

Données 1/2 Structurées & XML (Partie II)

Master INFORMATIQUE
Nacer.Boudjlida@loria.fr
 UdLorraine - LORIA

Données 1/2 Structurées & XML

- Les Problèmes:
 - Transformation/fusion/intégration de données fortement structurées
 - Idem pour des données non ou semi-structurées
 - XML, un cas particulier de données non structurées?


Données fortement structurées

Note : Arbre de données (Type et instance)

- Feuilles : types de base
- Nœuds internes : constructeurs de types
- Arcs labellés par les « noms des attributs » (fonctions de projection)
- Notations :
 - $\langle X_1 : T_1, \dots, X_n : T_n \rangle$: produit cartésien (record)
 - $[E : T]$: liste d'éléments E de type T
 - $\ast (E : T)$: ensemble d'éléments E de type T
 - $[i..j]$: intervalle


Données fortement structurées

- Livre : \langle Titre: chaîne, Auteurs: [auteur: chaîne], date : \langle j: [1..31], m: [1..12], an: entier \rangle , éditeur : chaîne \rangle
- Arbre du Type:




Données fortement structurées

- Arbre de l'instance du type:



Données fortement structurées (suite)

- Intégration et « Conflits » [cf. Sheth92]
 - Nommage (1), Structures (2)
 - Domaines (3), etc.



- Processus d'intégration :
 1. Parcours/Comparaison des structures
 2. Résolution des conflits
 3. Intégration
 - Restructuration
 - Conversion des valeurs

1. Comparaison

- Nommage : 'Aut' → 'Auteurs'
- Structure : <auteur : chaîne> → <auteur : <nom: chaîne, prénom : chaîne>>
- Domaine : <m : [1..12]> → <m : [Jan..Dec]>
- ????: <éditeur : chaîne> → ∅

2. Résolution des conflits

- Aut → Auteurs
- <auteur : chaîne> → <auteur : <nom: chaîne, prénom : chaîne>>
- <m : [1..12]> → <m : [Jan..Dec]>
- <éditeur : chaîne> → ∅

3. Intégration

- 3.a. « Ré-écriture » des structures
 - <Auteurs: [auteur: chaîne], Titre: chaîne, ... >
 - <Titre: chaîne, Aut: [auteur: <nom, pren: chaîne>]..>
 - X(A1: [A2: T2], A3: T3, ...)
 - X(A3: T3, B1: [A2: X(B2: T4, B3: T5)], ...)
- Sorte d'algèbre sur les constructeurs de types

3.b. « Ré-écriture » des valeurs


- <12, 12, 1992 > → <12, Déc, 1992 >
- auteur : chaîne → auteur : <nom , pren : chaîne> ?
- [A, B, C, D] → [0..20] ?
- Nombre fini de constructeurs de types
- Nombre fini de règles de ré-écriture de structures
- Souvent, solutions ad hoc

- Intégration de données :
 - Structure: Type 1 → Type 2
 - Valeur: Instances de Type 1 → Instances de Type 2
- Intégration/Fusion de schémas (≈ Type complexe)
 - n * Schémas → 1 Schéma
 - Instances conformes a chacun des n schémas → Instances conformes au schéma résultat

Données fortement structurées (suite)

Intégration données vs Intégration schémas

- (1) dans (2) | (2) dans (1)
- (1) \cup (2) =



UdL, FST, Dépt Informatique

©Nacer.Boudjlida@loria.fr p.13

Données fortement structurées (fin)

- Méta-données supposées disponibles
- Modèle commun de représentation: constructeurs de types et graphe de données
- Domaines des valeurs (généralement) simples
- Cas :
 - Pas de méta-données
 - Valeurs complexes (texte, sons, images, etc.)
 - Valeurs « fragmentées » et distribuées (ex: Web)
- Mêmes types de problèmes et de mécanismes?

UdL, FST, Dépt Informatique

©Nacer.Boudjlida@loria.fr p.14

Résumé

Transformation de données structurées

- Arbre/Grappe de données
- Processus
 - Comparaison
 - Identification des ressemblances/dissembances
 - Transformation
- Opération sur
 - Structure (Type)
 - Instance (Valeur)
- (Souvent) Solutions *ad hoc*

UdL, FST, Dépt Informatique

©Nacer.Boudjlida@loria.fr p.15

Données Semi-Structurées

La suite:

- Transformation de données fortement structurées
- Transformation de données non ou semi-structurées
- XML, un cas particulier de données non structurées

UdL, FST, Dépt Informatique

©Nacer.Boudjlida@loria.fr p.16

Données Semi-Structurées

- Pas nécessairement la même structure pour chaque instance

Délibérement

- « Oublier » le type de l'instance
- Sériialiser les valeurs en annotant chaque élément par sa description : Données « auto-décrites »

UdL, FST, Dépt Informatique

©Nacer.Boudjlida@loria.fr p.17

Données Semi-Structurées (suite)

Exemple : BDOO

```
{{personne : &o1{nom : LeBeauf, Age : 50,
  enft1 : &o2, enft2 : &o3},
```

```
{personne : &o2{prenom : Gentil, Age : 23,
  rel :{mère : &o1, sœur : &o3}}
```

```
{personne : &o3{prenom :Manon,
  pays-naiss : Là-Bas, mère : &o1}
```

```
}
```

UdL, FST, Dépt Informatique

©Nacer.Boudjlida@loria.fr p.18

Notion de graphe de données (suite)

- Graphe de données « objets »

Graphe de données (suite)

- O_i : OID, Identifiant d'objet (logique, physique, URL, etc.)

- *Dans la suite* : Nœuds avec/sans Oid :

$\{a: O_1 \{b: O_2\}\}$ isomorphe à

$\{a: \{b: O_2\}\}$ et à $\{a: O_1\{b: O_2\}\}$

Graphe de données (suite)


- {biblio:

{livre: {auteur: 'A1', auteur: 'A2', date: 2000},

livre: {auteur: 'A3', titre: 'T1', date: 1999},


article: {titre: 'T3', auteur: 'A4'} }

Récursion structurelle : Cas des arbres



Récursion structurelle : Cas des arbres

- S'agit-il des mêmes objets ?



Données semi-structurées: Récursion structurelle

- Égalité/Comparaison/Fusion de graphes de données
- Transformations complexes sur données semi-structurées par :
 - Parcours du graphe de données
 - Construction éventuelle d'un nouveau graphe

1. Cas des arbres (Récursion structurelle)

2. Cas des données cycliques

Récursion structurelle : Cas des arbres

- Récursion jusqu'à atteindre une feuille:
résultat = v ou { }
- { } dénote un graphe a un seul nœud (feuille)
- Quand une racine a plusieurs fils :
décomposition en unions d'arbres
 - $t1 \cup t2 = \{Val(t1), Val(t2)\}$

Récursion structurelle : Cas des arbres

- Trouver tous les entiers

- 1.
- 2.
- 3.
- 4.

Récursion structurelle : Cas des arbres

- Exécuter l'algorithme précédent
- Corrigé

Récursion structurelle : Cas des arbres

- Exercice: Ecrire un algorithme qui permet de ré-écrire les entiers en chaînes. On dispose de deux fonctions:
 - $Est_entier(x) = \text{Vrai si } x \text{ est un entier}$
 - $Int2String(x)$: Transforme l'entier x en chaîne de caractères
($Int2String(1) = 'UN'$; $Int2String(100) = 'CENT'$)

Récursion structurelle : Cas des arbres

- Ré-écrire les entiers en chaînes
- Corrigé

Récursion structurelle : Cas des arbres

- Modèle strict de définition :
 - Pour les valeurs atomiques (Déf. 1)
 - Pour { } (Déf. 2)
 - Pour des nœuds de type {!: t} (Déf. 3)
 - Pour $t1 \cup t2$ (Déf. 4)
- Pour { } : Résultat = { }, toujours
- Pour $t1 \cup t2$: Résultat = $f(t1) \cup f(t2)$

Résumé

Transformation de données non structurées


- Objets auto-décrits
- Pas de structure (typage) forte
- Arbres/Graphes de données
- Données non cycliques (Récursion structurelle)
- A suivre: Données cycliques (Structures Récursives)

2. Cas des données cycliques

- Exemple de données cycliques

Comparaison de données cycliques (suite)

- Considérer le dépliage « infini » des données
- Si $x_1 = y_1, \dots, x_n = y_n$ alors $\text{Objet1} = \text{Objet2}$



Comparaison de données cycliques (suite)

- Deux objets sont égaux si on peut récursivement montrer que leurs arbres de dépliage sont égaux
- Dépliage infinis *mais* chaque dépliage a un nombre fini de sous-arbres (*arbres rationnels/réguliers*)
- Bi-simulation : Egalité sans dépliage

Comparaison de données cycliques (suite)

- x, x' : Nœuds de t_1 ; y, y' : Nœuds de t_2
- Relation de bi-simulation entre les nœuds des graphes ($x \sim y$) satisfait :

1.

2.

Comparaison de données cycliques (suite)

3.

4.

Comparaison de données cycliques (suite)


- Calcul de la relation, si elle existe

Comparaison de données cycliques (fin)

- *Calcul de la relation* :
 - Si n_1, n_2 sont le nombre de nœuds de t_1, t_2 :
 $n_1 * n_2$ itérations
 - Chaque itération : inspection de tous les couples de nœuds des graphes : $O(n_1^2 * n_2^2)$

Comparaison de données cycliques (suite)

- *Exemple: Comparer les structures (corrigé)*



2. Données semi-structurées : Conclusion

- Structures
 - Irrégulières
 - Implicites (extraction ?)
 - Incomplètes
- Absence ou faible typage
- Exemples : OEM, LOREL
- XML : même veine ?

Données 1/2 structurées et XML

- La suite:
 - Transformation de données fortement structurées
 - Transformation de données non ou semi-structurées
 - XML, un cas particulier de données non structurées

3. Introduction à XML et « sa galaxie »


- XML: eXtensible Mark-up Language
 - World Wide Web Consortium (www.w3c.org)
 - Sous-ensemble de SGML (Standard Generalized Mark-up Language) : Gestion Electronique de Documents
 - Description du contenu des documents
 - Objectif Principal : Echange de données
 - Marquage (balisage) « libre » et extensible
 - Hypothèse : Compréhension commune des balises (e.g. XMI pour l'échange de diagrammes UML)

Introduction à XML

- Données *a priori* non interprétées (**P**arsed **C**haracter **D**ATA)
 - Langage facilement analysable
 - Mise en forme du contenu (XML → HTML)
 - CSS** (Cascading Style Sheet) : cf. HTML
 - XSL** (eXtensible StyleSheet Language) : non reconnu comme standard
 - XSLT** transformation ≈ XSL Microsoft (Internet Explorer)
 - Modules, Document profiles, DTDs (→ XML Schémas), ...
 - Génération de browsers Web fondée sur XML?

Introduction à XML

- XHTML**
 - But : être utilisable avec des balises provenant d'autres « vocabulaires » XML, comme
 - SMIL : Synchronized Multi-Média Integration Language
 - SVG : Scalable Vector Graphics
 - XForms : Formulaires Web
 - OFX : Open Financial eXchange



Introduction à XML

- XML :: HTML**
 - Description du contenu
 - Pas d'ensemble prédéfini de balises
 - Support de structures imbriquées ≈ objets complexes (**X**link et **X**pointer) :
 - Liens intra et inter documents
 - Navigation dans des documents XML
 - Données éventuellement auto-décrites :
 - D**ocument **T**ype **D**efinitions
 - D**ocument **C**ontent **D**escription (≈ Typage de document)
 - R**esource **D**escription **F**ramework (pour Méta-données)
 - XML-Schema

Introduction à XML

- XML (très bref) survol**


```

<tutorials>
  <tutorial>
    <author> Nacer </author>
    <email> nacer@loria.fr </email>
    <title Language = "English">
      Databases: Elements of their Story
    </title>
    <date> June-22-2000 </date>
  </tutorial>
</tutorials>
            
```

 - Balise ouvrante
 - Contenu élément
 - Balise fermante
 - Élément
 - Attribut de balise
 - Description d'ensembles

Introduction à XML : Survol de XML (suite)

- Représentation :



Introduction à XML : Survol de XML (fin)

- XML :: Données semi-structurées:**
 - ≈ Graphe de données auto-décrites
 - ≠ Labels dans les nœuds (:: sur les arcs)
 - ≠ Ordre sur les éléments
 - ≠ Processing Instructions, Commentaires, etc.
- XML** : pour l'échange (Constante évolution)

XML : des adresses utiles

- Consortium W3 (tout sur XML et même plus):
<http://www.w3.org/>
- Outils divers pour XML
<http://www.garshol.priv.no/download/xmltools>

Web et Bases de Données


Web et Bases de données

1. Web en tant que bases de données
2. Introduction à Xquery
3. Conclusion

Web en tant que BdD

≠ Accès à des bases via le Web

- Langages de scripts (perl, php, etc.)
- Convertisseurs de formats (médiateurs):
 - Peer-To-Peer vs Représentation Commune
 - Ce qui est ou n'est pas (commercialement) disponible :



Web en tant que BdD

- Le Web comme base de données : pourquoi ?
 - Sources d'informations
 - Introduction d'un peu « d'organisation »
- Interrogation base de données : schéma nécessaire (!?)
- A priori, aucune structure (Web ≈ gigantesque graphe) : quel(s) modèle(s) de données ?

Langages d'interrogation pour le Web (1/3)

- WebSQL: Web modélisé comme une base relationnelle avec 2 relations (virtuelles) i.e. graphe d'objets atomiques
 - Document(url, title, ...)
 - Anchor (Base, label, href)
- Exemple: « Documents sur Nancy dans les serveurs en France »

```
SELECT d.url, d.title
FROM Document d SUCH THAT d MENTIONS "Nancy"
WHERE d.url CONTAINS ".fr"
```

Langages d'interrogation pour le Web (2/3)

- WebOQL: Web modélisé comme un graphe d'objets structurés
- Interrogation :
 - Le Web
 - Une Page
 - Un ensemble de pages liées entre elles
- Restructuration :
 - HTML-HTML
 - HTML-Base de données
 - Base de données-HTML

- XQuery : Influences

- Quilt : langage de requêtes pour XML
- SQL : Modèle « Select from where »
- Xpath 1.0 (*) et XQL : Expressions de chemins
- XML-QL : « binding » de variables
- OQL : aspect fonctionnel du langage avec expressions imbriquées

(*) Notation pour naviguer dans un document XML

- XQuery : les exigences (requirements)

- Non procédural
- Syntaxe en XML et Syntaxe « human readable »
- Cloture du langage
- E/S de XQuery : instances de XQuery Data Model
- Combinaison d'opérateurs y compris des requêtes comme opérandes
- Possibilité de combiner des données de sources différentes
- Agrégation et tri

- XQuery : les exigences (requirements)

- Accès aux méta-données (Schéma, DTD)
- Extensibilité (types, fonctions)
- Applicabilité à tout type de sources XML i.e.
 - Documents stockés en mode natif ou
 - Documents vus comme des documents XML (grâce à des médiateurs ou des convertisseurs de formats)

- La suite :

1. XML-QL : une des influences de XQuery
2. XQuery : des exemples

- Relationnellement complet, pour des données de type relationnel

- Principaux composants du langage:
 - **where** ≈ clauses from + where de SQL
- Exemple:

- Intérêt des « patterns » :

- Spécification du « modèle » de résultat

- Traitement des requêtes :

- « Comparer » le pattern aux données (cf. comparaison de graphes/d'arbres de données semi-structurées)
- Lier les variables
- Retourner les variables de *construct*

- Spécification de la structure du résultat :

```
<query>
  where
  <freedb>
    <author> $A </author>
    <dbms> $D </dbms>
    <generation> OO </generation>
  </freedb> in "www.acm.org/..."
  construct
    <result> <author> $A </author>
    <result> <dbms> $D </dbms>
  </result>
</query>
```

```
<result>
  <author>
    <name> --- </name>
  </author>
  <dbms> --- </dbms>
</result>
.....
<result>
  .....
</result>
```

- Prise en compte des différences de structures
 - Pas le même ensemble de balises
- Exemple: <release> non présent partout
 - SGBD et leur release, quand elle existe

```
where <freedb> $F </freedb> in "www.acm.org/...",
      <dbms> $D </> in $F
construct
  <result> <dbms> $D </dbms>
    where <release> $R </> in $F
    construct <release> $R </release>
  </result>
```

- Principaux types d'expression XQuery
 - Expressions de chemin
 - Expressions For Let Where Return (*FLoWeR*)
 - Expressions avec opérateurs et fonctions
 - Expressions conditionnelles
 - Expressions avec quantificateurs
 - Expressions testant ou modifiant les types de données

- Expressions de Chemins: Prédicats filtrant un ensemble de nœuds
 - document("fichier.xml") : nœud racine
 - . équivaut à self::node()
 - .. équivaut à parent::node()
 - nom équivaut à child::nom (/)
 - @nom équivaut à attribut::nom
 - // équivaut à /descendant-or-self::node(/)

- **document("zoo.xml")//chapter[2]//figure[caption = "Tree Frogs"]**
 - Nœud racine : zoo.xml
 - 2ème descendant du nœud racine : <chapter[2]>
 - Recherche des éléments <figure> n'importe où dans l'élément <chapter>
 - Sélectionner ceux ayant un attribut <caption> avec la valeur "Tree Frogs".
- **document("zoo.xml")//chapter[2 TO 5]//figure**

[FOR | LET] ... WHERE ... RETURN

```
FOR $b IN
  document("bib.xml")//book
WHERE $b/publisher = "Morgan
  Kaufmann"
AND $b/year = "1998"
RETURN $b/title
```

```
LET $b := document("bib.xml")//book
RETURN $b/title
  [unordered()|distinct()]
```

- Consortium W3 (tout sur XML et même plus):
<http://www.w3.org/>
- Outils divers pour XML
<http://www.garshol.priv.no/download/xmltools>
- Implantations de XQuery
<http://www.softwareag.com/developer/quip>
<http://www.xhive.com/>

Conclusion : Bases de données vs Web

■ Bases de données

- Distinction entre les niveaux logiques et physiques
- Données structurées et fortement typées (schémas)
- Langages de description et de manipulation
- Concurrence, etc.

■ Sources Web:

- Données non ou semi-structurées ("typage faible")
- (Souvent) pas de schéma (méta-données)
- Pas (encore) de langage d'interrogation

Conclusion : Bases de données vs Web (suite)

■ Modèles de données

- Objets, ODMG

■ Stockage

- Fichiers texte
- Base relationnelle/objet
- Graphes/Arbres

■ Indexation

- cf. objets complexes
- Maintenance des index?

■ Schéma de données

- Bases sans schéma ?
- Extraire le schéma des données?
- Reverse engineering (HTML to XML schema) ?

Conclusion : Bases de données vs Web (suite)

■ Langage de requêtes

- SQL-Like, OQL
- Xquery
- Comparaison des Objets
- Egalité profonde/de surface
- Traitement des requêtes
- Cf. requêtes distribuées
- Avec/sans méta données ?
- Portée des requêtes ?
- Cycles données/hyperliens?
- Une fédération de sources?
- World-wide ?
- Complexité et efficacité ?
- Image, son, ...

■ Hétérogénéité

Conclusion : Bases de données vs Web (suite)

■ Optimisation de requêtes ?

- Mises à jour des sources ?
- Transactions ? Reprise ?
- Data mining vs Web mining
- Intégration Schémas/Vues
- Intégration de données hétérogènes

Du Relationnel au Web: Conclusions

- Noyau de la technologie BdD comme base (conceptuelle) : Besoin d'adaptation et d'extensions
- Ne pas "ré-inventer la roue"
- D. Suciu (Keynote address, 7th Intern'l Conf. On Database Systems for Advanced Applications, "Web Data and the Resurrection of Database Theory):
"new artefacts are not concepts but standards"
- Nouveaux défis : hétérogénéité (données et structures), efficacité (stockage, requêtes), etc.


Données 1/2 Structurées & XML : La suite

- Données structurées versus données semi-structurées
- XML et une partie de sa « galaxie »
 - Standards autour de XML: XSLT , XLINK, XPOINTER, ...
 - Métadonnées, Grammaire et Schema (XML-Namespace, DTD, XML-Schema)
 - Localisation et évaluation de requêtes (XPath et XQuery)
 - XML et les Bases de Données, orientation documents et données
- Sécurité
 - Dans les Bases de Données
 - Modèles de contrôle d'accès pour les Bases de Données XML.

That's all Folks !

Merci de votre attention.

Questions ?



Éléments de bibliographie

- K. Sivashanmugam, K. Verma A. Sheth and J. Miller, Adding Semantic to Web Services Standards, *1st Intern'l Conference on Web Services (ICWS'03)*, Las Vegas, Nevada, June 2003, pp. 395-401
- A. Kiryakov, B. Popov, I. Terziev, D. Manov, D. Ognyanoff, Semantic Annotation, Indexing, and Retrieval. *Elsevier's Journal of Web Semantics*, Vol. 2, Issue (1), 2005.
- N. Boudjlida and D. Cheng, Complement Concept and Capability Discovery, in *proceedings of the CaiSE (Conference on Advanced Information Systems Engineering) EMOI'04 (Enterprise Modelling and Ontologies for Interoperability) Open Workshop*, Vol.3, p.337-342, J. Grundspenkis and M. Kirikova Editors, Riga, Latvia, 7-11 June 2004.
- Silvana Castano, Maria Grazia Fugini, Giancarlo Martella, Pierangela Samarati, *Database Security*, Addison-Wesley & ACM Press 1995.

Éléments de bibliographie

- N. Boudjlida and H. Panetto, editors. *Proceedings of the 2nd International Workshop on Enterprises and Networked Enterprises Interoperability (ENEI)* in J. Eder and S. Dustdar eds, Business Process Management Workshops, BPM 2006 International Workshops, Vienna, Austria, September 2006, LNCS# 4103, Springer-Verlag, June 2006. ISBN 10: 3-540-38444-8.
- Serge Abiteboul, Peter Buneman, Dan Suciu, *Data on the Web: From Relations to Semistructured Data and XML*, Morgan Kaufmann Publishers, October 1999.
- J. Krogstie, C. Rolland, and N. Boudjlida, editors. *Journal of Enterprise Information Systems, Special Issue on Interoperability of Enterprise Systems and Applications*, 2006. Vol. 3, Issue 1.
- N. Boudjlida and H. Panetto. *Enterprise semantic modelling for interoperability*. In Proceedings of the 12th IEEE International Conference on Emerging Technologies and Factory Automation, ETFA 2007, 25-28 September, Patras, Greece, 2007.