

# Informatik I: Einführung in die Programmierung

## 25. Das WWW befragen

Albert-Ludwigs-Universität Freiburg



Bernhard Nebel

20.01.2017

# 1 Motivation



Motivation  
Webseiten  
und HTML  
Das urllib-  
Paket

20.01.2017

B. Nebel – Info I

3 / 20

# Motivation



Motivation  
Webseiten  
und HTML  
Das urllib-  
Paket

- Oft braucht ein Programm Informationen, die es im **WWW** einfach zu finden gibt.
- Dazu müsste man bloß kurz eine Webseite aufrufen und ein Detail nachschlagen.
- Zum Beispiel wollen wir die **aktuelle Temperatur** wissen.
- Könnte das nicht ein kleines Skript für uns tun?
- Auf <http://www.wetteronline.de> findet man die aktuelle Temperatur ziemlich weit oben auf der Seite.
- **https:**  
[//en.wikipedia.org/wiki/How\\_Not\\_to\\_Be\\_Seen](https://en.wikipedia.org/wiki/How_Not_to_Be_Seen)  
zeigt Tipps, wie man sich unsichtbar machen kann.

20.01.2017

B. Nebel – Info I

4 / 20

# Der elektrische Mönch ...



Motivation  
Webseiten  
und HTML  
Das urllib-  
Paket

*Der Elektrische Mönch war ein Gerät zur Arbeitseinsparung wie ein Geschirrspüler oder ein Videorecorder. Geschirrspüler spülten für einen das langweilige Geschirr und ersparten einem so die Mühe, es selber spülen zu müssen; Videorecorder sahen sich für einen langweilige Fernsehprogramme an und ersparten einem so die Mühe, sie selber ansehen zu müssen; Elektrische Mönche glaubten für einen gewisse Dinge und ersparten einem damit, was allmählich zu einer immer beschwerlicheren Aufgabe wurde, nämlich alle Dinge zu glauben, die zu glauben die Welt von einem erwartete.*

[Douglas Adams: Der elektrische Mönch – Dirk Gentlys holistische Detekte]

20.01.2017

B. Nebel – Info I

5 / 20

- Alle Webseiten bestehen aus Texten (und Bildern) mit **HTML**-Formatanweisungen (*Hypertext markup language*).
- Die HTML-Anweisungen beschreiben, wie bestimmte Textteile **erscheinen** sollen.
- HTML-Formatanweisungen kommen normalerweise in **Paaren**, z.B. `<h1>` und `</h1>` für Überschriften.
- Generell wird eine öffnende Markierung `<mark>` durch eine schließende Markierung abgeschlossen: `</mark>`.
- Bei der öffnenden Markierung werden oft noch weitere Attribute angegeben, z.B. `<table border="2">`.
- Außerdem können die Dateien weitere Formatanweisungen (**CSS**) und aktive Komponenten (**Javascript**) enthalten.
- Eine gute Einführung findet sich z.B. auf <http://de.selfhtml.org/>.

### HTML page

```
<!DOCTYPE html> <!-- kann hier auch mehr stehen -->
<html> <!-- Jede HTML-Seite beginnt damit -->
<head> <!-- leitet Head-Sektion ein -->
<meta 'not to be seen'>
</head>
<body> <!-- hier nach folgt der Seitentext -->
... <!-- der verschiedene Markierungen nutzt -->
</body>
</html>
```

- Man kann sich den **Quellcode** der Webseite anschauen.
- Normalerweise findet man schnell ein **Pattern**, das zutreffend ist.
- Schauen wir uns den Quellcode der <http://www.wetteronline.de/freiburg>-Seite an.
- Seite anwählen, dann rechts klicken und **Quelltext anschauen** wählen; ggfs. Text vorher markieren.
- Nach dem Text **suchen**.
- Pattern konstruieren!

## Regulären Ausdruck konstruieren



- Am besten nach `id=...name` schauen, da diese eindeutig auf der HTML-Seite sind.
  - Bei uns ist die Zeile nach der folgenden Zeile **relevant**:  
`<li class="preload-current-weather"> ...`
  - **Möglicher** regulärer Ausdruck: `r'<span id="preload-text"><span id="aktuell">aktuell</span> (+)&deg;'`
  - ... zumindest solange sich nichts ändert ...
  - ... und die Temperaturen über Null liegen ...
  - Aber wie kommen wir an die **Webseite**?
- `urllib`

Motivation  
Webseiten  
und HTML  
Das urllib-  
Paket

## 3 Das urllib-Paket



- Webseiten laden
- Browser vortäuschen
- Zertifikate
- Web-Scraping

Motivation  
Webseiten  
und HTML  
Das urllib-  
Paket  
Webseiten laden  
Browser  
vortäuschen  
Zertifikate  
Web-Scraping

## Das urllib-Paket



- Das **urllib-Paket** bietet komfortable Schnittstellen, um auf Ressourcen im WWW zuzugreifen.
- Das Paket enthält mehrere Module:
  - `urllib.request`: Enthält Funktionen und Klassen zum Zugriff auf Ressourcen im Internet.
  - `urllib.parse`: Unterstützt das Parsen von URLs (*Universal Resource Locators*).
- Die wichtigsten Funktionen aus `urllib.request` ist:
  - `urlopen(url, data=None, timeout=*, *, cafile=None, capath=None, cadefault=False)`:  
Stellt ein Datei-ähnliches Objekt zur Verfügung. `url` ist die URL, auf die zugegriffen werden soll; `data` sind zusätzliche Daten, die bei einer Anfrage geschickt werden; `timeout` ist ein optionaler Parameter für eine obere Zeitschranke. Die anderen Parameter sind für Zertifikate (bei HTTPS).
  - Nach `urlopen` kann man auf dem resultierenden Objekt `read`-Methoden anwenden und erhält `bytes` zurück.

Motivation  
Webseiten  
und HTML  
Das urllib-  
Paket  
Webseiten laden  
Browser  
vortäuschen  
Zertifikate  
Web-Scraping

## Eine Webseite anschauen



```
wetter0.py
from urllib.request import urlopen

showlines = 10
remotefile = urlopen("http://www.wetteronline.de/")
# method to get info about connection
print(remotefile.info())
# read all lines
remotedata = remotefile.readlines()
remotefile.close()
for line in remotedata[:showlines]:
    print(line)
```

Motivation  
Webseiten  
und HTML  
Das urllib-  
Paket  
Webseiten laden  
Browser  
vortäuschen  
Zertifikate  
Web-Scraping

## Browser vortäuschen



- So funktionierte es jedenfalls vorletztes Jahr.
- Heute kommt eine Fehlermeldung "HTTP Error 403: Forbidden"
- Webseitenbetreiber mögen keine Zugriffe über Skripte (s.u.).
- Vortäuschung falscher Tatsachen:

Motivation  
Webseiten  
und HTML  
Das urllib-  
Paket  
Webseiten laden  
Browser  
vortäuschen  
Zertifikate  
Web-Scraping

```
wetter1.py
```

```
...  
from urllib.request import Request  
req = Request(url="http://www.wetteronline.de/",  
data=b'None',headers={'User-Agent':' Mozilla/5.0 \  
(Windows NT 6.1; WOW64; rv:12.0) Gecko/20100101 \  
Firefox/12.0'})  
remotefile = urlopen(req)  
...
```

- Das täuscht einen Firefox-Browser vor.

20.01.2017

B. Nebel – Info I

16 / 20

## Zertifizierung abschalten



- So funktionierte es jedenfalls letztes Jahr.
- Heute kommt (auf meinem Mac) die Fehlermeldung:  
urllib.error.URLError: <urlopen error [SSL:  
CERTIFICATE\_VERIFY\_FAILED] ...
- Hier fehlt ein Zertifikat (kann man aber wohl nachrüsten).
- Alternativ: Ohne Zertifikat

Motivation  
Webseiten  
und HTML  
Das urllib-  
Paket  
Webseiten laden  
Browser  
vortäuschen  
Zertifikate  
Web-Scraping

```
wetter2.py
```

```
...  
import ssl  
  
context = ssl._create_unverified_context()  
...  
remotefile = urlopen(req, context=context)  
...
```

20.01.2017

B. Nebel – Info I

17 / 20

## Die Temperatur checken



```
temperature.py
```

```
import re  
...  
  
remotedata = remotefile.read().decode('utf8')  
remotefile.close()  
rx = re.compile(r'<span id="preload-text">  
<span id="aktuell">aktuell</span> (-?\d*)&deg;',  
re.I+re.M)  
  
print("Die Temperatur beträgt zur Zeit",  
rx.search(remotedata).group(1),  
"Grad Celsius")
```

Motivation  
Webseiten  
und HTML  
Das urllib-  
Paket  
Webseiten laden  
Browser  
vortäuschen  
Zertifikate  
Web-Scraping

20.01.2017

B. Nebel – Info I

18 / 20

## Web-Scraping



- Auf diese Weise, die man *Scraping* nennt, kann man beliebige interessante Informationen von Webseiten sammeln und z.B. per E-Mail verschicken.
- Zum Beispiel: Was gibt es heute in der Mensa?
- Aber **Vorsicht**:
  - Webdesigner ändern gerne öfter mal das **Seitenlayout**.
  - Seitenbetreiber lieben das Scraping nicht, speziell wenn es zu **starker Belastung des Webservers** führt.
  - Das umfangreiche **Kopieren** und auf eigener Webseite zur Verfügung stellen ist im Übrigen Missbrauch!
  - Manchmal gibt es Maßnahmen gegen den Zugriff durch Skripte.
- Manche Seitenbetreiber bieten auch **Webservices** an, über die man dann per definierter Schnittstelle maschinenlesbar Daten bekommen kann (Beispiel: der Wetterservice [www.wunderground.com](http://www.wunderground.com)).

Motivation  
Webseiten  
und HTML  
Das urllib-  
Paket  
Webseiten laden  
Browser  
vortäuschen  
Zertifikate  
Web-Scraping

20.01.2017

B. Nebel – Info I

19 / 20

- Wir müssen nicht jede Webseite selbst lesen, speziell nicht wiederkehrende Aufrufe!
- Das Modul `urllib` erlaubt den Download von Webseiten.
- **Achtung:** Webseiten-Designer und Bereitsteller von Services lieben keine automatisierten Downloads:
  - Das **Scrapen** und **Bereitstellen** dieser Information ist (praktisch immer) illegal.
  - Das **Scrapen** für private Zwecke sollte nicht eine übermäßige Belastung des Servers auslösen!
  - Deshalb lehnen Webseiten bei automatisierten Klienten oft den Service ab.
- Bei `urllib` können wir einen Browser vortäuschen.
- Mit regulären Ausdrücken können wir meist den interessanten Teil von der Webseite extrahieren.
- **Alternativ:** Webservices nutzen!

Motivation

Webseiten  
und HTML

Das `urllib`-  
Paket

Webseiten laden

Browser  
vortäuschen

Zertifikate

Web-Scraping