

Document et Web Sémantique - TP Validation à l'aide de schémas XSD

L'objectif de ce TP est d'utiliser le CI/CD de gitlab pour la validité des fichiers XML à l'aide de schémas XSD.

Préambule

Vous utiliserez `xmllint` pour valider un document XML à l'aide d'un schéma XSD. Il faudra utiliser les options suivantes :

noent pour interpréter les entités ;

noout pour éviter de produire le fichier XML sur la sortie standard lorsque celui ci est valide ;

schema pour indiquer que l'on veut une validation à l'aide d'un schéma XSD.

Le schéma global est décomposé en plusieurs schémas, chacun validant un type de fichier XML.

Question : pourquoi XSD propose deux instructions, `xsd:import` et `xsd:include`, pour inclure un schéma dans un autre ?

Les schémas sont dans le répertoire `xsd` :

specialite.xsd pour valider le fichier XML général, décrivant une spécialité, comme par exemple `iti.xml` ;

contrat.xsd pour valider le fichier XML décrivant un contrat d'un semestre, ceux se trouvant dans le répertoire `contrats` ;

ec.xsd pour valider le fichier XML décrivant un EC, les fichiers se trouvent dans le répertoire `ecs` ;

enseignants.xsd pour valider le fichier XML décrivant les enseignants : `enseignants.xml` ;

competences.xsd pour valider le fichier XML décrivant les savoir-agir, jalons et apprentissages critiques : `competences.xml`.

Il y a aussi des schémas décrivant des types simples et types complexes utilisés dans les précédents schémas :

texte.xsd proposant des types liés au texte (extrait du HTML, `LangString`, etc.)

general.xsd proposant les types `TDuree` et `TDecimalPositif`.

Enfin le schéma `xml.xsd`, issu du w3c, décrit entre autre le type simple `xml:lang`.

A chaque fois que vous choisissez un type XSD, sélectionnez le type le plus contraint. Pour rappel, pour les chaînes de caractères, XSD propose les types :

string Permet d'utiliser n'importe quel texte, y compris plusieurs espaces consécutifs, tabulations et retours à la ligne. Il conserve les espaces multiples.

normalizedString Supprime les retours à la ligne et tabulations, et remplace les espaces multiples par un seul. Il ne supprime pas les espaces en début ou fin de texte.

token Supprime les retours à la ligne, les tabulations et les espaces en début et fin de texte. Réduit les espaces multiples à un seul. Il conserve les caractères spéciaux.

NMTOKEN Permet uniquement des identifiants composés de lettres, chiffres et certains caractères spéciaux (–, _, ., :). Il n’accepte aucun espace ni caractère interdit dans un nom XML.

1 enseignants.xsd

Complétez le fichier `enseignants.xsd` tel qu’il définit :

TDepartement un énuméré avec les valeurs ITI, GM, HUMA, STPI, EXT, DSI, MECA;

TEnseignant un type complexe décrivant un enseignant;

TEnseignants un type complexe décrivant une liste d’enseignants;

enseignants un élément racine de type TEnseignants.

Vérifiez la validité du fichier XML `enseignants.xml`.

2 contrat.xsd

Complétez le fichier `contrat.xsd` tel qu’il définit :

TChoix un énuméré avec les valeurs Obligatoire, Electif et Facultatif;

TECDansUE un type complexe qui décrit les éléments EC au sein des élément UE.

TUE un type complexe qui décrit une UE;

TContrat un type complexe qui décrit un contrat;

Contrat un élément racine de type TContrat.

Vérifiez les validités des fichiers XML se trouvant dans le répertoire `contrats`.

Questions :

- Pourquoi n’avons nous pas appeler le type TECDansUE tout simplement TEC ?
- Quelle limite au pouvoir d’expression de XSD avez vous identifié ?

3 Ajout de la vérification au niveau du CI/CD

Ajoutez un nouveau *stage* et un nouveau *job* pour vérifier le fichier `iti.xml`.