Novática, revista fundada en 1975, es el órgano oficial de expresión y formación continua de ATI (Asociación de Técnicos de Informática). Novática publica también Upgrade, revista digital de CEPIS (Council of European Professional Informatics Societies), en lengua inglesa.

### <a href="http://www.ati.es/novatica/">http://www.ati.es/novatica/</a> <a href="http://www.upgrade-cepis.org/">http://www.upgrade-cepis.org/</a>

ATI es miembro de CEPIS y tiene un acuerdo de colaboración con ACM (*Association for Computing Machinery*). Tiene asimismo acuerdos de vinculación o colaboración con AdaSpain, Al² y ASTIC

#### CONSEJO EDITORIAL

Antoni Carbonell Nogueras, Rafael Fernandez Calvo, Francisco López Crespo, Julián Marcelo Cocho, Celestino Martín Alonso, Josep Molas i Bertrán, Roberto Moya Quiles, César Pérez Chirinos, Mario Piattini Velthuis, Fernando Piera Gómez (Presidente del Consejo), Miquel Sárries Griñó, Carmen Ugarte García, Asunción Yturbe Herranz

Coordinación Editorial

Rafael Fernández Calvo < rfcalvo@ati.es>

Composición y autoedición Jorge Llácer

Administración Tomás Brunete, María José Fernández

#### SECCIONES TECNICAS: COORDINADORES

Arquitecturas
Jordi Tubella (DAC-UPC) < jordit@ac.upc.es>

Bases de Datos Coral Calero Muñoz, Mario G. Piattini Velthuis

(Escuela Superior de Informática, UCLM) < Coral. Calero@uclm.es>, < mpiattin@ii

<Coral. Calero@uclm.es>, <mpiattin@inf-cr.uclm.es>
Calidad del Software
Juan Carlos Granja (Universidad de Granada) <jcgranja@goliat.ugr.es>
Derecho y Tecnologias
Isabel Hemando Collazos (Fac. Derecho de Donostia, UPV)
<ihernando@legaltek.ne/>

Enseñanza Universitaria de la Informática Cristóbal Pareja Flores (Dep. Sistemas Informáticos y Programación-UCM)

<cpareja@sip.ucm.es
Informática Gráfica</pre>

Roberto Vivó (Eurographics, sección española) < rvivo@dsic.upv.es> Ingeniería del Software

is Femández (PRIS-E.I./UEM) < lufern@dpris.esi.uem.es> teligencia Artificial

Federico Barber, Vicente Botti (DSIC-UPV)

<a href="https://www.es-">https://www.es-">https://www.es-</a>
Interacción Persona-Computador

Julio Abascal González (FI-UPV) <a href="https://julio@si.ehu.es-">julio@si.ehu.es-</a>

Lenguajes informáticos Andrés Marín López (Univ. Carlos III) < amarin@it.uc3m.es>

J. Ángel Velázquez (ESCET-URJC) < a.velazquez@escet.urjc.es> Libertades e Informática Libertades e Informática
Alfonso Escolano (FIR-Univ. de La Laguna) «aescolan@ull.es>
Lingüística computacional
Xavier Gómez Guinovart (Univ. de Vigo) «jgomez@uvigo.es>
Manuel Palomar (Univ. de Alicante) «npalomar@dlst.ua.es>
Profesión informática
Rafael Fernández Calvo (ATI) «rfcalvo@ati.es>
Miguel Sarries Grinyó (Ayto. de Barcelona) «msarries@ati.es>
Seguridad
Javier Areitio (Pedes v. Estarra. 1970)

Seguridad
Javier Arcitio (Redes y Sistemas, Bilbao) < jareitio@orion.deusto.es>
Sistemas de Tiempo Real
Alejandro Alonso, Juan Antonio de la Puente (DIT-UPM)

< {aalonso,jpuente}@dit.upm.es

Software Libre Jesús M. González Barahona, Pedro de las Heras Quirós

(GSYC, URJC) < \( \) \(\

Esperanza Marcos (URIC) < emarcos@escet.urjc.es>
Gustavo Rossi (LIFIA-UNLP, Argentina) < gustavo@sol.info.umpl.edu.ae>
Tecnologias para la Educación
Benita Compostela (F. CC. PP.- UCM) < benita@didal.eunet.es>
Josep Sales Rufi (ESPIRAL) < jsales@piex.tec.es>
Tecnologias y Empresa
Pablo Hemández Medrano < phmedrano@terra.es>
TIC para la Sanidad
Valentín Masero Vargas (DI-UNEX) < vmasero@unex.es>

Las opiniones expresadas por los autores son responsabilidad exclusiva de los mismos. Novática permite la reproducción de todos los artículos, salvo los marcados con © o copyright, debiéndose en todo caso citar su procedencia y enviar a Novática un ejemplar de la publicación.

y enviar a Novática un ejemplar de la publicación.

Coordinación Editorial y Redacción Central (ATI Madrid)
Padilla 66, 3°, dcha, 28006 Madrid
Tlf 914029391; fax 913093685 < novatica@att.es>
Composición, Edición y Redacción ATI Valencia
Palomino 14, 2°, 46003 Valencia
Tlf 1914029391; 531 < serceval@att.es>
Administración, Subscripciones y Redacción ATI Cataluña
Via Laietana 41, 9°, 1°, 80030 Barcelona
Tlf 934125235; fax 934127713 < secregen@att.es>
Redacción ATI Andalucía
Isaac Newton, s/n, Ed. Sadiel, Isla Cartuja 41092 Sevilla
Tlf 1748 59440779 < secregan@att.es>
Redacción ATI Aragón
Lagasca 9, 3-8, 50006 Zaragoza
Tlf./fax 976235181 < secregar@att.es>
Redacción ATI Astrias-Cantabria < sgp-astucant@att.es>
Redacción ATI Astrias-Cantabria < sgp-astucant@att.es>
Redacción ATI Calicia
Recinto Ferial s/n, 36540 Silleda (Pontevedra)
Tlf.986581413; fax 986580162 < secregal@att.es>
Publicidad: Padilla 66, 2° deba 2/8006 Madrid

**Publicidad:** Padilla 66, 3°, dcha., 28006 Madrid Tlf.914029391; fax.913093685 < novatica@ati.

Imprenta: 9-Impressió S.A., Juan de Austria 66, 08005 Barcelona. Depósito Legal: B 15.154-1975 ISSN: 0211-2124; CODEN NOVAEC

Portada: Antonio Crespo Foix / © ATI 2002



**(57)** 

47

59

#### **SUMARIO**

En resumen: Filtrando la avalancha 3 Rafael Fernández Calvo Monografía: «Recuperación de la información y la Web» (En colaboración con *Upgrade*, revista digital de CEPIS)

Editores invitados: Ricardo Baeza Yates y Peter Schäuble Presentación. Recuperación de información: una disciplina con tradición 4 Ricardo Baeza Yates, Peter Schäuble Recuperación de información de contenidos empresariales Prabhakar Raghavan

Recuperación de información en la Web: nuevos paradigmas 8 Jacques Savoy

Un análisis de lenguajes de consulta para XML 11 Adelaida Delgado Domínguez, Ricardo Baeza Yates

Recuperación de información distribuida de bibliotecas digitales vía Web utilizando agentes móviles 21 J. Alfredo Sánchez, Sandra Nava Muñoz, Lourdes Fernández Ramírez,

Griselda Chevalier Dueñas Extracción automática de información con semántica de la Web

27 Rafael Corchuelo, José Luis Arjona, Antonio Ruiz Sistema para la compresión y recuperación de documentos estructurados 34 Joaquín Adiego, Pablo de la Fuente, Jesús Vegas y Miguel Villarroel

Las campañas CLEF: evaluación de Sistemas de Recuperación de Información Multilingüe 41 Martin Braschler, Carol Peters

La Web de España 45 Ricardo Baeza Yates

### Secciones Técnicas

Enseñanza Universitaria de la Informática Computing Curricula 2001

Carlos Gregorio Rodríguez, Ángel Herranz Nieva, Raquel Martínez Unanue

Informática gráfica Tutorial sobre Detección de Colisiones en Informática Gráfica Juan J. Jiménez Delgado, Rafael J. Segura Sánchez, Francisco R. Feito Higueruela

Interacción Persona-Computador Ocultos pero no ausentes: los ciegos y la Informática (I) Victor M. Maheux

Referencias autorizadas 63

## Sociedad de la Información

Personal y transferible

LSSICE - Proyecto de Ley de Servicios de la Sociedad de la Información y de Comercio Electrónico: una ley, siete riesgos 67 Ignacio Boixo Pérez-Holanda, Darío Álvarez Gutiérrez

Programar es crear

72 Crucigramas 25º Concurso Internacional de Programación de ACM (2001): problema C 73 ¡Queso!: solución Manuel Carro, Pablo Sánchez, Julio Mariño

### **Asuntos Interiores**

Coordinación editorial / Programación de Novática 76 Normas de publicación para autores / Socios Institucionales

Monografía del próximo número: «XML, eXtended Mark-up Language»

# Recuperación de la información y la Web

# Ricardo Baeza Yates<sup>1</sup>, Peter Schäuble<sup>2</sup> <sup>1</sup> Departamento de Ciencias de la Computación, Universidad de Chile; <sup>2</sup> Eurospider, Zürich (Suiza)

### <rbaeza@dcc.uchile.cl>,<Peter.Schauble@eurospider.com>

Traducción: Manuel Galindo (Socio de ATI)

La Recuperación de Información (IR, Information Retrieval) se asocia a menudo con motores de búsqueda en Internet. Sin embargo, deriva de una disciplina académica cuyas raíces datan de los 50. Durante su primera década las actividades de investigación normalmente tenían lugar en los departamentos de Ciencias de la Computación y las aproximaciones más simples se basaban en las estadísticas de ocurrencia, que tenían una efectividad sorprendente en la recuperación de documentos relevantes. No obstante, un pequeño número de grupos de investigación en Recuperación de Información consiguieron resultados importantes en tres aspectos:

- 1. Teoría. Se desarrollaron modelos de recuperación pro-babilística que implicaban una óptima eficacia de recuperación (ver publicaciones de Cooper, Roberston y otros). Más tarde, la recuperación se extendió a otros medios, no sólo texto.
- 2. Sistemas. Recientemente se han intentado varios algoritmos y estructuras de datos, e integrado sistemas de recuperación impracticables (p.e., SMART, Topic, y Sistema Inquiry), así como sistemas de recuperación multimedia.
- 3. Evaluación. Se han construido colecciones de pruebas consistentes en documentos, consultas y --más importante aún-- de aserciones de relevancia que determinan qué documentos son relevantes para qué consultas. Estas colecciones de pruebas facilitan la comparación de distintos métodos de recuperación en lo concerniente a rellamada y precisión (p.e. colecciones Cranfield, SMART y TREC).

Con el crecimiento de Internet, estos sistemas de Recuperación de Información constituyeron bloques de construcción listos para ser usados. La gran cantidad de datos tanto como la federación del espacio abierto de Internet para nuevos y excitantes conceptos, como enlaces basados en *ranking*, recuperación XML, integración de fuentes de datos heterogéneas, etc. Algunos de estos conceptos son tratados por los autores de esta monografía de *Novática* y de *Upgrade* sobre Recuperación de Información y la Web, y se utilizan parcialmente a continuación para presentar los artículos que la componen.

### **Punteros Editoriales**

### - «Estado del Arte»

Prabakhar Raghavan muestra algunas aplicaciones comerciales de las técnicas IR. También elabora las diferencias entre la recuperación en Internet y en Intranet. Jacques Savoy presenta una encuesta sobre recuperación de información en la Web, con énfasis en recuperación distribuida, ranking basado en enlaces y evaluación de motores de búsqueda.

Adelaida Delgado y Ricardo Baeza Yates presentan un análisis de lenguajes de consulta para XML, enfatizando en la propuesta del W3C, Xquery, desde la perspectiva de datos estructurados, así como de recuperación de texto.

Alfredo Sánchez, Sandra Nava, Lourdes Fernández, y Griselda Chevalier presentan un marco basado en agentes como soporte de recuperación de información distribuida desde bibliotecas digitales heterogéneas accesibles vía Web.

Rafael Corchuelo, José Luis Arjona, y Miguel Toro introduce otro marco basado en agentes para extracción automática de información semántica de

páginas web.

Joaquín Adiego, Pablo de la Fuente, Jesús Vegas, y Miguel Villarroel presentan un sistema que usa índices invertidos comprimidos para recuperación de documentos considerando el contenido y la estructura de los documentos SGML o XML.

### Evaluación

Martin Braschlery Carol Peters describen el CLEF (European Cross Language Evaluation). Junto con el foro americano Trec y el japonés NTCIR, CLEF se

## Notas del Editor de Novática:

Con objeto de incluir el máximo número posible de artículos en la monografía, se ha reducido el tamaño del cuerpo de letra.

2. A pesar de lo anterior, por razones de espacio no se incluyen en esta 2. A pesar de lo anterior, por razones de espacio no se incluyen en esta monografía los siguientes artículos: «Ontologías en Federación de Bases de Datos», de Nieves R. Brisaboa, Miguel R. Penabad, Ángeles S. Places y Francisco J. Rodríguez; «Metodologías de desarrollo de Sistemas de Información en la Web y análisis comparativo», de M. José Escalona, Manuel Mejías y Jesús Torres; y «TEXRET: un sistema interactivo de Recuperación de Texturas (TEXture RETrieval)», de Javier Ruiz del Solar, Pablo Navarrete y Patricio Parada.

Dichos artículos serán publicados, en inglés, en el número 3/2002 de Upgrade, <a href="http://www.upgrade-cepis.org">http://www.upgrade-cepis.org</a>, y en próximos números de Novática, en castellano

# Presentación. Recuperación de información: una disciplina con tradición

encuentra entre los mayores puntos de encuentro para el avance de la tecnología de recuperación de información.

Ricardo Baeza Yates presenta un análisis de la Web española en comparación con la brasileña y la chilena. Los resultados y conclusiones deberían ser similares a los de otros países europeos.

A todos ellos expresamos nuestro agradecimiento por su valiosa colaboración, así como a los editores de *Novática* y *Upgrade* por su iniciativa.

#### Referencias útiles (lista elaborada por *Ricardo Baeza Yates*)

Además de las referencias que aparecen en los artículos de esta monografía, los lectores interesados pueden echar un vistazo a los siguientes libros, periódicos y actas de congresos, así como a muchos sitios web relativos a estándares web <a href="http://w3c.org">http://w3c.org</a>, motores de búsqueda <a href="http://w3c.org">http://w3c.org</a>) www.searchenginewatch.com>, etc.

- Abiteboul, S., Buneman, P. & Suciu, D. Data on the Web: from Relations to Semistructured Data and XML, Morgan Kauffman, 2000. Agosti, M. & Smeaton, A. (editores) Information Retrieval and Hypertext,
- Kluwer, 1996.
- Baeza-Yates, R. & Ribeiro-Neto, B. *Modern Information Retrieval*, Addison-Wesley 1999. Sitio Web: <a href="http://sunsite.dcc.uchile.cl/irbook/">http://sunsite.dcc.uchile.cl/irbook/</a> Witten, I., Moffat, A. & Bell, T. *Managing Gigabytes*, Morgan Kauffman,
- 1999 (segunda edicion).

- Publicaciones periódicas Information Processing & Management Information Retrieval Journal
- ACM transactions in office information systems

- Conferencias
   ACM SIGIR <a href="http://www.acm.org/sigir/">http://www.acm.org/sigir/>
   JCDL <a href="http://www.acm.org/jcdl/">http://www.acm.org/jcdl/</a>
   CIKM <a href="http://www.cs.umbc.edu/cikm/">http://www.cs.umbc.edu/cikm/</a>
   SPIRE <a href="http://www.its.gov/">http://wrec.nist.gov/</a>
   CICLE <a href="http://www.its.gov/">http://wrec.nist.gov/</a>

- -CLEF <a href="http://clef.iei.pi.cnr.it:2002/">http://clef.iei.pi.cnr.it:2002/</a>
- -NTCIR <a href="http://research.nii.ac.jp/~ntcadm/index-en.html">http://research.nii.ac.jp/~ntcadm/index-en.html</a>

### Editores invitados

Ricardo Baeza Yates es Ph. D. en Computer Science (Univ. of Waterloo, Canadá, 1989), Magister en Ingeniería Eléctrica (1986) y Ciencias de la Computación (1985) de la Universidad de Chile; e Ingeniero Civil Eléctrico de la misma universidad. Actualmente es Catedrático en el Depto. de Ciencias de la Computación de la Universidad de Chile y Director del Centro de Investigación de la Web <a href="https://www.ciw.cl">https://www.ciw.cl</a>. Sus áreas de investigación son recuperación de información, minería de la Web algoritmos, y visualización de información. Es co-autor de un libro en recuperación de informazacion de mormación: Es co-autor de un libro en recuperación de mormación (Addison-Wesley, 1999), de un manual de referencia en algoritmos y estructuras de datos (Addison-Wesley, 1991) y co-editor de un libro en recuperación de la información (Prentice-Hall, 1992). Ha sido dos veces presidente de la Sociedad Chilena de Ciencia de la Computación y ha recibido premios de la Organización de Estados Americanos y el Instituto de Ingenieros de Chile. Actualmente, entre otros cargos, es presidente del de ingenieros de Chile. Actualmente, entre otros cargos, es presidente del CLEI (Centro Latinoamericano de Estudios en Informática), miembro del directorio de IEEE-CS y es coordinador internacional del subprograma de informática y electrónica aplicadas de CYTED (Programa de Cooperación Iberoamericano). Durante el año 2000 puso en marcha una empresa de Internet para buscar en la Web chilena <a href="http://www.todocl.cl">http://www.todocl.cl</a>. Su página personal está en <a href="http://www.dcc.uchile.cl/~rbaeza/spanish.html">http://www.dcc.uchile.cl/~rbaeza/spanish.html</a>.

**Peter Schäuble** es CEO de la empresa Eurospider Information Technology AG, empresa suiza líder en recuperación de la información y que suministra software de monitorización de noticias y recuperación corporativa <a href="http://www.eurospider.com">http://www.eurospider.com</a>. Anteriormente fue Profesor Asistente de Ciencias de la Computación en el Instituto Federal Suizo de Tecnología (ETH, Zürich, Suiza) y dirigió el grupo de investigación de recuperación de la información. Es Licenciado en Matemáticas por el ETH y Doctor en Ciencias de la Computación por el mismo centro. Trabajó en el departamento técnico de la ESA (European Space Agency) y miembro invitado de los laboratorios de Hewlett-Packard en Palo Alto (Caifornia, EE.UU.). Ha publicado diversos artículos y libros de investigación sobre recuperación de la información.