XML et Programmation Internet

Cours 6

kn@lri.fr

Plan

1 Introduction, UTF-8 et XML ✔
2 XPath ✔
3 XPath (suite) ✔
4 XSLT ✔
5 XSLT (suite) ✔
6 DOM
  6.1 Le modèle DOM
  6.2 Java API for XML Processing

Programmer avec XML

La représentation textuelles de documents XML n'est pas adaptée à la manipulation des données par un programme :

- On ne veut pas lire le fichier « caractère par caractère »
- On veut s'assurer que le fichier est bien formé et valide
- On veut pouvoir manipuler la structure d'arbre que représente le fichier

Document Object Model

DOM est une spécification du W3C qui explique comment représenter un document dans un langage orienté objet.
Avantages :

- N'est pas limité à un seul langage
- Permet de spécifier une API unique : programmer en XML en Java ou Python ne sera pas différent

Inconvénients :

- En pratique, orienté Java
- Se focalise sur les lanages objets de manière arbitraire

Que définit le DOM ?

Le DOM définit des interfaces (c'est à dire, des noms de classes auquels sont associés des propriétés). Il définit aussi des types de bases (chaînes de caractères, entiers, etc.) et des types auxiliaires qui sont implantés par les types de bases du langage.

L'interface Node (1/4, constantes)

```
//attention ce n'est pas du Java
interface Node {

//constantes entières définissant les types de nœuds
const unsigned short      ELEMENT_NODE                = 1;
const unsigned short      ATTRIBUTE_NODE              = 2;
const unsigned short      TEXT_NODE                   = 3;
const unsigned short      CDATA_SECTION_NODE          = 4;
const unsigned short      ENTITY_REFERENCE_NODE       = 5;
const unsigned short      ENTITY_NODE                 = 6;
const unsigned short      PROCESSING_INSTRUCTION_NODE = 7;
const unsigned short      COMMENT_NODE                = 8;
const unsigned short      DOCUMENT_NODE               = 9;
const unsigned short      DOCUMENT_TYPE_NODE          = 10;
const unsigned short      DOCUMENT_FRAGMENT_NODE      = 11;
const unsigned short      NOTATION_NODE               = 12;
```


L'interface Node (2/4, valeur, nom et type)

```
//nom et valeur du nœud

readonly attribute DOMString       nodeName;
attribute DOMString                nodeValue;
```

- **Pour les éléments** nodeValue **vaut** null **et** nodeName **est le nom de la balise**
- **Pour les nœuds texte** nodeValue **est le texte et** nodeName **est la chaine fixe** #text
- **Pour les attributs** nodeValue **vaut la valeur de l'attribut et** nodeName **est son nom**

```
//L'une des 12 constantes du slide précédent
readonly attribute unsigned short  nodeType;
```


L'interface Node (3/4, navigation)

```
readonly attribute Node            parentNode;
readonly attribute NodeList        childNodes;
readonly attribute Node            firstChild;
readonly attribute Node            lastChild;
readonly attribute Node            previousSibling;
readonly attribute Node            nextSibling;
readonly attribute NamedNodeMap    attributes;
```

Utilise deux interfaces auxiliaires:

```
interface NodeList {
Node               item(in unsigned long index);
readonly attribute unsigned long   length;
};
interface NamedNodeMap {
Node               getNamedItem(in DOMString name);
…
}
```

L'interface Node (4/4, mise à jour)

```
//Renvoie le document auquel appartient le nœud
readonly attribute Document        ownerDocument;

Node               insertBefore(in Node newChild,
                                in Node refChild)
                               raises(DOMException);

Node               replaceChild(in Node newChild,
                                in Node oldChild)
                               raises(DOMException);
Node               removeChild(in Node oldChild)
                               raises(DOMException);
Node               appendChild(in Node newChild)
                               raises(DOMException);
boolean            hasChildNodes();

//Nécessaire pour copier un nœud d'un document dans un autre
Node               cloneNode(in boolean deep);
```


Sous-interfaces de Node

L'interface Node **est spécialisées en 12 sous-interfaces différents (les 12 types de nœuds possibles). Les principales sont:**

- `Document` **: l'interface du nœud « racine » du document**
- `Element` **: l'interface des nœuds correspondant à des balises**
- `Attr` **: l'interface des nœuds correspondant à des attributs**
- `Text` **: l'interface des nœuds correspondants à des textes**

L'interface Text

```
interface Text : Node {
//renvoie vrai si le nœud ne contient que des espaces
readonly attribute boolean         isElementContentWhitespace;
…
}
```

(La spécification de DOM mentionne d'autres propriétés)

L'interface Attr

```
interface Attr : Node {
readonly attribute DOMString       name;
readonly attribute DOMString       value;

readonly attribute Element         ownerElement;
…
};
```

L'interface Element

```
interface Element : Node {
readonly attribute DOMString       tagName;
//manipulation par chaine :
DOMString          getAttribute(in DOMString name);
void               setAttribute(in DOMString name,
                                in DOMString value)
                                raises(DOMException);

void               removeAttribute(in DOMString name)
                                raises(DOMException);

//manipulation par nœud :
Attr               getAttributeNode(in DOMString name);
Attr               setAttributeNode(in Attr newAttr)
                                raises(DOMException);
Attr               removeAttributeNode(in Attr oldAttr)
                                raises(DOMException);

//renvoie tous les descendants avec un certain tag
NodeList           getElementsByTagName(in DOMString name);

}
```


L'interface Document

```
inteface Document : Node {
//L'élément racine
readonly attribute Element         documentElement;

//Création de nœuds pour ce document :

Element            createElement(in DOMString tagName)
                                raises(DOMException);
Text               createTextNode(in DOMString data);
Attr               createAttribute(in DOMString name)
                                raises(DOMException);

//Les descendants avec un tag particulier
NodeList           getElementsByTagName(in DOMString tagname);


//Copie un nœud, éventuellement avec ses descendants et
//en fait un nœud ajoutable au document :
Node               importNode(in Node importedNode,
                        in boolean deep);
```


Modèle mémoire

Un nœud (objet implémentant l'interface Node) ne peut pas appartenir à deux documents. Exemple :

```
Node noeud_a = document1.getElementByTagName("a").item(0);

document2.appendChild(noeud_a);//Exception si document2 n'est
                               //pas le même objet que
                               document1
//par contre ceci est ok:
document2.appendChild(document2.importNode(noeud_a, true));
```


Plan

1 Introduction, UTF-8 et XML ✔
2 XPath ✔
3 XPath (suite) ✔
4 XSLT ✔
5 XSLT (suite) ✔
6 DOM
  6.1 Le modèle DOM ✔
  6.2 Java API for XML Processing

Introduction à JAXP

API de la bibliothèque standard Java qui permet de manipuler du XML. Elle comprend (entre autres) :

- Lecture et écriture de documents en streaming (cours 7)
- Implémentation complète de la spécification DOM
- Moteur XSLT (et donc XPath)

Inconvénients : la bibliothèque essaye d'être très générique, afin que n'importe qui puisse fournir son implémentation de DOM en utilisant les interfaces fournies. Il faut donc parfois passer par des grandes séquences d'incatations magiques pour créer un objet

Structure de l'API

- Les types et interfaces spécifiés par le w3C se trouvent dans le packages `org.w3c.*`
- Les types « usuels» pour XML sont dans `org.xml.*`
- Les classes concrètes java implémentant les interfaces sont dans `javax.xml.*`

Factory *design pattern*

Comme toutes les API complexes en Java (et dans les langages objets en général), Jaxp utilise le *design pattern* de Factory.

Pour créer un objet de type `Foo` on ne fait pas simplement `new Foo(…);` mais on utilise une classe `FooFactory` qui possède une méthode `.createFoo(…)`

Dans quel cas est-ce intéressant ?

Quand `Foo` est une interface. On ne peut pas faire `new` sur une interface. Il faut donc une méthode pour appeler le constructeur de la classe implémentant `Foo` puis qui le caste en `Foo` …

Factory *design pattern* (exemple)

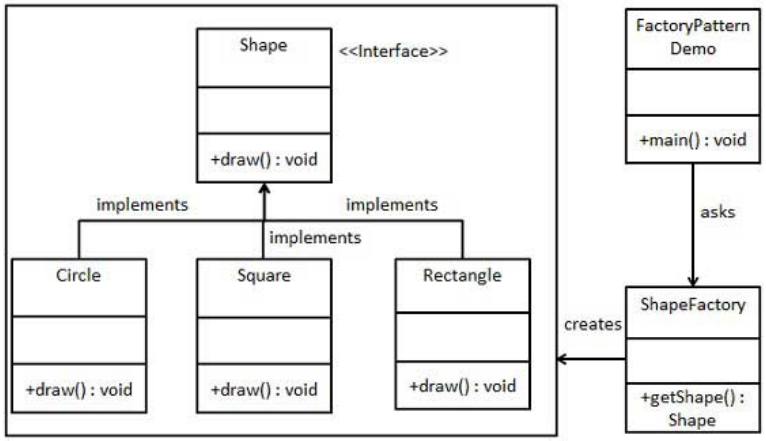

Création d'un document : DocumentBuilder

La classe `DocumentBuilder` **permet de créer un document XML :**

- **Soit en le lisant depuis un fichier (avec la méthode** `parse()`
- **Soit vide, avec la méthode** `newDocument()`

Pour obtenir un `DocumentBuidler`**, il faut passer par un** `DocumentBuilderFactory` **:**

```
//création de la Factory
DocumentBuilderFactory dbf = DocumentBuilderFactory.newInstance();

//On définit quelques options
dbf.setIgnoringElementContentWhitespace(true); // option
dbf.setValidating(false); // option

//On crée le documentBuilder
DocumentBuilder db = dbf.newDocumentBuilder();

//On charge le document
Document doc = db.parse("fichier.xml");
```


DOM dans JAXP

Le `DocumentBuilder` **permet d'obtenir un** `Document` **(interface Java qui implémente l'interface DOM du même nom)**

Conventions de nommage : les *propriétés* des interfaces DOM sont préfixées par `get` **ou** `set` **en Java. Les méthodes ont le même nom. Exemple :**

```
Node n = …;
n.getNodeType(); //DOM défini nodeType;
n.getFirstChild(); //DOM défini firstChild;
n.appendChild(m);  //C'est une méthode en DOM donc même nom
```


Conversions

On travaille la plupart du temps avec des objets ayant le type `Node`**. La manière correcte de les convertir est la suivante :**

```
switch (n.getNodeType()) {

case Node.DOCUMENT_NODE:
   Document d = (Document) n;
   …
   break;
case Node.ELEMENT_NODE:
   Element e = (Element) n;
   …
   break;
case Node.TEXT_NODE:
   Text t = (Text) n;
   …
   break;
}
```


Rappels : classes et interfaces utiles en Java

Interface `Map<K,V>` **permet d'associer des clés de types** `K` **à des valeurs de type** `V` **(**`K` **et** `V` **doivent être des** `Objects` **donc pas** `int`**,** `bool` **, ...)**

Implémentations possibles : `TreeMap`**,** `HashMap`