1 Einleitung, Motivation

- `lex` ist ein universelles Werkzeug für die lexikalische Analyse

- Entwicklung in den 70er Jahren als Ergänzung zum Parsergenerator `yacc`

- Erhebliche Vereinfachung bei der Erstellung eines Scanners
  - $\oplus$ kürzere Entwicklungszeit
  - $\oplus$ bessere Lesbarkeit
  - $\oplus$ leichtere Änderbarkeit
  - $\ominus$ ggf. schlechtere Effizienz

- Vorgehensweise:
  1. Spezifikation regulärer Ausdrücke und dazugehöriger Aktionen in Zielsprache $\rightarrow$ lex-Programm
  2. Übersetzung des lex-Programms in Zielsprache
  3. ggf. Einbinden in eigenes Programm, Übersetzung in Maschinencode

- Zielsprache kann C oder C++ sein

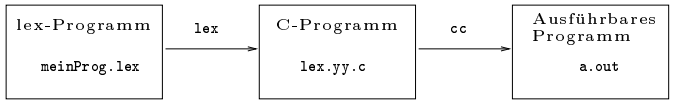

Einsatzgebiet:

- Compilerbau
- Textverarbeitung
- Chiffrierung

2 Lex-Programme

2.1 Struktur

Definitionsteil
%%
Regelteil
%%
Benutzerdefinierte Routinen

Der Regelteil ist der Kern eines lex-Programms

2.2 Der Regelteil

- Liste regulärer Ausdrücke r_i und dazugehöriger Aktionen $aktion_i$

r_1	$aktion_1$
r_2	$aktion_2$
$\vdots$	$\vdots$
r_n	$aktion_n$

- eine Aktion besteht aus C-Anweisungen

Beispiel 1 (Das erste Lex-Programm)

```
%%
a   printf("i");
e   printf("i");
o   printf("i");
u   printf("i");
```

2.2.1 Reguläre Ausdrücke

Einfache Zeichen und Metazeichen

- Alphabet Σ ist der Zeichensatz des Systems
- Einige Zeichen haben besondere Bedeutung in regulären Ausdrücken, die sog. *Metazeichen*

  `\ ^ $ . [ ] | ( ) * + ? { } " % < > /`
- Behandlung als normales Zeichen durch Voranstellen von "\" oder Einbinden in " "

Beispiel 2 (Erkennung von Metazeichen)

```
%%
\/\/    printf("Doppelslash");
"?"     printf("Fragezeichen");
```


Escape-Sequenzen und Spezialzeichen

Für einige Bestandteile eines Textes gibt es keine Zeichen.
Hierfür gibt es Ersatzdarstellungen:

`\b`	Backspace (Zurücksetzzeichen)
`\f`	Formfeed (Seitenvorschub)
`\n`	Newline (Zeilenvorschub)
`\t`	Tabulator
`\ddd`	Zeichen, das dem Oktalwert *ddd* entspricht
`^`	Anfang einer Zeile
`$`	Ende einer Zeile

Beispiel 3 (Erkennung von Leerzeilen)

```
%%
^\n     ;
```

Klassen von Zeichen

- Menge oder Bereich von Zeichen mit "[" und "]", z.B.

`[xyz]`	Eines der Zeichen x, y oder z
`[A-Z]`	Ein Großbuchstabe

- Beliebiges Zeichen mit "."

`.`	beliebiges Zeichen aus Σ (außer `\n`)

- Ausschluß von Zeichen mit "^", z.B.

`[^0-9]`	alle Zeichen außer Zahlen, $\Sigma \backslash \{0, ..., 9\}$

Operator "^" ist nur bei Mengen anwendbar.
Es gibt *keinen* Komplement Operator für einen regulären Ausdruck!

Zusammengesetzte reguläre Ausdrücke

Seien r, s reguläre Ausdrücke

`r|s`	r oder s (Vereinigung)
`rs`	r gefolgt von s (Konkatenation)
`r*`	beliebig oft r, auch keinmal
`(r)`	deckt r ab
`r+`	beliebig oft r, mindestens einmal
`r{n,m}`	zwischen n und m Vorkommen von r, $0 \leq n \leq m$
`r?`	ein- oder keinmal r

Priorität der Operatoren (aufsteigend):

```
|
{}
Konkatenation
* + ?
()
```

Beispiel 4 (C-Identifier)

```
%%
([a-zA-Z_])([a-z]|[A-Z]|_|[0-9])*
                    printf("Identifier\n");
```

Beispiel 5 (Ganze Zahlen)

```
%%
0|[+-]?[1-9][0-9]* printf("Ganze Zahl\n");
```


Kontextsensitivität

`r/s`	Es wird eine Zeichenkette erkannt, die von r akzeptiert wird, *und* zusätzlich eine Zeichenkette folgt, die von s akzeptiert wird.

Beispiel 6 (Klassifikation von C-Identifiern)

```
%%
([a-zA-Z_][a-zA-Z_0-9]*)/[ \t]*\[
                printf("Array\n");
([a-zA-Z_][a-zA-Z_0-9]*)/[ \t]*\(
                printf("Funktion/Makro\n");
([a-zA-Z_][a-zA-Z_0-9]*)
                printf("anderer\n");
.                                   ;
\n                                  ;
```

2.2.2 Aktionen

- Zur Erinnerung:

  r_1 $\quad$ $aktion_1$
  r_2 $\quad$ $aktion_2$
  $\vdots$ $\quad$ $\vdots$
  r_n $\quad$ $aktion_n$

- Eine Aktion besteht aus m C-Anweisungen, $m \geq 0$

  $m = 0$: *leere Aktion* ; bzw. {}

  $m = 1$: keine Klammerung nötig

  $m \geq 2$: Klammerung mit { ... }

- Paßt kein regulärer Ausdruck, wird eine *default-Aktion* ausgeführt; diese schreibt die gelesenen Zeichen unverändert auf stdout

- Ausführung derselben Aktion für mehrere reguläre Ausdrücke ist möglich durch Aktionszeichen "|"
  → Aktion des nächsten regulären Ausdrucks wird ausgeführt

Beispiel 7 (Entfernen von Whitespaces)

```
%%
" "     |
\t      |
\n      ;
```

2.2.3 Lex-interne Variablen, Makros und Funktionen

`yytext, yyleng`
char-Array `yytext` (mit Länge `yyleng`) enthält den aktuell gelesenen Eingabestring

Beispiel 8 (toLower)

```
%%
[A-Z]    printf("%c", yytext[0] + 32);
```

`yylineno`
enthält aktuelle Zeilennummer des Eingabetextes

`ECHO`
Makro, welches den Inhalt von `yytext` ausgibt

Die folgenden Funktionen bieten Lookahead-Möglichkeiten:

`yyless()`
Zurückschreiben von gelesenen Zeichen des Eingabetextes:
`yyless(n)`
es verbleiben n gelesene Zeichen in `yytext` ($\leftrightarrow$ $yyleng - n$ Zeichen werden zurückgeschrieben).

`input()`, `output()`, `unput()`
Verarbeitung einzelner Zeichen des Eingabetextes:

- `input()`
  liefert nächstes Zeichen des Eingabetextes
- `output(c)`
  gibt Zeichen c auf stdout aus
- `unput(c)`
  schiebt Zeichen c wieder zurück in den Eingabetext

`yywrap()`
Funktion, die beim Erreichen des Dateiendes der Eingabe aufgerufen wird.

- Kann vom Benutzer überschrieben werden
- Rückgabewert $\neq 0 \rightarrow$ Programm wird verlassen
- Rückgabewert $= 0 \rightarrow$ Programm arbeitet auf neuer Eingabe weiter

2.2.4 Zweideutige Regeln

Problem:
Mehrere reguläre Ausdrücke decken denselben Eingabestring bzw. Präfixe desselben Eingabestrings ab.

Lösung:

1. Es wird der reguläre Ausdruck ausgewählt, der den längsten Eingabestring abdeckt.
2. Gibt es mehrere reguläre Ausdrücke, die einen gleichlangen Eingabestring abdecken, so wird der erste ausgewählt.

2.3 Der Definitionsteil

Zur Erinnerung:

Definitionsteil
%%
Regelteil
%%
Benutzerdefinierte Routinen

Funktion des Definitionsteils:

- Einbinden von C-Code
- Spezifikation sog. *regulärer Definitionen* zur Vereinfachung regulärer Ausdrücke
- Definition von Startbedingungen

Einbinden von C-Code

- C-Code wird folgendermaßen eingebunden:

```
%{

  C-Anweisungen

%}
```

oder

```
␣C-Anweisung_1;


␣C-Anweisung_n;
```

- C-Anweisungen sind hier Präprozessor-Anweisungen und Variablen-Deklarationen
- Hilfsfunktionen werden im Teil *Benutzerdefinierte Routinen* eingebunden

Reguläre Definitionen

Reguläre Definitionen dienen der Vereinfachung von regulären Ausdrücken. Eine reguläre Definition ist eine Folge von Regeln der Form

$$\begin{array}{ll} Name_1 & r_1 \\ Name_2 & r_2 \\ \vdots & \vdots \\ Name_n & r_n \end{array}$$

wobei $Name_1, ..., Name_n$ paarweise verschiedene Bezeichner sind und jedes r_i ein regulärer Ausdruck über $\Sigma \cup \{Name_1\}, ..., \{Name_{i-1}\}$.

Beispiel 9 (C-Identifier, vereinfacht)

```
L   [a-z]|[A-Z]|_
D   [0-9]
%%
{L}({L}|{D})*
     printf("%s%s", "Identifier: ", yytext);
```


Startbedingungen

- Startbedingungen erlauben zustandsabhängige Aktivierung von regulären Ausdrücken
- Definition von Startbedingungen

  `%s name_1 name_2 ... name_n`
- Aktivierung eines Zustands im Aktionsteil eines regulären Ausdrucks mit

  `BEGIN name_i;`
- Der Normalzustand, in dem alle regulären Ausdrücke aktiv sind, ist `0`, d.h. mit

  `BEGIN 0;`

  wechselt man in den Normalzustand
- Kennzeichnung von zustandsabhängigen regulären Ausdrücken

  `<name_i>regAusdruck Aktion`

  bzw.

  `<name_i>,<name_j>regAusdruck Aktion`

Beispiel 10 (Entfernung von C-Kommentaren)

```
%s KOMMENTAR

%%
<KOMMENTAR>"*/"    BEGIN 0;
<KOMMENTAR>.       |
<KOMMENTAR>\n      ;
"/*"               BEGIN KOMMENTAR;
```


2.4 Benutzerdefinierte Routinen

Zur Erinnerung:

Definitionsteil
%%
Regelteil
%%
Benutzerdefinierte Routinen

Funktion des dritten Teils:

- Code wird unverändert nach `lex.yy.c` kopiert
- Einbinden von benutzerdefinierten Funktionen, die in den Aktionen benutzt werden können
- Einbinden des `main`-Programms oder der Funktion `yywrap()`

Beispiel 11 (LineCounter)

```
%{
int lineCounter = 0;
%}

%%
\n      lineCounter++;
.       ;

%%
yywrap(){
  printf("Number of Lines: %d\n",
 lineCounter);
  return 1;
}
```


3 Bedienung von lex

1. Erstellen des lex-Programms, z.B.

   `meinProg.lex`

2. Übersetzen des lex-Programms in C-File `lex.yy.c` mit

   ```
   lex meinProg.lex
   ```

3. Übersetzen von `lex.yy.c` (sowie Hinzulinken der lex-Bibliothek `libl.a`)
   (a) in eigenständiges Programm mit

   ```
   cc lex.yy.c -ll
   ```

   (b) zusammen mit eigenem Programm `meinProg.c`, welches die Funktion `yylex` aufruft, mit

   ```
   cc meinProg.c lex.yy.c -ll
   ```

4 Aufbau von `lex.yy.c`

1. Lex-interne Variablen-Deklarationen und Makro-Definitionen
2. C-Programmfragmente, die im Definitionsteil angegeben werden
3. Die Funktion `yylex`
   (a) Lesen des Eingabetextes
   (b) Erkennen des passenden regulären Ausdrucks und Verzweigung zum zugehörigen Aktionsteil
   (c) Ausführung des Aktionsteils
4. Benutzerdefinierte Routinen
5. Zustandstabellen, die von `lex` aus den regulären Ausdrücken generiert worden sind
6. Inhalt der Datei `ncform`; enthält im wesentlichen die Funktion `yylook()`, welche die Zustandstabellen durchläuft