

Identificación automática de la temática de un texto



Paz Ferrero García de Jalón

paz.ferrero@uam.es

Universidad Autónoma de Madrid

Universidad Popular de Alcobendas

21-23 de noviembre de 2011

Índice

- Objetivos
- Material de estudio
 - Discursos Navideños del Rey
 - Corpus de referencia (nativos españoles)
 - Exámenes de nivel intermedio de D.E.L.E.
- Métodos de análisis
 - Analizador morfosintáctico FreeLing (lematizador)
 - Campos Semánticos del Plan Curricular del Instituto Cervantes
 - Latent Semantic Analysis
- Conclusiones

Objetivos

Identificación **automática** del contenido de un texto:

- Conocer y cuantificar el contenido de un texto sin leerlo.
- Reconocimiento de textos similares.
- Detección de textos anómalos o fuera de tema.

Material de estudio

- Discursos navideños del Rey
 - Estructura similar
 - Temática común
 - 36 discursos
- Corpus de referencia
 - Textos de nativos españoles con temática semejante a los 40 exámenes de DELE analizados
- Exámenes de D.E.L.E.
 - 40 redacciones sobre 3 temas propuestos en la prueba escrita

Métodos de Análisis

- Campos semánticos: *Glosario del PCIC* o “*Índice de nociones generales y nociones específicas*”.
- Latent Semantic Analysis.
- *Corpus* de referencia

Campos Semánticos del *PCIC*


- 7 Nociones generales, y subcampos:
Existenciales, cuantitativas, espaciales,
temporales, cualitativas, evaluativa y mentales
- 20 Nociones específicas y subcampos:
Personas, alimentación, educación, trabajo, ocio,
medios de comunicación, vivienda, comercio,
salud, viajes, economía, ciencia, política, arte,
pensamiento y naturaleza.

Campos semánticos del PCIC

- Cálculo de las frecuencias de aparición de lemas en un texto en función del uso de:
 - Stop List
 - Lemas repetidos
 - Ponderación de ciertos campos en función de los campos semánticos de otros lemas dentro de la frase como desambiguación semántica


Distribución de lemas del PCIC

Campos Semánticos (Glosario Cervantes: 8662 lemas)




Ponderación de campos semánticos

Campos Semánticos (reynavidad1992: 558 lemas)




Correlación de textos nativos y DELE



Campos Semánticos del PCIC

Análisis de 40 exámenes de DELE Intermedio




Análisis Semántico

- Latent Semantic Analysis
 - Estudio de la correlación entre textos atendiendo a la frecuencia de aparición de las palabras.
 - Preprocesado:
 - Filtrado de las palabras contenido (*stoplist*).
 - Utilización de funciones de ponderación y normalización.
 - Resultados:
 - Cuantificación y representación del contenido semántico.
 - Identificación de discursos anómalos.
 - Reconstrucción o filtrado de la semántica de los textos.

Análisis Semántico


- Latent Semantic Analysis

Matriz de correlación de los discursos navideños del Rey Juan Carlos I.




Análisis Semántico

- Latent Semantic Analysis: Discursos Navideños



LSA de los exámenes DELE Intermedio



Conclusiones

- Se han identificado textos automáticamente, sin leerlos.
- Se ha parametrizado el contenido semántico de un texto, comparativa e individualmente, mediante la identificación de vocablos en ***campos semánticos*** definidos por el *PCIC*.
- Se han empleado herramientas de ***estadística multivariante***, aplicándolas al ámbito de la lingüística y de la evaluación de una L2.
- Se obtiene valores para ***medir cuantitativamente*** el contenido esperado en un tipo de texto con una temática concreta.
- La identificación automática del contenido de un texto hoy es un paso adelante para la ***evaluación automática de textos***.

Identificación automática de la temática de un texto

¡Muchas gracias por su atención, 😊!



Paz Ferrero García de Jalón

paz.ferrero@uam.es

Universidad Autónoma de Madrid:

Departamento de Filología Inglesa

Universidad Popular de Alcobendas

21-23 de noviembre de 2011

