

Compiler 1: Grundlagen

Compile-Fluß und Front-End



TECHNISCHE
UNIVERSITÄT
DARMSTADT

WS 2015/16

Andreas Koch

FG Eingebettete Systeme und ihre Anwendungen
Informatik, TU Darmstadt

Kompilierung

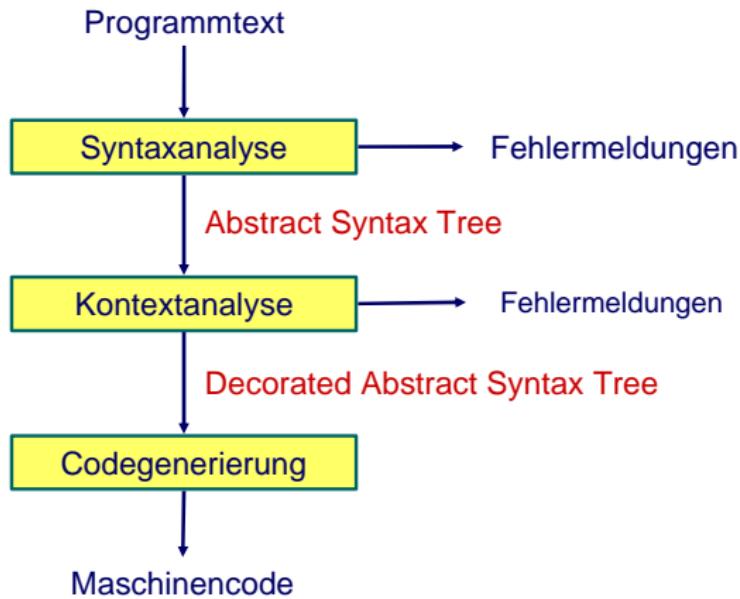
Terminologie: Phase

- ▶ Transformationsschritte
 - ▶ Von Quellcode
 - ▶ ... zum Maschinencode

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



TECHNISCHE
UNIVERSITÄT
DARMSTADT

Terminologie: Durchgang (*pass*)

- ▶ Kompletter Durchgang des Programmes
- ▶ Läuft über Quelltext oder IR
- ▶ Pass *kann* Phase entsprechen
- ▶ ... muss aber nicht!

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

Ein-Pass Compiler



TECHNISCHE
UNIVERSITÄT
DARMSTADT

- ▶ Macht nur **einen** Pass über den Quelltext
 - ▶ Baut in der Regel **keine** echte IR auf

Ein-Pass Compiler



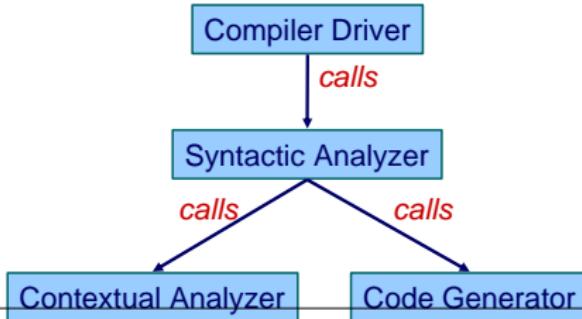
TECHNISCHE
UNIVERSITÄT
DARMSTADT

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

Ein-Pass Compiler



- ▶ 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



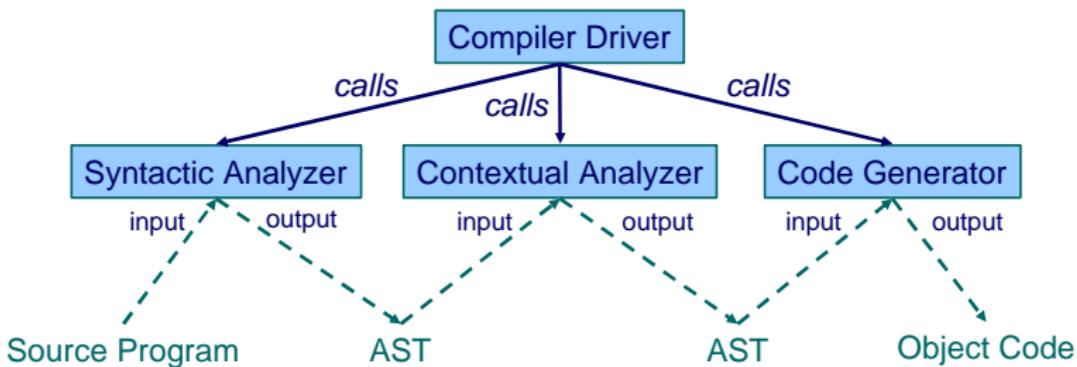
TECHNISCHE
UNIVERSITÄT
DARMSTADT

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

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**!

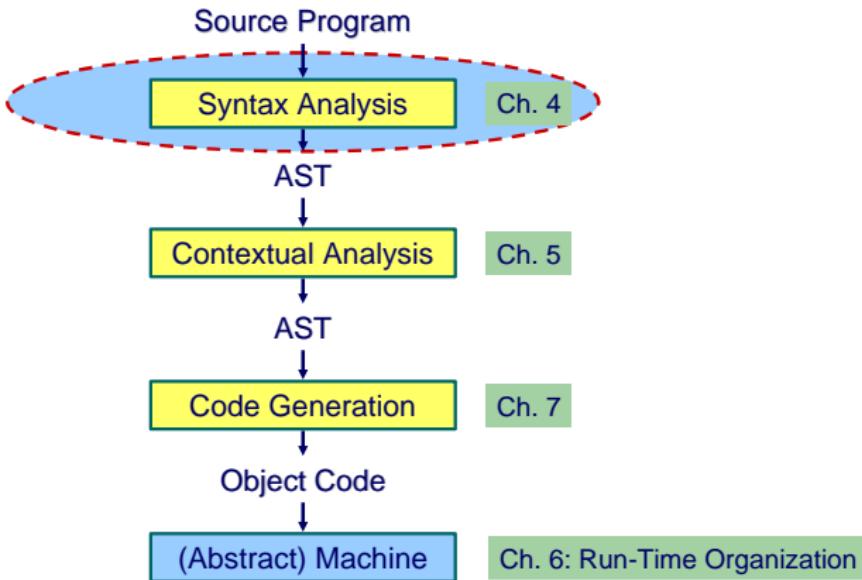
Aufbau des Triangle-Compilers



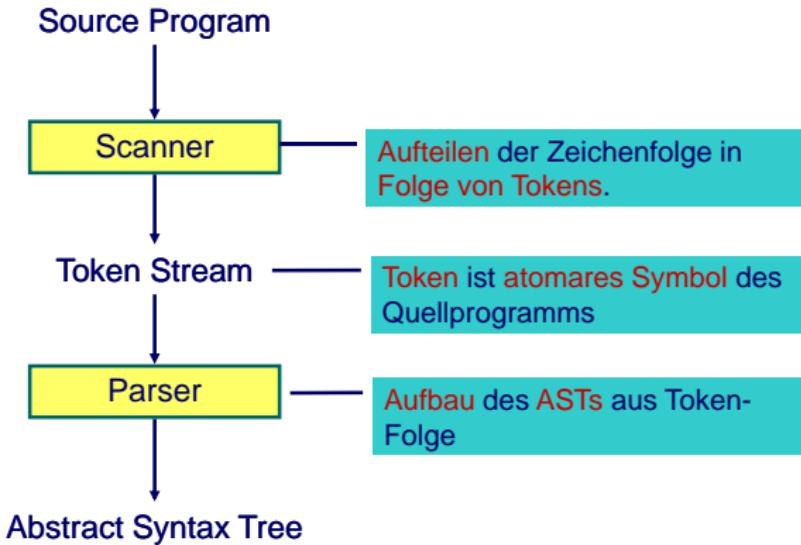
- ▶ Ein-Pass wäre für Triangle möglich
- ▶ Aus pädagogischen Gründen aber Multi-Pass

```
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))
```

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

- ▶ **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*

- ▶ **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

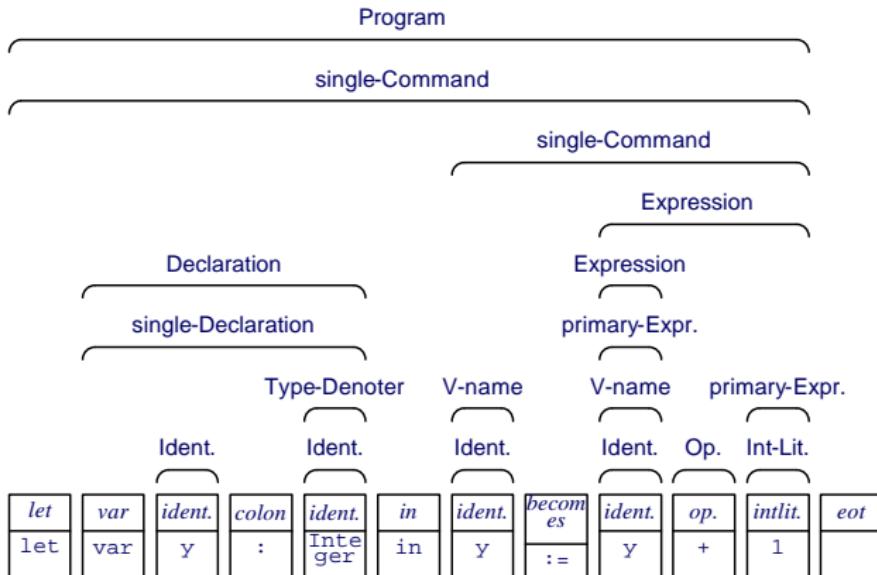
Konstanten für Token-Arten



```
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, "+");**

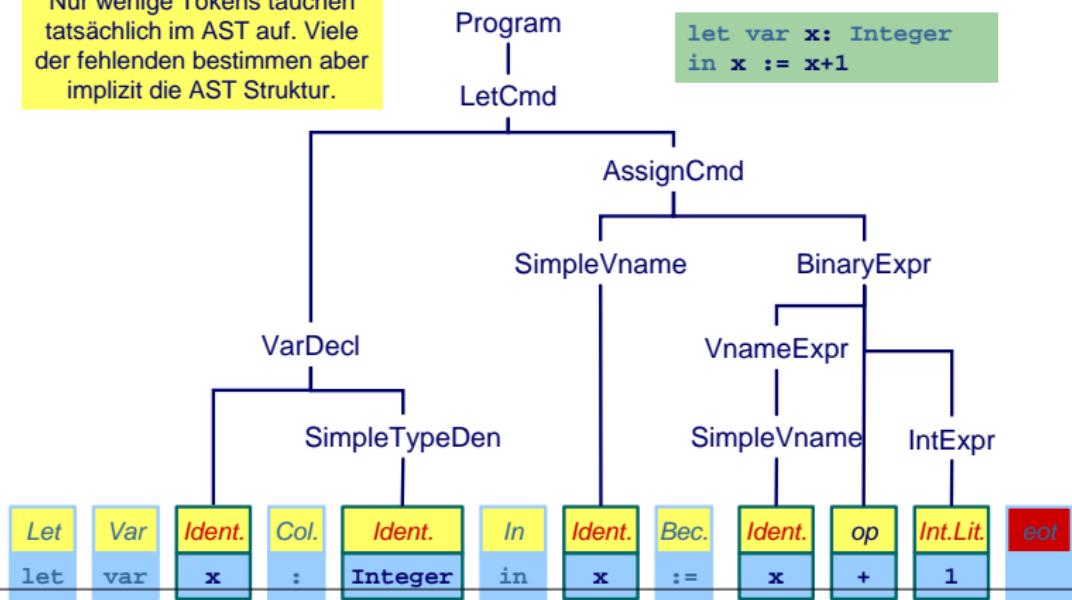
Parson der Token-Folge



Aufbau des AST aus Token-Folge



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



- ▶ 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

- ▶ 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

- ▶ 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

- ▶ 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

Grammatik-Transformation durch Gruppierung



TECHNISCHE
UNIVERSITÄT
DARMSTADT

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

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

Vor Transformation

S ::= X + S

S ::= X

S ::= ε

- ▶ 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



TECHNISCHE
UNIVERSITÄT
DARMSTADT

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

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
 - ▶ $N ::= X(Y)^*$

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)*
```

Kombinierter Fall



TECHNISCHE
UNIVERSITÄT
DARMSTADT

Vor Transformation

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

Kombinierter Fall



TECHNISCHE
UNIVERSITÄT
DARMSTADT

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

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

Kombinierter Fall



TECHNISCHE
UNIVERSITÄT
DARMSTADT

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

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

Ersetzen von Nicht-Terminalsymbolen



TECHNISCHE
UNIVERSITÄT
DARMSTADT

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

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

- ▶ 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 | ...

- ▶ 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 Terminologie



TECHNISCHE
UNIVERSITÄT
DARMSTADT

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

Parsing: Erkennung und zusätzlich Bestimmung der Phrasen-Struktur

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

Parsing Terminologie



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,

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

Parsing Strategien



TECHNISCHE
UNIVERSITÄT
DARMSTADT

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

Parsing Strategien



TECHNISCHE
UNIVERSITÄT
DARMSTADT

- ▶ Zwei wesentliche Verfahren
 - ▶ Unterscheiden sich in der Art ihres Vorgehens
- Top-Down Beispiel: Rekursiver Abstieg

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



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
```

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

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

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 .



TECHNISCHE
UNIVERSITÄT
DARMSTADT



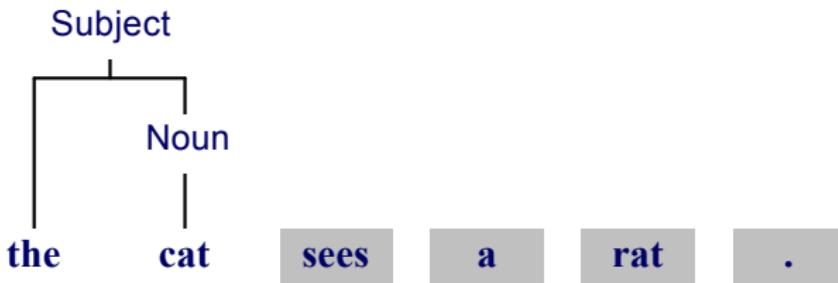
```
Sentence ::= Subject Verb Object .
Subject   ::= I | a Noun | the Noun
Object    ::= me | a Noun | the Noun
Noun     ::= cat | mat | rat
Verb      ::= like | is | see | sees
```

Beispiel Bottom-Up Parsing

the cat sees a rat .



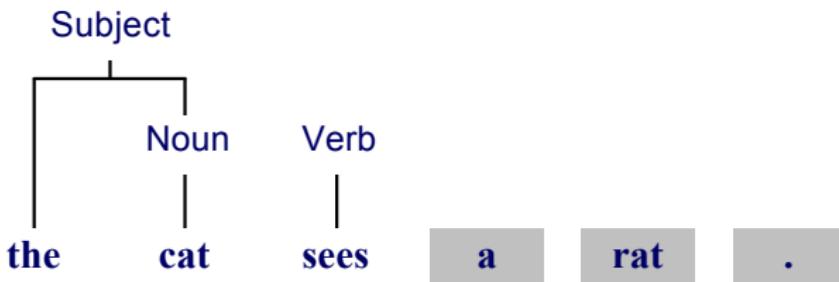
TECHNISCHE
UNIVERSITÄT
DARMSTADT



```
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
```

Beispiel Bottom-Up Parsing

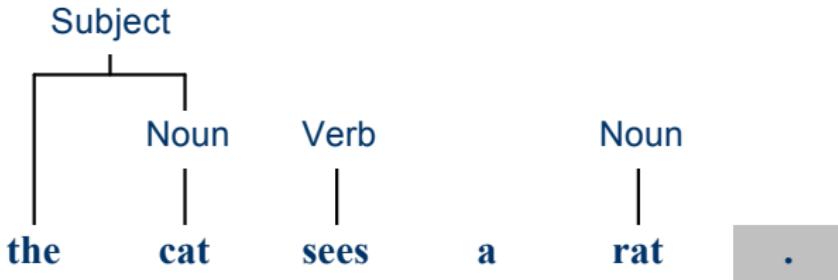
the cat sees a rat .



```
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
```

Beispiel Bottom-Up Parsing

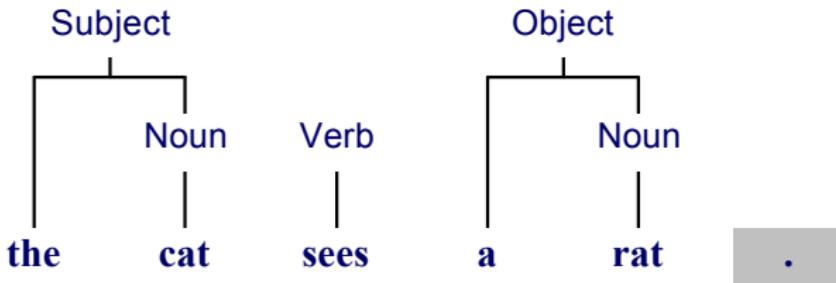
the cat sees a rat .



```
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
```

Beispiel Bottom-Up Parsing

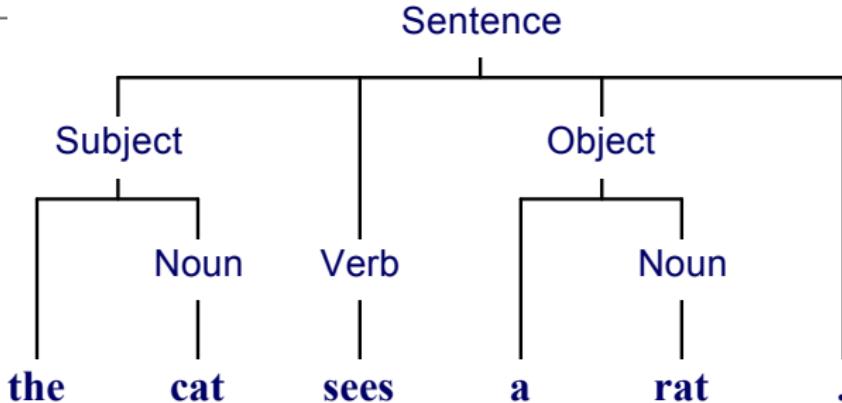
the cat sees a rat .



```
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
```

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



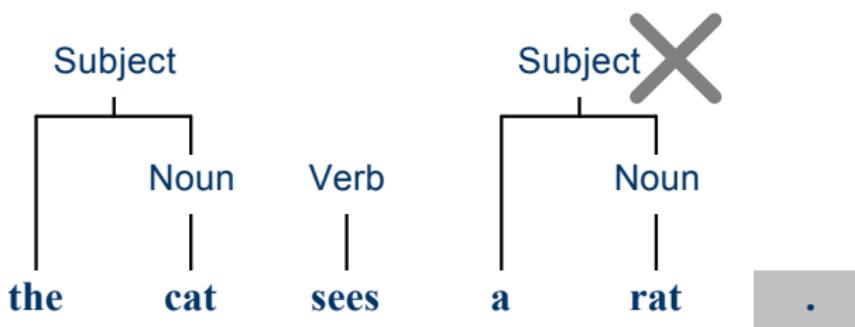
TECHNISCHE
UNIVERSITÄT
DARMSTADT

Welche Produktion beim Zusammenfassen anwenden?

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

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**

Aktion

- ▶ Expandiere jeweils das am weitestens links gelegene Nicht-Terminal **N**
- ▶ ... durch Anwendung einer Produktion **N ::= X**

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: $n = 1$)

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!

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

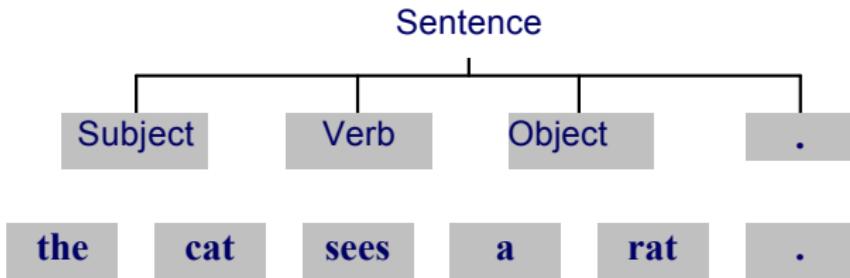
Beispiel Top-Down Parsing

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
```

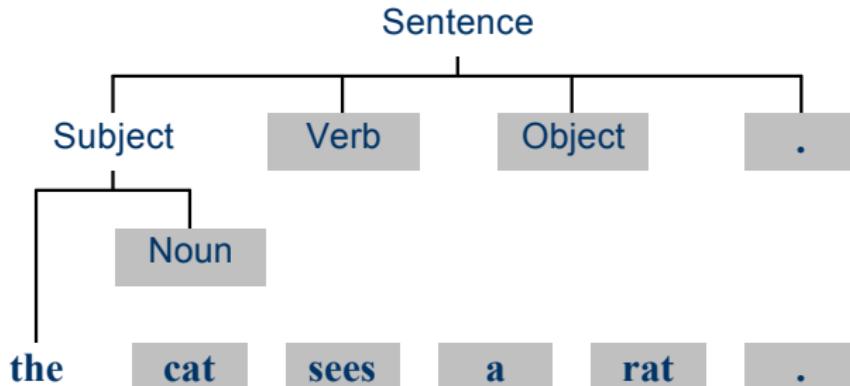


Beispiel Top-Down Parsing

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
```

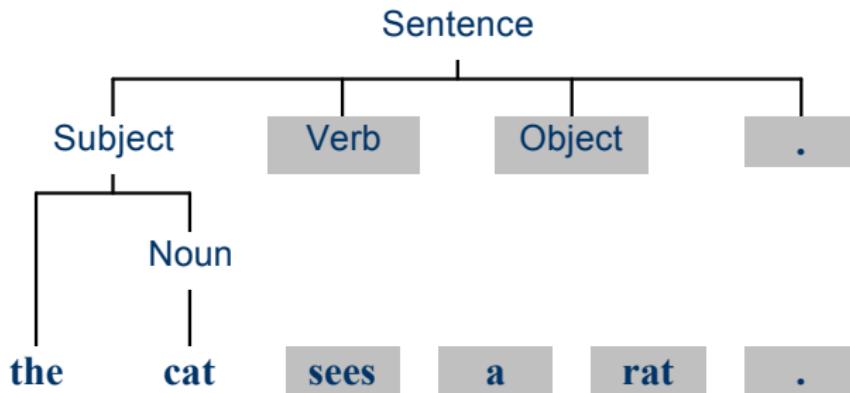


Beispiel Top-Down Parsing

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
```



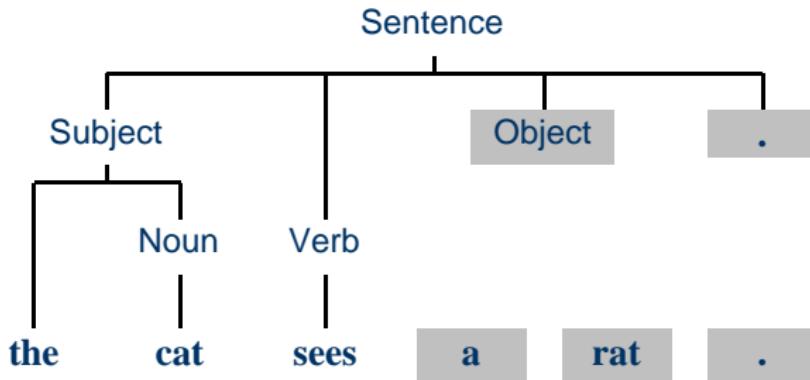
Beispiel Top-Down Parsing

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
```



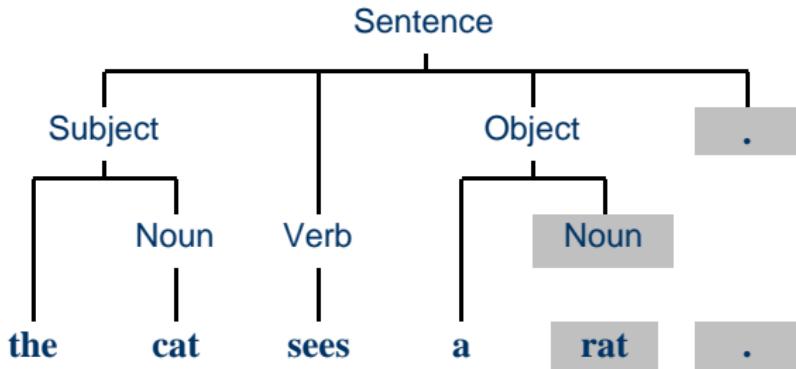
Beispiel Top-Down Parsing

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
```



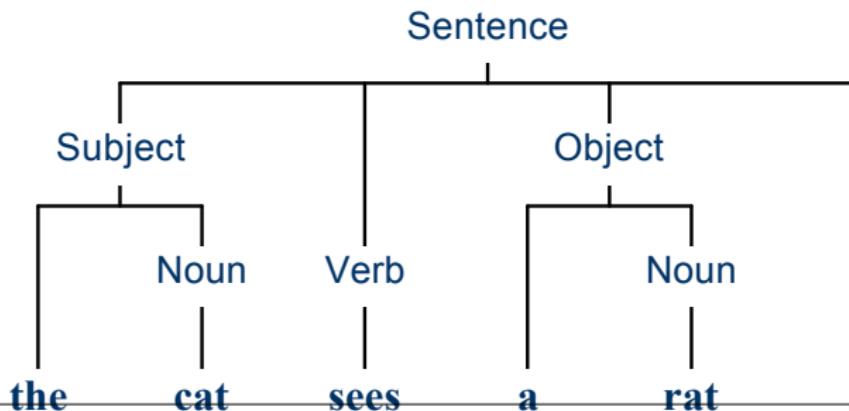
Beispiel Top-Down Parsing

the cat sees a rat .

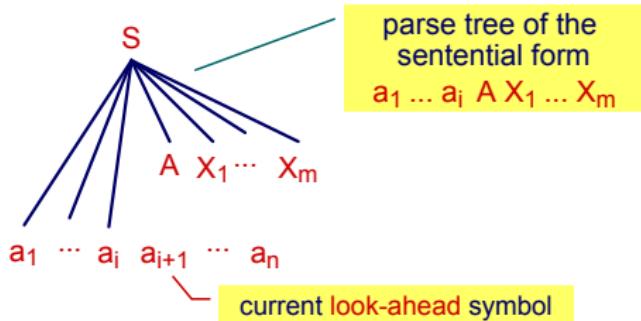


TECHNISCHE
UNIVERSITÄT
DARMSTADT

```
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
```



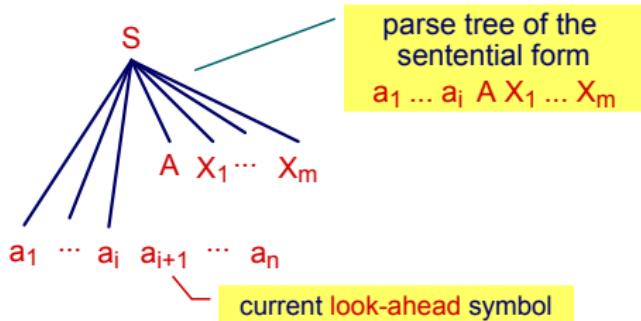
Hintergrund Top-Down Parsing



Falls es möglich ist,

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

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



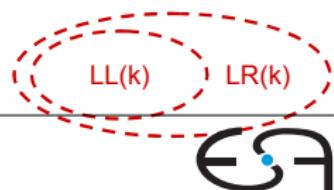
TECHNISCHE
UNIVERSITÄT
DARMSTADT

- ▶ 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

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

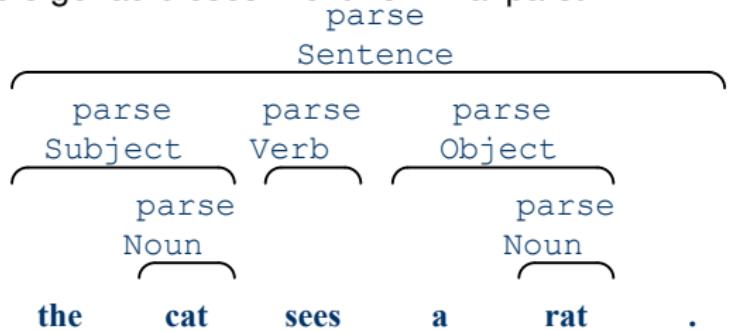
Parson mit rekursivem Abstieg



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() { ... }  
}
```

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() { ... }  
}
```

first token

Schnittstelle zum Scanner,
der die Tokens liefert

In Watt & Brown sind die Parse-Methoden als **private** deklariert. Ungeschickt, da es die Anpassung des Verhaltens durch Vererbung verhindert.

Erläuterung



TECHNISCHE
UNIVERSITÄT
DARMSTADT

- ▶ **currentToken** enthält nacheinander die Tokens des Eingabetextes

- ▶ **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

- ▶ **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**

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



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.

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]]



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

Berechnungsregeln für starters[[X]]



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

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)

Inhalt der `parseN`-Methoden



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

e ; (=leere Anweisung)

t accept (t);

Inhalt der `parseN`-Methoden



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

e ; (=leere Anweisung)

t accept(t);

P parseP();

Inhalt der `parseN`-Methoden



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

ε ; (=leere Anweisung)
t `accept(t);`
P `parseP();`
P Q `parseP();`
parseQ();

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
```

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() ;
```

Folgemengen



TECHNISCHE
UNIVERSITÄT
DARMSTADT

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

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

Beispiel

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

Anwendbarkeit der Zerlegungsregeln



TECHNISCHE
UNIVERSITÄT
DARMSTADT

Funktionieren nur dann, wenn in Grammatik G gilt:

Anwendbarkeit der Zerlegungsregeln



Funktionieren nur dann, wenn in Grammatik G gilt:

- Falls $G \ X|Y$ enthält und sich weder X noch Y zu ε ableiten lassen:
 $\text{starters}[[X]] \cap \text{starters}[[Y]] = \emptyset$

Anwendbarkeit der Zerlegungsregeln



Funktionieren nur dann, wenn in Grammatik G gilt:

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

Funktionieren nur dann, wenn in Grammatik G gilt:

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

Funktionieren nur dann, wenn in Grammatik G gilt:

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

Anwendbarkeit der Zerlegungsregeln

Funktionieren nur dann, wenn in Grammatik G gilt:

- ▶ Falls $G \ X|Y$ enthält und sich weder X noch Y zu ε ableiten lassen:
 $\text{starters}[[X]] \cap \text{starters}[[Y]] = \emptyset$
 - ▶ Falls $G \ X|Y$ enthält und sich beispielsweise Y zu ε 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!

Nachweis der LL(1)-Eigenschaft

S ::= **Xd**

X ::= **A | B | c**

A ::= **a ***

B ::= **b**

Nachweis der LL(1)-Eigenschaft

- ▶ **S ::= Xe, B ::= b**
- ▶ Nichts zu prüfen

S ::= Xd

X ::= A | B | c

A ::= a *

B ::= b

Nachweis der LL(1)-Eigenschaft



- ▶ **S ::= Xe, B ::= b**
- ▶ Nichts zu prüfen

S ::= Xd ▶ **X ::= A | B | c**

X ::= A | B | c

A ::= a *

B ::= b

Nachweis der LL(1)-Eigenschaft



- ▶ **S ::= Xe, B ::= b**
 - ▶ Nichts zu prüfen
- S ::=Xd**
- ▶ **X ::= A | B | c**
 - ▶ Produktion enthält 3 Alternativen → **paarweise prüfen!**
- X ::= A | B | c**
- A ::= a ***
- B ::= b**

Nachweis der LL(1)-Eigenschaft

- | | |
|-------------------------|--|
| $S ::= Xd$ | ▶ $S ::= Xe, B ::= b$
▶ Nichts zu prüfen |
| $X ::= A \mid B \mid c$ | ▶ $X ::= A \mid B \mid c$
▶ Produktion enthält 3 Alternativen → paarweise prüfen! |
| $A ::= a *$ | ▶ $B \mid c$
starters[[B]] ∩ starters[[c]] = ∅ ✓ |
| $B ::= b$ | |

Nachweis der LL(1)-Eigenschaft



- | | |
|-------------------|--|
| $S ::= Xd$ | ▶ $S ::= Xe, B ::= b$
Nichts zu prüfen |
| $X ::= A B c$ | ▶ $X ::= A B c$
Produktion enthält 3 Alternativen → paarweise prüfen! |
| $A ::= a *$ | ▶ $B c$
$\text{starters}[[B]] \cap \text{starters}[[c]] = \emptyset \checkmark$ |
| $B ::= b$ | ▶ $A B$
A kann zu ε abgeleitet werden!
$(\text{starters}[[A]] \cup \text{follow}[[A B]]) \cap \text{starters}[[B]] = \emptyset \checkmark$ |

Nachweis der LL(1)-Eigenschaft



- | | |
|-------------------|---|
| $S ::= Xd$ | ▶ $S ::= Xe, B ::= b$
Nichts zu prüfen |
| $X ::= A B c$ | ▶ $X ::= A B c$ |
| $A ::= a *$ | ▶ Produktion enthält 3 Alternativen → paarweise prüfen! |
| $B ::= b$ | ▶ $B c$
starters[[B]] \cap starters[[c]] = \emptyset ✓
▶ $A B$
A kann zu ε abgeleitet werden!
(starters[[A]] \cup follow[[A B]]) \cap starters[[B]] = \emptyset ✓
▶ $A c$ analog |

Nachweis der LL(1)-Eigenschaft



- | | |
|-------------------|---|
| $S ::= Xd$ | ▶ $S ::= Xe, B ::= b$
▶ Nichts zu prüfen |
| $X ::= A B c$ | ▶ $X ::= A B c$ |
| $A ::= a^*$ | ▶ Produktion enthält 3 Alternativen → paarweise prüfen! |
| $B ::= b$ | ▶ $B c$
starters[[B]] \cap starters[[c]] = \emptyset ✓
▶ $A B$
A kann zu ε abgeleitet werden!
(starters[[A]] \cup follow[[A B]]) \cap starters[[B]] = \emptyset ✓
▶ $A c$ analog |
| | ▶ $A ::= a^*$ |

Nachweis der LL(1)-Eigenschaft



- | | |
|-------------------|---|
| $S ::= Xd$ | ▶ $S ::= Xe, B ::= b$
▶ Nichts zu prüfen |
| $X ::= A B c$ | ▶ $X ::= A B c$ |
| $A ::= a^*$ | ▶ Produktion enthält 3 Alternativen → paarweise prüfen! |
| $B ::= b$ | ▶ $B c$
starters[[B]] \cap starters[[c]] = \emptyset ✓
▶ $A B$
A kann zu ε abgeleitet werden!
(starters[[A]] \cup follow[[A B]]) \cap starters[[B]] = \emptyset ✓
▶ $A c$ analog |
| | ▶ $A ::= a^*$
▶ a^*
starters[[a]] \cap follow[[a*]] = \emptyset ✓ |

Verfeinerte Zerlegungsregeln



Bisher gezeigt für P|Q

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

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.

Verfeinerte Zerlegungsregeln

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 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



TECHNISCHE
UNIVERSITÄT
DARMSTADT

- ▶ Aus Algol Grammatik

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

Beispiel für nicht-LL(1) Grammatik



TECHNISCHE
UNIVERSITÄT
DARMSTADT

- ▶ Aus Algol Grammatik
- Block ::= begin Declaration (; Declaration)* ; Command end**

- ▶ Prüfe Regel für X*

Beispiel für nicht-LL(1) Grammatik



- ▶ Aus Algol Grammatik

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

- ▶ Prüfe Regel für X*

- ▶ starters[[; Declaration]] = { ; }

Beispiel für nicht-LL(1) Grammatik

- ▶ Aus Algol Grammatik
- Block ::= begin Declaration (; Declaration)* ; Command end**
- ▶ Prüfe Regel für X*
- ▶ starters[["; Declaration"]] = {";"}
- ▶ follow[["(; Declaration)*"]]] = {";"}

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)*"]]
 $\neq \emptyset$

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**

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 $k > 1$.

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 $k = \infty$.

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)*

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



TECHNISCHE
UNIVERSITÄT
DARMSTADT

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

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`

- ▶ 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`: +, -, /, ...

- ▶ 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
                  | ...
```

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
```

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



TECHNISCHE
UNIVERSITÄT
DARMSTADT

Jetzt mit Linksausklammern

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

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



TECHNISCHE
UNIVERSITÄT
DARMSTADT

Auszug aus Grammatik vor Korrektur

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

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;

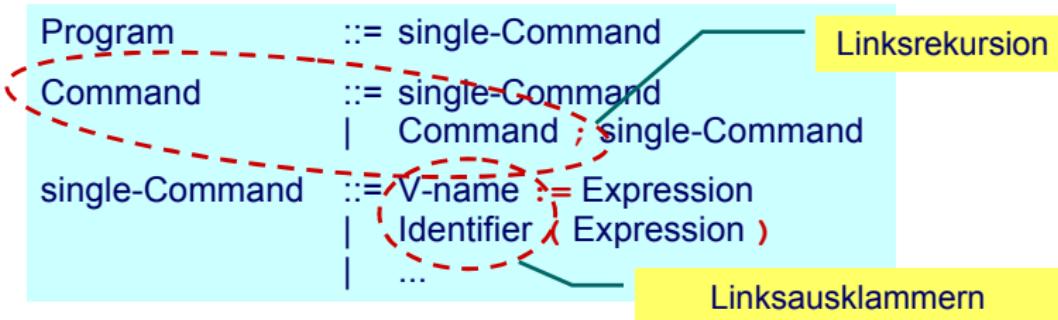
        default:
            report a syntactic error
    }
}
```

Parser für Mini-Triangle: Grammatikanpassung



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

Parser für Mini-Triangle: Grammatikanpassung



Parser für Mini-Triangle: Grammatikanpassung



TECHNISCHE
UNIVERSITÄT
DARMSTADT

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

Abstrakte Syntaxbäume 1

- ▶ Parser mit rekursivem Abstieg baut impliziten Syntaxbaum auf
 - ▶ Durch den Aufrufgraph der Parse-Methoden

- ▶ Parser mit rekursivem Abstieg baut impliziten Syntaxbaum auf
 - ▶ Durch den Aufrufgraph der Parse-Methoden
- ▶ In einem Ein-Pass-Compiler unproblematisch

- ▶ 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

- ▶ Beobachtung: Jedes Nicht-Terminalsymbol **XYZ** wird durch eine Parse-Methode **parseXYZ** bearbeitet
 - protected void parseXYZ ()**
 - ▶ Bisher nicht benutzt: Funktionsergebnis und Parameter

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

AST Knoten von Mini-Triangle



Program	::= Command	
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	
Expression	::= Integer-Literal V-name Operator Expression Expression Operator Expression	
V-name	::= Identifier	
Declaration	::= Declaration ; Declaration const Identifier ~ Expression var Identifier : Type-denoter	
Type-denoter	::= Identifier	



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

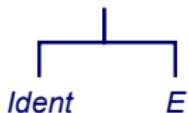
SequentialCmd



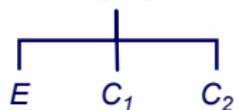
AssignCmd



CallCmd



IfCmd



WhileCmd



LetCmd



- ▶ Abstrakte Basisklasse

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

- ▶ Eigene Subklassen für alle Arten von AST-Knoten

- ▶ 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

```
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 { ... }
```

Unterklassen der Command-Klasse



```
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

Unterklassen der Command-Klasse



```
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

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;  
    ...  
}
```

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;  
    }  
}
```

Aufbau des ASTs



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

- ▶ 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  
}
```

Zusammensetzen von Subphrasen ASTs 1



TECHNISCHE
UNIVERSITÄT
DARMSTADT

EBNF

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

Zusammensetzen von Subphrasen ASTs 1



TECHNISCHE
UNIVERSITÄT
DARMSTADT

EBNF

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

AST

Command ::= Command ; Command

SequentialCmd

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;  
}
```

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;  
}
```

EBNF

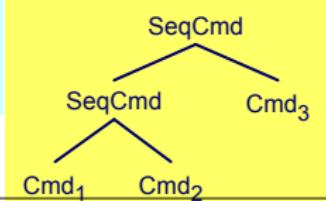
Command ::= single-Command (; single-Command)*

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:
            melde 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();  
    }  
  
    ...  
}
```

Scanner



TECHNISCHE
UNIVERSITÄT
DARMSTADT

- ▶ Auch genannt lexikalische Analyse oder Lexer

- ▶ 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

- ▶ 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



TECHNISCHE
UNIVERSITÄT
DARMSTADT

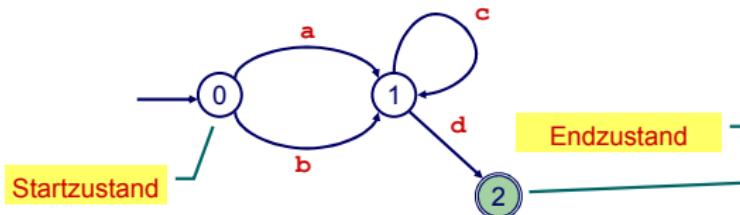
- ▶ Reguläre Ausdrücke können durch **Übergangsdiagramme** dargestellt werden
 - ▶ Endliche Automaten
 - ▶ Kanten/Transitionen beschriftet mit **Eingabesymbolen**
 - ▶ Zustände/Knoten
 - ▶ Genau ein Startzustand
 - ▶ Beliebig viele Endzustände (akzeptierende Zustände)

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



TECHNISCHE
UNIVERSITÄT
DARMSTADT

Systematische Konstruktion von Scannern

1. Formuliere lexikalische Grammatik in EBNF
 - ▶ Falls nötig: Transformiere für rekursiven Abstieg

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

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() { ... }
    ...
}
```

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() { ... }  
    ...  
}
```

Wäre besser lokale Variable in scan.

Hänge currentChar an currentSpelling an und lese nächstes Zeichen in currentChar.

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
```

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!

Feinheiten am Rande

- ▶ EBNF kann **nicht** trennen zwischen

Feinheiten am Rande

- ▶ EBNF kann **nicht** trennen zwischen
 - ▶ Schlüsselworten

Feinheiten am Rande



TECHNISCHE
UNIVERSITÄT
DARMSTADT

- ▶ EBNF kann **nicht** trennen zwischen
 - ▶ Schlüsselworten
 - ▶ Bezeichnern

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

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

- ▶ EBNF kann **nicht** trennen zwischen
 - ▶ Schlüsselworten
 - ▶ 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 == '!')
        || (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)| ~ | ( | ) | 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



```
...
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 nur Unterscheidung zwischen Bezeichnern und Schlüsselworten?

Compiler 1 Komplizierung Syntaxanalyse Parsing Rekursiver Abstieg Konstruktion ASTs Scanning

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