

Automatentheorie und ihre Anwendungen

Teil 1: endliche Automaten auf endlichen Wörtern

Thomas Schneider

15.–22. April 2015

Überblick

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

Und nun ...

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

Wörter, Sprachen, ...

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

Endliche Automaten

Definition 1

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



- Q eine endliche nichtleere **Zustandsmenge** ist,
 - Σ 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:
 Δ 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.

Beispiel und graphische Repräsentation von NEAs

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

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 **überführt** 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
 $L(\mathcal{A}) = \{w \in \Sigma^* \mid \mathcal{A} \text{ akzeptiert } w\}$.

Beispiele



Erkennbare Sprache

Definition 3

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

Determinismus

Definition 4

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

Enthält Δ 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

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).

Und nun ...

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

Stichwortsuche

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

Stichwortsuche ohne invertierte Indizes?

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!

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? ●

Implementation des NEAs \mathcal{A}

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

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 $w_i = a_{i1} \dots a_{il_i}$ für jedes $i = 1, \dots, n$.

Und nun ...

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

Operationen auf Sprachen sind Operationen auf Mengen

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?

Abgeschlossenheit

Satz 7

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

Absgeschlossenheit unter Vereinigung

Lemma 8

Seien $\mathcal{A}_1, \mathcal{A}_2$ NEAs über Σ .

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 Σ .

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 Σ .

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 Σ .

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

Beweis: Seien $\mathcal{A}_i = (Q_i, \Sigma, \Delta_i, l_i, F_i)$ für $i = 1, 2$.

O. B. d. A. gelte $Q_1 \cap Q_2 = \emptyset$ und $l_i = \{q_{0i}\}$.

Konstruieren $\mathcal{A}_3 = (Q_3, \Sigma, \Delta_3, l_3, F_3)$ 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 Σ .

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 ε -Kanten auf wie im \cdot -Fall

(Details siehe Th11 – nicht wichtig für diese Vorlesung)



Und nun ...

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

Ziel dieses Abschnitts

Wie können NEA-erkennbare Sprachen bequem charakterisiert werden?

Reguläre Sprachen

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)

Reguläre Ausdrücke

Definition 14

Ein **regulärer Ausdruck (RA)** r über Σ 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

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.



Anwendungen regulärer Ausdrücke

- 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

- UNIX und andere Anwendungen erweitern Syntax von RAs
- Hier: nur „syntaktischer Zucker“ – die Erweiterungen, die nicht aus den regulären Sprachen herausführen
- Alphabet Σ : 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:
 $[0-9]\{5\} \sqcup [A-Z][a-z]^*$

Anwendung: lexikalische Analyse

- **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.:¹
`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
 - ...

¹Weil der UNIX-RA `.` für Σ reserviert ist, steht `\.` für `{.}`

Und nun ...

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

Pumping-Lemma

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 $p \in \mathbb{N}$,²

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 $i \in \mathbb{N}$.²

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:

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

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

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

Index von \sim_L : Anzahl der Äquivalenzklassen

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.


Und nun ...

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

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

Einige übliche Komplexitätsklassen

Name	Bedeutung	Beispiel-Problem
L	logarithm. Speicherplatz	Grapherreichbarkeit
NL	nichtdetermin. log. Platz	"
P	Polynomialzeit	Primzahlen


NP	nichtdeterminist. Polyzeit	Erfüllbarkeit Auss.-logik
PSPACE	polynom. Speicherplatz	Erfüllbarkeit QBF
EXPTIME	Exponentialzeit	
NEXPTIME	nichtdet. Exponentialzeit	
EXSPACE	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>