

Enjeux culturels et linguistiques
autour des données liées :

Sémanticpédia et le programme
« Sémantisation »

Thibault Grouas
7 juin 2013



1. L'apport des technologies à la politique de la langue

- La Délégation générale à la langue française et aux langues de France (DGLFLF) élabore **la politique linguistique du gouvernement**
- Elle s'intéresse à toutes les langues parlées en France : le français, les langues régionales, les langues étrangères. On dénombre **75 langues parlées en France**
- Elle promeut activement **le multilinguisme**, notamment en Europe (Le multilinguisme, première langue européenne?)
- Elle dispose d'une **mission dédiée aux technologies numériques**
- Le numérique apparaît comme l'enjeu majeur pour les langues, comme un levier indispensable pour la conduite d'une politique.

2. Diversité des projets en terme de numérique

- Action sur les **technologies de la langue** (synthèse vocale, reconnaissance vocale, traduction automatique, correction d'orthographe, sous-titrage...)
- Utiliser l'**internet collaboratif** pour favoriser l'enrichissement du français : Wiktionnaire, WikiLF
- Promotion du multilinguisme sur internet
- Encourager la **diversité linguistique** et promotion des cultures locales via le web 2.0 et les réseaux sociaux : Projet de **wikilivre des Outre-mer**
- Soutien à l'action de l'association Wikimedia pour la création de communautés de contributeurs en langues locales
- Diffusion la plus large possible des langues et cultures de France sur les réseaux : **le web sémantique** et **le web de données** apparaissent comme un enjeu majeur

3. Le web sémantique en soutien à l'influence culturelle française

- Les technologies sémantiques et le web de données représentent **une évolution considérable** des méthodes d'accès et de classement de l'information
- La présence de la culture et de la langue dans le web de données est un enjeu significatif pour la France
- Le web sémantique sera peut-être demain la clé de voûte de **l'accès à l'information** sur l'internet. Les outils de recherche pourraient bénéficier de nouvelles fonctionnalités
- Il est indispensable que **la culture et les langues de France** soient présentes sur la toile sémantique, risque majeur si ce n'est pas le cas

4. Web sémantique et multilinguisme

- Autre intérêt des technologies sémantiques : lorsque les corpus sont multilingues (Wikipédia), elles représentent **une chance pour le multilinguisme**
 - Possibilité de créer des interfaces de navigation nativement multilingues rapidement
 - Pour un éditeur, la charge liée à la traduction baisse considérablement
 - Possibilité d'utiliser des méthodes de classement (mots clés, rubriques...) multilingues
 - exemple avec Europeana : 11000 résultats avec « Baroque », 1200 avec « Barocco », 1600 avec « Barock ».
- L'accès à la culture française est plus difficile pour ceux ne maîtrisant pas la langue française.
- Les technologies multilingues permettent donc d'**exporter la culture et la langue française**, de mieux la rendre visible aux locuteurs ne maîtrisant pas le français.

5. Web sémantique et langues de France

- La France parle **75 langues différentes**, certaines sont déjà bien présentes sur internet (basque, breton, catalan, occitan...) d'autres beaucoup moins visibles (langues de l'outre mer...)
- Intérêt croissant pour ces langues, dont certaines sont menacées.
- **Intérêt politique** : engagement du président de la République de ratifier la charte européenne des langues régionales
- **Wikipédia** et le **Wiktionnaire** constituent, pour beaucoup de ces langues, la seule présence sur la toile
- Les technologies sémantiques permettent aussi de **faciliter l'accès à la culture** pour les publics maîtrisant mal le français : interfaces de navigation et méthodes de classement en langues régionales

6. Sémanticpédia ?

Une **collaboration inédite** entre un acteur culturel public majeur, une expertise technologique, et une communauté de talents



6. Sémanticpédia ?

- Un **espace de collaboration** entre trois univers : la recherche, l'internet contributif et la culture
- Forte **complémentarité** des partenaires :
 - Wikimedia France : premier diffuseur de données culturelles en France sur internet (près de 25 millions de visiteurs par mois)
 - Ministère de la Culture : expertise unique sur les patrimoines et la création culturelle
 - INRIA : expertise technique sur le web et le web de données
- Objectifs : **croiser les expertises**, partager les retours d'expériences, mutualiser les efforts de recherche et développement.
- Créer des interconnexions avec l'écosystème du Web sémantique ouvrant **des usages aujourd'hui insoupçonnés**.

7. Pourquoi Sémanticpédia ?

- Pour pousser plus loin l'expérimentation **Histoire des Arts « HDA Lab »**, menée par le DPN, riche en enseignements.
- Parce que Wikipédia, qui compte **plus de 1,3 millions d'articles** en français, est une ressource culturelle unique en son genre.
 - Près de 40% des articles sur l'encyclopédie concerne directement **des contenus culturels**
 - Grande diversité des contenus : tous les formes d'expression culturelle sont représentés
 - Une partie importante d'informations sont déjà « **structurées** » et potentiellement exploitables : infobox, catégories, portails...
- Le projet initial **DBpedia.org** ne couvrait pas le français : risque pour tous les contenus qui ne sont disponibles qu'en français.
→ Nécessité de conduire un projet de sémantisation centré sur Wikipédia **en langue française**

8. Le projet DBpédia en français

- **DBpedia.org** est un projet sous licence libre d'extraction des données de Wikipédia anglophone, lancé en 2007, pour en proposer une version Web sémantique structurée
- Il est mené par l'université de Leipzig, l'université libre de Berlin (Freie Universität) et l'entreprise OpenLink Software
- L'INRIA, à travers le projet **DBpédia en français** est le contact de référence pour DBpedia.org pour la France
- **DBpédia en français** permet notamment de couvrir beaucoup plus largement la culture francophone et notamment la création contemporaine, qui n'est pas encore décrite en anglais sur Wikipédia.
- **Plusieurs innovations** par rapport au projet initial : identifiants pérennes (URI), nouveaux extracteurs...
- Ce projet positionne la langue française au cœur du Web de données émergent

9. DBpédia en français : réutilisations

HdA Lab
Accueil — Navigation par : **Facettes** Catégories de Wikipedia Thésaurus

Recherche par facettes : **Nouvelle session**
 Partager la session
 Mes vues : **Mes résultats de recherche** Ma liste +

Filtres : Toutes périodes

-1000
0
500
1000
1200
1400
1600
1700
1750
1800
1850
1900
1950
2000

Gérer la vue "Mes résultats de recherche"

Pays

Powered by [Leaflet](#)

Nuage de mots-clés

Portrait Religion Paysage Corps humain Urbanisme

Art contemporain Femme Vie quotidienne Archéologie Réalité

Couleur Nature Espace (notion) Lumière Ville Christianisme Temps

Voyage Société (sciences sociales) Mort Enfance Imaginaire

Église (édifice) Mythologie Installation (art) Conte Modernité Arts décoratifs Statue

Romantisme

Notes

- Annoter cette vue...

Disciplines artistiques

Peinture <div style="width: 80%; background-color: #2e3192; height: 10px;"></div>	Architecture <div style="width: 80%; background-color: #2e3192; height: 10px;"></div>
Sculpture <div style="width: 60%; background-color: #2e3192; height: 10px;"></div>	Cinéma <div style="width: 70%; background-color: #2e3192; height: 10px;"></div>
Musique <div style="width: 40%; background-color: #2e3192; height: 10px;"></div>	Théâtre <div style="width: 50%; background-color: #2e3192; height: 10px;"></div>
Photographie <div style="width: 30%; background-color: #2e3192; height: 10px;"></div>	Littérature <div style="width: 20%; background-color: #2e3192; height: 10px;"></div>
Mise en scène <div style="width: 20%; background-color: #2e3192; height: 10px;"></div>	Dessin <div style="width: 15%; background-color: #2e3192; height: 10px;"></div>

Résultats de recherche

4562 notices

Louise Bourgeois

<http://www.centrepompidou.fr/education/r...>
[S-bourgeois/ENS-bourgeois.html](http://www.centrepompidou.fr/education/r...)

Ce dossier, conçu à l'attention des enseignants, et basé sur l'exposition événement du Centre Pompidou (2008), propose d'interroger l'œuvre de Louise Bourgeois...

Louise Bourgeois (plasticienne) Installation (art)

XXe siècle 2008 Mémoire (sciences humaines)

Sculpture Peinture Art contemporain Enfance

Métamorphose Inconscient Famille

Localisation : Paris 4

Annotations

9. DBpédia en français : réutilisations

IZIPEDIA béta

Géographie

- Quelle est la capitale de la Suisse ?
- Quelle est la population de l'Inde ?
- Qui est le maire de Montargis ?
- Comment appelle-t-on les habitants de Poissy ?
- Quelle est la longueur de la Garonne ?
- Quelle est le débit du Mississippi ?
- Quelle est la hauteur du mont Ventoux ?
- Quelle est la superficie du Luxembourg ?

Personnalités

- Quel est l'âge de Benoît XVI ?
- Qui est l'épouse de Jacques Chirac ?
- Quelles sont les diplômes d'Albert Einstein ?

Culture

- Qui a joué dans Intouchables ?
- Dans quels films a joué George Clooney ?
- Chansons de Serge Gainsbourg ?
- Qui est l'auteur de la Légende des Siècles ?
- Peintures de Dalí ?

10. Le programme Sémantisation

- Le nouveau **schéma directeur 2013-2015** des systèmes d'information du ministère de la Culture consacre une partie de son budget à l'**innovation**
- Le **programme « Sémantisation »** financé dans ce cadre et lancé en février 2013 a pour but, sur les 3 prochaines années, de mener des projets d'expérimentation au MCC autour des données liées.
- Le programme constitue un des engagements du **programme ministériel de modernisation et de simplification** (PMMS).
- Les projets qui en sont issus sont développés rapidement et à budget limité. Premier exemple : **Muséophile**.
 - Une application optimisée pour le mobile
 - présentant un accès multilingue aux musées du monde
 - selon différents choix personnels (artiste ou mouvement préféré)
 - Durée totale du projet : deux mois avec 8 langues disponibles
 - L'application sera mise en ligne début juillet.

11. Le projet JocondeLab

- Une expérimentation a lieu cette année autour de **la base JOCONDE**, qui contient notamment **300 000 notices illustrées**.
- Cette expérimentation s'appuiera notamment sur les résultats de la preuve de concept « **HDA-Lab** ».
- Le projet associe plusieurs directions du MCC et est réalisé en partenariat avec l'**Institut de recherche et d'Innovation** (IRI) du Centre Pompidou.
- L'objectif est de démontrer l'intérêt du liage d'un corpus organisé tel que Joconde avec les données issues de Wikipédia via DBpédia.
- L'innovation se portera sur les modes d'accès à l'**image** et sur le **multilinguisme**
- Le site expérimental sera rendu public à la fin de l'année et devrait être disponible intégralement en au moins cinq langues dont une langue de France.
- Un bilan sera réalisé en fin de projet pour déterminer quelles innovations peuvent être reprises dans les **outils de travail** utilisés au quotidien au ministère de la Culture.

12. Autres projets de sémantisation envisagés

L'année prochaine, une autre expérimentation sera menée sur un **corpus d'archives sonores** en langues de France : Corpus de la Parole

- L'innovation portera sur **la navigation dans un corpus sonore**.
- D'autres expérimentations sont envisagées autour du Wiktionnaire (2 millions de termes en français) pour :
 - proposer des outils de traitement de la parole ou du langage,
 - de classement de termes,
 - de manipulation de synonymes,
 - de suivi des nouveaux termes issus du public...
- Ces expérimentations permettront au MCC d'**améliorer ses outils de travail** en fonction des résultats expérimentaux obtenus.

Des questions ?

Thibault Grouas
thibault.grouas@culture.gouv.fr
@tgrouas

