

Skript zur Vorlesung
Knowledge Discovery in Databases II
im Sommersemester 2008

Kapitel 8: Link Mining

Skript © 2007 Matthias Schubert

<http://www.dbs.ifi.lmu.de/Lehre/KDD>

419

Kapitelübersicht

8.1 Graphstrukturierte Datenmengen

Graphdatenbanken und ihre Anwendungen

8.2 Frequent Subgraph Mining

FSG, GSpan

8.3 Graph Analysis

Betweenness Centrality, Page-Rank, Hits

420

8.1. Graphdatenbanken und Anwendungen

Bisher: Objekte sind iid (independent and identical distributed)

⇒ Bedeutung der Objekte hängt nur von ihren Objektwerten ab.

⇒ Es gibt keine gegenseitige Beeinflussung und keine Beziehungen.

Jetzt: Link-Mining

Daten sind durch Beziehungen untereinander verbunden.

Bsp: Wichtigkeit eines Papers wird an Referenzierungen gemessen.

Ein Paper wird als wichtig betrachtet, wenn es in vielen anderen erwähnt wird. Der Inhalt wird dabei nicht betrachtet.

⇒ Objekte beeinflussen sich gegenseitig

⇒ Modellierung der Daten als großer Graph

Objekte sind Knoten und Beziehungen sind Kanten

421

Anwendungen

Vergleich zu Kapitel 7:

Datenbank aus Graph-Objekten: Nicht zusammenhängender Graph, bei dem jede Komponente genau einem Objekt entspricht.

Anwendungen:

- Soziale Netzwerke: MySpace, Telefonnetzwerke, E-Mail Traffic, Co-Citation Graph,...
- Protein Interaktionsnetzwerke, phänotypische Netzwerke..
- Straßennetzwerke: Knotenpunkte, relevante Verbindungen,..
- Kriminalitätsnetzwerke
- Computer Netzwerke
- WWW: Linkstrukturen, Webringe, Ranking von Internetseiten..
- Relationale Datenbestände: Internet Movie Database,...

422

8.2 Frequent Subgraph Mining

Idee: Finde alle häufigen Subgraphen in Netzwerken.

Anwendungen:

- Auftreten von häufigen Subgraphen kann als topologischer Deskriptor dienen.
- Finden typischer Subnetze (Cliquen) in sozialen Netzwerken
- Graph-Kompression: Substituieren häufiger Subgraphen durch neue Knoten => Graph wird kleiner.
- Ableiten von Regeln über Verbindungen von Personen

Achtung: Viele Lösungen gehen vom Szenario von Kapitel 7 aus.

(Datenbank aus graphstrukturierten Objekten)

Anwendung auf Netzwerken ist aber direkt möglich.

423

Lösungsansätze

- *Frequent Subgraph Mining ist ähnlich zum Itemset Mining*
 - Ausnützen von Monotonie für die Kandidatenbildung
=> k Itemset I nur frequent, wenn alle $k-1$ Itemsets in I auch frequent
analog: Subgraph G mit k Knoten kann nur frequent sein, wenn alle Subgraphen von G mit $k-1$ Knoten auch frequent sind
 - Generierung von Kandidaten durch Kombination 2er existierender Graphen.
- *Direktes Vergrößern der Graphen um jeweils einen Knoten*
 - Finde alle Graphen mit k Knoten und erweitere diese um einen weiteren Knoten => Kandidaten für $k+1$ elementige Graphen

424

Grundproblem für Frequent Subgraph Mining

Test auf Gleichheit 2er Subgraphen (Subgraph-Isomorphie !!):

⇒ Entscheidung, ob Kandidat in einem Datenbankgraphen enthalten ist, ist bereits Subgraph-Isomorphie-Test.

⇒ Es ist wichtig möglichst viele DB-Subgraphen auszuschließen bevor wirklich auf Subgraph-Isomorphie getestet wird.

⇒ Bestimmen des korrekten Supports

Mehrere Gruppen von isomorphen Subgraphen werden getrennt betrachtet

⇒ Support jeder Gruppe für sich zu niedrig,
aber alle zusammen können frequent sein.

⇒ Vermeidung von doppelten Kandidaten-Subgraphen

Es gibt exponentiell viele isomorphe Subgraphen.

⇒ generiere alle Graphen und streiche alle, die zu einem bereits vorhandenen Subgraphen isomorph sind.

⇒ generiere nur 1 Subgraphen für jede Isomorphie-Klasse

425

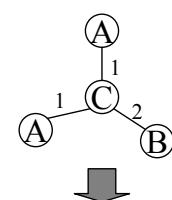
Lösungen Frequent Subgraph Mining

FSG [Kuramochi, Karypis 2001]

- Geht von Menge von gelabelten, ungerichteten Graphen aus.
- **Idee:** Erweiterung des Apriori-Algorithmus zum Itemset Mining auf Graphen.
- Darstellung der Graphen als Adjazenz-Listen
- Isomorphe Graphen entsprechen Permutationen der Adjazenz-Listen

⇒ Canonical Labelling

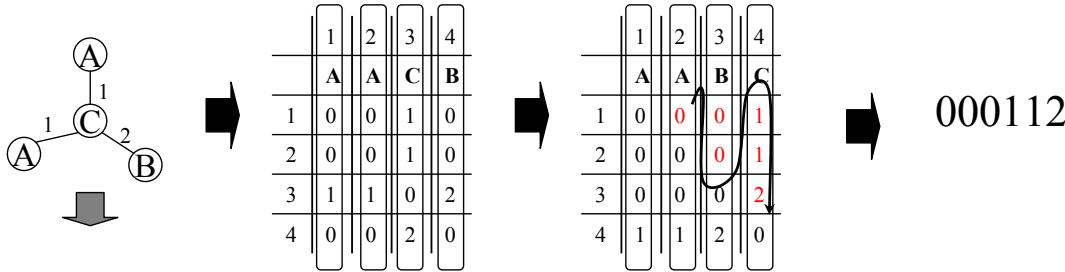
Finde eine eindeutige kanonische Form für jede Isomorphie-Klasse.



	1	2	3	4
	A	A	C	B
1	0	0	1	0
2	0	0	1	0
3	1	1	0	2
4	0	0	2	0

426

Canonical Labeling



- Sortieren der Spalten nach Grad der Knoten
 - bilden aller Permutationen
 - Auslesen der oberen Dreiecksmatrix
 - Auswahl der lexikografisch kleinsten Zeichenkette
- ⇒ eindeutige Zeichenkette repräsentiert jetzt Menge von isomorphen Graphen
- Verbesserung durch Gruppieren der Listen nach Knotenlabeln
- ⇒ verlangt nur noch Permutationen innerhalb jeder Gruppe.
- ⇒ weniger Permutationen müssen getestet werden

427

FSG Algorithmus(1)

```

Vector<Graphmenge> fsg(Graphmenge D, double δ)
    Graphmenge F1 = Menge aller häufigen Subgraphen mit einer Kante
    Graphmenge F2 = Menge aller häufigen Subgraphen mit zwei Kanten
    int k=3
    Vector<Graphmenge> frequentSubgraphs;
    frequentSubgraphs.add(F1)
    frequentSubgraphs.add(F2)
    while(frequentSubgraphs.getLastElement() != {})
        Graphmenge Ck= fsg-gen(frequentSubgraphs.getLastElement());
        foreach Graph c ∈ Ck
            int anzahl_c_in_D =0;
            foreach Graph d ∈ D
                if(d.includes(c))
                    anzahl_c_in_D++;
            if(anzahl_c_in_D < δ*|D|)
                ck.remove(c);
        frequentSubgraphs.add(Ck);
    return frequentSubgraphs;
}

```

428

FSG Algorithmus(2)

Kandidatengenerierung:

```
Graphmenge fsg-gen(Fk)
    Graphmenge Ck+1={};
    foreach Graph f1k ∈ Fk
        foreach Graph f2k ∈ Fk
            if(f1k.canonicalLabel <= f2k.canonicalLabel)
                foreach Edge e ∈ f1k
                    Graph f1k-1=f1k.remove(e);
                    if(f1k-1.isconnected && f2k.includes(f1k-1))
                        Graphmenge Tk+1 = Alle durch Join von f1k und f2k entstehende Graphen
                        foreach Graph tk+1 ∈ Tk+1
                            boolean all_tk_frequent = true;
                            foreach Edge ed ∈ tk+1
                                Graph tk = tk+1.remove(ed);
                                if(tk.isConnected && tk ∉ FK)
                                    all_tk_frequent = false;
                                    break;
                                if(all_tk_frequent)
                                    Ck+1.add(tk+1);
    return Ck+1
```

429

Komplexität von FSG

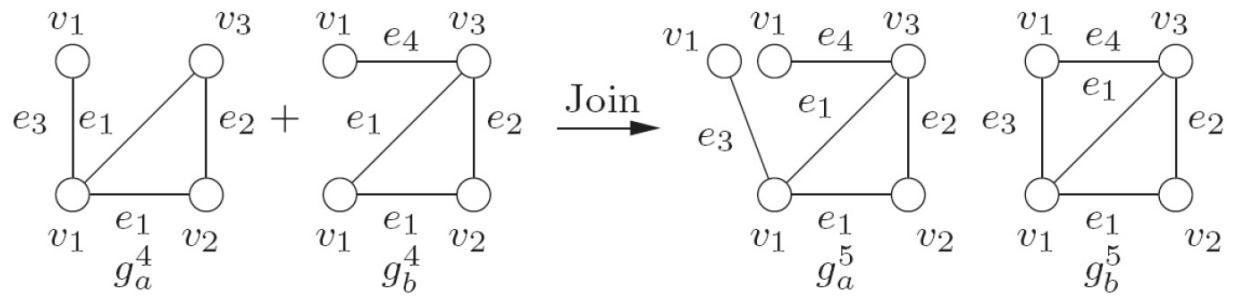
Im Code enthaltene komplexe Passagen:

1. Subgraph-Isomorphie-Test (g.includes(s))
 - notwendig beim Datenbank-Scan im Hauptalgorithmus
 - notwendig bei der Kandidatengenerierung:
Test auf gemeinsame $k-1$ Subgraph
2. Join zweier Graphen auf Basis eines **k-1** Subgraphen
 - ⇒ es gibt mehrere mögliche Ergebnisse
 - ⇒ alle müssen als Kandidaten in Betracht gezogen werden

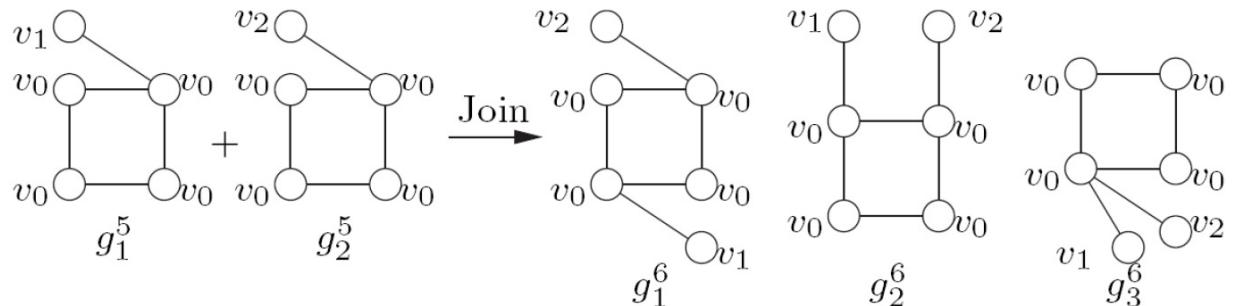
Fazit: Algorithmus ist sehr teuer !

430

Mögliche Kandidaten (1)

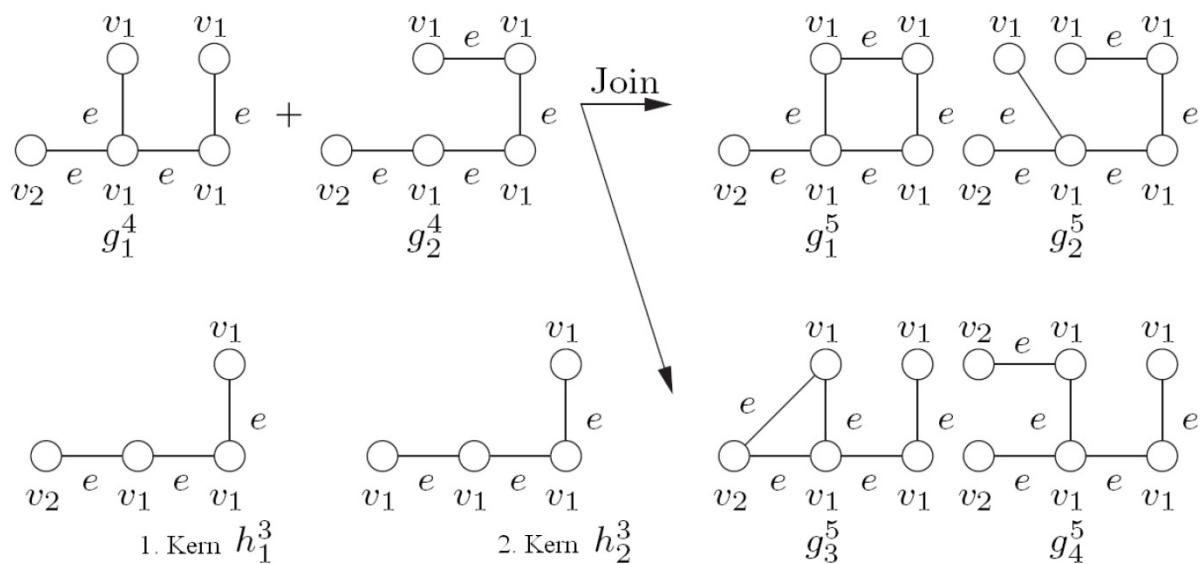


1. Gleiche Knoten-Markierung der den Kern erweiternden Knoten



431

Mögliche Kandidaten(2)



432

GSpan

Ideen:

- Erweitere häufige Sugraphen mit k Knoten direkt um 1 Kante.
- Annotation von Graphen durch Tiefensuchbaum (DFS-Code)
- Einschränkung der Kandidatengenerierung durch „right-most-only growth“

Ziel:

- Vermeide das Generieren von isomorphen Kandidaten
- Vermeide möglichst viele Isomorphismie-Tests

Verwendete Konzepte:

- DFS-Lexikographische Ordnung
- minimaler DFS-Code (kanonische Annotation eines Graphen)

433

Pattern Growth

Naiver Pattern Growth Ansatz:

S :Menge der frequent Graphs;
g :frequent Subgraph,
DB: Graphdatenbank
MinSup: minimaler Support des SubGraphen

```
S:={}
GrowPatterns(g,DB, S)

Function GrowPatterns(g,DB,S)
    if g ∈ S then return;
    else S.insert(g)
    EdgeSet E = findAdjacentEdges(DB,g MinSup); // finden aller Kanten in DB die g erweitern können
    for each frequent e ∈ E DO //es werden nur Kanten betrachtet die öfter als MinSup auftreten
        g' = extend(g,e)
        GrowPatterns(g',DB,S)
    end for
end function
```

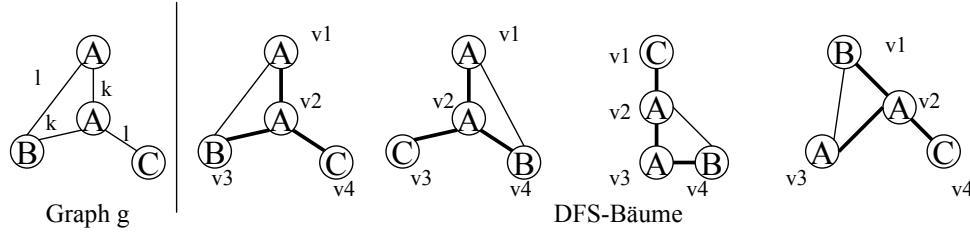
Bemerkung:

- Finden der Erweiterung sehr teuer und Isomorphie-Test für $g \in S$
- Klassen von isomorphen Graphen sollten in `findAdjacentEdges` nur 1 mal untersucht werden

434

DFS Codes

Einführen eines kanonischen Labelings zur Erkennung isomorphen Graphen
 Beschreibe Graphe durch Kantenreihenfolge in einem Tiefensuchbaum
(Depth First Search Baum)



Unterscheide **Vorwärtskanten**: Erweitern Graph um neuen Knoten

Rückwärtskanten: Verbinden bereits vorkommende Kanten

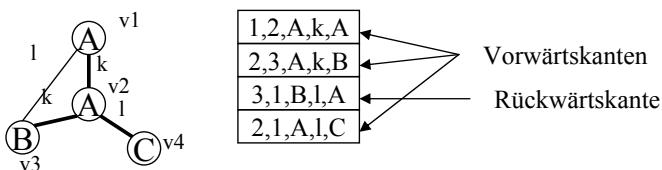
Ein DFS-Tree impliziert Reihenfolge der Kanten in Graph G (DFS-Code)

- Reihenfolge entspricht Tiefensuch-Reihenfolge (**v1,v2,..**)
- Rückwärtskanten werden eingefügt, nachdem Startknoten erreicht wurde
- Reihenfolge der Rückwärtskanten nach Besuchsreihenfolge der Zielknoten

435

DFS-Lexikographical Order

- Graph kann durch Menge seiner DFS-Trees beschrieben werden
- DFS-Tree ist eindeutig durch Kantensequenz DFS-Code gegeben
- Darstellung einer Kante: durch $(i, j, l_i, l_{(i,j)}, l_j) \rightarrow (0, 1, A, u, B)$
- Beispiel: DFS-Code



DFS-Lexicographical-Order: Vergleich mehrerer DFS-Codes

- Lexikografischer Vergleich der Kantensequenz
- Vergleich der Kanten: Startindex, Zielindex, Startlabel, Katenlabel, Ziellabel.

Durch Ordnung kann man jetzt kanonischen DFS-Code bestimmen:

Kleinster DFS-Code (Min DFS-Code) von G bezüglich DFS-Lexicographical Order beschreibt Graph G eindeutig.

=> Haben 2 Graphen G, G' gleiche Min-DFS-Codes $\Leftrightarrow G$ ist isomorph zu G'

436

Right-Most-Only Extension

Idee: Vermeide mehrfache Untersuchung monotoner Kandidaten

=> Bilde Kandidaten nach speziellen Regeln

Right-Most-Only Extension erlaub nur Erweiterungen entlang des rechten Pfades im DFS-Baum der Min-DFS-Code impliziert.

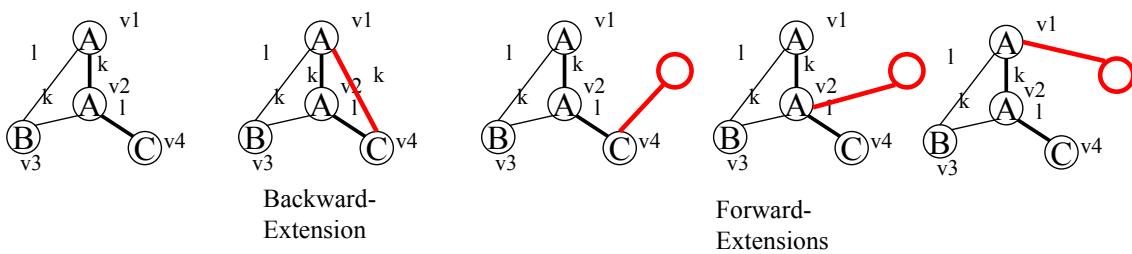
DFS-Tree:

- *Backward-Extension*

Verbinde Knoten auf dem rechten Pfad mit Rückwärtskante

- *Forward Extension*

Erweitere Graph um einen neuen Knoten. Verbindende Kante beginnt auf dem rechten Pfad.



437

GSpan

Pattern Growth Algorithmus, der nur right-most-only Extensions, des minimalen DFS-Tree erlaubt.

GSpan

S : Menge der frequent Graphs;

s : a DFS Code

min_dfs(s): Minimale DFS-Code von S.

DB: Graphdatenbank

MinSup: minimaler Support des SubGraphen

S := {}
GSpan(s, DB, S)

```
Function GrowPatterns(g, DB, S)
    if s ≠ min_dfs(s) then return;
    else S.insert(s)
    C := {}
    EdgeSet E = findRightMostExtensions(DB, s, MinSup); // finden aller gültigen Erweiterungen minimaler DFS-Trees
    C = extend(s, E);
    C.sortInLexDFSOrder;
    for each frequent s ∈ C DO
        G Span(s, DB, S)
    end for
end function
```

438

Frequent Subgraph Mining

- Finden häufiger Subgraphen ist ähnlich zum Itemset Mining
Aber:
 - Menge aller isomorphen Graphen ist größer als Menge aller Permutationen über Strings => Isomorphie schwieriger als Itemset- Vergleich.
 - Finden kanonischer Labels ist deutlich aufwendiger
 - Menge der möglichen Erweiterung eines Graphen ist auch deutlicher größer als Erweiterung von Itemsets => Kandidatengenerierung sehr teuer
- FSG: Apriori-basierter Ansatz mit paarweiser Kandidatengenerierung
- GSpan: Pattern-Growth Ansatz, der momentan als am schnellsten berichtet wird.

439

8.3. Graph Analysis

Ziel: Selektieren und Ranken besonders relevanter und interessanter Knoten/Subgraphen in großen Netzwerken.

Aufgaben:

- Ranking der Knoten nach Einfluss
- Suche nach Schlüsselknoten
- Suche nach Verbindungsgraph zwischen 2 oder mehreren Knoten
- Finden von stark verbundenen Subgraphen
- Link Prediction: Wird in naher Zukunft Kontakt zwischen 2 noch nicht verbundenen Knoten entstehen.

440

Zentralität eines Knotens im Netzwerk

Betweenness Centrality

Definition: Die Anzahl der kürzesten Pfade, die einen Knoten v im Graphen G enthalten, bezeichnet man als „Betweenness Centrality“.

Formal: σ_{st} Anzahl der kürzesten Pfade von s nach t .

$\sigma_{st}(v)$ Anzahl kürzeste Pfade von s nach t , die v enthalten.

$$C_B(v) = \sum_{s \neq v \neq t \in V} \frac{\sigma_{st}(v)}{\sigma_{st}}$$

Interpretation: Je höher die Betweenness Centrality desto wichtiger der Knoten innerhalb des Graphen.

441

Zentralität eines Knotens im Netzwerk

Beispiel: Betrachte Knoten als Router

Bei Ausfall des Routers mit der höchsten Betweenness Centrality, fallen am meisten direkte Kommunikationsverbindungen aus.

Berechnung: Verwende Algorithmus von Floyd-Warshall um alle kürzesten Pfade zu bestimmen.

=> Abzählen der Beteiligung jedes Knotens an den kürzesten Pfaden.

Komplexität: $O(n^3)$

Schnellere Berechnung möglich durch Aggregation von

Teilergebnissen: Für m Kanten und n Knoten

$O(nm)$ ohne Kantengewichte

$O(nm + n^2 \log n)$ mit Kantengewichten

442

Anwendungen im Web Mining

PageRank: (S.Brin/B. Page 1996)

- wichtige Komponente im Ranking moderner Suchmaschinen.
(in Kombination mit Ankertexten, Abstand, Worthäufigkeit)
- Web als stark verbundener, gerichteter Graph $G(V,E)$.
(Betrachtet gesamten Graph aus bekannten Webpages
z.B. alle in Suchmaschine gespeicherten Pages.)
- Zufallsurfer macht unendlichen Random-Walk.
Suche: Aufenthaltswahrscheinlichkeit für Page v
= „Prestige“ der Webpage v.

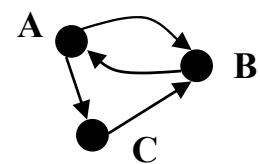
443

Anwendungen im Web Mining

Berechnung Pagerank

Startverteilung: $p_0(u) = 1 / |V|$

$$E = \begin{pmatrix} 0 & 1 & 1 \\ 1 & 0 & 0 \\ 0 & 1 & 0 \end{pmatrix}$$



Adjazenzmatrix E

Übergangsw'keit: $L[u,v] = \frac{E[u,v]}{\sum_{\beta} E[u,\beta]}$

$$L = \begin{pmatrix} 0 & \frac{1}{2} & \frac{1}{2} \\ 1 & 0 & 0 \\ 0 & 1 & 0 \end{pmatrix}$$

W'keit für Zeitpunkt i und Page v: $p_i[v] = \sum_{u \in V} L[u,v] p_{i-1}(u)$

Als Vektor aller Knoten: $\vec{p}_i = L^T \vec{p}_{i-1}$

Berechnung über „Power Iterations“: $\vec{p}_i \leftarrow L^T \vec{p}_{i-1}$
nach ca. 20-30 Iterationen stabil

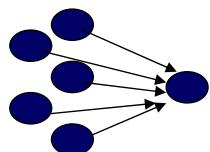
Lösung für nicht stark verbundene Graphen:
1. Weglassen von Knoten ohne Links
2. Zufallsprünge auf beliebige Seite

444

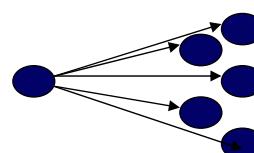
Anwendungen im Web Mining

HITS (Kleinberg 1998): Hyperlink Induced Topic Search

- Betrachte alle Seiten, die für Anfrage q relevant sind oder die mit einer relevanten Seite verlinkt sind (In- und Outlinks).
=> $G_q(V_q, E_q)$ für Anfrage q
- Zwei Typen von Webpages:
 - Hubs: Verlinken auf viele relevante Webpages (Authorities)
 - Authorities: Werden von vielen guten Hubs verlinkt.
=> Jede Webpage ist zu gewissen Grad sowohl Hub als auch Authority.
Für Webpage u sei $h[u]$ der Hub-Score und $a[u]$ der Authority-Score.



Eine gute Authority wird von vielen guten Hubs referenziert.



Ein guter Hub referenziert viele gute Authorities.

445

Anwendungen im Web Mining

Berechnung von HITS:

\vec{a} Vektor aus Authority-Scores aller $v \in V_q$

\vec{h} Vektor aus Hub-Scores aller $v \in V_q$

Berechnung über wechselseitige Iterationen : $\vec{a} = E^T \vec{h}$ (Authorityscore)

$\vec{h} = E \vec{a}$ (Hubscore)

Vorgehen:

1. Bestimme alle relevanten Pages (Rootset).
2. Bestimme alle Pages, die Rootset verlinken.(Extendedset)
3. Iteriere über Hub- und Authority-Scores (Extended Set)
4. Sortiere Ergebnisse nach Hub-Score, Authority-Score oder Kombination.

446

Zusammenfassung

- Link Mining untersucht, wichtige Substrukturen und Knoten in großen Netzwerken verlinkter Objekte
- Häufig Auftretende Subgraphen sind interessant, weil sie Muster in der Struktur des Netzwerkes darstellen
- Einzelne Knoten werden untersucht um die Bedeutung oder den Einfluss einzelner Objekte auf andere zu untersuchen
- Forschungsgebiet noch sehr jung
=> es ist noch nicht klar welche Strukturen besonders interessant aus Anwendungssicht sind.
- Da Objektnetzwerke sehr komplex sind, kann man interessante Muster in Vielerlei Hinsicht definieren

447

Literatur

- Yan X., Han J.:“gSpan: Graph-based substructure pattern mining“, In ICDM, 2002.
- Kuramochi M., Karypis G.:“Frequent Subgraph Discovery“, In ICDM, 2001
- Brin S., Page L.:“The anatomy of a large-scale hypertextual Web search engine“, Computer Networks and ISDN Systems, Vol 30, Nr.1-7, S.107-117, 1998
- Kleinberg J. M.:“Authoritative sources in a hyperlinked environment“, Journal of the ACM, Vol.46, Nr. 5, S. 604-632, 1999
- Brandes U.:“A faster Algorithm for Betweenness Centrality“, Journal of Mathematical Sociology, 25(2):163-177, 2001

448