第2章 词法分析

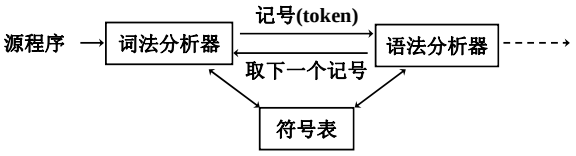

本章内容

– 词法分析器：把构成源程序的字符流翻译成记号流，还完成和用户接口的一些任务
– 围绕词法分析器的自动生成展开
– 介绍正规式、状态转换图和有限自动机概念

2.1 词法记号及属性

2.1.1 词法记号、模式、词法单元

记号名	词法单元例举	模式的非形式描述
if	if	字符i, f
for	for	字符f, o, r
relation	< , <= , = , …	< 或 <= 或 = 或 …
id	sum, count, D5	由字母开头的字母数字串
number	3.1, 10, 2.8 E12	任何数值常数
literal	“seg. error”	引号“和”之间的任意字符串，但引号本身除外

2.1 词法记号及属性

- 历史上词法定义中的一些问题
  – 忽略空格带来的困难（如 Fortran语言）
    DO 8 I = 3. 75　　DO8I = 3. 75
    DO 8 I = 3, 75
  – 关键字不保留（如 Fortran语言）
    IF THEN THEN THEN=ELSE；ELSE …
- 关键字、保留字和标准标识符的区别
  – 保留字是语言预先确定了含义的词法单元
  – 标准标识符也是预先确定了含义的标识符，但程序可以重新声明它的含义

2.1 词法记号及属性

2.1.2 词法记号的属性

position = initial + rate * 60

的记号和属性值：

⟨id，指向符号表中position条目的指针⟩
⟨assign _ op⟩
⟨id，指向符号表中initial条目的指针⟩
⟨add_op⟩
⟨id，指向符号表中rate条目的指针⟩
⟨mul_ op⟩
⟨number，整数值60⟩

2.1 词法记号及属性

2.1.3 词法错误

– 词法分析器对源程序采取非常局部的观点
– 例：难以发现下面的错误
    fi (a == f (x)) …
– 在实数是a.b格式下，可以发现下面的错误
    123.x
– 紧急方式的错误恢复
  删掉当前若干个字符，直至能读出正确的记号
– 错误修补
  进行增、删、替换和交换字符的尝试

2.2 词法记号的描述与识别

2.2.1 串和语言

– 字母表：符号的有限集合， 例：∑ = { 0, 1}
– 串：符号的有穷序列，例：0110, ε
– 语言：字母表上的一个串集
  {ε, 0, 00, 000, …}, {ε}, ∅
– 句子：属于语言的串

- 串的运算
  – 连接（积） xy，$s\varepsilon = \varepsilon s = s$
  – 幂　　s^0为ε，s^i为$s^{i-1}s$（$i > 0$）

2.2 词法记号的描述与识别

- 语言的运算
  - 并： $L \cup M = \{s \mid s \in L$ 或 $s \in M\}$
  - 连接： $LM = \{st \mid s \in L$ 且 $t \in M\}$
  - 幂： L^0是{ε}，L^i是$L^{i-1}L$
  - 闭包： $L^* = L^0 \cup L^1 \cup L^2 \cup \ldots$
  - 正闭包： $L^+ = L^1 \cup L^2 \cup \ldots$
- 例

  L: { $A, B, \ldots, Z, a, b, \ldots, z$ }, D: { 0, 1, …, 9 }

  $L \cup D, LD, L^6, L^*, L(L \cup D)^*, D^+$

2.2 词法记号的描述与识别

2.2.2 正规式

正规式用来表示简单的语言，叫做正规集

正规式	定义的语言	备注
ε	{ε}	
a	{a}	$a \in \Sigma$
$(r) \mid (s)$	$L(r) \cup L(s)$	r和s是正规式
$(r)(s)$	$L(r)L(s)$	r和s是正规式
$(r)^*$	$(L(r))^*$	r是正规式
(r)	$L(r)$	r是正规式

$((a)\ (b)^*) \mid (c)$可以写成$ab^* \mid c$

2.2 词法记号的描述与识别

- 正规式的例子 $\Sigma = \{a, b\}$
  - $a \mid b$ {a, b}
  - $(a \mid b)\ (a \mid b)$ {aa, ab, ba, bb}
  - $aa \mid ab \mid ba \mid bb$ {aa, ab, ba, bb}
  - a^* 由字母a构成的所有串集，含ε
  - $(a \mid b)^*$ 由a和b构成的所有串集，含ε
- 复杂的例子

  (00 | 11 | ((01 | 10) (00 | 11)* (01 | 10)))*

  句子：0100110100001000001011100 1

2.2 词法记号的描述与识别

2.2.3 正规定义

- 对正规式命名，使表示简洁

  $d_1 \rightarrow r_1$

  $d_2 \rightarrow r_2$

  . . .

  $d_n \rightarrow r_n$

- 各个d_i的名字都不同
- 每个r_i都是$\Sigma \cup \{d_1, d_2, \ldots, d_{i-1}\}$上的正规式

2.2 词法记号的描述与识别

- 正规定义的例子
  - C语言的标识符是字母、数字和下划线组成的串

    letter_ → $A \mid B \mid \ldots \mid Z \mid a \mid b \mid \ldots \mid z \mid$ _

    digit → 0 | 1 | … | 9

    id → letter_ (letter_ | digit)*

2.2 词法记号的描述与识别

- 正规定义的例子
  - 无符号数集合，例1946, 11.28, 63E8, 1.99E–6

    digit → 0 | 1 | … | 9

    digits → digit digit*

    optional_fraction → . digits | ε

    optional_exponent → (E (+ | – | ε) digits) | ε

    number→digits optional_fraction optional_exponent
  - 简化表示

    number → digit$^+$ (.digit$^+$)? (E(+|–)? digit$^+$)?

2.2 词法记号的描述与识别

- 正规定义的例子（进行下一步讨论的例子）

while → while
do → do
relop → < | < = | = | < > | > | > =
letter → ***A*** | ***B*** | … | ***Z*** | ***a*** | ***b*** | … | ***z***
id → **letter (letter | digit)***
number → **digit**+ **(.digit**+**)? (**E **(+ | –)? digit**+**)?**

delim → **blank | tab | newline**
ws → **delim**+

2.2 词法记号的描述与识别

2.2.4 转换图

- 关系算符的转换图

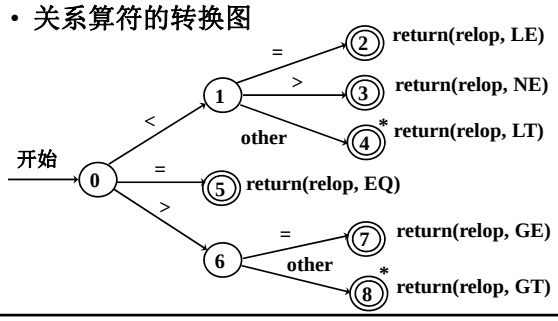

2.2 词法记号的描述与识别

- 标识符和保留字的转换图

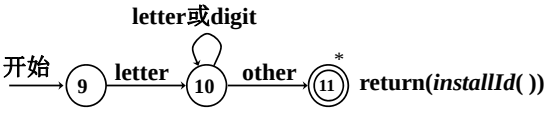

2.2 词法记号的描述与识别

- 无符号数的转换图

number → **digit**+ **(.digit**+**)? (**E **(+ | –)? digit**+**)?**

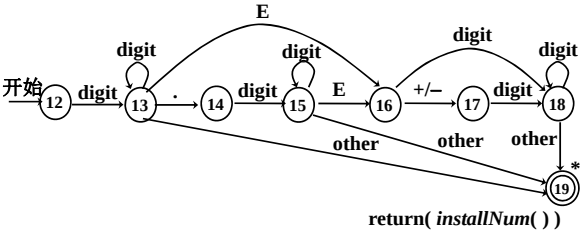

2.2 词法记号的描述与识别

- 空白的转换图

delim → **blank | tab | newline**
ws → **delim+**

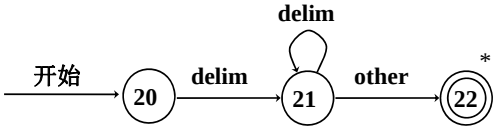

2.3 有 限 自 动 机

2.3.1 不确定的有限自动机（简称NFA）

一个数学模型，它包括：

1、有限的状态集合***S***
2、输入符号集合∑
3、转换函数***move*** : ***S*** × (∑∪{ε}) → ***P*(*S*)**
4、状态s_0是唯一的开始状态
5、***F*** ⊆ ***S***是接受状态集合

识别语言 (***a***|***b***)****ab*** 的NFA

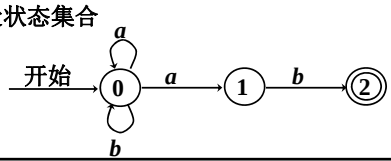

2.3 有限自动机

• NFA的转换表

状 态	输 入 符 号	
	a	*b*
0	{0, 1}	{0}
1	∅	{2}
2	∅	∅

识别语言 $(a|b)^*ab$ 的NFA

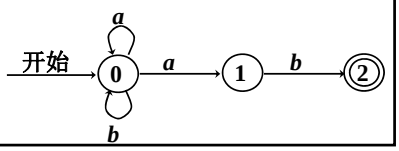

2.3 有限自动机

• 例 识别$aa^*|bb^*$的NFA

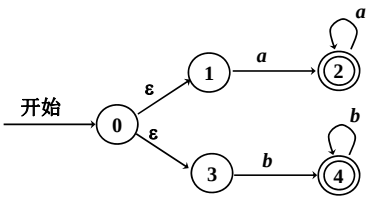

2.3 有限自动机

2.3.2 确定的有限自动机（简称DFA）

一个数学模型，包括：

1、有限的状态集合S

2、输入符号集合Σ

3、转换函数$move: S \times \Sigma \to S$，且可以是部分函数

4、唯一的开始状态 s_0

5、接受状态集合$F \subseteq S$

识别语言 $(a|b)^*ab$ 的DFA

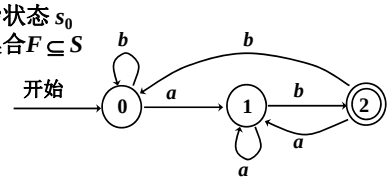

2.3 有限自动机

• 例 DFA，识别{0,1}上能被5整除的二进制数

	已读过	尚未读	已读部分的值
某时刻	101	0111000	5
读进0	1010	111000	5 × 2 = 10
读进1	10101	11000	10 × 2 + 1= 21

5个状态即可，分别代表已读部分的值除以5的余数

2.3 有限自动机

• 例 DFA，识别{0,1}上能被5整除的二进制数

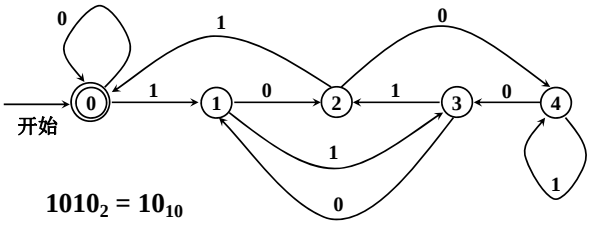

$1010_2 = 10_{10}$

$111_2 = 7_{10}$

2.3 有限自动机

2.3.3 NFA到DFA的变换

子集构造法

1、DFA的一个状态是NFA的一个状态集合

2、读了输入$a_1\ a_2 \ldots a_n$后，

NFA能到达的所有状态：$s_1, s_2, \ldots, s_k$，则

DFA到达状态$\{s_1, s_2, \ldots, s_k\}$

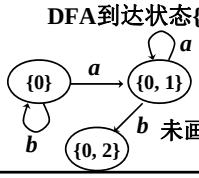

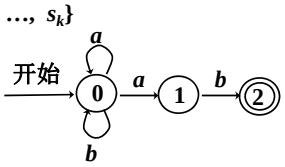

2.3 有限自动机

- 例 (*a*|*b*)**ab*，NFA如下，把它变换为DFA

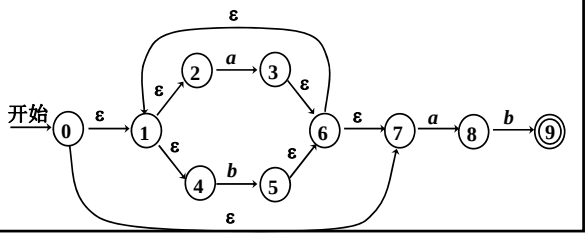

2.3 有限自动机

状态	输入符号	
	a	*b*

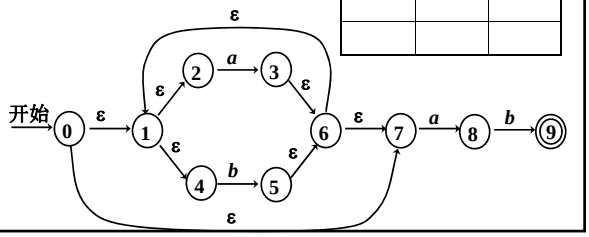

2.3 有限自动机

A = {0, 1, 2, 4, 7}

状态	输入符号	
	a	*b*
A		

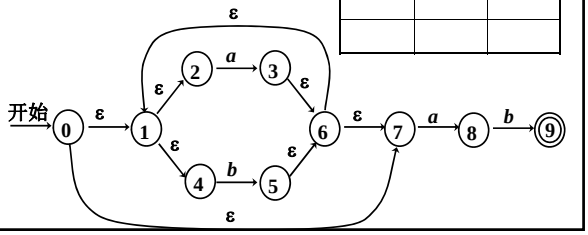

2.3 有限自动机

A = {0, 1, 2, 4, 7}
B = {1, 2, 3, 4, 6, 7, 8}

状态	输入符号	
	a	*b*
A	*B*	

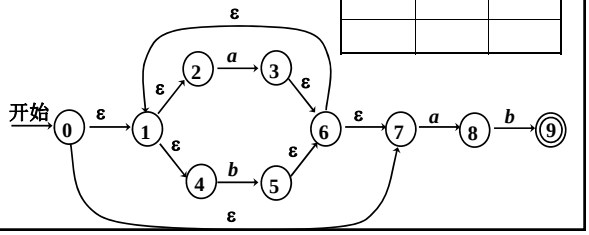

2.3 有限自动机

A = {0, 1, 2, 4, 7}
B = {1, 2, 3, 4, 6, 7, 8}

状态	输入符号	
	a	*b*
A	*B*	
B		

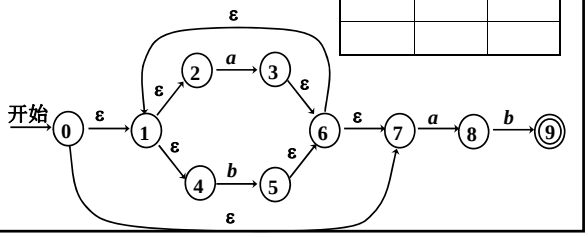

2.3 有限自动机

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

状态	输入符号	
	a	*b*
A	*B*	*C*
B		

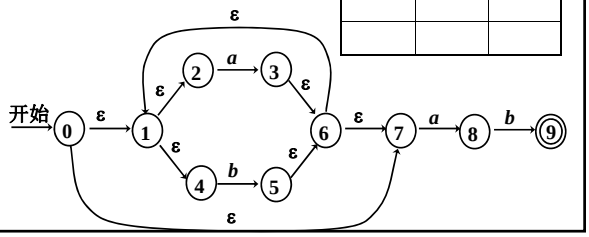

2.3 有限自动机

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

状态	输入符号	
	a	*b*
A	*B*	*C*
B		
C		

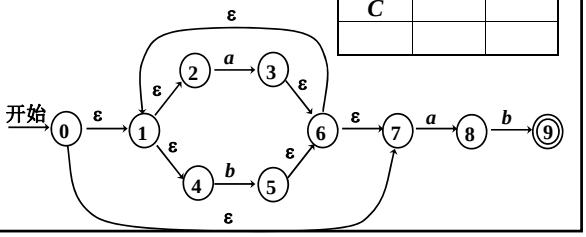

2.3 有限自动机

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

状态	输入符号	
	a	*b*
A	*B*	*C*
B	*B*	
C		

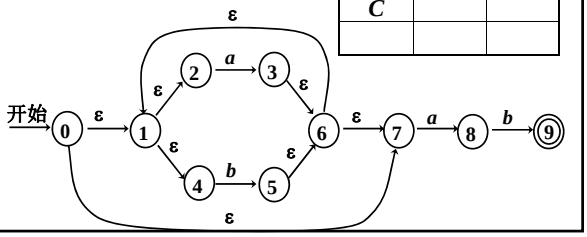

2.3 有限自动机

A = {0, 1, 2, 4, 7}
B = {1, 2, 3, 4, 6, 7, 8}
C = {1, 2, 4, 5, 6, 7}
D = {1, 2, 4, 5, 6, 7, 9}

状态	输入符号	
	a	*b*
A	*B*	*C*
B	*B*	*D*
C		

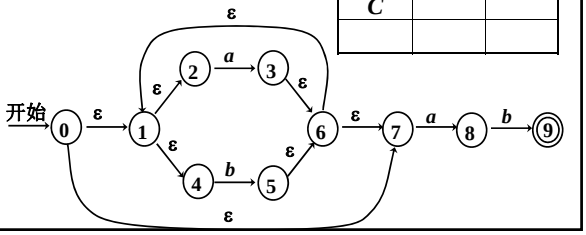

2.3 有限自动机

A = {0, 1, 2, 4, 7}
B = {1, 2, 3, 4, 6, 7, 8}
C = {1, 2, 4, 5, 6, 7}
D = {1, 2, 4, 5, 6, 7, 9}

状态	输入符号	
	a	*b*
A	*B*	*C*
B	*B*	*D*
C		
D		

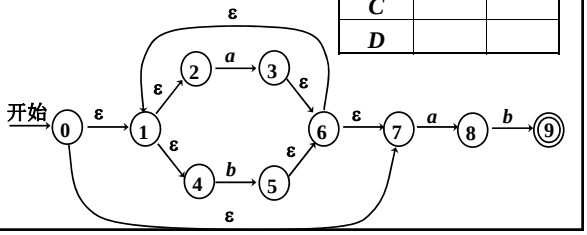

2.3 有限自动机

A = {0, 1, 2, 4, 7}
B = {1, 2, 3, 4, 6, 7, 8}
C = {1, 2, 4, 5, 6, 7}
D = {1, 2, 4, 5, 6, 7, 9}

状态	输入符号	
	a	*b*
A	*B*	*C*
B	*B*	*D*
C	*B*	*C*
D		

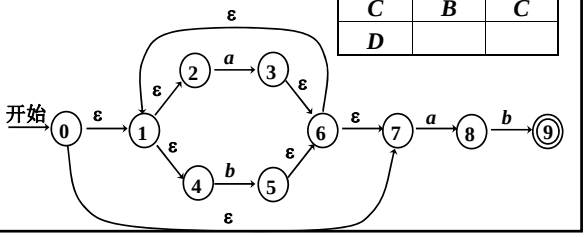

2.3 有限自动机

A = {0, 1, 2, 4, 7}
B = {1, 2, 3, 4, 6, 7, 8}
C = {1, 2, 4, 5, 6, 7}
D = {1, 2, 4, 5, 6, 7, 9}

状态	输入符号	
	a	*b*
A	*B*	*C*
B	*B*	*D*
C	*B*	*C*
D	*B*	*C*

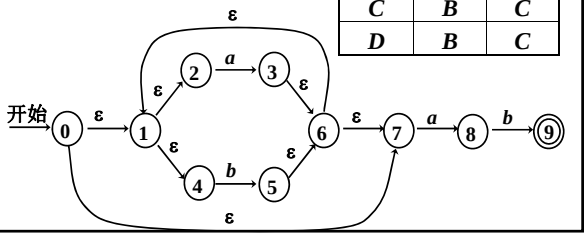

2.3 有限自动机

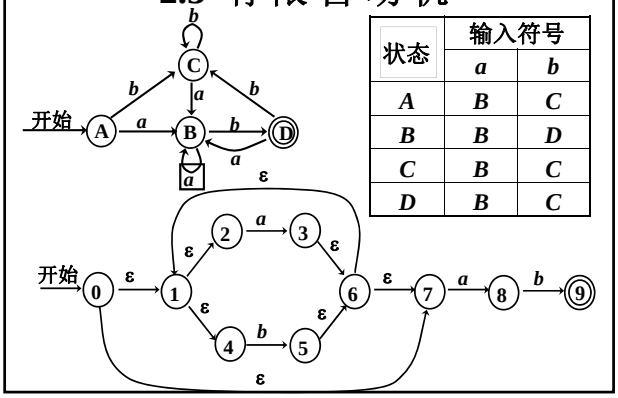

状态	输入符号	
	a	*b*
A	*B*	*C*
B	*B*	*D*
C	*B*	*C*
D	*B*	*C*

2.3 有限自动机

识别语言 $(a|b)^*ab$ 的自动机

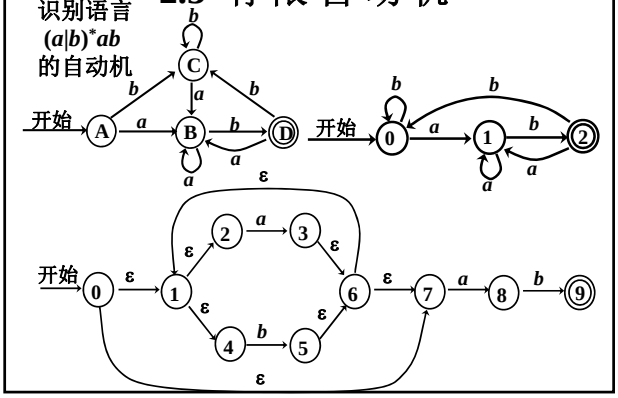

2.3 有限自动机

识别语言 $(a|b)^*ab$ 的自动机

子集构造法不一定得到最简DFA

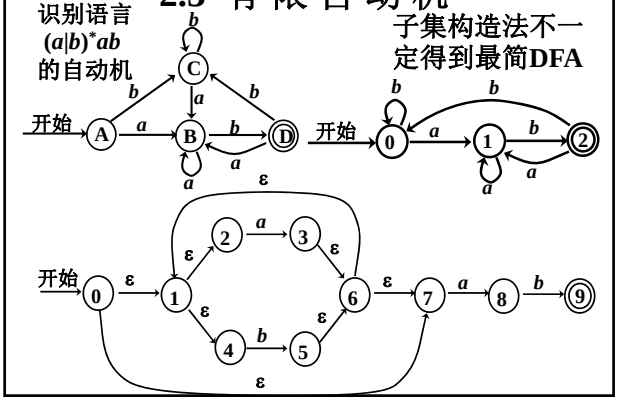

2.3 有限自动机

2.3.4 DFA的化简

- 死状态
  - 在转换函数由部分函数改成全函数表示时引入
  - 左图需要引入死状态E；右图无须引入死状态

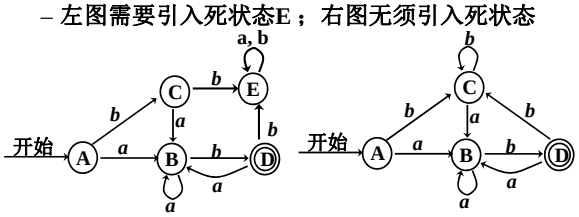

2.3 有限自动机

- 可区别的状态
  - A和B是可区别的状态

    从A出发，读过串b，到达非接受状态C，而从B出发，读过串b，到达接受状态D
  - A和C是不可区别的状态

    无任何串可用来像上面这样区别它们

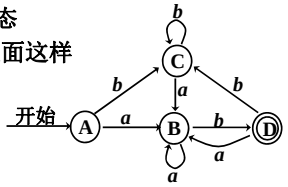

2.3 有限自动机

- 方法

  1. {A, B, C}, {D}

     move({A, B, C}, *a*) = {B}

     move({A, B, C}, *b*) = {C, D}

  2. {A, C}, {B}, {D}

     move({A, C}, *a*) = {B}

     move({A, C}, *b*) = {C}

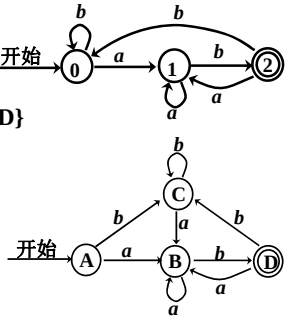

2.4 从正规式到有限自动机

- 从正规式建立识别器的步骤
  - 从正规式构造NFA（本节介绍）
    用语法制导的算法，它用正规式语法结构来指导构造过程
  - 把NFA变成DFA（子集构造法，已介绍）
  - 将DFA化简 （合并不可区别的状态，也已介绍）

2.4 从正规式到有限自动机

- 首先构造识别ε和字母表中一个符号的NFA
  重要特点：仅一个接受状态，它没有向外的转换

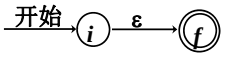

识别正规式ε的NFA

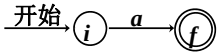

识别正规式*a*的NFA

2.4 从正规式到有限自动机

- 构造识别主算符为选择的正规式的NFA
  重要特点：仅一个接受状态，它没有向外的转换

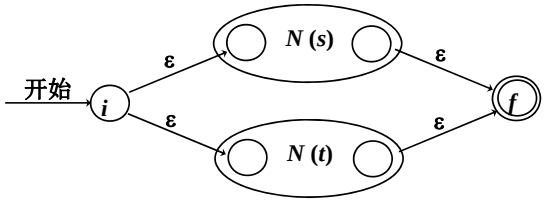

识别正规式*s* | *t* 的NFA

2.4 从正规式到有限自动机

- 构造识别主算符为连接的正规式的NFA
  重要特点：仅一个接受状态，它没有向外的转换

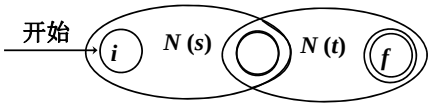

识别正规式 *st* 的NFA

2.4 从正规式到有限自动机

- 构造识别主算符为闭包的正规式的NFA
  重要特点：仅一个接受状态，它没有向外的转换

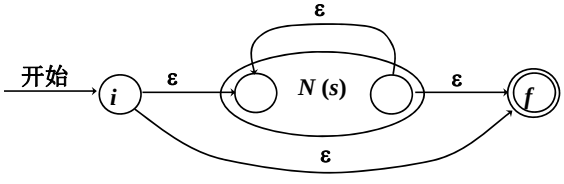

识别正规式 s^* 的NFA

2.4 从正规式到有限自动机

- 对于加括号的正规式(*s*)，使用*N*(*s*)本身作为它的NFA

2.4 从正规式到有限自动机

- 本方法产生的NFA有下列性质
  - *N*(*r*)的状态数最多是*r* 中符号和算符总数的两倍
  - *N*(*r*)只有一个接受状态，接受状态没有向外的转换

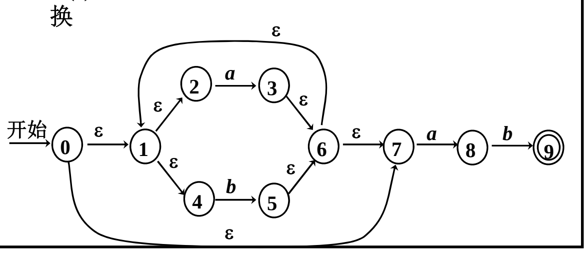

2.4 从正规式到有限自动机

- 本方法产生的NFA有下列性质
  - *N*(*r*)的每个状态有一个用Σ的符号标记的指向其他状态的转换，或者最多两个指向其他状态的ε转换

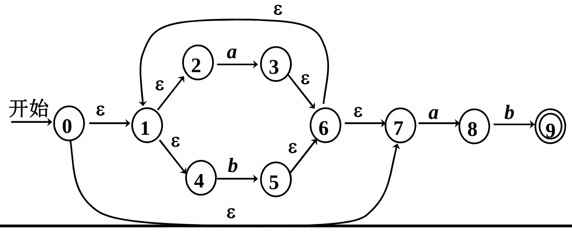

2.4 从正规式到有限自动机

$(a|b)^*ab$的分解

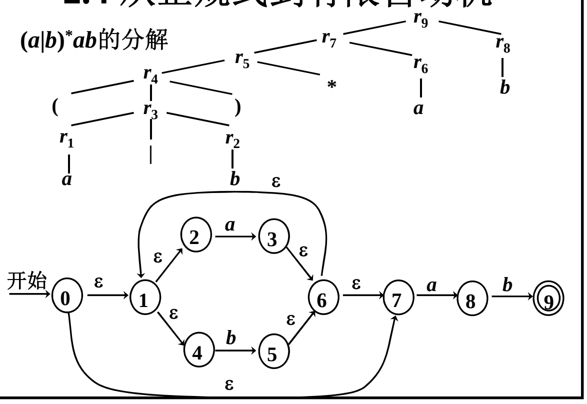

2.4 从正规式到有限自动机

$(a|b)^*ab$的分解

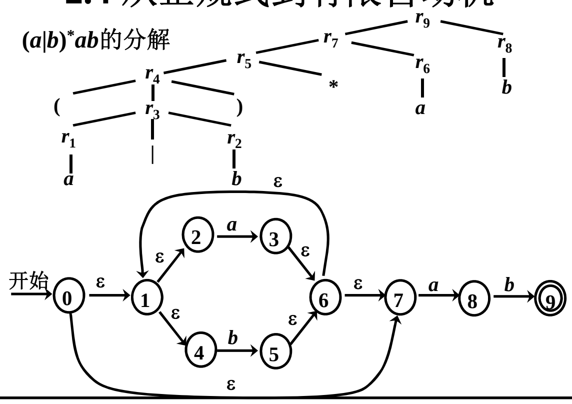

2.4 从正规式到有限自动机

$(a|b)^*ab$的分解

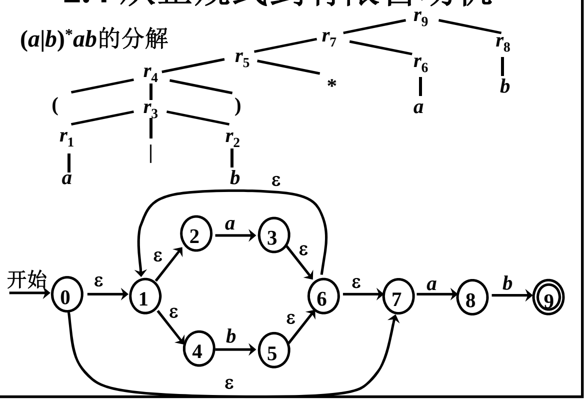

2.4 从正规式到有限自动机

$(a|b)^*ab$的分解

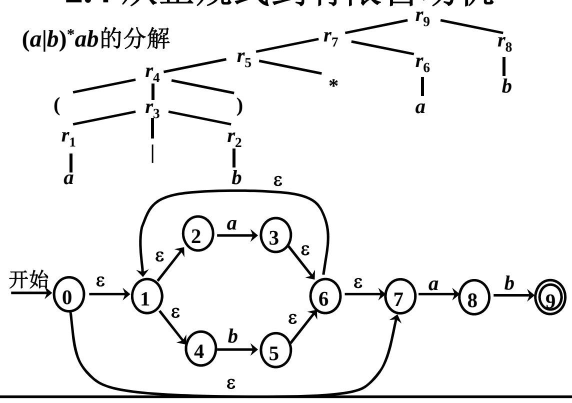

2.4 从正规式到有限自动机

(*a*|*b*)**ab***的分解

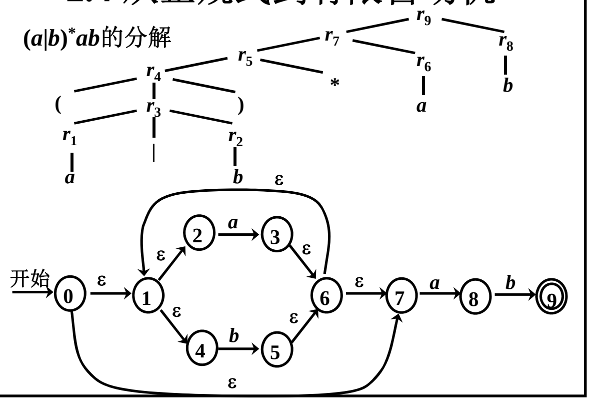

2.4 从正规式到有限自动机

(*a*|*b*)**ab***的分解

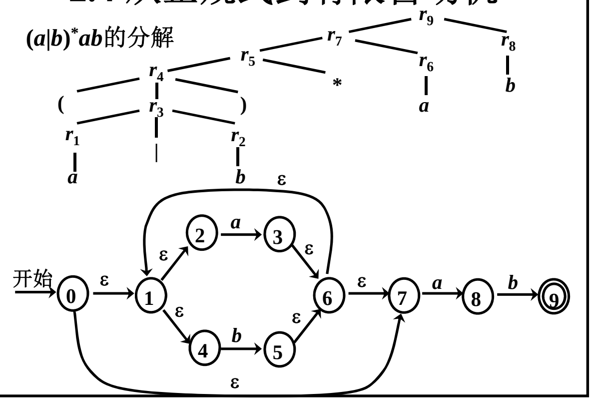

2.4 从正规式到有限自动机

(*a*|*b*)**ab***的分解

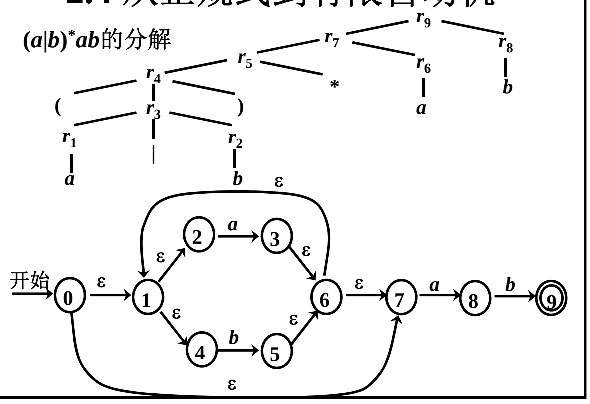

2.4 从正规式到有限自动机

- **(*a*|*b*)****ab***的两个**NFA**的比较

手工构造:

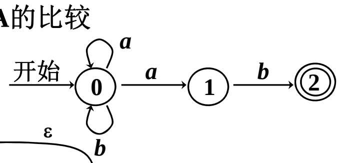

算法构造:

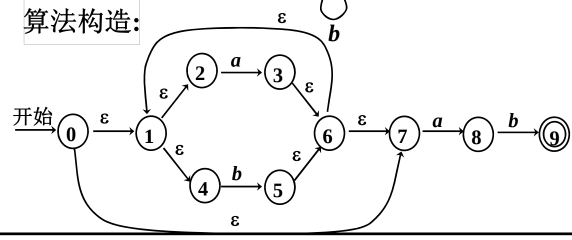

2.4 从正规式到有限自动机

- 例 **DFA**, 接受 **0**和**1**的个数都是偶数的字符串

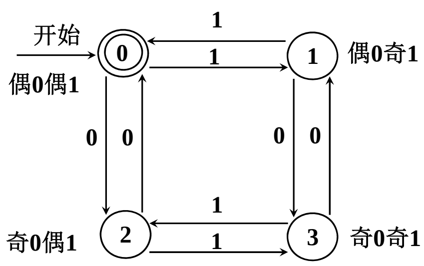

2.4 从正规式到有限自动机

- 小结：从正规式建立识别器的步骤
  - 从正规式构造**NFA**
  - 把**NFA**变成**DFA**
  - 将**DFA**化简
- 存在其他办法

2.5 词法分析器的生成器

- 用Lex建立词法分析器的步骤

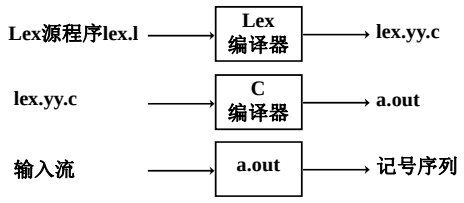

2.5 词法分析器的生成器

- Lex程序包括三个部分
  声明
  %%
  翻译规则
  %%
  辅助过程
- Lex程序的翻译规则

p_1	{动作1}
p_2	{动作2}
…	…
p_n	{动作n}

2.5 词法分析器的生成器

- 例——声明部分

```
%{
/* 常量LT, LE, EQ, NE, GT, GE, WHILE, DO, ID,
   NUMBER, RELOP的定义*/
%}
/* 正规定义 */
delim       [ \t \n ]
ws          {delim}+
letter      [A –Za – z]
digit       [0–9]
id          {letter}({letter}|{digit})*
number      {digit}+(\ .{digit}+)?(E[+\–]?{digit}+)?
```

2.5 词法分析器的生成器

- 例——翻译规则部分

```
{ws}        {/* 没有动作，也不返回 */}
while       {return (WHILE);}
do          {return (DO);}
{id}        {yylval = installId ( ); return (ID);}
{number}    {yylval = installNum( ); 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);}
```

2.5 词法分析器的生成器

- 例——辅助过程部分

```
installId( ) {
        /* 把词法单元装入符号表并返回指向它的指针。
        yytext指向该词法单元的第一个字符，
        yyleng给出它的长度              */
}

installNum ( ) {
        /* 类似上面的过程，但词法单元不是标识符
         而是数 */
}
```

本 章 要 点

- 词法分析器的作用和接口，用高级语言编写词法分析器等内容
- 掌握下面涉及的一些概念，它们之间转换的技巧、方法或算法
  - 非形式描述的语言 ↔ 正规式
  - 正规式 → NFA
  - 非形式描述的语言 ↔ NFA
  - NFA → DFA
  - DFA → 最简DFA
  - 非形式描述的语言 ↔ DFA（或最简DFA）

例 题 1

- 叙述下面的正规式描述的语言，并画出接受该语言的最简DFA的状态转换图

  (1|01)* 0*

  - 描述的语言是：所有不含子串001的0和1的串

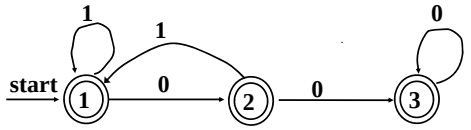

刚读过的不是0　　连续读过一个0　　连续读过不少于两个0

例 题 2

- 用状态转换图表示接受(a|b)*a(a|b)(a|b)的DFA

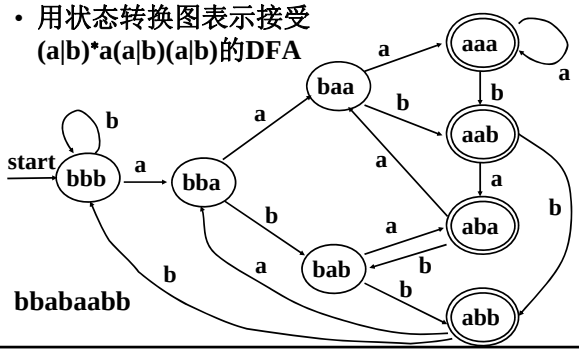

bbabaabb

例 题 3

- 写出语言“所有相邻数字都不相同的非空数字串”的正规定义

1230313571067980357901 23

answer → **(0 | *no_0* 0) (*no_0* 0)* (*no_0* | ε) | *no_0***
no_0 → **(1 | *no_0-1* 1) (*no_0-1* 1)* (*no_0-1* | ε) | *no_0-1***
. . .
no_0-8 → **9**

将这些正规定义逆序排列就是答案

例 题 4

下面C语言编译器编译下面的函数时，报告

parse error before ‘else’

```
long gcd(p,q)
long p,q;
{
   if (p%q == 0)
        /* then part */
        return q              此处遗漏分号
   else
        /* else part */
        return gcd(q, p%q);
}
```

例 题 4

现在少了第一个注释的结束符号后，反而不报错了

```
long gcd(p,q)
long p,q;
{
   if (p%q == 0)
        /* then part
        return q
   else
        /* else part */
        return gcd(q, p%q);
}
```