XPath

Cours « Document et Web Sémantique »

Nicolas Malandain et Nicolas Delestre

Architecture des Systèmes d'Information

XPath : un langage d'adressage

XPath est un langage non-xml permettant de sélectionner des nœuds dans l'arborescence d'un document XML.

Les 7 types de nœuds d'un document XML :

- le nœud racine,
- les nœuds d'élément,
- les nœuds de texte,
- les nœuds de commentaire,
- les nœuds d'attributs,
- les nœuds d'instruction de traitement,
- les nœuds d'espace de noms.

Remarques :

- le nœud racine "/" contient tout le document XML et donc inclut l'élément racine
- les appels d'entités, et les sections `CDATA` ne sont pas adressables.

Architecture des Systèmes d'Information

Représentation graphique du XML du TD

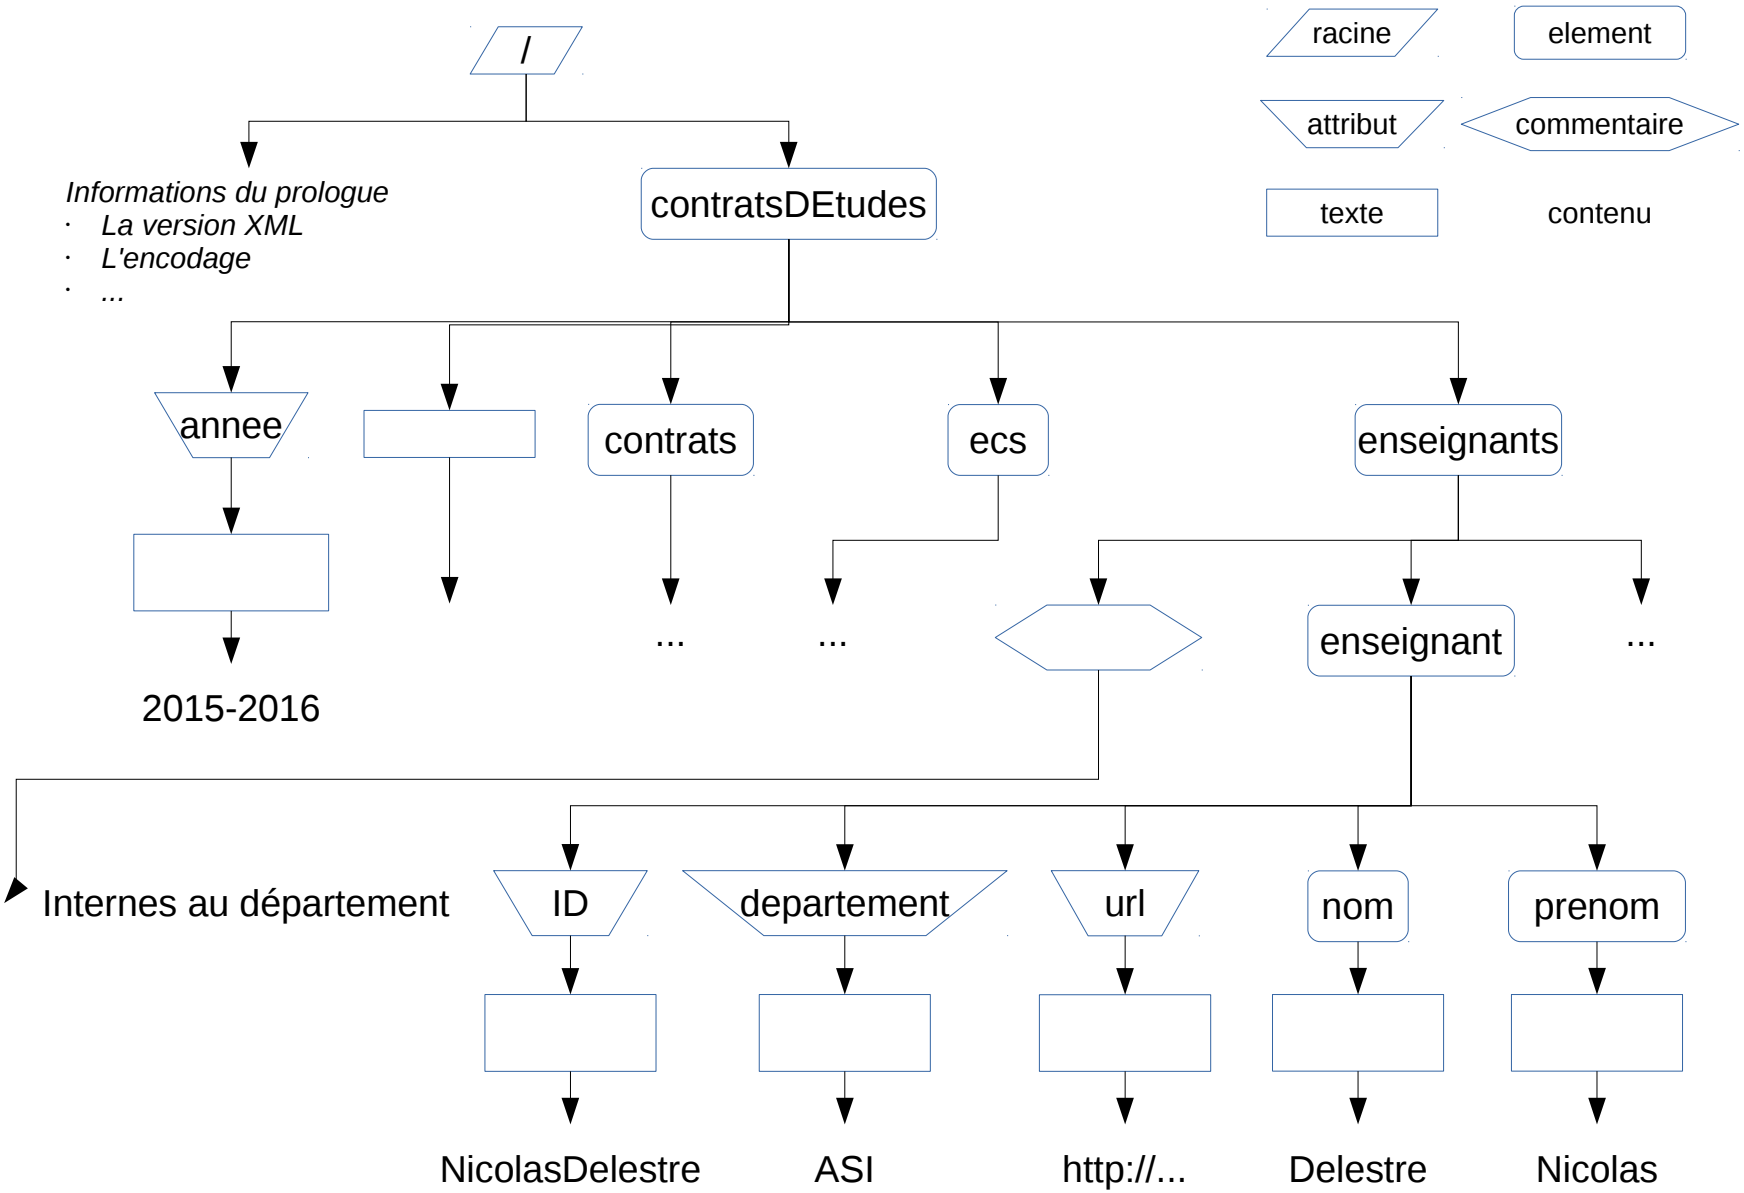

Syntaxe des chemins XPath

Un chemin est une suite de termes sélectionnant un nœud ou ensemble de nœuds. Les termes sont séparés par " /".

Chaque terme sélectionne un nœud, le terme suivant s'y applique pour ajouter une nouvelle condition de sélection.

Syntaxe générale d'un terme

`indicateur_de_relation::filtre[prédicat1][prédicat2]...`

Exemple

`descendant::enseignant[position()=2]`

Sélectionne le deuxième élément du type étudiant descendant du nœud courant

Indicateurs de relation (Axes)

Par rapport au nœud courant :

- `self` lui-même
- `child` sélectionne les nœuds fils
- `descendant` sélectionne les nœuds descendants
- `descendant-or-self` équivalent à `descendant` et `self`
- `parent` sélectionne le nœud racine ou le nœud d'élément parent
- `ancestor` sélectionne les ascendants dans l'ordre inverse d'apparition dans le document
- `ancestor-or-self` équivalent à `ancestor` et `self`
- `following-sibling` sélectionne les nœuds frères suivants
- `preceding-sibling` sélectionne les nœuds frères précédents
- `following` tous les nœuds suivant
- `preceding` tous les nœuds précédents
- `attribute` sélectionne ses attributs
- `namespace` sélectionne les espaces nominaux attachés

asi
Architecture des Systèmes d'Information

Filtres (Tests de nœuds)

Filtres pouvant suivre l'indicateur de relation (axe) :

- *nom d'élément* sélectionne le ou les éléments reliés au nœud courant par la relation indiquée
- *nom d'attribut* sélectionne l'attribut du nœud courant (axe `attribute`)
- `*` sélectionne les nœuds d'éléments de même nature (axe)
- *prefixe*`:*` sélectionne les nœuds d'éléments ayant le même préfixe d'espace de noms
- `node()` sélectionne tous types de nœuds
- `comment()` sélectionne les nœuds de type commentaire
- `processing-instruction(`*nom*`)` sélectionne les instructions de traitement, si le nom n'est pas spécifié les sélectionne toutes
- `text()` sélectionne les nœuds textuels fils du nœud courant

Prédicats

- `and`, `or` et `not()` combinaison de prédicats
- opérateurs `=`, `!=`, `<`, `>`, `<=`, `>=` ; les termes de ces opérateurs peuvent être des nombres, des chaînes de caractères, des expressions arithmétiques (+, -, *, div, mod), ou encore des fonctions
- `@`*`attribut`* vérifie la présence de l'attribut
- *`élément`* vérifie la présence de l'élément
- `not(`*`élément`*`)` vérifie l'absence de l'élément

Architecture des Systèmes d'Information

Fonctions sur les nœuds

- `last()` : position du dernier nœud dans le contexte courant
- `position()` : numéro d'ordre du nœud courant dans la liste de nœuds contextuelle
- `count(`*`liste-nœuds`*`)` : nombre de nœuds inclus dans la liste de nœuds (expression XPath)
- `id("`*`liste-identifiants`*`")` : éléments contenants un des identifiants présents dans la liste
- `local-name(`*`liste-nœuds`*`)` : nom (string) du premier nœud rencontré dans le document appartenant à la liste, s'il n'y a pas d'argument nom du nœud courant. Le nom est retourné sans préfixe
- `namespace-uri(`*`liste-nœuds`*`)` : idem mais retourne uniquement le préfixe
- `name(`*`liste-nœuds`*`)` : idem mais retourne le nom complet

Fonctions sur les chaînes de caractères

- `string(`*`objet`*`)` : retourne l'objet sous forme de chaîne de caractères (ex : s'il s'agit d'un élément, convertit tout le contenu de l'élément)
- `concat(`*`ch1, ch2, ...`*`)` : retourne la concaténation des chaînes de caractères
- `starts-with(`*`ch1, ch2`*`)` : est évalué à vrai si *ch1* commence par *ch2*
- `contains(`*`ch1, ch2`*`)` : est évalué à vrai si *ch1* contient *ch2*
- `substring-before(`*`ch1, ch2`*`)`, `substring-after(`*`ch1, ch2`*`)` : retourne la partie de *ch1* située avant/après *ch2*
- ...

Architecture des Systèmes d'Information

Fonctions booléennes

- `boolean(`*`objet`*`)` : retourne vrai si l'objet est un nombre non nul, une liste non vide de nœuds, ou une chaîne de caractères non vide
- `true()` : retourne toujours vrai
- `false()` : retourne toujours faux
- ...

Architecture des Systèmes d'Information

Fonctions numériques

- `number(`*`objet`*`)` : retourne l'objet sous forme de nombre
- `sum(`*`liste-nœuds`*`)` : retourne la somme des valeurs des nœuds
- `floor(`*`nbr`*`)`, `ceiling(`*`nbr`*`)`, `round(`*`nbr`*`)` : fonctions d'arrondis

Architecture des Systèmes d'Information

Quelques abbréviations

`self::node()`	$\Leftrightarrow$	`.`
`parent::node()`	$\Leftrightarrow$	`..`
`child::`*nom*	$\Leftrightarrow$	*nom*
`/descendant-or-self::`*nom*	$\Leftrightarrow$	*//nom*
`attribute::`*nom*	$\Leftrightarrow$	*@nom*
`[position()=`*x*`]`	$\Leftrightarrow$	[*x*]

Tout chemin commençant par / est absolu (commence à la racine)

$\Rightarrow$ `//@id` sélectionne tous les attributs `id` du document

$\Rightarrow$ `.//@id` sélectionne tous les attributs `id` à partir du nœud courant

Jokers et sélection multiple

Jokers

- `*` tout nœud d'élément
  ne sélectionne pas les attributs, les nœuds de texte, les commentaires ou les instructions de traitement
- `@*` tout nœud d'attribut

Sélections multiples

L'opérateur | permet de sélectionner plus d'un nœud

`cheminXpath1|cheminXPath2|...`

Exemple : `/personne/nom|/animal/nom`

Architecture des Systèmes d'Information

Un outil sous Linux

xmllint

- permet de faire de la validation (dtd, xsd, relaxNG), options :
  - `dtdvalid`, `schema`, `relaxng`
  - `noout`, `xmlout`
- permet de rechercher des nœuds via des XPath, option :
  - `xpath`
- propose un mode interactif (option `shell`), commandes :
  - `cat`, `cd`, `dir`, `ls` , etc.

Architecture des Systèmes d'Information

Quelques références

- XML in a Nutshell, O'Reilly (Elliotte Rusty Harold & W. Scott Means)
- Introduction à XML, O'Reilly (Erik T. Ray)
- XML langage et applications, Eyrolles (Alain Michard)

Architecture des Systèmes d'Information