

Praktische Informatik 3

Teil II - Compilerbau

Vorlesung des Grundstudiums
Prof. Dr. Joachim Fischer
Institut für Informatik, Humboldt-Universität zu Berlin
WS 2002 / 03

J. Fischer

Teil II: 2. Lexikalische Analyse (Forts.)

0.1

Teil II: Compilerbau 2. Lexikalische Analyse (Forts.)

Vorlesung des Grundstudiums
Prof. Dr. Joachim Fischer
Institut für Informatik, Humboldt-Universität zu Berlin
WS 2002 / 03

J. Fischer


Teil II: 2. Lexikalische Analyse (Forts.)

0.2

Überblick

- Reguläre Ausdrücke
- Endliche Automaten
 - deterministisch, nicht-deterministisch
 - Überführung
- Erzeugen und Erkennen regulärer Ausdrücke
- Architektur eines Scanners
- Praktische Aspekte eines Scanners
(Lex-Werkzeug)

Der Scanner (Wdh.)




Aufgaben eines Scanners

- Überführung von Zeichenketten des Quellcodes in **Token**
- Entfernung von Zwischenzeichen: Blank, Tab, Kommentare, ...
- Erkennung lexikalischer Fehler: illegale Zeichen in Token, ...
- Positionsermittlung von Symbolen im Quellprogramm: für Fehlerausschriften

Kurznotation Regulärer Ausdrücke (Wdh.)

a	gewöhnliches Zeichen
ε	leere Zeichenkette
s r	Alternative
s · r	Verkettung
sr	andere Schreibweise für Verkettung
s*	Wiederholung (null oder beliebig oft)
s+	Wiederholung (einmal oder beliebig oft)
s?	optionale Wiederholung (null oder einmal)
[a-zA-Z]	Zeichenalternative
.	jedes beliebige Zeichen (außer newline)
"a.+*"	Literal

Kombination von Einzela



Arbeitsweise des Automaten

- liegt in einem beliebigen Zustand (Startzustand, Zwischenzustand, Terminalzustand) ein akzeptables Eingabezeichen vor, wird
 - das Zeichen akzeptiert (d.h. konsumiert) und
 - der Folgezustand i.Abh. des akzeptierten Zeichens angenommen
- liegt ein nicht akzeptables Zeichen vor, sind folgende alternative Verhaltensformen des Automaten (im Unterschied zur theoret. Definition) möglich:
 - aktueller Zustand= Startzustand oder beliebiger Zwischenzustand
 - a) es gibt einen expliziten Übergang für "other" mit Fehlerbehandlungsprozedur
 - b) es gibt einen impliziten Übergang, der für den "Rest" in einen Fehlerzustand führt
 - aktueller Zustand= ERROR-Endzustand
 - unvollständige Token-Bildung, das Zeichen wird nicht konsumiert
 - explizite Fehlerbehandlungsprozedur
 - aktueller Zustand= Endzustand (kein ERROR)
 - Token- bzw. Eliminationstext-Bildung ist abgeschlossen, Ausgabe des Textes
 - das aktuelle Zeichen wird nicht konsumiert, der Automat stoppt

Vermeidung von Analyseproblemen (Wdh.)

wichtige Regeln beim Scanner-Bau

1. nächstes Token wird stets als maximale mögliche gültige Zeichenkette bestimmt
2. Die Bestimmung der Token-Klasse erfolgt entsprechend einer priorisierten Liste (d.h. Reihenfolge der RA ist signifikant)

Auswirkungen

- "if8" wird als Bezeichner erkannt: nach der 1.Regel
- "if 89" wird als Schlüsselwort erkannt: nach der 2.Regel

Tabelle für einen Scanner

- zwei Tabellen steuern den Scanner
- Zeichenklasse (char_class):


	a-z	0-9	other
value	letter	digit	other

- Zustandsübergangstabelle (next_state):

	1	2	3
letter	2	2	-
digit	3	2	-
other	3	-	-

- neue Sprache bedeutet neue Tabellen

Pseudoklasse
(kontextabhängig)



Vorteil: schneller Zugriff
Nachteil: Speicherplatz


Pseudocode für einen Scanner

```

char ← next_char();
state ← 1; /* code for state 1 */
done ← false;
token_value ← "" /* empty string */
while (not done) {
  class ← char_class[char];
  state ← next_state[class, state];
  switch (state) {
    case 2: /* building an id */
      token_value ← concatenate(token_value, char);
      char ← next_char();
      break;
    case 3: /* error */
      token_type ← error;
      done ← true;
      break;
    case -: /* accept state */
      token_type ← identifier;
      done ← true;
      break;
  }
}
  
```

Nichtdeterminierter Endlicher Zustandsautomat

- Nondeterministic Finite Automaton (NFA)




entweder in den linken oder rechten Teilgraphen

Bemerkung

- es ist einfacher NFAs zur Erkennung von RAs zu konstruieren als DFAs
- beide Automatentypen erkennen Sprachen, die sich mit regulären Ausdrücken beschreiben lassen
- Automaten lassen sich ineinander überführen
- es gibt Unterschiede beider Automatentypen für Ressourcenbedarf (Zeit, Speicher)

Übergänge in einem NFA

- Welcher FA erkennt den RA $(a|b)^*abb$?



- Zustand 0 hat mehrere Übergänge für a
⇒ nicht-deterministischer endlicher Automat (NFA)

$0 \xrightarrow{a} 0 \xrightarrow{a} 1 \xrightarrow{b} 2 \xrightarrow{b} 3 \dots$
 $0 \xrightarrow{a} 0 \xrightarrow{a} 0 \xrightarrow{b} 0 \xrightarrow{b} 0$
 viele Übergänge möglich, aber nur einer führt zur Akzeptanz

Definition eines NFA

Ein nicht-deterministischer endlicher Automat

$NFA = (S, \Sigma, T, s_0, F)$:

- Menge S von Zuständen: $S = \{s_0, \dots, s_n\}$
- Menge von Eingabesymbolen: Alphabet Σ
- Zustandsübergangsfunktion (Transition) T , die einem Zustand Folgezustände in Abh. des Eingabesymbols zuordnet (*Zustand, Symbol*)-Paare werden in *Zustandsmengen* überführt)
- ein ausgezeichnete Startzustand s_0
- eine Menge von akzeptierenden (End-) Zuständen F

Ein NFA akzeptiert eine Zeichenkette x , falls

- ein Pfad durch den Transitionsgraph existiert, der in s_0 beginnt und in einem Endzustand so endet, dass die Sequenz der durchlaufenden Kanten genau x ergibt

Spezialfall eines NFA: DFA

- Ein deterministischer endlicher Automat (DFA) ist ein Spezialfall eines NFAs:
 - es gibt keine ϵ -Transitionen (spontane Übergänge ohne Zeichen)
 - für jeden Zustand s und Eingabesymbol a existiert maximal eine Kante a , die s verlässt, d.h. für jedes (Zustand, Symbol)-Paar gibt es maximal einen neuen Zustand
- Ein DFA akzeptiert die Zeichenkette x , falls ein eindeutiger Pfad durch den Transitionsgraph existiert, der in s_0 beginnt und in einem Endzustand so endet, dass die Sequenz der durchlaufenden Kanten genau x ergeben

Abbildung von RAs zu NFAs

Wie konstruiert man einen NFA?

- man baut Einzelautomaten und
- fügt diese nach Vorschrift zusammen (beim DFA: nur ad-hoc)






Abbildung von RAs zu NFAs (2)






Abbildung von RAs zu NFAs (3)



M+ konstruiert als $M \cdot M^*$

M? konstruiert als $M \mid \epsilon$




'abc' konstruiert als $a \cdot b \cdot c$

Konstruktion eines NFAs (für nur vier RAs)



Konstruktion eines NFAs (für nur vier RAs)



Implementierung eines NFAs

- es ist einfacher, aus einem RA einen NFA zu konstruieren als einen DFA
- aber: Implementation eines NFA ist i.Allg. nicht effizient möglich
z.B. Einsatz von Backtracking-Verfahren
problematisch sind alternative Übergänge aus einem Zustand mit spontanen (ϵ -Transitionen) und Eingabe-getriebenen Übergängen
- besser: Umwandlung eines konstruierten NFA in einen DFA

Eigenschaften von FAs

DFA's und NFA's sind äquivalent (Theoretische Informatik)


- D.h. für jeden NFA gibt es einen DFA, der die gleiche Sprache erkennt und umgekehrt.

Warum?

- DFA's sind eine Untermenge von NFA's
- jeder NFA kann in einen DFA konvertiert werden, indem die gleichzeitig erreichten Zustände des NFA »simuliert« werden:
 - jeder Zustand im abgeleiteten DFA korrespondiert mit einer Menge an Zuständen im NFA


Überführung: NFA $\Rightarrow$ DFA

- Verfahren der Teilmengenkonstruktion
am Beispiel: $(a|b)^*abb$




Überführung NFA $\Rightarrow$ DFA

- Verfahren der Teilmengenkonstruktion




Überführung NFA $\Rightarrow$ DFA

- Verfahren der Teilmengenkonstruktion



Überführung NFA $\Rightarrow$ DFA


■ Verfahren der Teilmengenkonstruktion



	a	b
$\{s_0\}$	$\{s_0, s_1\}$	$\{s_0\}$
$\{s_0, s_1\}$	$\{s_0, s_1\}$	$\{s_0, s_2\}$
$\{s_0, s_2\}$	$\{s_0, s_1\}$	$\{s_0, s_3\}$

Überführung NFA $\Rightarrow$ DFA

■ Verfahren der Teilmengenkonstruktion




	a	b
$\{s_0\}$	$\{s_0, s_1\}$	$\{s_0\}$
$\{s_0, s_1\}$	$\{s_0, s_1\}$	$\{s_0, s_2\}$
$\{s_0, s_2\}$	$\{s_0, s_1\}$	$\{s_0, s_3\}$
$\{s_0, s_3\}$	$\{s_0, s_1\}$	$\{s_0\}$

Überführung NFA $\Rightarrow$ DFA (2)

	a	b
$\{s_0\}$	$\{s_0, s_1\}$	$\{s_0\}$
$\{s_0, s_1\}$	$\{s_0, s_1\}$	$\{s_0, s_2\}$
$\{s_0, s_2\}$	$\{s_0, s_1\}$	$\{s_0, s_3\}$
$\{s_0, s_3\}$	$\{s_0, s_1\}$	$\{s_0\}$


Jeder DFA-Zustand,
der mindestens einen Endzustand
des NFAs enthält,
wird zu einem Endzustand des DFAs



Konstruktion eines DFA von RE

- RA $\rightarrow$ NFA mit ϵ -Übergängen
 - Erzeuge NFA für jeden Teilausdruck
 - Verbinde mit ϵ -Übergängen
- NFA mit ϵ -Übergängen $\rightarrow$ DFA
 - Durch »Teilmengen«-Konstruktion
- DFA $\rightarrow$ minimierten DFA
 - Führe »kompatible« Zustände zusammen
- DFA $\rightarrow$ RA
 - Konstruiere $R_{ij}^k = R_{ik}^{k-1} (R_{kk}^{k-1})^* R_{kj}^{k-1} \cup R_{ij}^{k-1}$

Details s. Theoretische Informatik



NFA → DFA: Teilmengenkonstruktion

Eingabe: NFA **N**

Ausgabe: Ein DFA **D** mit Zuständen **D_Z** und Transitionen **D_T** mit $L(D) = L(N)$

Methode: Sei **s** ein Zustand in **N** und **T** eine Menge von Zuständen in **N**, dann benutze die folgenden Operationen:

Operation	Definition
ϵ -Hülle(s)	Menge aller NFA-Zustände, die vom NFA-Zustand s mit ϵ -Übergängen allein erreicht werden können
ϵ -Hülle(T)	Menge aller NFA-Zustände, die von einem NFA-Zustand s aus T allein mit ϵ -Übergängen erreicht werden können
move(T , a)	Menge aller NFA-Zustände, zu denen ein Übergang für das Eingabesymbol a von einem NFA-Zustand s aus T führt

NFA → DFA: Teilmengenkonstruktion (2)

Idee des Verfahrens:

- jeder Zustand des DFA entspricht einer Menge von Zuständen des NFA
- DFA merkt sich in seinen Zuständen alle möglichen Zustände, in denen sich der NFA nach Lesen von Eingabezeichen befinden kann,

d.h., der DFA befindet sich nach Eingabe von $a_1 a_2 \dots a_n$ in einem Zustand, der die Teilmenge **T** aller Zustände vom NFA bestimmt, die vom Startzustand des NFA entlang eines mit $a_1 a_2 \dots a_n$ markierten Pfades erreicht werden kann

Bemerkung

- Die Anzahl von DFA-Zuständen kann exponentiell größer sein, als die des NFA (Fall tritt aber in der Praxis kaum auf)

NFA → DFA: Teilmengenkonstr. (2)

- Algorithmus:

Anfangsschritt: ϵ -Hülle(s_0) bildet den Startzustand von **D**

Füge Zustände aus $T = \epsilon$ -Hülle(s_0) als unmarkierte Zustände **D_Z** hinzu

while es existieren noch unmarkierte Zustände **T** in **D_Z** **do**

markiere **T**;

for jedes Eingabesymbol **a do**

$U = \epsilon$ -Hülle(move(**T**,**a**));

if **U** nicht in **D_Z** **then** füge **U** als unmarkiert **D_Z** hinzu **endif**


$D_T[T, a] = U$

endfor

endwhile

- Ein Zustand von **D** ist ein Endzustand, falls er mindestens einen Endzustand aus **N** enthält

NFA → DFA: weiteres Beispiel



$A = \{0, 1, 2, 4, 7\}$

$B = \{1, 2, 3, 4, 6, 7, 8\}$


$C = \{1, 2, 4, 5, 6, 7\}$

$D = \{1, 2, 4, 5, 6, 7, 9\}$

$E = \{1, 2, 4, 5, 6, 7, 10\}$


	a	b
A	B	C
B	B	D
C	B	C
D	B	E
E	B	C

NFA → DFA: weiteres Beispiel (2)




Entwurf eines Scanner-Generators (Lex)

- Konstruktion eines Automaten ist eine automatisierbare Aufgabe



Entwurf eines Scanner-Generators (Lex)

- Konstruktion eines Automaten ist eine automatisierbare Aufgabe



Lex-Spezifikation (Überblick)

```

%{
/* C Declarations: */
#include "tokens.h" /*definitions of IF, ID, NUM, ...*/
#include "errmsg.h"
union {int ival; string sval; double fval;} yylval;
int charPos=1;
#define ADJ (EM_tokPos=charPos, charPos+=yyleng)
%}
  
```

1. Teil
Deklarationen

```

/* Lex-Definitions: */
digits [0-9]+ /* non-empty sequence of digits */
%%
  
```

2. Teil
• Abkürzungen
regulärer
Ausdrücke
• Zustands-
deklarationen

Lex-Spezifikation (Überblick-2)

```
/* Regular Expressions and Actions: */
if
[a-z][a-z0-9]*
{digits}
({digits}"[0-9]*")|([0-9]*)"{digits}
("--"[a-z]*"n")|(" |"n"|"t")+
.
{ADJ; return IF; }
{ADJ; yylval.sval= String(yytext);
return ID; }
{ADJ; yylval.ival= atoi(yytext);
return NUM; }
{ADJ; yylval.fval= atof(yytext);
return REAL; }
{ADJ;}
{ADJ; EM_error("illegal character");}
```

3. Teil RAs und Aktionen

- jede Aktion liefert return-Wert vom Tokentyp (Typ int)
- yytext ist Zeiger zum String (NULL-terminiert), der dem RA entspricht,
- Länge von yytext* ist yyleng
- charPos (Position des Token vom File-Beginn in Anzahl von char)
- EM_tokPos (aus errmsg.h: zählt Aufrufe von ADJ als Info für den Parser)
- yyval enthält semantische Werte eines Token

J. Fischer

Teil II: 2. Lexikalische Analyse (Forts.)

6.37

Lex-Spezifikation (Überblick- 3)

```
/* Regular Expressions and Actions: */
if
[a-z][a-z0-9]*
{digits}
({digits}"[0-9]*")|([0-9]*)"{digits}
("--"[a-z]*"n")|(" |"n"|"t")+
.
{ADJ; return IF; }
{ADJ; yylval.sval= String(yytext);
return ID; }
{ADJ; yylval.ival= atoi(yytext);
return NUM; }
{ADJ; yylval.fval= atof(yytext);
return REAL; }
{ADJ;}
{ADJ; EM_error("illegal character");}
```

3. Teil RAs und Aktionen

- jede Aktion liefert return-Wert vom Tokentyp (Typ int)
- yytext ist Zeiger zum String (NULL-terminiert), der dem RA entspricht,
- Länge von yytext* ist yyleng
- charPos (Position des Token vom File-Beginn in Anzahl von char)
- EM_tokPos (aus errmsg.h: zählt Aufrufe von ADJ als Info für den Parser)
- yyval enthält semantische Werte eines Token

J. Fischer

Teil II: 2. Lexikalische Analyse (Forts.)

6.38

Vordefinierte Bezeichner von Lex

int yylex(void)	Ruf des Lexers, liefert Token zurück
char *yytext	Zeiger zum String, das dem RA entspricht
yyleng	Länge des Strings, das dem RA entspricht
int yywrap(void)	Anwendung auf mehrere Files (1 falls fertig, 0 sonst)
FILE *yyout	Ausgabefile (default: stdout)
FILE *yyin	Inputfile (default: stdin)
INITIAL	initiale Startbedingung
BEGIN condition	Einschalten der Startbedingung
ECHO	Ausgabe des akzeptierten Strings

Lex-Beispiel: Zeilennummerierung

```
%{
/* C Declarations: */
int yylineno= 0;
}%
/* no Definitions */
%%
/* Regular Expressions and Actions: */
^.*\n { printf("%4d\t%s", ++yylineno, yytext); }
%%
int main (int argc, char *argv[]) {
    yyin= fopen(argv[1], "r");
    yylex();
    fclose(yyin);
    return 0;
}
```

- Jeder Input wird akzeptiert
- Einfügen von Zeilennummern in den Text

Lex-Beispiel: Zählen von Zeichen, ...

```
%{
/* C Declarations: */
int nchar, nword, nline;;
}%
%%
\n          {nline++; nchar++; }
[^\t\n]+    {nword++; nchar +=yyleng; } /* alle Zeichenketten, die kein Leerzeichen,
                                           Tabulator, Newline enthalten */
.           {nchar++; }
%%
int main (void) {
    yylex();
    printf("%d\t%d\t%d\n", n
    return 0;
}
```


- Jeder Input wird akzeptiert
- Einfügen von Zeilennummern in den Text

Möglicher Mix von Zuständen und RAs in Lex

- man kann eine Menge von Startzuständen deklarieren,
- jeder RA kann mit Menge von Startzuständen präfigiert sein, für die er gültig ist
- im Aktionsteil kann der Startzustand explizit geändert werden damit lassen sich Übergänge mit RA markieren (u. nicht nur mit Symbolen)
Effekt: abstraktere Automaten mit Wechsel von einem zum anderen

"Hierarchische" Automaten

- eigentlich Automaten auf gleicher Ebene



Fragen

