Intégration et entrepôts de données
Documents structurés – XML & JSON

Dan VODISLAV

CY Cergy Paris Université

Master Informatique M1

Cours IED

Plan

- Rappels XML: format, XPath, XQuery
- Bases de données XML
- Stockage XML
  - Stockage relationnel
  - Stockage natif
- Indexation XML
- Interrogation XML
  - SQL/XML
- XML dans Oracle

Données vs documents

- BD traditionnelles
  - Contenu structuré, typage fort, contraintes d'intégrité
  - Modèles relationnel, objet, …
  - Langages d'interrogation puissants: SQL, OQL, …
- Web
  - Contenu sous forme de documents non structurés: texte, balises HTML
  - Requêtes mots-clés
- Besoin de compromis
  - Pouvoir exploiter le texte des documents
  - Introduire de la structure, du typage, des contraintes d'intégrité
  - Langages d'interrogations plus puissants

XML

- XML: eXtensible Markup Lanuage
  - Langage de description de documents structurés
  - Utilisation de balises (balisage structurel)
- Standard W3C pour l'échange/publication de données sur le web
- Héritage:
  - HTML: documents publiés sur le web, mais ensemble de balises fixé, dédiées à la *présentation* du contenu → difficile à exploiter le contenu
  - Données structurées: bases de données, contenu structuré, mais mal adapté à la structure des documents web (texte, structure irrégulière)

  → XML décrit *le contenu* de façon (semi-)structurée, *flexible*, adaptée aux documents du web

Exemple

- HTML

```
<h1>Bibliographie</h1>
<ul><li>G. Gardarin, <i>XML : Des Bases de Données aux Services Web</i>, Dunod, 2003
    <li>S. Abiteboul, N. Polyzotis, <i>The Data Ring</i>, CIDR, 2007
</ul>
```

- XML

```
<bibliographie>
  <ouvrage année="2003">
    <auteur>G. Gardarin</auteur>
    <titre>XML : Des Bases de Données aux Services Web</titre>
    <éditeur>Dunod</éditeur>
  </ouvrage>
  <ouvrage année="2007">
    <auteur>S. Abiteboul</auteur>
    <auteur>N. Polyzotis</auteur>
    <titre>The Data Ring</titre>
    <conférence>CIDR</conférence>
  </ouvrage>
</bibliographie>
```


Formes sérialisée et arborescente

- Forme sérialisée d'un document/élément
  - Chaîne de caractères (texte) incluant balises et contenu textuel

  Exemple

```
<lettre type='court'><salutation>Bonjour!</salutation><fin>Au
revoir</fin></lettre>
```

  ou avec un peu de mise en forme

```
<lettre type='court'>
   <salutation>Bonjour!</salutation>
   <fin>Au revoir</fin>
</lettre>
```

- Forme arborescente
  - Utilisée par les applications, modèle DOM (W3C)
  - Plusieurs types de nœuds

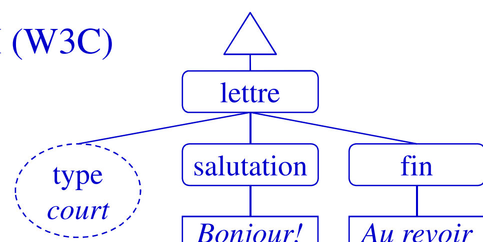

Espaces de noms

- Espace de noms (« namespace »)
  - Collection de noms d'éléments ou noms d'attributs, identifiée par un URI
  - Idée: rajouter un préfixe afin de rendre "uniques" et identifiables les noms utilisés
    - Unicité du préfixe: à travers l'URI associée

```
<document xmlns:dc='http://purl.org/dc/elements/1.1/'>
  <movie:film xmlns:movie='http://www.movie.fr/'
            dc:title='Décalage horaire'
            dc:creator='Danièle Thompson'>
    <movie:acteur nom='Juliette Binoche' />
  </movie:film>
</document>
```

- Nom qualifié: nom "visible" dans le document, préfixe + nom local
- Nom universel: vrai nom, URI + nom local

Nom qualifié	Nom universel
movie:film	http://www.movie.fr/:film
movie:acteur	http://www.movie.fr/:acteur
dc:title	http://purl.org/dc/elements/1.1/:title
dc:creator	http://purl.org/dc/elements/1.1/:creator

XML Schema

- Langage de description de types et schémas dans XML
- Types simples: 43 types prédéfinis
  - xsd:string, xsd:integer, xsd:double, xsd:boolean, xsd:date, …
- Types composés

```
<xsd:complexType name='AdresseType'>
  <xsd:sequence>
    <xsd:element name='ville' type='xsd:string'/>
    <xsd:element name='rue' type='xsd:string'/>
    <xsd:element name='numero' type='xsd:integer'/>
  </xsd:sequence>
</xsd:complexType>
```

- Contraintes d'intégrité: xsd:key, xsd:keyref, …
- Espace de noms
  xmlns:xsd="http://www.w3.org/2001/XMLSchema"

XPath

- Langage de sélection d'un ensemble de nœuds dans un document XML
  - Utilise des *expressions de chemin* pour désigner des nœuds dans l'arbre
- Une expression de chemin XPath: suite d'**étapes** à partir d'un **nœud contexte**

  `[/]étape`$_1$`/étape`$_2$`/…/étape`$_n$
- Étape = `axe::filtre[prédicat`$_1$`]…[prédicat`$_n$`]`

  Exemple: `child::B[position()=1]` (abréviation: `B[1]`)
- Axe: optionnel (par défaut `child`)
  - Spécifie *un ensemble des nœuds* par rapport au nœud contexte + *un ordre*
- Filtre: obligatoire, décrit le sous-ensemble de nœuds de l'axe retenu
- Prédicats: optionnels, décrivent les conditions à satisfaire par les nœuds
  - Combinés par l'opérateur "ET" logique

Axes XPath

- Douze types d'axes
  - `child` (axe par défaut): enfants directs du nœud contexte
  - `parent` (..): nœud parent
  - `attribute` (@): nœuds attribut du nœud contexte
  - `descendant` (//): nœuds descendants du nœud contexte
  - `descendant-or-self`: descendants, y compris le nœud contexte
  - `ancestor`: nœuds ancêtres du nœud contexte
  - `ancestor-or-self`: ancêtres, y compris le nœud contexte
  - `following`: nœuds suivants dans l'ordre du document
  - `following-sibling`: frères suivants dans l'ordre du document
  - `preceding`: nœuds précédents dans l'ordre du document
  - `preceding-sibling`: frères précédents dans l'ordre du document
  - `self` (.): le nœud contexte lui-même
- Attributs: seul l'axe `attribute` désigne des nœuds attribut !

Filtres et prédicats

- *Filtres*: deux façons de filtrer les nœuds d'un axe:
  - Par leur ***nom***
    - Pour les types de nœuds qui ont un nom (*Element*, *Attribute*, …)
    - * : n'importe quel nom
  - Par leur ***type***
    - *text(), comment(), …*
    - *node()* : n'importe quel type de nœud
- *Prédicat*: *tests* connectés par les opérateurs logiques « and » et « or »
  - Négation: par la fonction *not*()
- *Test* = expression booléenne élémentaire: comparaison, fonction booléenne
  - Expression de chemin convertie en booléen : `false` si l'ensemble est vide, sinon `true`

Fonctions XPath

- Pour nœuds
  - *count(expr)*: nombre de nœuds dans l'ensemble produit par l'expression
  - *string()*: valeur textuelle du nœud
- Pour chaînes de caractères
  - *concat(ch1, ch2, …)*: concaténation
  - *contains(ch1, ch2)*: vérifie si *ch1* contient *ch2*
  - *substring(ch, pos, l)*: extrait la sous-chaîne de *ch* de longueur *l*, commençant à la position *pos* (les positions démarrent à 1)
  - *string-length(ch)*: longueur de la chaîne
- Pour booléens
  - *true(), false()*: les valeurs vrai/faux
  - *not(expr)*: négation de l'expression logique
- Pour numériques
  - *sum(expr)*: somme des valeurs des nœuds produits par l'expression
  - *avg(expr)*: moyenne des valeurs des nœuds produits par l'expression

Exemples

```
<?xml version="1.0" ?>
<?java ... ?>
<A>
  <B att1="a1">
    <D>Texte 1</D>
    <D>Texte 2</D>
  </B>
  <B att1="a2">
    <D>Texte 3</D>
  </B>
  <C att2="a3" att3="15"/>
</A>
<!- CommFin -->
```

- D
- D/text()
- preceding-sibling::node()
- ../*
- //@att1
- /A/B[@att1="a1"]/D
- //B[count(D)>1]

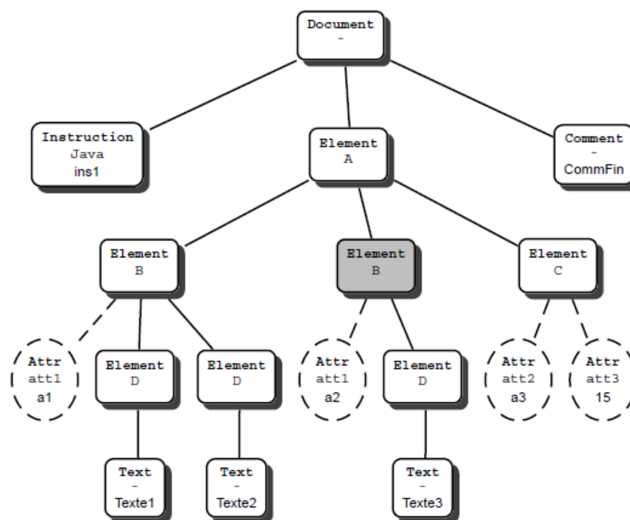

XQuery

- Langage de requêtes pour bases de données XML
  - Langage fonctionnel typé, sans effets de bord
- Modèle de données basé sur des *séquences ordonnées*
  - ***Valeur (séquence)*** = séquence ordonnée (liste) d'*items*
  - ***Item*** = *nœud* (tout type DOM) ou *valeur atomique*
    - Document, élément, attribut, texte, … + valeurs atomiques de différents types
  - Chaque nœud et chaque valeur atomique a un ***type*** (XML Schema)
  - Résultat de requête XQuery = valeur = séquence d'items

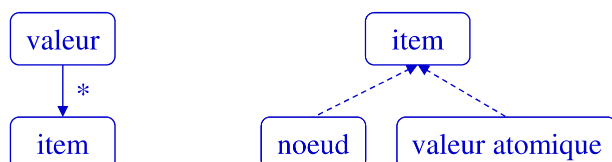

Séquences

- Pas de distinction entre item et séquence de longueur 1
  - Ex: 39 = (39)
- Une séquence peut contenir des valeurs hétérogènes
  - Ex: (39, "toto", <toto/>)
- Pas de séquences imbriquées
  - Ex: (39, (1, 2), "toto", <toto/>) = (39, 1, 2, "toto", <toto/>)
- Une séquence peut être vide
  - Ex: ( )
- L'ordre est important
  - Ex: (1, 2) ≠ (2, 1)

Expressions XQuery simples

- Valeurs atomiques littérales (des types simples XML Schema)
  Ex: *39*, *"toto"*, *3.9*, etc.
- Nœuds XML sous forme littérale
  Ex: *<film annee="2007">*
  <titre>La môme</titre>
  </film>
- Valeurs obtenues par des constructeurs simples
  Ex: *true()*, *false()*, *date("2006-12-08")*
- Collections de documents, documents
  - doc(*uri-document*) → retourne un item de type nœud *Document*
  - collection(*uri-collection*) → retourne une séquence de nœuds *Document*

  Ex: *document("biblio.xml")*, *collection("cinema/films")*
- Séquences construites
  Ex: *(1, 2, 3, 4, 5)*, *1 to 5*, *(1 to 3, 4, 5)*
- Variables
  - Nom précédé du signe $ (ex. *$x*) + valeur (séquence d'items)

Expressions XQuery complexes

- Expressions de chemin (XPath 2.0)
  - Toute expression produisant une séquence de nœuds peut être une étape
- Expressions FLWOR avec définition de variables
- Tests (*If-Then-Return-Else-Return*)
- Fonctions prédéfinies et fonctions utilisateur
- Mélange de littéraux et d'expressions complexes
  - Chaque expression doit être placée entre { } pour qu'elle soit évaluée

Ex.
```
<comedies>
    {doc("films.xml")//film[@genre="comedie"]}
</comedies>
```


Exemple

- Document *bib.xml*

```
<bib>
  <book year="2003" title="Comprendre XSLT">
    <author><name>Amann</name><country>FR</country></author>
    <author><name>Rigaux</name><country>FR</country></author>
    <publisher>O'Reilly</publisher>
    <price>28.95</price>
  </book>
  <book year="2001" title="Spatial Databases">
    <author><name>Rigaux</name><country>FR</country></author>
    <author><name>Scholl</name><country>FR</country></author>
    <author><name>Voisard</name><country>FR</country></author>
    <publisher>Morgan Kaufmann Publishers</publisher>
    <price>35.00</price>
  </book>
  <book year="2000" title="Data on the Web">
    <author><name>Abiteboul</name><country>FR</country></author>
    <author><Buneman</name><country>UK</country></author>
    <author><name>Suciu</name><country>US</country></author>
    <publisher>Morgan Kaufmann Publishers</publisher>
    <price>39.95</price>
  </book>
</bib>
```

Expressions FLOWR

- Une expression FLOWR ("flower")
  - Itère sur des séquences (**f**or)
  - Définit des variables (**l**et)
  - Trie les résultats (**o**rder by)
  - Applique des filtres (**w**here)
  - Construit et retourne un résultat (**r**eturn)
- Exemple

```
for $b in doc("bib.xml")//book
order by $b/@year
let $al := $b/author
where $b/publisher = "Morgan Kaufmann Publishers"
return <livre nb_auteurs="{count($al)}">
         <title>{$b/@title/string()}</title>
         {$al}
       </livre>
```


Requêtes motif d'arbre

- Les requêtes les plus courantes
  - Correspondent aux requêtes relationnelles de sélection/projection
- Exemple : *noms des auteurs français et titres des livres qu'ils ont publiés*
- Principe
  - Une variable par nœud de jonction
  - Conditions dans le "where"
  - Résultats dans le "return"

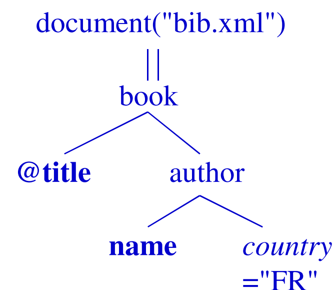

- Équivalent en XQuery

```
for $b in doc("bib.xml")//book, $a in $b/author
where $a/country="FR"
return <resultat>
         {$a/name}
         {$b/@title}
       </resultat>
```

Bases de données XML

- Base de données XML = base de données qui s'appuie sur un modèle logique de données XML
  - Représentation XML des données stockées / retournées par les requêtes
  - Langage de définition de données (LDD) spécifique à XML
  - Langage de requêtes / manipulation des données (LMD) spécifiques XML
  - Stockage physique et indexation spécifiques à XML
- Modèles de données
  - Relationnel: tables
  - Objet: objets persistants
  - Semi-structuré: arbres et texte → XML, JSON

Modèle semi-structuré / XML

- Modèle pour le contenu du web
  - Mélange de texte et de structure complexe: *arbres ordonnés*
    - Plus complexe que le relationnel ou l'objet
  - Faiblement typé et auto-descriptif (schéma facultatif)
  - Flexible pour gérer l'hétérogénéité
- Langage de requêtes XQuery/XPath
  - Expressions de chemin, récursivité, requêtes texte

Comparaison relationnel - XML

- Modèle conceptuel

- Traduction en modèle relationnel
  Acteur (nom, pays)
  Film (titre, année)
  Joue (nom, titre)
- Traduction en modèle XML
  - Plus proche du modèle conceptuel

```
<Acteurs>
  <Acteur nom="Daniel Auteuil">
    <pays>France</pays>
    <Film année="1986">Jean de Florette</Film>
    <Film année="1993">La Reine Margot</Film>
    <Film année="1996">Le Huitième Jour</Film>
  </Acteur>
  ...
</Acteurs>
```


Pourquoi des bases de données XML?

- XML est un format d'échange, pourquoi le stocker?
  - Éviter les (coûteuses) transformations de modèle

- Pourquoi ne pas stocker les documents XML dans des fichiers?
  - Possible: fichiers texte auto-descriptifs, un fichier par document, mais…
    - Fonctionnalités limitées offertes par le système de fichiers, pas d'accès rapide à des parties du document, pas de support pour concurrence, reprise, …
    - Très lent quand le nombre de fichiers augmente
  - Obtenir de bonnes performances → optimiser l'organisation physique
    - Stockage adapté à la navigation dans les arbres, indexation

Stockage XML

- Deux catégories de BD XML
  - *Natives*: le stockage est spécifique au modèle XML
  - *Non-natives*: le stockage se fait au-dessus d'un autre modèle
    - Très utilisé à cause de la prédominance des SGBD relationnels
- Types de documents XML
  - *Orientés données*: contenu structuré, ordre peu important
  - *Orientés documents*: proche de documents consultables, ordre important
    - Beaucoup de texte et de contenu mixte (style HTML)

```
<Acteurs>
  <Acteur>
    <nom>Daniel Auteuil</nom>
    <pays>France</pays>
  </Acteur>
  <Acteur>
    <nom>Julia Roberts</nom>
    <pays>États Unis</pays>
  </Acteur>
</Acteurs>
```

```
<Acteurs>
Parmi les acteurs présents à cette
avant-première on peut citer <nom>Daniel
Auteuil</nom> (<pays>France</pays>)
ou <nom>Julia Roberts</nom> (<pays>États
Unis</pays>), ainsi que ...
</Acteurs>
```


Stockage de XML dans le relationnel

- Distance assez grande entre les modèles
  - Tables non ordonnées ↔ arbres ordonnés
  - Mieux adapté aux documents XML orientés données
- Problèmes
  - Trouver le schéma relationnel pour stocker du XML
  - Traduire du XQuery en SQL
  - Construire des résultats XML à partir des tables
- Deux façons de stocker du XML dans le relationnel
  - Dans des tables: contenu décomposé entre plusieurs tables
    - Adapté à l'XML orienté données
    - Avantage: accès à des parties du document
  - Dans des LOB: contenu stocké comme un bloc
    - Adapté à l'XML orienté documents
    - Avantage: reconstitution rapide du document

Stockage relationnel générique

- Méthode simple, valable pour n'importe quel document
  - Une table pour l'arbre, une autre pour les valeurs
  - Inconvénient: beaucoup de jointures pour accéder aux fragments XML

```
<cinema>
  <film>
    <titre>Titanic</titre>
    <acteur>L. di Caprio</acteur>
    <acteur>K. Winslett</acteur>
  </film>
  <film>
    <titre>Alien</titre>
    <mes>R. Scott</pays>
    <acteur>S. Weaver</acteur>
  </film>
</cinema>
```

A

Id	Libellé	Pos	Type	Parent
1	cinema	1	ref	0
2	film	1	ref	1
3	titre	1	cdata	2
4	acteur	2	cdata	2
5	acteur	3	cdata	2
6	film	2	ref	1
7	titre	1	cdata	6
8	mes	2	cdata	6
9	acteur	3	cdata	6

V

Id	Valeur
3	Titanic
4	L. di Caprio
5	K. Winslett
7	Alien
8	R. Scott
9	S. Weaver

Stockage relationnel générique (suite)

- Requête XPath

```
//film[acteur="S. Weaver"]/titre
```

- Requête SQL équivalente

```
select vt.Valeur
from A f, A a, A t, V va, V vt
where f.Libellé="film" and
      a.Libellé="acteur" and
      t.Libellé="titre" and
      a.Parent=f.Id and
      t.Parent=f.Id and
      va.Id=a.Id and
      va.Valeur = "S. Weaver" and
      vt.Id=t.Id
```

→ 4 jointures et 4 sélections

Stockage relationnel guidé par le schéma

- Idée: utiliser le schéma XML pour en déduire un modèle conceptuel, traduit ensuite en relationnel
  - Graphe structurel décomposé en sous-arbres → une table par sous-arbre
  - Racine sous-arbre: nœud ayant $n \neq 1$ arcs entrants ou 1 arc entrant marqué * ou +

```
<!ELEMENT cinema (film)*>
<!ELEMENT film (titre, mes?, acteur*)>
<!ELEMENT titre (#PCDATA)>
<!ELEMENT mes (#PCDATA)>
<!ELEMENT acteur (#PCDATA)>
```

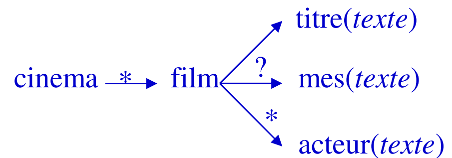


```
Cinema(id)
Film(id, parentId, titre, mes)
Acteur(id, parentId, acteur)
```

```
//film[acteur="S. Weaver"]/titre
```

```
select f.titre
from Film f, Acteur a
where a.parentId=f.id and
      a.acteur="S. Weaver"
```


Stockage XML natif

- Stockage basé sur des structures d'arbre
  - DOM persistant → mémoire virtuelle pour DOM
  - Pages disque organisées sous forme d'arbre
- Exemple: Natix
  - Un arbre XML est découpé en articles (sous-arbres)
  - Une page = un ou plusieurs articles + liens vers les pages suivantes
  - Utilisation de nœuds proxy/hub pour créer les liens entre pages

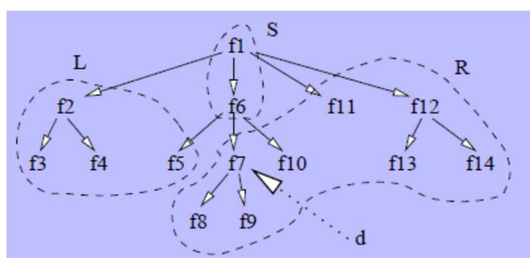

Éclatement d'une page
par rapport à un nœud pivot *d*

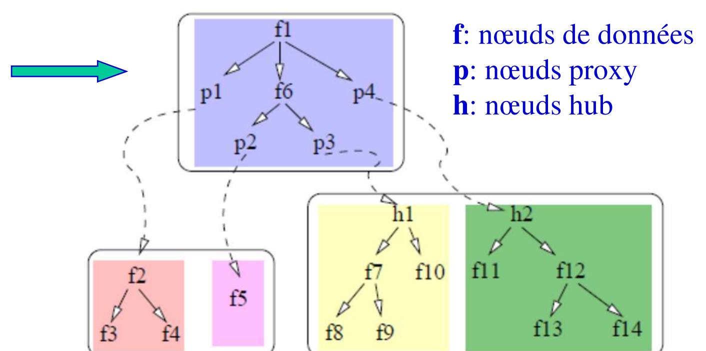

f: nœuds de données
p: nœuds proxy
h: nœuds hub

Indexation XML

- Particularités
  - Requêtes de chemin → indexation *de la structure* d'arbre
  - Requêtes sur le texte → indexation *des mots* du texte
- Les index relationnels (arbres B+) sont aussi utilisés
  - Éléments/attributs dont la valeur est de type "relationnel"
- Exemple d'index mixte structure/texte
  - Schéma de numérotation Dietz pour les nœuds d'un arbre
  - ***Identifiant structurel*** : *IS*=(*pre*, *post*, *niv*)
    - *pre*: position du nœud dans un parcours pré-ordre de l'arbre
      - Suit l'ordre d'ouverture des balises dans le document
    - *post*: position du nœud dans un parcours post-ordre de l'arbre
      - Suit l'ordre de fermeture des balises dans le document
    - *niv*: niveau du nœud dans l'arbre
      - Permet de vérifier des relations parent-enfant entre les noeuds

Index XML texte/structure

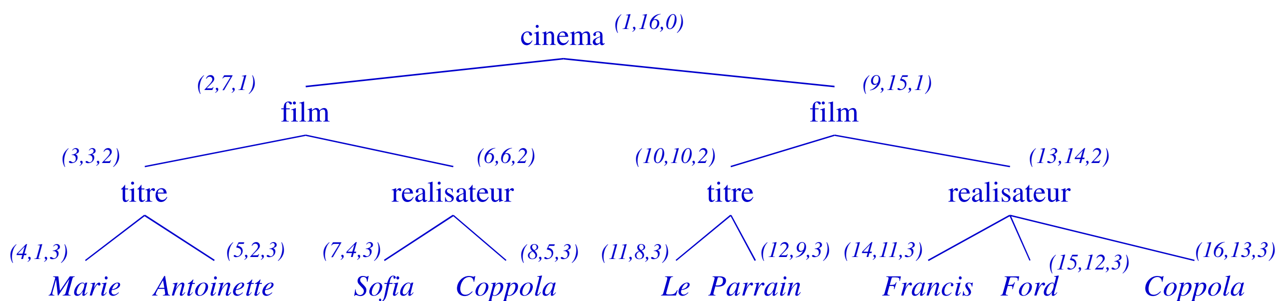

- Identifiants structurels *pour tous les nœuds* de l'arbre et *pour tous les mots* du texte
  - *n2* après *n1* : $pre(n1) < pre(n2)$
  - *n2* descendant de *n1* : $pre(n1) < pre(n2) \wedge post(n1) > post(n2)$
  - *n2* enfant de *n1* : *n2* descendant de *n1* $\wedge\ niv(n2) = niv(n1)+1$
  - *n* contient *mot* : *mot* descendant de *n*
  - *n* contient directement *mot* : *mot* enfant de *n*

Index texte/structure et requêtes

- Index = balise/mot → liste IS groupés par document
- Exemple requête: `//film[realisateur ftcontains "Sofia"]/titre`
  - Retrouver les listes d'IS pour chaque balise/mot de la requête
  - Combiner ces listes par rapport aux relations de chemin

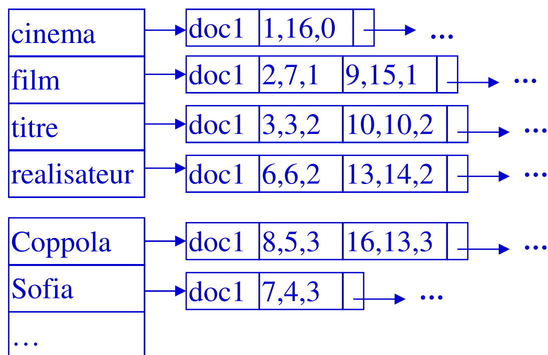

- realisateur: (6,6,2), (13,14,2)
- "Sofia": (7,4,3)
- realisateur ftcontains "Sofia": (6,6,2)
- film: (2,7,1), (9,15,1)
- film[…] : (2,7,1)
- titre: (3,3,2), (10,10,2)
- film[…]/titre: **(3,3,2)**

Interrogation XML

- Langages d'interrogation
  - W3C: *XQuery*, *XPath*
  - SQL: *SQL/XML*
- SQL/XML
  - Extension de SQL pour manipuler du XML dans un SGBD relationnel
  - Mélange de SQL, XQuery et opérateurs de passage relationnel – XML
  - Partie du standard SQL (*ISO/IEC 9075*) - SQL partie 14: "XML related specifications"
- Caractéristiques SQL/XML
  - Construction de fragments XML à partir de tables relationnelles
    - "Fonctions" spécifiques à XML rajoutées à SQL: XMLELEMENT, XMLATTRIBUTES, XMLAGG, XMLFOREST, etc.
  - Nouveau type de données XML
    - Type d'attribut (colonne) au même niveau que INTEGER, VARCHAR, …
  - Interrogation en XQuery des attributs XML → fonction XMLQUERY
  - Transformation d'un attribut XML sous forme de table → fonction XMLTABLE
  - Test d'existence d'information dans XML → fonction XMLEXISTS

Construction de XML à partir de tables

- Exemple utilisé

Table **FILM**

FID	TITRE	ANNEE	GENRE	MES
1	Vertigo	1958	Drame	2
2	Alien	1979	SF	3
3	Titanic	1997	Drame	5

Table **ARTISTE**

AID	NOM	PRENOM	ANNEENAISS
1	Stewart	James	1908
2	Hitchcock	Alfred	1899
3	Scott	Ridley	NULL
4	Depp	Johnny	NULL
5	Cameron	James	1954

XMLELEMENT

- Création d'éléments XML
  - XMLELEMENT crée un élément XML dans le résultat

Ex. Produire des éléments XML avec les titres des films

```
SELECT XMLELEMENT(NAME "film", TITRE) AS "Films"
FROM FILM
```

- Résultat:

```
Films
-----
<film>Vertigo</film>
<film>Alien</film>
<film>Titanic</film>
```

- Remarque: par défaut les noms d'attributs en SQL sont en majuscules, pour avoir un nom d'élément XML en minuscules il faut le mettre entre guillemets

XMLATTRIBUTES

- Définition d'attributs pour un élément
  - XMLATTRIBUTES: seulement en second paramètre de XMLELEMENT

Ex. Éléments XML plus complexes

```
SELECT XMLELEMENT(NAME "film",
         XMLATTRIBUTES(TITRE AS "titre", ANNEE AS "annee"),
         XMLELEMENT(NAME "realisateur",
                    (SELECT NOM FROM ARTISTE a
                     WHERE f.MES=a.AID)),
         XMLELEMENT(NAME "genre", GENRE)
       ) AS "Films"
FROM FILM f WHERE ANNEE<1980
```

```
Films
-----
<film titre="Vertigo" annee="1958">
  <realisateur>Hitchcock</realisateur><genre>Drame</genre>
</film>
<film titre="Alien" annee="1979">
  <realisateur>Scott</realisateur><genre>SF</genre>
</film>
```


XMLAGG

- Regrouper une séquence d'éléments en un seul élément
  - XMLAGG: par exemple regrouper les résultats d'une requête en un seul élément

Ex. Produire des éléments XML avec les titres des films

```
SELECT XMLELEMENT(NAME "films",
         XMLAGG(XMLELEMENT(NAME "film", TITRE)
                ORDER BY TITRE)
       ) AS "Films"
FROM FILM
```

```
Films
-----
<films>
  <film>Alien</film>
  <film>Titanic</film>
  <film>Vertigo</film>
</films>
```

- Remarque: clause ORDER BY possible dans XMLAGG

XMLAGG versus XMLELEMENT

- Question: pourquoi a-t-on besoin de XMLAGG en plus de XMLELEMENT?

Ex. La requête avec XMLELEMENT produit autre chose

```
SELECT XMLELEMENT(NAME "films",
         XMLELEMENT(NAME "film", TITRE))
       ) AS "Films"
FROM FILM
```

```
Films
-----
<films>
  <film>Vertigo</film>
</films>
<films>
  <film>Alien</film>
</films>
<films>
  <film>Titanic</film>
</films>
```


XMLFOREST

- Créer plusieurs éléments
  - Produit une séquence XML à partir de valeurs SQL
  - XMLFOREST: plus simple et flexible que plusieurs XMLELEMENT

Ex. Les informations sur les artistes dont le prénom commence par 'J'

```
SELECT XMLELEMENT(NAME "artiste",
         XMLFOREST(NOM AS "nom",
                   PRENOM AS "prenom",
                   ANNEENAISS AS "naissance")
       ) AS "Artistes"
FROM ARTISTE WHERE PRENOM LIKE 'J%'
```

```
Artistes
-----
<artiste>
  <nom>Stewart</nom><prenom>James</prenom><naissance>1908</naissance>
</artiste>
<artiste>
  <nom>Depp</nom><prenom>Johnny</prenom>
</artiste>
<artiste>
  <nom>Cameron</nom><prenom>James</prenom><naissance>1954</naissance>
</artiste>
```

Autres opérateurs

- XMLCOMMENT: produit un commentaire
- XMLPI: produit une instruction de traitement
- XMLCONCAT: produit une séquence de plusieurs nœuds
- XMLPARSE: transforme une chaîne de caractères en XML
- XMLSERIALIZE: transforme du XML en chaîne de caractères
- etc.

Type de données XML

- XML: nouveau type de données pour un attribut SQL
  - Avant: il fallait stocker le XML dans des attributs de type VARCHAR, CLOB ou BLOB
- Syntaxe: `XML(contenu(type))`
  - Seul le mot XML est obligatoire, le contenu et le type sont optionnels
- Contenu
  - DOCUMENT : document XML bien formé
  - CONTENT : fragment XML "enrobé" sous forme de document XML (peut avoir plusieurs éléments racine)
  - SEQUENCE : séquence de tous types de nœuds XML
- Type
  - UNTYPED: pas de schéma XML
  - XMLSCHEMA *description* : avec schéma XML spécifié par *description*
  - ANY: pas de précision (ça peut être n'importe lequel des deux)

Exemple de table avec attribut XML

```
create table FILMS_XML(
  FID  integer primary key,
  FILM XML(DOCUMENT(UNTYPED)));
```

Table **FILMS_XML**

FID	FILM
1	<film annee='1958'> <titre>Vertigo</titre> <genre>Drame</genre> <mes>Alfred Hitchcock</mes> </film>
2	<film annee='1979'> <titre>Alien</titre> <genre>SF</genre> <mes>Ridley Scott</mes> </film>
3	<film annee='1997'> <titre>Titanic</titre> <genre>Drame</genre> <mes>James Cameron</mes> </film>

Interrogation en XQuery

- On peut interroger le contenu des attributs XML avec des requêtes XQuery
- Principales commandes
  - Commande XMLQUERY à être utilisée dans la clause SELECT
    - Interrogation des données dans les attributs XML
  - Commande XMLTABLE à être utilisée dans la clause FROM
    - Transformation de données XML en table relationnelle
  - Commande XMLEXISTS à être utilisée dans la clause WHERE
    - Vérification de conditions sur les attributs XML

XMLQUERY

- Interrogation de contenu XML
  - Dans la clause SELECT, attributs XML passés sous forme de variables

Ex. Donner les titres des films

```
SELECT XMLQUERY(
         'for $f in $attr/film
          return $f/titre'
         PASSING FILM AS "attr"
         RETURNING CONTENT
         NULL ON EMPTY
       ) AS "Films"
FROM FILMS_XML
```

```
Films
-----
<titre>Vertigo</titre>
<titre>Alien</titre>
<titre>Titanic</titre>
```

- Remarque: l'attribut XML FILM est transmis en tant que variable `$attr`

Construction de tables à partir de XML

- Commande XMLTABLE
  - Extrait du contenu XML avec une requête XQuery et formate le résultat sous forme de table relationnelle
  - Utilisée dans la clause FROM
- Mieux adapté que XMLQUERY pour exploiter le contenu mixte relationnel-XML des tables
  - XMLQUERY: XML → XML, exploitable avec des outils XML
  - XMLTABLE: XML → table, exploitable avec SQL

XMLTABLE

Ex. Produire une table avec le titre, l'année et le réalisateur des films sortis avant 1980

```
SELECT f.*
FROM FILMS_XML,
     XMLTABLE(
       'for $f in $attr/film return $f'
       PASSING FILMS_XML.FILM AS "attr"
       COLUMNS
         "titre" VARCHAR(40) PATH 'titre',
         "annee" INTEGER PATH '@annee',
         "realisateur" VARCHAR(40) PATH 'mes'
     ) f
WHERE f.annee < 1980
```

```
titre      annee  realisateur
---------- ----- ---------------
Vertigo     1958  Alfred Hitchcock
Alien       1979  Ridley Scott
```


XMLEXISTS

- Test d'une condition sur un contenu XML
  - Utilisé la clause WHERE

Ex. Donner les identifiants des films après 1970

```
SELECT FID
FROM FILMS_XML
WHERE XMLEXISTS(
        '/film[@annee>1970]'
        PASSING BY VALUE FILM)
```

```
 FID
-----
   2
   3
```

- Remarque: le résultat de XMLEXISTS est faux seulement si le résultat de la requête XQuery est la séquence vide

XML dans Oracle

- Type d'attribut/table XML: XMLTYPE
  - Stockage sous forme de LOB ou de tables
  - Utilisation des attributs XML indépendante du mode de stockage
  - Langage SQL/XML assez proche de la norme
- Exemple

```
create table FILMS_XML(
  FID:integer primary key,
  FILM: sys.XMLType);
create table ARTISTES_XML of sys.XMLType;
```

- Insertion

```
insert into FILMS_XML values(1,
  XMLTYPE('<film titre="Alien">
     <acteur>S. Weaver</acteur>
   </film>'));
```


JSON

- JSON = JavaScript Object Notation
- Modèle pour les documents structurés
  - Pas de balises, mais des couples clé-valeur
  - Valeur
    - Simple: chaine de caractères, numérique, booléen
    - Liste de valeurs hétérogènes [ ]
    - Objet: ensemble de couples clé-valeur { }
  - Imbrication de valeurs → structure d'arbre, comme XML

```
{"ouvrage": [{"année": 2003,
              "auteur": ["G. Gardarin"],
              "titre": "XML : Des Bases de Données aux Services Web",
              "éditeur": "Dunod"},
             {"année": 2007,
              "auteur": ["S. Abiteboul", "N. Polyzotis"],
              "titre": "The Data Ring",
              "conférence": "CIDR"}
            ]
}
```

JSON

- Comparaison avec XML
  - Format plus compact que XML
  - Structure arborescente
    - XML: étiquettes sur les nœuds
    - JSON: étiquettes sur les arcs
  - Passage simple d'un modèle à l'autre
    - JSON plus adapté aux documents orientés données
  - Pas de langage de requêtes standardisé
    - Plusieurs propositions inspirés de XML
- Utilisation
  - Echange de données client-serveur dans Javascript
  - Format d'échange pour applications Web
  - Format de données pour les services Web REST

Comparaison XML-JSON