Programmierkurs Python I

Stefan Thater & Michaela Regneri
Universität des Saarlandes
FR 4.7 Allgemeine Linguistik (Computerlinguistik)

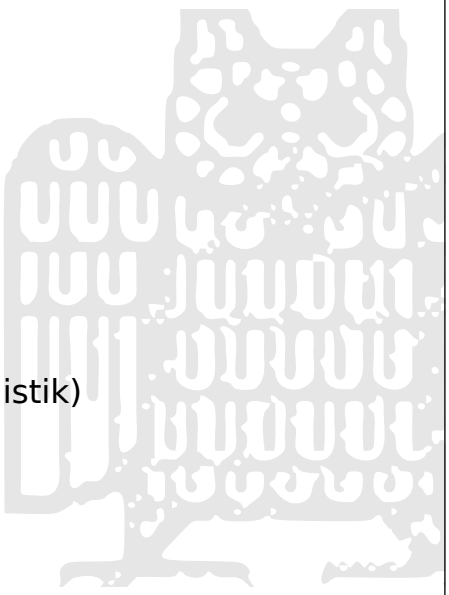

Übersicht

- Reguläre Ausdrücke
- Webseiten mit URLs auslesen

Reguläre Ausdrücke

- Reguläre Ausdrücke sind Suchmuster (Pattern) für Zeichenketten (Strings)
- „Matchen“ eines Reguläre Ausdrücks:
  Passt das Muster auf einen (Teil-) String?
- Weitere Operationen:
  - Ersetzen von Teilstrings in einem String
  - Zerlegen von Strings
  - Extraktion von Teilstrings

Reguläre Ausdrücke in Python

- Reguläre Ausdrücke sind nicht „fest eingebaut“ – um sie zu verwenden, muss das re-Modul importiert werden:

```
import re
```

- Keine eigene Syntax: Reguläre Ausdrücke werden als String-Literale aufgeschrieben
- Die einfachsten regulären Ausdrücke sind Strings - die matchen sich selbst
  - ‘a‘ matcht *a*
  - ‘hallo‘ matcht *hallo*

Reguläre Ausdrücke

- Im einfachsten Fall besteht ein regulärer Ausdruck aus einem normalen String
- Matchen von regulären Ausdrücken:
  - `re.match("fool", "foolish")` ⇒ Match-Objekt
  - `"fool"` – der reguläre Ausdruck
  - `"foolish"` – der String, auf den wir den regulären Ausdruck anwenden.
- Das Resultat ist ein Match-Objekt - oder `None`, wenn das Muster nicht passt. Über Match-Objekte kann man u.a. Teilstrings extrahieren (später mehr dazu).

Reguläre Ausdrücke in Python

- Der Standard-Weg, um in Python mit Regulären Ausdrücken zu arbeiten:
  - kompiliere den Ausdruck zu einem Pattern-Objekt
  - matche das Pattern mit einem Text (suche es im Text oder teste, ob der text dem Pattern entspricht)
  - Wenn der Abgleich erfolgreich war, kommt ein „Match-Objekt“ zurück, das Informationen über das Matching enthält
- Den Kompilier-Schritt muss man nicht explizit hinschreiben, es kann aber praktischer und effizienter sein (später mehr)

Reguläre Ausdrücke in Python

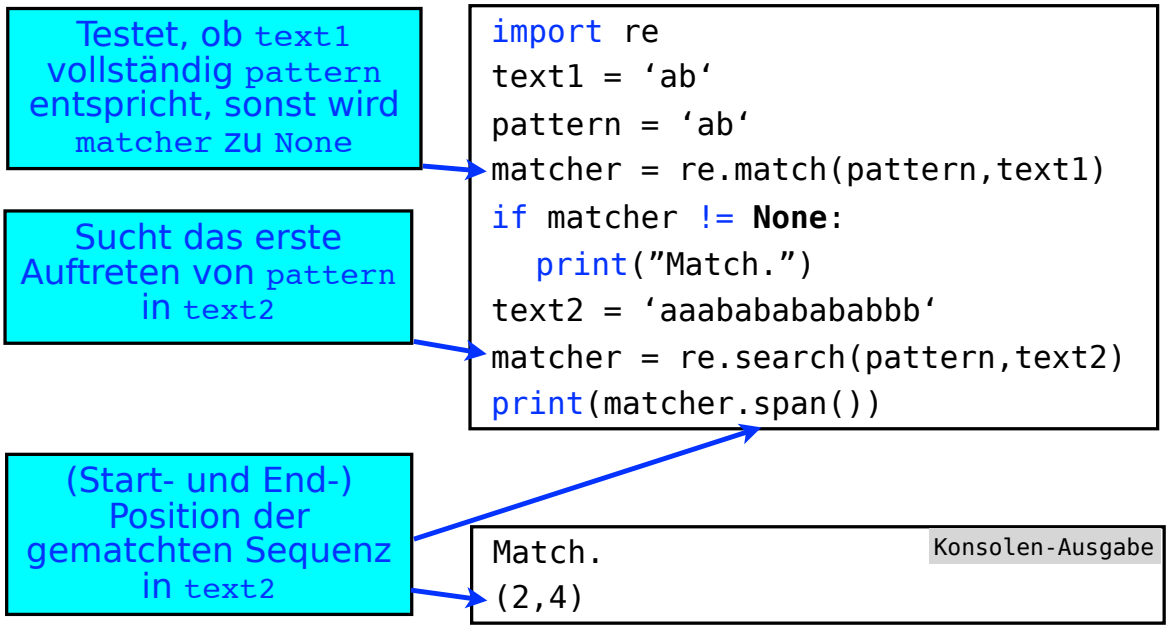

match & search

- `re.match(pattern, string)` ist erfolgreich, wenn `pattern` auf den Anfang von `string` matcht.
- `re.search(pattern, string)` ist erfolgreich, wenn `pattern` auf einen beliebigen Teilstring von `string` matcht
- beide geben Objekte vom Typ `MatchObject` zurück; das `MatchObject` von `re.search` entspricht dem ersten gefundenen Match

Funktionszeichen (Meta-Characters)

- Die meisten Zeichen in einem regulären Ausdruck matchen auf sich selbst
  - Groß- und Kleinschreibung wird unterschieden
  - Folgende Funktionszeichen haben eine besondere Bedeutung: `. ^ $ * + ? { [ ] \ | ( )`
- Maskierungszeichen (Escape Character): Wenn man ein Funktionszeichen als normales Zeichen („wörtlich“) verwenden möchte: Backslash als Präfix

„Raw String“ Notation

- Der Backslash ist Maskierungszeichen sowohl für Strings als auch für reguläre Ausdrücke
- Da reguläre Ausdrücke als Strings kodiert werden, führt dies schnell zu einer „Backslash-Plage“
  - Zeichenkette in einer Datei: `\section`
  - Als Python-String: `"\\section"`
  - Als regulärer Ausdruck: `"\\\\section"`
- Alternative String-Notation: `r"raw strings"`
  - Der Backslash wird einfach als Zeichen betrachtet
  - Zum Beispiel: `r"\section"`

Zeichenklassen (Character classes)

- Mit [und] kann man Zeichenklassen spezifizieren; sie matchen auf jedes Zeichen in der Klasse
  - `[abc]` match `'a'`, `'b'` oder `'c'`
  - `[a-z]` matcht alle Kleinbuchstaben (keine Umlaute)
- Funktionszeichen (modulo Backslash) verlieren in Zeichenklassen ihre Sonderbedeutung:
  - `[ab$]` matcht 'a', 'b' oder '$'
- Komplementieren: `[^abc]` matcht alle Zeichen, die nicht in der Klasse `[abc]` sind

Zeichenklassen (Character classes)

- Einige vordefinierte Zeichenklassen:
  - `\d = [0-9]` `\D = [^0-9]`
  - `\s = [ \t\n\r\f\v]` `\S = [^ \t\n\r\f\v]`
  - `\w =(Buchstaben +\d +_)` `\W = (der Rest)`
- Der Punkt . matcht normalerweise alles bis auf das Zeichen für den Zeilenumbruch (Newline, `\n`)

Quantoren

- Mit dem *-Operator matcht man den vorhergehenden Ausdruck beliebig oft
  - `[ab]*` matcht `'ac'`, `'aabac'`, `'c'`, etc.
- Weitere Quantoren:
  - `a+` (mindestens einmal)
  - `a?` (höchstens einmal)
  - `a{m,n}` (mindestens m, höchstens n mal)
- Der Quantor bezieht sich auf den unmittelbar vorhergeheden Ausdruck:
  - `ab*c` matcht `'abbc'`, aber nicht `'ababc'`
  - `(ab)*c` matcht `'ababc'`, aber nicht `'abbc'`

Weitere Operatoren

- `a|b` matcht a oder b
  - `(ver|ent|be)sorg(en|t|te)` – versorgen, versorgte, besorgen, besorgt, ...
- `^`, `$` matchen den Zeilenanfang bzw. das Zeilenende
- `\A`, `\Z` matchen den Anfang bzw. das Ende des Strings
  - `\A[abc]*\Z` matcht alle Strings, die aus beliebigen Kombinationen von `'a'`, `'b'` und `'c'` bestehen
- `\b` matcht Wortgrenzen:
  - `class\b.*` matcht `'class next Friday'`
  - `class\b.*` matcht nicht `'classified'`

Übung – Wer matcht was?

(1) abc

(2) ac

(3) abbb

(4) bbc

(5) aabcd

(6) b

(1) ab+c?

(2) a?b*c

(3) b+c*

(4) ^b+c*$

(5) a.+b?c

(6) b{2,}c?

(7) ^a{1,2}b+.?d*

Was matcht a(ab)*a?

(1) abababa

(2) aaba

(3) aabbaa

(4) aba

(5) aabababa

Gruppierungen

- Mit Klammern kann man reguläre Ausdrücke gruppieren
- Ausserdem kann man auf die Gruppe später über das Match-Objekt auf den gematchten Teilstring zugreifen:

```
mo = re.search(r'"(\d+)"', 'price="123"')
mo.groups() ⇒ ('123',)
mo.group(1) ⇒ '123'
```

`group(0) == group()`
– der vollständige Treffer-String

- Named Groups:

```
mo = re.search(r'"(?P<price>\d+)"', 'price="123"')
mo.groupdict() ⇒ { 'price': '123' }
```


Match-Objekte: Weitere Methoden

- `MatchObject.start([`*group*`])`
  Position im String, an der die Gruppe group beginnt.
- `MatchObject.end([`*group*`])`
  Position im String, an der die Gruppe group endet.
- MatchObject.span([*group*])
  Paar aus Beginn und Ende der Gruppe (Positionen)

„Greedy“ quantifiers
(„gierige Quantoren“)

- Vorsicht beim Verwenden von Quantoren in Gruppen: Quantoren matchen den langstmöglichen Teilstring!

```
mo = re.search('"(.*)"', 'price="123" art="ball"')
mo.group(1) ⇒ '123" art="ball'
```

- Mit einem nachgestellten ? ändert man das:

```
mo = re.search('"(.*?)"', 'price="123" art="ball"')
mo.group(1) ⇒ '123'
```


Non-Capturing Groups & Lookaheads

- Wenn man nur den regulären Ausdrück klammern möchte:

```
mo = re.match('(?:abc)+', 'abcabc')
mo.groups ⇒ ()
```

- Positiver Lookahead: matcht den regulären Ausdruck, ohne Teile der Eingabe zu konsumieren

```
mo = re.match('(.*)(?=(abc))(.*)', 'abcabc')
mo.groups ⇒ ('abc', 'abc', 'abc')
```

- Negativer Lookahead: `(?!a)`, a darf nicht matchen

Weitere Funktionen

- `re.findall(pattern, string)` – suchte alle nicht-überlappenden matchenden Teilstrings in `string` `(Rückgabe: Liste von Strings / Tupeln)`
- `re.finditer(pattern,string)`: wie findall; gibt iterierbares Objekt zurück, ein Sammelobjekt mit Match-Objekten
- `re.split(pattern, string)` – Zerlegt `string` in Teilstrings an Stellen, an denen `pattern` matcht
- `re.sub(pattern, repl, string)` – ersetzt alle matchenden Teilstrings in `string` durch `repl`

Optionen beim Matchen

- Man kann das Verhalten von re.match etc. durch Optionen modifizieren:
  - `re.IGNORECASE` – Groß/Kleinschreibung ignorieren
  - `re.MULTILINE` – `^`, `$` matchen den Anfang bzw. das Ende jeder Zeile im String.
  - `re.DOTALL` – . matcht auch den Zeilenumbruch (\n)
- Für mehrere Flags: kombination mit „|“ (bit-weises oder)

```
flag = re.DOTALL | re.IGNORECASE
mo = re.match('a.b', 'aA\nb',flag)
print(mo.group())
```

Konsolen-Ausgabe

```
A
b
```

Pattern kompilieren

- Wenn man das Pattern vorher kompilieren will, verändert sich die Benutzung von Match / Search:
  - `re.compile(str)` erzeugt ein Objekt vom Typ `re.RegexObject`
  - `re.RegexObject` implementiert alle Such-/ Matchfunktionen aus re (`match, search, findall`,...) mit gleichem Rückgabetyp
- Flags werden ggf. schon beim Kompilieren mitgegeben: `re.compile(str,flag)` produziert ein `RegexObject`, das nur mit den Bedingungen von `flag` sucht / matcht

Pattern kompilieren

- Wenn man das gleiche Pattern mehrmals braucht, ist es viel effizienter, es einmal zu kompilieren und dann mit dem `RegexObject` weiter zu arbeiten
- außerdem sind `search` und `match` hier flexibler:
  - `RegexObject.match(str, [start, [end]])` matcht den String von Position `start` bis `end` (wenn `end` fehlt, bis zu Ende)
  - `RegexObject.search(str, [start, [end]])` `search` und `RegexObject.findall(str,[start, [end]])` funktionieren analog

Pattern kompilieren

```
import re
pattern = re.compile(‘a.?b‘, re.DOTALL | re.IGNORECASE)
matcher1 = pattern.match(‘A\nb‘)
matcher2 = pattern.search(‘aaba‘)
matcher3 = pattern.match(‘aaba‘, 1, 4)
matcher4 = pattern.search(‘abA?BaB‘, 3)
```

```
matcher.group() ⇒ ?
```


Mehr zu regulären Ausdrücken

http://docs.python.org/3.1/library/re.html

http://docs.python.org/howto/regex.html

Reguläre Ausdrücke & Unicode

- Unicode ist Standard in regulären Ausdrücken
- \w z.b. matcht alle Buchstaben aus egal-welchem in Unicode repräsentierten Alphabet
- man kann explizit angeben, kein Unicode benutzen zu wollen, mit re.ASCII (und ggf. re.LOCALE):
  `re.findall('(\w+)', 'Hällo, Wörld!', re.ASCII)`

```
> re.findall('(\w+)', 'Hällo, Wörld!')
['Hällo', 'Wörld']

> re.findall('(\w+)', 'Hällo, Wörld!', re.ASCII)
['H', 'llo', 'W', 'rld']
```


UTF-8 – Achtung!

- Wenn man mit UTF8-kodierten Bytestrings arbeitet, muss man beachten, dass Zeichen mit Code-Point ≥ 128 durch eine variable Anzahl von Bytes repräsentiert werden
  - len("Hällo") ⇒ 5
  - len("Hällo".encode("utf-8")) ⇒ 6
  - "Hällo"[:2] ⇒ "Hä"
  - "Hällo"[:2].encode("utf-8") ⇒ b'H\xc3\xa4'
- Beim Verwenden regulärer Ausdrücke sollte generell mit Unicode-Strings gearbeitet werden

Ein- und Ausgabe: URLs

- `urllib.request` erlaubt das öffnen von URLs
- (den Quelltext von) Webseiten auslesen funktioniert ähnlich wie Dateien auslesen:

```
import urllib.request as url
hp = 'http://www.coli.uni-saarland.de'
for line in url.urlopen(hp):
    print(line)
```

- die von urlopen erzeugten Objekte unterstützen als Lesemethoden `read()` und `readlines()`
- Webseite in lokale Datei kopieren:

```
[...]
url.urlretrieve(hp, 'dateiname.html')
```


Mehr zu URLs

- Nicht alle URLs erlauben jeden automatischen Zugriff
- Manchmal braucht man kompliziertere Operationen als nur öffnen (Formulare,...)
- dafür gibt es in `urrllib.request` (u.a.) die Klassen URLOpener und `Request`
  - `Request` kann detaillierte Informationen beim Öffnen der Webseite mitschicken (wie den Namen des Programms, das die Webseite gerade öffnet)
  - URLOpener führet den komplexen `Request` aus

(Etwas) mehr zu URLs

ein Beispiel:

```
import urllib.reqeust as url

req = url.Request('http://www.google.com/search?q=hallo')
browser = 'Mozilla/4.0 (compatible; MSIE 6.0; Windows NT 5.0)'
req.add_header('User-Agent', browser)

opener = url.build_opener()

for line in opener.open(req):
    print(line)
```

Anfrage, die so tut, als käme sie von Mozilla

Der eigentliche „Browser“, der die Anfrage ausführt

Achtung - Byte-Strings!

Einfache „Web-Linguistik“ in Python

- automatisches Ermitteln von Google-Trefferzahlen
- Finde die URL, mit der man auf Suchergebnisse zugreift
- Finde einen regulären Ausdruck, der genau die Trefferanzahl matcht

Results **1** - **10** of about **133,000,000** for **hallo**. (**0.11** seconds)

```
Results <b>1</b> - <b>10</b> of about <b>133,000,000</b>
for <b>hallo</b>.  (<b>0.11</b> seconds)
```

Einfache „Web-Linguistik“ in Python

```
# *-* coding:utf-8 *-*
import urllib.reqeust as url
import re

req = url.Request('http://www.google.com/search?q=hallo')
browser = 'Mozilla/4.0 (compatible; MSIE 6.0; Windows NT 5.0)'
req.add_header('User-Agent', browser)

opener = url.build_opener()
pattern = re.compile('of about..b\W((\d+\W)*(\d+)).+b')

for line in opener.open(req):
  matcher = pattern.search(str(line))
  if matcher != None:
       print(matcher.group(1))
```

Pseudo-Mozilla-Browser

reg. Ausdruck für den String, der die Trefferzahl enthaelt

Byte-Strings! :-)

Übung 1: Bigramme

```
door nail: 3
a  door:   3
was as  :  2
in the  :  2
dead  as : 2
...
```

```
   MARLEY was dead: to begin with. There is no do
whatever about that. The register of his burial was
signed by the clergyman, the clerk, the undertaker,
and the chief mourner. Scrooge signed it: and
Scrooge's name was good upon 'Change, for anything he
chose to put his hand to. Old Marley was as dead as a
door-nail.
Mind! I don't mean to say that I know, of my
own knowledge, what there is particularly dead about
a door-nail. I might have been inclined, myself, to
regard a coffin-nail as the deadest piece of
ironmongery
in the trade. But the wisdom of our ancestors
is in the simile; and my unhallowed hands
shall not disturb it, or the Country's done for. You
will therefore permit me to repeat, emphatically,
that Marley was as dead as a door-nail.
```

Übung 2: Web Crawler

Übung 2: Web Crawler

```
<TD VALIGN="MIDDLE" height="18"><img src="dot.gif">
<a href="http://www.lepetitprince.com/"><b>Official Website</b></a> - The
'official' Little Prince website.</TD> </TR>

<TR><TD VALIGN="MIDDLE" height="18"><img src="dot.gif">
<a href="http://www.elprincipito.es/"><b>Julians Page</b></a> - Julian,
one of my fellow collectors, presents his own site. Very good work!</
TD></TR>

<TR><TD VALIGN="MIDDLE" height="18"><img src="dot.gif">
<a href="http://www.elpetitprincep.eu/"><b>Jaume Arbonès</b></a> -
Beautiful and comprehensive page!</TD></TR>

<TR> <TD VALIGN="MIDDLE" height="18"><img src="dot.gif">
<a href="http://www.fotodesignerin.de/prinz/"><b>Michaels Site</b></a> -
Very detailed site with lots of background information.</TD></TR>
```

Übung 2: Web Crawler