

# Web de données et RDA



# Le Web de données ?

- Un Web constitué de données accessibles, structurées, dans un format non-propriétaire, identifiées et liées entre elles sémantiquement  
*(Définition de Tim Berners-Lee dès 1999)*
- Objectif : Mettre à disposition des données en utilisant des techniques standardisées qui garantissent l'interopérabilité (utilisabilité dans des contextes et avec des systèmes différents sans restriction de conditions d'accès ou de mise en œuvre)

# Architecture du Web (1)

- **World Wide Web** : toile d'araignée de serveurs d'informations reliés les uns aux autres par des liens physiques (le réseau matériel) et des liens logiques (les liens hypertextes)
- **Architecture du Web** = les standards définissant l'infrastructure technologique
- Rôle du **W3C (World Wide Web Consortium)** : s'occupe de la standardisation de l'architecture du Web

# Les objectifs du W3C

- **Accessibilité** pour les logiciels et machines
  - Interopérabilité et portabilité
  - Production de contenu Web facilitée
  - Réduction du volume des pages
  - Meilleure visibilité et indexation par les moteurs de recherche
  - Compatibilité
  - Pérennité des documents
  - Validation des pages par des services de validation pour garantir la cohérence et la qualité du code
- **Accessibilité** universelle aux contenus


# Architecture du Web (2)

- **Repose sur 3 technologies :**
- **URI** (Uniform Resource Identifier)
  - Chaîne de caractères normalisés permettant d'identifier de manière permanente une ressource abstraite ou physique, accessible ou non sur Internet (personne, organisme, lieu, évènement, concept, ...)
  - 3 déclinaisons :
    - **URC** (Uniform Resource Characteristic) : caractéristiques d'une ressource
    - **URN** (Uniform Resource Name) : nom d'une ressource
    - **URL** (Uniform Resource Locator) : spécification de l'adresse physique de localisation d'une ressource sur Internet et de la méthode permettant d'y accéder
- **HTTP** (Hypertext Transfer Protocol)
- **HTML** (Hypertext Markup Language) : standard défini par le W3C pour la diffusion de documents sur le Web pour pouvoir afficher de l'information à l'aide de balises dont le nombre est limité. Il est interprété par le navigateur


# Une histoire : Web 1.0

- Web 1.0 = Web documentaire
    - Web statique
      - 1 page = 1 document
      - Traitement des ressources limité à leur mise en forme
      - Navigation entre les pages avec les liens hypertexte
- **Limites du Web statique**
- Contenu non structuré
  - Pas de possibilité de requête
  - Impossibilité de renvoyer une page personnalisée selon le visiteur
  - Impossibilité d'exploiter les ressources d'une base de données

# Web statique



# Une évolution : le Web dynamique



# Le Web 2.0

• **Pratiquement aujourd'hui tous les sites sont dynamiques**

- Exploitation de volumes importants d'informations (bases de données, moteurs de recherche)
- Personnalisation de l'accès à l'information
- Naissance du **Web 2.0** = Web contributif
  - Les utilisateurs font partie du processus documentaire
  - Ajout de connaissances et de commentaires aux contenus

# Le Web 3.0

- Extension du Web permettant de relier non pas des documents (pages HTML) mais les données elles-mêmes, et de les rendre exploitables par des machines
- Repose sur les mêmes technologies de base
  - **URI** : nommage des ressources
  - **HTTP** : transfert des données
- Mais :
  - Evolution du langage de balisage : il ne s'agit plus d'échanger des documents destinés à être immédiatement visualisés mais des données structurées
  - **XML (eXtensible Markup Language)** :
    - Format textuel d'échanges de documents et données structurées lisible par les machines
    - Chacun peut définir la structure et le balisage
    - Garantit l'interopérabilité, la portabilité et l'extensibilité des données et de leur structure
- Construction du Web de données liées grâce au langage **RDF** = 1 modèle et plusieurs syntaxes dont une en **XML**

# RDF = Resource Description Framework

- Nouveau modèle généraliste et standardisé pour encoder, échanger et réutiliser des métadonnées structurées
- Proposé en 1999 par le W3C
- Langage dans lequel on décrit, représente et relie des ressources (= données) à échanger sur le Web
- Permet de décrire des ressources simplement : document, personne, objet, évènement
- **Objectif** : partager les mêmes métadonnées pour des ressources partagées par utilisation d'une syntaxe commune

# RDF : un modèle conceptuel (1)

- Principe de base : toute chose peut être décrite avec des phrases minimales composées d'un verbe, d'un sujet et d'un complément = **déclaration RDF**

## Exemple :

Honoré de Balzac a écrit "La Comédie humaine"

## Sujet : Honoré de Balzac ⇒ Ressource

**Verbe** : a écrit ⇒ **Predicat**

## Complément : La Comédie humaine ➔ Objet

# RDF : un modèle conceptuel (2)

- Modèle de données élémentaires constitué de 3 types d'objets :
  - **Ressource** : toute chose décrite par une expression RDF = entité d'information pouvant être identifiée par un identificateur (URI)
  - **Propriété** : caractéristique, attribut ou relation utilisé pour décrire une ressource
  - **Déclaration** : association d'une propriété à une ressource

# RDF : la notion de triplet

- Une déclaration est composée de 3 éléments  
= **triplet**
- **Triplet {ressource – propriété – valeur}**
  - **sujet** = ressource
  - **predicat** = propriété : nature de la relation
  - **objet** = valeur : caractéristique ou ressource liée

Exemple :

Sujet (Ressource) : Honoré de Balzac

Predicat (Propriété) : Creator

Objet (Valeur) : La Comédie humaine


# RDF : Graph

- La déclaration est représentée visuellement par un graphe (système de nœuds reliés par des flèches) qui permet de parcourir l'information de lien en lien



# RDF : modèle de graphe

- Chaque membre du triplet est une ressource qui peut être le sujet ou l'objet d'autres déclarations
- On construit ainsi un modèle de graphe



# Formalisme RDF (1)

- Modèle permettant de représenter un nombre considérable de ressources désignées par un URI
- Eclatement de l'information
  - Des données et pas des « documents »
  - Plus de souplesse pour manipuler, sélectionner...

# Formalisme RDF (2)

- Mais, des inconvénients :
  - Problème pour la création et la maintenance des URI
  - Complexité pour représenter certaines déclarations, les périodes, les provenances, l'absence d'information, globalement, tout ce qui nécessiterait un 4<sup>e</sup> élément dans le triplet
    - Exemples :
      - Jacques Chirac a été président de la République française de 1995 à 2007
      - Ce livre a été publié en 1981 par l'IGN à Paris et par la Chambre d'Agriculture de l'Indre à Blois
      - La date de publication de ce livre est inconnue mais doit se situer entre 1917 et 1923 selon la source X

# RDF : un langage extensible

- Cadre conceptuel de description des ressources applicable à n'importe quel domaine d'application
- Peut être exprimé en utilisant la syntaxe **RDF/XML** (eXtensible Markup Language) : seule syntaxe qui fait l'objet actuellement d'une recommandation du W3C


# Syntaxe RDF

## exemple : métadonnées de la DCMI

- <?xml version="1.0" encoding="iso-8859-1" ?>
- <!DOCTYPE rdf:RDF PUBLIC "-//DUBLIN CORE//DCMES DTD 2002/07/31//EN" "http://dublincore.org/documents/2002/07/31/dcmes-xml/dcmes-xml-dtd.dtd">
- <rdf:RDF xmlns:rdf="http://www.w3.org/1999/02/22-rdf-syntax-ns#" xmlns:dc ="http://purl.org/dc/elements/1.1/">
- 
- <rdf:Description rdf:about="http://www.w3.org">
- <dc:Title>L'avenir des méta-tags</dc:Title>
- <dc:Description> Avenir des métadonnées </dc:Description>
- <dc:Publisher>W3C</dc:Publisher>
- <dc:Date>2004-02-10</dc:Date>
- <dc:subject>Avenir des métadonnées</dc:subject>
- <dc:Type>World Wide Web Home Page</dc:Type>
- <dc:Format>text/html</dc:Format>
- <dc:Language>en</dc:Language>
- </rdf:Description>
- </rdf:RDF>


# RDF (1) : Structurer l'information

700 \$311914283 \$aMann\$bThomas\$f1875-1955\$4070  
200 1 \$aDer Tod in Venedig\$bTexte imprimé\$fThomas Mann




## RDF (2) : Nommer les ressources avec des identifiants URI

<http://catalogue.bnf.fr/ark:/12148/cb350037659>




# RDF (3) : définir les relations entre les ressources en utilisant des vocabulaires normalisés

<http://catalogue.bnf.fr/ark:/12148/cb350037659>



# RDF (4) : Nommer les relations avec des URIs

<http://catalogue.bnf.fr/ark:/12148/cb350037659>



# RDF (5) : Exprimer le tout avec une syntaxe normalisée

@prefix dc: < <http://purl.org/dc/terms/>>

@prefix foaf: < <http://xmlns.com/foaf/0.1/>>

<http://catalogue.bnf.fr/ark:/12148/cb350037659> dc:creator <http://catalogue.bnf.fr/ark:/12148/cb119142833>.

<http://catalogue.bnf.fr/ark:/12148/cb119142833> foaf:familyName  
“Mann”;

foaf:givenName “Thomas”.

<http://catalogue.bnf.fr/ark:/12148/cb350037659> dc:title “Der Tod in  
Venedig”.

# Web de données et Web sémantique

- **Web de données** : possibilité de relier et d'échanger des données identifiées par des URI
- **Web sémantique** : possibilité d'échanger les schémas des données et la sémantique associée
  - Objectif : permettre aux machines de comprendre la sémantique, la signification de l'information sur le Web

C'est très bien tout ça mais...  
Quel rapport avec la bibliothèque, le catalogue, le catalogage ?

Zoom sur  
Le lecteur



# Les bibliothèques dans le Web de données aujourd’hui



Occupons l'espace !!

# Que peut nous apporter le Web de données ?

- Relier les catalogues des bibliothèques avec d'autres données existantes
- Ouverture à d'autres communautés (libraires, éditeurs, ...)
- Navigation par les utilisateurs sans avoir à connaître les formats des bases de données et les langages de requête spécifiques
- Plus de visibilité par les moteurs de recherche
- Tirer parti des données structurées des catalogue et des référentiels
- Interopérabilité = Souplesse pour la réutilisation des données