Introduction à XML et aux DTD

L3Pro BDISE – XML

Mathieu Sassolas

IUT de Sénart Fontainebleau
Département Informatique

Année 2016-2017
Cours 1

UPEC
UNIVERSITÉ PARIS-EST CRÉTEIL
IUT SENART FONTAINEBLEAU

Au menu de ce module

- XHTML et XML.
- DTD (« Doctypes »).
- CSS pour (X)HTML et XML.
- Transformations XSLT (en se servant de XPath).
- Requêtes XQuery.
- Application du XML : le SVG.

Détails pratiques

Ressources

`www.lacl.fr/~msassolas/enseignement/XML_Licence/`

- Cours
- Sujets de TD/TP.
- Parfois également des corrigés.
- Archives de contrôles.
- Sujets de TP notés le moment venu.

À garder dans ses favoris dès le premier TP.

Détails pratiques

« Modalité de contrôle des connaissances »

TP noté n° 1

- Vendredi 2 décembre, 14h.
- Coefficient 2,5.
- Programme : XML de base, DTD, CSS, un peu de XSLT.

TP noté n° 2

- Semaine du 16 janvier.
- Coefficient 2,5.
- Programme : XSLT, XPath, XQuery, SVG.

Susceptible de varier en fonction de l'état d'avancement du cours, des disponibilités de l'emploi du temps...

Plan de la séance

Plan de la séance

La base : les balises

- Tout dans la page est un élément encadré par des balises, qui peuvent avoir des attributs.
- `<balise attribut="valeur">Contenu</balise>`

⇝ `<div id="aveu">J'aime le XHTML!</div>`

- Élément sans contenu : `<balise/>`

⇝ `<img src="coeur.png" alt="J'aime le XHTML!"/>`

Vous connaissez déjà toutes les balises HTML nécessaires à l'édition d'une page.

Ecrire du XHTML *valide*

Règles simples qui diffèrent du HTML

- Les balises sont en minuscule.
- Les attributs sont en minuscule.
- Les guillemets sont obligatoires : `attribut="valeur"`.
- Tous les attributs ont une valeur : `<option selected="selected">`.

Toutes les balises doivent être fermée (même celles sans contenu) :

- ~~`<br>`~~ → `<br/>`
- ~~`<div><p>Bla bla bla</div>`~~ → `<div><p>Bla bla bla</p></div>`

Dans l'entête : « doctype »

```
<!DOCTYPE html PUBLIC
"-//W3C//DTD XHTML 1.0 Strict//EN"
"http://www.w3.org/TR/xhtml1/DTD/xhtml1-strict.dtd">
```

- Est utilisée par les validateurs.
- Il y a en fait plusieurs versions du XHTML :
  - *strict* : conseillée car plus propre, et refuse les archaïsmes ;
  - *transitional* : autorise des archaïsmes (éléments et attributs « deprecated ») ;
  - *frameset* : pour des page en tant qu'ensemble de trames (utilisé dans les années 1990...).

De la validité du XHTML

- Écrivez des pages valides et faites-les valider : `http://validator.w3.org/` (validateur du W3C).
- Dissociez le fond de la forme (CSS, à venir).

Remarque

De nos jour, il est plus probable que vous écriviez du code qui génère de l'HTML plutôt que vous ne l'écriviez directement. Gardez en tête l'objectif de la validité de l'HTML généré.

La version courte

⇝ Vous savez écrire du XHTML...

... donc vous savez écrire du XML

- Le XHTML est un cas particulier du XML.
- Dans XML, tout n'est qu'une imbrication d'éléments marqués par des balises.

La seule différence

Vous pouvez choisir n'importe quelle balise (ou presque)

En revanche...

Contrairement à XHTML, votre navigateur ne sait pas interpréter vos balises « maison ».

En conséquences...

Le menu du cours, réexpliqué

- XHTML ✓
- XML ✓
- DTD (« Doctypes »)
  Comment tout de même brider les balises utilisées.
- CSS pour (X)HTML et XML
  Comment afficher correctement le XML.
- Transformations XSLT (en se servant de XPath)
  Comment transformer du XML en autre chose.
- Requêtes XQuery
  Comment utiliser XML comme base de données.
- Application du XML : le SVG
  Comment utiliser XML pour dessiner.

XML et les arbres

- Comme le XML est une imbrication d'éléments, on peu le voir comme un arbre.

Attention !

Un arbre a une seule racine !
Sinon, cela s'appelle une forêt.

- Il peut permettre de stocker des données de manière structurée.

↪ Souvent le résultat d'une requête sur une base de données sera renvoyée par le serveur sous forme de XML.

- Chaque élément a des attributs.

Exemple


```
<person id="_42">
  <name><first_name>Alan</first_name>
        <last_name>Turing</last_name></name>
  <trade>informaticien</trade>
  <trade>mathématicien</trade>
</person>
```

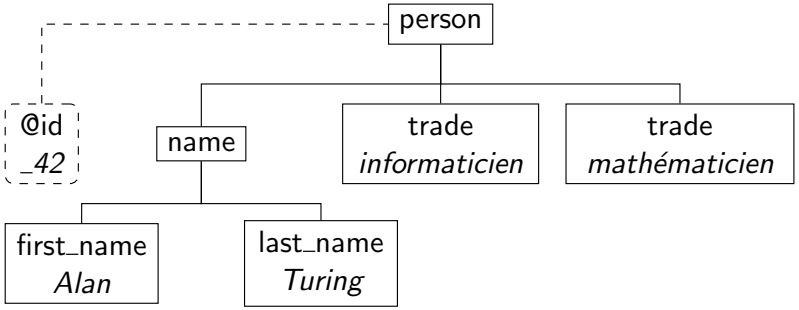

Entités et caractères spéciaux

↪ Comme en HTML, il faut échapper les caractères spéciaux.

<	`<`
>	`>`
"	`&quot;`
'	`&apos;`
&	`&`

Vocabulaire

En XML, ces caractères échappés s'appellent des entités.

Remarques

- Il faut en début de document préciser qu'on parle en XML :
  `<?xml version="1.0" encoding="UTF-8"?>`
- On peut utiliser des commentaires de la même manière qu'en (X)HTML :
  `<!-- Ceci est un commentaire. -->`
- XML (et les DTD, et tout le reste dans ce cours) sont sensibles à la casse.

Plan de la séance

Pourquoi une DTD ?

Pour spécifier la structure d'un document.

- Pour avoir des hypothèses sur les éléments rencontrés (potentiellement pour les afficher d'une certaine manière, *cf* XHTML et – plus tard – CSS).
- Pour garantir qu'un document suit bien les règles d'une application spécifique (format d'échange de données dans un protocole, par exemple).
- Pour dire ce qu'il est possible ou impossible de trouver dans un document. Ex : tel élément peut être suivi de tel autre.
- Pour spécifier que certains éléments doivent avoir des attributs obligatoires. Ex : tout élément `employé` doit avoir un attribut `no_secu`.

Comment invoquer une DTD ?

Cas d'une DTD externe

↪ Le cas de XHTML :

```
<!DOCTYPE html PUBLIC
"-//W3C//DTD XHTML 1.0 Strict//EN"
"http://www.w3.org/TR/xhtml1/DTD/xhtml1-strict.dtd">
```

↪ Dissection :

`DOCTYPE` Mot clef pour dire qu'on déclare une DTD.

`html` Nom de l'élément racine.

`PUBLIC` La DTD est publique : accessible publiquement en ligne. Autre possibilité : `SYSTEM`, la DTD se trouve sur le serveur.

`"-//W3C//DTD XHTML 1.0 Strict//EN"` Identifiant de la DTD ; ne s'applique que pour les DTD publiques.

`"http://www.w3.org/TR/xhtml1/DTD/xhtml1-strict.dtd"` URL de la DTD

Comment invoquer une DTD ?

Cas d'une DTD interne

```
<!DOCTYPE population[
```

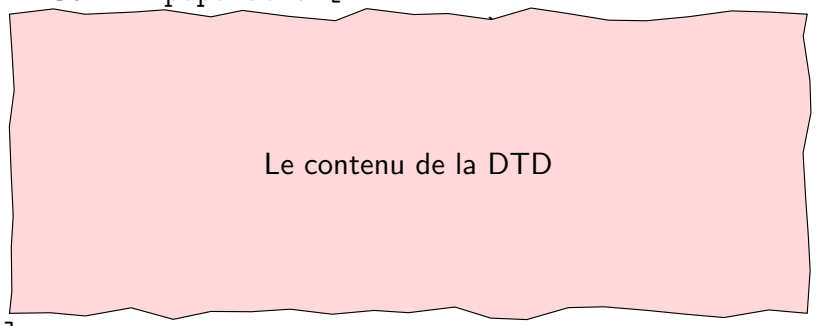


```
]>

<population/>
```

Exemple : DTD externe sur le serveur

```
<!DOCTYPE population SYSTEM "../DTDs/population.dtd">
```

Contenu de population.dtd

```
<!ELEMENT population (person)*>
<!ELEMENT person (name, trade+)>
<!ELEMENT name ((first_name,last_name)|
                (last_name,first_name))>
<!ELEMENT first_name (#PCDATA)>
<!ELEMENT last_name (#PCDATA)>
<!ELEMENT trade (#PCDATA)>
<!ATTLIST person id ID #REQUIRED>
<!ATTLIST last_name von_part CDATA #IMPLIED
                    junior CDATA #IMPLIED>
```


Remarques

Erreur fréquente à éviter

Pas de `<!DOCTYPE racine [... ]>` dans une DTD externe.

Concernant l'invocation

- Il faut parfois forcer les programmes à aller lire la DTD : un navigateur web s'en fiche ; pour le TP :

  Validation avec la DTD incluse ou référencée

  ```
  xmllint --valid monXml.ml
  ```

- Il n'est pas obligatoire d'invoquer une DTD dans le XML :

  Validation avec une autre DTD

  ```
  xmllint --dtdvalid maDtd.dtd monXml.ml
  ```


ELEMENT : définition d'éléments

Exemple

```
<!ELEMENT population (person)*>
```

Syntaxe

```
<!ELEMENT nom_de_l_element contenu_de_l_element>
```

Le `nom_de_l_element` :

- est formé de lettres, chiffres, et de caractères de ponctuation : `.` (point), `-` (tiret), `:` (deux points), `_` (tiret bas) ;
- doit commencer par une lettre ou `_` ;
- est sensible à la casse (majuscule/minuscule) ;
- ne doit pas commencer par `xml` (ni `XML`, `Xml`, `xMl`...).

ELEMENT : définition d'éléments

Exemple

```
<!ELEMENT population (person)*>
```

Syntaxe

```
<!ELEMENT nom_de_l_element contenu_de_l_element>
```

Dans la mesure du possible, le `nom_de_l_element` :

- évite d'utiliser `:` (deux points) hormis pour spécifier l'espace de noms ;
- évite l'utilisation de lettres non ASCII (même lorsque l'encodage est spécifié en entête), certains logiciels le supportent mal.

Exemple de XML accepté


```
<?xml version="1.0" encoding="UTF-8"?>
<!DOCTYPE population SYSTEM "population.dtd">
<population>
  <person [redacted]>
  [redacted]
  </person>
  <person [redacted]>
  [redacted]
  </person>
 </population>
```


Le contenu des éléments
Partie I

- Le `contenu_de_l_element` spécifie quels autres éléments peuvent apparaître en tant que fils, et de quelle manière.
- Les éléments fils doivent aussi être spécifiés dans la DTD.
- Les fils peuvent être :

`#PCDATA` « parsed character data » : texte qui sera lu lors du parcours ⇝ les entités (`&toto;`) seront remplacées par leur valeur.

Exemple

```
<!ELEMENT first_name (#PCDATA)>
```

`(elt1,elt2,...)` Élements `elt1`, `elt2`,... dans cet ordre.

Exemple

```
<!ELEMENT name (first_name,last_name)>
```


Le contenu des éléments
Partie II

`(elt1 | elt2 | ...)` Élements `elt1` ou `elt2`,...

Exemple

```
<!ELEMENT troisieme_plat (fromage|dessert|cafe)>
```

`EMPTY` L'élément doit alors être vide.

Exemple

```
<!ELEMENT image EMPTY>
```

`ANY` L'élément peut contenir n'importe quoi.

Exemple

```
<!ELEMENT trucs ANY>
```


Le contenu des éléments
Partie III

- On peut spécifier le nombre d'élements :
  - `*` 0 ou plus
  - `?` 0 ou 1
  - `+` 1 ou plus

Exemple

```
<!ELEMENT population (person)*>
```

- On peut évidemment combiner tout cela :

Exemple

```
<!ELEMENT person (name, trade+)>
<!ELEMENT name ((first_name,last_name)|
                (last_name,first_name))>
```

Le contenu des éléments
Partie IV

- Comment spécifier : « les enfants de `pere` sont des `fils` et des `filles`, sans ordre particulier » ? :

```
<!ELEMENT pere (fils|fille)* >
```

(au moins 1 : `<!ELEMENT pere (fils|fille)+ >`)

- Sur le même principe : mélange de texte et d'éléments `fils` :

```
<!ELEMENT pere (#PCDATA|fils)* >
```

⇝ `<pere>Blabla <fils/> Bloblu </fils></pere>`

- Attention ! Dans le cas d'un mélange entre texte (`#PCDATA`) et d'autres fils, `#PCDATA` doit être le premier.

↪ On appelle cela du contenu mixte (*mixed content*).

Exemple de XML accepté


```
<?xml version="1.0" encoding="UTF-8"?>
<!DOCTYPE population SYSTEM "population.dtd">
<population>
  <person [redacted]>
    <name>
      <last_name>Sassolas</last_name>
      <first_name>Mathieu</first_name>
    </name>
    <trade>informaticien</trade>
  </person>
  <person [redacted]>
    <name>
      <first_name>Alan</first_name>
      <last_name>Turing</last_name>
    </name>
    <trade>informaticien</trade>
    <trade>mathématicien</trade>
  </person>
 </population>
```


`ATTLIST` : définition d'attributs

Exemple

```
<!ATTLIST last_name von_part CDATA #IMPLIED
                     junior CDATA #IMPLIED>
```

Syntaxe

```
<!ATTLIST nom_de_l_element
   nom_de_l_attribut1 type_de_l_attribut1 options1
   nom_de_l_attribut1 type_de_l_attribut1 options2
                                                ...>
```

Le nom d'un attribut :

- est formé de lettres, chiffres, et de caractères de ponctuation : `.`, `-`, `:`, `_` ;
- doit commencer par une lettre ou `_` ;
- est sensible à la casse (majuscule/minuscule).

Les types d'attributs
Partie I

`CDATA` « character data » : du texte (qui ne sera pas lu).

Exemple

```
<!ATTLIST last_name von_part CDATA #IMPLIED
                     junior CDATA #IMPLIED>
```

`(val1|val2|...)` Une valeur parmi `val1`, `val2`...

Exemple

```
<!ATTLIST image type (jpeg|gif|png|svg) #REQUIRED>
```

`NMTOKEN` du texte sans espace.

Exemple

```
<!ATTLIST person country_code NMTOKEN #IMPLIED>
```

`NMTOKENS` plusieurs morceaux de texte (sans espaces) séparés par des espaces.

Les types d'attributs
Partie II

`ID` identifiant : la valeur doit être unique dans le document XML (et obéir aux mêmes règles que les noms d'attributs).

Exemple
```
<!ATTLIST person id ID #REQUIRED>
```

`IDREF, IDREFS` référence vers un (resp. plusieurs) identifiants.

`ENTITY, ENTITIES` une (resp. plusieurs) entités (*cf* suite).

`NOTATION (not1|not2...)` une notation parmi `not1`, `not2`,....

Les options d'attributs
Partie I

`"valeur_par_defaut"` Tous les éléments auront cet attribut, avec cette valeur si elle n'est pas spécifiée explicitement.

Exemple
```
<!ATTLIST image type (jpeg|gif|png|svg) "jpeg">
```

`#REQUIRED` Attribut obligatoire ; le XML n'est pas valide s'il n'est pas spécifié.

Exemple
```
<!ATTLIST person id ID #REQUIRED>
```


Les options d'attributs
Partie II

`#IMPLIED` Attribut optionnel ; s'il n'est pas spécifié, l'élément n'aura pas l'attribut.

Exemple
```
<!ATTLIST last_name von_part CDATA #IMPLIED
                     junior CDATA #IMPLIED>
```

`#FIXED "valeur"` Attribut fixe ; l'attribut n'est pas obligatoire, mais doit avoir cette valeur.

Exemple
```
<!ATTLIST person species CDATA #FIXED "human">
```


Les entités

- Dans le cas des entités prédéfinies (&, <, >, ", '), pour pouvoir utiliser des caractères réservés.
- Servent de raccourci pour ne pas avoir à répéter certaines choses.
- Peuvent n'être utilisables que dans la DTD (entité paramétrée) ou également dans le XML (entité générale, c'est le cas des entités prédéfinies).
- Peuvent être externes ou internes (au document).
- Attention ! Dans le cas d'entités externes, il faut que le lecteur du XML aille bien lire la DTD pour remplacer les entités. NB : les navigateurs web ne le font pas.

Les entités générales
En interne

Exemple

```
<!DOCTYPE tract [
  <!ELEMENT tract (#PCDATA | a)*>
  <!ELEMENT a (#PCDATA)>
  <!ATTLIST a href CDATA #IMPLIED>
  <!ENTITY moi "moi moi moi moi moi!">
  <!ENTITY vpm "votez pour
     <a href='http://votezpourmoi.com'>&moi;</a>">
]>

<tract>Bonjour, &vpm;</tract>
```

Syntaxe

```
<!ENTITY nom_de_l_entite "valeur_de_l_entite">
```


IUT SENART FONTAINEBLEAU

Les entités générales
En interne

Intro XML & DTD
M. Sassolas
L3Pro
Cours 1
Programme
XHTML & XML
DTD
Intro
Invocation
Dissection !
Les entités
Les notations
TD/TP

Exemple

```
<!DOCTYPE tract [
  <!ELEMENT tract (#PCDATA | a)*>
  <!ELEMENT a (#PCDATA)>
  <!ATTLIST a href CDATA #IMPLIED>
  <!ENTITY moi "moi moi moi moi moi!">
  <!ENTITY vpm "votez pour
     <a href='http://votezpourmoi.com'>&moi;</a>">
]>

<tract>Bonjour, &vpm;</tract>
```

```
−<tract>
   Bonjour, votez pour
   <a href="http://votezpourmoi.com">moi moi moi moi moi!</a>
 </tract>
```

36 / 45

IUT SENART FONTAINEBLEAU

Les entités générales
Externes analysées

Intro XML & DTD
M. Sassolas
L3Pro
Cours 1
Programme
XHTML & XML
DTD
Intro
Invocation
Dissection !
Les entités
Les notations
TD/TP

Exemple

```
<!DOCTYPE tract [
  <!ELEMENT tract (#PCDATA)>
  <!ENTITY moi SYSTEM "moi.txt">
  <!ENTITY prog PUBLIC "Mon Programme"
           "http://votezpourmoi.com/programme.txt">
]>

<tract>Bonjour, je suis &moi;,
           j'ai un beau programme: &prog;</tract>
```

Syntaxe

```
<!ENTITY nom_de_l_entite SYSTEM "URI_de_l_entite">
<!ENTITY nom_de_l_entite PUBLIC "identifiant"
                                "URL_de_l_entite">
```


IUT SENART FONTAINEBLEAU

Les entités générales
Externes non-analysées, partie I

Intro XML & DTD
M. Sassolas
L3Pro
Cours 1
Programme
XHTML & XML
DTD
Intro
Invocation
Dissection !
Les entités
Les notations
TD/TP

↪ Ces entités ne sont utilisables que dans des attributs (cas `<!ATTLIST el att ENTITY #IMPLIED>`).

Exemple

```
<!DOCTYPE tract [
 <!ELEMENT tract (#PCDATA | image)*>
 <!ELEMENT image EMPTY>
 <!ATTLIST image source ENTITY #REQUIRED>
 <!ENTITY moi SYSTEM
  "http://votezpourmoi.com/picture.png" NDATA png>
 <!NOTATION png SYSTEM "image/png">
]>

<tract>Ne suis-je beau?
                    <image source="moi"/></tract>
```

Les entités générales
Externes non-analysées, partie II

Syntaxe

```
<!ENTITY nom_de_l_entite SYSTEM "URI_de_l_entite"
                         NDATA notation>
<!ENTITY nom_de_l_entite PUBLIC "identifiant"
                 "URL_de_l_entite" NDATA notation>
```

- L'entité contient du code qui ne doit pas être analysé comme du XML.
- `NDATA notation` indique le type de données de l'entité, et donc comment elle devra être traitée.
- La `notation` devra elle aussi être définie (ce n'est qu'un nom), pour définir vraiment comment traiter ce type de contenu.

Les entités paramétrées
Internes

- Servent de variable dans la DTD.
- Ne peuvent être utilisées que dans des DTD externes.

Exemple

```
<!ELEMENT livre (auteur, editeur)>
<!ENTITY % info "(prenom,nom)">
<!ELEMENT nom (#PCDATA)>
<!ELEMENT prenom (#PCDATA)>
<!ELEMENT auteur %info;>
<!ELEMENT editeur (%info;,adresse)>
<!ELEMENT adresse (#PCDATA)>
```

Syntaxe

```
<!ENTITY % nom_de_l_entite "contenu">
<!ELEMENT elt %nom_de_l_entite;>
```


Les entités paramétrées
Internes


```
<!DOCTYPE livre SYSTEM "livre.dtd">

<livre>
<auteur>
<prenom>Victor</prenom>
<nom>Hugo</nom>
</auteur>
<editeur>
<prenom>François</prenom>
<nom>Didot</nom>
<adresse>À l'angle du quai des Grands-Augustins
et de la rue Séguier, à Paris</adresse>
</editeur>
</livre>
```


Les entités paramétrées
Externes

- Même principe, mais le contenu est dans une DTD

Exemple

```
<!DOCTYPE bibliotheque [
  <!ENTITY % livre SYSTEM "livre.dtd">
  %livre;
  <!ELEMENT bibliotheque (livre*)>
]>
```

Syntaxe

```
<!ENTITY % nom_de_l_entite SYSTEM
                                "URL_de_la_DTD.dtd">
%nom_de_l_entite;
```

Remarques

- On peut utiliser des entités dans la définition des entités.

Exemple

```
<!ENTITY % iut "IUT de Fontainebleau">
<!ENTITY copyright "Tous droits réservés
                                1993-2013, %iut;">
```

- Attention à ne pas faire de définition circulaire !

Exemple

```
<!ENTITY iut "IUT de &bleau;">
<!ENTITY bleau "Fonta[illegible]. la ville où se
                                trouve l'%iut;">
```


Les notations

- Les notations servent à définir des morceau de texte/code qui seront lues par une autre application.
- Cas d'usage majoritaire : définir les types de données (*MIME types*).

Exemple

```
<!NOTATION gif PUBLIC "image/gif">
<!NOTATION jpeg PUBLIC "image/jpeg">
<!ATTLIST image type NOTATION (gif|jpeg) #REQUIRED>
```

Syntaxe

```
<!NOTATION nom_de_la_notation SYSTEM
                              "contenu_de_la_notation">
<!NOTATION nom_de_la_notation PUBLIC "identifiant"
                              "contenu_de_la_notation">
```


Plan de la séance

Fin du cours 1

↳ On commence le TD ↵