

TDP001 - Handhavande av datormiljö

Pontus Haglund Emma Enocksson

Institutionen för datavetenskap

Översikt

- Introduktion
- Syntax
- Användning i Python

Introduktion

- Reguljära uttryck används för att matcha ett mönster (pattern) mot en text.
- Kallas ofta regex eller regexp (från regular expression)
- Skapades på 50-talet och finns tillgängligt i de flesta språk.
- Ett väldigt bra verktyg som kan användas till mycket.

Syntax

Ett tecken matchar sig själv

Mönster:	a	han	kul
Söksträng:	a anna	han hon hanna	kul kulle ful

Syntax

Med hakparenteser ([]) skapas en teckenklass

En teckenklass matchar ett av tecknen innanför hakarna

Mönster: `a[ab]c`

Söksträng: `abc` `aac` `acabca`

Syntax

Teckenklasser

Man kan även sätta ett intervall inom hakparenteser

Mönster: `a[a-c]c`

Söksträng: `abc` `aac` `acc`

Syntax

Med cirkumflex (^) tar du inversen av en teckenklass

Man matchar då alla tecken utom den givna teckenklassen

Mönster: `a[^ab]c`

Söksträng: `adc aqc aaca`

Syntax

Med lodstreck (|) anger du ett logiskt ELLER

Mönster:	a c	aa ab
Söksträng:	abc	acaab abc

Syntax

Vanliga parenteser skapar en "grupp"

Grupper kan användas för att ändra operatorers räckvidd och prioritering

Mönster: `a(aa|ab)c`

Söksträng: `aabc` `aaac` `acaabca`

Syntax

Upprepningar

Följande operatorer skrivs direkt efter det som ska upprepas.

? Matchar 0 eller 1

* Matchar 0 eller flera

+ Matchar minst 1

Mönster:	colou?r	a[nl]+a	S(oe? ö)der
Söksträng:	color colour	anna alla	Söder Soder

Syntax

Upprepningar

- Med klammerparenteser ({ }) upprepar man saker ett visst antal gånger.
- $x\{n, m\}$ matchar x upprepat n till m gånger.
- Precis som i Python kan man utelämna m

Mönster:	$[0-9]\{2, 3\}$	$[a-zA-Z]\{5\}$	$[a-zA-Z]\{4, \}$
Söksträng:	17a 5262	Linköping	Linköpings Universitet

Syntax

Speciella teckensekvenser

Teckensekvens	Motsvarighet
\w	[A-Za-z0-9_]
\W	[^A-Za-z0-9_]
\s	Vita tecken
\S	Inte vita tecken
\d	[0-9]
\D	[^0-9]

Mönster: \d+

Söksträng: 123a

Syntax

Bakåtreferenser

Alla grupper tilldelas ett nummer (indexeras från 0). Med \N refererar man tillbaka till grupp nummer N.

Mönster: `(\d)a\0`

Söksträng: `0a0 1a6 4a4`

Syntax

Några speciella tecken

Följande tecken har speciell betydelse:

Tecken	Matchar
.	Valfritt tecken (utom newline)
^	Början av rad
\$	Slut på rad eller fil

Mönster:	^ka..e\$ ^ka..e\$
Söksträng:	kalle kalle svensson

Syntax

Escapesekvenser

För att matcha någon av de speciella tecken (metatecken) som nämnts tidigare (`{ } [ ] ( ) ^ $ . | * + ? \`) används ett backslash:

Mönster:	<code>\d\.\d</code>	<code>\\a</code>	<code>\{\w+\}</code>
Söksträng:	<code>1.2 4a4</code>	<code>\\a</code>	<code>{hej}</code>

Användning i Python

- Python har, med stöd av sitt stora bibliotek, så klart stöd för regex.
- Importera bara modulen re!

<http://docs.python.org/3/library/re.html>

Användning i Python

- `re` har tre vanligt använda funktioner (och så klart fler):
 - `re.match(pat, str)` Söker efter mönstret `pat` i början av strängen `str`
 - `re.search(pat, str)` Söker efter första förekomsten av mönstret `pat` i strängen `str`
 - `re.findall(pat, str)` Hittar alla förekomster av mönstret `pat` i strängen `str`
- De två första ger ett "match object" vid matchning, annars `None`. `findall` ger en lista av matchande strängar.

Användning i Python

```
import re
val = input('Mata in ett heltal: ')
while re.match('[0-9]+$', val) is None:
    val = input('Felaktig inmatning, nytt heltal: ')

val = int(val)
```

Användning i Python

Det finns ett problem med reguljära uttryck... backslash!

Backslash används ju redan för escapesekvenser i Python. Tänk er att vi ska söka efter texten `\begin`. Då måste vi skriva såhär:

```
import re  
match = re.search('\\\\\\begin', str)
```

Vi vill söka efter ett `\`, då behövs ett extra enligt regex-syntax samt ett extra för varje backslash för att inte Python ska tolka det som en escapesekvens!

Användning i Python

Detta problem löses lättast med "råasträngar (raw string)

```
import re  
match = re.search(r'\\begin', str)
```

Användning i Python

Match objects

Grupper i mönstret kan tas fram i efterhand med funktionen `group`:

```
import re
match = re.search(r'(\d+) (\w+)', str)
if match is not None:
    print(match.group(0)) # Skriver ut hela matchningen
    print(match.group(1)) # Skriver ut första gruppen
    print(match.group(2))
```

Om en grupp var valbar (hade ett frågetecken) kan den ha värdet `None`.

Användning i Python

findall

```
>>> str="""En sträng som ibland har heltal i sig: 12345  
... Den kan vara lite 2313 olika lång. Denna sträng  
... är 3 rader lång!"""  
  
>>> lst = re.findall(r'\d+', str)  
['12345', '2313', '3']
```

www.liu.se