Compiler 1: Grundlagen

Compile-Fluß und Front-End

TECHNISCHE UNIVERSITÄT DARMSTADT

WS 2013/14

Andreas Koch

FG Eingebettete Systeme und ihre Anwendungen
Informatik, TU Darmstadt

Embedded Systems & Applications

Kompilierung

Ablauf der Übersetzung 1

TECHNISCHE UNIVERSITÄT DARMSTADT

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

TECHNISCHE UNIVERSITÄT DARMSTADT

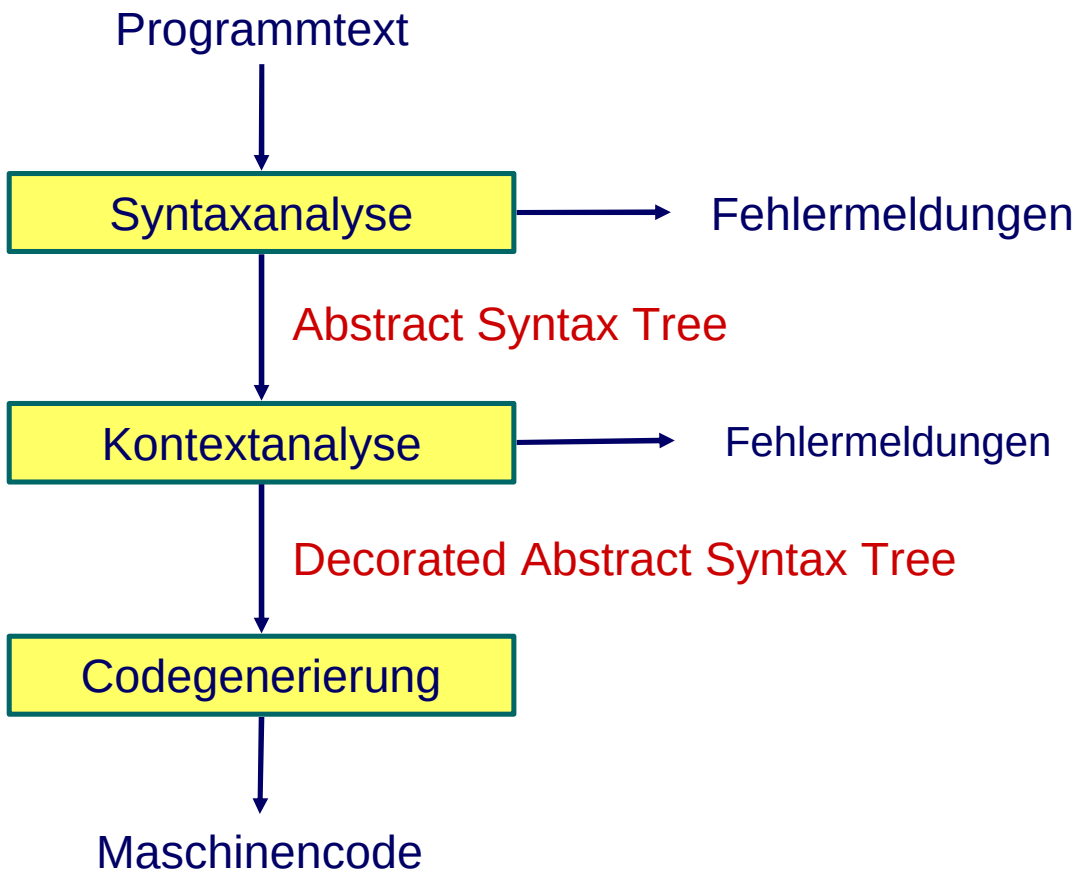

Ablauf der Übersetzung 3

TECHNISCHE UNIVERSITÄT DARMSTADT

Terminologie: Durchgang (*pass*)

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

Ein-Pass Compiler

TECHNISCHE UNIVERSITÄT DARMSTADT

- 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

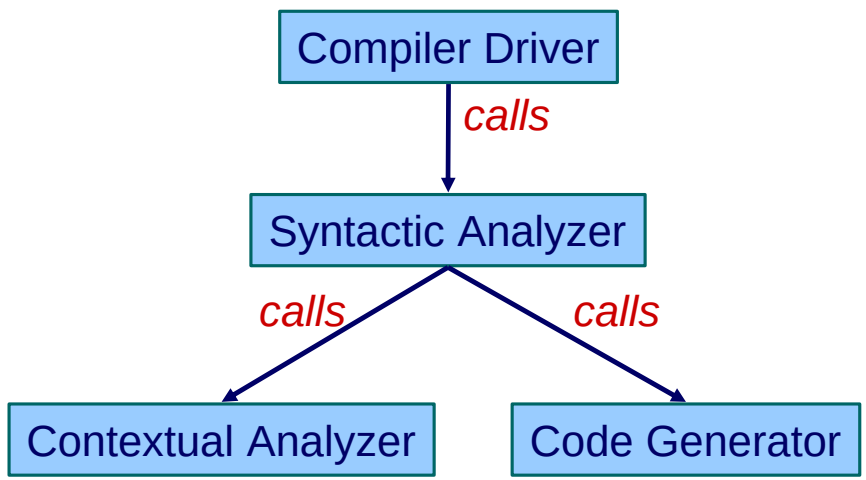

Multi-Pass Compiler

TECHNISCHE UNIVERSITÄT DARMSTADT

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

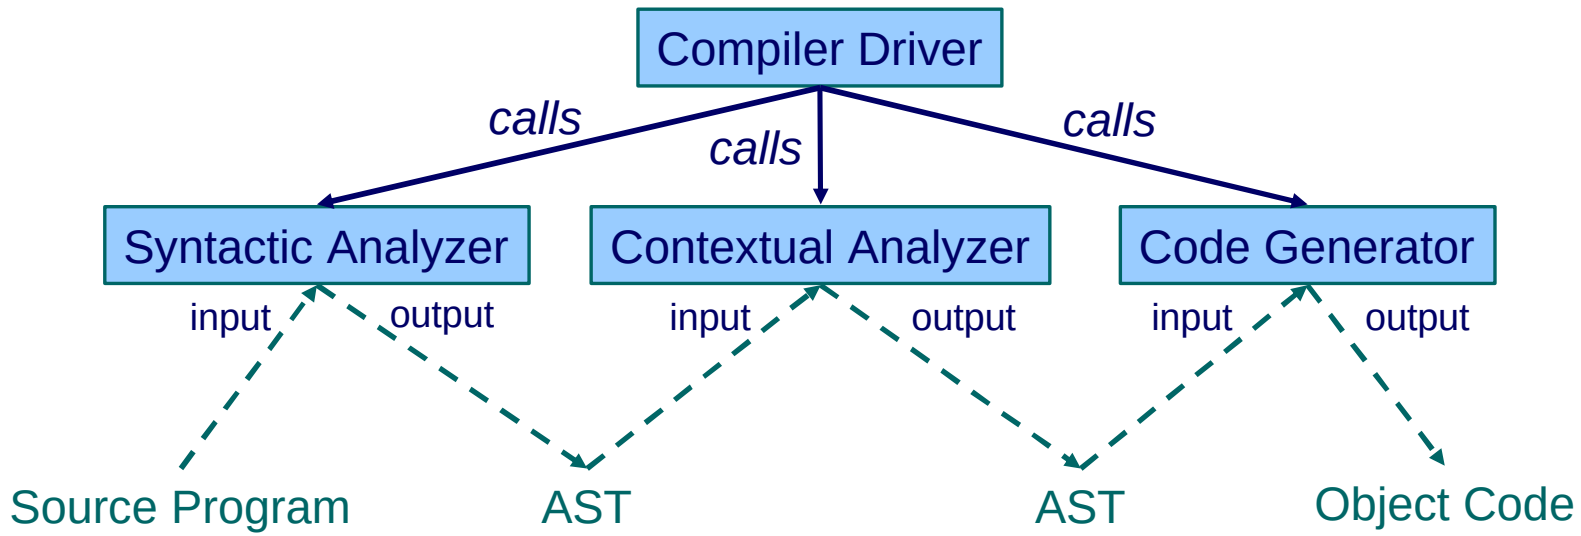

Vergleich Ein-Pass ./. Multi-Pass-Compiler

TECHNISCHE UNIVERSITÄT DARMSTADT

	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

TECHNISCHE UNIVERSITÄT DARMSTADT

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

TECHNISCHE UNIVERSITÄT DARMSTADT

- 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

TECHNISCHE UNIVERSITÄT DARMSTADT

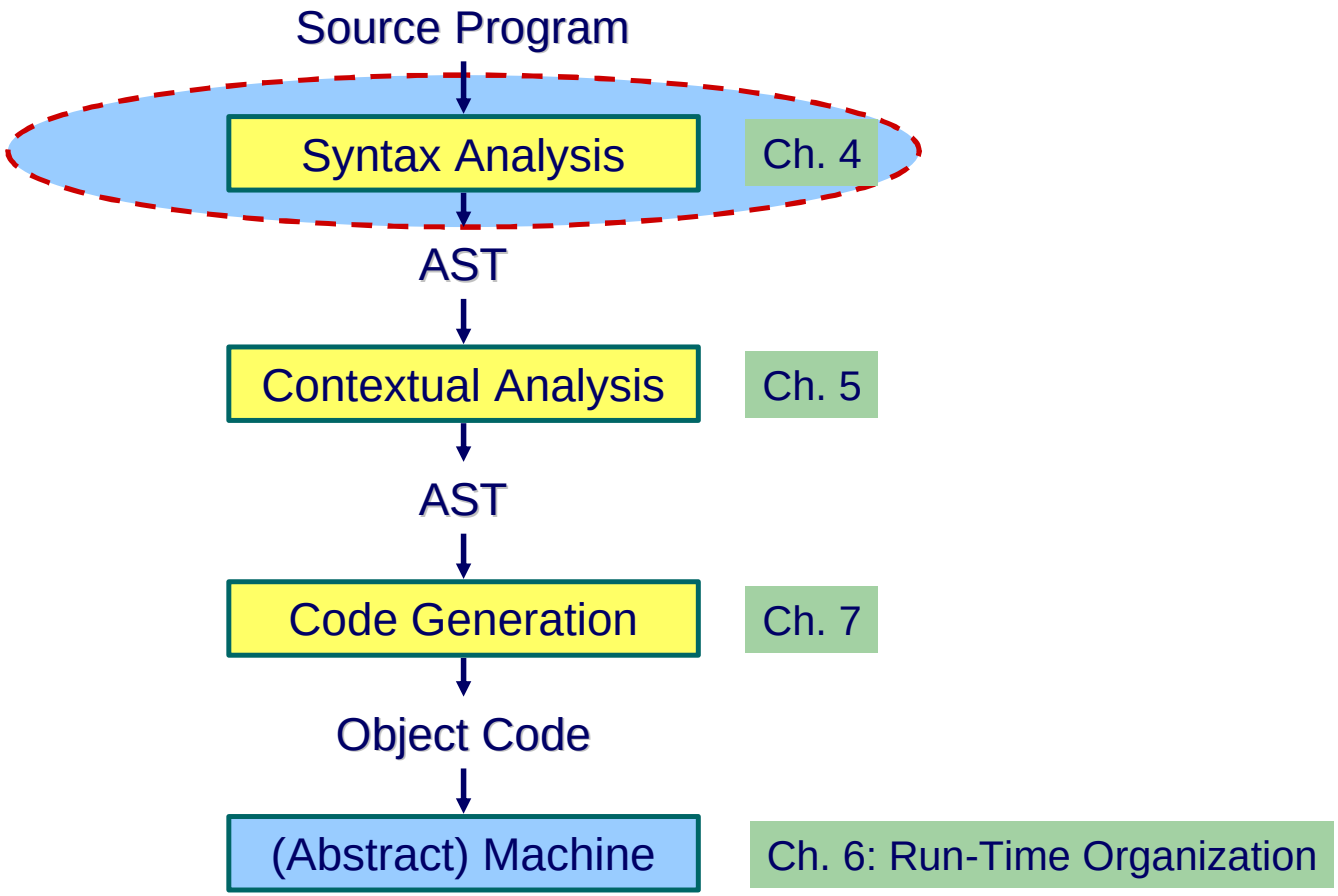

Subphasen der Syntaxanalyse

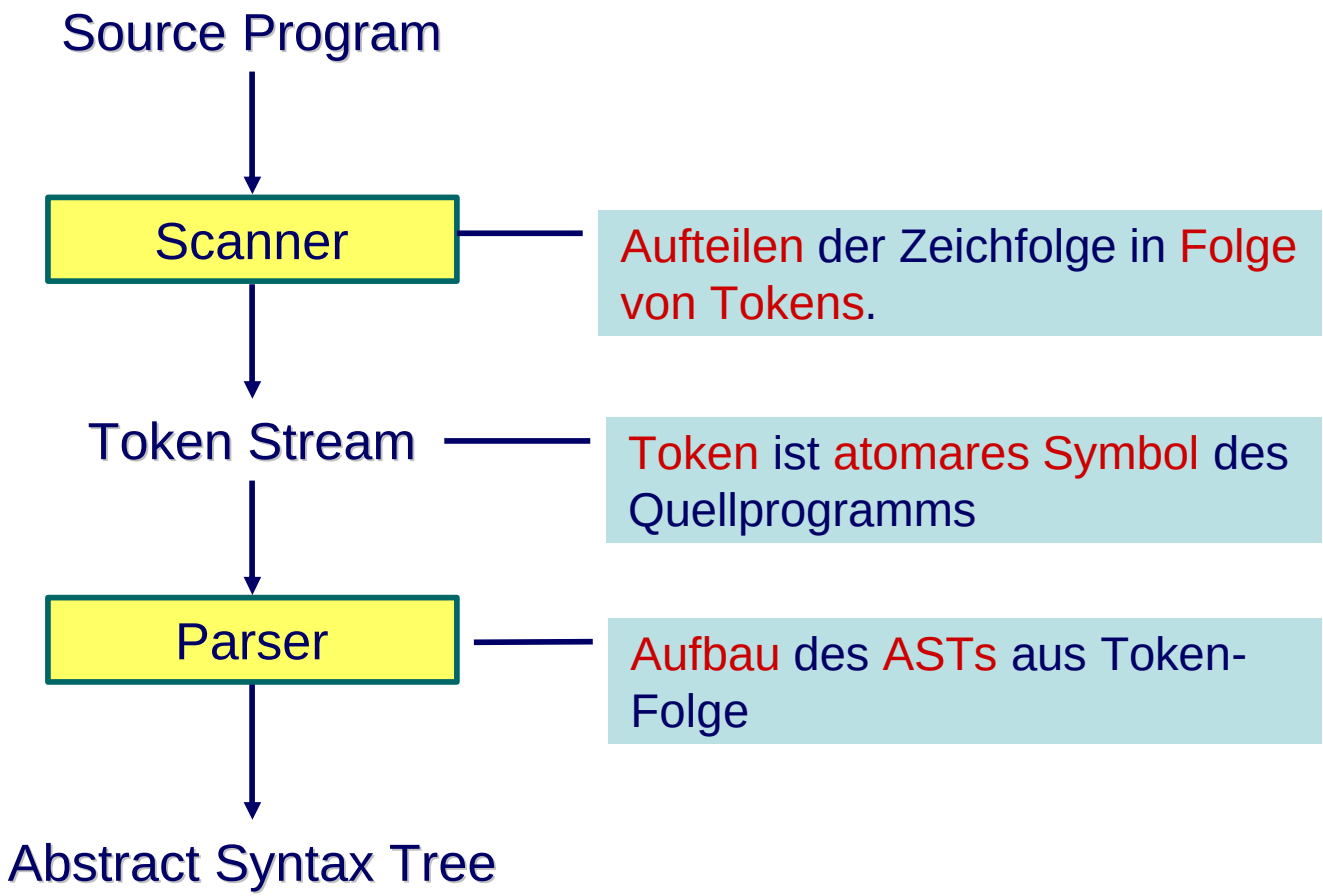

Token-Folge

TECHNISCHE UNIVERSITÄT DARMSTADT

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 ) )
```

Tokens

TECHNISCHE UNIVERSITÄT DARMSTADT

- 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

TECHNISCHE UNIVERSITÄT DARMSTADT

```
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, "+");`

Parsen der Token-Folge

TECHNISCHE UNIVERSITÄT DARMSTADT

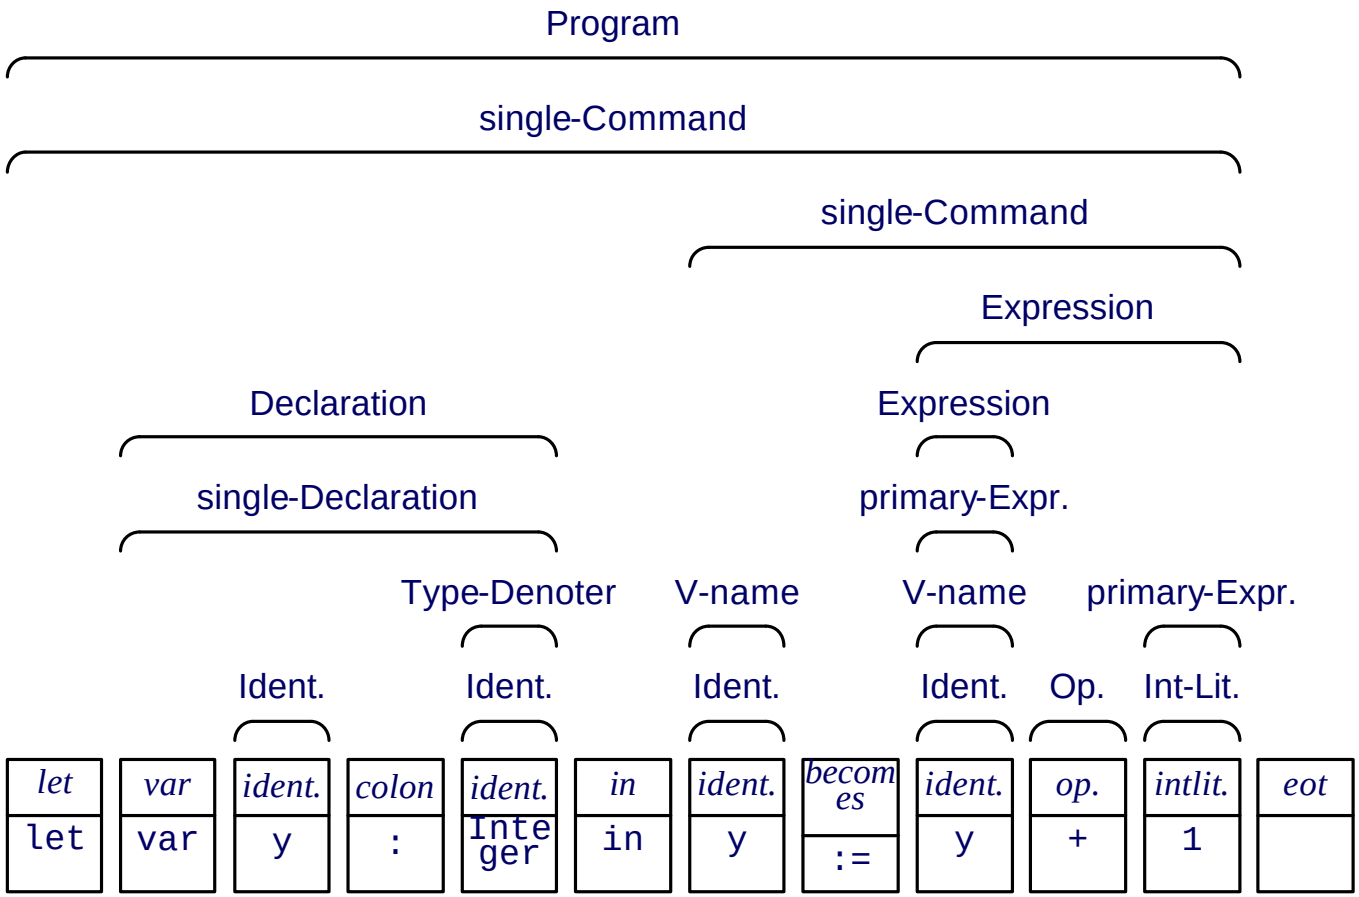

Aufbau des AST aus Token-Folge

TECHNISCHE UNIVERSITÄT DARMSTADT

Nur wenige Tokens tauchen tatsächlich im AST auf. Viele der fehlenden bestimmen aber implizit die AST Struktur.

```
let var x: Integer
in x := x+1
```

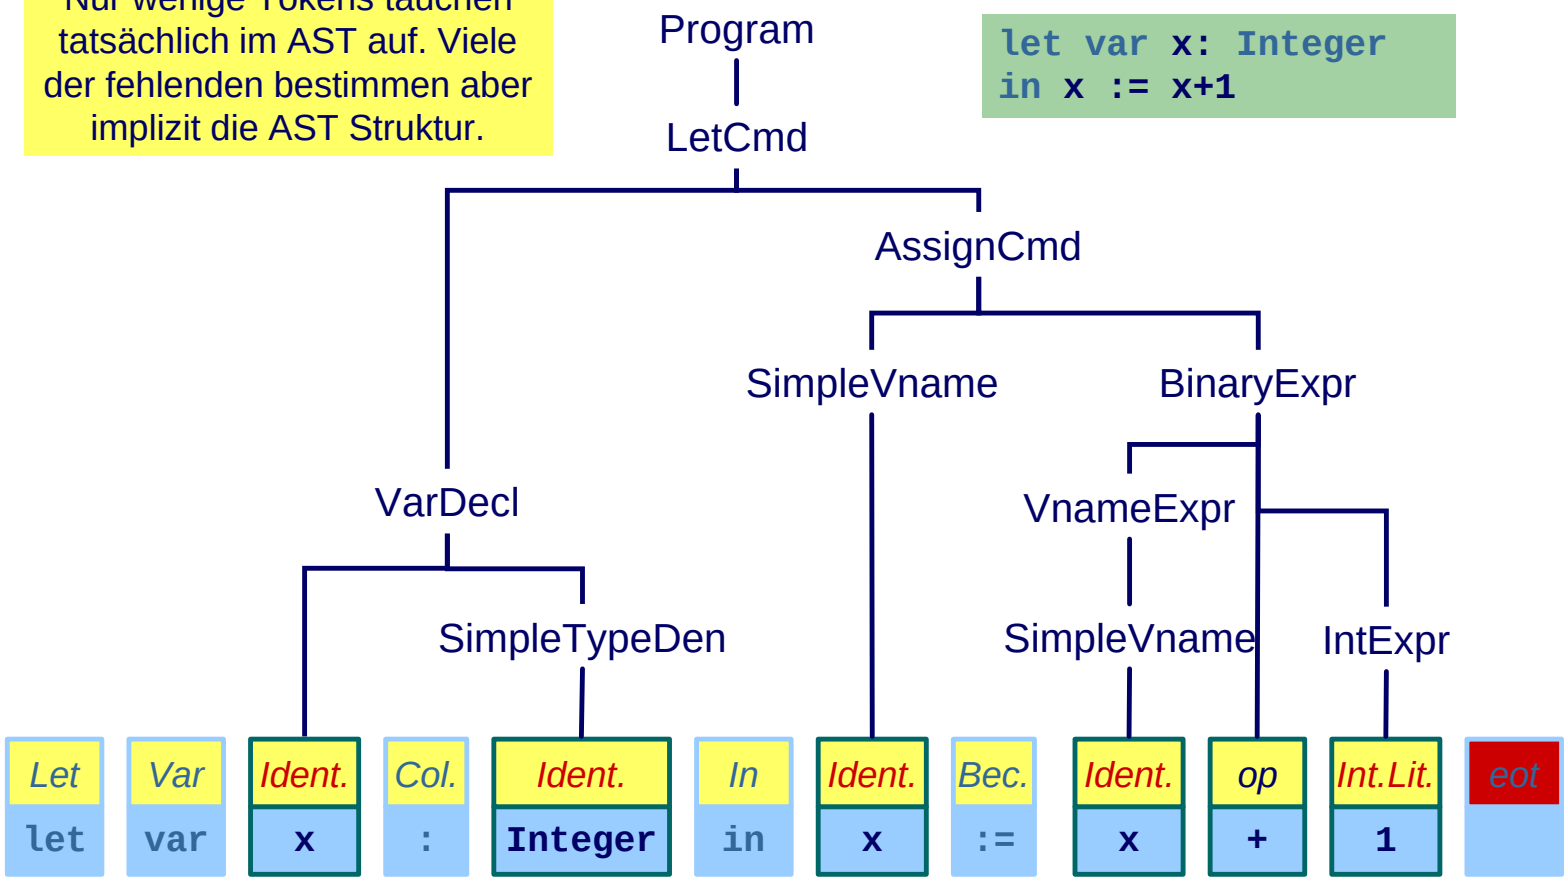

Kurzwiederholung Grammatiken

TECHNISCHE UNIVERSITÄT DARMSTADT

- 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

TECHNISCHE UNIVERSITÄT DARMSTADT

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)*
```

Reguläre Ausdrücke und Grammatiken

TECHNISCHE UNIVERSITÄT DARMSTADT

- 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

Transformation von Grammatiken

TECHNISCHE UNIVERSITÄT DARMSTADT

Hilfsmittel

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

Grammatik-Transformation durch Gruppierung

TECHNISCHE UNIVERSITÄT DARMSTADT

- 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

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

Grammatik-Transformation durch Linksausklammern

TECHNISCHE UNIVERSITÄT DARMSTADT

- Zusammenfassen von gleichen Anfängen in einer Produktion
- **X Y | X Z ➜ X(Y|Z)**

Beispiel:

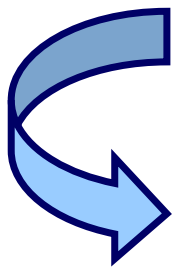

```
cmd   := if Expr then cmd
       |  if Expr then cmd else cmd
```

```
cmd   := if Expr then cmd (ε | else cmd)
```

Beseitigung von Linksrekursion

TECHNISCHE UNIVERSITÄT DARMSTADT

- Linksrekursion in Produktion
  - $\mathbf{N} ::= \mathbf{X} \mid \mathbf{N}\ \mathbf{Y}$
  - $L(\mathbf{N}) = \{\mathbf{X}, \mathbf{XY}, \mathbf{XYY}, \mathbf{XYYY}, \mathbf{XYYYY}, \ldots\}$
- Ersetzung durch
  - $\mathbf{N} ::= \mathbf{X}(\mathbf{Y})*$

Beispiel:

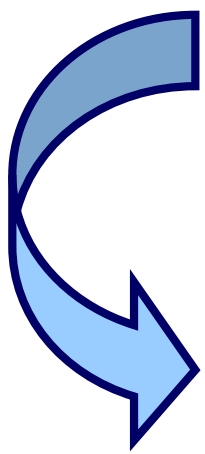

```
Identifier    ::=    Letter
                |    Identifier Letter
                |    Identifier Digit
```

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

Kombinierter Fall

TECHNISCHE UNIVERSITÄT DARMSTADT

Vor Transformation

$$\mathbf{N} \quad ::= \quad \mathbf{X}_1 \mid \ldots \mid \mathbf{X}_m \mid \mathbf{N}\,\mathbf{Y}_1 \mid \ldots \mid \mathbf{N}\,\mathbf{Y}_n$$

Nach Linksausklammern

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

Nach Beseitigen der Linksrekursion

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

Ersetzen von Nicht-Terminalsymbolen

TECHNISCHE UNIVERSITÄT DARMSTADT

- 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

Parsing Terminologie

TECHNISCHE UNIVERSITÄT DARMSTADT

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

Parsing Strategien

TECHNISCHE UNIVERSITÄT DARMSTADT

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

  Top-Down Beispiel: Rekursiver Abstieg

  Bottom-Up Beispiel: Shift/Reduce

Beispiel: Micro-English

TECHNISCHE UNIVERSITÄT DARMSTADT

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 .
```

Bottom-Up Parsing 1

TECHNISCHE UNIVERSITÄT DARMSTADT

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

Bottom-Up Parsing 2

TECHNISCHE UNIVERSITÄT DARMSTADT

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 .
```

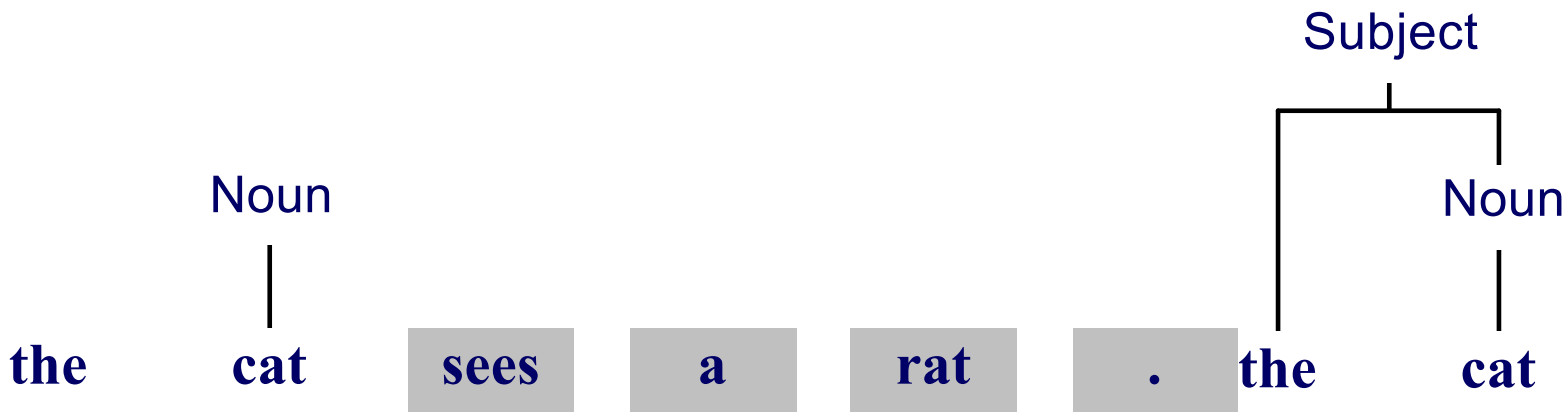

Sentence	::=	Subject Verb Object .
Subject	::=	I | a Noun | the Noun
Object	::=	me | a Noun | the Noun
Noun	::=	cat | mat | rat
Verb	::=	like | is | see | sees

Schwierigkeit bei Bottom-Up Parsing

TECHNISCHE UNIVERSITÄT DARMSTADT

Welche Produktion beim Zusammenfassen anwenden?

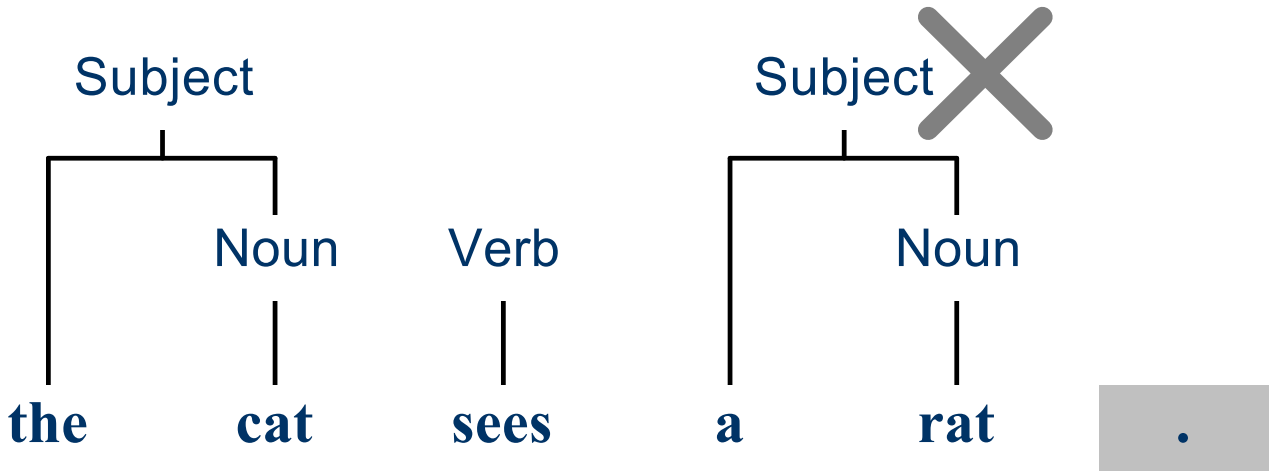

Lösung: Nicht nur bekannte Zeichen betrachten, sondern auch noch Zustand (“schon Subject gesehen”) einbeziehen.

. . . aber hier nicht weiter vertieft!

Top-Down Parsing 1

TECHNISCHE UNIVERSITÄT DARMSTADT

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

Top-Down Parsing 2

TECHNISCHE UNIVERSITÄT DARMSTADT

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
```

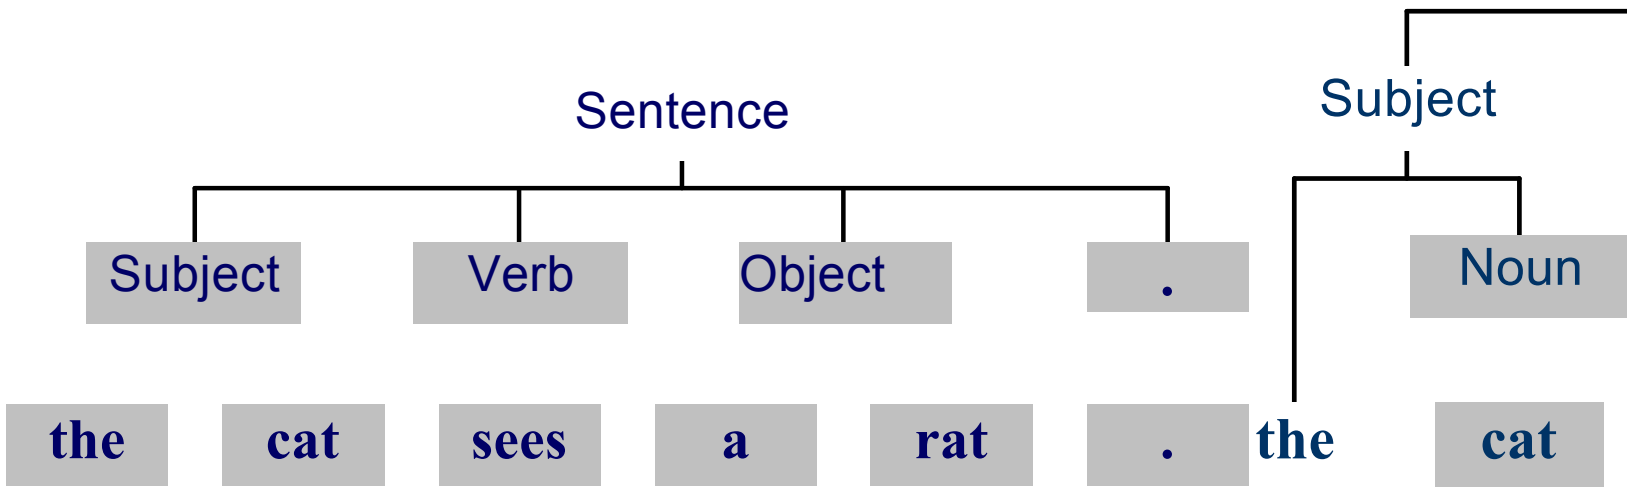

Hintergrund Top-Down Parsing

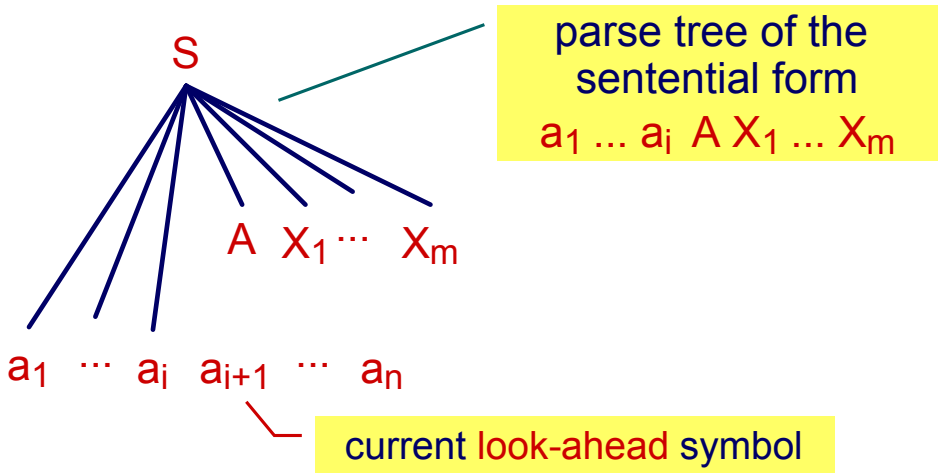

Falls es möglich ist,

- . . . 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

TECHNISCHE UNIVERSITÄT DARMSTADT

- 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

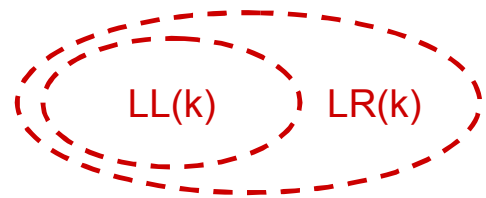

Parsen mit rekursivem Abstieg

TECHNISCHE UNIVERSITÄT DARMSTADT

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:

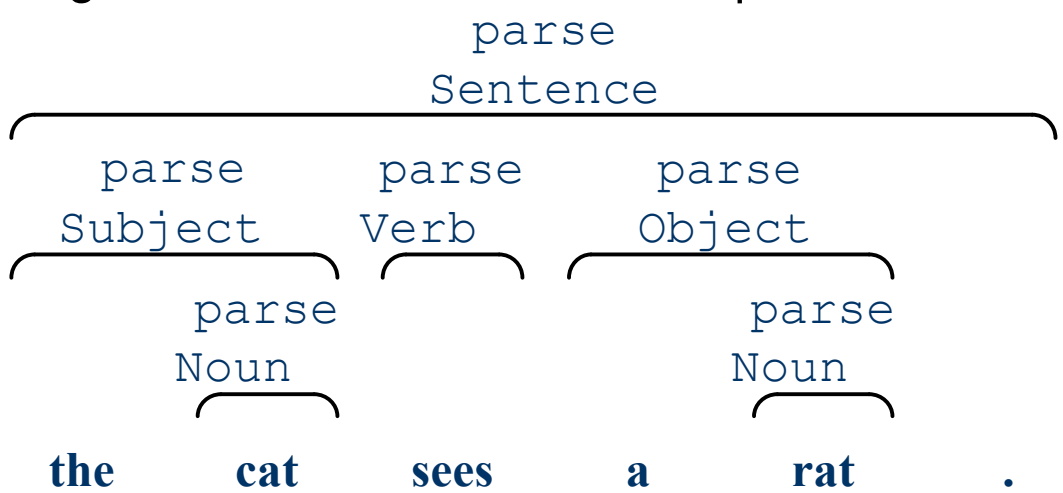

Beispiel für Micro-English 1

TECHNISCHE UNIVERSITÄT DARMSTADT

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

TECHNISCHE UNIVERSITÄT DARMSTADT

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

TECHNISCHE UNIVERSITÄT DARMSTADT

```
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
   protected

   public voi
      current
      parseSe
      check tha
   }

   protected
   protected
   protected
   protected
   protected
   protecte

   ...
}
```

Erläuterung

TECHNISCHE UNIVERSITÄT DARMSTADT

- **`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

Systematische Konstruktion von Parsern

TECHNISCHE UNIVERSITÄT DARMSTADT

Entwicklung von Parsern mit rekursivem Abstieg

1. Formuliere Grammatik (CFG) in EBNF
   - Eine Produktion pro Nicht-Terminal
   - Beseitige immer Linksrekursion
   - Klammere gemeinsame Teilausdrücks 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**

Anfangsmengen

TECHNISCHE UNIVERSITÄT DARMSTADT

starters$[[\mathbf{X}]]$ mit RE **X**

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

Beispiele

$$\begin{aligned} \text{starters}[[\mathbf{ab}]] &= \{\mathbf{a}\} \\ \text{starters}[[\mathbf{a}|\mathbf{b}]] &= \{\mathbf{a}, \mathbf{b}\} \\ \text{starters}[[(\mathbf{re}) * \mathbf{set}]] &= \{\mathbf{r}, \mathbf{s}\} \end{aligned}$$

Berechnungsregeln für starters$[[\mathbf{X}]]$

TECHNISCHE UNIVERSITÄT DARMSTADT

$$
\begin{aligned}
\text{starters}[[\varepsilon]] &= \{\} \\
\text{starters}[[\mathbf{t}]] &= \{\mathbf{t}\} \\
\text{starters}[[\mathbf{XY}]] &= \begin{cases} \text{starters}[[\mathbf{X}]] \text{: falls aus } \mathbf{X} \text{ kein } \varepsilon \text{ herleitbar} \\ \text{starters}[[\mathbf{X}]] \cup \text{starters}[[\mathbf{Y}]] \text{: sonst} \end{cases} \\
\text{starters}[[\mathbf{X}|\mathbf{Y}]] &= \text{starters}[[\mathbf{X}]] \cup \text{starters}[[\mathbf{Y}]] \quad \text{noch nicht ganz richtig!} \\
\text{starters}[[\mathbf{X}*]] &= \text{starters}[[\mathbf{X}]] \quad \text{dito!} \\
\text{starters}[[\mathbf{N}*]] &= \text{starters}[[\mathbf{X}]], \text{ wenn } \mathbf{N} ::= \mathbf{X} \quad \text{dito!}
\end{aligned}
$$

Ausbügeln der Ungenauigkeiten später (siehe Folie 51)

Inhalt der `parseN`-Methoden

TECHNISCHE UNIVERSITÄT DARMSTADT

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]])
   parseP();
else if (currentToken ∈ starters[[Q]])
   parseQ();
else
   melde Syntaxfehler
```
was bei $\mathbf{P} = \varepsilon$?

P$*$
```
while (currentToken ∈ starters[[P]])
      parseP();
```

Folgemengen

TECHNISCHE UNIVERSITÄT DARMSTADT

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

Beispiel

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

Anwendbarkeit der Zerlegungsregeln

TECHNISCHE UNIVERSITÄT DARMSTADT

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

- Falls *G* **X**|**Y** enthält und sich weder X noch Y zu ε ableiten lassen:
  $\text{starters}[[\mathbf{X}]] \cap \text{starters}[[\mathbf{Y}]] = \emptyset$
- Falls *G* **X**|**Y** enthält und sich beispielsweise **Y** zu ε ableiten lässt:
  $\text{starters}[[\mathbf{X}]] \cap (\text{starters}[[\mathbf{Y}]] \cup \text{follow}[[\mathbf{X}|\mathbf{Y}]]) = \emptyset$
- Falls *G* **X**$*$ enthält: $\text{starters}[[\mathbf{X}]] \cap \text{follow}[[\mathbf{X}*]] = \emptyset$

➥Wenn alles gilt: *G* ist LL(k) mit $k = 1$

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

Verfeinerte Zerlegungsregeln

TECHNISCHE UNIVERSITÄT DARMSTADT

Bisher gezeigt für **P**|**Q**

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

Problematisch, wenn ε aus **P** oder **Q** ableitbar.
Korrekt: Verwende statt $\text{starters}[[\mathbf{X}]]$

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

Analog für $\mathbf{P}*$. Korrigiere so Folie 48.

Beispiel für nicht-LL(1) Grammatik

TECHNISCHE UNIVERSITÄT DARMSTADT

- Aus Algol Grammatik

  Block ::= **`begin` Declaration** (**`;` Declaration**)$*$ **`;` Command `end`**

- Prüfe Regel für **X**$*$
  - $\text{starters}[[$**`;` Declaration**$]] = \{$**`;`**$\}$
  - $\text{follow}[[($**`;` Declaration**$)*]] = \{$**`;`**$\}$
  - $\text{starters}[[$**`;` Declaration**$]] \cap \text{follow}[[($**`;` Declaration**$)*]] \neq \emptyset$

- Produktion ist aber transformierbar

  Block ::= **`begin` Declaration `;`** (**Declaration `;`**)$*$ **Command `end`**

- Annahme: $\text{starters}[[$**Declaration`;`**$]] \cap \text{starters}[[$**Command**$]] = \emptyset$

LL(k)-Parser

TECHNISCHE UNIVERSITÄT DARMSTADT

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`

TECHNISCHE UNIVERSITÄT DARMSTADT

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`

TECHNISCHE UNIVERSITÄT DARMSTADT

```
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.

Sonderfälle

TECHNISCHE UNIVERSITÄT DARMSTADT

- 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)

TECHNISCHE UNIVERSITÄT DARMSTADT

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)

TECHNISCHE UNIVERSITÄT DARMSTADT

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

TECHNISCHE UNIVERSITÄT DARMSTADT

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

TECHNISCHE UNIVERSITÄT DARMSTADT

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

TECHNISCHE UNIVERSITÄT DARMSTADT

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

TECHNISCHE UNIVERSITÄT DARMSTADT

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

TECHNISCHE UNIVERSITÄT DARMSTADT

```
Program          ::= single-Command

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

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

```
Program          ::= sin
Command          ::= sin
                   |   Co
single-Command   ::= V-n
                   |   Ide
                   |   ...
```

Abstrakte Syntaxbäume 1

TECHNISCHE UNIVERSITÄT DARMSTADT

- 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

TECHNISCHE UNIVERSITÄT DARMSTADT

- 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

TECHNISCHE UNIVERSITÄT DARMSTADT

Program	::= Command	Program	
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	
Expression	::= Integer-Literal	IntegerExpr	
	| V-name	VnameExpr	
	| Operator Expression	UnaryExpr	
	| Expression Operator Expression	BinaryExpr	
V-name	::= Identifier	SimpleVname	
Declaration	::= Declaration **;** Declaration	SeqDecl	
	| **const** Identifier **~** Expression	ConstDecl	
	| **var** Identifier **:** Type-denoter	VarDecl	
Type-denoter	::= Identifier	SimpleTypeDen	

Program	::= C		
Command	::= C		
	| V		
	| Id		
	| **i**		
	| **w**		
	| **l**		
Expression	::= In		
	| V		
	| O		
	| E		
V-name	::= Id		
Declaration	::= D		
	| **c**		
	| **v**		
Type-denoter	::= Id		

Sub-ASTs von Mini-Triangle

TECHNISCHE UNIVERSITÄT DARMSTADT

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

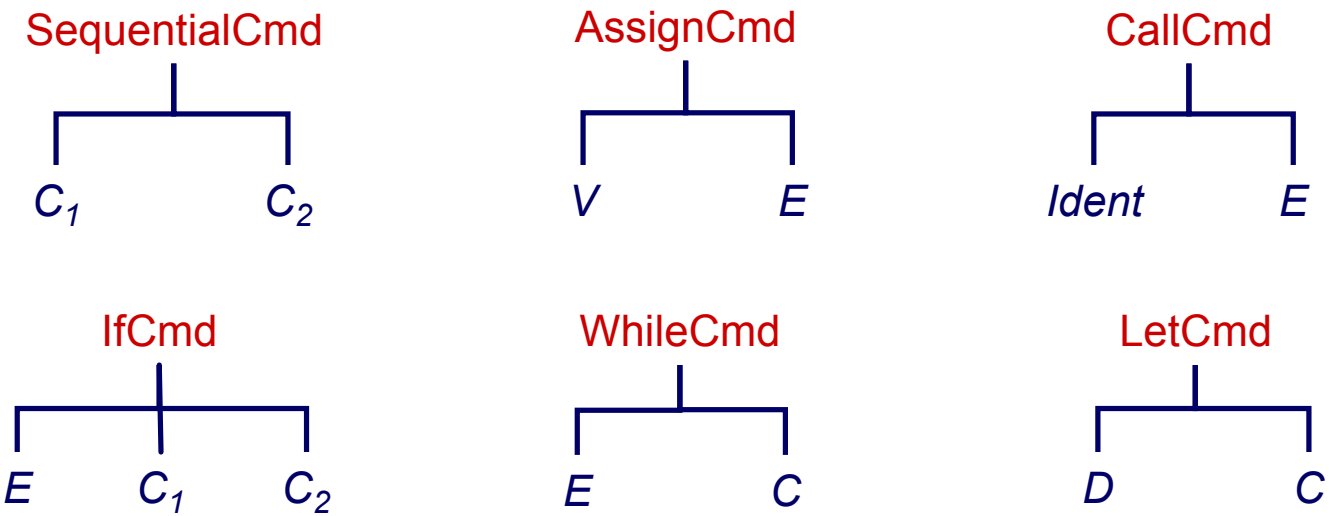

Java-Implementierung der ASTs

TECHNISCHE UNIVERSITÄT DARMSTADT

- 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

TECHNISCHE UNIVERSITÄT DARMSTADT

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

```
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
```

```
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

TECHNISCHE UNIVERSITÄT DARMSTADT

- 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;
        }
}
```

Aufbau des ASTs

TECHNISCHE UNIVERSITÄT DARMSTADT

- 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, sammele Subphrasen-ASTs in itsAST
  return itsAST
}
```

Zusammensetzen von Subphrasen ASTs 1

TECHNISCHE UNIVERSITÄT DARMSTADT

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;
}
```

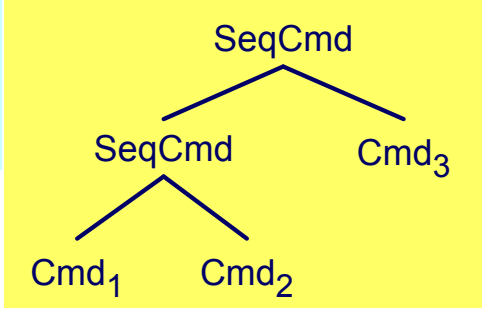

Zusammensetzen von Subphrasen ASTs 2

TECHNISCHE UNIVERSITÄT DARMSTADT

```
public Declaration parseSingleDeclaration() {
   Declaration declAST;
   switch (currenToken.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:
         melde Syntaxfehler
   }
   return declAST;
}
```

Scanning - Woher kommen die Tokens?

TECHNISCHE UNIVERSITÄT DARMSTADT

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();
   }

   ...
}
```

Scanner

TECHNISCHE UNIVERSITÄT DARMSTADT

- 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 unerwünsche Leerzeichen, Zeilenvorschübe, etc. (white space)
  - Führe Buch über Zeilennummern und Eingabedateinamen

Scanner-Sicht auf Tokens

TECHNISCHE UNIVERSITÄT DARMSTADT

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

TECHNISCHE UNIVERSITÄT DARMSTADT

- 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**

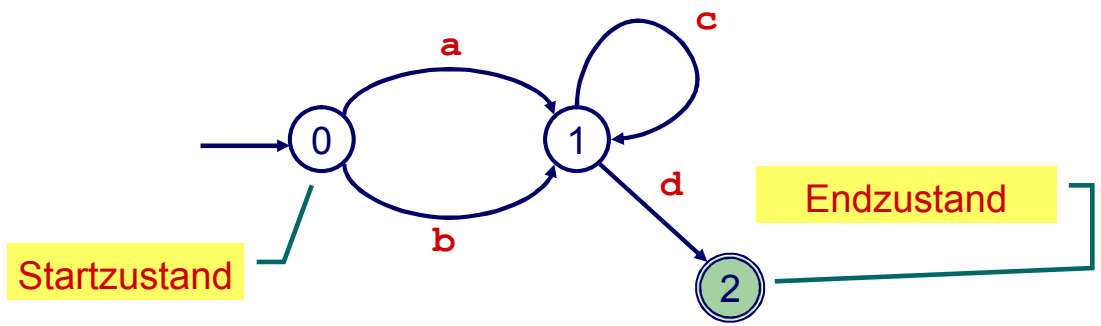

Alternative: Rekursiver Abstieg

TECHNISCHE UNIVERSITÄT DARMSTADT

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

TECHNISCHE UNIVERSITÄT DARMSTADT

```
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 cur

   public Token scan() {
      discard separators and whitesp
      currentSpelling = new S
      currentKind     = scanT
      return new Token(curren
                       curren
   }

   protected byte scanToken()
      switch (currentChar) {
         ...
      }
   }

   protected void take(char e
   protected void takeIt() {
   ...
}
```

Hänge c
an und les

Scanner für Mini-Triangle

TECHNISCHE UNIVERSITÄT DARMSTADT

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!

Feinheiten am Rande

TECHNISCHE UNIVERSITÄT DARMSTADT

- EBNF kann nicht trennen zwischen
  - Schlüsselworten
  - Bezeichnern
- Wird beides als **Identifier** beschrieben

➥während des Scannens reparieren.

Zeichenweises Einlesen

TECHNISCHE UNIVERSITÄT DARMSTADT

```
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 takeIt() {
    currentSpelling.append(currentChar);
    currentChar = get next source char;
  }
  ...
```

Scan-Methoden

TECHNISCHE UNIVERSITÄT DARMSTADT

```
...
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());
}

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

Entwicklung sehr ähnlich zu Parse-Methoden

Beispiel `scanToken`

TECHNISCHE UNIVERSITÄT DARMSTADT

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

```
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 ‘=’:
       takeIt();
       return Token.OPERATOR;
     ...etc...
}
```

Genauer: Scannen von Identifier

TECHNISCHE UNIVERSITÄT DARMSTADT

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

Hauptmethode `scan()`

TECHNISCHE UNIVERSITÄT DARMSTADT

```
...
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

TECHNISCHE UNIVERSITÄT DARMSTADT

```
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

TECHNISCHE UNIVERSITÄT DARMSTADT

```
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;

...
}
```

Automatisierbarkeit

TECHNISCHE UNIVERSITÄT DARMSTADT

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