



Textnavigation mit XPath

Ulrike Henny
&
Patrick Sahle


Fahrplan

- XPath: wieso – weshalb – warum?
- XPath im Editor
- XML als Baum
- XPath: Grundkonzepte
- XPath: der erste Baukasten
- XPath: gemeinsame Übungen
- XPath: der weitere Baukasten
- XPath: Einzelübungen



Xpath: wieso – weshalb – warum?


- Daten und Datenstrukturen verstehen und analysieren
- Daten mit anderen Technologien auswählen und verarbeiten
- Auswählen von Knoten, Knoten-Mengen, Attributwerten, Textinhalten, Textteilen
- Vergleichen, Zählen, Berechnen, Umwandeln etc.



The screenshot shows an IDE window titled "Postkarte_unsere_Beispiellösung.xml". The menu bar includes "Datei", "Bearbeiten", "Suchen", "Projekt", "Optionen", "Werkzeuge", "Dokument", and "Fen:". The toolbar contains various icons for file operations and editing. The XPath 2.0 expression `Postkarte/dokumentinhalt/rückseite/adresse/zeile/anrede` is entered in the XPath field and is circled in red. Below the XPath field, the XML document is displayed with line numbers 22 to 28. The element `<anrede>Fräulein</anrede>` on line 24 is circled in red. At the bottom, the "Resultate" pane shows a table with one row: "Fräulein" under "Beschreibung - 1 Element" and `/Postkarte[1]/dokumentinh` under "XPath Location". The status bar at the bottom indicates "XPath -- erfolgreich" and "U+003C 1 : 1".

Baum
komische Metaphern

Wurzel
<root>



viele "Knoten"
manche vielleicht mit attribut = "wert"

<Postkarte>

<bibliographischeAngaben> ... </bibliographischeAngaben>

<dokumentinhalt>

<vorderseite>

<titel><ort>Dortmund</ort>. Hauptbahnhof.</titel>

</vorderseite>

<rückseite>

<adresse>

<zeile><anrede>Fräulein</anrede></zeile>

<zeile><empfänger>

<name geschlecht="weiblich">

<vorname>Margarete</vorname>

<nachname>Grogorenz</nachname></name></empfänger>

</zeile>

<zeile><ort>Berlin</ort> S.O. 36</zeile>

<zeile>Wienerstr. 27.</zeile>

</adresse>

<haupttext>

<zeile><anrede>Mein liebes <adressat geschlecht="weiblich"><name><vorname
typ="koseform" norm="Margarete">Gretchen</vorname></name></adressat>
!</anrede> </zeile>

<zeile>Soeben bin ich "<ironisch>glücklich</ironisch>" in <ort>Dortmund</ort></zeile>

<zeile>angekommen und denke gleich an Dich!!</zeile>

... als Baum?



XPath Grundkonzepte

- XPath erlaubt die Konstruktion von Pfadausdrücken
- Pfade bestehen aus Ketten von Pfadschritten
- Es gibt „Achsen“, über die man sich im Baum bewegt
- Der letzte bzw. äußerste Schritt bestimmt, was ein XPath-Ausdruck zurückgibt
 - Pfade werden von vorne nach hinten abgearbeitet
 - Klammern von inner nach außen aufgelöst



XPath Grundkonzepte, Pfadschritte

- Schritt/Schritt/Schritt
- Postkarte/dokumentinhalt/rückseite/adresse/zeile/anrede



XPath Grundkonzepte, Achsen

- horizontale und vertikale Achsen
- Achse::Knotentest
- * für beliebige Elemente

parent | ancestor | ancestor-or-self

child | descendant | descendant-or-self

preceding | preceding-or-self | preceding-sibling

following | following-or-self | following-sibling

attribute

self

child::Postkarte/child::dokumentinhalt/child::rückseite/
child::adresse/child::zeile/child::anrede



XPath Grundkonzepte, Achsen

abgekürzte Syntax

- child::Elementname = /Elementname
- parent::* = /..
- descendant-or-self::Elementname = //Elementname
- attribute::Attributname = /@Attributname
- self = .



XPath Grundkonzepte, Rückgabe

ein XPath-Ausdruck kann verschiedene Dinge zurückgeben ...

- Knoten
- Knoten-Set
- Sequenz
- Wahrheitswert
- Text, String, Name (z.B. von Elementen)
- Zahl



XPath: der erste Baukasten

- Verkettung von Schritten
- Achsen
- Zusammengefasste Ausdrücke: (...)
- Bedingungen
 - Knotentest[Bedingung]
 - //zeile[anrede]
 - //zeile[not(@typ='vordruck')]
- Operatoren
 - and or |
 - = != < >
 - + - * div %
- Funktionen



XPath: Funktionen

- Funktionen können mit ihrem Namen aufgerufen werden.
- Sie bestehen aus Ihrem Namen und runden Klammern: *funktion()*
- Manche Funktionen erwarten in der Klammer die Übergabe von "etwas"
 - das kann ein Knoten sein, ein Knotensatz, ein String, eine Zahl ...
- Die Übergaben sind durch Kommata getrennt
 - *funktion(parameter,parameter)*
- Funktionen geben dann etwas zurück
 - das kann ein Wahrheitswert sein, eine Zahl, ein String, eine Sequenz ...

XPath: eine Funktion

`contains(string,string)`

- auf Deutsch: Enthält der erste String den zweiten? Ja oder nein?
- `contains('Schnecke','ecke')` → Rückgabe: true
- `contains(//stempel[2]/datum,'1920')` → Rückgabe: false
- `//stempel[2]/datum/contains(.,'1920')` → Rückgabe: false
- `//stempel[contains(.,'20')]` → das Element "stempel" wird zurückgegeben, das den String '20' enthält
- `//*[contains(stempel,'2009')]` → das Element wird zurückgegeben, das ein Element stempel enthält, das '20' enthält
- `//haupttext/zeile[contains(anrede,'lieb')]/adressat`
 - Beachten: Strings müssen in Hochkomma stehen, Elemente nicht!



XPath: der erste Baukasten, Funktionen

- `count()`
 - zählt etwas, erwartet eine Sequenz, z.B. Ein Knoten-Set
 - `count(XPath)`
- `position()`
 - gibt die Position eines Knotens an
- `contains()`
 - prüft, ob ein Element oder String einen anderen String enthält
 - `contains(string,string)`
- `string-length()`
 - zählt die Länge eines Strings – `string-length(string)`
- `starts-with()`
 - prüft, ob ein String mit einem anderen String beginnt
 - `starts-with(string,string)`
- `not()`
 - dreht einen Wahrheitswert um



XPath: ~~erste~~ zweite Beispiele

- `count(//ort)`
 - Zähle die Menge der Elemente *Ort* in beliebiger Tiefe des Baumes
- `count(//adresse/zeile)`
 - Wieviele Zeilen hat die Adresse?
- `//adresse/zeile[anrede]/position()`
 - Die wievielte Zeile der Adresse enthält die Anrede?
- `//haupttext[contains(zeile,'herzlich')]`
 - Gib mir den Haupttext, der eine Zeile enthält, die ‚herzlich‘ enthält.
 - Rückgabe = Knoten! Vgl. dagegen `contains(//haupttextzeile,'herzlich')` = Boolean
- `string-length(//empfänger/name/nachname)`
 - Wie lang ist der Nachname des Empfängers?
- `//ort[starts-with(.,'D')]`
 - Gib mir alle Orte, die mit D anfangen
- `//name[not(@geschlecht)]`
 - Bei welchen Namen fehlt das Attribut *geschlecht*?



XPath: gemeinsame Übungen (Postkarte)

- Gib mir alle Vornamen
 - Lösung: `//vorname`
- Wieviele Zeilen hat der Haupttext
 - Lösung: `count(//haupttext/zeile)`
- Was steht in der dritten Adresszeile?
 - Lösung: `//adresse/zeile[position()=3]`
- Gib mir die Ortsnamen, die mehr als 6 Zeichen lang sind
 - Lösung: `//ort[string-length()>6]`

XPath: gemeinsame Übungen (Weber)

- Wieviele Briefe enthält die Datei?
 - `count(//TEI)`
- Gib mir die Textanfänge, die ‚Du‘, ‚Ihr‘ oder ‚Sie‘ enthalten (Textanfänge stehen im Element *incipit*)
 - `//incipit[contains(.,'Du') or contains(.,'Ihr') or contains(.,'Sie')]`
- Wieviele verschiedene Bearbeiter gibt es? (Bearbeiter werden im Element *change* im Attribut *who* genannt)
 - `count(distinct-values(//change/@who))`
- Welche Änderungen wurden im Jahr 2012 gemacht?
 - `//change(starts-with(@when,'2012'))`
- Wieviele Änderungen sind für jeden Brief im Durchschnitt festgehalten? (Änderungen stehen in *revisionDesc/change*)
 - `count(//revisionDesc/change) div count(//TEI)`

XPath: der zweite Baukasten, Funktionen

- substring(string,number,number?)
 - Gib mir von *string* ab Zeichen *number* so viele Zeichen, wie im zweiten *number* angegeben (sonst bis zum Ende)
- substring-before(string,string), substring-after(string,string)
 - Gib mir eine Teilzeichenkette vor oder hinter einer bestimmten Zeichenkette
- translate(string,string,string)
- matches(string,pattern)
- replace(string,pattern,pattern)
- distinct-values(*sequenz*)
 - ... Verschiedene Werte, jeweils nur einmal
- name()
- max() – min() – sum() – avg()

XPath: Einzelübungen (Weber-Briefe)

- In welchen Repositorien liegen die Briefe eigentlich?
(schauen Sie sich mal msIdentifier an ...)
- Welche verschiedenen Arten von Anmerkungen gibt es?
(Element *node* mit Attribut *type*)
- Geben Sie in den Brieff-texten (und nur da) erwähnte Orte aus,
die mit B anfangen
- Extrahieren Sie die Kurztitel der Werke, in denen Briefe bereits
gedruckt vorliegen
(schauen Sie sich additional/listBibl/bibl an; Erstdrucke sind mit
dem Wert *firstPrint* im Attribut *n* gekennzeichnet; der Haupttitel
ist der Teil vor dem Komma)
- Sie brauchen: `substring-before()`, `starts-with()`, `distinct-values()`



XPath: Weiterführende Hinweise

- XPath bei WP: <http://de.wikipedia.org/wiki/XPath>
- Ein Tutorial: <http://www.w3schools.com/Xpath/>
- Die Heimat von XPath: <http://www.w3.org/TR/xpath>