

PageRank y HITS

Felipe Bravo Márquez

8 de noviembre de 2013



Analizando la Web como un Grafo

- La Web es una colección de documentos interconectados por hipervínculos (links).
- Se modela como un grafo dirigido donde los vértices son documentos y las aristas son links.
- Generalmente, cuando un sitio **A** apunta a un sitio **B** ($A \rightarrow B$). Se asume que el autor de **A** aprueba el contenido de **B**. [Manning et al., 2008]
- Los motores de búsqueda consideran para rankear documentos para una consulta además de la similitud de contenido, la popularidad del documento dentro del grafo Web.
- Una página es considerada popular cuando es muy apuntada, lo que tiene relación con la *centralidad* del vértice en el grafo.



- Tanto la Web como una red de publicaciones y sus citas son redes de información.
- Se puede realizar la analogía de la Web hacia sus link como para los papers hacia sus citas.
- Mientras mayor sea el número de citas de un paper, mayor es su impacto y más confiable es su contenido.
- No es lo mismo ser citado por un paper que con el tiempo se vuelve muy citado a ser citado por un paper que pasa al olvido .
- **Idea circular:**el voto o citación es ponderado de acuerdo al índice de impacto.
- Este concepto fue inventado en Bibliometría en 1960 por Pinski y Narin.



- Brin & Page lo introducen en 1998 en la Web como Pagerank como propuesta para el buscador Google. [Brin and Page, 1998]



El random surfer [1]

- Consideremos un *random surfer* que sigue un paseo aleatorio navegando a través de los links desde una página inicial.
- Cuando el *random surfer* se encuentra en la página A, éste puede seguir navegando por cada uno de sus *out-links* de manera **equiprobable**.




Figura: El random surfer seguirá por B,C o D con probabilidad $1/3$

- Las páginas que visite el surfista aleatorio con mayor frecuencia deben ser más importantes.
- El surfista se teletransporta cualquier sitio de manera uniforme si no existen *out-links* y puede **teletransportarse** en cualquier momento con probabilidad $0 < \alpha < 1$ a cualquier sitio del grafo.



PageRank [2]




Figura: Fuente: <http://en.wikipedia.org/wiki/PageRank>

El paseo aleatorio del random surfer se modela con cadenas de Markov discretas.

Markov

- Una cadena de Markov discreta es un **proceso estocástico** que ocurre en una serie de pasos de tiempo donde se toman decisiones aleatorias.
- Consiste en N estados (páginas) y una matriz de transiciones entre estados de $N \times N$ llamada P con valores $\in [0, 1]$ además $\forall i, \sum_{j=1}^N P_{ij} = 1$.
- En una cadena de Markov, el próximo estado depende solamente del estado actual.
- Una matriz con entradas no negativas, que satisfaga la ecuación anterior se denomina como una **matriz estocástica**.
- En cada paso del proceso, estamos en un estado particular (una página a la vez).
- Cada elemento P_{ij} representa la **probabilidad de transición** desde el estado i al estado j .




Figura: Cadena de Markov de tres estados

- La cadena de la figura tendría la siguiente matriz P de (3×3) de transiciones:

$$P = \begin{pmatrix} 0 & 0,5 & 0,5 \\ 1 & 0 & 0 \\ 1 & 0 & 0 \end{pmatrix}$$

- Todas las filas suman 1.

PageRank y Probabilidades Estacionarias

- Cuando calculamos PageRank, buscamos un vector de probabilidades **estacionarias** sobre la matriz de transiciones P .
- La probabilidad estacionaria de un estado π_i representa la probabilidad de llegar a ese estado cuando la cantidad de transiciones tiende a infinito.
- El **PageRank** de una página, es su probabilidad estacionaria.
- Sea $\eta(i, t)$ la cantidad de veces que se ha caído en el estado i para el período t en un paseo aleatorio sobre el grafo:

$$\pi_i = \lim_{t \rightarrow \infty} \frac{\eta(i, t)}{t}$$



Ergodicidad

- Una matriz estocástica admite probabilidad estacionarias sólo si es **ergódica**.
- Donde una cadena de Markov ergódica debe ser **irreductible** y **aperiódica**.
- La **irreductibilidad** exige que haya un camino desde cualquier página a otro (lo solucionamos con la teletransportación).
- La **aperiodicidad** exige que no se caiga en ciclos debido a referencias circulares tipo $A \rightarrow B$ y $B \rightarrow A$. (Se soluciona con teletransportación y se mejora podando las referencias circulares del grafo).

Vector Propio Izquierdo

- Una matriz estocástica ergódica tiene un **vector propio izquierdo principal** $\vec{\pi}$ correspondiente a su *valor propio* λ de mayor valor.
 $\vec{\pi}P = \lambda \vec{\pi}$
- El vector propio principal es equivalente al vector de probabilidades estacionarias $\vec{\pi}$.
- Por el teorema de **Perron-Frobenius** sabemos que para matrices estocásticas el mayor valor propio λ vale siempre 1, entonces

$$\vec{\pi}P = \vec{\pi}$$



Computando PageRank

- Podemos partir con un $\vec{\pi}_0$ y recomputar $\vec{\pi}P$ hasta converger al vector de probabilidades estacionarias (Iteración de Potencias).
- **Ejemplo:** Sea el grafo Web de nodos 1, 2, 3 con la siguiente estructura de links: $1 \rightarrow 2, 3 \rightarrow 2, 2 \rightarrow 1, 2 \rightarrow 3$.
- Comenzamos definiendo una matriz de adyacencia A tal que A_{ij} vale 1 si i apunta a j y 0 caso contrario. Para el ejemplo A es una matriz de 3×3 .

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

- Debemos transformar esta matriz en una matriz de transición estocástica y ergódica.
- Si alguna fila no tiene 1's reemplazamos sus valores por $1/N$.
- Dividimos cada valor 1 en A por la cantidad de 1's en su fila, para respetar propiedad estocástica.

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



Computando PageRank

- Multiplicamos la matriz resultante por el escalar $1 - \alpha$, generalmente se usa $\alpha = 0,25$ (teletransportación) ahora usaremos $\alpha = \frac{1}{2}$.

$$\begin{pmatrix} 0 & 1/2 & 0 \\ 1/4 & 0 & 1/4 \\ 0 & 1/2 & 0 \end{pmatrix}$$

- Sumamos $\frac{\alpha}{N}$, (1/6 en el ejemplo) a todas las entradas de la matriz resultante y obtenemos P . La matriz de transición del *random surfer*.

$$P = \begin{pmatrix} 1/6 & 2/3 & 1/6 \\ 5/12 & 1/6 & 5/12 \\ 1/6 & 2/3 & 1/6 \end{pmatrix}$$

- Imaginemos que el surfista comienza en la página 1 tomamos como $\vec{\pi}_0 = [1, 0, 0]$.
- Computamos $\vec{\pi}_1 = \vec{\pi}_0 P = [1/6, 2/3, 1/6]$.
- Computamos $\vec{\pi}_2 = \vec{\pi}_1 P = [1/3, 1/3, 1/3]$.
- Iteramos: $\vec{\pi}_3 = [1/4, 1/2, 1/4]$, $\vec{\pi}_4 = [7/24, 5/12, 7/24]$
- Después de varios pasos convergemos a $\vec{\pi} = [5/18, 4/9, 5/18]$.
- Podemos usar un criterio de parada $\|\vec{\pi}_{i+1} - \vec{\pi}_i\| < \epsilon$ [Velasquez and Palade, 2008].



Conclusiones de PageRank

- La actualización del *PageRank* de una página se puede representar con la siguiente expresión:


$$x_p^{i+1} = \frac{\alpha}{N} + (1 - \alpha) \sum_{\forall q, p/q \rightarrow p} \frac{x_q^{(i)}}{\text{outdeg}(q)}$$

- PageRank rankea las páginas de manera independiente de una consulta.
- Para tener un PageRank elevado no basta con ser muy apuntado (in-degree) es necesario ser apuntado por páginas con alto PageRank.
- PageRank se puede calcular off-line, osea se puede tener precalculado para cuando llega una consulta. Los motores de búsqueda lo precalculan.
- Variaciones de PageRank se usan en el proceso de **crawling** para darle prioridad a sitios más relevantes en la cola de prioridad. **OPIC** (Online Page Importance Computation).



- HITS (Hyperlink-Induced Topic Search) [Kleinberg, 1998] propone que dada una consulta q cada página existente en el grafo Web tendrá dos tipos de puntajes asociados (un puntaje hub y un puntaje authority).
- Al igual que PageRank, HITS propone que los links entregan información semántica no necesariamente contenida en el **matching de texto** entre una consulta y un documento.
- Para cada consulta se construye un subgrafo de la Web, donde se computa un puntaje de **hub** y otro de **authority** para cada documento del subgrafo donde:
 - 1 Una página con alto puntaje de **authority** proveerá información relevante para la consulta.
 - 2 Una página con alto puntaje de **hub** proveerá links a sitios relevantes para la consulta.
- Entonces un buen **hub** apunta a buenas **authorities** y una buena **authority** es apuntada por buenos **hubs**.





Query: **Top automobile makers**

Figura: Hubs y Autoridades para una consulta s **q= Top automobile makers**

- Se modelan los puntajes hubs y authority de una página de la siguiente forma:

Definiciones

- El puntaje hub de un sitio v $h(v)$ es la suma del puntaje de autoridad de todos los sitios que apunta:

$$h(v) \leftarrow \sum_{v \rightarrow y} a(y)$$

- El puntaje de autoridad de un sitio v $a(v)$ es suma del puntaje hub de todos los sitios que lo apuntan:

$$a(v) \leftarrow \sum_{y \rightarrow v} h(y)$$

Escogiendo un subconjunto de la Web

- Es muy importante en HITS el **subconjunto de la Web** que se procesa dada una consulta q .
- Se esperan encontrar documentos que no necesariamente son similares textualmente a la consulta pero que si son buenos satisfaciendo una necesidad de información.
- Por ejemplo para una consulta sobre **autos** una página que sólo contiene imágenes de autos no sería bien rankeada con tf-idf, pero probablemente sea apuntada por documentos que si contienen alta similitud textual.
- Se espera que las páginas hubs contengan mayor similitud textual, pero las autoridades sean mejores resolviendo la necesidad de información asociada a la consulta.
- Las autoridades aportan al ranking, mientras que los hubs no [Manning et al., 2008].
- Dada una consulta q se toman los primeros k documentos mediante alguna medida de ranqueo textual (tf-idf)
- Ese conjunto S se expande agregando todos los in-links y out-links del conjunto para obtener S' como subgrafo Web a procesar.



- Se tiene la matriz de adyacencia A sobre el subgrafo Web donde se computarán los puntajes $h(v)$ y $a(a) \forall v \in G$.
- Donde en A , $A_{ij} = 1$ si $v_i \rightarrow v_j$ para todo i, j y 0 en caso contrario.

Relaciones Matriciales

- Matricialmente se puede representar los puntajes de **hub** y **authority** como:

$$\begin{aligned}\vec{h} &\leftarrow A \vec{a} \\ \vec{a} &\leftarrow A^T \vec{h}\end{aligned}$$

- Si A_{ij} modela los existencia de out-links de i a j , A_{nm}^T modela la existencia de un in-link de n a m (m apunta a n).
- Reemplazamos en ambas ecuaciones para obtener definiciones recursivas:

$$\begin{aligned}\vec{h} &\leftarrow AA^T \vec{h} \\ \vec{a} &\leftarrow A^T A \vec{a}\end{aligned}$$

- Las relaciones anteriores se parecen a las relaciones de vectores propios usadas en Pagerank, entonces si pasamos las relaciones de \leftarrow a relaciones de igualdad, aparecen valores propios desconocidos porque nuestras matrices **no son estocásticas** y no necesariamente se cumple $\lambda = 1$ como en Pagerank :

$$\vec{h} = (1/\lambda_h)AA^T\vec{h}$$

$$\vec{a} = (1/\lambda_a)A^T A\vec{a}$$

- Para poder realizar iteración en potencias (como en PageRank), se normalizan los vectores \vec{h} y \vec{a} tal que la suma de sus elementos sume 1 en cada interacción.



- **Ejemplo:** Supongamos que a partir de una consulta obtenemos un sub-grafo Web de nodos 1, 2, 3 con la siguiente estructura de links:
 $1 \rightarrow 2, 1 \rightarrow 3, 2 \rightarrow 3, 3 \rightarrow 1.$

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

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

- Luego $\vec{h} \leftarrow AA^T \vec{h}$ con $h_0 = [1 \ 1 \ 1]^T$ con

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

- $h_1 \leftarrow AA^T \vec{h} = [3 \ 2 \ 1]^T$ Normalizamos y obtenemos
 $h_1 = [0,5 \ 0,33 \ 0,166]^T$ $h_2 = [0,571437 \ 0,357148 \ 0,07143]^T = h_3$

- Nos damos cuenta que el vector de hubs tiene sentido el sitio de acuerdo a la definición, 1 es el que más apunta por lo que tiene mayor peso, y el sitio 2 pesa más que el sitio 3 pues apunta al sitios con mayor autoridad.
- Ahora calculamos el vector de **autoridades** con $a_0 = [1 \ 1 \ 1]^T$

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

- $\vec{a} \leftarrow A^T A \vec{a} = [1 \ 2 \ 3]^T$, normalizamos y nos queda
 $a_1 = [0,1666 \ 0,3333 \ 0,5]$ $a_2 = [0,071429 \ 0,357143 \ 0,5471429]^T$
 $a_3 = [0,028571 \ 0,37149 \ 0,6]^T = a_4$



References I

-  Brin, S. and Page, L. (1998).
The anatomy of a large-scale hypertextual web search engine.
Computer Networks and ISDN Systems, 30(1-7):107–117.
Proceedings of the Seventh International World Wide Web Conference.
-  Kleinberg, J. M. (1998).
Authoritative sources in a hyperlinked environment.
In *SODA*, pages 668–677.
-  Manning, C. D., Raghavan, P., and Schütze, H. (2008).
Introduction to Information Retrieval.
Cambridge University Press, New York, NY, USA.
-  Velasquez, J. D. and Palade, V. (2008).
Adaptive Web Sites: A Knowledge Extraction from Web Data Approach.

