

LBD LOCAL: Un Sistema para la Recuperación de Documentos con Referencias Geográficas

Miguel R. Luaces, José R. Paramá, Oscar Pedreira, Diego Seco

Laboratorio de Bases de Datos
Universidade da Coruña
A Coruña, España



Organización


- Introducción
- Motivación
- Trabajo relacionado
- Arquitectura
- Estructura de indexación
- Tipos de consultas soportadas
- Demo
- Conclusiones y futuros desarrollos

Organización

- Introducción
- Motivación
- Trabajo relacionado
- Arquitectura
- Estructura de indexación
- Tipos de consultas soportadas
- Demo
- Conclusiones y futuros desarrollos

Introducción

- Dos campos de investigación muy activos:
 - Geographic Information Systems (GIS)
 - EIEL (<http://www.dicoruna.es/webeiel>)
 - Information Retrieval (IR)
 - Biblioteca Virtual Galega (<http://bvg.udc.es>)



Recuperar documentos relevantes temática y geográficamente respondiendo a consultas de la forma <tema, localización>

- Introducción
- **Motivación**
- Trabajo relacionado
- Arquitectura
- Estructura de indexación
- Tipos de consultas soportadas
- Demo
- Conclusiones y futuros desarrollos

Motivación

- Muchos documentos almacenados en bibliotecas digitales y bases de datos documentales incluyen referencias geográficas
 - Prensa, Web, IDEs, ...
 - “...las Jornadas de SIG Libre celebradas en Girona en marzo de 2007...”
- Pocas estructuras de indexación y algoritmos de recuperación explotan las referencias geográficas
- Las propuestas recientes no tienen en cuenta algunas particularidades específicas del espacio geográfico
 - Naturaleza jerárquica del espacio geográfico
 - Relaciones topológicas entre los objetos

Organización

- Introducción
- Motivación
- Trabajo relacionado
- Arquitectura
- Estructura de indexación
- Tipos de consultas soportadas
- Demo
- Conclusiones y futuros desarrollos


Trabajo relacionado

- Indexación de texto: Índice Invertido
 - Ignoran completamente las referencias geográficas
- Indexación espacial: R-Tree
 - No tienen en cuenta la jerarquía del espacio
- Propuestas para combinarlos (proyecto SPIRIT):
 - *Text-First* (primero filtrado textual y luego espacial)
 - *Geo-First* (primero filtrado espacial y luego textual)
 - No tienen en cuenta las relaciones entre los objetos geográficos que están indexando
- Descripción del espacio geográfico: Ontología
 - Empleadas en GIR para realizar *query expansion*, elaboración de rankings de relevancia y anotación de recursos web
 - Ningún intento de combinarlas con otros tipos de índices para obtener una estructura híbrida

Organización


- Introducción
- Motivación
- Trabajo relacionado
- Arquitectura
- Estructura de indexación
- Tipos de consultas soportadas
- Demo
- Conclusiones y futuros desarrollos

Arquitectura




- Abstracción de documentos
 - Documentos diferentes:
 - Diferentes formatos de archivo (texto plano, XML, etc.)
 - Diferentes esquemas de contenido
 - Representación abstracta de esos documentos:
 - *Documento* representado como agregado de *Campos*
 - Idea similar en el motor de búsqueda textual *Lucene*
 - Posibilidad de indexación espacial

Arquitectura




Arquitectura

- Construcción de la estructura de indexación
 - Indexación textual
 - *Lucene*
 - Indexación espacial
 - Obtención de posibles topónimos
 - Análisis Lingüístico: *Named-Entity Recognition*
 - Geo-referenciación de esos topónimos
 - *Servicio de Ontología del Espacio-Geográfico*



Arquitectura



Organización

- Introducción
- Motivación
- Trabajo relacionado
- Arquitectura
- Estructura de indexación
- Tipos de consultas soportadas
- Demo
- Conclusiones y futuros desarrollos


Estructura de indexación

Índice Invertido

...	...
hotel	1,3,7,8,12,...
mar	3,5,6,9,10,...
...	...

Tabla Hash de Nombres de Lugar

...	...
España	●
Alemania	●
...	...



Estructura de indexación

- Toma como base una ontología
- Árbol compuesto por nodos que representan topónimos interconectados por medio de relaciones de contenido
 - Si la lista de nodos hijo es muy larga se emplea un R-Tree
- Estructuras auxiliares:
 - Tabla hash de nombre de lugar a posición en el árbol
 - Índice Invertido tradicional
- Ventajas:
 - Procesado eficiente tanto de consultas textuales como espaciales
 - Soporte para consultas combinadas
 - Actualizaciones y optimizaciones independientes en cada índice
- Inconvenientes:
 - Árbol posiblemente desbalanceado
 - Estructura estática

Organización

- Introducción
- Motivación
- Trabajo relacionado
- Arquitectura
- Estructura de indexación
- **Tipos de consultas soportadas**
- Demo
- Conclusiones y futuros desarrollos

Tipos de consultas soportadas

- Consultas puramente textuales
 - “recuperar todos los documentos donde aparezcan las palabras hotel y mar”
 - ¿Cómo las resolvemos?
 - Índice textual
- Consultas puramente espaciales
 - “recuperar todos los documentos que se refieran a la siguiente área geográfica”
 - ¿Cómo las resolvemos?
 - Descenso en la estructura + refinado del resultado
 - El mismo algoritmo empleado con índices espaciales

Tipos de consultas soportadas


- Consultas textuales con nombres de lugar
 - “recuperar todos los documentos con la palabra hotel referidos a España”
 - ¿Cómo las resolvemos?
 - Ejemplo
 - Ahorro de tiempo evitando parte del recorrido en el árbol

Tipos de consultas soportadas

Inverted Index

...	...
hotel	1,3,7,8,12,...
sea	3,5,6,9,10,...
...	...

Index Structure



Place Name Hash Table

...	...
Spain	●
Germany	
...	...

Text Result	1,3,7,8,12,...
Spatial Result	2,3,5,7,12,14,...
Query Result	3,7,12,...

Tipos de consultas soportadas


- Consultas textuales sobre un área geográfica
 - *“recuperar todos los documentos con la palabra hotel que se refieren a la siguiente área geográfica”*
 - ¿Cómo las resolvemos?
 - Ejemplo

Tipos de consultas soportadas

Inverted Index

...	...
hotel	1,3,7,8,12,...
sea	3,5,6,9,10,...
...	...

Index Structure



Query Window



DocIds	12,14,...
Text Result	1,3,7,8,12,...
Spatial Result	12,14,...
Query Result	12,...

Tipos de consultas soportadas

- Otra ventaja: *EXPANSIÓN DE CONSULTAS*
 - “recuperar todos los documentos referidos a *España*”
 - ¿Cómo las resolvemos?
 - El Servicio de *Evaluación de Consultas* descubrirá que *España* es una referencia geográfica
 - La Tabla Hash de Nombres de Lugar localizará rápidamente el nodo interno que representa a *España*
 - Todos los documentos asociados con ese nodo forman parte del resultado
 - Todos los documentos asociados con el subárbol forman parte del resultado
 - El resultado contiene, además de aquellos documentos que incluyen el término *España*, todos los documentos que contienen el nombre de una división administrativa incluida en *España*

Organización

- Introducción
- Motivación
- Trabajo relacionado
- Arquitectura
- Estructura de indexación
- Tipos de consultas soportadas
- Demo
- Conclusiones y futuros desarrollos

Demo

LBD LOCAL - Mozilla Firefox

Archivo Editar Ver Historial Marcadores Herramientas Ayuda

http://localhost:8080/gir_ft/#

Local Search

Query Results

Textual

sunny place

Search Clear

Spatial

Name Tree

First Level Europe

Second Level Italian Republic

Third Level -


Mapa Satélite Híbrido Relieve

Milan

FT944-10650

Map showing locations in Europe, specifically Italy and surrounding areas. Milan is marked with a red pin. Other pins are located in Rome, Naples, and Sicily. A zoomed-in inset map shows the location of Italy relative to neighboring countries.

Terminado



Organización

- Introducción
- Motivación
- Trabajo relacionado
- Arquitectura
- Estructura de indexación
- Tipos de consultas soportadas
- Demo
- Conclusiones y futuros desarrollos

Conclusiones y futuros desarrollos

- Conclusiones:
 - Arquitectura de sistema para recuperación de información geográfica
 - Estructura de indexación formada por un índice textual, un índice espacial y una ontología
 - Resolución de nuevos tipos de consultas

Conclusiones y futuros desarrollos

- Trabajo futuro:
 - OpenLayers + WMS
 - Evaluación del prototipo
 - Desambiguación de topónimos
 - Implementación de algoritmos de ranking
 - Inclusión de otros tipos de relaciones (ej. Adyacencia)
 - Liberar el código

GRACIAS POR SU ATENCIÓN
