# XML et Programmation Internet

## Cours 2

kn@lri.fr

## Plan





## XML vu comme un arbre (1/2)

- Tout ce qui apparait dans le document correspond à un nœud de l'arbre (texte, balises, commentaires, blanc, ...)
- Il existe en plus, un nœud fictif se trouvant au dessus de l'élément racine, le nœud document
- Un couple balise ouvrante/balise fermante correspond à un seul nœud
- Les principaux types de nœuds sont: élément, attribut, texte, commentaire, document



## XML vu comme un arbre (2/2)

Un document XML peut être vu comme un arbre:

```xml
<bibliography>

  <book>
    <title>Foundations of Databases</title>
    <author>Abiteboul</author>
    <author>Hull</author>
    <author>Vianu</author>
    <publisher>Addison Wesley</publisher>
    <year>1995</year>
  </book>

  <book>
    <title>The Lord of the Rings</title>
    <author>J. R. R. Tolkien</author>
    <publisher>Houghton Mifflin</publisher>
    <year>2001</year>
  </book>

</bibliography>
```

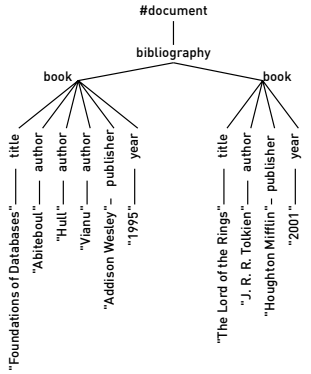

## Sérialisation d'un arbre sous forme de document

Étant donné un arbre, comment peut ont produire le document XML correspondant ?

```
 //pseudo-code
void print(Node n)
{
   if (n is text or comment) { output_text(n) }
   else {
          output_text ("<" + tag(n) + ">");
          for k in children(n)
              print(k);
          output_text ("</" + tag(n) + ">");
   }
```

- On effectue un parcours en profondeur d'abord
- Si le nœud courant est une feuille, on l'affiche
- Sinon on affiche la balise ouvrante, puis récursivement tous les fils, puis la balise fermante



## Ordre du document, parcours préfixe

On appelle ordre du document un ordre total sur les nœuds d'un document qui correspond à leur ordre dans un fichier sérialisé. Il correspond aussi à la numérotation lors du parcours préfixe

1. #document
2. bibliography
3. book
4. title
5. "Foundations of Databases"
6. author
7. "Abiteboul"
8. author
9. "Hull"
10. author
11. "Vianu"

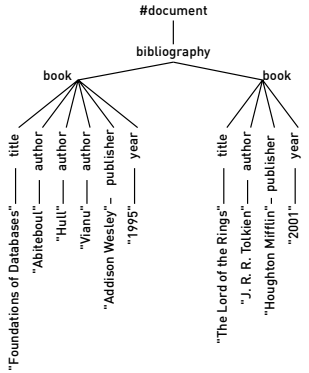




## Construction d'un arbre à partir d'un fichier XML ?

```
type Node = { label : string; children : List<Node> }
Stack<Node> stack;
stack.push (new Node("#document"), []));
while (true) {

 tag = read ();
 if end_of_file () break;
 if tag is opening {
             parent = stack.peek();
             node = new Node(tag, []);
             parent.addChild(node);
             stack.push(node);
 }
 if tag is closing {
     stack.pop();
 }
}
```

En pratique, on utilise des bibliothèques toutes faites pour lire/écrire des fichiers!



## Plan

## Intérogation de documents XML

Les documents représentant des données (semi-) structurées, on souhaite en extraire de l'information

On va pouvoir écrire des requêtes sur des critères scalaires ( « renvoyer tous les livres publiés après 2000 »), mais aussi sur des critères de structure (« renvoyer tous les éléments qui ont un fils `author` »)



## XPath

XPath est un langage de selection de nœud dans un document XML. Il ne permet que de sélectionner des nœuds, pas d'en construire de nouveaux. C'est un langage restreint qui ne contient pas de fonctions, variables, ... On peut le voir comme un équivalent du `SELECT` de SQL



## XPath (exemple)

Sélectionner tous les titres du document (de manière compliquée)

```
/descendant::author/parent::book/child::title
```

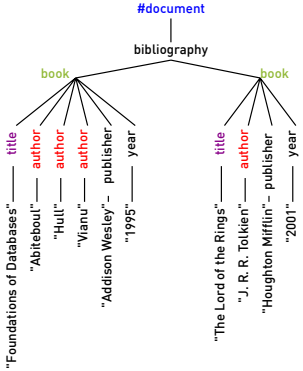




## XPath : syntaxe

La syntaxe d'une requête XPath est:

$/axe_1::test_1[\ pred_1\ ]/\ \ldots\ /axe_n::test_n[\ pred_n\ ]$

- **axe :** `self`, `child`, `descendant`, `parent`, ...
- **test :** `node()`, `text()`, `*`, ou un nom d'élément
- **pred(icat) :** chemin XPath, expression arithmétique, comparaison, ...

exemple:

```
/descendant::book[ child::year > 2000] / child::title
```

## XPath : sémantique

Étant donné la requête:

$/axe_1::test_1[\ pred_1\ ]/\ \ldots\ /axe_n::test_n[\ pred_n\ ]$

1. le nœud contexte au nœud document
2. on sélectionne l'ensemble $A_1$ tous les nœuds qui sont dans l'$axe_1$ par rapport au nœud contexte
3. on sélectionne l'ensemble $T_1$ des nœud de $A_1$ qui vérifient le test $test_1$
4. on sélectionne l'ensemble $P_1$ des nœud de $T_1$ qui vérifient $pred_1$
5. On réapplique le pas 2 sur $P_1$
6. ...



## XPath : sémantique (exemple)

`/descendant::author/parent::book/child::title`

1. On séléctionne le nœud document
2. On séléctionne tous les descendants
3. On filtre en ne gardant que les nœuds author ($T_1 \equiv P_1$)
4. Sur chacun des author on prend le parent (on n'obtient que 2 parents car on garde des ensembles de noeuds)
5. On filtre les parents pour ne garder que ceux qui sont book
6. On sélectionne tous les fils de chacun des book
7. On ne garde que les fils qui ont le tag title

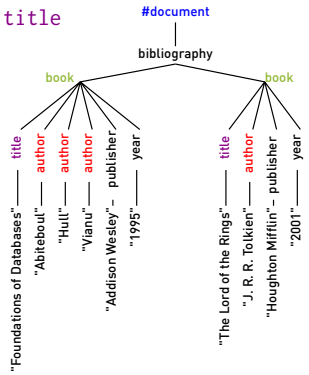




## XPath : axes

Le standard XPath définit un grand nombre d'axes

- self : on reste sur le nœud courant
- child : tous les fils du nœud courant
- parent : le parent du nœud courant. Seul le nœud document n'a pas de parent
- descendant : les fils, les fils des fils, etc. du nœud courant
- ancestor : le parent, et le parent du parent, etc. du nœud courant
- descendant-or-self, ancestor-or-seld : comme les précédents mais inclus le nœud courant
- following-sibling: le frères se trouvant après
- preceding-sibling: les frères se trouvant avant
- following, preceding, attributes : usage avancé



## XPath : les tests

On peut sélectionner des nœuds selon les critères suivants

- node() : n'importe quel nœud
- text() : un nœud texte (`"The Lord of the Rings"`)
- * : n'importe quel élément (`author`, `title`, ...)
- *nom_d_element* tous les éléments ayant ce nom

## XPath : prédicats (syntaxe)

```
p ::=   p or p
    |   p and p
    |   not (p)
    |   count(…), contains(…), position(), …
    |   chemin XPath
    |   e1 op e2
```

$e_1$ **et** $e_2$ **sont des expressions arithmétiques,** op **peut être** <, >, =, !=, +, -, *, /, mod, **…**



## XPath : prédicats (sémantique)

**On évalue le prédicat et on converti son résultat en valeur de vérité. Si la valeur vaut vrai, on garde le nœud courant, si elle vaut faux, on ne le garde pas**

**XPath connait 4 types de données pour les prédicats :**

- **Les booléens, valeur de vérité : vrai ou faux**
- **Les nombres (flottants), valeur de vérité compliquée…**
- **Les chaînes de caractères, chaîne vide = faux, sinon vrai**
- **Les ensembles de nœuds, ensemble vide = faux, sinon vrai**



## XPath : prédicats (exemples)

- `/descendant::book [ child::title ]` **: sélectionne chaque élément book pour lequel l'ensemble des fils de nom title n'est pas vide**
- `/descendant::book [ count(child::author) > 2 ]` **: séléctionne chaque book qui a plus de deux fils author**
- `/descendant::book [ contains(child::title, "Ring") ]`
-

```
/descendant::book [ count(child::author) > 2
                    or contains(child::author, "Tolk")
                  ]/child::title
```



## Caractéristiques d'XPath

- **XPath est un langage standardisé par le W3C**
- **Assez verbeux**
- **Langage de requêtes monadique (on ne peut renvoyer que des ensembles de nœuds. Par exemple il est impossible de renvoyer des ensembles de paires auteur/titre de livre)**
- **Il est assez compliqué à implémenter efficacement**