DBAI

181135 VU Semistrukturierte Daten 1

XPath
20.10.2005

Reinhard Pichler

XPath

- 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
- Nachteil: ist selbst nicht in XML Notation
- Ziel: Navigieren im Dokumentenbaum
  - in der Art wie Dateisystem
  - Das Abfrageergebnis ist meistens eine Knotenmenge
  - Selektion von Knoten nach Kriterien wie Elementnamen, Attributnamen, Typ, Inhalt, Wert, Beziehungen
  - Suchergebnis einschränken mittels Filtern möglich
  - weitere Datentypen: String, Number, Boolean
- Version 1.0 Recommendation, Version 2.0 Working Draft
  - XPath 2.0 insbesondere für XQuery

Inhalt

- Datenmodell (Dokumentenbaum)
- XPath Expressions
- Pfade (= location paths)
- location steps
- Operatoren
- Built-in Funktionen
- Tool: XPathTester

Datenmodell

- 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 Dokumentelements (für PIs und comments im Prolog, d.h.: vor dem Dokumentelement)
  - **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 (außerhalb einer DOCTYPE-Definition). Die xml-Deklaration gilt nicht als PI.
  - **Comment nodes**: für jeden Kommentar (außerhalb einer DOCTYPE-Definition)
  - **Text nodes**: Zeichendaten werden in möglichst große text nodes zusammengefasst (d.h.: Ein text node hat keine text nodes als Nachbarn).

Beispiel: XML Dokument

```
<?xml version="1.0" encoding="ISO-8859-1"?>
<!-- DBAI -->
<?xml-stylesheet type="text/css" href="lehre.css"?>
<lehre>
  <veranstaltung jahr="2003">
    <titel>Semistrukturierte Daten 1</titel>
    <schlagwort>XML</schlagwort>
    <schlagwort>SSD</schlagwort>
    <schlagwort>SGML</schlagwort>
    <vorbesprechung>
      <datum>Mo 28.4.</datum>
      <zeit sine_tempore="yes">9:00</zeit>
      <ort>Seminarraum 184/2</ort>
    </vorbesprechung>
  </veranstaltung>
</lehre>
```

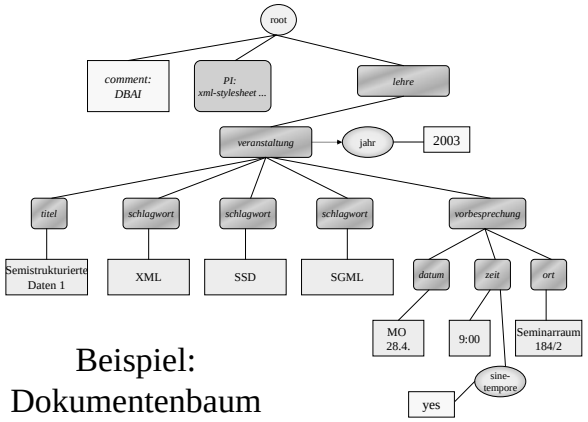

Beispiel: Dokumentenbaum

Document Order

- Alle Knoten im Baum sind geordnet.
- Die Ordnung der element nodes ist top-down, left-to-right (d.h.: Reihenfolge der Start-Tags ist entscheidend)
- NS-nodes kommen vor den attribute nodes.
- Attribute nodes kommen vor den (Element-)Kindknoten
- Reihenfolge innerhalb der NS-nodes sowie innerhalb der attribute nodes ist implementierungsabhängig.
- Wenn Resultat eines XPath-Ausdrucks eine Knotenmenge ist, dann sind diese Knoten geordnet:
  - Normalerweise in „document order“
  - Bei Navigation in umgekehrter Richtung: „inverse document order“

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

Expressions

- Expression = zentrales syntaktisches Konstrukt in XPath
- Auswertung einer XPath expression für einen 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.)
- 4 Datentypen als mögliches Resultat einer XPath Expression:
  - node-set
  - boolean
  - number
  - string

Typ-Konvertierungen

- Explizite vs. implizite 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!
- 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`**)
- Konvertierung number -> string/boolean
  - **`string(x)`** = Dezimaldarstellung von x bzw. **`"NaN", "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`)

Pfade

- Pfade (location paths) = wichtigste Form von XPath Expressions
- 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/@sine-tempore` bzw. `child::zeit/attribute::sine-tempore`
- „Unvollständiger“ Pfad:
  `.//zeit` bzw. `descendant::zeit`
  `/lehre/*/schlagwort` bzw. `/child::lehre/child::*/child::schlagwort`
  `//titel` bzw. `/descendant::titel`
- Verwendung von Filtern:
  `//zeit[@sine-tempore="yes"]` bzw.
  `/descendant::zeit[attribute::sine-tempore="yes"]`
  `schlagwort[2]` bzw. `child::schlagwort[position()=2]`
  `schlagwort[last()]` bzw. `child::schlagwort[position()=last()]`

Beispiel: Absolute Pfade

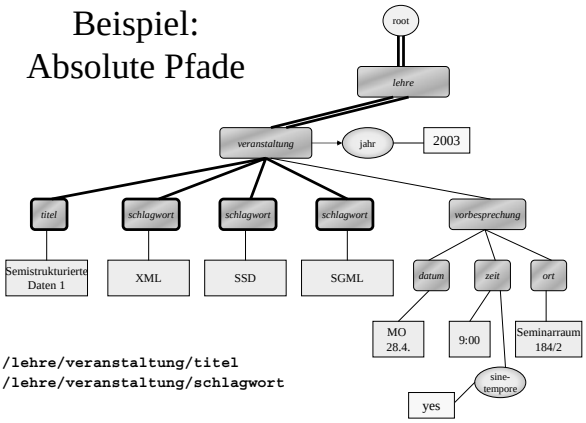

`/lehre/veranstaltung/titel`
`/lehre/veranstaltung/schlagwort`

Beispiel: Relative Pfade

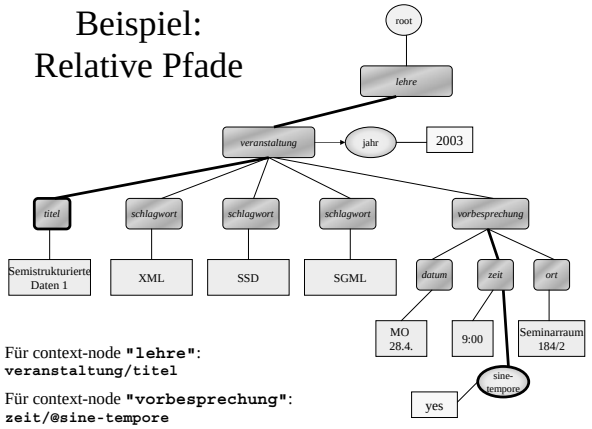

Für context-node **`"lehre"`**:
`veranstaltung/titel`

Für context-node **`"vorbesprechung"`**:
`zeit/@sine-tempore`

Beispiel: Unvollständige Pfade

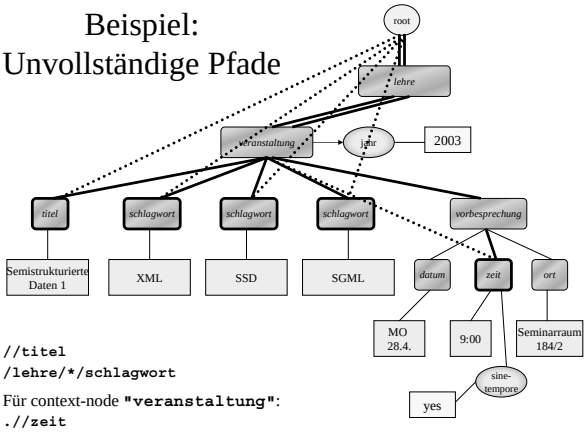

`//titel`
`/lehre/*/schlagwort`

Für context-node **`"veranstaltung"`**:
`.//zeit`

Beispiel: Verwendung von Filtern

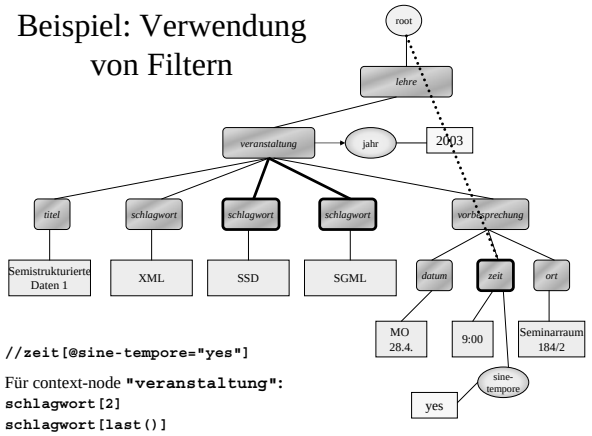

`//zeit[@sine-tempore="yes"]`

Für context-node **`"veranstaltung"`**:
`schlagwort[2]`
`schlagwort[last()]`

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 und Name der gewünschten Knoten
  - 0 oder mehr Filterbedingungen (= „predicates“)
- Beispiele:
  - `child::schlagwort[2]`
  - `parent::*`
  - `preceding-sibling::text()[last()]`
  - `following::node()[@sine-tempore="yes"][1]`
  - `attribute::jahr`
  - `descendant::processing-instruction()`

XPath Achsen

- child: Kindelemente
- ancestor: Vorfahren
- self: der Knoten selbst
- ancestor-or-self: alle Vorfahren und selbst
- descendant: alle Nachfahren
- descendant-or-self: alle Nachfahren und selbst
- parent: Elternelement
- following: alle in document order nachfolgenden Knoten außer Nachfahren, Attribut-Knoten und NS-Knoten
- following-sibling: alle nachfolgenden Geschwisterknoten
- preceding: alle in document order vorangehenden Knoten außer Vorfahren, Attribut-Knoten und NS-Knoten
- preceding-sibling: alle vorangehenden Geschwisterknoten
- attribute: alle Attribute eines Elements
- namespace: alle Namespaces eines Elements

Node Tests

- Üblicherweise: Angabe eines Namen
  - z.B. "/child::lehre/descendant::zeit"
- * steht für beliebigen Namen
  - child::* gibt alle Elementknoten zurück
  - attribute::* gibt alle Attributknoten zurück
- comment(): alle Kommentar-Knoten
  - z.B. "/child::lehre/child::comment()" bzw. "/lehre/comment()"
- processing-instruction(): alle PI-Knoten
  - z.B. "/child::lehre/child::processing-instruction()" bzw. "/lehre/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::*`**
- `//` = descendants des context node, d.h.: **`descendant::*`**
- `@` = Abkürzung für attribute-Achse
  - z.B. `@*` entspricht **`attribute::*`**
- Beispiele:

`./titel`	alle titel-Elemente im momentanen Kontext (in Verwendung äquivalent zu **`titel`**)
`/titel`	selektiert Titel wenn Top-Level Element
`.//titel`	starte vom aktuellen context-node und selektiere alle Titel Elemente, die tiefer liegen (also relativ)
`//titel`	starte von Wurzel und selektiere alle Titel Elemente, die tiefer liegen (also absolut)
`/lehre/veranstaltung`	absoluter Pfad zu Veranstaltungen
`//zeit/../*`	liefert Element plus seine Geschwister

Filter (= „predicate“)

- Angabe einer beliebigen XPath Expression in eckigen Klammern
  - z.B. **`//schlagwort[position() >= 2]`**
- Die predicate expression [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]`**
- Die Auswertung eines steps **`achse::node-test[x]`**
  - Zuerst wird das node-set aufgrund von **`achse::node-test`** berechnet. => Ergebnis S = $\{s_1, ..., s_k\}$
  - Nun wird für jeden Kandidaten s_i das predicate x ausgewertet bzgl. 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.

XPath Filter Beispiele

`veranstaltung[vorbesprechung]`
selektiert alle Elemente die ein Vorbesprechungselement enthalten
Bemerkung: Typumwandlung des Node-sets von „vorbesprechung“ in boolean erforderlich.

`vorbesprechung[datum="MO 28.4."]`
selektiert alle Vorbesprechungen, die ein datum-Subelement mit diesem Inhalt haben.

`zeit[@sine-tempore="yes"]`
selektiert alle Zeit-Elemente, die über das Attribut sine-tempore verfügen mit dem Wert "yes".

`vorbesprechung[not(zeit/@sine-tempore="yes")]`
selektiert alle Vorbesprechungs-Elemente, die kein Subelement **`zeit`** mit Attribut **`@sine-tempore="yes"`** haben.

`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 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[.="SSD"][2]`**
    wählt unter den Schlagwörtern mit Wert SSD das zweite aus
    => selektiert in diesem Fall die leere Knotenmenge
  - **`schlagwort[2][.="SSD"]`**
    wählt das zweite Schlagwort aus, vorausgesetzt dass der Wert SSD ist.
    => selektiert in diesem Fall das zweite Schlagwort

Operatoren

- 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 built-in Funktion **`not()`**
  - z.B. **`//schlagwort[not(position()=2)]`**
  - Operanden werden implizit in boolean konvertiert
  - z.B. **`//*[descendant::titel`** `and` **`descendant::datum]`**
    entspricht **`//*[boolean(descendant::titel) and boolean(descendant::datum)]`**
- Vergleichsoperatoren: **`<, >, <=, >=, =, !=`**
- Arithmetische Operatoren: **`+, -, *, mod, div`**
  (Bemerkung: **`div`** ist Dezimal-Division, „/“ hat eine andere Bedeutung)

Vergleichsoperationen mit Node-Sets

- Node-sets x in Ausdrücken der Form **`x RelOp y`** mit `RelOp` in {<, <=, =, !=, >, >=} haben eine „exists“-Semantik
- z.B.: **`.//schlagwort = "SSD"`** liefert true, wenn es einen Nachfahren des context-node gibt, der den Wert **`"SSD"`** hat.
- 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 conext-node aus mittels **`./veranstaltung/nummer`** und b ist vom conext-node aus mittels **`.//termin/lvanummer`** erreichbar.
  - string(a) = string(b)

Built-in Funktionen

- Built-in Funktionen von XPath (= „Core Library Functions“)
- Klassifizierung:
  - Node-set functions
  - String functions
  - Boolean functions
  - Number functions
- Beschreibung:
  result-type **function-name** (*arguments*)

Node-set Functions

- *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

id-Funktion

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 Functions

- *string* **string**(*object?*)
  Typkonvertierung in einen String. Falls Argument fehlt, wird der context-node in einen String konvertiert.
- *string* **concat**(*string,string,string**)
  Konkatenation der Argumente
- *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"**
  substring("abcdef",2) liefert **"bcdef"**

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

Boolean Functions

- *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 Functions

- *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

XPath Schwächen

- keine regulären Pfadausdrücke
  - wie **(part*)/name**
- keine regulären Ausdrücke für Textelemente
  - Diskussionen in XPath 2.0 und XSLT 2.0
- keine beliebige Kombinierbarkeit von Mengenoperationen und Navigation
  - z.B. **(child::a|preceding-sibling::b)/child::c** nicht erlaubt
- Fehlen nützlicher Funktionen (z.B.: min/max)
- eigenartige Typumwandlungen
  - z.B. **node-set+zahl** wird zu **number*(node-set[1])+zahl***
- exists-Semantik bei Vergleichsoperationen mit node-sets
  - z.B. **not(node-set = a)** ist verschieden von **node-set != a**

- http://www.fivesight.com/downloads/xpathtester.asp
- Graphische Testumgebung, um XPath Expressions auszuwerten
- 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

Beispiel 1

Übungsbeispiel A

Erstellen Sie XPath Queries, um aus der Datei „Buchbestand.xml“ folgende Informationen zu extrahieren:

- Alle Autoren von allen Büchern
- Gesamtwert der vorhandenen Bücher
- Titel der Bücher, die den Substring „Harry Potter“ enthalten
- Preis des teuersten Buchs
- Die erste Hälfte aller Bücher in der Liste
  bei ungerader Zahl: mittleres Buch zur ersten Hälfte dazurechnen
- Die restlichen Bücher
- Titel aller Bücher von Kafka (Vorsicht beim Vornamen)

Beispiel B

Erstellen Sie folgende XPath Queries für die Datei „Sammlung.xml“. Schreiben Sie die ersten 3 Queries derart, dass Sie sich nicht auf ein bestimmtes NS-Präfix im XML-Dokument verlassen, d.h.: verwenden Sie die Funktionen namespace-uri() und local-name()!

- Die Titel aller CDs
- Gesamtwert der vorhandenen Bücher
- Titel aller CDs, die von Mozart komponiert sind
- Titel aller CDs, die nur von Jagger komponiert sind
- Gesamtzahl der CDs
- Titel aller CDs mit mindestens 2 Komponisten