

Einführung

Compiler

Prof. Dr. Oliver Braun

Letzte Änderung: 27.01.2020 19:45

- ist ein Computerprogramm

- das ein Programm

 - geschrieben in einer Sprache

in ein Programm

 - geschrieben in einer anderen Sprache

übersetzt

- ist ein großes Softwaresystem
- mit vielen
 - internen Komponenten,
 - Algorithmen und
 - komplexen Interaktionen zwischen beiden

- ist eine Einführung in Techniken für die
 - Übersetzung und
 - Optimierung von Programmen
- und eine praktische Übung in
 - Software Engineering

- ein Compiler muss die
 - **Syntax** und die
 - **Bedeutung**der Eingabesprache sowie die
 - **Syntax** und die
 - **Bedeutung**der Ausgabesprache verstehen
- und ein Compiler benötigt ein
 - **Abbildungsschema**von der Quell- zur Zielsprache

- formale Sprachen
- haben rigide Eigenschaften und Bedeutungen
- sind so entworfen, dass sie keine Mehrdeutigkeiten enthalten

- Quellsprachen
 - z.B. Java, C, C++, ...
- Zielsprachen
 - z.B. Maschinensprache, Bytecode für die JVM oder .NET
- es gibt aus *source-to-source-translators*
 - z.B. Übersetzung einer neuen Programmiersprache nach C
- und andere, z.B.
 - LaTeX to PostScript
 - Markdown to HTML

- führen ein Programm aus
- benötigen aber auch Scanner, Parser, Zwischenrepräsentationen, ...
- z.B. Python, Perl, Scheme, ...

- Compiler nach Bytecode
- Bytecode wird von einem Interpreter ausgeführt

oft als JIT

- Compiler der zur Laufzeit übersetzt
- *just-in-time compiler*

Warum sollten Sie sich mit Compilerdesign beschäftigen...

- Ein Compiler enthält einen Informatik-Mikrokosmos
 - gierige (greedy) Algorithmen (register allocation)
 - heuristische Suchtechniken (list scheduling)
 - Graphalgorithmen (dead-code elimination)
 - dynamische Programmierung (instruction selection)
 - endliche Automaten und Kellerautomaten (scanning and parsing)
 - Fixpunktalgorithmen (data-flow analysis)
- Ein Compiler muss mit folgenden Problemen umgehen können
 - dynamischer Allokation
 - Synchronization
 - Namensgebung
 - Lokalität
 - hierarchischem Speichermanagement
 - Pipelinescheduling

Compiler demonstrieren den erfolgreiche Anwendung der Theorie auf praktische Probleme


- Werkzeuge zum Generieren von Scannern und Parsern
 - wenden Ergebnisse aus der formalen Sprachtheorie an
 - die selben Werkzeuge werden für die Textsuche, das Filtern von Websites, die Textverarbeitung und Kommandozeileninterpreter verwendet
- Typüberprüfung und statische Analyse
 - wenden Ergebnisse der Verbandstheorie, der Zahlentheorie und anderer mathematischer Teilgebiete an
- Codegeneratoren
 - benutzen Algorithmen für die Mustererkennung in Bäumen, das Parsen, die dynamische Programmierung und Textvergleiche

Erstes Prinzip

Der Compiler muss die Bedeutung des zu compilierenden Programms erhalten.


Zweites Prinzip

Der Compiler muss das Eingabeprogramm auf wahrnehmbare Art und Weise verbessern.



Ein 2-Phasen-Compiler

- das Frontend muss seine Kenntnis der Quellsprache nutzen
 - muss sicherstellen, dass das Quellprogramm wohlgeformt ist
- die Zwischenrepräsentationen (intermediate representation, IR) ist die maßgebliche Repräsentation des Codes für den Compiler
 - es kann mehrere Zwischenrepräsentationen für verschiedene Compilerphasen geben
- das Backend muss die IR abbilden auf
 - die Befehlsmenge und
 - die endlichen Ressourcen



Ein 3-Phasen-Compiler

Überblick über die Compilierung

- muss die Programmstruktur mit deiner **Sprachdefinition** vergleichen
- formale Definition = endliche Menge von Regeln = **Grammatik**, z.B.

Satz → *Subjekt* **Verb** *Objekt* **Satzendezeichen**

- **Verb** und **Satzendezeichen** sind Teile der Sprache
- *Satz*, *Subjekt* und *Objekt* sind syntaktische Variablen
- das Symbol → heisst “leitet her”

- Beispiel: "Compiler sind technische Objekte."
- der Scanner
 - nimmt diesen Zeichenstrom und
 - wandelt ihn um in einen Strom von klassifizierten Worten

- Beispiel:

(Substantiv, "Compiler"), (Verb, "sind"),
(Adjektiv, "technische"), (Substantiv, "Objekte"),
(Satzendezeichen, ".")

- Regeln

1. *Satz* → *Subjekt* **Verb** *Objekt* **Satzendezeichen**

2. *Subjekt* → **Substantiv**

3. *Subjekt* → *Modifikator* **Substantiv**

4. *Objekt* → **Substantiv**

5. *Objekt* → *Modifikator* **Substantiv**

6. *Modifikator* → **Adjektiv**

...

- wenn es möglich ist eine Herleitung zu finden, die

- mit dem Nichtterminal *Satz* startet und

- endet mit **Substantiv** **Verb** **Adjektiv** **Substantiv**
Satzendezeichen

dann gehört der Satz "Compiler sind technische Objekte." zur Sprache

- der Prozess der automatisch nach so einer Herleitung sucht heisst

- das Frontend ist außerdem dafür zuständig Typkonsistenz zu überprüfen
- z.B.


$a = a * 2 * b * c * d$

mag syntaktisch wohlgeformt sein

aber wenn **b** und **d** Zeichenketten sind, ist der Ausdruck ungültig

- Ziel des Frontends ist eine Zwischenrepräsentation des Codes zu erzeugen
- verschiedene Formen
 - Graphen
 - Assemblerprogramme

Zwischenrepräsentation: Beispiel Graph



DAG für $a = a * 2 * b * c * d$

Lowlevel, sequentieller Code für $a = a * 2 * b * c * d$:

```
t0 = a * 2
```

```
t1 = t0 * b
```

```
t2 = t1 * c
```

```
t3 = t2 * d
```

```
a = t3
```

- analysiert die Zwischenrepräsentation
- und schreibt den Code so um, dass er das selbe berechnet, aber in einer effizienteren Art und Weise
 - reduziert die Laufzeit der Anwendung oder
 - reduziert die Größe des generierten Codes oder
 - reduziert die Energie die der Prozessor verbraucht
 - oder ...

- ursprünglicher Code

```
b = ...  
c = ...  
a = 1  
for i = 1 to n  
  read d  
  a = a * 2 * b * c * d  
end
```

- verbesserter Code

```
...  
t = 2 * b * c  
for i = 1 to n  
  read d  
  a = a * d * t
```

- durchläuft die Zwischenrepräsentation
- gibt Code für die Zielplattform aus

Instruction Selection wählt die Maschinenbefehle aus die der jeweiligen IR-Operation entsprechen

Register Allokation entscheidet welche Werte in Registern und welche im Hauptspeicher gehalten werden

Instruction Scheduling ermittelt die Reihenfolge in der die Befehle effizient ausgeführt werden können