

Compilerbau Vorlesung – Prof. Dr. K. Indermark –
Wintersemester 2002/03

geT_EX't von Matthias Hensler (matthias@wspse.de)

14. Februar 2003

Inhaltsverzeichnis

0	Einleitung	7
0.1	Definition (Compiler)	7
0.2	Aspekte einer Programmiersprache	7
0.3	Struktur eines Compilers	8
0.3.1	Analyse	8
0.3.2	Synthese	8
0.3.3	Frontend / Backend	8
1	Lexikalische Analyse	9
1.1	Scanner-Konstruktion	10
1.1.1	Das einfache Matching-Problem	11
	DFA-Methode	11
	NFA-Methode	12
1.1.2	Das erweiterte Matching-Problem	12
	Konventionen für Eindeutigkeit	12
	Berechnung der flm-Analyse	13
1.2	Praktische Aspekte der Scanner-Konstruktion	14
1.3	Automatische Scannergenerierung mit flex (lex)	15
1.3.1	Aufbau einer Lex-Spezifikation	15
	Definitionen (optional)	15
	Regeln	15
1.3.2	Verwandte Probleme	15
2	Syntaktische Analyse	23
2.1	Kontextfreie Grammatiken	23
2.1.1	l -Analyse, r -Analyse	24
2.1.2	Syntaxanalyse	25
2.2	Top-Down Analyse mit $LL(k)$ -Grammatiken	25
2.2.1	Berechnung der la-Mengen	29
2.2.2	Der deterministische TD-Analyseautomat $DTA(G)$ für $G \in LL(1)$	30
2.3	Parserkonstruktion nach TD-Methode	31
2.3.1	Transformationen nach $LL(1)$	31
	Beseitigung von Linksrekursionen	31
	Komplexität der $LL(1)$ -Analyse	32
	Links-Faktorisieren	33
2.4	Top-Down Analyse mit rekursiven Prozeduren	33

2.4.1	Analyseverfahren durch rekursiven Abstieg (ohne la-Mengen)	33
2.4.2	Zusätzliche Verwendung der la-Mengen	33
2.5	Bottom-Up Analyse mit $LR(k)$ -Grammatiken	33
2.5.1	Nicht-Determinismus	34
2.5.2	$LR(0)$ -Grammatiken	35
	Berechnung der $LR(0)$ -Mengen einer Grammatik	35
	Die <u>goto</u> -Funktion	36
	Berechnung der $LR(0)$ -Mengen und <u>goto</u> -Funktion durch Potenzmengenkonstruktion nicht-deterministischer endlicher Automaten	36
	Konstruktion des deterministischen BU-Analyseautomaten für $G \in LR(0)$	36
2.5.3	$SLR(1)$ -Analyse	37
	Die $SLR(1)$ -action Funktion	38
2.5.4	$LR(1)$ -Analyse	38
	Berechnung der $LR(1)$ -Mengen	39
	Die $LR(1)$ -action Funktion von G	39
2.5.5	$LALR(1)$ -Analyse	39
	Die $LALR(1)$ -action Funktion von G	40
2.6	Bottom-Up Analyse mehrdeutiger Grammatiken	40
2.7	Ergebnis	41
3	Semantische Analyse, Attributgrammatiken	71
3.1	Attributgrammatiken	71
3.1.1	Lösbarkeit von E_t	74
3.1.2	Ein Zirkulartest für Attributgrammatiken	74
	Komplexität des Zirkulartest	75
3.1.3	Stark-nichtzirkuläre Grammatiken	75
3.1.4	Attributberechnung	76
3.2	S-Attributgrammatiken	76
3.3	L-Attributgrammatiken	78
3.3.1	Syntaxanalyse mit L-Attributauswertung	78
3.3.2	Anwendung von LAG	79
4	Übersetzung in Zwischencode	87
4.1	Übersetzung von Ausdrücken, Anweisungen, Blöcken und Prozeduren	87
4.1.1	Semantik von BPS	88
4.1.2	Zwischencode für BPS	88
	Berechnung des statischen Verweises	89
4.1.3	Übersetzung von BPS-Programmen in AM-Code	90
	Aufbau der Symboltabelle	90
	Anfangstabelle	91
4.1.4	Die Übersetzung	91
	Blockübersetzung	92
	Deklarationsübersetzung	92
	Anweisungsübersetzung	92
4.1.5	Jumping Code für boolesche Ausdrücke	94
4.1.6	Prozeduren mit Parametern	95
	Alternative zur Verweiskettentechnik: Display-Technik	96

4.2	Übersetzung von Datenstrukturen	97
4.2.1	Statische Datenstrukturen	97
	Erläuterung der Symboltabelle	97
	Aufbau einer Symboltabelle	98
4.2.2	Dynamische Datenstrukturen	99
5	Exkurs: Yacc	129
5.1	Automatische Parsergenerierung mit Yacc	129
5.1.1	Aufbau einer Yacc-Spezifikation	129
5.2	Behandlung von Konflikten in Yacc	130
5.3	Präzedenz von Operatoren in Yacc	131
5.3.1	Exkurs: Kodierung der Präzedenzregeln für arithmetische Ausdrücke über der Grammatik	131

Kapitel 0

Einleitung

0.1 Definition (Compiler)

Ein Compiler ist ein Programm zur Übersetzung von *PS-Programmen* (Quellprogramme) in äquivalente *MS-Programme* (Zielprogramme). Wir fordern hierbei, daß der Compiler korrekt arbeitet.

PS bezeichne hierbei eine höhere Programmiersprache, bei denen wir folgende Typen unterscheiden:

imperative PS: Variablen, Wertzuweisungen, Kontrollstrukturen, Datenstrukturen

deklarative PS: funktionale und logische Sprachen (→ Vorlesung „Formale Sprachen“)

nebenläufige PS: kommunizierende Prozesse, verteilte Systeme

objektorientierte PS: Klassen, Vererbung

Wir betrachten hier *imperative* Programmiersprachen.

MS bezeichne die Maschinensprache auf dem Grundkonzept des *von-Neumann-Rechners*. Die Menge der elementaren Maschinenbefehle lassen sich dabei wie folgt aufteilen:

RISC: Reduced Instruction Set Computer

CISC: Complex Instruction Set Computer

0.2 Aspekte einer Programmiersprache

1. *Syntax:* formaler hierarchischer Aufbau eines Programms aus strukturellen Komponenten
2. *Semantik:* Bedeutung eines Programms, Zustandstransformation einer abstrakten Maschine
3. *Pragmatik:* benutzerfreundliche Formulierung, natürliche Sprache, Maschinenabhängigkeiten (compiler options)

Definition: Äquivalenz von Programmen: Zwei Programme sind äquivalent, wenn sie semantisch gleich sind.

0.3 Struktur eines Compilers

Ein Compiler ist in logisch unabhängige Phasen aufgeteilt, die aber verzahnt als *Passes* (Läufe) ablaufen. Wir unterscheiden die *Analysephase* und die *Synthesephase*. Eine Übersicht über das Zusammenspiel der einzelnen Phasen gibt Abbildung 1.1.

0.3.1 Analyse

Bei der Analyse wird die syntaktische Struktur bestimmt und Fehler erkannt. Sie wird unterteilt in folgende Schritte:

lexikalische Analyse: Erkennung von Symbolen, Trennzeichen und Kommentaren (implementierbar durch endliche Automaten)

syntaktische Analyse: Erkennung des hierarchischen Programmaufbaus, Ableitungsbaum (implementierbar durch Kellerautomaten)

semantische Analyse: Kontextabhängigkeiten, statische Semantik, Typinformationen, Attributierung des Ableitungsbaums

0.3.2 Synthese

Die Synthese erzeugt MS-Code aus dem attributierten Ableitungsbaum, und läßt sich in die folgenden Schritte unterteilen:

Zwischencodeerzeugung: Übersetzung in Zwischencode für eine abstrakte Maschine (kann auch fehlen, erhöht bei Vorhandensein die Portabilität)

Optimierung: Verbesserung von Laufzeit und Speicherbedarf

Codegenerierung: effiziente Verwendung von Registern und MS-Befehlssatz zur Erzeugung von MS-Code

0.3.3 Frontend / Backend

Beim Compiler unterscheiden wir zwischen dem *Frontend*, welches MS-unabhängig arbeitet und dem MS-abhängigen *Backend*. Das Frontend ist zuständig für die Analyse und die Zwischencodeerzeugung. Ggf. wird eine MS-unabhängige Optimierung vorgenommen. Das Backend schließlich generiert dann den MS-Code und nimmt MS-abhängige Optimierungen vor.

Definition: One-Pass, n -Pass-Compiler: Anzahl der Läufe durch das Quellprogramm

Kapitel 1

Lexikalische Analyse

Ausgangspunkt: Quellprogramm P als Zeichenfolge, mit:

- Σ_0 : Zeichensatz (ASCII, Unicode)
- $a \in \Sigma_0$: Zeichen, lexikalisches Atom
- $P \in \Sigma_0^*$: Quellprogramm

P besitzt aufgrund der Pragmatik von PS eine *lexikalische Struktur*:

- natürliche Sprache für Bezeichner/Schlüsselwörter
- mathematische Formelsprache für Zahlen, Formeln
- Leerzeichen, Zeilenwechsel, Einrückungen (Tabulatoren), ...
- Kommentare

Die Semantik von P und damit die Übersetzung ist syntaxorientiert: sie folgt dem hierarchischen Programmaufbau. Dabei ist der pragmatische Aspekt irrelevant.

1. Beobachtung: Syntaktische Atome (*Symbole*) werden dargestellt als Folgen lexikalischer Atome, sogenannter *Lexeme*. Die erste Aufgabe der lexikalischen Analyse ist damit die Zerlegung des Quellprogramms P in eine Folge von Lexemen.

2. Beobachtung: Für die syntaktische Analyse ist der Unterschied von Lexemen oft irrelevant (z.B. Bezeichner). Lexeme werden daher zu *Symbolklassen* zusammengefaßt. Diese Symbolklassen werden dann als *Token* dargestellt.

1. Aufgabe: Zerlegung des Quellprogramms in eine Folge von Lexemen.

Die syntaktische Analyse bearbeitet eine Tokenfolge. Ein Symbol wird durch ein zusätzliches *Attribut* für die semantische Analyse und die Codegenerierung identifiziert. Symbol = (Token, Attribut).

2. Aufgabe: Transformation einer Lexem-Folge in eine Symbolfolge.

Definition: Lexikalische Analyse: Zerlegung eines Quellprogramms in eine Folge von Lexemen und deren Transformation in eine Folge von Symbolen.

Definition: *Scanner:* Der Scanner ist ein Programm für die lexikalische Analyse (siehe 1.2).

Wichtigste Symbolklassen:

- *Bezeichner*
- *Zahlwörter*
- *Schlüsselwörter*
- *Einfache Symbole:* ein Sonderzeichen (+, -, *, (, ,, ;, ...), bilden jeweils eine Symbolklasse
- *Zusammengesetzte Symbole:* Folge von zwei oder mehr Symbolzeichen (: =, **, < =, ...), bilden ebenfalls eine Symbolklasse
- *Leerzeichen:* $\sqcup, \sqcup \dots \sqcup, \dots$
- *Spezielle Symbole:* Kommentare, Pragmas von Compileroptions

Definition: *Token:* *id, const, divsym, semsym, leer*

Definition: *Attribute:* Zeiger in Symboltabelle, Binärdarstellung einer Zahl

Feststellung: Symbolklassen sind reguläre Mengen \rightarrow Beschreibung durch reguläre Ausdrücke; Erkennung durch endliche Automaten. Automatische Scannergenerierung, z.B. `lex` (UNIX).

1.1 Scanner-Konstruktion

Definition: reguläre Ausdrücke: Für ein Alphabet Σ ist die Menge $RA(\Sigma)$ der regulären Σ -Ausdrücke definiert durch:

- $\Lambda \in RA(\Sigma), \Sigma \subseteq RA(\Sigma)$
- $\alpha, \beta \in RA(\Sigma) \curvearrowright (\alpha \vee \beta), (\alpha \cdot \beta), (\alpha^*) \in RA(\Sigma)$

Ihre Semantik:

- $\llbracket \cdot \rrbracket : RA(\Sigma) \rightarrow \mathfrak{p}(\Sigma^*)$
- $\llbracket \Lambda \rrbracket := \emptyset$
- $\llbracket a \rrbracket := \{a\}$
- $\llbracket \alpha \vee \beta \rrbracket := \llbracket \alpha \rrbracket \vee \llbracket \beta \rrbracket$
- $\llbracket \alpha \cdot \beta \rrbracket := \llbracket \alpha \rrbracket \cdot \llbracket \beta \rrbracket$
- $\llbracket \alpha^* \rrbracket := \llbracket \alpha \rrbracket^* = \bigcup_{n=0}^{\infty} \llbracket \alpha \rrbracket^n$
- $\llbracket \Lambda^* \rrbracket := \llbracket \Lambda \rrbracket^* = \emptyset^*$
- $L^* = \bigcup_{n=0}^{\infty} L^n, L^n = \{w_1 w_2 \dots w_n \mid w_i \in L\} = \overbrace{L \cdot L \cdot L \cdot \dots \cdot L}^n$

- $L^n \cdot L^m = L^{n+m}, L^0 \cdot L^m = L^m, L^0 := \{\epsilon\}$
 - Spracherweiterung von $RA(\Sigma)$ zur einfacheren Beschreibung von Symbolklassen
- a. Vereinfachende Bezeichnungen:
- Präzedenzregeln zur Vermeidung von Klammern: $* > \cdot > \vee$ ($*$ bindet stärker als \cdot)
 - \cdot und \vee sind linksassoziativ
 - \cdot wird weggelassen, $|$ statt \vee
 - *Beispiel:* $(a \vee ((b^*) \cdot c))$, einfacher: $a|b^*c$
 - Abkürzungen:
 - $\alpha^+ := \alpha\alpha^*$ („einmal oder mehrmals“)
 - $\alpha? := \alpha|\Lambda^*$ („einmal oder keinmal“)
 - $[abc] := a|b|c$
 - $[a-z] := a|b|c|\dots|z$
- b. Reguläre Definitionen: Schrittweise Beschreibung von Symbolklassen durch zusätzliche frei-gewählte Bezeichner. \vdots
- $$\underline{id}_1 = \alpha_1 \quad \text{mit } \underline{id}_1, \dots, \underline{id}_n \notin \Sigma$$
- $$\underline{id}_n = \alpha_n \quad \text{und } \alpha_i \in RA(\Sigma \cup \{\underline{id}_1, \dots, \underline{id}_{i-1}\})$$

1.1.1 Das einfache Matching-Problem

Entscheide für $\alpha \in RA(\Sigma)$ und $w \in \Sigma^*$ ob $w \in \llbracket \alpha \rrbracket$ oder $w \notin \llbracket \alpha \rrbracket$. Hilfsmittel hierzu sind endliche Automaten

$$\mathfrak{A} = \langle Q, \Sigma, \delta, q_0, F \rangle \in \text{NFA}(\Sigma)$$

mit $\delta: Q \times (\Sigma \cup \{\epsilon\}) \rightarrow \mathfrak{p}(Q)$ (Epsilon-Transitionen sind zugelassen)

Für $T \subseteq Q$ ist die ϵ -Hülle $\epsilon(T)$ definiert durch

- $T \subseteq \epsilon(T)$
- $q \in \epsilon(T) \curvearrowright \delta(q, \epsilon) \subseteq \epsilon(T)$

DFA-Methode

$$\alpha \in RA(\Sigma) \xrightarrow{(1)} \mathfrak{A}(\alpha) \in \text{NFA}(\Sigma) \xrightarrow{(2)} \mathfrak{A}(\alpha)^P \in \text{DFA}(\Sigma)$$

- (1) Methode von Thompson (Satz von Kleene), linearer Platz und Zeitbedarf
 (2) Potenzmengenkonstruktion, exponentieller Platz und Zeitbedarf

Trotz aufwendiger Konstruktion, entscheidet $\mathfrak{A}(\alpha)^P$ in $|w| + 1$ Schritten ob $w \in \llbracket \alpha \rrbracket$ oder nicht.

NFA-Methode

Die NFA-Methode verbessert den Platzbedarf, benötigt dafür jedoch eine längere Laufzeit. Der Automat wird in Bezug auf die zu prüfende Eingabe w konstruiert, durch Verzicht auf volle Potenzmengen-Konstruktion. Da die Eingabe $w \in \Sigma^*$ bekannt, reicht die Potenzmengen-Konstruktion für den „Lauf von w durch $\mathfrak{A}(\alpha)$ “.

Der Algorithmus ist in Abbildung 1.4 gegeben.

Die Komplexität des Algorithmus ist wie folgt gegeben:

Platz: $O(|\alpha| + |w|)$

Zeit: $O(|\alpha| \cdot |w|)$

1.1.2 Das erweiterte Matching-Problem

Definition: Seien $\alpha_1, \dots, \alpha_n \in RA(\Sigma)$ und $w \in \Sigma^*$. Sei ferner $\Delta := \{T_1, \dots, T_n\}$ ein Alphabet von Token. Wenn $w = w_1 w_2 \dots w_k$ und $w_j \in \llbracket \alpha_{i_j} \rrbracket$ für $j = 1 \dots k$, dann heißt (w_1, \dots, w_k) eine Zerlegung von w bezüglich $\alpha_1, \dots, \alpha_n$ und $v = T_{i_1} \dots T_{i_k}$ eine Analyse von w bezüglich $\alpha_1, \dots, \alpha_n$. v repräsentiert die lexikalische Struktur von w bezüglich $\alpha_1, \dots, \alpha_n$.

Aufgabe: Analyse bestimmen bzw. Fehler melden.

Weder die Analyse noch die Zerlegung sind eindeutig bestimmt.

Konventionen für Eindeutigkeit

1. Prinzip des längsten Match (*maximal munch*) für die Eindeutigkeit der Zerlegung.

Definition: Eine Zerlegung (w_1, \dots, w_k) von w bezüglich $\alpha_1, \dots, \alpha_n$ heißt *lm-Zerlegung* („longest match“), wenn für alle $j = 1 \dots k$ und $x, y \in \Sigma^*$ und $p, q \in \{1, \dots, n\}$ gilt:

$$w = w_1 w_2 \dots w_j x y, w_j \in \llbracket \alpha_p \rrbracket, w_j x \in \llbracket \alpha_q \rrbracket \curvearrowright x = \varepsilon$$

Folgerung: Für $w, \alpha_1, \dots, \alpha_n$ gibt es höchstens eine lm-Zerlegung.

2. Prinzip des ersten Match für die Eindeutigkeit der Analyse.

Trotz der Eindeutigkeit der lm-Zerlegung sind mehrere Analysen möglich, weil $\llbracket \alpha_p \rrbracket \cap \llbracket \alpha_q \rrbracket \neq \emptyset$ möglich.

Konvention: der erste Match in der Folge $\alpha_1, \dots, \alpha_n$ zählt.

Definition: Sei (w_1, \dots, w_k) eine lm-Zerlegung und $v = T_{i_1} \dots T_{i_k}$ eine (zugehörige) Analyse von w bezüglich $\alpha_1 \dots \alpha_k$. Dann heißt v eine *flm-Analyse* („first longest match“), falls für alle $j = 1, \dots, k$ und $i = 1, \dots, n$ gilt:

$$w_j \in \llbracket \alpha_i \rrbracket \curvearrowright i_j \leq i$$

Folgerung: Für $w, \alpha_1, \dots, \alpha_n$ gibt es höchstens eine flm-Zerlegung. Sie existiert genau dann, wenn die lm-Zerlegung existiert.

Berechnung der flm-Analyse

Voraussetzung: $\alpha_1, \dots, \alpha_n \in RA(\Sigma)$, o.B.d.A. $\varepsilon \notin \llbracket \alpha_i \rrbracket \neq \emptyset$, für $i = 1, \dots, n$

$w \in \Sigma^*$

$\Delta = \{T_1, \dots, T_n\}$

1. Konstruiere für $i = 1, \dots, n$: $\mathfrak{A}_i = \langle Q_i, \Sigma, \delta_i, q_0^{(i)}, F_i \rangle \in \text{DFA}(\Sigma)$, so daß $\llbracket \alpha_i \rrbracket = L(\mathfrak{A}_i)$
2. Bilde aus diesen den Produktautomaten $\mathfrak{A} = \langle Q, \Sigma, \delta, q_0, F \rangle \in \text{DFA}(\Sigma)$, mit

$$\begin{aligned} Q &:= Q_1 \times \dots \times Q_n \\ q_0 &:= (q_0^{(1)}, \dots, q_0^{(n)}) \\ \delta((q^{(1)}, \dots, q^{(n)}), a) &:= (\delta_1(q^{(1)}, a), \dots, \delta_n(q^{(n)}, a)) \\ (q^{(1)}, \dots, q^{(n)}) \in F &: \curvearrowright \exists i \in \{1, \dots, n\}, q^{(i)} \in F_i \end{aligned}$$

Dann gilt: $L(\mathfrak{A}) = \bigcup_{i=1}^n \llbracket \alpha_i \rrbracket$

Zerlege F wegen der Eigenschaft „first match“ in $F = \bigcup_{i=1}^n F^{(i)}$ durch die Forderung

$$(q^{(1)}, \dots, q^{(n)}) \in F^{(i)} : \curvearrowright q^{(i)} \in F_i \text{ und } q^{(j)} \notin F_j \forall 1 \leq j < i$$

Dann gilt:

$$\bar{\delta}(q_0, w) \in F^{(i)} \curvearrowright w \in \llbracket \alpha_i \rrbracket \text{ und } w \notin \bigcup_{j=1}^{i-1} \llbracket \alpha_j \rrbracket$$

Definition: $q \in Q$ heißt *produktiv* : $\curvearrowright \exists v \in \Sigma^* : \bar{\delta}(q, v) \in F$

3. Erweitere $\mathfrak{A} = \langle Q, \Sigma, \delta, q_0, F \rangle$ zu dem *Backtrack-DFA* \mathfrak{B} mit Ausgabe.

Idee: Einweg-Leseband mit zwei Köpfen:

- Backtrack Kopf b zur Markierung eines Matches
- Lookahead-Kopf l zur Bestimmung des längsten Matches

Konfigurationsmenge von \mathfrak{B} : $\underbrace{(\{N\} \cup \Delta)} \times \underbrace{\Sigma^* Q \Sigma^*} \times \underbrace{\Delta^* \{\varepsilon, \text{lexerr}\}}$

Anfangskonfiguration für $w \in \Sigma^*$: $(N, q_0 w, \varepsilon)$

Transitionen: $q' := \delta(q, a)$

(a) normal mode (Match suchen):

$$(N, qaw, W) \vdash \begin{cases} (N, q'w, W) & \text{falls } q' \in P \setminus F \\ (T_i, q'w, W) & \text{falls } q' \in F^{(i)} \\ \text{Ausgabe : } W \cdot \text{lexerr} & \text{falls } q' \notin P \end{cases}$$

(b) backtrack mode (längsten Match suchen):

$$(T, vqaw, W) \vdash \begin{cases} (T, vaq'w, W) & \text{falls } q' \in P \setminus F \\ (T_i, q'w, W) & \text{falls } q' \in F^{(i)} \\ (N, q_0vaw, WT) & \text{falls } q' \notin P \end{cases}$$

(c) Eingabeende

$$\begin{array}{lll} (N, q, W) & \vdash & \text{Ausgabe : } W \cdot \text{lexerr} \quad \text{falls } q \in P \setminus F \\ (T, q, W) & \vdash & \text{Ausgabe : } W \cdot T \quad \text{falls } q \in F \\ (T, vaq, W) & \vdash & (N, q_0va, WT) \quad \text{falls } q \in P \setminus F \end{array}$$

Dann gilt für $w \in \Sigma^*$:

$$\begin{array}{lll} (N, q_0w, \varepsilon) & \vdash^* & W \in \Delta^* \quad \curvearrowright \quad W \text{ ist flm} - \text{Analyse von } w \\ (N, q_0w, \varepsilon) & \vdash^* & W \cdot \text{lexerr} \quad \curvearrowright \quad \text{es gibt keine flm} - \text{Analyse von } w \end{array}$$

Der Zeitaufwand beträgt im worst-case $O(|w|^2)$.


Beispiel: $\alpha_1 = abc \quad \alpha_2 = (abc)^* \quad w = (abc)^m d$ erfordert $O(m^2)$ Schritte.

1.2 Praktische Aspekte der Scanner-Konstruktion

- Spracherweiterung von $RA(\Sigma)$: Abkürzungen, reguläre Definition.
- Scannereffizienz wichtig: häufiger Aufruf des Scanners bei der syntaktischen Analyse durch „nexttoken“.
 - Programmierung des Scanners in Assembler
 - Erzeugung durch Scannergenerator (z.B. lex)
- Prinzip des längsten Match. Allgemein: beliebig langer Lookahead (Backtrack erforderlich). Lookahead von 1 Zeichen in Pascal, allerdings kann diese Beschränkung die lexikalische Analyse verändern.
- Besondere Rolle von „blanks“ (Whitespace): Trennung von eigentlichen Lexemen, um mit 1-lookahead auszukommen.
- Attributberechnung:
 - erneutes Lesen des Eingabestrings
 - Dezimalzahl \rightsquigarrow Binärzahl (Lex: install_num)
 - Bezeichner: Gleichheit prüfen, Symboltabelle (Lex: install_id)
 - Schlüsselwörter (alternativ) zunächst als Bezeichner behandeln, Symboltabelle mit Schlüsselwörtern initialisieren. Die Attributberechnung (install_id) liefert dann den Schlüsselwerttoken (z.B. (if,) statt (id, \rightarrow SymTab)

1.3 Automatische Scannergenerierung mit flex (lex)

Linux: > man flex, Unix-Tool



Programm $\xrightarrow{\text{a.out}}$ Symbolfolge

1.3.1 Aufbau einer Lex-Spezifikation

Definitionen

%%

Regeln

%%

C Hilfsprozeduren

Definitionen (optional)

1. Direkter C-Code `%{...C-Code ...}%{`
2. Substitutionen (reguläre Definition)
3. Startzustände

Regeln

muster {aktion}

muster von der Form `regex[/regex]`

aktion: C-Code zur Berechnung von i Token, $Attr_i$

Finden der passenden Regel:

- longest match
- first match
- kein match \longrightarrow abfangen mit `|\n ~\rightarrow` Fehlerausgabe

Token werden als ganze Zahlen kodiert. *Attribute* werden über die globale Variable `yyval` weitergeleitet. Am Fileende wird die benutzerdefinierte Prozedur „`int yywrap (void)`“ aufgerufen. Beim Rückgabewert 1 liefert lex eine „0“ um zu charakterisieren, daß kein Token mehr folgt. Ist der Rückgabewert 0, so scannt lex weiter.


1.3.2 Verwandte Probleme

Teilwortsuche in Texten, Dokumenten, Dateien

Beispiel: (Unix) **g**rep: **G**et **R**egular **E**xpression **P**rint


Syntax: `grep expr files`

Ausgabe: Zeilen der Dateien, in denen ein Match von `expr` vorkommt.



CB 1-1

Abbildung 1.1: Struktur eines Compilers



CB 1-2

Abbildung 1.2: Scanner

Beispiel: Pascal / Teil 1: Symbolklassen

- **Bezeichner:** letter = [A-Za-z]
 digit = [0-9]
 id = letter (letter | digit)*
- **Zahlwörter:** digits = digit+
 (ohne Vorzeichen) optfrac = (digits)?
 optexp = (E[+-]? digits)?
 num = digits optfrac optexp
- **Relat. Oper.:** relop = < | <= | = | <> | > | >=
- **Schlüsselwörter:** if = if
 then = then
 else = else
- **Zwischenraum:** blank = [\t \n]
 blanks = blank+

CB 1-3

Abbildung 1.3: Symbolklassen in Pascal, Teil I


NFA-Methode

```
T :=  $\epsilon(\{q_0\})$ ;  
a := nextchar;  
while a  $\neq$  eof do  
    T :=  $\epsilon(\bigcup_{q \in T} \delta(q, a))$ ;  
    a := nextchar;  
endwhile  
if T  $\cap$  F  $\neq \emptyset$  then ACCEPT  
    else REJECT
```

CB 1-4

Abbildung 1.4: NFA-Methode

Beispiel: Pascal / Teil 2: DFA's (partiell)



CB 1-5

Abbildung 1.5: Pascal, Teil II

Reguläre Ausdrücke in `lex`

Syntax	Semantik
normale Zeichen	das Zeichen
<code>\n, \t, \123, etc.</code>	wie in C
<code>.</code>	alle Zeichen außer <code>\n</code>
<code>[Zeichen]</code>	eins der <i>Zeichen</i> ; Bereiche 0-9 mögl.
<code>[^Zeichen]</code>	keins der <i>Zeichen</i>
<code>\\, \., \[, etc.</code>	<code>\, ., [, etc.</code>
<code>"Text"</code>	<i>Text</i> ohne Interpr. von <code>.</code> , <code>[</code> , <code>\</code> , etc.
<code>^</code>	als 1. Zeichen eines RA: Zeilenanfang; verbraucht kein Zeichen
<code>\$</code>	als 1. Zeichen eines RA: Zeilenende
<code>{S}</code>	RA zu Substitution <i>S</i>
<code>r?</code>	ein- oder keinmal RA <i>r</i>
<code>r*</code>	keinmal, einmal oder mehrmals RA <i>r</i>
<code>r+</code>	einmal oder mehrmals RA <i>r</i>
<code>r{n,m}</code>	<i>n</i> bis <i>m</i> mal RA <i>r</i> (<i>m</i> optional)
<code>(r)</code>	<i>r</i>
<code>r₁r₂</code>	Konkatenation
<code>r₁ r₂</code>	Alternative

Präzedenzregeln wie üblich

CB 1-6

Abbildung 1.6: reguläre Ausdrücke in `lex`

```
%{
    #include <stdio.h>
    int yywrap();
    enum token {IF=1, ID, RELOP, LT, ...}
}%

LETTER [A-Za-z]
DIGIT  [0-9]
L_OR_D {LETTER}|{DIGIT}

%%
"if"      { return IF; }
"<"      { yylval = LT; return RELOP; }
{LETTER}{L_OR_D}* { install_id(); return ID; }
.|\n     { fprintf(stderr, "Ungültiges Zeichen '%c'\n", yytext[0]); }

%%
int yywrap() { return 1; }
void main(void) {
    int token;
    while (token=yylex()) printf("Token %d\n", token);
}
... install_id() {...} /* Zugriff auf Bezeichner: Stringvariable yytext. */

```

CB 1-7

Abbildung 1.7: Scannergenerierung mit flex

Kapitel 2

Syntaktische Analyse

Aufgabe: Zerlegung der Symbolfolge, die der Scanner ausgibt, in syntaktische Einheiten, bzw. Behandlung syntaktischer Fehler.

Syntaktische Einheiten: Variablen, Ausdrücke, Anweisungen, ...

Beachte: Schachtelung syntaktischer Einheiten, Baumstruktur im Unterschied zur linearen Symbolfolge.

Parser: Programm für die syntaktische Analyse

Schnittstellen: siehe Abbildung 2.4

Beschreibung der syntaktischen Struktur durch eine *kontextfreie Grammatik*. Erkennung und Analyse durch *Kellerautomaten* mit Ausgabe.

Problem: deterministische Simulation.

Allgemeiner Fall: beliebige CFG (kontextfreie Grammatik): Tabularverfahren von Cocke, Younger, Kasami (CYK) mit $O(n^2)$ Platz- und $O(n^3)$ Zeitbedarf.

Im Fall einer Programmiersprache: spezielle CFG: Analyse durch deterministische Kellerautomaten mit „input look-ahead“, bei linearem Platz- und Zeitbedarf.

- a. *Top-Down-Analyse:* Konstruktion des Ableitungsbaums, von der Wurzel zu den Blättern hin, in Form einer *Linksanalyse*.
- b. *Bottom-Up-Analyse:* umgekehrt, gespiegelte *Rechtsanalyse*

2.1 Kontextfreie Grammatiken

$$G = \langle N, \Sigma, P, S \rangle \in \text{CFG}(\Sigma)$$

	$A, B, C, \dots \in N$	Nichtterminalsymbole
	$a, b, c, \dots \in \Sigma$	Terminalsymbole
Bezeichnungskonventionen:	$u, v, w, \dots \in \Sigma^*$	Terminalwörter
	$\alpha, \beta, \gamma, \dots \in \mathcal{X}^*$	Satzformen ($\mathcal{X} := N \cup \Sigma$)
	$A \rightarrow \alpha \in P$	Produktion / Regel

Definition: Die *Ableitungsrelation* $\Rightarrow \subseteq (\mathcal{X}^*)^2$ ist definiert durch

$$\alpha \Rightarrow \beta : \curvearrowright \quad \begin{aligned} \alpha &= \alpha_1 A \alpha_2, A \rightarrow \gamma \in P \\ \beta &= \alpha_1 \gamma \alpha_2 \end{aligned}$$

Gilt außerdem: $\alpha_1 \in \Sigma^*$, bzw. $\alpha_2 \in \Sigma^*$, so

$$\alpha_1 \xRightarrow{l} \beta \quad \text{bzw.} \quad \alpha_2 \xRightarrow{r} \beta$$

Sprechweise: Ableitungsschritt; α_1 : Links-, α_2 : Rechtsableitungsschritt

Erzeugte Sprache: $L(G) := \{w \in \Sigma^* \mid S \xRightarrow{*} w\}$

Offensichtlich gilt $L(G) = \{w \in \Sigma^* \mid S \xRightarrow{*}_l w\}$ und $L(G) = \{w \in \Sigma^* \mid S \xRightarrow{*}_r w\}$

Beispiel: $G : S \rightarrow aSb \mid \epsilon$

$S \Rightarrow aSb \Rightarrow aaSbb \Rightarrow aa\epsilon bb = aabb$




Abbildung 2.1: Der Ableitungsbaum, der die syntaktische Struktur von a^2b^2 bezüglich G repräsentiert

Definition: G heißt *eindeutig*, wenn es für jedes $w \in L(G)$ genau einen Ableitungsbaum gibt.

Folgerung: G ist eindeutig, wenn es für jedes $w \in L(G)$ genau eine Linksableitung (bzw. Rechtsableitung) gibt. In der Regel gibt es zu einem Ableitungsbaum mehrere Ableitungen, aber nur genau eine Links- bzw. Rechtsableitung.

Definition: G ist *mehrdeutig*, wenn G nicht eindeutig ist.

2.1.1 l -Analyse, r -Analyse

Darstellung von l/r -Ableitungen durch Nummernfolgen

$$|P| = p, [p] := \{1, 2, \dots, p\}, \Pi : [p] \xrightarrow{\text{bijektiv}} P$$

$$wA\alpha \xRightarrow{l} w\gamma\alpha \text{ bzw. } \alpha Aw \xRightarrow{r} \alpha\gamma w \text{ falls } \Pi(i) = A \rightarrow \gamma$$

Für $z = i_1 \dots i_k \in [p]^+$ soll für passende $\alpha_1 \dots \alpha_{k-1}$ gelten:

$$\alpha \xRightarrow{z} \beta : \curvearrowright \alpha \xRightarrow{i_1} \alpha_1 \xRightarrow{i_2} \alpha_2 \dots \xRightarrow{i_k} \alpha_k = \beta$$

und $\alpha \xrightarrow[l]{\varepsilon}$ („leerer“ 1-Ableitungsschritt)

Definition: z heißt *l-Analyse* von $\alpha : \curvearrowright S \xrightarrow[l]{\varepsilon} \alpha$.

z heißt *r-Analyse* von $\alpha : \curvearrowleft S \xrightarrow[r]{\varepsilon} \alpha$.

Bezeichnungskonvention: $i \in [p], z \in [p]^*$

Beispiel: siehe Abbildung 2.5

2.1.2 Syntaxanalyse

Gegeben ist eine Grammatik $G \in CFG(\Sigma), w \in \Sigma^*$. Dafür: Berechnung einer l- bzw. r-Analyse, falls $w \in L(G)$, andernfalls Bestimmung der syntaktischen Fehler.

Generalvoraussetzung: $G \in CFG$ ist *reduziert*, dh. für jedes $A \in N$ gibt es $\alpha, \beta \in \chi^*$ und $w \in \Sigma^*$, so daß $S \xrightarrow{*} \alpha A \beta \xrightarrow{*} w$

2.2 Top-Down Analyse mit $LL(k)$ -Grammatiken

Definition: Der *TD-Analyseautomat* von $G \in CFG, (NTA(G))$ ist gekennzeichnet durch:

Eingabealphabet: Σ (Zustandsalphabet entfällt)

Kellularphabet: χ Ausgabealphabet: $[p]$

Konfigurationsmenge: $\Sigma^* \times \chi^* \times [p]^*$ (Kellerspitze links)

sowie Transitionen wie folgt:

- Ableitungsschritte: $(w, A\alpha, z) \vdash (w, \beta\alpha, zi)$ falls $\Pi(i) = A \rightarrow \beta$
- Vergleichsschritte: $(aw, a\alpha, z) \vdash (w, \alpha, z)$ für $a \in \Sigma$

Die Anfangskonfiguration für ein $w \in \Sigma^*$ wie folgt: (w, S, ε) .

Beachte: Nichtdeterminismus wegen Mehrdeutigkeit $(A \rightarrow \beta|\gamma)$

Satz: Der $NTA(G)$ berechnet l-Analysen, dh. $(w, S, \varepsilon) \vdash^* (\varepsilon, \varepsilon, z) \curvearrowleft z$ ist l-Analyse von w .




Abbildung 2.2: Analyseautomat

Beispiel: siehe Abbildung 2.2 und Ausführung in Abbildung 2.6.

Beweis: „ \curvearrowright “ Automat arbeitet korrekt:

$$(*) \quad (w, \alpha, y) \vdash^* (\varepsilon, \varepsilon, yz) \curvearrowright \alpha \xrightarrow[l]{z} w$$

Beweis von $(*)$ durch Induktion über $k := |z|$

Induktionsanfang $k = 0$: $(w, \alpha, y) \vdash^* (\varepsilon, \varepsilon, y)$: nur Vergleichsschritte, also $w = \alpha$, es gilt $(*)$ mit $w \xrightarrow[l]{\varepsilon} w$.

Induktionsschritt $k \rightsquigarrow k + 1$: $z = iz', \alpha = uA\beta, w = uv, \Pi(i) = A \Rightarrow \gamma$

$$(w, \alpha, y) = (uv, uA\beta, y) \vdash^* (v, A\beta, y) \vdash^* (v, \gamma\beta, yi) \vdash^* (\varepsilon, \varepsilon, yiz')$$

Nach Induktionsvoraussetzung: $\gamma\beta \xrightarrow[l]{iz'} v$, und damit folgt $(*)$ wegen: $\alpha = uA\beta \xrightarrow[l]{i} u\gamma\beta \xrightarrow[l]{iz'} uv = w$

$$\alpha \xrightarrow[l]{iz'} w$$

Beweis: „ \curvearrowright “ ähnlich. □

Ziel: Nichtdeterminismus des TD-Analyseautomaten von G durch k -look-ahead auf der Eingabe beiseitigen, $k \in \mathbb{N}$.

Definition: (first-Mengen). Sei $G \in \text{CFG}$, $\alpha \in \chi^*$ und $k \in \mathbb{N}$. Dann definieren wir $\underline{\text{first}}_k(\alpha) \subseteq \Sigma^*$ durch $\underline{\text{first}}_k(\alpha) := \{v \in \Sigma^* \mid \exists w \in \Sigma^* : \alpha \xrightarrow{*} vw, |v| = k\} \cup \{v \in \Sigma^* \mid \alpha \xrightarrow{*} v, |v| < k\}$

Folgerung:




Abbildung 2.3: $|v| = k \curvearrowright v \in \underline{\text{first}}_k(A)$

- i. $\underline{\text{first}}_k(\alpha) \neq \emptyset$, weil G reduziert.
- ii. $\varepsilon \in \underline{\text{first}}_k(\alpha) \curvearrowright k = 0$ oder $\alpha \xrightarrow{*} \varepsilon$
- iii. $\alpha \xrightarrow{*} \beta \curvearrowright \underline{\text{first}}_k(\beta) \subseteq \underline{\text{first}}_k(\alpha)$
- iv. $v \in \underline{\text{first}}_k(\alpha) \curvearrowright \exists x \in \Sigma^* : \alpha \xrightarrow{*} x, \{v\} = \underline{\text{first}}_k(x)$

$LL(k)$: Lesen der Eingabe von links nach rechts mit k -Lookahead. Berechnung einer Linksanalyse.

Definition: ($LL(k)$ -Grammatik). Sei $G \in \text{CFG}$ und $k \in \mathbb{N}$. $G \in LL(k)$: Für alle Linksableitungen der Form

$$S \xrightarrow[l]{*} wA\alpha \begin{array}{l} \nearrow \quad w\beta\alpha \xrightarrow[l]{*} wx \\ \searrow \quad w\gamma\alpha \xrightarrow[l]{*} wy \end{array}$$

mit $\text{first}_k(x) = \text{first}_k(y)$, gilt: $\beta = \gamma$.

Bemerkung:

- Linksableitungsschritt für $wA\alpha$ ist durch die nächsten k auf w folgenden Symbole bestimmt.
- Der TD-Analyseautomat für eine $LL(k)$ -Grammatik kann deterministisch mit k -look-ahead auf Eingabe simuliert werden.

Problem: Bestimmung der A -Regel aus k -look-ahead.

Lemma: $G \in LL(k) \iff$ Für alle Linksableitungen der Form

$$S \xrightarrow[l]{*} wA\alpha \begin{array}{l} \nearrow \quad w\beta\alpha \\ \searrow \quad w\gamma\alpha \end{array} \quad \text{mit } \beta \neq \gamma$$

gilt $\text{first}_k(\beta\alpha) \cap \text{first}_k(\gamma\alpha) = \emptyset$.

Beweis: „ \downarrow “ (Definition \rightarrow Lemma)

Angenommen, $\beta \neq \gamma$, aber $v \in \text{first}_k(\beta\alpha) \cap \text{first}_k(\gamma\alpha)$. Dann muß $\beta\alpha \xrightarrow[l]{*} x$ und $\gamma\alpha \xrightarrow[l]{*} y$ mit $\{v\} = \text{first}_k(x) = \text{first}_k(y)$.

Daraus folgt ein Widerspruch, weil $LL(k)$ -Definition dann $\beta = \gamma$ erzwingt.

„ \uparrow “ (Lemma \rightarrow Definition)

Angenommen, Lemma-Eigenschaft gilt, aber die Definitions-Eigenschaft ist mit $\beta \neq \gamma$ verletzt. Dann muß $\text{first}_k(\beta\alpha) \cap \text{first}_k(\gamma\alpha) = \emptyset$.

Dies widerspricht der Voraussetzung, weil $\text{first}_k(x) \subseteq \text{first}_k(\beta\alpha)$ und entsprechend $\text{first}_k(y) \subseteq \text{first}_k(\gamma\alpha)$.

□

Folgerung: Bestimmung der A -Regel durch die look-ahead-Mengen $\text{first}_k(\beta\alpha), \text{first}_k(\gamma\alpha)$ für Regel-paar $A \rightarrow \beta|\gamma$.

Problem: Abhängigkeit der look-ahead-Menge vom Rechtskontext α .

Ziel: Bestimmung der look-ahead-Menge aus Regel allein.

Idee: Mögliche Rechtskontexte vereinigen.

Definition: (follow-Menge). Sie $G \in CFG, A \in N$ und $k \in \mathbb{N}$. Dann definieren wir $\text{follow}_k(A) \subseteq \Sigma^*$ durch $\text{follow}_k(A) := \{v \in \Sigma^* \mid S \xrightarrow[l]{*} wA\alpha, v \in \text{first}_k(\alpha)\}$.

Der Fall $k = 1$: Abkürzung $\underline{f}i := \underline{f}irst_1$ und $\underline{f}o := \underline{f}ollow_1$.

Satz: Für $G \in CFG$ (reduziert!) gilt:

$G \in LL(1) \iff$ Für alle Regelpaare $A \rightarrow \beta | \gamma$ mit $\beta \neq \gamma$ folgt $\underline{f}i(\underline{\beta}f\underline{o}(A)) \cap \underline{f}i(\underline{\gamma}f\underline{o}(A)) = \emptyset$.

Definition: $\underline{l}a(A \rightarrow \beta) := \underline{f}i(\underline{\beta}f\underline{o}(A)) \subseteq \Sigma_\epsilon := \Sigma \cup \{\epsilon\}$ heißt Look-ahead-Menge von $A \rightarrow \beta$ (la-Menge).

Beachte:

- $\epsilon \in \underline{l}a(A \rightarrow \beta) \iff \beta \xrightarrow{*} \epsilon$ und $\epsilon \in \underline{f}o(A)$
- $a \in \underline{l}a(A \rightarrow \beta) \iff a \in \underline{f}i(\beta)$ oder $(\beta \xrightarrow{*} \epsilon$ und $a \in \underline{f}o(A))$
- $\underline{f}i(\alpha) \subseteq \Sigma_\epsilon := \Sigma \cup \{\epsilon\}$
- $\underline{f}o(A) \subseteq \Sigma_\epsilon$
- $\underline{\beta}f\underline{o}(A) \subseteq \chi^*$
- für $\Gamma \subseteq \chi^*$ ist $\underline{f}i(\Gamma) := \bigcup_{\alpha \in \Gamma} \underline{f}i(\alpha)$

Beweis: (des Satzes)

a. „ \downarrow “ (Lemma \rightarrow Satz): Angenommen, es gibt $A \rightarrow \beta | \gamma$ mit $\beta \neq \gamma$, aber: $c \in \underline{f}i(\underline{\beta}f\underline{o}(A)) \cap \underline{f}i(\underline{\gamma}f\underline{o}(A))$

Fall 1: $c = \epsilon$

Es folgt: $\beta \xrightarrow{*} \epsilon, \gamma \xrightarrow{*} \epsilon$ und $\epsilon \in \underline{f}o(A)$. Dies ergibt folgenden Widerspruch zum Lemma:

$$S \xrightarrow[l]{*} wA\alpha \quad \begin{array}{l} \nearrow l \\ \searrow l \end{array} \quad \begin{array}{l} w\beta\alpha \\ w\gamma\alpha \end{array} \quad \text{mit } \beta \neq \gamma$$

aber: $\epsilon \in \underline{f}i(\beta\alpha) \cap \underline{f}i(\gamma\alpha)$.

Fall 2: $c = a \in \Sigma$

Es folgt:

- (1) $a \in \underline{f}i(\beta) \cap \underline{f}i(\gamma)$
- (2) $a \in \underline{f}i(\beta), \gamma \xrightarrow{*} \epsilon$ und $a \in \underline{f}o(A)$
- (3) $a \in \underline{f}i(\gamma), \beta \xrightarrow{*} \epsilon$ und $a \in \underline{f}o(A)$
- (4) $\beta \xrightarrow{*}, \gamma \xrightarrow{*} \epsilon$ und $a \in \underline{f}o(A)$

In jedem Fall existiert eine Ableitung

$$S \xrightarrow[l]{*} wA\alpha \quad \begin{array}{l} \nearrow l \\ \searrow l \end{array} \quad \begin{array}{l} w\beta\alpha \\ w\gamma\alpha \end{array} \quad \text{aber : } a \in \underline{f}i(\beta\alpha) \cap \underline{f}i(\gamma\alpha)$$

also ein Widerspruch zu $LL(1)$, da $\beta \neq \gamma$

b. „ \uparrow “ (Satz \rightarrow Lemma):

$$\text{Sei } S \xrightarrow[l]{*} wA\alpha \begin{array}{l} \nearrow w\beta\alpha \\ \searrow w\gamma\alpha \end{array} \text{ mit } \beta \neq \gamma$$

Nach „Satz“ gilt: $\underline{f}\text{i}(\beta\underline{f}\text{i}(A)) \cap \underline{f}\text{i}(\gamma\underline{f}\text{o}(A)) = \emptyset$. Da $\underline{f}\text{i}(\beta\alpha) \subseteq \underline{f}\text{i}(\beta\underline{f}\text{o}(A))$, mu auch $\underline{f}\text{i}(\beta\alpha) \cap \underline{f}\text{i}(\gamma\alpha) = \emptyset$

□

Bemerkung: Fr $k = 1$ kann der lokale Rechtskontext α durch $\underline{f}\text{o}(A)$ verallgemeinert werden. Die $\underline{f}\text{i}$ -Mengen $\underline{f}\text{i}(A \rightarrow \beta)$ bestimmen einen deterministischen TD-Analyseautomaten.

2.2.1 Berechnung der $\underline{f}\text{i}$ -Mengen

1. $\underline{f}\text{i}(X)$ fr $X \in \chi$

- $X = a \in \Sigma \curvearrowright \underline{f}\text{i}(X) = \{X\}$
- $X \rightarrow a\alpha \curvearrowright a \in \underline{f}\text{i}(X)$
- $X \rightarrow \varepsilon \curvearrowright \varepsilon \in \underline{f}\text{i}(X)$
- $X \rightarrow A_1 \dots A_k Y \alpha, k \geq 0, Y \in \chi, \varepsilon \in \underline{f}\text{i}(A_1) \cap \dots \cap \underline{f}\text{i}(A_k), a \in \underline{f}\text{i}(Y) \curvearrowright a \in \underline{f}\text{i}(X)$
- $X \rightarrow A_1 \dots A_k, k \geq 1, \varepsilon \in \underline{f}\text{i}(A_1) \cap \dots \cap \underline{f}\text{i}(A_k) \curvearrowright \varepsilon \in \underline{f}\text{i}(X)$

2. $\underline{f}\text{i}(X_1 \dots X_n)$ fr $X_i \in \chi, n \in \mathbb{N}$

- $\varepsilon \in \underline{f}\text{i}(X_1) \cap \underline{f}\text{i}(X_2) \cap \dots \cap \underline{f}\text{i}(X_{i-1}), a \in \underline{f}\text{i}(X_i) \curvearrowright a \in \underline{f}\text{i}(X_1 \dots X_n)$
- $\varepsilon \in \underline{f}\text{i}(X_1) \cap \underline{f}\text{i}(X_2) \cap \dots \cap \underline{f}\text{i}(X_n) \curvearrowright \varepsilon \in \underline{f}\text{i}(X_1 \dots X_n)$
- $\underline{f}\text{i}(\varepsilon) = \{\varepsilon\}$

3. $\underline{f}\text{o}(A)$

- $\varepsilon \in \underline{f}\text{o}(S)$
- $A \rightarrow \alpha B \beta, a \in \underline{f}\text{i}(\beta) \curvearrowright a \in \underline{f}\text{o}(B)$
- $A \rightarrow \alpha B, x \in \underline{f}\text{o}(A) \curvearrowright x \in \underline{f}\text{i}(B)$
- $A \rightarrow \alpha B \beta, \varepsilon \in \underline{f}\text{i}(\beta), x \in \underline{f}\text{o}(A) \curvearrowright x \in \underline{f}\text{o}(B)$

Beispiel:

$$\begin{aligned} G'_{AE} : E &\rightarrow TE' & (1) \\ E' &\rightarrow +TE' | \varepsilon & (2,3) \\ T &\rightarrow FT' & (4) \\ T' &\rightarrow *FT' | \varepsilon & (5,6) \\ F &\rightarrow (E) | a & (7,8) \end{aligned}$$

	E	E'	T	T'	F
$\underline{f}\text{i}$	(a	+ ε	(a	* ε	(a
$\underline{f}\text{o}$))	ε)	+ ε)	* + ε)

1	(a
2	+
3	ε)
4	(a
5	*
6	+ ε)
7	(
8	a

Der Schnitt der Alternativen muß leer sein! Die Alternativen sind hier die Regeln 2 + 3, 5 + 6 und 7 + 8.

Folgerung: G'_{AE} ist $LL(1)$.

$LL(1)$ -Test: la -Mengen berechnen und Alternativen auf Disjunktheit prüfen.

Beachte: (neue Prüfungsfrage): $G \in CFG$, G reduziert. Regel in $G : A \rightarrow \alpha B$.

Frage: Zusammenhang zwischen $\underline{fo}(A)$ und $\underline{fo}(B)$.

Antwort: $\underline{fo}(A) \subseteq \underline{fo}(B)$, aber im allgemeinen nicht $\underline{fo}(B) \subseteq \underline{fo}(A)$

2.2.2 Der deterministische TD-Analyseautomat $DTA(G)$ für $G \in LL(1)$

Idee: Die Zugehörigkeit des Eingabesymbols zu einer la -Menge steuert die Regelauswahl. „1-look-ahead“ auf dem Eingabeband.

Modifikation des Ableitungsschritts:

- $(aw, A\alpha, z) \vdash (aw, \beta\alpha, zi)$ falls $\Pi_i = A \rightarrow \beta$ und $a \in \underline{la}(\Pi_i)$
- $(\varepsilon, A\alpha, z) \vdash (\varepsilon, \beta\alpha, zi)$ falls $\Pi_i = A \rightarrow \beta$ und $\varepsilon \in \underline{la}(\Pi_i)$

Folgerung: Deterministische Arbeitsweise.

Beachte: Das Eingabesymbol wird bei Ableitungsschritten nicht gelöscht.

Darstellung des $DTA(G)$ durch die *Analysetabelle* von G (*action-Funktion* von G).

$$\underline{act} : \Sigma_\varepsilon \times (N \cup \Sigma_\varepsilon) \rightarrow \{\alpha | A \rightarrow \alpha \in G\} \times [p] \cup \{\underline{pop}, \underline{accept}, \underline{error}\}$$

\underline{act} ist definiert durch

$$\begin{aligned} \underline{act}(x, A) &:= (\alpha, i) \text{ falls } \Pi_i = A \rightarrow \alpha \text{ und } x \in \underline{la}(\Pi_i) \\ \underline{act}(a, a) &:= \underline{pop} \\ \underline{act}(\varepsilon, \varepsilon) &:= \underline{accept} \\ \underline{act}(x, X) &:= \underline{error} \text{ sonst} \end{aligned}$$

Die Analysetabelle für unsere Grammatik G'_{AE} ist in Abbildung 2.7 gegeben.

2.3 Parserkonstruktion nach TD-Methode

$G \in \text{CFG}$ reduziert gegeben.

Berechnung der $\underline{\text{la}}$ -Mengen ($\underline{\text{fi}}$ - und $\underline{\text{fo}}$ -Mengen)

Analysetablelle: Eindeutigkeit prüfen

tabellengesteuerter Parser

Problem: mehrdeutige Analysetablelle ($G \notin \text{LL}(1)$).

2.3.1 Transformationen nach $\text{LL}(1)$

2 Methoden um G in äquivalente $\text{LL}(1)$ -Grammatik zu transformieren (nicht immer möglich):

1. Beseitigung von Linksrekursionen
2. Links-Faktorisieren

Verwendung in Parser-erzeugenden Systemen.

Vorsicht: Transformationen erhalten zwar die Äquivalenz, im allgemeinen aber nicht die syntaktische Struktur (Ableitungsbaum).

Beseitigung von Linksrekursionen

Definition: $G \in \text{CFG}$ linksrekursiv: $\neg \exists A \in N, \alpha \in \chi^* : A \xrightarrow{\pm} A\alpha$.

Folgerung: G linksrekursiv $\neg \forall k \in \mathbb{N} \quad G \notin \text{LL}(k)$.

Grund: Wenn ein TD-Parser $A \xrightarrow{\pm} A\alpha$ simuliert, so bleibt der Eingabekopf stehen. Gleicher look-ahead. Damit: Schleife.

Es ist also nicht möglich Ableitungen der Form $S \xrightarrow{*}_i wA\beta \xrightarrow{*}_i wA\alpha\beta \xrightarrow{*}_i wv$ zu bilden.

Beispiel:

$$G_{AE} : E \rightarrow E + T | T \quad (1, 2)$$

$$T \rightarrow T * F | F \quad (3, 4)$$

$$F \rightarrow (E) | a \quad (5, 6)$$

G_{AE} ist linksrekursiv, also: $G_{AE} \notin \text{LL}(k)$.

Probe: $\text{LL}(1)$ -Test

$$\underline{\text{fi}}(E) = \underline{\text{fi}}(T) = \underline{\text{fi}}(F) = \{(\cdot, a) \cap \underline{\text{la}}(\Pi_i) = \{(\cdot, a), i = 1 \dots 6\}$$

Das bestätigt, daß G_{AE} keine $\text{LL}(1)$ -Grammatik ist.

Spezialfall: direkte Linksrekursion und ihre Beseitigung

$$A \rightarrow A\alpha | \beta (\beta \neq A, \alpha \neq \epsilon)$$

wird ersetzt durch

$$A \rightarrow \beta A' \quad A' \rightarrow \alpha A' | \epsilon$$

Folgerung: $L(G)$ unverändert, jedoch neue syntaktische Struktur (kein Problem bei assoziativen Operatoren $+, *, \dots$).

Beispiel: Beseitigung direkter Linksrekursionen in G_{AE} ergibt G'_{AE} .

Allgemeiner Fall: *indirekte Linksrekursion*

$$\begin{aligned} A &\rightarrow A_1 \alpha_1 | \dots \\ A_1 &\rightarrow A_2 \alpha_2 | \dots \\ &\vdots \\ A_n &\rightarrow A \beta | \dots \end{aligned}$$

Beseitigung durch Transformation in GNF (Greibach Normalform); Regeln der Form

$$A \rightarrow a B_1 \dots B_n \quad S \rightarrow \epsilon$$

Beachte: Beseitigung von Linksrekursion ergibt nicht notwendig eine LL(1)-Grammatik. Der Grund hierfür ist, daß jede Grammatik $G \in \text{CFG}$ in GNF äquivalent transformierbar ist, aber nicht jede kontextfreie Sprache ist durch eine LL(1)-Grammatik erzeugbar.

Es gilt:

$$\begin{aligned} \mathcal{L}(\text{LL}(k)) &\subsetneq \mathcal{L}(\text{LL}(k+1)), k \in \mathbb{N} \\ &\subsetneq \mathcal{L}(\text{DPDA}) \\ &\subsetneq \mathcal{L}(\text{PDA}) = \text{CFL} \end{aligned}$$

Komplexität der LL(1)-Analyse

G ist LL(1)-Grammatik $\Leftrightarrow G$ ist nicht links-rekursiv.

$DTA(G)$ mit Eingabe von $w \in \Sigma^*$:

- $|w|$ Vergleichsschritte plus einem „accept“-Schritt.
- maximal $|N|$ aufeinanderfolgende Ableitungsschritte (Begründung: würde ein Nichtterminalsymbol doppelt auftauchen, ohne das ein Vergleichsschritt durchgeführt wurde, so würde eine links-Rekursion vorliegen).

G nicht linksrekursiv. Dann ex. $c \in \mathbb{N}$ mit $A \xRightarrow{i} \alpha$ und $|\alpha| \geq 1 \wedge 1 \leq c|\alpha|$

\Rightarrow TD-Analyse in Linearzeit

$\Leftrightarrow \max |N| \cdot (|w| + 1)$ Transitionen.

maximale Kellerlänge: $\max\{|\alpha| \mid A \rightarrow \alpha \text{ in } P\} \cdot |N| \cdot (|w| + 1)$.

Also: linearer Platz und Zeitbedarf.

Links-Faktorisieren

Beispiel:

statement \rightarrow if condition then statement else statement fi
 statement \rightarrow if condition then statement fi

Keine Regelentscheidung mit beschränkten look-ahead möglich.

Idee: Verschieben der Entscheidung bis Alternativen erkennbar.

Links-Faktorisieren: $A \rightarrow \alpha\beta|\alpha\gamma$ ersetzen durch $A \rightarrow \alpha A'$ und $A' \rightarrow \beta|\gamma$.

Beispiel:

statement \rightarrow if condition then statement S'
 $S' \rightarrow$ else statement fi | fi

2.4 Top-Down Analyse mit rekursiven Prozeduren

Idee: keine explizite Kellerbenutzung wie beim $DTA(G)$, sondern implizite Verwendung des Laufzeitkellers durch Einsatz rekursiver Prozeduren.

Spezialfall: $G \in LL(1)$ (Beispiel: G'_{AE}).

2.4.1 Analyseverfahren durch rekursiven Abstieg (ohne la-Mengen)

Methode („Recursive descent parser“): $A \in N \mapsto A()$ parameterlose Prozedur, zur Simulation eines Ableitungsschritts.

Annahme: Alternativen durch Eingabesymbol unterscheidbar.

Eingabe: *sym* Variable für das Eingabesymbol, *nextsym* zum Lesen des nächsten Eingabesymbols.

Ausgabe: *print(i)* zur Ausgabe einer Regelnummer.

2.4.2 Zusätzliche Verwendung der la-Mengen

Vorteil: bessere Kontrolle der Regelanwendungen, frühere Fehlererkennung.

Weitere Möglichkeit: nicht-deterministische Programmierung (PROLOG: CFG als „Definite Clause Grammar“).

2.5 Bottom-Up Analyse mit $LR(k)$ -Grammatiken

Idee: Bottom-Up-Berechnung des Ableitungsbaums in Form einer gespiegelten Rechtsanalyse durch einen Kellerautomaten:

Shift-Schritte: Verschieben von Eingabesymbolen auf dem Keller

Reduce-Schritte: Umkehrung von Ableitungsschritten.

Dies wird *Shift-Reduce-Verfahren* genannt.

Definition: Der (nicht-deterministische) Bottom-Up-Analyseautomat von $G \in CFG$ ($NBA(G)$):

Eingabealphabet: Σ
 Kelleralphabet: \mathcal{X}
 Ausgabealphabet: $[p]$
 Konfigurationsmenge: $\underbrace{\mathcal{X}^*}_{\text{Keller}} \times \underbrace{\Sigma^*}_{\text{Eingabe}} \times \underbrace{[p]^*}_{\text{Ausgabe}}$

Transitionen:

Shift-Schritt: $(\alpha, aw, z) \vdash (\alpha a, w, z)$ für $a \in \Sigma$

Reduce-Schritt: $(\beta\alpha, w, z) \vdash (\beta A, w, zi)$ für $\Pi_i = A \rightarrow \alpha$

Anfangskonfiguration für $w \in \Sigma^*$: $(\varepsilon, w, \varepsilon)$.

Satz: Der $NBA(G)$ berechnet gespiegelte r -Analysen, d.h. für $w \in \Sigma^*$ und $z \in [p]^*$ gilt: z ist r -Analyse von $w \curvearrowright (\varepsilon, w, \varepsilon) \vdash (\mathcal{S}, \varepsilon, \overleftarrow{z})$.

Aufgabe: Gegeben $G \in CFG$. G ist nicht linksrekursiv. Dann existiert $c \in \mathbb{N}$, so daß $A \xRightarrow{i} B\alpha \curvearrowright i \leq c$. Der vorgestellte Lösungsvorschlag $c = |N|$ ist falsch (Gegenbeispiel: $S \rightarrow aBBBBBc, B \rightarrow \varepsilon$).

2.5.1 Nicht-Determinismus

1. Shift- oder Reduce-Schritt
2. Reduce-Schritt : linker Henkelrand (Henkel: rechte Regelseite auf Keller)
3. Reduce-Schritt: linke Regelseite
4. Analyseende

Ziel: Nicht-Determinismus durch k -look-ahead auf Eingabe beseitigen $\rightsquigarrow LR(k)$ -Grammatiken (R: Rechts-Analyse).

Generalvoraussetzung: G ist *startsepariert*, d.h. S nur in $S \rightarrow A$, mit $A \neq S$. Jedes $G \in CFG$ läßt sich durch Hinzufügen von $S' \rightarrow S$ in eine äquivalente startseparierte Grammatik transformieren. Im folgenden: G mit Sonderregel $S' \rightarrow S$ mit der Nummer 0.

Folgerung: (S', ε, z) ist eine Endkonfiguration. Also ergibt die Startsepariertheit ein deterministisches Analyseende.

Beseitigung des restlichen Nicht-Determinismus durch:

Definition: ($LR(k)$ -Grammatik): Sei $G \in CFG$, startsepariert mit $S' \rightarrow S, k \in \mathbb{N}$. Dann ist $G \in LR(K)$: \curvearrowright Für alle Rechtsableitungen der Form

$$\begin{array}{c}
 \begin{array}{l}
 \nearrow^* \\
 r
 \end{array}
 \alpha A w \xRightarrow[r]{\quad} \alpha \beta w \\
 S \\
 \begin{array}{l}
 \searrow^* \\
 r
 \end{array}
 \alpha' A' w' \xRightarrow[r]{\quad} \alpha \beta v = \underline{\text{first}}_k(v)
 \end{array}
 \quad \text{mit } \underline{\text{first}}_k(w)$$

gilt: $\alpha' = \alpha, A' = A, w' = v$.

Folgerung: Der BU-Analyseautomat kann mit k -look-ahead auf der Eingabe die nächste Transition entscheiden.

2.5.2 LR(0)-Grammatiken

$k = 0 \curvearrowright$ Entscheidung ohne look-ahead, allein durch den Kellerinhalt $\alpha\beta$.

Abstraktion endlicher Information aus $\alpha\beta$ welche für die Entscheidung ausreicht.

Definition: ($LR(0)$ -Auskünfte, $LR(0)$ -Mengen):

Sei $G \in CFG$ mit $S' \rightarrow S$ und $S' \xrightarrow[r]{*} \alpha A w \xrightarrow[r]{} \alpha\beta_1\beta_2 w$. Dann heißt $[A \rightarrow \beta_1 \cdot \beta_2]$ eine $LR(0)$ -Auskunft für $\alpha\beta_1$.

Für $\gamma \in \chi^*$ bezeichnet $\underline{LR(0)}(\gamma)$ die Menge aller $LR(0)$ -Auskünfte für γ , die sogenannte $LR(0)$ -Menge von γ ($LR(0)$ -Information).

Folgerung:

- i. $\underline{LR(0)}(\gamma)$ ist endlich.
- ii. $\underline{LR(0)}(G) := \{\underline{LR(0)}(\gamma) \mid \gamma \in \chi^*\}$ ist endlich.
- iii. $[A \rightarrow \beta_1 \cdot] \in \underline{LR(0)}(\gamma)$ signalisiert Reduktionsmöglichkeit. $(\alpha\beta_i, w, z) \vdash (\alpha A, w, zi)$ für $\Pi_i = A \rightarrow \beta_1$ und $\gamma = \alpha\beta_1$.
- iv. $[A \rightarrow \beta_1 \cdot \beta_2] \in \underline{LR(0)}(\gamma)$ mit $\beta_2 \neq \varepsilon$ bedeutet Shift-Möglichkeit wegen unvollständigen Henkel.
- v. $G \in LR(0) \curvearrowright$ Die $\underline{LR(0)}$ -Mengen von G enthalten keine widersprüchlichen Auskünfte.

Berechnung der $LR(0)$ -Mengen einer Grammatik

Satz: $G \in CFG$ mit $S' \rightarrow S$, G reduziert. Dann gilt:

1. $\underline{LR(0)}(\varepsilon)$ ist die kleinste Menge, welche
 - (a) $[S' \rightarrow \cdot S]$ enthält
 - (b) mit $[A \rightarrow \cdot B\delta]$ und $B \rightarrow \beta$ auch $[B \rightarrow \cdot \beta]$ enthält
2. $\underline{LR(0)}(\alpha X)$ mit $X \in \chi$ ist die kleinste Menge, welche
 - (a) $[A \rightarrow \beta_1 X \cdot \beta_2]$ enthält, falls $[A \rightarrow \beta_1 \cdot X \beta_2] \in \underline{LR(0)}(\alpha)$
 - (b) und mit $[A \rightarrow \gamma \cdot B\delta]$ und $B \rightarrow \beta$ in G auch $[B \rightarrow \cdot \beta]$ enthält

$\underline{LR(0)}(\varepsilon) \cdot \alpha = \varepsilon$ und $\beta_1 = \varepsilon$

$[S' \rightarrow \cdot S] \in \underline{LR(0)}(\varepsilon)$

$S \rightarrow A\gamma \curvearrowright [S \rightarrow \cdot A\gamma] \in \underline{LR(0)}(\varepsilon)$

$A \rightarrow a \curvearrowright [S \rightarrow \cdot a] \in \underline{LR(0)}(\varepsilon)$

Die goto-Funktion

$G : LR(0)$ -Grammatik $\curvearrowright \underline{LR(0)}(\gamma)$ liefert Shift/Reduce-Entscheidung für den BU-Analyseautomaten mit Kellerinschrift γ .

- neues Kelleralphabet: $\underline{LR(0)}(G)$ statt χ

Beachte: $\underline{LR(0)}(\gamma X)$ ist bereits durch $\underline{LR(0)}(\gamma)$ und X bestimmt.

$\underline{goto} : \underline{LR(0)}(G)x\chi \rightarrow \underline{LR(0)}(G)$ ist definiert durch

$$\underline{goto}(I, X) := I' \curvearrowright \exists \gamma \in \chi^*; I = \underline{LR(0)}(\gamma) \text{ und } I' = \underline{LR(0)}(\gamma X)$$

Berechnung der $LR(0)$ -Mengen und \underline{goto} -Funktion durch Potenzmengenkonstruktion nicht-deterministischer endlicher Automaten

Sei $G \in CFG$, G startsepariert mit $S' \rightarrow S$. Konstruktion eines $\mathfrak{A}(G) \in NFA_{\varepsilon}$

Zustandsmenge	$Q := \{[A \rightarrow \beta_1 \cdot \beta_2] \mid A \rightarrow \beta_1 \beta_2 \text{ in } G\}$
Eingabealphabet	$\chi := N \cup \Sigma$
Anfangszustand	$q_0 := [S' \rightarrow \cdot S]$
(Endzustandsmenge)	$F := Q$ ohne Bedeutung)
Transitionsfunktion	$\delta : Q \times \chi_{\varepsilon} \rightarrow \mathfrak{p}(Q)$
	$\delta([A \rightarrow \beta_1 \cdot X \beta_2], X) \ni [A \rightarrow \beta_1 X \cdot \beta_2]$
	$\delta([A \rightarrow \beta_1 \cdot B \beta_2], \varepsilon) \ni [B \rightarrow \cdot \beta], \text{ falls } B \rightarrow \beta \text{ in } G$

Potenzmengenkonstruktion nach Thompson: Konstruktion von $\widehat{\mathfrak{A}(G)} : \langle \hat{Q}, \chi, \hat{\delta}, \hat{q}_0, \emptyset \rangle \in DFA$. Erweiterte Transitionsfunktion:

$$\begin{aligned} \bar{\delta} &: \mathfrak{p}(Q) \times \chi^* \rightarrow \mathfrak{p}(Q) \\ \bar{\delta}(T, \varepsilon) &:= \varepsilon(T) \text{ („}\varepsilon\text{-Hülle von } T\text{“)} \\ \bar{\delta}(T, wa) &:= \varepsilon(\bigcup_{q \in \bar{\delta}(T, w)} \delta(q, a)) \\ \hat{Q} &:= \{\bar{\delta}(\{[S' \rightarrow \cdot S]\}, \alpha) \mid \alpha \in \chi^*\} \\ \hat{q}_0 &:= \varepsilon(\{[S' \rightarrow \cdot S]\}) \\ \hat{\varepsilon}(T, X) &:= \bar{\delta}(T, X) \end{aligned}$$

Dann gilt: $\hat{Q} = \underline{LR(0)}(G)$ $\hat{\delta} = \underline{goto}$

Konstruktion des deterministischen BU-Analyseautomaten für $G \in LR(0)$

Hilfsmittel: $\underline{LR(0)}(G)$ und \underline{goto} -Funktion.

Die \underline{action} -Funktion von G gibt die Shift/Reduce-Entscheidung an:

$$\underline{act} : \underline{LR(0)}(G) \rightarrow \{\underline{shift}, \underline{red}_i, \underline{error}, \underline{accept} \mid i \in [p]\}$$

$$\underline{act}(I) := \begin{cases} \underline{red}_i & \text{falls } \Pi_i = A \rightarrow \alpha \text{ und } [A \rightarrow \alpha \cdot] \in I \\ \underline{shift} & \text{falls } [A \rightarrow \alpha \cdot X \beta] \in I \\ \underline{accept} & \text{falls } [S' \rightarrow S \cdot] \in I \\ \underline{error} & \text{falls } I = \emptyset \end{cases}$$

Eindeutigkeit bei $G \in LR(0)$.

Die Funktionen $\underline{\text{act}}$ und $\underline{\text{goto}}$ bilden die $\underline{\text{LR}}(0)$ -Analysetabelle von G (Beispiel: Abbildung 2.17). Diese Tabelle bestimmt den $\underline{\text{LR}}(0)$ -Analyseautomaten.

Eingabealphabet: Σ
 Kelleralphabet: $\Gamma := \underline{\text{LR}}(0)(G)$
 Ausgabealphabet: $\Delta := [p] \cup \{\underline{\text{error}}\} \cup \{0\}$

Transitionen:

- Shift-Schritt: $(\alpha I, aw, z) \vdash (\alpha II', w, z)$, falls $\underline{\text{act}}(I) = \underline{\text{shift}}$ und $\underline{\text{goto}}(I, a) = I'$.
- Reduce-Schritt: (Bezeichnung: $wa_1 \dots a_n - (n) := w$) $(\alpha I, w, z) \vdash (\tilde{\alpha} \tilde{I}', w, zi)$, falls $\underline{\text{act}}(I) = \underline{\text{red}}$, $\Pi_i = A \rightarrow X_1 \dots X_n$, $\alpha I - (n) = \tilde{\alpha} \tilde{I}$ und $\underline{\text{goto}}(\tilde{I}, A) = I'$.
- Accept-Schritt: $(I_0 I, \varepsilon, z) \vdash (\varepsilon, \varepsilon, z0)$, falls $\underline{\text{act}}(I) = \underline{\text{accept}}$.
- Fehlererkennung: $(\alpha I, w, z) \vdash (\varepsilon, \varepsilon, z \cdot \underline{\text{error}})$, sonst.

Anfangskonfiguration für $w \in \Sigma^*$: (I_0, w, ε) mit $I_0 = \underline{\text{LR}}(0)(\varepsilon)$.

Folgerung: Wenn $\underline{\text{LR}}(0)(G)$ konfliktfrei, also $\underline{\text{act}}$ eindeutig ist, so arbeitet der $\underline{\text{LR}}(0)$ -Analyseautomat deterministisch, und es gilt für ein Eingabewort $w \in \Sigma^*$ und $z \in [p]^*$:

- $(I_0, w, \varepsilon) \vdash^* (\varepsilon, \varepsilon, z) \overset{\leftarrow}{\curvearrowright} z$ r-Analyse von w
- $(I_0, w, \varepsilon) \vdash^* (\varepsilon, \varepsilon, z \cdot \underline{\text{error}}) \overset{\leftarrow}{\curvearrowright} w \notin L(G)$

Beispiel: $w = aac$ (Grammatik G aus Abbildung 2.15):

$(0, aac, \varepsilon)$
 $(04, ac, \varepsilon)$
 $(044, c, \varepsilon)$
 $(0446, \varepsilon, \varepsilon)$
 $(0448, \varepsilon, 6)$
 $(048, \varepsilon, 65)$
 $(03, \varepsilon, 655)$
 $(01, \varepsilon, 6552)$
 $(\varepsilon, \varepsilon, 65520)$
 \leftarrow

2.5.3 $\underline{\text{SLR}}(1)$ -Analyse

In der Praxis treten widersprüchliche $\underline{\text{LR}}(0)$ -Mengen auf: $G \notin \underline{\text{LR}}(0)$.

Beispiel: Shift/Reduce-Konflikte in G_{AE} (siehe Abbildung 2.20: I_1, I_2, I_9).

Beseitigung der Konflikte durch nächstes Eingabesymbol. Beobachtung:

1. $[A \rightarrow \beta_1 \cdot a\beta_2] \in \underline{LR}(0)(\alpha\beta_1) \rightsquigarrow S \xrightarrow[r]{*} \alpha Aw \Rightarrow \alpha\beta_1 a\beta_2 w$
Also: Shift nur bei Eingabe von a .
2. $[A \rightarrow \beta \cdot] \in \underline{LR}(0)(\alpha\beta) \rightsquigarrow S \xrightarrow[r]{*} \alpha Aaw \Rightarrow \alpha\beta aaw \rightsquigarrow a \in \underline{fo}(A)$
Also: Reduktion mit $A \rightarrow \beta$ nur, falls $a \in \underline{fo}(A)$.

Für obiges Beispiel:

- I_1 : shift bei Eingabe von +
accept bei Eingabe von \$
- I_2 : shift bei Eingabe von *
red₂ bei Eingabe von +,), \$
- I_9 : shift bei Eingabe von *
red₁ bei Eingabe von +,), \$

So sind die Konflikte beseitigt. Weiterer Vorteil: frühere Fehlererkennung.

Die $SLR(1)$ -action Funktion

$\underline{act} : \underline{LR}(0)(G) \times (\Sigma \cup \{\$\}) \rightarrow \{\underline{shift}, \underline{red}_i, \underline{accept}, \underline{error} \mid 1 \leq i \leq r\}$ sei definiert durch:

$$\underline{act}(I, a) = \begin{cases} \underline{shift} & \text{falls } [A \rightarrow \alpha \cdot A\beta] \in I \\ \underline{red}_i & \text{falls } \Pi_i = A \rightarrow \alpha, [A \rightarrow \alpha \cdot] \in I, a \in \underline{fo}(A) \\ \underline{accept} & \text{falls } [S' \rightarrow S \cdot] \in I \text{ und } a = \$ \\ \underline{error} & \text{sonst} \end{cases}$$

Definition: G ist eine $SLR(1)$ -Grammatik $\rightsquigarrow \underline{act}(I, a)$ stets eindeutig.

Die action und goto Funktionen bilden die $SLR(1)$ -Analysetabelle von G (siehe Abbildung 2.21). Jedoch sind Konflikte möglich. Eine bessere Konfliktbeseitigung ergibt sich durch Verwendung des Look-ahead Symbols in der Auskunft:

$$[A \rightarrow \beta_1 \cdot \beta_2, a] \rightarrow LR(1), LALR(1)$$

2.5.4 $LR(1)$ -Analyse

Nicht immer sind Konflikte über follow-Mengen lösbar (siehe Abbildung 2.22).

Aber nicht jedes Element von $\underline{fo}(R)$ in beliebiger Rechtsableitung hinter R möglich \rightsquigarrow Verfeinerung der $LR(0)$ -Auskünfte durch mitführen der möglichen look-ahead Symbole.

Definition: $LR(1)$ -Auskünfte und Menge für $G \in \text{CFG}$:

1. Wenn $S \xrightarrow[r]{*} \alpha Aaw \Rightarrow \alpha\beta_1\beta_2aw$, so $[A \rightarrow \beta_1 \cdot \beta_2, a] \in LR(1)(\alpha\beta_1)$
2. Wenn $S \xrightarrow[r]{*} \alpha A \Rightarrow \alpha\beta_1\beta_2$, so $[A \rightarrow \beta_1 \cdot \beta_2, \$] \in LR(1)(\alpha\beta_1)$

$$\underline{LR}(1)(G) := \{\underline{LR}(1)(\gamma) \mid \gamma \in \chi^*\}$$

Berechnung der $LR(1)$ -Mengen

Modifikation der Berechnung von $LR(0)(G)$ unter Berücksichtigung des Rechtskontextes.

- $\underline{LR(1)}(\epsilon) : [S' \rightarrow \cdot S, \$] \in \underline{LR(1)}(\epsilon)$
 Wenn $[A \rightarrow \cdot B\delta, x] \in \underline{LR(1)}(\epsilon), B \rightarrow \beta$ in G und $y \in \underline{fi}(\delta x)$, so $[B \rightarrow \cdot \beta, y] \in \underline{LR(1)}(\epsilon)$
- $\underline{LR(1)}(\alpha X)$:
 - Wenn $[A \rightarrow \beta_1 \cdot X\beta_2, x] \in \underline{LR(1)}(\alpha)$, so $[A \rightarrow \beta_1 X \cdot \beta_2, x] \in \underline{LR(1)}(\alpha X)$
 - Wenn $[A \rightarrow \gamma \cdot B\delta, x] \in \underline{LR(1)}(\alpha X), B \rightarrow \beta$ in G und $y \in \underline{fi}(\delta x)$, so $[B \rightarrow \cdot \beta, y] \in \underline{LR(1)}(\alpha X)$

Die $LR(1)$ -action Funktion von G

$\underline{act} : \underline{LR(1)}(G) \times (\Sigma \cup \{\$\}) \rightarrow \{\underline{shift}, \underline{red}_i, \underline{accept}, \underline{error} \mid 1 \leq i \leq r\}$ ist definiert durch:

$$\underline{act}(I, x) = \begin{cases} \underline{red}_i & \text{falls } \Pi_i = A \rightarrow \alpha \text{ und } [A \rightarrow \alpha \cdot, x] \in I \\ \underline{accept} & \text{falls } x = \$ \text{ und } [S' \rightarrow S \cdot, \$] \in I \\ \underline{shift} & \text{falls } x \neq \$ \text{ und } [A \rightarrow \alpha_1 \cdot x\alpha_2, y] \in I \\ \underline{error} & \text{sonst} \end{cases}$$

Dann gilt: $G \in LR(1) \curvearrowright \underline{act}(I, x)$ eindeutig (konfliktfrei).

2.5.5 LALR(1)-Analyse

Beseitigung von Entscheidungskonflikten nach $LR(1)$ -Methode zu aufwendig (die Tabellen werden zu groß).

Im Beispiel $|\underline{LR(0)}(G_2)| = 11$ $|\underline{LR(1)}(G_2)| = 15$
 ALGOL 60 $\sim 10^2$ $\sim 10^3$

m. Beobachtung: ögliche Informationsredundanz bei $\underline{LR(1)}(G_2)$.

Definition: $I_1, I_2 \in \underline{LR(1)}(G)$ heißen $\underline{LR(0)}$ -äquivalent, $I_1 \sim_0 I_2$, falls die $LR(0)$ -Anteile von I_1 und I_2 gleich sind.

Beispiel: $I_4^{(1)} \sim_0 I_{11}^{(1)}, I_5^{(1)} \sim_0 I_{12}^{(1)}, I_7^{(1)} \sim_0 I_{13}^{(1)}, I_8^{(1)} \sim_0 I_{10}^{(1)}$.

Folgerung: $|\underline{LR(1)}(G) / \sim_0| = |\underline{LR(0)}(G)|$

Oft können $LR(0)$ -äquivalente $LR(1)$ -Informationen *vereinigt* werden, ohne daß die Konfliktlösbarkeit verloren geht.

Definition:

- $I \in \underline{LR(1)}(G)$ bestimmt eine $\underline{LALR(1)}$ -Menge.

$$\bigcup \{I' \in \underline{LR(1)}(G) \mid I' \sim_0 I\}$$

- $\underline{LALR(1)}(G)$: Menge der $\underline{LALR(1)}$ -Mengen von G .

Es gilt: $|\underline{LALR(1)}(G)| = |\underline{LR(0)}(G)|$; aber: im Unterschied zu $\underline{LR(0)}$ -Informationen enthalten $\underline{LALR(1)}$ -Mengen look-ahead-Symbole zur Lösung von Konflikten.

Die LALR(1)-action Funktion von G

Die LALR(1)-action Funktion von G ist analog zu der von LR(1) definiert.

Definition: $G \in \text{LALR}(1) : \curvearrowright \text{LALR}(1)$ -action Funktion ist eindeutig.

Beispiel: Die LALR(1)-Menge von G_2

$$\underline{\text{LALR}(1)}(G_2) := \{I_i^{(1/0)} \mid 1 \leq i \leq 9\}$$

$$I_i^{(1/0)} := I_i^{(1)} \text{ f\"ur } i = 0, 1, 2, 3, 6, 9$$

$$I_4^{(1/0)} := I_4^{(1)} \cup I_{11}^{(1)}$$

$$I_5^{(1/0)} := I_5^{(1)} \cup I_{12}^{(1)}$$

$$I_7^{(1/0)} := I_7^{(1)} \cup I_{13}^{(1)}$$

$$I_8^{(1/0)} := I_8^{(1)} \cup I_{10}^{(1)}$$

Die LR(1)-goto Funktion überträgt sich auf $\underline{\text{LALR}(1)}(G)$, weil für LR(1)-Mengen I_1 und I_2 gilt: $I_1 \underset{0}{\sim} I_2 \curvearrowright \underset{0}{\text{goto}}(I_1, X) \underset{0}{\sim} \underset{0}{\text{goto}}(I_2, X)$. Der Grund dafür ist folgender: der „LR(0)-Kern“ von $\underline{\text{LR}(1)}(\alpha X)$ ist durch den „LR(0)-Kern“ von $\underline{\text{LR}(1)}(\alpha)$ vollständig bestimmt.

2.6 Bottom-Up Analyse mehrdeutiger Grammatiken

Es gilt für $G \in \text{CFG}$: G mehrdeutig $\curvearrowright G \notin \text{LR} = \bigcup_{k \in \mathbb{N}} \text{LR}(k)$.

Mehrdeutigkeit ist aber ein natürliches Beschreibungsmittel bei Programmiersprachen, um aufwendige Klammerung zu vermeiden.

Auflösung der Mehrdeutigkeit durch Regeln für Präzedenz und Assoziativität von Op-Symbolen (allgemeiner: von syntaktischen Konstrukten).

Beispiel: (Abbildung 2.29) $G_{AE}^m : E \rightarrow E + E \mid E * E \mid (E) \mid a$:

Präzedenz: * vor + in $a + a * a$

Assoziativität: links in $a + a + a$

Die Konflikte in I_1 sind SLR(1)-lösbar, jedoch sind aufgrund der Mehrdeutigkeit die Konflikte in I_7 und I_8 nicht auflösbar.

Beispiel:

I_0 $a + a * a$

$I_0 I_3$ $+ a * a$

$I_0 I_1$ $+ a * a$

$I_0 I_1 I_4$ $a * a$

$I_0 I_1 I_4 I_3$ $* a$

$I_0 I_1 I_4 I_7$ $* a$ Reduktionskonflikt, $a > +$

$\underline{\text{act}}(I_7, *)$ = shift

$\underline{\text{act}}(I_7, *)$ = red₁ (falls $+ > *$)

Beispiel: Mehrdeutigkeit bei Verzweigungen („dangling else“)

$$S \rightarrow iSeS|iS|a \quad (1,2,3)$$

siehe auch Abbildung 2.31 (i : if, e : else). Im $LR(0)$ -Graph kommt es bei I_4 zum Konflikt: $e \in \underline{fo}(S) \curvearrowright$ nicht LR-lösbar.


if b then if b then a else a

Es existieren zwei Zerlegungen:

1. if b then (if b then a else a)
2. if b then (if b then a) else a

2.7 Ergebnis

Die Syntaxanalyse setzt eine lineare Struktur in eine Baumstruktur um. Dies ist wichtig für syntaxgerichtete Softwarewerkzeuge (Compiler, Editoren, Textformatierer, Befehlsinterpreter).



CB 2-1

Abbildung 2.4: Schnittstellen

Links- und Rechtsableitungen

Bsp: $G_{AE} : E \rightarrow E+T | T \quad (1,2)$
 $T \rightarrow T * F | F \quad (3,4)$
 $F \rightarrow (E) | a | b | c \quad (5-8)$

Linksableitung von $(a) * c :$

$$E \xRightarrow[l]{2} T \xRightarrow[l]{3} T * F \xRightarrow[l]{4} F * F \xRightarrow[l]{5} (E) * F \xRightarrow[l]{2}$$

$$(T) * F \xRightarrow[l]{4} (F) * F \xRightarrow[l]{6} (a) * F \xRightarrow[l]{8} (a) * c$$

\leadsto Linksanalyse von $(a) * c : 23452468$

Rechtsableitung von $(a) * c :$

$$E \xRightarrow[r]{2} T \xRightarrow[r]{3} T * F \xRightarrow[r]{8} T * c \xRightarrow[r]{4} F * c \xRightarrow[r]{5}$$

$$(E) * c \xRightarrow[l]{2} (T) * c \xRightarrow[l]{4} (F) * c \xRightarrow[l]{6} (a) * c$$

\leadsto Rechtsanalyse von $(a) * c : 23845246$

CB 2-2

Abbildung 2.5: Links- und Rechtsableitungen

Bsp: NTA(G_{AE})

$$G_{AE} : E \rightarrow E+T \mid T \quad (1,2)$$

$$T \rightarrow T*F \mid F \quad (3,4)$$

$$F \rightarrow (E) \mid a \mid b \mid c \quad (5-8)$$

Linksanalyse von $(a)*c$:

$$(E \quad , (a)*c, \quad)$$

$$(T \quad , (a)*c, 2 \quad)$$

$$(T*F \quad , (a)*c, 23 \quad)$$

$$(F*F \quad , (a)*c, 234 \quad)$$

$$((E)*F, (a)*c, 2345 \quad)$$

$$(E)*F \quad , a)*c \quad , 2345 \quad)$$

$$(T)*F \quad , a)*c \quad , 23452 \quad)$$

$$(F)*F \quad , a)*c \quad , 234524 \quad)$$

$$(a)*F \quad , a)*c \quad , 2345246 \quad)$$

$$()*F \quad ,))*c \quad , 2345246 \quad)$$

$$(*F \quad , *c \quad , 2345246 \quad)$$

$$(F \quad , c \quad , 2345246 \quad)$$

$$(c \quad , c \quad , 23452468)$$

$$(\quad , \quad , 23452468)$$

CB 2-3

Abbildung 2.6: Beispiel NTA

Analysetabelle für G'_{AE}

	E	E'	T	T'	F	a	$($	$)$	$+$	$*$	ϵ
a	$TE', 1$		$FT', 4$		$a, 8$	<u>pop</u>					
$($	$TE', 1$		$FT', 4$		$(E), 7$		<u>pop</u>				
$)$		$\epsilon, 3$		$\epsilon, 6$				<u>pop</u>			
$+$		$+TE', 2$		$\epsilon, 6$					<u>pop</u>		
$*$				$*FT', 5$						<u>pop</u>	
ϵ		$\epsilon, 3$		$\epsilon, 6$							<u>accept</u>

CB 2-4

Abbildung 2.7: Analysetabelle für G'_{AE}

Zustandsfolge des DTA für G'_{AE}

$\langle (a*a), E$, ε	\rangle
$\langle (a*a), TE'$, 1	\rangle
$\langle (a*a), FT'E'$, 14	\rangle
$\langle (a*a), (E)T'E'$, 147	\rangle
$\langle a*a) , E)T'E'$, 147	\rangle
$\langle a*a) , TE')T'E'$, 1471	\rangle
$\langle a*a) , FT'E')T'E'$, 14714	\rangle
$\langle a*a) , aT'E')T'E'$, 147148	\rangle
$\langle *a) , T'E')T'E'$, 147148	\rangle
$\langle *a) , *FT'T'E')T'E'$, 1471485	\rangle
$\langle a) , FT'T'E')T'E'$, 1471485	\rangle
$\langle a) , aT'T'E')T'E'$, 14714858	\rangle
$\langle) , T'T'E')T'E'$, 14714858	\rangle
$\langle) , T'E')T'E'$, 147148586	\rangle
$\langle) , E')T'E'$, 1471485866	\rangle
$\langle) ,)T'E'$, 14714858663	\rangle
$\langle , T'E'$, 14714858663	\rangle
\langle , E'	, 147148586636	\rangle
\langle , ε	, 1471485866363	\rangle

CB 2-5

Abbildung 2.8: Arbeitsweise von G'_{AE}

```

RD Parser für  $G'_{AE}$ 

proc T()                                proc E()
  if sym in {'(', 'a'}                  if sym in {'(', 'a'}
  then print(4);                          then print(1);
    F(); T'();                            T(); E'();
  else print(ERROR); stop;                else print(ERROR); stop;

proc F()
  if sym='(' then
    print(7);
    nextsym; E();
    if sym=')' then nextsym;
      else print(ERROR); stop;
  elseif sym='a' then
    print(8);
    nextsym;
  else
    print(ERROR); stop

proc E'()                                proc T'()
  if sym='+' then                          if sym='*' then
    print(2);                               print(5);
    nextsym;                                nextsym;
    T(); E'();                              F(); T'();
  elseif sym in {')', '\epsilon'}          elseif sym in {'+', '\epsilon'}
  then print(3);                            then print(6);
  else print(ERROR); stop;                  else print(ERROR); stop;
                                             CB 2-6


```

Abbildung 2.9: Recursive descent parser für G'_{AE}

Linksanalyse:

Top-down-Konstruktion des Ableitungsbaums

z.B. Linksanalyse 2 3 4 5 2 4 6 8 von $(a)*c$:




CB 2-7

Abbildung 2.10: Linksanalyse / TD-Konstruktion

Rechtsanalyse: Bottom-up-Konstruktion des Ableitungsbaums


z.B. gespiegelte Rechtsanalyse

6 4 2 5 4 8 3 2 von $(a) * c$:



CB 2-8a

Abbildung 2.12: Rechtsanalyse I



CB 2-8b

Abbildung 2.13: Rechtsanalyse II

Bottom-up-Analyseautomat von G_{AE}

$G_{AE} : E \rightarrow E+T|T \quad (1,2)$

$T \rightarrow T*F|F \quad (3,4)$

$F \rightarrow (E)|a|b|c \quad (5-8)$


Analyse von $(a)*c$:

(ϵ , $(a)*c$, ϵ) (T , $*c$, 64254)
 ((, a) $*c$, ϵ) ($T*$, c , 64254)
 ((a ,) $*c$, ϵ) ($T*c$, ϵ , 64254)
 ((F ,) $*c$, 6) ($T*F$, ϵ , 642548)
 ((T ,) $*c$, 64) (T , ϵ , 6425483)
 ((E ,) $*c$, 642) (E , ϵ , 64254832)
 ((E), $*c$, 642)
 (F , $*c$, 6425)

Abbildung 2.14: Bottom-Up-Analyseautomat von G_{AE}


LR(0)-Analyse und Ableitungsbäume

Allgemeine Situation:



$$\Rightarrow [A \rightarrow \beta_1 \cdot \beta_2] \in \mathbf{LR(0)}(\alpha\beta_1)$$

ϵ -Abschluß:



$$\Rightarrow [B \rightarrow \cdot \gamma] \in \mathbf{LR(0)}(\alpha\beta_1)$$

CB 2-10

Abbildung 2.15: LR(0)-Analyse und Ableitungsbäume

LR(0)–Informationen von G

$$G: \begin{array}{ll} S' \rightarrow S & (0) \quad S \rightarrow B \mid C \quad (1/2) \\ B \rightarrow aB \mid b & (3/4) \quad C \rightarrow aC \mid c \quad (5/6) \end{array}$$

$$I_0 := \mathbf{LR(0)}(\epsilon): \quad I_1 := \mathbf{LR(0)}(S):$$

$$[S' \rightarrow \cdot S]$$

$$[S' \rightarrow S \cdot]$$

$$[S \rightarrow \cdot B]$$

$$[S \rightarrow \cdot C]$$

$$I_2 := \mathbf{LR(0)}(B):$$

$$[B \rightarrow \cdot aB]$$

$$[S \rightarrow B \cdot]$$

$$[B \rightarrow \cdot b]$$

$$[C \rightarrow \cdot aC]$$

$$I_3 := \mathbf{LR(0)}(C):$$

$$[C \rightarrow \cdot c]$$

$$[S \rightarrow C \cdot]$$

$$I_4 := \mathbf{LR(0)}(a): \quad I_5 := \mathbf{LR(0)}(b):$$

$$[B \rightarrow a \cdot B]$$

$$[B \rightarrow b \cdot]$$

$$[C \rightarrow a \cdot C]$$

$$[B \rightarrow \cdot aB]$$

$$I_6 := \mathbf{LR(0)}(c):$$

$$[B \rightarrow \cdot b]$$

$$[C \rightarrow c \cdot]$$

$$[C \rightarrow \cdot aC]$$

$$[C \rightarrow \cdot c]$$

$$I_7 := \mathbf{LR(0)}(aB): \quad I_8 := \mathbf{LR(0)}(aC):$$

$$[B \rightarrow aB \cdot]$$

$$[C \rightarrow aC \cdot]$$

$$I_9 := \mathbf{LR(0)}(Sa):$$

$$\emptyset$$

CB 2-11

Abbildung 2.16: LR(0)-Informationen von G

goto- und action-Funktion zu G

$$G: \begin{array}{l} S' \rightarrow S \quad (0) \quad S \rightarrow B \mid C \quad (1/2) \\ B \rightarrow aB \mid b \quad (3/4) \quad C \rightarrow aC \mid c \quad (5/6) \end{array}$$

goto	I_0	I_1	I_2	I_3	I_4	I_5	I_6	I_7	I_8	I_9
S	I_1	-	-	-	-	-	-	-	-	-
B	I_2	-	-	-	I_7	-	-	-	-	-
C	I_3	-	-	-	I_8	-	-	-	-	-
a	I_4	-	-	-	I_4	-	-	-	-	-
b	I_5	-	-	-	I_5	-	-	-	-	-
c	I_6	-	-	-	I_6	-	-	-	-	-


$LR(0)(G)$	act	goto					
		S	B	C	a	b	c
I_0	shift	I_1	I_2	I_3	I_4	I_5	I_6
I_1	accept						
I_2	red 1						
I_3	red 2						
I_4	shift		I_7	I_8	I_4	I_5	I_6
I_5	red 4						
I_6	red 6						
I_7	red 3						
I_8	red 5						
I_9	error						

CB 2-12

Abbildung 2.17: goto- und action-Funktion zu G

Berechnung von $LR(0)(G)$ und $goto$
durch Potenzmengenkonstruktion


$G: S' \rightarrow S \quad (0) \quad S \rightarrow B \mid C \quad (1/2)$
 $B \rightarrow aB \mid b \quad (3/4) \quad C \rightarrow aC \mid c \quad (5/6)$



CB 2-13

Abbildung 2.18: Potenzmengenkonstruktion I

Potenzmengenkonstruktion (Fortsetzung)



CB 2-14

Abbildung 2.19: Potenzmengenkonstruktion II

SLR(1)–Analyse

$$G_{AE} : E' \rightarrow E \quad (0)$$

$$E \rightarrow E+T \mid T \quad (1,2)$$

$$T \rightarrow T*F \mid F \quad (3,4)$$

$$F \rightarrow (E) \mid a \quad (5,6)$$

LR(0)–Informationen zu G_1 :

$I_0 : E' \rightarrow \cdot E$ $E \rightarrow \cdot E+T$ $E \rightarrow \cdot T$ $T \rightarrow \cdot T*F$ $T \rightarrow \cdot F$ $F \rightarrow \cdot (E)$ $F \rightarrow \cdot a$	<div style="border: 1px solid black; padding: 5px; display: inline-block;"> $I_1 : E' \rightarrow E \cdot$ $E \rightarrow E \cdot +T$ </div> ⚡
$I_4 : F \rightarrow (\cdot E)$ $E \rightarrow \cdot E+T$ $E \rightarrow \cdot T$ $T \rightarrow \cdot T*F$ $T \rightarrow \cdot F$ $F \rightarrow \cdot (E)$ $F \rightarrow \cdot a$	<div style="border: 1px solid black; padding: 5px; display: inline-block;"> $I_2 : E \rightarrow T \cdot$ $T \rightarrow T \cdot *F$ </div> ⚡
$I_7 : T \rightarrow T* \cdot F$ $F \rightarrow \cdot (E)$ $F \rightarrow \cdot a$	$I_3 : T \rightarrow F \cdot$ $I_5 : F \rightarrow a \cdot$ $I_6 : E \rightarrow E+ \cdot T$ $T \rightarrow \cdot T*F$ $T \rightarrow \cdot F$ $F \rightarrow \cdot (E)$ $F \rightarrow \cdot a$
<div style="border: 1px solid black; padding: 5px; display: inline-block;"> $I_9 : E \rightarrow E+T \cdot$ $T \rightarrow T \cdot *F$ </div> ⚡	$I_8 : F \rightarrow (E \cdot)$ $E \rightarrow E \cdot +T$
$I_{11} : F \rightarrow (E) \cdot$	$I_{10} : T \rightarrow T*F \cdot$

CB 2-15

Abbildung 2.20: SLR(1)-Analyse von G_{AE}

$$\begin{aligned}
 G_1 : \quad & E' \rightarrow E && (0) \\
 & E \rightarrow E+T \mid T && (1,2) \\
 & T \rightarrow T*F \mid F && (3,4) \\
 & F \rightarrow (E) \mid a && (5,6)
 \end{aligned}$$

SLR(1)–Analysetabelle zu G_1 :

	action					goto								
	+	*	()	a	\$	+	*	()	a	E	T	F
I_0			shift		shift				I_4		I_5	I_1	I_2	I_3
I_1	shift					acc	I_6							
I_2	red 2	shift		red 2		red 2		I_7						
I_3	red 4	red 4		red 4		red 4								
I_4			shift		shift				I_4		I_5	I_8	I_2	I_3
I_5	red 6	red 6		red 6		red 6								
I_6			shift		shift				I_4		I_5		I_9	I_3
I_7			shift		shift				I_4		I_5			I_{10}
I_8	shift			shift			I_6			I_{11}				
I_9	red 1	shift		red 1		red 1		I_7						
I_{10}	red 3	red 3		red 3		red 3								
I_{11}	red 5	red 5		red 5		red 5								

A	fo(A)
E'	\$
E	\$, +,)
T	\$, +,), *
F	\$, +,), *

CB 2-16

Abbildung 2.21: SLR(1)-Analysetabelle

Motivation LR(1)-Analyse

$$\begin{aligned}
 G_2: \quad S' &\rightarrow S && (0) \\
 S &\rightarrow L=R \mid R && (1,2) \\
 L &\rightarrow *R \mid a && (3,4) \\
 R &\rightarrow L && (5)
 \end{aligned}$$

LR(0)-Informationen zu G_2 :

$$\begin{array}{ll}
 I_0: & [S' \rightarrow \cdot S] \\
 & [S \rightarrow \cdot L=R] \\
 & [S \rightarrow \cdot R] \\
 & [L \rightarrow \cdot *R] \\
 & [L \rightarrow \cdot a] \\
 & [R \rightarrow \cdot L] \\
 I_4: & [L \rightarrow * \cdot R] \\
 & [R \rightarrow \cdot L] \\
 & [L \rightarrow \cdot *R] \\
 & [L \rightarrow \cdot a] \\
 I_7: & [L \rightarrow *R \cdot] \\
 I_8: & [R \rightarrow L \cdot] \\
 I_1: & [S' \rightarrow S \cdot] \\
 I_2: & [S \rightarrow L \cdot =R] \\
 & [R \rightarrow L \cdot] \\
 I_3: & [S \rightarrow R \cdot] \\
 I_5: & [L \rightarrow a \cdot] \\
 I_6: & [S \rightarrow L = \cdot R] \\
 & [R \rightarrow \cdot L] \\
 & [L \rightarrow \cdot *R] \\
 & [L \rightarrow \cdot a] \\
 I_9: & [S \rightarrow L = R \cdot]
 \end{array}$$

Der Konflikt in I_2 ist mit der SLR-Methode nicht lösbar, da

$$= \in \mathbf{fo}(R)$$

CB 2-17

Abbildung 2.22: Motivation LR(1)-Analyse

LR(1)–Informationen zu G_2 :

$$I_0^{(1)} : \begin{array}{l} [S' \rightarrow \cdot S, \$] \quad [S \rightarrow \cdot L=R, \$] \quad [S \rightarrow \cdot R, \$] \\ [L \rightarrow \cdot *R, =] \quad [L \rightarrow \cdot a, =] \quad [R \rightarrow \cdot L, \$] \\ [L \rightarrow \cdot *R, \$] \quad [L \rightarrow \cdot a, \$] \end{array}$$

$$I_1^{(1)} : [S' \rightarrow S \cdot, \$]$$

$$I_2^{(1)} : [S \rightarrow L \cdot =R, \$] \quad [R \rightarrow L \cdot, \$] \quad \left\{ \begin{array}{l} \text{shift, bei } = \\ \text{reduce, bei } \$ \end{array} \right.$$

$$I_3^{(1)} : [S \rightarrow R \cdot, \$]$$

$$I_4^{(1)} : \begin{array}{l} [L \rightarrow * \cdot R, =] \quad [R \rightarrow \cdot L, =] \quad [L \rightarrow \cdot *R, =] \\ [L \rightarrow \cdot a, =] \quad [L \rightarrow * \cdot R, \$] \quad [R \rightarrow \cdot L, \$] \\ [L \rightarrow \cdot *R, \$] \quad [L \rightarrow \cdot a, \$] \end{array}$$

$$I_5^{(1)} : [L \rightarrow a \cdot, =] \quad [L \rightarrow a \cdot, \$]$$

$$I_6^{(1)} : [S \rightarrow L = \cdot R, \$] \quad [R \rightarrow \cdot L, \$] \quad [L \rightarrow \cdot *R, \$] \\ [L \rightarrow \cdot a, \$]$$

$$I_7^{(1)} : [L \rightarrow *R \cdot, =] \quad [L \rightarrow *R \cdot, \$]$$

$$I_8^{(1)} : [R \rightarrow L \cdot, =] \quad [R \rightarrow L \cdot, \$]$$

$$I_9^{(1)} : [S \rightarrow L = R \cdot, \$]$$

$$I_{10}^{(1)} : [R \rightarrow L \cdot, \$]$$

$$I_{11}^{(1)} : [L \rightarrow * \cdot R, \$] \quad [R \rightarrow \cdot L, \$] \quad [L \rightarrow \cdot *R, \$] \\ [L \rightarrow \cdot a, \$]$$

$$I_{12}^{(1)} : [L \rightarrow a \cdot, \$]$$

$$I_{13}^{(1)} : [L \rightarrow *R \cdot, \$]$$

CB 2-18

Abbildung 2.23: LR(1)-Informationen

$$\begin{aligned}
 G_2 : S' &\rightarrow S && (0) \\
 S &\rightarrow L=R \mid R && (1,2) \\
 L &\rightarrow *R \mid a && (3,4) \\
 R &\rightarrow L && (5)
 \end{aligned}$$

LR(1)–Analysetabelle zu G_2 :

	action				goto					
	*	=	a	\$	*	=	a	S	L	R
$I_0^{(1)}$	shift		shift		$I_4^{(1)}$		$I_5^{(1)}$	$I_1^{(1)}$	$I_2^{(1)}$	$I_3^{(1)}$
$I_1^{(1)}$				acc						
$I_2^{(1)}$		shift		red 5		$I_6^{(1)}$				
$I_3^{(1)}$				red 2						
$I_4^{(1)}$	shift		shift		$I_4^{(1)}$		$I_5^{(1)}$		$I_8^{(1)}$	$I_7^{(1)}$
$I_5^{(1)}$		red 4		red 4						
$I_6^{(1)}$	shift		shift		$I_{11}^{(1)}$		$I_{12}^{(1)}$		$I_{10}^{(1)}$	$I_9^{(1)}$
$I_7^{(1)}$		red 3		red 3						
$I_8^{(1)}$		red 5		red 5						
$I_9^{(1)}$				red 1						
$I_{10}^{(1)}$				red 5						
$I_{11}^{(1)}$	shift		shift		$I_{11}^{(1)}$		$I_{12}^{(1)}$		$I_{10}^{(1)}$	$I_{13}^{(1)}$
$I_{12}^{(1)}$				red 4						
$I_{13}^{(1)}$				red 3						

CB 2-19

Abbildung 2.24: LR(1)-Analysetabelle

Berechnung des LR(1)-Analyseautomaten für $*a = a$:

$$\begin{aligned}
 & \langle I_0^{(1)} \quad , \quad *a=a\$, \quad \epsilon \quad \rangle \\
 \vdash & \langle I_0^{(1)} I_4^{(1)} \quad , \quad a=a\$, \quad \epsilon \quad \rangle \\
 \vdash & \langle I_0^{(1)} I_4^{(1)} \underline{I_5^{(1)}} \quad , \quad =a\$, \quad \epsilon \quad \rangle \\
 \vdash & \langle I_0^{(1)} I_4^{(1)} \underline{I_8^{(1)}} \quad , \quad =a\$, \quad 4 \quad \rangle \\
 \vdash & \langle I_0^{(1)} \underline{I_4^{(1)} I_7^{(1)}} \quad , \quad =a\$, \quad 45 \quad \rangle \\
 \vdash & \langle I_0^{(1)} I_2^{(1)} \quad , \quad =a\$, \quad 453 \quad \rangle \\
 \vdash & \langle I_0^{(1)} I_2^{(1)} I_6^{(1)} \quad , \quad a\$, \quad 453 \quad \rangle \\
 \vdash & \langle I_0^{(1)} I_2^{(1)} I_6^{(1)} \underline{I_{12}^{(1)}} \quad , \quad \$, \quad 453 \quad \rangle \\
 \vdash & \langle I_0^{(1)} I_2^{(1)} I_6^{(1)} \underline{I_{10}^{(1)}} \quad , \quad \$, \quad 4534 \quad \rangle \\
 \vdash & \langle I_0^{(1)} I_2^{(1)} I_6^{(1)} \underline{I_9^{(1)}} \quad , \quad \$, \quad 45345 \quad \rangle \\
 \vdash & \langle \underline{I_0^{(1)} I_1^{(1)}} \quad , \quad \$, \quad 453451 \quad \rangle \\
 \vdash & \langle \epsilon \quad , \quad \$, \quad 4534510 \rangle
 \end{aligned}$$

CB 2-20

Abbildung 2.25: LR(1)-Analyseautomat

$$\begin{aligned}
 G_2: \quad S' &\rightarrow S && (0) \\
 S &\rightarrow L=R \mid R && (1,2) \\
 L &\rightarrow *R \mid a && (3,4) \\
 R &\rightarrow L && (5)
 \end{aligned}$$

LALR(1)–Analysetabelle zu G_2 :

	action				goto					
	*	=	a	\$	*	=	a	S	L	R
$I_0^{(1/0)}$	shift		shift		$I_4^{(1/0)}$		$I_5^{(1/0)}$	$I_1^{(1/0)}$	$I_2^{(1/0)}$	$I_3^{(1/0)}$
$I_1^{(1/0)}$				acc						
$I_2^{(1/0)}$		shift		red 5		$I_6^{(1/0)}$				
$I_3^{(1/0)}$				red 2						
$I_4^{(1/0)}$	shift		shift		$I_4^{(1/0)}$		$I_5^{(1/0)}$		$I_8^{(1/0)}$	$I_7^{(1/0)}$
$I_5^{(1/0)}$		red 4		red 4						
$I_6^{(1/0)}$	shift		shift		$I_4^{(1/0)}$		$I_5^{(1/0)}$		$I_8^{(1/0)}$	$I_9^{(1/0)}$
$I_7^{(1/0)}$		red 3		red 3						
$I_8^{(1/0)}$		red 5		red 5						
$I_9^{(1/0)}$				red 1						


Dabei ist:

$$\begin{aligned}
 I_i^{(1/0)} &= I_i^{(1)} && i \in \{0, 1, 2, 3, 6, 9\} \\
 I_4^{(1/0)} &= I_4^{(1)} \cup I_{11}^{(1)} \\
 I_5^{(1/0)} &= I_5^{(1)} \cup I_{12}^{(1)} \\
 I_7^{(1/0)} &= I_7^{(1)} \cup I_{13}^{(1)} \\
 I_8^{(1/0)} &= I_8^{(1)} \cup I_{10}^{(1)}
 \end{aligned}$$

CB 2-21

Abbildung 2.26: LALR(1)-Analysetabelle

Übersicht der Grammatikklassen




- $LL(0) \subsetneq LL(1) \subsetneq LR(1)$
- $LR(0) \subsetneq SLR(1) \subsetneq LALR(1) \subsetneq LR(1)$

CB 2-22

Abbildung 2.27: Übersicht der Grammatikklassen

Übersicht der Sprachklassen



Also (vgl. O. Mayer: *Syntaxanalyse*, BI 1978):


- $\mathcal{L}(LL(0)) \subsetneq REG \subsetneq \mathcal{L}(LL(1)) \subsetneq \mathcal{L}(SLR(1))$
- $\mathcal{L}(LR(0)) \subsetneq \mathcal{L}(SLR(1)) = \mathcal{L}(LALR(1))$
 $= \mathcal{L}(LR(1)) = det. CFL \subsetneq eind. CFL \subsetneq CFL$
- $\mathcal{L}(LR(0)) \not\subseteq \left\{ \begin{array}{l} LL(1) \\ REG \end{array} \right\}, \left\{ \begin{array}{l} LL(1) \\ REG \end{array} \right\} \not\subseteq \mathcal{L}(LR(0)),$
 $\mathcal{L}(LR(0)) \cap \left\{ \begin{array}{l} LL(1) \\ REG \end{array} \right\} \neq \emptyset$

CB 2-23

Abbildung 2.28: Übersicht der Sprachklassen

$$G_3 : E \rightarrow E+E \mid E * E \mid (E) \mid a \quad (1,2,3,4)$$

LR(0)-Informationen zu G_3 :



CB 2-24

Abbildung 2.29: LR(0)-Informationen von G_3

$$G_3 : E \rightarrow E+E \mid E * E \mid (E) \mid a \quad (1, 2, 3, 4)$$

Analysetablelle zu G_3 :

	action/goto						goto
	a	$+$	$*$	$($	$)$	$\$$	E
I_0	shift 3			shift 2			I_1
I_1		shift 4	shift 5			acc	
I_2	shift 3			shift 2			I_6
I_3		red 4	red 4		red 4	red 4	
I_4	shift 3			shift 2			I_7
I_5	shift 3			shift 2			I_8
I_6		shift 4	shift 5		shift 9		
I_7		red 1	shift 5		red 1	red 1	
I_8		red 2	red 2		red 2	red 2	
I_9		red 3	red 3		red 3	red 3	

SLR

$* \cdot > +$

linksass.

wobei $\text{action}(I, b) = \text{shift } i$ bedeutet:

$$\text{action}(I, b) = \text{shift}, \quad \text{goto}(I, b) = I_i$$


(Tabellenkompression)

CB 2-25

Abbildung 2.30: Analysetablelle von G_3

$$G_4 : S \rightarrow iSeS \mid iS \mid a \quad (1,2,3)$$

LR(0)-Informationen zu G_4 :



CB 2-26

Abbildung 2.31: LR(0)-Informationen von G_4

Kapitel 3

Semantische Analyse, Attributgrammatiken

Ergebnis der syntaktischen Analyse: Ableitungsbaum
kontextabhängige Eigenschaften:

- Deklariertheit von Bezeichnern ($\{ww \mid w \in \Sigma^*\} \notin CFL$)
- Typinformationen sind nicht durch CFG beschreibbar

Festlegung dieser Eigenschaften durch:

- Gültigkeitsregeln: Gültigkeitsbereich einer Deklaration
- Sichtbarkeitsregeln: Sichtbarkeit im Gültigkeitsbereich (Überdeckung globaler durch lokale Deklaration)
- Typvorschriften: Typkonsistenz

Definition: Statische Semantik: kontextabhängige, laufzeitunabhängige Eigenschaften eines Programms.

Formale Beschreibung durch *Attributgrammatiken*.

Idee: CFG + semantische Regeln \rightsquigarrow Zusatzinformationen für den Ableitungsbaum.

Semantische Analyse = Attributberechnung.

Als Ergebnis erhält man den attributierten Ableitungsbaum. Dieser bildet die Grundlage für die anschließende Synthesephase (Codegenerierung).

3.1 Attributgrammatiken

Idee: Attribute für $A \in N$ und zusätzliche semantische Regeln für ihre Berechnung.

synthetische Attribute: Bottom-Up-Berechnung

inherite Attribute: Top-Down-Berechnung

↷ beliebiger Informationstransfer im Ableitungsbaum.

Attributwerte: Symboltabellen, Typen, Code, Fehler. Daher breite Anwendbarkeit von Attributgrammatiken, syntaxgerichtete Programmierung. In Compilergeneratoren erfolgt eine automatische Attributauswertung.

Beispiel: (Binärzahlen) G_B :

$$\begin{array}{lll}
 B & \rightarrow & 0 & v.0 = 0 \\
 B & \rightarrow & 1 & v.0 = 1 \\
 L & \rightarrow & B & v.0 = v.1 \\
 & & & l.0 = 1 \\
 L & \rightarrow & LB & v.0 = 2 * v.1 + v.2 \\
 & & & l.0 = l.1 + 1 \\
 N & \rightarrow & L & v.0 = v.1 \\
 N & \rightarrow & L.L & v.0 = v.1 + v.2/2^{l.2}
 \end{array}$$

G_B erzeugt Binärzahlen mit und ohne Punkt. N ist das Startsymbol. Als synthetische Attribute sind $B, N : v$ („value“) und $L : v, l$ („length“). Semantische Regeln sind Attributgleichungen mit Attributvariablen. Mit dem Index i bezeichnen wir das i -te Nichtterminalsymbol.

Ziel: Bestimmung des Zahlwertes

- Attributwerte von v : rationale Zahlen
- Attributwerte von l : natürliche Zahlen

2. Attributisierung von G_B mit synthetischen und inheriten Attributen:

Zusätzliches *inherites* Attribut für Bits und Listen: p („position“)

$$\begin{array}{lll}
 B & \rightarrow & 0 & v.0 = 0 \\
 B & \rightarrow & 1 & v.0 = 2^{p.0} \\
 L & \rightarrow & B & v.0 = v.1 \\
 & & & l.0 = 1 \\
 & & & p.1 = p.0 \\
 L & \rightarrow & LB & v.0 = v.1 + v.2 \\
 & & & l.0 = l.1 + 1 \\
 & & & p.1 = p.0 + 1 \\
 & & & p.2 = p.0 \\
 N & \rightarrow & L & v.0 = v.1 \\
 & & & p.1 = 0 \\
 N & \rightarrow & L.L & v.0 = v.1 + v.2 \\
 & & & p.1 = 0 \\
 & & & p.2 = -l.2
 \end{array}$$

Definition: (Attributgrammatik): Sei $G = \langle N, \Sigma, P, S \rangle \in \text{CFG}$. Sei $\underline{\text{Att}}$ eine Menge von *Attributen*, $A = (A^\alpha | \alpha \in \underline{\text{Att}})$ eine Familie von *Attributwertmengen* und $\underline{\text{att}} : \chi \rightarrow \mathfrak{p}(\underline{\text{Att}})$ eine *Attributzuordnung*.

Sei $\underline{\text{Att}} = \underline{\text{Syn}} \cup \underline{\text{Inh}}$ eine Zerlegung in Teilmengen *synthetischer* und *inheriter* Attribute, so daß $\underline{\text{att}}$ zerfällt in

$$\begin{aligned} \underline{\text{syn}} : \chi &\rightarrow \mathfrak{p}(\underline{\text{Syn}}) & \text{mit } \underline{\text{syn}}(X) &= \underline{\text{att}}(X) \cap \underline{\text{Syn}} \\ \text{und } \underline{\text{inh}} : \chi &\rightarrow \mathfrak{p}(\underline{\text{Inh}}) & \text{mit } \underline{\text{inh}}(X) &= \underline{\text{att}}(X) \cap \underline{\text{Inh}} \end{aligned}$$

Eine Regel $\Pi = X_0 \rightarrow X_1 \dots X_r \in P$ bestimmt die Menge $\underline{\text{Var}}_\Pi = \{\alpha.i | \alpha \in \underline{\text{att}}(X_i), 0 \leq i \leq r\}$ der *formalen Attributvariablen* von Π mit den Teilmengen

$$\underline{\text{IVar}}_\Pi := \{ \alpha.i \mid (i = 0 \text{ und } \alpha \in \underline{\text{syn}}(X_0)) \text{ oder } (1 \leq i \leq r \text{ und } \alpha \in \underline{\text{inh}}(X_i)) \}$$

und $\underline{\text{OVar}}_\Pi := \underline{\text{Var}}_\Pi \setminus \underline{\text{IVar}}_\Pi$ der *Innenvariablen* und *Außenvariablen*

Eine *Attributgleichung* von Π (semantische Regel) hat die Form

$$\alpha.i = f(\alpha_1.i_1, \dots, \alpha_n.i_n)$$

mit $\alpha.i \in \underline{\text{IVar}}_\Pi, \alpha_1.i_1, \dots, \alpha_n.i_n \in \underline{\text{OVar}}_\Pi, f : A^{\alpha_1} \times \dots \times A^{\alpha_n} \rightarrow A^\alpha$ und $n \in \mathbb{N}$.

Sei E_Π eine Menge von Attributgleichungen, in der jede Innenvariable genau einmal vorkommt.

Dann heißt $\mathfrak{A} = \langle G, (E_\Pi | \Pi \in P) \rangle$ eine *Attributgrammatik*: $\mathfrak{A} \in \text{AG}$.

Definition: (Semantik von $G \in \text{AG}$ = Das Attributgleichungssystem eines Ableitungsbaums):

Sei $\mathfrak{A} = \langle G, (E_\Pi | \Pi \in P) \rangle \in \text{AG}$. \mathfrak{A} induziert für jeden Ableitungsbaum t von G ein *Attributgleichungssystem* E_t .

Sei $\underline{\text{Kn}}(t)$ die Menge der Knoten von t . Sie bestimmt die Menge

$$\underline{\text{Var}}_t := \{ \alpha.k \mid k \in \underline{\text{Kn}}(t) \text{ markiert durch } X \in \chi, \alpha \in \underline{\text{att}}(X) \}$$

der aktuellen *Attributvariablen* von t .

Wird an einem inneren Knoten (kein Blatt) $k_0 \in \underline{\text{Kn}}(t)$ die Regel $\Pi = X_0 \rightarrow X_1 \dots X_r$ angewandt und sind $k_1, \dots, k_r \in \underline{\text{Kn}}(t)$ die entsprechenden Nachfolgerknoten, so erhält man das *Attributgleichungssystem* E_{k_0} von k_0 aus E_Π durch Indexsubstitution ($i \mapsto k_i | 0 \leq i \leq r$) bei den Attributvariablen.

Dann ist $E_t := \bigcup \{ E_k \mid k \text{ innerer Knoten von } t \}$.

Beachte: Zu jeder aktuellen Attributvariablen $\alpha.k$, ausgenommen die inheriten der Wurzel und die synthetischen der Blätter, gibt es genau eine Gleichung der Form $\alpha.k = \dots$

Annahme:

- keine inheriten Attribute des Startsymbols
- synthetische Attribute der Terminalsymbole vom Scanner

3.1.1 Lösbarkeit von E_t

E_t kann keine, genau eine, oder mehrere Lösungen haben.

Beispiel: G enthalte die Regeln $A \rightarrow uBv$ (mit B an der i -ten Position) und $B \rightarrow w$. Ferner sei $\alpha \in \text{syn}(B)$ und $\beta \in \text{inh}(B)$. Als Attributgleichungen erhalten wir $\beta.i = f(\alpha.i)$, $\alpha.0 = g(\beta.0)$.

Der Ableitungsbaum t ergibt in E_t die *zirkuläre Abhängigkeit*

$$\beta.k = f(\alpha.k) \text{ und } \alpha.k = g(\beta.k) \Rightarrow \beta.k = f(\beta.k)$$

Für $A^\alpha = A^\beta = \mathbb{N}$, $g = \text{id}_{\mathbb{N}}$ und

1. $f(x) = x + 1 \rightsquigarrow$ keine Lösung
2. $f(x) = 2x \rightsquigarrow$ genau eine Lösung
3. $f(x) = x \rightsquigarrow$ mehrere Lösungen

Folgerung: Zirkularitäten können auftreten, sie sind unerwünscht wegen Mehrdeutigkeiten.

Definition: $\mathfrak{A} \in AG$ heißt *zirkulär*: \rightsquigarrow es gibt einen Ableitungsbaum t mit zirkulären Attributgleichungssystem E_t , d.h. eine aktuelle Attributvariable hängt von sich selbst ab.

3.1.2 Ein Zirkularitätstest für Attributgrammatiken

Sei $\mathfrak{A} = \langle G, (E_\Pi | \Pi \in P) \rangle \in AG$. Eine Regel $\Pi = X_0 \rightarrow X_1 \dots X_r$ bestimmt ihren *Abhängigkeitsgraphen* DG_Π mit der Knotenmenge $\text{Kno}(DG_\Pi) := \text{OKno}(DG_\Pi) \cup \text{UKno}(DG_\Pi)$

$$\text{OKno}(DG_\Pi) := \{\alpha.0 | \alpha \in \text{att}(X_0)\} \quad (\text{Oberknoten})$$

$$\text{UKno}(DG_\Pi) := \{\alpha.i | \alpha \in \text{att}(X_i), 1 \leq i \leq r\} \quad (\text{Unterknoten})$$

und der *Kantenmenge* $\text{Kan}(DG_\Pi)$:

$$(x_1, x_2) \in \text{Kan}(DG_\Pi) : \rightsquigarrow x_2 = f(\dots x_1 \dots) \in E_\Pi$$

$$\text{Beachte: } \text{Var}_\Pi = \text{UKno}(DG_\Pi) \cup \text{OKno}(DG_\Pi) = \text{OVar}_\Pi \cup \text{IVar}_\Pi$$

insbesondere: $\text{Kan}(DG_\Pi) \subseteq \text{OVar}_\Pi \times \text{IVar}_\Pi$, also: keine Zirkularität in DG_Π .

Problem: Beim Verkleben der DG_Π zu DG_t für einen Ableitungsbaum t können Schleifen auftreten.

Folgerung: \mathfrak{A} zirkulär \rightsquigarrow es gibt einen Ableitungsbaum t von \mathfrak{A} , so daß DG_t eine Schleife enthält.

Definition: (Attributabhängigkeit): Sei $A \in N$, $\alpha \in \text{inh}(A)$, $\alpha' \in \text{syn}(A)$. Dann heißt α' *von α unterhalb A abhängig* (Bezeichnung: $\alpha \xrightarrow{A} \alpha'$), wenn es einen Ableitungsbaum t mit Wurzel A und Wurzelknoten k existiert, so daß in DG_t ein Pfad von $\alpha.k$ nach $\alpha'.k$ führt:

$$(\alpha.k, \alpha'.k) \in \text{trans}(\text{Kan}(DG_t))$$

Beachte: Paare abhängiger Attribute von verschiedenen Ableitungsbäumen mit gleicher Wurzel müssen bei der Ermittlung von Schleifen getreent behandelt werden, weil sonst unzulässige Abhängigkeiten

entstehen können.

Definition: (Attributabhängigkeitsmengen): Sei t ein Ableitungbaum mit Wurzel A .

$$D(A, t) := \{(\alpha, \alpha') \mid \alpha \xrightarrow{A} \alpha' \text{ in } t\}$$

$$\mathcal{D}(A, t) := \{D(A, t) \mid t \text{ Ableitungsbaum mit Wurzel } A\}$$

Bei der induktiven Bestimmung benutzen wir folgende Bezeichnung:

Definition: Für $\Pi = A_0 \rightarrow w_0 A_1 w_1 A_2 \dots A_r w_r$ und $D_i \subseteq \underline{\text{inh}}(A_i) \times \underline{\text{syn}}(A_i)$ definieren wir

$$D[\Pi, D_1 \dots D_r] \subseteq \underline{\text{inh}}(A_0) \times \underline{\text{syn}}(A_0)$$

durch

$$\{(\alpha, \alpha') \mid (\alpha.0, \alpha'.0) \in \underline{\text{trans}}(\underline{\text{Kan}}(DG_\Pi) \cup \bigcup_{i=1}^r \{(\beta.i, \beta'.i) \mid (\beta, \beta') \in D_i\})\}$$

Lemma: Die Attributabhängigkeitssysteme $\mathcal{D}(A)$ mit $A \in N$ sind induktiv bestimmt durch:

1. $\Pi = A \rightarrow w \curvearrowright D[\Pi_i]$
2. $\Pi = A \rightarrow w_0 A_1 w_1 \dots A_r w_r, D_i \in \mathcal{D}(A_i) \curvearrowright D[\Pi, D_1, \dots, D_r] \in \mathcal{D}(A)$

Beweis: durch Induktion über die Struktur der Ableitungsbäume.

Bemerkung: Da für $D \in \mathcal{D}(A)$ gilt: $D \subseteq \underline{\text{inh}}(A) \times \underline{\text{syn}}(A)$ bricht der Berechnungsprozeß nach endlich vielen Schritten ab.

Folgerung: (Zirkularitätstest): $\mathfrak{A} \in AG$ ist zirkulär \curvearrowright es gibt $\Pi = A_0 \rightarrow w_0 A_1 \dots A_r w_r, a.k = \underline{\text{UKno}}$ und $D_i \in \mathcal{D}(A_i) (1 \leq i \leq r)$, so daß $(\alpha.k, \alpha.k) \in \underline{\text{trans}}(\underline{\text{Kan}}(DG_\Pi) \cup \bigcup_{i=1}^r \{(\beta.i, \beta'.i) \mid (\beta, \beta') \in D_i\})$.

Komplexität des Zirkularitätstest

$n = |\mathfrak{A}|, T(n)$ Zeit zur Entscheidung der Zirkularität.

$$2^{c \cdot n / \log(n)} \leq T(n) \leq 2^{d \cdot n^2}$$

3.1.3 Stark-nichtzirkuläre Grammatiken

Keine Trennung der Abhängigkeitsmengen verschiedener Ableitungsbäume.

$$D(A) := \{(\alpha, \alpha') \mid \alpha \xrightarrow{A} \alpha'\}$$

Hinzureichendes Kriterium für die Nichtzirkularität; Test in Polynomzeit.

Beachte: Es gibt $\mathfrak{A} \in AG$, so daß A nicht-zirkulär ist, ohne stark-nichtzirkulär zu sein.

3.1.4 Attributberechnung

1. E_t als Termersetzungssystem, Top-Down-Berechnung. Keine Zirkularität \leadsto Termination mit eindeutiger Lösung.
2. Bottom-Up-Auflösung von E_t : Variablen durch Werte ersetzen und Terme ausrechnen.
3. Uniforme Berechnung, unabhängig vom Ableitungsbaum
 - (a) Berechnungspläne für $(E_\Pi | \Pi \in P)$ aufstellen.
 - (b) Rekursive Funktionen für $(E_\Pi | \Pi \in P)$ aufstellen.

Idee: Jedem synthetischen Attribut einer Variablen wird eine Funktion zugeordnet mit ihrem inheriten Attribut als Parameter.

4. Spezialfall: SAG, LAG

3.2 S-Attributgrammatiken

Definition: $\mathcal{A} \in AG$ heißt S-Attributgrammatik ($A \in SAG$), wenn $\underline{Inh} = \emptyset$, also $\underline{Att} = \underline{Syn}$.

Folgerung: Bottom-Up-Berechnung der Attributwerte.

Idee: Durchführung während der Bottom-Up-Syntaxanalyse, zwischenspeichern von Attributwerten im Analysekeiler.

Beispiel: $A \rightarrow BaD$

I_1	$v3$
I_7	$v2$
I_3	$v1$

Beim Reduktionsschritt werden simultan die Werte der synthetischen Attribute von A aus den Werten unter $v1, v2, v3$ berechnet („Records“).

Beispiel: Stackcode für arithmetische Ausdrücke

E	\rightarrow	$(E + E)$	$ $	$c.0 = c.2; c.4; ADD$
		$(E * E)$	$ $	$c.0 = c.2; c.4; MULT$
		id	$ $	$c.0 = LOAD c.1$
		num	$ $	$c.0 = LIT c.1$

Werte von $c.1$: lexikalische Attribute, die mit dem Token vom Scanner übergeben: $(id, X) (num, 5)$

$$((3 + X) * (Y + 5))$$

↓ Scanner

$$((\langle num, 3 \rangle + \langle id, X \rangle) * (\langle id, Y \rangle + \langle num, 5 \rangle))$$

Codegenerierung durch Attributauswertung während der Syntaxanalyse.

Shift: Aufruf des Scanners durch „nextsym“

- (i) Token $\mapsto LR(0)$ -Menge (mit goto)
- (ii) lexikalisches Attribut

Beide Informationen auf dem Analysekeiler.

- Reduce:
- (i) Reduktion auf dem Analysekeiler
 - (ii) simultane Attributberechnung

Accept: Wurzelattribut; in diesem Fall: der Stackcode des Ausdrucks.

Das Wurzelattribut ergibt sich dann als: *LIT3;LOADX;ADD;LOADY;LIT5;ADD;MULT*

Beispiel: Berechnung des *Abstrakten Syntaxbaums* (AST). Konkrete Syntax und abstrakte Syntax:

$$\Pi = A_0 \rightarrow w_0 A_1 w_1 \dots A_r w_r$$

repräsentiert Operationssymbol F_{Π} vom Typ $A_1 \times \dots \times A_r \rightarrow A_0$ (A_r Sorte, Typ)

Das „Verkleben“ der Regeln zu einem Ableitungsbaum entspricht der funktionalen Applikation der zugehörigen Operationssymbole.

Folgerung: Der Ableitungsbaum vereinfacht sich zu dem AST. Nur der AST ist für die Übersetzung erforderlich.

Aufgabe: Berechnung des AST während der Bottom-Up Analyse. Dazu Methode der S-Attributgrammatik.

Darstellung des Aufbaus von ASTs durch Konstruktion von Graphen:

1. Graphen

- $a \in \underline{\text{Adr}}$ unendliche Menge von Adressen für Speicherplätze (Heap)
- Ω Operationsalphabet mit Stelligkeiten
- $f^{(n)} \in \Omega = \{\underline{\text{assign}}^{(1)}, \underline{\text{seq}}^{(2)}, \underline{\text{cond}}^{(2)}, \underline{\text{less}}^{(2)}, \underline{\text{plus}}^{(2)}, \underline{\text{id}}^{(0)}, \underline{\text{num}}^{(0)}\}$
- $k \in \underline{\text{Kno}} := \{(a, f, a_1, \dots, a_n) \mid a, a_i \in \underline{\text{Adr}}, f \in \Omega^{(n)}\}$
- Graph: Menge von Knoten mit einer Wurzel
- $G \in \underline{\text{Graph}} := \{(a, k) \mid a \in \underline{\text{Adr}}, k \subseteq \underline{\text{Kno}}\}$

2. Konstruktorfunktionen für Graphen

$$f^{(n)} \in \Omega \mapsto \underline{\text{mk-f}} : \underline{\text{Graph}}^n \rightarrow \underline{\text{Graph}}$$

$$\underline{\text{mk-f}}((a_1, k_1), \dots, (a_n, k_n)) := (a, k)$$

mit neuer Adresse a und

$$K := \{(a, f, a_1, \dots, a_n)\} \cup \bigcup_{i=1}^n K_i$$

Beispiel: Typberechnung für arithmetische Ausdrücke

$\underline{\text{Typ}} := \{\text{int}, \text{real}\}$ mit $\underline{\text{max}} : \underline{\text{Typ}}^2 \rightarrow \underline{\text{Typ}}$, bzgl. $\text{int} < \text{real}$

3.3 L-Attributgrammatiken

Definition: $\mathfrak{A} = \langle G, (E_{\Pi} | \Pi \in P) \rangle \in AG$ ist eine *L-Attributgrammatik* ($\mathfrak{A} \in LAG$): \curvearrowright Für jede Attributgleichung $\alpha.i = f(\dots \beta.j \dots)$ gilt: $\alpha \in \underline{\text{Inh}}, \beta \in \underline{\text{Syn}} \curvearrowright j < i$

Folgerung: $G \in LAG$ nicht zirkulär. Attributberechnung in „depth-first, left-to-right order“. Baumreise mit 2 Knotenbesuchen:

1. top-down: inherite Attribute
2. bottom-up: synthetische Attribute

3.3.1 Syntaxanalyse mit L-Attributauswertung

Sei $\mathfrak{A} = \langle G, (E_{\Pi} | \Pi \in P) \rangle \in LAG$ mit $G \in LL(1)$

Ziel: Erweiterung der Top-Down Analyse zur Berechnung eines synthetischen Wurzelattributs.

Methode: Expansion von $A \in N$ auf Analysekeiler so gestalten, daß spätere Reduktion möglich: Kombination von Top-Down (inherite Attribute) und Bottom-Up (synthetische Attribute).

Kellularalphabet: $\bigcup_{\Pi \in P} (\underline{\text{LR}}(0)_{\Pi}(G) \times \underline{\text{Val}}_{\Pi})$ mit $\underline{\text{LR}}(0)_{\Pi}(G) := \{[A \rightarrow \alpha.\beta] | \Pi = A \rightarrow \alpha\beta\}$ und $\underline{\text{Val}}_{\Pi} = \{\underline{\text{val}}_{\Pi} | \underline{\text{val}}_{\Pi} : \underline{\text{Var}}_{\Pi} \rightarrow \text{„Attributwerte“}\}$

1. „expand“-Schritt mit Berechnung inheriter Attribute.

\vdots $[A \rightarrow X_1 \dots X_{i-1} \cdot B\gamma]$	$\underline{\text{val}}$	\Rightarrow	\vdots $[A \rightarrow X_1 \dots X_{i-1} \cdot B\gamma]$	$\underline{\text{val}}$
			$[B \rightarrow \cdot \beta]$	$\underline{\text{val}}'$

Dabei ist $B \rightarrow \beta$ wegen $G \in LL(1)$ durch Eingabe-„look-ahead“ bestimmt.

$\underline{\text{val}}'$ belegt die inheriten Attributvariablen von B nach Attributgleichungen für $A \rightarrow X_1 \dots X_{i-1} B\gamma$.

Sei $\alpha \in \underline{\text{inh}}(B)$ und $\alpha.i = t \in E_{A \rightarrow X_1 \dots \gamma}$, so $\underline{\text{val}}'(\alpha.0) = \hat{t}$ (Wert von t bezüglich $\underline{\text{val}}$).

2. „match“-Schritt:

\vdots $[A \rightarrow \gamma \cdot a\gamma']$	$\underline{\text{val}}$	\Rightarrow	\vdots $[A \rightarrow \gamma a \cdot \gamma']$	$\underline{\text{val}}$
---	--------------------------	---------------	--	--------------------------

falls nächstes Eingabesymbol. Eingabekopf rückt vor

3. „reduce“-Schritt mit Berechnung der synthetischen Attribute.

\vdots $[A \rightarrow X_1 \dots X_{i-1} \cdot B\gamma]$	$\underline{\text{val}}$	\Rightarrow	\vdots $[A \rightarrow X_1 \dots X_{i-1} B \cdot \gamma]$	$\underline{\text{val}}''$
$[B \rightarrow \beta \cdot]$	$\underline{\text{val}}'$			

$\underline{\text{val}}''$ erweitert $\underline{\text{val}}$ um synthetische Attribute von B .

$\underline{\text{val}}''(\alpha.i) = \hat{t}$ (bezüglich $\underline{\text{val}}'$) falls $\alpha.0 = t \in E_{B \rightarrow \beta}$

3.3.2 Anwendung von LAG

Überprüfung der Deklariertheit von Bezeichnern. G sei gegeben durch:

Programm	$P \rightarrow DL;SL$
Deklarations-Liste	$DL \rightarrow V V;DL$
Statement-Liste	$SL \rightarrow S S;SL$
Variable	$V \rightarrow a b \dots$
Statement	$S \rightarrow V := V$
Beispiel	$c;b;a;a := c;b := a;d := a$

Attribute

syn. A.	v	deklarierte oder benutze Variable für V mit Wert aus $\{a, b, c, \dots\}$
syn. A.	dv	Menge von deklarierten Variablen für DL mit Werten aus $\subseteq \{a, b, c, \dots\}$
inh. A.	env	Umgebung für S, SL mit Werten aus $\subseteq \{a, b, c, \dots\}$
syn. A.	$decl$	„deklariert“ für S, SL, D mit Werten aus $\{true, false\}$


Attributgleichungen

$P \rightarrow DL;SL$	$decl.0 = decl.3$	
	$env.3 = dv.1$	(Beachte: $1 \leq 3!$)
$DL \rightarrow V$	$dv.0 = \{v.1\}$	
$DL \rightarrow V;DL$	$dv.0 = \{v.1\} \cup dv.3$	
$V \rightarrow a$	$v.0 = a$	
$SL \rightarrow S$	$env.1 = env.0$	
	$decl.0 = decl.1$	
$SL \rightarrow S;SL$	$env.1 = env.0$	
	$env.3 = env.0$	
	$decl.0 = decl.1 \underline{AND} decl.3$	
$S \rightarrow V := V$	$decl.0 = v.1 \in env.0 \underline{AND} v.3 \in env.0$	

3. Semantische Analyse

Bsp.: (Binärzahlen von Knuth)

- $$G_B : \quad (1) \quad B \rightarrow 0 \quad (2) \quad B \rightarrow 1$$
- $$(3) \quad L \rightarrow B \quad (4) \quad L \rightarrow LB$$
- $$(5) \quad N \rightarrow L \quad (6) \quad N \rightarrow L.L$$




CB 3-1

Abbildung 3.1: Binärzahlen von Knuth

Attributierung von G_B mit synthetischen und
inheriten Attributen:

- G_B : (1) $B \rightarrow 0$ (2) $B \rightarrow 1$
 (3) $L \rightarrow B$ (4) $L \rightarrow LB$
 (5) $N \rightarrow L$ (6) $N \rightarrow L.L$



CB 3-2

Abbildung 3.2: Attributierung von G_B mit synthetischen und inheriten Attributen

Attributgleichungen:	
π	E_π
$B \rightarrow 0$	$v.0 = 0$
$B \rightarrow 1$	$v.0 = 2** (p.0)$
$L \rightarrow B$	$v.0 = v.1$ $l.0 = 1$ $p.1 = p.0$
$L \rightarrow LB$	$v.0 = +(v.1, v.2)$ $l.0 = +(l.1, 1)$ $p.1 = +(p.0, 1)$ $p.2 = p.0$
$N \rightarrow L$	$v.0 = v.1$ $p.1 = 0$
$N \rightarrow L.L$	$v.0 = +(v.1, v.3)$ $p.1 = 0$ $p.3 = -(l.3)$

CB 3-3

Abbildung 3.3: Attributgleichungen




Abbildung 3.4: Das Attributgleichungssystem




Abbildung 3.5: Abhängigkeitsgraphen


Konkrete und abstrakte Syntax (Beispiel)

$G: S \rightarrow id:=E \mid begin\ S;S\ end \mid if\ B\ then\ S$

$B \rightarrow E < E$

$E \rightarrow E + E \mid id \mid num$

Ableitungsbaum:



Operationsalphabet:


assign : $E \rightarrow S$ **less** : $E \times E \rightarrow B$

seq : $S \times S \rightarrow S$ **plus** : $E \times E \rightarrow E$

cond : $B \times S \rightarrow S$ **ident** : $\rightarrow E$

number : $\rightarrow E$

Abstrakter Syntaxbaum:



CB 3-6

Abbildung 3.6: konkrete und abstrakte Syntax

Kapitel 4

Übersetzung in Zwischencode

Aufteilung der Codeerzeugung: $PS \xrightarrow{trans} Z \xrightarrow{code} MC$

- front-end: trans erzeugt maschinenunabhängigen Zwischencode für eine abstrakte Stackmaschine
- back-end: code erzeugt Maschinencode

Vorteil dieser Zerlegung: Z ist maschinenunabhängig \rightarrow Portabilität, Transparenz, Codeoptimierung.

4.1 Übersetzung von Ausdrücken, Anweisungen, Blöcken und Prozeduren

Beispiel: Programmiersprache *BPS* (Pascal ohne Datenstrukturen und Prozedurparameter)

- arithmetische und boolesche Ausdrücke mit strikter, bzw. nicht-strikter Semantik
- Blöcke und Prozeduren: lokale und globale Variablen. Erfordert dynamische Speicherverwaltung mit Laufzeitkeller. Unterschiedliche Verwendung in Programmiersprachen:
 - FORTRAN: Unterprogramme, nicht geschachtelt, keine Rekursion
 \rightsquigarrow statische Speicherverwaltung, Speicherbedarf zur Übersetzungszeit bekannt
 - C: rekursive Prozeduren, aber nicht geschachtelt
 \rightsquigarrow dynamische Speicherverwaltung, Speicherbedarf erst zur Laufzeit bekannt, keine statischen Verweise auf dem Laufzeitkeller
 - ALGOL-Familie: ALGOL60, Pascal, Modula, geschachtelte rekursive Prozedurdeklarationen
 \rightsquigarrow dynamische Speicherverwaltung, Laufzeitkeller mit statischen Verweisen
- keine Datenstrukturen, keine Prozedurparameter
- Beschränkung auf Datentyp int

4.1.1 Semantik von BPS

- Bezeichner einer Deklaration Δ müssen paarweise verschieden sein.
- Ein im Anweisungsteil Γ eines Blockes $\Delta\Gamma$ auftretender Bezeichner muß deklariert sein, und zwar in Δ oder in der Deklarationsliste eines $\Delta\Gamma$ umschließenden Blocks.
- Mehrfachdeklaration eines Bezeichners auf verschiedenen Niveaus möglich, die „innerste“ Deklaration ist für ein Auftreten gültig.
- **Static Scope:** Beim Aufruf einer Prozedur ist ihre Deklaration und nicht ihre Aufruf-Umgebung gültig.

4.1.2 Zwischencode für BPS

AM: abstrakte Maschine mit Datenkeller und Prozedurkeller.

Zustandsraum $ZR := BZ \times DK \times PK$

mit Befehlszähler $BZ := \mathbb{N}$, Datenkeller $DK = \mathbb{Z}^*$ (Spitze rechts) und Prozedurkeller $PK = \mathbb{Z}^*$ (Spitze links).

Zustand $s = (m, d, p) \in ZR$

mit Befehlsmarke $m \in \mathbb{N}$, DK-Zustand $d = d.r : \dots : d.1$ und PK-Zustand $p = p^1 \dots p^t$.

AM-Befehle:

- arithmetische Befehle: ADD, ...
- logische Befehle: NOT, AND, OR, LT, ...
- Sprungbefehle: JMP n , JFALSE n ($n \in \mathbb{N}$)
- Prozedurbefehle: CALL(ca, dif, loc) (mit $ca, dif, loc \in \mathbb{N}$), RET
- Transportbefehle: LOAD(dif, off), STORE(dif, off), mit $dif, off \in \mathbb{N}$ und LIT z mit $z \in \mathbb{Z}$

Befehlssemantik

$Z = (m, d, p) \in ZR$ (Z: Zustand der abstrakten Maschine)

$\llbracket B \rrbracket : ZR \rightarrow ZR$ für jeden AM-Befehl B

$\llbracket ADD \rrbracket(m, d : Z_1 : Z_2, p) := (m + 1, d : (Z_2 + Z_1), p)$

$\llbracket LT \rrbracket(m, d : z_1 : z_2, p) := (m + 1, d : b, p)$ mit $b = \begin{cases} 1 & , z_1 < z_2 \\ 0 & , z_1 \geq z_2 \end{cases}$

$\left. \begin{array}{l} \llbracket AND \rrbracket(m, d : b_1 : b_2, p) := (m + 1, d : b_1 \wedge b_2, p) \\ \llbracket OR \rrbracket(m, d : b_1 : b_2, p) := (m + 1, d : b_1 \vee b_2, p) \\ \llbracket NOT \rrbracket(m, d : b, p) := (m + 1, d : \neg b, p) \end{array} \right\} \text{ mit } b, b_1, b_2 \in \{0, 1\}$

$\llbracket JFALSE n \rrbracket(m, d : b, p) := \begin{cases} (n, d, p) & , b = 0 \\ (m + 1, d, p) & , b = 1 \end{cases}$

$\llbracket JMP n \rrbracket(m, d, p) := (n, d, p)$

p zerfällt in Aktivierungsblöcke („Frames“) der Form

$$sv : dv : ra : l_1 : \dots : l_n$$

mit sv : statischer Verweis, dv : dynamischer Verweis, ra : Rücksprungadresse nach Beendigung des Prozeduraufrufs und l_i : lokale Variable eines Prozessaufrufs.

sv zeigt auf den Aktivierungsblock der Deklarationsumgebung, dv zeigt auf den letzten Aktivierungsblock.

Berechnung des statischen Verweises

sv liefert die Differenz zwischen Aufruf und Deklarationsniveau und damit die Länge der Verweiskette. Dazu

$$\text{Hilfsfunktion } \underline{\text{base}} : PK \times \mathbb{N}^- \rightarrow \mathbb{N}$$

bestimmt für einen Prozedurkeller bezüglich einer Niveaudifferenz den Beginn der Deklarationsumgebung (als absolute Adresse des aktuellen PK).

$$\underline{\text{base}}(p, 0) := 1$$

$$\underline{\text{base}}(p, \text{diff} + 1) := \underline{\text{base}}(p, \text{diff}) + p.\underline{\text{base}}(p, \text{diff})$$

Beispiel: (Folie 4.7)

$$\begin{aligned} \underline{\text{base}}(p, 2) &= \underline{\text{base}}(p, 1) + p.\underline{\text{base}}(p, 1) \\ \underline{\text{base}}(p, 1) &= \underline{\text{base}}(p, 0) + p.\underline{\text{base}}(p, 0) \\ &= 1 + p.1 = 6 \\ \underline{\text{base}}(p, 2) &= 6 + p.6 = 11 \\ \text{Es folgt: } \underbrace{s}_{\text{rel. Adr.}} &= \underline{\text{base}}(p, 2) + \underbrace{2}_{\text{lok. Var.}} + \underbrace{2}_{ra+dv} = 15 \end{aligned}$$

- $CALL(ca, dif, loc)$
mit $ca \in \mathbb{N}$ als Codeadresse, $dif \in \mathbb{N}$ als Niveaudifferenz und $loc \in \mathbb{N}$ für die Anzahl lokaler Variablen. Erzeugt neuen Aktivierungsblock und springt zum Code des Prozedurrumpfs.

$$\begin{aligned} \llbracket CALL(ca, dif, loc) \rrbracket(m, d, p) := \\ (ca, d, \underbrace{(base(p, dif) + loc + 2)}_{sv} : \underbrace{loc + 2}_{dv} : \underbrace{m + 1}_{ra} : \underbrace{0 : \dots : 0}_{\text{lok. Var.}} : p) \end{aligned}$$

- RET löscht den letzten Aktivierungsblock und kehrt zur Aufrufstelle zurück

$$\begin{aligned} \llbracket RET \rrbracket(m, d, p.1 : \dots : p.t) := \\ \underline{\text{if}} t \geq 2 + p.2 \underline{\text{then}} (p.3, d, p. \underbrace{(2 + p.2)}_{\text{Start nächster Aktivierungsblock}} : \dots : p.t) \end{aligned}$$

PK wird stets mindestens einen Aktivierungsblock enthalten.

- $LOAD(dif, off)$ und $STORE(dif, off)$ laden und speichern zwischen.
 DK und PK : relative Adressierung mit

- Niveaudifferenz dif zwischen Auftreten und Deklaration
- Offset off als relative Adresse in Aktivierungsblock

Die Kette der statischen Verweise bestimmt die sichtbare Umgebung auf PK .

$$\llbracket \text{LOAD}(dif, off) \rrbracket(m, d, p) := (m + 1, d : p. [\text{base}(p, dif) + 2 + off], p)$$

$$\llbracket \text{STORE}(dif, off) \rrbracket(m, d : z, p) := (m + 1, d, p [\text{base}(p, dif) + 2 + off / z])$$

$$\llbracket \text{LIT}z \rrbracket(m, d, p) := (m + 1, d : z, p)$$

Definition: AM-Code: Befehlsfolgen mit aufsteigenden Befehlsmarken

$P \in \underline{\text{AM-Code}} := P = a_1 : B_1; \dots; a_p : B_{pi}$ mit $a_i \in \underline{\text{Adr}} := \mathbb{N}, a_i = a_1 + i - 1$ und B_i ein AM-Befehl ($1 \leq i \leq p$).

Semantik von P : Iteration der Befehle gemäß BZ

$$\mathcal{I} : \underline{\text{AM-Code}} \times \underline{\text{ZR-}} \rightarrow \underline{\text{ZR}}$$

$$\mathcal{I} \llbracket P \rrbracket(m, d, p) := \text{if } a_1 \leq m \leq a_p \text{ then} \\ \quad \mathcal{I} \llbracket P \rrbracket(\underbrace{\llbracket B_m \rrbracket(m, d, p)}_{(m', d', p')}) \\ \quad \text{else } (m, d, p)$$

4.1.3 Übersetzung von BPS-Programmen in AM-Code

$\text{trans} : \underline{\text{BPS-Prog}} \rightarrow \underline{\text{AM-Code}}$ (Zwischencode Z)

Hilfsmittel: Symboltabelle

$$\underline{\text{Tab}} := \{st \mid st : \underline{\text{Ide-}} \rightarrow (\{\underline{\text{const}}\} \times \mathbb{Z}) \\ \cup (\{\underline{\text{var}}\} \times \underline{\text{Lev}} \times \underline{\text{Off}}) \cup (\{\underline{\text{proc}}\} \times \underline{\text{Adr}} \times \underline{\text{Lev}} \times \underline{\text{Size}})$$

Variablendeklaration: Deklarationsniveau $dl \in \underline{\text{Lev}}$, Offset $off \in \underline{\text{Off}} := \mathbb{N}$

Prozessdeklaration: Startadresse $ca \in \underline{\text{Adr}}$ ds Prozedurcodes, Deklarationsniveau $dl \in \underline{\text{Lev}}$, Anzahl der lokalen Variablen $loc \in \underline{\text{Size}} := \mathbb{N}$

Aufbau der Symboltabelle

$$\underline{\text{up}} : \underline{\text{Decl}} \times \underline{\text{Tab}} \times \underline{\text{Adr}} \times \underline{\text{Lev-}} \rightarrow \underline{\text{Tab}}$$

$\underline{\text{up}}(\Delta, st, a, l)$ beschreibt den Update einer Symboltabelle st bezüglich einer Deklaration Δ bei freier Adresse a und aktuellem Niveau l (Blockschachtelungstiefe).

$$\underline{\text{up}}(\Delta_c \Delta_v \Delta_p, st, a, l) := \text{if } \text{diffid}(\Delta_c \Delta_v \Delta_p) \text{ then} \\ \quad \underline{\text{up}}(\Delta_p, \underline{\text{up}}(\Delta_v, \underline{\text{up}}(\Delta_c, st, a, l), a, l), a, l)$$

- $\underline{\text{up}}(\varepsilon, st, a, l) := st$
- $\underline{\text{up}}(\underbrace{\text{const}I_1 = Z_1, \dots, I_n = Z_n}_{\Delta_c}, st, a, l) := st[I_1/(\underline{\text{const}}, Z_1), \dots, I_n/(\underline{\text{const}}, Z_n)]$
- $\underline{\text{up}}(\underbrace{\text{var}I_1, \dots, I_n}_{\Delta_v}, st, a, l) := st[I_1/(\underline{\text{var}}, l, 1), \dots, I_n/(\underline{\text{var}}, l, n)]$
- $\underline{\text{up}}(\underbrace{\text{proc}I_1, B_1; \dots; I_n, B_n}_{\Delta_p}, st, a, l) :=$
 $st[I_1/(\underline{\text{proc}}, a_1, l, \underline{\text{size}}(B_1)), \dots, I_n/(\underline{\text{proc}}, a_n, l, \underline{\text{size}}(B_n))]$

Dabei sind a_1, \dots, a_n symbolische „freie“ Adressen.

$\underline{\text{size}} : \text{Block} \rightarrow \mathbb{N}$

ermittelt den Speicherbedarf als Anzahl der lokalen Variablen.

$$\underline{\text{size}}(\Delta_c \text{var}I_1, \dots, I_n; \Delta_p \Gamma) := n$$

Anfangstabelle

$P = \underline{\text{in/out}}I_1, \dots, I_n, B \cdot$ hat die Semantik $\mathcal{M}[[P]] : \mathbb{Z}^n \rightarrow \mathbb{Z}^n$. Für $(z_1, \dots, z_n) \in \mathbb{Z}^n$ wählen wir den Anfangszustand

$$s = (1, \varepsilon, 0 : 0 : 0 : z_1 : z_2 : \dots : z_n) \in ZR$$

mit 1 als Startadresse des AM-Codes von P , ε als leeren Datenkeller DK und $0 : 0 : 0 : z_1 : \dots : z_n$ als I/O-Block auf dem Prozedurkeller PK . Die entsprechend initialisierte Anfangstabelle hat daher n Einträge $st_{I/O}(I_j) = (\underline{\text{var}}, 0, j)$.

Weitere Hilfsfunktionen zur Definition der Übersetzung $\underline{\text{trans}}$ sind die folgenden:

- $\underline{\text{bt}} : \text{Block} \times \text{Tab} \times \text{Adr} \times \text{Lev}^- \rightarrow \text{AM-Code}$
- $\underline{\text{dt}} : \text{Decl} \times \text{Tab} \times \text{Adr} \times \text{Lev}^- \rightarrow \text{AM-Code}$
- $\underline{\text{ct}} : \text{Cmd} \times \text{Tab} \times \text{Adr} \times \text{Lev}^- \rightarrow \text{AM-Code}$
- $\underline{\text{et}} : \text{AExp} \times \text{Tab} \times \text{Adr} \times \text{Lev}^- \rightarrow \text{AM-Code}$
- $\underline{\text{sbt}} : \text{BExp} \times \text{Tab} \times \text{Adr} \times \text{Lev}^- \rightarrow \text{AM-Code}$

Der Parameter $l \in \text{Lev} := \mathbb{N}$ beschreibt die Blockschachtelungstiefe.

4.1.4 Die Übersetzung

Start der Übersetzung mit

$$\begin{aligned} \underline{\text{trans}}(\underline{\text{in/out}}I_1, \dots, I_n; B \cdot) &:= 1 : \text{CALL}(a_\Gamma, 0, \underline{\text{size}}(B)); \\ &2 : \text{JMP } 0; \\ &\underline{\text{bt}}(B, st_{I/O}, a_\Gamma, l) \end{aligned}$$

a_Γ : Startadresse des Anweisungsteils Γ in $B = \Delta\Gamma$

Blockübersetzung

$$\begin{aligned} \underline{bt}(\Delta\Gamma, st, a, l) &:= \underline{dt}(\Delta, \overbrace{\underline{up}(\Delta, st, a_1, l)}^!, a_1, l) \\ &\quad \underline{ct}(\Gamma, \underline{up}(\Delta, st, a_1, l), a, l) \\ &\quad d' : \mathbf{RET}; \end{aligned}$$

Dabei erzeugt \underline{dt} Code für die Prozedurrümpfe von Δ , in der zugehörigen Symboltabelle sind nicht nur die Konstanten und Variablen von Δ , sondern auch die Prozedurbezeichner (Rekursion!) eingetragen. \underline{ct} erhält die übergebene Startadresse und erzeugt Codes für einen Prozessrumpf, der mit einem Rücksprung endet.

Deklarationsübersetzung

$$\begin{aligned} \underline{dt}(\Delta_c\Delta_v\Delta_p, st, a, l) &:= \underline{dt}(\Delta_p, st, a, l) \\ \underline{dt}(\varepsilon, st, a, l) &:= \varepsilon \\ \underline{dt}(\underline{\text{proc}}I_1, B_1; \dots; I_n, B_n; st, a, l) &:= \underline{bt}(B_1, st, a_1, l + 1) \\ &\quad \vdots \\ &\quad \underline{bt}(B_n, st, a_n, l + 1) \end{aligned}$$

Beachte:

- $st(I_j) = (\underline{\text{proc}}, a_j, l + 1)$, weil \underline{bt} die Funktionen \underline{dt} und \underline{up} mit den gleichen Anfangsparameter aufruft und beide Funktionen aus diesen in gleicher Weise die Adressen für die Prozedurrümpfe erzeugt.
- \underline{bt} wird mit dem Level $l + 1$ aufgerufen.

Anweisungsübersetzung

$$\begin{aligned} \underline{ct}(I := E, st, a, l) &:= \underline{\text{if}} \quad st(I) = (\underline{\text{var}}, dl, off) \underline{\text{then}} \\ &\quad \underline{ct}(E, st, a, l) \\ &\quad d' : \mathbf{STORE}(l - dl, off); \end{aligned}$$

$$\begin{aligned} \underline{ct}(I(), st, a, l) &:= \underline{\text{if}} \quad st(I) = (\underline{\text{proc}}, ca, dl, loc) \underline{\text{then}} \\ &\quad a : \mathbf{CALL}(ca, l - dl, loc); \end{aligned}$$

$$\begin{aligned} \underline{ct}(\Gamma_1; \Gamma_2, st, a, l) &:= \underline{ct}(\Gamma_1, st, a, l) \\ &\quad \underline{ct}(\Gamma_2, st, a', l) \end{aligned}$$

$$\begin{aligned}
\underline{ct}(\underline{\text{if}} \ BE \ \underline{\text{then}} \ \Gamma_1 \ \underline{\text{else}} \ \Gamma_2, st, a, l) &:= \underline{sbt}(BE, st, a, l) \\
& a' : \mathbf{JFALSE} \ a''; \\
& \underline{ct}(\Gamma_1, st, a' + 1, l) \\
& a'' - 1 : \mathbf{JMP} \ a''; \quad // \text{hinter } \underline{ct}(\Gamma_2, \dots) \\
& \underline{ct}(\Gamma_2, st, a'', l) \\
& a''' : \dots
\end{aligned}$$

$$\begin{aligned}
\underline{ct}(\underline{\text{while}} \ BE \ \underline{\text{do}} \ \Gamma, st, a, l) &:= \underline{sbt}(BE, st, a, l) \\
& a' : \mathbf{JFALSE} \ a'' + 1 \\
& \underline{ct}(\Gamma, st, a' + 1, l) \\
& a'' : \mathbf{JMP} \ a;
\end{aligned}$$

$$\begin{aligned}
\underline{et}(z, st, a, l) &:= a : \mathbf{LIT} \ z; \\
\underline{et}(I, st, a, l) &:= \underline{\text{if}} \ st(I) = (\underline{\text{const}}, z) \ \underline{\text{then}} \\
& \quad a : \mathbf{LIT} \ z; \\
& \quad \underline{\text{if}} \ st(I) = (\underline{\text{var}}, dl, off) \\
& \quad \quad a : \mathbf{LOAD}(l - dl, off); \\
\underline{et}(E_1 + E_2, st, a, l) &:= \underline{et}(E_1, st, a, l) \\
& \quad \underline{et}(E_2, st, a', l) \\
& \quad a'' : \mathbf{ADD};
\end{aligned}$$

Bemerkung: \underline{et} erzeugt Stackcode, dessen Berechnung den Wert des Ausdruckes auf dem Datenkeller liefert.

$$\begin{aligned}
\underline{sbt}(E_1 < E_2, st, a, l) &:= \underline{et}(E_1, st, a, l) \\
& \quad \underline{et}(E_2, st, a', l) \\
& \quad a'' : \mathbf{LT}; \\
\underline{sbt}(\underline{\text{not}} \ BE, st, a, l) &:= \underline{sbt}(BE, st, a, l) \\
& \quad a' : \mathbf{NOT}; \\
\underline{sbt}(BE_1 \ \underline{\text{and}} \ BE_2, st, l) &:= \underline{sbt}(BE_1, st, a, l) \\
& \quad \underline{sbt}(BE_2, st, a', l) \\
& \quad a'' : \mathbf{AND};
\end{aligned}$$

Striker Stackcode für boolesche Ausdrücke: beide Argumente werden stets berechnet.

Satz: (Korrektheit der Übersetzung): Für jedes Programm $P \in \text{Prog}^{(n)}$ und $(z_1, \dots, z_n), (z'_1, \dots, z'_n) \in \mathbb{Z}^n$ gilt: $\mathcal{M}[[P]](z_1, \dots, z_n) = (z'_1, \dots, z'_i) \Leftrightarrow$

$$\mathcal{S}[[\text{trans}(P)]](1, \varepsilon, 0 : 0 : 0 : z_1 : \dots : z_n) = \\ (0, \varepsilon, 0 : 0 : 0 : z'_1 : \dots : z'_i)$$

Beweis: M Mohnen: A Compiler Correctness Proof for the Static Link Technique by means of Evolving Algebras (Fund. Inf. 29(1997)3,257-303).

4.1.5 Jumping Code für boolesche Ausdrücke

Übersetzung boolescher Ausdrücke mit nicht-strikter Semantik.

Idee: Vererbung von Sprungzielen für boolesche Ergebnisse

$$\underline{nbt} : \text{BExp} \times \text{Tab} \times \text{Adr}^3 \times \text{Lev-} \rightarrow \text{AM-Code}$$

(Adr: 1. freie Anfangsadresse, 2. true-Adresse, 3. false-Adresse).

mit geeigneter Modifikation der Übersetzung von Verzweigung und Iteration.

$$\begin{aligned} \underline{nbt}(E_1 < E_2, st, a, a_t, a_f, l) &:= \underline{et}(E_1, st, a, l) \\ &\quad \underline{et}(E_2, st, a', l) \\ &\quad a'' : \mathbf{LT}; \\ &\quad a'' + 1 : \mathbf{JFALSE} a_f; \\ &\quad a'' + 2 : \mathbf{JMP} a_t; \\ \underline{nbt}(\underline{\text{not}} BE, st, a, a_t, a_f, l) &:= \underline{et}(BE, st, a, a_f, a_t, l) \\ \underline{nbt}(BE_1 \underline{\text{and}} BE_2, st, a, a_t, a_f, l) &:= \underline{nbt}(BE_1, st, a, a', a_f, l) \\ &\quad \underline{nbt}(BE_2, st, a', a_t, a_f, l) \\ \underline{nbt}(BE_1 \underline{\text{or}} BE_2, st, a, a_t, a_f, l) &:= \underline{nbt}(BE_1, st, a, a_t, a', l) \\ &\quad \underline{nbt}(BE_2, st, a', a_t, a_f, l) \\ \underline{nct}(\underline{\text{if}} BE \underline{\text{then}} \Gamma_1 \underline{\text{else}} \Gamma_2, st, a, l) &:= \underline{nbt}(BE, st, a, a_t, a_f, l) \\ &\quad \underline{nct}(\Gamma_1, st, a_t, l) \\ &\quad a' : \mathbf{JMP} a''; \quad // \text{ Sprung ans Codeende} \\ &\quad \underline{nct}(\Gamma_2, st, a_f, l) \\ &\quad a'' : \dots \\ \underline{nct}(\underline{\text{while}} BE \underline{\text{do}} \Gamma, st, a, l) &:= \underline{nbt}(BE, st, a, a_t, a_f, l) \\ &\quad \underline{nct}(\Gamma, st, a_t, l) \\ &\quad a' : \mathbf{JMP} a; \\ &\quad a_f : \dots \end{aligned}$$

4.1.6 Prozeduren mit Parametern

Erweiterung von BPS um Wert- und Variablenparameter.

Syntax (Idee): I, J, V

$$\underline{\text{Decl}} : \Delta_p := \varepsilon | \underline{\text{proc}} I(I_1, \dots, I_p; \underline{\text{var}} J_1, \dots, J_q), B;$$

(Hierbei sind I_n und J_n die formalen Wert- und Variablenparameter)

$$\underline{\text{Cmd}} : \Gamma := \dots | I(E_1, \dots, E_p, V_1, \dots, V_q)$$

(mit E_n und V_n die aktuellen Parameterausdrücke)

Semantik:

- Prozessdeklaration: formale Parameter werden behandelt als in der Umgebung des Prozessrumpfes deklarierte Variablen (entsprechende Vererbung im Rumpf).
- Prozessaufwurf: Variablenparameter durch Zeiger auf entsprechenden Speicherplatz aktualisieren, Wertparameter als lokale Variable (neuer Speicherplatz).

Zwischencode ZPP (Zwischencode mit Prozedurparametern): Aktivierungsblöcke: zusätzlicher Speicher für aktuelle Parameter.

Zustandsraum: linearer Speicher mit vier Registern:

- IC: instruction counter
- SP: stack pointer
- FP: frame pointer
- R: index register

Sukzessiver Aufbau eines Frames:

1. Berechnung der aktuellen Parameter
2. Berechnung des statischen Verweises mit R
3. Sprung zur aufgerufenen Prozedur mit Eintrag der Rücksprungadresse
4. alten FP als dl (dynamic link) speichern
5. Speicherplatz für lokale Variablen bereitstellen

Die Punkte 1,2 und 3 erfolgen durch Code der aufrufenden Prozedur, die Punkte 4 und 5 durch Code der aufgerufenen Prozedur.

Befehlssatz ZPP:

- arithmetische, logische und Sprungbefehle wie bisher: DK auf Stackspitze, SP jeweils setzen.
- anstelle von $CALL(ca, dif, loc)$, RET , $LOAD(dif, off)$ und $STORE(dif, off)$ folgende neue Befehle:

CALL ca	$SP \leftarrow SP - 1, \langle SP \rangle \leftarrow IC + 1, IC \leftarrow ca$
RET k	$IC \leftarrow \langle SP \rangle, SP \leftarrow SP + k + 1$
PUSH z	$SP \leftarrow SP - 1, \langle SP \rangle \leftarrow z$
PUSH FP	} analog
PUSH $\langle FP \rangle$	
PUSH $\langle R + 2 \rangle$	
POP FP	$FP \leftarrow \langle SP \rangle, SP \leftarrow SP + 1$
POP $\langle n \rangle$	$Sn \leftarrow \langle SP \rangle, SP \leftarrow SP + 1$
SUB SP, n	$SP \leftarrow SP - n$
LOAD FP, SP	$FP \leftarrow SP$
LOAD $R, \langle n \rangle$	
LOAD $R, \langle R + 2 \rangle$	

Ein-/Ausgabe: $P = \text{in/out}I_1, \dots, I_n; B$. Die I/O-Parameter werden als Wertparameter (und nicht als lokale Variablen) gespeichert.

Zwischencodierung: Modifikation von $\text{trans} : \text{BSP} - \text{Prog} \rightarrow \text{AM} - \text{Code}$ unter Berücksichtigung von

- Prozedur mit Parametern
- neue abstrakte Maschine (neuer Befehlssatz)

Erweiterung der Symboltabelle um Einträge für Variablenparameter, aber Wertparameter wie lokale Variablen behandeln.

$$\dots \cup (\{\text{vpar}\} \times \text{Lev} \times \text{Off})$$

positive und negative Offsets: $\text{Off} := \mathbb{Z}$

Anfangstabelle: $st_{I/O}(I_j) := (\text{var}, 0, +3 + n - j)$

Aufbau der Symboltabelle mit up wie oben, aber negativen Offsets bei lokalen Variablen.

Alternative zur Verweiskettentechnik: Display-Technik

Im Unterschied zur Verweiskettentechnik schnellerer Variablenzugriff, aber höherer Speicheraufwand.

- lokale Displays: die aufgerufene Prozedur trägt alle statischen Verweise (sv) in den Frame ein.
- globale Displays: die sv werden global als SLA (static link array) gespeichert.

4.2 Übersetzung von Datenstrukturen

Datenstrukturen \leadsto Variablen mit Komponenten, strukturierter Zustandsraum.

Abstrakte Maschine: weiterhin lineare Speicherstruktur, Speicherzellen für atomare Daten.

Übersetzungsaufgabe: Abbildung des strukturierten Zustandsraumes auf linearen Speicherbereich \rightsquigarrow Adressberechnung.

statische Datenstrukturen: Speicherbedarf zur Übersetzungszeit bekannt.

dynamische Datenstrukturen: Speicherbedarf ist laufzeitabhängig.

Heap/Halbe als zusätzliche Maschinenkomponente.

Zeigertypen: garbage collection/Speicherbereinigung

4.2.1 Statische Datenstrukturen

PSSD: Programmiersprache mit statischen Datenstrukturen (Felder/Arrays und Verbunde/Records)

Typsemantik: Ein Typ bezeichnet eine Menge.

Beispiel: $\mathcal{T}[\text{int}] = \text{restr}(\mathbb{Z})$, $\mathcal{T}[\text{real}] = \text{restr}(\mathbb{R})$, ...

Typkompatibilität: Polymorphie (Ad-hoc) von Operationssymbolen.

Beispiel: $\text{int} \times \text{int} \rightarrow \text{int}$, $\text{real} \times \text{real} \rightarrow \text{real}$, $\text{int} \downarrow \text{real}$, *ldots*

Zuweisungskompatibilität: starkes/schwaches Typkonzept.

Beispiel: $\text{type } I_1 = T, I_2 = T$

$\text{var } V_1 : I_1; V_2 = I_2$

$V_1 := V_2?$

Beim starken Typkonzept: Bezeichner berücksichtigen! Vorteil: Kontrollmöglichkeit während der Übersetzung durch Typechecking, sorgt für Sicherheit von Softwaresystemen.

Beim schwachen Typkonzept: große Kompatibilität, beliebt für das programmieren im kleinen.

Erläuterung der Symboltabelle

- Basiswerte benötigen 1 Speicherplatz.

• (type, array, $\underbrace{Z_1, Z_2}_{\text{Grenzen}}$, $\underbrace{I}_{\text{Komponententyp}}$, $\underbrace{n}_{\text{Speicherbedarf}}$)

• (type, record, $\underbrace{I_1}_{\text{Selektor}}$, $\underbrace{I_1}_{\text{Komp. Typ}}$, $\underbrace{\sigma_1, \dots, \sigma_n}_{\text{Offset}}$, $\underbrace{s}_{\text{Speicherbedarf}}$)

- $st(I.I_j) = (I'_j, \sigma_j)$ falls $st(I) = (\underline{\text{type}}, \underline{\text{record}}, \dots, I_j, I'_j, \sigma_j \dots)$
- $(\underline{\text{var}}, \underbrace{I}_{\text{Typ}}, \underbrace{k}_{\text{Offset}})$

Aufbau einer Symboltabelle

$$\underline{\text{up}} : \underline{\text{Decl}} \times \underline{\text{Tab}} \rightarrow \underline{\text{Tab}}$$

Explizite Typschachtelung mit neuen Bezeichnern auflösen. Der Einfachheit halber nehmen wir an, daß

$$\Delta = \Delta_C \Delta_T \Delta_V \in \underline{\text{Decl}}$$

entschachtelt ist, d.h.

- Die Bezeichner sind paarweise verschieden.
- $\Delta_T = \underline{\text{type}} I_1 = T_1; \dots; I_n = T_n \curvearrowright$
 - $T_i \in \{\underline{\text{bool}}, \underline{\text{real}}, \underline{\text{int}}\}$
 - $T_i = \underline{\text{array}}[Z_1 \dots Z_n]$ of I_j mit $1 \leq j \leq i-1$
 - $T_i = \underline{\text{record}} S_1 : I_{j_1}; \dots \underline{\text{end}}$ mit $1 \leq j_1, \dots, j_n \leq i-1$
- $\Delta_V = \underline{\text{var}} V_1 : I_{j_1}; \dots V_s : I_{j_s}; \curvearrowright 1 \leq j_1, \dots, j_s \leq n$

Für entschachtelte Deklarationen ist

- $\underline{\text{up}}(\Delta_C \Delta_T \Delta_V, st) := \underline{\text{up}}(\Delta_V, \underline{\text{up}}(\Delta_T, \underline{\text{up}}(\Delta_C, st)))$
- $\underline{\text{up}}(\epsilon, st) = st$
- $\underline{\text{up}}(\underline{\text{const}} I_1 = C_1, \dots, st) := st[I_1 / (\underline{\text{const}}, C_1), \dots]$
- $\underline{\text{up}}(\underline{\text{type}} I = \underline{\text{bool}}; \underline{\text{drest}}, st) := \underline{\text{up}}(\underline{\text{type}} \underline{\text{drest}}, st[I / (\underline{\text{type}}, \underline{\text{bool}}, 1)])$
- $\underline{\text{up}}(\underline{\text{type}} I = J; \underline{\text{drest}}, st) := \underline{\text{up}}(\underline{\text{type}} \underline{\text{drest}}, st[I / st(J)])$
- $\underline{\text{up}}(\underline{\text{type}} I = \underline{\text{array}}[Z_1 \dots Z_2]$ of $J; \underline{\text{drest}}, st) :=$
 $\underline{\text{if}} st(J) = (\underline{\text{type}}, \dots, n)$ and $k = Z_2 - Z_1 + 1 \in \mathbb{N}$ then
 $\underline{\text{up}}(\underline{\text{type}} \underline{\text{drest}}, st[I / (\underline{\text{type}}, \underline{\text{array}}, Z_1, Z_2, J, k \cdot n)])$
- $\underline{\text{up}}(\underline{\text{type}} I = \underline{\text{record}} S_1 : J_1, \dots, S_r : J_r; \underline{\text{drest}}, st) :=$
 $\underline{\text{if}} st(J_i) = (\underline{\text{type}}, \dots, n_i), 1 \leq i \leq r$ then
 $\underline{\text{up}}(\underline{\text{type}} \underline{\text{drest}}, st[I / (\underline{\text{type}}, \underline{\text{record}}, S_1, J_1, 0, S_2, J_2, n_1, \dots, S_r, J_r, \sum_{i=1}^{r-1} n_i, \sum_{i=1}^r n_i)])$
- $\underline{\text{up}}(\underline{\text{type}}, st) = st$
- $\underline{\text{up}}(\underline{\text{var}} I_1 : J_1, \dots, I_n : J_n; st) :=$
 $\underline{\text{if}} st(J_i) = (\underline{\text{type}}, \dots, n_i), 1 \leq i \leq r$ then
 $st[I_1 / (\underline{\text{var}}, J_1, 1), I_2 / (\underline{\text{var}}, J_2, 1 + n_1), \dots, I_n / (\underline{\text{var}}, J_n, 1 + \sum_{i=1}^{n-1} n_i)]$

4.2.2 Dynamische Datenstrukturen

Variante Verbunde: Speicherbedarf für größte Variante vorgesehen. Denselben Bereich für verschiedene Varianten verwenden.

Dynamische Felder: Felder als formale Prozedurparameter. Variable Feldgröße (z.B. ISO-Pascal). Feldgrenzen nicht bei Deklaration, sondern erst bei Aufruf der Prozedur durch aktuelle Parameter festlegen.

Speicherreservierung: Bedarf zur Übersetzungszeit unbekannt, aber bei Prozedureintritt mit aktuellen Parametern bestimmbar.

Implementierung ohne Heap. *Idee:* indirekte Adressierung mit Hilfe eines Felddescriptors.

Zeiger (Pointer): dynamisch veränderbare Strukturen. Erzeugung von Objekten nicht durch Deklaration mit statischer Adresse, sondern durch Anweisung, zum Beispiel new.

Zeigervariable: p : POINTER TO t ;

Anweisung: new(p) zur Erzeugung von neuen Speicherplatz.

Die Speicherfreigabe erfolgt nicht automatisch, es werden spezielle Algorithmen für die Speicherbereinigung benötigt. Neuer Speicherbereich wird auf der Halde (heap) angelegt.

Semantik des new-Befehls:

if $NP - \langle SP \rangle \leq EP$ then error(„stack overflow“)

else $NP := NP - \langle SP \rangle$;

$\langle \langle SP - 1 \rangle \rangle := NP$;

$SP := SP - 2$;


EP (extrem stack pointer): Obergrenze des Kellers zur Durchführung eines Prozeduraufrufs, bestimmt durch die Größe der Ausdrücke im Prozedurrumpf, und ggf. die Größe der dynamischen Felder. $\Rightarrow EP$ ist bei Prozedureintritt berechenbar.

code($new(p)$) := **LOAD** $adr(p)$;


LOAD $size(p)$;

NEW;

- Historisch (1960): **UNCOL Universal Computer Oriented Language**



- ACK (Amsterdam Compiler Kit) CommACM 26(1983)
- JAVA (Sun Microsystems; ≥ 1990)



CB 4-1

Abbildung 4.1: Historischer Überblick

Strukturen von PS (imperativ)

- Basistypen und –operationen
- statische und dynamische Datenstrukturen
- Kontrollstrukturen
- applikative und funktionale Konzepte: Ausdrücke, Prozeduren, Funktionen
- Modulstrukturen: Blöcke, Module, Klassen

CB 4-2

Abbildung 4.2: Strukturen von Programmiersprachen

Strukturen von MC (von-Neumann-Typ; SISD)

- Speicherhierarchie: Register, Cache, Hauptspeicher, Hintergrundspeicher
- Befehlsarten: Op-Befehle, Test- und Sprungbefehle, Transferbefehle, I/O
- Adressierung: relative Adr. mit Index- und Basisregister, indirekte Adr.

CB 4-3

Abbildung 4.3: Strukturen von Maschinencode

Strukturen von Z

- Typen und Operationen aus PS übernehmen
- Datenkeller mit Basisoperationen
- Sprungbefehle für Kontrollstrukturen
- Prozedurkeller für Blöcke
- Heap für dynamische Datenstrukturen

CB 4-4

Abbildung 4.4: Strukturen der Zwischenmaschine

- Front-End-Aufgaben für trans : $PS \rightarrow Z$
- Übersetzung von Ausdrücken und Kontrollstrukturen
 - Übersetzung von Blöcken und Prozeduren
 - Übersetzung von Datenstrukturen
 - inkrementelle Übersetzung von Modulen

CB 4-5

Abbildung 4.5: Aufgaben des Front-ends

Syntax von BSP

Int : Z (* Z ist eine ganze Zahl *)
Ide : I (* I ist ein Bezeichner *)
Decl : $\Delta ::= \Delta_C \Delta_V \Delta_P$
 $\Delta_C ::= \varepsilon \mid \text{const } I_1 = Z_1, \dots, I_n = Z_n;$
 $\Delta_V ::= \varepsilon \mid \text{var } I_1, \dots, I_n;$
 $\Delta_P ::= \varepsilon \mid \text{proc } I_1; B_1; \dots; \text{proc } I_n; B_n;$
AExp : $E ::= Z \mid I \mid (E_1 + E_2) \mid \dots$
BExp : $BE ::= (E_1 < E_2) \mid \text{not } BE \mid (BE_1 \text{ and } BE_2) \mid \dots$
Cmd : $\Gamma ::= I := E \mid I() \mid$
 $\text{begin } \Gamma_1; \dots; \Gamma_n \text{ end} \mid$
 $\text{if } BE \text{ then } \Gamma \text{ else } \Gamma \mid \text{while } BE \text{ do } \Gamma$
Block : $B ::= \Delta \Gamma$
Prog : $P ::= \text{in/out } I_1, \dots, I_n; B. \quad (* n \geq 1 *)$

CB 4-6

Abbildung 4.6: Syntax von BSP




Abbildung 4.7: „static-scope“

<u>Semantische Bereiche</u>	
\mathbb{Z} ::= $\{0, 1, -1, \dots\}$	ganze Zahlen
\mathbb{B} ::= $\{\mathbf{true}, \mathbf{false}\}$	Boolesche Werte
\mathbf{Loc} ::= $\{\alpha_1, \alpha_2, \dots\}$	Speicherplätze (Locations)
S ::= $\{\sigma \mid \sigma : \mathbf{Loc} \rightarrow \mathbb{Z}\}$	Zustände (States)
C ::= $\{\theta \mid \theta : S \rightarrow S\}$	Zustandstransformationen (Continuations)
U ::= $\{\rho \mid \rho : \mathbf{Ide} \rightarrow \mathbb{Z} \cup \mathbf{Loc} \cup C\}$	Umgebungen (Environments)

CB 4-8

Abbildung 4.8: Semantische Bereiche

Ausdruckssemantik:

$$\text{a) } \mathcal{E}_a : \mathbf{AExp} \times U \times S \rightarrow \mathbb{Z}$$

$$\mathcal{E}_a[[Z]]\rho\sigma \quad := \quad Z$$

$$\mathcal{E}_a[[I]]\rho\sigma \quad := \quad \begin{cases} Z & , \text{ falls } \rho(I) = Z \in \mathbb{Z} \\ \sigma(\alpha) & , \text{ falls } \rho(I) = \alpha \in \mathbf{Loc} \end{cases}$$

$$\mathcal{E}_a[[E_1 + E_2]]\rho\sigma \quad := \quad \mathcal{E}_a[[E_1]]\rho\sigma + \mathcal{E}_a[[E_2]]\rho\sigma$$

$$\text{b) } \mathcal{E}_b : \mathbf{BExp} \times U \times S \rightarrow \mathbb{B}$$

$$\mathcal{E}_b[[E_1 < E_2]]\rho\sigma \quad := \quad \mathcal{E}_b[[E_1]]\rho\sigma < \mathcal{E}_b[[E_2]]\rho\sigma$$

$$\mathcal{E}_b[[\mathbf{not} BE]]\rho\sigma \quad := \quad \neg \mathcal{E}_b[[BE]]\rho\sigma$$

$$\mathcal{E}_b[[BE_1 \text{ and } BE_2]]\rho\sigma \quad := \quad \mathcal{E}_b[[BE_1]]\rho\sigma \wedge \mathcal{E}_b[[BE_2]]\rho\sigma$$

wobei $\wedge, \vee : \mathbb{B}_{\perp}^2 \rightarrow \mathbb{B}_{\perp}$ ($\perp = \text{undefiniert}$)

$$\text{i) strikt} \quad \perp \wedge b = b \wedge \perp = \perp$$

$$\text{ii) nicht-strikt} \quad \mathbf{false} \wedge \perp = \mathbf{false}$$

$$\mathbf{true} \vee \perp = \mathbf{true}$$

sonst wie i)

CB 4-9

Abbildung 4.9: Ausdruckssemantik

Anweisungssemantik: $C : \mathbf{Cmd} \times U \times S \rightarrow S$

$$\begin{aligned}
C[[I := E]]\rho\sigma &:= \sigma[\alpha/\mathcal{E}[[E]]\rho\sigma], \text{ falls } \rho(I) = \alpha \in \mathbf{Loc} \\
C[[\Gamma_1; \Gamma_2]]\rho\sigma &:= C[[\Gamma_2]]\rho(C[[\Gamma_1]]\rho\sigma) \\
C[[\mathbf{if } BE \mathbf{ then } \Gamma]]\rho\sigma &:= \begin{cases} C[[\Gamma]]\rho\sigma, & \text{falls } \mathcal{E}_b[[BE]]\rho\sigma = \mathbf{true} \\ \sigma, & \text{falls } \mathcal{E}_b[[BE]]\rho\sigma = \mathbf{false} \end{cases} \\
C[[\underbrace{\mathbf{while } BE \mathbf{ do } \Gamma}_{\Gamma'}]\rho\sigma &:= \begin{cases} C[[\Gamma']]\rho(C[[\Gamma]]\rho\sigma), & \text{falls } \mathcal{E}_b[[BE]]\rho\sigma = \mathbf{true} \\ \sigma, & \text{falls } \mathcal{E}_b[[BE]]\rho\sigma = \mathbf{false} \end{cases} \\
C[[I()]]\rho\sigma &:= \theta(\sigma), \text{ falls } \rho(I) = \theta \in C
\end{aligned}$$

CB 4-10

Abbildung 4.10: Anweisungssemantik

Deklarationssemantik: $\mathcal{D} : \mathbf{Decl} \times U \times S \rightarrow U \times S$

$$\mathcal{D}[\Delta_C \Delta_V \Delta_P] \rho \sigma := \mathcal{D}[\Delta_P] (\mathcal{D}[\Delta_V] (\mathcal{D}[\Delta_C] \rho \sigma))$$

, falls **diff-id**($\Delta_C \Delta_V \Delta_P$)

$$\mathcal{D}[\varepsilon] \rho \sigma := \rho \sigma$$

$$\mathcal{D}[\mathbf{const} I_1 = Z_1, \dots, I_n = Z_n] \rho \sigma := \rho[I_1/Z_1, \dots, I_n/Z_n] \sigma$$

$$\mathcal{D}[\mathbf{var} I_1, \dots, I_n] \rho \sigma :=$$

$$\rho[I_1/\alpha_{l+1}, \dots, I_n/\alpha_{l+n}] \sigma[\alpha_{l+1}/0, \dots, \alpha_{l+n}/0]$$

mit l = höchster Index eines belegten Speicherplatzes in σ

$$\mathcal{D}[\mathbf{proc} I_1; B_1; \dots; \mathbf{proc} I_n; B_n] \rho \sigma :=$$

$$\rho[I_1/\theta_1, \dots, I_n/\theta_n] \sigma$$

mit $\theta_i := \mathcal{B}[B_i] \rho[I_1/\theta_1, \dots, I_n/\theta_n]$ für $1 \leq i \leq n$

Blocksemantik: $\mathcal{B} : \mathbf{Block} \times U \times S \rightarrow S$

$$\mathcal{B}[\Delta \Gamma] \rho \sigma := \mathcal{C}[\Gamma] (\mathcal{D}[\Delta] \rho \sigma)$$

Programmsemantik: $\mathcal{M} : \mathbf{Prog}^{(n)} \times \mathbb{Z}^n \rightarrow \mathbb{Z}^n$

$$\mathcal{M}[\mathbf{in/out} I_1, \dots, I_n; B.] (z_1, \dots, z_n) := (\sigma(\alpha_1), \dots, \sigma(\alpha_n))$$


$$\text{mit } \sigma := \mathcal{B}[B] \rho_\emptyset [I_1/\alpha_1, \dots, I_n/\alpha_n] \sigma_\emptyset [\alpha_1/z_1, \dots, \alpha_n/z_n]$$

CB 4-11

Abbildung 4.11: Deklarationssemantik

Arbeitsweise des Laufzeitkellers

Bsp. 1: Programm von Folie CB 4-7, Zustand nach dem 2. Aufruf von A:




15 verweist auf die Deklarationsumgebung von A

Bsp. 2: Rekursion: **in/out X; var Y;**

```

proc A; var Z;
    [...A() ...]
    [...A() ...]
    
```



CB 4-12

Abbildung 4.12: Arbeitsweise des Laufzeitkellers

$$\begin{aligned}
\mathbf{up}(\Delta_C \Delta_V \Delta_P, st, a, l) &::= \mathbf{up}(\Delta_P, \mathbf{up}(\Delta_V, \mathbf{up}(\Delta_C, st, a, l), a, l), a, l) \\
&\quad \text{falls } \mathbf{diff-id}(\Delta_C \Delta_V \Delta_P) \\
\mathbf{up}(\varepsilon, st, a, l) &::= st \\
\mathbf{up}(\mathbf{const } I_1 = Z_1, \dots, I_n = Z_n; st, a, l) &::= st[I_1 / (\mathbf{const}, Z_1), \dots, I_n / (\mathbf{const}, Z_n)] \\
\mathbf{up}(\mathbf{var } I_1, \dots, I_n; st, a, l) &::= st[I_1 / (\mathbf{var}, l, 1), \dots, I_n / (\mathbf{var}, l, n)] \\
\mathbf{up}(\mathbf{proc } I_1; B_1; \dots; \mathbf{proc } I_n; B_n; st, a, l) &::= st[I_1 / (\mathbf{proc}, a.1, l, \mathbf{size}(B_1)), \dots, \\
&\quad I_n / (\mathbf{proc}, a.n, l, \mathbf{size}(B_n))] \\
\mathbf{dt}(\Delta_C, \Delta_V, \Delta_P, st, a, l) &::= \mathbf{dt}(\Delta_P, st, a, l) \\
\mathbf{dt}(\varepsilon, st, a, l) &::= \varepsilon \\
\mathbf{dt}(\mathbf{proc } I_1; B_1; \dots; \mathbf{proc } I_n; B_n; st, a, l) &::= \mathbf{bt}(B_1, st, a.1, l + 1) \dots \\
&\quad \mathbf{bt}(B_n, st, a.n, l + 1) \\
\mathbf{bt}(\Delta_\Gamma, st, a, l) &::= \mathbf{dt}(\Delta, \mathbf{up}(\Delta, st, a.1, l), a.1, l) \\
&\quad \mathbf{ct}(\Gamma, \mathbf{up}(\Delta, st, a.1, l), a.1, l)
\end{aligned}$$

CB 4-13

Abbildung 4.13: Semantik

Beispiel zur Übersetzung von BSP in ZP-Code

```

in/out X;
  var E;
  proc F;
    if 1 < X then begin
      E := E * X;
      X := X - 1;
      F()
    end;
  begin
    E := 1;
    F();
    X := E
  end.

```

$$\text{trans}(\text{in/out } X; \Delta \Gamma) = \begin{array}{l}
 1 : \text{CALL}(a_\Gamma, 0, 1); \\
 2 : \text{JMP}(0); \\
 \text{bt}(\Delta \Gamma, st_{I/O}, a_\Gamma, 1) \\
 \text{mit } st_{I/O}(X) = (\text{var}, 0, 1)
 \end{array}$$

CB 4-14

Abbildung 4.14: Beispiel: Übersetzung BSP in ZP

$$\begin{aligned}
\mathbf{bt}(\Delta\Gamma, st_{I/O}, a_\Gamma, 1) &= \mathbf{dt}(\Delta, \mathbf{up}(\Delta, st_{I/O}, a_1, 1), a_1, 1) \\
&\quad \mathbf{ct}(\Gamma, \mathbf{up}(\Delta, st_{I/O}, a_1, 1), a_\Gamma, 1) \\
&\quad a_2 : \mathbf{RET}; \\
\mathbf{up}(\Delta, st_{I/O}, a_1, 1) &= \underbrace{st_{I/O}[E/(var, 1, 1), F/(\mathbf{proc}, a_{11}, 1, 0)]}_{\bar{st}} \\
\mathbf{dt}(\Delta, \bar{st}, a_1, 1) &= \mathbf{bt}(B_F, \bar{st}, a_{11}, 2) \\
&= \mathbf{ct}(\Gamma_F, \bar{st}, a_{11}, 2, 2) \\
&\quad a_3 : \mathbf{RET}; \\
\mathbf{ct}(\Gamma, \bar{st}, a_\Gamma, 1) &= a_\Gamma : \mathbf{LIT}(1); \\
&\quad \mathbf{STO}(0, 1); \\
&\quad \mathbf{CALL}(a_{11}, 0, 0); \\
&\quad \mathbf{LOAD}(0, 1); \\
&\quad \mathbf{STO}(1, 1); \\
\mathbf{ct}(\Gamma_F, \bar{st}, a_{11}, 2) &= \mathbf{sbt}(1 < x, \bar{st}, a_{11}, 2) \\
&\quad a_4 : \mathbf{JFALSE}(a_5); \\
&\quad \mathbf{ct}(\mathbf{begin} \dots \mathbf{end}, \bar{st}, a_4 + 1, 2) \\
&\quad a_5 : \\
\mathbf{sbt}(1 < x, \bar{st}, a_{11}, 2) &= a_{11} : \mathbf{LIT}(1); \\
&\quad \mathbf{LOAD}(2, 1); \\
&\quad \mathbf{LT}; \\
\mathbf{ct}(\mathbf{begin} \dots \mathbf{end}, \bar{st}, a_4 + 1, 2) &= \mathbf{ct}(E := E * X, \bar{st}, a_4 + 1, 2) \\
&\quad \mathbf{ct}(X := X - 1, \bar{st}, a_6, 2) \\
&\quad \mathbf{ct}(F(), \bar{st}, a_7, 2) \\
&= a_4 + 1 : \mathbf{LOAD}(1, 1); \\
&\quad \mathbf{LOAD}(2, 1); \\
&\quad \mathbf{MULT}; \\
&\quad \mathbf{STO}(1, 1); \\
&\quad \mathbf{LOAD}(2, 1); \\
&\quad \mathbf{LIT}(1); \\
&\quad \mathbf{SUB}; \\
&\quad \mathbf{STO}(2, 1); \\
&\quad \mathbf{CALL}(a_{11}, 1, 0)
\end{aligned}$$

CB 4-15

Abbildung 4.15: Beispiel Fortsetzung

Ergebnis der Übersetzung:

trans(in/out X ; $\Delta\Gamma$) =

1 : CALL(a_Γ , 0, 1);	Also:
2 : JMP(0);	
a_{11} : LIT(1);	$a_{11} = 3$
LOAD(2, 1);	
LT;	
a_4 : JFALSE(a_5);	$a_4 = 6$
LOAD(1, 1);	
LOAD(2, 1);	
MULT;	
STO(1, 1);	
LOAD(2, 1);	
LIT(1);	
SUB;	
STO(2, 1);	
CALL(a_{11} , 1, 0);	
a_3 : a_5 : RET;	$a_3 = 16 = a_5$
a_Γ : LIT(1);	$a_\Gamma = 17$
STO(0, 1);	
CALL(a_{11} , 0, 0);	
LOAD(0, 1);	
STO(1, 1);	
a_2 : RET;	$a_2 = 22$

CB 4-16

Abbildung 4.16: Ergebnis der Berechnung des Beispiels

Berechnungsprotokoll für $X = 3$:

$m \in BZ$	$d \in DK$	$p \in PK$
1	ε	0:0:0:3
17	ε	4:3:2:0:0:0:0:3
18	1	4:3:2:0:0:0:0:3
19	ε	4:3:2:1:0:0:0:3
3	ε	3:2:20:4:3:2:1:0:0:0:3
4	1	3:2:20:4:3:2:1:0:0:0:3
5	1:3	3:2:20:4:3:2:1:0:0:0:3
6	1	3:2:20:4:3:2:1:0:0:0:3
7	ε	3:2:20:4:3:2:1:0:0:0:3
8	1	3:2:20:4:3:2:1:0:0:0:3
9	1:3	3:2:20:4:3:2:1:0:0:0:3
10	3	3:2:20:4:3:2:1:0:0:0:3
11	ε	3:2:20:4:3:2:3:0:0:0:3
12	3	3:2:20:4:3:2:3:0:0:0:3
13	3:1	3:2:20:4:3:2:3:0:0:0:3
14	2	3:2:20:4:3:2:3:0:0:0:3
15	ε	3:2:20:4:3:2:3:0:0:0:2
3	ε	6:2:16:3:2:20:4:3:2:3:0:0:0:2
4	1	6:2:16:3:2:20:4:3:2:3:0:0:0:2
5	1:2	6:2:16:3:2:20:4:3:2:3:0:0:0:2
6	1	6:2:16:3:2:20:4:3:2:3:0:0:0:2
7	ε	6:2:16:3:2:20:4:3:2:3:0:0:0:2
8	3	6:2:16:3:2:20:4:3:2:3:0:0:0:2
9	3:2	6:2:16:3:2:20:4:3:2:3:0:0:0:2
10	6	6:2:16:3:2:20:4:3:2:3:0:0:0:2
11	ε	6:2:16:3:2:20:4:3:2:6:0:0:0:2
12	2	6:2:16:3:2:20:4:3:2:6:0:0:0:2
13	2:1	6:2:16:3:2:20:4:3:2:6:0:0:0:2
14	1	6:2:16:3:2:20:4:3:2:6:0:0:0:2
15	ε	6:2:16:3:2:20:4:3:2:6:0:0:0:1
3	ε	9:2:16:6:2:16:3:2:20:4:3:2:6:0:0:0:1
4	1	9:2:16:6:2:16:3:2:20:4:3:2:6:0:0:0:1
5	1:1	9:2:16:6:2:16:3:2:20:4:3:2:6:0:0:0:1
6	0	9:2:16:6:2:16:3:2:20:4:3:2:6:0:0:0:1
16	ε	9:2:16:6:2:16:3:2:20:4:3:2:6:0:0:0:1
16	ε	6:2:16:3:2:20:4:3:2:6:0:0:0:1
16	ε	3:2:20:4:3:2:6:0:0:0:1
20	ε	4:3:2:6:0:0:0:1
21	6	4:3:2:6:0:0:0:1
22	ε	4:3:2:6:0:0:0:6
0	ε	0:0:0:6

CB 4-17

Abbildung 4.17: Berechnungsprotokoll des Beispiels

Syntax von BPS mit parametrisierten Prozeduren


Int :	Z	::=	$(* Z \text{ ist eine ganze Zahl } *)$
Ide :	I	::=	$(* I \text{ ist ein Bezeichner } *)$
Decl :	Δ	::=	$\Delta_C \Delta_V \Delta_P$
	Δ_C	::=	$\varepsilon \mid \text{const } I_1 = Z_1, \dots, I_n = Z_n;$
	Δ_V	::=	$\varepsilon \mid \text{var } I_1, \dots, I_n;$
	Δ_P	::=	$\varepsilon \mid \text{proc } I(I_1, \dots, I_p; \text{var } J_1, \dots, J_q;) B; \dots$
			$(* \text{ formale Wert- und Variablenparameter } *)$
AExp :	E	::=	$Z \mid I \mid (E_1 + E_2) \mid \dots$
BExp :	BE	::=	$(E_1 < E_2) \mid \text{not } BE \mid (BE_1 \text{ and } BE_2) \mid \dots$
V :	V	::=	$I \quad (* \text{ Variablenparameter } *)$
Cmd :	Γ	::=	$I := E \mid I(\underbrace{E_1, \dots, E_p; V_1, \dots, V_q}) \mid$ $(* \text{ aktuelle Parameter(ausdrücke) } *)$ $\text{begin } \Gamma_1; \dots; \Gamma_n \text{ end} \mid$ $\text{if } E \text{ then } \Gamma \mid \text{while } E \text{ do } \Gamma$
Block :	B	::=	$\Delta \Gamma$
Prog :	P	::=	$\text{in/out } I_1, \dots, I_n; B. \quad (* n \geq 1 *)$

CB 4-18

Abbildung 4.18: Syntax von BPS mit parametrisierten Prozeduren

Stackmaschine für Zwischencode

Zustandsraum:



- nur noch **ein Keller** für Daten und Aktivierungsblöcke
- Kellerspeicherezellen mit **fester Adresse**
- **SP** zeigt auf Kellerspitze (unten)
- **FP** zeigt auf den **dl**-Eintrag des obersten Aktivierungsblocks

CB 4-19

Abbildung 4.19: Stackmaschine für ZPP-Code

Übersetzung von BPS mit Parametern in Zwischencode

trans(**in/out** $I_1, \dots, I_n; B.$) :=
 1 : *PUSH FP*;
 2 : *CALL* a_Γ ;
 3 : *JMP* 0;
 bt($B, st_{I/O}, a_\Gamma, 1, 0$)

} Anlegen von sl und ra

bt($\Delta\Gamma, st, a, l, r$) :=
 dt($\Delta, \mathbf{up}(\Delta, st, a.1, l), a.1, l$)
 a : *PUSH FP*;
 – : *LOAD FP, SP*;
 – : *SUB SP, size*($\Delta\Gamma$);
 ct($\Gamma, \mathbf{up}(\Delta, st, a.1, l), a + 3, l$)
 – : *LOAD SP, FP*;
 – : *POP FP*;
 – : *RET* $r + 1$;

} Entry-Code

} Exit-Code

dt(**proc** $I(I_1, \dots, I_p; \mathbf{var} J_1, \dots, J_q); B; \dots, st, a, l$) :=
 bt($B, st', a.1, l + 1, p + q$) **bt**(...)

falls **diff-id**($I_1, \dots, I_p, J_1, \dots, J_q$) and **diff-id**(...)

wobei $st' := st[I_1 / (\mathbf{var}, l + 1, p + q + 2), \dots,$
 $I_p / (\mathbf{var}, l + 1, q + 3),$
 $J_1 / (\mathbf{vpar}, l + 1, q + 2), \dots,$
 $J_q / (\mathbf{vpar}, l + 1, 3)]$

(Beachte: Parameterlevel = Blocklevel)

CB 4-20

Abbildung 4.20: Übersetzung von BPS mit Parametern in Zwischencode I

Übersetzung von BPS mit Parametern in Zwischencode (Forts.)

```

ct( $I := E, st, a, l$ ) :=
  et( $E, st, a, l$ )
  if  $st(I) = (\mathbf{var}, dl, o)$  then
    if  $l - dl = 0$  then  $- : POP \langle FP+o \rangle;$ 
    if  $l - dl = k + 1$  then
       $- : LOAD R, \langle FP + 2 \rangle;$ 
       $- : LOAD R, \langle R + 2 \rangle;$ 
       $\vdots$ 
       $- : LOAD R, \langle R + 2 \rangle;$ 
       $- : POP \langle R+o \rangle;$ 
    }  $k$ -mal
  if  $st(I) = (\mathbf{vpar}, dl, o)$  then
    if  $l - dl = 0$  then
       $- : LOAD R, \langle FP+o \rangle;$ 
       $- : POP \langle R \rangle;$ 
    if  $l - dl = k + 1$  then
       $- : LOAD R, \langle FP + 2 \rangle;$ 
       $- : LOAD R, \langle R + 2 \rangle;$ 
       $\vdots$ 
       $- : LOAD R, \langle R + 2 \rangle;$ 
       $- : LOAD R, \langle R+o \rangle;$ 
       $- : POP \langle R \rangle;$ 
    }  $k$ -mal

```

CB 4-21

Abbildung 4.21: Übersetzung von BPS mit Parametern in Zwischencode II

Übersetzung von BPS mit Parametern in Zwischencode (Forts.)

```

ct( $I(E_1, \dots, E_p; V_1, \dots, V_q), st, a, l$ ) :=
  if  $st(I) = (\text{proc}, ca, dl, t)$  and
  typ( $E_i$ ) = int and
   $st(V_j) = (\text{var}, l_j, o_j)$  then
     $\left. \begin{array}{l} \text{ct}(E_1, st, a, l) \\ \vdots \\ \text{ct}(E_p, st, a, l) \end{array} \right\} \text{aktuelle Wertparameter}$ 
    if  $l - l_1 = 0$  then  $- : \text{PUSH } FP + o_1;$ 
    if  $l - l_1 = k + 1$  then
       $\left. \begin{array}{l} - : \text{LOAD } R, \langle FP + 2 \rangle; \\ - : \text{LOAD } R, \langle R + 2 \rangle; \\ \vdots \\ - : \text{LOAD } R, \langle R + 2 \rangle; \\ - : \text{PUSH } R + o_1; \end{array} \right\} k\text{-mal}$ 
     $\vdots$  (* analog für  $2, \dots, q$  *)
    if  $l - dl = 0$  then  $- : \text{PUSH } FP;$ 
    if  $l - dl = k + 1$  then
       $\left. \begin{array}{l} - : \text{LOAD } R, \langle FP + 2 \rangle; \\ - : \text{LOAD } R, \langle R + 2 \rangle; \\ \vdots \\ - : \text{LOAD } R, \langle R + 2 \rangle; \\ - : \text{PUSH } R; \end{array} \right\} k\text{-mal}$ 
     $- : \text{CALL } ca;$ 

```

(Ansonsten bleibt **ct** unverändert.)

CB 4-22

Abbildung 4.22: Übersetzung von BPS mit Parametern in Zwischencode III

Übersetzung von BPS mit Parametern in Zwischencode (Forts.)

```

et( $I, st, a, l$ ) :=
  if  $st(I) = (\text{const}, Z)$  then  $a: \text{PUSH } Z$ ;
  if  $st(I) = (\text{var}, dl, o)$  then
    if  $l - dl = 0$  then  $a: \text{PUSH } \langle FP+o \rangle$ ;
    if  $l - dl = k + 1$  then  $a: \text{LOAD } R, \langle FP + 2 \rangle$ ;
       $- : \text{LOAD } R, \langle R + 2 \rangle$ ;
       $\vdots$ 
       $- : \text{LOAD } R, \langle R + 2 \rangle$ ;
       $- : \text{PUSH } \langle R+o \rangle$ ;
    }  $k$ -mal
  if  $st(I) = (\text{vpar}, dl, o)$  then
    if  $l - dl = 0$  then  $a: \text{LOAD } R, \langle FP+o \rangle$ ;
       $- : \text{PUSH } \langle R \rangle$ ;
    if  $l - dl = k + 1$  then  $a: \text{LOAD } R, \langle FP + 2 \rangle$ ;
       $- : \text{LOAD } R, \langle R + 2 \rangle$ ;
       $\vdots$ 
       $- : \text{LOAD } R, \langle R + 2 \rangle$ ;
       $\text{LOAD } R, \langle R+o \rangle$ ;
       $\text{PUSH } \langle R \rangle$ ;
    }  $k$ -mal

```

(Ansonsten bleibt **et** unverändert.)

CB 4-23

Abbildung 4.23: Übersetzung von BPS mit Parametern in Zwischencode IV

Syntax von PSSD

Int : Z
Bool : $B ::= \text{true} \mid \text{false}$
Real : R
Const : $C ::= Z \mid B \mid R$
Ide : I
Typ : $T ::= I \mid \text{Bool} \mid \text{Int} \mid \text{Real} \mid$
 $\text{array } [Z_1..Z_2] \text{ of } T \mid$
 $\text{record } I_1 : T_1; \dots; I_n : T_n \text{ end}$
Var : $V ::= I \mid V[E] \mid V.I$
Exp : $E ::= C \mid V \mid (E_1 + E_2) \mid \dots$
Cmd : $\Gamma ::= V := E \mid \text{begin} \dots \text{end} \mid \text{if} \dots \mid$
 $\text{while} \dots$
Decl : $\Delta ::= \Delta_C \Delta_T \Delta_V$
 $\Delta_C ::= \varepsilon \mid \text{const } I_1 = C_1, \dots, I_n = C_n;$
 $\Delta_T ::= \varepsilon \mid \text{type } I_1 = T_1, \dots, I_n = T_n;$
 $\Delta_V ::= \varepsilon \mid \text{var } I_1 : T_1, \dots, I_n : T_1;$
Prog : $P ::= \Delta \Gamma$

CB 4-24

Abbildung 4.24: Syntax von PSSD

Semantik von PSSD (statisch)

- In Δ vereinbarte Bezeichner müssen **paarweise verschieden** sein.
- Recordselektoren müssen **paarweise verschieden** sein.
- **array** $[Z_1..Z_2]$ **of** $T \rightsquigarrow Z_1 \leq Z_2$
- **Keine Rekursion** in Δ_T , d.h. induktiver Typaufbau:
type $I_1 = T_1, \dots, I_n = T_n$; und Typbezeichner I in T_j
 $\rightsquigarrow I \in \{I_1, \dots, I_{j-1}\}$
- Analoge Bedingungen für Typbezeichner in Δ_V
- Bezeichner in Γ müssen in Δ **deklariert** sein.
- Variablen in Ausdrücken und Wertzuweisungen sind von einem **Basistyp**.

CB 4-25

Abbildung 4.25: statische Semantik von PSSD

Code für eine abstrakte Maschine mit Datenkeller DK und Hauptspeicher HS

Alte Befehle: arithmetische, logische, Sprungbefehle

Neue Transportbefehle:

$$C[\text{LODI}](m, d : n, h) := \text{if } h(n) = z \text{ then } (m + 1, d : z, h)$$

Bei Indexvariablen wird auf dem DK zunächst die Adresse berechnet und damit dann indirekt ein Wert geladen.

$$C[\text{STOI}](m, d : z : n, h) := (m + 1, d, h[n/z])$$

Laufzeitkontrolle bei Arraygrenzen:

$$C[\text{JAC}(Z_1, Z_2)](m, d : z, h) := \text{if } Z_1 \leq z \leq Z_2 \text{ then } (m + 1, d : z, h) \\ \text{else } (\text{STOP}, d : \underbrace{\text{RTE}}_{\text{„run-time error“}}, h)$$

Abbildung 4.26: Code für AM mit DK und HS

Symboltabelle: Informationen über Speicherbedarf und Offsets

$st \in \mathbf{Tab} :$

$\mathbf{Ide} \rightarrow \{\mathbf{const}\} \times (\mathbb{B} \cup \mathbb{Z} \cup \mathbb{R})$
 $\cup \{\mathbf{type}\} \times \{\mathbf{bool, real, int}\} \times \{1\}$
 $\cup \{\mathbf{type}\} \times \{\mathbf{array}\} \times \mathbb{Z}^2 \times \mathbf{Ide} \times \mathbb{N}$
 $\cup \{\mathbf{type}\} \times \{\mathbf{record}\} \times (\mathbf{Ide} \times \mathbf{Ide} \times \mathbb{N})^* \times \mathbb{N}$
 $\cup \{\mathbf{var}\} \times \mathbf{Ide} \times \mathbb{N}$

Für $\Delta = \mathbf{type} \ \mathbf{Bool} = \mathbf{bool}; \mathbf{Int} = \mathbf{int};$
 $\quad \mathbf{Array} = \mathbf{array}[1..20] \mathbf{of} \ \mathbf{Bool};$
 $\quad \mathbf{Record} = \mathbf{record} \ \mathbf{S} : \mathbf{Array}; \mathbf{T} : \mathbf{Int} \ \mathbf{end};$
 $\quad \mathbf{var} \ \mathbf{X} : \mathbf{Int}; \mathbf{Y} : \mathbf{Array}; \mathbf{Z} : \mathbf{Record};$

gilt:

$\mathbf{up}(\Delta, st) =$
 $st[\mathbf{Bool}/(\mathbf{type}, \mathbf{bool}, 1),$
 $\quad \mathbf{Int}/(\mathbf{type}, \mathbf{int}, 1),$
 $\quad \mathbf{Array}/(\mathbf{type}, \mathbf{array}, 1, 20, \mathbf{Bool}, 20),$
 $\quad \mathbf{Record}/(\mathbf{type}, \mathbf{record}, \mathbf{S}, \mathbf{Array}, 0, \mathbf{T}, \mathbf{Int}, 20, 21),$
 $\quad \mathbf{X}/(\mathbf{var}, \mathbf{Int}, 1),$
 $\quad \mathbf{Y}/(\mathbf{var}, \mathbf{Array}, 2),$
 $\quad \mathbf{Z}/(\mathbf{var}, \mathbf{Record}, 22)]$

CB 4-27

Abbildung 4.27: Symboltabelle

Übersetzung von PSSD-Programmen in Maschinencode

Hilfsfunktion $\mathbf{vtyp} : \mathbf{Var} \times \mathbf{Tab} \rightarrow \mathbf{Ide}$ bestimmt zu einer Variablen bzgl. einer Symboltabelle den zugehörigen Typbezeichner:

$$\begin{aligned} \mathbf{vtyp}(I, st) &:= \mathbf{if } st(I) = (\mathbf{var}, J, k) \mathbf{ then } J \\ \mathbf{vtyp}(V[E], st) &:= \mathbf{if } \mathbf{vtyp}(V, st) = I \mathbf{ and} \\ &\quad st(I) = (\mathbf{type}, \mathbf{array}, Z_1, Z_2, J, n) \\ &\quad \mathbf{ then } J \\ \mathbf{vtyp}(V.I, st) &:= \mathbf{if } \mathbf{vtyp}(V, st) = J \mathbf{ and } st(J) = \\ &\quad (\mathbf{type}, \mathbf{record}, S_1, J_1, 0, \dots, S_n, J_n, p, q) \\ &\quad \mathbf{ and } I = S_i \\ &\quad \mathbf{ then } J_i \end{aligned}$$

Übersetzungsfunktion $\mathbf{vt} : \mathbf{Var} \times \mathbf{Tab} \rightarrow \mathbf{Code}$ berechnet auf DK die Anfangsadresse einer Variablen im HS:

$$\begin{aligned} \mathbf{vt}(I, st) &:= \mathbf{if } st(I) = (\mathbf{var}, J, k) \mathbf{ then } \mathbf{LIT } k; \\ \mathbf{vt}(V[E], st) &:= \mathbf{if } \mathbf{vtyp}(V, st) = I \\ &\quad \mathbf{ and } st(I) = (\mathbf{type}, \mathbf{array}, Z_1, Z_2, J, n) \\ &\quad \mathbf{ and } st(J) = (\mathbf{type}, \dots, k) \mathbf{ then} \\ &\quad \mathbf{vt}(V, st) \\ &\quad \mathbf{et}(E, st) \\ &\quad \mathbf{JAC}(Z_1, Z_2); \\ &\quad \mathbf{LIT } Z_1; \\ &\quad \mathbf{SUB}; \\ &\quad \mathbf{LIT } k; \\ &\quad \mathbf{MULT}; \\ &\quad \mathbf{ADD}; \\ \mathbf{vt}(V.I, st) &:= \mathbf{if } \mathbf{vtyp}(V, st) = J \mathbf{ and } st(J) = \\ &\quad (\mathbf{type}, \mathbf{record}, S_1, J_1, p_1, \dots, S_n, J_n, p_n, q) \\ &\quad \mathbf{ and } I = S_i \mathbf{ then} \\ &\quad \mathbf{vt}(V, st) \\ &\quad \mathbf{LIT } p_i; \\ &\quad \mathbf{ADD}; \end{aligned}$$

CB 4-28

Abbildung 4.28: Übersetzung von PSSD I

Übersetzung PSSD (Forts.)

Übersetzungsfunktion $\text{et} : \mathbf{Exp} \times \mathbf{Tab} \rightarrow \mathbf{Code}$ erzeugt den üblichen DK-Berechnungscode, wobei jetzt Variablenwerte mit LODI geladen werden:

$$\begin{aligned} \text{et}(I, st) &:= \text{if } st(I) = (\mathbf{const}, C) \\ &\quad \text{then LIT } C; \\ &\quad \text{else if } st(I) = (\mathbf{var}, J, k) \\ &\quad \quad \text{and } st(J) = (\mathbf{type}, bas, 1) \text{ then} \\ &\quad \quad \text{LIT } k; \\ &\quad \quad \text{LODI}; \\ \text{et}(C, st) &:= \text{LIT } C; \\ \text{et}(V, st) &:= \text{if } \mathbf{vtyp}(V, st) = J \\ &\quad \quad \text{and } st(J) = (\mathbf{type}, bas, 1) \text{ then} \\ &\quad \quad \mathbf{vt}(V, st) \\ &\quad \quad \text{LODI}; \\ \text{et}(E_1 + E_2, st) &:= \dots \text{ (wie bei PSA)} \end{aligned}$$

Übersetzungsfunktion $\text{ct} : \mathbf{Cmd} \times \mathbf{Tab} \rightarrow \mathbf{Code} :$

$$\begin{aligned} \text{ct}(V := E, st) &:= \mathbf{vt}(V, st) \\ &\quad \mathbf{et}(E, st) \\ &\quad \text{STOI}; \\ &\quad \vdots \text{ (sonst wie PSA)} \end{aligned}$$

CB 4-29

Abbildung 4.29: Übersetzung von PSSD II

Kapitel 5

Exkurs: Yacc

5.1 Automatische Parsergenerierung mit Yacc

Parsergenerierung einschließlich synthetischer Attributauswertung (*LALR(1)*). Yacc steht für **Y**et **A**nother **C**ompiler **C**ompiler (1995).

Mit `lex` wird aus einer `lex`-Spezifikation eine `lex.yy.c`-Datei erzeugt (der Scanner in C). Mit `yacc` wird eine `yacc`-Spezifikation in eine `y.tab.c` und `y.tab.h` (Datei mit Tokennummern) umgewandelt. Die `y.tab.h` dient als Eingabe für `lex`. Mit Hilfe des C-Compilers wird dann ein ausführbarer Parser erzeugt.

5.1.1 Aufbau einer Yacc-Spezifikation

Eine `yacc`-Spezifikation hat eine ähnliche Struktur wie die `lex`-Spezifikation. Sie besteht aus drei Teilen, die durch `%Y` getrennt sind.

1. Definitionen

- von Token: z.B. `%token NAME NUMBER`
Beachte: nicht deklarierte Token möglich, Benutzung `'...'`, z.B. `'+' , '='`
- C-Code für Definitionen (Datenstrukturen, includes, ...). Bezeichnung: `%{ C-Code %}`

2. Regeln CFG mit Attributierung (Anweisungen), z.B.

```
stmt: NAME '=' expr
     | expr { printf("%d", $1) }
     ;

expr : expr '+' NUMBER { $$ = $1 + $3 }
     | NUMBER          { $$ = $1 }
     ;
```

Die `lex`-Attribute sind bestimmt durch den Anfang des Scanners mit `nextsym`.

3. C-Funktionen zur direkten Übernahme in die Datei `y.tab.c`. Verwendung bei Attributfunktionen. Passende `lex`-Spezifikation zu obigen Beispiel:

```

%{
    #include "y.tab.h"
    extern int yyval;
}%

%%

[0-9]+    { yyval = atoi(yytext); return NUMBER; }
[a-zA-Z]+ { return NAME; }
[ |\t]    /* Leerzeichen */
\n        { return 0; }
.         { return yytext[0]; }

%%

```

weitere Möglichkeiten

- mehrere synthetische Attribute mit C-Strukturen
- inherit Attribute mit C-Funktionen; Zugriff auf vorher berechnete, tiefer im Stack liegende Werte durch \$0, \$1, ...
- Konfliktbehandlung
- Präzedenz zur Behandlung von Mehrdeutigkeiten, z.B. Punkt-vor-Strichrechnung, dangling else

Beispielgrammatik

```

B → 0      v.0 = 0
B → 1      v.0 = 1
L → B      v.0 = v.1
           l.0 = 1
L → LB     v.0 = 2 * v.1 + v.2
           l.0 = l.1 + 1
N → L      v.0 = v.1
N → L.L    v.0 = v.1 + v.2 / 2l.2

```

5.2 Behandlung von Konflikten in Yacc

Shift/Reduce: Shift

Reduce/Reduce: Reihenfolge: erste Alternative bevorzugt

Beispiel: (O'Reilly: lex & yacc, S.258)

```

S: girls
  | boys
  ;

```

```
girls: Alice
      | Chris
      ;
```

```
boys: Bob
      | Chris
      ;
```

```
> yacc -d -v rr.y
yacc: 1 rule never reduced
yacc: 1 reduce/reduce conflict
```

Die Option „-v“ im obigen Beispiel erzeugt die Datei `y.output` mit Zusatzinformationen. Aufgrund des reduce/reduce-Konfliktes wird „chris“ immer zu „girls“ reduziert. Eine mögliche Lösung für dieses Problem ist eine Änderung der Grammatik:

```
S: girls
  | boys
  | either
  ;
```

```
girls: Alice;
```

```
boys: Bob;
```

```
either: Chris;
```

Beachte: Es kommt zu einer Änderung des Parsebaums \curvearrowright es sind also evtl. weitere Änderungen in anderen Phasen der semantischen Analyse erforderlich.

5.3 Präzedenz von Operatoren in Yacc

Assoziativität und Präzedenz werden gleichzeitig festgelegt. Syntax:

```
%[left|right] op1,1...op1,n
...
%[left|right] opm,1...opm,n
```

- Operatoren in **einer** Zeile haben angegebene Assoziativität und **gleiche** Präzedenz.
- In **späteren** Zeilen deklarierte Operatoren haben höhere Präzedenz.

5.3.1 Exkurs: Kodierung der Präzedenzregeln für arithmetische Ausdrücke über der Grammatik

Idee: +|- und */ in getrennten Regeln

```
expr: expr '+' mulexp
      | expr '-' mulexp
      | mulexp
```

```
    ;

mulexp: mulexp '*' primary
      | mulexp '/' primary
      | primary
      ;

primary: '(' expr ')'
       | '+' primary
       | '-' primary
       | NUMBER
       ;
```

Index

- LR(0)*-Auskunft, 35
- LR(0)*-Menge, 35
- ϵ -Hülle, 11
- k*-look-ahead, 26

- Abhängigkeitsgraphen, 74
- Ableitungsrelation, 24
- Abstrakten Syntaxbaums, 77
- action-Funktion, 30
- Analysephase, 8
- Analysetabelle von *G*, 30
- Attributgleichungssystem, 73
- Attribut, 9
- Attribute, 10, 15
- Attributen, 73
- Attributgleichung, 73
- Attributgleichungssystem, 73
- Attributgrammatik, 73
- Attributgrammatiken, 71
- Attributvariablen, 73
- Attributwertmengen, 73
- Attributzuordnung, 73
- Außenvariablen, 73

- Backend, 8
- Backtrack-DFA, 13
- Bezeichner, 10
- Bottom-Up-Analyse, 23

- direkte Linksrekursion, 31

- eindeutig, 24
- Einfache Symbole, 10

- flm-Analyse, 12
- Folge, 12
- formalen Attributvariablen, 73
- Frontend, 8

- imperative, 7
- indirekte Linksrekursion, 32

- inheriter, 73
- inherites, 72
- Innenvariablen, 73

- Kantenmenge, 74
- Kellerautomaten, 23
- kontextfreie Grammatik, 23

- l-Analyse, 25
- L-Attributgrammatik, 78
- Leerzeichen, 10
- Lexeme, 9
- lexikalische Struktur, 9
- Linksanalyse, 23
- linksrekursiv, 31
- lm-Zerlegung, 12

- maximal munch, 12
- mehrdeutig, 24
- MS-Programme, 7

- Parser, 23
- Passes, 8
- Pragmatik, 7
- produktiv, 13
- PS-Programmen, 7

- r-Analyse, 25
- Rechtsanalyse, 23
- reduziert, 25

- Scanner, 10
- Schlüsselwörter, 10
- Schnittstellen, 23
- Semantik, 7
- Shift-Reduce-Verfahren, 34
- Spezielle Symbole, 10
- startsepariert, 34
- Symbole, 9
- Symbolklassen, 9
- Syntaktische Einheiten, 23

Syntax, 7
Synthesephase, 8
synthetischer, 73

TD-Analyseautomat, 25
Token, 9, 10, 15
Top-Down-Analyse, 23

unterhalb A abhängig, 74

vereinigt, 39
von-Neumann-Rechners, 7

Zahlwörter, 10
zirkulär, 74
zirkuläre Abhängigkeit, 74
Zusammengesetzte Symbole, 10