

Knowledge Discovery in Databases II
WS 2013/2014


Übungsblatt 4: Cluster Analysis in High-Dimensional Data – CASH

Aufgabe 4-1 CASH: Hough-Transformation

Betrachten Sie den Datensatz “cashDaten.txt”, den Sie auf der Vorlesungsseite finden.

Zur Visualisierung des Datenraums können Sie folgenden Befehl in gnuplot eingeben:

```
plot [0:10][0:10] "cashDaten.txt" title ''
```



Bestimmen Sie für diesen Datenraum den entsprechenden Parameterraum, d.h. für die im Datensatz enthaltenen Punkte jeweils die Parametrisierungsfunktion nach dem Schema:

$$f_p(\alpha_1, \dots, \alpha_{d-1}) = \sum_{i=1}^d p_i \cdot \left(\prod_{j=1}^{i-1} \sin(\alpha_j) \right) \cdot \cos(\alpha_i)$$

(Beachten Sie: $\alpha_d = 0$).

Veranschaulichen Sie die Parametrisierungsfunktionen – wo finden sich dichte Regionen?

Aufgabe 4-2 Clustering-Algorithmen und der “Curse of dimensionality”

Als Effekte des “Curse of Dimensionality” sind für das Clustering-Problem in hochdimensionalen Vektorräumen vor allem folgende Probleme relevant:

- (a) **Komplexität der Mustersuche.** Mehr Attribute bedeuten mehr Variablen für eine Optimierung. Ein vollständige Suche wird mit mehr Dimensionen immer schwieriger oder gar undurchführbar.
- (b) **Irrelevanz von Distanz-Unterschieden.** Konzepte wie “Nähe”, “Distanz” oder “Nachbarschaft” werden mit zunehmender Dimensionalität immer bedeutungsloser.
- (c) **Irrelevante Attribute.** Da immer mehr Attribute “auf verdacht” aufgesammelt werden, sind viele dieser Attribute für bestimmte Muster letztlich wahrscheinlich irrelevant. Die Relevanz ist aber unterschiedlich für unterschiedliche Teilmengen der Datenobjekte.

Obwohl dieses Problem unabhängig vom Problem der Irrelevanz von Distanz-Unterschieden ist, werden auch durch diesen Effekt volldimensionale Distanzen zwischen Objekten fragwürdig.

- (d) **Korrelierte Attribute.** Mit der steigenden Anzahl von Attributen wird ebenfalls das Auftauchen von Korrelationen zwischen Attributen immer wahrscheinlicher. Wie das Problem irrelevanter Attribute kann dieses Problem allerdings auch schon bei niedrig-dimensionalen Daten auftauchen.

Korrelationen zwischen Attributen verändern die Gestalt eines Datensatzes und darin verborgener Muster erheblich. Darüberhinaus ist es nicht nur von Interesse, verborgene Muster trotz dieser Korrelationen zu entdecken, sondern auch diese Korrelationen selbst.

Überlegen Sie für die Clustering-Algorithmen CLIQUE, SUBCLU, FIRES, DiSH, PROCLUS, PreDeCon, Cheng&Church, p-cluster, ORCLUS, 4C und CASH (soweit in der Vorlesung bereits besprochen), welche dieser Probleme jeweils behandelt werden und welche vernachlässigt oder nicht zufriedenstellend gelöst werden.

	CLIQUE	SUBCLU	PROCLUS	PreDeCon	Cheng&Church	p-cluster	ORCLUS	4C	CASH
Problem (a)									
Problem (b)									
Problem (c)									
Problem (d)									