par Philippe Poulard

DOM & SAX

INRIA SOPHIA ANTIPOLIS

Philippe.Poulard@sophia.inria.fr

Sommaire

L'analyse XML

DOM

SAX

Analyseur XML

XML parser 


```
<?xml version="1.0" encoding="ISO-8859-1"?>
<!DOCTYPE Cours SYSTEM "Cours.dtd">
<Cours>
    <Titre>Cours XML</Titre>
    <Auteur>        <Nom>Poulard</Nom>
                    <Prénom>Philippe</Prénom>
    </Auteur>
    <Description>Ce cours aborde les concepts
         de base mis en œuvre dans <b>XML</b>
    </Description>
</Cours>
```

Structure physique

parsing

Processeur XML

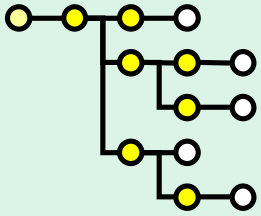

arbre DOM

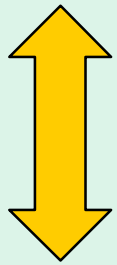

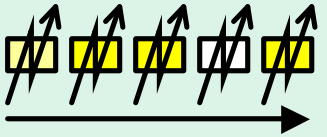

événements SAX

Modèle logique (Infoset)

Accède au document grâce aux APIs DOM ou SAX

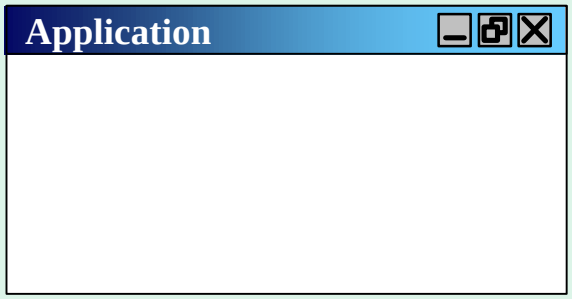

Application

Document Object Model

DOM, norme du W3C

Modèle Object du Document :
une API pour **accéder** et **agir** sur
le contenu et la structure d'un document

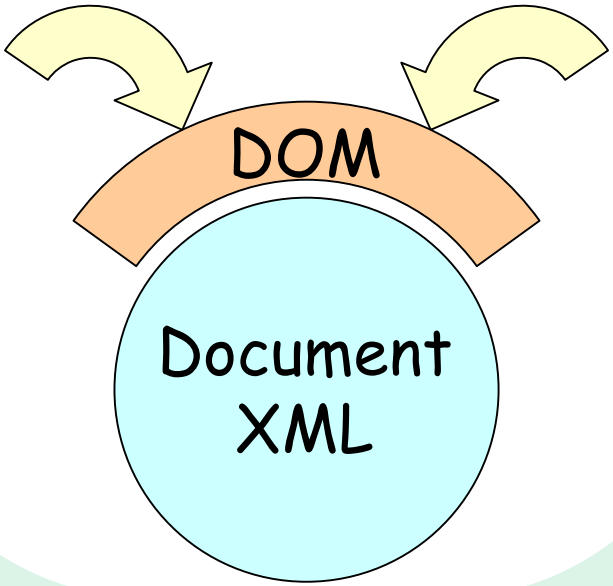

Le document est vu comme un arbre
Sa représentation ne l'est pas nécessairement
(DOM spécifie une API, pas une implémentation)

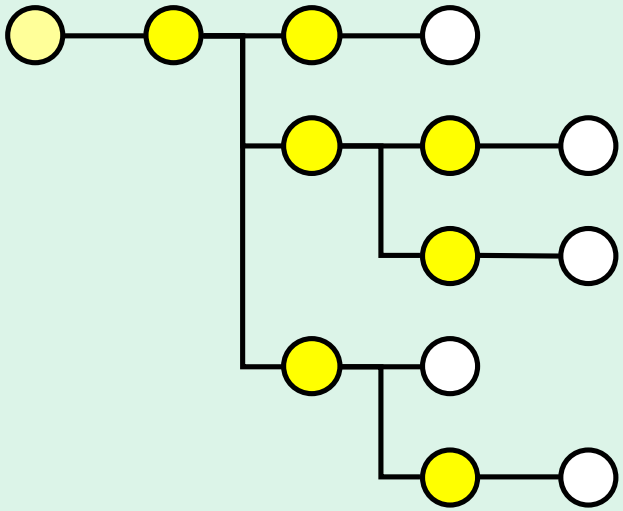

Schémas, XPath, entrées/sorties

Namespaces, vues, événements, styles, parcours

Noyau, HTML

Pas de compatibilité binaire entre différentes implémentations

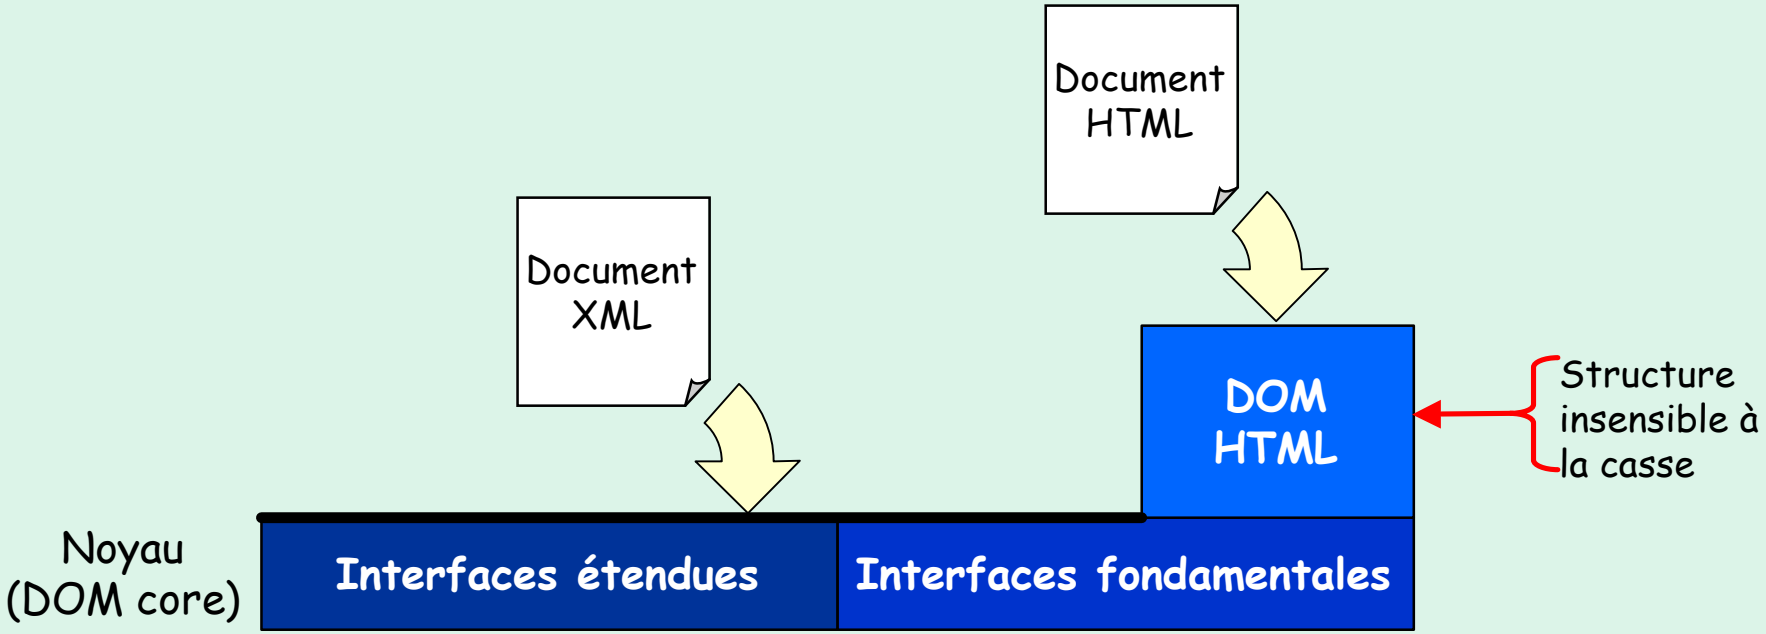

- CDATASection
- DocumentType
- Notation
- Entity
- EntityReference
- ProcessingInstruction

- Document
- DocumentFragment
- Element
- Attr
- Comment
- DOMImplementation
- Node
- NodeList
- NamedNodeMap
- CharacterData
- Text
- ***DOMException*** ← Classe

Le modèle d'objet spécifié par le W3C défini 12 types de nœuds différents.

Le modèle d'objet de document fourni tout une panoplie d'outils destinés à construire et manipuler un document XML. Pour cela, le DOM met à disposition des interfaces, des méthodes et des propriétés permettant de gérer l'ensemble des composants présents dans un document XML.

Le DOM spécifie diverses méthodes et propriétés permettant notamment, de **créer** (*createNode*…), **modifier** (*replaceChild*…), **supprimer** (*remove*…) ou d'**extraire des données** (*get*…) de n'importe quel élément ou contenu d'un document XML.

De même, **le DOM définit les types de relation entre chaque noeud, et des directions de déplacement dans une arborescence XML.** Les propriétés *parentNode*, *childNodes*, *firstChild*, *lastChild*, *previousSibling* et *nextSibling* permettent de retourner respectivement le père, les enfants, le premier enfant, le dernier enfant, le frère précédent et le frère suivant du noeud courant.

Le modèle d'objet de document offre donc au programmeur les moyens de traiter un document XML dans sa totalité

Principes de l'API DOM

- Vues héritées → Hiérarchie d'objet
- Vues aplaties → Tout est Node

Exemple

```
Element.tagName
        =
Node.nodeName
```

Si le nœud est un élément

Les implémentations sont libres d'utiliser ou non des accesseurs (`get`) et des mutateurs (`set`) pour protéger les propriétés

MSXML →
```
theName = node.nodeName;
```
Java →
```
theName = node.getNodeName();
```

DOM spécifie une API à minima. Les implémentations sont libres d'étendre les fonctionnalités

MSXML →
```
resultHTML = source.transformNode(stylesheet);
```

DOM level 2

Introduction des espaces de nommage : méthodes postfixées par `NS`

```
node.setAttributeNS(null, attr, value);
```
→ Default namespace

Node

Représente un nœud de l'arborescence d'un document XML.

Propriétés :

attributes, childNodes, firstChild, lastChild, localName, namespaceURI, nextSibling, nodeName, nodeType, nodeValue, ownerDocument, parentNode, prefix, previousSibling

Méthodes :

appendChild, cloneNode, hasAttributes, hasChildNodes, insertBefore, isSupported, normalize, removeChild, replaceChild

L'interface Node défini des constantes qui permettent de connaître le type du noeud

nodeType	nodeName	nodeValue
ELEMENT_NODE = 1	Nom d'élément	null
ATTRIBUTE_NODE = 2	Nom de l'attribut	Valeur de l'attribut
TEXT_NODE = 3	"#text"	Contenu du nœud du texte
CDATA_SECTION_NODE = 4	"#cdata-section"	Contenu de la section CDATA
ENTITY_REFERENCE_NODE = 5	Nom de l'entité référencée	null
ENTITY_NODE = 6	Nom de l'entité	null
PROCESSING_INSTRUCTION_NODE = 7	Cible	Contenu complet, sans la cible
COMMENT_NODE = 8	"#comment"	Contenu du commentaire
DOCUMENT_NODE = 9	"#document"	null
DOCUMENT_TYPE_NODE = 10	Nom du type de document	null
DOCUMENT_FRAGMENT_NODE = 11	"#document-fragment"	null
NOTATION_NODE = 12	Nom de notation	null

nodeType permet d'obtenir le type de nœud

Le goût du blanc


```
<?xml version="1.0" encoding="ISO-8859-1"?>
<Cours>¿
   ®   <Titre>Cours XML</Titre>¿
   ®   <Auteur>¿
   ®      ®   <Nom>Poulard</Nom>¿
   ®      ®   <Prénom>Philippe</Prénom>¿
   ®   </Auteur>¿
   ®   <Description>¿
   ®   Ce cours aborde les <b>concepts</b>¿
   ®   de base mis en &#339;uvre dans XML.¿
   ®   </Description>¿
</Cours>
```

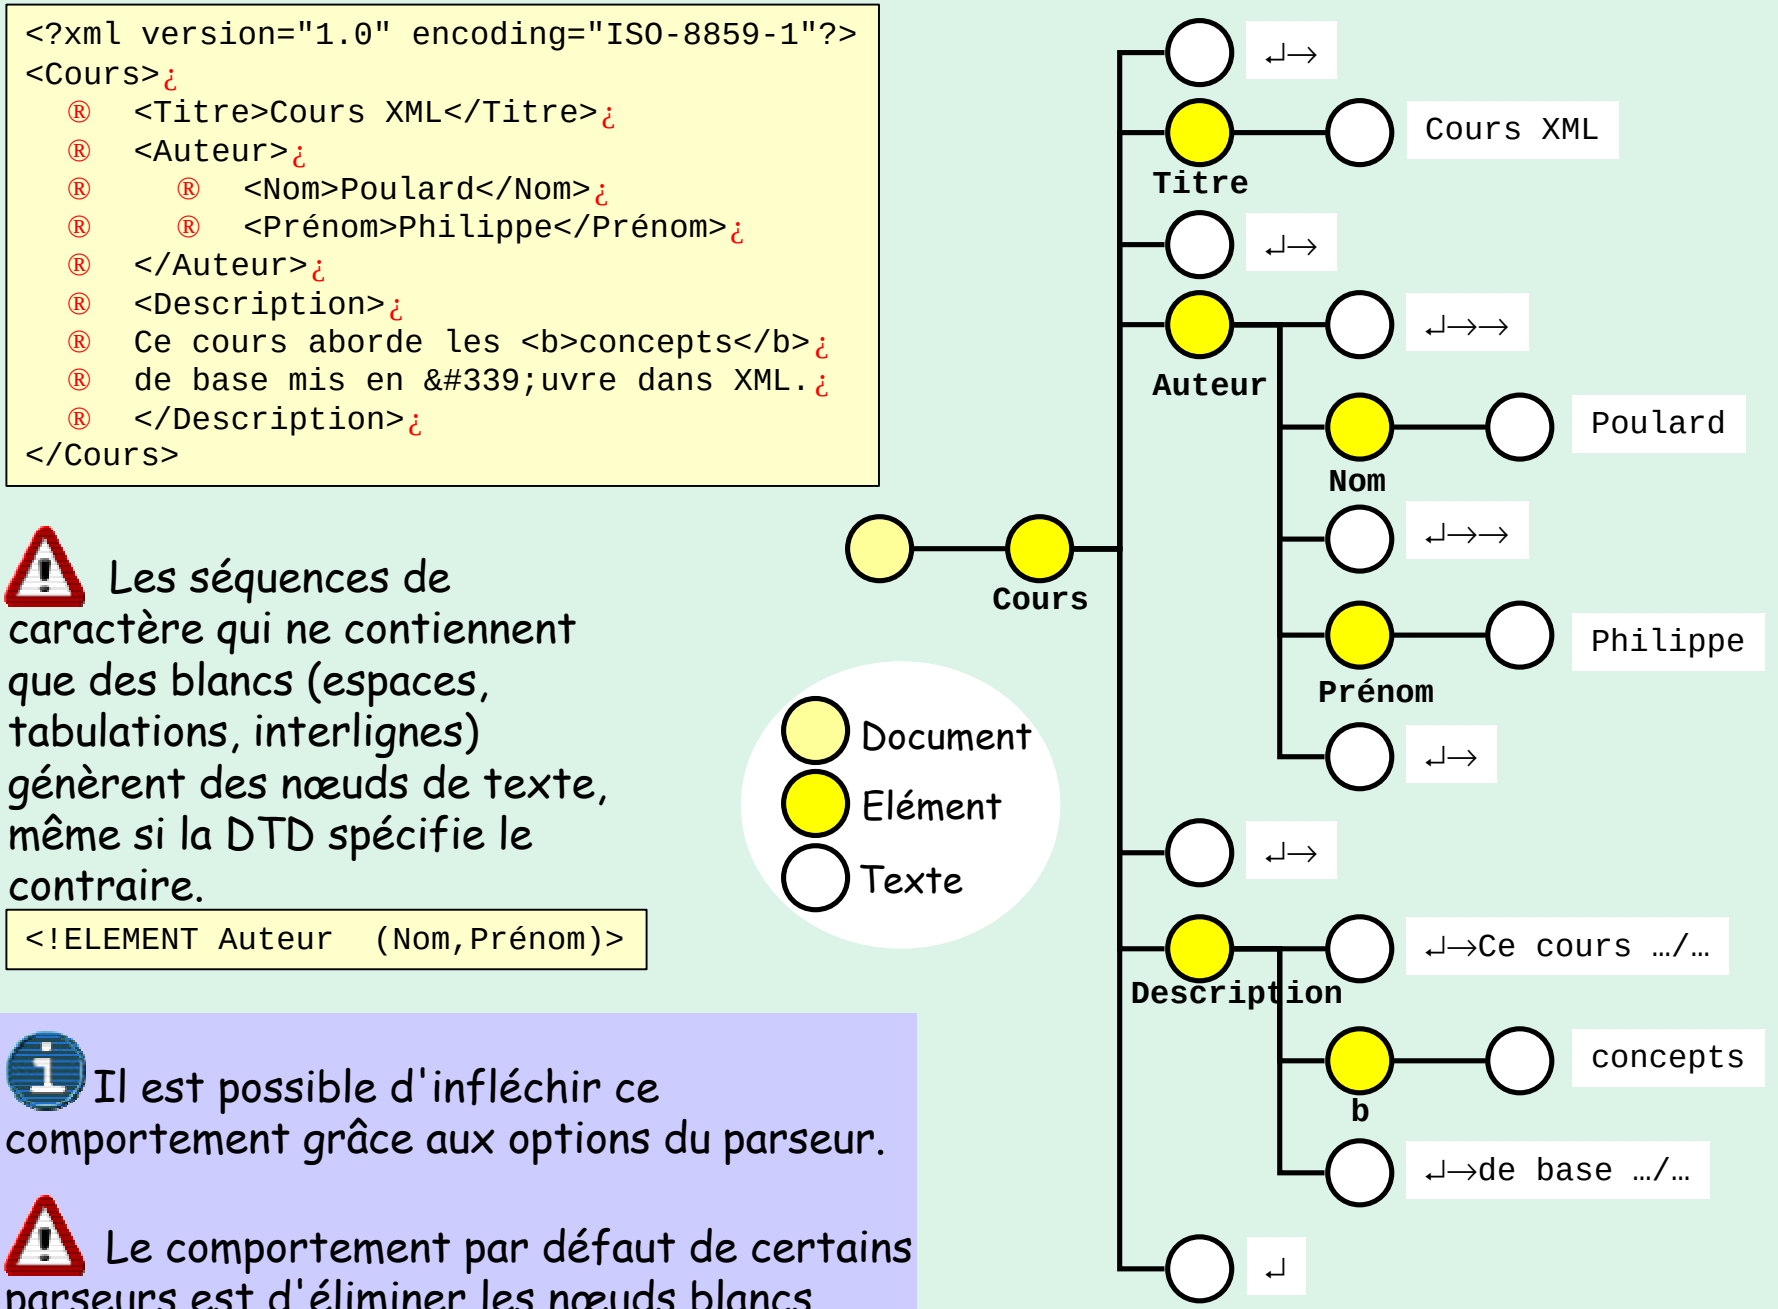

Les séquences de caractère qui ne contiennent que des blancs (espaces, tabulations, interlignes) génèrent des nœuds de texte, même si la DTD spécifie le contraire.

```
<!ELEMENT Auteur  (Nom,Prénom)>
```

Il est possible d'infléchir ce comportement grâce aux options du parseur.

Le comportement par défaut de certains parseurs est d'éliminer les nœuds blancs.

Déplacement dans l'arbre


```
<?xml version="1.0" encoding="ISO-8859-1"?>
<Cours>
          <Titre>Cours XML</Titre>
          <Auteur>
                    <Nom>Poulard</Nom>
                    <Prénom>Philippe</Prénom>
          </Auteur>
          <Description>
          Ce cours aborde les <b>concepts</b> de
          base mis en &#339;uvre dans XML.
          </Description>
</Cours>
```

```
Node#parentNode;
Node#hasChildNodes();
Node#firstChild;
Node#lastChild;
Node#previousSibling;
Node#nextSibling;
```

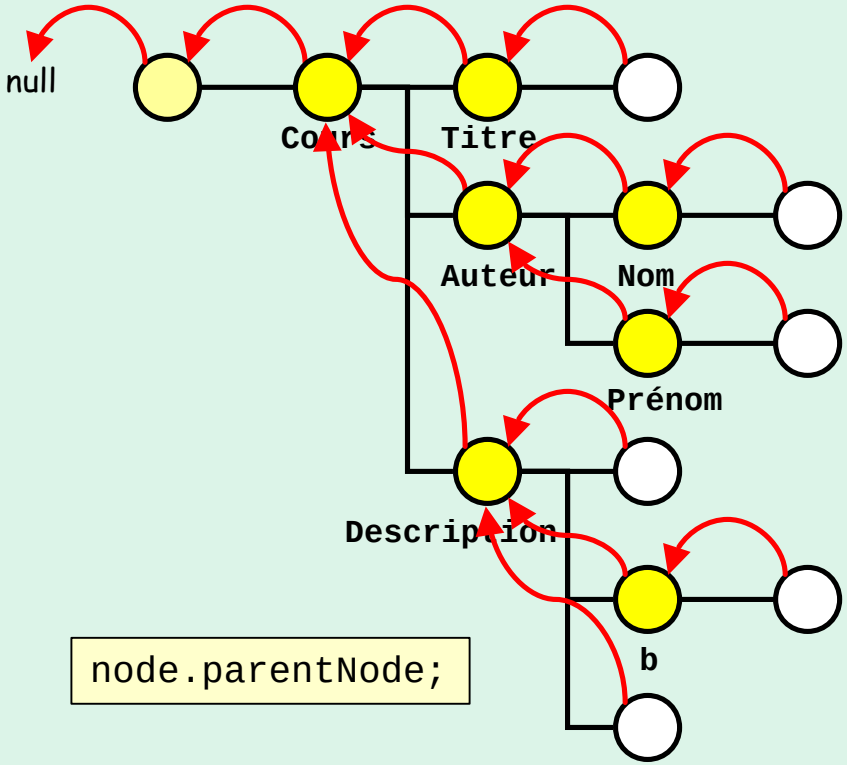

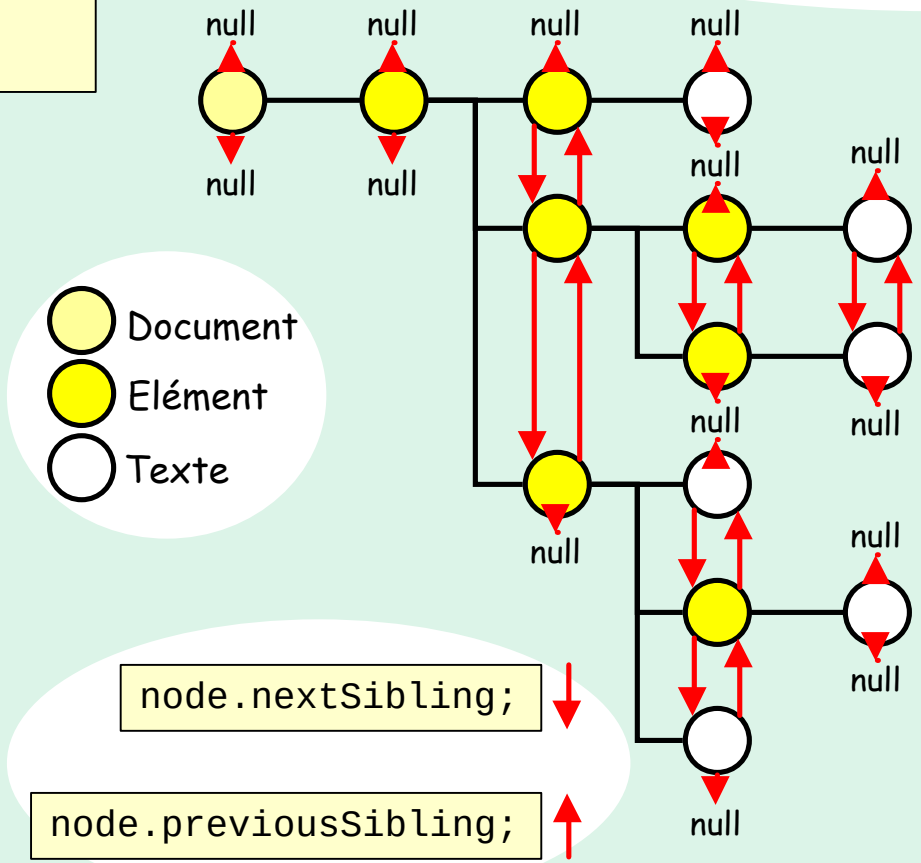

NodeList

Représente une collection de nœuds ordonnés.

Propriétés :

length

Méthodes :

item

Parcours des éléments de niveau inférieur immédiat

```
for (Node child = node.getFirstChild();
          child != null;
          child = child.getNextSibling()) {
    // do something
}
```

ou

```
NodeList nodeList = node.getChildNodes();
for (int i = 0;
          i < nodeList.getLength();
          i++) {
    Node child = nodeList.item(i);
    // do something
}
```

Parcours récursif

```
public void processNodeRecursively(Node node) {
    // do something
    for (Node child = node.getFirstChild();
          child != null;
          child = child.getNextSibling()) {
        processNodeRecursively(child);
    }
}
```

DOM level 2

traversal

```
DocumentTraversal t;
NodeIterator ni;
Node child;
t = (DocumentTraversal) node.getOwnerDocumet();
ni = t.createNodeIterator(node, NodeFilter.SHOW_ALL, null, false);
while ((child = iterator.nextNode()) != null) {
    // do something
}
ni.detach();
```

Document

Représente le document XML ou HTML.

Propriétés :

doctype, documentElement, implementation
attributes, childNodes, firstChild, lastChild, localName, namespaceURI, nextSibling, nodeName, nodeType, nodeValue, ownerDocument, parentNode, prefix, previousSibling

Méthodes :

createAttribute, createAttributeNS, createCDATASection, createComment, createDocumentFragment, createElement, createElementNS, createEntityReference, createProcessingInstruction, createTextNode, getElementById, getElementsByTagName, getElementsByTagNameNS, importNode
appendChild, cloneNode, hasAttributes, hasChildNodes, insertBefore, isSupported, normalize, removeChild, replaceChild

Element

Représente un nœud d'élément dans un document XML.

Propriétés :

tagName
attributes, childNodes, firstChild, lastChild, localName, namespaceURI, nextSibling, nodeName, nodeType, nodeValue, ownerDocument, parentNode, prefix, previousSibling

Méthodes :

getAttribute, getAttributeNS, getAttributeNode, getAttributeNodeNS, getElementsByTagName, getElementsByTagNameNS, hasAttribute, hasAttributeNS, removeAttribute, removeAttributeNS, removeAttributeNode, setAttribute, setAttributeNS, setAttributeNode, setAttributeNodeNS
appendChild, cloneNode, hasAttributes, hasChildNodes, insertBefore, isSupported, normalize, removeChild, replaceChild

Modifications de l'arbre

Un nœud créé fait partie du document mais n'est pas attaché à l'arbre.

Les ajouts se font donc en 2 étapes :

- création
- ajout

```
Document#createXXX()
Node#insertBefore(newChild, refChild)
Node#appendChild(newChild)
Node#replaceChild(newChild, refChild)
Node#removeChild(oldChild)
```

```
[1] Element newChild = doc.createElement("Date-naissance");
[2] newChild.appendChild(doc.createTextNode("10-06-1969"));
[3] node.appendChild(newChild);
```

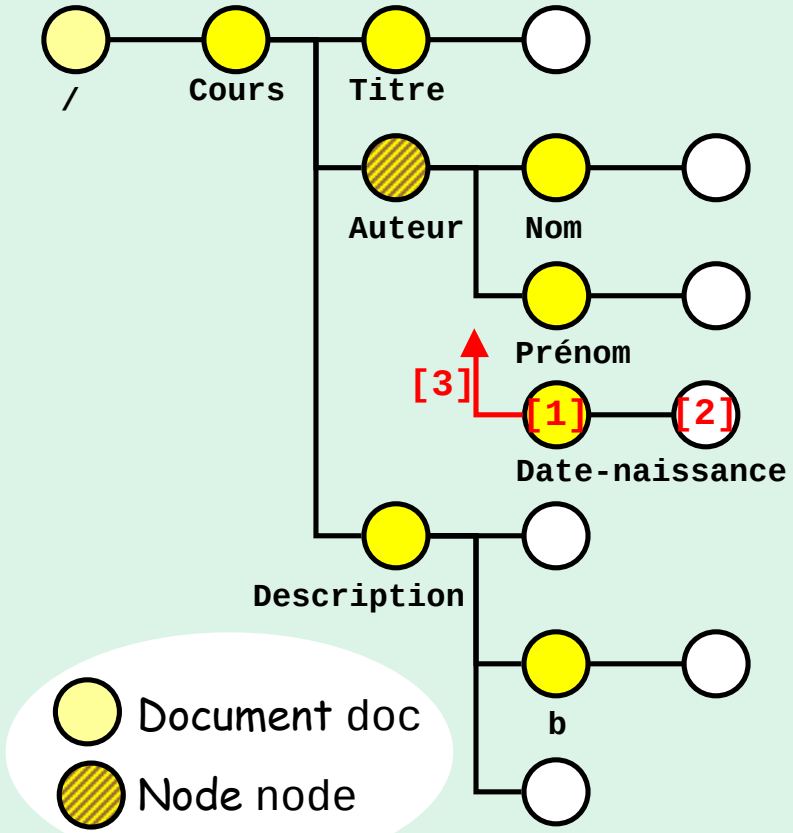

Les objets sont réactifs aux modifications de l'arbre qui peuvent avoir des effets de bord inattendus.

```
for (Node child = node.getFirstChild();
          child != null;
          child = child.getNextSibling()) {
    node.removeChild(child);
}
```

Après suppression du premier nœud de node, `child.getNextSibling()` retourne `null`, et les autres nœuds de node ne seront pas supprimés.

Pour supprimer tous les fils d'un nœud :

```
while (node.hasChildNodes()) {
        node.removeChild(node.getFirstChild());
}
```

DocumentType

Représente la déclaration de type de document indiqué par la balise `<!DOCTYPE>`

Propriétés :

`entities, internalSubset, name, notations, publicId, systemId`
`attributes, childNodes, firstChild, lastChild, localName, namespaceURI, nextSibling, nodeName, nodeType, nodeValue, ownerDocument, parentNode, prefix, previousSibling`

Méthodes :

`appendChild, cloneNode, hasAttributes, hasChildNodes, insertBefore, isSupported, normalize, removeChild, replaceChild`

DocumentFragment

Représente une partie de l'arborescence d'un document. Ce fragment pouvant ne pas être bien formé, est utilisé généralement pour des opérations d'insertion.

Propriétés :

```
attributes, childNodes, firstChild, lastChild, localName, namespaceURI,
nextSibling, nodeName, nodeType, nodeValue, ownerDocument, parentNode, prefix,
previousSibling
```

Méthodes :

```
appendChild, cloneNode, hasAttributes, hasChildNodes, insertBefore, isSupported,
normalize, removeChild, replaceChild
```

C'est un "espace de travail" pratique…

Attr

Représente un attribut d'un objet Element.

Propriétés :

`name, ownerElement, specified, value`
`attributes, childNodes, firstChild, lastChild, localName, namespaceURI, nextSibling, nodeName, nodeType, nodeValue, ownerDocument, parentNode, prefix, previousSibling`

Méthodes :

`appendChild, cloneNode, hasAttributes, hasChildNodes, insertBefore, isSupported, normalize, removeChild, replaceChild`

Les attributs sont des `Node`s, mais pas connectés à l'arbre par une dépendance hiérarchique.

Pour un `Node` élément, `Node#childNodes` ne retourne pas d'attributs, il faut utiliser `Node#attributes`

Attributs dans le DOM

Document
Elément
Texte
Attribut
Nœud contextuel

```
<?xml version="1.0" encoding="ISO-8859-1" ?>
<animaux>
    <chiens>
        <chien race="Labrador">Mabrouk
            <couleur>noir</couleur>
        </chien>
        <chien race="Labrador">Médor
            <couleur>marron</couleur>
        </chien>
    </chiens>
    <chats>
        <chat race="Siamois">Félix
            <couleur>crème</couleur>
        </chat>
        <chat race="Birman">Tom
            <couleur>crème</couleur>
        </chat>
        <chat race="Abyssin">Rominet
            <couleur>gris</couleur>
        </chat>
    </chats>
</animaux>
```

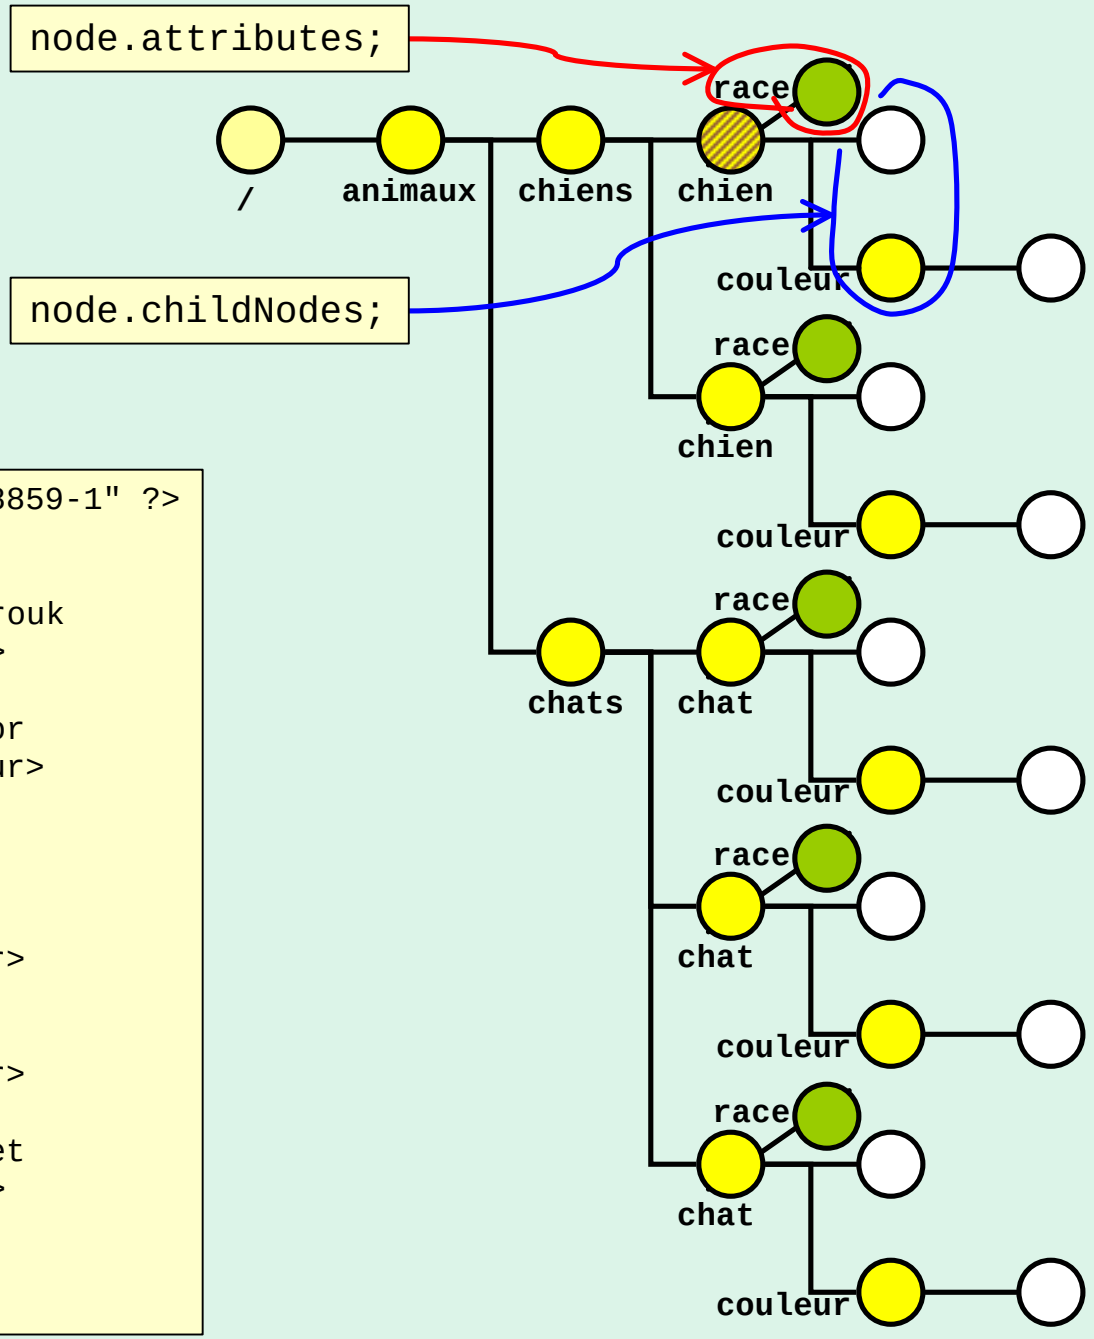

Attributs dans le DOM

```
NamedNodeMap Element#attributes
      String Element#getAttribute(String name)
        void Element#setAttribute(String name, String value)
        void Element#removeAttribute(String name)
        Attr Element#getAttributeNode(String name)
        void Element#setAttributeNode(Attr attr)
        void Element#removeAttributeNode(Attr attr)
```

```
NamedNodeMap map = elem.getAttributes();
for (int i = 0; i < map.getLength(); i++) {
    Attr attr = (Attr) map.item(i);
    // do something
}
```

Si l'attribut n'existe pas :

```
String value = elem.getAttribute("style");
```

Retourne ""

```
Attr attr = elem.getAttributeNode("style");
```

Retourne null

CDATASection

Représente une section de données textuelles (Character Data Section).

Propriétés :

```
data, length, attributes, childNodes, firstChild, lastChild, localName,
namespaceURI, nextSibling, nodeName, nodeType, nodeValue, ownerDocument,
parentNode, prefix, previousSibling
```

Méthodes :

```
appendData, deleteData, insertData, replaceData, substringData, appendChild,
cloneNode, hasAttributes, hasChildNodes, insertBefore, isSupported, normalize,
removeChild, replaceChild, splitText
```

CharacterData

Est une extension de l'interface Node qui permet d'accéder aux données textuelles dans le modèle d'objet.

Propriétés :

data, length
attributes, childNodes, firstChild, lastChild, localName, namespaceURI, nextSibling, nodeName, nodeType, nodeValue, ownerDocument, parentNode, prefix, previousSibling

Méthodes :

appendData, deleteData, insertData, replaceData, substringData
appendChild, cloneNode, hasAttributes, hasChildNodes, insertBefore, isSupported, normalize, removeChild, replaceChild

Comment

Représente un commentaire dans un document XML ou HTML

```
<!-- Commentaire -->
```

Propriétés :

`data, length, attributes, childNodes, firstChild, lastChild, localName, namespaceURI, nextSibling, nodeName, nodeType, nodeValue, ownerDocument, parentNode, prefix, previousSibling`

Méthodes :

`appendData, deleteData, insertData, replaceData, substringData, appendChild, cloneNode, hasAttributes, hasChildNodes, insertBefore, isSupported, normalize, removeChild, replaceChild`

DOMImplementation

Fournit des méthodes qui sont indépendantes de n'importe quelles instances particulières du Modèle d'Objet du Document

Propriétés :

Aucune

Méthodes :

`createDocument, createDocumentType, hasFeature`

Entity

Représente une entité analysée ou non-analysée dans un document XML.

```
<!ENTITY entité SYSTEM "blah-blah">
```

Propriétés :

notationName, publicId, systemId
attributes, childNodes, firstChild, lastChild, localName, namespaceURI, nextSibling, nodeName, nodeType, nodeValue, ownerDocument, parentNode, prefix, previousSibling

Méthodes :

appendChild, cloneNode, hasAttributes, hasChildNodes, insertBefore, isSupported, normalize, removeChild, replaceChild

EntityReference

Contient le nom de l'entité `&entité;`

Propriétés :

attributes, childNodes, firstChild, lastChild, localName, namespaceURI, nextSibling, nodeName, nodeType, nodeValue, ownerDocument, parentNode, prefix, previousSibling

Méthodes :

appendChild, cloneNode, hasAttributes, hasChildNodes, insertBefore, isSupported, normalize, removeChild, replaceChild

Entités dans le DOM


```
<?xml version="1.0" encoding="ISO-8859-1"?>
<!DOCTYPE Cours [
  <!ENTITY auteur
    "<Auteur>
        <Nom>Poulard</Nom>
        <Prénom>Philippe</Prénom>
    </Auteur>">
]>
<Cours>
    <Titre>Cours XML</Titre>
    &auteur;
    <Description>
    Ce cours aborde les <b>concepts</b>
    de base mis en &#339;uvre dans XML.
    </Description>
</Cours>
```

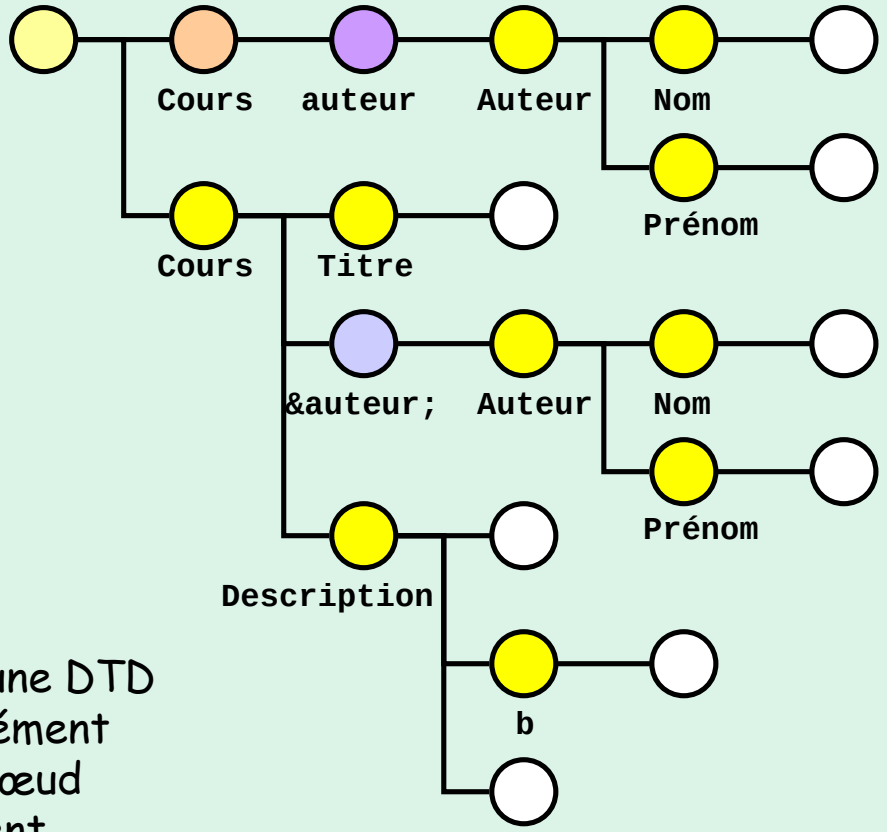

Ce document pourrait être conforme à une DTD dans laquelle l'élément `Auteur` suivrait l'élément `Titre`. Pourtant, dans le DOM, le premier nœud suivant (de type `ELEMENT_NODE`) de l'élément `Titre` n'est pas l'élément `Auteur`.

Certains parseurs proposent des options pour intégrer directement les contenus d'entités sans les références

DOM level 2

Les vues (views) permettent d'obtenir une représentation du document sans les références d'entités.

Le premier objet d'un document n'est pas nécessairement un élément

- Document
- Elément
- Texte
- DocumentType
- EntityReference
- Entity

NamedNodeMap

Représente des collections de nœuds qui peuvent être accédées par un nom.

Propriétés :

`length`

Méthodes :

`getNamedItem, getNamedItemNS, item, removeNamedItem, removeNamedItemNS, setNamedItem, setNamedItemNS`

Notation

Représente une notation `<!NOTATION notation>` déclarée dans la DTD.

Propriétés :

`publicId, systemId`
`attributes, childNodes, firstChild, lastChild, localName, namespaceURI, nextSibling, nodeName, nodeType, nodeValue, ownerDocument, parentNode, prefix, previousSibling`

Méthodes :

`appendChild, cloneNode, hasAttributes, hasChildNodes, insertBefore, isSupported, normalize, removeChild, replaceChild`

ProcessingInstruction

Représente une instruction de traitement

```
<?Nom_Instruction Cible?>
```

Propriétés :

data, target
attributes, childNodes, firstChild, lastChild, localName, namespaceURI, nextSibling, nodeName, nodeType, nodeValue, ownerDocument, parentNode, prefix, previousSibling

Méthodes :

appendChild, cloneNode, hasAttributes, hasChildNodes, insertBefore, isSupported, normalize, removeChild, replaceChild

Text

Représente le contenu textuel d'un attribut ou d'un élément.

Propriétés :

data, length, attributes, childNodes, firstChild, lastChild, localName, namespaceURI, nextSibling, nodeName, nodeType, nodeValue, ownerDocument, parentNode, prefix, previousSibling

Méthodes :

splitText
appendData, deleteData, insertData, replaceData, substringData, appendChild, cloneNode, hasAttributes, hasChildNodes, insertBefore, isSupported, normalize, removeChild, replaceChild

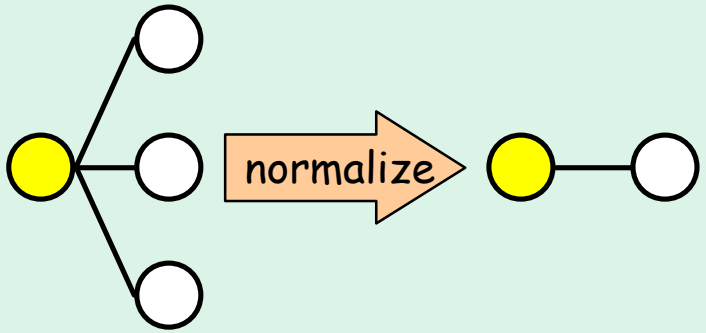


```
Text.splitText(offset);
```

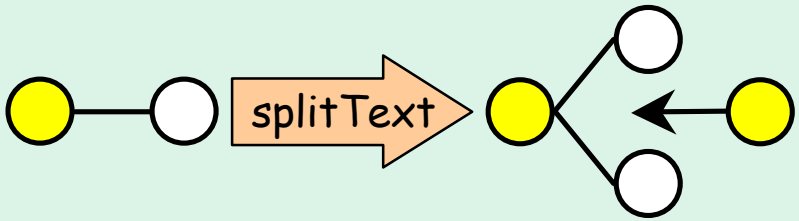

Possibilité d'inclusion d'un élément au milieu du texte

```
try {
          …
          root.appendChild(document.createTextNode("Un peu"));
          root.appendChild(document.createTextNode(" "));
          root.appendChild(document.createTextNode("de texte"));
          document.getDocumentElement().normalize();
} catch (ParserConfigurationException pce) {
          …
```

Héritage des objets DOM

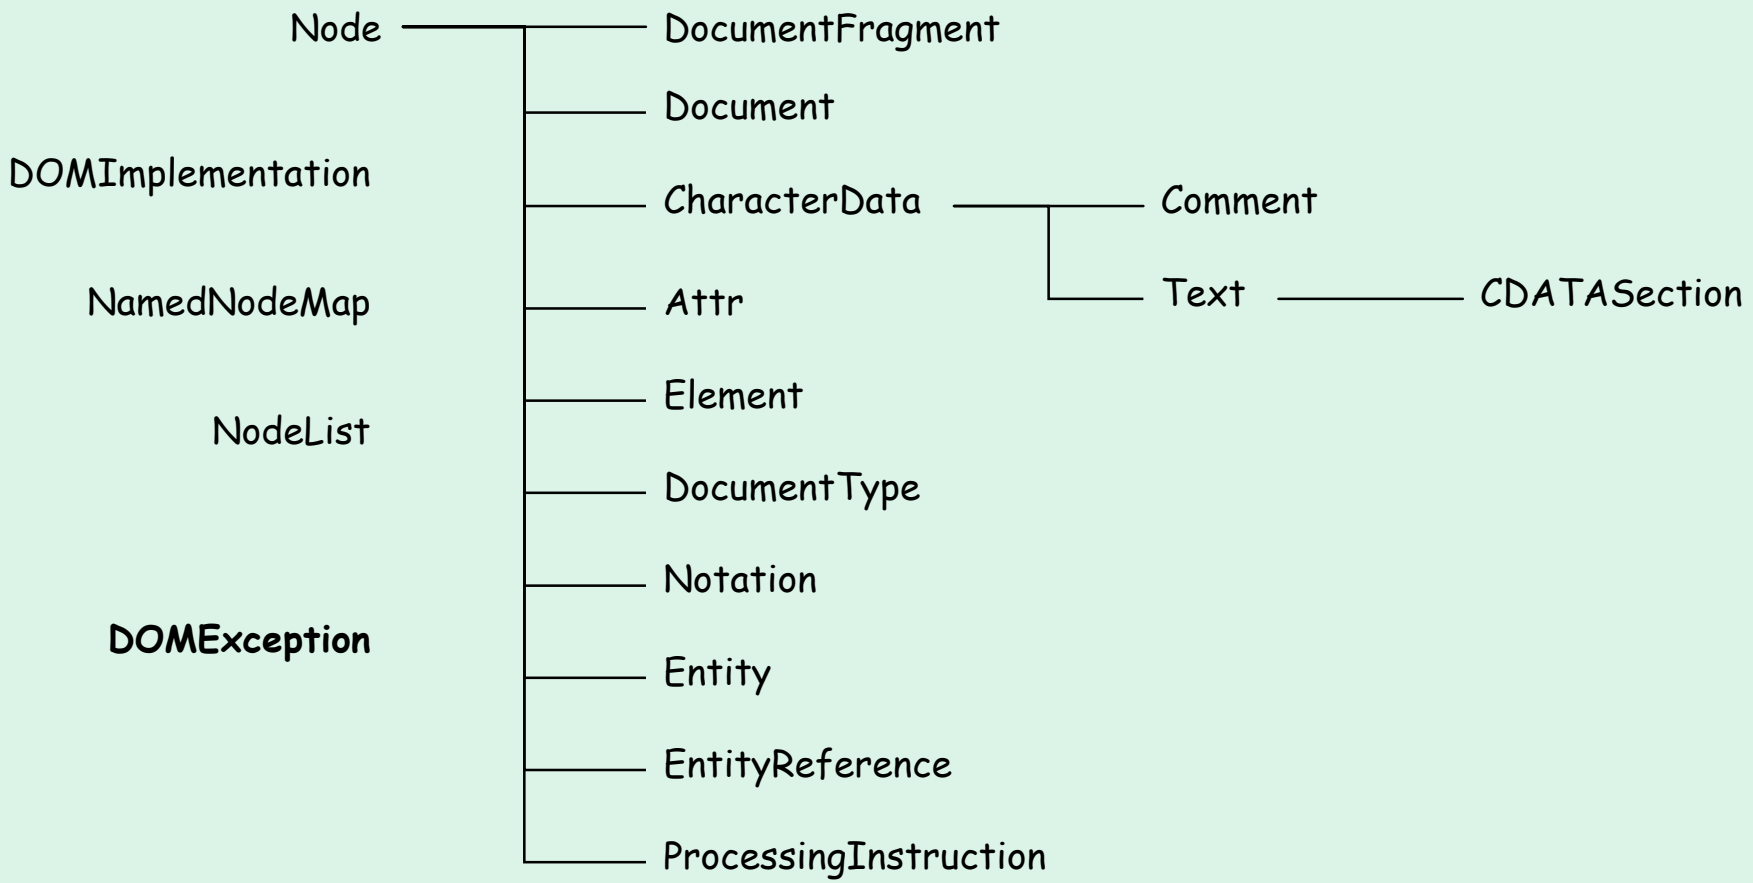

Pour obtenir les nœuds textuels, il faut penser à prendre en compte les sections CDATA

```
If (node.getNodeType()==Node.TEXT_NODE ||
    node.getNodeType()==Node.CDATA_SECTION_NODE) {
        // traitement des nœuds texte
}
```

Hiérarchie des nœud du DOM

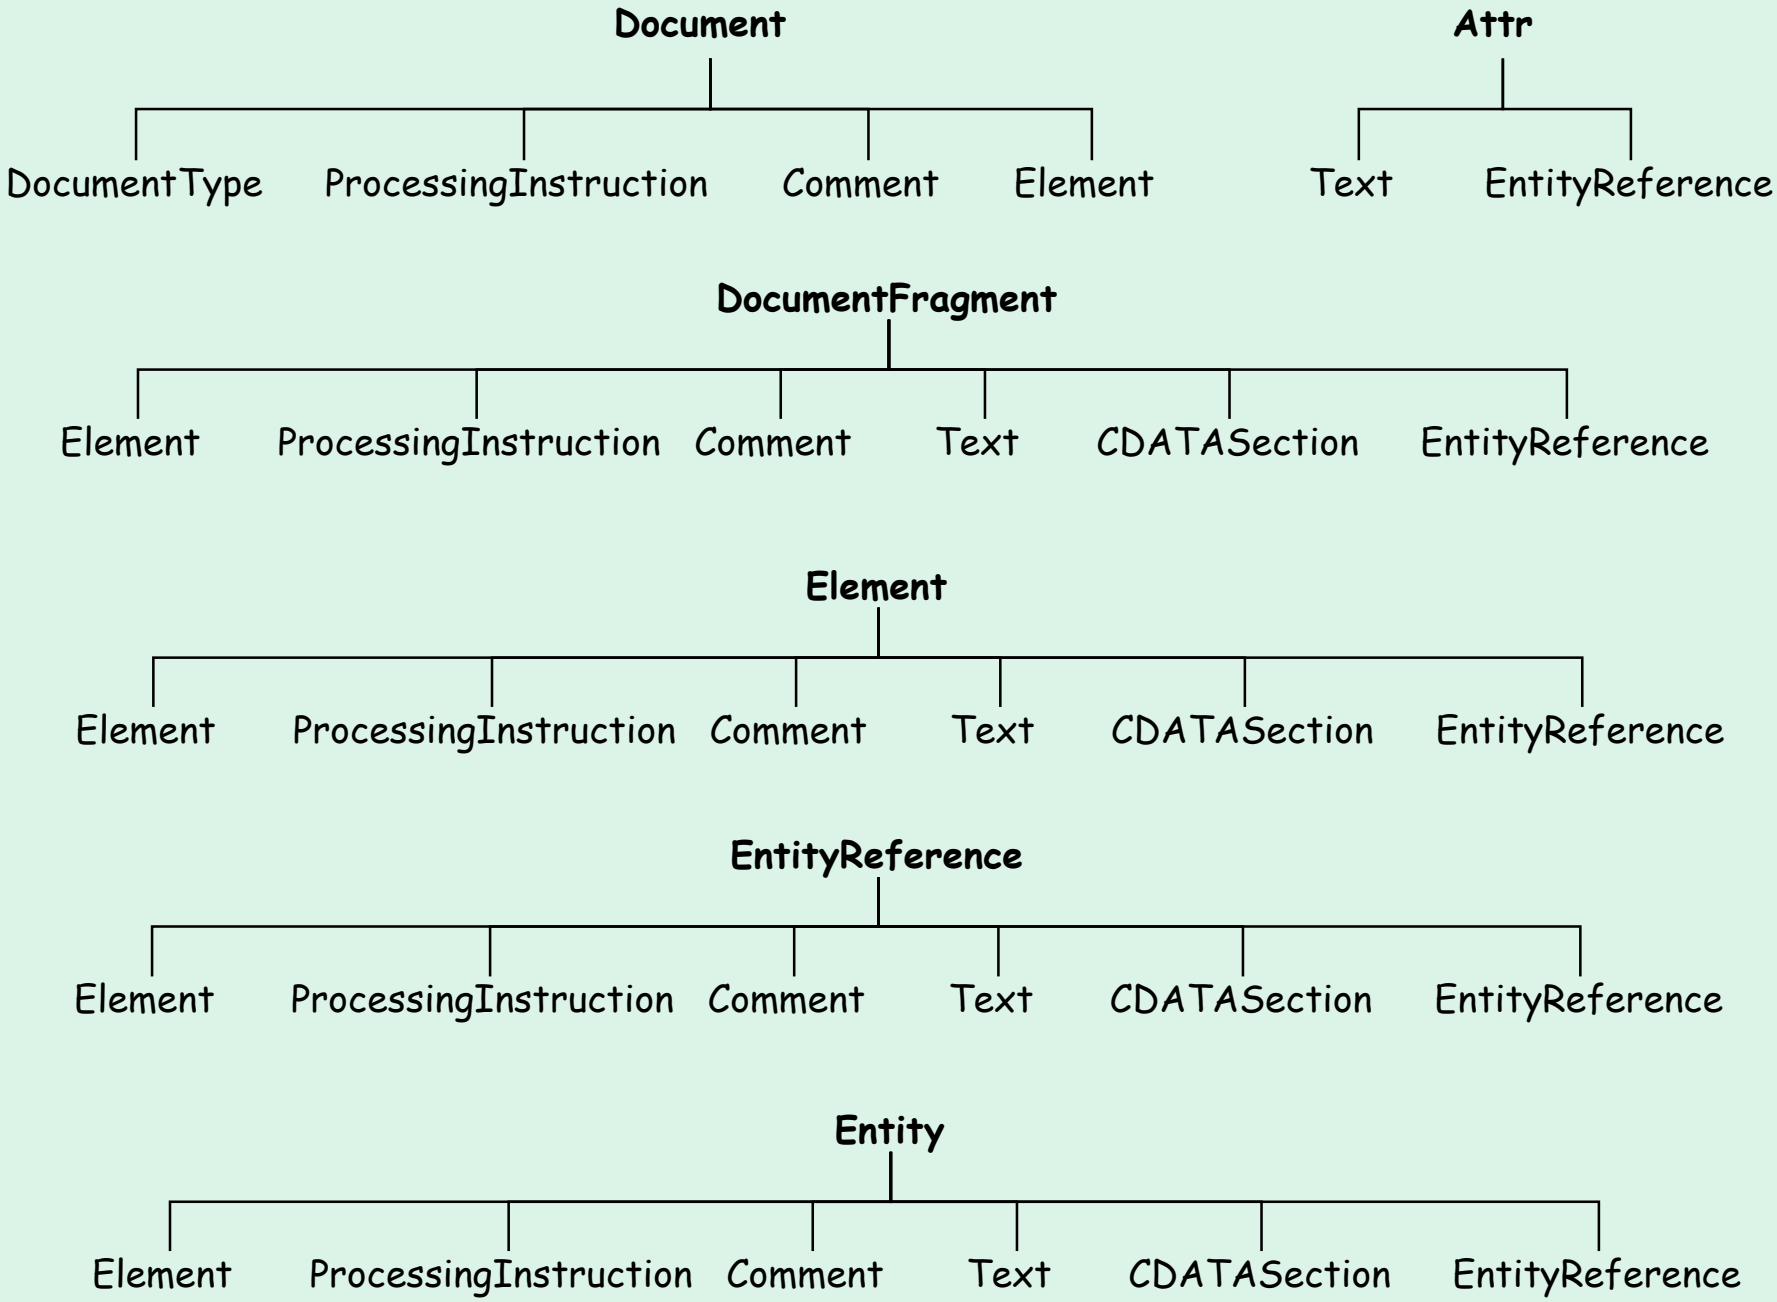

Clonage de nœuds dans le DOM

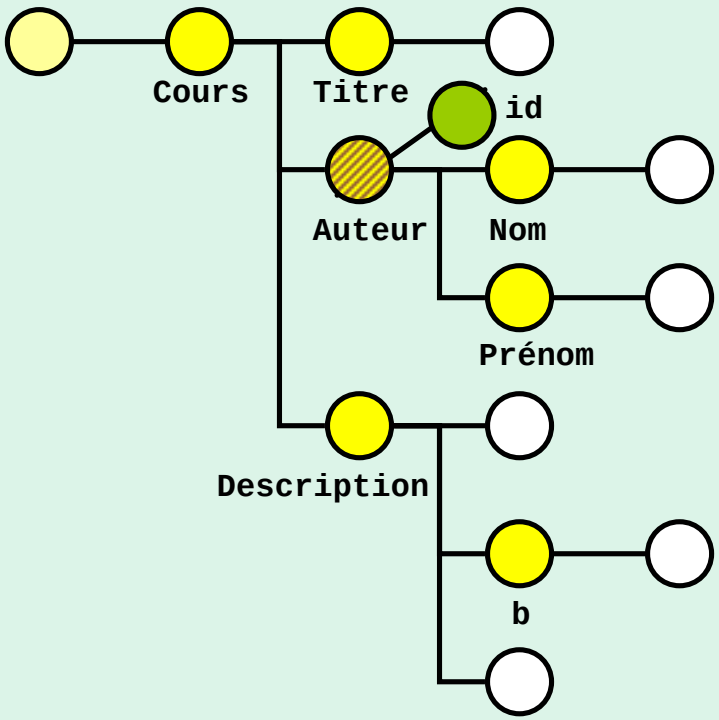

Elément elem

Elément newElement

Clonage en surface

```
Element newElement = elem.cloneNode(false);
```

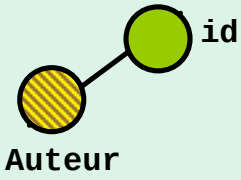

Clonage en profondeur

```
Element newElement = elem.cloneNode(true);
```

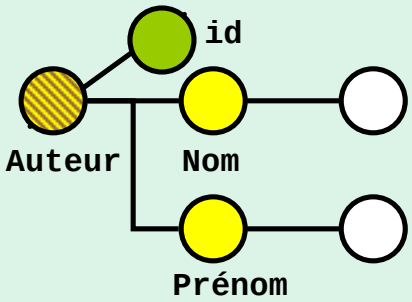

Echange de nœuds entre documents

Document	Document#ownerDocument
Node	Document#importNode()

Les nœuds, même non attachés à l'arbre, appartiennent au document.

```
DOMParser parser = new DOMParser();
parser.parse(…/…);
Document doc1 = parser.getDocument();
parser.parse(…/…);
Document doc2 = parser.getDocument();
…/…
Element el1 = doc1.getDocumentElement();
Element el2 = doc2.getDocumentElement();
el1.appendChild(el2);
```

Non — Provoque une exception DOMException

```
DOMParser parser = new DOMParser();
parser.parse(…/…);
Document doc1 = parser.getDocument();
parser.parse(…/…);
Document doc2 = parser.getDocument();
…/…
Element el1 = doc1.getDocumentElement();
Element el2 = doc2.getDocumentElement();
Node node = doc1.importNode(el2, true);
el1.appendChild(node);
```

Oui — Importation correcte d'un nœud

Espaces de nommage dans le DOM

DOM level 2

Propriétés des `Element` et `Attr` : `namespaceURI`
`localName`
`prefix`

Vérifier que votre parser prend en compte les espaces de nommage.
Le cas échéant, activer la fonctionnalité.

DOM ne réalise aucune déclaration d'espace de nommage automatiquement.

```
Element elem = doc.createElementNS(
        "http://www.foo.com",
        "foo:bar");
```

← URI de l'espace de nom
← Nom qualifié de l'élément

Crée un élément `bar` dont l'URI de l'espace de nom est `http://www.foo.com` et dont le préfixe est `foo`.
La déclaration de l'espace de nommage `xmlns:foo="http://www.foo.com"` n'est pas créée automatiquement.

Habituellement, on n'associe pas d'espaces de nommage aux attributs, puisqu'ils dépendent de leur élément parent. Lorsque ce n'est pas le cas, on peut les déclarer ainsi :

```
elem.setAttributeNS(
        "http://www.w3.org/1999/xlink",
        "xlink:type",
        "simple");
elem.setAttributeNS(
        "http://www.w3.org/1999/xlink",
        "xlink:href",
        "myDocument.html");
```

← URI de l'espace de nom
← Attribut
← Valeur
← URI de l'espace de nom
← Attribut
← Valeur

Déclaration des espaces de nommage


```
elem.setAttributeNS(
        "http://www.w3.org/2000/xmlns/",
        "xmlns:foo",
        "http://www.foo.com");
```

← URI de l'espace de nom xmlns
← Attribut
← Valeur

```
elem.setAttributeNS(
        "http://www.w3.org/2000/xmlns/",
        "xmlns:xlink",
        "http://www.w3.org/1999/xlink");
```

← URI de l'espace de nom xmlns
← Attribut
← Valeur

D'une manière générale :

```
ancestorElem.setAttributeNS(
        "http://www.w3.org/2000/xmlns/",
        "xmlns:" + elem.getPrefix(),
        elem.getNamespaceURI());
```

← URI de l'espace de nom xmlns
← Attribut
← Valeur

Les déclarations doivent se faire sur l'élément ou l'un de ses ancêtres.

Les déclarations d'espace de nommage (ou l'absence de déclaration) peuvent rendre le DOM inconsistant. Il appartient au programmeur de réaliser les déclarations idoines.

```
Element elem = doc.createElementNS(
          "http://www.foo.com","foo:bar");
elem.setAttributeNS(
          "http://www.w3.org/2000/xmlns/","xmlns:foo","http://www.blah.com");
```

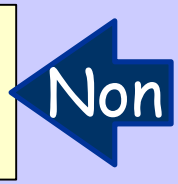

Espaces de nommage dans le DOM level 3

Le DOM level 3 permet de lire et écrire des documents XML

La méthode write s'assure de l'intégrité des déclarations d'espace de nommage avec le contenu

Spécialisation des APIs DOM

DOM Core
+
spécialisation par domaine

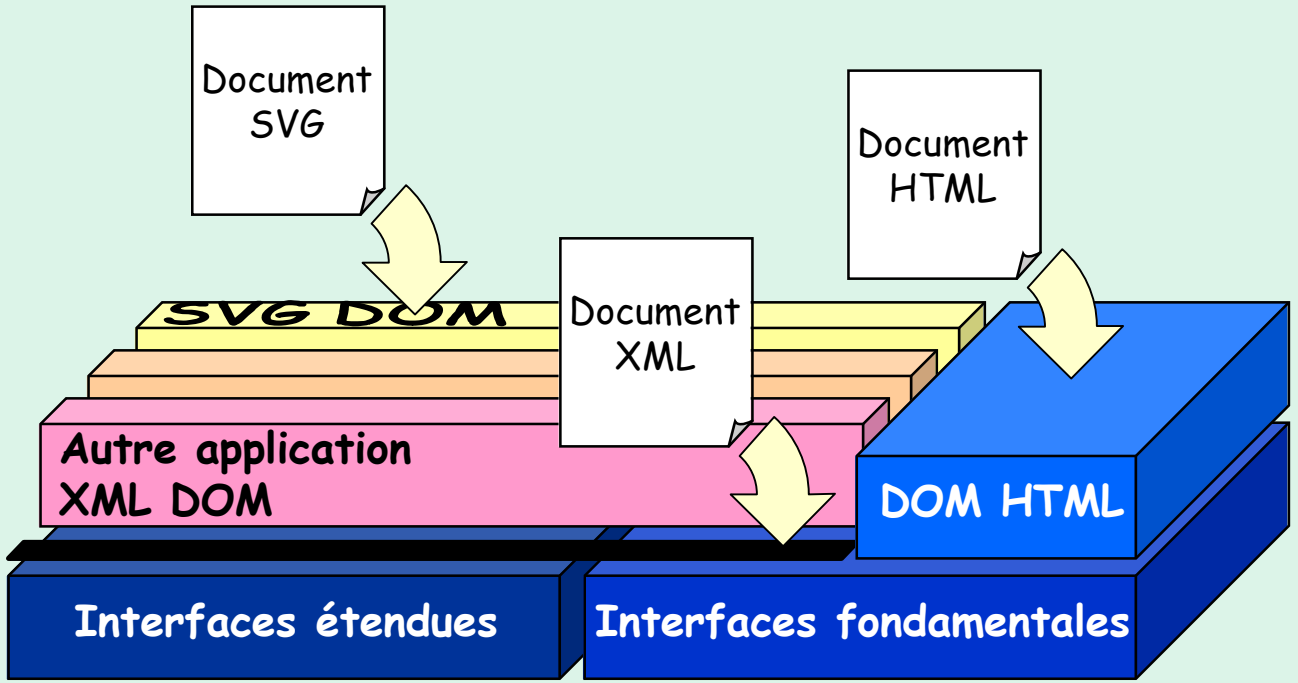

Exemple : SVG DOM

SVG DOM →
DOM Core →

```
Point.setX(12);
Element.setAttribute("x", "12");
```

Let's talk about sax

Simple API for XML

API simple pour XML :
une API pour **réagir** sur
le contenu et la structure d'un document

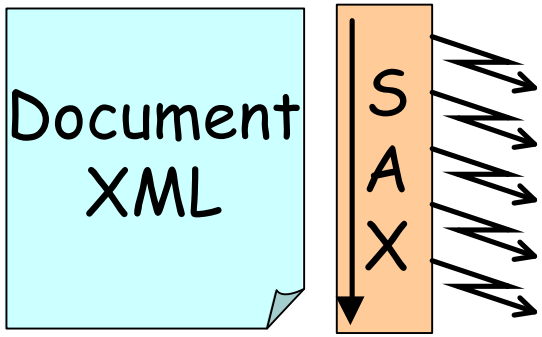

SAX, standard issu de xmldev mailing list
implémenté par David Megginson

Le document est vu comme une suite
d'événements qui surviennent lors de la
lecture séquentielle du document

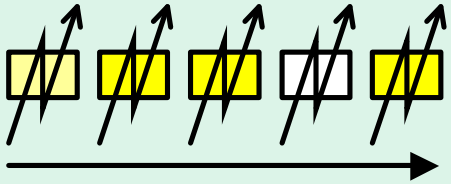

Support des espaces de nommage, support des filtres SAX, nouvelles interfaces, changement du nom de certaines classes et interfaces, mécanisme générique pour lire ou modifier les propriétés et fonctionnalités du parser

Fonctionnement de SAX

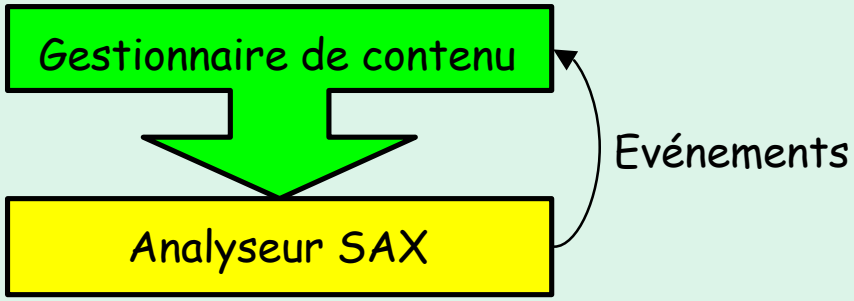

A chaque événement, un callback est appelé dans l'ordre d'apparition dans le document

- Début de document
- Début d'élément
- Caractères

...

- Fin de document

Le gestionnaire de contenu est une classe qui effectue les traitements appropriés à chaque appel d'un callback

Cette classe doit être enregistrée auprès de l'analyseur SAX

Principe de SAX


```
<?xml version="1.0" encoding="ISO-8859-1"?>
<Cours>
          <Titre>Cours XML</Titre>
          <Auteur>
                    <Nom>Poulard</Nom>
                    <Prénom>Philippe</Prénom>
          </Auteur>
          <Description>
          Ce cours aborde les <b>concepts</b> de
          base mis en &#339;uvre dans XML.
          </Description>
</Cours>
```

```
startDocument
startElement: Cours
startElement: Titre
characters: "Cours XML"
endElement: Titre
startElement: Auteur
startElement: Nom
characters: "Poulard"
endElement: Nom
startElement: Prénom
characters: "Philippe"
endElement: Prénom
endElement: Auteur
startElement: Description
characters: "Ce cours aborde les "
startElement: b
characters: "concepts"
endElement: b
characters: " de base mis en œuvre dans XML."
endElement: Description
endElement: Cours
endDocument
```

Principaux handlers

Les applications doivent enregistrer le handler d'événements auprès d'une instance d'un parser qui implémente l'interface `XMLReader`.

En Java :

Interfaces

Parser : `org.xml.sax.XMLReader`

Handlers : `org.xml.sax.ContentHandler`
`org.xml.sax.DTDHandler`
`org.xml.sax.EntityResolver`
`org.xml.sax.ErrorHandler`

Implémentation par défaut (qui ne fait rien) :
`org.xml.sax.helpers.DefaultHandler`

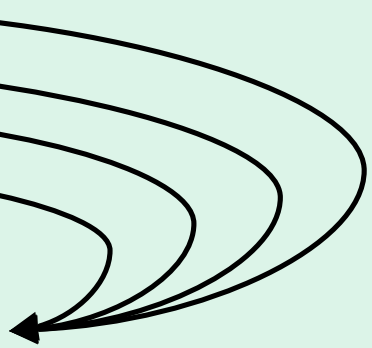

Avec MSXML2.4.0 :

Interfaces

Parser : `ISAXXMLReader`

Handlers : `ISAXContentHandler`
`ISAXDTDHandler`
`ISAXEntityResolver`
`ISAXErrorHandler`

L'interface ContentHandler

`startDocument()` Notification du début du document

`endDocument()` Notification de la fin du document

`startElement(String namespaceURI, String localName, String qName, Attributes atts)` Notification du début d'un élément

`endElement(String namespaceURI, String localName, String qName)`
Notification de la fin d'un élément

`characters(char[] ch, int start, int length)`
Notification de données caractères

`ignorableWhitespace(char[] ch, int start, int length)`
Notification d'espaces blancs ignorables dans le contenu d'un élément

`startPrefixMapping(String prefix, String uri)`
Notification du début de la portée d'un espace de nommage

`endPrefixMapping(String prefix)`
Notification de la fin de la portée d'un espace de nommage

`processingInstruction(String target, String data)`
Notification d'une instruction de traitement

`skippedEntity(String name)`
Notification d'une entité non résolue

`setDocumentLocator(Locator locator)`
Permet d'enregistrer un `Locator` qui délivre des informations sur la localisation d'un événement SAX (numéro de ligne, colonne…)

Enregistrement d'un handler


```
String fileName = "…";
ContentHandler myContentHandler = new …;
…/…
XMLReader parser = XMLReaderFactory.createXMLReader();
parser.setContentHandler(myContentHandler);
parser.parse(fileName);
```

```
String fileName = "…";
ContentHandler myContentHandler = new …;
DTDHandler myDTDHandler = new …;
ErrorHandler myErrorHandler = new …;
EntityResolver myEntityResolver = new …;
…/…
XMLReader parser = XMLReaderFactory.createXMLReader();
parser.setContentHandler(myContentHandler);
parser.setDTDHandler(myDTDHandler);
parser.setErrorHandler(myErrorHandler);
parser.setEntityResolver(myEntityResolver);
parser.parse(fileName);
```

```
String fileName = "…";
DefaultHandler handler = new …;
…/…
XMLReader parser = XMLReaderFactory.createXMLReader();
parser.setContentHandler(handler);
parser.setDTDHandler(handler);
parser.setErrorHandler(handler);
parser.setEntityResolver(handler);
parser.parse(fileName);
```

Liste des éléments rencontrés :

```
import java.io.File;
import java.io.IOException;
import org.xml.sax.XMLReader;
import org.xml.sax.SAXException;
import org.xml.sax.Attributes;
import org.xml.sax.helpers.DefaultHandler;
import org.xml.sax.helpers.XMLReaderFactory;

public class MySAXParser extends DefaultHandler {
  public MySAXParser() {}
  static public void main(String[] args) {
    try {
      DefaultHandler handler = new MySAXParser();
      XMLReader parser = XMLReaderFactory.createXMLReader();
      parser.setContentHandler(handler);
      parser.parse(args[0]);
    } catch (SAXException e) {e.printStackTrace();
    } catch (IOException e) {e.printStackTrace();
    }
  }
  public void startElement(String uri, String localName, String qName, Attributes atts) {
    System.out.println("Elément rencontré : " + qName);
  }
}
```

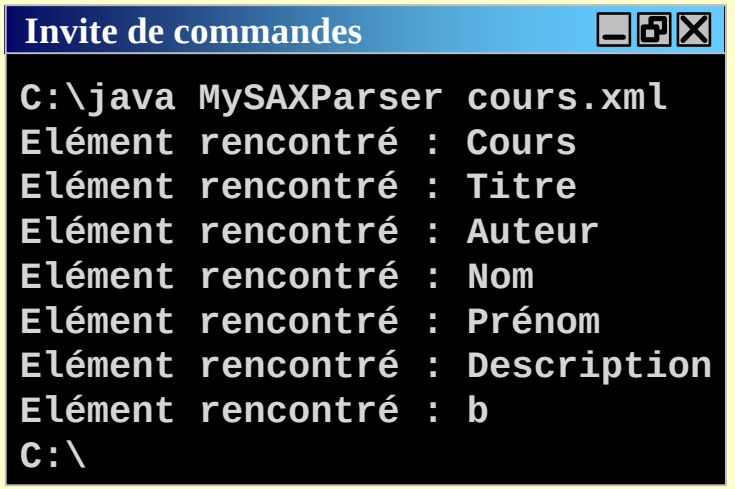

Evénements characters()

La spécification SAX permet aux parsers de décomposer un segment de texte en plusieurs événements caractères de l'interface `ContentHandler`

```
<foo>
    Les APIs
    DOM &#x26; SAX
</foo>
```

startDocument
startElement : foo
characters : "\n   Les APIs\n   DOM & SAX\n"
endElement : foo
endDocument

Parser SAX de Xerces

startDocument
startElement : foo
characters : "\n   Les APIs\n   DOM "
characters : "&"
characters : " SAX\n"
endElement : foo
endDocument

Parser SAX de Crimson

startDocument
startElement : foo
characters : ""
characters : "\n"
characters : "   Les APIs"
characters : "\n"
characters : "   DOM "
characters : "&"
characters : " SAX"
characters : "\n"
endElement : foo
endDocument

⇒ Les programmes qui traitent les caractères doivent utiliser des tampons (buffers)

Filtres SAX

Un filtre SAX reçoit des événements SAX d'un parser SAX, peut les modifier, et les fait suivre à un handler

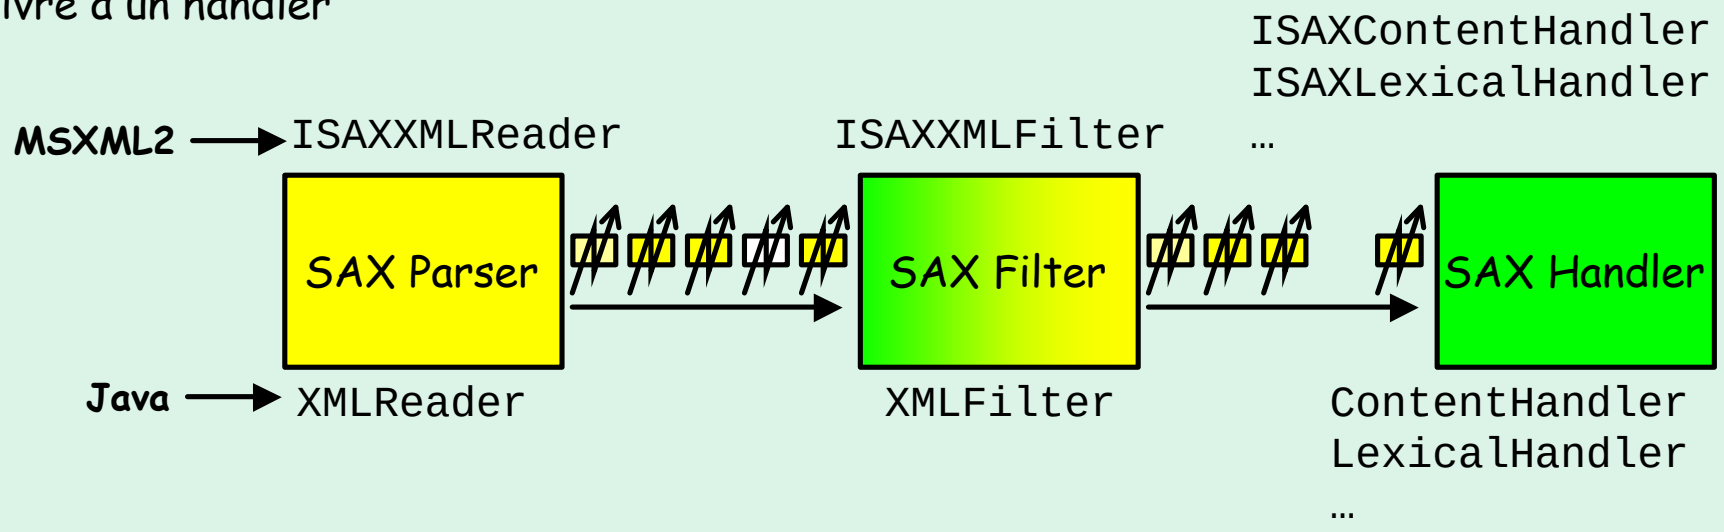

Le filtre SAX est vu par le parser SAX comme un handler SAX

Le filtre SAX est vu par le handler SAX comme un parser SAX

`XMLFilter` est dérivé de `XMLReader`

Pipeline SAX

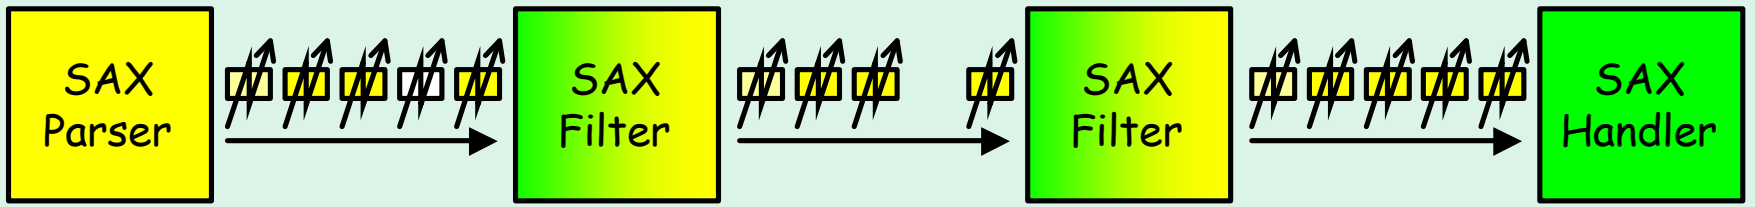

Utilité des filtres SAX

Permet à un handler d'accepter différentes variantes de structures

```
<livre>
    <titre>Les misérables</titre>
    …/…
</livre>
```

```
<livre titre="Les misérables">
    …/…
</livre>
```

startElement : livre
startElement : titre
characters : "Les misérables"
endElement : titre
…
endElement : livre

startElement : livre
…
endElement : livre

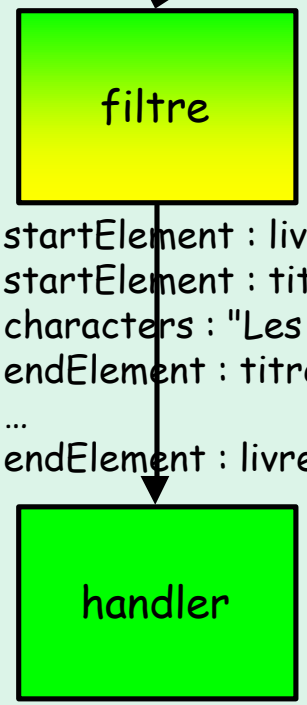

startElement : livre
startElement : titre
characters : "Les misérables"
endElement : titre
…
endElement : livre

à la réception de l'élément `livre`, le filtre vérifie s'il existe l'attribut `titre`.
Si c'est le cas, le filtre génère les événements :

startElement : titre
characters : "Les misérables"
endElement : titre

Utilisation des filtres SAX

```
XMLReader parser = XMLReaderFactory.createXMLReader();
XMLFilter filter = new MyFilter();
filter.setParent(parser);
filter.setContentHandler(handler);
filter.parse(…/…);
```

ou

```
XMLReader parser = XMLReaderFactory.createXMLReader();
XMLFilter filter = new MyFilter(parser);
filter.setContentHandler(handler);
filter.parse(…/…);
```

Pipeline SAX

```
XMLReader parser = XMLReaderFactory.createXMLReader();
XMLFilter myFilter = new MyFilter();
XMLFilter yourFilter = new YourFilter();
myFilter.setParent(parser);
yourFilter.setParent(myFilter);
yourFilter.setContentHandler(handler);
yourFilter.parse(…/…);
```

ou

```
XMLReader parser = XMLReaderFactory.createXMLReader();
XMLFilter yourFilter = new YourFilter(new MyFilter(parser));
yourFilter.setContentHandler(handler);
yourFilter.parse(…/…);
```

Analyseurs SAX validants

Un analyseur validant qui ne valide pas
n'est pas
un analyseur non validant

→ Traitement des espaces blancs

Certains analyseurs disposent de 2 implémentations :

- analyseur validant → `ignorableWhitespace()`
- analyseur non validant → `ignorableWhitespace()` ou `characters()`

```
<!ELEMENT dauphin (nom, sexe)>
```

```
<dauphin> ↵
    <nom>Flipper</nom> ↵
    <sexe>M</sexe> ↵
</dauphin>
```

Espaces blancs ignorables

Truc : éviter d'avoir des espaces blancs significatifs
Si on ne peut pas faire autrement : les inclure dans une section CDATA

Pour les entités non résolues, il existe un callback spécifique :

```
public void skippedEntity(String name) throws SAXException {}
```

Mais les analyseurs non validants peuvent résoudre les appels d'entités

Espaces de nommage dans SAX

La spécification SAX2 définie les 2 fonctionnalités standards suivantes :

Introduits dans SAX2

Fonction	Nom	Valeur par défaut
Namespaces	`http://xml.org/sax/features/namespaces`	`true`
Namespace-prefix	`http://xml.org/sax/features/namespace-prefixes`	`false`

Le parser peut fournir des informations sur les URI d'espace de nommage et les local names via `startElement()` et `endElement()` de `ContentHandler` et `getURI()` et `getLocalName()` de `Attributes`.

Disponibilité des noms qualifiés, selon l'implémentation

`startPrefixMapping()` et `endPrefixMapping()` de `ContentHandler` sont appelés quand les éléments qui déclarent des espaces de nommage sont rencontrés et quittés.

Il n'y a pas de déclaration d'espace de nommage (`xmlns…`) dans les instances d'`Attributes`.

Namespaces	Namespace -prefix					
false	true	X	-	X	-	Par défaut
true	true	X	X	X	X	
false	false	-	-	-	X	
true	false	-	X	-	X	

Comparaison SAX et DOM

DOM	SAX
Un processus qui utilise le DOM ne peut traiter l'arbre qu'après la lecture entière du document	Un analyseur SAX délivre les données à un processus au fur et à mesure de la lecture du document
Accès aléatoire	Accès séquentiel
Utilise beaucoup de mémoire	Utilise peu de mémoire pour son propre fonctionnement, et le strict nécessaire pour le processus traitant
Construction de l'arbre du document Les objets sont réutilisables Richesse des fonctionnalités	Evénementiel Les objets ne sont pas stockés Fonctionnalités rudimentaires
Programmation aisée	Beaucoup de code à produire
Les implémentations de DOM reposent souvent sur un analyseur SAX	

Quand utiliser SAX ou DOM ?

DOM	SAX
Toutes les données doivent être utilisées	Seule une partie des données doivent être utilisées
Les performances peuvent être limitées	Les performances sont critiques
Abondance de mémoire	Peu de mémoire

Les parsers DOM récents ont des temps de réponse à peine plus faibles que ceux de SAX : ils diffèrent la création des objets qui ne sont pas sollicités.

DOM pour Java :
- JDOM
- DOM4J

http://dom4j.org/
http://www.jdom.org/

XML Data Binding

Au lieu d'obtenir un modèle de données XML, on cherche à instancier des classes qui correspondent aux éléments rencontrés

Modèle généraliste

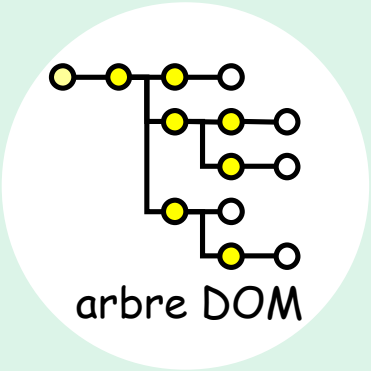

arbre DOM

Modèle spécifique

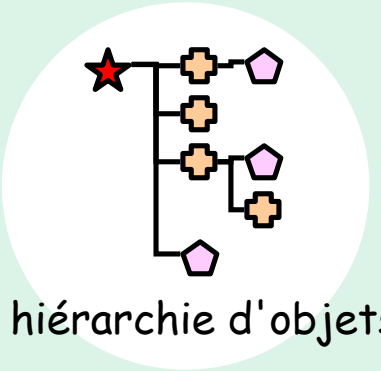

hiérarchie d'objets

Des techniques permettent de réaliser la désérialisation (unmarshal) automatiquement

Avec Java :
- JAXB
- Castor