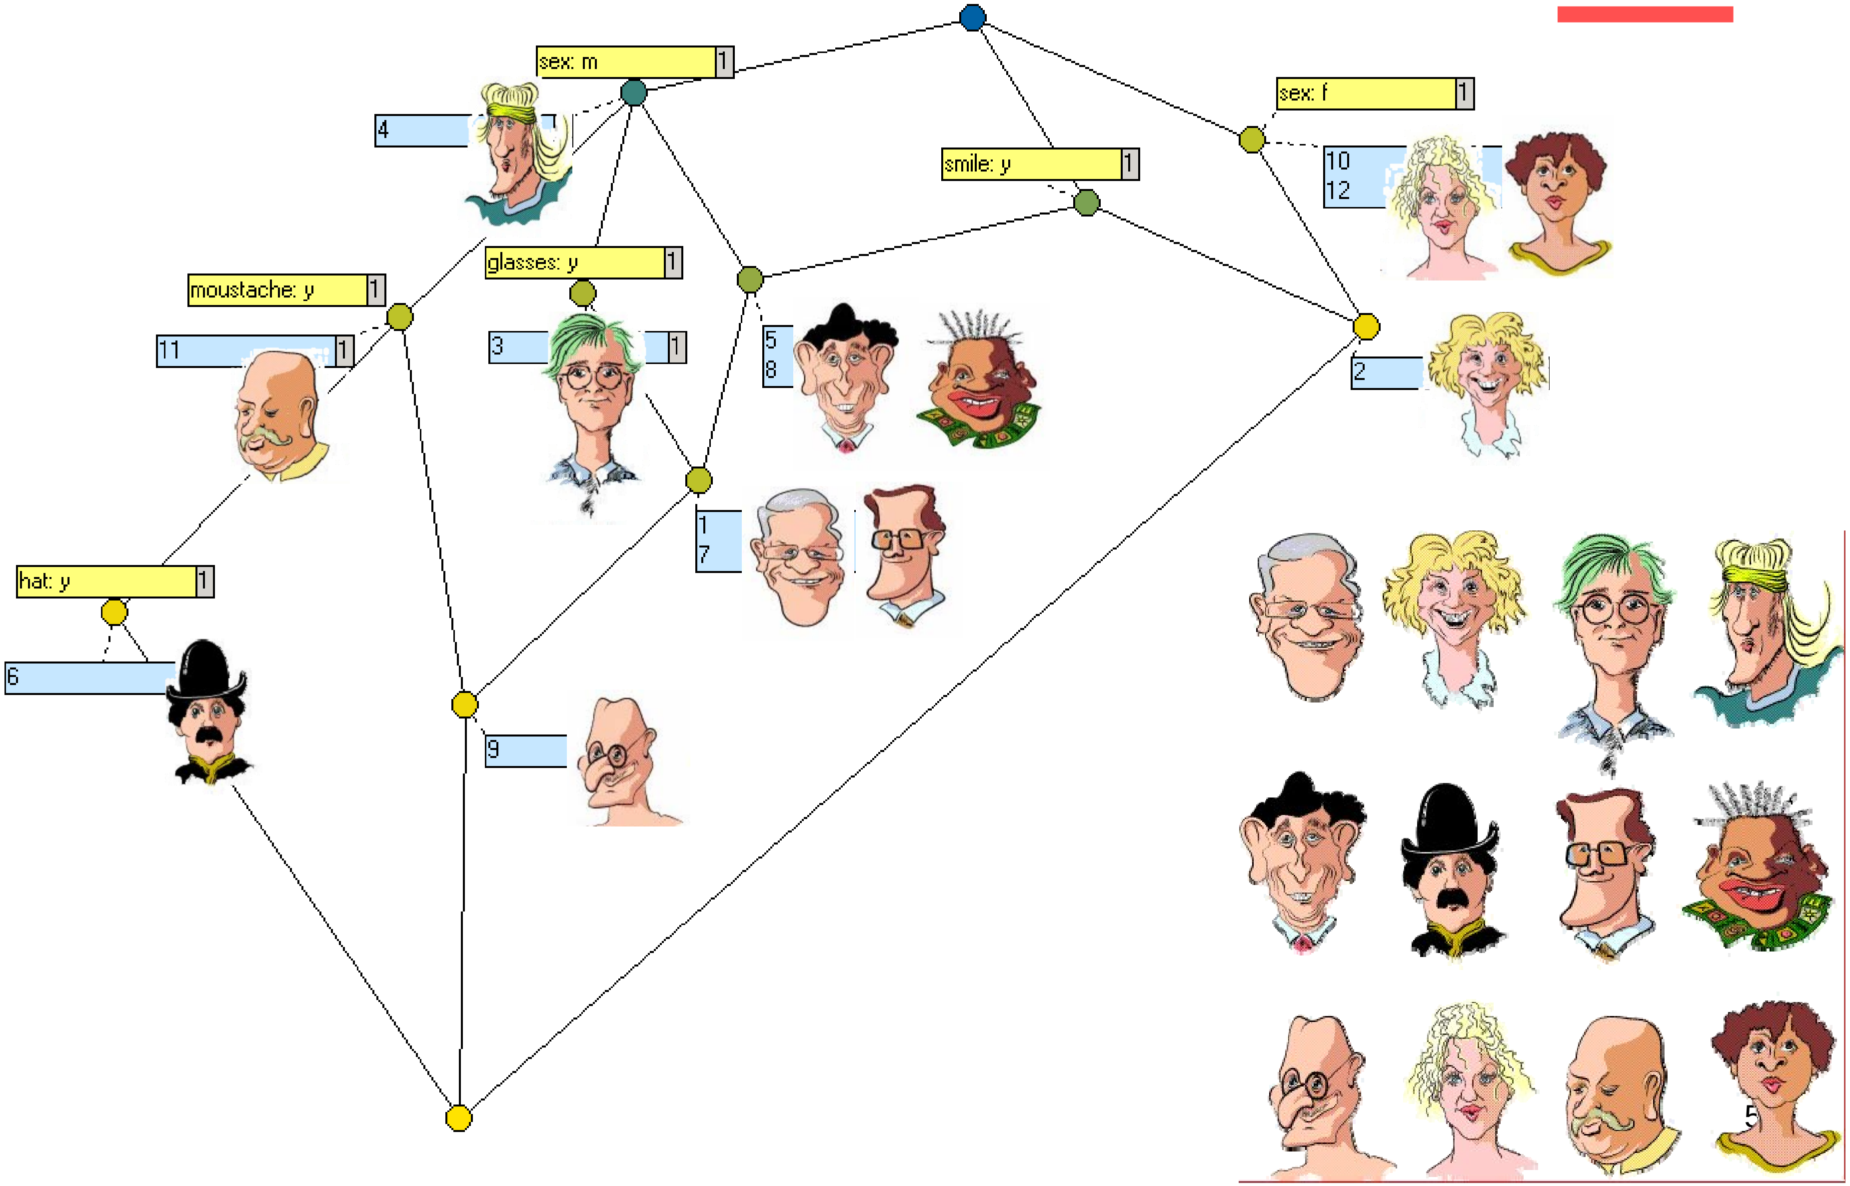

Typen von Clustering-Verfahren

- Hierarchische Verfahren
  - Parameter: Distanz- oder Ähnlichkeitsfunktion für Punkte und für Cluster
  - bestimmt eine Hierarchie von Clustern, indem die jeweils ähnlichsten Cluster verschmolzen werden
- Partitionierende Verfahren
  - Parameter: Anzahl *k* der Cluster, Distanzfunktion
  - sucht ein „flaches“ Clustering in *k* Cluster mit minimalen Kosten
- Dichtebasierte Verfahren
  - Parameter: minimale Dichte in einem Cluster, Distanzfunktion
  - erweitert Punkte um ihre Nachbarn solange Dichte groß genug
- Andere Clustering-Verfahren
  - Fuzzy Clustering
  - Soft Clustering (EM)
  - Graph-theoretische Verfahren
  - neuronale Netze

Mehr Details zu Clusterverfahren gibt es in der KDD Vorlesung.

Hierarchisches Clustern

- Bilde eine baum-basierte hierarchische Taxonomy (*Dendrogram*) aus einer Menge von Beispielen.

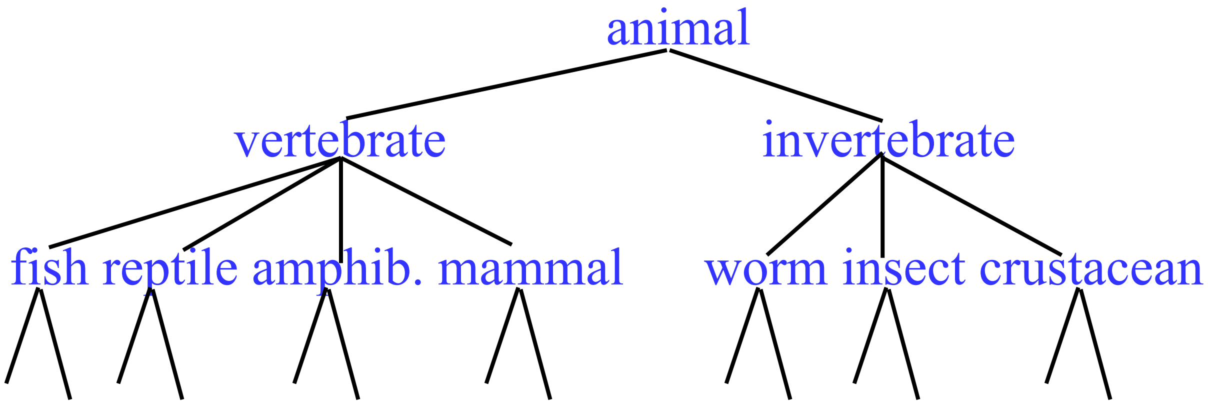

- Die rekursive Anwendung eines Standard-Cluster-Algorithmus führt auch zu hierarchischen Clustern (z.B. Bi-Sec-KMeans).

Agglomeratives vs. divisives Clustern

- *Agglomerative* (bottom-ip) Methoden beginnen mit je einem Beispiel als eigener Cluster und verbinden diese iterativ, um größere Cluster zu bilden.
- *Divisive* (*partitionierende*, *top-down*) trennen die Menge aller Beispiele in eine gegebene Anzahl von Cluster und wiederholen dies für jeden Cluster solange bis jeder Cluster nur noch ein Beispiel enthält.

Hierarchisches Agglomeratives Clustern (HAC)

- Gegeben ist eine *Ähnlichkeitsfunktion* zur Bestimmung der Ähnlichkeit von zwei Objekten.
- Beginnt mit allen Objekten in einem separatem Cluster und verbindet dann mehrmals die beiden Cluster, die am ähnlichsten sind, bis nur noch ein Cluster da ist.
- Die Historie des Zusammenlegens bildet einen binären Baum oder eine Hierarchie.

Cluster Ähnlichkeit

- Ähnlichkeitsfunktion, die die Ähnlichkeit von zwei Objekten bestimmt : $sim(x,y)$.
  – Kosinus Ähnlichkeit von Dokumentvektoren.
- Wie berechnet man die Ähnlichkeit von zwei Clustern, von denen jeder möglicherweise eine Vielzahl von Objekten enthält?
  – Single Link: Ähnlichkeit der zwei ähnlichsten Mitglieder.
  – Complete Link: Ähnlichkeit der zwei am wenigstens ähnlichen Mitglieder.
  – Average Link: Durchschnittsähnlichkeit zwischen allen Mitgliedern.

Single Link am Beispiel

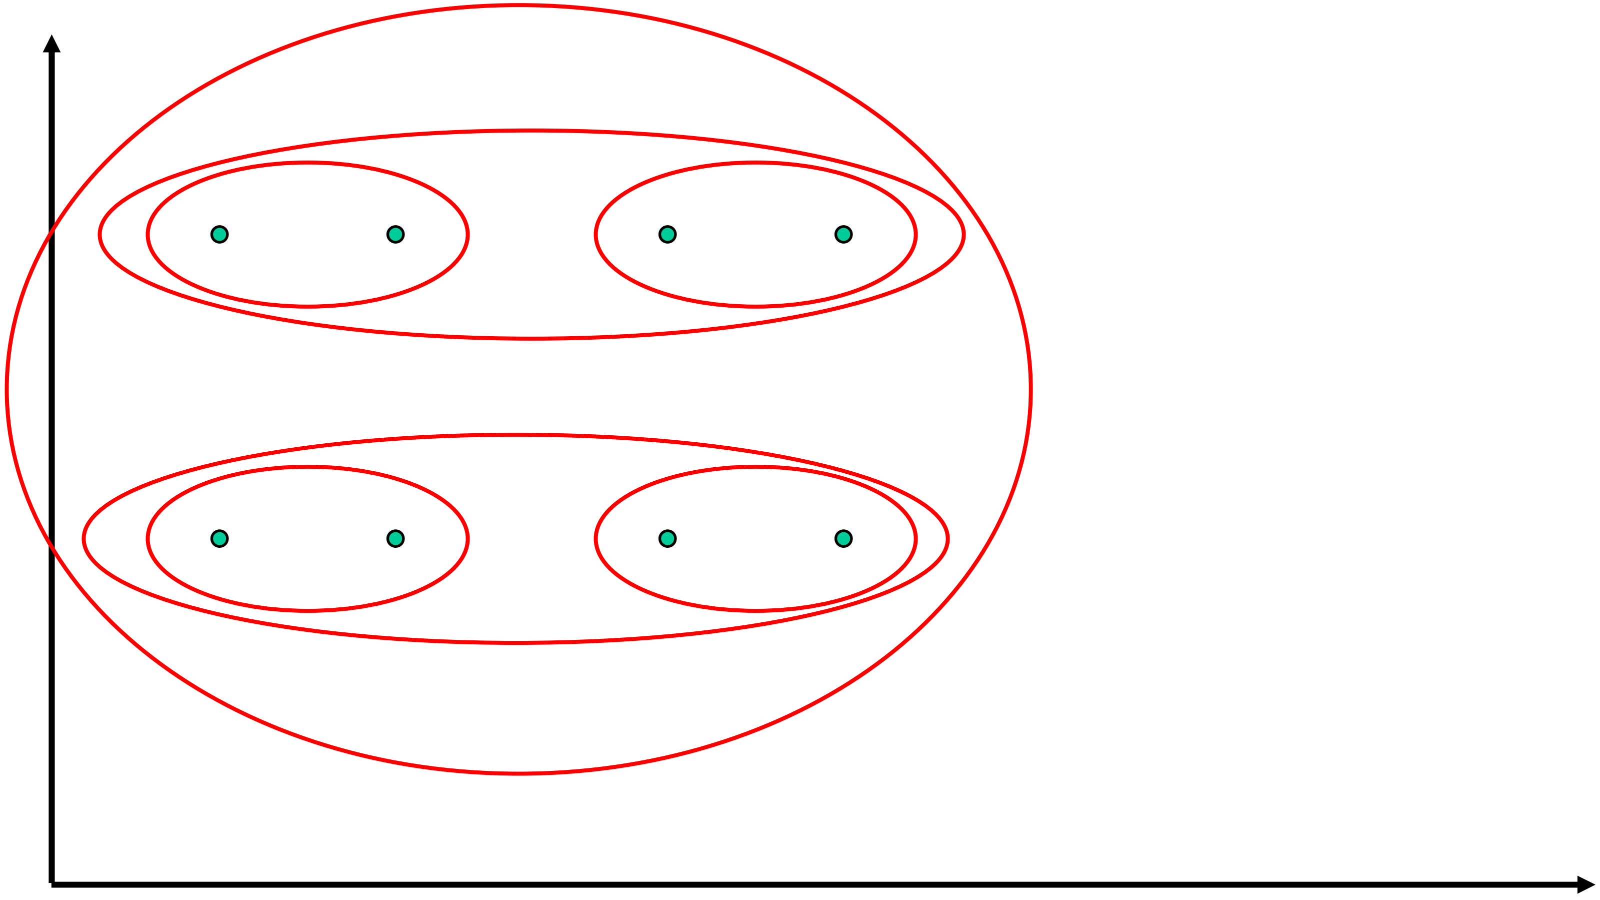

Rechnerische Komplexität

- Bei der ersten Iteration, müssen alle HAC Methoden die Ähnlichkeit aller Paare von n Objekten berechnen. Aufwand: $O(n^2)$
- Vor jedem der nachfolgenden $n-2$ Zusammenlegungsschritte, muss der Abstand zwischen dem neu erzeugten Cluster und allen anderen noch existierenden Clustern berechnet werden.
- Um bei einem Gesamtaufwand von $O(n^2)$ zu bleiben, muss die Berechnung der Ähnlichkeit mit jedem Cluster in konstanter Zeit erfolgen.

Nicht-Hierarchisches Clustern

- Typischerweise muß man bei den meisten Verfahren die Anzahl der gewünschten Cluster *k* angeben.
- Wähle willkürlich *k* Objekte als *Saat* (Ausgangspunkt) der Clusterung (einen pro Cluster).
- Bilde anfängliche Cluster, die auf dieser Saat basieren.
- Iteriere mehrfach und ordne Objekte Clustern neu zu, mit dem Ziel das Gesamtclusterergebnis zu verbessern.
- Stoppe, wenn das Clustern konvergiert oder nach einer festen Anzahl von Iterationen.

K-Means

- Gegeben: Objekte werden durch reelle-wertige Vektoren repräsentiert.
- Die Cluster basieren auf dem *Schwerpunkt* (Centroid) - dem Mittelwert von Punkten eines Cluster, *c*:

$$\vec{\mu}(c) = \frac{1}{|c|} \sum_{\vec{x} \in c} \vec{x}$$

- Die Neuzuordnung von Objekten zu Clustern basiert auf dem Abstand zu den aktuellen Cluster-Centroiden.

Abstandsmaße

- Euklidischer Abstand (L_2 Norm):

$$L_2(\vec{x}, \vec{y}) = \sum_{i=1}^{m} (x_i - y_i)^2$$

- L_1 Norm:

$$L_1(\vec{x}, \vec{y}) = \sum_{i=1}^{m} |x_i - y_i|$$

- Kosinus Ähnlichkeit (→ Abstandsmaß durch Subtraktion von 1):

$$1 - \frac{\vec{x} \bullet \vec{y}}{|\vec{x}| \cdot |\vec{y}|}$$

K Means Beispiel
(K=2)

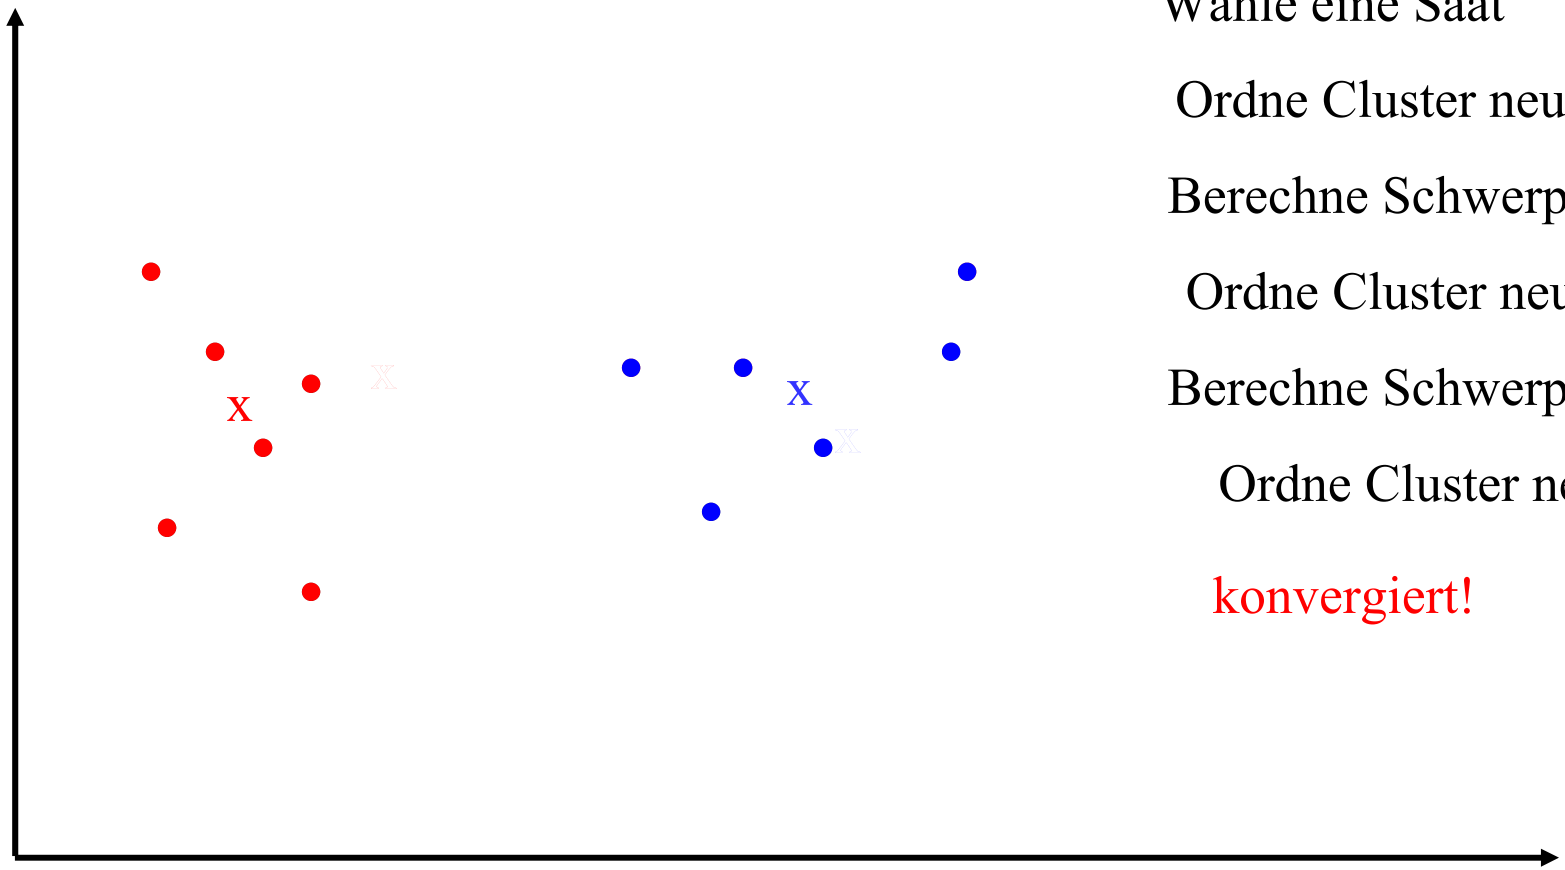

Wähle eine Saat

Ordne Cluster neu zu

Berechne Schwerpunkte

Ordne Cluster neu zu

Berechne Schwerpunkte

Ordne Cluster neu zu

konvergiert!

Zeit Komplexität

- Der Aufwand zur Berechnung des Abstandes zwischen zwei Objekten sei O(m), wobei m die Dimensionalität der Vektoren ist.
- Neuzuordnung von Clustern: O(kn) Abstands-berechnungen, oder O(knm).
- Centroidberechnung: Jeder Objektvektor wird einmal zu seinem Schwerpunkt addiert: O(nm).
- Die letzten zwei Schritte werden jeweils einmal pro Iterationen I durchgeführt: O($Iknm$).
- Linear in allen relevanten Faktoren, wobei von einer festen Anzahl von Iterationen ausgegangen wird,
- KMeans ist effizienter als HAC (O(n^2)).

Text Clustering

- HAC und K-Means wurden zum Clustern von Texten wie folgt angewendet.
- Typischer Weise nutzt man einen ***normalisierten***, TF/IDF-gewichteten Vektor und die Kosinus-Ähnlichkeit.
- Die Berechung wird für dünn besetzte Vektoren optimiert.
- Anwendungen:
  - Bei einer typischen Suchanfrage werden Dokumente des gleichen Clusters passend zu der ursprünglichen Antwortmenge zurückgeliefert, um so den Recall zu erhöhen.
  - Clustern der Suchergebnisse um besser organisierte Ergebnisse dem Anwender anbieten zu können. (z.B. http://de.vivisimo.com/).
  - Die automatische Erstellung von taxonomischen Hierarchien für eine Menge von Dokumenten mit dem Ziel das Browsing zu erleichtern. (z.B. Yahoo & DMOZ).