

¿Son adecuados  
los buscadores  
modernos?

Estudio realizado sobre *logs* de *AlltheWeb*. Jansen, B.J. y Spink, A. 2003, "An Analysis of Web Documents Retrieved and Viewed", *The 4<sup>th</sup> International Conference on Internet Computing*, pp. 65-69.

24 horas

150.000 sesiones de usuario

450.000 consultas

13% de las consultas eran únicas

53% de las sesiones constituidas por una única consulta

54% de las sesiones sólo examinaron primera página de resultados

54% de las consultas sólo examinaron un único resultado

66% de las sesiones examinaron de 1 a 5 resultados

Para 530 consultas evaluadas "manualmente" en el 48,5% de los casos el resultado visitado no era relevante

¿Son adecuados  
los buscadores  
modernos?

Estudio realizado sobre *logs* de *AlltheWeb*. Jansen, B.J. y Spink, A. 2003, "An Analysis of Web Documents Retrieved and Viewed", *The 4<sup>th</sup> International Conference on Internet Computing*, pp. 65-69.

Conclusiones Jansen y Spink

Mayoría de usuarios tienen necesidades de información simples

Los buscadores resuelven bien este tipo de consultas

Usuario promedio necesita ver 2 documentos para encontrar

1 relevante

¿Mis conclusiones?

Echémosle un ojo a este artículo que trabaja sobre los mismos *logs*...

Jansen, B.J. y Spink, A. 2006. "How are we searching the World Wide Web? A comparison of nine search engine transaction logs", *Information Processing and Management*



Sistemas y servicios informáticos para Internet (2007/08) Departamento de Informática  
 Oviedo, 3, 4 y 5 de Marzo de 2008 Web Semántica

**Distribución temática de las consultas (2.503 consultas)**

People, places or things	22,50%
Computers or Internet	21,80%
Commerce, travel, employment, or economy	12,30%
Entertainment or recreation	9,10%
Sex and pornography	10,80%
Health or sciences	7,80%
Society, culture, ethnicity, or religion	4,80%
Performing or fine arts	4,70%
Education or humanities	2,90%
Government or legal	2,70%
Non-English or unknown	0,60%

**¿Son adecuados los buscadores modernos?**

- 42,4% de todas las consultas son sobre famosos, ocio y sexo ("fáciles")
- 55%-84% de las consultas más frecuentes son análogas (dependiendo de la lista el porcentaje de sexo varía entre el 3%, el 48% o el 60%)
- Las consultas frecuentes suponen entre el 2% y el 18% del total de consultas
- Este tipo de consultas constituyen el 45% del total...

Sistemas y servicios informáticos para Internet (2007/08) Departamento de Informática  
 Oviedo, 3, 4 y 5 de Marzo de 2008 Web Semántica

**Más datos (elaboración propia)**

- Relevancia promedio de los resultados está, efectivamente, alrededor del 50%
- Sin embargo, ¿cuál es la dispersión?
- 20% consultas de la muestra tiene una precisión media del 21%
- 23% consultas no obtienen ningún resultado relevante en la primera página
- Estimación: 15%-20% todas las consultas no obtienen resultados relevantes

**¿Son adecuados los buscadores modernos?**

**Mis conclusiones**

- Casi la mitad de las consultas son relativas a famosos, ocio y sexo (es decir, "fáciles" de satisfacer)
- En consecuencia, casi la mitad de los usuarios quedan satisfechos con los resultados
- Pero... **Un porcentaje sustancial de consultas exige a los usuarios "bucear" más allá de la primera página de resultados**



(Más) Problemas del  
ranking basado en  
hiperenlaces

Tres escenarios problemáticos

- ★ Bharat, K., y Henzinger, M. 1998, "Improved Algorithms for Topic Distillation in a Hyperlinked Environment", en *Proceedings of SIGIR-98, 21st ACM International Conference on Research and Development in Information Retrieval*, pp. 104-111.

Enlaces "nepotistas"

Cada enlace es un "voto" aunque provengan todos del mismo servidor

No es un problema fácil de resolver. Davison, B.D. 2000, "Recognizing Nepotistic Links on the Web", en *Proceedings of AAAI-2000 Workshop on Artificial Intelligence for Web Search*, pp. 23-28.

Enlaces automáticos

Todos estos algoritmos parten del supuesto que los enlaces son establecidos por un ser humano y eso no siempre es cierto (*Wordpress scandal*)

Documentos irrelevantes enlazados desde autoridades

Inevitable puesto que no hay ningún análisis de contenidos, sólo se emplea la topología del grafo

(Más) Problemas del  
ranking basado en  
hiperenlaces

Page, L., Brin, S., Motwani, R. y Winograd, T. 1998, *The PageRank Citation Ranking: Bringing Order to the Web*

“ [...] PageRanks are virtually immune to manipulation by commercial interests. For a page to get a high PageRank, it must convince an important page, or a lot of non-important pages to link to it. At worst, you can have manipulation in the form of buying advertisements (links) on important sites. But, this seems well under control since it costs money.

(Más) Problemas del  
ranking basado en  
hiperenlaces

Page, L., Brin, S., Motwani, R. y Winograd, T. 1998, *The PageRank Citation Ranking: Bringing Order to the Web*

“ [...] PageRanks are virtually immune to manipulation by commercial interests. For a page to get a high PageRank, it must convince an important page, or a lot of non-important pages to link to it. At worst, you can have manipulation in the form of buying advertisements (links) on important sites. But, this seems well under control since it costs money.

**PWA PWA PWA!!!**

(Más) Problemas del  
ranking basado en  
hiperenlaces

Granjas de enlaces

Recordemos que el *PageRank* total es constante, sólo se reparte entre los nodos

¿Qué sucede si se construye un grafo con gran cantidad de nodos fuertemente conectados y unos pocos reciben la mayoría de enlaces?

Respuesta: Una porción del *PageRank* global termina en ese subgrafo y es asignada en su práctica totalidad a unos pocos nodos que aumentan su *PageRank* artificialmente

Si, además, la granja de enlaces es alojada o enlazada desde algún sitio “prestigioso” mejor que mejor

(Más) Problemas del  
ranking basado en  
hiperenlaces

**Google bombing**

Además de emplear la topología derivada de los enlaces *Google* (y el resto de buscadores) emplea/ba el texto de los enlaces que recibe una página para indexarla (ej. `google compra youtube`)

Si varios sitios web coordinados enlazan a un tercero empleando el mismo término o frase es posible construir "bromas" como las famosas: `ladrones, miserable failure` o `horrid operating system`

A finales de enero de 2007 *Google* anunció que las "bombas" ya no funcionaban gracias a una solución algorítmica

Pero...

Algunas siguen funcionando: `horrid operating system`

Búsquedas que deberían funcionar no lo hacen: `spanish airlines`

Todos los buscadores son vulnerables a esta técnica

*Off-topic*: ¿qué retornan las consultas `click here` o `pinche aquí`?

(Más) Problemas del  
ranking basado en  
hiperenlaces

**Daños "colaterales" (usuarios y autores)**

La ausencia de "prestigio" no implica carencia de relevancia

Al desvincularse el "prestigio" de los contenidos, resultados "prestigiosos" pueden satisfacer la consulta pero no al usuario.

El autor del documento puede no desear tales visitas.

Algunas consultas reales que me han traído "público"...

`algoritmos genéticos (documentos en inglés)`

`que es disertacion doctoral`

`articulos o comentarios de prensa sobre algoritmos geneticos`

¿Qué tienen en común? Son **consultas informativas**, el usuario quiere información/respuestas. Broder, A. 2002, "A taxonomy of web search", *ACM SIGIR Forum*, vol. 36, no. 2, pp. 3-10. ★

Sistemas y servicios informáticos para Internet (2007/08) Departamento de Informática  
 Oviedo, 3, 4 y 5 de Marzo de 2008 Web Semántica

En la Web también hay *spam* L y es preciso detectarlo y luchar contra él... Por esa razón se habla de *adversarial information retrieval*

**Algunos artículos interesantes:**

Gyöngyi, Z. *et al.* 2004, "Combating web spam with TrustRank"  
 Gyöngyi, Z. y Garcia-Molina, H. 2005, "Web spam taxonomy"  
 Fetterly, D. *et al.* 2004, "Spam, damn spam, and statistics: using statistical analysis to locate spam web pages"  
 Benczúr, A.A. *et al.* 2005, "SpamRank-Fully Automatic Link Spam Detection Work in progress"  
 Ntoulas, A. *et al.* 2006, "Detecting spam web pages through content analysis"  
 Becchetti, L. *et al.* 2006, "Link-Based Characterization and Detection of Web Spam"  
 Castillo, C. *et al.* 2006, "A reference collection for web spam"

(Más) Problemas del ranking basado en hiperenlaces

Web Spam Challenge  
<http://webspam.lip6.fr/>

Sistemas y servicios informáticos para Internet (2007/08) Departamento de Informática  
 Oviedo, 3, 4 y 5 de Marzo de 2008 Web Semántica

Los buscadores actuales son muy buenos...

...localizando sitios web conocidos/"oficiales"  
 ...facilitando el acceso a servicios *on-line* (mapas, tiempo, *e-mail*, subastas, etc.)  
 ...resolviendo consultas simples (famosos, ocio y sexo)

En suma... Satisfciendo a la mayor parte de la gente la mayor parte del tiempo

Pero como fuente de información la Web sigue siendo...

No hay talla única...



... y recordemos que  
las suposiciones  
son falsas

La Web no es un grafo fuertemente conectado,

Broder, A. et al. 2000, "Graph structure in the web: experiments and models", en *Proceedings of the ninth WWW Conference*

Sólo el 90% de la Web está fuertemente conectada

Meiss, M.R. et al. 2008, "Ranking web sites with real user traffic" ★

“ PageRank ranks sites very differently than actual human traffic, especially for the most important hosts. This finding is interpreted in light of *our empirical analysis, showing how each of the random behavior assumptions underlying PageRank is violated*: not all links from a site are followed equally, but even more importantly, some sites are much more likely than others to be the starting or ending points of surfing sessions.

Presente y futuro de la Web

¿Web 2.0?

Filtrado colaborativo

Personalización

Minería Web (*Web Mining*)

Análisis de tendencias

*Normalized Google Distance*

La Web como *corpus*

Para saber más...

Evolución

Sistemas y servicios informáticos para Internet (2007/08) Departamento de Informática  
 Oviedo, 3, 4 y 5 de Marzo de 2008 Web Semántica

¿Web 2.0?

O'Reilly, T. 2006, *Web 2.0 Compact Definition: Trying Again*

“ Web 2.0 is the business revolution in the computer industry caused by the move to the internet as platform, and an attempt to understand the rules for success on that new platform. Chief among those rules is this: Build applications that harness network effects to get better the more people use them.



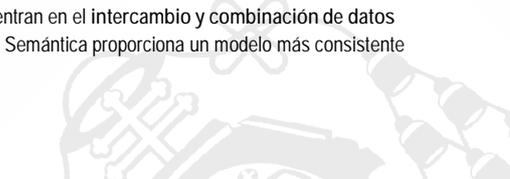
Sistemas y servicios informáticos para Internet (2007/08) Departamento de Informática  
 Oviedo, 3, 4 y 5 de Marzo de 2008 Web Semántica

¿Web 2.0?

¿Son lo mismo Web 2.0 y Web Semántica?

Según Tim Berners-Lee se parecen lo mismo que un huevo a una castaña (*"chalk and cheese"*)... Sin embargo, son buenas por separado y mucho mejor juntas

Según el W3C ambas se centran en el intercambio y combinación de datos heterogéneos pero la Web Semántica proporciona un modelo más consistente



Sistemas y servicios informáticos para Internet (2007/08) Departamento de Informática  
 Oviedo, 3, 4 y 5 de Marzo de 2008 Web Semántica

¿Web 2.0?

The diagram, titled "Web 2.0 Meme Map", features a central orange box with the following text:

- Strategic Positioning:**
  - The Web as Platform
- User Positioning:**
  - You control your own data
- Core Competencies:**
  - Services, not packaged software
  - Architecture of Participation
  - Cost-effective scalability
  - Remixable data source and data transformations
  - Software above the level of a single device
  - Harnessing collective intelligence

Surrounding this central box are various concepts and examples in ovals:

- Top row (green ovals):** Flickr, del.icio.us: Tagging, not taxonomy; PageRank, eBay reputation, Amazon reviews: user as contributor; Blogs: Participation, Not publishing; BitTorrent: Radical Decentralization.
- Second row (green ovals):** Gmail, Google Maps and AJAX: Rich User Experiences; Google AdSense: customer self-service enabling the long tail; Wikipedia: Radical Trust.
- Left side (tan ovals):** "An attitude, not a technology"; The Long Tail; Data as the "Intel Inside"; Hackability.
- Right side (tan ovals):** Trust your users; Small Pieces Loosely Joined (web as components); Rich User Experience; Granular Addressability of content.
- Bottom row (tan ovals):** The perpetual beta; Software that gets better: the more people use it; Play; Emergent: User behavior not predetermined; The Right to Remix "Some rights reserved"; Granular Addressability of content.

Sistemas y servicios informáticos para Internet (2007/08) Departamento de Informática  
 Oviedo, 3, 4 y 5 de Marzo de 2008 Web Semántica

¿Web 2.0?

This diagram is identical to the one above, but with several elements circled in red to highlight specific concepts:

- Flickr, del.icio.us: Tagging, not taxonomy
- PageRank, eBay reputation, Amazon reviews: user as contributor
- Trust your users
- The Long Tail
- Software that gets better: the more people use it
- Small Pieces Loosely Joined (web as components)
- Hackability

Sistemas y servicios informáticos para Internet (2007/08) Departamento de Informática  
 Oviedo, 3, 4 y 5 de Marzo de 2008 Web Semántica

**HYPE!  
WIZZ!**

**También hay algunos puntos interesantes...**

“ People subscribe to each others' sites, and easily link to individual comments on a page, but also, via [...] trackbacks, they can see when anyone else links to their pages, and can respond [...] Interestingly, two-way links were the goal of early hypertext systems like Xanadu. Hypertext purists have celebrated trackbacks as a step towards two way links.

...  
 “ (The Long Tail) Small sites make up the bulk of the internet's content; [...] Therefore: Leverage customer-self service and algorithmic data management to reach out to the entire web, to the edges and not just the center, to the long tail and not just the head.

...  
 “ The key to competitive advantage in internet applications is **the extent to which users add their own data to that which you provide.**

¿Web 2.0?

Sistemas y servicios informáticos para Internet (2007/08) Departamento de Informática  
 Oviedo, 3, 4 y 5 de Marzo de 2008 Web Semántica

**Folksonomía (folksonomy = folk + taxonomy)**

Una forma de metadatos

Etiquetado colaborativo de recursos en la Web

Las etiquetas no proceden de un vocabulario controlado sino que son elegidas libremente por los usuarios

La co-ocurrencia de etiquetas lleva a las folksonomías...

Otra cuestión es cómo emplearlas (más allá de la búsqueda por “serendipia”)

Ejemplos: *del.icio.us, flickr, tagzania*

Problemas: sinonimia, polisemia, acrónimos, términos multipalabra, multilingüismo...

Mathes, A. 2004, *Folksonomies – Cooperative Classification and Communication Through Shared Metadata*

¿Web 2.0?

### Filtrado colaborativo

Un sistema de filtrado de información procesa grandes volúmenes de datos para transmitir al usuario sólo aquellos *items* con mayores probabilidades de ser "interesantes"

El filtrado puede hacerse en base al contenido de los *items* o en base al juicio de otros usuarios del sistema (colaborativo)

El filtrado colaborativo no es reciente...

★ Goldberg, D., Nichols, D., Oki, B.M. y Terry, D. 1992, "Using Collaborative Filtering to Weave an Information Tapestry", *Com. of the ACM*, vol.35, no.12, pp. 61-70.

...Amazon lleva usándolo desde hace bastante tiempo ("*Customers who bought this book also bought*"). Funciona muy bien porque los usuarios "votan con dólares"

Otros ejemplos: *last.fm* (música), *IMDB* (películas)

### Personalización

No hay talla única. Cada usuario es un mundo...

Lo ideal sería darle a cada persona justo lo que necesita

El problema es ¿cómo?

**PageRank personalizado.** Recordemos el modelo del *random surfer*, había una probabilidad  $d$  de "saltar" a una página cualquiera de la Web; sin embargo no todas las páginas de la Web tienen que ser equiprobables. Page, L., et al. 1998, *The PageRank Citation Ranking: Bringing Order to the Web*

Inviabile, no se puede calcular el *PageRank* para toda la Web y cada usuario

Otra posible solución radicaría en calcular el *PageRank* tras dividir la Web en subgrafos "temáticos"; después se personalizaría la consulta en base a la temática de la misma y/o la detectada en el contexto del usuario. Haveliwala, T.H. 2003, "Topic-sensitive pagerank: A context-sensitive ranking algorithm for web search", *IEEE Transactions on Knowledge and Data Engineering*

**Explotando el historial de búsquedas y consultas.** Lawrence, S. 2000, "Context in Web Search", *IEEE Data Engineering Bulletin*, vo. 23, no. 3, pp. 25-32

Sistemas y servicios informáticos para Internet (2007/08) Departamento de Informática  
 Oviedo, 3, 4 y 5 de Marzo de 2008 Web Semántica

---

---

for [daniel.gayo@gmail.com](mailto:daniel.gayo@gmail.com)

Searches	Pages
Recent top queries related to your searches	Web pages related to your searches
<ol style="list-style-type: none"> <li>1. <a href="#">google apps</a></li> <li>2. <a href="#">erika oniz</a></li> <li>3. <a href="#">la casa de tu vida</a></li> <li>4. <a href="#">yahoo pipes</a></li> <li>5. <a href="#">constantine the great</a></li> <li>6. <a href="#">punic wars</a></li> <li>7. <a href="#">how student loans affect fico score</a></li> <li>8. <a href="#">jim gray</a></li> <li>9. <a href="#">jaimé pedraza</a></li> <li>10. <a href="#">lupercalia</a></li> </ol>	<ol style="list-style-type: none"> <li>1. <a href="#">AAAI-07: Twenty-Second Conference on Artificial Intelligence</a></li> <li>2. <a href="#">VLDB 2007 - 33rd Very Large Data Bases Conference</a></li> <li>3. <a href="#">2007 International Conference on Machine Learning</a></li> <li>4. <a href="#">TAIR - Home Page</a></li> <li>5. <a href="#">Sigma-Aldrich.com</a></li> <li>6. <a href="#">Invitrogen - Welcome To Invitrogen</a></li> <li>7. <a href="#">Perseus Project</a></li> <li>8. <a href="#">WORDS Latin-to-English Dictionary</a></li> <li>9. <a href="#">A Latin-English Dictionary Program - WORDS</a></li> <li>10. <a href="#">eBay: comprar y vender nuevo y segunda mano. Subastas, subasta y ...</a></li> </ol>

Sistemas y servicios informáticos para Internet (2007/08) Departamento de Informática  
 Oviedo, 3, 4 y 5 de Marzo de 2008 Web Semántica

---

---

for [daniel.gayo@gmail.com](mailto:daniel.gayo@gmail.com)

Searches	Pages
Recent top queries related to your searches	Web pages related to your searches
<ol style="list-style-type: none"> <li>1. <a href="#">google apps</a></li> <li>2. <a href="#">erika oniz</a></li> <li>3. <a href="#">la casa de tu vida</a></li> <li>4. <a href="#">yahoo pipes</a></li> <li>5. <a href="#">constantine the great</a></li> <li>6. <a href="#">punic wars</a></li> <li>7. <a href="#">how student loans affect fico score</a></li> <li>8. <a href="#">jim gray</a></li> <li>9. <a href="#">jaimé pedraza</a></li> <li>10. <a href="#">lupercalia</a></li> </ol>	<ol style="list-style-type: none"> <li>1. <a href="#">AAAI-07: Twenty-Second Conference on Artificial Intelligence</a></li> <li>2. <a href="#">VLDB 2007 - 33rd Very Large Data Bases Conference</a></li> <li>3. <a href="#">2007 International Conference on Machine Learning</a></li> <li>4. <a href="#">TAIR - Home Page</a></li> <li>5. <a href="#">Sigma-Aldrich.com</a></li> <li>6. <a href="#">Invitrogen - Welcome To Invitrogen</a></li> <li>7. <a href="#">Perseus Project</a></li> <li>8. <a href="#">WORDS Latin-to-English Dictionary</a></li> <li>9. <a href="#">A Latin-English Dictionary Program - WORDS</a></li> <li>10. <a href="#">eBay: comprar y vender nuevo y segunda mano. Subastas, subasta y ...</a></li> </ol>

Sistemas y servicios informáticos para Internet (2007/08) Departamento de Informática  
 Oviedo, 3, 4 y 5 de Marzo de 2008 Web Semántica

---

---

for [daniel.gayo@gmail.com](mailto:daniel.gayo@gmail.com)

Searches	Pages
Recent top queries related to your searches <ol style="list-style-type: none"> <li>1. <a href="#">google apps</a></li> <li>2. <a href="#">erika oniz</a></li> <li>3. <a href="#">la casa de tu vida</a></li> <li>4. <a href="#">yahoo pipes</a></li> <li>5. <a href="#">constantine the great</a></li> <li>6. <a href="#">punic wars</a></li> <li>7. <a href="#">how student loans affect fico score</a></li> <li>8. <a href="#">jim gray</a></li> <li>9. <a href="#">jaimé peñafiel</a></li> <li>10. <a href="#">lysergalia</a></li> </ol>	Web pages related to your searches <ol style="list-style-type: none"> <li>1. <a href="#">AAAI-07: Twenty-Second Conference on Artificial Intelligence</a></li> <li>2. <a href="#">VLDB 2007 - 33rd Very Large Data Bases Conference</a></li> <li>3. <a href="#">2007 International Conference on Machine Learning</a></li> <li>4. <a href="#">TAIR - Home Page</a></li> <li>5. <a href="#">Sigma-Aldrich.com</a></li> <li>6. <a href="#">Invitrogen - Welcome To Invitrogen</a></li> <li>7. <a href="#">Perseus Project</a></li> <li>8. <a href="#">WORDS Latin-to-English Dictionary</a></li> <li>9. <a href="#">A Latin-English Dictionary Program - WORDS</a></li> <li>10. <a href="#">eBay: comprar y vender nuevo y segunda mano. Subastas, subasta y ...</a></li> </ol>

Sistemas y servicios informáticos para Internet (2007/08) Departamento de Informática  
 Oviedo, 3, 4 y 5 de Marzo de 2008 Web Semántica

---

---

for [daniel.gayo@gmail.com](mailto:daniel.gayo@gmail.com)

Searches	Pages
Recent top queries related to your searches <ol style="list-style-type: none"> <li>1. <a href="#">google apps</a></li> <li>2. <a href="#">erika oniz</a></li> <li>3. <a href="#">la casa de tu vida</a></li> <li>4. <a href="#">yahoo pipes</a></li> <li>5. <a href="#">constantine the great</a></li> <li>6. <a href="#">punic wars</a></li> <li>7. <a href="#">how student loans affect fico score</a></li> <li>8. <a href="#">jim gray</a></li> <li>9. <a href="#">jaimé peñafiel</a></li> <li>10. <a href="#">lysergalia</a></li> </ol>	Web pages related to your searches <ol style="list-style-type: none"> <li>1. <a href="#">AAAI-07: Twenty-Second Conference on Artificial Intelligence</a></li> <li>2. <a href="#">VLDB 2007 - 33rd Very Large Data Bases Conference</a></li> <li>3. <a href="#">2007 International Conference on Machine Learning</a></li> <li>4. <a href="#">TAIR - Home Page</a></li> <li>5. <a href="#">Sigma-Aldrich.com</a></li> <li>6. <a href="#">Invitrogen - Welcome To Invitrogen</a></li> <li>7. <a href="#">Perseus Project</a></li> <li>8. <a href="#">WORDS Latin-to-English Dictionary</a></li> <li>9. <a href="#">A Latin-English Dictionary Program - WORDS</a></li> <li>10. <a href="#">eBay: comprar y vender nuevo y segunda mano. Subastas, subasta y ...</a></li> </ol>

Sistemas y servicios informáticos para Internet (2007/08) Departamento de Informática  
 Oviedo, 3, 4 y 5 de Marzo de 2008 Web Semántica

---

for [daniel.gayo@gmail.com](mailto:daniel.gayo@gmail.com)

Searches	Pages
Recent top queries related to your searches	Web pages related to your searches
<ol style="list-style-type: none"> <li>1. <a href="#">google apps</a></li> <li>2. <a href="#">erika oniz</a></li> <li>3. <a href="#">la casa de tu vida</a></li> <li>4. <a href="#">yahoo pipes</a></li> <li>5. <a href="#">constantine the great</a></li> <li>6. <a href="#">punic wars</a></li> <li>7. <a href="#">how student loans affect fice score</a></li> <li>8. <a href="#">jim gray</a></li> <li>9. <a href="#">jaimé spañalej</a></li> <li>10. <a href="#">lysergalia</a></li> </ol>	<ol style="list-style-type: none"> <li>1. <a href="#">AAAI-07: Twenty-Second Conference on Artificial Intelligence</a></li> <li>2. <a href="#">VLDB 2007 - 33rd Very Large Data Bases Conference</a></li> <li>3. <a href="#">2007 International Conference on Machine Learning</a></li> <li>4. <a href="#">Paris - Home Page</a></li> <li>5. <a href="#">Bloma.Aldrich.com</a></li> <li>6. <a href="#">Invitrogen - Welcome To Invitrogen</a></li> <li>7. <a href="#">Perseus Project</a></li> <li>8. <a href="#">WORDSE Latin-to-English Dictionary</a></li> <li>9. <a href="#">A Latin-English Dictionary Program - WORDS</a></li> <li>10. <a href="#">eBay: comprar y vender nuevo y segunda mano. Subastas, subasta y ...</a></li> </ol>

Sistemas y servicios informáticos para Internet (2007/08) Departamento de Informática  
 Oviedo, 3, 4 y 5 de Marzo de 2008 Web Semántica

**Minería web**  
(Web Mining)

La **extracción de conocimiento de la Web**, **minería Web** o **Web mining** tiene como objetivo extraer información útil mediante el procesamiento de los ingentes volúmenes de datos que existen en la Web y que se generan con su uso diario

La minería Web puede dividirse en tres grandes áreas:

- Extracción de conocimiento a partir de la **estructura hipertextual** de la Web (p.ej. algoritmos *PageRank* y *HITS*)
- Extracción de conocimiento a partir del **uso de la Web** (p.ej. *logs* de servidores y buscadores)
- Extracción de conocimiento a partir de los **contenidos disponibles** en la Web (la Web como *corpus*)

**Multidisciplinar:** aprendizaje automático, procesamiento de lenguaje natural, estadística, recuperación de información, bases de datos

### Minería web (Web Mining)

Los **buscadores modernos** son un ejemplo del conocimiento que se puede derivar de la **estructura topológica** de la Web

Los sistemas de **filtrado colaborativo** obtienen conocimiento a partir de las acciones de los usuarios en un sitio web concreto (podría considerarse un caso particular de **minería de uso**)

Aplicar minería de datos a los **archivos de log de un servidor web** no es nuevo

Mobasher, B. *et al.* 1996, *Web Mining: Pattern Discovery from World Wide Web Transactions*, informe técnico, Universidad de Minnesota

### Minería web (Web Mining)

Todos los servidores web generan archivos de **log** en los que se recoge información sobre las **acciones de los usuarios** en el sitio web

```
156.35.14.9 - - [17/Oct/2006:20:34:26 +0200] "GET /nol/shared/css/news_r5.css HTTP/1.0" 404 312
156.35.14.9 - - [17/Oct/2006:20:34:26 +0200] "GET /shared/css/toolbar_banner.css HTTP/1.0" 404 315
156.35.14.9 - - [17/Oct/2006:20:35:23 +0200] "GET /CursoWeb20/ HTTP/1.0" 200 1894
156.35.14.9 - - [17/Oct/2006:20:35:23 +0200] "GET /icons/blank.gif HTTP/1.0" 200 148
156.35.14.9 - - [17/Oct/2006:20:35:23 +0200] "GET /icons/back.gif HTTP/1.0" 200 216
156.35.14.9 - - [17/Oct/2006:20:35:23 +0200] "GET /icons/folder.gif HTTP/1.0" 200 225
156.35.14.9 - - [17/Oct/2006:20:35:23 +0200] "GET /icons/compressed.gif HTTP/1.0" 200 1038
```

En realidad, el servidor desconoce quién es el usuario, sólo dispone de su **dirección IP** que, en muchos casos, será utilizada por múltiples usuarios simultáneamente (**proxies**) y en otros será re-utilizada en diversas ocasiones (p.ej. direcciones dinámicas otorgadas por ISPs)

Por esa razón, lo máximo que puede hacerse con la información del archivo de **log** es tratar de encontrar **sesiones de usuario** (conjunto de peticiones realizadas desde una misma IP durante un periodo corto de tiempo)

Sistemas y servicios informáticos para Internet (2007/08) Departamento de Informática  
 Oviedo, 3, 4 y 5 de Marzo de 2008 Web Semántica

**Minería web  
(Web Mining)**

Objetivos de la extracción de conocimiento a partir de archivos de *log*:

- Entender los intereses de los usuarios de un sitio web
- Mejorar, en consecuencia, la satisfacción del usuario al reorganizar el sitio en base a dichos intereses
- Facilitar el acceso a la información mediante recomendaciones en tiempo real

El último objetivo también puede alcanzarse empleando *swarm intelligence*

★ Wu, J. y Aberer, K. 2003, "Swarm Intelligent Surfing in the Web", *ICWE 2003, LNCS 2722*, pp. 431-440

*Off-topic*: video sobre robots, *swarm intelligence* y rastros de feromonas  
<http://www.youtube.com/watch?v=z3E86D4dKN4>

Sistemas y servicios informáticos para Internet (2007/08) Departamento de Informática  
 Oviedo, 3, 4 y 5 de Marzo de 2008 Web Semántica

**Minería web  
(Web Mining)**

Los **motores de búsqueda** también disponen de archivos de *log* en los que se almacena información como:

- Identificador de sesión
- Fecha y hora
- Texto de la consulta
- URL visitada
- Posición de la URL visitada dentro de la página de resultados

### Minería web (Web Mining)

Los *logs* de un buscador resultan muy útiles para mejorar la **precisión**

Baeza-Yates, R. 2004, "Query Usage Mining in Search Engines", en *Web Mining: Applications and Techniques*

“ After a query, a user usually performs a click to view one answer page. Each click is considered a positive recommendation of that page (in most cases bad pages are not clicked).

★ Zhang, D. y Dong, Y. 2002, "A novel Web usage mining approach for search engines", *Computer Networks*, vol. 39, no. 3, pp. 303-310

“ A user is "good" if he/she issues many "good" queries, while a query is "good" if it can retrieve many "good" resources, while a resource is "good" if it is accessed by many "good" users.

### Minería web (Web Mining)

Los *logs* de un buscador resultan muy útiles para mejorar la **precisión**

Joachims, T. "Optimizing Search Engines Using Clickthrough Data", *Proceedings of the ACM Conference on Knowledge Discovery and Data Mining (KDD)*

<http://svmlight.joachims.org/>

Más artículos interesantes:

"Accurately Interpreting Clickthrough Data as Implicit Feedback"

"Query-Log Based Authority Analysis for Web Information Search"

"Optimizing Web Search using Spreading Activation on the Clickthrough Data"

### Minería web (Web Mining)

Ricardo Baeza-Yates lleva algún tiempo desarrollando técnicas para **agrupar consultas temáticamente** a partir de los resultados visitados.

★ Baeza-Yates, R. *et al.* 2004, "Query recommendation using query logs in search engines", en *Current Trends in Database Technology*, LNCS 3268, p. 588-596.

Las consultas de un grupo pueden ordenarse en base al porcentaje de documentos relevantes (determinados por los *clicks*) que retorna cada una

Una vez determinados los conjuntos de consultas pueden emplearse para...

... ofrecer consultas alternativas

... **mejorar la precisión de los resultados** (ofreciendo aquellos más relevantes para usuarios anteriores)

Más recientemente ha estudiado el modo de extraer **pseudo-folksonomías** a partir de los conjuntos de consultas

### Minería web (Web Mining)

A mediados de 2006 **Microsoft** financió una serie de proyectos de investigación sobre un conjunto de **15 millones de consultas**

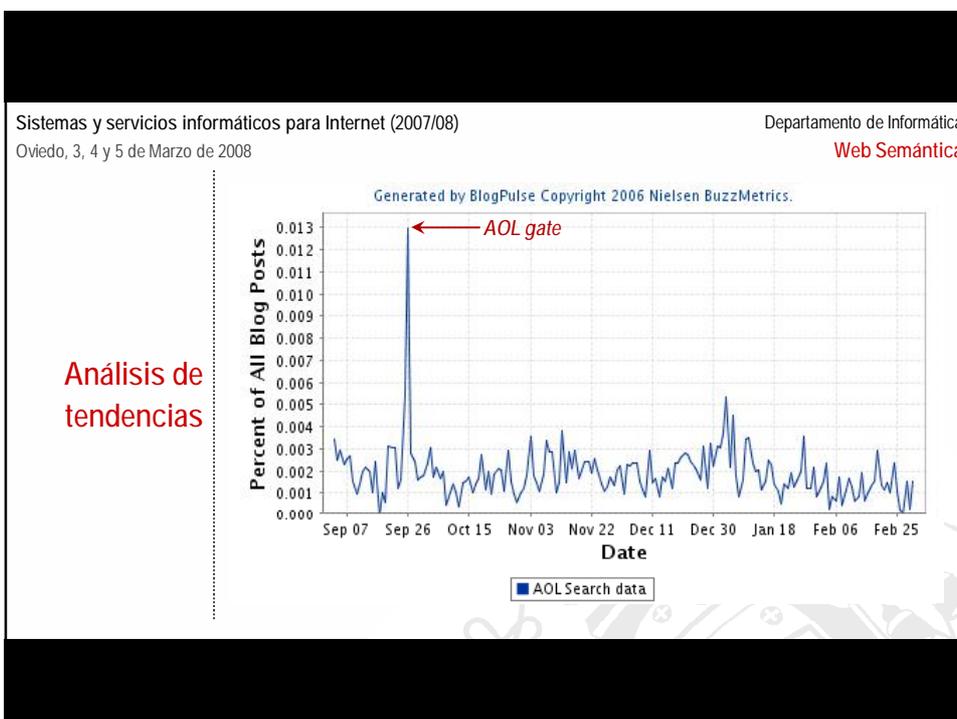
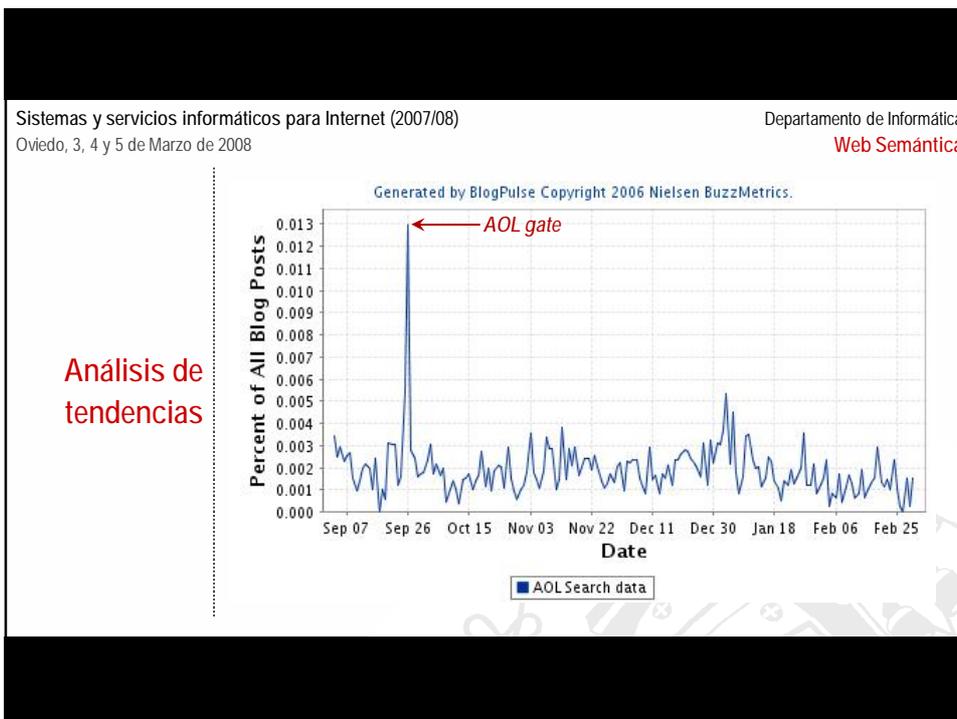
Poco después **AOL** liberó un archivo con datos sobre **20 millones de consultas** correspondientes a **650.000 usuarios** (miniescándalo)...

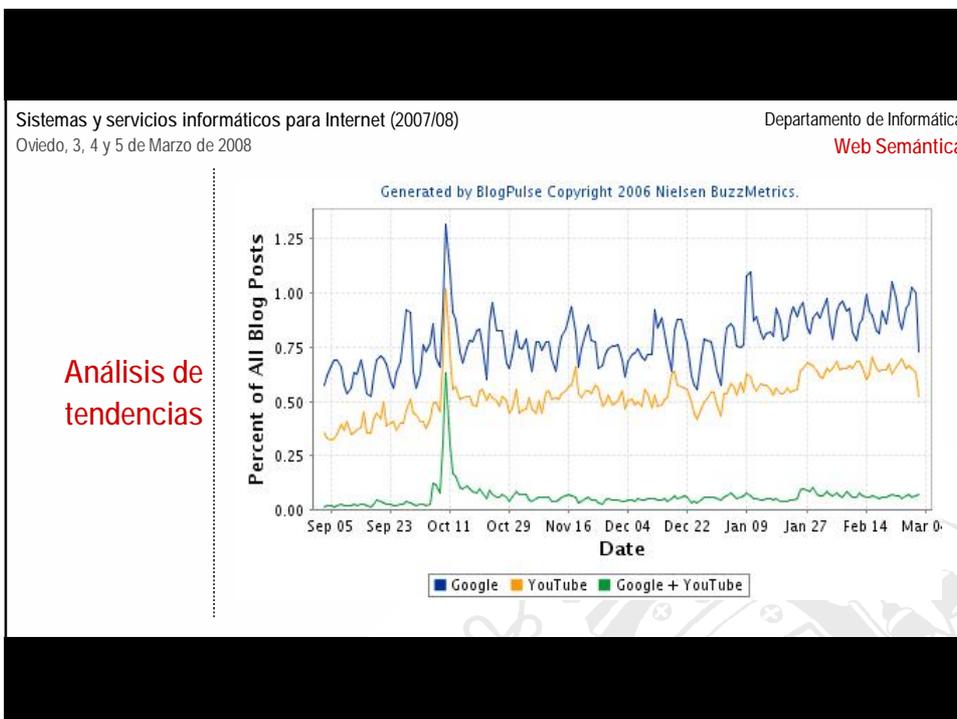
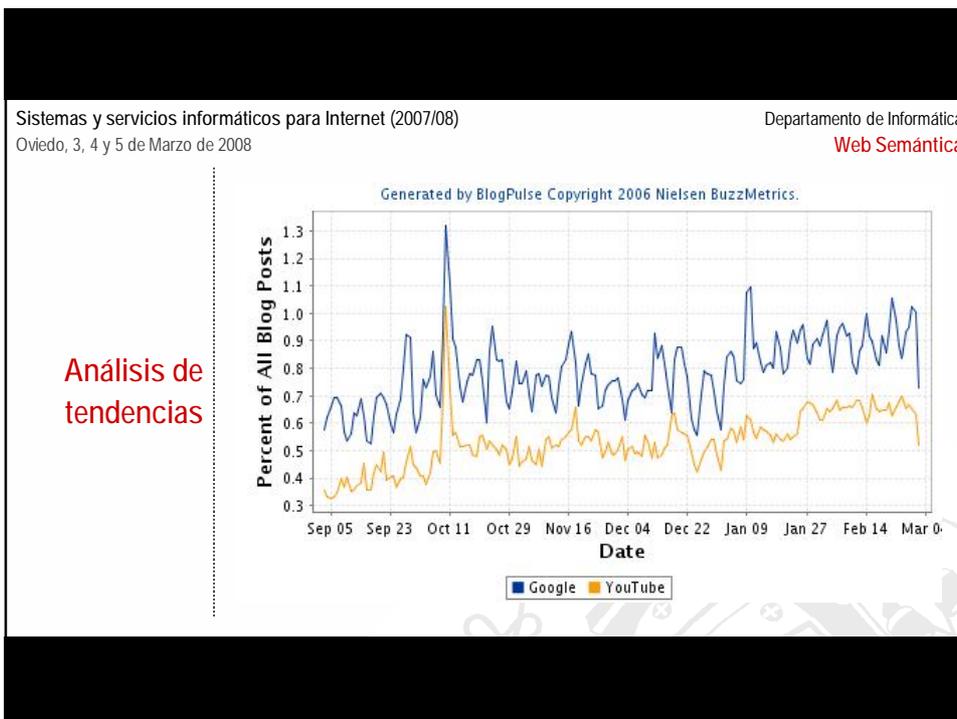
Rodaron cabezas, el sitio web fue eliminado en cuestión de horas y los datos...

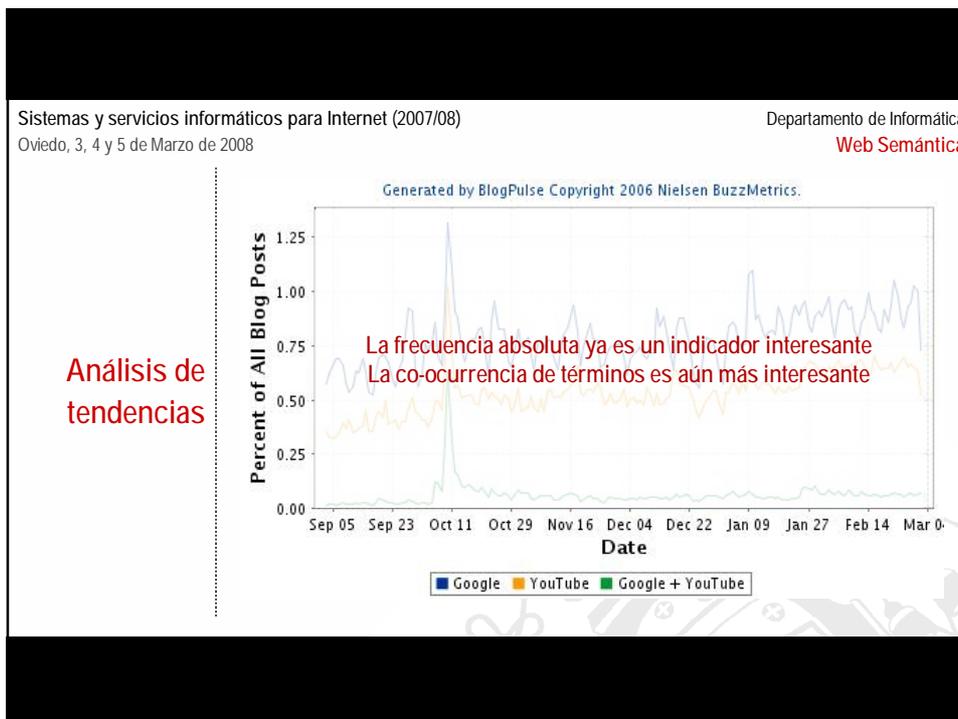
...no tardaron en ser replicados, hoy sobreviven en algunos *mirrors* y redes *P2P*.

Si os interesan quizás podáis descargarlos... **AOL-DATA.TGZ**

En 2007 **Microsoft** volvió a financiar proyectos de investigación relacionados con *semantic computing* e *internet economics* proporcionando, aparentemente, el mismo *log* de consultas que en 2006.







Análisis de  
tendencias

Sistemas y servicios informáticos para Internet (2007/08) Departamento de Informática  
 Oviedo, 3, 4 y 5 de Marzo de 2008 Web Semántica

Cilibrasi, R. y Vitanyi, P. 2005, *Automatic Meaning Discovery Using Google*,  
<http://arxiv.org/abs/cs.CL/0412098> ★

“ The rise of the world-wide-web has enticed millions of users to type in trillions of characters to create billions of web pages of on average low quality contents. The sheer mass of the information available about almost every conceivable topic makes it likely that extremes will cancel and the majority or average is meaningful in a low-quality approximate sense.

Normalized Google Distance (NGD)

$$NGD(x, y) = \frac{\max\{\log f(x), \log f(y)\} - \log f(x, y)}{\log M - \min\{\log f(x), \log f(y)\}}$$

Normalized  
Google  
Distance

Distancias *NGD* entre algunos paísesNormalized  
Google  
Distance

portugal	0	0,02	0,21	0,07	0,23	0,09	0,11
spain	0,02	0	0,18	-0,01	0,15	0,10	0,12
france	0,21	0,18	0	0,16	-0,01	0,20	0,30
italy	0,07	-0,01	0,16	0	0,12	0,11	0,16
germany	0,23	0,15	-0,01	0,12	0	0,17	0,24
belgium	0,09	0,10	0,20	0,11	0,17	0	0,00
netherl.	0,11	0,12	0,30	0,16	0,24	0,00	0

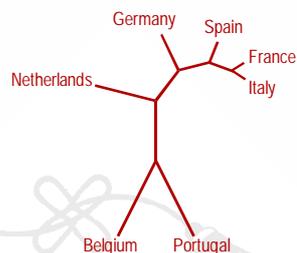
**Primer problema:** *Google* sólo proporciona estimaciones sobre el número total de documentos que contienen una palabra y, muchas veces, es una aproximación demasiado "gruesa" (p.ej. **spain**  $311 \times 10^6$ , **italy**  $303 \times 10^6$ , **spain italy**  $330 \times 10^6$ )

Normalized  
Google  
Distance

## Segundo problema:

¿Sobre qué "eje" se mide la distancia?

En este ejemplo, ¿población? ¿superficie? ¿PIB?



En resumen, interesante, inspiradora... Aún se necesita más trabajo...

Sistemas y servicios informáticos para Internet (2007/08) Departamento de Informática  
 Oviedo, 3, 4 y 5 de Marzo de 2008 Web Semántica

**La Web como corpus**

Un *corpus* es una **colección de documentos** que muestran el uso real de la **lengua natural**

Pueden ser **monolingües** o **multilingües** y estos, a su vez, **paralelos** o **comparables**

Los *corpora* multilingües son un recurso fundamental para la construcción de sistemas estadísticos de traducción automática

★ Brown, P.F. et al. 1990, "A Statistical Approach to Machine Translation", *Computational Linguistics*, vol. 16, no. 2

Viktor aprende inglés comparando dos guías turísticas de Nueva York



<http://video.google.com/videoplay?docid=6934089019347797736>

Sistemas y servicios informáticos para Internet (2007/08) Departamento de Informática  
 Oviedo, 3, 4 y 5 de Marzo de 2008 Web Semántica

**La Web como corpus**

La traducción automática es sólo uno de los campos que puede beneficiarse de la utilización de la Web como *corpus* o, mejor dicho, de *corpora* extraídos de la Web... Sin embargo, es uno de los más espectaculares

Trabajos interesantes:

★ Jones, R. y Ghani, R. 2000, "Automatically Building a Corpus for a Minority Language from the Web", en *Proceedings of the Student Workshop of the 38th Annual Meeting of the Association for Computational Linguistics*, pp. 29-36

★ Resnik, P. y Smith, N.A. 2003, "The Web as a parallel corpus", *Computational Linguistics*, vol. 29, no. 3, pp. 349-380

Kilgarrieff, A. y Grefenstette, G. 2003, "Introduction to the special issue on the web as corpus", *Computational Linguistics*, vol. 29, no. 3, pp. 333-347

A tener en cuenta: WAC (*Web as a Corpus Workshop*), CLEAN EVAL

Sistemas y servicios informáticos para Internet (2007/08) Departamento de Informática  
 Oviedo, 3, 4 y 5 de Marzo de 2008 Web Semántica

Para saber más...

Manning, C.D. y Schütze, H. 1999, *Foundations of statistical natural language processing*, MIT Press ★★★

Chakrabarti, S. 2002, *Mining the Web: Discovering Knowledge from Hypertext Data*, Morgan Kaufmann ★★★

Manning, C.D., Raghavan, P. y Schütze, H. 2007, *Introduction to Information Retrieval*, Cambridge University Press (online) ★★★



Sistemas y servicios informáticos para Internet (2007/08) Departamento de Informática  
 Oviedo, 3, 4 y 5 de Marzo de 2008 Web Semántica

Evolución

Aplicando las técnicas que hemos comentado  
 ¿qué nos depara el futuro?  
 ¿Cómo pueden evolucionar los buscadores?  
 Echemos a volar la imaginación "a la Berners-Lee"... J



Sistemas y servicios informáticos para Internet (2007/08) Departamento de Informática  
 Oviedo, 3, 4 y 5 de Marzo de 2008 Web Semántica

[Web](#) [Images](#) [Video](#) [News](#) [Maps](#) [more »](#)  

  [Advanced Search](#) [Preferences](#)

**Web**

[Rocky Balboa \(2006\)](#)  
 Had the opportunity last night to see the World Premier of **Rocky Balboa** two months before it will be released. A great **movie**. I was impressed with it, ...  
[imdb.com/title/tt0479143/](http://imdb.com/title/tt0479143/) - 42k - [Cached](#) - [Similar pages](#)

[Rocky \(1976\)](#)  
 Story- With minimum resources and low money, this **movie** was an underdog itself. Stallone wrote it and fought to play **Rocky**. When they were low on resources, ...  
[imdb.com/title/tt0075148/](http://imdb.com/title/tt0075148/) - 44k - [Cached](#) - [Similar pages](#)

[Rocky Balboa](#)  
[www.mgm.com/rocky\\_balboa/](http://www.mgm.com/rocky_balboa/) - 4k - [Cached](#) - [Similar pages](#)

[Rocky Balboa](#)  
[www.rockybalboa-derfilm.de/](http://www.rockybalboa-derfilm.de/) - 3k - [Cached](#) - [Similar pages](#)

Lenssen, P. 2007, "Evolution of a search Engine", *Google Blogoscoped*,  
<http://blog.outer-court.com/archive/2007-02-02-n25.html>

Evolución  
El presente

Sistemas y servicios informáticos para Internet (2007/08) Departamento de Informática  
 Oviedo, 3, 4 y 5 de Marzo de 2008 Web Semántica

[Knowledge](#) [Images](#) [Video](#) [News](#) [Maps](#) [more »](#)  

  [Advanced Search](#) [Preferences](#)

**Knowledge**

The **Rocky movie**, which currently hits theaters globally in its 7th installment as [Rocky Balboa Returns](#), is about an "underdog boxer" [1] fighting his way through life and the ring. Originally released in 1976, [Rocky](#), directed by John G. Avildsen and written by Sylvester Stallone, the movie "was an immediate sensation," as [TotalRocky.com](#) writes. The first movie won three Academy Awards, including *Best Picture* [2].

 Sponsor

[Rocky](#)  
 Get Movie Info He  
 Cast/Crew, DVDs  
 TurnerClassicMov

Image from [Hollywood.com](#)

**More knowledge:**

- >> [Rocky Balboa Returns reviews](#)
- >> [How the idea for Rocky was born](#)
- >> [Interviews with Sylvester Stallone](#)
- >> [Other interesting boxing movies](#)

[1] Various sources: [TotalRocky.com](#), [IMDB.com](#), [The Big Book of Film](#), [Answers.com](#)  
 [2] Various sources: [IMDB.com](#), [AcademyAwards.com](#), [Geocities.com/hollywood](#)

Evolución  
El futuro inmediato

Sistemas y servicios informáticos para Internet (2007/08) Departamento de Informática  
 Oviedo, 3, 4 y 5 de Marzo de 2008 Web Semántica

[Knowledge](#) [Images](#) [Video](#) [News](#) [Maps](#) [more »](#)  

  [Advanced Search](#)  
[Preferences](#)

**Knowledge**

The **Rocky movie**, which currently hits theaters globally in its 7th installment as [Rocky Balboa Returns](#), is about an "underdog boxer" [1] fighting his way through life and the ring. Originally released in 1976, [Rocky](#), directed by John G. Avildsen and written by Sylvester Stallone, the movie "was an immediate sensation," as [TotalRocky.com](#) writes. The first movie won three Academy Awards, including *Best Picture* [2].



Image from [Hollywood.com](#)

Sponsor  
**Rocky**  
 Get Movie Info He  
 Cast/Crew, DVDs  
 TurnerClassicMov

**More knowledge:**

- >> [Rocky Balboa Returns reviews](#)
- >> [How the idea for Rocky was born](#)
- >> [Interviews with Sylvester Stallone](#)
- >> [Other interesting boxing movies](#)

[1] Various sources: [TotalRocky.com](#), [IMDB.com](#), [The Big Book of Film](#), [Answers.com](#).  
 [2] Various sources: [IMDB.com](#), [AcademyAwards.com](#), [Geocities.com/hollywood](#).

Clustering  
Resumen automático

Evolución  
El futuro inmediato

Sistemas y servicios informáticos para Internet (2007/08) Departamento de Informática  
 Oviedo, 3, 4 y 5 de Marzo de 2008 Web Semántica

[Your knowledge](#) [Images](#) [Video](#) [News](#) [more »](#)  

  [Advanced Search](#)  
[Preferences](#)

**Your knowledge**

*This page is only visible to you. [Switch to public result...](#)*

As you know, **the Rocky movie**, which currently runs across theaters nationwide in its 7th installment as [Rocky Balboa Returns](#), is about an underdog boxer fighting his way through life and the ring. You went to see it on June 7th [1], and later on told your friend Frank that the movie was "excellent trash." [2] You ordered the original Rocky movie on DVD three days ago [3], and it will likely arrive tomorrow.



Image from [Hollywood.com](#)

Sponsor  
**Rocky**  
 Get Movie Info t  
 Cast/Crew, DVT  
 TurnerClassicM

**More knowledge:**

- >> [How the idea for Rocky was born](#)
- >> [Rocky Balboa in theaters near you](#)

[1] Source: Your [Google Calendar event](#).  
 [2] Source: Your [Gmail message](#).  
 [3] Source: Your [Google Checkout order](#).

Evolución  
Verdadera personalización

Sistemas y servicios informáticos para Internet (2007/08) Departamento de Informática  
 Oviedo, 3, 4 y 5 de Marzo de 2008 Web Semántica

[Knowledge](#) [Images](#) [Video](#) [News](#) [Maps](#) [more »](#)  


[Advanced Search](#)  
[Preferences](#)

---

**Knowledge**

**The Rocky movie**, which currently hits theaters globally in its 8th installment as [Rocky Jr.](#), is about the son of an "underdog boxer" [1] fighting his way through teen life and the ring. Originally released in 1976, [Rocky](#), directed by John G. Avildsen and written by Sylvester Stallone, the movie "was an immediate sensation," as [TotalRocky.com](#) writes.



Spons

**Rocky**

Get Movie Info + Cast/Crew, DVD TurnerClassicM

Image from [Hollywood.com](#)

**Clearly**, there was goof in this movie: in the scene where the 3D animated version of Sylvester Stallone talks to his son, he is first wearing a red shirt, and then a blue one. **In my opinion**, the Rocky movies are overrated, but the latest one is a very good action movie, if you happen to like action movies. It combines elements of a typical teen angst drama with a take on the American dream. If you like this movie, you might also like [Raging Bull](#) (1980).

**More knowledge:**  
 >> [Rocky Jr. reviews](#)

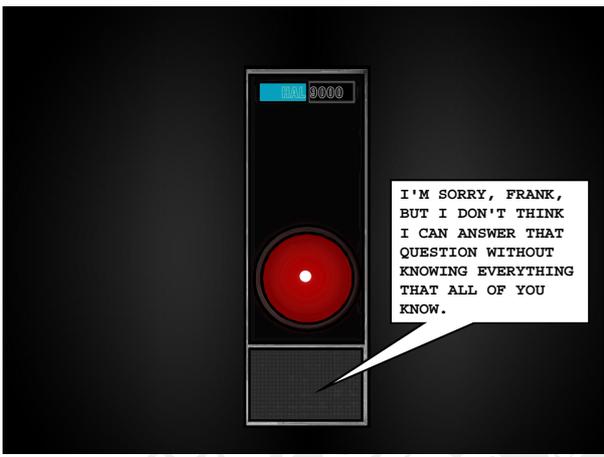
Evolución

Inferencia

Sistemas y servicios informáticos para Internet (2007/08) Departamento de Informática  
 Oviedo, 3, 4 y 5 de Marzo de 2008 Web Semántica

Evolución

... y más allá



Sistemas y servicios informáticos para Internet (2007/08) Departamento de Informática  
 Oviedo, 3, 4 y 5 de Marzo de 2008 Web Semántica

¿Preguntas?

**STOP!**

**Por hoy estuvo bien...**

**Lecturas de hoy**

Broder, A. 2002, "A taxonomy of web search", *ACM SIGIR Forum*, vol. 36, no. 2, pp. 3-10.

Wu, J. y Aberer, K. 2003, "Swarm Intelligent Surfing in the Web", *ICWE 2003*, LNCS 2722, pp. 431-440

Baeza-Yates, R. et al. 2004, "Query recommendation using query logs in search engines", en *Current Trends in Database Technology*, LNCS 3268, p. 588-596.

Cilibrasi, R. y Vitanyi, P. 2005, *Automatic Meaning Discovery Using Google*,  
<http://arxiv.org/abs/cs.CL/0412098>

**¿Quieres pasarte al lado oscuro?**

Sistemas y servicios informáticos para Internet (2007/08) Departamento de Informática  
 Oviedo, 3, 4 y 5 de Marzo de 2008 Web Semántica

**I WANT YOU**



**for the DARK SIDE  
ENLIST NOW**

¿Qué cosas se han hecho hasta ahora o se están haciendo en el "lado oscuro"...

- Prototipos de sistemas de recuperación de información, resumen automático, identificación de idiomas.
- Se he preparado un *corpus* paralelo inglés japonés alineado a nivel de sentencia que se siente muy solo...
- Un compañero está explorando la forma de aplicar *swarm intelligence* al campo de la recuperación de información en la Web.
- Otra compañera ha estudiado distintos algoritmos para obtener redes asociativas a partir de texto plano (un ejemplo a continuación).
- Varios alumnos están trabajando en la forma de explotar la Web como un *corpus* libre de ruido sin necesidad de recurrir al *screen-scraping*.

Sistemas y servicios informáticos para Internet (2007/08) Departamento de Informática  
 Oviedo, 3, 4 y 5 de Marzo de 2008 Web Semántica



I WANT YOU

Un *query log* es un archivo que contiene las consultas que los usuarios envían a un buscador.

avaliação carro construir instrumentos de musica misturas para aves tricot bonecos purificadores agua pensões porto	avaliação automovel fabricar instrumentos de musica misturas para periquitos coser malhas desenho animados filtros agua residenciais porto	carro and automovel are co-hyponym construir and fabricar are co-hyponyms periquito is hyponym of ave tricot can be defined as coser malha bonecos and desenhos aniamdos are co-hyponyms purificador and filtro are co-hyponyms pensão and residencial are co-hyponyms
---	--	--

Table 1: Example of extractable semantic links from sessions.  
 Seco, N. y Cardoso, N. 2006, "Detecting User Sessions in the Tumba! Query Log"



for the DARK SIDE  
ENLIST NOW

automáticas.

¿Relación con folksonomías y ontologías?

Sistemas y servicios informáticos para Internet (2007/08) Departamento de Informática  
 Oviedo, 3, 4 y 5 de Marzo de 2008 Web Semántica



I WANT YOU



for the DARK SIDE  
ENLIST NOW



Un ejemplo reciente, se generó una red asociativa para los artículos de la Wikipedia enlazados con el de Pablo Picasso.

¿Qué términos serán los que están más fuertemente asociados con **Picasso** de los 12.000 términos directamente relacionados?



Programa de doctorado  
"Sistemas y servicios informáticos para Internet" (2007/08)  
Departamento de Informática

Web Semántica

**THAT'S ALL FOLKS**

Oviedo, 3, 4 y 5 de Marzo de 2008