

Разработка лексического анализатора

- Входной язык содержит операторы цикла **for (...; ...; ...) do ...**, разделённые символом **;** (точка с запятой). Операторы цикла содержат идентификаторы, знаки сравнения **<**, **>**, **=**, десятичные числа с плавающей точкой (в обычной и экспоненциальной форме), знак присваивания **(:=)**

```
for(abc1:=2.;abc1<11.0E+1;abc1:=abc1>.1)do _id:=_id=34e-5;
```

Lexeme table:

KEYWORD: for

DELIMITER: (

IDENTIFIER: abc1

OPERATION: :=

NUMBER: 2.

DELIMITER: ;

IDENTIFIER: abc1

OPERATION: <

NUMBER: 11.0E+1

DELIMITER: ;

IDENTIFIER: abc1

OPERATION: :=

IDENTIFIER: abc1

OPERATION: >

NUMBER: .1

DELIMITER:)

KEYWORD: do

IDENTIFIER: _id

OPERATION: :=

IDENTIFIER: _id

OPERATION: =

NUMBER: 34e-5

for(abc1:=. ;abc1<11.0E+1;abc1:=abc1>.1)do _id:=_id=34e-5;

Unknown character: .

Lexeme table:

KEYWORD: for

DELIMITER: (

IDENTIFIER: abc1

OPERATION: :=

DELIMITER: ;

IDENTIFIER: abc1

OPERATION: <

NUMBER: 11.0E+1

DELIMITER: ;

IDENTIFIER: abc1

OPERATION: :=

IDENTIFIER: abc1

OPERATION: >

NUMBER: .1

DELIMITER:)

KEYWORD: do

IDENTIFIER: _id

OPERATION: :=

IDENTIFIER: _id

OPERATION: =

NUMBER: 34e-5

for(ab%c1:=. ;abc1<.E+1;abc1:=abc1>1.1)do _id:=_id=34e-5;

Unknown character: %

Unknown character: .

Unknown character: .

Lexeme table:

KEYWORD: for

DELIMITER: (

IDENTIFIER: ab

IDENTIFIER: c1

OPERATION: :=

DELIMITER: ;

IDENTIFIER: abc1

OPERATION: <

IDENTIFIER: E

NUMBER: +1

DELIMITER: ;

IDENTIFIER: abc1

OPERATION: :=

IDENTIFIER: abc1

OPERATION: >

NUMBER: 1.1

DELIMITER:)

KEYWORD: do

IDENTIFIER: _id

OPERATION: :=

IDENTIFIER: _id

OPERATION: =

NUMBER: 34e-5

Состояния, действия

Состояния	
H	Начальное состояние
ID	Идентификаторы
NM	Числа
ASGN	Знак присваивания (:=)
DLM	Разделители (;, (,), =, >, <)
ERR	Нераспознанные символы
Действия	
fgetc	чтение символа из файла
is_kword	проверка, является ли идентификатор ключевым словом
is_num	проверка на правильность записи числа
add_token	добавление токена в таблицу лексем

Регулярные выражения

Идентификатор — это последовательность букв и цифр. Первым символом должна быть буква; знак подчеркивания (`_`) считается буквой. Буквы нижнего и верхнего регистров различаются.

$$(_ | a-zA-Z)(_ | a-zA-Z | 0-9)^*$$

Вещественная константа с плавающей точкой состоит из целой части, десятичной точки, дробной части, символа `e` или `E`, целого показателя степени с необязательным знаком и необязательного суффикса типа — одной из букв `f`, `F`, `l` или `L`. Целая и дробная части состоят из последовательностей цифр. Может отсутствовать либо целая, либо дробная часть (но не обе сразу). Тип определяется суффиксом: `F` или `f` обозначают тип `float`, `L` или `l` — тип `long double`. При отсутствии суффикса принимается тип `double`.

$$(-|+)?((0-9)^*(0-9)^+|(0-9)^+.(0-9)^+)(e|E)(-|+)?(0-9)^+(f|l|F|L)?$$

Диаграмма состояний



Диаграмма состояний




Диаграмма состояний




Диаграмма состояний




Диаграмма состояний





Диаграмма состояний



Программная реализация

```
#define NUM_OF_KEYWORDS 2

char *keywords[NUM_OF_KEYWORDS] = {"for", "do"};

enum states {H, ID, NM, ASGN, DLM, ERR};
enum tok_names {KEYWORD, IDENT, NUM, OPER, DELIM};

struct token
{
    enum tok_names token_name;
    char *token_value;
};

struct lexeme_table
{
    struct token tok;
    struct lexeme_table *next;
};

struct lexeme_table *lt = NULL;

int lexer(char *filename);
int is_keyword(char *id);
int add_token(struct token *tok);
```

Программная реализация (продолжение)

```
int lexer(char *filename)
{
    FILE *fd;
    int c, err_symbol;
    struct token tok;

    if((fd = fopen(filename, "r")) == NULL)
    {
        printf("\nCannot open file %s.\n", filename);
        return -1;
    }

    enum states CS = H;
    c = fgetc(fd);
```

Программная реализация (продолжение)

```
while(!feof(fd)){
    switch(CS){
        case H:
        {
            while((c == ' ') || (c == '\t') || (c == '\n')){
                c = fgetc(fd);
            }
            if(((c >= 'A') && (c <= 'Z')) || ((c >= 'a') && (c <= 'z')) ||
                (c == '_')){
                CS = ID;
            }else if(((c >= '0') && (c <= '9')) || (c == '.') || (c == '+') ||
                (c == '-')){
                CS = NM;
            }else if(c == ':'){
                CS = ASGN;
            }else{
                CS = DLM;
            }
            break;
        } // case H
    }
}
```

Программная реализация (продолжение)

```
case ASGN:
{
    int colon = c;
    c = fgetc(fd);
    if(c == '='){
        tok.token_name = OPER;
        if((tok.token_value =(char *)malloc(sizeof(2))) == NULL){
            printf("\nMemory allocation error in function \"lexer\"\n");
            return -1;
        }
        strcpy(tok.token_value, " :=");
        add_token(&tok);
        c = fgetc(fd);
        CS = H;
    }else{
        err_symbol = colon;
        CS = ERR;
    }
    break;
} // case ASGN
```

Программная реализация (продолжение)

```
case DLM:
{
    if((c == '(') || (c == ')') || (c == ';')){
        tok.token_name = DELIM;
        if((tok.token_value = (char *)malloc(sizeof(1))) == NULL){
            printf("\nMemory allocation error in function \"lexer\"\n");
            return -1;
        }
        sprintf(tok.token_value, "%c", c);
        add_token(&tok);
        c = fgetc(fd);
        CS = H;
    }else if((c == '<') || (c == '>') || (c == '=')){
        tok.token_name = OPER;
        if((tok.token_value = (char *)malloc(sizeof(1))) == NULL){
            printf("\nMemory allocation error in function \"lexer\"\n");
            return -1;
        }
    }
}
```

Программная реализация (продолжение)

```
        sprintf(tok.token_value, "%c", c);
        add_token(&tok);
        c = fgetc(fd);
        CS = H;
    }else{
        err_symbol = c;
        c = fgetc(fd);
        CS = ERR;
    }// if((c == '(') || (c == ')') || (c == ';'))
        break;
}// case DLM
case ERR:
{
    printf("\nUnknown character: %c\n", err_symbol);
    CS = H;
    break;
}
```

Программная реализация (продолжение)

```
case ID:
{
    int size = 0;
    char buf[256];
    buf[size] = c;
    size++;
    c = fgetc(fd);
    while(((c >= 'A') && (c <= 'Z')) || ((c >= 'a') && (c <= 'z')) ||
           ((c >= '0') && (c <= '9')) || (c == '_')){
        buf[size] = c;
        size++;
        c = fgetc(fd);
    }
    buf[size] = '\0';
    if(is_keyword(buf)){
        tok.token_name = KWWORD;
    }else{
        tok.token_name = IDENT;
    }
}
```

Программная реализация (продолжение)

```
    if((tok.token_value = (char *)malloc(strlen(buf))) == NULL){  
        printf("\nMemory allocation error in function \"lexer\"\n");  
        return -1;  
    }  
    strcpy(tok.token_value, buf);  
    add_token(&tok);  
    CS = H;  
    break;  
} // case ID
```

Программная реализация (продолжение)

```
case NM:
```

```
{
```



```
}
```

Генератор лексических анализаторов

Генераторы лексических анализаторов

- **lex** — стандартный генератор в Unix
- **Flex** — альтернативный вариант классической утилиты lex (<https://github.com/westes/flex>, <http://gnuwin32.sourceforge.net/packages/flex.htm>)
- **Quex** — генератор лексических анализаторов для C/C++ (<http://quex.sourceforge.net/>)
- **RE2C** — генератор лексических анализаторов для C/C++ (<http://re2c.org/>)
- **JFLex** — генератор на Java (<http://jflex.de/>)
- **Oolex** — объектно-ориентированный генератор анализаторов на Java (<http://luna2.informatik.uni-osnabrueck.de/alumni/bernd/oolex/index.html>)
- **Lex под Windows** (<http://www.bumblebeessoftware.com/>)
- **alex** — генератор лексических анализаторов для Haskell (<http://www.haskell.org/alex/>)
- **leex** — генератор для Erlang (<http://www.erlang.org/doc/man/leex.html>)
- **FLEX/EIFFEL** — версия генератора лексических анализаторов для языка Eiffel (<http://efsa.sourceforge.net/archive/kalberer/flex.htm>)


Генератор лексических анализаторов (Lex / Flex)

- 1975 – М. Леск (Mike Lesk) и Э. Шмидт (Eric Schmidt) разработали lex, генератор лексических анализаторов
- 1987 – В. Пакссон (Vern Paxson) переписал версию lex, написанную на ratfor (расширение Фортрана), на Си и назвал ее flex (Fast Lexical Analyzer Generator)
- Сейчас Flex – <https://github.com/westes/flex>


Генератор лексических анализаторов (Lex / Flex)

1. Levine J.R. Flex & bison. – O'Reilly Media, Inc., 2009. – 274 p.
Режим доступа: http://web.iitd.ac.in/~sumeet/flex_bison.pdf
2. Niemann T. A Compact Guide To Lex & Yacc. Режим доступа:
<http://epaperpress.com/lexandyacc/download/LexAndYaccTutorial.pdf>
3. Hubert B. Lex и YACC в примерах. Режим доступа: <http://rus-linux.net/lib.php?name=/MyLDP/algol/lex-yacc-howto.html>
4. Lesk M.E., Schmidt E. (July 21, 1975). Lex – A Lexical Analyzer Generator // UNIX TIME-SHARING SYSTEM:UNIX PROGRAMMER'S MANUAL, Seventh Edition, Volume 2B. bell-labs.com. Режим доступа:
<http://epaperpress.com/lexandyacc/download/lex.pdf>

Генератор лексических анализаторов (Lex / Flex)




Структура программы на языке Flex



Как работает Flex

`letter(letter|digit)*`



Метасимволы, используемые в Flex

.	Любой символ, кроме \n
\n	Новая строка
*	Повторение 0 или более раз
+	Повторение 1 или более раз
?	Повторение 0 или 1 раз
^	Соответствует началу строки, если указан в начале регулярного выражения. В квадратных скобках соответствует исключению символа из диапазона
\$	Конец строки
a b	a или b
(ab)+	Группировка (повторение последовательности ab 1 или более раз)
"a+b"	Строка a+b
[]	Класс (диапазон) символов
{ }	A{1,3} соответствует повторению буквы A от одного до трех раз 0{5} соответствует 00000 {reg_def} – обращение к регулярному определению

Примеры

<code>abc</code>	<code>abc</code>
<code>abc*</code>	<code>ab abc abcc abccc ...</code>
<code>abc+</code>	<code>abc abcc abccc ...</code>
<code>a(bc)+</code>	<code>abc abcbcb abcbcbcb ...</code>
<code>a(bc)?</code>	<code>a abc</code>
<code>[abc]</code>	<code>a или b или c</code>
<code>[a-z]</code>	<code>любая буква в диапазоне от a до z</code>
<code>[a\ -z]</code>	<code>a или - или z</code>
<code>[-az]</code>	<code>- или a или z</code>
<code>[A-Za-z0-9]+</code>	<code>любая буква или цифра, повторенная 1 или более раз</code>
<code>[\t\n]+</code>	<code>один или несколько пробелов, знаков табуляции или перехода на новую строку</code>
<code>[^ab]</code>	<code>кроме a и b</code>
<code>[a^b]</code>	<code>a или ^ или b</code>
<code>[a b]</code>	<code>a или или b</code>
<code>a b</code>	<code>a или b</code>

Самый короткий файл на языке Flex

%%

Пример

%%

.

\n

Пример

```
%%  
. ECHO;  
\n ECHO;  
%%  
int main(void)  
{  
    yylex();  
    return 0;  
}
```

Вывод данных

```
.      ECHO;
```

```
#define ECHO fwrite( yytext, yyleng, 1, yyout )
```

```
%option nodefault
```

Функции, макросы, predefined переменные в Flex

<code>int yylex(void)</code>	вызов лексического анализатора, возвращает токен
<code>char *yytext</code>	распознанная строка
<code>yylen</code>	длина распознанной строки
<code>yyval</code>	значение, ассоциирующееся с токеном
<code>FILE *yyout</code>	выходной файл (по умолчанию stdout)
<code>FILE *yyin</code>	входной файл (по умолчанию stdin)
<code>ECHO</code>	вывод распознанной строки в yyout

Правила выбора лексем в Lex

1. Предпочтение всегда отдается более длинному префиксу
2. Если наибольший возможный префикс соответствует двум и более шаблонам, предпочтение отдается шаблону, указанному в программе первым

```
"+"      { return ADD; }  
"="      { return ASSIGN; }  
"+="    { return ASSIGNADD; }
```

```
"if"     { return KEYWORDIF; }  
"else"   { return KEYWORDEELSE; }  
[a-zA-Z_][a-zA-Z0-9_]* { return IDENTIFIER; }
```

Начальные состояния

- *Начальные состояния* позволяют контролировать, когда и какие шаблоны можно использовать
- INITIAL – начальное состояние, которое всегда присутствует в программе Flex
- BEGIN – макрос, позволяющий переключаться между состояниями
- *Исключающие* начальные состояния (%x)
- *Включающие* начальные состояния (%s)

Разработка лексического анализатора с помощью Flex

- Входной язык содержит операторы цикла **for (...; ...; ...) do ...**, разделённые символом **;** (точка с запятой). Операторы цикла содержат идентификаторы, знаки сравнения **<**, **>**, **=**, десятичные числа с плавающей точкой (в обычной и экспоненциальной форме), знак присваивания (**:=**)

Регулярные выражения

Идентификатор — это последовательность букв и цифр. Первым символом должна быть буква; знак подчеркивания (`_`) считается буквой. Буквы нижнего и верхнего регистров различаются.

$$(_ | a-zA-Z)(_ | a-zA-Z | 0-9)^*$$

Вещественная константа с плавающей точкой состоит из целой части, десятичной точки, дробной части, символа `e` или `E`, целого показателя степени с необязательным знаком и необязательного суффикса типа — одной из букв `f`, `F`, `l` или `L`. Целая и дробная части состоят из последовательностей цифр. Может отсутствовать либо целая, либо дробная часть (но не обе сразу). Тип определяется суффиксом: `F` или `f` обозначают тип `float`, `L` или `l` — тип `long double`. При отсутствии суффикса принимается тип `double`.

$$(- | +)^?((0-9)^*.(0-9)^+ | (0-9)^+.(0-9)^+)(e | E)(- | +)^?(0-9)^+(f | l | F | L)^?$$

Текст программы на Flex

```
%option yylineno
%{
#include <stdio.h>

int ch;
%}

digit[0-9]
letter[a-zA-Z]
delim[();]
oper[<>=]
ws[ \t\n]

%%
```

Текст программы на Flex (продолжение)

```
for { printf("KEYWORD (%d, %d): %s\n", yylineno, ch, yytext);  
    ch += yyleng;  
}  
do { printf("KEYWORD (%d, %d): %s\n", yylineno, ch, yytext);  
    ch += yyleng;  
}  
("_" | {letter})("_" | {letter} | {digit})* {  
    printf("IDENTIFIER (%d, %d): %s\n", yylineno, ch, yytext);  
    ch += yyleng;  
}  
[-+]?({digit}*\. {digit}+ | {digit}+\. | {digit}+)[eE][-+]?{digit}+[f1FL]? {  
    printf("NUMBER (%d, %d): %s\n", yylineno, ch, yytext);  
    ch += yyleng;  
}
```

Текст программы на Flex (продолжение)

```
{oper} { printf("OPERATION (%d, %d): %s\n", yylineno, ch, yytext);  
        ch += yyleng;  
        }  
":=" { printf("OPERATION (%d, %d): %s\n", yylineno, ch, yytext);  
      ch += yyleng;  
      }  
{delim} { printf("DELIMITER (%d, %d): %s\n", yylineno, ch, yytext);  
         ch += yyleng;  
         }  
{ws}+ {ch += yyleng; }  
. { printf("Unknown character (%d, %d): %s\n", yylineno, ch, yytext);  
   ch += yyleng;  
   }
```

%%

Текст программы на Flex (окончание)

```
int main(int argc, char **argv)
{
    if(argc < 2)
    {
        printf("\nNot enough arguments. Please specify filename.\n");
        return -1;
    }
    if((yyin = fopen(argv[1], "r")) == NULL)
    {
        printf("\nCannot open file %s.\n", argv[1]);
        return -1;
    }
    ch = 1;
    yylineno = 1;
    yylex();
    fclose(yyin);
    return 0;
}
```

```
for(abc1:=. ;abc1<11.0E+1;abc1:=abc1>.1)do abc1:=abc1=34E5;
```

```
$ ./scanner prog
```

```
KEYWORD (1, 1): for  
DELIMITER (1, 4): (  
IDENTIFIER (1, 5): abc1  
OPERATION (1, 9): :=  
Unknown character (1, 11): .  
DELIMITER (1, 12): ;  
IDENTIFIER (1, 13): abc1  
OPERATION (1, 17): <  
NUMBER (1, 18): 11.0E+1  
DELIMITER (1, 25): ;  
IDENTIFIER (1, 26): abc1  
OPERATION (1, 30): :=  
IDENTIFIER (1, 32): abc1  
OPERATION (1, 36): >  
NUMBER (1, 37): .1  
DELIMITER (1, 39): )  
KEYWORD (1, 40): do  
IDENTIFIER (1, 43): abc1  
OPERATION (1, 47): :=  
IDENTIFIER (1, 49): abc1  
OPERATION (1, 53): =  
NUMBER (1, 54): 34E5  
DELIMITER (1, 58): ;
```

Применение состояний в Flex

```
...
%X COMM

%%

...

"/*" { ch += yyleng; BEGIN COMM; }
<COMM>"/*" { ch += yyleng;
    printf("\"/*\" within comment" (%d, %d): %s\n", yylineno, ch, yytext);
    BEGIN INITIAL;
}
<COMM>.|\\n { ch += yyleng; continue; }
<COMM>"/*" { ch += yyleng; BEGIN INITIAL; }
<COMM><<EOF>> { ch += yyleng;
    printf("Unterminated comment (%d, %d): %s\n", yylineno, ch, yytext);
    BEGIN INITIAL;
}

...
```

```
/* this is a comment !!! */
```

```
for(abc1:=.;abc1<11.0E+1;abc1:=abc1>.1)do abc1:=abc1=34E5;
```

```
$ ./scanner prog
```

```
KEYWORD (2, 29): for
```

```
DELIMITER (2, 32): (
```

```
IDENTIFIER (2, 33): abc1
```

```
OPERATION (2, 37): :=
```

```
Unknown character (2, 39): .
```

```
DELIMITER (2, 40): ;
```

```
IDENTIFIER (2, 41): abc1
```

```
OPERATION (2, 45): <
```

```
NUMBER (2, 46): 11.0E+1
```

```
DELIMITER (2, 53): ;
```

```
IDENTIFIER (2, 54): abc1
```

```
OPERATION (2, 58): :=
```

```
IDENTIFIER (2, 60): abc1
```

```
OPERATION (2, 64): >
```

```
NUMBER (2, 65): .1
```

```
DELIMITER (2, 67): )
```

```
KEYWORD (2, 68): do
```

```
...
```

Многострочный комментарий

```
/* this is the 1st line of a comment  
   this is the 2nd line of a comment  
   this is the last line of a comment  
*/
```

```
for( );
```

```
$ ./scanner prog  
KEYWORD (6, 118): for  
DELIMITER (6, 121): (  
DELIMITER (6, 122): )  
DELIMITER (6, 123): ;
```

Многострочный комментарий

```
/* this is the 1st line of a comment  
   this is the 2nd line of a comment  
   this is the last line of a comment
```

```
for( );
```

```
$ ./scanner prog
```

```
Unterminated comment (7, 124):
```