

Övning 5 - Tillämpad datalogi 2012

```
0 # coding: latin
```


Automater, reguljära uttryck, syntax

1. Sammanfattning

Idag gick vi igenom **automater**, **reguljära uttryck** och **syntax**. Vi exemplifierade detta genom att lösa 5 uppgifter. Vi tittade på hur next vektorn i en KMP automat byggs up, hur reguljära uttryck kan skapas och tolkas samt vi felsökte 4 olika syntax grammatiker och skapade fär egna grammatik för att kolla om en websida är rätt skriven.

1. Abrakadabra

Konstruera en KMP-automat som söker efter texten ABRAKADABRA. Ange även den next-vektor som definierar automaten. **Ungefär hur många jämförelser behövs för att automaten ska se att ordet inte finns med i "Harry Potter och Fenixorden", en bok på 1.8 MB?**




i	1	2	3	4	5	6	7	8	9	10	11
$\text{next}(i)$	0	1	1	0	2	0	2	0	1	1	0

KMP-sökning tar $n + m$ jämförelser, där m är antal tecken i söksträngen och n är antal tecken i texten. ASCII kod kräver en byte, vanligtvis 8 bits där en bit kan ta värdet 0 eller 1).

För varje tecken så vi får alltså $1.8 \text{ miljoner} + 11$ (alt. med bas två definitionen av en megabyte som då är $2^{20} = 1048576$ bytes så att vi får $1.8 * 2^{20} + 11 = 1887437 + 11$ jämförelser.

2. Värstingvrålsautomat (Tildatenta 000831)

Skriv en KMP-automat som söker efter OHOJ-OHOJ! i en texfil med nedtecknade värstingvrål från en vitmaktskonsert. Ange också den next-vektor som definierar automaten.



i	1	2	3	4	5	6	7	8	9	10
$\text{next}(i)$	0	1	0	2	1	0	1	0	2	5

Example regular expression

For example, `ca*t` will match `ct` (0 a characters), `cat` (1 a), `caaat` (3 a characters), and so forth.

A step-by-step example will make this more obvious. Let's consider the expression `a[bcd]*b`. This matches the letter 'a', zero or more letters from the class `[bcd]`, and finally ends with a 'b'. Now imagine matching this RE against the string `abcbd`.

Step	Matched	Explanation
1	<code>a</code>	The <code>a</code> in RE matches
2	<code>abcbd</code>	The engine matches <code>[bcd]*</code> , going as far as it can but the current position is to the end of the string.
3	<i>Failure</i>	The engine tries to match <code>b</code> , but the current position is at the end of the string so it fails
4	<code>abcb</code>	Back up so that <code>[bcd]*</code> matches one less character
5	<i>Failure</i>	Try <code>b</code> again, but the current position is at the last character, which is 'd'
6	<code>abc</code>	Back up again, so that <code>[bcd]*</code> only matches <code>bc</code>
7	<code>abcb</code>	Try <code>b</code> again. This time the character at the current position is 'b', so it succeeds.

<http://docs.python.org/howto/regex.html#regex-howto>

```

94
95 import re
96 pattern="a[bcd]*b"
97 sometext="abcbd"
98 print re.findall(pattern, sometext)

[ 'abcb' ]

```

3. Regexp

a) Givet det reguljära uttrycket

$s(a|o)nd-?l\ddot{a}da$

Skriv upp tre strängar som matchas av det reguljära uttrycket och ett som inte gör det.

b) Söka efter Kronskog. Skriv ett reguljärt uttryck som matchar alla tänkbara -bara sätt att stava namnet Kronskog (Crounskog, Krohnskoog, etc).

1. sandlåda, sand-låda, sondlåda men inte syndlåda

2.

i) 'C' eller 'K' $\Rightarrow$ [CK]

ii) alltid ro $\Rightarrow$ ro

iii) eventuellt flöljt av ett u $\Rightarrow$ u?

iv) eventuellt flöljt av ett h $\Rightarrow$ h?

v) sen alltid 'nsko' $\Rightarrow$ nsko

vi) eventuellt flöljt av ett 'o' $\Rightarrow$ o?

vii) och alltid 'g' på slutet $\Rightarrow$ h?

Det ger oss det reguljära uttrycket [CK]rou?h?nskoo?g Observera att [CK]ro[uh]?nskoo?g ($\Rightarrow$ Kouhuhuhnskog), dvs multipla uh

Metatecken	Beskrivning
.	matchar <i>ett tecken</i> , vilket som helst (utom radslut)
X?	matchar noll eller X
X*	matchar noll eller flera X
X+	matchar en eller flera X
X _{m,n}	matchar <i>m</i> till <i>n</i> st X (utökat)
[]	matchar ett av tecknen inom klammrarna
^	matchar matchar början på rad
[^]	matchar uttrycket X eller uttrycket Y
&	matchar slutet på en rad
X Y	matchar uttrycket X eller uttrycket Y
\.	matchar en punkt. ("escape:a metatecken")
()	skapar en grupp
\n	refererar n:te gruppen (0-9)

Extra

Vad matchar det reguljära uttrycket?: $(bb|[^b]{2})$

bb eller två karaktärer som inte är b

```

157
158 import re
159 pattern="(bb|[^b]{2})"
160 sometext="bbbbaa"
161 # Findall returns a, returns a tuple with as many elements as there is
162 # groups. Each tuple is all the matches from a group. You can have
163 # groups within groups. Then first the main group is evaluated
164 # following the the smaller sub groups.
165 print re.findall(pattern, sometext)
```

```
['bb', 'bb', 'aa']
```

```

166
167 sometext="ac3adg2"
```

```
168 print re.findall(pattern, sometext)
```

```
['ac', '3a', 'dg']
```

Vad matchar det reguljära uttrycket?: $(b+(ab*ab*))$

Yttre grupp $b+(ab*ab*)$: ett eller flera b plus match inre grupp Inre grupp $ab*ab*$: a följt av noll eller flera b följ av a och noll eller flera b

```
175 import re
176 pattern="(b+(ab*ab*))"
177 sometext="bbbabbabaa"
178 print re.findall(pattern, sometext)
```

```
[('bbbabbab', 'abbab')]
```

Vad matchar det reguljära uttrycket?: $(.*) are(*)$

```
182 line = "Cats are smarter than dogs";
```

Först vilket ord som helst $'(.*)'$ följt av $'are'$ följt av noll eller flera punkter $(*)$.

```
185 # With search one can access the group results individually
186 matchObj = re.search( r'((.*) are(\\.*))', line)
187
188 if matchObj:
189     print "matchObj.group() : ", matchObj.group()
190     print "matchObj.group(1) : ", matchObj.group(1)
191     print "matchObj.group(2) : ", matchObj.group(2)
192
193 else:
194     print "No match!!"
```

```
matchObj.group() : Cats are
matchObj.group(1) : Cats are
matchObj.group(2) : Cats
```


```
197
198 print re.findall('((.*) are(\\.*))', line)
```

```
[('Cats are', 'Cats', '')]
```

Alternativ 3 godkänner felaktigt
Kanot och kanot 2

Exempel på syntaxträd:

Mening at parse: Kanot 42, kanot 4711 och kanot 17 ska in!




Utmaningen är att skriva ett program som **rekursivt** kan bygga trädet och identifiera att varje löv är ok.

Grammatik:

$\langle \text{meddelande} \rangle ::= \text{Kanot } \langle \text{tal} \rangle \langle \text{svans} \rangle \mid$
 $\quad \langle \text{meddelande} \rangle \text{ kanot } \langle \text{tal} \rangle \langle \text{svans} \rangle$
 $\langle \text{svant} \rangle ::= \text{och} \mid \text{ska in!} \mid ,$
 $\langle \text{tal} \rangle ::= 1 \mid 2 \mid 3 \dots$

Mening at parse: Kanot 42 och kanot 4711 ska in! kanot 17,



Felaktig mening som grammatiken godkänner

Grammatik:

$\langle \text{meddelande} \rangle ::= \text{Kanot } \langle \text{tal} \rangle \langle \text{svans} \rangle \mid$
 $\quad \langle \text{meddelande} \rangle \text{ kanot } \langle \text{tal} \rangle \langle \text{svans} \rangle$
 $\langle \text{svant} \rangle ::= \text{och} \mid \text{ska in!},$
 $\langle \text{tal} \rangle ::= 1 \mid 2 \mid 3 \dots$

5. Värsta webbsyntaxen (Tildatenta 000831)

En webbfil innehåller dels webbsidans text, dels taggar för radbrytningar och indragningar. Taggen `<BR>` ger ny rad och för att få indragning av ett textavsnitt skriver man taggen `<Q>` före och taggen `</Q>` efter. Exempelvis ger webbfilen Organismer `<BR>` `<Q>` Djur `<BR>` `<Q>` Flugor `<BR>` Sillar `<BR>` `</Q>` Svamp `<BR>` `<Q>` Flugsvamp `<BR>` Sillkremla `<BR>` `</Q>` `</Q>` följande webbsideutseende:

```
Organismer
Djur
Flugor
Sillar
Svamp
Flugsvamp
Sillkremla
```

Skriv en syntax för webbfiler där endast dessa taggar och vanlig text före- kommer. Du kan få använda `<text>` för att beteckna godtycklig taggfri text.

Låt os skriva om det: **websida1**=

```
Organismer <BR> <Q>
Djur <BR> <Q> Flugor <BR> Sillar <BR> </Q>
Svamp <BR> <Q> Flugsvamp <BR> Sillkremla <BR> </Q>
</Q>
```

Men detta är också en websida:

```
websida2=
Djur <BR> <Q> Flugor <BR> Sillar <BR> </Q>
Svamp <BR> <Q> Flugsvamp <BR> Sillkremla <BR> </Q>
```

Så vi kan egentligen skriva **websida1** som Organismer `<BR>` `<Q>` **websida2** `</Q>`. Så texten mellan `<Q>` och `</Q>` är också en websida. Vi får regeln.

(1) **websida**=`<Q>` websida `</Q>`

Två triviala hemsidor är en **tom** och endast en **text**, så vi behöver att grammatiken godkänner dessa två alternativ.

(2) **websida**=**tom**

(3) **websida**=**text**

Slutligen observerar vi att om **organismer** är en websida och `<Q>` **Djur** `<BR>` `<Q>` **Flugor** `<BR>` **Sillar** `<BR>` `</Q>` **Svamp** `<BR>` `<Q>` **Flugsvamp** `<BR>` **Sillkremla** `<BR>` `</Q>` `</Q>` är en websida enligt (1) så får vi att **websida** `<BR>` **websida** är en websida. Det ger oss regeln:

(4) **websida**=**websida** `<BR>` **websida**

Den resulterande grammatiken blir:

```
<wpage> ::= <nothing>
          | <text>
          | <Q><wpage></Q>
          | <wpage><BR><wpage>
<Q> ::= "<Q>"
</Q> ::= "</Q>"
<BR> ::= "<BR>"
```