Données ouvertes : traitement, formats

Guillaume Allègre
Guillaume.Allegre@silecs.info

Polytech Grenoble - RICM

2017-2018

Traitements des données

Workflow de données

Récupération des données brutes

- fichier (éventuellement prétraitement manuel)
- API web : récupération au vol
- autant que de sources de données

"Traitement"

- Calculs... (cf suite)

Publication des données raffinées

- format final simple (ex. table HTML)
- mise à disposition d'un webservice (ex. index/recherche)
- visualisation ("*datavisualization*" ou "*dataviz*")

Workflow de données - 2

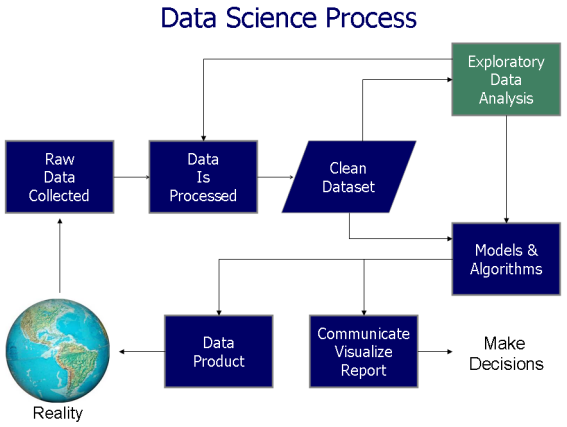

Exemples de traitements - 1

Agrégation

- ex. liste des communes de France, dont population, superficie
- statistiques : moyenne, médiane, quartiles...
- top N : les plus pleuplées, les plus grandes...
- domaine des **statistiques descriptives**

Visualisation

- stats+ : courbes, histogrammes, diagrammes de classes
- dynamique : côté serveur / clients
- cartographie (choroplète, monde, pays, ville...)

Visualisations

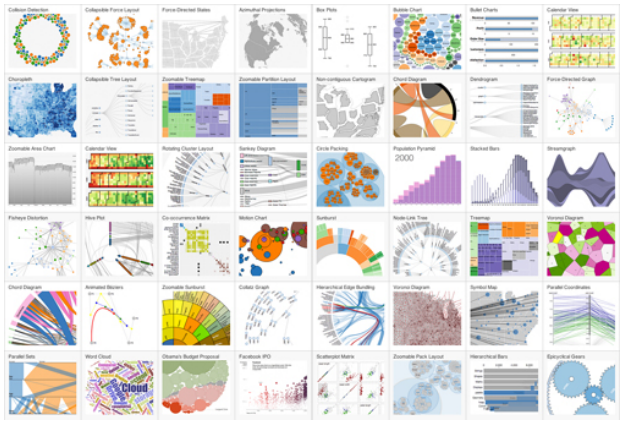

Exemples de traitements - 2 Mashups

Mashups

- utilisations de plusieurs sources de données
- de nature identiques ou différentes
- exemple
  - localisation des crèches et écoles (ex. data.metropolegrenoble)
  - tracés des routes par importance (ex. OpenStreetMap)
  - relevés qualité de l'air (ex. Air Rhône-Alpes)

Précautions

- Cohérence des données (ex. date des collectes)
- "*jointure*" des données : utilisation d'un identifiant commun
- ex. code INSEE pour les communes (ex. 38421 Saint-Martin-d'Hères)

Traitements des données

Échanges

- fichiers : **formats** et systèmes de fichiers
- réseau : **protocoles**

Exploitation des données

- bases de données
  - relationnelles (SQL) : Oracle, MySQL/MariaDB, PostgreSQL
  - bases "NoSQL" : orientées document ou clé-valeur
- langage et structures de données
- (ici PHP)

Rappels : les tableaux en PHP

Pourquoi utiliser des tableaux ?

```php
$val1 = "Moi";
$val2 = "Toi";
$val3 = "Lui";
echo $val1;
```

Quand on a plusieurs valeurs reliées, mieux vaux les mettre dans un tableau.

```php
$val = array("Moi", "Toi", "Lui");
echo $val[0];
```

Les tableaux numériques

- `array(...)` permet de créer un tableau PHP.
- ou `[...]` à partir de PHP 5.4.
- Par défaut, les tableaux sont numérotés à partir de 0.
- Pour accèder à un élément : `$val[...]`
- Pour ajouter à la fin du tableau :

```php
$val[] = array("Nous"); # $val[3]
```


Rappel : les tableaux en PHP 2

- plus précisément : **tableaux associatifs ordonnés**
- paires **clé / valeur** (dictionnaire) :

```php
$tab = array(
"yes" => "oui",
"no"  => "non",
);
```

- **accès aux valeurs** :

```php
// Lecture
echo "Traduction de yes : " . $tab["yes"];
// Ecriture
$tab["never"] = "jamais";
```

- multitude de fonctions pour les tableaux :
  `http://fr.php.net/manual/fr/function.array.php`

Rappel : parcours d'un tableau

Pour ne lire que le contenu des cases

```php
<?php
foreach ($tableau as $valeur) {
    echo "$valeur\n";
}
```

Pour lire à la fois la clé de la case et sa valeur

```php
<?php
foreach ($tableau as $cle => $valeur) {
    echo "$cle -> $valeur\n";
}
```

foreach est la boucle la plus fréquente en PHP !

Ex. d'utilisation d'un tableau structuré

```php
$annuaire = array( [
    'nom' => 'Allegre',
    'prenom' => 'Guillaume',
    'email' => 'allegre.guillaume@free.fr',
    'role' => 'enseignant'],
[
    'nom' => 'Pittion',
    'prenom' => 'Sebastien',
    'email' => 'sebastien.pittion@exemple.fr',
    'role' => 'enseignant'],
[
    'nom' => 'Dupont',
    'prenom' => 'Jeanne',
    'email' => 'jeanne.dupont@e.univ-grenoble-alpes.fr',
    'role' => 'etudiant'],
);
print_r($annuaire);
```


Ex. d'utilisation d'un tableau structuré - résultat `print_r`

```
Array
(
  [0] => Array
    (
      [nom] => Allegre
      [prenom] => Guillaume
      [email] => allegre.guillaume@free.fr
      [role] => enseignant
    )
  [1] => Array
    (
      [nom] => Pittion
      [prenom] => Sebastien
      [email] => sebastien.pittion@exemple.fr
      [role] => enseignant
    )
  [2] => Array
    (
      [nom] => Dupont
      [prenom] => Jeanne
      [email] => jeanne.dupont@e.univ-grenoble-alpes.fr
```


Variante plus structurée

```php
$annuaire2 = array( [
    'etatcivil' => ['nom' => 'Allegre',
                    'prenom' => 'Guillaume',
                    'dnaiss'=>'19740928'],
    'email' => 'allegre.guillaume@free.fr',
    'role' => 'enseignant' ],
[
    'etatcivil' => ['nom' => 'Pittion',
                    'prenom' => 'Sebastien',
                    'dnaiss'=>'00000000'],
    'email' => 'sebastien.pittion@exemple.fr',
    'role' => 'enseignant' ],
[
    'etatcivil' => ['nom' => 'Dupont',
                    'prenom' => 'Jeanne',
                    'dnaiss' => '19940412'],
    'email' => 'jeanne.dupont@e.univ-grenoble-alpes.fr',
    'role' => 'etudiant' ]
);
print_r($annuaire2);
```


Variante plus structurée - résultat `print_r`

```
Array
(
  [0] => Array
    (
      [etatcivil] => Array
        (
          [nom] => Allegre
          [prenom] => Guillaume
          [dnaiss] => 19740928
        )
      [email] => allegre.guillaume@free.fr
      [role] => enseignant
    )
  [1] => Array
    (
      [etatcivil] => Array
        (
          [nom] => Pittion
          [prenom] => Sebastien
          [dnaiss] => 00000000
```


Utilisation d'une classe - validation des données

```php
class EntreeAnnuaire extends stdClass
{
    public $nom;
    public $prenom;
    public $email;
    public $role;

    public function validate()
    {
        ...
    }

}
```

Principaux formats de données

Identifier les formats : MIME

Comment déterminer un type de fichiers ?

- Plusieurs concepts à distinguer
  - l'extension du fichier (si elle existe) : métadonnée (ex. `data.csv`)
  - sa signature (si elle existe)
  - son type MIME (Multipurpose Internet Mail Extensions)
    - `Content-Type: text/plain; charset=UTF-8`
    - protocoles : mail (SMTP), **HTTP**, HTTPS...
    - les applications le prenant en charge
- Techniquement
  - ex. `Content-Type: application/json`
  - ex. `Content-Type: text/csv`, `text/html`
  - `file -i` renvoie le type MIME
  - `/etc/mime.types`, `/etc/mime-magic`

Principaux formats de données

CSV - comma separated values

- fichier tabulé, texte

JSON - JavaScript Object Notation

- format récent, orienté web
- proche des structures des données
- formats dérivés : GeoJson, TopoJson...

XML - eXtended Markup Language

- format très extensible et versatile
- très nombreux formats dérivés
- bien plus lourd que JSON

Formats métiers spécifiques

- ...

CSV et autres formats tableur

CSV - Comma separated values

Le format CSV

- format **tabulé** simple
- lisible à l'oeil humain
- *parsable* assez facilement
- variantes : séparateur (tab, virgule, point-virgule), guillemets

En pratique

- prototypage rapide en shell (ligne de commande Unix)
- lisible dans un tableur (LibreOffice...)
- en PHP, lecture : `fgetcsv()`, `str_getcsv()`
- écriture `fputcsv()`

CSV en PHP

Exemple de données

`borneswifi_EPSG4326.csv`

```
AP_ANTENNE1,Antenne 1,longitude,latitude
AP_APP_GAGNANT,Musée Stendhal Appt Gagnon,5.7280,45.1915
AP_BIB_ABBAYE,Bibliothèque Abbaye,5.7420,45.1794
AP_BIB_ALLIANCE,Bibliothèque Alliance,5.7245,45.1733
AP_BIB_ARLEQUIN,Bibliothèque Arlequin,5.7329,45.1640
AP_BIB_CENTRE_VILLE,Bibliothèque Centre Ville,5.7293,45.1903
AP_BIB_CENTRE_VILLE2,Bibliothèque Centre Ville,5.7293,45.1903
[...]
```

Code : 3 fonctions PHP dédiées

- `fputcsv` formate une ligne en CSV et l'écrit dans un fichier
- `str_getcsv` analyse une chaîne de caractères CSV dans un tableau
- `fgetcsv` obtient une ligne depuis un pointeur de fichier et l'analyse pour des champs CSV

`fgetcsv` par l'exemple

```php
$row = 1;
if (($handle = fopen("test.csv", "r")) !== FALSE) {
    while (($data = fgetcsv($handle, 1000, ",")) !== FALSE) {
        $num = count($data);
        echo "<p> $num champs sur la ligne $row: <br /></p>\n";
        $row++;
        for ($c=0; $c < $num; $c++) {
            echo $data[$c] . "<br />\n";
        }
    }
    fclose($handle);
}
```


Prototypage CSV - filtres Unix

`ls -1 | wc` sortie de `ls` canalisée vers l'entrée du filtre `wc`.

`find /etc |& wc` StdOut et StdErr fusionnées puis canalisées

Exemples

1. `cat` taper `Ctrl+D` = fin de flux
2. `cat liste.txt | wc -l`
3. `wc -l liste.txt`
4. `wc -l < liste.txt`
5. `cat < liste.txt | wc -l`
6. `wc -l liste.txt l2.txt l3.txt`
7. `cat liste.txt l2.txt l3.txt | wc -l`

Filtres textes courants

Principe Unix : une tâche, un outil.

Beaucoup de filtres fonctionnent ligne par ligne :

- `grep` Garde les lignes correspondant à un motif (cf. `WHERE`)
  Ex. `ls / | grep v`
- `cut` Conserve les colonnes données (cf. `SELECT`)
- `head` Premières lignes
- `tail` Dernières lignes
- `sort` Trie les lignes
- `uniq` Enlève les doublons
- moins courants : `tr`, `tac`, `paste`, `fmt`...
- paquet `coreutils`

Exemple complet

En TP !

Les formats tableur

- `XLS` Excel traditionnel
- `XLSX` Excel en XML (récent)
- `ODS` OpenDocument Spreadsheet (LibreOffice...) (XML)

Avantages

- permettent les métadonnées
- permettent la mise en forme (lecture humaine)

Inconvénients

- incompatibles avec les filtres unix
- nécessitent des bibliothèques spécifiques (courantes)
- plusieurs versions / peuvent évoluer

Les formats JSON

JSON

Le format JSON

- format de **sérialisation** de données structurées (tableaux, objets...)
- produit une chaine de caractères : lisible
- *parsable* par une machine
- provient de JavaScript : JavaScript Object Notation
- intégré à tous les langages modernes

Usages

- sérialisation/désérialisation de structures mémoire
- échanges de données
- fichiers de configuration (sans commentaires)

JSON - les types

Les scalaires

- chaîne de caractères, entourée de guillemets
- nombre : un nombre décimal signé
- booléen : True ou False
- Null

Les types complexes

- Tableau (à index numérique)
- Object, incluant les tableaux associatifs

JSON en pratique

En pratique

- en PHP : `json_encode()` et `json_decode()`
- en JavaScript : `JSON.parse()`

Variantes

- HJSON "Human JSON" accepte les commentaires
- BSON "Binary JSON" utilisé par MongoDB
- JSONP "JSON with Padding" : JavaScript inter-sites (ajax...)

echo json_encode($annuaire)

["nom" :"Allegre","prenom" :"Guillaume","email" :"allegre.guillaume@free.fr"
grenoble-alpes.fr","role" :"etudiant"]
[
  {
    "nom" : "Allegre",
    "role" : "enseignant",
    "prenom" : "Guillaume",
    "email" : "allegre.guillaume@free.fr"
  },
  {
    "nom" : "Pittion",
    "role" : "enseignant",
    "prenom" : "Sebastien",
    "email" : "sebastien.pittion@free.fr"
  },
  {
    "nom" : "Dupont",
    "email" : "jeanne.dupont@e.univ-grenoble-alpes.fr",
    "prenom" : "Jeanne",

GeoJSON : un exemple de spécialisation de JSON

Format spécifique de JSON

- format spécialisé pour les objets géolocalisés
- partie géométrique : coordonnées + tracé (**Point**, **LineString**, **Polygon**, MultiPoint, MultiLineString, MultiPolygon)
- partie propriétés libres (nom, description, style d'affichage...)
- 2016 normalisation RFC 7946 par l'IETF
- documentation sur `http://geojson.org`

Outils

- `Leaflet` bibliothèque cartographique javascript très simple
- services en ligne : `http://geojson.io` et `http://umap.openstreetmap.fr`

Exemple - 1

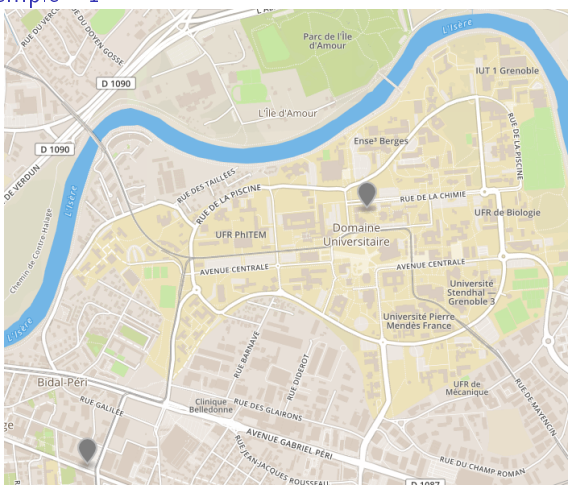

Exemple 1 deux points - 1/2

```geojson
{
  "type": " FeatureCollection ",
  " features ": [
    {
      "type": "Feature",
      " properties ": {
        "marker-color": "#7e7e7e",
        "name": "Polytech"
      },
      "geometry": {
        "type": "Point",
        " coordinates ": [ 5.75368, 45.18426 ]
      }
    },
```


Exemple 1 deux points - 2/2

```geojson
    {
      "type": "Feature",
      " properties ": {
        "marker-color": "#7e7e7e",
        "name": "UFR IMA"
      },
      "geometry": {
        "type": "Point",
        " coordinates ": [ 5.76857, 45.19387 ]
      }
    }
  ]
}
```


Exemple - 2

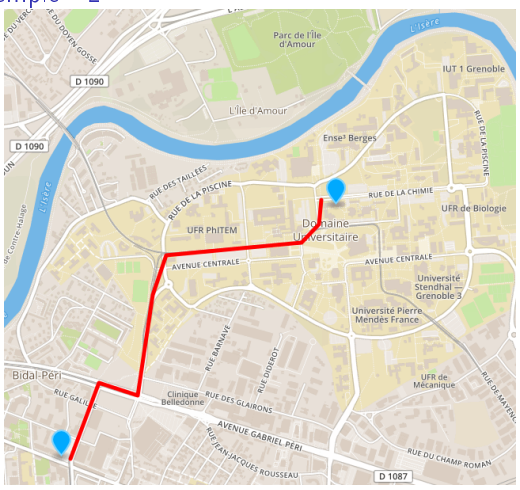

Exemple 2 un itinéraire - 1/2

```geojson
{
  "type": " FeatureCollection ",
  " features ": [
    {
      "type": "Feature",
      " properties ": {
        "marker-color": "#0af",
        "name": "Polytech"
      },
      "geometry": {
        "type": "Point",
        " coordinates ": [ 5.75368, 45.18426 ]
      }
    },
    {
      "type": "Feature",
      " properties ": {
        "marker-color": "#0af",
        "name": "UFR IMA"
      },
      "geometry": {
```


Exemple 2 un itinéraire - 2/2

```geojson
    {
      "type": "Feature",
      " properties ": {
        "stroke": "#f00",
        "stroke-width": "5",
      },
      "geometry": {
        "type": " LineString ",
        " coordinates ": [
          [ 5.75417, 45.1841 ],
          [ 5.75572, 45.1870 ],
          [ 5.75782, 45.1865 ],
          [ 5.75863, 45.1904 ],
          [ 5.75936, 45.1919 ],
          [ 5.76670, 45.1924 ],
          [ 5.76765, 45.1931 ],
          [ 5.76777, 45.1940 ]
        ]
      }
    }
```


Les formats XML

XML - historique 1/2

GML - Generalized Markup Language

- IBM 1967-1969...
- Charles **G**odfarb, Edward **M**osher, Raymond **L**orie $\longrightarrow$ GML
- langage de balisage pour documentation technique (juridique)
- renommé Generalized Markup Language

SGML - Standard Generalized Markup Language

- séparation complète et rigoureuse
  - document technique : texte balisé
  - structure DTD : Document Type Definition
  - feuille de style : présentation dépendant du support
- devient un standard de documentation technique industrielle
- impression, lecture écran, indexation/recherche
- 1986 normalisé ISO 8879 :1986

XML - historique 2/2

HTML - HyperText Markup Language

- application (sous-ensemble) de SGML, jusqu'à HTML5
- **Très** simplifiée
- 1990- créé par Tim Berners-Lee (avec le HTTP)
- nombreuses évolutions, standardisation par le W3C

XML - eXtensible Markup Language

- 1998, Jon Bosak (Sun Microsystems) et Dan Connoly (W3C)
- HTML $\longrightarrow$ besoin d'un SGML simplifié + hypertexte/réseau
- sous-ensemble de SGML, simplifié
- mais fortement **extensible**
- nombreuses applications : XHTML, SVG, RSS, ODS, XLSX....

XML, un exemple

```
<?xml version="1.0" encoding="utf-8" ?>
<annuaire>
    <entree numero="1">
        <etatCivil>
            <nom>Allegre</nom>
            <prenom>Guillaume</prenom>
        </etatCivil>
        <email>allegre.guillaume@free.fr</email>
        <role>enseignant</role>
    </entree>
    <entree numero="2">
        <etatCivil>
            <nom>Pittion</nom>
            <prenom>Sebastien</prenom>
        </etatCivil>
        <email>sebastien.pittion@gmail.com</email>
        <role>enseignant</role>
    </entree>
</annuaire>
```


XML - les principes de base

Une généralisation du HTML

- structure d'arbre avec élément racine unique
- des éléments (balises ouvrantes/fermantes)
- des attributs
- des contenus libres (PCDATA)

Des différences

- élément racine **libre** ($\neq$ `<html>`)
- des éléments libres
- des entités libres `&quelquechose;`
- ...

XML format "robuste" et générique

Deux niveaux de validation

- document **bien formé**
- document **conforme** à un schéma

Des outils standard

- nombreux éditeurs, dont `kate`, `xmlcopyeditor`
- en ligne : `http://utilities-online.info/xsdvalidation`
- `xmllint` en ligne de commande

Document bien formé ?

Validation syntaxique

- déclaration XML obligatoire
- éléments sensibles à la casse
- valeurs d'attributs entre guillemets

Cohérence de l'arbre

- élément racine unique
- éléments fermés (balises ouvrates / fermantes)
- cohérence de la structure d'arbre

xmllint

xmllint

- paquet `libxml2-utils` (debian, ubuntu)
- documentation `man xmllint`
- `xmllint --format` : réindente la sortie
- `xmllint --noout` : supprime la sortie (uniquement le diagnostic)

XML en erreur ! (balise email)

```
1  <?xml version="1.0" encoding="utf-8" ?>
2  <annuaire>
3      <entree numero="1">
4          <etatCivil>
5              <nom>Allegre</nom>
6              <prenom>Guillaume</prenom>
7          </etatCivil>
8          <email>allegre.guillaume@free.fr<email>
9          <role>enseignant</role>
10     </entree>
11     <entree numero="2">
12         <etatCivil>
13             <nom>Pittion</nom>
14             <prenom>Sebastien</prenom>
15         </etatCivil>
16         <email>sebastien.pittion@gmail.com</email>
17         <role>enseignant</role>
18     </entree>
19 </annuaire>
```

xmllint - document mal formé

```
xmllint --noout annuaire.xml
```

```
annuaire1-err.xml:10: parser error :
  Opening and ending tag mismatch: email line 8 and entree
</entree>
^
annuaire1-err.xml:19: parser error :
  Opening and ending tag mismatch: email line 8 and annuaire
</annuaire>
^
annuaire1-err.xml:21: parser error :
  Premature end of data in tag entree line 3
^
annuaire1-err.xml:21: parser error :
Premature end of data in tag annuaire line 2
^
```


Validation de DTD

Limitation de la validité syntaxique

- un document **bien formé** peut être incohérent
- ex. une entrée vide
- ex. `etapCivil` au lieu de `etatCivil`

DTD Document Type Definition

- une DTD est optionnelle
- elle permet de vérifier la **conformité** d'un document /fichier

Outils

- `[xmllint] --valid <fichier.xml>`
- ou `[xmllint] --dtdvalid <fichier.dtd> <fichier.xml>`

fichier annuaire.dtd

```
<!ELEMENT annuaire (entete?,entree+)>
<!ELEMENT entree (etatCivil, email, role, dateNaiss*)>
  <!ATTLIST entree numero CDATA #REQUIRED>
<!ELEMENT etatCivil (nom, prenom)>
<!ELEMENT nom (#PCDATA)>
<!ELEMENT prenom (#PCDATA)>
<!ELEMENT dateNaiss (#PCDATA)>
<!ELEMENT email (#PCDATA)>
<!ELEMENT role (#PCDATA)>

<!ENTITY copy "(C) ">
<!ENTITY licence "Creative Commons CC-By-SA">
<!ENTITY ga "Guillaume Allegre">
```

Remarques :

- syntaxe spécifique aux DTD
- ajout d'**entités** possible dans la DTD

XML "bien défini"

```
<?xml version="1.0" encoding="utf-8" ?>
<!DOCTYPE annuaire SYSTEM "annuaire.dtd">
<annuaire>
    <entree numero="1">
        <etatCivil>
            <nom>Allegre</nom>
            <prenom>Guillaume</prenom>
        </etatCivil>
        <email>allegre.guillaume@free.fr</email>
        <role>enseignant</role>
    </entree>
    <entree numero="2">
        <etatCivil>
            <nom>Pittion</nom>
            <prenom>Sebastien</prenom>
        </etatCivil>
        <email>sebastien.pittion@gmail.com</email>
        <role>enseignant</role>
    </entree>
</annuaire>
```


XML non conforme ! (balise etapCivil, numero)

```
<?xml version="1.0" encoding="utf-8" ?>
<!DOCTYPE annuaire SYSTEM "annuaire.dtd">
<annuaire>
    <entree numero="1">
        <etapCivil>
            <nom>Allegre</nom>
            <prenom>Guillaume</prenom>
        </etapCivil>
        <email>allegre.guillaume@free.fr</email>
        <role>enseignant</role>
    </entree>
    <entree>
        <etatCivil>
            <nom>Pittion</nom>
            <prenom>Sebastien</prenom>
        </etatCivil>
        <email>sebastien.pittion@gmail.com</email>
        <role>enseignant</role>
    </entree>
</annuaire>
```


xmllint - document non conforme DTD

```
xmllint --noout --valid annuaire2.xml
```

```
annuaire2-err.xml:8: element etapCivil: validity error :
    No declaration for element etapCivil
</etapCivil>
^
annuaire2-err.xml:11: element entree: validity error :
    Element entree content does not follow the DTD, expecting
</entree>
^
annuaire2-err.xml:19: element entree: validity error :
    Element entree does not carry attribute numero
</entree>
^
```


Validation par schéma - XSD

Limitations des DTD

- syntaxe obsolète (SGML)
- fonctionnalités de contrôle limitées

XSD (XML Schema Definition)

- syntaxe XML !
- application des outils XML standard (validation, parcours, transformation)
- fusion, réutilisation, héritage des schémas

XSD - fichier annuaire.xsd 1/2

```
<?xml version="1.0"?>
<xs:schema xmlns:xs="http://www.w3.org/2001/XMLSchema">

<xs:element name="annuaire">
  <xs:complexType>
    <xs:sequence>
      <xs:element name="entree" maxOccurs="unbounded">
        <xs:complexType>
          <xs:sequence>
            <xs:element name="etatCivil">
              <xs:complexType>
                <xs:sequence>
                  <xs:element name="nom" type="xs:string"/>
                  <xs:element name="prenom" type="xs:string"/>
                  <xs:element name="dateNais" type="xs:string" minOccurs=
                </xs:sequence>
              </xs:complexType>
            </xs:element> <!--etatCivil-->
```

XSD - fichier annuaire.xsd 2/2

```
19            <xs:element name="email" type="xs:string"/>
20            <xs:element name="role" type="xs:string"/>
21          </xs:sequence>
22          <xs:attribute name="numero" type="xs:string" use="optional"/>
23        </xs:complexType>
24      </xs:element> <!--entree-->
25    </xs:sequence>
26  </xs:complexType>
27 </xs:element> <!--annuaire-->
28
29 </xs:schema>
```

Remarques

- utilisation obligatoire du mécanisme d'espace de noms `xmlns`
- bien plus verbeux que les DTD

Exemple de conformité XSD

```
xmllint --schema annuaire.xsd --valid --noout
annuaire1.xml

annuaire2-err.xml:8: element etapCivil: validity error :
No declaration for element etapCivil
</etapCivil>
^
annuaire2-err.xml:11: element entree: validity error :
Element entree content does not follow the DTD, expecting (eta
</entree>
^
annuaire2-err.xml:19: element entree: validity error :
Element entree does not carry attribute numero
</entree>
^
```