


Novas aplicacións das humanidades dixitais: O etiquetador semántico multilingüe automático e sostible ESMAS-ES⁺

Celia Fernández Vasco / Elena Martín-Cancela  UNIVERSIDADE DA CORUÑA



CONTEXTO

-  **Panorama actual:** múltiples ferramentas de PLN orientadas ao inglés, pouco integradas e con acceso limitado ao significado.
-  **Necesidade:** recursos lexicográficos multilingües para o tratamento automático da semántica nos nomes.
-  **Marco conceptual:** semántica combinatoria + ontoloxías + PLN como resposta ás limitacións dos sistemas actuais.
-  **Proxectos previos:** continuidade de PORTLEX, que desenvolveu o Dicionario da valencia do nome en catro linguas.



OBXECTIVOS

- Diseñar un **prototipo de etiquetador semántico multilingüe** centrado en substantivos.
- Integrar **semántica léxica, ontoloxías e técnicas de PLN** baixo un enfoque **modular e automático**.
- Crear **paquetes léxicos computacionais reutilizables** e **corpus anotados** que sirvan como base para novas aplicacións lingüísticas.
- Desenvolver un sistema **adaptable, sostible e interoperable**, válido para español, galego, francés e alemán.



NOVIDADES E IMPACTO

- **Enfoque multilingüe e sostible:** etiquetador semántico-ontolóxico automático para español, galego, francés e alemán. Un método modular único para todas as linguas.
- **Uso de recursos abertos** (WordNet, TreeTagger, Freeling, etc.) e **criterios de interoperabilidade** para garantir a sostibilidade e a reutilización de datos nunha mellora continua.
- **Paquetes léxicos computacionais reutilizables:** os paquetes léxicos son interlingüísticos e serven como recurso adestrable e ampliable para futuros proxectos.
- **Gold Standard multilingüe para a avaliación:** Desenvolvemento dun corpus Gold Standard que permite medir cuantitativamente a eficacia do etiquetador e guiar sucesivas fases de optimización.

APROXIMACIÓN METODOLÓXICA

-  **Recursos de partida:** léxicos existentes, corpus anotados, WordNet, Freeling, TreeTagger...
-  **Modelo bottom-up:** elaboración dunha ontoloxía adaptada a cada lingua a partir de datos reais.
-  **Etiquetado automático:** identificación e asignación de etiquetas semánticas mediante regras e algoritmos.
-  **Validación:** revisión manual (Gold Standard) para axustar e mellorar o rendemento do prototipo.
-  **Circularidade:** os datos alimentan e melloran sucesivamente o modelo e a anotación.



RESULTADOS

1. Compilación de **3600 paquetes léxicos multilingües** ✓
2. Creación dun **corpus Gold Standard** paralelo ✓
3. Elaboración dunha **ontoloxía bottom-up**, que mellora a adecuación cultural e lingüística en cada lingua ✓
4. Elaboración do **prototipo de etiquetador**, con resultados moi prometedores na **asignación automática de categorías semántico-ontolóxicas** ✓

FUTURAS LIÑAS DE TRABAJO E RETOS

Tradución automática de paquetes: explotar TraduWord para xerar versións automáticas de paquetes en diferentes linguas, revisando e filtrando o *output* para maximizar a interoperabilidade.

Mellora da **desambiguación polisémica** e identificación das principais **diverxencias cuantitativas** (volume de anotación) e **cualitativas** (erros ontolóxicos) entre etiquetas manuais e automáticas.

Desenvolvemento dun motor automático para o etiquetado directo de textos, automatizando desde a lematización ata a anotación semántica completa.

Colaboración: desenvolvemento de interfaces gráficas para que a comunidade lexicográfica aporte validacións.