

XML

Yannick Prié
UFR Informatique – Université Lyon 1
UE2.2 – Master SIB M1 – 2008-2009

Objectifs des trois cours

- Etre capable de comprendre des documents XML et des DTD
- Etre capable de construire des documents XML et des DTD
- Découverte de quelques DTD « importantes »

Un document XML

```
<?xml version="1.0" encoding="UTF-8"?>
<!DOCTYPE livre SYSTEM "E:\prie\Enseignement\2004-2005\Master SIB
\SIB2.2-bloc2-XML\Fichier CM XML\exemple-intro.dtd">
<livre id="561" nbpages="190" titre="La compagnie des spectres">
  <auteur>
    <nom>Salvyre</nom>
    <prenom>Lydie</prenom>
  </auteur>
  <format type="poche">
    <mesure type="largeur" unite="cm">11</mesure>
    <mesure type="longueur" unite="cm">19</mesure>
    <mesure type="hauteur" unite="mm">10</mesure>
  </format>
</livre>
```

La DTD correspondante

```
<!ELEMENT livre (auteur, format)>
<!ATTLIST livre
  id CDATA #REQUIRED
  nbpages CDATA #REQUIRED
  titre CDATA #REQUIRED >
<!ELEMENT auteur (nom, prenom)>
<!ELEMENT format (mesure+)>
<!ATTLIST format
  type CDATA #REQUIRED >
<!ELEMENT mesure (#PCDATA)>
<!ATTLIST mesure
  type (hauteur | largeur | longueur) #REQUIRED
  unite (cm | mm | in) #REQUIRED >
<!ELEMENT nom (#PCDATA)>
<!ELEMENT prenom (#PCDATA)>
```

Plan

- Documents XML
 - Syntaxe XML et documents bien formés
- Types de documents XML
 - DTD et documents valides
 - Introduction à XML-Schema
- Le monde XML
 - Quelques normes liés à XML
 - Quelques DTD importantes

Plan

- **Documents XML**
 - Syntaxe XML et documents bien formés
- Types de documents XML
 - DTD et documents valides
 - Introduction à XML-Schema
- Le monde XML
 - Quelques normes liés à XML
 - Quelques DTD importantes

Qu'y a-t-il dans un document XML ?

- Prologue
 - Déclaration XML
 - Déclarations de DTD
 - Instructions pour les processeurs XML
 - Instructions de traitement
 - Instructions pour applications externes
- Arbre des éléments
 - Éléments
 - Balises XML pour le marquage
 - Contenu
 - texte
 - autres éléments
 - Attributs des éléments
 - Information associées aux éléments
- Commentaires

Déclaration XML

- Syntaxe générale

```
<?xml version="1.0" [encoding = "encodage"] [standalone="yes|no »] ?>
```

- Est une des informations de traitement
- Indique
 - Conformité du document à une version de la norme XML
 - version="1.0"
 - Jeu de caractères utilisé dans le document
 - encoding = "UTF-8"
 - Présence ou non de références externes
 - standalone="yes"

Instructions de traitement

- Informations nécessaires à une application externe
- Format :
 - `<?NomApplication paramètres ?>`
- Exemples
 - Déclaration de feuille de style à utiliser
 - `<?xml-stYLESHEET href="fichier.xml" type="text/xsl"?>`
 - Déclaration XML de début de fichier
 - `<?xml version='1.0' ?>`

Éléments : règles de base

- Un nom d'élément
 - commence par une lettre ou souligné
 - contient des lettres, chiffres, et "-", ".", ":", " ", "_"
 - peut posséder un préfixe
 - `prefixe:nom_element`
 - Ex : `xsl:template`
- Les noms d'éléments dépendent de la casse
 - `<nom_element> ≠ <nom_Element>`
- Balises
 - de début : `<nom_element>`
 - de fin : `</nom_element>`
- Les éléments peuvent être vides
 - pas de contenu
 - `<element_vide />`
 - Ex :
 - ``

Arbre des éléments

- Un seul élément racine qui contient tous les autres
- Pas d'intersections entre éléments
 - Mauvais : `<nom1><nom2>...</nom1></nom2>`
 - Bon : `<nom1><nom2>...</nom2></nom1>`
- Blancs ou retours chariot en général non significatifs
 - `<section><p> ... </p></section>`
 - `<section><p> ... </p></section>`
- Les éléments sont ordonnés

Caractères spéciaux

- Ces caractères ont une signification spéciale pour les outils XML
- Il faut les écrire différemment
 - < <
 - > >
 - & &
 - ' '
 - " "

Attributs associés aux éléments : règles de base

- Dans les balises ouvrantes
 - `<el att1="valeur1" att2="valeur2">`
- Les noms d'attributs dépendent de la casse
 - `<el att1="valeur1" Att1="valeur2">`
- Valeurs d'attributs entourées
 - par des guillemets (") ou des apostrophes (')
- Les attributs sont non-ordonnés

Attributs

- Les valeurs peuvent être
 - des données textuelles
 - `value="N'importe quoi"`
 - des *tokens* (noms XML) simples
 - `value = "blue"`
 - des ensembles de *tokens*
 - `value = "red green blue"`
- Possibilité d'énumérer les valeurs possibles et de mettre des valeurs par défaut (voir DTD)

Attributs de type ID et IDREF(S)

- Permettent des relations non hiérarchiques entre éléments
 - ID : identificateur unique dans le document XML
 - IDREF : référence à un élément ayant un attribut de type ID
 - IDREFS : références à des éléments ayant un attribut de type ID
- Exemple

```
<société codes_services="A001 A003">
  <service code="A001">
    <employé code="E205" code_service="A001"> Jean Dupont </employé>
    <employé code="E206" code_service="A001"> Frédéric Marc </employé>
    <employé code="E207" code_service="A001"> Fabrice Detterre </
    employé>
    <employé code="H107" code_service="A003"> Angélique Millet </
    employé>
  </service>
  <service code="A003">
    <employé code="A115" code_service="A003"> Isabelle Mascot </employé>
  </service>
</société>
```
- Exercice
 - Construire l'arbre correspondant, dessiner les relations entre référence vers des identificateurs (idrefs) et identificateurs (id)

Commentaires

- Les commentaires ne sont pas considérés comme faisant partie du document XML.
 - `<!-- Un commentaire -->`
- Pas de '–' dans un commentaire !
- Un commentaire ne peut pas se trouver dans une autre déclaration

Au bilan : dans un document XML

- Prologue
 - en-tête
 - déclaration de DTD (*pas encore vu*)
 - instructions de traitement
- Eléments
 - attributs
 - contenus
- Commentaires

Plan

- Documents XML
 - Syntaxe XML et documents bien formés
- **Types de documents XML**
 - DTD et documents valides
 - Introduction à XML-Schema
- Le monde XML
 - Quelques normes liés à XML
 - Quelques DTD importantes

Traiter automatiquement un document XML

- Parseur (anglicisme d'après *parser*)
 - Outil qui lit un document XML et construit l'arbre des éléments en mémoire
- Vérifier qu'un document répond bien à la syntaxe XML
 - Document *bien formé*
 - Possibilité de l'utiliser en tant que tel
 - ex. : le présenter à l'utilisateur
- Vérifier en plus qu'un document suit bien la grammaire définie dans une DTD
 - Document *valide*

Document Type Definition

- Pour définir le type de document XML voulu
 - grammaire pour décrire comment construire un document XML
- Permet de
 - valider un document XML (avec un parseur validant)
 - vérifier que tous les éléments sont présents et corrects
 - vérifier que les noms d'attributs et leurs valeurs sont corrects
 - transmettre cette connaissance à d'autres
 - ils pourront définir leurs propres documents XML suivant la même DTD
 - d'où possibilité de standardisation et d'échanges

DTD

- Déclaration
 - contenant la définition formelle de la structure autorisée,
 - décrit
 - quels noms sont utilisés pour les types d'éléments
 - comment ces types d'éléments s'organisent
 - ordre
 - hiérarchie
 - les attributs des éléments
 - des entités analysables ou non
 - des notations pour les types de données binaires
- Liaison DTD / document XML
 - soit la DTD est dans le document XML (inline)
 - soit le document XML réfère à la DTD avec une URI (la DTD est dans un fichier externe)

Langage de DTD

- Un autre langage que XML
 - autre syntaxe, mots-clés différents
 - origines dans SGML
- Pour décrire des types de documents XML
- Remarque
 - XML schema permet de faire la même chose, en XML

Déclarations

- Instructions pour le processeur XML
- Format : `<! ... >` ou `<! ... [<! ... >]>`
 - Document type - `<!DOCTYPE ... >`
 - Character data - `<![CDATA[...]]>`
 - Entities - `<!ENTITY ... >`
 - Notation - `<!NOTATION ... >`
 - Element - `<!ELEMENT ... >`
 - Attributes - `<!ATTLIST ... >`
 - `<![INCLUDE [...]]>` et `<![IGNORE [...]]>`

Déclaration Document Type

- Placée au début du document XML
- Identifie le nom de l'élément *racine* du document
 - `<!DOCTYPE Racine>`
- Permet aussi de rajouter des définitions d'entités et des DTD
 - `<!DOCTYPE Racine [...] >`
 - `<Racine>`
 - ...
 - `</Racine>`

déclaration de la DTD

Déclaration Character Data

- o Placée dans le document XML
- o Permet de taper directement du texte qui ne doit pas être interprété par un outil XML
- o Deux textes équivalents
 - `Press <<<ENTER>>>`
 - `<![CDATA[Press <<<ENTER>>>]]>`

DTD et document XML

Valide, contraint

```
<?xml version="1.0" encoding="UTF-8"?>
<!DOCTYPE livre SYSTEM "exemple-intro.dtd">
<livre id="561" nbpages="190"
      titre="La compagnie des spectres">
  <auteur>
    <nom>Salvayre</nom>
    <prenom>Lydie</prenom>
  </auteur>
  <format type="poche">
    <mesure type="largeur" unite="cm">11</mesure>
    <mesure type="longueur" unite="cm">19</mesure>
    <mesure type="hauteur" unite="mm">10</mesure>
  </format>
</livre>
```

Document XML

```
<!ELEMENT livre (auteur, format)>
<!ATTLIST livre
  id CDATA #REQUIRED
  nbpages CDATA #REQUIRED
  titre CDATA #REQUIRED >
<!ELEMENT auteur (nom, prenom)>
<!ELEMENT format (mesure+)>
<!ATTLIST format
  type CDATA #REQUIRED >
<!ELEMENT mesure (#PCDATA)>
<!ATTLIST mesure
  type (hauteur | largeur |
longueur) #REQUIRED
  unite (cm | mm | in)
#REQUIRED >
<!ELEMENT nom (#PCDATA)>
<!ELEMENT prenom (#PCDATA)>
```

Est validé par, Est contraint par

Mettre en place une DTD


- o Définir différents composants XML...
 - Entités, éléments, déclarations, instructions de traitements, listes d'attributs, etc.
- o ... dans des DTD pour spécifier les règles permettant de valider des documents XML
 - Définir un modèle (type) de document de façon formelle
 - o pour qu'une machine puisse valider les documents qui lui seront soumis
- o Une DTD décrit
 - Quels noms peuvent être utilisés pour les types d'éléments
 - L'ordre dans lesquels ceux-ci peuvent apparaître
 - La hiérarchie documentaire
 - Les noms et les types des attributs d'éléments

Déclaration de DTD

- o La DTD est stockée
 - soit dans le fichier XML
 - soit dans un fichier extérieur
 - soit dans les deux
- o Une DTD interne peut écraser ou ajouter des ENTITY ou des ATTLIST à des définitions de DTD externes
 - principe : "le dernier qui parle a raison"
- o Une DTD est composée de déclarations
 - ELEMENT – définitions d'éléments
 - ATTLIST – définitions d'attributs
 - ENTITY – définitions d'entités
 - NOTATION – définitions de notations

Déclarations d'éléments

- o Définir un élément et son contenu
 - `<!ELEMENT name (#PCDATA)>`
 - ⇒ `<name> ...du texte... </name>`
- o Définir un élément vide (sans contenu)
 - `<!ELEMENT name EMPTY>`
 - ⇒ `<name/>`
- o Définir des éléments fils spécifiques
 - `<!ELEMENT person (name, email*)>`
 - Éléments fils quelconques
 - o `<!ELEMENT name ANY>`



Définir une hiérarchie (grammaire)

- o Définir le contenu des éléments
 - `<!ELEMENT person (name, email*)>`
- o ...et définir une hiérarchie d'éléments
 - `<!ELEMENT name (fname, surname)>`
 - `<!ELEMENT fname (#PCDATA)>`
 - `<!ELEMENT surname (#PCDATA)>`
 - `<!ELEMENT e-mail (#PCDATA)>`
- o Organisation des sous-éléments
 - Connecteur de séquence '': (A, B, C) [puis]
 - Connecteur de choix '|': (A | B | C) [ou]



Indicateurs de quantité

- Contraintes sur les éléments des DTD

A?	Possible	[0..1]
A+	1 fois et plus	[1..*]
A*	0 ou plus	[0..*]
- Exemples
 - (A, B)+
 - ((A,B?) | C+)*

Déclaration d'attributs

- Les attributs sont associés aux types d'éléments
- Déclarés dans une déclaration ATTLIST liée à l'élément
 - <!ELEMENT nom_element ... >
 - <!ATTLIST nom_element ... >
 - Il faut ensuite définir
 - le nom de l'attribut
 - le type de l'attribut
 - sa valeur par défaut

Noms et types d'attributs

- Noms d'attributs
 - <!ATTLIST elem nom type par_defaut>
 - <!ATTLIST elem attribut_1 ...
attribut_2 ...
attribut_3 ... >
- Dix types possibles d'attributs

CDATA	ID
NMTOKEN	IDREF
NMTOKENS	IDREFS
ENTITY	NOTATION
ENTITIES	name group

Types d'attributs (1)

- CDATA
 - Chaîne de caractères
 - <!ATTLIST person name CDATA >
 - <person name = "Tom Jones">
 - NMTOKEN
 - Token unique
 - <!ATTLIST mug color NMTOKEN >
 - <mug color="red">
 - NMTOKENS
 - Multiples tokens
 - <!ATTLIST temp values NMTOKENS >
 - <temp values="12 15 34">
- Joue sur la manière dont le parseur interprète l'attribut :
 • comme une chaîne de caractères quelconque
 • comme une chaîne représentant un élément
 • comme un ensemble d'éléments séparés par des espaces

Types d'attributs (2)

- ID
 - Identificateur unique pour l'élément
 - <!ATTLIST person id ID >
 - <person id = "P09567">Toto</person>
 - <person id = "P09567">Tutu</person> ← Nonvalide
- IDREF
 - Référence à un ID
 - <!ATTLIST person father IDREF >
 - <person father="P09567">
- IDREFS
 - Référence à plusieurs ID
 - <!ATTLIST person children IDREFS >
 - <person children="P09567 P09677">

Types d'attributs (3)

- Name group
 - Liste restreinte de valeurs possibles
 - <!ATTLIST point coord (X|Y|Z) >
 - <point coord="X">
- ENTITY (substitut pour autre chose)
 - L'attribut est une référence d'entité
 - <!ATTLIST person photo ENTITY >
 - <person photo="MyPic">
- ENTITIES
 - Plusieurs références d'entités
 - <!ATTLIST album photos ENTITIES >
 - <album photos="pic1 pic2">

Types d'attributs (4)

o NOTATION

- Décrit des données non XML
- `<!NOTATION jpg SYSTEM "JPEG Image" >`
- `<!NOTATION gif PUBLIC "+//ISBN 0-7923-9432-1::Graphic Notation//NOTATION CompuServer Graphic Interchange Format//EN">`
- `<!ATTLIST image format NOTATION (jpg|gif) ...>`
- `<image format="gif">`

Valeurs d'attributs par défaut

o Quatre types

- **#REQUIRED** *doit* être spécifié
- **#IMPLIED** *peut* être spécifié
- **"default"** valeur par défaut si non spécifié
- **#FIXED** seule valeur autorisée

<ATTLIST	element	nom	type	par_defaut
<!ATTLIST	citoyen	parents	IDREFS	#REQUIRED
		id	ID	#IMPLIED
		sex	(m f)	"f"
		adress	CDATA	#IMPLIED
		nat	CDATA	#FIXED "Fr"

Définition interne de DTD

o Dans la déclaration DOCTYPE

```
<?xml version="1.0" standalone="yes" ?>
<!DOCTYPE racine [
  <!-- ici la DTD -->
  <! ... >
  <! ... >
]>
<!-- ici le reste du fichier XML -->
<racine>
...
</racine>
```

Pas besoin de fichier supplémentaire

Définition externe privée de DTD

o Référence à la DTD externe par un chemin dans la déclaration DOCTYPE

- `<?xml version="1.0" standalone="no" ?>`
 - `<!DOCTYPE racine`
 - `SYSTEM "dossiers/MyDoc.dtd" [`
 - `<!-- déclarations supplémentaires -->`
 - `<! ... >`
 - `<! ... >`
 - `]>`
 - `<!-- ici le reste du fichier XML -->`
- Les déclarations spécifiques au document restent définies de façon interne

DTD externe privée

Définition externe privée de DTD

o Référence à la DTD externe par une URL dans la déclaration DOCTYPE

- `<?xml version="1.0" standalone="no" ?>`
 - `<!DOCTYPE racine`
 - `SYSTEM "http://serveur/chemin/MyDoc.dtd" [`
 - `<!-- déclarations supplémentaires -->`
 - `<! ... >`
 - `<! ... >`
 - `]>`
 - `<!-- ici le reste du fichier XML -->`
- Les déclarations spécifiques au document restent définies de façon interne

DTD externe privée, URL

Définition externe publique de DTD

o Utilisation du mot-clé PUBLIC


```
<!DOCTYPE racine
PUBLIC "identifiant public" "url" >
```

o Exemple

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

Les entités

- Sont des alias associant un nom à des « unités d'information »
- Les entités spécifiques au document sont décrites dans sa DTD interne
- Les entités plus générales sont décrites dans des DTD externes
- Chaque entité
 - est identifiée par un nom
 - est définie par une déclaration d'entité
 - est utilisée en appelant une référence d'entité



CM2-3-4 : eXtensible Markup Language – Yannick Prié UE2.2 – Master SIB M1 – 2008-2009 : Représentation des données et des connaissances

43

Utilisation des entités

- Quand l'information
 - Est utilisée dans plusieurs endroits
 - Ex. déclaration légale, caractère spécial
 - Est une partie d'un document qui doit être tronçonné pour rester gérable
 - Ex. livre = 1 fichier général + n chapitres soit n+1 fichiers en tout
 - Est conforme à un format de donnée différent de XML
 - Ex. : image JPEG

CM2-3-4 : eXtensible Markup Language – Yannick Prié UE2.2 – Master SIB M1 – 2008-2009 : Représentation des données et des connaissances

44

Types d'entités

- Entités internes
 - générales
 - utilisées dans les documents XML
 - « paramètre »
 - utilisées dans les déclarations dans les DTD
- Entités externes
 - générales
 - paramètres
- Entités analysables
- Entités non analysables
- Entités caractères
 - déjà vues

CM2-3-4 : eXtensible Markup Language – Yannick Prié UE2.2 – Master SIB M1 – 2008-2009 : Représentation des données et des connaissances

45

Entités générales internes

- ```
<!ENTITY nom "chaîne de remplacement">
```
- Entités analysables utilisées uniquement dans le document
  - Référence : &nom\_entité;
  - Exemple
    - Déclaration dans la DTD

```
<!ENTITY PCI "Permis de conduire informatique" >
```
    - Utilisation

```
<p>Le cours du PCI (&PCI;) se compose de...</p>
```

CM2-3-4 : eXtensible Markup Language – Yannick Prié UE2.2 – Master SIB M1 – 2008-2009 : Représentation des données et des connaissances

46

## Entités générales externes

- ```
<!ENTITY nom SYSTEM "URI" >
```
- Permet de construire un document XML à partir de plusieurs autres documents
 - Référence : &nom_entité;
 - Exemple
 - Déclaration dans la DTD

```
<!ENTITY doc SYSTEM "http://toto.org/doc.xml" >
```
 - Utilisation

```
<aide>Voir cette URL : &doc; </aide>
```

CM2-3-4 : eXtensible Markup Language – Yannick Prié UE2.2 – Master SIB M1 – 2008-2009 : Représentation des données et des connaissances

47

Entités paramètres internes

- ```
<!ENTITY % nom "caractères de remplacement" >
```
- Entités analysables uniquement utilisées dans les DTD
  - Référence dans la DTD : (%nom\_entité;) (parenthèses conseillées)
  - Exemples
    - Déclarations DTD

```
<!ENTITY % tout "ANY" >
<!ENTITY % common "(para|list|table)">
```
    - Utilisations dans la DTD

```
<!ELEMENT paragraphe %tout; >
<!ELEMENT chapter ((%common;)*, section*)>
<!ELEMENT section (%common;)*>
```

CM2-3-4 : eXtensible Markup Language – Yannick Prié UE2.2 – Master SIB M1 – 2008-2009 : Représentation des données et des connaissances

48



## Entités paramètres externes

- <!ENTITY % nom SYSTEM "URI" >
  - o Pour construire une DTD complexe à partir d'autres DTD complémentaires
  - o Référence dans la DTD : %nom\_entité;
  - o Exemple
    - Déclaration dans la DTD
- ```
<!ENTITY % règles SYSTEM "http://toto.org/regles.dtd" >
```
- Utilisation dans la DTD
- ```
%règles;
```

## Entités analysables

- o Le texte de remplacement fait partie intégrale du document
  - les données sont analysées correctement par le parser XML
- o Déclaration dans la DTD comme ENTITY
- o Utilisation avec &nom; ou %nom;

## Entités non analysables

- <!ENTITY % nom SYSTEM "URI" NDATA notation >
  - o Pour déclarer un contenu non XML dans un document XML
    - fichier image, audio, etc.
  - o Référence : &nom\_entité; uniquement comme attribut de type ENTITÉ
  - o Exemple
    - Déclaration DTD
- ```
<!NOTATION TIFF SYSTEM "format TIFF">
```
- ```
<!ENTITY photo SYSTEM "photo.tif" NDATA TIFF>
```
- ```
<!ELEMENT pic EMPTY>
```
- ```
<!ATTLIST pic name ENTITY #REQUIRED>
```
- Utilisation dans le document XML
- ```
<pic name="photo" />
```

Déclarations de notations

- <!NOTATION nom SYSTEM "URI" >
 - o Pour
 - Identifier par un nom le format des entités non XML externes
 - Définir les formats des données et les applications qui permettent de les traiter
 - o Exemple
- ```
<!NOTATION GIF SYSTEM "GIF" >
```
- ```
<!NOTATION GIF89a PUBLIC "-//CompuServe//NOTATION Graphics Interchange format 89a//EN" >
```

Identificateurs publics

- ```
PUBLIC "-//EBI//DTD My book//EN" "url"
```
- o PUBLIC keyword
  - o Identifiant type - Registered + / - / ISO
  - o Owner identifier
  - o Public text class
    - DTD, NOTATIONS, ENTITIES, TEXT
  - o Public text description
  - o Public text language
  - o url non obligatoire mais conseillée

### Exemples d'utilisation

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

```
<!NOTATION GIF89a PUBLIC "-//CompuServe//NOTATION Graphics Interchange format 89a//EN" >
```

## Construire une DTD

- o Non trivial : il faut éviter de se tromper
  - Changer une DTD XML a des conséquences sur les documents qui la suivent
- o Ressemble à la création d'un schéma de base de données
- o Il faut considérer
  - Le problème de la granularité
  - La questions des attributs et des éléments
  - Les limitations inhérentes aux DTD

## Identifier les données qui nécessitent d'être balisées

- Pour chaque unité d'information, déterminer
  - Peut-on lui donner un nom ?
  - Apparaît-elle tout le temps ?
  - Peut-il y en avoir plusieurs ?
  - Peut-on la décomposer en des unités plus petites ?
  - Y-a-t'il du contenu textuel qui ne change pas ?
  - Comment est-elle associée aux autres unités ?

## Granularité

- `<PERSON>`
  - `<NAME>Jon Smith</NAME>`
  - `</PERSON>`
- `<PERSON>`
  - `<FORENAME>Jon</FORENAME>`
  - `<SURNAME>Smith</SURNAME>`
  - `</PERSON>`

## Éléments ou attributs ?

- Comment les données doivent-elles être encapsulées ?
  - `<book>`
    - `<title>The Forty-nine Steps</title>`
    - ...
    - `</book>`
  - `<book title="The Forty-nine Steps">`
  - ...
  - `</book>`
- Tout dépend de ce que l'on veut faire...
- Il existe des avis tranchés...

## Éléments ou attributs ? (2)

- Séparer le contenu des métadonnées
  - Données qui doivent être imprimées comme du texte comme contenu
  - Métadonnées comme attributs
- Règles générales
  - Si on enlève toutes les balises, le document doit encore être lisible et utilisable
  - S'il y a doute, utiliser un attribut

## Limites des DTD

- XML est seulement une syntaxe
- XML ne porte pas de sémantique
- Uniquement description de structure
- Pas de types
- Un des moyens de pallier certains problèmes
  - XML-schema

## Problèmes des DTD

- Une syntaxe de description non-XML, héritée de SGML
  - Oblige à apprendre un langage supplémentaire
  - Ne permet pas de manipuler les DTD avec des outils XML
- Pas assez de contraintes sur les données manipulées
  - Toute données est une chaîne de caractères
  - Impossible de
    - spécifier des types simples
      - ex. entiers, dates, etc.
    - spécifier des cardinalités simples
      - ex. « un ARTICLE aura entre 1 et 4 MOTS-CLE »
    - spécifier des contraintes simples
      - ex. entier positif

## XML-Schema

- Autre manière de spécifier des types de documents XML
- Le schéma est exprimé en XML
- Possibilité de spécifier plus de contraintes sur les données
- Possibilités avancées d'extension des schémas
- On élargit l'approche de gestion documentaire à celle plus générale de gestion de données

## Exercice 1 : Propos XML valides suivant

```
(suite)
<ELEMENT abstract (#PCDATA)>
<ELEMENT number (#PCDATA)>
<ELEMENT note (#PCDATA)>
<ELEMENT publisher (#PCDATA)>
<ELEMENT institution (#PCDATA)>
<ELEMENT school (#PCDATA)>
<ELEMENT howpublished (#PCDATA)>
<ELEMENT address (#PCDATA)>
<ELEMENT inproceedings (%req_fields;, booktitle,
%opt_fields;)>
<ATTLIST inproceedings %key_atts;
<ELEMENT article (%req_fields;, journal,
%opt_fields;)>
<ATTLIST article %key_atts;
<ELEMENT book (%req_fields;, publisher,
%opt_fields;)>
<ATTLIST book %key_atts;
<ELEMENT techreport (%req_fields;, institution?,
number?, %opt_fields;)>
<ATTLIST techreport %key_atts;
<ELEMENT phdthesis (%req_fields;, school?,
%opt_fields;)>
<ATTLIST phdthesis %key_atts;
<ELEMENT unpublished (%req_fields;, %opt_fields;)>
<ATTLIST unpublished %key_atts;
<ELEMENT misc (%req_fields;, howpublished,
%opt_fields;)>
<ATTLIST misc %key_atts;

<ENTITY % opt_fields "year?, volume?, pages?, month?, uri?,
abstract?, note?>
<ENTITY % req_fields "author, title">
<ENTITY % key_atts "key ID #REQUIRED">

<ELEMENT bibtex-file (article|inproceedings|book|techreport|
phdthesis|unpublished|misc)>

<ELEMENT key (#PCDATA)>
<ELEMENT author (name+)>
<ELEMENT name (#PCDATA)>
<ELEMENT title (#PCDATA)>
<ELEMENT booktitle (short, long?)>
<ELEMENT short (#PCDATA)>
<ELEMENT long (#PCDATA)>(suite)
<ELEMENT year (#PCDATA)>
<ELEMENT volume (#PCDATA)>
<ELEMENT pages EMPTY>
<ATTLIST pages
first NMTOKEN #REQUIRED
last NMTOKEN #REQUIRED
%key_atts;
<ELEMENT month (#PCDATA)>
<ATTLIST month
mtype (short | long) "short"
<ELEMENT uri EMPTY>
<ATTLIST uri
type (ps|pdf|html) #REQUIRED
href CDATA #REQUIRED
```

Un examen a entre 3 et 4 questions et chaque question a une ou plusieurs parties. Une partie se découpe en textes mélangés avec d'autres parties. Le code est uniquement alphanumérique, sans espace, la valeur de mois doit être une chaîne de caractère valide.

## Exercice 2

- Proposez deux DTD permettant de valider le document XML suivant

```
<examen code="coursXML">
<titre>Outils et documents XML</titre>
<date mois="jan" annee="2006"/>
<questions>
<question> <partie>Première partie<partie>Une sous-partie</partie>
/partie</question>
<question> <partie>Deuxième partie</partie> </question>
<question> <partie/> </question>
</questions>
</examen>
```

## Exercice 3

- On veut représenter en XML des données concernant les étudiants en SIB et leurs enseignements
- Proposez une DTD

## Plan

- Documents XML
  - Syntaxe XML et documents bien formés
- Types de documents XML
  - DTD et documents valides
  - Introduction à XML-Schema
- **Le monde XML**
  - Quelques normes liés à XML
  - Quelques DTD importantes

## Standardisation

- XML permet de définir des DTD
  - modèles de documents
  - modèles de représentation de données
- Dès qu'on a un groupe, partage de données/documents
  - nécessité de partager les manières de décrire
    - accord
      - local
      - global → standardisation
- Des standards sous la forme de DTD (ou de schémas),
  - stricts
  - qui peuvent être raffinés
    - les spécialiser avec des DTD internes
    - n'en utiliser que des parties

CM2-3-4 : eXtensible Markup Language – Yannick Prié UE2.2 – Master SIB M1 – 2008-2009 : Représentation des données et des connaissances

67

## Avantages et applications XML

- Avantages
  - réutilisabilité, partage
  - pérennité
  - intégrité
  - portabilité
- Applications
  - documents
  - échange de données
  - bureautique
  - Web
  - BDD semi-structurées
  - commerce électronique
  - ...

CM2-3-4 : eXtensible Markup Language – Yannick Prié UE2.2 – Master SIB M1 – 2008-2009 : Représentation des données et des connaissances

68

## Quelques standards XML

- The XML Bookmark Exchange Language (XBEL)
- Open eBook Publication Structure
- SportsML
- NewsML
- XML Book Industry Transaction Standards (XBITS)
- OpenDocument...
- DocBook
- ebXML (electronic Business)
- Universal Description, Discovery & Integration (UDDI)
- Text Encoding and Interchange (TEI)
- XTM (XML Topic Maps)
- ...

<http://publishing.xml.org/standards/>  
<http://www.oasis-open.org/specs/index.php>

CM2-3-4 : eXtensible Markup Language – Yannick Prié UE2.2 – Master SIB M1 – 2008-2009 : Représentation des données et des connaissances

69

## Quelques spécifications du W3C liées à XML

- XML Schema
- XLink et XPointer
- XPath
- XSL et XSLT
- XML Query
- Namespaces
- SAX
- DOM
- MathML
- OWL
- RDF
- SMIL
- SOAP
- SVG
- XHTML

Voir <http://www.w3c.org/>

CM2-3-4 : eXtensible Markup Language – Yannick Prié UE2.2 – Master SIB M1 – 2008-2009 : Représentation des données et des connaissances

70

## XPath

- Standard permettant d'identifier et de spécifier toutes données dans un document XML
- Exemples
  - `//toto[@name]`  
→ Tous les élément toto qui ont un attribut name
  - `//tata/descendant::*`  
→ Tous les descendants des éléments tata
- Voir cours XPath

CM2-3-4 : eXtensible Markup Language – Yannick Prié UE2.2 – Master SIB M1 – 2008-2009 : Représentation des données et des connaissances

71

## XLink

- Objectif
  - Donner la possibilité de liens riches
- XLink
  - XML Linking Specification
  - Liens
    - simples (1:1) et étendus (n:n),
    - typés
    - internes ou externes
- Exemple

```
<site xlink:type="local"
xlink:href="http://www.xml.fr/FAQ.xml"
xlink:label="fr"
xlink:title="Version française"/>
```

CM2-3-4 : eXtensible Markup Language – Yannick Prié UE2.2 – Master SIB M1 – 2008-2009 : Représentation des données et des connaissances

72

## XPointer

- Objectif
  - pointer précisément dans un document XML
- XPointer
  - XML Extended Pointer Specification
  - une référence absolue (le document XML)
  - et une référence relative (à l'intérieur du document)
    - expression XPATH
- Exemples
  - `http://www.toto.org/xml/doc.xml#xptr(/intro/title)`  
élément `title` dans élément `intro` de `doc.xml`
  - `http://site.fr/page.xml|id('ref12').child(1,session)`  
premier élément `session` enfant de l'élément  
identifié par `ref12`, dans le document `page.xml`

## XSL


- Ensemble d'outils permettant de
  - transformer les documents XML en d'autres documents XML (changement de format)
  - visualiser les documents XML sous forme lisible, pour de multiples supports
- eXtensible Style Language
  - XSL-FO (« XSL Formatting Objects »)
    - présenter des informations
  - XSLT (XSL Transformation)
    - transformer un arbre XML en un autre arbre XML
  - Voir cours XSL-XSLT

## Xquery

- Standard XML permettant d'exprimer des requêtes dans les documents XML
- Syntaxe XML ou non
- Utilisation de XPath


## XML et les applications : SAX

- SAX : Simple API for XML
  - principe : un parser SAX lit un document XML, et envoie un message à une application dès qu'il
    - rencontre un début ou une fin de document
    - rencontre un début ou une fin d'élément
    - trouve des caractères dans un élément, etc.
  - le programmeur qui écrit l'application XML décide quoi faire de chaque message



## XML et les applications : DOM

- DOM : Document Object Model
  - principe : un parser lit un document XML et fabrique un arbre des éléments en mémoire.
  - le programmeur qui écrit l'application XML peut alors accéder aux informations de cet arbre, les modifier, enregistrer celui-ci, etc.



## SVG

- Objectif
  - Description de schémas graphiques
  - Éléments
    - formes (lignes, courbes, triangles, rectangles, etc.), images, textes, groupes d'éléments, ...
  - Affichages
    - opacités, redimensionnements, masques...
  - Hypermédia
    - liens, animations (changements de propriétés, déplacements)...

## Un exemple qui bouge !

```
<?xml version="1.0" standalone="no"?>
<!DOCTYPE svg PUBLIC "-//W3C/DTD SVG December 1999/EN" "http://www.w3.org/Graphics/SVG/
SVG-19991203.dtd">
<svg width="8cm" height="3cm" viewBox="0 0 800 300">
<desc>Exemple animé 1 - demonstrate animation elements</desc>
<rect id="RectElement" x="300" y="100" width="300" height="100" style="fill:rgb(255,255,0)" />
<animate attributeName="x" attributeType="XML" begin="0s" dur="9s" fill="freeze" from="300"
to="0" />
<animate attributeName="y" attributeType="XML" begin="0s" dur="9s" fill="freeze" from="100"
to="0" />
<animate attributeName="width" attributeType="XML" begin="0s" dur="9s" fill="freeze" from="300"
to="800" />
<animate attributeName="height" attributeType="XML" begin="0s" dur="9s" fill="freeze" from="100"
to="300" />
</rect>
<g transform="translate(100,100)" >
<text id="TextElement" x="0" y="0" style="font-family:Verdana; font-size:35.27; visibility:hidden" > It's
alive!
<set attributeName="visibility" attributeType="CSS" to="visible" begin="3s" dur="6s" fill="freeze" />
<animateMotion path="M 0 0 L 100 100" begin="3s" dur="6s" fill="freeze" />
<animateColor attributeName="fill" attributeType="CSS" from="rgb(0,0,255)" to="rgb(128,0,0)"
begin="3s" dur="6s" fill="freeze" />
<animateTransform attributeName="transform" attributeType="XML" type="rotate" from="0" to="0"
begin="3s" dur="6s" fill="freeze" />
<animateTransform attributeName="transform" attributeType="XML" type="scale" from="1" to="3"
begin="3s" dur="6s" fill="freeze" />
</text > </g> </svg>
```

CM2-3-4 : eXtensible Markup Language – Yannick Prié UE2.2 – Master SIB M1 – 2008-2009 : Représentation des données et des connaissances

## MathML

- Objectifs
  - Intégrer proprement des expressions mathématiques dans les pages Web
  - Permettre l'échange de formules entre logiciels mathématiques
  - Représenter la structure de présentation et la structure mathématique des formules

### Exemples

Mathématique	Présentation
<pre>(a + b)<sup>2</sup></pre>	<pre>&lt;msup&gt;   &lt;mrow&gt;     &lt;mo&gt; (&lt;/mo&gt;     &lt;mi&gt;a&lt;/mi&gt;     &lt;mo&gt;+&lt;/mo&gt;     &lt;mi&gt;b&lt;/mi&gt;     &lt;mo&gt;)&lt;/mo&gt;   &lt;/mrow&gt;   &lt;mn&gt;2&lt;/mn&gt; &lt;/msup&gt;</pre>

CM2-3-4 : eXtensible Markup Language – Yannick Prié UE2.2 – Master SIB M1 – 2008-2009 : Représentation des données et des connaissances

## Espaces de noms

- Problème
  - deux schémas ou DTD peuvent définir des éléments qui ont le même nom
  - exemple :
    - DTD biblio : <ELEMENT name (nom,prénom) >
    - DTD vcard : <ELEMENT name (titre,prénom,nom) >
  - question
    - Comment utiliser plusieurs DTD dans un unique document en évitant les collisions de noms ?
- Solution
  - utiliser des « espaces de nom », « espaces de nommage », « vocabulaires » (*namespaces*)

CM2-3-4 : eXtensible Markup Language – Yannick Prié UE2.2 – Master SIB M1 – 2008-2009 : Représentation des données et des connaissances

## Namespaces

- Spécification W3C
- Principes
  - on considère qu'un schéma (DTD) définit son propre espace de nom, dans lequel tous les noms d'éléments et d'attributs sont uniques
  - on dispose d'un mécanisme pour
    - identifier les espaces de nom utilisés dans le document
    - identifier pour chaque élément ou attribut à quel espace de nom il appartient
  - ainsi,
    - toute référence à un nom d'élément est non ambiguë
    - un document unique peut contenir des informations définies dans plusieurs espaces de nom

CM2-3-4 : eXtensible Markup Language – Yannick Prié UE2.2 – Master SIB M1 – 2008-2009 : Représentation des données et des connaissances

## Identification des namespace

- Beaucoup de standards ont une URI officielle
  - une URI est unique
- On peut utiliser l'URI pour identifier l'espace de nom
  - pas forcément besoin d'un accès à Internet
  - l'URI devient une simple chaîne de caractères identifiant un schéma
- On « marque » les noms d'éléments et d'attributs en les préfixant avec l'URI ou un raccourci
  - préfixe:nom
  - aussi appelé Qname (nom qualifié)

CM2-3-4 : eXtensible Markup Language – Yannick Prié UE2.2 – Master SIB M1 – 2008-2009 : Représentation des données et des connaissances

## Exemple d'utilisation

- On définit les espaces de nom avec des attributs
- Le nom de l'attribut est **xmlns**
  - on peut le spécifier n'importe où (auquel cas il est valable pour tous les sous-éléments)
 

```
<h4:html xmlns:h4="http://www.w3c.org/TR/REC-html40"
xmlns:toto="file:/DTD/maDTD.dtd">
 <h4:p>Un paragraphe HTML</h4:p>
 <toto:p>Un paragraphe spécial</toto:p>
</h4:html>
```
  - L'espace de nom par défaut peut être spécifié sans identificateur
 

```
<book xmlns="file:/DTD/maDTD.dtd"
xmlns:h4="http://www.w3c.org/TR/REC-html40" >
 <h4:p>Un paragraphe HTML </h4:p>
 <p>Un paragraphe spécial</p>
</book>
```

CM2-3-4 : eXtensible Markup Language – Yannick Prié UE2.2 – Master SIB M1 – 2008-2009 : Représentation des données et des connaissances

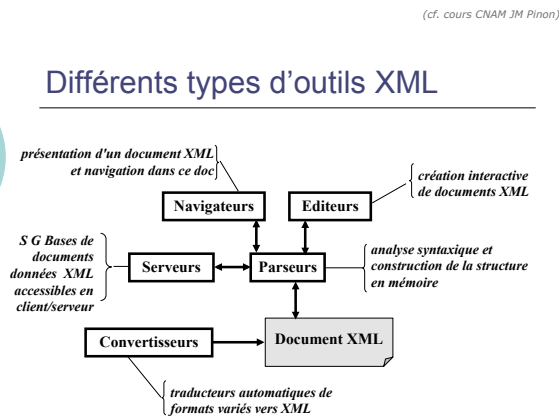
## Autre exemple avec MathML

```
<?xml version="1.0"?>
<html xmlns="http://www.w3.org/1999/xhtml">
<head>...</head>
<body>
<h1>Exemple</h1>
<math xmlns="http://www.w3.org/1998/Math/
MathML"> <mi>x</mi><mo>+</mo><mi>y</mi></math>
</math>
</body>
</html>
```

## Espaces de noms et DTD

- On peut utiliser des préfixes dans les DTD
  - <!ELEMENT document (feature, gene, sequence, collection:sequence, collection:list)\*>
- On peut inclure les définitions d'espace de nom dans les DTD
  - <!ATTLIST document xmlns:collection #FIXED "file:/DTDs/collection.dtd">
  - // Implique un attribut fixé à l'élément "document",
  - <document xmlns:collection = "file:/DTDs/collection.dtd">

## Différents types d'outils XML



## Exemples d'outils

- Parseurs
  - SAX et DOM souvent intégrés directement dans les langages (Java, .NET, etc.)
- Editeurs
  - XML-Spy
  - Cooktop
  - XMetal...
- Navigateurs
  - Firefox, IE, Opera, etc.
- Convertisseurs
  - nombreux outils avec format de sortie textuel
- SGB données/documents XML
  - évolutions des SGBD classiques
  - SGBD dédiés

## Autres outils

- XHTML / CSS
  - Dreamweaver, NVU...
- XSL
  - Style-vision...
- RDF
  - Outils du web sémantique...
- SMIL
  - Player : REAL ...
- SVG
  - Adobe, firefox, Opera...

## DocBook

- Objectif
  - codage de texte de documentation
  - sorties multi-formats
- <http://www.oasis-open.org/docbook/>
- A voir en TP
  - sdocbook : sous-ensemble de balises

## Open Document

- Objectif
  - codage des documents de suites bureautiques
    - textes, feuilles de calcul, présentations, dessins, formules, bases de données...
    - modèles pour ces documents
- Mis en place par OASIS
  - à partir des formats de OpenOffice (SUN)
- Mai 2005 : version 1.0
- 2006 : ISO
- Utilisé dans Open Office 2.0
- Standard ouvert
  - intérêt pour le partage, la récupération, etc.
  - enjeu politique (Massachusetts, sept 2005)
  - finalement MS Office exportera en Open Document
  - tentative Microsoft ISO / OOXML

CM2-3-4 : eXtensible Markup Language – Yannick Prié UE2.2 – Master SIB M1 – 2008-2009 : Représentation des données et des connaissances

91

## Conclusion

- XML
  - standard sorti en 1998
  - Unicode / généricité
  - documents / données
  - mondialement adoptée
- Standards et normes
  - variés : dans tous les domaines nécessitant
    - pérennité
    - échange
  - plus ou moins adaptés et adoptés
  - questions récurrentes
    - évolution
    - interopérabilité
  - guerre des standards et le contrôle de l'information

CM2-3-4 : eXtensible Markup Language – Yannick Prié UE2.2 – Master SIB M1 – 2008-2009 : Représentation des données et des connaissances

92

## Annexes : EAD/EAC - TEI

- Pour info
  - quelques transparents sur ces normes utiles aux sciences de la documentation

CM2-3-4 : eXtensible Markup Language – Yannick Prié UE2.2 – Master SIB M1 – 2008-2009 : Représentation des données et des connaissances

93

## EAD / EAC

- Objectif
  - Normalisation des instruments de recherche et des descriptions de contextes pour les archives
- EAD
  - Encoded Archival Description
- EAC
  - Encoded Archival Context
- Un point d'entrée
  - <http://www.archivesdefrance.culture.gouv.fr/fr/archiviste/DAFlangage.html>
- Il y a des spécialistes à l'ENSSIB

CM2-3-4 : eXtensible Markup Language – Yannick Prié UE2.2 – Master SIB M1 – 2008-2009 : Représentation des données et des connaissances

94

## Les trois éléments principaux de l'instrument de recherche en XML/EAD

- Sous l'élément racine <ead> :

<eadheader>	en-tête EAD (description bibliographique de l'IR) (obligatoire)
<frontmatter>	préliminaires (page de titre, introduction, préface...)
<archdesc>	description archivistique (obligatoire)

Ce transparent et les suivants sur l'EAD sont extraits de « L'EAD, une DTD pour la rédaction, l'archivage et la diffusion des instruments de recherche archivistiques » F. Clavaud / 5 avril 2004

CM2-3-4 : eXtensible Markup Language – Yannick Prié UE2.2 – Master SIB M1 – 2008-2009 : Représentation des données et des connaissances

95

## En-tête EAD <eadheader>

```
<eadheader>
 <eadid> Identifiant EAD (du fichier électronique)
 <filedesc> Description du fichier
 <titlestmt> Mention de titre et de responsabilité
 <titleproper> Titre propre de l'instrument de recherche
 <subtitle> Sous-titre de l'instrument de recherche
 <author> Auteur de l'instrument de recherche
 <editionstmt> Mention d'édition
 <publicationstmt> Mention de publication
 <seriesstmt> Mention de collection
 <notestmt> Mention de note
 <profiledesc> Description du profil
 <creation> Informations sur la création de l'inventaire
 <date> Date de l'inventaire
 <language> Langue utilisée
 <desrules> Règles de description (archivistique utilisée)
 <revisiondesc> Descriptions des révisions ; permet de gérer les versions successives de l'instrument de recherche encodé
</eadheader>
```

CM2-3-4 : eXtensible Markup Language – Yannick Prié UE2.2 – Master SIB M1 – 2008-2009 : Représentation des données et des connaissances

96



## En-tête EAD <eadheader>

```
<eadheader audience="external" findstatus="edited-partial-draft" encodinganalog="DC"
 <eadid encodinganalog="Identifier"="FRDAF-ANCR00AP_00000001" version="1.0"
 <title>
 <titleproper encodinganalog="title"="Etat sommaire des fonds d'archives privées du Centre historique des Archives nationales"
 <subtit> Série AP 317AP à 637AP et AB/XX/368 à AB/XX/525</subtit>
 <author encodinganalog="Creator"="Instrument de recherche rédigé par Claire Sibille, [...] encodé en XML conformément à la DTI EAD puis converti en HTML par Martin Sévigny (société AULSM) et Florence Clavaud (service des nouvelles technologies du CHAN)"
 </title>
 <edition>
 <edition> Quatrième édition </edition></editionstmt>
 </edition>
 <publicationstmt>
 <publisher encodinganalog="publisher"="Centre historique des Archives nationales de France (CHAN)"</publisher>
 <address>
 <addressline>60 rue des Francs-Bourgeois</addressline>
 <addressline>F-75141 PARIS CEDEX 03</addressline>
 <date encodinganalog="date"="août 2003"</date>
 </address>
 </publicationstmt>
 <filedesc>
 <creation>Instrument de recherche produit sous Word et converti en XML [...] en <date> novembre 2001 </date>. Encodage relu et complété par [...]</creation>
 <language>Instrument de recherche rédigé en <language langcode="fr">français</language>. </language>
 <revisiondesc>
 <change>
 <date>8 septembre 2003</date>
 <item>Fichier converti en EAD 2002 par programme XSLT fourni par D. Pitt (SAA adapté)</item>
 </change>
 </revisiondesc>
 </filedesc>
</eadheader>
```

CM2-3-4 : eXtensible Markup Language – Yannick Prié UE2.2 – Master SIB M1 – 2008-2009 : Représentation des données et des connaissances

97

## Préliminaires <frontmatter> : exemple

```
<frontmatter>
 <titlepage>
 <publisher>Centre historique des Archives nationales</publisher>
 <titleproper>Etat sommaire</title> des fonds d'archives privées</titleproper>
 <subtit> Série AP (317AP à 637AP) et AB XIX (AB/XX/368 à AB/XX/525)</subtit>
 <author> par Claire SIBILLE</author> <conservateur du Patrimoine>
 <author> avec la collaboration de Fanny AUDOUIS et de Violaine LE NENON </author>
 <publisher> Direction des Archives de France</publisher>
 <date> août 2003</date>
 </titlepage>
 <div>
 <head>Introduction</head>
 <p> Paru en 1973, l'état sommaire des fonds de la série AP (archives de personnes et de familles) rédigé par Suzanne d'Huart et Chantal Bonazzi traitait des fonds privés IAP à 315AP. Depuis, plus de 300 nouveaux fonds d'archives privées sont entrés aux Archives nationales. [...] Ces notices sont également consultables dans la base <extref href="http://dx.archivesdefrance.culture.gouv.fr/ap">BORA</extref></p>
 </div>
 <div>
 <head>Mode d'emploi</head>
 <p> [...]</p>
 </div>
 [...]
</frontmatter>
```

CM2-3-4 : eXtensible Markup Language – Yannick Prié UE2.2 – Master SIB M1 – 2008-2009 : Représentation des données et des connaissances

98

## Description archivistique <archdesc>

```
<archdesc level="niveau de description"> (nota : L'attribut level est obligatoire)
 <did> Identification et Description </did>
 <accessrestrict> et <userestrict> Conditions d'accès et Conditions d'utilisation
 <acquired> Acquissements
 <scoping> Informations sur les modalités d'entrée
 <altformavail> Documents de substitution
 <appraisal> Informations sur l'évaluation
 <arrangement> Classement
 <bibliography> Bibliographie
 <bioghist> Biographie ou Histoire (du producteur)
 <controlaccess> Vedettes et accès contrôlés </controlaccess>
 <custodial> Historique de la conservation
 <dao> et <daogrp> Objet archivistique numérique
 <note> Note
 <odd> Autres données descriptives
 <originalsloc> Existence et lieu de conservation des documents originaux
 <otherfindaid> Autre instrument de recherche
 <physdesc> Caractéristiques matérielles et contraintes techniques
 <pretercite> Mention conseillée
 <processinfo> Informations sur le traitement
 <relatedmaterial> et <separatedmaterial> Documents en relation et documents séparés
 <scopecontent> Présentation du contenu
 <desc> Description des sous-composants </desc>
</archdesc>
```

CM2-3-4 : eXtensible Markup Language – Yannick Prié UE2.2 – Master SIB M1 – 2008-2009 : Représentation des données et des connaissances

99

## Les sous-éléments de <did> Identification et description

- <head> Titre
- <repository> Organisme responsable de l'accès intellectuel
- <origination> Origine
- <unittitle> Intitulé de l'unité documentaire
- <unitdate> Date de l'unité documentaire
- <unitid> Identifiant de l'unité documentaire
- <physdesc> Description physique
- <physloc> Localisation physique
- <container> Unité de conditionnement
- <note> Note
- <dao> Objet archivistique numérique
- <daogrp> Groupe d'objets archivistiques numériques
- <abstract> Résumé
- <langmaterial> Langue des unités documentaires
- <materialspec> Particularités matérielles

CM2-3-4 : eXtensible Markup Language – Yannick Prié UE2.2 – Master SIB M1 – 2008-2009 : Représentation des données et des connaissances

100

## Exemple d'utilisation de <did>

```
<archdesc level="fonds">
 <did>
 <unitid>320 AP</unitid>
 <unittitle>Fonds Bazaine</unittitle>
 <unitdate normal="1801/1900">XIX</unitdate>
 render="super" >e</render>
 <origination>Bazaine, Achille</origination>
 <physdesc> 7 cartons (320AP/1 à 320AP/7), 0,75 mètres linéaires</physdesc>
 </did>
 <!-- Etc. : les autres sous-éléments de archdesc -->
```

CM2-3-4 : eXtensible Markup Language – Yannick Prié UE2.2 – Master SIB M1 – 2008-2009 : Représentation des données et des connaissances

101

## <archdesc> : exemple de description globale d'un fonds

```
<archdesc level="fonds">
 <did>
 <repository>Centre historique des Archives nationales (France)</repository>
 <origination>Ce fonds a été produit par <persname>Henry-Louis Duhamel du Monceau</persname>, par son frère <persname>Duhamel de Denainvillers</persname>, par leur neveu <persname>Auguste Louis Fougeroux de Bondaroy </persname> et par le frère de ce dernier <persname>Fougeroux de Secval</persname>
 <unittitle>Fonds Duhamel du Monceau, Duhamel de Denainvillers, Fougeroux de Bondaroy et Fougeroux de Secval</unittitle>
 <unitid>127AP</unitid>
 <physdesc> <extent>8 cartons</extent> (127AP/1 à 127AP/7, 127AP/20), <extent>1 mètre linéaire</extent>
 <langmaterial> <language langcode="fr">français</language>
 </did>
 <scoping> <p> achats, 7 juin 1957, 24 mars 1960, 16 juin 1977, 11 décembre 1991 </p>
 <bioghist>
 <p> Henry-Louis Duhamel du Monceau (1700-1782) fit des études scientifiques au jardin du Roy, actuel jardin des plantes, en 1724. Associé-botaniste à l'Académie des sciences en 1739, inspecteur général de la Marine en 1739, membre de l'Académie des sciences de Paris et de la Société royale de Londres, Duhamel du Monceau écrivit en 1745 un Essai sur la conservation des grains et en 1747, un Traité de la fabrique des manœuvres pour les vaisseaux ou fait de la cordee perfectionnée. On lui doit aussi [...] </p>
 </bioghist>
 <custodial>
 <p> Commencé vers 1720 par Le Masson du Parc, commissaire ordinaire de la Marine et inspecteur général des pêches, le Traité général des pêches s'inscrivait dans le monumental projet éditorial entrepris par l'Académie des sciences sous l'impulsion de Colbert puis du Régent. La Description des Arts et Métiers. Après la mort de Le Masson du Parc, survenue en 1741, le projet fut repris par Henry-Louis Duhamel du Monceau, alors inspecteur général de la Marine, qui s'attacha personnellement à cette entreprise. Aidé de ses neveux Fougeroux, Duhamel du Monceau en poursuivit la réalisation pendant une trentaine d'années, mais n'en publia qu'une petite partie (Traité général des pêches et histoire des poissons) : sa mort l'empêcha de la mener à son terme. Le Masson du Parc avait rassemblé une importante documentation [...] </p>
 </custodial>
 <accessrestrict> <p> Il n'y a pas de restriction juridique à la consultation de ces documents, qui se fait selon les modalités matérielles en vigueur dans le service d'archives </p>
 <scopecontent> <p> Documentation scientifique plus que fonds d'archives personnelles, cette sous-série rassemble des documents réunis tout au long du XVIIIe siècle sur deux thèmes principaux : la pêche et l'agriculture </p>
 <otherfindaid> <p> Répertoire numérique détaillé dactylographié (127AP/1 à 127AP/7), par B. Gille, 1957, 19 pages. Inventaire semi-analytique dactylographié (127AP/8 à 127AP/19), 7 pages. Supplément dactylographié (127AP/20) </p>
</archdesc>
```

CM2-3-4 : eXtensible Markup Language – Yannick Prié UE2.2 – Master SIB M1 – 2008-2009 : Représentation des données et des connaissances

## TEI

- Text Encoding Initiative
- Lancé en 1987
  - incompatibilité totale des formats
  - chercheurs du domaine de l'archivage structuration et analyse des textes électroniques
  - pour permettre la préparation et l'échange de textes électroniques
- Principes
  - – être aussi complet que possible,
  - – être simple, clair et concret,
  - – être facile à utiliser sans logiciel particulier,
  - – être rigoureusement défini,
  - – permettre un traitement efficace,
  - – être ouvert à des extensions définies par les utilisateurs,
  - être compatible avec les standards existants ou en développement.

## TEI : suite de l'histoire

- Financé sur des programmes « Humanités »
- Sortie de la norme (Recommandation) en mai 1994
- Ensemble de conventions de codage utilisables dans une grande variété d'applications
  - publication électronique, analyse littéraire et historique, lexicographie, traitement automatique des langues, recherche documentaire, hypertexte, etc.
  - Textes écrits ou parlés, sans restriction de langue, de période, de genre ou de contenu
- Répondent aux besoins fondamentaux de nombreux utilisateurs
  - lexicographes, linguistes, philologues, bibliothécaires  
→ tous ceux qui sont concernés par l'archivage et l'accès à des documents électroniques.

## TEI : codage

- Construction de la DTD de façon modulaire :
  - jeu de balises « noyau » (*core tag set*) composé d'éléments communs à tous les types de textes (divisions, paragraphes, etc.)
  - des ensembles de balises de base (*base tag sets*) pour chaque type particulier de texte (prose, poésie en vers, etc.)
  - des jeux de balises additionnelles (*additional tag sets*) pour des mécanismes particuliers qui peuvent se superposer à n'importe quel type de texte (liens hypertextuels, etc.).
- Noyau obligatoire, autres éléments facultatifs
- Importance de l'en-tête
  - codage systématique des méta-données de n'importe quel document électronique

## TEI : où en est on ?

- Au départ : SGML, puis XML
- Utilisation dans de très nombreux projets
- Reste la question du codage
  - pour qui code-t-on ?
  - un chercheur peut-il réutiliser le codage d'un autre ? Ajouter au codage d'un autre ?
  - possibilité de mixer avec d'autres formats ? (particulièrement docbook)
  - multiplier les éléments / aux besoins
    - ou bien limiter volontairement le nombre d'éléments
  - etc.