

Méthode et outil de construction d'ontologies à partir de textes

Sylvie Szulman

LIPN
Université Paris 13

16 novembre 2011

(1/51)



Plan

Le LIPN -équipe RCLN

Equipe RCLN

LabEx EFL

Thématiques de Recherche

Projets récents

Le projet Dafoe4App

Présentation générale

Objectifs

Réalisations

Le projet OntoRule

Présentation générale

Architecture du projet

Acquisition des modèles


Exploitation et recherche dans l'index



LIPN = Laboratoire d'Informatique de Paris Nord (P13)
dirigé par Christophe Fouqueré
UMR7030
> 100 membres
5 équipes dont l'équipe RCLN



dirigée par Adeline Nazarenko






Entre Textes et Connaissances


Représentation et ingénierie des connaissances

Traitement automatique des langues
Analyse sémantique





Compréhension





- ▶ Construction de connaissances à partir de textes
- ▶ Modèles et outils d'accès au contenu

Construction de connaissances à partir de textes



► Résultats

- Outils de construction de terminologies : YaTea
- Méthodes et outils d'acquisition de thesaurus, ontologies ...
- Méthodes et outils d'évaluation des méthodes d'acquisition

► Méthodes

- Exploitation d'outils de TAL
- Techniques d'apprentissage
- Méthodes d'Ingénierie des connaissances : interaction, formalisation



Plan

Le LIPN -équipe RCLN

Equipe RCLN

LabEx EFL

Thématiques de Recherche

Projets récents

Le projet Dafoe4App

Présentation générale

Objectifs

Réalisations

Le projet OntoRule

Présentation générale

Architecture du projet

Acquisition des modèles

Exploitation et recherche dans l'index



Objectifs -2

- ▶ Pouvoir passer à l'échelle pour créer des ressources importantes à partir de corpus sans se préoccuper de leur taille.
- ▶ Fournir un éditeur d'ontologie qui prend en charge toute la question de la sémantique de ces ontologies, à travers des questions épistémologiques liées aux concepts formels de haut niveau (la top ontology ou ontologie catégoriale).



Réalisations

- ▶ Séparation du coeur de la plateforme et des greffons
- ▶ Réalisation d'un cahier des charges avec prise en compte de l'ensemble des scénarios de l'ensemble des participants
- ▶ Spécification précise du modèle de données




Développement

- ▶ Une société de développement
- ▶ Réaliser comme une application eclipse en Java (Open Source)
- ▶ Un prototype a été livré



Architecture générale





Exemple

Dafoe Platform

File Edit Windows Help

Dafoe Corpus Terminology Terminology-ontology Ontology v6

Termino-concept Relations

Termino-concept x

Update

- rôle
 - marité
 - femme
 - homme
 - témoin
 - maré
 - maré
- rite civil
 - marriage civil
 - préparatif
 - rite religieux
 - marriage religieux
 - costume

Differential x

mariage civil

Definition in natural language : Le mariage civil ou mariage à la mairie

Differential principles

Similarities with parent :

Differences with parent :

Similarities with siblings :

Differences with siblings :

Relations x

TC1	RTC Type	TC2	St...
mère	participe	mariage civil	■
témoin	participe	mariage civil	■
homme	participe	mariage civil	■
femme	participe	mariage civil	■

Terminology x

mariage civil

Terms	Lang...
mariage civil	FR
union civile	FR

Translated terms

Translated terms	Lang...
A civil wedding	EN

Sentences

En 2006, elle a assisté au mariage civil en région
 Méthodologie Le chercheur n'a pas assisté au n
 Le couple vit à Paris, dans l'appartement que
 Maud Nicolas-Daniel : pouvez-vous nous parler
 Il n'y a aucune possibilité de mariage civil outp
 Pour d'autres religions, il y a par exemple des f
 En Italie, le mariage religieux a valeur de maria
 Une interview filmée du chercheur a été réalise
 Le mariage à l'église reste, par rapport au mar
 4 fils de famille (d'une durée totale de 18h) :
 Le mariage civil a été suivi d'un repas donné da
 Méthodologie Clara Barrelet a assisté à différen
 Résultats De nombreuses photographies docum

Conceptual x

mariage civil

Object type	Object name
Concept	mariage civil

TERMINO-ONTOLOGY



Partenaires

- ▶ IBM France (coordinateur)
- ▶ Ontoprise
- ▶ Free University of Bolzano
- ▶ Vienna University of Technology
- ▶ PNA
- ▶ Université Paris 13
- ▶ Fundación CTIC
- ▶ Audi
- ▶ ArcelorMittal

Les modèles -1


- ▶ modèle pour le document
 - ▶ un ensemble d'unités textuelles
 - ▶ une unité textuelle est repérée par l'offset de son premier caractère
 - ▶ une annotation d'une unité textuelle dans le document est exprimée à l'aide de RDFa

Les modèles -2

- ▶ une ontologie exprimée en OWL
- ▶ un modèle pour les règles
 - ▶ définition de règles *candidates* (expression dans le texte d'une règle)
 - ▶ réécriture de la règle candidate éventuellement en plusieurs règles dans un langage naturel en évitant les phénomènes de langue comme les ellipses, les métonymies . . .
 - ▶ classification de la règle : contrainte statique, règle effective, réglementaire. . .
 - ▶ Ecriture en SBVR (Semantic of Business Vocabulary and Rule) -Anglais simplifié



Le processus d'acquisition



Analyse linguistique : filtrage

- ▶ Extraction automatique des unités textuelles : ex *airline participant*
- ▶ Filtrage manuel ou semi-automatique des unités textuelles
- ▶ Regroupement d'unités textuelles : ex regroupement des candidats termes
e.g. *airline participant* regroupé avec *Airline participant* et *participant*

Normalisation

- ▶ Plan linguistique
- ▶ constitué de 2 phases.
 - ▶ Analyse terminologique :
 - ▶ Identifier les variantes de natures diverses : graphique (NY vs. New York), morphologique (member vs. members) ou bien morpho-syntaxique (program member vs. member of the program)
 - ▶ Identifier des unités synonymes (qui décrivent un même sens ou renvoient à une même entité du monde) et les regrouper sous une forme canonique
 - ▶ Construction du réseau termino-conceptuel

Niveau Termino-conceptuel/1

Un termino-concept est un terme désambiguïsé dont le sens est défini par son usage dans le corpus

Un termino-concept est décrit par :

- ▶ un terme vedette (terme préféré)
- ▶ un ensemble de termes synonymes
- ▶ une définition en langage naturel
- ▶ un ensemble de liens avec d'autres termino-concepts.

ex participant

2 utilisations soit membre, soit organisation

Création de 2 termino-concepts **Participant** et **Member**

Les 2 termino-concepts sont liés au terme *participant*



Formalisation


- ▶ Formalisation dans l'ontologie e.g. Creation de 2 concepts :
 - ▶ **Participant** fils du concept **Company**
 - ▶ **Member** fils du **Client**



Un outil pour l'expert

L'outil Terminae

(<http://www-lipn.univ-paris13.fr/~szulman/TerminaeWorkbench/>)



Annotation des textes

- ▶ Les connaissances linguistiques sont sauvegardées en SKOS

```
<skos:Concept rdf:about="http://ontorule#AdjustingDevice">
  <skos:prefLabel>adjusting device</skos:prefLabel>
  <skos:definition />
  <skos:altLabel>adjusting devices</skos:altLabel>
  <skos:altLabel>belt adjustment devices</skos:altLabel>
  <skos:example>index Corpus = 0 DOC = 0 Sentence = 48 Start_position = 5 End_posi
Text =Belt adjusting device .</skos:example>
  <skos:example>index Corpus = 0 DOC = 0 Sentence = 1004 Start_position = 119
End_position =135 Text =When the belt is being worn , it shall either adjust automatic
  <skos:example>index Corpus = 0 DOC = 0 Sentence = 383 Start_position = 5
End_position =21 Text =Belt adjusting device .</skos:example>
```

- ▶ peut être utilisées pour annoter de nouvelles versions ou d'autres textes sur le même domaine.

Acquisition des règles métiers

- ▶ Stratégie : analyse et exploration du texte
- ▶ SemEx : un outil pour eliciter et explorer les règles métiers

exploration sémantique

The screenshot shows the SemEx application window. On the left is a 'Hierarchy' tree with the following structure:

- Space
- Source
- Agent
- Function
- Attribute
 - Safety
 - Humidity
 - Temperature
 - Number
 - Device
 - Dimension
 - Conditioning
 - Method
 - VirtualMethod
 - PhysicalMethod
 - ResistanceTest
 - PhysicalSeatBeltTest
 - TrolleyTest
 - TensileTest
 - BreakingStrength
 - ExposureTest
 - MicroSlipTest
 - CorrosionTest

The main window displays a 'Corpus' with the following text and annotations:

7.3. **Micro-slip test** (see Annex 11, figure 3 to this [Regulation](#)).

7.3.1. [R1]The samples to be submitted to the **micro-slip test** shall be kept for a minimum of 24 hours in an **atmosphere** having a **temperature** of 20 + 5 C and a relative **humidity** of 65 + 5 per cent. [R1]The **test** shall be carried out at a **temperature** between 15 and 30 C.

7.3.2. It shall be ensured that the free section of the **adjusting device** points either up or down on the **test bench**, as in the **vehicle**.

7.3.3. [R18]A 5 **daN** load shall be attached to the lower end of the section of **strap**. [R18] The end shall be subjected to a back and forth motion, the total amplitude being 300 + 20 mm (see figure).

7.3.4. If there is a free end serving as reserve **strap**, it must in no way be fastened or clipped to the section under load.

7.3.5. It shall be ensured (34/51) the **test bench** the **strap**, in the slack position, descends in a concave curve from the **adjusting device**, as in the **vehicle**. The 5 **daN** load



Questions Sparql sur tout l'index

SemEx

File Edit View Settings

Search Engine Annotator Rule Editor Navigator

Semantic search

SPARQL query

```
PREFIX schema: <http://lipn.univ-paris13.fr/RCLN/schema#>
PREFIX audirules: <http://lipn.univ-paris13.fr/RCLN/ontorule/Audi/
rules#>
select distinct ?rule ?content ?concept
where{
  audirules:R19 schema:annoted ?link.
  ?link schema:defineResource ?resource.
  ?resource schema:realizeConcept ?concept.

  optional{
    ?rule schema:ruleText ?content.
    ?rule schema:annoted ?textlink.
    ?textlink schema:defineResource ?resource2.
    ?resource2 schema:realizeConcept ?concept.
  }
}
ORDER BY ?rule
```

The number of results : 21

?concept	Class_AND_Class_AND_122:http://lipn.univ-paris13.fr/RCLN/terminae/Audi#Strap
?content	if the <u>strap</u> breaks at or within 10 mm of either of the clamps then the <u>TestOfBreakingStrengthOfStrip</u> shall be invalid
?rule	http://lipn.univ-paris13.fr/RCLN/ontorule/Audi/rules#R10
	result 1
?concept	Class_AND_Class_AND_122:http://lipn.univ-paris13.fr/RCLN/terminae/Audi#Strap
?content	if the <u>strap</u> slips then a new <u>TestOfBreakingStrengthOfStrip</u> shall be carried out on another <u>strap</u> .
?rule	http://lipn.univ-paris13.fr/RCLN/ontorule/Audi/rules#R11
	result 2
?concept	Class_AND_Class_AND_122:http://lipn.univ-paris13.fr/RCLN/terminae/Audi#Strap
?content	if the <u>strap</u> breaks at or within 10 mm of either of the clamps then a new <u>TestOfBreakingStrengthOfStrip</u> shall be carried out on another <u>strap</u> .
?rule	http://lipn.univ-paris13.fr/RCLN/ontorule/Audi/rules#R12
	result 3
?concept	Class_AND_Class_AND_122:http://lipn.univ-paris13.fr/RCLN/terminae/Audi#Mesure
?content	A 5 daN load shall be attached to the lower end of the section of <u>strap</u> . The other end shall be subjected to (37/51) μ m motion, the total amplitude being 300 + 20 mm (see figure).



Ressources sémantiques

- ▶ Terminologie
- ▶ Thesaurus
- ▶ Ontologie
- ▶ Ressource Termino-ontologique



Terminologie

- ▶ Terminologie : une terminologie est une construction linguistique qui fournit une liste de termes. Pour chaque terme, il y a un ensemble de caractéristiques linguistiques comme (éléments morphologiques, l'équivalent dans d'autres langages ...)



Ontologies

Une ontologie est une spécification normalisée représentant les classes des objets reconnus comme existant dans un domaine (Charlet 2002).

Vocabulaire : mots, termes, concepts

Element	Ensemble
mots	
relations syntaxiques	Textes
Termes - relations terminologiques	Terminologies
Descripteurs - relations sémantiques	Thesaurus
Concepts - Roles propriétés	Ontologies

Un termino-concept peut s'apparenter à un descripteur dans un thesaurus mais en plus du terme qui le désigne, sa signification est exprimée par les occurrences dans le corpus de l'ensemble des termes qui lui correspondent.

- ▶ Un termino-concept est caractérisé par
 - * sa pertinence pour le domaine à modéliser
 - * il est non-ambigü
 - * il n'a pas de synonyme au niveau termino-conceptuel



Les termino-concepts sont organisés sous forme de réseau sémantique dont les relations sont :

- ▶ soit génériques/spécifiques non transitives, sans héritage de propriétés mais sans cycle
- ▶ soit associatives qui peuvent être symétriques ou inverses
- ▶ si deux termino-concepts sont liés par une relation associative, ils ne peuvent être liés par une relation spécifique/générique



- ▶ Un réseau termino-conceptuel est construit à partir d'un réseau de termes (terminologie)
- ▶ Un réseau termino-conceptuel sert à construire une ontologie.
Chaque termino-concept peut être formalisé par :
 - ▶ un concept (classe)
 - ▶ une instance
 - ▶ une propriété



- ▶ Pour la classification comme un thesaurus
- ▶ Comme une terminologie normative pour le modèle d'un domaine
- ▶ Si le réseau de termino-concepts est construit à partir d'une terminologie et si il sert de base à construction d'une ontologie, il permet de réaliser une RTO sous la forme d'un couplage faible entre les unités lexicales et les éléments conceptuels créés dans une ontologie.e



Pour finir

terme <> concept !!!