

# Compiler 1: Grundlagen

## Compile-Fluß und Front-End



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

WS 2012/13

Andreas Koch

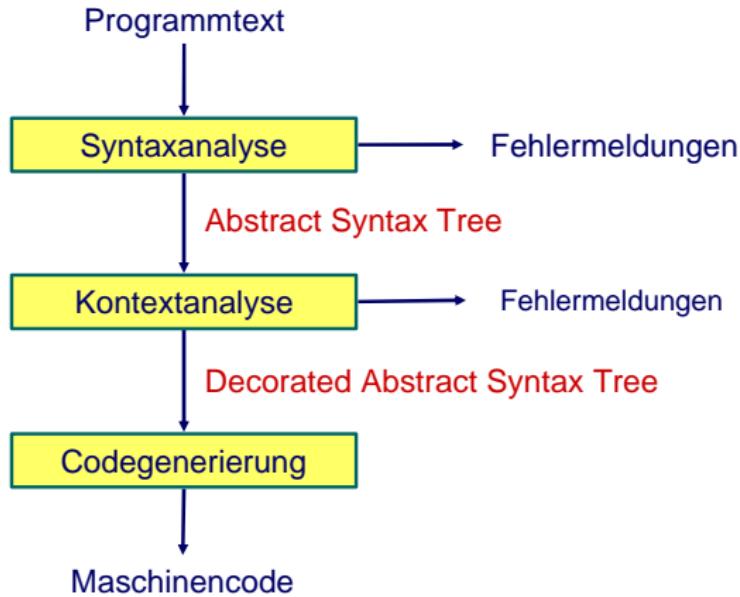
FG Eingebettete Systeme und ihre Anwendungen  
Informatik, TU Darmstadt

# Kompilierung

## Terminologie: Phase

- ▶ Transformationsschritte
  - ▶ Von Quellcode
  - ▶ ... zum Maschinencode
- ▶ Entspricht häufig den Teilen der Sprachspezifikation
  1. Syntax → Syntaxanalyse
  2. Kontextuelle Einschränkungen → Kontextanalyse
  3. Semantik → Codegenerierung

# Ablauf der Übersetzung 2

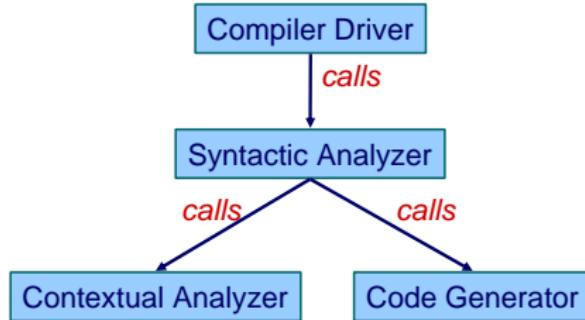


# Ablauf der Übersetzung 3

Terminologie: Durchgang (*pass*)

- ▶ Kompletter Durchgang des Programmes
- ▶ Läuft über Quelltext oder IR
- ▶ Pass *kann* Phase entsprechen
- ▶ ... muss aber nicht!
- ▶ Einzelter Pass kann mehrere Phasen durchführen
- ▶ Aufbau des Compilers wird von der Anzahl der Passes dominiert

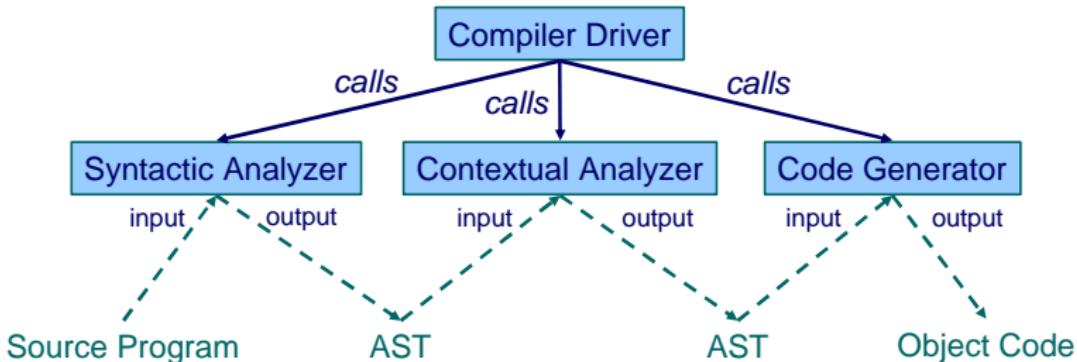
- ▶ Macht nur **einen** Pass über den Quelltext
  - ▶ Baut in der Regel **keine** echte IR auf
- ▶ Führt gleichzeitig aus
  - ▶ Syntaxanalyse (Parsing)
  - ▶ Kontextanalyse
  - ▶ Codegenerierung
- ▶ Pascal Compiler haben häufig Ein-Pass-Struktur



# Multi-Pass Compiler



- ▶ Macht mehrere Passes über das Program
  - ▶ Quelltext und IR
- ▶ Datenweitergabe zwischen Passes über IR



# Vergleich Ein-Pass ./ Multi-Pass-Compiler



	Ein-Pass	Multi-Pass
Laufzeit	+	-
Speicher	+ für große Prog.	+ für kleine Prog.
Modularität	-	+
Flexibilität	-	+
Globale Optim.	--	+
Eingabesprachen	Nicht für alle	

Müssen Bezeichner vor Verwendung  
deklariert werden?

# Beispiel Multi-Pass

Java-Compilierung **erfordert** mehrere Passes

```
class Example {  
    void inc() { n = n + 1; }  
    int n;  
    void use() { n = 0; inc(); }  
}
```

Beachte Reihenfolge Verwendung/Bindung von **n**!

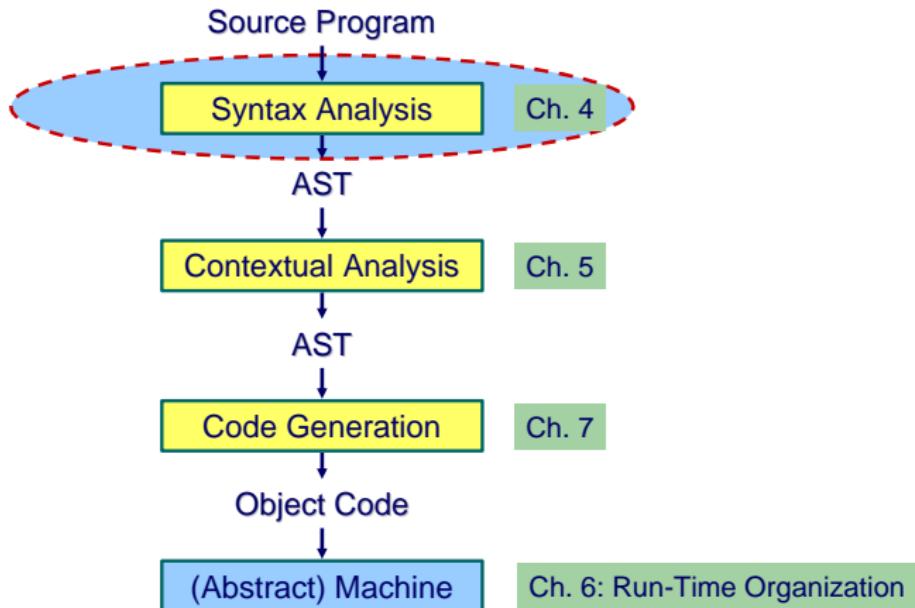
# Aufbau des Triangle-Compilers



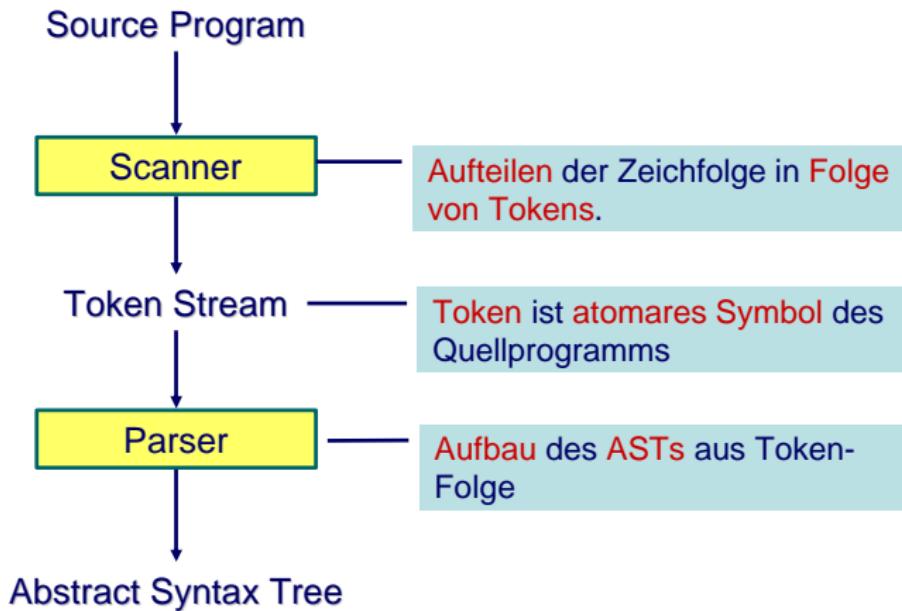
- ▶ Ein-Pass wäre für Triangle möglich
- ▶ Aus pädagogischen Gründen aber Multi-Pass

```
public class Compiler {  
    public static void compileProgram(...) {  
  
        Parser parser      = new Parser(...);  
        Checker checker   = new Checker(...);  
        Encoder generator = new Encoder(...);  
  
        Program theAST = parser.parse();  
        checker.check(theAST);  
        generator.encode(theAST);  
    }  
  
    public void main(String[] args) {  
        ...  
        compileProgram(...)  
    }  
}
```

# Syntaxanalyse



# Subphasen der Syntaxanalyse



## Beispielprogramm in Triangle

```
! Groesster Gemeinsamer Teiler
let func gcd(x: Integer, y: Integer) : Integer ~
    if x // y = 0                      ! // -> Modulo
    then y
    else gcd(y, x // y);
in putint(gcd(321,81))
```

Token-Folge: Ohne Leerzeichen, Zeilenvorschub und Kommentare

```
let func gcd ( x : Integer , y : Integer )
: Integer ~ Integer if x // y = 0 then y
else gcd ( y , x // y ) ; in putint ( gcd
( 321 , 81 ) )
```

- ▶ **Token** ist atomares Symbol des Programms
- ▶ Verwendet zwischen Scanner und Parser
- ▶ Kann auch aus mehreren Zeichen bestehen
- ▶ Zeichen selbst i.d.R. uninteressant, Ausnahmen:
  - ▶ Bezeichnernamen
  - ▶ Konstante Werte (Zahlen, Zeichen), sog. *Literale*
- ▶ ... Parser ist nur an der **Art** des Tokens interessiert

```
public class Token {  
    private byte kind;  
    private String spelling;  
  
    public Token(byte kind, String spelling) {  
        this.kind = kind;  
        this.spelling = spelling;  
    }  
}
```

Unterschiedliche Token haben eindeutige Werte

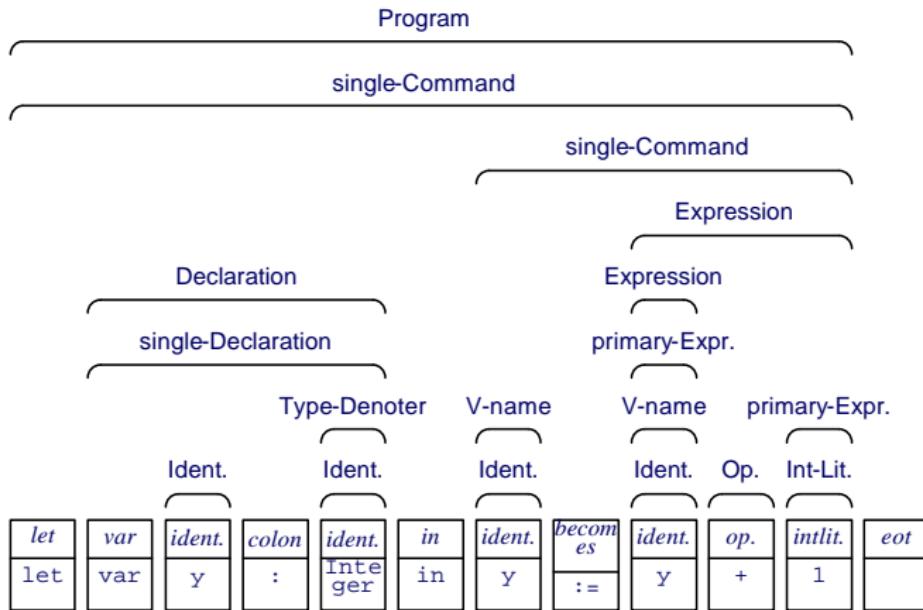
# Konstanten für Token-Arten



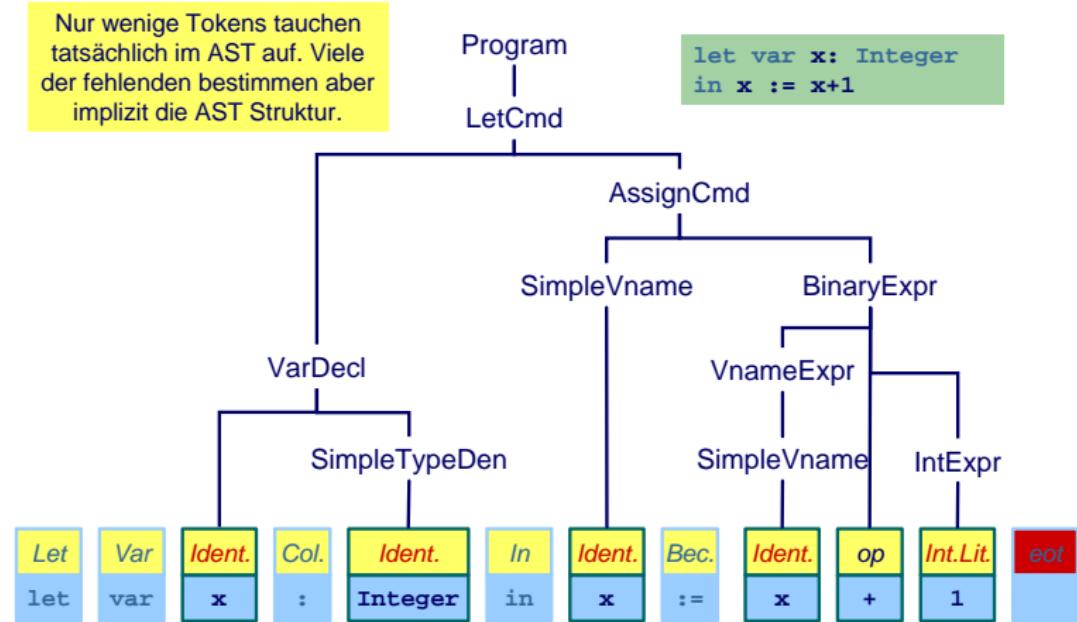
```
public class Token {  
    ...  
    public static final byte  
        IDENTIFIER = 0,  
        INTLITERAL = 1,  
        OPERATOR = 2,  
        BEGIN = 3,  
        ...  
        EOT = 20; // end-of-text  
}
```

Beispiel: `t = new Token(Token.OPERATOR, "+");`

# Parson der Token-Folge



# Aufbau des AST aus Token-Folge



- ▶ Kontextfreie Grammatiken (CFG)
- ▶ Spezifiziert durch  $(N, T, P, S)$
- ▶ CFG definiert Menge von Zeichenketten
  - ▶ Elemente sind *Sätze* bestehend aus Terminalsymbolen
  - ▶ Gesamtmenge ist *Sprache* der CFG
- ▶ Hier: Sätze haben eindeutige Phrasenstruktur
- ▶  $P$  häufig in Backus-Naur-Form (BNF) angegeben
- ▶ Übersichtlicher: Extended BNF
  - ▶ BNF + Reguläre Ausdrücke auf rechter Seite der Produktionen

# Beispiel: Produktionen in EBNF



BNF

```
Program ::= single-Command
Command ::= single-Command
           | Command ; single-Command
...
Expression ::= primary-Expression
            | Expression operator primary-Expression
```

EBNF

```
Command ::= single-Command ( ; single-Command)*
...
Expression ::= primary-Expression
              (operator primary-Expression)*
```

- ▶ Auch REs definieren eine Sprache
  - ▶ Reguläre Sprache
  - ▶ Weniger komplex als durch CFG beschreibbare Sprachen
- ▶ CFG erlaubt Beschreibung von Selbsteinbettung
  - ▶ Ausdruck  $a^* (b+c) / d$ bettet Ausdruck  $b+c$  ein
  - ▶ Vergleichbar dem Konzept der Rekursion
- ▶ REs erlauben **keine** Beschreibung von Selbsteinbettung

Ziel: Systematische Herleitung von Parsern aus CFG



## Hilfsmittel

- ▶ CFG kann transformiert (umgestellt) werden
- ▶ ... unter Beibehaltung der beschriebenen Sprache

- ▶ Zusammenfassen von Produktionen mit gleichem Nicht-Terminal auf linker Seite
  - ▶ *Left-Hand Side* (LHS), analog RHS

## Vor Transformation

$$\begin{aligned}\mathbf{S} &::= \mathbf{X} + \mathbf{S} \\ \mathbf{S} &::= \mathbf{X} \\ \mathbf{S} &::= \varepsilon\end{aligned}$$

## Nach Gruppierung

$$\mathbf{S} ::= \mathbf{X} + \mathbf{S} | \mathbf{X} | \varepsilon$$

# Grammatik-Transformation durch Linksausklammern



- ▶ Zusammenfassen von gleichen Anfängen in einer Produktion
- ▶  $X Y \mid X Z \rightarrow X(Y|Z)$

Beispiel:



```
cmd  := if Expr then cmd
      | if Expr then cmd else cmd

cmd  := if Expr then cmd ( $\epsilon$  | else cmd)
```

# Beseitigung von Linksrekursion



- ▶ Linksrekursion in Produktion
  - ▶  $N ::= X \mid N Y$
  - ▶  $L(N) = \{X, XY, XYY, XXXY, XYYYY, \dots\}$
- ▶ Ersetzung durch
  - ▶  $N ::= X(Y)^*$

Beispiel:



```
Identifier ::= Letter
             | Identifier Letter
             | Identifier Digit
```

```
Identifier ::= Letter (Letter | Digit)*
```

## Vor Transformation

$$\mathbf{N} ::= \mathbf{X}_1 \mid \dots \mid \mathbf{X}_m \mid \mathbf{N} \mathbf{Y}_1 \mid \dots \mid \mathbf{N} \mathbf{Y}_n$$

## Nach Linksausklammern

$$\mathbf{N} ::= (\mathbf{X}_1 \mid \dots \mid \mathbf{X}_m) \mid (\mathbf{N}(\mathbf{Y}_1 \mid \dots \mid \mathbf{Y}_n))$$

## Nach Beseitigen der Linksrekursion

$$\mathbf{N} ::= (\mathbf{X}_1 \mid \dots \mid \mathbf{X}_m)(\mathbf{Y}_1 \mid \dots \mid \mathbf{Y}_n)^*$$

- ▶ Wenn **N** ::= **X** einzige Produktion mit LHS **N** ist
- ▶ ... **N** durch **X** in RHS aller Produktionen ersetzen

Beispiel:

## Vor Transformation

single-Declaration ::= **var** Identifier : Type-denoter | ...

Type-denoter ::= Identifier

## Nach Ersetzung

single-Declaration ::= **var** Identifier : Identifier | ...

## Aber ...

Solche "überflüssigen" Nicht-Terminals können nützlichen Dokumentationscharakter für den menschlichen Leser haben!

# Nutzen von Grammatiktransformationen



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Hier auf den ersten Blick noch nicht erkennbar
- ▶ Erlauben kompaktere und lesbarere Beschreibung von CFGs
- ▶ **Sehr nützlich** bei der Konstruktion von Parsern für CFGs

**Erkennung:** Entscheidung, ob ein Eingabetext ein Satz der Grammatik  $G$  ist.

**Parsing:** Erkennung und zusätzlich Bestimmung der Phrasen-Struktur

- ▶ Beispiel: Durch *konkreten* Syntaxbaum

**Eindeutigkeit:** Eine Grammatik ist eindeutig falls jeder Eingabetext auf maximal eine Weise geparsed werden kann,

- ▶ Ein syntaktisch korrekter Eingabetext hat genau einen eindeutigen Syntaxbaum

- ▶ Zwei wesentliche Verfahren
- ▶ Unterscheiden sich in der Art ihres Vorgehens

Top-Down Beispiel: Rekursiver Abstieg

Bottom-Up Beispiel: Shift/Reduce

# Beispiel: Micro-English

## Produktionen

```
Sentence ::= Subject Verb Object .
Subject ::= I | a Noun | the Noun
Object ::= me | a Noun | the Noun
Noun ::= cat | mat | rat
Verb ::= like | is | see | sees
```

## Beispiele der erzeugten Sprache

```
the cat sees a rat .
I like the cat .
the cat see me .
I like me .
a rat like me .
```

## Vorgehensweise

- ▶ Untersuche Eingabetext zeichenweise, von links nach rechts
- ▶ Baue Syntaxbaum von **unten nach oben** auf
  - ▶ Von den Terminalzeichen in den Blättern
  - ▶ ... zum  $S$  Nicht-Terminal in der Wurzel

## Zwei Arten von Aktionen

**Shift** Lese Zeichen ein

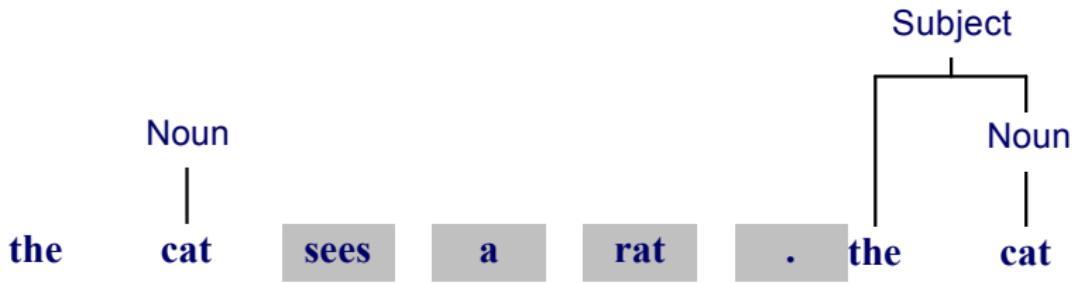
- ▶ Zusätzlich: Und lege es auf dem Stack ab

**Reduce** Erkenne ein Nicht-Terminal LHS der Produktion  $p$

- ▶ Zusätzlich: Oberste Elemente des Stapels müssen RHS von  $p$  entsprechen, ersetze durch LHS von  $p$  (Zusammenfassen)
- ▶ Ende wenn Startsymbol  $S$  erreicht und Eingabetext komplett gelesen

# Beispiel Bottom-Up Parsing

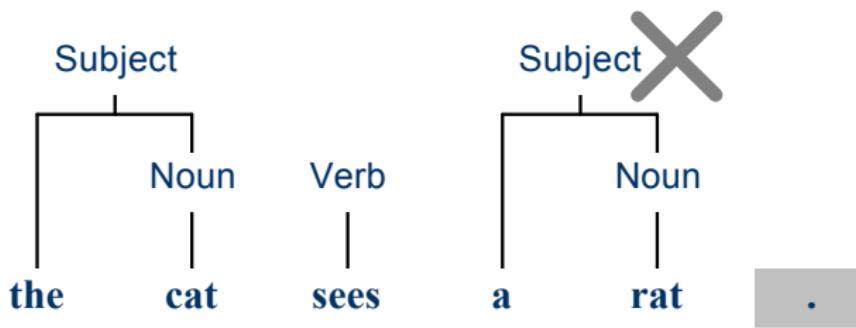
the cat sees a rat .



```
Sentence ::= Subject Verb Object .
Subject  ::= I | a Noun | the Noun
Object   ::= me | a Noun | the Noun
Noun    ::= cat | mat | rat
Verb     ::= like | is | see | sees
```

# Schwierigkeit bei Bottom-Up Parsing

Welche Produktion beim Zusammenfassen anwenden?



Lösung: Nicht nur bekannte Zeichen betrachten, sondern auch noch Zustand ("schon Subject gesehen") einbeziehen.  
... aber hier nicht weiter vertieft!

## Vorgehensweise

- ▶ Untersuche Eingabetext zeichenweise, von links nach rechts
- ▶ Baue Syntaxbaum von **oben nach unten** auf
  - ▶ Vom Start-Nicht-Terminal  $S$  in der Wurzel
  - ▶ ... zu den Terminalzeichen in den Blättern

## Aktion

- ▶ Expandiere jeweils das am weitestens links gelegene Nicht-Terminal **N**
- ▶ ... durch Anwendung einer Produktion **N ::= X**
- ▶ Wähle Produktion aus durch Betrachten der nächsten  $n$  Zeichen des Eingabetextes (Annahme hier:  $n = 1$ )
- ▶ Falls keine Produktion auf Zeichen passt → Fehler!
- ▶ Ende wenn Eingabetext komplett gelesen und kein unexpandiertes Nicht-Terminal mehr existiert

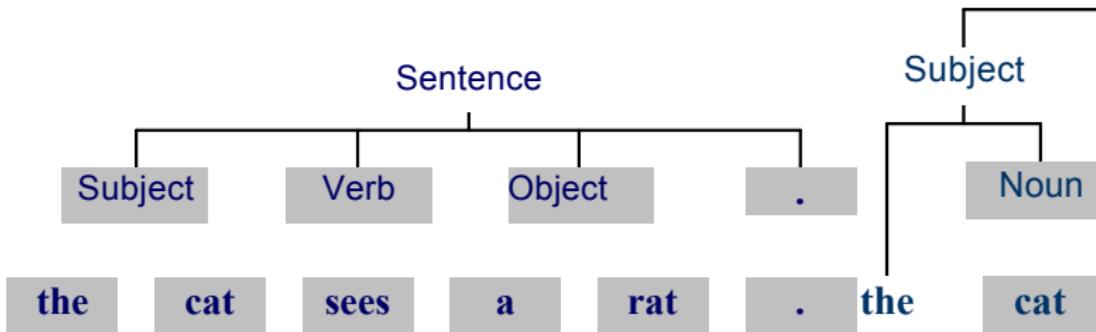
# Beispiel Top-Down Parsing

the cat sees a rat .

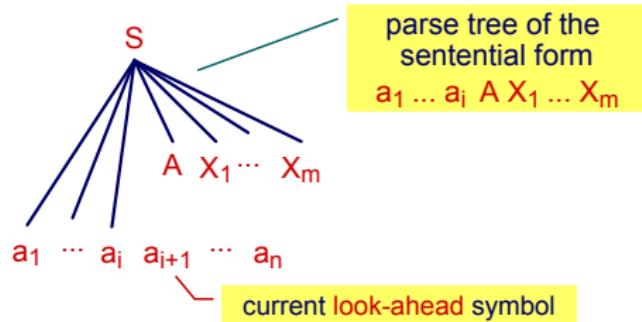


TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

```
Sentence ::= Subject Verb Object .
Subject  ::= I | a Noun | the Noun
Object   ::= me | a Noun | the Noun
Noun     ::= cat | mat | rat
Verb     ::= like | is | see | sees
```



# Hintergrund Top-Down Parsing



Falls es möglich ist,

- ▶ ... bei Betrachten der nächsten  $k$  Zeichen des Textes
- ▶ ... immer die richtige Produktion zu finden

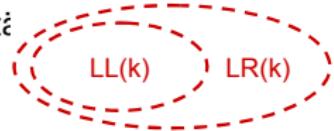
dann ist die Grammatik  $LL(k)$

- ▶ L: Lese Eingabetext von **links nach rechts**
- ▶ L: Leite immer vom am weitesten **links** stehenden Nicht-Terminal ab.

# Vergleich Top-Down mit Bottom-Up Parsing



- ▶ Probleme mit Top-Down-Parsing
  - ▶ Konstruktion einer LL( $k$ ) Grammatik für die gewünschte Sprache gelegentlich mühsam
  - ▶ Linksausklammern und Beseitigen von Linksrekursion können Lesbarkeit der Grammatik erschweren
- ▶ Lösung: Bottom-Up-Parsing mit LR( $k$ )-Techniken
  - ▶ L: Lese Eingabetext von **links nach rechts**
  - ▶ R: Fasse die am weitesten **rechts** stehenden Terminal-Symbole zusammen und baue den Baum **rückwärts** auf
  - ▶ Mächtigeres Beschreibungsinstrument als LL( $k$ )
  - ▶ Nachteil: Parsing-Vorgang komplexer und schlechter verständlich



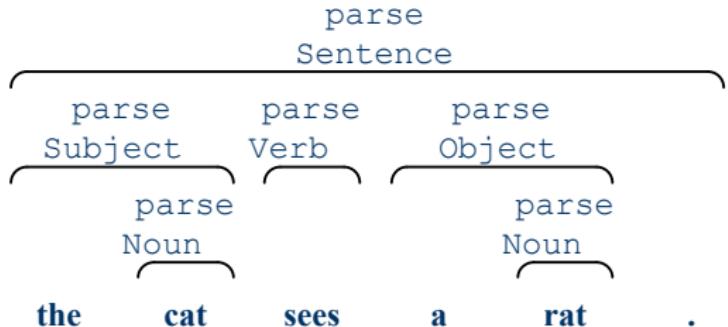
# Parson mit rekursivem Abstieg



Einfache Implementierung der Top-Down Strategie, Idee:

- ▶ Struktur des konkreten Syntaxbaumes (Parse-Baum) entspricht
- ▶ ... Aufrufmuster von sich wechselseitig aufrufenden Prozeduren
- ▶ Für jedes Nicht-Terminal **XYZ** existiert
- ▶ ... Parse-Prozedur **parseXYZ**, die genau dieses Nicht-Terminal parst

Beispiel:



# Beispiel für Micro-English 1



Sentence ::= Subject Verb Object .

```
protected void parseSentence() {  
    parseSubject();  
    parseVerb();  
    parseObject();  
    accept(".");  
}
```

accept(t) prüft, ob aktuelles Token das erwartete Token t ist.

# Beispiel für Micro-English 2



Subject ::= I | a Noun | the Noun

```
protected void parseSubject() {  
    if (currentToken matches "I") {  
        accept("I");  
    } else if (currentToken matches "a") {  
        accept("a");  
        parseNoun();  
    } else if (currentToken matches "the") {  
        accept("the");  
        parseNoun();  
    } else  
        report a syntax error  
}
```

Die Methode muß immer anhand von currentToken die passende Alternative auswählen können.

# Beispiel für Micro-English 3



```
public class MicroEnglishParser {  
    protected Token currentToken;  
  
    public void parse() {  
        currentToken = first token;  
        parseSentence();  
        check that no token follows the sentence  
    }  
  
    protected void accept(Token expected) { ... }  
    protected void parseSentence() { ... }  
    protected void parseSubject() { ... }  
    protected void parseObject() { ... }  
    protected void parseNoun() { ... }  
    protected void parseVerb() { ... }  
}
```

```
public class MicroEnglishParser {  
    protected Token currentToken;  
    public void parse() {  
        currentToken = first token;  
        parseSentence();  
        check that no token follows the sentence  
    }  
    protected void accept(Token expected) { ... }  
    protected void parseSentence() { ... }  
    protected void parseSubject() { ... }  
    protected void parseObject() { ... }  
    protected void parseNoun() { ... }  
    protected void parseVerb() { ... }  
}
```

- ▶ **currentToken** enthält nacheinander die Tokens des Eingabetextes
- ▶ Ablauf einer Methode **parseN**
  - ▶ Bei Eintritt enthält **currentToken** eines der Token, **mit denen N** beginnen kann
  - ▶ ... sonst wäre eine andere Parse-Methode aufgerufen werden (oder Syntaxfehler)
  - ▶ Bei Austritt enthält **currentToken** das auf die **N**-Phrase folgende Token
- ▶ Ablauf der Methode **accept (t)**
  - ▶ Bei Eintritt muß **currentToken = t** sein
  - ▶ ... sonst Syntaxfehler
  - ▶ Bei Austritt enthält **currentToken** das auf **t** folgende Token

## Entwicklung von Parsern mit rekursivem Abstieg

1. Formuliere Grammatik (CFG) in EBNF
  - ▶ Eine Produktion pro Nicht-Terminal
  - ▶ Beseitige **immer** Linksrekursion
  - ▶ Klammere gemeinsame Teilausdrucks nach links aus wo **möglich**
2. Erstelle Klasse für den Parser mit
  - ▶ **protected** Variable **currentToken**
  - ▶ Schnittstellenmethoden zum Scanner
    - ▶ **accept (t)** und **acceptIt ()**
  - ▶ **public** Methode **parse**, welche ...
    - ▶ erstes Token via Scanner aus dem Eingabetext liest
    - ▶ die Parse-Methode des Start Nicht-Terminals  $S$  der CFG aufruft
3. Implementiere **protected** Parsing-Methoden
  - ▶ Methode **parseN** für jedes Nicht-Terminalsymbol  $N$

## starters[[X]] mit RE X

Menge aller Terminal-Symbole, die am Anfang einer aus X herleitbaren Zeichenkette stehen können.

Beispiele

$$\text{starters}[[\mathbf{ab}]] = \{\mathbf{a}\}$$

$$\text{starters}[[\mathbf{a}|\mathbf{b}]] = \{\mathbf{a}, \mathbf{b}\}$$

$$\text{starters}[[\mathbf{(re)*set}]] = \{\mathbf{r}, \mathbf{s}\}$$

# Berechnungsregeln für starters[[X]]



$$\text{starters}[[\varepsilon]] = \{\}$$

$$\text{starters}[[t]] = \{t\}$$

$$\text{starters}[[XY]] = \begin{cases} \text{starters}[[X]] : \text{falls aus } X \text{ kein } \varepsilon \text{ herleitbar} \\ \text{starters}[[X]] \cup \text{starters}[[Y]] : \text{sonst} \end{cases}$$

$$\text{starters}[[X|Y]] = \text{starters}[[X]] \cup \text{starters}[[Y]]_{\text{noch nicht ganz richtig!}}$$

$$\text{starters}[[X^*]] = \text{starters}[[X]]_{\text{ditto!}}$$

$$\text{starters}[[N^*]] = \text{starters}[[X]], \text{wenn } N ::= X \text{ ditto!}$$

Ausbügeln der Ungenauigkeiten später (siehe Folie 51)

# Inhalt der `parseN`-Methoden

Annahme: **N** ::= **X**, nun schrittweise Zerlegung von **X**

```
ε ; (=leere Anweisung)
t accept(t);
P parseP();
P|Q parseP();
    parseQ();
P|Q if (currentToken ∈ starters[[P]]) was bei P = ε?
        parseP();
    else if (currentToken ∈ starters[[Q]])
        parseQ();
    else
        melde Syntaxfehler
P* while (currentToken ∈ starters[[P]])
        parseP();
```

Analog:  $\text{follow}[[\mathbf{X}]]$  ist Menge der Tokens, die in der CFG nach  $\mathbf{X}$  folgen können.

Beispiel

$$\begin{array}{lll} \mathbf{N} & ::= & \mathbf{XY} \\ \mathbf{X} & ::= & \mathbf{a} \mid \mathbf{b} \\ \mathbf{Y} & ::= & \mathbf{c} \mid \mathbf{d} \\ \text{follow}[[\mathbf{N}]] & ::= & \{\} \\ \text{follow}[[\mathbf{X}]] & ::= & \{\mathbf{c}, \mathbf{d}\} \\ \text{follow}[[\mathbf{Y}]] & ::= & \{\} \end{array}$$

# Anwendbarkeit der Zerlegungsregeln



Funktionieren nur dann, wenn in Grammatik  $G$  gilt:

- ▶ Falls  $G \ X|Y$  enthält und sich weder  $X$  noch  $Y$  zu  $\varepsilon$  ableiten lassen:  
 $\text{starters}[[X]] \cap \text{starters}[[Y]] = \emptyset$
  - ▶ Falls  $G \ X|Y$  enthält und sich beispielsweise  $Y$  zu  $\varepsilon$  ableiten lässt:  
 $\text{starters}[[X]] \cap (\text{starters}[[Y]] \cup \text{follow}[[X|Y]]) = \emptyset$
  - ▶ Falls  $G \ X^*$  enthält:  $\text{starters}[[X]] \cap \text{follow}[[X^*]] = \emptyset$
- Wenn alles gilt:  $G$  ist  $\text{LL}(k)$  mit  $k = 1$

Hinweis: Definition in PLPJ, p. 104 ist nicht ausreichend!

## Bisher gezeigt für $P|Q$

```
if (currentToken ∈ starters[[P]])  
    parseP();  
else if (currentToken ∈ starters[[Q]])  
    parseQ();  
else  
    melde Syntaxfehler
```

Problematisch, wenn  $\varepsilon$  aus  $P$  oder  $Q$  ableitbar.

Korrekt: Verwende statt  $\text{starters}[[X]]$

$$\text{dirset}[[X]] = \begin{cases} \text{starters}[[X]] & : \text{falls aus } X \text{ kein } \varepsilon \text{ herleitbar} \\ \text{starters}[[X]] \cup \text{follow}[[X]] & : \text{sonst} \end{cases}$$

Analog für  $P^*$ . Korrigiere so Folie 48.

# Beispiel für nicht-LL(1) Grammatik



- ▶ Aus Algol Grammatik

**Block ::= begin Declaration ( ; Declaration)\* ; Command end**

- ▶ Prüfe Regel für  $X^*$

- ▶ starters[["; Declaration"]] = { ; }
- ▶ follow[["(; Declaration)\*"]] = { ; }
- ▶ starters[["; Declaration"]]  $\cap$  follow[["(; Declaration)\*"]]  
 $\neq \emptyset$

- ▶ Produktion ist aber transformierbar

**Block ::= begin Declaration ; (Declaration ;)\* Command end**

- ▶ Annahme: starters[["Declaration ;"]]  $\cap$  starters[["Command"]] =  $\emptyset$

## Annahme bis 1992

Rekursiver Abstieg funktioniert sinnvoll nur für  $k = 1$ , exponentieller Worst-Case-Aufwand bei  $k > 1$ .

## Gegenbeispiel 1992: PCCTS (jetzt ANTLR)

Worst-case kann für Grammatiken typischer Programmiersprachen in der Regel vermieden werden, sogar bei  $k = \infty$ .

- ▶ Konstruktion von Top-Down-Parsern gut automatisierbar
- ▶ Für Java beispielsweise
  - ▶ ANTLR: LL( $k$ ) bis LL(\*)
  - ▶ JavaCC: LL( $k$ )

# Parser für Mini-Triangle: parseCommand

```
Command      ::= single-Command ( ; single-Command)*
```

```
protected Command parseCommand() {  
    parseSingleCommand();  
    while (currentToken.kind == Token.SEMICOLON) {  
        acceptIt();  
        parseSingleCommand();  
    }  
}
```

## acceptIt()

- ▶ Könnte auch `accept (Token.SEMICOLON)` sein
- ▶ Würde aber überflüssige Fehlerüberprüfung vornehmen
  - ▶ Token wurde schon vorher in `while(...)` geprüft
- ▶ Also ohne weitere Bearbeitung akzeptieren

# Parser für Mini-Triangle: parseSingleCommand



```
single-Command ::= Identifier ( := Expression
                                | ( Expression ) )
                                |
                                ...
```

```
protected void parseSingleCommand() {
    switch (currentToken.kind) {
        case Token.IDENTIFIER: {
            parseIdentifier();
            switch (currentToken.kind) {
                case Token.BECOMES: {
                    acceptIt();
                    parseExpression();
                    break;
                }
                case Token.LPAREN: {
                    acceptIt();
                    parseExpression();
                    accept(Token.RPAREN);
                    break;
                }
                default: report a syntactic error
            }
            break;
        }
        ...
    }
}
```

Weitere Beispiele in PLPJ.

- ▶ Aufpassen bei
    - ▶ `parseIdentifier`
    - ▶ `parseIntegerLiteral`
    - ▶ `parseOperator`
  - ▶ ... hier nicht nur **Art** des Tokens relevant
  - ▶ sondern **tatsächlicher** Text
    - ▶ `Token.IDENTIFIER`: foo, bar, pi, k9, ...
    - ▶ `Token.INTLITERAL`: 23, 42, 2006, ...
    - ▶ `Token.OPERATOR`: +, -, /, ...
- Eingabetext nicht nur auf Token-**Art** reduzieren, Text selbst muß **erhalten** bleiben

# Häufige Fehler: Grammatik ist nicht LL(1)



## Auszug aus Grammatik

```
single-Command ::= V-name := Expression
                  | Identifier ( Expression )
                  | if Expression then single-Command
                    else single-Command
                  | ...
```

## Anfangsmengen

```
starters[[ V-name := Expression ]] = starters[[ V-name ]]
                                         = { Identifier }
starters[[Identifier ( Expression )]] = { Identifier }
starters[[ if Expression then ... ]] = { if }
```

# Häufige Fehler: Grammatik ist nicht LL(1)



## Durch Zerlegung gewonnener Java-Code

```
private void parseSingleCommand () {
    switch (currentToken.kind) {

        case Token.IDENTIFIER: {
            parseVname();
            accept(Token.BECOMES);
            parseExpression(); }
            break;

        case Token.IDENTIFIER: {
            parseIdentifier();
            accept(Token.LPAREN);
            parseExpression();
            accept(Token.RPAREN)

        }
            break;
        case Token.IF:
            ...
        default:
            ...
    }
}
```

# Häufige Fehler: Linksausklammern vergessen



Auszug aus Grammatik nach Ersetzen von **V-name** durch **Identifier**

```
single-Command ::= Identifier := Expression
                  | Identifier ( Expression )
                  | if Expression then single-Command
                    else single-Command
```

Anfangsmengen

```
starters[[ Identifier := Expression ]] = { Identifier }
starters[[ Identifier ( Expression ) ]] = { Identifier }
```

# Häufige Fehler: Linksausklammern vergessen



Jetzt mit Linksausklammern

```
single-Command ::= Identifier ( := Expression | ( Expression ) )
                  | if Expression then single-Command
                     else single-Command
```

Neue Anfangsmengen

```
starters[[ := Expression ]] = { := }
starters[[ ( Expression ) ]] = { ( }
```

# Häufige Fehler: Linksrekursion nicht beseitigt



Auszug aus Grammatik vor Korrektur

```
Command ::= single-Command
          | Command ; single-Command
```

Anfangsmengen

```
starters[[ single-Command ]]
= { Identifier, if, while, let, begin }

starters[[ Command ; single-Command ]]
= { Identifier, if, while, let, begin }
```

# Häufige Fehler: Linksrekursion nicht beseitigt



## Java-Code

```
private void parseCommand () {
    switch (currentToken.kind) {

        case Token.IDENTIFIER:
        case Token.IF:
        case Token.WHILE:
        case Token.LET:
        case Token.BEGIN:
            parseSingleCommand();
            break;

        case Token.IDENTIFIER:
        case Token.IF:
        case Token.WHILE:
        case Token.LET:
        case Token.BEGIN:  {
            parseCommand();
            accept (Token.SEMICOLON)
            parseSingleCommand();
        }
            break;

        default:
            report a syntactic error
    }
}
```

# Parser für Mini-Triangle: Grammatikanpassung



Program	$::= \text{single-Command}$
Command	$::= \text{single-Command}$ $\mid \text{Command ; single-Command}$
single-Command	$::= \text{V-name} := \text{Expression}$ $\mid \text{Identifier ( Expression )}$ $\mid \dots$

Program	$::= \text{single-Command}$
Command	$::= \text{single-Command}$ $\mid \text{Command ; single-Command}$
single-Command	$::= \text{V-name} := \text{Expression}$ $\mid \text{Identifier ( Expression )}$ $\mid \dots$

- ▶ Parser mit rekursivem Abstieg baut impliziten Syntaxbaum auf
  - ▶ Durch den Aufrufgraph der Parse-Methoden
- ▶ In einem Ein-Pass-Compiler unproblematisch
- ▶ Reicht nicht für Multi-Pass Compiler
  - ▶ Weitergabe der Daten zwischen Passes erforderlich

# Abstrakte Syntaxbäume 2



- ▶ Beobachtung: Jedes Nicht-Terminalsymbol **XYZ** wird durch eine Parse-Methode **parseXYZ** bearbeitet
  - protected void parseXYZ ( )**
  - ▶ Bisher nicht benutzt: Funktionsergebnis und Parameter
- ▶ Idee: Ausnutzung der Möglichkeiten zum Aufbau eines AST

# AST Knoten von Mini-Triangle



Program	$\ ::= \text{Command}$	Program	$\ ::= \text{C}$
Command	$\ ::= \text{Command} ; \text{Command}$   V-name := Expression   Identifier ( Expression )   if Expression then single-Command else single-Command   while Expression do single-Command   let Declaration in single-Command	SequentialCmd AssignCmd CallCmd IfCmd WhileCmd LetCmd	$\ ::= \text{C}$ V Id i w l
Expression	$\ ::= \text{Integer-Literal}$   V-name   Operator Expression   Expression Operator Expression	IntegerExpr VnameExpr UnaryExpr BinaryExpr	$\ ::= \text{In}$ V O E
V-name	$\ ::= \text{Identifier}$	SimpleVname	$\ ::= \text{Id}$
Declaration	$\ ::= \text{Declaration} ; \text{Declaration}$   const Identifier ~ Expression   var Identifier : Type-denoter	SeqDecl ConstDecl VarDecl	$\ ::= \text{D}$ c v
Type-denoter	$\ ::= \text{Identifier}$	SimpleTypeDen	$\ ::= \text{Id}$

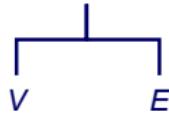
# Sub-ASTs von Mini-Triangle

Command	::= Command ; Command	SequentialCmd
	V-name := Expression	AssignCmd
	Identifier ( Expression )	CallCmd
	if Expression then single-Command	IfCmd
	else single-Command	
	while Expression do single-Command	WhileCmd
	let Declaration in single-Command	LetCmd

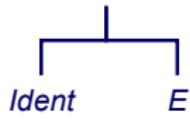
SequentialCmd



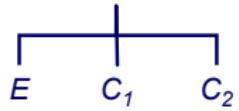
AssignCmd



CallCmd



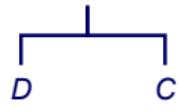
IfCmd



WhileCmd



LetCmd



- ▶ Abstrakte Basisklasse

```
public abstract class AST { ... }
```

- ▶ Eigene Subklassen für alle Arten von AST-Knoten

Jede Subklasse hat Instanzvariablen für ihre Unterknoten

```
public class Program extends AST {  
    public Command C;  
    ...  
}
```

Abstrakte Basisklasse aller **Command** AST-Knoten

```
public abstract class Command extends AST {
```

# Unterklassen der Command-Klasse



```
abstract class Command  
extends AST { ... }
```

Command  
::= Command ; Command  
| V-name := Expression  
| Identifier ( Expression )  
| if Expression then single-Command  
| | else single-Command  
| while Expression do single-Command  
| let Declaration in single-Command

SequentialCmd  
AssignCmd  
CallCmd  
IfCmd  
WhileCmd  
LetCmd

```
public class SequentialCmd extends Command {  
    public Command c1, c2;  
    ...  
}  
public class AssignCmd extends Command {  
    public Vname v;  
    public Expression e;  
    ...  
}  
public class CallCmd extends Command {  
    public Identifier i;  
    public Expression e;  
    ...  
}  
public class IfCmd extends Command {  
    public Expression e;  
    public Command c1, c2;  
    ...  
}
```



Die AST Subklassen haben  
auch entsprechende  
Konstruktoren zur korrekten  
Initialisierung der Objekte.

etc.

# Sonderfall: Terminal-Knoten



- ▶ Blätter des ASTs, hier ist **Text** des Tokens relevant
- ▶ Bezeichner, Zahlen, Operatoren

## Abstrakte Superklasse aller Terminal-Knoten

```
public abstract class Terminal extends AST {  
    public String spelling;  
    ...  
}
```

## Konkrete Unterklasse für Bezeichner

```
public class Identifier extends Terminal {  
    public Identifier (String spelling) {  
        this.spelling = spelling;  
    }  
}
```

- ▶ Während des rekursiven Abstiegs
- ▶ Idee: `parseN`-Methode liefert AST für **N**-Phrase
- ▶ AST für **N**-Phrase wird durch Zusammensetzen der ASTs der Subphrasen erstellt

## Beispiel für Produktion **N ::= X**

```
protected ASTN parseN () {  
    ASTN itsAST;  
    Parse X, sammle Subphrasen-ASTs in itsAST  
    return itsAST  
}
```

## EBNF

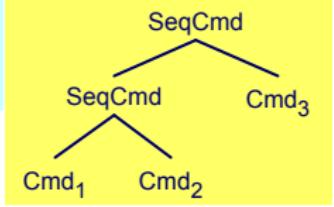
**Command ::= single-Command ( ; single-Command)\***

## AST

**Command ::= Command ; Command**

SequentialCmd

```
protected Command parseCommand() {  
    Command c1AST = parseSingleCommand();  
    while (currentToken.kind == Token.SEMICOLON) {  
        acceptIt();  
        Command c2AST = parseSingleCommand();  
        c1AST = new SequentialCmd(c1AST, c2AST);  
    }  
    return c1AST;  
}
```



# Zusammensetzen von Subphrasen ASTs 2



```
public Declaration parseSingleDeclaration() {
    Declaration declAST;
    switch (currentToken.kind) {
        case Token.CONST: {           single-Declaration ::= const Identifier ~ Expression
            acceptIt();
            Identifier iAST = parseIdentifier();
            accept(Token.IS);
            Expression eAST = parseExpression();
            declAST = new ConstDeclaration(iAST, eAST);
        } break;
        case Token.VAR: {             single-Declaration ::= var Identifier : Type-denoter
            acceptIt();
            Identifier iAST = parseIdentifier();
            accept(Token.COLON);
            TypeDenoter tAST = parseTypeDenoter();
            declAST = new VarDeclaration(iAST, tAST);
        } break;
        default:
            meld Syntaxfehler
    }
    return declAST;
}
```

# Scanning - Woher kommen die Tokens?



Zwei relevante Methoden im Parser

```
public class Parser {
    Token currentToken;

    protected void accept(byte expectedKind) {
        if (currentToken.kind == expectedKind)
            currentToken = scanner.scan();
        else
            report syntax error
    }

    protected void acceptIt() {
        currentToken = scanner.scan();
    }

    ...
}
```

- ▶ Auch genannt lexikalische Analyse oder Lexer
- ▶ Ähnlich Parsing, aber auf einer Ebene feinerer Details
  - ▶ Parser: Arbeitet mit Tokens, die zu Phrasen gruppiert werden
  - ▶ Scanner: Arbeitet mit Zeichen, die zu Tokens gruppiert werden
- ▶ Aufgaben des Scanners
  - ▶ Bilde Tokens aus Zeichen
  - ▶ Entferne unerwünschte Leerzeichen, Zeilenvorschübe, etc. (white space)
  - ▶ Führe Buch über Zeilennummern und Eingabedateinamen

Tokens werden durch REs definiert, bestehend aus:

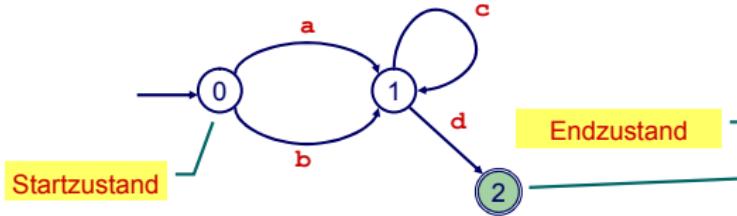
- ▶ Einzelzeichen
- ▶ Operatoren
  - ▶ Konkatenation: **A B**
  - ▶ Alternative: **A | B**
  - ▶ Optionalität: **A?**
  - ▶ Wiederholung: **A\***
  - ▶ Vordefinierte REs (sog. Macros)
- ▶ **aber:** keine rekursiven Definitionen

# Darstellung von Scannern als endliche Automaten



- ▶ Reguläre Ausdrücke können durch Übergangsdiagramme dargestellt werden
  - ▶ Endliche Automaten
  - ▶ Kanten/Transitionen beschriftet mit Eingabesymbolen
  - ▶ Zustände/Knoten
    - ▶ Genau ein Startzustand
    - ▶ Beliebig viele Endzustände (akzeptierende Zustände)

Beispiel: **(a | b) c\* d**



# Alternative: Rekursiver Abstieg



## Systematische Konstruktion von Scannern

1. Formuliere lexikalische Grammatik in EBNF
  - ▶ Falls nötig: Transformiere für rekursiven Abstieg
2. Implementiere Scan-Methoden `scanN` für jede Produktion  $N ::= X$ , mit Rumpf passend zu  $X$
3. Implementiere Scanner-Klasse, bestehend aus
  - ▶ **protected** Instanzvariable `currentChar`
  - ▶ **protected** Methoden `take` und `takeIt`
    - ▶ Analog zu `accept/acceptIt` im Parser
    - ▶ Lesen diesmal aber zeichenweise in `currentChar`
  - ▶ **protected** Scan-Methoden aus 2., erweitert um Erstellen von Token-Objekten
  - ▶ Eine **public** Methode `scan`, die den nächsten Token liefert
    - ▶ Überspringt dabei white space und Kommentare

# Struktur des Java-Codes



```
public class Scanner {  
    protected char currentChar;  
    protected byte currentKind;  
    protected StringBuffer currentSpelling;  
  
    public Token scan() {  
        discard separators and whitespace;  
        currentSpelling = new StringBuffer("");  
        currentKind = scanToken();  
        return new Token(currentKind,  
                         currentSpelling.toString());  
    }  
  
    protected byte scanToken() {  
        switch (currentChar) {  
            ...  
        }  
    }  
  
    protected void take(char expectedChar) { ... }  
    protected void takeIt() { ... }  
    ...  
}
```

```
public class Scanner {  
    protected char currentChar;  
    protected byte currentKind;  
    protected StringBuffer currentSpelling;  
  
    public Token scan() {  
        discard separators and whitespace;  
        currentSpelling = new StringBuffer("");  
        currentKind = scanToken();  
        return new Token(currentKind,  
                         currentSpelling.toString());  
    }  
  
    protected byte scanToken() {  
        switch (currentChar) {  
            ...  
        }  
    }  
  
    protected void take(char expectedChar) { ... }  
    protected void takeIt() { ... }  
    ...  
}
```

Hänge c  
an und les

# Scanner für Mini-Triangle

## 1. Lexikalische Grammatik in EBNF verfassen

```
Token ::= Identifier | Integer-Literal | Operator |
        ; | : | := | ~ | ( ) | eot
Identifier ::= Letter (Letter | Digit)*
Integer-Literal ::= Digit Digit*
Operator ::= + | - | * | / | < | > | =
Separator ::= Comment | space | eol
Comment ::= ! Graphic* eol
```

## 2. Umstellen für rekursiven Abstieg: Ersetzung und Linksausklammern

```
Token ::= Letter (Letter | Digit)*
        | Digit Digit*
        | + | - | * | / | < | > | =
        | ; | : (=|ε) | ~ | ( ) | eot
Separator ::= ! Graphic* eol | space | eol
```

Hier eigentlich nicht nötig. Aber: Schneller!

- ▶ EBNF kann **nicht** trennen zwischen
    - ▶ Schlüsselwörtern
    - ▶ Bezeichnern
  - ▶ Wird beides als **Identifier** beschrieben
- während des Scannens reparieren.

# Zeichenweises Einlesen



```
public class Scanner {  
  
    private char currentChar = get first source char;  
    private StringBuffer currentSpelling;  
    private byte currentKind;  
  
    private char take(char expectedChar) {  
        if (currentChar == expectedChar) {  
            currentSpelling.append(currentChar);  
            currentChar = get next source char;  
        }  
        else report lexical error  
    }  
    private char takelt() {  
        currentSpelling.append(currentChar);  
        currentChar = get next source char,  
    }  
    ...  
}
```

# Scan-Methoden



```
...
public Token scan() {
    // Get rid of potential separators before
    // scanning a token
    while ( (currentChar == 'I')
        || (currentChar == ' ')
        || (currentChar == '\n' ) )
        scanSeparator();
    currentSpelling = new StringBuffer();
    currentKind = scanToken();
    return new Token(currentkind,
                     currentSpelling.toString());
}

private void scanSeparator() { ... }
private byte scanToken() { ... }
```

Entwicklung sehr  
ähnlich zu Parse-  
Methoden

# Beispiel scanToken



```
Token ::= Letter (Letter | Digit)*  
| Digit Digit*  
| + | - | * | / | < | > | =  
| ; | : (=|ε) | ~ | ( | ) | eof
```

```
private byte scanToken() {  
    switch (currentChar) {  
        case 'a': case 'b': ... case 'z':  
        case 'A': case 'B': ... case 'Z':  
            scan Letter (Letter | Digit)*  
            return Token.IDENTIFIER;  
        case '0': ... case '9':  
            scan Digit Digit*  
            return Token.INTLITERAL;  
        case '+': case '-': ... : case '=':  
            takelt();  
            return Token.OPERATOR;  
        ...etc...  
    }  
}
```

# Genauer: Scannen von Identifier



```
...
return ...
case 'a': case 'b': ... case 'z':
case 'A': case 'B': ... case 'Z':
    takelt();
    while (isLetter(currentChar)
        || isDigit(currentChar) )
        takelt();
    return Token.IDENTIFIER;
case '0': ... case '9':
...
```

# Hauptmethode scan()



```
...
public Token scan() {
    // Get rid of potential separators before
    // scanning a token
    while ( (currentChar == '!')
        || (currentChar == ' ')
        || (currentChar == '\n' ) )
        scanSeparator();
    currentSpelling = new StringBuffer();
    currentKind = scanToken();
    return new Token(currentkind,
                     currentSpelling.toString());
}
```

Wo nun Unterscheidung zwischen Bezeichnern und Schlüsselworten?

# Ändern von Token-Art während der Konstruktion



```
public class Token {  
    ...  
    public Token(byte kind, String spelling) {  
        if (kind == Token.IDENTIFIER) {  
            int currentKind = firstReservedWord;  
            boolean searching = true;  
            while (searching) {  
                int comparison = tokenTable[currentKind].compareTo(spelling);  
                if (comparison == 0) {  
                    this.kind = currentKind;  
                    searching = false;  
                } else if (comparison > 0 || currentKind == lastReservedWord) {  
                    this.kind = Token.IDENTIFIER;  
                    searching = false;  
                } else {  
                    currentKind++;  
                }  
            }  
        } else  
            this.kind = kind;  
    }  
}
```

# Liste der Schlüsselworte



```
public class Token {  
    ...  
  
    private static String[] tokenTable = new String[] {  
        "<int>", " <char> ", "<identifier> ", "<operator> ",  
        "array", "begin", "const", "do", "else", "end",  
        "func", "if", "in", "let", "of", "proc", "record",  
        "then", "type", "var", "while",  
        ".", ";", ":", ":", "~", "(", ")", "[", "]", "{", "}", "",  
        "<error> "};  
  
    private final static int firstReservedWord = Token.ARRAY,  
        lastReservedWord = Token.WHILE;  
    ...  
}
```

- ▶ Sehr mechanischer Ablauf
- ▶ Gut automatisierbar
- ▶ Beispiele
  - ▶ JLex/JFlex: Scanner basiert auf endlichem Automaten
  - ▶ Eingebaute Scanner in Parser-Generatoren ANTLR/JavaCC