第3章　词法分析

LI Wensheng, SCS, BUPT

基础知识：PASCAL、C语言、正规表达式
正规文法、有限自动机

知识点：词法分析器的作用、地位
记号、模式
词法分析器的状态转换图

词法分析

简介

3.1 词法分析程序与语法分析程序的关系

3.2 词法分析程序的输入与输出

3.3 记号的描述和识别

3.4 词法分析程序的设计与实现

3.5 软件工具LEX

小结

简介

- 任务：把构成源程序的字符串转换成语义上关联的记号序列
- 编译程序是在单词的级别上来分析和翻译源程序，因此，词法分析是编译的基础
- 本章内容安排

讨论手工设计并实现词法分析程序的方法和步骤

- 词法分析程序的作用
- 词法分析程序的地位
- 源程序的输入与词法分析程序的输出
- 单词符号的描述及识别
- 词法分析程序的设计与实现

词法分析程序自动生成工具LEX简介

词法分析程序的作用

- 源程序由单词组成，单词是最小的语义单位
- 词法分析程序的作用：

  扫描源程序字符流

  按照源语言的词法规则识别出各类单词符号

  产生用于语法分析的记号序列

  词法检查

  创建符号表(需要的话)

    把识别出来的标识符插入符号表中

  与用户接口的一些任务：

    - 跳过源程序中的注释和空白
    - 把错误信息和源程序联系起来

3.1 词法分析程序与语法分析程序的关系

- 词法分析程序与语法分析程序之间的三种关系
  - 词法分析程序作为独立的一遍
  - 词法分析程序作为语法分析程序的子程序
  - 词法分析程序与语法分析程序作为协同程序
- 分离词法分析程序的好处
- 词法分析的一些难点

词法分析程序作为独立的一遍

- 输出放入一个中间文件

  磁盘文件
  内存文件

词法分析程序作为语法分析程序的子程序

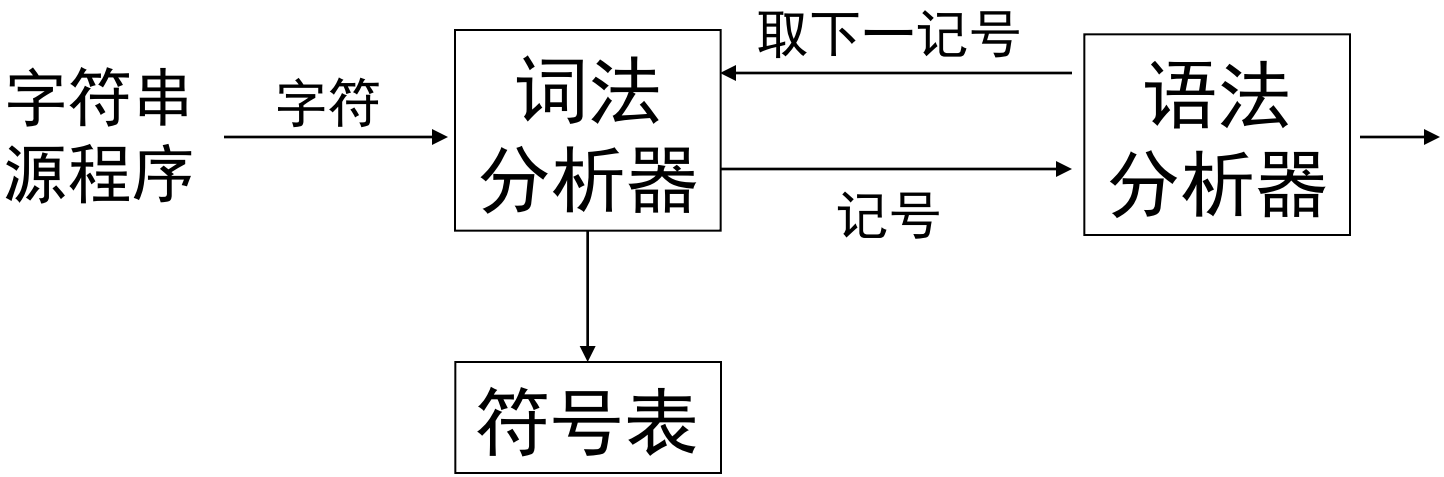

- 避免了中间文件
- 省去了取送符号的工作
- 有利于提高编译程序的效率

词法分析程序与语法分析程序作为协同程序

- 协同程序：

  如果两个或两个以上的程序，它们之间交叉地执行，这些程序称为协同程序。

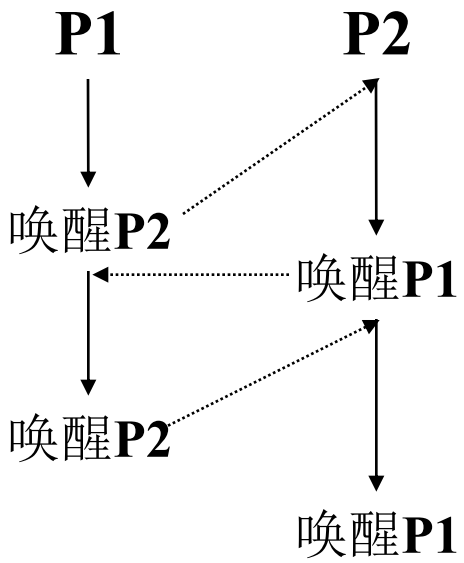

词法分析程序与语法分析程序在同一遍中，以生产者和消费者的关系同步运行。

分离词法分析程序的好处

- 可以简化设计
  - 词法程序很容易识别并去除空格、注释，使语法分析程序致力于语法分析，结构清晰，易于实现。
- 可以改进编译程序的效率
  - 利用专门的读字符和处理记号的技术构造更有效的词法分析程序。
- 可以加强编译程序的可移植性
  - 在词法分析程序中处理特殊的或非标准的符号。

词法分析的一些难点

- 位置对准

  Fortran要求某些结构出现在输入行的固定位置

- 空白不作为分隔符

  Fortran中空格是无意义的，可以随便加入

  DO 5 I = 1.25　　（赋值语句，DO5I是标识符）

  DO 5 I = 1,25　　（循环语句，DO是关键字）

- 关键字不保留

  PL/I语言的关键字不保留

  IF THEN THEN THEN=ELSE; ELSE ELSE=THEN

3.2 词法分析程序的输入与输出

一、词法分析程序的实现方法

二、设置缓冲区的必要性

三、配对缓冲区

四、词法分析程序的输出

一、词法分析程序的实现方法

- 利用词法分析程序自动生成器
  - 从基于正规表达式的规范说明自动生成词法分析程序。
  - 生成器提供用于源程序字符流读入和缓冲的若干子程序
- 利用传统的系统程序设计语言来编写
  - 利用该语言所具有的输入/输出能力来处理读入操作
- 利用汇编语言来编写
  - 直接管理源程序字符流的读入

二、设置缓冲区的必要性

- 超前搜索：为了得到某一个单词符号的确切性质，需要超前扫描若干个字符。

  例：有合法的FORTRAN语句：

  DO99K=1,10　　和　　DO99K=1.10

  为了区别这两个语句，必须超前扫描到等号后的第一个分界符处。

  例：Pascal语言中： do99、 <>、 :=、 (*

  例：C语言中：==、/*、//、++ 、for_loop

- 方便实现读字符和退字符操作，提高词法分析器的效率

三、配对缓冲区

- 原因：不论缓冲器多大都不能保证单词不被它的边界打断
- 把一个缓冲器分为相同的两半，每半各含N个字符，一般N=1KB或4KB。

- 基本方法

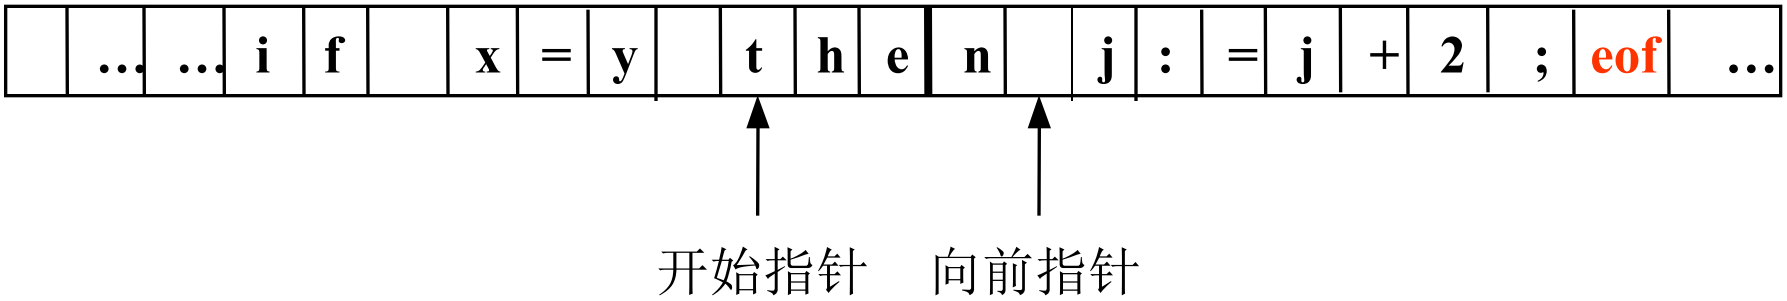

测试指针的过程(1)

```
IF (向前指针在左半区的终点) {
    读入字符串，填充右半区;
    向前指针前移一个位置;
    }
ELSE IF (向前指针在右半区的终点){
            读入字符串，填充左半区;
            向前指针移到缓冲区的开始位置;
        }
        ELSE 向前指针前移一个位置;
```

每半区带有结束标记的缓冲器

- 基本方法的缺点：

  更新向前指针时要做二次测试

- 改进：每半区带有结束标记的缓冲器

  更新向前指针时只要做一次测试

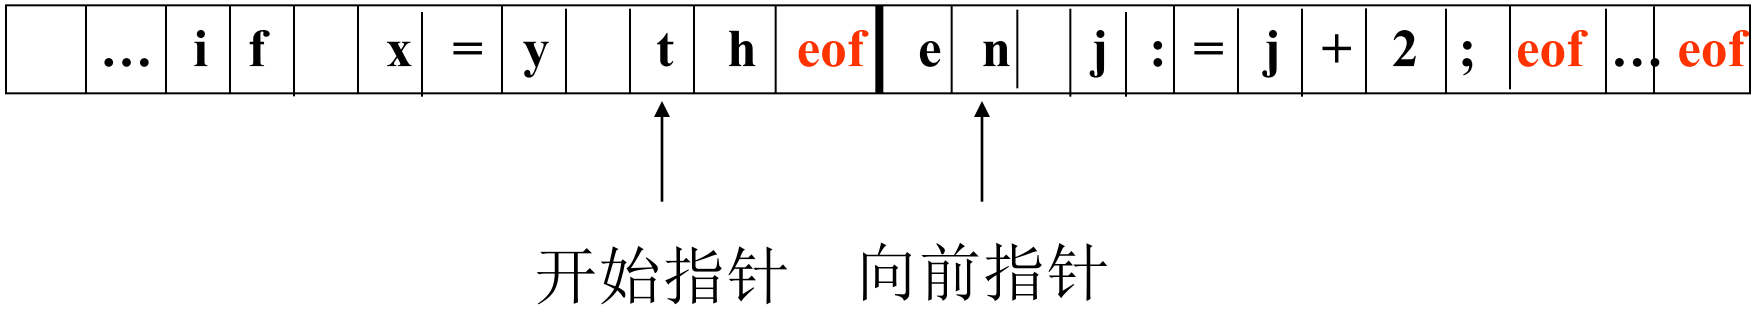

测试指针的过程(2)

```
向前指针前移一个位置;
IF (向前指针指向 eof ) {
    IF (向前指针在左半区的终点) {
        读入字符串，填充右半区;
        向前指针前移一个位置;
    };
    ELSE IF (向前指针在右半区的终点) {
        读入字符串，填充左半区;
        向前指针指向缓冲区的开始位置;
    };
    ELSE 终止词法分析;
}
```

四、词法分析程序的输出——记号

- 记号、模式和单词
  - 记号：是指某一类单词符号的种别编码，如标识符的记号为**id**，数的记号为**num**等。 机内表示
  - 模式：是指某一类单词符号的构词规则，如标识符的模式是"由字母开头的字母数字串"。 构词规则
  - 单词：是指某一类单词符号的一个特例，如**position**是标识符。 外部表示

- 记号的种类

1.关键字　2.标识符　3.常数　4.运算符　5.分界符

记号的属性

- 词法分析程序在识别出一个记号后，要把与之有关的信息作为它的属性保留下来。
- 记号影响语法分析的决策，属性影响记号的翻译。
- 在词法分析阶段，对记号只能确定一种属性
  - 标识符：单词在符号表中入口的指针
  - 常数：它所表示的值
  - 关键字：（一符一种、或一类一种）
  - 运算符：（一符一种、或一类一种）
  - 分界符：（一符一种、或一类一种）
- 记号的属性是指记号的特征或特性，反映特征或特性的值是属性值
- 一种一符则种别值可以认为是属性值，一种多符则需给出属性值

total:=total+rate*4 的词法分析结果

<id，指向标识符total在符号表中的入口的指针>

<assign_op，- >

<id，指向标识符total在符号表中的入口的指针>

<plus_op，- >

<id，指向标识符rate在符号表中的入口的指针>

<mul_op，- >

<num，整数值4>

3.3 记号的描述和识别

- 识别单词是按照记号的模式进行的，一种记号的模式匹配一类单词的集合。
  - 为设计词法程序，对模式要给出规范、系统的描述。
- 正规表达式和正规文法是描述模式的重要工具。
  - 二者具有同等表达能力
  - 正规表达式：清晰、简洁
  - 正规文法：便于识别

一、词法与正规文法
二、记号的文法
三、状态转换图与记号的识别

一、词法与正规文法

- 把源语言的文法G分解为若干子文法：

G_0、 G_1、G_2、…、G_n

语法　　词法

- 词法：描述语言的标识符、常数、运算符和标点符号等记号的文法 —— 正规文法
- 语法：借助于记号来描述语言的结构的文法 —— 上下文无关文法

二、记号的文法

- 标识符
- 常数
  - 整数
  - 无符号数
- 运算符
- 分界符
- 关键字

标识符

- 假设标识符定义为“由字母打头的、由字母或数字组成的符号串”

- 描述标识符集合的正规表达式：

  letter(letter|digit)*

- 表示标识符集合的正规定义式：

  letter → **A|B|...|Z|a|b|...|z**

  digit → **0|1|...|9**

  id → letter**(**letter|digit**)***

把正规定义式转换为相应的正规文法

$$
\begin{aligned}
&(\ \text{letter} \mid \text{digit}\ )^{*} \\
&= \varepsilon \mid (\ \text{letter} \mid \text{digit}\ )^{+} \\
&= \varepsilon \mid (\ \text{letter} \mid \text{digit}\ )\,(\ \text{letter} \mid \text{digit}\ )^{*} \\
&= \varepsilon \mid \text{letter}\,(\ \text{letter} \mid \text{digit}\ )^{*} \mid \text{digit}\,(\ \text{letter} \mid \text{digit}\ )^{*} \\
&= \varepsilon \mid (\text{A}|\ldots|\text{Z}|\text{a}|\ldots|\text{z})\,(\ \text{letter} \mid \text{digit}\ )^{*} \\
&\quad \mid (0|\ldots|9)(\ \text{letter} \mid \text{digit}\ )^{*} \\
&= \varepsilon \mid \text{A}\,(\ \text{letter} \mid \text{digit}\ )^{*} \mid \ldots \mid \text{Z}\,(\ \text{letter} \mid \text{digit}\ )^{*} \\
&\quad \mid \text{a}\,(\ \text{letter} \mid \text{digit}\ )^{*} \mid \ldots \mid \text{z}\,(\ \text{letter} \mid \text{digit}\ )^{*} \\
&\quad \mid 0\,(\ \text{letter} \mid \text{digit}\ )^{*} \mid \ldots \mid 9\,(\ \text{letter} \mid \text{digit}\ )^{*}
\end{aligned}
$$

标识符的正规文法

id → **A *rid*|...|Z *rid*|a *rid*|...|z *rid***

rid → ε **|A *rid*|B *rid*|...|Z *rid***

|a *rid*|b *rid*|...|z *rid*

|0 *rid*|1 *rid*|...|9 *rid*

- 一般写作:

id → **letter *rid***

rid → ε **| letter *rid* | digit *rid***

常数——整数

- 描述整数结构的正规表达式为：

$$(digit)^+$$

- 对此正规表达式进行等价变换：

$$(digit)^+ = digit(digit)^*$$

$$(digit)^* = \varepsilon \mid digit(digit)^*$$

- 整数的正规文法：

$$digits \rightarrow digit\ remainder$$

$$remainder \rightarrow \varepsilon \mid digit\ remainder$$

常数——无符号数

- 无符号数的正规表达式为：
  (digit)$^+$ (.(digit)$^+$)? (E(+|-)?(digit)$^+$)?

- 正规定义式为
  digit → **0|1|...|9**
  digits → digit$^+$
  optional_fraction → **(.**digits**)?**
  optional_exponent → **(E(+|-)?**digits**)?**
  num → digits optional_fraction optional_exponent

把正规定义式转换为正规文法

$(\text{digit})^+ (.(\text{digit})^+)? (E(+|-)?(\text{digit})^+)?$

$=(\text{digit})^+ (.(\text{digit})^+ |\varepsilon) (E(+|-|\varepsilon)(\text{digit})^+ |\varepsilon)$

$=\text{digit}(\text{digit})^* (.\ \text{digit}(\text{digit})^*|\varepsilon) (E(+|-|\varepsilon)\ \text{digit}(\text{digit})^*|\varepsilon)$

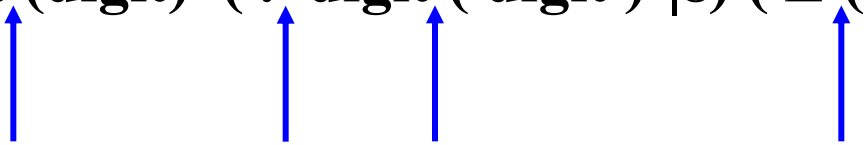

num1 表示无符号数的第一个数字之后的部分

num2 表示小数点以后的部分

num3 表示小数点后第一个数字以后的部分

num4 表示E之后的部分

num5 表示(digit)*

digits 表示$(\text{digit})^+$

无符号数分析图

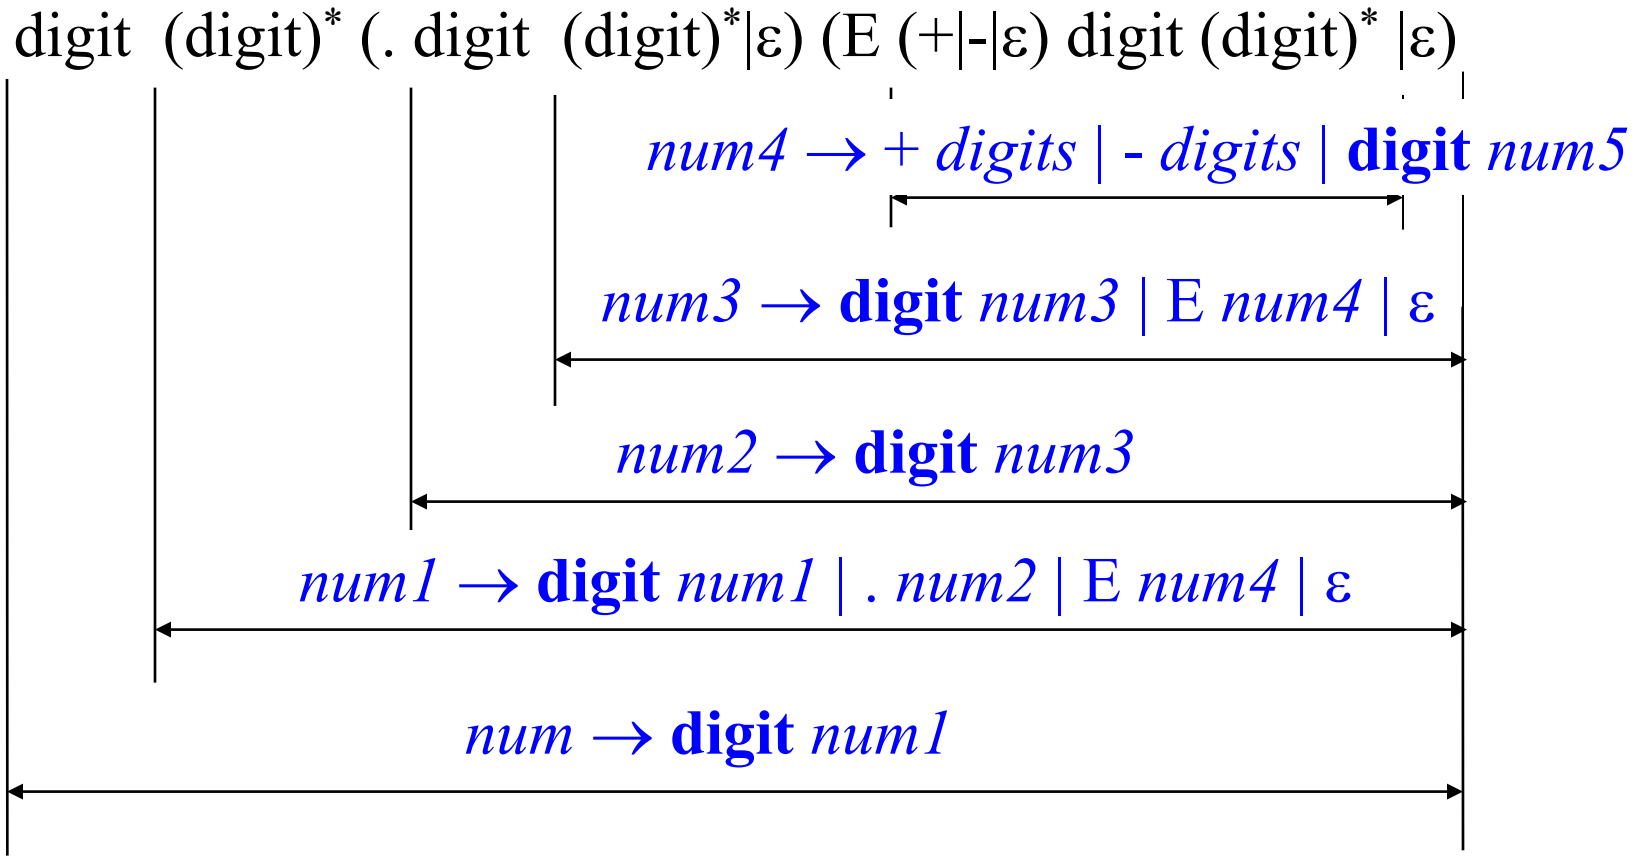

digits 表示(digit)+

num5 表示(digit)*

digits → **digit** *num5*

num5 → **digit** *num5* | ε

无符号数的正规文法

num → **digit *num1***

num1 → **digit *num1* | . *num2* | E *num4* |** ε

num2 → **digit *num3***

num3 → **digit *num3* | E *num4* |** ε

num4 → **+ *digits* | - *digits* | digit *num5***

digits → **digit *num5***

num5 → **digit *num5* |** ε

无符号数 4.6E-8 的分析树

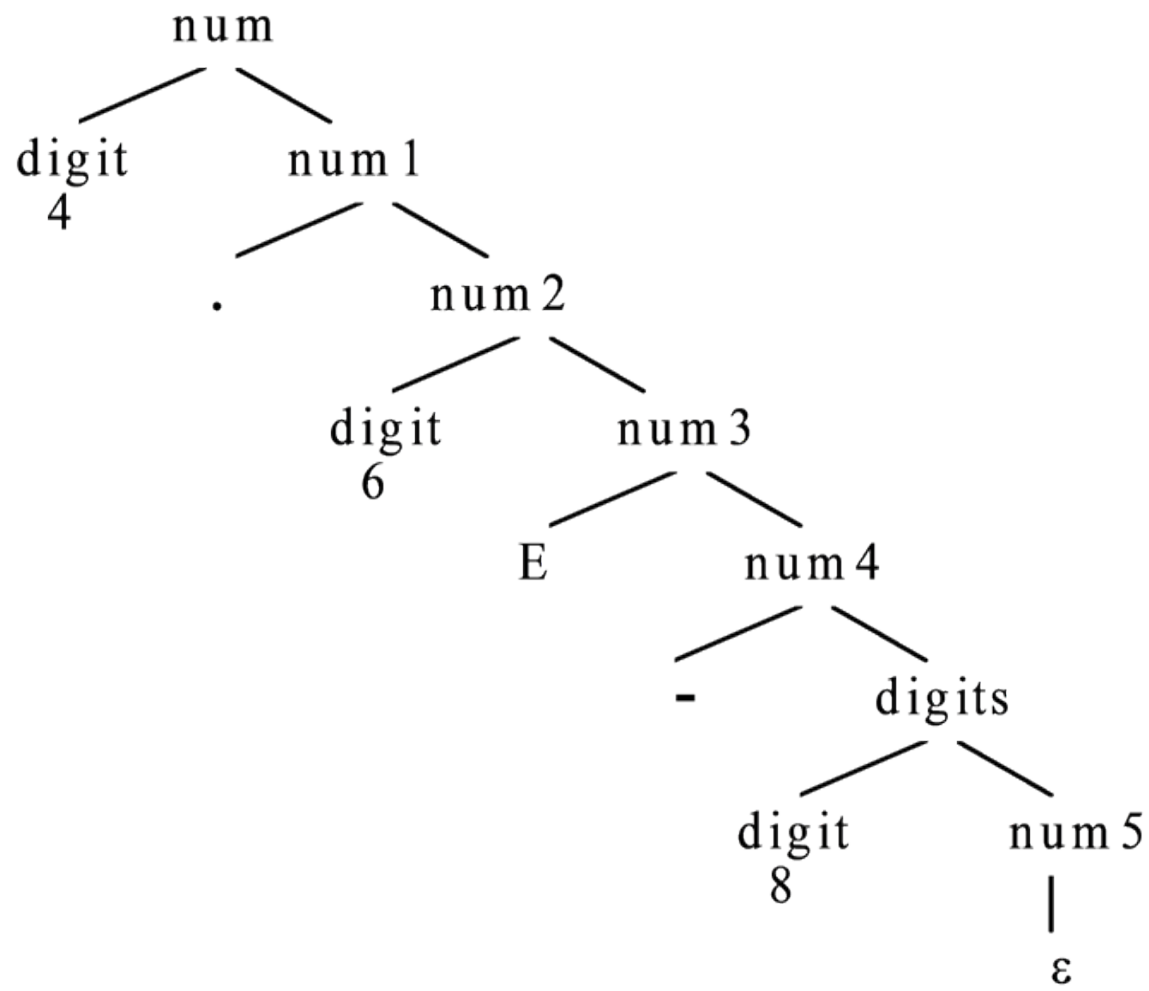

运算符

- 关系运算符的正规表达式为：

  < |<= | = | <> | >= | >

- 正规定义式：

  relop →**< |<= | = | <> | >= | >**

- 关系运算符的正规文法：

  relop → **< | *<equal*** **| = |*<greater*** **| > | *>equal***

  greater → **>**

  equal → **=**

三、状态转换图与记号的识别

- 状态转换图
- 利用状态转换图识别记号
- 为线性文法构造相应的状态转换图
  - 状态集合的构成
  - 状态之间边的形成

状态转换图

- 构造词法分析程序的第一步首先是根据单词符号的正规文法构造状态转换图，然后再根据状态转换图进一步构造分析程序

- 根据有限自动机与正规文法的等价性，可以根据记号的正规文法来构造相应的有效自动机，并用状态转换图表示

标识符的状态转换图

- 标识符的文法产生式：

  id $\rightarrow$ **letter *rid***

  rid $\rightarrow \varepsilon$ **| letter *rid* | digit *rid***

- 标识符的状态转换图

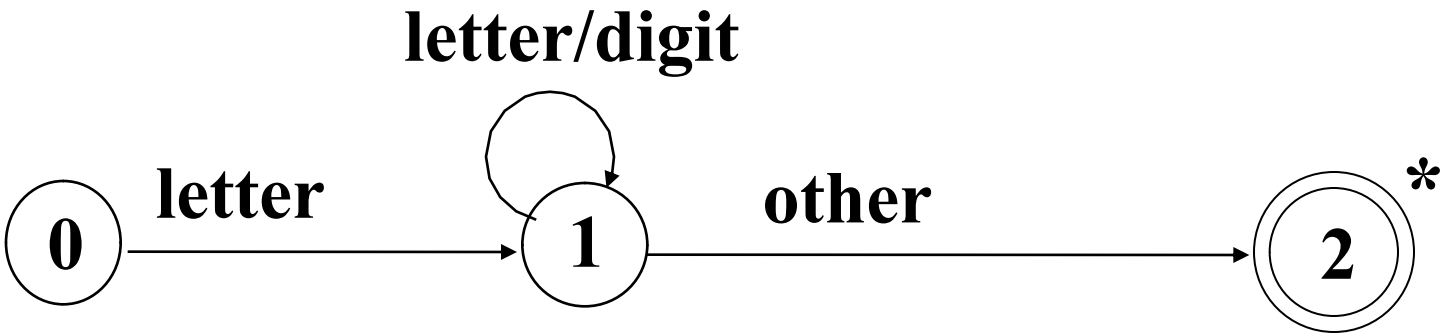

利用状态转换图识别记号

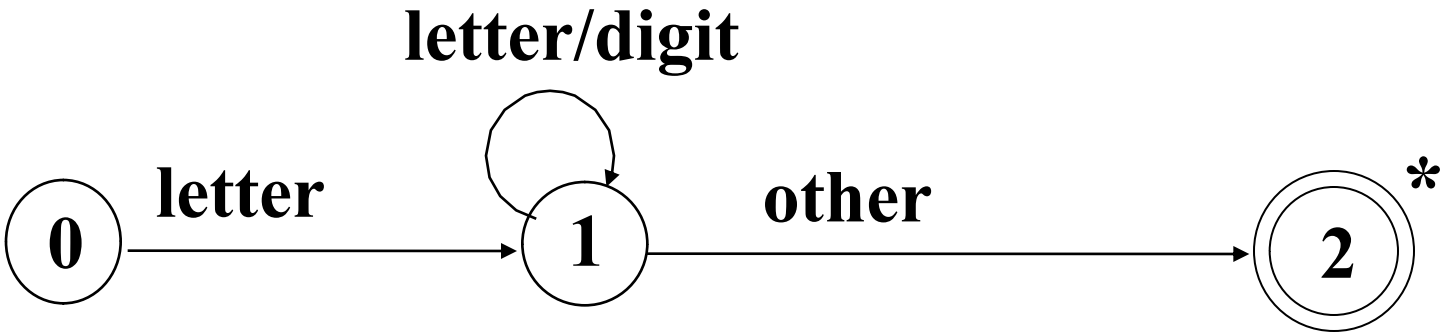

- 语句 DO99K=1.10 中标识符 DO99K 的识别过程

状态 **0** → 状态**1** → 状态**1** → 状态**1** → 状态**1** → 状态**1** → 状态**2**

读入**D** 读入**O** 读入**9** 读入**9** 读入**K** 读入=

- 在终态结点2上有一个星号，表示多读入了一个不属于标识符本身的字符，需要把它退还给输入串

为线性文法构造相应的状态转换图

- 状态集合的构成
  - 对文法G的每一个非终结符号设置一个对应的状态
  - 文法的开始符号对应的状态称为初态
  - 增加一个新的状态，称为终态。

- 状态之间边的形成
  - 对产生式A→aB，从A状态到B状态画一条标记为a的边
  - 对产生式A→a，从A状态到终态画一条标记为a的边
  - 对产生式A→ε，从A状态到终态画一条标记为ε的边

无符号数的右线性文法的状态转换图

num → digit ***num1***
num1 → digit ***num1*** | **.** ***num2*** | **E** ***num4*** | ε
num2 → digit ***num3***
num3 → digit ***num3*** | **E** ***num4*** | ε
num4 → **+** ***digits*** | **-** ***digits*** | digit ***num5***
digits → digit ***num5***
num5 → digit ***num5*** | ε

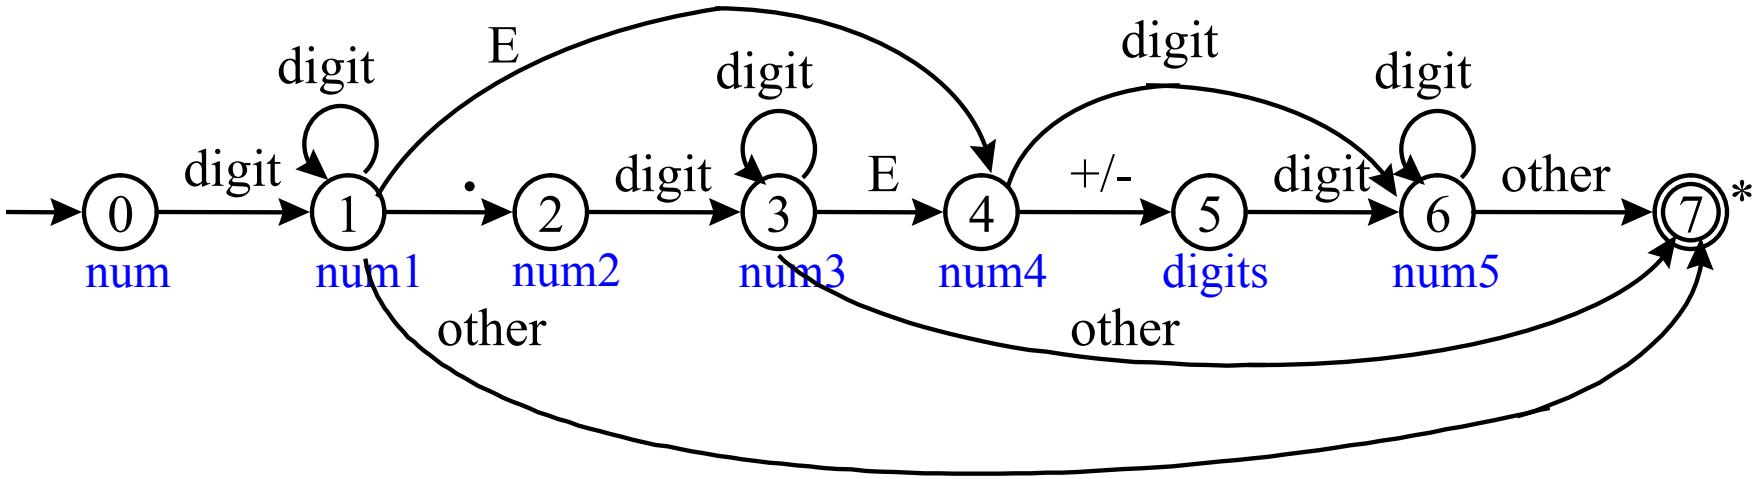

3.4 词法分析程序的设计与实现

步骤：

1. 给出描述该语言各种单词符号的词法规则
2. 画出状态转换图
3. 根据状态转换图构造词法分析器

一、文法及状态转换图

1. 语言说明
2. 记号的正规文法
3. 状态转换图

二、词法分析程序的构造

三、词法分析程序的实现

1. 输出形式
2. 设计全局变量和过程
3. 编制词法分析程序

一、文法及状态转换图

- 语言说明

标识符：以字母开头的、后跟字母或数字组成的符号串。
保留字：标识符的子集。
无符号数：同**PASCAL**语言中的无符号数。
关系运算符：**<**、**<=**、**=**、**<>**、**>=**、**>**。
算术运算符：**+**、**-**、*****、**/**。
标点符号：**(**、**)**、**:**、**'**、**;** 等。
赋值号：**:=**
注释标记：以**'/*'**开始，以**'*/'**结束。
单词符号间的分隔符：空格

记号的正规文法

- 标识符的文法

  id → **letter *rid***

  rid → ε | **letter *rid*** | **digit *rid***

- 无符号整数的文法

  digits → **digit *remainder***

  remainder → ε | **digit *remainder***

记号的正规文法(续1)

- 无符号数的文法

num → **digit *num1***

num1 → **digit *num1* | . *num2* | E *num4* |** ε

num2 → **digit *num3***

num3 → **digit *num3* | E *num4* |** ε

num4 → **+ *digits* | - *digits* |digit *num5***

digits → **digit *num5***

num5 → **digit *num5* |** ε

- 关系运算符的文法

relop →**< |<*equal* | = |<*greater* |>|>*equal***

greater →**>**

equal → **=**

记号的正规文法(续2)

- 赋值号的文法

  assign_op → **:*equal***

  equal → **=**

- 算术运算符及标点符号的文法

  single → **+ | - | * | / | (|) | : | ′ | ;**

- 注释头符号的文法

  note → **/ *star***

  star → *****

状态转换图

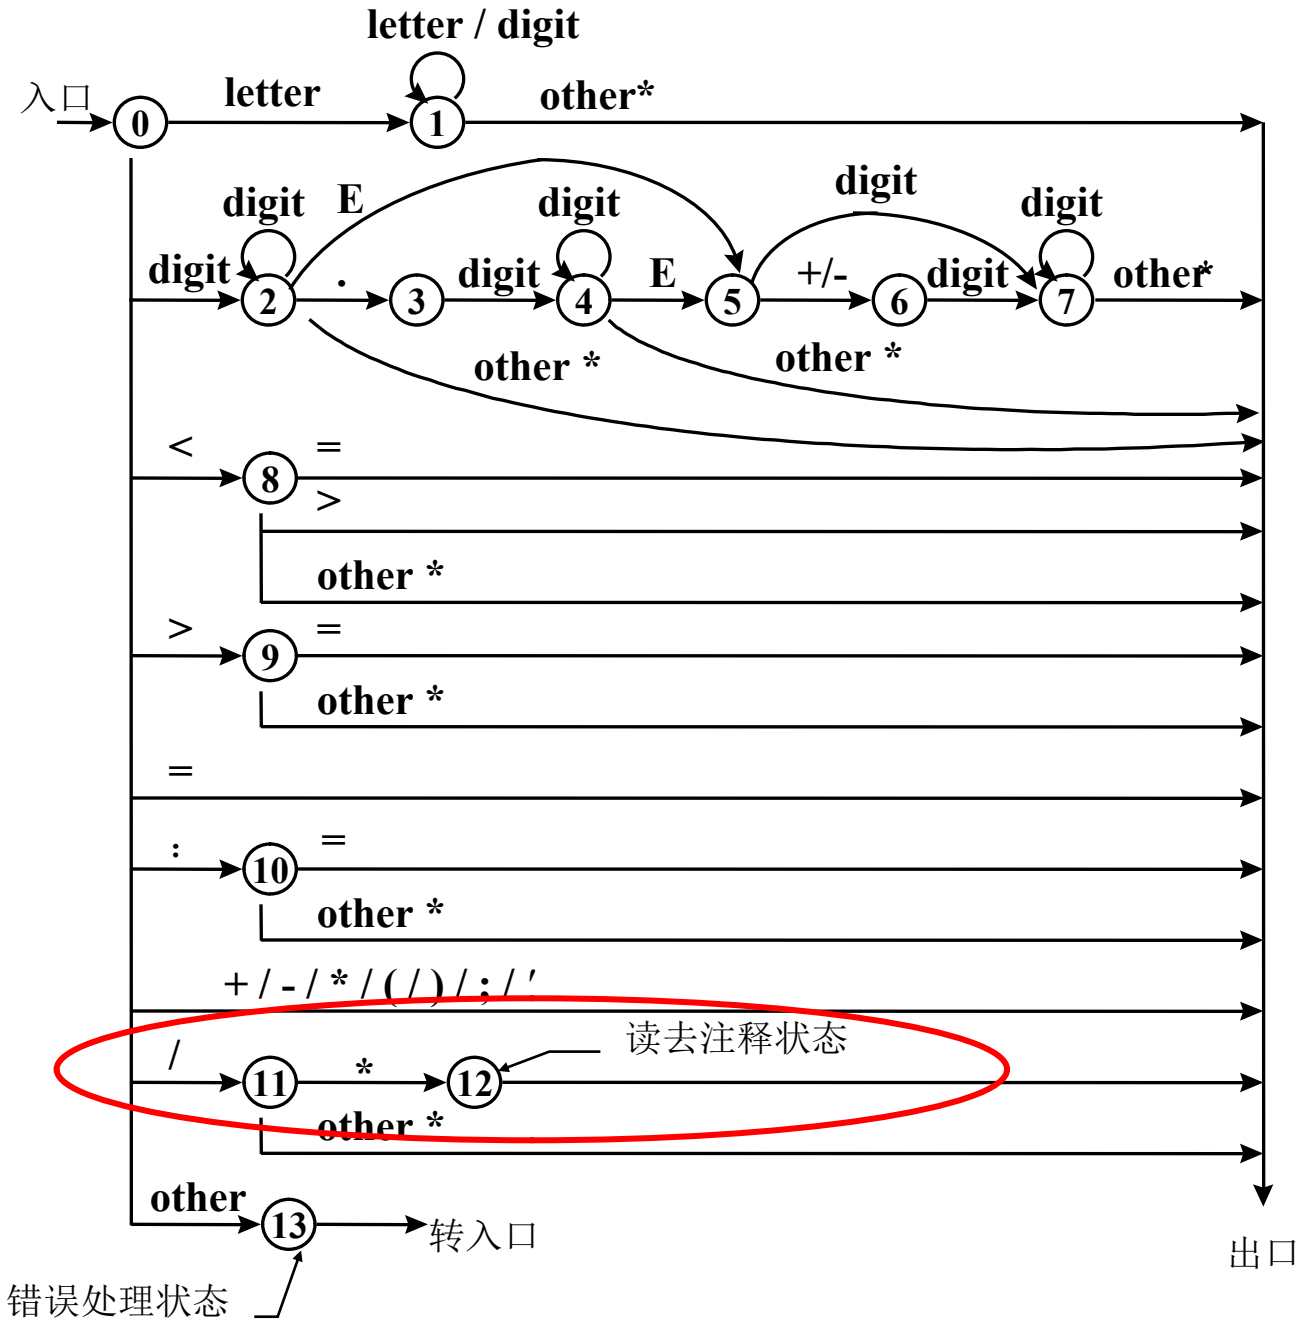
letter / digit
入口
letter
other*
digit
E
digit
digit
digit
digit
.
digit
E
+/-
digit
other*
other *
other *
<
=
>
other *
>
=
other *
=
:
=
other *
+ / - / * / (/) / ; / '
读去注释状态
/
*
other *
other
转入口
出口
错误处理状态
0
1
2
3
4
5
6
7
8
9
10
11
12
13

识别注释的DFA

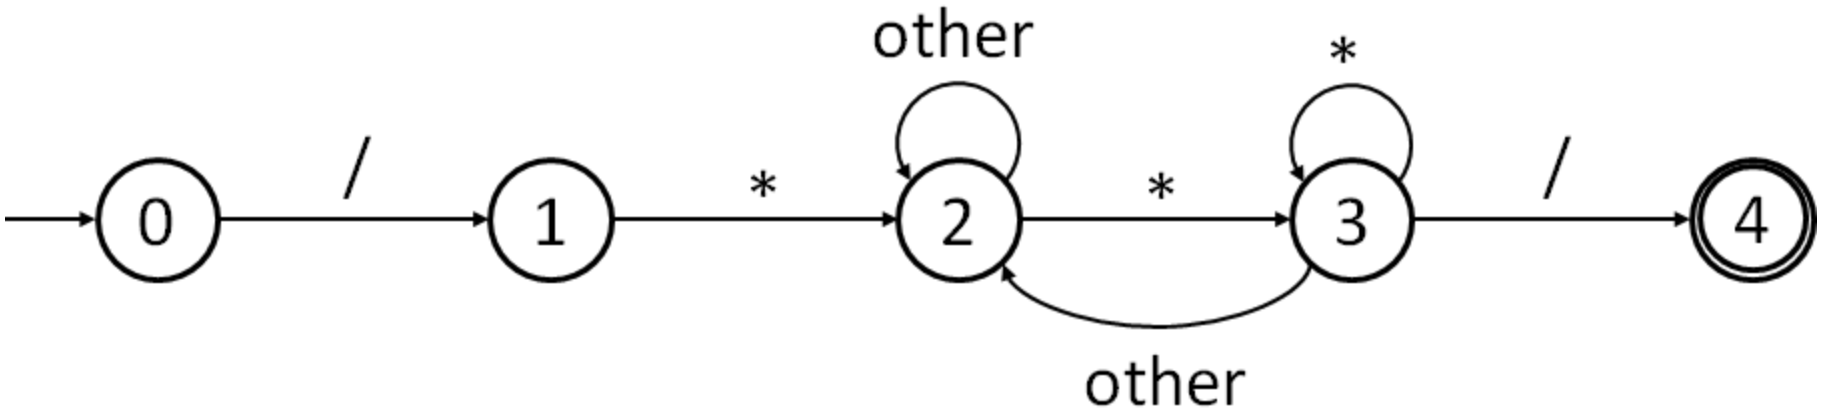

二、词法分析程序的构造

- 把语义动作添加到状态转换图中，使每一个状态都对应一小段程序，就可以构造出相应的词法分析程序。
- 如果某一状态有若干条射出边，则程序段：读一个字符，根据读到的字符，选择标记与之匹配的边到达下一个状态，即程序控制转去执行下一个状态对应的语句序列。
- 在状态0，首先要读进一个字符。若读入的字符是一个空格（包括blank、tab、enter）就跳过它，继续读字符，直到读进一个非空字符为止。接下来的工作就是根据所读进的非空字符转相应的程序段进行处理。
- 在标识符状态，识别并组合出一个标识符之后，还必须加入一些动作，如查关键字表，以确定识别出的单词符号是关键字还是用户自定义标识符，并输出相应的记号。
- 在“<”状态，若读进的下一个字符是“=”，则输出关系运算符“<=”；若读进的下一个字符是“>”，则输出关系运算符“<>”；否则输出关系运算符“<”。

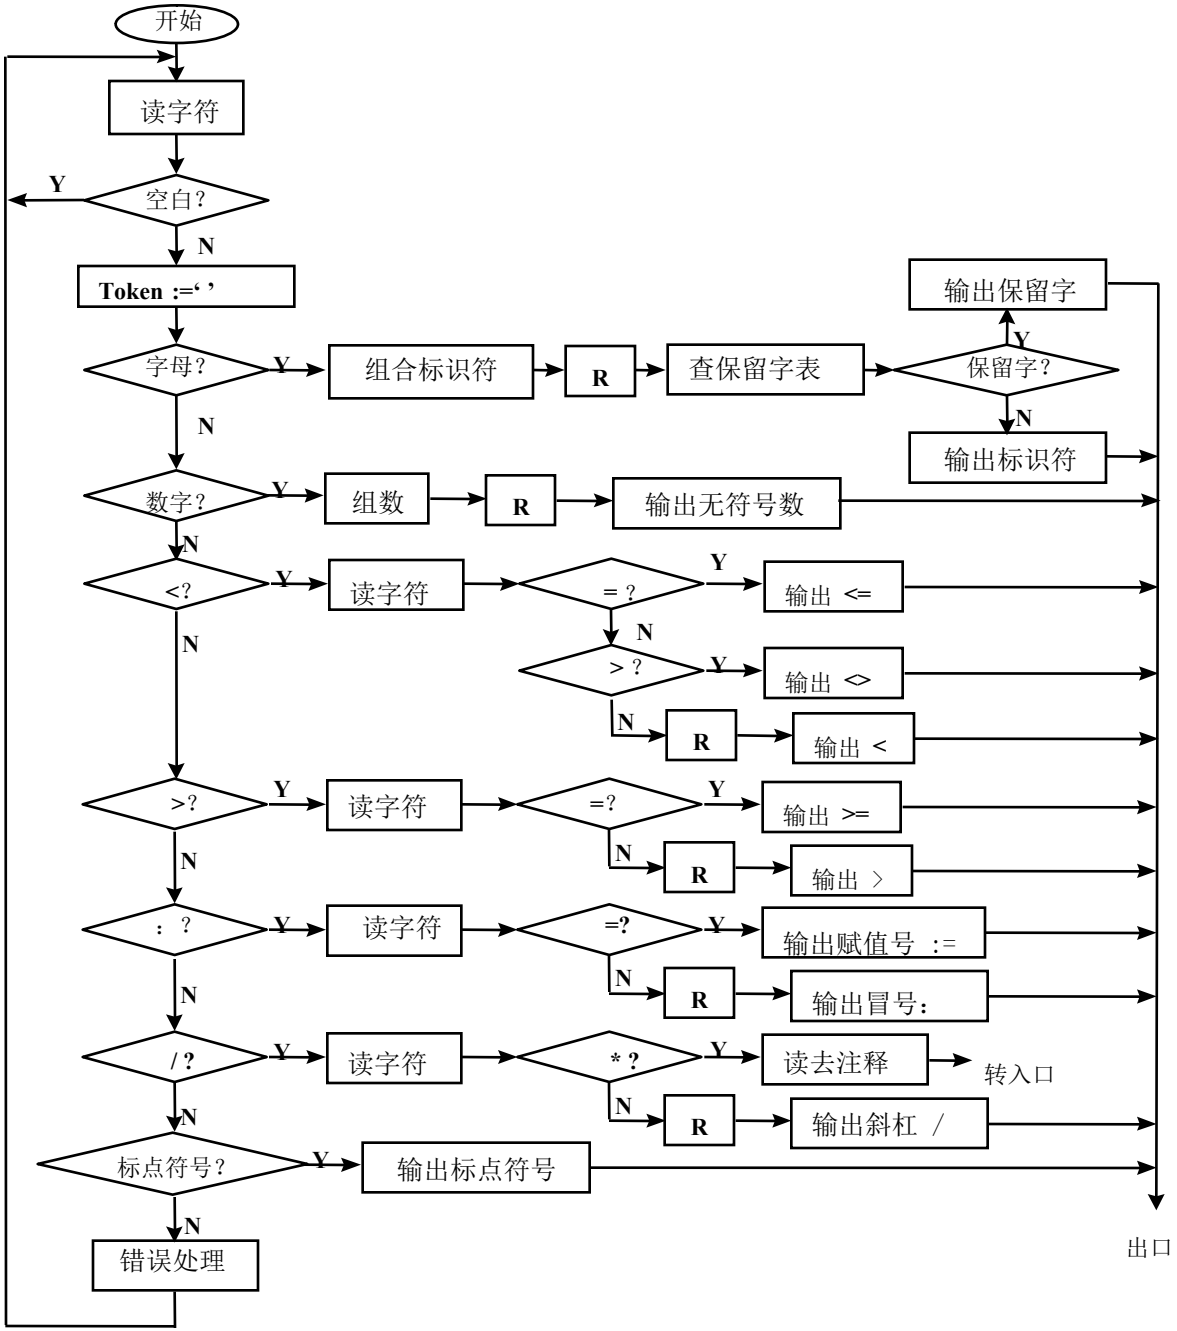

说明： **R** 为一过程，其功能是向前指针回退一个字符； **Token** 为字符数组，用于存放单词符号

三、词法分析程序的实现

- 输出形式
- 设计全局变量和过程
- 编制词法分析程序

输出形式

- 利用翻译表，将识别出的单词的记号以二元式的形式加以输出
- 二元式的形式：

  〈记号，属性〉
- 翻译表：

翻译表

正规表达式	记号	属性
if	if	-
then	then	-
else	else	-
id	id	符号表入口指针
num	num	常数值
<	relop	LT
<=	relop	LE
=	relop	EQ
<>	relop	NE
>	relop	GT
>=	relop	GE
:=	assign-op	-
+	+	-
-	-	-
*	*	-
/	/	-
(	(	-
)	)	-
,	,	-
;	;	-
:	:	-

设计全局变量和过程

(1) state：整型变量，当前状态指示。

(2) C：字符变量，存放当前读入的字符。

(3) token：字符数组，存放当前正在识别的单词字符串。

(4) buffer：字符数组，输入缓冲区。

(5) forward：字符指针，向前指针。

(6) lexemebegin：字符指针，指向buffer中当前单词的开始位置。

(7) get_char：过程，每调用一次，根据forward的指示从buffer中读一个字符，并把它放入变量C中，然后，移动forward，使之指向下一个字符。

(8) get_nbc：过程，检查C中的字符是否为空格，若是，则反复调用过程get_char，直到C中进入一个非空字符为止。

(9) cat：过程，把C中的字符连接在token中的字符串后面。

(10) iskey：整型变量，值为-1，表示识别出的单词是用户自定义标识符，否则，表示识别出的单词是关键字，其值为关键字的记号。

设计全局变量和过程（续）

(11) letter：布尔函数，判断C中的字符是否为字母，
若是则返回true，否则返回false。

(12) digit：布尔函数，判断C中的字符是否为数字，
若是则返回true，否则返回false。

(13) retract：过程，向前指针forward后退一个字符。

(14) reserve：函数，根据token中的单词查关键字表，
若token中的单词是关键字，则返回值该关键字的记号，
否则，返回值“-1”。

(15) SToI：过程，将token中的字符串转换成整数。

(16) SToF：过程，将token中的字符串转换成浮点数。

(17) DTB：过程，它将token中的数字串转换成二进制的数值表示。

(18) table_insert：函数，将识别出来的标识符（即token中的单词）插入符号表，返回该单词在符号表中的位置指针。

(19) error：过程，对发现的错误进行相应的处理。

(20) return：过程，将识别出来的单词的记号返回给调用程序。

编制词法分析程序（方法一）

```
token=’’;
get_char();
get_nbc();
SWITCH (C)
{
CASE ‘a’..‘z’: WHILE (letter() || digit()) {
                    cat(); get_char(); }
               retract();
               iskey=reserve();  // 查关键字表
               IF iskey=-1 {        // 识别出的是用户自定义标识符
                  identry=table_insert(); // 返回该标识符在符号表的入口指针
                  return(ID, identry);
                };
               ELSE return (iskey,-); // 识别出的是关键字
               BREAK;
```

编制词法分析器（续）

```
CASE '0'..'9': WHILE (digit()||'.'||'E'||'+'||'-') {
                        cat(); get_char();  }
               retract(); return(num, DTB(token));
               BREAK;
CASE '<' : get_char();
           IF (C=='=') return(relop, LE);
           ELSE IF (C=='>') return(relop, NE);
                ELSE { retract;  return(relop, LT);}
           BREAK;
CASE '=' : return(relop, EQ); BREAK;
CASE '>' : get_char();
           IF (C=='=') return(relop, GE);
           ELSE { retract; return(relop, GT);}
           BREAK;
```

编制词法分析器（续）

```
CASE ':' : get_char();
      IF (C=='=') return(assign-op, -);
       retract(); return(':', -);
       BREAK;
CASE '+' : return('+', -); BREAK;
CASE '-' : return('-', -); BREAK;
CASE '(' : return('(', -); BREAK;
CASE ')' : return(')', -); BREAK;
CASE ';' : return(';', -); BREAK;
```

编制词法分析程序（方法二）

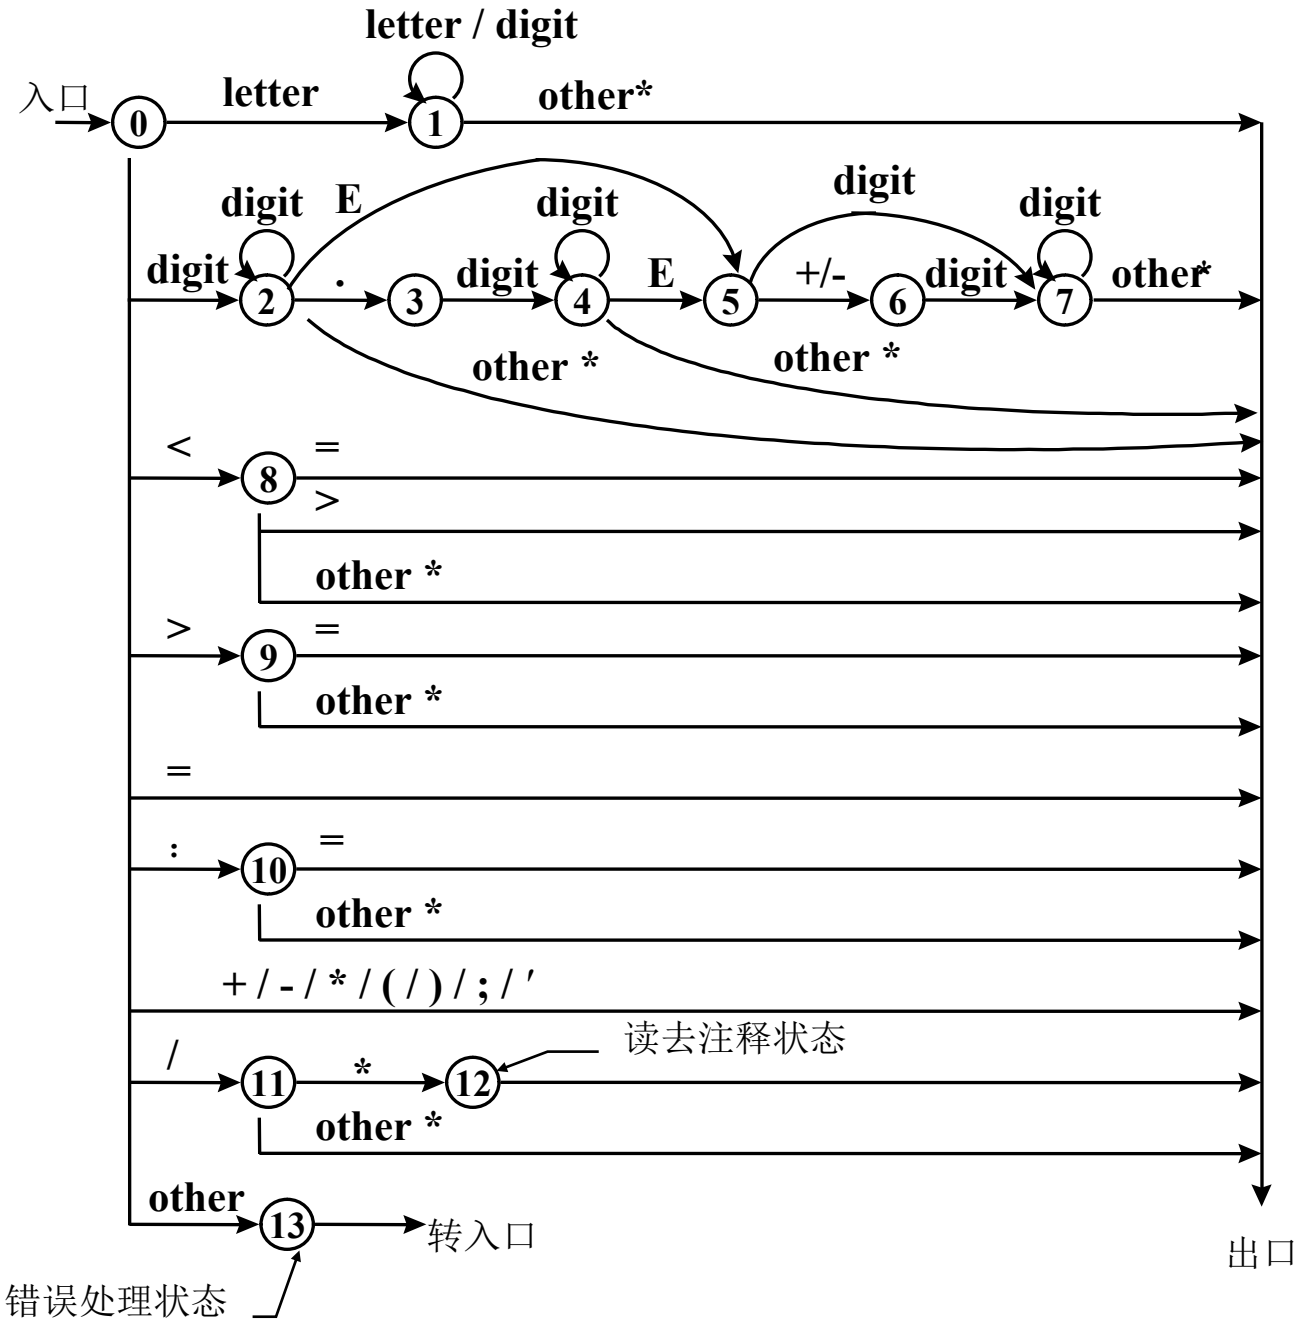

词法分析程序（类C语言描述）

```
state=0;
DO {
SWITCH ( state ) {
   CASE 0:     // 初始状态
      token=' ';       get_char() ;       get_nbc();
      SWITCH ( C ) {
         CASE 'a':  CASE 'b':  …    CASE 'z':  state=1; break;     //设置标识符状态
         CASE '0':  CASE '1':  …    CASE '9':  state=2; break;     //设置常数状态
         CASE '<':  state=8; break;     //设置‘<’状态
         CASE '>':  state=9; break;     //设置‘>’状态
         CASE ':':  state=10; break;     //设置‘：’状态
         CASE '/':  state=11; break;     //设置‘/’状态
         CASE '=':  state=0; return(relop, EQ); break;     //返回‘=’的记号
         CASE '+':  state=0; return('+', –); break;          //返回‘+’的记号
         CASE '–':  state=0; return('–', –); break;          //返回‘-’的记号
         CASE '*':  state=0; return('*', –); break;          //返回‘*’的记号
         CASE '(':  state=0; return('(', –); break;          //返回‘（’的记号
         CASE ')':  state=0; return(') ', –); break;         //返回‘）’的记号
         CASE ';':  state=0; return('; ', –); break;         //返回‘；’的记号
         CASE '\'':  state=0; return('\'', –); break;        //返回‘’’的记号
         default: state=13; break;     //设置错误状态
       };
      break;
```

词法分析程序(续1)

```
CASE 1:     // 标识符状态
  cat();
  get_char();
  IF ( letter() || digit() )  state=1;
  ELSE {
      retract();
      state=0;
      iskey=reserve();   // 查关键字表
      IF ( iskey!=-1 ) return (iskey，–);   // 识别出的是关键字
      ELSE {   // 识别出的是用户自定义标识符
          identry=table_insert();    // 返回该标识符在符号表的入口指针
          return(ID, identry);
       };
    };
 break;
```

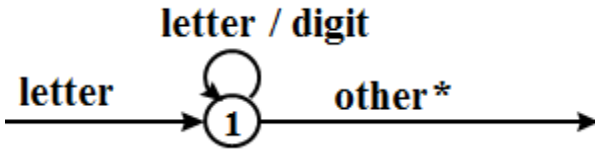

词法分析程序（续2）

```
CASE 2:     // 常数状态
  cat();
  get_char();
  SWITCH ( C ) {
     CASE '0':
     CASE '1':
        ┆
     CASE '9': state=2; break;
     CASE '.' : state=3; break;
     CASE 'E': state=5; break;
     DEFAULT:    // 识别出整常数
     retract();
     state=0;
     return(NUM, SToI(token));      // 返回整数
     break;
  };
  break;
```

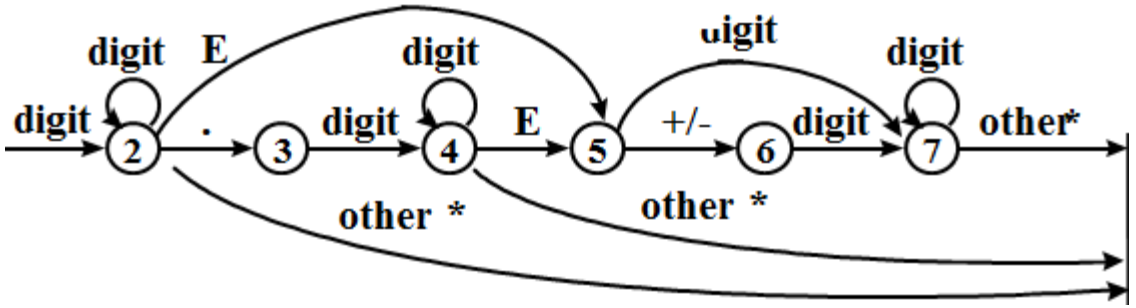

3.5 软件工具 LEX

- 词法分析程序自动生成工具

一、LEX使用流程

二、LEX源程序结构

三、LEX工作原理

一、LEX使用流程

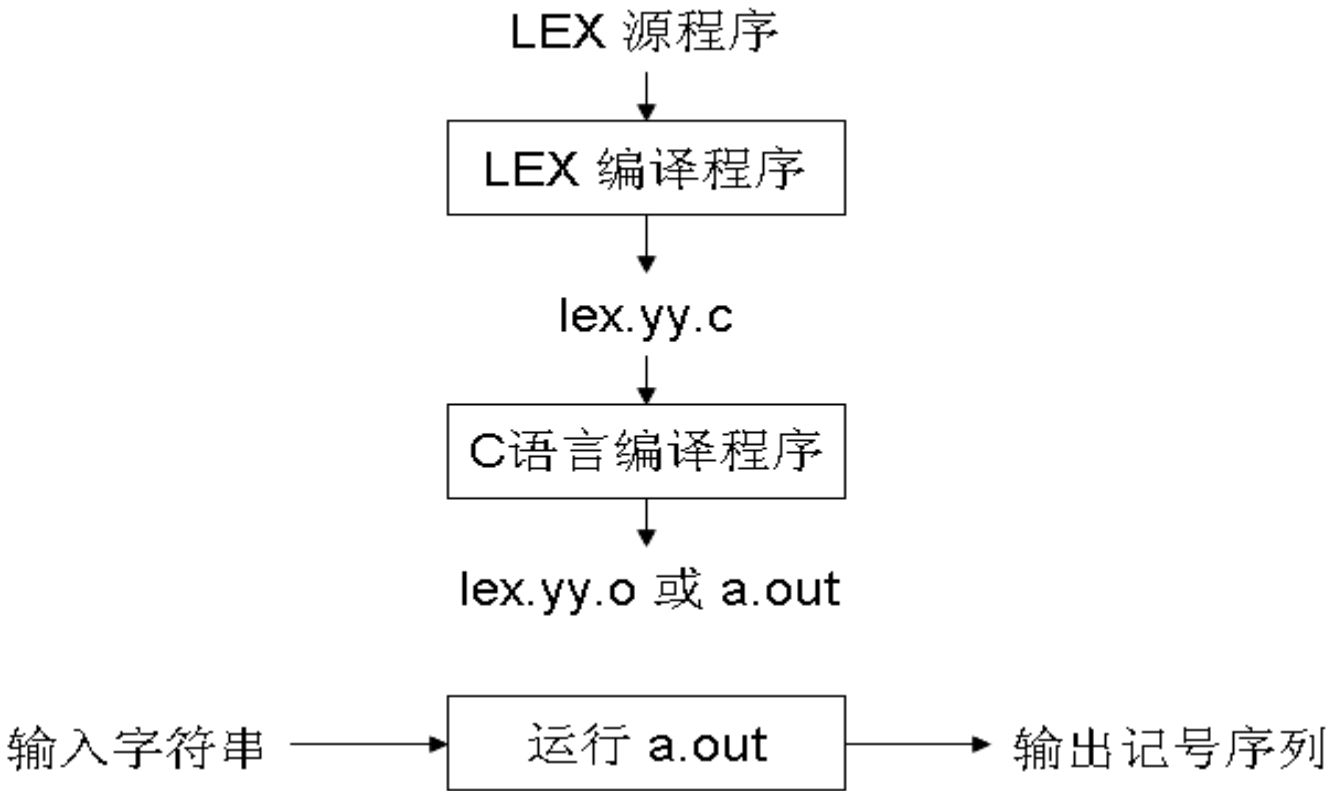

Lex. yy. o可以和其它程序的目标代码连接

a. out是可执行的目标程序，可以作为独立运行的词法分析器

二、LEX源程序结构

一个LEX源程序由三部分组成：

1. 说明部分
2. 翻译规则
3. 辅助过程

说明部分
%%
翻译规则
%%
辅助过程

1. 说明部分

- 包括：变量的声明、符号常量的声明、正规定义
- 正规定义中的名字可在翻译规则中用作正规表达式的成分
- C语言的说明必须用分界符“ %{ ”和“%} ”括起来。
  - 出现在括号中的任何东西都直接抄写到词法分析器Lex.yy.c中，不作为正规定义和翻译规则的一部分。在第三节中的辅助过程也按同样方式处理
  - 比如：

```
%{
  #include <stdio.h>
  #include <stdlib.h>
  #include <string.h>
  #include <ctype.h>
  #include " y.tab.h"
  typedef char * YYSTYPE;
  char * yylval;
%}
```

2. 翻译规则

- 形式：

  P1　　{ 动作1 }
  P2　　{ 动作2 }
  …
  Pn　　{ 动作n }

- Pi 是一个正规表达式，描述一种记号的模式。

- 动作i 是C语言的程序语句，表示当一个串匹配模式Pi时，词法分析器应执行的动作。

P_i书写中可能用到的规则

(1) 转义字符：" \ [ ] ^ - ? . * + | ( ) $ / { } % < >

- 具有特殊含义，不能用来匹配自身。如果需要匹配的话，可以通过引号(")或者转义符号(\)来指示。比如：C"++"和C\+\+ 都可以匹配C++。

(2) 通配符：. 可以匹配任何一个字符。

- 如：a.c匹配任何以a开头、以c结尾的长度为3的字符串。

(3) 字符集：用方括号“[”和“]”指定的字符构成一个字符集。

- 如，[abc]表示一个字符集，可以匹配a、b或c中的任意一个字符。
- 使用“-”可以指定范围。比如：[A-Za-z]。

(4) 重复：“*”表示任意次重复（可以是零次），
“+”表示至少一次的重复，
“?”表示零次或者一次。

- 如：a+相当于aa*，a*相当于a+|ε，a?相当于a|ε。

(5) 选择和分组：“|”表示二者则一；括号“(”和“)”表示分组，括号内的组合被看作是一个原子。

3. 辅助过程

- 对翻译规则的补充
- 翻译规则部分中某些动作需要调用的过程，如果不是C语言的库函数，则要在此给出具体的定义。
- 这些过程也可以存入另外的程序文件中，单独编译，然后和词法分析器连接装配在一起。

LEX源程序举例

- 传递单词的属性，是把属性值赋给全程变量yylval
- 正规定义式：

if → if

then → then

else → else

relop → < | <= | = | <> | > | >=

id → letter(letter|digit)*

num → digit$^+$(.digit$^+$)?(E(+|-)?digit$^+$)?

相应的 LEX 源程序 框架

```
/*  声明部分 */
%{
   #include  <stdio.h>
   /* C语言描述的符号常量的定义，如LT、LE、EQ、NE、GT、
         GE、IF、THEN、ELSE、ID、NUMBER、RELOP */
   extern yylval, yytext, yyleng;
%}
/* 正规定义式 */
   delim          [  \t\n]
   ws             {delim}+
   letter         [A-Za-z]
   digit          [0-9]
   id             {letter}({letter}|{digit})*
   num            {digit}+(\.{digit}+)?(E[+\-]?{digit}+)?
%%
```

相应的 LEX 源程序 框架

```
/* 规则部分 */
    {ws}        {/* 没有动作，也不返回 */}
    if          { return(IF); }
    then        { return(THEN); }
    else        { return(ELSE); }
    {id}        { yylval=install_id(); return(ID); }
    {num}       { yylval= num_val();   return(NUMBER); }
    "<"         { yylval=LT;   return(RELOP); }
    "<="        { yylval=LE;   return(RELOP); }
    "="         { yylval=EQ;   return(RELOP); }
    "<>"        { yylval=NE;   return(RELOP); }
    ">"         { yylval=GT;   return(RELOP); }
    ">="        { yylval=GE;   return(RELOP); }
    %%
```

如果没有return语句，则，处理完整个输入之后才会返回！！

相应的 LEX 源程序 框架

```
/* 辅助过程 */
    int install_id() {
    ¦  /*  把单词插入符号表并返回该单词在符号表中的位置
           yytext指向该单词的第一个字符
           yyleng给出它的长度  */
    }
    int num_val() {
    ¦  /* 将识别出的无符号数字符串转换成数值型返回。*/
    }
```

LEX解决冲突的方式

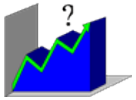

1. 根据规则定义的先后次序

   解决了例子中关键字和标识符的冲突

1. 最长匹配原则

   解决了例子中诸如“<”和“<=”的冲突

三、LEX的工作原理

1. LEX的工作过程
2. 处理二义性问题的两条规则
3. LEX工作过程举例
4. 控制执行程序

1. 工作过程

- 扫描每一条翻译规则Pi，为之构造一个非确定的有限自动机NFA Mi
- 将各条翻译规则对应的NFA Mi合并为一个新的NFA M

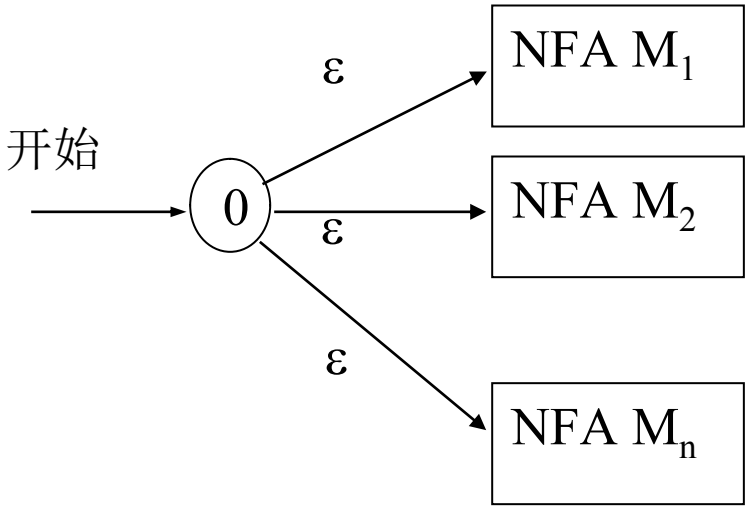

- 将NFA M确定化为DFA D，并生成该DFA D的状态转换矩阵和控制执行程序。

2. 识别单词时的二义性处理

- 最长匹配原则
  - 在识别单词符号过程中，当有几个规则看来都适用时，则实施最长匹配的那个规则
- 优先匹配原则
  - 如有几条规则可以同时匹配一字符串，并且匹配的长度相同，则实施最上面的规则。

- 如果有一些内容不匹配任何规则，则LEX将会把它拷贝到标准输出

3. 工作过程举例

```
%%
a                    {    }
abb                  {    }
{a}*b{b}*            {    }
%%
```

读LEX源程序，分别生成非确定的有限自动机

a

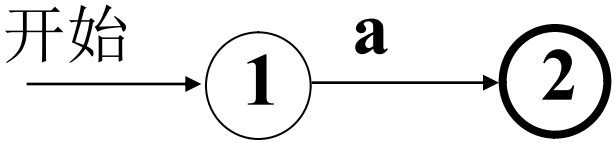

abb

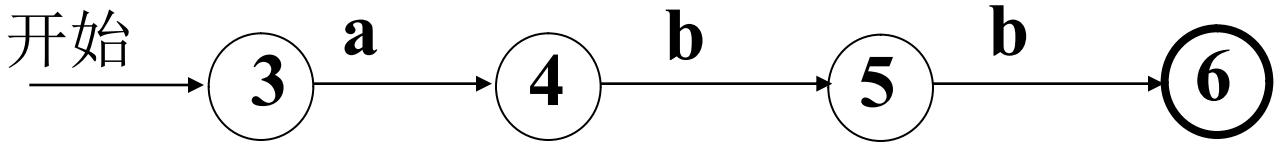

{a}*b{b}*

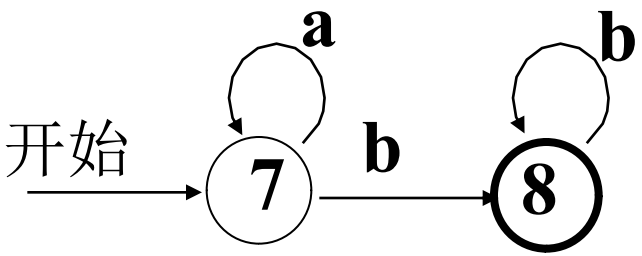

合并为一个NFA M

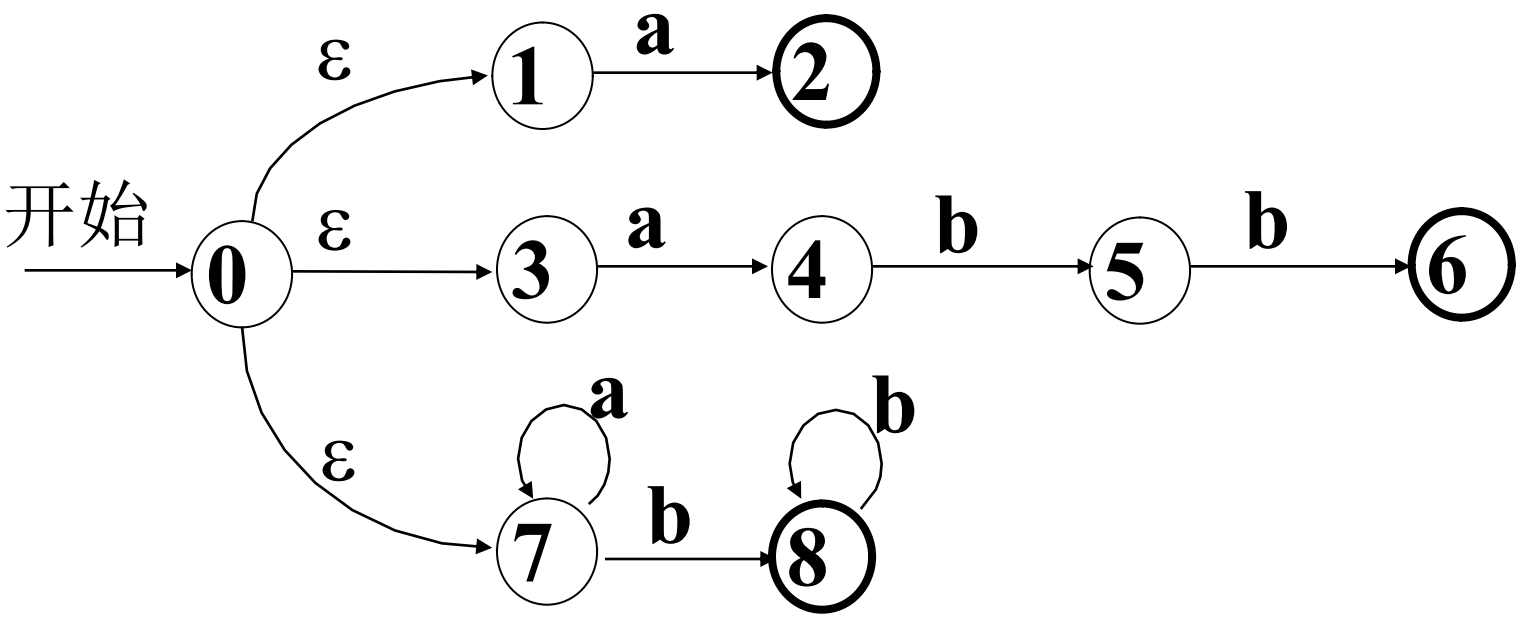

将该NFA M确定化为DFA D

DFA D=({a, b}, {A, B, C, D, E, F}, A, {B. C. E. F}, φ)

其中：A={0, 1, 3, 7}　　B={2, 4, 7}　　C={8}

D={7}　　E={5, 8}　　F={6, 8}

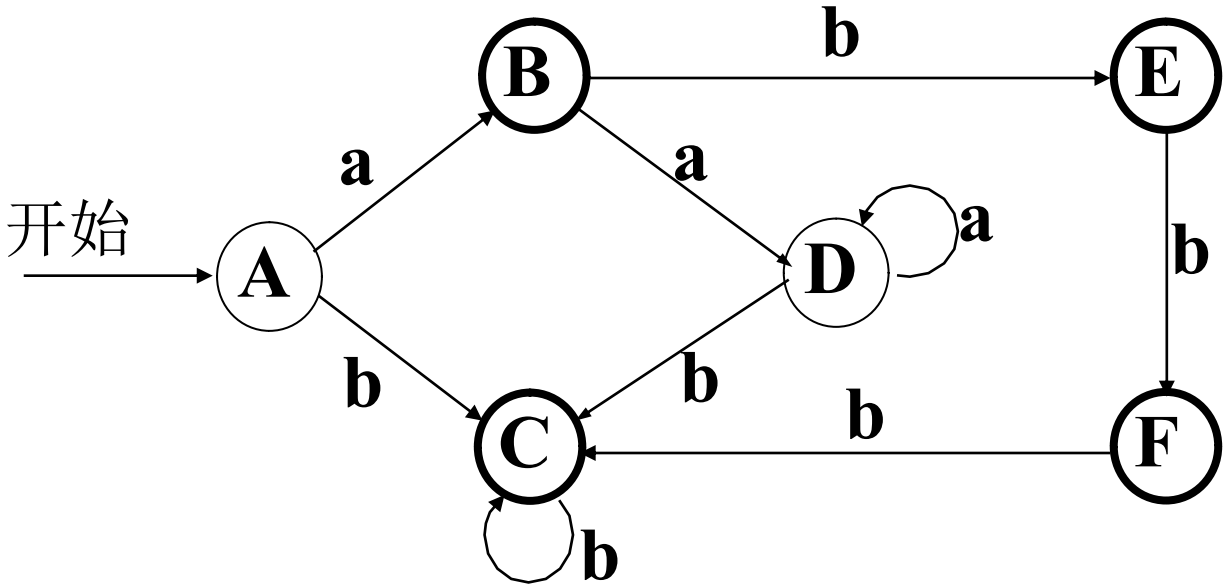

控制执行程序——最长匹配原则

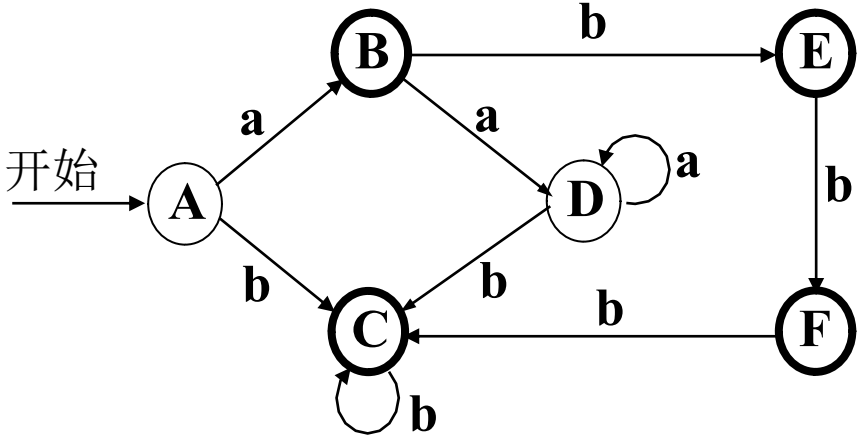

A={0, 1, 3, 7}　B={2, 4, 7}
C={8}　D={7}　E={5, 8}
F={6, 8}

规则顺序：

a　　终态：B

abb　　终态：F

{a}*b{b}*　终态：C, E, F

输入字符串为 aba...

读入	状态
–	A
a	B
b	E
a	–

控制执行程序——优先匹配原则

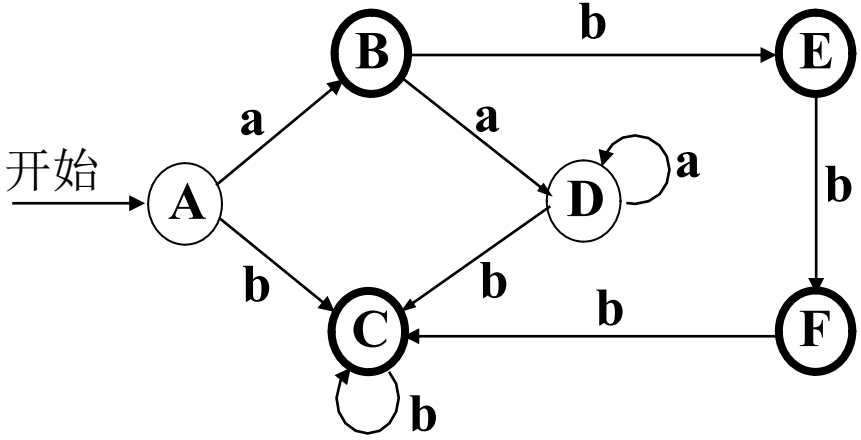

输入字符串为 abba...

读入	状态
–	A
a	B
b	E
b	F
a	–

A={0, 1, 3, 7} B={2, 4, 7}
C={8} D={7} E={5, 8}
F={6, 8}

规则顺序：

a　　终态：B

abb　　终态：F

{a}*b{b}*　终态：C, E, F

小　　结

- 词法分析器的作用
- 与语法分析器的关系
  - 独立、子程序、协同程序
- 配对缓冲区
  - 必要性、算法
- 记号
  - 记号、模式、单词
  - 属性
  - 二元式形式　　<记号，属性>
  - 描述：正规表达式、正规文法
  - 识别：状态转换图

小　　结（续）

- 词法分析器的设计与实现
  - 各类单词符号的正规表达式
  - 各类单词符号的正规文法
  - 构造与文法相应的状态转换图
  - 合并为词法分析器的状态转换图
  - 增加语义动作，构造词法分析器的程序框图
  - 确定输出形式、设计翻译表
  - 定义变量和过程
  - 编码实现
- LEX工具
  - LEX源程序的结构
  - LEX工具的使用