Les API pour XML

Fabrice Rossi

http://apiacoa.org/contact.html

Université Paris-IX Dauphine

Le problème

Comment manipuler un document XML dans un programme ?

- très bas niveau : analyse syntaxique (*parsing*)
- bas niveau : validation
- niveau intermédiaire :
  - manipulations du document chargé en mémoire
  - sauvegarde d'un document
- haut niveau :
  - sérialisation (*binding*)
  - transformations d'un document XML
  - interprétation d'un format XML particulier :
    - SVG
    - MathML
    - XSL:FO
    - etc.
  - etc.

Analyse syntaxique

- **Principe** : lire le document et reconnaître les structures XML (balise ouvrante, attribut, etc.)
- Un grand standard : *Simple API for Xml* (SAX)
- Un concurrent (très spécifique) : *Xerces Native Interface* (XNI)
- Avantages (du travail au niveau *parsing*) :
  - efficacité maximale
  - occupation mémoire minimale
  - très souple
- Inconvénients :
  - délicat à programmer
  - il faut tout faire !
- En général, la validation est déjà possible au niveau de SAX (ou de XNI)

Chargement en mémoire

- **Principe** : lire le document, le placer en mémoire et fournir une API permettant sa manipulation
- Un grand standard : *Document Object Model* (DOM) du W3C
- Des concurrents :
  - JDOM (`http://www.jdom.org`) même esprit que DOM, mais spécifique à `Java` et plus simple
  - XOM (`http://cafeconleche.org/XOM/`) : tente de faire mieux que DOM et JDOM (pour `Java`)
  - Electric XML : intéressant mais non *open source*
- Principe informatique commun : un document XML est un arbre
- Avantages :
  - beaucoup de fonctions déjà définies
  - modifications, manipulations globables, etc.
- Inconvénient majeur : performances (mémoire et temps)

Les API de *binding*

- **Principe** : transformation “automatique” et réversible d’un document XML en un objet
- une forme de persistance pour les langages OO
- le futur pour de nombreuses applications
- Des solutions :
  - travail officiel en cours pour Java : Java Architecture for XML Binding (JAXB), `http://java.sun.com/xml/jaxb/`
  - CASTOR (`http://castor.exolab.org`) : permet le *binding* d’objets `Java` vers XML mais aussi la persistance par d’autres techniques (bases de données, LDAP, etc.)
  - ZEUS (`http://zeus.enhydra.org/`), toujours pour `Java`
- Point négatif : vision objet pure et dure (pas vraiment adapté à des documents XML textuels)

Autres API (Java)

Pour les opérations de bas niveau (i.e., chargement et validation), on trouve :

- Java API for XML Processing (JAXP) (`http://java.sun.com/xml/jaxp/`) :
  - sorte de couche d'abstraction
  - comment charger et configurer un analyseur (SAX ou DOM)
  - depuis la version 1.1, comment lancer une transformation XSLT : TrAX (transformation API for XML)
- `datatype` : ajout de nouveaux types de données aux validateurs RELAX NG
- autres API disponibles, mais pour des tâches de plus haut niveau (par exemple RPC XML)

SAX

SAX

Simple API for Xml :

- développement communautaire
- `http ://www.saxproject.org/`
- 1.0 : 11 Mai 98, 2.0 : 5 Mai 2000, 2.0.1 : 29 Janvier 2002
- nombreuses implantations (par exemple Xerces, open source)

Caractéristiques majeures :

- modèle évènementiel : évènement d'analyse syntaxique
- bas niveau
- efficace
- délicat à mettre en œuvre

Langage de référence : `Java` (officiellement intégré à `j2se 1.4` avec JAXP 1.1). Actuellement :

- Xerces : `Java`, C++, COM, Perl
- Microsoft : binding COM et donc C, C++, VB, etc.
- Support en Python, Perl, etc.

Modèle évènementiel

Principes :

- un document est transformé en un flux d'**évènements syntaxiques** (balise ouvrante, balise fermante, etc.)
- **aucune mémoire**
- une application est un "écouteur" d'évènements
- modèle calqué sur celui des interfaces graphiques
- correspond à un parcours préfixe en profondeur de l'arbre du document : c'est l'ordre des informations dans le fichier
- **lecture seule**

Exemple

hello-sax.xml

```
1 <?xml version="1.0"?>
2 <doc>
3 <p>Un texte</p>
4 </doc>
```

Evènements engendrés :

1. start document
2. start element : `doc`
3. start element : `p`
4. characters : `Un texte`
5. end element : `p`
6. end element : `doc`
7. end document

Exemple (suite)

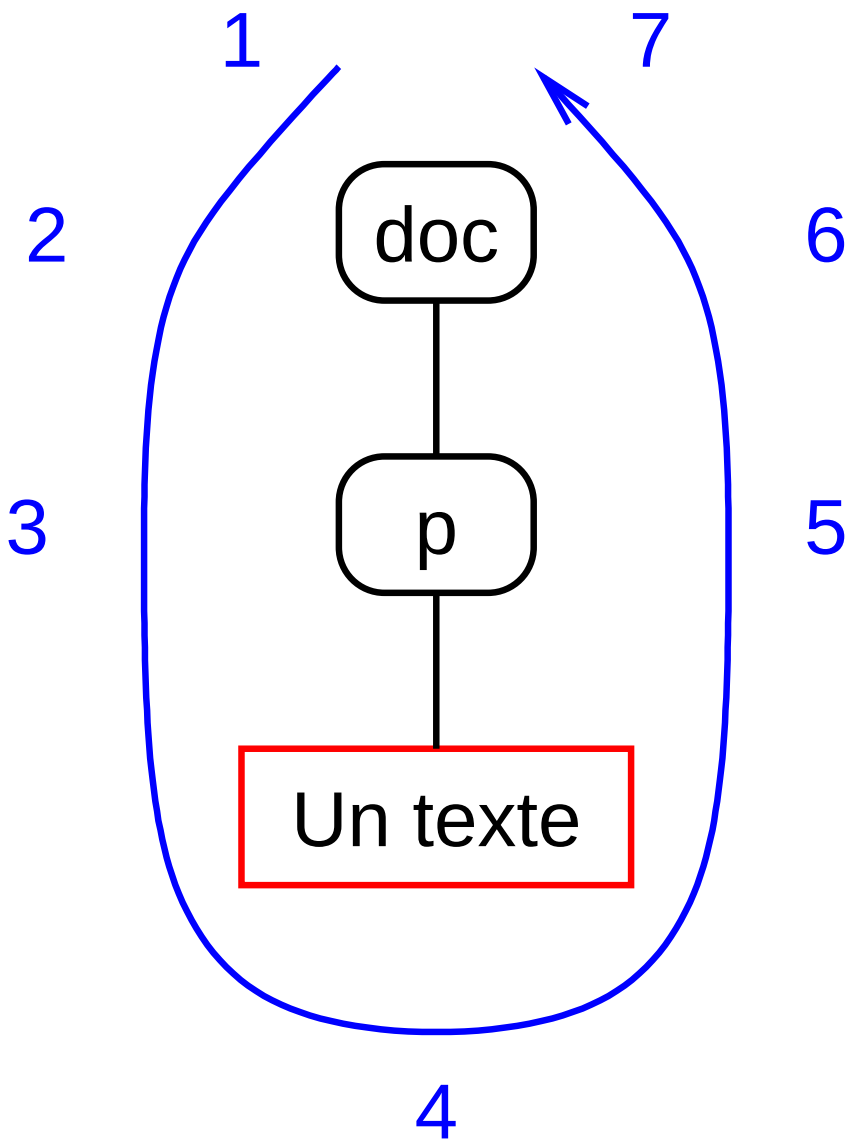

1. start document
2. start element : `doc`
3. start element : `p`
4. characters : Un texte
5. end element : `p`
6. end element : `doc`
7. end document

Exemple 2 (1)

a-memo.xml

```
1  <?xml version="1.0" encoding="ISO-8859-1"?>
2  <mémo>
3  <de>John</de>
4  <à>Bob</à>
5  <contenu>
6  <titre>Bonjour</titre>
7  <texte>Ca va ?</texte>
8  </contenu>
9  </mémo>
```

Exemple 2 (2)

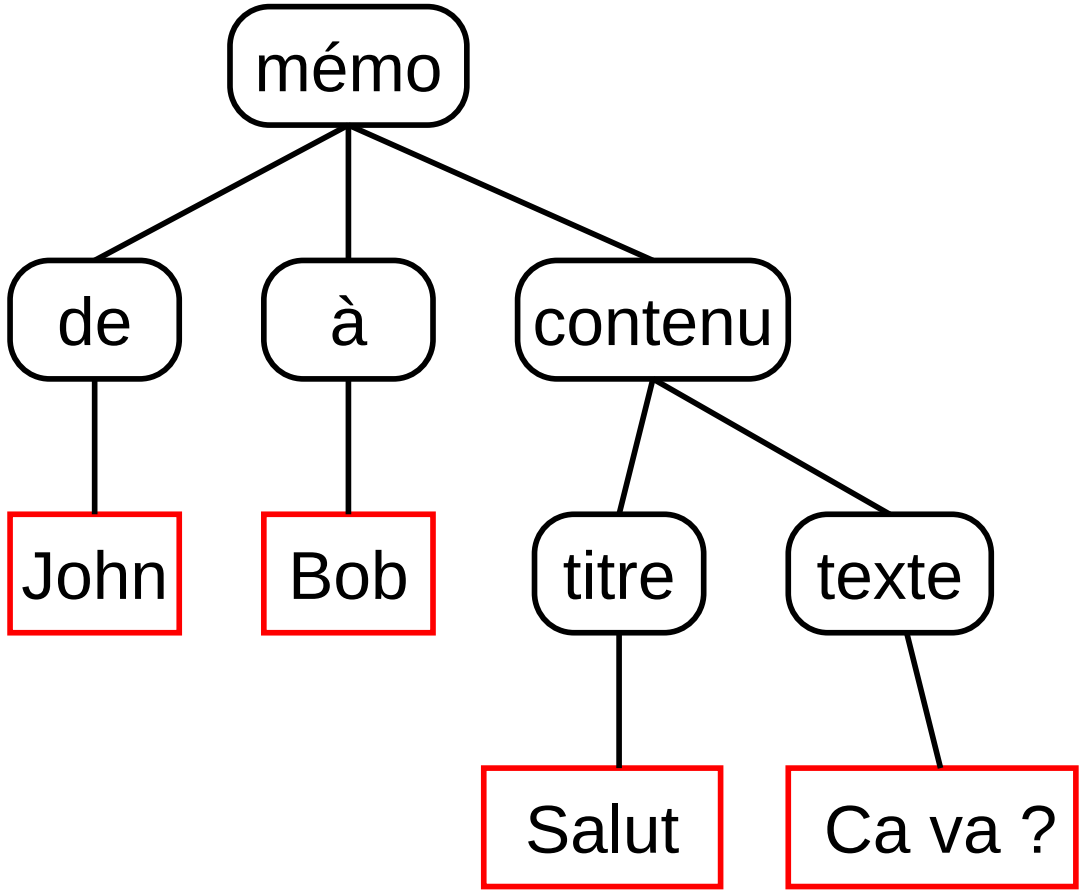

Exemple 2 (3)

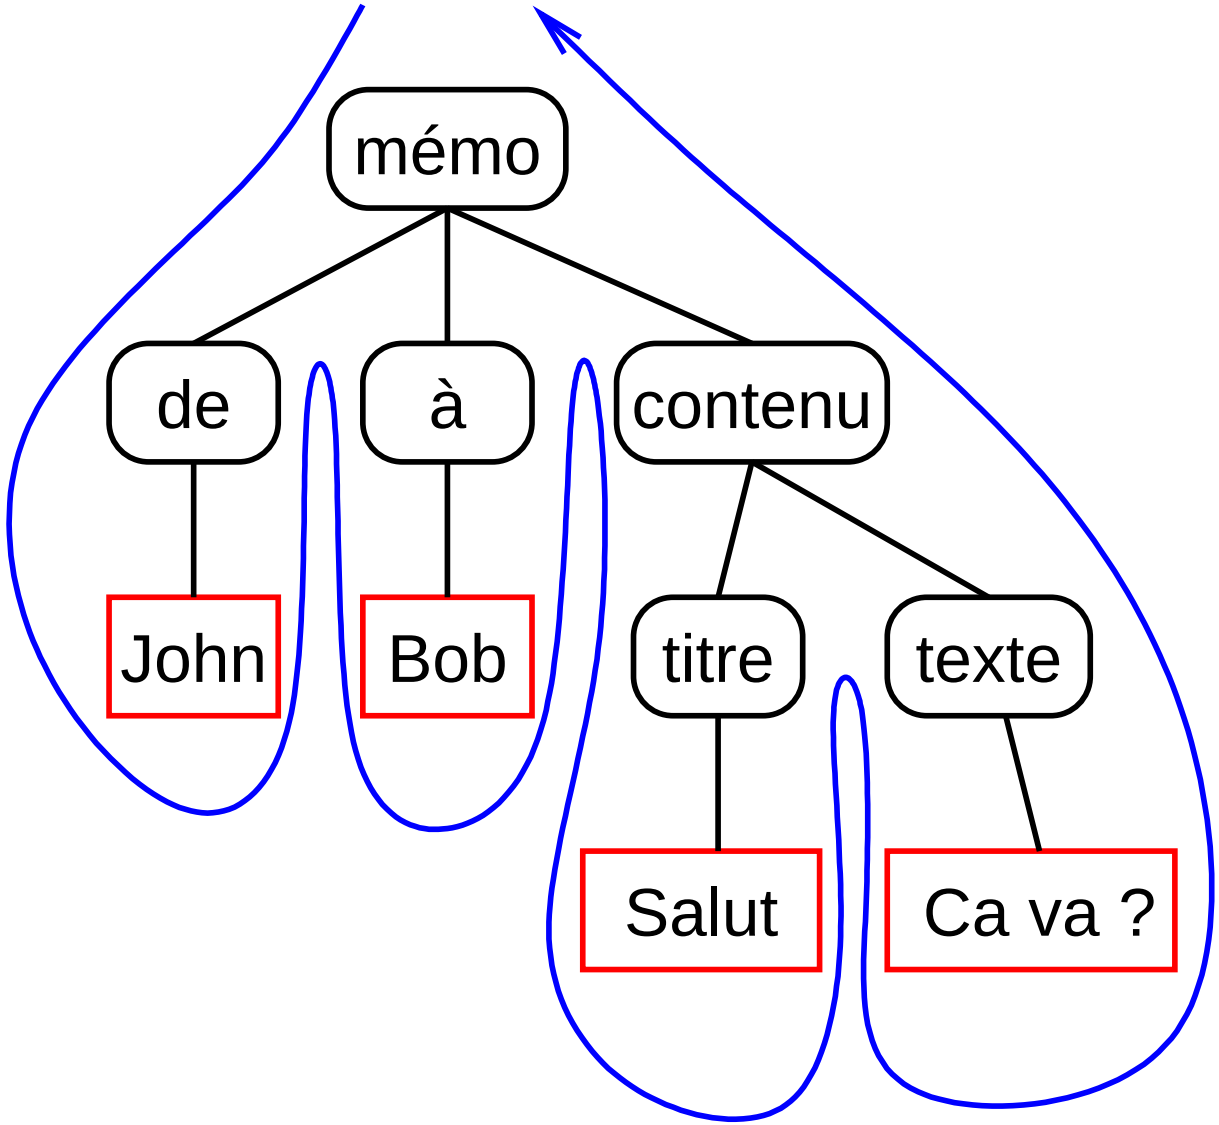

Exemple 2 (4)

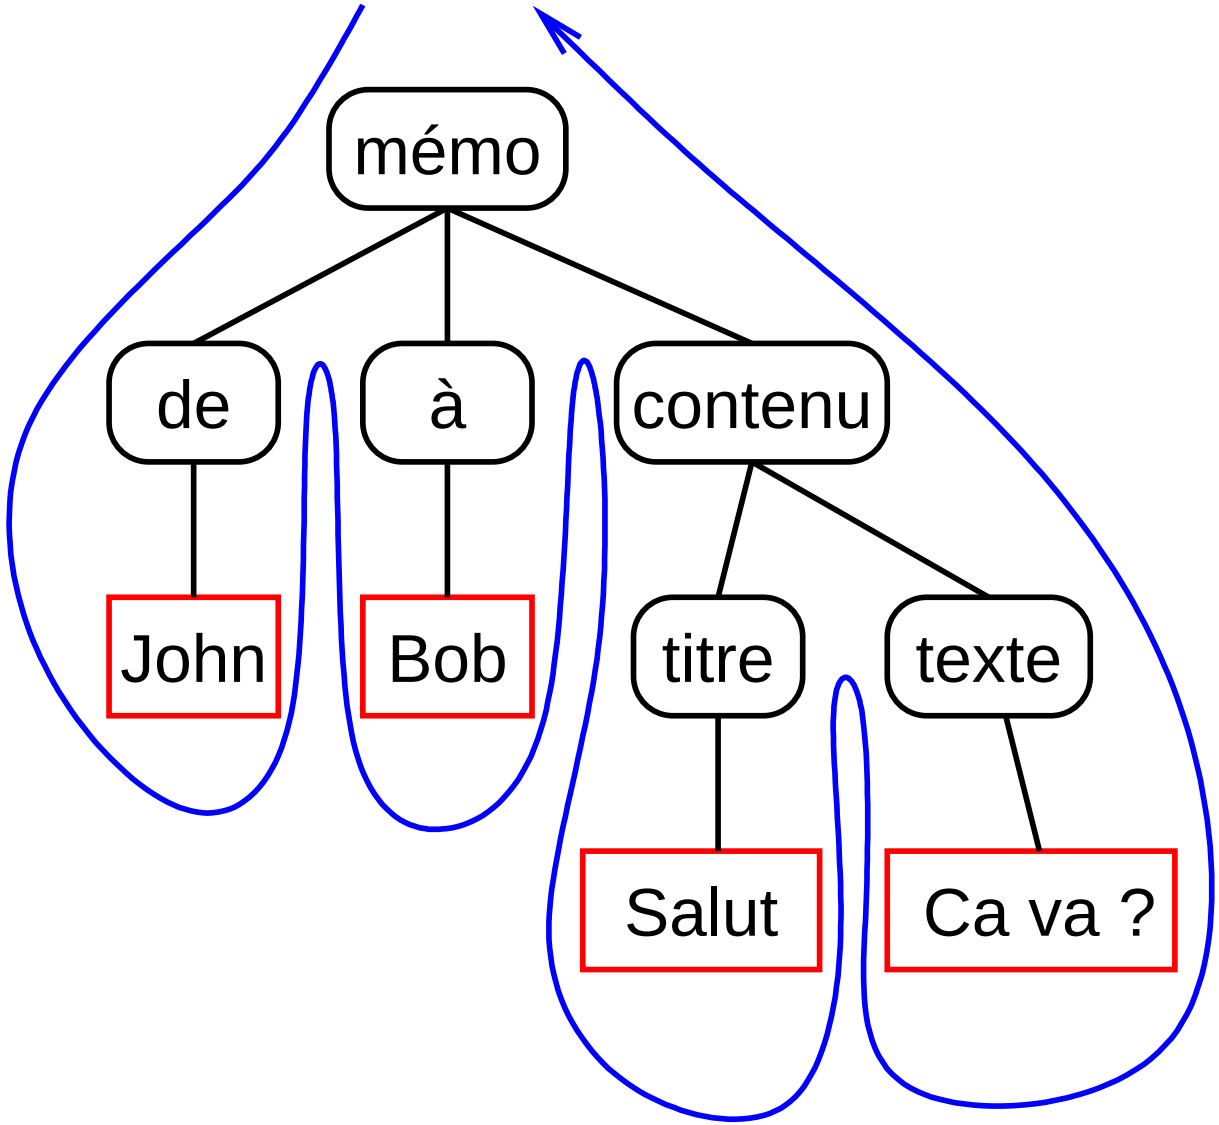

1. SD
2. SE : `mémo`
3. SE : `de`
4. C : John
5. EE : `de`
6. SE : `à`
7. C : Bob
8. EE : `à`

Exemple 2 (5)

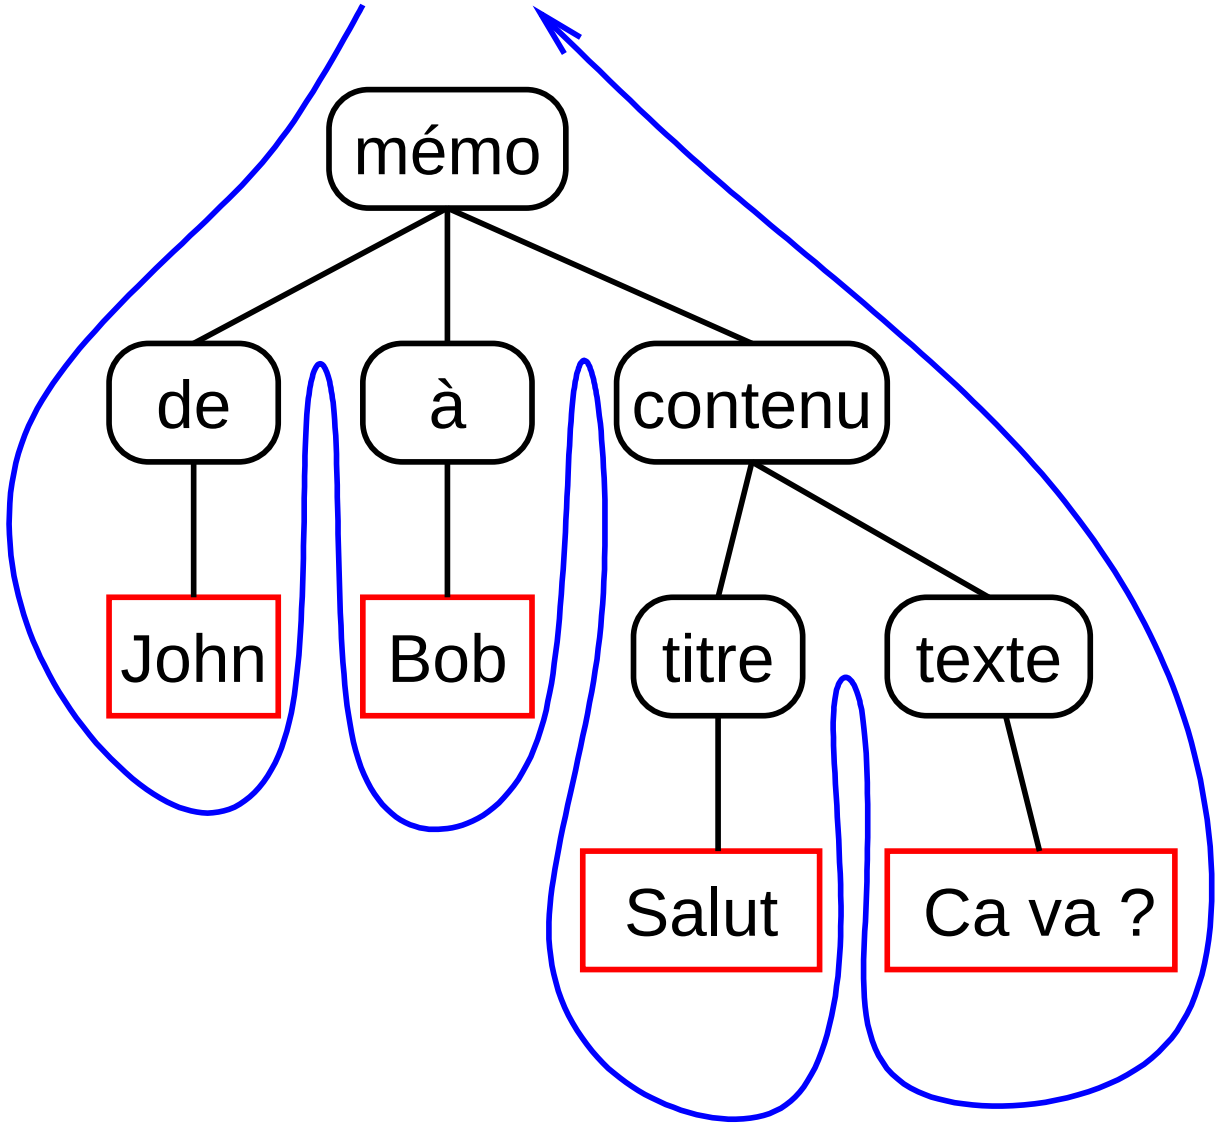

9. SE : `contenu`
10. SE : `titre`
11. C : Salut
12. EE : `titre`
13. SE : `texte`
14. C : Ca va ?
15. EE : `texte`
16. EE : `contenu`
17. EE : `mémo`
18. ED

Mécanismes

Tout est basé sur quatre interfaces :

- `ContentHandler` :
  - la plus importante
  - réagit aux évènements : une méthode par type d'évènement (exemple `startDocument`)
- `ErrorHandler` : gestion des erreurs, en particulier les problèmes de validation
- `DTDHandler` : gestion d'une petite partie des DTDs
- `EntityResolver` : gestion du remplacement des entités externes

Les quatre interfaces sont implantées par `DefaultHandler`, qui ne fait pas grand chose (même principe que les couples `Listener`/`Adapter` de `Java`).

Fonctionnement d'un analyseur

1. ouverture du fichier à analyser
2. lecture d'une partie significative du fichier :
3. si cette partie
   (a) pose un problème (document mal formé ou non valide), appel d'une méthode du `ErrorHandler`
   (b) est une référence à une entité (`&truc;`), appel d'une méthode du `EntityResolver`
   (c) est un composant de la DTD, appel d'une méthode du `DTDHandler`
   (d) est une balise, du texte, etc., appel d'une méthode du `ContentHandler`
4. si le document n'est pas terminé, retour en 2

Exemple

hello-sax.xml

```
1 <?xml version="1.0"?>
2 <doc>
3 <p>Un texte</p>
4 </doc>
```

Evènement	Appel
start document	`ContentHandler.startDocument`
start element : `doc`	`ContentHandler.startElement`
start element : `p`	`ContentHandler.startElement`
characters : Un texte	`ContentHandler.characters`
end element : `p`	`ContentHandler.endElement`
end element : `doc`	`ContentHandler.endElement`
end document	`ContentHandler.endDocument`

Modèle de mise en œuvre

Deux composants :

1. un programme principal basé sur JAXP
2. une implantation de `ContentHandler`

Comportement attendu : affichage les éléments contenus dans le document XML analysé.

Implantation du `ContentHandler`

PrintElement

```
1  import org.xml.sax.helpers.DefaultHandler;
2  import org.xml.sax.Attributes;
3  public class PrintElement extends DefaultHandler {
4    public void startElement(String namespaceURI, String localName,
5                             String qName, Attributes atts) {
6      System.out.println(qName);
7    }
8  }
```

- on dérive de `DefaultHandler` : permet de ne programmer que ce qui nous intéresse
- la méthode `startElement` est appelée à chaque balise ouvrante rencontrée
- `Attributes` : les attributs de la balise ouvrante
- les autres paramètres : nom de l'élément (prise en compte des espaces de noms)

Analyse syntaxique

Avec JAXP :

- permet de changer d'implantation de SAX sans modifier l'application
- algorithme :
  1. on crée une usine à *parser* (`SAXParserFactory`)
  2. on configure l'usine (c'est-à-dire les analyseurs qu'elle va produire)
  3. on crée l'analyseur (`SAXParser`)
  4. on lance l'analyse syntaxique (méthode `parse`)
- l'analyse syntaxique se fait à partir d'un `DefaultHandler` (i.e., toutes les interfaces implantées d'un seul coup)
- solution plus souple en obtenant un `XMLReader` (SAX)

Modèle

AnalyseDeBase

```
1  import javax.xml.parsers.SAXParserFactory;
2  import javax.xml.parsers.SAXParser;
3  import org.xml.sax.SAXException;
4  import java.io.IOException;
5  import java.io.File;
6  public class AnalyseDeBase {
7    public static void main(String[] args) {
8      if(args.length!=1) {
9        System.err.println("usage: AnalyseDeBase xmlfile");
10       System.exit(1);
11     }
12     try {
13       // création de l'usine
14       SAXParserFactory factory=SAXParserFactory.newInstance();
15       factory.setNamespaceAware(true);
16       factory.setValidating(false);
17       // création de l'analyseur
18       SAXParser parser=factory.newSAXParser();
```

Modèle (2)

AnalyseDeBase

```
19        // ContentHandler
20        PrintElement handler=new PrintElement();
21        try {
22          // analyse du document
23          parser.parse(new File(args[0]),handler);
24        } catch (SAXException se) {
25          se.printStackTrace();
26        } catch (IOException ioe) {
27          ioe.printStackTrace();
28        }
29      } catch (Exception e) {
30        System.err.println(e);
31      }
32    }
33  }
```

Résultat

Appliqué à

a-memo.xml

```
1 <?xml version="1.0" encoding="ISO-8859-1"?>
2 <mémo>
3 <de>John</de>
4 <à>Bob</à>
5 <contenu>
6 <titre>Bonjour</titre>
7 <texte>Ca va ?</texte>
8 </contenu>
9 </mémo>
```

le programme affiche

```
mémo
de
à
contenu
titre
texte
```

Affichage des données

On propose un nouveau `DocumentHandler` :

PrintText

```
1  import org.xml.sax.helpers.DefaultHandler;
2  import org.xml.sax.SAXException;
3  public class PrintText extends DefaultHandler {
4    public void characters(char[] ch, int start, int length) {
5      System.out.println('"'+(new String(ch,start,length))+'"');
6    }
7  }
```

- la méthode `characters` est appelée à chaque évènement de texte
- paramètres :
  - `char[] ch` : tableau de charactères contenant le texte de l'évènement
  - `int start` : début du texte dans le tableau
  - `int length` : longueur du texte
- on modifie `AnalyseBase` pour utiliser `PrintText`

Résultat

Appliqué au mémo, le programme affiche :

```
"
"
"John"
"
"
"Bob"
"
"
"
"
"Bonjour"
"
"
"Ca va ?"
"
"
"
"
```

Interprétation

- un évènement `characters` à chaque fois qu'il y a du texte en dehors d'une balise
- chaque couple de guillemets correspond à un texte
- caractère invisible : **passage à la ligne !**
- un passage à la ligne après chaque élément (ici 7)
- deux solutions :
  - ajouter une DTD et activer la validation
    - modifier la ligne 16 de `AnalyseDeBase`
    - ajouter éventuellement un `ErrorHandler` (pour avoir les messages d'erreur)
  - déterminer (à la main) si la chaîne de caractères correspond à quelque chose

Version avec validation

On remplace le mémo par :

a-memo-dtd.xml

```
1  <?xml version="1.0" encoding="ISO-8859-1"?>
2  <!DOCTYPE mémo [
3  <!ELEMENT mémo (de,à,contenu)>
4  <!ELEMENT de (#PCDATA)>
5  <!ELEMENT à (#PCDATA)>
6  <!ELEMENT contenu (titre,texte)>
7  <!ELEMENT titre (#PCDATA)>
8  <!ELEMENT texte (#PCDATA)>
9  ]>
10 <mémo>
11 <de>John</de>
12 <à>Bob</à>
13 <contenu>
14 <titre>Bonjour</titre>
15 <texte>Ca va ?</texte>
16 </contenu>
17 </mémo>
```

Version avec validation (2)

Quand on active la validation, on obtient l'affichage suivant :

```
"John"
"Bob"
"Bonjour"
"Ca va ?"
```

Interprétation :

- l'analyseur sait que les espaces (au sens large) peuvent être ignorés
- pour une suite d'espaces ignorables, il appelle `ignorableWhitespace` à la place de `characters`
- certains analyseurs (comme `Xerces`) n'ont pas besoin d'être en mode validant pour lire la DTD et l'exploiter (en partie)

Solution intéressante, mais qui nécessite un modèle de contenu et une validation (partielle) de celui-ci.

Version avec validation (3)

Il est reste des subtilités. Par exemple :

a-memo-dtd-2.xml

```
1 <?xml version="1.0" encoding="ISO-8859-1"?>
2 <!DOCTYPE mémo SYSTEM "memo.dtd">
3 <mémo><de>John</de><à>Bob</à>
4 <contenu><titre>Bonjour</titre><texte>Ca
5 va
6 ?</texte>
7 </contenu>
8 </mémo>
```

donne :

```
"John"
"Bob"
"Bonjour"
"Ca "
"
va "
"
?"
```

Emplacement dans l'arbre

- une feuille de données peut être traduite en *plusieurs* évènements `characters`
- la méthode `characters` (comme les autres méthodes) n'a aucun moyen (automatique) de connaître son contexte d'appel :
  - l'appel correspondant à "John" est "identique" à celui correspondant à "Bob"
  - il n'y a pas de lien entre les appels correspondant au contenu de l'élément `texte`
- question générale : **comment connaître le contexte d'un évènement ?**
- réponse : pas de solution automatique $\Rightarrow$ programmation au cas par cas

Contexte d'un évènement

Cas général :

- on utilise une pile (variable d'instance du `ContentHandler`)
- chaque balise ouvrante empile un élément
- chaque balise fermante dépile un élément
- à tout moment, la pile contient la branche de l'arbre contexte d'un évènement
- la localisation reste limitée : pas de prise en compte de l'ordre des fils d'un élément (et plus généralement du contexte d'un nœud, excepté les parents)

Une solution par pile

ContextStack

```
1  import org.xml.sax.helpers.DefaultHandler;
2  import org.xml.sax.Attributes;
3  import java.util.*;
4  public class ContextStack extends DefaultHandler {
5    private List stack;
6    public void startDocument() {
7      stack=new ArrayList();
8    }
9    public void startElement(String namespaceURI, String localName,
10                            String qName, Attributes atts) {
11     stack.add(qName);
12     Iterator i=stack.iterator();
13     StringBuffer context=new StringBuffer(i.next().toString());
14     while(i.hasNext()) {
15       context.append('/');
16       context.append(i.next());
17     }
18     System.out.println(context);
19   }
```

Une solution par pile (2)

ContextStack

```
20    public void endElement(String namespaceURI, String localName,
21                           String qName) {
22      stack.remove(stack.size()-1);
23    }
24  }
```

Affichage sur le mémo :

```
mémo
mémo/de
mémo/à
mémo/contenu
mémo/contenu/titre
mémo/contenu/texte
```

Remarque : `startDocument`, méthode appelée une fois au début de l'analyse.

Application

Extraire le texte du mémo sous forme d'une (unique) `String` :

- Algorithme naïf : concaténer les chaînes obtenues lors des appels de `characters` correspondant à l'élément `texte`
- Problème en SAX :
  - obtenir le contexte
  - garder en mémoire le résultat des évènements antérieurs
  - communiquer le résultat à la méthode appelante
- Solution possible :
  - déterminer le contexte
  - conserver les résultats intermédiaire dans des variables d'instance du `ContentHandler`
  - ajouter des méthodes au `ContentHandler` pour obtenir les résultats

Une solution par pile

MemoGetText

```
1  import org.xml.sax.helpers.DefaultHandler;
2  import org.xml.sax.Attributes;
3  import java.util.*;
4  public class MemoGetText extends DefaultHandler {
5    private List stack;
6    private StringBuffer result;
7    public void startDocument() {
8      stack=new ArrayList();
9      result=new StringBuffer();
10   }
11   public void startElement(String namespaceURI, String localName,
12                            String qName, Attributes atts) {
13     stack.add(qName);
14   }
15   public void endElement(String namespaceURI, String localName,
16                          String qName) {
17     stack.remove(stack.size()-1);
18   }
```

Une solution par pile (2)

MemoGetText

```
19    public void characters(char[] ch, int start, int length) {
20      if(stack.size()>0 && stack.get(stack.size()-1).equals("texte")) {
21        result.append(new String(ch,start,length));
22      }
23    }
24    // méthode spécifique
25    public String getText() {
26      return result.toString();
27    }
28  }
```

Modification dans `AnalyseBase` :

AnalyseGetText

```
20      MemoGetText handler=new MemoGetText();
21      try {
22        // analyse du document
23        parser.parse(new File(args[0]),handler);
24        // récupération du résultat
25        String result=handler.getText();
26        System.out.println(result);
```

Une solution par pile (3)

L'application à

a-memo-dtd-2.xml

```
1  <?xml version="1.0" encoding="ISO-8859-1"?>
2  <!DOCTYPE mémo SYSTEM "memo.dtd">
3  <mémo><de>John</de><à>Bob</à>
4  <contenu><titre>Bonjour</titre><texte>Ca
5  va
6  ?</texte>
7  </contenu>
8  </mémo>
```

donne :

```
Ca
va
?
```

sous forme d'une seule `String`.

Critique

- l'utilisation de la pile n'est pas justifiée
- solution possible par un automate à pile très simple
- Exemple dans le cas du mémo :

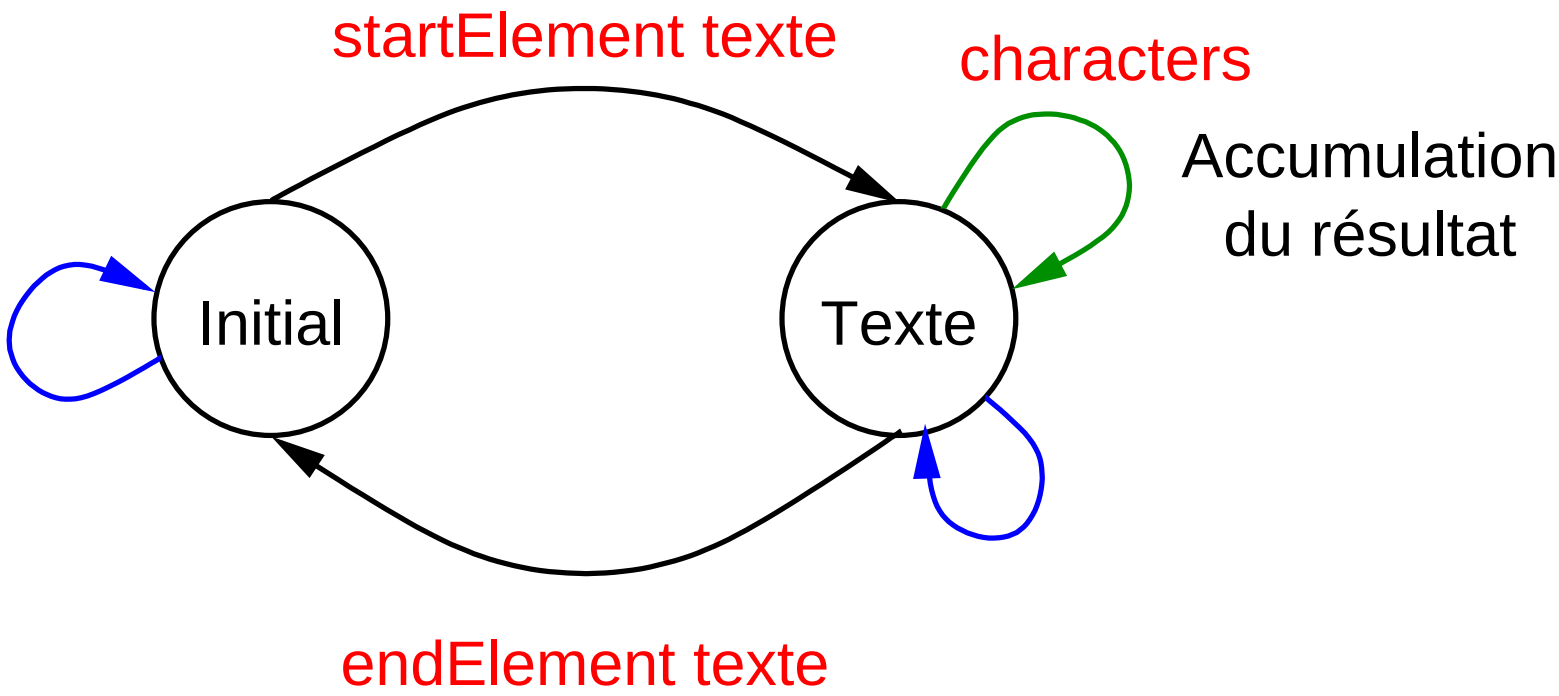

Implantation simple

MemoGetText2

```
1  import org.xml.sax.helpers.DefaultHandler;
2  import org.xml.sax.Attributes;
3  import java.util.*;
4  public class MemoGetText2 extends DefaultHandler {
5    private boolean inText=false;
6    private StringBuffer result=new StringBuffer();
7    public void startElement(String namespaceURI, String localName,
8                             String qName, Attributes atts) {
9      if(qName.equals("texte")) {
10       inText=true;
11     }
12   }
13   public void endElement(String namespaceURI, String localName,
14                          String qName) {
15     if(qName.equals("texte")) {
16       inText=false;
17     }
18   }
```

Implantation simple (2)

MemoGetText2

```
19    public void characters(char[] ch, int start, int length) {
20      if(inText) {
21        result.append(new String(ch,start,length));
22      }
23    }
24    // méthode spécifique
25    public String getText() {
26      return result.toString();
27    }
28  }
```

- ici l'automate est basique $\Rightarrow$ un `boolean`
- il faut être très attentif aux transitions : ici on reste dans l'état Texte tant qu'on n'a pas vu une balise fermante `texte`

Implantation simple (3)

L'application à

another-memo.xml

```
1  <?xml version="1.0" encoding="ISO-8859-1"?>
2  <mémo>
3  <de>John</de>
4  <à>Bob</à>
5  <contenu>
6  <titre>Bonjour</titre>
7  <texte><strong>Ca va ?</strong>
8  Je teste le mémo.
9  </texte>
10 </contenu>
11 </mémo>
```

donne :

```
1  Ca va ?
2  Je teste le mémo.
3
```

sous forme d'une seule `String`.

Gestion des erreurs

- pour gérer les erreurs, il faut implanter `ErrorHandler`
- très utile quand le *parser* est validant
- Exemple :

PrintError

```
1  import org.xml.sax.ErrorHandler;
2  import org.xml.sax.SAXParseException;
3  import org.xml.sax.SAXException;
4  public class PrintError implements ErrorHandler {
5    public void error(SAXParseException exception) throws SAXException {
6      System.err.println("error: "+exception);
7    }
8    public void fatalError(SAXParseException exception)
9      throws SAXException {
10     System.err.println("fatal error: "+exception);
11   }
12   public void warning(SAXParseException exception)
13     throws SAXException {
14     System.err.println("warning: "+exception);
15   }
16 }
```

Activation de la validation

AnalyseValid

```
1  import javax.xml.parsers.SAXParserFactory;
2  import javax.xml.parsers.SAXParser;
3  import org.xml.sax.SAXException;
4  import org.xml.sax.ContentHandler;
5  import java.io.IOException;
6  import java.io.File;
7  import org.xml.sax.XMLReader;
8  public class AnalyseValid {
9    public static void main(String[] args) {
10     if(args.length!=1) {
11       System.err.println("usage: AnalyseValid xmlfile");
12       System.exit(1);
13     }
14     try {
15       SAXParserFactory factory=SAXParserFactory.newInstance();
16       factory.setNamespaceAware(true);
17       // activation de la validation (DTD !)
18       factory.setValidating(true);
19       SAXParser parser=factory.newSAXParser();
20       MemoGetText2 handler=new MemoGetText2();
```

Activation de la validation (2)

AnalyseValid

```
21        // on passe par SAX
22        XMLReader reader=parser.getXMLReader();
23        reader.setContentHandler(handler);
24        // mise en place du gestionnaire d'erreur
25        reader.setErrorHandler(new PrintError());
26        try {
27          // analyse (SAX)
28          reader.parse(args[0]);
29          System.out.println(handler.getText());
30        } catch (SAXException se) {
31          se.printStackTrace();
32        } catch (IOException ioe) {
33          ioe.printStackTrace();
34        }
35      } catch (Exception e) {
36        System.err.println(e);
37      }
38    }
39  }
```

Activation de la validation (3)

L'analyse de `another-memo.xml` donne :

```
1 error: org.xml.sax.SAXParseException: Document is invalid: no grammar found.
2 error: org.xml.sax.SAXParseException: Document root element "mémo", must
3 match DOCTYPE root "null".
4 Ca va ?
5 Je teste le mémo.
6
```

En jouant avec le `ErrorHandler` et les exceptions, on peut éviter de traiter un document non valide. Limitations :

- pas de support direct des schémas dans SAX et JAXP (1.1)
- pour les schémas W3C, on doit passer par des *features* SAX spécifiques à Xerces (par exemple) ou par JAXP 1.2
- pour RELAX NG, on utilise un validateur externe

Gestion des attributs

- très facile grâce à `Attributes`
- permet de parcourir la liste des attributs :
  - grâce à la position
  - directement grâce au nom de l'attribut
  - exemple :

PrintAttributes

```
1  import org.xml.sax.helpers.DefaultHandler;
2  import org.xml.sax.Attributes;
3  public class PrintAttributes extends DefaultHandler {
4    public void startElement(String namespaceURI, String localName,
5                             String qName, Attributes atts) {
6      System.out.println(qName);
7      for(int i=0;i<atts.getLength();i++) {
8        System.out.println("\t"+atts.getQName(i)+"="+atts.getValue(i));
9      }
10     String bozo=atts.getValue("bozo");
11     if(bozo!=null) System.out.println("\tBozo : "+bozo);
12   }
13 }
```

Exemple

L'application à

atts.xml

```
1  <?xml version="1.0" encoding="ISO-8859-1"?>
2  <a val="12">
3    <b/><c truc="bidude"/>
4    <c bozo="hop"/><d x="1" y="2"/>
5  </a>
```

donne :

```
1  a
2          val=12
3  b
4  c
5          truc=bidude
6  c
7          bozo=hop
8          Bozo : hop
9  d
10         x=1
11         y=2
```

Autres possibilités de SAX

- `EntityResolver` : gestion des entités XML
- `DTDHandler` : support basique des DTDs
- `DeclHandler` : support additionnel pour les DTDs (extension de SAX)
- `LexicalHandler` : support des commentaires et autres détails (extension)
- `XMLFilter` :
  - comme un `XMLReader`, mais “lit” un `XMLReader` au lieu d’un fichier
  - permet de fabriquer une chaîne de traitements

Résumé

SAX n'est pas toujours facile d'emploi :

- l'accès est séquentiel
- l'API n'a aucune mémoire : impossible de connaître le contexte d'un évènement

Il faut :

- avoir un modèle de l'analyse (par exemple sous forme d'un automate)
- gérer à la main la mémorisation des informations importantes
- en particulier le contexte (la position dans l'arbre)

DOM

DOM

Document Object Model :

- recommandation du W3C
- `http ://www.w3.org/DOM/`
- s'applique à XML et à HTML (utilisé en particulier dans les navigateurs avec Javascript)
- Level 1 : 1 octobre 98, Level 2 (XML) : 13 novembre 2000, Level 3 : *working draft*, devrait sortir dans le courant de l'année 2003
- nombreuses implantations (par exemple Xerces, open source)

Langage de référence : IDL (Interface Definition Language, CORBA). Il existe des *bindings* dans de très nombreux langages (Java, Javascript, C, C++, Perl, Python, VB, etc.).

Caractéristiques majeures

- modèle objet (arbre)
- haut niveau
- très riche (nombreux outils intégrés, surtout depuis le Level 2)
- coûteux : document entièrement en mémoire
- parfois un peu lourd à programmer
- en général construit au dessus de SAX : un `ContentHandler` spécifique transforme le flux d'évènements en un arbre (exemple : Xerces)

Attention : pour de gros documents XML, DOM est pratiquement impossible à utiliser (la définition de gros évolue avec les capacités des ordinateurs !)

Modèle par arbre

Principes :

- un document est transformé en un objet `Document`
- un `Document` possède quelques fils :
  - un `Element` : la racine du document
  - divers éléments *top level* : commentaires, *processing instructions* et DTD (pour l'accès aux entités)
- la structure d'arbre est obtenue grâce aux `Elements` :
  - un `Element` possède éventuellement des fils `Elements` ou `Text`
  - un `Element` possède éventuellement des attributs (`Attr`)
- DOM définit toutes les interfaces de manipulations de l'arbre et de son contenu

Modèle en mémoire

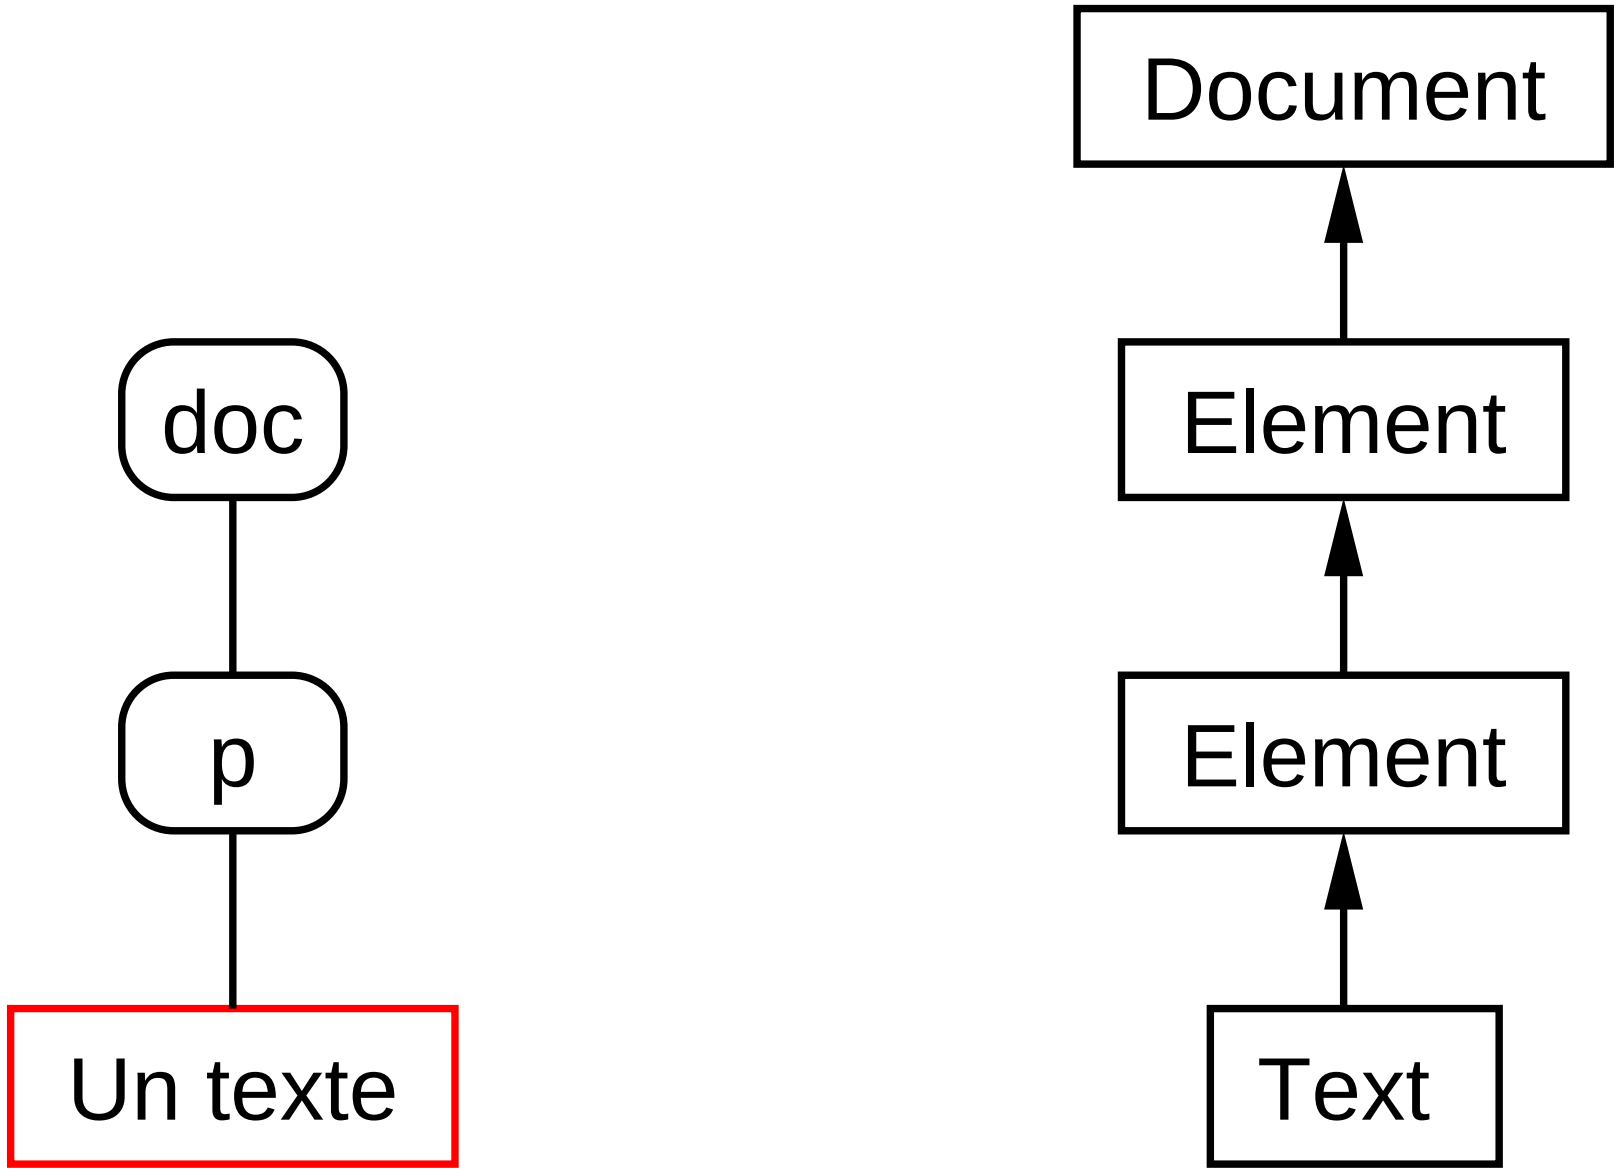

Diagramme des interfaces (partiel)

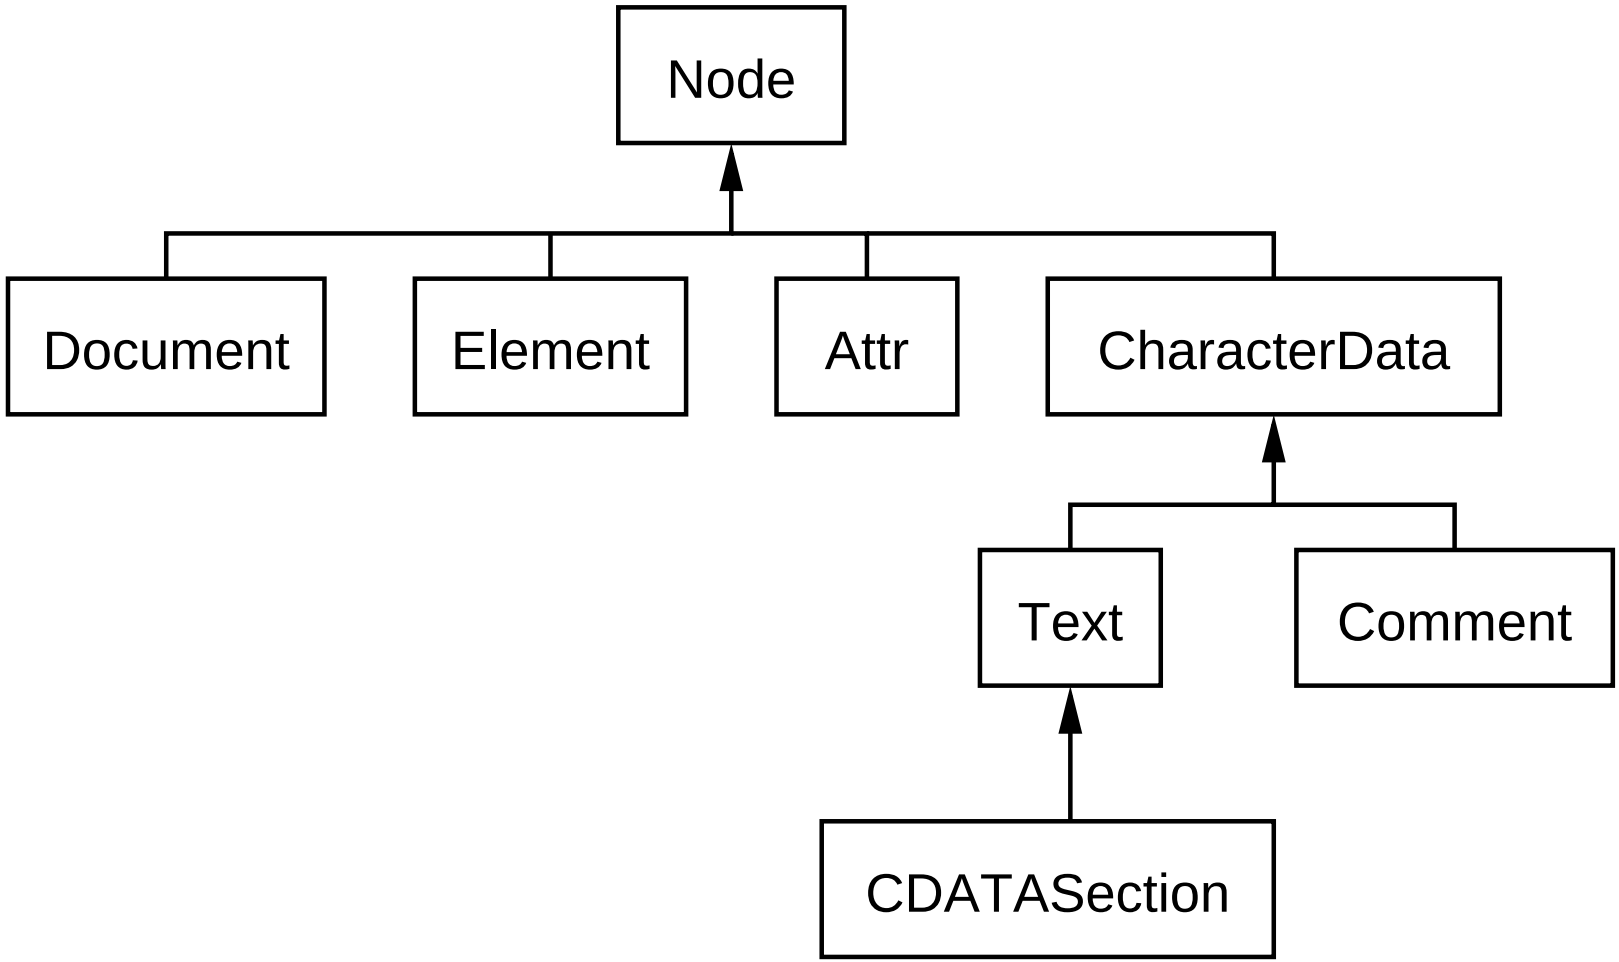

Remarques

- il y a d'autres classes (`DocumentType`, `EntityReference`, etc.)
- l'héritage est "déroutant" :
  - certains méthodes de `Node` n'ont pas vraiment de sens à ce niveau :
    - `getNodeName` : nom de l'élément (pas de sens pour du texte)
    - `getNodeValue` : contenu du nœud (étrange pour un élément)
  - le typage se fait par une constante de type `short` : `getNodeType`
- implantations astucieuses :
  - développement paresseux de l'arbre
  - modèle interne léger (*Document Table Model* de Xalan)

Utilisation

Modèle d'une application DOM :

1. création d'un parseur DOM
2. (in)activation des options du parseur
3. obtention de l'objet Document
4. manipulations du document

Amorce de traitement récursif :

dom/java/Amorce

```
1  Document doc=...;
2  Node root=doc.getDocumentElement();
3  root.normalize();
4  traitement(root);
```

Problème de portabilité

DOM n'est pas assez complet, ce qui oblige à utiliser des extensions spécifiques à chaque implantation :

- DOM niveau 1 : pas de création du *parseur*, pas de gestion des options, pas d'obtention d'un `Document`
- DOM niveau 2 : création d'un `Document` vide (pas de lecture, pas de sauvegarde, etc.)
- DOM niveau 3 (enfin !) : API spécifique *Load and Save* qui règle les problèmes de portabilité (*draft* supporté par Xerces)
- JAXP 1.1 : règle les problèmes de portabilité en Java

Exemple récursif

dom/java/PrintTextRecursif

```
1  public static void print(Node node) {
2    switch(node.getNodeType()) {
3    case Node.ELEMENT_NODE:
4      NodeList children=node.getChildNodes();
5      for(int i=0;i<children.getLength();i++) {
6        print(children.item(i));
7      }
8      break;
9    case Node.TEXT_NODE:
10     String text=node.getNodeValue().trim();
11     if(text.length()>0) {
12       System.out.println(text);
13     }
14     break;
15   default:
16     // rien à faire d'autre
17   }
18 }
```

Exemple itératif

dom/java/PrintTextIteratif

```
1  public static void printIteratif(Node node) {
2    final int DOWN=1;
3    final int UP=2;
4    int status=DOWN;
5    while(node!=null) {
6      if(node.getNodeType()==Node.TEXT_NODE) {
7        String text=node.getNodeValue().trim();
8        if(text.length()>0)
9          System.out.println(text);
10     }
11     Node next;
12     if(status==DOWN) {
13       next=node.getFirstChild();
14       if(next!=null) {
15         node=next;
16         continue;
17       }
18     }
```

Exemple itératif (suite)

dom/java/PrintTextIteratif2

```
1     next=node.getNextSibling();
2     if(next!=null) {
3       node=next;
4       status=DOWN;
5     } else {
6       node=node.getParentNode();
7       status=UP;
8     }
9   }
10 }
```

Outils de haut niveau

DOM Level 2 apporte des outils de haut niveau :

- *Traversal* :
  - API de parcours de l'arbre
  - filtre sur les noeuds `NodeFilter`
  - itération `NodeIterator`
  - parcours complet `TreeWalker`
- *Range* : modèle de sélection dans un arbre DOM
- *Events* : évènements de modification d'un arbre DOM
- etc.

Exemple

dom/java/PrintTraversal

```
1  public static void printTraversal(Node node,Document doc) {
2    NodeIterator iter=
3      ((DocumentTraversal)doc).createNodeIterator(
4          node, NodeFilter.SHOW_TEXT, null,true);
5    node=iter.nextNode();
6    while (node!=null) {
7      String text=node.getNodeValue().trim();
8      if(text.length()>0) {
9        System.out.println(text);
10     }
11     node=iter.nextNode();
12   }
13 }
```