

Base de données et vocabulaires contrôlés

Utilisation des vocabulaires contrôlés
en ligne pour les données

JDEV 2017 (05/07/2017)

Marie-Claude Quidoz – Baptiste Laporte

Contexte

- Thèse de MA Laporte (2011) en écoinformatique
- Groupe interopérabilité de rBDD / CESAB (2013-2016)
 - Informaticien / documentaliste / chercheur
 - <http://rbdd.cnrs.fr/spip.php?rubrique34>
- GDR Semandiv (2017-2021)
 - Informaticien / documentaliste / chercheur
 - Axe 4 : Visualisation, interrogation, mise en correspondance avec les bases de données

Pourquoi ?

- Contrôle des données
- Interopérabilité
- Evolution des données

Contrôle des données

Réduire les erreurs humaines

Réduire l'hétérogénéité syntaxique

Réduire l'hétérogénéité sémantique

BDD propre = basé sur une sémantique définie !!!

Nécessité de l'interopérabilité

- mise en commun de données issues d'observations/expérimentations conçues initialement de façon indépendante et/ou dans des contextes disciplinaires différents
- Produire de nouvelles connaissances à partir de ces données
- Interface entre écologie et sciences de l'information: développement de l'écoinformatique

Interopérabilité

Association données/sémantique
commune

=

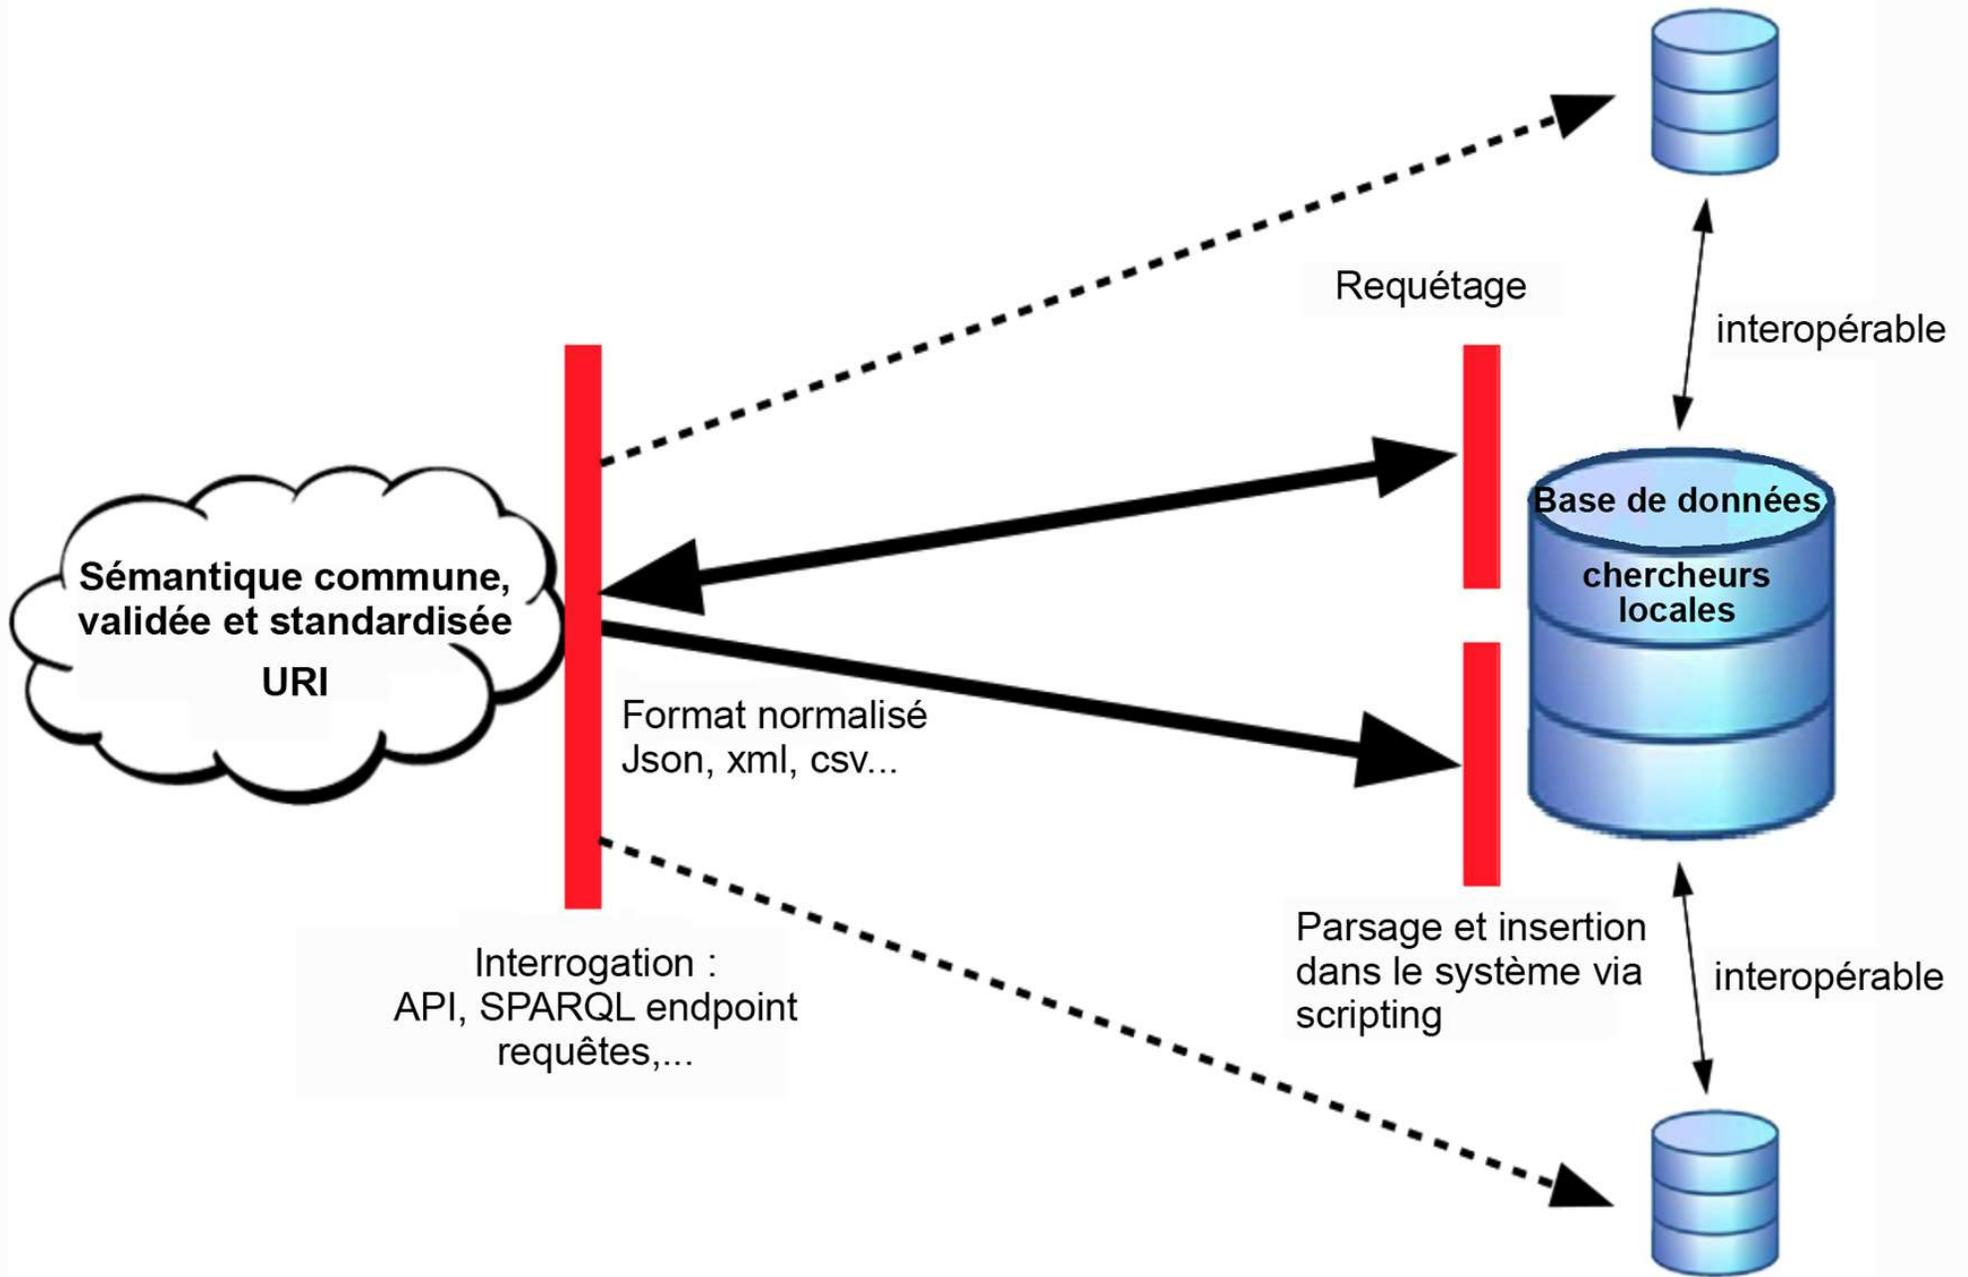
premier pas
vers l'interopérabilité

Evolution des données

Web sémantique = données intelligentes

URI/URL (persistant) + lien entre eux = évolution

Synonymie, hiérarchie, etc.



Exemple d'utilisation

Utilisation d'un thésaurus

Simplicité de construction, outil thesauform existant

Lien avec une base de données SQL (EAV)

SQL = contrôle fort des données

EAV = flexibilité de la base, permet l'annotation

Interfaçage avec un langage de scripting PHP

Librairie lecture json disponible, etc

Modèle EAV

Schéma sensible à modifications

Ne pas coder les attributs des entités en dur

coder le couple nom de l'attribut/valeur

⇒ Ajouts de nouveaux attributs sans modifier le schéma conceptuel / la structure des requêtes pour extraire l'information

Inconvénients :

- impossible de mettre des contraintes physiques dessus sans vérification poussés des données
- le type des données non spécifié = colonne supplémentaire
- Ralentissement des performances
- la lecture de la donnée en ligne = transformation des résultats des requêtes
- Requêtage direct des données difficile, besoin d'interface (pl-SQL, scripting externe)

Thesaurus

- *Une liste de terme définie permettant d'être sûr de travailler sur la même chose entre expert et non-expert, début de l'interopérabilité. (**définition personnelle sûrement erronée**)*
- *Liste organisée de termes contrôlés et normalisés représentant les concepts d'un domaine de la connaissance*

Les termes sont reliés entre eux par des relations de :

- **Synonymie (terme équivalent)**
- **Hiérarchie (terme générique et spécifique)**
- **Association (terme associé)**

Capacité d'indexation et de recherche

Thesaurus

Pour une expérience réussie

- couverture du domaine
- expertise des validateurs
- respect des standards
- utilisation par une communauté

Les outils

- Différentes solutions
 - licence (libre/commercial)
 - utilisateur impliqués (mono poste / collaboratif)
 - différents standards (OBO, OWL, SKOS, ...)
 - différentes technologies (java, technologies web, ...)
 - différents moyens d'accès (local, web, web sémantique compliant, etc.)

⇒ Intégration données = scientifiques utilisateurs (ergonomie importante)

Le Thesauform

Prototype développé dans le cadre d'une thèse en écoinformatique (2011)

- Collaboratif (web)
- Standard SKOS
- Simple d'utilisation
- Visualisation travaillée
- Extraction par API

=> <https://github.com/CESAB-FRB/Thesauform>

Technique

J2EE, modèle MVC

Fichier texte OWL compatible SKOS

JENA

Exemples d'utilisations réussies

A Terminological Resource for Plant Functional Diversity : <http://top-thesaurus.org/>

Thesaurus for Soil Invertebrate Trait-based Approaches : <http://tsita.cesab.org/>

Démonstration

Thesauform

http://localhost:8080/thesauform_V1.0

Thesauform API

<http://t-sita.cesab.org>

Exemple d'API:

Id = 1 : test existence of trait

Id = 2 : select all direct sons of a trait

Id = 3 : all qualitative traits

Id = 4 : all quantitative traits

Id = 5 : select trait real name

Id = 6 : test a trait is quantitative

Id = 7 : get synonym of a trait

Id = 8 : get all trait with unit interval (temporal traits)

Id = 9 : get all trait and synonyms with at least one synonym

Id = 10 : test a trait is interval

[http://t-sita.cesab.org/BETSI_php.jsp?id=\(3,4,8,9\)](http://t-sita.cesab.org/BETSI_php.jsp?id=(3,4,8,9))

[http://t-sita.cesab.org/BETSI_php.jsp?id=\(1,2,5,6,7,10\)&trait=Repulsive_glands](http://t-sita.cesab.org/BETSI_php.jsp?id=(1,2,5,6,7,10)&trait=Repulsive_glands)

Scripting PHP

Curl et json: `apiSPARQL.php`

Gestion des exceptions: `insertTraits.php`

Requête: `exempleSyn.php`

Limitations

Besoin de connexion

Risque de création de multiples thésaurus

Gestion de l'ajout des termes utilisateurs
spécifiques