XML als Datenstruktur

XPath

Wuppertal, 11.2.2020

i|d|e
Leopoldina
Nationale Akademie
der Wissenschaften
berlin-brandenburgische
AKADEMIE DER WISSENSCHAFTEN
BERGISCHE
UNIVERSITÄT
WUPPERTAL

Wer hat Spaß an purer Logik?

Übersicht

- Wozu XPath?
- XPath als Standard
- Bäume, Hierarchien, Schachteln
- Konzepte und Grundbausteine
- Üben, Üben, Üben

Was ist XPath?

- "XPath is a language for addressing parts of an XML document” (XPath Specifications)
- XPath dient der Navigation in XML-Dokumenten und der Erzeugung von “Rückgaben”

- XPath wird vor allem in anderen X-Technologien verwandt: XSLT, XQuery

Was ist XPath?

- XPath ist ein W3C-Standard
- XPath 1.0 – 1999
- XPath 2.0 – 2010
- XPath 3.1 – 2017
- Unterstützung durch andere Technologien?
- Was davon brauchen Sie?

Warum brauche ich XPath?

- XPath wird vor allem in anderen X-Technologien verwandt: XSLT, Xquery
- Selbst wenn Sie diese Technologien nicht selbst einsetzen, wollen Sie Sich in Daten zurechtfinden, Dinge finden, Sachen prüfen, Kennzahlen ermitteln etc. XPath verschafft Ihnen Durchblick durch die Daten

Wo findet man XPath?

- Einfacher Einstieg: https://www.w3schools.com/xml/xpath_intro.asp
  - dort auch eine einfache Referenz
- Einfache Referenz: https://www.w3schools.com/xml/xsl_functions.asp (nur bis 2.0!)
- Vollständige Referenz: https://maxtoroq.github.io/xpath-ref/

Einfacher Einstieg

https://edition.onb.ac.at/okopenko/context:okopenko/methods/sdef:Context/get

Einfacher Einstieg

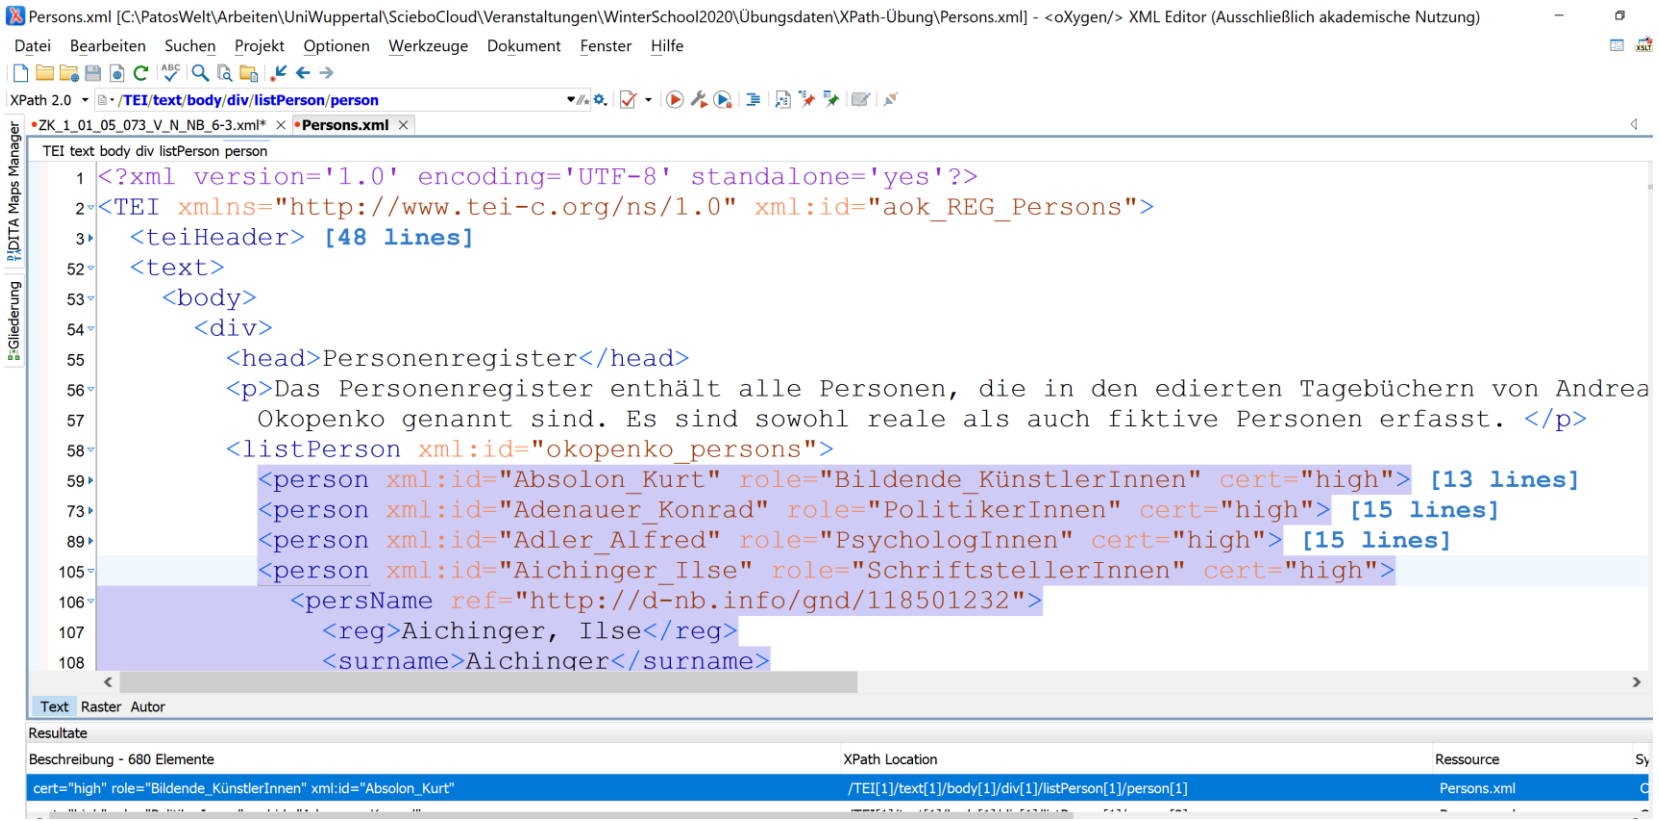

Schachteln, Hierarchien, Bäume

Sie haben es schon gelernt:

- Text ist sequentiell
- Tags + Inhalt = Elemente
- Elemente in Elementen = Verschachtelung
- Ein äußerstes Element = Eine Hierarchie!
- Ein „Baum“?

XML als Baum

Grafik von PixelKit, http://www.pixelkit.com, Lizenz: cc BY 3.0

XML als Baum

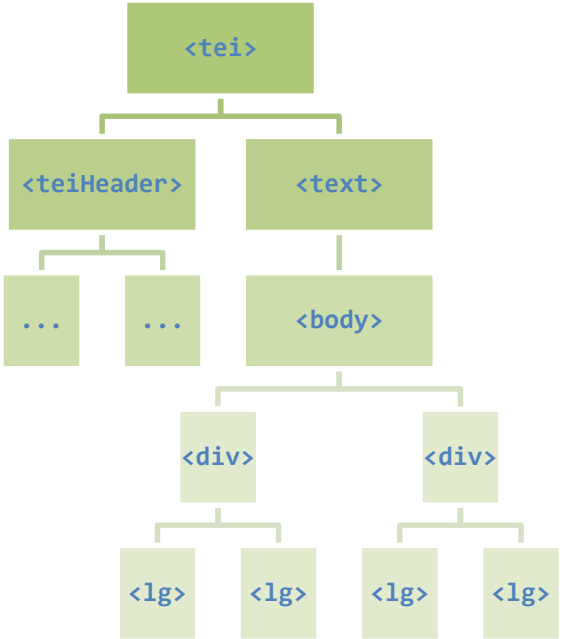

XML als Baum

```
<TEI xmlns="http://www.tei-c.org/ns/1.0">
 <teiHeader>...</teiHeader>
 <text>
   <body>
     <div type="sonnet">
       <head>Sonnet 18</head>
       <lg type="quatrain">
         <l n="1">Shall I compare thee to a summer's day?</l>
         <l n="2">Thou art more lovely and more temperate:</l>
         ...
       </lg>
       ...
       <lg type = "couplet">
         <l n="13">So long as men can breathe or eyes can see,</l>
         <l n="14">So long lives this and this gives life to thee. </l>
       </lg>
     </div>
   </body>
 </text>
</TEI>
```

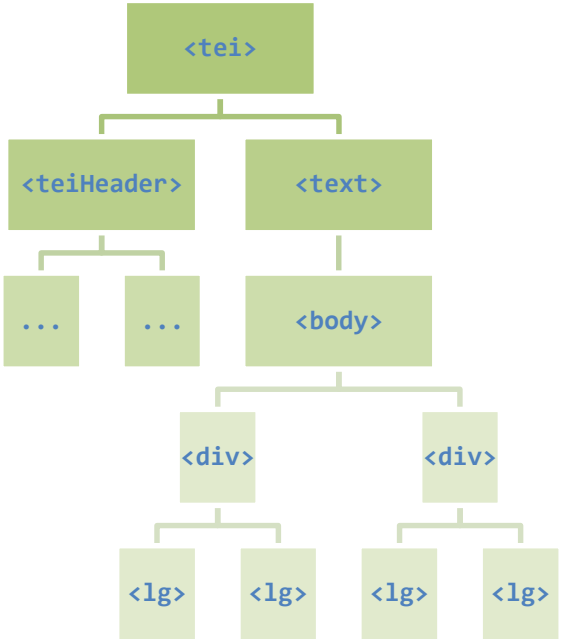

Wichtige Begriffe, kennen Sie schon

- Elemente / Attribute / Knoten
- Eltern – Kinder
- Vorfahren – Nachfahren
- Geschwister
- Wurzelknoten, Dokumentknoten

Knotentypen

- Dokumentknoten
- Wurzelknoten
- Elementknoten
- Attributknoten
- Textknoten

- Kommentarknoten

Bewegung im Baum

Lokalisierungsschritte

„gehe von hier nach da“

Knotentests

„bist Du der, den ich suche?“

Lokalisierungspfade

[Schritt]/[Schritt]/[Schritt]

/TEI/text/body/div

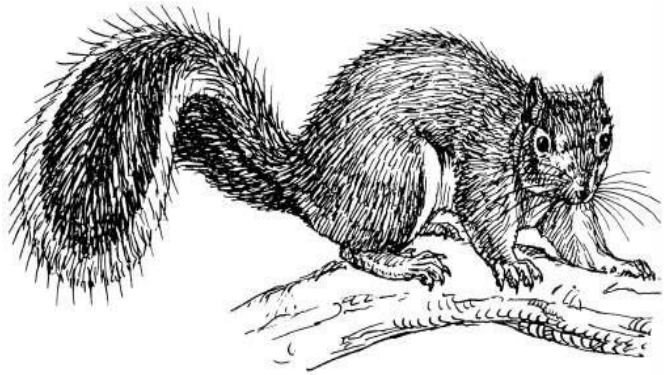

„Kontext“

absolute Pfade (vom Dokument ausgehend)

vs. relative Pfade (vom aktuellen Kontext ausgehend)

Bewegung im Baum: Achsen

Vertikale Achsen

self::

child:: descendant:: descendant-or-self::

parent:: ancestor:: ancestor-or-self::

Horizontale Achsen

following:: following-or-self:: following-sibling::

preceding:: preceding-or-self:: preceding-sibling::

Achsen

Selbst
`self`

Eltern / Kind
`parent` / `child`

Vorfahren / Nachfahren
`ancestor` / `descendant`

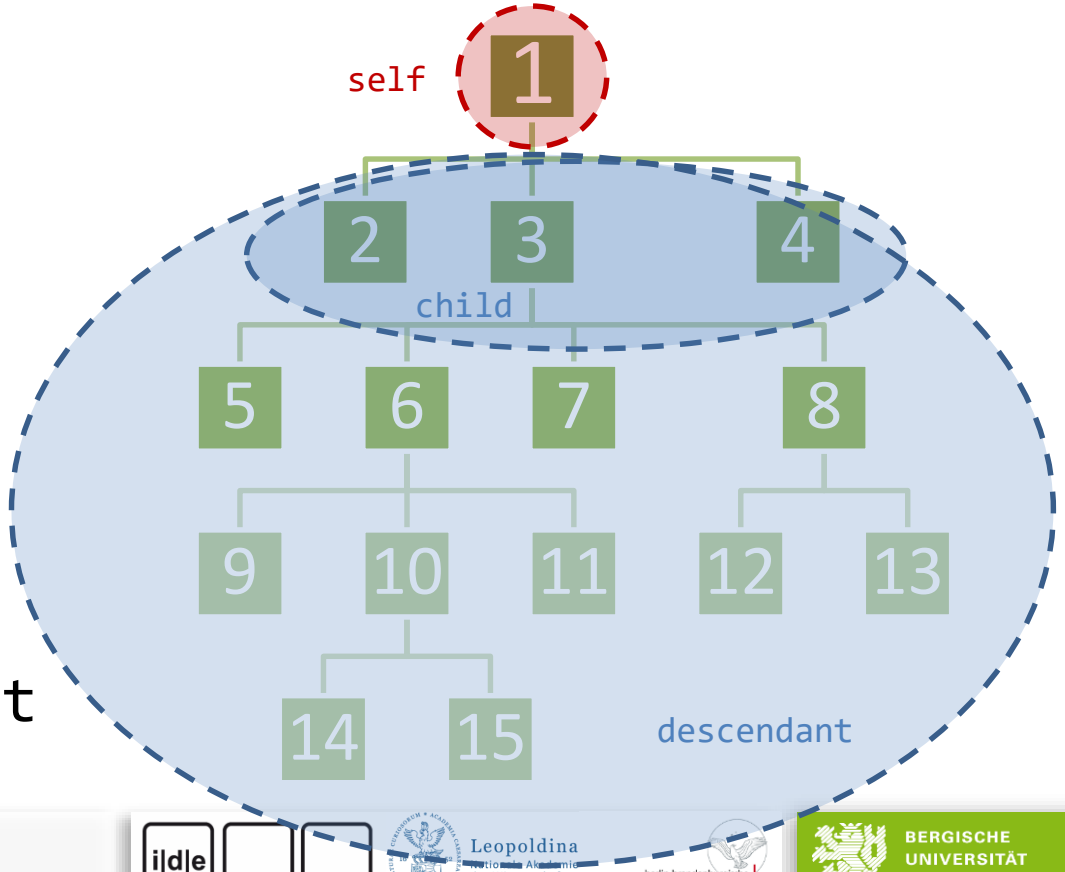

Achsen

- Selbst
  `self`
- Eltern / Kind
  `parent / child`
- Vorfahren / Nachfahren
  `ancestor`
  `descendant`
- Geschwister
  `preceding-sibling`
  `following-sibling`
- Sequenz statt Baum
  `preceding`
  `following`

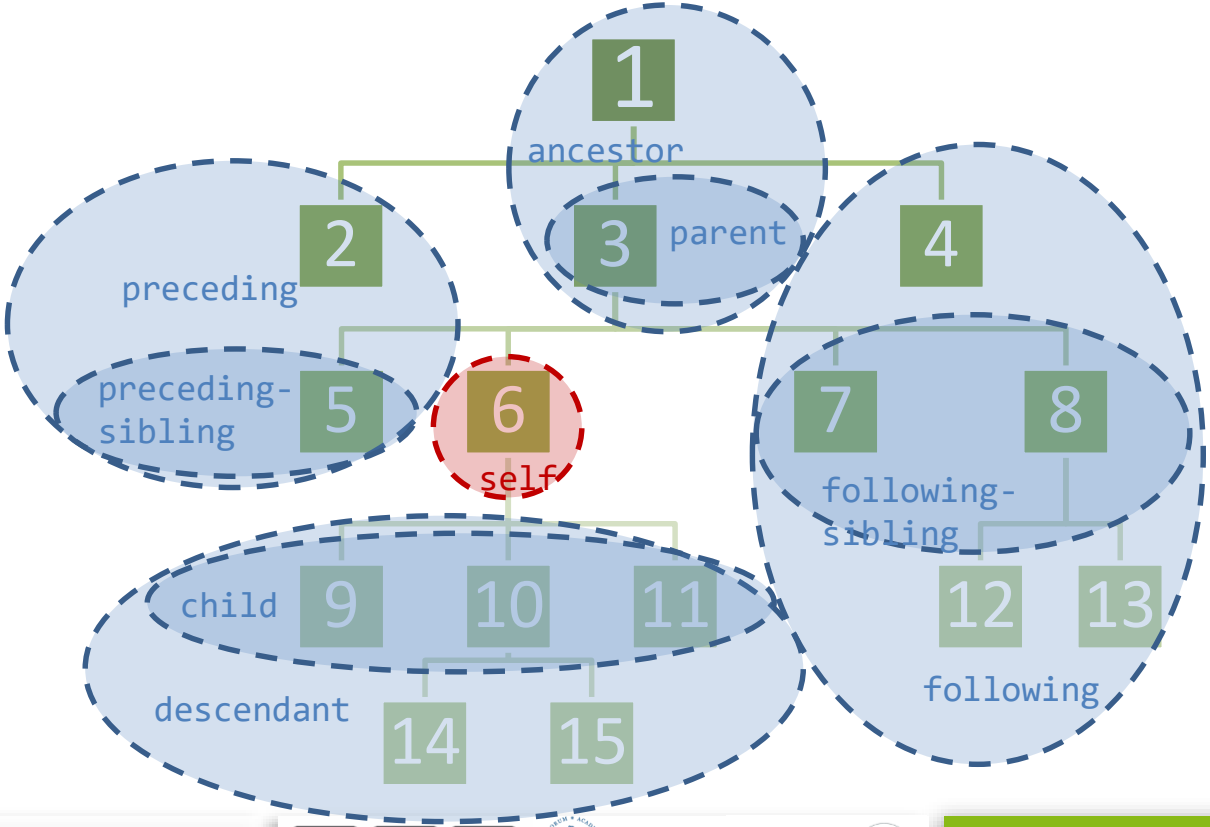

Achsen: abgekürzte Syntax

Wichtig!

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

Knotentest, beliebiger Elementname *

Beispiel: /TEI/text/body/div//person/@id

Bewegung im Baum

Lokalisierungsschritte

Prinzip: Achse + Knotentest + Prädikat

Syntax: achse::knotentest[Prädikat]

Beispiel

//body/descendant::persName[@key='A000584']

Der Grundbaukasten

- Verkettete Lokalisierungsschritte /…/…/
- Bedingungen, Prädikate […….]
- Klammern, Schachtelung (…(…))
- Operatoren
  and or | = != < > + - * div
- Funktionen
  Funktionsname(*Argument*, *Argument*, …)
- Syntax: 'Strings' in Anführungszeichen! Zahlen nicht!

Die Grund-Funktionsweise

- Der letzte bzw. äußerste Schritt bestimmt, was ein XPath-Ausdruck zurückgibt
- Pfade werden von vorne nach hinten abgearbeitet
- Klammern werden von innen nach außen aufgelöst

Beispiel

```
//body/descendant::persName[@key='A000584']
```

Rückgaben

XPath-Ausdrücke ergeben Rückgaben verschiedenen Typs:

- Knoten
- Knotenmengen
- Zahlen
- Strings
- Wahrheitswerte / Boolean
- Sequenzen

Funktionen

- Funktionen können mit ihrem Namen aufgerufen werden.
- Funktionen 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 …

Funktionen: Ein Beispiel

contains(string,string)

- prüft, ob ein Element oder String (das erste Argument) einen anderen String (das zweite Argument) enthält
- liefert einen Wahrheitswert zurück
- Auf Deutsch: Enthält der erste String den zweiten? Wahr oder falsch? True / False?

- contains('Schnecke','ecke')
  - Deutsch: Enthält der String Schnecke den String ecke?
  - Rückgabe: true

- //forename[contains(.,‘Patrick')]
  - Deutsch: Gibt es in meinem Baum ein Element forename, das den String Patrick enthält?
  - Rückgabe: Alle Elemente forename, für die das Prädikat "true" zurückgibt (Knotenset)

Funktionen

Zum Nachschlagen, zum Lernen, zur Inspiration

- Einfache Liste (bis XPath 2.0): https://www.w3schools.com/xml/xsl_functions.asp
- Lange Liste (mit XPath 3.1): https://www.altova.com/xpath-xquery-reference
- Die autoritative Referenz: https://www.w3.org/TR/xpath-functions-31/

Einige Funktionen I

count(nodeset)

- zählt etwas, erwartet eine Sequenz oder ein Knotenset
- liefert eine Zahl zurück

position()

- gibt die Position eines Knotens an, liefert eine Zahl zurück
- Abgekürzte Syntax: *//person[position()=11] == //person[11]*

string-length(string)

- zählt die Länge eines Strings (in Zeichen)
- liefert eine Zahl zurück

Einige Funktionen II

starts-with(string, string)

- prüft, ob ein String mit einem anderen String beginnt, liefert einen Wahrheitswert zurück
- Starts-with('Patrick‘,'P') → true

not(boolean)

- dreht einen Wahrheitswert um, liefert einen Wahrheitswert
- not(1 > 2) → true

max(sequence of numbers) ähnlich: min(), sum(), avg()

- ermittelt den maximalen Wert aus einer Reihe von Werte, liefert eine Zahl zurück
- max(//preis) → *eine Zahl*

distinct-values(sequence of strings)

- gibt eine Sequenz von (unterschiedlichen) Werten zurück
- distinct-values(//vorname) → eine Sequenz unterschiedlicher Strings

Einige Funktionen III

- substring(string,start,length)
- matches(string, pattern)
  → reguläre Ausdrücke!
- tokenize(string, pattern)
- name()
- not(argument)
- number(string), string(number)
- doc(URI)

Einige Funktionen IV

Nur der Vollständigkeit halber …

- concat(string, string, …)
- translate(string1,string2,string3)
  Converts string1 by replacing the characters in string2 with the characters in string3
- sum(arg,arg,…)
- last()
- current-date()
- (

Übungen

1. Legen Sie sich den Foliensatz bereit (zum nachschlagen)
2. persons.xml in oXygen öffnen (**https://tinyurl.com/wsde20**)
3. Ein Gefühl für die Daten entwickeln
4. Den XPath-Evaluator benutzen
5. Üben heißt Übersetzen (Deutsch-XPath / XPath-Deutsch)
   Man kann sich schrittweise an das Ergebnis herantasten!

Wie lautet die Überschrift des Dokuments?

/TEI/text/body/div/head

Gib mir alle Personen zurück

/TEI/text/body/div/listPerson/person

oder //person (?) oder //listPerson/person

Übungen

Welche ist die dritte Person in der Liste?

```
//listPerson/person[position()=3]  oder  //listPerson/person[3]
```

Gib mir alle Frauen zurück

```
//listPerson/person[sex/@value='F']
```

Gib mir alle Vornamen aller Frauen zurück

```
//listPerson/person[sex/@value='F']/persName/forename
```

Gib mir alle Frauen, die mit C anfangen

```
//listPerson/person[sex/@value='F']/persName/forename[starts-with(.,'C')]
```

Gib mir die unterschiedlichen Vornamen aller Frauen zurück

```
distinct-values(//listPerson/person[sex/@value='F']/persName/forename)
```

Übungen

Zu welchen Personen liegt kein GND-Link vor?

```
//listPerson/person[not (contains(persName/@ref,'gnd'))]
```

Wieviele sind das?

```
count(//listPerson/person[not (contains(persName/@ref,'gnd'))])
```

Wieviel Prozent der Liste haben keine GND-Information?

```
count(//listPerson/person[not (contains(persName/@ref,'gnd'))])
div count(//listPerson/person) * 100
```

Das früheste Geburtsjahr in der Liste?

```
min(//listPerson/person/birth/date/@when-iso)
```

Wie alt sind die Leute im Durchschnitt geworden?

Pseudocode! Sterbejahr minus Geburtsjahr. Das einer Funktion übergeben …

```
avg(//listPerson/person/((death/date/@when-iso) - (birth/date/@when-iso)))
```

Fun: „Hallo Welt“ in XPath ?

XPath ist ein großer Spaß !