



Semistrukturierte Daten

Sommersemester 2008

Teil 7: XPath 1.0

- 7.1. Einführung
- 7.2. XPath Ausdrücke (expressions)
- 7.3. Pfadangaben (location paths)
- 7.4. Operatoren
- 7.5. Vordefinierte Funktionen



7.1. Einführung

- XPath Recommendation
- Datenmodell
- Document Order
- String-Wert

XPath Recommendation

- XPath ist die Basis für viele XML-related Standards:
 - insbesondere für XSLT
 - aber auch für XPointer und XQuery
 - (in eingeschränkter Form) auch in XML Schema
 - XPath ist selbst nicht in XML Notation
- Hauptaufgabe:
 - Navigation im Dokumentenbaum
 - Selektion von **Knotenmengen** und Inhalten
 - einfache Operationen auf Inhalten
 - => weitere Datentypen: **String, Number, Boolean**
- Versionen:
 - **XPath 1.0**: Recommendation seit 1999
 - XPath 2.0: Recommendation seit 2007: entspricht im wesentlichen XQuery ohne Benutzer-definierte Funktionen

Datenmodell (1)

- XPath betrachtet ein **XML-Dokument als Baum**
- Dieser Baum ist leicht abweichend vom "DOM"
- 7 Arten von Knoten im Dokumentenbaum:
 - **Root node**: Wurzelknoten des Baums als parent des Dokuments (für PIs und comments im Prolog)
 - **Element nodes**: für jedes Element im Dokument
 - **Attribute nodes**: assoziiert mit entsprechendem element node
 - **Namespace nodes**: für alle NS-Präfixe plus einen etwaigen Default-NS, die für ein Element gültig sind
 - **Processing instruction nodes**: für jede PI.
 - **Comment nodes**: für jeden Kommentar
 - **Text nodes**: Zeichendaten werden in möglichst große text nodes zusammengefasst

Datenmodell (2)

- Knoten liefern die folgenden Informationen:
 - **Name:** qualifizierter Name bei element und attribute nodes, Präfix bei namespace nodes
 - **URI:** Namespace eines element bzw. attribute nodes
 - **Elternknoten:** jeder Knoten außer der root node hat genau einen Elternknoten.
 - **Liste von Kindknoten:** nur bei root und element node
 - **Wert:** (siehe nächste Folie)
 - **Sammlung von attribute und namespace nodes:** nur bei element nodes; die namespace nodes enthalten die aktuellen Präfix-Bindungen; die attribute nodes enthalten die Attribute des Elements (außer xmlns und xmlns:*präfix*).


String-Wert eines Knoten

- **Root node:** Konkatenation aller Textknoten im Dokument
- **Element node:** Konkatenation aller Textknoten unterhalb eines Elementknotens, d.h.: descendant::text()
- **Attribute node:** normalisierter Attributwert
- **Namespace node:** Namespace-URI
- **Processing instruction node:** String hinter dem (lokalen) Namen der PI, z.B. `'type="text/css" href="lehre.css"'`
- **Comment node:** Inhalt des Kommentars, ohne `<!--` und `-->`
- **Text nodes:** Zeicheninhalt

Beispiel: XML Dokument

```
<?xml version="1.0" encoding="ISO-8859-1"?>
<!-- DBAI -->
<?xml-stylesheet type="text/css" href="lehre.css"?>
<lehre>
  <veranstaltung jahr="2008">
    <titel>Semistrukturierte Daten</titel>
    <vorbesprechung>
      <datum>Mi 5.3.</datum>
      <zeit cum_tempore="yes">15:00</zeit>
      <ort>Radinger HS</ort>
    </vorbesprechung>
    <schlagwort>XML</schlagwort>
    <schlagwort>DTD</schlagwort>
    <schlagwort>SGML</schlagwort>
  </veranstaltung>
</lehre>
```

Beispiel: Dokumentenbaum



Document Order

- Alle Knoten im Baum sind geordnet.
- Die Ordnung der **element nodes** im Baum ist top-down, left-to-right (d.h.: Reihenfolge der Start-Tags ist entscheidend)
- Reihenfolge **innerhalb der namespace nodes** eines Elements bzw. innerhalb der **attribute nodes** eines Elements ist implementierungsabhängig.
- Wenn Resultat eines XPath-Ausdrucks eine Knotenmenge ist, dann sind diese Knoten geordnet:
 - normalerweise in "document order"
 - bei Navigation in umgekehrter Richtung: "reverse document order"

7.2. XPath Ausdrücke (expressions)

- XPath Auswertung
- Datentypen
- Typ-Konvertierungen

XPath Auswertung

- **Expression** = zentrales syntaktisches Konstrukt in XPath
- Die Auswertung einer XPath Expression geschieht immer relativ zu einem **Kontext**:
 - **context-node** Knoten im Dokumentenbaum
 - **context-position** pos. Integer
 - **context-size** pos. Integer
 - **variable bindings** für alle Variablen einer XPath expression (Variablennotation: \$x)

context-node/position/size können sich während der Auswertung einer XPath expression ändern (s.u.)

Datentypen

- **4 Datentypen** als mögliches Resultat einer XPath Expression:
 - ☐ node-set
 - ☐ boolean
 - ☐ number
 - ☐ string
- **Typkonvertierungen** in XPath:
 - ☐ implizit: Operanden von Operatoren, die einen bestimmten Typ erwarten, z.B.: Operanden von **and** müssen boolean sein.
 - ☐ explizit: durch Aufruf der XPath-Konvertierungsfunktionen **string(x)**, **number(x)**, **boolean(x)**
 - ☐ Konvertierung in ein node-set ist nicht möglich!

Typ-Konvertierungen (1)

- Konvertierung node-set -> string/number/boolean
 - `string(x)` = Stringwert des ersten Knotens von x
bzw. leerer String (bei leerem node-set x)
 - `number(x)` = `number(string(x))`
 - `boolean(x)` = `true`, falls x nicht leer ist (sonst `false`)
- Konvertierung string -> number/boolean
 - `number(x)` = von x dargestellte Zahl bzw.
`NaN` falls x keine Zahl darstellt.
 - `boolean(x)` = `true`, falls x ein nicht-leerer String ist
(sonst `false`)

Typ-Konvertierungen (2)

■ Konvertierung number -> string/boolean

□ `string(x)` = Dezimaldarstellung von x bzw.
"NaN" (= not a number),
"Infinity", "-Infinity"

□ `boolean(x)` = `true`, falls x weder 0 noch NaN
(sonst `false`)

■ Konvertierung boolean -> string/number

□ `string(x)` = "`true`", falls x = `true` (sonst "`false`")

□ `number(x)` = 1 falls x = `true` (sonst 0)

7.3. Pfadangaben (location paths)

- Überblick
- Location steps
- XPath Achsen
- Node tests
- Abkürzungen
- Filter (= "predicates")
- Filterlisten
- Auswertung von Location steps

Überblick

- wichtigste Form von XPath Expressions: Pfadangaben
(= **location paths**)
- Ein Pfad besteht aus 1 oder mehreren Schritten
(= **location steps**)
- Absoluter Pfad:
 - beginnt beim root node
 - Schreibweise, z.B.: `/lehre/veranstaltung/schlagwort`
- Relativer Pfad:
 - beginnt beim aktuellen context-node
 - Schreibweise, z.B.: `veranstaltung/schlagwort`

Beispiele

- Absoluter Pfad:

`/lehre/veranstaltung/titel`

bzw. `/child::lehre/child::veranstaltung/child::titel`

- Relativer Pfad:

`veranstaltung/titel` bzw. `child::veranstaltung/child::titel`

`zeit/@cum_tempore` bzw. `child::zeit/attribute::cum_tempore`

- Verwendung von Filtern:


`//zeit[@cum_tempore="yes"]` bzw.

`/descendant-or-self::zeit[attribute::cum_tempore="yes"]`


`schlagwort[2]` bzw. `child::schlagwort[position()=2]`

`schlagwort[last()]` bzw. `child::schlagwort[position()=last()]`


Beispiel: absolute Pfade



Beispiel: relative Pfade



Beispiel: Verwendung von Filtern



Location Steps

- Ein Pfad setzt sich aus beliebig vielen Schritten zusammen (= location steps)
- Bestandteile eines location steps:
 - **Achse**: Richtung, in die navigiert wird
 - **Node-Test**: Typ bzw. Name der gewünschten Knoten
 - keine, eine, oder mehrere Filterbedingungen (= "**predicates**")
- Beispiele:
 - `child::schlagwort[2]`
 - `parent::*`
 - `preceding-sibling::text()[last()]`
 - `following::node()[@cum_tempore="yes"][1]`
 - `attribute::jahr`
 - `descendant::processing-instruction()`

XPath Achsen (1)

- **child**: Kind-Knoten
- **descendant**: alle Nachfahren
- **descendant-or-self**: alle Nachfahren und selbst
- **parent**: Elternelement
- **ancestor**: Vorfahren
- **ancestor-or-self**: alle Vorfahren und selbst
- **self**: der Knoten selbst


XPath Achsen (2)

- **following**: alle in document order nachfolgenden Knoten außer eigene Nachfahren
- **following-sibling**: alle nachfolgenden Geschwisterknoten
- **preceding**: alle in document order vorangehenden Knoten außer eigene Vorfahren
- **preceding-sibling**: alle vorangehenden Geschwisterknoten

preceding(-sibling) bzw. **ancestor(-or-self)** erzeugen node-sets in **reverse** document order.

- **attribute**: alle Attribute eines Elements
- **namespace**: alle Namespaces eines Elements

Dokumentenbaum: XPath Achsen (3)



Node Tests

- Üblicherweise: Angabe eines Namen
z.B. `/child::lehre/descendant::zeit`
- *** steht für beliebigen Namen, z.B.:
 - `child::*` gibt alle Kind-Elementknoten zurück
 - `attribute::*` gibt alle Attributknoten zurück
- *prefix:** steht für beliebige qual. Namen mit Präfix *prefix*
- `comment()`: alle Kommentar-Knoten
z.B. `/child::lehre/child::comment()`
- `processing-instruction(ziel?)`: alle PI-Knoten
z.B. `/child::lehre/child::processing-instruction()`
- `text()`: alle Textknoten
- `node()`: alle Knoten

Abkürzungen

- Weglassen der Achse entspricht der child-Achse
z.B. `zeit` entspricht `child::zeit`
- `.` = context node: entspricht `self::node()`
- `..` = parent des context node: entspricht `parent::node()`
- `//` = `descendant-or-self::node()` /
- `@` = Abkürzung für attribute-Achse
z.B. `@*` entspricht `attribute::*`

Beispiele

<code>./titel</code>	alle titel-Elemente im momentanen Kontext (äquivalent zu <code>titel</code> bzw. <code>child::titel</code>)
<code>/titel</code>	selektiert titel, falls es das Dokument- Element ist.
<code>./titel</code>	starte vom aktuellen context-node und selektiere alle titel Elemente, die tiefer liegen (also relativ): eigentlich <code>descendant-or-self::node()/titel</code> (vgl. <code>descendant::titel</code> !)
<code>//titel</code>	starte von Wurzel und selektiere alle titel Elemente, die tiefer liegen (also absolut)
<code>//zeit/../*</code>	liefert Element plus seine Geschwister
<code>/lehre/*/schlagwort</code>	ist äquivalent zu <code>/child::lehre/child::*/child::schlagwort</code>

Filter (= "predicates")

- Angabe einer beliebigen XPath Expression in eckigen Klammern
z.B. `//veranstaltung/schlagwort[position() >= 2]`
- Die Filter-Bedingung `[x]` muss ein boolean Resultat liefern.
Andernfalls wird der Typ auf folgende Weise konvertiert:
 - node-set, string: `[x]` entspricht `[boolean(x)]`
z.B.: `[./datum]` entspricht `[boolean(./datum)]`
 - number: `[x]` entspricht `[position() = x]`
z.B.: `[3]` entspricht `[position() = 3]`

Beispiele

veranstaltung[vorbesprechung]

selektiert alle Elemente die ein Vorbesprechungselement enthalten
Bemerkung: Typumwandlung des Node-sets von "vorbesprechung"
in boolean erforderlich.

vorbesprechung[datum="Mi 7.3."]

selektiert alle Vorbesprechungen, die ein datum-Subelement mit
diesem Inhalt haben.

zeit[@cum_tempore="yes"]

selektiert alle Zeit-Elemente, die über das Attribut cum_tempore
verfügen mit dem Wert "yes".

vorbesprechung[not (zeit/@cum_tempore="yes")]

selektiert alle Vorbesprechungs-Elemente, die kein Subelement zeit mit
Attribut @cum_tempore="yes" haben.

Beispiele

`vorbesprechung[datum and ort]`

selektiert alle Vorbesprechungs-Elemente, die mindestens ein Datum sowie einen Ort als Kinder haben.

`schlagwort[1] bzw. schlagwort[position()=1]`

findet das erste Schlagwort

`schlagwort[last()] bzw. schlagwort[position()=last()]`

findet das letzte Schlagwort

`schlagwort[2]/following::*`

findet alle Elemente, die im XML-Dokument nach dem zweiten schlagwort-Subelement vorkommen (aber nicht als Nachfahre von schlagwort).

Filterlisten

- Ein location step kann 0 oder beliebig viele "predicates" haben.
- Wenn `[b]` weder `position()` noch `last()` enthält, dann sind `[a and b]` und `[a][b]` identisch. Aber im allgemeinen sind die beiden Ausdrücke verschieden, da nach der Auswertung eines predicates der context neu ermittelt wird.
- Beispiel:
 - `schlagwort[.="DTD"][2]`
wählt unter den Schlagwörtern mit Wert DTD das zweite aus
=> selektiert in diesem Fall die leere Knotenmenge
 - `schlagwort[2][.="DTD"]`
wählt das zweite Schlagwort aus, vorausgesetzt dass der Wert DTD ist.
=> selektiert in diesem Fall das zweite Schlagwort

Auswertung von Location Steps

Auswertung eines steps **achse::node-test [x]**

- Zuerst wird das node-set aufgrund von **achse::node-test** berechnet. => Ergebnis $S = \{s_1, \dots, s_k\}$
- Nun wird für jeden Kandidaten s_i das predicate x bezüglich dem folgenden Context ausgewertet:
 - context-node = s_i
 - context-position = i und
 - context-size = k
- Im Endergebnis liegen jene Knoten s_i , für die x den Wert true liefert.

7.4. Operatoren

- Überblick
- Vergleichsoperatoren mit Knotenmengen

Überblick

- Verknüpfung von node-sets:
 - | bildet die Vereinigung von 2 node-sets
 - z.B. `child::schlagwort | descendant::datum`
- Boole'sche Operatoren:
 - Operatoren `and` und `or`
 - Außerdem gibt es eine built-in Funktion `not ()`
z.B. `//schlagwort[not(position())=2]`
 - Operanden werden implizit in boolean konvertiert
z.B. `//*[descendant::titel and descendant::datum]`
- Vergleichsoperatoren: `<`, `>`, `<=`, `>=`, `=`, `!=`
- Arithmetische Operatoren: `+`, `-`, `*`, `mod`, `div`
(Bemerkung: `div` ist Dezimal-Division, weil `/` eine andere Bedeutung hat.)

Vergleichsoperationen mit Node-Sets

- Node-sets x in Ausdrücken der Form $x \text{ RelOp } y$ mit RelOp in $\{<, <=, =, !=, >, >=\}$ haben "exists"-Semantik
- z.B.: `./schlagwort = "XML"` liefert true, wenn es ein schlagwort-Element mit dem Textinhalt "XML" als Nachfahren des context-node gibt.
- Wenn sowohl x als auch y ein node-set liefert, dann wird "exists" auf beide node-sets angewendet.
- z.B.: `./veranstaltung/nummer = ./termin/lvanummer` liefert true, wenn es 2 Knoten a und b gibt, sodass gilt:
 - a ist vom context-node aus mittels `./veranstaltung/nummer` und b ist vom context-node aus mittels `./termin/lvanummer` erreichbar.
 - `string(a) = string(b)`

7.5. Vordefinierte Funktionen

- Überblick
- Node-set Funktionen
- String Funktionen
- Boolean Funktionen
- Number Funktionen

Überblick

- Klassifizierung (laut XPath Recommendation):
 - Node-set Funktionen
 - String Funktionen
 - Boolean Funktionen
 - Number Funktionen
- Beschreibung:
result-type **function-name** (*arguments*)

Node-set Funktionen (1)

- *number* **position**()
Knotenposition in einer Knotenmenge (d.h.: context-position)
- *number* **last**()
Gesamtzahl der zuletzt selektierten Knoten (d.h.: context-size)
- *string* **local-name**(*node-set*?)
Lokaler Name des ersten Knoten (in document order) im node-set bzw. des context-node (falls node-set fehlt).
- *string* **namespace-uri**(*node-set*?)
Namespace URI des ersten Knoten (in document order) im node-set bzw. des context-node (falls node-set fehlt).
- *string* **name**(*node-set*?)
Qualifizierter Name (d.h.: NS-Präfix + local-name) des ersten Knoten (in document order) im node-set bzw. des context-node.
- *number* **count**(*node-set*)
Anzahl der Knoten im node-set

Node-set Funktionen (2)

■ `node-set id(object?)`

Fall 1: Object = **string**:

- Zerlege string in whitespace-separated Liste von Tokens
- Selektiere alle Knoten, deren ID-Attribut (laut ID-Definition in der DTD) den Wert eines solchen Token hat.

Fall 2: Object = **node-set**:

- Betrachte den string-Wert von jedem Knoten im node-set
- Zerlege jeden dieser Strings in Liste von Tokens (wie Fall 1)
- Selektiere alle Knoten, deren ID-Attribut (laut ID-Definition in der DTD) den Wert eines solchen Token hat.

Beispiel: `id("XY07 YZ21")` wählt die Elemente, die ein ID-Attribut mit dem Wert "XY07" oder "YZ21" haben.

String Funktionen (1)

- `string string(object?)`
Typkonvertierung in einen String. Falls Argument fehlt, wird der context-node in einen String konvertiert.
- `string concat(string, string, string*)`
Konkatenation von 2 oder mehr Strings
- `boolean starts-with(string, string)`
liefert true, wenn das erste Argument mit dem zweiten beginnt
- `boolean contains(string, string)`
liefert true, wenn das erste Argument das zweite enthält
- `string substring(string, number, number?)`
liefert substring des ersten Arguments;
zweites Argument = Startposition (Zählung beginnt bei 1);
drittes Argument = Länge.
z.B.: `substring("abcdef", 2, 3)` liefert "bcd"

String Funktionen (2)

- *string* **substring-before**(*string*, *string*)
liefert substring des ersten Arguments vor dem ersten Auftreten des zweiten Arguments (sonst den leeren String).
- *string* **substring-after**(*string*, *string*)
liefert substring des ersten Arguments nach dem ersten Auftreten des zweiten Arguments (sonst den leeren String).
- *number* **string-length** (*string*?)
liefert String-Länge des Arguments (bzw. des String-Wertes des context-node)
- *string* **normalize-space** (*string*?)
normalisiert Argument-String (bzw. des String-Wertes des context-node) bzgl. Whitespaces
- *string* **translate** (*string*, *string*, *string*)
Zeichen-weise Transformation des ersten Arguments, z.B.:
translate("---aaa---", "abc", "ABC") liefert "---AAA---"

Boolean Funktionen

- `boolean boolean(object)`
Typkonvertierung in einen boolean Wert.
- `boolean not(boolean)`
logische Negation.
- `boolean true()`
liefert den Wahrheitswert true
- `boolean false()`
liefert den Wahrheitswert false
- `boolean lang(string)`
liefert true, wenn die Sprache des context-node (laut xml:lang-Attribut) dieselbe Sprache oder eine Subsprache des Input-Strings ist.


Number Funktionen

- *number* **number**(*object*?)
Typkonvertierung in eine Zahl. Falls Argument fehlt, wird der context-node in eine Zahl konvertiert.
- *number* **sum**(node-set)
Konvertiert den String-Wert jedes Knoten im node-set in eine Zahl und bildet von diesen Zahlen die Summe.
- *number* **round**(number)
rundet zur nächstgelegenen ganzen Zahl
- *number* **ceiling**(number)
rundet nach oben
- *number* **floor**(number)
rundet nach unten

Tools (1)

XpathTester:

- basiert auf XPath Engine von
 - Xalan XSLT Processor (XPathTester Version 1.3) bzw.
 - Saxon XSLT Processor (XPathTester Version 1.4)
- Start von der Kommandozeile aus:
 - `java -jar xpathtester_1_3_xalan2.jar`
- Bemerkung:
 - XPathTester ist nur ein "Spielzeug", um XPath kennen zu lernen.
 - XPath wird hauptsächlich als Teil von XSLT verwendet.
- http://www.dbai.tuwien.ac.at/education/ssd/SS08/uebung/xpathtester_1_3_xalan2.jar



Tools (2)

xpath (linux commandline zB auf minteka)

- Aufruf: `xpath file "xpath-query"`
- Achtung! unterstützt keine NS.

XPath Explorer:

- <http://sourceforge.net/projects/xpe/>

XPathTester und Xpath Explorer haben Probleme bei NS, insb. bei Redefinitionen von Präfixes.