


**Bachelor-Programm**

# **Compilerbau**

im SoSe 2014

Prof. Dr. Joachim Fischer  
Dr. Klaus Ahrens  
Dr. Andreas Kunert  
Dipl.-Inf. Ingmar Eveslage

fischer@informatik.hu-berlin.de



## 4.3 LL-Parser

- Prinzip der prädiktiven Syntaxanalyse  
(LL- und LR-Parser sind prädiktive Parser)
- FIRST-Mengen-Bildung
- FOLLOW-Mengen-Bildung
- LL-Grammatik-Eigenschaften

# Motivation FIRST-Mengen

Für bekannte Programmiersprachen gibt es LL(1) und LL(2)-Grammatiken

Wie kann die LL(k)-Eigenschaft einer Grammatik ohne Betrachtung aller möglichen Ableitungen überprüft werden?

- **erstes Hilfsmittel: FIRST-Mengen-Konstruktion**  
enthalten Anfangsstücke herleitbarer Terminalworte

Sei  $G = (V, \Sigma, P, S)$  eine kontextfreie Grammatik,  $k \in \mathbb{N}$

$\text{FIRST}_k : (V \cup \Sigma)^+ \rightarrow \mathcal{P}(\Sigma)$  ist definiert durch

$$\text{FIRST}_k(\alpha) = \{ w \mid \alpha \Rightarrow^* w \text{ und } |w| \leq k \}$$

- 1)  $\text{FIRST}_k$  ist also die Menge der Anfangsstücke der **Länge k** von Terminalwörtern, die aus  $\alpha$  ableitbar sind
- 2) Falls kürzere Wörter ableitbar sind, dann sind auch diese in der **FIRST**-Menge enthalten, insbesondere  $\epsilon$ .

letzte Vorlesung betrachtete den speziellen **Fall: k=1**

# Definition einer FIRST-Menge (für $k=1$ )

Def.: FIRST-Menge (formale Definition)

$$FIRST^0 : (V \cup \Sigma)^+ \rightarrow \wp(\Sigma)$$

$$FIRST^0(x) := \{y \mid \exists \alpha \in (\Sigma \cup V)^* : x \Rightarrow^* y\alpha, y \in \Sigma\}$$

$$FIRST : (V \cup \Sigma)^+ \rightarrow \wp(\Sigma \cup \{\varepsilon\})$$

$$FIRST(x) := \begin{cases} FIRST^0(x) \cup \{\varepsilon\}, & \text{wenn } x \Rightarrow^* \varepsilon \\ FIRST^0(x), & \text{sonst} \end{cases}$$

# Konstruktion von FIRST-Mengen (für $k=1$ )

sei  $\alpha \in V$  die rechte Seite einer Produktion

## folgende Regeln

werden solange zur Berechnung von  $FIRST_1(\alpha)$  angewendet,  
bis zu keiner  $FIRST_1$ -Menge mehr ein neues **Terminalsymbol** oder  $\epsilon$  hinzukommt:

**Regel 1** ist  $\alpha$  **Terminalsymbol**, dann ist  $FIRST(\alpha) = \{ \alpha \}$ ;

**Regel 2** gibt es eine Produktion  $\alpha \rightarrow Y_1 Y_2 \dots Y_k$ , dann ist

- zunächst  $FIRST(Y_1) \setminus \{\epsilon\}$  der Menge  $FIRST(\alpha)$  zuzuführen;
- sollte  $\epsilon$  in  $FIRST(Y_1)$  enthalten sein, so ist auch  $FIRST(Y_2) \setminus \{\epsilon\}$  der Menge  $FIRST(\alpha)$  hinzuzufügen;
- Fortsetzung bis zu einem  $i \leq n$ , wo  $Y_i$  **nicht**  $\epsilon$ -ableitbar ist;
- sollte  $\epsilon$  jedoch in **allen**  $FIRST(Y_i)$  enthalten sein, ist auch  $\epsilon$  der Menge  $FIRST(\alpha)$  hinzuzufügen;

**Regel 3** gibt es eine Produktion  $\alpha \rightarrow \epsilon$ , dann ist  $\epsilon$  der Menge  $FIRST(\alpha)$  hinzuzufügen.

# Beispiel-1: FIRST-Mengen

**G-1**  
 $S \rightarrow A B c$   
 $A \rightarrow a$   
 $A \rightarrow \epsilon$   
 $B \rightarrow b$   
 $B \rightarrow \epsilon$

Wir betrachten alle Regeln und deren RS, um FIRST der  $Y_i$ s bestimmen zu können

| $\alpha \in V$ | FIRST( $\alpha$ )<br>Anfangsschritt | $Y_1$      | $Y_2$ | $Y_3$    | FIRST( $\alpha$ )<br>Final |
|----------------|-------------------------------------|------------|-------|----------|----------------------------|
| S              | $\emptyset$                         | A          | B     | <b>c</b> | Regel 2                    |
| A              | $\emptyset$                         | <b>a</b>   |       |          | Regel 1                    |
| A              | $\epsilon$                          | $\epsilon$ |       |          |                            |
| B              | $\emptyset$                         | <b>b</b>   |       |          |                            |
| B              | $\epsilon$                          | $\epsilon$ |       |          |                            |

Regel 3

# Beispiel-1: FIRST-Mengen

**G-1**  
 $S \rightarrow A B c$   
 $A \rightarrow a$   
 $A \rightarrow \varepsilon$   
 $B \rightarrow b$   
 $B \rightarrow \varepsilon$

Wir betrachten alle Regeln und deren RS, um FIRST der  $Y_i$ s bestimmen zu können

| $\alpha \in V$ | FIRST( $\alpha$ )<br><i>Anfangsschritt</i> | $Y_1$         | $Y_2$ | $Y_3$    | FIRST( $\alpha$ )<br><i>Final</i>      |
|----------------|--|---------------|-------|----------|--|
| S              | $\emptyset$                                | A             | B     | <b>c</b> | <b>{ a, b, c }</b>                     |
| A              | $\emptyset$                                | <b>a</b>      |       |          | <b>{ a, <math>\varepsilon</math> }</b> |
| A              | $\varepsilon$                              | $\varepsilon$ |       |          |  |
| B              | $\emptyset$                                | <b>b</b>      |       |          | <b>{ b, <math>\varepsilon</math> }</b> |
| B              | $\varepsilon$                              | $\varepsilon$ |       |          |  |

Regel 3

# Beispiel-4: FIRST-Mengen

|                             |     |
|-----------------------------|-----|
| <b>G-4</b>                  |     |
| $Z \rightarrow d$           | [1] |
| $Z \rightarrow XYZ$         | [2] |
| $Y \rightarrow \varepsilon$ | [3] |
| $Y \rightarrow c$           | [4] |
| $X \rightarrow Y$           | [5] |
| $X \rightarrow a$           | [6] |

|     | $\alpha \in V$ | $FIRST^0(\alpha)$ | $Y_1$         | $Y_2$ | $Y_3$ | $FIRST^1(Y_1)$                          | $FIRST(Y_2)$                         | $FIRST(Y_3)$     | $\varepsilon$ | $FIRST^1(\alpha)$                       |
|-----|----------------|-------------------|---------------|-------|-------|---|--------------------------------------|------------------|---------------|---|
| [1] | Z              | $\emptyset$       | <b>d</b>      |       |       | <b>{d}</b>                              | <b>{a, c, d}</b>                     | <b>{a, c, d}</b> | nein          | <b>{a, c, d}</b>                        |
| [2] | Z              |                   | X             | Y     | Z     | <b>{a, c, <math>\varepsilon</math>}</b> | <b>{<math>\varepsilon</math>, c}</b> |                  |               |   |
| [3] | Y              | $\varepsilon$     | $\varepsilon$ |       |       | <b>{<math>\varepsilon</math>, c}</b>    |                                      |                  | ja            | <b>{<math>\varepsilon</math>, c}</b>    |
| [4] | Y              |                   | <b>c</b>      |       |       |   |                                      |                  |               |   |
| [5] | X              | $\emptyset$       | Y             |       |       | <b>{<math>\varepsilon</math>, c, a}</b> |                                      |                  | ja            | <b>{<math>\varepsilon</math>, a, c}</b> |
| [6] | X              |                   | <b>a</b>      |       |       |   |                                      |                  |               |   |

Z wird nach Z selbst abgeleitet,  
kann also nicht mehr erweitert werden



# Prädiktives (vorausschauendes) Parsen

## Schlüsseleigenschaft:

Falls zwei Produktionen  $A \rightarrow \alpha | \beta$

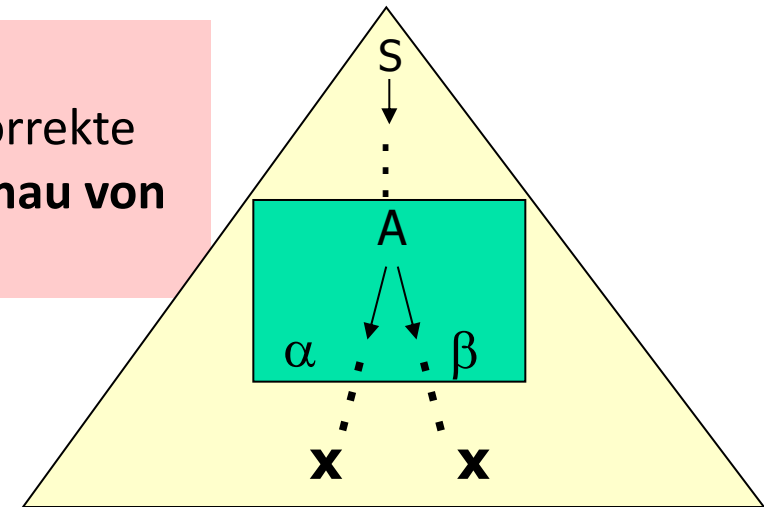
in einer Grammatik vorkommen, soll die Eigenschaft gelten:

$$\text{FIRST}(\alpha) \cap \text{FIRST}(\beta) = \emptyset$$

### Bem.:

Diese Eigenschaft sollte es dem Parser erlauben, eine korrekte Wahl der richtigen Produktionsregel mit einer **Vorausschau von einem Symbol** zu treffen

insbesondere können nicht beide Alternativen zu  $\epsilon$  abgeleitet werden



Die Sicherung der FIRST-Mengen-Eigenschaft allein reicht jedoch noch nicht in jedem Fall aus, die Eindeutigkeit des Ableitungsbaumes zu sichern

# LL(1)-Eigenschaft

mehrdeutige  
oder linksrekursive  
Grammatiken  
gehören nicht dazu

Eigenschaft einer kfG,  
dass deren Sprachen durch einen LL(1)-Parser  
analysiert werden können.

## Forderung-I:

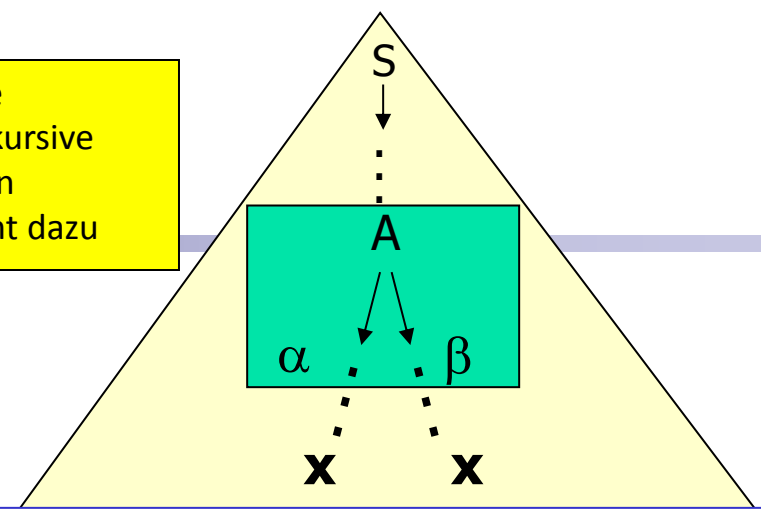
Falls zwei Produktionen  $A \rightarrow \alpha | \beta$   
in einer Grammatik vorkommen, gilt:

$$\text{FIRST}(\alpha) \cap \text{FIRST}(\beta) = \emptyset$$


## Forderung-II:

Sollte jedoch eine der beiden Alternativen zu  $\epsilon$  werden  
(o.B.d.A.:  $\beta$ ), gilt zusätzlich

$$\text{FIRST}(\alpha) \cap \text{FOLLOW}(A) = \emptyset$$



- bilden alle möglichen Ableitungen von  $\alpha$  (bzw.  $\beta$ )
- schauen uns dabei nur jeweils das erste Terminalsymbol an
- fassen diese zur Menge FIRST zusammen



- Terminalsymbole, die potentiell unmittelbar rechts nach dem  $A$  auftauchen können (steht man bereits ganz rechts, wird  $\$$  als Repräsentation fürs Eingabeende verwendet)

## 4.3 LL-Parser

- Prinzip der prädiktiven Syntaxanalyse  
(LL- und LR-Parser sind prädiktive Parser)
- FIRST-Mengen-Bildung
- FOLLOW-Mengen-Bildung
- LL-Grammatik-Eigenschaft
- LL-Analyseverfahren

# Definition einer FOLLOW-Menge

## Def.: FOLLOW-Menge (informale Definition)

sei  $A$  eine Variable,

dann ist  $FOLLOW(A)$  die Menge aller Terminalsymbole  $x$ ,  
die in einem Resultat von Ableitungsschritten **direkt rechts** neben  $A$  stehen  
dürfen

$\$$  gehört zu  $FOLLOW(A)$ ,

wenn  $A$  die am weitesten rechts stehende Meta-Variablen ist

$\$$  als eof-Kennung



## Bem.:

1. FOLLOW-Mengen werden ausschließlich über **Variablen** (Nichtterminalsymbole) definiert
2. ACHTUNG: es könnten durchaus zwischen  $A$  und  $x$  während der Bearbeitung Meta-Symbole gestanden haben, die in  $\epsilon$  übergegangen sind

# Konstruktion von FOLLOW-Mengen

## folgende Regeln

werden solange zur Berechnung von **FOLLOW(X)** angewendet, bis die Menge nicht mehr vergrößert werden kann:

Regel 1  $\$$  gehört zu **FOLLOW(X)** (falls  $X=S$ , das Startsymbol);

Regel 2 gibt es eine Produktion  $Y \rightarrow \alpha X \beta$ ,  
wird **FIRST( $\beta$ ) \setminus \{\epsilon\}** in **FOLLOW(X)** aufgenommen;

Regel 3 gibt es Produktionen  
 $Y \rightarrow \alpha X$  oder  
 $Y \rightarrow \alpha X \beta$  und **FIRST( $\beta$ )** enthält dabei  $\epsilon$  (d.h.  $\beta \Rightarrow^* \epsilon$ ),  
dann wird **jedes** Element von **FOLLOW(Y)**  
auch Element von **FOLLOW(X)**.

# FOLLOW: Berechnungsalgorithmus

//Anfangsschritt

$\forall X \in V$  : FOLLOW( $X$ ) =  $\emptyset$

FOLLOW( $S$ ) : FOLLOW( $S$ ) = { \$ }

**do** { //Iteration bis sich keine FOLLOW-Menge mehr ändert

**do**  $\forall$  Regeln  $X \rightarrow \alpha A$  in  $P$  {

FOLLOW ( $A$ )= FOLLOW( $A$ )  $\cup$  FOLLOW( $X$ )

}

**do**  $\forall$  Regeln  $X \rightarrow \alpha A \beta$  in  $P$  {

FOLLOW ( $A$ )= FOLLOW( $A$ )  $\cup$  (FIRST( $\beta$ ) - { $\epsilon$ })

**if** ( $\epsilon \in$  FIRST( $\beta$ )) **then** FOLLOW( $A$ )= FOLLOW( $A$ )  $\cup$  FOLLOW( $X$ )

}

//Abbruch

**if** ( $\forall$  Metasymbole  $X$ : FOLLOW( $X$ ) unverändert)

**then continue;**

# Beispiel-1: FOLLOW-Mengen (a)

## Grammatik:

- $Z \rightarrow S$  [1]
- $S \rightarrow S b$  [2]
- $S \rightarrow b A a$  [3]
- $A \rightarrow a S c$  [4]
- $A \rightarrow a$  [5]
- $A \rightarrow a S b$  [6]

Z ist das Startsymbol

$Z \rightarrow S$

| X | FIRST(X) | FOLLOW(X) |
|---|----------|-----------|
| Z | {b}      | {}        |
| S | {b}      | {}        |
| A | {a}      | {}        |

Regel 1/

Produktion 1

| X | FIRST(X) | FOLLOW(X) |
|---|----------|-----------|
| Z | {b}      | {\$}      |
| S | {b}      | {}        |
| A | {a}      | {}        |

# Beispiel-1: FOLLOW-Mengen (b)

## Grammatik:

- Z  $\rightarrow$  S [1]
- S  $\rightarrow$  S b [2]
- S  $\rightarrow$  b A a [3]
- A  $\rightarrow$  a S c [4]
- A  $\rightarrow$  a [5]
- A  $\rightarrow$  a S b [6]

| X | FIRST(X) | FOLLOW(X) |
|---|----------|-----------|
| Z | {b}      | {}        |
| S | {b}      | {}        |
| A | {a}      | {}        |

Regel 1/  
Produktion 1

| X | FIRST(X) | FOLLOW(X) |
|---|----------|-----------|
| Z | {b}      | {\$}      |
| S | {b}      | {}        |
| A | {a}      | {}        |

Regel 2/  
Produktion 2,3,4,6

| X | FIRST(X) | FOLLOW(X) |
|---|----------|-----------|
| Z | {b}      | {\$}      |
| S | {b}      |           |
| A | {a}      |           |

- A  $\rightarrow$  a S c
- A  $\rightarrow$  a S b
- S  $\rightarrow$  S b
- S  $\rightarrow$  b A a

$$\text{FOLLOW}(S) = \text{FOLLOW}(S) \cup \text{FIRST}(c) \setminus \{\epsilon\}$$

$$\text{FIRST}(c) \setminus \{\epsilon\} = \{c\}$$

$$\text{FIRST}(b) \setminus \{\epsilon\} = \{b\}$$

$$\text{FIRST}(b) \setminus \{\epsilon\} = \{b\}$$

$$\text{FIRST}(a) \setminus \{\epsilon\} = \{a\}$$



# Beispiel-1: FOLLOW-Mengen (b)

## Grammatik:

- Z → S [1]
- S → S b [2]
- S → b A a [3]
- A → a S c [4]
- A → a [5]
- A → a S b [6]

| X | FIRST(X) | FOLLOW(X) |
|---|----------|-----------|
| Z | {b}      | {}        |
| S | {b}      | {}        |
| A | {a}      | {}        |

Regel 1/  
Produktion 1

| X | FIRST(X) | FOLLOW(X) |
|---|----------|-----------|
| Z | {b}      | {\$}      |
| S | {b}      | {}        |
| A | {a}      | {}        |

Regel 2/  
Produktion 2,3,4,6

| X | FIRST(X) | FOLLOW(X) |
|---|----------|-----------|
| Z | {b}      | {\$}      |
| S | {b}      | {b, c}    |
| A | {a}      | {a}       |

- A → a S c
- A → a S b
- S → S b
- S → b A a

$$\text{FOLLOW}(S) = \text{FOLLOW}(S) \cup \text{FIRST}(c) \setminus \{\epsilon\}$$

$$\text{FIRST}(c) \setminus \{\epsilon\} = \{c\}$$

$$\text{FIRST}(b) \setminus \{\epsilon\} = \{b\}$$

$$\text{FIRST}(b) \setminus \{\epsilon\} = \{b\}$$

$$\text{FIRST}(a) \setminus \{\epsilon\} = \{a\}$$

# Beispiel-1: FOLLOW-Mengen (c)

**Grammatik:**

- $Z \rightarrow S$  [1]
- $S \rightarrow S b$  [2]
- $S \rightarrow b A a$  [3]
- $A \rightarrow a S c$  [4]
- $A \rightarrow a$  [5]
- $A \rightarrow a S b$  [6]

| X | FIRST(X) | FOLLOW(X) |
|---|----------|-----------|
| Z | {b}      | {}        |
| S | {b}      | {}        |
| A | {a}      | {}        |

Regel 1  
 Produktion 1

| X | FIRST(X) | FOLLOW(X) |
|---|----------|-----------|
| Z | {b}      | {\$}      |
| S | {b}      | {}        |
| A | {a}      | {}        |

Regel 2  
 Produktion 2,3,4,6

| X | FIRST(X) | FOLLOW(X) |
|---|----------|-----------|
| Z | {b}      | {\$}      |
| S | {b}      | {b, c}    |
| A | {a}      | {a}       |

Regel 3  
 Produktion 1

| X | FIRST(X) | FOLLOW(X)  |
|---|----------|------------|
| Z | {b}      | {\$}       |
| S | {b}      | {b, c, \$} |
| A | {a}      | {a}        |

$Z \rightarrow S$

$FOLLOW(S) = FOLLOW(S) \cup FOLLOW(Z)$

weitere Anwendung der Regeln erzeugt keine neuen Elemente der FOLLOW-Mengen

# Beispiel-2: FOLLOW-Mengen (a)

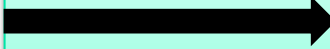
**Grammatik:**

- $S \rightarrow s$  [1]
- $S \rightarrow A B S$  [2]
- $B \rightarrow \epsilon$  [3]
- $B \rightarrow b$  [4]
- $A \rightarrow B$  [5]
- $A \rightarrow a$  [6]

S ist das Startsymbol

| X | FIRST(X)         | FOLLOW(X) |
|---|------------------|-----------|
| A | {a, b}           | {}        |
| B | {b, $\epsilon$ } | {}        |
| S | {s, a, b}        | { $\$$ }  |

$S \rightarrow A B S$

Regel 2/  
  
 Produktion 2

| X | FIRST(X)         | FOLLOW(X) |
|---|------------------|-----------|
| A | {a, b}           |           |
| B | {b, $\epsilon$ } |           |
| S | {s, a, b}        | { $\$$ }  |

$S \rightarrow A B S$

**FOLLOW(A):**  
 Hinzunahme von  $FIRST(B) \setminus \{\epsilon\} = \{b\}$   
 da  $\epsilon \in FIRST(B)$   
zusätzlich: Hinzunahme von FOLLOW(S)

**FOLLOW(B):**  
 Hinzunahme von  $FIRST(S) \setminus \{\epsilon\} = \{s, a, b\}$

# Beispiel-2: FOLLOW-Mengen (a)

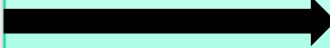
**Grammatik:**

- $S \rightarrow s$  [1]
- $S \rightarrow A B S$  [2]
- $B \rightarrow \epsilon$  [3]
- $B \rightarrow b$  [4]
- $A \rightarrow B$  [5]
- $A \rightarrow a$  [6]

S ist das Startsymbol

| X | FIRST(X)         | FOLLOW(X) |
|---|------------------|-----------|
| A | {a, b}           | {}        |
| B | {b, $\epsilon$ } | {}        |
| S | {s, a, b}        | { $\$$ }  |

$S \rightarrow A B S$

Regel 2/  
  
 Produktion 2

| X | FIRST(X)         | FOLLOW(X)  |
|---|------------------|------------|
| A | {a, b}           | {b, $\$$ } |
| B | {b, $\epsilon$ } | {s, a, b}  |
| S | {s, a, b}        | { $\$$ }   |

$S \rightarrow A B S$

**FOLLOW(A):**  
 Hinzunahme von  $FIRST(B) \setminus \{\epsilon\} = \{b\}$   
 da  $\epsilon \in FIRST(B)$   
zusätzlich: Hinzunahme von FOLLOW(S)

**FOLLOW(B):**  
 Hinzunahme von  $FIRST(S) \setminus \{\epsilon\} = \{s, a, b\}$

# Beispiel-2: FOLLOW-Mengen (b)

**Grammatik:**

- $S \rightarrow s$  [1]
- $S \rightarrow A B S$  [2]
- $B \rightarrow \epsilon$  [3]
- $B \rightarrow b$  [4]
- $A \rightarrow B$  [5]
- $A \rightarrow a$  [6]

S ist das Startsymbol

| X | FIRST(X)          | FOLLOW(X)   |
|---|-------------------|-------------|
| A | { a, b }          | { b, \$ }   |
| B | { b, $\epsilon$ } | { s, a, b } |
| S | { s, a, b }       | { \$ }      |

A → B

Regel 3  
 Produktion 2

| X | FIRST(X)          | FOLLOW(X)      |
|---|-------------------|----------------|
| A | { a, b }          | { b, \$ }      |
| B | { b, $\epsilon$ } | { s, a, b, ? } |
| S | { s, a, b }       | { \$ }         |

**FOLLOW(B):**  
 Hinzunahme von FOLLOW(A): { b, \$ }

# Beispiel-2: FOLLOW-Mengen (b)

**Grammatik:**

- $S \rightarrow s$  [1]
- $S \rightarrow A B S$  [2]
- $B \rightarrow \epsilon$  [3]
- $B \rightarrow b$  [4]
- $A \rightarrow B$  [5]
- $A \rightarrow a$  [6]

S ist das Startsymbol

| X | FIRST(X)          | FOLLOW(X)   |
|---|-------------------|-------------|
| A | { a, b }          | { b, \$ }   |
| B | { b, $\epsilon$ } | { s, a, b } |
| S | { s, a, b }       | { \$ }      |

A → B

Regel 3  
 Produktion 2

| X | FIRST(X)          | FOLLOW(X)       |
|---|-------------------|-----------------|
| A | { a, b }          | { b, \$ }       |
| B | { b, $\epsilon$ } | { s, a, b, \$ } |
| S | { s, a, b }       | { \$ }          |

**FOLLOW(B):**  
 Hinzunahme von FOLLOW(A): { b, \$ }

weitere Anwendung der Regeln erzeugt keine neuen Elemente der FOLLOW-Mengen

# Beispiel-3: FOLLOW-Mengen (a)

## Grammatik:

$S \rightarrow E$

$E \rightarrow TE'$

$E' \rightarrow +TE' \mid \epsilon$

$T \rightarrow FT'$

$T' \rightarrow *FT' \mid \epsilon$

$F \rightarrow (E) \mid id$

| $\alpha \in V$ | $Y_1$      | $Y_2$ | $Y_3$ | FIRST( $Y_1$ ) | FIRST <sup>2</sup> ( $Y_1$ ) | $\epsilon$ | FIRST( $\alpha$ ) |
|----------------|------------|-------|-------|----------------|------------------------------|------------|-------------------|
| S              | E          |       |       |                | {(, id}                      | nein       | {(, id}           |
| E              | T          | E'    |       |                | {(, id}                      | nein       | {(, id}           |
| E'             | +          | T     | E'    | {+}            |                              | ja         | { $\epsilon$ , +} |
| E'             | $\epsilon$ |       |       | { $\epsilon$ } |                              |            |                   |
| T              | F          | T'    |       |                | {(, id}                      | nein       | {(, id}           |
| T'             | *          | F     | T'    | {*}            |                              | ja         | { $\epsilon$ , *} |
| T'             | $\epsilon$ |       |       | { $\epsilon$ } |                              |            |                   |
| F              | (          | E     | )     | {(, id}        |                              | nein       | {(, id}           |
| F              | id         |       |       |                |                              |            |                   |

benötigen  
zunächst  
die FIRST-Mengen

# Beispiel-3: FOLLOW-Mengen (b)

da S Startsymbol

| X  | FIRST(X) | FOLLOW(X) |
|----|----------|-----------|
| S  | {(, id}  | { \$ }    |
| E  | {(, id}  |           |
| E' | {ε, +}   |           |
| T  | {(, id}  |           |
| T' | {ε, *}   |           |
| F  | {(, id}  |           |

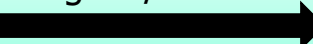
E → TE'

E' → +TE'

T → FT'

T' → \*FT'

F → (E)

Regel 2/  
  
 Produktion 2,5,8

| X  | FIRST(X) | FOLLOW(X) |
|----|----------|-----------|
| S  | {(, id}  | { \$ }    |
| E  | {(, id}  | { ) }     |
| E' | {ε, +}   |           |
| T  | {(, id}  | { +, }    |
| T' | {ε, *}   |           |
| F  | {(, id}  | { *, }    |

**Grammatik:**

- S → E [1]
- E → TE' [2]
- E' → +TE' | ε [3]
- T → FT' [4]
- T' → \*FT' | ε [5]
- F → (E) | id [6]



# Beispiel-3: FOLLOW-Mengen (c)

**Grammatik:**

|                                     |     |
|-------------------------------------|-----|
| $S \rightarrow E$                   | [1] |
| $E \rightarrow TE'$                 | [2] |
| $E' \rightarrow +TE' \mid \epsilon$ | [3] |
| $T \rightarrow FT'$                 | [5] |
| $T' \rightarrow *FT' \mid \epsilon$ | [6] |
| $F \rightarrow (E) \mid id$         | [8] |
|                                     | [9] |

da S Startsymbol

| X  | FIRST(X)          | FOLLOW(X) |
|----|-------------------|-----------|
| S  | {(, id}           | { \$ }    |
| E  | {(, id}           | { ) }     |
| E' | { $\epsilon$ , +} |           |
| T  | {(, id}           | { +, }    |
| T' | { $\epsilon$ , *} |           |
| F  | {(, id}           | { *, }    |

| X  | FIRST(X)          | FOLLOW(X)    |
|----|-------------------|--------------|
| S  | {(, id}           | { \$ }       |
| E  | {(, id}           | { ) }        |
| E' | { $\epsilon$ , +} |              |
| T  | {(, id}           | { +, ), }    |
| T' | { $\epsilon$ , *} |              |
| F  | {(, id}           | { *, +, ), } |


- $E \rightarrow TE'$
- $E' \rightarrow +TE'$
- $T \rightarrow FT'$
- $T' \rightarrow *FT'$

Regel 2  
 Produktion 2,3,5,6

noch offen

**FOLLOW(T):** da  $\epsilon$  FIRST(E') zusätzlich: Hinzunahme von FOLLOW(E) und FOLLOW (E')

**FOLLOW(F):** da  $\epsilon$  FIRST(T') zusätzlich: Hinzunahme von FOLLOW(T) und FOLLOW (T')



noch offen

# Beispiel-3: FOLLOW-Mengen (d)

**Grammatik:**

|                                     |     |
|-------------------------------------|-----|
| $S \rightarrow E$                   | [1] |
| $E \rightarrow TE'$                 | [2] |
| $E' \rightarrow +TE' \mid \epsilon$ | [3] |
| $T \rightarrow FT'$                 | [5] |
| $T' \rightarrow *FT' \mid \epsilon$ | [6] |
| $F \rightarrow (E) \mid id$         | [8] |
|                                     | [9] |

| X  | FIRST(X)           | FOLLOW(X)      |
|----|--------------------|----------------|
| S  | { (, id }          | { \$ }         |
| E  | { (, id }          | { ) }          |
| E' | { $\epsilon$ , + } |                |
| T  | { (, id }          | { +, ), } ←    |
| T' | { $\epsilon$ , * } |                |
| F  | { (, id }          | { *, +, ), } ← |

$S \rightarrow E$

$E \rightarrow TE'$

$E' \rightarrow +TE'$

$T \rightarrow FT'$

$T' \rightarrow *FT'$

Regel 2  
→  
 Produktion 1,2,3,5,6

| X  | FIRST(X)           | FOLLOW(X)         |
|----|--------------------|-------------------|
| S  | { (, id }          | { \$ }            |
| E  | { (, id }          | { ), \$ }         |
| E' | { $\epsilon$ , + } | { ), \$ } ←       |
| T  | { (, id }          | { +, ), \$ } ←    |
| T' | { $\epsilon$ , * } | { +, ), \$ } ←    |
| F  | { (, id }          | { *, +, ), \$ } ← |

**FOLLOW(E):** zusätzlich: Hinzunahme von FOLLOW(S)

**FOLLOW(E'):** zusätzlich: Hinzunahme von FOLLOW(E) und FOLLOW(E')

**FOLLOW(T'):** zusätzlich: Hinzunahme von FOLLOW(T) und FOLLOW(T')

weitere Anwendung der Regeln erzeugt keine neuen Elemente der FOLLOW-Mengen

## 4.3 LL-Parser

- Prinzip der prädiktiven Syntaxanalyse  
(LL- und LR-Parser sind prädiktive Parser)
- FIRST-Mengen-Bildung
- FOLLOW-Mengen-Bildung
- LL-Grammatik-Eigenschaften
- LL-Analyseverfahren

# Kriterien für LL(1)- Eigenschaft einer Grammatik

Sei  $G$  eine beliebige kontextfreie Grammatik. Dann ist  $G$   
eine LL(1)-Grammatik g.d.w.

für alle Alternativen

$$A \rightarrow \alpha_1 \mid \dots \mid \alpha_n$$

gilt:

- I. Die Mengen  $\text{FIRST}(\alpha_1), \dots, \text{FIRST}(\alpha_n)$  sind paarweise disjunkt, insbesondere enthält **höchstens** eine der Mengen  $\epsilon$  und
- II. aus  $A \Rightarrow^* \epsilon$  folgt:  
 $\text{FIRST}(A) \cap \text{FOLLOW}(A) = \emptyset$ .

# Erfüllung der LL(1)-Eigenschaft

LL(1)-Eigenschaft einer kfG, die garantiert, dass deren Sprachen durch einen LL(1)-Parser analysiert werden können.

**G-1:**

$S \rightarrow A$   
 $S \rightarrow B$   
 $A \rightarrow a$   
 $B \rightarrow b$

$$\text{FIRST}(A) \cap \text{FIRST}(B) = \emptyset$$

/                      \  
 $\{a\}$                        $\{b\}$

**kein Auswahlkonflikt :**  
in keiner  
FIRST-Menge  
ein  $\epsilon$   
 $\rightarrow$  FOLLOW muss  
nicht betrachtet  
werden

**G-2:**

$S \rightarrow A a$   
 $S \rightarrow B$   
 $A \rightarrow \epsilon$   
 $A \rightarrow a$   
 $B \rightarrow b$

$$\text{FIRST}(A) \cap \text{FIRST}(B) = \emptyset$$

/                      \  
 $\{a, \epsilon\}$                        $\{b\}$

**Auswahlkonflikt :**  
 $\text{FOLLOW}(A) = \{a\}$   
keine 1-deutige Regelwahl  
möglich

$$\text{FIRST}(A) \cap \text{FOLLOW}(A) \neq \emptyset$$

**G-3:**

$S \rightarrow A a$   
 $S \rightarrow b$   
 $A \rightarrow \epsilon$   
 $A \rightarrow c$

$$\text{FIRST}(A) \cap \text{FIRST}(b) = \emptyset$$

/                      \  
 $\{c, \epsilon\}$                        $\{b\}$

**kein Auswahlkonflikt :**  
 $\text{FOLLOW}(A) = \{a\}$

$$\text{FIRST}(A) \cap \text{FOLLOW}(A) = \emptyset$$

# Kriterien für Sonderfall von LL(1)-Grammatiken

Sei  $G$  eine  $\epsilon$ -freie kontextfreie Grammatik,  
d.h. ohne Produktionen der Form  $X \rightarrow \epsilon$ ,

dann ist  $G$  eine **LL(1)-Grammatik** g.d.w.  
für jedes Nichtterminal  $A$  mit den Alternativen

$$A \rightarrow \alpha_1 \mid \dots \mid \alpha_n$$

gilt:

die Mengen  $\text{FIRST}(\alpha_1), \dots, \text{FIRST}(\alpha_n)$  sind paarweise disjunkt.

## 4.3 LL-Parser

- Prinzip der prädiktiven Syntaxanalyse  
(LL- und LR-Parser sind prädiktive Parser)
- FIRST-Mengen-Bildung
- FOLLOW-Mengen-Bildung
- LL-Grammatik-Eigenschaften
- LL-Analyseverfahren

# LL(k)- Analyseverfahren

---

... sind

- Top-Down-Verfahren
- Leserichtung= **links-rechts**, Baumexpansion= **Linksableitung**
- deterministisch, d.h. ohne Rücksetzen und damit effizient (lineare Komplexität)
- prädiktives Verfahren

für die Auswahl der richtigen Regelalternative reicht für gewisse Grammatiken die Kenntnis **der nächsten k Symbole** (LookAhead) aus

»maßgeschneiderte« Grammatiken für LL(k)-Analyseverfahren

sind LL(k)-Grammatiken

betrachtet hatten wir aber  
nur den Fall  $k=1$



# Eigenschaften von $LL(k)$ -Grammatiken

---

- nicht mehrdeutig, nicht linksrekursiv
- für eine beliebige kontextfreie Grammatik  $G$  ist **nicht entscheidbar**, ob ein  $k \geq 1$  existiert, so dass  $G$  eine  $LL(k)$ -Grammatik ist
- **aber** für ein fixiertes  $k \geq 1$  und eine beliebige kontextfreie Grammatik  $G$  ist **entscheidbar**, ob  $G$  eine  $LL(k)$ -Grammatik ist

**Bem.:** Programmiersprache Pascal hat eine  $LL(1)$ -Grammatik

# LL(1)-Analysealgorithmus (1)

---

## Herangehensweise

Benutzung von Parse-Prozeduren, um Terminalsymbole zu erkennen, die durch Meta-Variablen akzeptiert werden

## Allgemeines Problem rekursiver Parse-Techniken

Bestimmung der anzuwendenden Produktionsregel

## Ausgangssituation

sei  $G$  eine LL(1)-Grammatik und

sei der Stand der Analyse mit der Auswertung der Regel

$$A \rightarrow \alpha_1 \mid \alpha_2 \mid \dots \mid \alpha_n$$

bestimmt, wo entschieden werden muss, welche Produktionsregel für  $A$  anzuwenden ist

# LL(1)-Analysealgorithmus (2)

---

Entscheidung lässt sich formalisieren

## Entscheidungsalgorithmus

- zunächst wird überprüft, ob das LookAhead-Symbol in einer der  $FIRST(\alpha_i)$ -Mengen enthalten ist
  - wenn **ja** : ist die Wahl der Regel eindeutig
  - wenn **nicht**: ...
- ... gibt es die Möglichkeit der Ableitung:  $A \rightarrow \epsilon$  ?
  - wenn **ja** : sollte  $FOLLOW(A)$  die Entscheidung bringen
- wenn **nicht**: (also keine  $\epsilon$  –Ableitung bzw. keine FOLLOW-Lösung) liegt ein syntaktischer Fehler vor

# Implementation der LL(1)-Analyse

---

## Implementationsvarianten prädiktiver Top-Down-Verfahren

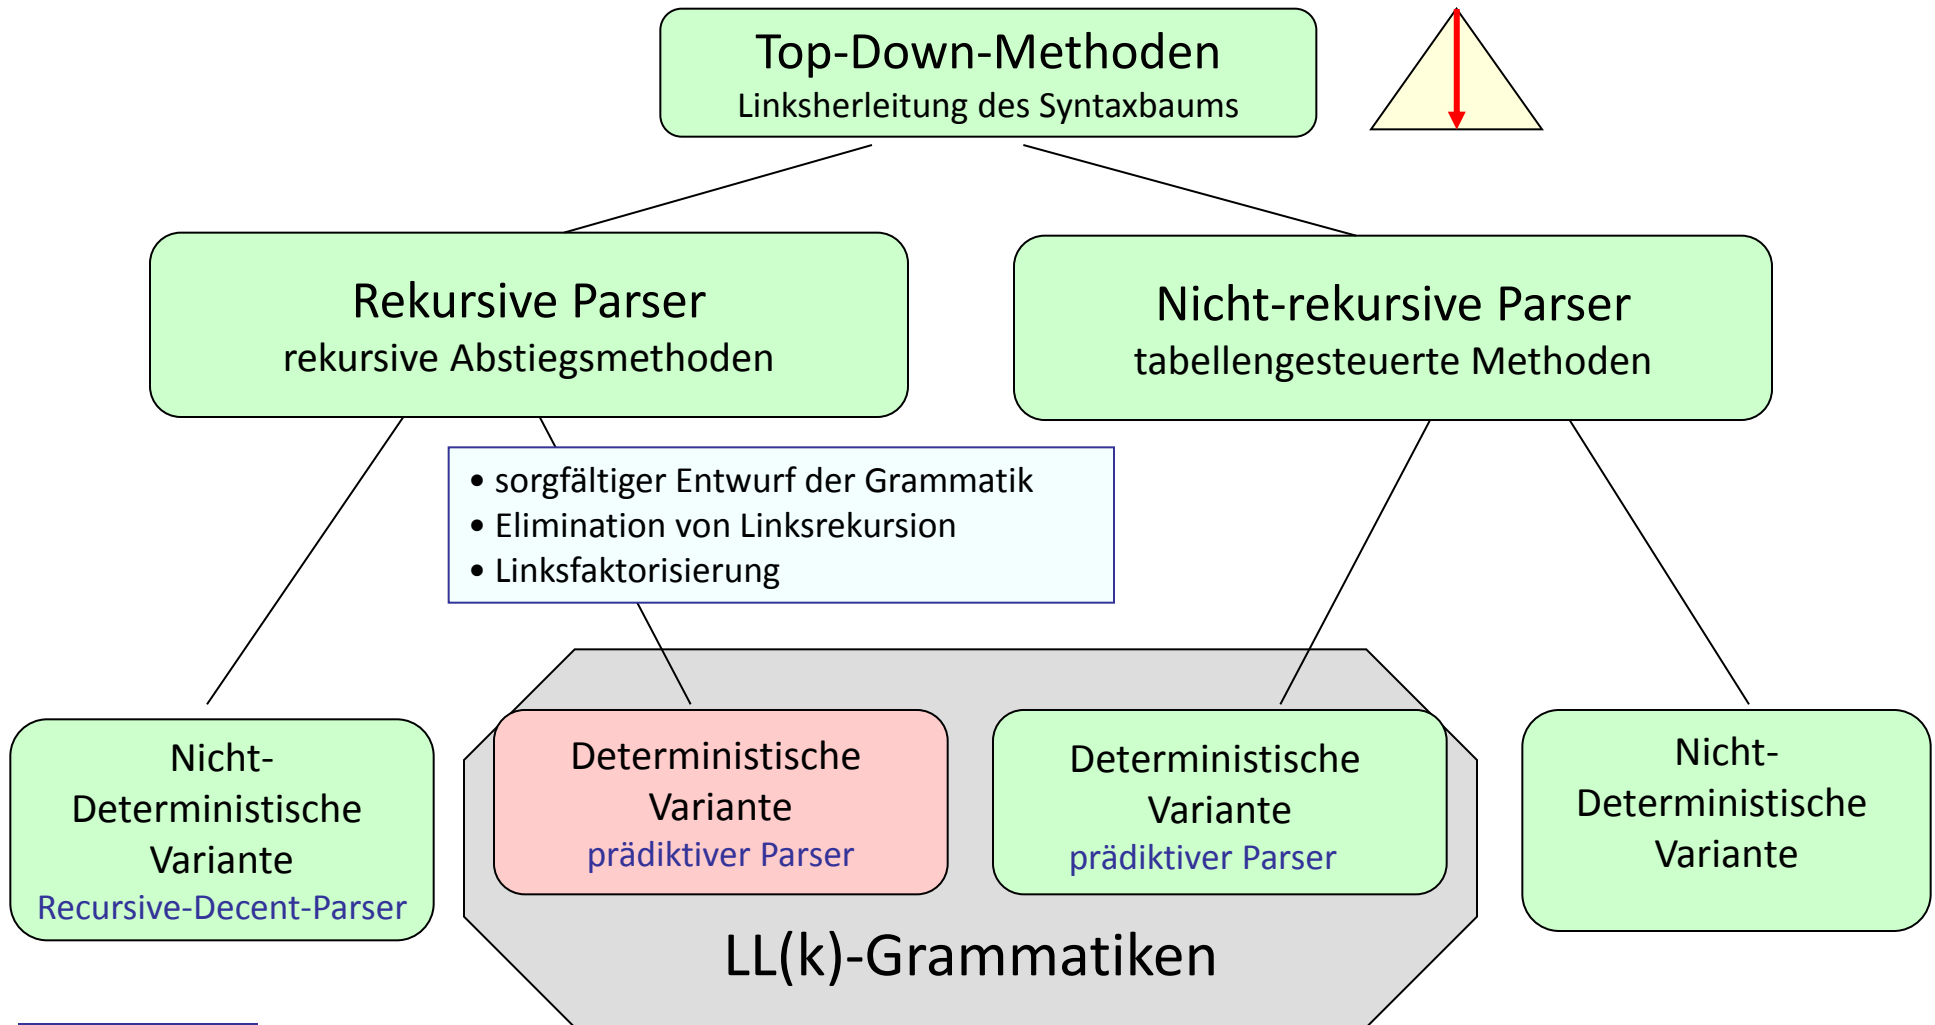
- a) rekursiver Abstieg
- b) nicht-rekursive, tabellengesteuerte Analyse

### Bemerkung

Umsetzung der FIRST- und FOLLOW-Mengen

am günstigsten in Form von Mengen als abstrakter Datentyp  
(muss in C aber selbst implementiert werden)

# Zwischenfazit: Klassen von Top-Down-Methoden



# Position

© **Teil I**  
Die Programmier

© **Teil II**  
Methodische Grund

© **Teil III**  
Entwicklung ein

© **Kapitel 1**  
Compilationsprozess

© **Kapitel 2**  
Formalismen zur Sprachbeschreibung

© **Kapitel 3**  
Lexikalische Analyse: der Scanner

© **Kapitel 4**  
Lexikalische Analyse: der Parser

© **Kapitel 5**  
Parsergeneratoren: Yacc, Bison

© **Kapitel 6**  
Statische Semantikanalyse

© **Kapitel 7**  
Laufzeitsysteme

© **Kapitel 8**  
Ausblick: Codegenerierung

© **4.1**  
Einführung in die Syntaxanalyse

© **4.2**  
Restrukturierung von Grammatiken

© **4.3**  
LL-Parser

© **4.4**  
Beispiel: Ein-Pass-Compiler  
(Scanner, Parser, Übersetzer)

## 4.4 Beispiel

### Ein einfacher Einpass-Compiler (Front- und Back-End)

als Transformation (s. letzte Vorlesung):

*Infix-Ausdrücke* → *Postfixausdrücke*

bei Einsatz

– eines

*handgeschriebenen Scanners*

– der prädiktiven Syntaxanalyse-Technik:

*rekursiv absteigender Parser*

– der Übersetzungstechnik:

*Übersetzungsschema*

# Umformung der Grammatik

Ziel: Behandlung mit Prädiktiver Syntaxanalyse

nicht  
eindeutig

|     |  |
|-----|--|
| 1.  | $goal \rightarrow expr$                  |
| 2.  | $expr \rightarrow expr \text{ op } expr$ |
| 3.  | num                                      |
| 4.  | id                                       |
| 5.  | $op \rightarrow *$                       |
| 6.  | +  |
| 7.  | -  |
| 8.  | /  |
| 9.  | DIV                                      |
| 10. | MOD                                      |

|     |                                  |
|-----|----------------------------------|
| 1.  |                                  |
| 2.  |                                  |
| 3.  |                                  |
| 4.  | $expr \rightarrow expr + term$   |
| 5.  | $expr - term$                    |
| 6.  | $term$                           |
| 7.  | $term \rightarrow term * factor$ |
| 8.  | $term / factor$                  |
| 9.  | $term \text{ DIV } factor$       |
| 10. | $term \text{ MOD } factor$       |
| 11. | $factor$                         |
| 12. | $factor \rightarrow num$         |
| 13. | $id$                             |

eindeutig, linksreursive Regeln

LL(1)-Parser

Sequenz von expr;

|     |   |
|-----|---|
| 1.  | $goal \rightarrow list$                         |
| 2.  | $list \rightarrow expr; list$                   |
| 3.  | $\epsilon$                                      |
| 4.  | $expr \rightarrow expr + term \{print('+')\}$   |
| 5.  | $expr - term \{print('-')\}$                    |
| 6.  | $term$  |
| 7.  | $term \rightarrow term * factor \{print('*')\}$ |
| 8.  | $term / factor \{print('/')\}$                  |
| 9.  | $term \text{ DIV } factor \{print('DIV')\}$     |
| 10. | $term \text{ MOD } factor \{print('MOD')\}$     |
| 11. | $factor$  |
| 12. | $factor \rightarrow num \{print(num.value)\}$   |
| 13. | $id \{print(id.lexeme)\}$                       |

Übersetzungsschema  
eindeutig, linksreursive Regeln



# Umformung der Grammatik

rechtsrekursives  
Übersetzungsschema

eindeutig, linksrekursive Regeln

|     |   |
|-----|---|
| 1.  | $goal \rightarrow list$                           |
| 2.  | $list \rightarrow expr; list$                     |
| 3.  | $\mid \varepsilon$                                |
| 4.  | $expr \rightarrow expr + term \{print('+')\}$     |
| 5.  | $\mid expr - term \{print('-')\}$                 |
| 6.  | $\mid term$                                       |
| 7.  | $term \rightarrow term * factor \{print('*')\}$   |
| 8.  | $\mid term / factor \{print('/')\}$               |
| 9.  | $\mid term \mathbf{DIV} factor \{print('DIV')\}$  |
| 10. | $\mid term \mathbf{MOD} factor \{print('MOD')\}$  |
| 11. | $\mid factor$                                     |
| 12. | $factor \rightarrow ( expr )$                     |
| 13. | $\mid \mathbf{num} \{print(\mathbf{num.value})\}$ |
| 14. | $\mid \mathbf{id} \{print(\mathbf{id.lexeme})\}$  |

|     |   |
|-----|---|
| 1.  | $goal \rightarrow list$   |
| 2.  | $list \rightarrow expr; list$   |
| 3.  | $\mid \varepsilon$  |
| 4.  | $expr \rightarrow term \mathit{moreterms}$                                      |
| 5.  | $\mathit{moreterms} \rightarrow = + term \{print('+')\} \mathit{moreterms}$     |
| 6.  | $\mid - term \{print('-')\} \mathit{moreterms}$                                 |
| 7.  | $\mid \varepsilon$  |
| 8.  | $term \rightarrow factor \mathit{morefactors}$                                  |
| 9.  | $\mathit{morefactors} \rightarrow * factor \{print('*')\} \mathit{morefactors}$ |
| 10. | $\mid / factor \{print('/')\} \mathit{morefactors}$                             |
| 11. | $\mid \mathbf{DIV} factor \{print('DIV')\} \mathit{morefactors}$                |
| 12. | $\mid \mathbf{MOD} factor \{print('MOD')\} \mathit{morefactors}$                |
| 13. | $\mid \varepsilon$  |
| 14. | $factor \rightarrow ( expr )$   |
| 15. | $\mid \mathbf{num} \{print(\mathbf{num.value})\}$                               |
| 16. | $\mid \mathbf{id} \{print(\mathbf{id.lexeme})\}$                                |

# Markierung des Eingabeendes

---

## Sonderfall:

**eof** kann als Token erkannt und weitergereicht werden

- es folgt dem äußersten rechten Symbol der RS der **Startproduktion**
- häufig wird es dennoch in der Grammatik **weggelassen**, obwohl es vorhanden ist

→ Wir fügen die eof-Behandlung explizit ein.

# Behandlung von eof

Behandlung von eof  
als Token \$

```
void parse()
/* analysiert und transformiert Ausdrücke */
{
    lookAhead = lexAnalyse();

    while (lookAhead != DONE) {
        expr();
        match(';');
    }
}
```

|     |  |
|-----|--|
| 1.  | <i>goal</i> → <i>list</i> \$   |
| 2.  | <i>list</i> → <i>expr</i> ; <i>list</i>                              |
| 3.  | ε  |
| 4.  | <i>expr</i> → <i>term</i> <i>moreterms</i>                           |
| 5.  | <i>moreterms</i> → + <i>term</i> {print('+')} <i>moreterms</i>       |
| 6.  | - <i>term</i> {print('-')} <i>moreterms</i>                          |
| 7.  | ε  |
| 8.  | <i>term</i> → <i>factor</i> <i>morefactors</i>                       |
| 9.  | <i>morefactors</i> → * <i>factor</i> {print('*')} <i>morefactors</i> |
| 10. | / <i>factor</i> {print('/')} <i>morefactors</i>                      |
| 11. | <b>DIV</b> <i>factor</i> {print('DIV')} <i>morefactors</i>           |
| 12. | <b>MOD</b> <i>factor</i> {print('MOD')} <i>morefactors</i>           |
| 13. | ε  |
| 14. | <i>factor</i> → ( <i>expr</i> )                                      |
| 15. | <b>num</b> {print(num.value)}  |
| 16. | <b>id</b> {print(id.lexeme)}   |

# Bestimmung von FIRST

| $\alpha \in V$     |               | $Y_1$         | $Y_2$       | $Y_3$       | FIRST( $Y_1$ )                 | $\varepsilon$ | FIRST( $\alpha$ )                                 |
|--------------------|---------------|---------------|-------------|-------------|--------------------------------|---------------|---|
| <i>goal</i>        |               | list          | \$          |             | { $\varepsilon$ , (, num, id } | ja            | { $\varepsilon$ , (, num, id }                    |
| <i>list</i>        |               | expr          | ;           | list        | { (, num, id }                 | nein          |   |
| <i>list</i>        | $\varepsilon$ | $\varepsilon$ |             |             | { $\varepsilon$ }              | ja            | { $\varepsilon$ , (, num, id }                    |
| <i>expr</i>        |               | term          | moreterms   |             | { (, num, id }                 | nein          | { (, num, id }                                    |
| <i>moreterms</i>   |               | +             | term        | moreterms   | { + }                          | nein          |   |
| <i>moreterms</i>   |               | -             | term        | moreterms   | { - }                          | nein          |   |
| <i>moreterms</i>   | $\varepsilon$ | $\varepsilon$ |             |             | { $\varepsilon$ }              | ja            | { $\varepsilon$ , +, - }                          |
| <i>term</i>        |               | factor        | morefactors |             | { (, num, id }                 | nein          | { (, num, id }                                    |
| <i>morefactors</i> |               | *             | factor      | morefactors | { * }                          | nein          |   |
| <i>morefactors</i> |               | /             | factor      | morefactors | { / }                          | nein          |   |
| <i>morefactors</i> |               | <b>DIV</b>    | factor      | morefactors | { <b>DIV</b> }                 | nein          | { $\varepsilon$ , *, /, <b>DIV</b> , <b>MOD</b> } |
| <i>morefactors</i> |               | <b>MOD</b>    | factor      | morefactors | { <b>MOD</b> }                 | nein          |   |
| <i>morefactors</i> | $\varepsilon$ | $\varepsilon$ |             |             | { $\varepsilon$ }              | ja            |   |
| <i>factor</i>      |               | (             | expr        | )           | { ( }                          | nein          | { (, num, id }                                    |
| <i>factor</i>      |               | num           |             |             | { num }                        | nein          |   |
| <i>factor</i>      |               | id            |             |             | { id }                         | nein          |   |

# Test der LL(1)-Eigenschaft

| $\alpha \in V$     | FIRST( $\alpha$ )               | FOLLOW( $\alpha$ )             |
|--------------------|---------------------------------|--------------------------------|
| <i>goal</i>        | { $\epsilon$ , (, num, id }     | { }                            |
| <i>list</i>        | { $\epsilon$ , (, num, id }     | { \$ }                         |
| <i>expr</i>        | { (, num, id }                  | { ;, ) }                       |
| <i>moreterms</i>   | { $\epsilon$ , +, - }           | { ;, ) }                       |
| <i>term</i>        | { (, num, id }                  | { +, -, ;, ) }                 |
| <i>morefactors</i> | { $\epsilon$ , *, /, DIV, MOD } | { +, -, ;, ) }                 |
| <i>factor</i>      | { (, num, id }                  | { *, /, DIV, MOD, +, -, ;, ) } |

FIRST(*expr*)  $\cap$  FIRST( $\epsilon$ ) =  $\emptyset$  ?  
 { (, num, id }  $\cap$  {  $\epsilon$  } =  $\emptyset$

FIRST(*expr*)  $\cap$  FOLLOW(*list*) =  $\emptyset$  ?  
 { (, num, id }  $\cap$  { \$ } =  $\emptyset$

FIRST(*moreterms*)  $\cap$  FOLLOW(*moreterms*) =  $\emptyset$  ?  
 {  $\epsilon$ , +, - }  $\cap$  FOLLOW(*expr*) =  $\emptyset$  ?  
 {  $\epsilon$ , +, - }  $\cap$  { ), ; } =  $\emptyset$

|     |  |
|-----|--|
| 1.  | <i>goal</i> $\rightarrow$ <i>list</i> \$   |
| 2.  | <i>list</i> $\rightarrow$ <i>expr</i> ; <i>list</i>                              |
| 3.  | $\epsilon$   |
| 4.  | <i>expr</i> $\rightarrow$ <i>term</i> <i>moreterms</i>                           |
| 5.  | <i>moreterms</i> $\rightarrow$ + <i>term</i> {print('+')} <i>moreterms</i>       |
| 6.  | - <i>term</i> {print('-')} <i>moreterms</i>                                      |
| 7.  | $\epsilon$   |
| 8.  | <i>term</i> $\rightarrow$ <i>factor</i> <i>morefactors</i>                       |
| 9.  | <i>morefactors</i> $\rightarrow$ * <i>factor</i> {print('*')} <i>morefactors</i> |
| 10. | / <i>factor</i> {print('/')} <i>morefactors</i>                                  |
| 11. | DIV <i>factor</i> {print('DIV')} <i>morefactors</i>                              |
| 12. | MOD <i>factor</i> {print('MOD')} <i>morefactors</i>                              |
| 13. | $\epsilon$   |
| 14. | <i>factor</i> $\rightarrow$ ( <i>expr</i> )                                      |
| 15. | num {print(num.value)}   |
| 16. | id {print(id.lexeme)}  |

FIRST(*morefactors*)  $\cap$  FOLLOW(*morefactors*) =  $\emptyset$  ?  
 {  $\epsilon$ , \*, /, DIV, MOD }  $\cap$  FOLLOW(*term*) =  $\emptyset$

# Entwurf + Optimierung des Parsers

- ...als rekursives Abstiegsverfahren mit Übersetzungsschemata

## und Optimierungsansatz

manche rekursive Aufrufe lassen sich durch einfache Iterationen ersetzen (Effekt: Laufzeitverbesserung)

## Parser-Änderungen

- (1) **End-ständige Rekursionen:**  
Selbstaufrufe (wie `moreterms`, `morefactors`) lassen sich durch Iterationen ersetzen
- (2) Zusammenführung von
  - `expr` und `moreterms`
  - `term` und `morefactors`zu jeweils einer Funktion
- (3) strukturierte Ausgabe: Funktion `emit` (`Token`, `Tokenwert`)

|     |  |
|-----|--|
| 1.  | <code>goal</code> → <code>list</code> \$                                   |
| 2.  | <code>list</code> → <code>expr</code> ; <code>list</code>                  |
| 3.  | $\epsilon$   |
| 4.  | <code>expr</code> → <code>term</code> <i>moreterms</i>                     |
| 5.  | <i>moreterms</i> → + <code>term</code> {print('+')} <i>moreterms</i>       |
| 6.  | - <code>term</code> {print('-')} <i>moreterms</i>                          |
| 7.  | $\epsilon$   |
| 8.  | <code>term</code> → <code>factor</code> <i>morefactors</i>                 |
| 9.  | <i>morefactors</i> → * <code>factor</code> {print('*')} <i>morefactors</i> |
| 10. | / <code>factor</code> {print('/')} <i>morefactors</i>                      |
| 11. | <b>DIV</b> <code>factor</code> {print('DIV')} <i>morefactors</i>           |
| 12. | <b>MOD</b> <code>factor</code> {print('MOD')} <i>morefactors</i>           |
| 13. | $\epsilon$   |
| 14. | <code>factor</code> → ( <code>expr</code> )                                |
| 15. | <b>num</b> {print( <b>num.value</b> )}                                     |
| 16. | <b>id</b> {print( <b>id.lexeme</b> )}                                      |

# Vereinfachungen nach Code-Review (1)

## Änderungen

- (1) End-ständige Rekursionen → Iteration
- (2) Zusammenführung von Routinen
- (3) strukturierte Ausgabe

```
void expr() {
    term(); moreterms();
}
```

```
void moreterms() {
    if (lookAhead == '+') {
        match('+'); term(); print('+'); moreterms();
    }
    else if (lookAhead == '-') {
        match('-'); term(); print('-'); moreterms();
    }
    else ; /* do nothing */
}
```

|     |  |
|-----|--|
| 1.  | <i>goal ::= list \$</i>                            |
| 2.  | <i>list ::= expr; list</i>                         |
| 3.  | $\epsilon$   |
| 4.  |  |
| 5.  | <i>moreterms ::= + term {print('+')} moreterms</i> |
| 6.  | - term {print('-')} moreterms                      |
| 7.  | $\epsilon$ <i>expr ::= term moreterms</i>          |
| 8.  | <i>term ::= factor morefactors</i>                 |
| 9.  | <i>more</i>  |
| 10. |  |
| 11. |  |
| 12. |  |
| 13. |  |
| 14. | <i>facto</i>                                       |
| 15. | <i>facto</i>                                       |
| 16. |  |

```
void expr() {
    int token;

    term();
    while (1)
        switch (lookAhead) {
            case '+':
            case '-':
                token= lookAhead;
                match(lookAhead);
                term();
                emit(token, NONE);
                continue;
            default:
                return;
        }
}
```

# Vereinfachungen nach Code-Review (2)

```
void emit (int token, int tokenValue) { /* erzeugt die Ausgabe */
    switch (token) {
        case '+':
        case '-':
        case '*':
        case '/':    printf("%c\n", token);
                    break;
        case DIV:   printf("div\n");
                    break;
        case MOD:   printf("mod\n");
                    break;
        case NUM:   printf("%d\n", tokenValue);
                    break;
        case ID:    printf("%s\n", symbolTable[tokenValue].lexPtr);
                    break;
        case ';':   printf(";\n");
                    break;
        default:    printf("token %d, tokenValue %d\n", token, tokenValue);
    }
}
```



# Vereinfachungen nach Code-Review (3)

```
void morefactors()
{
    int token;

    switch (lookAhead) {
        case '*':
        case '/':
        case DIV:
        case MOD:
            token = lookAhead;
            match(lookAhead);
            factor();
            emit(token, NONE);
            morefactors();
        default:
            return;
    }
}
```

```
void term()
{
    factor();
    morefactors();
}
```

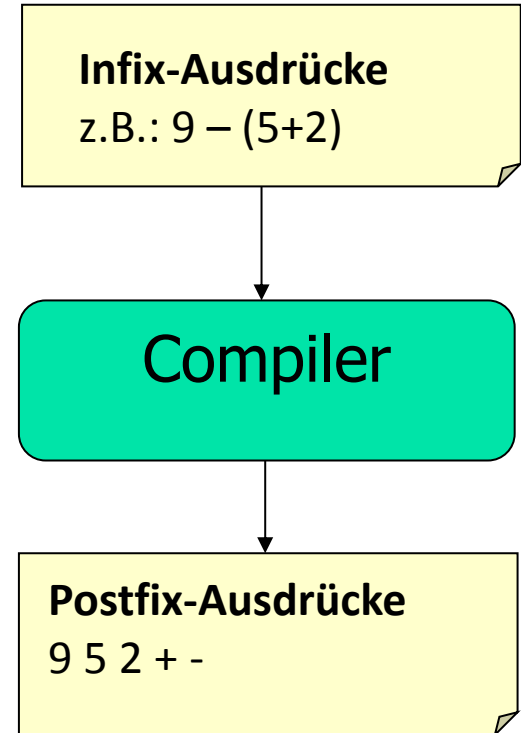
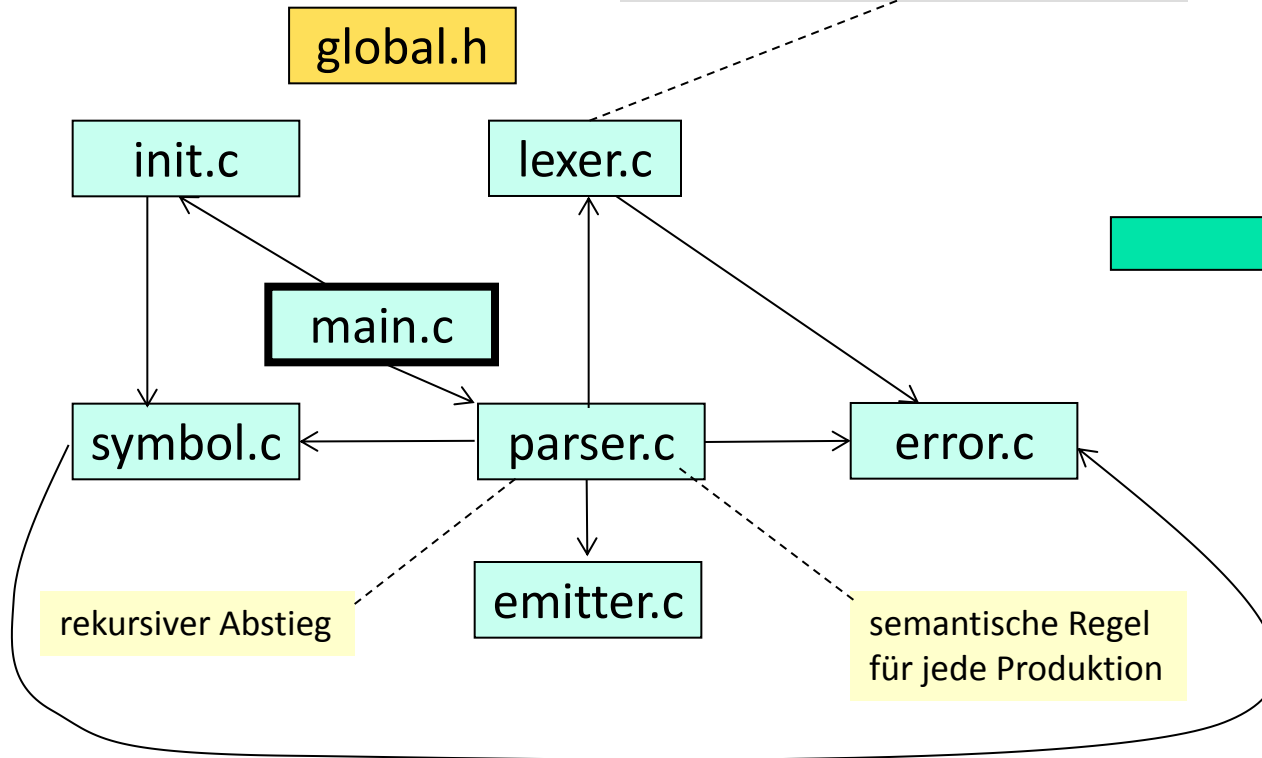
```
void term()
{
    int token;

    factor();
    while (1)
        switch (lookAhead) {
            case '*':
            case '/':
            case DIV:
            case MOD:
                token= lookAhead;
                match(lookAhead);
                factor();
                emit(token, NONE);
                continue;
            default:
                return;
        }
}
```

# Umsetzung: Ein einfacher Ein-Pass-Compiler (komplette Handimplementierung)

Verzicht auf individuelle Header-Files der einzelnen Module

Token: +, -, \*, /, DIV, MOD, (, ), ID, NUM, DONE



Aufruf-Abhängigkeit

```
#include <stdio.h>
#include <ctype.h>
```

## global.h

```
#define BUFFERSIZE 128 /* Puffergroesse */
#define NONE -1
#define EOS '\0'

#define NUM 256 /* bis 255 einfache Zeichen */
#define DIV 257
#define MOD 258
#define ID 259
#define DONE 260

int tokenValue; /* Lexem, Tokenwert */
int lineNo;


typedef struct entry {
    char *lexPtr;
    int token;
} entry;

extern entry symbolTable[];

int insert (char[], int); /* Op von symbolTabelle */
int lookup (char[]); /* Op von symbolTabelle */
void error (char *, int);
void error1 (char*, int);
void init(); /*Initialisierung von symbolTabelle*/
void parse();
int lexAnalyse(); /* yylex(); falls generierter Lexer*/
void emit(int, int);
void expr();
void term();
void factor();
void match(int);
```

```
#include "global.h"
```

```
int main()
{
    init();
    parse();
    return 0; /* erfolgreiche Terminierung */
}
```



## main.c

```
#include "global.h"
```

```
entry keywords[] = {
    {"div", DIV },
    {"mod", MOD },
    {0, 0} /* Schlusskennung */
};

void init() /* laedt die Modul-lokalen Schlueselworte in die
            Symboltabelle */
{
    entry *p;
    for (p= keywords; p->token; p++)
        insert(p->lexPtr, p->token);
}
```

## init.c

```

global.h  + X
#include <stdio.h>
#include <ctype.h>

#define BUFFERSIZE 128 /* Puffergroesse */
#define NONE -1
#define EOS '\0'

#define NUM 256
#define DIV 257
#define MOD 258
#define ID 259
#define DONE 260

int tokenValue; /* Lexem, Tokenwert */
int lineNo;


struct entry {
    char *lexPtr;
    int token;
};

extern struct entry symbolTable[];

int insert(char[], int);
void error(char *, int);
int lookup(char[]);
void init();
void parse();
int lexAnalyse();
void emit(int, int);
void expr();
void term();
void factor();
void match(int);

```

yylex();  
/\*falls generierter Lexer\*/



```

main.c  + X
#include "global.h"

int main()
{
    init();
    parse();
    return(0); /* erfolgreiche Terminierung */
}

```

```

init.c  + X
#include "global.h"

struct entry keywords[] = {
    { "div", DIV },
    { "mod", MOD },
    { 0, 0 }
};

void init() /* laedt die Schluesselworte in die Symboltabelle */
{
    struct entry *p;
    for (p= keywords; p->token; p++)
        insert(p->lexPtr, p->token);
}

```

```

global.h  ▢ ×
#include <stdio.h>
#include <ctype.h>

#define BUFFERSIZE 128 /* Puffergroesse */
#define NONE -1
#define EOS '\0'

#define NUM 256
#define DIV 257
#define MOD 258
#define ID 259
#define DONE 260

int tokenValue; /* Lexem, Tokenwert */
int lineNo;

struct entry {
    char *lexPtr;
    int token;
};

extern struct entry symbolTable[];

int insert(char[], int);
void error(char *, int);
int lookup(char[]);
void init();
void parse();
int lexAnalyse();
void emit(int, int);
void expr();
void term();
void factor();
void match(int);

```

```

symbol.c  ▢ ×
#include <string.h>
#include "global.h"

#define STRMAX 999 /* Größe des Lexem_arrays */
#define SYMMAX 999 /* Größe der Symboltabelle */

char lexemes[STRMAX];
int lastChar= -1; /* zuletzt benutzte lexemes-Position */

struct entry symbolTable[SYMMAX];
int lastEntry= 0; /* zuletzt benutzter SymbolTable-Eintrag */

int lookup(char s[]) /* liefert Index des Eintrages für s */
{
    int p;

    for (p=lastEntry; p>0; p= p-1)
        if (strcmp(symbolTable[p].lexPtr, s) == 0)
            return p;
    return 0;
}

int insert(char s[], int tok) /* */
{
    int len;
    len= strlen(s);

    if (lastEntry + 1 >= SYMMAX)
        error("interner Fehler: Symboltabelle voll, Anzahl von Einträgen >", SYMMAX);
    if (lastChar + len + 1 >= STRMAX)
        error("interner Fehler: LexemArray voll, Länge >", STRMAX);
    lastEntry++;
    symbolTable[lastEntry].token= tok;
    symbolTable[lastEntry].lexPtr= &lexemes[lastChar + 1];
    lastChar= lastChar + len + 1;
    strcpy(symbolTable[lastEntry].lexPtr, s);
    return lastEntry;
}

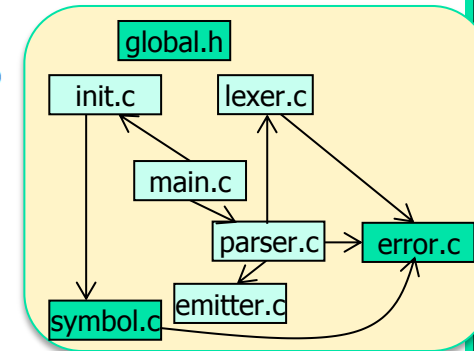
```

```

error.c  ▢ ×
#include "global.h"
#include <stdlib.h>
#include <ctype.h>

void error(char *n, int token)
{
    fprintf(stderr, "Zeile %d: %s: %c\n", lineNo, n, token);
    exit(1); /* keine erfolgreiche Terminierung */
}

```



```

parser.c  + x
#include "global.h"

int lookAhead;

void parse() /* analysiert und transformiert Ausdrücke */
{
    lookAhead= lexAnalyse();

    while (lookAhead != DONE) {
        expr(); match(';');
    }
}

void expr()
{
    int token;
    term();
    while (1)
        switch (lookAhead) {
            case '+':
            case '-': token= lookAhead;
                    match(lookAhead);
                    term();
                    emit(token, NONE);
                    continue;
            default: return;
        }
}

void term()
{
    int token;

    factor();
    while (1)
        switch (lookAhead) {
            case '*':
            case '/':
            case DIV:
            case MOD:
                token= lookAhead;
                match(lookAhead);
                factor();
                emit(token, NONE);
                continue;
            default: return;
        }
}

```

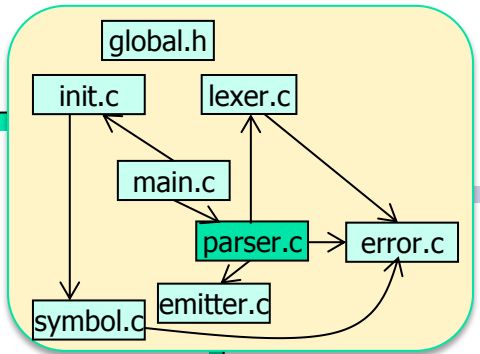
```

void term()
{
    int token;

    factor();
    while (1)
        switch (lookAhead) {
            case '*':
            case '/':
            case DIV:
            case MOD:
                token= lookAhead;
                match(lookAhead);
                factor();
                emit(token, NONE);
                continue;
            default: return;
        }
}

void factor()
{
    switch (lookAhead) {
        case '(':
            match('(');
            expr();
            match(')');
            break;
        case NUM:
            emit(NUM, tokenValue);
            match(NUM);
            break;
        case ID:
            emit(ID, tokenValue);
            match(ID);
            break;
        default:
            error("Syntaxfehler: illegales Symbol", lookAhead);
    }
}

```



```

void match(int token)
{
    if (lookAhead == token){
        if (token == ';') printf(";\n");
        lookAhead= lexAnalyse();
    }
    else
        error("Syntaxfehler", token);
}

```

```
#include "global.h"
```

```
char lexBuffer[BUFFERSIZE];  
int lineNo= 1;  
int tokenValue= NONE;
```

```
int lexAnalyse() /* Scanner */  
{
```

```
int c;
```

```
while (1)
```

```
{
```

```
c= getchar();
```

```
if (c == ' ' || c == '\t')
```

```
    /* Entfernung von Leerräumen */
```

```
else if (c == '\n')
```

```
    lineNo++;
```

```
else if ( isdigit(c) )
```

```
    /*number */
```

```
{
```

```
    ungetc (c, stdin);
```

```
    scanf("%d", &tokenValue);
```

```
    return NUM;
```

```
}
```

```
else if (isalpha(c))
```

```
{
```

```
int p, b =0;
```

```
while (isalnum(c))
```

```
{
```

```
lexBuffer[b]= c;
```

```
c= getchar();
```

```
b++;
```

```
if (b >= BUFFERSIZE)
```

```
    error("Fehler: Bezeichnerlänge größer als",BUFFERSIZE );
```

```
}
```

```
lexBuffer[b]= EOS;
```

```
if (c!= EOF)
```

```
    ungetc(c, stdin);
```

```
p= lookup(lexBuffer);
```

```
if (p==0)
```

```
    p= insert(lexBuffer, ID);
```

```
tokenValue= p;
```

```
return symbolTable[p].token;
```

```
}
```

```
else if (c==EOF)
```

```
    return DONE;
```

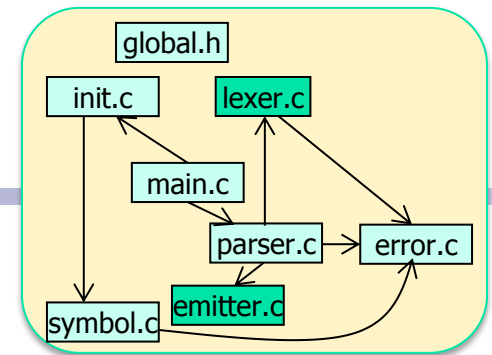
```
else {
```

```
tokenValue= NONE;
```

```
return c;
```

```
}
```

```
}
```



```
emitter.c
```

```
#include "global.h"
```

```
void emit(int token, int tokenValue) /* erzeugt die Ausgabe */
```

```
{
```

```
switch (token) {
```

```
case '+':
```

```
case '-':
```

```
case '*':
```

```
case '/': printf("%c\n", token);
```

```
break;
```

```
case DIV: printf("div\n");
```

```
break;
```

```
case MOD: printf("mod\n");
```

```
break;
```

```
case NUM: printf("%d\n", tokenValue);
```

```
break;
```

```
case ID: printf("%s\n", symbolTable[tokenValue].lexPtr);
```

```
break;
```

```
case ';': printf(";\n");
```

```
break;
```

```
default: printf("token %d, tokenValue %d\n", token, tokenValue);
```

```
}
```

```
}
```

# Makefile

make  
Realisierung von Übersetzung, ...

*Kürzel: zur Auszeichnung der ersten abhängigen Quelle, hier: emitter.c*

*Einsatz von gcc als Compiler, Linker, ...*

*alle Warnungen*

*Sprachstandard C-89*

*Fehleranzeigemodus*

```
CC = gcc  
CFLAGS = -Wall -std=c89 -pedantic
```

```
OBJECTS = emitter.o error.o init.o lexer.o main.o  
          parser.o symbol.o
```

*Angabe des Zielnamens  
c0*

```
c0: $(OBJECTS)  
    $(CC) $(CFLAGS) -o c0 $(OBJECTS)
```

*Symbolische Variable des Make-Kommandos*

*Name des verbundenen Programms  
als Ausgabe des Programmverbinders (Linker)*

make clean  
(Löschen generierter Dateien)

```
emitter.o: emitter.c global.h  
    $(CC) $(CFLAGS) -c $<  
  
error.o: error.c global.h  
    $(CC) $(CFLAGS) -c $<  
  
init.o: init.c global.h  
    $(CC) $(CFLAGS) -c $<  
  
lexer.o: lexer.c global.h  
    $(CC) $(CFLAGS) -c $<  
  
main.o: main.c global.h  
    $(CC) $(CFLAGS) -c $<  
  
parser.o: parser.c global.h  
    $(CC) $(CFLAGS) -c $<  
  
symbol.o: symbol.c global.h  
    $(CC) $(CFLAGS) -c $<  
  
clean:  
    rm -f *.o c0
```

*force: unter allen Umständen*