


# Einführung in manuelles Webscraping mit dem Browser-Plugin *Scraper*



Agnes Brauer  
a.brauer@ub.uni-frankfurt.de

# Was ist Webscraping?

---

- Technik zur Extraktion von spezifischen Informationen aus Webseiten
- Überführung von unstrukturierten Daten in ein nutzbares, strukturiertes Format
- Anwendungsfälle:
  - Marktstudien (kommerziell)
  - Aggregation von Datensets für wissenschaftliche Fragestellungen / Auswertungen
  - Für Zwecke der Archivierung
  - ...

# Voraussetzung für viele Scraping-Techniken: XPath

- *XPath* ist eine Abfragesprache und dient der **Suche und Navigation** innerhalb von XML-Dokumenten
- XPath gehört zu den sogenannten X-Technologien und ist Bestandteil vieler Anwendungen
- *XPath*-Ausdrücke lokalisieren Teile eines XML-Dokuments und lesen ihre Eigenschaften aus
- XPath kann auch für XML-ähnliche Strukturen wie **HTML** verwendet werden
- diese Eigenschaft macht sich der Chrome Scraper zu Nutze

# XML- Basics

---

- XML-Dokumente haben eine Baumstruktur, die durch Knoten strukturiert sind:
  - Elemente
  - Attribute
  - Textknoten
- XML-Elemente haben öffnende und schließende Tags. Z.B.:  
`<head>Dies ist eine Überschrift</head>`
- XML-Tags sind case-sensitive, d.h.:  
`<head>` ist nicht gleich `<Head>`
- XML-Elemente müssen ordentlich geschachtelt sein, z.B.:  
`<beispiele>`
  - `<beispiel>Erstes Beispiel</beispiel>`
  - `<beispiel>Zweites Beispiel</beispiel>``</beispiele>`

# Aufbau eines XML-Dokuments

- XML-Deklaration: `<?xml version="1.0" encoding="UTF-8"?>`
- Wurzelement
- Elemente: `<head>` Dies ist eine Überschrift `</head>`
- Attribute: `<hi rend=„italic">` Dies ist eine kursive Hervorhebung `</hi>`
- `<!-- Kommentare -->`

```
<?xml version="1.0" encoding="UTF-8"?>
```

```
<TEI xmlns="http://www.tei-c.org/ns/1.0">
```

```
<fileDesc>
  <titleStmt>
    <title>TEI-Minimal-Beispiel</title>
  </titleStmt>
  <publicationStmt>
    <p>Frei verfügbar</p>
  </publicationStmt>
  <sourceDesc>
    <p>Dieser Text ist digital born.</p>
  </sourceDesc>
</fileDesc>
```

```
<!-- Ein XML Kommentar -->
```

```
<head>Minimalbeispiel</head>
```

```
<hi rend="italic">Textauszeichnung mit
TEI</hi>
```

```
</body>
</text>
</TEI>
```

# Beispiel einer HTML-Datei

---

```
<!DOCTYPE html>
<html xmlns="http://www.w3.org/1999/xhtml">
  <head>
    <meta charset="utf-8" />
    <title>HTML-Minimal-Beispiel</title>
  </head>
  <body>
    <h1>Beispieltext</h1>
    <p>Ein Beispieltext von <b>Agnes Brauer</b>
      <br/>für die Übung <i>Textauszeichnung mit TEI</i>.</p>
  </body>
</html>
```

# XPath

Beispiel für einen XPath:

/ html / body / h1

Knotentest  
(node test)

/ Pfadabschnitt  
(location step)




Abb.: <https://librarycarpentry.org/lc-webscraping/02-xpath/index.html>

# XPath - Grundlagen

---

- Ein XPath besteht aus einem oder mehreren **Pfadabschnitten** (location steps)
- die Pfadabschnitte bestehen aus einem Schrägstrich (/) und einem **Knotentest** (node test)
- dem Knotentest kann eine **Achse** (axis) vorangestellt werden
- die Ergebnismenge eines Pfadabschnitts kann durch **Bedingungen** (predicates) eingeschränkt werden
- der letzte angegebene Knotentest im XPath bestimmt den **Typ** des Ergebnisses

# XPath

---

## Knotentypen:

- **Element:** geprüft über **Knotennamen** oder **\*** (als Abkürzung für ein beliebiges Element)
- **Attribut:** geprüft über **@Knotennamen** oder **@\***
- **Text:** geprüft durch **text()**
- **Kommentar:** geprüft durch **comment()**

# Wichtige XPath-Achsen




Abb.: <https://librarycarpentry.org/lc-webscraping/02-xpath/index.html>

# Xpath-Achsen




Abb.: <https://librarycarpentry.org/lc-webscraping/02-xpath/index.html>

# XPath

---

## Wichtige Achsen:

self:: der aktuelle Kontextknoten (.)

child:: direkte Kindelemente ()

parent:: direkter Elternknoten (..)

ancestor:: alle Vorfahren

descendant:: alle Nachkommen (//)

preceding:: alle Knoten vorher

following:: alle Knoten nachher

following-sibling:: alle Geschwisterknoten nachher (gemeinsamer Elternknoten)

attribute:: alle Attribute (@)

# XPath: Wichtige Selektionen

- `nodename` selektiert Knotenpunkte des gleichen Namens
- `/` selektiert Kindknoten
- `//` Selektiert alle direkten und indirekten Childnodes (d.h. alle Nachfahren) → erlaubt ein (Über-)Springen
- `.` meint aktuell selektierten/s Element/Knoten (=Kontextknoten)
- `..` selektiert das Elternelement des aktuell gesuchten Elements
- `@` selektiert Attribute des Kontextknoten
- `[@attribute='value']` selektiert Elemente mit Attributen, die einen bestimmten Wert haben
- `text()` selektiert den Text eines Elements

Quelle: <https://librarycarpentry.org/lc-webscraping/02-xpath/index.html>

# XPath

---

## Ergebnisse einschränken:

- um eine bestimmte Einschränkung des Abfrageergebnisses zu erlangen, können sogenannte **Prädikate** verwendet werden
- hierbei handelt es sich um zusätzliche Bedingungen, die an den Knotentest geknüpft werden

Beispiel:

```
/ TEI / text / body / p / hi [@rend='italic']
```

Einschränkung  
predicate

# XPath - Funktionen

## Beispiele für die Verwendung von XPath-Funktionen:

```
/ TEI / text / body // head [starts-with(text(), 'Herz') ]
```

```
/ TEI / text / body // head / string-length()
```

```
/TEI/text/body//p[last()]
```

```
//p[ exists(./term)]
```

```
/ TEI / text / body //p [ not( exists(./ q ) ) ]
```

```
//p[1]/term/substring(text(), 1,6)
```

```
exists( //head [ . / parent::body ] )
```

```
/ TEI / text / body // div [ not( exists(./ head ) ) ]
```

# Links

---

<https://www.w3.org/TR/xpath-31/>

[https://www.w3schools.com/xml/xsl\\_functions.asp](https://www.w3schools.com/xml/xsl_functions.asp)

# Chrome Scraper

---

## Übung im Pad

# Chrome Scraper

---

## Übung

Extraktion von Informationen der Seite: <https://www.geschichtsquellen.de>


Schritt 1:

- Eingrenzen der Treffermenge:  
Suche > Erweiterte Suche > Filter Gattung = Chronologie → 30 Treffer

Schritt 2:

- Scrapen der Informationen:
  - Titel
  - Autor
  - Link zur ausführlichen Beschreibung

<trailer>Vielen Dank für Ihre Aufmerksamkeit!</trailer>



Workshop konzipiert in Anlehnung an [Library Carpentry: Introduction to web scraping.](#)