

Automater

Matematik för språkteknologer

Mattias Nilsson

Automater

- ▶ Beräkningsmodeller
 - ▶ Beräkning - (eng) Computation
- ▶ Inom automatateorin studeras flera olika beräkningsmodeller med olika egenskaper och olika beräkningsförmåga
- ▶ *Finita automater* är en typ av beräkningsmodell som ligger till grund för många, mer avancerade, beräkningsmodeller som t.ex. *stackautomater* eller *pushdown-automater*, och *Turingmaskiner*.

Tillämpning av automatateori

- ▶ Viktigt hjälpmedel för design, implementation, och modellering av många typer av system.
- ▶ Mönsterigenkänning:
 - ▶ Textsökning (t.ex. grep)
 - ▶ Stavnings- och grammatikkontroll
 - ▶ Kompilator teknik
 - ▶ Optisk teckenigenkänning (OCR)

Inledande språktekniska begrepp

- ▶ Alfabet
- ▶ Strängar
- ▶ Språk

Inledande språktekniska begrepp

Alfabet: Σ

- ▶ En ändlig mängd av *ett eller flera* tecken (symboler)

Exempel

- ▶ Det binära alfabetet: $\Sigma = \{0, 1\}$
- ▶ Det svenska alfabetet: $\Sigma = \{a, \dots, \ddot{o}, A, \dots, \ddot{O}\}$
- ▶ Mängden av små bokstäver (Latin): $\Sigma = \{a, b, \dots, z\}$
- ▶ Mängden av ASCII-tecken

Inledande språktekniska begrepp

Strängar

- ▶ En sträng w över ett alfabet är en ändlig sekvens av *noll eller flera* tecken från alfabetet.
 - ▶ $\Sigma_1 = \{0, 1\}$ $w_1 = 01101$
 - ▶ $\Sigma_2 = \{a, b, c\}$ $w_2 = babca$

Den tomma strängen: ϵ

- ▶ En sträng utan realiserade tecken (dvs. som består av noll tecken)

Längden av en sträng w : $|w|$

- ▶ $|w_1| = 5$ $|w_2| = 5$ $|\epsilon| = 0$

Inledande språktekniska begrepp

Sammansättning av strängar (strängkonkatenering)

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

$$w_1 = \textit{king} \quad w_2 = \textit{kong}$$

$$w_1 w_2 = \textit{kingkong} \quad w_2 w_1 = \textit{kongking} \quad w_1 \epsilon = \textit{king}$$

$$\Sigma = \{0, 1\}$$

$$x = 01101 \quad y = 110$$

$$xy = 01101110 \quad yx = 11001101 \quad \epsilon y = 110$$

$$w\epsilon = \epsilon w = w$$

Inledande språktekniska begrepp

Språk: L

- ▶ Ett språk L är en mängd av strängar

Kleenstjärna: Σ^*

- ▶ Mängden av alla strängar över ett alfabet Σ
- ▶ $\{0, 1\}^* = \{\epsilon, 0, 1, 00, 01, 10, 11, 000, \dots\}$
- ▶ $\{a, b\}^* = \{\epsilon, a, b, aa, bb, ab, ba, aab, \dots\}$

Finita automater

Vad är finita automater?

- ▶ En abstrakt (idealiserad) beräkningsmodell
- ▶ Ett system som har ett ändligt antal möjliga tillstånd och vars beteende kan beskrivas med enkla transitionsregler, t.ex. om systemet är i tillstånd p och det får input a då går det till tillstånd q .
- ▶ En automat läser en given indatasträng från vänster till höger, en symbol i taget.
- ▶ Beroende på vilket tillstånd automaten befinner sig i när hela strängen är läst, accepteras eller avvisas strängen, så varje automat definierar en mängd av godkända strängar - automatens *språk*.

Finita automater

Deterministisk finit automata (definition)

En *deterministisk finit automat* (DFA) är en fem-tupel $(Q, \Sigma, \delta, q_0, F)$, där

- ▶ Q är en ändlig mängd *tillstånd*,
- ▶ Σ är en ändlig mängd symboler - ett *alfabet*,
- ▶ $\delta : Q \times \Sigma \mapsto Q$ är en *transitionsfunktion*,
- ▶ q_0 är det initiala tillståndet (*starttillstånd*),
- ▶ F är en delmängd av Q ; *mängden accepterande tillstånd*.

Determinism


Deterministisk finit automata (DFA)

- ▶ Givet ett tillstånd och en inputsymbol finns det exakt ett möjligt måltillstånd (exakt en tillämpbar transition).

Ickedeterministisk finit automata (NFA)

- ▶ Givet ett tillstånd och en inputsymbol kan det finnas flera möjliga måltillstånd (mer än en tillämpbar transition).
- ▶ För varje NFA finns det en ekvivalent DFA. En ickedeterministisk finit automat kan således alltid *determiniseras*, dvs. konverteras till en deterministisk finit automat.


Finita automater som grafer



Finita automater representeras ofta som grafer (tillståndsdigram):

- ▶ noder = tillstånd
- ▶ riktade bågar (pilar) med symboler = transitioner
- ▶ inkommande pil utan avsändare = starttillstånd
- ▶ dubbla cirklar = accepterande tillstånd

Finita automater som grafer



Automaten ovan definieras formellt:

$$Q = \{s_1, s_2, s_3\}$$

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


$$q_0 = s_1$$

$$\delta = \{ \langle s_1, a \rangle = s_2, \langle s_2, a \rangle = s_2, \langle s_2, b \rangle = s_3 \}$$

$$F = \{s_3\}$$

Övning

Hur definieras automaten nedan formellt? Vilket språk accepterar den?



Övning

- ▶ Hur ser tillståndsdiagrammet ut för automaten $M = (Q, \Sigma, \delta, q_0, F)$, där $Q = \{s_1, s_2\}$, $\Sigma = \{1, 0\}$, $q_0 = s_1$, $F = \{s_1\}$, och δ ges av tabellen nedan?

	0	1
s_1	s_1	s_2
s_2	s_2	s_1

- ▶ Vilket språk accepterar M ?

Accepterande automater

Accepterande automater kan användas för att avgöra om en viss sträng ingår i automatens språk:

1. Starta i starttillståndet

2. Läs nästa symbol i strängen

Om strängen inte innehåller fler symboler:

Acceptera strängen om tillståndet är ett accepterande tillstånd


Annars: avvisa strängen

3. Följ bågen markerad med inläst symbol

Om ingen sådan finns avvisas strängen

4. Gå till steg 2.


Övning



- ▶ Vilka av följande strängar känns igen (accepteras) av automaten ovan?
 $w_1 = bababa$; $w_2 = ababab$; $w_3 = aabbaa$; $w_4 = bbaabb$;
 $w_5 = bbbaaa$; $w_6 = aaabbb$;
- ▶ Vilket språk accepterar automaten ovan?
- ▶ Definera en sträng w , där $|w| = 8$, som känns igen av automaten

Övning

- Vilket språk accepterar automaten?



Övning

- ▶ Konstruera en automat som känner igen språket av alla binära strängar som slutar på 1.
- ▶ Konstruera en automat som känner igen språket av alla binära strängar som innehåller noll eller fler förekomster av 0 följt av noll eller fler förekomster av 1.
- ▶ Konstruera en automat som känner igen språket av alla binära strängar som innehåller exakt tre ettor.

Automater med utmatning

Mealyautomater

- ▶ En deterministisk finit automat (DFA) kompletterad med en funktion som lämnar utdata vid varje tillståndsövergång.

Mooreautomater

- ▶ En deterministisk finit automat (DFA) som lämnar utdata vid varje tillståndsbesök (även i starttillståndet).

Reguljära språk

- ▶ Varje språk som accepteras av en finit automat är ett *reguljärt* språk
- ▶ Reguljära språk är en klass av formella språk
 - ▶ Alla språk är alltså inte reguljära
- ▶ Är naturliga språk reguljära?

Reguljära operationer

Låt A och B vara (reguljära) språk. De reguljära operationerna *union*, *konkatenering* och *Kleenstjärna* definieras som följer:

- ▶ Union: $A \cup B = \{x \mid x \in A \text{ eller } x \in B\}$
- ▶ Konkatering: $A \cdot B = \{xy \mid x \in A \text{ och } y \in B\}$
- ▶ Kleenstjärna: $A^* = \{x_1x_2 \dots x_k \mid k \geq 0 \text{ och } x_i \in A\}$

Reguljära operationer: exempel

Låt $L_1 = \{001, 10, 111\}$ och $L_2 = \{\epsilon, 001\}$

- ▶ $L_1 \cup L_2 = \{\epsilon, 001, 10, 111\}$
- ▶ $L_1 \cdot L_2 = \{001, 10, 111, 001001, 10001, 111001\}$
- ▶ $L_2^* = \{\epsilon, 001, 001001, 001001001, \dots\}$

Reguljära uttryck

- ▶ Matematiskt uttryckssätt för att beskriva klassen av reguljära språk
- ▶ *Varje språk som accepteras av en finit automat är ett reguljärt språk*
- ▶ Går att översätta mellan reguljära uttryck och finita automater
- ▶ Reguljära uttryck och finita automater är två olika beräkningsmodeller som båda beskriver klassen av reguljära språk


Övning

Konstruera automater som känner igen följande reguljära språk

- ▶ ab
- ▶ ab^+
- ▶ $a|b$
- ▶ ab^*
- ▶ $(ab)^*$

Övning

Formulera ett reguljärt uttryck för det språk som känns igen av följande automat:



Övningar (Eriksson & Gavel)

Sektion 9.1

- ▶ Övning 9.1 - 9.7

Sektion 9.2

- ▶ Övning 9.9, 9.16, 9.19, 9.20

Sektion 9.3

- ▶ Övning 9.32-9.33