

---

# **Soporte de vocabularios controlados y autoridades en repositorios digitales**

Autor: de Albuquerque, Pablo César

Directora: Dra. De Giusti, Marisa Raquel

Asesor técnico: Lic. Lira, Ariel Jorge

---

# Objetivos

- Diseñar e implementar un sistema de gestión de autoridades y vocabularios controlados para repositorios digitales.

## Objetivos secundarios

- Permitir la reutilización de vocabularios controlados
- Implementar un sistema genérico para gestión de vocabularios controlados en el ámbito del repositorio SEDICI
- Migrar sistema de autoridades en SEDICI
- Implementar un conector para DSpace que se comunique con el nuevo sistema.



# Repositorio institucional

Infraestructura web cuya finalidad es:

- Almacenar, organizar, preservar y publicar la producción digital generada en una institución
- Describir a través de **metadatos** los recursos almacenados
- Interoperar con otros repositorios similares.

El origen de la información que describa al recurso depende del metadato

---

## Vocabularios controlados en repositorios

Conjunto limitado de términos y reglas que forman parte de una estructura

- Mejora la búsqueda y descubrimiento de contenidos.
- Asisten a la usuarios:
  - búsqueda específicas de contenido
  - navegación de un sitio
- Asocian diversos sinónimos en un término controlado

---

# SEDICI

Repositorio institucional central de la Universidad Nacional de La Plata

- Aloja más de 64000 recursos
- Desarrollado sobre DSpace
- Gestiona autoridades externas en CelsiusDL





# Autoridades

Vocabulario controlado constituido por:

- Un registro
  - información asociada con una entidad
- Una clave
  - identificador único
- Variantes
  - variaciones sintácticas de un registro

René Favaloro, se identifica con la URI

[http://catalogo.bn.gov.ar/F/?func=direct&doc\\_number=000036235&local\\_base=BN\\_A10](http://catalogo.bn.gov.ar/F/?func=direct&doc_number=000036235&local_base=BN_A10)

- Favaloro, René, 1923-2000
- Favaloro, René Gerónimo, 1923-2000
- Favaloro, René G. (René Gerónimo), 1923-2000

---

# Control de autoridades

La práctica de mantener un catálogo autoridades

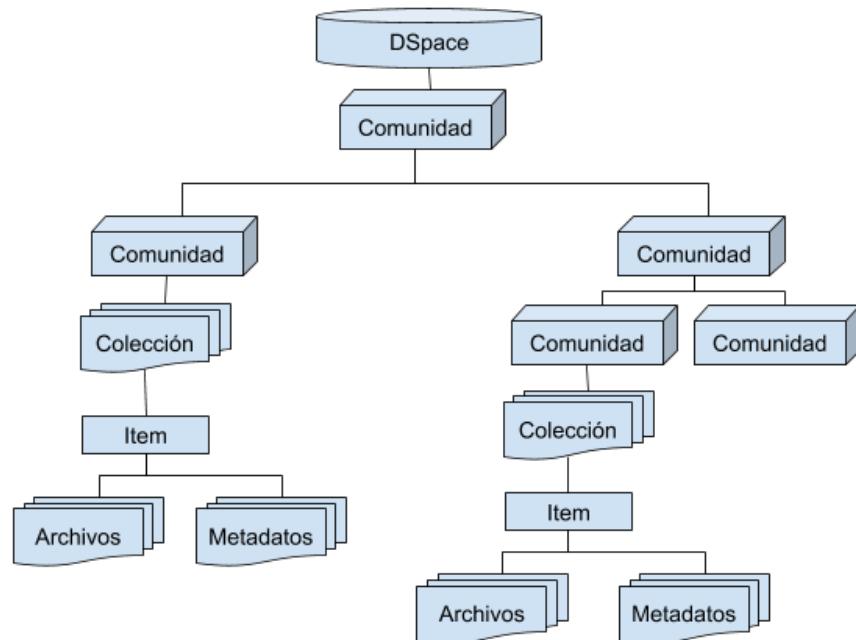
Este proceso tiene como objetivo:

- Probar que dos valores son idénticos
- Ayudar a completar metadatos con valores correctos.
- Mejorar la calidad de los metadatos
- Mejorar la interoperabilidad
- Reducir los tiempos de carga de metadatos

---

# Modelo de datos de DSpace

Los repositorios basados en DSpace poseen una o más comunidades de nivel base que se organizan jerárquicamente en subcomunidades.



---

# Uso de autoridades en DSpace

3 formas de controlar los valores

- value-pairs
- vocabularios controlados
- módulo de autoridades



## DSpace - Módulo de autoridades

Utiliza una arquitectura de plug-in

- Afecta todas las fases de la gestión de metadatos
- Aplicarse a cualquier metadato.

CelsisusDL módulo de autoridades que usaba SEDICI

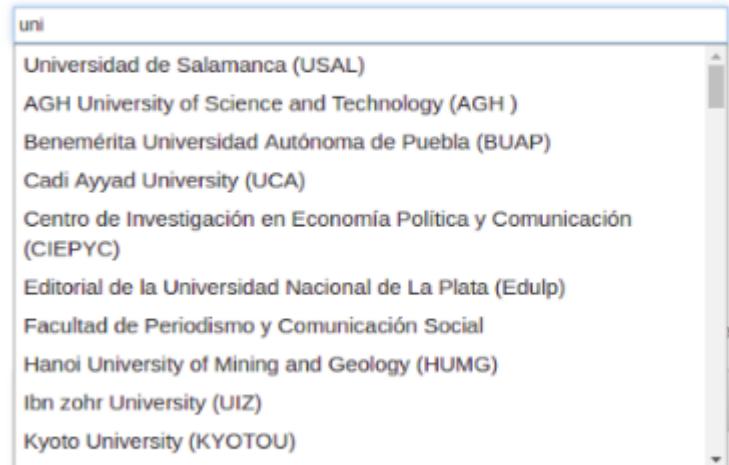
El módulo de autoridades fue diseñado para controlar dos aspectos básicos llamados **Choice Management** y **Authority Control**.

# Módulo de autoridades - Choice Management

## Choice Management

Mecanismo que permite seleccionar los posibles valores de un metadato provenientes de una base de autoridades, a partir de un valor de consulta.

**Autor Institucional:**  
Institución creadora del contenido intelectual de la obra



The screenshot shows a dropdown menu titled "Autor Institucional" with the subtitle "Institución creadora del contenido intelectual de la obra". A search bar at the top contains the text "uni". Below the search bar is a list of institutions, each preceded by a small blue "Add" button. The institutions listed are: Universidad de Salamanca (USAL), AGH University of Science and Technology (AGH ), Benemérita Universidad Autónoma de Puebla (BUAP), Cadi Ayyad University (UCA), Centro de Investigación en Economía Política y Comunicación (CIEPYC), Editorial de la Universidad Nacional de La Plata (Edulp), Facultad de Periodismo y Comunicación Social, Hanoi University of Mining and Geology (HUMG), Ibn zohr University (UIZ), and Kyoto University (KYOTOU). The menu has a light gray background and a white list area.

- uni
- Universidad de Salamanca (USAL)
- AGH University of Science and Technology (AGH )
- Benemérita Universidad Autónoma de Puebla (BUAP)
- Cadi Ayyad University (UCA)
- Centro de Investigación en Economía Política y Comunicación (CIEPYC)
- Editorial de la Universidad Nacional de La Plata (Edulp)
- Facultad de Periodismo y Comunicación Social
- Hanoi University of Mining and Geology (HUMG)
- Ibn zohr University (UIZ)
- Kyoto University (KYOTOU)

---

# Módulo de autoridades - Authority Control

## Authority Control

Este mecanismo trabaja junto con el módulo Choice Management identificando una autoridad que contiene un valor elegido.

- confidence
- authority

text_value	authority	Confidence
Universidad Nacional de La Plata (UNLP)	<a href="http://ejemplo/auth/node/86555">http://ejemplo/auth/node/86555</a>	600
Cañuelo, Matías F.	<a href="http://ejemplo/auth/node/204702">http://ejemplo/auth/node/204702</a>	600
Attribution 4.0 International (BY 4.0)	<a href="http://creativecommons.org/licenses/by/4.0/">http://creativecommons.org/licenses/by/4.0/</a>	600
UNLP	<a href="http://ejemplo/auth/node/86555">http://ejemplo/auth/node/86555</a>	500
Cañuelo, Matías G.		-1



## Etapas de la solución

1. Relevar funcionamiento de CelsiusDL
2. Analizar y elegir herramientas de gestión de VC
3. Desarrollar nuevo módulo de gestión de autoridades
4. Normalizar entidades en CelsiusDL y exportarlas.
5. Importar entidades normalizadas en nuevo sistema
6. Desarrollar conector en SEDICI
7. Actualizar referencias a autoridades en SEDICI

---

# Etapa 1 - Relevar estado de CelsiusDL

Autoridades gestionados en CelsiusDL.

- Desarrollada en Java en 2003
- Gestiona personas, instituciones, tesauros y sistemas de clasificación.

Tabla	Entidad representada
<i>jerarquias termino</i>	Instituciones de Argentina Grado a alcanzar
<i>tesaruro termino</i>	Tesoro de UNESCO Descriptores SeDiCI Materias Tesoro de Eurovoc Tesoro DeCS

---

# **Etapa 1 - Relevar estado de CelsiusDL**

## **Problemas de la solución actual**

- Software antiguo, muy difícil de actualizar.
- Falta de mantenimiento y actualizaciones
- Problemas de diseño
- Redundancia de datos.
- Duplicación de información
- UI carece de chequeos de validez
- Problemas de integridad de datos
- Gran porcentaje de información almacenada que no es utilizada
- Ausencia de roles y permisos

# Etapa 1 - Relevar estado de CelsiusDL

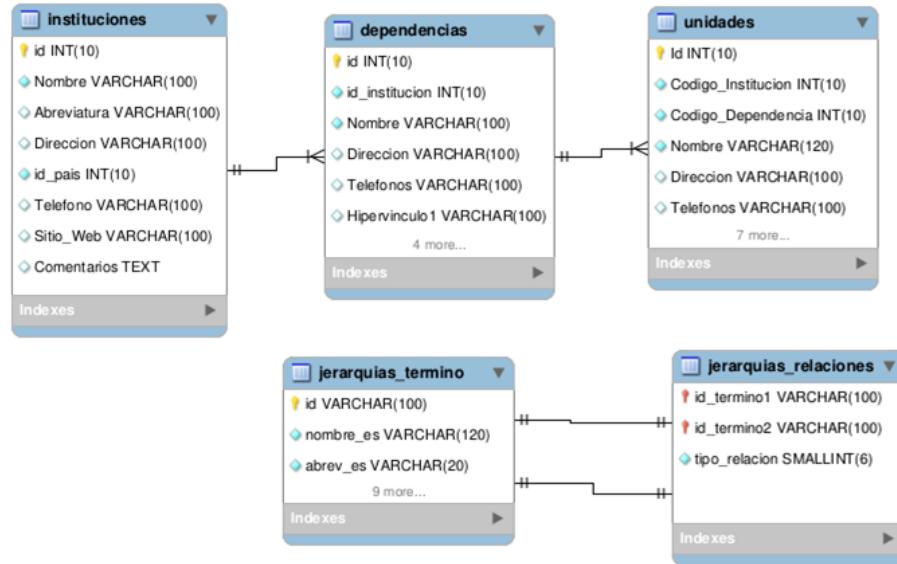
## Entidades duplicadas

Institución de las personas representadas en las tablas:

- países
- instituciones
- dependencias
- unidades

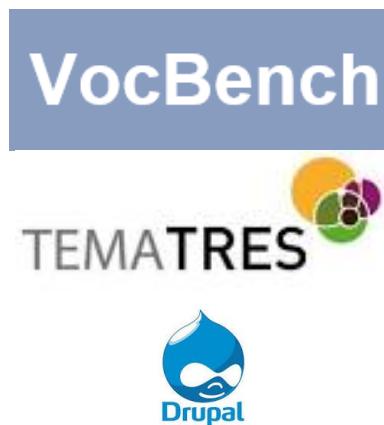
Más Instituciones en tabla

- jerarquia\_terminos



---

## Etapa 2 - Análisis y elección de herramientas



### Aspectos analizados

- Integración de vocabularios
- Interoperabilidad
- Casos de uso

---

## Etapa 2 - Análisis y elección de herramientas

VocBench:



- Usuarios deben tener conocimientos sobre OWL, SKOS(XL) y RDF
- El propósito y las funcionalidades de VocBench son demasiado específicas para SEDICI.
- No permite generar instancias de la información a migrar

TemaTres:

- Vocabularios gestionados como un tesoro y posee estados que no interesan en el contexto de nuestra aplicación.
- No permite representar entidades de todo tipo
- No dispone de algún módulo que permita importar los datos de CelsiusDL

---

## Etapa 2 - Análisis y elección de herramientas

Drupal permite:

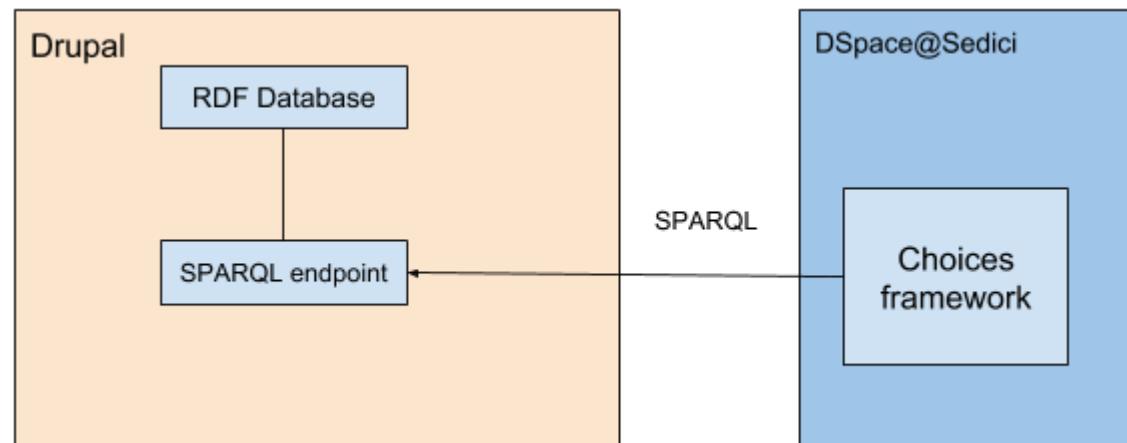


- Definir tipos de nodos con estructura dinámica
- Disponibilidad de módulos reutilizables
- Importar contenidos con sus relaciones a través de módulos contrib
- Exponer su contenido a otros sistemas a través de SPARQL
- Definir roles para administrador y editor

## Etapa 2 - Análisis y elección de herramientas

### Solución propuesta

- Almacenar autoridades como nodos en una instalación de Drupal 7
- URI del recurso identifica la autoridad
- Mapear nodos a RDF
- Exponer RDF a través de un endpoint SPARQL



---

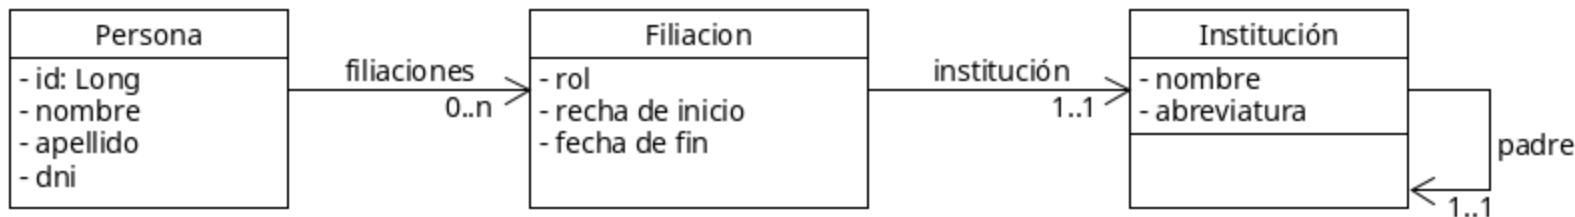
## **Etapa 3 - Desarrollo de nuevo módulo de gestión de Vocabularios Controlados**

AuthVoc compuesto por:

- AuthCTypes
- Auth SPARQL
- Auth Importer

# Módulo AuthCTypes

El modelo propuesto permite relacionar a una persona con una o más instituciones, registrando también la fecha de inicio, fecha de fin y rol que cumple en dicha institución.



# AuthSPARQL

- Exponer los campos de las entidades Persona e Institución
- Utilizar los módulos contrib RDF indexer y SearchAPI

## ARC SPARQL+ Endpoint (v2011-12-01)

This interface implements [SPARQL](#) and [SPARQL+](#) via [HTTP Bindings](#).

Enabled operations: select, construct, ask, describe

Max. number of results : 500

```
PREFIX foaf: <http://xmlns.com/foaf/0.1/>
PREFIX dc: <http://purl.org/dc/terms/>
PREFIX sioc: <http://rdfs.org/sioc/ns#>
SELECT ?institution ?label ?initials
WHERE {
?institution a foaf:Organization ; foaf:name ?label .
OPTIONAL { ?institution sioc:id ?initials}
FILTER(REGEX(?label, "universidad", "i") || REGEX(?initials, "universidad", "i"))
}
ORDER BY ASC(?label)
```

Change HTTP method: [GET](#) [POST](#)

[Send Query](#) [Reset](#)

---

# AuthSPARQL

```
PREFIX foaf: <http://xmlns.com/foaf/0.1/>
PREFIX dc: <http://purl.org/dc/terms/>
PREFIX sioc: <http://rdfs.org/sioc/ns#>
SELECT ?institution ?label ?initials
WHERE {
?institution a foaf:Organization ; foaf:name ?label .
OPTIONAL { ?institution sioc:id ?initials}
FILTER(REGEX(?label, "universidad", "i"))
}
ORDER BY ASC(?label)
```

```
<?xml version="1.0"?>
.....
<binding name="institution">
<uri>http://voc.sedici/node/46624</uri></binding>
<binding name="label">
<literal>Universidad Nacional de La Plata</literal>
</binding>
<binding name="initials">
<literal>UNLP</literal>
</binding>
</result>
</results>
</sparql>
```

---

## **Etapa 4 Normalización y exportación de entidades**

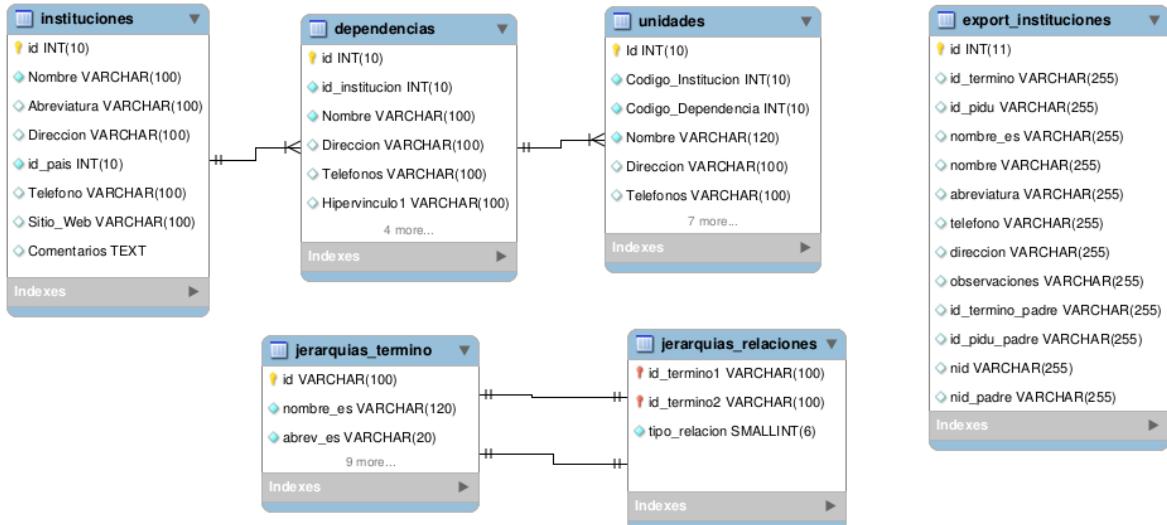
Sub-etapas:

1. Normalización de información en CelsiusDL
  - a. Unificación de instituciones.
  - b. Corrección de errores de sintaxis.
2. Depuración de autoridades innecesarias
3. Exportación de autoridades a formato CSV
4. Importación de autoridades en AuthVoc

# Normalización

Se creó una tabla intermedia, que fue utilizada para unificar las instituciones.

Mientras se realizaba la unificación de instituciones se corrigieron los errores encontrados.



# Normalización

Para definir la importancia de una institución se tuvo en cuenta:

1. País de origen de la institución
2. Si forma parte de la UNLP
3. Cantidad de publicaciones

Para definir el peso de un autor se hizo hincapié en:

1. Institución a la que pertenece
2. Cantidad de publicaciones
3. Fecha de su última publicación

CelsiusDL				
Personas		Instituciones		
Id	Nombre	Institución	Id	Nombre
1	Juan Martinez	1.1	1.1	UNLP
2	Pedro Gonzalez	1.2.1	1.2.1	UNS
3	Maria Fernandez	1.1	1.4	AUGM

DSpace@SEDICI			
Personas			
Id	Nombre	Último envío	Cantidad
1	J. Martinez	17/3/18	20
2	Pedro Gonzalez	4/3/11	3
3	Maria Fernandez	5/11/14	2

Tablas intermedias con datos normalizados					
Personas a exportar				Instituciones a exportar	
Id autor	Institución	Fecha último envío	Cantidad envíos	Institución	Cantidad envíos
1	1.1	17/3/18	20	1.1	22
2	1.2.1	4/3/11	3	1.2.1	3
3	1.1	-	2	1.4	-

---

# Depuración de autoridades

## Reglas de eliminación

### Personas :

- Con sólo 1 ítem y no pertenecían a la UNLP.
- No son de Argentina y que tenían 2 ítems o menos y cuyo último haya sido 2017 o antes.
- No son de argentina y que tenían participación en 3 o menos ítems, cuyo último envío fuese en 2013 o antes.
- No argentinos que pertenecen a instituciones que hayan hecho 10 o menos publicaciones.
- No pertenecientes a la UNLP con 1 solo ítem cuyo envío tenga fecha anterior al 2011.

### Instituciones

- Argentinas que no pertenecían a la UNLP, CONICET y CIC con menos de 10 publicaciones

---

## Depuración de autoridades

Se redujo en un 41 % el número autoridades

- 48436 a 20028 autoridades
- 46900 a 18600 autores
- 1536 a 1428 instituciones



# Exportación en CSV

- Registros propios de cada entidad
- Claves de las autoridades en CelsiusDL

nid	old_id	apellido	nombre	dni	cargo	filiacion
48368	12649	González	Carlos		Becario	48024
48369	12650	Mármol	Juan			48024

nid	nid padre	nombre	abrev	id termino	id termino padre	id pidu	id pidu padre
46940		Universidad Nacional de La Plata	UNLP	1.1	1	1	1
46941		Comisión Nacional de Energía Atómica	CNEA	1.15	1	5	1

# Etapa 5 - Importación

## AuthImporter

- Importar desde un CSV la información normalizada del sistema de autoridades CelsiusDL.
- Basado en el módulo Feeds

### Mapping for Node processor

Define which elements of a single item of a feed (= Sources) map to which content pieces in Drupal. A unique target means that a value for a target can only occur once. E. g. only one item with the UF

SOURCE	TARGET
+ nid	Node ID (nid)
+ nombre	Nombre (field_nombre)
+ apellido	Apellido (field_apellido)
+ dni	DNI (field_dni)
+ filiacion	-- (Entity reference by Entity ID) (field_filiaci_n:etid)
<input type="text"/>	- Select a target -
The name of source field.	The field that stores the data.
► LEGEND	
<input type="button" value="Guardar"/>	

---

# Etapa 6 - Desarrollo de Conecotor en DSpace

## Clases provistas por DSpace

1. [org.dspace.content.authority.Choice](#):

- a. Representa un término controlado por una autoridad. Contiene los atributos authority, label, confidence y value.

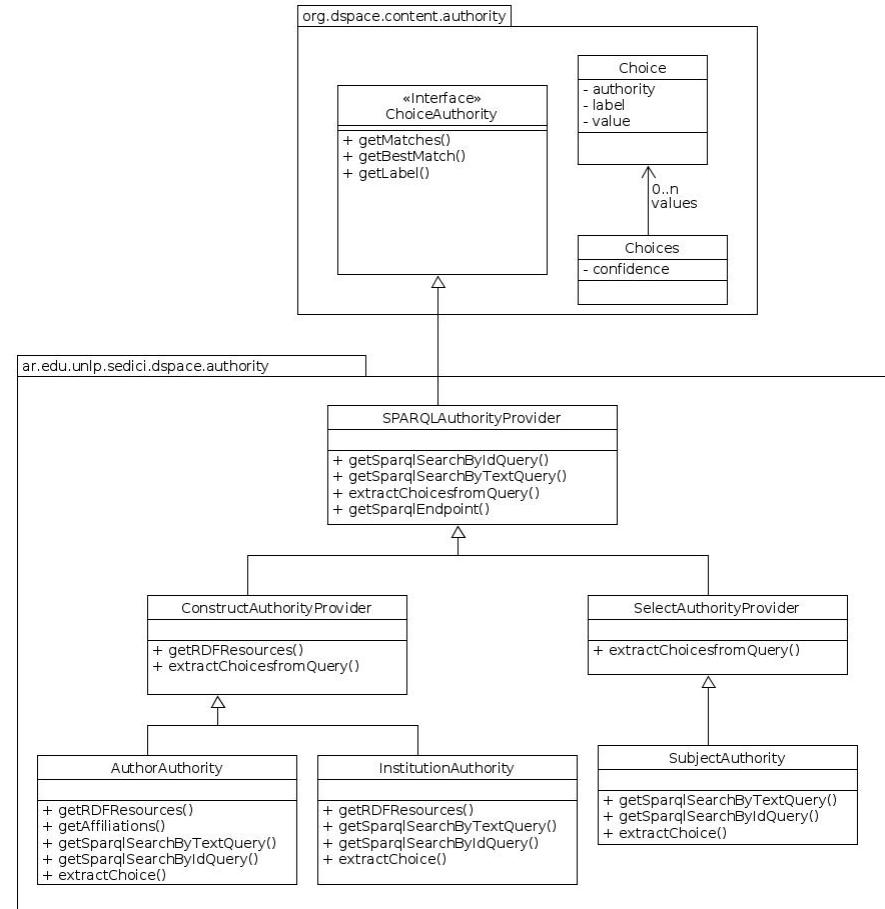
2. [org.dspace.content.authority.Choices](#)

3. [org.dspace.content.authority.ChoiceAuthority](#):

- a. Esta interfaz, se define para tomar valores de una autoridad que puede ser provista de cualquier fuente, ya sea una base de datos local o no, un servicio prestado por un tercero, documentos en cualquier formato, algo que provea términos controlados.

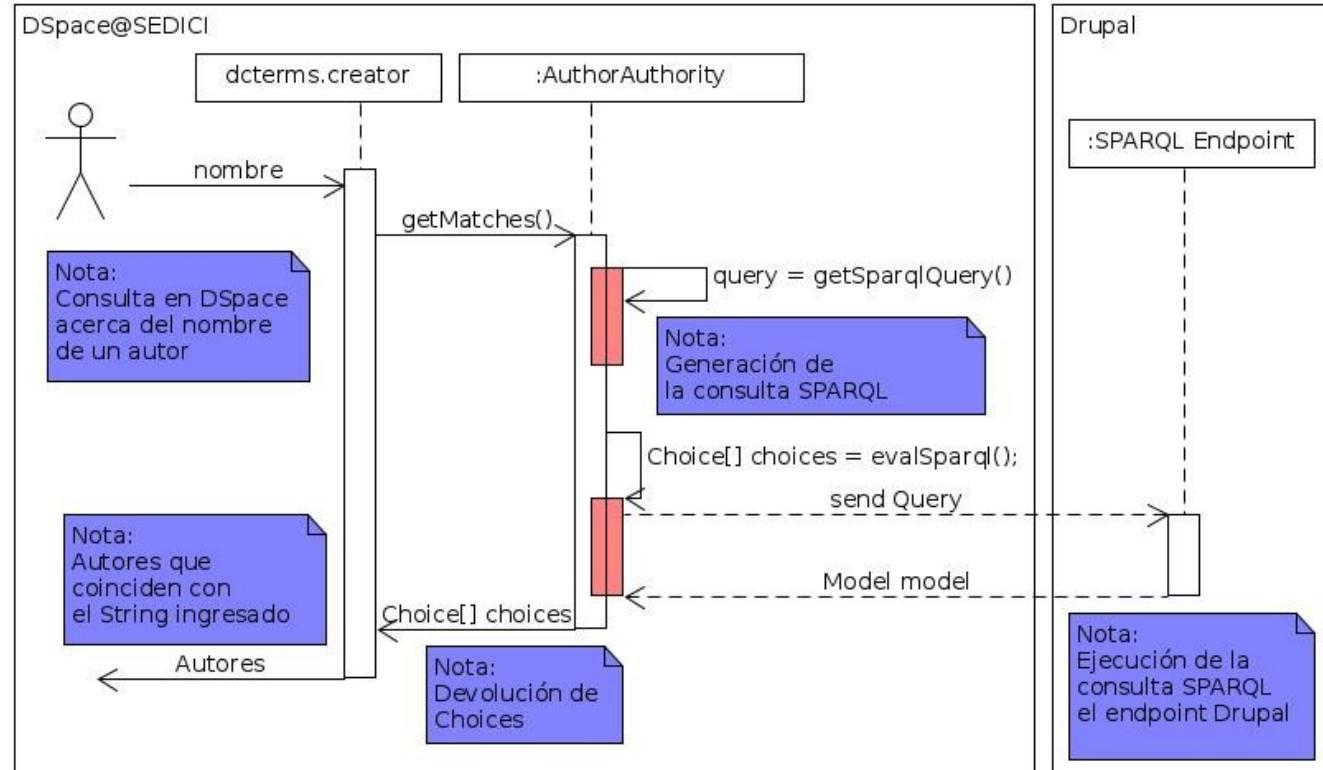
# Conektor en DSpace

- [SPARQLAuthorityProvider.java](#)
  - extiende ChoiceAuthority que sirve de base para definir fuentes de autoridades específicas.
- [AdvancedSPARQLAuthorityProvider.java](#)
  - Procesar consultas SPARQL con CONSTRUCT
- [SimpleSPARQLAuthorityProvider.java](#)
  - Clase que contiene la funcionalidad para procesar consultas SPARQL con SELECT
- [AuthorAuthority.java](#) e [InstitutionAuthority.java](#)



# Conektor en DSpace

Recuperación de un valor  
de autoridad



# Resultados finales

## GRADOS

- Facultad de Arquitectura y Urbanismo
  - Doctor en Arquitectura
  - Especialista en Arquitectura y Hábitat Sustentable
  - Especialista en Ciencias del Territorio
  - Especialista en Higiene y Seguridad Laboral en la Industria
  - Magister en Arquitectura y Hábitat Sustentable
  - Magister en Ciencias del Territorio
  - Magister en Conservación, Restauración e Intervención del Patrimonio
  - Magister en Paisaje, Medioambiente y Ciudad
- Facultad de Bellas Artes
  - Diseñador en Comunicación Visual
  - Doctor en Artes
  - Especialista en Lenguajes Artísticos
  - Licenciado en Artes Plásticas
  - Licenciado en Artes Plásticas (orientación Cerámica)
  - Licenciado en Artes Plásticas (orientación Dibujo)
  - Licenciado en Artes Plásticas (orientación Escenografía)

## MATERIAS

- Arquitectura
- Bellas Artes
- Ciencias Agrarias
  - Ingeniería Agronómica
  - Ingeniería Forestal
- Ciencias Astronómicas
- Ciencias de la Educación
- Ciencias Económicas
  - Administración
  - Contabilidad
  - Cooperativismo
  - Economía
  - Turismo
- Ciencias Exactas
- Ciencias Informáticas
- Ciencias Jurídicas
- Ciencias Médicas
- Ciencias Naturales
- Ciencias Sociales
- Ciencias Veterinarias
- Comunicación Social
- Desarrollo Regional
- Humanidades
- Ingeniería
- Odontología
- Trabajo Social

Editar Persona Riesco, Daniel Eduardo 

Apellido

Riesco

Nombre

Daniel Eduardo

DNI

MAIL

Añadir otro elemento

FILIACIÓN

Institución

Departamento de Informática (48265)

Rol

FECHA DE INICIO

Format: 2016

FECHA DE FIN

# Resultados finales

## The quantum-classical transition as an information flow

Autores: Kowalski, Andrés | Martín, María Teresa | Zunino, Luciano José | Plastino, Ángel Luis | Casas, Montserrat

Tipo de documento: Artículo

### Resumen

We investigate the classical limit of the semiclassical evolution with reference to a well-known model that represents given field. This is done by recourse to a special statistical quantifier called the "symbolic transfer entropy". The transition gets thereby described as the sign-reversal of the dominating direction of the information flow between classes.

### Información general

Fecha de publicación: 2010

Idioma del documento: Inglés

Revista: Entropy; vol. 12, no. 1

Institución de origen: Facultad de Ciencias Exactas

ISSN: 1099-4300

Extensión: p. 148-160

Materias: Ciencias Exactas ; Ingeniería ; Física

Palabras clave: Bandt and Pompe method; quantum chaos; semiclassical theories; transfer entropy

### Refine su búsqueda

#### Autor

- Riesco, Daniel Eduardo (45)
- Montejano, German Antonio (36)
- Pons, Claudia (36)
- Fillottrani, Pablo Ruben (28)
- Cechich, Alejandra (25)
- Giandini, Roxana Silvia (25)
- Daniele, Marcela (23)

### Navegar por autor

Todos A B C D E F G H I J K L M

O introducir las primeras letras:

Riesco, Daniel Eduardo [104]

Rimoldi, Marta Lidia [18]

Riesco, Gonzalo Ezequiel [1]

Rimoldi, Omar Jorge [5]

Riestra, Dora [2]

Rimorini, Laura [1]

Díaz Correa, Franklin [51]

Rinaldi, Carla Andrea [1]

Rinaldi, Emerson Valen

---

# Conclusiones

1. Uso de CMS como base de herramienta de gestión de vocabularios
  - a. Drupal
  - b. Uso de módulos y personalización
  - c. Buenas prácticas
2. Proceso de migración
  - a. Relevamiento de CelsiusDL
  - b. Normalización
3. Acercamiento hacia el enfoque propuesto por los principios de Linked Data
4. Implementación de conectores en DSpace
5. Se redujo en un 41 % el número autoridades

---

## Trabajo a futuro

- Migrar tesauros y la jerarquía de materias y grados alcanzados de CelsiusDL
- Implementar una distribución en Drupal
- Replicar módulo nuevo en CIC-DIGITAL
- Modelar y la gestionar variantes para las autoridades en Drupal
- Implementar en DSpace nuevos conectores que consuman información de otros sistemas



# ¡Gracias!

## Preguntas

de Albuquerque Pablo César