

Lexikalische Analyse mit LEX

Jan Hendrik Dithmar
15.12.2005

Motivation

- Klassische Beispiele:
 - das zu entwickelnde Programm ist ein Compiler
 - die Eingabe ist eine Konfigurationsdatei
- Eingabe hat eine bestimmte Struktur
- Struktur muss erkannt werden
- Dazu muss die Struktur (Syntax der Eingabe) formal festgelegt sein



Beispiel: Konfigurationsdatei

[General]

WindowState = Maximized

ShowSplashScreen = True

[Help]

ShowTooltips = True

ShowTipOfTheDay = False

[Config]

SaveTemporaryFiles = True

BrowserExecutable = firefox

StandardSearchEngine = <http://www.google.de/>


Eingaben parsen

- Man muss Eingaben (z.B. Konfigurationsdateien) parsen können.
- Solche Parser selbst zu programmieren ist zeitaufwändig und teilweise auch kompliziert.



Eingaben parsen (2)


- Es kann leicht passieren, dass man vom Arbeitsaufwand für die Entwicklung des Parsers „erschlagen“ wird.



- Aus diesem Grund ist es einfacher, sich einen Scanner generieren zu lassen.

Lösung: LEX

- Mit LEX kann man z.B. folgende Aufgabe lösen:
 - Lexikalische Analyse
- Wie verwendet man LEX?



LEX-Spezifikation

- LEX benötigt eine Spezifikationsdatei.
- Aufbau der Spezifikationsdatei:


Definitionen

%%

Regeln

%%

Funktionen



- Aus der Spezifikation generiert LEX den Scanner.

Arbeitsweise von LEX



Beispiel: Artikel entfernen

Als Beispiel nehmen wir eine Datei `artike1.1`, die Artikel filtern soll:

```
%%  
der      |  
die      |  
das      |  
ein      |  
eine     ;  
.        |  
\n      ECHO;
```



Beispiel: Artikel entfernen (2)

```
$ lex artikel.1  
$ cc -o artikel lex.yy.c -ll  
$ echo "das Haus" | ./artikel  
Haus  
$ _
```

- **artikel.1**: LEX-Eingabe
- **lex.yy.c**: von LEX erzeugte Datei (Scanner)
- **-ll**: Compileroption zum Binden der LEX-Bibliothek

Überlappende Regeln und **REJECT**

LEX bietet die Möglichkeit eine Regel zurückzuweisen und somit überlappende Regeln zu realisieren.


Beispiel (Datei `reject.1`):

```
%%  
.    printf("Ja %s\n", yytext);  
...  printf("Nein %s\n", yytext); REJECT;  
win  printf("Treffer %s\n", yytext);  
\n   ;
```

In `yytext` ist die betrachtete Zeichenkette gespeichert.

Überlappende Regeln und **REJECT** (2)

```
$ lex reject.1
$ cc -o reject lex.yy.c -ll
$ echo iwinthat | ./reject
Nein iwi
Ja i
Nein win
Treffer win
Nein tha
Ja t
Nein hat
Ja h
Ja a
Ja t
$ _
```



Neugierig geworden?

Literatur:

Andreas Zeller, Jenk Krinke:
„Open-Source-Programmierwerkzeuge“
2. Auflage
dpunkt.verlag
ISBN 3-89864-226-7
Preis: 39,00 € (D), 40,10 € (A)
www.programmierwerkzeuge.de

