




Algorithmische Methoden zur Netzwerkanalyse

Prof. Dr. Henning Meyerhenke

Institut für Theoretische Informatik



Vorlesung 2, Wiederholung und heutiges Thema

- Knotengradverteilung:
“Wie viele Leute kenne ich?”
- k -Kerne:
“Wie gut bin ich vernetzt?”

Vorlesung 2, Wiederholung und heutiges Thema

- Knotengradverteilung:
“Wie viele Leute kenne ich?”
- k -Kerne:
“Wie gut bin ich vernetzt?”
- **Heute auch:** Clusterkoeffizienten:
“Der Freund meines Freundes ist mein Freund”
- NetworKit-Grundlagen

Eigenschaften von Netzwerken

k -Kern-Zerlegung

Struktur der k -Kern-Zerlegung

Berechnung der k -Kern-Zerlegung

Cluster-Koeffizienten

Grundlagen

Lokaler CK

Lemma

- Sei $G = (V, E)$ ein Graph,
- (V_0, \dots, V_k) seine Kern-Zerlegung und
- $G_i := (V_i, E_i) := G[V_i]$ sein i -Kern.

- Sei $n_i := |V_i \setminus V_{i+1}|$ die Anzahl der **Knoten** in der i -Schale.
- Sei $m_i := |E_i \setminus E_{i+1}|$ die Anzahl der **Kanten**, die zu einem Knoten mit Kernzahl i und zu einem Knoten mit Kernzahl $j \geq i$ inzident sind.
- Per Definition: $V_{k+1} := \emptyset, E_{k+1} := \emptyset$.

Lemma

- Sei $n_i := |V_i \setminus V_{i+1}|$ die Anzahl der **Knoten** in der i -Schale.
- Sei $m_i := |E_i \setminus E_{i+1}|$ die Anzahl der **Kanten**, die zu einem Knoten mit Kernzahl i und zu einem Knoten mit Kernzahl $j \geq i$ inzident sind.
- Per Definition: $V_{k+1} := \emptyset, E_{k+1} := \emptyset$.

Dann lässt sich die Größe der i -Schale beschränken durch:

$$0 \leq n_i \leq |V| \quad (1)$$

$$\left. \begin{array}{l} \lceil \frac{i \cdot n_i}{2} \rceil \\ \binom{n_i}{2} + n_i(i - n_i + 1) \end{array} \right\} \begin{array}{l} , \text{ if } n_i > i \\ , \text{ if } n_i \leq i \end{array} \leq m_i \leq \begin{cases} i \cdot n_i & , \text{ if } i < k \\ i \cdot n_i - \frac{i(i+1)}{2} & , \text{ if } i = k \end{cases} \quad (2)$$

Beweis: Siehe Tafel!

Algorithm 1 Berechnung der Kernzerlegung eines Graphen

```
1: function COREDECOMPOSITION( $G = (V, E)$ )
2:   Output: Kernzahl  $k$  des Kerns von  $G$  und Feld  $core$  mit Kernzahl jedes
   Knotens
3:   Speichere die Knotengrade für alle Knoten in  $resdegree$ 
4:    $i \leftarrow 0$ 
5:   while  $V \neq \emptyset$  do
6:      $i \leftarrow i + 1$ 
7:     for each  $v \in V$  mit  $resdegree[v] < i$  do
8:        $core[v] \leftarrow i - 1$ 
9:       for each  $u \in N(v)$  do
10:         $resdegree[u] \leftarrow resdegree[u] - 1$ 
11:      end for
12:      Entferne  $v$  aus  $G$ 
13:    end for
14:  end while
15:  return  $(i - 1, core)$ 
16: end function
```

Beispiel

[Baur et al., 2008]




Fig. 1. A k -core decomposition with 5 core shells.

Theorem

Sei $G = (V, E)$ mit $|E| = m$ zusammenhängend und ungewichtet.

Der Algorithmus COREDECOMPOSITION kann in

Laufzeit $\mathcal{O}(m)$

implementiert werden.

Beweis: Siehe Tafel und Skript!

Parallele Berechnung der Kernzerlegung

- Bräuchten eine parallele PQ
- Wird durch parallele Suche nach Knoten mit passendem Residualgraph ersetzt
- Diese Knoten und deren Nachbarschaft werden parallel abgearbeitet
- Siehe Implementierung in NetworKit

Literaturhinweise

N.S. Dasari, D. Ranjan, and M. Zubair: Park: An efficient algorithm for k-core decomposition on multicore processors. In Proc. Intl. Conference on Big Data 2014, pages 9–16.

- Die k -Kernstruktur gibt ein Maß an, das robuster ist als der Knotengrad zur Bestimmung der Verbindung eines Knotens zum Rest des Graphen
- Lemmas beleuchten Größe der i -Schalen
- Algorithmische Definition führt zu Algorithmus, der die Struktur berechnet

Eigenschaften von Netzwerken

k -Kern-Zerlegung

Struktur der k -Kern-Zerlegung

Berechnung der k -Kern-Zerlegung

Cluster-Koeffizienten

Grundlagen

Lokaler CK

Fragestellung

- Ihnen gibt jemand einen Graphen und behauptet, es sei ein soziales Netzwerk.
- Sie möchten die Behauptung überprüfen.
- Welche Analyse-Möglichkeiten fallen Ihnen dazu bereits ein?

Fragestellung

- Ihnen gibt jemand einen Graphen und behauptet, es sei ein soziales Netzwerk.
- Sie möchten die Behauptung überprüfen.
- Welche Analyse-Möglichkeiten fallen Ihnen dazu bereits ein?

Hinweis: Erwarten Sie relativ viele oder relativ wenige Dreiecke im Netzwerk?

Fragestellung

- Ihnen gibt jemand einen Graphen und behauptet, es sei ein soziales Netzwerk.
- Sie möchten die Behauptung überprüfen.
- Welche Analyse-Möglichkeiten fallen Ihnen dazu bereits ein?

Hinweis: Erwarten Sie relativ viele oder relativ wenige Dreiecke im Netzwerk?

Aufgabe: Formalisierung dieses Konzeptes

Cluster-Koeffizient

Beschreibung

- Der **Cluster-Koeffizient** misst die **durchschnittliche Wahrscheinlichkeit**, dass zwei **Nachbarn desselben Knotens zueinander benachbart** sind.
- ⇒ Maß für die Dichte von Dreiecken im Netzwerk

- Der **Cluster-Koeffizient** misst die **durchschnittliche Wahrscheinlichkeit**, dass zwei **Nachbarn desselben Knotens zueinander benachbart** sind.
- ⇒ Maß für die Dichte von Dreiecken im Netzwerk
- Gleiche Netzwerktypen haben häufig ähnliche Koeffizienten
 - Unterschiedliche Netzwerktypen haben häufig unterschiedliche Koeffizienten
 - **Aber:** Ausnahmen nicht so selten

- Der **Cluster-Koeffizient** misst die **durchschnittliche Wahrscheinlichkeit**, dass zwei **Nachbarn desselben Knotens zueinander benachbart** sind.
- ⇒ Maß für die Dichte von Dreiecken im Netzwerk
- Gleiche Netzwerktypen haben häufig ähnliche Koeffizienten
- Unterschiedliche Netzwerktypen haben häufig unterschiedliche Koeffizienten
- **Aber:** Ausnahmen nicht so selten
- Beispiel in [Newman, S. 237]: Werte oft zwischen 0.1 und 0.6
- ⇒ Typische Wkt. dafür, dass gemeinsame Nachbarn zueinander benachbart sind, liegt zwischen 10% und 60%.

Definition

Der **globale Cluster-Koeffizient** C ist definiert als

$$C := \frac{3 \cdot \text{Zahl der (geschlossenen) Dreiecke}}{\text{Zahl der zusammenhängenden Dreiergruppen}}$$

Definition

Der **globale Cluster-Koeffizient** C ist definiert als

$$C := \frac{3 \cdot \text{Zahl der (geschlossenen) Dreiecke}}{\text{Zahl der zusammenhängenden Dreiergruppen}}$$

Alternative Definition:

Definition

Der **globale Cluster-Koeffizient** C ist definiert als

$$C := \frac{6 \cdot \text{Zahl der (geschlossenen) Dreiecke}}{\text{Zahl der Wege der Länge 2}}$$

- Siehe Tafel

Beispiel

- Siehe Tafel

(1, 2, 3)	(4, 2, 1)
(1, 2, 4)	(4, 2, 3)
(1, 2, 5)	(4, 2, 5)
<hr/>	
(2, 3, 4)	(4, 3, 2)
(2, 3, 5)	(4, 3, 5)
(2, 3, 6)	(4, 3, 6)
(2, 4, 3)	(4, 6, 3)
(2, 4, 6)	<hr/>
(2, 5, 3)	(5, 2, 1)
<hr/>	(5, 2, 3)
(3, 2, 1)	(5, 2, 4)
(3, 2, 4)	(5, 3, 2)
(3, 2, 5)	(5, 3, 4)
(3, 4, 2)	(5, 3, 6)
(3, 4, 6)	<hr/>
(3, 5, 2)	(6, 3, 2)
(3, 5, 4)	(6, 3, 4)
(3, 6, 4)	(6, 3, 5)
	(6, 4, 2)
	<hr/>
	(6, 4, 3)

⇒ 34 Wege der
Länge 2,
3 Dreiecke
⇒ $C = 18/34$

- Durchschnittliche Wahrscheinlichkeit, dass zwei Personen mit einem gemeinsamen Freund auch befreundet sind.
- C liegt im Intervall $[0, 1]$.
- Ist der Freund meines Freundes mein Freund?
- Nicht unbedingt, aber viel wahrscheinlicher als jemand Zufälliges!
- Bei $C = 1$: Alle zusammenhängenden Dreiergruppen bilden eine Clique.
- **Frage:** Wie hoch ist C in einem Baum?

- Soziale Netzwerke: C oft im zweistelligen Prozent-Bereich.
- Bei technischen Netzwerken ist C häufig niedriger.
- Bsp.: AS-Netzwerk hat nur ca. $C = 0.01$.

- Soziale Netzwerke: C oft im zweistelligen Prozent-Bereich.
- Bei technischen Netzwerken ist C häufig niedriger.
- Bsp.: AS-Netzwerk hat nur ca. $C = 0.01$.

Intuitive Signifikanz der Werte:

- Annahme: Alle Knoten haben etwa Grad c
 - Annahme: Meine Freunde wählen ihre Freunde zufällig
- Wkt., dass ein solcher Freund auch mein Freund ist, ist etwa c/n

- Cluster-Koeffizient gibt **durchschnittliche Dichte von Dreiecken** an (global bzw. lokal)
- Maß zur Bestimmung von Netzwerktypen mit bestimmten Eigenschaften
- Auch für gerichtete Graphen möglich bei geeigneter Abwandlung der Definition

- Cluster-Koeffizient gibt **durchschnittliche Dichte von Dreiecken** an (global bzw. lokal)
- Maß zur Bestimmung von Netzwerktypen mit bestimmten Eigenschaften
- Auch für gerichtete Graphen möglich bei geeigneter Abwandlung der Definition

- Laufzeit der exakten Berechnung des globalen CK mit **naivem Algorithmus abhängig von Knotengradverteilung**: $O(nd_{max}^2)$
- Bester bekannter exakter Algorithmus: $O(MM(n))$ mit $MM(N) \approx n^{2,373}$
- Approximationsalgorithmus: **Deutlich bessere Laufzeit**