

## 5.2. СКАНЕР

Сканер как составная часть языкового процессора стоит на первой фазе обработки исходного текста. Функциональным назначением сканера является *лексическая свертка* исходного текста программы в символы, идентифицируемые в дальнейшем как ключевые слова, числовые константы, встроенные функции и так далее. Кроме того, на этапе лексического анализа происходит так называемая фильтрация незначащей части текста.

*Незначащей частью текста* будем называть вспомогательные символы, которые не являются носителями смыслового содержания текста. Такими символами являются символы табуляции '\t', символы перевода на новую строку '\n', пробелы ' ', комментарии и другие. Эти символы используются только при редактировании исходного текста, когда необходимо соблюдать определенное форматирование текста и повысить читабельность.

На рис 5.5 показана схема потоков при фильтрации исходного текста.




Рис. 5.5. Схема потоков сканера при фильтрации

Реализация процедуры фильтрации (очистки от *мусора* [13]) осуществляется с помощью стандартных функций `getchar( )` и `ungetc( )` из встроенной стандартной библиотеки `<stdio.h>`. Ниже (рис. 5.6) приведена функция `clear( )`, которая очищает текст от символов табуляции, переводов строки и пробелов и возвращает отфильтрованный текст во входной поток.

```

#include <stdio.h>
int clear ( )
{
  int liter;
  while (1) /* цикл по всему входному потоку символов*/
  {
    liter = getchar ( );
    if ( liter == ' ' || liter == '\n' || liter == '\t' )
      then ungetc (liter, stdio);
  }
}
  
```

Рис. 5.6. Фильтрация

Часто в процессорах функцию сканера заменяет синтаксический анализатор, при этом нет необходимости в специальном просмотре исходного текста, который осуществляется на этапе синтаксического анализа. В отличие от синтаксического анализатора сканер определяет лишь принадлежность символов алфавиту языка и не устанавливает принадлежность языковых конструкций к грамматике.

Проиллюстрируем разработку сканера, используя грамматику арифметических выражений  $G[<AB>]$

$$\begin{aligned} <AB> \rightarrow T \mid <AB> + T \mid <AB> - T \\ T &\rightarrow O \mid O * T \mid O / T \\ O &\rightarrow (<AB>) \mid <Идентификатор> \mid <ЦБЗ> \\ <Идентификатор> &\rightarrow B \{B|C\} \\ <Целое без знака> &\rightarrow Ц \{Ц\}, \end{aligned}$$

где  $B - [A, B, C, \dots, Z]$ ;  $Ц - [0, 1, \dots, 9]$ ;  $<ЦБЗ> - <Целое без знака>$ .  
 Функцией сканера на этом примере является внутреннее представление символов арифметического выражения, под которым будем понимать символический (условный) код. Этим кодом характеризуются идентификаторы, числовые константы и другие объекты языка. Для рассматриваемого примера арифметических выражений примем следующие соглашения относительно лексем:

Символ	<ЦБЗ>	<идент-р>	+	-	/	*	( )
Условный код	1	2	3	4	5	6	7 8

На рис. 5.7 приведена диаграмма состояний для грамматики  $G[<AB>]$ . На диаграмме представлена посимвольная декомпозиция арифметических выражений с генерацией соответствующего символического кода символов <идентификатор>, <целое без знака> и литер «+», «-» и др. Непомеченные дуги на диаграмме соответствуют состоянию ERROR (отсутствие данного символа в словаре грамматики) либо выходу из обработки очередного символа и переходу на start для обработки следующего терминального символа.




Рис. 5.7. Диаграмма состояний сканера

### Пример

Пусть строка с арифметическим выражением имеет вид:

$$A1 * A2 \#.$$

Перемещение по узлам графа для данного примера:

0 – 2 – 2 – OUT – START – 6 – OUT – START – 2 – 2 – OUT

### СЕМАНТИКА СКАНЕРА

На семантической диаграмме «навешаны» семантические атрибуты: SC – сканирование очередного символа, Cod – адресная генерация кода соответствующего символа.

Реализацию сканера по диаграмме состояний или по графу на рис. 5.6 приведем на языке C. Отметим, что данная реализация универсальна для графов, в которых переходы соответствуют терминальному символу из узла в узел либо по петле. Поэтому программа для графа <числовая константа> (см. рис. 5.3) мало чем будет отличаться от приведенной ниже.