

Compilerbau

Martin Plümicke

WS 2021/22

Agenda

Überblick Vorlesung
Literatur

Compiler Überblick

Compiler (I)
Scanner
Parser

Literatur

 Bauer and Höllerer.
Übersetzung objektorientierter Programmiersprachen.
Springer-Verlag, 1998, (in german).

 Alfred V. Aho, Ravi Lam, Monica S.and Sethi, and Jeffrey D. Ullman.
Compiler: Prinzipien, Techniken und Werkzeuge.
Pearson Studium Informatik. Pearson Education Deutschland, 2.
edition, 2008.
(in german).

 Alfred V. Aho, Ravi Sethi, and Jeffrey D. Ullman.
Compilers Principles, Techniques and Tools.
Addison Wesley, 1986.

 Reinhard Wilhelm and Dieter Maurer.
Übersetzerbau.
Springer-Verlag, 2. edition, 1992.
(in german).

Literatur II



James Gosling, Bill Joy, Guy Steele, Gilad Bracha, and Alex Buckley.
The Java[®] Language Specification.

The Java series. Addison-Wesley, Java SE 8 edition, 2014.



Tim Lindholm, Frank Yellin, Gilad Bracha, and Alex Buckley.
The Java[®] Virtual Machine Specification.

The Java series. Addison-Wesley, Java SE 8 edition, 2014.



Bryan O'Sullivan, Donald Bruce Stewart, and John Goerzen.
Real World Haskell.


O'Reilly, 2009.




Peter Thiemann.
Grundlagen der funktionalen Programmierung.

Teubner, 1994.


Compiler Überblick




Compiler Überblick




Compiler Überblick




Compiler Überblick




Compiler Überblick



Compiler Überblick



Parser



Programmiersprachen

Programmiersprachen werden als formale Sprachen über einem Alphabet von Tokens definiert.

Spezifikation eines Parser

Eingabe: Grammatik $G = (N, \Sigma, \Pi, S)$, $w \in \Sigma^*$

Ausgabe: $erg \in \{True, False\}$

Nachbedingung: $erg = (w \in \mathcal{L}(G))$

Mit anderen Worten: Es muss eine Ableitung $S \xrightarrow{*} w$ gefunden werden.

Beispiel

$G = (N, T, \Pi, S)$ mit

$$N = \{S, A\}$$

$$T = \{a, b, c\}$$

$$\Pi = \{S \rightarrow cAb \\ A \rightarrow ab \mid a\}$$

Beispiel

$G = (N, T, \Pi, S)$ mit

$$N = \{S, A\}$$

$$T = \{a, b, c\}$$

$$\Pi = \{S \rightarrow cAb \\ A \rightarrow ab \mid a\}$$

$$w = cab$$

Beispiel

$G = (N, T, \Pi, S)$ mit

$$N = \{S, A\}$$

$$T = \{a, b, c\}$$

$$\Pi = \{S \rightarrow cAb \\ A \rightarrow ab \mid a\}$$

$$w = cab$$

$$\Rightarrow \text{Ableitung} : S \rightarrow cAb \rightarrow cab$$

Beispiel

$G = (N, T, \Pi, S)$ mit

$$N = \{S, A\}$$

$$T = \{a, b, c\}$$

$$\Pi = \{S \rightarrow cAb \\ A \rightarrow ab \mid a\}$$

$$w = cab$$

$$\Rightarrow \text{Ableitung} : S \rightarrow cAb \rightarrow cab$$

Ergebnis: $erg = True$

Ansatz für einen Parser

Programmiersprachen werden als kontextfreie Grammatiken mit kontextsensitiven Nebenbedingungen beschrieben

Ansatz für einen Parser

Programmiersprachen werden als kontextfreie Grammatiken mit kontextsensitiven Nebenbedingungen beschrieben

- ▶ Cocke-Younger-Kasami-Algorithmus

Nachteil:

- ▶ Voraussetzung: Grammatik Chomsky-Normalform
- ▶ Aufwand $O(n^3)$

Ansatz für einen Parser

Programmiersprachen werden als kontextfreie Grammatiken mit kontextsensitiven Nebenbedingungen beschrieben

- ▶ Cocke-Younger-Kasami-Algorithmus

Nachteil:

- ▶ Voraussetzung: Grammatik Chomsky-Normalform
- ▶ Aufwand $O(n^3)$

- ▶ (Nicht deterministische) Push-Down-Automaten

Nachteil:

- ▶ Polynomialer Aufwand

⇒ Betrachtung einer Teilmenge der Chomsky-2-Sprachen (LR-Sprachen)
(sind äquivalent zu den Sprachen, die durch deterministische Push-Down-Automaten erkannt werden.

⇒ Effiziente Implementierung möglich.

Ableitungsbaum

Man kann die Ableitung eines Wortes als Baum betrachten.

Ableitungsbaum

Man kann die Ableitung eines Wortes als Baum betrachten.

Aufbau:

Top-down: **Linksableitungen** (man erhält eine Ableitung, bei der immer das am weitesten links stehende Nichtterminal abgeleitet wird)

Ableitungsbaum

Man kann die Ableitung eines Wortes als Baum betrachten.

Aufbau:

Top-down: **Linksableitungen** (man erhält eine Ableitung, bei der immer das am weitesten links stehende Nichtterminal abgeleitet wird)

Bottom-Up: **Rechtsableitungen** (man erhält (rückwärts) eine Ableitung bei der immer das am weitesten rechts stehende Nichtterminal abgeleitet wird)

Linksableitungen (top-down)

$G = (N, T, \Pi, S)$ mit $N = \{S, A, B, C\}$ $T = \{a, b, c\}$ und
 $\Pi = \{S \rightarrow AB, A \rightarrow a, B \rightarrow bC, C \rightarrow c\}$


Eingabewort: $w = abc$

Linksableitungen (top-down)

$G = (N, T, \Pi, S)$ mit $N = \{S, A, B, C\}$ $T = \{a, b, c\}$ und
 $\Pi = \{S \rightarrow AB, A \rightarrow a, B \rightarrow bC, C \rightarrow c\}$

Eingabewort: $w = abc$

$nexttoken() = a$




Linksableitungen (top-down)

$G = (N, T, \Pi, S)$ mit $N = \{S, A, B, C\}$ $T = \{a, b, c\}$ und
 $\Pi = \{S \rightarrow AB, A \rightarrow a, B \rightarrow bC, C \rightarrow c\}$

Eingabewort: $w = abc$

$nexttoken() = a$





Linksableitungen (top-down)


$G = (N, T, \Pi, S)$ mit $N = \{S, A, B, C\}$ $T = \{a, b, c\}$ und
 $\Pi = \{S \rightarrow AB, A \rightarrow a, B \rightarrow bC, C \rightarrow c\}$

Eingabewort: $w = abc$

$nexttoken() = a$



$nexttoken() = b$




Linksableitungen (top-down)


$G = (N, T, \Pi, S)$ mit $N = \{S, A, B, C\}$ $T = \{a, b, c\}$ und
 $\Pi = \{S \rightarrow AB, A \rightarrow a, B \rightarrow bC, C \rightarrow c\}$

Eingabewort: $w = abc$


$nexttoken() = a$



$nexttoken() = c$



$nexttoken() = b$



Recursive Decent–Syntaxanalyse

- ▶ Eingabe wird durch eine Menge rekursiver Funktionen abgearbeitet.
- ▶ Jedem Nichtterminal der Grammatik entspricht eine Funktion.
- ▶ Die Folge der Funktionsaufrufe bestimmt implizit den Ableitungsbaum.

Linksrekursive Grammatik

$G = (N, T, \Pi, S)$ mit

$$\Pi = \left\{ \begin{array}{l} \textcolor{blue}{Exp} \rightarrow \textcolor{red}{let\ var = Exp\ in\ Exp} \\ \quad \quad \quad | \textcolor{red}{Exp + Exp} \\ \quad \quad \quad | \textcolor{red}{var} \\ \quad \quad \quad | \textcolor{red}{digits} \end{array} \right\}$$

Problem: Linksrekursion

Linksrekursive Grammatik

$G = (N, T, \Pi, S)$ mit

$$\Pi = \left\{ \begin{array}{l} \textcolor{blue}{Exp} \rightarrow \textcolor{red}{let\ var = Exp\ in\ Exp} \\ \quad \quad \quad | \textcolor{red}{Exp + Exp} \\ \quad \quad \quad | \textcolor{red}{var} \\ \quad \quad \quad | \textcolor{red}{digits} \end{array} \right\}$$

Problem: Linksrekursion

Eingabewort $\textcolor{blue}{1 + 1 + 1}$


Linksrekursive Grammatik

$G = (N, T, \Pi, S)$ mit

$$\Pi = \left\{ \begin{array}{l} \text{Exp} \rightarrow \text{let var} = \text{Exp in Exp} \\ \text{Exp} \rightarrow \text{Exp} + \text{Exp} \\ \text{Exp} \rightarrow \text{var} \\ \text{Exp} \rightarrow \text{digits} \end{array} \right\}$$

Problem: Linksrekursion

Eingabewort $1 + 1 + 1$




Linksrekursive Grammatik

$G = (N, T, \Pi, S)$ mit

$$\Pi = \left\{ \begin{array}{l} \text{Exp} \rightarrow \text{let var} = \text{Exp in Exp} \\ \quad \quad \quad \text{Exp} + \text{Exp} \\ \quad \quad \quad \text{var} \\ \quad \quad \quad \text{digits} \end{array} \right\}$$

Problem: Linksrekursion

Eingabewort $1 + 1 + 1$





Linksrekursive Grammatik

$G = (N, T, \Pi, S)$ mit

$$\Pi = \left\{ \begin{array}{l} \text{Exp} \rightarrow \text{let var} = \text{Exp in Exp} \\ \text{Exp} \rightarrow \text{Exp} + \text{Exp} \\ \text{Exp} \rightarrow \text{var} \\ \text{Exp} \rightarrow \text{digits} \end{array} \right\}$$

Problem: Linksrekursion

Eingabewort $1 + 1 + 1$






Linksrekursive Grammatik

$G = (N, T, \Pi, S)$ mit

$$\Pi = \left\{ \begin{array}{l} \text{Exp} \rightarrow \text{let var} = \text{Exp in Exp} \\ \text{Exp} \rightarrow \text{Exp} + \text{Exp} \\ \text{Exp} \rightarrow \text{var} \\ \text{Exp} \rightarrow \text{digits} \end{array} \right\}$$

Problem: Linksrekursion

Eingabewort $1 + 1 + 1$







Linksrekursive Grammatik

$G = (N, T, \Pi, S)$ mit

$$\Pi = \left\{ \begin{array}{l} \text{Exp} \rightarrow \text{let var} = \text{Exp in Exp} \\ \text{Exp} \rightarrow \text{Exp} + \text{Exp} \\ \text{Exp} \rightarrow \text{var} \\ \text{Exp} \rightarrow \text{digits} \end{array} \right\}$$

Problem: Linksrekursion

Eingabewort $1 + 1 + 1$



Linksrekursive Grammatik

$G = (N, T, \Pi, S)$ mit

$$\Pi = \left\{ \begin{array}{l} \textcolor{blue}{Exp} \rightarrow \textcolor{red}{let\ var = Exp\ in\ Exp} \\ \quad \quad \quad | \textcolor{red}{Exp + Exp} \\ \quad \quad \quad | \textcolor{red}{var} \\ \quad \quad \quad | \textcolor{red}{digits} \end{array} \right\}$$

Problem: Linksrekursion

Eingabewort $\textcolor{blue}{1 + 1 + 1}$


Linksrekursive Grammatik

$G = (N, T, \Pi, S)$ mit

$$\Pi = \left\{ \begin{array}{l} \text{Exp} \rightarrow \text{let var} = \text{Exp in Exp} \\ \text{Exp} \rightarrow \text{Exp} + \text{Exp} \\ \text{Exp} \rightarrow \text{var} \\ \text{Exp} \rightarrow \text{digits} \end{array} \right\}$$

Problem: Linksrekursion

Eingabewort $1 + 1 + 1$




Linksrekursive Grammatik

$G = (N, T, \Pi, S)$ mit

$$\Pi = \left\{ \begin{array}{l} \text{Exp} \rightarrow \text{let var} = \text{Exp in Exp} \\ \quad \quad \quad \text{Exp} + \text{Exp} \\ \quad \quad \quad \text{var} \\ \quad \quad \quad \text{digits} \end{array} \right\}$$

Problem: Linksrekursion

Eingabewort $1 + 1 + 1$






Linksrekursive Grammatik

$G = (N, T, \Pi, S)$ mit

$$\Pi = \left\{ \begin{array}{l} \text{Exp} \rightarrow \text{let var} = \text{Exp in Exp} \\ \text{Exp} \rightarrow \text{Exp} + \text{Exp} \\ \text{Exp} \rightarrow \text{var} \\ \text{Exp} \rightarrow \text{digits} \end{array} \right\}$$

Problem: Linksrekursion

Eingabewort $1 + 1 + 1$



Elimination der Linksrekursion

$G = (N, T, \Pi, S)$ mit

$$\Pi = \left\{ \begin{array}{l} \textcolor{blue}{Exp} \rightarrow \textcolor{red}{let var = Exp in Exp} \\ \quad \quad \quad | \textcolor{violet}{Exp} + \textcolor{violet}{Exp} \\ \quad \quad \quad | \textcolor{red}{var} \\ \quad \quad \quad | \textcolor{red}{digits} \end{array} \right\}$$

Elimination der Linksrekursion

$G = (N, T, \Pi, S)$ mit

$$\Pi = \left\{ \begin{array}{l} \text{Exp} \rightarrow \text{let var} = \text{Exp in Exp} \\ \quad \quad \quad \text{Exp} + \text{Exp} \\ \quad \quad \quad \text{var} \\ \quad \quad \quad \text{digits} \end{array} \right\}$$

$$\Pi = \left\{ \begin{array}{l} \text{Exp} \rightarrow \text{TExp Exp}' \\ \text{Exp}' \rightarrow + \text{TExp Exp}' \\ \quad \quad \quad \epsilon \\ \text{TExp} \rightarrow \text{let var} = \text{Exp in Exp} \\ \quad \quad \quad \text{var} \\ \quad \quad \quad \text{digits} \end{array} \right\}$$

Rechtsableitungen (bottom-up)

$$\Pi = \{S \rightarrow AB, A \rightarrow a, B \rightarrow bC, C \rightarrow c\}$$

Eingabewort: $w = abc$

Rechtsableitungen (bottom-up)

$\Pi = \{S \rightarrow AB, A \rightarrow a, B \rightarrow bC, C \rightarrow c\}$

Eingabewort: $w = abc$

nexttoken() = a

wende an: $A \rightarrow a$

A
↓
a

Rechtsableitungen (bottom-up)

$\Pi = \{S \rightarrow AB, A \rightarrow a, B \rightarrow bC, C \rightarrow c\}$

Eingabewort: $w = abc$

$nexttoken() = a$

wende an: $A \rightarrow a$

A
↓
a

$nexttoken() = b$

$nexttoken() = c$

wende an: $C \rightarrow c$

A b C
↓ ↓
a c

Rechtsableitungen (bottom-up)

$\Pi = \{S \rightarrow AB, A \rightarrow a, B \rightarrow bC, C \rightarrow c\}$

Eingabewort: $w = abc$

nexttoken() = a


wende an: $A \rightarrow a$




nexttoken() = b

nexttoken() = c

wende an: $C \rightarrow c$



wende an: $B \rightarrow bC$



Rechtsableitungen (bottom-up)

$\Pi = \{S \rightarrow AB, A \rightarrow a, B \rightarrow bC, C \rightarrow c\}$


Eingabewort: $w = abc$

nexttoken() = a

wende an: $A \rightarrow a$




wende an: $S \rightarrow AB$




nexttoken() = b

nexttoken() = c

wende an: $C \rightarrow c$



wende an: $B \rightarrow bC$



Rechtsableitungen (bottom-up)

$\Pi = \{S \rightarrow AB, A \rightarrow a, B \rightarrow bC, C \rightarrow c\}$


Eingabewort: $w = abc$

$nexttoken() = a$

wende an: $A \rightarrow a$




wende an: $S \rightarrow AB$




$nexttoken() = b$

$nexttoken() = c$

wende an: $C \rightarrow c$



wende an: $B \rightarrow bC$



Betrachtet man die Konstruktion rückwärts:

$\underline{S} \rightarrow \underline{A}\underline{B} \rightarrow \underline{A}b\underline{C} \rightarrow \underline{A}bc \rightarrow abc,$

Weiteres Beispiel:

$G = (N, T, \Pi, S)$ mit

$N = \{S, A, B\},$

$T = \{a, b, c, d, e\}$ und

$\Pi = \{S \rightarrow aABe, A \rightarrow Abc \mid b \mid d, B \rightarrow d\}$

Eingabestring: $w = abbcd e$

Weiteres Beispiel:

$G = (N, T, \Pi, S)$ mit

$N = \{S, A, B\},$

$T = \{a, b, c, d, e\}$ und

$\Pi = \{S \rightarrow aABe, A \rightarrow Abc \mid b \mid d, B \rightarrow d\}$

Eingabestring: $w = abbcde$

Bottom–Up Syntaxanalyse:

$a.bbcde$

Weiteres Beispiel:

$G = (N, T, \Pi, S)$ mit

$N = \{S, A, B\},$

$T = \{a, b, c, d, e\}$ und

$\Pi = \{S \rightarrow aABe, A \rightarrow Abc \mid b \mid d, B \rightarrow d\}$

Eingabestring: $w = abbcd e$

Bottom–Up Syntaxanalyse:

$a.bbcde \longleftarrow ab.bcde$

Weiteres Beispiel:

$G = (N, T, \Pi, S)$ mit

$N = \{S, A, B\},$

$T = \{a, b, c, d, e\}$ und

$\Pi = \{S \rightarrow aABe, A \rightarrow Abc \mid b \mid d, B \rightarrow d\}$

Eingabestring: $w = abbcd e$

Bottom–Up Syntaxanalyse:

$a.bbcde \leftarrow ab.bcde \leftarrow aA.bcde$

Weiteres Beispiel:

$G = (N, T, \Pi, S)$ mit

$N = \{S, A, B\},$

$T = \{a, b, c, d, e\}$ und

$\Pi = \{S \rightarrow aABe, A \rightarrow Abc \mid b \mid d, B \rightarrow d\}$

Eingabestring: $w = abbcd e$

Bottom–Up Syntaxanalyse:

$a.bbcde \longleftarrow a\textcolor{blue}{b}.\textcolor{violet}{b}cde \longleftarrow a\textcolor{blue}{A}.bcde \longleftarrow aA\textcolor{violet}{b}.cde$

Weiteres Beispiel:

$G = (N, T, \Pi, S)$ mit

$N = \{S, A, B\},$

$T = \{a, b, c, d, e\}$ und

$\Pi = \{S \rightarrow aABe, A \rightarrow Abc \mid b \mid d, B \rightarrow d\}$

Eingabestring: $w = abbcd e$

Bottom-Up Syntaxanalyse:

$a.bbcde \leftarrow a\textcolor{blue}{b}.\textcolor{magenta}{b}cde \leftarrow a\textcolor{blue}{A}.bcde \leftarrow aA\textcolor{magenta}{b}.cde \leftarrow a\textcolor{blue}{Abc}.de$

Weiteres Beispiel:

$G = (N, T, \Pi, S)$ mit

$N = \{S, A, B\},$

$T = \{a, b, c, d, e\}$ und

$\Pi = \{S \rightarrow aABe, A \rightarrow Abc \mid b \mid d, B \rightarrow d\}$

Eingabestring: $w = abbcd e$

Bottom-Up Syntaxanalyse:

$a.bbcde \leftarrow a.b.bcde \leftarrow aA.bcde \leftarrow aAb.cde \leftarrow aAbc.de$

Shift-Reduce-
Konflikt

$aAA.cde$

Weiteres Beispiel:

$G = (N, T, \Pi, S)$ mit

$N = \{S, A, B\},$

$T = \{a, b, c, d, e\}$ und

$\Pi = \{S \rightarrow aABe, A \rightarrow Abc \mid b \mid d, B \rightarrow d\}$

Eingabestring: $w = abbcd e$

Bottom-Up Syntaxanalyse:

$a.bbcde \leftarrow a b . bcde \leftarrow a A . bcde \leftarrow a Ab . cde \leftarrow a Abc . de \leftarrow$

Shift-Reduce-
Konflikt

$aA A . cde$

$a A . de \leftarrow a A d . e$

Weiteres Beispiel:

$G = (N, T, \Pi, S)$ mit

$N = \{S, A, B\},$

$T = \{a, b, c, d, e\}$ und

$\Pi = \{S \rightarrow aABe, A \rightarrow Abc \mid b \mid d, B \rightarrow d\}$

Eingabestring: $w = abbcd e$

Bottom-Up Syntaxanalyse:

$a.bbcde \leftarrow a.b.bbcde \leftarrow aA.bbcde \leftarrow aAb.bbcde \leftarrow aAbc.bbcde \leftarrow$

Shift-Reduce-
Konflikt

$aAA.bbcde$

$aA.de \leftarrow aAd.de \leftarrow aAB.de$

Weiteres Beispiel:

$G = (N, T, \Pi, S)$ mit

$N = \{S, A, B\},$

$T = \{a, b, c, d, e\}$ und

$\Pi = \{S \rightarrow aABe, A \rightarrow Abc \mid b \mid d, B \rightarrow d\}$

Eingabestring: $w = abbcde$

Bottom-Up Syntaxanalyse:

$a.bbcde \leftarrow a**b**.bcde \leftarrow a**A**.bcde \leftarrow aAb**b**.cde \leftarrow aAb**bc**.de \leftarrow$
 $aA**A**.cde$
Shift-Reduce-Konflikt

$a**A**.de \leftarrow aA**d**.e \leftarrow aA**B**.e$
 $aA**A**.e$
Reduce-Reduce-Konflikt

Weiteres Beispiel:

$G = (N, T, \Pi, S)$ mit

$N = \{S, A, B\},$

$T = \{a, b, c, d, e\}$ und

$\Pi = \{S \rightarrow aABe, A \rightarrow Abc \mid b \mid d, B \rightarrow d\}$

Eingabestring: $w = abbcde$

Bottom-Up Syntaxanalyse:

$a.bbcde \leftarrow a**b**.bcde \leftarrow a**A**.bcde \leftarrow aAb**b**.cde \leftarrow aAbc**b**.de \leftarrow$
 $\swarrow$ Shift-Reduce-Konflikt
 $aA**A**.cde$

$a**A**.de \leftarrow aAd**e** \leftarrow aAB**e** \leftarrow aABe \leftarrow S$
 $\swarrow$ Reduce-Reduce-Konflikt
 $aA**A**.e$

Konfliktlösungsansätze

LR(0): Es muss ohne Vorausschau möglich sein zu entscheiden, ob geshiftet oder reduziert wird.

SLR(1): An Hand der Bildung der Menge aller möglichen folgenden Terminalsymbole auf ein Nichtterminal, wird entschieden ob reduziert wird.

LR(1): Für jeden möglichen Ableitungsschritt in einer Produktion wird die Menge der darauffolgenden Terminalsymbole zur Unterscheidung betrachtet.

LALR(1): Es werden alle Mengen von LR(1)–Elementen zusammengefasst, die den gleichen Ableitungsschritt vollziehen.

$$LR(0) \subset SLR(1) \subset LALR(1) \subset LR(1) (= \mathcal{L}(DPDA))$$

Parsergenerator-Tool jaooy

Tokens

- ▶ Lexer/Scanner fasst die Strings zusammen, die an einer Stelle als Terminalsymbol in einer Grammatik stehen dürfen:

Lexeme mit gleicher Bedeutung: z.B.: [`<html>`, `<HTML>`]

Lexeme unterschiedlicher Bedeutung: z.B.: Text zwischen Tags

Ziel: Definition einer Datenstruktur, die diesem Rechnung trägt.

Klasse yyTokenclass

```
class yyTokenclass {  
    public int tokennr;  
    public Object value;  
  
    yyTokenclass () {  
        this.tokennr=-1;  
    }  
    yyTokenclass (Object o) {  
        this.value = o;  
    }  
}
```

Alle Tokens erben von yyTokenclass.

JLex-Spezifikation mit Tokens


```
%%
%class browserlexer
%eofval{
    return new EOF();
%eofval}

ws = [ \t\r\n]+

%%
"<(h|H)(t|T)(m|M)(l|L)">" { return new HTMLSTART(yytext());}
"</(h|H)(t|T)(m|M)(l|L)">" { return new HTMLEND(yytext());}
"[^<]+" { System.out.println(yytext());
          return new WORT(yytext());}
```

Wo kommen die Tokens (Java-Klassen) her?

Token-Klasse



jay-Tool (jaooy)

Eingabe (Grammatik)

- ▶ Namen der Tokenklassen (Terminale)
- ▶ Produktionen


Ausgabe

- ▶ Kellerautomat, der die Sprache der eingegebenen Grammatik erkennt als Java-Programm

jay-Spezifikation

```
%{  
class browserparser {  
%}  
  
%token HTMLSTART  
%token HTMLEND  
  
...  
  
%%  
S : HTMLSTART Head Body HTMLEND { }  
Head : HEADSTART Title HEADEND { }  
...  
  
%%  
}
```

Klassendiagramm JLex und jay



JLex-Spezifikation mit Klassendeklarationen

```
%%
%jayscanner browserscanner
%jayparser browserparser
%class browserlexer
%eofval{
    return new EOF();
%eofval}

ws = [ \t\r\n]+

%%
"<(h|H)(t|T)(m|M)(l|L)">" { return new HTMLSTART(yytext());}
"</(h|H)(t|T)(m|M)(l|L)">" { return new HTMLEND(yytext());}
"[^<]+" { System.out.println(yytext());
          return new WORT(yytext());}
```

Java-Klasse für den Aufruf

```
public class main {  
    public static void main (String [] args) {  
        browserscanner scanner =  
            new browserscanner  
                (new java.io.InputStreamReader (System.in));  
        browserparser parser = new browserparser() ;  
        try {  
            parser.yyparse(scanner);  
        }  
        catch (Exception e) {  
            e.printStackTrace();  
        }  
    }  
}
```

Makefile

```
Main.class: Main.java yyTokenclass.class browserscanner.class
    javac Main.java

yyTokenclass.class: browserparser.java
    javac browserparser.java

browserscanner.class: browserlexer.java
    javac browserlexer.java

browserlexer.java: browserlexer
    java -cp JLex2.jar JLex2.Main browserlexer

browserparser.java: browserparser.jay skeleton.jaooy
    jaooy -v browserparser.jay < skeleton.jaooy > browserparser.java

clean:
    rm -f *.class browserlexer.java browserparser.java
```

Aufgabe

Entwickeln Sie eine Mini-html-Parser als Grundlage für einen Browser.

- ▶ Definieren Sie eine Grammatik für Mini-html.
- ▶ Ergänzen Sie das JLex- und das Jay-File dementsprechend.