3. Kapitel

Zerteilung

Kapitel 3: Zerteilung

3. Zerteilung

vorgegeben:

- Symbolfolge
- kontextfreie Grammatik (deterministisch?)

Aufgaben

- syntaktische Struktur bestimmen
- syntaktische Fehler melden, korrigieren (?)
- Ausgabe (immer): abstrakte Syntax (Rechts-/Linksableitung), Symbole (Bezeichner, Konstanten, usw.)

3. Einbettung des Zerteilers

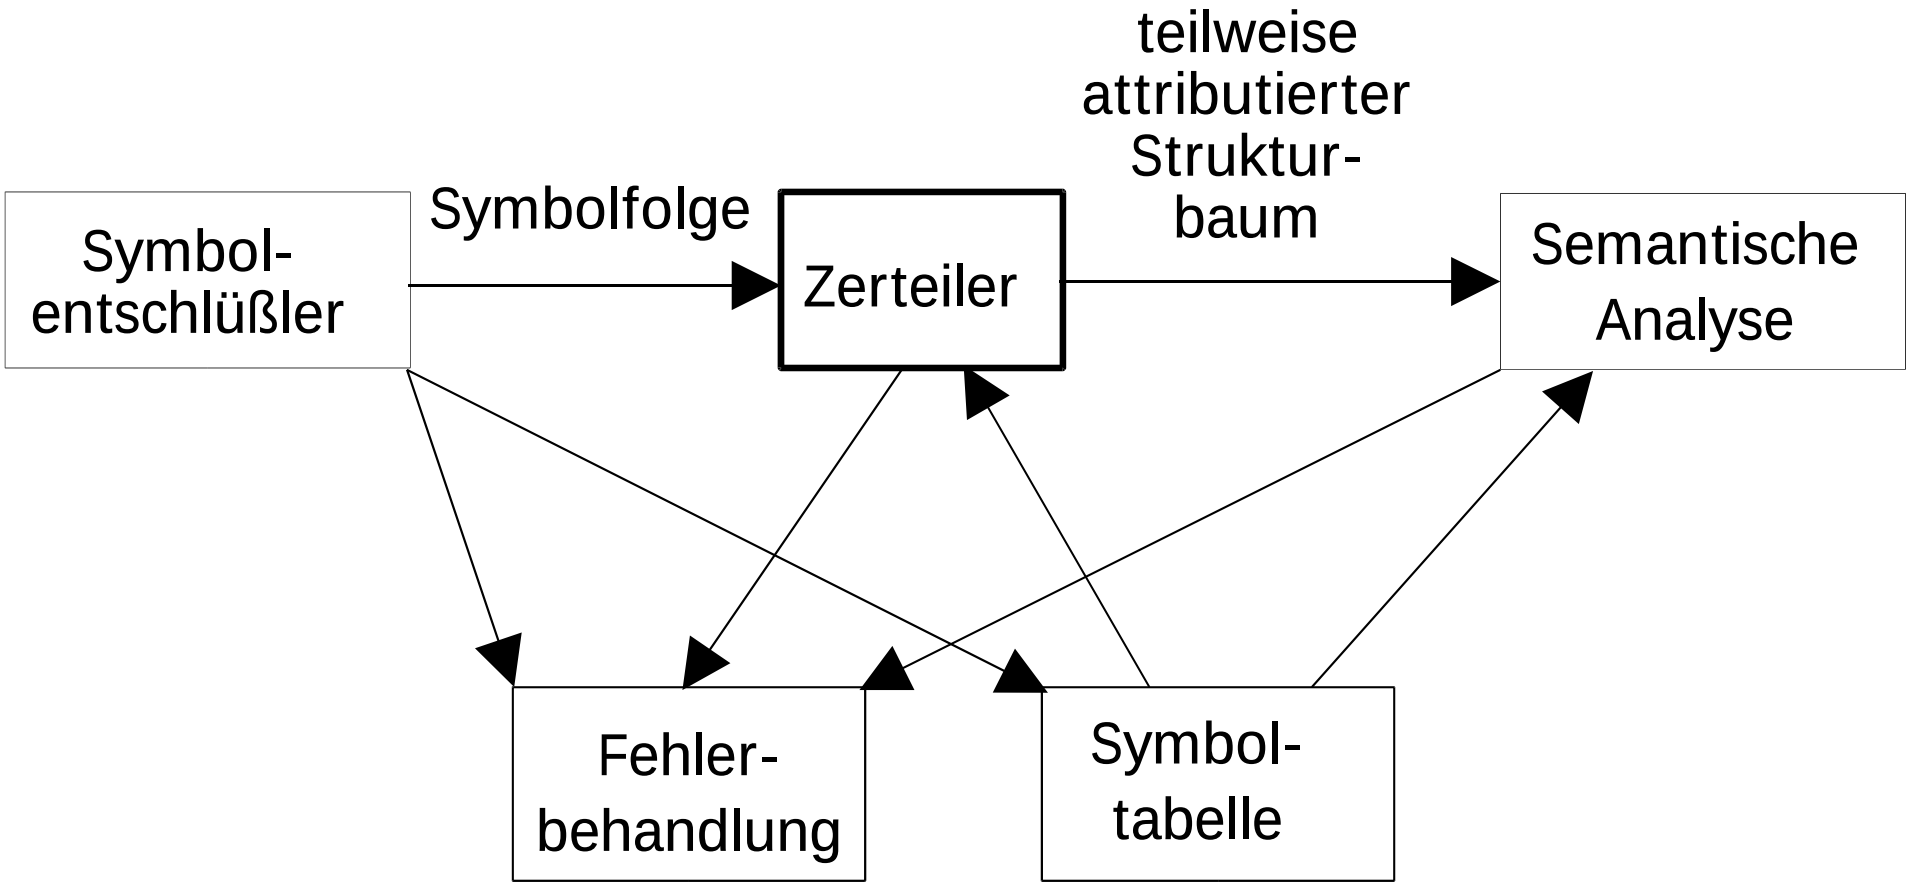

3. ADT Zerteiler

gelieferte Operationen:

```
initialisiere
beende
zerteile
```

benötigte Operationen:

- Symbolentschlüßler/Symbolfolge
  `nächstes_Symbol();`
- Fehlerbehandlung
  `Fehlereintrag(Nr,pos)`
- für Aufbau Strukturbaum
  `produktion(nr), symbol(merkmal)`

3. Aufgabe des Zerteilers, formal

Gegeben: Grammatik $G=(\Sigma,N,P,Z)$ mit

Σ Alphabet, N Nichtterminale, P Produktionen, Z Zielsymbol

Gesucht: Entscheidung, gehört Symbolfolge s zu $L(G)$,

wenn ja, Produktionenfolge für Links-/Rechtsableitung
wenn nein, Fehlerbehandlung zur Korrektur der Symbolfolge.

Unterscheide konkrete Syntax G_k und abstrakte Syntax G_a:

Gesucht: Entscheidung, gehört Symbolfolge s zu $L(G_k)$,
wenn ja, Produktionenfolge für Links-/Rechtsableitung für G_a?

Beziehung zwischen G_k und G_a?

3. Fragen

Wie wird Sprache erkannt?

Wie wird abstrakter Strukturbaum aufgebaut?

Was geschieht bei Fehlern?

3 Historie, kf Grammatiken + Verarbeitung

1955	Definition und Klassifikation (Chomsky und Bar Hillel)
1957-59	Kellerautomaten (Bauer&Samelson, sequentielle Formelübersetzung, 1959)
1961	formaler Zusammenhang kfGs-Kellerautomat (Öttinger)
1958-1966	kfGs und BNF setzen sich für die Syntax von Programmiersprachen durch (Algol 58, Algol 60, ...)
1960-1972	Verfahren des rekursiven Abstiegs (Glennie) und dessen theoretische Fundierung als LL-Grammatiken (auch heute noch oft neu erfunden!)
1963-1969	deterministische kfGs: beschränkte Operatorpräzedenz, LR, SLR, LALR,...
seit 1972	nichts wesentlich Neues außer Optimierung, Fehlerbehandlung

Kapitel 3: Zerteilung

1. Theoretische Grundlage: Kontextfreie Grammatiken
   - Notation
   - Konkrete und abstrakte Syntax
   - Rekursiver Abstieg
   - Kellerautomaten
   - Elimination von Linksrekursion und ε-Produktionen
   - Systematische Zerteilerkonstruktion: LL-, LR-Grammatiken
2. LL- und SLL-Grammatiken
3. LR-, SLR-Grammatiken
   - 3.1 LALR-Konstruktion
   - 3.2 Optimierungen und Komplexität
4. Fehlerbehandlung

3.1 Schreibweise der Produktionen

in der Theorie: $A \rightarrow x \mid y \mid ..., A \in N, x,y \in V^*, V = \Sigma \cup N$

praktisch: Backus-Naur-Form (BNF)

- Nichtterminale in spitzen Klammern,
- Terminale als Symbole oder wie Nichtterminale
- ::= statt $\rightarrow$

  <Ausdruck> ::= <Term> | <Ausdruck> + <Term>

Rechnereingabe: Erweiterte Backus-Naur-Form (EBNF)

- wie BNF, aber Bezeichner oft ohne spitze Klammern
- | (oder), . (Abschluß), ( ) (Gruppierung), [ ] (optional),

  * (Wiederholung, auch 0-mal), + (Wiederholung, mindestens einmal) als Beschreibungssymbole
- Terminale durch Apostrophs o. ä. ausgezeichnet

  Ausdruck ::= Term ('+' Term)* .

Fortran-, Cobol-, Java-Beschreibung: Abarten von EBNF

3.1 EBNF mit Listennotation

Grammatik ::= *Regel* + .
Regel ::= *Bezeichner* '::=' *Ausdruck* '.' .
Ausdruck ::= (*Element* + || ' |') | *Ausdruck* ' ||' *Atom* .
Element ::= *Einheit* ['*' | '+'] | ' [' *Ausdruck* ']'
Einheit ::= *Atom* | '(' *Ausdruck* ')' .
Atom ::= *Bezeichner* | *Literal* .

Ein Literal ist ein Text begrenzt durch Apostrophs.

x || ',' bedeutet ein oder mehrere *x*, getrennt durch Komma

Stärkste Bindung *, +, dann ||, dann |, dann Gesamtregel

3.1 Beispielgrammatik

Ausdrücke

(0) $Z \rightarrow A$

(1) $A \rightarrow T$ (2) $A \rightarrow A + T$

(3) $T \rightarrow F$ (4) $T \rightarrow T * F$

(5) $F \rightarrow bez$ (6) $F \rightarrow (A)$

EBNF:

(0) $Z \rightarrow A\,.$

(1) $A \rightarrow T\ (\ '+'\ T)^*\,.$

(2) $T \rightarrow F\ (\ '*'\ F)^*\,.$

(3) $F \rightarrow bez \mid '('\ A\ ')'\,.$

Ausdruck *a + (b+c)*

konkreter Strukturbaum:

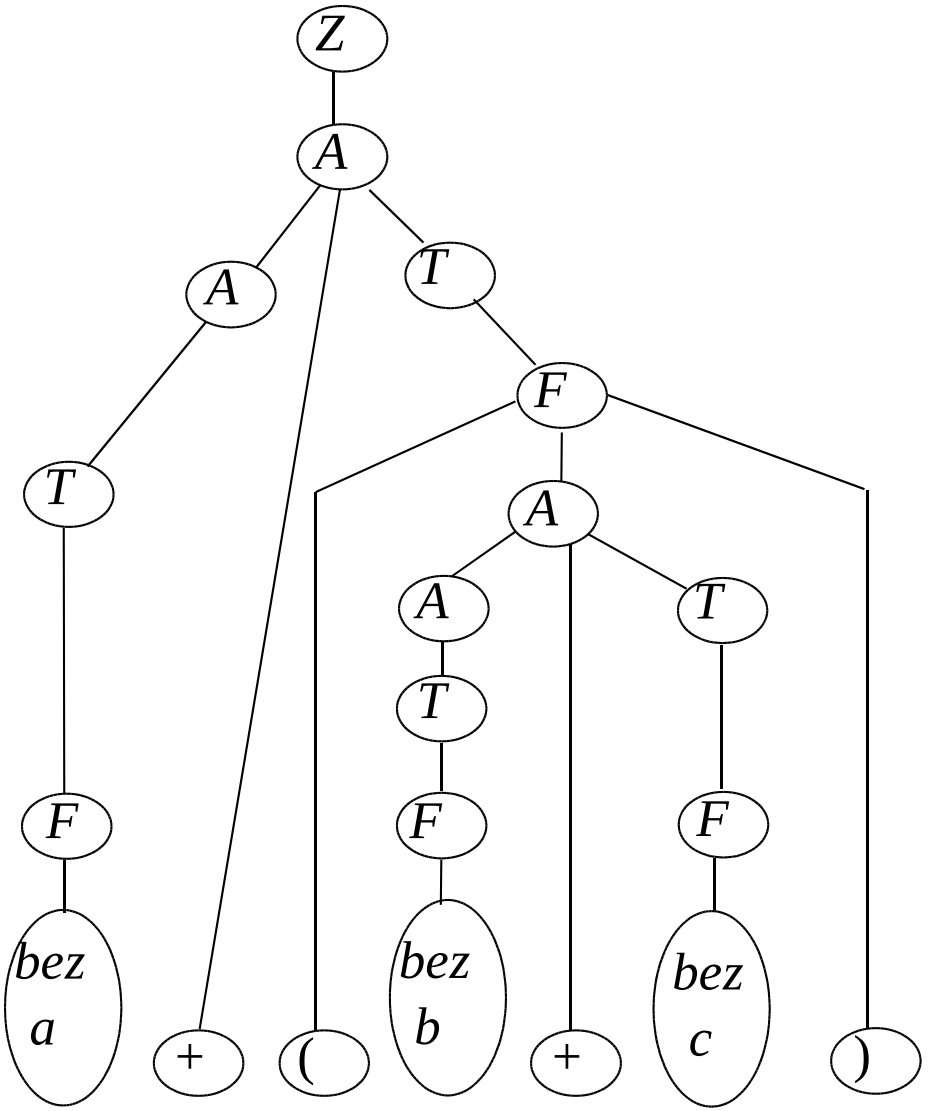

3.1 Konkrete und abstrakte Syntax

Prinzip der abstrakten Syntax: nur die für die Semantik wichtige Struktur behalten: $A \rightarrow A + A \mid A * A \mid bez$

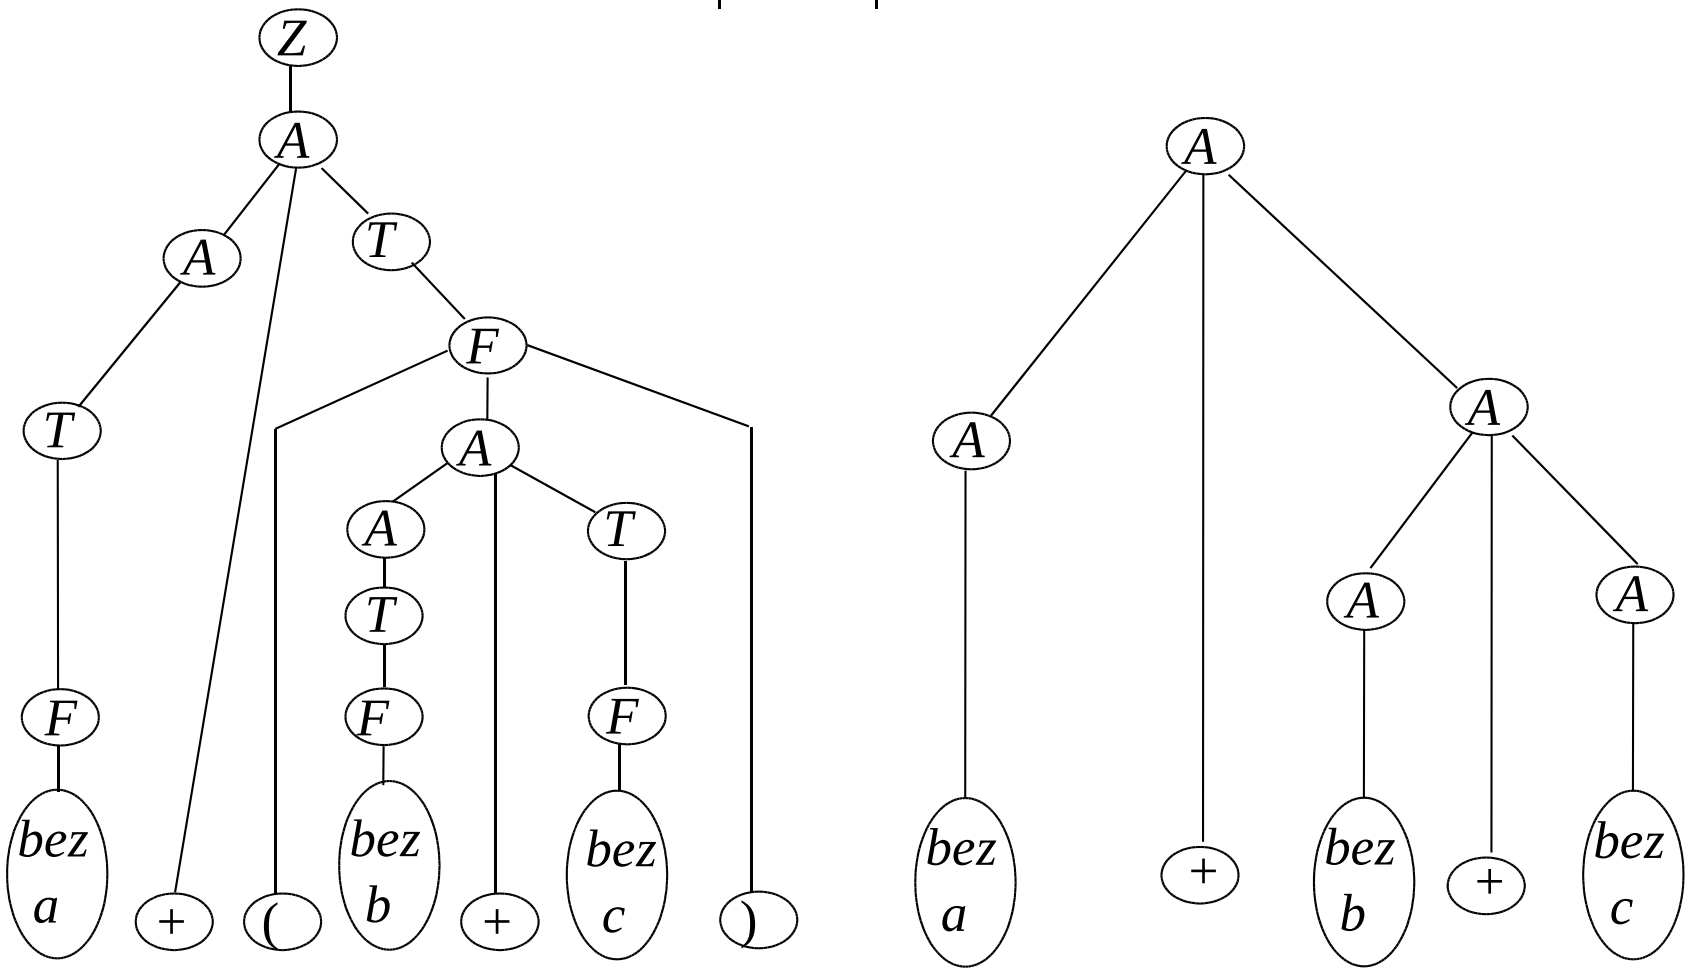

3.1 Konkrete und abstrakte Syntax

Prinzip der abstrakten Syntax: nur die für die Semantik wichtige Struktur behalten: $A \rightarrow A + A \mid A * A \mid bez$

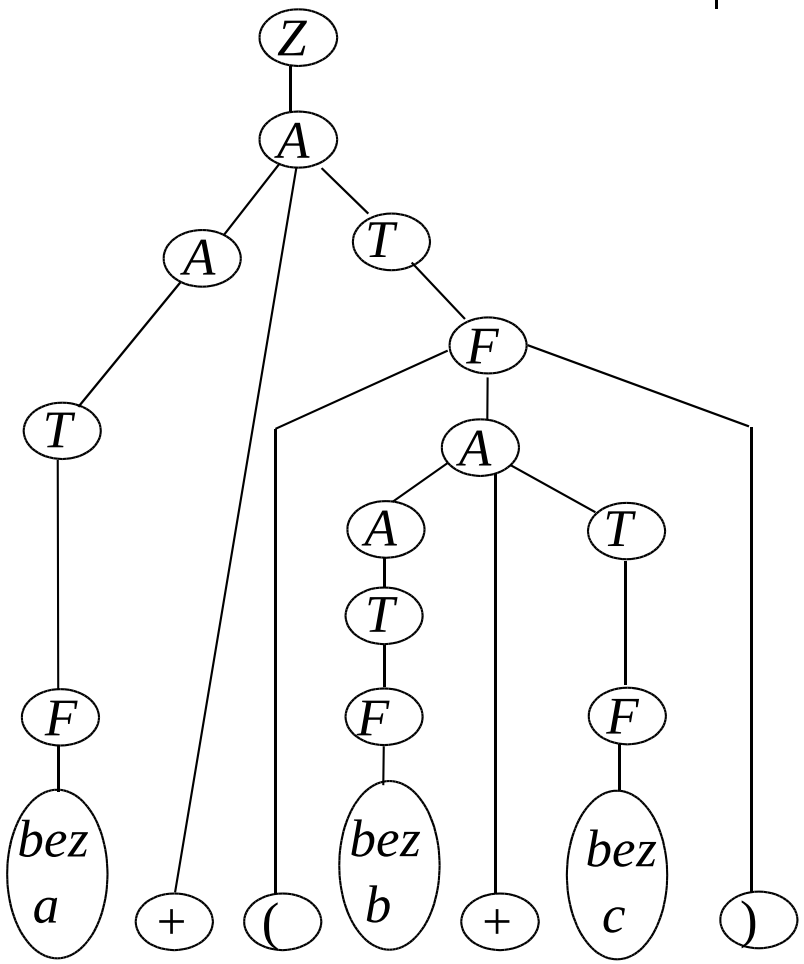

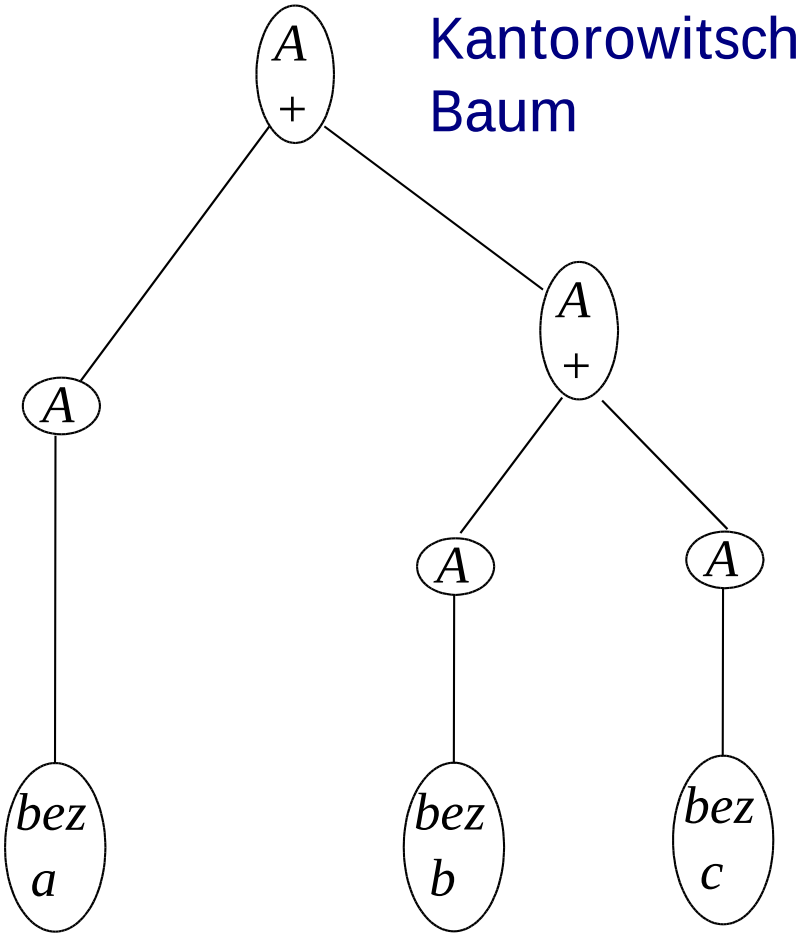

Kantorowitsch-Baum

3.1 Abstrakte Syntax

Konkrete Syntax enthält redundante Information:

- Ketten- und Verteilerproduktionen $A \rightarrow B$ bzw. $A \rightarrow B \mid C \mid \ldots$
- Wort- und Operatorsymbole, die spezifisch für die Produktion sind
- explizite Strukturinformation (Klammerung)

diese Ecken und Produktionen entfallen im Strukturbaum,
außer sie tragen semantische Bedeutung

- z.B. beim Operandenzugriff: Unterschied Adresse/Wert

Produktionsnummer wird Eckentyp

Operatoren als Attribute der Ecke für den Ausdruck

3.1 Sonderfälle in abstrakter Syntax

Bezeichner:

- $A \rightarrow bez$ ist Kettenproduktion mit semantischer Bedeutung *leseInhalt* der Variablen *bez* (Unterschied zu *bez* := ...)

Klammern in Fortran:

- Information eigentlich bereits in der Baumstruktur
- aber Klammern sind bindend (kein Umordnen erlaubt)
- sonst gilt eventuell Assoziativgesetz (umordnen erlaubt?)
- müssen als Operator gespeichert werden

Anweisungslisten in C:

- sind Verteilersymbole
- aber Strichpunkt-Operator legt Auswertungsfolge fest (auch ohne Datenabhängigkeiten), Code-Verschiebung verboten?

3.1 Abstrakte Syntax II

- abstrakte Syntax quellsprachenunabhängig?
  - Programmstruktur in semantischer Analyse aufgearbeitet, danach nur noch Prozeduren interessant
  - Prozeduraufrufe nur bezüglich Parameterübergabe unterschiedlich
  - Ablaufsteuerung identisch, eventuelle Ausnahme: Zählschleifen
  - Ausnahmebehandlung in allen modernen Sprachen identisch
  - Zuweisung, Ausdrucksoperatoren, usw.: identisch, manchmal vielleicht Ergänzungen erforderlich
- Konsequenz: weitere Verarbeitung (Transformation, Optimierung, Codegen.) weitgehend unabhängig von der Quellsprache
  - Systeme: UNCOL, ANDF, Dotnet
  - Dotnet kann als Postfixcodierung von UNCOL angesehen werden

3.1 Anknüpfungen

Ausgabe des Zerteilers: Produktionen von G_a und Symbole

Methode: Anknüpfung der Ausgaberoutinen in die Grammatik eintragen

Syntaktische Anknüpfungen: %Ausgabe

Symbol Anknüpfungen: &Ausgabe

Beachte: Symbole werden in der Reihenfolge abgenommen, in der sie in der Symbolfolge erscheinen

3.1 Ausgabe von Postfix- oder Präfixform

Ausgaberoutinen:

addop:	gib aus '+'
mulop:	gib aus '*'
bezeichner:	gib aus *bez*
merke:	merke *bez*
bez_aus:	gib gemerkten *bez* aus

Postfixform, d.h. abstrakter Syntaxbaum als Rechtsableitung:

(1) $A \rightarrow T\ (\ '+'\ T\ \%addop\ )^*\ .$

(2) $T \rightarrow F\ (\ '*'\ F\ \%mulop\ )^*\ .$

(3) $F \rightarrow bez\ \&bezeichner\ |\ '('\ A\ ')'\ .$

Präfixform, d.h. abstrakter Syntaxbaum als Linksableitung:

(1) $A \rightarrow T\ (\ '+'\ \%addop\ \%bez\_aus\ T)^*\ \%bez\_aus\ .$

(2) $T \rightarrow F\ (\ '*'\ \%mulop\ \%bez\_aus\ F)^*\ \%bez\_aus\ .$

(3) $F \rightarrow bez\ \&merke|\ '('\ A\ ')'\ .$

3.1 Rekursiver Abstieg

Einfachstes und intuitives Verfahren:

Verstehe die Produktionen als rekursives Programm mit Rücksetzmöglichkeit bei Fehlentscheidungen

Konstruiere Linksableitung

Füge explizit an entsprechenden Stellen ein:

- Anknüpfungen
- (Setzen von Attributen)
- notwendige Fehlermeldungen

3.1 Zerteiler für Beispielgrammatik I

Anwendung von rekursivem Abstieg auf die Beispielgrammatik

(0) $Z \rightarrow A\,.$

(1) $A \rightarrow T\ (\ '+'\ T)^*\,.$

(2) $T \rightarrow F\ (\ '*'\ F)^*\,.$

(3) $F \rightarrow bez \mid\ '('\ A\ ')'\,.$

mit Aufbau des Strukturbaums als Linksableitung

Ecken des Strukturbaums gehören zur Klasse

```
class AST {
    AST links, rechts;    // die beiden Söhne
    OPER operator;        // kennzeichnet die Produktion
    SYMBOL merkmal;       // Merkmal von Bezeichnern
    AST(SYMBOL s) { this.merkmal = s; };
    AST(OPER op)  { this.operator = op; }
};                        // class AST
```

i.a. ist AST eine abstrakte Klasse, von der die verschiedenen Eckentypen (hier: operator- und symbol-Ecke) erben

3.1 Zerteiler für Beispielgrammatik II

```
class Syntaxanalyse {
zerteile(): AST {s=nextSymbol(); return Z();}
Z(): AST {return A();}
A(): AST {
  AST res = T(); // merke 1. Operand
     while ( s == "+" ) {s=nextSymbol();
         AST res1   = new AST(plus);
         res1.left  = res; res1.right = T(); res = res1;}
     return res; }
T(): /* analog A */
F(): AST{
  if (class(s)== bez){AST res = new AST(s);s=nextSymbol(); return
   res;}
  if (class(s)==KlammerAuf){s=nextSymbol(); AST res = A();
         if (class(s)==KlammerZu) s=nextSymbol();
         else Fehlerbehandlung.Fehlereintrag(KlammerZuFehlt,s.pos); }
  else Fehlerbehandlung.Fehlereintrag(unzulässigesSymbol,s.pos);
  return res;}
}
```

3.1 Annahmen für die Zerteilung

Syntax ist kontextfrei

- eigentlich ist sie kontext-sensitiv
- aber kontext-sensitive Grammatiken nicht in linearer Zeit zerteilbar (Kontextfreiheit ist selbsterfüllende Prophezeiung)
- der über die kontextfreie Grammatik hinausgehende Teil der Syntax heißt im Übersetzerbau statische Semantik

Syntax ist deterministisch kontextfrei

- keine wesentliche Einschränkung, da auch vom menschlichen Leser erwünscht

keine Rückkopplung zur Symbolentschlüsselung

- sonst gäbe es mehrere Grundzustände des Symbolentschlüßlers, gesteuert vom Zerteiler

keine Rückkopplung semantische Analyse - Zerteilung

- typunabhängige Zerteilung: Zustände des Zerteilers unabhängig von der Namens- und Typanalyse

3.1 Typunabhängiges Zerteilen

Typunabhängiges Zerteilen

- Zerteilen ohne Kenntnis über Typen von Symbolen
- ist üblich, aber nicht immer ausreichend

Typabhängiges Zerteilen

- Bsp: ADA `a⋆first(2)`

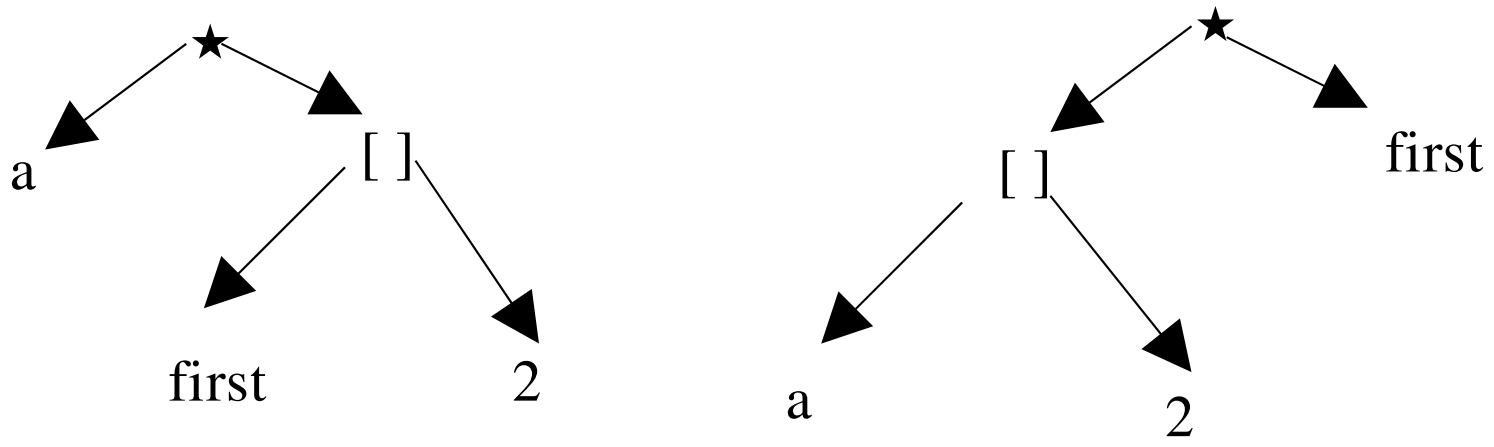

3.1 Typabhängiges Zerteilen

Beispiel: Formate in FORTRAN

- `print(r 20, real_const)`
- `r 20` ist Format und muß anders behandelt werden, sonst `r` Bezeichner und `20` ganze Zahl

Zerteiler umschaltbar, um Formate zu bearbeiten

- D.h., es gibt zwei verschiedene Zerteiler
- Erst semantische Analyse erkennt Bezeichner `print`

Umschaltung also semantik- (oder typ-) gesteuert

Ähnliche Probleme in ABAP/4

3.1 Kellerautomaten

$A = (\Sigma, Q, R, q_0, F, S, s_0)$

Σ Eingabealphabet (Symbole)

Q Zustandsmenge

R Menge von Regeln $sqx \rightarrow s'q'x'$, $s,s' \in S^*$, $q,q' \in Q$, $x \in \Sigma^*$, $x = x'' x'$

- q_0 Anfangszustand, $F \subseteq Q$ Menge von Endzuständen

  S Kelleralphabet, $s_0 \in S$ Anfangszeichen im Keller

- Konfiguration: $\underline{s}q\underline{x}$, $\underline{s}$ vollständiger Kellerinhalt, $\underline{x}$ restliche Eingabe
- Anfangskonfiguration: s_0qy, y vollständige Eingabe

- Regel $sqx \rightarrow s'q'x'$ anwendbar, wenn $\underline{s} = \underline{s'}\underline{s}$, $\underline{x} = x\underline{x'}$
- Folgekonfiguration: $\underline{s'}\underline{s}\,s'q'x'\underline{x'}$
- Halt bei Konfiguration sq, $q \in F$, Eingabe vollständig gelesen

  praktisch Endezeichen # erforderlich, Halt bei $sq\#$

$\underline{s'}$	s	q	x	$\underline{x'}$
$\underline{s'}$	s'	q'	x'	$\underline{x'}$

3.1 Kontextfreie Grammatik und Kellerautomaten

Satz: Für jede kontextfreie Grammatik G gibt es einen (nicht-deterministischen) Kellerautomaten A mit $L(A)=L(G)$

$\Rightarrow$ das Akzeptionsproblem für kontextfreie Sprachen ist entscheidbar.

Aber: Sprachinklusion und Gleichheit nicht entscheidbar

$\Rightarrow$ keine eindeutige Normalform

Aber: Aufwand i.a. $O(n^3)$

$\Rightarrow$ praktisch nur Teilklassen mit linearem Aufwand brauchbar, dazu Grammatik-Umformungen erforderlich

3.1 Textmengen

$k:x = x\#, \quad$ falls $\quad |x| < k$

$k:x = x_1 \ldots x_k, \quad$ falls $\quad x = x_1 \ldots x_m \wedge m \geq k$

$\text{Anf}_k(x) = \{u \mid \exists y \in \Sigma^* \text{ so daß } x \Rightarrow^* y, u = k:y\}$

$\text{Anf}'_k(x) = \{u \mid u \in \text{Anf}_k(x) \wedge \neg\exists A \in N, y \in \Sigma^* \text{ so daß } x \Rightarrow^R Auy \Rightarrow uy\}$

$\text{Folge}_k(x) = \{u \mid \exists y \in V^* \text{ so daß } Z \Rightarrow^* mxy, u \in \text{Anf}_k(y)\}$

3.1 Beseitigung von ε-Produktionen

Satz: Für jede kfG G mit ε Produktionen gibt es eine kfG G' ohne ε Produktionen mit $L(G) - \{\varepsilon\} = L(G')$ und umgekehrt.

Technik dazu: Linksfaktorisierung

3.1 Linksfaktorisierung

Produktionen $X \to Yb \mid Yc$ mit gleicher LS und gemeinsamem Anfang Y kann man nicht mit rekursivem Abstieg verarbeiten, wenn Länge $|y|$,$Y \Rightarrow^* y$, unbeschränkt, $|y| \geq 0$.

Lösung: den gemeinsamen Anfang ausklammern
ersetze $X \to Yb \mid Yc$ durch $X \to YX', X' \to b \mid c$

Analog kann man rechtsfaktorisieren (seltener benötigt).

3.1 Systematische Zerteilerkonstruktion

- Es gibt weit mehr als 25 verschiedene Techniken zur Zerteilerkonstruktion, vgl. Aho&Ullman, *The Theory of Parsing and Compiling*, 2 Bde, 1972
- Nur zwei Techniken , LL und LR, haben die Eigenschaften:
  - Der Zerteiler liest die Quelle einmal von links nach rechts;
  - Der Zerteiler erkennt einen Fehler beim ersten Zeichen t, das nicht zu einem Satz der Sprache gehören kann. t heißt zerteilerdefinierte Fehlerstelle (*parser defined error*):
    Wenn $x \notin L(G)$ und der Zerteiler erkennt den Fehler beim Zeichen t, $x = x'tx''$, so gibt es einen Satz $y \in L(G)$ mit $y = x'y'$.
  - Alternative: Erkennen des Fehlers einige Zeichen später, keine syntaktische Fehlerlokalisierung möglich.

3.1 Herleitung der LL- und LR-Zerteiler

- gegeben Grammatik $G=(\Sigma,N,P,Z)$, $V=\Sigma \cup N$, konstruiere indeterministischen Kellerautomat mit genau einem Zustand q, angesetzt auf Eingabe x

Für LL: (prädiktiv)	Für LR: (reduzierend)
$tqt \rightarrow q,\ t \in T$	$qt \rightarrow tq,\ t \in T$
$Xq \rightarrow x_n...x_1q,\ X \rightarrow x_1...x_n \in P$	$x_1...x_nq \rightarrow Xq,\ X \rightarrow x_1...x_n \in P$

- mache Kellerautomat deterministisch durch Hinzunahme Rechtskontext, also Vorhersage $Xqx' \rightarrow x_n...x_1qx'$ bzw. Reduktion $x_1...x_nqx' \rightarrow Xqx'$,
  x' Anfang des unverarbeiteten Eingaberests
- deterministisch machen geht nur für eingeschränkte Grammatikklassen

3.1 Nichtdeterministische LL- und LR-Zerteiler

Für LL: (prädiktiv)	Für LR: (reduzierend)
Vergleich (compare):	Schift (shift):
$tqt \rightarrow q, t \in T$	$qt \rightarrow tq, t \in T$
Vorhersage (produce):	Reduktion (reduce):
$Xq \rightarrow x_n...x_1q, X \rightarrow x_1...x_n \in P$	$x_1...x_nq \rightarrow Xq, X \rightarrow x_1...x_n \in P$

top-down Zerteiler

vom Startsymbol zum Wort

bottom-up Zerteiler

vom Wort zum Startsymbol

Anmerkung: Der Zustand ist bedeutungslos.

Kapitel 3: Zerteilung

1. Theoretische Grundlage: Kontextfreie Grammatiken
   - Notation
   - Konkrete und abstrakte Syntax
   - Rekursiver Abstieg
   - Kellerautomaten
   - Elimination von Linksrekursion und ε-Produktionen
   - Systematische Zerteilerkonstruktion: LL-, LR-Grammatiken
2. LL- und SLL-Grammatiken
3. LR-, SLR-Grammatiken
   - 3.1 LALR-Konstruktion
   - 3.2 Optimierungen und Komplexität
4. Fehlerbehandlung

3.2 $LL(k)$-Grammatiken

Für $k \geq 1$ heißt eine kfG $G=(\Sigma,N,P,Z)$ eine $LL(k)$-Grammatik, wenn

für alle Paare von Ableitungen

$$Z \Rightarrow_L \mu A \chi \Rightarrow \mu\nu\chi \Rightarrow^* \mu\gamma \qquad \mu, \gamma \in T^* \qquad \nu, \chi \in V^*, A \in N$$

$$Z \Rightarrow_L \mu A \chi' \Rightarrow \mu\omega\chi' \Rightarrow^* \mu\gamma' \qquad \mu, \gamma' \in T^* \qquad \omega, \chi', \in V^*$$

gilt:

$$(k:\gamma = k:\gamma') \Rightarrow \nu = \omega.$$

Also: Aus den nächsten k Zeichen kann unter Berücksichtigung des Kellerinhalts die nächste anzuwendende Produktion eindeutig vorhergesagt werden.

Die k Zeichen können aus der Produktion resultieren oder ganz oder teilweise dem Folgetext angehören, z.B. bei ε-Produktionen.

3.2 Beispiele von LL-Grammatiken

$A \to TA', A' \to \varepsilon \mid +TA', T \to FT', T' \to \varepsilon \mid *FT', F \to bez \mid '('\ A\ ')\diamond$
ist $LL(1)$.

$Z \to aAab \mid bAbb, A \to \varepsilon \mid a$ ist $LL(2)$, nicht $LL(1)$: Vorschau aa, ab, bb entscheidet unter Berücksichtigung der Produktion für Z über die Produktion für A.

$Z \to X, X \to Y \mid bYa, Y \to c \mid ca$ ist $LL(3)$.

$Z \to X, X \to Yc \mid Yd, Y \to a \mid bY$ ist für kein k $LL(k)$; aber Linksfaktorisieren macht daraus $LL(1)$.

Anweisungen, die mit Schlüsselwort `while`, `if`, `case`, usw. beginnen, sind mit $LL(1)$-Technik vorhersagbar. Bei Beginn mit Bezeichner sind Umformungen nötig.

3.2 Satz über Linksrekursion

Satz: Eine linksrekursive kfG ist für kein k $LL(k)$.

Beweisidee:

Seien $A \rightarrow Ax$ und $A \rightarrow y$ linksrekursive bzw. terminierende Regeln.

Jeder k-Anfang der terminierenden Regel ist auch
k-Anfang der linksrekursive Regel.

3.2 Elimination von Linksrekursion

Satz: Für jede kfG G mit linksrekursiven Produktionen gibt es eine kfG G' ohne Linksrekursion mit $L(G)=L(G')$.

- Konstruktion:
  - Numeriere Nichtterminale $X_1,\ldots,X_n$. Ziel: $i<j$, wenn $X_i \to X_j\, x \in P$
  - Für $i=1,\ldots,n$
    - Für $j=1,\ldots,n-1$ ersetze $X_i \to X_j\, x$ durch $\{X_i \to y_j x \mid X_j \to y_j \in P\}$
      (danach $i \le j$, wenn $X_i \to X_j\, x \in P$)
    - ersetze die Produktionenmengen $\{X_i \to X_i\, x\} \cup \{X_i \to z \mid z \neq X_i z'\}$ durch $\{Y_i \to xY_i \mid X_i \to X_i x \in P\} \cup \{Y_i \to \varepsilon\} \cup \{X_i \to zY_j \mid X_i \to z \in P \text{ und } z \neq X_i\, z'\}$ mit einem neuen Nichtterminal Y_i. (Numerierung der Y_i mit $n+1, n+2,\ldots$)
- Beachte: in Schritt 2 Ersetzung durch
  $\{Y_i \to x, Y_i \to xY_i \mid X_i \to X_i x \in P\} \cup \{X_i \to zY_j \mid X_i \to z \in P \text{ und } z \neq X_i z'\}$
  ohne ε-Produktionen möglich, wenn x nicht mit X_j, $j \le i$, beginnt.

3.2 Beispiel

- $A \rightarrow T \mid A + T\,,\; T \rightarrow F \mid T * F, F \rightarrow bez \mid (\,A\,)$
  ist linksrekursiv
- Ersetzung: Schritt 1 leer, Schritt 2: $A \rightarrow T \mid A + T$ durch
  $A \rightarrow T\,A', A' \rightarrow \varepsilon \mid + TA'$ ersetzen; $T \rightarrow F \mid T * F$ analog.
  Dies entspricht der EBNF
  $A \rightarrow\; T\;(\,'+'\,T)^*\,,\; T \rightarrow F\;(\,'*'\;F)^*\,,\; F \rightarrow bez \mid '\,('\,A\;\;')'\,.$
- Andere mögliche Ersetzung $A \rightarrow T \mid T\,A', A' \rightarrow +\;T\;\mid TA'$
- Vorsicht!
  Die Ersetzung durch $A \rightarrow T \mid T + A$ ist semantisch unzulässig!
- Sie transformiert Links- in Rechtsassoziativität, verändert also die semantisch bedeutungsvolle Struktur.
- Beseitigung von Linksrekursion bei rekursivem Abstieg nötig für alle Anweisungen, die mit $<Bezeichner>$ $<Operator>$ anfangen können (Zuweisungen, Ausdrücke)

3.2 $SLL(k)$-Grammatiken

Für $k \geq 1$ heißt eine kf Grammatik $G=(\Sigma,N,P,Z)$ eine $SLL(k)$-Grammatik (starke LL-Grammatik), wenn für alle Paare von Ableitungen

$$Z \Rightarrow_L \mu A\chi \Rightarrow \mu\nu\chi \Rightarrow^* \mu\gamma \qquad \mu, \gamma \in T^* \qquad \nu, \chi \in V^*, A \in N$$
$$Z \Rightarrow_L \mu' A\chi' \Rightarrow \mu'\omega\chi' \Rightarrow^* \mu'\gamma' \qquad \mu', \gamma' \in T^* \qquad \omega, \chi' \in V^*$$

gilt:

$$(k : \gamma = k : \gamma') \Rightarrow \nu = \omega.$$

Also: Aus den nächsten k Zeichen kann ohne Berücksichtigung des Kellerinhalts die nächste anzuwendende Produktion eindeutig vorhergesagt werden.

3.2 SLL-Bedingung

Satz: Eine Grammatik ist genau dann eine $SLL(\mathrm{k})$-Grammatik, wenn für alle Paare von Produktionen $A \to x \mid x',\ x \neq x'$, die $SLL(k)$-Bedingung gilt:

$$\mathrm{Anf}_k(x\ \mathrm{Folge}_k(A)) \cap \mathrm{Anf}_k(x'\ \mathrm{Folge}_k(A)) = \varnothing$$

Beweis: trivial

- Also: $SLL(k)$-Eigenschaft durch Berechnung von Anf_k- und Folge_k-Mengen einfach nachzuprüfen.
- Wenn aus x, x' nur terminale Zeichenreihen mit mindestens k Zeichen ableitbar sind, trägt $\mathrm{Folge}_k(A)$ nichts zum Ergebnis bei und kann entfallen.
- Anwendung: Für $k = 1$ entfällt $\mathrm{Folge}_1(A)$ bei ε-freien Grammatiken.

3.2 $LL(1)$ und $SLL(1)$

Satz: Jede $SLL(k)$-Grammatik ist auch eine $LL(k)$-Grammatik.

Satz: Jede $LL(1)$-Grammatik ist eine $SLL(1)$-Grammatik.

Beweis: gegeben $A \to x \mid x',\ x \neq x'$, und

ein Zeichen $t \in \text{Anf}_1(x\ \text{Folge}_1(A)) \cap \text{Anf}_1(x'\ \text{Folge}_1(A))$.

Fallunterscheidung

- $t \in \text{Anf}_1(x), t \in \text{Anf}_1(x')$
- $\varepsilon \in \text{Anf}_1(x), t \in \text{Anf}_1(x'), t \in \text{Folge}_1(A)$
- $t \in \text{Anf}_1(x), \varepsilon \in \text{Anf}_1(x'), t \in \text{Folge}_1(A)$
- $\varepsilon \in \text{Anf}_1(x), \varepsilon \in \text{Anf}_1(x'), t \in \text{Folge}_1(A)$

Alle 4 Fälle nach $LL(1)$-Definition unzulässig. Vierter Fall sogar mehrdeutig.

Satz nicht auf $k > 1$ verallgemeinerbar:

$Z \to aAab \mid bAbb, A \to \varepsilon \mid a$ ist LL(2), aber nicht $SLL(2)$.

3.2 Situationen

Ziel: bei Prüfung der Anwendbarkeit von Regeln $sqx \rightarrow s'q'x'$

sq in einem Zustandssymbol codieren (Prüfung mehrerer Symbole im Keller vermeiden)

Lösungsidee:

- bei LL und LR ist s rechte bzw. linke Seite einer Produktion $X \rightarrow x_1 \ldots x_n$
- Übergänge $tqt \rightarrow q$ bzw. $qt \rightarrow qt$ sind nur zulässig, wenn in der Produktion ein Terminalzeichen t ansteht, $x_1 \ldots x_n = x'x''$ und $x'' = t\underline{x''}$
- also: ersetze sqx durch Situation $[X \rightarrow x' \simeq x'';x]$, die durch den Punkt anzeigt, wieweit die Produktion abgearbeitet ist.
- Situationen $[X \rightarrow \simeq x'';x]$ oder $[X \rightarrow x' \simeq ;x]$ sind erlaubt und notwendig.
- Verwende Situationen als Zustände und als Kellersymbole.
- Situationen heißen englisch *items*.

3.2 Formale Konstruktion $LL(k)$-Automat

1. **Initial** $Q = \{q_0\}$ und $R = \varnothing$, mit $q_0 = [Z \to \bullet\, S;\#]$.
   Anfangszustand und erster Kellerzustand q_0. Hinweis: $Folge_k(Z) = \{\#\}$.
2. Sei $q = [X \to \mu \bullet \nu;\, \Omega] \in Q$ und noch nicht betrachtet.
3. **Wenn** $\nu = \varepsilon$ **setze** $R := R \cup \{q\, \varepsilon \to \varepsilon\}$
   Auskellern $q'q \to q'$ mit beliebigem $q' \approx$
4. **Wenn** $\nu = t\gamma$ mit $t \in T$ und $\gamma \in V^*$, **setze** $q^\star = [X \to \mu\, t \bullet \gamma;\, \Omega]$.
   Setze $Q := Q \cup \{q^\star\}$ und $R := R \cup \{qt \to q'\}$.
5. **Wenn** $\nu = B\gamma$ mit $B \in N$ und $\gamma \in V^*$, **setze** $q^\star = [X \to \mu B \bullet \gamma;\, \Omega]$ und
   $H = \{[B \to \bullet\, \beta_i;\, \mathrm{Anf}_k(\gamma\, \Omega)] \mid B \to \beta_i \in P\}$.
   Hinweis: $1 \le i \le m$, wenn es m Produktionen mit linker Seite B gibt.
   Setze $Q := Q \cup \{q'\} \cup H$ und $R := R \cup \{q\tau_i \to q' h_i \tau_i \mid h_i \in H,\ \tau_i \in Anf_k(\beta_i\, \gamma\, \Omega)\}$.
6. **Wenn alle** $q \in Q$ betrachtet wurden, **stop**. **Sonst**, gehe zu (2).

3.2 Formale Konstruktion SLL(k)-Automat

1. **Initial** $Q = \{q_0\}$ und $R = \varnothing$, mit $q_0 = [Z \to \bullet\, S;\#]$.
   Anfangszustand und erster Kellerzustand q_0. Hinweis: $Folge_k(Z) = \{\#\}$.
2. Sei $q = [X \to \mu \bullet \nu;\, \Omega] \in Q$ und noch nicht betrachtet.
3. **Wenn** $\nu = \varepsilon$ **setze** $R := R \cup \{q\, \varepsilon \to \varepsilon\}$
   Auskellern $q' \otimes t \to q' \ominus$ mit beliebigem $q' \approx$
4. **Wenn** $\nu = t\gamma$ mit $t \in T$ und $\gamma \in V^*$, **setze** $q^\star = [X \to \mu\, t \bullet \gamma;\, \Omega]$.
   Setze $Q := Q \cup \{q^\star\}$ und $R := R \cup \{qt \to q'\}$.

5'. **Wenn** $\nu = B\gamma$ mit $B \in N$ und $\gamma \in V^*$, **setze** $q^\star = [X \to \mu B \bullet \gamma;\, \Omega]$ und
$H = \{[B \to \bullet\, \beta_i;\, Folge_k(B)] \mid B \to \beta_i \in P\}$.
Hinweis: $1 \le i \le m$, wenn es m Produktionen mit linker Seite B gibt.
Setze $Q := Q \cup \{q'\} \cup H$ und $R := R \cup \{q\tau_i \to q' h_i \tau_i \mid h_i \in H,\ \tau_i \in Anf_k(\beta_i Folge_k(B))\}$.

6. **Wenn alle** $q \in Q$ betrachtet wurden, **stop**, **Sonst**, gehe zu (2).

3.2 Formale Konstruktion $SLL(k)$-Automat

Einzig Regel 5 der $LL(k)$ Konstruktion ändert sich:

5'. **Wenn** $v = B\gamma$ mit $B \in N$ und $\gamma \in V^*$, setze $q^\star = [X \to \mu B \bullet \gamma; \Omega]$ und
$H = \{[B \to \bullet\, \beta_i; Folge_k(B)] \mid B \to \beta_i \in P\}$.

Hinweis: $1 \le i \le m$, wenn es m Produktionen mit linker Seite B gibt.

Setze $Q := Q \cup \{q'\} \cup H$ und $R := R \cup \{q\tau_i \to q'h_i\tau_i \mid h_i \in H,\ \tau_i \in Anf_k(\beta_i Folge_k(B))\}$.

3.2 *LL(1)*-Zerteiler mit rekursivem Abstieg

1. Definiere Prozedur X für alle Nichtterminale X
2. Für alternative Produktionen $X \to X_1, ..., X \to X_n$ sei Rumpf von X

```
switch s {
 case s ∈ Anf(X1 Folge(X)) : Code für X1 ;
 ...
 case s ∈ Anf(Xn Folge(X)) : Code für Xn ;
 default : Fehler(...); }
```

3. Für rechte Seite $X_i = Y_1 \ldots Y_m$ erzeuge:

   $C_1; \ldots; C_m;$ **return**

   Es gilt C_i =

   (a) `if (s == Yi)s = nächstesSymbol() else Fehler(...);`
   wenn $Y_i \in T$

   (b) $Y_i()$; wenn $Y_i \in N$

3.2 Zerteiler aus Grammatik in EBNF

Nichtterminal	X	`X();`
Terminal	t	`if (symbol == t) {nächstesSymbol();} else Fehler();`
Option	$[X]$	`if (symbol ∈ Anf(X)) X();`
Iteration	X^+	`repeat X(); until !(symbol ∈ Anf(X));`
	X^*	`while (symbol ∈ Anf(X)) X();`
Liste	$X\|\|d$	`X(); while (symbol ∈ Anf(d)) { d; X(); }`
Anknüpfung	$t\&Y$	`if (symbol == t) {Y(); nächstesSymbol();} else Fehler();`
	$\%Z$	`Z();`

3.2 Zerteiler für Beispielgrammatik

```
class Syntaxanalyse {
zerteile(): AST {s=nextSymbol(); return Z();}
Z(): AST {return A();}
A(): AST {
  AST res = T(); // merke 1. Operand
     while ( s == "+" ) {s=nextSymbol();
         AST res1   = new AST(plus);
         res1.left  = res; res1.right = T(); res = res1; }
     return res; }
T(): /* analog A */
F(): AST{
  if (class(s)== bez){AST res = new AST(s);s=nextSymbol(); return res;}
  if (class(s)==KlammerAuf){
´              s=nextSymbol(); AST res = A();
         if (class(s)==KlammerZu) s=nextSymbol();
         else Fehlerbehandlung.Fehlereintrag(KlammerZuFehlt,s.pos); }
  else Fehlerbehandlung.Fehlereintrag(unzulässigesSymbol,s.pos);
  return res;}
}
```

3.2 Praxis des rekursiven Abstiegs

- Einfügung von Anknüpfungen: Anknüpfung formal wie Produktion $A \rightarrow \varepsilon$ behandeln, statt der Prozedur für ein Nichtterminal A die Ausgabeprozedur aufrufen.
- Rekursiver Abstieg baut Linksableitung auf. Vorteil: beim Aufbau bereits erste Berechnungen von semantischen Attributen möglich (s. Kapitel "Semantische Analyse").
- Problem: Durch die Handprogrammierung können leicht während der Wartung syntaktische Eigenschaften eingeschleust werden, die die Systematik der Syntax und die Unabhängigkeit Syntax-Semantik zerstören. Negativbeispiel: ABAP 4
- Rekursiver Abstieg kann auch tabellengesteuert implementiert werden! Zerteiler wird Interpretierer der Tabelle. Vorteile: Vermeidung von Prozeduraufrufen, einfachere Fehlerbehandlung. Nachteil: nicht von Hand programmierbar.

Kapitel 3: Zerteilung

1. Theoretische Grundlage: Kontextfreie Grammatiken
   - Notation
   - Konkrete und abstrakte Syntax
   - Rekursiver Abstieg
   - Kellerautomaten
   - Elimination von Linksrekursion und ε-Produktionen
   - Systematische Zerteilerkonstruktion: LL-, LR-Grammatiken
2. LL- und SLL-Grammatiken
3. LR-, SLR-Grammatiken
   - 3.1 LALR-Konstruktion
   - 3.2 Optimierungen und Komplexität
4. Fehlerbehandlung

3.3 Motivation für LR/LALR

- LR basierte Zerteiler sind die mächtigsten, die noch effizient berechenbar sind und es gibt ausgreife Generatoren.
- Für den yacc-Generator produziert die Grammatik

```
%token IF ELSE THEN IDENT
%%
Statement:  IfStatement | Expr ;

Expr:       IDENT;

IfStatement:    IF Expr THEN Statement |
                IF Expr THEN Statement ELSE Statement ;
```

- allerdings folgende Fehlerdiagnose

```
state 7 contains 1 shift/reduce conflict.
...
state 7
  IfStatement  ->  IF Expr THEN Statement .                (rule 4)
  IfStatement  ->  IF Expr THEN Statement . ELSE Statement (rule 5)

  ELSE         shift, and go to state 8
  ELSE         [reduce using rule 4 (IfStatement)]
  $default     reduce using rule 4 (IfStatement)
```

3.3 Motivation für LR/LALR

- Frage: Wie kann man diese Fehlerdiagnose verstehen?
  - Zweck aller nachfolgenden Ausführungen ist nur darauf zu beziehen.
  - Detailliertes wissen über automatische Konstruktion vernachlässigbar
  - Aber: Intuitive „Hand"konstruktion muss beherrscht werden.
- Lösungen:
  - Grammatik ändern: abschließendes „end" einführen (meist unzulässig)
  - Ausfaktorisieren:

```
%token IF ELSE THEN IDENT
%%
Statement: IfStatement | Expr ;

Expr:      IDENT;

IfStatement:
   IF Expr THEN Statement |
   IF Expr THEN IfThenElseStat ELSE Statement ;

IfThenElseStat:
   IF Expr THEN IfThenElseStat ELSE IfThenElseStat |
   Expr ;
```

3.1 Wdh. Nichtdeterministische LL- und LR-Zerteiler

Für LL: (prädiktiv)	Für LR: (reduzierend)
Vergleich (compare):	Schift (shift):
$tqt \rightarrow q, t \in T$	$qt \rightarrow tq, t \in T$
Vorhersage (produce):	Reduktion (reduce):
$Xq \rightarrow x_n...x_1q, X \rightarrow x_1...x_n \in P$	$x_1...x_nq \rightarrow Xq, X \rightarrow x_1...x_n \in P$

top-down Zerteiler

vom Startsymbol zum Wort

bottom-up Zerteiler

vom Wort zum Startsymbol

Anmerkung: Der Zustand ist bedeutungslos.

3.3 Herleitung der LR-Zerteiler

- Gegeben Grammatik $G=(\Sigma,N,P,Z)$, $V=\Sigma \cup N$,
  konstruiere indeterministischen Kellerautomat mit genau einem Zustand q, angesetzt auf Eingabe x
- Mache Kellerautomat deterministisch durch Hinzunahme von Rechtskontext, also Reduktion $x_1 \ldots x_n q x' \rightarrow X q x'$,
  x' Anfang des unverarbeiteten Eingaberest

- Deterministisch machen geht nur für eingeschränkte Grammatikklassen

3.3 LR-Grammatiken

Ziel:

- alle deterministisch zerteilbaren kfG charakterisieren ($LL(k)$ ist stark eingeschränkt)
- Rechtsableitung konstruieren

Endgültige Definition von D.E. Knuth 1966:

Eine kf-Grammatik heißt eine $LR(k)$-Grammatik, wenn für alle Paare von Ableitungen

$$Z \Rightarrow_R \mu A \omega \Rightarrow \mu\chi\omega \qquad \mu \in V^*, \omega \in \Sigma^*, \qquad A \to \chi \in P$$

$$Z \Rightarrow_R \mu' B \omega' \Rightarrow \mu'\gamma\omega' \qquad \mu' \in V^*, \omega' \in \Sigma^*, B \to \gamma \in$$

gilt

$$(|\mu\chi| + k) : \mu\chi\omega = (|\mu'\gamma| + k) : \mu'\gamma\omega' \Rightarrow \mu = \mu', A = B, \chi = \gamma .$$

- Probleme: LR-Automat nur automatisch generierbar, sehr große Tabellen, Test der Eigenschaft nur durch Konstruktion möglich
- In der Praxis Beschränkung auf Unterklassen von $LR(1)$ mit $LR(0)$-Zustandsmenge .

3.3 Reduktionsklassen

Unter welchen Bedingungen soll der LR-Automat schiften/reduzieren?

maximal verfügbare Information:

Reduktionsklasse $\{(Kellerinhalt, Eingaberest)\}$ R_0 für Schift und R_p für Produktionen $A_p \to y_p$, p=1,...,n :

$R_0 = \{(r,s) \mid r = r''r',\ s = s's'' \text{ mit } Z \Rightarrow_R r''As'', A \Rightarrow_{R'} r's', s' \neq \varepsilon\}$

$R_p = \{(r, s) \mid r = r'' y_p,\ \text{mit } Z \Rightarrow_R r'' A_p s,\ A_p \to y_p \in P\}$

$R_i \cap R_j = \varnothing$ für $i \neq j$ bedeutet: Schiften bzw. Reduzieren mit Produktion p kann stets eindeutig entschieden werden. Jeder Satz besitzt eindeutige Rechtsableitung und eindeutigen Strukturbaum.
Grammatik ist eindeutig.

Leider: Eindeutigkeit von kf Grammatiken nicht entscheidbar, d.h. $R_i \cap R_j = \varnothing$ nicht algorithmisch entscheidbar.
Problem ist der unbeschränkt lange Eingaberest.

3.3 Textmengen (Wiederholung)

$k : x = \quad x\#, \qquad$ falls $\qquad |x| < k$

$k : x = \quad x_1 \ldots x_k\ , \qquad$ falls $\qquad x = x_1 \ldots x_m \wedge m \geq k$

$\text{Anf}_k(x) \ = \qquad \{u \mid \exists y \in \Sigma^* \ \text{so daß}\ x \Rightarrow^* y, u = k : y\}$

$\text{Anf}'_k(x) \ = \qquad \{u \mid u \in \text{Anf}_k(x) \wedge \neg\exists\, A \in N, y \in \Sigma^* \ \text{so daß}\ x \Rightarrow_R Auy \Rightarrow uy\}$

$\text{Folge}_k(x) = \qquad \{u \mid \exists y \in V^* \ \text{so daß}\ Z \Rightarrow^* mxy, u \in \text{Anf}_k(y)\}$

3.3 Warum ist Anf' nötig: Beispiel

$L(G) = \{cb, b\}$ und

$G =$ $\quad 1 : Z \to S, \quad 2: S \to Ab,$

$\quad 3 : A \to c, \quad 4: A \to \varepsilon$

$R_0 = \{(\varepsilon, cb\#), (A,b\#), \cancel{(\varepsilon,b\#)}\}, \quad R_1 = \{(S,\#)\},$

$R_2 = \{(Ab,\#)\}, \quad R_3 = \{(c,b\#)\},$

$R_4 = \{(\varepsilon,b\#)\}.$

Rechtsableitung $Z \Rightarrow_R S \Rightarrow_R Ab \Rightarrow_R b$:

ε auf A reduzieren, bevor das Zeichen b geschiftet wird. Ohne Unterscheidung zwischen $\Rightarrow_{R'}$ und $\Rightarrow_R$:

$(\varepsilon, b\#)$ gehört zu R_0, also Sackgasse

3.3 k-Kellerklassen

Idee: Beschränke den betrachteten Eingaberest auf $k \geq 0$ Zeichen:

k-Kellerklasse K_p^k, $p=0,\ldots,n$ definiert durch

$$K_p^k = \{(r,\underline{s}) \mid \exists\, (r,s) \in R_p \text{ mit } \underline{s} = k{:}s\}$$

Vergleich mit LR-Definition: Mit

$$Z \Rightarrow_R \mu A\omega \Rightarrow \mu\chi\omega \qquad \mu \in V^*,\ \omega \in T^*,\ A \to \chi \in P$$

$$Z \Rightarrow_R \mu' B\omega' \Rightarrow \mu'\gamma\omega' \qquad \mu' \in V^*,\ \omega' \in T^*,\ B \to \gamma \in P$$

gilt

$$(|\mu\chi| + k) : \mu\chi\omega = (|\mu'\gamma| + k) : \mu'\gamma\omega' \Rightarrow \mu = \mu',\ A = B,\ \chi = \gamma\ .$$

Satz: Eine Grammatik ist genau dann LR(k), wenn die k-Kellerklassen paarweise disjunkt sind. Eine Grammatik G ist genau dann deterministisch zerteilbar, wenn es ein $k \geq 0$ gibt, so daß G LR(k) ist.

3.3 Situationen (Wiederholung)

Ziel: bei Prüfung der Anwendbarkeit von Regeln $sqx \rightarrow s'q'x'$

sq in einem Zustandssymbol codieren (Prüfung mehrerer Symbole im Keller vermeiden)

Lösungsidee:

- bei LL und LR ist s (Teil einer) rechten bzw. linken Seite einer Produktion $X \rightarrow x_1 ... x_n$
- Übergang $qt \rightarrow q't$ sind nur zulässig, wenn in der Produktion ein Terminalzeichen t ansteht, $x_1 ... x_n = x'x''$ und $x'' = t\underline{x''}$
- also: ersetze sq durch Situation $[X \rightarrow x' \bullet x''; x]$, die durch den Punkt anzeigt, wieweit die Produktion abgearbeitet ist.
- Situationen $[X \rightarrow \bullet x''; x]$ oder $[X \rightarrow x' \bullet ; x]$ sind erlaubt und notwendig.
- Verwende Situationen als Zustände und als Kellersymbole

3.3 Entscheidungsverfahren, k-Kellerklassen

Satz (Büchi):

Die k-Kellerklassen sind regulär.

Beweis durch Angabe einer Grammatik G_i^k für K_i^k ,

$i = 0,\ldots,n.$

Dabei spielt die k-Vorschau keine wichtige Rolle, da es nur endlich viele Kombinationen von k Zeichen gibt.

Eigenschaften von G_i^k

- Situationen als Nichtterminale, Symbole $t \in V$ als Terminale
- Ziel $[Z \rightarrow S \bullet ;\#]$

3.3 Reguläre Grammatik für k-Kellerklassen

Situationen $[X \to x \bullet ty\ ;\ \omega]$ als Nichtterminale,

- Übergänge: mit $t \in V$ in Folgezustand
  $P' = \{[X \to x \bullet ty\ ;\ \omega] \to t\ [X \to xt \bullet y\ ;\ \omega] \mid t \in V\}$
- mit $B \in N$ im Keller spontan Unterproduktion $B \to \nu$ beginnen
  $P'' = \{[X \to x \bullet By\ ;\ \omega] \to [B \to \bullet\nu\ ;\ \tau] \mid B \to \nu \in P, \tau \in \mathrm{Anf}_k(y\omega)\}$
- mit $t \in V$ in Endzustand für K_0^k, wenn Vorschau stimmt
  $P_0 = \{[X \to x \bullet y\ ;\ \omega] \to \&\tau \mid y \neq \varepsilon, \tau \in \mathrm{Anf}_k'(y\omega)\}$
- von $[X_p \to x_p \bullet\ ;\ \omega]$ in Endzustand für K_p^k, wenn Vorschau stimmt
  $P_p = \{[X_p \to x_p \bullet\ ;\ \omega] \to \&\omega\}, p = 1,\ldots, n$

Produktionen für G_i^k: $P' \cup P'' \cup P_i$, $i=0,\ldots,n$, also alle Grammatiken gleich außer Abschluß einer Ableitung (Übergang Endzustand)

3.3 Nicht-deterministischer, endlicher Automat

$Z \to S,\ S \to Ac,\ A \to AB,\ A \to B,\ B \to aAb,\ B \to ab$

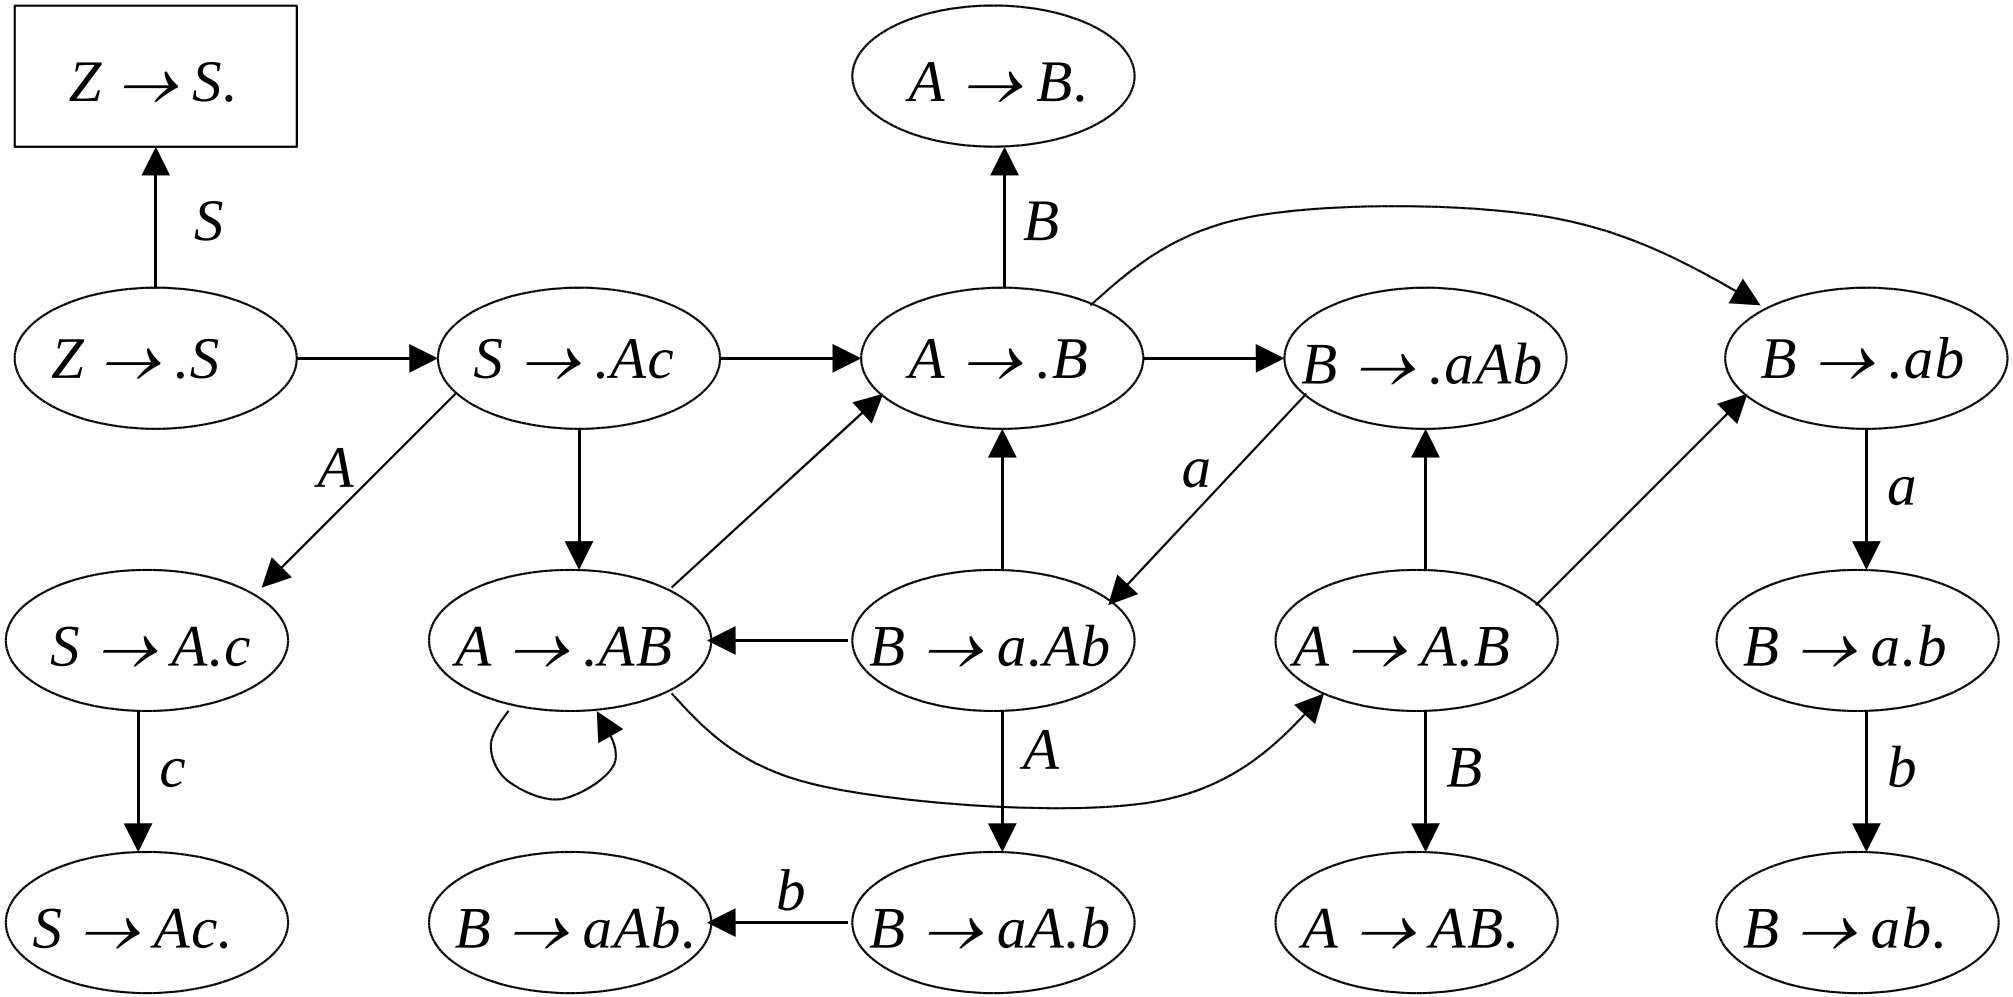

3.3 Charakteristischer Automat

$Z \to S,\ S \to Ac,\ A \to AB,\ A \to B,\ B \to aAb,\ B \to ab$

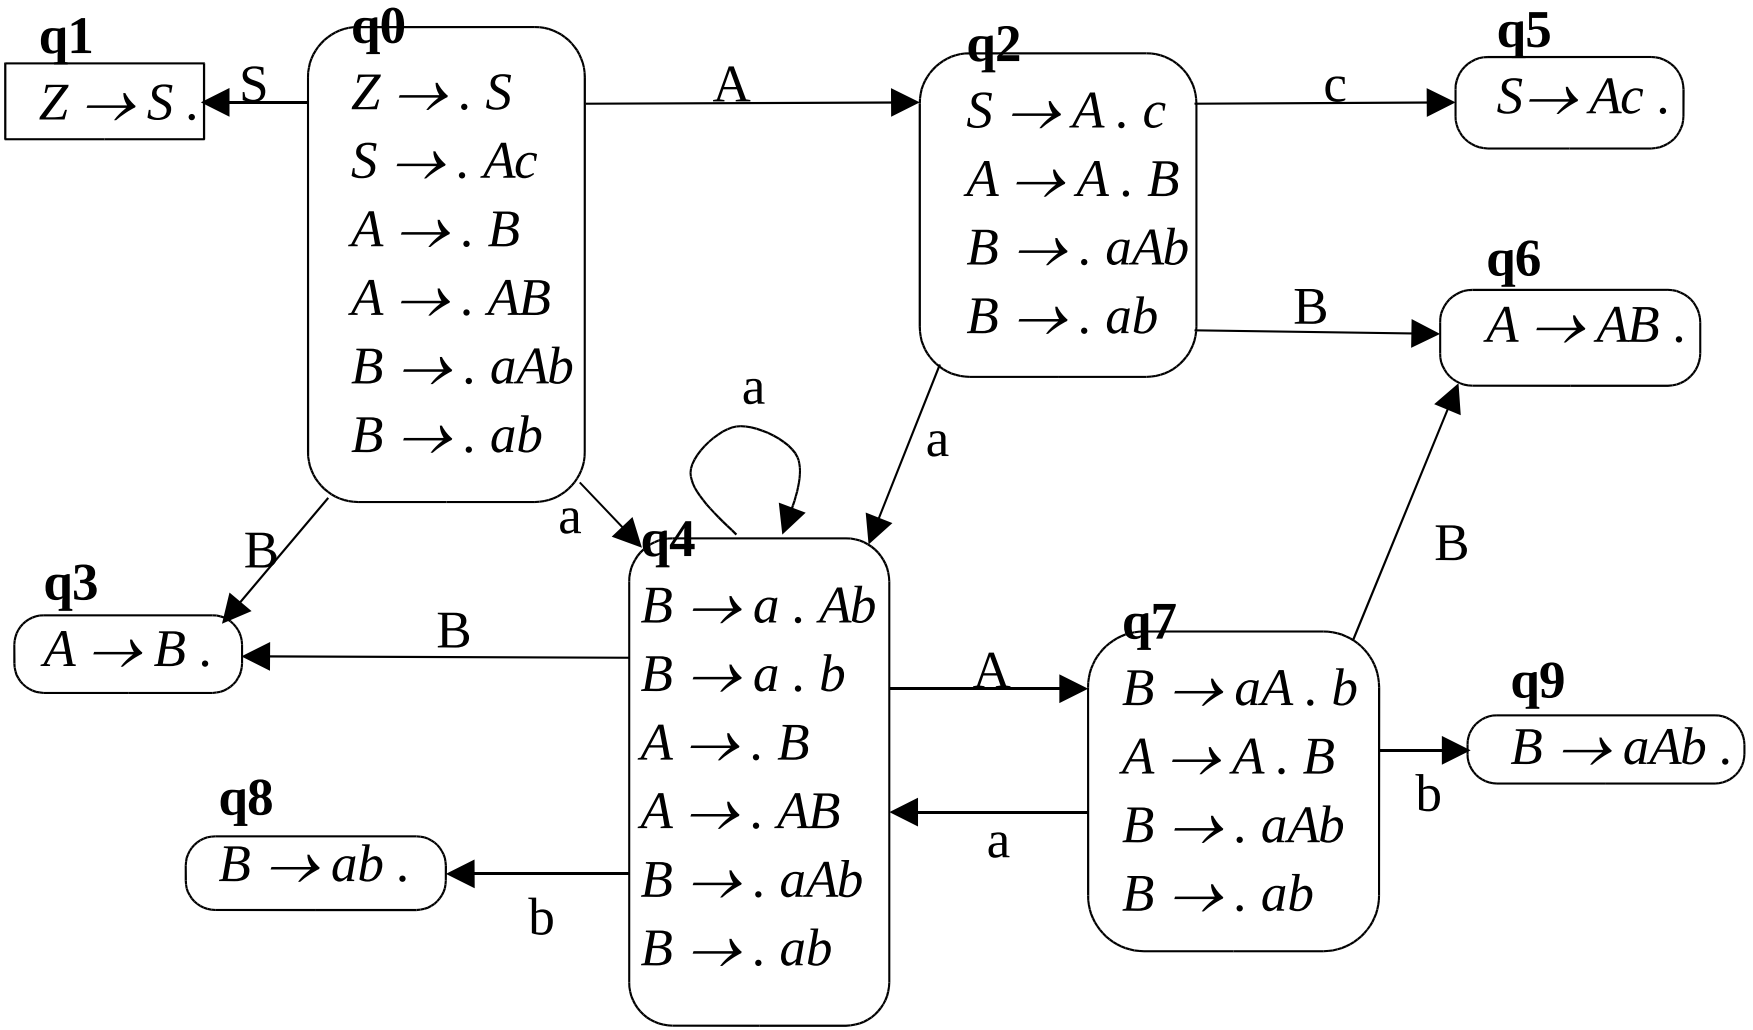

3.3 Charakteristischer Automat als Kellerautomat

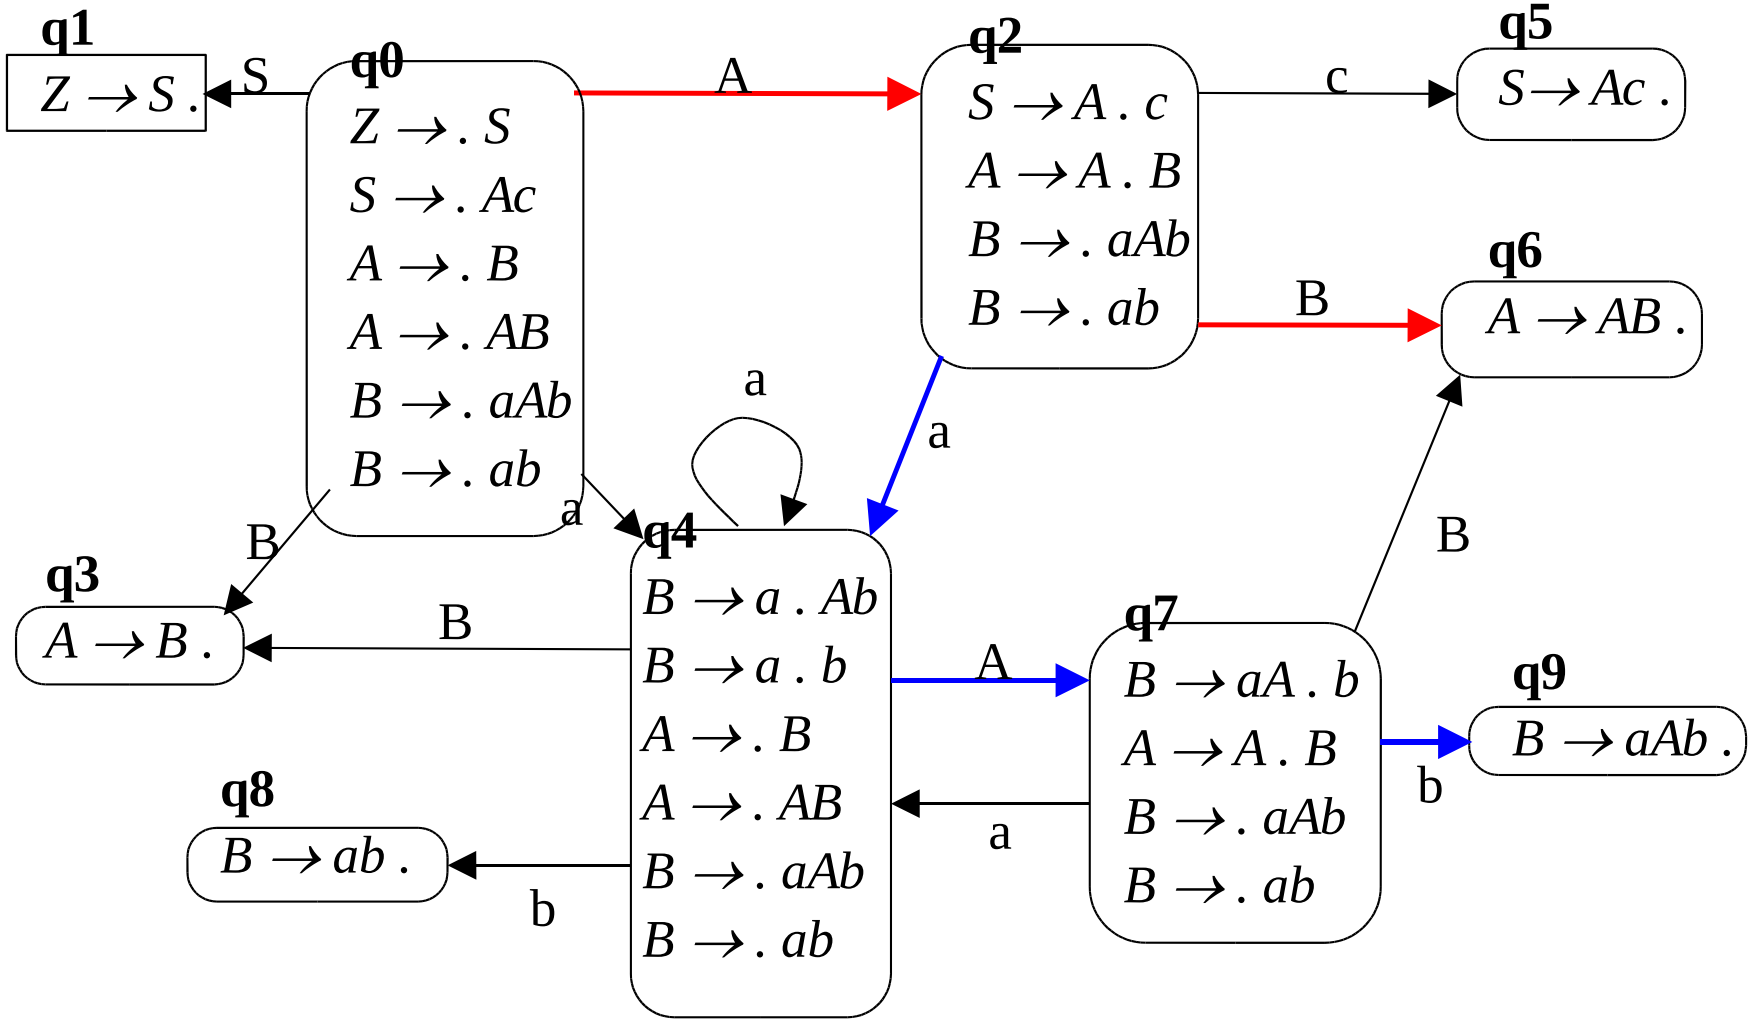

Ableitung $Z \Rightarrow S \Rightarrow AB \Rightarrow AaAb \Rightarrow \ldots$ Bei Reduktion $B \to aAb$ in q9 gehe $3 = |aAb|$ Schritte zurück und dann einen Schritt nach q6 mit B

3.3 Konstruktion des charakteristischen Automaten

Entscheidungsverfahren nach Büchi:

- Aus den Grammatiken deterministische endliche Automaten machen:
  Anwendung der Teilmengenkonstruktion und Hüllenbildung:
  - Transitive Hülle eines Nichtterminals:
    $H(A) = \{A\} \cup \{B \mid C \to B \in P, C \in H(A)\}$
  - angewandt auf Mengen M von Situationen:
    $H(M) = M \cup \{[B \to \bullet\, b;\, t] \mid \exists [X \to \mu \bullet\, B\, \gamma;\, \omega] \in H(M);\, B \to \beta \in P,\, t \in \mathrm{Anf}_k(\gamma\omega)\}$
- Kellerinhalt und Vorschau durch alle Automaten schicken
- Endzustand bestimmt, welche Aktion (Schift, Reduktion mit Produktion p) ausgeführt wird, falls Kellerklassen disjunkt

Erkenntnis: alle Automaten sind gleich außer Übergang in Endzustand, also nur ein charakteristischer Automat mit verschiedenen Endzuständen

3.3 Charakteristischer Automat als LR-Kellerautomat

- charakteristischen Automaten mit Keller ergänzen
  - statt Zeichen $t \in V$ Zustände, d.h. Mengen von Situationen, als Kellersymbole
- oberstes Kellersymbol ist laufender Zustand
- Beginn mit $H(\{[Z \rightarrow \bullet\ S;\ \#]\})$
- Übergang in Endzustand für Schiften mit Schiften der Folgesituation in den Keller zusammenlegen, d.h. die Endzustände für $K_0{}^k$ streichen.

  Folgezustand von q bei Zeichen t:
  - $basis(q,t) = \{[X \rightarrow \mu t \bullet \gamma;\ \Omega] \mid [X \rightarrow \mu \bullet t\gamma\ ;\Omega] \in q\}$.
  - $next(q,t)=H(basis\ (q,t))$, wenn $basis(q,t) \neq \emptyset$
- Nach Erreichen Endzustand für $K_p{}^k$, $p=1,...,n$, $p: B \rightarrow x_1...x_m$: m Situationen aus Keller streichen, Zustandsübergang mit B
- spart die Ableitung des Kelleranfangs, die unverändert ist

3.3 Übergangsfunktion des LR-Automaten

- Für $v \in V$:

$$f(q, v) = \begin{cases} next(q,v), & \text{wenn } basis(q, v) \neq \emptyset, \text{ (schiften)} \\ X \to x, & \text{wenn } [X \to x \bullet;\Omega] \in q, v \in \Omega, \text{ (reduzieren)} \\ \text{HALT}, & \text{wenn } v = \# \text{ und } [Z \to S \bullet;\{\#\}] \in q \\ \text{FEHLER}, & \text{sonst} \end{cases}$$

- Zustand q heißt inadäquat, wenn Übergangsfunktion $f(q, v)$ für irgendein v nicht eindeutig definiert. Zwei Möglichkeiten:
- Schift-Reduktionskonflikt: sowohl schiften als auch reduzieren möglich
- Reduktions-Reduktionskonflikt: Reduktion mit zwei verschiedenen Produktionen möglich
- Eine kfG G ist genau dann $LR(k)$-Grammatik, wenn der charakteristische Automat keine inadäquaten Zustände besitzt.

3.3 Vereinfachter charakteristischer Automat, $k = 1$

(1) $Z \rightarrow A$ (2) $A \rightarrow A + F$ (5) $F \rightarrow (A)$

(3) $A \rightarrow F$ (4) $F \rightarrow bez$

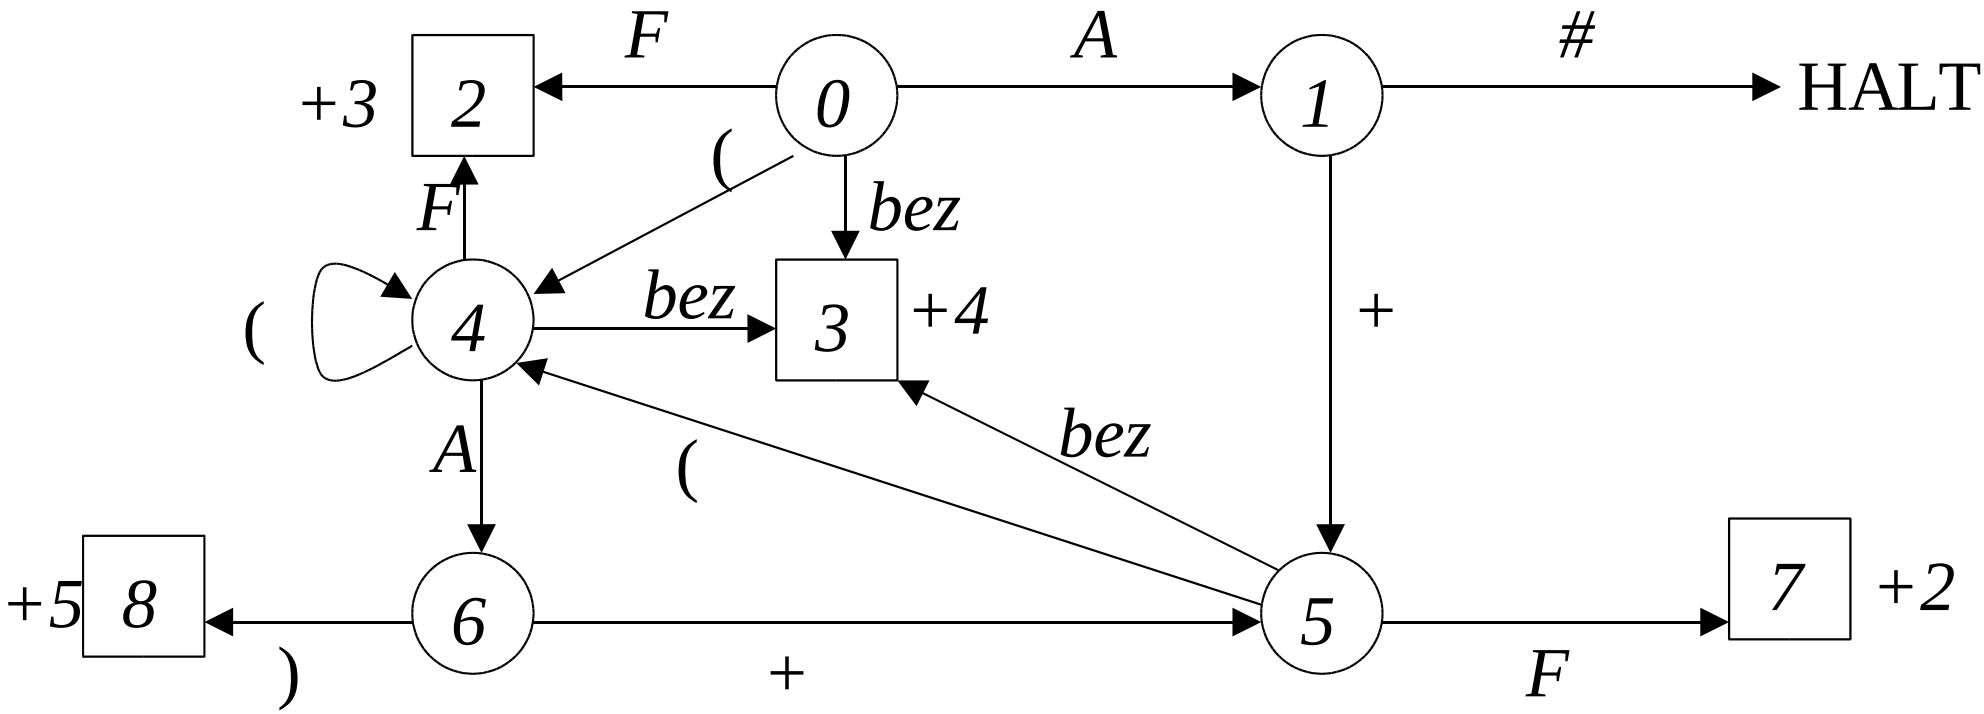

vereinfacht: Zustände mit unterschiedlicher Vorschau zusammengelegt

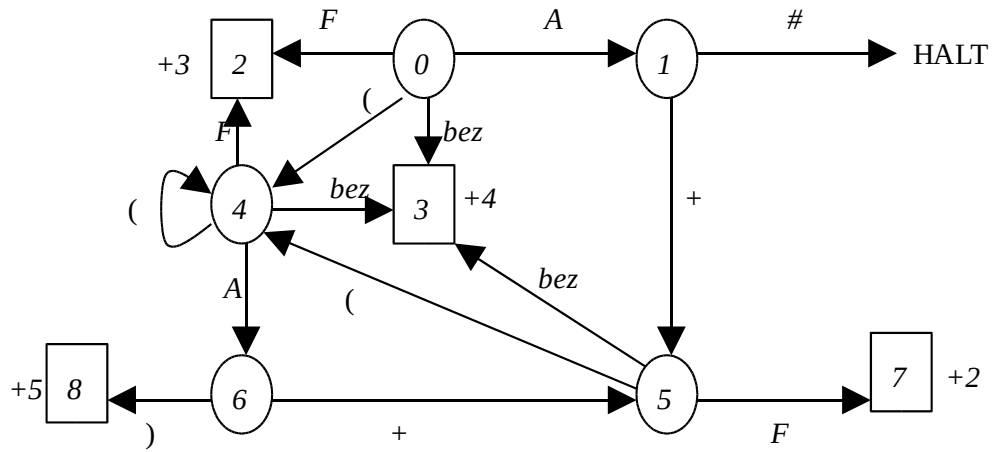

Keller	Erkannt	Eingabe	Bemerkungen
0		$a+(b+c)\#$	
0 3	a	$+(b+c)\#$	Red. $F \rightarrow bez$
0	F	$+(b+c)\#$	
0 2	F	$+(b+c)\#$	Red. $A \rightarrow F$
0	A	$+(b+c)\#$	
0 1	A	$+(b+c)\#$	
0 1 5	$A+$	$(b+c)\#$	
0 1 5 4	$A+($	$b+c)\#$	
0 1 5 4 3	$A+(b$	$+c)\#$	Reduktion $F \rightarrow bez$
0 1 5 4	$A+(F$	$+c)\#$	
0 1 5 4 2	$A+(F$	$+c)\#$	Reduktion $A \rightarrow F$
0 1 5 4	$A+(A$	$+c)\#$	
0 1 5 4 6	$A+(A$	$+c)\#$	
0 1 5 4 6 5	$A+(A+$	$c)\#$	
0 1 5 4 6 5 3	$A+(A+c$	$)\#$	Reduktion $F \rightarrow bez$
0 1 5 4 6 5	$A+(A+F$	$)\#$	
0 1 5 4 6 5 7	$A+(A+F$	$)\#$	Reduktion $A \rightarrow A+F$
0 1 5 4	$A+(A$	$)\#$	
0 1 5 4 6	$A+(A$	$)\#$	
0 1 5 4 6 8	$A+(A)$	$\#$	Reduktion $F \rightarrow (A)$
0 1 5	$A+F$	$\#$	
0 1 5 7	$A+F$	$\#$	Reduktion $A \rightarrow A+F$
0	A	$\#$	
0 1	A	$\#$	
0 1	$A\#$		HALT

rot: nach Kürzen des Kellers

3.3 Konstruktion $LR(1)$ Kellerautomat

1. Initial $Q = \{q_0\}$, mit $q_0 = H(\{[Z \to \bullet S;\#]\})$.
2. Sei $q \in Q$ noch nicht betrachtet. Führe Schritte (3)-(5) für jedes $v \in V$ aus.
3. Wenn $basis(q,v) \neq \emptyset$, setze $next(q,v)=H(basis\ (q, v))$. $Q:= Q \cup \{q' = next\ (q,v)\ \}$.
4. Wenn $basis(q,v) \neq \emptyset$ und $v \in T$, für $k \leq 1$ setze $R:= R \cup \{qv \to qq'\}$, sonst setze
   $R:= R \cup \{qvt \to qq't \mid [X \to x \bullet v\gamma\ ;\ \omega] \in q,\ t \in \mathrm{Anf}_{k-1}(\gamma\ \omega)\}$.
5. Wiederhole Schritt (2) bis alle $q \in Q$ betrachtet sind.
6. Für jedes $q \in Q$ und $[X \to x \bullet\ ;\ \omega] \in q$ mit $x = x_1 \ldots x_n$ setze

$$R := R \cup \{\ q_1 \ldots q_n q\omega \to q_1 q'\omega\ \mid$$
$$[X \to x \bullet\ ;\omega] \in q_1,\ q_{i+1} = next(q_i, x_i)\ \ (i = 1, \ldots, n\text{-}1),$$
$$q = next(q_n, x_n),\ q' = next(q_1, X)\ \}$$

3.3 Beispiel: $LR(2)$ Kellerautomat

Grammatik	Zustände		Übergang	Zustände		Übergang
(1) $Z \rightarrow X$	q_0:	$[Z \rightarrow \bullet X; \#]$	b,c	q_4:	$[Y \rightarrow c \bullet; \#]$	red #
(2) $X \rightarrow Y$		$[X \rightarrow \bullet Y; \#]$			$[Y \rightarrow c \bullet a; \#]$	$a\#$
(3) $X \rightarrow bYa$		$[X \rightarrow \bullet bYa; \#]$		q_5:	$[X \rightarrow bY \bullet a; \#]$	$a\#$
(4) $Y \rightarrow c$		$[Y \rightarrow \bullet c; \#]$		q_6:	$[Y \rightarrow c \bullet; a\#]$	red $a\#$
(5) $Y \rightarrow ca$		$[Y \rightarrow \bullet ca; \#]$			$[Y \rightarrow c \bullet a; a\#]$	aa
	q_1:	$[Z \rightarrow X \bullet; \#]$	HALT	q_7:	$[Y \rightarrow ca \bullet; \#]$	red #
	q_2:	$[X \rightarrow Y \bullet; \#]$	red #	q_8:	$[X \rightarrow bYa \bullet; \#]$	red #
	q_3:	$[X \rightarrow b \bullet Ya; \#]$	c	q_9:	$[Y \rightarrow ca \bullet; a\#]$	red $a\#$
		$[Y \rightarrow \bullet c; a\#]$				
		$[Y \rightarrow \bullet ca; a\#]$				

Regeln $R = \{ q_0bc \rightarrow q_0q_3c,\ q_0c\# \rightarrow q_0q_4\#,\ q_0ca \rightarrow q_0q_4a, q_3ca \rightarrow q_3q_6a, q_4a\# \rightarrow q_4q_7\#,\ q_5a\# \rightarrow q_5q_8\#,$
$q_6aa \rightarrow q_6q_9a,\ q_0q_2\# \rightarrow q_0q_1\#, q_0q_4\# \rightarrow q_0q_2\#, q_3q_6a\# \rightarrow q_3q_5a\#,\ q_3q_4q_7\# \rightarrow q_0q_2\#,$
$q_0q_3q_5q_8\# \rightarrow q_0q_1\#, q_3q_6q_9\# \rightarrow q_3q_5\# \}$

3.3 $SLR(k)$-Grammatiken

Problem: Wegen Unterscheidung verschiedener Rechtskontexte hat der $LR(k)$-Automat bereits für k=1 sehr viele Zustände, verglichen mit LR(0)
Beispiel: für Ausdrucksgrammatik mit „+" 17 statt 9 für k=0.

$SLR(k)$-Grammatik (*simple* LR(k)): Eine Grammatik heißt $SLR(k)$, wenn sie LR(0) ist oder die modifizierte Übergangsfunktion

$$f(q, v) = \begin{cases} next(q,v) & \text{wenn } basis(q,v) \neq \emptyset, \text{ (schiften)} \\ X \to x & \text{wenn } [X \to x \bullet] \in q,\ v \in \text{Folge}_k(X), \text{ (reduzieren)} \\ \text{HALT} & \text{wenn } v = \# \text{ und } [Z \to S \bullet] \in q \\ \text{FEHLER} & \text{sonst} \end{cases}$$

keine inadäquaten Zustände liefert.
Problem: SLR(k) genügt für Ausdrucksgrammatiken, berücksichtigt aber Rechtskontext zu wenig.
Achtung: Keine Analogie zu LL vs. SLL (LL ohne Keller).

3.3.1 nicht SLR, aber LALR

(1) $Z \rightarrow A$ (2) $A \rightarrow aBb$ (3) $A \rightarrow adc$

(4) $A \rightarrow bBc$ (5) $A \rightarrow bdb$ (6) $B \rightarrow d$

$Folge_1(B) = \{b,c\}$

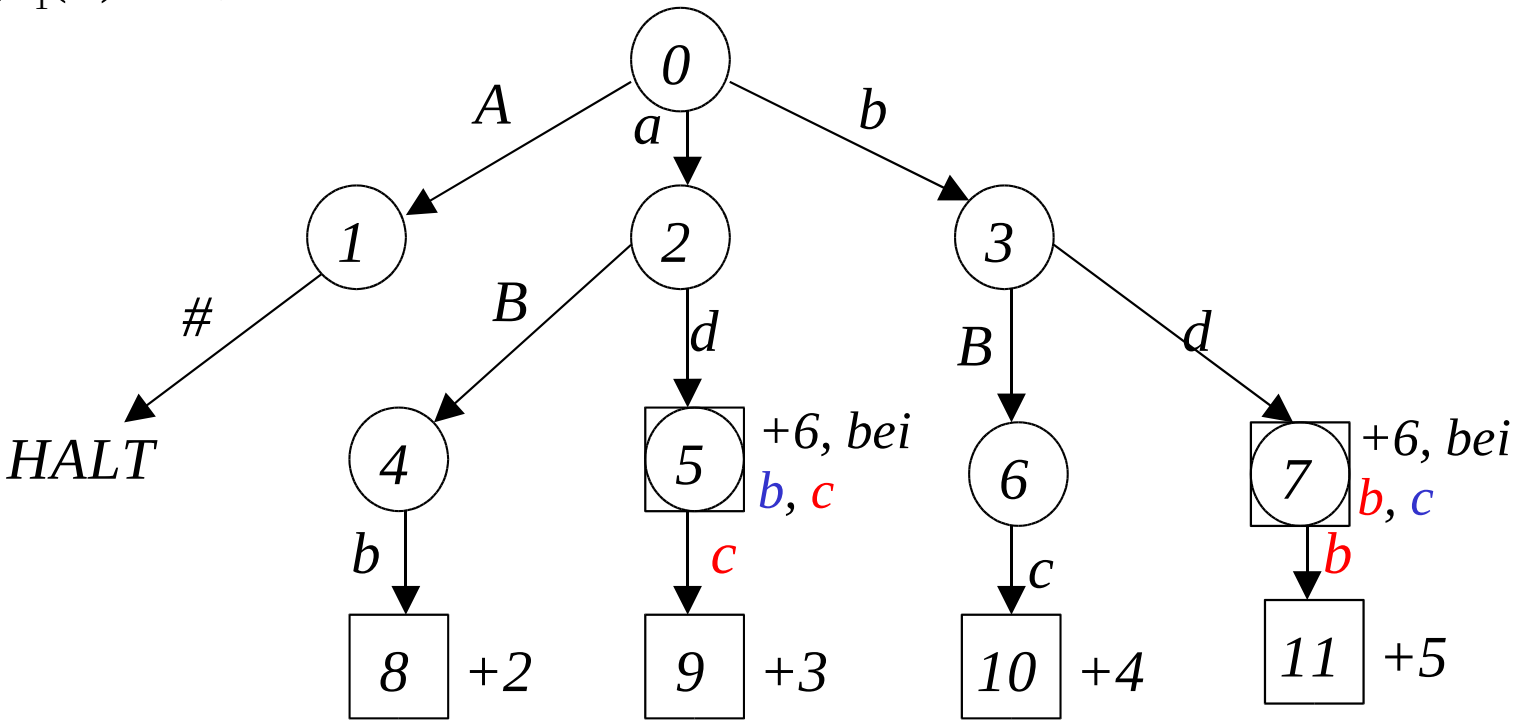

praktisches Beispiel (Algol 60): Unterscheide ;abc: und [abc:

Kapitel 3: Zerteilung

1. Theoretische Grundlage: Kontextfreie Grammatiken
   - Notation
   - Konkrete und abstrakte Syntax
   - Rekursiver Abstieg
   - Kellerautomaten
   - Elimination von Linksrekursion und ε-Produktionen
   - Systematische Zerteilerkonstruktion: LL-, LR-Grammatiken
2. LL- und SLL-Grammatiken
3. LR-, SLR-Grammatiken
   - 3.1 LALR-Konstruktion
   - 3.2 Optimierungen und Komplexität
4. Fehlerbehandlung

3.3.1 LALR(*k*)-Grammatiken

Sei $\text{kern}(q) = \{[X \to \mu \bullet \gamma] \mid [X \to \mu \bullet \gamma\ ;\Omega] \in q\}$.

- Eine Grammatik heißt LALR(*k*) (*look ahead* LR(*k*)), wenn es keine inadäquaten Zustände gibt, falls man im LR(*k*)-Automaten alle Zustände q,q' mit $\text{kern}(q) = \text{kern}(q')$ zusammenlegt.
- Satz: Jeder SLR(*k*)- oder LALR(*k*)-Automat hat die gleiche Anzahl von Zuständen wie der LR(0)-Automat zur gleichen Grammatik.
- Der Unterschied zwischen LALR(k) und LR(k) ist praktisch unerheblich. Alle verbreiteten LR-Zerteilergeneratoren (*yacc, pgs, lalr, bison,* ...) konstruieren LALR(1)-Automaten.

3.3.1 Konstruktion $LALR(1)$ Kellerautomat

Erweitern von Zuständen mit gleichem Kern:

$erweitere(q,q') = \{[\ldots;\Omega \cup \Delta] | [\ldots;\Omega] \in q, [\ldots;\Delta] \in q'\}$.

1. Initial $Q = \{q_0\}$, mit $q_0 = H(\{[Z \rightarrow \bullet S;\#]\})$.
2. Sei $q \in Q$ noch nicht betrachtet. Für alle $v \in V$ führe Schritt (3) aus.
3. Wenn $basis(q,v) \neq \emptyset$, berechne $\underline{q} = H(basis(q,v))$.

3a. Wenn es ein $q' \in Q$ mit $kern(q') = kern(\underline{q})$ gibt, so setze

$next(q,v) = erweitere(q, q')$; wenn $next(q,v) \neq q'$, ersetze q' durch $next(q,v)$ und markiere q' als nicht betrachtet.

3b. Wenn es kein $q' \in Q$ *mit* $kern(q') = kern(\underline{q})$ gibt, so setze

$next(q,v) = \underline{q}$, nimm $next(q,v)$ in Q auf und markiere es als nicht betrachtet.

4. Wiederhole Schritt (2) bis alle $q \in Q$ betrachtet sind.
5. Für jedes $q \in Q$ und $v \in V$, berechne $f(q,v)$.

3.3.1 Wiederholung Übergangsfunktion

Für $v \in V$:

$$f(q, v) = \begin{cases} next(q,v), & \text{wenn } basis(q,v) \neq \emptyset, \quad \text{(schiften)} \\ X \rightarrow x, & \text{wenn } [X \rightarrow x \bullet;\Omega] \in q,\ v \in \Omega, \quad \text{(reduzieren)} \\ \text{HALT}, & \text{wenn } v = \# \text{ und } [Z \rightarrow S \bullet;\{\#\}] \in q \\ \text{FEHLER}, & \text{sonst} \end{cases}$$

3.3.1 Konstruktion am Beispiel

(1) $Z \rightarrow A$

(2) $A \rightarrow A + T$

(3) $A \rightarrow T$

(4) $T \rightarrow T * F$

(5) $T \rightarrow F$

(6) $F \rightarrow bez$

(7) $F \rightarrow (A)$

3.3.1 Anfangszustand

Zustand q_0

Basis	Hülle
$[Z \to \bullet A;\{\#\}]$	
	$[A \to \bullet A+T;\{+\#\}]$
	$[A \to \bullet T;\{+\#\}]$
	$[T \to \bullet T*F;\{*+\#\}]$
	$[T \to \bullet F;\{*+\#\}]$
	$[F \to \bullet bez;\{*+\#\}]$
	$[F \to \bullet(A);\{*+\#\}]$

Übergang

mit	in neue Basis
A	$\{[Z \to A\bullet;\{\#\}]$
	$[A \to A\bullet+T;\{+\#\}]\}$
T	$\{[A \to T\bullet;\{+\#\}]$
	$[T \to T\bullet*F;\{*+\#\}]\}$
F	$\{[T \to F\bullet;\{*+\#\}]\}$
bez	$\{[F \to bez\bullet;\{*+\#\}]\}$
$($	$\{[F \to (\bullet A);\{*+\#\}]\}$

3.3.1 Zustand 1

Zustand q_1

Basis	Hülle	Übergang mit	in neue Basis
$[Z \rightarrow A\bullet;\{\#\}]$		#	Reduktion, HALT
$[A \rightarrow A\bullet + T;\{+\#\}]$		+	$\{[A \rightarrow A + \bullet T;\{+\#\}]\}$

3.3.1 Zustand 2

Zustand q_2

Basis	Hülle
$[A \rightarrow T\bullet;\{+\#\}]$	
$[T \rightarrow T\bullet * F;\{*+\#\}]$	

Übergang

mit	in neue Basis
Reduktion bei +,#	
*	$\{[T \rightarrow T*\bullet F;\{*+\#\}]\}$

3.3.1 Zustand 3

Zustand q_3

Basis	Hülle	Übergang mit	in neue Basis
$[T \rightarrow F\bullet;\{*+\#\}]$		Reduktion bei *,+,#	

3.3.1 Zustand 4

Zustand q_4

Basis	Hülle	Übergang mit	in neue Basis
$[F \rightarrow bez\bullet;\{*+\#\}]$		Reduktion bei *,+,#	

3.3.1 Zustand 5

Zustand q_5

Basis	Hülle	Übergang mit	in neue Basis
$[F \rightarrow (\bullet A);\{*+\#\}]$		A	$\{[F \rightarrow (A\bullet);\{*+\#\}]$
	$[A \rightarrow \bullet A+T;\{+)\}]$		$[A \rightarrow A\bullet+T;\{+)\}]\}$
	$[A \rightarrow \bullet T;\{+)\}]$	T	$\{[A \rightarrow T\bullet;\{+)\}]$
	$[T \rightarrow \bullet T*F;\{*+)\}]$		$[T \rightarrow T\bullet*F;\{*+)\}]\}$
	$[T \rightarrow \bullet F;\{*+)\}]$	F	$\{[T \rightarrow F\bullet;\{*+)\}]\}$
	$[F \rightarrow \bullet bez;\{*+)\}]$	bez	$\{[F \rightarrow bez\bullet;\{*+)\}]\}$
	$[F \rightarrow \bullet (A);\{*+)\}]$	$($	$\{[F \rightarrow (\bullet A);\{*+)\}]\}$

Die Hülle blau gekennzeichneter Basen erweitert vorhandene Zustände.

3.3.1 Erweitere Zustand 2

Zustand q_2

Basis	Hülle	Übergang mit	in neue Basis
$[A \rightarrow T\bullet;\{+\#\}]$		Reduktion bei +,#	
$[T \rightarrow T\bullet *F;\{*+\#\}]$		*	$\{[T \rightarrow T*\bullet F;\{*+\#\}]\}$
$[A \rightarrow T\bullet;\{+)\}]$			
$[T \rightarrow T\bullet *F;\{*+)\}]$			

Neuer Zustand q_2

$[A \rightarrow T\bullet;\{+\#)\}]$		Reduktion bei +,#,)	
$[T \rightarrow T\bullet *F;\{*+\#)\}]$		*	$\{[T \rightarrow T*\bullet F;\{*+\#)\}]\}$

3.3.1 Erweitere Zustand 3

Zustand q_3

Übergang

Basis	Hülle	mit	in neue Basis
$[T \rightarrow F\bullet;\{*+\#\}]$		Reduktion bei *,+,#	
$[T \rightarrow F\bullet;\{*+)\}]$			

Neuer Zustand q_3

$[T \rightarrow F\bullet;\{*+\#)\}]$	Reduktion bei *,+,#,)

3.3.1 Erweitere Zustand 4

Zustand q_4

Basis	Hülle	Übergang mit	in neue Basis
$[F \rightarrow bez\bullet;\{*+\#\}]$		Reduktion bei *,+,#	
$[F \rightarrow bez\bullet;\{*+)\}]$			

Neuer Zustand q_4

$[F \rightarrow bez\bullet;\{*+\#)\}]$		Reduktion bei *,+,#,)	

3.3.1 Erweitere Zustand 5

Zustand q_5

Basis	Hülle	Übergang mit	in neue Basis
$[F \to (\bullet A);\{*+\#\}]$		A	$\{[F \to (A\bullet);\{*+\#\}]$
	$[A \to \bullet A+T;\{+)\}]$		$[A \to A\bullet+T;\{+)\}]\}$
	$[A \to \bullet T;\{+)\}]$	T	$\{[A \to T\bullet;\{+)\}]$
	$[T \to \bullet T*F;\{*+)\}]$		$[T \to T\bullet*F;\{*+)\}]\}$
	$[T \to \bullet F;\{*+)\}]$	F	$\{[T \to F\bullet;\{*+)\}]\}$
	$[F \to \bullet bez;\{*+)\}]$	bez	$\{[F \to bez\bullet;\{*+)\}]\}$
	$[F \to \bullet(A);\{*+)\}]$	$($	$\{[F \to (\bullet A);\{*+)\}]\}$

$[F \to (\bullet A);\{*+)\}]$

Neuer Zustand enthält) in der Folgemenge:

$[F \to (\bullet A);\{*+\#\ )\}]$	A	$\{[F \to (A\bullet);\{*+\#)\}]$
$[A \to \bullet A+T;\{+)\}]$		$[A \to A\bullet+T;\{+)\}]\}$
...	...	

3.3.1 Zustand 6

Zustand q_6

Basis	Hülle	mit	Übergang in neue Basis
$[A \rightarrow A+\bullet T;\{+\#\}]$		T	$\{[A \rightarrow A+T\bullet;\{+\#\}]\}$
	$[T \rightarrow \bullet T*F;\{*+\#\}]$		$[T \rightarrow T\bullet *F;\{*+\#\}]\}$
	$[T \rightarrow \bullet F;\{*+\#\}]$	F	$\{[T \rightarrow F\bullet;\{*+\#\}]\}$
	$[F \rightarrow \bullet bez;\{*+\#\}]$	bez	$\{[F \rightarrow bez\ \bullet;\{*+\#\}]\}$
	$[F \rightarrow \bullet(A);\{*+\#\}]$	(	$\{[F \rightarrow (\bullet A);\{*+\#\}]\}$

Die Hülle rot gekennzeichneter Basen ergibt keine Erweiterung vorhandener Zustände.

3.3.1 Zustand 7

Zustand q_7

Basis	Hülle	mit	Übergang in neue Basis
$[T \rightarrow T* \bullet F;\{*+\#)\}]$		F	$\{[T \rightarrow T*F\bullet;\{*+\#)\}]\}$
	$[F \rightarrow \bullet bez;\{*+\#)\}]$	bez	$\{[F \rightarrow bez \bullet;\{*+\#)\}]\}$
	$[F \rightarrow \bullet(A);\{*+\#)\}]$	$($	$\{[F \rightarrow (\bullet A);\{*+\#)\}]\}$

3.3.1 Zustand 8

Zustand q_8

Basis	Hülle	mit	Übergang in neue Basis
$[F \rightarrow (A\bullet);\{*+\#)\}]$		)	$\{[F \rightarrow (A)\bullet;\{*+\#)\}]\}$
$[A \rightarrow A\bullet+T;\{+)\}]$		+	$\{[A \rightarrow A+\bullet T;\{+)\}]\}$

3.3.1 Erweitere Zustand 6

Zustand q_6

Basis	Hülle	mit	Übergang in neue Basis
$[A \to A+\bullet T;\{+\#\}]$		T	$\{[A \to A+T\bullet;\{+\#\}]\}$
	$[T \to \bullet T*F;\{*+\#\}]$		$[T \to T\bullet *F;\{*+\#\}]\}$
	$[T \to \bullet F;\{*+\#\}]$	F	$\{[T \to F\bullet;\{*+\#\}]\}$
	$[F \to \bullet bez;\{*+\#\}]$	bez	$\{[F \to bez\ \bullet;\{*+\#\}]\}$
	$[F \to \bullet(A);\{*+\#\}]$	(	$\{[F \to (\bullet A);\{*+\#\}]\}$

$[A \to A+\bullet T;\{+)\}]$

Neuer Zustand enthält) in der Folgemenge:

$[A \to A+\bullet T;\{+\#\ )\}]$		T	$\{[A \to A+T\bullet;\{+\#)\}]\}$
	$[T \to \bullet T*F;\{*+\#\ )\}]$		$[T \to T\bullet *F;\{*+\#)\}]\}$
	$[T \to \bullet F;\{*+\#)\}]$	F	$\{[T \to F\bullet;\{*+\#)\}]\}$
	$[F \to \bullet bez;\{*+\#)\}]$	bez	$\{[F \to bez\ \bullet;\{*+\#)\}]\}$
	$[F \to \bullet(A);\{*+\#)\}]$	(	$\{[F \to (\bullet A);\{*+\#)\}]\}$

3.3.1 Zustand 9

Zustand q_9			Übergang
Basis	Hülle	mit	in neue Basis
$[A \rightarrow A + T \bullet ; \{+\#)\}]$			Reduktion bei +,#,)
$[T \rightarrow T \bullet * F ; \{*+\#)\}]$		*	$\{[T \rightarrow T * \bullet F ; \{*+\#)\}]\}$

3.3.1 Zustand 10

Zustand q_{10}

Basis	Hülle	mit	Übergang in neue Basis
$[T \rightarrow T*F\bullet;\{*+\#)\}]$			Reduktion bei *,+,#,)

3.3.1 Zustand 11

Zustand q_{11}

Basis	Hülle	mit	Übergang in neue Basis
$[F \rightarrow (A)\bullet;\{*+\#)\}]$			Reduktion bei *,+,#,)

3.3.1 Übergangsfunktionen

q_0 $f(q_0,A)=q_1$ $f(q_0,T)=q_2$ $f(q_0,F)=q_3$ $f(q_0,bez)=q_4$ $f(q_0,(\ )=q_5$

q_1 $f(q_1,\#)$ =HALT $f(q_1,+)=q_6$

q_2 $f(q_2,+\#)\ )$ = Reduziere$(A\rightarrow T)$ $f(q_2,*)=q_7$

q_3 $f(q_3,*+\#)\ )$ = Reduziere$(T\rightarrow F)$

q_4 $f(q_4,*+\#)\ )$ = Reduziere$(F\rightarrow bez)$

q_5 $f(q_5,A)=q_8$ $f(q_5,T)=q_2$ $f(q_5,F)=q_3$ $f(q_5,bez)=q_4$ $f(q_5,(\ )=q_5$

q_6 $f(q_6,T)=q_9$ $f(q_6,F)=q_3$ $f(q_6,bez)=q_4$ $f(q_6,(\ )=q_5$

q_7 $f(q_7,F)=q_{10}$ $f(q_7,bez)=q_4$ $f(q_6,(\ )=q_5$

q_8 $f(q_8,)\ )=q_{11}$ $f(q_9,+)=q_6$

q_9 $f(q_9,+\#)\ )$ = Reduziere$(A\rightarrow A+T)$ $f(q_9,*)=q_7$

q_{10} $f(q_{10},*+\#)\ )$= Reduziere$(T\rightarrow T*F)$

q_{11} $f(q_{11},*+\#)\ )$ = Reduziere $(F \rightarrow (A)\ )$

3.3.1 Übergangstabelle

	bez	(	)	+	*	#	*A*	*T*	*F*
0	4	5	-	-	-	-	1	2	3
1	-	-	-	6	-	*			
2	-	-	+3	+3	7	+3			
3	+5	+5	+5	+5	+5	+5			
4	+6	+6	+6	+6	+6	+6			
5	4	5	-	-	-	-	8	2	3
6	4	5	-	-	-	-		9	3
7	4	5	-	-	-	-			10
8	-	-	11	6	-	-			
9	-	-	+2	+2	7	+2			
10	+4	+4	+4	+4	+4	+4			
11	+7	+7	+7	+7	+7	+7			

3.3.1 Fakten und Fragen zu LR

- Automat $qt \to tq,\ t \in T,\ x_1 \ldots x_n q \to Xq,\ X \to x_1 \ldots x_n \in P$ deterministisch machen
  - dazu Reduktionsklassen bestimmen, Kellerklassen ableiten
  - Kellerklassen sind regulär, Produktionen mit Situationen als Nichtterminale
- charakteristischen Automaten herleiten: nicht-deterministischen Automaten in deterministischen überführen (Hüllenbildung)
- LR-Automat zu groß: SLR-Klasse (Vorschau: $\text{Folge}_k(A)$) ungenügend
- LALR: Zustände des LR-Automaten mit gleichem Kern verschmelzen
- SLR- und LALR-Automat hat gleiche Zustandsmenge wie LR(0)-Automat
- Wie lautet die Übergangsfunktion?
- Wie bestimmt man Zustände und Übergänge des LALR(1)-Automaten von Hand?
- Wie korrigiert man Grammatik, wenn es inadäquate Zustände gibt?

3.3.1.1 Beispiele

- Abstrakte Beispiele:
  - http://www.info.uni-karlsruhe.de/~heuzer/grammars.ps
- 1. Grammatik:
  - Zerteiler-Generator: **antlr**
  - LL (k) für $k \geq 0$
  - Quellsprache: Java Spec. 2.0 für `kjc/kaffe`
  - Implementierungssprache: Java
- 2. Grammatik:
  - Zerteiler-Generator: **GNU bison**
  - LALR (1)
  - Quellsprache: Java für GNU `gcj`
  - Implementierungssprache: C

Grammatik 1: antlr, Java

```
// Definition of a Java class
jClassDefinition[int mods]
  returns [JClassDeclaration self = null]
{
  String                          superClass = null;
  CClassType[]                    interfaces = CClassType.EMPTY;
  CParseClassContext context      = new CParseClassContext ();
  TokenReference                  sourceRef  = buildTokenReference    ();
  JavadocComment                  javadoc    = getJavadocComment      ();
  JavaStyleComment[] comments     = getStatementComment    ();
}
:
  "class" ident:IDENT
  superClass = jSuperClassClause[]          // it might have a superclass
  interfaces = jImplementsClause[]          // it might implement some interfaces
  jClassBlock[context]                      // the body of the class
    {
      self = new JClassDeclaration(sourceRef,
                                   mods, ident.getText     (),
                                   superClass,  interfaces,
                                   context.getFields       (),
                                   context.getMethods      (),
                                   context.getInnerClasses (),
                                   context.getBody         (),
                                   javadoc,  comments);
    }
;
```

Grammatik 2: bison, Java

```
/* 19.8.1 Production from §8.1: Class Declaration */
class_declaration:
modifiers CLASS_TK identifier super interfaces
          { create_class ($1, $3, $4, $5); }
class_body
          {;}
|         CLASS_TK identifier super interfaces
          { create_class (0, $2, $3, $4); }
class_body
          {;}
|         modifiers CLASS_TK error      { yyerror ("Missing class name"); RECOVER; }
|         CLASS_TK error                { yyerror ("Missing class name"); RECOVER; }
|         CLASS_TK identifier error
          {
            if (!ctxp->class_err) yyerror ("'{' expected");
            DRECOVER(class1);
          }
|        modifiers CLASS_TK identifier error
        { if (!ctxp->class_err) yyerror ("'{' expected"); RECOVER;}
;

super:
         { $$ = NULL; }
|        EXTENDS_TK class_type          { $$ = $2; }
|        EXTENDS_TK class_type error    {yyerror ("'{' expected"); ctxp->class_err=1;}
|        EXTENDS_TK error
       {yyerror ("Missing super class name"); ctxp->class_err=1;}
;
```

Kapitel 3: Zerteilung

1. Theoretische Grundlage: Kontextfreie Grammatiken
   - Notation
   - Konkrete und abstrakte Syntax
   - Rekursiver Abstieg
   - Kellerautomaten
   - Elimination von Linksrekursion und ε-Produktionen
   - Systematische Zerteilerkonstruktion: LL-, LR-Grammatiken
2. LL- und SLL-Grammatiken
3. LR-, SLR-Grammatiken
   - 3.1 LALR-Konstruktion
   - 3.2 Optimierungen und Komplexität
4. Fehlerbehandlung

3.3.2 Tabellenoptimierung

LR(0)-Reduktionszustand: Zustand, in dem auf jeden Fall reduziert wird
(Kontext unbeachtlich)

LR(0)-Reduktionszustände beseitigen, im vorigen Zustand bereits reduzieren (Schift-Reduktionszustand)

Kettenproduktionen eliminieren

echte und unechte (*don't care*) Fehlerübergange unterscheiden.
Unecht: Übergang kann nie erreicht werden, z.B. alle leeren Übergänge mit Nichtterminalen

Fehlerübergänge ausfaktorisieren in Fehlermatrix F:
$f(q,t)$ = **if** $F[q,t]$ **then** *Fehler* **else** *Eintrag_in_Übergangsmatrix*

Übergangsmatrix komprimieren: leere Übergänge berücksichtigen

Übergangsmatrix weiter komprimieren (Graphfärbung, usw.)

3.3.2 Kettenproduktionen

(1) $Z \rightarrow A$ (2) $A \rightarrow A + T$ (3) $A \rightarrow T$

(4) $T \rightarrow T*bez$ (5) $T \rightarrow bez$

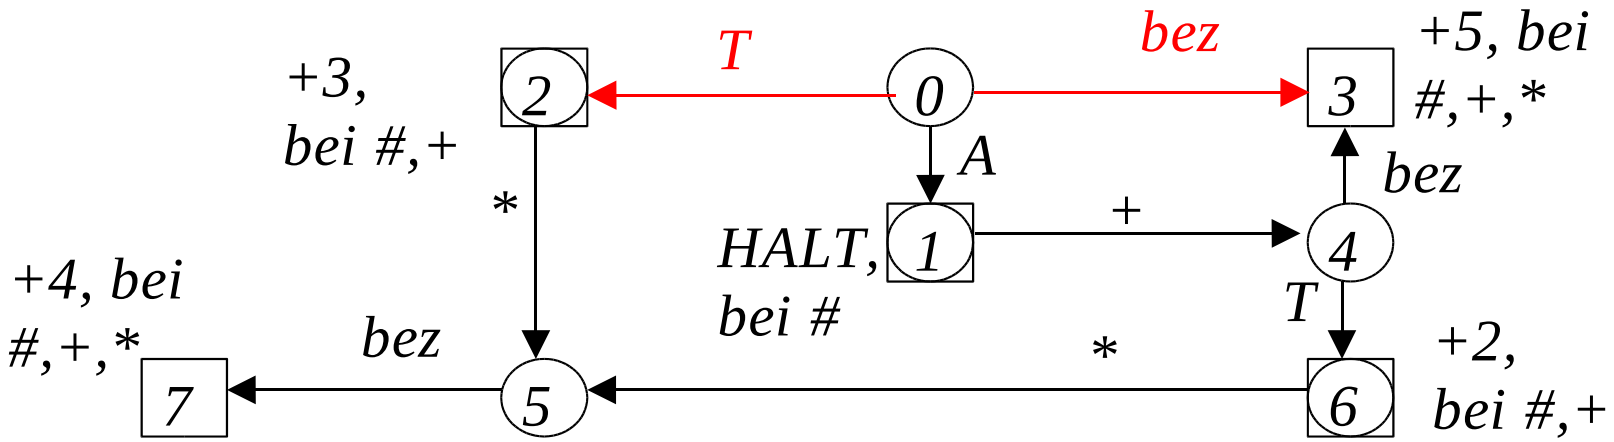

3.3.2 Kettenproduktionen Eliminieren

(1) $Z \rightarrow A$ (2) $A \rightarrow A + T$ (3) $A \rightarrow T$

(4) $T \rightarrow T*bez$ (5) $T \rightarrow bez$

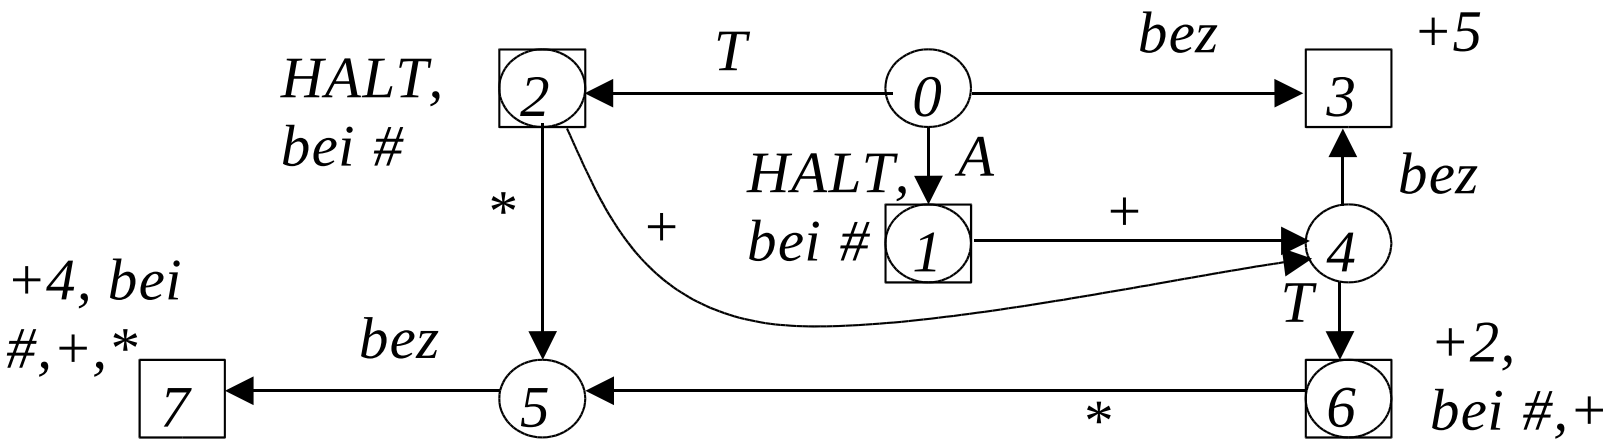

3.3.2 Tabelle mit Schift-Reduktionen, ohne Kettenproduktionen

	bez	(	)	+	*	#	*A*	*T*	*F*
0	-6	3	-	-	-	-	1	2	2
1			-	4		*			
2	-	-	-	4	5	*			
3	-6	3	-	-	-	-	6	7	7
4	-6	3	-	-	-	-		8	8
5	-6	3	-	-	-	-			-4
6			-7	4		-			
7	-	-	-7	4	5	-			
8	-	-	+2	+2	5	+2			

3.3.2 Fehlermatrix und komprimierte Übergangsmatrix

	A	*T,F*
0,1,2	1	2
3	6	7
4		8
5,6,7,8		-4

	bez	(	)	+	*	#
0	*f*	*f*	*t*	*t*	*t*	*t*
1			*t*	*f*		*f*
2	*t*	*t*	*t*	*f*	*f*	*f*
3	*f*	*f*	*t*	*t*	*t*	*t*
4	*f*	*f*	*t*	*t*	*t*	*t*
5	*f*	*f*	*t*	*t*	*t*	*t*
6			*f*	*f*		*t*
7	*t*	*t*	*f*	*f*	*f*	*t*
8	*t*	*t*	*f*	*f*	*f*	*f*

	bez	(	)	+	*	#
0,1,2,3, 4,5,6,7	-6	3	-7	4	5	*
8			+2	+2	5	+2

3.3.2 Tabellengröße

Tabellengröße nach Elimination von Ketten (Beispiel ADA 83):

- 95 Terminale, 252 Nichtterminale
- 540 Zustände (kodiert in 2 *Bytes*)
- Tabellengröße: 374.760 *Bytes*

Reduktion des Platzbedarfes durch:

- Einfache Tabellenkomprimierung
- Elimination der Fehlerübergänge bei Nichtterminalen

Tabellengröße nach diesen Reduktionen 22.584 *Bytes* (ca. 6%)

Quelle: J. Grosch: "Lalr – A Generator for Efficient Parsers." GMD-Bericht 1988.

3.3.2 Vergleich verschiedener Zerteilergeneratoren

	Bison	yacc	PGS	Lalr	Ell
Grammatik	LALR(1)	LALR(1)	LALR(1)	LALR(1)	LL(1)
Spezifiziert in	BNF	BNF	EBNF	EBNF	EBNF
Geschwindigkeit in [10^3 Symbol / Sekunde]	8.93	15.94	17.32	34.94	54.64
Geschwindigkeit in [10^3 Zeilen / Minute]	150	270	290	580	910
Tabellengröße in [bytes] (komprimiert)	7724	9968	9832	9620	-
Zerteilergröße in [bytes]	10900	12200	14140	16492	18048

Eingabe: Modula-2 Code.
Hardware: PCS Cadmus mit MC68020 Prozessor (16.7 MHz).
Quelle: J. Grosch: "Lalr - A Generator for Efficient Parsers." GMD-Bericht 1988.

3.3.2 Studienarbeit zu vergeben

Neuer Vergleich der Zerteilergeneratoren

- Bison
- yacc
- PGS
- Lalr
- Ell

Auf aktuellen PC Architekturen um aktuelle Zahlen zu erhalten

Kann auch als Übersetzerbaupraktikum angerechnet werden

Freiwillige vor!

3.2.2 Komplexität Zerteilung in $O(n)$

Für alle Klassen gilt: Zerteilen benötigt Aufwand $O(n)$

Jeder Knoten, da kein Rücksetzen $O(1)$

Beweis über Grad der Knoten und mögliche Höhe des Baumes
(Kettenproduktionen und Epsilonproduktionen berücksichtigen)

3.3.2 Komplexität

Grammatiktyp	Zerteiler-generierung	Test der Grammatik
LL(1)	$O(n^2)$	$O(n^2)$
SLL(k)	$O(n^{k+1})$	$O(n^{k+1})$
LL(k)	$O(2^{n^k+(k+1)\log n})$	$O(n^{2k})$
SLR(1)	$O(2^{n+\log n})$	$O(n^2)$
SLR(k)	$O(2^{n+k\log n})$	$O(n^{k+2})$
LR(k)	$O(2^{n^{k+1}+k\log n})$	$O(n^{2(k+1)})$

Sätze über kontextfreie Grammatiken

Satz 1: Für jede $\mathrm{LR}(k)$-Grammatik G mit $k > 1$ gibt es eine $LR(1)$-Grammatik G' mit $L(G) = L(G')$.
Beweis durch Rechtsfaktorisierung.

Satz 2: Jede $\mathrm{LL}(k)$-Grammatik ist auch $\mathrm{LR}(k)$.

Satz 3: Es gibt $\mathrm{LR}(k)$-Grammatiken, die für kein k' $\mathrm{LL}(k')$ sind.

Satz 4: Es ist entscheidbar, ob es für eine gegebene $LR(k)$-Grammatik G ein k' gibt, so daß G $LL(k')$ ist.

Satz 5: Es ist unentscheidbar, ob für eine Sprache L eine Grammatik G existiert, so daß G $LL(1)$ ist.

Satz 6: Es ist unentscheidbar, ob es für eine Sprache L eine Grammatik G gibt, so daß G $\mathrm{LL}(k)$ oder $\mathrm{LR}(k)$ ist.

Kapitel 3: Zerteilung

1. Theoretische Grundlage: Kontextfreie Grammatiken
   - Notation
   - Konkrete und abstrakte Syntax
   - Rekursiver Abstieg
   - Kellerautomaten
   - Elimination von Linksrekursion und ε-Produktionen
   - Systematische Zerteilerkonstruktion: LL-, LR-Grammatiken
2. LL- und SLL-Grammatiken
3. LR-, SLR-Grammatiken
   - 3.1 LALR-Konstruktion
   - 3.2 Optimierungen und Komplexität
4. Fehlerbehandlung

3.4 Fehlerbehandlung

Ziel: Analyse soll formal korrekte Ergebnisse liefern (oder wegen zu vieler Fehler abbrechen), um möglichst viele Fehler zu finden.

- Gefahr von Folgefehlern wegen unzutreffender Korrektur unvermeidbar
- Unterscheide Fehler (= *Ursache*) und Fehlersymptom (= *beobachtbare Wirkung*)

Reaktionen:

- Bericht: Immer notwendig
- Reparatur, wenn Fehlerursache feststellbar und korrigierbar
- Wiederaufsetzen: Internen Zustand konsistent machen und weitere Fehler suchen
- Abbruch bei zu vielen Fehlern oder bei zu hohem Ressourcenverbrauch (Tabellenüberlauf, ...)

3.4 Fehlerbehandlung II

Fehler: Nicht (vom Programmierer) intendiertes Programm

Fehlersymptom:

- Sichtbare Auswirkung des Fehlers: Verletzung der Sprachdefinition
- zerteilerdefinierte Fehlerstelle.

Diagnose:

- Versuch, den Fehler auf der Grundlage des Symptoms zu erkennen.

- Entsprechende Fehlermeldung, Reparatur oder Wiederaufsetzen.

3.4 Beispiel

Zuweisung: `x := (a+b*c;`

Fehler (vermutlich):) nach **b** fehlt.

Fehlersymptom:) fehlt vor ;

Position des Fehlersymptoms ist nicht die Fehlerstelle!

3.4 Klassifikation

Fehlerklassen:

- Anomalien (verdächtig, aber nicht gefährlich)
  - Notiz — keine Standardkonstruktion
  - Kommentar — unpassender Programmierstil
  - Warnung — möglicher Fehler, z.B. unbenutzte Variable
- Fehler
  - einfacher Fehler — reparierbar, Code kann erzeugt werden
  - fataler Fehler — kein Code erzeugbar, nur Wiederaufsetzen möglich
  - Abbruchfehler — Übersetzer gibt auf (z.B. wegen Ressourcenbeschränkung)

3.4 Fehlermeldung

- Ausgabe von
  - *Position* (Datei, Zeile, Spalte),
  - Fehler*klasse*,
  - *Meldung*

- Intern: Meldung kodiert durch ganze Zahl

- Meldungstexte in getrennter Datei zur Anpassung der Sprache

- Meldungen fallen nicht in der Reihenfolge des Eingabetexts an:
  - Meldungen aufsammeln
  - nach Position sortiert ausgeben

3.4 Unterscheidung nach Übersetzerphase

1. Symbolfehler: unzulässiges Eingabezeichen, Abschluß Textkonstante oder Kommentar fehlt (falls erkennbar), verfrühtes Eingabeende: kein Endzustand des Symbolentschlüsselungsautomaten erreicht.
   Reparatur: falsche Zeichen oder vorhandenen Symbolanfang ignorieren
2. Syntaktischer Fehler: Satz gehört nicht zu der durch den Zerteiler definierten Obermenge der Sprache.
3. Semantischer Fehler: Fehler in der statischen Semantik.
4. Semantischer Fehler, der erst in der Optimierung entdeckt wird, z.B. Verletzung Indexgrenzen bei Reihungsindizierung.
5. Ressourcenbeschränkung verletzt (stets Abbruch), in allen Phasen möglich.

3.4 Zerteilerdefinierte Fehlerstelle

zerteilerdefinierte Fehlerstelle t:

$\forall \underline{s} \in \sum^* : st\underline{s} \notin L$ und $\exists\, s' : ss' \in L$.

LL-, *SLL*-, *LR*-, *SLR*- und *LALR*-Zerteiler finden die zerteilerdefinierte Fehlerstelle.

Andere Zerteiler, z.B für Präzedenzgrammatiken, finden sie nicht.

3.4 Beweisskizze für $LL(k)$

Angenommen t zerteilerdefinierte Fehlerstelle, d.h. $st\underline{s} \notin L$,

$\exists\, s'$: $ss' \in L$: Sei s im Keller und

$q = [P \rightarrow P_{anf} \bullet P_{rest}; \Omega]$

Terminal t *ist* zerteilerdefinierte Fehlerstelle gdw:

$\neg\exists k : t\underline{s} \in \mathrm{Anf}_k(P_{rest}\,\Omega)$

3.4 Problem am Beispiel

Grammatik:

(1)	Z	$\rightarrow$	$I \mid A$
(2)	I	$\rightarrow$	**if** E **then** Z **end**
(3)	A	$\rightarrow$	$E := E$
(4)	E	$\rightarrow$	$id\ E_{rest}$
(5)	E_{rest}	$\rightarrow$	$e \mid = id$

SLL-Zerteilung des fehlerhaften Satzes:

if a:=b **then ... end**

mit zerteilerdefiniertem Fehler := landet in Situation

[$I \rightarrow$ **if** E• **then** Z **end;** Ω] := b **then ... end**

Beachte: := $\in$ Folge(E)

3.4 Problem am Beispiel

leicht modifizierte Grammatik:

(1)	Z	$\rightarrow$	$I \mid A$
(2)	I	$\rightarrow$	**if** B **then** Z **end**
(3)	A	$\rightarrow$	$E := E$
(4)	B	$\rightarrow$	E
(5)	E	$\rightarrow$	$id\ E_{rest}$
(6)	E_{rest}	$\rightarrow$	$e \mid = id$

Zerteilung von: **if** $a := b$ **then ... end**

mit zerteilerdefiniertem Fehler := landet in Situation

[$I \rightarrow$ **if** E • **then** Z **end;** Ω] := b **then ... end**

Beachte: := $\notin$ Folge(B)

3.4 Ideale Korrektur

Minimale Anzahl von Operationen

- Einsetzen
- Streichen
- Ersetzen (= Streichen + Einsetzen)

ausführen

3.4 Tatsächliche Korrektur

- Panischer Modus: Wiederaufsetzen an Anweisungs- oder Vereinbarungsende
- Systematische Fortsetzung an zerteilerdefinierter Fehlerstelle $st\underline{s} \notin L$: frühest möglichen Wiederaufsetzpunkt finden
- Totalkorrektur:
  - Eingabe $st\underline{s} = s_1x_1...s_nx_n$, $s_1 = s$, n minimal, so aufteilen, daß alle s_i Ausschnitte einer korrekten Eingaben sind, die durch eventuell unbrauchbare Texte x_i verknüpft sind
  - die x_i durch korrekte Texte y_i so ersetzen, daß $s_1y_1...s_ny_n$ korrekt ist
  - Nachteil: quadratischer Aufwand, praktisch nicht eingesetzt

zahlreiche weitere Verfahren bekannt

3.4 Panischer Modus

alle Symbole bis Anweisungs- oder Vereinbarungsende streichen

Keller soweit abbauen, daß Folgesymbol ; **`end`**, `}`, ... akzeptiert wird

Fehlermeldung ausgeben und Analyse fortsetzen

Vorteil:

- einfache Implementierung

Nachteile:

- keine Analyse des Anweisungsrests
- Schwierigkeiten mit korrektem Abschluß von Klammerungen
  `if` ... **`then`**, **`then`** ... **`else`**, usw.

3.4 C (gcc) – Panischer Modus

```
int main ( ) {
 int j, i ;
 if (i<j) {{          /*FEHLER*/
  I = j ;
 }                    /*FEHLER-SYMPTOM 1: } erwartet*/
 else {
  if ( i != j ){
    j: = i ;          /*FEHLER 2 bleibt unerkannt*/
  }                   /*Ende if */
 }                    /*Ende main*/
 return 0 ;           /*FEHLER-SYMPTOM 2: return unerwartet*/
}
-----------
test.c: In function ´main´:
test.c: 6: parse error before ´else´
test.c: At top level:
test.c: 11: parse error before ´return´
```

3.4 Sather-K (fiasco) - Ad Hoc

```
class TEST is
main is
 j,i: INT;
 if  i < j then then          /* FEHLER 1 */
  i := j ;
 else
  if  i /= j then
    j := i_                   /* FEHLER 2 bleibt unerkannt */
 end;
end;
end;
end;
-------
test.sa:4: parse error, expecting ´TOK_END´
if i < j then then            -- FEHLER 1
```

3.4 Systematische Korrektur (Röhrich)

gegeben zerteilerdefinierter Fehlerstelle $str \notin L$

gesucht Fortsetzung sy in L:

- Bestimme eine Ankermenge $D=\{ d \in \Sigma \mid y=ss'ds'' \in L \}$
- Suche ein $d \in D$, so dass $r=r'dr''$ und $|r'|$ minimal ist.
- Ersetze $tr'dr''$ durch $s'dr''$.
- gib Fehlermeldung aus und setze Analyse fort
- Vorteile:
  - nahe bei Minimalkorrektur, einfache Fehlermeldung
  - fast vollautomatisch erzeugbar
  - terminiert, da Eingabe um d verkürzt.
- Nachteile:
  - Korrektur nicht zwangsläufig korrekt
  - Schwierigkeiten bei Listenkonstruktionen (Anweisungs-, Bezeichner-, Vereinbarungslisten, usw.)
  - bei rekursivem Abstieg Vorbereitung notwendig
  - bei LR-Analyse Adaption des Generators notwendig

$$\frac{s\ tr \quad = \quad s\ tr'dr''}{s\ s'\ dr''}$$

3.4 ADA (adac) - Fehlerbehandlung

```
procedure Main is
I;J : Integer;
begin
if I > J then then   /* FEHLER 1: I in Ankermenge,
                        then gestrichen */
I:=J
else
    if I /= J then
J = ; I              /* FEHLER 2: = unerwartet,
                        ; in Ankermenge, = gestrichen */
    end if           /* SYMPTOM: ; erwartet, end in
                                  Ankermenge,
                        ; eingefügt */
end if;
end Main;
```

3.4 ADA (adac) - Fehlerausgabe

```
error.ada...
4, 19: Error  syntax error
4, 19: Information expected tokens:
IDENTIFIER CHAR_STRING NULL PRAGMA CASE RETURN
FOR BEGIN EXIT GOTO DELAY ABORT RAISE REQUEUE IF
WHILE LOOP DECLARE ACCEPT SELECT <<
5,  3: Information          restart point
8,  7: Error                syntax error
8,  7: Information          expected tokens: . ; ( , : : =
8,  9: Information          restart point
8,  6: Error                syntax error
9,  6: Information          expected tokens: . ; ( , : : =
9,  6: Repair               token inserted : ;
```

3.4 Durchführung

1. Zeichne in jedem Zustand eine Situation aus, deren weitere Verfolgung zur Generierung der Fortsetzung führt.
   Die Fortsetzung muß terminieren.
   Ankermenge sind alle Symbole in dieser Fortsetzung.
2. Streiche in der Eingabe alle Zeichen bis zum ersten Zeichen in der Ankermenge.
3. Dieses Zeichen wird während der Verarbeitung der generierten Fortsetzung in einem Zustand q' akzeptiert und es gibt einen Übergang vom Fehlerzustand q nach q'
4. Setze die Zeichen ein, die den Automaten vom Zustand q nach q' bringen.

3.4 *LL* Durchführung

- Zeichne für jedes Nichtterminal eine Produktion aus, die in der Fortsetzungserzeugung vorhergesagt wird. Die Produktion darf nicht rekursiv sein!
- Bestimme für die laufenden und jede vorhergesagte Produktion die noch fehlenden Symbole. Diese bilden die Ankermenge. Die noch laufenden Produktionen sind aus dem Keller ersichtlich.
- Schwierigkeit bei rekursivem Abstieg: Keller nur nach Prozedurrückkehr zugänglich.
  - Abhilfe: Ankermenge bereits während der normalen Zerteilung aufbauen und in getrenntem Keller (Datenstruktur) ablegen oder als Argument bei Prozeduraufruf mitgeben.

3.4 *LL* Beispiel Automat

$Z \rightarrow A$

$A \rightarrow FA`$

$A` \rightarrow \varepsilon \mid + FA`$

$F \rightarrow i \mid (A)$

$q_0 : [Z \rightarrow \bullet A]$

$q_1 : [Z \rightarrow A \bullet]$

$q_2 : [Z \rightarrow \bullet FA']$

$q_3 : [A \rightarrow F \bullet A']$

$q_4 : [F \rightarrow \bullet i]$

$q_5 : [F \rightarrow \bullet (A)]$

$q_6 : [A \rightarrow FA' \bullet]$

$q_7 : [A' \rightarrow \bullet \varepsilon]$

$q_8 : [A` \rightarrow \bullet + F A`]$

$q_9 : [F \rightarrow i \bullet]$

$q_{10} [F \rightarrow (\bullet A)]$

$q_{11} [A' \rightarrow + \bullet FA']$

$q_{12} [F \rightarrow (A \bullet)]$

$q_{13} [A' \rightarrow + F \bullet A']$

$q_{14} [F \rightarrow (A) \bullet]$

$q_{15} [A' \rightarrow + FA' \bullet]$

$*q_0 i \rightarrow q_1\, q_2\, i,\ q_0(\rightarrow q_1\, q_2(,$

$*q_1 \rightarrow \varepsilon,$

$*q_2 i \rightarrow q_3 q_4 i,\ q_2(\rightarrow q_3 q_5(,$

$*q_3 \# \rightarrow q_6\, q_7\, \#,\ q_3) \rightarrow q_6 q_7),\ q_3 \rightarrow q_6 q_8 +,$

$*q_4 i \rightarrow q_9,$

$*q_5 (\rightarrow q_{10},$

$*q_6 \rightarrow \varepsilon\ ,$

$*q_7 \rightarrow \varepsilon,$

$*q_8 + \rightarrow q_{11},$

$*q_9 \rightarrow \varepsilon,$

$*q_{10}\, i \rightarrow q_{12}\, q_2\, i,\ q_{10}\, (\rightarrow q_{12}\, q_2\, (,$

$*q_{11} i \rightarrow q_{13}\, q_4 i\ ,\ q_{11}\, (\rightarrow q_{13}\, q_5\, (,\ *q_{12}) \rightarrow q_{14},$

$*q_{13}\, \# \rightarrow\ q_{15}\, q_7\, \#,\ q_{13}\,) \rightarrow q_{15} q_7\,),\ q_{13}\, + \rightarrow q_{15}\, q_{15} +,$

* zeichnet die vorherzusagenden Produktionen bzw. Zustandsübergänge aus $*q_{14} \rightarrow \varepsilon$, $*q_{15} \rightarrow \varepsilon$.

3.4 *LL* Beispiel *i* +

Zerteilen bis zum Fehler	Fortsetzung finden		Wiederaufsetzen	
$q_0 i + \#$	$q_1 q_6 q_{11}$	$D = \{ i (\}$	$q_1 q_6 q_{11} \#$	
$q_1 q_2 i + \#$	$q_1 q_6 q_{13} q_4$		$q_1 q_6 q_{13} q_4 \#$	
$q_1 q_3 q_4 i + \#$	$q_1 q_6 q_{13} q_9$		$q_1 q_6 q_{13} q_9 \#$	*i* generiert mit
$q_1 q_3 q_9 + \#$	$q_1 q_6 q_{13}$	$D = \{ i (\#) + \}$		$q_4 i \rightarrow q_9$
$q_1 q_3 + \#$	$q_1 q_6 q_{15} q_7$		$q_1 q_6 q_{13} \#$	weiter normal
$q_1 q_6 q_8 + \#$	$q_1 q_6 q_{15}$			
$q_1 q_6 q_{11} \#$	$q_1 q_6$			
	q_1			

3.4 *LR* Durchführung

- Zeichne für jedes Nichtterminal eine nichtrekursive Produktion aus
- Zustände sind nicht Mengen, sondern geordnete Listen von Situationen. Die Situationen für ausgezeichnete Produktionen kommen jeweils vor allen anderen Situationen mit gleicher linker Seite.
- Erzeugung der Fortsetzung: Benutze in jedem Zustand jeweils die erste Situation und ihren Übergang.
- Die ausgezeichnete Situation gehört zur Basis des Zustandes.
- Verfahren terminiert wegen Nichtrekursivität der ausgezeichneten Produktionen
- Sonderbehandlung von Trennzeichen für Listen. Sie werden initial in entsprechende Ankermenge übernommen.

3.4 *LR* Beispiel-Automat

(1) $Z \rightarrow A\,\#$

(2) $A \rightarrow A + F$

(3) $A \rightarrow F$

(4) $F \rightarrow \text{bez}$

(5) $F \rightarrow (\,A\,)$

0: $Z \rightarrow \bullet\, A\,;\,\#$

$A \rightarrow \bullet\, F\,;\,\#+$

$A \rightarrow \bullet\, A + F\,;\,\#+$

$F \rightarrow \bullet\, bez\,;\,\#+$

$F \rightarrow \bullet\, (A)\,;\,\#+$

1: $Z \rightarrow A \bullet;\,\#$

$A \rightarrow A \bullet + F\,;\,\#+$

2: $A \rightarrow F \bullet;\,\#+)$

3: $F \rightarrow bez \bullet;\,\#+)$

4: $F \rightarrow (\bullet\, A\,)\,;\,\#+)$

$A \rightarrow \bullet\, F\,;\,)+$

$A \rightarrow \bullet\, A + F\,;\,)+$

$F \rightarrow \bullet\, bez\,;\,)+$

$F \rightarrow \bullet\, (A)\,;\,)+$

5: $A \rightarrow A + \bullet\, F\,;\,\#+)$

$F \rightarrow \bullet\, bez\,;\,\#+)$

$F \rightarrow \bullet(A\,)\,;\,\#+)$

6: $F \rightarrow (\,A \bullet)\,;\,\#+)$

$A \rightarrow A \bullet + F\,;\,)+$

7: $A \rightarrow A + F \bullet;\,\#+)$

8: $F \rightarrow (A) \bullet\,;\,\#+)$

3.4 Übergänge

q	**bez**	**(**	**)**	**+**	**#**	***A***	***F***
0	-4	4	-	-	-	1	-3
1	-	-	-	5	*1		
4	-4	4	-	-	-	6	-3
5	-4	4	-	-	-		-2
6	-	-	-5	5	-		

Grau hinterlegt: Ausgezeichnete Übergänge

3.4 *LR* Beispiel *i +)i #*

Zerteilen bis zum Fehler	Fortsetzung finden		Wiederaufnahme
$q_0 i +) \; i \; \#$	$q_0 q_1 q_5$	$D = \{ i \; (\; \}$	$q_0 q_1 q_5 i \; \#$ wobei) gelöscht
$q_0 q_1 +) \; i \; \#$	$q_0 q_1$	$D = \{ i \; (\; + \; \# \; \}$	weiter normal
$q_0 q_1 q_5) \; i \; \#$			

3.4 Fehlerbehandlung in der semantischen Analyse

für jede Eigenschaft oder Wertetyp einen ausgezeichneten Wert *unbekannt* definieren

- Operationen mit *unbekannt* liefern wieder *unbekannt*
- Fehlermeldung nur, wenn *unbekannt* als Ergebnis, nicht als Operand erscheint.

Quellen fataler Fehler:

- fehlende Vereinbarung: Bezeichner erhält Typ *unbekannt* (oder Typ durch Typinferenz aus Anwendung erschließen)
- unzulässige Operation: Ergebnistyp ist *unbekannt*
- inkompatible Operanden oder sonstige Verletzung von Konsistenzbedingungen: Fehler melden, Ergebnistyp *unbekannt*, mit Analyse fortfahren