Structuration et échange d'informations sur le Web

Université Lyon 1
Master CCI

L. Médini, Janvier 2007

Plan du cours 1 : Principes fondamentaux, syntaxe et validation

- Introduction
  - Définitions
  - Aperçu de quelques langages documentaires
  - Les langages dédiés au web
- HTML, XML et XHTML
  - Principes de base
  - Syntaxe
- Validation de documents XML : les DTD
- Feuilles de style CSS

Plan du cours 2 : Applications et programmation XML

- Applications XML
  - Notion d'espaces de noms XML
  - Retour sur la validation de documents : les schémas XML
  - Le langage de feuilles de style XSL
    - Xpath
    - XSLT
- Programmation XML
  - Les API existantes
  - Le Document Object Model (DOM)
  - Simple API for XML (SAX)

Introduction

- De quoi on va parler dans ce cours ?
  - De « Nouvelles Technologies de l'Information et de la Communication »
    - Langages dédiés au web (XHTML, XML...)
    - Programmation web
- Points de vue abordés
  - Structuration des données
  - Échange et partage des données
- Ce qu'on ne fera pas
  - Applications web (« services Web »)
  - Aspects sémantiques (« Web sémantique »)

Introduction

- Définitions
  - L’information en tant que signal circulant entre un émetteur et un récepteur lors d’un processus de communication
    - Origine : théorie de l’information (Shannon 1948), traitement du signal (Fourier ~1800)
    - On s’intéresse uniquement à l’aspect physique du signal transmis
    - Émetteur et récepteur peuvent être humains ou logiciels.

Introduction

- Définitions
  - L'information en tant que message véhiculé lors d'un processus de communication
    - On s'intéresse au contenu de l'information
    - Émetteur et récepteur logiciels : traitement de l'information, informatique
    - Émetteur et récepteur humains : linguistique, sémiologie (De Saussure 1916)
    - Extension de cette notion par la prise en compte du contexte général de la communication : sémiotique (Pierce ~1870)

Introduction

- Définitions
  - Donnée : valeur associée à un type de données
    - Décrite par des caractéristiques de forme
    - Indépendante de son interprétation : donnée « brute »
  - Élément d'information : ensemble de données faisant « sens »
    - On parle aussi de « grains d'information »
  - Document : regroupement cohérent d'éléments d'information
    - Autour d'une thématique commune
    - Selon une structure donnée

Introduction

- Définitions
  - Information structurée : bases de données
    - Éléments d'information stockés séparément
    - Accès par requêtes
    - Traitements facilités
  - Information non structurée : corpus documentaires
    - Éléments d'information stockés sous forme de textes
    - Accès par recherche d'information
    - Traitements complexes
  - Information semi-structurée : langages à balises
    - Éléments d'information stockés dans des documents
    - Permet les deux types d'accès et de traitements

Introduction

- Définitions
  - Balise : signe marquant une position particulière
    - Signe = élément d'information
    - Marquer = permettre la distinction
      - Ex : fusée de détresse, signal radio, « tag » HTML
    - Position = par rapport à l'espace considéré
      - Ex : espace 3D (avion), 2D (bateau), 1D (document)
    - Particulière = en général, la position d'un élément de l'espace qu'on cherche à repérer
      - Ex : aéroport, bateau, élément d'information

  ⇒ Type d'information facilement repérable permettant d'identifier d'autres éléments informationnels (i.e. « méta-information »)

Introduction

- Définitions
  - Balisage documentaire : utilisation de balises
    - Pour marquer des points précis d'un document
    - Pour marquer des zones (segments) de document
      - Balisage de début et de fin de zone
    - Pour structurer le document
  - ⇒ Utilisation de plusieurs types de balises
    - ⇒ En fonction du type d'élément à marquer
    - ⇒ En fonction du type de marquage (point, début, fin)
  - Langage à balises : langage de description de documents utilisant ces techniques de balisage
  - Élément : une balise et son contenu

Introduction

- Quelques langages à balises
  - Langages de *balisage procédural* : permettent de décrire la mise en forme (formatage) d'un document
    - Ex : PS, RTF, TeX, HTML
  - Langages de *balisage descriptif* : se contentent de décrire les données, sans but de traitement
    - Ex : RDF, OWL, MathML
  - *Méta-langages* de balisage : permettent de définir des langages de balisage
    - Ex : SGML, XML

Introduction

- Le langage Postscript

```
%!PS-Adobe-3.0
%%Title: Microsoft Word -
Document1
%%Creator: PSCRIPT.DRV
Version 4.0
%%CreationDate: 03/02/02
10:47:00
...
%%EndComments
%%BeginProlog
%%BeginProcSet:
Pscript_Res_Emul 1.0 0
/defineresource
where{pop}{userdict
begin/defineresource{userdi
ct/Resources 2
...
}ifelse}bind readonly def
end}ifelse
%%EndProcSet
```

```
%%BeginResource: file
...
%%EndResource
...
%%EndProlog
%%BeginSetup
...
%%BeginFeature:
*PageSize A4
...
%%EndFeature
...
%%EndSetup
%%Page: 1 1
%%BeginPageSetup
...
%%EndPageSetup
...
```

```
%%IncludeFont: Courier
...
 (Courier) cvn /Type1
...
(Essai impression)S
...
(%%[ Page: 1 ]%%)  =
%%PageTrailer
%%Trailer
%%DocumentNeededFonts:
%%DocumentSuppliedFonts:
/Pscript_Win_Driver /ProcSet
findresource dup /terminate g
exec
Pscript_Win_Compat dup
/terminate get exec
%%Pages: 1
(%%[ LastPage ]%%)  =
%%EOF
```

Introduction

- Le langage RTF

{\rtf1\adeflang1025\ansi\ansicpg1252\uc1\adeff0\deff0\stshfdbch0\stshfloch0\stshfhich0
\stshfbi0\deflang1036\deflangfe1036{\fonttbl{\f0\froman\fcharset0\fprq2{*\panose
020206030504050203 04}Times New Roman;}{\f36\froman\fcharset238\fprq2 Times
New Roman CE;}{\f37\froman\fcharset204\fprq2 Times New Roman Cyr;}…
{\f43\froman\fcharset186\fprq2 Times New Roman Baltic;}
{\f4
{\cc
en2
{\st
…;}
{*\
{*\
{\op
\pap
\def
…
{\rt
{\rt

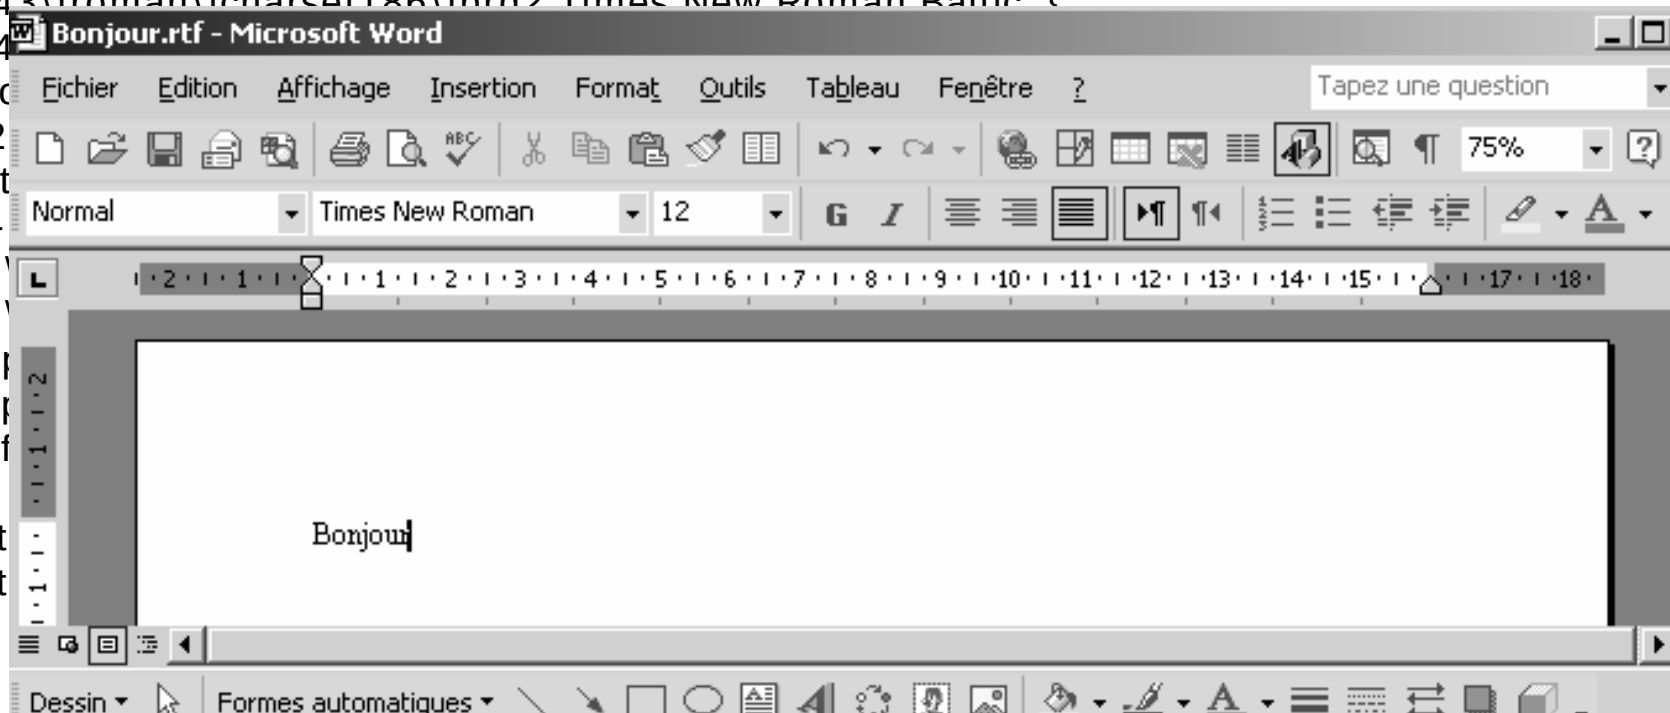

Introduction

- Les langages dédiés au Web
  - Historique 1/3
    - 1960-1986 : SGML (norme ISO)
    - 1989 : ODA (norme ISO, concurrent de SGML)
    - Fin des années 80 : apparition/essor du web
    - 1992-1997 : HTML (versions 1.0 -> 4.01)
    - Octobre 1994 : création du World Wide Web Consortium (W3C) : http://www.w3.org
    - 1996-1999 : CSS Level 1 (fonctionnalités de base)
    - Février 1998 : XML version 1.0
    - 1998 : CSS Level 2 (fonctionnalités supplémentaires)
    - Octobre 1998 DOM Level 1 (supporte XML et HTML)

Introduction

- Les langages dédiés au Web
  - Historique 2/3
    - Décembre 1999 : XHTML 1.0
    - 1999-2004 : RDF et RDF-Schema 1.0
    - Novembre 2000 : DOM Level 2 (supporte CSS et espace de noms XML)
    - Mai 2001 : schémas XML 1.0
    - Juin 2001 : XLink 1.0
    - Juillet 2001 : SVG 1.0
    - Novembre 2001 : XSL 1.0
    - Janvier 2003 : SVG 1.1

Introduction

- Les langages dédiés au Web
  - Historique 3/3
    - Février 2004 et août 2006 : XML 1.1
    - Février 2004 : OWL 1.0
    - Avril 2004 : DOM Level 3 Core
    - Octobre 2004 : XML Schema (2e edition)
    - Octobre 2004 : XQuery 1.0
    - Octobre 2004 : XPath 2.0 (Working Draft)
    - Novembre 2004 : XSLT 2.0 (Working Draft)
    - Décembre 2004 : WSDL 2.0
    - Restent en développement : CSS L3, DOM L3...

Introduction

- Quelques langages dédiés au Web

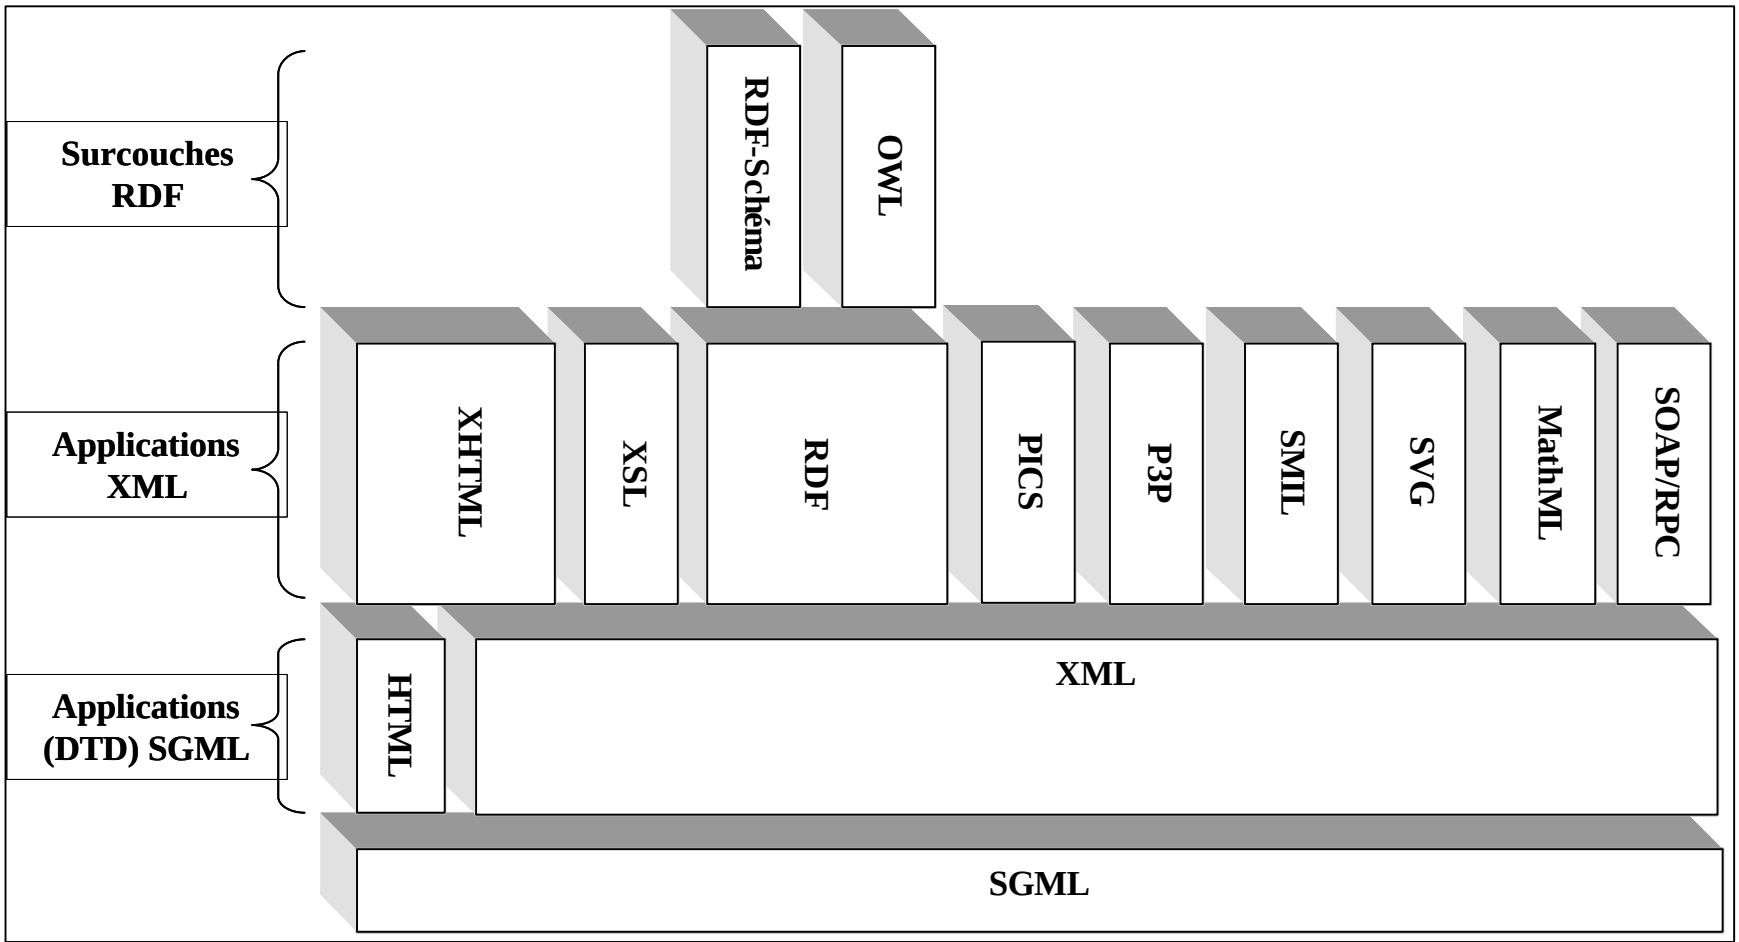

HTML, XML et XHTML

- HTML
  - DTD SGML : ensemble (dé)fini d'éléments SGML
  - Destiné à visualiser des hyperdocuments sur écran
  - Interprété côté client par les navigateurs
  - V. 1.0 : 1992 -> V. 4.01 (dernière) : oct. 1997
  - Souvent associé à d'autres langages
    - CSS : langage de feuilles de style
    - Langages de scripts : JavaScript, JScript, VBscript…
    - Inclusion d'objets définis dans d'autres langages : applets Java, contrôles ActiveX…
  - Remarque : le langage D(H)TML n'existe pas

HTML, XML et XHTML

- XML : principes de base
  - DTD de SGML (beaucoup plus concis)
  - Restrictions de syntaxe et non de contenu
  - Au même titre que SGML, c'est un méta-langage de description des données
    - ⇒ Ça ne sert à rien
    - ⇒ Ça permet de définir des « applications » pour faire ce qu'on veut avec
      - Visualiser des pages web
      - Décrire des images
      - Échanger des données techniques…
  - V 1.0 : fév. 1998 -> 04 fév. 2004 (3ème édition)
  - V 1.1 : 04 fév. 2004 ; 16 août 2006 (2ème éd.)

HTML, XML et XHTML

- XML : composants
  - XML (syntaxe) : documents « bien formés »
  - DTD/schémas XML : documents « valides »
  - Processeur (parser) XML : analyse et traitement
  - DOM : modèle arborescent des données d'un document pour un langage de programmation
  - SAX : accès « simple » aux données (programmation événementielle)
  - Espaces de noms (« namespaces ») : interopérabilité des applications
  - XBase, XPointer, XLink : mécanismes de liens
  - XSL : mécanismes de transformation

HTML, XML et XHTML

- Syntaxe XML (voir poly p. 50) : un document XML bien formé est composé
  - D'un prologue, contenant :
    - Éventuellement une déclaration XML

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

    - Éventuellement une déclaration de type de document

```
<!DOCTYPE Nom_de_l_élément_racine Type_de_source
  emplacement1 emplacement2 [sous-ensemble interne
  de DTD]>
```

  - D'un élément « racine », composé :
    - Soit d'une balise ouvrante, éventuellement d'un contenu et d'une balise fermante

```
<NomElement attribut1="valeur1" attribut2="valeur2"...>
  contenu
</NomElement>
```

HTML, XML et XHTML

- Syntaxe XML (voir poly p. 50) : un document XML bien formé est composé
  - D'un prologue, contenant :
    - Éventuellement une déclaration XML

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

    - Éventuellement une déclaration de type de document

```
<!DOCTYPE Nom_de_l_élément_racine Type_de_source
  emplacement1 emplacement2 [sous-ensemble interne
  de DTD]>
```

  - D'un élément « racine », composé :
    - Soit d'une balise d'élément vide

```
<Nom_element_vide att1="val1" att2="val2"... />
```

HTML, XML et XHTML

- Syntaxe XML (voir poly p. 50) : remarques
  - Structure
    - Un contenu est composé de texte et / ou d'autres éléments appelés fils de l'élément courant
    - Le texte est appelé « données caractères analysables » ou PCDATA (pour Parsed Character DATA).
    - Le contenu autorisé pour le PCDATA dépend du type d'encodage choisi
    - Le fait d'avoir un unique élément racine, des éléments fils, eux-mêmes décomposables, etc. définit une **structure arborescente**
    - Pas de chevauchement de balises entre un élément père et un élément fils

HTML, XML et XHTML

- Syntaxe XML (voir poly p. 50) : remarques
  - Caractères spéciaux
    - Les caractères "<" (inférieur) et "&" (esperluète) sont interdits dans les contenus. On aura recours aux entités "<" et "&".
    - L'usage de ">" (supérieur) ou des guillemets simples ou doubles peut également être perturbant. Dans ce cas, on a recours à ">", "'" et """.
    - Si l'on veut vraiment utiliser les caractères "<" ou "&", il est possible de définir une balise sous forme de zone de caractères non analysés (CDATA), sous la forme :

```
<![CDATA [ texte comprenant des caractères
  interdits ]]>
```

HTML, XML et XHTML

- XHTML
  - DTD XML : ensemble (dé)fini de balises XML
  - But : réécrire HTML, mais en plus propre
  - V. 1.0 : janv. 2000, révisée en 2002
  - V. 1.1 : mai 2001 (pas de rapport avec XML 1.1)
  - Trois recommandations
    - XHTML frameset
    - XHTML transitionnel
    - XHTML strict

  ⇒ Séparation du fond et de la forme

  ⇒ Pris en charge par tous les navigateurs récents

  ⇒ Pris en charge par les outils de traitement XML

HTML, XML et XHTML

- Syntaxe (X)HTML :
  - Polycopié : page 21
  - Tutoriel web : http://pci.univ-lyon1.fr/TP/Tutoriel-TP11/

Feuilles de style (X)HTML : CSS

- Buts : définir des caractéristiques de style
  - Standardisées pour être reconnues par tous les navigateurs
  - Dans un langage différent de HTML pour séparer la forme du fond
  - Externalisables pour pouvoir les réutiliser
  - Imbriquables pour pouvoir les appliquer à des sous-ensembles de documents

Feuilles de style (X)HTML : CSS

- Trois niveaux d'application
  - Niveau élément : feuilles de style intégrées
    - Syntaxe : caractéristiques de style dans la valeur de l'attribut `style` de la balise ouvrante
  - Niveau document : feuilles de style incorporées
    - Syntaxe : élément `<style type="text/css">` dans la balise <head> d'un document HTML
  - Niveau site web : feuilles de style liées
    - Syntaxe
      - Caractéristiques de style dans un fichier à part
      - Lien vers ce fichier par son URI dans un document HTML :

      ```
      <link rel="stylesheet" type="text/css" href="URI" /
      ```

Feuilles de style (X)HTML : CSS

- Syntaxe du langage
  - Définition des caractéristiques de style

    ```
    nom_element {caract1:valeur1; caract2: valeur2;…}
    .nom_classe {caract1:valeur1; caract2: valeur2;…}
    nom_element.nom_classe {caract1:valeur1;…}
    ```

  - Application de styles
    - Aux éléments HTML : pas besoin de demander l'application
    - À des classes de style : application par l'attribut `class="nom_classe"`
  - Détail des caractéristiques : poly p. 37.

Document XML valide : les DTD

- Généralités
  - Héritées de SGML
  - Syntaxe : grammaire EBNF
  - Partie intégrante de la recommandation XML
  - Reconnues par tous les parsers XML validants
- Composants
  - Déclaration de type de document (dans le document XML)
  - Définition de type de document (interne ou externe)

Document XML valide : les DTD

- Déclaration de type de document
  - Une et une seule par document XML
  - Placée
    - Après la déclaration XML
    - Avant le début de l'élément racine du document
  - Syntaxe générique

```
<!DOCTYPE Nom_élément_racine Type_de_source
  emplacement1 emplacement2 [sous-ensemble
  interne de DTD]>
```

Document XML valide : les DTD

- Déclaration de type de document

```
<!DOCTYPE Nom_élément_racine Type_de_source emplacement1
   emplacement2 [sous-ensemble interne de DTD]>
```

  - Types de sources
    - Emplacements des fichiers DTD
  - Sources de type SYSTEM
    - DTD internes

```
<!DOCTYPE Nom_élément_racine SYSTEM [sous-ensemble interne]>
```

    - DTD externes
    - Un seul emplacement possible
    - Indiqué par une URI

```
<!DOCTYPE Nom_élément_racine SYSTEM "../DTD/nom_fichier.dtd">
<!DOCTYPE Nom_élément_racine SYSTEM
   "http://www.une_url_quelconque.com.nom_fichier.dtd">
```

Document XML valide : les DTD

- Déclaration de type de document

```
<!DOCTYPE Nom_élément_racine Type_de_source emplacement1
   emplacement2 [sous-ensemble interne de DTD]>
```

  - Sources de type PUBLIC
    - Uniquement des DTD externes
    - Un ou deux emplacements possibles
    - Indiqués par
      - Un identificateur public (reconnu par l'application)

```
<!DOCTYPE HTML PUBLIC "-//W3C//DTD HTML 4.01//EN">
```

      - Un identificateur public + une URI

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

Document XML valide : les DTD

- Définition de type de document
  - Quatre types de données
    - ELEMENT : un élément XML et son contenu
      - Syntaxe : `<!ELEMENT nom_elt (contenu)>`
      - Types de contenu
        - Autres élément(s)
        - #PCDATA (pour « Parsed Character DATA »)
        - mixte (élément(s) + PCDATA)
        - #ANY (n'importe quel type de contenu XML bien formé)
        - #EMPTY
      - Pour éléments ou mixte : indiquer leur(s) nom(s) séparés par des virgules (« , » : ET) ou des pipes (« | » : OU)
      - Pour éléments, PCDATA ou mixte : contenus entre parenthèses

Document XML valide : les DTD

- Définition de type de document
  - Quatre types de données
    - ELEMENT : un élément XML et son contenu
      - Opérateurs de cardinalité
        - "" (rien) : une et une seule occurrence
        - "?" : zéro ou une occurrence
        - "*" : zéro, une ou plusieurs occurrences
        - "+" : une ou plusieurs occurrences

        Remarque : les opérateurs de cardinalité sont postfixés
      - Exemple de définition d'élément

Document XML valide : les DTD

```
<?xml version="1.0" standalone="no"?>
<!DOCTYPE Texte SYSTEM "Texte.dtd">
<Texte>
 <Titre>
  <Mot>XML</Mot>
 </Titre>
 <Phrase>
  <Mot>XML</Mot>
  <Mot>c</Mot>
  <Ponctuation>’</Ponctuation>
  <Mot>est</Mot>
  <Mot>chouette</Mot>
  <Ponctuation>.</Ponctuation>
 </Phrase>
</Texte>

<!ELEMENT Texte (Titre, Phrase+)>
<!ELEMENT Titre (Mot+,(Ponctuation, Mot+)*)>
<!ELEMENT Phrase (Ponctuation?, (Mot+, Ponctuation)+)>
<!ELEMENT Mot (#PCDATA)>
<!ELEMENT Ponctuation (#PCDATA)>
```

Document XML valide : les DTD

- Définition de type de document
  - Quatre types de données
    - ATTLIST : ensemble des attributs d'un élément XML
      - Syntaxe

      <!ATTLIST nom_element
      nom_att type_att déclaration_valeur_implicite>
      - Types d'attributs
        - CDATA : chaîne textuelle simple
        - Valeurs énumérées dans une liste entre parenthèses et séparés par des pipes.
        - ID : identifiant unique ; un seul attribut ID par élément
        - IDREF : référence à un élément identifié par son attribut ID
        - IDREFS : liste de plusieurs IDREF séparés par des espaces
        - NMTOKEN : jeton de nom qui permet de limiter le nombre de valeurs que peut prendre l'attribut
        - NMTOKENS : liste de jetons de noms séparés par des espace
        - ENTITY : nom d'une entité prédéfinie
        - ENTITIES : liste de plusieurs entités séparés par des espaces
        - NOTATION : type de notation déclaré ailleurs dans la DTD

Document XML valide : les DTD

- Définition de type de document
  - Quatre types de données
    - ATTLIST : ensemble des attributs d'un élément XML
      - Syntaxe

```
<!ATTLIST nom_element
  nom_att type_att déclaration_valeur_implicite>
```

      - Déclaration de valeur implicite
        - `#REQUIRED` : obligatoire
        - `#IMPLIED` : facultatif sans valeur par défaut
        - `"valeur"` : facultatif avec valeur par défaut
        - `#FIXED "valeur"` : facultatif, mais s'il est présent, il doit obligatoirement avoir la valeur indiquée

Document XML valide : les DTD

```
<Livre titre="Développer en XML avec Java 2" auteurs="C. Daconta,
Al Saganich" isbn="2-7440-1099-5" editeur="CampusPress"
idlivre="L1">
 <Table_des_matieres>
  ...
 </Table_des_matieres>
 <Resume>
  ...
 </Resume>
</Livre>

<!ELEMENT Livre (Table_des_matieres, Resume)>
<!ATTLIST Livre
        titre           CDATA                   #REQUIRED
        isbn            CDATA                   #REQUIRED
        auteurs         CDATA                   #REQUIRED
        editeur         CDATA                   #IMPLIED
        date_publi      CDATA                   #IMPLIED
        prix            CDATA                   "0"
        avis            (TB|B|P)                #IMPLIED
        idlivre         ID                      #REQUIRED>
```

Document XML valide : les DTD

- Définition de type de document
  - Quatre types de données
    - ENTITY : séquence de caractères repérée par un nom
      - Syntaxes

```
<!ENTITY nom_entité "valeur">
<!ENTITY % nom_entité "valeur">
<!ENTITY nom_entité SYSTEM "URI">
<!ENTITY nom_entité PUBLIC "URI1" "URI2">
```

      - Associent à nom_entité soit la valeur entre guillemets, soi
        la valeur définie dans la ressource pointée par les URI.
      - Les deux premiers exemples définissent des « entités internes » et les deux derniers des « entités externes »

Document XML valide : les DTD

- Définition de type de document
  - Quatre types de données
    - ENTITY : séquence de caractères repérée par un nom
      - Syntaxes

```
<!ENTITY nom_entité "valeur">
<!ENTITY % nom_entité "valeur">
<!ENTITY nom_entité SYSTEM "URI">
<!ENTITY nom_entité PUBLIC "URI1" "URI2">
```

      - Le deuxième exemple définit une « entité paramètre », qu n'est utilisable que dans la DTD et référençable par `%nom_entité;`
      - les trois autres définissent des « entités générales » référençables par `&nom_entité;` dans la DTD et dans le document XML

Document XML valide : les DTD

- Définition de type de document
  - Quatre types de données
    - NOTATION : séquence de caractères non XML destinées à être traitées par une application particulière
      - Syntaxes

```
<!NOTATION nom_notation SYSTEM "URI">
<!NOTATION nom_notation PUBLIC "URI1" "URI2">
```

      - Les notations sont déclarées comme des entités externes
      - Il est possible d'utiliser les noms de notations comme types d'attributs