Skriptsprachen: Python

xml.dom.minidom

Jan Krüger, Alexander Sczyrba

Technische Fakultät
Universität Bielefeld

12. Februar 2018

XML – eXtensible Markup Language

- Daten sind sturkturiert (Texte, Bilder, Messergebnisse)
- Maschinelle Verarbeitung erfordert Kenntnis der Struktur
- Automatisierte Verarbeitung erfordert einheitliches Datenformat

Gesucht: Formalismus, um beliebige Strukturen zu beschreiben

Lösung: XML

- XML kann textuelle Daten strukturieren
- XML ist eine Metasprache zur Definition von Auszeichnungssprachen
  - Welche Elemente/Attribute sind vorhanden?
  - Wie dürfen diese verschachtelt sein?

XML-Sprachbeispiele

- XHTML 1.1
- SVG
- RSS 2.0
- RDF
- MathML

```
<?xml version="1.0" encoding="UTF-8"?>
<Wurzelelement>
  <Element>...</Element>
  <Element>
    <Standalone-Element Attribut="" />
  </Element>
  <Standalone-Element />
</Wurzelelement>
```

XML - Und dann?

- XML dient rein zur Datenrepräsentation
- Darstellung sekundäres Problem
- XML muss weiterverarbeitet werden

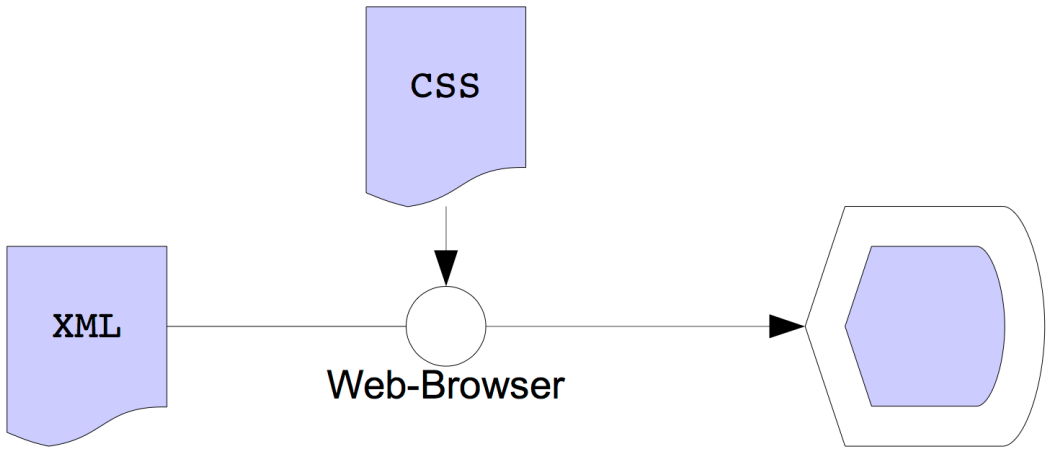

XML transformieren

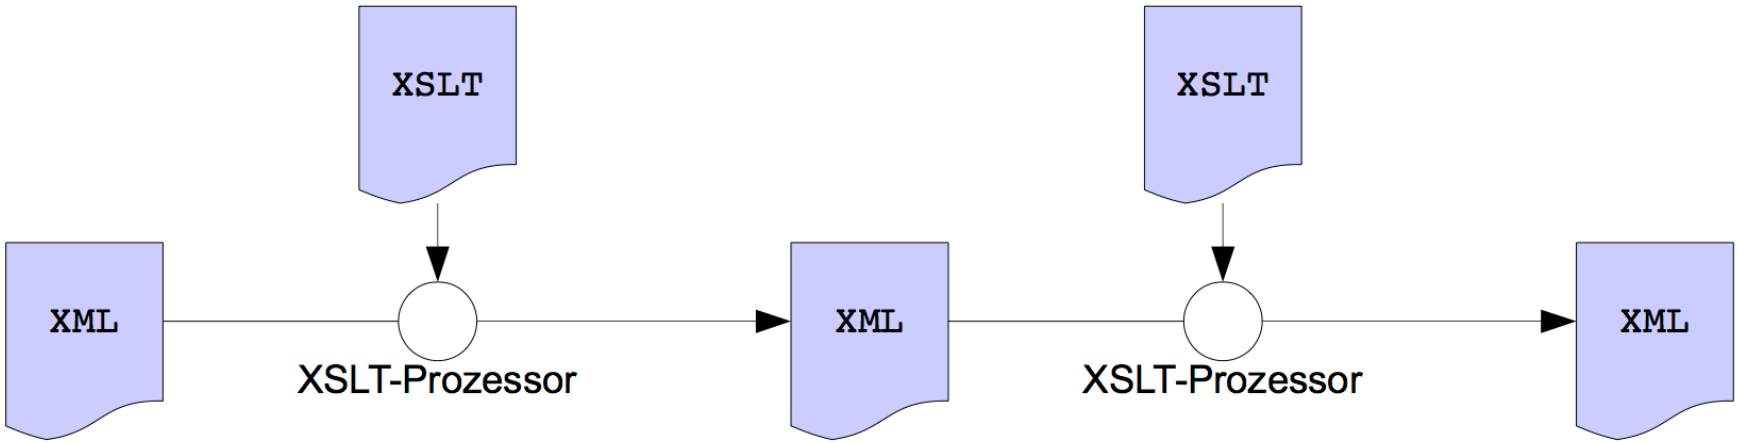

XML transformieren & darstellen

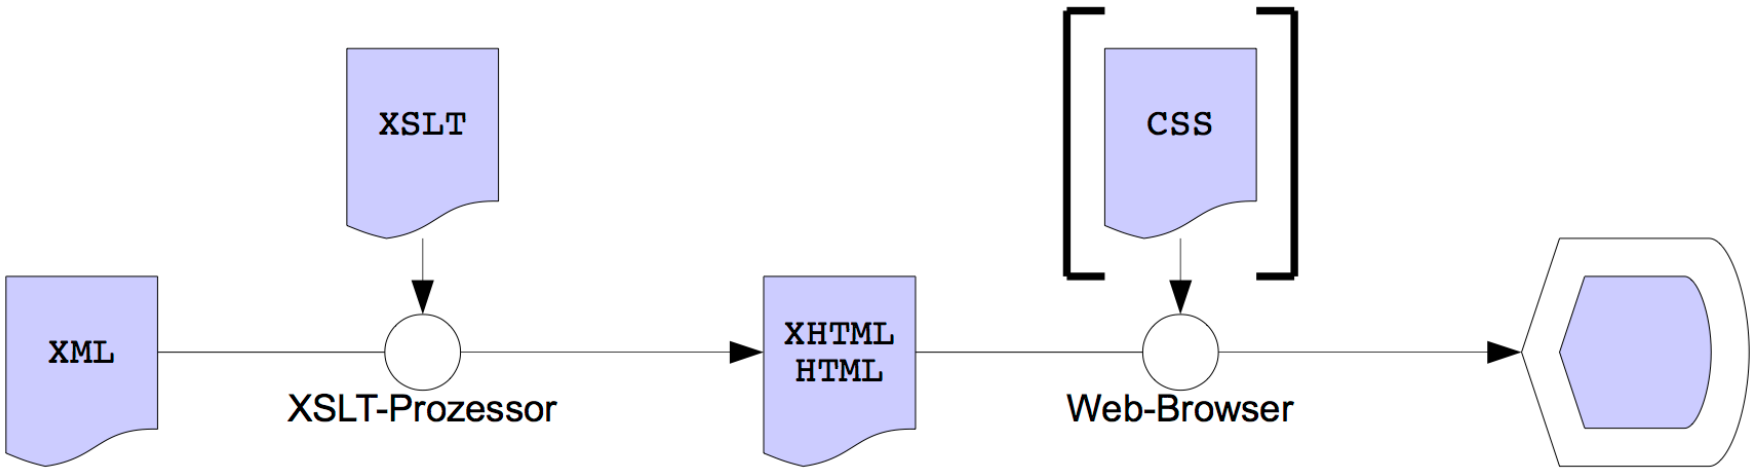

Ein Beispiel

```
<?xml version="1.0"?>
<presentation status="draft" date="2002-10-04">
  <title>XML &amp;amp; Friends for Dummies</title>
  <author>Joe User</author>
  <slide>
    <title toc="yes">What is XML?</title>
    <ilist>
      <item>XML is not a markup language (unlike HTML)
      </item>
      <item>XML instances can be <emph>well formed</emph>
    or even <emph>validating</emph></item>
      <item>XML stands for &xml;</item>
    </ilist>
</slide>
  <slide>...</slide>
</presentation>
```

XML-Deklaration

Optional Kodierung:
encoding="UTF-8"
encoding="ISO-8859-1"

Ein Beispiel

```
<?xml version="1.0"?>
<presentation status="draft" date="2002-10-04">
  <title>XML &amp;amp; Friends for Dummies</title>
  <author>Joe User</author>
  <slide>
    <title toc="yes">What is XML?</title>
    <ilist>
      <item>XML is not a markup language (unlike HTML)
      </item>
      <item>XML instances can be <emph>well formed</emph>
    or even <emph>validating</emph></item>
      <item>XML stands for &xml;</item>
    </ilist>
</slide>
  <slide>...</slide>
</presentation>
```

Root

XML-Dokumente besitzen genau ein Root-Element (Wurzel).

Ein Beispiel

```
<?xml version="1.0"?>
<presentation status="draft" date="2002-10-04">
  <title>XML &amp;amp; Friends for Dummies</title>
  <author>Joe User</author>
  <slide>
    <title toc="yes">What is XML?</title>
    <ilist>
      <item>XML is not a markup language (unlike HTML)
      </item>
      <item>XML instances can be <emph>well formed</emph>
    or even <emph>validating</emph></item>
      <item>XML stands for &xml;</item>
    </ilist>
</slide>
  <slide>...</slide>
</presentation>
```

Element

Ab der Wurzel können beliebig viele Kindelemente folgen. Sie werden auch Elementknoten genannt.

Ein Beispiel

```
<?xml version="1.0"?>
<presentation status="draft" date="2002-10-04">
  <title>XML &amp;amp; Friends for Dummies</title>
  <author>Joe User</author>
  <slide>
    <title toc="yes">What is XML?</title>
    <ilist>
      <item>XML is not a markup language (unlike HTML)
      </item>
      <item>XML instances can be <emph>well formed</emph>
    or even <emph>validating</emph></item>
      <item>XML stands for &xml;</item>
    </ilist>
</slide>
  <slide>...</slide>
</presentation>
```

Öffnendes und schließendes Tag

Ein Element besitzt genau ein öffnendes und ein schließendes Tag:
<elem> – öffnend
</elem> – schließend

Alternativ kann ein Tag auch leer sein: <elem/>

Ein Beispiel

```
<?xml version="1.0"?>
<presentation status="draft" date="2002-10-04">
  <title>XML &amp;amp; Friends for Dummies</title>
  <author>Joe User</author>
  <slide>
    <title toc="yes">What is XML?</title>
    <ilist>
      <item>XML is not a markup language (unlike HTML)
      </item>
      <item>XML instances can be <emph>well formed</emph>
    or even <emph>validating</emph></item>
      <item>XML stands for &xml;</item>
    </ilist>
</slide>
  <slide>...</slide>
</presentation>
```

Textknoten

Elemente können als Inhalt Text enthalten, sodass sie als Kindknoten einen Textknoten besitzen.

Ein Beispiel

```
<?xml version="1.0"?>
<presentation status="draft" date="2002-10-04">
  <title>XML &amp;amp; Friends for Dummies</title>
  <author>Joe User</author>
  <slide>
    <title toc="yes">What is XML?</title>
    <ilist>
      <item>XML is not a markup language (unlike HTML)
      </item>
      <item>XML instances can be <emph>well formed</emph>
    or even <emph>validating</emph></item>
      <item>XML stands for &xml;</item>
    </ilist>
</slide>
  <slide>...</slide>
</presentation>
```

Entities (Entitäten)

Spezielle Zeichen werden als Entitäten gesetzt – Textmakro.

Sie dienen zur Kodierung von Sonderzeichen, reservierten Zeichen und oft verwendeten Zeichenketten.

Neben bereits vorgegebenen, können neue definiert werden. Sieger hierzu: DTD.

Ein Beispiel

```
<?xml version="1.0"?>
<presentation status="draft" date="2002-10-04">
  <title>XML &amp;amp; Friends for Dummies</title>
  <author>Joe User</author>
  <slide>
    <title toc="yes">What is XML?</title>
    <ilist>
      <item>XML is not a markup language (unlike HTML)
      </item>
      <item>XML instances can be <emph>well formed</emph>
    or even <emph>validating</emph></item>
      <item>XML stands for &xml;</item>
    </ilist>
</slide>
  <slide>...</slide>
</presentation>
```

Attribute

Elemente können Attribute besitzen, um Zusatzinformationen zu hinterlegen. Das key/value-Paar kommt nur im öffnenden Tag vor und muss eindeutig benannt sein.

Ein Beispiel

```
<?xml version="1.0"?>
<presentation status="draft" date="2002-10-04">
  <title>XML &amp;amp; Friends for Dummies</title>
  <author>Joe User</author>
  <slide>
    <title toc="yes">What is XML?</title>
    <ilist>
      <item>XML is not a markup language (unlike HTML)
      </item>
      <item>XML instances can be <emph>well formed</emph>
    or even <emph>validating</emph></item>
      <item>XML stands for &xml;</item>
    </ilist>
</slide>
  <slide>...</slide>
</presentation>
```

Nested Elements

In Textknoten können eingebettete Elemente vorkommen, wobei hier auf korrekte Schachtelung geachtet werden muss:

<a>...
vs.
<a>...

Besonderheiten

- Groß-/Kleinschreibugn ist relevant:
  <elem>GEHT NICHT</Elem>
- Reservierte Sonderzeichen:

  < – < > – > & – &
  ' – ' " – "

- Mehrzeilige Kommentare: <!––*KOMMENTAR* ––>
  - Darf nicht vorkommen: ––
  - Keine Verschachtelung möglich

Wohlgeformheit und Validierbarkeit

Wenn alle Vorgaben eingehalten wurden, ist das XML-Dokument wohlgeformt und kann korrekt verarbeitet werden, wenn eien DTD/Schema angegeben wurde.

Überprüfung durch Validierer:

Kommandozeile xmlwf, xmllint

Onlinetools W3C, Validome

Übung – Mediendatenbank

Erstellt ein XML-Dokument, das eine Mediendatenbank für Musikstücke repräsentiert. Überprüfe die Wohlgeformheit mittels der vorgestellten Kommandozeilentools und Onlinetools.

Fügt beispielhaft drei Einträge ein(inkl. leerer Elemente in einem Eintrag)

Namespaces

- Verwendung unterschiedlicher XML-Sprachen in einem Dokument
- Vergleichbar mit Modulen (Python, Java) oder einer Telefonvorwahl
  $\rightarrow$ Unterscheidung zwischen gleichnamigen Elementen
- Werden durch URIs (Uniform Resource Identifier) dargestellt
  - Müssen keine gültige URL (Uniform Resource Locator) darstellen
  - Wenn gültige URL, dann sollte dort zu finden sein:
    - DTD (Dokumenttypdefinition)
    - XML-Schema

Namespaces

```
<html xmlns="http://www.w3.org/1999/xhtml">
  ... XHTML-Elemente
  <math xmlns="http://www.w3.org/1998/Math/MathML">
    ... MathML-Elemente
  </math>
  ... XHTML-Elemente
</html>
```

Attribut xmlns:pf="http://..." binden den Namensraum pf an die URI http://...

```
<html xmlns="http://www.w3.org/1999/xhtml"
      xmlns:m="http://www.w3.org/1998/Math/MathML">
  ... XHTML-Elemente
  <m:math>
    <span>Hier steht XHTML. Variable x: <m:i>x</m:i></spa
  </m:math>
  ... XHTML-Elemente
</html>
```

XPath & DOM-Repräsentation

Es existieren unterschiedliche Techniken, um durch ein XML-Dokument zu navigieren (und dieses zu verändern)

XPath Navigieren

DOM-Repräsentation Navigieren und Modifizieren

Beide Verfahren sehen das Dokument als Baum an, mit:

- Knoten: Element, Attribut, Text, Kommentar, Namespace, PI(Processing Instruction)
- Navigation entlang einer Achse
- Optionale Knotentests (Bedingungen)

Baumrepräsentation

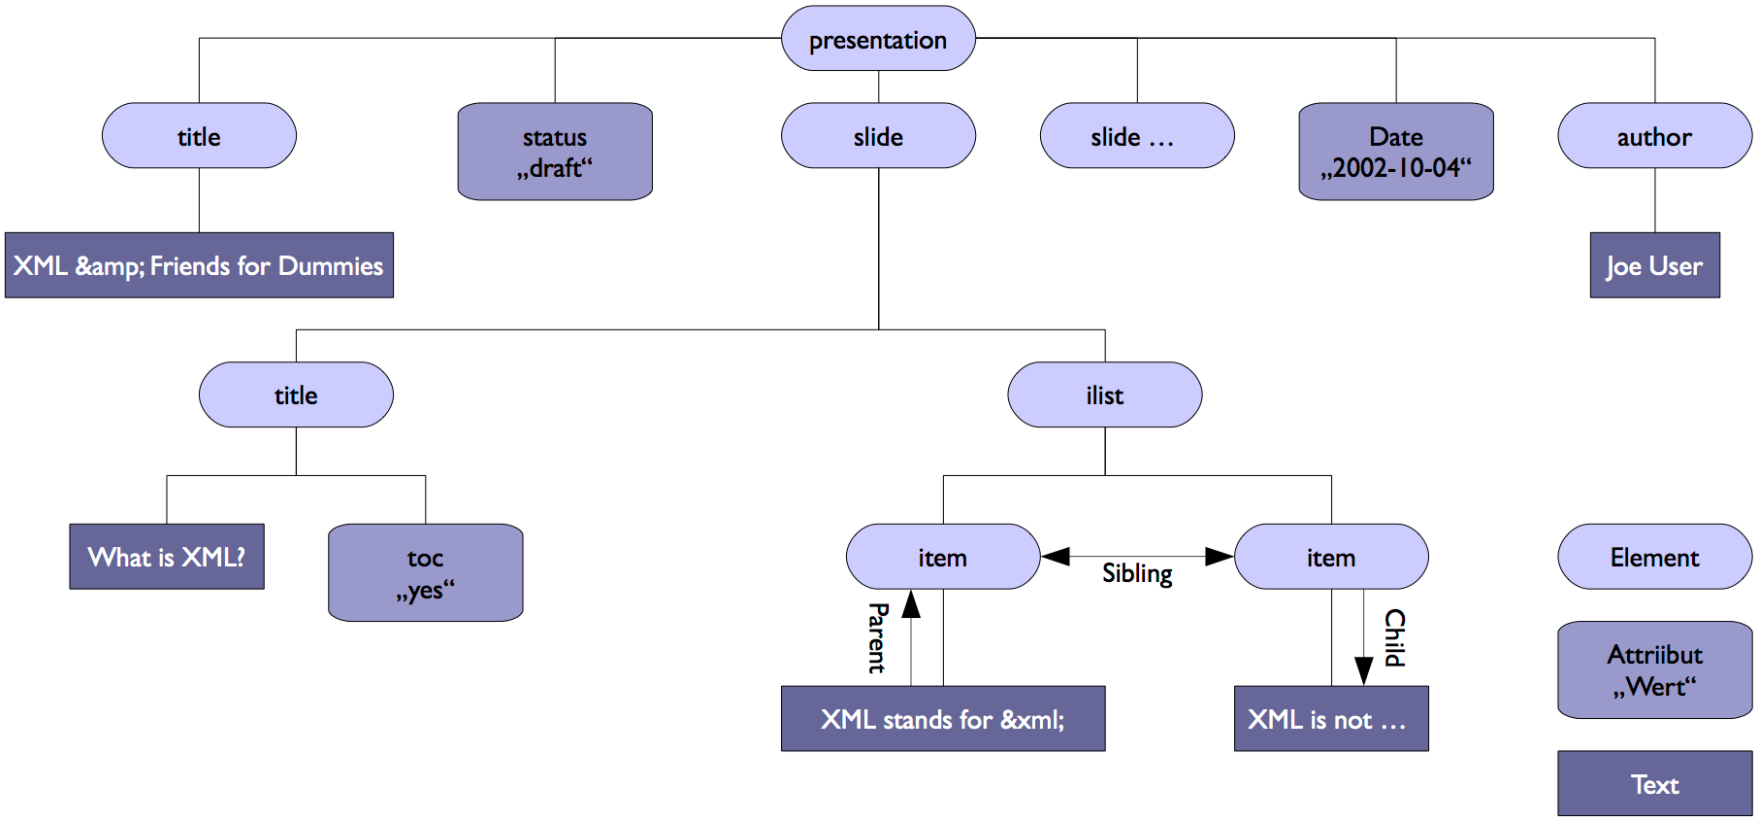

XPath

- Beginnt mit der Suche ab dem aktuellen Kontextknoten
- Finden eines Zielknotens während der Lokalisierung:
  Achse::Knotentest[Praedikat1][Praedikat2]

Achse	Pfad, getrennt mit / oder Achsangabe
Knotentest	$*$ alle Kindknoten, NAME eines Knotens oder Funktionsaufruf wie z.B. Text() oder comment()
Prädikat	Index, Relationszeichen, Zeichenkettenfunktion, Operatoren, Knotenmengenfunktionen

XPath – Beispiele

```
/* – Wurzelelemente
//Interpret – Alle Elemente auf der Interpret-Achse
//Titel/Produzent[2] – Der zweite Produzent
      eines Titels
//Titel/Produzent[2][@gema='ja'] – Der zweite
      Produzent eines Titels, der GEMA-Mitglied ist

attribute::* – Alle Attribute des Kontextknotens
child::text() – Alle Textknoten des Kontextknotens

. – Der aktuelle Kontextknoten
```

DOM-Repräsentation

- Document Object Model (DOM): Spezifikation für Zugriff auf XML-Dokumente
- Implementationen in vielen Sprachen verfügbar: JavaScript, JDOM für Java, LibXML jeweils für C, Python, Perl...
- Durch Spezifikation: Einheitliche Funktionen, Funktionsnamen, Funktionsweise
- Lesender und schreibender Zugriff

Arbeiten mit DOM

- XML-Dokument wird eingelesen und gebarst – Parser
- XML-Dokument liegt als Baumstruktur vor, mit folgenden Knotentypen:

Document	Node	Element
Attr	Text	Comment
CDATA	Namespace	DTD
Processing Instructions		

- Variablen repräsentieren Knoten eines bestimmten Typs $\rightarrow$ Funktionen auf Variablen sind kontextabhängig
- Knoten können anhand einer eindeutigen ID, Tarnnamen (mit/ohne Namespace), Namen, Verwandtschaftsverhältnisses und mittels XPath-Ausdrücken angesteuert werden

Das Modul xml.dom.minidom ist eine besonders leichtgewichtige DOM-Implementierung für Python.

- Implementiert DOM 1.0 vollständig
- DOM 2-Featureliste nur teilweise, aber für uns ausreichend
- Voll OO-Ansatz

Parsen eines Dokuments

Modulimport import xml.dom.minidom as dom

Datei parsen dom.parse(<FILENAME>)

String parsen dom.parseString(<STRING>)

Leerer DOM-Baum dom.Document()

DOM-Baum serialisieren

als String	toxml([ENCODING]), Default-Encoding: UTF-8
in Datei	writexml(WRTR[, indent[, addindent [, nl]]]) , mit:
WRTR	Oftmals file -Instanz
indent	Einschub des Startknotens
addindent	Einschub aller weiter Kinderknoten
nl	Newline-Charakter

```
> f = open("stuff.xml", "w")
> domTree.writexml(f, "", "\t", "\n")
> f.close()
```

Elemente erstellen

- Elementknoten

```
element = doc.createElement(qname)
element = doc.createElementNS(nsURI, qname)
```

- Textknoten
  text = doc.createTextNode(data)
- Kommentarknoten
  comment = doc.createComment(data)
- Attributknoten
  attribute = doc.createAttribute(nsURI, qname)

Attributknoten

Attributknoten erstellt, und dann? Was ist mit dem Wert?

```
> aNode.value = <StrAsValue>
> node.setAttributeNode(aNode)
```

Oder direkt am Knoten erstellen:

```
node.setAttribute(<NAME>, <StrAsValue>)
```

Und wieder weg damit...

```
node.removeAttribute(name)
node.removeAttributeNode(aNode)
```

Finden von Knoten(listen

- über die Element id

```
node = doc.getElementById(id)
```

Achtung! Das Attribute muß vom Typ id sein!

- über den Element Namen

```
nodes = doc.getElementsByTagName(tagname)
nodes = doc.getElementsByTagNameNS(nsURI, tagname)
```

Anhängen, austauschen, löschen von Knoten

```
child = node.appendChild(children_node)

node.replaceChild(new_node, old_node)

child = node.removeChild(child_node)
```

Übung – minidom ganz schön groß

Erweitert das in der vorherigen Übungsaufgabe erstellte XML-Dokument mit Hilfe von minidom in Python um einen weiteren Eintrag. Lest hierfür euer Dokument ein, findet den zu erweiternden

Knoten, erstellt neue Knoten, hängt diese an den DOM-Baum an entsprechender Stelle wieder ein und speichert das XML-Dokument unter einem neuen Dateinamen ab.