

# Überblick

## Automatentheorie und ihre Anwendungen Teil 1: endliche Automaten auf endlichen Wörtern

Thomas Schneider

15.–22. April 2015

- 1 Grundbegriffe
- 2 *Anwendung: Textsuche*
- 3 Abschlusseigenschaften
- 4 Reguläre Ausdrücke und *Anwendungen*
- 5 Charakterisierungen
- 6 Entscheidungsprobleme

### Und nun ...

### Wörter, Sprachen, ...

- 1 Grundbegriffe
- 2 *Anwendung: Textsuche*
- 3 Abschlusseigenschaften
- 4 Reguläre Ausdrücke und *Anwendungen*
- 5 Charakterisierungen
- 6 Entscheidungsprobleme

- **Symbole**  $a, b, \dots$
- **Alphabet**  $\Sigma$ : endliche nichtleere Menge von Symbolen
- **(endliches) Wort**  $w$  über  $\Sigma$ :  
endliche Folge  $w = a_1 a_2 \dots a_n$  von Symbolen  $a_i \in \Sigma$
- **leeres Wort**  $\varepsilon$
- **Wortlänge**  $|a_1 a_2 \dots a_n| = n$ ,  $|\varepsilon| = 0$
- **Menge aller Wörter** über  $\Sigma$ :  $\Sigma^*$
- **Sprache**  $L$  über  $\Sigma$ : Teilmenge  $L \subseteq \Sigma^*$  von Wörtern
- **Sprachklasse**  $\mathcal{L}$ : Menge von Sprachen

# Endliche Automaten

# Beispiel und graphische Repräsentation von NEAs

## Definition 1

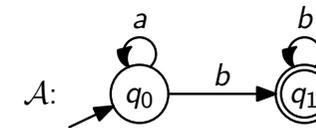
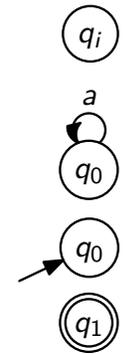
Ein **nichtdeterministischer endlicher Automat (NEA)** über einem Alphabet  $\Sigma$  ist ein 5-Tupel  $\mathcal{A} = (Q, \Sigma, \Delta, I, F)$ , wobei

- $Q$  eine endliche nichtleere **Zustandsmenge** ist,
  - $\Sigma$  ein Alphabet ist,
  - $\Delta \subseteq Q \times \Sigma \times Q$  die **Überföhrungsrelation** ist, (\*)
  - $I \subseteq Q$  die Menge der **Anfangszustände** ist,
  - $F \subseteq Q$  die Menge der **Endzustände** ist.
- (\*) bedeutet:  
 $\Delta$  besteht aus Tripeln  $(q, a, q')$  mit  $q, q' \in Q$  und  $a \in \Sigma$   
 $(q, a, q') \in \Delta$  bedeutet intuitiv:  
 ist  $\mathcal{A}$  in Zustand  $q$  und liest ein  $a$ , geht er in Zustand  $q'$  über.

Betrachte  $\mathcal{A} =$

$(\{q_0, q_1\}, \{a, b\}, \{(q_0, a, q_0), (q_0, b, q_1), (q_1, b, q_1)\}, \{q_0\}, \{q_1\})$

- Zustände:  $q_0, q_1$
- Alphabet  $\{a, b\}$
- Übergänge: von  $q_0$  mittels  $a$  zu  $q_0, \dots$
- Anfangszustand  $q_0$
- Endzustand  $q_1$




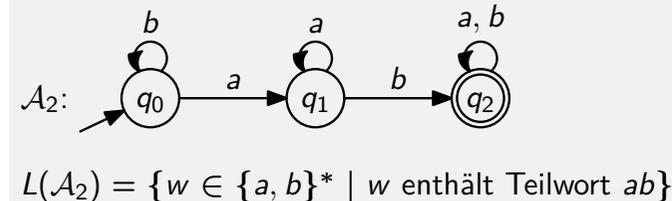

# Berechnungen und Akzeptanz

# Beispiele

## Definition 2

Sei  $\mathcal{A} = (Q, \Sigma, \Delta, I, F)$  ein NEA.

- Eine **Berechnung** (Run) von  $\mathcal{A}$  auf  $w = a_1 a_2 \dots a_n$  ist eine Folge  
 $q_0 q_1 q_2 \dots q_n$ ,  
 so dass für alle  $i = 0, \dots, n - 1$  gilt:  $(q_i, a_{i+1}, q_{i+1}) \in \Delta$ .  
 Man sagt/schreibt:  $w$  **überföhrt**  $q_0$  in  $q_n$ ,  $q_0 \xrightarrow{a_1 \dots a_n} \mathcal{A} q_n$
- $\mathcal{A}$  **akzeptiert**  $w = a_1 a_2 \dots a_n$ ,  
 wenn es eine Berechnung  $q_0 q_1 q_2 \dots q_n$  von  $\mathcal{A}$  auf  $w$  gibt  
 mit  $q_0 \in I$  und  $q_n \in F$ .
- Die von  $\mathcal{A}$  **erkannte Sprache** ist  
 $L(\mathcal{A}) = \{w \in \Sigma^* \mid \mathcal{A} \text{ akzeptiert } w\}$ .



# Erkennbare Sprache

# Determinismus

## Definition 3

Eine Sprache  $L \subseteq \Sigma^*$  ist (NEA-)erkennbar, wenn es einen NEA  $\mathcal{A}$  gibt mit  $L = L(\mathcal{A})$ .

## Definition 4

Sei  $\mathcal{A} = (Q, \Sigma, \Delta, I, F)$  ein NEA.

Enthält  $\Delta$  für jedes  $q \in Q$  u. jedes  $a \in \Sigma$  **genau 1** Tripel  $(q, a, q')$  und enthält  $I$  **genau 1** Zustand,

dann ist  $\mathcal{A}$  ein **deterministischer endlicher Automat (DEA)**.

↪ Nachfolgezustand für jedes Paar  $(q, a)$  eindeutig bestimmt

- Jeder DEA ist ein NEA, aber nicht umgekehrt (z. B.  $\mathcal{A}_1, \mathcal{A}_3$  auf Folie 8).
- Auf Folie 8 ist nur  $\mathcal{A}_2$  ein DEA;  $\mathcal{A}_1$  kann mittels *Papierkorbzustand* zum DEA werden – und  $\mathcal{A}_3$ ? •

# Potenzmengenkonstruktion

# Und nun ...

**Frage:** Sind DEAs und NEAs gleichmächtig?

D. h.:  $\{L \mid L \text{ ist DEA-erkennbar}\} = \{L \mid L \text{ ist NEA-erkennbar}\}?$

**Antwort:** Ja!

## Satz 5

Sei  $\mathcal{A}$  ein NEA.

Dann gibt es einen DEA  $\mathcal{A}^d$  mit  $L(\mathcal{A}^d) = L(\mathcal{A})$ .

Beweis: siehe Tafel. •

Im schlimmsten Fall kann  $\mathcal{A}^d$  im Vergleich zu  $\mathcal{A}$  exponentiell viele Zustände haben (s. Hopcroft et al. 2001, S. 65).

1 Grundbegriffe

2 Anwendung: Textsuche

3 Abschlusseigenschaften

4 Reguläre Ausdrücke und Anwendungen

5 Charakterisierungen

6 Entscheidungsprobleme

# Stichwortsuche

# Stichwortsuche ohne invertierte Indizes?

## Typisches Problem aus dem Internetzeitalter

Gegeben sind **Stichwörter**  $w_1, \dots, w_n \in \Sigma^*$  und **Dokumente**  $D_1, \dots, D_M \in \Sigma^*$ .  
 Finde alle  $j$ , so dass  $D_j$  mindestens ein (alle)  $w_i$  als Teilwort hat.

- relevant z.B. für **Suchmaschinen**
- übliche Technologie: **invertierter Index (II)**  
 speichert für jedes im Internet auftretende  $w_i$  eine Liste aller Dokumente  $D_j$ , die  $w_i$  enthalten
- Ils sind zeitaufwändig zu erstellen und setzen voraus, dass die  $D_j$  sich nur langsam ändern

Ils versagen, wenn

- die (relevanten) Dokumente sich schnell ändern:
    - Suche in tagesaktuellen Nachrichtenartikeln
    - Einkaufshelfer sucht nach bestimmten Artikeln in aktuellen Seiten von Online-Shops
  - die Dokumente nicht katalogisiert werden können:
    - Online-Shops wie Amazon generieren oft Seiten für ihre Artikel nur auf Anfragen hin.
- Wie kann man dafür Stichwortsuche implementieren?

# Ein Fall für endliche Automaten!

# Implementation des NEAs $\mathcal{A}$

## Wdhlg.: Typisches Problem aus dem Internetzeitalter

Gegeben sind **Stichwörter**  $w_1, \dots, w_n \in \Sigma^*$  und **Dokumente**  $D_1, \dots, D_M \in \Sigma^*$ .  
 Finde alle  $j$ , so dass  $D_j$  mindestens ein  $w_i$  als Teilwort hat.

- Ziel:** konstruiere NEA  $\mathcal{A}$ , der
- ein  $D_j$  zeichenweise liest und
  - in einen Endzustand geht gdw. er eins der  $w_i$  findet

## Beispiel 6

Seien  $w_1 = \text{web}$  und  $w_2 = \text{ebay}$ .  
 Wie muss  $\mathcal{A}$  aussehen? ●

Eine Möglichkeit:

- 1 Determinisierung (Potenzmengenkonstruktion)
- 2 Simulation des resultierenden DEA  $\mathcal{A}^d$

**Wird  $\mathcal{A}^d$  nicht zu groß?**

( $2^{27} > 134$  Mio. Zustände bei Stichw. „Binomialkoeffizient“, „Polynom“)

**Nein,**

- für unsere spezielle Form von  $\mathcal{A}$ ,
- mit unserer Version der Potenzmengenkonstruktion

wird  $\mathcal{A}^d$  genauso viele Zustände haben wie  $\mathcal{A}$ !

Beispiel: siehe Tafel ●

# Zum Nachdenken

# Und nun ...

## Übung:

- Konstruiere den DEA  $\mathcal{A}^d$  für  $\mathcal{A}$  von Folie 15.
- Beschreibe die Konstruktion von  $\mathcal{A}^d$  allgemein, wenn  $w_1, \dots, w_n$  gegeben sind, mit  $w_i = a_{i1} \dots a_{i\ell_i}$  für jedes  $i = 1, \dots, n$ .

- 1 Grundbegriffe
- 2 Anwendung: Textsuche
- 3 Abschlusseigenschaften
- 4 Reguläre Ausdrücke und Anwendungen
- 5 Charakterisierungen
- 6 Entscheidungsprobleme

## Operationen auf Sprachen sind Operationen auf Mengen

## Abgeschlossenheit

Wie können (NEA-erkennbare) Sprachen kombiniert werden?

- Boolesche Operationen
  - Vereinigung**  $L_1 \cup L_2 = \{w \mid w \in L_1 \text{ oder } w \in L_2\}$
  - Schnitt**  $L_1 \cap L_2 = \{w \mid w \in L_1 \text{ und } w \in L_2\}$
  - Komplement**  $\bar{L} = \{w \in \Sigma^* \mid w \notin L\}$
- Wortoperationen
  - Konkatenation**  $L_1 \cdot L_2 = \{vw \mid v \in L_1 \text{ und } w \in L_2\}$
  - Kleene-Hülle**  $L^* = \bigcup_{i \geq 0} L^i$ ,  
wobei  $L^0 = \{\varepsilon\}$  und  $L^{i+1} = L^i \cdot L$  für alle  $i \geq 0$

### Frage

Unter welchen Op. sind die NEA-erkennbaren Sprachen abgeschlossen?

### Satz 7

Die Menge der NEA-erkennbaren Sprachen ist abgeschlossen unter den Operationen  $\cup, \cap, \bar{\phantom{x}}, \cdot, *$ .

Das heißt:

Wenn  $L, L_1, L_2$  NEA-erkennbar sind, dann sind auch

- $L_1 \cup L_2$
- $L_1 \cap L_2$
- $\bar{L}$
- $L_1 \cdot L_2$
- $L^*$

NEA-erkennbar.

**Beweis:** Direkte Konsequenz aus den folgenden Lemmata. □

## Abgeschlossenheit unter Vereinigung

### Lemma 8

Seien  $\mathcal{A}_1, \mathcal{A}_2$  NEAs über  $\Sigma$ .  
 Dann gibt es einen NEA  $\mathcal{A}_3$  mit  $L(\mathcal{A}_3) = L(\mathcal{A}_1) \cup L(\mathcal{A}_2)$ .

**Beweis:** Seien  $\mathcal{A}_i = (Q_i, \Sigma, \Delta_i, I_i, F_i)$  für  $i = 1, 2$ .  
 O. B. d. A. gelte  $Q_1 \cap Q_2 = \emptyset$ .

Konstruieren  $\mathcal{A}_3 = (Q_3, \Sigma, \Delta_3, I_3, F_3)$  wie folgt.

► *Idee:* vereinige  $\mathcal{A}_1$  und  $\mathcal{A}_2$ .

- $Q_3 = Q_1 \cup Q_2$
- $\Delta_3 = \Delta_1 \cup \Delta_2$
- $I_3 = I_1 \cup I_2$
- $F_3 = F_1 \cup F_2$  (Beispiel siehe Tafel)

Dann gilt  $L(\mathcal{A}_3) = L(\mathcal{A}_1) \cup L(\mathcal{A}_2)$ . (Tafel)

•  
• □

## Abgeschlossenheit unter Komplement

### Lemma 9

Sei  $\mathcal{A}$  ein NEA über  $\Sigma$ .  
 Dann gibt es einen NEA  $\mathcal{A}^c$  mit  $L(\mathcal{A}^c) = \overline{L(\mathcal{A})}$ .

**Beweis:**

► *Idee:* Vertausche End- und Nicht-Endzustände (im DEA!).

O. B. d. A. sei  $\mathcal{A} = (Q, \Sigma, \Delta, I, F)$  ein DEA (Satz 5).

Dann erkennt  $\mathcal{A} = (Q, \Sigma, \Delta, I, Q \setminus F)$  die Sprache  $\overline{L(\mathcal{A})}$ . □

### Folgerung 10

Seien  $\mathcal{A}_1, \mathcal{A}_2$  NEAs über  $\Sigma$ .  
 Dann gibt es einen NEA  $\mathcal{A}_3$  mit  $L(\mathcal{A}_3) = L(\mathcal{A}_1) \cap L(\mathcal{A}_2)$ .

Gilt wegen  $L_1 \cap L_2 = \overline{\overline{L_1} \cup \overline{L_2}}$ .

## Abgeschlossenheit unter Verkettung

### Lemma 11

Seien  $\mathcal{A}_1, \mathcal{A}_2$  NEAs über  $\Sigma$ .  
 Dann gibt es einen NEA  $\mathcal{A}_3$  mit  $L(\mathcal{A}_3) = L(\mathcal{A}_1) \cdot L(\mathcal{A}_2)$ .

**Beweis:** Seien  $\mathcal{A}_i = (Q_i, \Sigma, \Delta_i, I_i, F_i)$  für  $i = 1, 2$ .  
 O. B. d. A. gelte  $Q_1 \cap Q_2 = \emptyset$  und  $I_i = \{q_{0i}\}$ .

Konstruieren  $\mathcal{A}_3 = (Q_3, \Sigma, \Delta_3, I_3, F_3)$  wie folgt.

► *Idee:* „Hintereinanderhängen“ von  $\mathcal{A}_1$  und  $\mathcal{A}_2$ .

(Details siehe Th11 – nicht wichtig für diese Vorlesung)

•  
□

## Abgeschlossenheit unter Kleene-Hülle

### Lemma 12

Sei  $\mathcal{A}$  ein NEA über  $\Sigma$ .  
 Dann gibt es einen NEA  $\mathcal{A}^k$  mit  $L(\mathcal{A}^k) = L(\mathcal{A})^*$ .

**Beweis:** Sei  $\mathcal{A} = (Q, \Sigma, \Delta, I, F)$ . Konstruieren  $\mathcal{A}^k = (Q^k, \Sigma, \Delta^k, I^k, F^k)$  wie folgt.

► *Idee:* Lege „Schleife“ um  $\mathcal{A}$ ;  
 Löse  $\varepsilon$ -Kanten auf wie im  $\cdot$ -Fall

(Details siehe Th11 – nicht wichtig für diese Vorlesung)

•  
□

# Und nun ...

# Ziel dieses Abschnitts

- 1 Grundbegriffe
- 2 Anwendung: Textsuche
- 3 Abschlusseigenschaften
- 4 Reguläre Ausdrücke und Anwendungen
- 5 Charakterisierungen
- 6 Entscheidungsprobleme

Wie können NEA-erkennbare Sprachen bequem charakterisiert werden?

## Reguläre Sprachen

## Reguläre Ausdrücke

### Definition 13

Eine Sprache  $L \subseteq \Sigma^*$  ist **regulär**, falls gilt:

- $L = \emptyset$  oder
- $L = \{\varepsilon\}$  oder
- $L = \{a\}$ ,  $a \in \Sigma$ , oder
- $L$  lässt sich durch (endlichmaliges) Anwenden der Operatoren  $\cup, \cdot, *$  aus den vorangehenden Fällen konstruieren.

### Beispiele:

$(\{a\} \cup \{b\})^* \cdot \{a\} \cdot \{b\}$  (siehe  $\mathcal{A}_3$  auf Folie 8)  
 $\{b\}^* \cdot \{a\} \cdot \{a\}^* \cdot \{b\} \cdot (\{a\} \cup \{b\})^*$  (s.  $\mathcal{A}_2$  auf Folie 8)

### Definition 14

Ein **regulärer Ausdruck (RA)**  $r$  über  $\Sigma$  und die *zugehörige Sprache*  $L(r) \subseteq \Sigma^*$  werden induktiv wie folgt definiert.

- $r = \emptyset$  ist ein RA mit  $L(r) = \emptyset$
- $r = \varepsilon$  ist ein RA mit  $L(r) = \{\varepsilon\}$
- $r = a$ , für  $a \in \Sigma$ , ist ein RA mit  $L(r) = \{a\}$
- $r = (r_1 + r_2)$  ist ein RA mit  $L(r) = L(r_1) \cup L(r_2)$
- $r = (r_1 r_2)$  ist ein RA mit  $L(r) = L(r_1) \cdot L(r_2)$
- $r = (r_1)^*$  ist ein RA mit  $L(r^*) = (L(r))^*$

### Beispiele: (wir lassen Klammern weg soweit eindeutig)

$(a + b)^* ab$  (siehe  $\mathcal{A}_3$  auf Folie 8)  
 $b^* aa^* b(a + b)^*$  (siehe  $\mathcal{A}_2$  auf Folie 8)

## Reguläre und NEA-erkennbare Sprachen

## Anwendungen regulärer Ausdrücke

### Satz 15 (Kleene)

Sei  $L \subseteq \Sigma^*$  eine Sprache.

- ①  $L$  ist regulär gdw. es einen RA  $r$  gibt mit  $L = L(r)$ .
- ②  $L$  ist regulär gdw.  $L$  NEA-erkennbar ist.

### Beweis.

- ① Folgt offensichtlich aus Def. 13, 14.
- ② Benutze Teil (1).

„ $\Rightarrow$ “: Induktion über Aufbau von  $r$ .

IA: gib Automaten an, die  $\emptyset$ ,  $\{\varepsilon\}$ ,  $\{a\}$  erkennen.

IS: benutze Abschlusseigenschaften – Lemmas 8, 11, 12

„ $\Leftarrow$ “: siehe Theoretische Informatik 1.



- RAs werden verwendet, um „Muster“ von zu suchendem Text zu beschreiben  
 z. B.: suche alle Vorkommen von „PLZ Ort“:  
 $(0 + \dots + 9)^5 \sqcup (A + \dots + Z)(a + \dots + z)^*$
- Programme zum Suchen von Mustern im Text übersetzen RAs in NEAs/DEAs und simulieren diese
- wichtige Klassen von Anwendungen:  
**lexikalische Analyse, Textsuche**

## Komfortablere Syntax regulärer Ausdrücke

## Anwendung: lexikalische Analyse

- UNIX und andere Anwendungen erweitern Syntax von RAs
- Hier: nur „syntaktischer Zucker“ – die Erweiterungen, die nicht aus den regulären Sprachen herausführen
- Alphabet  $\Sigma$ : alle ASCII-Zeichen
- RA  $.$  mit  $L(.) = \Sigma$
- RA  $[a_1 a_2 \dots a_k]$ , Abkürzung für  $a_1 + a_2 + \dots + a_k$
- RAs für Bereiche: z. B.  $[a-z0-9]$ , Abkü. für  $[ab\dots z01\dots 9]$
- Operator  $|$  anstelle  $+$
- Operator  $?$ :  $r?$  steht für  $\varepsilon + r$
- Operator  $+$ :  $r+$  steht für  $rr^*$
- Operator  $\{n\}$ :  $r\{5\}$  steht für  $rrrrr$
- Klammern und  $*$  wie gehabt

PLZ-Ort-Beispiel:  
 $[0-9]\{5\} \sqcup [A-Z][a-z]^*$

- **Lexer** durchsucht Quelltext eines Programms nach **Token**: zusammengehörende Zeichenfolgen, z. B. Kennwörter, Bezeichner
- Ausgabe des Lexers: Token-Liste, wird an Parser weitergegeben
- Mit RAs: Lexer leicht programmier- und modifizierbar
- UNIX-Kommandos `lex` und `flex` generieren Lexer
  - Eingabe: Liste von Einträgen RA + Code
  - Code beschreibt Ausgabe des Lexers für das jeweilige Token
  - generierter Lexer wandelt RAs in DEAs um, um Vorkommen der Tokens zu finden (siehe Folie 15)
  - anhand des Zustands des DEAs lässt sich bestimmen, *welches* Token gefunden wurde

## Beispieleingabe für lex

```

else
  {return(ELSE);}

[A-Za-z][A-Za-z0-9]*
  {<Trage gefundenen Bezeichner in Symboltabelle ein>;
  return(ID);}

>=
  {return(GE);}

=
  {return(EQ);}
    
```

(Lexer-Generator muss Prioritäten beachten:  
 else wird auch vom 2. RA erkannt, ist aber reserviert)

## Anwendung: Finden von Mustern im Text

**Beispiel:** Suchen von Adressen (Str. + Hausnr.) in Webseiten

Solche Angaben sollen gefunden werden:

Parkstraße 5  
 Enrique-Schmidt-Straße 12a  
 Breitenweg 24A  
 Knochenhauergasse 30-32

aber auch solche:

Straße des 17. Juni 17  
 ...boulevard, ...allee, ...platz, ...  
 Postfach 330 440  
 Am Wall 8

- ↪ Ausmaß der Variationen erst während der Suche deutlich
- ↪ Gesucht: einfach modifizierbare Beschreibung der Muster

## Mustersuche mit regulären Ausdrücken

Mögliches Vorgehen:

- 1 Beschreibung des Musters mit einem einfachen RA
- 2 Umwandlung des RA in einen NEA
- 3 Implementation des NEA wie auf Folie 15
- 4 Test
- 5 Wenn nötig, RA erweitern und Sprung zu Schritt 2

## Adresssuche mit regulären Ausdrücken

So kann sich der RA entwickeln:

- Vorkommen von „straße“ etc.:<sup>1</sup>  
`straße|str\.|weg|gasse`
- Plus Name der Straße und Hausnummer:  
`[A-Z][a-z]*(straße|str\.|weg|gasse) [0-9]*`
- Hausnummern mit Buchstaben (12a), -bereiche (30-32):  
`[A-Z][a-z]*(straße|str\.|weg|gasse) ([0-9]*[A-Za-z]?-)?[0-9]*[A-Za-z]?`
- und mehr:
  - Straßennamen mit Bindestrichen
  - „Straße“ etc. am Anfang
  - Plätze, Boulevards, Alleen etc.
  - Postfächer
  - ...

<sup>1</sup>Weil der UNIX-RA . für  $\Sigma$  reserviert ist, steht \. für {.}

# Und nun ...

# Pumping-Lemma

- 1 Grundbegriffe
- 2 Anwendung: Textsuche
- 3 Abschlusseigenschaften
- 4 Reguläre Ausdrücke und Anwendungen
- 5 Charakterisierungen
- 6 Entscheidungsprobleme

Wie zeigt man, dass  $L$  **nicht** NEA-erkennbar (regulär) ist?

### Satz 16 (Pumping-Lemma)

Sei  $L$  eine NEA-erkennbare Sprache.  
 Dann gibt es eine Konstante  $p \in \mathbb{N}$ ,<sup>2</sup>  
 so dass für alle Wörter  $w \in L$  mit  $|w| \geq p$  gilt:  
 Es gibt eine Zerlegung  $w = xyz$  mit  $|y| > 0$  und  $|xy| \leq p$ ,  
 so dass  $xy^i z \in L$  für alle  $i \in \mathbb{N}$ .<sup>2</sup>

Beweis: siehe Tafel. ●  
□

$${}^2\mathbb{N} = \{0, 1, 2, \dots\}$$

## Anwendung des Pumping-Lemmas

Zur Erinnerung:

### Satz 16 (Pumping-Lemma)

**Wenn**  $L$  eine NEA-erkennbare Sprache ist,  
**dann gibt es** eine Konstante  $p \in \mathbb{N}$ ,  
 so dass **für alle** Wörter  $w \in L$  mit  $|w| \geq p$  gilt:  
**Es gibt** eine Zerlegung  $w = xyz$  mit  $|y| > 0$  und  $|xy| \leq p$ ,  
 so dass  $xy^i z \in L$  **für alle**  $i \in \mathbb{N}$ .

Benutzen Kontraposition:

**Wenn** es **für alle** Konstanten  $p \in \mathbb{N}$   
 ein Wort  $w \in L$  mit  $|w| \geq p$  **gibt**, so dass es  
**für alle** Zerlegungen  $w = xyz$  mit  $|y| > 0$  und  $|xy| \leq p$   
 ein  $i \in \mathbb{N}$  **gibt** mit  $xy^i z \notin L$ ,  
**dann** ist  $L$  **keine** NEA-erkennbare Sprache. ◀ Bsp.: s. Tafel ●

## Bemerkungen zum Pumping-Lemma

- Bedingung in Satz 16 ist **notwendig** dafür, dass  $L$  NEA-erkennbar ist.
- nicht **hinreichend** (Bsp.:  $\{a^n b^k c^k \mid n, k \geq 1\} \cup \{b^n c^k \mid n, k \geq 0\}$ )
- ↪ Pumping-L. nur zum **Widerlegen** von Erkennbarkeit verwendbar, nicht zum Beweisen, dass  $L$  regulär ist
- Notwendige und hinreichende Bedingung: *Jaffes Pumping-L.*

# Der Satz von Myhill-Nerode

**Ziel:** notwendige **und** hinreichende Bedingung für Erkennbarkeit

## Definition 17

Sei  $L \subseteq \Sigma^*$  eine Sprache.

Zwei Wörter  $u, v \in \Sigma^*$  sind  **$L$ -äquivalent** (Schreibweise:  $u \sim_L v$ ), wenn für alle  $w \in \Sigma^*$  gilt:

$$uw \in L \text{ genau dann, wenn } vw \in L$$

$\sim_L$  heißt **Nerode-Rechtskongruenz** und ist Äquivalenzrelation:

- reflexiv: offensichtlich
- symmetrisch: offensichtlich
- transitiv: offensichtlich

**Index** von  $\sim_L$ : Anzahl der Äquivalenzklassen

## Und nun ...

- 1 Grundbegriffe
- 2 Anwendung: Textsuche
- 3 Abschlusseigenschaften
- 4 Reguläre Ausdrücke und Anwendungen
- 5 Charakterisierungen
- 6 Entscheidungsprobleme

# Der Satz von Myhill-Nerode

## Satz 18 (Myhill-Nerode)

$L \subseteq \Sigma^*$  is NEA-erkennbar gdw.  $\sim_L$  endlichen Index hat.

Ohne Beweis. Beispiel siehe Tafel.

Interessantes **“Nebenprodukt”** des Beweises:

Endlicher Index  $n$  von  $\sim_L$

= minimale Anzahl von Zuständen in einem DEA, der  $L$  erkennt.

## Entscheidbarkeit

### (Entscheidungs-)Problem

- ... ist eine Teilmenge  $X \subseteq M$
- Beispiele:
  - $X$  = Menge aller Primzahlen,  $M = \mathbb{N}$
  - $X$  = Menge aller NEAs  $\mathcal{A}$  mit  $L(\mathcal{A}) \neq \emptyset$ ,  $M$  = Menge aller NEAs
- man stelle sich eine Blackbox vor:



**Entscheidbarkeit:**  $X$  ist entscheidbar,

wenn es einen Algorithmus  $A$  gibt, der die Blackbox implementiert.

(Programmiersprache u. Rechnermodell sind relativ unerheblich: erweiterte Churchsche These)

# Komplexität



## Komplexität:

zusätzliche Anforderungen an Zeit-/Speicherplatzbedarf von  $A$

- **Polynomialzeit:** Anzahl Rechenschritte von  $A$  ist  $\leq pol(|m|)$ ,  $|m|$ : Länge der Eingabe;  $pol$  ist ein festes **Polynom**
- **Polynomieller Platz:** von  $A$  benötigter Speicherplatz  $\leq pol(|m|)$
- **Exponentialzeit:** Anzahl Rechenschritte von  $A$  ist  $\leq 2^{pol(|m|)}$
- ...

# Einige übliche Komplexitätsklassen


Name	Bedeutung	Beispiel-Problem
<b>L</b>	logarithm. Speicherplatz	Grapherreichbarkeit
<b>NL</b>	nichtdetermin. log. Platz	"
<b>P</b>	Polynomialzeit	Primzahlen
-----		
<b>NP</b>	nichtdeterminist. Polyzeit	Erfüllbarkeit Auss.-logik
<b>PSPACE</b>	polynom. Speicherplatz	Erfüllbarkeit QBF
<b>EXPTIME</b>	Exponentialzeit	
<b>NEXPTIME</b>	nichtdet. Exponentialzeit	
<b>EXSPACE</b>	exponentieller Platz	
⋮	⋮	
	unentscheidbar	Erfüllbarkeit Präd.-logik

# Reduktion



**(Polynomielle) Reduktion** von  $X \subseteq M$  nach  $X' \subseteq M'$  ist eine (in Polyzeit berechenbare) Funktion  $\pi : M \rightarrow M'$  mit

$$m \in X \quad \text{gdw.} \quad \pi(m) \in X'$$



Wenn  $X$  zu  $X'$  reduzierbar, dann ist  $X$  **höchstens so schwer** wie  $X'$ .

Wenn alle Probleme aus Komplexitätsklasse  $\mathcal{C}$  auf  $X$  reduzierbar, dann ist  $X$  **schwer für  $\mathcal{C}$** .

# Bestimmung der Komplexität

Normalerweise zeigt man, dass ein Problem  $X \subseteq M \dots$

- **in** einer Komplexitätsklasse  $\mathcal{C}$  liegt, indem man
  - einen Algorithmus  $A$  findet, der  $X$  löst
  - zeigt, dass  $A$  korrekt ist (*ja/nein*-Antworten) und terminiert
  - zeigt, dass  $A$  für jedes  $m \in M$  **höchstens** die  $\mathcal{C}$ -Ressourcen braucht
  - ...  $A$  kann z. B. eine Reduktion zu einem Problem aus  $\mathcal{C}$  sein
- **schwer (hard) für  $\mathcal{C}$**  ist, indem man
  - ein Problem  $X' \subseteq M'$  findet, dass **schwer für  $\mathcal{C}$**  ist
  - und eine Reduktion von  $X'$  nach  $X$  angibt
- **vollständig für  $\mathcal{C}$**  ist, indem man zeigt, dass es
  - **in  $\mathcal{C}$**  liegt und
  - **schwer für  $\mathcal{C}$**  ist

## Entscheidungsprobleme für endliche Automaten

- Betrachten wesentliche Eigenschaften von Sprachen (Sprachen repräsentiert durch NEAs oder reguläre Ausdr.)
  - Ist eine gegebene Sprache leer?
  - Ist ein gegebenes Wort  $w$  in einer Sprache  $L$ ?
  - Beschreiben zwei Repräsentationen einer Sprache tatsächlich dieselbe Sprache?
- Wichtig für die bisher gesehenen Anwendungen (Ü: finde Gründe!)
- Art der Repräsentation spielt manchmal eine Rolle:
  - Umwandlung DEA  $\rightarrow$  NEA: konstante Zeit 😊
  - NEA  $\rightarrow$  DEA: Exponentialzeit ☹️
  - reg. Ausdr.  $\rightarrow$  NEA: Polynomialzeit 😊
  - NEA  $\rightarrow$  reg. Ausdr.: Exponentialzeit ☹️

Wir beschränken uns im Folgenden auf NEAs.

## Das Leerheitsproblem

Ist definiert als  $\{\mathcal{A} \mid L(\mathcal{A}) = \emptyset\}$ .

### Satz 19

*Das Leerheitsproblem ist entscheidbar.*

**Beweis:** Siehe Tafel. ●

Komplexität: **NL**-vollständig (Wegsuche in gerichteten Graphen)

## Das Wortproblem

Ist definiert als  $\{(\mathcal{A}, w) \mid w \in L(\mathcal{A})\}$ .

### Satz 20

*Das Wortproblem ist entscheidbar.*

**Beweis:** Reduktion zum Leerheitsproblem – siehe Tafel. ●

Komplexität: **NL**-vollständig (modifizierte Wegsuche)  
 (Reduktion zum Leerheitsproblem liefert nur „in **P**“)

## Das Äquivalenzproblem

Ist definiert als  $\{(\mathcal{A}_1, \mathcal{A}_2) \mid L(\mathcal{A}_1) = L(\mathcal{A}_2)\}$ .

### Satz 21

*Das Äquivalenzproblem ist entscheidbar.*

**Beweis:** Siehe Tafel. ●

Komplexität: für DEAs in **P**, für NEAs **PSPACE**-vollständig  
 (aus Beweis folgt nur „in **EXPTIME**“)

## Das Universalitätsproblem

Ist definiert als  $\{\mathcal{A} \mid L(\mathcal{A}) = \Sigma^*\}$ .

## Satz 22

*Das Universalitätsproblem ist entscheidbar.*

**Beweis:** Übungsaufgabe.

Komplexität: für DEAs in **P**, für NEAs **PSPACE**-vollständig  
(aus Beweis folgt nur „in **EXPTIME**“)

## Literatur für diesen Teil



John E. Hopcroft, Rajeev Motwani, Jeffrey D. Ullman.

Introduction to Automata Theory, Languages and Computation.

2. Auflage, Addison-Wesley, 2001. Kapitel 1,2.

Verfügbar in SUB:

Zentrale a inf 420 e/028(2)

dt. Versionen 2002–11:

2× TB Technik n 438/101(3,2)

dt. Version 2006: 2× Zentrale a inf 420 ef/238a,b

Vorgängerversion von 1979: Zentrale a inf 420 e/806

oder BB Math.-MZH 19h kyb 315 e/996a

oder auf dt., 1988: 2× Zentr. a kyb 308 f/352, (a)



Meghyn Bienvenu.

Automata on Infinite Words and Trees.

Vorlesungsskript, Uni Bremen, WS 2009/10.

<http://www.informatik.uni-bremen.de/tdki/lehre/ws09/automata/automata-notes.pdf>