

DD1360 Programmeringsparadigm: Artificiella språk och syntaxanalys, föreläsning 1

Karl Palmskog

KTH

Måndag 27 Februari, 2023

① Introduktion

② Artificiella språk

③ Reguljära uttryck

④ Ändliga automater

① Introduktion

② Artificiella språk

③ Reguljära uttryck

④ Ändliga automater

Om mig

- Tekn. dr., KTH, 2014; postdoktor/forskare 2015-2021
- Adjunkt, KTH, 2021-
- Forskar inom:
 - programverifiering och bevisteknik
 - distribuerade system (t ex blockkedjor)
- Undervisar även inom:
 - parallella och distribuerade system
 - programvarukonstruktion
- Kontaktinformation finns i kurskatalogen, men använd gärna forumet på Canvas för generella frågor

Syntaxdelen i kursen

- Teoretiskt verktygslåda för strängmatchning
 - Reguljära uttryck och reguljära språk
 - Grammatiker
 - Språkklasser, leder till algoritmteori
- Praktisk tillämpning av verktygslådan
 - Lexikal analys för programspråk
 - Syntaktisk analys för programspråk
 - Leder till konstruktion av parsers

Kursbok för syntaxdelen

- **Introduction to Automata Theory, Languages, and Computation**
 - Hopcroft, Motwani, Ullman
 - 3rd Edition, Pearson, 2006
 - <http://www-db.stanford.edu/~ullman/ialc.html>
- Slides är fristående från boken, men följer bokens ansatser
- Syntaxordlista och läsanvisningar för boken finns på Canvas
 - bara vissa delar av boken ingår (t ex inte algoritmer och bevis)
 - vissa räkneuppgifter i boken ej relevanta för kursen ...
 - ... men kan hjälpa förståelse
- Andra liknande böcker går att använda
 - ex **Compilers: Principles, Techniques, and Tools**, 2nd Ed
 - tänk på avvikelser i terminologi och definitioner

Mästarprovet i syntax

- Mästarprovet följer andra mästarprov i upplägg
 - skriftliga lösningar som redovisas muntligt
 - ett eller fler allvarliga fel ger underkänt
- Kursboken användbar som uppslagsverk/referens
- Tänk på att dubbelkolla svarsförsök
- Vissa exempeluppgifter och referenslösningar går igenom under föreläsningarna

① Introduktion

② Artificiella språk

③ Reguljära uttryck

④ Ändliga automater

Språk

- Ett **ord** är en ändlig sekvens av element från ändlig mängd Σ
- Vi kallar oftast Σ för ett **alfabet**
- Vi tillåter det **tomma ordet** ϵ
- Ett **språk** är en delmängd av Σ^*
- uv är sammanslagningen (konkateneringen) av orden u och v

$$L_1 L_2 = \{u_1 u_2 \mid u_1 \in L_1, u_2 \in L_2\}$$

$$L^0 = \{\epsilon\}, \quad L^{k+1} = L L^k$$

$$L^* = \bigcup_k L^k \text{ (Kleenestjärna)}$$

- Kleenestjärna: “det som stod framför, valfritt antal gånger”

Exempel på språk

$$\Sigma = \{a, b\}$$

$$\Sigma^* = \{\epsilon, a, b, aa, ab, ba, bb, aaa, aab, aba, \dots\}$$

Exempel på två språk (delmängder av Σ^*):

$$L_1 = \{a, bb, ab\} \text{ (ändligt språk, tre ord)}$$

$$L_2 = \{ab, abab, ababab, \dots\}$$

$$= \{(ab)^n | n > 0\} \text{ (oändligt språk)}$$

Exempel på språk, fortsättning

- 8-bitars binära tal: $\{0, 1\}^8$
- Satisfierbara Booleska formler
- Binära strängar med udda paritet:
 $\{w \in \{0, 1\}^* \mid \text{udda antal ettor i } w\}$
- Mersenne-primtal i bas 10
- Syntaktiskt korrekta Javaprogram som terminerar

Exempel på operationer på språk

$$L = \{a, ab\}$$

$$LL = \{aa, aab, aba, abab\}$$

$$\begin{aligned} L^* &= \{\epsilon, a, ab, aa, aab, aba, abab, aaa, \dots\} \\ &= \{u \mid \text{omedelbart före varje } b \text{ i } u \text{ finns ett } a\} \end{aligned}$$

Hur bevisa att $bb \notin L^*$?

Språk och problem

- Vi pratar ofta om (datalogiska) problem att avgöra om ett ord är i ett språk L
 - givet $w \in \Sigma^*$, avgör om w är i L eller inte
 - t ex för binärt tal w , avgör om w är primt eller inte
- Vi säger också ekivalent att vi letar efter metoder för att **känna igen** ord i L
 - en korrekt metod måste förkasta alla ord som **inte är** i L
 - en korrekt metod måste godkänna alla ord som **är** i L
- Att definiera ett problem kan vara, men är inte alltid, en implicit uppmaning att hitta en metod att känna igen språket

Artificiella språk och kompilatorer

- **Lexikal analys** i en kompilator känner igen beståndsdelar (*tokens*) i ett programspråk:
 - nyckelord som `class`, `while`, `if`
 - variabelnamn, parameternamn, metodnamn, klassnamn, etc.
 - operatorer och avgränsare: `+`, `-`, `*`, `/`, `%`, `;`, etc.
 - alfabet Σ i lexikal analys: tecken, t ex ASCII, UTF-8
- **Syntaktisk analys** i en kompilator känner igen syntaktiska konstruktioner i ett programspråk:
 - uttryck som `34 + x`
 - variabeldeklARATIONER som `int x = 3`
 - alfabet Σ i syntaktisk analys: tokens från lexikal analys

① Introduktion

② Artificiella språk

③ Reguljära uttryck

④ Ändliga automater

Reguljära uttryck

- Strukturerat sätt att beskriva språk entydigt
 - ofta språk med oändligt antal ord
- Reguljära uttryck byggs med:
 - tomta språket $\emptyset$
 - $\{\epsilon\}$, skrivs oftast ϵ
 - $\{a\}$, där $a \in \Sigma$, skrivs oftast a
 - union, skrivs oftast $|$ (ibland $+$)
 - konkatenering, skrivs oftast som multiplikation (punkt/tom)
 - repetition med Kleenestjärna

Reguljära uttryck: exempel 1

- Namn på labbar i DD1360:
 - F1, F2, F3, S1, S2, S3, X1, X2
- Vi kan beskriva labbarna med följande reguljära uttryck:
 - F1 | F2 | F3 | S1 | S2 | S3 | X1 | X2
- Förklaring:
 - F står för språket $\{F\}$, där $F \in \Sigma$
 - F1 står för språket $\{F1\}$, där $F \in \Sigma$ och $1 \in \Sigma$
 - F1 | F2 står för språket $\{F1, F2\}$, där $F, 1, 2 \in \Sigma$
 - etc.

Reguljära uttryck: exempel 1, fortsättning

- Namn på labbar i DD1360:
 - F1, F2, F3, S1, S2, S3, X1, X2
- Namnen följer ett **mönster**:
 - börjar med F, S eller X följt av 1, eller
 - börjar med F, S eller X följt av 2, eller
 - börjar med F eller S följt av 3
- Detta mönster kan beskrivas med följande reguljära uttryck:
 - $(F \mid S \mid X)1 \mid (F \mid S \mid X)2 \mid (F \mid S)3$
- Kan vi använda andra alfabet än ASCII?

Reguljära uttryck: exempel 2

- Alla binära strängar:
 - "", "0", "1", "00", "01", "10", "11", "000", ...
- Fundamental skillnad från tidigare exempel?
 - det finns ett **obegränsat** antal binära strängar
 - vi kan inte lista dem alla med |
- Använd Kleenestjärna: $(0 \mid 1)^*$

Syntaktiskt socker

- parenteser för gruppering
- $[a-z] = a \mid b \mid \dots \mid z$ (använder ASCII-ordning)
- $e?$ (en eller ingen gång)
- e^+ (en eller flera gånger)
- $!e$ (komplement/matcha inte, ibland $[\sim a-z]$)
- $e1 \ \& \ e2 = !(\ !e1 \mid \ !e2)$ (snitt, matcha båda)

Fler reguljära uttryck

- Decimaltal, "digit": `0 | 1 | 2 | ... | 9`
- Heltalskonstanter: `digit digit*`
- Tecken i alfabetet, "letter": `[a-z] | [A-Z]`
- Identifierare: `letter (letter | digit)*`
 - variabelnamn i programspråk
 - metodnamn
 - etc.

Reguljära uttryck: exempel 3

- Förenklade domännamn består av minst två punktseparerade icke-tomma strängar med bara små bokstäver och siffror
- Reguljärt uttryck för “icke-tom sträng med bara små bokstäver och siffror”: $[a-z0-9]^+$
- Försök till reguljärt uttryck för domännamn:
 $[a-z0-9]^+(\.[a-z0-9]^+)^*$
- Problem(?): domännamn med bara en del (utan punkt)
- Slutligt reguljärt uttryck: $[a-z0-9]^+(\.[a-z0-9]^+)^+$

Reguljärt uttryck för epostadress?

```
(?: (?: \r\n)? [ \t] ) * (?: (?: (?: [^()<>@,;:
\\\".\[\] \000-\031] + (?: (?: (?: \r\n)? [ \t]
) + | \Z | (?= [\"()<>@,;: \\\".\[\]])) ) | \"(?:
[^\\" \r\\] | \\ . | (?: (?: \r\n)? [ \t] )) * \"(?: (?:
\r\n)? [ \t] ) * ) (?: \. (?: (?: \r\n)? [ \t] ) *
(?: [^()<>@,;: \\\".\[\] \000-\031] + (?: (?: (?:
?: \r\n)? [ \t] ) + | \Z | (?= [\"()<>@,;: \\\".
\[\]])) ) | \"(?: [^\\" \r\\] | \\ . | (?: (?: \r\n)? [
\t] )) * \"(?: (?: \r\n)? [ \t] ) * ) * @ (?: (?: \r\n)?
[ \t] ) * (?: [^()<>@,;: \\\".\[\] \000-\0
31] + (?: (?: (?: \r\n)? [ \t] ) + | \Z | (?= [\"()<>@
,;: \\\".\[\]])) ) | \[ ( [^\[\] \r\\] | \\ . ) * \
```

Se även RFC 5321 och 5322.

Reguljära uttryck i praktiken: regex

- Reguljära uttryck används implicit för textbehandling
 - sök och ersätt i IDE:er
 - del av informationssökningsgränssnitt
- Många verktyg/programspråk implementerar egna reguljära uttryck (regex)
 - många olika inkompatibla variationer i syntax
 - utvidgningar (backtracking, negativ lookahead, ...)
 - läs dokumentationen innan du matchar
 - se upp för regex som inte är reguljära uttryck

Reguljära uttryck i Unixverktyg

- `grep '<regex>' <file>`
 - matar ut rader i <file> där text som matchar <regex> finns
- `sed 's/<regex>/<replacement>/g' < <file>`
 - matar ut innehållet i <file> med matchningar av <regex> ersatta med <replacement>

Exempel med grep och sed

```
$ grep '..ing' wikipedia
```

grep is a command-line utility for searching plain-text
has the same effect: doing a global search with the
and printing all matching lines.

```
$ sed 's/Bell/Whistle/g' < wikipedia > wikipedia_funny
```

Reguljära uttryck i Java

- Paketet `java.util.regex` har klasser för att matcha Javas strängar mot mönster uttryckta som reguljära uttryck
- En instans av klassen `Pattern` representerar ett reguljärt uttryck som uttryckts i form av en sträng

```
import java.util.regex.*;
```

```
Pattern p = Pattern.compile("cat");
```

```
Matcher m = p.matcher("one cat, two cats in the yard");
```

```
String s = m.replaceAll("dog");
```

```
// --> s = "one dog, two dogs in the yard"
```

Exempeluppgift om reguljära uttryck

På matematisk nivå definierar vi språket L med hjälp av ordvariablerna w och v och tecknen a , b , c , d och e :

$$L = \{ wcdv \mid w \text{ är tom eller innehåller bara } a \text{ och } b, \text{ och } v \text{ består av ett eller flera } e \}$$

Definiera ett reguljärt uttryck som precis beskriver L .

Rimliga tolkningar och svar

$L = \{ wcdv \mid w \text{ är tom eller innehåller bara } a \text{ och } b, \text{ och } v \text{ består av ett eller flera } e \}$

- Tolka “tom eller innehåller bara a och b” som: $(ab|ba|\epsilon)$
 - kan även skrivas $(ab|ba)?$
 - vi får reguljära uttrycket $(ab|ba)?cd(e)^+$
 - $(e)^+$ kan även skrivas $e(e)^*$
- Tolka “tom eller innehåller bara a och b” som: $(a|b)^*$
 - vi får reguljära uttrycket $(a|b)^*cd(e)^+$
- Inget tolkningsutrymme för entydig ordning mellan a och b
 - fel att tolka “tom eller innehåller bara a och b” som: $(ab)?$
 - fel att tolka “tom eller innehåller bara a och b” som: $(ba)?$

① Introduktion

② Artificiella språk

③ Reguljära uttryck

④ Ändliga automater

Vad är en ändlig automat?

En ändlig automat består av:


- En ändlig mängd av tillstånd Q
- Ett ändligt alfabet med indatasymboler Σ
- En mängd av övergångar δ mellan tillstånd märkta med element i Σ
- Ett initialt tillstånd $q \in Q$
- En mängd av accepterande tillstånd F (ibland *slutliga* tillstånd)

Ändliga automater och determinism

- Om alla övergångar ut från ett tillstånd har olika märkning är den ändliga automaten **deterministisk**
 - DFA, Deterministic Finite Automaton
- Om det finns flera övergångar ut från ett tillstånd med samma märkning är automaten **indeterministisk**
 - NFA, Nondeterministic Finite Automaton
- Vi fokuserar på **deterministiska** ändliga automater här (mängden av övergångar är en **funktion**)

Ändliga automater och matchning

- Ändliga automater kan ses som abstrakta maskiner för matchning av ord/strängar
- Tillstånd är kanter i maskinens graf
- Övergångar är hörn i maskinens graf
- Tecken från indatasträng matchas mot märkningar för övergångar och leder till tillståndsbyte
- Om vi slutar i ett accepterande tillstånd accepteras strängen
- Alternativ till reguljära uttryck för språkigenkänning
- Mer om automater i nästa föreläsning



Bonus: exempeluppgift reguljära uttryck

På matematisk nivå definierar vi språket L med hjälp av ordvariabeln w och tecknen a , b , och c :

$$L = \{ wc \mid w \text{ är tom eller består av ett jämnt positivt antal } a \text{ följt av ett jämnt positivt antal } b \}$$

Rimliga tolkningar och svar

$L = \{ wc \mid w \text{ är tom eller består av ett jämnt positivt antal } a \text{ följt av ett jämnt positivt antal } b \}$

- Föreslaget reguljärt uttryck: $((aa)^+(bb)^+)?c$
- Orimligt med $(a)^+$ eller $(b)^+$, då är det inte nödvändigtvis jämnt antal
- Orimligt med $(aa)^*$ eller $(bb)^*$, då är det inte positivt antal
- Glöm inte c på slutet