




Actas del XXVII Congreso de la Sociedad Española para el Procesamiento del Lenguaje Natural

Huelva

5 - 7 Septiembre de 2011





Comité de Organización

Presidente:

Manuel J. Maña López

Miembros:

Mariano A. Crespo Azcárate
Noa P. Cruz Díaz
Manuel de la Villa Cordero
Juan Luis Domínguez Olmedo
Jacinto Mata Vázquez
Victoria Pachón Álvarez
Miguel Ángel Vélez Vélez

Comité Científico

Presidente:

Manuel J. Maña López

Universidad de Huelva

Miembros:

José Gabriel Amores
Toni Badía
Manuel de Buenaga
Sylviane Cardey-Greenfield
Irene Castellón
Arantza Díaz de Ilaraza
Manuel de la Villa Cordero
Juan Luis Domínguez Olmedo
Antonio Ferrández
Florentino Fernández Riverola
Mikel Forcada
Ana García-Serrano
Alexander Gelbukh
Koldo Gojenola
Xavier Gómez Guinovart
José María Gómez Hidalgo
Julio Gonzalo
Ramón López-Cózar Delgado
José Miguel Goñi
Bernardo Magnini
Nuno J. Mamede
José Mariño
M. Antonia Martí
María Teresa Martín
Patricio Martínez-Barco
Raquel Martínez
Paloma Martínez Fernández
Jacinto Mata Vázquez
Ruslan Mitkov
Manuel Montes y Gómez
Roser Morante

Universidad de Sevilla
Universitat Pompeu Fabra
Universidad Europea de Madrid
Centre de Recherche Lucien Tesnière. Besançon, France
Universitat de Barcelona
Euskal Herriko Unibertsitatea
Universidad de Huelva
Universidad de Huelva
Universitat d'Alacant
Universidade de Vigo
Universitat d'Alacant
UNED
Instituto Politécnico Nacional, México
Euskal Herriko Unibertsitatea
Universidade de Vigo
Optenet
UNED
Universidad de Granada
Universidad Politécnica de Madrid
Fondazione Bruno Kessler, Italia
Instituto de Eng. de Sistemas e Computadores em Lisboa, Portugal
Universitat Politècnica de Catalunya
Universitat de Barcelona
Universidad de Jaén
Universitat d'Alacant
UNED
Universidad Carlos III de Madrid
Universidad de Huelva
Universidad de Wolverhampton
Instituto Nacional de Astrofísica, Óptica y Electrónica, México
University of Antwerp, Bélgica

Lidia Moreno
Lluís Padró
Victoria Pachón Álvarez
Manuel Palomar
Ferrán Pla
German Rigau
Horacio Rodríguez
Leonel Ruiz Miyares
Emilio Sanchís
Kepa Sarasola
Isabel Segura Bedmar
Mariona Taulé
L. Alfonso Ureña
Felisa Verdejo Maillo
Manuel Vilares Ferro
Luis Villaseñor-Pineda

Universitat Politècnica de València
Universitat Politècnica de Catalunya
Universidad de Huelva
Universitat d'Alacant
Universitat Politècnica de València
Euskal Herriko Unibertsitatea
Universitat Politècnica de Catalunya
Centro de Lingüística Aplicada de Santiago de Cuba
Universitat Politècnica de València
Euskal Herriko Unibertsitatea
Universidad Carlos III de Madrid
Universitat de Barcelona
Universidad de Jaén
UNED
Universidad de A Coruña
Instituto Nacional de Astrofísica, Óptica y Electrónica, México

Revisores adicionales

Emmanuel Aguiano Hernández
Alexandra Balahur
Zoraida Callejas
Arantza Casillas
Alberto Díaz
Manuel-Carlos Díaz Galiano
Miguel A. García Cumbreiras
Meritxell González
David Griol
Antonio Juárez-González
Gorka Labaka Intxauspe
Marina Lloberes
Héctor Llorens
Elena Lloret
Montserrat Maritxalar Anglada
José Luis Martínez-Fernández
Joaquim Moré
Antoni Oliver González
Jesús Peral
José Manuel Perea Ortega
Juan A. Pérez Ortiz
Felipe Sánchez Martínez
Esaú Villatoro Tello

Instituto Nacional de Astrofísica, Óptica y Electrónica, México
Universitat d'Alacant
Universidad de Granada
Euskal Herriko Unibertsitatea
Universidad Complutense de Madrid
Universidad de Jaén
Universidad de Jaén
Universitat Politècnica de Catalunya
Universidad Carlos III de Madrid
Instituto Nacional de Astrofísica, Óptica y Electrónica, México
Euskal Herriko Unibertsitatea
Universitat de Barcelona
Universitat d'Alacant
Universitat d'Alacant
Euskal Herriko Unibertsitatea
Universidad Carlos III de Madrid
Universitat Oberta de Catalunya
Universitat Oberta de Catalunya
Universitat d'Alacant
Universidad de Jaén
Universitat d'Alacant
Universitat d'Alacant
Instituto Nacional de Astrofísica, Óptica y Electrónica, México



Preámbulo

Anualmente la Sociedad Española para el Procesamiento del Lenguaje Natural (SEPLN) organiza un Congreso que pretende ser un foro de publicación de artículos científico-técnicos inéditos de calidad relevante en el ámbito del Procesamiento de Lenguaje Natural (PLN) tanto para la comunidad científica nacional e internacional, como para las empresas del sector. El XXVII Congreso de la SEPLN ha sido organizado por el Laboratorio de Recuperación de Información y Minería de Textos y Datos de la Universidad de Huelva y tendrá lugar los días 5 a 7 de septiembre de 2011. El Congreso contará con la presentación de trabajos que incluirán artículos originales, presentaciones de proyectos en marcha y descripciones de herramientas. Así mismo, se llevarán a cabo dos talleres asociados: *ICL: Workshop on Iberian Cross-Language NLP tasks* y *DDIExtraction2011: First Challenge Task: Drug-Drug Interaction Extraction*.

Las áreas temáticas tratadas en el Congreso fueron las siguientes:

- Modelos lingüísticos, matemáticos y psicolingüísticos del lenguaje.
- Lingüística de corpus.
- Desarrollo de recursos y herramientas lingüísticas.
- Gramáticas y formalismos para el análisis morfológico y sintáctico.
- Semántica, pragmática y discurso.
- Lexicografía y terminología computacional
- Resolución de la ambigüedad léxica.
- Aprendizaje automático en PLN.
- Generación textual monolingüe y multilingüe.
- Traducción automática.
- Reconocimiento y síntesis del habla.
- Extracción y recuperación de información monolingüe, multilingüe y multimodal.
- Sistemas de búsqueda de respuestas.
- Análisis automático del contenido textual.
- Resumen automático.
- PLN para la generación de recursos educativos.
- PLN para lenguas con recursos limitados.
- Aplicaciones industriales del PLN.
- Sistemas de diálogo.
- Análisis de sentimientos y opiniones.
- Minería de texto.
- Evaluación de sistemas de PLN.
- Implicación textual y paráfrasis.

Todos los trabajos presentados en el XXVII Congreso de la SEPLN han sido aceptados mediante el proceso de revisión tradicional y ha sido llevado a cabo según el calendario previsto. Queremos agradecer a los miembros del Comité Científico y a los revisores adicionales la labor que han realizado.

En esta edición, se recibieron 78 trabajos, de los cuales 60 eran artículos científicos y 18 correspondían a resúmenes de proyectos de investigación y descripciones de herramientas. De entre los 60 artículos recibidos, 33 fueron finalmente seleccionados para su presentación oral, lo cual fija una tasa de aceptación del 55%. Adicionalmente, se aceptaron otros 12 artículos para su exposición en forma de póster. Autores de otros 10 países han participado en los trabajos presentados en esta edición. Estos países son: Polonia, Bulgaria, Singapur, Portugal, Noruega, Cuba, México, EEUU, Argentina y Brasil.

El Comité Científico del Congreso se ha hecho cargo de la revisión de los trabajos. Este proceso de revisión es de doble anonimato, se mantiene oculta la identidad de los autores que son evaluados y de los revisores que realizan las evaluaciones. En un primer paso cada artículo ha sido examinado de manera ciega o anónima por tres revisores. En un segundo paso, para aquellos artículos que tenían una divergencia mínima de tres puntos (sobre siete) en sus puntuaciones sus tres revisores han reconsiderado su evaluación en conjunto. Finalmente, la evaluación de aquellos artículos que estaban en posición muy cercana a la frontera de aceptación ha sido supervisada por más miembros del Comité.

Estimamos que la calidad de los artículos es alta. El criterio de corte adoptado ha sido la media de las tres calificaciones, siempre y cuando haya sido igual o superior a 5 sobre 7.

Julio de 2011
El Comité de Organización



Artículos.....	11
Extracción y Recuperación de Información.....	13
<i>Análisis de la expansión de consulta para colecciones médicas utilizando información mutua, ganancia de información y la ontología MeSH</i>	
José M. Perea-Ortega, Arturo Montejó-Ráez, Manuel C. Díaz-Galiano y Miguel Á. García-Cumbreras.....	15
<i>¿De verdad sabes lo que quieres buscar? Expansión guiada visualmente de la cadena de búsqueda usando ontologías y grafos de conceptos</i>	
Manuel de la Villa, Sebastián García y Manuel J. Maña	23
<i>Biomedical event extraction using Kybots</i>	
Arantza Casillas, Arantza Díaz de Ilarraza, Koldo Gojenola, Maite Oronoz y German Rigau	33
<i>Estudio del uso de Ontologías para la Expansión de Consultas en Recuperación de Imágenes en el Dominio Biomédico</i>	
Jacinto Mata, Mariano Crespo y Manuel J. Maña	41
<i>Resolución de Correferencia de Nombres de Persona para Extracción de Información Biográfica</i>	
Marcos García y Pablo Gamallo.....	49
<i>Expansión fonética de la consulta para la recuperación de información en documentos hablados</i>	
Alejandro Reyes Barragán, Luis Villaseñor-Pineda y Manuel Montes y Gómez	59
<i>Extracting terminology from Wikipedia</i>	
Jorge Vivaldi y Horacio Rodríguez	67
<i>A Spoken Document Retrieval System for TV Broadcast News in Spanish and Basque</i>	
Amparo Varona, Silvia Nieto, Luis Javier Rodríguez-Fuentes, Mikel Penagarikano, Germán Bordel y Mireia Diez	77
Resumen Automático	87
<i>Spanish Text Simplification: An Exploratory Study</i>	
Stefan Bott y Horacio Saggon	89
<i>Using Semantic Graphs and Word Sense Disambiguation Techniques to Improve Text Summarization</i>	
Laura Plaza y Alberto Díaz.....	99
<i>COMPENDIUM: Una herramienta de generación de resúmenes modular</i>	
Elena Lloret y Manuel Palomar	109
Traducción Automática	119
<i>Evaluación de estrategias para la traducción automática estadística de chino a castellano con el inglés como lengua pivote</i>	
Marta R. Costa-jussà, Carlos Henríquez y Rafael E. Banchs	121
Lexicografía y Terminología Computacionales	129
<i>Parallel corpus alignment at the document, sentence and vocabulary levels</i>	
Rogelio Nazar	131
<i>Unidad discursiva y relaciones retóricas: un estudio acerca de las unidades de discurso en el etiquetado de un corpus en euskera</i>	
Mikel Iruskieta, Arantza Díaz de Ilarraza y Mikel Lersundi	139
<i>Extracción automática de colocaciones terminológicas en un corpus extenso de lengua general</i>	
Octavio Santana Suárez, José Pérez Aguiar, Isabel Sánchez Berriel y Virginia Gutiérrez Rodríguez.....	147
<i>AnCora-Net: Integración multilingüe de recursos lingüísticos semánticos</i>	
Mariona Taulé, Oriol Borrega y M. Antònia Martí	155
Aprendizaje Automático en PLN.....	163
<i>Técnicas de clasificación de opiniones aplicadas a un corpus en español</i>	
Eugenio Martínez Cámara, M. Teresa Martín Valdivia, José M. Perea Ortega y L. Alfonso Ureña López	165

<i>Caracterización de Niveles de Informalidad en Textos de la Web 2.0</i>	
Alejandro Mosquera y Paloma Moreda	173
<i>Análisis de Sentimientos y Minería de Opiniones: el corpus EmotiBlog</i>	
Javi Fernández, Ester Boldrini, José Manuel Gómez y Patricio Martínez-Barco	181
<i>Augmenting Web Page Classifiers with Social Annotations</i>	
Arkaitz Zubiaga, Raquel Martínez y Víctor Fresno	191
<i>A Part-of-Speech Tag Clustering for a Word Prediction System in Portuguese Language</i>	
Daniel Cruz Cavalieri, Teodiano Freire Bastos Filho, Mário Sarcinelli Filho, Sira Elena Palazuelos Cagigas, Javier Macias-Guarasa y José L. Martín Sánchez	199
<i>Performance analysis of Particle Swarm Optimization applied to unsupervised categorization of short texts</i>	
Leticia Cagnina, Diego Ingaramo, Marcelo Errecalde y Paolo Rosso	209
<i>Detección de menciones anidadas basada en expansión para el español</i>	
Marcel Puchol-Blasco y Patricio Martínez-Barco	217
<i>Error Analysis for the Improvement of Subject Ellipsis Detection</i>	
Luz Rello, Gabriela Ferraro y Alicia Burga	225
<i>Generación automática de reglas de categorización de texto en un método híbrido basado en aprendizaje</i>	
Sara Lana-Serrano, Julio Villena-Román, Sonia Collada-Pérez y José Carlos González-Cristóbal	233
Desarrollo de Recursos y Herramientas Lingüísticas	241
<i>ATLAS – Multilingual Language Processing Platform</i>	
Maciej Ogródniczuk y Diman Karagiozov	243
<i>Enriching the Integration of Semantic Resources based on WordNet</i>	
Yoan Gutiérrez, Antonio Fernández, Sonia Vázquez y Andrés Montoyo	251
<i>ModeS TimeBank: A Modern Spanish TimeBank Corpus</i>	
Marta Guerrero Nieto, Roser Saurí y Miguel Ángel Bernabé Poveda	261
<i>Cognos: A Pragmatic Annotation Toolkit for the Acquisition of Natural Interaction Knowledge</i>	
Francisco Javier Calle, Esperanza Albacete, Garazi Olaziregi, Enrique Sánchez, David del Valle, Jessica Rivero y D. Cuadra	271
<i>Handling Reduplication in Basque: A Problem for Spell Checking</i>	
Dorota Krajewska y Tamara Hernández Godoy	279
<i>Conversión Fonética Automática con Información Fonológica para el Gallego</i>	
Marcos García e Isaac González López	285
<i>Construcción de los WordNets 3.0 para castellano y catalán mediante traducción automática de corpus anotados semánticamente</i>	
Antoni Oliver y Salvador Climent	295
<i>Ensinador: corpus-based Portuguese grammar exercises</i>	
Alberto Simões y Diana Santos	303
Demostraciones	313
<i>AVI.cat: Asistente virtual para la mejora de la redacción en catalán</i>	
Antoni Oliver, Salvador Climent y Marta Coll-Florit	315
<i>Inferring the Scope of Negation and Speculation Via Dependency Analysis</i>	
Miguel Ballesteros, Virginia Francisco, Alberto Díaz, Jesús Herrera y Pablo Gervás	317
<i>MDFaces: An intelligent system to recognize significant terms in texts from different domains using Freebase</i>	
Fernando Aparicio, Rafael Muñoz, Manuel de Buenaga y Enrique Puertas	319
<i>MarUja: Prototipo de Asistente Virtual para la Carta de Servicios del Servicio de Informática de la Universidad de Jaén</i>	
Eugenio Martínez Cámara, L. Alfonso Ureña López y José M. Perea Ortega	321
<i>Gestión de la información morfológica para la creación de un nuevo par de lenguas con distintos dialectos en un sistema de traducción automática de código abierto</i>	
Garbiñe Aranbarri Ariztondo y Itziar Cortés Etxabe	323
<i>Matxin-Informatika: versión del traductor Matxin adaptada al dominio de la informática</i>	
Iñaki Alegria, Unai Cabezón, Gorka Labaka, Aingeru Mayor y Kepa Sarasola	325
<i>Sistema de diálogo multimodal basado en modelos estadísticos</i>	
E. Sanchis, L. Hurtado, J.A. Gómez, F. García, J. Pastor, J. Planells y E. Segarra	327
<i>Una demostración de Onoma, el conjugador en línea de verbos y neologismos verbales en español</i>	
Eduardo Basterrechea, Luz Rello y Rodrigo Alarcón	329
<i>BioViewMed, una herramienta visual de ayuda a la expansión de la cadena de búsqueda usando ontologías</i>	
Sebastián García Pérez, Manuel de la Villa y Manuel J. Maña	331
<i>ALICE: Acquisition of Language through an Interactive Comprehension Environment</i>	
Maria Fuentes y Meritxell González	333
Proyectos	335
<i>Desarrollo de Recursos para el Análisis Sintáctico Automático del Español: AVALON, una gramática formal y CSA, un corpus sintácticamente analizado</i>	
M. ^a Paula Santalla del Río	337

<i>Araknion: inducción de modelos lingüísticos a partir de corpora</i>	
M. Antònia Martí, Mariona Taulé, Xavier Carreras, Horacio Rodríguez y Patricio Martínez-Barco	339
<i>TextMess 2.0: Las Tecnologías del Lenguaje Humano ante los nuevos retos de la comunicación digital</i>	
Patricio Martínez-Barco, M. Antònia Martí, L. Alfonso Ureña y Paolo Rosso	341
<i>Text Simplification in Simplex: Making Text More Accessible</i>	
Horacio Saggion, Elena Gómez-Martínez, Esteban Etayo, Alberto Anula y Lorena Bourg	343
<i>AutoIndexer: Investigación y Desarrollo de Metodologías y Recursos Terminológicos de Apoyo para los Procesos de Indexación Automática de Documentos Clínicos</i>	
Alberto Díaz, Laura Plaza, Virginia Francisco, Pablo Gervás, Alejandro Palacios, Oliver Partida, Enrique Mota, Arturo Romero e Ignacio Colodrón	345
<i>Procesamiento automático de metáforas con métodos no supervisados</i>	
B. Navarro-Colorado, D. Tomás, S. Vázquez, P. Moreda, R. Izquierdo, E. Saquete y F. Llopis	347
<i>MULTIMEDICA: Extracción de información multilingüe en Sanidad y su aplicación a documentación divulgativa y científica</i>	
Paloma Martínez, José C. González-Cristóbal y Antonio Moreno Sandoval	349
<i>Spoken language recognition in conversational telephone speech and TV broadcast news (GLOSA)</i>	
Luis Javier Rodríguez-Fuentes, Amparo Varona, Mikel Peñagarikano, Mireia Díez y Germán Bordel	351
Pósteres	353
<i>Extracting Information from a Parallel Spanish-English Summary Corpus</i>	
Horacio Saggion y Sandra Szasz	355
<i>Domain-neutral, Linguistically-motivated Sentiment Analysis: a performance evaluation</i>	
Antonio Moreno-Ortiz, Chantal Pérez Hernández y Rodrigo Hidalgo García	361
<i>Metodología y desarrollo del primer corpus en español anotado con relaciones retóricas</i>	
Iria da Cunha, Juan-Manuel Torres-Moreno y Gerardo Sierra	371
<i>Preliminary evaluation of EPEC-RolSem, a Basque corpus labelled at predicate level</i>	
Izaskun Aldezabal, María Jesús Aranzabe, Arantza Díaz de Ilaraza y Ainara Estarrona	381
<i>Detección de la polaridad de tweets en español</i>	
Eugenio Martínez Cámara, Miguel Ángel García Cumbreiras, M. Teresa Martín Valdivia y L. Alfonso Ureña López	391
<i>Georeferencing Textual Annotations and Tagsets with Geographical Knowledge and Language Models</i>	
Daniel Ferrés y Horacio Rodríguez	399
<i>Natural Language Processing in Recommender Systems based on Collaborative Filtering</i>	
Juan D. Borrero, José Carpio Cañada, Víctor Rivas Santos, Juan J. Merelo Guervós y José L. Álvarez Macías	409
<i>Análisis de preguntas para Búsqueda de Respuestas: evaluación de tres parsers del español</i>	
Iria Gayo	419
<i>Minimizando el etiquetado manual en la modelización estadística para la comprensión del habla</i>	
Lucía Ortega, Isabel Galiano y Emilio Sanchís	427
<i>Text::Perfide::BookCleaner, a Perl module to clean and normalize plain text books</i>	
André Santos y José João Almeida	433
<i>Propuesta metodológica para la creación automática de patrones léxicos usando el Corpus Pattern Analysis</i>	
Irene Renau y Rogelio Nazar	443
<i>Detecting source code reuse across programming languages</i>	
Enrique Flores, Alberto Barrón-Cedeño, Paolo Rosso y Lidia Moreno	451

Propuesta metodológica para la creación automática de patrones léxicos usando el Corpus Pattern Analysis*

Methodological Proposal for Automatic Creation of Lexical Patterns using Corpus Pattern Analysis

Irene Renau

IULA - Universitat Pompeu Fabra
C/Roc Boronat, 138, 08018 Barcelona
irene.renau@upf.edu

Rogelio Nazar

IULA - Universitat Pompeu Fabra
C/Roc Boronat, 138, 08018 Barcelona
rogelio.nazar@upf.edu

Resumen: El presente artículo propone una metodología para la creación automática de patrones léxicos basada en el Corpus Pattern Analysis (CPA) de Hanks. El CPA se fundamenta en la idea de que las palabras no tienen significado en sí mismas, sino que lo adquieren en contexto. Se aborda la cuestión desde las necesidades de la lexicografía, especialmente de aprendizaje, que demanda cada vez más la incorporación de información gramatical y acorde con la lengua actual en uso. Se ejemplifica dicho procedimiento con el verbo *volcar*.

Palabras clave: Corpus Pattern Analysis (CPA), desambiguación semántica, lexicografía computacional, lingüística de corpus

Abstract: This article presents a methodology for the automatic creation of lexical patterns based on Hank's Corpus Pattern Analysis (CPA). CPA is a corpus analysis method based on the idea that words do not have meaning in isolation, but they acquire it in context. We tackle the problem from the needs of lexicography, especially the pedagogical lexicography, which is demanding more grammatical information, appropriate to language in use. We exemplify the procedure with the verb *volcar* (= 'knock over').

Keywords: computational lexicography, corpus linguistics, Corpus Pattern Analysis (CPA), word sense disambiguation

1. Introducción y objetivos

Este trabajo tiene como objetivo presentar una metodología de detección y configuración automáticas de patrones léxicos basada en el Corpus Pattern Analysis, CPA (Hanks, 2004; Hanks, En prensa), enfocada especialmente desde las necesidades de la lexicografía. El CPA es un método basado en corpus para la detección de los patrones normales de uso de una palabra, en relación con sus rasgos sintácticos y semánticos. A diferencia de las aproximaciones tradicionales basadas fuertemente en la noción de las acep-

ciones vinculadas a los distintos sentidos que una palabra puede tener, el CPA clasifica los distintos usos de la palabra en función de una serie limitada de dichos patrones extraídos de los contextos de uso. El objetivo del presente trabajo es aplicar el procedimiento propuesto por Hanks al análisis de verbos en castellano y explorar las posibilidades de automatización de esta tarea. En concreto, la metodología que se expondrá a continuación surge de una necesidad tanto general, en el panorama lexicográfico, como particular, en relación con un proyecto de *Diccionario de aprendizaje de español como lengua extranjera* (DAELE) que se encuentra en desarrollo (Battaner y Renau, 2008), y del cual se ofrece en línea un primer núcleo de verbos (<http://www.iula.upf.edu/rec/daele>). Por otro lado, el propósito del trabajo se vincula no solamente con la actividad previa a la publicación de los datos, sino también con

* Este trabajo ha recibido una subvención de los siguientes proyectos del MCI: "Agrupación semántica y relaciones lexicológicas en el diccionario", dir.^a: J. DeCesaris (HUM2009-07588/FILO); APLE: "Procesos de actualización del léxico del español a partir de la prensa", período 2010-2012, dir.^a: M. T. Cabré (FFI2009-12188-C05-01/FILO). También ha recibido subvención de la Fundación Comillas en relación con el proyecto DAEL.

la traslación de estos a la interfaz de usuario de forma dinámica y acorde con la tecnología actual.

El artículo seguirá la siguiente estructura: en primer lugar, se indicarán las necesidades de la lexicografía, en especial de aprendizaje, en relación con la automatización de tareas, como justificación del procedimiento que se describirá; en segundo lugar, se detallará el CPA como método de análisis de corpus; en tercer lugar, se explicará el procedimiento de clasificación y generación de patrones léxicos, ejemplificándolo con el verbo *volcar*; por último, se abordarán las perspectivas de trabajo futuras en relación con la implementación de esta metodología.

2. Lexicografía de aprendizaje y procesamiento del lenguaje natural

Desde que Sinclair inauguró la era de los diccionarios basados en corpus con el *Collins Cobuild English Language Dictionary* (J. Sinclair, 1987), el análisis de corpus constituye el procedimiento estándar admisible para la elaboración rigurosa de diccionarios y cualquier otra herramienta lexicográfica. En la actualidad, la necesidad de dotar de mayor rigor la explotación de corpus, así como de agilizarla y facilitar la extracción de información, constituyen necesidades fundamentales para los equipos lexicográficos tanto investigadores como comerciales. Así pues, se trata de alcanzar objetivos de mayor rigor metodológico y teórico, pero también mayor competitividad y rendimiento en cuanto al tiempo y al esfuerzo dedicados. Apresjan (2002) define la “lexicografía sistemática” como una reconstrucción de los significados abstractos basada en los patrones de uso gramaticales y semánticos, y aboga por un “integrated dictionary” que reúna no solo semántica sino también gramática.

En este sentido, se ha demandado a menudo, sobre todo en relación con los *learner's dictionaries* (inaugurados con el citado diccionario Cobuild) incorporar más información gramatical en la microestructura de la entrada lexicográfica (Boogards, 2010; Bosque, 2006). Los diccionarios ya no se conciben solo como repositorios de información semántica con pequeñas indicaciones sintácticas suplementarias (como la categoría gramatical), sino que se ven como repertorios alfabéticos en los cuales un usuario puede

consultar las dudas puntuales que tenga sobre cierta palabra, sean estas dudas semánticas o sintácticas. En este panorama se hacen aún más necesarias las herramientas que permitan detectar esta información gramatical e incorporarla de forma sistemática al diccionario.

Aparte de las necesidades de fundamentación teórica y metodológica, de ahorro de costos y de mayor explotación de la información gramatical, un cuarto objetivo justifica que el análisis de corpus se ejecute de forma cada vez más refinada y con más prestaciones: el paso de los diccionarios en papel a la publicación en la web. Pese a que Internet se popularizó en los años noventa, los diccionarios en línea existentes hoy en día no cubren todas las prestaciones que la tecnología les permite ofrecer, de modo que son muy pocos los diccionarios que incorporan elementos complementarios a la información clásica que se ofrecía ya en papel. A causa de ello, los especialistas en español como lengua extranjera y los metalexicógrafos demandan desde hace tiempo la incorporación en el diccionario de hiperenlaces, abundancia de información, múltiples opciones de búsqueda y otros elementos relacionados con la interacción usuario-web y con el hecho de que el espacio en Internet ya ha dejado de ser un problema, antes endémico de los diccionarios.

El análisis de corpus es la actividad que más tiempo consume de las que se requieren en la elaboración de un producto lexicográfico. Así, esta metodología, que se prevé implementar en el corto plazo, pretende no solamente cubrir necesidades teóricas y metodológicas que justifiquen el procedimiento empleado, sino que también pretende cubrir necesidades de coste económico y en relación con los extensos calendarios a los que un proyecto de diccionario se somete. Las relaciones entre la lexicografía y el procesamiento del lenguaje natural han sido ya explicadas (Wilks, Slator, y Guthrie, 1996; Corréard, 2002; Fontenelle, 2002). Se han realizado avances en la incorporación de herramientas computacionales en lexicografía, sobre todo encaminadas a la mejor explotación del corpus, por ejemplo, en relación con la detección de ciertos colocados o de ciertas estructuras gramaticales: Sketh Engine, de Kilgariff et al. (2004), o DANTE Database, de Convery et al. (2010), son una muestra; pero la vinculación directa entre el corpus y el

diccionario (mediada por la supervisión humana experta) está aún en su fase inicial. Así pues, parece necesario ofrecer alternativas computacionales a la tarea costosa en tiempo y esfuerzo del análisis manual del corpus y de la incorporación de los datos tanto semánticos como sintácticos al diccionario.

3. Metodología de análisis de corpus: el CPA

Como se ha avanzado en la introducción, los principales objetivos del CPA son identificar patrones normales de uso de las palabras y asociarlos con un significado, que no se contempla aisladamente, sino en su contexto de uso. El CPA se fundamenta en la Theory of Norms and Exploitations, TNE (Hanks, 2004; Hanks, En prensa), según la cual el comportamiento sintáctico-semántico de una unidad léxica se establece mediante normas (o usos más frecuentes) y sus desviaciones o “explotaciones”, que son usos específicos y no estandarizados que se emplean en contextos poco frecuentes. Por ejemplo, la frase “Le acusaban de desórdenes públicos por haber volcado un contenedor” se considera un uso normal del verbo *volcar* (v. apartado 5), pero la frase “El verano volcaba ya oleadas de turismo” se considera una explotación en la que un sujeto inanimado e inmaterial (una estación del año) ejecuta una acción. En este caso, se está explotando uno de los patrones normales de uso del verbo para crear una metáfora en la que probablemente se personifica al verano. La TNE se basa en la teoría de prototipos (Pustejovsky, 1995), que postula una relación jerárquica entre tipos semánticos (o significados abstractos); dicha concepción se unifica en la TNE con la de *lexical item* de Sinclair (1998), según la cual el significado se asocia fuertemente a un contexto. En última instancia, la distinción nos remite a la obra de Hjelmslev (1943), concretamente a la distinción hecha por él entre semióticas denotativas, en las que un plano de la expresión está en función de un plano del contenido, y las semióticas connotativas, en las que ambos planos forman un nuevo plano de expresión para un nuevo plano del contenido.

El CPA puede considerarse una de las posibles aplicaciones de la TNE, focalizada en la investigación lexicológica y aplicable a la lexicografía. Este modelo de análisis de corpus se está desarrollando para el inglés a través del *Pattern Dictionary of En-*

glish Verbs, PDEV (Hanks y Pustejovsky, 2000; Cinková, Holub, y Smejkalová, 2010), y se está comenzando a implementar para el castellano (Renau y Alonso, En preparación) y el italiano (Jezek y Frontini, 2010). Existen unos 700 verbos ya redactados en el PDEV, y se han redactado unos 120 de la versión española. El PDEV es de acceso libre (<http://deb.fi.muni.cz/pdev>).

Se considera que el CPA resulta útil para fundamentar en él la tarea de análisis de corpus en relación con un proyecto lexicográfico porque cada patrón puede asociarse con la correspondiente acepción del artículo (al menos en el caso de los verbos, que es lo que se ha probado tanto en el PDEV como en los CPA italiano y español). Así pues, constituye un modo de sistematizar la microestructura de la entrada lexicográfica, y permite evitar la subjetividad del lexicógrafo en el análisis de corpus, un problema que a menudo ha sido relacionado con los diccionarios (Atkins y Rundell, 2008).

El CPA permite, en resumen, reunir en un patrón de uso las características sintácticas del verbo, señalar los argumentos y relacionar estos con una ontología que se encuentra en proceso de elaboración (pues se establece *bottom-up*, en vez de *top-down*), que sirve para etiquetar cada argumento mediante un tipo semántico. Es el cruce entre el análisis sintáctico y semántico lo que hace muy preciso y completo el CPA, pero particularmente el hecho de que este análisis semántico cuente con una ontología que se suma a la identificación de argumentos.

4. Propuesta de detección automática de patrones léxicos en el corpus mediante CPA

En relación con las necesidades de más rigor y rapidez en la extracción de información del corpus en relación con el proyecto DAELE, nos proponemos una doble tarea. Por un lado, perseguimos el objetivo de clasificar automáticamente cada uno de los contextos reales de uso del verbo (obtenidos de corpus de prensa en castellano) según los patrones que hemos encontrado para este verbo. Por otro lado, pretendemos generar automáticamente los distintos patrones que presenta el verbo. La metodología que proponemos está basada en el supuesto de que disponemos de una taxonomía del castellano y un conocimiento de la sintaxis de los grupos

nominales en castellano; así, la primera tarea consiste en crear dicha taxonomía (Nazar y Janssen, 2010; Nazar, Vivaldi, y Wanner, En prensa). Para cada contexto verbal analizado, nuestro algoritmo identificará aquellos grupos nominales que aparecen como argumentos del verbo. Acto seguido, estos grupos nominales serán buscados en la taxonomía para reemplazarlos por los hiperónimos a los que aparecen asociados, continuando el ascenso por la taxonomía hasta llegar a alguna de las denominaciones altamente abstractas que aparecen en la ontología de Hanks.

Es relevante para el experimento el hecho de que lo que se pretende no es (o no es prioritariamente) etiquetar correctamente la mayoría de concordancias, sino encontrar los principales patrones de uso de cada palabra. Por ejemplo, si en una muestra de 1.000 concordancias hay un 75 % de ellas mal anotadas, pero el 25 % restante ha ofrecido los patrones léxicos correctos de la palabra analizada, el resultado puede considerarse positivo, porque se persigue principalmente hallar los patrones de uso normales de cada unidad, no un porcentaje elevado de éxito en la adjudicación de patrones a cada concordancia.

La propuesta que se presenta consiste en reflejar en procedimientos automáticos tareas que hasta ahora se realizaban manualmente, y añadir otras que el análisis manual no permite. Se observan las siguientes necesidades, que se corresponden con las distintas fases de análisis de corpus y la creación de patrones: 1) Detección de los argumentos del verbo; 2) Asociación de los argumentos a los tipos semánticos de una ontología; 3) Sustitución de los argumentos por los tipos semánticos para crear el patrón léxico; 4) Introducción de los patrones en la base de datos lexicográfica, como base para la redacción de la entrada; y 5) Asociación de cada acepción del diccionario con los patrones detectados y con las concordancias de corpus vinculadas a cada patrón.

Se exponen a continuación estos pasos del procedimiento.

4.1. Detección de los argumentos del verbo

La detección de los argumentos del verbo en el corpus se proyecta, por el momento, como dependiente de lengua y se configurará teniendo en cuenta los supuestos teóricos básicos acerca del concepto de argumento y

de las funciones sintácticas (RAE, 2009). Se tomará como punto de partida la herramienta de análisis lingüístico Freeling (Carreras et al., 2004), que tiene la ventaja de haber desarrollado un analizador de dependencias y ser de código libre. La mayor complejidad en la detección de argumentos del verbo radica en distinguir argumentos de adjuntos, lo cual ocurre en el caso de los complementos de régimen frente a los circunstanciales, por ejemplo. Sin embargo, es más fácil detectar argumentos que se encuentran en posición de sujeto, objeto directo o indirecto: solamente dicha detección es ya un avance para acelerar y hacer más riguroso el análisis de corpus con vistas a su explotación lexicográfica.

4.2. Asociación de los argumentos a los tipos semánticos de una ontología

Todo diccionario podría definirse como una ontología o taxonomía “plana”, expuesta de forma lineal, en la que sus lemas se interconectan entre sí mediante una red de relaciones hiperónimo-hipónimo que crea agrupaciones semánticas. Sin embargo, es bien conocido el problema de los círculos viciosos, pistas perdidas y otros defectos de este sistema en los diccionarios hasta hace muy poco realizados sin más herramientas que la pericia de cada lexicógrafo. El trabajo lexicográfico sustentado en una ontología ayuda a sistematizar estas relaciones, y a explotar las posibilidades de ofrecer la información de modo diferente al tradicional, a través de redes relacionales entre las palabras de la macroestructura, más allá de sinonimia, antonimia y otras clásicas relaciones.

La ontología de Hanks, que se va elaborando conforme se van analizando verbos, se establece, como cualquier ontología, mediante tipos semánticos conectados jerárquicamente. Por ejemplo, el tipo semántico “Event” se subdivide en “Process” y “Activity”: “Process” se refiere a los eventos no controlados por el ser humano (como enfermedades o fenómenos atmosféricos), y “Activity” denota las acciones humanas.

El empleo de la ontología, clave para la propuesta metodológica expuesta, se observa como una paradoja: por un lado, utilizar la ontología de Hanks en su estadio actual puede ser un primer paso, pero no permitiría etiquetar todos los argumentos con su tipo semántico, porque dicha ontología está avan-

zada pero incompleta; por otro lado, emplear otra ontología ya terminada implicaría incorporar al sistema una herramienta no optimizada para este y requeriría adaptarla. El propio Hanks ha rechazado el uso para CPA de ontologías como WordNet (Miller et al., 1988) porque contemplan las palabras aisladamente, sin tener en cuenta el contexto de uso (Hanks, En prensa). Uno de los objetivos principales del CPA es precisamente vincular los diversos significados de las palabras a sus respectivos contextos.

En cuanto a las explotaciones, se prevé que sean numerosas, pero muy diversas, de modo que no puedan acumularse en patrones unificados (pues si lo hiciesen dejarían de ser explotaciones para ser usos normales). Así, las concordancias que no pudieran agruparse bajo patrones de frecuencia alta serían colocadas en un grupo aparte y clasificadas como explotaciones.

4.3. Sustitución de los argumentos por los tipos semánticos y creación del patrón léxico

Esta fase consiste en tomar el verbo buscado en el corpus y sustituir sus argumentos (detectados en la fase previa) por aquellos que aparecen en la ontología como elementos semánticos hiperónimos de los hallados en la concordancia. El límite de abstracción del tipo semántico de la ontología seleccionado para ser incorporado al patrón se corresponde con aquel que agrupa en niveles inferiores de la jerarquía un gran número de tipos semánticos. Los patrones resultantes deben tener las mismas características que tienen los patrones realizados manualmente, y deben respetar los códigos tipográficos y la metalengua. Igualmente, deben ordenarse por frecuencia decreciente y deben ofrecerse los porcentajes de frecuencia de cada uno (dato que podría mostrarse también en el propio diccionario).

4.4. Introducción de los patrones en la base de datos lexicográfica

Los patrones creados para cada verbo se exportan a la base de datos, como uno de los componentes del campo acepción. Es decir, a cada acepción le corresponde un patrón de CPA, y dicho patrón es utilizado por el redactor como base para la redacción de la definición. La adaptación del patrón a las

necesidades del usuario es ya una tarea propiamente lexicográfica.

No está previsto que el patrón sea visible para el usuario, pues se considera que un diccionario didáctico no debe ofrecer información tan técnica a un aprendiz; en cambio, los patrones sí se consideran clave para guiar al lexicógrafo en la configuración tanto sintáctica como semántica de cada acepción (como ya se ha advertido, apartado 4, inicio). La definición natural, que han adoptado la serie Cobuild y otros diccionarios didácticos (entre ellos el DAELE), puede entenderse como una paráfrasis del patrón explicada de modo pedagógico y enriquecida semánticamente.

4.5. Asociación de las concordancias de cada patrón con su correspondiente acepción

Por último, cada definición elaborada con base en su respectivo patrón se asocia con las concordancias de corpus, etiquetadas con dicho número de patrón, con el fin de que sean empleadas como ejemplos. Así, estas concordancias se exportan a la base de datos vinculándolas a su acepción, del mismo modo que se ha hecho con el patrón (apartado anterior). Con vistas a la adaptación de las concordancias a los criterios lexicográficos (relacionados con las necesidades y características del usuario), parece requerirse que estas puedan ser modificadas (extractadas, corregidas ortográficamente, etc.), pese a que la meta para el diccionario que se proyecta es que no se modifiquen excesivamente (en la línea de los Cobuild proyectada por Sinclair). Igualmente, se considera apropiado que dichos ejemplos puedan ordenarse y que puedan marcarse aquellos considerados más relevantes desde el criterio lexicográfico, con respecto a los menos apropiados.

5. Un ejemplo: el verbo “volcar”

Ejemplificaremos el procedimiento mediante el verbo *volcar*. En castellano, este verbo puede utilizarse de distintas formas, por ejemplo, un vehículo puede volcar, pero también una persona puede volcar un líquido sobre una superficie. Claramente se trata de distintos usos, pero en la lexicografía de Hanks, en lugar de representar distintas acepciones, estos usos se representan en patrones. En el verbo *volcar* podemos encontrar, por ejemplo, los siguientes cuatro pa-

tronos (aunque en realidad hay por lo menos ocho); se añade un ejemplo de corpus para cada uno de ellos:

- Patrón 1: [[Vehicle]] volcar

Implicatura: [[Vehicle]] turns over, capsizes

Ejemplo: “Otro autobús volcaba en un lugar próximo a la presa de Chira”.

- Patrón 2: [[Animate - Process]] volcar
[[Artifact]]

Implicatura: [[Human - Process]] knocks over
[[Artifact]]

Ejemplo: “Le acusaban de desórdenes públicos por haber volcado un contenedor”.

- Patrón 3: [[Human]] volcarse (en - con
[[Activity]])

Implicatura: [[Human]] dedicates lot of efforts
and enthusiasm to make an [[Activity]]

Ejemplo: “Hay que volcarse en los problemas sociales”.

- Patrón 4: [[Human 1]] volcarse [[con Human 2]]

Implicatura: [[Human 1]] dedicates lot of attention to [[Human 2]] or enthusiastically encourages him/her

Ejemplo: “...una afición que ayer se volcó con su equipo”.

El verbo *volcar* aparece en 942 concordancias del corpus empleado actualmente para el desarrollo del CPA en castellano, del cual están tomados los ejemplos anteriores. Se trata de un corpus de prensa de 50 millones de palabras. De estas concordancias, se analizaron manualmente 250, que se dividieron en los patrones mencionados, descritos mediante las correspondientes “implicaturas” o significados potenciales que deben inferirse en cada caso. Las etiquetas entre corchetes corresponden a los tipos semánticos de la ontología de CPA, el objeto de la cual es hacer abstracción sobre el tipo de entidad que aparece como argumento del verbo analizado. El sentido de estos patrones es expresar que, en castellano, uno de los usos de *volcar* puede ser el accidente de un vehículo, en el que el vehículo aparece como el único argumento del verbo. Pero también, según el patrón 2, un agente puede volcar un artefacto, tal como un manifestante puede volcar un contenedor. En

un uso totalmente distinto, según el patrón 3, una persona puede volcarse en una actividad o bien, en otro uso distinto del verbo, según el patrón 4, una persona puede volcar una sustancia sobre una superficie.

Otros usos de *volcar* hallados en el corpus se dibujan de forma menos precisa como patrones fijos, y apuntan más bien a explotaciones de otros patrones o a usos en decadencia: “El verano volcaba ya oleadas de turismo” (mencionado *supra* como explotación metafórica del patrón 2), “La atención se vuelca en las dos figuras femeninas” (el argumento *atención* no es usual para el patrón 3, “(Alemania) se ha volcado a la fibra de carbono” (no es usual el empleo de la preposición *a* para el patrón 4), etc.

En el caso del primer patrón, por ejemplo, el algoritmo debe identificar, en primer lugar, que el patrón tiene un argumento que se corresponde con el sujeto (es una estructura intransitiva). Identificará como sujetos de *volcar* sustantivos como *autobús*, *autocar*, *barca*, *camión*, *convoy*, *embarcación*, *patera*, *tren*, etc. En la ontología de Hanks, existe el tipo semántico “Vehicle” como subtipo de “Machine”, y se subdivide en “Road Vehicle” y “Water Vehicle”. En el caso de *volcar*, tanto puede combinarse con un vehículo terrestre como marino, pues las propiedades semánticas de *volcar* se refieren genéricamente a que un objeto se gira hacia un lado y cae por efecto de la gravedad. Así, puede volcar casi cualquier vehículo, siempre que esté sometido a gravedad y esté apoyado en una superficie, sea agua o suelo.

Una vez identificado el argumento, una ontología suficientemente completa debe proporcionar las relaciones hiperonímicas entre cada sustantivo y el tipo semántico correspondiente: debe asociar *barca*, *embarcación* y *patera* a “Water Vehicle”, y el resto a “Road Vehicle”. Siendo ambos tipos semánticos dependientes de “Vehicle”, el sistema debe poder unir ambos en este único tipo semántico. No hallando otros sustantivos en posición de sujeto que coincidan con otros tipos semánticos superiores en la jerarquía (es decir, al mismo nivel de “Vehicle”).

Pueden encontrarse casos de ambigüedad debida tanto a la sintaxis como a la semántica. La frase “El conductor falleció tras volcar el vehículo” es interpretada por los humanos como intransitiva por conocimiento del mundo, pero un sistema automático podría clasi-

ficarla como transitiva y adjudicarle el patrón 2. Es igualmente difícil clasificar los nombres propios en casos como “Nueva Pepita Aurora volcó, pero no se hundió”. Sin embargo, como ya se ha advertido (apartado 4), el objetivo consiste en facilitar y agilizar la labor lexicográfica hasta ahora manual, de modo que se obtenga un porcentaje de aciertos lo suficientemente alto como para justificar el procedimiento.

Dejando de lado, pues, estos casos conflictivos, el algoritmo habría identificado que uno de los patrones con los que se expresa *volcar* es intransitivo y consta de un argumento en posición de sujeto que denota vehículos. Así, este patrón se traslada a la base de datos y se vincula con las concordancias que se ajustan a él. El traslado del patrón a la base de datos lexicográfica es el último paso automático para realizar antes de la redacción propiamente dicha. Puede consultarse el artículo de *volcar* en la versión actual del DAELE (web. cit.).

6. Reflexiones finales y trabajo futuro

En esta exposición se ha propuesto un método de extracción automática de patrones léxicos a través del CPA, con fines lexicográficos. El CPA no tiene por qué ser un sistema válido para cualquier finalidad de desambiguación semántica, pero se considera que resulta útil para la confección de diccionarios, pues ha sido concebido principalmente para ello. La aplicación de esta metodología, como también otras aplicaciones automáticas relacionadas con PLN y CPA, están aún bajo estudio y discusión (Cinková et al., 2010; Ide y Wilks, 2006), por lo que una de las contribuciones del trabajo futuro (si bien secundaria para nuestras necesidades) debe ser ayudar a resolver la cuestión sobre si CPA puede ser una herramienta generalizable para PLN.

Las dificultades de la labor por hacer son evidentes, como también el hecho de que un porcentaje relativamente bajo de éxito equivaldría al mismo porcentaje de tiempo y coste económico ahorrados. Como ya se ha indicado, las herramientas de análisis de corpus disponibles (apartado 2) son muy adecuadas para la tarea lexicográfica, pero está aún por explorar una mayor relación corpus-diccionario.

El plan de implementación de este método se incluye dentro de las actividades para

realizar durante el periodo 2011-2012, destinado entre otras cosas a la automatización de procesos para aumentar el rigor y el rendimiento. Se persigue, en definitiva, dotar al diccionario de más herramientas automáticas tanto para el proceso de preparación del contenido como para la interfaz de usuario. Está previsto obtener los primeros resultados en el mismo período.

Bibliografía

- Apresjan, J. D. 2002. Principles of systematic lexicography. En M.-H. Corréard, editor, *Lexicography and Natural Language Processing*. Euralex, United Kingdom, páginas 91–104.
- Atkins, S. y M. Rundell. 2008. *The Oxford Guide to Practical Lexicography*. Oxford University Press, United Kingdom.
- Battaner, P. y I. Renau. 2008. Sobre las construcciones pronominales y su tratamiento en algunos diccionarios monolingües de cuatro lenguas románicas. En DeCesaris y Bernal (DeCesaris y Bernal, 2008), páginas 495–504.
- Boogards, P. 2010. Dictionaries and Second Language Acquisition. En Dykstra y Schoonheim (Dykstra y Schoonheim, 2010), páginas 99–123.
- Bosque, I. 2006. Una nota sobre la relevancia de la información sintáctica en el diccionario. En E. Bernal y J. DeCesaris, editores, *Palabra por palabra. Estudios ofrecidos a Paz Battaner*. Institut Universitari de Lingüística Aplicada, Universitat Pompeu Fabra, Barcelona, páginas 47–53.
- Carreras, X., I. Chao, L. Padró, y M. Padró. 2004. FreeLing: An Open-Source Suite of Language Analyzers. En *Proceedings of the 4th International Conference on Language Resources and Evaluation (LREC'04)*, Lisboa. European Language Resources Association.
- Cinková, S., M. Holub, P. Richlý, L. Smejkalová, y J. Indlerová. 2010. Can Corpus Pattern Analysis be used in natural language processing? En *Text, Speech and Dialogue: 13th International Conference*, páginas 67–74, Berlin. Springer.
- Cinková, S., M. Holub, y L. Smejkalová. 2010. The lexical population of semantic types in hank's pdev. En G.-M. De

- Schryver, editor, *A Way with Words: Recent Advances in Lexical Theory and Analysis. A Festschrift for Patrick Hanks*. Menha Publishers, Kampala (Uganda), páginas 199–214.
- Convery, C., S. Atkins, A. Kilgarrieff, M. Rundell, P. Ó Mianáin, y M. Ó Raghallaigh. 2010. The DANTE Database (Database of Analysed Texts of English). En Dykstra y Schoonheim (Dykstra y Schoonheim, 2010).
- Corréard, M.-H. 2002. *Lexicography and Natural Language Processing*. Euralex, United Kingdom.
- DeCesaris, J. y E. Bernal, editores. 2008. *Proceedings of the XIII EURALEX International Congress*, Barcelona. Institut Universitari de Lingüística Aplicada, Universitat Pompeu Fabra.
- Dykstra, A. y T. Schoonheim, editores. 2010. *Proceedings of the XIV Euralex International Congress*, Ljouwert (Países Bajos). Fryske Akademy.
- Fontenelle, T. 2002. Lexical knowledge and natural language processing. En M.-H. Corréard, editor, *Lexicography and Natural Language Processing*. Euralex, United Kingdom, páginas 216–229.
- Hanks, P. 2004. The Syntagmatics of Metaphor and Idioms. *International Journal of Lexicography*, 17(3):245–274.
- Hanks, P. En prensa. *Lexical Analysis: Norms and Exploitations*. MIT Press, Massachusetts.
- Hanks, P. y J. Pustejovsky. 2000. A Pattern Dictionary for Natural Language Processing. *Revue Française de Linguistique Appliquée*, 10(2):63–82.
- Hjelmslev, L. 1943. *Prolegomena to a Theory of Language*. Indiana University Publications in Anthropology and Linguistics, Baltimore.
- Ide, N. y Y. Wilks. 2006. Making senses about sense. En E. Agirre y P. Edmonds, editores, *Word Sense Disambiguation. Algorithms and Applications*. Springer, Nueva York, páginas 47–74.
- J. Sinclair, dir. 1987. *The Collins Cobuild English Language Dictionary*. Harper-Collins, Nueva York.
- Jezek, E. y F. Frontini. 2010. From pattern dictionary to patternbank. En G.-M. De Schryver, editor, *A Way with Words: Recent Advances in Lexical Theory and Analysis. A Festschrift for Patrick Hanks*. Menha Publishers, Kampala (Uganda), páginas 215–239.
- Kilgarrieff, A., P. Rhychly, P. Smrz, y P. Tugwell. 2004. The Sketch Engine. En *Proceedings of the Eleventh Euralex International Congress*, páginas 105–116, Lorient (Francia). Université de Bretagne-Sud.
- Miller, G. A., Ch. Fellbaum, J. Kegl, y J. K. Miller. 1988. WordNet: an electronic lexical reference system based on theories of lexical memory. *Revue Québécoise de Linguistique*, 17(2):181–213.
- Nazar, R. y M. Janssen. 2010. Combining resources: taxonomy extraction from multiple dictionaries. En *Proceedings of LREC 2010 (The 8th edition of the Language Resources and Evaluation Conference)*, páginas 1055–1061, Valletta (Malta).
- Nazar, R., J. Vivaldi, y L. Wanner. En prensa. Automatic taxonomy extraction for specialized domains using distributional semantics. *Terminology: International Journal of Theoretical and Applied Issues in Specialized Communication*.
- Pustejovsky, J. 1995. *The Generative Lexicon*. MIT Press, Massachusetts.
- RAE. 2009. *Nueva gramática de la lengua española*. Espasa, Madrid.
- Renau, I. y A. Alonso. En preparación. Using Corpus Pattern Analysis for the Spanish Learner's Dictionary DAELE (Diccionario de aprendizaje del español como lengua extranjera). En *Corpus Linguistics 2011*, Birmingham.
- Sinclair, J. 1998. The lexical item. En E. Wiegand, editor, *Contrastive Lexical Semantics*. John Benjamins, Amsterdam, páginas 1–14.
- Wilks, Y., B. Slator, y L. Guthrie. 1996. *Electric Words. Dictionaries, Computers and Meanings*. MIT Press-Cambridge, Massachusetts-Cambridge.