

# Langages à balises : une introduction

LIONEL MÉDINI  
UFR INFORMATIQUE  
UNIVERSITÉ CLAUDE BERNARD LYON 1

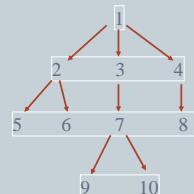
D'après le cours de Yannick Prié  
2010-2011 – Master SIB  
M1 – UE 3 / Bloc 2 – Cours 1

## Objectifs de ce cours introductif

- Introduction aux langages à balises et à leurs principes
    - arbres
      - ✖ définition
      - ✖ grammaires
    - balises et balisage
    - langages à balises
      - ✖ historique de ces langages
      - ✖ présentation des principaux langages de la « galaxie XML »
      - ✖ présentation de la suite du cours

# Parler des arbres

- Arbre
  - Nœud
    - nœuds fils et pères
  - Racine
  - Feuille
  - Chemin
    - suite de nœud
  - Branche
    - chemin se terminant sur une feuille
  - Ancêtres et descendants
  - Taille d'un arbre
    - nombre de nœuds
  - Profondeur d'un nœud

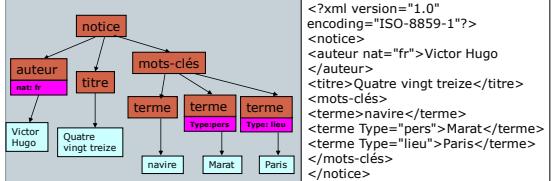


## Objectif généraux du module

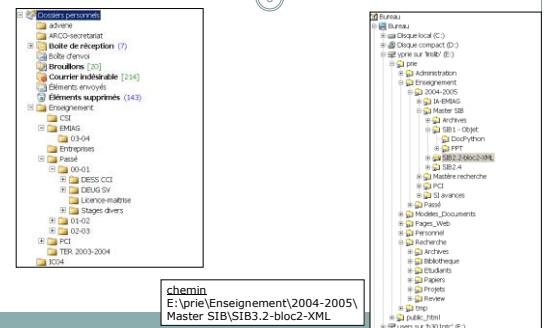
- Comprendre les grands principes de la représentation de données et de documents numériques à l'aide d'un langage à balises
  - Découvrir XML, son histoire et son fonctionnement
  - Définir des langages basés sur XML à l'aide de DTD
  - Apprendre les bases de XHTML pour la génération de pages web
  - S'initier à la transformation de documents en utilisant XSL et un moteur XSLT

## Idée générale

- Représenter de l'information dans des structures arborescentes
  - Coder ces structures dans des fichiers, qui pourront être échangés



## Les arbres sont partout !



## Parcours d'arbre

(7)

- Largeur d'abord**

$$\begin{array}{l} 1 \\ \rightarrow 2 \rightarrow 3 \rightarrow 4 \\ \rightarrow 5 \rightarrow 6 \rightarrow 7 \rightarrow 8 \\ \rightarrow 9 \rightarrow 10 \end{array}$$

```

graph TD
    1[1] --> 2[2]
    1 --> 3[3]
    1 --> 4[4]
    2 --> 5[5]
    2 --> 6[6]
    3 --> 7[7]
    4 --> 8[8]
    5 --> 9[9]
    5 --> 10[10]
  
```
- Profondeur d'abord**

$$\begin{array}{l} 1 \rightarrow 2 \rightarrow 5 \rightarrow 6 \\ \rightarrow 3 \rightarrow 7 \rightarrow 9 \rightarrow 10 \\ \rightarrow 4 \rightarrow 8 \end{array}$$

## Notion de grammaire

(8)

- Définition**
  - Une grammaire est un système formel qui définit complètement un arbre
- Contenu**
  - vocabulaire
  - règles de production
    - Avec une syntaxe spécifique
- Exemple du système de fichiers**
  - Vocabulaire
    - D (Dossier)
    - F (fichier)
  - Règles
    - Départ : D
    - $D \rightarrow (D|P)^*$
  - Syntaxe des règles

Règle	Signification
*	Zéro, un, plusieurs
	OU

```

graph TD
    D[D] --> D1[D]
    D --> F1[F]
    D1 --> D2[D]
    D1 --> F2[F]
  
```

## Grammaire : autre exemple

(9)

- Vocabulaire**
  - A, B, C, D
- Règles**
  - Départ : A
  - $A \rightarrow B+$
  - $B \rightarrow (B, C^*) \mid D$
  - $C \rightarrow (D \mid B)$
- Syntaxe des règles**

Règle	Signification
*	Zéro, un, plusieurs
+	Un ou plusieurs
	OU
,	ET

→ Question  
quel est le plus petit arbre que l'on peut écrire avec cette grammaire ?

```

graph TD
    A[A] --> B1[B]
    A --> B2[B]
    A --> C1[C]
    B1 --> D1[D]
    B1 --> D2[D]
    B2 --> C2[C]
    C1 --> B3[B]
    C1 --> C3[C]
    B3 --> D3[D]
    B3 --> D4[D]
  
```

## Notions de balise et de balisage

(10)

- Définitions**
  - Donnée : valeur associée à un type de données
    - Décrise 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

## Notions de balise et de balisage

(11)

- 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

## Notions de balise et de balisage

(12)

- 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. « métainformation »)

## Notions de balise et de balisage

- 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)

## Notion de langage à balises

- Tous les langages ayant pour objectif de représenter de l'information en utilisant des balises

- Définis par

- vocabulaire
    - \* noms des éléments
  - grammaire
    - \* mode d'organisation des éléments
      - des éléments en contiennent d'autres
  - + attributs des éléments
    - \* un peu plus de structure (voir cours XML)
  - Une description
    - ensemble d'éléments organisés dans un fichier
    - contenus terminaux (texte)

- Une description

- ensemble d'éléments organisés dans un fichier
  - contenus terminaux (texte)

## Notion d'élément

15

- Problème

- Un fichier est une suite d'octets

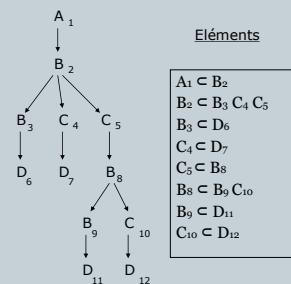
→ Comment représenter une structure d'arbre dans un fichier ?

- Solution

- décrire l'arbre comme un ensemble d'éléments qui se contiennent les uns les autres.
  - représenter les éléments entre deux balises
    - \* **balises ouvertes**
      - on les notera par exemple <nom>
    - \* **balises fermantes**
      - on les notera par exemple </nom>

## Exemple

- 16 -



```
<A>
  <B>
    <B>
      <D></D>
    </B>
    <C>
      <D></D>
    </C>
    <C>
      <B>
        <B><D></D></B>
        <C><D></D></C>
      </B>
    </C>
  </B>
</A>
```

## Types de langages à balises

1

- Langages de *balisage procédural*

- permettent de décrire la mise en forme (formatage) d'un document
  - ex. : PS, RTF, TeX, HTML

### Exemple 1/3

- Le langage Postscript

```
%!PS-Adobe-3.0
%%Title: Microsoft Word -
Document1
%%Creator: PSCRIPT.DRV
Version 4.0
%%CreationDate: 03/02/02
10:47:00

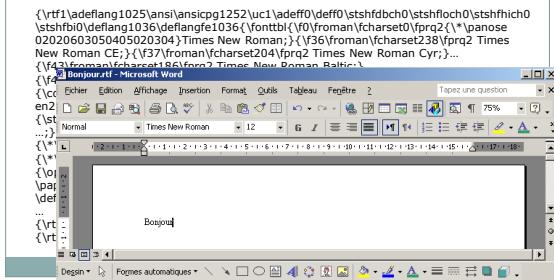
%%EndComments
%%BeginProlog
%%BeginProcSet:
Pscript_Res_Email 1.0 0
/defineresource
where {pop} /userdict
begin /defineresource {userdi
ct /Resource 2
...
}ifelse /bind readonly def
end;false
%%EndProcSet

%%BeginResource: file ...
%%EndResource
...
%%EndProlog
%%BeginSetup
...
%%BeginFeature:
*PageSize A4
...
%%EndFeature
...
%%EndSetup
...
%%BeginPageSetup
%%Page: 1 1
%%BeginPageSetup
...
%%EndPageSetup
...
%%IncludeFont: Courier
...
(Courier) cvn /Type1
...
(Essai impression)S
...
(%[ % Page: 1 %]%) =
%%PageTrailer
%%Trailer
%%DocumentNeededFonts:
%%DocumentFonts:
/Pscript_Win_Driver /ProcSet
findresource dup /terminate get
exec
Pscript_Win_Compat dup
/terminate get exec
%%Pages: 1
(%[% LastPage %]%) =
%%EOF
```

## Exemple 2/3



- Le langage RTF



## Exemple 3/3



- HyperText Markup Language (HTML)

```
<ul>
  <li>tutorial : <a href="http://www.python.org/tut">http://www.python.org/tut</a></li>
  <li>documentation : <a href="http://www.python.org/doc">http://www.python.org/doc</a></li>
  <li>telecharger : chargement de la dernière version :
    <a href="http://www.python.org/download">http://www.python.org/download</a><br>
  </li>
</ul>
<ul>
  <li>point t l'executer: charge Dr Python :
    <a href="http://drpython.sourceforge.net">http://drpython.sourceforge.net</a>
    (vous aurez aussi besoin de la librairie graphique WxWidget :
      <a href="http://www.wxwidgets.org">http://www.wxwidgets.org</a>).</li>
  <li>quelques parents (PPT) sur le :
    <a href="http://cern.cern.ch/~lgrandi/pythonintro.ppt">structures de données</a> par Claudio Grandi (Université de Bologne)</li>
  <li>une : <a href="http://www.cis.upenn.edu/~fcole391/cse391_2004/PythonIntro.ppt">introduction</a>
    (PPT aux structures de base de Python, aux instructions de base, et &grave; la syntaxe, par Matt Buenerd (Université de Pennsylvanie)</li>
</ul>
```

The screenshot shows a course page for 'Introduction à la programmation orientée-objet (SIB M1 / 2004-2005)' by Yannick Piat - UFR Informatique - Université Claude Bernard Lyon 1. The page contains course descriptions for TD1, TD2, and TD3, along with links to various resources like Python documentation and introduction slides.

## Types de langages à balises



- Langages de *balisage descriptif*

- se contentent de décrire les données, sans but de traitement
- ex. : RDF, OWL, MathML, n'importe quelle structure documentaire

The screenshot shows an XML example for describing a poem. It includes a list of descriptive points and the corresponding XML code.

- Décrire une notice bibliographique
  - notice, titre, auteur, mots-clés, terme, résumé, ...
- Décrire un poème :
  - poème, quatrain, tercet, vers, ...

```
<notice>
<auteur nat="fr">Victor Hugo
</auteur>
<titre>Quatre vingt treize</titre>
<mots-clés>
<terme>navire</terme>
<terme Type="pers">Marat</terme>
<terme Type="lieu">Paris</terme>
</mots-clés>
</notice>

<poeeme type="sonnet">
<quatrain>
<vers>Je vis, je meurs ; je me brûle
et me noie.</vers>
<vers>J'ai chaud extrême en
endurant froidure ; </vers>
<vers>... </vers>
<vers>... </vers>
</quatrain>
...
</poeeme>
```

→ vocabulaires différents  
→ grammaires différentes  
→ mais même manière d'exprimer les descriptions

## Types de langages à balises



- Méta-langages de balisage

- Langage avec lequel on peut définir d'autres langages
- Pour les langages à balises
  - \* langage exprimant la manière dont on peut décrire une famille de langages à balise
    - comment exprimer les éléments ?
    - comment organiser les éléments ?
  - Exemples de métalangages
    - \* SGML
      - permet de définir : TEI, HTML...
    - \* XML
      - permet de définir : SVG, TEI, XHTML...

## 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)

## 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 espaces 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

## 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 (2<sup>e</sup> édition)
- 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...

## Remarque sur la normalisation

### • Norme industrielle

- Référentiel publié par un organisme officiel (ISO, AFNOR...).
- En anglais : *standard*

### • Standard

- Référentiel publié par une entité privée
- Si diffusion large : standard *de fait*

### • Consortium

- Ensemble d'entreprises, de centres de recherche, de particuliers qui s'allient pour définir des normes et standards sur tout et n'importe quoi
- Gain : fournir les outils au moment où le référentiel est publié
  - \* JPEG (Joint Picture Expert Group) → norme ISO
  - \* MPEG (Moving Picture Expert Group) → norme ISO
  - \* W3C (World Wide Web Consortium) → standards
  - \* ...

## SGML

(29)

- Objectif : représenter l'information contenue dans un document indépendamment
  - des systèmes utilisés pour la saisie et le traitement
  - de la forme physique qu'il sera amené à prendre (papier, CD-ROM, web...)
  - des langues et des alphabets, latins ou non
  - des applications
- Naissance chez IBM (années soixante)
  - GML
  - gestion de la documentation technique
- Normalisation 1986 ISO-8879
  - une dizaine d'années de travail
- Utilisation
  - Description des documents dans les grosses organisations
    - \* complexité des langages
    - \* lourdeur et coût des outils (*chaîne de traitement*)
    - \* Journal Officiel, grosses entreprises/documentations, éditeurs...
  - Echange des documents

## SGML : principes

(30)

### • Métalangage

- permet de décrire des modèles (grammaires)

### • Notion de DTD

- Document Type Definition
- Permet de décrire un modèle
  - \* un type de document

### • Un document SGML

- Est une instance du type de document
- Doit être conforme à la DTD associée

## SGML : exemple

31

The diagram illustrates the XML structure of the `memo.dtd` file and its corresponding DTD definition.

**XML Structure (`memo.dtd`):**

```
<!DOCTYPE memo SYSTEM "memo.dtd">
<memos statut="conf">
  <auteur>Serge Fleury</auteur>
  <dest>
    <dest>André Salem</dest>
    <nom>Salem Samuelien</nom>
  </dest>
  <sujet>Cours SLEEF</sujet>
  <corps>
    <p>...</p>
    <p>...</p>
    <p>...</p>
  </corps>
</memos>
```

**DTD Definition (`memo.dtd`):**

```
<!ELEMENT memos (statut) >
<!--statut: "conf" -->
<!--auteur et dest & sujet et corps-->
<!--dest: <dest>...</dest> -->
<!--ATTLIST memos statut (conf|pub) pub>
<!--ELEMENT sujet (date | nom+)>
<!--ELEMENT corps (par+)>
<!--ELEMENT auteur (date | sujet | nom | par)-->
<!--ELEMENT dest (date | nom+ | par)-->
<!--ELEMENT statut (#PCDATA)-->
```

**Annotations:**

- A red arrow points from the `corps` element in the XML structure to the `<ELEMENT corps (par+)>` declaration in the DTD.
- A green arrow points from the `dest` element in the XML structure to the `<!--ELEMENT dest (date | nom+ | par)-->` declaration in the DTD.
- A blue arrow points from the `sujet` element in the XML structure to the `<!--ELEMENT sujet (date | nom+)>` declaration in the DTD.
- A yellow arrow points from the `auteur` element in the XML structure to the `<!--ELEMENT auteur (date | sujet | nom | par)-->` declaration in the DTD.
- A grey arrow points from the `statut` element in the XML structure to the `<!--ELEMENT statut (#PCDATA)-->` declaration in the DTD.

(d'après <http://www.cavi.univ-paris3.fr/ilpqa/ilpqa/tal/>)

## XML : prérequis

33

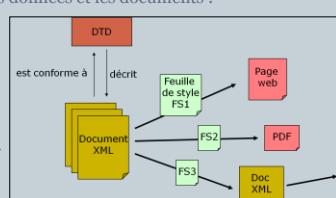
- XML doit être facilement utilisable sur le Web
  - XML doit supporter une grande variété d'applications
  - XML doit être compatible avec SGML
  - Il doit être facile d'écrire des programmes qui traitent des documents XML
  - Le nombre d'options doit être réduit au minimum, idéalement à zéro
  - Les documents XML doivent être lisibles et raisonnablement clairs
  - La conception de XML doit être menée rapidement
  - La description de XML doit être formelle et concise
  - Les documents XML doivent être faciles à créer
  - La concision du balisage XML est d'une importance minime

## Utilisation de XML : principe général

35

- DTDs, Schéma
    - comment décrire les données et les documents ?
  - Documents XML
    - les données et les documents, eux-mêmes dans des fichiers
  - Feuilles de style
    - manière de présenter les données et les documents
  - Remarque
    - on ne sait plus bien où sont les données et où sont les documents

The diagram illustrates the relationship between XML documents and their associated schema and stylesheets. A central yellow stack of three documents is labeled "Document XML". Above it, a red box labeled "DTD" has a downward arrow pointing to the document, with the text "est conforme à" (is conformant to) written vertically next to the arrow. To the right of the document, a green box labeled "Feuille de style FS1" has a downward arrow pointing to the document, with the text "décrit" (describes) written vertically next to the arrow. Three arrows point from the "FS1" box to the three pages of the "Document XML". Below the "FS1" box are two more boxes: "FS2" and "FS3", each with an arrow pointing to one of the three pages of the "Document XML".



## Extended Markup Language (XML)

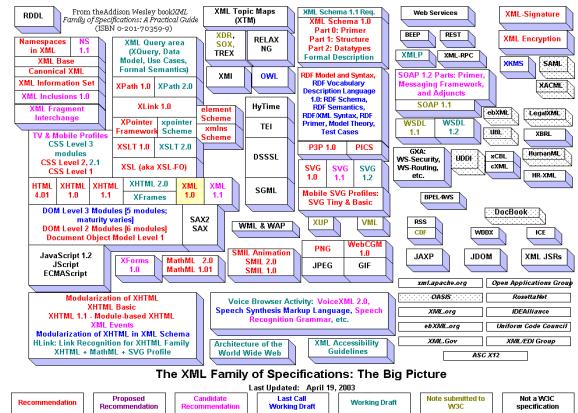
- 32 -

- Position du problème
    - représenter et échanger des données et des documents sur le web
  - SGML
    - un peu vieux
    - trop complexe
  - HTML
    - trop basique
      - \* document = en-tête + corps
    - mélange logique / présentation
      - \* balise **b** = bold (mise en gras) :  
`<b>Attention !</b>`
      - \* bonne approche
        - `<important>Attention !</important>`
        - préservé la chaîne de caractères importante avec une mise en forme particulière (Italique, rouge, gras, etc.)

## XML : principes de base

—

- DTD de SGML (beaucoup plus concis)
    - Restrictions de syntaxe et non de contenu
  - Versions
    - V 1.0 : fév. 1998 -> 04 fév. 2004 (3<sup>ème</sup> édition)
    - V 1.1 : 04 fév. 2004 ; 16 août 2006 (2<sup>ème</sup> éd.)
  - Au même titre que SGML, c'est un métalangage de description des données
    - ⇒ Ça ne sert à rien
    - ⇒ Ça permet de définir des « applications » (types de documents) pour faire ce qu'on veut avec
      - Visualiser des pages web
      - Décrire des images...
    - Chaque document correspondant à une application est appellé « instance »



## XML : intégration dans les SI

(37)

- Stockage de données
  - simples fichiers (ex. configuration)
  - bases de données semi-structurées (requêtes, etc.)
  - bases de données documentaires
    - ✖ documents XML
    - ✖ documents XHTML (web)
- Echange de données
  - d'une base de données vers une autre (format d'échange)
  - serveur vers un navigateur : données + feuille de style
- Remarque :
  - circulation de flux XML sur un réseau :
    - ✖ utilisation de l'arbre entier (le document)
    - ✖ utilisation à la volée pour les très gros documents (exemple : BIM)

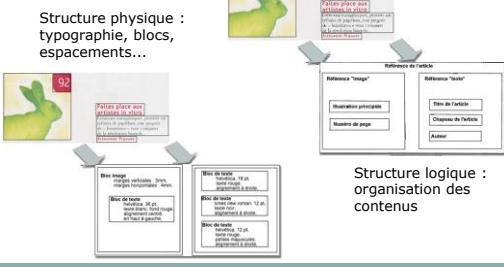
## Retour sur la représentation de documents

(38)

- Document numérique
  - manipulations et gestion par des ordinateurs
- Document structuré
  - séparation structure physique / structure logique
  - séparation forme / contenu
- D'où possibilité
  - de manipuler la structure logique des documents
  - d'accéder au texte des différentes parties logiques des documents
  - de générer plusieurs structures physiques à partir d'une structure logique

## Structures logique / physique

(39)



## Balisage de texte

(40)

- Idée
  - marquer des zones des textes pour les qualifier
    - ✖ les balises ouvrantes et fermantes délimitent les éléments de description
    - ✖ la structure logique est un arbre « ajouté » au texte

< p > Il est de tradition de présenter un langage de programmation à l'aide d'un premier exemple comme : < eg > CHAR\*20 GRTG GRTG = 'BONJOUR TOUT LE MONDE' PRINT \*, GRTG END </ eg > </ p >  
< p > Dans cet exemple, on commence par déclarer la variable < ident > GRTG </ ident >, dans la ligne < kw > CHAR\*20 GRTG </ kw >, qui identifie < ident > GRTG </ ident > comme formée de 20 octets de type < kw > CHAR </ kw >. On affecte alors à cette variable la valeur < mentioned > BONJOUR TOUT LE MONDE </ mentioned >. Suivent alors l'ordre d'impression < kw > PRINT </ kw > et l'instruction finale < kw > END </ kw > . </ p >

p : servira à la mise en page  
eg, kw,mentioned : seront mis en évidence dans la structure physique  
kw,mentioned : utilisés pour utiliser un index etc.

## Conclusion

(41)

- Notions d'arbre et métalangage XML à la base de ce cours
- Utilité
  - pour le Web, l'échange de données, le tagging de documents...
- Suite du module
  - XML : 3 CM / 2 TP
  - (X)HTML / CSS : 2 CM / 2 TP
  - XPATH, XSL : 2 CM / 2 TP
  - Projet
  - Tutorat