par Philippe Poulard

Technologies de Schemas XML

Philippe.Poulard@sophia.inria.fr

© Philippe Poulard

Qu'est-ce qu'un schéma ?

Document Type Definition

Modèles de contenus
Déclarations d'attributs
Entités générales / paramètres, internes / externes
Appels de DTD
Identificateurs et catalogues
Documents bien formés, réglages de l'analyse
Conception des DTD : best practice

W3C XML Schema (Présentation)

Types de données
Structures
Modèles de contenus
Attributs
Autres structures

Relax NG (Présentation)

Structures
Modèles de contenus
Attributs
Autres structures
Typage avec WXS

PSVI et validation

PSVI
Choisir une techno, incomplétude de la validation
Schematron

Les DTD appartiennent à une classe fonctionnelle de documents : les schémas

Les schémas décrivent la grammaire utilisable dans un document XML

<table>
<tr><td>Document Type Definition DTD</td><td>syntaxe non XML</td><td rowspan="2">W3C</td></tr>
<tr><td>W3C XML Schema WXS</td><td rowspan="2">syntaxe XML</td></tr>
<tr><td>Relax-NG</td><td>OASIS</td></tr>
</table>

D'autres propositions ont été faites, les offres ne manquent pas…

Microsoft XDR (XML-Data Reduced) est une implémentation basée sur les travaux d'origine du W3C (XML-Data Note et Document Content Description (DCD) initiative for XML)

Document Type Definition

DTD XML

Document Type Definition

DTD : description formelle de la structure du document
Une DTD peut être :
- locale au document (sous-ensemble interne),
- importée dans le document (sous-ensemble externe)
- ou les deux

Permet de contraindre les données d'un document
Fait partie du standard XML, ne surcharge pas les applications

Une DTD contient (entre autres) :
- La définition des éléments-type
- Leurs listes d'attributs
- La définition des entités ➔ assimilable à des macros-textes

La DTD est facultative
Mais :
- Un document qui déclare une DTD doit s'y conformer ⇦ Validation
- Dans un contexte professionnel, on ne peut pas s'en passer

Pour « bricoler », on peut s'en passer

Intérêt d'une DTD externe : permet d'être réutilisée par d'autres documents

Utilisation optimale :
- sous-ensemble externe : pour la classe de document
- sous-ensemble interne : pour des particularités propres au document

Déclaration d'éléments DTD XML

Un élément peut se contenir

Syntaxe

```
<!ELEMENT nom-element (modèle-de-contenu)>
```

Modèles de contenu :

Séquence :

- indique quel(s) élément(s) compose(nt) le modèle
- liste d'éléments séparés par une virgule
- **tous les éléments devront apparaître dans l'ordre prévu**

Pour spécifier qu'un `Auteur` doit avoir un `Nom` puis un `Prénom` :

Exemple

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

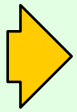

```
<Auteur>
    <Nom>Poulard</Nom>
    <Prénom>Philippe</Prénom>
</Auteur>
```

Element ne contenant que des données textuelles parsées (Parsed Caracter Data)

Syntaxe

```
<!ELEMENT nom-element (#PCDATA)>
```

Exemple

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

Element vide

Syntaxe

```
<!ELEMENT nom-element EMPTY>
```

Exemples

```
<!ELEMENT br EMPTY>
```

```
<!ELEMENT img EMPTY>
```

```
<br>      </br>
<br><!---></br>
<br><?br?></br>
```

Non

```
<br></br>
<br/>
```

Oui

Déclaration d'éléments DTD XML

Modèles de contenu :

Choix :

- indique quel(s) élément(s) compose(nt) le modèle
- liste d'éléments séparés par une barre verticale
- **un seul élément de la liste devra apparaître**

Pour spécifier qu'un Menu peut contenir un Fromage ou un Dessert, mais pas les deux :

Exemple

```
<!ELEMENT Menu (Fromage | Dessert)>
```

```
<Menu>
    <Fromage>Camembert</Fromage>
</Menu>
```

Modèle de contenu universel :

Permet à un sous-élément de contenir n'importe quoi (éléments et contenu)
Les éléments qu'il peut contenir doivent être déclarés

Syntaxe

```
<!ELEMENT nom-element ANY>
```

Très peu utilisé, très peu pratique

Modèles de contenu combinés :

Choix et séquences peuvent être combinés à volonté
Les regroupements se font avec des parenthèses

Pour spécifier qu'un Menu est un peu plus compliqué…

Exemple

```
<!ELEMENT Menu (Entrée, Plat, (Fromage | Dessert))>
```

Déclaration d'éléments DTD XML

Fréquence d'apparition d'un sous-élément

Un suffixe indique le nombre d'instance attendues
Peut s'appliquer à un élément seul ou à un groupe d'éléments

Suffixe	Cardinalité	
	(1,1)	Obligatoire (par défaut) : doit apparaître une et une seule fois
?	(0,1)	Optionnel : doit apparaître zéro ou une seule fois
*	(0,n)	Multiple : peut apparaître plusieurs fois ou ne pas apparaître
+	(1,n)	Multiple obligatoire : doit apparaître au moins une fois

Exemples

```
<!ELEMENT Menu (Entrée?, Plat, (Fromage* | Dessert)>
```

```
<!ELEMENT Section (Titre, ((Contenu, Section*) | Section+))>
```

Représentation graphique

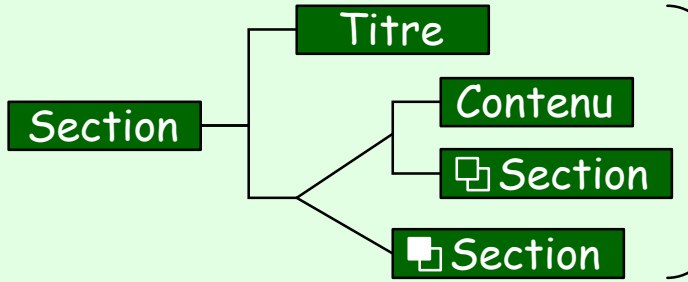

Élément avec contenu mixte dans les DTD


```
<!ELEMENT foo (#PCDATA , bar?)>
```

Non

```
<!ELEMENT foo (#PCDATA | bar)*>
```

Oui

```
<foo>Il y a à la fois du contenu <bar>et un élément</bar>.</foo>
```

Dans tout model contenant #PCDATA et d'autres éléments :

- ce doit être un groupement simple séparé par "|"
- #PCDATA doit apparaître en premier
- le groupe doit être optionnel et répétable (*)

Solution alternative :

```
<!ELEMENT text (#PCDATA)>
<!ELEMENT foo (text | bar?)>
```

Eviter de définir des structures avec du contenu mixte
➔ difficilement réalisable dans les structures documentaires

Déclaration d'attributs DTD XML

Syntaxe

```
<!ATTLIST nom-element
                    nom-attribut type défaut
                    nom-attribut type défaut
                    nom-attribut type défaut
>
```

Déclaration pour chaque attribut

…qui peut être faite séparément

Une déclaration d'attribut est réalisée au profit d'un élément
Tous les attributs d'un élément doivent être déclarés
(y compris les attributs spéciaux `xmlns`, `xml:space` et `xml:lang`)
On ne peut pas spécifier l'ordre d'apparition des attributs dans un élément

Type Défaut

Type caracter data (CDATA)

Présence de l'attribut obligatoire

Exemple

```
<!ATTLIST image     source    CDATA #REQUIRED
                    hauteur   CDATA #REQUIRED
                    largeur   CDATA #REQUIRED
                    texte     CDATA #IMPLIED
>
```

```
<image     source="bubulle.jpg"
           largeur="10cm"
           hauteur="5cm"
           texte="mon poisson rouge"/>
```

Types d'attributs possibles :

- CDATA
- NOTATION
- Enumération
- NMTOKEN
- NMTOKENS
- ENTITY
- ENTITIES
- ID
- IDREF
- IDREFS

Les valeurs des attributs peuvent contenir des appels d'entités
Les retours chariots contenus dans les valeurs d'attributs ne sont pas significatifs
CDATA est le type le plus général, la valeur de l'attribut peut contenir n'importe quelle chaîne de caractères

Types d'attributs DTD XML

- CDATA
- NOTATION
- Enumération
- NMTOKEN
- NMTOKENS
- ENTITY
- ENTITIES
- ID
- IDREF
- IDREFS

La valeur d'un attribut de type NMTOKEN doit contenir des caractères d'**unité lexicale nominale**

- Caractères alphabétiques accentués
- Chiffres
- Caractères _ - . :
- Caractères des autres langues non romanes

Exemple

```
<!ATTLIST user      insee     NMTOKEN   #REQUIRED>
```

```
<user insee="1-69-06-13-001-084"/>
```

La valeur d'un attribut de type NMTOKENS contient une ou plusieurs **unités lexicales XML** séparées par des blancs

Exemple

```
<!ATTLIST article   nno       NMTOKENS #REQUIRED>
```

```
<article nno="1234 14 1234567"/>
```

Types d'attributs DTD XML

- CDATA
- NOTATION
- Enumération
- NMTOKEN
- NMTOKENS
- ENTITY
- ENTITIES
- ID
- IDREF
- IDREFS

Les valeurs possibles que peut prendre un attribut peuvent être énumérées

Syntaxe

```
<!ATTLIST nom-element nom-attribut (val1 | val2 | val3 … | valn) defaut>
```

Exemples

```
<form method="post"/>
```

Défaut

```
<!ATTLIST form      method    ( get | post )                              'get'>
```

```
<!ATTLIST date      mois      ( janvier | février | mars | avril | mai
                              | juin | juillet | août | septembre
                              | octobre | novembre | decembre      )     #REQUIRED
>
```

```
<date mois="juin"/>
```

Chaque valeur de la liste doit être une unité lexicale nominale

(➔ aucune valeur ne peut contenir de caractères blancs)

Types d'attributs DTD XML

- CDATA
- NOTATION
- Enumération
- NMTOKEN
- NMTOKENS
- ENTITY
- ENTITIES
- ID
- IDREF
- IDREFS

La valeur d'un attribut de type ID doit être un **nom XML**, unique dans le document (2 attributs de type ID ne peuvent pas avoir la même valeur)

- Un élément ne peut définir qu'un seul attribut de type ID
- Un attribut dont le nom est id n'est pas nécessairement de type ID
- Le nommage d'un attribut de type ID n'est pas plus contraint que les autres attributs

```
<!ATTLIST a id   ID      #IMPLIED
            name ID      #IMPLIED >
```

Non

```
<!ATTLIST a id   ID      #IMPLIED
            name NMTOKEN #IMPLIED >
```

Oui

- Un attribut de type IDREF contient la valeur d'un attribut de type ID
- Un attribut de type IDREFS en contient une ou plusieurs séparées par des blancs

```
<a href="fichier1.htm" id="link">fichier 1</a>
<a href="fichier2.htm" id="link">fichier 2</a>
```

Non

```
<a href="fichier1.htm" id="link1">fichier 1</a>
<a href="fichier2.htm" id="link2">fichier 2</a>
```

Oui

```
<!ELEMENT user (#PCDATA)>
<!ATTLIST user    id      ID      #REQUIRED>

<!ELEMENT project (#PCDATA)>
<!ATTLIST project users   IDREFS #REQUIRED>
```

```
<user id="u1"/>Jean</user>
<user id="u2"/>Paul</user>
<user id="u3"/>Marc</user>
<project users="u1 u2">Foo<project>
<project users="u2 u3">Bar<project>
<project users="u1 u2 u3">Any<project>
```

Types d'attributs DTD XML

- CDATA
- NOTATION
- Enumération
- NMTOKEN
- NMTOKENS
- ENTITY
- ENTITIES
- ID
- IDREF
- IDREFS

La valeur d'un attribut de type NOTATION est le nom d'une des notations déclarées dans la DTD et énumérées pour l'attribut

Exemple

```
<!NOTATION jpeg     SYSTEM "image/jpeg">
<!NOTATION gif      SYSTEM "image/gif">
<!NOTATION png      SYSTEM "image/png">
<!ATTLIST  image    source    CDATA #REQUIRED
                    hauteur   CDATA #REQUIRED
                    largeur   CDATA #REQUIRED
                    texte     CDATA #IMPLIED
                    type      NOTATION (gif | jpeg | png) #REQUIRED
>
```

```
<image    source="photo.jpg"
          largeur="10cm"
          hauteur="5cm"
          texte="mon poisson rouge"
          type="jpeg"/>
```

…d'un usage très limité (héritage de SGML)

Types d'attributs DTD XML

- CDATA
- NOTATION
- Enumération
- NMTOKEN
- NMTOKENS
- ENTITY
- ENTITIES
- ID
- IDREF
- IDREFS

La valeur d'un attribut de type ENTITY est le nom d'une entité non parsée déclarée dans la DTD

Exemple

```
<!NOTATION jpeg     SYSTEM "image/jpeg">
<!ENTITY   photo    SYSTEM "photo.jpg" NDATA jpeg>
<!ATTLIST  image    source     ENTITY #REQUIRED
                    hauteur    CDATA  #REQUIRED
                    largeur    CDATA  #REQUIRED
                    texte      CDATA  #IMPLIED
>
```

```
<image    source="photo"
          largeur="10cm"
          hauteur="5cm"
          texte="mon poisson rouge"/>
```

C'est un moyen intégré au standard qui permet d'indiquer à une application que d'autres fichiers (images…) font partie du document.

Utilisé par des éditeurs (EPIC)

- Un attribut de type ENTITIES contient un ou plusieurs noms d'entités séparés par des blancs

Exemple

```
<!ATTLIST  diaporama          diapos    ENTITIES #REQUIRED>
```

```
<diaporama diapos="intro objectifs résultats analyse outro"/>
```

Attribut par défaut DTD XML

#IMPLIED — Attribut optionnel

#REQUIRED — Attribut obligatoire

```
<!ATTLIST image     source    CDATA              #REQUIRED
                    hauteur   CDATA              #REQUIRED
                    largeur   CDATA              #REQUIRED
                    texte     CDATA              #IMPLIED
>
```

Littéral — Valeur par défaut en tant que chaîne entre quotes (simples / doubles)
L'application doit considérer l'attribut renseigné avec cette valeur s'il n'est pas noté dans le document

```
<!ATTLIST form      method    ( get | post )     'get'>
```

#FIXED — Valeur fixe et non modifiable
Bien que l'attribut puisse ne pas être explicitement noté dans le document, l'application doit considérer l'attribut comme renseigné

```
<!ATTLIST svg   xmlns       CDATA #FIXED "http://www.w3.org/2000/svg">
```

```
<!ATTLIST livre xmlns:xlink CDATA #FIXED "http://www.w3.org/1999/xlink">
```

Entités dans les DTD XML

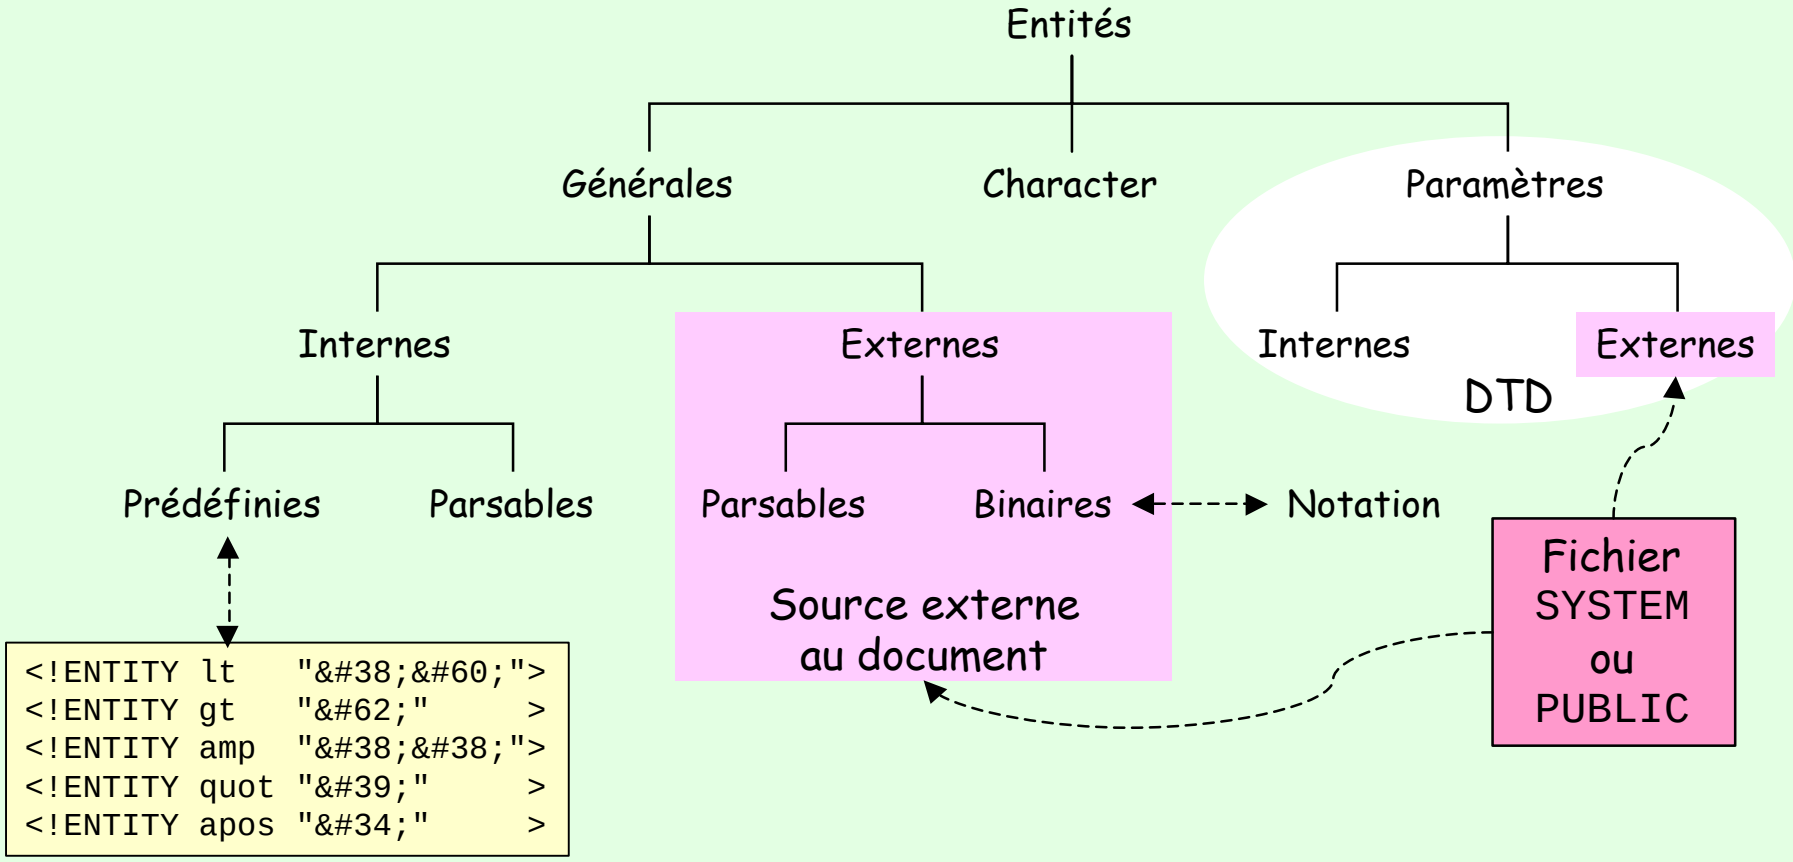


```
<!ENTITY lt    "&#38;&#60;">
<!ENTITY gt    "&#62;"     >
<!ENTITY amp   "&#38;&#38;">
<!ENTITY quot  "&#39;"     >
<!ENTITY apos  "&#34;"     >
```

Le contenu de remplacement d'une entité parsée est du texte
Une entité interne DOIT être une entité parsable

Qui peut contenir des sections CDATA
(<![CDATA[ ]]>), donc non parsée

L'instance XML est aussi appelée **l'entité document**

Entités générales internes dans les DTD XML

Déclaration

- dans la DTD

```
<!ENTITY version "2.1">
```

Caractères interdits :
% & "
(ils doivent être échappés par des appels de caractères)

Appel

```
<pub>
Commandez la dernière version (&version;)
</pub>
```

Rendu

Commandez la dernière version (2.1)

Déclaration avec éléments (biens formés)

```
<!ENTITY flipper
          "<dauphin photo='flipper.jpg'>
                    <nom>Flipper</nom>
                    <age>12</age>
           </dauphin>">
```

Appel dans la DTD

```
<!ENTITY release "1">
<!ENTITY version "2.&release;">
```

Restrictions:

- pas de référence circulaire

```
<!ENTITY a "&b;">
<!ENTITY b "&a;">
```

Non

- pas de possibilité d'insérer du contenu qui fait partie de la DTD (les entités paramètres servent à ça)

```
<!ENTITY a "#PCDATA">
<!ENTITY b &a;>
```

Non

Entités générales externes parsables dans les DTD

Les résolutions d'entités sont effectuées au moment de leur appel

Externes = dans un autre fichier que le document

Les entités externes sont référencées par un **identificateur** :

- SYSTEM : URI vers le nom du fichier
- PUBLIC : référence dans un catalogue connu du parseur
- ou les 2

Les **identificateurs** ne sont pas parsés

```
<!ENTITY acme SYSTEM "http://www.acme.com/entities/MyEntity.xml">
```

```
<!ENTITY acme PUBLIC "-//ACME//My entity//EN">
```

```
<!ENTITY acme PUBLIC "-//ACME//My entity//EN"
                     "http://www.acme.com/entities/MyEntity.xml">
```

L'appel d'une entité externe parsée ne peut se faire que dans le contenu d'un élément

```
<foo bar="&acme;"/>
```

Non

```
<foo>&acme;</foo>
```

Oui

MyEntity.xml

```
<truc>
Du contenu avec <machin chose="des
balise">et des attributs</machin>
</truc>
```

Les parseurs validants DOIVENT remplacer les appels d'entité par leur contenu
Les parseurs non validants peuvent ne pas rapatrier les entités externes parsées

Entités externes parsables dans les DTD

L'entité externe peut ne pas être un document XML bien formé (en particulier, il n'est pas nécessaire qu'il ait un seul élément racine), du moment que le document qui l'appelle soit lui, un document bien formé.

Tout élément ouvert dans l'entité externe doit se fermer dans cette même entité.

Declaration de texte

Une entité externe n'a ni prologue ni déclaration de DTD
Toutefois, une entité externe peut contenir une déclaration de texte

```
<?xml encoding="ISO-8859-1"?>
```

ou

```
<?xml version="1.0" encoding="ISO-8859-1"?>
```

Chaque entité peut avoir son propre encodage différent de l'entité document maître.

Entités externes parsables dans les DTD

Une entité externe n'a pas de DTD, mais peut être l'unique contenu d'un document qui peut avoir sa DTD (qui correspond à l'entité seulement)

```
<?xml encoding="ISO-8859-1"?>
<!DOCTYPE foo SYSTEM foo.dtd [
<!ENTITY bar SYSTEM bar.xml>
]>
<foo>Document complet avec
des appels à plusieurs structures
importées
&bar;
</foo>
```

1-Ce fichier incorpore une entité externe

bar.xml

```
<?xml encoding="ISO-8859-1"?>
<bar>Contenu contraint par une DTD
</bar>
```

2-Ce fichier n'a pas de DTD car il est incorporé dans un document qui est déjà doté de sa DTD

```
<?xml encoding="ISO-8859-1"?>
<!DOCTYPE bar SYSTEM bar.dtd[
<!ENTITY bar SYSTEM bar.xml>
]>
&bar;
```

3-L'entité externe peut être contrainte par un fichier maître qui l'appelle : l'entité bar.xml peut ainsi avoir sa propre DTD

Une meilleure méthode : XInclude (Working draft) : `http://www.w3.org/TR/xinclude/`

Entités externes binaires dans les DTD

Déclaration dans la DTD

```
<!NOTATION jpeg     SYSTEM "image/jpeg">
<!ENTITY   photo    SYSTEM "photo.jpg" NDATA jpeg>
<!ATTLIST  image    source    ENTITY #REQUIRED
                    hauteur   CDATA  #REQUIRED
                    largeur   CDATA  #REQUIRED
                    texte     CDATA  #IMPLIED
>
```

C'est un moyen intégré au standard qui permet d'indiquer à une application que d'autres fichiers (images…) font partie du document.

↓

Utilisé par des éditeurs (EPIC)

Appel dans le document

```
<image    source="photo"
          largeur="10cm"
          hauteur="5cm"
          texte="mon poisson rouge"/>
```

Notations dans les DTD


```
<!NOTATION jpeg     SYSTEM "image/jpeg">
<!ATTLIST  image    source    ENTITY #REQUIRED
                    hauteur   CDATA  #REQUIRED
                    largeur   CDATA  #REQUIRED
                    texte     CDATA  #IMPLIED
>
<!ENTITY   photo    SYSTEM "photo.jpg" NDATA jpeg>
```

devrait être défini dans le sous-ensemble interne de la DTD (l'image fait partie du document)

Dépendance applicative

```
<!NOTATION jpeg SYSTEM "apps/imgviewer.exe">
```

À éviter : dépendance vis à vis d'une application donnée sur un système donné

Formel

```
<!NOTATION jpeg PUBLIC "ISO/IEC 10918:1993//NOTATION
                        Digital Compression and Coding of
                        Continuous-tone Still Images
                        (JPEG)//EN" >
```

☹

MIME

```
<!NOTATION jpeg SYSTEM "image/jpeg">
```

À la mode…

Entités paramètres dans les DTD

Déclaration : `<!ENTITY % foo "bar">` Appel : `%foo;`

Différence avec les entités générales :

- Appel avec le signe % au lieu de &
- Appel uniquement dans la DTD et jamais dans le document
- Permet de **factoriser** les définitions d'élément

Contraintes :

- Une entité paramètre doit toujours être déclarée **avant** d'être appelée
- Une entité paramètre peut être appelée pour **compléter** une déclaration uniquement dans le sous-ensemble externe

```
<?xml version="1.0" encoding="ISO-8859-1" ?>
<!DOCTYPE zoo SYSTEM "zoo.dtd">
```

zoo.dtd

```
<!ENTITY % animal "nom, sexe, taille, poids, date-naissance, commentaire?">
<!ELEMENT dauphin (%animal;)>
```

Oui

```
<?xml version="1.0" encoding="ISO-8859-1" ?>
<!DOCTYPE zoo [
<!ENTITY % animal "nom, sexe, taille, poids, date-naissance, commentaire?">
<!ELEMENT dauphin (%animal;)>
]>
```

Non

```
<?xml version="1.0" encoding="ISO-8859-1" ?>
<!DOCTYPE zoo [
<!ENTITY % HR "<!ELEMENT hr EMPTY>">
%HR;
]>
```

Déclaration et appel corrects dans le sous-ensemble interne et dans le sous-ensemble externe

Entités paramètres dans les DTD


```
<!ELEMENT dauphin (nom, sexe, taille, poids, date-naissance, commentaire?)>
<!ATTLIST dauphin
          id                    ID #REQUIRED
          espèce                CDATA #IMPLIED
          nom-savant            CDATA #IMPLIED
          photo                 ENTITY #IMPLIED
>
<!ELEMENT baleine (nom, sexe, taille, poids, date-naissance, commentaire?)>
<!ATTLIST baleine
          id                    ID #REQUIRED
          espèce                CDATA #IMPLIED
          nom-savant            CDATA #IMPLIED
          photo                 ENTITY #IMPLIED
>
```

```
<!ENTITY % animal "nom, sexe, taille, poids, date-naissance, commentaire?">
<!ENTITY % animal-attr "
          id                    ID #REQUIRED
          espèce                CDATA #IMPLIED
          nom-savant            CDATA #IMPLIED
          photo                 ENTITY #IMPLIED
">
<!ELEMENT dauphin (%animal;)>
<!ATTLIST dauphin %animal-attr;>
<!ELEMENT baleine (%animal;)>
<!ATTLIST baleine %animal-attr;>
```

Après substitution d'une entité paramètre par sa valeur, les parseurs peuvent insérer un espace avant et après, sauf si l'entité est contenue dans une chaîne

Sections conditionnelles dans les DTD


```
<![IGNORE[
          <!ELEMENT annotation (#PCDATA)>
          <!ELEMENT p (b | i | annotation)*>
]]>
<![INCLUDE[
          <!ELEMENT p (b | i)*>
]]>
```

Ces déclarations ne sont pas interprétées

Cette déclaration est interprétée

Une section conditionnelle ne peut pas être utilisée pour **compléter** une déclaration

```
<!ELEMENT p (b | i <![INCLUDE[ | annotation]]>)*>
```

Non

Imbrications de blocs conditionnels :

```
<![IGNORE[
          <![IGNORE[
          ]]>
                    …/…
          <![INCLUDE[
                    …/…
          ]]>
]]>
<![INCLUDE[
          <![IGNORE[
                    …/…
          ]]>
          <![INCLUDE[
                    …/…
          ]]>
]]>
```

Tout le bloc est ignoré, même le sous-bloc INCLUDE

Ce bloc est ignoré, bien qu'il soit dans un bloc INCLUDE

Entités paramètres dans les DTD

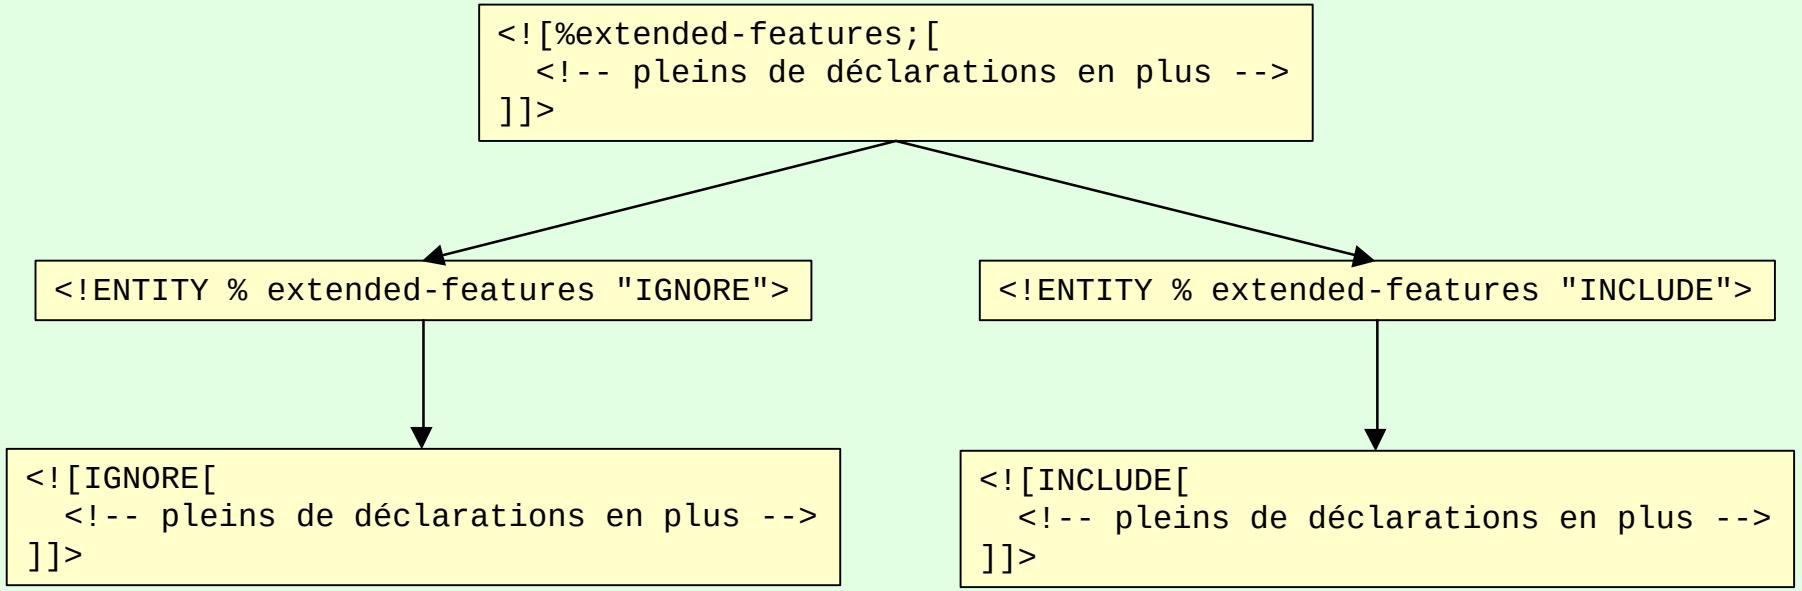


```
<!ENTITY % full-dtd "IGNORE">
<!ENTITY % light-dtd "INCLUDE">
<![%full-dtd;[
          <!ELEMENT annotation (#PCDATA)>
          <!ENTITY % inline "b | i | annotation">
]]>
<![light-dtd;[
          <!ENTITY % inline "b | i">
]]>
<!ELEMENT p (%inline;)*>
```

Appel d'un DTD dans un document XML


```
<!DOCTYPE acme SYSTEM "http://www.acme.com/entities/MyDTD.dtd">
```

```
<!DOCTYPE acme PUBLIC "-//ACME//My DTD//EN"
                      "http://www.acme.com/entities/MyDTD.dtd">
```

Une seule déclaration par document
Pour utiliser plusieurs DTD, faire des appels d'entités

Nom de l'élément racine du document

Les outils tentent de résoudre les identificateurs PUBLIC
- En accédant à un catalogue
- En utilisant un programme spécifique (EntityResolver)

S'ils n'y arrivent pas, ils accèdent au fichier SYSTEM

Les DTD peuvent être :
- externes
- internes
- ou les 2 : dans ce cas, le sous-ensemble interne est lu en premier

```
<?xml version="1.0" encoding="ISO-8859-1" ?>
<!DOCTYPE foo SYSTEM "foo.dtd" [
          <!ENTITY % FOO "INCLUDE">
          <!ENTITY bar.jpg SYSTEM "bar.jpg" NDATA jpg>
]>
<foo>
          …/…
</foo>
```

Peut utiliser des paramètres du sous-ensemble interne

Déclarations lues en premier

L'identificateur système

S'utilise pour les appels de DTD et les déclarations d'entités externes

Peut être une adresse absolue :

```
<!DOCTYPE acme SYSTEM "http://www.acme.com/entities/MyDTD.dtd">
```

Peut être une adresse relative :

```
<!DOCTYPE acme SYSTEM "/entities/MyDTD.dtd">
```

```
<!DOCTYPE acme SYSTEM "../../MyDTD.dtd">
```

Les appels en cascade sont résolus relativement à l'objet appelant :

foo.xml

```
<!ENTITY foo-1 SYSTEM "foo/foo1.xml">
```

foo1.xml

```
<!ENTITY foo-2 SYSTEM "bar/foo2.xml">
```

foo2.xml

```
<foo>bar</foo>
```

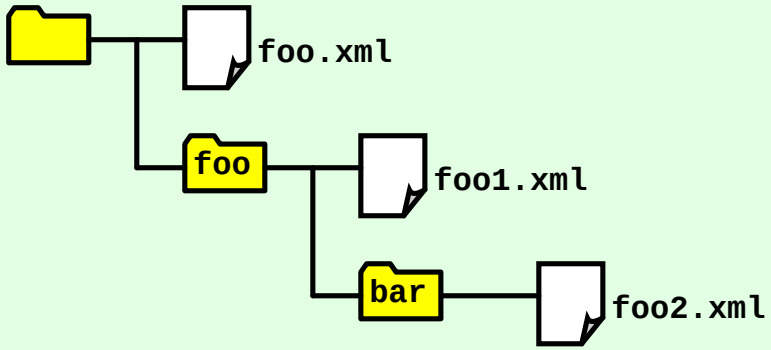

Pas de boucle infinie :

foo.xml

```
<!ENTITY bar SYSTEM "bar.xml">
```

bar.xml

```
<!ENTITY foo SYSTEM "foo.xml">
```

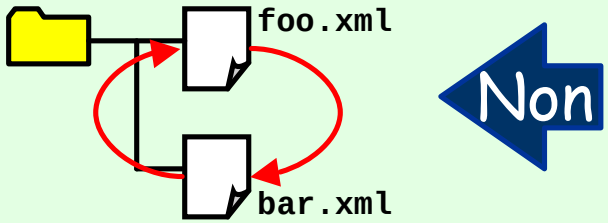

L'identificateur public

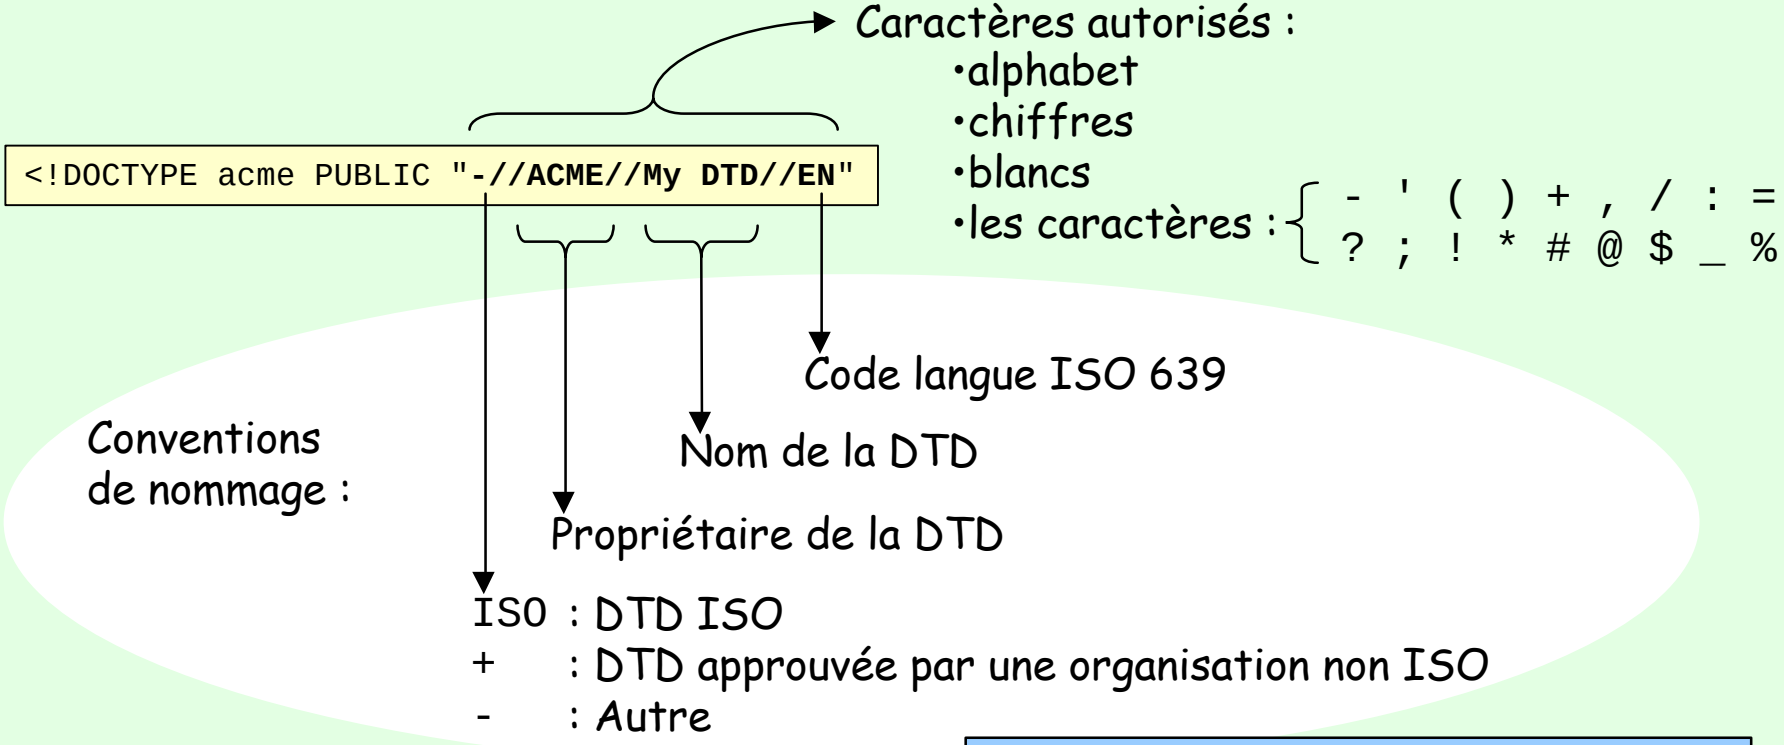

Comment trouver le catalogue ?

- Ça dépend du logiciel qui l'utilise

En utilisant une variable système

```
SGML_CATALOG_FILES=C:\sgml\CATALOG
```

Quels logiciels utilisent un catalogue?
BALISE
EPIC
NEAR&FAR
SP
...

En spécifiant le chemin dans le fichier de configuration du logiciel
En utilisant une classe `EntityResolver`

C'est un résidu de SGML, qu'il est souvent inutile de trimbaler, surtout si l'outil ne le prend pas en compte

Contenu d'un catalogue PUBLIC


```
PUBLIC "ISO 8879-1986//ENTITIES Added Latin 1//EN" "c:\sgml\ISO\ISOLat1.ent"
PUBLIC "ISO 8879-1986//ENTITIES Added Latin 2//EN" "c:\sgml\ISO\ISOLat2.ent"
PUBLIC "ISO 8879-1986//ENTITIES Russian Cyrillic//EN" "c:\sgml\ISO\ISOcyr1.ent"
PUBLIC "ISO 8879-1986//ENTITIES Non-Russian Cyrillic //EN" "c:\sgml\ISO\ISOcyr2.ent"
PUBLIC "ISO 8879-1986//ENTITIES Numeric and Special Graphic//EN" "c:\sgml\ISO\ISOnum.ent"
PUBLIC "ISO 8879:1986//ENTITIES Publishing//EN" "c:\sgml\ISO\ISOpub.ent"
PUBLIC "-//TEI//DTD TEI Level 2//EN//2.0" "c:\sgml\tei\tei2.dtd"
PUBLIC '-//TEI P2: 1993//NOTATION WSD for ISO 8859-2//EN' 'C:\SGML\ISO\ISO88592.wsd'
PUBLIC "-//TEI P2: 1993//NOTATION WSD for ISO 8859-1:1986//EN" 'C:\SGML\ISO\iso88591.wsd'
PUBLIC "-//TEI P2 1994//NOTATION WSD for TLG Classical Greek//EN" "c:\CUCUK\teigk2.wsd"
```

Les tendances d'aujourd'hui :

Les parsers permettent de traiter les entités externes par des classes spécifiques (`EntityResolver`)

Il est possible de les utiliser pour conserver une compatibilité avec les "anciens" catalogues publiques (la correspondance doit être effectuée "à la main")

Ils permettent de traiter aussi bien les références `SYSTEM` que `PUBLIC`

Utilité

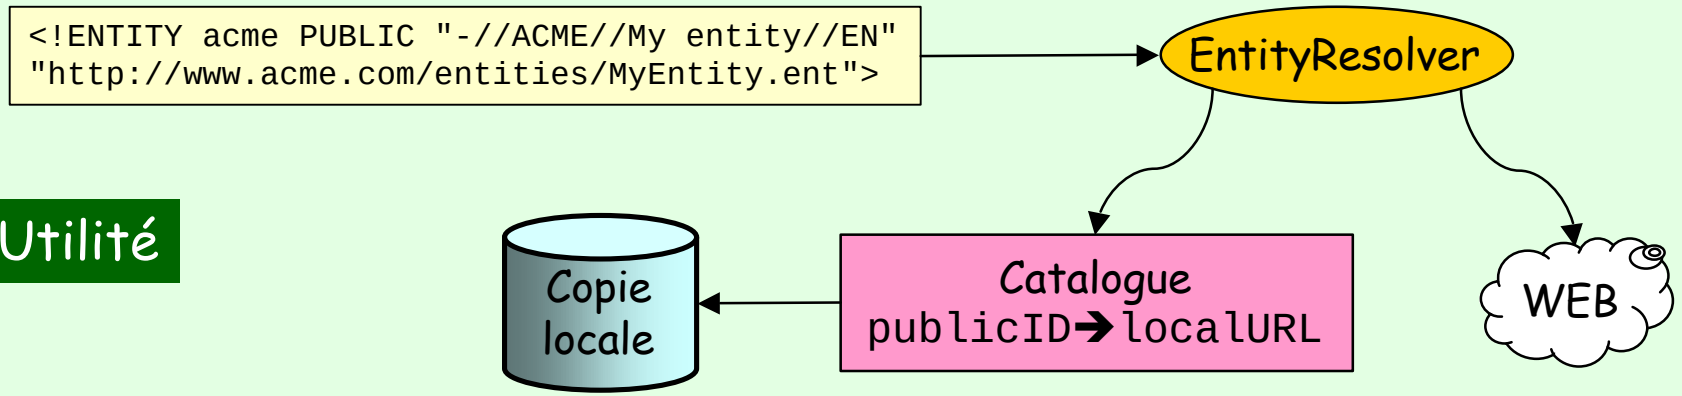

Les catalogues XML

http://oasis-open.org/committees/entity/spec-2001-08-06.html

Java implémentation : http://wwws.sun.com/software/xml/developers/resolver/

Un catalogue pour DocBook :

```
<!DOCTYPE catalog
  PUBLIC "-//OASIS//DTD Entity Resolution XML Catalog V1.0//EN"
         "http://www.oasis-open.org/committees/entity/release/1.0/catalog.dtd">
<catalog xmlns="urn:oasis:names:tc:entity:xmlns:xml:catalog"
         prefer="public">
  <group xml:base="http://www.oasis-open.org/docbook/xml/4.1.2/">
    <public publicId="-//OASIS//DTD DocBook XML V4.1.2//EN"
            uri="docbookx.dtd"/>
    <public publicId="-//OASIS//ENTITIES DocBook XML Notations V4.1.2//EN"
            uri="dbnotnx.mod"/>
    <public publicId="-//OASIS//ENTITIES DocBook XML Character Entities V4.1.2//EN"
            uri="dbcentx.mod"/>
    <public publicId="-//OASIS//ELEMENTS DocBook XML Information Pool V4.1.2//EN"
            uri="dbpoolx.mod"/>
    <public publicId="-//OASIS//ELEMENTS DocBook XML Document Hierarchy V4.1.2//EN"
            uri="dbhierx.mod"/>
    <public publicId="-//OASIS//ENTITIES DocBook XML Additional General Entities V4.1.2//EN"
            uri="dbgenent.mod"/>
    <public publicId="-//OASIS//DTD DocBook XML CALS Table Model V4.1.2//EN"
            uri="calstblx.dtd"/>
  </group>
  <public publicId="-//OASIS//DTD DocBook MathML Module V1.0//EN"
          uri="http://www.oasis-open.org/docbook/xml/mathml/1.0/dbmathml.dtd"/>
  <nextCatalog catalog="stylesheets.xml"/>
</catalog>
```

Utilisation des documents bien-formés

Le monde réel

Document sans DTD (sans contrainte de structure)

Que faire avec ce document ?
- Comment l'afficher?
- Comment accéder à son contenu si les éléments sont inconnus des applications ?

Dans un contexte professionnel, les documents XML seront toujours contraints (DTD, schéma)

Les contraintes sur les données font partie du standard XML
Autant en profiter pour ne pas surcharger les applications

Utilisation des documents bien-formés

Utilité :
- pour le programmeur et le concepteur (pour XSLT)
- pour les processus qui génèrent des documents XML
- pour lever les contraintes sur certains processus

L'existence d'une DTD permet de servir de support de documentation de la structure de données

…et en cas d'utilisation dans un processus validant de déceler les bugs du programme générateur

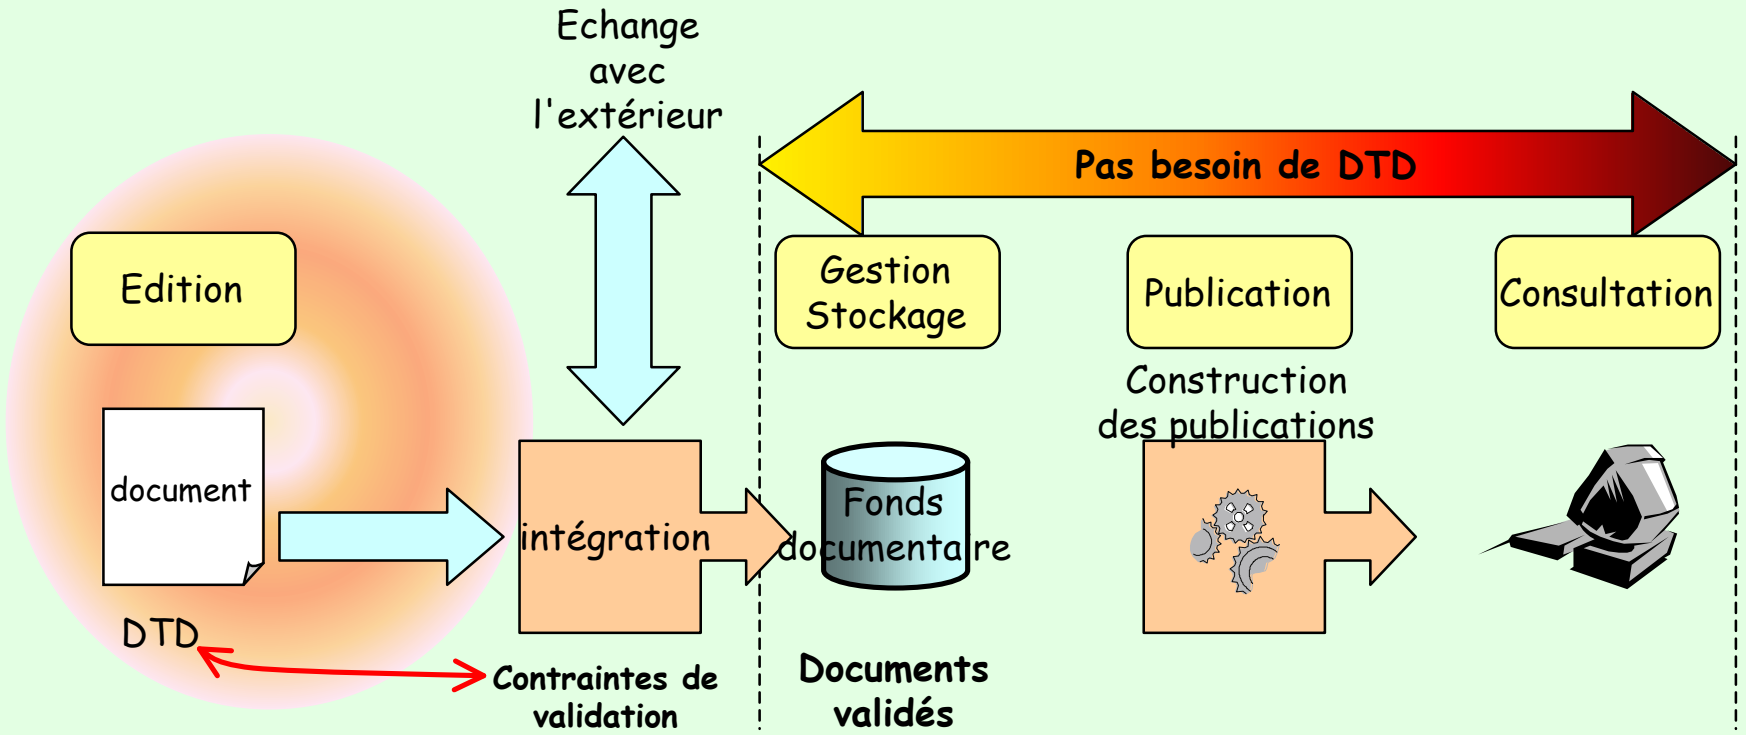

Réglages de l'analyse

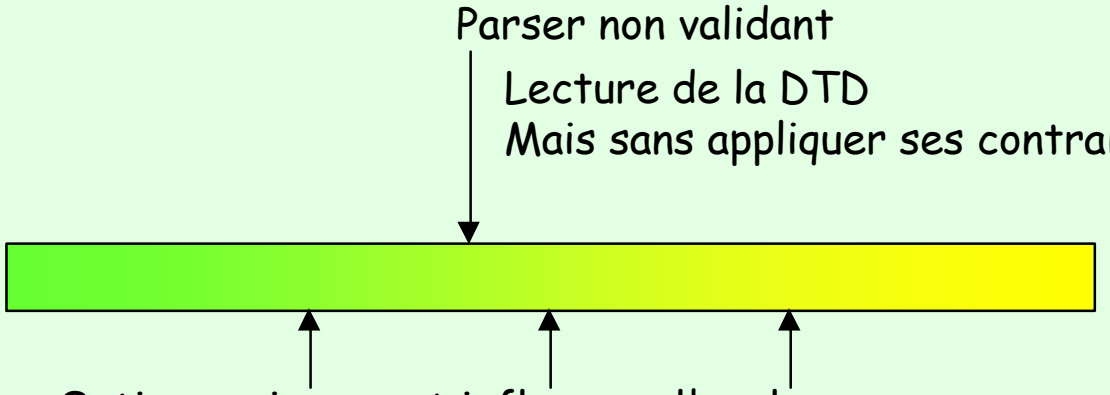

Peut changer la structure logique du contenu

Options qui peuvent influencer l'analyse :

- suppression des nœuds blancs
- non prise en compte des espaces de nommage
- pas de création des nœuds de référence d'entité parsables

...

Dans la chaîne de publication, on peut se passer de la DTD complète :

Appauvrissement de la DTD
Une deuxième DTD, permettant :

- d'inclure dans le document les entités externes
- d'incorporer la DTD dans le document (en y mettant "juste ce qu'il faut")

```
<?xml version="1.0"?>
<!DOCTYPE foo [
          …/…
]>
<foo>
          …/…
</foo>
```

...et d'utiliser un parseur qui ne valide pas mais qui lit la DTD

Limitation des DTD

Pas de format de données
Pas de contrainte de longueur de champs
Pas de contrainte d'intégrité sur un type d'élément
(les ID ↔ IDREF ont une portée sur tout le document ∀ les éléments)
Syntaxe spécifique
"Verrue" des espaces de nommage
…

Pas de maîtrise des PI, ni des commentaires (qui ne font pas partie de la structure)

Pour valider des contraintes non exprimées (car non exprimable dans les DTD)
⇨introspection des données (parser dans un parser)

Solutions :

utiliser d'autres schemas

Cependant, toutes les technologies de schémas ont leur limitations

Représentation graphique des DTD

- XML authority
- Near&Far designer

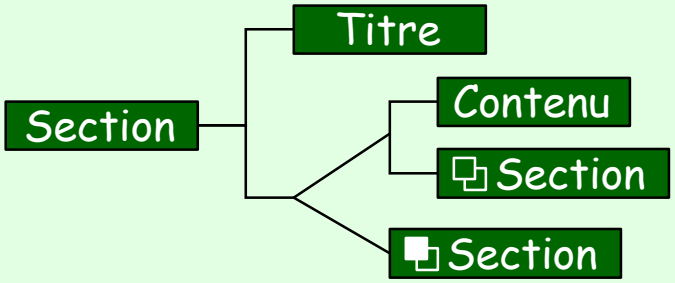

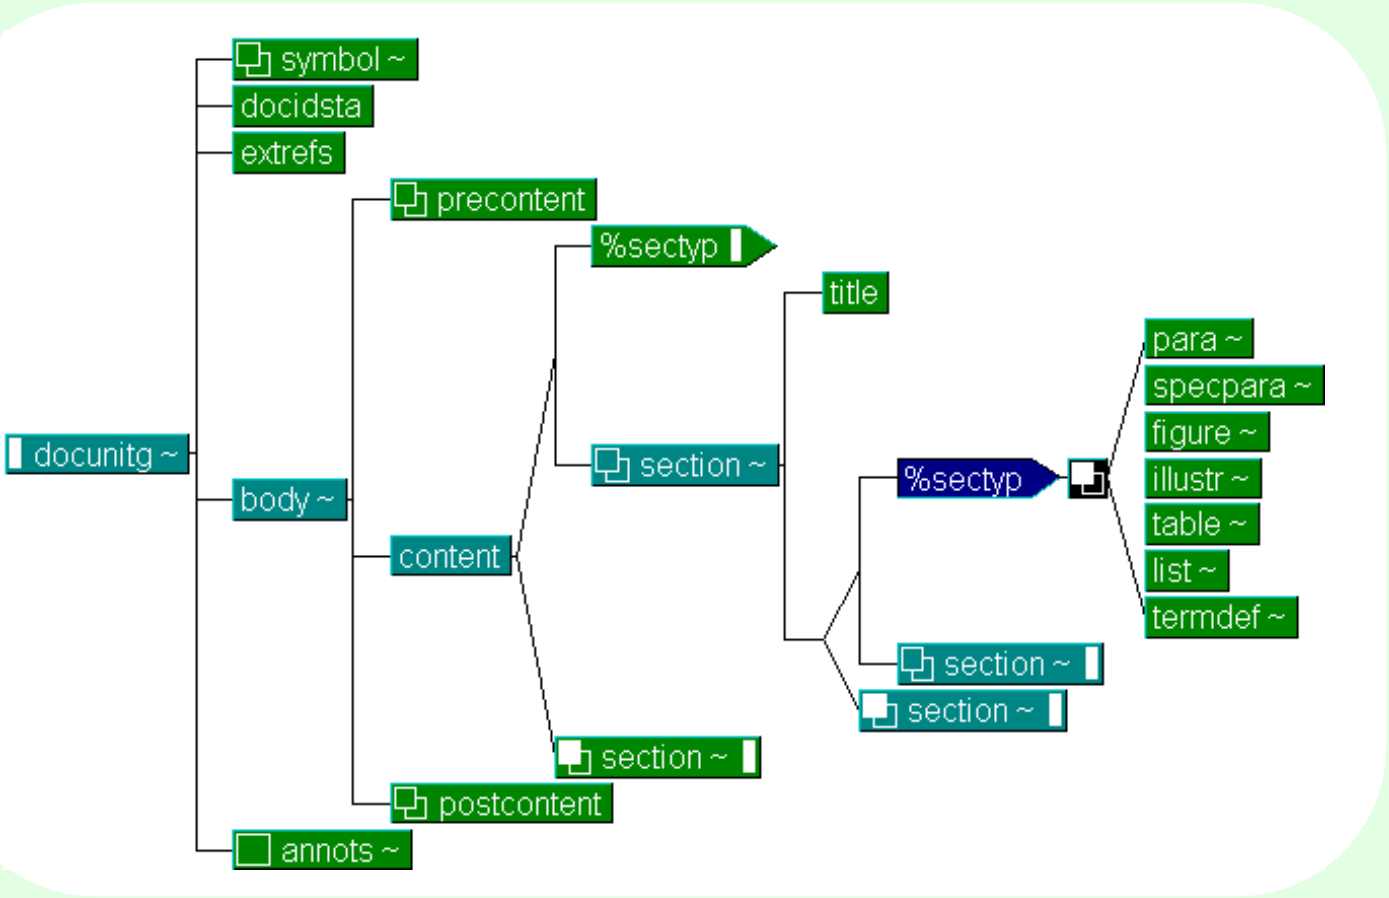

Conception de DTD

Dans mon entreprise,
je crée mes DTD pour
mes propres besoins.

Utiliser les standards métiers existants :

Ma DTD :
- Un peu de RDF pour les Meta-Données
- Un peu de XHTML pour les données documentaires
- Un peu de SVG pour insérer des graphiques
- Un peu de MathML pour insérer des formules mathématiques
- Un peu de XLink pour décrire des liens complexes
- Un peu de mes balises issues de mon métier
- ...

➔ Instrumentation des DTD

- construire sa DTD en piochant dans les standards existants

Utiliser les applications XML liées au standard pour la modélisation et les traitements :

- WXS : conception
- XSLT : publication cross-media
- DOM : traitement du contenu (BdD...)
- XCL : intégration
- ...

Entités externes binaires

A utiliser seulement si vos outils les supportent

```
<?xml version="1.0" encoding="ISO-8859-1" ?>
<!DOCTYPE zoo [
          <!NOTATION jpg SYSTEM "images/jpeg">
          <!ELEMENT dauphin (nom, taille, poids)>
          <!ATTLIST dauphin
                    id        ID #REQUIRED
                    photo     ENTITY #IMPLIED>
          <!ENTITY flipper.jpg SYSTEM "flipper.jpg" NDATA jpg>
          …/…
]>
<zoo>
          <aquarium>
                    <dauphin id="jhgtr13" photo="flipper.jpg">
                              <nom>Flipper</nom>
                              …/…
</zoo>
```

- Marque l'appartenance au document
- Permet à certains éditeurs l'affichage

La redondance `flipper.jpg` permet de dissocier le document de sa DTD pour des traitements ayant lieu après la validation

```
<dauphin id="jhgtr13" photo="flipper.jpg">
```

- Lors de l'édition, la valeur de l'attribut `photo` référence l'entité externe binaire
- Lors de la publication, la valeur de l'attribut `photo` référence le nom du fichier

Du bon usage des DTD

Factoriser les DTD en utilisant les entités générales

Dans un document XML :
- définir l'utilisation des parties optionnelles (INCLUDE ou IGNORE)
- appeler les modules généraux, comme les notations
- définir les entités qui "font partie" du document
  (ça ne sert à rien ?)
  (→penser aux cas ou ça peut servir)

C'est un moyen simple qui permet à des traitements de prendre en compte les médias contenus dans un document

notations.ent

```
<?xml version="1.0" encoding="ISO-8859-1" ?>
<!NOTATION jpg SYSTEM "images/jpeg">
<!NOTATION gif SYSTEM "images/gif">
```

```
<?xml version="1.0" encoding="ISO-8859-1" ?>
<!DOCTYPE zoo SYSTEM "zoo.dtd" [
          <!ENTITY % notations SYSTEM "notations.ent">
%notations;
          <!ENTITY % svg_structure SYSTEM "svg.dtd" >
%svg_structure;
          <!ENTITY flipper.jpg SYSTEM "flipper.jpg" NDATA jpg>
          <!ENTITY oum SYSTEM "oum.xml">
]>
<zoo>
          <aquarium>
                    <dauphin id="jhgtr13" photo="flipper.jpg">
                              <nom>Flipper</nom>
                              …/…
</zoo>
```

flipper.jpg

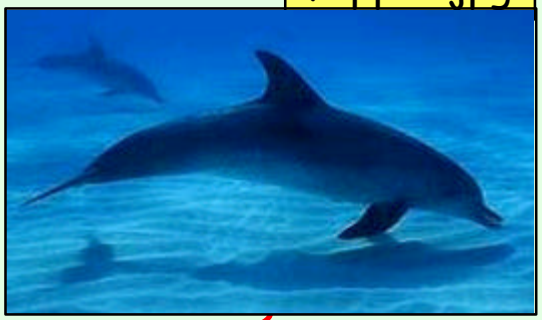

Exemple : construction d'un rapport

Edition à partir d'un éditeur XML

```
<?xml version="1.0" encoding="ISO-8859-1" ?>
<!DOCTYPE rapport SYSTEM "rapport.dtd" [
          <!ENTITY ventes SYSTEM "ventes.xml">
]>
<rapport>
          &ventes;
          <analyse>
                    <p>Cette année, la croissance
                    est au rendez-vous,
                    …/…
                    </p>
          <analyse>
</rapport>
```

Système d'information

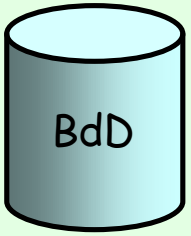

Génération automatique du fichier

ventes.xml

```
<?xml version="1.0" encoding="ISO-8859-1" ?>
<ventes>
          <charcuterie>23</charcuterie>
          <fromages>45</fromages>
          <primeurs>78</primeurs>
</ventes>
```

Publication

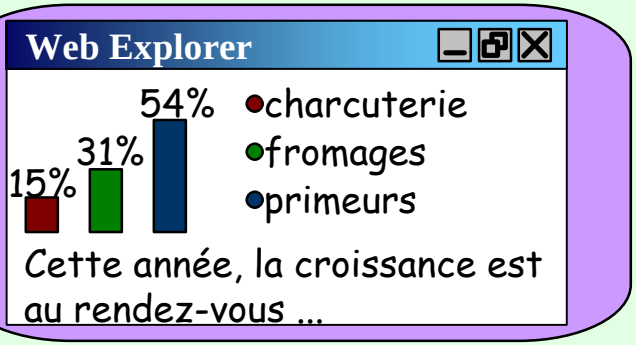

W3C XML Schema

DTD
- Spécifie un modèle de contenu

WXS ou XSD
- Syntaxe XML
- Supporte les format de données basiques
- Permet l'extension des types de données

XML Schema definition language (XSD)

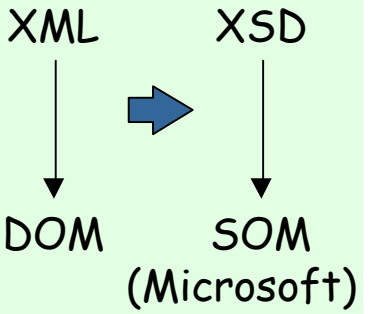


```
<?xml version="1.0"?>
<!DOCTYPE document SYSTEM "document.dtd">
<document>
          …/…
</document>
```

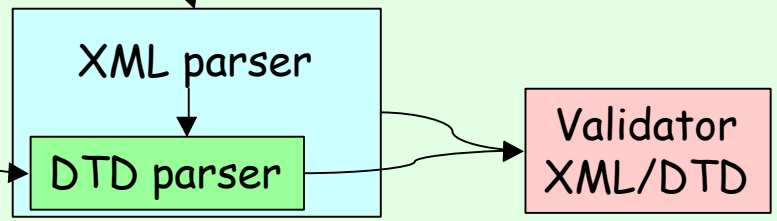


```
<?xml version="1.0"?>
<document xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance"
xsi:schemaLocation="http://document.org document.xsd">
          …/…
</document>
```

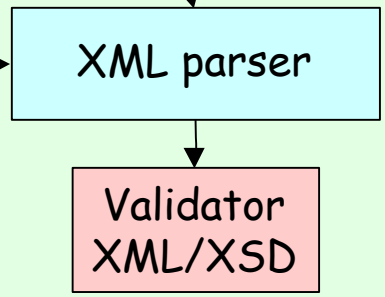

Types de données WXS

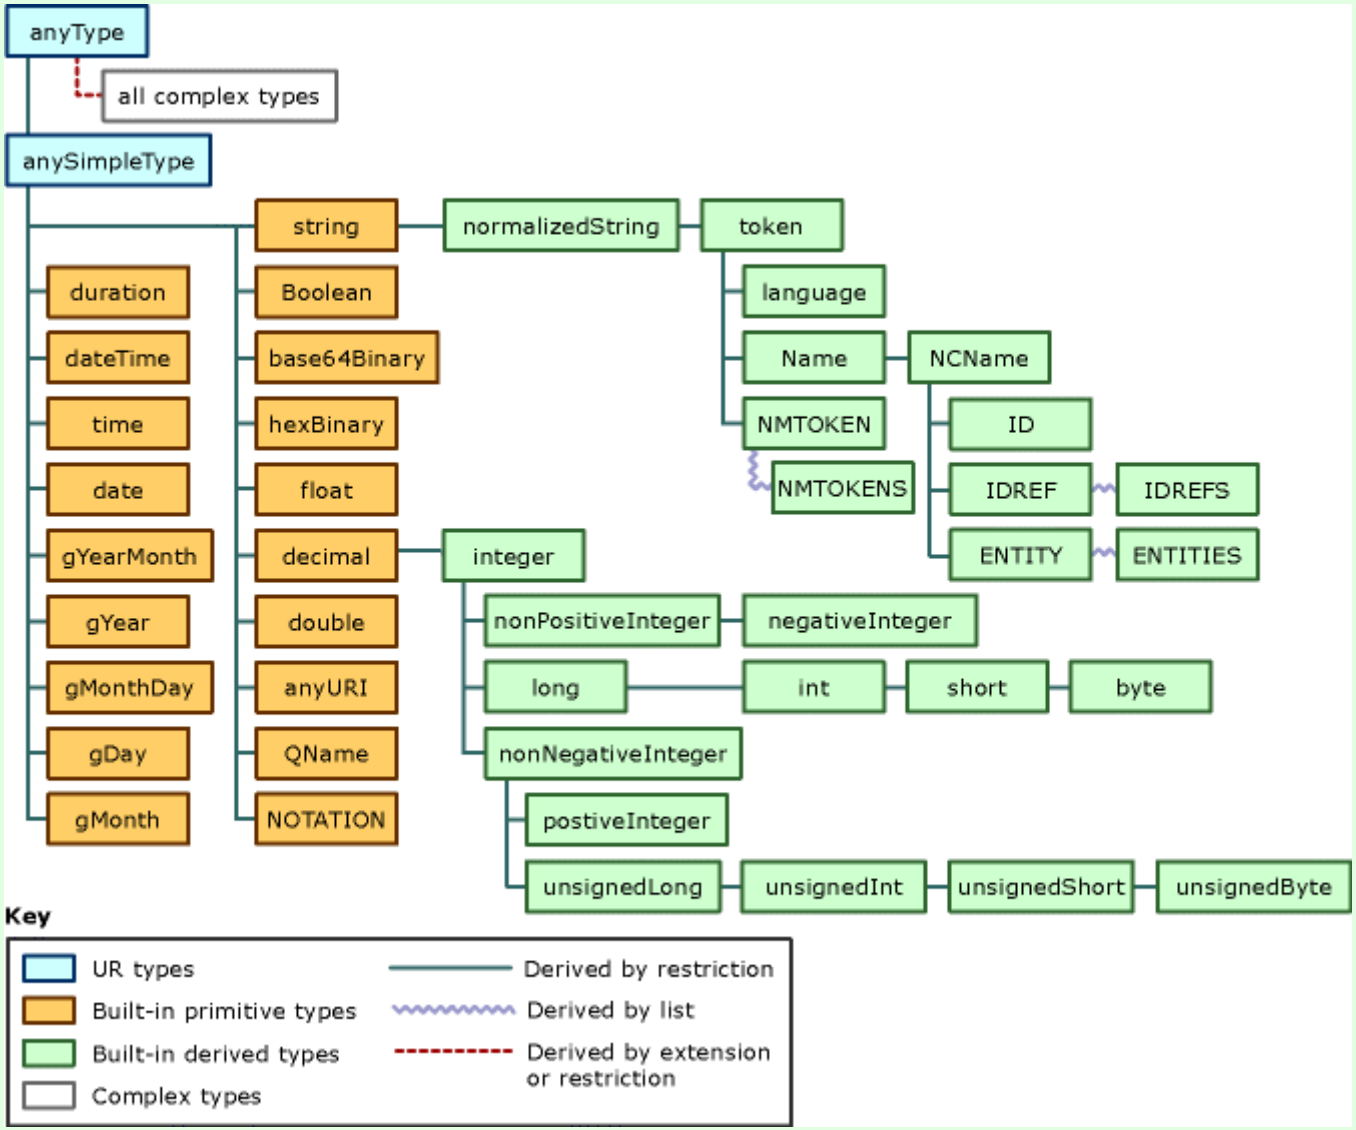

```
<!ELEMENT name (#PCDATA)>
```

```
<xsd:element name="name" type="xsd:string"/>
```

```
<!ELEMENT name (#PCDATA)>
with attribute-list declarations
```

```
<xsd:element name="name">
  <xsd:complexType>
    <xsd:simpleContent>
      <xsd:extension base="xsd:string">
        <xsd:attributeGroup ref="foo"/>
      </xsd:extension>
    </xsd:simpleContent>
  </xsd:complexType>
</xsd:element>
```

```
<!ELEMENT name (#PCDATA | foo1 | foo2 | …)*>
with attribute-list declarations
```

```
<xsd:element name="name">
  <xsd:complexType mixed="true">
    <xsd:choice minOccurs="0" maxOccurs="unbounded">
      <xsd:element ref="foo1"/>
      <xsd:element ref="foo2"/>
      …
    </xsd:choice>
    <xsd:attributeGroup ref="foo"/>
  </xsd:complexType>
</xsd:element>
```

```
<!ELEMENT name (element-content-model)>
with attribute-list declarations
```

```
<xsd:element name="name">
  <xsd:complexType>
    element-content-model
    <xsd:attributeGroup ref="foo"/>
  </xsd:complexType>
</xsd:element>
```

Modèles de contenus WXS

Référence des autres éléments dans le modèle de contenu	`<xsd:element ref="name"/>`
, dans le modèle de contenu	`<xsd:sequence>…</xsd:sequence>`
| dans le modèle de contenu	`<xsd:choice>…</xsd:choice>`
* dans le modèle de contenu	`minOccurs="0" maxOccurs="unbounded"`
+ dans le modèle de contenu	`minOccurs="1" maxOccurs="unbounded"`
? dans le modèle de contenu	`minOccurs="0" maxOccurs="1"`

Déclarations des attributs WXS


```
<!ATTLIST name
    attribute-declarations>
```

```
<xsd:attributeGroup name="name">
    attribute-declarations
</xsd:attributeGroup>
```

attribute declaration

```
<xsd:attribute name="…" …>
    …
</xsd:attribute>
```

#IMPLIED

use="optional"***(default)***

#REQUIRED

use="required"

CDATA

type="xsd:string"

`<!-- … -->`	`<xsd:annotation>`
	`  <xsd:documentation>`
	`  …`
	`  </xsd:documentation>`
	`</xsd:annotation>`

`<!ENTITY % param-ent-name`
`  attribute-declarations>`
	`<xsd:attributeGroup name="param-ent-name">`
	`  attribute-declarations`
	`</xsd:attributeGroup>`

`<!ENTITY % param-ent-name`
`  element-content-model>`
	`<xsd:modelGroup name="param-ent-name">`
	`  element-content-model`
	`</xsd:modelGroup>`

`%param-ent-name;`	`<xsd:attributeGroup ref="param-ent-name"/>`
`%param-ent-name;`	`<xsd:modelGroup ref="param-ent-name"/>`
`<!ENTITY name …>`	Non applicable

Déclarations d'entités parsées ou non

Relax NG

(Technical Report ISO/IEC TR 22250-1:2001 de l'ISO/IEC JTC1)

Relax Core (James Clark)

TREX

Relax NG

(OASIS, puis ISO)

Un super bouquin complet et en ligne :

`http://books.xmlschemata.org/relaxng/`

`http://www.oasis-open.org/committees/relax-ng/`

`http://www.relaxng.org/`

Permet d'exprimer à peu près les mêmes choses que les DTD :

- dans une forme XML
- avec beaucoup plus de puissance d'expression
- en utilisant le typage de données

Forme XML

```
<element name="author">
  <attribute name="id"/>
  <ref name="name-element"/>
  <optional>
    <element name="born">
      <text/>
    </element>
  </optional>
  <optional>
    <element name="died">
      <text/>
    </element>
  </optional>
</element>
```

Forme Compacte

```
element author {
  attribute id { text },
  name-element,
  element born { text }?,
  element died { text }?
}
```

```
<!ELEMENT name (#PCDATA)>
with attribute-list declarations
```

```
<define name="name">
  <element name="name">
    attribute-declarations
    <text/>
</define>
```

```
<!ELEMENT name (#PCDATA | foo1 | foo2 | …)*>
with attribute-list declarations
```

```
<define name="name">
  <element name="name">
    attribute-declarations
    <mixed>
      <zeroOrMore>
        <choice>
          <ref name="foo1"/>
          <ref name="foo2"/>
          …
        </choice>
      </zeroOrMore>
    </mixed>
</define>
```

```
<!ELEMENT name (element-content-model)>
with attribute-list declarations
```

```
<define name="name">
  <element name="name">
    attribute-declarations
    element-content-model
</define>
```

Modèles de contenus RNG

Référence des autres éléments dans le modèle de contenu

```
<ref name="name"/>
```

, dans le modèle de contenu

```
<group>…</group>
```

| dans le modèle de contenu

```
<choice>…</choice>
```

* dans le modèle de contenu

```
<zeroOrMore>…</zeroOrMore>
```

+ dans le modèle de contenu

```
<oneOrMore>…</oneOrMore>
```

? dans le modèle de contenu

```
<optional>…</optional>
```

Déclarations des attributs RNG

attribute declaration	`<attribute name="…">`
	`  …`
	`</attribute>`

#IMPLIED	`<optional>…</optional>`
CDATA	`<text/>`

Autres structures RNG

`<!-- … -->`	`<a:documentation> … </a:documentation>`
`<!ENTITY % param-ent-name attribute-declarations>`	`<define name="param-ent-name"> attribute-declarations </define>`
`<!ENTITY % param-ent-name element-content-model>`	`<define name="param-ent-name"> element-content-model </define >`
`%param-ent-name;`	`<ref name="param-ent-name"/>`
`%param-ent-name;`	`<ref name="param-ent-name"/>`
`<!ENTITY name …>`	Non applicable

Déclarations d'entités parsées ou non

Typage dans RNG avec WXS

Relax NG définit 2 types de données : "String" et "token", mais offre la possibilité d'utiliser des librairies externes.
En particulier, Relax NG peut utiliser les types de données et les facettes des schémas XML du W3C

```
<?xml version="1.0" encoding="ISO-8859-1" ?>
<element name="itemList"
  xmlns="http://relaxng.org/ns/structure/1.0"
  xmlns:a="http://relaxng.org/ns/compatibility/annotations/1.0"
  datatypeLibrary="http://www.w3.org/2001/XMLSchema-datatypes">
  <zeroOrMore>
    <element name="item">
      <attribute name="number"/>
      <element name="name">
        <data type="token">
          <a:documentation>Jusqu'à 5 caractères</a:documentation>
          <param name="maxLength">5</param>
        </data>
      </element>
      <element name="quantity">
        <data type="short">
          <a:documentation>Nombres de 0 à 20</a:documentation>
          <param name="maxInclusive">20</param>
          <param name="minInclusive">0</param>
        </data>
      </element>
    </element>
  <zeroOrMore>
</element>
```

PSVI et validation

PSVI = data augmentation

Post Schema Validation Infoset

Les valeurs par défaut des attributs fournis par la DTD sont fixées dans le modèle de données

```
<?xml encoding="ISO-8859-1"?>
<!DOCTYPE foo [
    <!ATTLIST foo bar CDATA #FIXED "BAR">
]>
<foo/>
```

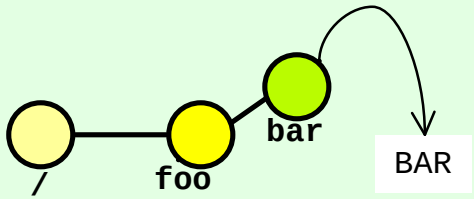

➔ Le schéma "augmente" les informations contenues dans le document

Relax NG ne propose aucun mécanisme similaire

Bien qu'avantageux, cette technique pose des problèmes :
- information manquante quand on n'a pas accès au schéma
- technique non normalisée, sauf pour les DTD (DOM)

Mais offre aussi des avantages :
- typage des données fourni par le schéma (avec WXS)
- data-binding grâce au typage

Choisir son schéma

- Celui qu'on connaît
- Celui qui est supporté par les outils qu'on utilise
- Celui qui correspond à ses exigences en termes d'expressions de contrainte

Incomplétude de la validation par schéma

On ne peut pas tout valider avec un schéma

- DTD
- W3C XML Schema
- Relax NG

→

- Contraintes non exprimables
- Mono-document
- Autres sources (SGBDR…) ?

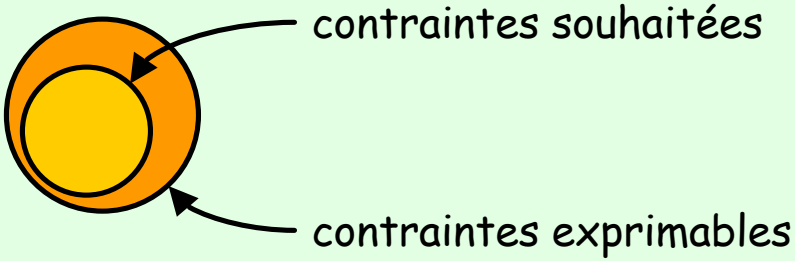

Les schémas laissent toujours plus de liberté que nécessaire

Complément : validation par programmation

- Permet seulement de valider
- Ne permet pas de savoir ce qui est autorisé dans un contexte donné

L'outsider : Schematron

http://www.schematron.com/

The Schematron Assertion Language

Bientôt une norme ISO

Basé sur des règles

```
<?xml version="1.0" encoding="iso-8859-1"?>
<sch:schema xmlns:sch="http://www.ascc.net/xml/schematron">
  <sch:title>Example Schematron Schema</sch:title>
  <sch:pattern>
    <sch:rule context="dog">
     <sch:assert test="count(ear) = 2">A 'dog' element should
                          contain two 'ear' elements.</sch:assert>
     <sch:report test="bone">This dog has a bone.</sch:report>
   </sch:rule>
  </sch:pattern>
</sch:schema>
```

Validation partielle

```
<phase id="basicValidation">
 <active pattern="text" />
 <active pattern="tables" />
 <active pattern="attributePresence" />
</phase>
<phase id="fullValidation">
 <active pattern="metadata" />
 <active pattern="text" />
 <active pattern="tables" />
 <active pattern="attributePresence" />
 <active pattern="attributeValueChecks" />
</phase>
```

- Permet seulement de valider
- Ne permet pas de savoir ce qui est autorisé dans un contexte donné