5.5 Aufsteigende Analyse

5. Syntaxanalyse und der Parser-Generator yacc

Absteigende Analyse versus aufsteigende Analyse

- Absteigende Analyse (top-down-Analyse)
  - Knoten des Ableitungsbaums werden von der Wurzel her konstruiert
  - leichter von Hand zu programmieren
    - „Praktische Informatik 2“
- Aufsteigende Analyse (bottom-up-Analyse)
  - Knoten des Ableitungsbaums werden von den Blättern her konstruiert
  - größere Klasse von Grammatiken
    - seltener Grammatiktransformation von Hand nötig
  - yacc

5.5 Aufsteigende Analyse

Prinzip der aufsteigenden Analyse

- „reduzieren“ des Eingabeworts auf das Startsymbol
  - Reduktionsschritt:
    - wenn: ein Teilwort = rechte Seite einer Regel
    - ersetze Teilwort durch Symbol auf linker Seite
  - richtige Wahl des Teilworts nötig
  - liefert Rechtsableitung in umgekehrter Reihenfolge
  - Name auch: „shift-reduce-Syntaxanalyse“

Prinzip: Beispiel

- Grammatik:
  - $s \rightarrow A\,a\,b\,E$
    $a \rightarrow a\,BC \mid B$ ← (ist übrigens keine LL-Grammatik!)
    $b \rightarrow D$
- Eingabe: ABBCDE
- Schritte:
  - ABBCDE
    A*a*BCDE
    A*a*DE
    A*ab*E
    s
- Rechtsableitung:
  $s \Rightarrow_r A\,a\,b\,E \Rightarrow_r A\,a\,DE \Rightarrow_r A\,a\,BCDE \Rightarrow_r ABBCDE$

Implementierung der aufsteigenden Analyse mit einem Stack

- Idee:
  - lies jeweils ein Zeichen und packe es oben auf den Stack
  - wenn ein passendes Muster im Stack steht, wende eine Grammatikregel rückwärts an
  - Stack:
    - repräsentiert die bisher gelesene Eingabe
    - bereits erkannte Teile sind zu Nichtterminalen verdichtet

Stack-Implementierung: Beispiel

Stack	Eingabe
	ABBCDE
A	BBCDE
AB	BCDE
A*a*	BCDE
A*a*B	CDE
A*a*BC	DE
A*a*	DE
A*a*D	E
A*ab*	E
A*ab*E	
s	

Grundoperationen eines Shift-Reduce-Parsers

1. schieben (shift)
   - nächstes Eingabesymbol → Stack
2. reduzieren (reduce)
   - Stack: oberste Symbole → Nichtterminal
3. akzeptieren
4. Fehler melden

- Satz:
  Beim Reduzieren reicht es, nur die obersten Symbole auf dem Stack zu betrachten
  - Beweis: Drachenbuch

Konflikte bei der Shift-Reduce-Syntaxanalyse

- Parser kann nicht entscheiden, was zu tun ist
  - obwohl er den ganzen Stack kennt
  - obwohl er das nächste Eingabesymbol kennt
    - bzw. k nächste Symbole bei LR(k)-Grammatik
- mögliche Konflikte:
  - schieben oder reduzieren?
    - shift/reduce-Konflikt
  - welche mehrerer Reduktionen?
    - reduce/reduce-Konflikt
- Grammatik ist dann nicht LR (bzw. LR(k))

Shift/Reduce-Konflikt: Beispiel

- mehrdeutige Grammatik:
  - *statement* ::= 'if' *expression* 'then' *statement*
    | 'if' *expression* 'then' *statement* 'else' *statement*
    | *other*
- aktuelle Parser-Konfiguration:

Stack	Eingabe
... 'if' *expression* 'then' *statement*	'else' ...

- 'else' schieben oder 4 Symbole reduzieren??
  - es gibt mehrere Parse-Bäume
  - mehrdeutige Grammatik ist niemals LR

Reduce/Reduce-Konflikt: Beispiel

- mehrdeutige Grammatik:
  - kinder ::= *maedchen* | *jungen*
    maedchen ::= KIRSTEN | BIRGIT | EIKE | KAI
    jungen ::= JAN | ULRICH | EIKE | KAI
  - gehört EIKE zu *maedchen* oder *jungen*??

Stack	Eingabe
... EIKE	...

Reduce/Reduce-Konflikt: Auflösung

- mögliche eindeutige Grammatik:
  - kinder ::= *maedchen* | *jungen* | *maedchenOderJungen*
    maedchen ::= KIRSTEN | BIRGIT
    jungen ::= JAN | ULRICH
    maedchenOderJungen ::= EIKE | KAI
  - ist *andere* Grammatik!

Absteigende Analyse versus aufsteigende Analyse (2)

- Parser muß rechte Seite einer Regel erkennen, wenn ...
  - aufsteigend, LR(k):
    ... alles gesehen, was von dieser Regel abgeleitet wird, plus k Symbolen Vorschau
  - absteigend, LL(k):
    ... die ersten k Symbole dessen gesehen, was von dieser Regel abgeleitet wird
    - daher LL(k)-Parser weniger mächtig

5.5 Aufsteigende Analyse

LR-Syntaxanalyse

- eine (von mehreren) aufsteigende Analysemethode
- yacc verwendet sie
  - genauer: LALR(1)
- LR(k)
  - **l**inks-nach-rechts lesen, **R**echtsableitung umgekehrt, Vorausschau um **k** Symbole
  - LR(1) = LR

LR-Syntaxanalyse: Eigenschaften

- fast allgemeinste Methode für kontextfreie Grammatiken
- allgemeinste bekannte aufsteigende Analyse ohne Backtracking
- erkennt Syntaxfehler an frühestmöglicher Stelle beim Lesen von links
- LR-Parser sehr aufwendig von Hand
  - Lösung: Parser-Generator

LR-Parser

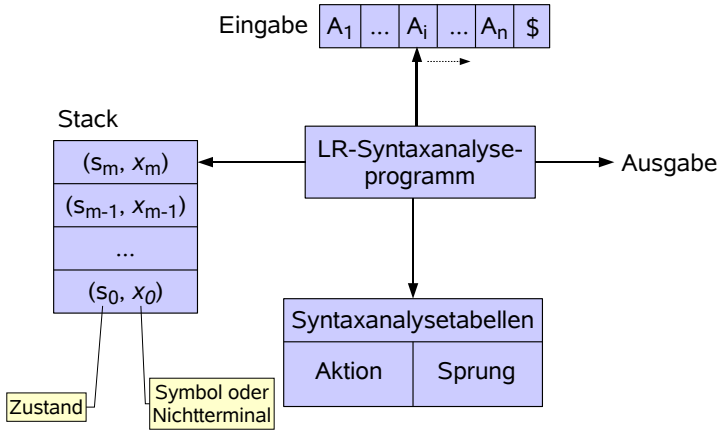

LR-Syntaxanalyseprogramm

- betrachtet
  - Zustand s_m oben auf Stack und
  - aktuelles Eingabesymbol A_i
- Aktion[s_m, A_i] kann sein
  - schiebe Zustand s
  - reduziere mit Regel $a \rightarrow \beta$
  - akzeptiere
  - Fehler
- Sprung
  - Zustand x Nichtterminal → Zustand
    - deterministischer endlicher Automat

Schiebe Zustand s

- liest ein Eingabesymbol A_i
- legt Zustand s und Eingabesymbol A_i auf Stack
  - neu: Zustand mit auf Stack
    - Zustand oben auf Stack repräsentiert *gesamten* Stack
    - deshalb kein Vergleich von Regeln mit Stack nötig!

Reduziere mit Regel $a \rightarrow \beta$

- Eingabe unverändert
- löscht |β| Symbole vom Stack
  - ohne sie anzusehen
  - s_f: freigelegter Zustand oben auf Stack
- legt Zustand Sprung[s_f, *a*] und Nichtterminal *a* auf Stack

Ausgabe des LR-Parsers

- nach Reduzier-Aktion
- durch semantische Aktion zur Syntaxregel
  - siehe später

Implementierung des Stacks

- für jedes Stackelement j gilt:
  Zustand s_j bestimmt eindeutig Symbol/Nichtterminal x_j
  - x_j muß nicht wirklich gespeichert werden

Algorithmus

- Initialisierung:
  - Stack: push((s_0, dummy)); (s_0: Parser-Startzustand)
  - Eingabezeiger: i := Anfang der Eingabe A;
- Schleife:
  - (s, *x*) := top;
  - **case** Aktion[s, A_i] **of**
    - „schiebe s' “: push((s', A_i)); i++;
    - „reduziere $a \rightarrow \beta$“:
      |β| **x** pop; (s_f, *y*) := top; push((Sprung[s_f, *a*], *a*));
    - „akzeptiere“: **return;**
    - **sonst: Fehler;**

Beispiel: Eindeutige Ausdrücke

1. $e \longrightarrow e + t$
2. $e \rightarrow t$
3. $t \rightarrow t * f$
4. $t \rightarrow f$
5. $f \rightarrow (e)$
6. $f \rightarrow$ ID

Syntaxanalysetabellen

Aktion

Zustand	Symbol					
	ID	+	*	(	)	$
0	s 5			s 4		
1		s 6				akz
2		r 2	s 7		r 2	r 2
3		r 4	r 4		r 4	r 4
4	s 5			s 4		
5		r 6	r 6		r 6	r 6
6	s 5			s 4		
7	s 5			s 4		
8		s 6			s 11	
9		r 1	s 7		r 1	r 1
10		r 3	r 3		r 3	r 3
11		r 5	r 5		r 5	r 5

Sprung

Zustand	Nichtterminal		
	e	*t*	*f*
0	1	2	3
1			
2			
3			
4	8	2	3
5			
6		9	3
7			10
8			
9			
10			
11			

Demo

Beispielablauf

	Stack	Eingabe	Aktion
1	(0,?)	ID * ID + ID $	schiebe 5
2	(0,?) (5,ID)	* ID + ID $	reduziere durch 6. $f \rightarrow$ ID
3	(0,?) (3,*f*)	* ID + ID $	reduziere durch 4. $t \rightarrow f$
4	(0,?) (2,*t*)	* ID + ID $	schiebe 7
5	(0,?) (2,*t*) (7,*)	ID + ID $	schiebe 5
6	(0,?) (2,*t*) (7,*) (5,ID)	+ ID $	reduziere durch 6. $f \rightarrow$ ID
7	(0,?) (2,*t*) (7,*) (10,*f*)	+ ID $	reduziere durch 3. $t \rightarrow t * f$
8	(0,?) (2,*t*)	+ ID $	reduziere durch 2. $e \rightarrow t$
9	(0,?) (1,*e*)	+ ID $	schiebe 6
10	(0,?) (1,*e*) (6,+)	ID $	schiebe 5
11	(0,?) (1,*e*) (6,+) (5,ID)	$	reduziere durch 6. $f \rightarrow$ ID
12	(0,?) (1,*e*) (6,+) (3,*f*)	$	reduziere durch 4. $t \rightarrow f$
13	(0,?) (1,*e*) (6,+) (9,*t*)	$	reduziere durch 1. $e \rightarrow e + t$
14	(0,?) (1,*e*)	$	akzeptiere

Das Beispiel mit bison (1)

- expr-unambig.l

```
%{
#include "expr-unambig.tab.h"
%}
%option noyywrap
%option nodefault
%%
"+"                     |
"*"                     |
"("                     |
")"                     { return *yytext; }
[[:alpha:]][[:alnum:]]* { return ID; }
[ \t]+                  /* ueberspringe White-Space */
\n                      { return 0; /* Nur eine Zeile lesen. */ }
.                       { return ILLEGAL_CHAR; }
```

Das Beispiel mit bison (2)

- expr-unambig.y

```
%{
#define YYERROR_VERBOSE
void yyerror(char *);
%}
%debug
%verbose
%token '+' '*' '(' ')' ID ILLEGAL_CHAR
%%
e:      e '+' t
;
e:      t
;
t:      t '*' f
;
t:      f
;
f:      '(' e ')'
;
f:      ID
;
%%
void yyerror(char *msg) {
    printf("\nEingabefehler: %s\n", msg);
}
int main() {
    yydebug = 1;
    return yyparse();
}
```


Das Beispiel mit bison (3)

- `%verbose`
  - erzeugt `expr-unambig.output` mit Informationen über generierten Parser
- YYERROR_VERBOSE
  - Parser gibt genauere Fehlermeldungen
- `%debug` und „`yydebug = 1`“ zusammen
  - schaltet Debug-Ausgabe ein

5.5 Aufsteigende Analyse

Idee der SLR-Methode

- Erinnerung:
  - Stack:
    - repräsentiert die bisher gelesene Eingabe
    - bereits erkannte Teile sind zu Nichtterminalen verdichtet
- Idee:
  - konstruiere endlichen Automaten, der einen korrekten verdichteten Stackinhalt erkennt

Idee der SLR-Methode (2)

- siehe Folie „Beispielablauf“ oben:
  - Zeile 13, während des Reduzierens:
    - Zustand s_f ist 0 (Startzustand)
    - Nichtterminal *e* wird auf leeren Stack gelegt
    - neuer Zustand: Sprung[0, *e*] = 1
  - Zeile 14:
    - Eingabe ist $
    - Aktion[1, $] = akz
  - Teilautomat dazu:

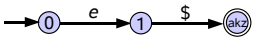

Idee der SLR-Methode (3)

- siehe Folie „Beispielablauf“ oben:
  - Zeile 12:
    - Stack enthält: <*e*, +, *f*>
    - Eingabe ist $
    - Zustände auf Stack: <0, 1, 6, 3>
    - Sprung[0, *e*] = 1, Aktion[1, +] = s 6,
      Sprung[6, *f*] = 3, Aktion[3, $] = r 4
  - Teilautomat dazu:

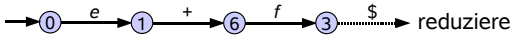

Idee der SLR-Methode (4)

- endlicher Automat *nicht* für Eingabewort
  - weil keine reguläre Menge
- endlicher Automat für verdichtetes Eingabewort auf Stack
- nichtdeterministisch
  - weil viele Teilautomaten zusammen„geklebt“ werden
    - z.B. (mind.) zwei Aktionen für „*e*“ in Zustand 0
- Stack von Zuständen/Automaten
  - für richtige Fortsetzung nach einem Verdichtungsschritt
    - kann *ein* endlicher Automat nicht

Idee der SLR-Methode (5)

- nichtdeterministischer EA
  → deterministischer EA
  - durch bekannte Potenzmengenkonstruktion

LR(0)-Element

- eine Regel mit einem Punkt irgendwo auf der rechten Seite
  - Intuition:
    - wieviel bereits von Regel gesehen
- Beispiele:
  - Regel: $a \rightarrow x\ y\ z$
  - LR(0)-Elemente:
    - $a \rightarrow \cdot\ x\ y\ z$
    - $a \rightarrow x \cdot y\ z$
    - $a \rightarrow x\ y \cdot z$
    - $a \rightarrow x\ y\ z \cdot$

Regel: $a \rightarrow \varepsilon$
LR(0)-Element:
$a \rightarrow \cdot$

Idee der SLR-Methode (6)

- ein LR(0)-Element: ein Zustand des NEA
- eine Menge von LR(0)-Elementen: ein Zustand des DEA
- Potenzmengenkonstruktion
  - wieder nötige Operationen:
    - Hülle (ε-Hülle)
    - Sprung („move“)
  - siehe Kapitel „lexikalische Analyse“

Idee der SLR-Methode (7)

- Konstruktion der Funktionen für „Aktion“ und „Sprung“:
  - mit den Ergebnissen dieser Operationen
  - Details: siehe „Drachenbuch“

LR(1)-Grammatik, die nicht SLR(1) ist

- Grammatik (Zuweisung in C)
  - $s \rightarrow l = r$
  - $s \rightarrow r$
  - $l \rightarrow * r$
  - $l \rightarrow$ ID
  - $r \rightarrow l$
- ist aber
  - nicht mehrdeutig
  - LALR(1)

Shift/Reduce-Konflikt:
Zustand 2 des DEA
mit LR(0)-Elementen
$s \rightarrow l \cdot = r$
$r \rightarrow l \cdot$
bei Eingabe „=“:
Schieben oder Reduzieren?
nicht genug Information in LR(0)-Elementen

Idee der kanonischen LR-Methode

- erweitere LR(0)-Element
  um ein zulässiges Vorschauzeichen
  zu „LR(1)-Element“
  - Zustände mit unterschiedlichem Vorschauzeichen werden getrennt
- Tabellen ca. 10 mal so groß
  - für Programmiersprache mit ca. 100 Regeln

Idee der LALR-Methode

- wie eben, aber
  identifiziere DEA-Zustände mit gleichem „Kern“
  - Kern:
    - Menge von LR(1)-Elementen für DEA-Zustand
      - LR(1)-Element: LR(0)-Element + Vorschauzeichen
    - Vorschauzeichen bei Kern-Vergleich ignoriert
      - Vorschauzeichen in DEA-Transitionen berücksichtigt
  - erzeugt nie Shift/Reduce-Konflikte
  - kann Reduce/Reduce-Konflikte erzeugen
- Tabellengröße: klein wie bei SLR
- für Programmiersprachen in der Regel ausreichend

5.5 Aufsteigende Analyse