XML Vorlesung FH Aargau, SS 2006

XML Schema Teil III

Erik Wilde

15.5.2006

http://dret.net/lectures/xml-fhnw-ss06/

Übersicht

- Reusable Groups
  - Named Model Groups
  - Attribute Groups
- Type Substitution
- Modellierungstechniken in XML Schema
- Namensgebung in Schemas
  - qualified vs. unqualified Names
- Modularisierung von XML Schema
  - Verwendung mehrerer Schemas
  - Erweiterung und Versionierung von Schemas

Was sind Reusable Groups?

- zwei Arten von Reusable Groups
  - einmalige Deklaration und mehrfache Verwendung
  - benannte Gruppierungen von XML Inhalt
    - Named Model Groups für Elementgruppen
    - Attribute Groups für Attributgruppen
- Referenzierung über Gruppennamen
  - in Element Content oder Attributdeklarationen
- entspricht Parameter Entities in DTDs
  - in DTDs eher eine Notlösung
  - in XML Schema ein eingebautes Konzept

Named Model Groups

- Content-Model Strukturen (Gruppe von Elementen), die mehrmals in einem Schema auftreten, werden am besten als *Named Model Group* deklariert
- Beispiel: Elemente *Beschreibung* und *Kommentar* werden in jedem Objekt zur Dokumentation verwendet
- die Gruppe von Element-Deklarationen wird benannt
- überall im Schema, wo die Gruppe von Elementen in einem Content Model verwendet wird, kann sie – anstelle einer Neu-Definition – über den Namen referenziert werden
- Named Model Groups dürfen andere Named Model Groups referenzieren

Named Model Groups

- Beispiel:

```
<xs:group name="dokumentation">
   <xs:sequence>
     <xs:element name="Beschreibung" type="xs:string"/>
     <xs:element name="Kommentar" type="xs:string"
       minOccurs="0"/>
   </xs:sequence>
</xs:group>

...
   <xs:group ref="dokumentation"/>
...
```


Attribute Groups

- Gruppen von Attribute, die mehrmals in einem Schema auftreten, werden am besten als *Attribute Group* deklariert
- Beispiel: Attribute *ID*, *Name* und *Version*
- die Gruppe von Attribut-Deklarationen wird benannt
- überall im Schema, wo die Gruppe von Attributen in einem Schema verwendet wird, kann sie – anstelle einer Neu-Definition – über den Namen referenziert werden
- Attribute Groups dürfen andere Attribute Groups referenzieren

Attribute Groups

- Beispiel:

```
<xs:attributeGroup name="identifier">
    <xs:attribute name="Name" type="xs:string" use="optional"/>
    <xs:attribute name="ID" type="xs:integer"/>
</xs:attributeGroup>
<xs:attributeGroup name="versioning">
    <xs:attribute name="Version" type="xs:integer"/>
    <xs:attributeGroup ref="identifier"/>
</xs:attributeGroup>

...
    <xs:attributeGroup ref="versioning"/>
...
```


Vorteile von Reusable Groups

- Konsistenz über Schema-Komponenten kann erhöht werden
- Änderungen können an einem zentralen Ort gemacht werden
- Zusammenhänge der einzelnen Schema-Komponenten werden offensichtlicher (Teilen von gemeinsamen Strukturen)
- Schema wird übersichtlicher

Was ist Type Substitution?

- ein Element eines abgeleiteten Typen kann in einer Instanz ein Element des entsprechenden Basis-Typs ersetzen
- Type Substitution Varianten:
  - der Typ eines Elementes muss dann mit Attribut `xsi:type` in der Element-Instanz deklariert werden
  - der Typ wird per *Substitution Group* durch den Elementnamen signalisiert
- die Typ Substitution kann mehrstufig sein

Beispiel Type Substitution (I)

- Beispiel: 1. Typ ableiten

```
<xs:complexType name="kochkursTyp">
  <xs:complexContent>
    <xs:extension base="kursTyp">
      <xs:sequence>
        <xs:element name="Kueche" type="xs:string"/>
      </xs:sequence>
    </xs:extension>
  </xs:complexContent>
</xs:complexType>
```

Bespiel Type Substitution (II)

- Beispiel: 2. Type Substitution

```
<Kursliste>
  <Kurs letzteAenderungen="2002-04-06">
    <Kursname>XML Schema Kurs</Kursname>
    ...
  </Kurs>
  <Kurs xsi:type="kochkursTyp"
        letzteAenderungen="2002-04-06">
    <Kursname>Fein Kochen</Kursname>
    ...
    <Kueche>Asiatisch</Kueche>
  </Kurs>
</Kursliste>
```


Kontrolle Type Substitution

- Kontrolle der Ersetzung von Typen
  - Attribut `block` in complexType-Deklaration:
    - `#all`: Typ darf in Instanzen weder durch erweiterten Typ noch durch eingeschränkten Typ ersetzt werden
    - `restriction`: Typ darf nicht durch eingeschränkten Typ ersetzt werden
    - `extension`: Typ darf nicht durch erweiterten Typ ersetzt werden
  - Attribut `abstract` in complexType-Deklaration :
    - Typ darf nicht instanziiert werden

Was sind Substitution Groups?

- erlauben das Ersetzen von Elementen (!) durch andere Elemente in XML Schemas
- Beispiel: das Element Kurs könnte in einer Liste von Kursen ersetzt werden durch Elemente wie Kochkurs, JavaKurs etc
- machen zum Beispiel heterogene Aufzählungen möglich (Liste von Elementen unterschiedlicher Typen in einer Schema-Instanz)
- Substitution Groups machen solche Listen lesbarer

Was sind Substitution Groups?

```
<Kursliste>
   <Kurs letzteAenderungen="2002-03-14">
      <Kursname>XML Schema</Kursname>
      ...
   </Kurs>
   <Kochkurs letzteAenderungen="2002-03-14">
      <Kursname>Fein Kochen</Kursname>
      ...
      <Kueche>Asiatisch</Kueche>
   </Kochkurs>
   <JavaKurs letzteAenderungen="2002-03-14">
      <Kursname>Java Einführung</Kursname>
      ...
   </JavaKurs>
   ...
</Kursliste>
```

Substitution Group Hierarchien

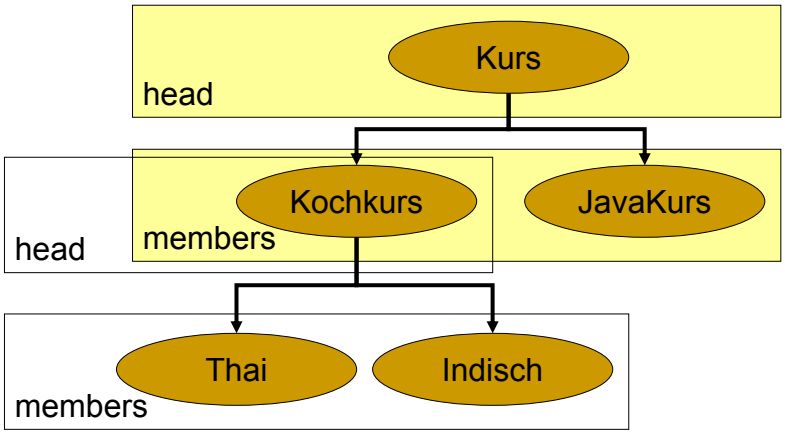

Substitution Group Hierarchien

- eine Substitution Group besteht aus einem *Head* und einem oder mehreren *Members*
- überall wo das *Head* Element in einem Content Model referenziert wird, kann eines der entsprechenden *Member* Elemente verwendet werden
- Elemente können nur zu *einer* Substitution Group gehören
- eine Substitution Group Hierarchie kann aber mehrere Stufen haben

Substitution Group Deklaration

- Beispiel:

```
<xs:element name="Kochkurs" substitutionGroup="Kurs">
  <xs:complexType>
    <xs:complexContent>
      <xs:extension base="kursTyp">
        <xs:sequence>
          <xs:element name="Kueche" type="xs:string"/>
        </xs:sequence>
      </xs:extension>
    </xs:complexContent>
  </xs:complexType>
</xs:element>
```


Substitution Group Deklaration

- Beispiel:

```
<xs:element name="Kursliste">
  <xs:complexType>
    <xs:sequence>
      <xs:element ref="Kurs" maxOccurs="unbounded"/>
    </xs:sequence>
  </xs:complexType>
</xs:element>
```

Substitution Group Deklaration

- Beispiel:

```
<Kursliste>
   <Kurs letzteAenderungen="2002-03-14">
      <Kursname>XML Schema</Kursname>
      ...
   </Kurs>
   <Kochkurs letzteAenderungen="2002-03-14">
      <Kursname>Fein Kochen</Kursname>
      <AnmeldeTermin>2002-06-12</AnmeldeTermin>
      <Referenten>
         <Name>Bossi</Name>
         <Vorname>Betti</Vorname>
      </Referenten>
      ...
      <Kueche>Asiatisch</Kueche>
   </Kochkurs>
</Kursliste>
```


Substitution Group Deklaration

- der *Head* einer Substitution Group wird nicht speziell gekennzeichnet, ausser dass der *Head* als globales Element deklariert werden muss
  - sonst ist er nicht über einen globalen Namen referenzierbar
- *Members* haben ein Attribut `substitutionGroup` in der Element-Deklaration, welches das entsprechende *Head*-Element referenziert
  - *Members* müssen ebenfalls global deklariert sein
- falls das *Member*-Element ohne Typ deklariert wird, hat es automatisch den gleichen Typ wie das *Head* Element
- *Member*-Elemente müssen immer entweder den gleichen Typ wie das *Head*-Element haben, oder aber einen davon abgeleiteten Typ

Substitution Group Deklaration

- Kontrolle über die Verwendung von Substitution Groups in Elementen mit `final`, `block` und `abstract` möglich
  - Attribut `final`: Element darf nicht als Head einer Substitution Group verwendet werden
  - Attribut `block`: verhindert die Bildung von Instanzen, die Substitution Groups verwendet (erlaubt aber Deklaration)
  - Attribut `abstract`: Head Element dient nur als Platzhalter, Members müssen deklariert und instanziert werden

Substitution Group Alternativen

- "heterogene Listen" können auch mit `choice` Groups und *Type Substitution* modelliert werden
- `choice` Group:
  - Liste der möglichen Elemente wird in `choice` Group deklariert
  - feste Verdrahtung dieser Aufzählung in der entsprechenden Gruppe (vgl. *Substitution Group*: Verdrahtung über Referenz, flexibler, Kombination von Schemas)
- Type Substitution:
  - Verwenden des gleichen Element-Namens (z.B. *Kurs*)
  - Element-Typen als Derived Types deklarieren
  - Verwendung des Attributes `xsi:type` im Element-Tag
  - Vorteil: leichtere Verarbeitung (Typ ist direkt benannt)
    - ist aber nach Validierung auch über das Infoset verfügbar

Type Derivation vs. Reusable Groups

- Type Derivation, wenn
  - der wiederverwendbare Teil des Content Models am Anfang des Content Models steht (Subtypen bilden)
  - der komplexe Datentyp ähnliche Objekte beschreibt (Person, Teilnehmer, Referent etc)
- Reusable Groups, wenn
  - der wiederverwendbare Teil in verschiedenen komplexen Datentypen vorkommt, die typmässig nichts miteinander zu tun haben (Personen, Kurse, Autos, etc.)

Modellierungstechniken

- DTD sind "einfacher"
  - keine Typenkonzept, also kein Typenmodell
  - oft Typenmodellierung ausserhalb, dann Mapping auf DTD Mechanismen
- XML Schema unterstützt Typenmodellierung
  - aber muss man es deshalb immer so machen?
  - Varianten der Verwendung von XML Schema
    1. Typen ausserhalb modellieren
    2. XML Schema zur Typmodellierung verwenden
  - XML Schema braucht Planung vor der Verwendung

Russian Doll Design

- Elementdeklarationen ineinander schachteln
  - vermeidet globale Typdefinitionen
- Vorteile des Russian Doll Designs
  - Struktur sehr offensichtlich
  - Vermeidung Doppelspurigkeit Typen/Elemente
- Nachteile des Russian Doll Designs
  - u.U. sehr tiefe Schachtelungstiefe der Elemente
  - keine Wiederverwendung von Deklarationen
    - Rekursionen brechen das Design-Modell
    - Wiederverwendungen brechen das Design-Modell

Venetian Blinds Design

- prinzipiell globale Typdeklarationen
  - Verwendung der Typen per Referenz
- Vorteile des Venetian Blinds Designs
  - Rekursion wird einfach ermöglicht
  - generell: Wiederverwendung von Typen ist einfach
    - zu jedem Element und Attribut gibt es einen Named Type
- Nachteile des Venetian Blinds Designs
  - grosse Menge an (globalen) Typen
    - XML Schema Code wird noch grösser und unübersichtlicher

Praxisorientierte Designmodelle

- in der Praxis oft kombinierte Modelle
  - Russian Doll für restriktive Strukturen
    - Struktur der Instanz stark durch das Schema vorgegeben
  - Venetian Blinds für permissive Strukturen
    - Struktur der Instanz kann sehr stark schwanken
  - viele Schemas sind eine Kombination
    - z.B. in HTML: Tabellenstruktur vs. Tabelleninhalt
- Modellierung nicht immer in XML Schema
  1. Abbildungsvorschriften nach XML Schema
  2. Modellierung im bevorzugten Tool/Formalismus
  3. XML Schema generieren aus externem Modell

Namensgebung in Schemas

- Namen gehorchen den XML-Regeln
  - beginnen mit Buchstaben oder _
  - enthalten Buchstaben, Ziffern und _ : - .
  - immer NCNames verwenden (keine Doppelpunkte)
- Trennungsregeln definieren und befolgen
  - mit Separatoren trennen: _ - .
  - CamelCase benutzen
    - erster Buchstabe GrossBuchstabe oder kleinBuchstabe?
- Typnamen sollten erkennbar sein
  - `Typ(e)` Anhang oder andere Schreibweise

Namespaces und Schemas

- XML Schema unterstützt Namespaces
  - Namespace URI wird im Schema angegeben
  - definiert auf diese Weise einen Namespace
- kein Namespace notwendig
  - bei kleineren Experimenten und im Entwicklungsstadium
  - bei rein lokalen Verwendungen
- Namespace sollte verwendet werden
  - verteilte Verwendung eines Schemas
  - Erweiterung oder Versionierung eines Schemas
- Tip: RDDL hinter der Namespace URI ablegen

Qualified/Unqualified Names

- global Names in Instanzen müssen immer qualified Names verwenden
  - natürlich nur, wenn es einen Namespace gibt
- Kontrolle bei local Names mit zwei Attributen
  - `elementFormDefault` für Elemente
    - Default-Wert ist `unqualified`
  - `attributeFormDefault` für Attribute
    - Default-Wert ist `unqualified`
- `unqualified` bei Elementen kann irritieren
  - Instanzen müssen wissen, ob ein Element-Typ lokal oder global deklariert ist

Unqualified Names + Namespaces

- Unqualified Names sind in keinem Namespace
  - definiert durch `elementFormDefault`
- oft gibt es Default Namespaces
  - praktisch für kompaktere Dokumente
  - `xmlns="..."` im Document Element
  - wird auf alle unqualified Names angewendet
  - kann zu Problemen führen
- gute Planung unerlässlich
  - qualified Names für Elemente empfehlenswert
  - wenige Gründe für den Default-Wert (unqualified)

Qualified Names für Attribute

- Attribute gehören meistens zu Elementen
  - damit sind unqualified Names sinnvoll
  - der XML Schema Default kann belassen werden
- globale Attribute sollten qualified Names haben
  - das haben sie in jedem Fall
    - `attributeFormDefault` ist nur für local Names
  - Beispiele finden sich an verschiedenen Stellen
    - `xml:lang` ist ein solches Attribut aus XML
    - `xsi:type` ein weiteres aus XML Schema
- der Default ist in fast allen Fällen sinnvoll

Sprachabhängige Instanzen

- nicht direkt unterstützt von XML Schema
- Substitution Groups können verwendet werden
  - Abbildung von Elementnamen auf andere Sprachen
    - `<xs:element name="nummer" substitutionGroup="number"/>`
- Nachteile dieser Methode
  - funktioniert nur für Elemente
    - keine Substitution Groups für Attribute
  - alle Elemente müssen global deklariert sein
- u.U. besserer Ansatz: XSLT
  - Transformationen in beide Richtungen definieren

Modularisierung von Schemas

- XML Schema unterscheidet 3 Mechanismen
- `include` ist wie textuelles Einbinden
  - muss global angegeben werden
  - bezieht sich immer auf den gleichen Namespace
- `redefine` erweitert die `include` Methode
  - macht alles, was `include` macht
  - ermöglicht die Neudefinition von Komponenten
    - nur möglich für Complex Types, Simple Types, Named Model Groups, Attribute Groups
- `import` verwendet andere Namespaces
  - Referenzen auf Namen aus anderen Namespaces

Erweiterungsmöglichkeiten

- Erweiterungen wenn möglich evolutionär
  - weniger Kompatibiltätsprobleme
- XML Schema bietet diverse Mechanismen
  - Wildcards (verfügbar für Elemente und Attribute)
  - Type Derivation
  - Substitution Groups
  - Type Redefinition
    - verlangt Kontrolle über das zu erweiternde Schema
  - Reusable Group Redefinition

Versionierung von Schemas

- Versionierung oft notwendig
  - Speziallfall der Erweiterung von Schemas
  - die gleichen Mechanismen sind verwendbar
- Frage der Kompatibilität zwischen Versionen
  - minor Versions müssen voll kompatibel sein
  - major Versions dürfen inkompatibel sein
    - u.U. Fallback-Mechanismen vorsehen
  - Ziel sollte Kompatibilität in beide Richtungen sein
- Kompatibilität über Erweiterungen
  - alte Versionen müssen Untermengen sein

Zusammenfassung

- Reusable Groups:
  - Named Model Groups
  - Attribute Groups
- Substitution Groups
  - erlauben heterogene Aufzählungen
  - Head und Member Elemente deklarieren
  - ähnliche Konzepte:
    - Choice Group
    - Type Substitution