

Algorithmische Methoden der Netzwerkanalyse

Marco Gaertler

03. Februar, 2009

1 Clustering: Algorithmen

Frage

Nach welchen Kriterien könnten Algorithmen vorgehen, um sinnvolle Clusterungen zu identifizieren, wenn das Berechnen einer optimalen Struktur bezüglich der meisten Qualitätsindizes schwer ist?

Frage

Nach welchen Kriterien könnten Algorithmen vorgehen, um sinnvolle Clusterungen zu identifizieren, wenn das Berechnen einer optimalen Struktur bezüglich der meisten Qualitätsindizes schwer ist?

Wie könnte ein *greedy* Clusteralgorithmus vorgehen?

Definition

Sei $G = (V, E, \omega)$ ein Graph und \mathcal{C}_1 eine beliebige Clustering von G . Weiter seien entweder eine globale

Kostenfunktion $c_{\text{global}}: \mathcal{A}(G) \rightarrow \mathbb{R}_0^+$ oder eine lokale

Kostenfunktion $c_{\text{local}}: 2^V \times 2^V \rightarrow \mathbb{R}_0^+$ gegeben.

Das *allgemeine Linkage* Verfahren berechnet eine Folge von Clusterungen $\mathcal{C}_2, \dots, \mathcal{C}_\ell$, wobei \mathcal{C}_{i+1} aus $\mathcal{C}_i = \{C_1, \dots, C_k\}$ wie folgt entsteht:

Definition (Fortsetzung)

global: $C_{i+1} := \underset{C' \in M}{\operatorname{argmin}} c_{\text{global}}(C')$ mit

$$M := \left\{ \{C_\mu \cup C_\nu\} \cup \left(C_i \setminus \{C_\mu, C_\nu\} \right) \mid \mu \neq \nu \right\}$$

local:

$$C_{i+1} := \underset{\{C_\mu \cup C_\nu\} \cup (C_i \setminus \{C_\mu, C_\nu\})}{\operatorname{argmin}} c_{\text{local}}(C_\mu, C_\nu)$$

Fragen:

- Was könnten globale/lokale Kosten konkret messen?
- Was unterscheidet die globalen Kosten von den lokalen?
- Welche Vor-/Nachteile haben globale/lokale Kosten?

Frage

Kann es eigentlich *sinnvolle* Algorithmen zur Clusterungen geben?

Wie kann man *sinnvoll* formalisieren?

Definition

Ein Clusteringalgorithmus ist eine Funktion $f: \mathbb{R}_0^{n \times n} \rightarrow \text{Part}(n)$.

Anschaulich: Ein Algorithmus berechnet aus den paarweisen Abständen/Ähnlichkeiten von n Elementen eine Partition.

Definition

Ein Clusteringalgorithmus ist eine Funktion $f: \mathbb{R}_0^{n \times n} \rightarrow \text{Part}(n)$.

Anschaulich: Ein Algorithmus berechnet aus den paarweisen Abständen/Ähnlichkeiten von n Elementen eine Partition.

Frage

Welche Eigenschaften sollte f nun erfüllen?

Axiomatisierung?

Axiom: Scale-Invariance

$$\forall D \in \mathbb{R}_0^{n \times n}, \forall \alpha \in \mathbb{R}^+ : f(D) = f(\alpha D)$$

Axiom: Richness

f ist surjektiv.

Axiomatisierung?

Axiom: Scale-Invariance

$$\forall D \in \mathbb{R}_0^{n \times n}, \forall \alpha \in \mathbb{R}^+ : f(D) = f(\alpha D)$$

Axiom: Richness

f ist surjektiv.

Für $D \in \mathbb{R}_0^{n \times n}$ definiere den f -Support durch die Menge

$$\left\{ D' \in \mathbb{R}_0^{n \times n} \mid \forall 1 \leq i, j \leq n : \begin{cases} D'_{ij} \leq D_{ij}, & \text{falls } i \sim_{f(D)} j \\ D'_{ij} \geq D_{ij}, & \text{falls } i \not\sim_{f(D)} j \end{cases} \right\}$$

Axiom: Consistency

$$\forall D, D' \in \mathbb{R}_0^{n \times n} : \left(D' \in f\text{-Support}(D) \implies f(D) = f(D') \right)$$