

# Searching over Public Administration Legal Documents using Ontologies

Diego Berrueta

Jose E. Labra

Luis Polo

CTIC Foundation, R & D Department  
University of Oviedo, Spain





- Features of public administration documents
  - Lots of documents are published everyday
  - Concrete domains: Law, administration, etc.
- Poor effectiveness of syntactic approaches
- Our approach:
  - We applied Semantic web tools and ontologies in this domain
  - A search tool with ontology based query expansion
- General aim:
  - Bridge the gap between public administration and citizens



- BOPA (**B**oletín **O**ficial del **P**rincipado de **A**sturias)
  - Official Journal of the Principality of Asturias, Spain
  - Asturias:
    - Northern region of Spain
    - Approx. 1,1 million people





- The BOPA contains every announcement related with Asturias public administration
  - Laws, resolutions, public auctions, etc.
    - General interest to every citizen
    - Specialized jargon
- The previous system:
  - PDF and plain HTML
  - Simple syntactic Search tool
    - Chronological and by title
- Some statistics:
  - 14.314 articles in 23.100 pages (2005)

Principado de Asturias  
BOLETIN OFICIAL  
DEL PRINCIPADO DE ASTURIAS

Dirección: Oviedo, España, 33  
ISSN: 1137-9322 Depósito Legal: B-1088-05  
http://www.bopa.asturias.es

Martes, 1 de agosto de 2006

Nº 177

### SUMARIO

	Page	Page
<b>I. Principado de Asturias</b>		
<b>*AUTORIDADES Y PRESIDENCIA</b>		
<b>CONSEJO GENERAL DEL PRINCIPADO DE ASTURIAS</b>		
<b>RESOLUCIÓN GENERAL</b>		
Resolución de 21 de julio de 2006, de la Presidencia General, por la que se nombra como Secretaría General a don Juan María Fernández Miguel...	15354	
<b>*OTRAS DEBERACIONES</b>		
<b>COMISIÓN DE EDUCACIÓN Y CIOBENA</b>		
Resolución de 10 de julio de 2006, de la Comisión de Educación y Ciencia, por la que se remite el segundo ciclo de las convocatorias públicas de contratación de ayudas a empresas para la ejecución de proyectos de investigación durante el período 2005-2007	15354	
<b>COMISIÓN DE CULTURA, COMUNICACIÓN SOCIAL Y TURISMO</b>		
Resolución de 4 de julio de 2006, de la Comisión de Cultura, Comunicación Social y Turismo, por la que se suspenden y desvirtúan/desvirtuaciones a publicación de la Ley 2. Normativa sobre el estatuto y del artículo 2006	15357	
<b>COMISIÓN DE INDUSTRIA Y ENERGÍA</b>		
Resolución de 3 de julio de 2006, del Servicio Público de Empleo, de concesión de subvenciones a la línea de personal de apoyo a las Comarcas Especiales de Empleo	15371	
<b>*ANEXOS</b>		
<b>COMISIÓN DE EDUCACIÓN Y CIOBENA</b>		
Información pública de concursos, por procedimiento abierto y sistema de ofertas, para la contratación de los servicios de limpieza en varios centros dependientes de esta Comisión	15372	
<b>COMISIÓN DE INDUSTRIA Y ENERGÍA</b>		
<b>COMISIÓN DE INDUSTRIA Y ENERGÍA</b>		
Resolución de la Comisión del organismo autónomo "Establecimiento Asturiano de para desarrollo de Asturias" por la que se anuncia la convocatoria, por el procedimiento abierto y sistema de concurso, de la construcción completa de la edificación del proyecto y la ejecución de las obras de reforma y ampliación de la Residencia "Oviedo" (proyecto 14/05), contractual completa de la edificación del proyecto y la ejecución de las obras de construcción de la Residencia "Macedón" (proyecto 15/06) y la contractual completa de la edificación del proyecto y la ejecución de las obras de construcción Residencia "Polo de Siero" (proyecto 16/06)	15373	
<b>COMISIÓN DE INDUSTRIA Y ENERGÍA</b>		
Información pública por la que se anuncia licitación por oferta, mediante el sistema de concurso, procedimiento abierto y contratación de urgencia	15375	
<b>COMISIÓN DE INDUSTRIA Y ENERGÍA</b>		
<b>COMISIÓN DE INDUSTRIA Y ENERGÍA</b>		
Información pública de las subvenciones correspondientes al programa de la Ley 1/2005, por el que se regula el régimen general de contratación de subvenciones	15376	
Modificación de Resolución de 20 de mayo de 2006, del Instituto de Desarrollo Económico del Principado de Asturias, por la que se propone la subvención técnica a María y Esteban García Ferrás (resolución de C/CM-02-039)	15376	
Modificación de la Resolución del Instituto de Desarrollo Económico del Principado de Asturias de 1 de febrero de 2006, por la que se anuncia la subvención técnica a María y Esteban García Ferrás (resolución de C/CM-02-039)	15377	
<b>III. Administración del Estado</b>		15379
<b>IV. Administración Local</b>		15430



# Motivation

## Some restrictions

- We could not interfere with the established process
  - We were allowed to work only with the generated data
- Adding tags to each document manually = not practical
  - Not enough personal and lots of documents
  - Error prone



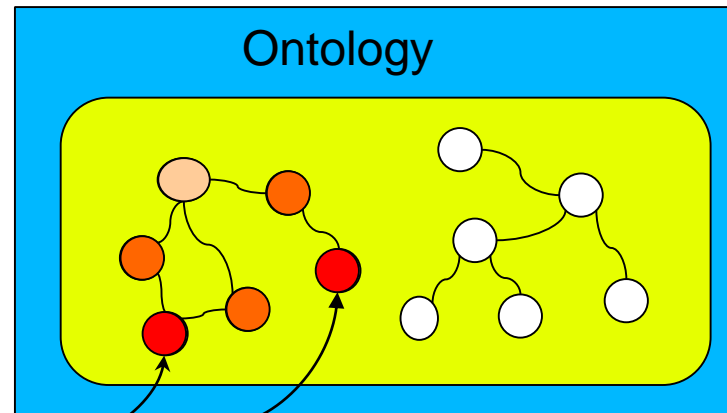
- We defined ontologies for our problem domain
  - A team of 3 domain experts was employed
- Ontologies were developed in a modular way
  - One upper legal & administrative Ontology
  - Several domain ontologies
    - We defined micro-ontologies for several contexts
    - Micro-ontologies import the upper ontology
    - Examples: [public-employment](#), [subventions](#), etc.



- Each concept has a synonym set (synset) associated
  - In practice, we use 2 types of synsets:
    - Input synset: Terms used in common language
      - Allow to find a concept from a query term
    - Output synset: Legal and administrative terms
      - Allow to find a document that contains a concept
  - Example:
    - Concept: **Holiday**
    - Input synsets: "holiday", "vacation", "break"
    - Output synsets: "holiday" "vacation"



# Ontology Based Search Search Process overview




2. Spread activation


3. Obtain list of words and weights

Word	Weight
● janitor	1.0
● holiday	1.0
● vacation	1.0
● staff	0.5
● collective agreement	0.5
● work day	0.5
● legal contract	0.75

4. Apply enriched query



Results



BOPA

Terms: *holiday*      *janitor*

Query: "*holidays of janitors*"







# Ontology Based Search

## Step 1. Match terms to concepts

- Query sentence is parsed to obtain terms
  - Remove non-content words like “the”, “but”, etc.
  - Remove suffixes of words
- Terms are matched against input synsets of ontology concepts
- A context (micro-ontology) is determined for the query
  - If several concepts belong to different contexts, we take the common one
  - In case of several choices, the user can select one
- Search can be restricted to that context



# Ontology Based Search

## Step 2. Spreading activation

- We use the spreading activation algorithm
  - It returns a weighted list of related concepts

$w_{ij}$  = weight of relation between nodes  $i$  and  $j$   
 $\Delta$  = set of activation nodes  
           Initialized to initial query concepts  
           Implemented as a queue ordered by activation value  
 $\Theta$  = set of output concepts  
 $N_{\min}$  = Minimum activation level

```

while  $\Delta \neq \emptyset$  and  $N_k > N_{\min}$ 
    extract a node  $n_k$  from  $\Delta$ 
    add  $n_k$  to  $\Theta$ 
    For each node  $n_i$  such that  $w_{ki} > 0$ 
         $N_i = N_i + w_{ki} N_k$ 
        Add  $n_i$  to  $\Delta$ 
endWhile
return  $\Theta$ 
    
```

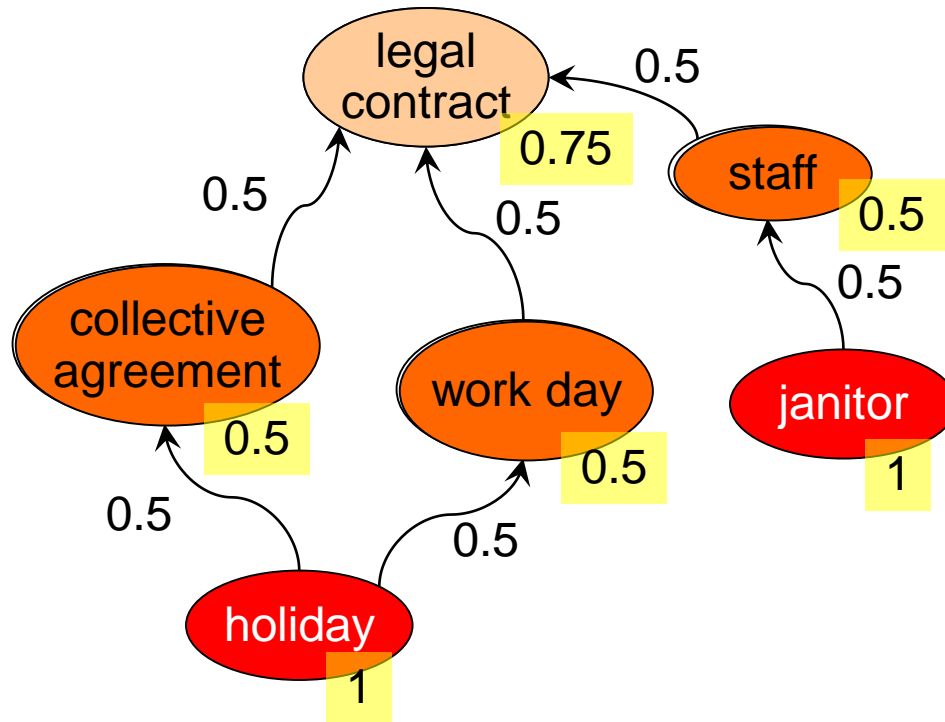
Spreading activation algorithm (*simplified*)



# Ontology Based Search

## Step 2. Spreading Activation

- Example of Spread activation



Output concepts

Concept	Weight
janitor	1.0
holiday	1.0
staff	0.5
collective agreement	0.5
work day	0.5
legal contract	0.75



# Ontology Based Search

## Step 3. Obtain words from concepts

- For each concept, we obtain the representative words
  - The words are obtained from the output synsets

Output concepts

Word list

	<b>Concept</b>	<b>Weight</b>
●	janitor	1.0
●	holiday	1.0
●	staff	0.5
●	collective agreement	0.5
●	work day	0.5
●	legal contract	0.75

	<b>Word</b>	<b>Weight</b>
●	janitor	1.0
●	holiday	1.0
●	vacation	1.0
●	staff	0.5
●	collective agreement	0.5
●	work day	0.5
●	legal contract	0.75





# Ontology Based Search

## Step 4. Apply syntactic search

- Syntactic Search

- We used Apache Lucene search engine
- Search expression:

```
"janitor"^1 "holiday"^1 "vacation"^1 "staff"^.5  
("collective agreement"~1)^.5 ("work day"~1)^.5  
("legal contract"~1)^.75
```

- Search results are ordered according to relevance level



# Other Services Syntactic search

Buscador del BOPA (Boletín Oficial del Principado de Asturias) - Mozilla Firefox

Archivo Editar Ver Ir Marcadores Herramientas Ayuda

https://80.24.255.48:4443/bopa/action/enhancedSyntacticSearch?query=vacaciones+del+portero&label.button.search=Buscar

**PRINCAST.ES**  
GOBIERNO DEL PRINCIPADO DE ASTURIAS

Inicio: Buscador Sintáctico miércoles, 30 / agosto / 2006

labra Salir

Inicio Boletín de hoy Acceso por fecha Buscador Lista de conceptos Lista de contextos

## Buscador

Término(s) de búsqueda:   [Ayuda sobre la búsqueda](#) [Cambiar al formulario de búsqueda avanzada](#)

Búsqueda por términos  Búsqueda semántica en el contexto «Particular empleado de fincas»

Términos buscados: vacaciones del portero

Mostrando 10 artículos encontrados ( tiempo de búsqueda: 0,015 seg.)

### Artículos

	Relevancia	Título	Fecha
1	<input type="text"/>	<a href="#">RESOLUCION de 31 de agosto de 2005, de la Consejería de Industria y Empleo, por la que se ordena la inscripción del Convenio colectivo para los Almacenes de Material Eléctrico (ASOMATEL), en el Registro de Convenios Colectivos de la Dirección General de Trabajo.</a>	24/09/05
2	<input type="text"/>	<a href="#">RESOLUCION de 2 de marzo de 2005, de la Consejería de Industria y Empleo, por la que se ordena la inscripción del Convenio colectivo del sector de Comercio de Equipos, Recambios, Componentes y Accesorios del Automóvil, en el Registro de Convenios Colectivos de la Dirección General de Trabajo.</a>	26/03/05
3	<input type="text"/>	<a href="#">RESOLUCION de 3 de agosto de 2005, de la Consejería de Industria y Empleo, por la que se ordena la inscripción del Convenio Colectivo del sector Grupo Deportes, en el Registro de Convenios Colectivos de la Dirección General de Trabajo.</a>	31/08/05

### Conceptos reconocidos

- Vacaciones
- Portero

### Términos relacionados

- relacion



Buscador del BOPA (Boletín Oficial del Principado de Asturias) - Mozilla Firefox

Archivo Editar Ver Ir Marcadores Herramientas Ayuda

https://80.24.255.48:4443/bopa/action/semanticSearch?contextUri=http%3A%2F%2Fwebsemantica.fundacionctic.org%2Fontologia.RSS GO

**PRINCAST.ES**  
GOBIERNO DEL PRINCIPADO DE ASTURIAS  
Inicio: Buscador Sintáctico: Buscador semántico miércoles, 30 / agosto / 2006

labra Salir

Inicio Boletín de hoy Acceso por fecha Buscador Lista de conceptos Lista de contextos

## Buscador

Término(s) de búsqueda:   [Ayuda sobre la búsqueda](#) [Cambiar al formulario de búsqueda avanzada](#)

Búsqueda por términos  Búsqueda semántica en el contexto «Particular empleado de fincas»

Mostrando 100 primeros resultados (encontrados 1.226 artículos en 0,721 seg.)

### Artículos

	Relevancia	Título	Fecha
1	<input type="text"/>	<a href="#">RESOLUCION de 26 de abril de 2005, de la Consejería de Industria y Empleo, por la que se ordena la inscripción del Convenio colectivo del sector de Empleados de Fincas Urbanas, en el Registro de Convenios Colectivos de la Dirección General de Trabajo.</a>	21/05/05
2	<input type="text"/>	<a href="#">RESOLUCION de 26 de agosto de 2005, de la Consejería de Industria y Empleo, por la que se ordena la inscripción del Convenio colectivo del sector de Empleados de Fincas Urbanas, en el Registro de Convenios Colectivos de la Dirección General de Trabajo.</a>	24/09/05
3	<input type="text"/>	<a href="#">RESOLUCION de 8 de abril de 2005, de la Consejería de Industria y Empleo, por la que se ordena la inscripción del Convenio para el Personal Laboral del Ayuntamiento de Langreo, en el Registro de Convenios Colectivos de la Dirección General de Trabajo.</a>	07/05/05
4	<input type="text"/>	<a href="#">RESOLUCION de 11 de julio de 2005, de la Consejería de Industria y Empleo, por la que se ordena la inscripción del Convenio para el Personal Laboral del Ayuntamiento de Mieres en el Registro de Convenios Colectivos de la Dirección General de Trabajo.</a>	27/08/05
		<a href="#">DECRETO 99/2005 de 23 de septiembre por el que se regula el régimen jurídico y retributivo del</a>	

#### Conceptos reconocidos

- [Vacaciones](#)
- [Portero](#)

#### Conceptos consultados

- [Vacaciones](#)
- [Portero](#)
- [Contrato laboral](#)



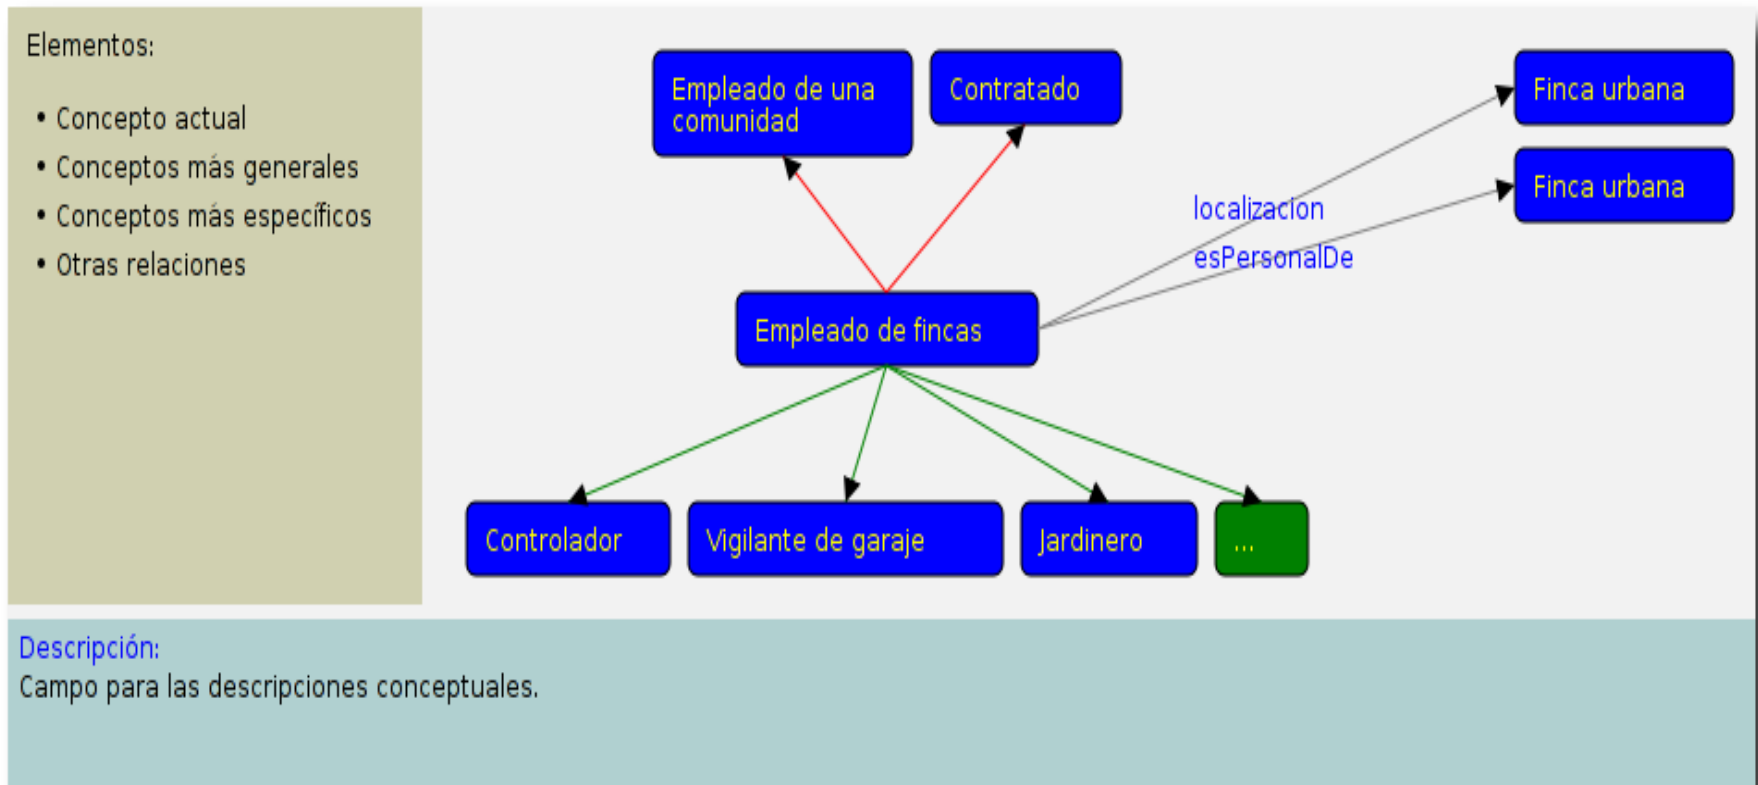
# Other Services

## Alert subscription service

- Query subscription
  - Users can subscribe to a query
  - A notification can be send when new results for that query appear
  - Email and SMS alerts can be send to registered users



- User interface developed in SVG
- Navigational representation of the Ontology concepts





**PRINCAST.ES**  
GOBIERNO DEL PRINCIPADO DE ASTURIAS

Inicio: [Buscador Sintáctico](#): [Buscador semántico](#) sábado, 26 / agosto / 2006

Inicio | Boletín de hoy | Acceso por fecha | **Buscador** | Lista de conceptos | Lista de contextos

### Explicación de los resultados de la búsqueda semántica

#### Conceptos reconocidos

Relevancia	Concepto	Explicación	Explicación en SVG
	<a href="#">Portero</a>	=> <a href="#">Portero</a>	
	<a href="#">Vacaciones</a>	=> <a href="#">Vacaciones</a>	
	<a href="#">Contrato laboral</a>	=> <a href="#">Vacaciones</a> => <a href="#">Contrato laboral</a>	
	<a href="#">Elementos de un contrato laboral</a>	=> <a href="#">Vacaciones</a> => <a href="#">Elementos de un contrato laboral</a>	
	<a href="#">Convenio laboral</a>	=> <a href="#">Vacaciones</a> => <a href="#">Elementos de un contrato laboral</a> => <a href="#">Convenio laboral</a>	
	<a href="#">Regulación empleado de fincas</a>	=> <a href="#">Vacaciones</a> => <a href="#">Elementos de un contrato laboral</a> => <a href="#">Regulación empleado de fincas</a>	
	<a href="#">Empleado de fincas</a>	=> <a href="#">Portero</a> => <a href="#">Empleado de fincas</a>	
	<a href="#">Contratado</a>	=> <a href="#">Portero</a> => <a href="#">Empleado de fincas</a> => <a href="#">Contratado</a>	
	<a href="#">Empleado de una comunidad</a>	=> <a href="#">Portero</a> => <a href="#">Empleado de fincas</a> => <a href="#">Empleado de una comunidad</a>	
	<a href="#">Jornada laboral</a>	=> <a href="#">Vacaciones</a> => <a href="#">Elementos de un contrato laboral</a> => <a href="#">Jornada laboral</a>	
	<a href="#">Trabajo de mantenimiento</a>	=> <a href="#">Portero</a> => <a href="#">Trabajo de mantenimiento</a>	
	<a href="#">Finca urbana</a>	=> <a href="#">Portero</a> => <a href="#">Empleado de fincas</a> => <a href="#">Finca urbana</a>	
	<a href="#">Limpiador</a>	=> <a href="#">Portero</a> => <a href="#">Empleado de fincas</a> => <a href="#">Limpiador</a>	
	<a href="#">Conserje</a>	=> <a href="#">Portero</a> => <a href="#">Empleado de fincas</a> => <a href="#">Conserje</a>	
	<a href="#">Jardinero</a>	=> <a href="#">Portero</a> => <a href="#">Empleado de fincas</a> => <a href="#">Jardinero</a>	



# System Development Architecture and Methodology

- J2EE application
  - Data access tier
    - XML Native Database: XIndice
    - Relational database
    - Syntactical indexes managed by Lucene
    - Original web server where BOPA is still published
  - Business tier
    - Several vertical subsystems (low coupling)
      - Search engines, syntactical analysis, ontology processing, etc.
    - Functionality exported through web services
  - Main User interface developed with the Struts framework
- Development methodology
  - We used some agile development techniques
    - Pair programming



# System Development

## Recovering information from HTML

- A web crawler fetches HTML pages
  - The pages are not valid HTML
- JTidy transforms bad formed HTML to well formed XHTML
- A chain of XSLT transformations allows to extract information in XML format
  - We use a custom XML vocabulary
- Static HTML data is completed with database data



# System Development Application integration

- Interoperability has been a design goal
- All the functionality can be accessed by web services
- 5 clients have been implemented
  - Standard Web application front end
  - VoiceXML interface
  - Desktop .Net client
  - Desktop Python client
  - Java client using SWT libraries for Eclipse
- We export a RSS channel which is updated daily with the contents of new bulletins
- Bulletin contents are exported in HTML, PDF and RDF



# System Development

## Evaluation of search results

- At this moment, we are logging user activity and we collect different statistics
  - How many times the first result is selected, etc....
- Developed framework for testing quality of results
  - Difficulties to define good search results
  - We apply it mainly for regression tests
- We are planning to do medium scale tests with real users in short term



# Conclusions and Future work

- Practical application using a knowledge based approach
  - The prototype has been adopted by the Public Administration department
    - It will be part of a production environment
- Future work
  - Extend the search to the whole public administration site
  - Practical evaluation of the approach
    - Usability, search results, etc.
  - Extend Context-Theory
    - Allow more flexibility in context definition
    - Relationship between contexts and spread-activated nodes
    - Allow users feedback (tags)
  - Ontology development and reusability
    - Incorporate other ontologies (DOLCE, SUMO, etc.)
    - Develop a general legal and administrative ontology
  - Digitization project of past documents
    - BOPA started to be published before 1900



**The end**