

Fortgeschrittene Netzwerk- und Graph-Algorithmen

Dr. Hanjo Täubig

Lehrstuhl für Effiziente Algorithmen
(Prof. Dr. Ernst W. Mayr)
Institut für Informatik
Technische Universität München

Wintersemester 2009/10



Übersicht

- 1 Lokale Dichte
 - Kohäsive Gruppen
 - Cliques

Kohäsive Gruppen

Eigenschaften:

- **Gegenseitigkeit**
Gruppenmitglieder wählen sich gegenseitig in die Gruppe und sind im graphtheoretischen Sinn benachbart
- **Kompaktheit / Erreichbarkeit:**
Gruppenmitglieder sind gegenseitig gut erreichbar (wenn auch nicht unbedingt adjazent), insbesondere
 - auf kurzen Wegen
 - auf vielen verschiedenen Wegen
- **Dichte:**
Gruppenmitglieder haben eine große Nachbarschaft innerhalb der Gruppe
- **Separation:**
Gruppenmitglieder haben mit größerer Wahrscheinlichkeit Kontakt zu einem anderen Mitglied der Gruppe als zu einem Nicht-Gruppenmitglied

Lokale Dichte

- Eine Gruppeneigenschaft heißt *lokal*, wenn sie bestimmt werden kann, indem man nur den von der Gruppe induzierten Teilgraphen betrachtet.
- ⇒ Separation ist *nicht lokal*, weil hier auch die Verbindungen zu den anderen Knoten betrachtet werden
- Viele Definitionen von kohäsiven Gruppen verlangen außer einer Eigenschaft Π auch *Maximalität* (im Sinne von Nichterweiterbarkeit), d.h. die Gruppe darf nicht in einer anderen größeren Gruppe enthalten sein.
- Maximalität verletzt die Lokalitätsbedingung
- ⇒ Betrachten diese Eigenschaften ohne Maximalitätsbedingung
- Lokalität reflektiert wichtige Eigenschaft von Gruppen:
 - Invarianz unter Veränderung des Netzwerks außerhalb der Gruppe
 - Innere Robustheit und Stabilität ist eine wichtige Gruppeneigenschaft

Cliquen

Definition

Sei $G = (V, E)$ ein ungerichteter Graph. Ein Knotenteilmenge $U \subseteq V$ heißt **Clique** genau dann, wenn der von U in G induzierte Teilgraph $G[U]$ ein vollständiger Graph ist.

Eine Clique U in G ist eine **maximale Clique**, falls es keine Clique U' mit $U \subset U'$ in G gibt.

Cliques – ideale kohäsive Gruppen

Cliques sind ideale kohäsive Gruppen:
(Sei U eine Clique der Kardinalität k .)

- Cliques haben größtmögliche Dichte

$$\delta(G[U]) = \bar{d}(G[U]) = \Delta(G[U]) = k - 1$$

- Cliques besitzen größtmögliche Kompaktheit

$$\text{diam}(G[U]) = 1$$

- Cliques sind bestmöglich verbunden
 U ist $(k - 1)$ -fach knotenzusammenhängend und
 $(k - 1)$ -fach kantenzusammenhängend

Satz von Turán

Satz (Turán, 1941)

Sei $G = (V, E)$ ein ungerichteter Graph mit $n = |V|$ und $m = |E|$.
Falls $m > \frac{n^2}{2} \cdot \frac{k-2}{k-1}$, dann existiert eine Clique der Größe k in G .

Spezialfall:

Satz (Mantel, 1907)

Die maximale Anzahl von Kanten in einem dreiecksfreien Graphen ist $\left\lfloor \frac{n^2}{4} \right\rfloor$.

Da die meisten (z.B. soziale) Netzwerke eher dünn sind (also $o(n^2)$ Kanten haben), müssen sie nicht unbedingt von vornherein Cliques einer bestimmten Größe > 2 enthalten.

Maximale Cliques

- Graphen enthalten immer maximale Cliques.
- Meistens sind es sogar viele.
- Sie können sich überlappen (ohne identisch zu sein).

Satz (Moon & Moser, 1965)

Jeder ungerichtete Graph G mit n Knoten hat höchstens $3^{\lceil \frac{n}{3} \rceil}$ maximale Cliques.

Cliquen-Struktur

- Cliques sind abgeschlossen unter Exklusion, d.h. wenn U eine Clique in G ist und v ein Knoten aus U , dann ist $U \setminus \{v\}$ auch eine Clique.

Oder anders gesagt:

Die Cliqueneigenschaft ist eine *hereditäre* Grapheigenschaft, denn sie vererbt sich auf induzierte Teilgraphen.

- Cliques sind geschachtelt, d.h. jede Clique der Größe n enthält eine Clique der Größe $n - 1$ (sogar n davon).

(Das folgt hier sofort aus dem Abschluss unter Exklusion. Für andere Eigenschaften, die nicht unter Exklusion abgeschlossen sind, muss man das aber extra beweisen.)

Generalisierte Cliques

Sei $G = (V, E)$ ein ungerichteter Graph, U eine Teilmenge der Knoten und $k > 0$ eine natürliche Zahl.

Generalisierte (distanz-basierte) Cliques:

- U heißt **k -Clique** g.d.w. $\forall u, v \in U : d_G(u, v) \leq k$.
- U heißt **k -Club** g.d.w. $\text{diam}(G[U]) \leq k$.
- U heißt **k -Clan** g.d.w. U ist eine maximale k -Clique und U ist ein k -Club.
- k -Cliques sind nicht lokal definiert (die Distanzen können sich aus Pfaden ergeben, die über Knoten außerhalb von U führen).
- Obwohl k -Clubs und k -Clans lokal definiert sind (abgesehen von der Maximalitätsbedingung), sind sie nur von geringerem Interesse. Distanz-basierte Cliques sind i.A. nicht abgeschlossen unter Exklusion und nicht geschachtelt.

Grundfunktionen

In $\mathcal{O}(m + n)$ können folgende Funktionen berechnet werden:

- Bestimme, ob eine gegebene Knotenteilmenge $U \subseteq V$ eine Clique in G ist.
Bestimme für jede Kante in G , ob beide Endknoten in U sind.
Zähle die Fälle und vergleiche mit $|U| \cdot (|U| - 1)/2$.

- Bestimme, ob eine gegebene Clique $U \subseteq V$ maximal ist in G .
Teste, ob es einen Knoten in $V \setminus U$ gibt, der adjazent zu allen Knoten in U ist.

Maximale Clique

Bestimme die lexikographisch kleinste maximale Clique U , die eine gegebene Clique $U' \subseteq V$ enthält.

- Annahme: V ist eine geordnete Menge
 - Seien $U, U' \in V$. Def.: $U \leq U' \Leftrightarrow$ der kleinste Knoten der nicht in $U \cap U'$ ist, ist in U .
 - Starte mit $U = U'$
 - Iteriere über alle $v \in V \setminus U$ in aufsteigender Reihenfolge und teste, ob $U \subseteq N(v)$.
 - Falls ja, dann füge v zu U hinzu.
 - Am Ende ist U eine maximale Clique, die U' enthält.
- \Rightarrow ebenfalls $\mathcal{O}(m+n)$

Cliques maximaler Kardinalität

Maximum-Clique: Clique der größtmöglichen Kardinalität in einem gegebenen Graphen

Primitiver Algorithmus: erschöpfende Suche
Zähle alle Kandidatensets $U \subseteq V$ auf
und bestimme, ob U eine Clique ist.
Gib die größte gefundene Clique aus.
 \Rightarrow Laufzeit $\mathcal{O}(n^2 \cdot 2^n)$

Clique-Problem

Entscheidungsproblem:

Problem

Problem: **Clique**

Eingabe: Graph G , Parameter $k \in \mathbb{N}$

Frage: Existiert eine Clique der Kardinalität $\geq k$ in G ?

Härte des Clique-Problems

Sei $\omega(G)$ die Größe der Maximum-Clique(n) in G .

Wenn wir einen Algorithmus hätten, der **Clique** in Zeit $T(n)$ entscheidet, dann könnten wir $\omega(G)$ in Zeit $\mathcal{O}(T(n) \cdot \log n)$ mit binärer Suche berechnen.

Andererseits ergibt sich aus jedem Algorithmus zur Berechnung von $\omega(G)$ in Zeit $T(n)$ ein Algorithmus, der **Clique** in $T(n)$ entscheidet. Ein polynomieller Algorithmus für das eine Problem würde als einen polynomiellen Algorithmus für das jeweils andere Problem implizieren.

Aber:

Satz

***Clique** ist \mathcal{NP} -complete.*

Beweis: Reduktion von **Satisfiability** (Erfüllbarkeit)

Versteckte Cliques

Folgerung

Falls $\mathcal{P} \neq \mathcal{NP}$ gilt, gibt es keinen Polynomialzeit-Algorithmus, der eine Clique der Größe k in einem Graphen findet, der garantiert eine solche Clique der Größe k enthält.

Bemerkung: die Schwierigkeit, eine versteckte Clique zu finden, hängt nicht von der Größe der Clique ab. Auch Cliques der Größe $(1 - \varepsilon) \cdot n$ können nicht in Polynomialzeit gefunden werden.

Maximum-Clique: besserer exponentieller Algorithmen

Satz

Eine Clique maximaler Kardinalität kann in Zeit $\mathcal{O}^(1.3803^n)$ berechnet werden.*

(\mathcal{O}^* ignoriert polynomielle Faktoren)

Maximum-Clique: besserer exponentieller Algorithmus

Beweis.

- Sei v ein Knoten mit minimalem Grad $\deg_G(v) = \delta(G)$
 - Falls $\delta(G) \geq n - 3$, dann
 - fehlen in G nur einfache Pfade und Kreise im Vergleich zum vollständigen Graphen K_n
- ⇒ Maximum Clique kann in $\mathcal{O}(m + n)$ berechnet werden:
- In einem Pfad P kann man die Größe einer maximalen unabhängigen Menge (independent set) berechnen als $\lfloor |V(P)|/2 \rfloor$.
 - In einem Kreis C ist die Größe $\lfloor |V(C)|/2 \rfloor$.
 - Da die Pfade und Kreise paarweise disjunkt sind, kann man die einzelnen Werte einfach addieren.

Maximum-Clique: besserer exponentieller Algorithmus

Beweis.

- Ansonsten sei v ein Knoten mit Grad $\deg_G(v) \leq n - 4$
- Jede Maximum-Clique ist entweder
 - $\{v\}$ vereinigt mit einer Maximum-Clique von $G[N(v)]$ oder
 - eine Maximum-Clique von $G[V \setminus \{v\}]$.

⇒ Rekursive Berechnung mit worst-case-Zeit

$$T(n) \leq T(n-4) + T(n-1) + c \cdot (m+n)$$

⇒ $T(n) \in \mathcal{O}^*(\beta^n)$ mit $\beta \approx 1.3803$, wobei β die größte reelle Nullstelle des charakteristischen Polynoms $\beta^4 - \beta^3 - 1$ ist



Approximation von Maximum-Cliques

Approximation der größten Clique mit Faktor $n/2$ ist einfach (wähle die Endknoten einer Kante, falls es eine gibt).

Satz

Es gibt einen Algorithmus, der bei Eingabe eines Graphen G mit n Knoten in polynomieller Zeit eine Clique ausgibt, deren Größe maximal um einen Faktor $\mathcal{O}\left(\frac{n}{(\log n)^2}\right)$ von der Maximum-Cliquengröße $\omega(G)$ abweicht.

Satz

Falls nicht $\mathcal{NP} = \mathcal{ZPP}$ gilt, dann existiert kein Polynomialzeitalgorithmus, der bei Eingabe eines Graphen G mit n Knoten eine Clique ausgibt, deren Größe maximal um einen Faktor $n^{1-\epsilon}$ von der Maximum-Cliquengröße $\omega(G)$ abweicht (für jedes $\epsilon > 0$).

Suche nach Cliques fester Größe

- In einigen Fällen reicht es, nach Cliques fester Größe zu suchen
⇒ Cliquengröße wird nicht als Teil der Eingabe betrachtet

- Vollständige Suche: $\mathcal{O}(k^2 \cdot n^k) = \mathcal{O}(n^k)$,
wenn Cliquengröße k fest ist

Bessere Komplexität für Dreiecke

- $A(G)$: Adjazenzmatrix von Graph G
 - $B(G) = A(G)^2 = A(G) \cdot A(G)$: Einträge b_{ij} sind die Wege der Länge 2 zwischen den Knoten v_i und v_j
- ⇒ läßt sich durch schnellere Matrixmultiplikation ausrechnen, z.B. in $\mathcal{O}(n^{2.376})$ (Coppersmith / Winograd, 1990)
- Existiert ein Eintrag $b_{ij} \geq 1$ mit $i \neq j$, dann gibt es einen Knoten $u \in V$, der zu v_i und zu v_j adjazent ist.
 - Wenn nun auch eine Kante $\{v_i, v_j\}$ existiert, dann enthält der Graph ein Dreieck $\{v_i, v_j, u\}$
- ⇒ Checke für alle echt positiven Werte b_{ij} , ob es eine Kante $\{v_i, v_j\}$ gibt
- ⇒ Zeit-Komplexität: $\mathcal{O}(n^\alpha)$ mit $\alpha < 2.376$

Cliques fester Größe $k \geq 3$

Sei $\alpha(r, s, t)$ so definiert, dass man die Multiplikation einer $n^r \times n^s$ -Matrix mit einer $n^s \times n^t$ -Matrix in Zeit $\mathcal{O}(n^{\alpha(r,s,t)})$ berechnen kann.

Satz

Für jedes $k \geq 3$ existiert ein Algorithmus, der eine Clique der Größe k in einem Graphen mit n Knoten finden kann (falls eine solche existiert) und der in Zeit $\mathcal{O}(n^{\beta(k)})$ läuft, wobei $\beta(k) = \alpha(\lfloor k/3 \rfloor, \lceil (k-1)/3 \rceil, \lceil k/3 \rceil)$.

Cliques fester Größe $k \geq 3$

Beweis.

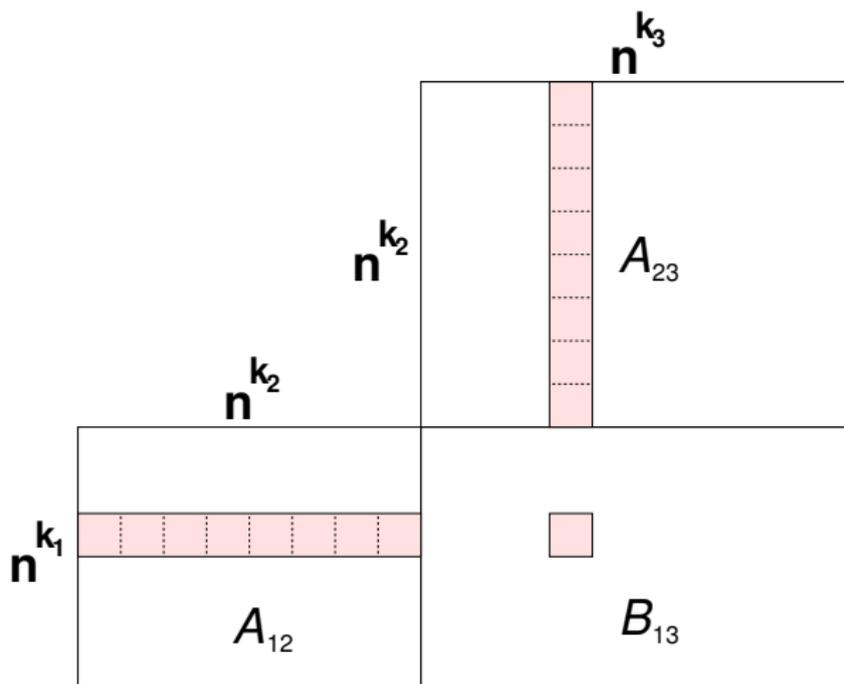
- Seien $k_1 = \lfloor k/3 \rfloor$, $k_2 = \lceil (k-1)/3 \rceil$ und $k_3 = \lceil k/3 \rceil$
- Es gilt $k = k_1 + k_2 + k_3$.
- Konstruiere tripartiten Hilfsgraph \tilde{G}
 - $\tilde{V} = \tilde{V}_1 \cup \tilde{V}_2 \cup \tilde{V}_3$, wobei V_i aus allen Cliques der Größe k_i in G besteht
 - Knoten $U \in \tilde{V}_i$ und $U' \in \tilde{V}_j$ sind adjazent in \tilde{G} g.d.w. $i \neq j$ und $U \cup U'$ eine Clique der Größe $k_i + k_j$ in G ist.
- Teste \tilde{G} auf Dreiecke

Cliques fester Größe $k \geq 3$

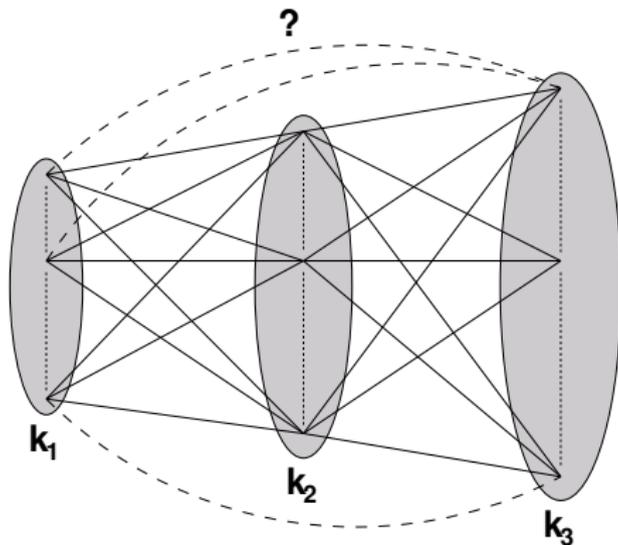
Beweis.

- Dreieck $\{U_1, U_2, U_3\}$ impliziert eine Clique der Größe k in G
- geht mit schneller Matrixmultiplikation, aber hier muss eine $n^{k_1} \times n^{k_2}$ -Matrix (Kanten zwischen \tilde{V}_1 und \tilde{V}_2) mit einer $n^{k_2} \times n^{k_3}$ -Matrix (Kanten zwischen \tilde{V}_2 und \tilde{V}_3) multipliziert werden, und zwar in Zeit $\mathcal{O}(n^{\beta(k)})$
- Berechnung der drei Matrizen A_{12} , A_{23} und A_{13} in $\mathcal{O}(n^{\max\{k_1+k_2, k_1+k_3, k_2+k_3\}}) = \mathcal{O}(n^{\lceil \frac{2k}{3} \rceil})$
(wird dominiert durch die Zeit $\mathcal{O}(n^{\beta(k)})$ für die Multiplikation der rechteckigen Matrizen, also $B_{13} = A_{12} \cdot A_{23}$)



Cliques fester Größe $k \geq 3$ 

B_{13} wird dann mit A_{13} verknüpft

Cliques fester Größe $k \geq 3$ 

Cliques fester Größe: Beispielkomplexitäten

Cliquengröße	Vollständige Suche	Matrixmultiplikation
3	$\mathcal{O}(n^3)$	$\mathcal{O}(n^{2.376})$
4	$\mathcal{O}(n^4)$	$\mathcal{O}(n^{3.376})$
5	$\mathcal{O}(n^5)$	$\mathcal{O}(n^{4.220})$
6	$\mathcal{O}(n^6)$	$\mathcal{O}(n^{4.751})$
7	$\mathcal{O}(n^7)$	$\mathcal{O}(n^{5.751})$
8	$\mathcal{O}(n^8)$	$\mathcal{O}(n^{6.595})$

Cliques fester Größe: Mitgliedszahlen

Satz

Für jedes $k \geq 3$ existiert ein Algorithmus, der in Zeit $\mathcal{O}(n^{\beta(k)})$ läuft und der für jeden Knoten zählt, an wieviel Cliques der Größe k er beteiligt ist (in einem Graphen mit n Knoten), wobei $\beta(k) = \alpha(\lfloor k/3 \rfloor, \lceil (k-1)/3 \rceil, \lceil k/3 \rceil)$.

Cliques fester Größe: Mitgliedszahlen

Beweis.

- Für $k = 3$ (Dreiecke) kann man nicht nur feststellen, *ob* zwei Knoten v_i und v_j zu einem Dreieck gehören, sondern auch *zu wievielen*.
- Wenn Kante $\{v_i, v_j\}$ in G existiert, dann ist diese Anzahl gleich dem Eintrag b_{ij} in der quadrierten Adjazenzmatrix $B(G) = A(G) \cdot A(G)$.
- Anwendung im allgemeinen Fall von \tilde{G} :
für jeden Knoten $v \in V$ sei $C_k(v)$ die Anzahl verschiedener Cliques der Größe k , in denen v enthalten ist.
- Entsprechend sei $\tilde{C}_3(U)$ die Anzahl der Dreiecke in \tilde{G} , zu denen Knoten U gehört.
(U ist eine Clique der Größe kleiner als k)

Cliques fester Größe: Mitgliedszahlen

Beweis.

- Cliques der Größe k können viele verschiedene Repräsentationen in \tilde{G} haben.
- Diese Anzahl ist die Anzahl der Partitionierungen von einer Menge der Kardinalität k in drei Mengen der Kardinalitäten k_1 , k_2 und k_3 , also der Multinomialkoeffizient $\binom{k}{k_1, k_2, k_3}$.
- o.B.d.A. sei k_1 der kleinste der drei Parameter.
Sei $\mathcal{U}(v)$ die Menge aller Cliques U der Größe k_1 in G , so dass $v \in U$. Dann gilt:

$$\sum_{U \in \mathcal{U}(v)} \tilde{C}_3(U) = \binom{k-1}{(k_1-1), k_2, k_3} \cdot C_k(v)$$

- Berechne linke Seite in $\mathcal{O}(n^{\beta(k)})$ (berechne Matrizen; suche Einträge für alle U , die v enthalten); Berechne $C_k(v)$