Programmierkurs Python I

Michaela Regneri

2009-12-10

(Folien basieren auf dem gemeinsamen Kurs mit Stefan Thater)

Übersicht

- XML
- XML-Parser in Python
- HTML
- HTML-Parser in Python

Extensible Markup Language (XML)

- XML ist eine Sprache zum Annotieren und Strukturieren von Text
- Markierungen sind sog. Tags (in spitzen Klammern)
- Jeder öffnende Tag (`<tag>`) braucht einen schließenden (`</tag>`)

```
<kalender>
 <woche nr="50">
  <termin>
   <tag>Freitag</tag>
   <start>8.30</start>
   <ende>10.00</ende>
   <was>Python I</was>
  </termin>
 </woche>
</kalender>
```


XML - Syntax

- keine vordefinierten Elemente (Tags)
- Elementnamen: beliebige Standard-ASCII-Zeichen, keine Leerzeichen; am Anfang muss ein Buchstabe stehen, aber nicht xml / Xml / XML ...
- Die Elemente dürfen Attribute haben:
  `<element attribut="wert">...</element>`
- zwischen öffnendem und schließendem Tag kann Text stehen (CDATA): `<element>c-data text</element>`
- Tags dürfen „leer" sein, (keine CDATA) in dem Fall darf man Start- und End-Tag zusammenfassen:
  `<element attribut="irgendwas"/>`

XML - Syntax

- Elemente dürfen (und müssen) geschachtelt sein
  - es gibt immer ein „Wurzel“-Element (Root), das alle anderen Element einschachtelt
  - ein Element darf beliebig viele *Kinder* (=eingeschachtelte Elemente) haben
- Die Elemente müssen *wohlgeschachtelt* sein:
  wenn ein Tag `<tag1>` vor einem Tag `<tag2>` geöffnet wird, muss der schließende Tag `</tag2>` vor `</tag1>` kommen
  (verboten: `<wurzel><a><b></a></b></wurzel>`)

XML - Kopfzeile

- XML-Dateien sollten eine Kopfzeile haben, die die benutze XML- Variante decodiert; minimal so:
  `<?xml version="1.0"?>`
- In dieser Zeile kann auch Encoding spezifiziert werden, damit die übrige Datei später korrekt verarbeitet werden kann:
  `<?xml version="1.0" encoding="ISO-8859-1"?>`

XML - ein Beispiel

```
<?xml version="1.0"?>
<sentence>
 <phrase type="NP">
  <word id="1" pos="Det" flek="nom.pl.m">Die</word>
  <word id="2" pos="NN" lemma="Spatz" flek="nom.pl.m">
  Spatzen</word>
 </phrase>
 <phrase type="VP">
  <word id="3" pos="VV" lemma="frieren"
   flek="3ps.pl.indik.praes.akt">frieren</word>
 </phrase>
</sentence>
```


Document Type Definition (DTD)

http://www.w3schools.com/dtd/default.asp

- DTDs beschreiben die Struktur für bestimmte XML-Dokumente (Elemente, Attribute und deren Anordnung)
- DTDs können sehr nützlich sein, wenn man mehrere XML-Dokumente der gleichen Klasse hat (z.B. mehrere Sätze, annotiert nach dem gleichen Schema)
- DTDs können als eigene Datei oder in der XML-Datei definiert werden
- Ein einfaches Beispiel für die Satz-Annotation...

DTD - ein einfaches Beispiel

```
<!DOCTYPE sentence [
<!ELEMENT sentence (phrase+)>
<!ELEMENT phrase (word+)>
<!ELEMENT word (#PCDATA)>

<!ATTLIST phrase type CDATA #REQUIRED>
<!ATTLIST word id ID #REQUIRED>
<!ATTLIST word pos CDATA #REQUIRED>
<!ATTLIST word lemma CDATA #IMPLIED>
<!ATTLIST word flek CDATA #IMPLIED>
]>
```

Wurzel

Elemente:
Name, Kinder
(Typ/Tag, Menge)

Attribute:
zugeh. Element,
Name, Typ,
Restriktion

DTD und XML-Dateien

- ein Sinn von DTDs kann sein, XML-Dateien zu validieren
- Um eine XML-Datei mit einer DTD zu verknüpfen, fügt man zwischen Kopfzeile und XML-Code
  - entweder die DTD selbst ein
  - oder folgendes:
    `<!DOCTYPE note SYSTEM "mydtd.dtd">`
    (mydtd.dtd enthält die DTD, nach der die XML-Datei validiert werden soll)

XML-Parser in Python
(und anderswo)

- SAX (Simple API for XML)
  - SAX-Parser verarbeiten XML-Dokumente von vorne nach hinten
  - bestimmte Methoden werden aufgerufen, wenn Tags geöffnet oder geschlossen werden
  - kein Zugriff auf Dokumentstruktur (Kinder-Elemente, nachfolgende Elemente auf der gleichen Ebene / mit dem gleichen Namen..)
- DOM (Document Object Model)
  - Liest das Dokument einmal ganz ein
  - stellt dann die komplette Struktur zur Verfügung

SAX-Parser in Python

`http://docs.python.org/3.1/library/xml.sax.html`

- `xml.sax.make_parser()` gibt ein generisches Parser-Objekt zurück
- Das Parser-Objekt ist eine Instanz von `XMLReader`, es kann u.a. die XML-Datei lesen und strukturiert ausgeben (Zugriff auf Attribute, Tags...)
- damit der Parser etwas mit der Datei tut, muss mit `parser.setContentHandler(ContentHandler)` ein „Content Handler“ eingebaut werden
- `ContentHandler` ist die Klasse, von der wir unsere eigene XML-verarbeitende Klasse ableiten müssen

SAX-Parser - `ContentHandler`

`http://docs.python.org/3.1/library/xml.sax.handler.html`

- `startDocument()` / `endDocument()` wird direkt vor / nach Verarbeiten des XML-Codes aufgerufen
- `startElement(name, attrs)` wird bei jedem öffnenden Tag aufgerufen
  - `name` ist die Bezeichnung des Tags
  - `attrs` ist ein `Attributes`-Objekt:
    * Anzahl der Attribut-Wert-Paare: `attrs.getLength()`
    * Liste alle Atrributs-Namen: `attrs.getNames()`
    * der Wert von Attribut `at`: `attrs.getValue(at)`
    * alle Einträge in attrs (≈ Dictionaries): `atts.items()`

SAX-Parser - `ContentHandler`

`http://docs.python.org/3.1/library/xml.sax.handler.html`

- `endElement(name)` wird aufgerufen, wenn ein Tag geschlossen wird
- `characters(str)` gibt aktuell gelesene CDATA zurück
  - keine Garantie, dass die CDATA für den aktuellen Tag als ganzes zurückgegeben wird!
  - um den ganzen Text zu bekommen, muss man die CDATA für den aktuellen Tag „aufsammeln“ -> ein Beispiel...

SAX-Parser - Beispiel

```
from xml.sax.handler import ContentHandler

class CDATAPrinter(ContentHandler):
  def startElement(self, name, attrs):
    self.cdata= ""

  def endElement(self, name):
    if self.cdata.strip():
      print(name, ':', self.cdata.strip())

  def characters(self, str):
    self.cdata += str
```


SAX-Parser - Beispiel

cal.xml

```
<kalender> <woche nr="50"> <termin>
   <tag>Freitag</tag> <start>8.30</start>
   <ende>10.00</ende> <was>Python I</was>
  </termin></woche></kalender>
```

```
import xml.sax
parser = xml.sax.make_parser()
parser.setContentHandler(CDATAPrinter())
parser.parse('cal.xml')
```

Konsolenausgabe

```
tag : Freitag
start : 8.30
ende : 10.00
was : Python I
```

DOM

- DOM ist kein reiner Parser, sondern eine Datenstruktur für Zugriff *und* Bearbeitung / Erstellung von XML-Strukturen
- anderes Konzept als SAX: das Dokument wird eingelesen, dann kann strukturierter Zugriff erfolgen
- die benutzerdefinierten Aktionen finden mit dem DOM-Objekt statt, nicht beim Einlesen der XML-Datei
- das ist speicherintensiver, aber kann auch deutlich bequemer sein
- Ein DOM-Parser verwaltet Dokumente als Bäume:

Baumstruktur in XML

```
<kalender>
 <woche nr="50">
  <termin>
   <tag>Freitag</tag>
   <start>8.30</start>
   <ende>10.00</ende>
   <was>Python I</was>
  </termin>
 </woche>
</kalender>
```

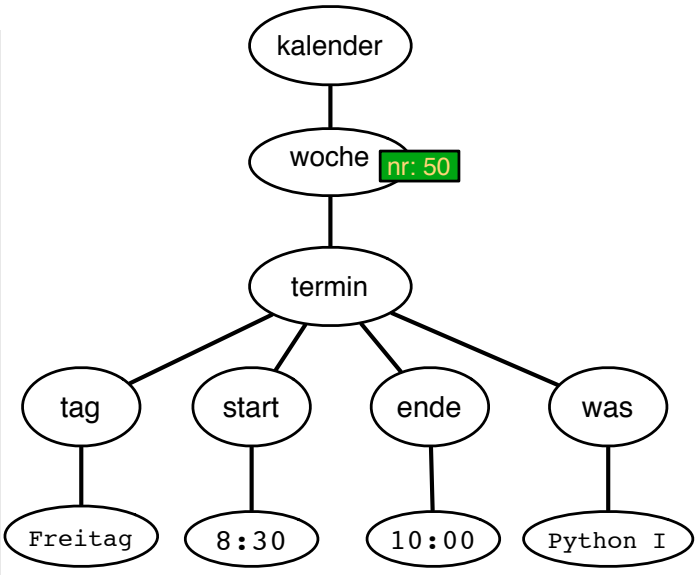

DOM-Parser in Python

http://docs.python.org/3.1/library/xml.dom.html
http://docs.python.org/3.1/library/xml.dom.minidom.html

- Zuerst erzeugt man sich ein DOM-Objekt:

```
from xml.dom.minidom import parse
domobject = parse('calendar.xml')
```

- Man kann auch XML-String direkt parsen:

```
from xml.dom.minidom import parseString
domobject = parseString("<root><c>text</c></root>")
```

- auf die Knoten im XML-Baum kann dann mit verschiedenen Methoden zugegriffen werden

DOM-Parser in Python

- Alle Elemente sind von Node abgeleitet und geben Zugriff auf diverse Felder und Methoden:
  - `Node.nodeType` Die Art des XML-Elements, u.a.: `TEXT_NODE, ENTITY_NODE, DOCUMENT_NODE, ATTRIBUTE_NODE`
  - `Node.childNodes` Geordnete Liste der direkten Kinder
  - `Node.firstChild` / `Node.lastChild`
  - `Node.hasChildNodes()`
  - `Node.attributes` das Attribut-Objekt
  - `Node.nextSibling` / `Node.previousSibling`

DOM-Parser in Python

- für „normale“ Tags (Element):
  - `Element.tagName`
  - `Element.hasAttribute(name)`
    `Element.getAttribute(name)`
  - `Element.getElementsByTagName(name)`

- Attribut-Objekte funktionieren im Prinzip wie in SAX (sind aber abgeleitet von `Node`)
- CDATA sind `Text`-Objekte, auch von `Node` abgeleitet. Für Knoten der Klasse `Text` gibt es das Feld `Text.data` (beinhaltet den CDATA-Text)

DOM-Parser - Beispiel

```
from xml.dom.minidom import parse

domobject = parse('sentence.xml')
for e in domobject.getElementsByTagName('word'):
    for a,v in e.attributes.items():
        print(a, ':',v)
    for node in e.childNodes:
        if node.nodeType == node.TEXT_NODE:
          print(node.data)
```

Hyper Text Markup Language (HTML) http://de.selfhtml.org/ http://www.w3schools.com/html/default.asp

- HTML dient zur Formatierung und „Funktionalisierung“ von Text
- anders als bei XML geht es weniger um zusätzliche Semantik als um die Strings selbst
- Wie bei XML: Tags in spitzen Klammern
- Anders als bei XML: mögliche Tags sind vordefiniert (und werden von Browsern etc. visualisiert)

HTML - Beispiel

```
<html>
  <body>
  <b>This</b> <i>text</i> is <code>formatted</code>.
  </body>
</html>
```

This *text* is `formatted`.

HTML - XML

- auch in HTML haben manche Tags Attribute, wie der Tag für Links:
  `<a href="http://www.yahoo.de">YAHOO!</a>`
- nicht alle HTML-Seiten sind auch korrektes XML:
  - nicht alle Tags in HTML müssen geschlossen werden (z.B. <p> für Abschnitte, `<li>` für Elemente in Aufzählungen)
  - manche Attribute in HTML dürfen ohne Anführungszeichen benutzt werden, z.B. `<table border=0>`
  - HTML unterscheidet Groß- und Kleinschreibung nicht (`<b>fett</B>` ist ok in HTML)

HTML-Parser in Python

`http://docs.python.org/3.1/library/html.parser.html`

- HTML-Parsing funktioniert ähnlich wie XML-Parsing
- Um eigene Parser-Funktionen zu implementieren, leitet man eine Klasse von `HTMLParser` ab
- Die zur Verfügung stehenden Methoden sehen ähnlich aus wie die im XML-Parser:
  - `handle_starttag(tag, attrs)`, `handle_endttag(tag)` und `handle_startendtag(tag,attrs)` (leere Elemente)
  - `handle_data(data)` ist (so ungefähr) äquivalent zu `characters(str)`

HTML-Parser in Python

`http://docs.python.org/3.1/library/html.parser.html`

- der HTML-Parser ist sein eigener „ContentHandler“, eine Instanz gibt‘s einfach mit `HTMLParser()` bzw. einer Instanz der abgeleiteten Klasse
- um zu Parsen, „füttert“ man den Parser mit HTML-Text: `parser.feed(htmlstring)`
- wenn der Parser inkorrektem XML begegnet, wird er es so lange ignorieren, bis der Fehler unkorrigierbar oder das Dokument zu Ende ist
- wenn man den Text eine URL parsen will, muss man die URL zuerst einlesen:

```
text = urllib.request.urlopen(url).read()
parser.feed(str(text))
```


HTML-Parser - Beispiel

```
from html.parser import HTMLParser

class MyHTMLParser(HTMLParser):

    def handle_starttag(self, tag, attrs):
        print("Oeffne " , tag)

    def handle_endtag(self, tag):
        print("Schliesse", tag)

    def handle_startendtag(self, tag, attrs):
        print("Leerer Tag", tag)
```

HTML-Parser - Beispiel

```
from urllib.request import urlopen
[...]
parser = MyHTMLParser()
parser.feed(str(urlopen("http://www.flickr.com/".read()))
```

Konsole

```
Oeffne html
Oeffne head
Oeffne meta
Oeffne title
Schliesse title
Oeffne meta
[...]
Leerer Tag meta
Schliesse head
```

flickr.com

```
<html>
<head>
    <meta http-equiv="[...]>
    <title>Welcome to Flickr [...]</title>
    <meta name="keywords" content="[...]">
[...]
<meta name="viewport" content="width=950"/>
</head>
```


Zusammenfassung

- XML zur Annotation von Text
- DTDs zum Validieren von XML-Dokumenten
- XML-Parsing
  - SAX-Parser
  - DOM
- HTML zur Formatierung von Text
- HTML vs. XML
- HTML-Parsing