

Ein Transparentes Datenmodell zur Verarbeitung Verlinkter XML-Dokumente


Wolfgang May & Dimitrio Malheiro
Univ. Freiburg/Göttingen Univ. Freiburg

GI-Fachtagung BTW 2003
Leipzig, 26.2.2003

Situation

- autonome XML-Datenquellen im Web
- Referenzen zwischen Datenquellen

- mondial-countries.xml
- mondial-cities-car-code.xml
- mondial-organizations.xml
- mondial-memberships.xml



XLink:Referenzen in XML

- W3C XLink-Standard: Sprache zur Definition von Referenzen zwischen XML-Dokumenten

- Wohin?

XPointer: *url#xpath-expr*

<linkelement xlink:type="simple" href="url#xpath-expr"/>

Simple Links


- ähnlich: HTML ``.

Sitz einer Organisation:

```
<organization abbrev="EU">  
  <headq xlink:type="simple"  
    xlink:href=  
      "file:cities-B.xml#//city[name='Brussels']" />  
  :  
</organization>
```

Anfrage:

```
//organization[@abbrev="EU"]/headq/??/name
```



Anfragen über Links

XPointer und XLink:

- Sprachen um inter-Dokument-Referenzen in XML zu *beschreiben*,
- XLink-Verhaltensspezifikation auf Browsing beschränkt

Bisher nicht spezifiziert

- Semantik von Referenzen im Datenmodell (d.h., XML Query Data Model),
- Formulierung und Auswertung von Anfragen über Referenzen

Sichtweisen

- Anfragender:
 - transparent gegenüber den Benutzern
- eigene Daten referenzieren fremde Datenquellen:
 - Anfragen an die Dokumente müssen weitergeleitet werden
- fremde Daten referenzieren die eigenen Daten:
 - Restrukturierung, Aufteilung
 - Beibehaltung desselben externen Schemas

Datenmodelle für Referenzen


- Erweiterung des abstrakten Datenmodells um Referenzen
 - erfordert einen expliziten Navigationsoperator und einen Zwischenschritt

```
organization[@abbrev="EU"]/headq/@href~>city/name
```

- Logisches Datenmodell mit transparenten Referenzen:
 - Jedes XLink wird als View-Definition gesehen
 - Eingebettete Views als implizite Teilbäume
 - Integration der externen Schemata
 - Anfragen mit üblicher XPath-Syntax/Semantik

Logisches Modell: Transparente Links


- Link-Elemente als *transparent* ansehen



```
<organization abbrev="EU">  
  <headq xlink:type="simple"  
    href="file:cities-B.xml#//city[name='Brussels']"  
    attributes of Brussels >  
    contents of Brussels  
  </headq>  
  :  
</organization>
```

Anfrage:

```
//organization[@abbrev="EU"]/headq/name
```



Logisches Datenmodell

- XLink-Spracherweiterung zur Spezifikation des gewünschten **logischen Datenmodells**:
dbxlink:transparent-Attribut:

Zusammensetzen der Bäume

- Beitrag der XLink-Elemente
 - Elementhüllen der XLink-Elemente behalten oder weglassen
keep-element, **drop-element**
 - in Referenzattribute umwandeln – **make-attribute**
 - nur Attribute behalten und durchgeben – **keep-attributes**
- Beitrag der referenzierten Elemente:
 - Elemente als ganzes einfügen – **insert-elements**
 - nur Elementinhalt (und Attribute) in vorhandene Hülle einfügen – **insert-contents**
- Namen für from/to bei arc-Elementen

Anwendung des logischen Modells

- transparente Integration von *View-Definitionen* in die XML-Datenbank
- Anfragen an verlinkte XML-Dokumente im Web
- Aufsplitten eines XML-Dokuments in mehrere Dokumente
Beibehaltung desselben **logischen** Schemas.

Realisierung

(Diplomarbeit Dimitrio Malheiro)

- Materialisierung der logischen Instanz:
 - Validierung und Veranschaulichung des Ansatzes
 - Erstellung der logischen Instanz zu einem gegebenen Einstiegsdokument durch ein XSLT-Skript
 - Problem bei unendlicher Rekursionstiefe
 - <http://www.informatik.uni-freiburg.de/~malheiro/demo>
- Auswertung von Anfragen gegen das logische Modell
 - Erweiterung des LoPiX-Systems
 - keine Materialisierung
 - Zerlegung der Anfragen
 - on-demand-Zugriff auf externe Quellen
 - <http://www.informatik.uni-freiburg.de/~may/lopix>

Auswertungsaspekte

Definition von weiteren Attributen im `dbxlink`-Namespace zur Auswertung von Anfragen in diesem Modell:

- **Wann** wird ein Link ausgewertet?
(Parsing-Zeitpunkt oder Auswertungszeitpunkt)
`dbxlink:actuate`-Attribut
- **Wo** findet die Berechnung statt?
(lokal oder bei dem referenzierten Server)
`dbxlink:eval`-Attribut
- **welche** (Zwischen)ergebnisse werden gespeichert und wiederverwendet.
(Dokument, Link-Ergebnis, Anfrageergebnis, Nichts)
`dbxlink:cache`-Attribut

Fortsetzung im Rahmen des DFG-Projektes "LinXIS".

<http://www.informatik.uni-freiburg.de/~may/LinXIS>

Fragen ??