

20. Parser-Generatoren im Technikraum

Grammarware

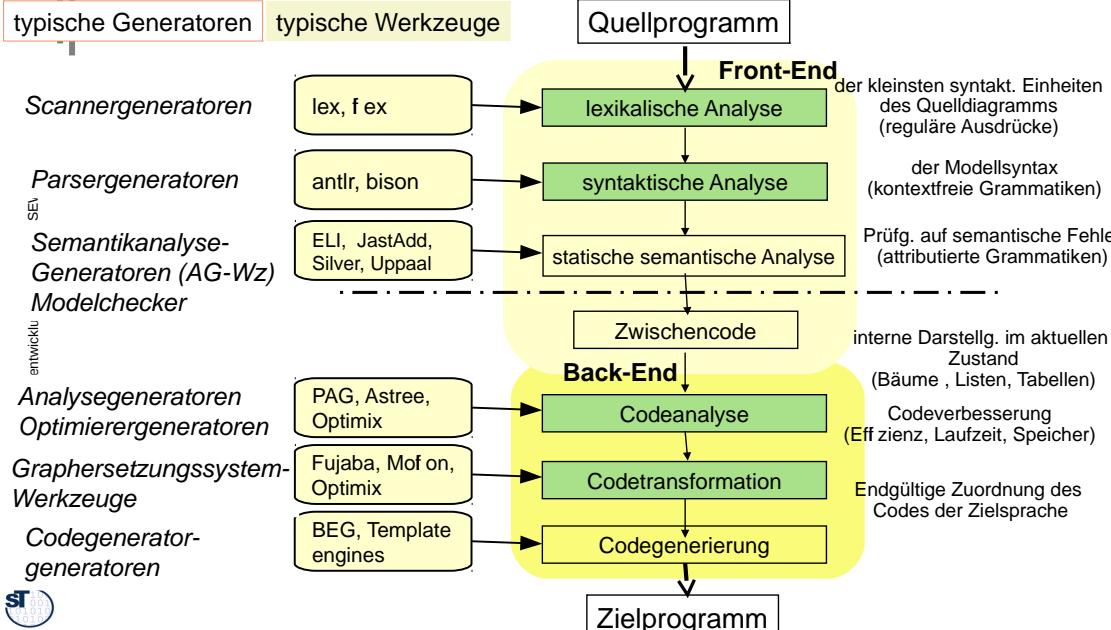
1

- 1) Grundlagen
- 2) Beispiel Taschenrechner

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 12-1.1, 15.11.12

Softwareentwicklungswerkzeuge (SEW) © Prof. Uwe Aßmann

Phasen eines Compilers und die erzeugenden Werkzeuge

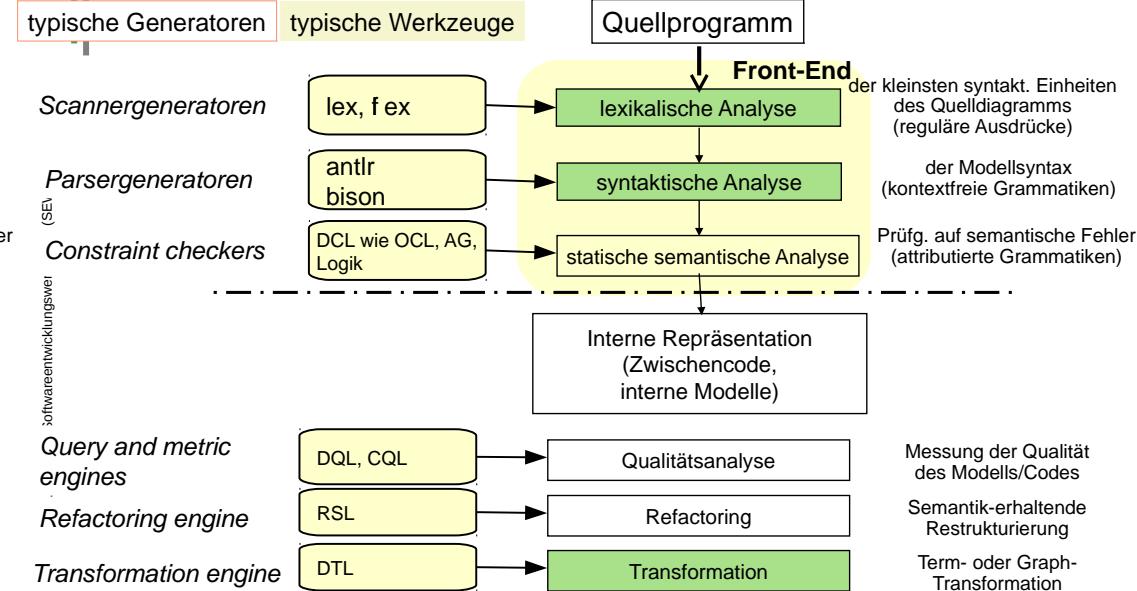


Literatur

- 2
- Obligatorisch:
- <http://www.antlr.org>
- Zusätzlich:
 - Cocktail www.cocolab.de, die Compiler-Toolbox für die schnellsten Compiler der Welt (kommerziell, Demoversionen erhältlich)

Prof. U. Aßmann, Softwareentwicklungswerkzeuge (SEW)

Phasen eines Importers in ein Repository und die erzeugenden Werkzeuge



Messung der Qualität des Modells/Codes
 Semantik-erhaltende Restrukturierung
 Term- oder Graph-Transformation

Problem

- ▶ 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?

Beispiel EMFText

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

Antwort

- ▶ 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: ANTLR www.antlr.org

- ▶ In den 90er Jahren gab es für C viele Parsergeneratoren
 - Cocktail's lalr, ell, lark www.cocolab.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

/Users/bovet/ Demo/objc.g

Statement

- parameter_declarator
- identifier_list
- initializer
- initializer_list
- type_name
- abstract_declarator
- direct_abstract_declarator
- typedef_name

Expression

Lexer

Syntax Diagram Interpreter Debugger Console

129 rules 452:23

/Users/bovet/Development/Research/depot/antlr/examples-v3/java/java.java.g

Parse Tree

Break on: All Location Consume LT Exception

Input

```
public class Sample {
    public void main() {
        System.out.println("Hello, world");
    }
}
```

Stack

#	Rule
0	compilationUnit
1	typeDeclaration
2	classOrInterfaceDeclaration
3	classDeclaration
4	normalClassDeclaration
5	classBody
6	classBodyDeclaration
7	modifier

Input Output Parse Tree AST Stack Events Syntax Diagram Interpreter Debugger Console

148 rules (2 warnings) 254:9 Warnings reported in console

/Users/bovet/ Grammars/java.g

field

```
public void main() {
    int a = 2+3;
}
```

Zoom

Syntax Diagram Interpreter Debugger Console

132 rules 528:1

/Users/bovet/ Grammars/java.g

Parse Tree

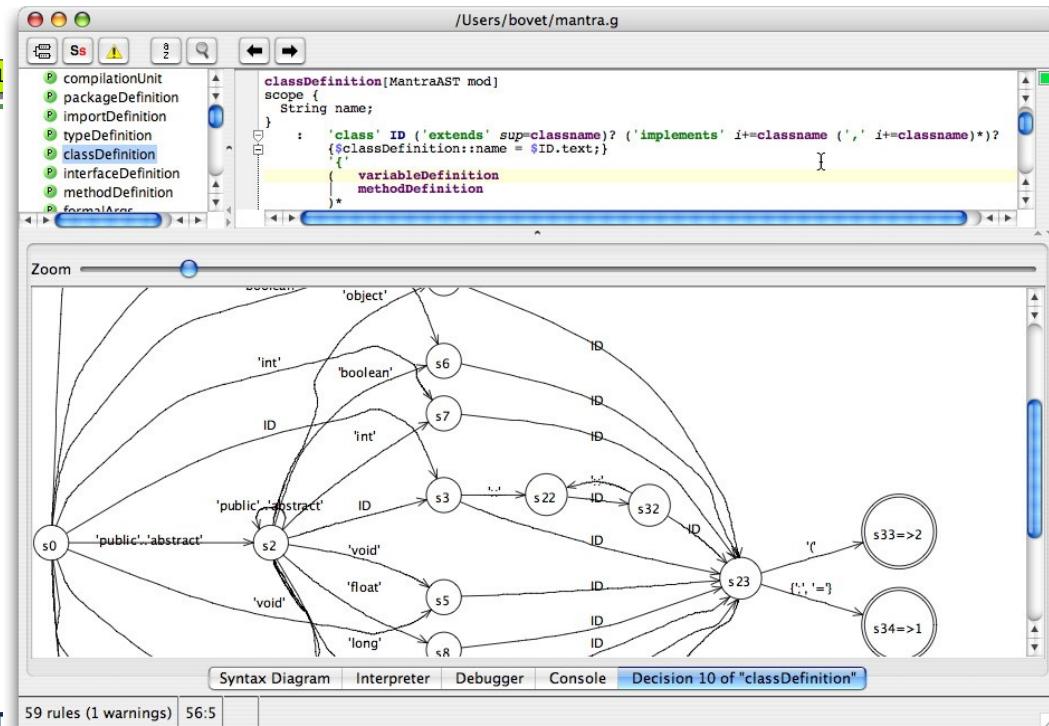
(1/2) Decision can match input such as "default" using multiple alternatives

Alternatives: 1 2

Zoom

Syntax Diagram Interpreter Debugger Console

132 rules (6 warnings) 433:1



15

```
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 ) $value = v.intValue();
        else System.err.println("undefined variable "+$ID.text);
    }
    | '(' e=expr ')' {$value = $e.value;}
    ;
ID : ('a'..'z'|'A'..'Z')+ ;
INT : '0'..'9'+ ;
NEWLINE:'\r'? '\n'+ ;
WS : (' '|\t')+ {skip();} ;
```

13.2 Ein Taschenrechner

14

Softwareentwicklungsprojekte (SEW) © Prof. Uwe Aßmann

Ansteuerung

16

```
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();
    }
}
```

17

```
/Users/bovet/ Grammars/Demo/Expr.g
```

```
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;}
|^;
```

The screenshot shows the SEW IDE interface with the Expr grammar loaded. The 'Interpreter' tab is selected, displaying a parse tree for the input '2 + 3 * 4'. The tree structure is as follows:

```

    <grammar Expr>
    |
    +-- prog
    |   |
    |   +-- stat
    |   |   |
    |   |   +-- expr
    |   |   |
    |   |   +-- multExpr
    |   |   |
    |   |   +-- atom
    |   |   |
    |   |   +-- 2
    |
    +-- expr
        |
        +-- multExpr
            |
            +-- atom
            |
            +-- +
            |
            +-- multExpr
                |
                +-- atom
                |
                +-- *
                |
                +-- atom
                    |
                    +-- 3
                    |
                    +-- atom
                        |
                        +-- 4

```

The 'Stack' panel shows the stack state: 0: prog, 1: stat, 2: expr, 3: multExpr, 4: atom.

19

```
/Users/bovet/ Grammars/Demo/Expr.g
```

```
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;}
|^;
```

The screenshot shows the SEW IDE interface with the Expr grammar loaded. The 'Parser Tree' tab is selected, displaying a parse tree for the input '2 + 3 * 4'. The tree structure is identical to the one in the previous screenshot. The 'Stack' panel shows the stack state: 0: prog, 1: stat, 2: expr, 3: multExpr, 4: atom.

18

```
/Users/bovet/ Grammars/Demo/Expr.g
```

```
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]
: e=atom {$value = $e.value;} (* e=atom {$value *= $e.value;})
| '+' e=multExpr {$value += $e.value;}
| '-' e=multExpr {$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);
| ;
| 'C' e=expr {$value = $e.value;};

ID : ('_''.''_')? [A..Z]+ ;
INT : '0'..'9'+ ;
NEWLINE : '\n' | '\r' | '\n'\r';
```

The screenshot shows the SEW IDE interface with the Expr grammar loaded. The 'Parser Tree' tab is selected, displaying a parse tree for the input '2 + 3 * 4'. The tree structure is identical to the ones in the previous screenshots. The 'Stack' panel shows the stack state: 0: prog, 1: stat, 2: expr, 3: multExpr, 4: atom.

20

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 *statischen semantischen Analyse* vorbehalten.

The End

