Websuche

Linkanalyse

Bibliometrik: Zitatanalyse

- Viele Dokumente enthalten *Bibliographien* (oder *Referenzen*), d.h. eindeutige *Zitierungen* anderer vorher veröffentlichter Dokumente.
- Bei Verwendung von Zitaten als Links können solche Korpora als Graph betrachtet werden.
- Die Struktur dieses Graphen kann unabhängig vom Inhalt interessante Informationen über die Ähnlichkeit von Dokumenten und die Struktur von Informationen liefern.

Einflussfaktor (Impact Factor)

- Von Garfield in 1972 entwickelt, um die Bedeutung (Qualität, Einfluss) von wissenschaftlichen Zeitschriften zu messen.
- Maß dafür, wie oft Artikel einer Zeitschrift von anderen Wissenschaftlern zitiert werden.

- Wird jährlich vom Thompson Scientific (http://www.isinet.com/) berechnet und veröffentlicht.

- Der *Einflussfaktor* einer Zeitschrift *J* im Jahr *Y* ist die durchschnittliche Anzahl von Zitaten (von allen indizierten Dokumenten, die im Jahr Y veröffentlicht wurden) eines Papers, das in J im Jahr *Y*–1 oder *Y*–2 veröffentlicht wurde.
- Berücksichtigt nicht die Qualität des zitierenden Artikels.

- Siehe auch http://citeseer.ist.psu.edu/impact.html für einen ähnlichen Index.

Bibliographische Kopplung

- Maß für die Ähnlichkeit von Dokumenten, das 1963 von Kessler eingeführt wurde.
- Die bibliographische Kopplung von zwei Dokumenten *A* und *B* ist die Anzahl der Dokumente, die *sowohl* von *A* als auch von *B* zitiert werden, d.h. der Umfang des Durchschnitts ihrer Bibliographien (ggf. normiert durch die Größe der Bibliographien).

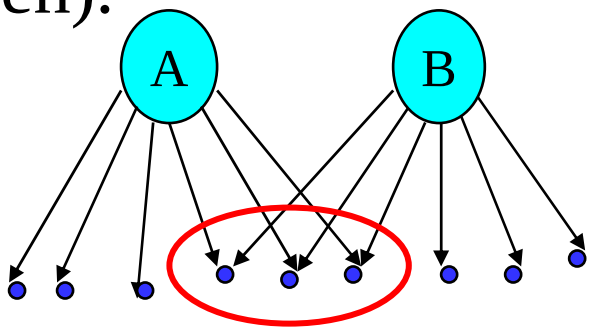

Ko-Zitatation

- Ein alternatives auf Zitaten basierendes Maß der Ähnlichkeit, das 1973 von Small eingeführt wurde.
- Anzahl der Dokumente, die sowohl *A* als auch *B* zitieren, ggf. normalisiert durch die gesamte Anzahl von Dokumenten die entweder *A* oder *B* zitieren.

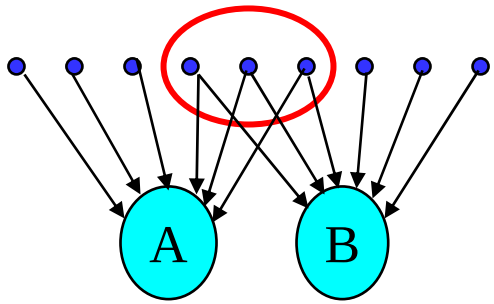

Zitate im Vergleich zu Links

- Weblinks sind anders als Zitate:
  - Links sind navigationsfähig.
  - Viele Seiten mit hohem In-Grad sind Portale und keine Inhaltsanbieter.
  - Nicht alle Links (aber auch nicht alle Zitate) sind Bestätigungen.
  - Firmenwebseiten verweisen nicht auf ihre Konkurrenten, Zitate relevanter Literatur werden hingegen durch Peer-Reviewing erzwungen.

Autoritäten

- *Autoritäten* sind Seiten, die anerkannt sind, und die signifikante, vertrauenswürdige und nützliche Information zu einem Thema zu liefern.
- *In-Grad* (Anzahl von Zeigern auf eine Seite) ist ein einfaches Maß der Autorität.
- Jedoch behandelt ein In-Grad alle Links gleich.
- Sollten nicht Links von Seiten, die selbst Autoritäten sind, mehr zählen?

Hubs

- *Hubs* sind Indexseiten, die viele nützliche Links auf relevante Inhaltsseiten (Themenautoritäten) liefern.
- Hubseiten zum Thema “Information Retrieval” sind z.B unter http://www.cs.utexas.edu/users/mooney/ir-course zu finden.

HITS

- Algorithmus, der 1998 von Kleinberg entwickelt wurde.
- Er versucht, Hubs und Autoritäten zu einem bestimmten Thema rechnerisch durch die Analyse eines relevanten Subgraphen des Webs zu bestimmen.
- HITS basiert auf einer rekursiven Definition:
  - Hubs verweisen auf viele Autoritäten.
  - Auf Autoritäten wird von vielen Hubs verwiesen.

Hubs und Autoritäten

- Zusammen neigen sie dazu, einen bipartiten Graphen zu bilden:

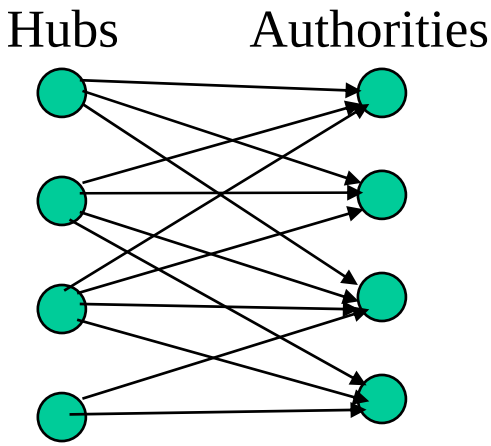

HITS Algorithmus

- Aufgabe: Berechnet Hubs und Autoritäten für ein bestimmtes Thema, das durch eine Anfrage spezifiziert ist.
- Bestimmt zuerst eine Menge relevanter Seiten für die Anfrage, die als *Basis*-Menge *S* bezeichnet wird.
- Analysiert die Linkstruktur des durch *S* induzierten Teilgraphen, um Autoritäts- und Hubseiten in dieser Menge zu finden.

Konstruieren eines Basis-Subgraphen

- Für eine spezifische Anfrage *Q* sei die *Wurzel*-Menge *R* die Menge der von einer Standard-Suchmaschine (z.B. KSM) zurückgegebenen Dokumente.
- *S* := *R*.
- Füge zu *S* alle Seiten hinzu, auf die mindestens eine Seite in *R* verweist.
- Füge zu *S* alle Seiten hinzu, die auf mindestens eine Seite in *R* verweisen.

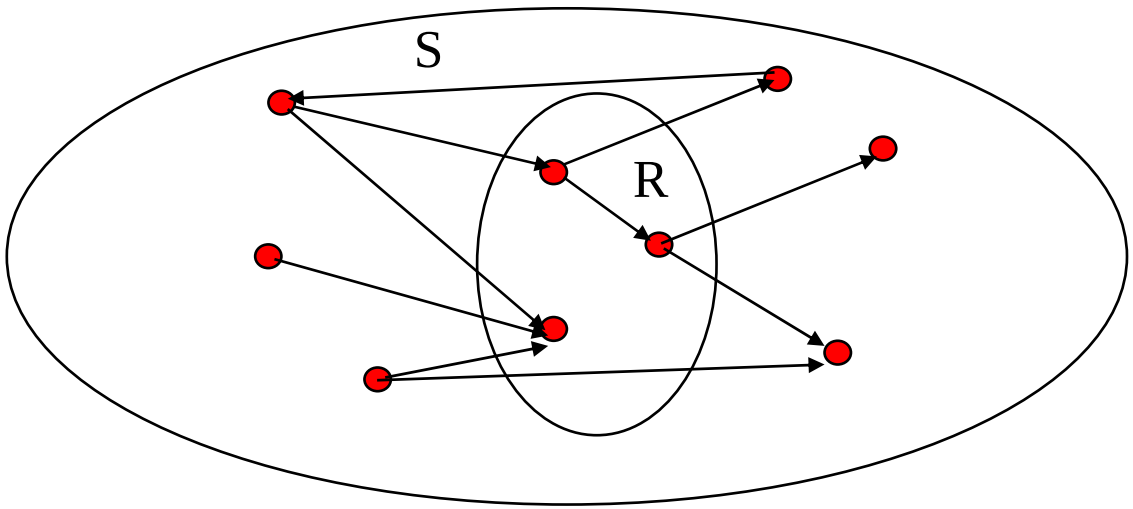

Aufwandsbegrenzung

- Um den rechnerischen Aufwand zu limitieren:
  - Begrenze die Anzahl der Wurzelseiten auf die besten 200 Seiten, die für die Anfrage gefunden wurden.
  - Begrenze die Anzahl der “Rückwärts-Link”-Seiten auf eine willkürliche Menge von höchstens 50 Seiten, die von einer “Rückwärts-Link”-Anfrage zurückgegeben wurden.
- Um reine Navigationslinks zu eliminieren:
  - Eliminiere Links zwischen zwei Seiten auf dem gleichen Host.
- Um “nicht-autoritätsfördernde” Links zu eliminieren:
  - Erlaube max. m ($m \simeq 4$–8) Seiten von jedem Host als Zeiger auf ein beliebige individuelle Seite.

Autorität und In-Grad

- Selbst in der Basismenge *S* einer gegebenen Anfrage sind die Knoten mit dem höchsten In-Grad nicht notwendigerweise Autoritäten (sondern evtl. nur allgemein bekannte Seiten wie Yahoo oder Amazon).
- Auf ‘wahre’ Autoritätsseiten wird von mehreren Hubs verwiesen (dies sind Seiten, die auf viele Autoritäten verweisen.)

HITS – Iterativer Algorithmus

- Iterativer Algorithmus, der sich langsam einer sich gegenseitig verstärkenden Menge von Hubs und Autoritäten nähert.

- Aufgabe: Bestimme für jede Seite $p \in S$
  - den Autoritätswert a_p (zusammengefasst in einem Vektor $\boldsymbol{a}$)
  - und den Hubwert h_p (Vektor $\boldsymbol{h}$)

HITS-Algorithmus

1. Initialisiere alle $a_p := h_p := 1$
2. Normalisiere die Werte, so dass gilt:

$$\sum_{p \in S} \left(a_p\right)^2 = 1 \qquad \sum_{p \in S} \left(h_p\right)^2 = 1$$

3. Auf Autoritäten wird durch viele gute Hubs verwiesen:

$$a_p = \sum_{q:q \to p} h_q$$

4. Hubs verweisen auf viele gute Autoritäten:

$$h_p = \sum_{q:p \to q} a_q$$

5. Solange die Vektoren sich (signifikant) ändern, gehe zu Schritt 2.

Illustrierte Update-Regeln

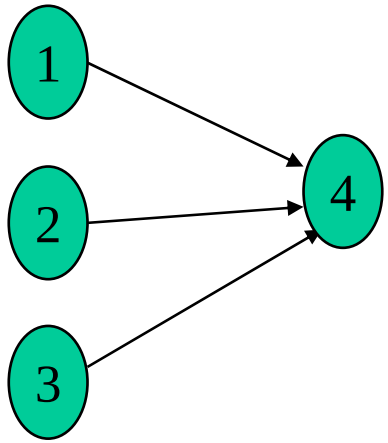

$a_4 := h_1 + h_2 + h_3$

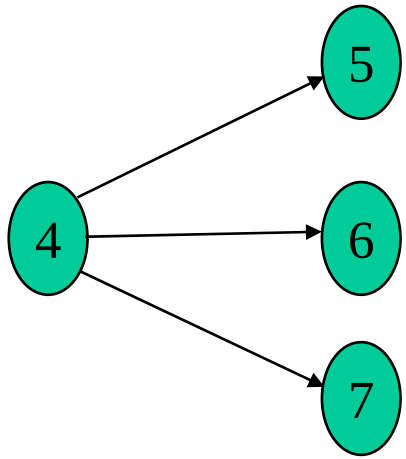

$h_4 := a_5 + a_6 + a_7$

HITS im Detail

Initialisiere für alle $p \in S$: $a_p := h_p := 1$

Bis Änderung kleiner als gegebener Schwellwert:

Für alle $p \in S$:

$$a_p := \sum_{q:q \to p} h_q$$

/* aktualisiere Autoritätswerte */

Für alle $p \in S$:

$$h_p := \sum_{q:p \to q} a_q$$

/* aktualisiere Hubwerte */

Für alle $p \in S$: $a_{p:} = a_p / c$ mit $c := \sqrt{\sum_{p \in S} a_p^2}$

/* ***a*** normalisieren */

Für alle $p \in S$: $h_{p:} = h_p / c$ mit $c := \sqrt{\sum_{p \in S} h_p^2}$

/* ***h*** normalisieren */

Darstellung in linearer Algebra

- Definiere A als Adjazenzmatrix für den durch S induzierten Subgraphen.
  - $A_{ij} = 1$ für $i \in S$, $j \in S$ gdw. $i \rightarrow j$ im Graphen.
- Die Autoritätswerte a_p werden in einem Vektor $\boldsymbol{a}$ zusammengefasst, und die Hubwerte h_p in einem Vektor $\boldsymbol{h}$.
- Die Schritte der Iteration ergeben sich zu
  - $\boldsymbol{h} := A\boldsymbol{a}$
  - $\boldsymbol{a} := A^{\mathrm{T}}\boldsymbol{h}$

Konvergenz

- Algorithmus konvergiert zu einem *Fixpunkt*, falls unendlich wiederholt.
- Autoritätsvektor $\boldsymbol{a}$ konvergiert gegen den ersten Eigenvektor von A^TA.
- Hubvektor, $\boldsymbol{h}$, konvergiert gegen den ersten Eigenvektor von AA^T.
- In der Praxis liefern 20 Wiederholungen ziemlich stabile Ergebnisse.

Ergebnisse

- Autoritäten für Anfrage “Java”
  - java.sun.com
  - comp.lang.java FAQ
- Autoritäten für Anfrage “search engine”
  - Yahoo.com
  - Excite.com
  - Lycos.com
  - Altavista.com
- Autoritäten für Anfrage “Gates”
  - Microsoft.com
  - roadahead.com

(Nach [Kleinberg 1998])

Beobachtung

- In den meisten Fällen waren die endgültigen Autoritäten nicht in der anfänglichen Wurzelmenge, die mit Altavista bestimmt wurde.
- Autoritäten wurden durch Vor- und Rückwärtslinks hinzugefügt (und dann durch HITS als Autorität bestimmt).

Finden ähnlicher Seiten durch Verwendung der Linkstruktur

- Aufgabe: Bestimmung ähnlicher Seiten zu einer Seite *P*. (Dieser Ansatz findet Autoritäten in der "Link-Nachbarschaft" von *P*.)

- Sei *t* gegeben (z.B. *t* = 200).
- Sei *R* eine Menge von *t* Seiten, die auf *P* verweisen (die Wurzelmenge).
- Bestimme die Basismenge *S* von *R* wie o.a.
- Lasse HITS auf *S* laufen.
- Gebe die besten Autoritäten in *S* als die "ähnlichsten Seiten von *P*" zurück.

Ergebnisse der Ähnlichkeitssuche

- Gegeben “honda.com”
  - toyota.com
  - ford.com
  - bmwusa.com
  - saturncars.com
  - nissanmotors.com
  - audi.com
  - volvocars.com

PageRank

- Alternative Link-Analyse-Methode, die von Google verwendet wird (Brin & Page, 1998).
- Versucht nicht, die Unterscheidung zwischen Hubs und Autoriäten zu erfassen, sondern klassifiziert Seiten nur nach Autorität.
- Wird eher auf das gesamten Web angewandt als auf eine lokale Nachbarschaft von Seiten, die die Ergebnisse einer Anfrage umgeben.

Grund-Idee PageRank

- Die Messung des In-Grades alleine (Zitatzählung) berücksichtigt nicht die Autorität der Quelle eines Links.
- (Vereinfachte) PageRank-Gleichung für Seite *p*:

$$R(p) = \sum_{q:q \to p} \frac{R(q)}{N_q}$$

  - N_q ist die Gesamtzahl der Out-Links von Seite *q*.
  - Eine Seite *q* gibt einen gleichen Anteil ihrer Autorität an alle Seiten weiter, auf die sie verweist (z.B. auf *p*).

Grund-Idee PageRank

- PageRank “fließt” entlang der Kanten:

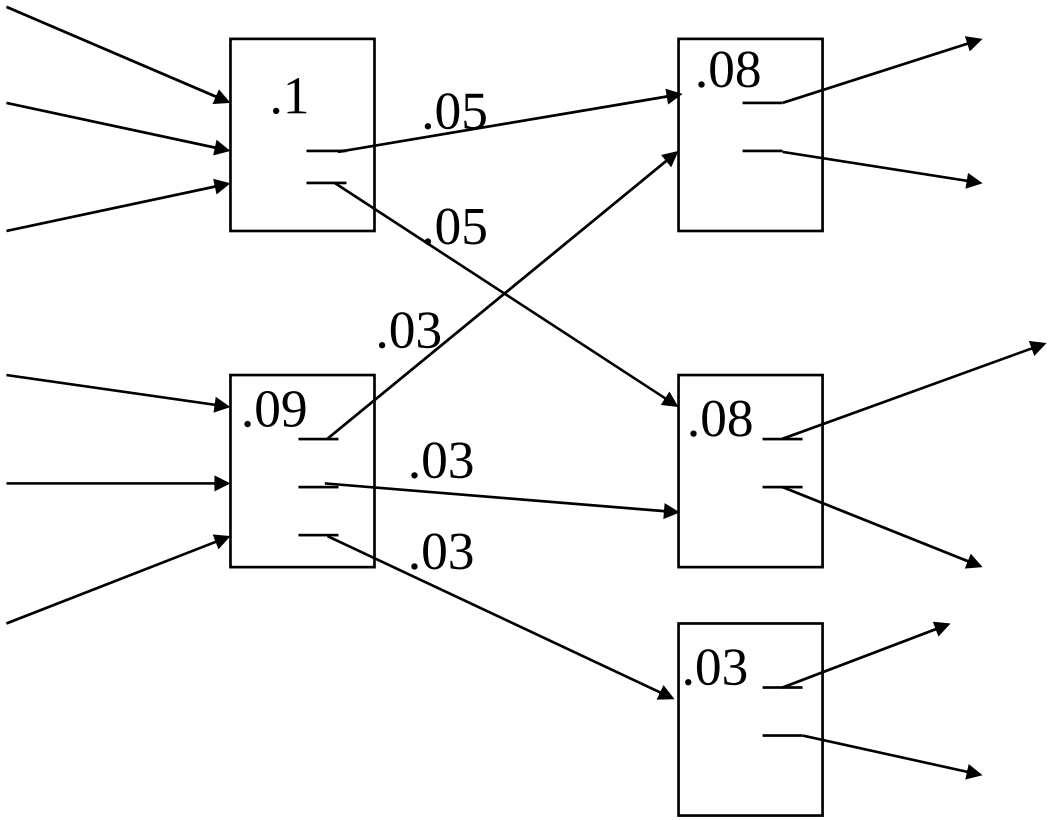

Grundidee PageRank

- Wiederhole den Fluss-Prozess bis zur Konvergenz:

  Sei S die Gesamtmenge der Seiten.

  Initialisiere für alle $p \in S$: $R(p) = 1/|S|$

  Bis sich Werte nicht mehr (viel) ändern (*Konvergenz*)

  Für jedes $p \in S$: $R'(p) = \sum_{q:q \to p} \frac{R(q)}{N_q}$

Beispiel: stabiler Fixpunkt

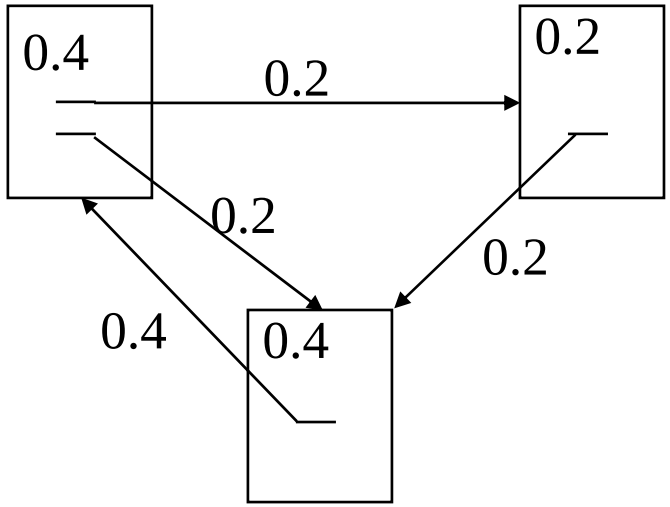

Lineare-Algebra-Version

- Betrachte $\boldsymbol{r}:=(R(p))_{p \in S}$ als einen Vektor in $\mathrm{IR}^{|S|}$.
- Sei $\mathbf{A}$ die $|S|\times|S|$-Matrix mit

  $\mathbf{A}_{vu} := 1/N_u$ falls $u \rightarrow v$, und $\mathbf{A}_{vu} := 0$ sonst.

- Dann gilt am Ende des Algorithmus $\boldsymbol{r} = \mathbf{A}\boldsymbol{r}$, d.h. $\boldsymbol{r}$ konvergiert zu dem Eigenvektor von $\mathbf{A}$, der zum Eigenwert 1 gehört.

Problem mit anfänglicher Idee

- Eine Gruppe von Seiten, die nur auf sich selbst verweist, aber auf die durch andere Seiten verwiesen wird, agiert als eine Gewichts-Senke, die das ganze Gewicht absorbiert.
- “Suchmaschinenoptimierer” nutzen diesen Effekt in “Linkfarmen” aus.

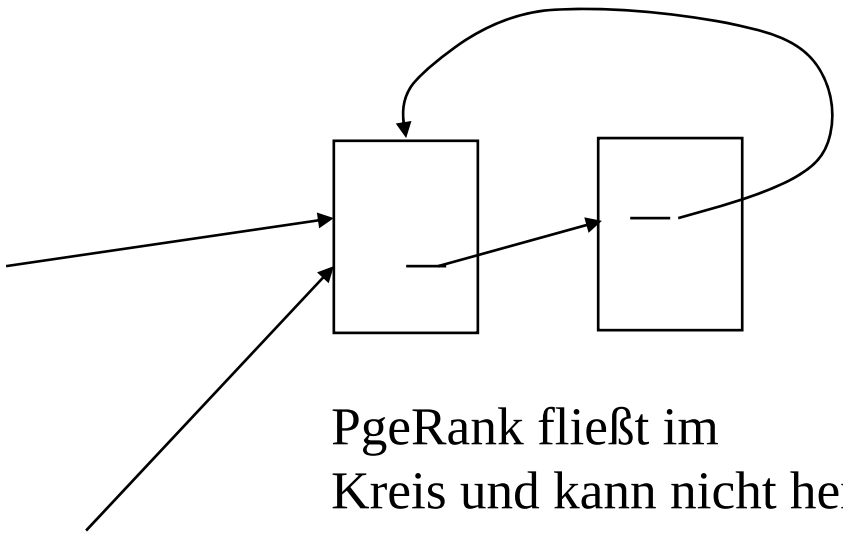

PgeRank fließt im
Kreis und kann nicht heraus

Gewichts-Quelle

- Führe eine Gewichts-Quelle E ein, die kontinuierlich den Rank jeder Seite p durch einen festen Betrag $E(p)$ ergänzt.

$$R(p) = \alpha \sum_{q:q \to p} \frac{R(q)}{N_q} + (1-\alpha)E(p)$$

PageRank-Algorithmus

Sei S die Gesamtmenge der Seiten.

Sei $\alpha \in (0,1)$, z.B. $\alpha = 0.85$.

Für alle $p \in S$: $E(p) := 1/|S|$

Für alle $p \in S$ initialisiere $R(p) := 1/|S|$.

Bis sich die Gewichte nicht mehr (viel) ändern (*Konvergenz*):

$$R(p) = \alpha \sum_{q:q \to p} \frac{R(q)}{N_q} + (1-\alpha)E(p)$$

Lineare Algebraversion

- Nach Konvergenz gilt $\boldsymbol{r} = \alpha\mathbf{A}\boldsymbol{r} + (1-\alpha)\mathbf{E}$.
- Wegen $\|\boldsymbol{r}\|_1 = 1$ gilt $\boldsymbol{r} = c(\alpha\mathbf{A} + (1-\alpha)\mathbf{E}\times\mathbf{1})\boldsymbol{r}$

  wobei **1** der Vektor ist, der nur aus 1ern besteht.
- Somit ist $\boldsymbol{r}$ ein Eigenvektor von $\alpha\mathbf{A} + (1-\alpha)\mathbf{E}\times\mathbf{1}$.

Random-Surfer-Modell

- PageRank kann als Modelierung eines “willkürlichen Surfers” betrachtet werden, der auf einer beliebigen Seite startet und dann entweder
  - mit der Wahrscheinlicheit $E(p)$ willkürlich auf die Seite p springt
  - oder willkürlich einem Link auf der aktuellen Seite folgt.

- $R(p)$ modelliert dann die Wahrscheinlichkeit, dass sich dieser willkürliche Surfer zu jeder gegebenen Zeit auf der Seite p befindet.

- Die “Sprünge” in **E** werden benötigt, um zu vermeiden, dass der willkürliche Surfer in Web-Senken “gefangen” wird, aus denen kein Link herausführt.

Konvergenz

- Frühe Experimente in Google verwendeten 322 Millionen Links.
- PageRank-Algorithmus konvergiert (mit einer kleinen Toleranz) in ca. 52 Wiederholungen.
- Die Anzahl der für Konvergenz erforderlichen Wiederholungen ist empirisch O(log *n*) (wobei *n* die Anzahl der Links ist).
- Daher ist die Berechnung ziemlich effizient.

Einfache Titelsuche mit PageRank

- Verwende zunächst die einfache Boolesche Suche, um Titel von Webseiten zu suchen und klassifiziere die gefundenen Seiten dann nach ihrem PageRank.
- Beispiel-Suche nach “Universität” (aus [Page, Brin 1998]):
  - Altavista gab eine beliebige Menge von Seiten mit “Universität” im Titel wieder (schien kurze URLs zu bevorzugen).
  - Primitives Google gab die Homepages der erstklassigen amerikanischenUniversitäten wieder.

Google-Suche

- Komplette Google-Suche umfasste vor der Kommerzialisierung (basierend auf wissenschaftlichen Veröffentlichungen):
  - Vektorraummodell
  - Abstandsmaß zu Schlüsselwörtern
  - HTML-Tag-Gewichtung (z.B. Titelpräferenz)
  - PageRank
- Details zu aktuellen Google-Komponenten sind Betriebsgeheimnisse.

HTML-Struktur & Merkmalgewichtung

- Gewichte ggf. Tokens unter bestimmten HTML- Tags stärker:
  - <TITLE> Token (Google scheint Titelüberein-stimmungen zu mögen)
  - <H1>,<H2>… Token
  - <META> Schlüsselwort-Token
- Zerlege eine Seite in verschiedene Abschnitte (z.B. Navigationsleiste und Seiteninhalt) und gewichte auf den unterschiedlichen Abschnitten basierende Token unterschiedlich.

Nachtrag zu Kap. 4 Modelle

Personalisierter PageRank

- PageRank kann durch Ändern von **E** beeinflusst (personalisiert) werden: Beschränken des "Random Surfers" auf eine Menge als relevant spezifizierter Seiten.
- Zum Beispiel durch Setzen von $E(p) := 0$, außer auf der eigenen Homepage, wo $E(p) := \alpha$
- Dies führt zu einer Ausrichtung auf Seiten, die im Webgraphen näher zu der eigenen Homepage sind.

PageRank-basiertes Spidering

- Verwende PageRank, um den Spider auf “wichtige” Seiten zu leiten (zu fokussieren).
- Berechne PageRank unter Verwendung der aktuellen Menge der bearbeiteten Seiten.
- Sortiere die Anfrage-Warteschlange des Spiders auf der Basis des aktuell geschätzten PageRanks.

Schlussfolgerungen zur Linkanalyse

- Die Linkanalyse verwendet als Suchhilfe Informationen über die Struktur des Webgraphen.
- Dies ist eine der wesentlichen Innovationen bei der Websuche
- ... und der primäre Grund für den Erfolg von Google.