CC52D - DCC/Univ. de Chile

Recuperación de la Información: Modelos, Estructuras de Datos, Algoritmos y Búsqueda en la Web

Apuntes por

Ricardo Baeza-Yates, Univ. de Chile

en base a una versión inicial de

Gonzalo Navarro, Univ. de Chile

Enero, 2005

Objetivos del Curso

- Comprender los principales desafíos de RI y sus diferencias con otras disciplinas relacionadas.
- Poder entender la descripción de un Sistema de RI (SRI).
- Poder evaluar y elegir un SRI, poder hacer las preguntas adecuadas y entender las respuestas.
- Conocer los conceptos necesarios para implementar un SRI.
- Comprender los principales aspectos de un SRI sobre la Web.

Bibliografía

- *Modern Information Retrieval.*
  R. Baeza-Yates y B. Ribeiro-Neto.
  Addison-Wesley, 1999.
- *Managing Gigabytes.*
  I. Witten, A. Moffat y T. Bell.
  Van Nostrand Reinhold, 2da edición, 1999.
- `http://www.searchenginewatch.com`

Contenidos del Curso

Introducción

Parte I: Modelos

1. Modelo booleano
2. Modelo vectorial
3. Comparación de los modelos clásicos
4. Expansión de consultas y retroalimentación
5. Evaluación: Precisión y recuperación

Parte II: Estructuras de Datos

1. Indices invertidos
2. Indices distribuídos
3. Arreglos de sufijos

Parte III: La Web

1. Caracterizando la Web
2. Alternativas para el usuario
3. Arquitectura de las máquinas de búsqueda
4. Algoritmos de ranking
5. Indices para la Web
6. Algoritmos de crawling

¿Qué es Recuperación de Información?

- Recuperar datos (RD) versus recuperar información (RI):

```
SELECT nombre, puesto, salario
FROM Employees
WHERE empresa = "La Caixa" and salario >= 3,000
```

versus

```
Quiero información sobre las consecuencias
de la crisis de los misiles cubanos
en el desarrollo de la guerra fría
```

- Los datos se pueden estructurar en tablas, árboles, etc. para recuperar exactamente lo que se quiere. El texto no tiene estructura clara y no es fácil crearla.
- En RD se sabe exactamente lo que se quiere, en RI no existe *la* respuesta correcta.
- En RI, cada documento puede ser más o menos relevante, y esto puede cambiar según el usuario y la situación.
- En RD sólo importa la eficiencia (básicamente velocidad y espacio), mientras que en RI importa también (o más) la *calidad* de la respuesta.
- Dado que comprender cabalmente el significado de un texto en forma automática es imposible en la práctica, RI busca una *aproximación* a responder lo que el usuario busca.

Problema Formal

- El problema de RI se puede definir como:

  Dada una necesidad de información (consulta + perfil del usuario + ...) y un conjunto de documentos, ordenar los documentos de más a menos relevantes para esa necesidad y presentar un subconjunto de los más relevantes.

- Ejemplo principal: la Web

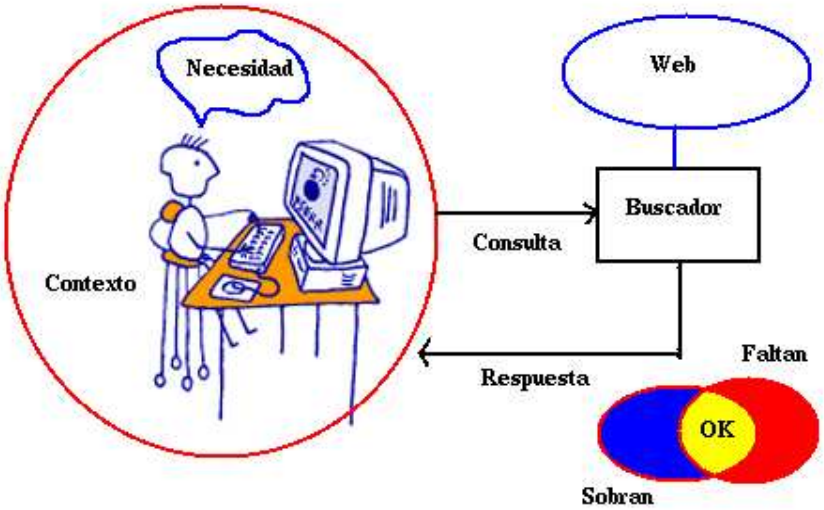

- Varios desafíos técnicos

- Dos grandes etapas para abordar el problema:
  - Elegir un *modelo* que permita calcular la relevancia de un documento frente a una consulta.
  - Diseñar algoritmos y estructuras de datos que lo implementen eficientemente (índices).
- Cuán bien hecha está la primera etapa se mide comparando las respuestas del sistema contra las que un conjunto de expertos consideran relevantes.
- Cuán bien hecha está la segunda etapa se mide considerando el tiempo de respuesta del sistema, espacio extra de los índices, tiempo de construccíon y actualización del índice, etc.
- En general, RI no congenia bien con el modelo relacional. Las extensiones hechas a los RDBMS para incorporar texto son limitadas y no todo lo eficientes que se necesita.
- RI requiere modelos, estructuras de datos y algoritmos especializados.

Parte I

Modelos

O cómo adivinar lo que el usuario realmente quiso preguntar

Modelo Booleano

- La relevancia es binaria: un documento es relevante o no lo es.
- Consultas de una palabra: un documento es relevante si y sólo si contiene la palabra.
- Consultas `AND`: los documentos deben contener todas las palabras.
- Consultas `OR`: los documentos deben contener alguna palabra.
- Consultas A `BUTNOT` B: los documentos deben ser relevantes para A pero no para B.
- Ejemplo: lo mejor de Maradona

```
Maradona AND Mundial
AND ((Mexico'86 OR Italia'90) BUTNOT U.S.A.'94)
```

- Es el modelo más primitivo, y bastante malo para RI.
- Sin embargo, es bastante popular.

- ¿Por qué es malo?
  - No discrimina entre documentos más y menos relevantes.
  - Da lo mismo que un documento contenga una o cien veces las palabras de la consulta.
  - Da lo mismo que cumpla una o todas las cláusulas de un `OR`.
  - No considera un calce parcial de un documento (ej. que cumpla con *casi* todas las cláusulas de un `AND`).
  - No permite siquiera ordenar los resultados.
  - El usuario promedio no lo entiende:

    `"Necesito investigar sobre los Aztecas y los Incas"` $\longrightarrow$ `Aztecas AND Incas`

    (se perderán excelentes documentos que traten una sola de las culturas en profundidad, debió ser `Aztecas OR Incas`)
- ¿Por qué es popular?
  - Es de las primeras ideas que a uno se le ocurren. y los primeros sistemas de RI se basaron en él.
  - Es la opción favorita para manejar texto en una base de datos relacional .
  - Es simple de formalizar y eficiente de implementar.
  - En algunos casos (usuarios expertos) puede ser adecuado.
  - Puede ser útil en combinación con otro modelo, ej. para excluír documentos (Google usa AND como filtro).
  - Puede ser útil con mejores interfaces.

Modelo Vectorial

- Se selecciona un conjunto de palabras útiles para discriminar (*términos* o *keywords*).
- En los sistemas modernos, toda palabra del texto es un término, excepto posiblemente las *stopwords* o *palabras vacías*.
- Se puede enriquecer esto con procesos de *lematización* (o *stemming*), *etiquetado*, e identificación de frases.
- Sea $\{t_1, \ldots, t_k\}$ el conjunto de términos y $\{d_1, \ldots, d_N\}$ el de documentos.
- Un documento d_i se modela como un vector

$$d_i \longrightarrow \vec{d_i} = (w(t_1, d_i), \ldots, w(t_k, d_i))$$

  donde $w(t_r, d_i)$ es el *peso* del término t_r en el documento d_i.
- Hay varias fórmulas para los pesos, una de las más populares es

$$w(t_r, d_i) = w_{r,i} = \frac{tf_{r,i} \times idf_r}{|\vec{d_i}|} = \frac{tf_{r,i} \times \log \frac{N}{n_r}}{\sqrt{\Sigma_{s=1}^{k} \left(tf_{s,i} \times \log \frac{N}{n_s}\right)^2}}$$

  donde $tf_{r,i}$ (term frequency) es la cantidad de veces que t_r aparece en d_i, y n_r es la cantidad de documentos donde aparece t_r.

- Si un término aparece mucho en un documento, se supone que es importante en ese documento (tf crece).
- Pero si aparece en muchos documentos, entonces no es útil para distinguir ningún documento de los otros (idf decrece).
- Además podemos normalizar las frecuencias para no favorecer documentos más largos (por ejemplo $tf_{norm} = tf_{r,d} / \max_{k \in d}(tf_{k,d})$).
- Lo que se intenta medir es cuánto ayuda ese término a distinguir ese documento de los demás.
- Se calcula la *similaridad* entre dos documentos mediante la *distancia coseno*:

$$sim(d_i, d_j) \;=\; \vec{d_i} \cdot \vec{d_j} \;=\; \sum_{r=1}^{k} w_{r,i} \times w_{r,j}$$

(que geométricamente corresponde al coseno del ángulo entre los dos vectores).

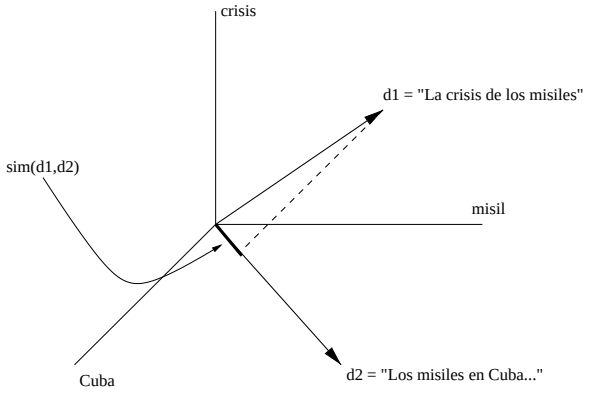

- La similaridad es un valor entre cero y uno.
- Notar que dos documentos iguales tienen similaridad 1, y ortogonales (si no comparten términos) tienen similaridad cero.
- En particular, una consulta se puede ver como un documento (formado por esas palabras) y por lo tanto como un vector.
- Dado que en general cada palabra aparece una sola vez en la consulta y esta es muy corta, se puede en general calcular la *relevancia* de d_i para q con la fórmula

$$sim(d_i, q) \;=\; \sum_{r=1}^{k} w_{r,i} \times w_{r,q} \;\sim\; \sum_{t_r \in q} w_{r,i} \times idf_r$$

- La última fórmula no es idéntica a sim pero genera el mismo orden en los documentos (falta dividir por $|\vec{q}|$).
- Podemos simplificar aún más la fórmula anterior definiendo $w_{r,i} = \frac{tf_{r,i}}{|\vec{d_i}|}$ y $w_{r,q} = idf_r$. El primer peso se llama *factor de impacto*.
- Pero el modelo es más general, y permite cosas como:
  - Que la consulta sea un documento.
  - Hacer *clustering* de documentos similares.
  - Retroalimentación (*Relevance feedback, "documents like this"*).
- Este modelo es, de lejos, el más popular en RI pura hoy en día.

Comparación de los Modelos Clásicos

- El modelo clásico más popular es el vectorial, por ser simple, fácil y eficiente de implementar, y entregar buenos resultados. En muchos casos las aplicaciones llegan hasta aquí.
- Hay modelos más sofisticados. Sin embargo lo que se gana no justifica el esfuerzo.
- Sin embargo, todos los modelos clásicos tienen ciertas falencias comunes, la más notoria de las cuales es la incapacidad para capturar las relaciones entre términos.
- Por ejemplo, si busco

  `guerra fría`

  quisiera recuperar un documento que habla sobre

  `la crisis de los misiles cubanos`

  Sin embargo, el sistema no tiene idea de que ambas cosas están relacionadas y la intersección de vocabulario puede ser nula.
- Parte de la solución pasa por el análisis lingüístico:
  - lematizar (para no perderse variantes de la misma palabra),
  - etiquetar (para distinguir verbos de sustantivos),
  - detectar frases comunes (para no recuperar información sobre heladeras cuando se pregunte por `"guerra fría"`).
  - Es posible hacer un análisis lingüístico más fino, pero la tecnología existente tiene sus limitaciones.
- Otro elemento es el uso de tesauros y sinónimos para expandir la consulta, de modo de poder recuperar

  `vendo camioneta usada`

  frente a la consulta

  `coches de segunda mano`

  Sin embargo, mantener un buen tesauro es costoso en términos de trabajo manual y no suele ser posible mantenerlo al día con las expresiones que van apareciendo.
- Además es sabido que un tesauro global no funciona siempre bien, por ejemplo `"estrella"` puede ser una generalización de `"supernova"` pero no en un contexto que habla de estrellas de televisión.
- Se puede utilizar información del texto como la estructura para refinar mejor la consulta (ej. un término que aparece en el título debe ser más relevante que en un pie de página).
- Se pueden utilizar distintas técnicas para descubrir que ciertos términos están correlacionados. A esto apuntan los modelos alternativos y las técnicas de expansión de consultas que veremos a continuación.

Modelos Alternativos

Estos modelos son en general bastante costosos de implementar, y no siempre dan grandes resultados. Por ello son en general poco populares, con la excepción del modelo probabilístico (otro clásico), LSI y las redes neuronales y Bayesianas.

- Extensiones al modelo Booleano
  - Booleano Extendido
  - Conjuntos Difusos
- Extensiones al modelo Vectorial
  - Vectorial generalizado
  - LSI: Latent Semantic Indexing
  - Redes neuronales
- Modelo Probabilístico
- Extensiones al modelo Probabilístico
  - Redes Bayesianas
  - Redes de Inferencia Bayesiana

Expansión de Consultas

- Es posible asimismo expandir una consulta para mejorar la relevancia del resultado sin alterar el modelo original.
- Un modelo posible es considerar un espacio vectorial donde los *términos son los puntos y los documentos las coordenadas*:

$$t_r \longrightarrow \vec{t_r} = (w_{1,r}, \ldots, w_{N,r})$$

- La similaridad entre términos se define exactamente como la de documentos:

$$sim(t_r, t_s) = \vec{t_r} \cdot \vec{t_s} = \sum_{i=1}^{N} w_{i,r} \times w_{i,s}$$

- Si dos términos tienden a aparecer en los mismos documentos sus vectores serán cercanos.

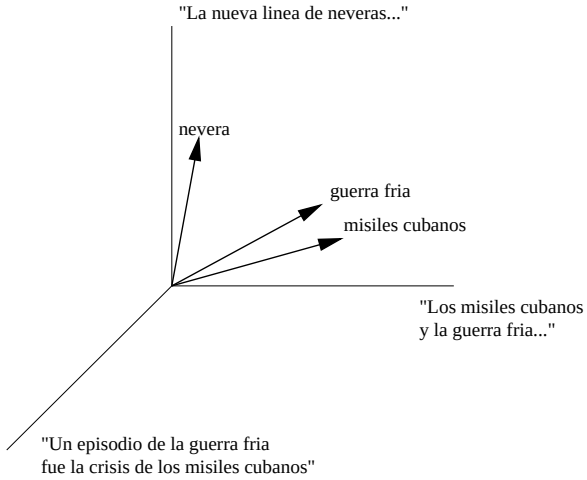

- Dada una consulta formada por términos, éstos se consideran vectores y la consulta se expande con todos los vectores (términos) cercanos a los de la consulta.
- También podemos usar diccionarios o teasuros para agregar sinónimos y/o términos relacionados (será un OR de ellos).
- Otra forma de usar estas distancias es formar *clusters* de términos considerados similares, mediante cualquier método jerárquico (la idea es construír un tesauro automáticamente), y luego recuperar el cluster (a cierto nivel) de la consulta.
- El clustering puede hacerse en forma "local", considerando solamente los documentos recuperados como relevantes, en un estilo parecido al de redes neuronales. Puede definirse la intensidad de la asociación por la distancia en el texto entre los términos (clusters métricos), la fórmula $c_{s,r}$ de conjuntos difusos (clusters de asociación), o la previa donde los términos son puntos (clusters escalares).

Retroalimentación (Relevance Feedback)

- Finalmente, puede preguntársele al usuario cuáles documentos de los recuperados son relevantes y cuáles no, y volver a pesar todo en función de la respuesta.
- Sea V el conjunto de documentos recuperados, que el usuario divide en V_r (relevantes) y V_n (no relevantes). La fórmula clásica de Rochio modifica el vector $\vec{q}$ de la siguiente forma

$$\vec{q_m} = \alpha\vec{q} + \frac{\beta}{|V_r|}\sum_{d_i \in V_r}\vec{d_i} - \frac{\gamma}{|V_n|}\sum_{d_i \in V_n}\vec{d_i}$$

- La idea es "acercar" el vector $\vec{q}$ al conjunto de documentos relevantes y "alejarlo" del conjunto de documentos no relevantes.
- Se puede particularizar según el caso. Por ejemplo, puede ser mucho pedir que el usuario marque los documentos no relevantes. En ese caso se puede usar $\gamma = 0$ (retroalimentación positiva).
- El "documents like this" de varios buscadores Web utiliza una versión sencilla de esta fórmula.

Evaluación: Precisión y Recuperación

- Finalmente, ¿cómo mediremos la bondad de un modelo para RI?
- Hay muchas medidas, pero la más popular es un diagrama de *precisión – recuperación* (precision – recall).
- *Precisión:* cuántos documentos recuperados son relevantes.
- *Recuperación:* cuántos documentos relevantes se recuperaron (también se traduce como exhaustividad).

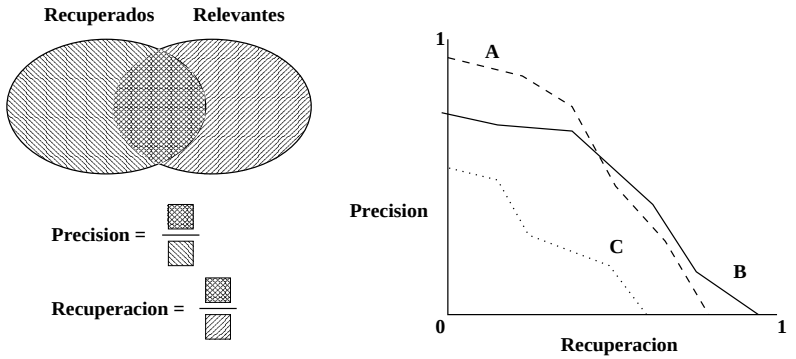

- Según la cantidad que se elige como relevantes, se puede hacer aumentar una a costa de reducir la otra.
- Para evaluar un modelo de RI se debe tener en cuenta todo el gráfico. En la figura, A o B pueden ser preferibles según la aplicación.
- En ciertos casos, como la Web, puede ser imposible calcular la recuperación. Se puede hacer mediante muestreo.
- Es fácil tener alta precisión: basta con retornar el documento más relevante, pero entonces la recuperación es cercana a 0. Es fácil tener alta recuperación: basta retornar todos los documentos, pero ahora la precisión es cercana a 0. El objetivo es tratar de aumentar ambos al mismo tiempo.
- Para comparar dos sistemas tenemos que decidir que precisión y/o recuperación necesitamos.
- Además necesitamos una colección de referencia: documentos, preguntas y respuestas correctas (e.g. TREC)

Parte II

Estructuras de Datos: Indices

O cómo, además de adivinar,
no tardarse demasiado

Indices Invertidos

- Es la estructura más elemental para recuperación de palabras.
- En su versión más básica, consta de dos partes:

  Vocabulario: conjunto de términos distintos del texto.

  Posteo: para cada término, la lista de documentos donde aparece.

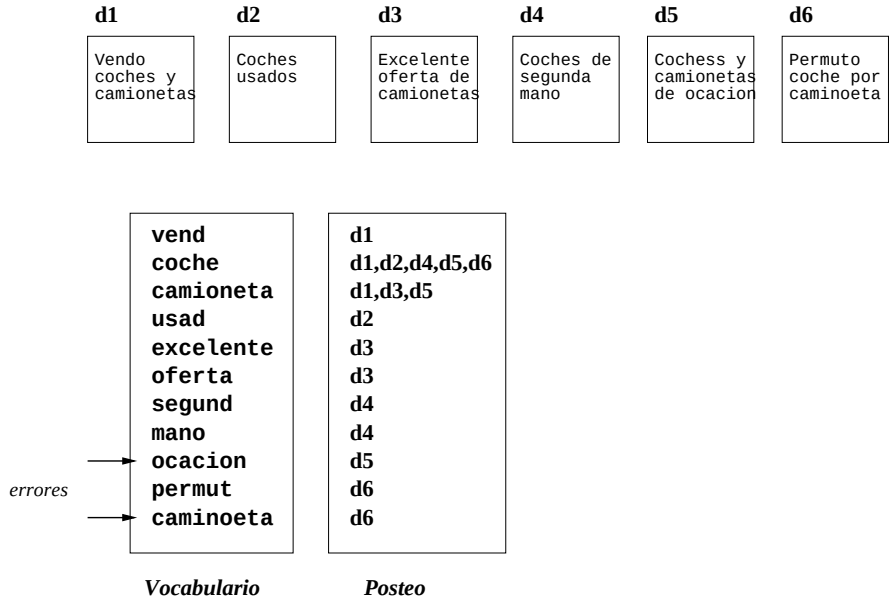

- Variante para los modelos booleano:
  - Es conveniente almacenar la lista de posteo de cada término en orden creciente de documento.
- Variante para el modelo vectorial:
  - Debe almacenar el tf correspondiente en cada entrada de posteo (puede ser el factor de impacto $tf/|d_i|$).
  - Debe almacenar el idf correspondiente en cada entrada del vocabulario.
  - Es conveniente almacenar el máximo tf de cada término en el vocabulario.
  - Es conveniente almacenar la lista de posteo de cada término en orden decreciente de tf.
- Variante para búsqueda de frases:
  - Se debe almacenar además la **inversión**: para cada término y documento, la lista de sus posiciones exactas en el documento.
  - Para reducir espacio, se puede tener un *índice de bloques*: se corta el texto en grandes bloques y se almacena sólo los bloques donde ocurre cada término.

Indices Invertidos: Consulta en el Modelo Booleano

- Las palabras de la consulta se buscan en el vocabulario (que está en memoria), por ejemplo usando hashing.
- Se recuperan de disco las listas de posteo de cada palabra involucrada (restricciones de metadatos).
- Se realizan las operaciones de conjuntos correspondientes sobre ellas (unión, intersección, diferencia).
- Las listas están ordenadas crecientemente, de modo que se puede operar recorriéndolas secuencialmente. Los documentos se recuperan ordenados por número de documento.
- Si una lista es muy corta y la otra muy larga, es más rápido buscar binariamente la corta en la larga ($O(1)$ por Zipf).
- Esto se complica si las listas están representadas por diferencias, pero se puede almacenar cada tanto un valor absoluto.
- Se puede usar evaluación completa o parcial (restricciones AND, BUTNOT).

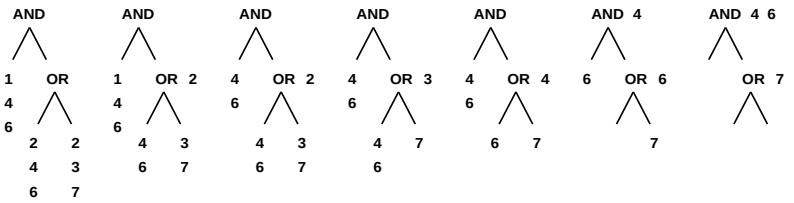

Indices Invertidos: Consulta en el Modelo Vectorial

- La consulta puede tener muchas palabras y sólo nos interesa recuperar los R documentos más relevantes.
- Por otro lado, los documentos de cada término están almacenados en orden decreciente de tf.
- La idea es mantener un *ranking* de los R documentos d_i con mayor $sim(d_i, q)$.
- Partimos con el término de la consulta de mayor idf (lista de posteo más corta), y traemos los R primeros documentos de su lista (almacenados en ese orden).
- Si no llegamos a juntar R, seguimos con el segundo término de mayor idf y así.
- Una vez que tenemos ya R candidatos, seguimos recorriendo las listas de los términos, de mayor a menor idf.
- Sin embargo, como el tf en cada lista decrece, podemos en cierto momento determinar que no es necesario seguir recorriendo la lista pues los candidatos no pueden entrar al ranking de los R mejores.
- Si se almacena el máximo tf en el vocabulario, es posible eliminar términos completos sin siquiera ir al disco una vez.
- Puede hacerse incluso más eficiente cortando las listas donde se considere *improbable* que modifiquen el ranking.
- Este tipo de "relajamiento" está permitido en RI y es muy utilizado en las máquinas de búsqueda para la Web.
- En particular, en la Web la *recuperación* no sólo es difícil de medir sino que ya viene condicionada por el crawling, que raramente alcanza a cubrir el 50 % del total. De modo que las máquinas de búsqueda se concentran más en la precisión. Es decir, que lo que se recupera sea bueno más que recuperar todo lo bueno.

quiero informacion sobre las consecuencias de la crisis de los misiles cubanos en el desarrollo de la guerra fria

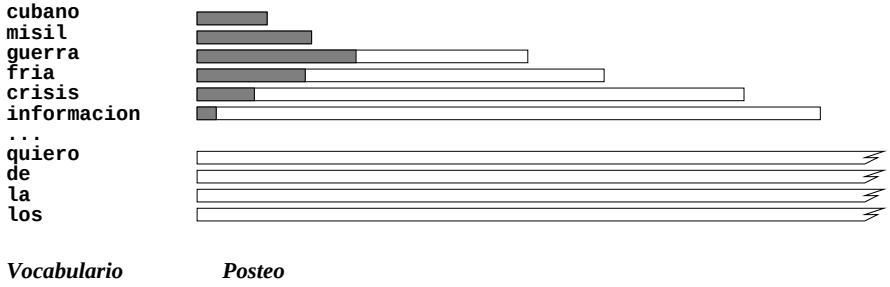

Indices Invertidos: Búsqueda de Frases

- Para búsqueda por frases o proximidad, se obtienen las listas de las ocurrencias exactas de las palabras involucradas y se realiza una pseudo intersección (inversión, secuencial o combinado).
- Si se tiene sólo un índice de bloques, éste permitirá determinar que el patrón no aparece en algunos bloques del texto, pero en los demás se deberá recurrir a búsqueda secuencial (compresión).
- Se ha probado que eligiendo correctamente el tamaño del bloque se puede obtener un índice que sea sublineal en espacio extra y tiempo de búsqueda simultáneamente.
- Esta es una alternativa aceptable para colecciones medianas (200 Mb) y necesita tener acceso al texto (ej. no sirve para indexar la Web pero sí para un buscador interno del sitio Web).
- Para búsquedas más complicadas se puede realizar una búsqueda *secuencial* en el vocabulario. Esto es tolerable por la ley de Heaps (se explica a continuación).
- Luego se realiza la unión de las listas de posteo de todas las palabras del vocabulario que calzaron con el patrón de la búsqueda. Observar que esto puede ser costoso si la consulta tiene poca precisión.

Ejemplo:

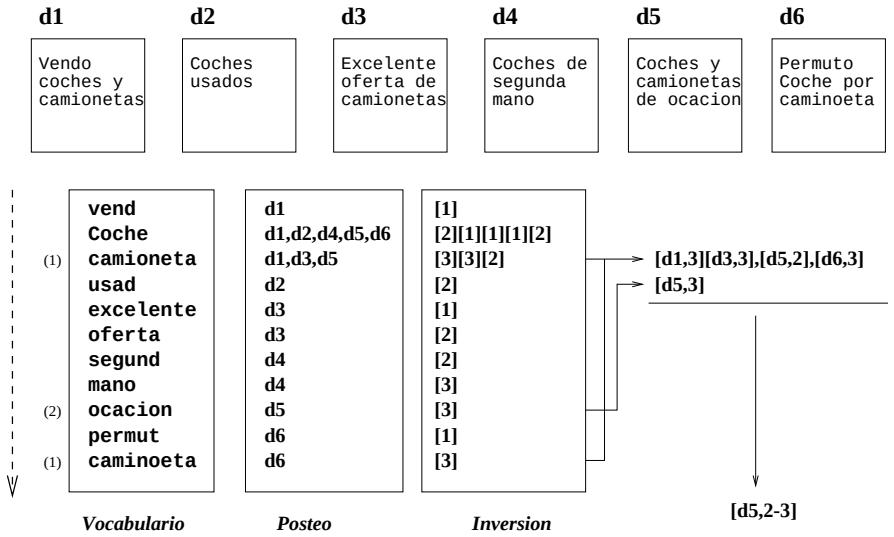

"Camioneta de ocasion" [con errores]

Indices Invertidos: Espacio Extra

- Dos leyes empíricas importantes, ampliamente aceptadas en RI.
- Ley de Heaps: el vocabulario de un texto de largo n crece como

$$k \;=\; C \times n^{\beta}$$

  donde C y $0 < \beta < 1$ dependen del tipo de texto. En la práctica, $5 < C < 50$ y $0{,}4 \leq \beta \leq 0{,}6$, y k es menos del 1 % de n.
- En la práctica el vocabulario entra en memoria RAM (ej. 5 Mb para 1 Gb de texto).
- Ley de Zipf: si se ordenan los términos de un texto de más a menos frecuente, entonces

$$n_r \;=\; \frac{N}{r^{\alpha} H_N(\alpha)}$$

  donde

$$H_N(\alpha) \;=\; \sum_{r=1}^{k} \frac{1}{r^{\alpha}}$$

  lo que significa que la distribución es muy sesgada: unas pocas palabras (las stopwords) aparecen muchas veces y muchas aparecen pocas veces.
- En particular, las stopwords se llevan el 40 %-50 % de las ocurrencias y aproximadamente la mitad de las palabras aparecen sólo una vez.
- Notar que la Ley de Heap puede deducirse a partir de la Ley de Zipf y entonces $\alpha = 1/\beta$.

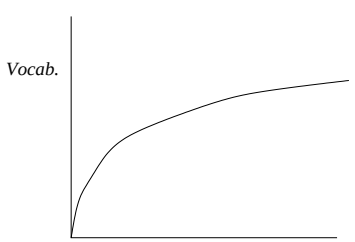

Ley de Heaps

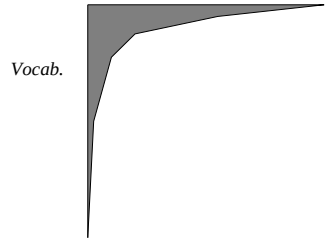

Ley de Zipf

- Posteo/Inversión:
  - Caso booleano: los números de documentos son crecientes, se pueden almacenar las diferencias (Elías). Así comprimido, requiere un 10 %-25 % extra sobre el texto.
  - Caso vectorial: eso ya no ocurre, pero todos los documentos con el mismo tf (muchos, por Zipf) pueden aún ordenarse. El índice requiere 15 %-30 % extra.
  - Búsqueda de frases: la inversión lleva el espacio total a 25 %-45 % extra (posiciones crecientes).
  - Con direccionamiento a bloques ésto puede bajar hasta a 4 % para colecciones no muy grandes, al costo de mayor búsqueda secuencial.
  - Se puede comprimir el texto a 25 %-30 % del espacio original (Huffman sobre palabras).

Indices Invertidos: Construcción

- Se recorre la colección de texto secuencialmente.
- Para cada término leído, se busca en el vocabulario (que se mantiene en memoria).
- Si el término no existe aún, se lo agrega al vocabulario con una lista de posteo vacía.
- Se agrega el documento que se está leyendo al final de la lista de posteo del término.
- Una vez leída toda la colección, el índice se graba en disco.
- En el caso de índices de bloques, se construye sólo el posteo considerando a los bloques como documentos.
- En el caso de necesitar inversión, se almacena además de la lista de posteo de cada término una de inversión, donde se debe almacenar la posición de cada ocurrencia de ese término.
- En el caso de los índices para el modelo vectorial, la lista de posteo está ordenada por tf y dentro del tf por número de documento. A medida que vamos encontrando más y más veces el término en el mismo documento su entrada va siendo promovida más adelante en la lista del término.
- Otro método: generar las tuplas $(t_r, tf_{r,i}, i)$ y luego ordenar, pero no se puede comprimir hasta el final.

- El mayor problema que se presenta en la práctica es que, obviamente, la memoria RAM se terminará antes de poder procesar todo el texto.
- Cada vez que la memoria RAM se agota, se graba en disco un *índice parcial*, se libera la memoria y se comienza de cero.
- Al final, se realiza un *merge* de los índices parciales. Esta mezcla no requiere demasiada memoria porque es un proceso secuencial, y resulta relativamente rápido en I/O porque el tamaño a procesar es bastante menos que el texto original.
- Aridad del merge, orden de la mezcla, forma de hacer la mezcla.
- El método se adapta fácilmente para actualizar el índice.

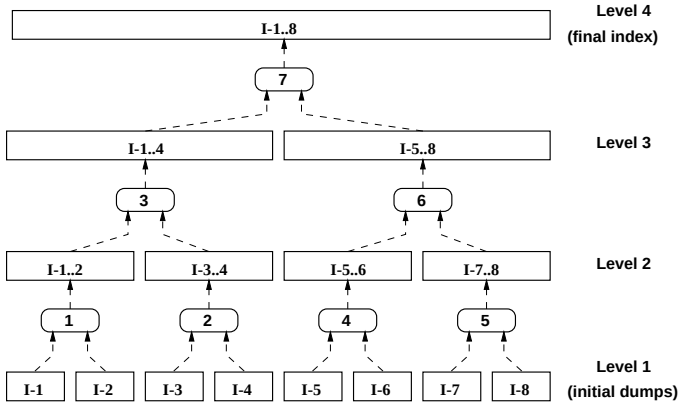

Indices Invertidos Distribuídos

- En muchos casos, por bueno que sea el algoritmo de indexación o de búsqueda, no es suficiente para cubrir la demanda:
  - El texto es demasiado grande
  - La frecuencia de actualización es demasiado alta
  - Llegan demasiadas consultas por segundo
  - La velocidad de los discos no está creciendo al ritmo necesario.
- Una alternativa es utilizar paralelismo. Bien diseñado, puede expandir la capacidad de procesamiento tanto como se quiera.
- Las redes muy rápidas formadas por unas pocas máquinas muy potentes se han convertido en una alternativa de bajo costo.
- En estas redes el acceso remoto cuesta aproximadamente lo mismo que el acceso al disco local.
- Normalmente todos los procesadores pueden comunicarse de a pares sin causar congestión.
- Se puede considerar el total de RAMs como una gran memoria distribuída.

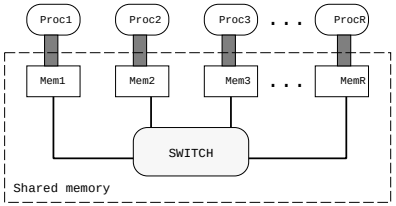

- Podemos utilizar un conjunto de máquinas de diversas formas:
  - Para construír (o actualizar) el índice en paralelo.
  - Para replicar el índice (si no es muy grande).
  - Para particionar el texto.
- Dos medidas de interés para las consultas
  - *Concurrencia (Throughput)*: cantidad de consultas respondidas por segundo.
  - *Tiempo de respuesta*: tiempo que demora una consulta particular.
- Mayor concurrencia: replicar máquina de consultas e índices.
- Mayor volumen: particionar el índice.

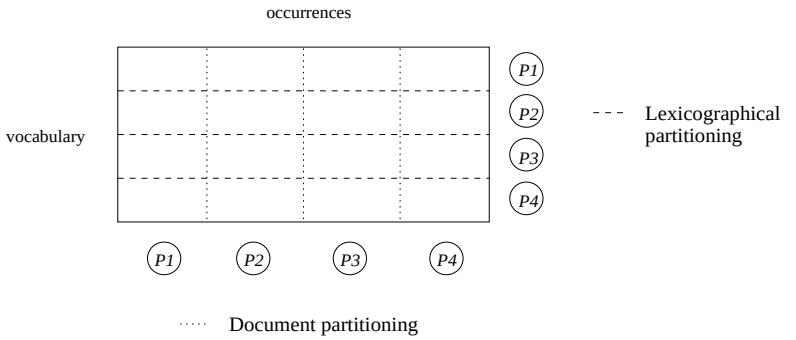

Generación Distribuída de Indices Invertidos

1. Se distribuye el texto entre las máquinas equitativamente.
2. Cada máquina construye su índice invertido local.
3. Se aparean de a dos, jerárquicamente, hasta que una sola contiene todo el vocabulario.
4. Esa máquina calcula qué parte del vocabulario será responsabilidad de cada procesador, y distribuye esa información.
5. Los procesadores se aparean todos con todos intercambiando las listas de posteo.
6. Secuencialmente transmiten su parte del índice a un disco central, donde se concatenan para formar un índice centralizado.

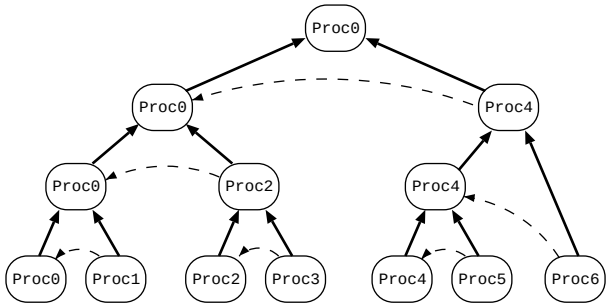

Tipos de Indices Invertidos Distribuídos

- Si nos detenemos en el punto (2), tenemos un índice particionado por documentos.
  - Para consultar se debe distribuír la consulta a todos los procesadores y luego integrar los resultados.
  - El trabajo se reparte bien, pero como el tiempo es sublineal, el throughput no escala idealmente.
  - El tiempo de respuesta se reduce un poco.
  - Para el modelo booleano es ideal porque no transmite información redundante por la red.
  - Para el modelo vectorial debe seleccionar lo mejor de todos los rankings, pero presenta un problema grave: los rankings locales no coinciden con el ranking global.
  - Otro problema posible son los documentos muy populares que pueden generar una carga mal repartida.
  - En sistemas heterogéneos suele ser la única opción.
- Si nos detenemos en el punto (4), tenemos una versión de lo anterior que resuelve el problema del ranking inconsistente.

- Si nos detenemos en el punto (5), tenemos un índice particionado por léxico.
  - Para consultar se pide a cada procesador que resuelva las palabras de las que es responsable y luego se coopera para integrar los resultados.
  - En consultas cortas maximiza el throughput, pero el tiempo de respuesta puede no variar porque toda la consulta la sigue resolviendo un procesador (salvo si hay congestión).
  - En consultas complejas tiene el problema de enviar demasiada información por la red (para el caso booleano). Mismo algoritmo que con las listas.
  - Para el modelo vectorial es problemático responder con exactitud por la misma razón que cuando se cortaba el recorrido de listas invertidas. Mismo algoritmo que con las listas.
  - Para la Web es bueno porque la mayoría de las consultas son muy cortas y suele haber congestión, de modo que escala casi idealmente.
  - Un problema posible son los términos muy populares que pueden generar una carga mal repartida.
- Si llegamos hasta el final tenemos un índice centralizado (construído en forma distribuída), que puede ser replicado en todos los procesadores
  - Sólo es factible si una sola máquina puede manejar toda la colección.
  - Permite repartir idealmente el trabajo y es tolerante a fallas.

Indices para Caracteres

- Trie (árbol digital) y árbol de sufijos
  - Trie con todos los sufijos del texto.
  - Búsqueda simple en tiempo $O(m)$
  - Cada nodo es un intervalo en el arreglo de sufijos.
  - El árbol comprime caminos unarios, $O(n)$ espacio y tiempo de construcción (árboles Patricia).
  - Ocupan mucho espacio, 8 a 12 veces el tamaño del texto.
  - Malos en memoria secundaria.
  - Puede utilizarse la idea para búsqueda secuencial en el vocabulario.
- Solución: eliminar el árbol y quedarse con las hojas (espacio de 1 a 4 veces el texto)

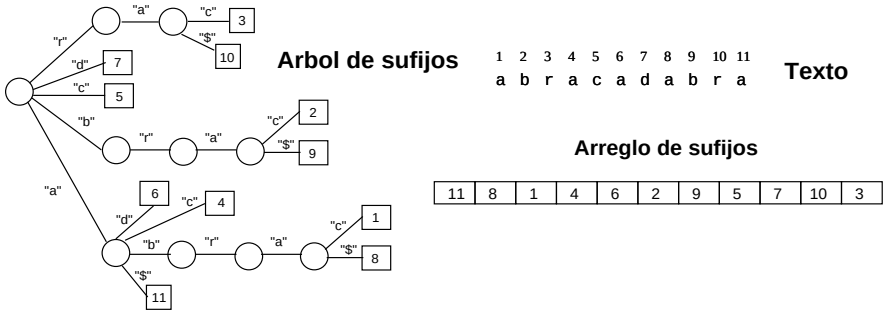

Arreglos de Sufijos

- Es un índice que no necesita que el texto esté formado por palabras.
- Es capaz de recuperar cualquier substring del texto, buscar expresiones regulares y realizar búsqueda aproximada en tiempo sublineal.
- Resulta ideal para biología computacional, lenguajes orientales, etc.
- En RI tradicional, puede resultar útil para
  - Análisis lingüístico especializado (ej. encontrar la autorrepetición más larga de una colección, permitiendo errores).
  - Búsqueda de frases de varias palabras (es más rápido que un índice invertido).
  - Búsqueda de patrones que trascienda palabras (ej. el índice invertido no permite detectar errores que involucren separadores).
- El espacio que requiere es cercano al 40 % del texto.
- Es más costoso de construír y mantener que un índice invertido.
- Es superior al índice invertido para búsqueda de patrones, pero no para las otras operaciones típicas en RI.

Arreglos de Sufijos: Estructura

- El arreglo de sufijos es simplemente un array con los punteros a todas las posiciones de interés en el texto.
- Cada posición define un *sufijo* del texto.

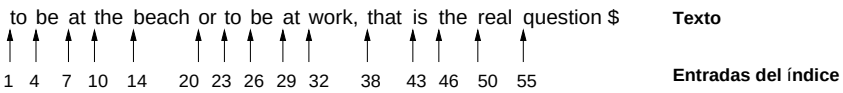

1: to be at the beach or to be at work, that is the real question
4: be at the beach or to be at work, that is the real question
7: at the beach or to be at work, that is the real question
10: the beach or to be at work, that is the real question
.....
55: question

Sufijos

- En el arreglo, las posiciones están ordenadas *lexicográficamente* por los sufijos.

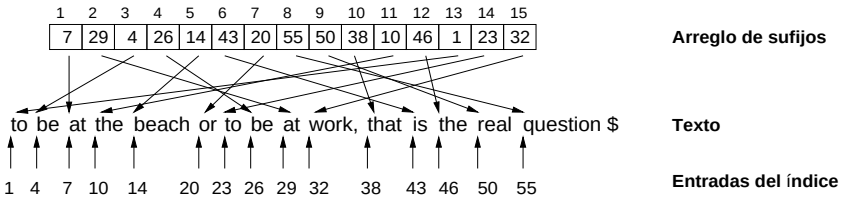

Arreglos de Sufijos: Búsqueda

- Todo substring del texto es el prefijo de un sufijo.
- La relación *prefijo de* puede traducirse a relaciones de orden lexicográfico:

$$x : a \text{ prefijo de } y \iff (x : a \leq y) \wedge (y < x : (a+1))$$

- Por lo tanto, basta un par de búsquedas binarias en el arreglo de sufijos para obtener el rango del arreglo que contiene todas las ocurrencias de x (en tiempo logarítmico).

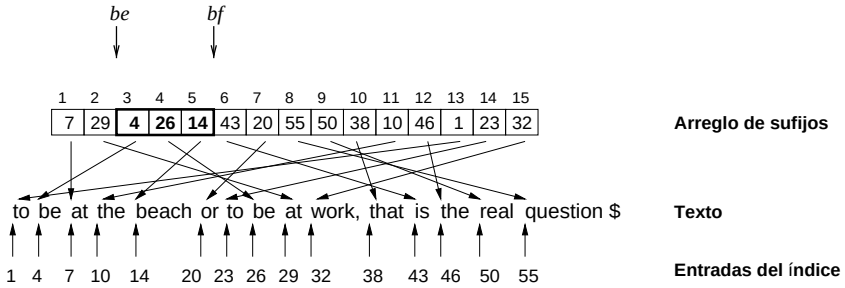

- En memoria secundaria la búsqueda binaria puede resultar costosa. El problema no es tanto el acceso al arreglo de sufijos sino a las posiciones aleatorias del texto.
- Se pueden usar *supraíndices* en RAM para reducir este costo.

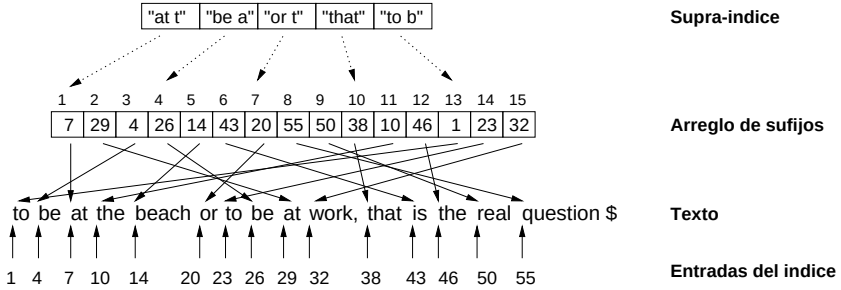

- Un supraíndice interesante puede ser el mismo vocabulario.

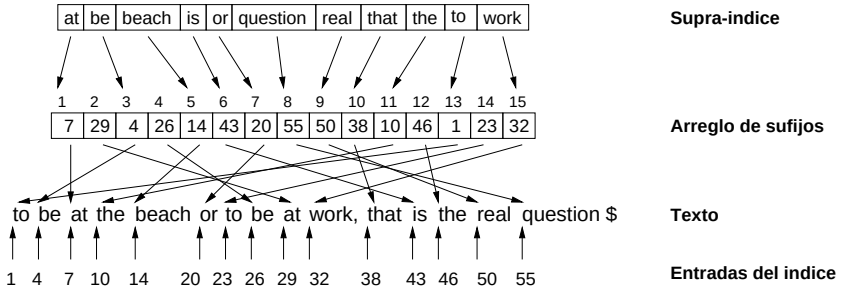

- En este caso la estructura es muy similar a un índice invertido para búsqueda de patrones (con inversión).

Arreglo de Sufijos: Construcción

- En principio, no es más que ordenar un arreglo.
- Sin embargo, se puede aprovechar la estructura del problema: los sufijos son sufijos de otros sufijos.
- Existen algoritmos (Manber & Myers) que en promedio toman tiempo $O(n \log \log n)$.
- Sin embargo, el verdadero problema aparece en memoria secundaria, por los accesos aleatorios al texto.
- La mejor solución ($O((n^2/M) \log M)$) es la siguiente:
  - Cortar el texto en bloques que se puedan indexar en memoria.
  - Traerse el primer bloque, construír su arreglo y mandarlo a disco.
  - Al procesar el bloque i, el invariante es que el arreglo de sufijos para los $i-1$ bloques anteriores estáconstruído.
  - Traer el bloque i-ésimo y construír su arreglo de sufijos.
  - Leer el texto de los $i-1$ bloques anteriores y buscar cada sufijo en el arreglo del bloque i-ésimo.
  - Determinar así cuántos sufijos del arreglo grande van entre cada par de posiciones del arreglo chico.
  - Realizar el merge secuencial de los dos arreglos con esa información.

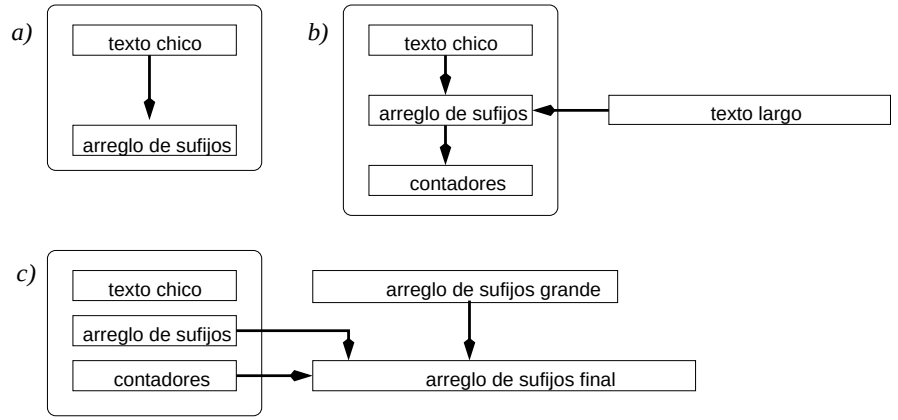

- El método se adapta fácilmente para actualizar el índice.
- Recientemente se han encontrado algoritmos lineales que aún no son competitivos.

Parte III

La Web: RI contra adversarios

O cómo adivinar, y rápido,
lo que la mitad del planeta quiere decir
y lo que la otra mitad quiere saber.

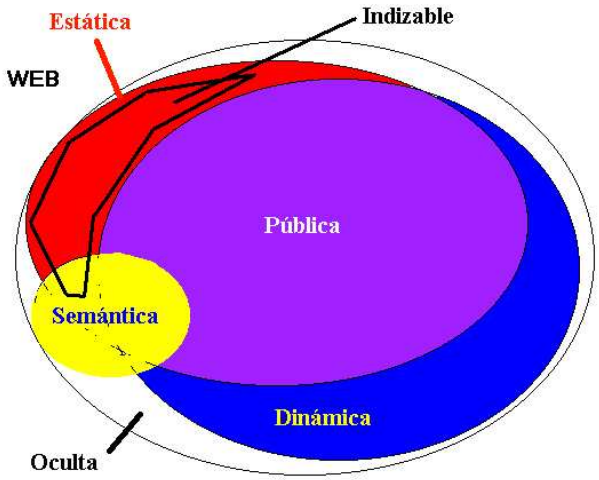

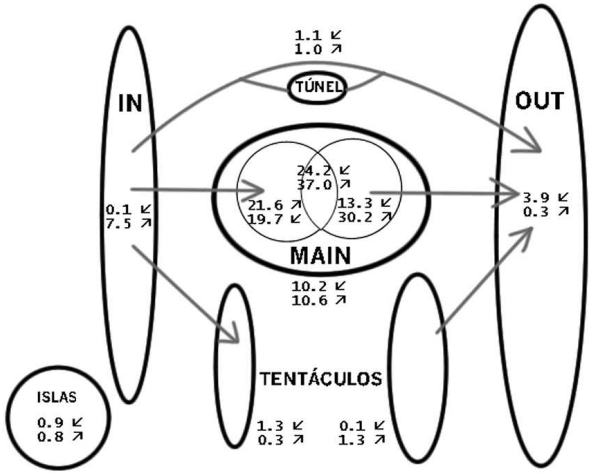

Caracterizando la Web

- Se puede considerar como un gigantesco texto distribuído en una red de baja calidad, con contenido pobremente escrito, no focalizado, sin una buena organización y consultado por los usuarios más inexpertos.
- Principales desafíos (datos de 2004):
  - Gigantesco volumen de texto (más de 100 Tb sólo de texto)
  - Información distribuída y conectada por una red de calidad variable (60 millones de sitios Web, más de 10.000 millones de páginas).
  - Contenido altamente volátil (el 50 % cambia o nace en seis meses, y duplica su tamaño en 9 meses).
  - La mayoría de las páginas son dinámicas y están ocultas.
  - Información mal estructurada y redundante (aproximadamente 20 % de las páginas son prácticamente duplicados).
  - Información de mala calidad, sin revisión editorial de forma ni contenido (1 error de tipeo cada 200 palabras comunes y cada 3 apellidos extranjeros).
  - Información heterogénea: tipos de datos, formatos, idiomas, alfabetos.
  - *Spam* de texto, metadatos, enlaces, uso, etc.
- Hipótesis: páginas físicas son documentos lógicos
- ¡Es la peor pesadilla para un sistema de RI!
- Otras estadísticas de interés
  - Sitios Web no uniformes: el 1 % de los sites tiene el 50 % de las páginas.
  - Tamaños de documentos no uniformes: en promedio una página tiene como 8 Kb de texto (es casi tan malo como indexar posiciones exactas); más del 90 % de las páginas tiene menos de 10 Kb, pero hay una cantidad no despreciable de documentos grandes.
  - En promedio de una página salen 8 enlaces, la mayoría locales. La “red” no está muy densamente conectada: el 80 % de las *homepages* recibe menos de 10 enlaces desde fuera.
  - Yahoo!, ODP (dmoz.org) y otros directorios es quien más enlaces hacia fuera tiene. Microsoft, Google, Yahoo! y las mejores universidades de U.S.A. son quienes reciben más enlaces. Los directorios como Yahoo! son quienes verdaderamente “conectan” la Web.
  - 50 % de las páginas están en inglés, 5 % en alemán y japonés, 4 % en castellano, etc.
  - Hay más de 300 millones de internautas.

Alternativas para el Usuario

- Puede utilizar directorios como Yahoo! (bueno cuando se sabe exactamente lo que se busca) o buscadores generales (bueno en el otro caso). Y siempre puede hacer browsing usando los enlaces.
- Una propuesta interesante es WebGlimpse, que intercepta la navegación para agregar una caja de búsqueda al final de cada página entregada. Esta caja permite buscar en la vecindad de la página actual.
- Otra alternativa útil son los *metabuscadores*, que dan una única interfaz y consultan a varios buscadores. Su principal argumento a favor es la poca cobertura e intersección entre buscadores específicos (la intersección entre los 3 mayores es pequeña). Sus principales problemas son
  - Ranking inconsistente (distinto) entre los resultados obtenidos.
  - Distintos lenguajes de consulta en cada buscador.
  - No son queridos por los buscadores (pues viven de la publicidad), quienes tratan de hacerles la vida difícil.
  - Lo que vemos en un índice es como las estrellas del cielo: jamás existió. Cada página se indexó en un momento distinto del tiempo (pero al ir a ella obtenemos el contenido actual).
- Un problema para el usuario es que la misma consulta tiene distinta semántica según el buscador, y además los usuarios no suelen entender esta semántica (problemas con el modelo booleano, mala elección de palabras para la consulta, etc.).
- A la hora de seleccionar un buscador, los usuarios consideran facilidad de uso, velocidad, cobertura, calidad de la respuesta y hábito.
- Algunas estadísticas sobre cómo consultan los usuarios Web
  - El 80 % de las consultas no usa ningún tipo de operador.
  - El 25 % de los usuarios usa normalmente *una sola palabra* en su consulta, y en promedio usan 2. Esto afecta la calidad el ranking pero simplifica el algoritmo de consulta.
  - Sólo el 15 % restringe la búsqueda a un tema determinado.
  - Un 80 % no modifica la consulta (retroalimentación nula).
  - Un 85 % sólo mira la lista de los primeros calces (en promedio dos páginas).
  - En promedio se navegan dos páginas de los resultados.
  - Un 65 % de las consultas son únicas (recordar caching).
  - Muchas palabras de la consulta suelen aparecer en la misma frase, es bueno buscar y dar ranking por proximidad.
- Diseñar buenas interfaces es un desafío interesante.
- Está creciendo la idea de que vale la pena enseñarle al usuario a buscar lo que quiere más que tratar de adivinarlo.

Arquitectura de las máquinas de búsqueda

- Componentes básicos
  - *Crawler:* recorre la Web buscando las páginas a indexar.
  - *Indexador:* manteniene un índice con esa información.
  - *Máquina de consultas:* realiza las búsquedas en el índice.
  - *Interfaz:* interactúa con el usuario.
- Arquitectura centralizada (ej. AltaVista)
  - El crawler (robot, spider...) corre *localmente* en la máquina de búsqueda, recorriendo la Web mediante pedidos a los servers y trayendo el texto de las páginas Web que va encontrando.
  - El indexador corre localmente y mantiene un índice sobre las páginas que le trae el crawler.
  - La máquina de consultas también corre localmente y realiza las búsquedas en el índice, retornando básicamente las URLs ordenadas.
  - La interfaz corre en el cliente (en cualquier parte de la Web) y se encarga de recibir la consulta, mostrar los resultados, retroalimentación, etc.

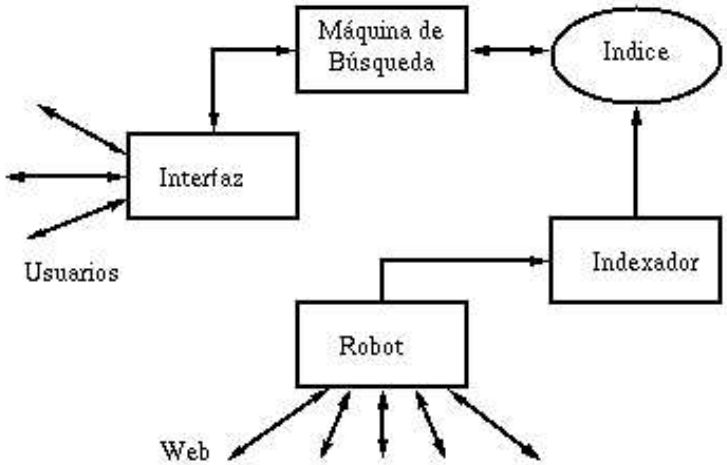

- En 1998, AltaVista corría sobre 20 máquinas multiprocesador, en conjunto con más de 130 Gb de RAM y más de 500 Gb de disco. La búsqueda consumía 75 % de esos recursos, respondiendo 13 millones de consultas diarias (es decir, en el mejor de los casos, 150 consultas por segundo). Todo esto cuando AltaVista indexaba el 50 % de la Web (140 millones de páginas – 660 Gb).
- En el 2004 Google usaba más de 20 mil PCs con 1Gb RAM ejecutando Linux.

- Problemas de una arquitectura centralizada
  - El crawling es la actividad más lenta, y posiblemente en el futuro el tamaño de la Web y su dinamismo hagan imposible que se realice en forma centralizada. Actualmente las mejores máquinas indexan sólo un 25 % de la Web. Notar que esto no se resuelve haciendo el crawling con varias máquinas.
  - Los servidores Web se saturan con pedidos de diferentes crawlers.
  - Las redes se saturan innecesariamente porque los crawlers traen toda la página, para luego descartar casi todo su contenido (polling vs. interrupciones).
  - Cada crawler recolecta independientemente, sin cooperar.
- Existen arquitecturas distribuídas como Harvest
  - *Gatherer:* recolecta páginas de ciertos servidores Web y extrae la información a indexar, periódicamente.
  - *Broker:* indexa la información de determinados gatherers *y otros brokers* y responde consultas.
  - Se pueden organizar de distintas formas.
  - Por ejemplo, un gatherer puede ser local y no generar tráfico, y enviar la información a varios brokers, evitando repetir la recolección.
  - Los brokers pueden construír índices y enviar esos índices a otros brokers, que mezclarán varios, evitando transmitir tanta información y reindexar tanto.

Algoritmos de Ranking

- Es una de las partes más difíciles.
- La mayoría de las máquinas Web usa variantes del modelo booleano o vectorial. El texto *no* suele estar accesible al momento de la consulta, de modo que por ejemplo clustering métrico es impensable. Incluso si el texto se almacena localmente, el proceso es lento.
- No hay mucha información publicada sobre ésto, y en todo caso medir la recuperación es casi imposible.
- Una diferencia importante entre indexar la Web y la RI normal está dada por los enlaces. Algunos métodos modernos explotan esta información.
- Por ejemplo, una página que recibe muchos enlaces se puede considerar muy popular. Páginas muy conectadas entre sí o referenciadas desde la misma página podrían tener contenido similar.
- ¿Es bueno ordenar por popularidad? ¿No terminaremos viendo novelas y programas de animación como en la TV? ¡El efecto se retroalimenta!
- Ej. WebQuery utiliza métodos “locales”: a partir de la respuesta normal, re-ordena usando información de cuán conectadas están las páginas y trae otras páginas que reciban muchas conexiones del conjunto ya recuperado.

- PageRank, un esquema utilizado por Google, considera la probabilidad de visitar una página realizando una navegación aleatoria en la que nos aburrimos con probabilidad q y escogemos al azar una página cualquiera de la Web. Sino, seguimos con la misma probabilidad cualquier enlace en la página. Es decir, tenemos que la probabilidad de visitar la página p está dada por:

$$PR(p) = \frac{q}{T} + (1-q) \sum_{v_i \in V} \frac{PR(v_i)}{L_{v_i}}$$

  donde T es el número total de páginas y $V = \{v_i\}$ es el conjunto de páginas que apuntan a p. Cuando realizamos una búsqueda, seleccionamos las páginas que calzan con la consulta y proyectamos estas páginas al orden ascendente dado por PR.

- Otro esquema (HITS) toma el conjunto S de páginas de la respuesta más las que están a un enlace de distancia (directo o inverso). Llama *autoridades* a las páginas que reciben muchos enlaces desde S (que deberían tener contenido relevante) y *hubs* a las que apuntan mucho a S (deberían apuntar a contenido similar).

- HITS considera que los buenos hubs y autoridades están conectadas, y los evalúa usando

$$H(p) = \sum_{u \in S, p \to u} A(u), \quad A(p) = \sum_{v \in S, v \to p} H(v),$$

- Un problema con esto es que el contenido se puede difuminar, pero se puede resolver utilizando ranking clásico.

- Las pruebas muestran que la precisión y recuperación mejoran significativamente.

Indices para la Web

- La mayoría usa variantes del índice invertido.

- No se puede almacenar el texto completo, por el volumen que representa.

- Se almacenan algunas cosas, como el título y otros atributos: fecha de modificación, tamaño, etc.

- Si suponemos 500 bytes por página, sólo las descripciones requieren 50 Gb para 100 millones de páginas.

- Dados los tamaños de las páginas Web, los índices requieren aproximadamente 30 % del tamaño del texto. Para las 100 millones de páginas a 5 Kb de texto por página esto representa unos 150 Gb de índice.

- Algunos buscadores permiten búsquedas de frase y proximidad, pero no se sabe cómo las implementan.

- Normalmente no permiten búsquedas aproximadas o patrones extendidos arbitrarios, pues la búsqueda en el vocabulario suele ser impensable dada la carga de la máquina de consultas. 1 Tb de texto generaría un vocabulario de 300 Mb según Heaps, lo que requiere unos 10-300 segundos para ser recorrido secuencialmente.

- Aún así, máquinas como Google sugieren variantes a términos no encontrados o muy poco frecuentes.

- Al usuario se le presentan sólo los primeros 10–20 documentos. El resto de la respuesta se calcula cuando los pida el usuario o parte de ella se guarda temporalmente en memoria, para evitar recalcularlos.
- Un problema con ésto es que el protocolo HTTP no tiene el concepto de sesión. ¿Cómo saber que el usuario no está más ahí y descartar la respuesta?
- Una idea interesante para reducir tiempos de consulta es *caching*: mantener las respuestas a las consultas más populares en memoria (¿qué es una consulta, palabras o toda la consulta?), o las páginas más populares, o los pedazos de listas invertidas más populares, etc.
- Otras capacidades interesantes que algunas máquinas tienen son la restricción por dominios, fechas, tamaños, idioma, directorios, etc.

Algoritmos de Crawling

- Se comienza desde un conjunto de URLs muy populares o enviadas explícitamente por administradores de Web sites, y se siguen los enlaces desde allí recursivamente, evitando repeticiones.
- El recorrido puede ser *breadth-first* (cobertura amplia pero no profunda) o *depth-first* (cobertura vertical).
- Es complicado coordinar varios crawlers para que no repitan trabajo. Una alternativa utilizada es que se repartan los dominios.
- Las páginas suelen tener entre 1 día y 2 meses de antigüedad, 2 %-9 % de los enlaces almacenados son inválidos. Las páginas enviadas a indexar explícitamente demoran pocos días o semanas en ser indexadas, las no enviadas entre semanas y dos meses.
- Los mejores crawlers recorren decenas de millones de páginas por día. Requerirían meses para recorrer todo la Web en el mejor caso. En la práctica ni siquiera alcanzan a indexar gran parte de ella.
- Para complicar las cosas, existen protocolos de buen comportamiento para crawlers, de modo que no saturen a los servidores Web: cumplir las normas de cortesía (robots.txt, metatags)

- Algunos crawlers aprenden la frecuencia de actualización de las páginas e indexan las más volátiles más frecuentemente (ej. la página de la CNN versus mi página personal).
- Google utiliza el algoritmo de ranking de páginas para determinar el orden de crawling y obtiene buenos resultados.
- Las páginas generadas dinámicamente son actualmente uno de los mayores problemas para los crawlers. Para peor, esta tendencia se está acentuando.

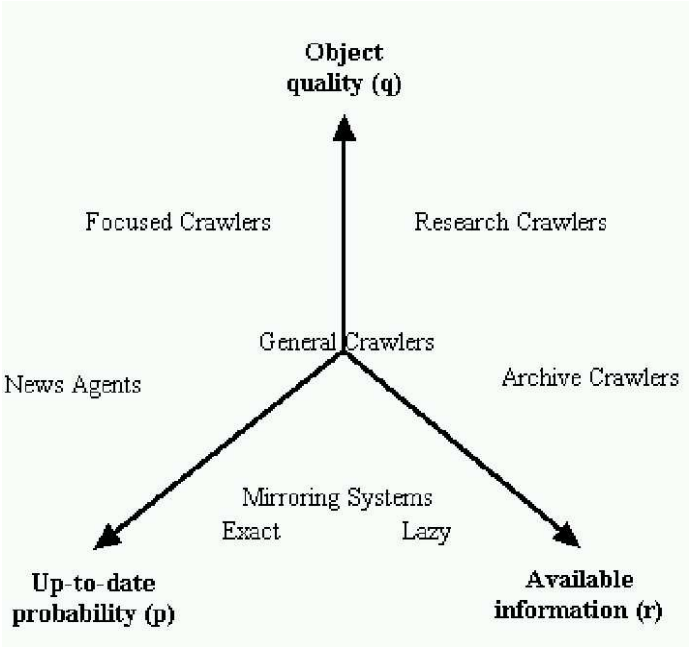

Otros Temas

- Bibliotecas Digitales
- Recuperación Multimedia
- Minería Web: contenido, estructura y uso, todo dinámico
- Agrupar (clustering) y clasificar (o categorizar)
- Compresión de índices y textos