

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



Literatur

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

Phasen eines Compilers

typische Werkzeuge

Quelldiagramm

Scanner **lex, flex**

lexikalische Analyse

der kleinsten syntakt. Einheiten
des Quelldiagramms
(reguläre Ausdrücke)

Front-End Parser **antlr, yacc, bison**

syntaktische Analyse

der Modellsyntax
(kontextfreie Grammatiken)

AG-Werkzeug

**ELI, MAX, MUG, JastAdd,
Silver**

semantische Analyse

Prüfg. auf semantische Fehler
(attributierte Grammatiken)

Back-End

(Codegenerator) *Optimierergener.*

(Ziel-
sprachen-
abhängig)

**PAG, Optimix,
grgen**

Codegeneratorgener.
BEG, cggg

Zwischencode

interne Darstellg. im aktuellen Zustand
(Bäume, Listen, Tabellen)

Codeoptimierung

Codeverbesserung
(Effizienz, Laufzeit, Speicher)

Codegenerierung

Endgültige Zuordnung des
Codes der Zielsprache

Zielprogramm



Problem

Wie arbeite ich flexibel mit mehreren Programmiersprachen oder DSL?

Antwort

- ▶ Technikraum "Grammarware"

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

Beispiel EMFText

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

- ▶ 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



- parameter_declaration
- identifier_list
- initializer
- initializer_list
- type_name
- abstract_declarator
- direct_abstract_declarator
- typedef_name
- ▼ Statement
 - statement
 - labeled_statement
 - expression_statement
 - compound_statement
 - statement_list
 - selection_statement
 - iteration_statement
 - jump_statement
- Expression
- Lexer

```

compound_statement
: RCURLY declaration_list? statement_list? LCURLY
;

statement_list
: statement+
;

selection_statement
: 'if' LPAREN expression RPAREN statement ('else' statement)?
'switch' LPAREN expression RPAREN statement
;

iteration_statement
: 'while' LPAREN expression RPAREN statement
'do' statement
'for' LPAREN expression SEMI expression SEMI statement
;

jump_statement
: 'goto' identifier SEMI statement
'continue' SEMI statement
'break' SEMI statement
'return' expression SEMI statement
;

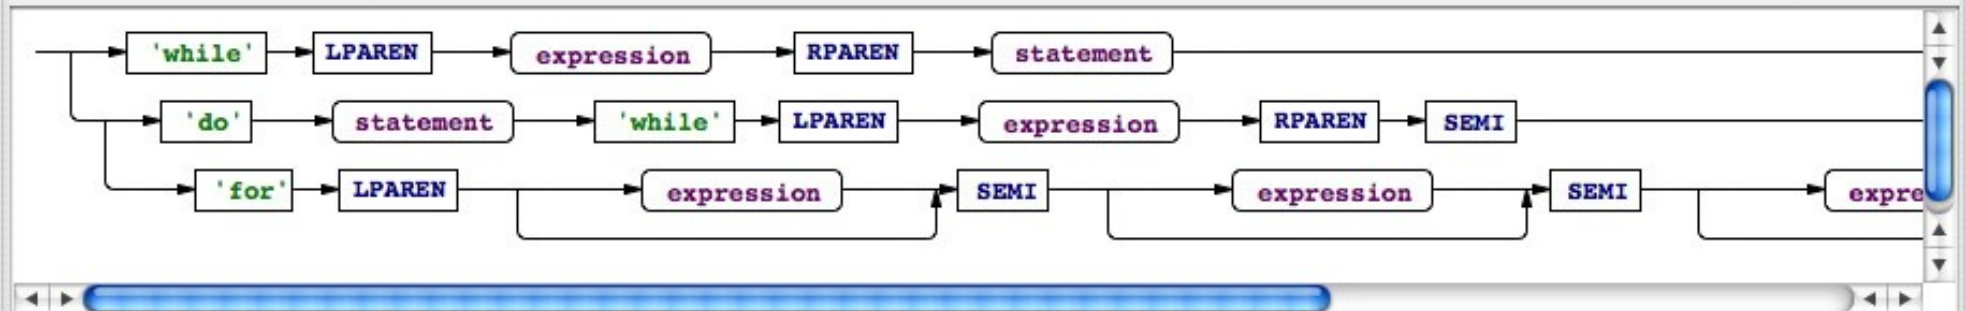
```

Enter rule name:

st

- struct_or_union_specifier
- storage_class_specifier
- struct_or_union
- struct_declaration_list
- struct_declaration
- struct_declarator_list
- struct_declarator
- statement
- statement_list
- string

Zoom Show NFA



Syntax Diagram Interpreter Debugger Console



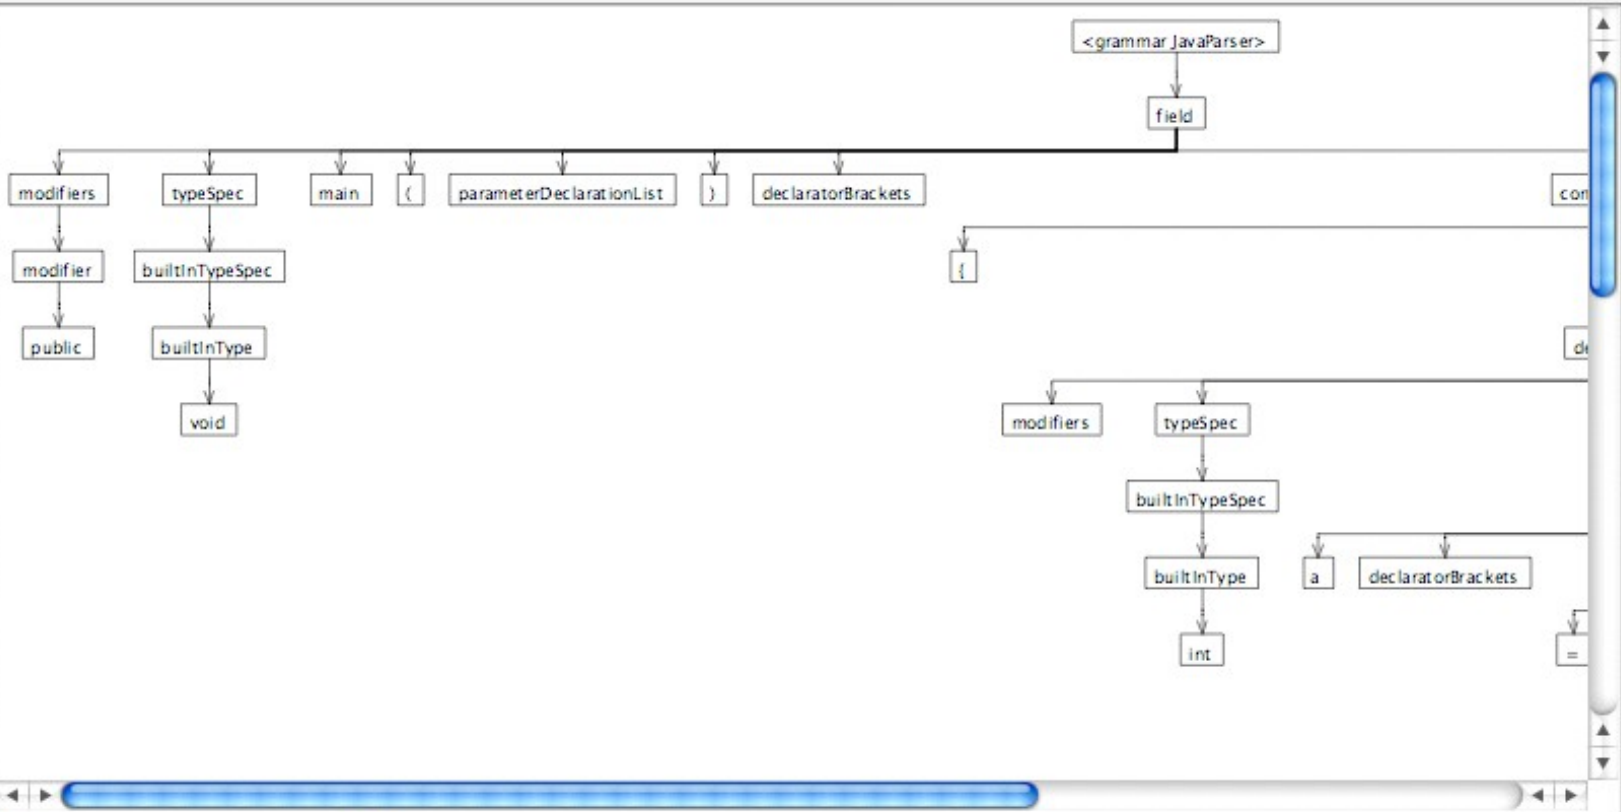


- handler
- expression
- expressionList
- assignmentExpression
- conditionalExpression

```
// the mother of all expressions  
expression  
: assignmentExpression  
;
```

field

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



Zoom

Syntax Diagram Interpreter Debugger Console

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

- interfaceBodyDeclaration
- interfaceMemberDecl
- interfaceMethodOrFieldDecl
- interfaceMethodOrFieldRest
- methodDeclaratorRest
- voidMethodDeclaratorRest
- interfaceMethodDeclaratorRest
- interfaceGenericMethodDecl
- voidInterfaceMethodDeclaratorRest
- constructorDeclaratorRest
- constantDeclarator
- variableDeclarators
- variableDeclarator
- variableDeclaratorRest
- constantDeclaratorsRest
- constantDeclaratorRest
- variableDeclaratorId
- variableInitializer
- arrayInitializer
- modifier

```

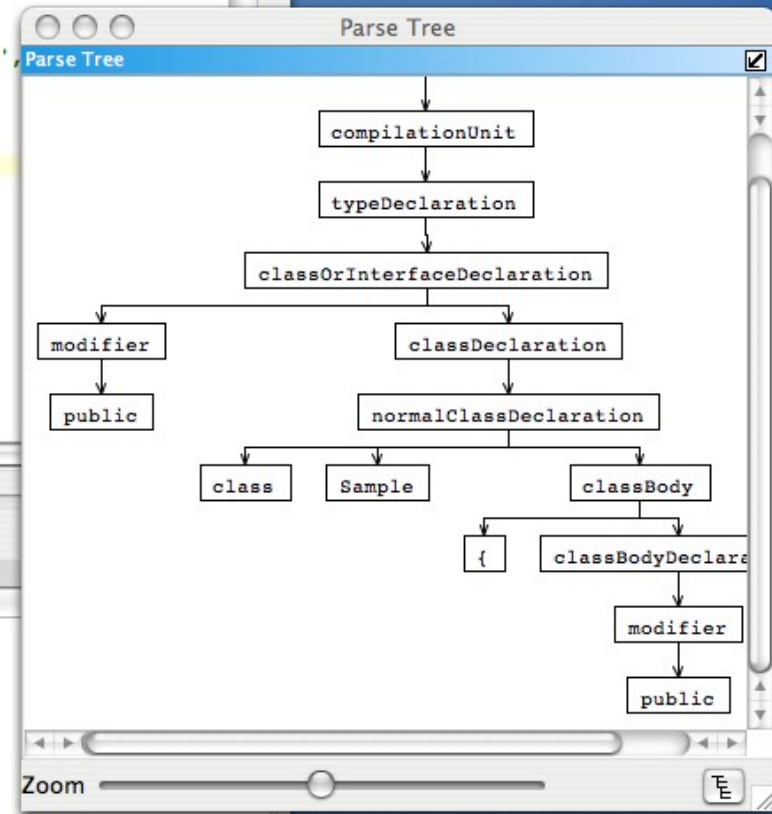
variableDeclaratorId
    : Identifier ('[' ']')*
    ;

variableInitializer
    : arrayInitializer
    | expression
    ;

arrayInitializer
    : '{' (variableInitializer ',' variableInitializer)* ','
    ;

modifier
    : annotation
    | 'public'
    | 'protected'
    | 'private'
    | 'static'
    | 'abstract'
    | 'final'
    | 'native'
    | 'synchronized'
    | 'transient'
    | 'volatile'
    | 'strictfp'
    ;

```



Break on: All Location Consume LT Exception

Input

```

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

```

#	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

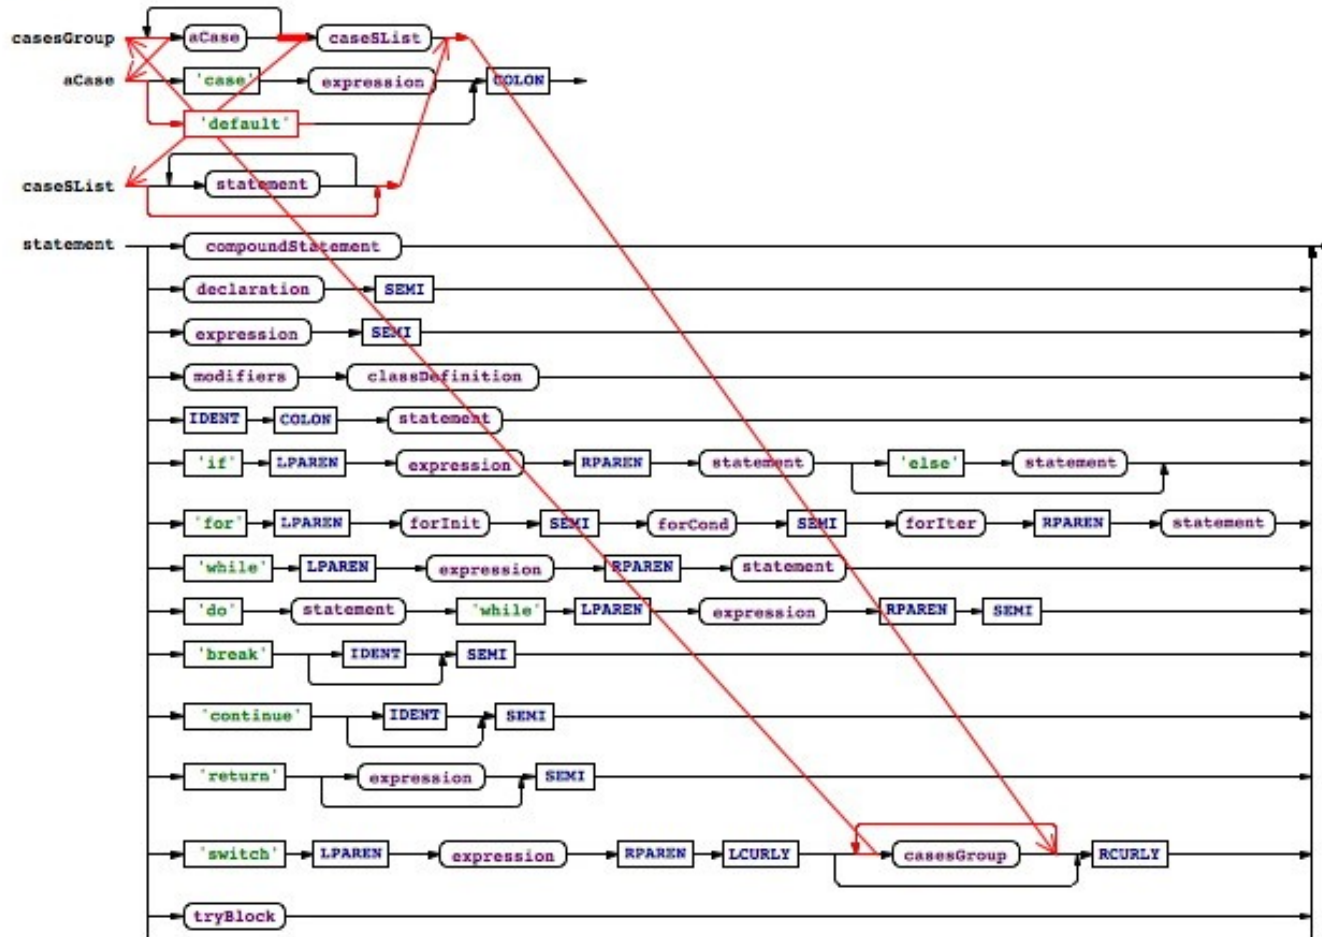




Zoom Show NFA

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

Alternatives: 1 2

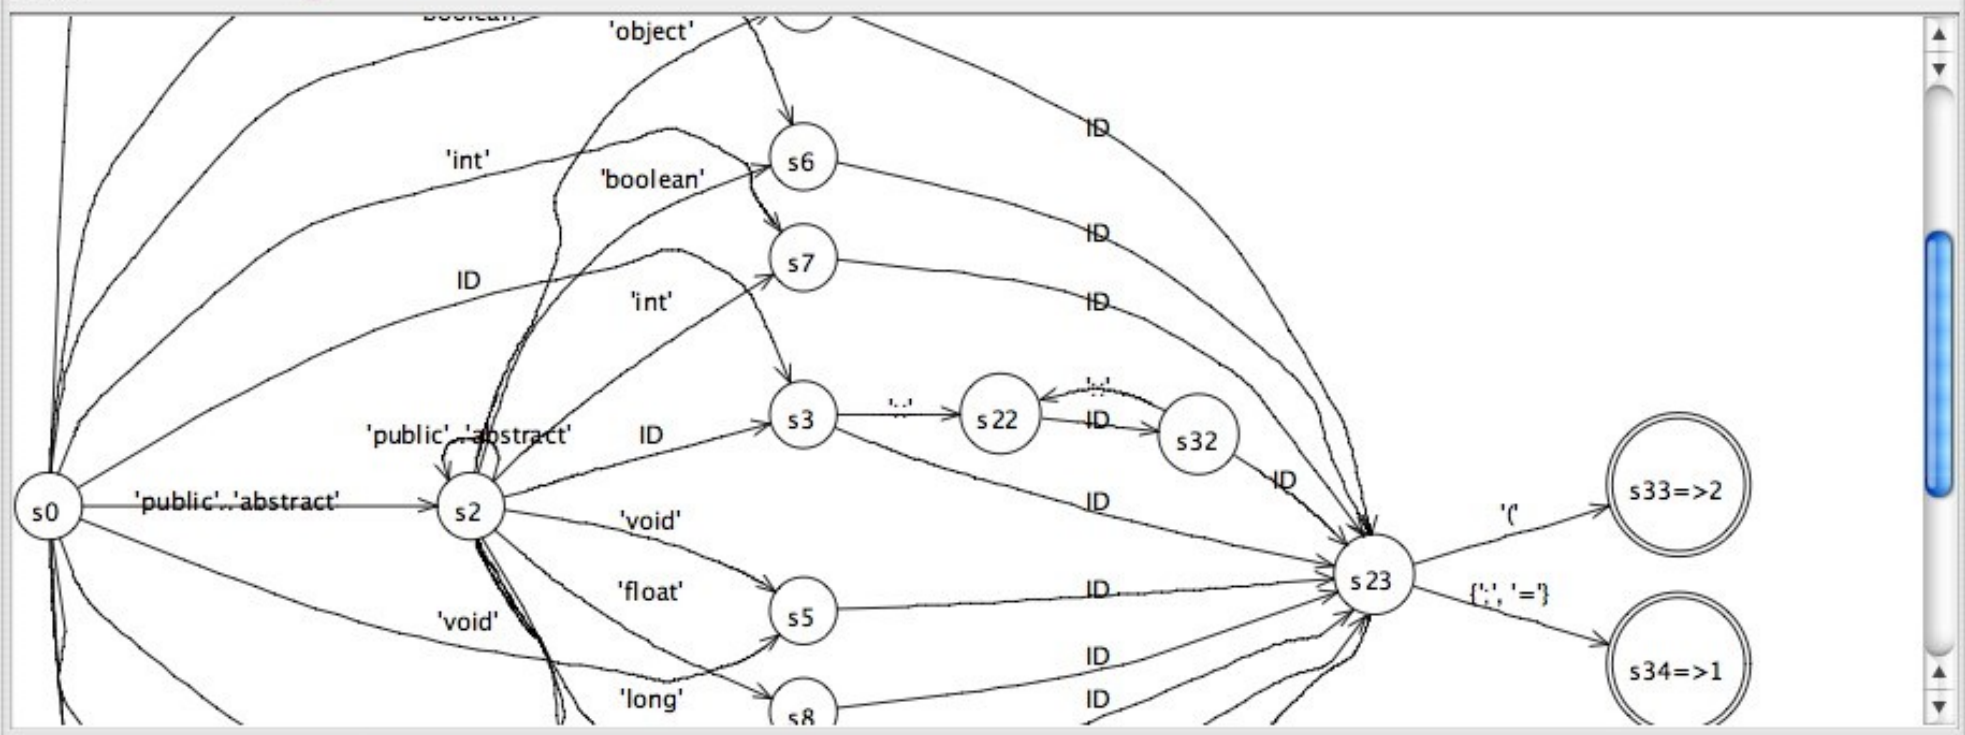



Syntax Diagram Interpreter Debugger Console



- P compilationUnit
- P packageDefinition
- P importDefinition
- P typeDefinition
- P classDefinition
- P interfaceDefinition
- P methodDefinition
- P formalArgs

```
classDefinition[MantraAST mod]
scope {
  String name;
}
: 'class' ID ('extends' sup=classname)? ('implements' i+=classname (',' i+=classname)*)?
  {$classDefinition::name = $ID.text;}
  {
    variableDefinition
    methodDefinition
  }*
```



Syntax Diagram Interpreter Debugger Console **Decision 10 of "classDefinition"**

59 rules (1 warnings) 56:5



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 ) $value = v.intValue();
    else System.err.println("undefined variable "+$ID.text);
    }
  | '(' e=expr ')' {$value = $e.value;}
  ;

ID : ('a'..'z'|'A'..'Z')+ ;
INT : '0'..'9'+ ;
NEWLINE: '\r'? '\n' ;
WS : (' |\t')+ {skip();} ;

```

```
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();
    }
}
```

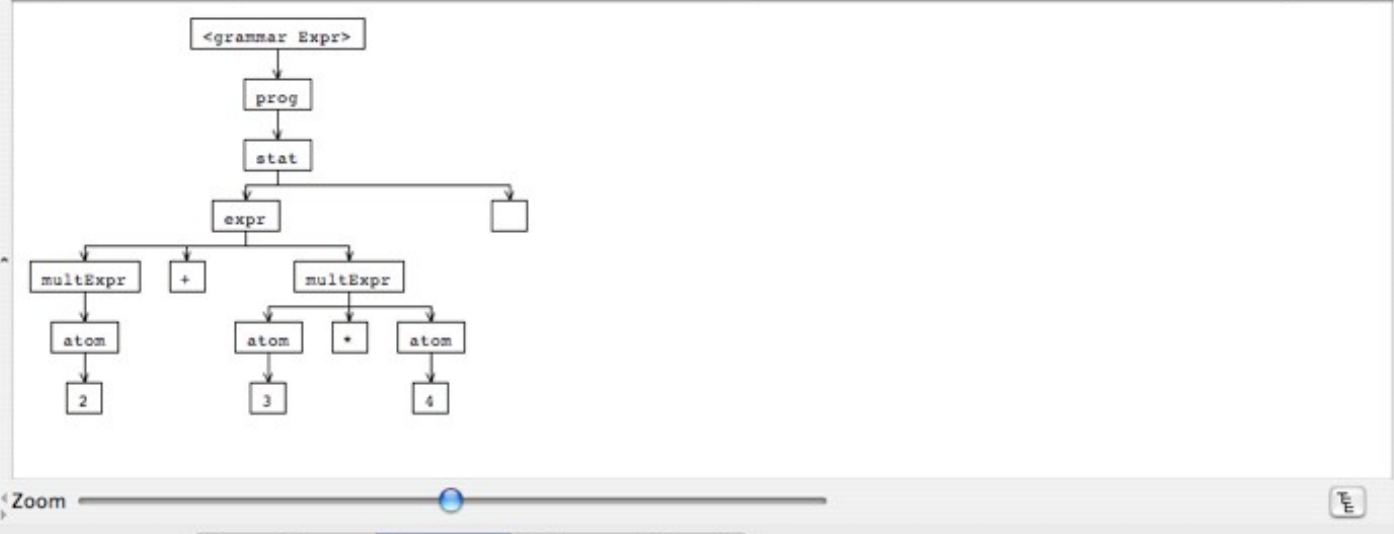



- prog
- stat
- expr
- multExpr
- atom
- ID
- INT
- NEWLINE
- WS

```
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;}  
}*
```

prog Line Endings: Unix (LF) Ignore rules: WS Guess

2+3*4



Zoom

Syntax Diagram Interpreter Debugger Console



```

/Users/bovet/ Grammars/Demo/Expr.g
[Icons] [S] [Warning] [Z] [Search] [Back] [Forward]
prog
stat
expr
multExpr
atom
ID
INT
NEWLINE
WS

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 : '\s+' ;

```

Break on: All Location Consume LT Exception

Input: 2

Parse Tree

```

graph TD
    root --> prog
    prog --> stat
    stat --> expr
    expr --> multExpr
    multExpr --> atom
    atom --> 2

```

Stack

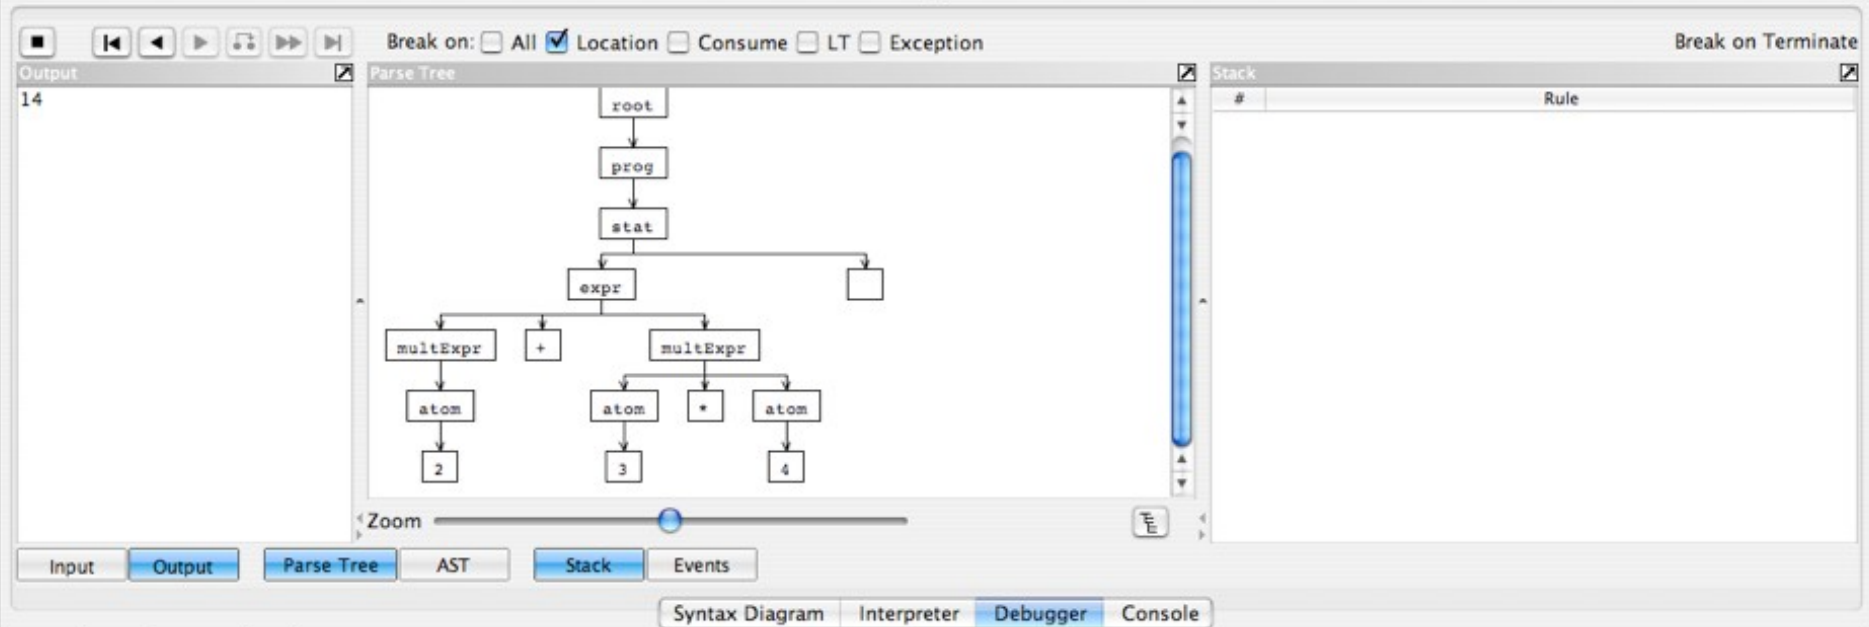
#	Rule
0	prog
1	stat
2	expr
3	multExpr
4	atom

Zoom: [Slider]

Input Output Parse Tree AST Stack Events

Syntax Diagram Interpreter Debugger Console

```
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;}
)*
```





Was haben wir gelernt?

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



The End