

Fortgeschrittene Netzwerk- und Graph-Algorithmen

Prof. Dr. Hanjo Täubig

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

Wintersemester 2010/11



PageRank

Lawrence Page, Sergey Brin, Rajeev Motwani & Terry Winograd (1998):
PageRank

- wesentlicher Bestandteil der Suchmaschine von Google
- Idee: Bewertung der Wichtigkeit einer Webseite bezüglich der **topologischen Eigenschaften** (seiner Position im Web), **unabhängig vom Inhalt** (mal abgesehen von den Links)
- ist eine Feedback-Zentralität: Wert einer Webseite hängt von der Anzahl und der Zentralität der Webseiten ab, die darauf zeigen
- Gewicht einer Seite wird gleichmäßig an die verlinkten Seiten weitergegeben

$$c_{PR}(p) = \frac{1-d}{n} + d \sum_{q \in N^-(p)} \frac{c_{PR}(q)}{d^+(q)}$$

d : Dämpfungsfaktor

$N^-(p)$: Knoten mit einer Kante zu p

PageRank

- definiere Transitionsmatrix P :

$$p_{ij} = \begin{cases} \frac{1}{d^+(j)}, & \text{falls } (j, i) \in E \\ 0, & \text{sonst} \end{cases}$$

- oder anders: $p_{ij} = \frac{1}{d^+(j)} a_{ji}$ bzw. $P = (D^+ A)^T$,
wobei D^+ die Diagonalmatrix ist, die im i -ten Diagonaleintrag den Kehrwert des Ausgangsgrads $d^+(i)$ von Knoten i enthält (falls > 0)

- Matrixform:

$$\mathbf{c}_{\text{PR}} = dP\mathbf{c}_{\text{PR}} + \frac{1-d}{n}\mathbf{1}_n$$

- Lösung meist durch Power (oder Jacobi) Iteration:

$$\mathbf{c}_{\text{PR}}^k = dP\mathbf{c}_{\text{PR}}^{k-1} + \frac{1-d}{n}\mathbf{1}_n$$

PageRank

Folgender Satz garantiert eindeutige Lösung und Konvergenz für $d < 1$:

Satz

Falls $0 \leq d < 1$ dann hat die Gleichung

$$\mathbf{c}_{PR} = dP\mathbf{c}_{PR} + \frac{1-d}{n}\mathbf{1}_n$$

eine eindeutige Lösung $\mathbf{c}_{PR}^* = \frac{1-d}{n} (I_n - dP)^{-1} \mathbf{1}_n$

und die Lösungen des dynamischen Systems

$$\mathbf{c}_{PR}^k = dP\mathbf{c}_{PR}^{k-1} + \frac{1-d}{n}\mathbf{1}_n$$

erfüllen

$$\lim_{k \rightarrow \infty} \mathbf{c}_{PR}^k = \mathbf{c}_{PR}^*$$

für jeden Startvektor \mathbf{c}_{PR}^0 .

PageRank

Etwas anderer Ansatz:

$$\mathbf{c}_{\text{PR}}^k = dP\mathbf{c}_{\text{PR}}^{k-1} + \frac{\|\mathbf{c}^{k-1}\| - \|dP\mathbf{c}_{\text{PR}}^{k-1}\|}{n} \mathbf{1}_n$$

Die Lösungen dieses System konvergieren gegen $\frac{\mathbf{c}_{\text{PR}}^*}{\|\mathbf{c}_{\text{PR}}^*\|}$, die normalisierte Lösung des vorherigen Ansatzes.

Hubs & Authorities

Jon Kleinberg, 1997:

- HITS: Hyperlink-Induced Topic Search
- “A good **hub** is a page that points to many good authorities.”
- “A good **authority** is a page that is pointed to by many good hubs.”
- im Gegensatz zu PageRank berücksichtigt HITS auch den Inhalt von Webseiten
- 2 Phasen:
 - ▶ 1. Phase hängt von der Suchanfrage ab
 - ▶ 2. Phase beschäftigt sich nur mit der Linkstruktur des entsprechenden Netzwerks

Hubs & Authorities

- Suchanfrage σ
- 1. Phase berechnet $V_\sigma \in V$ mit
 - ▶ V_σ ist klein im Vergleich zu V ,
 - ▶ V_σ enthält viele Seiten, die für die Suchanfrage σ relevant sind,
 - ▶ V_σ enthält viele wichtige Authorities

Hubs & Authorities

Algorithmus 5 : Hubs & Authorities, 1. Phase

Output : $V_\sigma =$ Menge relevanter Seiten

Benutze eine textbasierte Suchmaschine für Suchanfrage σ ;

Sei W_σ die Liste von Ergebnissen;

Wähle $t \in \mathbb{N}$;

Sei $W_\sigma^t \subset W_\sigma$ die Menge der t Seiten, die am höchsten bewertet wurden;

$V_\sigma := W_\sigma^t$;

forall the $i \in W_\sigma^t$ **do**

$V_\sigma := V_\sigma \cup N^+(i)$;

if $|N^-(i)| \leq r$ (r ist eine benutzerspezifizierte Schranke) **then**

$V_\sigma := V_\sigma \cup N^-(i)$;

else

 Wähle $N_r^-(i) \subseteq N^-(i)$ so, dass $|N_r^-(i)| = r$;

$V_\sigma := V_\sigma \cup N_r^-(i)$;

return V_σ ;

Hubs & Authorities

- 2. Phase berechnet die Hub/Authority-Werte der Seiten im induzierten Graphen $G[V_\sigma]$ aus der gegenseitigen Abhängigkeit zwischen Hubs und Authorities:

$\mathbf{c}_{\text{HA-H}} = A_\sigma \mathbf{c}_{\text{HA-A}}$ unter der Annahme, dass $\mathbf{c}_{\text{HA-A}}$ bekannt ist

$\mathbf{c}_{\text{HA-A}} = A_\sigma^T \mathbf{c}_{\text{HA-H}}$ unter der Annahme, dass $\mathbf{c}_{\text{HA-H}}$ bekannt ist

A_σ : Adjazenzmatrix von $G[V_\sigma]$

- Da weder $\mathbf{c}_{\text{HA-A}}$ noch $\mathbf{c}_{\text{HA-H}}$ bekannt sind, schlägt Kleinberg eine iterative Bestimmung mit Normalisierung vor.

Hubs & Authorities

Algorithmus 6 : Hubs & Authorities Iteration

Output : Approximationen für $\mathbf{c}_{\text{HA-H}}$ and $\mathbf{c}_{\text{HA-A}}$

$$\mathbf{c}_{\text{HA-A}}^0 := \mathbf{1}_n;$$

for $k = 1 \dots$ **do**

$$\mathbf{c}_{\text{HA-H}}^k := A_{\sigma} \mathbf{c}_{\text{HA-A}}^{k-1};$$

$$\mathbf{c}_{\text{HA-A}}^k := A_{\sigma}^T \mathbf{c}_{\text{HA-H}}^k;$$

$$\mathbf{c}_{\text{HA-H}}^k := \frac{\mathbf{c}_{\text{HA-H}}^k}{\|\mathbf{c}_{\text{HA-H}}^k\|};$$

$$\mathbf{c}_{\text{HA-A}}^k := \frac{\mathbf{c}_{\text{HA-A}}^k}{\|\mathbf{c}_{\text{HA-A}}^k\|};$$

Hubs & Authorities

Satz

Sei A_σ die Adjazenzmatrix von $G[V_\sigma]$.

Dann sind die Grenzwerte

$$\lim_{k \rightarrow \infty} \mathbf{c}_{HA-A}^k = \mathbf{c}_{HA-A}$$

und

$$\lim_{k \rightarrow \infty} \mathbf{c}_{HA-H}^k = \mathbf{c}_{HA-H}$$

wobei \mathbf{c}_{HA-A} (\mathbf{c}_{HA-H}) der erste Eigenvektor von $A_\sigma^T A_\sigma$ ($A_\sigma A_\sigma^T$) ist.

Hubs & Authorities

⇒ iterative Methode ist nichts anderes als die Lösung der Eigenvektor-Gleichungen

$$\lambda \mathbf{c}_{\text{HA-A}} = (A_{\sigma}^T A_{\sigma}) \mathbf{c}_{\text{HA-A}}$$

$$\lambda \mathbf{c}_{\text{HA-H}} = (A_{\sigma} A_{\sigma}^T) \mathbf{c}_{\text{HA-H}}$$

für den größten Eigenwert per Power Iteration

$\mathbf{c}_{\text{HA-A}}$: enthält dann die Authority-Werte

$\mathbf{c}_{\text{HA-H}}$: enthält dann die Hub-Werte

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
- Einige 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

Cliques

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.

Eine Clique U in G ist eine **Maximum-Clique**, falls es keine Clique U' mit $|U| < |U'|$ 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 $\lfloor \frac{n^2}{4} \rfloor$.

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 mindestens eine maximale Clique, meistens 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.

Die Ordnung auf den Cliques sei wie folgt definiert ($U, U' \subseteq V$):

$U < U' \Leftrightarrow$ Der kleinste Knoten aus $U \cup U'$, der nicht in $U \cap U'$ ist, ist in U .

- Annahme: V ist eine geordnete Menge
- Starte mit $U = U'$
- Iteriere über alle $v \in V \setminus U$ in aufsteigender Reihenfolge
 - ▶ 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.

⇒ 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 U der Kardinalität $|U| \geq k$ 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} -vollständig.

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