XML-Manipulation in BaseX

Julia Beck | j.beck@ub.uni-frankfurt.de | @j4lib

11.12. und 18.12.2019

Praxislabor Digitale Geisteswissenschaften
Universitätsbibliothek Frankfurt am Main

Organisatorisches

Kursmaterial

Melden Sie sich für den moodle-Kurs Praxislabor Digitale Geisteswissenschaften an und schreiben Sie sich ein.

moodle

https://moodle.studiumdigitale.uni-frankfurt.de/moodle/course/view.php?id=511
[2]

Alle Materialien sind dort verlinkt:

- Diese Präsentation
- Links zu BaseX[1] und Spezifikationen (XQuery)
- Links zu den Beispieldaten, zu den Übungen und den Lösungen

Kursinhalt

Was ist das Lernziel?

- Was ist mit "meinen" XML-Daten möglich? (Was kann ich für Informationen aus ihnen ziehen? Wie kann ich sie bearbeiten/visualisieren/ändern?)
- Was ist eigentlich XQuery und wo ist der Unterschied zu anderen XML-Technologien?
- Welche Probleme kann ich mit XQuery oder XML-Datenbanken lösen?
- Diese Präsentation dient als Einblick in das Thema und als kleines Nachschlagewerk

Kursinhalt

Teil 1 (heute)

- Die XML Familie
- Die XML-Datenbank BaseX
- XQuery - Einführung
- XQuery - Sprachelemente
- XQuery - FLWOR
- XQuery - Konstruktion
- XQuery - Update

Teil 2 (nächste Woche)

- Übungen mit BaseX

Die XML Familie

Die XML Familie

Was ist was?

- `XML` = Extensible Markup Language

  Auszeichnungssprache zur Darstellung hierarchisch strukturierter Daten (menschen- und maschinenlesbar); andere XML-basierte Sprachen: TEI, SVG, GML, ...

XML (kurze Wiederholung)

Beispiel-XML

```
<collection>
  <book id="B1">
    <title>The Raven</title>
    <author>E.A. Poe</author>
  </book>
  <book id="B2">
    <title>The Empty House</title>
    <author>A.C. Doyle</author>
  </book>
</collection>
```

- Wurzelelement (<collection>)
- Elemente (<book>,<author>, <title>)
- Attribut (@id)
- Text ("The Raven", "E.A. Poe", ...)

Die XML Familie

Was ist was?

- `XML` = Extensible Markup Language

  Auszeichnungssprache zur Darstellung hierarchisch strukturierter Daten (menschen- und maschinenlesbar); andere XML-basierte Sprachen: TEI, SVG, GML, ...

- `XPath` = XML Path Language

  Abfragesprache zur Suche und Navigation, zum Testen und Filtern innerhalb von XML-Dokumenten

XPath (kurze Wiederholung)

- Abfragesprache zur Suche und Navigation, zum Testen und Filtern innerhalb von XML-Dokumenten
- In `XPath` ist es nicht möglich neue XML-Knoten zu erzeugen oder das XML-Dokument zu ändern
- Reihenfolge der Ergebnismenge entspricht der Reihenfolge im XML-Dokument ("document order")
- `XPath` ist Teil anderer XML-Technologien wie `XQuery` oder `XSLT`

XPath (kurze Wiederholung)

Mini-Übung

Titel aller Bücher

- //title/text() *oder*
- /collection/book/title/text()

Alle Ids

- /collection/book/@id *oder*
- //@id *bzw.* data(//@id)

Autor des Buches "The Empty House"

- /collection/book[title/text() = "The Empty House"]/author/text()

```
<collection>
  <book id="B1">
    <title>The Raven</title>
    <author>E.A. Poe</author>
  </book>
  <book id="B2">
    <title>The Empty House</title>
    <author>A.C. Doyle</author>
  </book>
</collection>
```

Die XML Familie

Was ist was?

- `XML` = Extensible Markup Language

  Auszeichnungssprache zur Darstellung hierarchisch strukturierter Daten (menschen- und maschinenlesbar); andere XML-basierte Sprachen: TEI, SVG, GML, ...

- `XPath` = XML Path Language

  Abfragesprache zur Suche und Navigation, zum Testen und Filtern innerhalb von XML-Dokumenten

- `XSD` = XML Schema Definition

  Schemasprache zur Definition und Validierung von XML-Strukturen

XSD

Was kann ich mit XSD ausdrücken?
Beispiel (von Wikipedia):

```
<celsiusKoerperTemp>37.0</celsiusKoerperTemp>
```

In XSD können Einschränkungen gemacht werden:

```
<xs:simpleType name="celsiusKoerperTemp">
  <xs:restriction base="xs:decimal">
    <xs:fractionDigits value="1"/>
    <xs:minInclusive value="35.0"/>
    <xs:maxInclusive value="42.5"/>
  </xs:restriction>
</xs:simpleType>
```

Der Wert soll den Typ "Dezimalzahl" haben.

Der Wert soll eine Nachkommastelle haben.

Definition von Minimal- und Maximalwert.

Die XML Familie

Was ist was?

- `XSLT` = Extensible Stylesheet Language Transformation

  Transformationssprache für XML-Dokumente

XSLT

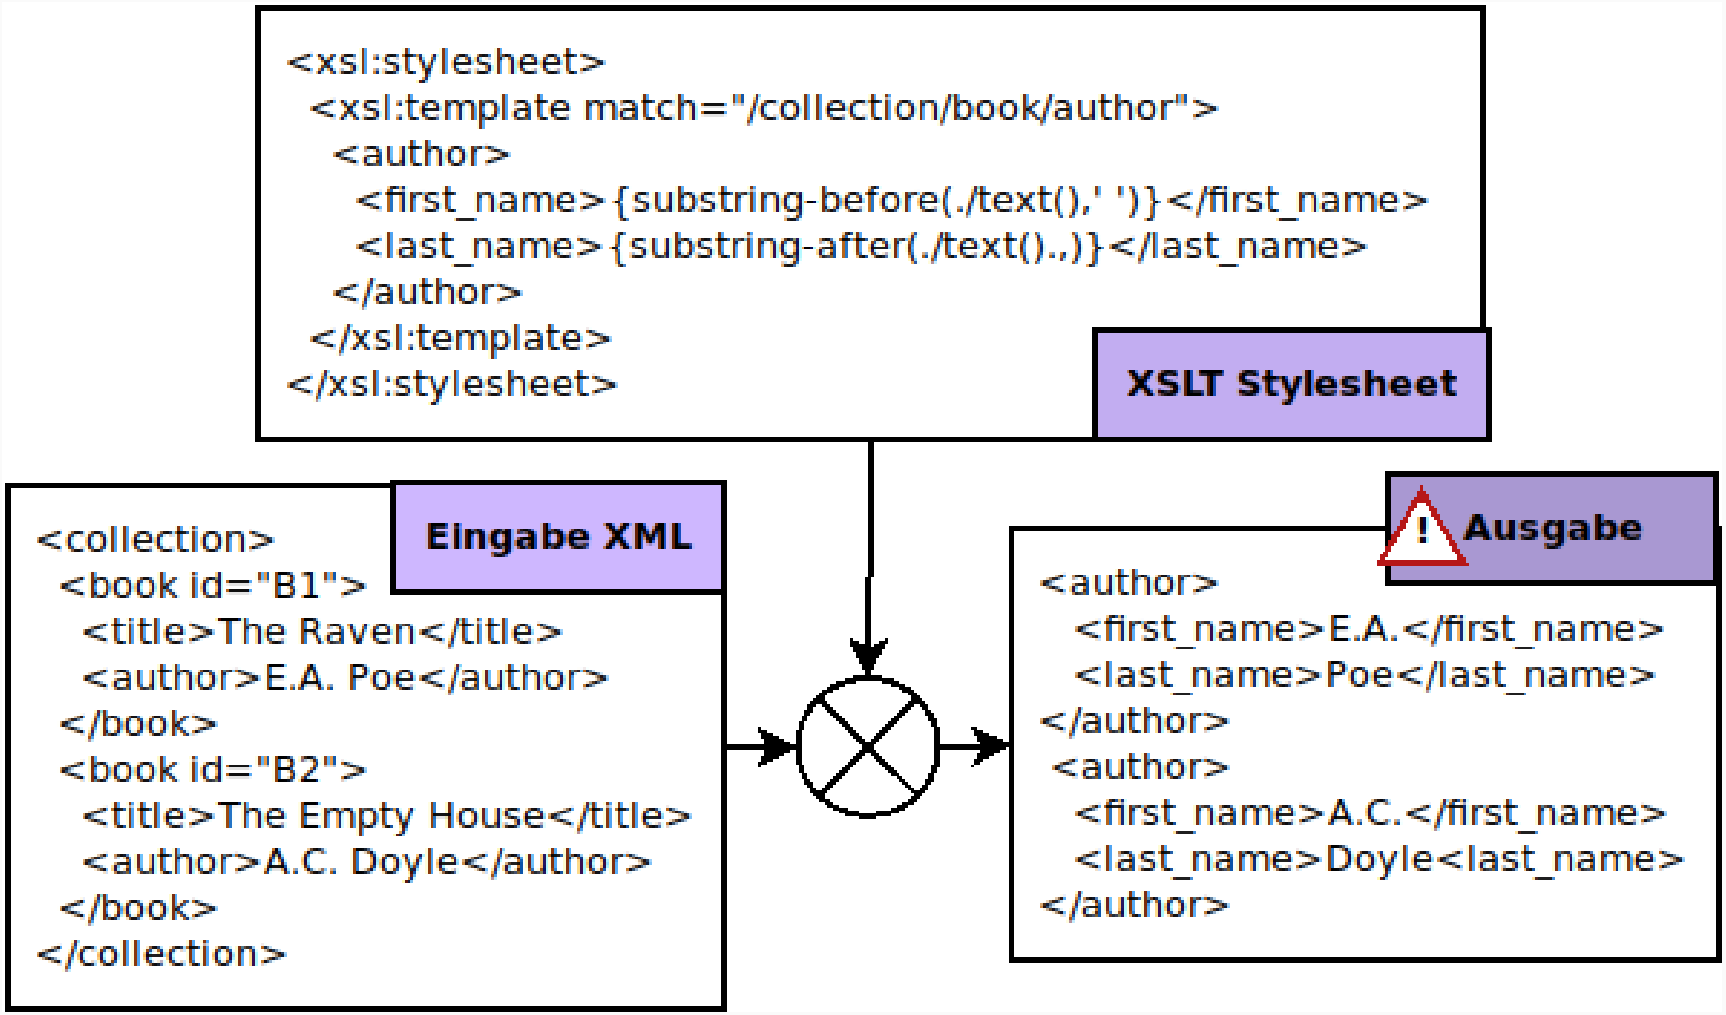
<xsl:stylesheet>
<xsl:template match="/collection/book/author">
<author>
<first_name>{substring-before(./text(),' ')}</first_name>
<last_name>{substring-after(./text()..)}</last_name>
</author>
</xsl:template>
</xsl:stylesheet>
XSLT Stylesheet
<collection>
<book id="B1">
<title>The Raven</title>
<author>E.A. Poe</author>
</book>
<book id="B2">
<title>The Empty House</title>
<author>A.C. Doyle</author>
</book>
</collection>
Eingabe XML
Ausgabe
<author>
<first_name>E.A.</first_name>
<last_name>Poe</last_name>
</author>
<author>
<first_name>A.C.</first_name>
<last_name>Doyle<last_name>
</author>

Die XML Familie

Was ist was?

- `XSLT` = Extensible Stylesheet Language Transformation

  Transformationssprache für XML-Dokumente
- `XQuery` = XML Query Language

  Abfragesprache für XML-Datenbanken
- ...

Die XML-Datenbank BaseX

XML-Datenbank

Was ist eigentlich eine XML-Datenbank?

- Datenbank für XML-Dokumente, die dort gespeichert und durchsucht werden können
- dokumentenorientierte Datenbank (NoSQL)
- So wie man mit SQL relationale Datenbanken abfragt, fragt man XML-Datenbanken mit XPath und XQuery ab
- Möglichkeit zur Volltextsuche
- BaseX ist ein Beispiel für eine XML-Datenbank, es gibt noch andere :-)

BaseX

- XML-Datenbank mit XQuery Prozessor
- erlaubt die Speicherung, Abfrage und Manipulation großer Textdateien (XML/JSON/CSV/...)
- enhält einen XQuery Editor, um XQuery in Echtzeit zu testen
- bietet verschiedenste Visualisierungsmöglichkeiten für die Analyse der Daten

BaseX

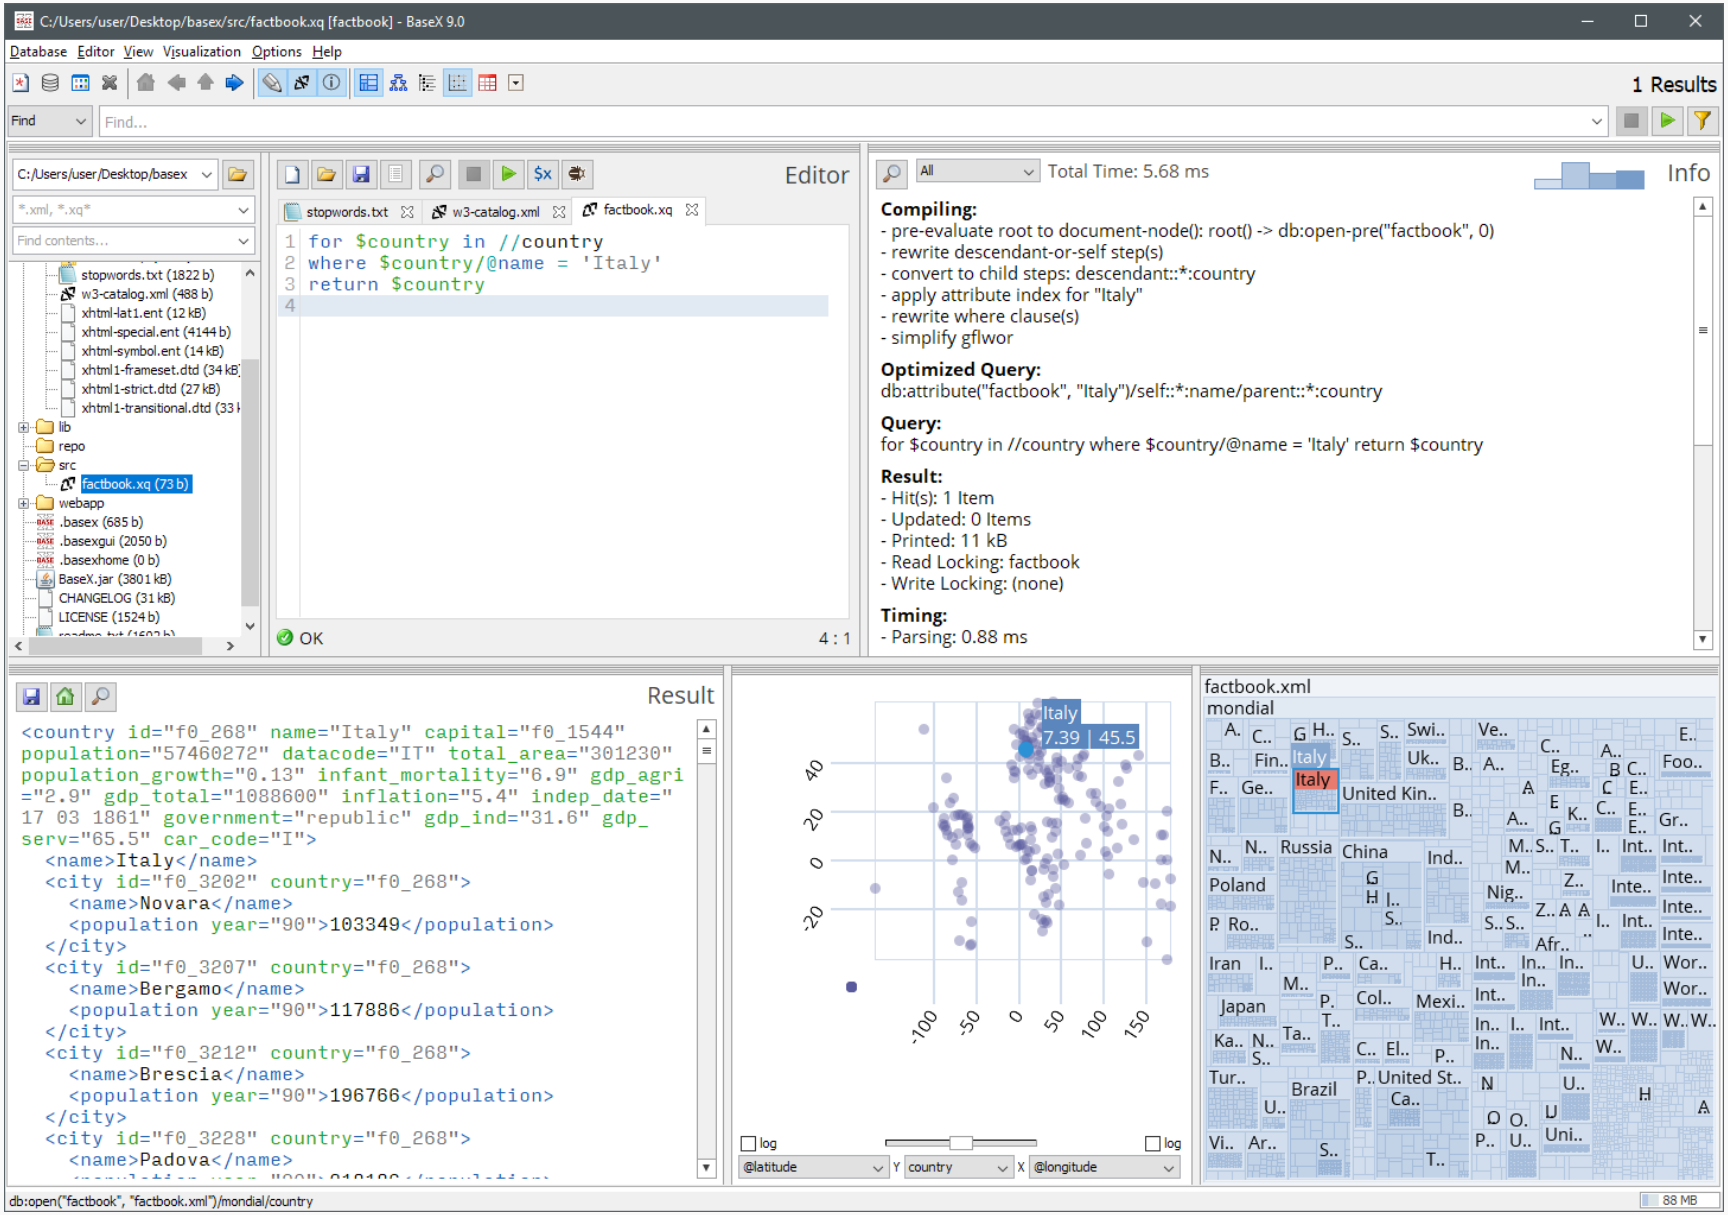
C:/Users/user/Desktop/basex/src/factbook.xq [factbook] - BaseX 9.0
Database Editor View Visualization Options Help
1 Results
Find
Find...
C:/Users/user/Desktop/basex
*.xml, *.xq*
Find contents...
stopwords.txt (1822 b)
w3-catalog.xml (488 b)
xhtml-lat1.ent (12 kB)
xhtml-special.ent (4144 b)
xhtml-symbol.ent (14 kB)
xhtml1-frameset.dtd (34 kB)
xhtml1-strict.dtd (27 kB)
xhtml1-transitional.dtd (33 k
lib
repo
src
factbook.xq (73 b)
webapp
.basex (685 b)
.basexgui (2050 b)
.basexhome (0 b)
BaseX.jar (3801 kB)
CHANGELOG (31 kB)
LICENSE (1524 b)
Editor
stopwords.txt
w3-catalog.xml
factbook.xq
1 for $country in //country
2 where $country/@name = 'Italy'
3 return $country
4
OK
4 : 1
All
Total Time: 5.68 ms
Info
Compiling:
- pre-evaluate root to document-node(): root() -> db:open-pre("factbook", 0)
- rewrite descendant-or-self step(s)
- convert to child steps: descendant::*:country
- apply attribute index for "Italy"
- rewrite where clause(s)
- simplify gflwor
Optimized Query:
db:attribute("factbook", "Italy")/self::*:name/parent::*:country
Query:
for $country in //country where $country/@name = 'Italy' return $country
Result:
- Hit(s): 1 Item
- Updated: 0 Items
- Printed: 11 kB
- Read Locking: factbook
- Write Locking: (none)
Timing:
- Parsing: 0.88 ms
Result
<country id="f0_268" name="Italy" capital="f0_1544" population="57460272" datacode="IT" total_area="301230" population_growth="0.13" infant_mortality="6.9" gdp_agri="2.9" gdp_total="1088600" inflation="5.4" indep_date="17 03 1861" government="republic" gdp_ind="31.6" gdp_serv="65.5" car_code="I">
<name>Italy</name>
<city id="f0_3202" country="f0_268">
<name>Novara</name>
<population year="90">103349</population>
</city>
<city id="f0_3207" country="f0_268">
<name>Bergamo</name>
<population year="90">117886</population>
</city>
<city id="f0_3212" country="f0_268">
<name>Brescia</name>
<population year="90">196766</population>
</city>
<city id="f0_3228" country="f0_268">
<name>Padova</name>
Italy
7.39 | 45.5
40
20
0
-20
-100
-50
0
50
100
150
log
log
@latitude
Y
country
X
@longitude
factbook.xml
mondial
Russia
China
United Kin..
Poland
Iran
Japan
Brazil
United St..
db:open("factbook", "factbook.xml")/mondial/country
88 MB

BaseX

Hilfreiche Kommandos in BaseX:

- Erstellen einer Datenbank (geht auch über die GUI)

```
db:create("books")
```

- Öffnen einer Datenbank (geht auch über die GUI)

```
db:open("books")
```

- Dokument einer Datenbank hinzufügen

```
db:add("books","/home/dir/meinDoc.xml")
```

- Optimieren einer Datenbank

```
db:optimize("books")
```

BaseX - Installation

BaseX benötigt die Java Runtime Environment (JRE) mindestens in der Version Java 8. (Sie können auch OpenJDK installieren.)

BaseX ist plattformunabhängig und wurde auf Windows, Mac OS X, Linux und OpenBSD getestet.
Bitte installieren Sie die JRE und BaseX bis nächste Woche auf Ihrem Laptop, wenn Sie die Übungen live mitmachen möchten.

Melden Sie sich, falls Sie Probleme bei der Installation haben.

Beispieldaten für die Übungen

Metadaten vom Städel Museum, die Teil des Coding da Vinci Rhein-Main waren. Sie sind unter CC0-Lizenz verfügbar.

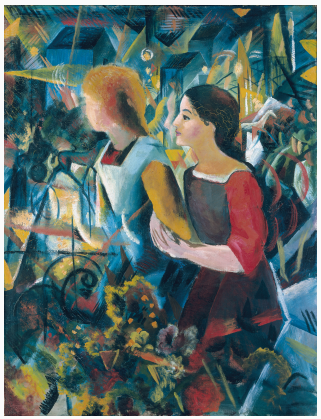

{ COD1NG DA V1NC1 }
RHEIN-MAIN 2018

Siehe Link im Moodle!

XQuery - Einführung

XQuery - Einführung

XQuery

- Abfragesprache für XML-Datenbanken; Dateiendung `.xq`
- ähnlich zu `SQL` für relationale Datenbanken
- streng typisierte, funktionale Programmiersprache
  $\rightarrow$ eine Eingabe liefert eine Ausgabe
- hat den Ruf einfacher zu lernen zu sein als XSLT ;-)

XQuery - Einführung

XQuery kann z.B. Aufgaben erfüllen wie:

- Suche alle Titel, die mit "A" beginnen.
- Suche alle Titel im Dokument und sortiere sie alphabetisch.
- Zähle die Anzahl verschiedener Autoren im Dokument und sage mir, bei wie vielen Büchern sie jeweils als Autor aufgeführt sind.
- Erzeuge ein XML-Dokument oder eine CSV-Tabelle, die jedem Autor, die Liste der von ihnen geschriebenen Büchern zuordnet.

XQuery - Sprachelemente

XQuery - Sprachelemente

- grundlegende Datenstruktur ist eine Sequenz,
  eine geordnete Liste, z.B.:
  ()
  (1,3,2)
  (<a/>,hallo,<c/>)
  ("The Raven","The Empty House")

XQuery - Sprachelemente

- Literale, Variablen, Kommentare

```
(:  Kommentar - Titel, die mit "T" beginnen :)
```

  - `declare variable $titles := //title;`
  - `$titles[starts-with(text(),"T")]`

- Ausdrücke, Funktionsaufrufe
  - 1 + 4 * 2
  - `starts-with(text(),"T")`
- Boolesche Ausdrücke und Vergleiche
  - 1 < 3
  - 1 < 3 and 2 > 5

XQuery - Sprachelemente

Bedingte Aussagen mit if/then/else:

```
if (starts-with($title/text(), "T"))
then $title/text()
else "Nope!"
```

(Hinweis: für weitere Sprachelemente, siehe auch `switch`, Sequenzoperationen, Type Casts, FLWOR)

XQuery - FLWOR

XQuery - FLWOR

- `for` - Schleife (für alle x in xs)

  ```
  for $x in $xs
  ```

- `let` - Variablendefinition

  ```
  let $x := 5
  ```

- `where` - Einschränkung

  ```
  where $x > 2
  ```

- `order by ...  descending/ascending`
  - Sortieren nach ... absteigend/aufsteigend

  ```
  order by $x descending
  ```

- `return` - Rückgabe

  ```
  return $x
  ```

XQuery - FLWOR

Beispiel XML - Variante (books2.xml in Datenbank "books"):

```
<collection>
  <book id="B1">
    <title>The Raven</title>
    <author>E.A. Poe</author>
  </book>
  <book id="B2">
    <title>The Empty House</title>
    <author>A.C. Doyle</author>
  </book>
  <book id="B3">
    <title>A Study in Scarlet</title>
    <author>A.C. Doyle</author>
  </book>
  <book id="B4">
    <title>The Dancing Men</title>
    <author>A.C. Doyle</author>
  </book>
</collection>
```

XQuery - FLWOR

Minimalbeispiel `for`:

```
for $title in db:open("books")//title
return $title/text()
```

Ausgabe:

The Raven
The Empty House
A Study in Scarlet
The Dancing Men

XQuery - FLWOR

Beispiel + `let`:

```
for $title in db:open("books")//title
let $t := $title/text()
return $t
```

Ausgabe:

The Raven
The Empty House
A Study in Scarlet
The Dancing Men

XQuery - FLWOR

Beispiel + `where`:

```
for $title in db:open("books")//title
let $t := $title/text()
where starts-with($t,"T")
return $t
```

Ausgabe:

The Raven
The Empty House
The Dancing Men

XQuery - FLWOR

Beispiel + order by:

```
for $title in db:open("books")//title
let $t := $title/text()
where starts-with($t,"T")
order by $t ascending
return $t
```

Ausgabe:

The Dancing Men

The Empty House

The Raven

XQuery - FLWOR

Beispiel author:

```
for $book in db:open("books")//book
let $author := $book/author/text()
return $author
```

Ausgabe:

E.A. Poe

A.C. Doyle

A.C. Doyle

A.C. Doyle

:-(

XQuery - FLWOR

Beispiel group by:

```
for $book in db:open("books")//book
group by $author := $book/author/text()
return $author
```

Ausgabe:

E.A. Poe

A.C. Doyle

:-)

XQuery - Konstruktion

XQuery - Konstruktion

- Erinnerung: XPath kann nur gewünschte Teilmengen eines XML Dokuments zurückgeben, aber keine neuen Knoten erzeugen
- Mit XQuery kann man sein eigenes Ausgabe XML bauen!

```
<label>{$title/text()}</label>
```

- oder falls der Elementname variabel ist:

```
element {"label" || $n} {$title/text()}
```

XQuery - Konstruktion

Beispiel Elemente erzeugen:

```
for $title in db:open("books")//title
return <label>{$title/text()}</label>
```

Ausgabe:

<label>The Raven</label>
<label>The Empty House</label>
<label>A Study in Scarlet</label>
<label>The Dancing Men</label>

XQuery - Konstruktion

Beispiel group by:

```
for $book in db:open("books")//book
group by $author := $book/author/text()
return
 <author>
  <name>{$author}</name>
 </author>
```

XQuery - Konstruktion

Ausgabe:

```
<author>
  <name>E.A. Poe</name>
</author>
<author>
  <name>A.C. Doyle</name>
</author>
```

XQuery - Konstruktion

Beispiel - group by + count:

```
for $book in db:open("books")//book
group by $author := $book/author/text()
return
 <author>
  <name>{$author}</name>
  <bookCount>{count($book/title/text())}</bookCount>
 </author>
```

XQuery - Konstruktion

Ausgabe:

```
<author>
  <name>E.A. Poe</name>
  <bookCount>1</bookCount>
</author>
<author>
  <name>A.C. Doyle</name>
  <bookCount>3</bookCount>
</author>
```

XQuery - Konstruktion

Beispiel - Verschachtelung:

```
for $book in db:open("books")//book
let $title := $book/title/text()
group by $author := $book/author/text()
return <author>
          <name>{$author}</name>
          {for $t in $title
          order by $t ascending
          return <wrote>{$t}</wrote>}
       </author>
```

XQuery - Konstruktion

Ausgabe:

```
<author>
  <name>E.A. Poe</name>
  <wrote>The Raven</wrote>
</author>
<author>
  <name>A.C. Doyle</name>
  <wrote>A Study in Scarlet</wrote>
  <wrote>The Dancing Men</wrote>
  <wrote>The Empty House</wrote>
</author>
```

XQuery - Update

XQuery - Update

Mit Updating-Ausdrücken kann man z.B.:

- Knoten einfügen

```
insert node <type/> into $book
```

- bestimmte Knoten löschen

```
delete node //type
```

- Knoten oder ihre Werte durch andere ersetzen

```
replace node //type with <description/>
replace value of node //type with "book"
```

- Knoten umbenennen

```
rename node //type as "description"
```

Nach Updating-Ausdrücken immer db:optimize("book") ausführen!

XQuery - Update

Beispiel Elemente hinzufügen (insert node ... into ...):

```
for $book in db:open("books")//book
return if ($book/author/text() = "A.C. Doyle")
  then insert node
       <genre>Kriminalliteratur</genre>
       into $book,
db:optimize("books")
```

XQuery - Update

```
<collection>
  <book id="B1">
    <title>The Raven</title>
    <author>E.A. Poe</author>
  </book>
  <book id="B2">
    <title>The Empty House</title>
    <author>A.C. Doyle</author>
    <genre>Kriminalliteratur</genre>
  </book>
  <book id="B3">
    <title>A Study in Scarlet</title>
    <author>A.C. Doyle</author>
    <genre>Kriminalliteratur</genre>
  </book>
  <book id="B4">
    <title>The Dancing Men</title>
    <author>A.C. Doyle</author>
    <genre>Kriminalliteratur</genre>
  </book>
</collection>
```

XQuery - Update

Beispiel Wert ersetzen (replace value of node ... with "..."):

```
for $book in db:open("books")//book
let $author := $book/author
return if ($author/text() = "A.C. Doyle")
 then replace value of node $author
      with "Arthur Conan Doyle"
 else if ($author/text() = "E.A. Poe")
  then replace value of node $author
       with "Edgar Allan Poe"
  else (),
db:optimize("books")
```

XQuery - Update

Datenbank nach Update:

```
<collection>
  <book id="B1">
    <title>The Raven</title>
    <author>Edgar Allan Poe</author>
  </book>
  <book id="B2">
    <title>The Empty House</title>
    <author>Arthur Conan Doyle</author>
    <genre>Kriminalliteratur</genre>
  </book>
  <book id="B3">
    <title>A Study in Scarlet</title>
    <author>Arthur Conan Doyle</author>
    <genre>Kriminalliteratur</genre>
  </book>
  <book id="B4">
    <title>The Dancing Men</title>
    <author>Arthur Conan Doyle</author>
    <genre>Kriminalliteratur</genre>
  </book>
</collection>
```

Fragen?

References i

- Basex.
  http://basex.org/.
- moodle.
  https://moodle.studiumdigitale.uni-frankfurt.de/moodle/course/view.php?id=511.
- M. Vogelgesang.
  Metropolis beamer theme.
  Metropolis is licensed under a Creative Commons Attribution-ShareAlike 4.0 International License.