Схема работы лексического анализатора

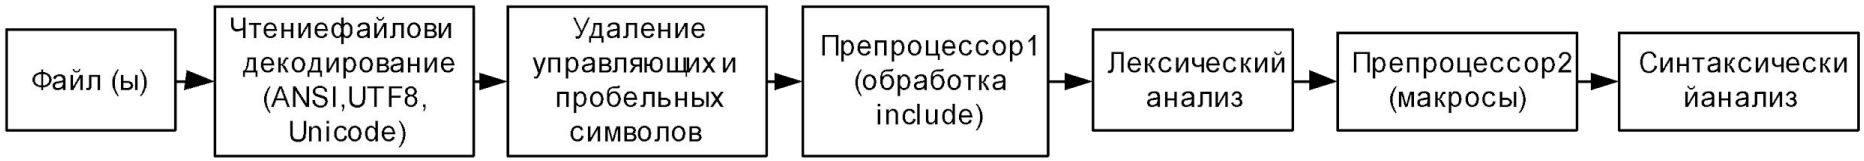

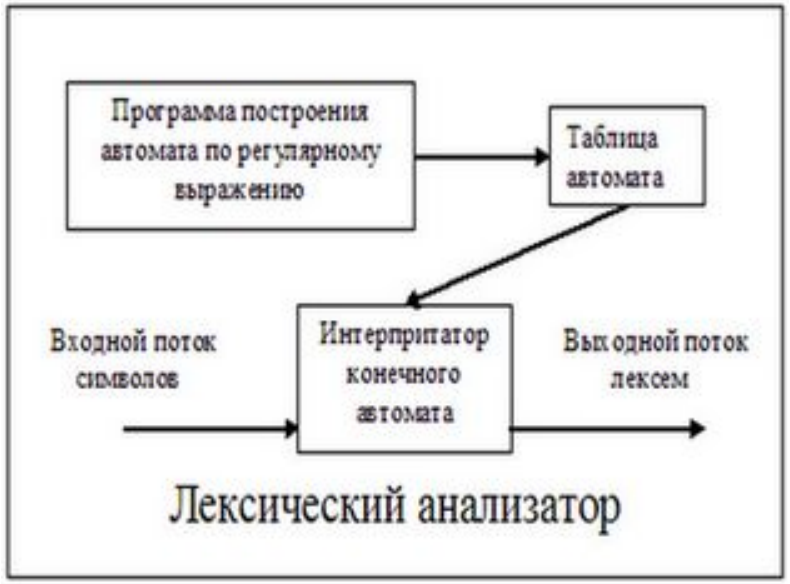

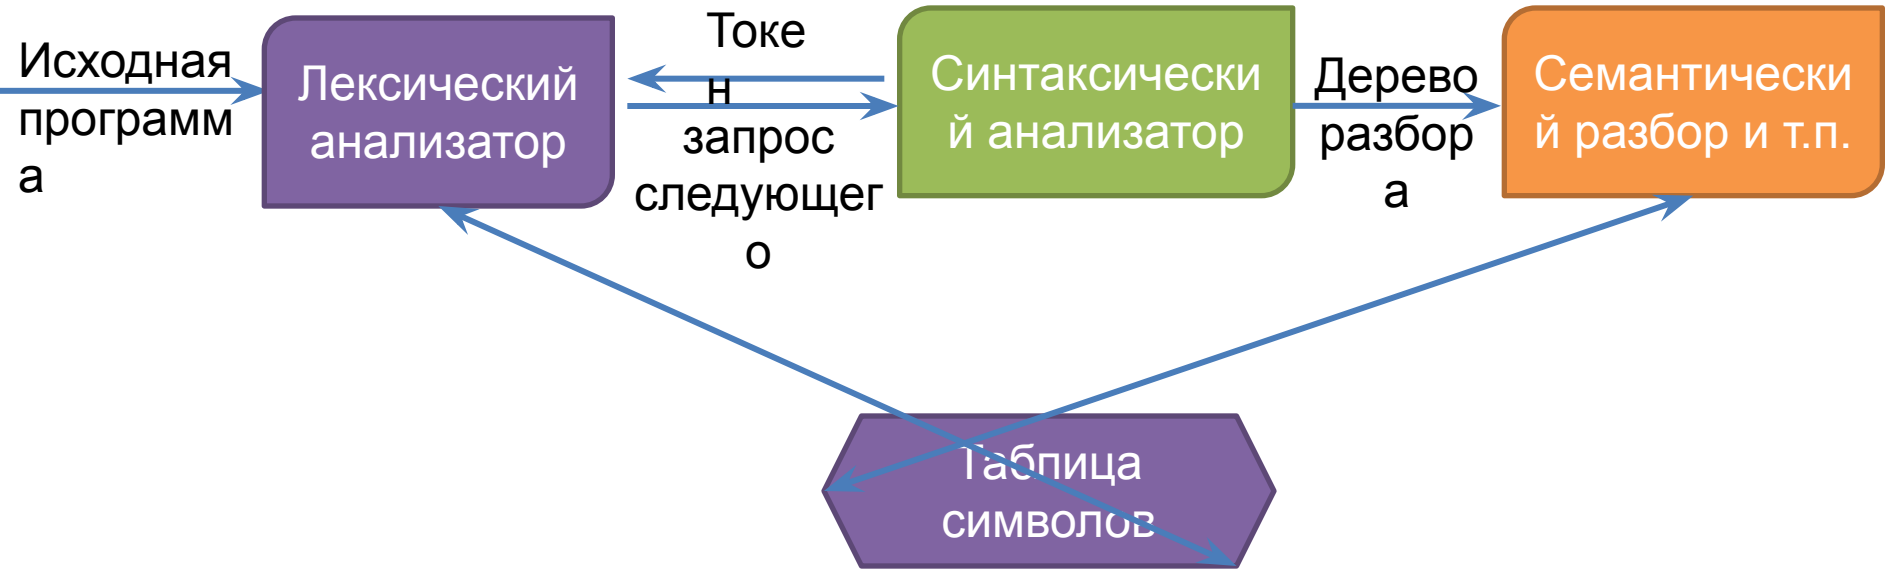
Исходная программа
Лексический анализатор
Токен
запрос следующего
Синтаксический анализатор
Дерево разбора
Семантический разбор и т.п.
Таблица символов

Токены, шаблоны, лексемы

Токен	Пример лексем	Неформальное описание шаблона
const	const	const
if	if	if
relation	<, <=, =, <>, >, >=	< или <= или = или о или > или >=
id	pi, count, D2	Буква, за которой следуют буквы и цифры
num	3.1416, 0, 6.02E23	Любая числовая константа
literal	"core dumped"	Любые символы между парными кавычками, исклю- исключая сами кавычки

Пример результирующего набора лексем

- 1. Лексема **id** («Идентификатор») с номером лексемы и таблицу с именами идентификаторов. Можно также считать, что выдаётся лексема **id** («Идентификатор») с атрибутом «Имя».
- 2. Лексема **ots** (операция типа сложения) и её подтип – атрибут (+, –, xor, or или иное).
- 3. Лексема **otm** (операция типа умножения) и её подтип – атрибут (*, /, and или иное).
- 4. Лексема **rel** (операция типа сравнения) и её подтип – атрибут (>, <, =, is, as или иное).
- 5. Лексема **lb** (левая скобка)
- 6. Лексема **rb** (правая скобка)
- 7. Лексема **sem** (точка с запятой)
- 8. Лексема **ass** (:=)
- 9. Различные ключевые слова:
  - Лексема **if**.
  - Лексема **then**.
  - Лексема **begin**.
  - …

Пример обработки входного потока

if distance >= speed * (endtime-starttime) **then**
distance := distance – delta;

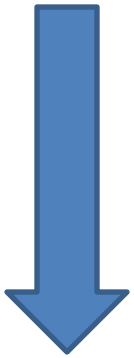

if id rel id otm lb id ots id rb then id ass id ots id sem

Простейший вариант конечного автомата

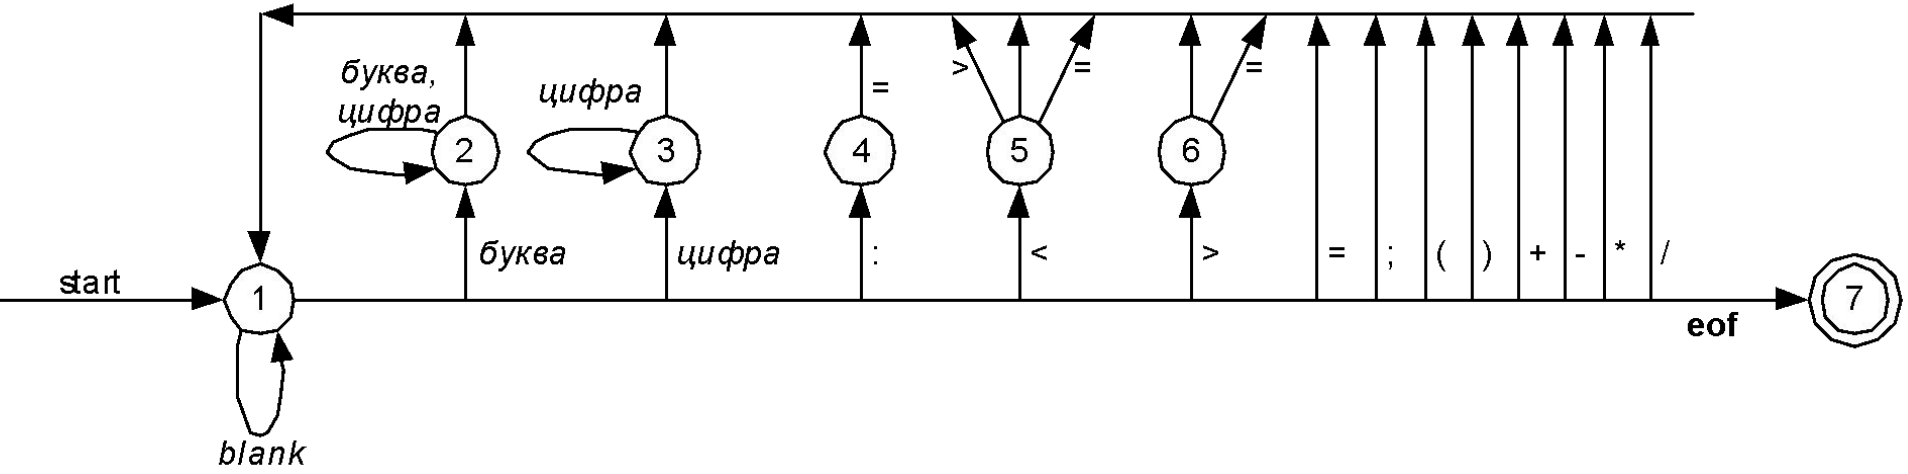

Атрибуты лексем

- Атрибуты – это способ хранения дополнительной информации о лексеме (например, конкретное значение константы, имя идентификатора и т.д.)

- Достаточно часто атрибуты представляют собой ссылки в специальные таблицы, например, таблицу представлений, таблицу идентификаторов и т.п.

Пример:

```
bool c; int a=1,b=2;
c = a>b>>2;
```

Последний оператор порождает следующую последовательность лексем и их атрибутов:

<Identifier_LC, указатель в таблицу на *c*>
<AssignOP_LC, >
<Identifier_LC, указатель в таблицу на *a*>
<GreaterThanOP_LC, >
<Identifier_LC, указатель в таблицу на *b*>
<RightShiftOP_LC, >
<Number_LC, указатель в таблицу на *2*>

Таблица представлений

Место хранения экземпляров (по одному) всех *внешних представлений* идентификаторов (и, возможно, также для всех констант). Позже идентификаторы заменяются на ссылку в эту таблицу – этот процесс называется *свертыванием.*

- Простейший вид таблицы представлений – массив указателей на строки
- Требуется возможность расширения и быстрого поиска
- Более распространая форма организации таблицы представлений – в виде набора хэшированных списков

Разработка лексера с Coco/R

- Coco/R использует метод рекурсивного спуска для анализа LL(1)-грамматик, т.е. грамматик, для которых можно по 1 следующему символу сразу понять, какое правило было применено для порождения цепочки.
- **Пример**. Не LL(1)-грамматика:

  Statement ::= Ident ‘:=’ Expression | Ident [‘(’ ExpressionList ‘)’]
- **Пример**. LL(1)-грамматика:

  Statement ::= Ident (‘:=’ Expression | [‘(’ ExpressionList ‘)’])
-
- Однако, используя некоторые дополнительные возможности, реально можно разбирать LL(k)-грамматики с k>1.
- В настоящее время есть версии Coco/R для **C**, **CPP**, **C#**, **Java**, **Pascal**, **Delphi**, **Modula-2**, **Oberon**, **Ada**, **Ruby**, **Unicon**.

Грамматика Pascal для Coco/R

```
COMPILER Pascal
IGNORE CASE

CHARACTERS
  eol     = CHR(13) .
  letter   = "ABCDEFGHIJKLMNOPQRSTUVWXYZabcdefghijklmnopqrstuvwxyz" .
  digit    = "0123456789".
  noQuote1 = ANY - "'" - eol .

IGNORE CHR(9) .. CHR(13)

COMMENTS FROM "(*" TO "*)"
COMMENTS FROM "{" TO "}"

TOKENS
  identifier  =  letter { letter | digit } .
  integer     =  digit { digit } | digit { digit }  CONTEXT ("..") .
  real        =  digit { digit } "." digit { digit }
                 [ "E" ["+" | "-"] digit { digit } ]
                 |  digit { digit } "E" ["+" | "-"] digit { digit }  .
  string      = "'" { noQuote1 | "''" } "'" .

PRODUCTIONS
…
```

Разработка лексера с lex/Flex

- Инструмент для создания лексически анализаторов – Lex, состоящий из Lex-языка и Lex-компилятора.

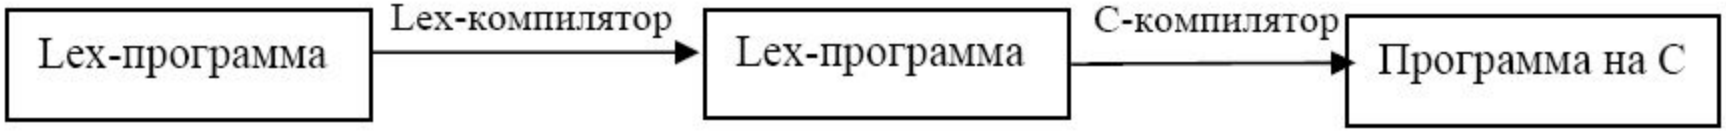

- Lex-программа состоит из трех частей: описаний, правил трансляции и процедур. Каждая часть отделяется от следующей строкой, содержащей два символа %%.

Грамматика Pascal для lex

```
%{
#include <stdio.h>
#include "y.tab.h"
int line_no = 1;
%}

A [aA]
B [bB]
C [cC]
D [dD]
E [eE]
F [fF]
G [gG]
H [hH]
I [iI]
J [jJ]
K [kK]
L [lL]
M [mM]
N [nN]
```

```
{A}{N}{D}   return(AND);
{A}{R}{R}{A}{Y}   return(ARRAY);
{C}{A}{S}{E}   return(CASE);
{C}{O}{N}{S}{T}   return(CONST);
{D}{I}{V}   return(DIV);
{D}{O}    return(DO);
{D}{O}{W}{N}{T}{O}  return(DOWNTO);
{E}{L}{S}{E}   return(ELSE);
{E}{N}{D}   return(END);
{E}{X}{T}{E}{R}{N} |
{E}{X}{T}{E}{R}{N}{A}{L} return(EXTERNAL);
{F}{O}{R}   return(FOR);
{F}{O}{R}{W}{A}{R}{D}  return(FORWARD);
{F}{U}{N}{C}{T}{I}{O}{N} return(FUNCTION);
{G}{O}{T}{O}   return(GOTO);
{I}{F}    return(IF);
{I}{N}    return(IN);
{L}{A}{B}{E}{L}   return(LABEL);
{M}{O}{D}   return(MOD);
{N}{I}{L}   return(NIL);
{N}{O}{T}   return(NOT);
{O}{F}    return(OF);
{O}{R}    return(OR);
{O}{T}{H}{E}{R}{W}{I}{S}{E} return(OTHERWISE);
```

```
":="    return(ASSIGNMENT);
'({NQUOTE}|'')+'  return(CHARACTER_STRING);
":"    return(COLON);
","    return(COMMA);
[0-9]+    return(DIGSEQ);
"."    return(DOT);
".."    return(DOTDOT);
"="    return(EQUAL);
">="    return(GE);
">"    return(GT);
"["    return(LBRAC);
"<="    return(LE);
"("    return(LPAREN);
"<"    return(LT);
"-"    return(MINUS);
"<>"    return(NOTEQUAL);
"+"    return(PLUS);
"]"    return(RBRAC);
[0-9]+"."[0-9]+   return(REALNUMBER);
")"    return(RPAREN);
";"    return(SEMICOLON);
"/"    return(SLASH);
"*"    return(STAR);
"**"    return(STARSTAR);
```

```
"(*"    |
"{"    { register int c;
     while ((c = input()))
     {
      if (c == '}')
       break;
      else if (c == '*')
      {
       if ((c = input()) == ')')
        break;
       else
        unput (c);
      }
      else if (c == '\n')
       line_no++;
      else if (c == 0)
       commenteof();
     }
    }

[ \t\f]    ;
```

Простейший лексический анализатор

```
while (1)
{ fix=i;
switch(s[i])
    {
case '"':       // Распознавание строковой
     константы ". . ." с двойными ""
     внутри
mmm: i++; while (s[i] !='"') i++;
    i++; if (s[i]=='"') goto mmm;
    lexem(1); break;
case '/': i++;    // Распознавание / и /*
    if (s[i]!='*')
        { lexem(14); break; }
// Распознавание комментария /* ... */
n1: while (s[i] !='*') i++;
    i++; if (s[i]=='/')
        { i++; lexem(2); break; }
    goto n1;
case '+': i++;
 // Распознавание += и +
    if (s[i]=='=')
        { i++; lexem(5); }
    else lexem(15);
    break;
case '<': i++;
 // Распознавание << и <
    if (s[i]=='<')
        { i++; lexem(6); }
    else lexem(16); break;
default: if (isalpha(s[i]))
 / / Распознавание идентификатора
        { i++; while (isalpha(s[i])) i++;
        lexem(11); break; }
if (isdigit(s[i]))
// Распознавание константы
        { i++; while (isdigit(s[i])) i++;
        lexem(12); break; }
```

Подсчет числа слов и строк в файле

```
/***************** Раздел определений ********************/
NODELIM [^" "\t\n]
/* NODELIM означает любой символ, кроме разделителей слов */
int l, w, c; /* Число строк, слов, символов */
%% /******************** Раздел правил ***********************/
{ l=w=c=0; /* Инициализация */ }
{NODELIM}+ { w++; c+=yyleng; /* Слово */ }
\n { l++; /* Перевод строки */ }
. { c++; /* Остальные символы */ }
%% /******************* Раздел программ ***********************/
int main()
{ yylex(); }
yywrap()
{
printf( " Lines - %d Words - %d Chars - %d\n", l, w, c );
return( 1 );
}
```

Специальные конструкции и функции Lex

yytext – указатель на отождествленную цепочку символов, оканчивающуюся нулем;

yyleng – длина этой цепочки

yyless(n) – вернуть последние n символов цепочки обратно во входной поток;

yymore() – считать следующие символы в буфер yytext после текущей цепочки

yyunput(c) – поместить байт c во входной поток

ECHO – копировать текущую цепочку в yyout

yylval – еще одно возвращаемое значение

Заглядывание вперед при лексическом анализе

- В некоторых случаях может потребоваться заглядывание вперед для точного определения текущей лексемы
- Для этого используется выражение A/B, которое выдает лексический класс A только втом случае, если за ним следует B
- DO 5 I=1,25
- *DO/ ({letter} | {digit})* = ({letter} | {digit})*,*