中国科学技术大学
University of Science and Technology of China

词 法 分 析

《编译原理和技术》

张昱

0551-63603804，yuzhang@ustc.edu.cn

中国科学技术大学

计算机科学与技术学院

本章内容

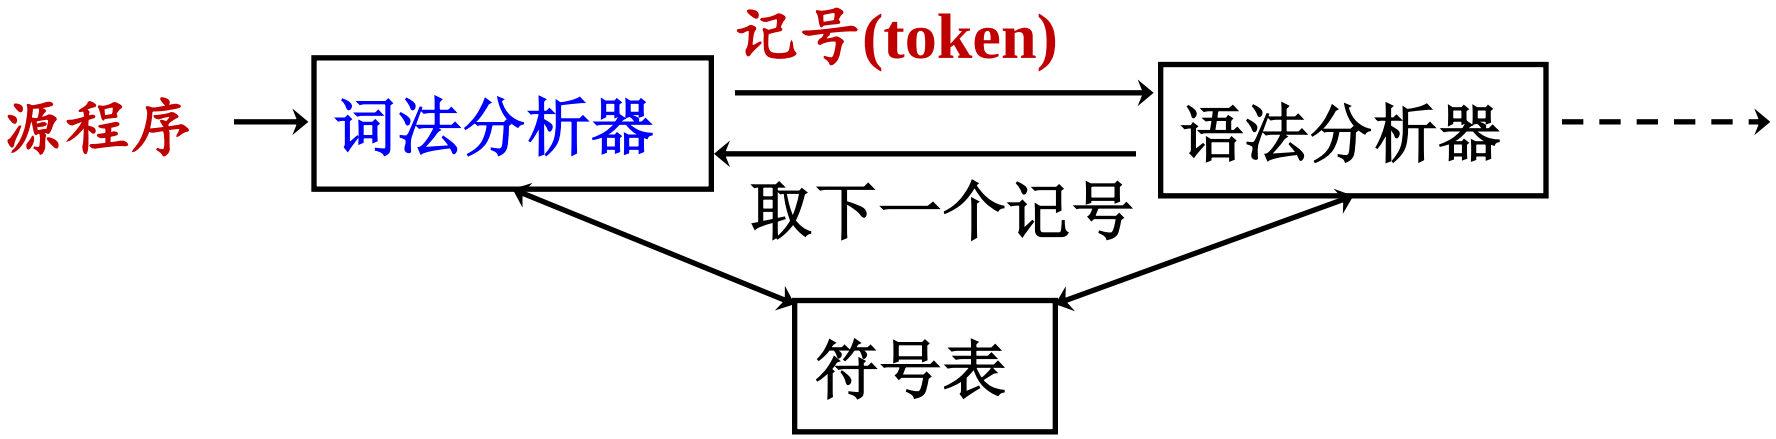

- 词法分析及问题
  - 向前看(Lookahead)、歧义(Ambiguities)
- 词法分析器的自动生成
  - 词法记号的描述：正规式；词法记号的识别：转换图
  - 有限自动机：NFA、DFA

中国科学技术大学
University of Science and Technology of China

2.1 词法记号及属性

- 记号、词法单元、模式

词法记号、模式、词法单元

记号名	词法单元举例	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”之间任意不含引号本身的字符串
whitespace	换行符	换行符\n

无意义，被丢弃，
不提供给语法分析器

词法定义中的问题

- 关键字、保留字
  - 关键字(keyword)：有专门的意义和用途，如if 、else
  - 保留字：有专门的意义，不能当作一般的标识符使用
    例如，C语言中的关键字是保留字
- 历史上词法定义中的一些问题
  - 忽略空格带来的困难，例如 Fortran

    DO 8 I = 3. 75　等同于　DO8I = 3. 75

    DO 8 I = 3, 75
  - 关键字不保留

    IF THEN THEN THEN=ELSE; ELSE …

歧义和lookahead

- 词法分析
  - 从左到右读取输入串，每次识别出一个token
  - 可能需要“lookahead”来判断当前是否是一个token的结尾、下一个token的开始（尤其是在Fortran语言中）

```
DO 5 I = 1
DO 5 I = 1.25
DO 5 I = 1, 25
```

```
if (then .gt. else) then
        then = else
else
        else = then
endif
```

词法分析器：实现

一个词法分析器的实现必须做两件事

1. 识别子串并对应到 tokens

2. 返回token的值或词法单元(lexeme)
   - 词法单元是子串（token的实例）

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⟩

中国科学技术大学
University of Science and Technology of China

2.2 词法记号的描述与识别

- 描述：正规式
- 识别：转换图

串和语言

- 术语
  - 字母表：符号的有限集合， 例：$\sum = \{0, 1\}$
  - 串：符号的有穷序列，例：0110， ε
  - 语言：字母表$\sum$上的一个串集

    $\{\varepsilon, 0, 00, 000, \ldots\}$， $\{\varepsilon\}$， $\varnothing$
  - 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$s^{i-1}s$（$i > 0$）

串和语言

语言的运算

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

优先级：
幂〉连接〉并

例

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

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

正规式（regular expression）

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	$\{\varepsilon\}$	
a	$\{a\}$	$a \in \Sigma$
(r)	$L(r)$	r是正规式
$(r) \mid (s)$	$L(r) \cup L(s)$	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

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

优先级：
闭包*〉连接〉选择|

正规式举例

- $\Sigma = \{a, b\}$
  - $a \mid b$ $\{a, b\}$
  - $(a \mid b)\,(a \mid b)$ $\{aa, ab, ba, bb\}$
  - $aa \mid ab \mid ba \mid bb$ $\{aa, ab, ba, bb\}$
  - a^* 由字母a构成的所有串的集合
  - $(a \mid b)^*$ 由a和b构成的所有串的集合
- 复杂的例子

$(\ 00 \ \mid \ 11 \mid \ (\ (01 \mid 10)\ (00 \mid 11)^*\ (01 \mid 10)\ )\ )^*$

句子：01001101000010000010111001

正规定义(regular definition)

- 对正规式命名，使正规式表示简洁

$$d_1 \rightarrow r_1$$
$$d_2 \rightarrow r_2$$
$$\cdots$$
$$d_n \rightarrow r_n$$

- 各个d_i 的名字都不同
- 每个r_i 都是 $\sum \cup \{d_1, d_2, \ldots, d_{i-1}\}$ 上的正规式
- C语言的标识符是字母、数字和下划线组成的串

$$\text{letter\_} \rightarrow A \mid B \mid \ldots \mid Z \mid a \mid b \mid \ldots \mid z \mid \_$$
$$\text{digit} \rightarrow 0 \mid 1 \mid \ldots \mid 9$$
$$\text{id} \rightarrow \text{letter\_}(\text{letter\_} \mid \text{digit})^*$$

正规定义举例

- 无符号数集合，例1946, 11.28, 63E8, 1.99E–6

$$digit \rightarrow 0 \mid 1 \mid \ldots \mid 9$$
$$digits \rightarrow digit\ digit^{*}$$
$$optional\_fraction \rightarrow .digits \mid \varepsilon$$
$$optional\_exponent \rightarrow (E (+ \mid - \mid \varepsilon) digits) \mid \varepsilon$$
$$number \rightarrow digits\ optional\_fraction\ optional\_exponent$$

- 简化的表示

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

词法记号的识别：转换图

- 转换图(transition diagram)
  - 关系算符的转换图

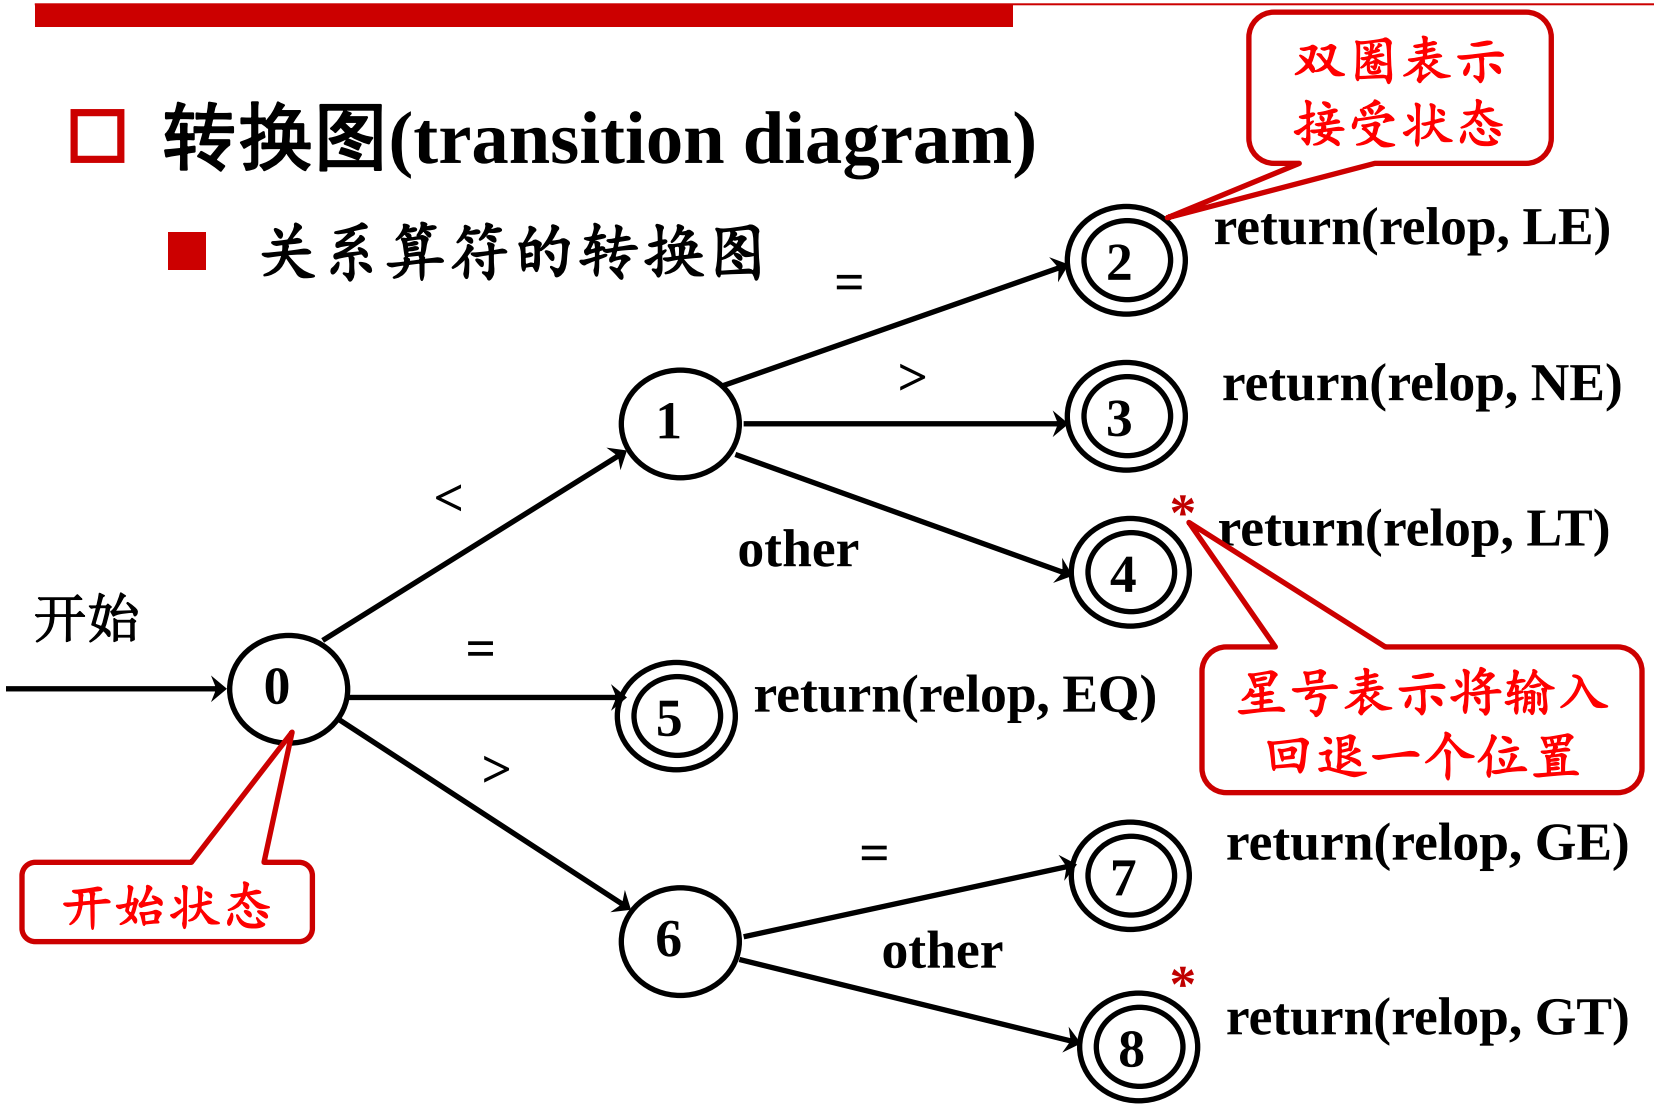

转换图

- 标识符和关键字的转换图

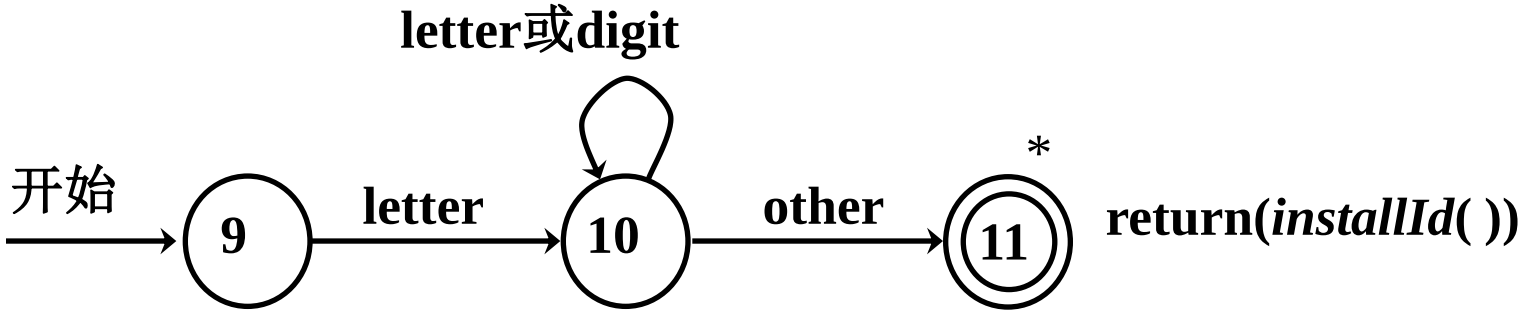

- 无符号数的转换图 number → digit⁺ (.digit⁺)? (E(+|-) ? digit⁺)?

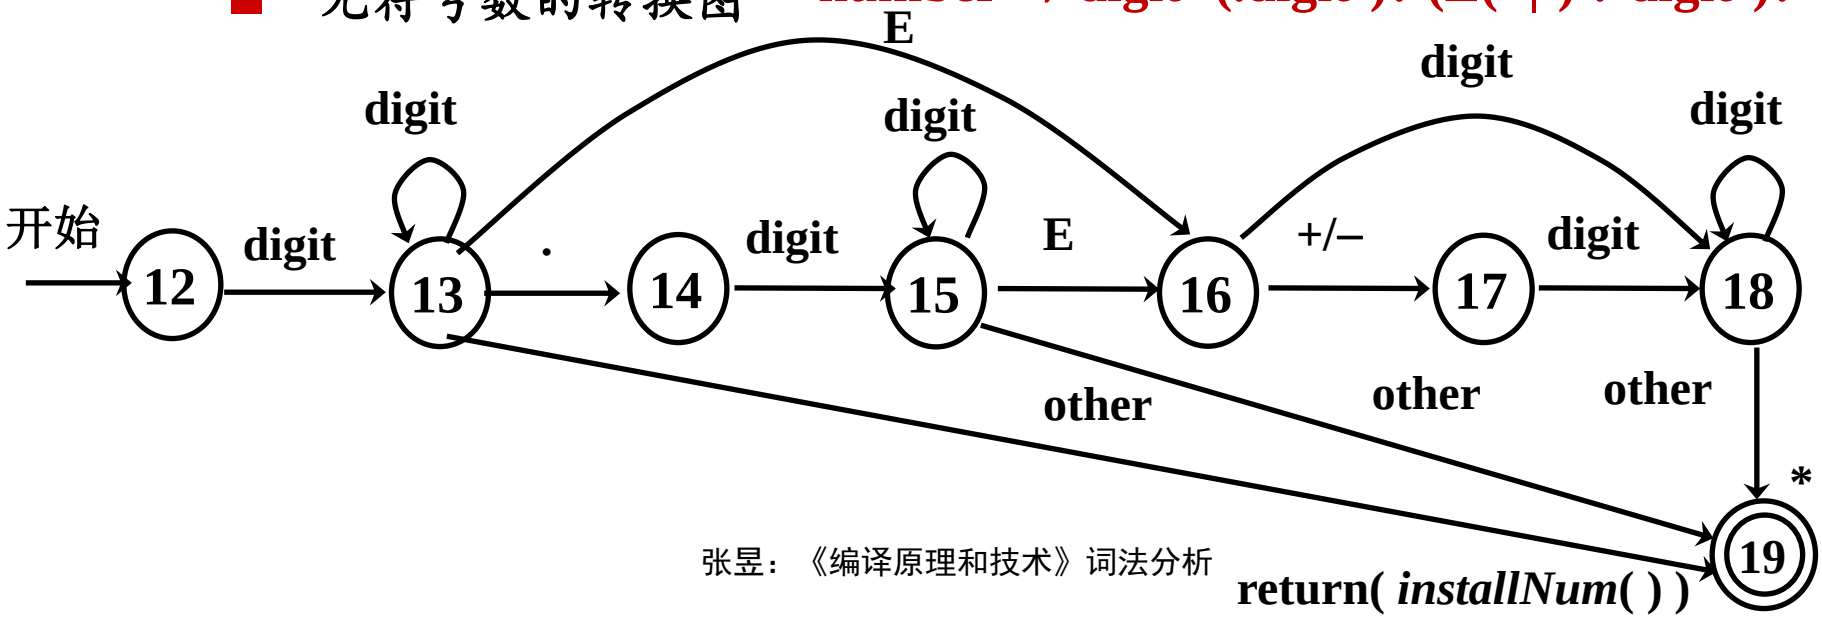

转换图

- 空白的转换图

delim → blank | tab | newline

ws → delim+

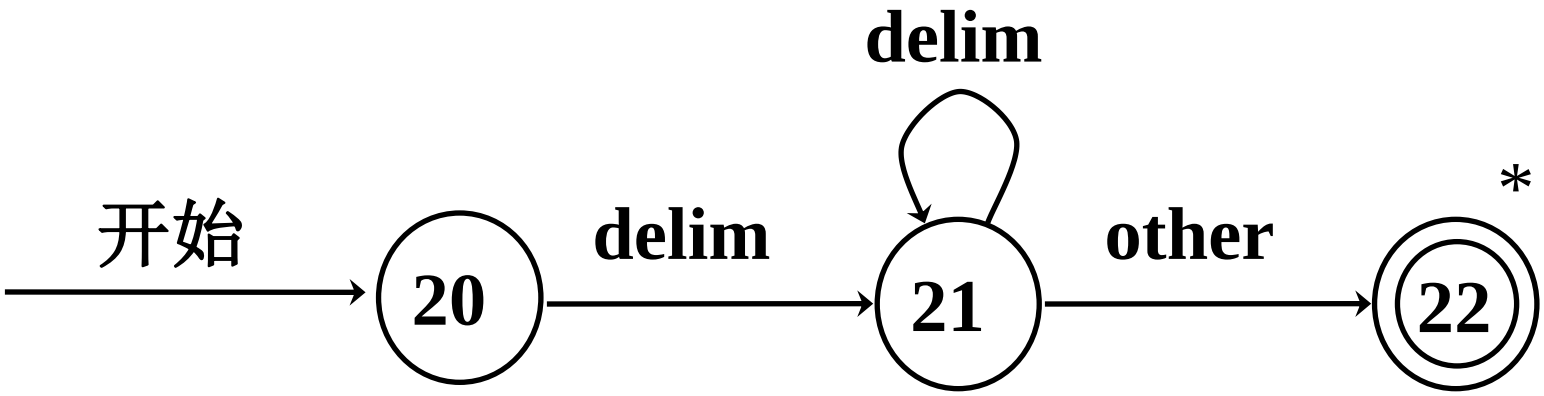

基于转换图的词法分析

- 例：relop的转换图的概要实现

```
TOKEN getRelop() {
  TOKEN retToken = new(RELOP);
  while (1) {
    switch (state) {
      case 0: c = nextChar();
        if (c == '<') state = 1;
        else if (c == '=') state = 5;
        else if (c == '>') state = 6;
        else fail();
        break;
      case 1: ...
      ...
      case 8: retract();
        retToken.attribute = GT;
        return(retToken);
    }
  }
}
```

出错处理，要能从错误恢复

回退

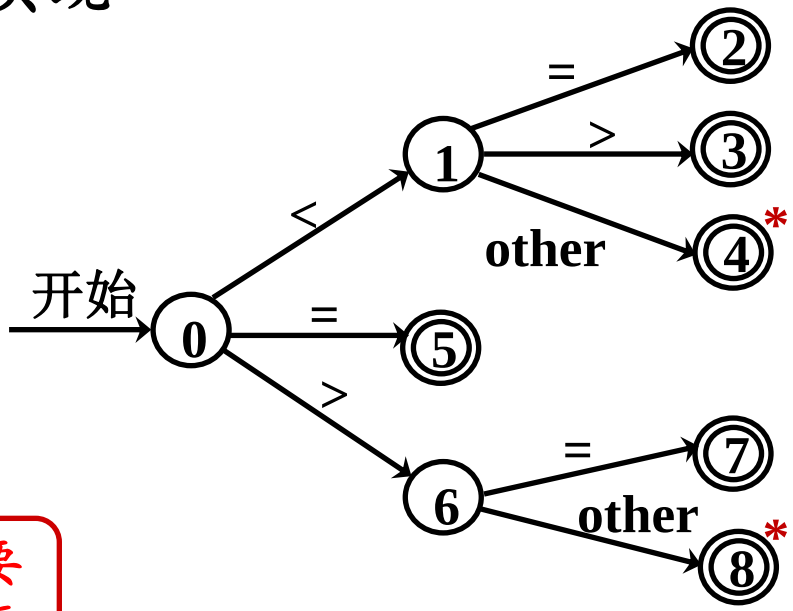

词法分析中的冲突及解决

R = Whitespace | Integer | Identifier | '+'

分析 "**foo+3**"

→ "**f**" 匹配 **R**, 更精确地说是 **Identifier**

→ 但是 "**fo**" 也匹配 **R**, "**foo**"也匹配, 但 "**foo+**"不匹配

如何处理输入？如果

→ $x_1 \ldots x_i \in L(R)$ 并且 $x_1 \ldots x_K \in L(R)$

"**Maximal munch**" 规则:

→ 选择匹配 **R** 的最长前缀

最长匹配规则在实现时：lookahead, 不符合则回退

词法分析：分类的不确定性

R = Whitespace | ‘new’ | Integer | Identifier

分析 “**new foo**”

→ “**new**” 匹配 **R**，更精确地说是 ‘**new**’

→ 但是也匹配 **Identifier**，此时该选哪个？

一般地，如果 $x_1 \ldots x_i \in L(R_j)$ 和 $x_1 \ldots x_i \in L(R_k)$

规则：选择先列出的模式 (j 如果 j < k)

→ 必须将 ‘**new**’ 列在 **Identifier** 的前面

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“数字串.数字串”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

例题 1

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

解答：

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2

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          此处遗漏了分号
   else
        /* else part */
        return gcd(q, p%q);
}
```

例题2

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);
}
```

中国科学技术大学
University of Science and Technology of China

2.3 有限自动机

- 描述分析器：NFA、DFA
- 自动机的转换
  - NFA→DFA →化简的DFA

有限自动机

不确定的有限自动机（NFA）

(nondeterministic finite automaton)

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Σ

3、转换函数$move: S \times (\Sigma \cup \{\varepsilon\}) \rightarrow P(S)$

4、状态s_0是唯一的开始状态

5、$F \subseteq S$是接受状态集合

识别语言
$(a|b)^*ab$
的NFA

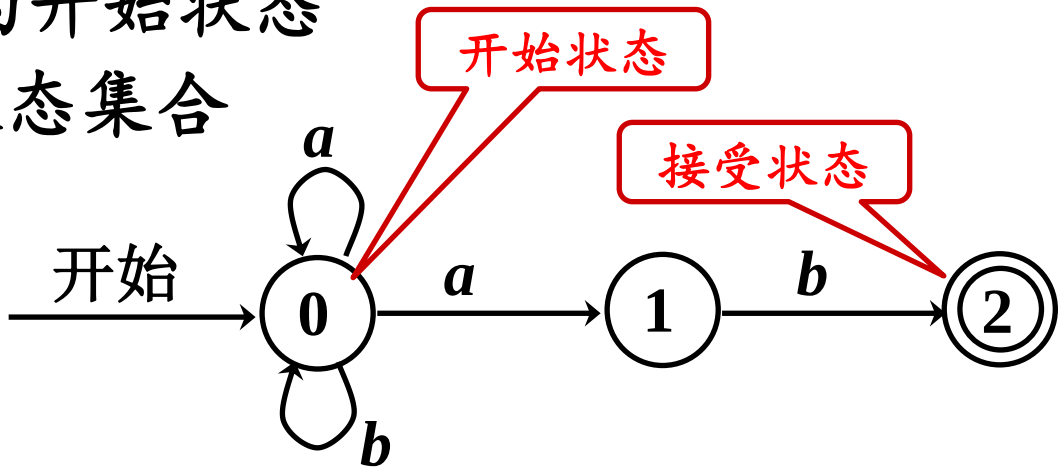

转换表

- NFA的转换表

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

识别语言
$(a|b)^*ab$
的NFA

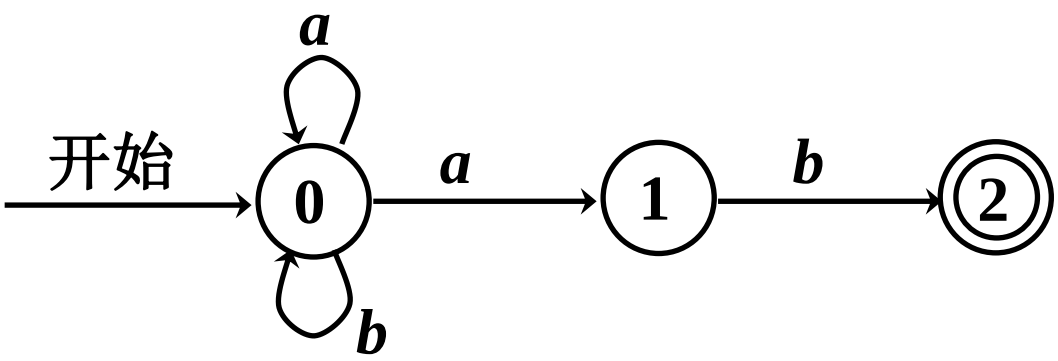

例题3

- 识别$aa^*|bb^*$的NFA

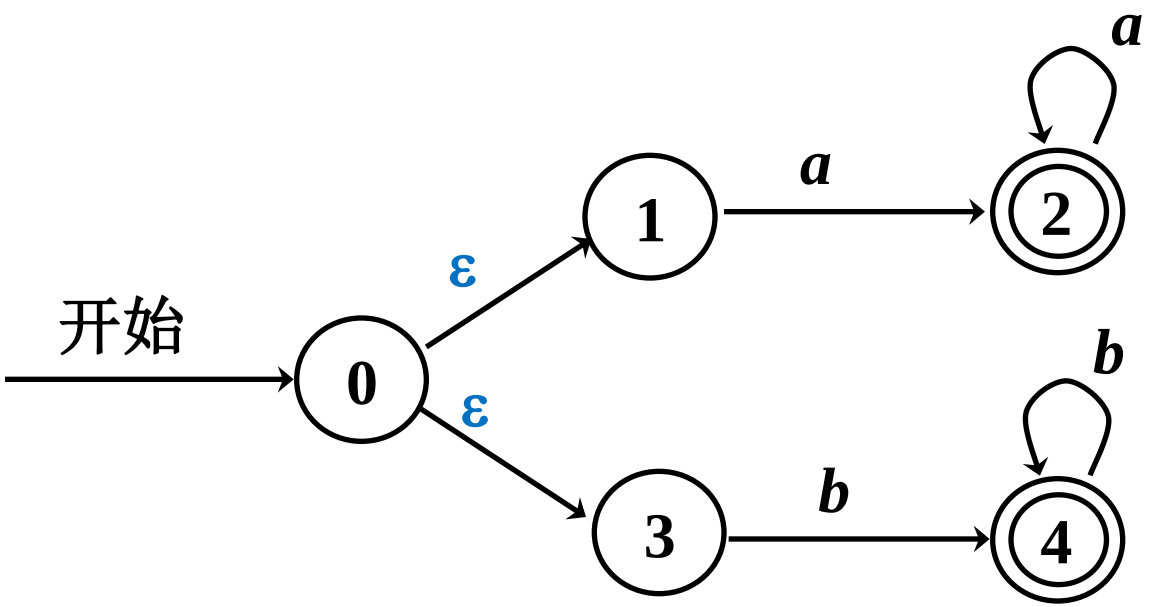

确定的有限自动机

确定的有限自动机（DFA）

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$\sum$

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

4、状态s_0是唯一的开始状态

5、$F \subseteq S$是接受状态集合

识别语言
$(a|b)^*ab$
的DFA

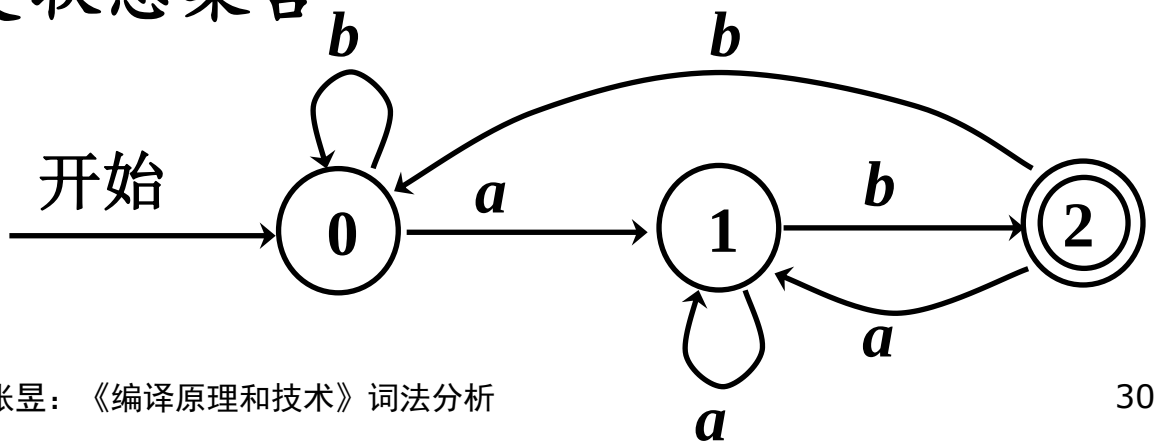

例题4

构造一个DFA，它能识别{0,1}上能被5整除的二进制数。

解答

	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

引入5个状态即可，分别代表已读部分的值除以5的余数

例题4

构造一个DFA，它能识别{0,1}上能被5整除的二进制数。

解答

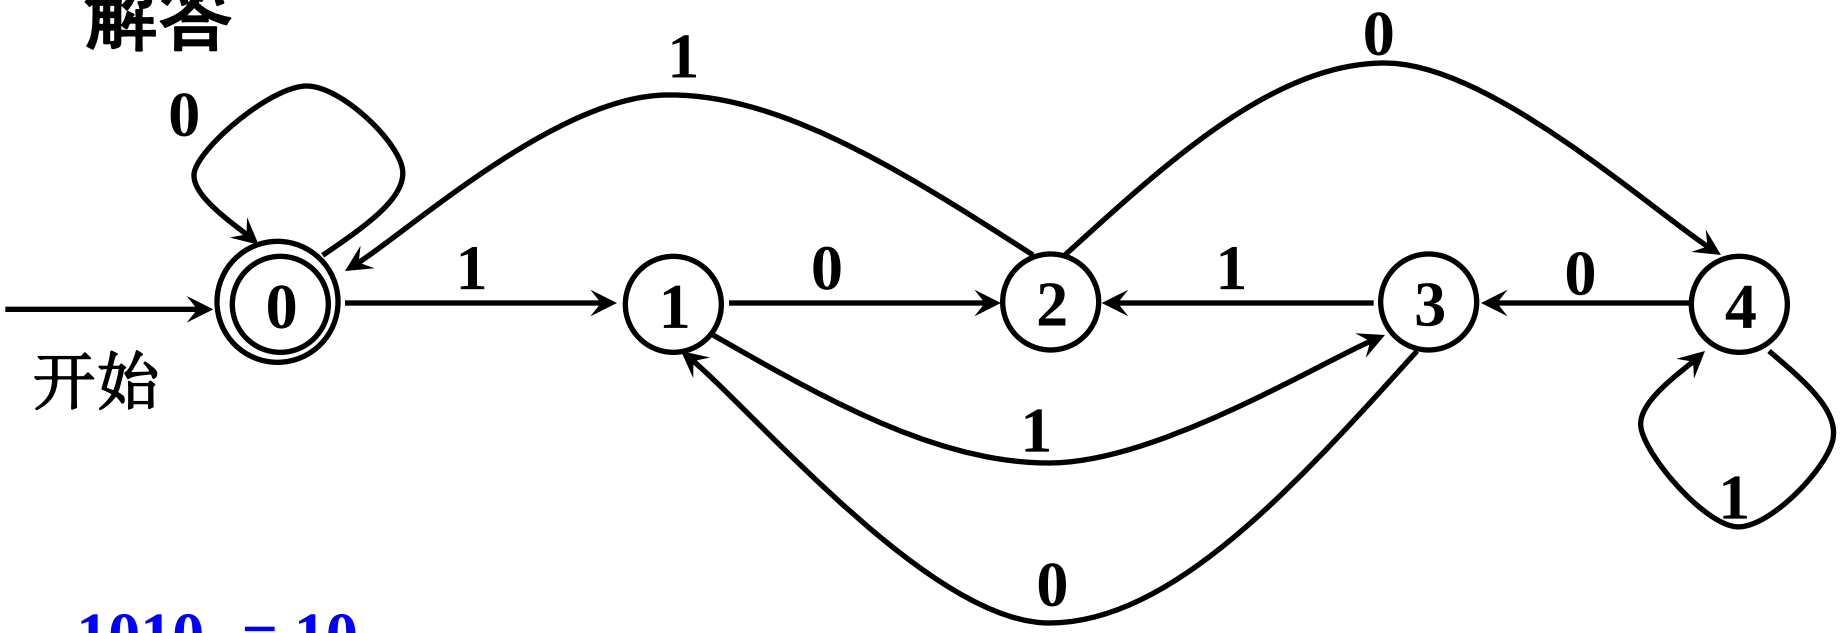

$1010_2 = 10_{10}$

$111_2 = 7_{10}$

例题5

构造一个DFA，它能接受0和1的个数都是偶数的字符串。

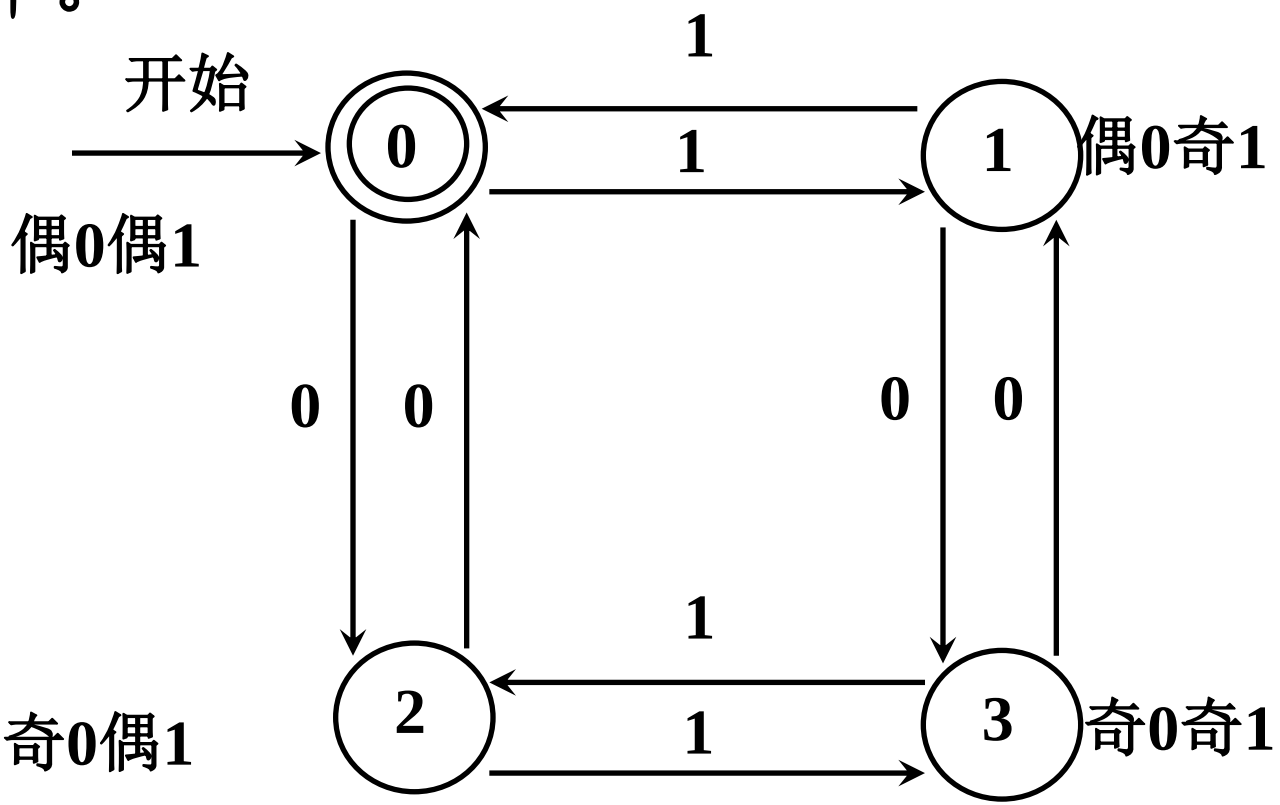

NFA到DFA的变换

子集构造法(subset construction)

1. DFA的一个状态是NFA的一个状态集合
2. 读了输入 a_i 后，
   NFA能到达的所有状态：$s_1, s_2, \ldots, s_k$，则
   DFA到达一个状态，对应于NFA的$\{s_1, s_2, \ldots, s_k\}$

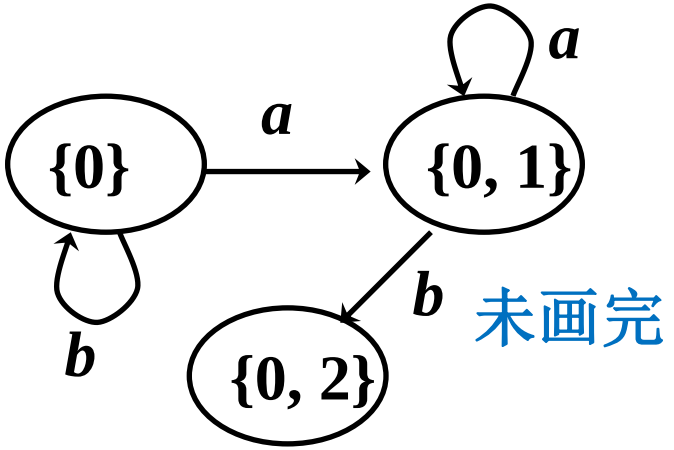

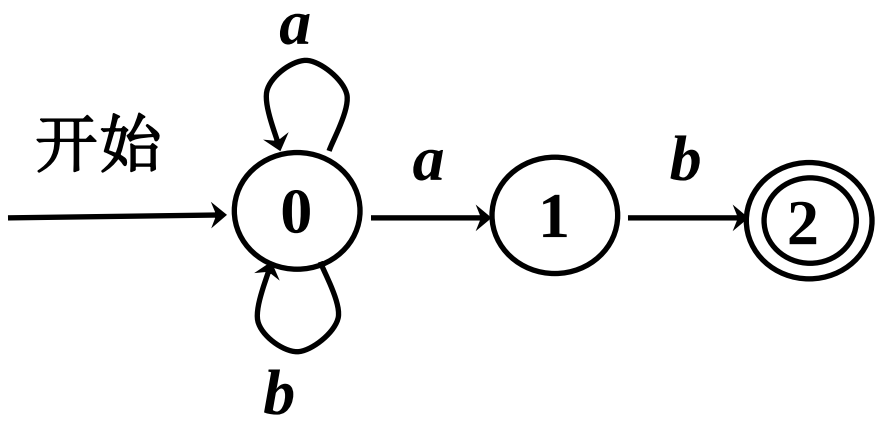

NFA到DFA的变换

- 子集构造法(subset construction)
  1. ε-闭包（ε- closure）状态s 的ε-闭包是 s 经 ε转换所能到达的状态集合
  2. NFA的初始状态的 ε-闭包对应于DFA的初始状态
  3. 针对每个DFA 状态 – NFA状态子集，求输入每个a_i后能到达的NFA状态的ε-闭包并集，该集合对应于DFA中的一个已有状态，或者是一个要新加的DFA状态

例题6

正规式 $(a|b)^*ab$ 对应的NFA如下，把它变换为DFA

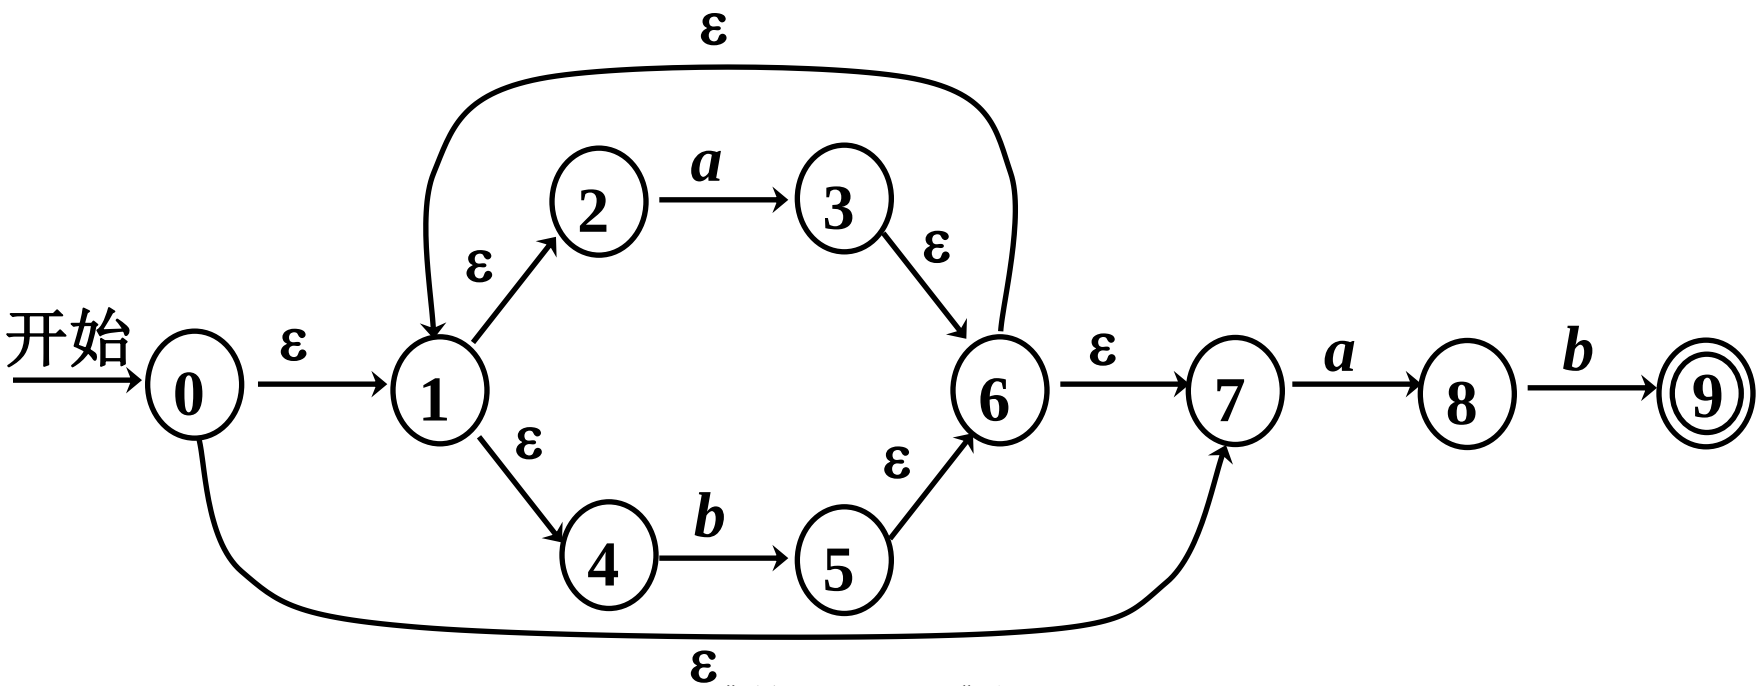

例题6

状态	输入符号	
	a	*b*

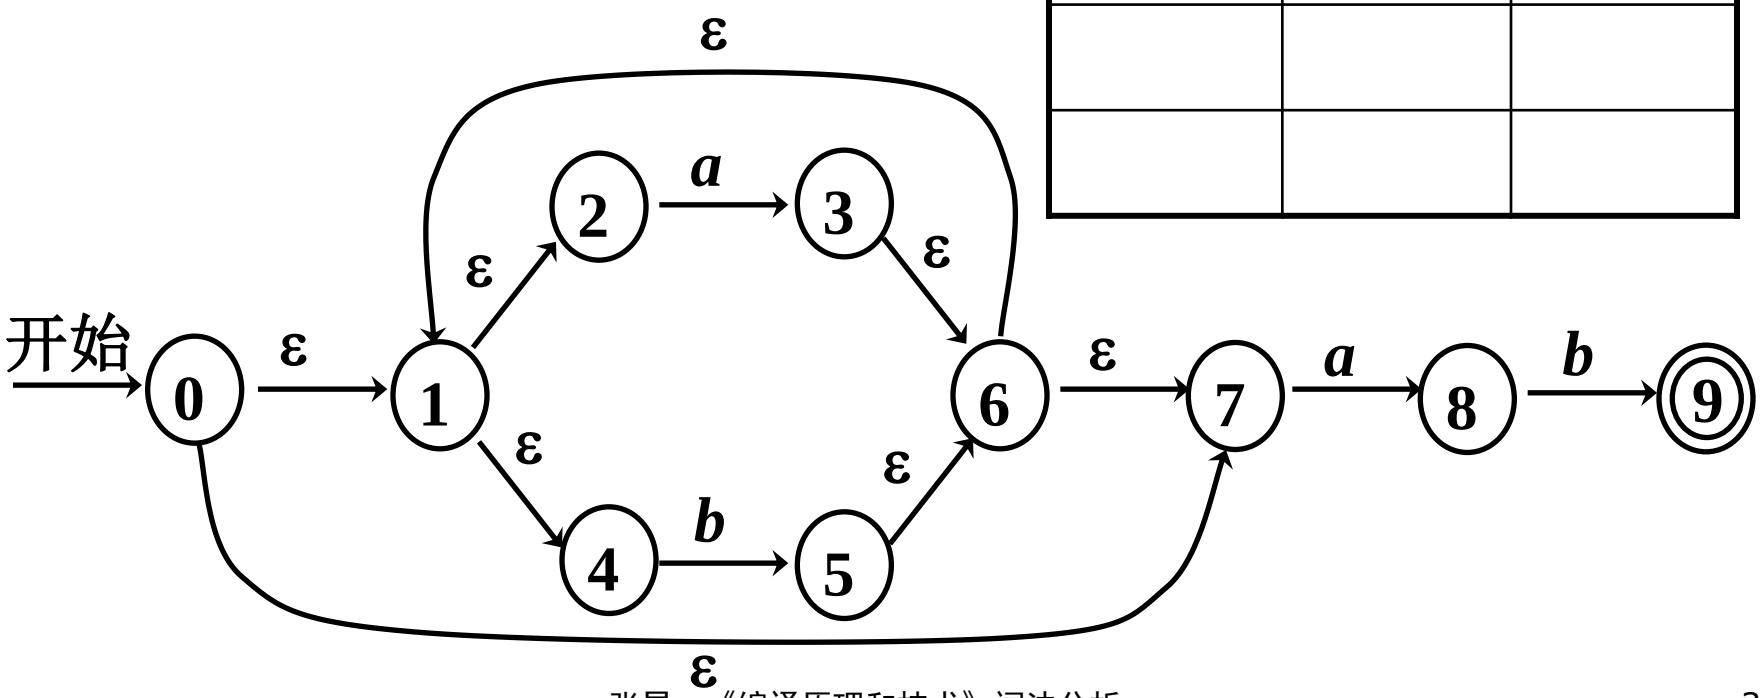

例题6

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

状态	输入符号	
	a	*b*
A		

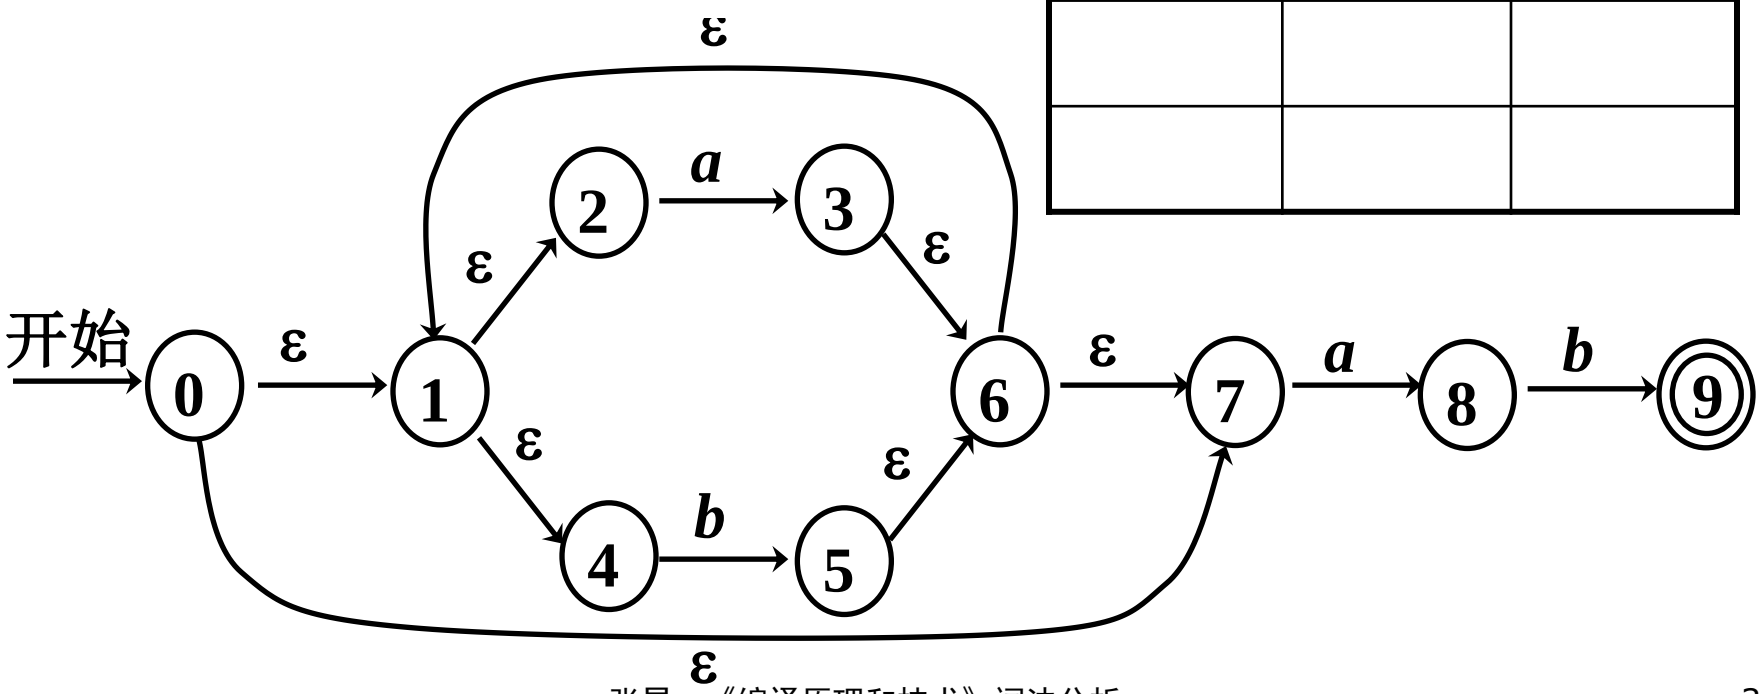

例题6

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

$B = \{1, 2, 3, 4, 6, 7, 8\}$

状态	输入符号	
	a	*b*
A	*B*	

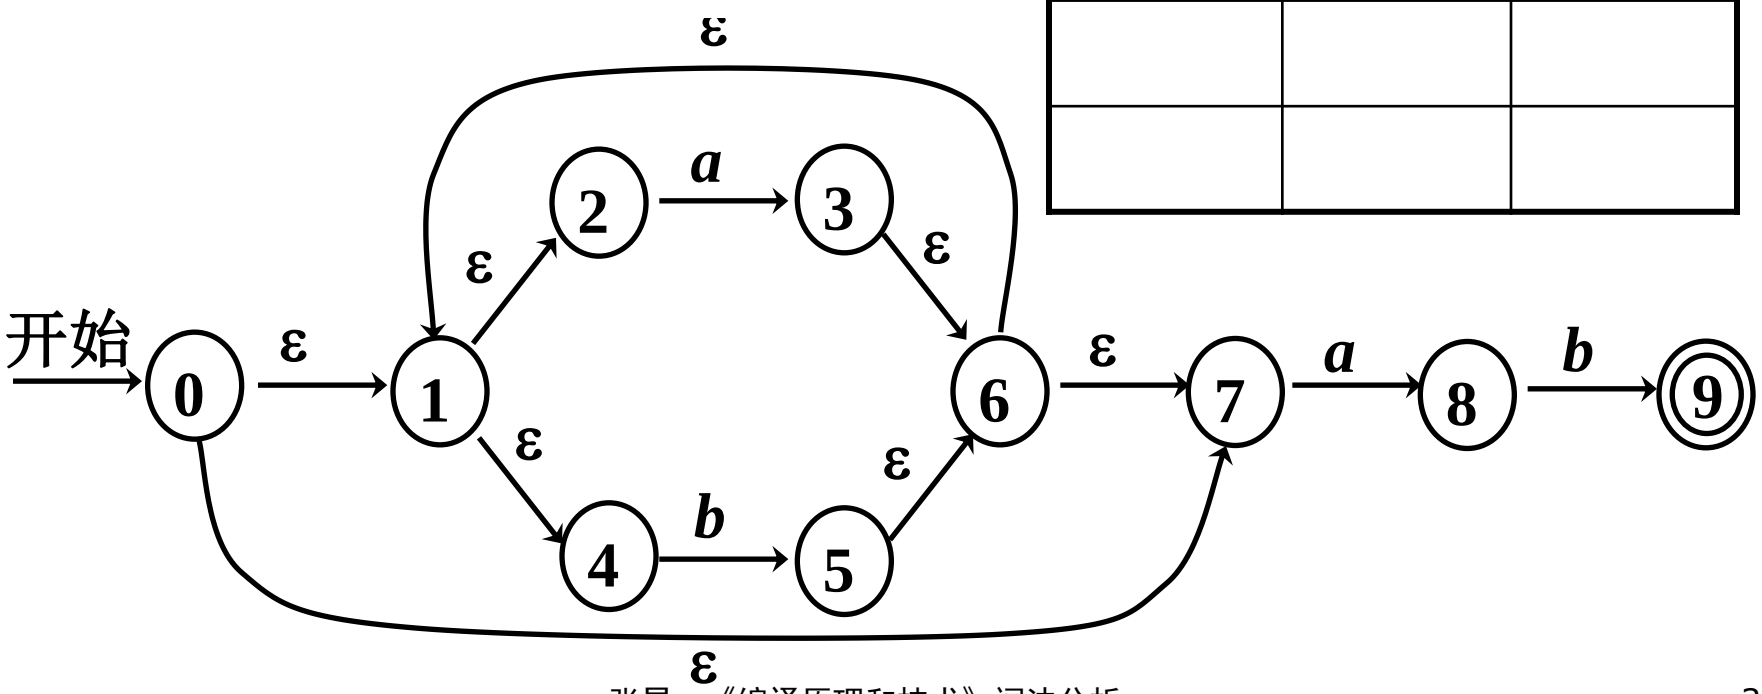

例题6

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

$B = \{1, 2, 3, 4, 6, 7, 8\}$

状态	输入符号	
	a	*b*
A	*B*	
B		

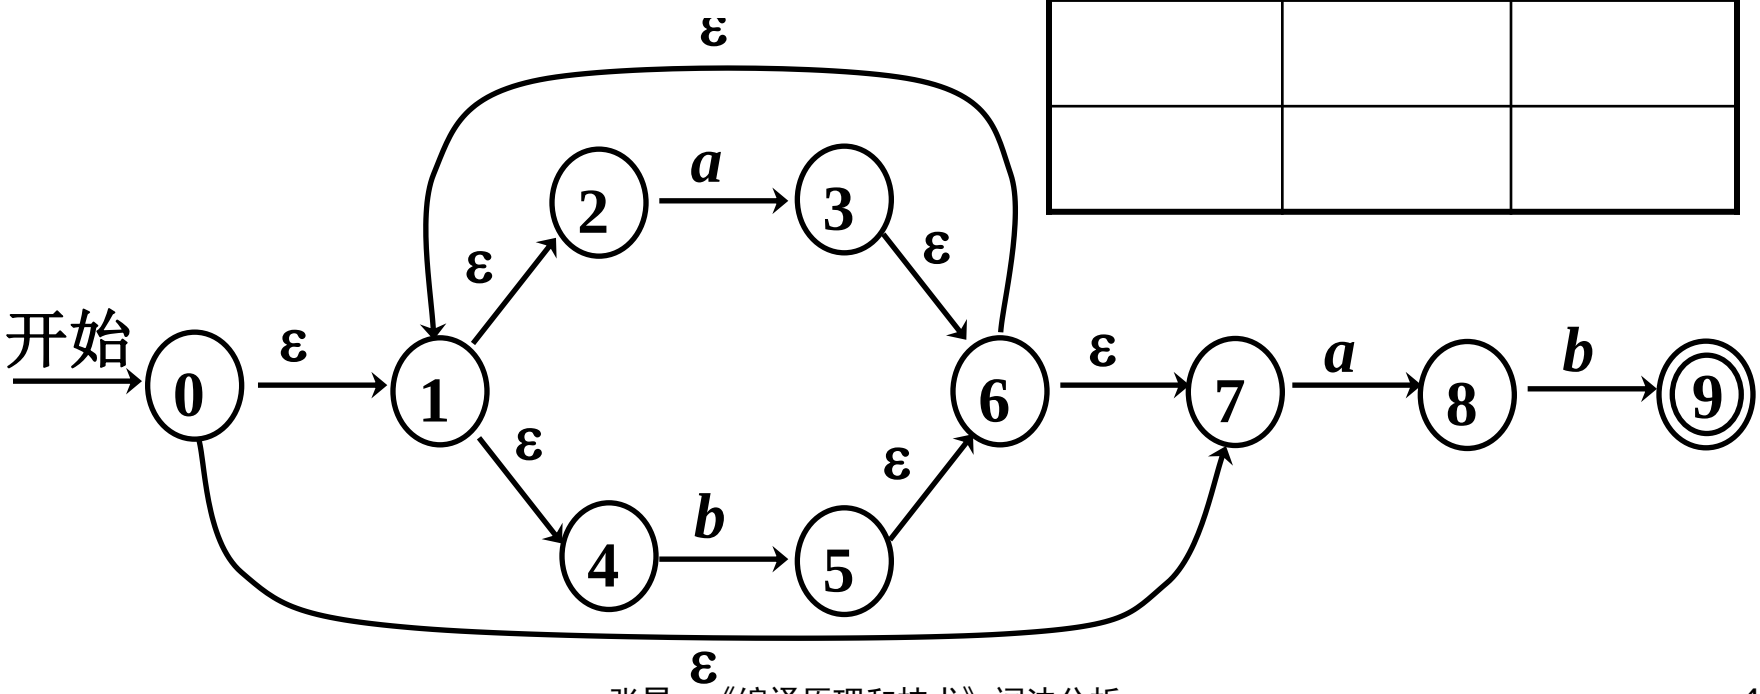

例题6

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

$B = \{1, 2, 3, 4, 6, 7, 8\}$

$C = \{1, 2, 4, 5, 6, 7\}$

状态	输入符号	
	a	*b*
A	*B*	*C*
B		

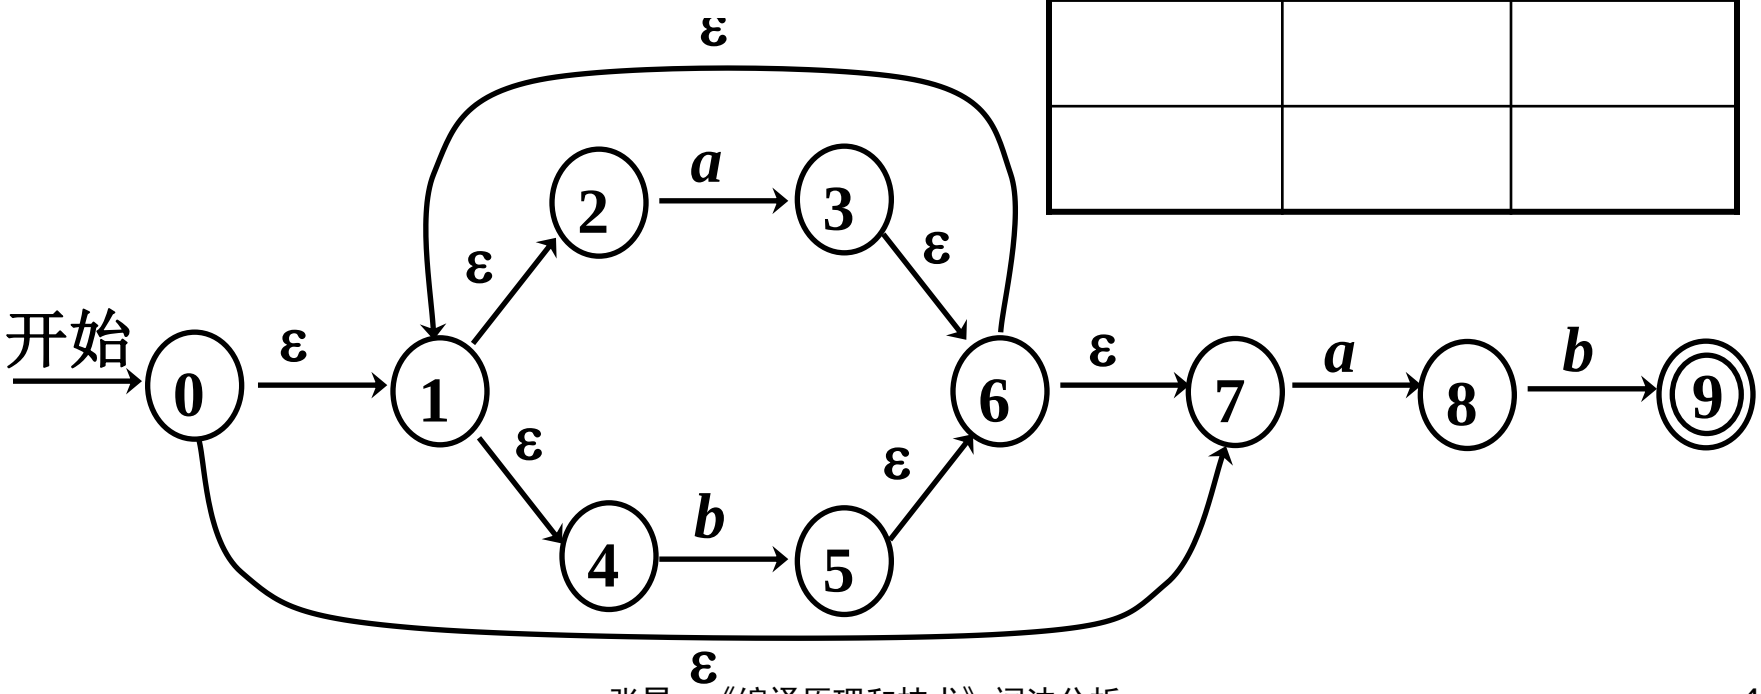

例题6

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

状态	输入符号	
	a	*b*
A	*B*	*C*
B		
C		

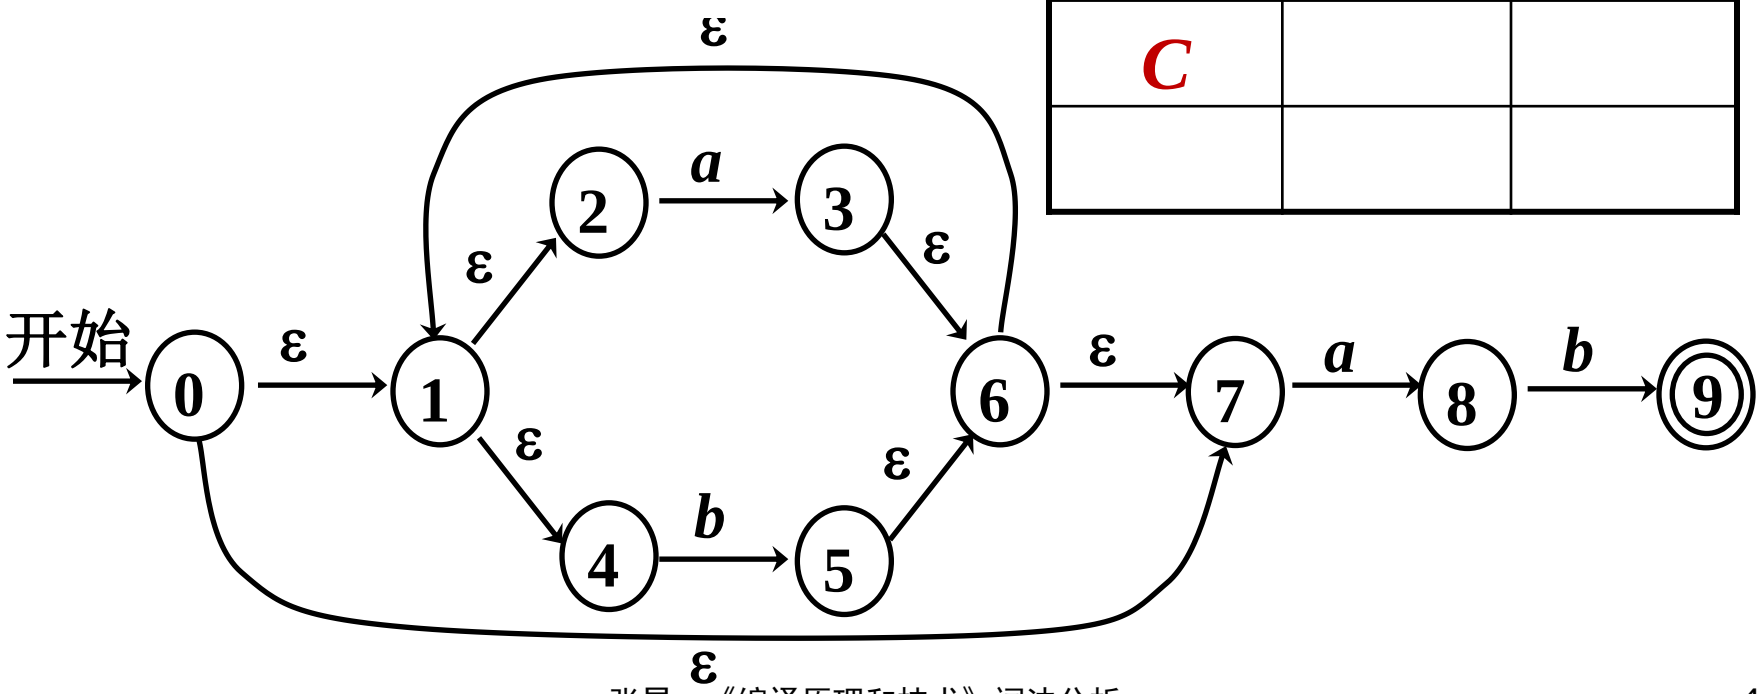

例题6

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

状态	输入符号	
	a	*b*
A	*B*	*C*
B	*B*	
C		

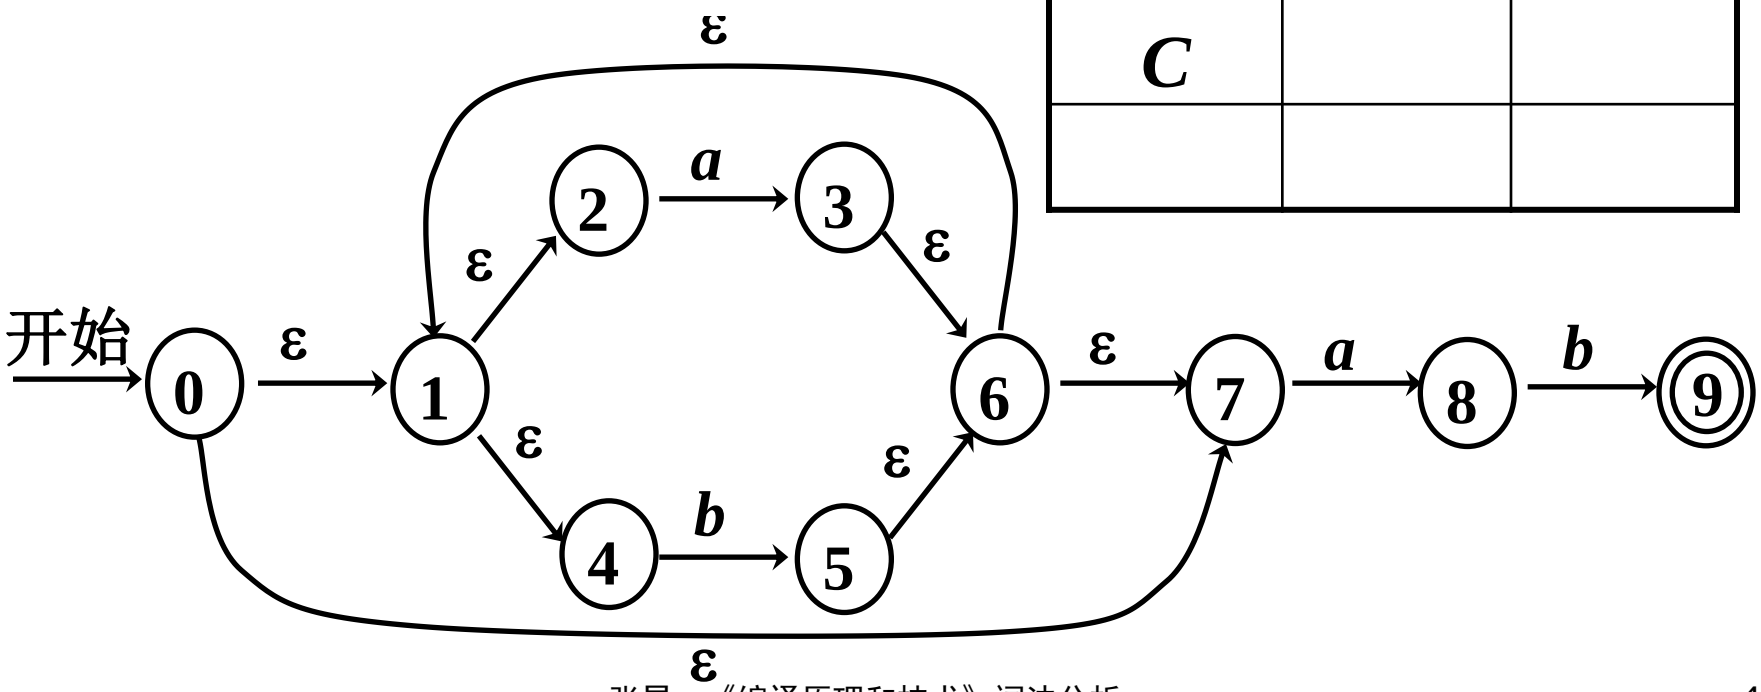

例题6

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

$B = \{1, 2, 3, 4, 6, 7, 8\}$

$C = \{1, 2, 4, 5, 6, 7\}$

$D = \{1, 2, 4, 5, 6, 7, 9\}$

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

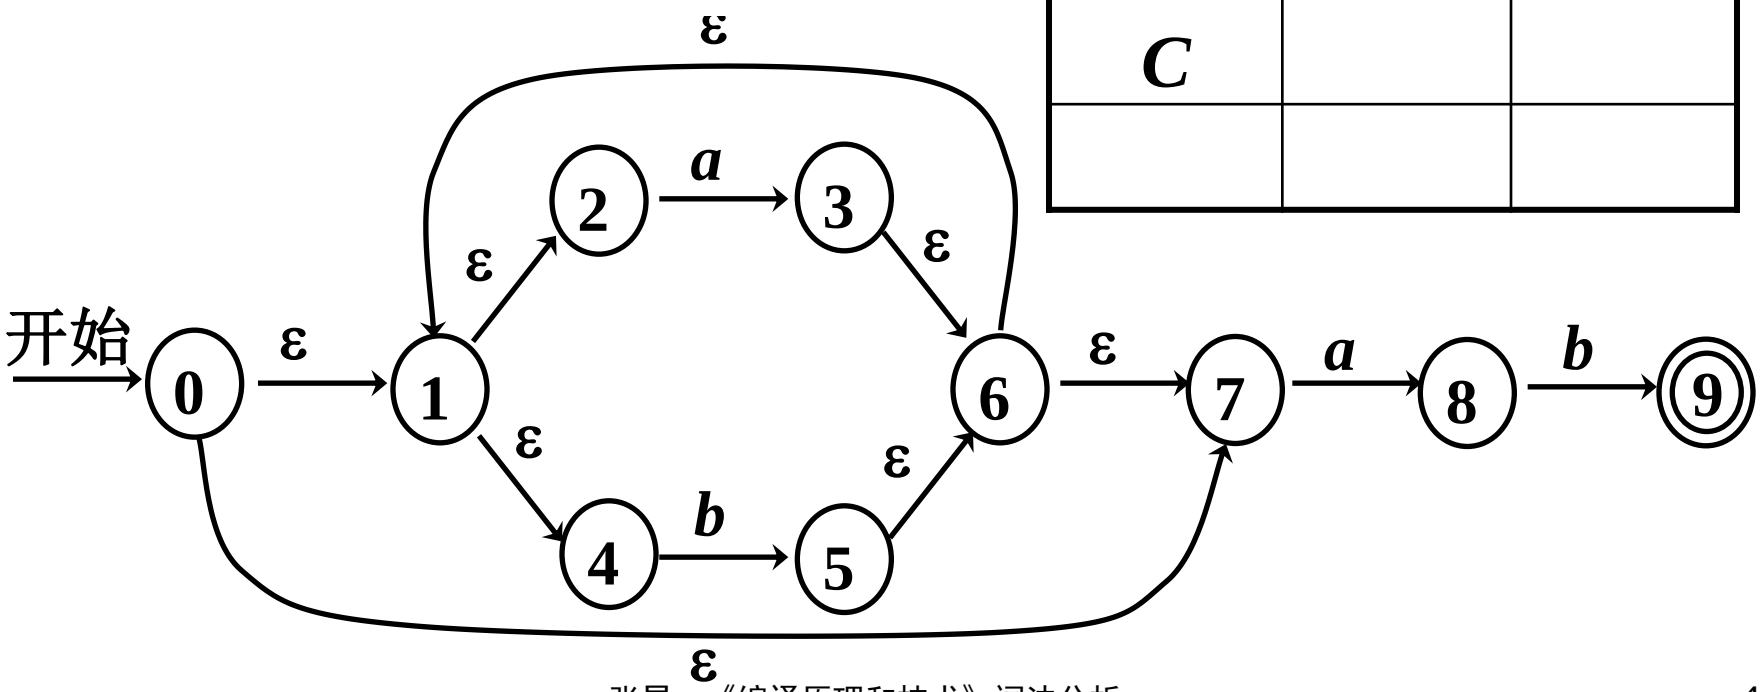

例题6

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

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

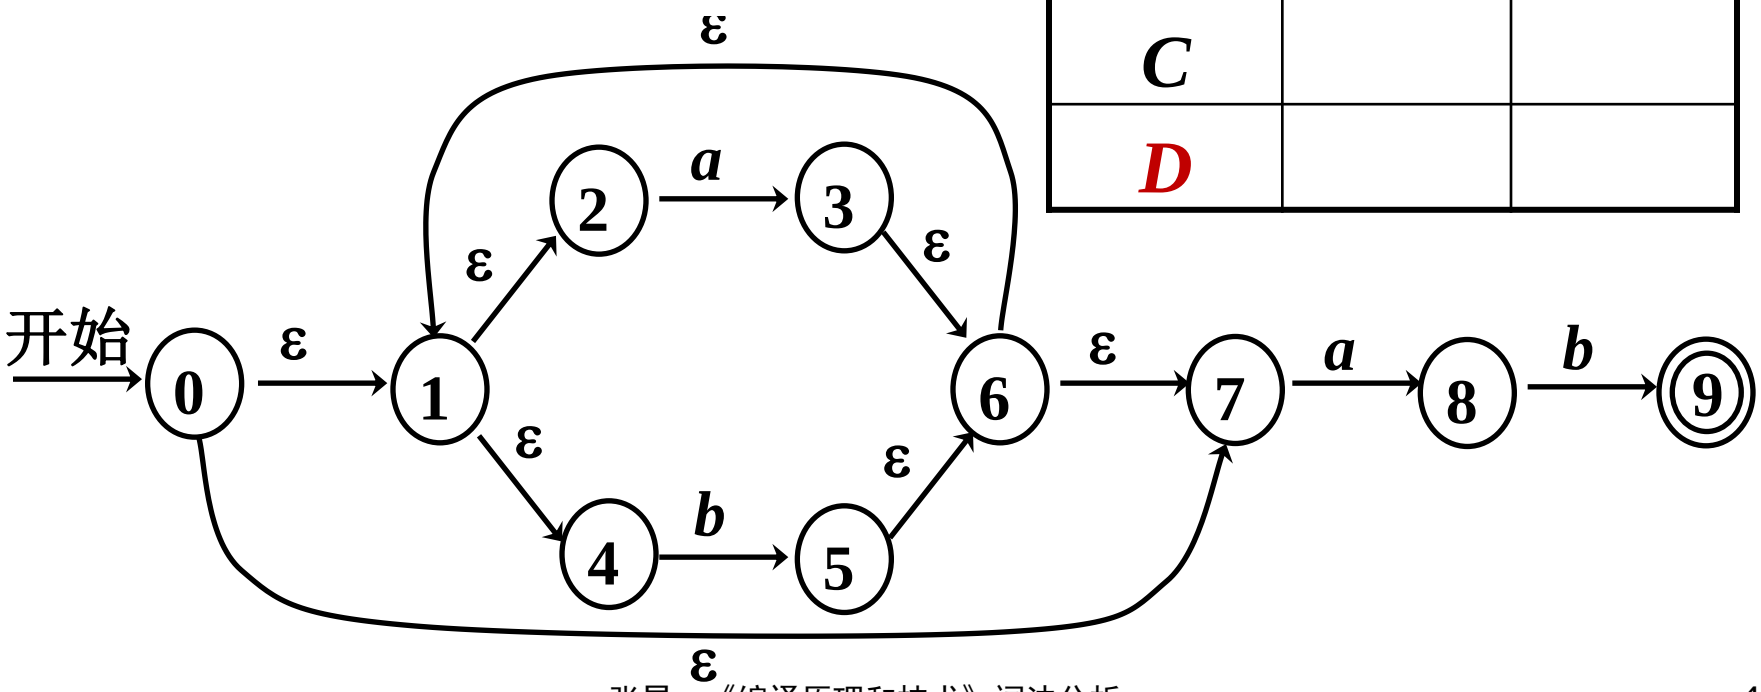

例题6

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

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

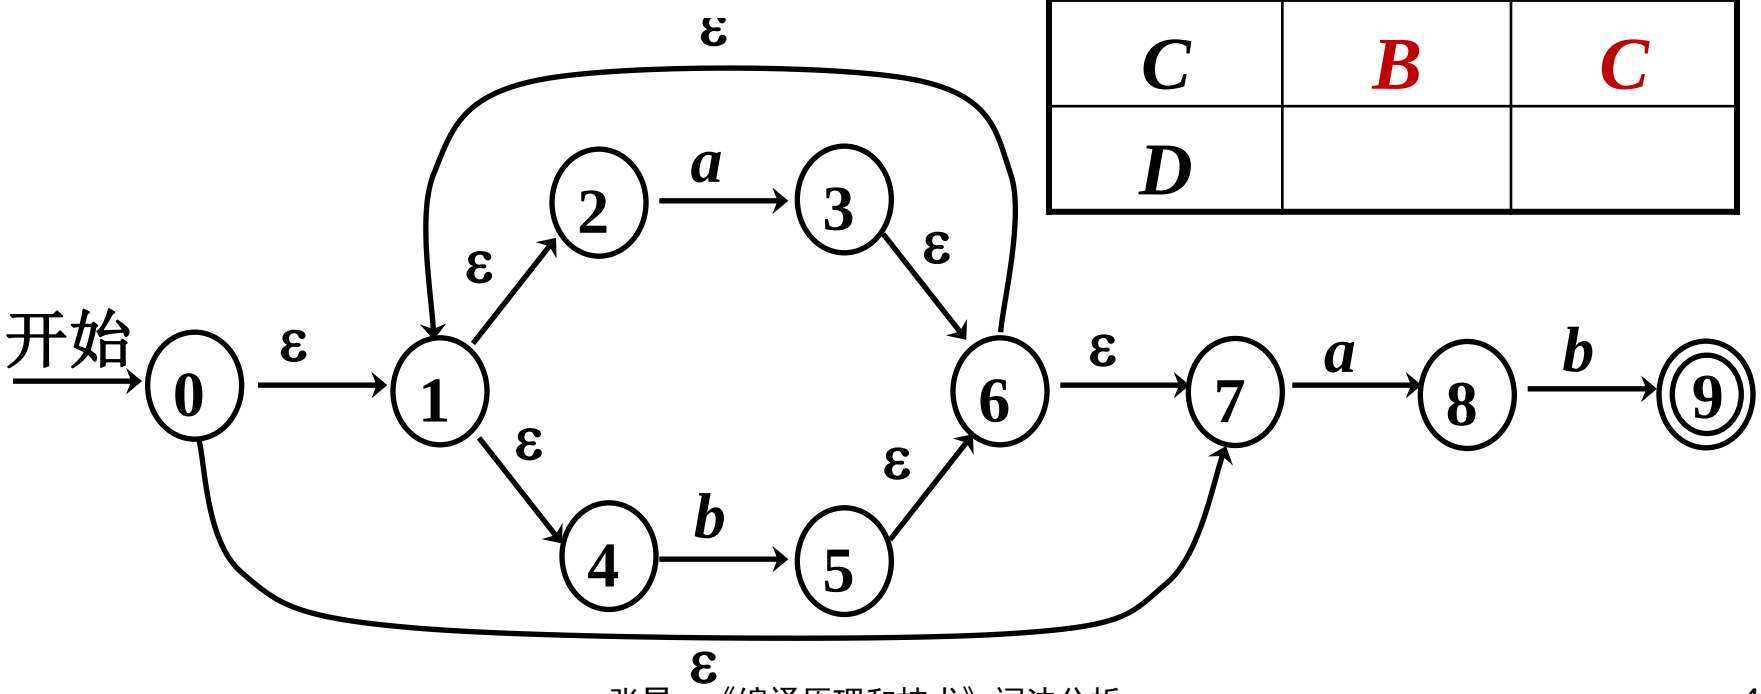

例题6

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

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

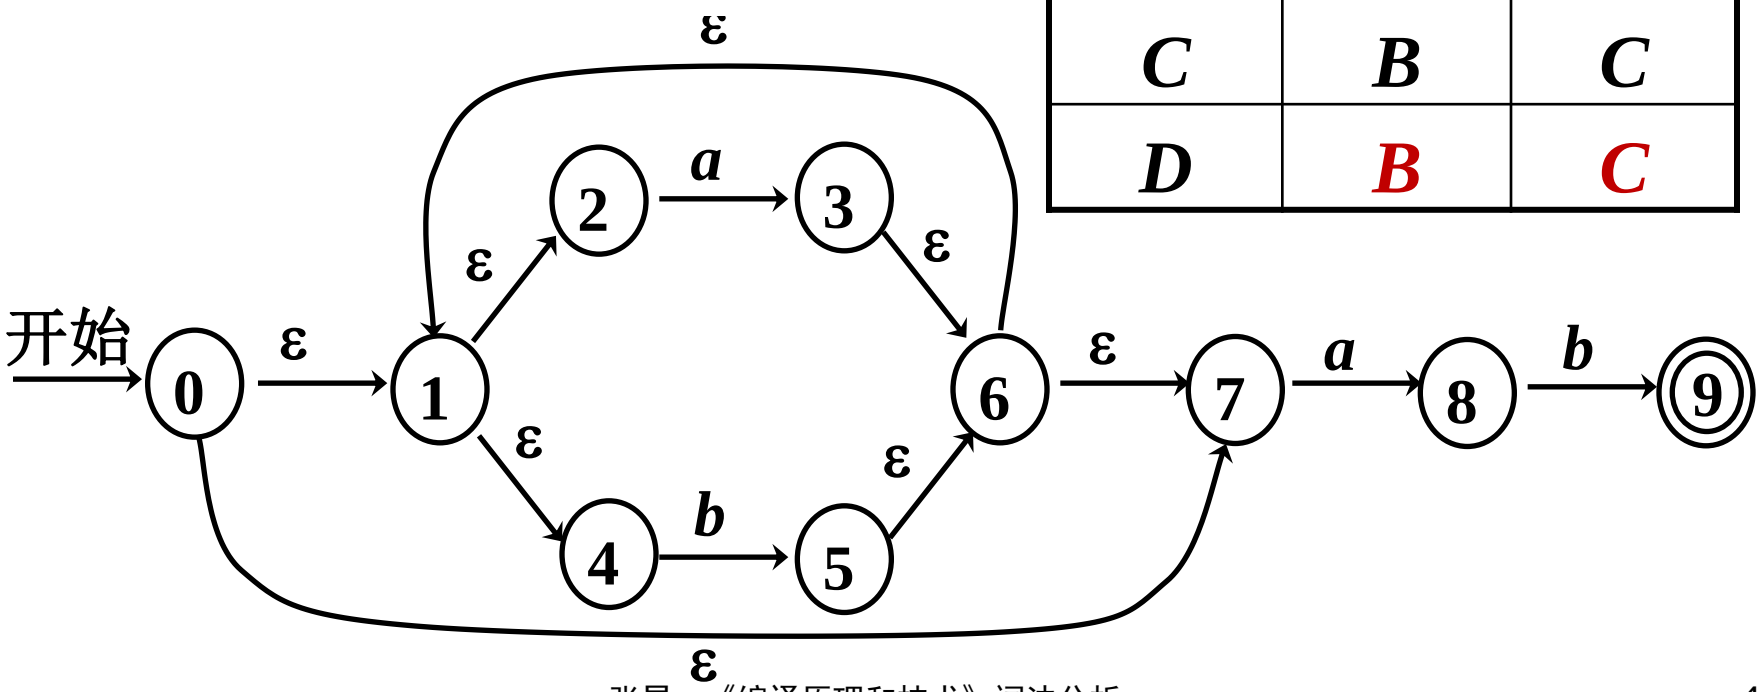

例题6

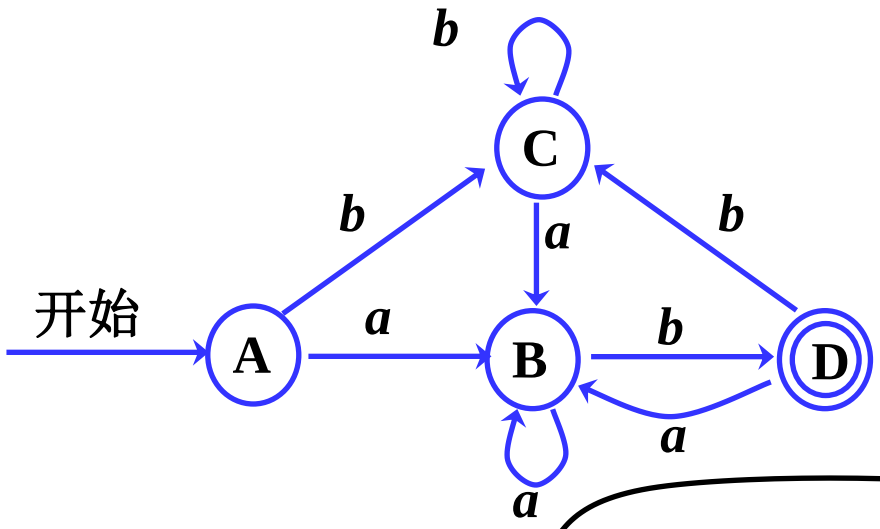

状态	输入符号	
	a	*b*
A	*B*	*C*
B	*B*	*D*
C	*B*	*C*
D	*B*	*C*

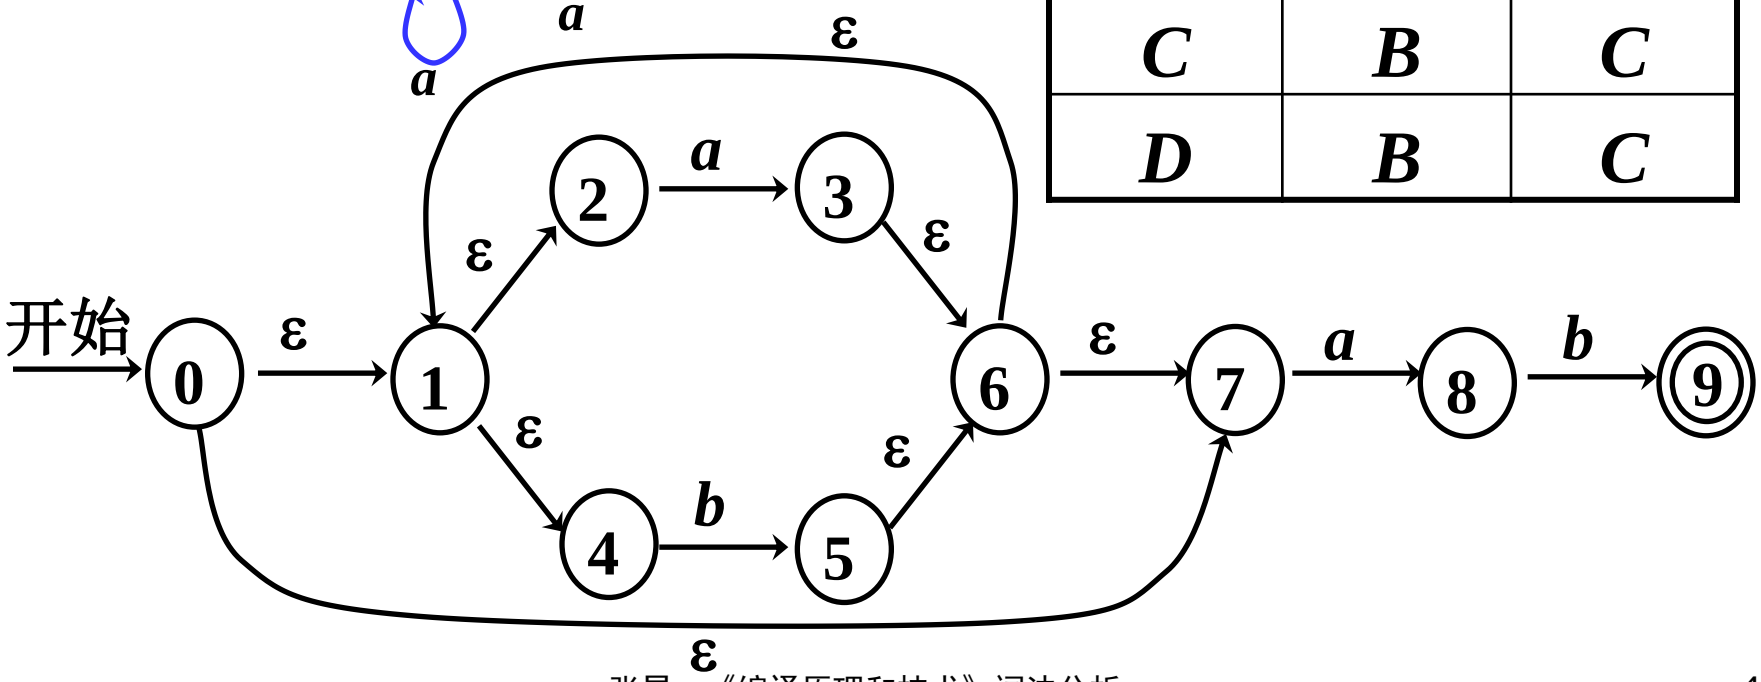

例题6

识别语言 $(a|b)^*ab$ 的DFA

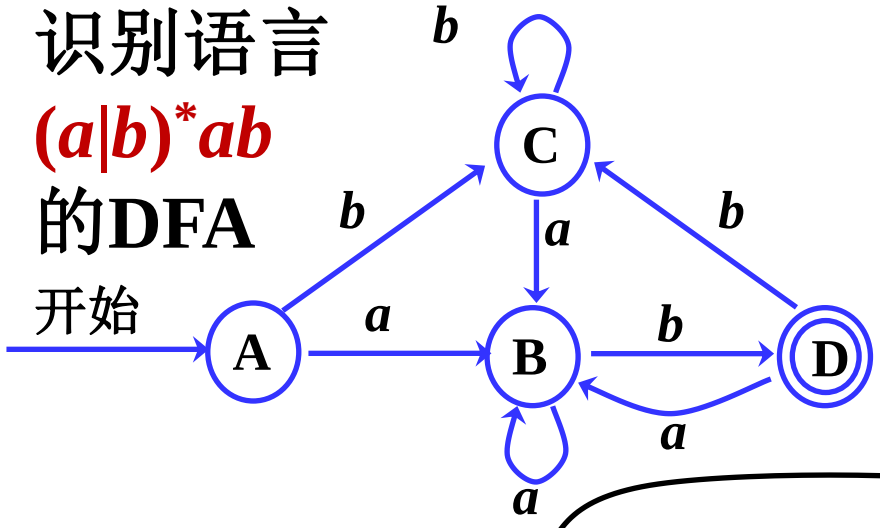

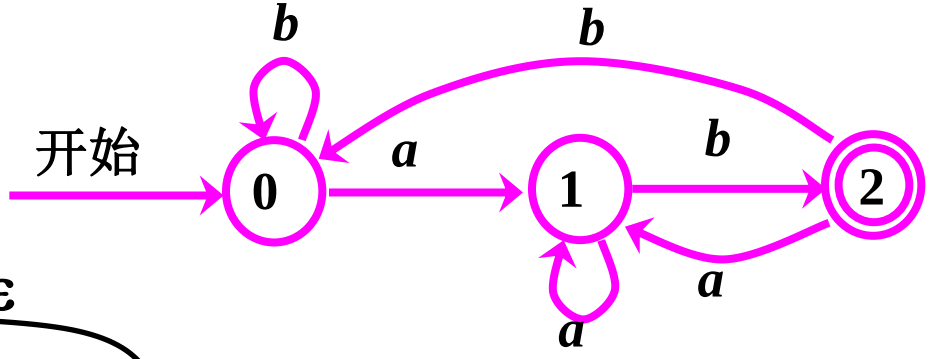

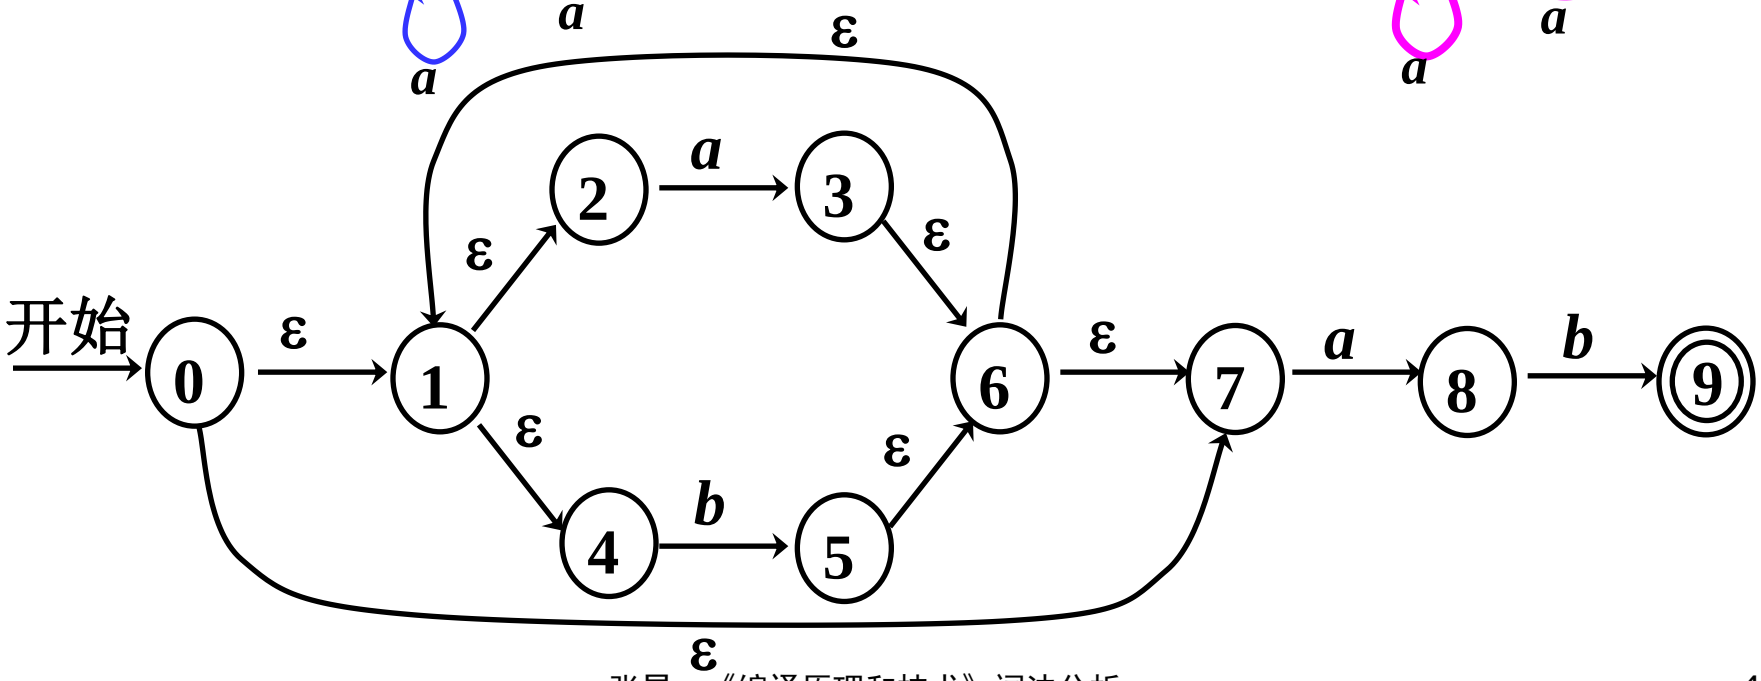

例题6

识别语言 $(a|b)^*ab$ 的DFA

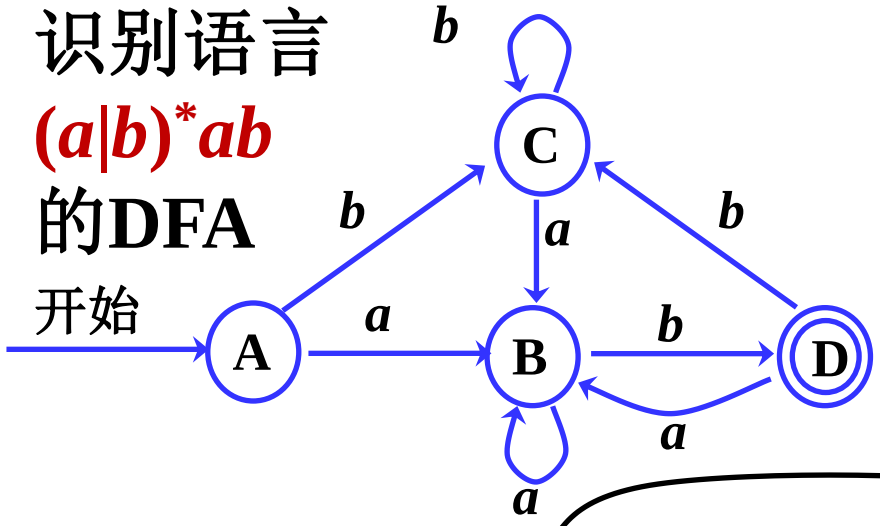

子集构造法不一定得到最简DFA

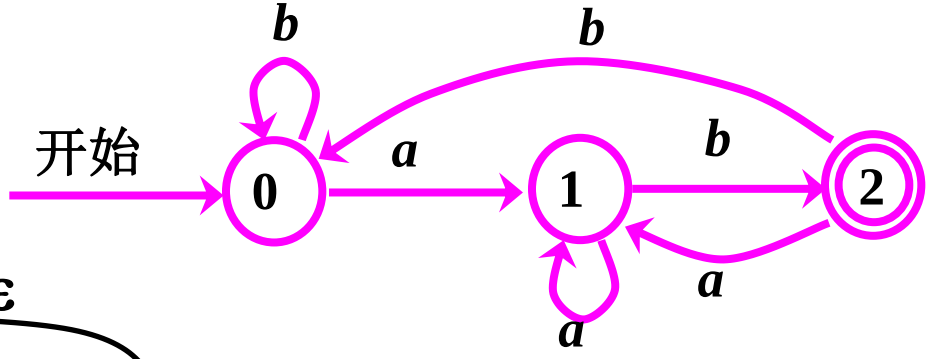

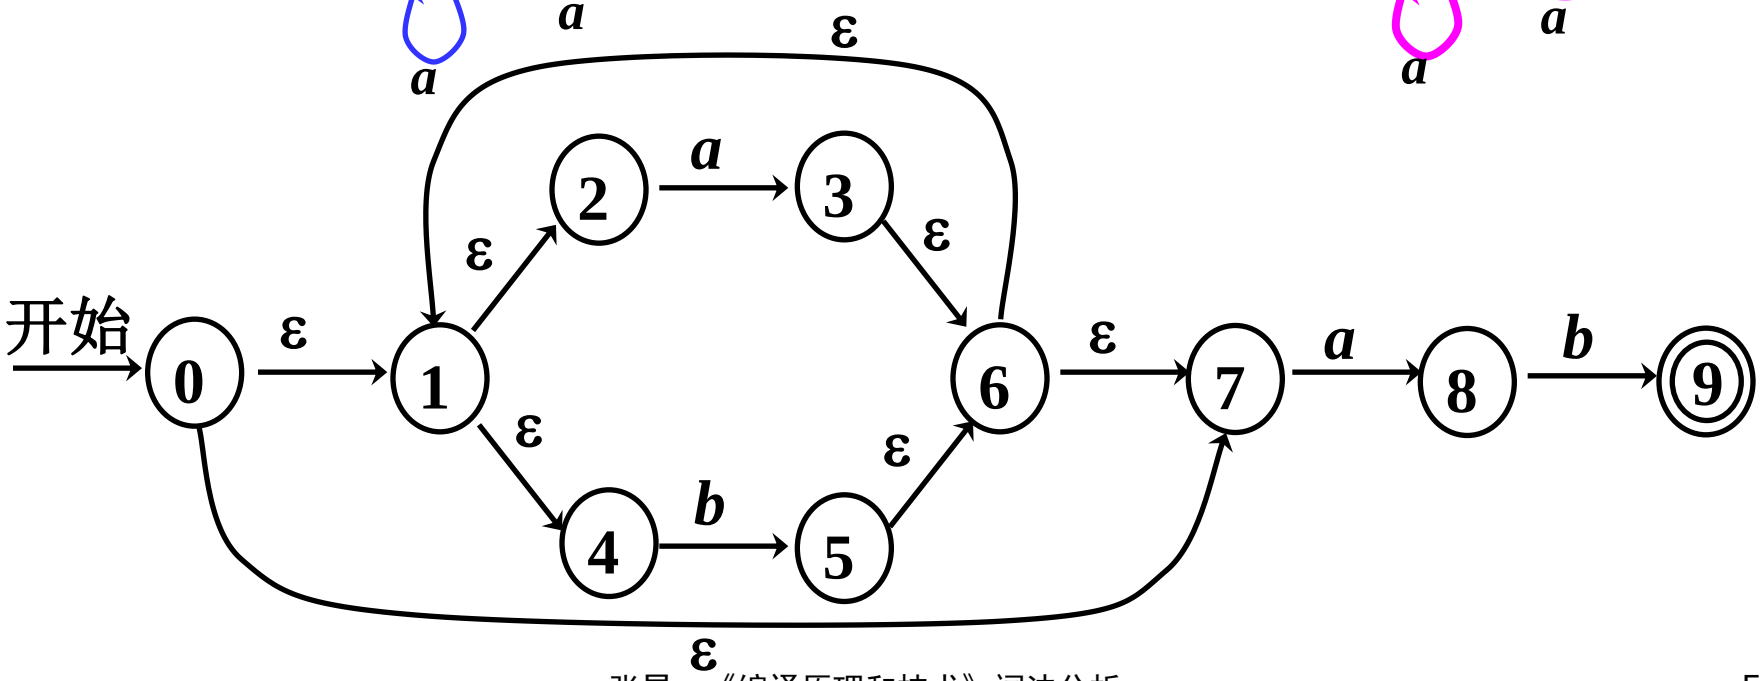

DFA的化简

- 该方法用于化简转换函数是全函数的DFA
- 死状态 (dead state)
  - 当转换函数由部分函数改成全函数表示时引入左图引入死状态E

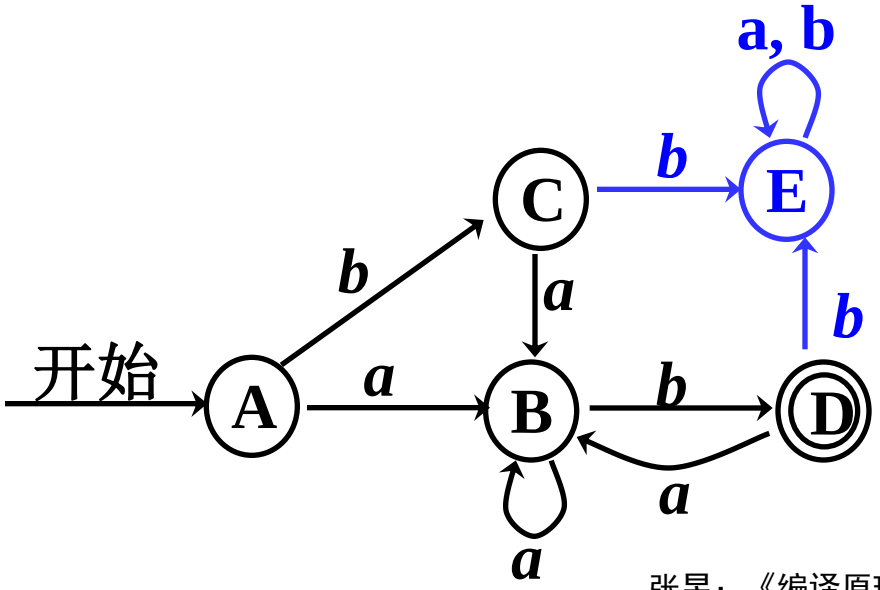

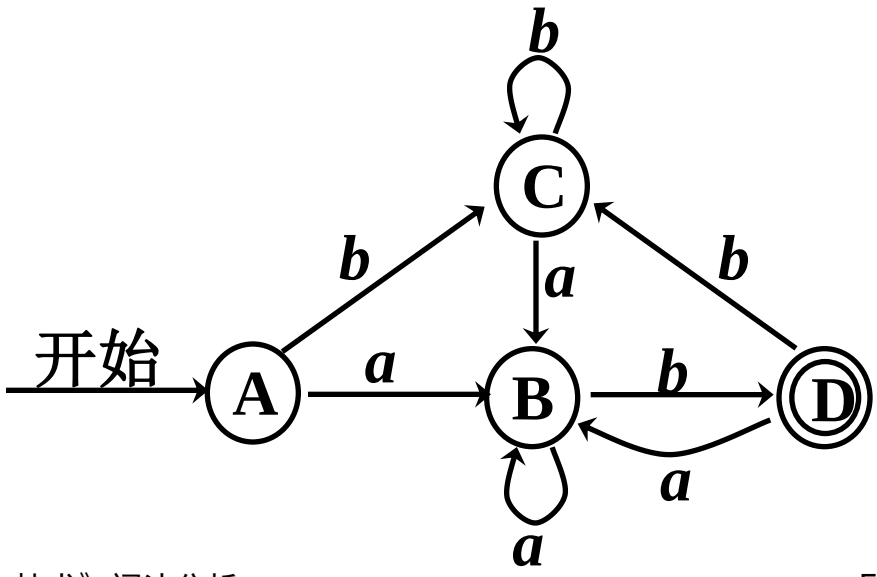

DFA的化简

- 可区别的状态(distinguishable states) *s* 和 *t*

  分别从*s*、*t*出发，存在一个输入符号*w*，使得一个到达接受状态，另一个到达非接受状态。

  - A 和 B 是可区别的状态：

    从A出发，读入 *b* 后到达非接受状态C；从B出发，读过 *b* 后到达接受状态D

  - A 和 C 是不可区别的状态：

    无任何输入符号可用来区别它们

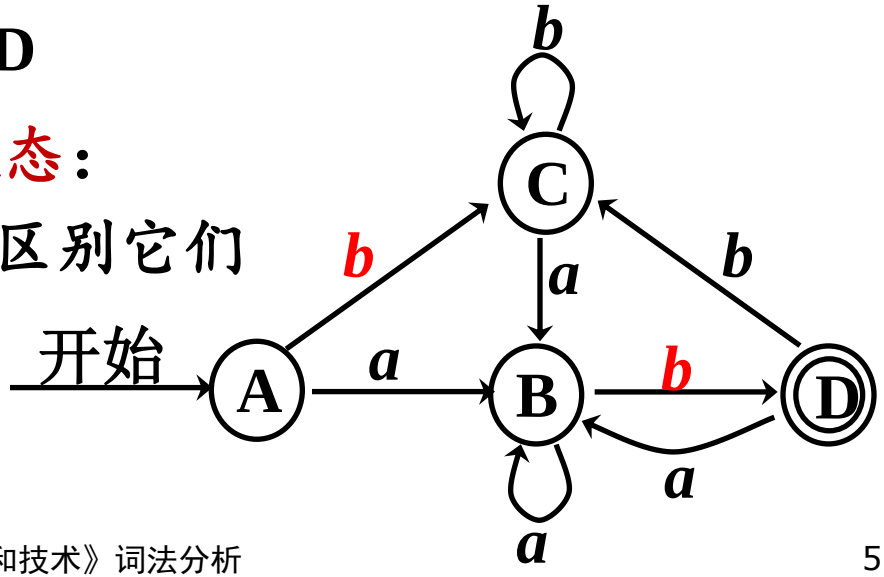

DFA的化简

方法

1. 按是否是接受状态来区分

   {A, B, C}, {D}

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

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

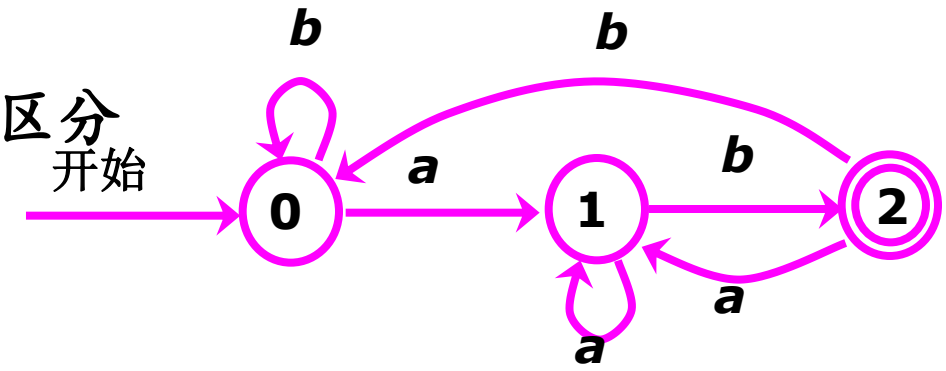

2. {A, C}, {B}, {D}

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

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

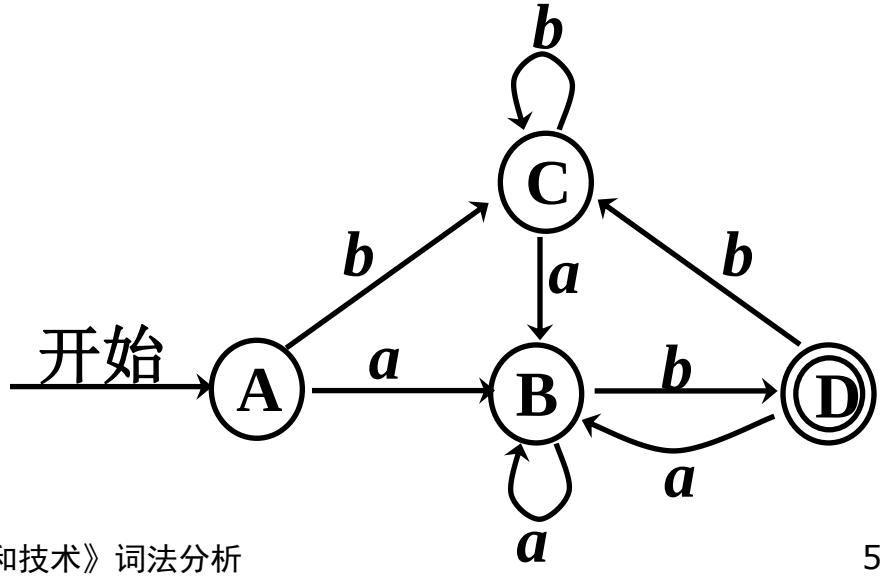

例题7

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

$$(1|01)^* 0^*$$

解答

描述的语言是，所有不含子串001的、由0和1组成的串

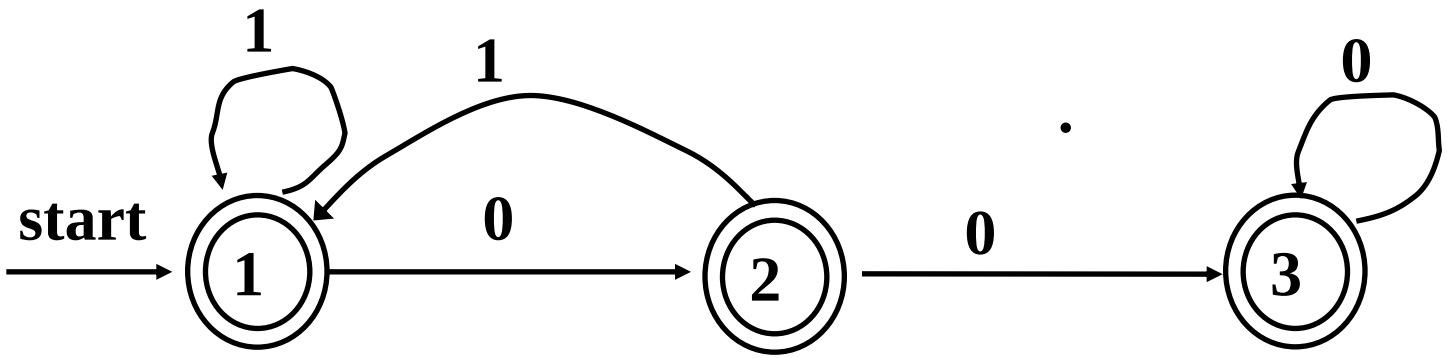

刚读过的不是0

连续读过一个0

连续读过
不少于两个0

例题8

用状态转换图表示接受如下正规式的DFA

$(a|b)^*a(a|b)(a|b)$

解答

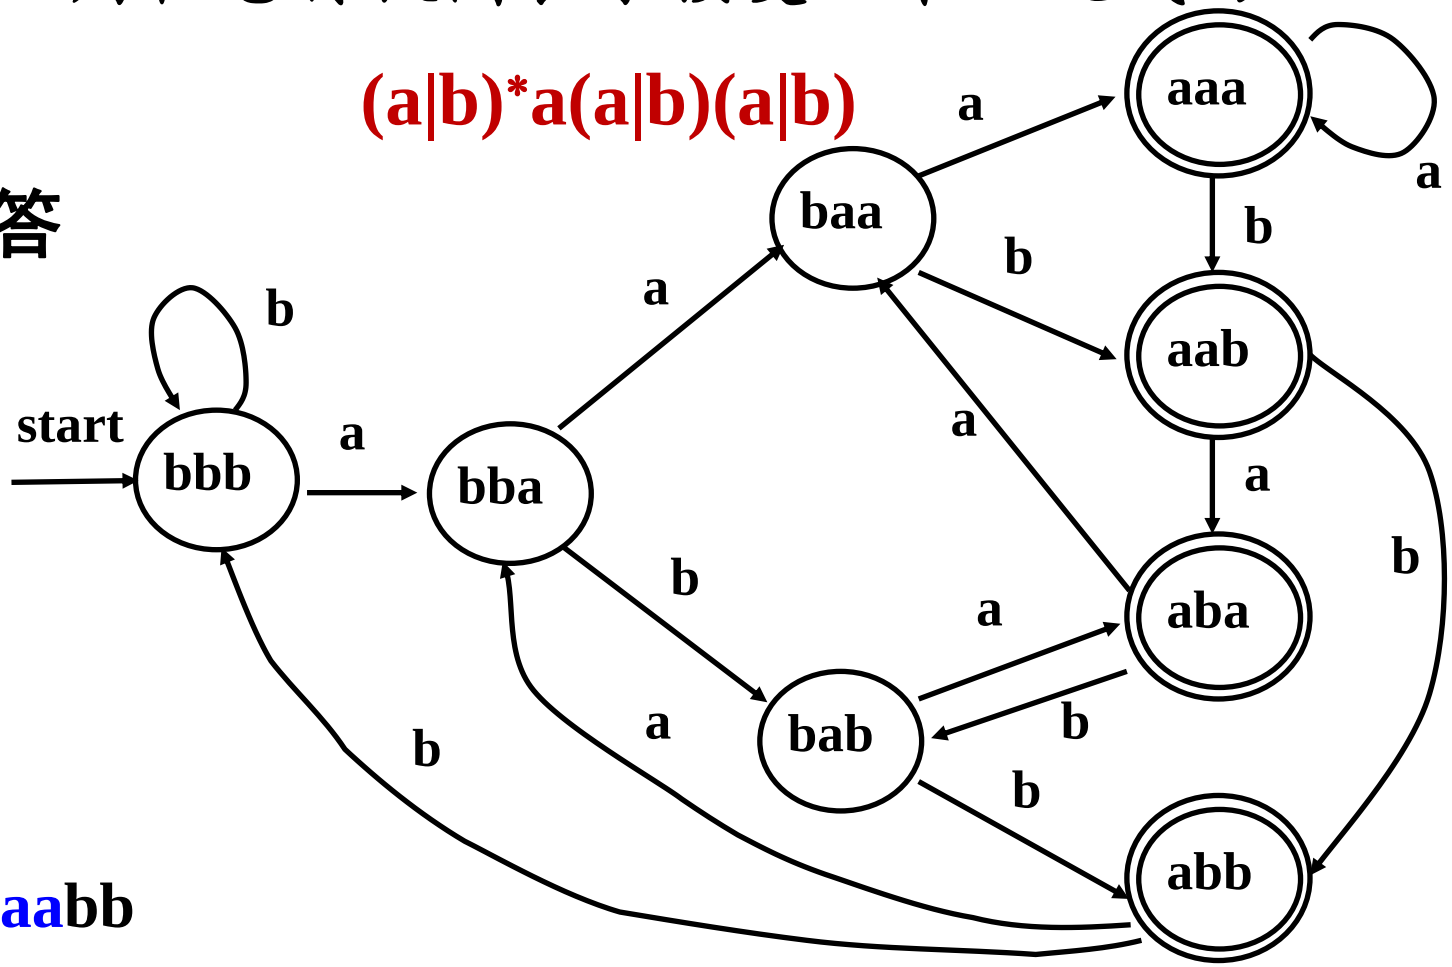

bbabaabb

中国科学技术大学
University of Science and Technology of China

2.4 从正规式到有限自动机

- 分析器的自动构造
  - 正规式→ NFA→DFA →化简的DFA
    采用语法制导的算法来构造NFA

语法制导的构造算法

- “语法制导”：按正规式的语法结构来指导构造
- 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

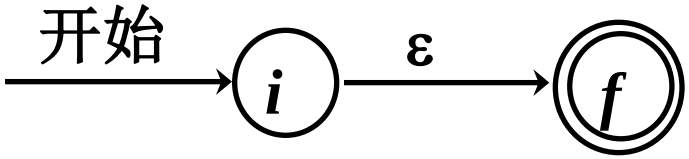

识别正规式 ε的NFA

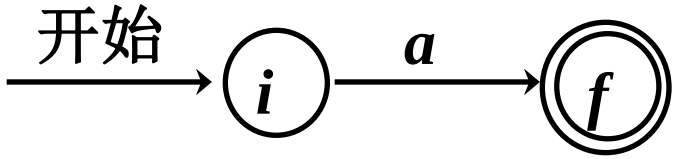

识别正规式 *a* 的NFA

- 对于带括号的正规式(*s*)，使用 *s* 对应的NFA *N*(*s*) 本身作为它的NFA

语法制导的构造算法

- 构造识主算符为选择的正规式的NFA
  - 重要特点：仅一个接受状态

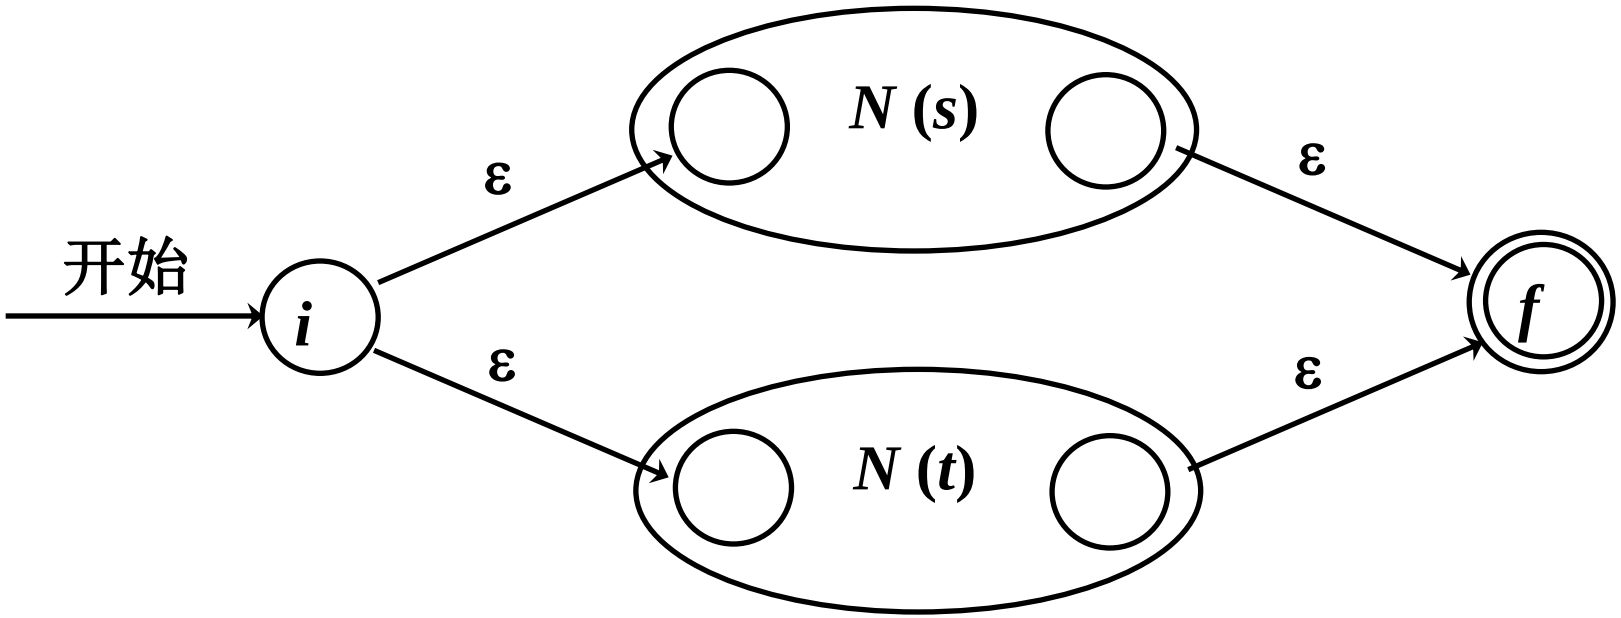

识别正规式 $s \mid t$ 的NFA

语法制导的构造算法

- 构造识主算符为**连接**的正规式的NFA
  - **重要特点**：仅一个接受状态

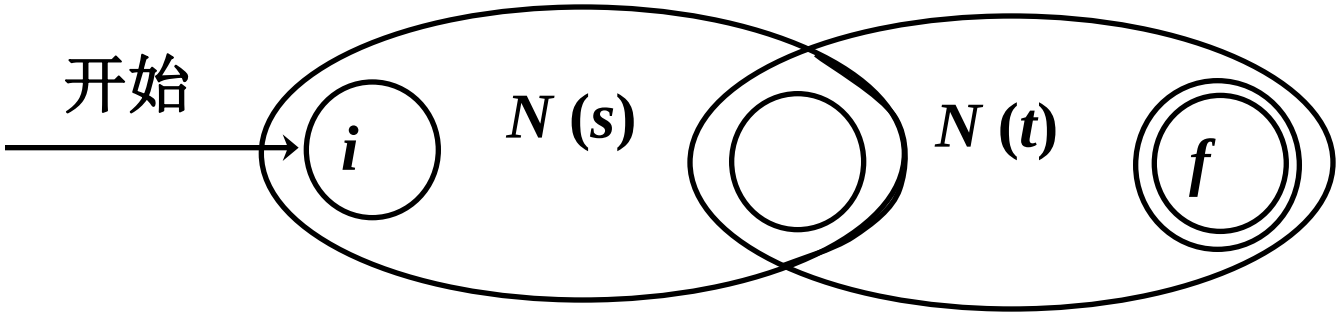

识别正规式 *st* 的NFA

语法制导的构造算法

- 构造识主算符为**闭包**的正规式的NFA
  - **重要特点**：仅一个接受状态，且接受状态没有出边

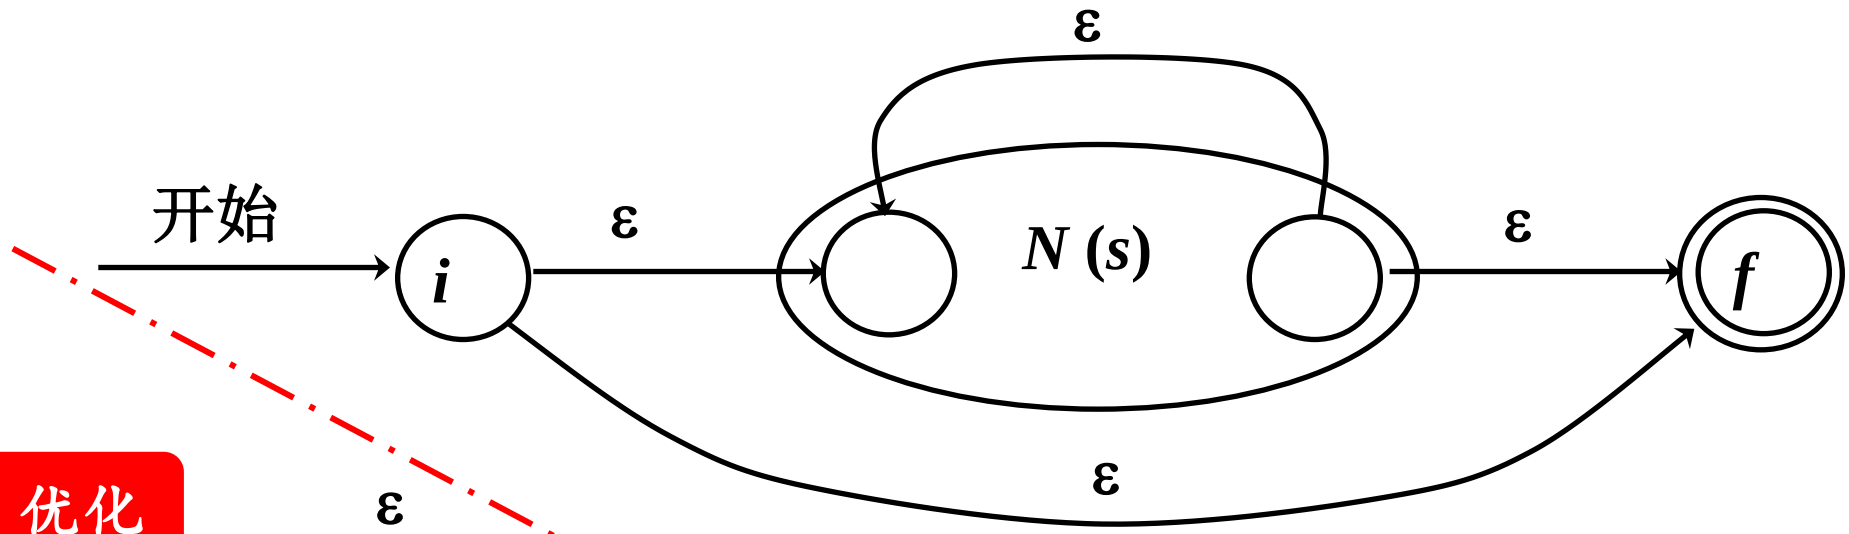

语法制导的构造算法

- 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
  - *N*(*r*)的每个状态有一个用Σ的符号标记指向其它结点的转换，或者最多两个指向其它结点的ε转换

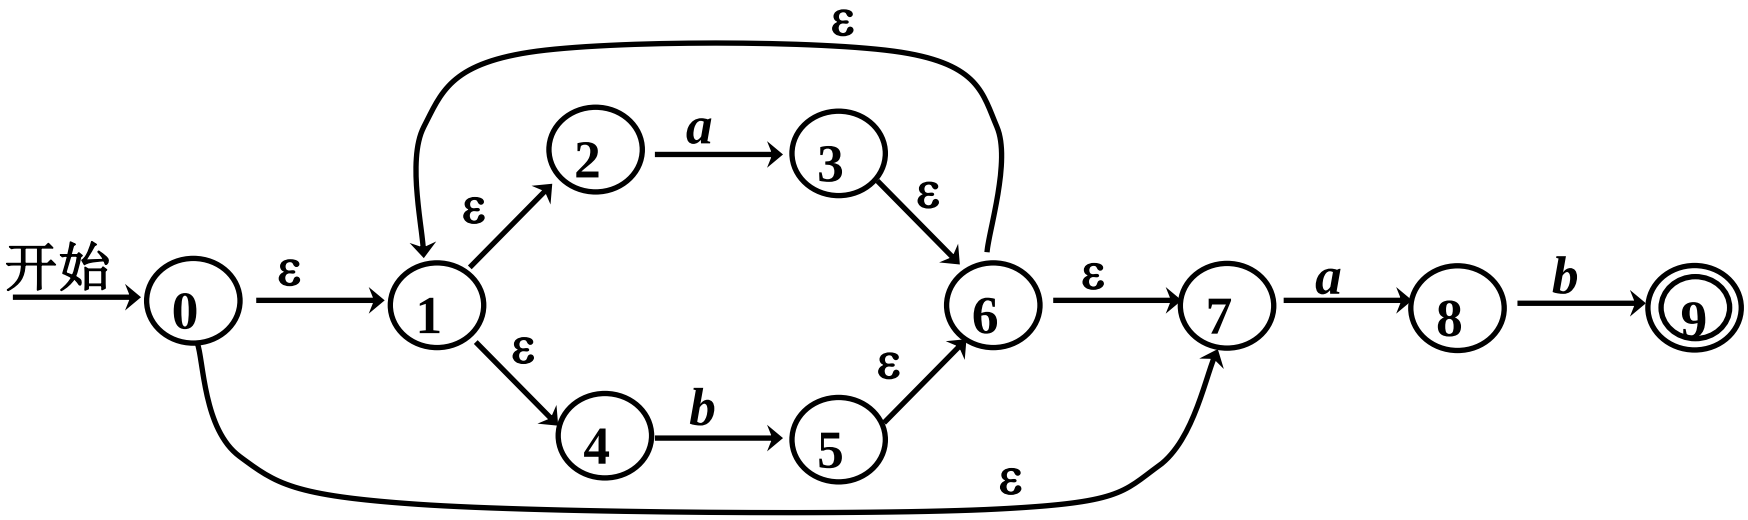

NFA构造过程举例

$(a|b)^*ab$的分解

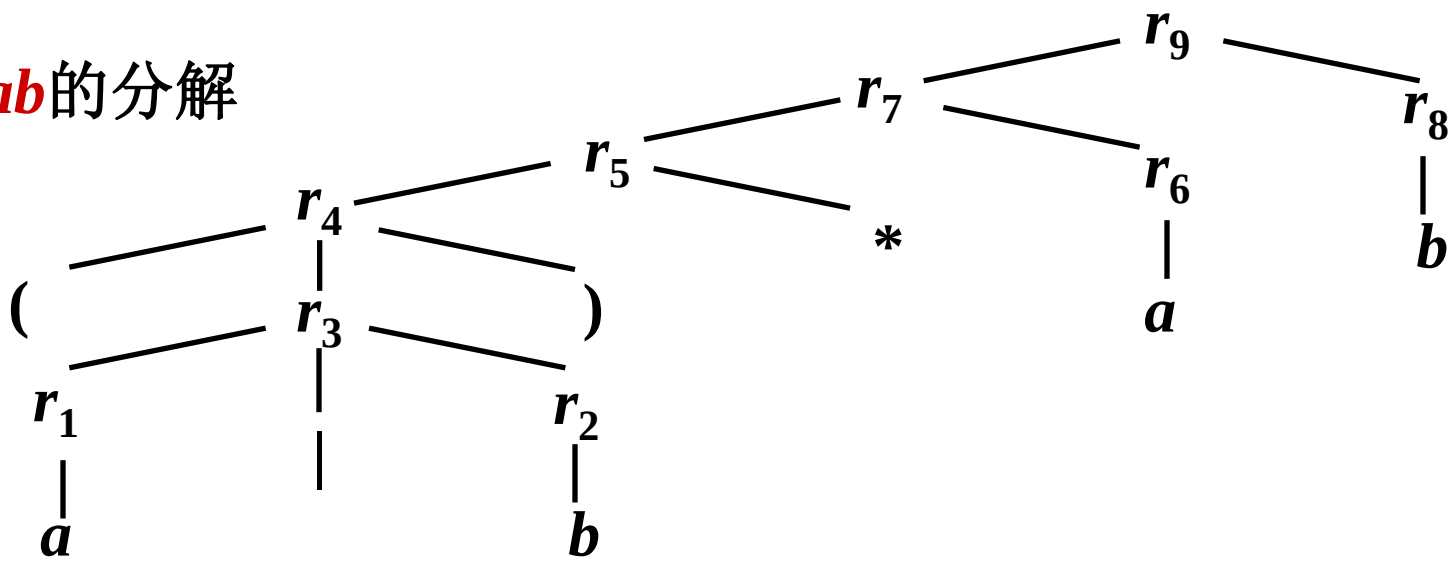

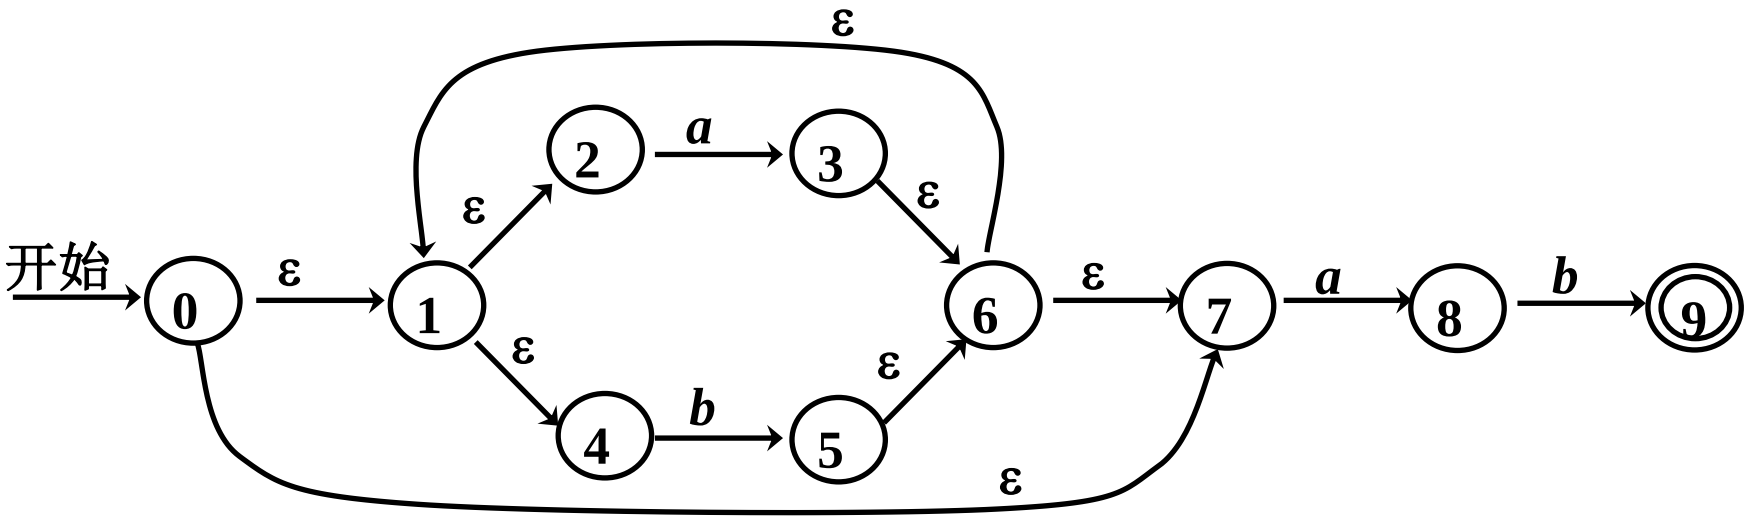

NFA构造过程举例

$(a|b)^*ab$的分解

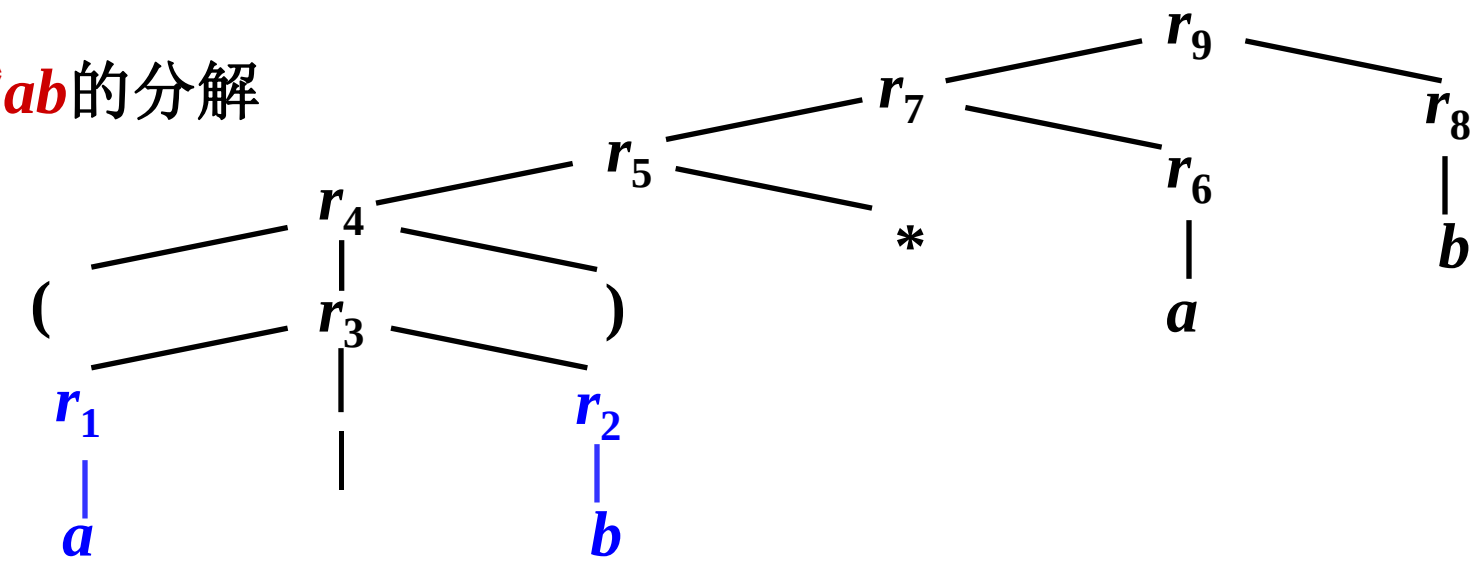

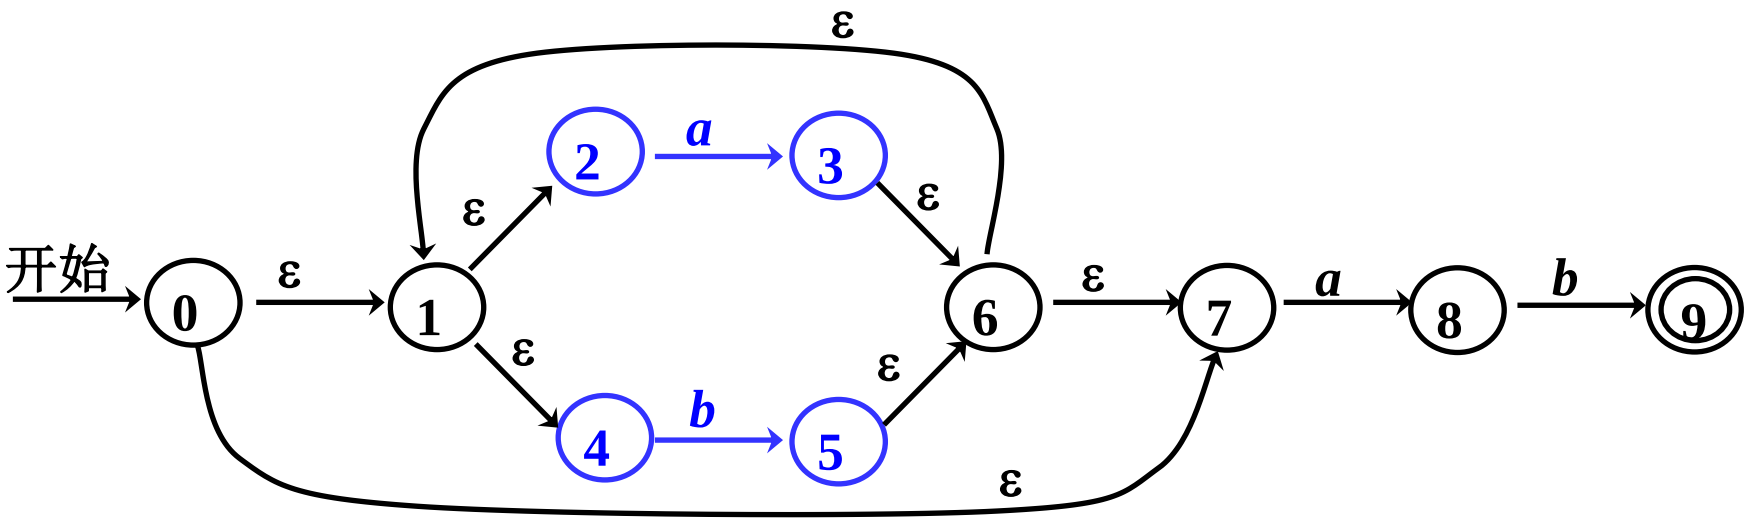

NFA构造过程举例

$(a|b)^*ab$的分解

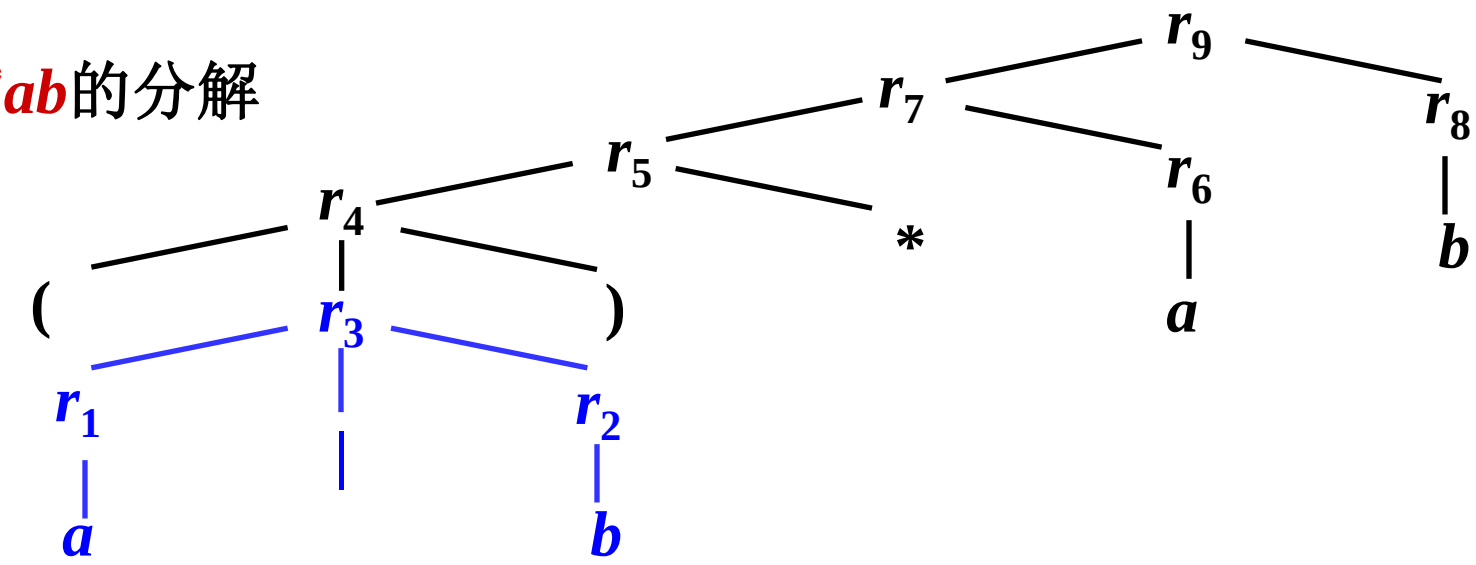

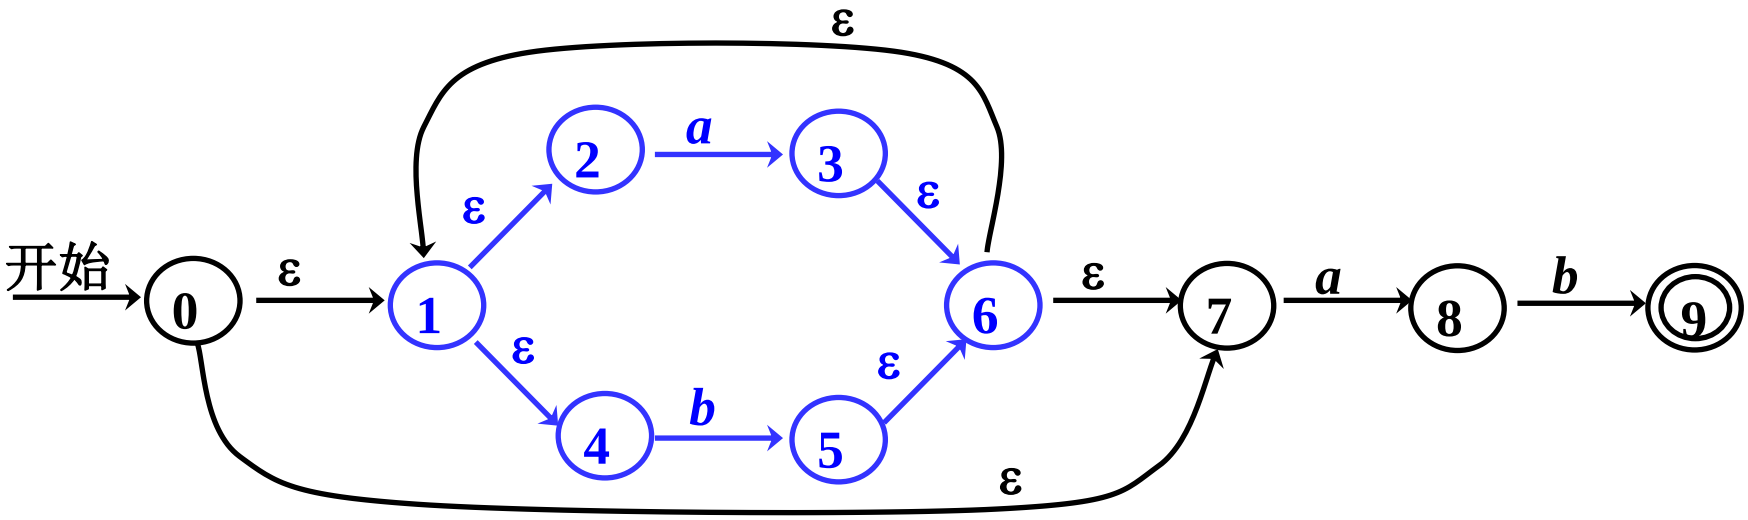

NFA构造过程举例

$(a|b)^*ab$的分解

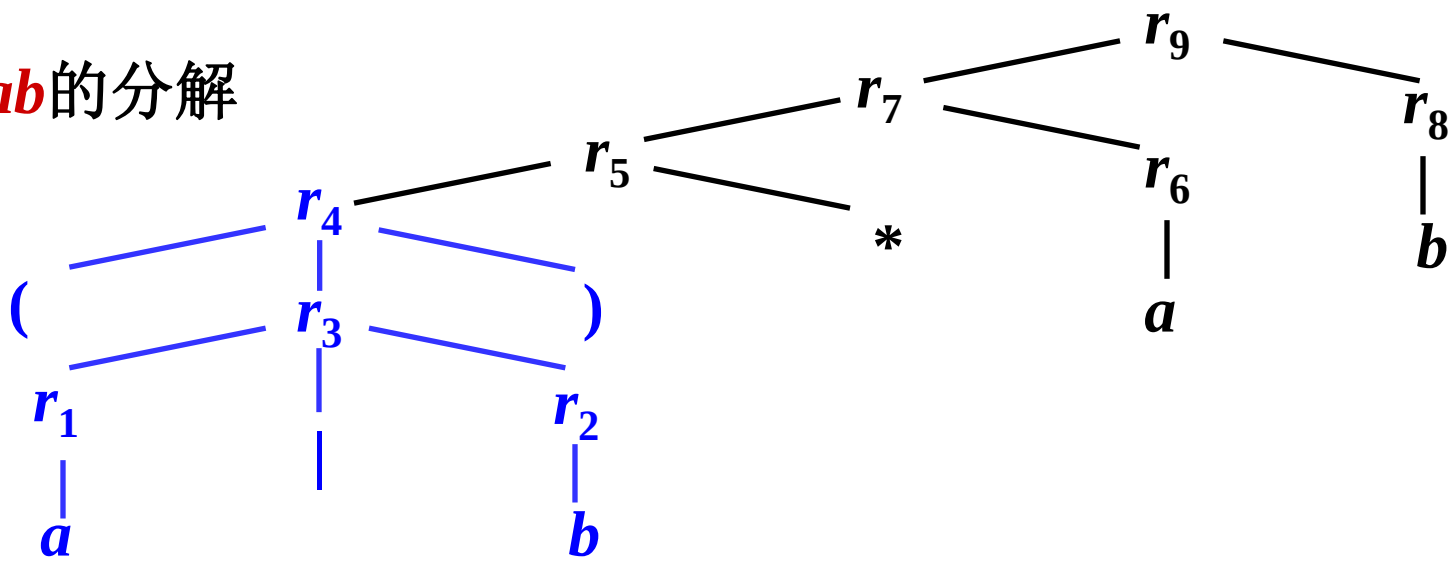

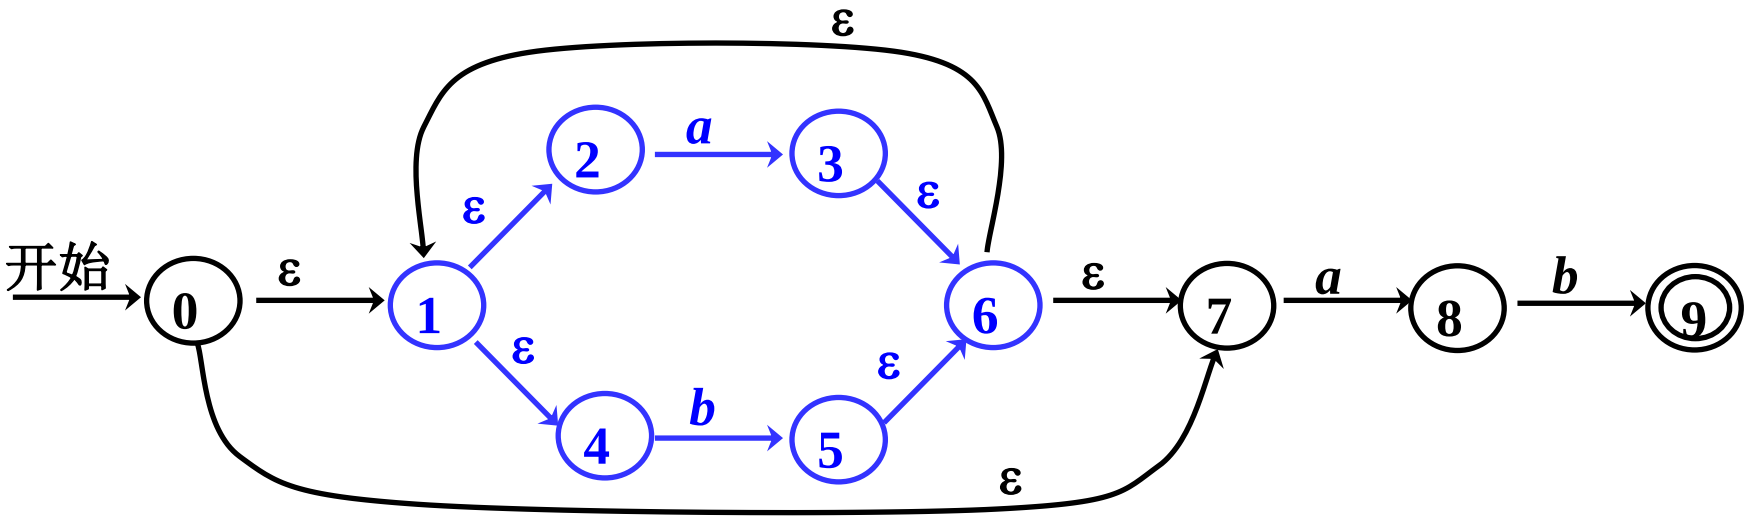

NFA构造过程举例

$(a|b)^*ab$的分解

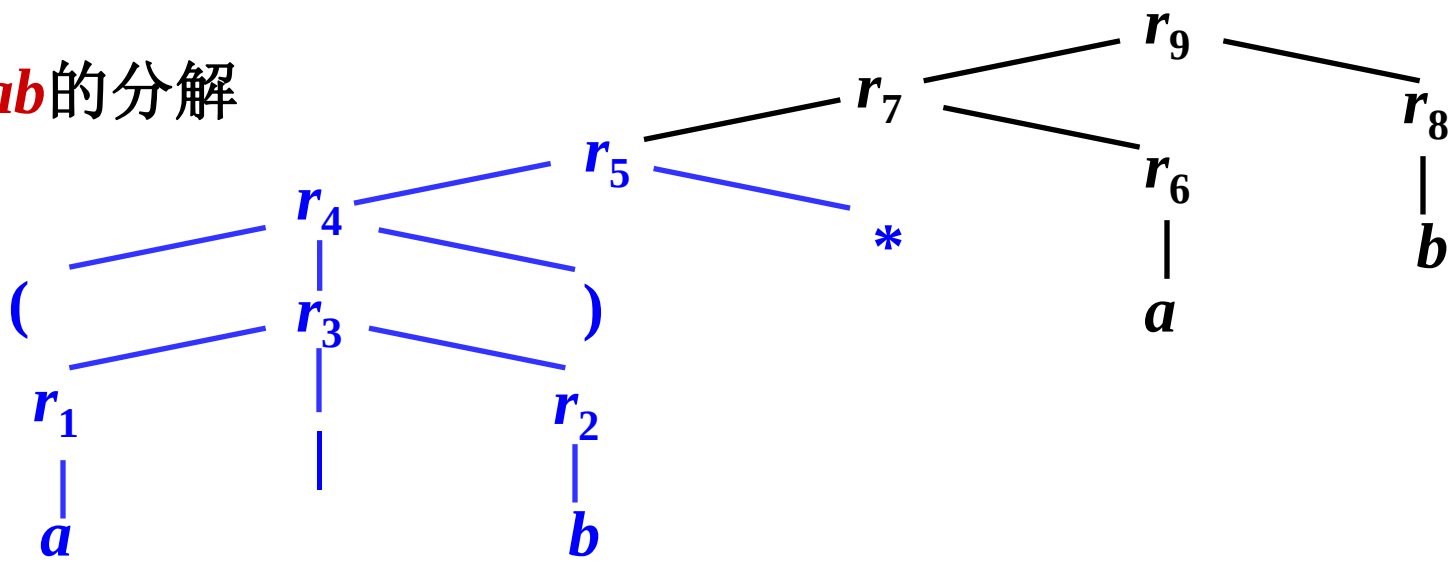

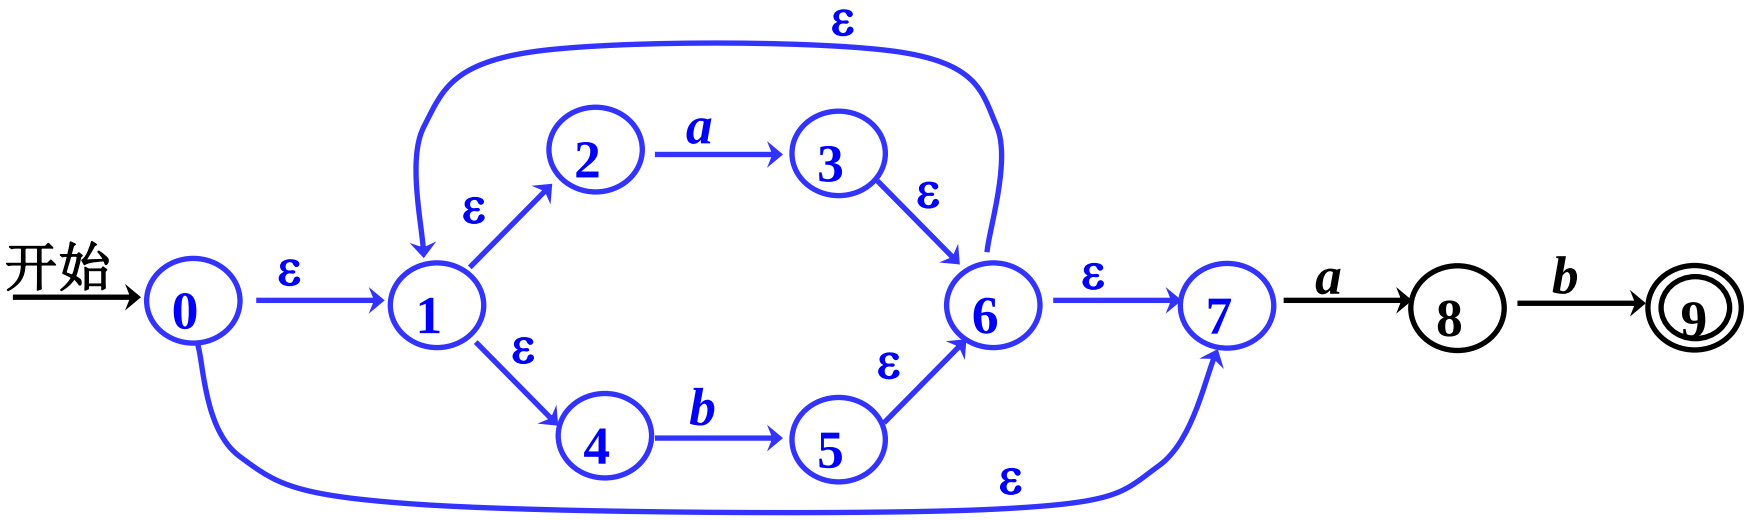

NFA构造过程举例

$(a|b)^*ab$的分解

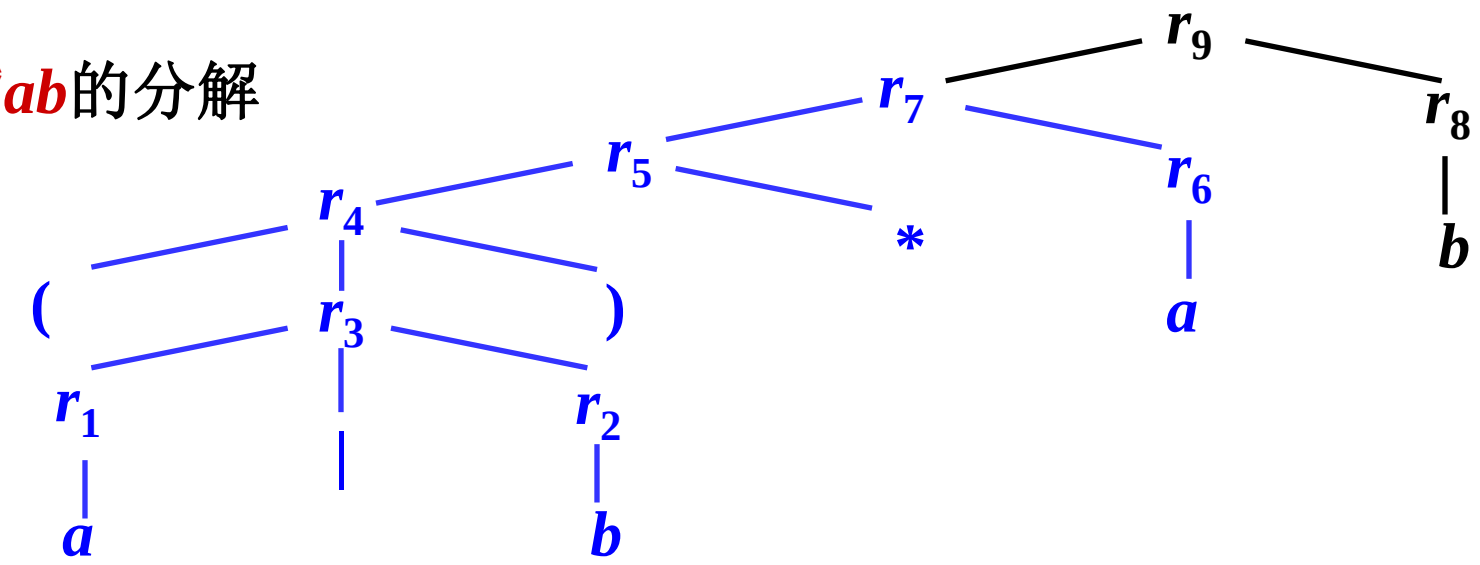

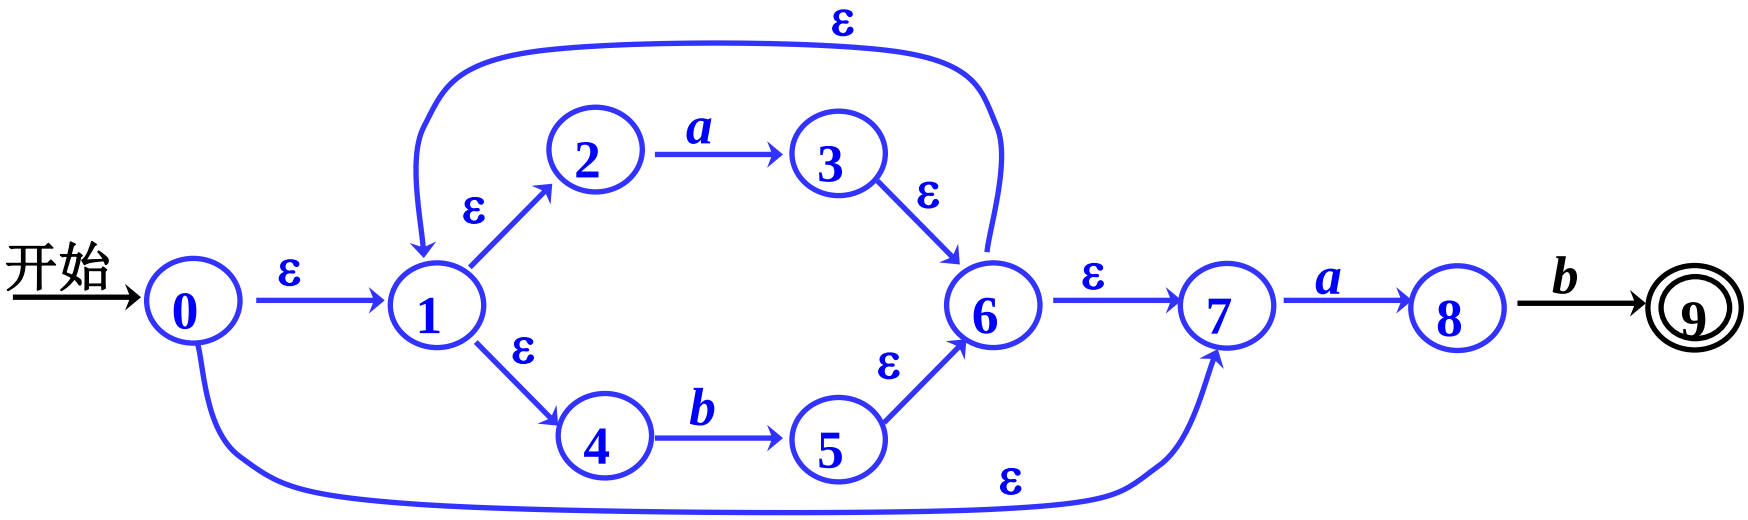

NFA构造过程举例

$(a|b)^*ab$的分解

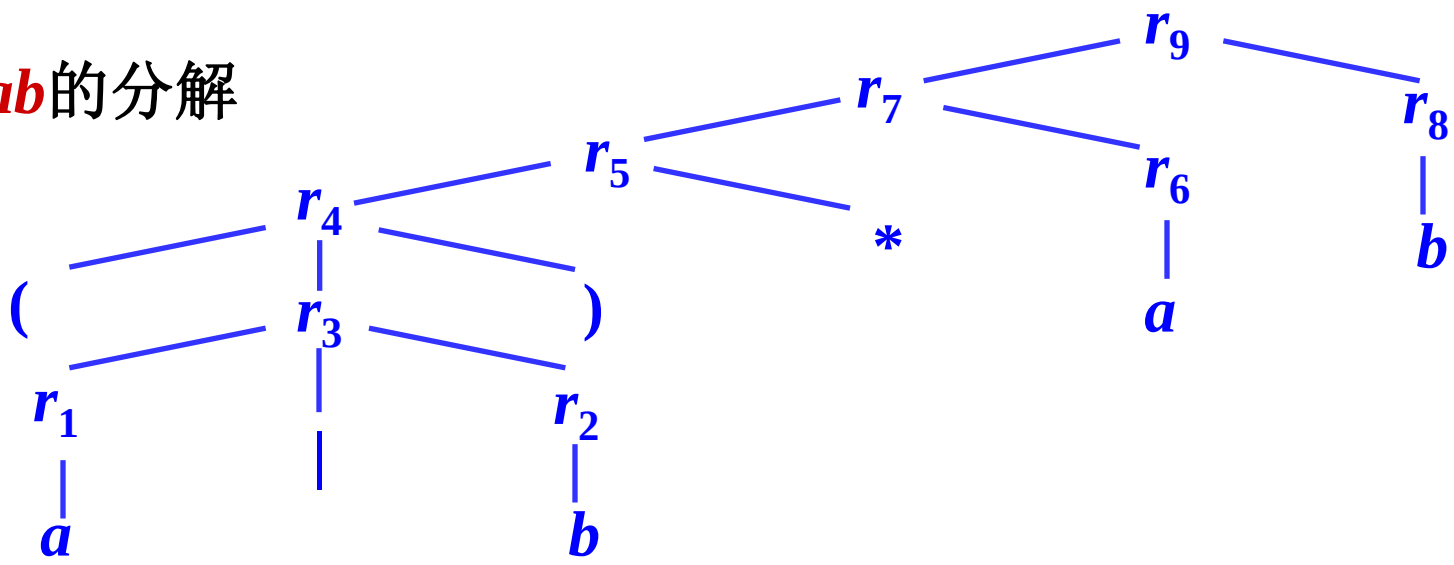

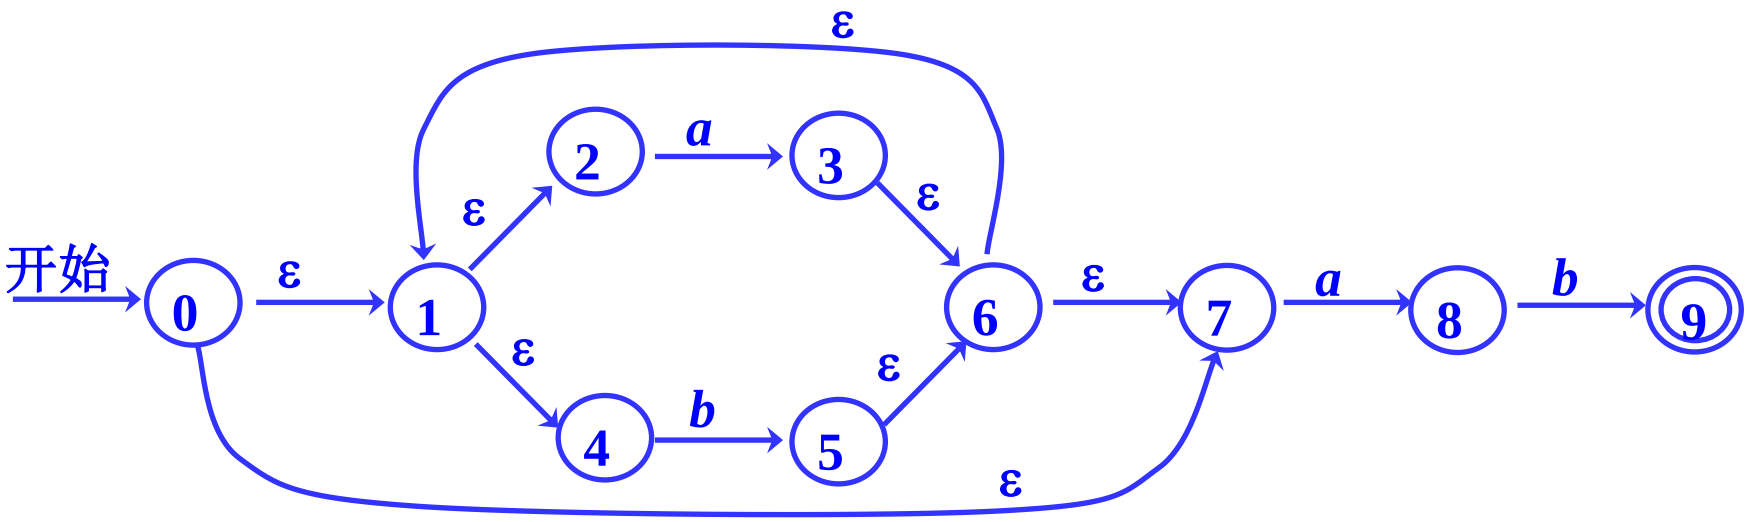

NFA的手工构造和算法构造

- $(a|b)^*ab$的两个NFA的比较

手工构造:

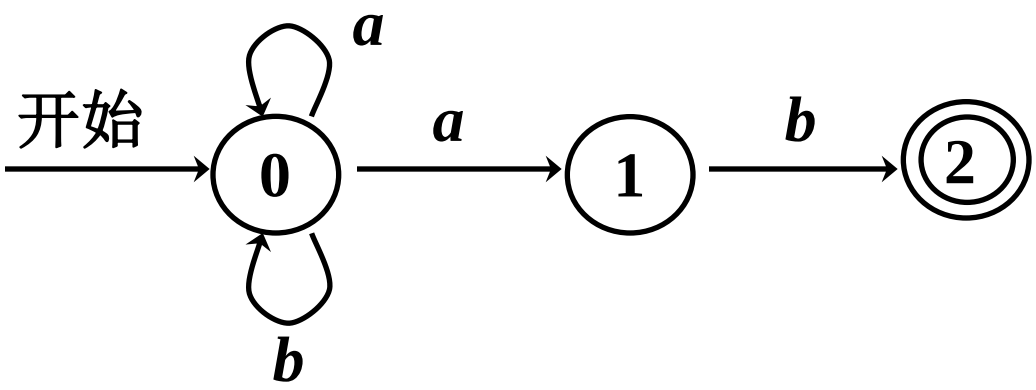

算法构造:

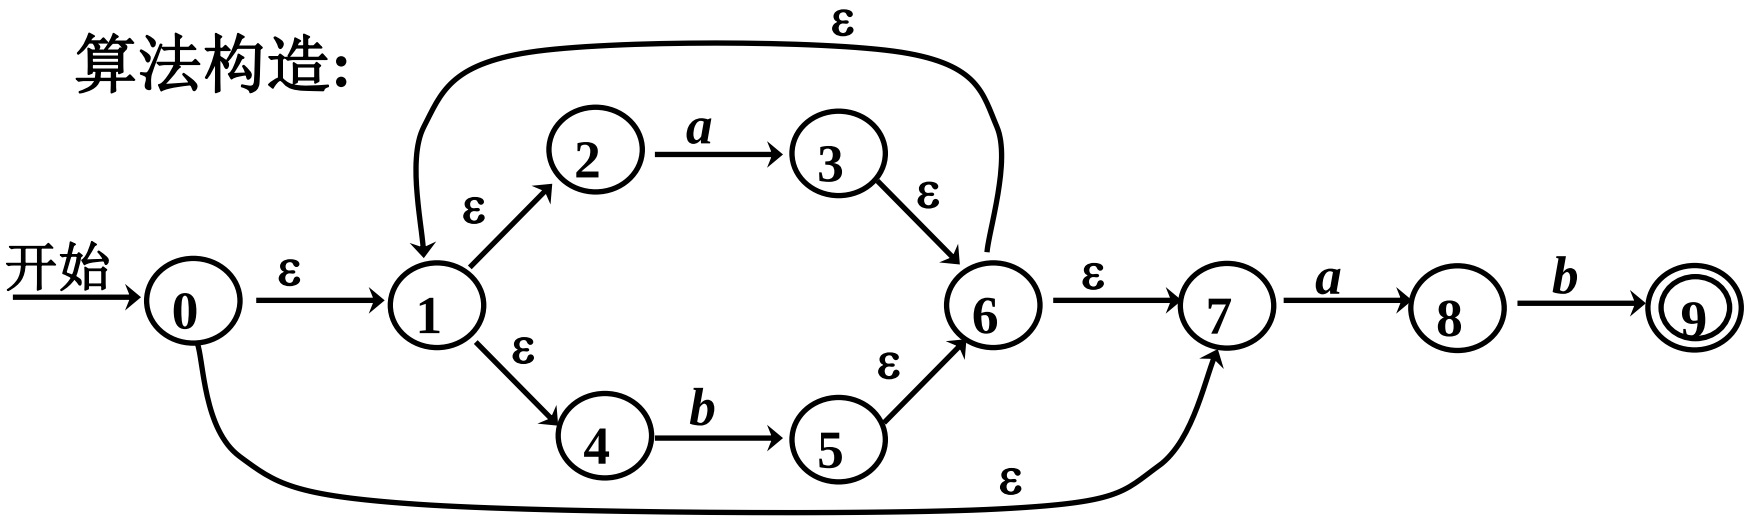

中国科学技术大学
University of Science and Technology of China

2.5 词法分析器的生成器

- Lex: flex、jflex、antlr

用Lex建立词法分析器

词法分析器 — Lexical analyzer, scanner

生成器 — generator

Flex https://github.com/westes/flex ; JFlex http://jflex.de/

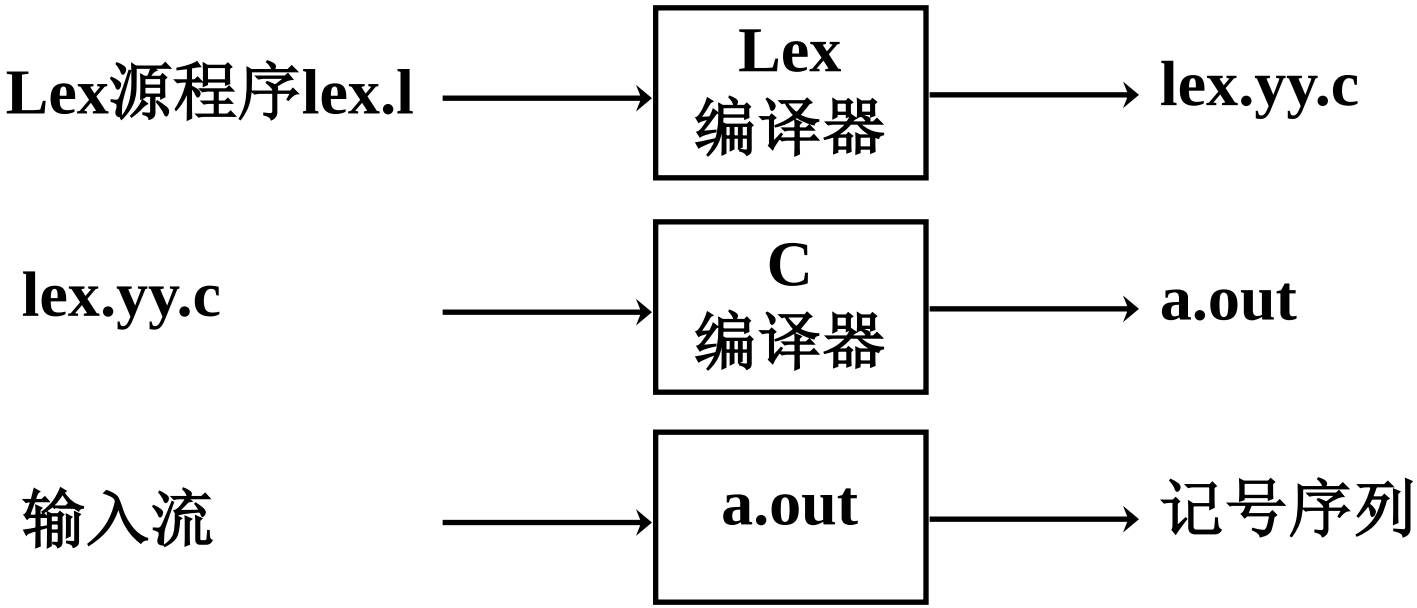

Lex程序

- 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}

Lex文件举例—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}+)?
```

%{和%}包含的代码将直接复制到生成的分析器源程序文件中

Lex文件举例—翻译规则部分

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

Lex文件举例—辅助过程部分

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

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

ANTLR 的文法文件 .g4

- 格式

  grammar MyG;

  options { … }

  import … ;

  tokens { … }

  @actionName { … }

  ruleName : <stuff> ;

  ……

- ruleName
  - 词法：大写字母开头
  - 语法：小写字母开头
- 纯词法分析器

  lexer grammar MyG;

- 词法规则

```
INT : DIGIT+ ;
fragment DIGIT : [0-9] ;
LQUOTE : '"' -> more, mode(STR) ;
mode STR;
STRING : '"' -> mode(DEFAULT_MODE);
```

正规定义，DIGIT不是记号

模式定义
词法状态

模式调用

ANTLR：Lexer命令

- 命令格式

  TokenName : <选项> -> 命令名 [(参数)]

- 命令
  - skip：不返回记号给parser，如识别出空白符或注释
  - type(T)：设置当前记号的类型
  - channel(C)：设置当前记号的通道，缺省为Token.DEFAULT_CHANNEL(值为0)；Token.HIDDEN_CHANNEL(值为1)
  - mode(M)：匹配当前记号后，切换到模式M
  - pushMode(M)：与mode(M)类似，但将当前模式入栈
  - popMode：从模式栈弹出模式，使之成为当前模式

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
- 掌握下面的相关概念，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）