

Número 27 / 2009 - 13 de outubro de 2009

Investigadores da UDC e da Uvigo colaboran neste singular proxecto


OS ORDENADORES TAMÉN PODERÁN LER EN GALEGO

I S.U. . SANTIAGO

Varios investigadores do Grupo COLE (Compiladores e Linguaxes), da Escola Superior de Enxeñaría Informática da Universidade de Vigo, dirixido polo catedrático Manuel Vilares Ferro, levan xa varios anos inmersos na investigación da recuperación de información.

Tanto é así, que Juan Otero Pombo, un dos investigadores, presentou recentemente a súa tese de doutoramento sobre este tema, baixo o título *Analisis léxico robusto*, na cal aborda o desenvolvemento e a avaliación de técnicas de corrección ortográfica e a súa aplicación en contornos de recuperación de información nos que os errores ortográficos están presentes. Trataríase de desenvolver un sistema que permita identificar correctamente as palabras con errores ortográficos que un usuario introduce nunha busca, por exemplo en Google ou na base de datos dunha biblioteca.

Tal como se recolle na tese de Juan Otero Pombo, hoxe en día hai unha "frenética e constante evolución da informática" que deu lugar ó



Funcións como as procura en internet simplificáranse cun software que lle permitise ó ordenador entende ro que queremos

e eficaz. Porén, "a maior parte dos contidos atopáse con escaso ou, simplemente, sen ningún tipo de estrutura". É aquí onde entran os sistemas de recuperación de informa-

poidan comunicarse directamente coas máquinas en lingua humana, e que estas sexan capaces de extraer coñecemento a través da lingua natural.

Por iso xorde o Procesamiento da Lingua Natural (PLN), subdisciplina da Intelixencia Artificial que persigue a representación e comprensión automática da lingua humana por medio da realización dunha análise léxica (recoñece unidades mínimas da lingua), sintáctica (recoñece unidades gramaticais formadas por varias unidades léxicas), semántica (captura o significado dunha frase) e pragmática (engádelle información ó significado da frase en función do contexto). Así e todo, na busca

de información, como actividade humana que é, sucede frecuentemente a "introdución de errores ortográficos ou de dixitación na consulta, o cal complica a tarefa de recuperación".

Por todo isto, o obxectivo é desenvolver e avaliar a tecnoloxía de base necesaria para o PLN, sobre todo no ámbito da análise léxica e da corrección ortográfica e a etiquetación. Así, tras estas investigacións, Juan Otero Pombo aportou coa súa tese un novo método de corrección ortográfica "máis eficiente e menos custoso que os que se viñeron aplicando ata o momento, xa que reduce ó mínimo posible a explotación do diccionario en busca da corrección máis adecuada en cada momento". Esta técnica integrouse despois no etiquetador morfosintáctico MiTagoo, desenvolvido polo grupo COLE da Universidade de Vigo e o LyS (Lengua y Sociedad de la Información) da Universidade da Coruña, que permite asignar automaticamente unha categoría léxica (sustantivo, verbo, ...) a cada palabra dun texto en español ou galego.

O resultado desta integración permite solucionar os tres problemas comúns no proceso de consultas nun sistema computacional de recuperación de información: a ambigüidade segmental (cando a identificación dos termos que forman unha consulta non resultan triviais), a ambigüidade morfosintácti-

ca (cando as palabras poden xogar distintos papeis segundo a frase na que aparezan) e a corrección ortográfica contextual (eliye entre as alternativas de corrección a que mellor encaixa coa consulta). O resultado dos experimentos, realizados nunha contor-

O OBXECTIVO É FACILITAR A INTERACCIÓN DE HUMANOS E COMPUTADORAS

na de recuperación de información con consultas degradadas, poñen de manifesto que "o emprego de técnicas de corrección ortográfica ten un impacto moi positivo sobre os sistemas de recuperación de información", fronte a outras propostas realizadas con anterioridade.

No proxecto quíxose dotar dun PLN a lingua galega, e para iso naceu o proxecto Victoria, con equipos franceses e españoles, nos cales se integraron Miguel Ángel Molinero (investigador do grupo LyS da Universidade da Coruña) e Elena Sánchez Trigo (investigadora do grupo COLE da Universidade de Vigo). Nunha primeira fase, os investigadores de Victoria concentráronse nos recursos necesarios para construir analizadores sintácticos para español e galego.

Actualmente, o proxecto xa construíu varios recursos que serán liberados baixo licenza LGPL-LR (Lesser General Public License for Linguistic Resources), entre os cales destacan regras de configuración idiomáticas e un léxico con información morfolóxica para a lingua galega. •

PRETÉNDESE DOTAR O NOSO IDIOMA DUN NOVO PROGRAMA INFORMÁTICO DE PROCESAMENTO DA LINGUAJE NATURAL

que se coñece como Sociedade da Información. Na súa investigación, Otero Pombo, que estivo seis anos recabando datos, asegura que actualmente xéranse e publicánsense numerosos datos en formato electrónico, que deben ser procesados e estruturados para facilitar o acceso rápido

ción, que permiten localizar aqueles documentos dunha colección que satisfan os requisitos dun usuario.

Polo tanto, tal como defende Otero Pombo, fai-se necesario contar con mecanismos eficaces que, desde o punto de vista computacional, permitan que as persoas

A Universidade da Coruña preparou para finais de mes a II Feira Europea do Emprego

A institución herculina, co apoio da Deputación da Coruña e da Xunta de Galicia organizou unha nova edición deste foro no cal se poden reunir e coñecer empresas e estudiantes. Página 13

Carlos Pajares, delegado do CERN en España, inaugurou o Máster de Física Nuclear da USC



O catedrático da universidade compostelá, delegado no noso país da Organización Europea para as Investigacións Nucleares, abriu cunha conferencia este novo ciclo formativo. Página 12

