



# Estudio de las relaciones causales:

## De un marco teórico a una aplicación práctica



**Cristina Puente Águeda**

Ingeniera Superior Informática (Promoción 2001) y Doctora con Mención Europea, por la Universidad Pontificia de Comillas. Desde 2005 es profesora del Departamento de Sistemas Informáticos en el ICAI.



**José Ángel Olivas Varela**

Licenciado en Filosofía (1990), Máster en Ingeniería del Conocimiento del Dpto. de Inteligencia Artificial (1992), y Doctor en Ingeniería Informática (2000).



**Alejandro Sobrino Cerdeiría**

Licenciado en Filosofía y Ciencias de la Educación por la Universidad de Santiago de Compostela en 1982 y Doctor en Filosofía en 1989.

**Palabras clave:** Relaciones causales, Soft Computing, búsqueda conceptual, deducción.

### Resumen:

En este artículo se presenta el resumen de un modelo de causalidad teórica aplicado a un proceso de recuperación de información. Desde los tiempos de Aristóteles, la causalidad ha sido fuente de diversas teorías y discusiones en diversos ámbitos en el que se incluye la ciencia. El desarrollo teórico de este trabajo está influenciado por varios modelos que tratan la causalidad, la condicionalidad y la causalidad imperfecta. Como aplicación de estos estudios, se presenta un sistema automático de recuperación de oraciones condicionales y causales para su posterior análisis y representación. El resultado del proceso es un esquema que puede servir para establecer nuevas conexiones entre conceptos, como, por ejemplo, a través de un grafo causal. Parte de este trabajo fue reconocido con el Best Paper Award en el congreso FUZZ-IEEE'2010.

**Key words:** Causal relationship, Soft Computing, conceptual search, deduction.

### Abstract

*This paper presents an overview of a causal theoretical model applied to an information retrieval procedure. Causality has been a matter of study since the times of Aristotle, being applied to many different areas such as science, law or social sciences. The theoretical part of this work is inspired by several causality models dealing with causality, conditionality and imperfect causality. As a result a semi-automatic process has been developed to detect, classify, analyze and represent causal and conditional sentences which may serve to establish new relationships among concepts though a causal graph. Part of this work was rewarded with the Best Paper Award in the FUZZ-IEEE'2010 congress.*

## Introducción

### Estudio de la causalidad

La idea de que el conocimiento causal es una característica fundamental para el entendimiento del mundo es muy antigua. Ya Aristóteles, en la obra *Metaphysics* (I, I, 981 a 24-30) sostiene que el conocimiento está fundamentado en las causas. En la historia de la causalidad ha habido dos concepciones que han tenido gran influencia sobre el resto: a) la causalidad como una ilusión, defendida por Hume [1], y b) la causalidad como base epistemológica para la ciencia, defendida por Kant [2] o por Mill [3].

Dentro del ámbito científico, en las ciencias empíricas como la física, las relaciones causales son una manera típica de generar conocimiento y aportar explicaciones. Por ejemplo, cuando un físico cuántico calcula la probabilidad de que un átomo absorba un protón, está en realidad determinando la causa por la que el átomo salta a un nivel de energía. Es decir, intenta establecer una relación causa-efecto [4]. En las ciencias sociales, como en el derecho, la causalidad se utiliza para establecer una conexión entre conducta y responsabilidad, por ejemplo, como justificación en la imposición de una pena. Así, un jurado puede determinar si la negligencia de un médico en el tratamiento de la víctima fue la causa inmediata de su muerte y, en función de eso, condenarle o no.

### Causalidad perfecta

La causalidad es un tipo de relación entre dos entidades: causa y efecto. La causa provoca un efecto, y el efecto sucede a consecuencia de la causa. La causalidad es un proceso directo, cuando A causa B y B es un efecto directo de A, o indirecto cuando A causa C a través de B, y C es un efecto indirecto de A. En este artículo trataremos la causalidad en ambos sentidos, pero fundamentalmente en el segundo.

Dentro del ámbito científico, la causalidad se ve generalmente como una relación precisa: la misma causa provoca siempre el mismo efecto. Pero en el mundo cotidiano, los enlaces entre causa y efecto son frecuentemente imprecisos o imperfectos por

naturaleza. La lógica borrosa ofrece un marco adecuado para tratar con la causalidad imperfecta. En éste ámbito, algunas preguntas son [5]:

- ¿En qué grado causa e?
- ¿La relación entre causa y efecto siempre se mantiene con la misma intensidad en el tiempo y en cada situación?
- ¿La fortaleza del enlace causal representa el grado de influencia que la causa tiene sobre el efecto?

Un objetivo de este trabajo es proporcionar un proceso semiautomático de extracción y análisis de oraciones causales y condicionales en textos. Las frases recuperadas pueden ser utilizadas como evidencia experimental para verificar hipótesis sobre posibles respuestas a las preguntas antes planteadas.

### Causalidad y condicionalidad

Condicionalidad y causalidad presentan analogías y divergencias. Hay muchas oraciones causales que pueden ponerse en términos condicionales. Las leyes científicas son un caso paradigmático: por ejemplo, la primera ley de la termodinámica dice que la causa de que la energía interna de un sistema cambie es que se realice trabajo sobre ese sistema o intercambie calor con

otro. Esta ley puede parafrasearse en términos condicionales diciendo que si se realiza trabajo sobre un sistema o bien éste intercambia calor con otro, la energía interna del sistema cambiará. Pero hay enunciados causales que no son condicionales. Por ejemplo, 'La causa de la muerte de Kennedy fue un disparo' no admite paráfrasis en términos condicionales (si se dispara a Kennedy, se le mata) porque introduce una posibilidad que puede contradecir la factualidad de un hecho verdadero ya sucedido. Los enunciados condicionales tampoco tienen siempre naturaleza causal. Muchas veces sí, como ocurre en el enunciado condicional de la primera ley de la termodinámica antes aludida. Pero otras veces no, por ejemplo: 'si salto, me caigo' expresa una relación entre un acto y una consecuencia más débil que una relación causal. En una relación causal, siempre que se da la causa, se da el efecto. Pero en el enunciado arriba proferido, por ser conjetural, deja abierta la posibilidad a que salte y caiga, pero también a que no salte y caiga, o a que no salte y no caiga. Sólo si a posteriori se vincula con seguridad la caída al salto, y de manera predominante a él, saltar sería



causa de la caída. Además, con las partículas 'si...entonces' se pueden hacer extraños enunciados, muy infrecuentes en el lenguaje (casi experimentales, se podría decir) donde no hay relación alguna entre antecedente y consecuente, como ocurre, por ejemplo en 'si 2 es par, Madrid es capital de España'. Son los condicionales materiales, que en ningún caso, obviamente, expresan vínculos causales. Por tanto, aunque no se puede identificar completamente condicionalidad y causalidad, ambas nociones están bastante relacionadas.

Dado que el objetivo de este trabajo tiene que ver con el rescate de oraciones causales en textos, será relevante detectar oraciones condicionales que expresen posibles relaciones causales y oraciones típicamente causales en tanto incluyan léxico causal que las caracterice como tales. Para lograr este objetivo, este artículo está dividido en tres bloques. En el primero se presenta un método de extracción y clasificación automática de oraciones condicionales y causales a través de un analizador morfológico. En el segundo bloque se presenta un proceso asociado al anterior; capaz de seleccionar del total de frases extraídas un conjunto relacionado con un concepto en particular; dando como resultado un esquema de representación. En el tercer bloque se describe un experimento en el que se prueba el proceso completo.

### Detección condicional y causal en documentos de texto

En [6] se describe un proceso para detectar y clasificar oraciones condicionales en documentos de texto. Estas sentencias se extraen de acuerdo a 20 patrones predefinidos [7] que abarcan los casos más comunes de condicionales en el idioma inglés. Para ello se utilizó el analizador morfológico de libre distribución *Flex* junto con el lenguaje de programación *C*, dando lugar a un proceso capaz de seleccionar oraciones de un texto que encajen dentro de unos patrones.

En un principio se analizaron las formas en inglés pertenecientes al condicional en su modo más típico, 'if x then

y', así como otras fórmulas equivalentes que pudieran dar lugar a este tipo de oraciones (*due to, caused by, provided that, have something to do with*).

Para comprobar el nivel de fiabilidad de la aplicación se analizaron manualmente una serie de documentos pertenecientes a diferentes ámbitos (50 páginas por categoría), y se calcularon las medidas de relevancia y precisión (en inglés: recall, precision), como se puede apreciar en la tabla 1. La relevancia *R* es el número de oraciones causales correctamente clasificadas por el sistema dividido por el número de oraciones causales clasificadas manualmente. La precisión *P* es el número de oraciones causales correctamente clasificadas por el proceso dividido por el total de sentencias devueltas. La medida *F* (*F-Measure*) determina la relación entre la relevancia y precisión, viene dada por la fórmula  $F = (2 * P * R) / (P + R)$ , y sirve para controlar la importancia relativa de uno u otro parámetro.

Los resultados indican que los textos científicos y médicos tienen unos mejores resultados en relevancia y precisión que el resto de dominios tratados, por lo que los experimentos a partir de este punto se efectuaron dentro del ámbito médico.

### Esquemmatización automática del grafo causal

Existen varios estudios sobre el análisis de la causalidad en documentos de texto. Algunos están enfocados a la extracción de sentencias causales, como el propuesto por R. Girju [8], y otros en la causalidad y los pronombres interrogativos, como el de Black

y Paice [9]. Utilizando estos estudios como referencia se ha creado un algoritmo capaz de lanzar un proceso causal, utilizando un concepto inicial de entrada y el conjunto de sentencias causales y condicionales recuperadas como base de conocimiento. Este concepto de entrada podrá proceder de una pregunta (por ejemplo en un sistema pregunta-respuesta), o ser formulado directamente al proceso.

El siguiente paso consistirá en la localización de todas aquellas oraciones condicionales, previamente seleccionadas, en las que se mencione el concepto solicitado. Se ha creado otra aplicación mediante el analizador morfológico *Flex*<sup>1</sup> que se encarga de generar un fichero de texto plano con las frases seleccionadas.

Cada una de estas oraciones pasará directamente a una aplicación programada en *C*, donde se analizará si el concepto introducido en el proceso está dentro del contexto condicional de la oración. En caso afirmativo se presentará un esquema con las conjunciones, modificadores y demás términos relevantes para su posterior representación en el grafo causal.

Los pasos que sigue el algoritmo son los siguientes:

- Procesar una frase mediante un programa (*Stanford parser* [10] o *part-of-speech-tagger* (POST) [11], según los patrones considerados) para dividirla en lexemas.
- Localizar el concepto buscado dentro de la frase analizada.
- Localizar la partícula condicional o causal más próxima al concepto buscado y evaluar si pertenecen al mismo

Tabla 1. Resultados de relevancia, precisión y F-Measure

Tipo de texto	Relevancia	Precisión	F-Measure
Científicos	0,65	0,84	0,73
Médicos (Medlars)*	0,77	0,91	0,83
Novelas	0,32	0,79	0,41
Noticias (Reuters)**	0,58	0,79	0,67
Evangelios	0,50	0,70	0,58

\* <http://www.nlm.nih.gov/bsd/mmshome.html>

\*\* <http://www.davidlewis.com/resources/testcollections/reuters21578/>

<sup>(1)</sup> <http://www.gnu.org> (última visita: octubre 2010).

Figura 1. Esquema general del proceso

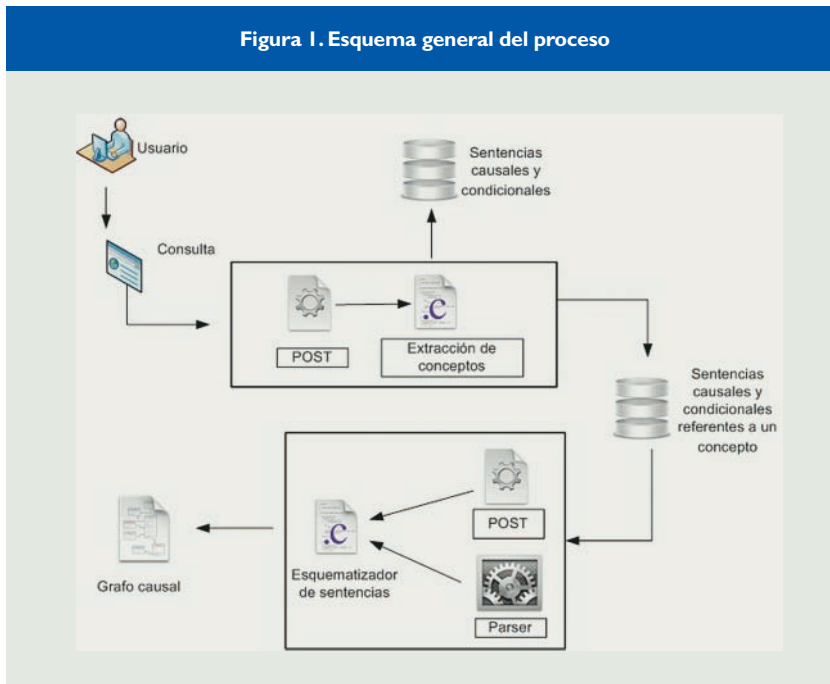


Figura 2. Salida esquematizada del programa

Node = pulmonary hypoplasia  
 ----->>  
 Node: more than 50% neonates

contexto (en base al número de palabras que los separan). Si no, eliminar la sentencia.

- Determinar si el concepto es causa o efecto dentro de la sentencia analizada para establecer la dirección de la flecha dentro del grafo.
- Localizar atributos y modificadores como adjetivos y adverbios cerca del concepto.
- Si el concepto buscado está antes de la conjunción causal/condicional, etiquetar el nodo como efecto y buscar el nodo causal junto con sus modificadores. En caso contrario etiquetar el nodo como causa y buscar el nodo efecto junto con sus modificadores.

De una manera más general, el esquema completo del proceso es el representado en la figura 1, donde se

parte de un conjunto de documentos para, a través del proceso descrito, generar un grafo causal con la información relacionada con el concepto introducido por el usuario.

El proceso desarrollado es capaz de simplificar una sentencia compleja, extrayendo los conceptos y modificadores que pudieran estar relacionados con el buscado.

El algoritmo, según va recuperando los nodos y modificadores asociados a los mismos, los va guardando en una base de datos diseñada para conectar este proceso con el algoritmo de representación (programado en lenguaje java). Por ejemplo, la siguiente sentencia: *Preterm rupture of membranes at 20 weeks or earlier is*

*associated with a poor prognosis for miscarriage within five days of membrane rupture due to chorioamnionitis, and in the remaining 60 % of pregnancies, more than 50% of neonates die due to pulmonary hypoplasia, daría como resultado el diagrama representado en la Figura 2.*

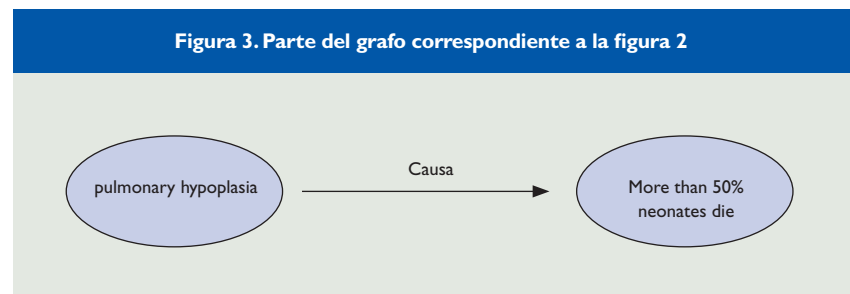
Ésta es la manera más simple de extracción de una sentencia. La representación correspondiente a esta salida del programa se corresponde con la figura 3, donde el nodo con el concepto *pulmonary hypoplasia* apunta al nodo con el concepto *more than 50% neonates die*, o en otras palabras, *pulmonary hypoplasia* causa o provoca que *more than 50% neonates die*.

Generalmente, el proceso de representación es bastante más complicado que el reflejado en las figuras 2 y 3, por los modificadores asociados a cada uno de los nodos, como se puede ver en los ejemplos expuestos en el siguiente apartado.

### Desarrollo de un ejemplo completo

Esta sección presenta un ejemplo completo del proceso descrito en los apartados anteriores, estableciendo la relación entre dos conceptos como *smoking* y *lung cancer*. El conjunto de documentos seleccionados para este experimento fueron tomados de la página web de la clínica Mayo<sup>2</sup>, la sociedad americana de oncología<sup>3</sup>, el centro de control y prevención de enfermedades<sup>4</sup> y los portales de e-medicina salud<sup>5</sup> y cáncer de pulmón online<sup>6</sup>.

Figura 3. Parte del grafo correspondiente a la figura 2



<sup>(2)</sup> <http://www.mayoclinic.com> (última visita: octubre 2010).

<sup>(3)</sup> <http://www.cancer.net/patient/Cancer+Types/Lung+Cancer/> (última visita: octubre 2010).

<sup>(4)</sup> [http://www.cdc.gov/cancer/lung/basic\\_info/](http://www.cdc.gov/cancer/lung/basic_info/) (última visita: octubre 2010).

<sup>(5)</sup> [http://www.emedicinehealth.com/lung\\_cancer](http://www.emedicinehealth.com/lung_cancer) (última visita: octubre 2010).

<sup>(6)</sup> <http://www.lungcanceronline.org/info/index.html> (última visita: octubre 2010).

## Detección y clasificación de oraciones causales y condicionales

La primera parte en este experimento se encarga de extraer y clasificar las oraciones condicionales y causales de acuerdo a los 20 patrones definidos [7]. Los resultados fueron bastante satisfactorios, en parte por el tipo de lenguaje utilizado en los textos médicos, mucho más claro y preciso que en otras áreas, como se puede ver en la figura 4.

### Proceso de síntesis

Esta parte del proceso se encarga de filtrar aquellas frases que contienen las palabras *lung cancer* o *smoking*. El algoritmo devolvió 82 frases de las que se seleccionaron 15 para representar un grafo de tamaño mediano, y por tanto más manejable. Algunas de las oraciones representadas son las mostradas en la tabla 2.

Una vez que las frases han sido seleccionadas, el programa tiene que dividir las frases en tokens mediante el parser de Stanford [10].

Finalizado el análisis, el proceso de esquematización localizará aquellas etiquetas relativas a partículas causales, por ejemplo *due\_to*. Esta etiqueta (*prep\_due\_to(die-7, smoke-14)*) asocia las palabras *die* y *smoking* como nodos causa y efecto respectivamente. Para crear los dos nodos, el algoritmo busca dentro de cada etiqueta utilizando

Figura 4. Informe de sentencias recuperadas

Sentencias recuperadas
Every year, about 3.000 nonsmokers die from lung cancer due to secondhand smoke
In the United States, about 85% of lung cancer deaths are due to smoking
Your risk of lung cancer increases if you're exposed to secondhand smoke
About 90% of lung cancers arise due to tobacco use.

Nº Páginas	Nº Palabras	Detectadas	Rechazadas	Clasificadas	No clasificadas	% Clasificación
59	23.629	83	0	56	26	68

Tabla 2. Oraciones causales representadas

Sentencias recuperadas
Every year, about 3.000 nonsmokers die from lung cancer due to secondhand smoke
In the United States, about 85% of lung cancer deaths are due to smoking
Your risk of lung cancer increases if you're exposed to secondhand smoke
About 90% of lung cancers arise due to tobacco use.

Figura 5. Esquema de la frase "Every year, about 3.000 nonsmokers die from lung cancer due to secondhand smoke"

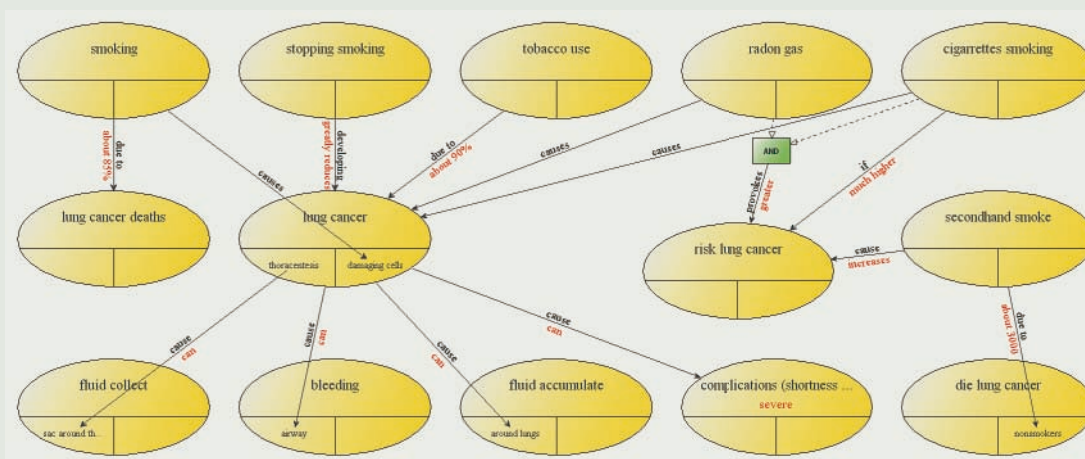
Node: secondhand smoke  
 ----->> due to  
 Node: die lung cancer  
 Node intensity: about 3000 nonsmokers

los números asociados a cada palabra. Por ejemplo, para crear el nodo causante, el algoritmo buscará entre las etiquetas la palabra *smoke* junto con el número 14. Si la etiqueta es un mo-

dificador, como en este caso *amod (smoke-14, seconhand-13)*, el programa incluirá la palabra asociada en el nombre del nodo, como se ve por ejemplo en la figura 5.

El algoritmo devuelve un esquema de la información útil de la oración que se almacena dentro de una base de datos. Una vez que todas las frases

Figura 6. Grafo causal creado automáticamente que evalúa la relación entre *smoking* y *lung cancer*



se han terminado de procesar y esquematizar, se representará automáticamente a través de la API de Java Jgraph<sup>7</sup> el grafo causal con los datos almacenados.

A la hora de representar el grafo, algunas de estas oraciones comparten el mismo nodo antecedente o consecuente, como por ejemplo el nodo *risk lung cancer*, que aparece varias veces. Este nodo hereda todos los modificadores que aparecen en todas las frases. Una relación está especificada por un modificador si la flecha entra dentro del nodo apuntando al modificador implicado. En caso contrario, la flecha de la relación señalará al borde del nodo. Tanto causas como efectos pueden ser descritos de forma general (*pulmonary hypoplasia*) o más específicamente: los médicos generalmente hablan de *pulmonary hypoplasia* localizada en *right lung* o *right upper lobe pulmonary hypoplasia*. Por esto, en los textos médicos es frecuente encontrar localizaciones (*right*) o especificaciones (*upper lobe*) en frases nominales. Si

la relación tiene más de un modificador, la flecha apuntará a un nodo intermedio que a su vez dirigirá otras flechas a los modificadores correspondientes. La intensidad de la relación, si existe, estará marcada en rojo, y el tipo de enlace causal en negro. Como se puede ver en el grafo (figura 6), hay cuatro nodos con la palabra *smoking*, o similar; y otros cuatro con las palabras *lung cancer*. El resto de nodos se han creado durante el proceso. Por lo tanto, con un grafo como éste se pueden establecer nuevas relaciones ocultas a primera vista, como por ejemplo la existente entre *smoking* y *fluid being accumulate around the lungs*, con un cierto grado de relación, teniendo en cuenta los modificadores y cuantificadores que aparecen en el camino causal que enlazan estos dos nodos.


### Conclusiones y trabajo futuro

El objetivo de este artículo es por un lado (i) presentar un programa capaz de recuperar oraciones causales o condicionales de documentos de texto

pertenecientes a diferentes géneros y (ii) representar los resultados automáticamente mediante un grafo causal en el que se muestran, de modo explícito, los cuantificadores aproximados y las cercas semánticas con la que se califican los nodos o se matizan los enlaces. Las sentencias recuperadas son utilizadas como una base de datos para estudiar la causalidad imperfecta. ■

### Bibliografía

- [1] Hume D., *A Treatise of Human Nature*. D. F. Norton & U. J. Norton, (eds.), Oxford University Press, 2000.
- [2] Kant I., *Critique of Pure Reason*, 2nd ed., 1787. trans. by N. K. Smith, London, McMillan, 1929.
- [3] Mill J. S., *A system of logic, ratiocinative and inductive: being a connected view of the principles of evidence and the methods of scientific investigation*. N. Y. Harper & Brothers, 8 ed.
- [4] Bunge M., *Causality and modern sciences*, Dover, 1979.
- [5] Mazlack L. J., *Imperfect causality*, *Fundamenta Informaticae*, vol. 59, pp. 191-201, 2004.
- [6] Puente C., Sobrino A., Olivas J. A., *Extraction of conditional and causal sentences from queries to provide a flexible answer*. Eighth International Conference Flexible Question Answering FQAS 2009. Springer, LNCS vol. 5822, pp. 477-487, 2009.
- [7] Puente C., Olivas J. A., *Analysis, detection and classification of certain conditional sentences in text documents*. Proceedings of the 12th International Conference on Information Processing and Management of Uncertainty in Knowledge-Based Systems, IPMU'08, Torremolinos, Spain, 2008.
- [8] Girju R., *Automatic detection of causal relations for question answering*. Proc. of the 41st ACL Workshop on Multilingual Summarization and Question Answering – Machine Learning and Beyond, Sapporo, Japan, 2003.
- [9] Paice C., Black W., *The use of causal expressions for abstracting and question-answering*. Proc. of the 5th Int. Conf. on Recent Advances in Natural Language Processing, RANLP, 2005.
- [10] Klein D., Manning C. D., *Fast Exact Inference with a Factored Model for Natural Language Parsing*. In *Advances in Neural Information Processing Systems 15 (NIPS 2002)*, Cambridge, MA: MIT Press, pp. 3-10, 2002.
- [11] Schmid H., *Probabilistic Part-of-Speech Tagging Using Decision Trees*. Proceedings of International Conference on New Methods in Language Processing, 1994.



<sup>7</sup> <http://www.jgraph.com> (última visita: octubre 2010).