HY463 - Συστήματα Ανάκτησης Πληροφοριών
Information Retrieval (IR) Systems

Web Searching II
Τεχνικές Ανάλυσης Συνδέσμων
(Link Analysis Techniques)

Γιάννης Τζίτζικας

Διάλεξη : 9
Ημερομηνία :

Διάθρωση

- Bibliometrics
  - citation analysis, impact factor, bibliographic coupling, co-citation, citations vs links
- Authorities and Hubs (HITS algorithm)
- PageRank
  - Personalized PageRank
- Other applications of Link Analysis
  - Crawling
  - Reverse Engineering

Ανάκτηση Πληροφοριών από τον Ιστό: **Προκλήσεις και Απαιτήσεις**

- Gathering techniques
- Scalable Index Structures efficiently updatable
- Improve the discrimination ability

Θα δούμε τεχνικές που συμβάλουν σε αυτό

Bibliometrics: **Citation Analysis**

- Πολλά έγγραφα περιλαμβάνουν **βιβλιογραφία**, δηλαδή **μνείες** (**αναφορές**) σε ήδη δημοσιευμένα άρθρα.
- Θεωρώντας τις μνείες ως συνδέσμους, μπορούμε να δούμε μια συλλογή εγγράφων ως έναν διευθυνόμενο γράφο.
- Η δομή αυτού του γράφου είναι ανεξάρτητη των περιεχομένων και από αυτόν μπορούμε να εξάγουμε συμπεράσματα για την ομοιότητα των εγγράφων και τη δομή του χώρου.

Impact Factor (Βαθμός Επιρροής)

- **Μέτρο σπουδαιότητας** (ποιότητας, επίδρασης) των επιστημονικών περιοδικών που προτάθηκε από τον Garfield το 1972.
- Μετρά πόσο συχνά τα άρθρα του περιοδικού αναφέρονται από άλλα (μεταγενέστερα) άρθρα
  - Υπολογίζεται και δημοσιεύεται ετησίως από το Institute for Scientific Information (ISI).

- Ο **βαθμός επιρροής** ενός περιοδικού J το έτος Y
  - είναι ο μέσος αριθμός των αναφορών σε άρθρα δημοσιευμένα στο περιοδικό J τα έτη Y-1 ή Y-2, από άρθρα δημοσιευμένα σε άλλα περιοδικά το έτος Y.
  - Δεν λαμβάνει υπόψη την «ποιότητα» των άρθρων που κάνουν τις αναφορές

Συμβολισμοί

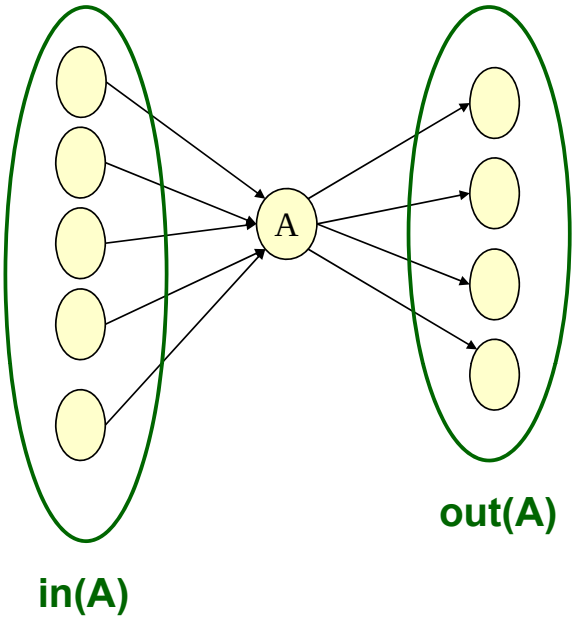

Bibliographic Coupling (Βιβλιογραφική Ζεύξη)

- **Μέτρο ομοιότητας** εγγράφων που προτάθηκε από τον Kessler το 1963
- Η **βιβλιογραφική ζεύξη** 2 εγγράφων A και B ισούται με το πλήθος των εγγράφων που αναφέρονται και από το A και από το B.
  - Το μέγεθος της τομής των βιβλιογραφιών τους
- Κανονικοποίηση βάσει του μεγέθους των βιβλιογραφιών

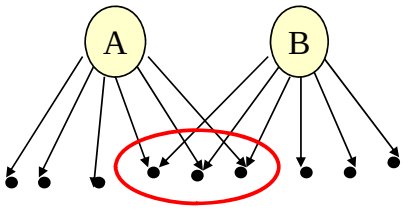

$$|out(A) \cap out(B)|$$

$$\frac{|out(A) \cap out(B)|}{|out(A) \cup out(B)|}$$

Co-Citation

- Ένα διαφορετικό **μέτρο ομοιότητας** που προτάθηκε από τον Small το 1973
- Ο **βαθμός co-citation** 2 εγγράφων A και B ισούται με το πλήθος των εγγράφων που αναφέρουν και το A και το B.
- Κανονικοποίηση βάσει του συνολικού αριθμού εγγράφων που αναφέρουν ή το A ή το B

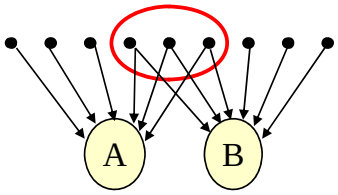

$$|in(A) \cap in(B)|$$

$$\frac{|in(A) \cap in(B)|}{|in(A) \cup in(B)|}$$

Μνείες vs. **Σύνδεσμοι** (Citations vs. Links)

Οι σύνδεσμοι του Ιστού είναι κάπως διαφορετικοί από τις αναφορές:

- Many links are navigational.
- Many pages with high in-degree are portals (not content providers).
- Not all links are endorsements.
- Company websites don't point to their competitors.
- Citations to relevant literature is enforced by peer-review.

Ο Γράφος του Ιστού

Θεωρούμε τον Ιστό ως έναν διευθυνόμενο γράφο G=(V,E)

- Διαγράφουμε τους κυκλικούς συνδέσμους (αυτοσυνδέσμους self-hyperlinks)
- Οι πολλαπλοί σύνδεσμοι (από μια σελίδα p σε μια q) καταπίπτουν σε έναν σύνδεσμο (p,q) in E

Authorities (Αυθεντίες)

- *Authorities* are pages that are recognized as providing significant, trustworthy, and useful information on a topic.

- A simple measure of authority could be **|in(p)|**
- However in-degree treats all links as equal (όπως στο βαθμό επιρροής).
- Should links from pages that are themselves authoritative count more?

Hubs (Κομβικά Σημεία)

- *Hubs* are index pages that provide lots of useful links to relevant content pages (topic authorities).
- Παραδείγματα Hub pages για ανάκτηση πληροφοριών:
  - http://trec.nist.gov/
  - http://www-a2k.is.tokushima-u.ac.jp/member/kita/NLP/IR.html
- A simple measure for identifying hubs could be **|out(p)|**

HITS (Hyperlink-Induced Topic Search)

- Αλγόριθμος που προτάθηκε από τον Kleinberg το 1998.
- Προσπαθεί να διακρίνει authorities και hubs για ένα συγκεκριμένο θέμα (topic), αναλύοντας το σχετικό υπογράφο του Ιστού.
- Βασίζεται στις εξής (αμοιβαίως οριζόμενες και αναδρομικές) προτάσεις:
  - **Hubs** point to lots of authorities.
  - **Authorities** are pointed to by lots of hubs.

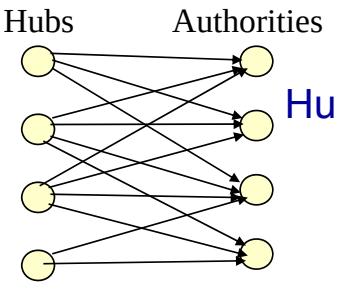

Hubs and Authorities tend to form a bipartite graph

- (nodes can be partitioned into 2 groups such that there are no links between the nodes of the same group):

Ο Αλγόριθμος HITS

- Εντοπίζει τα hubs και τα authorities για ένα συγκεκριμένο θέμα (topic) που προσδιορίζεται από μια **επερώτηση q**
- Κατ' αρχάς προσδιορίζεται το σύνολο *S* των σχετικών σελίδων με το q και αυτό ονομάζεται βάση (base set)
- Κατόπιν, αναλύει τη δομή των συνδέσμων στον υπογράφο του ιστού που ορίζεται από το *S*, και διακρίνει hubs και authorities.

Κατασκευή του Υπογράφου Βάσης (Base Subgraph)

- For a specific query *Q*, let the set of documents returned by a standard search engine be called the *root* set *R (i.e. R=Ans(Q))*.
- Initialize *S* to *R*.
- Add to *S* all pages pointed to by any page in *R*.
- Add to *S* all pages that point to any page in *R*.

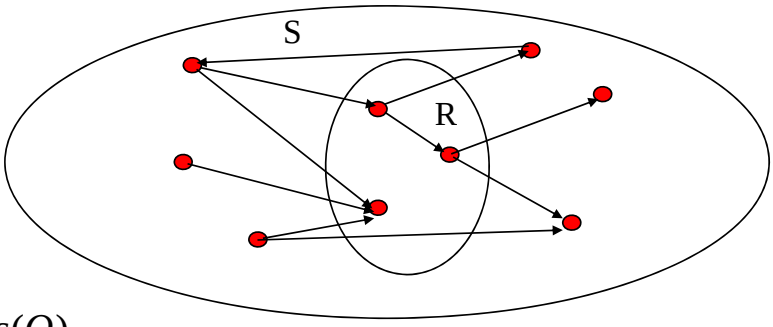

$$R = ans(Q)$$

$$S := R \cup \left(\cup \{out(p) \mid p \in R\}\right) \cup \left(\cup \{in(p) \mid p \in R\}\right)$$

Περιορίζοντας το μέγεθος της Βάσης

- To limit computational expense:
  - Limit number of root pages to the top 200 pages retrieved for the query.
  - Limit number of "back-pointer" pages to a random set of at most 50 pages returned by a "reverse link" query.
- To eliminate purely navigational links:
  - Eliminate links between two pages on the same host.
- To eliminate "non-authority-conveying" links:
  - Allow only *m* (*m* ≅ 4–8) pages from a given host as pointers to any individual page.

Authorities and In-Degree

- Even within the base set *S* for a given query, the nodes with highest in-degree are not necessarily authorities (may just be generally popular pages like Yahoo or Amazon).
- True authority pages are pointed to by a number of hubs (i.e. pages that point to lots of authorities).

HITS: **Επαναληπτικός αλγόριθμος**

- Use an **iterative** algorithm to slowly converge on a mutually reinforcing set of hubs and authorities.
- Maintain for each page $p \in S$:
  - Authority score: ***a(p)*** (vector ***a***)
  - Hub score: ***h(p)*** (vector ***h***)
- Initialize all $a(p)=h(p)=1$
- Maintain normalized scores:

$$\sum_{p \in S} a(p)^2 = 1 \qquad \sum_{p \in S} h(p)^2 = 1$$

HITS: **Κανόνες Ενημέρωσης** (Update Rules)

- Authorities are pointed to by lots of good hubs:

$$a(p) = \sum_{q \in in(p)} h(q)$$

- Hubs point to lots of good authorities:

$$h(p) = \sum_{q \in out(p)} a(q)$$

Παράδειγμα Κανόνων Ενημέρωσης

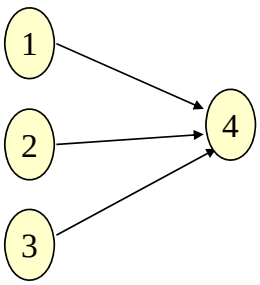

a(4) = h(1) + h(2) + h(3)

h(4) = a(5) + a(6) + a(7)

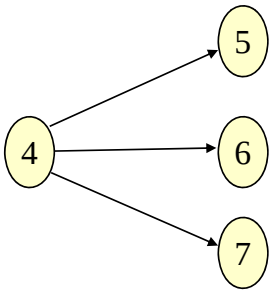

HITS: Επαναληπτικός Αλγόριθμος

Initialize for all $p \in S$: $a(p)=h(p) = 1$

For i = 1 to k:

For all $p \in S$: (*update auth. scores*)

$$a(p) = \sum_{q \in in(p)} h(q)$$

For all $p \in S$: (*update hub scores*)

$$h(p) = \sum_{q \in out(p)} a(q)$$

For all $p \in S$:

$a(p)=a(p)/c$ $\quad c = \sum_{p \in S} a(p)^2$ (*normalize* $\mathbf{a}$)

For all $p \in S$:

$h(p)= h(p)/c$ $\quad c:$ $\quad c = \sum_{p \in S} h(p)^2$ (*normalize* $\mathbf{h}$)

HITS: Σύγκλιση

- Με άπειρες επαναλήψεις ο αλγόριθμος συγκλίνει σε ένα σταθερό σημείο (*fix-point*).
- Define A to be the adjacency matrix for the subgraph defined by S.
  - A_{ij} = 1 for $i \in$ S, $j \in$ S iff $i \rightarrow j$
- Authority vector, $\boldsymbol{a}$, converges to the principal eigenvector of A^TA
- Hub vector, $\boldsymbol{h}$, converges to the principal eigenvector of AA^T
- Στην πράξη, 20 επαναλήψεις συνήθως επαρκούν.

HITS: Αποτελέσματα

- Authorities for query: "Java"
  - java.sun.com
  - comp.lang.java FAQ
- Authorities for query "search engine"
  - Yahoo.com
  - Excite.com
  - Lycos.com
  - Altavista.com
- Authorities for query "Gates"
  - Microsoft.com
  - roadahead.com

- Σχόλια
  - In most cases, the final authorities were not in the initial root set generated using Altavista.
  - Authorities were brought in from linked and reverse-linked pages and then HITS computed their high authority score.

Εύρεση παρόμοιων σελίδων αξιοποιώντας τη δομή συνδέσμων

- Given a page p, let *R* (the root set) be k (e.g. 200) pages that point to p *(≈ R=in(p))*
- Grow a base set *S* from *R*.
- Run HITS on *S*.
- Return the best authorities in *S* as the best similar-pages for p.
  - θυμηθείτε το co-citation
- Finds authorities in the "link neighbor-hood" of p.

- Αποτελέσματα για "honda.com"
  - toyota.com
  - ford.com
  - bmwusa.com
  - saturncars.com
  - nissanmotors.com
  - audi.com
  - volvocars.com

PageRank

- Μια διαφορετική τεχνική ανάλυσης συνδέσμων που χρησιμοποιείται από το Google (Brin & Page, 1998).

- Δεν κάνει διάκριση μεταξύ αυθεντιών και κομβικών σημείων
- Διατάσσει τις σελίδες βάσει κύρους (authority).

- Εφαρμόζεται σε όλες τις σελίδες του ιστού (δεν περιορίζεται στη γειτονιά των σελίδων της απάντησης μιας επερώτησης)

PageRank: Η αρχική έκδοση

- Η απλή καταμέτρηση των εισερχόμενων συνδέσμων (δηλαδή ο in-degree ή αλλιώς citation count) δεν λαμβάνει υπόψη το κύρος των σελίδων από τις οποίες εκκινούν οι εισερχόμενοι σύνδεσμοι.
- Αρχικός βαθμός (page rank) για μια σελίδα *p*:

$$R(p) = c \sum_{q \in in(p)} \frac{R(q)}{|out(q)|}$$

- Μια σελίδα q «δίδει ίσο ποσοστό τους κύρους της» στις σελίδες που δείχνει.
- Το c είναι μια σταθερά για κανονικοποίηση (ώστε το άθροισμα των βαθμών των σελίδων να ισούται με 1)

PageRank: Η αρχική έκδοση (II)

- Μπορούμε να εκλάβουμε τη βαθμολόγηση ως μια διαδικασία ροής «κύρους».
- Η ροή γίνεται μέσω των συνδέσμων (και έχει την ίδια κατεύθυνση με αυτούς)

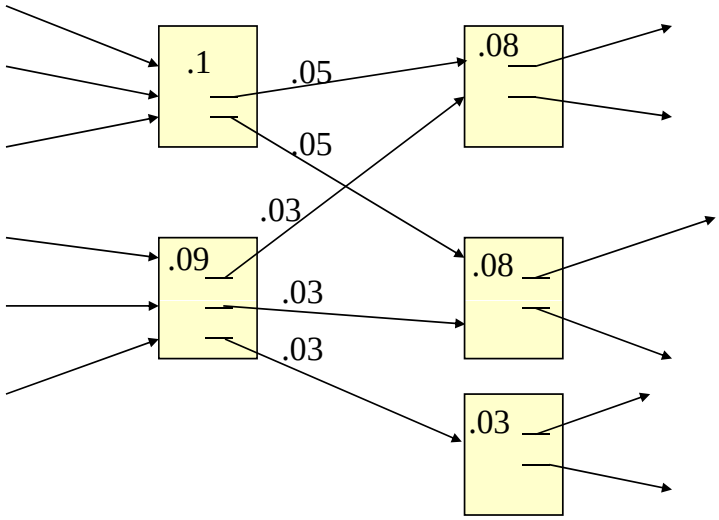

PageRank: Ο Αρχικός Αλγόριθμος

- Επανάληψη της διαδικασίας ροής μέχρι να έχουμε σύγκλιση:

Let *S* be the total set of pages.
Initialize $\forall p \in S$: $R(p) = 1/|S|$
Until ranks do not change (much) (*convergence*)
For each $p \in S$:

$$R'(p) = \sum_{q \in in(p)} \frac{R(q)}{|out(q)|}$$

For each $p \in S$: $R(p) = R'(p)/c$ (*normalize*)

$$c = \sum_{p \in S} R'(p)$$

Παράδειγμα Σημείου Σταθεροποίησης (Fixpoint)

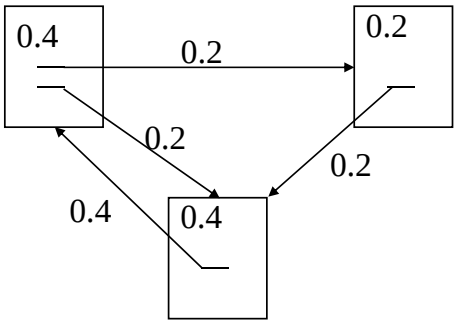

Παράδειγμα Επαναλήψεων

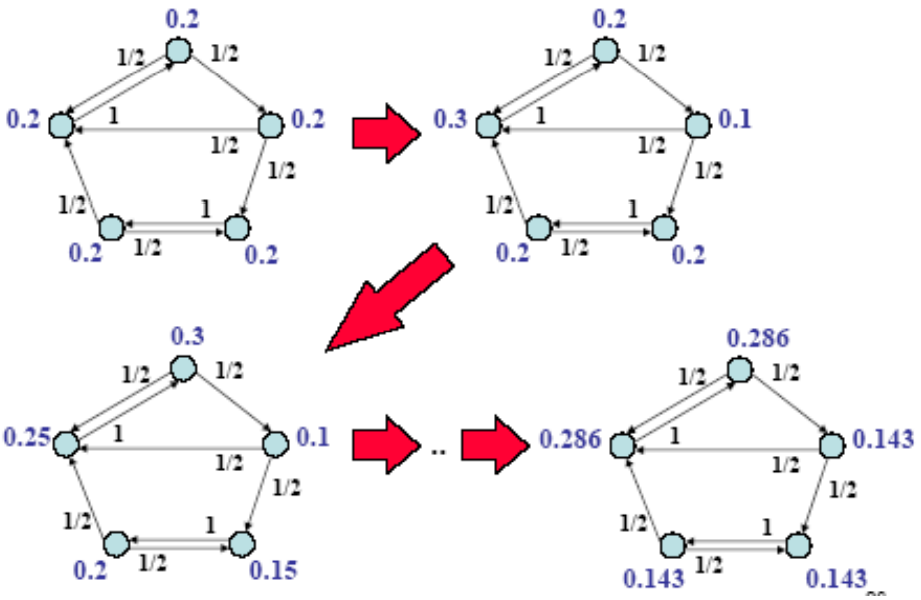

Random Surfer Model
(Μοντέλο Τυχαίου Περιηγητή)

- Ο PageRank μπορεί να θεωρηθεί οτι μοντελοποιεί έναν «τυχαίο περιηγητή» (random surfer) ο οποίος
  - ξεκινάει από μια τυχαία επιλεγμένη σελίδα και κατόπιν
  - **τυχαία επιλέγει και ακολουθεί έναν σύνδεσμο από την τρέχουσα σελίδα, κ.ο.κ**
- *Το R(p)* εκφράζει την πιθανότητα να βρίσκεται ο τυχαίος περιηγητής στη σελίδα p μια δεδομένη στιγμή

Οι αδυναμίες της αρχικής έκδοσης:
Rank Sinks and Rank Leaks

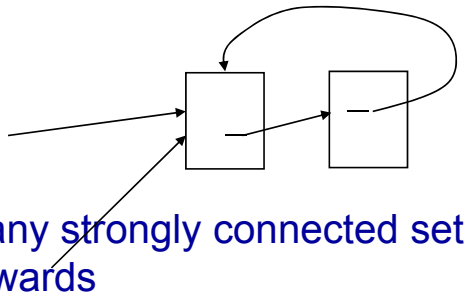

- **Rank sink (καταβόθρα βαθμών)**: any strongly connected set of k pages from which no links point outwards
  - problem: nodes not in the sink receive 0 rank
    - a random surfer would enclave for ever within the sink
- **Rank leak (διαρροή)**: any individual page with no outgoing link
  - any rank reaching a rank leak is lost forever
    - will cause all the ranks to eventually converge to 0
- Rank leak is a special case of Rank sink (for k=1)

Rank Leak: Παράδειγμα

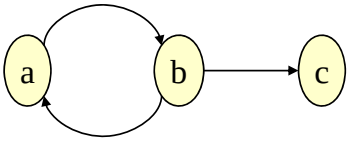

a	b	c
0.3	0.3	0.3
0.15	0.3	0.15
0.15	0.15	0.15
0.075	0.15	0.075
0.075	0.075	0.075
0.0375	0.075	0.0375
0.0375	0.0375	0.0375
0.01875	0.0375	0.01875
0.01875	0.01875	0.01875
0.009375	0.01875	0.009375
0.009375	0.009375	0.009375
0.004688	0.009375	0.004688
0.004688	0.004688	0.004688
0.002344	0.004688	0.002344
0.002344	0.002344	0.002344
0.001172	0.002344	0.001172
0.001172	0.001172	0.001172
0.000586	0.001172	0.000586
0.000586	0.000586	0.000586
0.000293	0.000586	0.000293

Τρόποι Αντιμετώπισης

- Leak nodes:
  - Μια σκέψη θα ήταν να απαλείψουμε όλους τους leak nodes (those with out-degree 0)
  - Μια άλλη λύση θα ήταν να θεωρήσουμε ότι κάθε leak node έχει ένα σύνδεσμο προς κάθε άλλη σελίδα
- Sink nodes
  - …. «τηλεμεταφορά» (“teleporting”)

$$R(p) = c\left(\sum_{q \in in(p)} \frac{R(q)}{|out(q)|} + E(p)\right)$$

Αναθεωρώντας το Μοντέλου του Τυχαίου Περιηγητή

- Ο PageRank μπορεί να θεωρηθεί οτι μοντελοποιεί έναν «τυχαίο περιηγητή» (random surfer) ο οποίος
  - ξεκινάει από μια τυχαία επιλεγμένη σελίδα και κατόπιν
  - **με πιθανότητα E(p) κάνει ένα άλμα σε μια τυχαία σελίδα,**
  - **αλλιώς (με πιθανότητα 1-E(p)) επιλέγει και ακολουθεί έναν σύνδεσμο από την τρέχουσα σελίδα, κ.ο.κ**
- *Το R(p)* εκφράζει την πιθανότητα να βρίσκεται ο τυχαίος περιηγητής στη σελίδα p μια δεδομένη στιγμή
- Σημείωση: Τα τυχαία άλματα αποτρέπουν την «παγίδευση» του περιηγητή σε καταβόθρες ή σε σελίδες που δεν έχουν εξερχόμενους συνδέσμους

Ο αλγόριθμος PageRank

Let S be the total set of pages.

Let $\forall p \in S: E(p) = \alpha/|S|$ (for some $0<\alpha<1$, e.g. 0.15)

Initialize $\forall p \in S: R(p) = 1/|S|$

Until ranks do not change (much) (*convergence*)

For each $p \in S$:

$$R'(p) = \sum_{q \in in(p)} \frac{R(q)}{|out(q)|} + E(p)$$

For each $p \in S$: $R(p) = R'(p)/c$ (*normalize*)

$$c = \sum_{p \in S} R'(p)$$

PageRank: Διατύπωση με Γραμμική Αλγεβρα

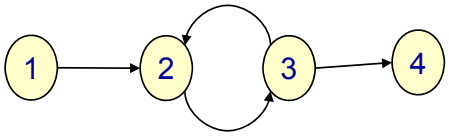

Adjacency matrix M

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

Transition matrix T

$$T(p,q) = \begin{cases} 0 & if\ (q,p) \notin M \\ 1/|out(q)| & if\ (q,p) \in M \end{cases}$$

$$T = \begin{pmatrix} 0 & 0 & 0 & 0 \\ 1 & 0 & 1/2 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1/2 & 0 \end{pmatrix}$$

- The PageRank score R(p) of a page is defined as

$$R(p) = a \cdot \sum_{q \in in(p)} \frac{R(q)}{|out(q)|} + (1-a)\frac{1}{N}$$

- The equivalent matrix equation:

$$R = a \cdot T \cdot R + (1-a)\frac{1}{N}1_N$$

PageRank: Διατύπωση με Γραμμική Αλγεβρα

$$R = a \cdot T \cdot R + (1-a)\frac{1}{N}1_N$$

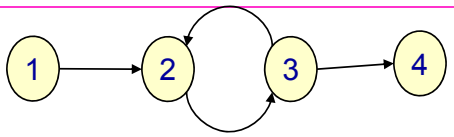

$$\begin{bmatrix} r1 \\ r2 \\ r3 \\ r4 \end{bmatrix} = a \cdot \begin{bmatrix} 0 & 0 & 0 & 0 \\ 1 & 0 & 1/2 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1/2 & 0 \end{bmatrix} \cdot \begin{bmatrix} r1 \\ r2 \\ r3 \\ r4 \end{bmatrix} + (1-a)\frac{1}{4}\begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \end{bmatrix}$$

$$\begin{bmatrix} r1 \\ r2 \\ r3 \\ r4 \end{bmatrix} = a \cdot \begin{bmatrix} 0 \\ r1 + r3/2 \\ r2 \\ r3/2 \end{bmatrix} + (1-a)\frac{1}{4}\begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \end{bmatrix} \qquad \begin{bmatrix} r1 \\ r2 \\ r3 \\ r4 \end{bmatrix} = \begin{bmatrix} (1-a)/4 \\ a(r1 + r3/2) + (1-a)/4 \\ ar2 + (1-a)/4 \\ ar3/2 + (1-a)/4 \end{bmatrix}$$

Ο Αλγόριθμος PageRank

function **PageRank**
Input T: transition matrix, N: number of pages,
a_b: decay factor for PageRank, M_b: number of iterations
output **R*** : PageRank scores

(1) **d** =1/N * $\mathbf{1}_N$ // initial score for all pages is 1/N
(2) **R*** = **d**
(3) for i=1 to M_b do // evaluates PageRank scores
R* = a_b T **R*** + (1 - a_b) **d**
return **R***

PageRank: **Ταχύτητα σύγκλισης**
(Speed of Convergence)

- Early experiments on Google used 322 million links.
- PageRank algorithm converged (within small tolerance) in about 52 iterations.
- Number of iterations required for convergence is empirically O(log *n*) (where *n* is the number of links).
- Therefore calculation is quite efficient.

Personalized PageRank (Εξατομικευμένος PageRank)

- Μπορούμε να εξατομικεύσουμε / προκαταβάλουμε το PageRank, τροποποιώντας κατάλληλα το **E**
  - (ώστε να μην περιγράφει μια ομοιόμορφη κατανομή)

- Για παράδειγμα, με τον τρόπο αυτό μπορούμε να περιορίσουμε τα «τυχαία άλματα» σε ένα συγκεκριμένο σύνολο σελίδων

Παράδειγμα:
Αν p=www.csd.uoc.gr/~hy463 τότε E(p)=α αλλιώς E(p)=0
// ευνοεί τις ιστοσελίδες που είναι κοντά (στο γράφο) στην ιστοσελίδα
// του μαθήματος HY463

Simple Title Search with PageRank (Google Ranking)

- Use simple Boolean search to search web-page titles and rank the retrieved pages by their PageRank.
- Sample search for “university”:
  - Altavista returned a random set of pages with “university” in the title (seemed to prefer short URLs).
  - Primitive Google returned the home pages of top universities.
- Complete Google ranking includes (based on university publications prior to commercialization).
  - Vector-space similarity component.
  - Keyword proximity component.
  - HTML-tag weight component (e.g. title preference).
  - PageRank component.
- Details of current commercial ranking functions are trade secrets

Ανάλυση Συνδέσμων: Συμπεράσματα

- Η Ανάλυση συνδέσμων αξιοποιεί τη δομή του γράφου του Ιστού προκειμένου να βοηθήσει την ανάκτηση πληροφοριών
- Είναι ίσως η μεγαλύτερη καινοτομία στην αναζήτηση στον Ιστό
- Ο βασικό ατού της επιτυχίας του Google.

Άλλες Εφαρμογές του PageRank: **Crawling/Spidering**

- Αξιοποίηση του PageRank για εστίαση της διάσχισης στις «σημαντικές σελίδες»

Τρόπος

- Υπολογισμός του PageRank βάσει των σελίδων που έχουν ήδη συλλεχθεί
- Ταξινόμηση των σελίδων στην ουρά του crawler βάσει του εκτιμούμενου PageRank.

Ανάλυση Συνδέσμων: Άλλες εφαρμογές

- **Αναγνώριση κοινοτήτων** (communities)
  - Έχει παρατηρηθεί ότι κάθε κοινότητα χαρακτηρίζεται από ένα σύνολο authority και hub σελίδων
- **Αναγνώριση σελίδων "spam"** *(θα παρουσιαστεί στην επόμενη διάλεξη)*
  - Web-spam page identification
- **Κατανόηση και Οπτικοποίηση μεγάλων Εννοιολογικών Σχημάτων**
- **Node Reputability in P2P Networks**
- ...
- και πολλές άλλες εφαρμογές

SALSA (Stochastic Approach for Link-Structured Analysis)

- Ο αλγόριθμος SALSA, όπως συμβαίνει και με τον HITS, διατάσει τις σελίδες μια απάντησης βάσει των υπερσυνδέσμων και στην διάκριση authority και hub σελίδων.
- Η διαφοροποίηση του από το HITS εντοπίζεται στα εξής :

- καταφέρνει να αναγνωρίσει και να ανιχνεύσει περισσότερες σελίδες ως authorities, σε θεματικές ομάδες εγγράφων όπου το HITS αδυνατεί.
- θεωρεί λιγότερο στενή τη σχέση ανάμεσα στις authority και hub σελίδες