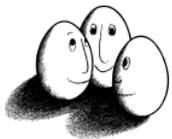


Suchstrategien

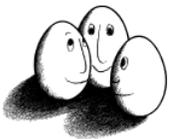
PG 402

Phillip Look
Christian Hüppe

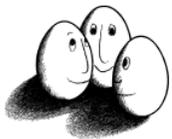
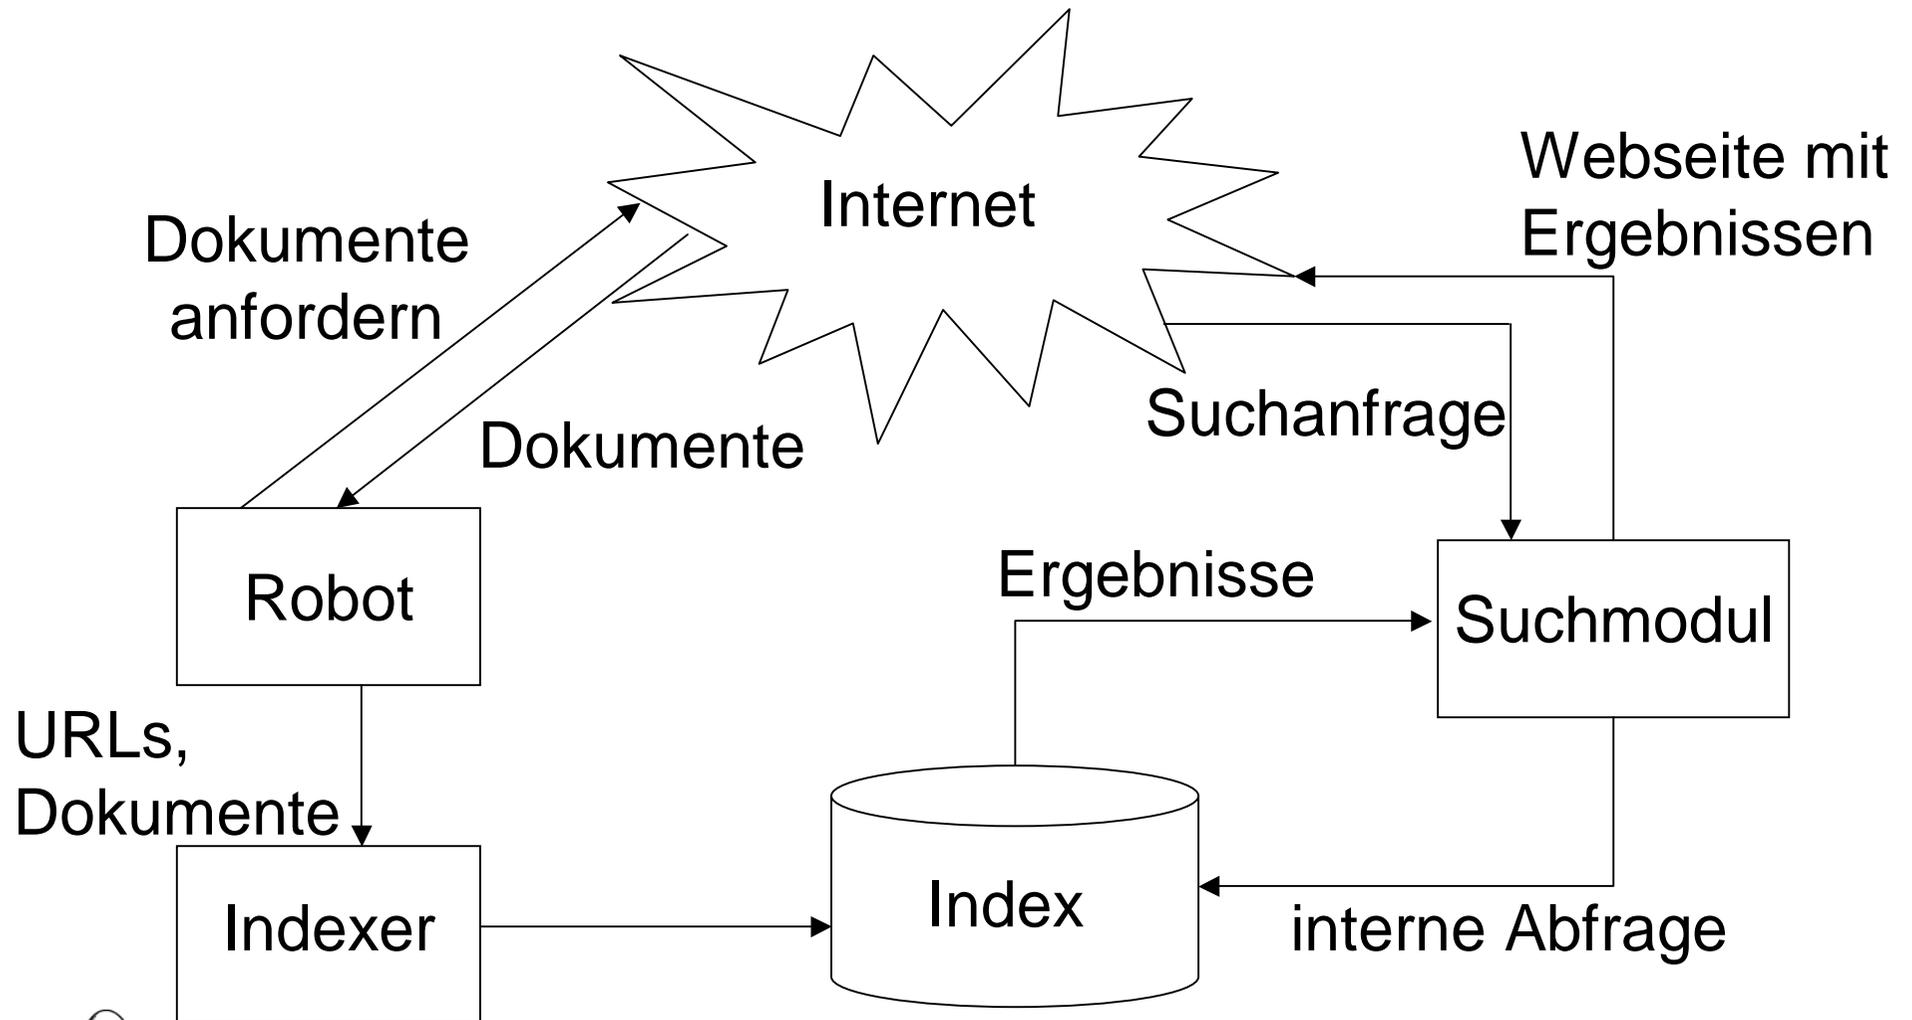


Überblick

- Einführung
- Untersuchung von 2 Suchmaschinen
- Verbesserung der Rankingfunktion mit Hilfe von Clickthrough-Daten
- Clustering von Query Logs
- Strukturorientierte Ansätze



Arbeitsweise von Suchmaschinen

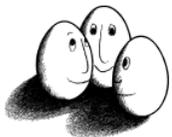


Ranking

- Handgepflegte Listen (Katalogsysteme)
- Häufigkeit der Schlagworte
- Formatierung der Schlagworte (Überschrift, fett, unterstrichen usw.)
- Link-Popularität
- Link-Qualität

manuell

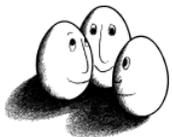
auto-
matisch



Kriterien einer guten Suchmaschine

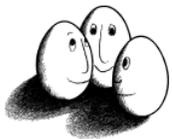
- Geschwindigkeit der Antwort
- Anzahl u. Aktualität des Indexes
- Qualität des gelieferten Rankings
 - Absolute Qualität → Precision / Recall
 - Relative Qualität → Benutzerverhalten

Wie kann man das Ranking verbessern?



Verbesserung des Rankings

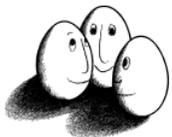
- Benutzerfeedback einbeziehen:
Problem: schwer zugänglich, gering vorhanden¹
Lösung: System beobachtet, welche Links benutzt werden
→ Clickthrough-Daten analysieren



¹ WebWatcher: A Tour Guide for the World Wide Web,
T. Joachims, D. Freitag, T. Mitchell,
Proceedings of IJCAI97, August 1997

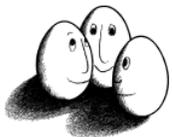
Clickthrough Daten

- Speicherung von
 - Name der anfragenden Maschine
 - IP-Adresse der anfragenden Maschine
 - Browser-Typ
 - Bildschirmauflösung
 - Benutzeranfragen
 - gewählte URLs
 - usw.
- } für uns interessant



Beispiel für Clickthrough Daten

felony	jud13.flcourts.org/felony.html
missoula,+mt	missoula.bigsky.net/score/
feeding+infants+solid+foods	members.tripod.com/drlee90/solid.html
colorado+lotto+results	www.co-lotto.com/
northern+blot	www.invitrogen.com/expressions/1196-3.html
wildflowers	www.life.ca/nl/43/flowers.html
ocean+whales	playmaui.com/ocnraftn.html
ralph+lauren+polo	www.shopbiltmore.com/dir/stores/polo.htm
bulldog+hompag	www.adognet.com/breeds/2abulm01.html
lyrics	www.geocities.com/timessquare/cauldron/8071
churches+in+atlanta	acme-atlanta.com/religion/christn.html
retail+employment	www.crabtree-evelyn.com/employ/retail.html
illinois+mortgage+brokers	www.birdview.com/ypages2/c3.htm
stock+exchange+of+singapore	www.ses.com.sg
front+office+software	www.saleslogic.com/saleslogix.phtml
free+3d+home+architect	www.adfoto.com/ads1/homeplans.shtml
country+inns+sale	innmarketing.com/form.html
free+desktop+wallpaper	www.snap-shot.com/photos/fireworks/
automotive+marketing+research	www.barndoors.com/rcmresources.htm
router+basics	www.wheretobuy.com/prdct/706/55.html



Vorteile von Clickthrough-Daten

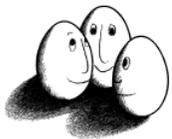
- man kommt sehr einfach an Daten
- die Datenmenge ist quasi unendlich
- unbeeinflusstes Benutzerverhalten wird aufgezeichnet
- man kann sinngemäße Queries / URLs finden
 - Benutzer wählen gleiche URLs bei unterschiedlichen Queries
 - Benutzer wählen unterschiedliche URLs bei gleicher Query



Experiment 1

Vergleichen von 2 Suchmaschinen A und B:

- Einheitliche Benutzeroberfläche
- Keine Einschränkung der Produktivität des Benutzers
- Benutzerbeurteilung soll klar demonstriert werden

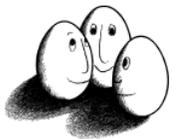


Experiment 1

- Query wird an Suchmaschine A und B gesandt
- Ranking $A = (a_1, a_2, \dots)$ und $B = (b_1, b_2, \dots)$ können in ein gemeinsames Ranking $C = (c_1, c_2, \dots)$ gemischt werden, so dass für jeden Rang n von C gilt

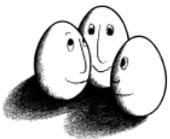
$$\{c_1, \dots, c_n\} = \{a_1, \dots, a_{n_a}\} \cup \{b_1, \dots, b_{n_b}\}$$

mit $n_b \leq n_a \leq n_b + 1$.



Ranking generieren

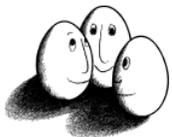
```
public void combine( Vector a, Vector b, int na, int nb, Vector c ) {  
    if ( na == nb ) {  
        if ( !c.contains( a.get( na + 1 ) ) ) {  
            c.add( a.get ( na + 1 ) );  
        }  
        this.combine( a, b, na+1, nb, c );  
    }  
    else {  
        if ( !c.contains( b.get( nb + 1 ) ) ) {  
            c.add( b.get( nb + 1 ) );  
        }  
        this.combine( a, b, na, nb +1, c );  
    }  
}
```



Vorteile dieses Aufbaus

Annahme:

- Alle Links werden ohne Ausnahme betrachtet
 - Benutzer nimmt von Top-Ranking A und Top-Ranking B gleich viele Links wahr
- Benutzer wählt relevante Links
- Kurzzusammenfassung bietet genug Informationen → Wahl nicht zufällig
 - Klicks enthalten Informationen über die Qualität der Top n_a und n_b Links beider Suchmaschinen



Google Results:

1. Kernel Machines
<http://svm.first.gmd.de/>
2. SVM-Light Support Vector Machine
http://ais.gmd.de/~thorsten/svm_light/
3. Support Vector Machine and Kernel ... References
<http://svm.....com/SVMrefs.html>
4. Lucent Technologies: SVM demo applet
<http://svm.....com/SVT/SVMset.html>
5. Royal Holloway Support Vector Machine
<http://svm.dcs.rhbnc.ac.uk/>
6. Support Vector Machine - The Software
<http://www.support-vector.net/software.html>
7. Support Vector Machine - Tutorial
<http://www.support-vector.net/tutorial.html>
8. Support Vector Machine
<http://jbolivar.freesevers.com/>

MSNSearch Results:

1. Kernel Machines
<http://svm.first.gmd.de/>
2. Support Vector Machine
<http://jbolivar.freesevers.com/>
3. An Introduction to Support Vector Machines
<http://www.support-vector.net/>
4. Archives of SUPPORT-VECTOR-MACHINES ...
<http://www.jiscmail.ac.uk/lists/SUPPORT...>
5. SVM-Light Support Vector Machine
http://ais.gmd.de/~thorsten/svm_light/
6. Support Vector Machine - The Software
<http://www.support-vector.net/software.html>
7. Lagrangian Support Vector Machine Home Page
<http://www.cs.wisc.edu/dmi/lsvm>
8. A Support ... - Bennett, Blue (ResearchIndex)
<http://citeseer.../bennett97support.html>

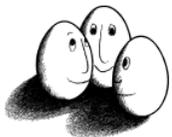
Combined Results:

1. Kernel Machines
<http://svm.first.gmd.de/>
2. Support Vector Machine
<http://jbolivar.freesevers.com/>
3. SVM-Light Support Vector Machine
http://ais.gmd.de/~thorsten/svm_light/
4. An Introduction to Support Vector Machines
<http://www.support-vector.net/>
5. Support Vector Machine and Kernel Methods References
<http://svm.research.bell-labs.com/SVMrefs.html>
6. Archives of SUPPORT-VECTOR-MACHINES@JISMAIL.AC.UK
<http://www.jiscmail.ac.uk/lists/SUPPORT-VECTOR-MACHINES.html>
7. Lucent Technologies: SVM demo applet
<http://svm.research.bell-labs.com/SVT/SVMset.html>
8. Royal Holloway Support Vector Machine
<http://svm.dcs.rhbnc.ac.uk/>
9. Support Vector Machine - The Software
<http://www.support-vector.net/software.html>
10. Lagrangian Support Vector Machine Home Page
<http://www.cs.wisc.edu/dmi/lsvm>



Google vs. MSNSearch

Ranging A	Ranging B	A besser	B besser	A = B	Total
Google	MSNSearch	34	20	69	123
Google	Standard	18	1	15	34
MSNSearch	Standard	16	2	5	23

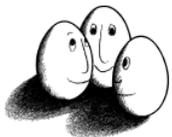


Benutzerfeedback aus Clickthrough-Daten Extrahieren

- Gegebenes Ranking: $(\text{link}_1, \text{link}_2, \text{link}_3, \dots)$
- C ist Ranking der angeklickten Links

$$\text{link}_i <_{r^*} \text{link}_j$$

für alle Paare $1 \leq j < i$, mit $i \in C$ und $j \notin C$.



Lernen einer Rankingfunktion mit der SVM

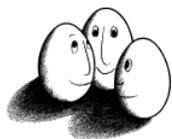
- Vereinfache das Problem in ein binäres Klassifikations-Problem
 - relevanter Link
 - unrelevanter Link
- Trainingmenge mit queries q und (optimales) Zielranking r^*

$$(q_1, r^*_1), (q_2, r^*_2), \dots, (q_n, r^*_n).$$



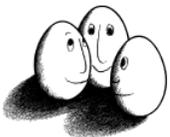
Attribute eines Links zum Lernen

- Link-Rang bei anderen Suchmaschinen
- Domain-Name in Query enthalten
- Länge der URL
- Länderkennung der URL
- Domain der URL
- Tilde in der URL
- Cosinusmaß zwischen URL-Worten und Query
- Cosinusmaß zwischen Titel und Query



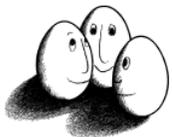
Vektorraummodell (1)

- Terme der Datenbasis spannen einen orthogonalen Vektorraum auf
- Dokumente und Queries sind Punkte in diesem Vektorraum
- Gesucht werden Dokumente, deren Vektoren ähnlich zum Queryvektor sind

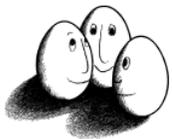
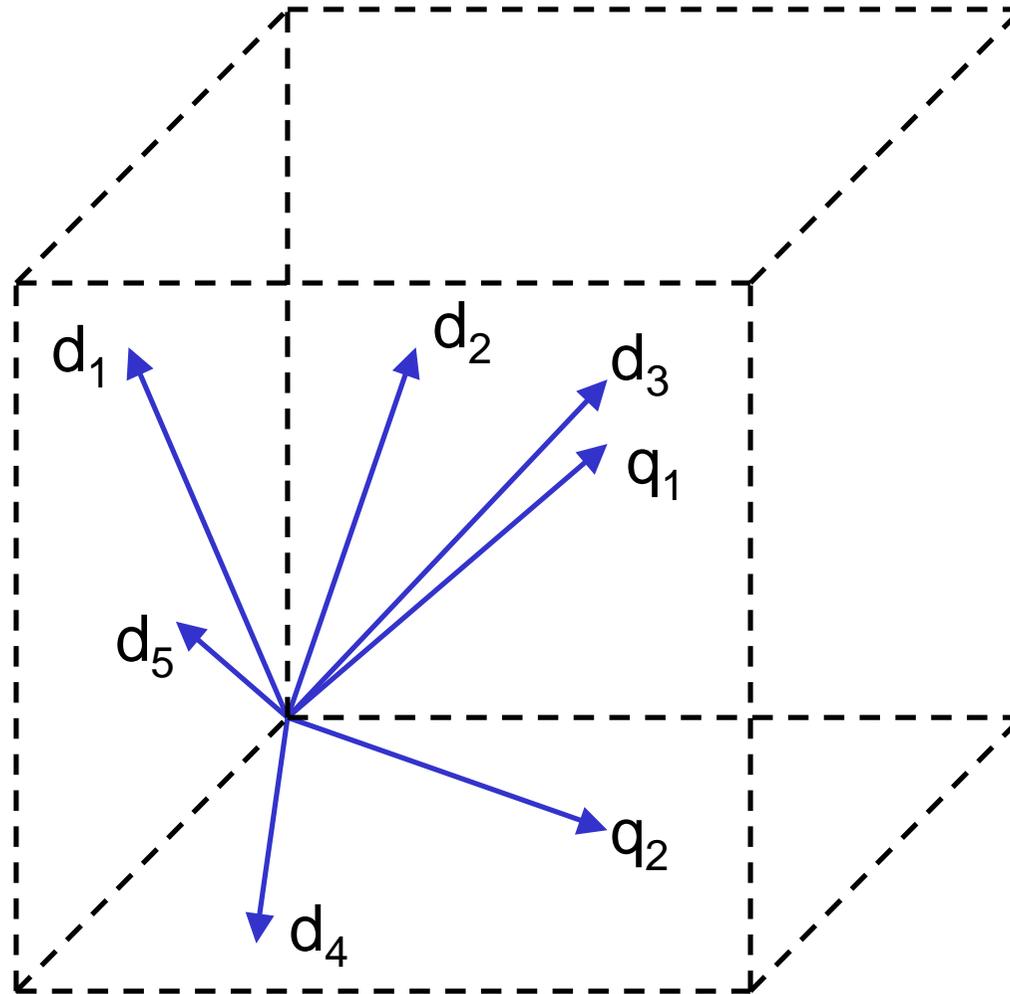


Vektorraummodell (2)

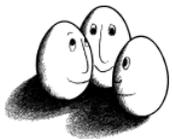
- Ähnlichkeit wird über Cosinusmaß bestimmt
- Cosinusmaß: Cosinus des Winkels zwischen zwei Dokumentvektoren bzw. zwischen Query- und Dokumentvektor
- Wenn Vektoren ähnlich ausgerichtet sind
→ Winkel entsprechend klein



Vektorraummodell - Beispiel

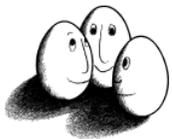


Clustering von Query Logs



Clustering von Query Logs

- Daten → Clickthroughdaten
{Query, ausgewählte URLs}
- Betrachtung der Daten als Graph
Konten → Queries und URLs
Kanten → Zusammenhang: Query und URL
- Besonderheit
Inhalt der URLs wird ignoriert

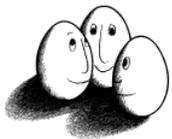


Clustering Algorithmus

- hierarchical agglomerative clustering (HAC)
- Inhalt wird entgegen normalen HAC-Algorithmen ignoriert

Vorteil:

- Clustering erfordert keine Speicherung von großen Datenmenge
- Kann auch bei textfreien Seiten angewandt werden (z. B. Bilder)
- Implementierung ist sehr viel einfacherer (Kein aufwendiges Preprocessing um Inhalte aufzuarbeiten)



Clustering Algorithmus

- Clustering von queries

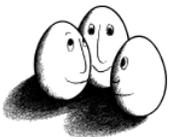
Beispiel:

- Benutzer stellt Anfrage q

- $q \in \text{Cluster } C$

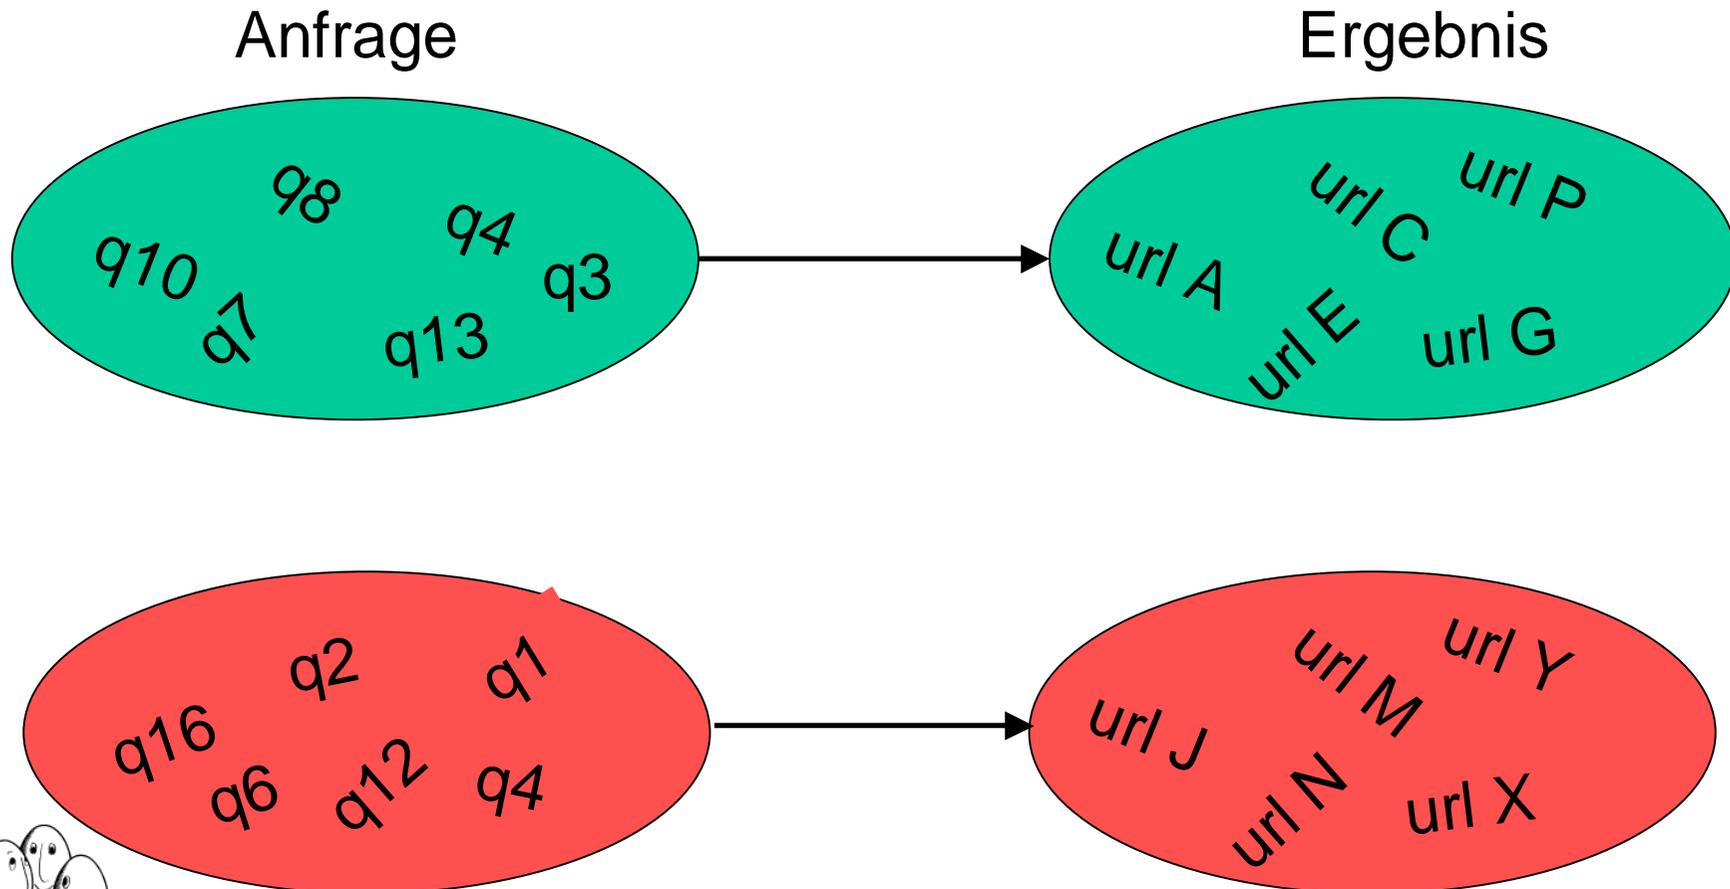
→ System schlägt andere queries aus C vor

Gute Unterstützung, bei unbefriedigendem Ergebnis



Graph-Based Iterative Clustering

- Disjunkte Mengen von Anfragen
- Disjunkte Mengen von URLs

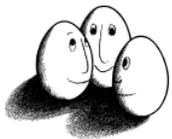


Algorithmus 1

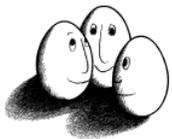
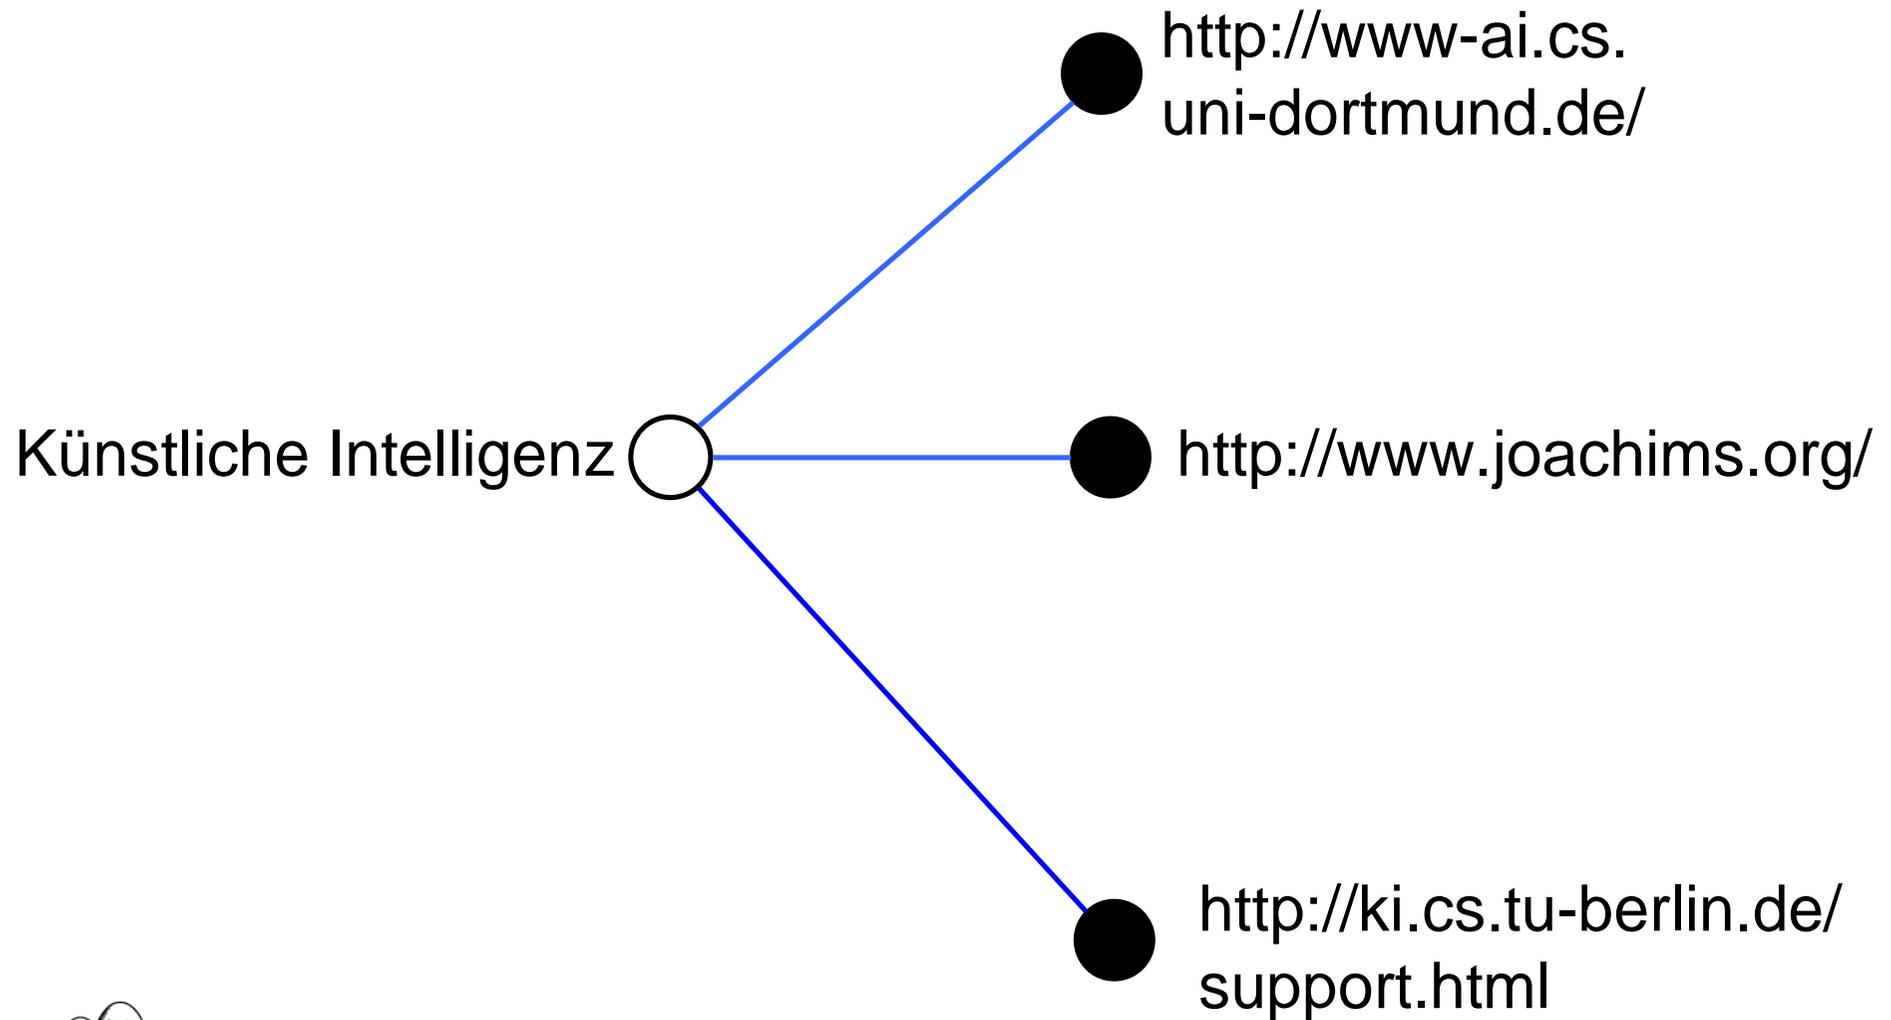
Input: Clickthrough-Daten C

Output: Graph G

1. Sammle alle Anfragen aus C in der Menge Q
2. Sammle alle URLs aus C in der Menge U
3. Für jedes Element in Q erzeuge einen „weißen“ Knoten in G
4. Für jede URL in U erzeuge einen „schwarzen“ Knoten in G
5. Wenn Anfrage q mit einer URL u auftritt, dann lege eine Kante in G zwischen den schwarzen und den weißen Knoten



Beispiel zum Algorithmus 1



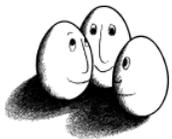
Ähnlichkeit zwischen Knoten

- $N(x)$ = Menge benachbarter Knoten von x in einem Graphen
- Knoten y ähnelt x , wenn $N(x)$ und $N(y)$ eine große Überschneidung haben

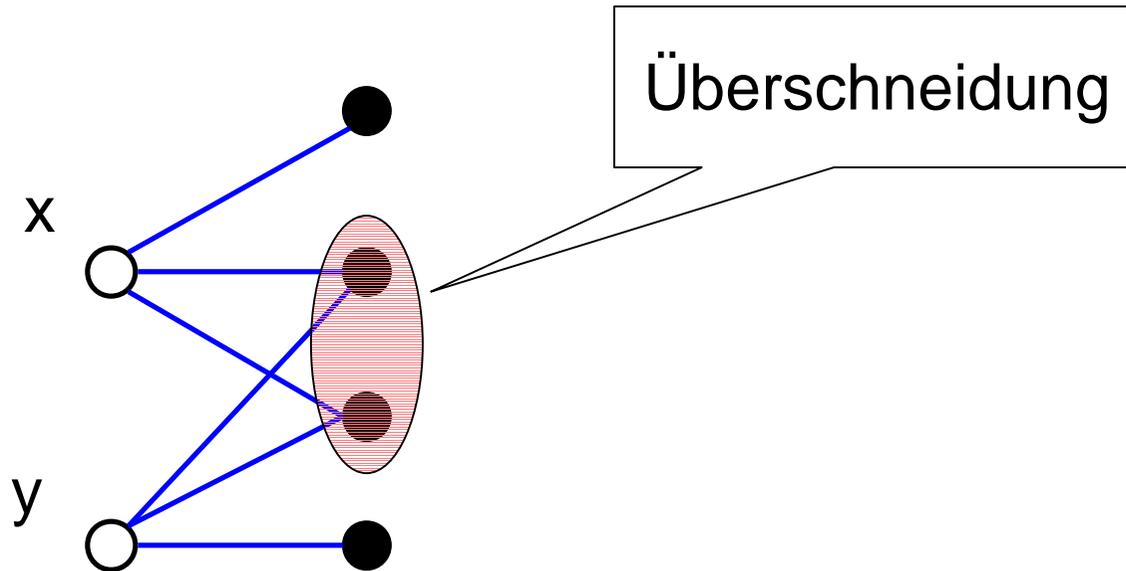
Formal:

$$\sigma(x, y) \stackrel{\text{def}}{=} \begin{cases} \frac{N(x) \cap N(y)}{N(x) \cup N(y)} \\ 0 \end{cases}$$

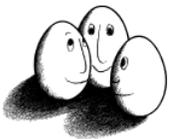
Mit $|N(x) \cup N(y)| > 0$



Beispiel zur Ähnlichkeit



Ähnlichkeit: $\sigma(x, y) = \frac{2}{4}$

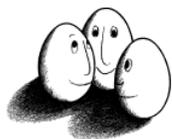


Algorithmus 2

Input: Graph G

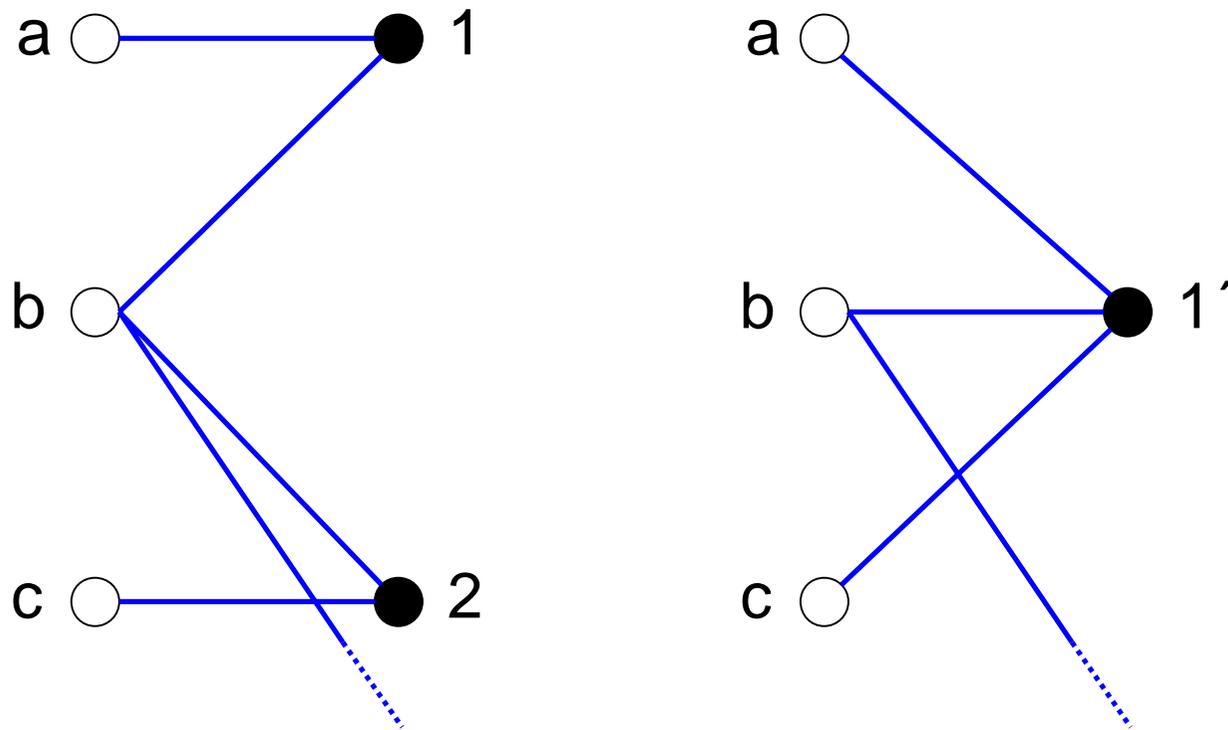
Output: Neuer Graph G' :

1. Bewerte alle weißen Knotenpaare in G
2. Füge die Knoten w_x, w_y zusammen, für die $\sigma(w_x, w_y)$ am größten ist
3. Schritt 1 und 2 für schwarze Knoten durchführen
4. Bis zur Abbruchbedingung gehe zu 1



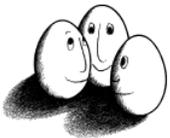
Iterativeransatz?

- Manche Ähnlichkeiten können nicht im Originalgraphen erkannt werden

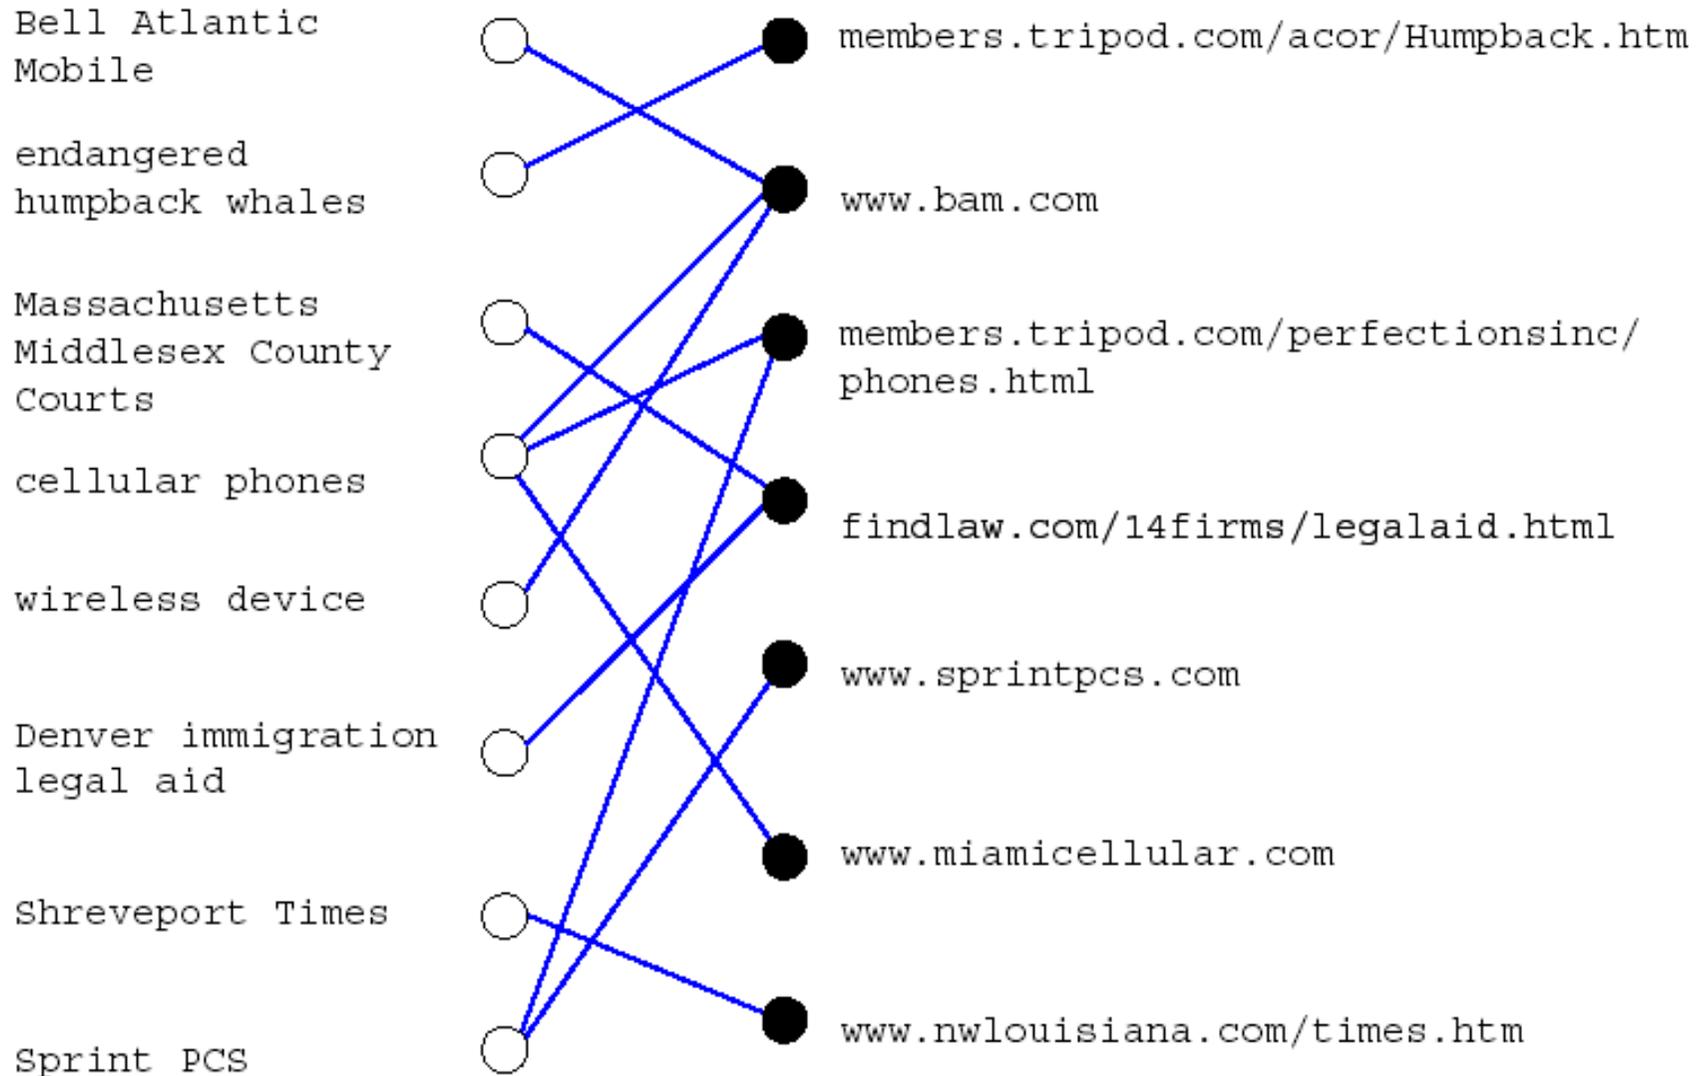


$$\sigma(a, c)=0$$

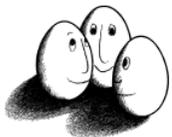
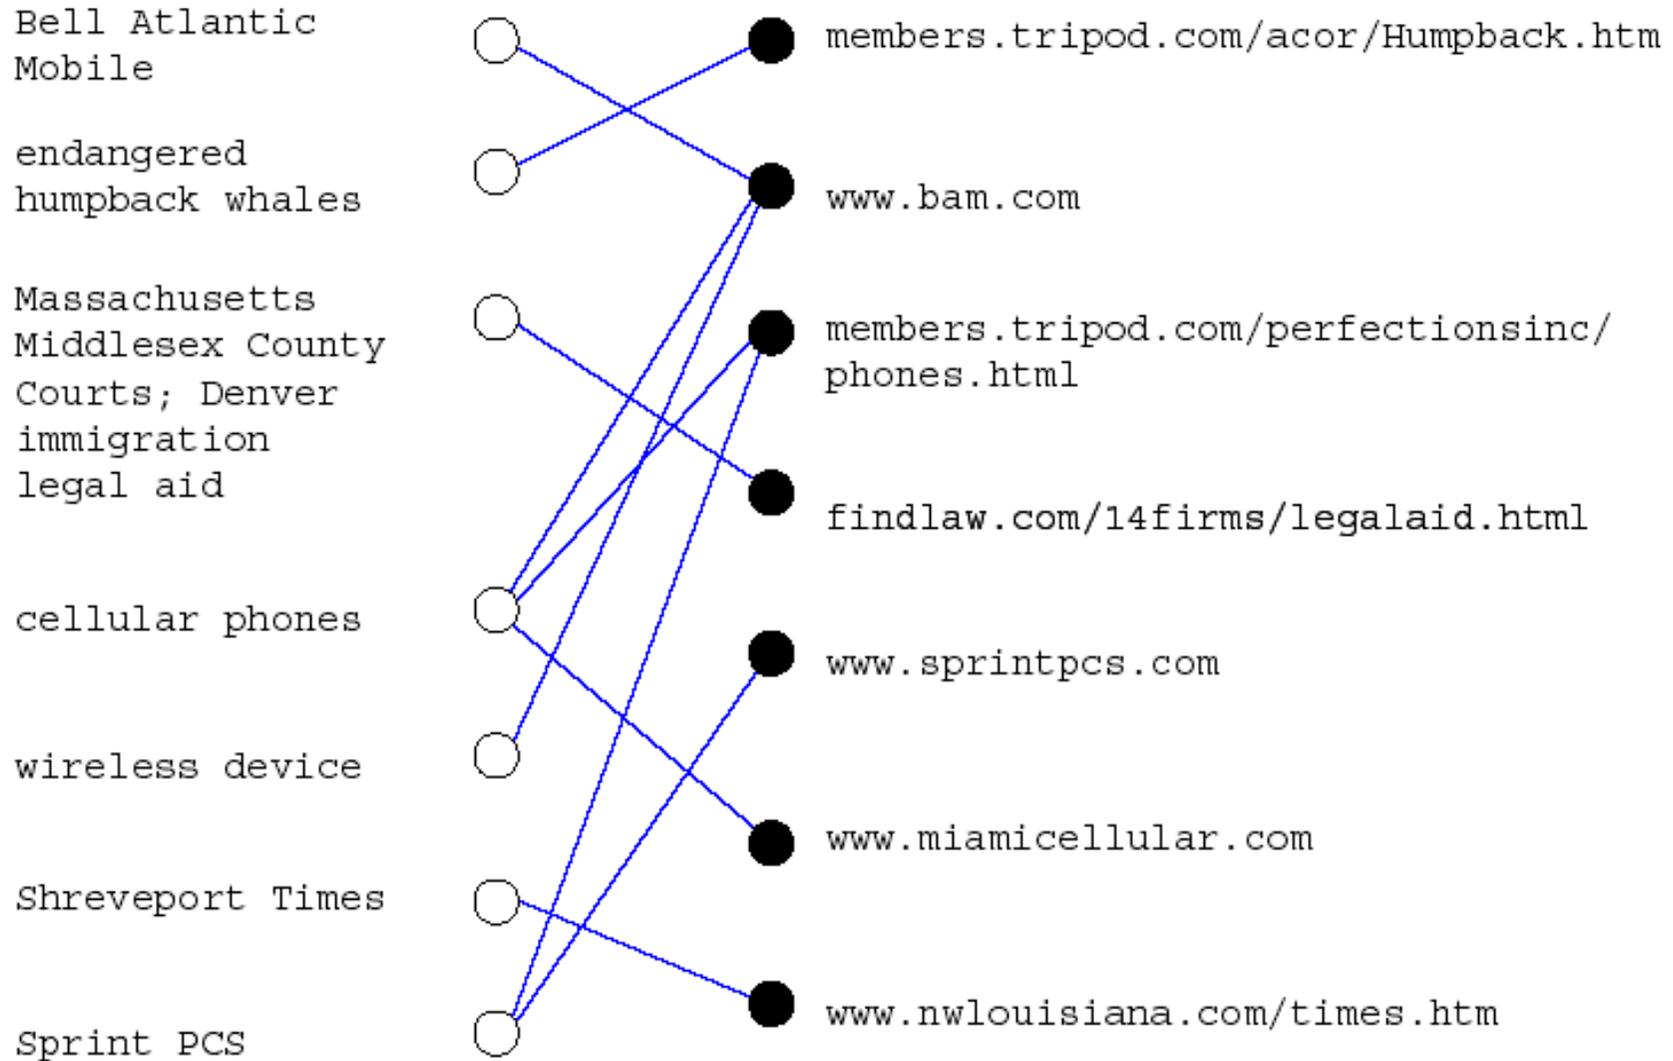
$$\sigma(1, 2)=1/3 \longrightarrow \sigma(a, c)=1$$



Originalgraph



Query Clustering



URL Clustering

Bell Atlantic
Mobile

endangered
humpback whales

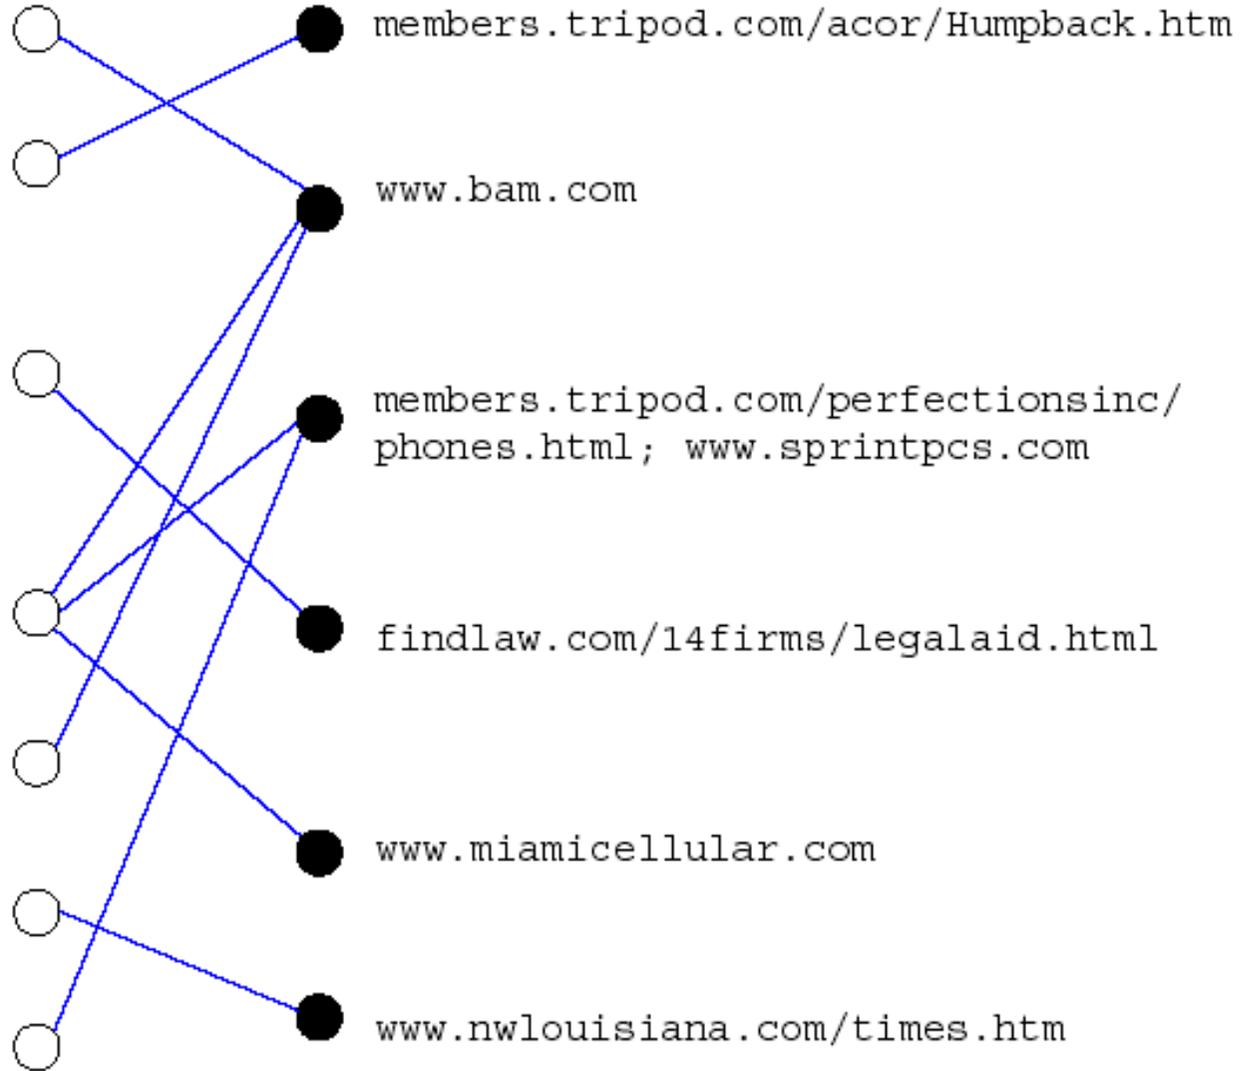
Massachusetts
Middlesex County
Courts; Denver
immigration
legal aid

cellular phones

wireless device

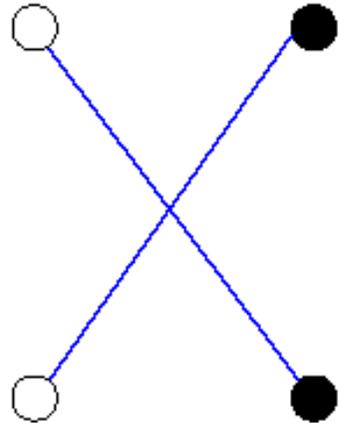
Shreveport Times

Sprint PCS



Fertige Cluster

Bell Atlantic
Mobile, wireless
device, cellular
phones, Sprint
PCS



members.tripod.com/acor/Humpback.htm

endangered
humpback whales

www.bam.com,
www.miamicellular.com,
members.tripod.com/perfectionsinc/phones.html, www.sprintpcs.com

Massachusetts
Middlesex County
Courts, Denver
immigration
legal aid

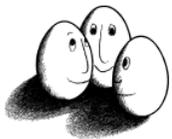


findlaw.com/14firms/legalaid.html

Shreveport Times



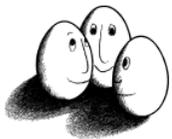
www.nwlouisiana.com/times.htm



Strukturorientierte Ansätze

Überblick:

- Fish-Search
- Enhanced Categorization
- Focused Crawling
- Related Pages
- Fourier Domain Scoring

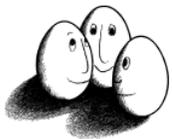


Fish-Search

zum Verfahren:

- Eingabe: URL (einzelner Fisch)
- folge den Links * (Fischschwarm)
- bewerte die Seite (Stärke des Fisches)
- gehe zu (*)

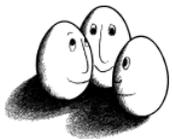
P.M.E. De Bra, R.G.J. Post **1994**



Fish-Search

Vor- und Nachteile:

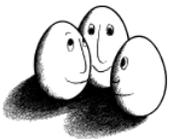
- + gefundenen Seiten existieren
- + keine Datenbank erforderlich
- hohe Netzlast
- nicht gelinkte Seiten werden nicht gefunden
- Sackgassen werden nicht verlassen



Fish-Search

für uns:

- ausgehende Links verfolgen
- URL als Ausgangspunkt

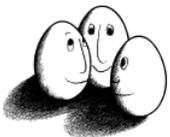


Enhanced Categorization

zum Verfahren:

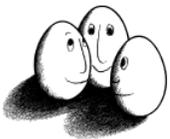
- gegeben ist eine Unterteilung in Kategorien (Freizeit / Sport / Tennis / Turniere / ...)
- für jede Kategorie sind gute Beispiele vorhanden
- ermittle Diskriminanten und Rauschen

Soumen Chakrabarti, Byron Dom, Piotr Indyk **1998**



Enhanced Categorization

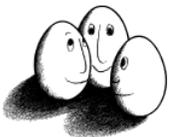
- erweitere Inhalt der Seite um:
 - a) Text der benachbarten Seiten
 - b) Pfad der benachbarten Seiten (besser)
- Ordne die Seite in eine Kategorie ein.



Enhanced Categorization

Vor- und Nachteile:

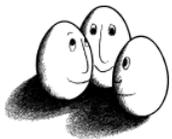
- + Nachbarschaft der Seite wird mit untersucht
- große Beispielmengen erforderlich (20.000 Seiten von Yahoo)
- Einteilung in Kategorien erforderlich
- benötigte Kategorien zu speziell



Enhanced Categorization

für uns:

- Diskriminanten finden
- aus- und eingehende Links untersuchen



Focused Crawling

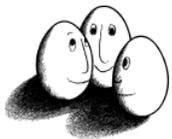
Verfahren:

- vereint die ersten beiden Verfahren
- Ausgangspunkt ist eine URL
- Nachkommen werden auch kategorisiert

Vor- und Nachteile:

- + Search-On-Demand spart Speicherplatz
- Interaktion

Soumen Chakrabarti, Byron Dom, Martin van den Berg **1999**



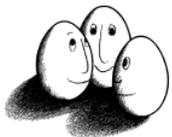
Related Pages

zum Verfahren:

- Eingabe: URL
- Ausgabe: ähnliche Seiten

- basiert nur auf der Linkstruktur
- zwei verschiedene Ansätze

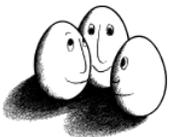
Jeffrey Dean, Monika Henzinger **1998**
basiert auf HITS Algo. von Kleinberg **1998**



Related Pages

zum Verfahren: (cocitation)

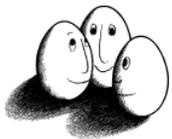
1. suche Eltern und Kinder der Start-URL
2. suche Geschwister
3. wähle die besten Geschwister



Related Pages

zum Verfahren: (companion)

1. baue vicinity-Graph
2. entferne Duplikate (Mirror Seiten)
3. bewerte Kanten
4. wähle die bestbewerteten Seiten



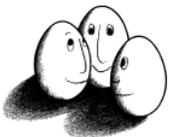
Related Pages

Vor- und Nachteile:

- + einfache zu implementieren
- es werden nicht alle Dokumente gefunden
- hohe Performance nur mit Cache

für uns:

- mehrere Generationen von Links verarbeiten

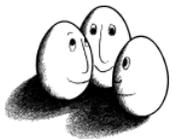


Fourier Domain Scoring

zum Verfahren:

- Idee: betrachte Wörter als Wellen
 - Eingabe: Schlüsselwörter
1. teile Text in Abschnitte
 2. berechne die Wellen
 3. Fourier-Transformation -> Amplitude, Phase
 4. vergleiche Dokument mit der Eingabe

Laurence Park, M. Palaniswami, R. Kotagiri, 2001



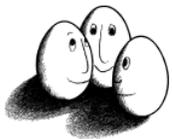
Fourier Domain Scoring

Vor- und Nachteile:

+ Häufigkeit und Position werden beachtet

für uns:

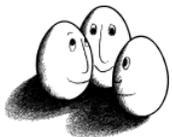
- als Post-Processing-Schritt möglich
- Unbekannte: Fourier-Transformation



Auswertung

Qualität der Links:

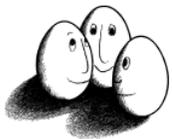
	gesamt	gleicher Host	guter Inhalt	gute Links
absolut (ein.):	15	12	3	5
relativ (ein.):	1,6	80%	20%	33%
absolut (aus.):	138	138	19	14
relativ (aus.):	15,5	100%	14%	10%



Auswertung

Links verfolgen:

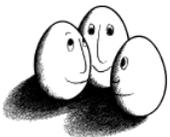
- es gibt kaum Links zu guten Treffern
- Sackgassen werden nicht verlassen
- Verfolgung der Links lohnt sich nicht



Auswertung

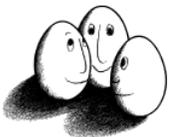
Diskriminanten finden:

- Schlüsselwörter: Alterspyramide, Deutschland
- Diskriminante: Bevölkerungsentwicklung
- Suchergebnis: viele gute Treffer
- Ansatz ist vielversprechend

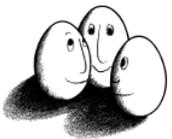


Literatur

- [**Fish-Search**] P.M.E. De Bra, R.G.J. Post, **1994**, „Information Retrieval in the World-Wide-Web: Making Client-based search feasible“
- [**Enhanced Categorization**] Soumen Chakrabarti, Byron Dom, Piotr Indyk, **1998**, „Enhanced Hypertext Categorization using hyperlinks“
- [**Focused Crawling**] Soumen Chakrabarti, Byron Dom, Martin van den Berg, **1999**, „Focused Crawling: a new approach to topic-specific Web resource discovery“
- [**Related Pages**] Jeffrey Dean, Monika Henzinger, **1998**, „Finding Related Pages in the World Wide Web“
- [**Fourier Domain Scoring**] Laurence Park, M. Palaniswami, R. Kotagiri, **2001**, „Internet Document Filtering using Fourier Domain Scoring“
- [**Untersuchung von 2 Suchmaschinen**] Joachims Thorsten, **2002**, „Evaluating Search Engines using Clickthrough Data“
- [**Verbesserung der Rankingfunktion mit Hilfe von Clickthrough-Daten**] Joachims Thorsten, **2002**, „Optimizing Search Engines using Clickthrough Data“
- [**Clustering von Query Logs**] Beeferman Doug, Berger Adam, **200?**, „Agglomerative clustering of a search engine query log“
- [**Einführung**] Babiak Ulrich, **1997**, „Effektive Suche im Internet“



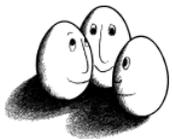
Ende



Google

- entwickelt von Lawrence Page u. Sergey Brin
- Prototyp 1997, Stanford-Universität
- Abdeckung: 1.2 Milliarden (ges. 2 Milliarden)*
- Strategie, Analyse:
 - Wie sind die Seiten vernetzt?
Beispiel: Zitate in wissenschaftlichen Artikel
 - Welche Seite verweist auf eine andere?
Ranghöhe von Seite A bestimmt Ranghöhe von Seite B

* Stand: Feb. 2001



- Menge von Dokumenten $D = \{d_1, \dots, d_m\}$
- optimales Ranking r^*

