

20. Parser-Generatoren im Technikraum Grammarware

1

- 1) Grundlagen
- 2) Beispiel Taschenrechner

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

Lehrstuhl Softwaretechnologie

Fakultät für Informatik

TU Dresden

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

Version 12-1.1, 15.11.12



Softwareentwicklungswerkzeuge (SEW) © Prof. Uwe Aßmann

Literatur

► Obligatorisch:

► <http://www.antlr.org>

► Zusätzlich:

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



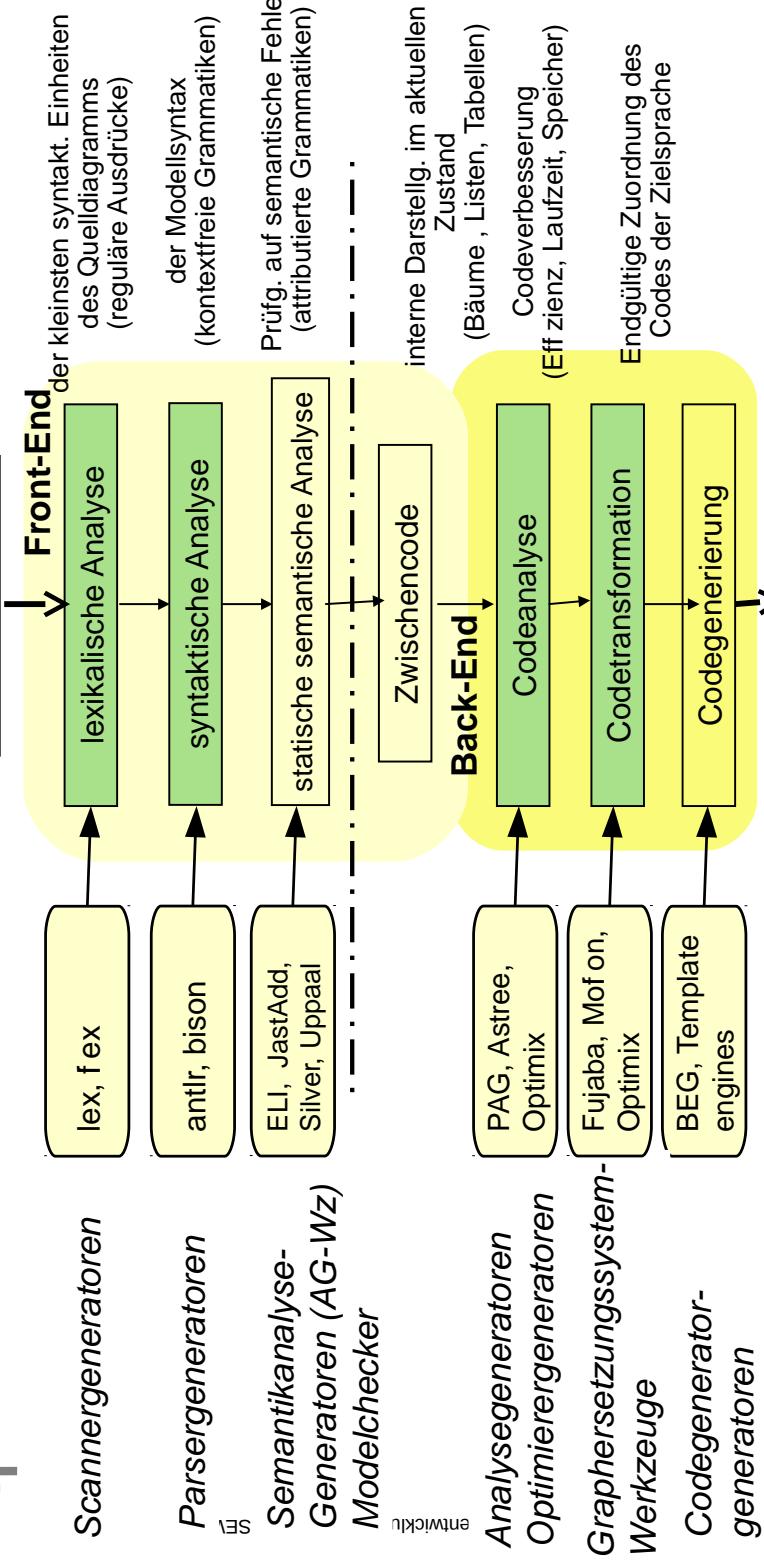
2



Phasen eines Compilers und die erzeugenden Werkzeuge

typische Generatoren

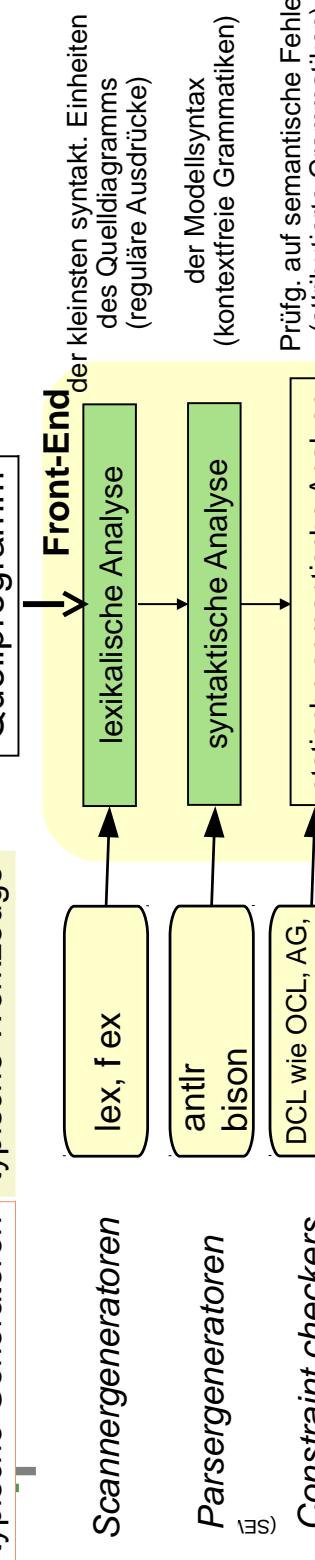
Quellprogramm



Phasen eines Importers in ein Repository und die erzeugenden Werkzeuge

typische Generatoren

Quellprogramm



Query and metric engines

Refactoring engine

Transformation engine

Messung der Qualität des Modells/Codes

Semantik-erhaltende Restrukturierung

Term- oder Graph-Transformation

Problem

5

- ▶ Parsen eines Programms, Modells oder Artefakts bedeutet, seine kontextfreie Syntax zu erkennen
- ▶ Parser sind die ersten Phasen eines Werkzeugs, denn es muss ein Artefakt importieren und damit ihn parsen
- ▶ Parsen erzeugt einen *Syntaxbaum*
- ▶ Parser wurden ursprünglich von Hand geschrieben (Compilerbau), heute generiert man sie aus Grammatiken in *EBNF*

Wie arbeite ich flexibel mit mehreren Programmiersprachen oder DSL?

Antwort

6

- ▶ Bidirektionale Abbildung zwischen Technikraum “Grammarware” und einem anderen Technikraum, wie z.B. “Treeware” oder “Modelware”

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

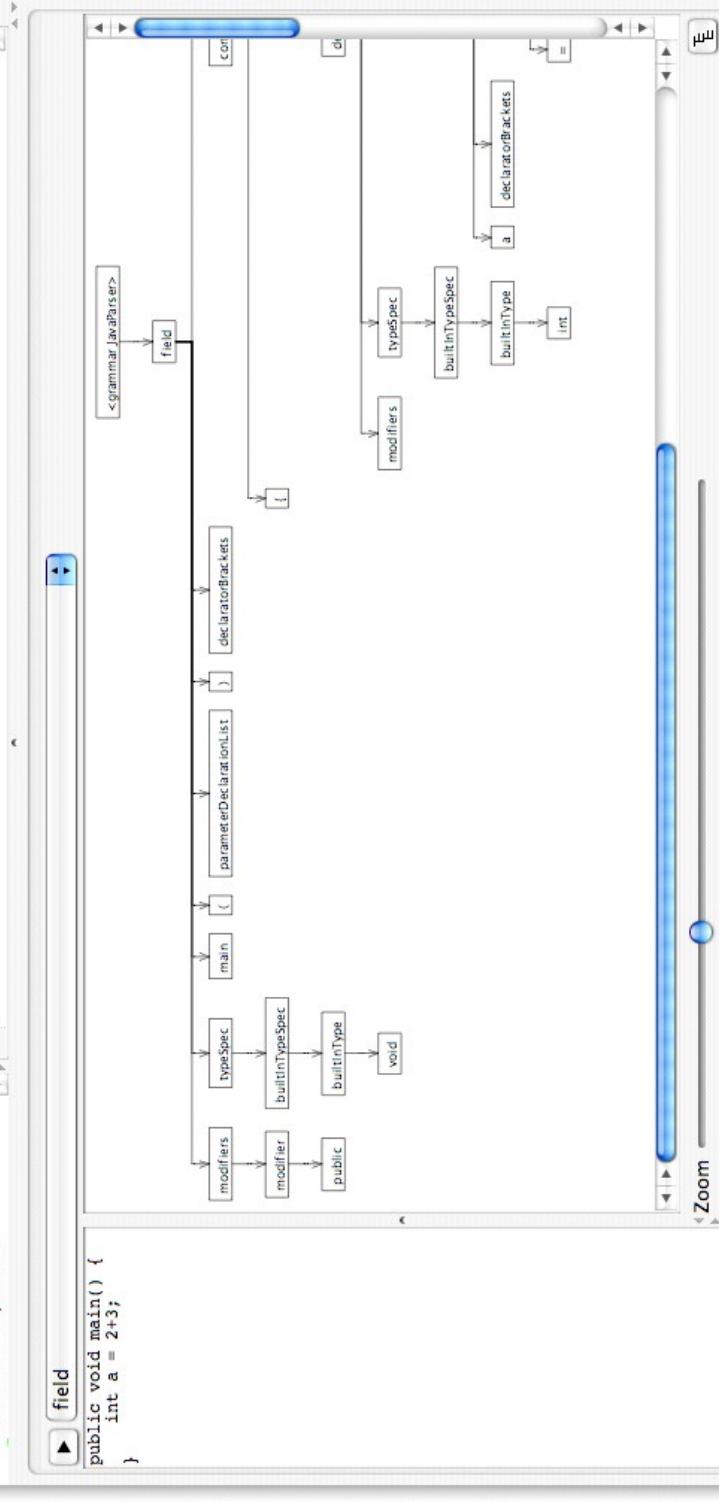
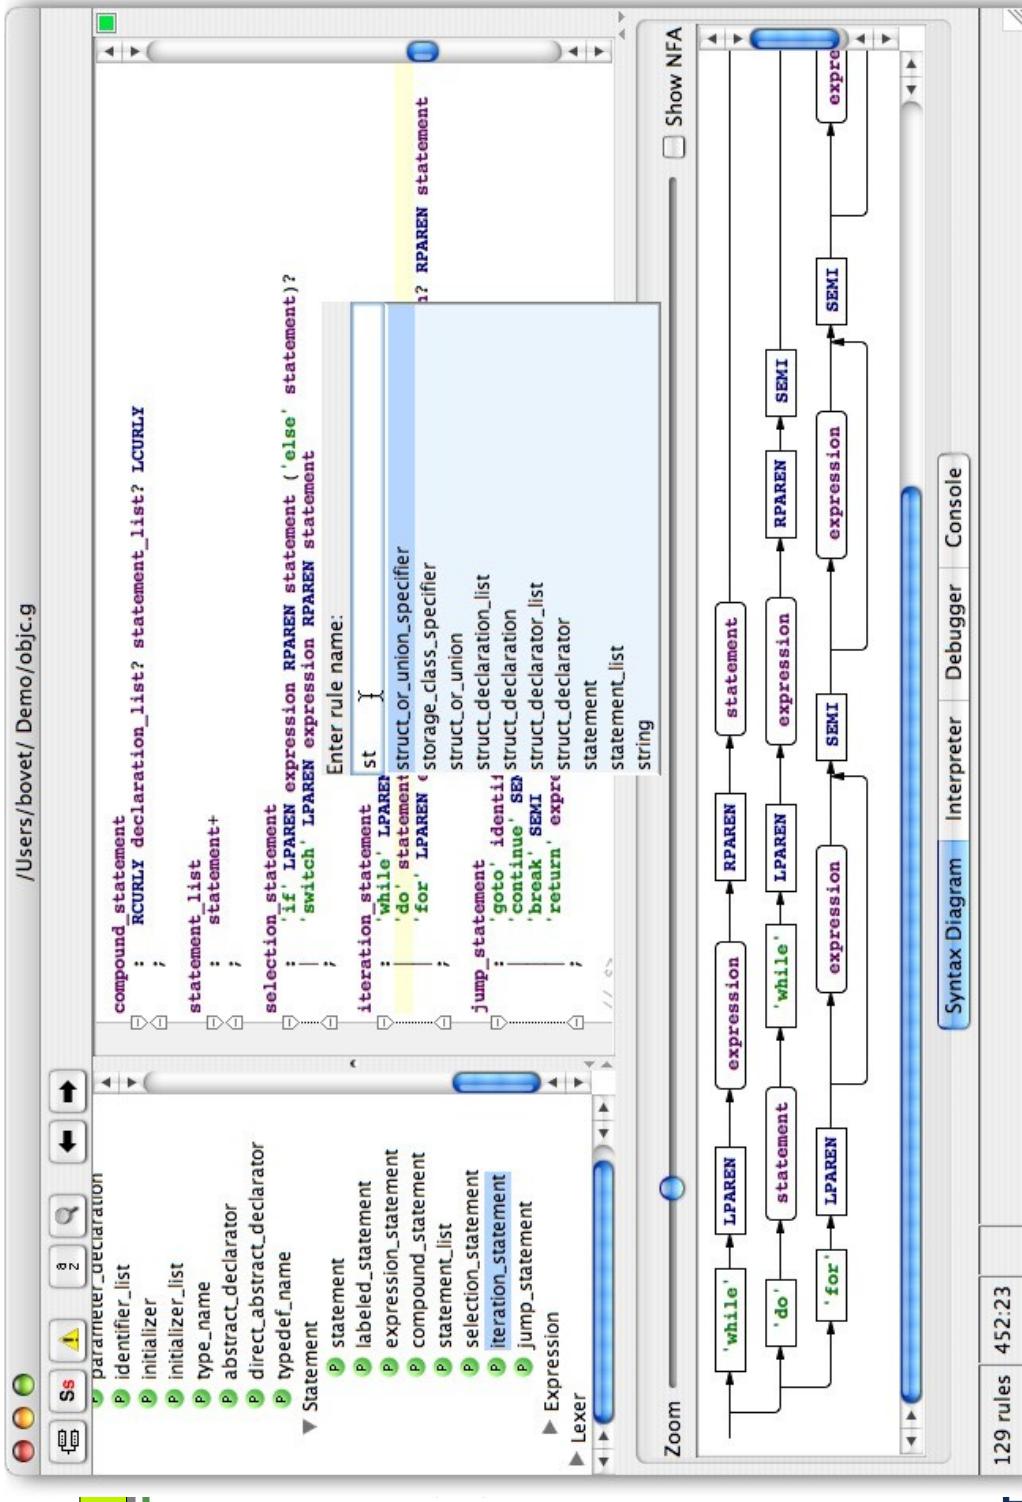


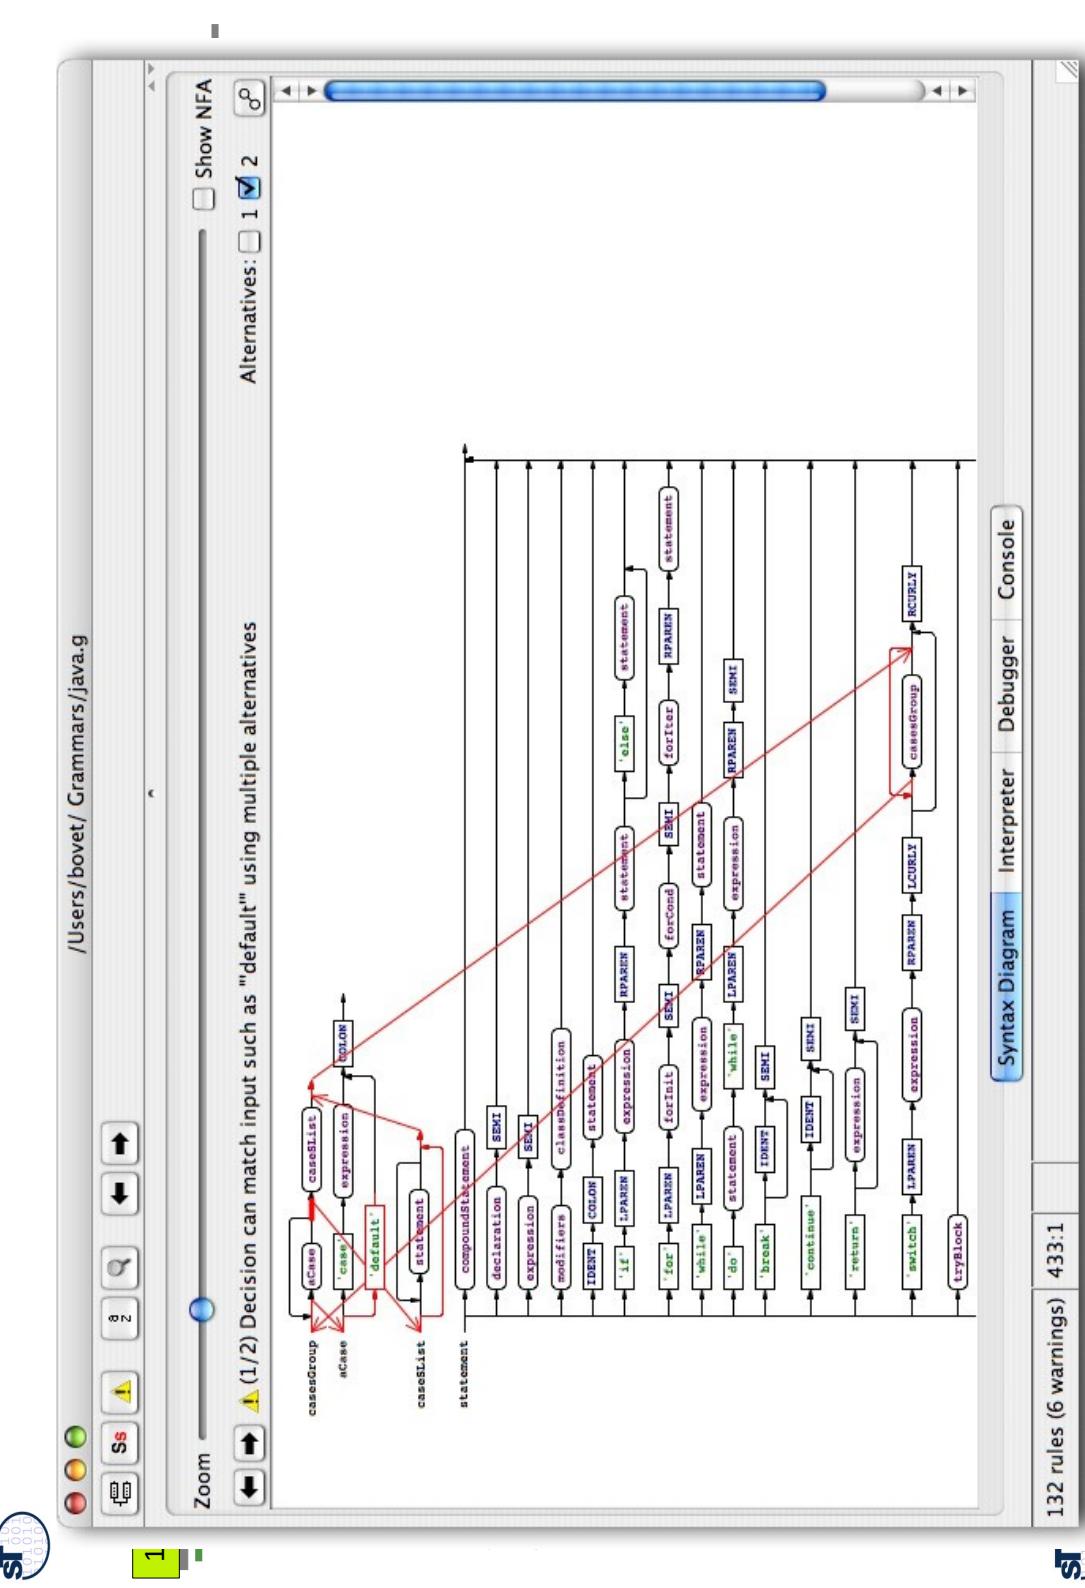
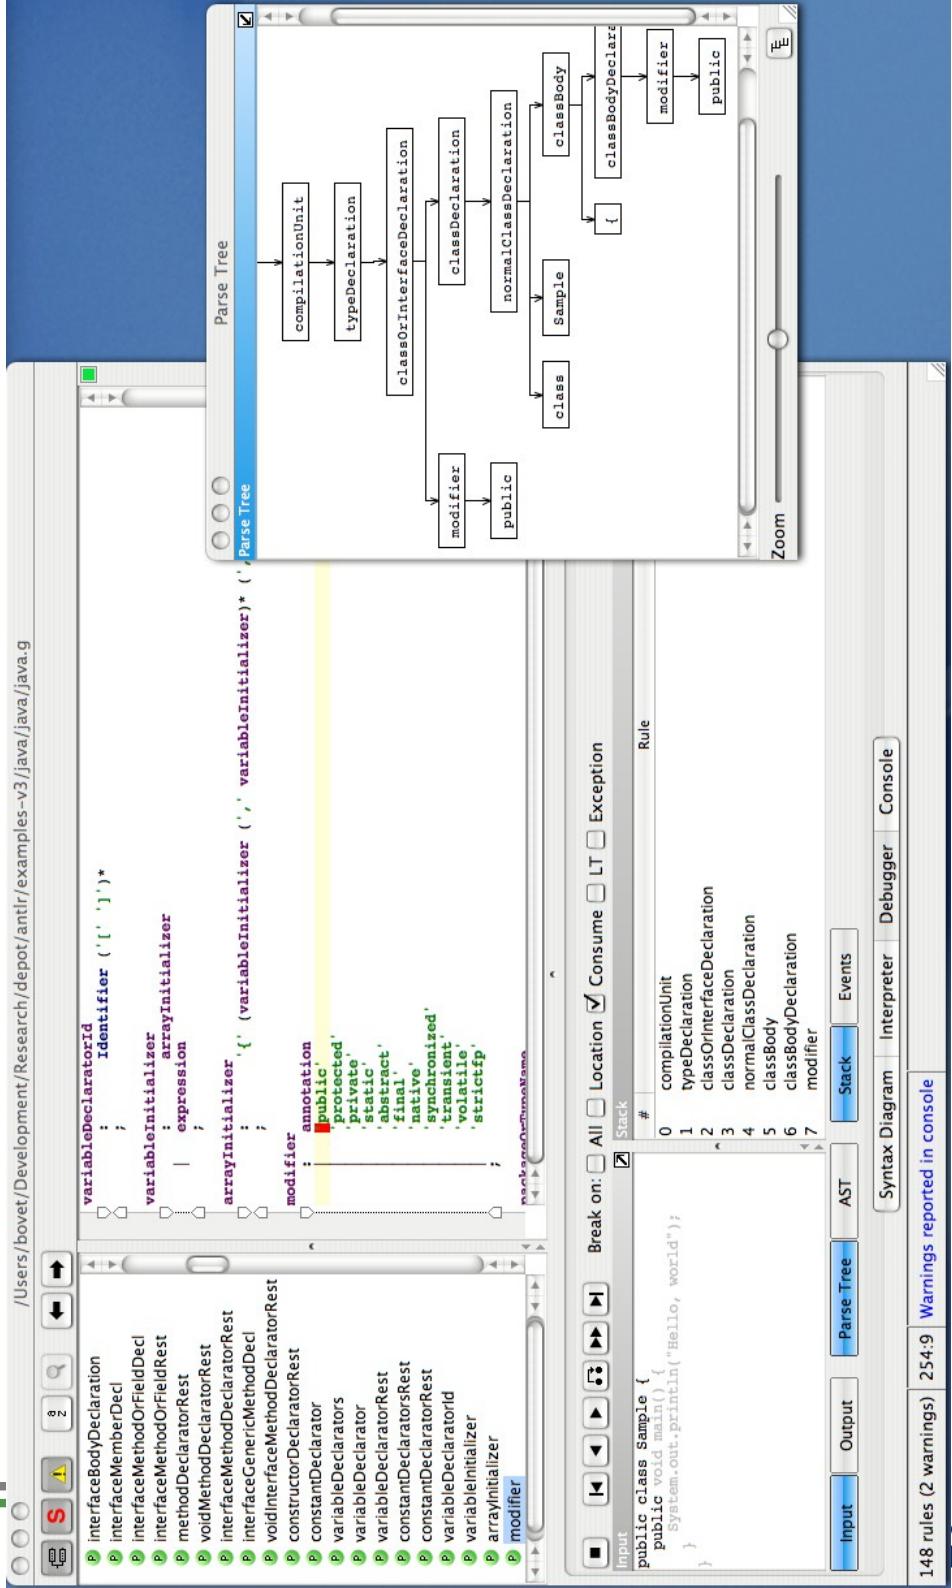
Beispiel EMFText

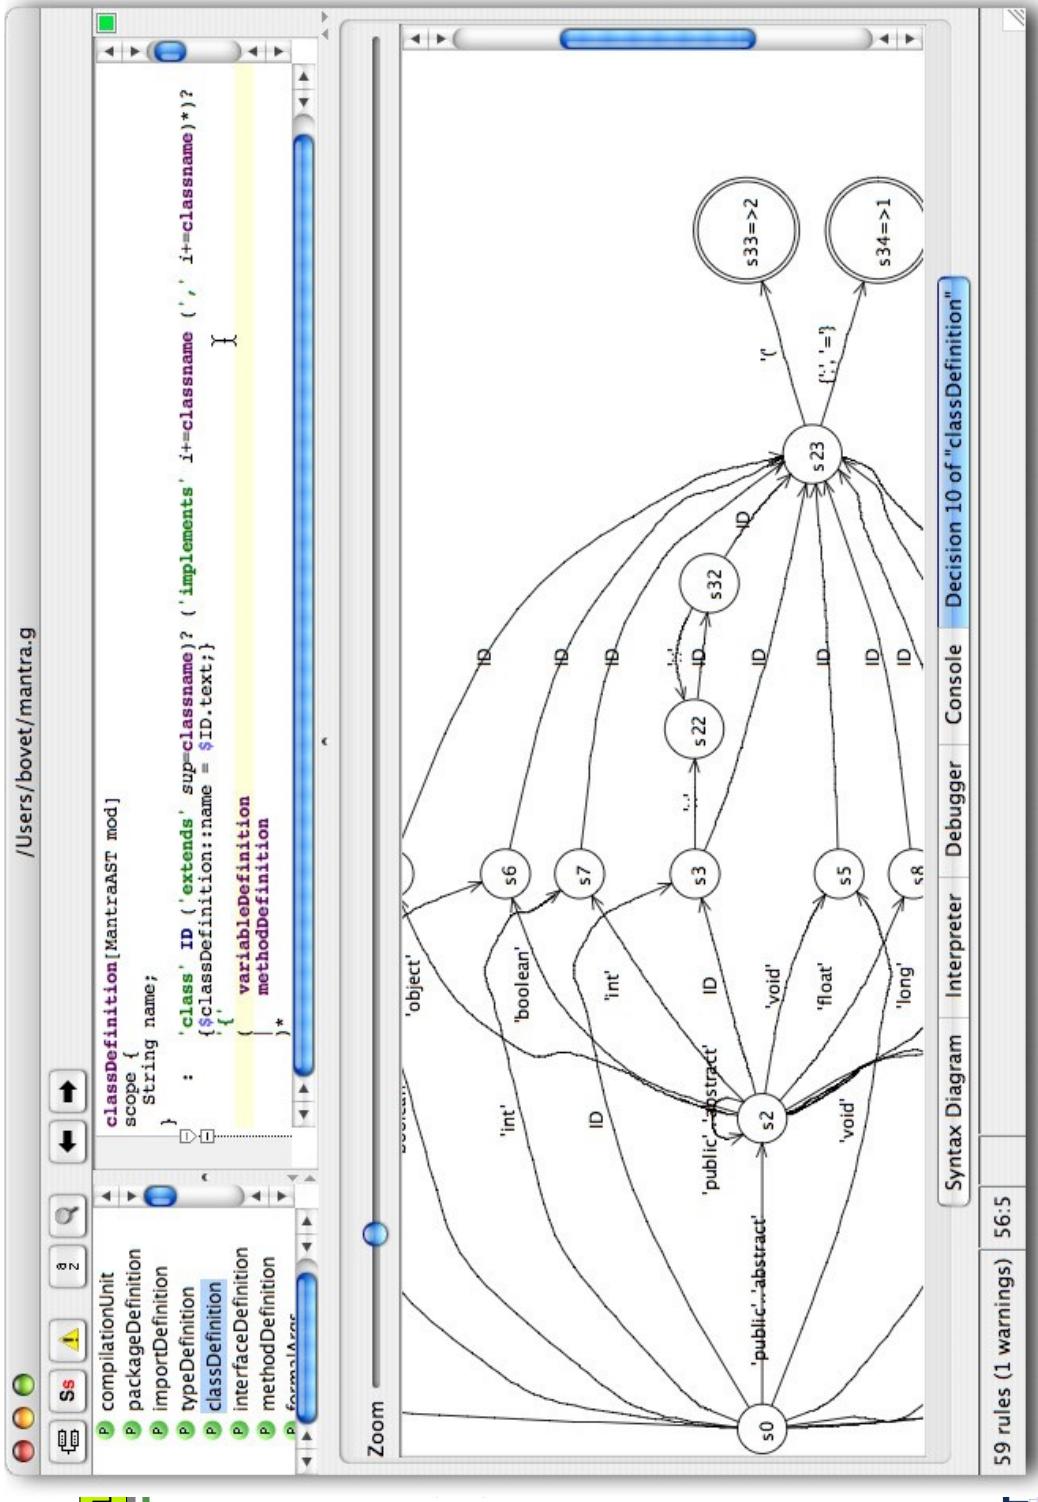
- ▶ Nutzt Parser-Generator ANTLR zur Generierung von Parsem
 - Parser und Metamodell werden aufeinander abgebildet (mapping), um konkrete auf abstrakte Syntax abzubilden
- ▶ Nutzt schablonengesteuerte Codegenerierung zur Erzeugung von Text und Programmen (siehe später).

Beispiel: ANTLR www.antlr.org

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







13.2 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();} ;
```

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 -= $e.value;}
  | '*' e=multExpr {$value *= $e.value;}
  | '/'
  ;
multExpr returns [int value]
: atom {$value = $atom.value;}
  | '+' atom {$value += $atom.value;}
  | '-' atom {$value -= $atom.value;}
  | '*' atom {$value *= $atom.value;}
  | '/' atom {$value /= $atom.value;}
  | '(' expr ')'
  ;
atom: INT;
INT: '0'..'9'+;
NEWLINE: '\r' '\n';
WS: [ \t ]*;

```

Syntax Diagram (Left): A parse tree diagram for the grammar Expr. The root node is prog, which contains multiple stat nodes. Each stat node contains an expr node. The expr nodes are further broken down into multExpr nodes, which then resolve to atom nodes. The atoms represent integer values (e.g., '1', '+2'). The diagram also shows the tokens INT, NEWLINE, WS, and the assignment operator '='.

Syntax Diagram (Right): A more detailed parse tree diagram for the same input. It shows the hierarchical structure of the expression and how it matches the grammar rules. The root is prog, which leads to stat+, which then leads to expr, and so on, down to the individual tokens and values.

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 -= $e.value;}
  | '*' e=multExpr {$value *= $e.value;}
  | '/'
  ;
multExpr returns [int value]
: atom {$value = $atom.value;}
  | '+' atom {$value += $atom.value;}
  | '-' atom {$value -= $atom.value;}
  | '*' atom {$value *= $atom.value;}
  | '/' atom {$value /= $atom.value;}
  | '(' expr ')'
  ;
atom: INT;
INT: '0'..'9'+;
NEWLINE: '\r' '\n';
WS: [ \t ]*;

```

Stack (Left): Shows the stack state during parsing. The stack starts with the root node prog. As the parser processes the input, it pushes and pops nodes from the stack to build the parse tree. The stack ends with the final value node.

Stack (Right): Another view of the stack during parsing. It shows the current rule being processed (multExpr) and the nodes it has generated (atom, value). The stack also includes the tokens INT and NEWLINE.

Break on Location (Left): A dialog box for setting a break point. It allows selecting a location (e.g., All, Location, Consume, LT, Exception) and specifying a rule or node to break on.

Break on Location (Right): Another instance of the break point dialog, showing a similar configuration.

18



The screenshot shows the Prot. U. ALGmannn tool interface. On the left, there is a toolbar with various icons for file operations. The main area displays a grammar file named 'Expr.g'. The grammar defines a 'prog' rule with a header section and a body section containing rules for 'stat', 'expr', 'atom', 'ID', 'INT', and 'WS'. The 'expr' rule includes logic for printing values and updating a global variable 'memory'. Below the grammar is a parse tree diagram for a specific input string. The parse tree shows the hierarchical structure of the expression, with nodes for 'expr', 'multExpr', 'atom', and numerical values. A blue circle highlights a node in the tree.

```

grammar Expr;
prog @header {
    package test;
    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];
     | NEWLINE;

expr returns [int value]
: e=multExpr {$value = $e.value;}
  ( '+' e=multExpr {$value += $e.value;}
  | '-' e=multExpr {$value -= $e.value;}
  | '*' );

```

Was haben wir gelernt?

- ▶ Parsergeneratoren gehören heute zum Werkzeugsatz jeden Softwareingenieurs
- ▶ Neben Cocktail gibt es freie Initiativen, z.B. ANTLR
- ▶ Leider erfasst der Parser nur die kontextfeie Struktur des Programms oder Dokuments; Kontextbedingungen und Integritätsbedingungen bleiben der *semantischen Analyse* vorbehalten.

The End

