Einführung in die Informatik

Grammars & Parsers

Grammatiken, Parsen von Texten

Wolfram Burgard
Cyrill Stachniss

Einleitung

- Wir haben in den vorangehenden Kapiteln meistens vollständige Java-Programme als mögliche Beschreibungen von Algorithmen angegeben.
- Einzelne Befehle einer Programmiersprache stellen **abstrakte Befehle** zur **Manipulation der Daten** und zur **Kontrolle der Ausführung** zur Verfügung.
- Damit werden sie **unabhängig von dem konkreten Rechner**.
- Der **Compiler** sorgt dann dafür, dass sie in die Sprache des entsprechenden Rechners übersetzt werden.
- Darüber hinaus erlauben sie eine **Strukturierung des Programms**, was die Wartung und Entwicklung deutlich vereinfacht.
- In diesen Kapitel beschäftigen wir uns mit der Beschreibung von künstlichen Sprachen (z.B. Programmiersprachen).

Techniken zur Beschreibung der Syntax von Programmiersprachen

- Um Programme übersetzen zu können, muss der Rechner die Programmiersprache kennen, d.h. er muss wissen, was **gültige Programme** sind.
- Programmiersprachen sind **künstliche Sprachen**.
- Eine **Sprache** ist nichts anderes als eine **(im allgemeinen unendliche) Menge von Sätzen**, die jeweils aus **einzelnen Symbolen** bestehen.
- Die einzelnen, **nicht weiter unterteilbaren Symbole** nennt man auch **Tokens** der Sprache.
- Bei der Analyse eines Programms wird es in der so genannten **lexikalischen Analyse** zunächst in die Folge seiner Tokens zerlegt.

Kategorien von Tokens

Reservierte Wörter: Dies sind **Schlüsselwörter**, wie z.B. `boolean`, `int`, `class`, `static` usw.

Konstanten: Dazu gehören **Literale**, wie z.B. `4711L` oder `"Mehrwertsteuer"`.

Sonderzeichen: Z.B. `+`, `-`, `=`, `;`, . . . für Operatoren und Begrenzer.

Bezeichner: Alle **benutzerdefinierten Namen** zur Benennung von Variablen, Methoden, etc

Kommentare: Besonders gekennzeichnete Zeichenfolgen, die **vom Compiler übersprungen** werden.

...

Syntax von Programmiersprachen

- Unter der **Syntax einer Programmiersprache** versteht man die Regeln, die **festlegen, was gültige Programme sind**.
- Eine typische Form zur Formulierung dieser Regeln sind so genannte **kontextfreien Grammatiken**.
- Obwohl manche Teile der Syntax-Definition nicht durch kontextfreie Grammatiken erfasst werden können, hat diese Form der Syntaxbeschreibung große Vorteile.
- Dazu gehört insbesondere, dass **Analyseprogramme für Programme** (so genannte **Parser**) **automatisch konstruiert** werden können.

Arithmetische Ausdrücke

Arithmetische Ausdrücke können induktiv folgendermaßen definiert werden:

1. Jede Zahl ist ein arithmetischer Ausdruck.
2. Ist E ein arithmetischer Ausdruck, so ist auch (E) ein arithmetischer Ausdruck.
3. Sind E_1 und E_2 arithmetische Ausdrücke, so sind auch E_1+E_2, E_1-E_2 und E_1*E_2, E_1/E_2 arithmetische Ausdrücke.
4. Nur die auf diese Weise erhältlichen Zeichenreihen sind syntaktisch korrekt gebildete, arithmetische Ausdrücke.

Eine kontextfreie Grammatik für arithmetische Ausdrücke

$$\langle \text{Ziffer} \rangle \rightarrow 0 \mid 1 \mid 2 \mid 3 \mid 4 \mid 5 \mid 6 \mid 7 \mid 8 \mid 9$$

$$\langle \text{Zahl} \rangle \rightarrow \langle \text{Ziffer} \rangle \mid \langle \text{Ziffer} \rangle \langle \text{Zahl} \rangle$$

$$\langle \text{Ausdruck} \rangle \rightarrow \langle \text{Zahl} \rangle$$

$$\langle \text{Ausdruck} \rangle \rightarrow (\langle \text{Ausdruck} \rangle)$$

$$\langle \text{Ausdruck} \rangle \rightarrow \langle \text{Ausdruck} \rangle + \langle \text{Ausdruck} \rangle$$

$$\langle \text{Ausdruck} \rangle \rightarrow \langle \text{Ausdruck} \rangle - \langle \text{Ausdruck} \rangle$$

$$\langle \text{Ausdruck} \rangle \rightarrow \langle \text{Ausdruck} \rangle * \langle \text{Ausdruck} \rangle$$

$$\langle \text{Ausdruck} \rangle \rightarrow \langle \text{Ausdruck} \rangle / \langle \text{Ausdruck} \rangle$$

Typen von Symbolen in Grammatiken

Bei den einzelnen Symbolen unterscheidet man:

Metasymbole: Zeichen wie → und |, die **zur Formulierung der Regeln benötigt** werden.

Terminalsymbole: Sie entsprechen den **Tokens der Sprache** und sind die einzigen Zeichen, die in Sätzen der Sprache auftreten können. In unserem Beispiel sind dies 0, 1, 2 , 3, 4, 5, 6, 7, 8, 9, (,), +, - und *.

Nichtterminalsymbole: Dies sind die in spitze Klammern eingeschlossenen Zeichenreihen. Sie werde manchmal auch **Variablen oder syntaktische Kategorien** genannt.

Bedeutung der Komponenten

- Die oben angegebene Grammatik besteht aus einer Menge von **Regeln** oder **Produktionen**.
- Mit Hilfe der Regeln lassen sich, ausgehend von einem Startsymbol (hier: <Ausdruck>), Zeichenreihen erzeugen, indem man ein Vorkommen **eines Nichtterminalsymbols**, das **auf der linken Seite einer Regel** vorkommt, in der Zeichenreihe **durch die rechte Seite ersetzt**.
- Tritt auf der rechten Seite das **Metasymbol |** auf, so fasst man die dadurch abgetrennten Zeichenreihen als **alternative Ersetzungsmöglichkeiten** auf.
- Die erste Regel ist somit als Abkürzung für zehn einzelne Regeln der Form:

$$\langle \text{Ziffer} \rangle \rightarrow n$$

für $n = 0 \ldots\ldots\ldots 9$ aufzufassen

Anwendungsbeispiele

$$\langle \text{Ziffer} \rangle \rightarrow 0 \mid 1 \mid 2 \mid 3 \mid 4 \mid 5 \mid 6 \mid 7 \mid 8 \mid 9$$

$$\langle \text{Zahl} \rangle \rightarrow \langle \text{Ziffer} \rangle \mid \langle \text{Ziffer} \rangle \langle \text{Zahl} \rangle$$

$$\langle \text{Ausdruck} \rangle \rightarrow \langle \text{Zahl} \rangle$$

$$\langle \text{Ausdruck} \rangle \rightarrow (\langle \text{Ausdruck} \rangle)$$

$$\langle \text{Ausdruck} \rangle \rightarrow \langle \text{Ausdruck} \rangle + \langle \text{Ausdruck} \rangle$$

$$\langle \text{Ausdruck} \rangle \rightarrow \langle \text{Ausdruck} \rangle - \langle \text{Ausdruck} \rangle$$

$$\langle \text{Ausdruck} \rangle \rightarrow \langle \text{Ausdruck} \rangle * \langle \text{Ausdruck} \rangle$$

$$\langle \text{Ausdruck} \rangle \rightarrow \langle \text{Ausdruck} \rangle / \langle \text{Ausdruck} \rangle$$

Anwendungsbeispiel

$$
\begin{aligned}
\langle \text{Ausdruck} \rangle &\Rightarrow \langle \text{Ausdruck} \rangle * \langle \text{Ausdruck} \rangle \\
&\Rightarrow (\langle \text{Ausdruck} \rangle) * \langle \text{Ausdruck} \rangle \\
&\Rightarrow (\langle \text{Ausdruck} \rangle + \langle \text{Ausdruck} \rangle) * \langle \text{Ausdruck} \rangle \\
&\Rightarrow (\langle \text{Zahl} \rangle + \langle \text{Ausdruck} \rangle) * \langle \text{Ausdruck} \rangle \\
&\Rightarrow (\langle \text{Zahl} \rangle \langle \text{Ziffer} \rangle + \langle \text{Ausdruck} \rangle) * \langle \text{Ausdruck} \rangle \\
&\Rightarrow (\langle \text{Ziffer} \rangle \langle \text{Ziffer} \rangle + \langle \text{Ausdruck} \rangle) * \langle \text{Ausdruck} \rangle \\
&\Rightarrow (1 \langle \text{Ziffer} \rangle + \langle \text{Ausdruck} \rangle) * \langle \text{Ausdruck} \rangle \\
&\Rightarrow (17 + \langle \text{Ausdruck} \rangle) * \langle \text{Ausdruck} \rangle \\
&\Rightarrow (17 + \langle \text{Zahl} \rangle) * \langle \text{Ausdruck} \rangle \\
&\Rightarrow (17 + 4) * \langle \text{Ausdruck} \rangle \\
&\Rightarrow (17 + 4) * \langle \text{Zahl} \rangle \langle \text{Ziffer} \rangle \\
&\Rightarrow (17 + 4) * \langle \text{Zahl} \rangle \langle \text{Ziffer} \rangle \langle \text{Ziffer} \rangle \\
&\Rightarrow (17 + 4) * \langle \text{Ziffer} \rangle \langle \text{Ziffer} \rangle \langle \text{Ziffer} \rangle \\
&\Rightarrow (17 + 4) * 3 \langle \text{Ziffer} \rangle \langle \text{Ziffer} \rangle \\
&\Rightarrow (17 + 4) * 3 \langle \text{Ziffer} \rangle \langle \text{Ziffer} \rangle \\
&\Rightarrow (17 + 4) * 37 \langle \text{Ziffer} \rangle \\
&\Rightarrow (17 + 4) * 372
\end{aligned}
$$

Eine formale Definition von Grammatiken

Eine **Grammatik** ist ein 4-Tupel $G = (V, T, P, S)$ bestehend aus:

1. Einer Menge V von **Nichtterminalsymbolen** (Variablen),
2. einer Menge T von **Terminalsymbolen** (Tokens) mit $V \cap T = \emptyset$,
3. einer Menge P von **Produktionen** (Regeln) der Form $p \to q$ mit $p \in (V \cup T)^*$ und $q \in (V \cup T)^*$ sowie
4. einem **Startsymbol** $S \in V$.

Hierbei bedeutet $v \in V^*$, dass v eine **Zeichenkette** ist, die aus den Variablen in V gebildet wird.

Ableitbarkeit

- Sei $x=x_1...p...x_n$ ein Wort aus , $(V \cup T)^*$ das die linke Seite einer Regel $p \to q \in P$ enthält.
- Dann kann man durch Ersetzen von p durch q in x ein Wort $y=y_1...q...y_n$ erhalten und schreibt dafür: $x \Rightarrow y$ oder, falls erforderlich $x \underset{G}{\Rightarrow} y$, oder $x \underset{p \to q}{\Rightarrow} y$.

  Wir sagen, dass **y in einem Schritt aus x ableitbar** ist.
- **y heißt ableitbar aus x** mithilfe von G, kurz $x \overset{*}{\underset{G}{\Rightarrow}} y$, wenn entweder $x=y$ ist oder es Worte $x_1, x_2, \ldots, x_n$ gibt mit $x= x_1$ und $y= x_n$, $n \geq 2$, und $x_i \underset{G}{\Rightarrow} x_{i+1}$, für $i=1, \ldots n-1$.

Von einer Grammatik erzeugte Sprache

- Die **von einer Grammatik erzeugte Sprache** ist die Menge der aus dem Startsymbol ableitbaren Worte, die nur aus Terminalzeichen bestehen:

$$L(G) = \left\{ W \mid S \overset{*}{\Longrightarrow} W \text{ und } W \in T^* \right\}.$$

- *L(G)* ist also die **Menge aller aus dem Startsymbol in endlich vielen Schritten ableitbaren Terminalzeichenreihen**.
- Meistens gibt man nur die Produktionen von *G* an und legt damit *V* und *T* implizit fest.
- Für unsere Grammatik *G* zur Definition arithmetischer Ausdrücke ist also *L(G)* die Menge aller syntaktisch korrekt gebildeten, arithmetischen Ausdrücke.

Beispiel (1)

G=(V,T,P,S) sei eine Grammatik mit

$$V = \{S, A, B\}$$
$$T = \{a, b\}$$
$$P = \{S \to AB, A \to AA, A \to a, B \to BB, B \to b\}$$

Dann sieht man leicht, dass gilt:

$$L(G) = \{a^n b^m \mid n, m \geq 1 \text{ und } m, n \in \mathbb{N}\}.$$

Beispiel (2)

G=(V,T,P,S) sei eine Grammatik mit

$$V = \{S\}$$
$$T = \{a, b\}$$
$$P = \{S \to aSb, S \to \varepsilon\}$$

wobei ε das leere Wort bezeichnet. Dann ist

$$L(G) = \{a^n b^n : n \in \mathbb{N}, n \geq 0\}.$$

- Offensichtlich kann man mit Regeln dieser Art **Klammerstrukturen** erzeugen.
- In Java kommen solche Strukturen z.B. in Form von `{ . . . }` oder `if ... then ... else` vor.

Typen von Grammatiken

- Nach der Art der zugelassenen Regeln klassifiziert man Grammatiken in verschiedene Typen (Chomsky-Hierarchie: Typ 0 bis Typ 3).
- Dies geht zurück auf Noam Chomsky, 1959, und wird in der theoretischen Informatik genauer studiert.
- Noam Chomsky ist eigentlich Linguist und kein Informatiker
- Prof. (Emeritus) am MIT in Boston
- Er ist einer der bedeutenden politischen Denker in den USA

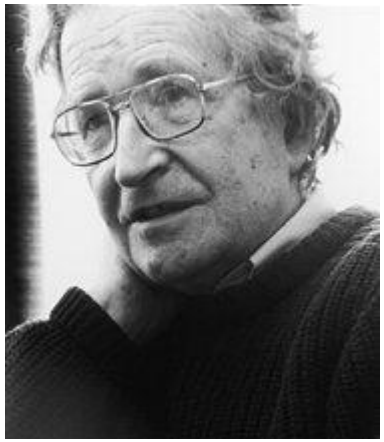

Die Chomsky-Hierarchie

Typ	Bezeichnung	Regelart $p \to q$
0	**unbeschränkte Grammatiken**	$p \in (V \cup T)^* \setminus \{\epsilon\}$ $q \in (V \cup T)^*$
1	**kontextsensitive Grammatiken** oder monotone Grammatiken	$p \in (V \cup T)^* \setminus \{\epsilon\}$ $q \in (V \cup T)^*$ Länge$(p) \leq$ Länge(q)
2	**kontextfreie Grammatiken**	$p \in V$ $q \in (V \cup T)^*$
3	**reguläre Grammatiken** d.h. linkslineare Grammatiken oder rechtslineare Grammatiken mit	$p \to qt \mid \epsilon$ $p \to tq \mid \epsilon$ $p, q \in V, t \in T$

Ein Beispiel für eine Typ-0-Grammatik

- Beide oben angegebenen Sprachen sind kontextfrei!
- Betrachten wir die folgende Typ-0-Grammatik:

$V = \{S,a,b,c,d,n\}$, $T = \{0,1\}$,
$P = \{S \rightarrow anb,\ d \rightarrow 0,\ d \rightarrow 1,\ n \rightarrow d,\ n \rightarrow dn,\ 1b \rightarrow b0,\ 0b \rightarrow c1,\ ab \rightarrow 1,$
$1c \rightarrow c1,\ 0c \rightarrow c0,\ ac \rightarrow \in \}$

Anwendungen:

Vergleich dieser Sprachtypen

- Eine Sprache *L* heißt vom Typ *i*, $0 \leq i \leq 3$, wenn es eine Grammatik vom Typ *i* gibt mit *L=L(G)*.
- Bezeichnet L_i die Familie der Sprachen vom Typ *i*, so gilt der (hier nicht bewiesene) **Hierarchiesatz**:

$$L_o \supset L_1 \supset L_2 \supset L_3$$

- Somit ist jede Sprache vom Typ *i* echt mächtiger als eine Sprache vom Typ *i*+1.

Existiert eine Grammatik für Java?

- Es ist möglich, eine Grammatik *G* anzugeben, so dass *L(G)* die Menge der korrekt gebildeten Java-Programme ist (bis auf die semantischen Nebenbedingungen).
- Aufgrund der semantischen Nebenbedingungen kann ein der Grammatik entsprechendes Java-Programm eventuell nicht übersetzbar sein.
- Beispielsweise kann man aus der Grammatik nicht ableiten, dass eine Variable erst deklariert werden muss, bevor sie benutzt wird.
- Eine Grammatik für Java findet man z.B. in: R. Kühnel, Java Fibel, Addison Wesley, 1996, Anhang A.

Backus-Naur-Form (BNF)

- Für die Spezifikation der Syntax von Programmiersprachen verwendet man häufig kontextfreie Grammatiken.
- Allerdings werden die Regeln meist in der **Backus-Naur-Form** (BNF) dargestellt:
  - Anstelle von → wird ::= (oder =) verwendet.
  - Mit dem Metasymbol | werden Regeln zusammengefasst.
  - Nichtterminalsymbole werden als in spitzen Klammern eingeschlossene Zeichenreihen repräsentiert.
- Beispiel:

<Zahl> ::= <Ziffer> | <Zahl><Ziffer>
<Ziffer> ::= 0|1|2|3|4|5|6|7|8|9

Erweiterte Backus-Naur-Form (EBNF)

- Hierbei stehen Terminalzeichen in Anführungszeichen oder werden anderweitig hervorgehoben.
- Für $n \geq 0$ Wiederholungen verwendet man die Notation `{...}`.
- Optionale Teile hingegen werden in eckige Klammern `[...]` eingeschlossen.
- Lässt man führende Nullen zu, so kann man eine `Integer`-Zahl folgendermaßen beschreiben:

Integer ::= [+|-]Ziffer{Ziffer}

Techniken zum Parsen

Chomsky	Technik
0	**Turing-Maschine**
1	**Linear beschränkte Turing-Maschine**
2	**Kellerautomat (Stack Machine)**
3	**Endlicher Automat**

Wie funktioniert ein Parser

- Top-Down oder Bottom-Up Realisierung
- Meist wird ein so genannter Kellerautomat (Stack Machine) verwendet, da oft kontextfreie Grammatiken verwendet werden
- Idee:
  1. Verarbeitung der Eingabe von rechts nach links
  2. Abarbeiten (Ersetzen) eines Strings sobald dies möglich ist
  3. Ansonsten auf dem Stack abspeichern und
     diesen Ausdruck abarbeiten sobald dies möglich ist

Parser-Baum

- Die Anwendung einer Grammatik kann auch als Baum dargestellt werden
- Die Blattelement beschreiben dabei den zu parsenden String
- Die inneren Element bezeichnen die Regel nach der der String ersetzt wird

- Regeln
  <S> ::= <S><S>
  <S> ::= a
- String
  aa

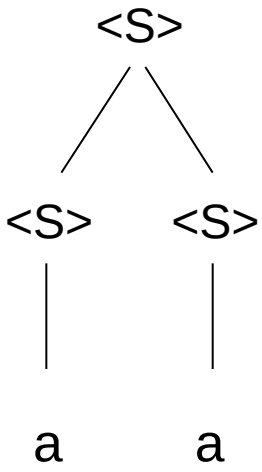

Beispiel HTML-Tabelle parsen

- Regeln

  <TAB> ::= “<table>” <ROWS> “</table>”

  <ROWS> ::= <ROWS><ROWS> | “<tr>” <COLS> ”</tr>”

  <COLS> ::= <COLS><COLS> | “<td>” <TEXT> “</td>” |
  “<td>” <TAB> “</td>”

  <TEXT> ::= …..

- Eingabe
  <table><tr><td>Hallo</td></tr></table>

Parser-Baum

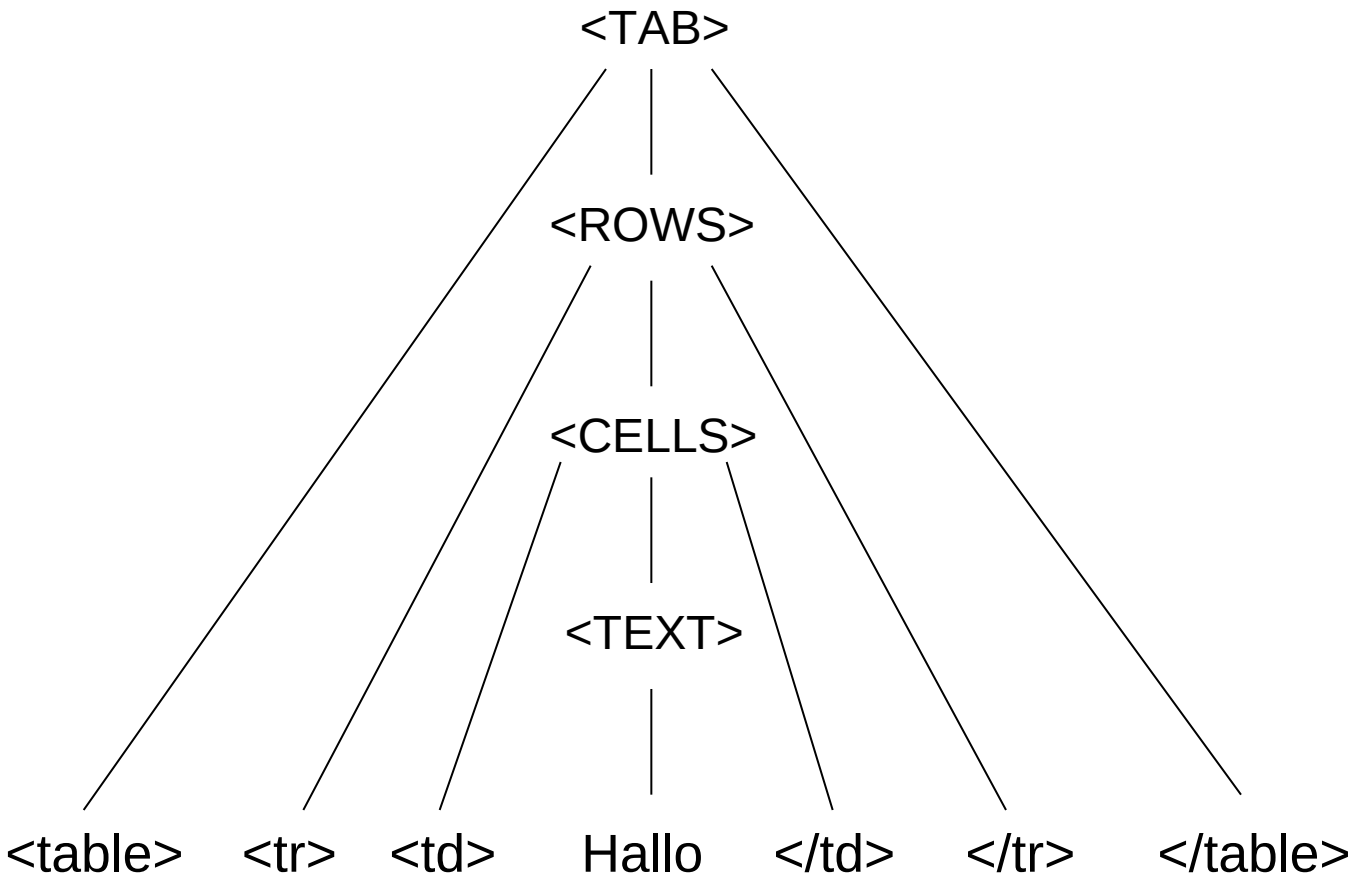

Lex und Yacc

- Tools zum einfachen Bauen von Parsern
- Lex
  - Lexikalische Analyse
- Yacc
  - Parsergenerator für kontextfreie Grammatiken
  - Nutzt einen Kellerautomat

Zusammenfassung

- **(Imperative) Programmiersprachen** stellen **abstrakte Anweisungen zur Manipulation von Daten** zur Verfügung.
- Zur Beschreibung von Programmiersprachen verwendet man **Grammatiken**.
- Die von einer **Grammatik erzeugte Sprache** ist die Menge aller in **endlich vielen Schritten ableitbaren, variablenfreie Zeichenketten**.
- Je nach **Struktur der Regeln** sind **Grammatiken unterschiedlich mächtig**.
- Die **Chomsky-Hierarchie klassifiziert** verschiedene Arten von **Grammatiken**.
- Die **(erweiterte) Backus-Naur-Form** ist eine typische Art **Grammatiken von Programmiersprachen** zu **notieren**.