MYE003: Ανάκτηση Πληροφορίας

Διδάσκουσα: Ευαγγελία Πιτουρά

Κεφάλαιο 21: Ανάλυση Συνδέσμων.

Ακαδημαϊκό Έτος 2022-2023

Τι θα δούμε σήμερα

Πως μπορούμε να χρησιμοποιήσουμε το δίκτυο στη διάταξη των αποτελεσμάτων

Δεν είναι όλες οι σελίδες (κόμβοι) ίσες. Ποιες σελίδες είναι «σημαντικές»?

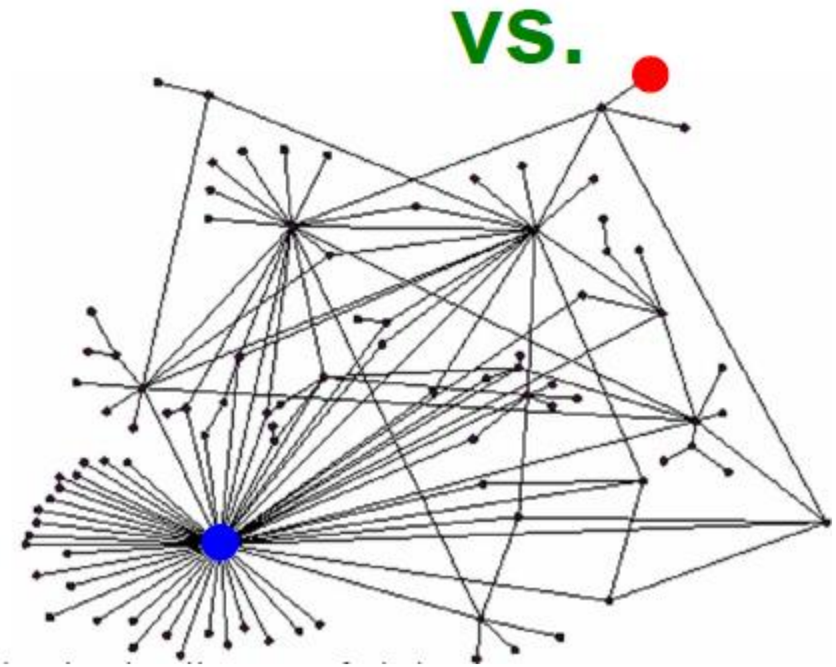

Τι θα δούμε σήμερα

Ανάλυση συνδέσμων (link analysis)

- PageRank

Υπολογισμός μιας τιμής ανά σελίδα (κόμβο) που εκφράζει το πόσο σημαντική είναι στο δίκτυο

Διάταξη με βάση τη δημοτικότητα

Διάταξη των σελίδων με βάσει τον αριθμό των εισερχόμενων ακμών (in-degree, degree centrality)

Αρκεί η δημοτικότητα;

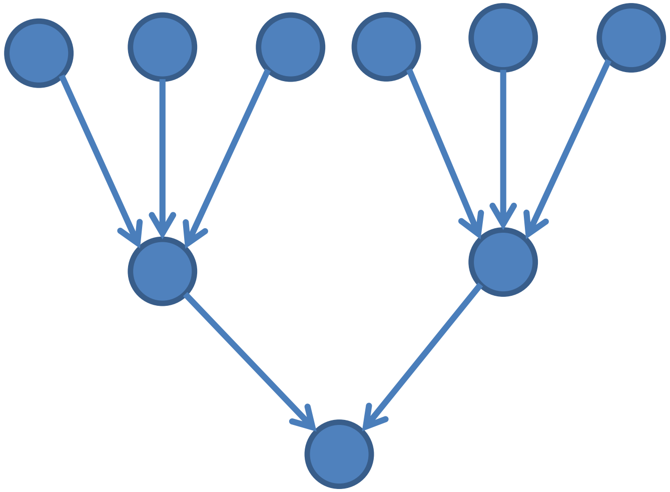

- Δεν είναι σημαντικό *πόσοι κόμβοι* δείχνουν σε μια σελίδα αλλά το *πόσο σημαντικοί* είναι αυτοί οι κόμβοι

PageRank

PageRank

- Βασική ιδέα: Μια σελίδα είναι σημαντική αν δείχνουν σε αυτήν σημαντικές σελίδες
- Η αξία (PageRank) ενός κόμβου είναι το άθροισμα της αξίας των φίλων του

PageRank: Βασική ιδέα

Έχουμε μια «μονάδα κύρους» που τη λέμε PageRank και την μοιράζουμε στις σελίδες.

Κάθε σελίδα έχει μια τιμή PageRank

- Κάθε σελίδα *μοιράζει το PageRank της στις σελίδες που δείχνει*
- Το PageRank μιας σελίδας είναι το *άθροισμα των PageRank των σελίδων που δείχνουν σε αυτήν*

PageRank: Ορισμός

$$PageRank(v) = \sum_{u \in InNeigbors(v)} \frac{PageRank(u)}{outdegree(u)}$$

παράδειγμα

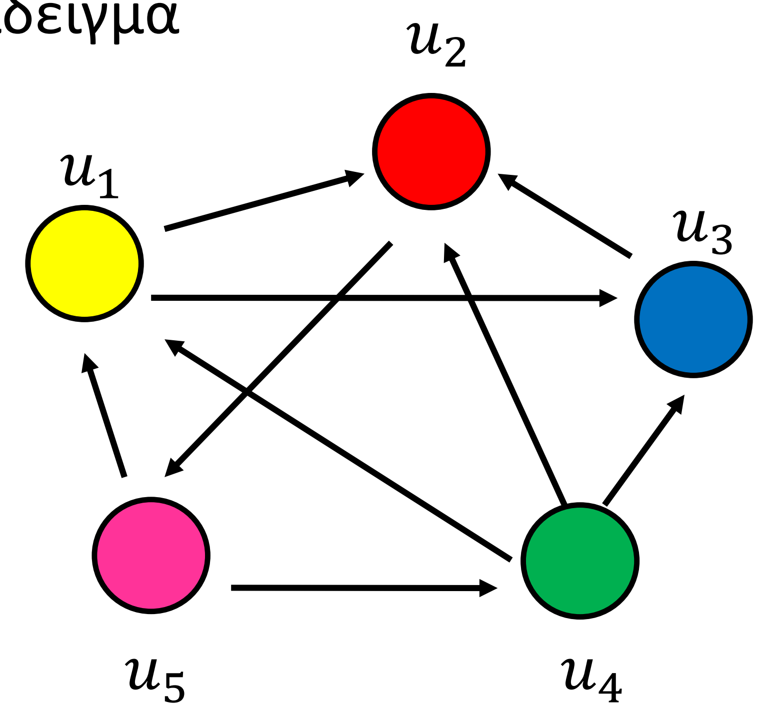

PageRank: παράδειγμα

$r(u_1) = 1/3\ r(u_4) + 1/2\ r(u_5)$

$r(u_2) = 1/2\ r(u_1) + r(u_3) + 1/3\ r(u_4)$

$r(u_3) = 1/2\ r(u_1) + 1/3\ r(u_4)$

$r(u_4) = 1/2\ r(u_5)$

$r(u_5) = r(u_2)$

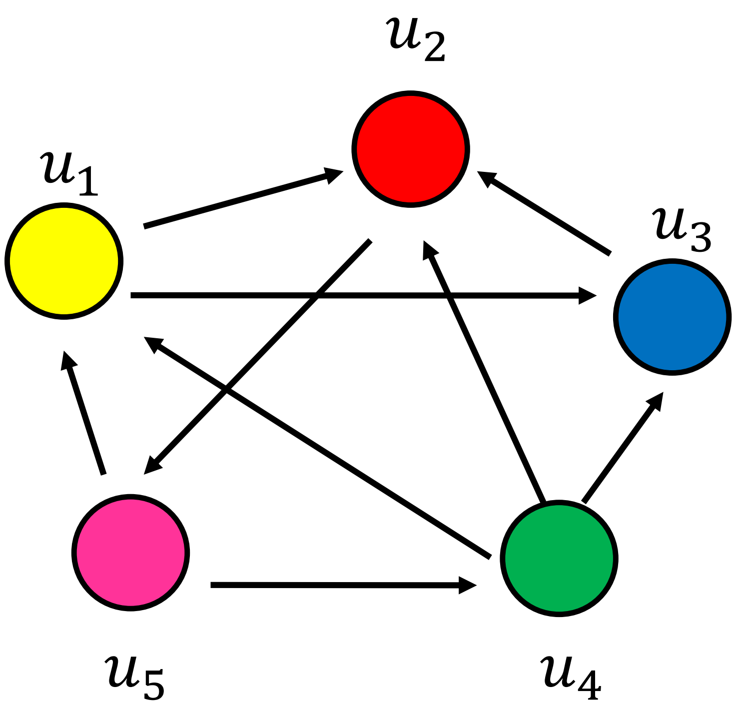

$r(u_1) + r(u_2) + r(u_3) + r(u_4) + r(u_5) = 1$

r(u): PageRank(u)

Ένα απλό παράδειγμα: υπολογισμός

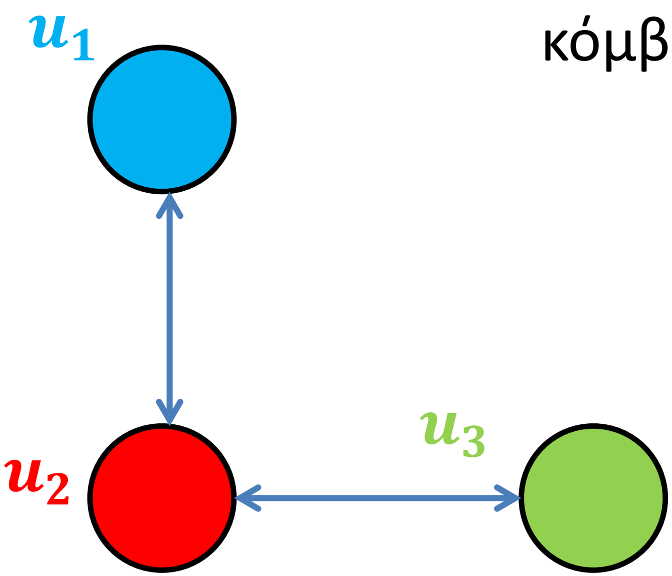

Το συνολικό PageRank μοιράζεται στους 3 κόμβους

$$r(u_2) + r(u_2) + r(u_2) = 1$$

$$r(u_1) = \frac{1}{2} r(u_2)$$
$$r(u_2) = r(u_1) + r(u_3)$$
$$r(u_3) = \frac{1}{2} r(u_2)$$

- Λύνοντας το σύστημα εξισώσεων παίρνουμε το PageRank των κόμβων

$$r(u_2) = \frac{1}{2} \quad r(u_1) = \frac{1}{4} \quad r(u_3) = \frac{1}{4}$$

PageRank: επαναληπτικός αλγόριθμος

Επαναληπτικός υπολογισμός (power iteration method)

Initialize $r^0(v) \leftarrow \frac{1}{n}$

t = 1

repeat

$r^t(v) \leftarrow \sum_{u \rightarrow v} \frac{r^{t-1}(u)}{outdegree(u)}$

t = t + 1

until convergence

Υπολογισμός: Παράδειγμα

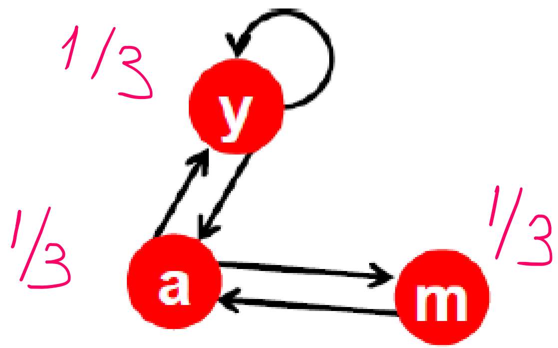

$$r_y = r_y/2 + r_a/2$$
$$r_a = r_y/2 + r_m$$
$$r_m = r_a/2$$

στην πρώτη επανάληψη

$$r_y^1 = \frac{1}{2}\cdot\frac{1}{3} + \frac{1}{2}\cdot\frac{1}{3} = \frac{1}{3}$$

$$r_a^1 = \frac{1}{2}\cdot\frac{1}{3} + \frac{1}{2} = 3/6$$

$$r_m^1 = \frac{1}{3}\cdot\frac{1}{2} = 1/6$$

y	1/3	1/3	5/12	
a	1/3	1/2	1/3	. . .
m	1/3	1/6	1/4	

στη 2η επανάληψη

$$r^2_y = \frac{1}{2}\cdot\frac{1}{3} + 1/2 \cdot 1/2 = 5/12$$

$$r^2_a = \frac{1}{2}\cdot 1/3 + 1/6 = 1/3$$

$$r_m^2 = 1/2 \cdot 1/2 = 1/4$$

Υπολογισμός: Παράδειγμα

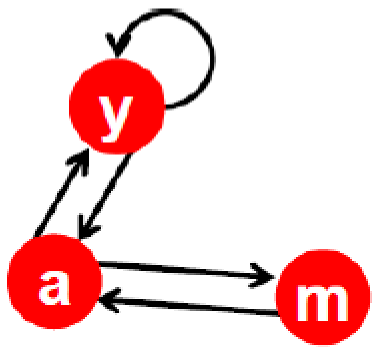

$$r_y = r_y/2 + r_a/2$$
$$r_a = r_y/2 + r_m$$
$$r_m = r_a/2$$

$$\begin{bmatrix} r_y \\ r_a \\ r_m \end{bmatrix} = \begin{matrix} 1/3 & 1/3 & 5/12 & 9/24 & & 6/15 \\ 1/3 & 3/6 & 1/3 & 11/24 & \ldots & 6/15 \\ 1/3 & 1/6 & 3/12 & 1/6 & & 3/15 \end{matrix}$$

Ένα μεγαλύτερο παράδειγμα

Αρχικά όλοι οι κόμβοι PageRank 1/8

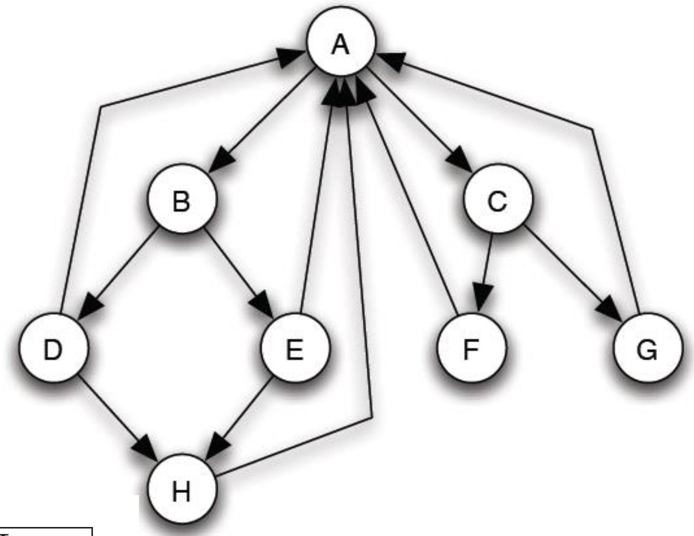

Step	A	B	C	D	E	F	G	H
1	1/2	1/16	1/16	1/16	1/16	1/16	1/16	1/8
2	3/16	1/4	1/4	1/32	1/32	1/32	1/32	1/16

- Ένα είδος ροής ("fluid") που κινείται στο δίκτυο
- Το συνολικό PageRank στο δίκτυο παραμένει σταθερό (δε χρειάζεται κανονικοποίηση)

Ισορροπία

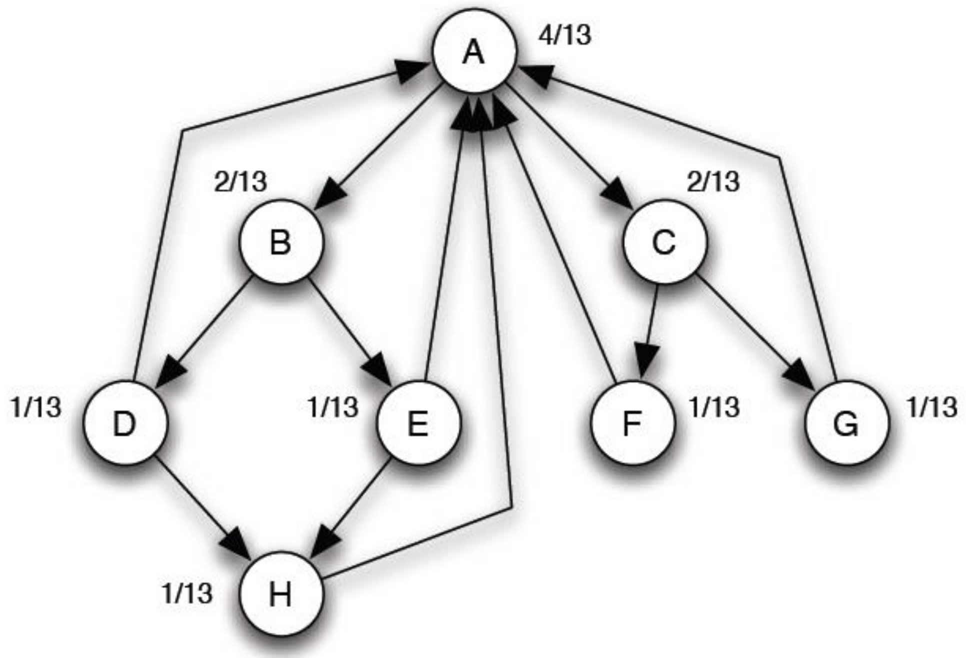

- Ένας απλός τρόπος να ελέγξουμε αν το σύνολο PageRank τιμών αντιστοιχεί σε ισορροπία: οι τιμές αθροίζουν σε 1 και δεν αλλάζουν αν εφαρμόσουμε τον κανόνα ενημέρωσης

PageRank: Διανυσματική αναπαράσταση

Stochastic Adjacency Matrix – (Στοχαστικός) Πίνακας Γειτνίασης *M*

Πίνακας M – πίνακας γειτνίασης του web

Αν j -> i, τότε M_{ij} = 1/outdegree(j)

Αλλιώς, M_{ij} = 0

Page Rank Vector *r*

Ένα διάνυσμα με μία τιμή για κάθε σελίδα (το PageRank της σελίδας)

$$\sum r_i = 1$$

PageRank: Διανυσματική αναπαράσταση

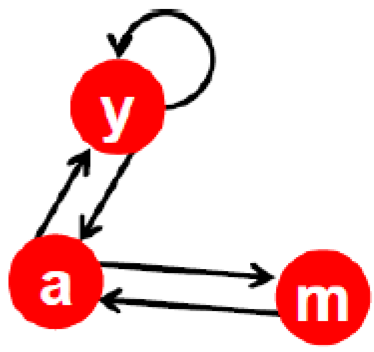

	y	a	m
y	½	½	0
a	½	0	1
m	0	½	0

Column stochastic: οι τιμές στις στήλες αθροίζουν στο 1

$$\begin{bmatrix} r_y \\ r_a \\ r_m \end{bmatrix} \qquad \boldsymbol{r} = \boldsymbol{M} \cdot \boldsymbol{r}$$

ιδιοδιάνυσμα, με ιδιοτιμή 1

Ισοδύναμα, r^T 1 x n vector (αριστερό ιδιοδιάνυσμα)

row stochastic adjacency matrix

$r^T = r^T\ M^T$

PageRank: παράδειγμα

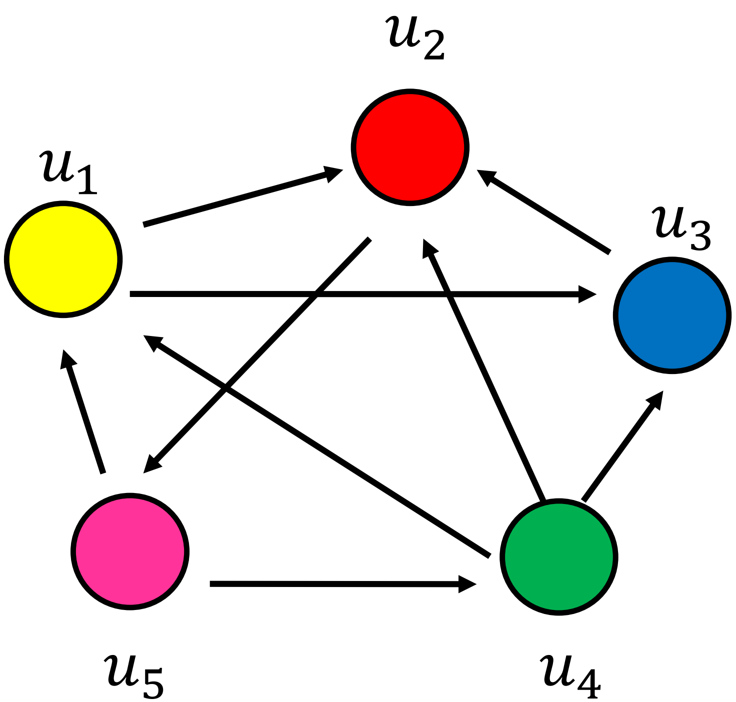

$$A^T = \begin{bmatrix} 0 & 0 & 0 & 1 & 1 \\ 1 & 0 & 1 & 1 & 0 \\ 1 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \\ 0 & 1 & 0 & 0 & 0 \end{bmatrix}$$

$$\mathrm{M} = \begin{bmatrix} 0 & 0 & 0 & 1/3 & 1/2 \\ 1/2 & 0 & 1 & 1/3 & 0 \\ 1/2 & 0 & 0 & 1/3 & 0 \\ 0 & 0 & 0 & 0 & 1/2 \\ 0 & 1 & 0 & 0 & 0 \end{bmatrix} \qquad \begin{bmatrix} r(u_1) \\ r(u_2) \\ r(u_3) \\ r(u_4) \\ r(u_5) \end{bmatrix}$$

$r(u_1) = 1/3\ r(u_4) + 1/2\ r(u_5)$

$r(u_2) = 1/2\ r(u_1) + r(u_3) + 1/3\ r(u_4)$

$r(u_3) = 1/2\ r(u_1) + 1/3\ r(u_4)$

$r(u_4) = 1/2\ r(u_5)$

$r(u_5) = r(u_2)$

PageRank: Διανυσματική αναπαράσταση

$$r_j^{(t+1)} = \sum_{i \to j} \frac{r_i^{(t)}}{\mathrm{d}_\mathrm{i}}$$

$$r = Mr$$

- Ποια είναι η φυσική σημασία;
- Συγκλίνει ο επαναληπτικός αλγόριθμος;

Τυχαίος Περίπατος (Random Walks)

Ο αλγόριθμος προσομοιώνει ένα τυχαίο περίπατο (random walk) στο γράφο

Τυχαίος περίπατος:

- Ξεκίνα από κάποιον τυχαίο κόμβο (επιλεγμένο uniformly at random) με πιθανότητα 1/n
- Επέλεξε τυχαία (uniformly at random) μια από τις εξερχόμενες ακμές του κόμβου
- Ακολούθησε την ακμή
- Επανέλαβε

Παράδειγμα

- Step 0

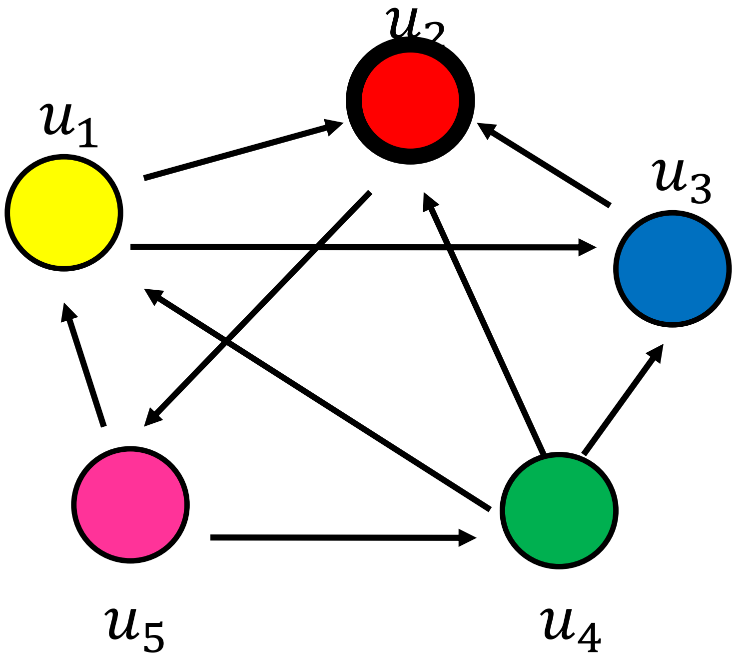

Παράδειγμα

- Step 0

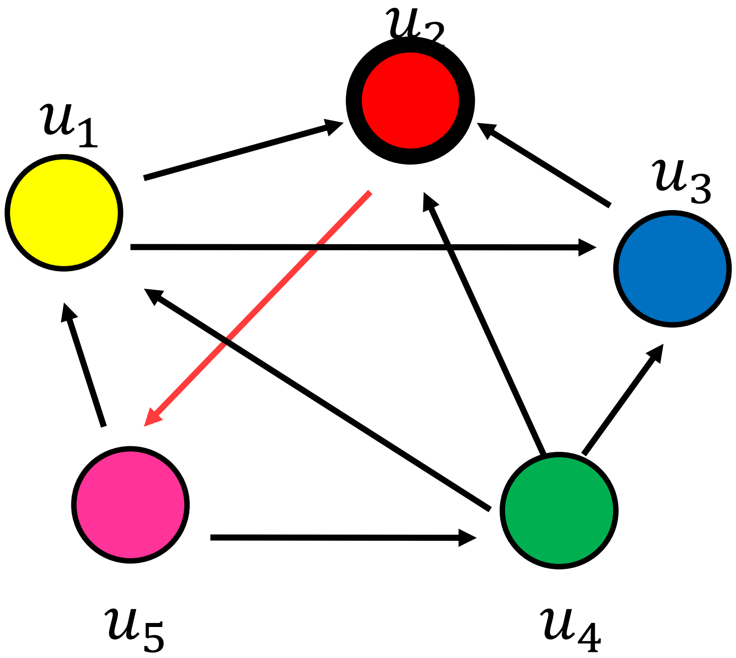

Παράδειγμα

- Step 1

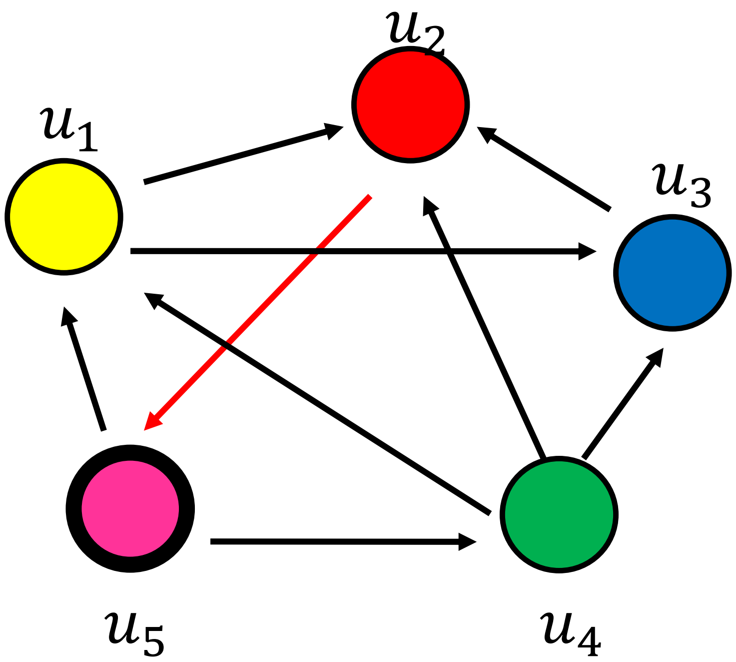

Παράδειγμα

- Step 1

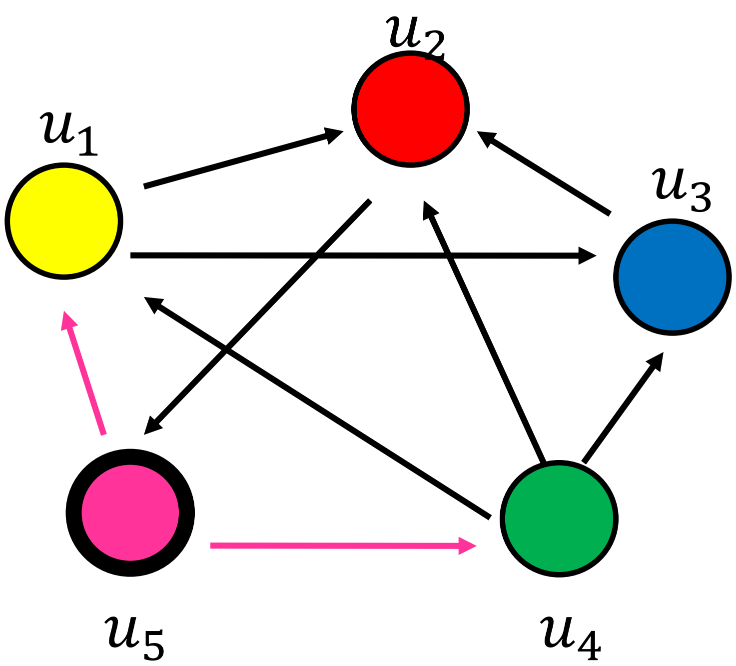

Παράδειγμα

- Step 2

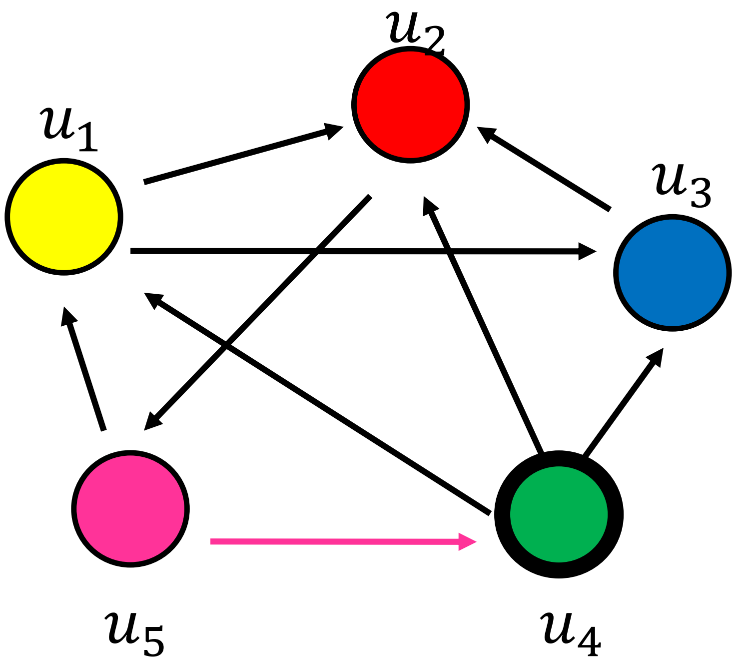

Παράδειγμα

- Step 2

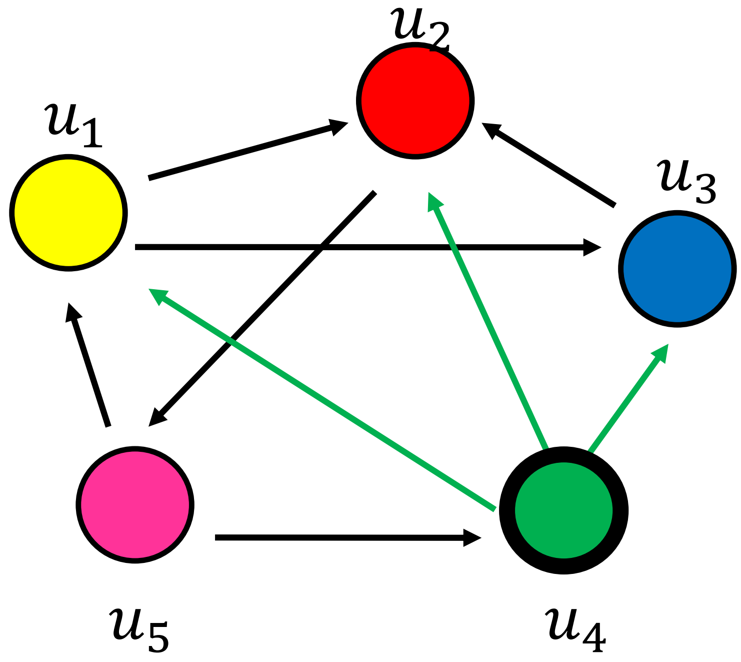

Παράδειγμα

- Step 3

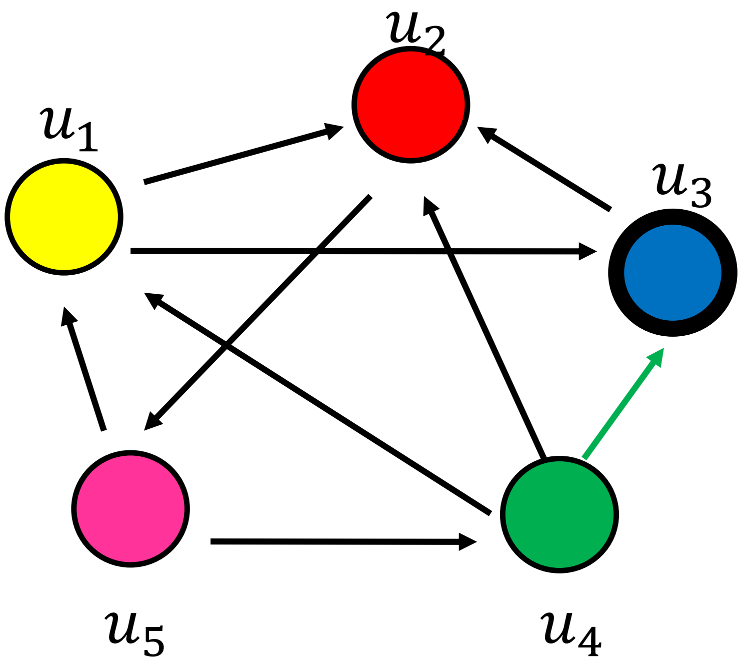

Παράδειγμα

- Step 3

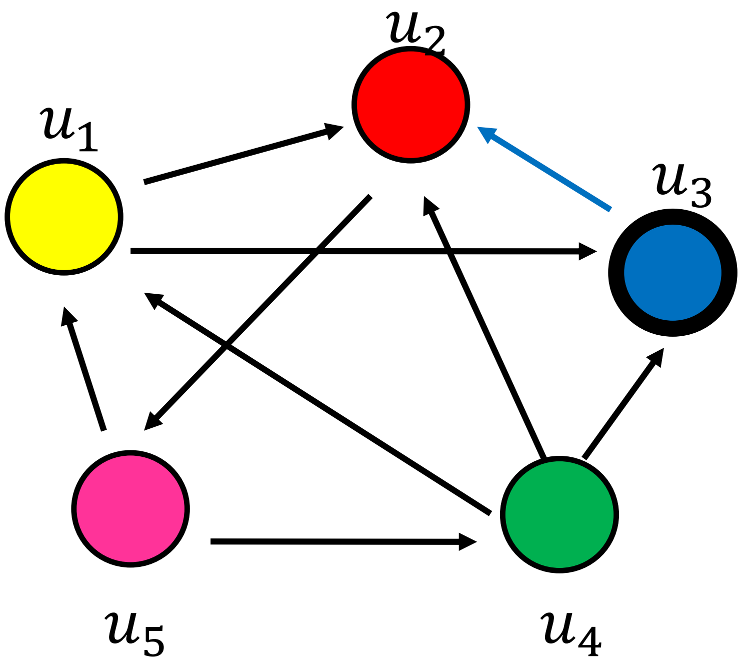

Παράδειγμα

- Step 4…

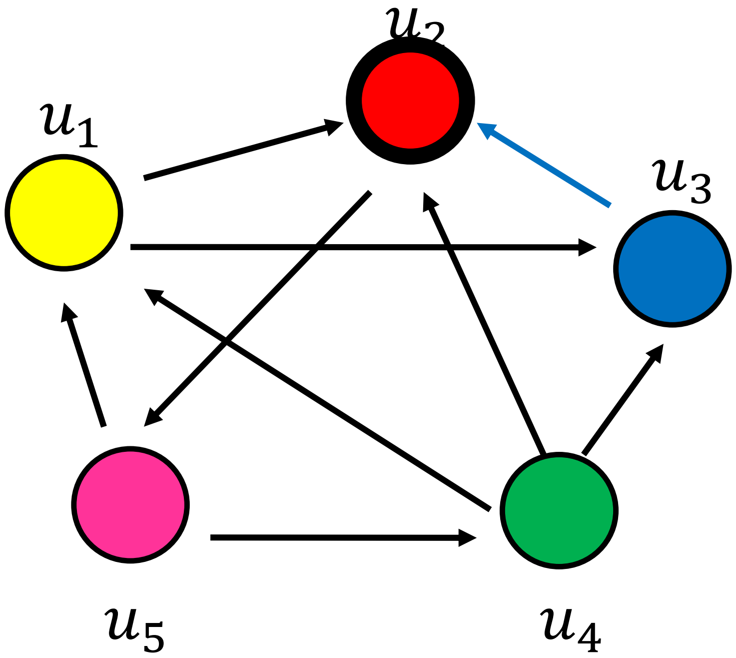

Τυχαίος Περίπατος

Η πιθανότητα να είσαι στη σελίδα X μετά από k βήματα του τυχαίου περιπάτου είναι το PageRank της σελίδας X μετά από k επαναλήψεις του υπολογισμού του PageRank

Το μοντέλο του Random Surfer

Του χρήστη που τριγυρνά στο web, ξεκινώντας από μια τυχαία σελίδα και συνεχίζει ακολουθώντας τυχαία κάποια από τις συνδέσεις της σελίδας

PageRank: Επεκτάσεις

Δύο προβλήματα

1. Dead ends: σελίδες χωρίς εξερχόμενες ακμές
   - Έχουν ως αποτέλεσμα να ξεφεύγει (leak out) το PageRank
2. Spider traps: Ομάδα σελίδων που όλες οι εξερχόμενες ακμές είναι μεταξύ τους
   - Τελικά απορροφούν όλο το PageRank

PageRank: Αδιέξοδα

Αδιέξοδα (dead ends): σελίδες που δεν έχουν εξερχόμενες ακμές

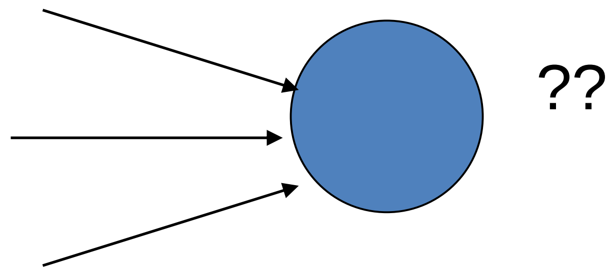

Ο τυχαίος περίπατος μπορεί να κολλήσει σε ένα τέτοιον κόμβο

Λέγονται και sink nodes

PageRank: Αδιέξοδα

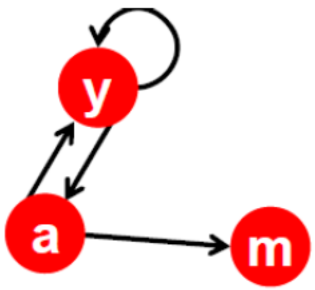

	y	a	m
y	½	½	0
a	½	0	0
m	0	½	0

$$\mathbf{r_y} = \mathbf{r_y/2 + r_a/2}$$
$$\mathbf{r_a} = \mathbf{r_y/2}$$
$$\mathbf{r_m} = \mathbf{r_a/2}$$

$$\begin{bmatrix} r_y \\ r_a \\ r_m \end{bmatrix} = \begin{matrix} 1/3 & 2/6 & 3/12 & 5/24 & & 0 \\ 1/3 & 1/6 & 2/12 & 3/24 & \ldots & 0 \\ 1/3 & 1/6 & 1/12 & 2/24 & & 0 \end{matrix}$$

PageRank: Αδιέξοδα

Teleports: ακολούθησε με πιθανότητα 1 τυχαία links από τους αδιέξοδους κόμβους

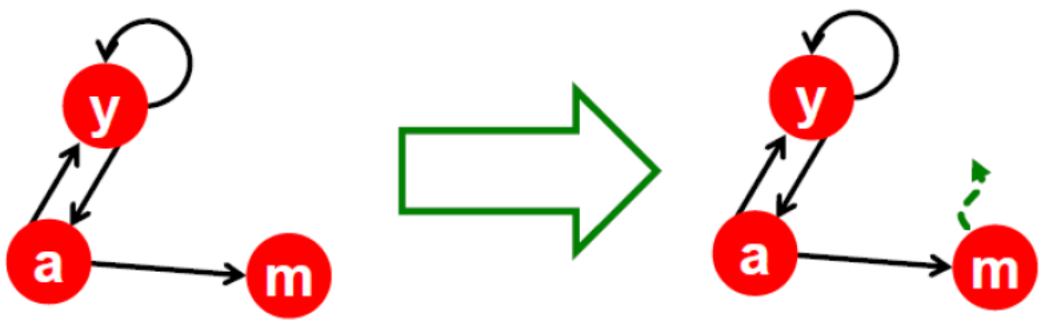

Αντίστοιχη τροποποίηση του πίνακα

	y	a	m
y	½	½	⅓
a	½	0	⅓
m	0	½	⅓

PageRank: Spider Traps

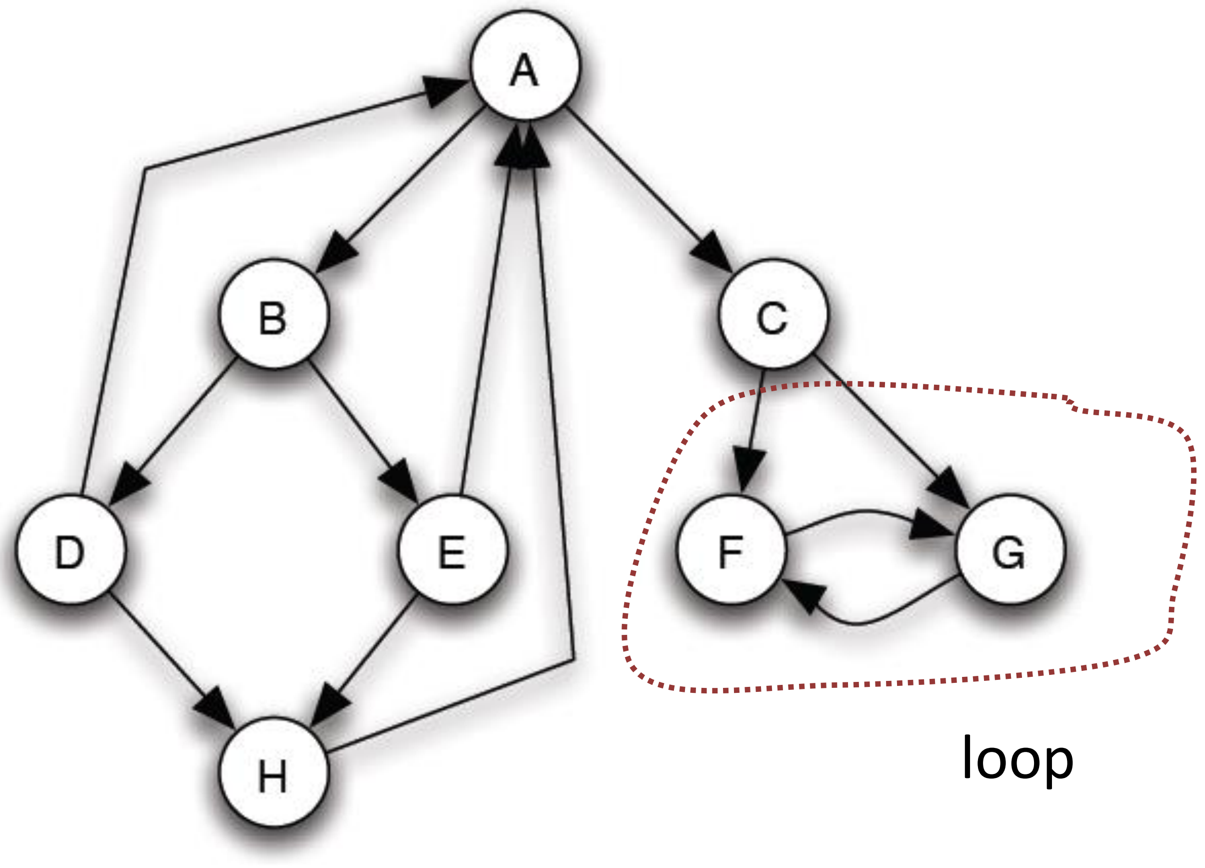

PageRank: Spider Traps

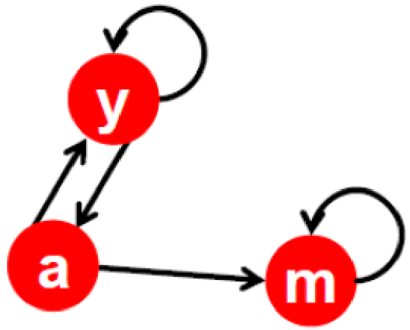

	y	a	m
y	½	½	0
a	½	0	0
m	0	½	1

$$r_y = r_y/2 + r_a/2$$
$$r_a = r_y/2$$
$$r_m = r_a/2 + r_m$$

$$\begin{bmatrix} r_y \\ r_a \\ r_m \end{bmatrix} = \begin{matrix} 1/3 & 2/6 & 3/12 & 5/24 & & \\ 1/3 & 1/6 & 2/12 & 3/24 & \ldots & \\ 1/3 & 3/6 & 7/12 & 16/24 & & \end{matrix} \boxed{\begin{matrix} 0 \\ 0 \\ 1 \end{matrix}}$$

Random Walks with Jumps

Τυχαία περίπατοι με «άλματα»

Με πιθανότητα β, ο περιπατητής ακολουθεί μια τυχαία εξερχόμενη ακμή όπως πριν και με πιθανότητα 1-β επιλέγει (jumps) σε μια τυχαία σελίδα στο δίκτυο, επιλεγμένη με πιθανότητα 1/n

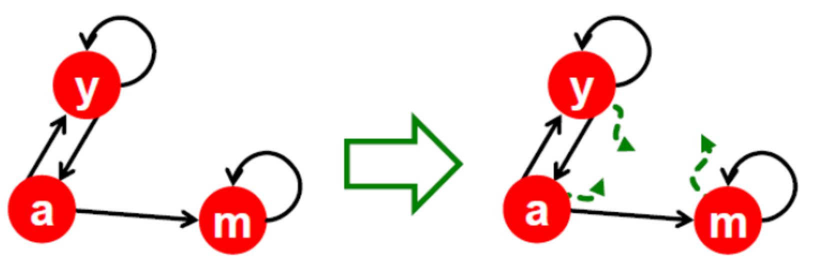

Random Walks with Jumps

Γράφος με 3 κόμβους

Brin-Page, 1998

$$r_j = \sum_{i \to j} \beta \frac{r_i}{d_i} + (1-\beta)\frac{1}{n}$$

$$\beta M + (1-\beta)\begin{bmatrix} 1/3 & 1/3 & 1/3 \\ 1/3 & 1/3 & 1/3 \\ 1/3 & 1/3 & 1/3 \end{bmatrix}$$

Προτεινόμενη τιμή 0,8 – 0,9

damping factor: probability to jump ~0,15

Μοντέλο του Random Surfer

Του χρήστη που τριγυρνά στο web, ξεκινώντας από μια τυχαία σελίδα συνεχίζει ακολουθώντας τυχαία συνδέσεις ή με κάποια πιθανότητα βαριέται και πάει (jumps) σε μια άλλη τυχαία σελίδα

5 links και 1 jump

- Προσθέτουμε ένα τυχαίο άλμα σε ένα διάνυσμα v (jump vector) με πιθανότητα $1 - \beta$
  - συνήθως, το ομοιόμορφο διάνυσμα
  - β dumping factor
- Ο τυχαίος περίπατος ξαναρχίζει μετά από $1/(1-\beta)$ βήματα in expectation

$$r = \beta\, M\, r + (1 - \beta)\, v^t$$

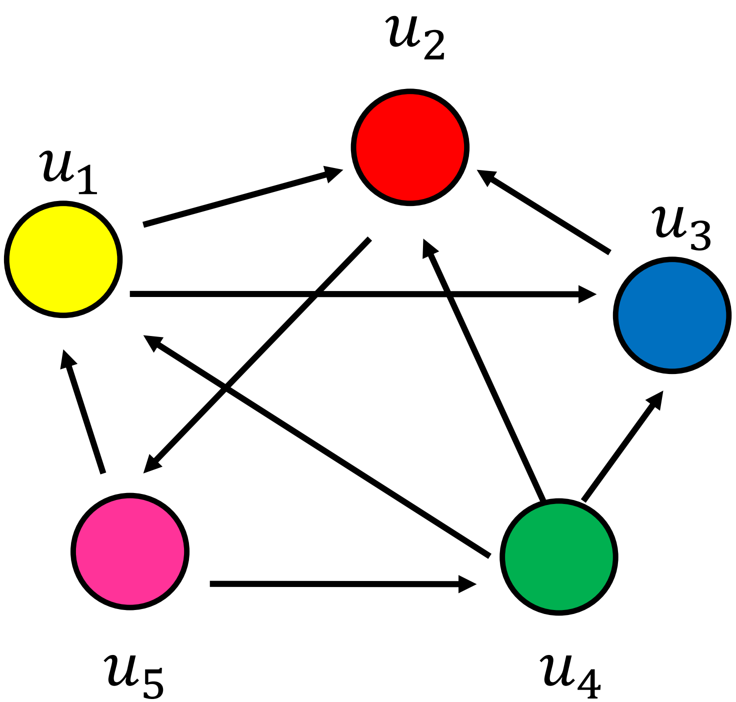

$r(u_1) = 1/3\ r(u_4) + 1/2\ r(u_5)$

$r(u_2) = 1/2\ r(u_1) + r(u_3) + 1/3\ r(u_4)$

$r(u_3) = 1/2\ r(u_1) + 1/3\ r(u_4)$

$r(u_4) = 1/2\ r(u_5)$

$r(u_5) = r(u_2)$

Πίνακας μετάβασης

$$M = \begin{bmatrix} 0 & 0 & 0 & 1/3 & 1/2 \\ 1/2 & 0 & 1 & 1/3 & 0 \\ 1/2 & 0 & 0 & 1/3 & 0 \\ 0 & 0 & 0 & 0 & 1/2 \\ 0 & 1 & 0 & 0 & 0 \end{bmatrix}$$

$$r = \begin{bmatrix} r(u_1) \\ r(u_2) \\ r(u_3) \\ r(u_4) \\ r(u_5) \end{bmatrix}$$

$$r = Mr$$

$$r = \beta\, M\, r + (1 - \beta)\, v^t$$

$$v = \begin{bmatrix} 1/5 \\ 1/5 \\ 1/5 \\ 1/5 \\ 1/5 \end{bmatrix}$$

Νέος πίνακας μετάβασης

$$P' = \beta \begin{bmatrix} 0 & 1/2 & 1/2 & 0 & 0 \\ 1/5 & 1/5 & 1/5 & 1/5 & 1/5 \\ 0 & 1 & 0 & 0 & 0 \\ 1/3 & 1/3 & 1/3 & 0 & 0 \\ 1/2 & 0 & 0 & 0 & 1/2 \end{bmatrix} + (1-\beta) \begin{bmatrix} 1/5 & 1/5 & 1/5 & 1/5 & 1/5 \\ 1/5 & 1/5 & 1/5 & 1/5 & 1/5 \\ 1/5 & 1/5 & 1/5 & 1/5 & 1/5 \\ 1/5 & 1/5 & 1/5 & 1/5 & 1/5 \\ 1/5 & 1/5 & 1/5 & 1/5 & 1/5 \end{bmatrix}$$

$$P' = \beta\, M + (1 - \beta)\, i_1\, v^t$$ όπου i_1 το διάνυσμα με όλα 1

PageRank, τυχαίοι περίπατοι και αλυσίδες Markov

Ποια είναι η πιθανότητα p_i^t να είσαι στον κόμβο i μετά από t βήματα;

$$p_1^0 = \frac{1}{5} \qquad p_1^t = \frac{1}{3}p_4^{t-1} + \frac{1}{2}p_5^{t-1}$$

$$p_2^0 = \frac{1}{5} \qquad p_2^t = \frac{1}{2}p_1^{t-1} + p_3^{t-1} + \frac{1}{3}p_4^{t-1}$$

$$p_3^0 = \frac{1}{5} \qquad p_3^t = \frac{1}{2}p_1^{t-1} + \frac{1}{3}p_4^{t-1}$$

$$p_4^0 = \frac{1}{5} \qquad p_4^t = \frac{1}{2}p_5^{t-1}$$

$$p_5^0 = \frac{1}{5} \qquad p_5^t = p_2^{t-1}$$

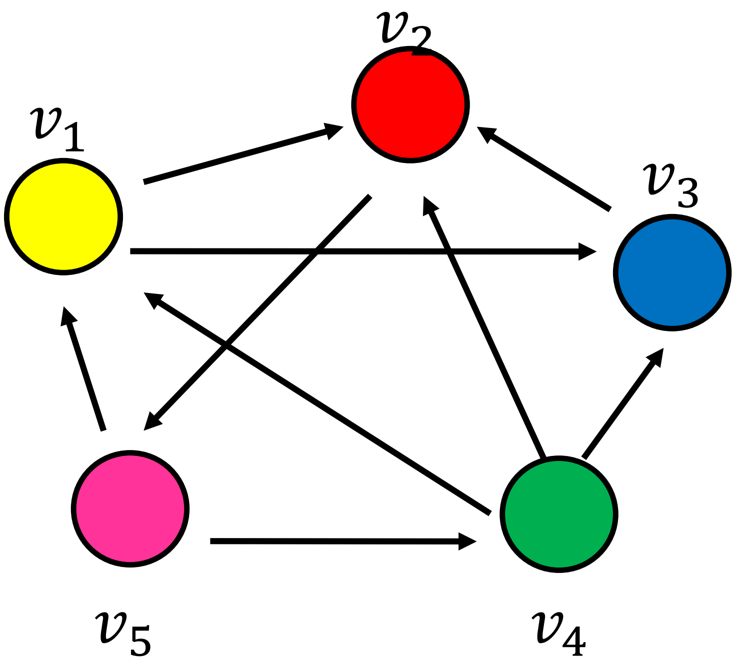

Αλυσίδες Markov

- Περιγράφουν μια στοχαστική διαδικασία διακριτού χρόνου σε ένα σύνολο από καταστάσεις S

$$S = \{s_1, s_2, \ldots, s_n\}$$

  με βάση έναν πίνακα πιθανοτήτων μετάβασης (transition probability matrix) P

  Όπου $P[i, j]$ είναι η πιθανότητα $s_i \text{ -> } s_j$ να μεταβούμε στην κατάσταση s_j όταν είμαστε στην κατάσταση s_i

- Οι γραμμές αθροίζουν σε 1 (row stochastic)

- Memoryless: η επόμενη κατάσταση εξαρτάται *μόνο* από την τωρινή κατάσταση και όχι από τον παρελθόν της διαδικασίας

Τυχαίοι Περίπατοι

Οι τυχαίοι περίπατοι στους γράφους αντιστοιχούν σε Αλυσίδες Markov

- Το σύνολο των καταστάσεων S είναι οι κόμβοι του γράφου
- Ο πίνακας πιθανοτήτων μετάβασης είναι η πιθανότητα να ακολουθήσουμε μια ακμή από έναν κόμβο σε ένα άλλο

$$P[i,j] = 1/outdegree(i)$$

Στα επόμενα θα θεωρήσουμε τον ανάστροφο (transpose) του πίνακα M

Ένα παράδειγμα

$$A = \begin{bmatrix} 0 & 1 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 \\ 0 & 1 & 0 & 0 & 0 \\ 1 & 1 & 1 & 0 & 0 \\ 1 & 0 & 0 & 1 & 0 \end{bmatrix}$$

$$P = \begin{bmatrix} 0 & 1/2 & 1/2 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 \\ 0 & 1 & 0 & 0 & 0 \\ 1/3 & 1/3 & 1/3 & 0 & 0 \\ 1/2 & 0 & 0 & 1/2 & 0 \end{bmatrix}$$

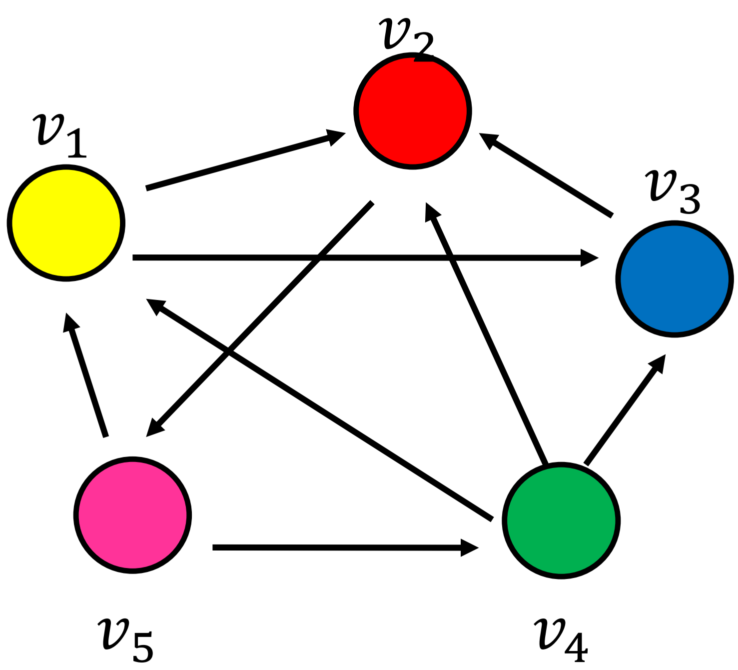

Αλυσίδες Markov

- State probability distribution vector

$$p^t = (p_1^t, p_2^t, \ldots, p_n^t)$$

Διάνυσμα που αποθηκεύει την πιθανότητα να είμαστε στην κατάσταση p_i μετά από t βήματα

- Μπορούμε να το υπολογίσουμε ως:

$$p^t = P\, p^{t-1}$$

- Το state probability vector συγκλίνει σε μια μοναδική κατανομή αν η αλυσίδα είναι *μη περιοδική* (aperiodic) και *αμείωτη* (irreducible)

Το διάνυσμα πιθανοτήτων

$$p^t = (p_1^t, p_2^t, \ldots, p_n^t)$$

Διάνυσμα που αποθηκεύει την πιθανότητα να είμαστε στον κόμβο u_i μετά από t βήματα

- p_i^0 πιθανότητα να αρχίσουμε από τον κόμβο i (συνήθως) ομοιόμορφη
- $p^t = \mathrm{P}\, p^{t-1}$

Ένα παράδειγμα

$$P = \begin{bmatrix} 0 & 1/2 & 1/2 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 \\ 0 & 1 & 0 & 0 & 0 \\ 1/3 & 1/3 & 1/3 & 0 & 0 \\ 1/2 & 0 & 0 & 1/2 & 0 \end{bmatrix}$$

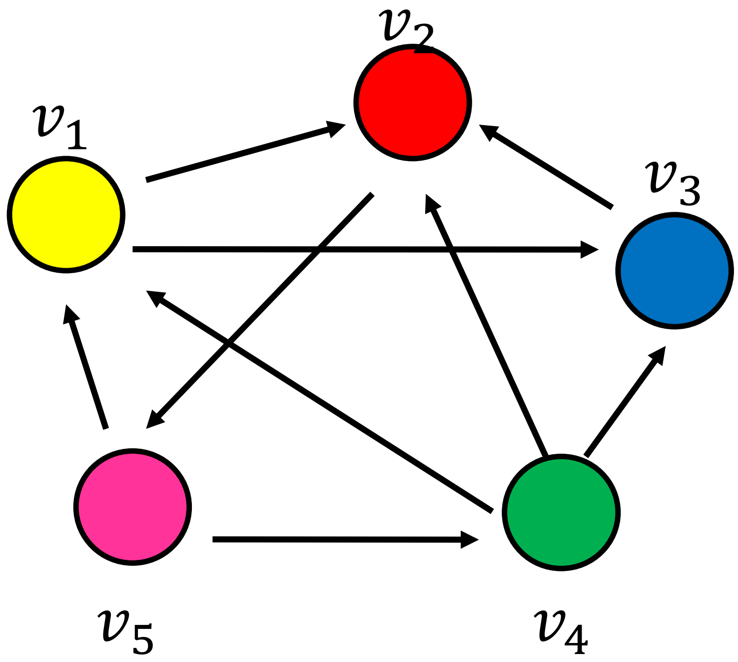

$$p_1^t = \frac{1}{3} p_4^{t-1} + \frac{1}{2} p_5^{t-1}$$

$$p_2^t = \frac{1}{2} p_1^{t-1} + p_3^{t-1} + \frac{1}{3} p_4^{t-1}$$

$$p_3^t = \frac{1}{2} p_1^{t-1} + \frac{1}{3} p_4^{t-1}$$

$$p_4^t = \frac{1}{2} p_5^{t-1}$$

$$p_5^t = p_2^{t-1}$$

Αλυσίδες Markov

Irreducible: υπάρχει πάντα μια ακολουθία μεταβάσεων με μη μηδενική πιθανότητα από μια οποιαδήποτε κατάσταση σε μία άλλη (connectivity)

Aperiodicity: οι καταστάσεις δε μπορούν να χωριστούν σε σύνολα τέτοια ώστε όλες οι μεταβάσεις να συμβαίνουν κυκλικά από το ένα σύνολο στο άλλο

Stationary distribution

- Η stationary κατανομή ενός τυχαίου περίπατου με πίνακα μετάβασης P είναι η κατανομή πιθανοτήτων π τέτοια ώστε
  - $\pi = \pi P$

- Το ιδιοδιάνυσμα (principal left eigenvector) του πίνακα P (οι στοχαστικοί πίνακες έχουν μέγιστη ιδιοτιμή 1)

- Το ποσοστό των φορών που επισκεπτόμαστε την κατάσταση (κόμβο) i όταν $t \to \infty$

- Θεωρία Αλυσίδων Markov: Ο τυχαίος περίπατος συγκλίνει σε μια μοναδική stationary distribution ανεξάρτητα από την αρχική κατάσταση αν ο γράφος είναι ισχυρά συνεκτικός και δεν είναι διμερής

Stationary distribution

- Τι σημαίνει η stationary distribution π ενός τυχαίου περίπατου
- $\pi(i)$: η πιθανότητα να είμαστε στον κόμβο *i* μετά από ένα πολύ μεγάλο (άπειρο) αριθμό από βήματα
- $\pi = p_0 P^{\infty}$, όπου P ο πίνακας μετάβασης, p_0 το αρχικό διάνυσμα
  - $P(i, j)$: πιθανότητα μετάβασης από το i στο j σε ένα βήμα
  - $P^2(i, j)$: πιθανότητα μετάβασης από το i στο j σε δύο βήματα (πιθανότητα όλων των μονοπατιών μήκους 2)
  - $P^{\infty}(i, j) = \pi(j)$: πιθανότητα μετάβασης από το i στο j σε άπειρα βήματα – δεν έχει σημασία το αρχικό σημείο

Υπολογισμός

- Power Method

Initialize q^0 to some distribution
Repeat
    $q^t = q^{t-1}P$
Until convergence

- Μετά από πολλές επαναλήψεις $q^t \to \pi$ ανεξάρτητα από το αρχικό διάνυσμα q^0
- Power method γιατί υπολογίζει το $q^t = q^0 P^t$

- Ρυθμός σύγκλισης
  - Καθορίζεται από τη δεύτερη ιδιοτιμή ${\lambda_2}^t$

PageRank: Παράδειγμα

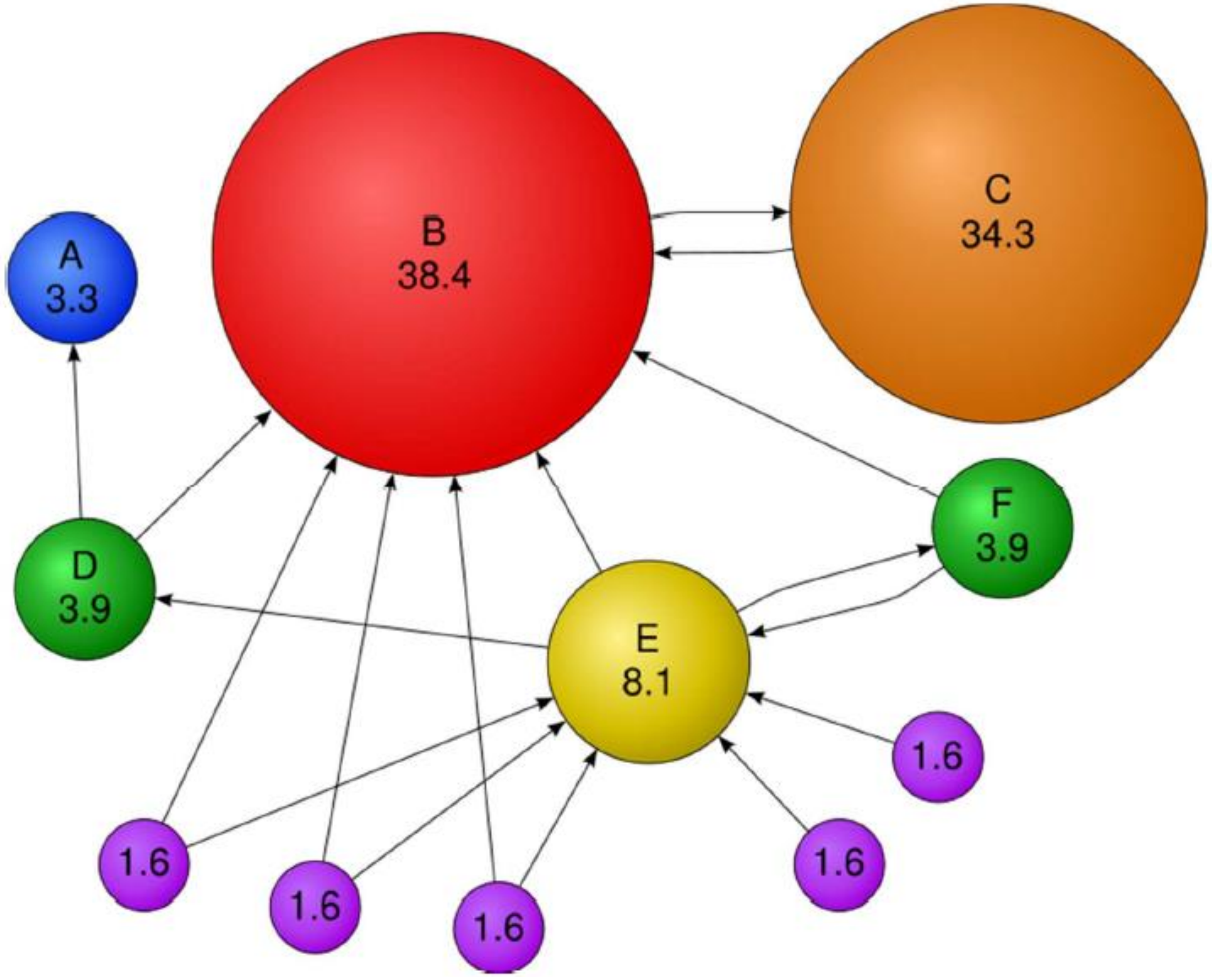

PageRank: τυχαίος περίπατος

Αν το διάνυσμα v που γίνεται το jump δεν είναι uniform, τότε μια *προτίμηση* σε συγκεκριμένους κόμβους

Ονομάζεται και τυχαίος περίπατος με επανεκκίνηση (random walk with restart) - Personalized page rank – Rooted page rank

Κόμβοι σε «μικρή» απόσταση από τον «restart» κόμβο

Θεματικό PageRank

Η σημασία μιας σελίδας μόνο με βάση το δίκτυο – ανεξάρτητη από την ερώτηση (ή, το θέμα)

Πως μπορούμε να υπολογίσουμε «θεματικό» ή personalized PageRank;

Θεματικό PageRank

Έστω *S* ένα σύνολο από σελίδες «συναφείς» με το θέμα
Προσθέτουμε συνδέσεις teleports σε αυτές αντί σε τυχαίους κόμβους

$$
\begin{aligned}
M'_{ij} &= (1-\beta)\, M_{ij} + \beta / |S| && \text{if } i \in S \\
&= (1-\beta)\, M_{ij} && \text{otherwise}
\end{aligned}
$$

Γειτνίαση με τις σελίδες στο σύνολο *S* $\begin{bmatrix} 0 \\ \vdots \\ 0 \end{bmatrix}$

εκτός, από τις σελίδες που [illegible] έρουν

PageRank

Link Farms: δίκτυα από εκατομμύρια σελίδες που δείχνουν η μία στην άλλη με στόχο την αύξηση του PageRank κάποιων σελίδων

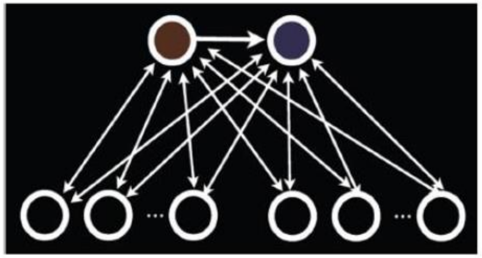

PageRank: χρήση στην ανάκτηση

- Σελίδες με μεγάλο PageRank υψηλότερα στη διάταξη
- Τελικός βαθμός συνδυασμός πολλών χαρακτηριστικών (features)

ΤΕΛΟΣ 21^{ου} Κεφαλαίου

Ερωτήσεις?

Χρησιμοποιήθηκε κάποιο υλικό από:

- ✓ *Pandu Nayak and Prabhakar Raghavan, CS276:Information Retrieval and Web Search (Stanford)*
- ✓ *Hinrich Schütze and Christina Lioma, Stuttgart IIR class*
- ✓ *Τις αντίστοιχες διαλέξεις του μεταπτυχιακού μαθήματος «Κοινωνικά Δίκτυα και Μέσα»*