

XML Vorlesung ETHZ, Sommersemester 2006

XML und Datenbanken

Erik Wilde

4.7.2006

<http://dret.net/lectures/xml-ss06/>

4.7.2006

XML Vorlesung ETHZ SS 2006

1

Übersicht

- Sichten auf XML
 - Transfer vs. Datenmodell, XML Support im DBMS
- XML vs. relationales Modell (ER-Modell)
- SQL/XML
 - Integration von XML in die Welt von SQL
- XQuery
 - eine eigene Abfragesprache für XML Datenbanken

4.7.2006

XML Vorlesung ETHZ SS 2006

2

Sichten auf XML

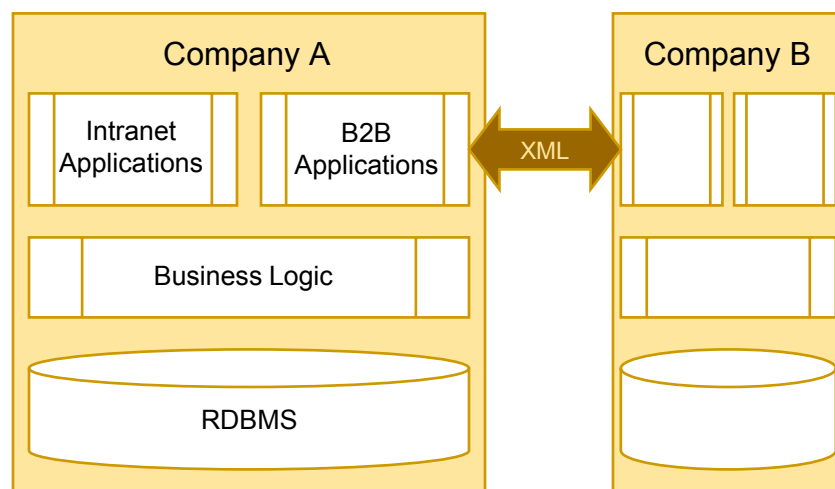
- verschiedene Sichten sind möglich
- reine Transfersyntax
 - alles irgendwie auf XML abbilden
 - XML-basiert übertragen
 - beim Empfänger umgekehrtes Mapping
- XML als Datenmodell
 - XML Daten auf Business-Ebene
 - RDF Beschreibungen der XML-Daten
- momentan überwiegt (noch) die Transfersicht

4.7.2006

XML Vorlesung ETHZ SS 2006

3


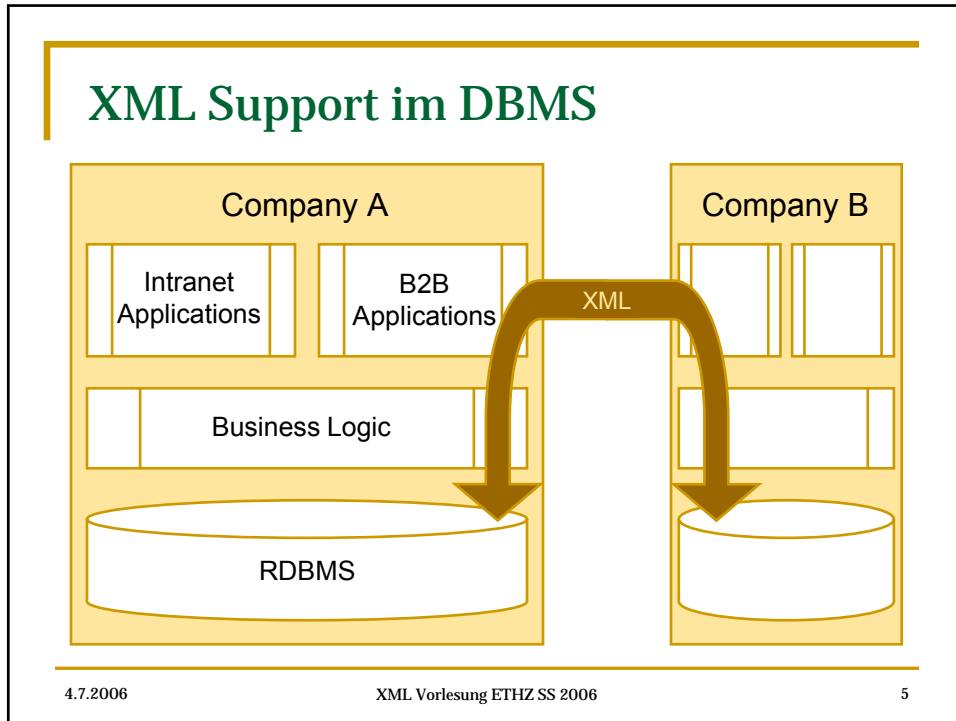
3-Tier und XML-basierter B2B



4.7.2006

XML Vorlesung ETHZ SS 2006

4



ER-Modellierung

- Entities repräsentieren Konzepte
 - reale Dinge wie Personen oder Produkte
 - abstrakte Dinge wie Projekte
- Relationships verbinden Konzepte
 - kein semantischer Gehalt im Modell
 - verschiedene Kardinalitäten unterstützt
- ER-Modelle sind beliebt und verbreitet
 - einfache Abbildung auf das relationale Modell
 - einfach zu verstehen und anzuwenden
 - für viele Probleme ausreichend gut

4.7.2006

XML Vorlesung ETHZ SS 2006

7

XML ist hierarchisch

- Erbe aus der Dokumentenwelt
 - Dokumente sind recht klar hierarchisch aufgebaut
 - bei modularem Aufbau schon weniger klar
 - `<!ELEMENT section (content, chapter+)`
 - `<!ELEMENT chapter (content, subchapter+)`
 - `<!ELEMENT part (content, part+)`
- relational und hierarchisch gemischt
 - Entities als eigenständige Teile modellieren
 - klar hierarchische Teile als XML-Strukturen
- auch hier sind Entscheidungen nötig
 - welche Teile sollen wiederverwendbar sein?

4.7.2006


XML Vorlesung ETHZ SS 2006

8

Datenbankhersteller und XML

- XML als reines Export/Import-Format
 - die Welt wird weiterhin relational modelliert
 - neue APIs für XML-Support
- XML als Sub-modell in der Datenbank
 - relationale Welt mit XML-orientierten Teilen
 - XML-spezifischer Support in der DB-Engine
- XML als "Informationsmodell" der Applikation
 - XML-basierte Datenbank
 - komplett neue DDL, DML, und Query-Sprache
 - Unterstützung der generischen Funktionen
 - Backup, Administration, Redundanz, Optimierung, ...

Variante 1a: XML → *LOB



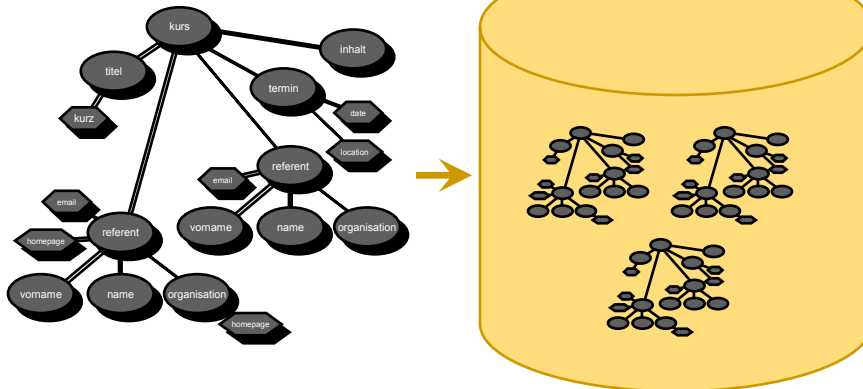
Variante 1b: XML → Spaltentyp

4.7.2006 XML Vorlesung ETHZ SS 2006 11

Variante 2: XML → Shredding

4.7.2006 XML Vorlesung ETHZ SS 2006 12

Variante 3: XML Datenbank



4.7.2006

XML Vorlesung ETHZ SS 2006

13

Relationships in XML

- XML basiert auf einer Dokumentensicht
 - es gibt eine vorgegebene hierarchische Sicht
 - Verweise in dieser Hierarchie sind möglich
- XML ist nicht immer ideal
 - auch Dokumente sind oft "modular" aufgebaut
 - Hierarchien definieren Hauptbeziehungen
 - ER-Modelle definieren gleichberechtigte Beziehungen
- XML modelliert Beziehungen auf zwei Arten
 - Inhalt (beliebig tiefe Verschachtelung)
 - Verweise (von einem Knoten auf einen anderen)

4.7.2006

XML Vorlesung ETHZ SS 2006

14

Referenzen in XML

- *well-formed* XML ist ein Baum
 - keine weitergehende Semantik
 - beliebige Semantik durch Schemasprachen möglich
- *valid* XML kennt Referenzen im Baum
 - Attribute werden als I D (Typ, nicht Name!) deklariert
 - Wert muss eindeutig sein im gesamten XML Dokument
 - Attribute werden als I DREF (S) deklariert
 - müssen auf existierende(n) I Ds verweisen
- XML Schema verallgemeinert I D/I DREF (S)
 - DTD-Mechanismen oft zu primitiv und einschränkend

4.7.2006

XML Vorlesung ETHZ SS 2006

15

XML Schema Identity Constraints

- XML Schema berücksichtigt Datentypen
 - Werte mit unrelated Types sind niemals gleich
 - einer Instanz nicht unbedingt anzusehen
 - z.B. gilt `xs:integer 2` ist nicht gleich `xs:string 2`
 - aber `xs:integer 2` ist gleich `xs:integer +0002`
 - und `xs:string 2` ist nicht gleich `xs:string +0002`
 - Identity Constraints sind auf Instanzen definiert, und nicht auf ihren Typen
- d.h. am besten definiert man eigene Typen
 - z.B. Simple Type als Restriction von `xs:integer`
 - eigene Types für Key und KeyRef

4.7.2006

XML Vorlesung ETHZ SS 2006

16

Semistrukturierte Daten

- XML unterstützt semistrukturierte Daten
- Inhaltsmodelle mit 0-∞ Wiederholungen
 - mehrere Vornamen in einem Namen
 - Reihenfolge der Vornamen ist wichtig
- Text gemischt mit Elementen
 - Text vermischt mit strukturiertem Inhalt
 - `<p>Di eser <i>Text</i> benutzt... </p>`
- keine gute Abbildung auf ER-Konstrukte möglich
 - Vermeidung dieser Aspekte im Modell
 - Speicherung als XML-Struktur

4.7.2006

XML Vorlesung ETHZ SS 2006

17

SQL:2003 Datentyp XML

- neuer Basisdatentyp in SQL:2003
 - vergleichbar BOOLEAN, INTEGER, CHAR, DATE, ...
 - damit im Grundvokabular der Sprache enthalten
- erlaubte Werte des XML Datentyps
 - NULL
 - XML Content (well-formed XML Entity)
 - XML Documents (well-formed XML Dokument)
- kann in DDL Statements benutzt werden
 - `CREATE TABLE DEMO (ID INTEGER, TEXT XML)`

4.7.2006

XML Vorlesung ETHZ SS 2006

18

Eigenschaften des XML Datentyps

- keine Ordnung
 - auch die Gleichheit ist nicht definiert
 - offene Fragen der Zeichenkodierung, Infoset vs. XML, usw.
 - lässt sich benutzerspezifisch definieren
 - CREATE ORDERING FOR . . .
 - potentiell aufwendige Operation
- Erzeugung von XML aus anderen Werten
 - Auswertung von XQuery Anfragen
 - Konstruktoren für XML Knoten
 - Kombinieren bestehender XML Strukturen

4.7.2006

XML Vorlesung ETHZ SS 2006

19

SQL/XML Funktion XMLGEN

- basiert auf XQuery
 - noch nicht abgeschlossene Standardisierung
 - erste prototypische Implementierungen
- Argument ist ein XQuery Ausdruck
 - optional mit einer Liste von Variablen
 - Variablen sind beliebige SQL Wertausdrücke
 - Verwendung im XQuery
- Resultat ist immer vom Typ XML
 - XQuery wird später näher betrachtet

4.7.2006

XML Vorlesung ETHZ SS 2006

20

SQL/XML Funktion XMLELEMENT

- Erzeugung eines Elements
 - Name muss angegeben werden
 - optional können Attribute angegeben werden
 - markiert mit XMLATTRIBUTES

```
SELECT XMLELEMENT(NAME "kurs",
                  XMLATTRIBUTES(id AS Nummer),
                  titel) AS Kursliste FROM Kurse
```

Kursliste:

```
<kurs Nummer="1">XML</kurs>
<kurs Nummer="2">XSLT</kurs>
<kurs Nummer="3">XML und Datenbanken</kurs>
```

4.7.2006

XML Vorlesung ETHZ SS 2006

21

SQL/XML Funktion XMLFOREST

- Erzeugung eines Waldes von XML Elementen
 - kein umschliessendes Element
 - d.h. für sich betrachtet kein XML Dokument
 - Angabe einer Elementliste als Argumente

```
SELECT XMLFOREST(id AS "Nummer",
                 titel )
                 AS Kursliste FROM Kurse
```

Kursliste:

```
<Nummer>1</Nummer><titel >XML</titel >
<Nummer>2</Nummer><titel >XSLT</titel >
<Nummer>3</Nummer><titel >XML und Datenbanken</titel >
```

4.7.2006

XML Vorlesung ETHZ SS 2006

22

SQL/XML Funktion XMLCONCAT

- Zusammenfügen von XML Strukturen
 - Liste von XML-Werten (keine Dokumente)
 - erzeugt einen XML-Wert pro Zeile

```
SELECT XMLCONCAT(XMLELEMENT(NAME "Nummer", id ),
                 XMLELEMENT(NAME "kurs", ti tel))
AS Kursl iste FROM Kurse
```

Kursliste:

```
<Nummer>1</Nummer><kurs>XML</kurs>
<Nummer>2</Nummer><kurs>XSLT</kurs>
<Nummer>3</Nummer><kurs>XML und Datenbanken</kurs>
```

4.7.2006

XML Vorlesung ETHZ SS 2006

23

SQL/XML Funktion XMLAGG

- aggregiert mehrere XML-Werte
 - funktioniert über Zeilen hinweg
 - Zusammenführen von Results in einem XML-Wert
 - optionale Sortierung kann angegeben werden

```
SELECT XMLELEMENT(NAME "kursl iste", TMP) FROM
( SELECT XMLAGG(XMLELEMENT(NAME "Nummer", id ),
                    XMLELEMENT(NAME "kurs", ti tel)) AS TMP
  FROM Kurse ORDER BY ti tel)
```

```
<kursl iste>
<Nummer>1</Nummer><kurs>XML</kurs>
<Nummer>3</Nummer><kurs>XML und Datenbanken</kurs>
<Nummer>2</Nummer><kurs>XSLT</kurs>
</kursl iste>
```

4.7.2006

XML Vorlesung ETHZ SS 2006

24

SQL/XML Funktion XMLCOLATTVAL

- von Oracle vorgeschlagen und implementiert
 - nicht Bestandteil des SQL/XML Standards
 - erzeugt Elemente aus Spalten

```
SELECT XMLELEMENT(NAME "kurs",
                  XMLCOLATTVAL(id, ti tel))
       AS Kursl i ste FROM Kurse
```

Kursliste:

```
<kurs>
  <col umn name="i d">1</col umn>
  <col umn name="ti tel ">XML</col umn>
</kurs>
```

4.7.2006

XML Vorlesung ETHZ SS 2006

25

Weitergehende Regeln

- Abbildungen von Namensräumen
 - SQL und XML haben andere Konventionen
 - u.U. nicht transparente Umwandlung
- Abbildung von Datentypen
 - SQL und XML Schema Datentypen
 - komplexe SQL Datentypen ergeben XML Strukturen
 - z.B. werden SQL Tupel zu Elementlisten

4.7.2006

XML Vorlesung ETHZ SS 2006

26

Zusammenfassung SQL/XML

- einfache Funktionen zur Erzeugung von XML
 - XML Elemente
 - XML Attribute
 - XML Entities (Listen von Elementen)
 - XML Dokumente
- keine Unterstützung von
 - DML Konstrukten
 - Volltextsuche auf XML Dokumenten

4.7.2006

XML Vorlesung ETHZ SS 2006

27

W3C XQuery/XSLT Working Group

- Vereinigung von XQuery und XSLT
 - XQuery aufbauend auf Quilt
 - XSLT 2.0 aufbauend auf XSLT 1.1
- grosse Arbeitsgruppe mit vielen Teilnehmern
 - alle wichtigen Firmen sind vertreten
 - grosse Wahrscheinlichkeit für Akzeptanz
- aufwendiger Entwicklungsprozess
 - parallel aktualisierte Requirements Dokumente
 - Parser und Specs automatisch erzeugt aus EBNF
 - aktueller Stand sind einige Last Call WDs (03/05)

4.7.2006

XML Vorlesung ETHZ SS 2006

28

Querying XML: Language Wars?

- Produkte werden diverse Sprachen anbieten
 - SQL/XML erzeugt XML aus SQL Queries
 - evolutionärer Ansatz auf dem relationalen Datenmodell
 - erlaubt Zugriff auf andere SQL Features
 - Weiterverwendung bestehender SQL Tools/Applikationen
 - XQuery als neue Technologie
 - operiert auf XML als Datenmodell
 - keine DML in der ersten Version, kein Full-Text Support
 - geht von einer XML-zentrierten Anwendung aus
 - XPath als grundlegende Selektionssprache
 - von vielen frühen XML-Datenbanken unterstützt
 - keine echte Query-Sprache, nur einfache Prädikate

4.7.2006

XML Vorlesung ETHZ SS 2006

29

XQuery, XPath und XSLT


- XSLT als Style Sheet Sprache für XML
 - Transformationsteil als Programmiersprache
 - XPath als Expression Language von XSLT
- XSLT 1.0 und XPath 1.0 sind recht einfach
 - sehr schwaches Typsystem
 - praktisch keine Typfehler
- XSLT 2.0 und XPath 2.0 sind viel komplexer
 - XPath 2.0 als gemeinsame Basis für XSLT/XQuery
 - XPath 1.0 kann keine first-order logic
 - XPath 2.0 erweitert XPath 1.0 erheblich

4.7.2006

XML Vorlesung ETHZ SS 2006

30

XQuery Datentypen



- 5 Arten von Datentypen:
 - Knoten
 - Folgen
 - Schemakomponenten
 - einfache Werte
 - 19 XML Schema Datentypen
 - Fehler
 - ein einziger Fehlertyp
- alle Wertebereiche (bis auf Fehler) sind unendlich

4.7.2006

XML Vorlesung ETHZ SS 2006

31

XQuery unterstützt Static Typing

- alle Konstrukte sind typgestützt
 - XML Schema als Voraussetzung
- statische Typanalyse ist möglich
 - weniger Laufzeitfehler
 - XML Schema und XQuery Code reichen aus
 - XQueries können Typen deklarieren (bessere Tests möglich)
- statische Typen haben weitere Vorteile
 - bessere Optimierungen sind möglich
 - generell robustere Software
 - bessere Vorhersage der erwarteten Resultattypen

4.7.2006

XML Vorlesung ETHZ SS 2006

32

FLWOR Expressions

- vergleichbar dem SQL SELECT FROM WHERE
- vergleichbar mit XSLT Konstrukten
 - FOR → xsl : for - each
 - LET → xsl : vari abl e
 - WHERE → xsl : i f
 - ORDER BY → xsl : sort
- deklarative Programmiersprache
 - keine Konstrukte aus prozeduralen Sprachen
- funktional kein tatsächlicher Unterschied
 - mit XSLT und XQuery sind gleiche Resultate möglich

4.7.2006

XML Vorlesung ETHZ SS 2006

33

Zusammenfassung XQuery

- XQuery als neue Query-Sprache
 - operiert auf XML als Datenmodell
- XPath 2.0 als Grundlage von XQuery
 - ebenfalls die Grundlage für XSLT 2.0
 - wird Grundwissen für XML-Experten werden
- momentan noch in Entwicklung
 - Syntax kann sich noch ändern
 - stabiler Standard gegen Ende 2005 zu erwarten

4.7.2006

XML Vorlesung ETHZ SS 2006

34

Zusammenfassung

- XML wird immer wichtiger
 1. XML als Transferformat zwischen Anwendungen
 2. XML als Schnittstelle zwischen Anwendungen
 3. XML als Datenmodell von Anwendungen
- der Grossteil aller Daten ist in Datenbanken
 - zunehmende Unterstützung von XML
- Fusion der Datenmodelle
 - viele Daten sind angemessen mit ER modelliert
 - Teile sind u.U. besser in XML modelliert