

30. Parser-Generatoren

Prof. Dr. rer. nat. Uwe Aßmann
Institut für Software- und
Multimediatechnik

Lehrstuhl Softwaretechnologie
Fakultät für Informatik
TU Dresden

<http://st.inf.tu-dresden.de>

Version 11-0.1, 29.12.11

- 1) Grundlagen
- 2) Beispiel Taschenrechner



1

SEW, © Prof. Uwe Aßmann

Literatur

► Obligatorisch:

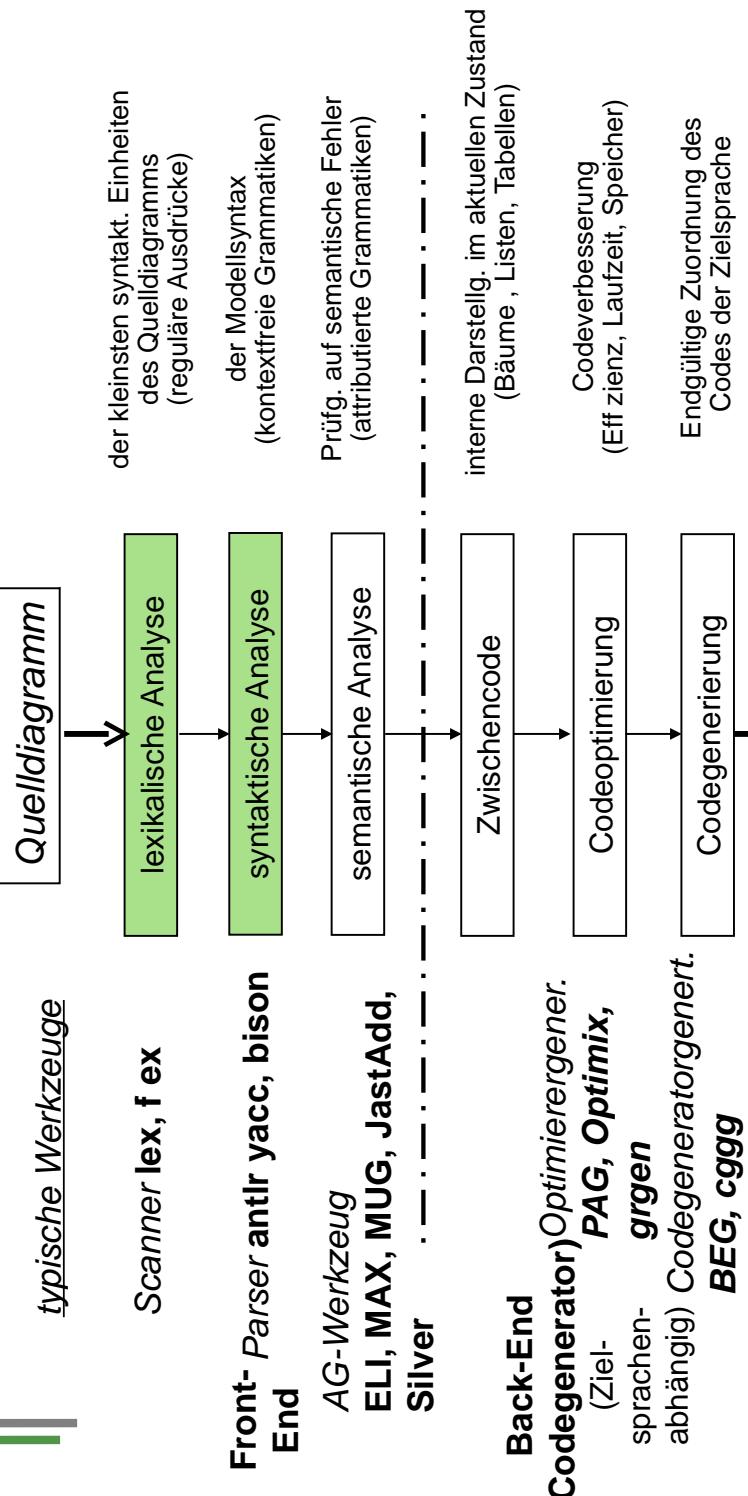
► <http://www.antlr.org>

► Zusätzlich:

- Cocktail www.cocollab.de, die Compiler-Toolbox für die schnellsten Compiler der Welt (kommerziell, Demoversionen erhältlich)



Phasen eines Compilers



Antwort

- Technikraum "Grammarware"

In dem ich aus Grammatiken Parser (Zerteiler) generiere
und
zusätzlich Prettyprinter



Beispiel EMFText

- Nutzt Parser-Generator ANTLR zur Generierung von Parsem
 - Parser und Metamodell werden aufeinander abgebildet (mapping), um konkrete auf abstrakte Syntax abzubilden
- Nutzt schablonengesteuerte Codegenerierung zur Erzeugung von Text und Programmen (siehe später).



Beispiel EMFText

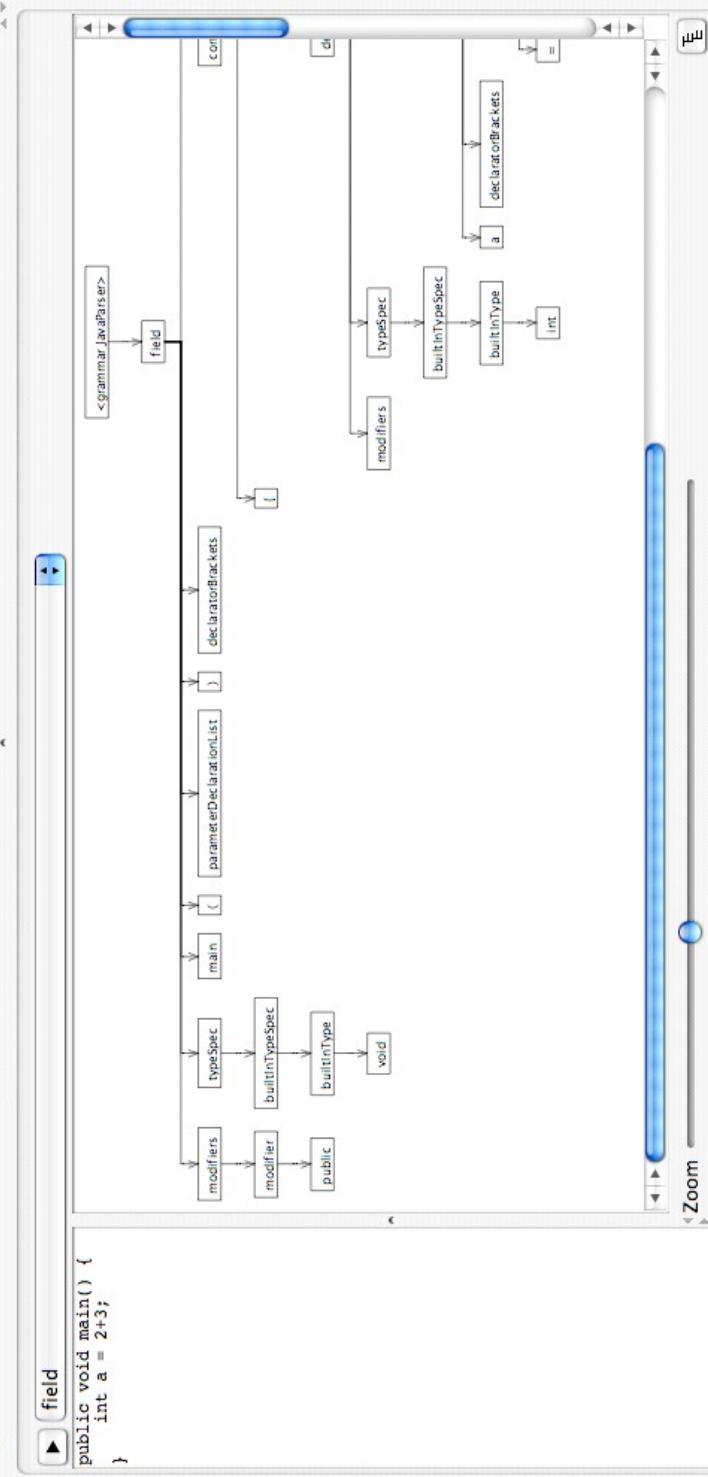
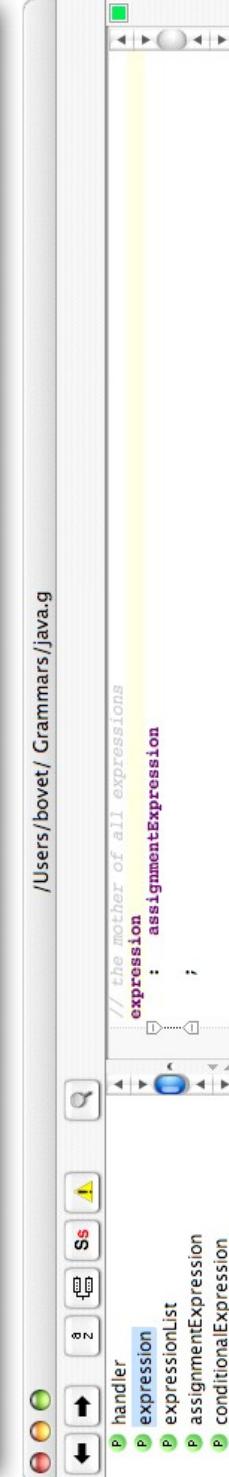
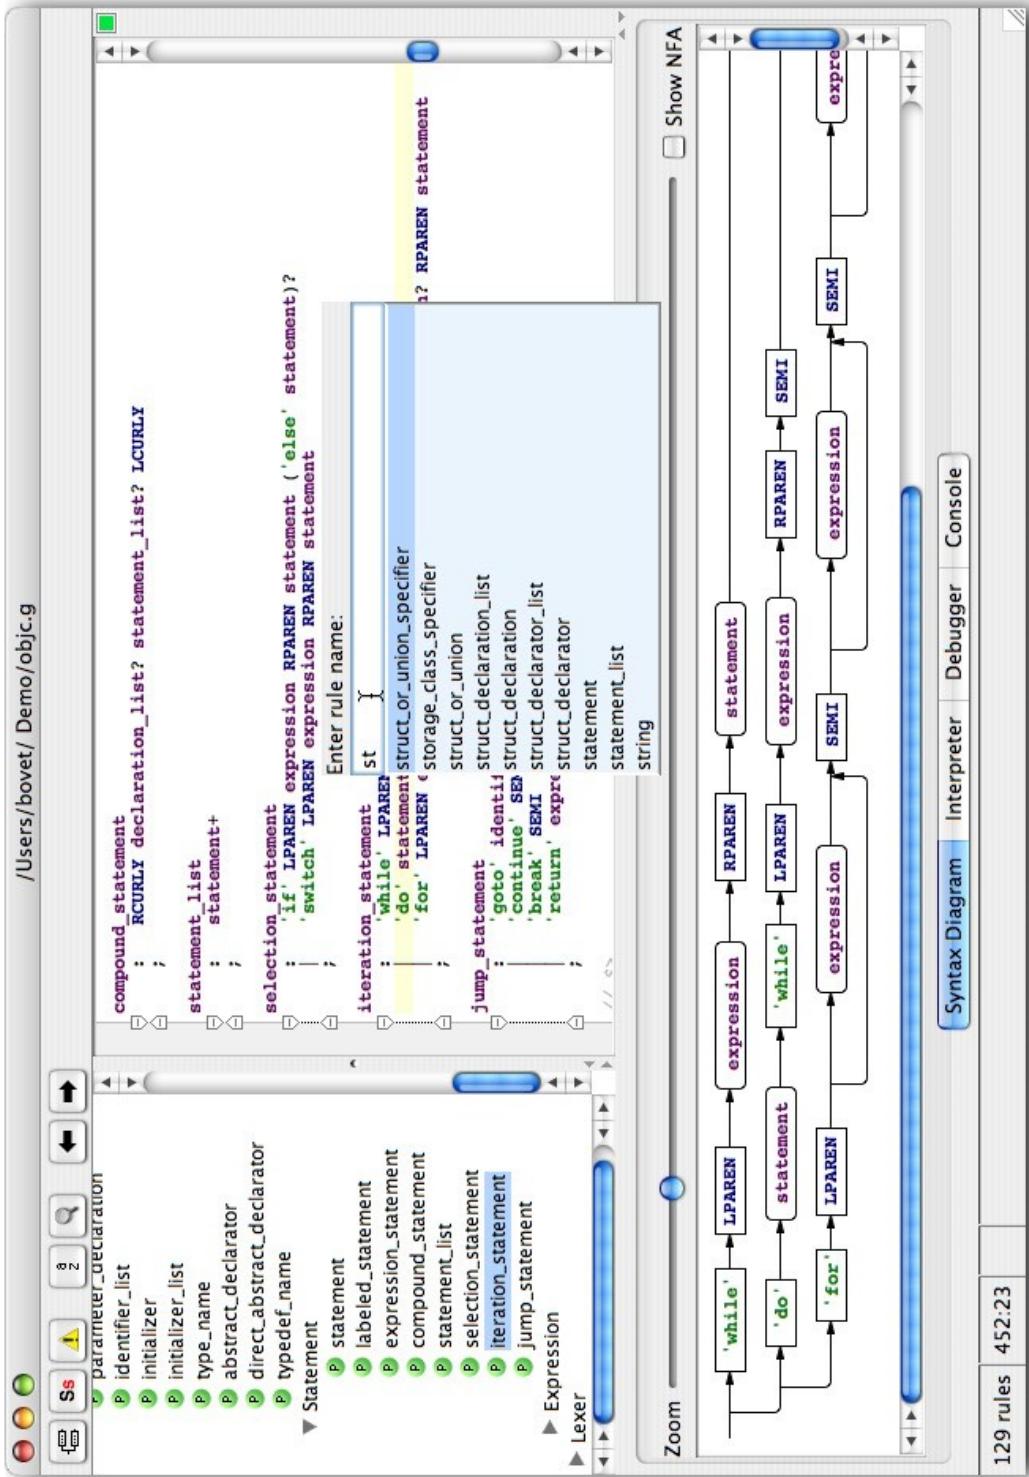
- ▶ Nutzt Parser-Generator ANTLR zur Generierung von Parsem
 - Parser und Metamodell werden aufeinander abgebildet (mapping), um konkrete auf abstrakte Syntax abzubilden
- ▶ Nutzt schablonengesteuerte Codegenerierung zur Erzeugung von Text und Programmen (siehe später).

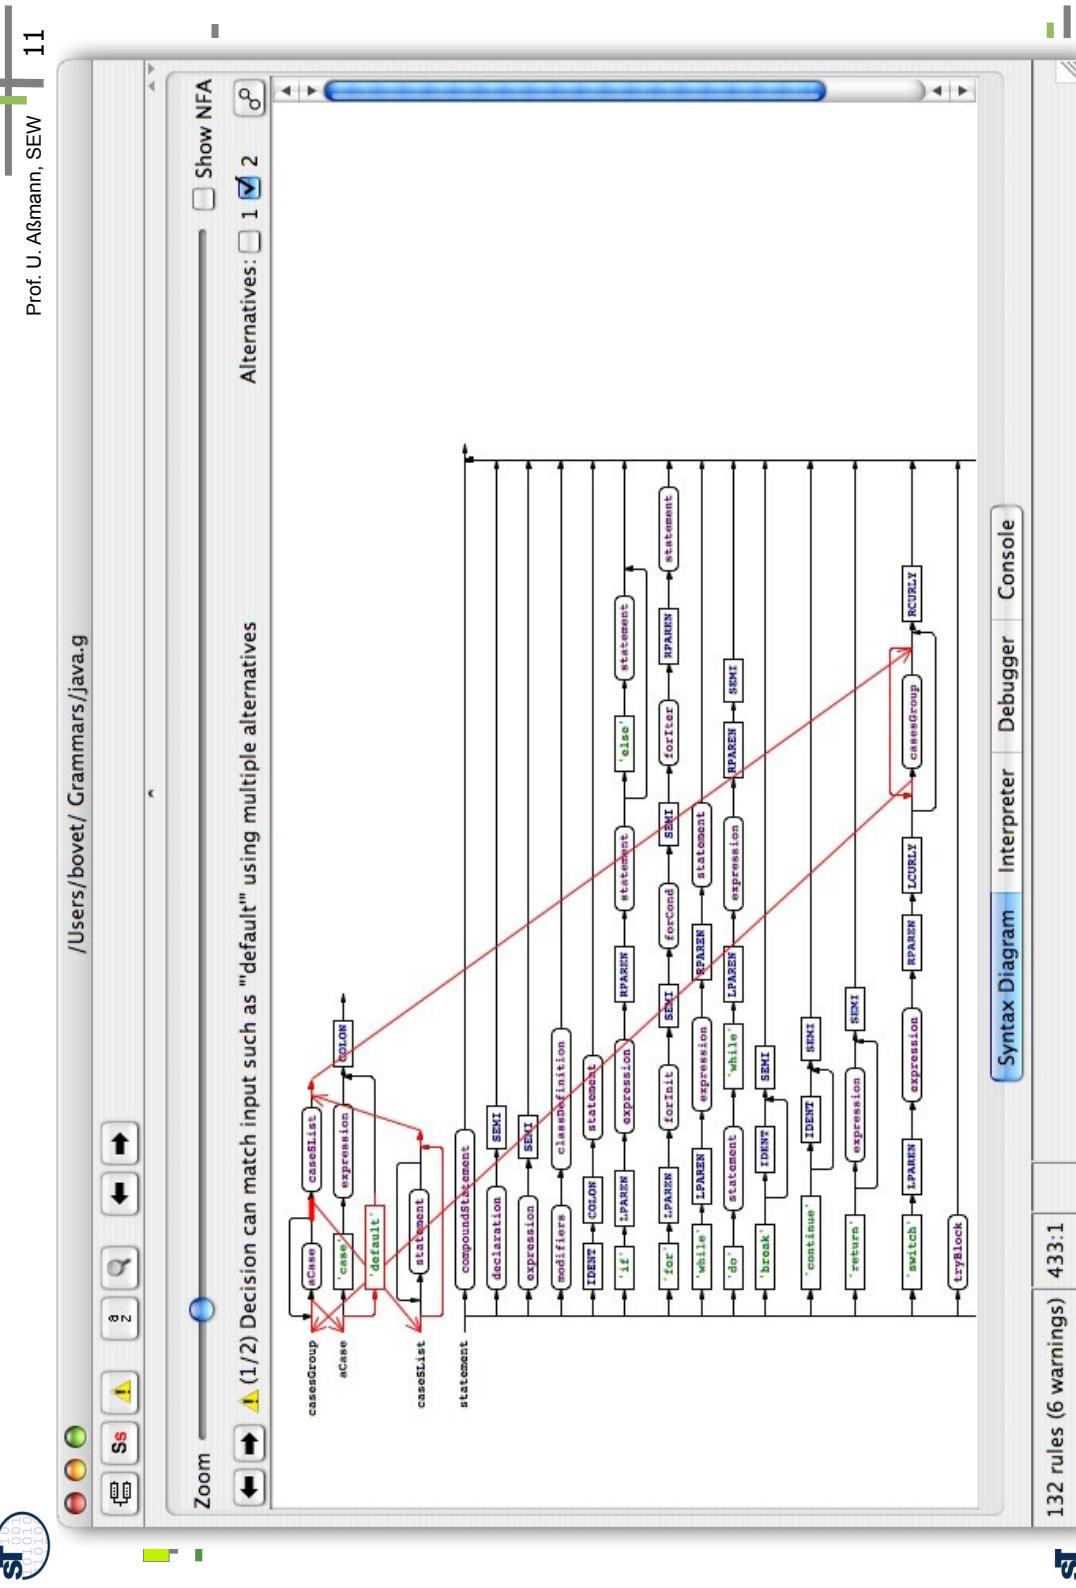
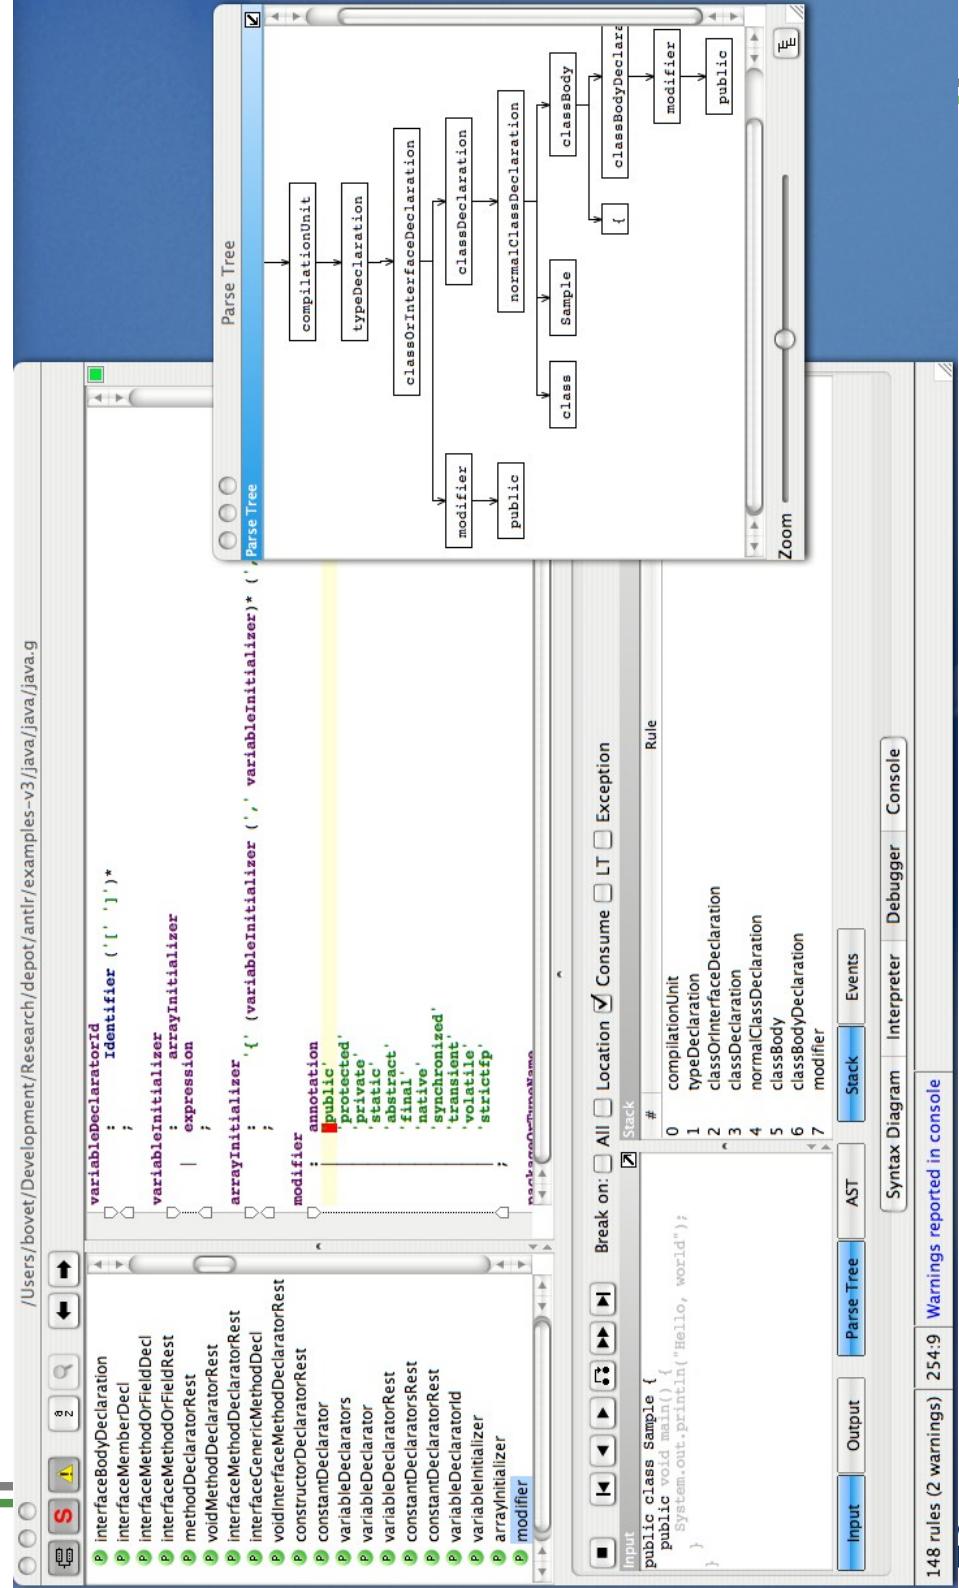


ANTLR www.antlr.org

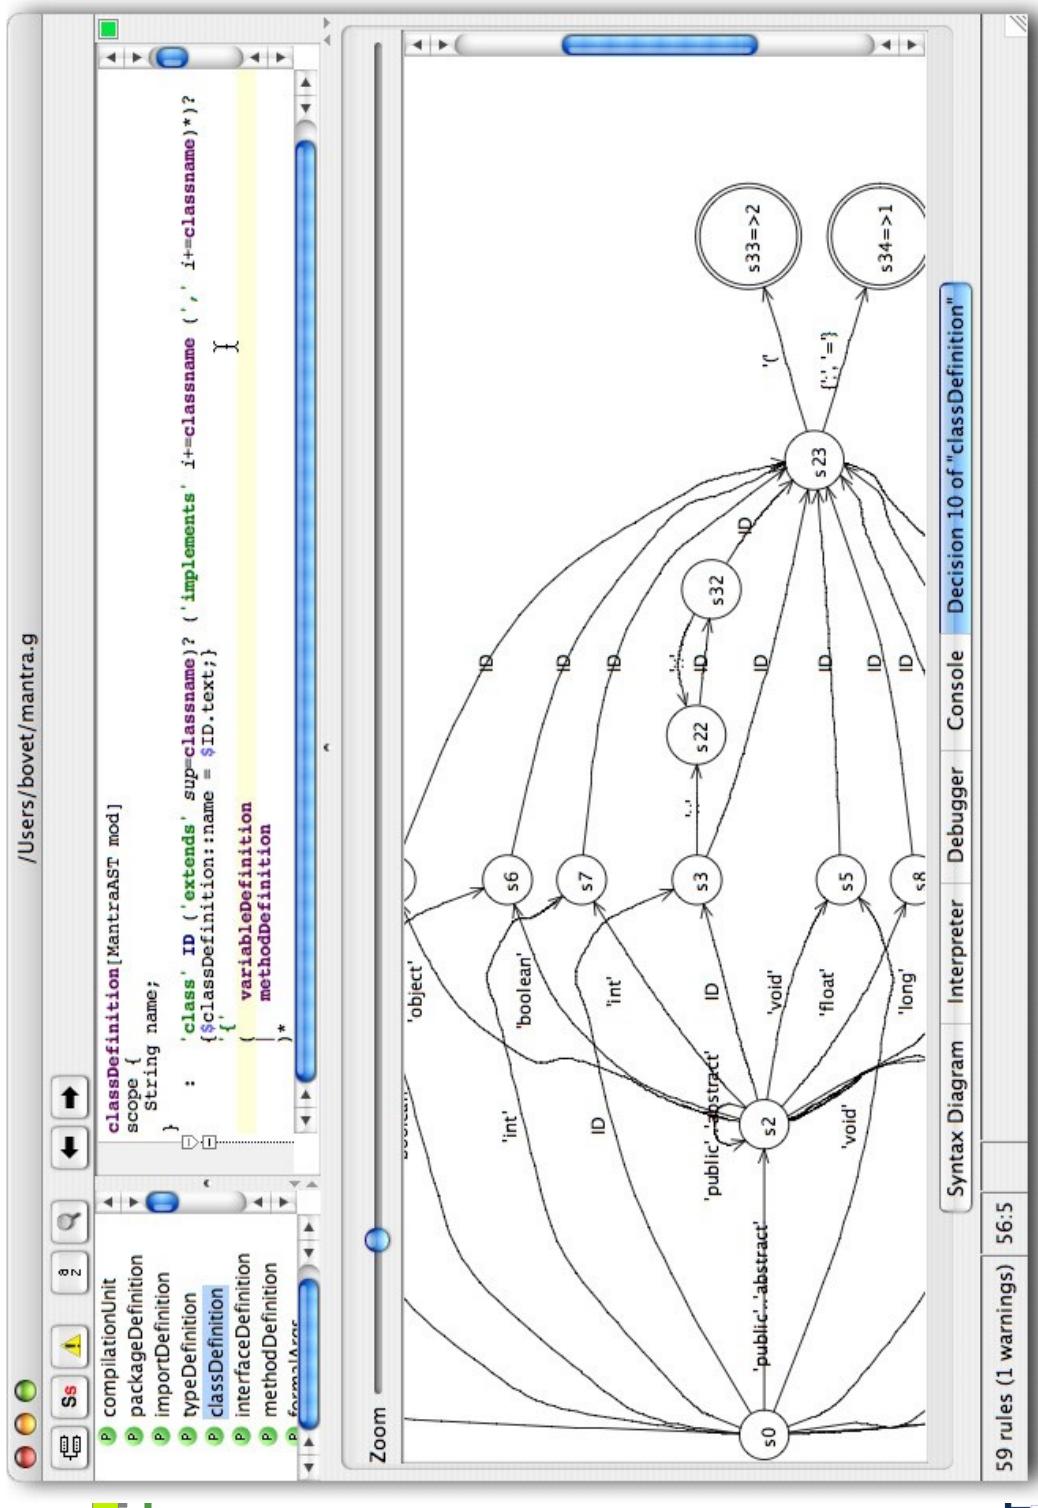
- ▶ In den 90er Jahren gab es für C viele Parsergeneratoren
 - Cocktail's lalr, ell, lark www.coccolab.de
 - fnc2
 - flex und bison (gnu)
- ▶ Für Java ist ANTLR populär geworden
 - LL(k)
 - Generierter Parser mit Algorithmus "rekursiver Abstieg"
 - Etwas "gefärbte" Seite mit Geschichte
http://www.bearcave.com/software/antlr/antlr_expr.html







30.2 Ein Taschenrechner



```

grammar Expr;
@header {
    package test;
    import java.util.HashMap;
}
@lexer::header {package test;}
@members {
    /* Map variable name to Integer object holding value */
    HashMap memory = new HashMap();
}
prog: stat+ ;
stat: expr NEWLINE {System.out.println($expr.value);}*
     | ID '=' expr NEWLINE
       {memory.put ($ID.text, new Integer($expr.value)) ;}
     | NEWLINE
expr returns [int value]
: e=multExpr {$value = $e.value; }
  ( '+' e=multExpr {$value += $e.value; }
  | '-' e=multExpr {$value -= $e.value; }
  )*
multExpr returns [int value]
: e=atom {$value = $e.value; } ( '*' e=atom {$value *= $e.value; })*
atom returns [int value]
: INT {$value = Integer.parseInt($INT.text); }
| ID
{
    Integer v = (Integer)memory.get($ID.text);
    if ( v==null ) $value = v.intValue();
    else System.out.println("undefined variable "+$ID.text);
}
| (' e=expr ') {$value = $e.value; }
ID : ('a'..'z'|'A'..'Z')+;
INT : '0'.. '9'+ ;
NEWLINE: '\r'? '\n' ;
WS : (' '|'\t')+ {skip();} ;

```

Prof. U. Asmann, SEW

15

Ansteuerung

```

import org.antlr.runtime.*;
public class Test {
    public static void main(String[] args) throws Exception {
        ANTLRInputStream input = new
        ANTLRInputStream(System.in);
        ExprLexer lexer = new ExprLexer(input);
        CommonTokenStream tokens = new
        CommonTokenStream(lexer);
        ExprParser parser = new ExprParser(tokens);
        parser.prog();
    }
}

```

```

grammar Expr;
@header {
    package test;
    import java.util.HashMap;
}
@lexer::header [package test]

@members {
    /* Map variable name to integer object holding value */
    HashMap memory = new HashMap();
}

prog: stat+ ;
stat: expr NEWLINE [System.out.println(${expr.value});]
     | ID '=' expr NEWLINE
       [memory.put($ID.text, new Integer(${expr.value}))]
     | NEWLINE
expr returns [int value]
: e=multExpr {$value = $e.value;}
  ( '+' e=multExpr {$value += $e.value;}
  | '-' e=multExpr {$value -= $e.value;}
  )*
Line Endings: Unix (LF)
Ignore rules: WS

```

Syntax Diagram:

17

```

grammar Expr;
@header {
    package test;
    import java.util.HashMap;
}
@lexer::header [package test]

@members {
    /* Map variable name to integer object holding value */
    HashMap memory = new HashMap();
}

prog: stat+ ;
stat: expr NEWLINE [System.out.println(${expr.value});]
     | ID '=' expr NEWLINE
       [memory.put($ID.text, new Integer(${expr.value}))]
     | NEWLINE
expr returns [int value]
: e=multExpr {$value = $e.value;}
  ( '+' e=multExpr {$value += $e.value;}
  | '-' e=multExpr {$value -= $e.value;}
  )*
multExpr returns [int value]
: e=atom {$value = $e.value;} ("+" e=multExpr {$value += $e.value;})
| e=atom {$value = $e.value;} ("-" e=multExpr {$value -= $e.value;})
atom returns [int value]
: INT {$value = Integer.parseInt($INT.text);}
ID
{
    Integer v = (Integer)memory.get($ID.text);
    if (v==null) $value = v.intValue();
    else System.out.println("undefined variable "+$ID.text);
}
expr returns [int value]
| e=expr Y {$value = $e.value;}
Y: ID : ('a','z')|('A','Z')+;
INT: '0'..'9'+;
NEWLINE: '\r' '\n';
WS: [ \t ]*;

Break on:  All  Location  Consume  LT  Exception
Parse Tree
Input 2
Stack
Rule
# 0: prog
1: stat
2: expr
3: multExpr
4: atom

```

Syntax Diagram:

18

The screenshot shows the ANTLR4 IDE interface. On the left, the grammar file `Expr.g` is displayed:

```

grammar Expr;

prog : @header {
        package test;
        package java.util.HashMap;
        import java.util.*;
    }
    @lexer::header {package test;}
    @members {
        /* Map variable name to integer object holding value */
        HashMap memory = new HashMap();
    }

    prog: stat+
    stat: ID '=' expr NEWLINE [System.out.println($expr.value);]
        | NEWLINE
        | INT
        | WS
        | NEWLINE
        | expr returns [int value]
            : e=multExpr {$value = $e.value;}
            | '+' e=multExpr {$value += $e.value;}
            | '-' e=multExpr {$value -= $e.value;}
            | '*' e=multExpr {$value *= $e.value;}
    ;

```

The right side of the interface shows a parse tree for the input expression `2 + 3 * 4`. The tree structure is as follows:

```

graph TD
    root[Root] --> prog[prog]
    prog --> stat1[stat]
    stat1 --> ID1[ID]
    ID1 --> E1[2]
    stat1 --> plus[+]
    plus --> E2[3]
    E2 --> atom2[atom]
    atom2 --> num2["2"]
    stat1 --> mult[*]
    mult --> E3[4]
    E3 --> atom3[atom]
    atom3 --> num3["4"]

```

The parse tree is visualized with nodes representing tokens and non-terminals, and arrows indicating the hierarchical structure of the expression.

19

Was haben wir gelernt?

- ▶ Parsegeneratoren gehören heute zum Werkzeugsatz jeden Softwareingenieurs
- ▶ Neben Cocktail gibt es freie Initiativen, z.B. ANTLR

The End

