

El proyecto Gari-Coter* en el seno del proyecto RICOTERM2**

Fco. Mario Barcala Rodríguez y Eva M.^a Domínguez Noya
Centro Ramón Piñeiro para a Investigación en Humanidades
{fbarcala,edomin}@cirp.es

Pablo Gamallo Otero y Marisol López Martínez y Eduardo Miguel Moscoso Mato y
Guillermo Rojo y María Paula Santalla del Río y Susana Sotelo Docío
Universidade de Santiago de Compostela
{pablogam, fgmarsol, fgmato, guillermo.rojo, fescocio}@usc.es

Resumen: Descripción del proyecto Gari-Coter para la elaboración de los recursos lingüísticos en gallego necesarios para un re-elaborador de consultas multilingüe.

Palabras clave: expansión de consultas, corpus, base de datos terminológica, extracción automática de términos

Abstract: Description of the Gari-Coter project for the development of the necessary linguistic resources in Galician for a multilingual query re-elaborator.

Keywords: query expansion, corpus, terminological database, automatic terminology extraction

1. Situación actual

Como se ha indicado en la nota de agradecimiento adjunta al acrónimo del proyecto incluido en el título, éste se ha venido desarrollando desde 2004, y su cierre está previsto para finales de 2007. Dos años y medio, por tanto, lleva el proyecto en curso, por lo cual lo que incluimos aquí es una presentación esquemática de lo que se proponía, así como de algunos de sus, ahora ya, resultados de hecho, a falta de un sexto de tiempo de desarrollo del proyecto. Lo que queda del mismo, por otra parte, es previsible que se dedique a la integración de los recursos y herramientas generados en el seno de cada uno de los subproyectos que integran el proyecto coordinado RICOTERM2, el propio Gari-Coter, y el subproyecto, del mismo nombre que el coordinado, RICOTERM2¹.

2. El subproyecto Gari-Coter en el seno del proyecto coordinado RICOTERM2

El proyecto coordinado RICOTERM2 tiene como objetivo principal el desarrollo de un prototipo para un sistema multilingüe de reformulación de consultas planteadas por usuarios de Internet interesados en la búsqueda de información acerca de un ámbito comunicativo especializado, en nuestro caso, economía. El sistema se integrará, como se describe en (?), en una aplicación que consistirá en una interfaz, ubicada en un portal web especializado en economía, para la transformación de consultas simples en consultas multilingües expandidas lingüística y conceptualmente. Actualmente las lenguas de trabajo son el catalán, el castellano, el gallego, el inglés y el vasco. El diseño general del prototipo está también descrito en (?): baste aquí, para que puedan ser cabalmente entendidos los objetivos específicos del subproyecto Gari-Coter, indicar que, con el propósito de mejorar los resultados de las aplicaciones implicadas de Recuperación de Información mediante técnicas de expansión de consultas, el proyecto utiliza métodos tanto de expansión únicamente por términos (*only-term expansion*) como de expansión de texto completo (*full-text expansion*). Para lo primero, se hará uso de una ontología del dominio. Para lo segundo, de un corpus específico de economía, estructural y lingüísticamente anotado, el cual

* *Creación e integración multilingüe de recursos terminológicos en gallego para Recuperación de Información mediante estrategias de control terminológico y discursivo en ámbitos comunicativos especializados.* Subproyecto financiado, bajo la dirección de M.^a Paula Santalla, por el Ministerio de Educación y Ciencia entre 2004 y 2007 (HUM2004-05658-C02-02/FILO).

** *Control terminológico y discursivo para la recuperación de información en ámbitos comunicativos especializados, mediante recursos lingüísticos específicos y un reelaborador de consultas.* Proyecto coordinado financiado, bajo la dirección de Mercè Lorente Casafont, por el Ministerio de Educación y Ciencia entre 2004 y 2007 (HUM2004-05658-C02-00/FILO).

habrá de servir para, mediante el recurso a herramientas como extractores automáticos de terminología y similares, detectar colocaciones o fraseología propia de los términos introducidos por el propio usuario, u obtenidos tras la consulta a la ontología.

Dentro de este planteamiento general, el proyecto Gari-Coter (aparte de objetivos compartidos, relacionados, como puede suponerse, con el diseño y la integración de todo lo producido en una aplicación web) tiene como objetivos propios la constitución de los recursos para el gallego: un corpus de economía, adecuadamente codificado y anotado, adaptando para ello herramientas de procesamiento existentes para el gallego, y un banco de datos terminológicos, obtenido a partir de recursos previos y de la explotación del propio corpus constituido. A falta de algo más de seis meses para la finalización del proyecto, estos recursos han podido ser elaborados en la forma y dimensión que someramente describimos a continuación.

2.1. El corpus

Como para todas las lenguas implicadas en el proyecto RICOTERM2, no uno sino, en realidad, dos subcorpus de dominio han sido desarrollados para el gallego: un subcorpus genérico y uno específico. El primero integrado por 609 noticias de periódico que suman 206510 palabras distribuidas en 7892 oraciones. El segundo integrado por 14 libros y dos revistas especializadas que entre todos suman 801702 palabras distribuidas en 34588 oraciones.

Ambos corpus están codificados utilizando el estándar XML. Cada documento consta de una cabecera con información bibliográfica y de contenido, seguida ésta del documento mismo, estructurado hasta el nivel de la oración. Ambos corpus, asimismo, han sido anotados morfosintácticamente con información acerca de clase de palabras y categorías flexivas consideradas relevantes.

En línea con los planteamientos generales del proyecto coordinado (búsqueda y aprovechamiento de recursos preexistentes), para la constitución de ambos corpus llegamos a un acuerdo con el Centro Ramón Piñeiro para a Investigación en Humanidades², que nos cedió los textos procedentes del corpus CORGA, Corpus de Referencia del Gallego Actual, procesados lingüísticamente con su propio sistema de etiquetación. Toda la anota-

ción del corpus genérico fue corregida manualmente.

2.2. El banco de datos terminológico

El banco de datos terminológico se ha elaborado a partir, por un lado, de recursos previos que constituían fuentes considerablemente heterogéneas³ en cuanto a calidad, dimensión y fiabilidad: dos diccionarios, dos glosarios electrónicos y la sección de economía de una base de datos terminológica, ésta última la más rica y rigurosa sin duda.

Actualmente, el banco de datos consta de 6046 términos del dominio económico obtenidos por esta vía, la mayoría de ellos asociados a información exhaustiva acerca del lema, la clase de palabras y la definición, así como, en la mayoría de los casos, equivalentes en otras lenguas e información sobre sinónimos e hiperónimos.

El conjunto de términos descrito, así como el corpus, se han utilizado además para, mediante técnicas de extracción automática de términos multipalabra basadas en medidas de similitud contextual, ampliar el banco de datos terminológico. En la última de las experiencias llevadas a cabo 740 términos multipalabra pudieron obtenerse, pero los resultados de precisión asociados, debidos sin duda al reducido tamaño del corpus, aconsejan, cuanto menos, una revisión manual de los mismos.

Notes

¹Con el mismo acrónimo y nombre que el proyecto coordinado, financiado por el Ministerio de Educación y Ciencia entre 2004 y 2007, y dirigido por Mercè Lorente (HUM2004-05658-C02-01/FILO).

²<http://www.cirp.es>. [Consultado: 6, junio, 2007].

³**Eiras:** Eiras Rey, A.: *Diccionario de economía*, no publicado. **Formoso:** Formoso Gosende, V. (coord.) (1997): *Diccionario de termos económicos e empresariais galego-castelán-inglés*. Santiago de Compostela: Confederación de Empresarios de Galicia. **Panlatin Electronic Commerce Glossary:** <http://fon.gs/panlatino>. **Glossary about commerce from galego.org:** <http://galego.org/vocabularios/ccomercial.html>. **SNL:** <http://www.usc.es/en/servizos/portadas/snl.jsp>.