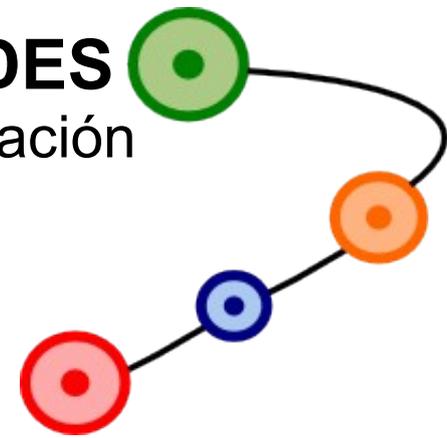


Laboratorio de REDES
Recuperación de Información
y Estudios de la Web



Recuperación de Información en la Web y Motores de Búsqueda

Dr. Gabriel H. Tolosa
tolosoft@unlu.edu.ar

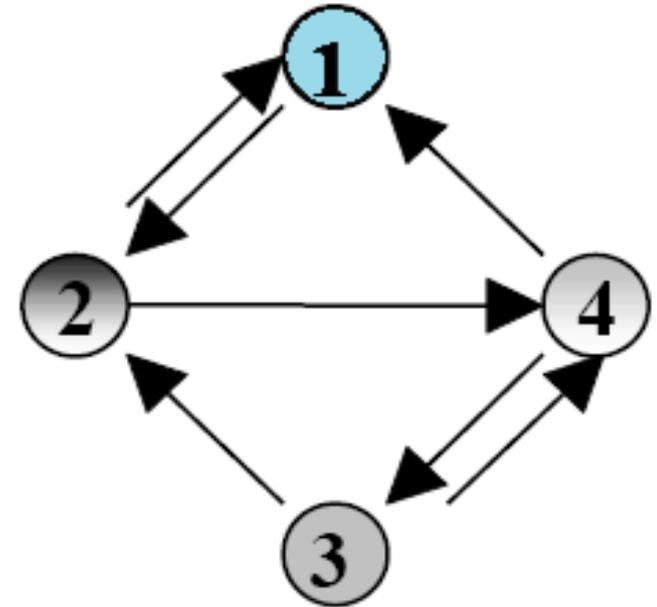


Análisis de Enlaces

El grafo de la web

Se modela la web como un grafo dirigido

- Cada página es un nodo
- Cada hyperlink es un arco dirigido
 - Grado entrante
 - Grado saliente
 -
- Se puede representar mediante la matriz de adyacencia:



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

Estructura

Los enlaces (hyperlinks)

X Representan una relación entre páginas conectadas

X Documento origen -> link

`Universidad Nacional de Luján`

Doc. Destino

Anchor Text

X In-links → indegree

X Out-links → outdegree

X Los enlaces son fuente de evidencia, pero también pueden aportar ruido



Estructura

Suposiciones sobre la creación de enlaces

X Recomendación

El autor recomienda la página destino

X Localidad temática

Las páginas conectadas tienen mayor probabilidad de ser del mismo tema que las que no lo están.

X “anchor text” descriptor

El texto del “ancla” describe el destino

Para la indexación:

- X (Probablemente) Provea una descripción consisa de la página misma
- X (Probablemente) Contenga más términos significativos que la página misma
- X Representa el contenido de páginas aún no recolectadas
- X Representa objetos no textuales (imágenes, programas, etc.)



Ranking

Algoritmos de Ranking

X Ranking basado en contenido

Modelos booleano, vectorial, etc.

X Ranking basado en enlaces

Mediante el análisis de los enlaces se determina la calidad de la página

Clásicos: HITS [Kleinberg] y PageRank [Brin & Pag]

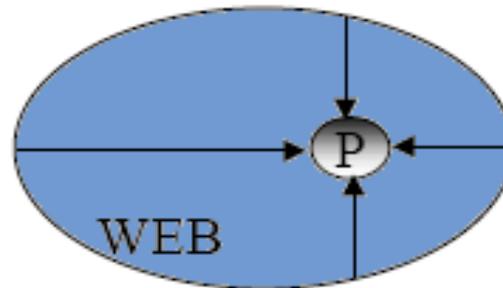
X Combinación de los anteriores

Análisis de enlaces

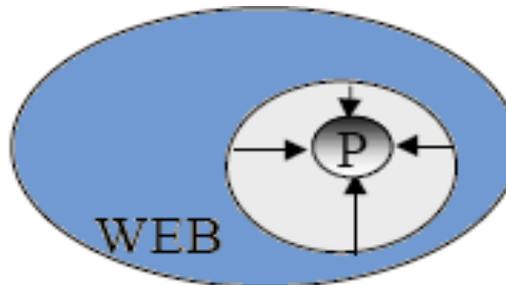
Algoritmos

X Dos enfoques:

X Análisis global: la calidad de la página es **independiente** de la consulta



X Análisis local: la calidad de la página es **dependiente** de la consulta



Análisis de enlaces

HITS – Hypertext Induced Topic Search

X Kleinberg, 1997.

X Identifica para un tema determinado (Query)

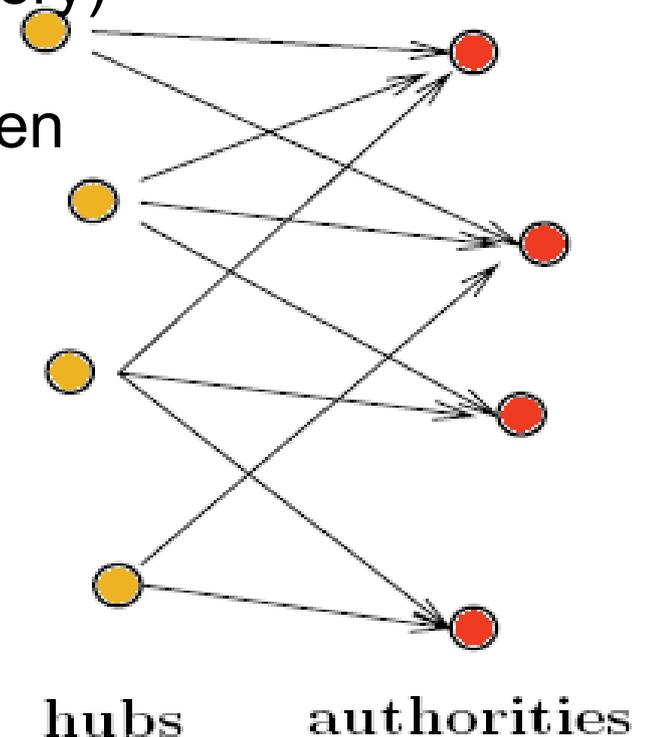
X Autoridades: Páginas que contienen información relevante respecto de Q.

X Hubs: Páginas que poseen links salientes ("apuntan") a páginas útiles.

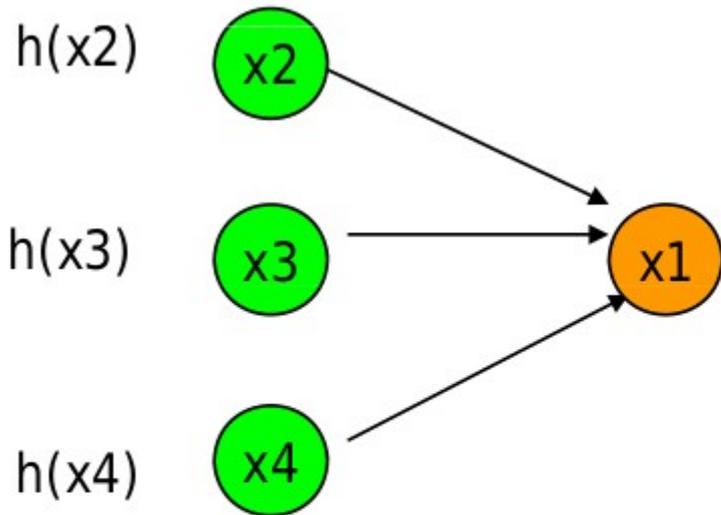
X El valor de autoridad viene de los inlinks

X El valor de hub viene de los outlinks

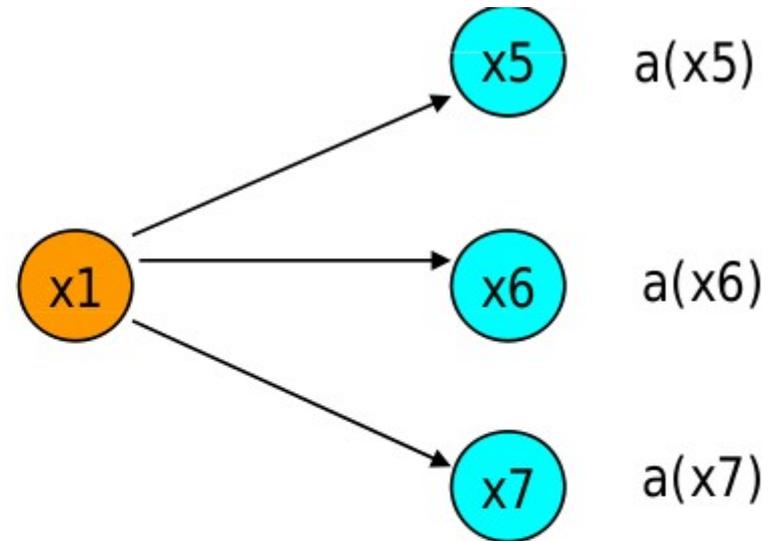
X Refuerzo mutuo



HITS



$$a(x_1) = h(x_2) + h(x_3) + h(x_4)$$



$$h(x_1) = a(x_5) + a(x_6) + a(x_7)$$

HITS

Proceso

X Dado un query, identifica:

X Root set – top k relevantes

X Base set – vecinos-a-1

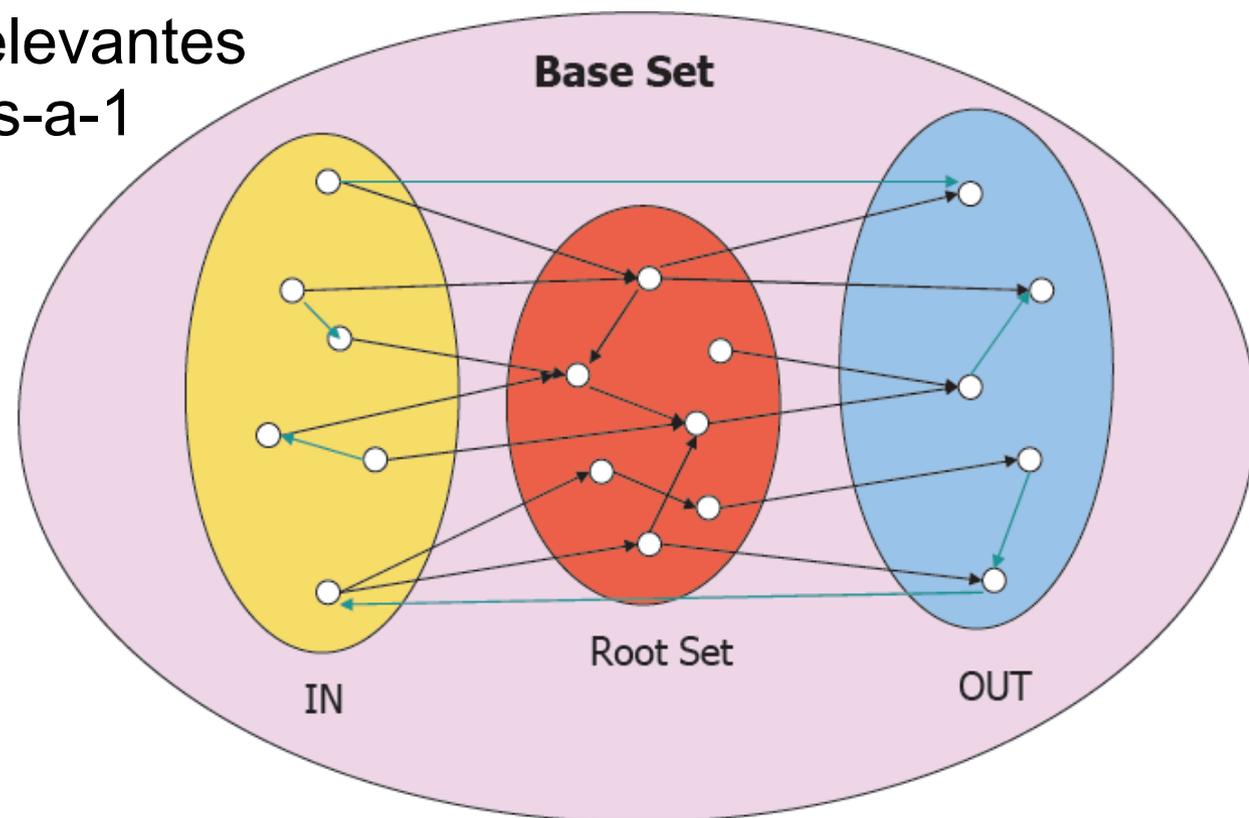
X Construye el grafo correspondiente

X Construye la matriz de adyacencia

X Calcula

X Hub-score

X Auth-score



HITS

Cómputo de los Scores

- Inicializar todos los pesos a 1
- Repetir hasta converger
 - #Operación O – los hubs suman los pesos de las autoridades

$$h_i = \sum_{j:i \rightarrow j} a_j$$

#Operación I – las autoridades suman los pesos de los hubs

$$a_i = \sum_{j:j \rightarrow i} h_j$$

Normalizar los pesos

Análisis de Enlaces

PageRank

X Brin & Page, 1998.

X **Idea**: Una página es importante si otras páginas importantes apuntan a ésta (*Buenas autoridades apuntan a buenas autoridades*)

X Cada link entrante es un voto

X Entonces:

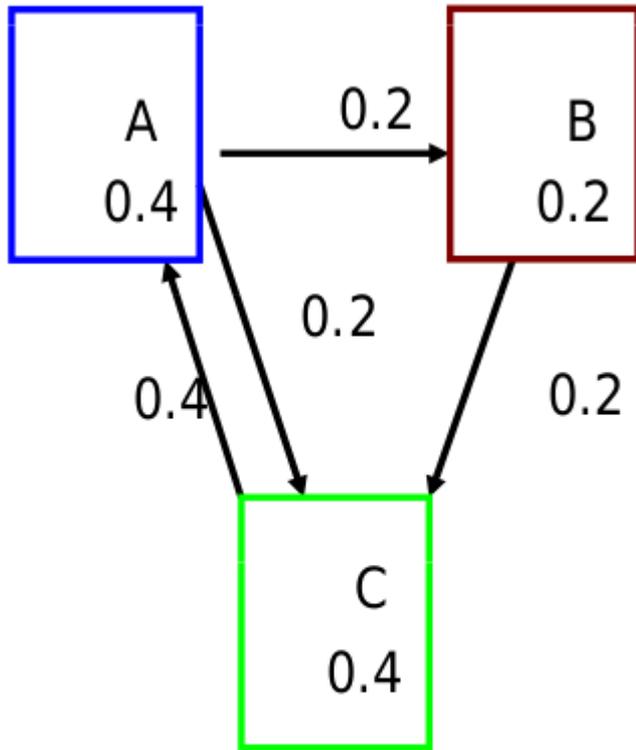
$$r_i = \sum_{j \in L_i} r_j / N_j, \quad i = 1, 2, \dots, n.$$

Donde:

N_j → #de outlinks de P_j

L_i → Páginas que apuntan a P_i

Pagerank



$$\mathbf{PR}^k = [0.4; 0.2; 0.4]$$

Dado:

El grafo de la web $G = (V, E)$

$$PR(i) = \sum_{(j,i) \in E} \frac{PR(j)}{O_j}$$

$$H = \begin{matrix} & \begin{matrix} A & B & C \end{matrix} \\ \begin{matrix} A \\ B \\ C \end{matrix} & \begin{bmatrix} 0 & \frac{1}{2} & \frac{1}{2} \\ 0 & 0 & 1 \\ 1 & 0 & 0 \end{bmatrix} \end{matrix}$$

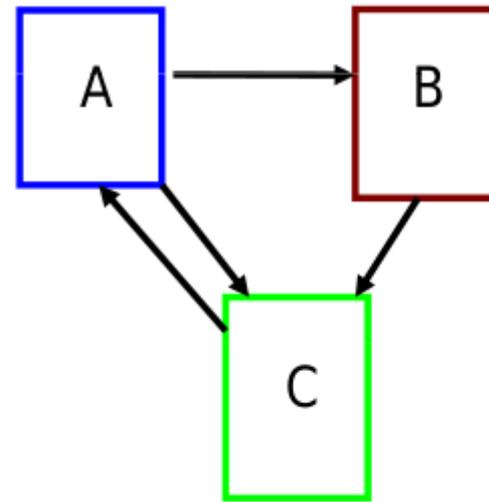
Matriz estocástica!

Pagerank

Hay que resolver

$$\text{i.e. } PR^{k+1} = H^T PR^k$$

Donde la solución corresponde al autovector del autovalor 1.



$$H = \begin{matrix} & \begin{matrix} A & B & C \end{matrix} \\ \begin{matrix} A \\ B \\ C \end{matrix} & \begin{bmatrix} 0 & \frac{1}{2} & \frac{1}{2} \\ 0 & 0 & 1 \\ 1 & 0 & 0 \end{bmatrix} \end{matrix}$$

PR^0	PR^1	PR^2	PR^3	PR^k
0.33	0.33	0.33	0.42	0.40
0.33	0.17	0.25	0.17	0.20
0.33	0.50	0.42	0.42	0.40

Pagerank: Random Surfing

Cadena de Markov

- * Cada página web es un estado
- * Cada enlace es una transición de un estado a otro
- * Se modela la navegación como un proceso estocástico

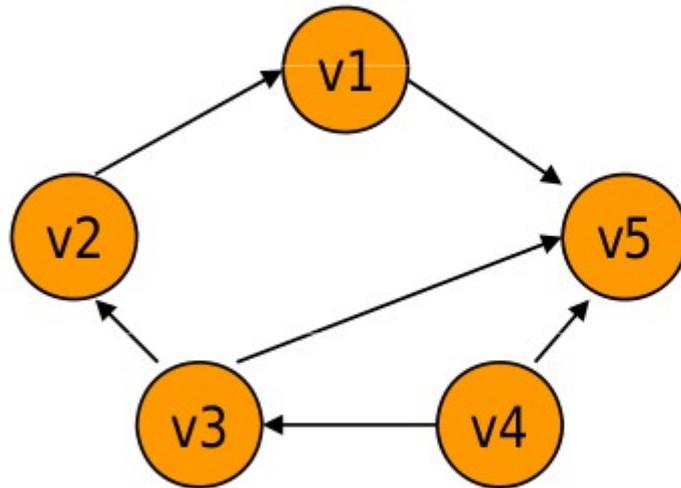
Es el modelo del “**random surfer**”, que elige siempre un link saliente

Cuando se alcanza el estado estacionario (*steady*) resulta:

$$\mathbf{PR}^k = \mathbf{PR}^{k+1} = \mathbf{PR}$$

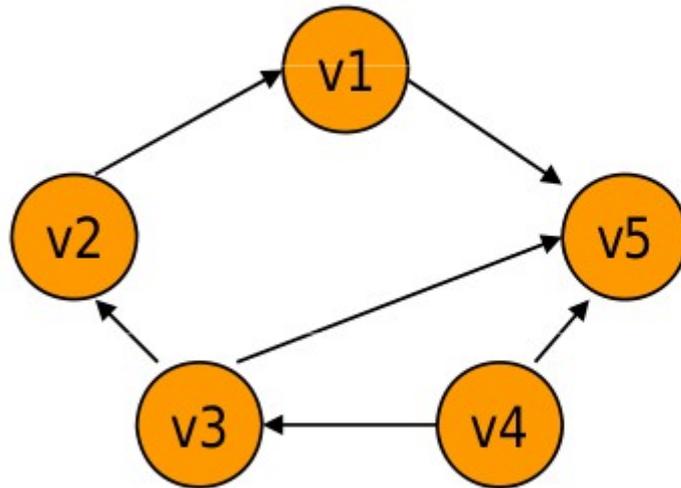
PR es el autovector principal de H^T con autovalor 1

H es estocástica?



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

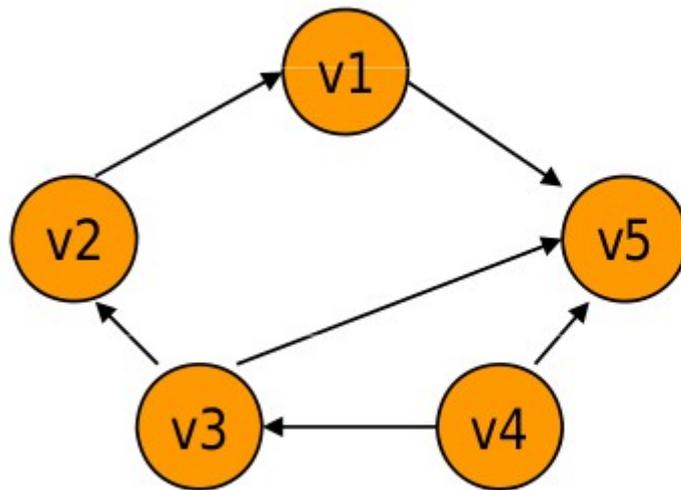
H es estocástica?



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

dangling pages

H es estocástica?



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

dangling pages

$$H = \begin{pmatrix} 0 & 0 & 0 & 0 & 1 \\ 1 & 0 & 0 & 0 & 0 \\ 0 & 1/2 & 0 & 0 & 1/2 \\ 0 & 0 & 1/2 & 0 & 1/2 \\ 1/5 & 1/5 & 1/5 & 1/5 & 1/5 \end{pmatrix}$$

Solucionando H

Agregar un link de todas las páginas a todas las páginas, asignándole una probabilidad de transición pequeña, controlada por un parámetro d (damping factor).

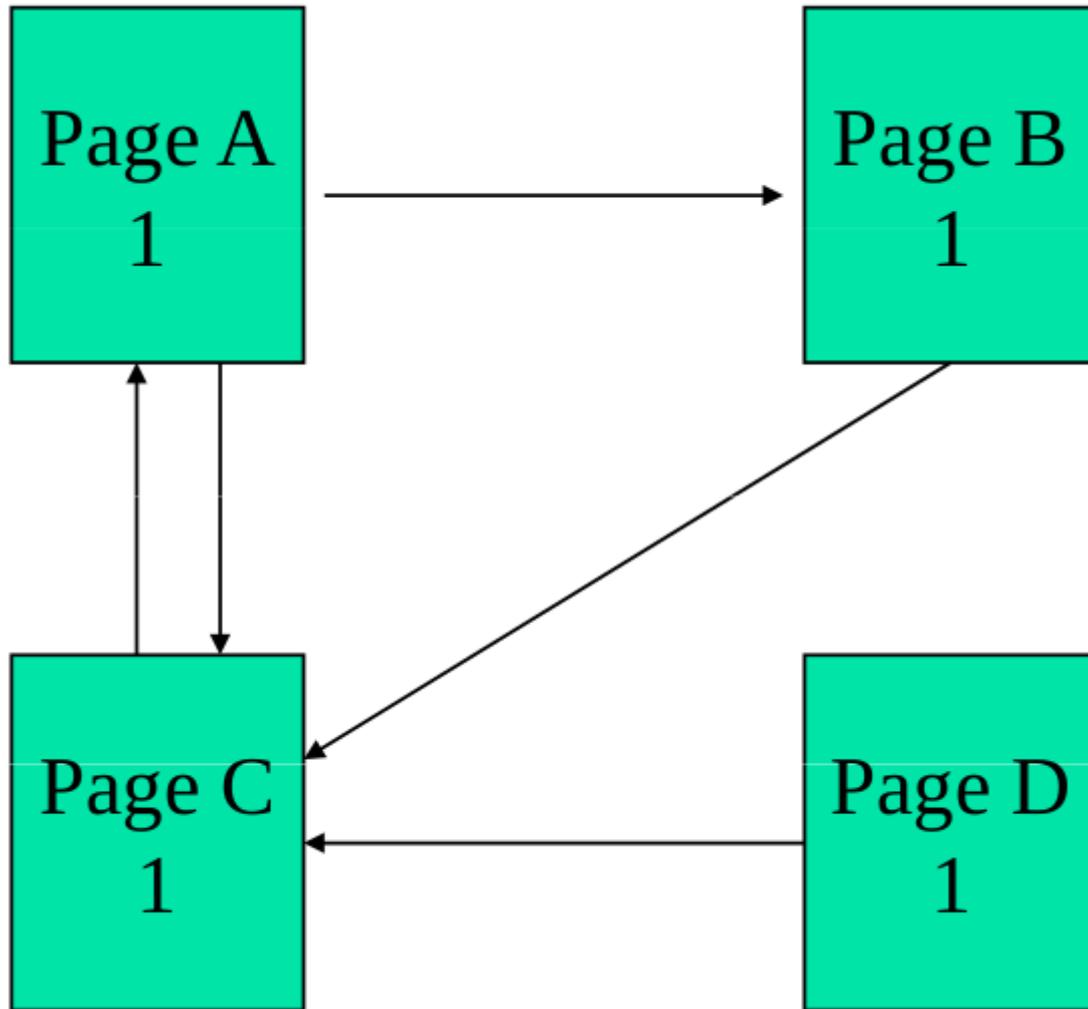
Luego, la nueva matriz es **irreducible**, ya que cada par de nodos se puede comunicar con cierta P .

$$\begin{aligned} PR(i) &= (1-d) + d \sum_{j=1}^n H_{ji} PR(j) \\ &= (1-d) + d \sum_{(j,i) \in E} \frac{PR(j)}{O_j} \end{aligned}$$

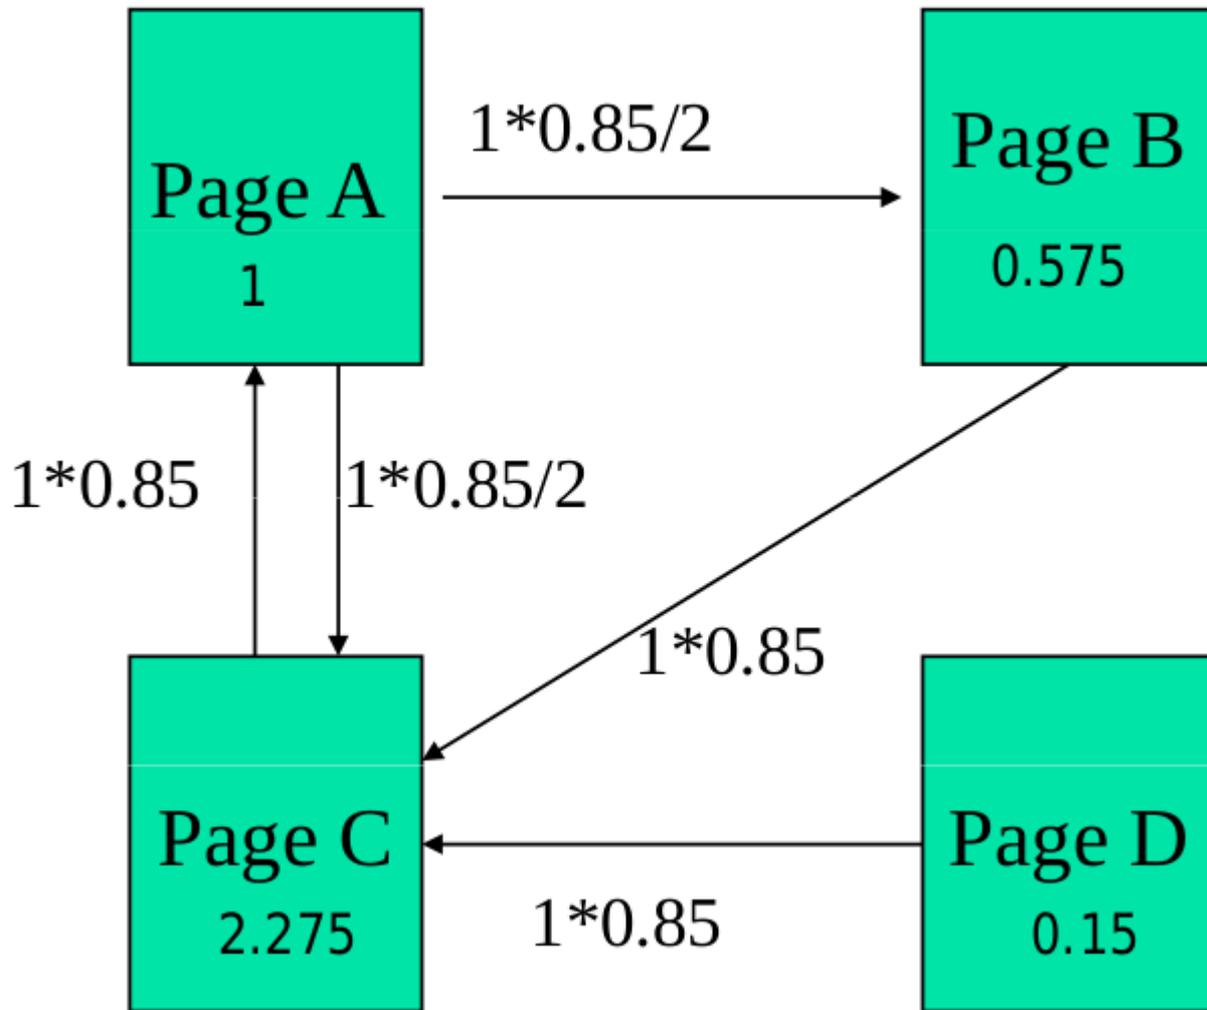
El random surfer tiene dos opciones:

- Con probabilidad d , elige al azar uno de los links salientes de la página.
- Con probabilidad $(1 - d)$, “salta” a una página al azar.

Ejemplo



Ejemplo



Page A:
 0.85 (de Page C) +
 0.15 (random jump) = **1**

Page B:
 0.425 (de Page A) +
 0.15 (random jump) = **0.575**

Page C:
 0.85 (de Page D) +
 0.85 (de Page B) +
 0.425 (de Page A) +
 $+ 0.15$ (random jump) = **2.275**

Page D:
Recibe nada + 0.15 = **0.15**



Pagerank

X Algunas consideraciones:

- X Actualmente, se considera el problema de cómputo con matrices más grande en el mundo.
- X Las operaciones se realizan sobre matrices de más 20 mil millones de filas/columnas.
- X La matriz es esparcida, la cantidad media de enlaces es 8.
- X Con el factor de damping seteado en 0.15 se requieren aproximadamente 100 iteraciones.
- X La detección de web spam es – en la actualidad – una tarea importante para no sesgar artificialmente los valores.

Funciones de Ranking

- Combinación lineal de todas las “señales” consideradas en el ranking

- Ejemplo con PR:

$$R(p, Q) = \alpha BM25(p, Q) + (1 - \alpha)PR(p)$$

Comparación

PageRank	HITS
Google	CLEVER (IBM)
Independiente del query. Calculado offline para todas las páginas web en el índice.	Dependiente del query. Calculado online para un subconjunto de páginas (Root-set + Base-set)
Calcula sólo un score de autoridad	Calcula dos scores: Hub y Autoridad
Cálculo sobre un grafo muy grande	Cálculo sobre un grafo reducido
Trivial y rápido de calcular (la dificultad es de escala)	Fácil de calcular, pero de ejecución más compleja en tiempo real.
Menos susceptible a ataques de Spam	Más susceptible a ataques de Spam
Más estable	Menos estable, la calidad depende del seed