



TEMA

Recuperación de la Información en Internet



UNIVERSIDAD CARLOS III DE MADRID



2008-2009

Jorge Morato Lara
Sonia Sánchez-Cuadrado



UNIVERSIDAD CARLOS III DE MADRID



Recuperación de Información en Internet

1. Buscadores Web

- Tipología
- Componentes y funcionamiento
- Ejemplos de Motores de Búsqueda
- Buscadores Web especiales

2. Internet Invisible

3. Posicionamiento en Recuperación Web

4. Optimización de Páginas Web

5. Criterios de Evaluación de buscadores



UNIVERSIDAD CARLOS III DE MADRID





¿Qué es un Buscador Web?

Un **buscador** (*search engine*) es un software que recopila e indexa archivos almacenados en servidores web y recupera conforme a algunos criterios específicos.



Objetivos

- Recopilar la información de la red
- Indizar la red constantemente para permitir la consulta de sus índices
- Encontrar los documentos que contengan las palabras clave introducidas por el usuario.

Tipos:

- Directorios o índices temáticos
- Motores de búsqueda
- Metabuscadore



UNIVERSIDAD CARLOS III DE MADRID



Tipología: Directorios

¿Qué es un Directorio?

- Sitio Web que gestiona una BBDD gestionada según criterios manuales
- Las URL están clasificadas en categorías temáticas
- Suele estar organizado por temas y categorías jerárquicas

Características

- Selección y clasificación manual de recursos
- Datos poco actualizados y poco exhaustivos
- Resultados relevantes y páginas de calidad
- Suelen ser temáticos



UNIVERSIDAD CARLOS III DE MADRID





Tipología: Directorios

- ❑ Argus Clearinghouse
- ❑ DMOZ (The Open Directory Project -ODP- o Proyecto de Directorio Abierto)
- ❑ Yahoo!
- ❑ Google Directory
- ❑ Buscador.com <http://www.buscador.com>
- ❑ Lasonet.com www.lasonet.com es un directorio temático de enlaces a las páginas de Internet organizadas por temas, prensa, bancos, pueblos, buscadores, planos, etc.
- ❑ Web Directorio <http://www.web-directorio.com>
- ❑ Bubl <http://bubl.ac.uk/> (Con la clasificación Dewey)
- ❑ Galaxy <http://www.galaxy.com>
- ❑ IPL the Internet Public Library <http://ipl.org/ref>
- ❑ Intute (RDN) <http://www.intute.ac.uk>



UNIVERSIDAD CARLOS III DE MADRID



Directorios temáticos: Yahoo!

- ❑ Catorce materias subdivididas en un número similar de subtemas. Bueno para Usabilidad.
- ❑ Se puede hacer una búsqueda general en cualquier sección o nivel. Si no encuentra resultados “salta” Yahoo!Search
- ❑ Cada resultado consiste en un título o una breve descripción.

Directorio de sitios Web ¡Hemos organizado la web para ti!

Arte y cultura Literatura, Teatro, Museos, Moda...	Internet y ordenadores WWW, Software, Chat, Redes...
Ciencia y tecnología Astronomía, Biología, Ingeniería...	Materiales de consulta Bibliotecas, Diccionarios...
Ciencia Sociales Filosofía, Historia, Idiomas, Psicología...	Medios de comunicación Radio, TV, Revistas, Periódicos...
Deportes y ocio Coches, Fútbol, Videoclips, Turismo...	Política y gobierno Elecciones, Boletines oficiales, Ministerios...
Economía y negocios Empresas, Inmobiliarias, Empleo...	Salud Medicina, Enfermedades, Embarazo...
Educación y formación Primaria, Secundaria, Universidades...	Sociedad Gastronomía, Religión, Para niños...
Espectáculos y diversión Actores, Música, Humor, Genial!	Zonas geográficas Países, Europa, España, CC.AA...

Los más buscados de 2003 - Novedades



UNIVERSIDAD CARLOS III DE MADRID



Directorios temáticos: Dmoz/Open Directory Project



open directory project In partnership with AOL search

qué es dmoz | bitácora de dmoz | sugerir URL | reportar abuso/spam | ayuda

Buscar en todo el directorio

Top: World: Español (168.312) Descripción

- Regional (109.439)
- Artes (1.561)
- Ciencia y tecnología (4.330)
- Compras (894)
- Computadoras (3.518)
- Deportes (1.308)
- Educación (4.977)
- Hogar (524)
- Juegos (1.808)
- Medios de comunicación (1.207)
- Negocios (3.134)
- Referencia (1.362)
- Salud (2.561)
- Sociedad (10.734)
- Tiempo libre (4.935)
- Niños y jóvenes@ (2.439)
- Usenet esp.bienvenida - news - Google Groups
- Buscar "Español" en: [AltaLista](#) - [AOL](#) - [Ask](#) - [Chusty](#) - [Gigablast](#) - [Google](#) - [Lycos](#) - [MSN](#) - [Yahoo](#)



UNIVERSIDAD CARLOS III DE MADRID



Directorios temáticos: Características de Buscador



Buscador.com

Directorio de Enlaces Web

Log in

Usuario

Clave

Entrar

Registro

Enviar Enlace

Top Enlaces

Top Usuarios

Tags

Categorías

RSS / Atom

Arte | Animación | Artes escénicas | Artes gráficas | Artes plásticas | Artistas | Pintura

Belleza | Cosmética | Dietas para adelgazar | Masaje y relax | Mujer

Blog | Directorios | Personales | Temáticos

Ciencia | Ciencias de la tierra | Electricidad | Energía | Medio ambiente

Comedia | Chistes | Humor

Compras | Anuncios compra venta | Compras online | Moda | Móviles | No3 | Regalos

Deporte | Especialidades deportivas | Golf | Noticias deportivas | Tiendas deportivas

Electrónica | Cámaras digitales | PDA | Sonido | TDT | Telefonía | Telefonía móvil | Televisión

Finanzas | Ahorro | Bolsa | Créditos | Depósitos | Préstamo | Tarjetas de crédito

Formación | A distancia | Cursos | Cursos gratis | Formación online | Idiomas | Master y posgrados

Informática | ADSL | Centrales de Comunicaciones | Diseño Web | Hardware | Multimedia | Portátiles | Programación | Procedores | Seguridad | Sistemas | Software

Inmobiliaria | Alarma | Alquiler vacaciones | Casas | Hipotecas | Instalación aire acondicionado | Mudanzas | Pisos | Reparaciones 24 horas | Seguro de hogar

Internet | Posicionamiento | Servicios | Webmaster

Los + populares

Logichuegos

Chat Chatar

Chatar

Los + recientes

Chatar Gratis

Fundación Biotecnológica Down 21: Síndrome de Down

Fibras Químicas

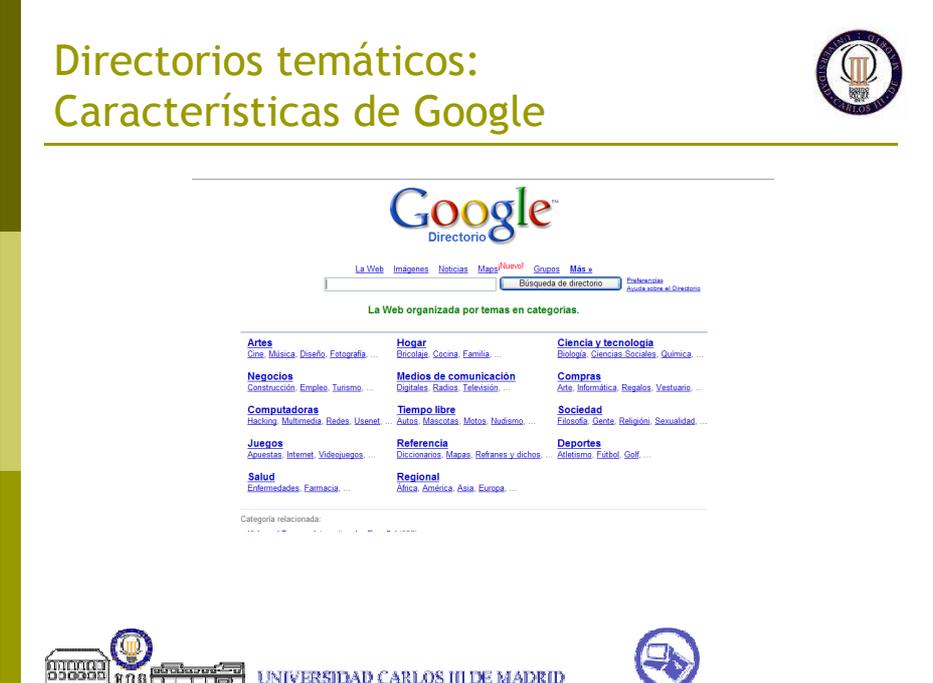
Tags



UNIVERSIDAD CARLOS III DE MADRID



Directorios temáticos: Características de Google



The screenshot shows the Google Directory interface. At the top, the Google logo is followed by the word 'Directorio'. Below this, there are navigation links for 'La Web', 'Imágenes', 'Noticias', 'Mapa', 'Nuevo!', 'Grupos', and 'Más >'. A search bar is present with the text 'Búsqueda de directorio' and a 'Ejecutar' button. A green banner states 'La Web organizada por temas en categorías.' Below this, there are several columns of category links: Artes, Hogar, Ciencia y tecnología, Negocios, Medios de comunicación, Compras, Computadoras, Tiempo libre, Sociedad, Juegos, Referencia, Deportes, Salud, and Regional. Each category has a list of sub-links. At the bottom, there is a 'Categoría relacionada:' section. The footer includes the University of Carlos III of Madrid logo and name.

Tipología: Motores de búsqueda

- ¿Características de los motores de búsqueda?
 - Software con un sistema de recolección de URLs e indización automatizadas
 - Generales o temáticos (buscadores verticales)

Características

- Muy exhaustivos
- Muy actualizados
- Manipulables
- Problemas con la calidad de los resultados y ambigüedad semántica



The footer of the slide features the University of Carlos III of Madrid logo and name, along with a small icon of a computer monitor.



Tipología: Motores de búsqueda

Ejemplos

- Google
- MSN - Microsoft
- Teoma/AskJ
- Yahoo! Search
- Exalead
- Virgilio.it

- Searchenginewatch <http://www.searchenginewatch.com/>



UNIVERSIDAD CARLOS III DE MADRID



Tipología: Motores de búsqueda

- **Generales** (Google, Alexa, Ask, Exalead, Wikia Search, Yahoo!, Msn, Yandex (ruso <http://www.yandex.ru>) Baidu (Chino <http://www.baidu.com>) Cuil (<http://www.cuil.com>))
- **Temáticos**
 - De alcance limitado geográficamente
 - Financieros
 - De negocios
 - Para la empresa
 - Dispositivos de búsqueda
 - Empleo
 - Legal
 - Médicos
 - Noticias
 - Personas
 - Propiedad inmobiliaria



UNIVERSIDAD CARLOS III DE MADRID





Tipología: Motores de búsqueda

- ❑ Temáticos
 - ❑ Video juegos
 - ❑ Foros
 - ❑ Blogs
 - ❑ Multimedia
 - ❑ Código fuente
 - ❑ BitTorrent
 - ❑ Email
 - ❑ Mapas
 - ❑ Precio
 - ❑ Preguntas y respuestas (answers.com)
 - ❑ Motores de búsqueda de código abierto (Google Code Search, Jexamples, Koders, Krugle)
 - ❑ Motores de búsqueda sociales
 - ❑ Motores de búsqueda visuales
 - ❑ Usenet
 - ❑ Buscadores basados en otros buscadores



UNIVERSIDAD CARLOS III DE MADRID



Tipología: Motores de búsqueda

Extintos	Transformaciones
<ul style="list-style-type: none">❑ BRS/ Search❑ Google Answers❑ Infoseek❑ Inktomi❑ Lotus Magellan❑ Noxtrum❑ Overture.com❑ PubSub❑ Singingfish❑ WiseNut❑ World Wide Web Worm	<ul style="list-style-type: none">❑ Web Crawler (ahora metabuscador)❑ Excite (ahora metabuscador)❑ Teoma /AskJ



UNIVERSIDAD CARLOS III DE MADRID



Tipología: Metabuscadores

¿Qué son?

- Software que agrega los resultados de varios motores o directorios para encontrar las páginas más relevantes.

Características

- Sin base de datos propia
- Optimización por tiempos de respuesta
- Incertidumbres sobre métodos de combinación de buscadores, pesos, orden de resultados, ...

Tipos:

- Metabuscadores propiamente dichos
- Multibuscadores
- Agentes de búsqueda

Ejemplos

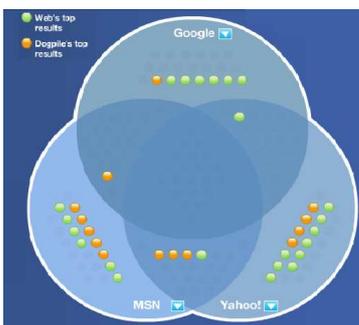
- MetaCrawler, Mibúsqueda, Copernic



UNIVERSIDAD CARLOS III DE MADRID



Tipología: Metabuscadores



Ejemplo: comprueba cuantas páginas únicas existen entre las primeras de cada buscador [Google, Yahoo, MSN y AJ] en promedio es un 1%

[Comparar](#)



UNIVERSIDAD CARLOS III DE MADRID





Tipos de metabuscadores

- ❑ **Metabuscadores:** combinan los resultados, lanzando una consulta en varios buscadores. Ejemplo: MetaCrawler
- ❑ **Multibuscadores:** no combinan los resultados, sólo lanzan la consulta en varios buscadores. Ejemplo: My Search ([MiBúsqueda](#))
- ❑ **Agentes de Búsqueda:** metabuscadores instalados localmente. Ejemplo: WebFerrer, Copernic



UNIVERSIDAD CARLOS III DE MADRID



Ejemplos Metabuscadores

- ❑ **MetaCrawler** www.metacrawler.com *Elimina los duplicados*
- ❑ **Dogpile** www.dogpile.com *motores distintos según categoría*
- ❑ **Vivísimo** www.vivisimo.com/ *con clusters y posición en cada buscador*
- ❑ **Kartoo** <http://www.kartoo.com/> *mapas de clusters navegables y con expansión de consultas*
- ❑ **Myway** <http://myway.com/>
- ❑ **SurfWax** <http://www.surfwax.com/> (en la opción focus con expansión de consultas en inglés mediante tesauro)
- ❑ **Ixquick** <http://www.ixquick.com/> buen metabuscador (cada estrella un buscador) con refinamiento de búsqueda
- ❑ **Beaucoup** <http://www.beaucoup.com/> combina un metabuscador con un directorio y con términos específicos)



UNIVERSIDAD CARLOS III DE MADRID





Recuperación de Información en Internet

1. Buscadores Web
 - Tipología
 - Componentes y funcionamiento
 - Ejemplos de Motores de Búsqueda
 - Buscadores Web especiales
2. Internet Invisible
3. Posicionamiento en Recuperación Web
4. Optimización de Páginas Web
5. Criterios de Evaluación de buscadores



UNIVERSIDAD CARLOS III DE MADRID



Funcionamiento MB: Componentes



Componentes

- Spider/Robot/Crawler. Robot.txt para ver directorios permitidos: Localizador y Recolector.
- Indizador
- Base de datos
- Interfaz de búsqueda
- Interfaz de Recuperación



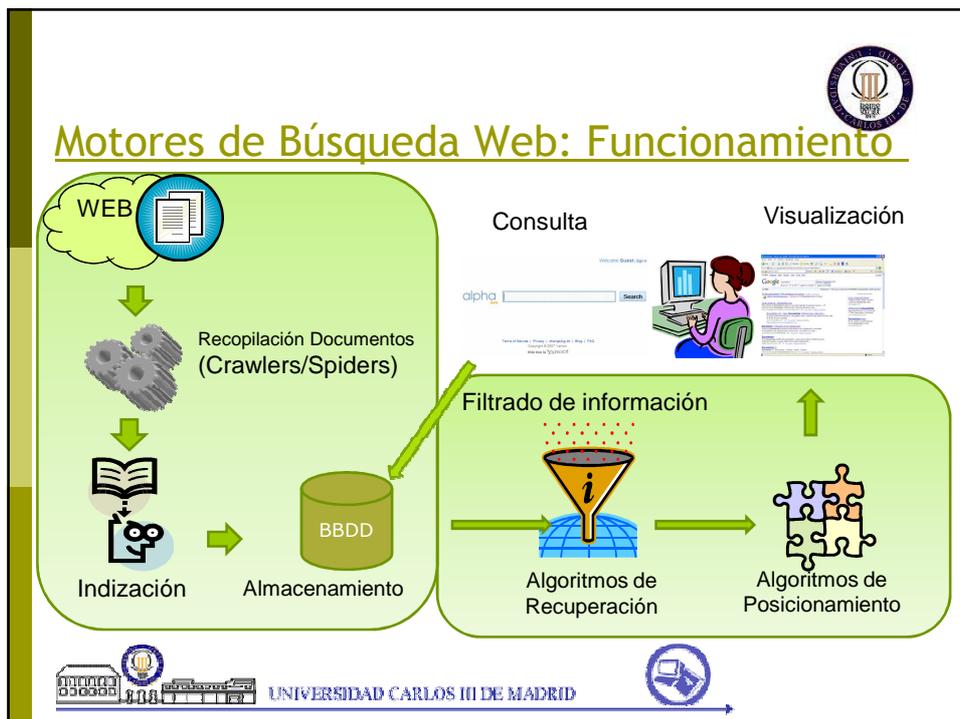
Cada Buscador tiene su propio motor:

- ✓ Altavista-Scooter,
- ✓ Lycos-Tres,
- ✓ Excite-Architext,
- ✓ Infoseek-Sidewinder,
- ✓ Google-Googlebot,...



UNIVERSIDAD CARLOS III DE MADRID





Motores de búsqueda: Recopilación de documentos

Spider, crawlers, robots o Agentes de Búsqueda son los nombres que recibe el software que recopila los documentos.

Funcionamiento

- Comienza en una página (A) y recopila todas sus URL
- Envía la página (A), comprueba que no está indizada y que no se tiene una versión menos actualizada, indiza la página (A)
- Recupera la página (B) que está primera en la lista
- Envía la página (B)...

UNIVERSIDAD CARLOS III DE MADRID

Motores de búsqueda: Recopilación de documentos



Criterios para organizar la lista a procesar:

- Puede tener en cuenta novedad o prestigio.
- Depth First Crawling: Hasta que no acaba con todas las páginas de un site no pasa a las del siguiente site.
- Breath Crawling: procesa primero las primeras páginas que ha encontrado en cada site, luego las segundas páginas de cada site, etc.



UNIVERSIDAD CARLOS III DE MADRID



Motores de búsqueda: Bases de datos



Grandes bases de datos:



- Google
- Yahoo
- MSN
- Teoma
- Wisenut/LookSmart
- Gigablast
- Exalead /Quaero

Los demás buscadores utilizan estas BD.



UNIVERSIDAD CARLOS III DE MADRID



Base de Datos: Ficheros Inversos



- Permite búsquedas rápidas de textos
- Cada término asociado a un conjunto de URLs y opcionalmente a su frecuencia y posición en cada URL.
 - Suele dividirse en glosario, con la frecuencia total y número de documentos
 - Y resto de datos: URL, posición o frecuencia en el documento.
- El glosario puede estar repetido y repartido en distintas máquinas.
- Una opción para acelerar es: las páginas más populares pueden estar en muchos servidores (y a ellos se acude primero), si no hay resultados se acude a unos pocos servidores que tienen las menos populares



BBDD

Término	#d	#frc
A	99	128
Arandela	1	2
Baraja	2	2
Casa	31	40
Tecla	1	1
...
...

LEXICON

URL	Posición
uc3m.es	34, 45, 78
uc3m.es	43, 67
cartas.com	45
www.o.org	33
...	..
...	..
...	..
...	..
...	..

POSICIÓN (POSTINGS)



UNIVERSIDAD CARLOS III DE MADRID



Base de datos: Ficheros Inversos



Término	#d	#frc
A	99	128
Arandela	1	2
Baraja	2	2
Casa	31	40
Tecla	1	1
...
...

LEXICON

URL	Posición
uc3m.es	34, 45, 78
uc3m.es	43, 67
cartas.com	45
www.o.org	33
...	..
...	..
...	..
...	..
...	..

POSICIÓN (POSTINGS)



BBDD



UNIVERSIDAD CARLOS III DE MADRID





Ejemplo: La base de Google

Característica de la base de datos de Google

- “+” antes de una palabra no elimina aun siendo vacía, si se quiere buscar por frase poner comillas. “-” que no aparezca un término.
- No es lo mismo la ubicación geográfica desde donde hagamos la consulta (desde 2004)
- El orden de las palabras importa
- La misma consulta desde un mismo sitio con intervalo de segundos puede dar resultados distintos.
- No admite truncamiento, es decir poner singular y plural
- No distingue mayúsculas, poner sin acentos
- Búsquedas por campos limitado
- Imposible combinar operadores booleanos de carácter distinto (todos AND todos OR pero no paréntesis)
- Aunque Google diga que existan 2000 resultados, jamás podrás pasar del resultado 1000.



UNIVERSIDAD CARLOS III DE MADRID



Motores de Búsqueda: opciones búsqueda por campos en Google

Opciones de búsqueda por campos

- Descubrir vínculos que le apuntan `link:www.google.com`
- restricciones de búsqueda de un dominio `site:ejemplodedominio.com`, `site:information`
- para encontrar información de artículos de prensa en el sitio de Google: `press site:www.google.com`
- Para que aparezca en el título: `intitle`, `allintitle`
- Para que aparezca en la url: `inurl`, `allinurl`
- **Definition:** “palabra”

“Betas de siempre” de Google

- MoreGoogle, GoogleDesktop, Barra de Google
- Google Scholar, APIS (recuerda que van contra un servidor no actual)
- Calculadora
- Google Suggest, profiles y demás google labs
- Y demás Gmail (los indiza para adwords), telefonía IP, ..



UNIVERSIDAD CARLOS III DE MADRID





Recuperación de Información en Internet

1. Buscadores Web
 - Tipología
 - Componentes y funcionamiento
 - Ejemplos de Motores de Búsqueda
 - Buscadores Web especiales
2. Internet Invisible
3. Posicionamiento en Recuperación Web
4. Optimización de Páginas Web
5. Criterios de Evaluación de buscadores



UNIVERSIDAD CARLOS III DE MADRID



Motores de búsqueda: Yahoo!Search

→ Yahoo! fue el primer gran directorio hecho a mano, tardo cinco años en llegar al millón de páginas, mucha calidad, poca actualización, poco exhaustivo.

2004: compra AltaVista (por contenido de su BD), AlltheWeb (por contenido de su BD), Inktomi (por su algoritmo de posicionamiento y estructura de BD), Kelkoo (como comparador de precios) y Oberture

→ Comienza a utilizar Yahoo Search, con el motor de Inktomi

En 2004 muchos problemas con integración de BD, se quejan mucho de la calidad resultados...mejora mucho

Posicionamiento: asignación de pesos denominada WebRank (parece relacionada con la barra de búsqueda), el interfaz y otros pesos de posicionamiento copiados de Google



UNIVERSIDAD CARLOS III DE MADRID





Motores de búsqueda: MSN

- Copia el algoritmo de posicionamiento de Google en 2004
- Problemas por instalación por defecto en las aplicaciones MS
- Actualmente el mejor valorado junto con Google y Yahoo!



UNIVERSIDAD CARLOS III DE MADRID



Ejemplos: A9 y AskJeeves

- A9
 - Permite buscar a texto completo en libros de muchas editoriales
 - Perteneció a Amazon
- AskJeeves
 - Ha comprado a Excite, iWon y a Teoma
 - Siempre ha tenido algo de PLN y ha establecido comparación con news
 - Actualmente el motor de Teoma hace que AJ tenga los mejores rankings de precisión. Teoma utiliza un criterio denominado autoridad basado en los enlaces de las páginas del mismo tema que apuntan a la página.
 - Es actualmente el cuarto buscador mundial



UNIVERSIDAD CARLOS III DE MADRID





Recuperación de Información en Internet

1. Buscadores Web
 - Tipología
 - Componentes y funcionamiento
 - Ejemplos de Motores de Búsqueda
 - Buscadores Web especiales
2. Internet Invisible
3. Posicionamiento en Recuperación Web
4. Optimización de Páginas Web
5. Criterios de Evaluación de buscadores



UNIVERSIDAD CARLOS III DE MADRID



Buscadores Web especiales

1. Por su temática
2. Por su tecnología y recursos
3. Por los servicios que ofrece



UNIVERSIDAD CARLOS III DE MADRID



Búsqueda de Código



❑ **Koders** <http://www.koders.com/>




UNIVERSIDAD CARLOS III DE MADRID


Búsqueda de Código



❑ **Google Code Search** (<http://www.google.com/codesearch>)




UNIVERSIDAD CARLOS III DE MADRID




Buscadores especializados

- ❑ Textos especializados y académicos → Digital.CSIC Acceso Abierto a Documentos Digitales <http://digital.csic.es/>
- ❑ Textos especializados y académicos → Citeseer
- ❑ Textos especializados y académicos → Google Scholar
- ❑ Videos → YouTube
- ❑ Imágenes



UNIVERSIDAD CARLOS III DE MADRID



Scirus (for scientific information only)

- ❑ Scirus es un motor de búsqueda específico de contenido científico. Semejante a [Citeseer](#) y [Google Scholar](#), está enfocado a la información científica. A diferencia de Citesser, Scirus no se centra sólo en ciencias informáticas y no todo su contenido es de libre acceso (p.e. algunos resultados pueden estar en [PubMed](#) en cualquier revista de [Elsevier](#), requiriendo suscripción para su acceso. www.scirus.com



UNIVERSIDAD CARLOS III DE MADRID





Recuperación de imágenes

- ❑ Tradicionalmente con metadatos, texto asociado a la imagen por nombre del fichero, texto de la página, etc
- ❑ Con la Web social con descriptores de los usuarios, p.e. Flickr

Otros buscadores de este tipo son:

- ❑ [Pixsy](#) imágenes y videos de Buzznet, flickr, iStockphoto, Fotolia, YouTube entre otros
- ❑ [Riya](#) buscador que incluye a Google, Yahoo, MSN, y flickr.
- ❑ [Tiltomo](#) basado en flickr
- ❑ [Liveplasma](#) para buscar música y video, busca por artista, grupo, película, director o actor.
- ❑ [Vdoogle](#) para buscar videos



UNIVERSIDAD CARLOS III DE MADRID



Recuperación de imágenes

- ❑ Para buscar imágenes similares se intenta actualmente utilizar inteligencia artificial, para ello se necesita una base de datos de imágenes y descriptores asociados, como experimente el más impresionante es <http://images.google.com/imagelabeler/>
- ❑ Existen buscadores para buscar este tipo de material como [Retrievr](#) capaz de buscar a partir de una imagen (lo hace con la transformación [wavelet](#) en vez de una red de neuronas). Quizás sea el buscador más prometedor de este tipo



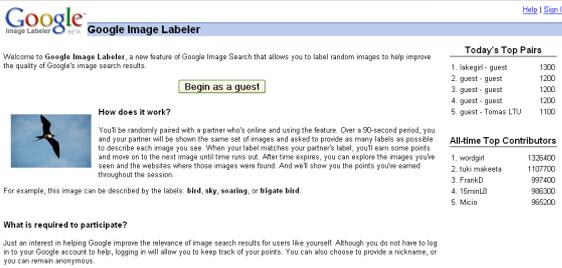
UNIVERSIDAD CARLOS III DE MADRID



Indización por competición: Imágenes



- ❑ Flickr
- ❑ <http://www.espgame.org/>
- ❑ Google Image Labeler



Google Image Labeler

Welcome to Google Image Labeler, a new feature of Google Image Search that allows you to label random images to help improve the quality of Google's image search results.

[Begin as a guest](#)

How does it work?

You'll be randomly paired with a partner who's online and using the feature. Over a 90-second period, you and your partner will be shown the same set of images and asked to provide as many labels as possible to describe each image you see. When your label matches your partner's label, you'll earn some points and move on to the next image until time runs out. After time expires, you can explore the images you've seen and the websites where those images were found. And we'll show you the points you've earned throughout the session.

For example, this image can be described by the labels: **bird, sky, seagull, or flight bird.**

Today's Top Pairs

1. lakegriff - guest	1300
2. guest - guest	1200
3. guest - guest	1200
4. guest - guest	1200
5. guest - Tomas LTV	1100

All-time Top Contributors

1. wordgrl	1326400
2. tati-makela	1107700
3. FrankD	897400
4. 15mmLB	896300
5. Micie	865200

What is required to participate?

Just an interest in helping Google improve the relevance of image search results for users like yourself. Although you do not have to log in to your Google account to help, logging in will allow you to keep track of your points. You can also choose to provide a nickname, or you can remain anonymous.

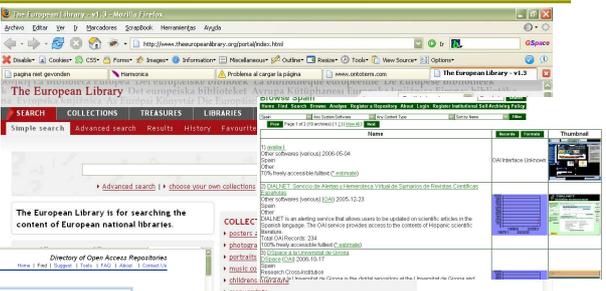


UNIVERSIDAD CARLOS III DE MADRID

Buscar en Repositorios de Bibliotecas



- European Library
- OpenDOAR
- ROAR
- WorldCat (OCLC)



The European Library

SEARCH | COLLECTIONS | TREASURES | LIBRARIES

Simple search | Advanced search | Results | History | Favorites

The European Library is for searching the content of European national libraries.

COLLECT

- books
- periodicals
- photographs
- maps
- children's literature
- manuscripts
- electronic books
- press & reference
- newspapers
- scientific articles



OpenDOAR Directory of Open Access Repositories

Search or Browse for Repositories

Search: [input] [button]

Any Subject Area: [input] Any Content Type: [input]

Any Country: [input] Any Language: [input] Any Software: [input]

Clearance: [input] [input] [input] [input] [input] [input]

Sort by: [input] [input] [input] [input] [input] [input]

Results: 1 - 20 of 182

Organization: **CONICET** (Consejo Nacional de Investigaciones Científicas)

Description: This is a closed subject based repository containing papers from the 2004 conference. Part of the [Consejo Nacional de Investigaciones Científicas \(CONICET\)](#).

URL: <http://www.conicet.gov.ar/>

Base: 10 items (2004-04-09)

Metadata: [View details](#) [Add to list](#)



WorldCat

Encontrar en una biblioteca con WorldCat

YOU ARE SEARCHING

Information retrieved: **448** items

WorldCat Search Results

WorldCat Search Results

WorldCat Search Results



UNIVERSIDAD CARLOS III DE MADRID

Búsqueda en Bibliotecas

- ❑ Z39.50
<http://www.csic.es/cbic/catalogosz.html>
<http://www.loc.gov/z3950/gateway.html>

- ❑ BookSearch
- ❑ Bibliotext
- ❑ ProCite



UNIVERSIDAD CARLOS III DE MADRID



Los Buscadores de la Web Social

En su mayoría vuelven a ser directorios:

- ❑ [Ajaxwhois](#) , para buscar nombres de dominios
- ❑ [FundooWeb](#) multibuscador, busca a la vez en Yahoo!, Flickr, Yahoo! News, Yahoo! Answers, Amazon, y Yahoo! Maps images.
- ❑ [Keotag's](#) multibuscador con Web 2.0. Google, Technorati, y Bloglines
- ❑ [Whonu](#) Multibuscador inteligente
- ❑ [Similicio.us](#) sitios similares segun delicious
- ❑ [KwMap](#) similar a kartoo con búsquedas próximas
- ❑ [Mnemomap](#) categoriza los resultados en "Token", "Tags", "Translations" y "Synonyms".
- ❑ [PreFound](#), va contra unos pocos buscadores pero se pueden ajustar las preferencias si se esta registrado.
- ❑ [Quintura](#), terminos para expandir la consulta, para obtener mas terminos solo pararse sobre un término
- ❑ [Ujiko](#). Como un video, buen funcionamiento
- ❑ [Topix](#) buscador de noticias sobre un grafico cronologico



UNIVERSIDAD CARLOS III DE MADRID





Buscadores Web especiales

1. Por su temática
2. Por su tecnología y recursos
3. Por los servicios que ofrece

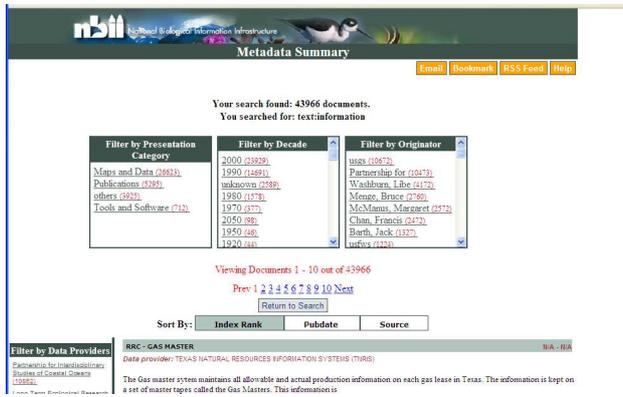


UNIVERSIDAD CARLOS III DE MADRID



Búsqueda por Metadatos

Cleringhouse <http://mercdev3.ornl.gov/nbii/>



nbii National Biological Information Infrastructure

Metadata Summary

Your search found: 43966 documents.
You searched for: text:information

Filter by Presentation Category	Filter by Decade	Filter by Originator
Mgmt. and Data (26532)	2000 (23829)	usgs (10872)
Publications (2389)	1990 (14891)	Partnership for (10473)
others (521)	unknown (2359)	Washburn, L. (6170)
Tools and Software (71)	1980 (1578)	Menge, Bruce (2749)
	1970 (377)	McMinn, Margaret (2572)
	2050 (89)	Chan, Francis (2472)
	1950 (48)	Barth, Jack (1937)
	1920 (41)	usfws (1324)

Viewing Documents 1 - 10 out of 43966
Prev 1 2 3 4 5 6 7 8 9 10 Next
(Return to Search)

Sort By: Index Rank Pubdate Source

Filter by Data Providers: RNC: GAS MASTER (NA - NA)
Data provider: TEXAS NATURAL RESOURCES INFORMATION SYSTEMS (TNRS)
Partnership for Interdisciplinary Studies of Coastal Genetics (PICOG)
The Gas master system maintains all allowable and actual production information on each gas lease in Texas. The information is kept on a set of master tapes called the Gas Masters. This information is



UNIVERSIDAD CARLOS III DE MADRID



Recuperación con tesauros

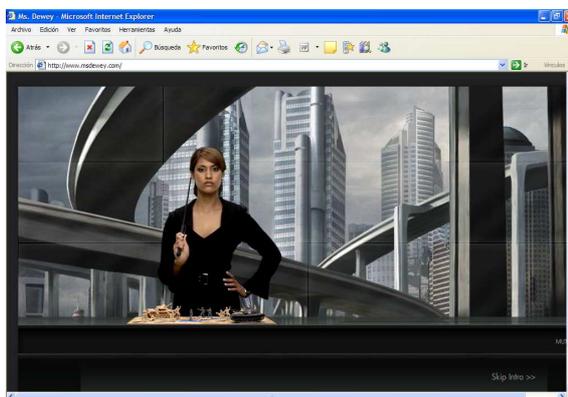


UNIVERSIDAD CARLOS III DE MADRID

Buscador - Sistema pregunta-respuesta



Mr. Dewey <http://www.msdevery.com/>





PLN y QA

- Procesamiento Lenguaje Natural
 - Natural Finder <http://demos.bitext.com/LIVE/>
 - Powerset <http://www.powerset.com/>
 - Hakia <http://www.hakia.com>
 - Google <http://www.google.es>
- Question-Answer
 - Brainboost→answers <http://www.answers.com/bb/>
 - Answers.com <http://www.answers.com/>
 - Ask Jeeves <http://es.ask.com/>
 - Start <http://start.csail.mit.edu/>



UNIVERSIDAD CARLOS III DE MADRID



Asistentes Virtuales

- Se trata de un sistema pregunta-respuesta
- En inglés también se denomina Chatterbot agente conversacional (<http://en.wikipedia.org/wiki/Chatterbot>), este termino fue acuñado por Michael Mauldin en 1994 en las conferencias de Twelfth Nacional Conference on Artificial Intelligence
- Un chatterbot (o chatbot/ talk bots o chat bots o chatterboxes) es un tipo de agente conversacional, un programa de ordenador diseñado para simular un conversación inteligente con uno o más humanos.
- Se evaluan mediante los “Turing Test” (http://en.wikipedia.org/wiki/Turing_Test)



UNIVERSIDAD CARLOS III DE MADRID



Asistentes Virtuales



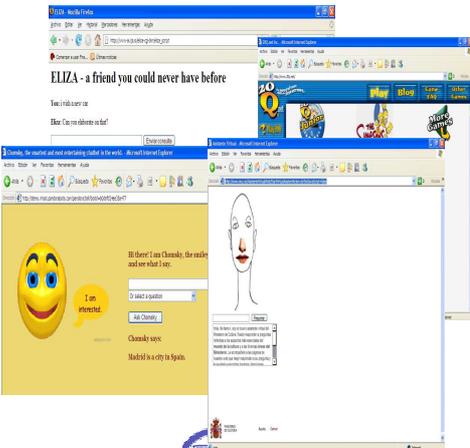
- ❑ **Asistentes Virtuales Interactivos (*interactive virtual assistant*)** son básicamente personajes virtuales para mejorar la interacción con el usuario/cliente en entornos web, quioscos interactivos, cajeros, móviles, etc.
- ❑ En inteligencia artificial los avatares son utilizados por las organizaciones para interactuar con los consumidores. Algunos avatares son conocidos como “*bots*” (*robots*) y han adquirido relevancia por el procesamiento del lenguaje natural.
- ❑ Ejemplos: Algunos ejemplos famosos son los de **IKEA (Anna)**. Con ellos se mantiene una conversación digital (digital conversation, http://en.wikipedia.org/wiki/Digital_conversation). Este tipo de avatar es conocido como **Structured Language Processing or SLP Avatar**.



Asistentes Virtuales



- [A.L.I.C.E \(Artificial Linguistic Internet Computer Entity\)](#)
- [Jabberwacky](#)
- [Ella](#)
- [Chomsky](#)
- [IKEA](#)



Buscadores semánticos



The screenshot shows the eyePlover web application in a Microsoft Internet Explorer browser. The main content is a conceptual map for 'Don Quixote'. The map is a circular diagram with 'Don Quixote' at the center. It is divided into several colored segments representing related concepts: 'Picaresque novel', 'List of characters in Don Quixote', 'Hidalgo (Spanish nobility)', 'La Mancha', 'Novel', 'Miguel de C.', 'Spanish Golden Age', 'Farce', 'Spain', 'Moors', and 'Spanish literature'. To the right of the map is a text area with the instruction 'Drag facts here - and rearrange them!'. The browser's address bar shows the URL 'http://www.eyeplover.com/eyeplover/?conceptTerm=Carlos%20III'. The footer of the slide features the logo of the Universidad Carlos III de Madrid.

Buscadores Web especiales

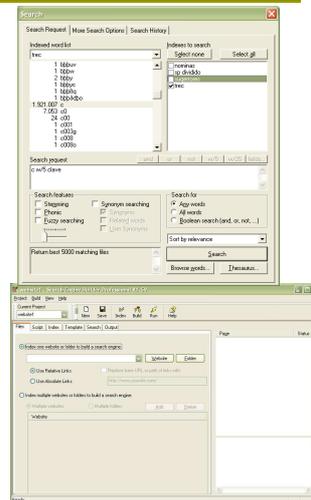
1. Por su temática
2. Por su tecnología y recursos
3. Por los servicios que ofrece



The footer of the slide features the logo of the Universidad Carlos III de Madrid on the left and a navigation icon on the right. The text 'UNIVERSIDAD CARLOS III DE MADRID' is centered below the logo.

Buscadores en PC

- ❑ **Google Desktop**: rápido y gratuito pero sin facilidades de búsqueda
- ❑ **DTSearch**: buscador versátil, pero caro
- ❑ **SearchEngineBuilder**, constructor de buscador Web
- ❑ **Exalead Desktop**



UNIVERSIDAD CARLOS III DE MADRID

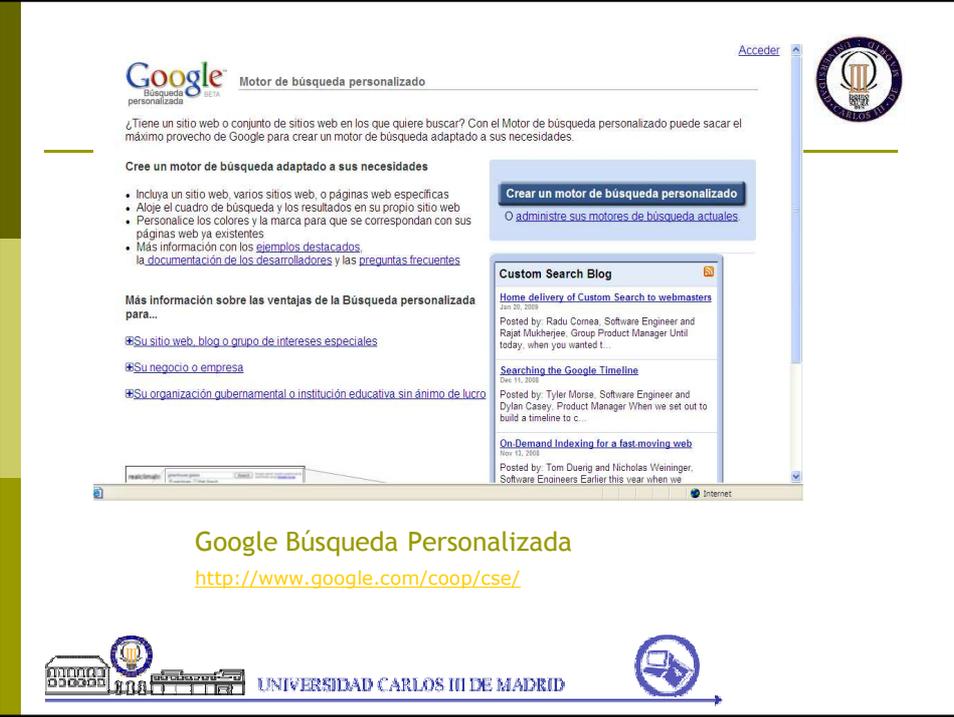
Los Buscadores de la Web Social

En su mayoría vuelven a ser directorios:

- ❑ [Ajaxwhois](#), para buscar nombres de dominios
- ❑ [FundooWeb](#) multibuscador, busca a la vez en Yahoo!, Flickr, Yahoo! News, Yahoo! Answers, Amazon, y Yahoo! Maps images.
- ❑ [Keotag's](#) multibuscador con Web 2.0. Google, Technorati, y Bloglines
- ❑ [Whonu](#) Multibuscador inteligente
- ❑ [Similicio.us](#) sitios similares segun delicious
- ❑ [KwMap](#) similar a kartoo con búsquedas próximas
- ❑ [Mnemomap](#) categoriza los resultados en "Token", "Tags", "Translations" y "Synonyms".
- ❑ [PreFound](#), va contra unos pocos buscadores pero se pueden ajustar las preferencias si se esta registrado.
- ❑ [Quintura](#), terminos para expandir la consulta, para obtener mas terminos solo pararse sobre un término
- ❑ [Ujiko](#). Como un video, buen funcionamiento
- ❑ [Topix](#) buscador de noticias sobre un grafico cronologico



UNIVERSIDAD CARLOS III DE MADRID



Google **Búsqueda personalizada** Motor de búsqueda personalizado

¿Tiene un sitio web o conjunto de sitios web en los que quiere buscar? Con el Motor de búsqueda personalizado puede sacar el máximo provecho de Google para crear un motor de búsqueda adaptado a sus necesidades.

Cree un motor de búsqueda adaptado a sus necesidades

- Incluya un sitio web, varios sitios web, o páginas web específicas
- Aloje el cuadro de búsqueda y los resultados en su propio sitio web
- Personalice los colores y la marca para que se correspondan con sus páginas web ya existentes
- Más información con los [ejemplos destacados](#), la [documentación de los desarrolladores](#) y las [preguntas frecuentes](#)

Más información sobre las ventajas de la Búsqueda personalizada para...

- [Su sitio web, blog o grupo de intereses especiales](#)
- [Su negocio o empresa](#)
- [Su organización gubernamental o institución educativa sin ánimo de lucro](#)

Crear un motor de búsqueda personalizado
O [administre sus motores de búsqueda actuales](#)

Custom Search Blog

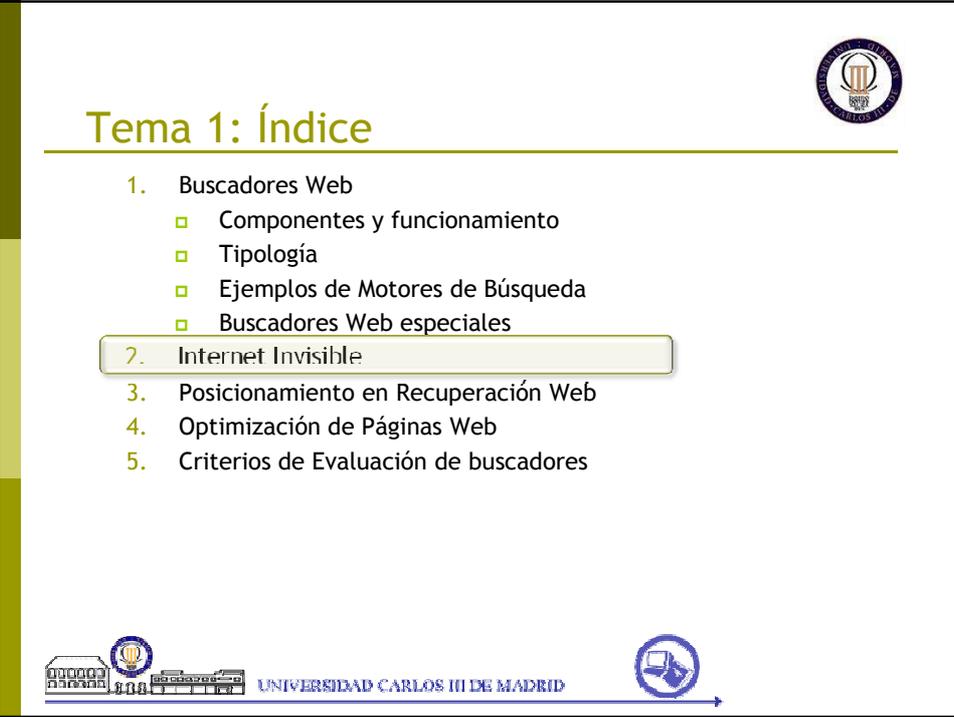
[Home delivery of Custom Search to webmasters](#)
24th Oct 2009
Posted by: Radu Comea, Software Engineer and Rajat Mukherjee, Group Product Manager Until today, when you wanted t...

[Searching the Google Timeline](#)
Dec 11, 2008
Posted by: Tyler Morse, Software Engineer and Dylan Casey, Product Manager When we set out to build a timeline to c...

[On-Demand Indexing for a fast-moving web](#)
Nov 15, 2008
Posted by: Tom Duerig and Nicholas Weininger, Software Engineers Earlier this year when we

Google Búsqueda Personalizada
<http://www.google.com/coop/cse/>

UNIVERSIDAD CARLOS III DE MADRID



Tema 1: Índice

1. Buscadores Web
 - Componentes y funcionamiento
 - Tipología
 - Ejemplos de Motores de Búsqueda
 - Buscadores Web especiales
2. Internet Invisible
3. Posicionamiento en Recuperación Web
4. Optimización de Páginas Web
5. Criterios de Evaluación de buscadores

UNIVERSIDAD CARLOS III DE MADRID



2. Internet Invisible: conceptos y soluciones

Internet invisible sector de sitios y de páginas Web que no pueden indizar los motores de búsqueda de uso público

Aproximadamente el 65% del Web. Con un 50% más de tráfico que el visible (mayor calidad)

- P.e., OPACs , nombres de calles en mapas de ciudades, sitios que precisen de una password,...)
- "no indizable"
 - Formato de los documentos (no son html)
 - Formularios
 - Páginas generadas de forma dinámica, imágenes, ...
 - Conjunto de sitios o de páginas web que, de forma expresa, se excluyen



UNIVERSIDAD CARLOS III DE MADRID



Buscadores para Internet Invisible

- Direct Search www.freepint.com/gary/direct.htm
- Turbo10 <http://turbo10.com>
- Profusion <http://www.profusion.com>
- Internet Invisible <http://www.internetinvisible.com>
<http://www.internetinvisible.com/ii/>
- Invisible Web <http://www.invisible-web.net/>
- Complete Planet <http://www.completeplanet.com>
- Librarian's Index to the Internet <http://www.lii.org>
- Infomine <http://infomine.ucr.edu/>
- Look Smart <http://search.looksmart.com/>
- Web Brain <http://www.webbrain.com>
- Easy searcher <http://www.easysearcher.com>



UNIVERSIDAD CARLOS III DE MADRID





Tema 1: Índice

1. Buscadores Web
 - Componentes y funcionamiento
 - Tipología
 - Ejemplos de Motores de Búsqueda
 - Buscadores Web especiales
2. Internet Invisible
3. Posicionamiento en Recuperación Web
4. Optimización de Páginas Web
5. Criterios de Evaluación de buscadores



UNIVERSIDAD CARLOS III DE MADRID



Posicionamiento

El posicionamiento es un conjunto de **criterios** que se aplican para construir un **algoritmo** para que un motor ordene por **relevancia las páginas** correspondientes al resultado de una consulta.

Características

- Secretos comerciales
- Cada buscador tiene algoritmos de posicionamiento diferentes
- Los algoritmos pueden ser más o menos complejos

Objetivos

- Seleccionar documentos relevantes como respuesta a una consulta
- Ordenar los resultados por orden de relevancia
- Encontrar los documentos que contengan las palabras clave introducidas por el usuario.



UNIVERSIDAD CARLOS III DE MADRID



Posicionamiento: Factores que influyen en algoritmo



Factores directos

- Tipología de la búsqueda
- Popularidad de la página
- Formato (fuente, extensión)
- Perfiles de usuario
- Factor de interés económico

Factores indirectos

- Contenidos y estructura
- Credibilidad/fiabilidad
- Usabilidad
- Accesibilidad



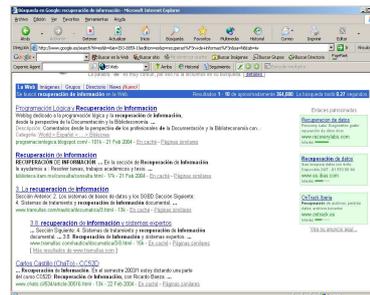
UNIVERSIDAD CARLOS III DE MADRID



Factores directos: posicionamiento por similitud de búsqueda (i)



- Frases, presencia de frases de búsqueda en frases del documento (Infoseek)
- Palabras clave al principio y final de la página (Altavista, Inktomi)
- IDF - *Inverse Document Frequency* (Altavista)
- Búsqueda booleana con OR, gana el que más palabras diferentes tiene (Altavista)
- Por clusters de conceptos asociados Excite, Intelligence Concept Extraction (tb en labgoogle.com/sets, clusty, vivisimo, exalead, kelkoo)
- Tamaño de la página (mejor si son pequeñas) (Google)



UNIVERSIDAD CARLOS III DE MADRID



Factores directos: posicionamiento por similitud de búsqueda (ii)



- ❑ URL con el término de búsqueda (Altavista, Google, Hotbot, Infoseek, Excite y Lycos)
- ❑ Posición de los términos de búsqueda al principio (Altavista, Excite, Webcrawler)
- ❑ Proximidad de los términos de búsqueda en el texto (Altavista, Lycos, Webcrawler). Frecuencia del término de búsqueda en el texto (Altavista, Lycos)
- ❑ Título, presencia del término en búsqueda en el título (Lycos, Webcrawler, Google)



UNIVERSIDAD CARLOS III DE MADRID



Factores indirectos



Usabilidad. Ejemplos que bajan la popularidad:

- Poner una página de bienvenida
- Todo lo que tenga muchos colores, no sea claro en su unidad, o se parezca a un anuncio
- No poner las conclusiones al principio ni escribir de forma esquemática

Accesibilidad. Ejemplos:

- Animaciones flash (es una imagen y no la leen los motores), páginas dinámicas.
- Todo lo que afecte al tiempo de descarga

Otros: Contenido, Arquitectura hipertextual y Credibilidad



UNIVERSIDAD CARLOS III DE MADRID





Penalizaciones (i)

- ❑ **Por limitaciones del motor o limitaciones en su acceso**
 - Tamaño (muchas penalizan el tamaño, p.e. Google, sólo los primeros 100k)
 - Porcentaje alto de código respecto al texto, y todo lo que influye en web invisible (formularios, passwords, bases de datos, ficheros no procesables, ...)
- ❑ **Por limitaciones en la comunicación con el usuario**
 - Elementos que disminuyan la credibilidad, la usabilidad o accesibilidad



UNIVERSIDAD CARLOS III DE MADRID



Penalizaciones (ii)

Por engaños al motor y protección contra herramientas SEO (Search Engine Optimization)

- ❑ Poner texto y fondo del mismo color o etiquetas o meta con contenidos engañosos (a Altavista se le engaña durante mucho tiempo. Google es la única que actualmente no lo penaliza)
- ❑ Creación de páginas falsas con la palabra clave repetida miles de veces y con enlaces a la página a promocionar (Google incluso no permite repetirla en la misma línea. También Infoseek, Stuffing)
- ❑ Poner texto en tamaño muy pequeño (Inktomi)
- ❑ Redireccionamientos automáticos (Altavista, Infoseek, Lycos, Excite)
- ❑ Mandar varias veces la misma página al motor, por ejemplo en la misma semana. (Evitar que nos lo envíe un software automático)
- ❑ Utilizar Cloaking (páginas falsas enmascaradas) y Doorway (páginas especiales para un buscador e ininteligibles para los usuarios)
- ❑ SandBox (cuarentenas) (motivo: migración BD o protección SEO para nuevos dominios)
- ❑ Revisad <http://www.google.com/webmasters/seo.html>



UNIVERSIDAD CARLOS III DE MADRID





Tema 1: Índice

1. Buscadores Web
 - Componentes y funcionamiento
 - Tipología
 - Ejemplos de Motores de Búsqueda
 - Buscadores Web especiales
2. Internet Invisible
3. Posicionamiento en Recuperación Web
4. Optimización de Páginas Web
5. Criterios de Evaluación de buscadores



UNIVERSIDAD CARLOS III DE MADRID



2. Optimización

- Directrices de diseño
 - Elementos a tener en cuenta (título, palabras clave, metadatos, descripción, texto)
 - Recomendaciones
- Optimización de páginas Web para un motor
 - Google: Descripción de elementos
 - Yahoo!Search
- Herramientas SEO (*Search Engine Optimization*)
 - Monitorización de páginas Web
 - Simuladores de motores (palabras clave y enlaces)
 - Soluciones integradas
- Factores indirectos
 - Accesibilidad
 - Usabilidad
 - Calidad de Uso
 - Credibilidad
 - Interoperabilidad



UNIVERSIDAD CARLOS III DE MADRID





Directrices de diseño: Título de la página

- Las palabras clave se encuentran en las palabras del título y de la URL. Da muy buenos resultados, siendo lo más específicos posible.
- Poner una etiqueta META con TITLE (Con DC. Title mejor).
- Título sencillo acorde con el tema, palabras clave y con pocas palabras (entorno a 5).
- Algún buscador ordena alfabéticamente, que en ASCII es: "#\$%&'()*+,-./012...89:;<=> ?@A...XYZ[\]^_`ab c...yz {}~
- Dar de alta la página, con el mismo título. No es recomendable dar de alta la página con distintos títulos pero con la misma URL.



UNIVERSIDAD CARLOS III DE MADRID



Directrices de diseño: Palabras Clave

- Pensad en el tema principal, pero también en como lo buscarían los usuarios para una necesidad de recuperación
- No poner en la misma línea la misma palabra clave
- Para seleccionar las palabras, se puede indizar el documento, quitando palabras vacías y realimentar con el estudio de los enlaces que apuntan a mi página

En meta keywords

- Unas 25 palabras o frases (no repetir en las etiquetas meta la misma más de tres veces para no ser penalizados)
- Evitar palabras muy comunes o muy raras o difíciles de escribir
- Palabras con/sin acento y en plural/singular
- Incluir errores comunes en la ortografía de las palabras (depende del idioma del público objetivo, p.e. *busines*, *bussines*, *ingeneering* ... son críticas en España)



UNIVERSIDAD CARLOS III DE MADRID





Directrices de diseño: Descripción

- Sencilla explicación del contenido temático de su página Web
- Si el buscador exige que tenga un número determinado de palabras, se recomienda no superarlos, puede aparecer cortadas y sin ningún sentido
- Parece que en las meta, Google da mejores resultados si se usa el *dc. description* en vez de *description* a secas.



UNIVERSIDAD CARLOS III DE MADRID



Directrices de diseño: Enlaces

Texto del enlace

- Enlazar sitios útiles con información y escribir términos que describan el contenido claramente y con exactitud
- Determinar las palabras de búsqueda que los usuarios escribirían para encontrar las páginas
- Ejemplos de malos textos para enlaces: “mas sobre mi”, “mis enlaces”, “mis amigos” “sobre mi”

- Sitios con jerarquía
- Si existen más de 100 enlaces dividir la página. Google podría marcarla como granja de enlaces y penalizarla
- Poner etiquetas ALT en imágenes y enlaces, el texto debe ser descriptivo, si no puede ser penalizado. (mejora la accesibilidad)
- Comprobar que no existen vínculos rotos o código HTML incorrecto
- Vínculos con texto claro (**Bombing**)
- En Google, poner URL absolutas. Se debe poder acceder a todas las páginas desde al menos un vínculo estático



UNIVERSIDAD CARLOS III DE MADRID





Directrices de diseño: Recomendaciones

- ❑ **Abusos con Palabras clave**
 - Los robots las detectan y eliminan el sitio
 - No escribir más de 3 veces la misma palabra clave
 - Mantener separadas las frases y palabras que contengan palabras repetidas
- ❑ **Metaetiquetas**
 - Seleccionar diferentes palabras clave para cada página
 - Variaciones morfológicas de una palabras son palabras diferentes (p.e. casa, casas, casa de fin de semana)



UNIVERSIDAD CARLOS III DE MADRID



Optimización de páginas Web: Google

Consideraciones

- ❑ El último gran cambio en el algoritmo es de octubre de 2004. Actualmente se cree que Google podría estar utilizando hasta tres algoritmos diferentes
- ❑ **PageRank**, cálculo basado en el número de páginas que apuntan a una página. Un enlace de una página vale más si está a su vez recibe muchos enlaces. Tiene en cuenta 100 factores, pero los enlaces son el principal dada la estabilidad de resultados a lo largo del tiempo.

Ejemplos de factores que valora Google

- ❑ Formato del texto
- ❑ Densidad de la palabra de consulta en título y body
- ❑ Presencia de la consulta de URL (tanto en el body como en URL, ignora los guiones bajos e interpreta los guiones normales como separadores)
- ❑ Texto de los enlaces que apuntan a la página
- ❑ Número de enlaces que recibe la página en estudio (PageRank)



UNIVERSIDAD CARLOS III DE MADRID



Optimización de páginas Web: Google



PageRank de Google

- Estimación PageRank por vecindad. Profundidad en el directorio, si el sitio principal tiene un PR de 6 y la página está en una subcarpeta “nieta”, se resta dos al PR

El PageRank tiene en cuenta:

- Número de páginas que enlazan a la página
- Los enlaces puntúan más si vienen de páginas que PR es alto o con pocos enlaces salientes (p.e. Estar dado de alta en DMOZ -directorio que incorpora Google- da de media un punto más de PR si el tenía un valor inferior a seis). Algo similar ocurre en Yahoo!

PR(A)=(1-d)+d(PR(t1)/C(t1)+PR(t2)/C(t2)....)

PR(A), es el PageRank de la página A
d, factor de amortiguación, probabilidad de que el usuario abandone la página. Por defecto 0.85
PR (t1)...t1, t2 son los Pr de las páginas que apuntan a A
C(t1), enlaces que salen de la página t1, para evitar división por cero, la página se considera autolenlace

Explicación PR:
<http://www.webworkshop.net/pagerank.html>

Calculadora de PR:
http://www.webworkshop.net/pagerank_calculador.php

Saber tu PR:
<http://www.googlemania.com/pagerank.php>



UNIVERSIDAD CARLOS III DE MADRID



Optimización de páginas Web: Google



Directrices de Calidad -Principios básicos-

- Tiene en cuenta el texto del enlace con la consulta (*Bombing*)
- Tiene en cuenta enlaces internos, pero si sólo existen enlaces internos y no externos lo puede penalizar
- Google evita repeticiones en su lista de resultados
- Crear páginas para usuarios y no para motores de búsqueda.
- No tratar de engañar a los usuarios presentando a los motores de búsqueda contenido distinto al que se desea mostrar
- Penalizaciones: programas de comprobación de rankings, programas para remitir páginas, intercambio de links ...



UNIVERSIDAD CARLOS III DE MADRID



Optimización de páginas Web: Recomendaciones



- Una página con *frames* depende de links externos y del título para posicionarse. Añadir información mediante la etiqueta `<no frame>`, poner títulos descriptivos y etiquetas meta.
- En las páginas flash, utilizar la etiqueta `<noembed>` para poner texto. Poner un buen título
- Javascript, usar la etiqueta `<noscript>` y poner buen título



UNIVERSIDAD CARLOS III DE MADRID



Optimización de páginas Web: Recomendaciones para Yahoo!



- Incluirse en DMOZ y directorio Yahoo!. DMOZ (Open Project) está realizado a mano
- El texto de los enlaces que van en una página no son tan relevantes para esa página como en Google. Poner pocas palabras en el texto de los enlaces
- No tiene en cuenta palabras vacías
- Yahoo! Valora el texto no los enlaces que apuntan y la estructura del Web. Es muy permisivo con prácticas indeseables. Spam con keywords abusivas (span interno) y el spam externo funciona bien, pues le da igual de quien recibe los enlaces
- Mucho peso al título, permitiendo repeticiones de palabras, se puede llegar a 100 caracteres
- Las keywords en la URL parecen tener más peso
- Utiliza etiquetas meta, pero las da poco peso
- Tiene en cuenta enlaces entrantes
- Tarda mucho en subir una página y penaliza sin sentido



UNIVERSIDAD CARLOS III DE MADRID



Herramientas SEO (Search Engine Optimization)



Herramientas de análisis:

- ❑ Comprobar palabras clave y título con las mejores páginas posicionadas
- ❑ Estudio de enlaces
- ❑ Ver con los ojos de un motor
- ❑ Monitorizar nuestra página con la competencia

Herramientas de mejora:

- ❑ Elección del título, elección de palabras clave
- ❑ Políticas de intercambio de enlaces

Simuladores de motores

- <http://www.1-hit.com/all-in-one/tool.search-engine-viewer.htm>
- <http://www.delorie.com/web/ses.cgi>
- *Search Engine Spider Simulator*
<http://www.webconfs.com/search-engine-spider-simulator.php>
- http://www.searchenginewold.com/cgi-bin/sim_spider.cgi

Cálculo de densidad de palabras

- Keyword Counter-Keyword Frequency Analyzer <http://www.keywordcount.com/>
- <http://www.forobuscadores.com/recursos/index.php?m=c&c=27>



UNIVERSIDAD CARLOS III DE MADRID



Herramientas SEO: Monitorización



ALEXA <http://www.alexa.com>

- ❑ Ranking basado en popularidad, mide el tráfico (con usuarios con la barra de Alexa) media geométrica de
 - Reach (alcance): media del número de usuarios (visitas) que recibe un site (no URL) por millón y día
 - Page View: número de páginas vistas por diferentes URL que han solicitado determinada página [diferentes=mismo día]

Límites de ALEXA:

- sólo funciona con Explorer y Windows,
- sólo tiene en cuenta si hay más de mil visitas,
- no accede a https,
- sólo mide la URI principal, no las páginas secundarias de un site.

Google Monitor
<http://www.googlemania.com/monitor.php>

Google Tracking mira los enlaces
<http://www.googlemania.com/tracking.php>

Soluciones Integradas

IBP

SEO Toolbox
<http://www.webrankinginfo.com/english/tools/seo-toolbox.php>



UNIVERSIDAD CARLOS III DE MADRID





Los factores indirectos

- Accesibilidad
- Usabilidad
- Credibilidad
- Contenido
- Interoperabilidad

Todos estos factores tienen un equivalente en creación de aplicaciones



UNIVERSIDAD CARLOS III DE MADRID



Los factores indirectos: Accesibilidad

No poner barreras al público objetivo (invidentes, daltónicos, “torpes” desmemoriados, propietarios de un hardware obsoleto), niños, conexiones lentas, países en desarrollo

La accesibilidad se mide con test con varios niveles A, AA, AAA

- [http:// www.w3c.org/TR/WCAG10/full-checklist.html](http://www.w3c.org/TR/WCAG10/full-checklist.html)
- Software: Bobby, TAW
 - <http://www.tawdis.net>
 - <http://www.cynthiasays.com>

Corrección HTML y CSS:

- <http://validator.w3c.org> Valid XHTML 1.0
- <http://jigsaw.w3c.org/css-validator> Valid CSS



UNIVERSIDAD CARLOS III DE MADRID





Los factores indirectos: Usabilidad

Facilidad de uso y de aprendizaje.
Mejora si se elimina lo superfluo
(no significa falta de estética)

Evalúa:

- Facilidad de aprendizaje
- Facilidad de recuerdo
- Eficiencia del usuario
- Tasa de errores
- Satisfacción

Son interdependientes, bajar una puede suponer aumentar otra



UNIVERSIDAD CARLOS III DE MADRID



Los factores indirectos: Credibilidad

Estudia como se relaciona la credibilidad y el nivel de compromiso, enlaces recibidos y ofrecidos y diseño del Web

Depende de: mención de autoría, institución, política de confidencialidad, fecha de actualización

Estudios de usuarios revelan que también está en función de la **usabilidad y la calidad técnica del sitio**

Credibilidad positiva:

- El sitio te ha servido en el pasado
- Prestigio de la organización que avala el sitio
- El sitio responde rápido al cliente
- Se facilita la dirección física y el teléfono
- Se ha actualizado recientemente
- El sitio parece diseñado por profesionales
- La usabilidad es correcta (contenido, comprensión, arquitectura)

Credibilidad Negativa:

- Dificultad para distinguir anuncios de texto
- Falta de actualización
- Tiene pop-ups con anuncios
- Falta de usabilidad
- Enlaces erróneos o desacertados
- Enlaces o recursos no accesibles



UNIVERSIDAD CARLOS III DE MADRID





Los factores indirectos: Credibilidad

Credibilidad positiva (factores de importancia)	Credibilidad negativa (factores de importancia)
<ul style="list-style-type: none">□ 1.5 dar la dirección e-mail□ 1.5 organización racional□ 1.3 listar autores, existencia de citas claras y referencias□ 1.3 sitio enlazado creíble□ 1.2 se muestra la política de privacidad□ 1.2 el sitio manda correos de confirmación tras las transacciones□ 1.2 existe un buscador interno□ 1.0 permite imprimir fácilmente□ 1.0 dar la información en más de un idioma	<ul style="list-style-type: none">□ -1.4 dificultad para navegar□ -1.4 enlaces no creíbles o erróneos□ -1.3 errores tipográficos□ -1.3 el sitio no está siempre accesible□ -1.1 no coincide nombre de empresa y nombre de URL□ -1.0 se tarda mucho tiempo en descargar la página



UNIVERSIDAD CARLOS III DE MADRID



Los factores indirectos: Contenido

<ul style="list-style-type: none">□ Redacción de texto breve (50% menos texto que en otros medios). Evitar <u>palabras no específicas</u> del contenido (p.e. bienvenido), <u>texto subjetivo</u>, <u>énfasis</u>, <u>metáforas</u>, sin <u>juegos de palabras</u>, sin palabras ingeniosas ni similares. No poner URL, sino <u>texto para navegar</u> a otra página mediante clic□ Estructurado: <u>párrafos cortos</u>, una idea un párrafo, con varios niveles de encabezados, <u>viñetas anidadas</u>, <u>páginas cortas</u> y vinculadas, <u>subtítulos informativos</u>, <u>tipografía</u>, <u>colores en palabras clave</u> (sin exagerar)□ Se citan menos páginas muchos temas distintos, hacer <u>contenidos específicos</u>□ No dividir un mismo texto en páginas con "continuación"	Legibilidad <ul style="list-style-type: none">• Selección de <u>colores con contraste</u>. Evitar fondo, mejor los fondos claros• No usar marquesinas ni realizar cambios de tamaño. El cerebro lo asocia a publicidad (banners)• <u>Alinear a la izquierda</u>• <u>Sans-serif</u> (verdana) es la más legible a <u>tamaño 10</u>• No usar tablas anidadas Hoja de Estilo <ul style="list-style-type: none">• El formato es recomendable en hojas de estilo• Dan coherencia, mejoran aprendizaje y memoria del sitio• No usar más de dos fuentes• La página debe ser legible si desaparece la hoja de estilo• Tamaño de letra en tamaño relativo (%) a la que tiene por defecto el usuario
---	--



UNIVERSIDAD CARLOS III DE MADRID



Los factores indirectos: Página de inicio y navegación



- ❑ Hacer visible logo y nombre de la compañía (superior izda)
- ❑ Ancho variable. Si se exige tamaño fijo poner 600*640
- Navegación**
 - ❑ Accesible desde el resto de las páginas
 - ❑ Navegación rápida y fácil. Poner directorio temático, interfaz de búsqueda y enlaces a noticias especiales
 - ❑ Se debe saber dónde se está, dónde he estado y donde ir en relación al Web y al sitio
 - ❑ Evitar navegación lineal
 - ❑ Interfaz de navegación lo más estándar posible
 - ❑ Evitar nuevas ventanas, impide ir hacia atrás y agobia al usuario



UNIVERSIDAD CARLOS III DE MADRID



Factores indirectos: Interoperabilidad



- ❑ Metadatos
- ❑ Ontologías
 - RSS
 - RDF
- ❑ Mapeados (Alineaciones)



UNIVERSIDAD CARLOS III DE MADRID





Tema 1: Índice

1. Buscadores Web
 - Componentes y funcionamiento
 - Tipología
 - Ejemplos de Motores de Búsqueda
 - Buscadores Web especiales
2. Internet Invisible
3. Posicionamiento en Recuperación Web
4. Optimización de Páginas Web
5. Criterios de Evaluación de buscadores



UNIVERSIDAD CARLOS III DE MADRID



4. Criterios de evaluación de motores

Nielsen NetRankings
Actualización, tamaño, spam, enlaces muertos, cobertura según tema y área geográfica...

- Frecuencia de reindexación: Google (de 1-68 días), Hotbot, MSN y Alltheweb tardan poco, las más antiguas en Alltheweb todos pasa cada mes. MSN y hotbot los mejores. Altavista tardaba entre 12-51 días y WiseNut entre 247-286 días [abril 2002]. Google tiene el Google Dance cada 15 días y los mirrors nacionales cada mes.
- **Tamaño:** la mayor son Google 9500 millones (101 k por pg), MSN 5000 millones (150 kpg) y Yahoo!Search 19200 millones (500k) y por último AJ 2500 millones a 101 k . Directorios manuales DMOZ y looksmart 2, 5 millones Yahoo 1,8 millones
- **Enlaces muertos:** Enlaces que conducen a enlaces muertos, en 2000 Altavista tenía un 14% (9% 2002) mientras que Google tenía un 3%→se hunde Altavista
- **Cobertura:** Páginas que aparecen en un único buscador: casi la mitad están en Google, pero tb destacan WiseNut y Yahoo
- Los más usados en el mundo google 46% yahoo!Search 24% MSN 11% (2005)
- **Tiempo** que se permanece en Google 29 m AOL 28 Netscape 13



UNIVERSIDAD CARLOS III DE MADRID





4. Criterios de evaluación de motores

Nielsen NetRankings
Actualización, tamaño, spam, enlaces muertos, cobertura según tema y área geográfica...

- ❑ Frecuencia de reindización
- ❑ Tamaño:
- ❑ Enlaces muertos:
- ❑ Cobertura:
- ❑ Los más usados en el mundo google 46% yahoo!Search 24% MSN 11% (2005)



UNIVERSIDAD CARLOS III DE MADRID



Tema 1: Índice

1. Buscadores Web
 - ❑ Componentes y funcionamiento
 - ❑ Tipología
 - ❑ Ejemplos de Motores de Búsqueda
 - ❑ Buscadores Web especiales
2. Internet Invisible
3. Posicionamiento en Recuperación Web
4. Optimización de Páginas Web
5. Criterios de Evaluación de buscadores
6. Medidas de Recuperación de Información



UNIVERSIDAD CARLOS III DE MADRID



Evaluación de un Sistema de Recuperación

CONTENIDO

- Cobertura
- **Tamaño**
- Novedad
- Actualización

RECUPERACIÓN

- Algoritmo Recuperación
- Algoritmo Posicionamiento

- Recall
- Precisión

DISEÑO

- Interfaz de búsqueda
- Arquitectura:
 - Estruc. índices (árboles, hash, ...)
 - Tipo almacenamiento datos, etc
 - **Eficacia almacenamiento**
(Índices+reg.doc)/espac.doc
 - **Eficacia de ejecución**
Tiempo en hacer una operación
- Visualización resultados
- Política de Indización

UNIVERSIDAD CARLOS III DE MADRID

Ruido y Silencio

	Relevante	No Relevante
Recuperado	A	B
No Recuperado	C	D

- ❑ Ruido: Documentos no relevantes recuperados (B)
- ❑ Silencio: Documentos relevantes no recuperados (C)

Recuperados Relevantes

Recuperados relevantes

UNIVERSIDAD CARLOS III DE MADRID

Relación Ruido/Silencio y Estrategias de búsqueda



- **Disminuir Ruido**
 - **Consulta**
 - Utilizar términos específicos, añadir términos asociados
 - Operadores AND y NOT
 - Búsqueda por frases, campos, paréntesis, evitar términos polisémicos, usar términos poco frecuentes
 - **Medio**
 - Utilizar Directorios
- **Disminuir Silencio**
 - **Consulta:**
 - Emplear OR, variantes ortográficas (incluido acentos, mayúsculas, género, número, ..), idiomáticas y dialectales
 - Expansión de búsqueda: Términos genéricos y sinónimos
 - **Medio**
 - Metabuscadores y Motores



UNIVERSIDAD CARLOS III DE MADRID



Relación Ruido/Silencio



Silencio



↓

Ruido

Ruido



↓

Silencio

	Relevan.	No Relev.
Rec.	A	B
No Rec.	C	D

Ley de Cleverdon

↑ Precision

↓ Recall

↑ Precision

↓ Recall

Recall = Exhaustividad =
 $A/(A+C)$

Mide como evita el sistema el silencio

Entre 0 y 1, mejor si próximo a 1

Precision = $A/(A+B)$

Mide como evitar el ruido

Entre 0 y 1, mejor si próximo a 1



UNIVERSIDAD CARLOS III DE MADRID





Ejercicio 1

Dos buscadores con misma consulta y misma BD

Buscador 1 { r, r, r, r, r, r }

Buscador 2 { r, nr, r, r, nr, r, r, nr, r, nr, r, r }

Donde nr es un documento no relevante y r es relevante
 La base de datos tiene 10.000 documentos, 10 son relevantes a la consulta estudiada

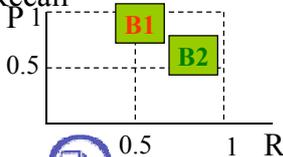
Indicad que buscador evita mejor el ruido y el silencio según las tasas de Precision Recall

$Pb1=6/6=1$

$Pb2=8/12=0.6$

$Rb1=6/10=0.6$

$Rb2=8/10=0.8$





UNIVERSIDAD CARLOS III DE MADRID





Ejercicio 2

Suponga los siguientes resultados de dos buscadores en Internet ante la misma consulta y la misma base de datos

Buscador 1 { 1, 2, 3, nr, 18, 12, nr, 4, 5, nr }

Buscador 2 { 1, 3, 2, 18, 9, 29, 6, nr, nr, nr }

Donde

- nr es un documento no relevante
- Los números son el orden de relevancia del documento
- El orden es en el que han ido apareciendo los documentos

Calcular las tasas de Precision/Recall



UNIVERSIDAD CARLOS III DE MADRID





Solución Ejercicio 2

	Precision	Recall
Buscador1	7/10	7/x
Buscador2	7/10	7/x

¿son entonces iguales los dos buscadores?



UNIVERSIDAD CARLOS III DE MADRID



Precision Recall- Problemas

- ❑ Una sola medida de precision recall mide la calidad del algoritmo de recuperación no del algoritmo de **posicionamiento** (el posicionamiento solo tiene sentido cuando el modelo de recuperación lo permite)
- ❑ En **Internet** es imposible saber **cuantos documentos relevantes** existen a una pregunta dada
- ❑ No se tiene en cuenta el ajuste a la medida **manual de la relevancia**
- ❑ No se tiene en cuenta la **interacción con el usuario**
- ❑ Son **dos medidas** de una misma cuestión, hay que decidir a cual se la quiere dar **preferencia**



UNIVERSIDAD CARLOS III DE MADRID





Precision-Recall unificada

- Medida de la F
 - Unifica Precision-recall en una única medida utilizando la media armónica, cuanto más próximo a uno mejor (a cero peor). Se mide en el j documento recuperado.
$$F(j)=2/((1/r(j))+1/P(j))$$
- Medida de Evaluación
 - Como la armónica pero configurable, si $b>1$ más peso a la precisión, si $b<1$ a la recall
$$F(j)=1+b^2/((b^2 /r(j))+1/P(j))$$



UNIVERSIDAD CARLOS III DE MADRID



Otras medidas:

- Índice de irrelevancia
 - $\frac{\text{N}^\circ \text{ documentos no relevantes recuperados}}{\text{n}^\circ \text{ documentos no relevantes en la colección}}$
 - Da información aun cuando no hay documentos relevantes (¡para Recall division por cero!) o cuando no recupera documentos relevantes. Tiene en cuenta D el número de documentos irrelevantes recuperados. Cuanto más pequeña mejor
- Recall de documentos relevantes únicos (URR)
 - Sirve para comparar dos buscadores se tienen en cuenta sólo los relevantes no duplicados en los resultados de los dos buscadores
 - $\frac{\text{N}^\circ \text{ de relevantes únicos}}{\text{número total de relevantes}}$



UNIVERSIDAD CARLOS III DE MADRID





Gráficos de Precision Recall

- ❑ Es el sistema **más utilizado** en la literatura para mostrar el funcionamiento de un motor o varios
- ❑ Sirve para **mostrar gráficamente**, de forma sencilla, la eficacia y eficiencia de un sistema de recuperación
- ❑ Se mide la Precision a **11 niveles de Recall**:
0%, 10%, 20%, ...70%, 80%, 90%, 100%
- ❑ Si no se posee determinado valor de Precision se **interpola** con la Precision correspondiente al siguiente Recall conocido (incluido el caso del 0% de Recall)
- ❑ Opcionalmente se puede ver la **Precision en valores fijos**. P.e. Cuando se han recuperado 10, 20, 30... documentos relevantes



UNIVERSIDAD CARLOS III DE MADRID





Gráfico Precision Recall

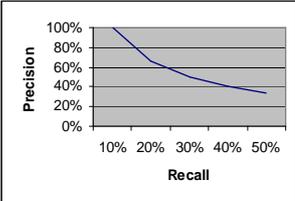
Relevantes															
Recuperados	Buscador														
	r	nr	r	nr	nr	r	nr	nr	nr	r	nr	nr	nr	nr	r
Documentos Rec	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Relev Rec	1	1	2	2	2	3	3	3	3	4	4	4	4	4	5

$\frac{2}{10}$ $\frac{2}{3}$

Recall	10%	10%	20%	20%	20%	30%	30%	30%	30%	40%	40%	40%	40%	40%	50%
Precision	100%	50%	67%	50%	40%	50%	43%	38%	33%	40%	36%	33%	31%	29%	33%

Gráfico

Recall	10%	20%	30%	40%	50%
Precision	100%	67%	50%	40%	33%





UNIVERSIDAD CARLOS III DE MADRID



Gráfico Precision Recall. Interpolación

Relev 3
Recs 15

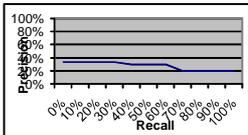


	nr	nr	r	nr	nr	nr	r	nr	r						
Doc Rec	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Rel Rec	0	0	1	1	1	1	2	2	2	2	2	2	2	2	3

Recall	0%	0%	33%	33%	33%	33%	67%	67%	67%	67%	67%	67%	67%	67%	100%
Precision	0%	0%	33%	25%	20%	17%	29%	25%	22%	20%	18%	17%	15%	14%	20%

Gráfico

33%	67%	100%
33%	29%	20%



Interpolación

0%	10%	20%	30%	40%	50%	60%	70%	80%	90%	100%
33%	33%	33%	33%	29%	29%	29%	20%	20%	20%	20%

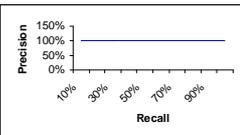


UNIVERSIDAD CARLOS III DE MADRID



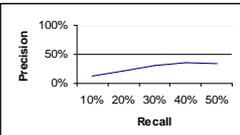
Gráficos de precisión recall





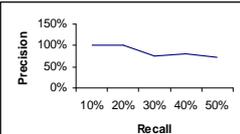
Recuperación idónea

Cada documento recuperado es relevante



Recuperación tardía

Los primeros docs no son relevantes
pero los últimos si



Recuperación temprana

Los primeros docs son relevantes
pero los últimos no



UNIVERSIDAD CARLOS III DE MADRID



Consultas agrupadas



- ❑ Los gráficos de precision recall no suelen contener una sola consulta, sino que **agrupan varias consultas**
- ❑ El método es calcular la **precisión media** a cada uno de los 11 niveles de recall



UNIVERSIDAD CARLOS III DE MADRID



Estimación Recuperación en Internet



- ❑ Problema:
 - Se desconoce el total de relevantes (Recall)
 - Difícil conocer el total de relevantes recuperados si la búsqueda tiene muchos docs
 - Dificultades añadidas por documentos no indizados por el motor y documentos no recuperados pero indizados por el motor
 - Para poder comparar motores en Internet deberíamos de poder utilizar la BD de un motor (p.e. Google) con los algoritmos de recuperación y posicionamiento de otro motor (p.e. Altavista)



UNIVERSIDAD CARLOS III DE MADRID



Estimación Recuperación en Internet: Soluciones



- ❑ No calcular la Recall
- ❑ Limitarse a los n primeros resultados recuperados (20)
- ❑ Utilizar palabras de muy baja presencia para así poder evaluar todos los documentos
- ❑ Para Comparar motores: A veces se normaliza el número total de relevantes sumando los documentos relevantes de los 20 primeros resultados de varios motores
- ❑ Identificar documentos que deberían de estar (p.e. por estar en una revista electrónica o un dominio relevante), ver cuantos recupera
- ❑ Poner artículos relevantes en el motor y ver cuantos se recuperan
- ❑ Si se puede acceder a subcolecciones como newsgroups hacer muestreos de relevantes



UNIVERSIDAD CARLOS III DE MADRID



Estimación Recuperación en Internet



- ❑ Algunos autores (Chignell) proponen modificar la medida de Precision de los 20 primeros resultados añadiendo información sobre el grado de Relevancia

$$P = \frac{\sum \text{puntuación}}{20 * 4}$$

La puntuación se asigna manualmente de 1 (mínimo) a 4 (máximo)



UNIVERSIDAD CARLOS III DE MADRID





Consultas sin Agrupar

- Desventajas de Agrupar
 - No se puede saber como se comporta un tipo específico de consultas
 - No permite comparar dos algoritmos frente a consultas individuales

✦Tipos:

- Media de Precision en n valores de recuperación
- R-Precision
- Histogramas de Precision




UNIVERSIDAD CARLOS III DE MADRID





Consultas sin agrupar

- Media precision: favorece los algoritmos que dan antes los docs relevantes

Relevantes	10
Recuperados	15

R-Precision = 40%
→ Valor de la precisión al recuperar el mismo nº de docs q el nº de documentos relevantes

Documentos															
Recuperados	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Relevantes															
Recuperados	1	1	2	2	2	3	3	3	3	4	4	4	4	4	5

Recall	10%	10%	20%	20%	20%	30%	30%	30%	30%	40%	40%	40%	40%	40%	50%
Precision	100%	50%	67%	50%	40%	50%	43%	38%	33%	40%	36%	33%	31%	29%	33%

Precisión media a n documentos relevantes

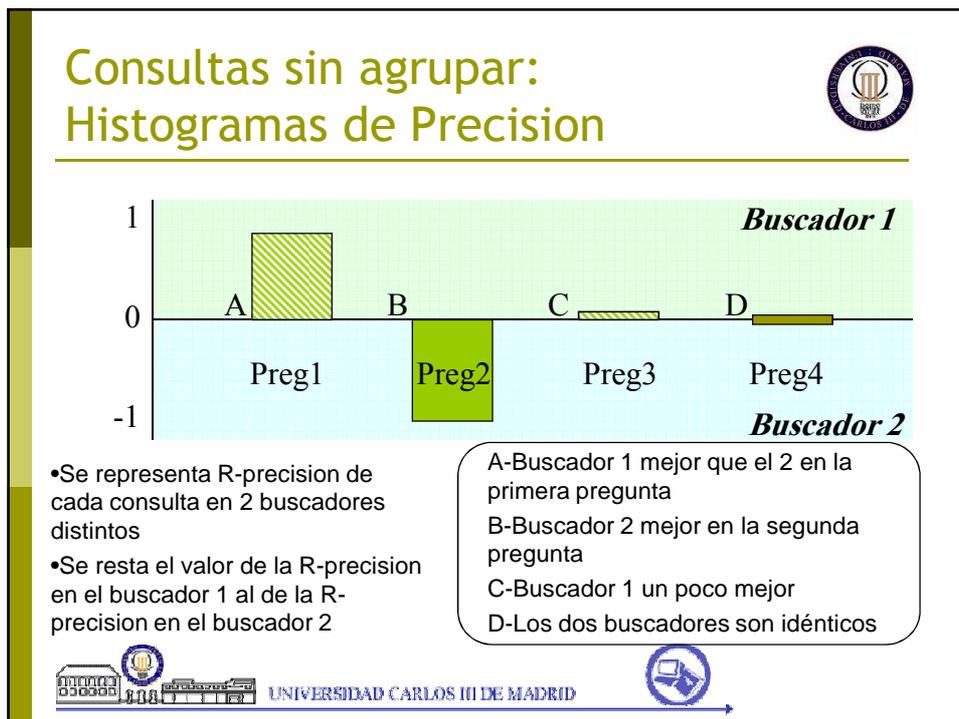
	10%	20%	30%	40%	50%
	100%	67%	50%	40%	33%

=suma porcentajes dividido número de relevantes recuperados **58%**




UNIVERSIDAD CARLOS III DE MADRID





Medidas orientadas al usuario

Para un usuario concreto	Conocidos	Desconocidos
Relevantes Recuperados	A	B
Relevantes (presentes o no en la BD)	C	D

- ▣ Cobertura= A/C
 De los relevantes conocidos por el usuario cuantos se han recuperado
- ▣ Novedad= $B/(A+B)$
 De los relevantes recuperados cuantos le eran desconocidos

UNIVERSIDAD CARLOS III DE MADRID



Medidas Centradas en el Usuario

- Recall Relativa
$$\frac{\text{Documentos relevantes recuperados}}{\text{Documentos relevantes esperados}}$$
- Esfuerzo en la Recuperación
$$\frac{\text{Documentos relevantes esperados}}{\text{Documentos relevantes examinados}}$$



UNIVERSIDAD CARLOS III DE MADRID



Colecciones de Prueba: Test collections

- Las tasas de Precision Recall son solo ciertas para determinada colección y determinadas preguntas, no es extrapolable
- Colecciones predefinidas de documentos, preguntas y juicios de relevancia (ajuste de cada documento a cada pregunta)→Benchmarking
- Sirven para mejorar los algoritmos de recuperación y posicionamiento
- Tendencia a ajustarse a la realidad. En sus inicios eran documentos breves y las preguntas no eran las típicas de los usuarios
- En un principio con etiquetas propias, actualmente con DTDs de XML
- Existen competiciones en que varios motores muestran sus prestaciones:
 - TREC (Recuperación), Message Understanding Conferences (MUC), Document Understanding Conferences (DUC), Cross-Language Evaluation Forum (CLEF), Summarization evaluation effort (SUMMAC), SENSEVAL (Semántica), CLEF (Multilingüe)
 - Colecciones clásicas: <ftp://ftp.cs.cornell.edu/pub/smart>



UNIVERSIDAD CARLOS III DE MADRID





Colecciones clásicas (Smart)

COLECCIÓN	DOCS	terms	PREG	terms	TAMAÑO
CACM Informatica	3,204	10,446	64	11,4	1.5
CISI Biblio.	1,460	7,392	112	8,1	1.3
CRAN Aeronau.	1,400	258,771	225	4043	1.6
MED Medicina	1,033		30		1.1
TIME Articulos	425		83		1.5



UNIVERSIDAD CARLOS III DE MADRID





Cranfield

- Ejemplo documento
 - .I 250
 - .T pressure distributions at zero lift for delta wings with rhombic cross sections .
 - .A eminton,e.
 - .B arc cp.525, 1960.
 - .W pressure distributions at zero lift for delta wings with rhombic cross sections ... calculation and some of the results are compared with those of slender thin wing theory .
- Ejemplo pregunta
 - .I 029
 - .W material properties of photoelastic materials .



UNIVERSIDAD CARLOS III DE MADRID





Cranfield

- Evaluación

Pregunta ID	Documento ID	Grado Relevancia
29	225	3
29	250	2
29	464	4
29	513	-1



UNIVERSIDAD CARLOS III DE MADRID



Campos en las colecciones clásicas

- Título, Autor, Fuente (casi todas)
- Resumen (Cranfield, CISI, Time, Medline)
- Fecha (Time, CACM)
- Raíces de palabras (CACM, CISI)
- Referencias (CACM)
- Categoría (CACM)
- Cocitaciones (CACM, CISI)
- Preguntas con autor y su perfil de trabajo (CACM)
- Glosario (Time, CACM)



UNIVERSIDAD CARLOS III DE MADRID



TREC

- ❑ Antiguo TIPSTER, organizado por NIST y por DARPA
- ❑ Existen distintas modalidades, algunos son:
 - Ad hoc: Aparecen nuevas preguntas pero el corpus de documentos es fijo
 - Routing: Aparecen nuevos documentos pero el corpus de preguntas es fijo. Existe un corpus de entrenamiento
 - Grandes Corpus: de hasta 8 millones de documentos
- ❑ TREC tiene estadísticas propias de análisis que son las que la han dado su aceptación



UNIVERSIDAD CARLOS III DE MADRID



Ejemplo Documento

```
<DOC>
<DOCNO> WSJ870324-0001 </DOCNO>
<HL> John Blair Is Near Accord To Sell Unit, Sources Say </HL>
<DD> 03/24/87</DD>
<SO> WALL STREET JOURNAL (J) </SO>
<IN> REL TENDER OFFERS, MERGERS, ACQUISITIONS (TNM) MARKETING, ADVERTISING (MKT)
TELECOMMUNICATIONS, BROADCASTING, TELEPHONE, TELEGRAPH (TEL) </IN>
<DATELINE> NEW YORK </DATELINE>
<TEXT>
  John Blair & Co. is close to an agreement to sell its TV station advertising
  representation operation and program production unit to an investor group led by
  James H. Rosenfield, a former CBS Inc. executive, industry sources said. Industry
  sources put the value of the proposed acquisition at more than $100 million. ...
</TEXT>
</DOC>
```



UNIVERSIDAD CARLOS III DE MADRID





TREC Consulta

<top> <head> Tipster Topic Description
<num> Number: 066
<dom> Domain: Science and Technology
<title> Topic: Natural Language Processing
<desc> Description: Document will identify a type of natural language processing technology which is being developed or marketed in the U.S.
<narr> Narrative: A relevant document will identify a company or institution developing or marketing a natural language processing technology, identify the technology, and identify one of more features of the company's product.
<con> Concept(s): 1. natural language processing ;2. translation, language, dictionary
<fac> Factor(s): **<nat>** Nationality: U.S.**</nat></fac>**
<def> Definitions(s): **</top>**



UNIVERSIDAD CARLOS III DE MADRID

