

“Theorie der Informatik” (CS206)

Nicht-deterministische endl. Automaten reguläre Sprachen, Pumping Lemma

18. März 2018

Proff Malte Helmert und Christian Tschudin

Departement Mathematik und Informatik, Universität Basel

Wiederholung/Einstieg

1. Wie lautet das Wortproblem?
2. Zusammenhang Typ-3 Sprachen und endliche Automaten?
3. Was ist der Unterschied zw DFA und NFA?

Definition Endlicher Automat (Repetition)

DFA = deterministischer finiter Automat $(\Sigma, Z, z_0, E, \delta)$

Σ endliches Alphabet

Z endliche Menge von Zuständen, $Z \cap \Sigma = \{ \}$

z_0 Startzustand $\in Z$

E Endzustandsmenge $\subseteq Z$

$\delta : Z \times \Sigma \rightarrow Z$ Transitionsfunktion

“Berechnung durch DFA” (=Akzeptor, determinist. Fall)

Sei M ein endlicher Automat $(\Sigma, Z, z_0, E, \delta)$ und w ein Wort über dem Alphabet Σ

- M **akzeptiert** w falls es eine Sequenz von Zuständen $r_0, \dots, r_n$ gibt in Z so dass
 - $r_0 = z_0$
 - $\delta(r_i, w[i+1]) = r_{i+1}$ für alle $i = 0, \dots, n-1$
 - $r_n \in E$
- M **erkennt** die Sprache A falls $A = \{w \mid M \text{ akzeptiert } w\}$
- Eine Sprache ist **regulär** falls ein endlicher Automat existiert der diese Sprache erkennt.

NFA in einen DFA verwandeln

Grundidee: aus NFA neuen Automaten konstruieren, dessen Zustände Mengen (aus ursprünglichen Zuständen) sind.

Konstruktion:

- $\Sigma' := \Sigma$
- $Z' := P(Z)$, und $S' = \{z_0\}$
- $E' := \{Y \subseteq Z \mid Y \cap E \neq \{\}\}$
- $\delta'(Z, a) := \bigcup \delta(z, a)$ über alle $z \in Z$

NFA in einen DFA verwandeln – Beispiel

$$\Sigma = \{a, b\} \quad S = z_0, \quad E = \{z_0\}$$

	a	b
$\{z_0\}$	$\{z_1\}$	—
$\{z_0, z_1\}$	$\{z_1\}$	$\{z_0, z_2\}$
$\{z_0, z_1, z_2\}$	$\{z_0, z_1\}$	$\{z_0, z_2\}$
$\{z_1\}$	—	$\{z_0, z_2\}$
$\{z_1, z_2\}$	$\{z_0\}$	$\{z_0, z_2\}$
$\{z_2\}$	$\{z_0\}$	—
$\{z_0, z_2\}$	$\{z_1, z_0\}$	—

Neuer Automat:

$$S' = \{z_0\}, \quad E' = \{\{z_0\}\}$$

Neue Zustände A-Z:


$$A := \{z_1\}$$

$$B := \{z_0\}$$

$$C := \{z_0, z_1\}$$

$$D := \{z_0, z_2\}$$

NFA in einen DFA verwandeln – Beispiel (Forts)



$\{z_0\} \rightarrow B$

$\{z_1\} \rightarrow A$

$\{z_0, z_1\} \rightarrow C$

$\{z_0, z_2\} \rightarrow D$

DFA-Minimierung

Verwandlung eines NFA in DFA mit Potenzmengen-Konstruktion:
Gewisse Zustände können weggelassen werden:

1. Sackgasse

Zustand q ist Sackgasse, wenn $\neg \exists w \in \Sigma^* : \delta(q, w) \in E$


2. unerreichbare Zustände

Zustand q unerreichbar, wenn $\neg \exists w \in \Sigma^* : \delta(z_0, w) = q$

3. Äquivalenzklassen

Zustände sind äquivalent, wenn von ihnen aus die gleichen Wörter akzeptiert bzw nicht akzeptiert werden.

DFA-Minimierung: Beispiel Äquivalenzklassen



Von z_1 , z_2 und z_4 aus werden die gleichen Wörter akzeptiert.

Akzeptor (nicht-deterministischer Fall)

Sei M ein nicht-deterministischer endlicher Automat $(\Sigma, Z, z_0, E, \delta)$ und w ein Wort über dem Alphabet Σ


- M **akzeptiert** w falls es eine Sequenz von Zuständen $r_0, \dots, r_n$ gibt in Z so dass
 - $r_0 = z_0$
 - $r_{i+1} \in \delta(r_i, w[i+1])$ für alle $i = 0, \dots, n-1$
 - $r_n \in E$

Bemerkung:


Diese Definition ist bis auf die Aenderung wegen der unterschiedlichen Transitionsfunktion (die nun eine Menge statt einen Folgezustand zurückgibt) identisch mit dem Akzeptieren durch einen deterministischen Automaten.

Deterministisch vs Nicht-determ. endliche Automaten

Deterministic
computation



Nondeterministic
computation



Typ-3-Sprachen und reguläre Ausdrücke

Enger Zusammenhang zwischen **regulären Ausdrücken** und Sprachen vom Typ-3

- Reguläre Ausdrücke definieren ein “Muster” für Wörter, definieren eine Sprache.
- Regulärer Ausdruck kann in einen DFA verwandelt werden (siehe nachfolgende Slides)
- egrep macht dies intern, um die Mustersuche zu beschleunigen.

Reguläre Ausdrücke (RA, “regex”)

Induktive Definition eines RA

1. ϵ ist der RA für die Sprache $\{\epsilon\}$
2. für $a \in \Sigma$ ist a ein RA (für die Sprache $\{a\}$)
3. sei r, s jeweils ein RA. Dann ist
 - $(r)|(s)$ ein RA für $L(r) \cup L(s)$
 - $(r)(s)$ $L(r)L(s)$ (Konkatenation)
 - $(r)^*$ $(L(r))^*$
 - (r) $L(r)$ (Klammern)


Bau eines DFA, der die Sprache eines RA akzeptiert

Hilfsmittel: ϵ -Transition (leeres Wort)

- kann überall eingesetzt werden


$$a\epsilon\epsilon b \sim ab$$

- wird auch “stumme Transition” genannt




Bau eines DFA zu einem RA (Forts I)

Plan: RA $\rightarrow$ NFA $\rightarrow$ DFA




Bau eines DFA zu einem RA (Forts I)

$(r)(s)$ wird zu



$(r)^*$ wird zu



Gesamt-NFA: Bilden des “ ϵ -Abschlusses”, DFA, Minimierung

Elimination der ϵ

Die stillen Transitionen (ϵ) sollten “ignoriert” werden. Wie?

- Ausgehend von einem Zustand z :
welche andere Zustände kann ich durch (reine) ϵ -Schritte von z aus erreichen?
- ϵ -“Abschluss” genannt.
- Um neues δ (für einen NFA ohne Epsilons) zu finden:
bei jedem Zustand zuerst dessen Epsilon-Abschluss bilden,
dann von dieser Menge (!) die möglichen abgehenden Transitionen zeichnen.

ϵ -Abschluss (ϵ -closure)

Input: Zustands(teil)menge T; Output: Closure C

S = T

C = T

WHILE S $\neq$ {} DO

 pick (and remove) any s from S

 FOREACH l in Alphabet plus epsilon: transition(s,l) $\neq$ {} DO

 u = transition(s,l)

 IF l == epsilon AND NOT (u IN C) THEN

 C = C + {u}

 S = S + {s}


 OD

OD

Kontextfreie Sprachen

Ist $\{a^n b^n \mid n \geq 1\}$ eine reguläre Sprache?

Versuch:



Pumping-Lemma

Schleifentheorem, Bar-Hill-Theorem

Sei L eine reguläre Sprache. Dann $\exists n \in \mathbb{N}$ mit:
alle Wörter $x \in L$ mit $|x| \geq n$ lassen sich so in die
Form $x = u v w$ ($u, v, w \in \Sigma^*$) zerlegen, dass gilt:

1. $|v| \geq 1$
2. $|u v| \leq n$ (d.h., u ist “endlicher Prefix”)
3. $\forall i = 0, 1, \dots$ gilt: $u v^i w \in L$ (d.h., v^i ist eine Schleife)

Pumping Lemma, Beweis

Gegeben: reguläre Sprache L


Gesucht: n so dass jedes $x \in L$, $|x| \geq n$ gewünschte Form hat.

Beweis:

- Da L regulär ist, gibt es einen DFA M , der L akzeptiert.
- Sei $n = |Z|$ die Anzahl Zustände von M ,
und x ein Wort mit $|x| \geq n$.
- Beim Akzeptieren von x durchlaufen wir $|x| + 1$ Zustände,
d.h. mind. 1 Zustand z_j wird zweimal besucht
- Wähle u so, dass $\delta(z_0, u) = z_j$, v so, dass $\delta(z_j, v) = z_j$,
und w so, dass $\delta(z_j, w) \in E$.

Pumping Lemma, DFA-Ueberlegung

Bei genügend langem Wort wird es einen Zustand z_j geben, den man zwei- oder mehrmals besucht:




Uebrigens: Wort " uw " wird auch akzeptiert (d.h. $\emptyset$)

Pumping Lemma, Benutzung

- Einsatz: um zu zeigen, dass eine Sprache *nicht* regulär ist
- Dazu:
 - suche (konstruiere) ein $x \in L$
 - so dass es keine Zerlegung $uv^i w$ gibt.
- Beachte:

Es gibt nicht-reguläre Sprachen, für die das Pumping-Lemma auch gilt (d.h. mit Wortstruktur uvw für genügend grosses n).
Deshalb folgendes Mengendiagramm:

Durch Pumping Lemma-Struktur erfasste Sprachen



Alle RA-Sprachen werden dabei erfasst, es gibt aber auch Typ 2-Sprachen mit der Pumping-Lemma-Eigenschaft.

Kontextfreie Sprachen: Ambiguität

Betrachte die Grammatik

```
Stmt -->  'if'  Expr  'then'  Stmt
          | 'if'  Expr  'then'  Stmt  'else'  Stmt
          | Other
```

und folgende zwei Programme

```
if E1 then
  if E2 then
    S1
  else
    S2
```

```
if E1 then
  if E2 then
    S1
else
  S2
```

Ambiguität, Umgang

Ambiguität kann behoben werden:

- Regeln einführen, welche Ableitung vorzuziehen ist (im Falle von Ambiguität)
- Linksableitung-Regel:
Versuche, immer die am meisten links stehende Variable der rechten Produktionsseite abzuleiten.
 $\Rightarrow$ mögliches Rekursionsproblem.
- Oder Grammatik umschreiben (falls möglich)

Elimination der Links-Rekursion

- Gegeben: Grammatik mit (unmittelbarer) Links-Rekursion

$$A \rightarrow A\alpha_1 | A\alpha_2 | \dots | \beta_1 | \beta_2 | \dots | \beta_n$$

- Ersetze die A-Produktionen, führe ein A' ein, wie folgt:

$$A \rightarrow \beta_1 A' | \beta_2 A' | \dots | \beta_n A'$$

$$A' \rightarrow \alpha_1 A' | \alpha_2 A' | \dots | \epsilon$$

- Beispiel:

$$E \rightarrow E "+" T \mid T$$

$$T \rightarrow T "*" F \mid F$$

$$F \rightarrow "(" E ")" \mid \text{Identifier}$$

- (Weitere Schritte nötig, falls mehrstufige Link-Rekursion)

Links-Faktorisierung

- “Dangling else”-Beispiel: rechte Seiten mit gleichem Anfang:

```
Stmt -->  "if"  Expr  "then"  Stmt
          | "if"  Expr  "then"  Stmt  "else"  Stmt
          | Other
```

- Die “gleichen Anfänge” zusammenfassen, neue Verlängerungsvariable S' :

```
Stmt -->  "if"  Expr  "then"  Stmt S'
          | Other
S'   -->  "else"  Expr S  | epsilon
```

- Bemerkung: Ambiguität weiterhin vorhanden, aber schon beim “if”, bzw “else” vorausszusagen, welche Regel anzuwenden ist.

Parsing Problem

- Reguläre Ausdrücke: jedes eingelesene Symbol bestimmt die nächste Aktion (Wechsel des Zustands)
- Kontext-Frei: Falls die “falsche” Ableitungs-Variante gewählt wurde, muss dies rückgängig gemacht werden, Symbole müssen “zurückgeschrieben” werden.
- Wieviele Zeichen muss man max vorausschauen, um **die** korrekte Ableitungsregel zu bestimmen?
- Sprachen vom Typ **LL(1)**:
L(inks-nach-rechts-Parsing) L(inks-Ableitung) mit
max 1 Zeichen zurückschreiben

Top-Down Parsing


LL(1) erlaubt Parsing ohne Backtracking

- Beispiel *für* Bedarf an Backtracking am Wort c a d

$S \rightarrow c A d$

$A \rightarrow a b \mid a$

- Beginne mit Regel S, dann mit Links-Ableitungs-Regel parsen.



Backtracking!

Beim Lesen des nächsten Zeichens (d) wurde erkannt, dass es kein 'b' ist.

Top-Down Parsing ohne Backtrack: Predictive Parsing

Siehe Beispiel arithm. Ausdrücke (Links-Rekursion-Elimination):

```
S  --> E "#"          T  --> ...
E  --> T E'           ...
E' --> "+" T E' | epsilon
```

```
PROC parse() {
    expr();
    t = getToken();
    if (t != "#")
        error();
}
```

```
PROC expr() {
    term();
    exprCont();
}
```

```
PROC exprCont() {
    s = getToken();
    if (s != "+") {
        ungetToken(s);
        return;
    }
    term(); exprCont();
} ...
```

Predictive Parsing – Bewertung

Predictive Parser auch “recursive-descent parser” genannt.

- Wie unterscheidet sich ein solcher Akzeptor von den einfachen endlichen Automaten? → **Speicherplatz**
- Für DFA: 1 Zustandsvariable
- Für recursive-descent Parser:
 - Rekursion möglich
 - Speicherbedarf hängt vom Eingabewort ab!
 - “Stack” muss genügend gross sein

Formalisierung: Keller/Stapel-Automat mit beliebig grossem Stapel

Kontextfreie Sprache (Wiederholung)

Def: alle Grammatikregeln haben die Form

$V \rightarrow w_2, V \in \text{Nichtterminale}$ *Kontext von V (linke Seite) ist leer!*

Beispiel von vorher: Sprache $L = \{a^n b^n \mid n \geq 1\}$

Endlicher Automat kann die Anzahl der Klammern nicht speichern:

$S \rightarrow "(T)"$

$T \rightarrow S \mid \text{epsilon}$

aber mit einem Stapel (Stack) könnte es gehen.

Beispiel natürliche Sprache

<SENTENCE> → <NOUN-PHRASE><VERB-PHRASE>

<NOUN-PHRASE> → <CMPLX-NOUN> | <CMPLX-NOUN><PREP-PHRASE>

<VERB-PHRASE> → <CMPLX-VERB> | <CMPLX-VERB><PREP-PHRASE>

<PREP-PHRASE> → <PREP><CMPLX-NOUN>

<CMPLX-NOUN> → <ARTICLE><NOUN>

<CMPLX-VERB> → <VERB> | <VERB><NOUN-PHRASE>

<ARTICLE> → a | the

<NOUN> → boy | girl | flower

<VERB> → touches | likes | sees

<PREP> → with

Beispiel natürliche Sprache (Forts.)

Mit der Grammatik (vorangehendes Slides) kann abgeleitet werden:

a boy sees

the boy sees a flower

a girl with a flower likes the boy

Zeichne jeweils den Ableitungsbaum ...

Chomsky Normalform (CNF)

Definition:

Eine kontextfreie Grammatik ist in **Chomsky-Normalform**, falls jede der Regeln eine der folgenden Formen hat:

$A \rightarrow BC$, oder

$A \rightarrow a$, oder

$S \rightarrow \epsilon$

wobei

- A, B, C, S sind Variablen (Nicht-Terminale)
- a ist ein Terminalsymbol
- S ist die Startvariable, B und C sind *nicht* die Startvariable

Chomsky Normalform – Theorem

Jede kontextfreie Sprache ist durch eine Grammatik in Chomsky-Normalform erzeugt.

Beispiel

Die Sprache zur kontextfreie Grammatik

$$G = (\{A, B\}, \{0, 1, \#\}, R, A)$$

$$R = \{A \rightarrow 0A1, A \rightarrow B, B \rightarrow \#\}$$

wird auch durch diese Grammatik in CNF erzeugt:

$$G' = (\{A, B, C, N, E\}, \{0, 1, \#\}, R, S)$$

$$R = \{S \rightarrow NC, N \rightarrow 0, S \rightarrow \#, A \rightarrow NC, C \rightarrow AE, E \rightarrow 1, A \rightarrow \#\}$$

Chomsky Normalform – Technik

Ansatz: Umschreiben aller Regeln die nicht in CNF sind, allenfalls neue Variablen einführen. Vier Fälle:

1. Startvariable erscheint in rechter Seite:
 $\Rightarrow$ Führe “Ersatz- S_0 ” ein und eine Ableitungsregel dazu.
2. Epsilon-Regeln der Form $A \rightarrow \epsilon$
 $\Rightarrow$ Falls A in der rechten Seite der Regel auftritt, führe eine neue Regel ohne A auf der rechten Seite ein.
3. Einer-Regeln der Form $A \rightarrow B$
 $\Rightarrow$ ersetze B direkt durch seine eigene Produktion.
4. Lange und/oder gemischte Regeln: $A \rightarrow aBcAbA$
 $\Rightarrow$ neue (Zwischen-) Variablen und Regeln

Chomsky Normalform – Technik (II)

Beispiel für (den Beginn) der Transformationstechniken (Ansatz 1)

$$S \rightarrow ASA \mid aB$$

$$A \rightarrow B \mid S$$

$$B \rightarrow b \mid \epsilon$$

$$S_0 \rightarrow S$$

$$S \rightarrow ASA \mid aB$$

$$A \rightarrow B \mid S$$

$$B \rightarrow b \mid \epsilon$$

... und nun die beiden ϵ wegtransformieren

Bedeutung der CNF

- Der “Cocke-Younger-Kasami-Algorithmus” (CYK) erlaubt die Konstruktion des Parse-Trees zu einem gegebenen Wort.
- Voraussetzung for CYK: die Grammatik muss in CNF vorliegen.

Da die Grammatik jeder kontextfreien Sprache in CNF gebracht werden kann, ist das Wortproblem für kontextfreie Sprachen lösbar.

(Verallgemeinerung der CNF für kontextsensitive Sprachen:
Kuroda-Normalform)

Keller-Automat

Ansatz: endlicher Automat, der beliebig viele Symbole auf einem “Stack” (Stapel) zwischenlagern kann.

Theoreme: (ohne Beweis)

- a) Jede kontextfreie Sprache kann von einem *nicht-deterministischen* Keller-Automat akzeptiert werden.
- b) Nicht-deterministische Keller-Automaten akzeptieren gerade die kontextfreien Sprachen.

(Deterministische Keller-Automaten erkennen nur eine Teilmenge der kontextfreien Sprachen, aber mehr als die regulären Sprachen)

Def. eines Keller-Automaten (Push Down Automaton)

PDA = 6-Tupel $M = (Z, \Sigma, \Gamma, \delta, z_0, \#)$

Z endl. Zustandsmenge

Σ Eingabealphabet

Γ Keller-Alphabet


$\delta \quad Z \times (\Sigma \cup \{\epsilon\}) \times \Gamma \rightarrow$

Menge aller endl. Teilmengen von $Z \times \Gamma^*$

z_0 Startzustand

$\#$ Stapel-End-Symbol

Keller-Automat – graphische Darstellung



Keller-Automat – Abarbeitung

1. $\delta(z, a, A) \rightarrow (z', B_1 \dots B_n)$

“Push”: aus Zustand z , oberstes Stapelsymbol A und Input a ,
gehe in neuen Zustand z' und lege $B_1 \dots B_n$ auf den Stapel

2. $\delta(z, a, A) \rightarrow (z'', \{\})$ “Pop”: aus Zustand z , oberstes Stapelsymbol
 A und Input a ,

gehe in neuen Zustand z'' und entferne A vom Stapel

3. $\delta(z, \epsilon, A) \rightarrow (z''', \{\})$

“stille Transition”: aus Zustand z , oberstes Stapelsymbol A ,
gehe in neuen Zustand z''' ohne einen Input zu konsumieren.