BDBIO - XML et XQuery

Fabien Duchateau

fabien.duchateau [at] univ-lyon1.fr

Université Claude Bernard Lyon 1

2024 - 2025

https://perso.liris.cnrs.fr/fabien.duchateau/BDBIO/

Rappels

Les données d'application sont principalement gérées par des systèmes de gestion de bases de données (SGBD), qui suivent un modèle de données

Modèle	**Sérialisation**	**LDD**	**LMD**	**Exemples SGBD**
Relationnel	n-uplets	SQL	SQL	SQLite, MariaDB, PostgreSQL

Rappels

Les données d'application sont principalement gérées par des systèmes de gestion de bases de données (SGBD), qui suivent un modèle de données

Modèle	**Sérialisation**	**LDD**	**LMD**	**Exemples SGBD**
Relationnel	n-uplets	SQL	SQL	SQLite, MariaDB, PostgreSQL

Comment modéliser et interroger des SGBD qui suivent d'autres modèles de données ?

Aperçu des notions de BDBIO

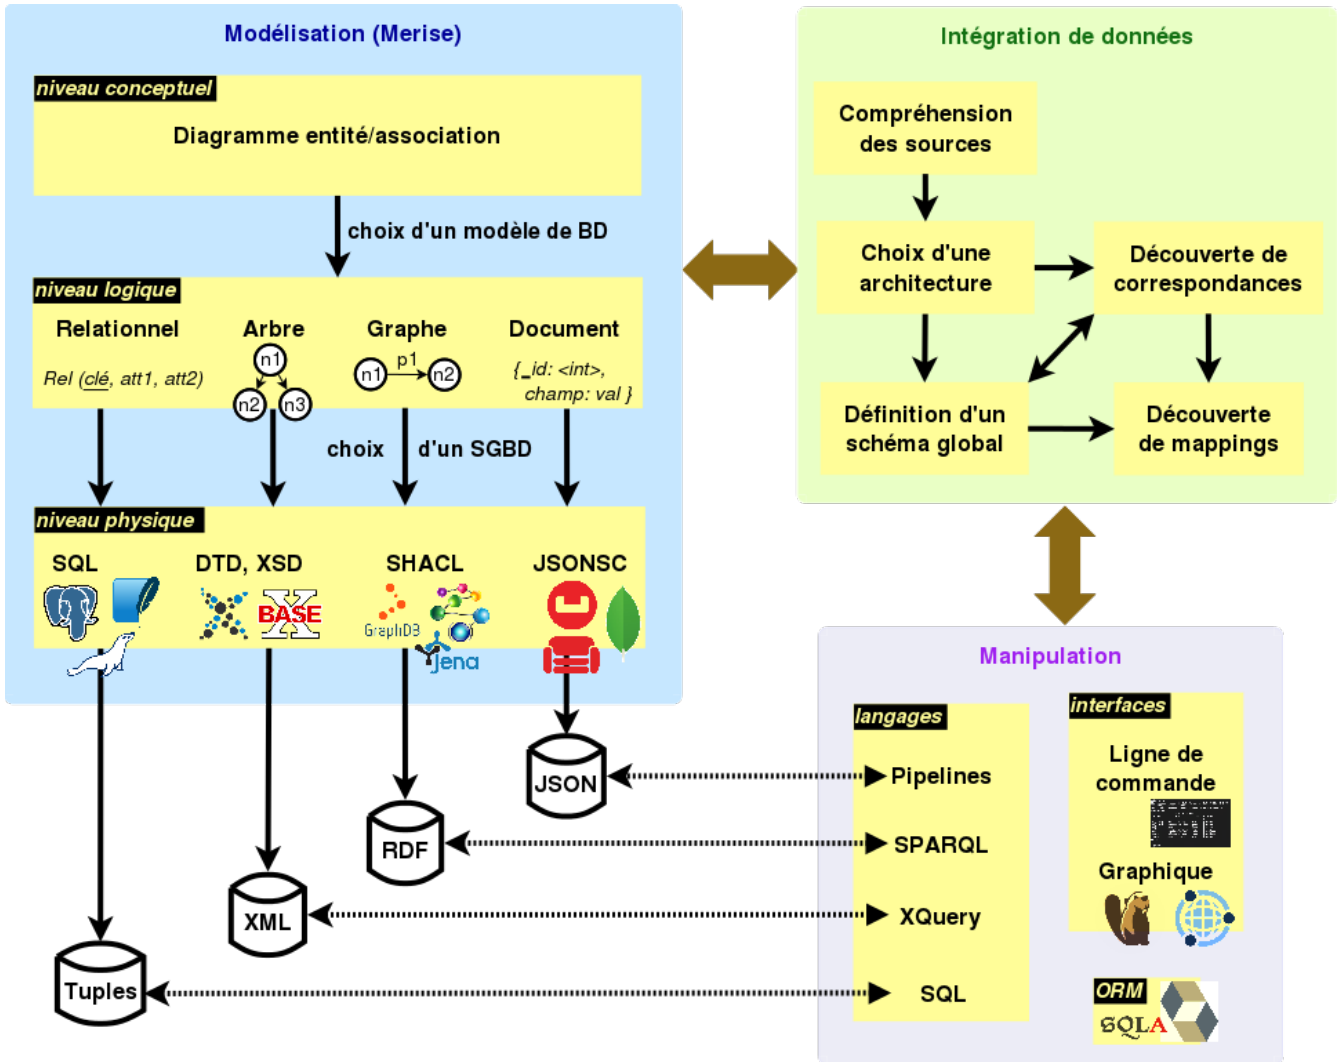

Ces diapositives utilisent le genre féminin (e.g., chercheuse, développeuses) plutôt que l'écriture inclusive (moins accessible, moins concise, et pas totalement inclusive)

Le langage XML

- XML pour e**X**tensible **M**arkup **L**anguage
- Standard W3C depuis 2008
- Langage de balisage (avec les chevrons)
- Initialement développé pour faciliter l'interopérabilité et le stockage (échange de données, sérialisation)
- Quelques SGBD basés sur le stockage de documents XML

---

http://fr.wikipedia.org/wiki/Extensible_Markup_Language
http://en.wikipedia.org/wiki/Serialization

Technologies XML

XML regroupe un ensemble de technologies :

- Description d'un document (DTD, XML schema)
- Sélection d'une partie d'un document (XPath)
- Interrogation de document (XQuery)
- Transformation de document (XSLT)
- API pour manipuler un document (DOM pour une représentation en arbre, SAX par déclenchement d'événements)
- ...

---

http://en.wikipedia.org/wiki/XML#Related_specifications
http://en.wikipedia.org/wiki/XML#Programming_interfaces

SGBD natifs XML

Quelques SGBD orientés document (mouvement NoSQL, post-relationnel) utilisent un document XML comme unité de stockage (logique)

- BaseX
- eXist
- Berkeley DB XML

---

http://en.wikipedia.org/wiki/XML_database
http://basex.org/
http://www.exist-db.org/
http://www.oracle.com/database/berkeley-db/xml.html

Plan

Concepts de XML

Modélisation en XML

Manipulation avec XPath

Manipulation avec XQuery

Définition

Un document XML correspond à un ensemble de données organisées dans un **arbre**

- Format textuel
- Extension de fichier : `.xml`
- Considéré compréhensible à la fois par les humains et les machines
- Syntaxe à base de balises (comme en HTML)
  - balise par paire (`<div>...</div>`)
  - balise orpheline (`<img />`)

Exemple de document simple

```
<?xml version="1.0" encoding="utf-8"?>
<collection>
    <bd id="1">
        <auteure>Fmurrr</auteure>
        <titre>Sabotage et pâturage</titre>
        <annee>1995</annee>
    </bd>
</collection>
```

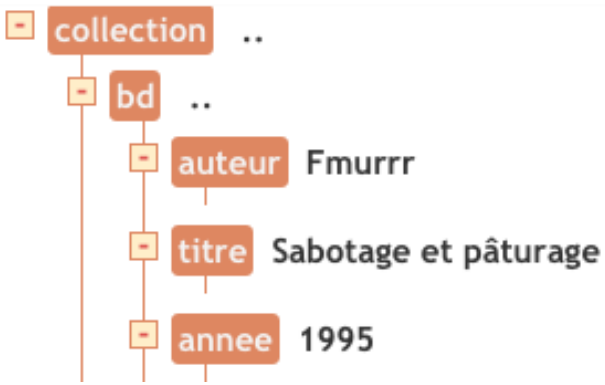

Un simple document avec son entête, un élément `<collection>` qui contient un élément `<bd>`. L'élément `<bd>` est décrit par trois propriétés (éléments et texte)

Types de noeuds XML

Un arbre XML possède différents types de noeuds :

- **Racine** = document complet. Elle possède exactement un noeud élément contenant les données
- **Élément** = noeud possédant un nom (balise). Il peut posséder des noeuds filles de tous types (sauf racine)
- **Attribut** = noeud sous forme `nom="valeur"` et qui est rattaché à la balise ouvrante d'un élément. Pour un élément donné, impossible d'avoir deux attribut portant le même nom
- **Texte** entre une balise ouvrante et une fermante
- **Commentaire**

Syntaxe XML

- Un prologue optionnel (indications pour la lecture du document)

```
<?xml version="1.0" encoding="utf-8" ?>
```

- Des éléments imbriqués pouvant contenir des attributs
  - l'ordre entre les noeuds enfants est significatif
  - l'ordre entre les noeuds attributs (d'un même élément) n'est pas important

```
<element attribut="valeur">…</element>
<element attribut="valeur" attribut2="valeur" />
```

Exemple de syntaxe XML

```xml
<?xml version="1.0" encoding="utf-8"?>
<racine attribut1="valeur1" attribut2="valeur2">
    <!-- commentaire -->
    <element1>
        texte1
    </element1>
    <element2 attribut3="valeur3" />
    <prefixe:element3 attribut4="valeur4">
        texte2
    </prefixe:element3>
</racine>
```

Un exemple de document XML avec les différents types de noeuds

Espaces de nom XML

Un espace de nom est une URI qui permet d'éviter les ambiguïtés sur les noms XML (issus de vocabulaires / schémas différents)

- Nom qualifié = `prefixe:nom`, où `prefixe` est une référence vers une URI
- Nom sans préfixe = nom local, dont l'espace de nommage est celui du schéma
  - s'il n'y a pas d'espace pour le schéma, le nom n'a pas d'espace de nommage

---

http://en.wikipedia.org/wiki/XML_namespace
http://en.wikipedia.org/wiki/Uniform_Resource_Identifier

Syntaxe des espaces de nom XML

Un espace de nom est précisé par l'attribut `xmlns`

```
<element xmlns:prefix=URI>
<element xmlns=URI>
```

- Un espace de nom défini pour un élément est disponible pour tous les enfants de cet élément
- Sans préfixe, l'espace de nommage est celui par défaut

```
<root xmlns:espace1="uri1" xmlns:espace2="uri2">
    <espace1:element>
        <!-- cette balise element vient du vocabulaire de uri1 -->
    </espace1:element>
    <espace2:element>
        <!-- cette balise element vient du vocabulaire de uri2 -->
    </espace2:element>
</root>
```

Exemples d'espaces de nom XML

```
<?xml version="1.0" encoding="utf-8"?>
<collection xmlns="http://www.bd.db/">
    <bd id="1" xmlns:sch="http://schema.org/">
        <auteure>Fmurrr</auteure>
        <titre>Sabotage et pâturage</titre>
        <annee>1995</annee>
        <sch:numberOfPages>47</sch:numberOfPages>
        <editeur>Dargaud</editeur>
    </bd>
</collection>
```

Un espace de nom par défaut (pour `<auteur>`, `<titre>`, etc.), et un préfixe `sch` associé à un autre espace de nom uniquement pour l'élément `<bd>`

Plan

Concepts de XML

Modélisation en XML

Manipulation avec XPath

Manipulation avec XQuery

Modélisation XML

- Des modèles conceptuels pour XML : XSEM, TreeModel, ERX, EReX, etc.
- Des extensions du diagramme E/A ou du diagramme de classe UML : XER
- Des propositions de conversion de relationnel vers XML

Mais pas de pratique bien établie pour modéliser en XML !

Chen, Haitao, and Husheng Liao. *"A survey to conceptual modeling for XML"*. ICCSIT (2010)

M. Franceschet et al. *"From Entity Relationship to XML Schema : a graph-theoretic approach"*. XSym (2009)

J. Fong et al. *"Translating relational schema with constraints into XML schema"*. International Journal of Software Engineering and Knowledge Engineering (2006)

Schémas pour XML

En XML, un schéma est un ensemble de contraintes structurelles que doit vérifier un document XML pour être valide :

- Noeuds attribut ou noeuds enfants autorisés pour un élément
- Type de valeurs pour les noeuds attribut et noeud texte
- Noeuds attribut ou noeuds enfants obligatoires pour un élément
- ...

Plusieurs langages pour la définition d'un schéma en XML

---

http://en.wikipedia.org/wiki/Data_model

Langages de schéma pour XML

Différents langages de schéma pour des données XML :

- DTD (Document Type Definition)
- XML Schema ou XSD (XML Schema Definition)
- Relax NG : un langage simplifié

Exemples de schémas publics :

- XHTML, RSS
- SVG
- OpenDocument, OpenXML

---

http://schema.org/
http://en.wikipedia.org/wiki/Document_type_definition
http://en.wikipedia.org/wiki/List_of_types_of_XML_schemas
http://en.wikipedia.org/wiki/RELAX_NG

Document Type Definition (DTD)

- Une DTD précise la structure d'un document XML valide et les balises autorisées (grammaire) ainsi que les nouveaux termes (vocabulaire supplémentaire)
- Une DTD est incluse dans le document XML ou dans un fichier externe (extension `.dtd`)
- Syntaxe spécifique
- Limitations par rapport à d'autres schémas (e.g., type de données, contrainte complexes)

---

http://en.wikipedia.org/wiki/Document_type_definition
http://www.w3.org/TR/REC-xml/#sec-prolog-dtd
http://www.w3schools.com/xml/xml_dtd_intro.asp

Exemple de DTD

```
<!DOCTYPE collection [
<!ELEMENT collection (serie*)>
<!ELEMENT serie (nom, tome*)>
<!ATTLIST serie id ID #REQUIRED>
<!ELEMENT nom (#PCDATA)>
<!ELEMENT tome (auteure+, titre, annee?, genre*)>
<!ATTLIST tome numero CDATA #IMPLIED>
<!ELEMENT auteure (#PCDATA)>
<!ELEMENT titre (#PCDATA)>
<!ELEMENT annee (#PCDATA)>
<!ELEMENT genre (#PCDATA)>
]>
```

L'élément racine est `collection`, et contient 0 ou plusieurs `séries`. Une série possède un seul `nom`, et 0 ou plusieurs `tomes`. La série a également un attribut obligatoire `id` de type `ID`. Le nom de la série est une chaîne de caractère (#PCDATA). Un tome contient au moins une `auteure`, un `titre`, une `année` optionnelle et 0 ou plusieurs genres. Un tome possède aussi un attribut `numero` optionnel de type chaîne (#CDATA), etc.

XML Schema (XSD)

- XML Schema Definition
- Extension de fichier : `.xsd`
- Par rapport au langage DTD :
  - XSD est un fichier XML, donc facilite le "parsing"
  - XSD permet le typage des données et ajoute de nouvelles contraintes
  - possibilité de référencer d'autres schémas
  - langage assez complexe

---

http://en.wikipedia.org/wiki/XML_Schema_(W3C)
http://www.w3.org/TR/xmlschema-2/

Exemples d'éléments simples en XML Schema

```
<xsd:element name="dateNaissance" type="xsd:date" />
<xsd:element name="dateParution" type="xsd:gYearMonth" />
<!-- ... -->
<dateNaissance>2000-01-31</dateNaissance><!-- 31/01/2000 -->
<dateParution>2004-06</dateParution><!-- juin 2004 -->
```

Définition de deux éléments typés (lignes 80 et 81) et exemples d'instance pour ces définitions (lignes 83 et 84)

```
<xsd:attribute name="numéro" type="xsd:ID" />
<xsd:attribute name="tomes" type="xsd:IDREFS" />
<!-- ... -->
<bd numero="11">Sabotage et pâturage</bd>
<bd numero="13">Cheptel maudit</bd>
<serie tomes="11 13">Le génie des alpages</serie>
```

Définition d'attributs typés (lignes 87 et 88) et exemples d'instances pour ces définitions (lignes 90 à 92). Les éléments qui sont autorisés à utiliser un attribut sont définis par des types

Exemple d'élément complexe en XML Schema

Un élément complexe avec contenu texte est composé d'un texte (valeur entre les balises) et d'éventuels attributs

```
<xsd:element name="titre">
    <xsd:complexType>
        <xsd:simpleContent>
            <xsd:extension base="xsd:string" />
        </xsd:simpleContent>
    </xsd:complexType>
</xsd:element>
<!-- ... -->
<titre>Sabotage et pâturage</titre>
```

Définition d'un élément complexe avec un texte de type chaine (lignes 111 à 117) et exemples d'instance pour cette définition (ligne 119)

Exemple d'élément complexe en XML Schema (2)

Un élément complexe avec contenu éléments est composé d'un ou plusieurs éléments et d'éventuels attributs

```
<xsd:element name="bd">
    <xsd:complexType>
        <xsd:all>
            <xsd:element name="auteure" type="xsd:string"/>
            <xsd:element name="titre" type="xsd:string"/>
            <xsd:element name="annee" type="xsd:gYear"/>
        </xsd:all>
        <xsd:attribute name="numero" type="xsd:ID"/>
    </xsd:complexType>
</xsd:element>
```

Définition d'un élément complexe "bd" contenant trois éléments (obligatoires et uniques) et un attribut

Lier un document XML à un schéma

```xml
<?xml version="1.0" encoding="utf-8"?>
<collection xmlns="http://www.bd.db/"
    xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance"
    xsi:schemaLocation="http://www.bd.db/unSchema.xsd">
<!-- ... -->
</collection>
```

Document XML contenant un lien vers un schéma XML avec espace de nom

```xml
<?xml version="1.0" encoding="utf-8"?>
<collection xmlns="http://www.bd.db/"
    xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance"
    xsi:noNamespaceSchemaLocation="unSchema.xsd">
<!-- ... -->
</collection>
```

Document XML contenant un lien vers un schéma XML sans espace de nom

Exemple de modélisation - imbrication totale

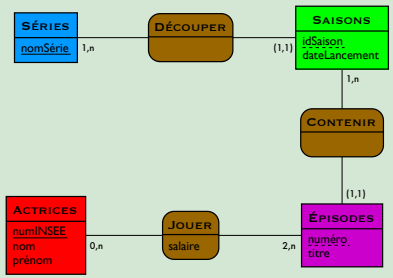

Diagramme E/A (niveau conceptuel)

Exemple de modélisation - imbrication totale

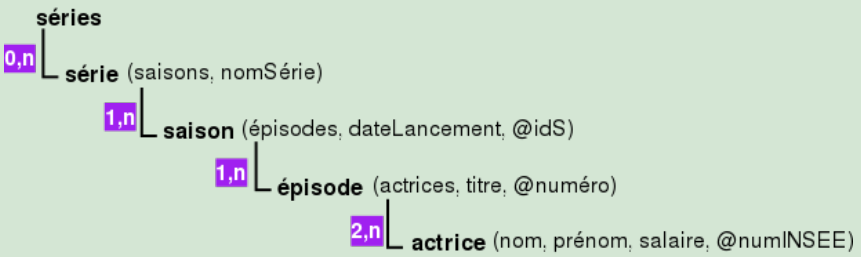

Représentation libre (niveau logique)

Exemple de modélisation - imbrication totale

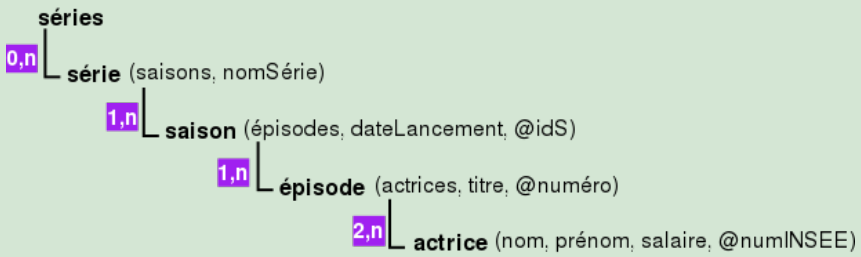

Représentation libre (niveau logique)

DTD (niveau physique)

```
<!DOCTYPE collection [
<!ELEMENT séries (série*)>
<!ELEMENT série (nomSérie, saisons)>
<!ELEMENT nomSérie (#PCDATA)>
<!ELEMENT saisons (saison+)>
<!ELEMENT saison (dateLancement, épisodes?)>
<!ATTLIST saison idS ID #REQUIRED>
<!ELEMENT dateLancement (#PCDATA)>
<!ELEMENT épisodes (épisode+)>
<!ELEMENT épisode (titre, actrices)>
<!ATTLIST épisode numéro CDATA #REQUIRED>
<!ELEMENT titre (#PCDATA)>
<!ELEMENT actrices (actrice+)>
<!ELEMENT actrice (nom, prénom, salaire)>
<!ATTLIST actrice numINSEE ID #REQUIRED>
<!ELEMENT nom (#PCDATA)>
<!ELEMENT prénom (#PCDATA)>
<!ELEMENT salaire (#PCDATA)>
]>
```

Exemple de modélisation - imbrication totale

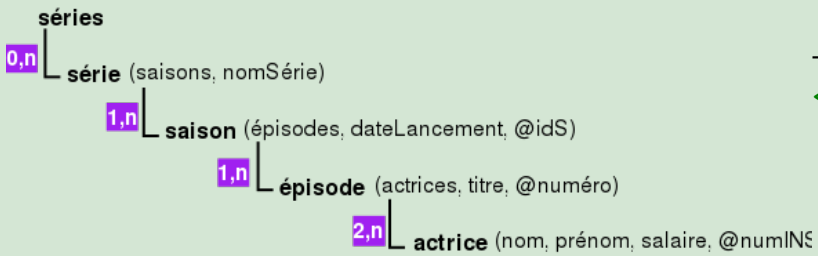

Représentation libre (niveau logique)

DTD (niveau physique)

```
<!DOCTYPE collection [
<!ELEMENT séries (série*)>
<!ELEMENT série (nomSérie, saisons)>
<!ELEMENT nomSérie (#PCDATA)>
<!ELEMENT saisons (saison+)>
<!ELEMENT saison (dateLancement, épisodes?)>
<!ATTLIST saison idS ID #REQUIRED>
<!ELEMENT dateLancement (#PCDATA)>
<!ELEMENT épisodes (épisode+)>
<!ELEMENT épisode (titre, actrices)>
<!ATTLIST épisode numéro CDATA #REQUIRED>
<!ELEMENT titre (#PCDATA)>
<!ELEMENT actrices (actrice+)>
<!ELEMENT actrice (nom, prénom, salaire)>
<!ATTLIST actrice numINSEE ID #REQUIRED>
<!ELEMENT nom (#PCDATA)>
<!ELEMENT prénom (#PCDATA)>
<!ELEMENT salaire (#PCDATA)>
]>
```

Exemple de document (données)

```
<séries>
    <série>
        <nomSérie>Love, death and
        ↪ robots</nomSérie>
        <saisons>
            <saison idS="123">
                <dateLancement>2019</dateLancement>
                <épisodes>
                    <épisode numéro="1">
                        <titre>Sonnie's
                        ↪ Edge</titre>
                        <actrices>
                            <actrice
                            ↪ numINSEE="12345">
                                <nom>Sadler</nom>
                                <prénom>Helen<prénom>
                                <salaire>3000</salaire>
                            </actrice>
                            ...
                        </actrices>
                    </épisode>
                    ...
                </épisodes>
            </saison>
            ...
        </saisons>
    </série>
    ...
</séries>
```

Exemple de modélisation - concept Actrice hors de Série

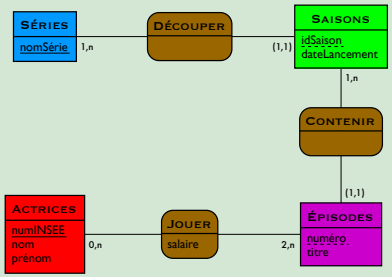

Diagramme E/A (niveau conceptuel)

Exemple de modélisation - concept Actrice hors de Série

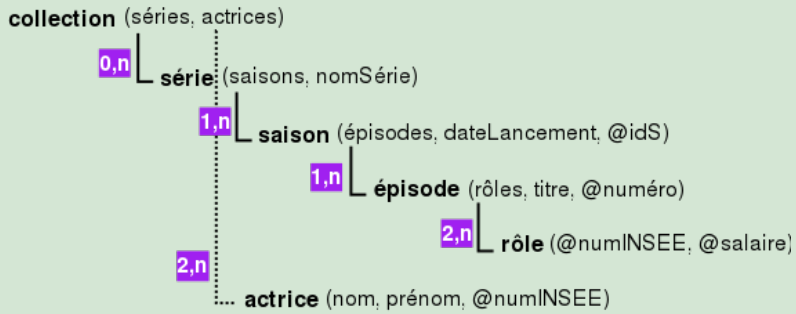

Représentation libre (niveau logique)

Exemple de modélisation - concept Actrice hors de Série

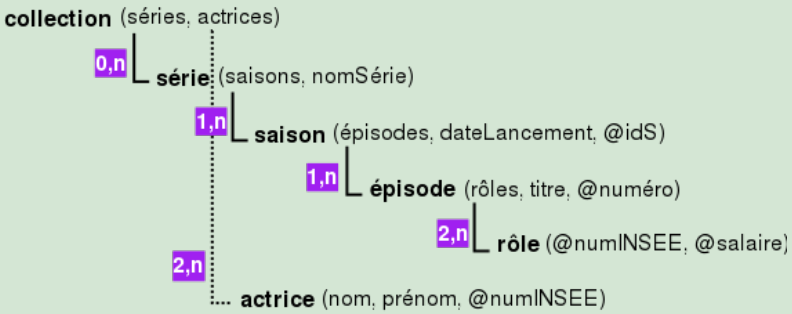

Représentation libre (niveau logique)

DTD (niveau physique)

```
<!DOCTYPE collection [
<!ELEMENT bd (séries, actrices)>
<!ELEMENT séries (série*)>
<!ELEMENT série (nomSérie, saisons)>
<!ELEMENT nomSérie (#PCDATA)>
<!ELEMENT saisons (saison+)>
<!ELEMENT saison (dateLancement, épisodes?)>
<!ATTLIST saison idS ID #REQUIRED>
<!ELEMENT dateLancement (#PCDATA)>
<!ELEMENT épisodes (épisode+)>
<!ELEMENT épisode (titre, roles)>
<!ATTLIST épisode numéro CDATA #REQUIRED>
<!ELEMENT titre (#PCDATA)>
<!ELEMENT roles (role+)>
<!ELEMENT role EMPTY>
<!ATTLIST role numINSEE IDREF #REQUIRED>
<!ATTLIST role salaire CDATA #IMPLIED>
<!ELEMENT actrices (actrice+)>
<!ELEMENT actrice (nom, prénom)>
<!ATTLIST actrice numINSEE ID #REQUIRED>
<!ELEMENT nom (#PCDATA)>
<!ELEMENT prénom (#PCDATA)>
]>
```

Exemple de modélisation - concept Actrice hors de Série

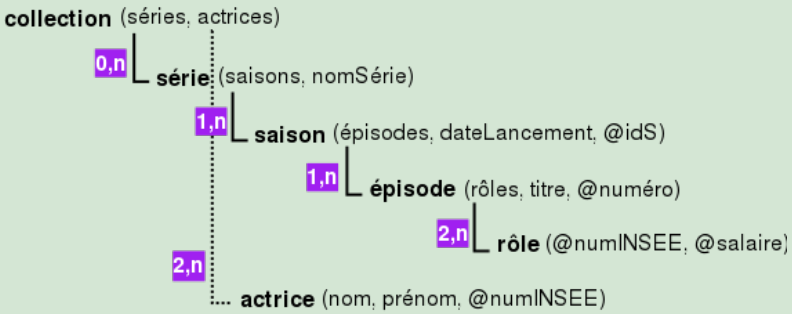

Représentation libre (niveau logique)

DTD (niveau physique)

```
<!DOCTYPE collection [
<!ELEMENT bd (séries, actrices)>
<!ELEMENT séries (série*)>
<!ELEMENT série (nomSérie, saisons)>
<!ELEMENT nomSérie (#PCDATA)>
<!ELEMENT saisons (saison+)>
<!ELEMENT saison (dateLancement, épisodes?)>
<!ATTLIST saison idS ID #REQUIRED>
<!ELEMENT dateLancement (#PCDATA)>
<!ELEMENT épisodes (épisode+)>
<!ELEMENT épisode (titre, roles)>
<!ATTLIST épisode numéro CDATA #REQUIRED>
<!ELEMENT titre (#PCDATA)>
<!ELEMENT roles (role+)>
<!ELEMENT role EMPTY>
<!ATTLIST role numINSEE IDREF #REQUIRED>
<!ATTLIST role salaire CDATA #IMPLIED>
<!ELEMENT actrices (actrice+)>
<!ELEMENT actrice (nom, prénom)>
<!ATTLIST actrice numINSEE ID #REQUIRED>
<!ELEMENT nom (#PCDATA)>
<!ELEMENT prénom (#PCDATA)>
]>
```

Exemple de document (données)

```
<bd>
    <séries>
        <série>
            <nomSérie>Love, death and
            ↪ robots</nomSérie>
            <saisons>
                <saison idS="123">
                    <dateLancement>2019</dateLancement>
                    <épisodes>
                        <épisode numéro="1">
                            <titre>Sonnie's
                            ↪ Edge</titre>
                            <roles>
                                <role
                                ↪ numINSEE="12345"
                                ↪ salaire="3000" />
                                ...
                            </roles>
                        </épisode>
                        ...
                    </épisodes>
                </saison>
                ...
            </saisons>
        </série>
        ...
    </séries>
    <actrices>
        <actrice numINSEE="12345">
            <nom>Sadler</nom>
            <prénom>Helen<prénom>
        </actrice>
        ...
    </actrices>
</bd>
```

En résumé

- Modèles conceptuels pour XML peu utilisés
- Définition d'un schéma pour un document XML :
  - DTD (grammaire et vocabulaire, mais pas de contraintes de validité)
  - XML Schema (XSD), plus avancé que DTD
- Plusieurs manières d'écrire un schéma (différents langages, mais aussi différents choix de modélisation)
- En pratique, de nombreux documents XML ne possèdent pas de schéma associé

Plan

Concepts de XML

Modélisation en XML

Manipulation avec XPath

Manipulation avec XQuery

Généralités

XML Path Language (XPath) :

- Sélection de morceaux d'un document XML
- Utilisé par d'autres langages comme XQuery ou XSLT ou par des bibliothèques (Python, Java, etc.)
- Expression XPath : chemins dans l'arbre XML pour sélectionner les noeuds intéressants
  - chemins similaires à la syntaxe de chemin de fichiers sous Unix
- Une version compacte (mais limitée) et une version complète (mais verbeuse)

---

http://fr.wikipedia.org/wiki/XPath
http://www.w3.org/TR/xpath-3/

Exemples

```xml
<?xml version="1.0" encoding="utf-8"?>
<collection>
    <bd id="1">
        <auteure>Fmurrr</auteure>
        <titre>Sabotage et pâturage</titre>
        <annee>1995</annee>
    </bd>
</collection>
```

Quelques exemples d'expressions XPath :

```
/collection/bd
//auteure
collection/bd/annee[text() = 1995]/parent::node()
```

Syntaxe (complète)

`axe::test[prédicat]/ … /axe::test[prédicat]`

- Expression XPath = suite d'étapes
- Étape = `axe::test[prédicat]`, avec le prédicat optionnel
- Évaluation d'une expression XPath :
  - soit à partir du noeud courant
  - soit à partir de la racine si l'expression commence par un slash (e.g., `/collection`)

Chaque étape de l'expression XPath modifie l'ensemble des noeuds sélectionnés

---

La syntaxe compacte ne respecte pas cette syntaxe (utilisation de raccourcis)

Axes

Un axe indique la direction de navigation dans l'arbre

Axes en arrière (remontent dans l'arbre) :

- `ancestor` pour les ancêtres du noeud courant
- `ancestor-or-self`
- `parent`
- `preceding` pour les noeuds qui précédent le noeud courant, hors ancêtres
- `preceding-sibling` pour les noeuds de même parent et qui précédent le noeud courant

---

http://en.wikipedia.org/wiki/XPath#Axis_specifiers
http://www.w3.org/TR/xpath-3/#axes

Axes (2)

Axes en avant (descendent dans l'arbre) :

- `attribute` pour les attributs du noeud courant
- `child` pour les enfants du noeud courant
- `descendant` pour les descendants du noeud courant
- `descendant-or-self`
- `following` pour les noeuds qui suivent le noeud courant, hors descendants
- `following-sibling` pour les noeuds de même parent et qui suivent le noeud courant
- `self` pour le noeud courant

Tests de noeud

Un test de noeud sélectionne, parmi les noeuds désignés par l'axe, ceux avec un nom ou un type donné

- *nom* pour les éléments avec le nom donné
- `*` pour tous les noeuds élément
- `node()` pour tous les noeuds
- `attribute()` pour tous les éléments de type attribut
- `text()` pour tous les éléments de type texte
- ...

---

http://en.wikipedia.org/wiki/XPath#Node_tests
http://www.w3.org/TR/xpath-3/#dt-node-test

Prédicat

Un prédicat filtre les noeuds sélectionnés en évaluant une expression booléenne (similaire au WHERE de SQL)

- Vrai si l'expression retourne un résultat non vide
- L'expression peut :
  - combiner différentes conditions (`and`, `or`)
  - utiliser des fonctions booléennes
  - être un chemin (évalué à partir du noeud à tester)
  - utiliser des fonctions non booléennes (avec éventuellement un chemin comme argument)

---

http://en.wikipedia.org/wiki/XPath#Predicates
http://www.w3.org/TR/xpath-3/#dt-predicate

Quelques abréviations de syntaxe

- `..` ↔ `parent::node()`
- `.` ↔ `self::node()`
- `//` ↔ `descendant-or-self::node()/`
- `balise` ↔ `child::balise`
- `@att` ↔ `attribute::att`
- `[X]` ↔ `[fn:position() = X]`
- ...

Exemples XPath

Tous les titres de tome (sans la balise titre) :

```
//titre/text()
```

Les tomes avec un genre :

```
//tome[genre]
```

Le nom des séries avec un tome 13 :

```
//serie[tome/@numero = 13]/nom
```

Les tomes avec un genre et un numéro supérieur ou égal à 1 :

```
//tome[genre and @numero >= 1]
```

Le titre des tomes dont le numéro est inférieur à 12 :

```
//tome[@numero <= 12]/titre
```

```
<collection>
  <serie id="1">
    <nom>Le génie des alpages</nom>
    <tome numero="11">
      <auteure>Fmurrr</auteure>
      <titre>Sabotage et pâturage</titre>
      <annee>1995</annee>
    </tome>
    <tome numero="13">
      <auteure>Fmurrr</auteure>
      <titre>Cheptel maudit</titre>
      <annee>2004</annee>
    </tome>
  </serie>
  <serie id="2">
    <nom>Tu mourras moins bête</nom>
    <tome numero="1">
      <auteure>Marion Montaigne</auteure>
      <titre>La science, c'est pas du cinéma!</titre>
      <annee>2011</annee>
      <genre>Humour</genre>
    </tome>
  </serie>
</collection>
```

Fonctions

- `fn:round(num)` arrondit *num* à l'entier le plus proche
- `fn:position()` retourne la position d'un noeud
- `fn:not(expr)` retourne vrai si *expr* est fausse
- `[fn:contains(foin, aiguille)]` est vrai si la chaine *foin* contient la chaine *aiguille*
- `fn:count(elem, elem, …)` retourne le nombre de noeuds
- …

---

http://www.w3schools.com/xml/xsl_functions.asp

Exemples de fonctions XPath

Le nombre de séries :

```
/collection/fn:count(node())
ou fn:count(//serie)
```

Les tomes en seconde position :

```
//tome[2]
```

Les séries dont un noeud textuel commence par "T" :

```
//serie[descendant::node()
[fn:starts-with(child::text(), "T")]]
```

Les séries dont aucun noeud textuel ne commence par "T" :

```
//serie[fn:not(descendant::node()[fn:starts-with(
child::text(), "T")])]
```

```
<collection>
  <serie id="1">
    <nom>Le génie des alpages</nom>
    <tome numero="11">
      <auteure>Fmurrr</auteure>
      <titre>Sabotage et pâturage</titre>
      <annee>1995</annee>
    </tome>
    <tome numero="13">
      <auteure>Fmurrr</auteure>
      <titre>Cheptel maudit</titre>
      <annee>2004</annee>
    </tome>
  </serie>
  <serie id="2">
    <nom>Tu mourras moins bête</nom>
    <tome numero="1">
      <auteure>Marion Montaigne</auteure>
      <titre>La science, c'est pas du cinéma!</titre>
      <annee>2011</annee>
      <genre>Humour</genre>
    </tome>
  </serie>
</collection>
```

Plan

Concepts de XML

Modélisation en XML

Manipulation avec XPath

Manipulation avec XQuery

Généralités

XML Query (XQuery) :

- Langage de manipulation pour des documents XML (utilisé par les SGBD XML)
- Fabrication de (morceaux de) documents XML à partir de données XML
- Standard W3C, basé sur XPath
- Requêtes FLWOR contenant 5+ clauses

---

https://www.w3.org/TR/2017/REC-xquery-31-20170321/#id-flwor-expressions

https://fr.wikipedia.org/wiki/XQuery

https://www.w3schools.com/xml/xquery_intro.asp

https://www.martinbroadhurst.com/open-source-xquery-implementations.html

Syntaxe FLWOR

for $var **in** chemin_xpath ou intervalle
let var_1$:= val$_1$, ..., var_n$:= val$_n$
where condition
order by expression
return expression_xquery

- `for` pour sélectionner une séquence de noeuds, chaque élément étant stocké dans la variable $var
- `let` pour lier une séquence à une variable (sans itération)
- `where` pour filtrer les noeuds (prédicats reliés par *and*/*or*)
- `order by` pour trier les noeuds (*ascending*, *descending*)
- `return` pour retourner un résultat par noeud (seule clause obligatoire)

---

http://www.w3schools.com/xml/xquery_select.asp

Comparaisons et fonctions en XQuery

- Deux symboles pour les mêmes comparaisons :
  - =, !=, <, <=, >, >= (comparaison vérifiée au moins une fois)
  - eq, ne, lt, le, gt, ge (comparaison vérifiée obligatoirement une seule fois)
- Possibilité d'un `if - then - else` dans la clause `return`
- Mêmes fonctions et opérateurs que XPath : *fn :round()*, *fn :contains()*, *fn :substring()*, etc.

```
for $x in doc("collection.xml")/collection/serie/tome
where $x/annee > 2000 and contains($x/auteure/text(), "g")
order by $x/titre
return $x/titre
```

La fonction `doc()` permet d'ouvrir un document XML, elle est ici suivie directement d'une expression XPath

http://www.w3schools.com/xml/xsl_functions.asp

Exemple de requête FLWOR

```
for $to in //tome
let $ti := $to/titre
where $to/@numero > 5
order by $ti descending
return
    <album>{$to/@numero}
        {$ti}
        <serie>{$to/../nom/text()}</serie>
    </album>
```

```
<collection>
  <serie id="1">
    <nom>Le génie des alpages</nom>
    <tome numero="11">
      <auteure>Fmurrr</auteure>
      <titre>Sabotage et pâturage</titre>
      <annee>1995</annee>
    </tome>
    <tome numero="13">
      <auteure>Fmurrr</auteure>
      <titre>Cheptel maudit</titre>
      <annee>2004</annee>
    </tome>
  </serie>
  <serie id="2">
    <nom>Tu mourras moins bête</nom>
    <tome numero="1">
      <auteure>Marion Montaigne</auteure>
      <titre>La science, c'est pas du cinéma!</titre>
      <annee>2011</annee>
      <genre>Humour</genre>
    </tome>
  </serie>
</collection>
```

Exemple de requête FLWOR

```
for $to in //tome
let $ti := $to/titre
where $to/@numero > 5
order by $ti descending
return
    <album>{$to/@numero}
        {$ti}
        <serie>{$to/../nom/text()}</serie>
    </album>
```

```
<collection>
  <serie id="1">
    <nom>Le génie des alpages</nom>
    <tome numero="11">
      <auteure>Fmurrr</auteure>
      <titre>Sabotage et pâturage</titre>
      <annee>1995</annee>
    </tome>
    <tome numero="13">
      <auteure>Fmurrr</auteure>
      <titre>Cheptel maudit</titre>
      <annee>2004</annee>
    </tome>
  </serie>
  <serie id="2">
    <nom>Tu mourras moins bête</nom>
    <tome numero="1">
      <auteure>Marion Montaigne</auteure>
      <titre>La science, c'est pas du cinéma!</titre>
      <annee>2011</annee>
      <genre>Humour</genre>
    </tome>
  </serie>
</collection>
```

```
<album numero="11">
  <titre>Sabotage et pâturage</titre>
  <serie>Le génie des alpages</serie>
</album>
<album numero="13">
  <titre>Cheptel maudit</titre>
  <serie>Le génie des alpages</serie>
</album>
```

Le résultat (clause `return`) mélange des balises XML avec des expressions XQuery pour construire un nouveau document

Bilan
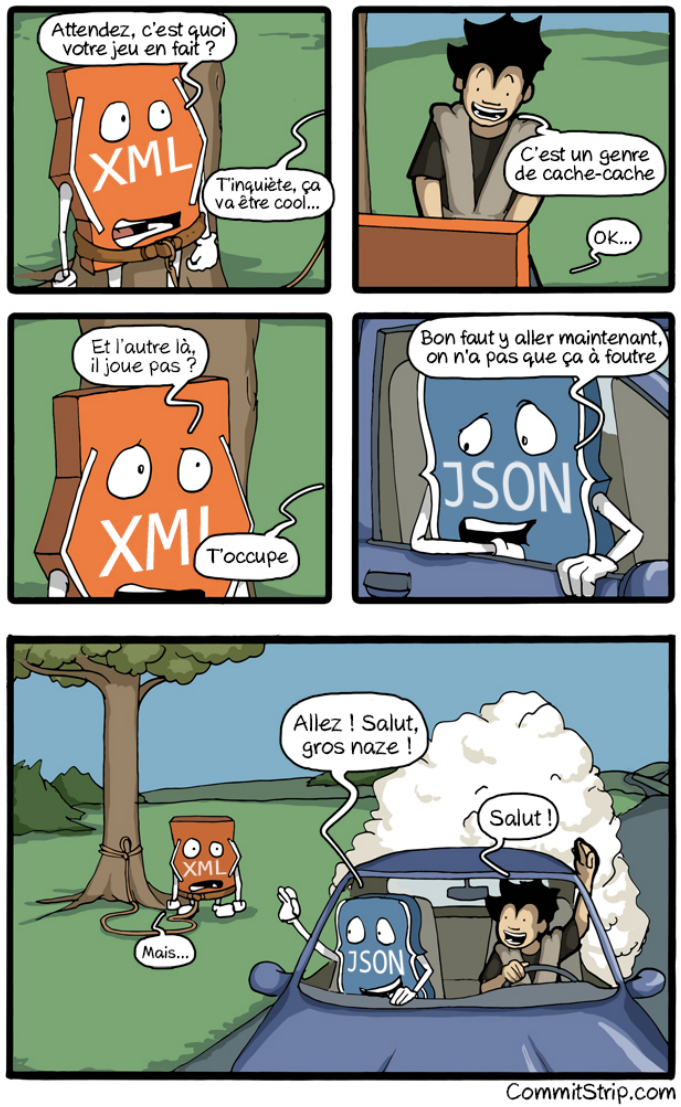
- Syntaxe d'un document XML
- Définition d'un schéma pour un document avec DTD ou XSD
- Sélection de chemins dans un document avec XPath
- Interrogation de document avec XQuery
- Interrogation d'arbre avec d'autres modèles (e.g., JSONpath, jq)