Documents XML
Description - Manipulation

Elisabeth Murisasco
murisasco@univ-tln.fr

Programme du cours (7 CM, 5 TD)

- Introduction
  - Documents structurés, XML, Bases de données
- Documents XML : description et manipulation
  - Description de documents
  - Typage – *Xschema*
  - Modélisation -- *XDM*
  - Localisation de composants XML -- *XPath*
  - Transformation de documents XML -- *XSLT*
  - Interrogation de documents XML -- *XQuery*

XQuery

http://www.w3.org/TR/xquery

http://www.w3.org/TR/xquery-semantics

http://www.w3.org/TR/xpath-functions

Cours en ligne de Bernd Amman LIP6, Jacques Le Maitre LSIS, Georges Gardarin, Prism, Benjamin Nguyen Prism

Objectifs

- Comment interroger/manipuler des documents XML ?
  - SQL : stocker XML dans une BDR
  - XPath : extraction de fragments d’arbres
  - XSLT : Extraction + transformation (règles)
- Un vrai langage de requêtes XML
  - Le « SQL » de XML
  - XQuery 1.0 recommandation de janvier 2007 (langage typé)
    - À partir de plusieurs propositions (depuis 1994)
  - Véritable langage de programmation, très puissant

Document XML

```
<guide>...
   <itinéraire numéro="6">
      <nom>Col d'Izoard</nom>
      <commentaire>Cette montée pédestre, au haut lieu du cyclotourisme, vous évite les
lacets de la route et, du fond du vallon du torrent d'Izoard, vous permet d'admirer,
loin des foules et de la motorisation, les rochers déchiquetés de la Casse Déserte
(carneules).</commentaire>
      <cotation>1</cotation>
      <départ>
         <lieu>Brunissard</lieu>
         <altitude>1760</altitude>
      </départ>
      <arrivée>
         <lieu>Col d'Izoard</lieu>
         <altitude>2360</altitude>
      </arrivée>
      <temps unité="heure">2</temps>
      <montée>De <lieu>Brunissard<lieu> remonter (NW) la route de l'Izoard, <lieu>D
902</lieu>, jusqu'au premier virage de l'entrée des bois ...</montée>
      <descente> Sur <lieu>Brunissard<lieu> par l'itinéraire de montée. Sur Cervières,
par le <lieu>refuge d'Izoard<lieu> et la route <lieu>D 902</lieu>, sur le versant Nord
du col.</descente>
   </itinéraire>
...
</guide>
```

On suppose le document XML précédent lié à la variable $guide

Exemple de requête

Numéro et nom des itinéraires au départ de Brunissard

```
<réponse>                                              (1)
    {
    for $i in $guide/guide/itinéraire                  (2)
    where $i/départ/lieu = 'Brunissard'                (3)
    return                                             (4)
     <itinéraire>                                      (5)
      {<numéro>$i/@numéro</numéro>}                    (6)
      {$i/nom}                                         (7)
     </itinéraire>                                     (8)
    }
</réponse>                                             (9)
```

On suppose le document XML précédent lié à la variable $guide

Exemple de requête

Numéro et nom des itinéraires au départ de Brunissard

```
<réponse>                                                    (1)
    {
    for $i in $guide/guide/itinéraire                        (2)
    where $i/départ/lieu = 'Brunissard'                      (3)
    return                                                   (4)
     <itinéraire>                                            (5)
      {<numéro>$i/@numéro</numéro>}                          (6)
      {$i/nom}                                               (7)
     </itinéraire>                                           (8)
    }
</réponse>                                                   (9)
```

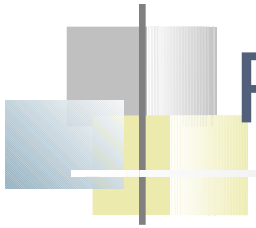

Résultat

Numéro et nom des itinéraires au départ de Brunissard

```
<réponse>
    ...
    <itinéraire>
      <numéro>6</numéro>
      <nom>Col d'Izoard</nom>
    </itinéraire>
    ...
</réponse>
```

Le FLWR intuitivement – Forme de base

for `i` **in** `s` **where** `cond` **return** `i'`

- L'opérateur *for...where...return* itère sur les items `i` de la séquence `s` et construit une séquence de nouveaux items `i'`
  - Pour chaque `i` de `s`, si `cond` est vérifiée, `i'` est construit
- Analogie forte avec SQL

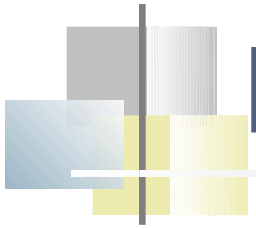

Expressions XQuery

- Une requête XQuery est une composition d’expressions
- Chaque expression a une valeur ou retourne une erreur
- La valeur d’une expression est une instance du modèle XDM
  - une séquence de 0 ou plusieurs items
- Les expressions n’ont pas d’effets de bord (par exemple, de mise à jour)

Expressions XQuery

- Une expression est construire à partir :
  - De constantes littérales (chaînes, nombres)
  - De noms de variable
  - D’opérateurs (sur les nœuds, arithmétiques, etc.)
  - De chemins de localisation
  - De fonctions prédéfinies etc.

Modèle de données

- Commun à XPath et XQuery
- Une valeur (une instance du modèle) est une séquence ordonnée d’items
- Un item est soit un nœud, soit une valeur atomique
- Une valeur atomique est une instance d’un type atomique (cf.XSchema)
- Chaque nœud et chaque valeur a un type

Modèle de données

- Une séquence peut être vide (séquence vide)

  ```
  ()
  ```

- Il y a équivalence entre un item et une séquence singleton (une séquence de 1 item)

  ```
  12=(12)
  ```

- Les séquences sont plates : elles ne sont pas imbriquées

  ```
  (12, (3,5), <exemple/>, "exemple") =
  (12, 3, 5, <exemple/>, "exemple")
  ```

- Les séquences sont triées

  `(3,5)` est différent de `(5,3)`

Expressions simples (requêtes)

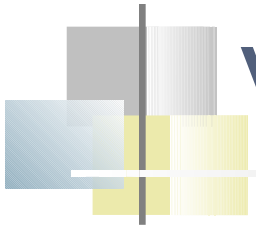

Valeurs atomiques

- Valeurs atomiques
  - nombres `12` `3.14` `2.602e-19`
  - chaînes `"salut"`
- Valeurs construites

```
fn:true()
xs:date("2008-03-03")
```

Variable

- Référence à une variable v

  $v

  Retourne la valeur la plus récemment liée à la variable *v*

- Déclaration de variables globales

  ```
  declare variable $v := <exp>
  ```

  ```
  declare variable $doc := doc('docs/xmpbib.xml')
  ```

Quelques premiers opérateurs

- Opérateurs arithmétiques

  `+ - * div(`attention `/` réservé`) idiv mod`

  `1+2  3.4-6.5  $x mod 2`

- Opérateurs de comparaison pour valeurs atomiques, nœuds et séquences

  `5 gt 7.5` → `FALSE`

  La comparaison est effectuée après la conversion de 5 en xs:float

- Opérateurs booléens

  `$x=2 and $y=4`

  `$x=2 or $y=4`

  `fn:not(1 and 1)` → `FALSE`

Premiers opérateurs

- Séquences d'entiers exp_1 `to` exp_2
  - `()` si la valeur de exp_1 ou de exp_2 égale `()`
  - si les valeurs de exp_1 et exp_2 sont convertibles en deux entiers n_1 et n_2
    - `()` si $n_1 > n_2$
    - séquence des entiers de n_1 à n_2 si $n_2 \geq n1$

```
3 to 7      ->          3,4,5,6,7
13 to 7     ->          ()
```

Premiers opérateurs

- Opérations sur les séquences
  - concaténation exp_1, exp_2

    séquence constituée des items de la séquence valeur de exp_1 suivis des items de la séquence valeur de exp_2

```
1+2, 4-2, 3*2    ->        3,2,6

((9,1), 5, (8,2)) ->      (9,1,5,8,2)
```

Expressions complexes

- Expressions de chemin (XPath 2.0)
- Constructeurs de nœuds
- Opérateurs
- Expressions FLWR (`for-let-where-return`)
- Expressions conditionnelles - tests (`if-then-else`)

Expressions complexes

- Fonctions
  - nom(exp$_1$,…,exp$_n$)
  - Racines : `collection("url")` `doc("url")`
    - `fn:doc` retourne le nœud racine du document dont l'URL est donné en argument

      ```
      declare variable $bib := fc:doc(xmpbib.xml)
      ```
    - `fn:collection` retourne la séquence de nœuds contenus dans la ressource dont l'URL est donné en argument
  - Fonctions prédéfinies
    - XQuery 1.0 and XPath 2.0 functions and operators
  - Fonctions définies par les utilisateurs

Expressions de chemin

Valeur : une séquence de nœuds

Un cas d'usage : sa DTD

```
<!ELEMENT bib (book* )>
<!ELEMENT book (title, (author+ | editor+ ), publisher, price )
   >
<!ATTLIST book year CDATA #REQUIRED >
<!ELEMENT author (last, first )>
<!ELEMENT editor (last, first, affiliation )>
<!ELEMENT title (#PCDATA )>
<!ELEMENT last (#PCDATA )>
<!ELEMENT first (#PCDATA )>
<!ELEMENT affiliation (#PCDATA )>
<!ELEMENT publisher (#PCDATA )>
<!ELEMENT price (#PCDATA )>
```

```
<bib>
    <book year="1999">
        <title>The Economics of Technology and Content for Digital TV</title>
        <editor>
                <last>Gerbarg</last><first>Darcy</first>
                <affiliation>CITI</affiliation>
        </editor>
        <publisher>Kluwer Academic Publishers</publisher>
        <price>129.95</price>
    </book>
    <book year="1994">
        <title>TCP/IP Illustrated</title>
        <author><last>Stevens</last><first>W.</first></author>
        <publisher>Addison-Wesley</publisher>
        <price> 65.95</price>
    </book>
    <book year="1992">
        <title>Advanced Programming in the Unix environment</title>
        <author><last>Stevens</last><first>W.</first></author>
        <publisher>Addison-Wesley</publisher>
        <price>65.95</price>
    </book>
    <book year="2000">
        <title>Data on the Web</title>
        <author><last>Abiteboul</last><first>Serge</first></author>
        <author><last>Buneman</last><first>Peter</first></author>
        <author><last>Suciu</last><first>Dan</first></author>
        <publisher>Morgan Kaufmann Publishers</publisher>
        <price>39.95</price>
    </book>
</bib>
```

Expressions de chemin

Requête

```
doc("biblio.xml")//author

$bib//author
```

Réponse

```
<author><last>Stevens</last><first>W.</first></author>
<author><last>Stevens</last><first>W.</first></author>
<author><last>Abiteboul</last><first>Serge</first></author>
<author><last>Buneman</last><first>Peter</first></author>
<author><last>Suciu</last><first>Dan</first></author>
```

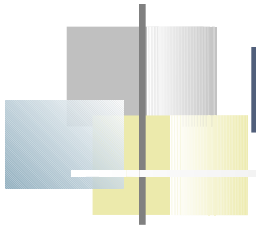

Expressions de chemin

```
doc("biblio.xml")/bib/book/author

doc("biblio.xml")/bib/book[1]/publisher

doc("biblio.xml")//book/(author,publisher)

doc("biblio.xml")//book[position() lt last()]
```

les nœuds restants sont triés selon l'ordre du document

Dans une expression de chemin

```
doc("biblio.xml")//book[2]/(publisher union title)
doc("biblio.xml")//book[2]/(title union publisher)
```

<title>TCP/IP Illustrated</title>
<publisher>Addison-Wesley</publisher>

les nœuds restants sont triés selon l'ordre du document

Dans une expression de chemin

```
doc("biblio.xml")//book[2]/(publisher union title)
doc("biblio.xml")//book[2]/(title union publisher)
```

doc("biblio.xml")//book[2]/(publisher,title)

```
<title>TCP/IP Illustrated</title>
<publisher>Addison-Wesley</publisher>

for $b in doc("biblio.xml")//book
return
   ($b/publisher,$b/title)

<publisher>Addison-Wesley</publisher>
<title>TCP/IP Illustrated</title>
```

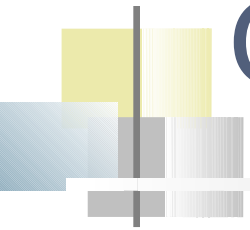

Constructeurs de nœuds

Constructions de nœuds XML

- Un constructeur produit un nouveau nœud
  - Il existe des constructeurs pour chaque sorte de nœud
    - élément et attribut

- Un résultat peut contenir des fragments prédéfinis et des expressions à évaluer
  - parties connues (constructeurs directs)
  - parties calculées par expressions (constructeurs calculés)
- A l'exécution
  - les parties connues sont recopiées
  - les parties calculées sont évaluées

Constructions de nœuds XML

Le nom du nœud est connu, son contenu est calculé par une expression

Requête:

```
<auteurs>
      { doc("biblio.xml")//book[4]/author/last  }
</auteurs>
```

Résultat:

```
<?xml version="1.0"?>
<auteurs>
  <last>Abiteboul</last>
  <last>Buneman</last>
  <last>Suciu</last>
</auteurs>
```

Constructions de nœuds XML

- Le nom du nœud et son contenu sont calculés par des expressions

```
element {expression_nom}{expression_contenu}
attribute{expression_nom}{expression_contenu}
```

Requête:

```
<auteurs>
      {doc("biblio.xml")//book[4]/author/last  }
</auteurs>

element auteurs {doc("biblio.xml")//book[4]/author/last}
```

Constructions de nœuds XML

Requête:

```
element
 { doc("biblio.xml")//book[1]/fn:name(*[1]) }
 {
   attribute
   { doc("biblio.xml")//book[1]//fn:name(*[3]) }
   {doc("biblio.xml")//book[1]/*[3]}
 }
```

Résultat:

```
<title publisher="Kluwer Academic Publishers"/>
```

Opérateurs (suite)

Opérateurs Séquences de nœuds

- Union intersection différence
- Si le nœud contexte est la racine du fragment

```
c/e union c/*          ⇒ n4, n5 , n7, n8
c/d intersect c/*      ⇒ n4, n7
c/* except c/d        ⇒ n5, n8
```

Doublons éliminés
Nœuds rangés dans l'ordre du document
(sauf contre ordre dans le prologue)

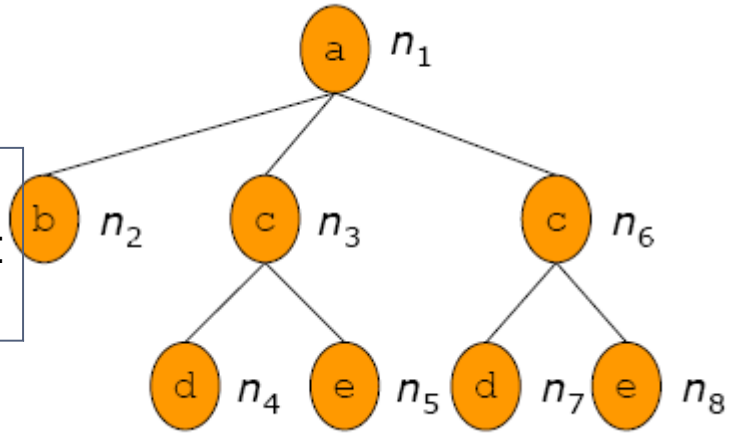

Différence de séquences de nœuds dans un constructeur

Requête:

```
<livre>
  Tous les sous-elements sauf les auteurs:
  {doc("biblio.xml")//book[2]/(* except author) }
</livre>
```

Résultat:

```
    <livre>
     Tous les sous-éléments sauf les auteurs:
        <title>TCP/IP Illustrated</title>
        <publisher>Addison-Wesley</publisher>
        <price>65.95</price>
    </livre>
```

Dans une expression de chemin

```
doc("biblio.xml")//book[2]/(title union publisher)

<title>TCP/IP Illustrated</title>
<publisher>Addison-Wesley</publisher>
```

Concaténation de séquences de noeuds

Requête:

```
<livre>
  Le prix suivi du titre:
  {doc("biblio.xml")//book[2]/price,
        doc("biblio.xml")//book[2]/ title) }
</livre>
```

Résultat:

```
    <livre>
     Le prix suivi du titre:
     <price> 65.95</price>
     <title>TCP/IP Illustrated</title>
    </livre>
```

Transformation nœud ->valeur

Requête:

```
"Les auteurs du quatrième livre sont",
doc("biblio.xml")//book[4]/author/fn:string(last)
```

Résultat:

```
" Les auteurs du quatrième livre sont", "Abiteboul",
   "Buneman", "Suciu"
```

Comparaison de valeurs atomiques

```
eq
ne
lt
le
gt
ge
```

Requête:

```
doc("biblio.xml")//book/author[last eq "Suciu"]
```

Résultat:

```
<author><last>Suciu</la><first>Dan</first></author>
```

Requête:

```
doc("biblio.xml")//book[author/last eq "Suciu"]
```

Résultat:

ERROR

L'expression `author/last` dans le prédicat ne retourne pas une valeur atomique mais une séquence de valeurs

Comparaison de séquences

=
!=
<=
<
>=
>

$exp_1 = exp_2$

s'il existe au moins un item dans la valeur de exp_1 qui est égal à un item de la valeur de exp_2

```
5 != 7                    → FALSE
2 > (5,10,6)              → FALSE
(1,2) = (7,2,10,7)        → TRUE
```

Comparaison de séquences

=
!=
<=
<
>=
>

Requête:

```
Count(doc("biblio.xml")
              //book[author/last =("Suciu“, "Stevens“)]
```

Résultat:

3

Comparaison de nœuds

n_1 is n_2

n_1 est identique à n_2

Requête:

```
doc("biblio.xml")//book[author[3] is author[last()]]
```

Résultat:

```
<book year="2000">
       <title>Data on the Web</title>
       <author><last>Abiteboul</last><first>Serge</first></author>
       <author><last>Buneman</last><first>Peter</first></author>
       <author><last>Suciu</last><first>Dan</first></author>
       <publisher>Morgan Kaufmann Publishers</publisher>
       <price>39.95</price>
   </book>
```

Comparaison de nœuds par la position

<< >>

n_1 << n_2

n_1 apparaît avant n_2 dans le document (true)

n_1 >> n_2

n_1 apparaît après n_2 dans le document

Requête:

```
<livre>
 {doc("biblio.xml")
   //book[author[last="Abiteboul"] << author[last="Suciu"]]
   //title}
</livre>
```

Résultat:

```
<title>data on the web</title>
```

FLWR

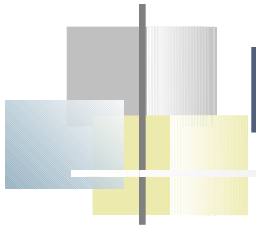

FLWR

(clause `for` | clause `let`)+
(clause `where`)?
(clause `order by`)?
(clause `return`)

For – let - return

- La clause `for $var in exp`

  affecte la variable `$var` successivement avec chaque item de la séquence retournée par `exp` (itérer sur une séquence)
- La clause `let $var := exp`

  affecte la variable `$var` avec la séquence “complète” retournée par `exp` (liaisons)
- La clause `return exp`

  permet de construire le résultat

Illustrations simples

Requête

```
for $i in (1, 2)
Return
 <regle> {$i} </regle>
```

Résultat

```
<regle> 1 </regle>
<regle> 2 </regle>
```

Requête

```
for $i in (1, 2), $j in (5, 6)
return
<regle>
  {$i} fois {$j} vaut {$i * $j}
</regle>
```

Résultat

```
<regle> 1 fois 5 vaut 5</regle>
<regle> 1 fois 6 vaut 6</regle>
<regle> 2 fois 5 vaut 10</regle>
<regle> 2 fois 6 vaut 12</regle>
```

Illustrations simples

```
For $i in (1 to 3) {--FLWR incomplet--}
Let $j := (1 to $i)
```

Produit successivement :

- `$i=1, $j=1`
- `$i=2, $j=(1,2)`
- `$i=3, $j=(1,2,3)`

For – let - return

Requête:

```
for $b in doc("biblio.xml")//book[last()]
let $a := $b/author
return
<livre nb_auteurs="{count($a)}"> { $a }  </livre>
```

Résultat:

```
<livre nb_auteurs="3">
  <author><last>Abiteboul</last><first>Serge</first></author>
  <author><last>Buneman</last><first>Peter</first></author>
  <author><last>Suciu</last><first>Dan</first></author>
</livre>
```

Where

La clause *where* ***exp***
permet de filtrer un résultat par rapport au résultat booléen de l'expression exp

Requête:

```
<livre>
  { for $a in doc("biblio.xml")//book
    where $a/author[1]/last eq "Abiteboul"
    return $a/title }
</livre>
```

Résultat:

```
<livre>
 <title>Data on the Web</title>
</livre>
```


Tests

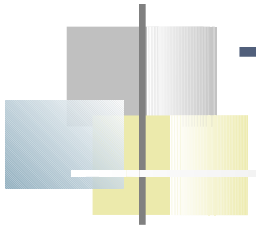

Tests

`if` exp_1 `then` exp_2 `else` exp_3

- teste la valeur booléenne de exp_1
- Retourne la valeur de exp_2 si elle est vraie
- Retourne la valeur de exp_3 sinon

Tests

Requête:

```
<livres>
  { for $b in doc("biblio.xml")//book
   return
        if ($b/@year > 1995)
        then <livre récent='vrai'> {$b/title} </livre>
        else <livre> {$b/title} </livre> }
</livres>
```

Résultat:

```
<livres>
 <livre récent="vrai">The Economics of Technology …</livre>
 <livre>TCP/IP Illustrated</livre>
 <livre>Advanced Programming in the Unix environment</livre>
 <livre récent="vrai" >Data on the Web</livre>
</livres>
```

Quantifications

- `some $var in` exp_1 `satisfies` exp_2

  il existe au moins un item retourné par l'expression exp_1 qui satisfait l'expression exp_2

- `every $var in` exp_1 `satisfies` exp_2

  tous les items retournés par l'expression exp_1 satisfont l'expression exp_2

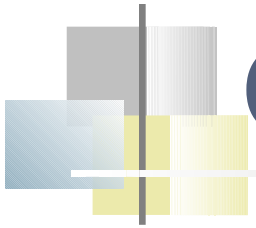

Quantifications

Requête

```
every $b in doc("biblio.xml")//book
satisfies $b/@year > 2000
```

Réponse

```
False
```

Requête

```
some $b in doc("biblio.xml")//book
satisfies $b/price < 50
```

Réponse

```
true
```

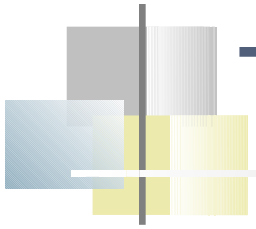

Tri

- exp_1 `order by` exp_2 `(ascending | descending)`

  trier les éléments de la séquence retournée par l'expression exp_1 par les valeurs retournées par l'expression exp_2

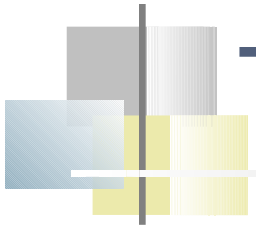

Tri

Requête

```
<livres>
   { for $b in doc("biblio.xml")//book
     order by ($b/@year)
     return $b/title
   }
</livres>
```

Réponse

```
<livres>
  <title>Advanced Programming in the Unix environment</title>
  <title>TCP/IP Illustrated </title>
  <title>The Economics of Technology and … TV</title>
  <title>Data on the Web</title>
</livres>
```

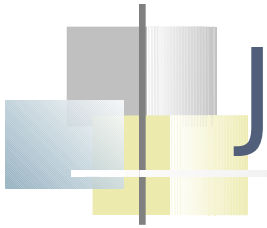

Jointures

Un nouveau document XML : un fichier d'adresses

```
<adresses>
 <personne>
 <nom>Abiteboul</nom>
 <pays>France</pays>
 <institution>INRIA</institution>
 </personne>
 <personne>
 <nom>Suciu</nom>
 <pays>USA</pays>
 <institution>Université de Washington</institution>
 </personne>
 <personne>
 <nom>Buneman</nom>
 <pays>Ecosse</pays>
 <institution> LFCS, School of Informatics </institution>
 </personne>
</adresses>
```

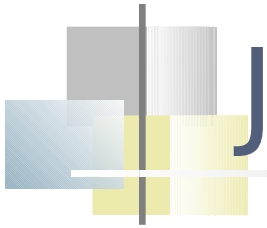

Jointure : le résultat

Résultat:

```
<livre titre="The Economics of Technology …"/>
<livre titre="TCP/IP Illustrated">
  <auteur nom="Stevens"/>
</livre>
<livre titre="Advanced Programming in the Unix environment" >
  <auteur nom="Stevens"/>
</livre>,
<livre titre="Data on the Web">
  <auteur nom="Abiteboul" institution="INRIA" />
  <auteur nom="Buneman" institution=" LFCS, School of Informatics " />
  <auteur nom="Suciu"  institution="Université de Washington" />
</livre>
```

Jointure : une requête

Requête:

```
for $b in doc("biblio.xml")//book
 return
 <livre titre='{$b/title}'>
   {for $a in $b/author
      return
  <auteur  nom='{$a/last}'>
        {for $p in doc("addr.xml")//personne
         where $a/last = $p/nom
       return
            attribute institution {$p/institution}}
 </auteur>
   }
 <livre>
```

Jointure : une requête

```
for $b in doc("biblio.xml")//book
  return
   element livre
    {(attribute titre {$b/title},
     for $a in $b/author
        return element auteur
   {
         (attribute nom {$a/last},
      for $p in doc("addr.xml")//personne
              where $a/last = $p/nom
         return attribute institution {$p/institution}
          )
        }
     )}
```

Fonctions

Fonction avg

Requête:

```
for $p in distinct-values(doc("biblio.xml")//publisher)
let $l := doc("biblio.xml")//book[publisher = $p]
return element publisher
       {attribute name {fn:string($p)},
        attribute avg_price { fn:avg($l/price) } }
```

Résultat :

```
<publisher name="Kluwer Academic Publishers"  avg_price="129.95"/>,
<publisher name="Addison-Wesley"  avg_price="65,95"/>,
<publisher name="Morgan Kaufmann Publishers" avg_price="39.95"/>
```

Définition de fonctions

- XQuery permet à l'utilisateur de définir ses propres fonctions

```
declare function NombreAuteurs($b as element(book)) as
xs:integer
 {
return count($b/author)
}
```

- Le résultat est de type xs:integer

Remarques

- XQuery est un langage sensible à la casse
  - Les mots clés sont en minuscules
- Tous les axes ne sont pas supportés

child	ancestor
descendant	ancestor-or-self
attribute	preceding
self	preceding-sibling
descendant-or-self	following
parent	following-sibling
	namespace

Structure d'une requête

- Le Prologue contient en particulier:
  - Declarations de Namespace
  - Importations de schémas
  - Définitions de fonctions
  - Déclarations de variable globales
- Le Corps contient:
  - Une expression qui définit le résultat de la requête

Evaluation d'une expression

- Elle est évaluée dans
  - un contexte statique - analyse de l'expression – prologue
    - La requête est analysée et traduite en un arbre d'opérateurs
    - Un type statique est associé à chaque expression (s'appuie sur les types des opérandes - Règles d'inférence de type basées sur XML Schema)
    - Déclenche une erreur si les opérandes ne correspondent pas aux opérateurs
  - un contexte dynamique - évaluation de l'expression (focus)
    - Elle n'est lancée que si aucune erreur n'a été détectée
    - Elle consiste à évaluer l'arbre d'opérateurs
    - Un type dynamique est associé à chaque valeur calculée, qui peut être plus spécifique que le type statique de l'expression à partir de laquelle cette valeur est calculée