

# Grundlagen Theoretischer Informatik I

SoSe 2011 in Trier

Henning Fernau

Universität Trier

fernau@uni-trier.de

# Grundlagen Theoretischer Informatik I

## Gesamtübersicht

- Organisatorisches; Einführung
- Logik & Beweisverfahren
- Mengenlehre
- reguläre Sprachen

## Formale Sprachen — eine Annäherung

Was ist eine Sprache ?

Eine *Sprache* ist eine Menge von Wörtern.

Das sollte jetzt auch mathematisch klar sein:

Eine Menge  $\Sigma$  heißt *Alphabet*, falls  $\Sigma$  eine endliche, nicht-leere Menge ist, i.Z.:  
 $|\Sigma| < \infty$  und  $\Sigma \neq \emptyset$ .

Kurz gesagt: Eine Sprache  $L$  (über  $\Sigma$ ) ist eine Teilmenge des von der Menge  $\Sigma$  frei erzeugten Monoids, i.Z.:  $L \subseteq \Sigma^*$ .

Ein **deterministischer endlicher Automat** oder DEA wird beschrieben durch ein Quintupel

$$A = (Q, \Sigma, \delta, q_0, F)$$

wobei gilt:

$Q$ : endliche Menge von *Zuständen* (Zustandsalphabet)

$\Sigma$ : endliche Menge von *Eingabezeichen* (Eingabealphabet)

$\delta : Q \times \Sigma \rightarrow Q$ : *Überföhrungsfunktion*

$q_0 \in Q$ : *Anfangszustand*

$F \subseteq Q$ : *Endzustände*

## Was “tut” der folgende Automat ?

$\delta$	a	b
$\rightarrow s$	s	q
q $\rightarrow$	r	q
r	r	r

Wie sieht der Automatengraph aus ?

Wie kann man  $L(A)$  beschreiben

- in Worten oder
- in Mengennotation?

**Lemma:**  $L(A) = L := \{a^n b^m \mid n \geq 0, m \geq 1\}$   
mit  $a^0 := \lambda$  and  $a^{n+1} = a^n \cdot a$  (*Wortpotenzen*).

Der Beweis von  $L(A) = L$  hat in der Regel zwei Richtungen: (a)  $L(A) \subseteq L$  und (b)  $L \subseteq L(A)$ .

Beweistechnik: Induktion.

- für (a) betrachtet das Induktionsargument i.d.R.  $n$ -Schritt-Konfigurationsübergänge  $c \vdash^n c'$
- für (b) erfolgt das Induktionsargument hingegen über die Wortlänge  $n = |w|$  mit  $w \in L$  (oder aus  $\Sigma^*$ ).

Lemma 1:  $\forall n \geq 0 : (s, a^n) \vdash^* (s, \lambda)$ .

Beweis: ✓ für  $n = 0$ . Für  $n > 0$ :

$$(s, a^n) = (s, a \cdot a^{n-1}) \vdash (s, a^{n-1}) \vdash^* (s, \lambda)$$

Beweis von  $L(A) \supseteq L$ : Offensichtlich ist  $b \in L$  das einzige Wort der Länge Eins oder kürzer in  $L$  und  $b \in L(A)$ , denn  $\delta(s, b) = q$ .

Betrachte  $a^n b^m \in L$  mit  $n + m > 1$ . Gilt  $m = 1$ , so folgt mit Lemma 1:

$$(s, a^n b) \vdash^* (s, b) \vdash (q, \lambda)$$

Für  $m > 1$  folgt mit der IH:

$$(s, a^n b^{m-1} b) \vdash^* (q, b) \vdash (q, \lambda).$$

In beiden Fällen ist  $a^n b^m \in L(A)$ .

Zustand  $r$  ist eine "Falle" in folgendem Sinne:

**Lemma 2:**  $\forall v, w \in \Sigma^* : ((r, v) \vdash^* (x, w)) \Rightarrow x \in \{r\}$ .

**Lemma 3:**  $\forall w \in \Sigma^* : ((q, w) \vdash^* (q, \lambda)) \Rightarrow w \in \{b\}^*$ .

Beweis durch Induktion über  $|w|$ . ✓ für  $n = 0$ .

Für  $n > 0$  betrachte  $w = a_1 a_2 \dots a_n$  mit  $\forall 1 \leq i \leq n : a_i \in \Sigma$ .

Diskutiere  $(q, a_1 a_2 \dots a_n) \vdash (x, a_2 \dots a_n) \vdash^* (q, \lambda)$ .

Falls  $a_1 = a$ , so gilt  $x = r$ , und wegen Lemma 2 ist  $(x, a_2 \dots a_n) \vdash^* (q, \lambda)$  unmöglich.

Ist  $a_1 = b$ , so gilt  $x = q$ , und die IH liefert  $a_2 = \dots = a_n = b$ .

**Beweis von  $L(A) \subseteq L$ :** Betrachte  $(s, w) \vdash^n (q, \lambda)$ .

Für  $n = 1$ ,  $w = b \in L$ .

Für  $n > 1$  erörtern wir  $(s, w) \vdash (x, w') \vdash^{n-1} (q, \lambda)$ .

Ist  $w = aw'$ , so  $x = s$ ; die IH liefert die Behauptung.

Ist  $w = bw'$ , so  $x = q$ ; dann folgt mit Lemma 3 die Behauptung.



## Operationen auf Sprachen

Erinnerung: Eine Sprache ist eine *Menge* von Wörtern.


Also: Vereinigung, Durchschnitt, Komplement, ... von Sprachen liefern wieder Sprachen, sind also *Operationen auf Sprachen*.

Eine Menge von Sprachen heißt auch *Sprachfamilie*.

Wir haben bislang die Familie **DEA** der DEA-akzeptierbaren Sprachen betrachtet.

Ist  $f$  eine  $k$ -stellige Operation auf Sprachen und ist  $\mathcal{L}$  eine Sprachfamilie, so heißt  $\mathcal{L}$  *abgeschlossen gegen  $f$*  gdw. für alle  $L_1, \dots, L_k \in \mathcal{L}$  gilt:  $f(L_1, \dots, L_k) \in \mathcal{L}$ .

**Ein Beispiel** Was beschreibt folgender Automat ?




$$\begin{aligned}
L(A) &= \{w \in \{0, 1\}^* \mid w \text{ enthält } \underline{\text{nicht}} \text{ das Teilwort } 11\} \\
&= \{w \in \{0, 1\}^* \mid \text{Auf jedes Vorkommen von } 1 \\
&\quad \text{vor der letzten Stelle in } w \text{ folgt } 0. \}
\end{aligned}$$

**Satz:** **DEA**-Sprachen sind komplementabgeschlossen.

Beweis: Sprachkomplement entspricht Endzustandsmengenkomplement.

Hinweis: Dies ist streng genommen gar kein Beweis, sondern die bloß Angabe einer Konstruktion, die zu vorgelegtem DEA  $A$  einen DEA  $A'$  bastelt, für den zu zeigen wäre, dass  $L(A)$  das Komplement von  $L(A')$  akzeptiert. Man hat also zu zeigen:  $w \in L(A) \rightarrow w \notin L(A')$  und  $w \in L(A') \rightarrow w \notin L(A)$ . Die formale Durchführung ist Ihnen zur Übung überlassen.

## Das Beispiel



## Schwieriger: Vereinigungsbildung

Wie kann man aus DEA-Beschreibungen für

$$L_1 = \{w \in \{0, 1\}^* \mid w \text{ enthält das Teilwort } 11\},$$


$$L_2 = \{w \in \{0, 1\}^* \mid w \text{ enthält das Teilwort } 00\},$$

einen DEA für  $L_1 \cup L_2$  basteln ?


Idee: Verwende “irgendwie” Automaten für  $L_1$  und für  $L_2$ .

Kann man EAs aus “Teilprogrammen” zusammensetzen ?

Ein DEA für  $L_2$  sähe wie folgt aus:



## Vereinigung durch mehrere Anfangszustände ??



Ein **nichtdeterministischer endlicher Automat** oder NEA wird beschrieben durch ein Quintupel

$$A = (Q, \Sigma, \delta, Q_0, F)$$

wobei gilt:

$Q$ : endliche Menge von *Zuständen* (Zustandsalphabet)

$\Sigma$ : endliche Menge von *Eingabezeichen* (Eingabealphabet)

$\delta \subseteq Q \times \Sigma \times Q$ : *Überführungsrelation*

$Q_0 \subseteq Q$ : *Anfangszustände*

$F \subseteq Q$ : *Endzustände*

Sprachfamilie: **NEA**.



## Überführungstafel

Ein endlicher Automat kann vollständig durch seine *Überführungstafel* beschrieben werden.

Beispiel: Betrachte:

$\delta$	0	1
$\rightarrow q$	q	r
r $\rightarrow$	q	s
s	s	s
$\rightarrow q'$	r'	q'
r' $\rightarrow$	s'	q'
s'	s'	s'

Die **von einem NEA  $A = (Q, \Sigma, \delta, Q_0, F)$  akzeptierte Sprache** kann man formal wie folgt beschreiben.

Ein Element aus  $C = Q \times \Sigma^*$  heißt *Konfiguration* von  $A$ .

Definiere eine binäre Relation  $\vdash_A$  auf  $C$  durch  $(q, w) \vdash_A (q', w')$  gdw.  $\exists a \in \Sigma : w = aw'$  und  $\delta \ni (q, a, q')$ .

Die zweite Komponente einer Konfiguration ist die Resteingabe.

$\vdash_A$  beschreibt einen möglichen Konfigurationsübergang in einem Schritt.

Entsprechend beschreibt  $\vdash_A^n$   $n$  Schritte von  $A$ .

Daher können wir definieren:

$$L(A) = \{w \in \Sigma^* \mid \exists q_0 \in Q_0, q \in F : (q_0, w) \vdash_A^* (q, \lambda)\}.$$

## NEAs zur Spezifikation I

**Beispiel:** Gesucht: NEA, der in der Reihenfolge (aber nicht unbedingt nebeneinander) die Zeichen 0, 1, 1 enthält.

Lösung:

$\delta$	0	1
$\rightarrow q$	q, r	q
r	r	r, s
s	s	s, t
t $\rightarrow$	t	t

## Dazu DEA ?!

Idee: “erstes Vorkommen” zu prüfen genügt !

$\delta$	0	1
$\rightarrow q$	r	q
r	r	s
s	s	t
t $\rightarrow$	t	t

Hinweis: Pattern Matching !

## NEAs zur Spezifikation II

**Satz:** Jede endliche Sprache ist **NEA**-Sprache.

Beweis: Sei  $L = \{w_1, \dots, w_M\} \subseteq \Sigma^*$  mit

$$w_i = a_{i,1} \cdots a_{i,\ell(w_i)}, \quad 1 \leq i \leq M.$$

Betrachte den folgendenmaßen spezifizierten *Skelettautomaten*:

$$Q = \{(i, j) \mid 1 \leq i \leq M, 0 \leq j \leq \ell(w_i)\},$$

$$Q_0 = \{(i, 0) \mid 1 \leq i \leq M\} \quad \text{und} \quad F = \{(i, \ell(w_i)) \mid 1 \leq i \leq M\}$$

$$\delta = \{((i, j), a, (i, j + 1)) \mid 1 \leq i \leq M, 0 \leq j < \ell(w_i), a_{i,j+1} = a\}.$$

Hinweis: Master-Vorlesung über Lernalgorithmen

## Unterschiede DEA / NEA Spezifikation

anhand der Überführungstafel; wie DEA, ABER:

- Einträge dürfen leer sein, d.h. der Automat ist *unvollständig*.  
Manchmal auch bei DEAs zugelassen. . . (partielle DEAs)
- Es gibt mehr als einen Eintrag (das heißt ja Nichtdeterminismus!).
- Es gibt eine Anfangszustandsmenge.
- Manchmal werden neben Buchstaben auch Wörter als Spaltenüberschrift zugelassen, insbesondere das leere Wort: *NEA mit  $\lambda$ -Übergängen*.

## Vereinigung leicht gemacht

**Satz:** NEA ist unter Vereinigung abgeschlossen.

Beweis: Es seien  $A_i = (Q_i, \Sigma, \delta_i, Q_{i,0}, F_i)$  für  $i = 1, 2$  zwei NEAs.

Durch Umbenennen können wir  $Q_1 \cap Q_2 = \emptyset$  voraussetzen.

Dann wird  $L(A_1) \cup L(A_2)$  beschrieben durch:

$$(Q_1 \cup Q_2, \Sigma, \delta_1 \cup \delta_2, Q_{1,0} \cup Q_{2,0}, F_1 \cup F_2).$$

**NEA=DEA**  $\rightsquigarrow$  Sprachfamilie **REG** der *regulären Sprachen*.

Beweis:  $\supseteq$  ✓. Für  $\subseteq$  betrachte NEA  $A = (Q, \Sigma, \delta, Q_0, F)$ .

Die Relation  $\delta$  lässt sich als Abbildung

$$\delta_f : Q \times \Sigma \rightarrow 2^Q \text{ auffassen mit } (q, a) \mapsto \{r \in Q \mid (q, a, r) \in \delta\}.$$

Dies liefert auch eine Abbildung  $\delta_f : 2^Q \times \Sigma \rightarrow 2^Q, (P, a) \mapsto \bigcup_{p \in P} \delta_f(p, a)$ .

Setze  $F' = \{P \in 2^Q \mid P \cap F \neq \emptyset\}$  und betrachte DEA

$$A' = (2^Q, \Sigma, \delta_f, Q_0, F').$$

Behauptung:  $L(A) = L(A')$ .

Hinweis: **Zustandsexplosion !**



## Zustandsexplosion: ein böses Beispiel

$$L_k = \{x \in \{0, 1\}^* \mid \ell(x) \geq k, \text{ das } k\text{-letzte Zeichen von } x \text{ ist } 0 \}$$

**Lemma:**  $L_k$  kann durch einen NEA mit  $k + 1$  Zuständen erkannt werden, aber durch keinen DEA mit weniger als  $2^k$  Zuständen.

Beweis: Der NEA ist durch folgende Tafel beschrieben:

	0	1	
$\rightarrow q_0$	$q_0, q_1$	$q_0$	
$q_i$	$q_{i+1}$	$q_{i+1}$	für $0 < i < k$
$q_k \rightarrow$			

## Warum ist das Beispiel “böse” ?

$$L_k = \{x \in \{0, 1\}^* \mid \ell(x) \geq k, \text{ das } k\text{-letzte Zeichen von } x \text{ ist } 0 \}$$

Gäbe es einen DEA  $A$  mit  $< 2^k$  Zuständen für  $L_k$ , so gibt es (Schubfachprinzip) Wörter  $y_1, y_2 \in \{0, 1\}^k$  und einen Zustand  $q$  mit  $(q_0, y_i) \vdash_A^k (q, \lambda)$  für  $i = 1, 2$ .

Wähle  $j$ , sodass es ein Wort  $u \in \{0, 1\}^{j-1}$  gibt mit  $y_1 = ua_1v_1$  und  $y_2 = ua_2v_2$  mit  $\{a_1, a_2\} = \{0, 1\}$  (längstes gemeinsames Anfangswort von  $y_1, y_2$ ).

Da  $|v_1| = |v_2| = k - j$ , liegt genau eines der Wörter  $y_1u$  bzw.  $y_2u$  in  $L_k$ .

Andererseits gibt es genau ein  $q'$ , sodass:

$$(q_0, y_i u) \vdash_A^k (q, u) \vdash_A^{j-1} (q', \lambda) \quad \text{für } i = 1, 2,$$

d.h.,  $y_1u$  und  $y_2u$  werden gleichermaßen akzeptiert oder verworfen, denn  $A$  arbeitet deterministisch.

## Zustandsexplosion vermeidbar ?

Manchmal ja: durch “lazy evaluation” (Bereitstellen erst wenn nötig!)

**Beispiel:** Betrachte den Skelettautomaten zu  $L = \{a, aa, ab, abb\}$  mit Zustandsmenge  $\{(1, 0), (1, 1); (2, 0), (2, 1), (2, 2); (3, 0), (3, 1), (3, 2); (4, 0), (4, 1), (4, 2), (4, 3)\}$ .

Beginnen wir mit  $Q_0 = \{(1, 0), (2, 0), (3, 0), (4, 0)\}$ , dem Startzustand des DEA.

$$\delta_f(Q_0, a) = \{(1, 1), (2, 1), (3, 1), (4, 1)\} =: Q_1$$

$$\delta_f(Q_0, b) = \emptyset$$

$$\delta_f(Q_1, a) = \{(2, 2)\} =: Q_2$$

$$\delta_f(Q_1, b) = \{(3, 2), (4, 2)\} =: Q_3$$

$$\delta_f(Q_3, a) = \emptyset$$

$$\delta_f(Q_3, b) = \{(4, 3)\} =: Q_4$$

$$\delta_f(\emptyset, x) = \delta_f(Q_2, x) = \delta_f(Q_4, x) = \emptyset \text{ für } x = a, b.$$

Endzustände sind  $Q_1, Q_2, Q_3, Q_4$ .

Anstelle von  $2^{12}$  hat unser DEA nur 5 Zustände, weniger als Ausgangs-NEA!

Der so aus Skelettautomaten gewonnene DEA heißt *Präfixbaumakzeptor*.

## **Boolesche Abschlusseigenschaften**—zusammengefasst

Aus den abgeleiteten Abschlusseigenschaften von **DEA** und von **NEA** sowie dem Gesetz von de Morgan und der soeben bewiesenen Sprachfamiliengleichheit folgt:

**Satz:** **REG** ist abgeschlossen gegenüber Vereinigung, Durchschnitt und Komplementbildung.