



Theoretische Informatik

Sprachen und Sprachanalyse
Berechenbarkeit
Komplexität



Der Aufbau von Sprachen

n Sprachen sind in mehreren Schichten aufgebaut

1. Zeichen bzw. Symbole

n Endliche Menge, z.B.:

® Lateinisch	=	{ a, b, c, ... }
® Telugu	=	{ అ, బ, త, మ, హ, ఋ, ఌ, ఓ, ... },
® Kyrillisch	=	{ Д, Ж, Ё, И, Л, Б, С, ... },
® Arabisch	=	{ ز, ف, ي, ١, ٢, ٣, ... }

2. Worte

n Aus Zeichen gebildet

- ® endliche Länge
- ® unendlich viele Möglichkeiten

n Korrektheit meist leicht erkennbar

- ® Wörterbuch, Beugung, Konkatenation

3. Sätze

n Aus Worten gebildet

n Regeln durch Grammatik beschrieben

n Korrektheit schwieriger zu erkennen

- ® „*Der Dativ ist dem Genitiv sein Tod.*“



Programmiersprachen

1. Zeichen

n a,b,..., z, A,..., Z,0,1,...,9,+,-,*,/,“, \$, =, <, (,), ...

2. Worte

n Schlüsselworte

® if, then, while, exit, case, ...

n Bezeichner

® betrag, summe, fact, print, Stack, int

n Wertliterale

® int-Konstante,

β 31, -2005, +181

® float-Konstante,

β 3.14, 0.5E-12, -.12

® String-Konstante, ...

β "Otto", "Das ist ein \n zweizeiliger Text"

n Symbole

® :=, ==, (,), <=, ++, +, +=, ...

3. Sätze

n Programme

® "public static void main (String[] args){
 System.out.println "



Analyse von Programmtexten

n Eingabe:

- ④ Programm als Textstring
(Folge von Zeichen).
- ④ **“PROGRAM ggT; BEGIN x:=54;y:=30;WHILE not x=y DO
IF x>y THEN x:=x-y;ELSE y:= ...”**

n Ausgabe:

- ④ Entscheidung ob das Programm **syntaktisch korrekt** ist
 - n Ggf: Fehlerhinweis
- ④ Analyse des Programms
 - n Wie sind die Teile **geschachtelt**
 - n Kontrollfluss
- ④ Übersetzung in einfachere Sprache
 - n Maschinensprache
 - n Code für VM



Drei Phasen eines Compilers

1. Lexikalische Analyse

- ® *Scanner*
- ® Zerlegung des Programmtextes in Worte

2. Syntaktische Analyse

- ® *Parser*
- ® Erkennung der Satzstruktur
- ® Interne Repräsentation des Programms als Baum

3. Codeerzeugung

- ® Übersetzung anhand einer Baumtraversierung



Aufgabe des Scanners

- n Zerlegt Programmtext in Worte
 - Ⓡ nach welchen Kriterien ?
- n klassifiziert Worte in einem Programmtext
 - Ⓡ Schlüsselwort, Zahlkonstante, Bezeichner, ...
- n Wortklassen werden durch *Token* repräsentiert
 - Ⓡ **187, 3.14, -1.18E-12, 0.5** ⇒ *num*
 - Ⓡ **betrag, zins, x** ⇒ *id*
 - Ⓡ **:=** ⇒ *assignOp*
 - Ⓡ **;** ⇒ *semi*
 - Ⓡ **WHILE, while, While, wHiLe** ⇒ *while*
- n Aufgabe des Scanners also:
 - Ⓡ Programmtext ⇒ *Liste von Token*
- n In *java.util* gibt es eine Klasse *Scanner*



Scannerlauf

Programm (repräsentiert als Text)

```
"PROGRAM ggT;  
BEGIN  
  x:=54;  
  y:=30;  
    WHILE not x=y DO  
      IF x>y THEN x:=x-y  
        ELSE y:=y-x;  
      writeln('Das Ergebnis ist: ',x)  
END."
```

Scanner

Tokenliste repräsentiert
z.B. als

<i>program</i>	17
<i>id</i>	23
<i>semi</i>	54
<i>begin</i>	19
<i>id</i>	23
<i>assignOp</i>	37
<i>num</i>	18
<i>semi</i>	54
<i>id</i>	23
<i>assignOp</i>	37
<i>num</i>	18
<i>semi</i>	54
<i>while</i>	74
...	...




Scanner als Automat

n *Scanner* ist ein *Automat*

- ® Abhängig von Input und Zustand
 - n geht er in einen neuen Zustand
 - n klassifiziert einen Teilstring

Aus dem Input erzeugte Token





Drei Phasen eines Compilers

1. Lexikalische Analyse

- ® *Scanner*
- ® Zerlegung des Programmtextes in Worte

2. Syntaktische Analyse

- ® *Parser*
- ® Erkennung der Satzstruktur
- ® Interne Repräsentation des Programms als Baum

3. Codeerzeugung

- ® Übersetzung anhand einer Baumtraversierung



Grammatik

- n Grammatiken legen mögliche Satzstrukturen fest
- n **Rekursion** ist erlaubt

Grammatik für Java:

block :: { *Anweisungen* }
Anweisung :: *if (Expr) Anweisung*
 | *while(Expr) Anweisung*
 | { *Anweisungen* }
 | ...

Anweisungen :: *Anweisungen Anweisung*
 | */* Nix */*

Grammatik für Anfänger:

Satz :: *Subjekt Prädikat Objekt*

Subjekt :: **artikel nomen**
 | **artikel adjektiv nomen**


Prädikat :: **verb** | **hilfsverb**

Objekt :: *Subjekt*



Syntax nat. Sprache

n Gruppierung von Worten anhand einer *Grammatik*



Die lila Kuh legt ein Schokoladenei

Deutsche Grammatik:

Satz :: Subjekt Prädikat Objekt

Subjekt :: **artikel nomen**
| **artikel adjektiv nomen**

Prädikat :: **verb** | **hilfsverb**

Objekt :: Subjekt

: Syntaxbaum

: Tokenliste

: Ein Satz

Parser

Scanner



Aufgabe des Parsers

n Parser erzeugt **Syntaxbaum**


Grammatik für Pascal:

block :: **Begin** *Stmts* **End**

Stmt :: **id** **:=** *Expr*

| **while** *Expr* **do** *Stmt*

| *Stmt* ; *Stmts*



Liste der Token

begin

id

:=

num

;

while

id

<=

num

do

Erwartet:



Drei Phasen eines Compilers

1. Lexikalische Analyse

- ® *Scanner*
- ® Zerlegung des Programmtextes in Worte

2. Syntaktische Analyse

- ® *Parser*
- ® Erkennung der Satzstruktur
- ® Interne Repräsentation des Programms als Baum

3. Codeerzeugung

- ® Übersetzung anhand einer Baumtraversierung




Codeerzeugung

- n Aus Syntaxbaum
 - ® erzeuge Maschinencode
 - ® führe Buch über Speicherplatz für Variablen
 - n Symboltabelle
- n Kein Thema in dieser Vorlesung

betrag := betrag*(1+zins)

Name	Typ	Sp.Platz
betrag	float	17F4
zins	float	17F8
x	int	201C
test	boolean	C011

Parse Tree_:




Code für einen
Stackprozessor

```
LOAD* 17F4
LOAD 17F4
LOADC 1
LOAD 17F8
ADD
MULT
STORE
```



Berechenbarkeit

- n Was ist ein Algorithmus
 - Ⓡ Was kann man mit Algorithmen lösen
 - Ⓡ Was kann man nicht algorithmisch lösen
- n Kann eine Programmiersprache mehr als die andere ?
 - Ⓡ Kann man jeden Algorithmus in Java formulieren
 - Ⓡ in Pascal, C, Prolog, C, C++, Assembler ?
- n Kann man jeden Algorithmus
 - Ⓡ rekursiv formulieren ?
 - Ⓡ braucht man Zuweisungen ?
 - Ⓡ braucht man Variablen ?
- n Wie kompliziert muss ein Rechner sein ?
 - Ⓡ Kann eine Workstation **mehr** als ein PC
 - Ⓡ mehr als ein programmierbarer Taschenrechner ?





Was können Algorithmen nicht

n Gibt es Algorithmen, um zu entscheiden, ob ein Programm

® syntaktisch korrekt ist ?

ÿ ja, Parser

® semantisch korrekt ist

n kein Laufzeitfehler ?

n keine Endlosschleife ?

ÿ nein, nicht algorithmisch lösbar

n Gibt es einen Algorithmus, um zu entscheiden, ob

® zwei Programme äquivalent sind ?

® ein Rechner virenverseucht ist

® ein Programm einen Virus hat





Game of Life

n Gibt es einen Algorithmus um festzustellen, ob eine Konfiguration

- Ⓡ ausstirbt
 - nein
- Ⓡ sich reproduziert
 - nein
- Ⓡ periodisch wird
 - nein
- Ⓡ sich nach höchstens k Schritten wiederholt
 - ja



n Regeln (John Conway)

- Ⓡ Eine lebendes Feld
 - n mit 2 oder 3 Nachbarn überlebt
 - n mit weniger als 2 oder mehr als 3 Nachbarn stirbt
 - Ⓡ vor Einsamkeit
 - Ⓡ wegen Überbevölkerung
- Ⓡ Ein leeres Feld
 - n mit 3 Nachbarn erweckt zum Leben



Komplexität

n Inhärent schwere Probleme

- ® Travelling Salesman
- ® Bin Packing
- ® Satisfiability
- ® Hamiltonscher Kreis

n Lösbar, aber kein effizienter Algorithmus bekannt


- ® Könnte man eines effizient lösen, dann auch alle anderen

n Lösungsalgorithmus im wesentlichen

- ® systematisches Ausprobieren

n Oft behilft man sich mit Näherungslösungen

- ® z.B.: simulated Annealing
- ® siehe: Algorithmus der Woche
 - » Simulated Annealing




<http://www-i1.informatik.rwth-aachen.de/~algorithmus/algo41.php>




NP-Vollständigkeit

- n Problem P ist NP-vollständig, wenn es genau so schwer ist, wie eines (= alle) dieser Probleme
 - ® Könnte man eines der schweren Probleme effizient lösen, dann auch P
 - ® Könnte man P effizient lösen, so könnte man auch die berühmten schweren Probleme lösen
- n Viele Probleme sind NP-vollständig
 - ® trotzdem nicht die Flinte ins Korn werfen
 - ® Komplexitätsaussagen gelten nur asymptotisch
 - ® für „kleine“ Inputgrößen gibt es viel Raum für Kreativität
- ÿ SAT-Probleme mit tausend Variablen heute lösbar
 - ÿ Binary Decision Diagrams
 - ÿ Stålmark-Algorithmus®
 - ÿ industriell relevant
 - ÿ z.B. für Model checking



I can't find an efficient algorithm, I guess I'm just too dumb.



I can't find an efficient algorithm, because no such algorithm is possible.



I can't find an efficient algorithm, but neither can all these famous people.