Web et données liées

Release 2012

December 05, 2012

CONTENTS

CHAPTER

ONE

WEB DE DONNÉES

author Pierre-Antoine Champin

1.1 Motivation et historique

Figure 1.1: source: http://en.wikipedia.org/wiki/File:Tim_Berners-Lee.jpg

1.1.1 Le Web vu par Tim Berners-Lee (1989)

« Vague, but exciting »

1.1.2 Web de ressources

Le web est constitué de **ressources**, par exemple :

- le bulletin météo du jour pour Lyon
- le bulletin météo du jour pour le lieu courant
- ma commande de café de jeudi dernier

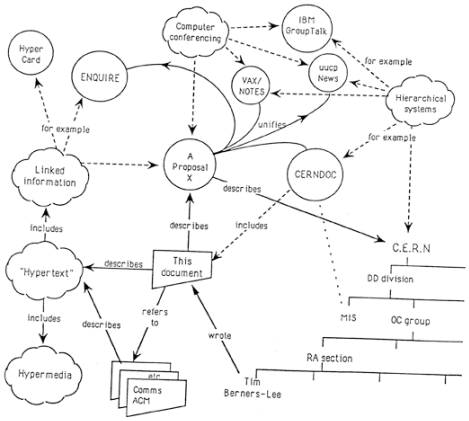

Figure 1.2: source: http://info.cern.ch/images/proposal.gif

Chaque ressource est identifiée par un IRI (*Internationalized Resource Identifier*), *e.g.*:

- http://meteo.example.com/lyon
- http://meteo.example.com/ici
- http://commerce.example.com/commande/192837

/!\ Un IRI n'est pas un nom de fichier (cf. exemples ci-dessus)

Parenthèse : URL/URI/IRI

- URL: Uniform Resource Locator (**RFC 1738**, 1994)
- URI: Uniform Resource Identifier (**RFC 2396**, 1998)
- IRI: Internationalized Resource Identifier (**RFC 3987**, 2005)
- technologies successives
- même concept

Ressources et représentations

- Une ressource n'est jamais manipulée directement, mais toujours à travers des **représentations** (pour la créer, la consulter, la modifier).
- Les représentations d'une ressource peuvent varier en fonction
  - de son *état*
  - de l'agent qui manipule la ressource (négociation de contenu, context)

représentation :	**utilisable par :**
texte	humains, moteurs de recherche
médias (image, son...)	*surtout* humains
données structurées	machines

1.1.3 De HTML à XML

XML (eXtensible Markup Language) a été recommandé par le W3C en 1998. L'objectif était de pallier la sémantique « faible » de HTML.

```
<!-- HTML -->
<a href="http://champin.net/">
  Pierre-Antoine <strong>Champin</strong>
  (<em>Maître de conférences</em>)</a>

<!-- XML -->
<Person homepage="http://champin.net/">
  <givenName>Pierre-Antoine</givenName>
  <surname>Champin</surname>
  <job>Maître de conférences</job></Person>
```

1.1.4 XML et la sémantique

On a dit tout et son contraire l'apport sémantique de XML :

- XML a *plus* de sémantique que HTML,
- XML a *moins* de sémantique que HTML,

Les deux ont leur part de vérité.

XML a *plus* de sémantique que HTML...

... dans le sens ou il est extensible : on peut donc exprimer des choses que HTML ne permet pas d'exprimer (e.g.‘‘<givenName>‘‘).

- Importance des *espaces de noms*, qui évitent les collisions de noms et fournissent ainsi une sémantique « structuraliste » (i.e. par différenciation).

```
<Person xmlns="http://xmlns.com/foaf/0.1/"
        xmlns:pro="http://example.com/"
     homepage="http://champin.net/">
  <givenName>Pierre-Antoine</givenName>
  <surname>Champin</surname>
  <pro:job>Maître de conférence</pro:job></Person>
```

XML a *moins* de sémantique que HTML...

... dans la mesure ou :

- un navigateur standard ne saura pas quoi faire de la balise `<givenName>` ou de la balise `<ονομα>`,
  - tout au plus il saura les afficher s'il possède une feuille de style,
- tandis qu'il connaît la sémantique de la balise `<em>` : elle dénote un texte à mettre en évidence *selon les moyens dont il dispose*, par exemple :
  - en le mettant en italique (standard)
  - en le mettant en gras (police déjà en italique)
  - en le mettant en couleurs (police sans italique, terminal)
  - en marquant une pause (synthèse vocale)

XML : apports et limitations

Le surplus de sémantique promis par XML n'est donc pas « magique » : il suppose

- de créer de nouveaux langages basés sur XML (DTD, schémas),
- d'écrire les logiciels qui *interpréteront* ces nouveaux langages,

  → chaque langage reste relativement idiosyncratique.

XML : apports et limitations (suite)

L'apport est donc essentiellement technique : la base commune de XML permet de *factoriser* les efforts de développement et d'apprentissage :

- analyseurs syntaxiques (*parsers*),
- langages de schémas (DTD, XML-Schema, Relax-NG...),
- langages de requêtes (XPath, XQuery),
- langages de transformation (XSL-T),
- méthode de signature cryptographique (xmldsig),
- methode de compression (EXI)...

1.1.5 De XML à RDF

- Le modèle sous-jacent de la syntaxe XML est un arbre (*XML Infoset*), ce qui n'est pas adapté à la structure décentralisée du Web.
- L'objectif du *Resource Description Framework* (RDF), recommandé par le W3C en 1999, vise à munir le Web d'un modèle de données plus adapté, ayant une structure de *graphe*.
- L'objectif est de construire le *Semantic Web* : un web dans lequel les machines ont (enfin) accès à la sémantique des données.
- Recommandation un peu hâtive, présentant quelques défauts importants (notamment l'absence de sémantique formelle).

  → faible adoption de RDF

1.1.6 De RDF à RDF

- En 2004, le W3C publie un nouvel ensemble de recommandations sur RDF pour remplacer celles de 1999.
- Pour des raisons de compatibilité avec l'existant, certains aspects sont conservés malgré les débats qu'ils suscitent, mais les défauts considérés comme majeurs sont corrigés.
- Après cet échec relatif, l'appellation *Semantic Web* tombe peu a peu en disgrâce. Certains défenseurs de RDF parlent plus modestement de *Data Web*, puis de *Web of Linked Data* (2006).

1.1.7 Le mouvement OpenData

Toute donnée publique (gouvernementale, ONU) ou publiée (scientifique) devrait être accessible sous une forme permettant le traitement automatique (en plus d'une forme lisible pour des humains).

- http://data.gov/

Figure 1.3: source: http://www.w3.org/RDF/icons/

- http://data.un.org/
- http://data.gouv.fr/
- http://opendata69.org/
- Raw Data Now (Tim Berners-Lee à TED)

1.2 Linked Open Data

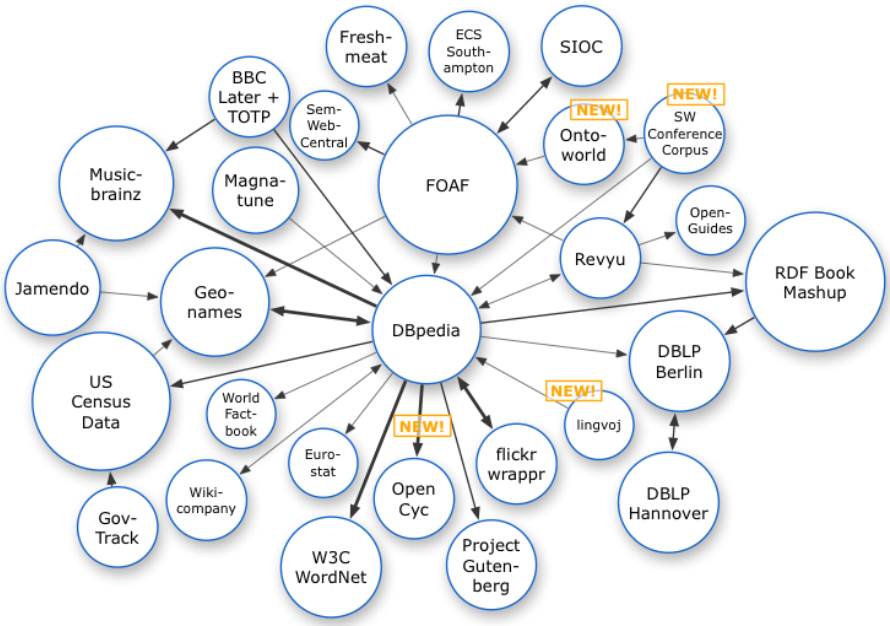

Figure 1.4: source: http://richard.cyganiak.de/2007/10/lod/

1.2.1 Les quatre principes de Linked Data

- Utiliser des IRIs pour nommer les choses (= ressources).
- Utiliser des IRIs HTTP pour pouvoir obtenir des *représentations* de ces ressources.
- Fournir ces représentations en utilisant des langages et des protocoles standards (RDF, SPARQL).
- Inclure des liens pour permettre de découvrir de nouvelles ressources.

d'après Tim Berners-Lee, http://www.w3.org/DesignIssues/LinkedData.html

Ouvrir les données liées

- Intérêt des IRIs : tout jeu de données peut référencer des données d'un autre jeu de données
  - réutilisation de l'existant
- Intérêt des IRIs déréférençable (*cool IRIs*) : permet de découvrir de nouvelles données sur le mode de l'hypertexte
  - passage à l'échelle
  - importance d'un format commun → RDF
- Linked open data star scheme

Figure 1.5: source: http://lab.linkeddata.deri.ie/2010/lod-badges/

1.2.2 Projet emblématique : DBpedia

- Projet lancé par Chris Bizer en 2007.
- Objectif : extraire les informations structurées (*infobox*) présentes dans Wikipedia pour les exposer en RDF.
- En juillet 2011 (version 3.7) :

  > The new DBpedia data set describes more than 3.64 million things, of which 1.83 million are classified in a consistent ontology, including 416,000 persons, 526,000 places, 106,000 music albums, 60,000 films, 17,500 video games, 169,000 organizations, 183,000 species and 5,400 diseases.

Informations structurées dans Wikipedia

1.2.3 Le « *LOD cloud* »

Le « *LOD cloud* »

Le « *LOD cloud* »

Le « *LOD cloud* »

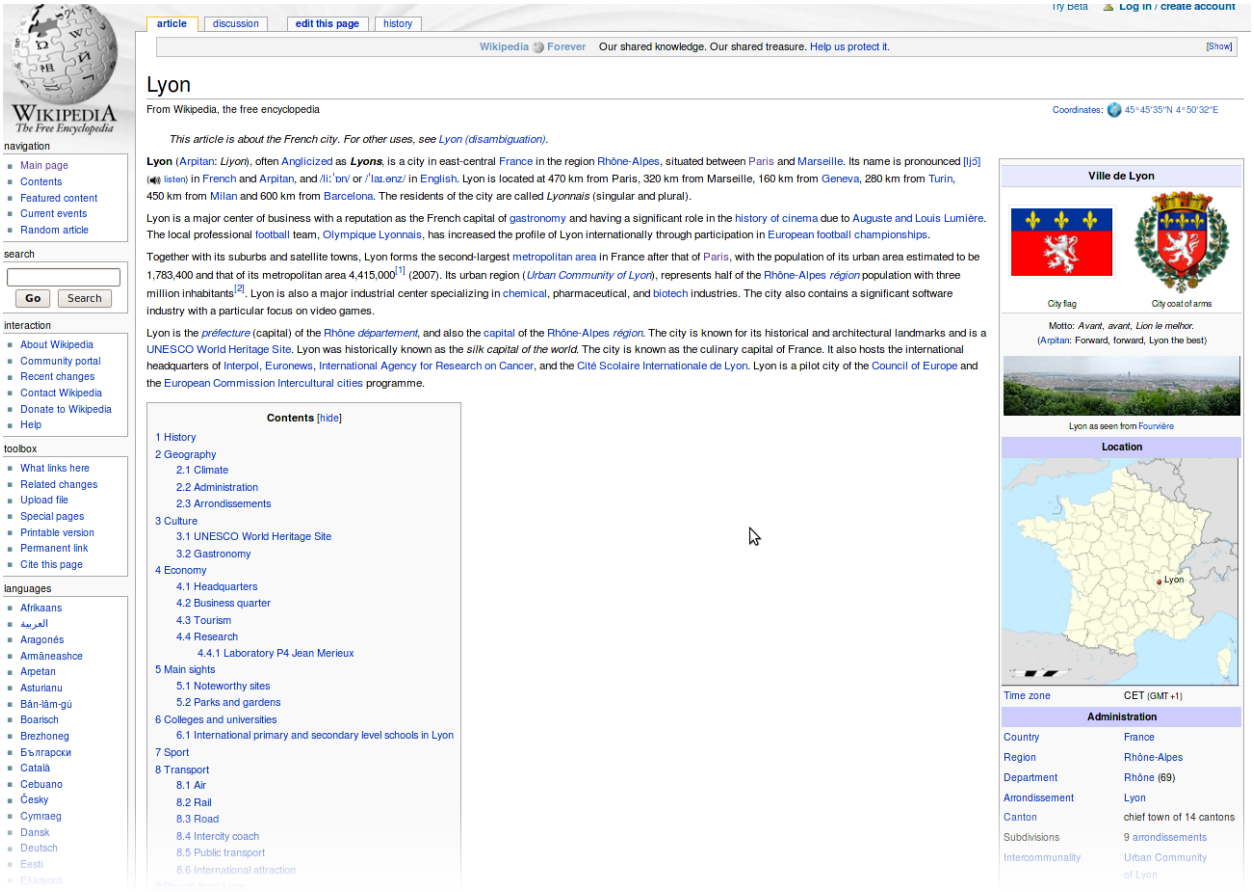

Figure 1.6: source : http://en.wikipedia.org/wiki/Lyon

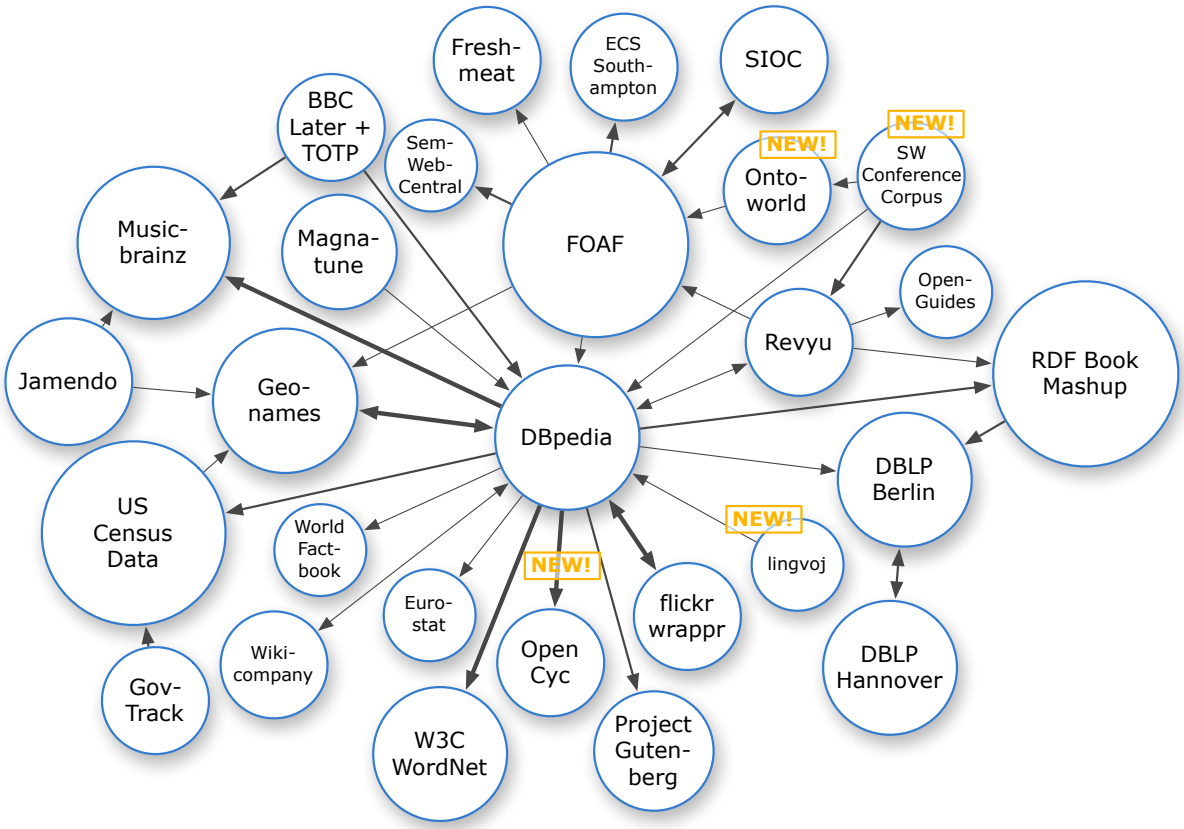

Figure 1.7: source: http://richard.cyganiak.de/2007/10/lod/
En 2007

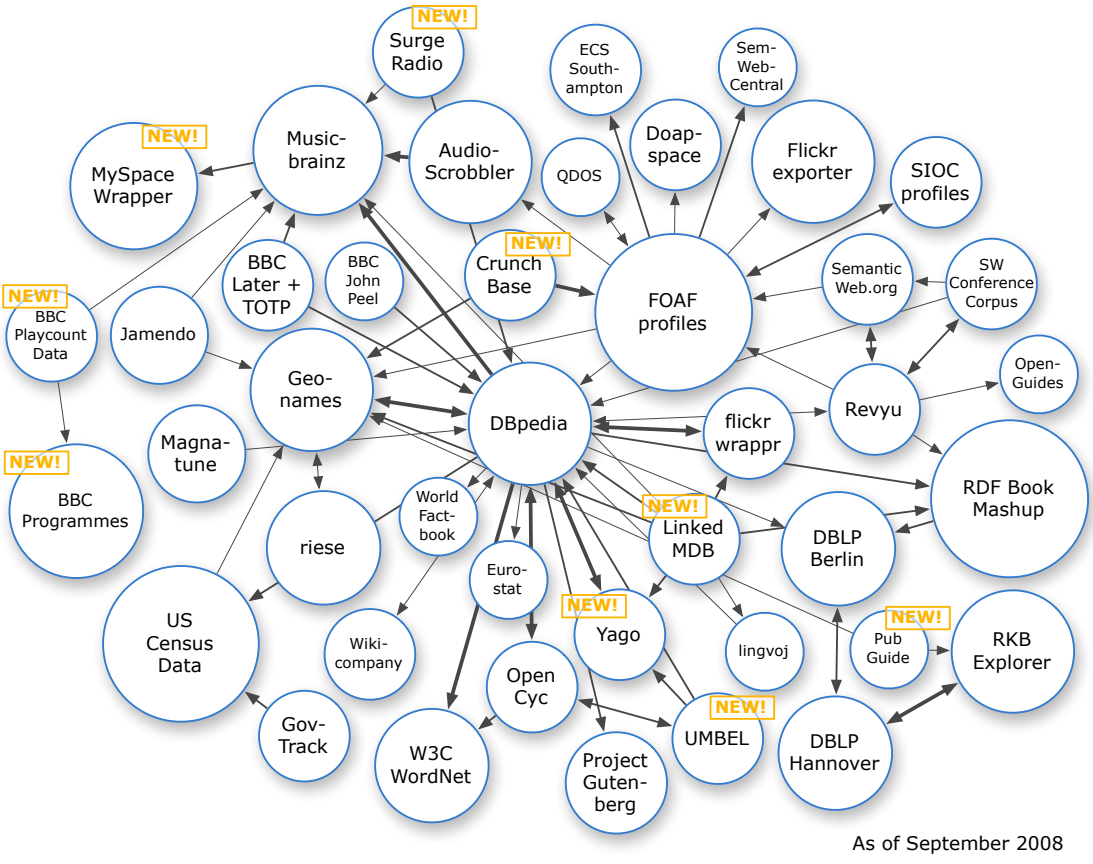

Figure 1.8: source: http://richard.cyganiak.de/2007/10/lod/
en 2008

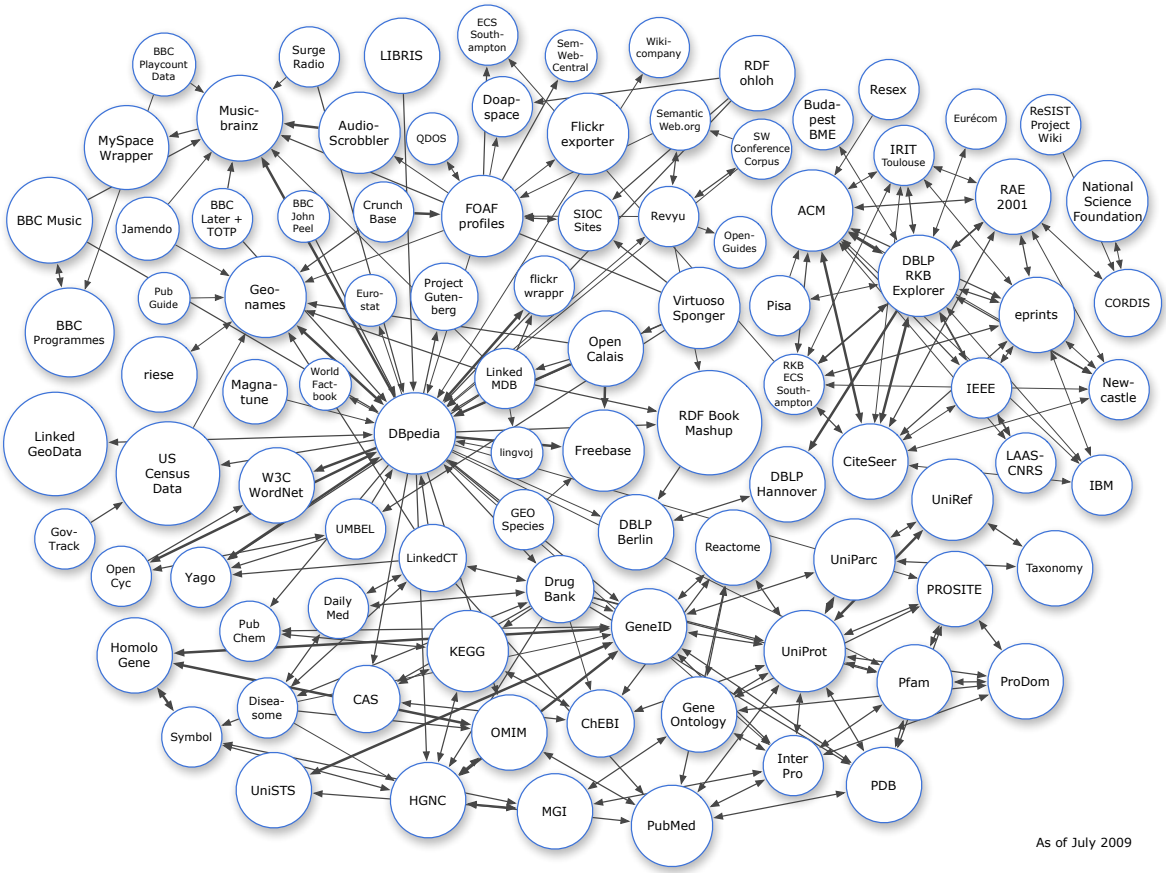

Figure 1.9: source: http://richard.cyganiak.de/2007/10/lod/
en 2009

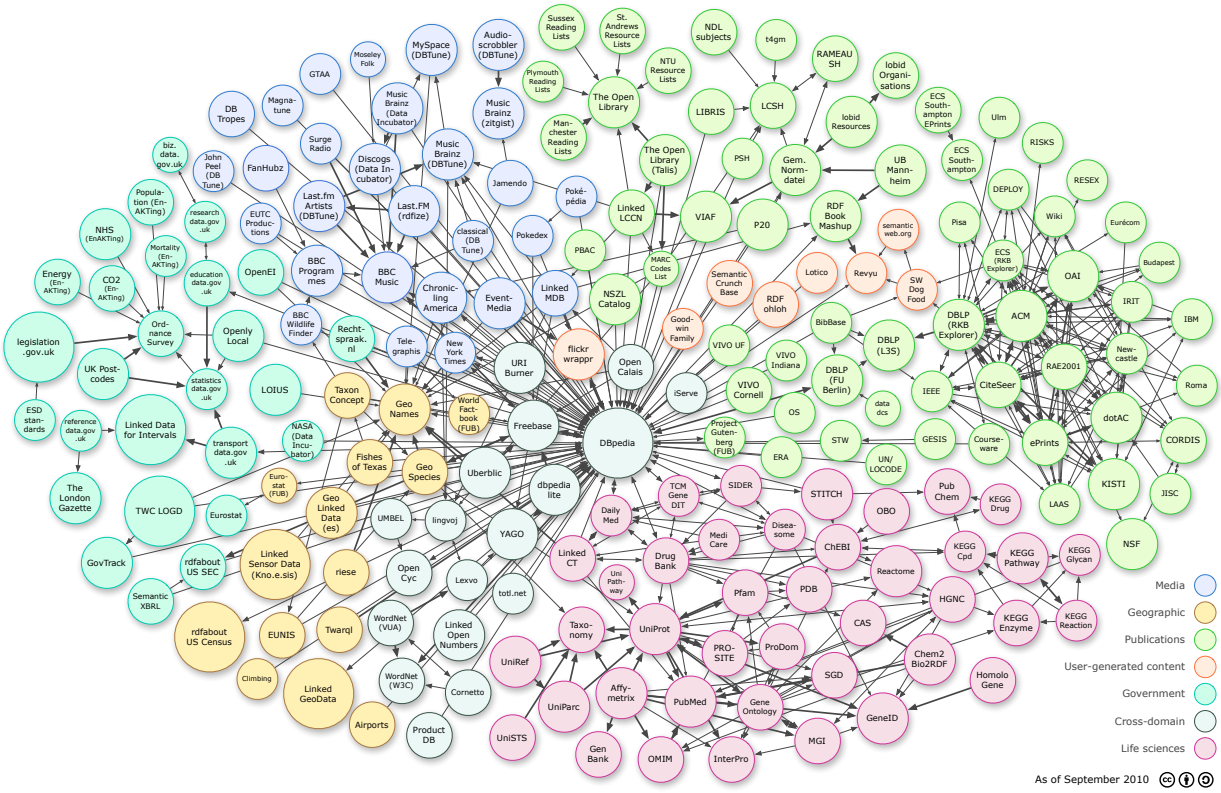

Figure 1.10: source: http://richard.cyganiak.de/2007/10/lod/
en 2010

Le « *LOD cloud* »

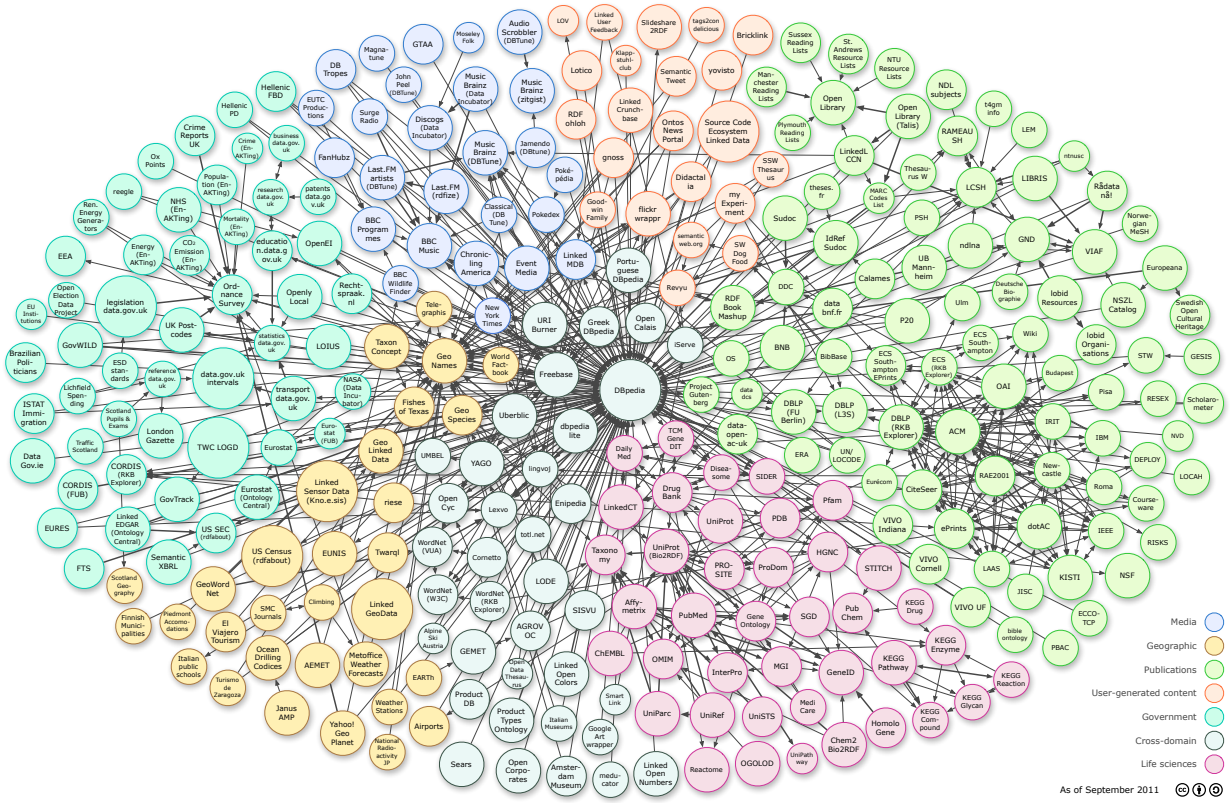

Figure 1.11: source: http://richard.cyganiak.de/2007/10/lod/
en 2011

Rechercher et explotation des données

- Annuaire des sources de données :
  - http://thedatahub.org/
- Moteur de recherche :
  - http://sindice.com/
- Navigateurs de données :
  - http://graphite.ecs.soton.ac.uk/browser/ (navigateur simple)
  - http://sig.ma/ (navigateur multi-source)
  - http://www.visualdataweb.org/relfinder.php

1.2.4 Divergences et convergences

- The Open Graph protocol (Facebook)

http://ogp.me/

- Schema.org (Bing, Google, Yahoo)

  http://schema.org/

  http://schema.rdfs.org/

CHAPTER

TWO

RDF

author Pierre-Antoine Champin

2.1 Introduction

2.1.1 Vue d'ensemble

RDF 2004 définit :

- une syntaxe abstraite (modèle de donnée),
- une sémantique pour *interpréter* la syntaxe abstraite,
- plusieurs syntaxes concrètes pour représenter/échanger la syntaxe abstraite.

2.2 Syntaxe abstraite et sémantique

2.2.1 Triplet

Toute information en RDF est représentée par un *triplet*,

signifiant qu'une *chose* est en *relation* avec une autre.

Exemple :

> Le laboratoire LIRIS (sujet)
>
> a pour membre (prédicat)
>
> Pierre-Antoine Champin (objet)

Nommage

Les choses sont nommées par des IRIs :

> http://liris.cnrs.fr/#lab
>
> http://xmlns.com/foaf/0.1/member
>
> http://champin.net/#pa

On peut représenter ceci graphiquement :

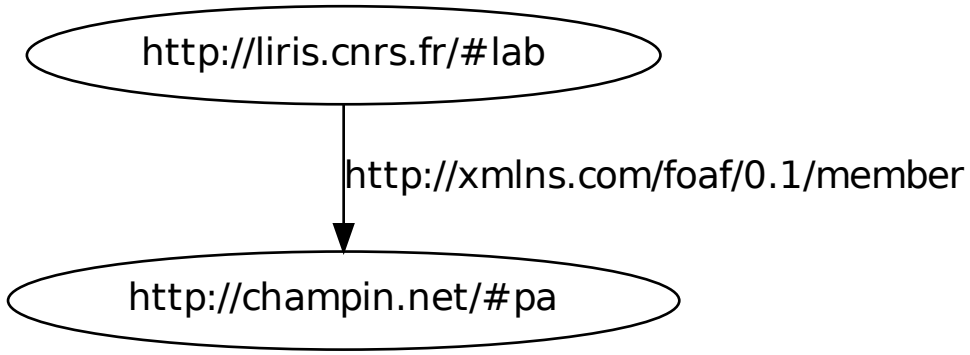

2.2.2 Préfixes

Pour simplifier les **notations**, on définit des préfixes courts correspondant à des préfixes d'IRI :

liris: → `http://liris.cnrs.fr/#`

foaf: → `http://xmlns.com/foaf/0.1/`

champin: → `http://champin.net/#`

On utilise ensuite des *noms préfixés* :

liris:lab foaf:member champin:pa

et également sous forme graphique :

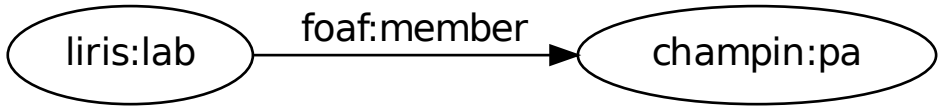

2.2.3 Littéraux

On peut également lier une ressource à une *donnée typée* (chaîne de caractère, entier, réel...), nommée un littéral.

champin:pa foaf:name "Pierre-Antoine Champin"

Traditionnellement, on représente les littéraux par des nœuds rectangulaires :

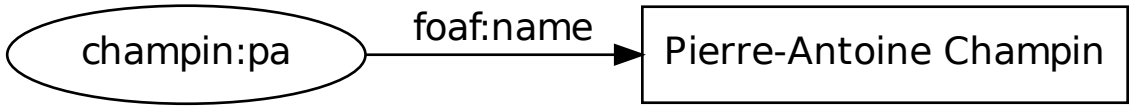

2.2.4 Nœuds muets

Enfin, RDF permet de parler d'une ressource sans connaître son IRI. Cela revient en logique à utiliser une variable quantifiée existentiellement.

(quelque chose) foaf:name "Alain Mille"

On parle alors de nœud *muet* (par analogie aux variables muettes).

Graphiquement, on représente cette ressource par un nœud vierge (*blank node*).

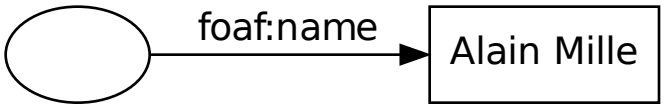

2.2.5 Exemple de graphe

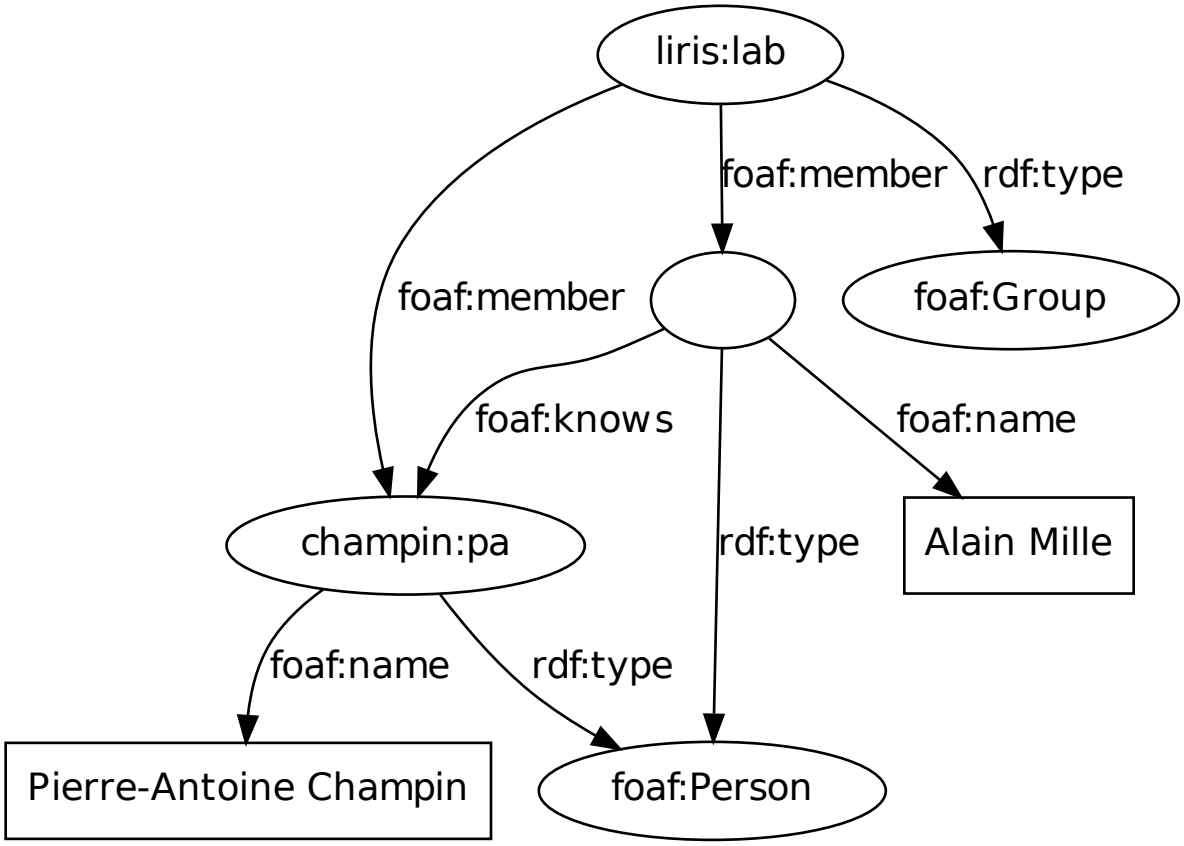

2.2.6 Sémantique et inférences

La structure du graphe permet de faire un minimum d'inférence, sans même avoir besoin de connaître le vocabulaire.

Exemple : « Toto est le tata de titi et tutu »

Par analogie, étant donné un arbre XML, on peut inférer en un arbre dans lequel seul l'ordre des attributs a changé.

Bien sûr, des inférences supplémentaires peuvent être faites en prêtant une sémantique particulière aux IRIs utilisés dans le graphe.

Exemple : « tata est une relation symétrique et transitive »

Vocabulaire et sémantique additionelle

On verra plus tard des langages (RDF-Schema, OWL) permettant de définit la sémantique de certains IRIs.

Mais ces langages ne peuvent pas remettre en cause la sémantique du graphe lui-même.

Analogie : lorsqu'on définit un format XML, on prête une sémantique particulière aux éléments et attributs de ce format, mais on ne peut *pas* prêter de sémantique à l'ordre des attributs ;

- sémantiquement, ce ne serait plus du XML,
- pragmatiquement, les outils standards (analyseur syntaxique, sérialiseurs) ne permettraient pas de contrôler cet aspect de la syntaxe.

2.3 Syntaxes concrètes

2.3.1 RDF/XML

- syntaxe recommandée par le W3C (1999)
- basée sur XML
- relativement complexe et verbeuse

  Syntaxe http://www.w3.org/TR/rdf-syntax-grammar/

  Valideur http://www.w3.org/RDF/Validator/

RDF/XML : exemple

```
<rdf:RDF xmlns:rdf="http://www.w3.org/1999/02/22-rdf-syntax-ns#"
         xmlns:foaf="http://xmlns.com/foaf/0.1/"                    >
 <foaf:Group rdf:about="http://liris.cnrs.fr/#lab">
  <foaf:member>
   <foaf:Person>
    <foaf:name>Alain Mille</foaf:name>
    <foaf:knows
     rdf:resource="http://champin.net/#pa"/>
   </foaf:Person>
  </foaf:member>
  <foaf:member>
   <foaf:Person rdf:about="http://champin.net/#pa">
    <foaf:name>Pierre-Antoine Champin</foaf:name>
   </foaf:Person>
  </foaf:member>
  </foaf:Group>
</rdf:RDF>
```

2.3.2 Turtle : Terse RDF Triple Language

- dérivée du langage N3
- en passe d'être recommandé par le W3C (en 2012)
- vise la simplicité et la compacité

  Syntaxe http://www.w3.org/TR/turtle/

  Valideur http://www.rdfabout.com/demo/validator/

Turtle: exemple

```
@prefix foaf: <http://xmlns.com/foaf/0.1/> .
@prefix champin: <http://champin.net/#> .

liris:lab
    a foaf:Group ;
    foaf:member champin:pa, _:am .
champin:pa
    a foaf:Person ;
    foaf:name "Pierre-Antoine Champin" .
_:am
    a foaf:Person ;
    foaf:name "Alain Mille" ;
    foaf:knows champin:pa .
```

Turtle: exemple 2

```
@prefix foaf: <http://xmlns.com/foaf/0.1/> .
@prefix champin: <http://champin.net/#> .

liris:lab
    a foaf:Group ;
    foaf:member champin:pa, [
      a foaf:Person ;
      foaf:name "Alain Mille" ;
      foaf:knows champin:pa .
    ] .
champin:pa
    a foaf:Person ;
    foaf:name "Pierre-Antoine Champin" .
```

2.3.3 RDFa : RDF in attributes

RDFa est une utilisation d'attributs (existants ou supplémentaires) de (X)HTML pour y inclure du RDF (à la manière des micro-formats) :

- facilite la migration de contenus HTML vers RDF
- facilite la maintenance en cohérence de la version HTML et des données RDF (*DRY : Don't Repeat Yourself*)

  Syntaxe http://www.w3.org/TR/rdfa-primer/

  Valideur http://check.rdfa.info/

  Distiller http://www.w3.org/2012/pyRdfa/

RDFa : exemple

```
<p prefix="foaf http://xmlns.com/foaf/0.1/"
   about="_:am">
  <span property="foaf:name"
    >Alain Mille</span>
  est membre du
  <a rev="foaf:member" href="http://liris.cnrs.fr/#lab"
    >LIRIS</a>.
```

```
  Il connaît
  <span rel="foaf:knows" href="http://champin.net/#pa">
    <span property="foaf:name"
      >Pierre-Antoine Champin</span>,
    un autre membre de
    <span rev="foaf:member" href="http://liris.cnrs.fr/#lab">
      ce laboratoire.</span>
  </span> </p>
```

2.3.4 JSON-LD

- Rappel : JSON est un langage d'échange de données, basé sur Javascript, et très utilisé en développement web.
- JSON-LD (JSON Linked Data) permet d'interpréter une structure JSON comme du RDF,
- grâce à un *contexte* (implicite ou explicite).
- Objectif : faciliter l'adoption de RDF (syntaxe abstraite) auprès des développeurs d'applications web.

  Syntaxe http://www.w3.org/TR/json-ld-syntax/

  Valideur http://json-ld.org/playground/

JSON-LD: exemple

```
{ "@context" : { /* ... */                                    },
 "@id": "http://liris.cnrs.fr/#lab",
 "@type": "Group",
 "member": [
   {
     "@type": "Person",
     "name": "Alain Mille",
     "knows": {
       "@id": "http://champin.net/#pa",
       "@type": "Person",
       "name": "Pierre-Antoine Champin"
     }
   },
   "http://champin.net/#pa"
 ]
}
```

2.3.5 Autres syntaxes

- Comme l'illustrent RDFa et JSON-LD, tout langage peut être interprété comme du RDF:
  - dialectes en XML (GRDDL)
  - microformats (http://http://microformats.org/)
  - microdata (http://www.data-vocabulary.org/)
- ← Prépondérance de la syntaxe abstraite.
- Difficulté : faire correspondre des IRIs là ou d'autres langages utilisent des termes « locaux ».

2.4 Vocabulaires

2.4.1 Trouver un vocabulaire

- http://swoogle.umbc.edu/
- http://lov.okfn.org/

2.4.2 Quelques vocabulaires utiles

Dublin Core

Méta-données à propos des documents :

- titre, résumé...
- créateur, contributeur...
- date de création, de dernière modification, versions...

description http://lov.okfn.org/dataset/lov/details/vocabulary_dc.html

homepage http://purl.org/dc/terms/

FOAF: Friend of a friend

Description de personnes et de leur réseau social

- Personne (nom, prénom, page weg, adresse e-mail, *connaissance*...)
- Groupe (membres...)
- Document (a pour sujet...), Image (représente...)

description http://lov.okfn.org/dataset/lov/details/vocabulary_foaf.html

homepage http://www.foaf-project.org/

SIOC: Semantically-Interlinked Online Communities

Description de communautés en ligne

- Forum, Blog, Wiki...
- Article, Commentaire...

description http://lov.okfn.org/dataset/lov/details/vocabulary_sioc.html

homepage http://rdfs.org/sioc/spec/

WGS84: Word Geodetic System

Coordonnées géographiques

- SpatialThing, Point
- lattitue, longitude, altitude

  description http://lov.okfn.org/dataset/lov/details/vocabulary_geo.html

  homepage (rdf) http://www.w3.org/2003/01/geo/wgs84_pos

GoodRelations

e-commerce

- Produit et Service, Offre...
- quantité, prix, garantie...

  description http://lov.okfn.org/dataset/lov/details/vocabulary_gr.html

  homepage http://purl.org/goodrelations/v1

CHAPTER

THREE

SPARQL

author Pierre-Antoine Champin

3.1 Introduction

3.1.1 Objectifs

- Vous donner des bases pour écrire des requêtes SPARQL.
- Bonus: lire/écrire du Turtle (très proche de SPARQL).
- Ce n'est qu'une introduction ; pour en savoir plus :

  http://www.w3.org/TR/sparql11-overview/

3.1.2 Requête simple

```
PREFIX foaf: <http://xmlns.com/foaf/0.1/>

SELECT ?n1 ?n2
WHERE {
    ?p1 a <http://xmlns.com/foaf/0.1/Person> .
        foaf:name ?n1 ;
        foaf:knows ?p2 .
    ?p2 a foaf:Person ;
        foaf:name ?n2 .
}
```

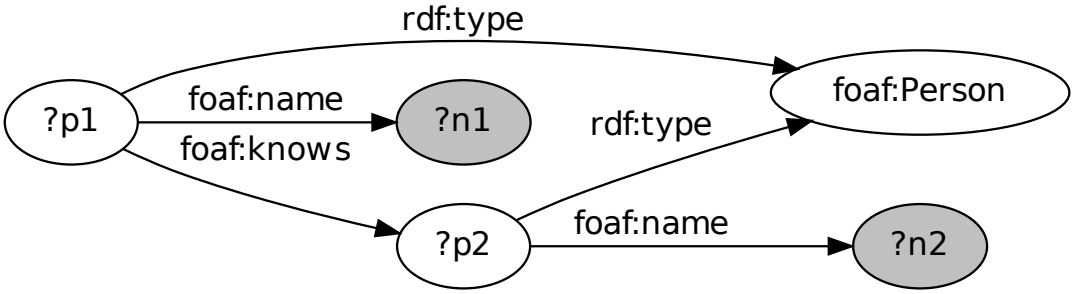

3.2 Description du graphe

3.2.1 Préfixes

Rappel : les préfixes servent à abréger les IRIs.

SPARQL :

```
PREFIX foaf: <http://xmlns.com/foaf/0.1/>
PREFIX : <http://example.com/>
```

Turtle :

```
@prefix foaf: <http://xmlns.com/foaf/0.1/> . # /!\ point final
@prefix : <http://example.com> .   # après chaque déclaration
```

3.2.2 Termes

IRI en extension (relatif ou absolu) :

```
<http://xmlns.org/foaf/0.1/Person>
<../other-file.rdf>
<#something>
<>
```

IRI abrégé :

```
foaf:Person
:something
```

Termes (suite)

Litéral :

```
"Bonjour"
"Hello"@en          # avec tag de langue
"123"^^xsd:integer  # typé
```

```
42                  # equiv. "42"^^xsd:integer
1.5                 # equiv. "1.5"^^xsd:decimal
314e-2              # equiv. "314e-2"^^xsd:double
true                # equiv. "true"^^xsd:boolean
```

Nœud muet :

```
_:toto
[]        # voir ci-après
```

Termes (suite)

Variable (SPARQL seulement) :

```
?foo
$foo
```

NB: pas de distinction entre `?` et `$`.

3.2.3 Triplets

- 3 termes (sujet, prédicat, objet) séparés par des espaces et suivis d'un point `"."` :

```
?p1 foaf:name "Pierre-Antoine Champin" .
```

- cas particulier : le mot clé `"a"` en position de prédicat est un raccourci pour `<http://www.w3.org/1999/02/22-rdf-syntax-ns#type>` :

```
?p1 a foaf:Person .
```

- le retour à la ligne vaut pour une espace ; la structure est donnée par la ponctuation.

Factorisation

- On *peut* « factoriser » plusieurs triplets ayant le même sujet en séparant les couples <prédicat, objet> par un point-virgule `";"` :

```
<#pa> a foaf:Person ;
      foaf:givenName "Pierre-Anntoine" ;
      foaf:surname "Champin" .
```

- On *peut* « factoriser » plusieurs triplets ayant le même sujet et le même prédicat en séparant les objets par une virgule `","` :

```
<#pa> foaf:phone <tel:+33-472-44-82-40>, <tel:+33-472-69-21-73>.
```

- On peut bien sûr combiner les deux types de factorisation.
- On n'est jamais obligé de factoriser, on peut aussi répéter les termes.

Nœud muet

Lorsqu'un nœud muet n'a qu'un seul arc entrant, au lieu de lui inventer un identifiant local :

```
<#pa> foaf:know _:quelqun .
_:quelqun a foaf:Person ; foaf:name ?n .
```

on peut utiliser la notation `[]` :

```
<#pa> foaf:knows [
    a foaf:Person ;
    foaf:name ?n
] .
```

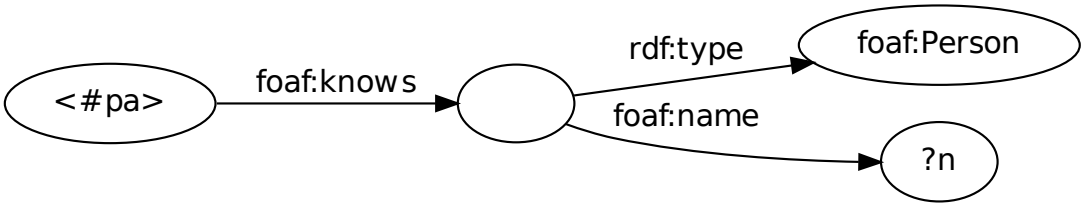

3.2.4 Sous-graphe optionel

En SPARQL, on peut accepter qu'une partie du graphe ne soit pas satisfaite :

```
?p1 a foaf:Person ; foaf:name ?n .
OPTIONAL { ?p1 foaf:phone ?tel }
```

3.2.5 Filtres

En SPARQL, on peut ajouter des contraintes sur les valeurs d'un graphe, avec la clause `FILTER`.

```
?p foaf:age ?a .
FILTER (?a >= 18)
```

On peut combiner des conditions avec les opérateurs logiques « et » (`&&`), « ou » (`||`) et « non » (`!`).

```
FILTER ( 20 <= ?a  &&  ?a < 30 )
```

Opérations utiles pour les filtres

- comparaisons : =, !=, <, >, <=, >=
- opérateurs arithmétiques : +, -, *, /
- nature d'un nœud : `isIRI`, `isBLANK`, `isLITERAL`, `isNUMERIC`
- vérifier qu'une variable (utilisée avec `OPTIONAL`) a bien une valeur : `Bound`
- recherche de texte : `REGEX(<variable>, <texte>)`

3.3 Requête SELECT

3.3.1 Présentation

- Similaire au SELECT de SQL :

  projection sur un sous-ensemble des variables du graphe
- Résultat : tableau
  - une colonne par variable sélectionnée
  - une ligne par résultat
- Structure :

  `SELECT <variables> WHERE { <graphe> }`

3.3.2 DISTINCT

```
SELECT DISTINCT ?sn
WHERE { <#pa> foaf:knows ?p. ?p foaf:surname ?sn. }
```

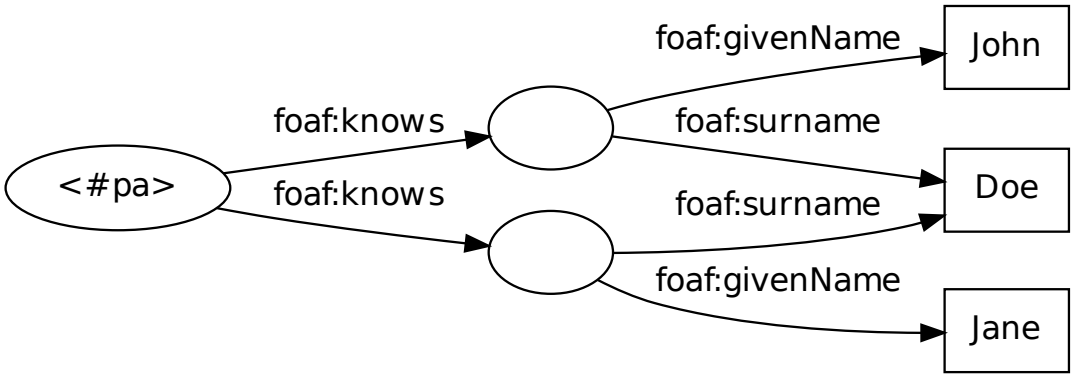

3.3.3 LIMIT et OFFSET

Pour obtenir les 10 premiers résultats :

```
SELECT ?p
WHERE { <#pa> foaf:knows ?p. }
LIMIT 10
```

Pour obtenir les 5 résultats suivants :

```
SELECT ?p
WHERE { <#pa> foaf:knows ?p. }
LIMIT 5 OFFSET 10
```

3.3.4 ORDER BY

```
SELECT ?p ?n
WHERE { <#pa> foaf:knows [ foaf:givenName ?p ; foaf:surname ?n ] }
ORDER BY ?n ?p
```

On peut aussi trier par ordre descendant :

```
SELECT ?p ?n
WHERE { <#pa> foaf:knows [ foaf:age ?age ] }
ORDER BY DESC(?age)
LIMIT 1
```

3.3.5 GROUP BY

Sert à *aggréger* certaines valeurs avec l'une des fonctions d'aggrégations : `Count`, `Sum`, `Avg`, `Min`, `Max`, `GroupConcat` et `Sample`.

```
SELECT ?p1 count(?p2)
WHERE { ?p1 foaf:knows ?p2 }
GROUP BY ?p1
```

On peut combiner `GROUP BY` avec `ORDER BY` et `LIMIT` (attention à l'ordre) :

```
SELECT ?p1 count(?p2)
WHERE { ?p1 foaf:knows ?p2 }
GROUP BY ?p1
ORDER BY DESC(count(?p2))
LIMIT 3
```

3.4 Autres types de requête

3.4.1 ASK

- Sert à demander si un graphe existe ou non dans la base.
- Résultat : vrai ou faux
- Structure :

  ```
  ASK { <graphe> }
  ```

3.4.2 CONSTRUCT

- Sert à construire un graphe à partir des résultat d'un autre
- Résultat : un graphe RDF
- Structure :

  ```
  CONSTRUCT { <graphe> } WHERE { <graphe> }
  ```

- Peut jouer un rôle similaire à XSL-T pour RDF

3.4.3 SPARQL Update

Depuis la version 1.1, possibilité de *modifier* les données.

3.5 Quelques requêtes utiles

3.5.1 Exploration des types de ressources

```
SELECT ?type count(?o)
WHERE { ?o a ?type }
GROUP BY ?type
ORDER BY DESC(count(?o))
LIMIT 30
```

3.5.2 Exploration des propriétés liées à un type

```
SELECT DISTINCT ?prop
WHERE { ?o a <http://example.org/UnType> ; ?prop ?val . }
LIMIT 30
```

CHAPTER

FOUR

MÉTA-VOCABULAIRES

author Pierre-Antoine Champin

4.1 Introduction

4.1.1 Motivation

Découverte de la sémantique d'un terme (IRI) en le déréférençant.

Exemple : `http://dbpedia.org/resource/James_Bond`

```
:James_Bond
    a dbo:FictionalCharacter ;
    dbo:creator :Ian_Fleming .
```

Ce principe s'applique également aux classes et aux prédicats.

4.1.2 Problème

Syndrome du dictionnaire : il faut pouvoir s'« arrêter » sur des termes connus.

> Nécessité d'un vocabulaire (ensemble de termes) permettant de décrire d'autres vocabulaires : **méta-vocabulaires**.

Analogie : XML-Schema est un vocabulaire XML dont la sémantique est connue *a priori*, et qui permet d'exprimer la structure de nouveaux vocabulaires.

4.1.3 Objectif

Expliciter *formellement* la sémantique des vocabulaires (en conformité avec la sémantique de RDF), afin de

- limiter les problèmes d'ambigüité sur les termes
- permettre leur découverte dynamique
  - relations sémantiques internes
- assurer l'interopérabilité
  - relations sémantiques avec d'autres vocabulaires

4.1.4 Exemples d'inférences

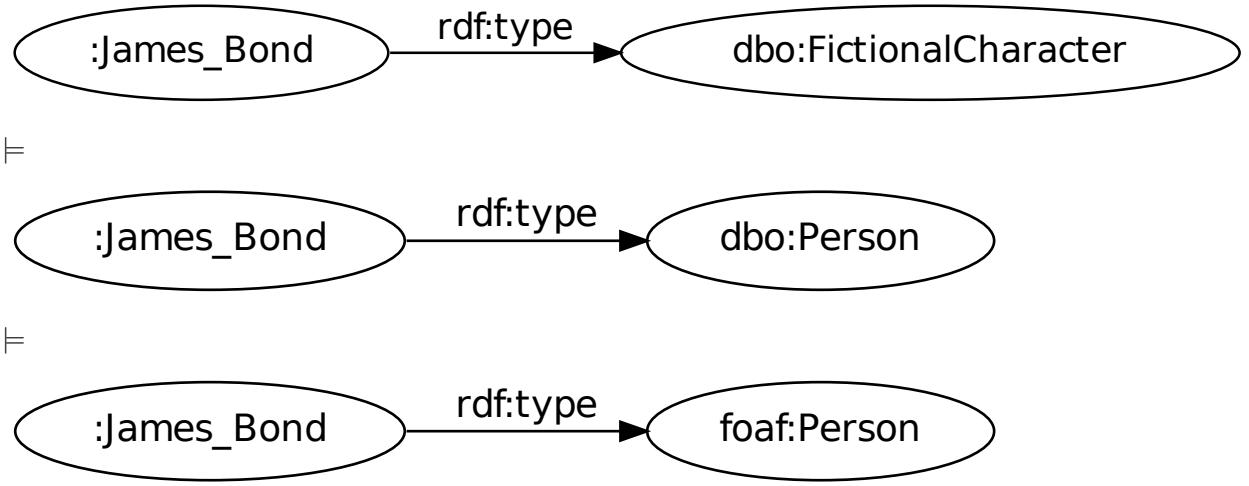

4.2 RDF-Schema

4.2.1 Présentation

- RDF-Schema (ou RDF-S) est une recommandation du W3C publiée en même temps que RDF (1999 et révisée en 2004).
- Il permet d'exprimer une hiérarchie de classes et une hiérarchie de propriétés (relations).

  $\rightarrow$ hiérarchie au sens *large* : treillis
- Il permet aussi d'exprimer des contraintes sémantiques sur les propriétés et les classes.

  /!\ contrainte sémantique $\neq$ contrainte d'intégrité

4.2.2 Escpaces de noms et préfixes

Suite à des circonvolutions historiques, le vocabulaire RDF-Schema utilise deux espaces de nom, associés respectivement aux préfixes suivants :

```
@prefix rdf:    <http://www.w3.org/1999/02/22-rdf-syntax-ns#>
@prefix rdfs:   <http://www.w3.org/2000/01/rdf-schema#>
```

4.2.3 rdf:type

`rdf:type` indique l'appartenance d'une ressource à une classe.

Exemple :

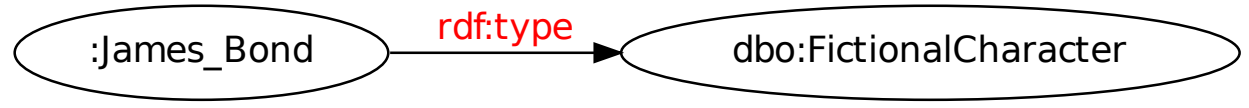

4.2.4 rdfs:subClassOf

`rdfs:subClassOf` indique une relation une spécialisation entre classes (« est une sorte de », ou « tous les X sont des Y »).

Exemple :

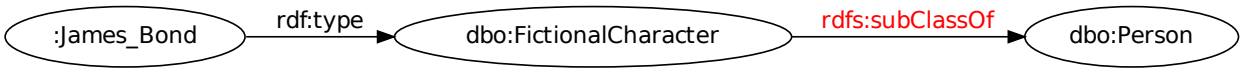

⊨

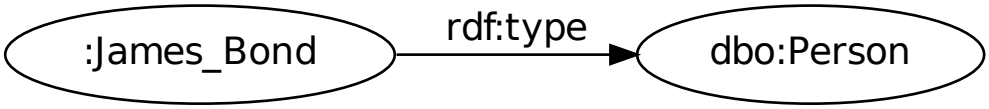

4.2.5 rdfs:subPropertyOf

`rdfs:subPropertyOf` indique une relation une spécialisation entre propriétés (« est une sorte de »).

Exemple :

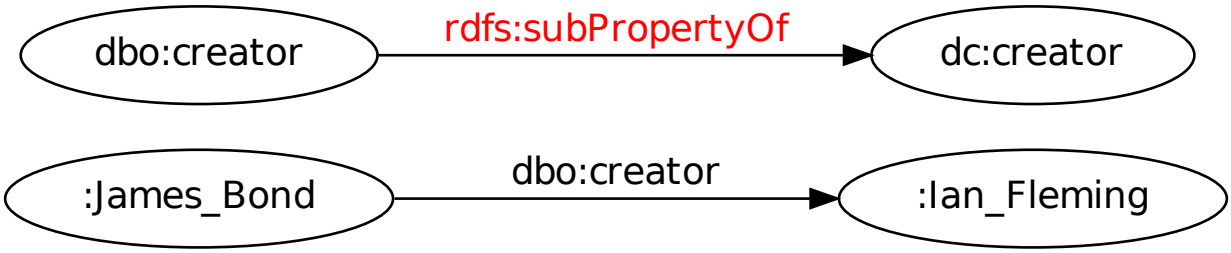

⊨

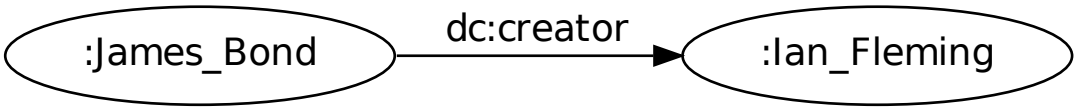

4.2.6 rdfs:domain

Indique qu'une propriété porte nécéssairement sur les instance d'une classe.

Exemple :

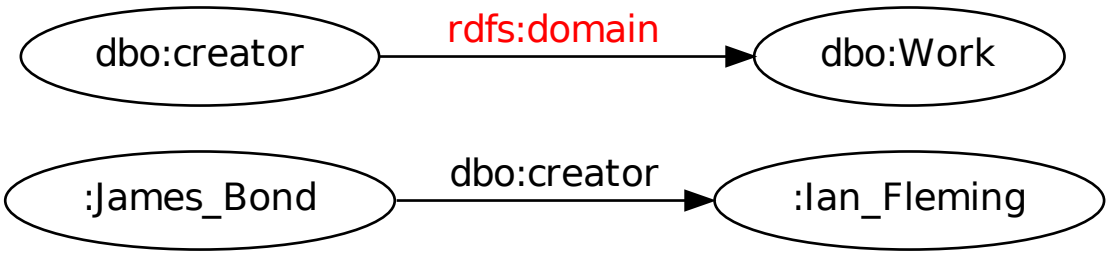

⊨

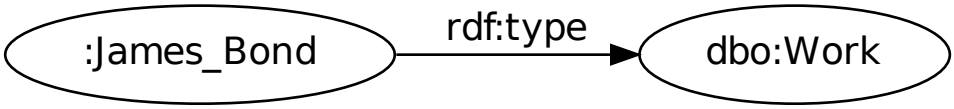

4.2.7 rdfs:range

Indique qu'une propriété a nécéssairement pour valeur les instance d'une classe.

Exemple :

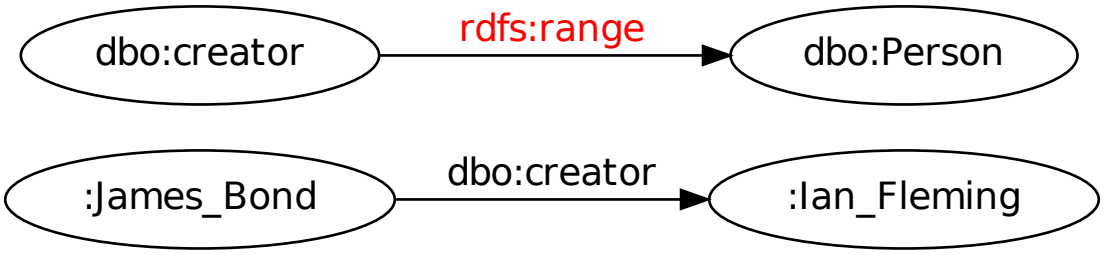

$\models$

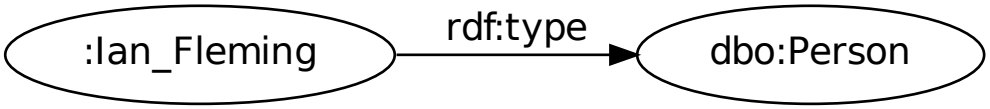

4.2.8 Documentation

RDF-Schema fournit aussi des termes pour *documenter* un vocabulaire :

- `rdfs:label` permet d'associer un libellé textuel à un URI (éventuellement plusieurs, par exemple dans plusieurs langues) ;
- `rdfs:comment` permet d'associer un commentaire textuel plus long ;
- `rdfs:seeAlso` permet de pointer vers une autre ressource.

4.2.9 Méta-modélisation

Rien n'empêche, en RDF-S, d'avoir une classe qui soit elle même une instance d'une autre classe (méta-classe). C'est d'ailleurs de cette manière que les classes sont identifiées.

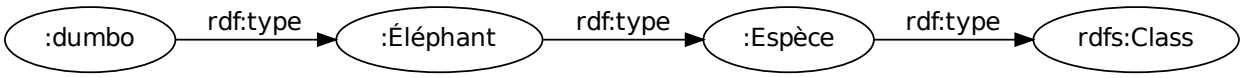

4.2.10 Contrainte sémantique $\neq$ contraintes d'intégrité

Les méta-propriétés `rdfs:domain` et `rdfs:range` ne servent *pas* à vérifier qu'un graphe serait « valide ». Il ne permettent que d'*inférer* des faits supplémentaires.

- Comme RDF-S n'a pas de négation, ceci n'entraîne jamais d'incohérence *formelle*.

  $\rightarrow$ en d'autre termes, la sémantique de RDF-S ne permet pas de détecter les incohérences (conceptuelles) que pourraient entrainer ces inférences.

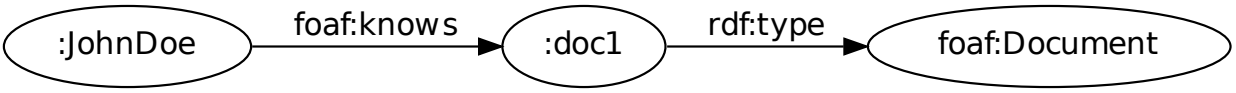

4.3 OWL

4.3.1 Présentation

OWL (Web Ontology Language) a été recommandé par le W3C en 2004, et sa version 2 en 2009.

- C'est un méta-vocabulaire (comme RDF-S) inspiré des **logiques de descriptions** avec valeurs concrètes (littéraux).
- Il définit plusieurs *profils* offrant des compromis différents en terme d'expressivité et de complexité.
- Il mime les capacités de méta-modélisation de RDF-S (*punning*).

4.3.2 owl:sameAs

Indique que deux IRIs dénotent la même ressource.

Exemple :

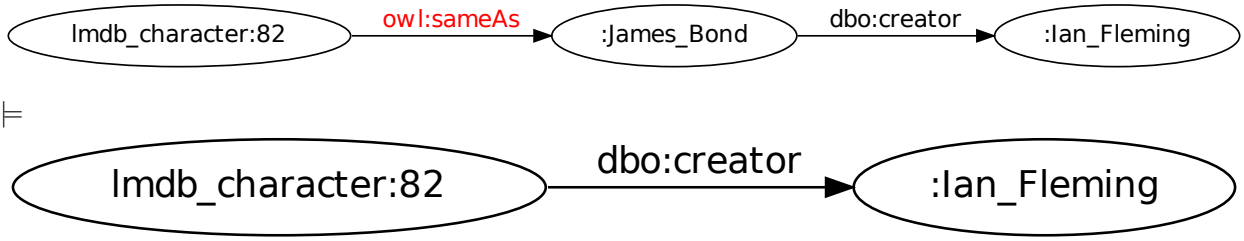

⊨

INDEX

R