



Stuttgart

Organisatorisches

- Ablauf der Vorlesung gliedert sich in 3 Teile:
 - 1 Vorlesung
 - 2 Übungsblatt (in 2er Gruppen bearbeiten)
 - 3 Vorstellen/Besprechung der Ergebnisse

- Bearbeiten der Aufgaben mit eigenem Laptop
 - Jede Zweiergruppe sollte mindestens einen Rechner besitzen

Literatur

- Offizielle ANTLR-Website unter: <https://www.antlr.org/>
- *The Definitive ANTLR 4 Reference* von Terence Parr, ISBN: 978-1-93435-699-9
- Readme auf Github:
<https://github.com/antlr/antlr4/blob/master/doc/index.md>

Entwicklungsumgebung

ANTLR-Jar Datei

`https://www.antlr.org/download/antlr-4.12.0-complete.jar` lässt sich zusammen mit jeder Entwicklungsumgebung auf jedem gängigen Betriebssystem nutzen.

Plugin ANTLR lässt sich per Plugin in gängige Java IDEs integrieren:

Intellij `http://plugins.jetbrains.com/plugin/7358?pr=idea`

Eclipse `https://github.com/jknack/antlr4ide`

Parser Generator

Vorzüge von ANTLR

- Trennung von Grammatik und Verarbeitungslogik
 - Programm verarbeitet den geparsten Syntaxbaum. Kein Java-Source Code innerhalb der Grammatik
 - Bessere Integration des SourceCodes in die IDE
 - Leichter anpassbar/erweiterbar
 - Arbeiten mit bekannter Java Syntax
- Gutes Tooling: Plugins für gängige Java IDEs, wie Eclipse und IntelliJ IDEA
 - Syntax Highlighting
 - Gute Fehlerausgabe

G4-Grammatik: Syntax

- Comments sind gleich wie in Java (`/**` `/**`)
- Tokens/Terminale beginnen mit Großbuchstaben, Non-Terminale mit Kleinbuchstaben
- Literale in Single-Quotes (`'literal'`)
- Regeln bestehen aus Namen für Token, Literale und den Zeichen (`|` `.` `*` `+` `?`)
 - `|` entspricht *Oder*
 - `.` `*` `+` `?` verhalten sich wie bei Regulären Ausdrücken
 - `~[A]` entspricht allen 16-bit wertigen Zeichen außer *A*

Syntax Veranschaulichung

```
//Datei GrammatikBeispiel.g4
//Name der Grammatik (gleich wie Dateiname):
grammar GrammatikBeispiel;
regel1 : Token1 Token2;
Token1 : 'Hallo';
Token2 : [a-z]+;
/*
Grammatik parst Texte der Form:

Hallo nameinkleinbuchstaben
*/
Linefeed: '\r'? '\n';
WS : [ \t]+ -> skip; //Leerzeichen ignorieren
```


G4-Grammatik Beispiel

```
grammar Beispiel2;  
s : s '(' s ')' s  
  | TEXT?;  
TEXT : ~[()]+;
```

- (Gibt es ein äquivalent zu dieser Grammatik als regulären Ausdruck?)

Hinweise

- Keine separate Datei für Lexeme notwendig. Alle Regeln und Lexeme werden in der G4-Grammatik beschrieben.
- Der Lexer nimmt immer das erste in der Grammatik auftauchende Lexem. Allgemeinere Terminale also ans Ende der Grammatik verlegen.

//Warum kann diese Grammatik "int 1" nicht parsen?

```
grammar Number;  
number : integer | float;  
integer : 'int_' Integer;  
float : 'float_' Float;
```


```
Float : [0-9\.]
```

```
Integer : [0-9]
```

- Bei nicht eindeutigen Regeln wird die zuerst spezifizierte Regel bevorzugt
- ANTLR versucht immer das längste Lexem auszuwählen

Falsch:


`expr : expr '+' expr | expr '*' expr | Number;`



Baum beim Parsen von $1 * 2 + 2 * 3$

Korrekt:

`expr : expr '*' expr | expr '+' expr | Number;`



Baum beim Parsen von $1 * 2 + 2 * 3$

Übungsblock 1

Übungsblatt 1: Aufgabe 1 und 2

- Link zum Übungsblatt: <http://www2.ba-horb.de/~stan/%C3%BCbung1.pdf>
- IntelliJ-Download: <https://www.jetbrains.com/idea/download>
- Download der ANTLR-Java-Library
<https://www.antlr.org/download/antlr-4.12.0-complete.jar>

Tip: Installation des ANTLR Plugins in IntelliJ

- File → Settings → Suche nach *Antlr v4 Grammar Plugin*
Oder: Download ANTLR-Plugin: <https://plugins.jetbrains.com/plugin/download?pr=idea&updateId=26416>

ANTLR-Library dem Projekt hinzufügen

- antlr-complete.jar ins Projektverzeichnis kopieren
- File → Project Structure → Libraries
- anschließend '+' → Java → antlr-complete.jar auswählen

Beispielimplementierung für Aufgabe 3.b

Grammatik für Expressions (Fehlerhaft)

```
grammar IntExpression;  
s : expr;
```

```
expr : expr ADD expr | expr MUL expr  
      | expr SUB expr | '(' expr ')'  
      | Number;
```

```
MUL : '*' ;  
ADD : '+' ;  
SUB : '-' ;
```

```
Number : [0-9]+;  
WS : [ \t\r\n] -> skip;
```

Methode zum Einlesen und Parsen eines Strings aus System.in

```
public static void main(String[] args) throws Exception {
    CharStream input = CharStreams.fromString("100+2*3");
    IntExpressionLexer lexer = new IntExpressionLexer(input);
    CommonTokenStream tokens = new CommonTokenStream(lexer);
    IntExpressionParser parser = new IntExpressionParser(tokens);
    IntExpressionParser.StartContext tree = parser.start(); //Parsen

    ExpressionCalculator calc = new ExpressionCalculator();
    int ergebnis = calc.calculate(tree.expr()); // initiate walk of tree with listener
    System.out.println(ergebnis);
}
```

ExprAdapter:

```
class ExpressionCalculator{
    int calculate(IntExpressionParser.ExprContext ctx){
        if(ctx.MUL()!=null){
            return this.calculate(ctx.expr(0)) * this.calculate(ctx.expr(1));
        }else
        if(ctx.ADD()!=null){
            return this.calculate(ctx.expr(0)) + this.calculate(ctx.expr(1));
        }else
        if(ctx.Number()!=null){
            return Integer.parseInt(ctx.Number().toString());
        }
        return 0;
    }
}
```


Einlesen von Texten

- **CharStreams** Doku: <http://www.antlr.org/api/Java/org/antlr/v4/runtime/CharStreams.html>
- Factory zur Generierung von CharStream's
- Kann String, InputStream, File und viele weitere Eingabeformate in das von ANTLR benutzte CharStream konvertieren

//Beispiel:

```
CharStream input = CharStreams.fromFileName("/pfad/zu/Datei");
```

Übungsblock 2

Übungsblatt 1: Aufgabe 3

Aufbau des ParseTrees

- ANTLR generiert zu jeder Regel in der Grammatik eine eigene Klasse
- Der Aufbau der Klasse wird direkt von dieser Regel abgeleitet
- Der ParseTree baut sich aus diesen Klasse auf

Beispiel 1:

```
regel : unterRegel1 | unterRegel2
```

wird durch die Klasse `RegelContext` repräsentiert, welche folgende Methoden enthält:

```
UnterRegel1Context unterRegel1();  
UnterRegel2Context unterRegel2();
```

Aufbau des ParseTrees

Beispiel 2:

`regel : unterRegel+`

wird durch die Klasse `RegelContext` repräsentiert, welche folgende Methoden enthält:

```
List<UnterRegelContext> unterRegel();
```

Decaf Programmiersprache

- Simple Programmiersprache
- Java-like Syntax
- aber keine Klassen und Vererbung

Beispiel:

```
def int add(int x, int y)
{
    return x + y;
}
```

```
def int main()
{
    int a;
    a = 3;
    return add(a, 2);
}
```

Decaf: Syntax (1)

Program \rightarrow (*Var* | *Method*)*

Var \rightarrow *Type* ID ';'

Method \rightarrow 'def' *Type* ID '(' *Params?* ') ' *Block*

Type \rightarrow 'int' | 'bool' | 'void'

Block \rightarrow '{' *Var** *Stmt** '}'

Stmt \rightarrow *Loc* '=' *Expr* ';'

| *MethodCall* ';'

| 'if' '(' *Expr* ')' *Block* ('else' *Block*)?

| 'while' '(' *Expr* ')' *Block*

| 'return' *Expr?* ';'

Decaf: Syntax (2)

$$\begin{aligned} \text{Expr} &\rightarrow \text{Expr Operator Expr} \\ &| \text{'(' Expr ')'} \\ &| \text{Loc} \\ &| \text{MethodCall} \\ &| \text{Constant} \end{aligned}$$
$$\text{Loc} \rightarrow \text{ID}$$
$$\text{MethodCall} \rightarrow \text{ID ' (' Args? ') '}$$
$$\text{Args} \rightarrow \text{Expr (',' Expr)*}$$
$$\text{Constant} \rightarrow \text{NUMBER} \mid \text{'true'} \mid \text{'false'}$$
$$\text{Operator} \rightarrow \text{'+'} \mid \text{'-'} \mid \text{'*'}$$

Decaf: Abstrakte Syntax (1)

Program	(enthält Variablen und Funktionen)
Variable	
Function	(enthält einen Block)
Block	(enthält Variablen und Statements)
Statement	
Assignment	(Location = Expression)
VoidFunctionCall	(wrapper für FunctionCall)
IfElse	(eine Expression und zwei Blöcke)
WhileLoop	(enthält Expression und Block)
Return	(enthält Expression)
VoidReturn	(return ohne Expression)

Decaf: Abstrakte Syntax (2)

Expression

BinaryExpr

(enthält zwei Expressions)

Location

(Variablenzugriff)

FunctionCall

(enthält mehrere Expressions)

Literal

StringLiteral

IntLiteral

BoolLiteral

AST Implementierung (1)

- Implementierung als record Typen
 - Immutable (unveränderliche) Datenstruktur
 - Erstellt get und set Methoden automatisch

```
record Program(List<Variable> variablen, List<Function> funktionen) {}  
record Variable(String name, Type type) {}  
record Function(Type type, String name, List<Variable> params, Block block)
```

```
interface Expression {}  
record BinaryExpr(Expression left, Operator op, Expression right) implements Expression {}  
enum Operator { ADD, SUB, MUL }  
record Location(String varName) implements Expression {}  
record FunctionCall(String varName, List<Expression> params) implements Expression {}  
record StringLiteral(String value) implements Expression {}  
record IntLiteral(Integer value) implements Expression {}  
record BoolLiteral(Boolean value) implements Expression {}
```

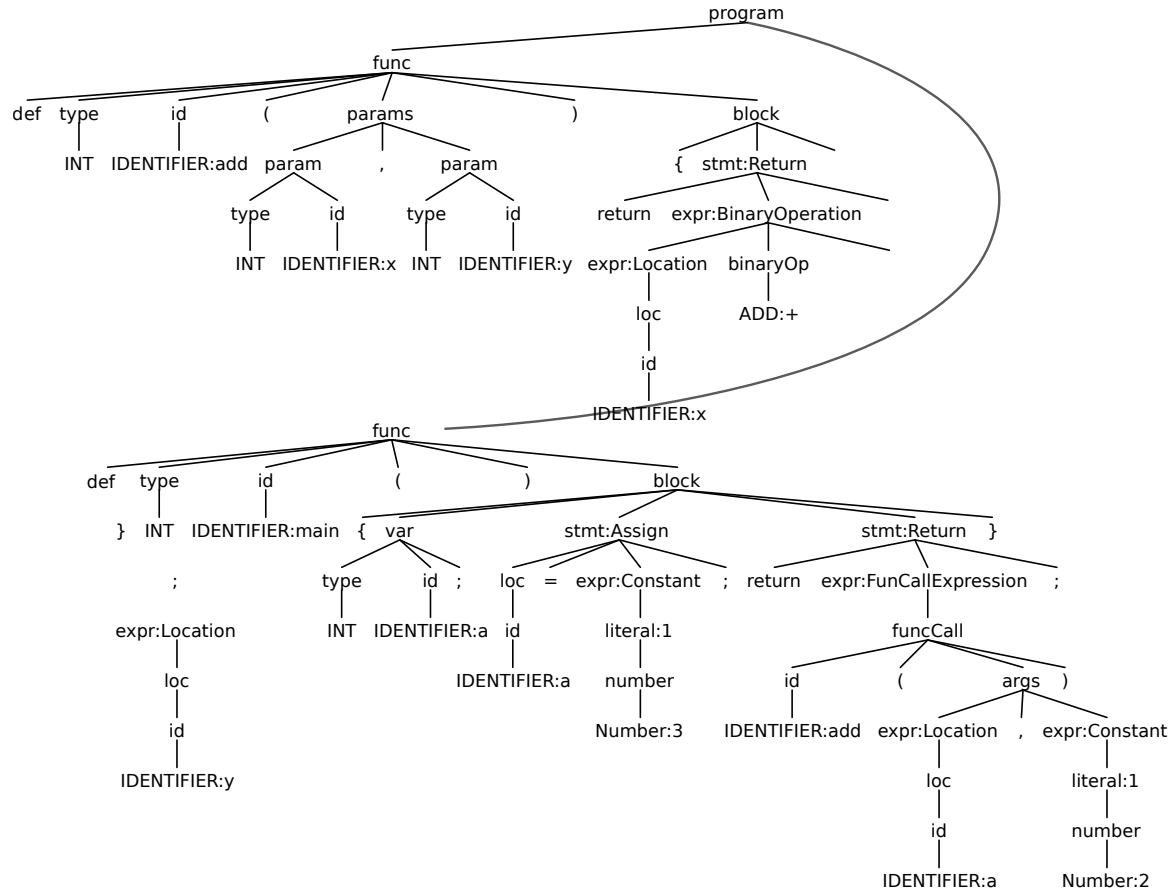
AST Implementierung (2)

■ Statements:

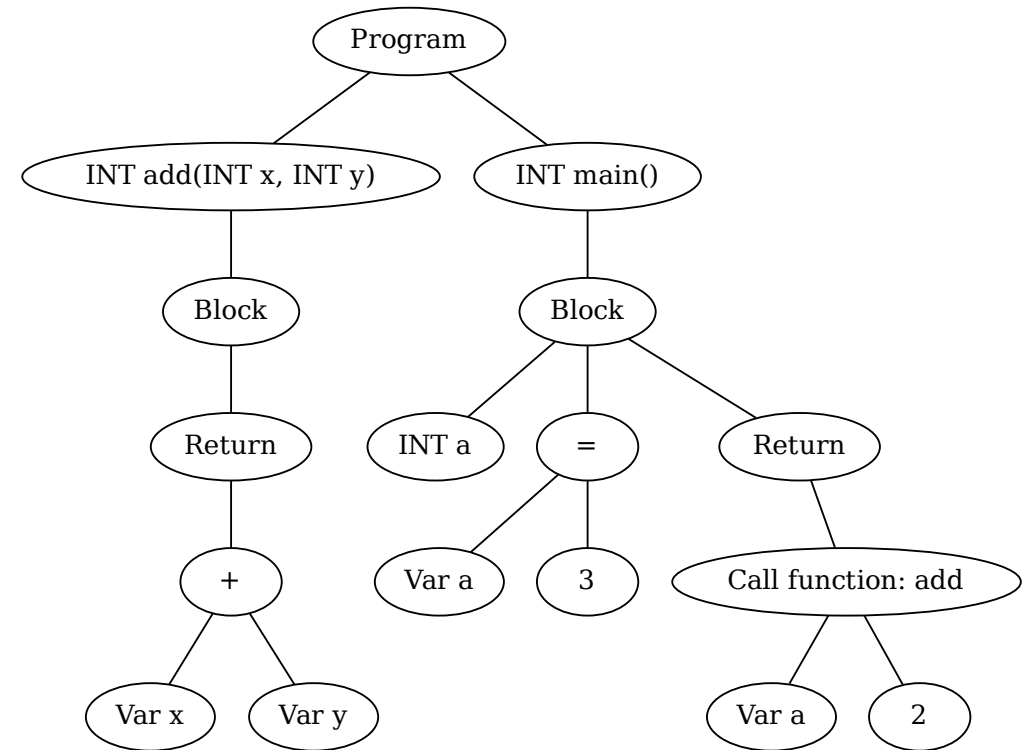
```
interface Statement {}
record Assignment(Location loc, Expression value) implements Statement {}
record VoidFunctionCall(FunctionCall expr) implements Statement {}
record ReturnVoid() implements Statement {}
record Return(Expression expr) implements Statement {}
record IfElse(Expression cond, Block ifBlock, Block elseBlock) implements Statement{}
record While(Expression cond, Block block) implements Statement {}
```

Umwandlung: ParseTree → AST

Parse Tree



Abstract Syntax Tree



ASTVisitor

- ANTLR erzeugt eine Visitor und eine BaseVisitor Klasse.
- Beispiel:

```
grammar Beispiel;  
  
regel : unterRegel1 | unterRegel2;  
unterRegel1 : "Hallo";  
unterRegel2 : "Besucher";
```

generiert die BeispielBaseVisitor Klasse:

```
interface TestVisitor<T> {  
    <T> visitRegel(RegelContext ctx);  
    <T> visitUnterRegel1(UnterRegel1Context ctx);  
    <T> visitUnterRegel2(UnterRegel2Context ctx);  
}
```

ASTVisitor

Problem: StmtContext im ParseTree kann verschiedene Statements darstellen.

Kann beispielsweise durch Typcasts gelöst werden:

```
//Methode soll aus dem ParseTree Element Statement ein AST Element generieren:
Statement generate(StatementContext ctx){
    if(ctx instanceof WhileContext){
        WhileContext wCtx = (WhileContext) ctx;
        return ... //Generate While
    }
    if(ctx instanceof ReturnContext){
        ...
    }
}
```

ASTVisitor

Problem: StmtContext im ParseTree kann verschiedene Statements darstellen.

Lösung: Mithilfe der BaseVisitor Klasse geht es auch ohne Casts:

```
class StatementGenerator extends DecafBaseVisitor<Statement> {
    Statement visitWhile(WhileContext ctx){
        ...
    }
    Statement visitReturn(ReturnContext ctx){
        ...
    }
}
```

ASTVisitor - Grammatik Labels

```
stmt : loc '=' expr ';'           #Assign
      | funcCall ';'             #FunctionCall
      | 'if' '(' expr ')' block ('else' block)? #If
      | 'while' '(' expr ')' block #While
      | 'return' expr ';'        #Return
      | 'return' ';'            #ReturnVoid
      | 'break' ';'             #Break
      | 'continue' ';'         #Continue
      ;
```

- Zusätzliche Strukturierung durch #Labels
- ANTLR generiert einen zusätzlichen Visitor für jedes Label

Übungsblock 3

Übungsblatt 2: Aufgabe 1 und 2

- Link zum Übungsblatt: <http://www2.ba-horb.de/~stan/%C3%BCbung2.pdf>
- Link zum Maven-Download: <https://maven.apache.org/download.cgi>