

Page Rank: Google Search


IN831: Auxiliar2 – Tarea1 – Parte 2
Pablo Roman

Tarea1: Googlito


- Aplicación que:
 - Busque y “capture el texto” de paginas de Internet, datos que se almacenan en un repositorio.
 - Un buscador que dado una palabra clave liste las 10 paginas con mejor PageRank.

Tarea1: Googlito

- Sitio Wikipedia (en.wikipedia.org)
 - Video Game
 - Toy
- Máximo de 300-1000 páginas
- Debe por ejemplo poder encontrar “Duke Nukem”.



Googlito: Estructura muy general



Segunda Fase del proyecto

- Tenemos un crawler que almacena páginas, contenido de texto (palabras) y links entre páginas.
- Tenemos un buscador que dadas las palabras claves encuentra las paginas asociadas.

Segunda Fase del proyecto: Que falta?

- Calcular el ranking de las páginas, de acuerdo al algoritmo PageRank.
- Mejorar el resultado de las búsquedas incorporando algún tipo de score a las palabras encontradas y mejorar el buscador.
- Comparar con google: haciendo búsquedas como “Duke Nukem site:en.wikipedia.org”.
- Informe con el proyecto, evaluación del sistema, algoritmos e instalación.

Algoritmo PageRank© for beginners

- Matrices estocásticas
- Teoría de cadenas de markov
- Cálculo (de verdad) de vectores propios de matrices estocásticas de 1000×1000

Pagerank: El valor de un algoritmo

- Patentado Brin&Page 1998
- Valor numérico de importancia de una página respecto de otras.
- Esta claro que es parte del algoritmo real que usa Google, el verdadero algoritmo tiene un valor incalculable.
- Motivación de mas para mejorar la búsqueda que hace su tarea.

Pagerank: Intuición

- Una página recomienda a otra si tiene un link hacia ella.
- Páginas más recomendadas por otras son más importantes, valor de importancia de página i : Π_i
- Una página al recomendar a otra le agrega una fracción de su valor de importancia, página k recomienda a página i que recibe: $H_{ki} \Pi_k$, $H_{ki} < 1$.
- $\Pi_i = \sum_k \Pi_k H_{ki} \rightarrow \Pi^t = \Pi^t H$, Π es vector propio de H .
- Las fracciones de importancia deben sumar 1, $\sum_i H_{ki} = 1$
- H : es entonces una matriz estocástica.
- En la teoría de las cadenas de markov las matrices estocásticas son probabilidades de transición.
- ¿CÓMO ENTENDEMOS ESTAS PROBABILIDADES H_{ki} ?

Pagerank: ¿Cómo entendemos H?

The random surfer

- Necesitamos un modelo del comportamiento de navegación de los usuarios.
- Consideremos un personaje muy simple:
 - navega siguiendo los links entre páginas y tiene una probabilidad “d” (aprox 0.85) de NO dejar de seguir links.
 - Si deja de seguir links entonces empieza en otro cualquiera equiprobable.
- Elige el próximo links en una página de manera equiprobable.

Pagerank: H la matriz de probabilidad de transición del random surfer.

- Cada nodo es una pagina.
- Hay un nodo adicional: El nodo “salida”
- Cada transición es un link.
- Hay transiciones adicionales: las transiciones a la salida, con probabilidad “d”.
- Todos los estados son transientes. H es irreducible y aperiódica.
- **El tiempo que pasa el random surfer en cada nodo será proporcional a la importancia de la página.**
- Π_k : la probabilidad de estar en k
- $\Pi_k = P(k|\text{no salir})P(\text{no salir}) + P(\text{recomenzar en } k)(1 - P(\text{no salir}))$
 - $P(\text{no salir}) = d$
 - $P(\text{recomenzar en } i) = 1/n$ (n: el número de páginas)
 - $P(k|\text{no salir}) = \sum_k \Pi_k S_{ki}$
- $H_{ki} = d * S_{ki} + (1 - d)/n$
- S_{ki} : probabilidad de transición de $k \rightarrow i = 1/(\text{número de links que salen de } k)$.


Pagerank: H la matriz de probabilidad de transición del random surfer.

- $\Pi^t = \Pi^t H, \sum_i \Pi_i = 1$
- Π_i : probabilidad estacionaria o probabilidad de estar en i a largo plazo o la proporción del tiempo que paso el random surfer en el nodo i .
- $\Pi_i = \lim_{n \rightarrow \infty} (H^{(n)})_{ki}$
- 1. Iterar potencias de la matriz H (muy costoso !!) o
- 2. O resolver el sistema lineal o
- 3. Iterar $\Pi^{(l)}$:
 - $\Pi_i^{(l+1)} = (1-d)/n + d * \sum_k \Pi_k^{(l)} S_{ki}$
 - $\Pi_i^{(0)} = 1/n$ <- Ergodicidad nos permiten partir de cualquier vector.
 - HAY QUE NORMALIZAR EN CADA ITERACION.

Implementación

- Almacenar matrices de tamaño $n \times n$ y multiplicarlas es muy costoso.
- Guardaremos el vector Π con la tabla page.
- Guardaremos la matriz S con la tabla de links
- La base de datos efectuará la iteración:
 - Maneja mejor la memoria.
 - Esta construida para efectuar estos tipos de cálculos.
 - OJO: Precisión numérica, implica usar tipo de dato DECIMAL(n,m).

Implementación: Tablas



Implementación: Precisión numérica en MySQL

- Valores numéricos “normales” efectúa aproximaciones burdas.
- Debe indicarse al motor que se esta trabajando con datos con gran precisión numérica.
- usar DECIMAL(n,m) : indica precisión de n dígitos numéricos totales y m decimales ($m < n$).
- Ejemplo: para hacer “ $1/n$ ” usar CONVERT
`CONVERT(1, DECIMAL(40,30))/CONVERT(n, DECIMAL(40,30))`

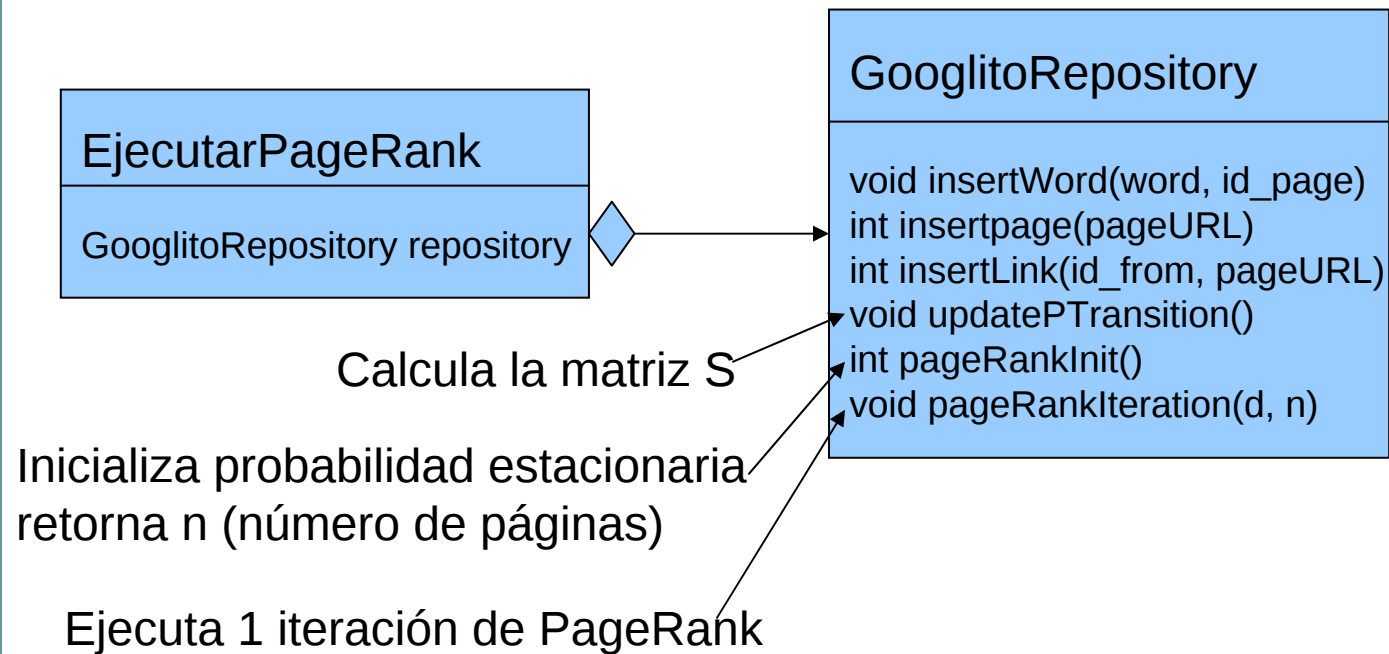
Los datos del crawler: links

- En cada visita a página i
 - Busca cada link j de la pagina
 - Si `shouldVisit(j)` es true
 - Trato de insertar j como nueva page
 - Inserto (i,j) en link
-
- Resultado: Para video_games 241.418 links.

Los datos del crawler: page

- Solo se bajan 1000 páginas con todos sus links.
- Pero se registran 93.483 páginas en la tabla.
- La mayoría son solo apuntadas.
- El calculo de pagerank debe hacerse solo a las 1000 que se bajaron y que son apuntadas.
- Por lo que en la tabla links hay varios links que tampoco son útiles para el calculo.
- Truco: en page se actualizo con rank=0 a aquellas paginas que no se encuentran en el dominio.
- De haber querido cargar el total de las 90000 paginas se hubieran necesitado unos 100G de espacio en disco y 2-3 días de carga. Además de modificar la configuración de MySQL.

La carga de pagerank



EjecutarPageRank

```
public static void main(String[] args) {  
    int n;  
    System.out.println("Inicializando rank ...");  
    // Inicializo los valores de page rank  
    n=repository.pageRankInit();  
  
    System.out.println("Inicializando matriz S ...");  
    // Actualizo la matriz S que esta implicita en la tabla links.  
    repository.updatePTransition();  
  
    System.out.println("Ejecutando PageRank ...");  
  
    for (int k=1; k<=100; k++) {  
        System.out.println("Iteracion " + k);  
        // iteracion de PageRank  
        repository.pageRankIteration(0.85, n);  
    }  
}
```

Actualizando la matriz S


```
public synchronized void updatePTransition() {  
    Statement stmt1, stmt2;  
    ResultSet rs1;  
    int id_page_from, c;  
    String query="";  
    try {  
        stmt1 = conn.createStatement();
```

Cuento cuantas
salen de un
mismo origen

```
        query = "Select id_page_from, count(*) as c from links group by id_page_from";  
        rs1=stmt1.executeQuery(query);  
        while (rs1.next()) {  
            id_page_from=rs1.getInt("id_page_from");  
            c=rs1.getInt("c");  
            stmt2 = conn.createStatement();  
            query="update links set ptransition=CONVERT(1,  
                DECIMAL(40,30))/CONVERT("+c+", DECIMAL(40,30)) where id_page_from="+id_page_from;  
            stmt2.execute(query);  
            stmt2.close();  
            stmt2=null;
```

Actualizo a
1/c la prob

```
        }  
        stmt1.close();  
        stmt1=null;  
        rs1.close();  
        rs1=null;  
    } catch (SQLException ex) {  
        System.out.println("SQLException: " + ex.getMessage());  
        System.out.println("SQLState: " + ex.getSQLState());  
        System.out.println("VendorError: " + ex.getErrorCode());  
        System.out.println("SQL: " + query);  
    }  
    notifyAll();  
}
```



Inicializo la probabilidad estacionaria

```
public synchronized int pageRankInit() {  
    ""  
    try {  
        stmt = conn.createStatement();  
        // obtenemos el numero real de paginas crawladas  
        query = "Select count(distinct id_page_from) as n from links";  
        rs=stmt.executeQuery(query);  
        if (rs.next()) {n=rs.getInt("n"); }  
        // actualizamos todo en 0  
        query="update page set rank=0";  
        stmt.execute(query);  
        //Iteramos sobre las paginas validas  
        stmt2 = conn.createStatement();  
        query = "Select distinct id_page_from as i from links";  
        rs=stmt.executeQuery(query);  
        while (rs.next()) {  
            i=rs.getInt("i");  
            // actualizamos el rank de las paginas validas en 1/n  
            query="update page set rank=CONVERT(1, DECIMAL(40,30))/CONVERT("+n+",  
DECIMAL(40,30)) where id="+i;  
            stmt2.execute(query);  
        }  
        stmt.close(); stmt=null;  
        rs.close(); rs=null;  
        stmt2.close(); stmt2=null;  
    } catch (SQLException ex) {  
        ""  
    }  
    notifyAll();  
    return(n);  
}
```

Todo queda en 0

Actualiza solo para aquellas paginas que fueron leídas, a 1/n

Iteración Pagerank

```


public synchronized void pageRankIteration(double d /*es la probabilidad de salir*/, int n /*numero de paginas*/)
{
    ...
    try {
        stmt1 = conn.createStatement();
        // la iteracion
        query = "Select id_page_from, (1-CONVERT("+d+",
DECIMAL(40,30)))/CONVERT("+n+",DECIMAL(40,30)) + CONVERT("+d+", DECIMAL(40,30))*sum(ptransition*rank) as r from
links, page where page.id=id_page_to and page.rank!=0 group by id_page_from";
        rs1=stmt1.executeQuery(query);
        while (rs1.next()) {
            i=rs1.getInt("id_page_from");
            r=rs1.getDouble("r");
            stmt2 = conn.createStatement();
            query="update page set rank="+r+" where id="+i;
            stmt2.execute(query);
            stmt2.close();
            stmt2=null;
        }
        // vamos a normalizar
        query = "Select sum(rank) as s from page where page.rank!=0";
        rs1=stmt1.executeQuery(query);
        if (rs1.next()) {s=rs1.getDouble("s"); }
        query = "update page set rank=rank/CONVERT("+s+", DECIMAL(40,30)) where page.rank!=0";
        stmt1.execute(query);
        stmt1.close();          stmt1=null;
    } catch (SQLException ex) {
        ...
    }
    notifyAll();
}

```

$$P_i^{(l+1)} = (1-d)/n + d * \sum_k P_k^{(l)} S_{ki}$$

Normalizo

Resultado




Googlito

duke nukem

Enviar consulta

http://en.wikipedia.org/wiki/Video_game
http://en.wikipedia.org/wiki/Computer_and_Video_Games
http://en.wikipedia.org/wiki/Mouse_%28computing%29
http://en.wikipedia.org/wiki/January_25
<http://en.wikipedia.org/wiki/1947>
http://en.wikipedia.org/wiki/December_14
http://en.wikipedia.org/wiki/Duke_Nukem_Forever
http://en.wikipedia.org/wiki/Mod_%28computer_gaming%29
http://en.wikipedia.org/wiki/University_of_Wisconsin
http://en.wikipedia.org/wiki/Video_game_controversy
<http://en.wikipedia.org/wiki/Advertising>
http://en.wikipedia.org/wiki/Recreational_drug_use
http://en.wikipedia.org/wiki/United_States
http://en.wikipedia.org/wiki/Entertainment_Software_Ratings_Board
<http://en.wikipedia.org/wiki/Geneva>
<http://en.wikipedia.org/wiki/France>
<http://en.wikipedia.org/wiki/Image:Gamepad.svg>
http://en.wikipedia.org/wiki/Unlockable_games
http://en.wikipedia.org/wiki/October_30
http://en.wikipedia.org/wiki/October_16
http://en.wikipedia.org/wiki/October_24
http://en.wikipedia.org/wiki/May_15

Comparación con Google



The screenshot shows a web browser window with several tabs open: 'U-Cursos :: IN831-1 W...', 'Correo :: Resultados de...', 'Multi-Objective Optimiz...', and 'W Legendre transformatio...'. The address bar shows 'La Web' and navigation links like 'Imágenes', 'Noticias', 'Grupos', 'Libros', 'Gmail', and 'Más'. The Google logo is visible, followed by a search bar containing 'Duke Nukem site:en.wikipedia.org'. Below the search bar, there are radio buttons for 'la Web', 'páginas en español', and 'páginas de Chile'. The search results are displayed under the heading 'La Web'.

Duke Nukem 3D - Wikipedia, the free encyclopedia - [[Traduzca esta página](#)]
Duke Nukem 3D is a first-person shooter computer game developed by 3D Realms and published by Apogee Software. It was released on January 29, 1996. ...
en.wikipedia.org/wiki/Duke_Nukem_3D - 79k - [En caché](#) - [Páginas similares](#) - [Anotar esto](#)

Duke Nukem (computer game) - Wikipedia, the free encyclopedia - [[Traduzca esta página](#)]
Duke Nukem is a platform video game developed and published by Apogee Software (now 3D Realms), featuring the adventures of Duke Nukem. ...
[en.wikipedia.org/wiki/Duke_Nukem_\(computer_game\)](http://en.wikipedia.org/wiki/Duke_Nukem_(computer_game)) - 33k - [En caché](#) - [Páginas similares](#) - [Anotar esto](#)

Duke Nukem (character) - Wikipedia, the free encyclopedia - [[Traduzca esta página](#)]
Duke Nukem first appeared as the title character of the Apogee platform game Duke Nukem, which was published in 1991. This game was written for the IBM PC ...
[en.wikipedia.org/wiki/Duke_Nukem_\(character\)](http://en.wikipedia.org/wiki/Duke_Nukem_(character)) - 44k - [En caché](#) - [Páginas similares](#) - [Anotar esto](#)

Vaporware - Wikipedia, the free encyclopedia - [[Traduzca esta página](#)]
One such example is the computer game Duke Nukem Forever, which has been in development for over ten years, announced shortly after the success of Duke ...
en.wikipedia.org/wiki/Vaporware - 52k - [En caché](#) - [Páginas similares](#) - [Anotar esto](#)

Duke Nukem Forever - Wikipedia, the free encyclopedia - [[Traduzca esta página](#)]
Duke Nukem Forever (DNF) is a first-person shooter video game being developed by 3D Realms, and is slated to be the next game in the Duke Nukem series. ...
en.wikipedia.org/wiki/Duke_Nukem_Forever - 73k - [En caché](#) - [Páginas similares](#) - [Anotar esto](#)

¿Por qué no es igual?

- Algoritmo real es secreto: PageRank no toma en cuenta los textos para rankear!!
- Faltan páginas que cargar
- Se sabe que el algoritmo secreto:
 - Toma en cuenta la relevancia de las palabras en el texto.
 - Toma en cuenta el comportamiento de usuarios (varias formas de capturarlo)

Tarea 1 – Parte 2

- Deben proponer mejoras al sistema:
 - Mejorar ajuste de la salida a google.
 - Mejorar presentación del search, que se parezca a google.
- Grupo con mejor ajuste a google en 5 primeras salidas tendrá 1 punto de bonus.

Tarea: Hints

- En tabla keyword_page agregar un número (keyword_score) que indique la relevancia de la palabra en la página.
 - Si esta en el titulo -> keyword_score += T
 - Si aparece n veces en el texto -> keyword_score += n*c
- Modificar el search para que ordene según una función $\text{score} = \text{score}(\text{keyword_score}, \text{rank})$
- Quizás podrían almacenar ese score en la tabla keyword_page y ordenar los resultados según $\text{SUM}(\text{keyword_page})$ para todos los key que se consultaron para esa pagina....

Tarea: Hints

- Mejorar el crawler
 - Afinar búsquedas relativas a Toy y Video_Games: que no busque en otros lados.
 - Que guarde paginas irrelevantes.
 - Afinar selección de palabras a guardar: que no guarde palabras no útiles.
- Quizás mejorar la iteración para que indique convergencia.
- Cargar desde varios orígenes para cubrir mejor los temas indicados.

Entrega

- 5 Mayo: Entrega proyecto completo.
- 2 personas.
- Informe completo.
- Códigos
- Base de datos
- `proman@ing.uchile.cl`

Corrección

- Informe: Igual que todos los informes de proyectos.
- Código:
 - Que compile.
 - Que tenga la intención de hacer lo que se dice en el informe.
 - Que instalación (BD y código) funcione como lo dice el informe.
 - Que se ejecute sin errores.
- Sistema: Se tomaran varias consultas a Google relativas al tema y se compararan los 5 primeros resultados. Si hay grupos empatados se agregan mas consultas hasta llegar a 1 solo grupo.