Freie Universität Berlin

XPath und XQuery

Marko Harasic
Freie Universität Berlin
Institut für Informatik
Netzbasierte Informationssysteme
harasic@inf.fu-berlin.de

XML Path Language (XPath)

XPath

- Standard zum Zugreifen auf beliebige Teile eines XML-Dokuments
- keine XML-Anwendung
- wird von XSLT und XQuery benutzt
- Adressierungspfaden eines Dateisystems ähnlich aber wesentlich mächtiger:

  z.B. /order/item

- XPath 1.0 – W3C-Recommendation seit Nov. 1999
  - http://www.w3.org/TR/xpath
- XPath 2.0 – W3C-Recommendation seit Jan. 2007
  - http://www.w3.org/TR/xpath20/

Zugrundelegendes Dokumentenmodell

- ähnliches Modell wie in DOM
  - XML-Dokument als Baum mit Elementen, Attributen und PCDATA als Knoten

- virtuelle Dokument-Wurzel (Wurzelknoten):
  durch "/" repräsentiert (links von "/" steht nichts)
  ⇨ Wurzel-Element immer Kind von "/":
  z.B. /root

Knotentypen (I)

- **Wurzelknoten**
  - oberster Knoten im Baum, dessen Kind der Elementknoten des Dokumentelements ist
  - string-Wert: Verkettung der Zeichendaten aller Textknoten-Kinder in der Dokumentenreihenfolge
- **Elementknoten**
  - Knoten für ein Element
  - string-Wert: Verkettung der Zeichendaten aller Textknoten-Kinder des Elements
- **Attributknoten**
  - Knoten für jedes Element zugeordnete Attribut
  - string-Wert: Normalisierter Attributwert

Knotentypen (II)

- **Textknoten**
  - Knoten der Zeichendaten enthält
  - string-Wert: die Zeichendaten des Textknotens
- **Namensraumknoten**
  - der Namensraum ist jeweils einem Elementknoten als Elternknoten zugeordnet, ist aber nicht Kind dieses Elementknoten
  - string-Wert: URI des Namensraum
- **Kommentarknoten**
  - Knoten für jeden einzelnen Kommentar
  - string-Wert: Kommentarinhalt

Dokumentenreihenfolge

- Baummodell als Basis
- feste Dokumentreihenfoge (document order) = Reihenfolge der Start-Tags im Dokument
- Tiefensuche

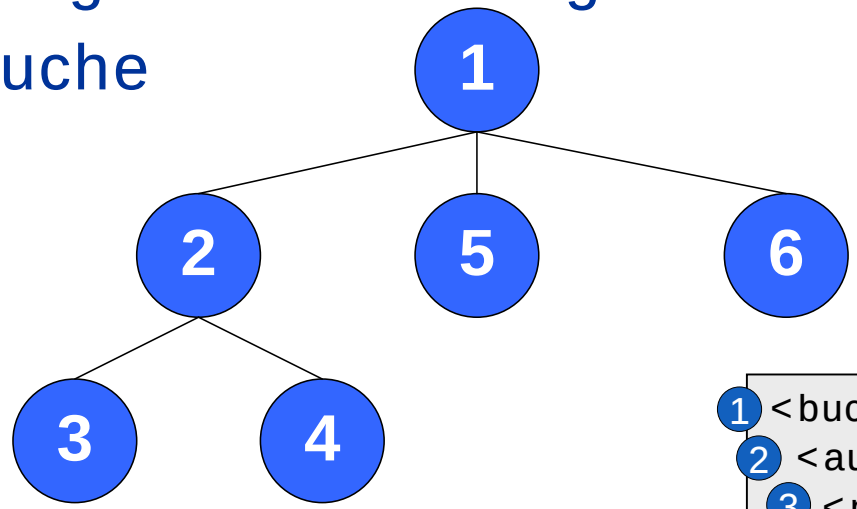


```
1 <buch>
2  <autoren>
3   <name> Anna Baum</name>
4   <name>Hans Gruber</name>
    </autoren>
5   <titel>Ein Buch</titel>
6   <preis>45</preis>
  </buch>
```

(De)Serialisierung


```
<buch>
 <autoren>
  <name> Anna Baum</name>
  <name>Hans Gruber</name>
 </autoren>
 <titel>Ein Buch</titel>
 <preis>45</preis>
</buch>
```

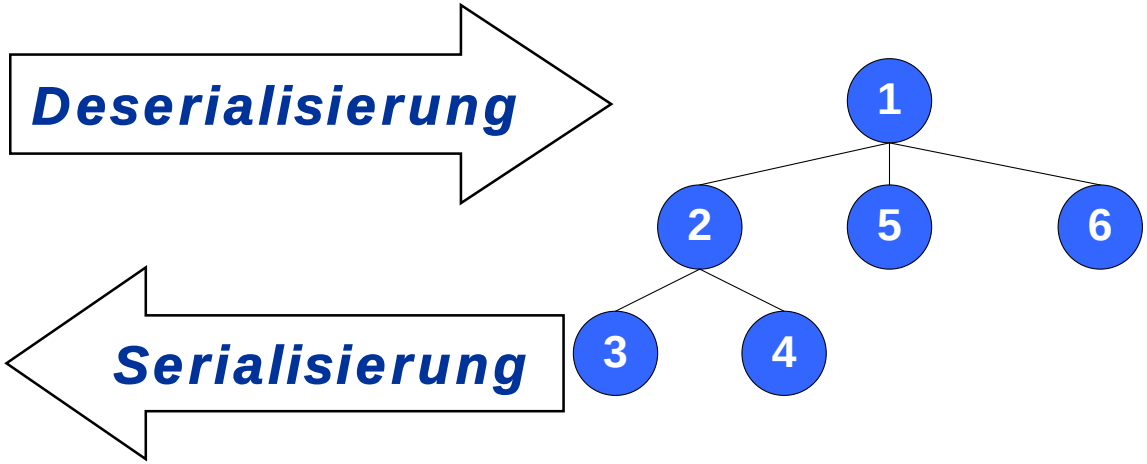

- **Deserialisierung** – Erzeugung eines Baums aus einem Dokument
- **Serialisierung** – Erzeugung eines Dokuments aus einem Baum

Zugriff auf Elemente und Attribute

- Elemente werden einfach **über ihren Namen** identifiziert:

  z.B. **order** oder order/**item**

- Attribute werden mit **"@name"** identifiziert:

  z.B. **@id** oder order/**@id**

```
<?xml version="..." encoding="..."?>
<order id="O56">
  <item item-id="E16-2">
    <name>buch</name>
  </item>
</order>
```

Pfad-Ausdrücke

.	aktueller Knoten
..	Eltern-Knoten
*	beliebiges Kind-Element
@*	beliebiges Attribut
//	überspringt ≥ 0 Hierarchie-Ebenen nach unten
[]	spezifiziert ein Element
|	Auswahl (Vereinigung)

Beispiel: *|@*

„Kind-Element oder Attribut des aktuellen Knotens“

Absolute und relative Pfade

- absolute Pfade
  - beginnen mit /

    z.B. /order/item

    lesen: (➔)Folge dem Pfad von der Dokument-Wurzel zu einem Kind-Element order und von dort aus zu einem Kind-Elementen item!
- relative Pfade
  - beginnen mit einem Element oder Attribut

    z.B. order/item

    lesen: (🡐) item-Elemente, die Kind eines Elementes order sind
  - Element order kann an beliebiger Stelle des XML-Dokumentes stehen

Kontext-Knoten

- XPath-Pfade werden in XSLT immer bzgl. eines bestimmten **Kontext-Knotens** ausgewertet:
  Element-, Attribut- oder Text-Knoten
- Beispiel:

```
<xsl:template match="p">
      <DIV>
        <xsl:value-of select="."/>
      </DIV>
</xsl:template>
```

- Was bedeutet hier aktueller Knoten "." ?
- "." = Kontext-Knoten
- Kontext-Knoten = Knoten, auf den das Template angewandt wird (hier ein p-Element)

Ausführliche Schreibweise

```
<?xml version="..." encoding="..."?>
<buch>
  <autoren item-id="E16-2">
    <name> Anna Baum</name>
    <name>Hans Gruber</name>
  </autoren>
   <titel>Ein Buch</titel>
   <preis>45</preis>
</buch>
```

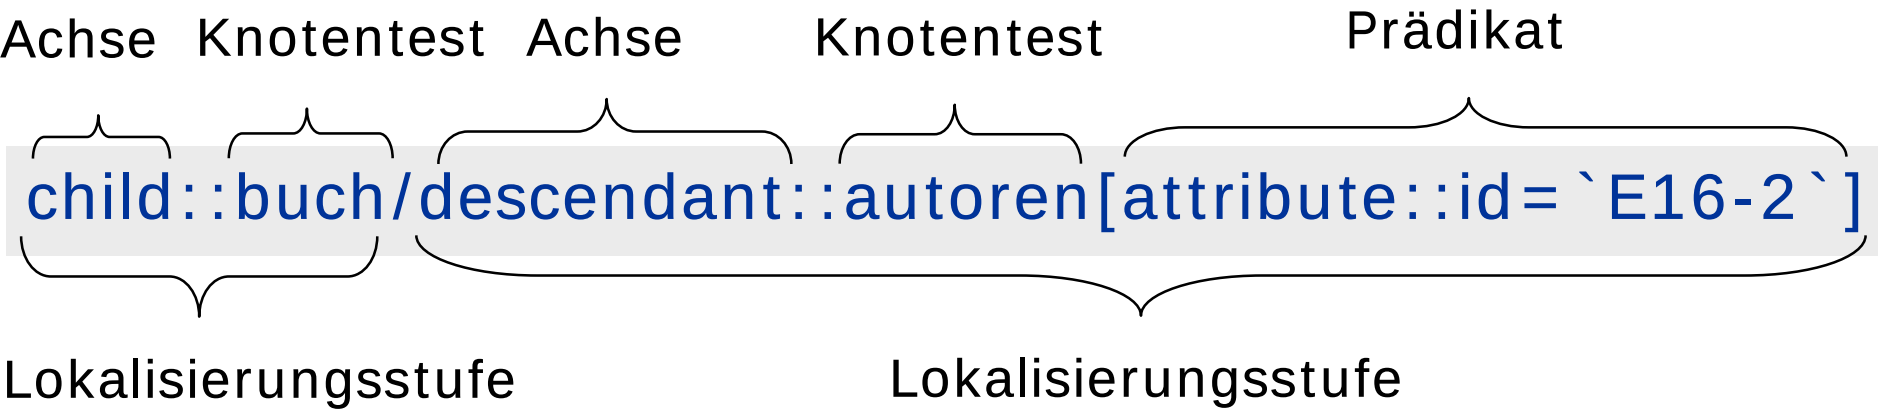

Lokalisierungsstufe

- besteht aus:
  - einem Achsenbezeichner
  - einem Knotentest
  - einem oder mehreren Prädikat (optional)

  ...in der Form:

```
Achsenbezeichner::Knotentest[Prädikat1][Prädikat2]
```

- :: Trennzeichen zwischen Achsenbezeichner und Knotentest

Achsen

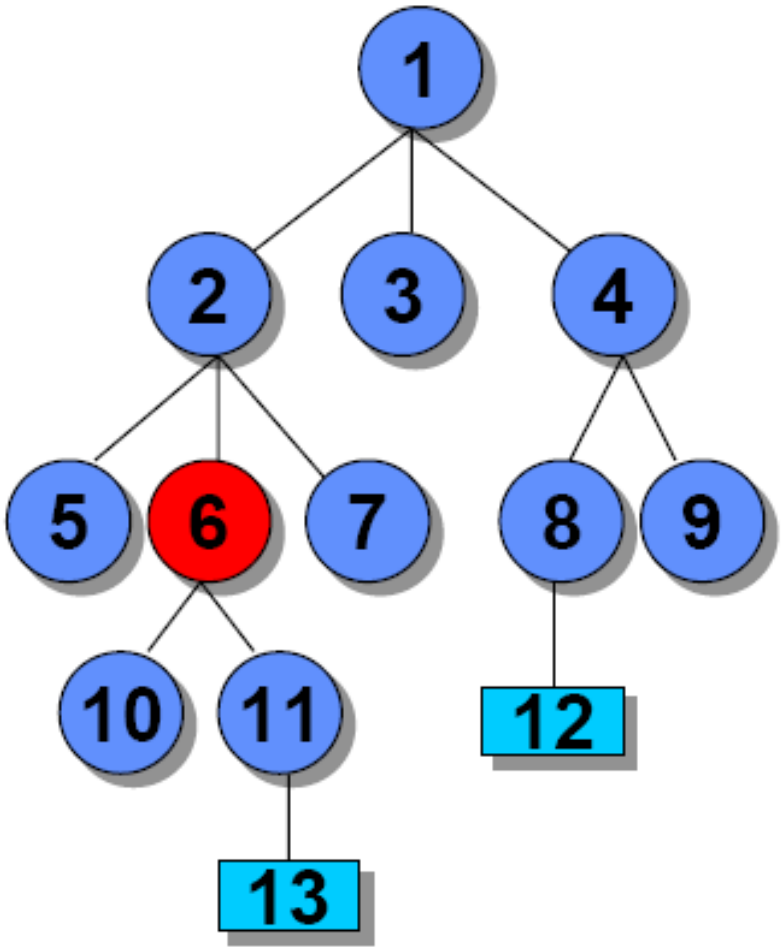

Quelle: http://swt.cs.tu-berlin.de/informatik2000/skripte/xml-datenbank.pdf

- self:: 6
- child:: 10, 11
- parent:: 2
- descendant:: 10, 11, 13
- descendant-or-self:: 6, 10, 11, 13
- ancestor:: 2, 1
- ancestor-or-self:: 6, 2, 1
- preceding-sibling:: 5
- preceding:: 5, 2, 1
- following-sibling:: 7
- following:: 10,11,13, 7, 3, 4, 8, 12, 9

Knotentest

- Filterung der Knotenmenge
- Filterungs-Kriterium:
  - Knotenname

    z.B.: child::buch

  - Knotentyp

    z.B.: child::text()

    child::node()

Prädikate

- Verfeinerung der Filterung durch Prädikate
- Anzahl der Prädikate ≥ 0
- [ ] Bedingung
- Prädikatausdruck unterstützen
  - logische Operatoren: <, >, ≤, ≥, =, !=

    >, < müssen als Entity-Referenzen > und < benutzt werden
  - numerische Operatoren: +, -, *, div, mod

Prädikate – Randbedingungen für Pfade

- order/item[@item-id = 'E16-2']
  - item-Elemente, die Kind von order sind und Attribut item-id mit Wert 'E16-2' haben

```
<order id="4711">
 <item item-id="E16-2">
  <name>buch</name>
 </item>
</order>
```

- Randbedingungen können an beliebiger Stelle in einem Pfad vorkommen:
  - order[@order-id = '4711']/item

```
<orders>
 <order id="4711">
  <item item-id="E16-2">
   <name>buch</name>
  </item>
 </order>
 <order id="4711">
  <item item-id="E16-3"/>
 </order>
</orders>
```

XPath Funktionen

Grundlegende Datentypen

- node-set – eine ungeordnete Knotenmenge
- string – Zeichenfolge
- boolean – true und false
- number – Fließkommazahl

Knotenmenge-Funktionen

- Funktionen:
  - *number* last() — eine Zahl, die die Größe der aktuellen Knotenmenge entspricht
  - *number* position() — Position eines Knotens
  - *number* count(node-set) — Anzahl der Knoten in der Knotenmenge

- Beispiele:

```
order/item[position() = 1]
order/item[position()=last()]
```

String-Funktionen

- Funktionen:
  - *string* string(object)
    interpretiert ein übergebenes Argument als Zeichenkette
  - *string* string-length(string)
    Länge vom String (Anzahl der Zeichen)
  - *boolean* starts-with(string, string)
    true wenn die erste Zeichenkette mit der zweiten Zeichenkette anfängt

Boolesche Funktionen

Freie Universität Berlin

- Funktionen:
  - *boolean* boolean(object)
    Objekt ist +0,-0,NaN, { }, „“ => **false** , sonst **true**
  - *boolean* not(boolean)
    Negation
  - *boolean* true() – immer true
  - *boolean* false() – immer false
- Beispiel:
  order/item[not(position()=last())]

Numerische Funktionen

- Funktionen:
  - *number* number(object)
    interpretiert Zeichenkette als Zahl
  - *number* sum(node-set)
    Gesamtsumme der Zahlenwerte der Knotenmenge (nach Umwandlung)
  - *number* round(number)
    rundet den Wert zur nächsten Ganzzahl
- Beispiel:

  number(3xy) → 3

Beispiele

Wähle das Wurzelelement AAA aus:

```
<AAA>
    <BBB/>
    <CCC/>
    <BBB/>
    <BBB/>
    <DDD>
        <BBB/>
    </DDD>
    <CCC/>
</AAA>
```

/AAA

Wähle alle CCC Elemente aus, die Kinder des Elements AAA sind:

```
<AAA>
    <BBB/>
    <CCC/>
    <BBB/>
    <BBB/>
    <DDD>
        <BBB/>
    </DDD>
    <CCC/>
</AAA>
```

/AAA/CCC

Beispiele

//BBB

```
<AAA>
    <BBB/>
    <CCC/>
    <BBB/>
    <DDD>
        <BBB/>
    </DDD>
    <CCC>
        <DDD>
            <BBB/>
            <BBB/>
        </DDD>
    </CCC>
</AAA>
```

//DDD/BBB

```
<AAA>
    <BBB/>
    <CCC/>
    <BBB/>
    <DDD>
        <BBB/>
    </DDD>
    <CCC>
        <DDD>
            <BBB/>
            <BBB/>
        </DDD>
    </CCC>
</AAA>
```

Beispiele

/*/*/*/BBB

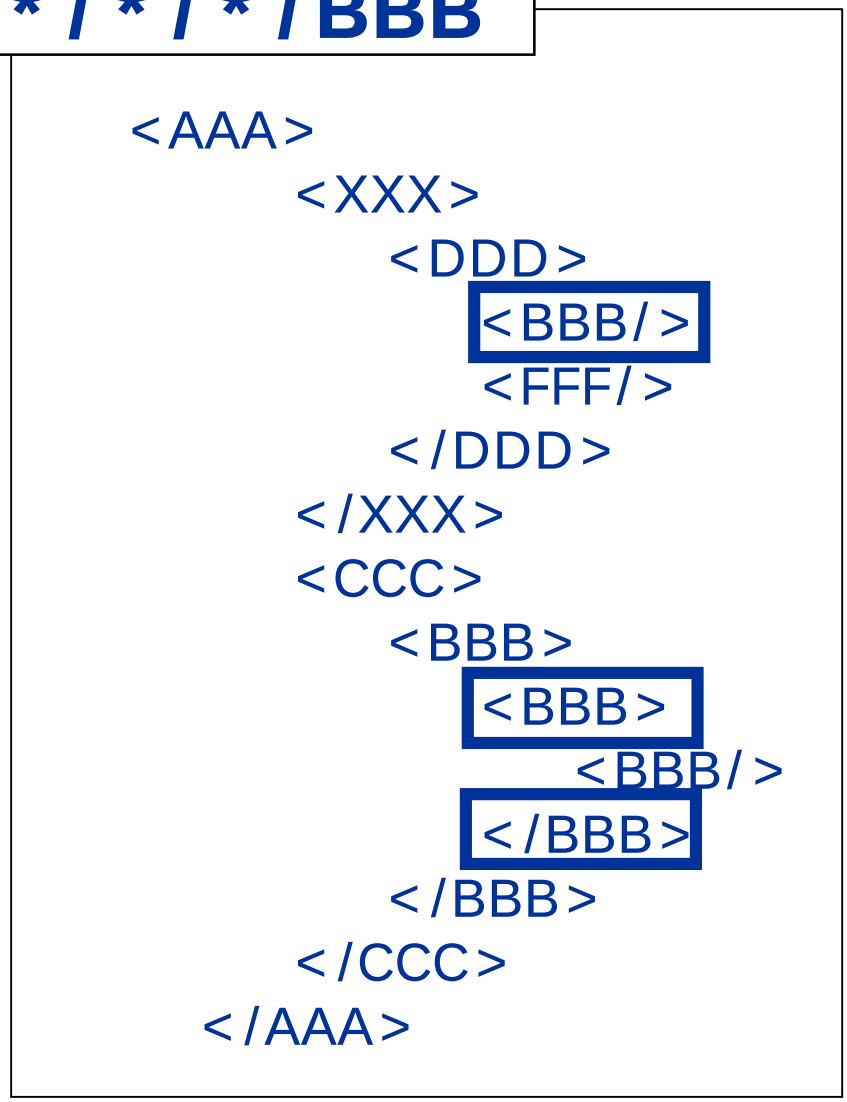

//*

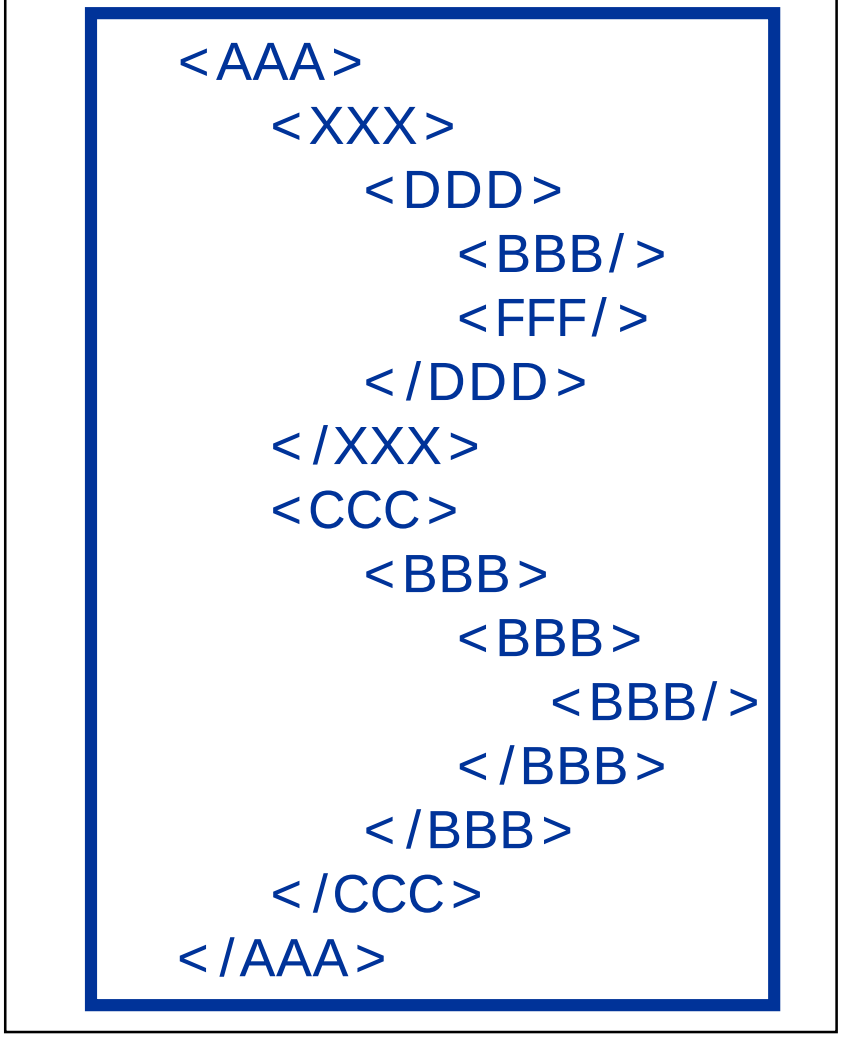

Beispiele

/AAA/BBB[last()]

```
<AAA>
    <BBB/>
    <BBB/>
    <BBB/>
    <BBB/>
</AAA>
```

//@id

```
<AAA>
   <BBB id="b1"/>
   <BBB id="b2"/>
  <BBB
      name="bbb"/>
 <BBB/>
</AAA>
```

Beispiele

//CCC | //BBB

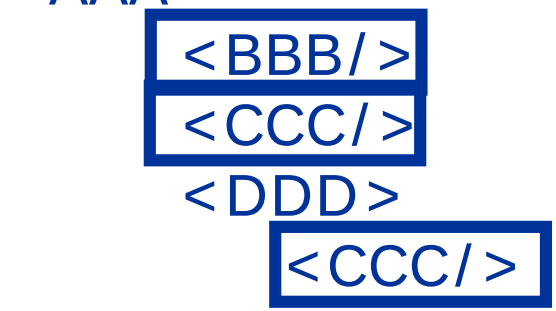

//CCC/following-sibling::*

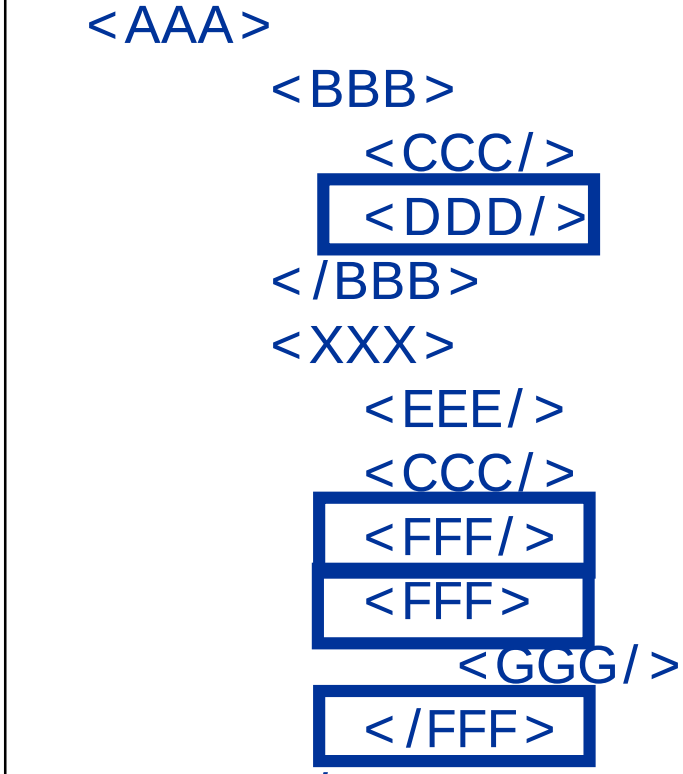

⇨ http://www.futurelab.ch/xmlkurs/xpath.de.html

XPath 2.0

- Januar 2007 – W3C Recommendation für neue Version von XPath
- zeitgleich mit XQuery 1.0 & XSLT 2.0
  - erweitertes Datenmodell
  - neue Konstrukte für Ausdrücke
  - neue Datentypen
  - neue Operatoren
  - erweiterte Funktionsbibliothek

Erweitertes Datenmodell

- Berücksichtigung einzelner Werte (**atomic values**)
- Daten unterschiedlichen Typs:
  - Zeichenfolgen, Zahlen, logische Werte, Datums- und Zeitwerte
  - qualifizierte Namen & URIs
  - einfache Sequenzen & Listen
- Ergebnis eines XPath Ausdrucks: Auswahl von Knoten, Einzelwert oder Sequenz

- XPath 2.0 auf Knotenbaum
  - nur Daten auslesen
- XPath 2.0 auf Einzelwerten & Sequenzen
  - neue Werte/Sequenzen erzeugen

Konstrukte für Ausdrücke

- für Operationen mit Sequenzen Verwendung des ***for***-Ausdrucks

- Beispiel

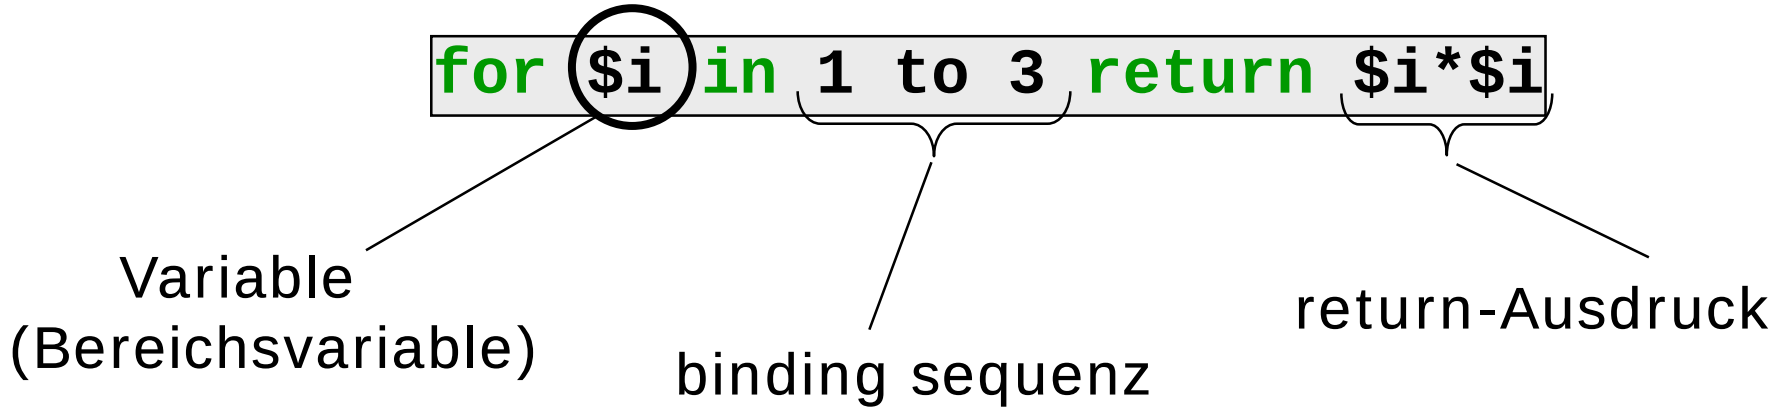

Ergebnis: 1, 4, 9

Weitere Ausdrucke

- bedingter Ausdruck ***if***

```
if @menge > 1000 then “gut“ else “weniger gut“
```

- quantifizierende Ausdrücke ***some*** und ***every***

```
some $a in $lager/artikel satisfies $lager/artikel/menge=0
```

  - wahr, wenn die Menge mind. bei einem Artikel = 0

```
every $a in $lager/artikel satisfies $lager/artikel/menge>0
```

  - wahr, wenn von allen Artikeln mind. einer vorhanden ist.

Datentypen

- Unterstützung der XML-Schema Datentypen

- XPath 1.0
  - number – Fließkommazahl

- XPath 2.0
  - integer
  - decimals
  - single precision
  - Datums-, Zeit- und Dauerwerte

Operatoren

- Knotenvergleiche
  - ***is*** – prüft, ob zwei Ausdrücke den selben Knoten liefern
  - **<<**, **>>** – prüfen, welcher von zwei Knoten in der Dokumentreihenfolge früher oder später erscheint

- Kombination von Knotensequenzen
  - ***union*** – Vereinigung zwei Knotensequenzen zu einer Sequenz
  - ***intersect*** – erzeugt aus zwei Sequenzen eine Sequenz, die Knoten enthält, die in beiden vorkommen
  - ***except*** – erzeugt aus zwei Sequenzen eine Sequenz, die Knoten enthält, die in der ersten Sequenz aber nicht in der zweiten vorkommen

Funktionen in Xpath (und Xquery)

- Xpath, Xquery und XSLT Ausdrücke können Funktionen verwenden
- Vereinheitlicht in Standard
  - XQuery 1.0 and XPath 2.0 Functions and Operators (Second Edition)
  - W3C Recommendation 14 December 2010
  - http://www.w3.org/TR/xpath-functions/
- Neue Version 8.1.13…

- Im Folgenden exemplarische Auszüge aus http://www.w3schools.com/xpath/xpath_functions.asp
- Namensraum fn hat die URI http://www.w3.org/2005/xpath-functions

Zusätzlich Funktionen

- Zugriffe
- Numerische Funktionen
- Zeichenketten
- Zeit, Datum
- Knoten
- Listen
- Kardinalitäten
- Statistik
- Verarbeitungskontext

XQuery

Was ist XQuery?

XQuery …

- ist **die Abfragesprache** für XML-Daten
  - XML-Dateien &
  - alles was in XML darstellbar ist (auch DBs)

- ist für XML das, was SQL für Datenbanken
- basiert auf **XPath-Ausdrucken**
- wird bei fast allen DB-Engines unterstützt (IBM, Oracle, Microsoft, etc.)
- ist sein Januar 2007 eine **W3C Recommendation**
  → http://www.w3.org/TR/xquery/

XQuery kann benutzt werden um ...

- Informationen zu extrahieren, um sie in Web Services zu nutzen
- in Web-Dokumenten nach relevanten Informationen zu suchen
- XML in XHTML zu transformieren
- Reports zu generieren

Einfache Anfrage

- XPath Ausdruck ist eine Anfrage an ein XML-Dokument

```
doc('test')//student
```

- Ergebnis der Anfrage: Alle <student>-Knoten

- Komplexe Anfrageausdrücke als FLWOR („Flower“)
  - For Auswahl von Elementen
  - Let Wertzuweisung an Variablen
  - Where Filtern von Elementen
  - Order by Ergebnisordnung
  - Return Ergebnisrückgabe

Beispiel

```
for $d in fn:doc("depts.xml")/depts/deptno
let $e := fn:doc("emps.xml")/emps/emp[deptno=$d]
where fn:count($e) >= 10
order by fn:avg($e/salary) descending
return
   <big-dept>
     { $d,
     <headcount>{fn:count($e)}</headcount>,
     <avgsal>{fn:avg($e/salary)}</avgsal>    }
   </big-dept>
```

For Klausel

- For erzeugt einen Strom aus Objekttupeln
- Dieser wird iterativ verarbeitet

```
for $s in (<one/>, <two/>, <three/>)
return <out>{$s}</out>
```

```
<out>
  <one/>
</out>
<out>
  <two/>
</out>
<out>
  <three/>
</out>
```

XML Knoten

- Strom aus zu betrachtenden Knoten mit XPath Ausdruck

```
for $s in doc('test')//student
return $s/name/text()
```

- Ergibt

```
Joe AverageJack Doe
```

- doc(URI) betrachtet das Document bei URI

```
<students>
 <student id="100026">
  <name>Joe Average</name><age>21</age>
  <major>Biology</major>
  <results>
   <result course="Math 101" grade="C-"/>
   <result course="Biology 101" grade="C+"/>
   <result course="Statistics 101" grade="D"/>
  </results>
 </student>
 <student id="100078">
  <name>Jack Doe</name><age>18</age>
  <major>Physics</major>
  <major>XML Science</major>
  <results>
   <result course="Math 101" grade="A"/>
   <result course="XML 101" grade="A-"/>
   <result course="Physics 101" grade="B+"/>
   <result course="XML 102" grade="A"/>
  </results>
 </student>
</students>
```

Beispiele nach *Anders Møller and Michael I. Schwartzbach.* An Introduction to XML and Web Technologies Addison-Wesley, 2006

Let Klausel

- Let ist eine Zuweisung innerhalb einer Iteration über den Tupelstrom:

```
for $s in (<one/>, <two/>, <three/>)
let $t := ($s, <four/>, <five/>)
return <out>{$t}</out>
```

```
<out>
  <one/>
  <four/>
  <five/>
</out>
```

```
<out>
  <two/>
  <four/>
  <five/>
</out>
```

```
<out>
  <three/>
  <four/>
  <five/>
</out>
```

Am Beispiel

```
for $s in doc("test")//student
let $m := $s/major/text()
return  <studies> {$s/name/text()}: {$m} </studies>
```

```
<studies>Joe Average: Biology</studies>
<studies>Jack Doe: PhysicsXML Science</studies>
```

Where Klausel

- Filter der mit allen aus for und let erzeugten Tupeln geprüft wird
- Bei true wird return Klausel ausgeführt

```
for $s in fn:doc("students.xml")//student
let $m := $s/major
where fn:count($m) ge 2
return <double> { $s/name/text() } </double>

<double>Jack Doe</double>
```

Verarbeitungsreihenfolge

- Bearbeitung und Ausgabe entsprechend dem Tupelstrom
- Änderbar durch ordering mode

```
unordered {
for $p in fn:doc("parts.xml")/parts/part[color = "Red"],
$s in fn:doc("suppliers.xml")/suppliers/supplier
where $p/suppno = $s/suppno
return <ps> { $p/partno, $s/suppno } </ps>
}
```

- ordered: Entsprechend Standard, Dokumentenordnung
- unordered: Implementierungsabhängig, nichtdeterministisch

Order by Klausel

- Order by Klausel ordnet den Tuplestrom entsprechend um und wendet dann die Return Klausel an

```
for $s in fn:doc("students.xml")//student
let $m := $s/major
where fn:count($m) ge 2
order by $s/@id
return <double> { $s/name/text() } </double>
```

Order by

- Sortieren nach mehreren Kriterien:

```
for $s in doc("students.xml")//student
order by fn:count($s/results/result[fn:contains(@grade,"A")])
    descending,
  fn:count($s/major) descending,
  xs:integer($s/age/text()) ascending
return $s/name/text()
```

- Jack DoeJoe Average

Return Klausel

- Return Klausel bei allen Tupeln angewandt die durch den where-Filter gekommen sind
- Return Ergebnisse zusammengehängt als Ergebnis der Anfrage

- Abstraktion und Fallunterscheidung

```
declare function local:grade($g) {
  if ($g="A") then 4.0 else if ($g="A-") then 3.7
  else if ($g="B+") then 3.3 else if ($g="B")  then 3.0
  else if ($g="B-") then 2.7 else if ($g="C+") then 2.3
  else if ($g="C")  then 2.0 else if ($g="C-") then 1.7
  else if ($g="D+") then 1.3 else if ($g="D")  then 1.0
  else if ($g="D-") then 0.7 else 0
};

declare function local:gpa($s) {
  fn:avg(for $g in $s/results/result/@grade return
   local:grade($g))
};
```

Grade Point Average

- Abstraktion und Fallunterscheidung

```
<gpas>
  { for $s in fn:doc("students.xml")//student
    return <gpa id="{$s/@id}" gpa="{local:gpa($s)}"/>
  }
</gpas>

<gpas>
  <gpa id="100026" gpa="1.6666666666666667"/>
  <gpa id="100078" gpa="3.75"/>
</gpas>
```