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

词法分析II

《编译原理和技术(H)》

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

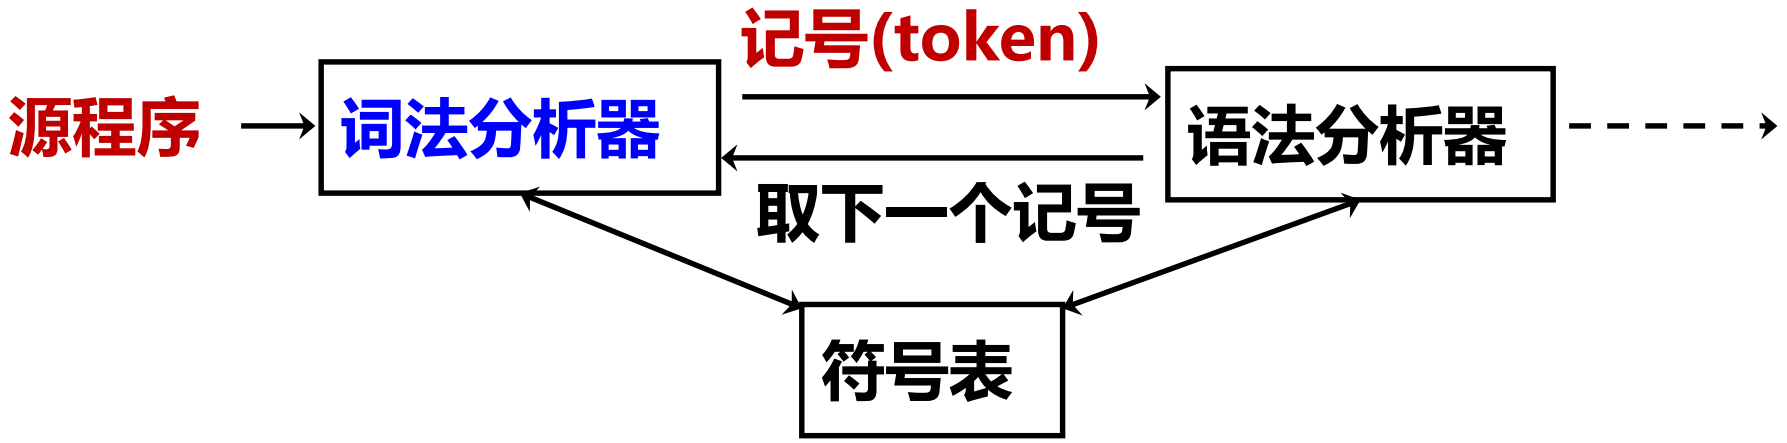

- 词法分析及要解决的问题
  - 向前看(Lookahead)、歧义(Ambiguities)
- 词法分析器的自动生成
  - 词法的描述：正规式；词法记号的识别：转换图
  - 有限自动机：NFA、DFA

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

2.3 有限自动机

- 描述分析器：NFA、DFA
  (对转换图的形式定义和分类)

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$\sum$

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

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

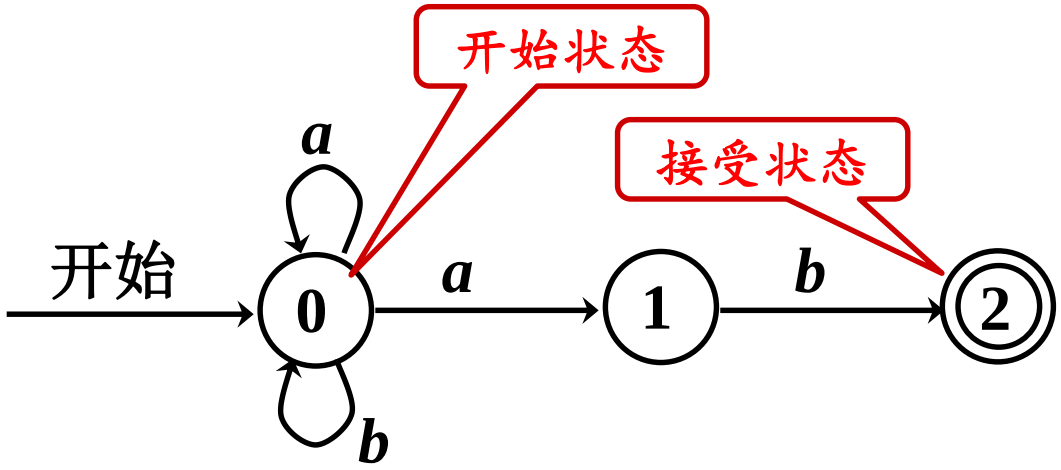

转换表

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

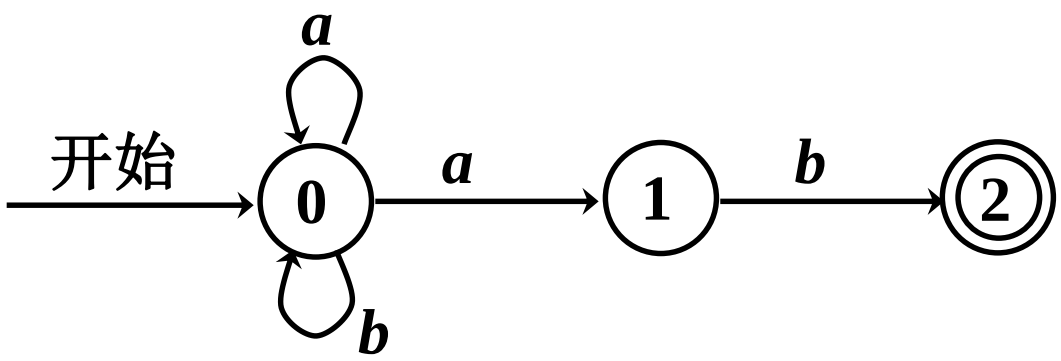

例题3

识别$aa^*|bb^*$的NFA

识别aa^*的NFA

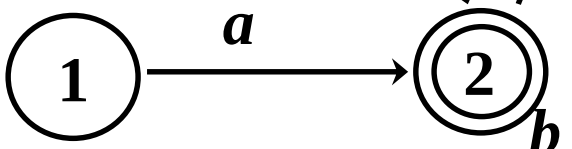

识别bb^*的NFA

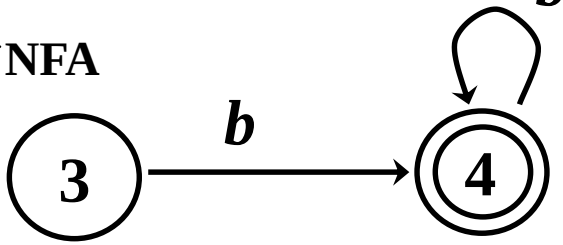

方法1

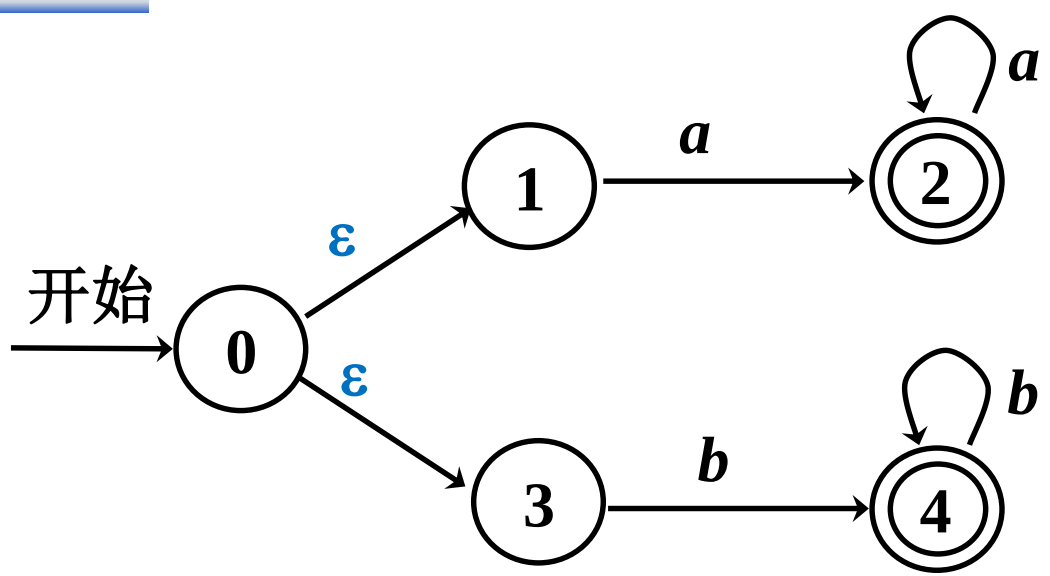

输入串*aaa*由开始状态0、到1、2、2、2的路径来接受
或者由开始状态0、到3、回退到0，再到1、2、2、2的路径来接受

方法2

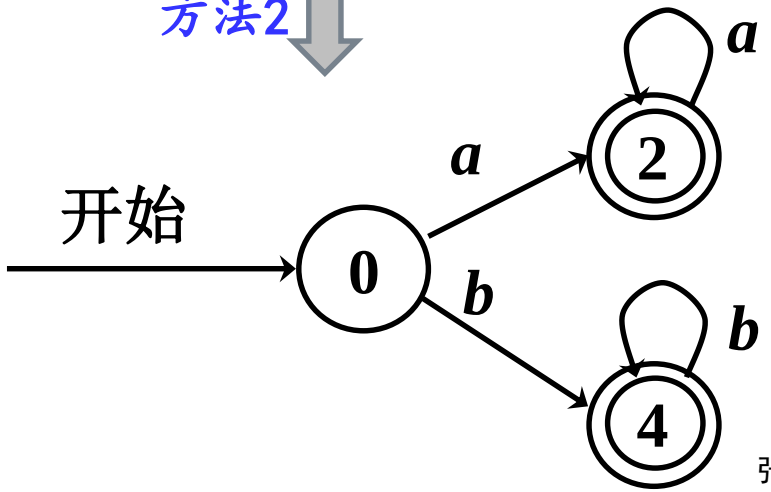

合并两个子NFA的开始状态1和3，设为0

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

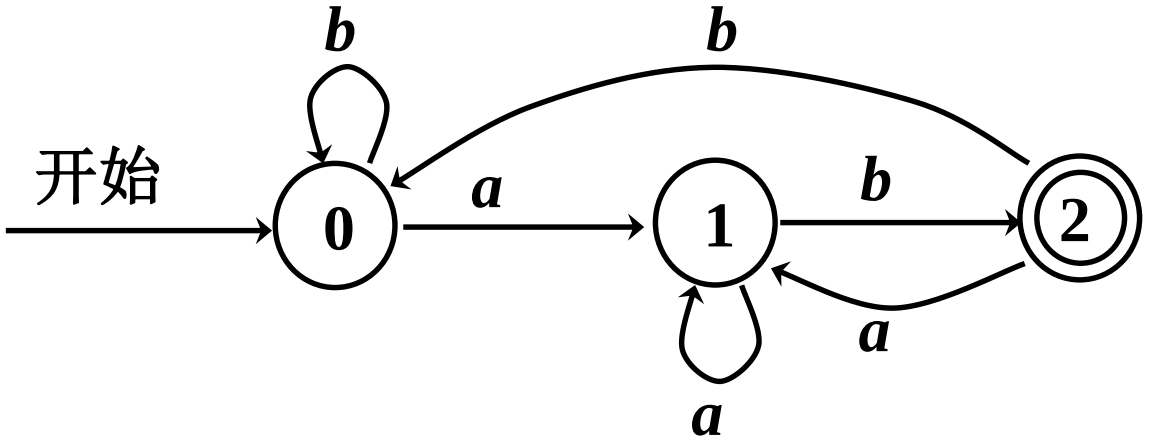

NFA vs. DFA

主要差异在转换函数

- **NFA：** $move : S \times (\sum \cup \{\varepsilon\}) \rightarrow P(S)$

  效率低

  - 要识别一个token，需要对多种可能的路径试探+失败回退

- **DFA：** $move : S \times \sum \rightarrow S$，可以是部分函数

  快速高效

  - 对于面临的∑中的符号，状态转换是明确的

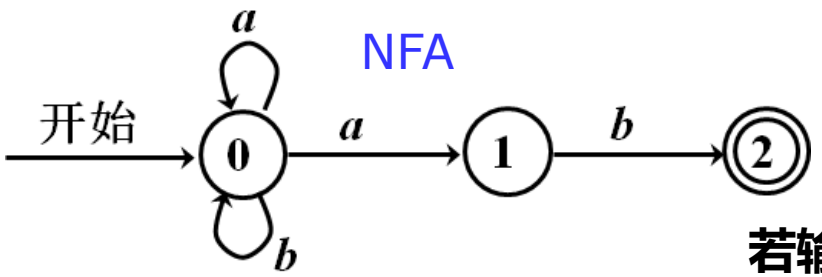

识别语言 $(a|b)^*ab$

若输入串是 ab

0-(a)→0-(b)→0-结束符
0←回退b
0←回退a
0-(a)→1-(b)→2-结束(接受状态)

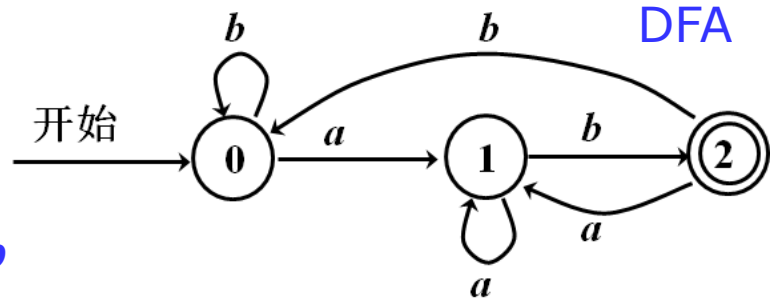

0-(a)→1-(b)→2-结束(接受状态)

但是，由正规式不易构造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	$5 \times 2 = 10$
读进1	10101	11000	$10 \times 2 + 1 = 21$

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

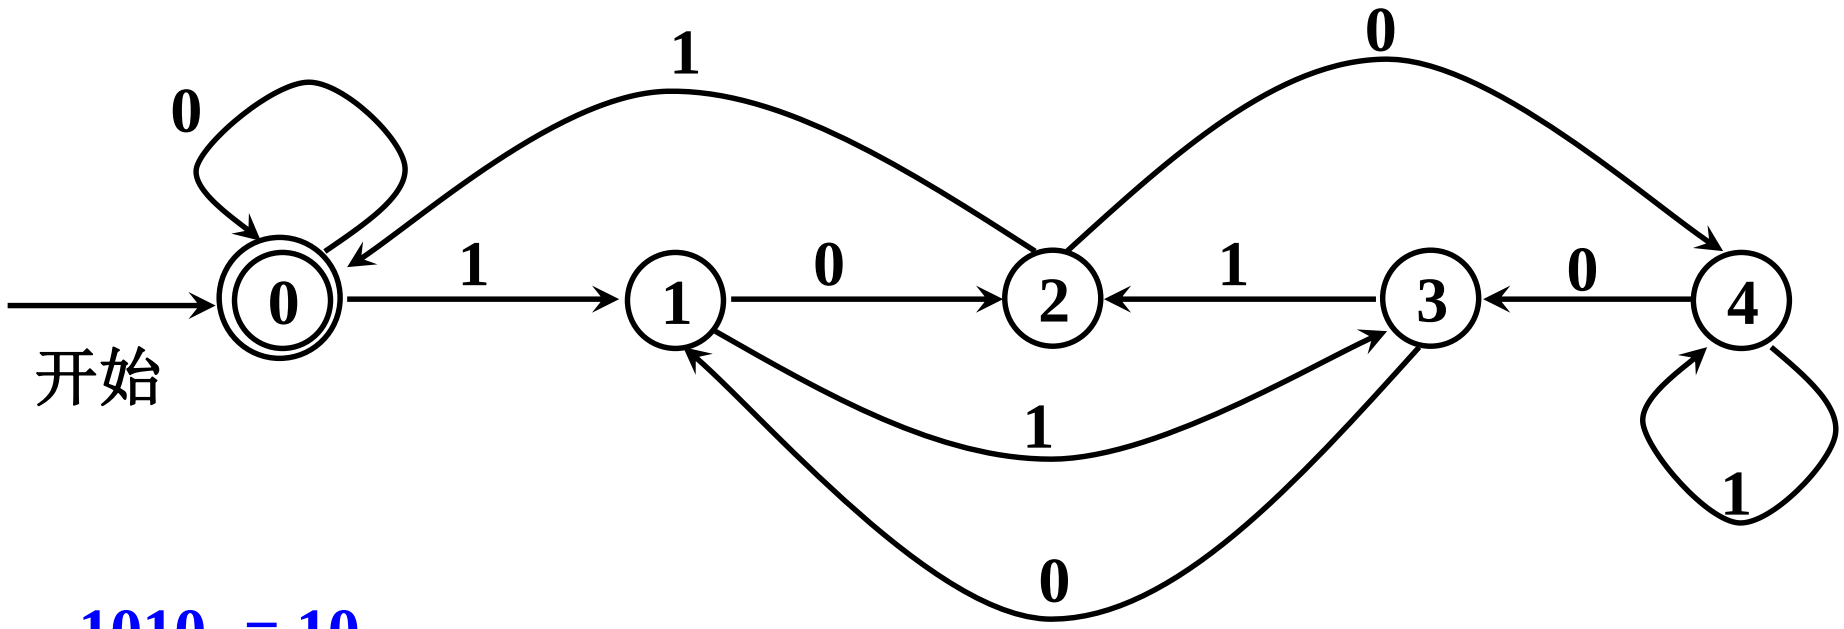

$1010_2 = 10_{10}$

$111_2 = 7_{10}$

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。

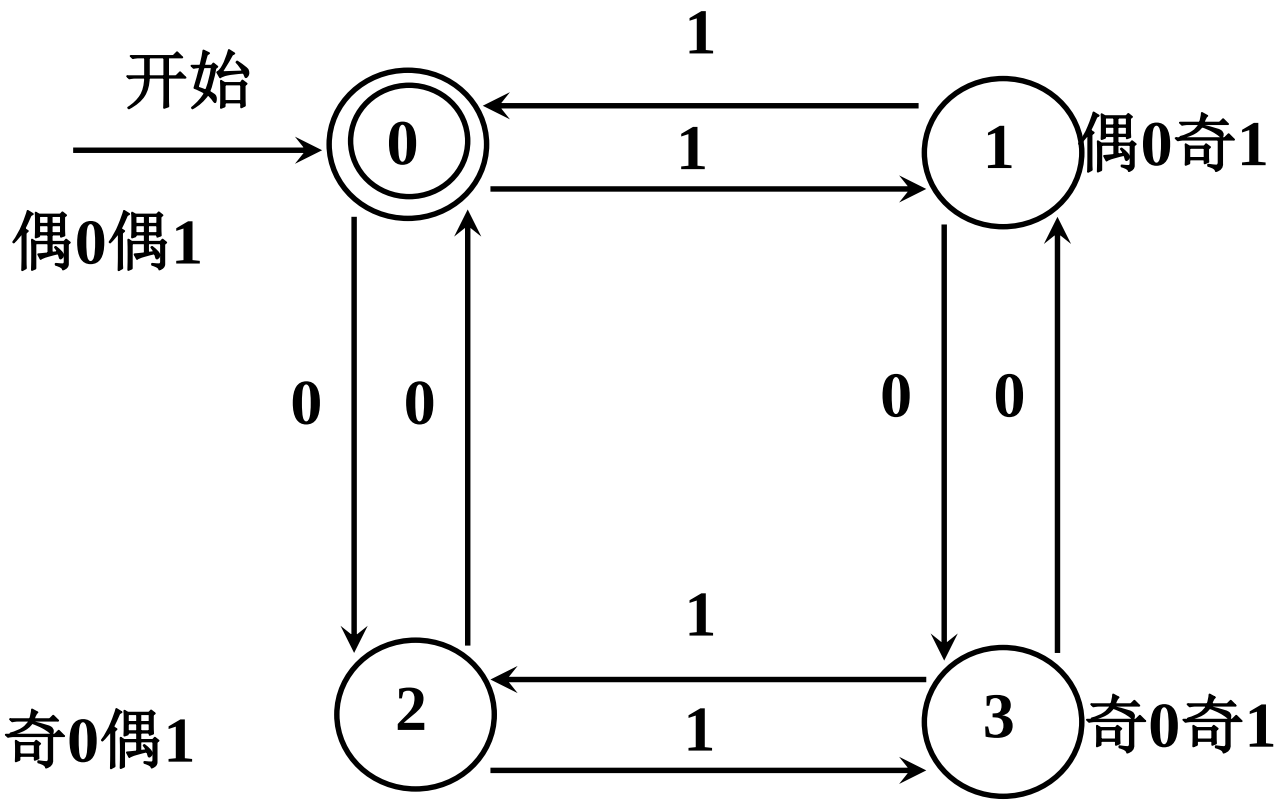

中国科学技术大学
University of Science and Technology of China

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

词法分析器的自动生成技术

- 正规式：描述语言的词法
- 有限自动机：刻画词法分析的实现

- 词法分析器自动生成的主要过程
  - 正规式→NFA（语法制导的构造算法）
  - NFA→DFA (子集构造法)
  - DFA化简
  - 根据DFA构造词法分析器源码

语法制导的NFA构造算法

- 语法制导(Syntax-directed)：按正规式的语法结构来指导构造
- 首先，构造识别 ε 和字母表中一个符号的NFA
  - 重要特点：仅有一个接受状态，接受状态没有出边

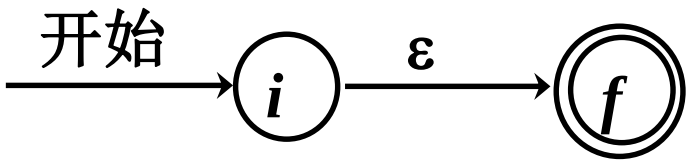

识别正规式 ε的NFA

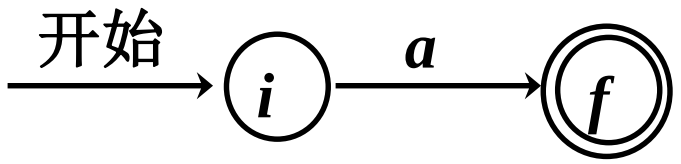

识别正规式 *a* 的NFA

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

语法制导的NFA构造算法

- 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，接受状态没有出边

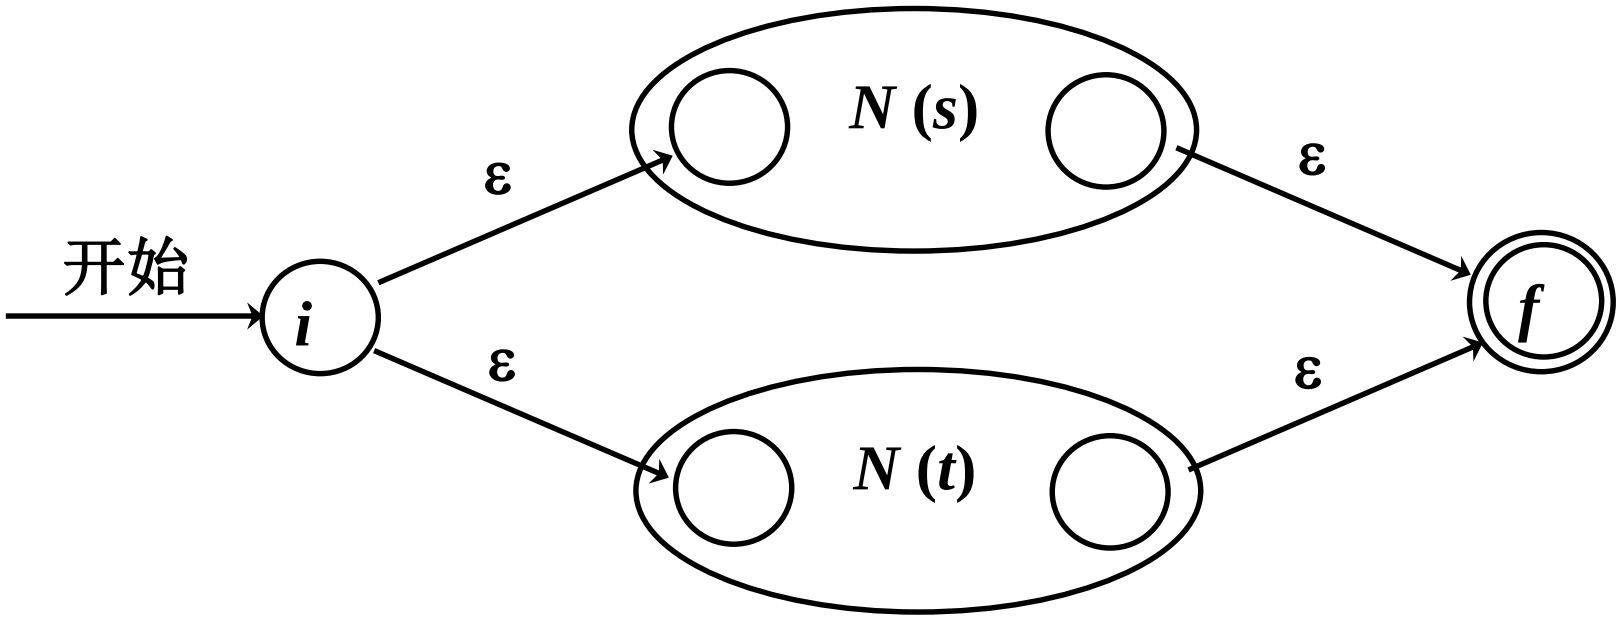

识别正规式 (s) | (t) 的NFA

语法制导的NFA构造算法

- 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，接受状态没有出边

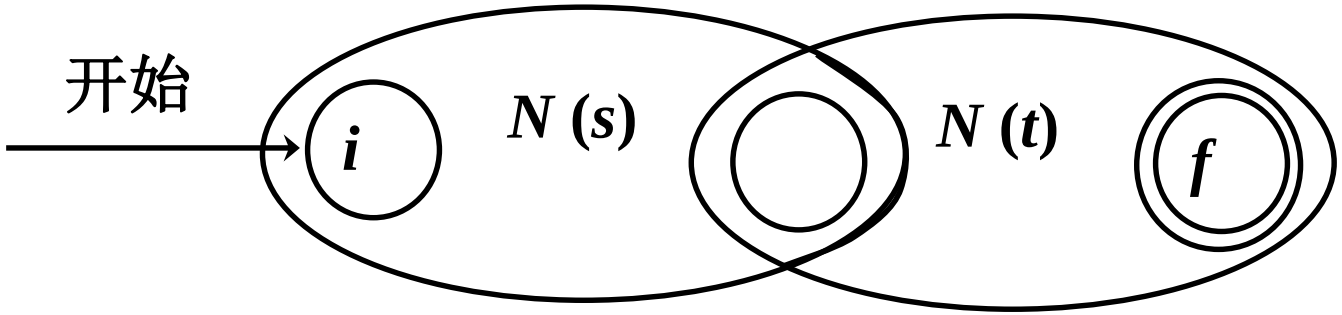

识别正规式 $(s)(t)$ 的NFA

语法制导的NFA构造算法

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，接受状态没有出边

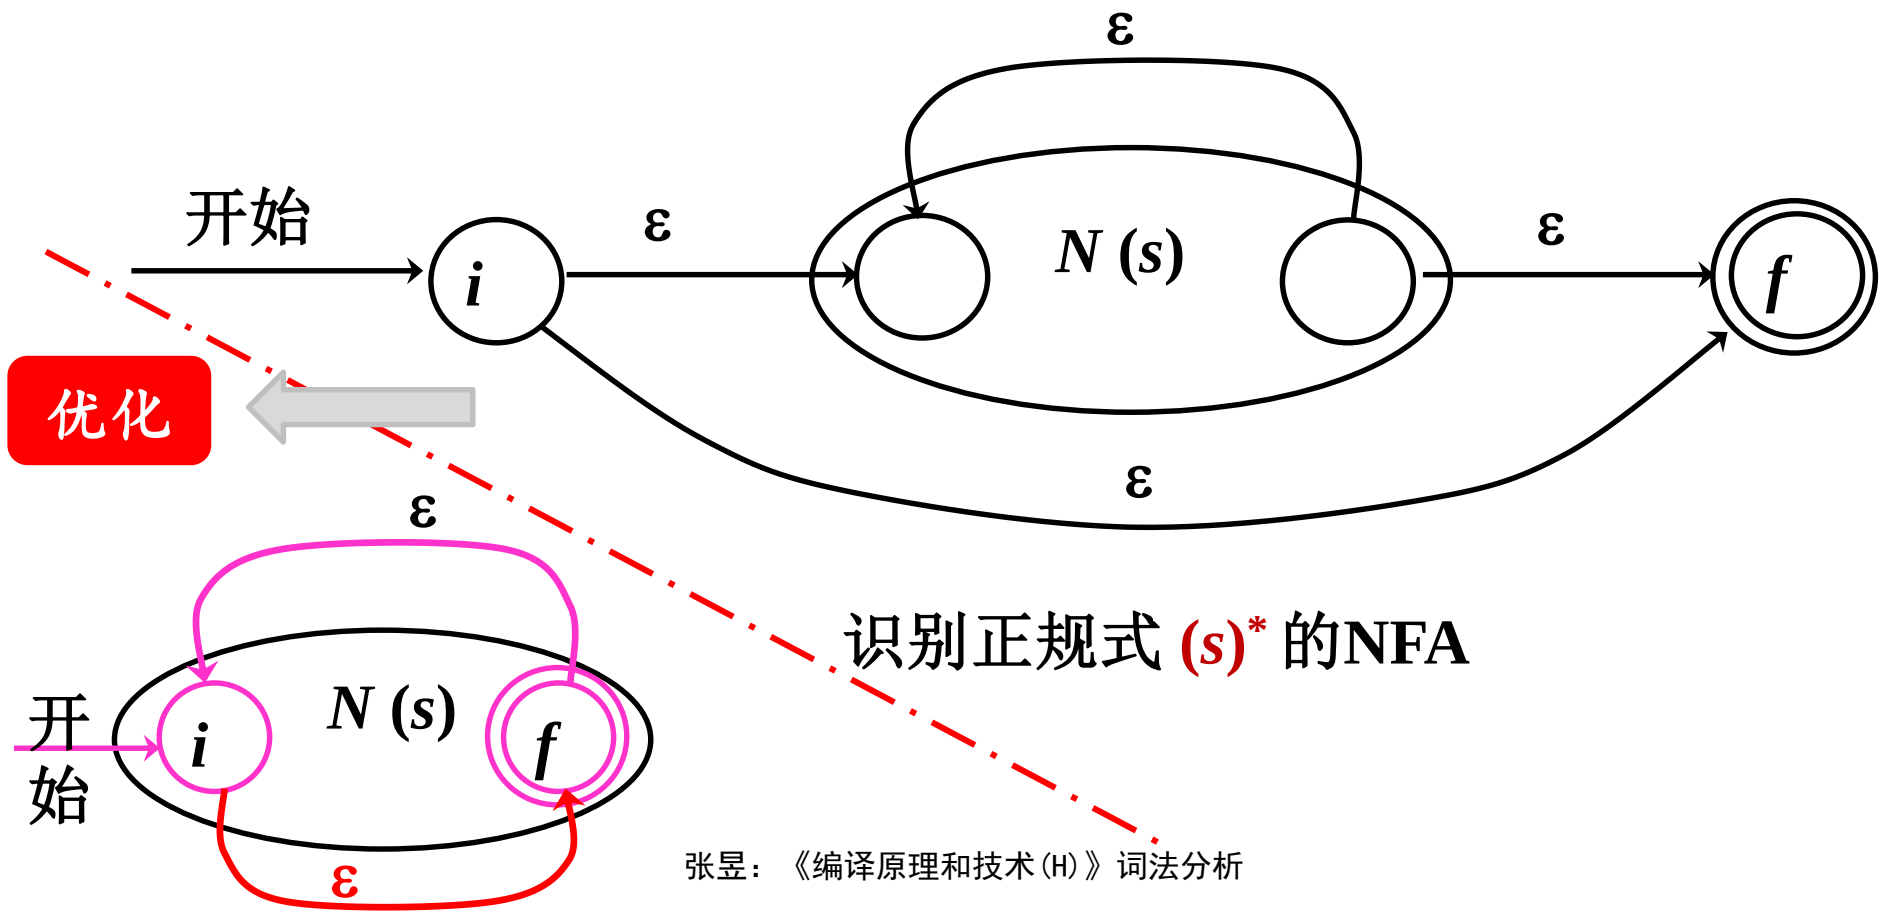

语法制导的NFA构造算法

- 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
  - $N(r)$的每个非接受状态有
    - 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

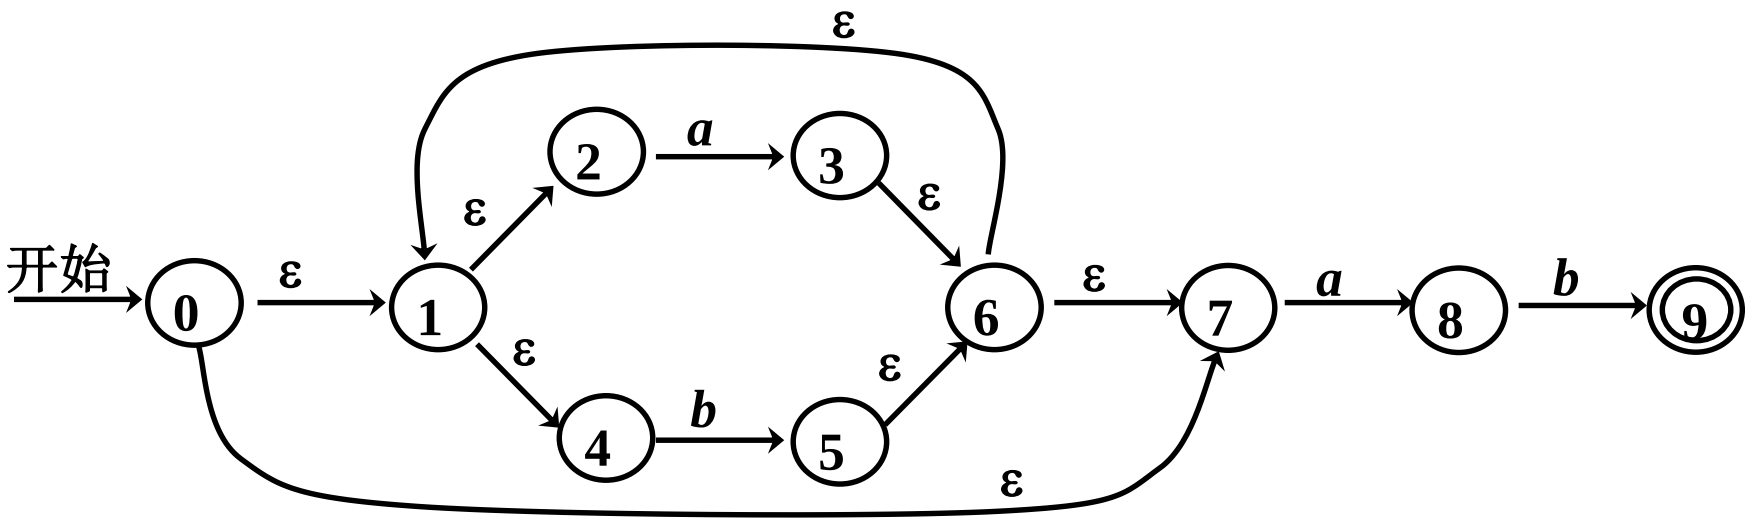

NFA构造过程举例

语法制导(Syntax-directed)：按正规式的语法结构来指导构造

$(a|b)^*ab$的分解

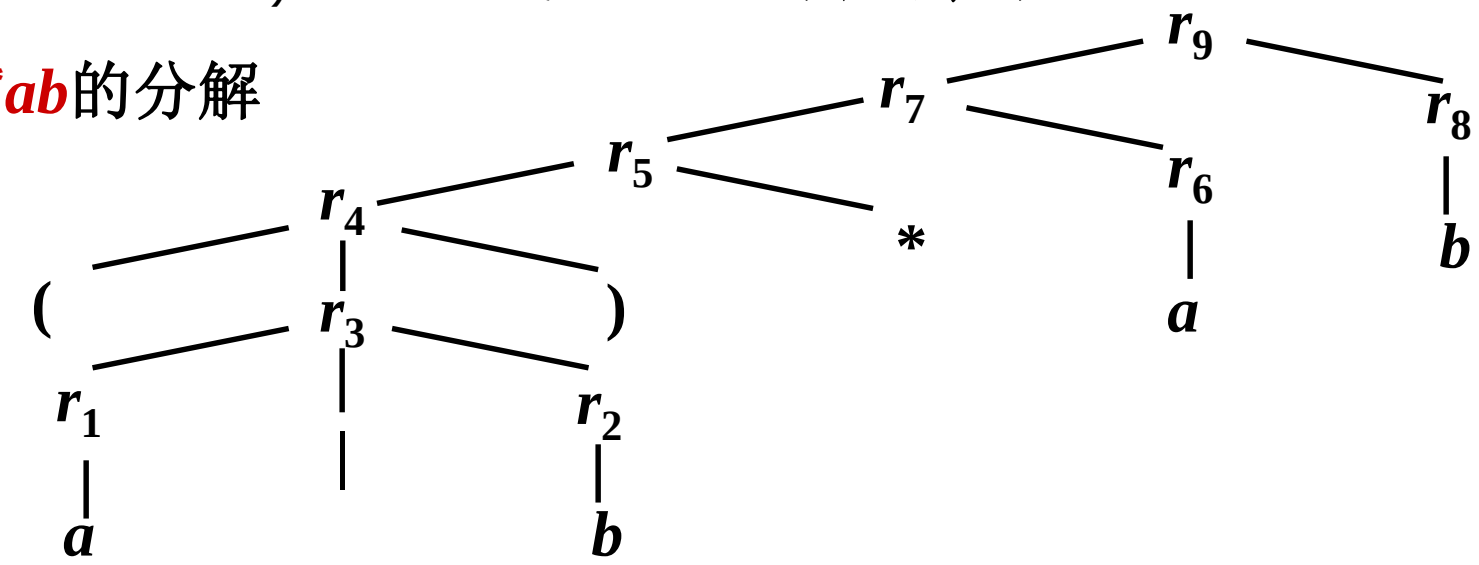

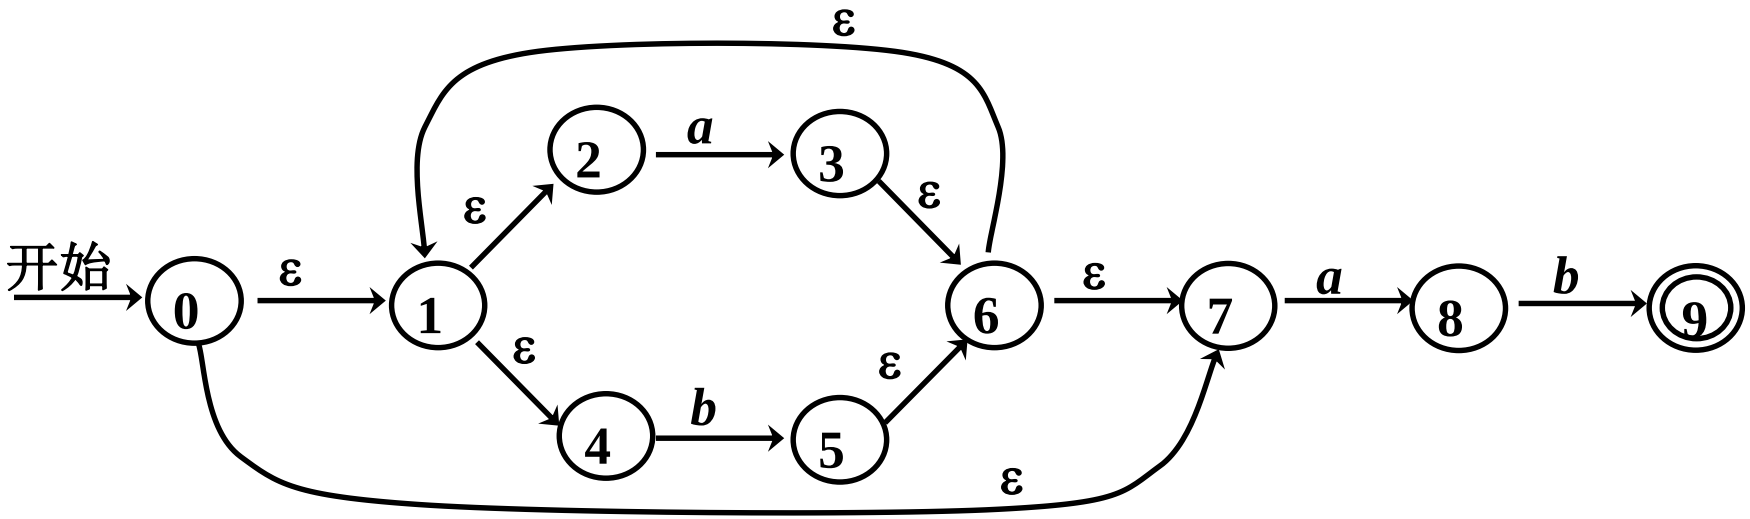

NFA构造过程举例

$(a|b)^*ab$的分解

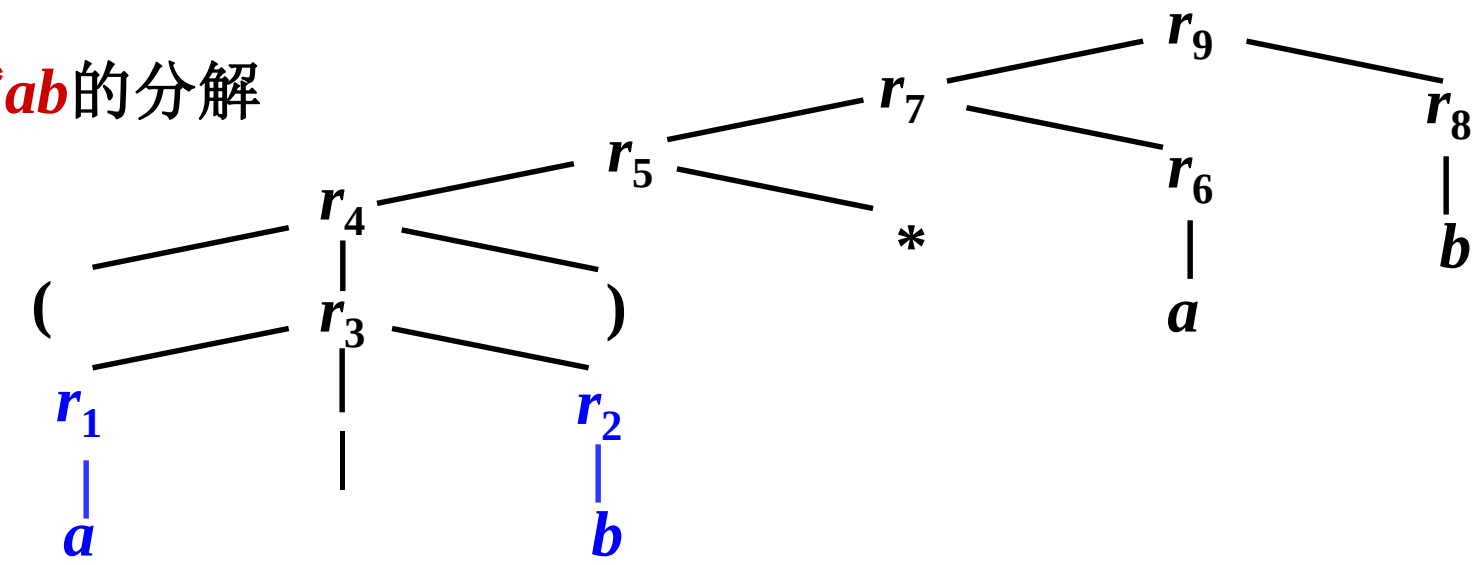

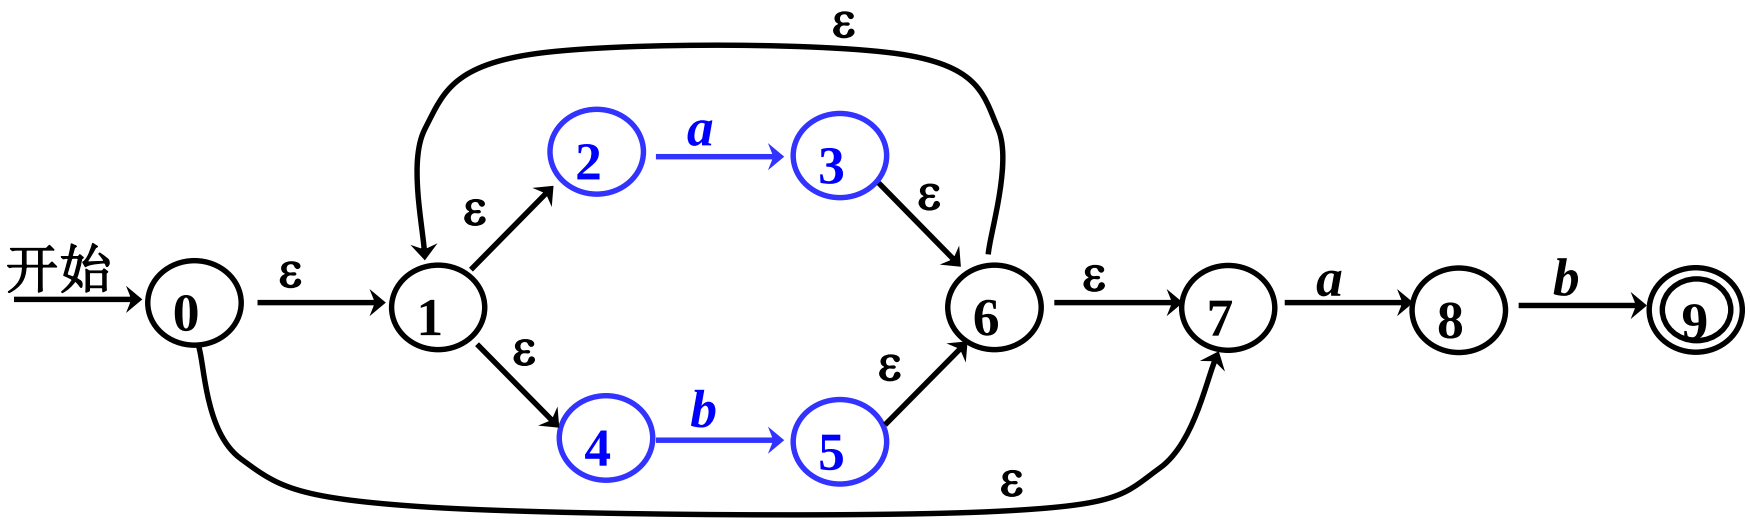

NFA构造过程举例

$(a|b)^*ab$的分解

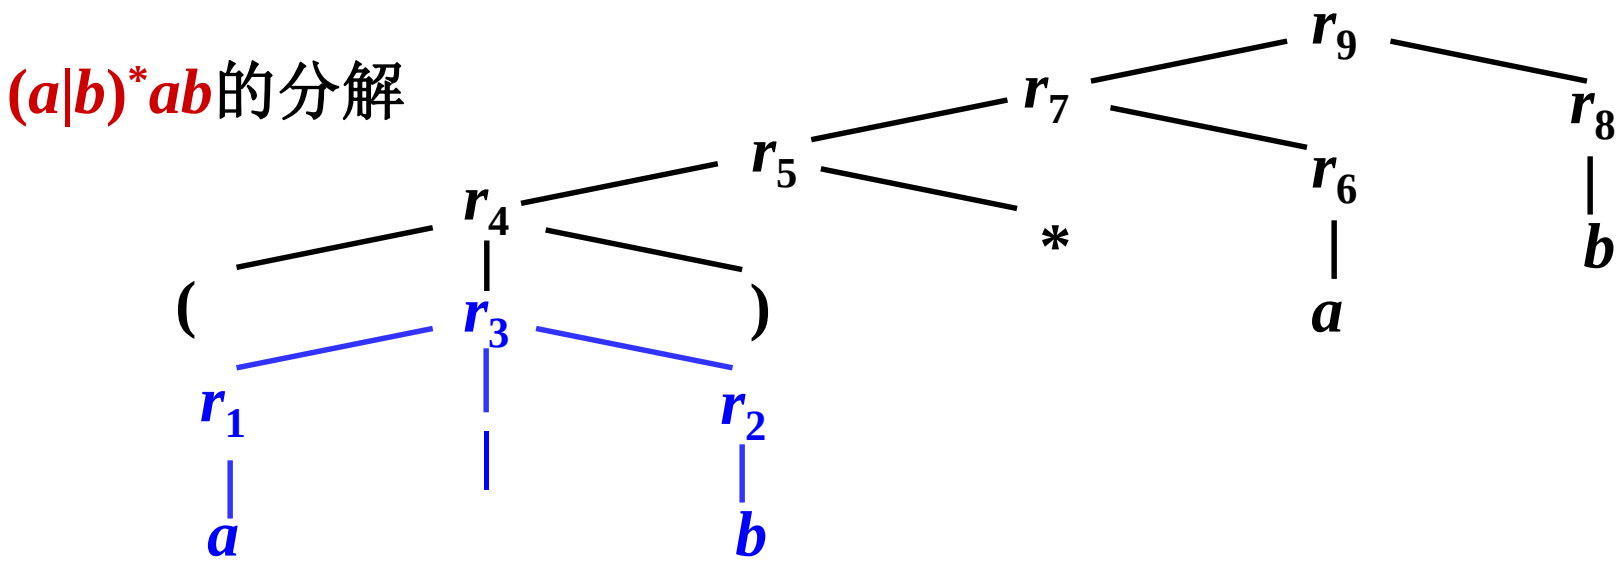

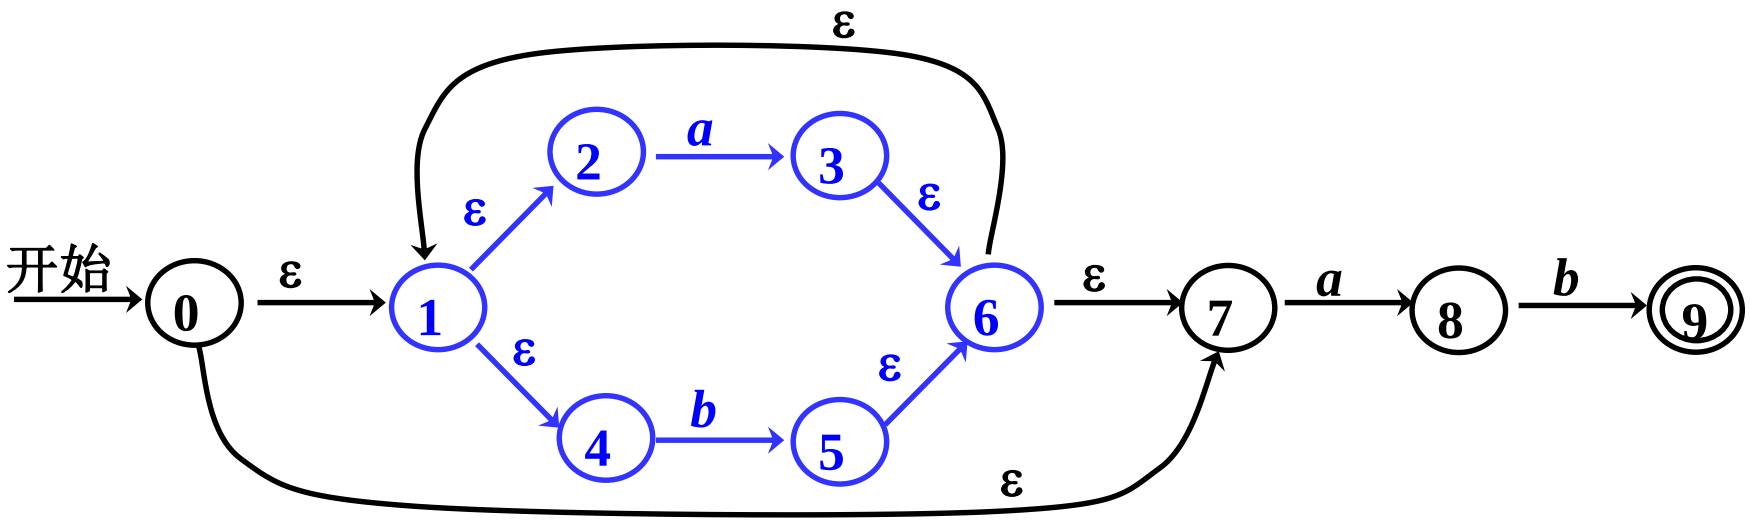

NFA构造过程举例

$(a|b)^*ab$的分解

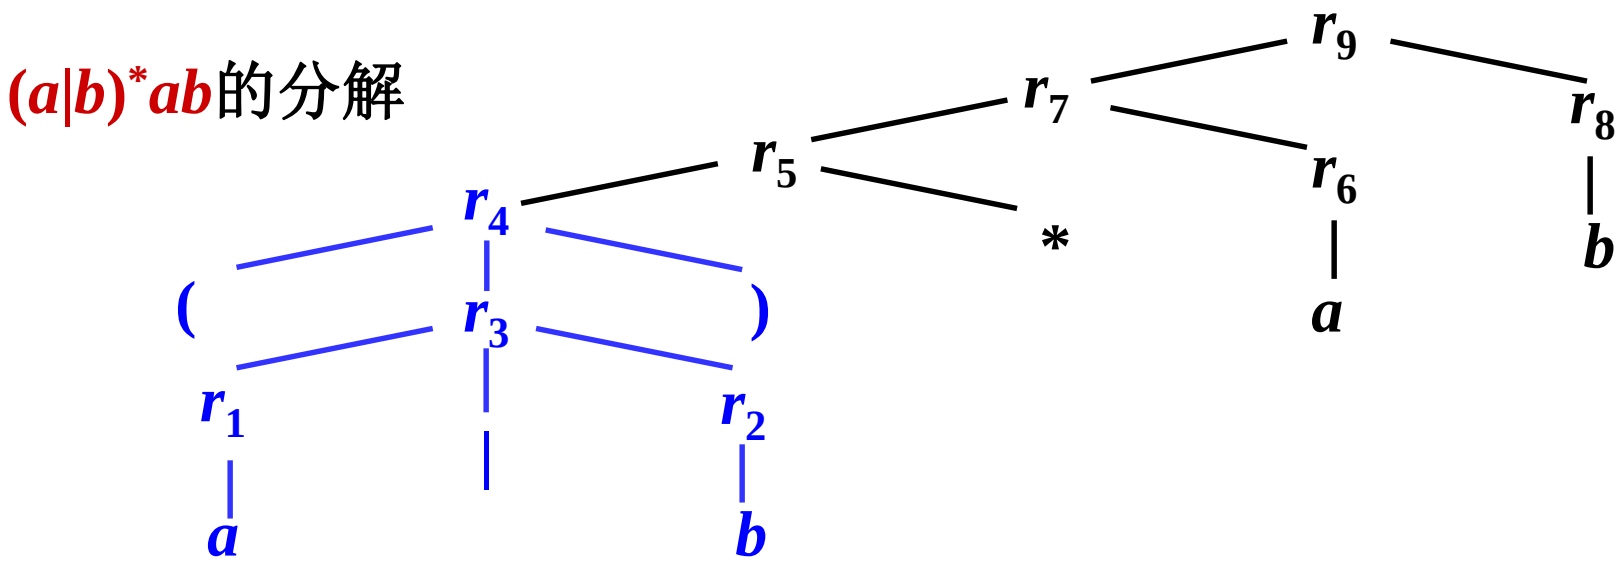

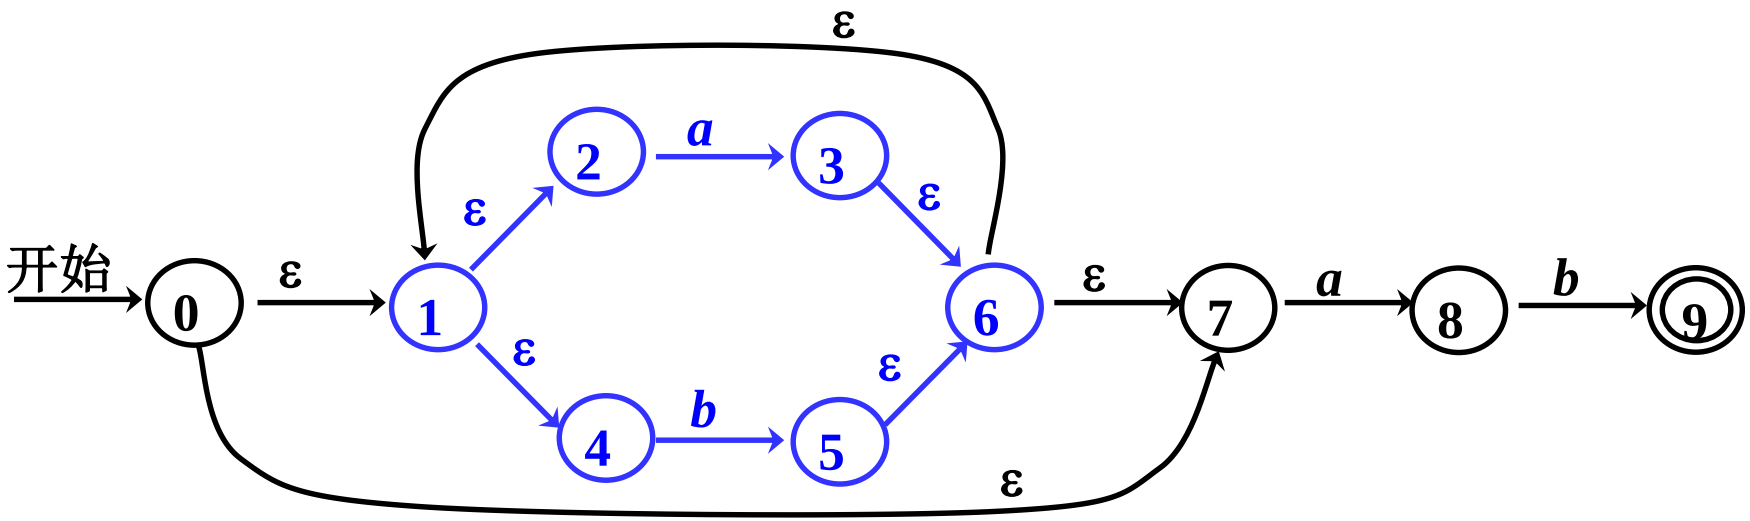

NFA构造过程举例

$(a|b)^*ab$的分解

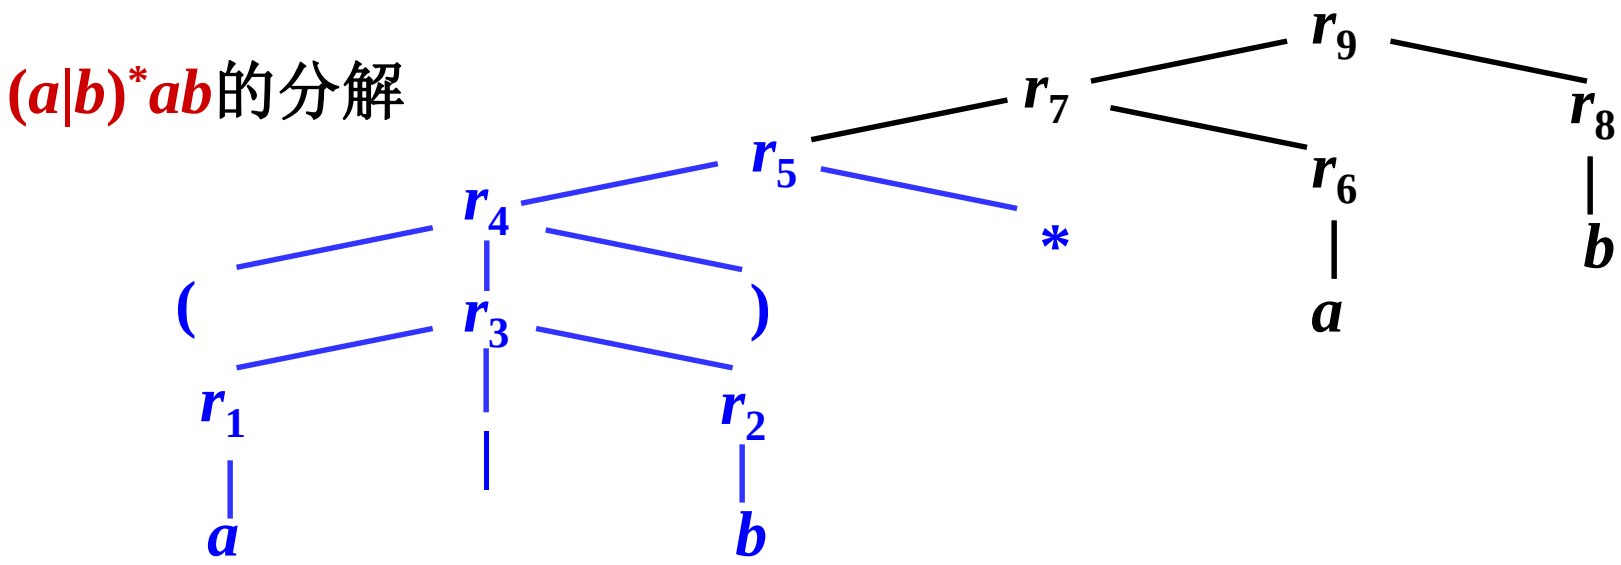

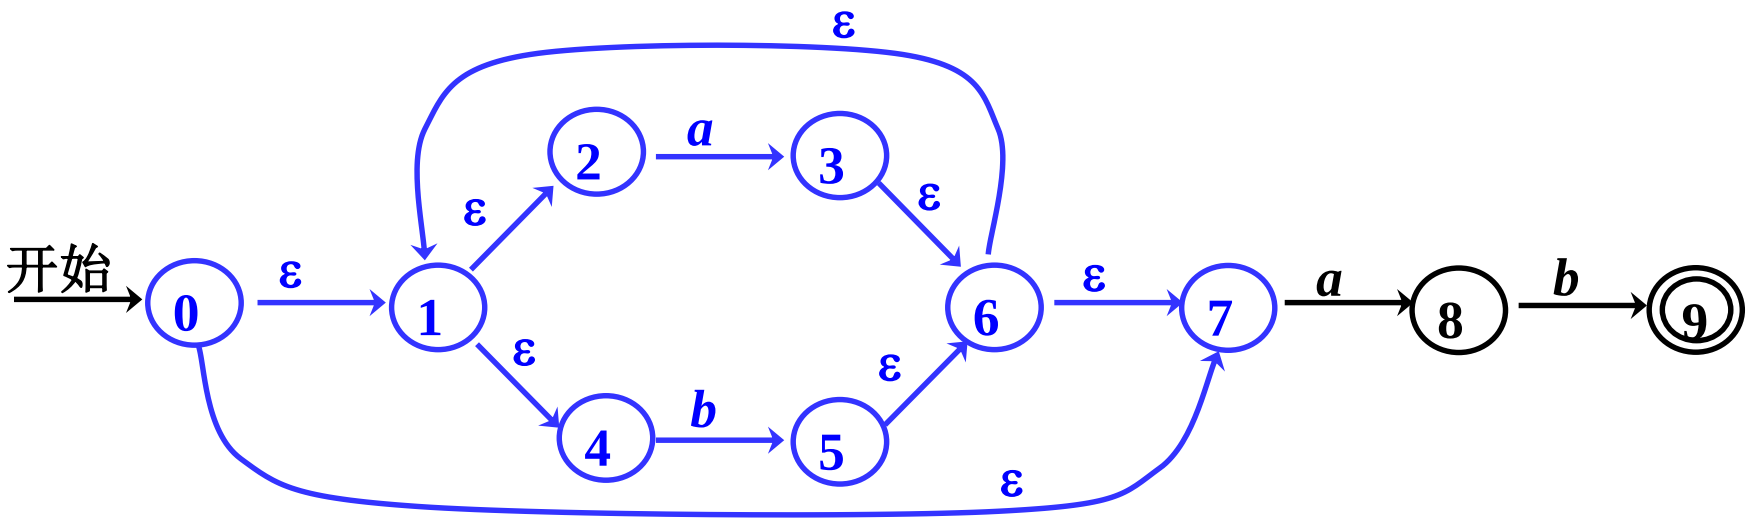

NFA构造过程举例

$(a|b)^*ab$的分解

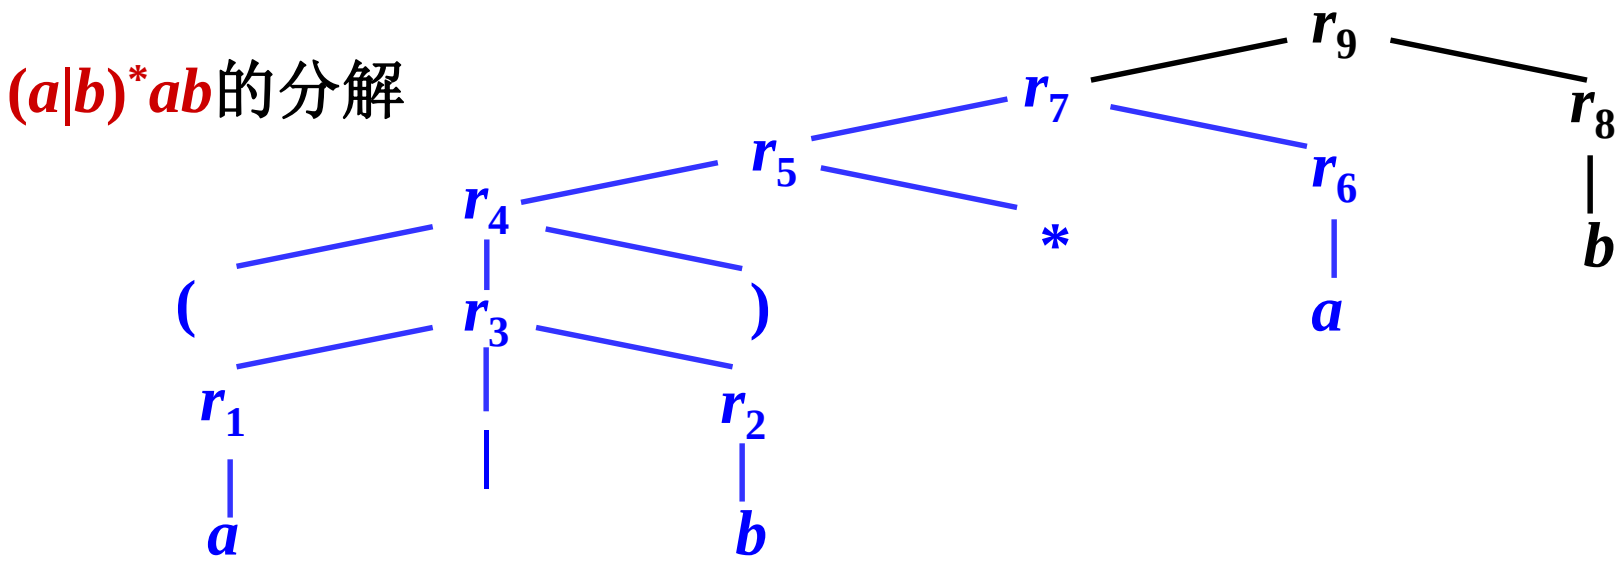

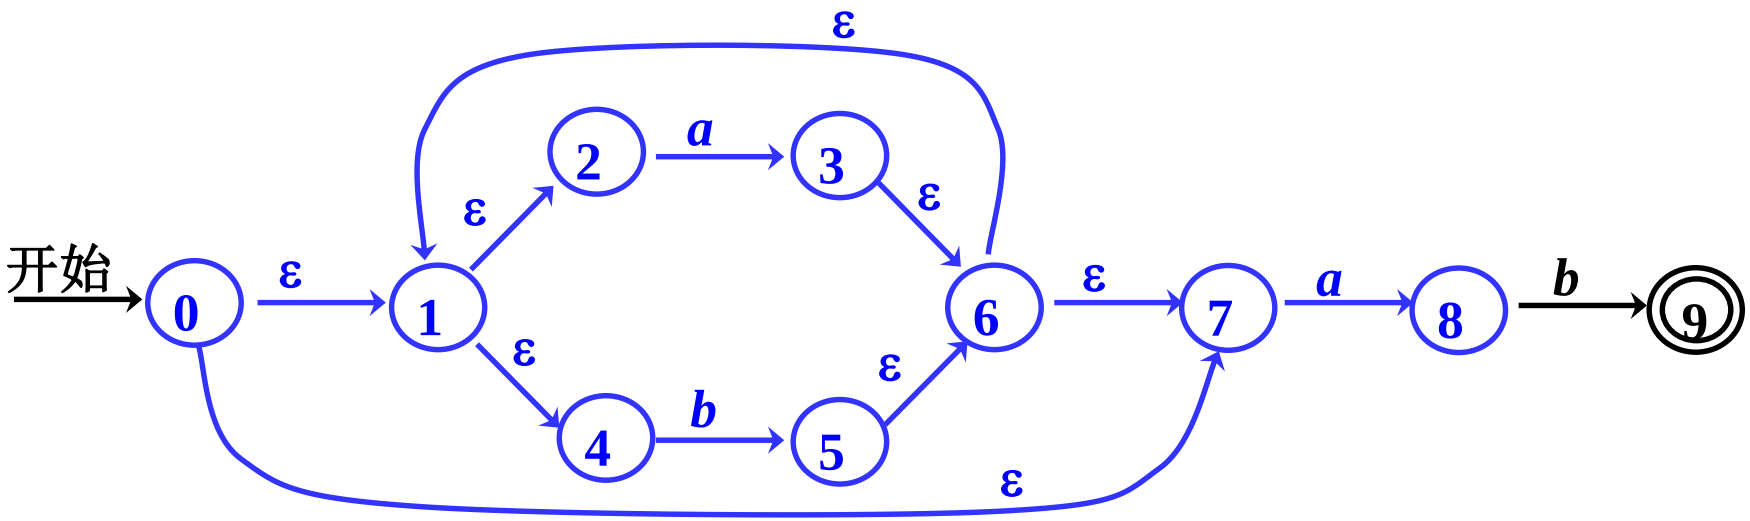

NFA构造过程举例

$(a|b)^*ab$的分解

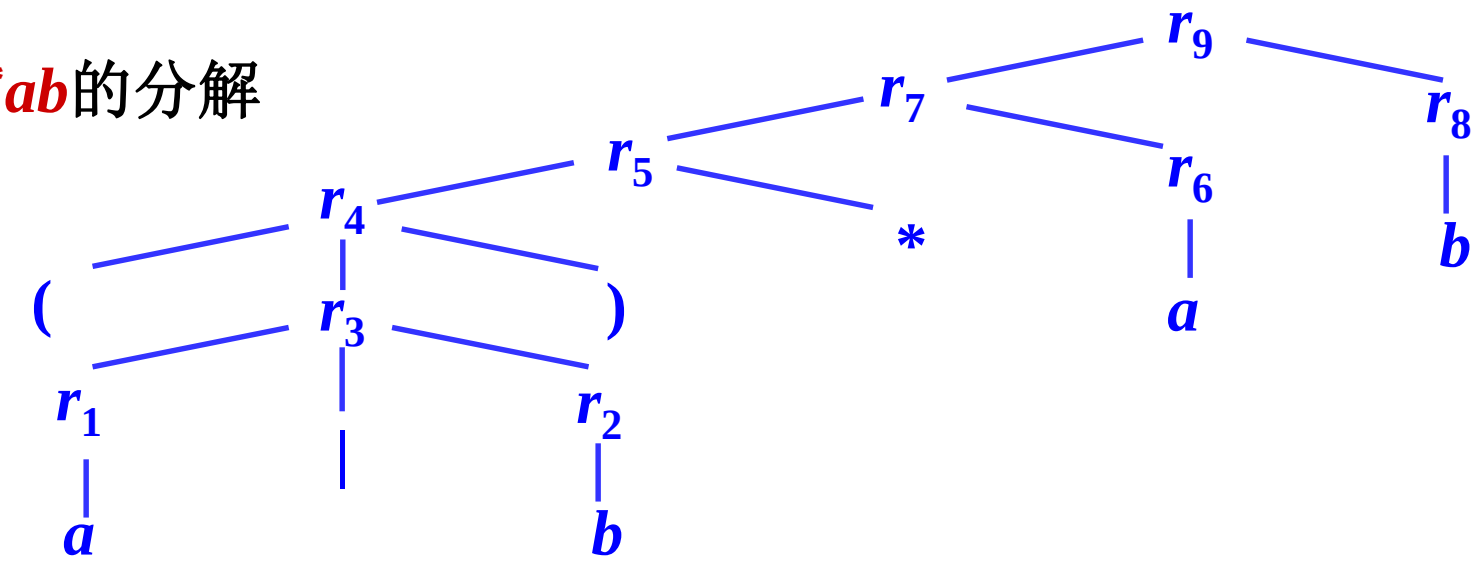

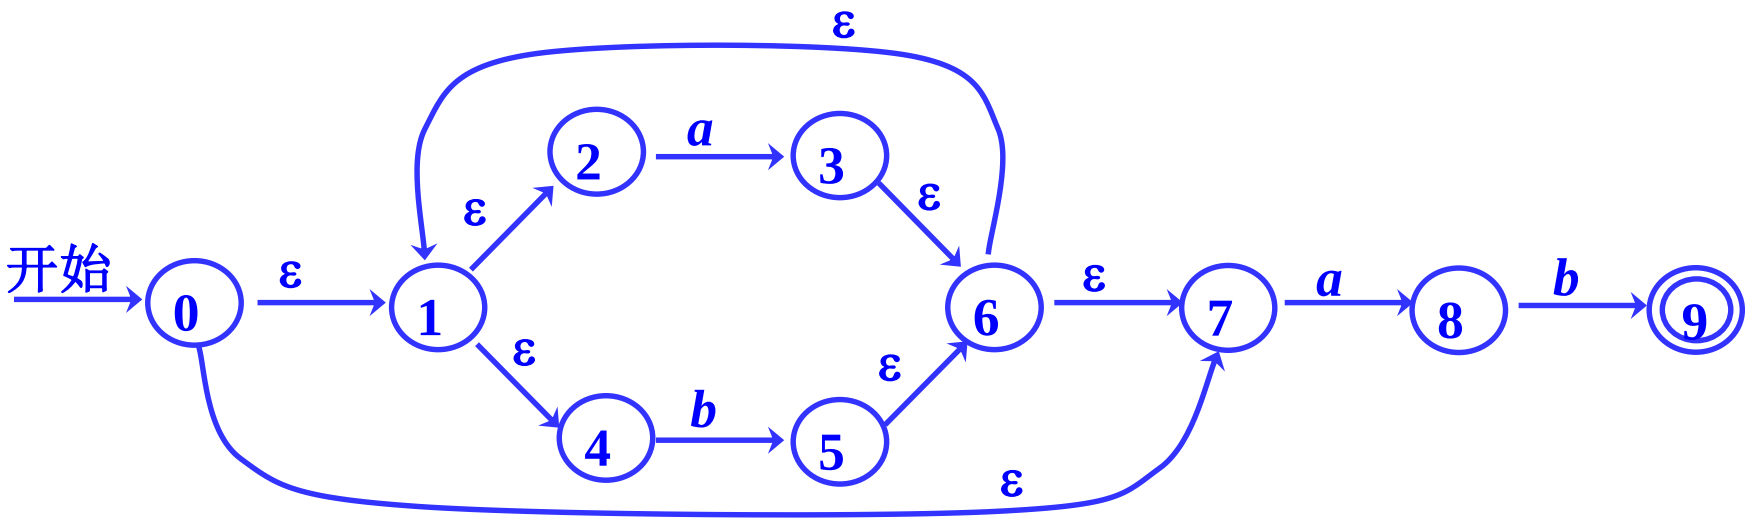

NFA的手工构造和算法构造

- $(a|b)^*ab$的两个NFA的比较

手工构造:

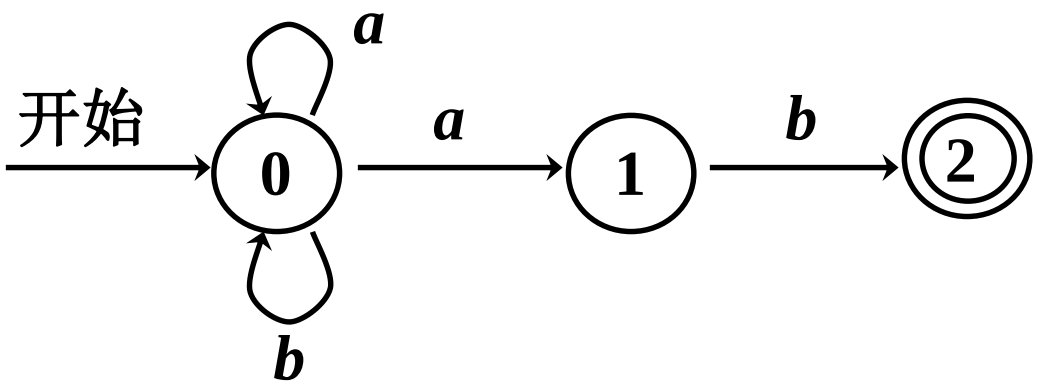

算法构造:

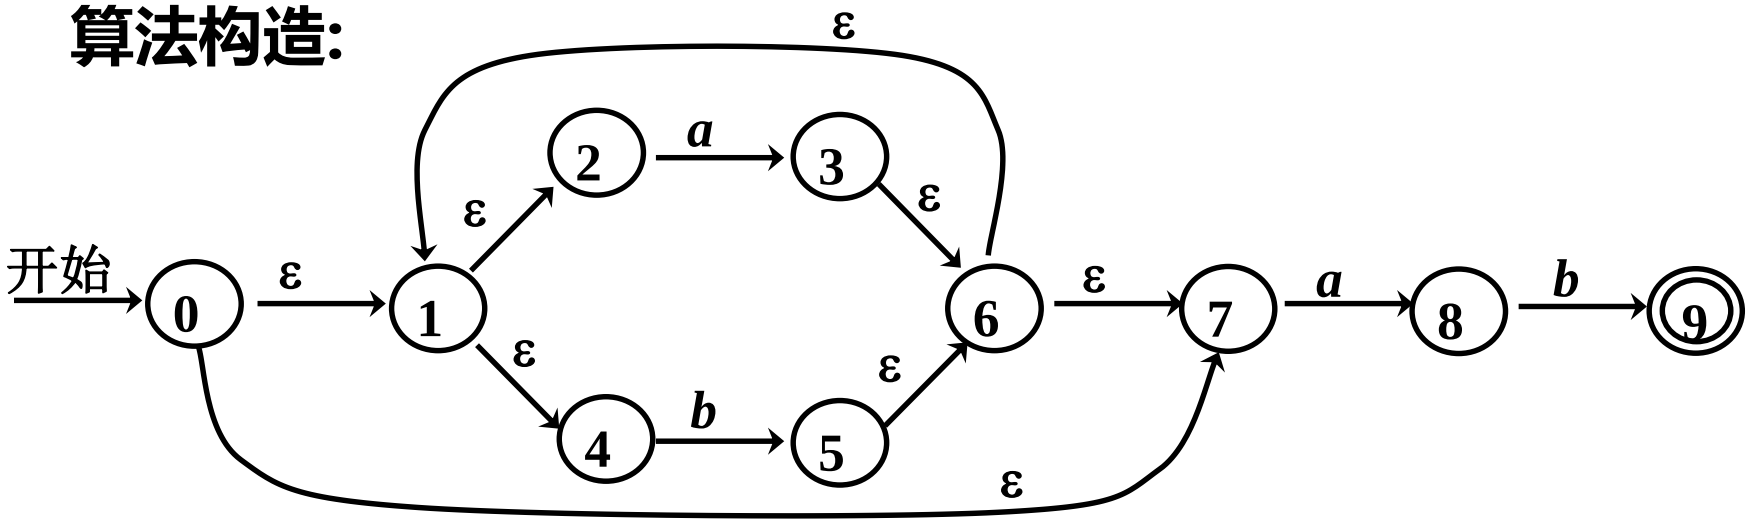

词法分析器的自动生成技术

- 正规式：描述语言的词法
- 有限自动机：刻画词法分析的实现

- 词法分析器自动生成的主要过程
  - 正规式→NFA（语法制导的构造算法）
  - NFA→DFA (子集构造法)
  - DFA化简
  - 根据DFA构造词法分析器源码

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. DFA的开始状态是包含NFA的开始状态的状态集合
3. 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$\{s_1, s_2, \ldots, s_k\}$

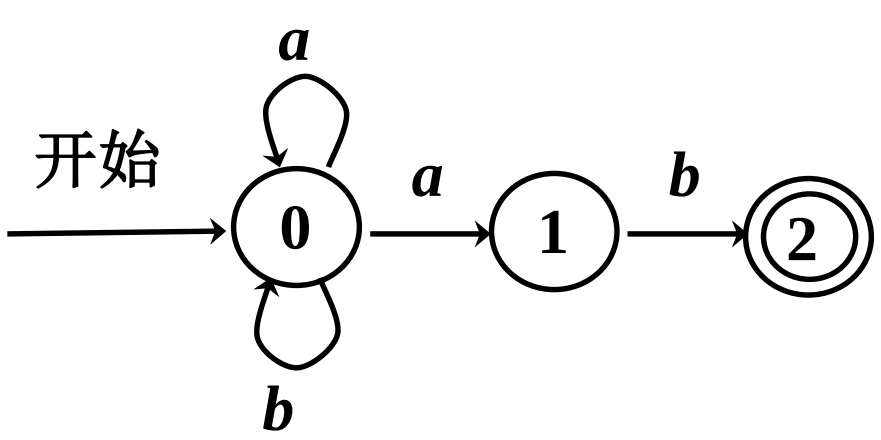

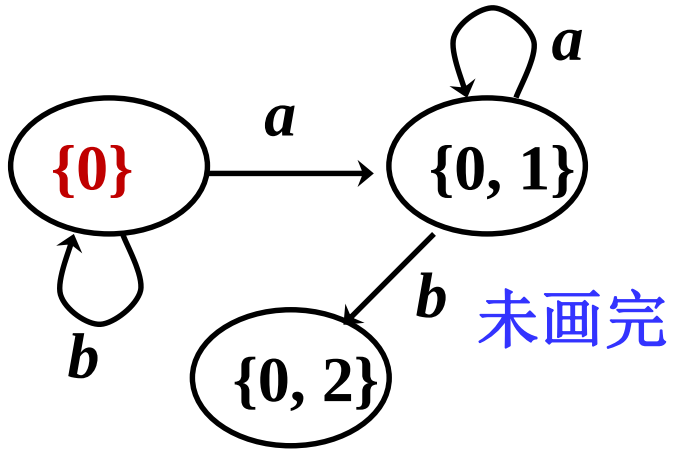

NFA到DFA的变换

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A，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

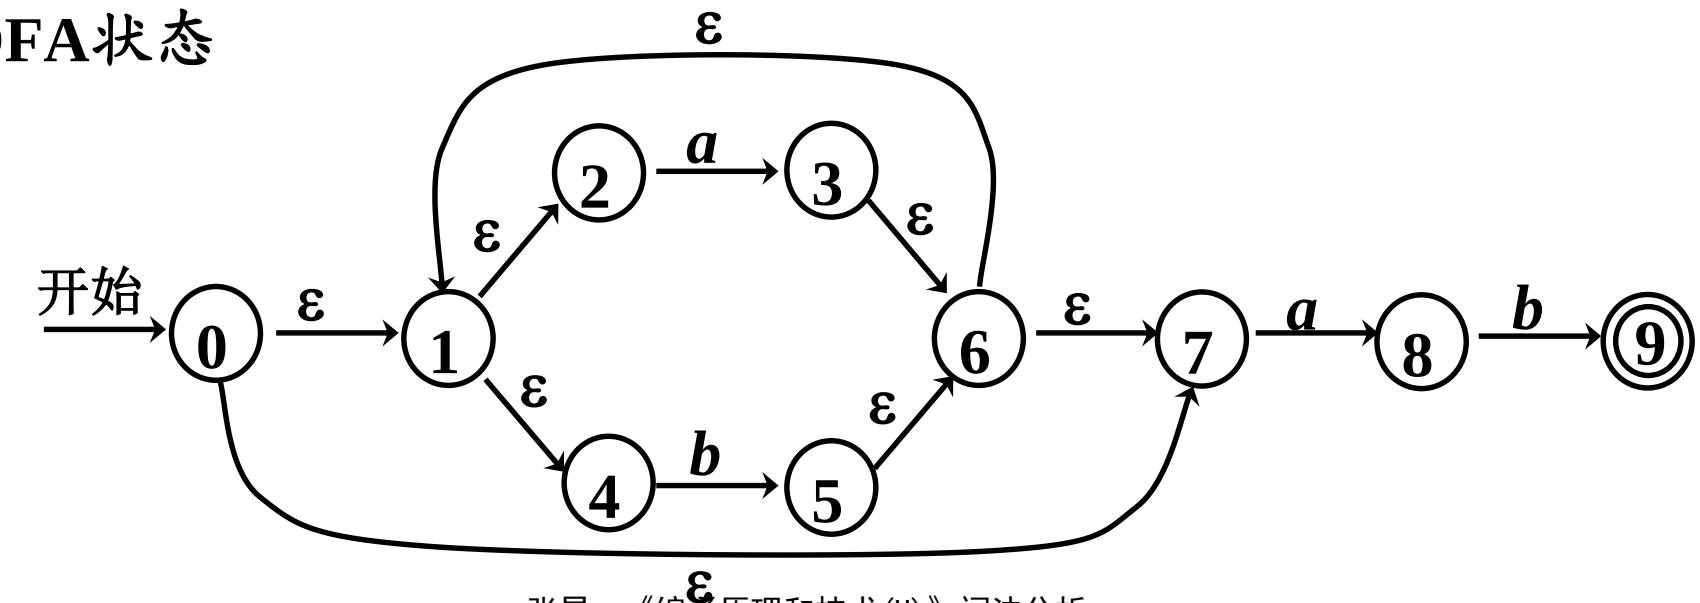

例题6

正规式 $(a|b)^*ab$ 对应的NFA如下，把它变换为DFA

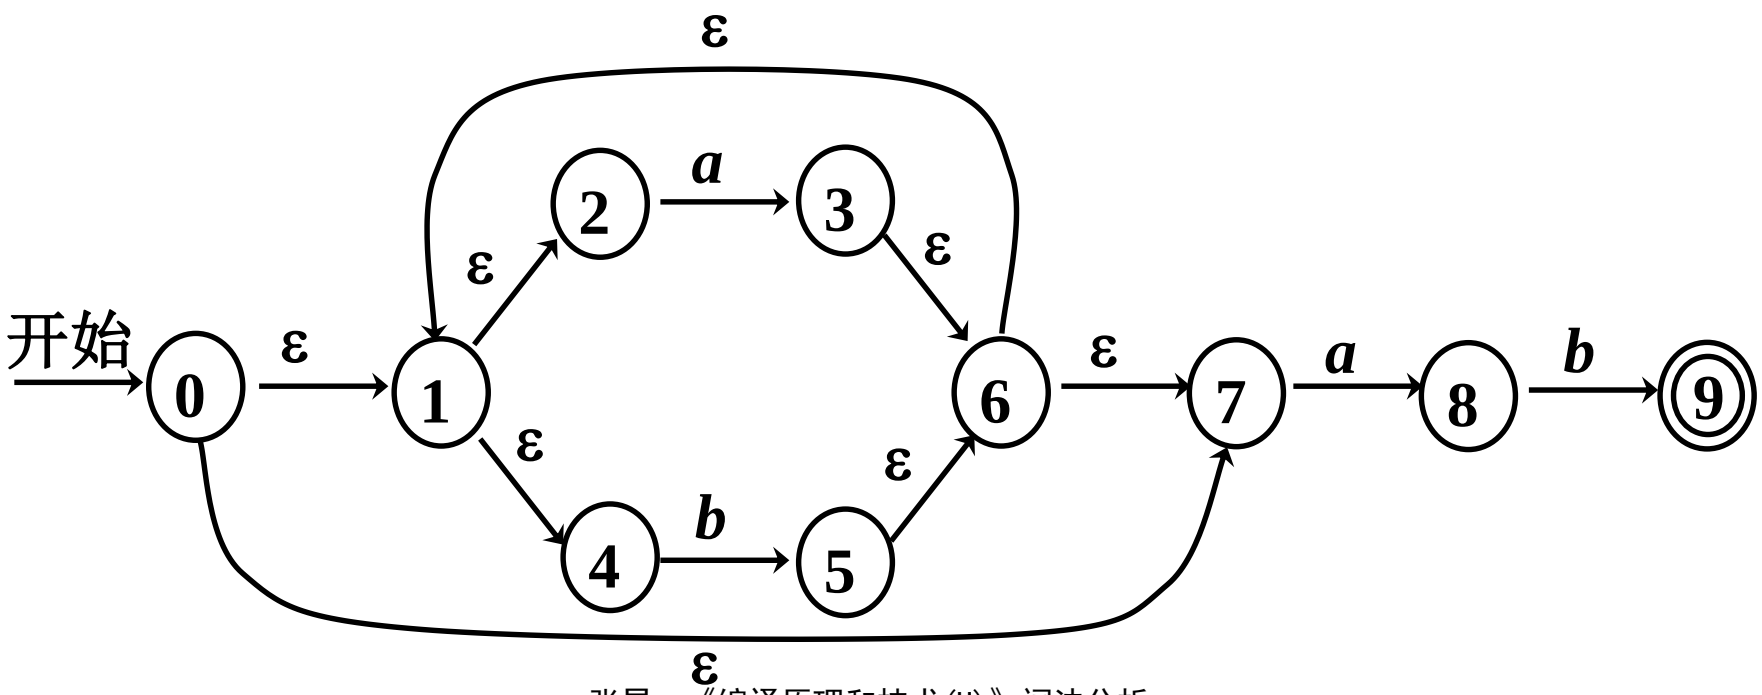

例题6

状态	输入符号	
	a	*b*

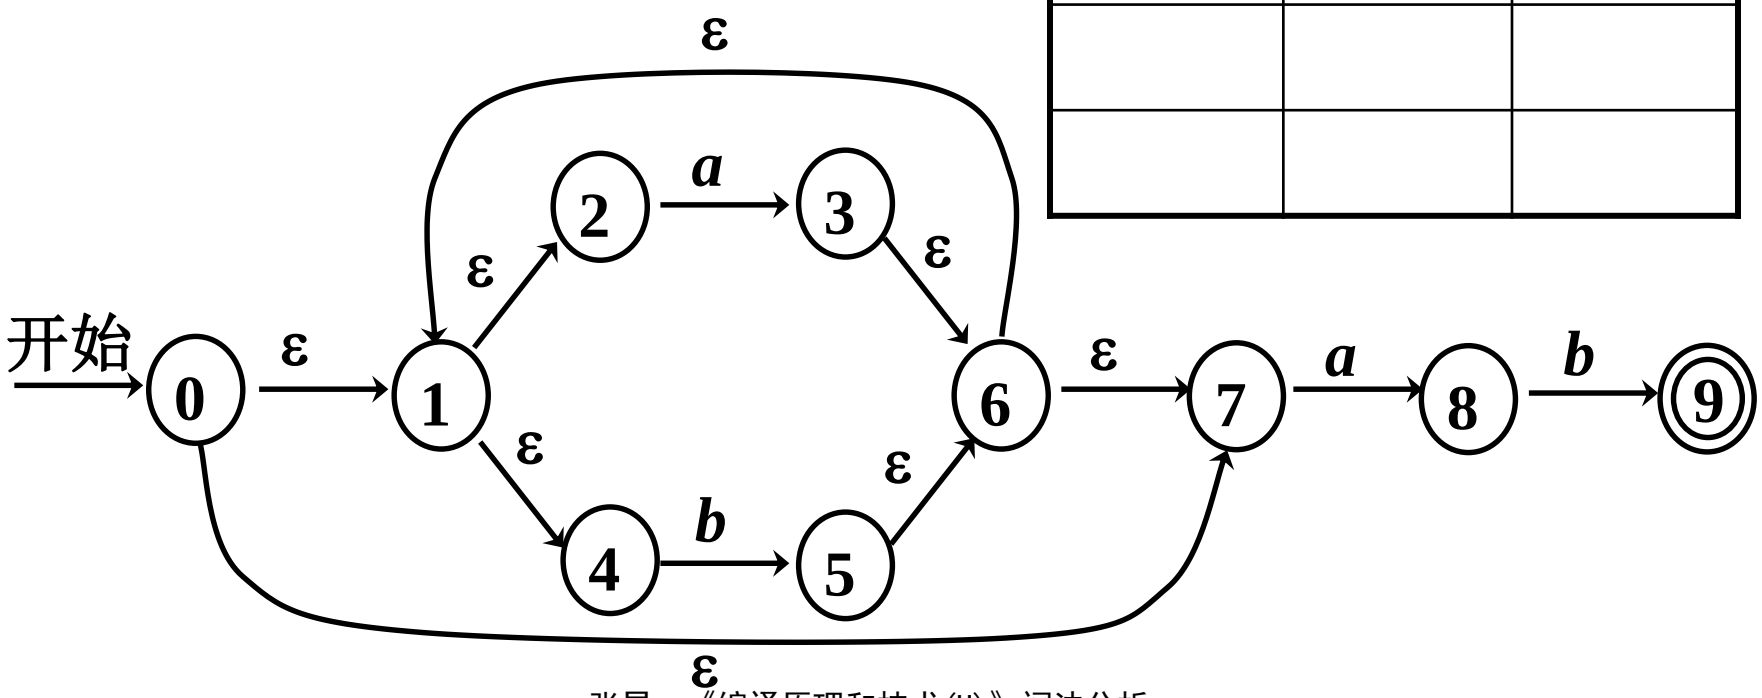

例题6

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

状态	输入符号	
	a	*b*
A		

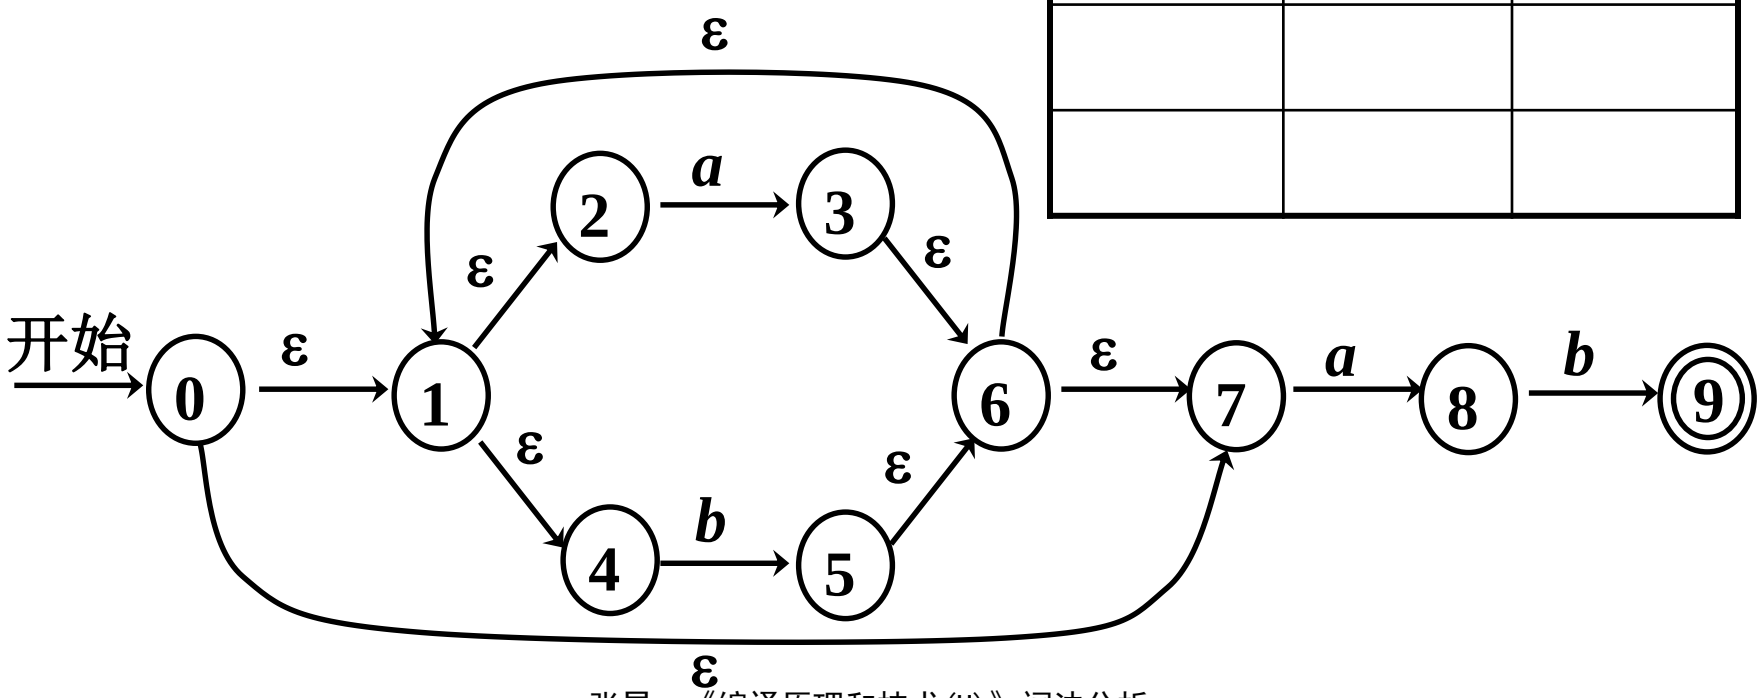

例题6

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

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

状态	输入符号	
	a	b
A	B	

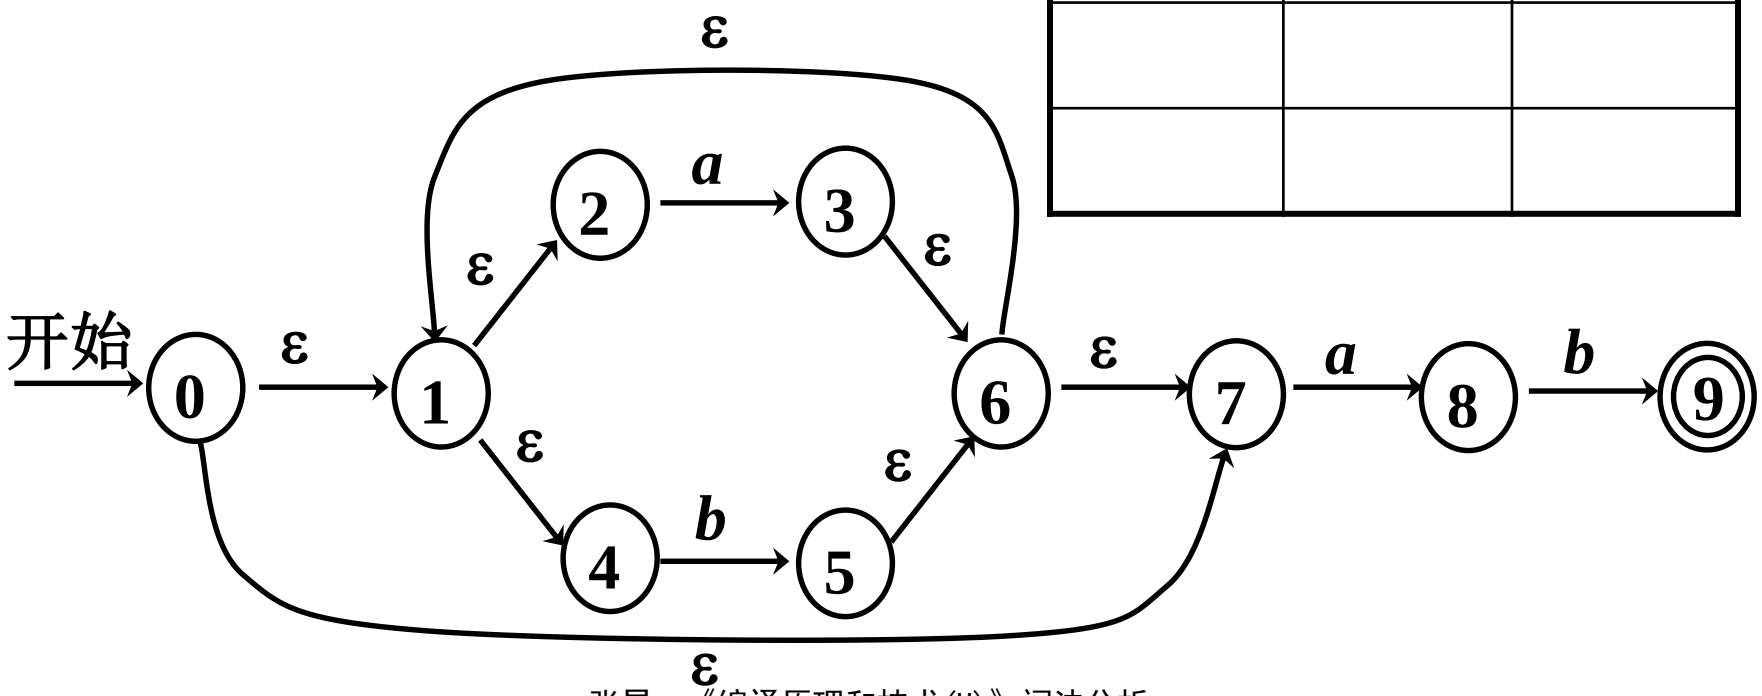

例题6

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

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

状态	输入符号	
	a	b
A	B	
B		

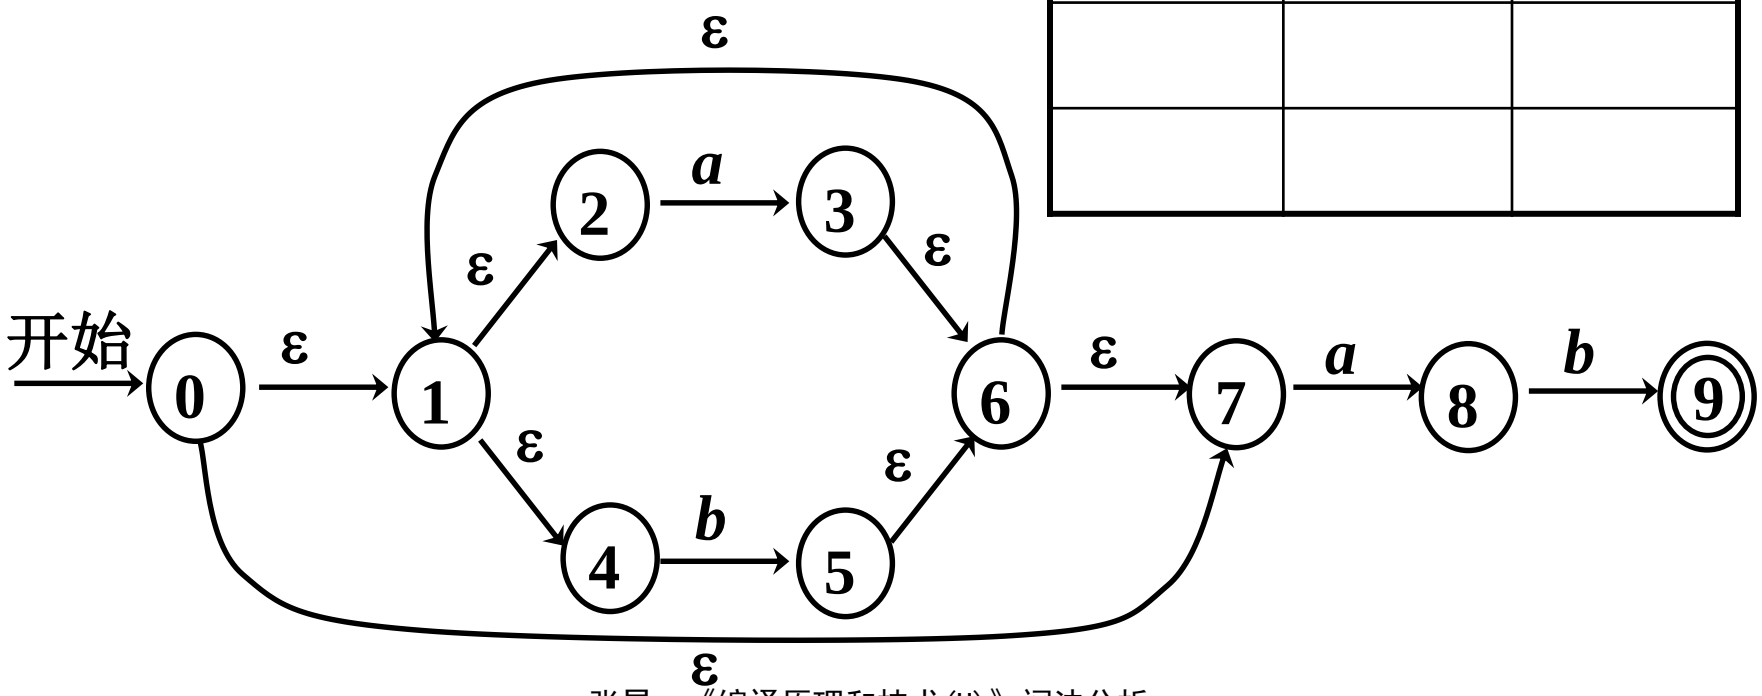

例题6

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

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

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

状态	输入符号	
	a	b
A	B	C
B		

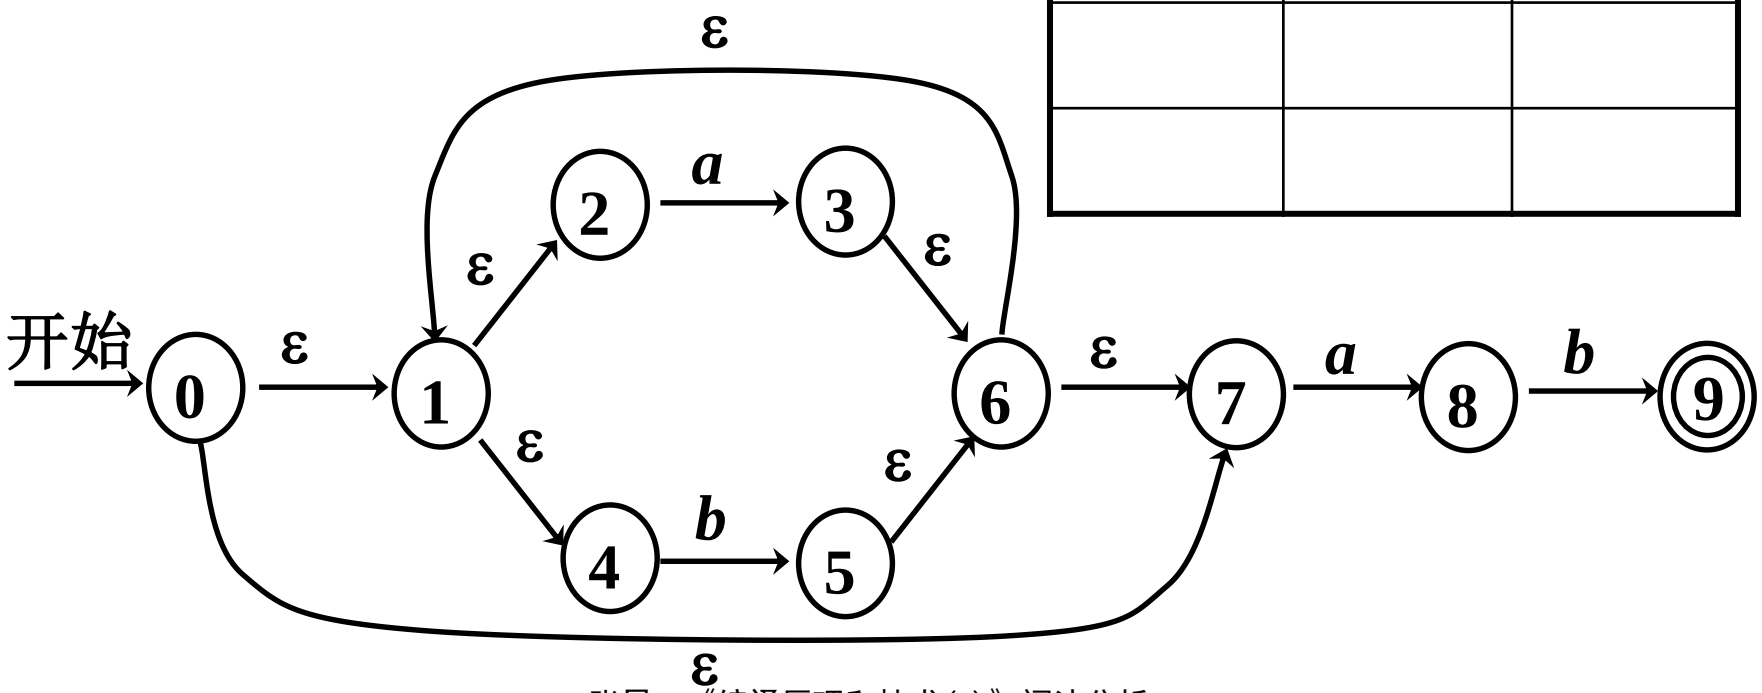

例题6

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

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

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

状态	输入符号	
	a	b
A	B	C
B		
C		

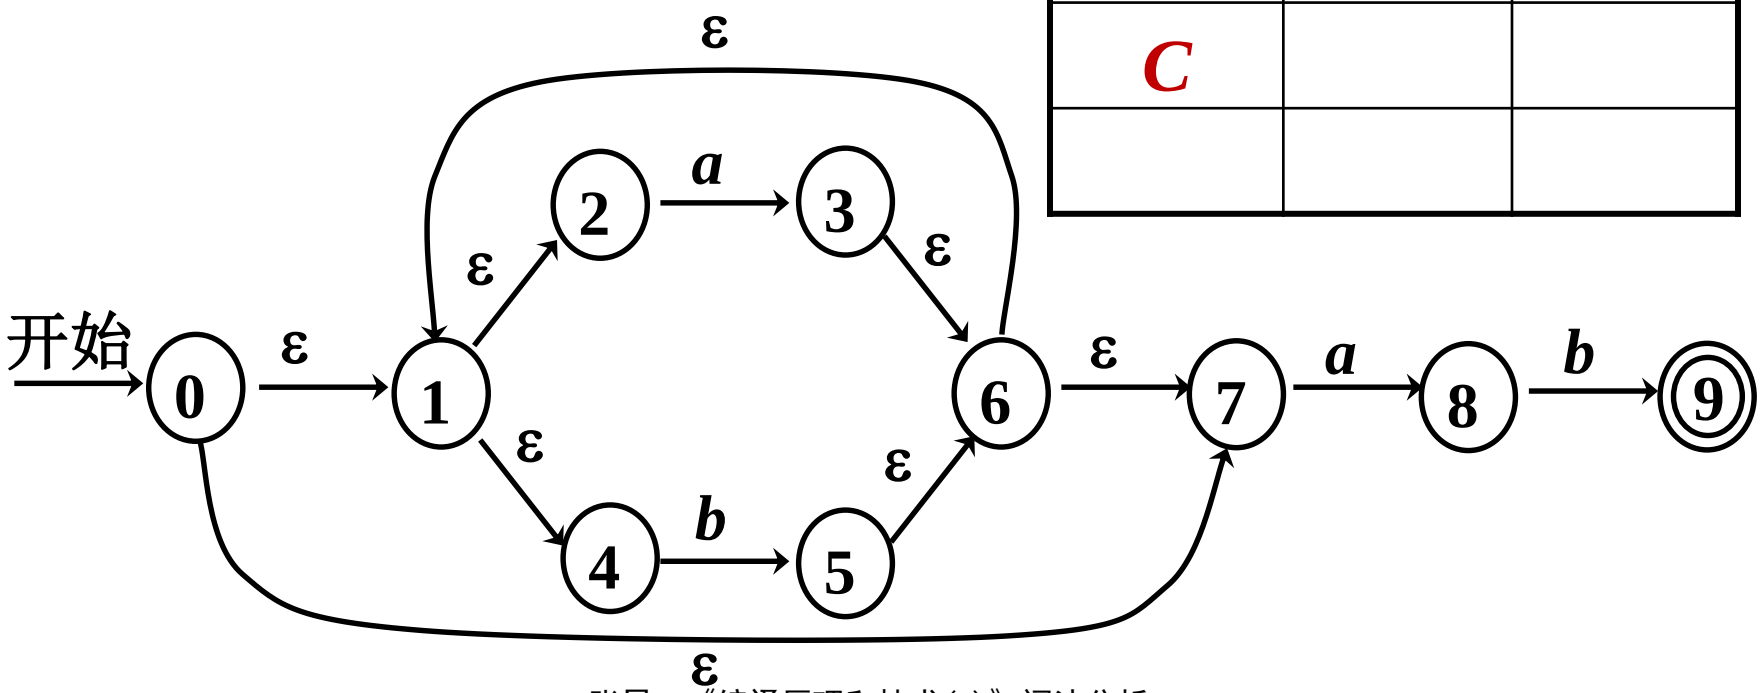

例题6

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

状态	输入符号	
	a	*b*
A	*B*	*C*
B	*B*	
C		

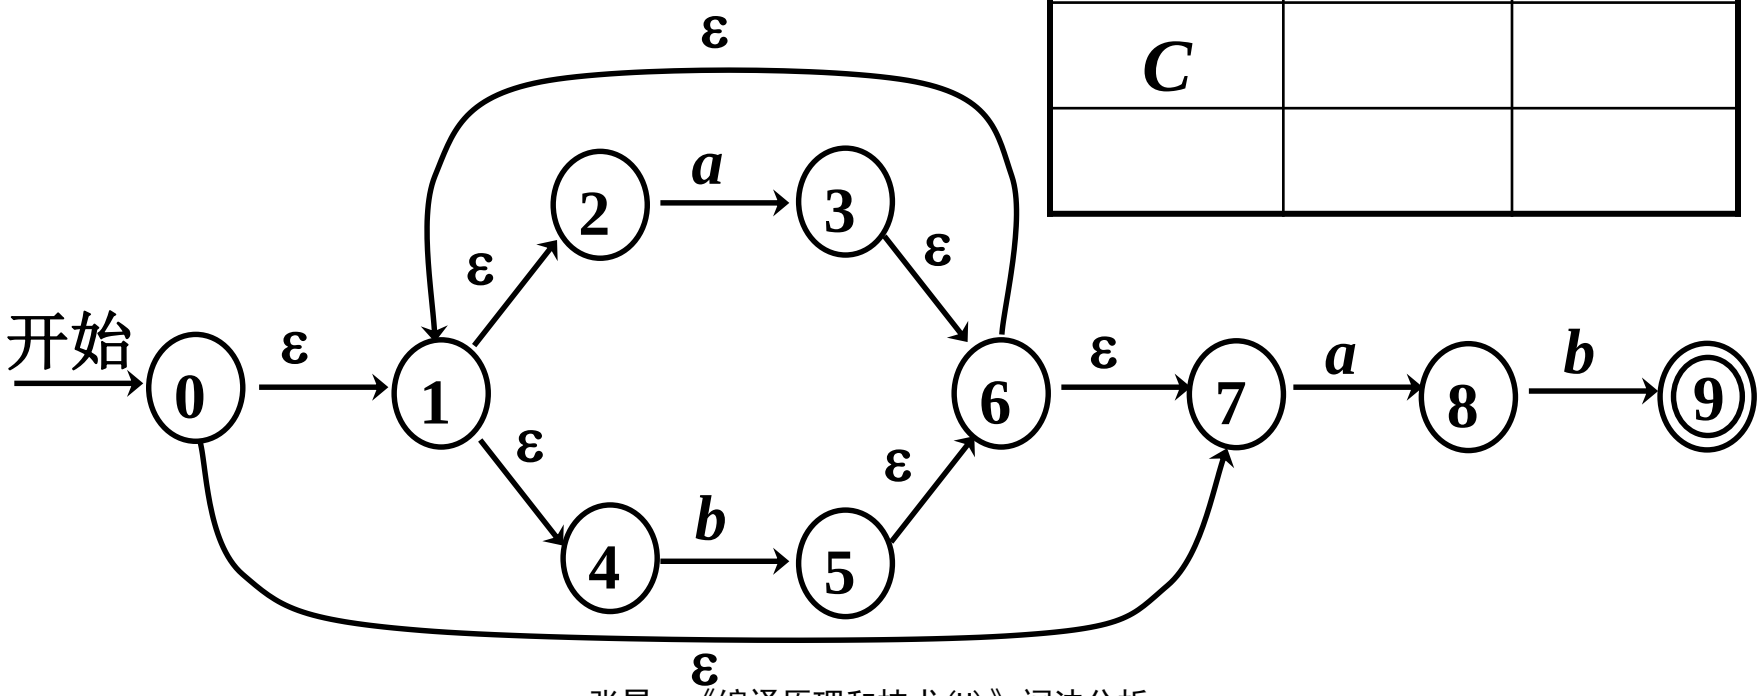

例题6

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

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

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

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

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

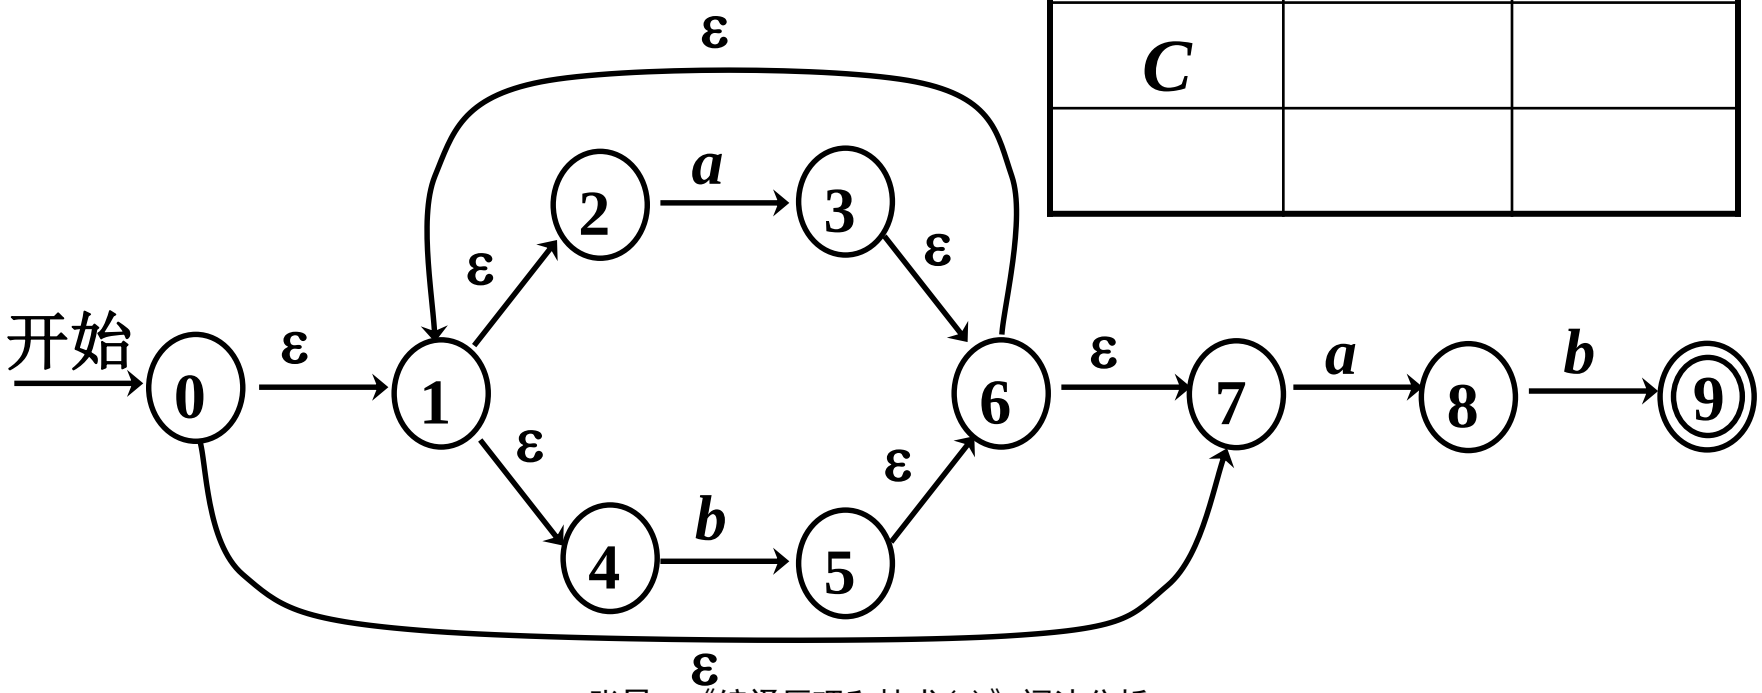

例题6

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

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

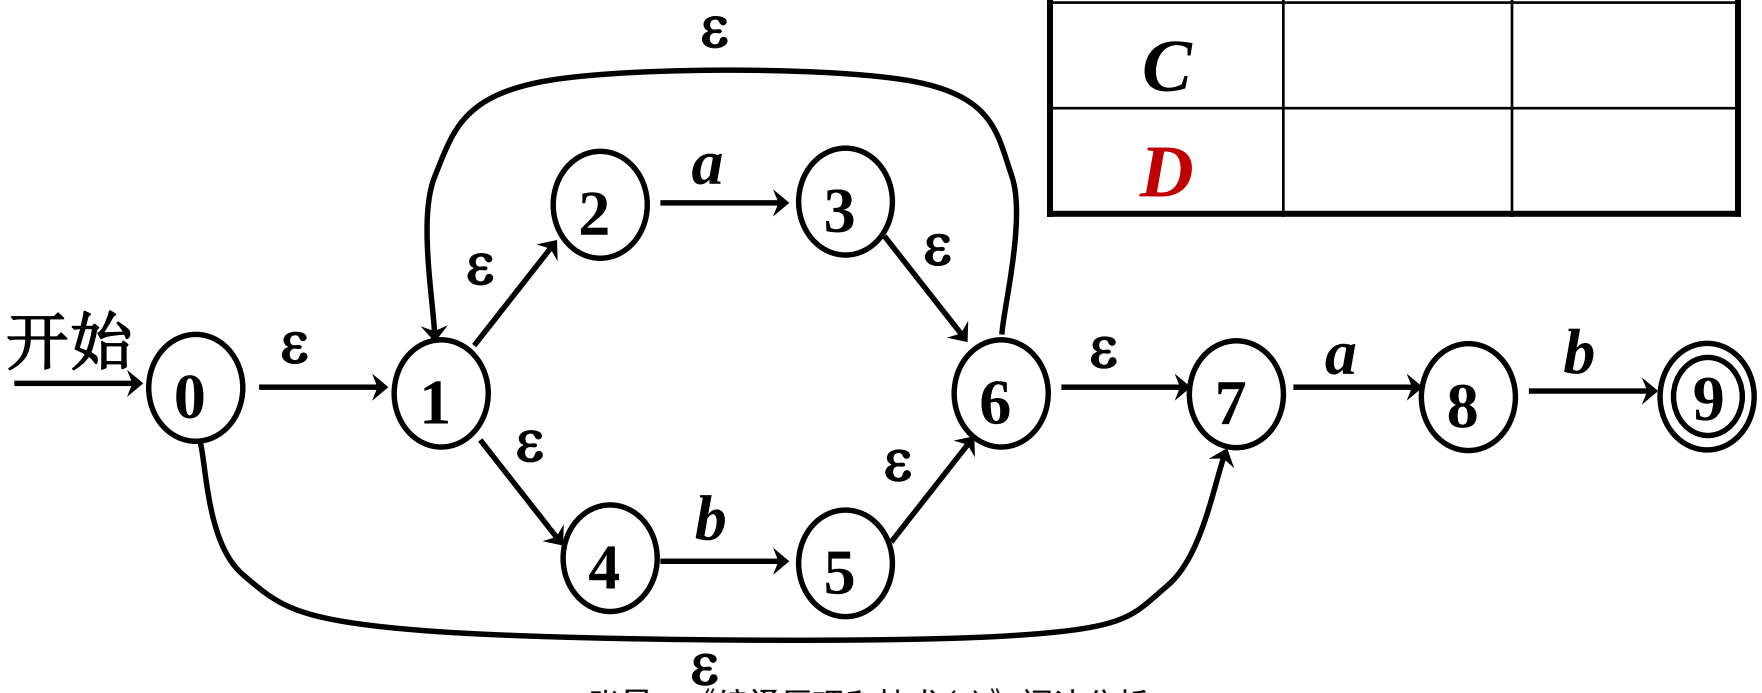

例题6

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

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

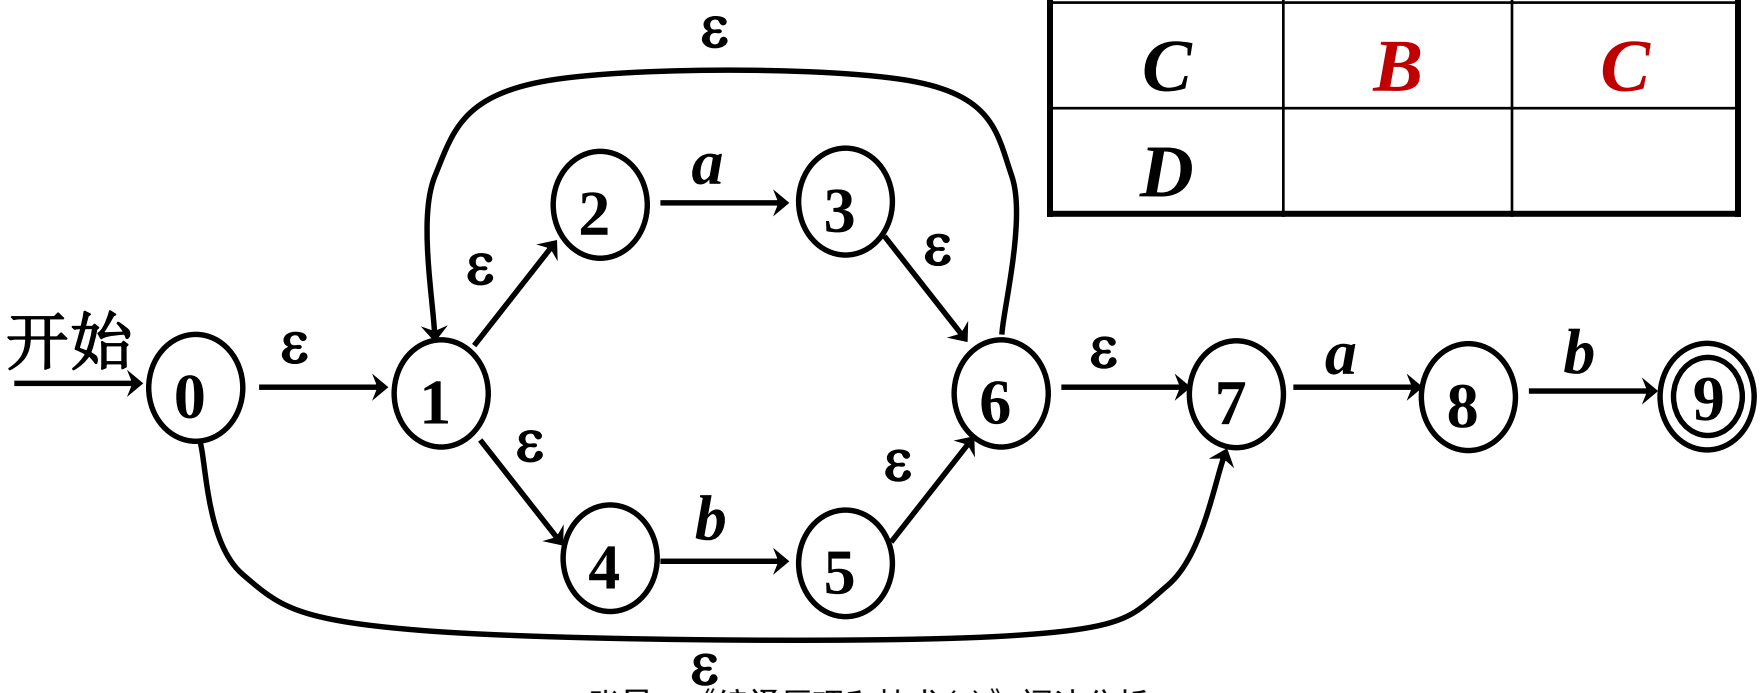

例题6

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

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

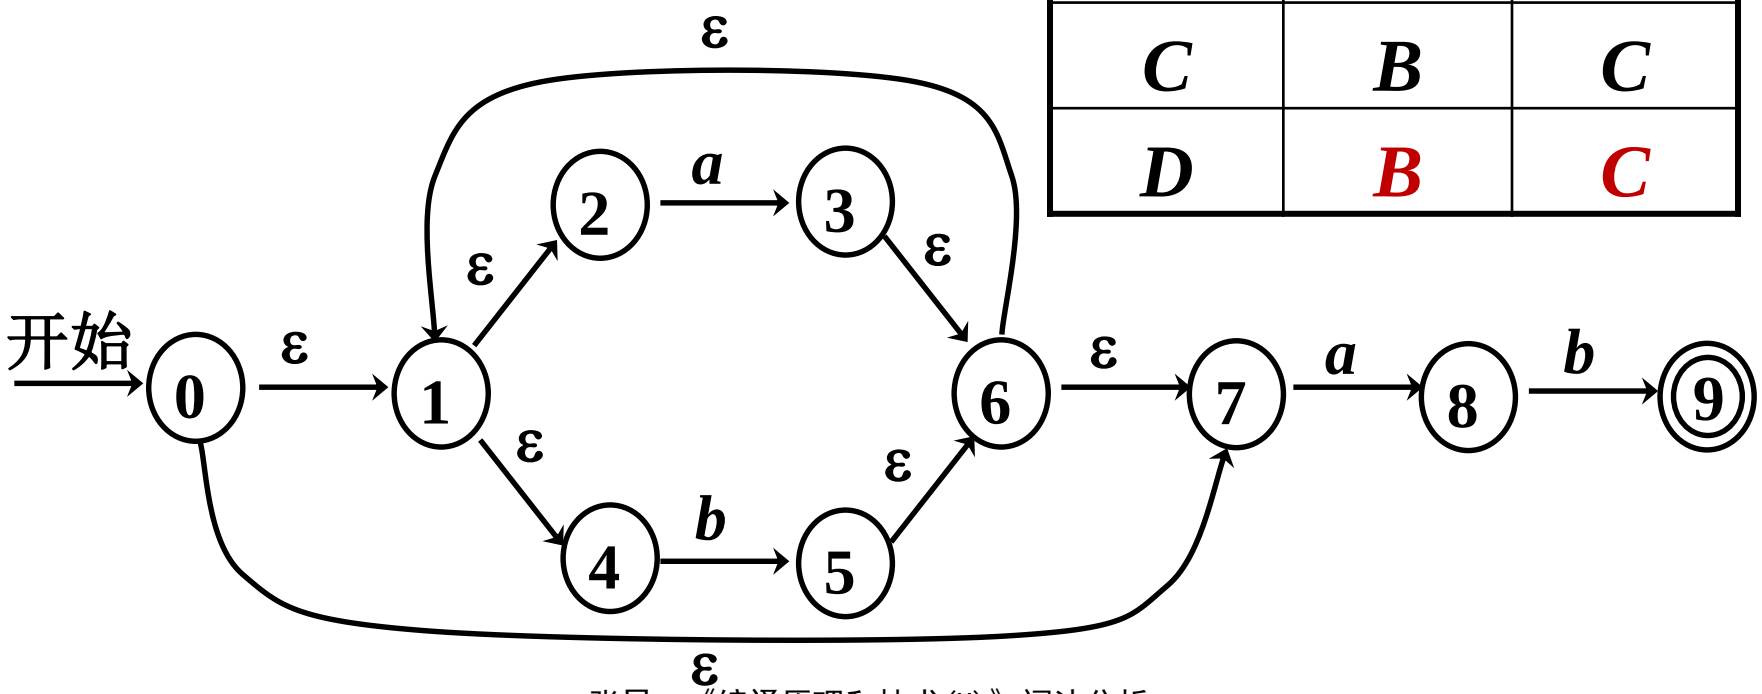

例题6

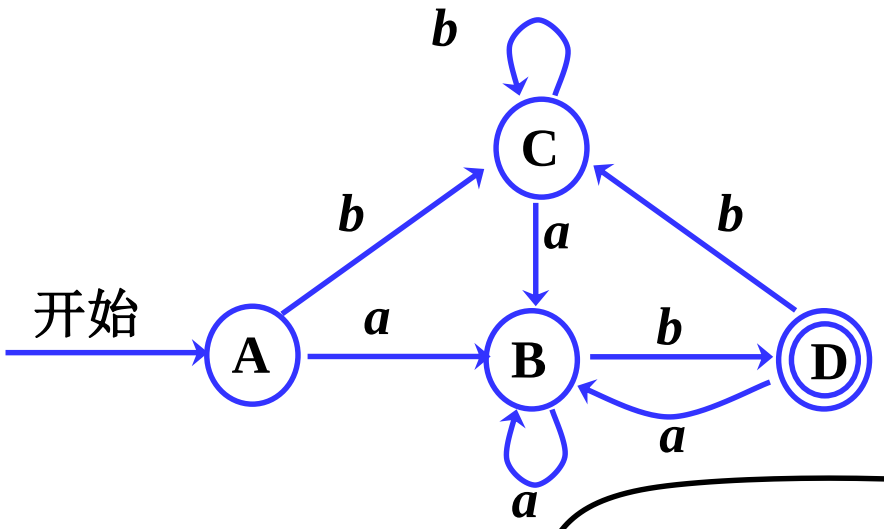

状态	输入符号	
	a	b
A	B	C
B	B	D
C	B	C
D	B	C

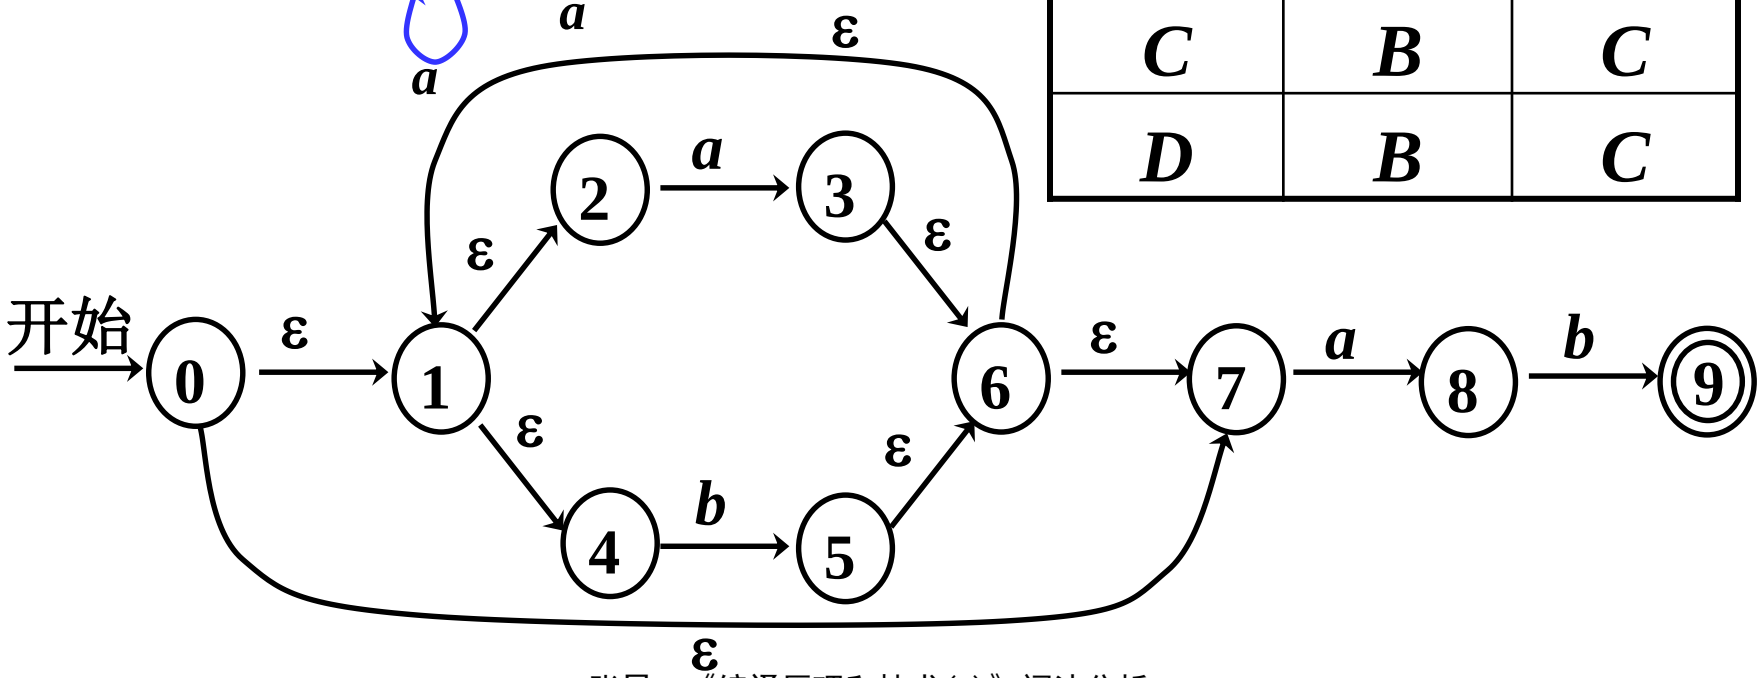

例题6

识别语言 $(a|b)^*ab$ 的DFA

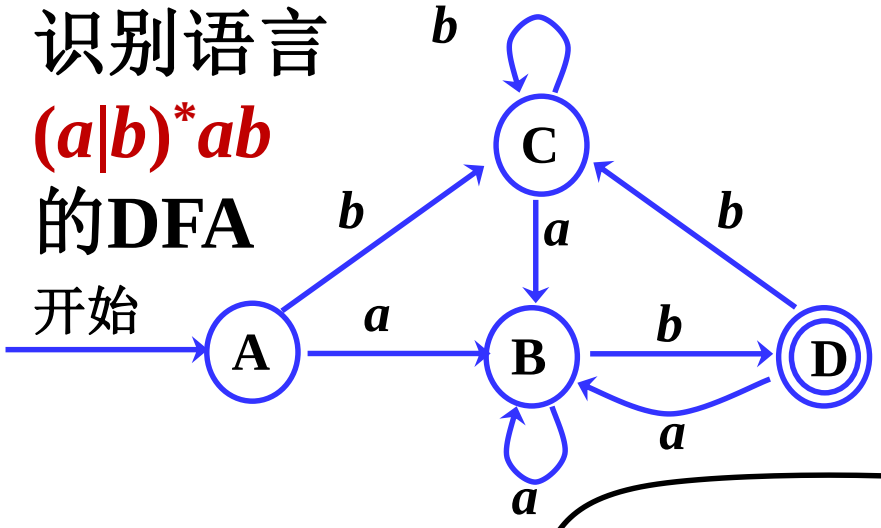

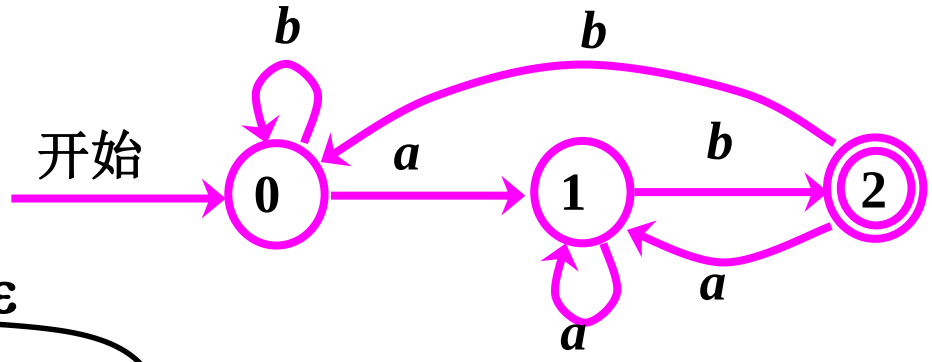

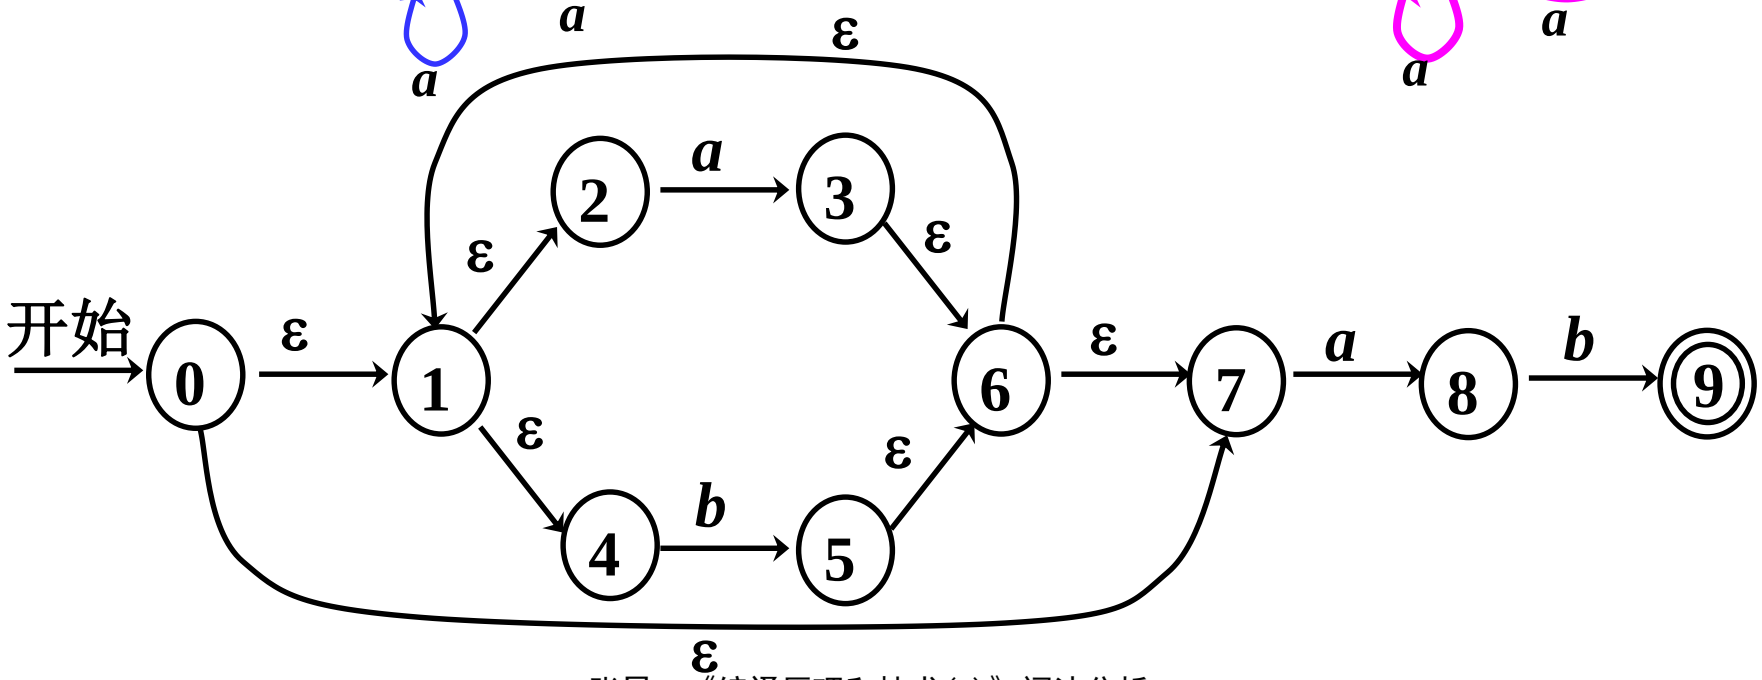

例题6

识别语言
$(a|b)^*ab$
的DFA

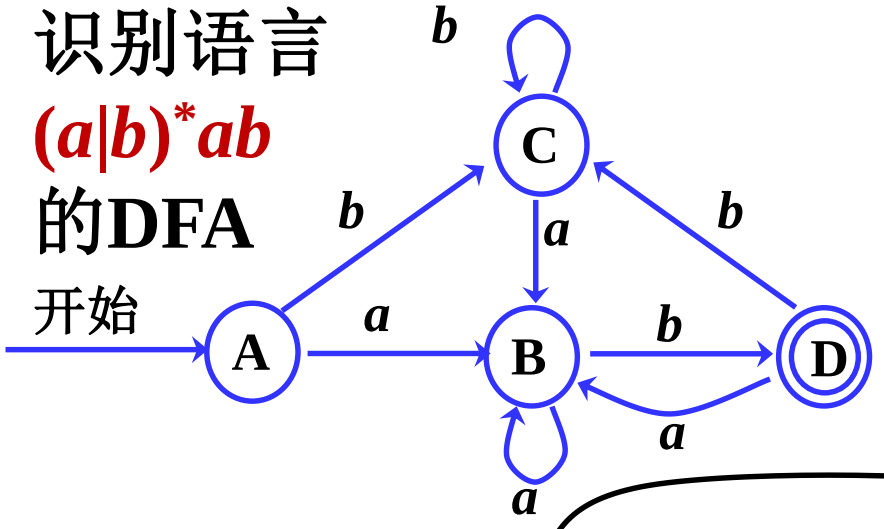

子集构造法不一定
得到最简DFA

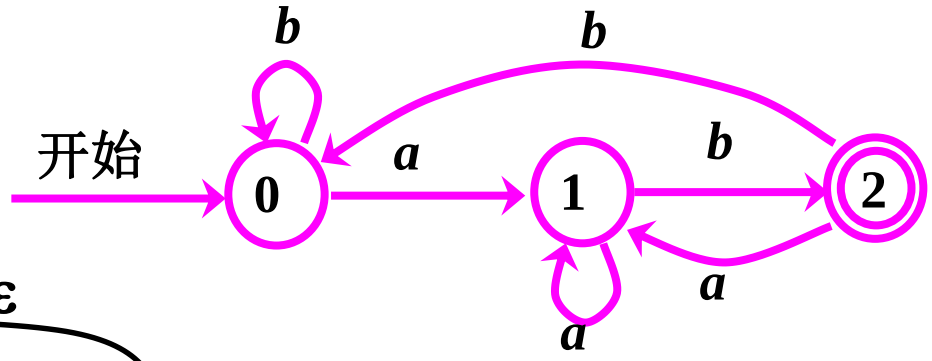

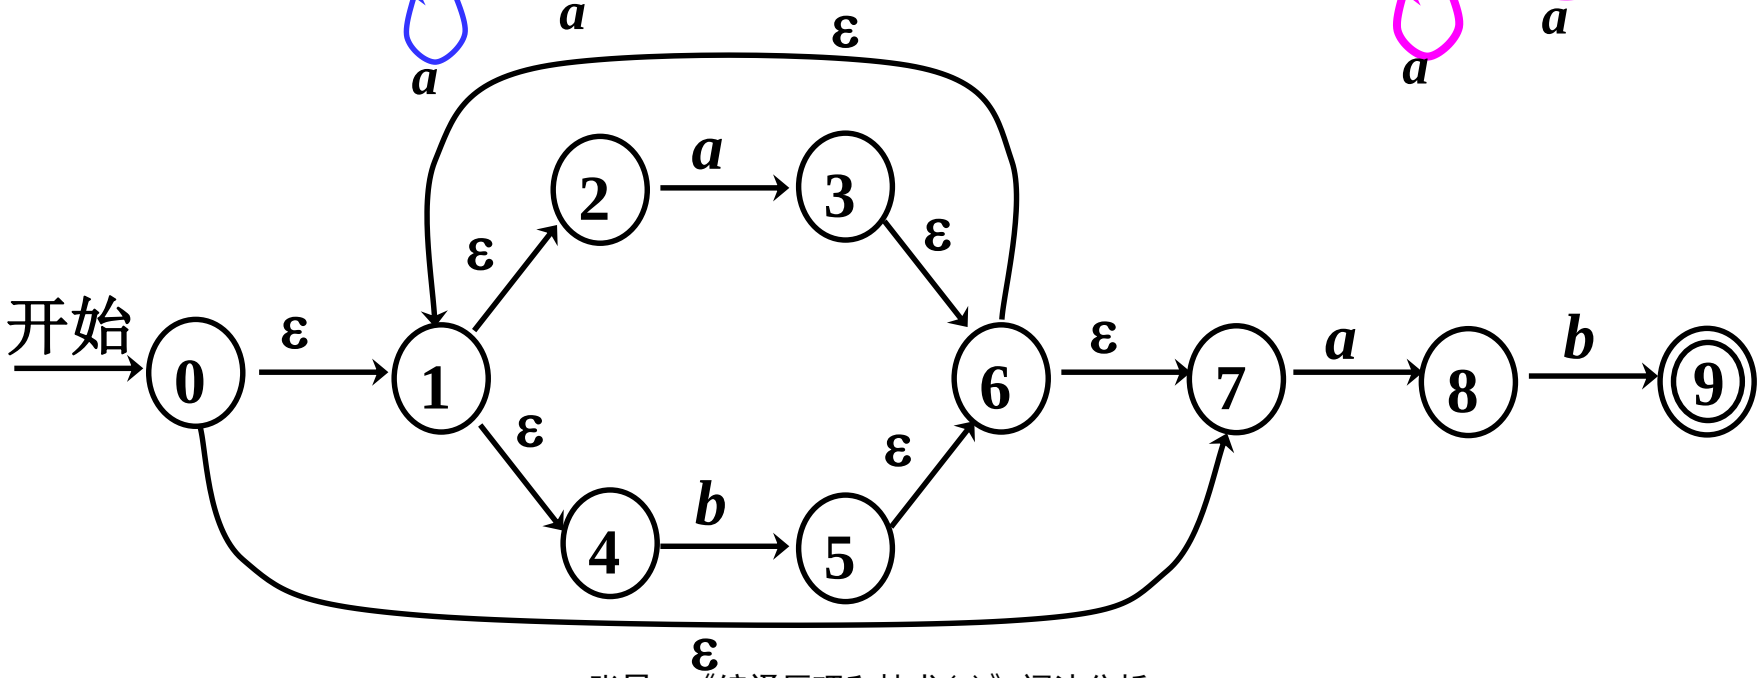

词法分析器的自动生成技术

- 正规式：描述语言的词法
- 有限自动机：刻画词法分析的实现

- 词法分析器自动生成的主要过程
  - 正规式→NFA（语法制导的构造算法）
  - NFA→DFA (子集构造法)
  - DFA化简
  - 根据DFA构造词法分析器源码

DFA的化简

- 该方法用于化简转换函数是**全函数**的DFA

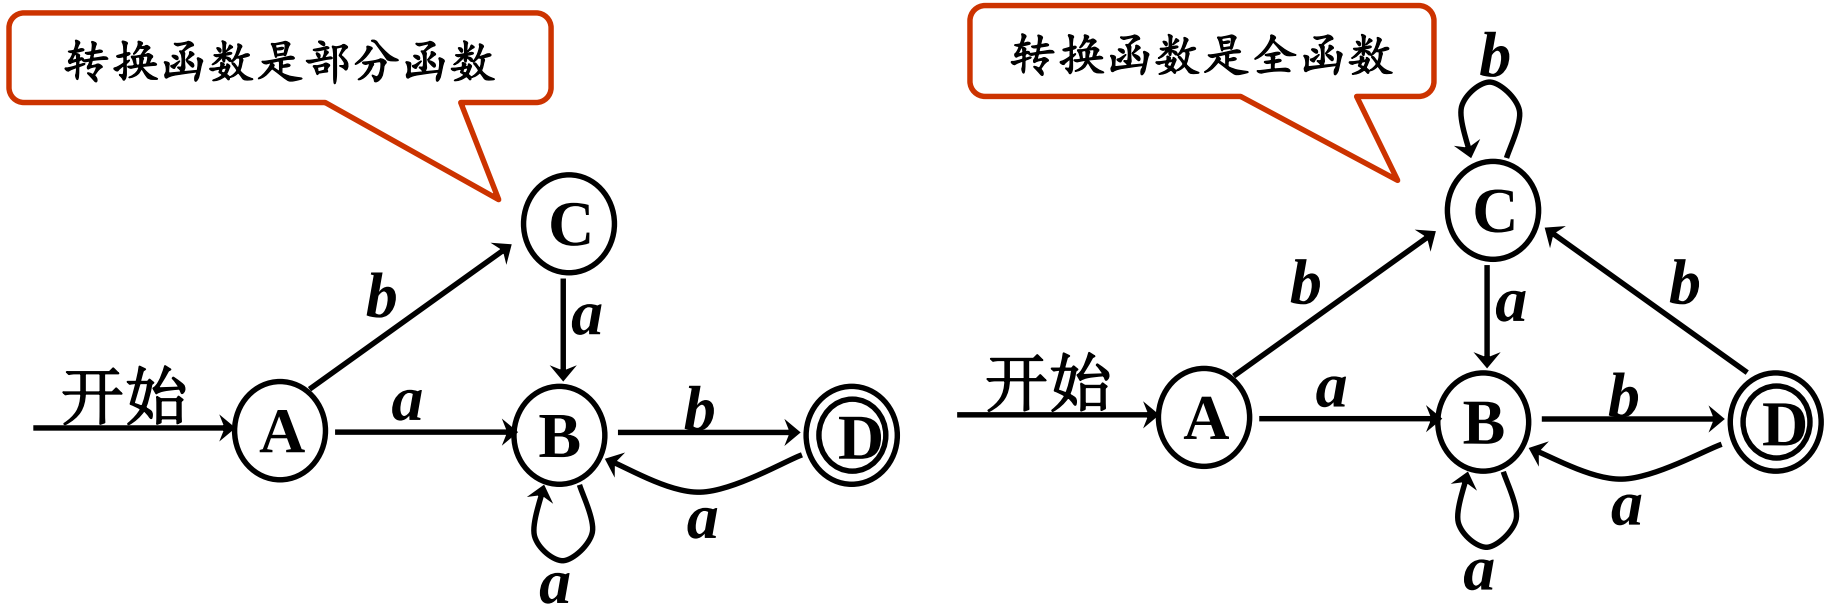

DFA的化简

- 该方法用于化简转换函数是全函数的DFA
- 死状态 (dead state)
  - 当DFA的转换函数由部分函数改成全函数表示时，要在左图引入死状态E, 将缺失的状态转换都指向该死状态

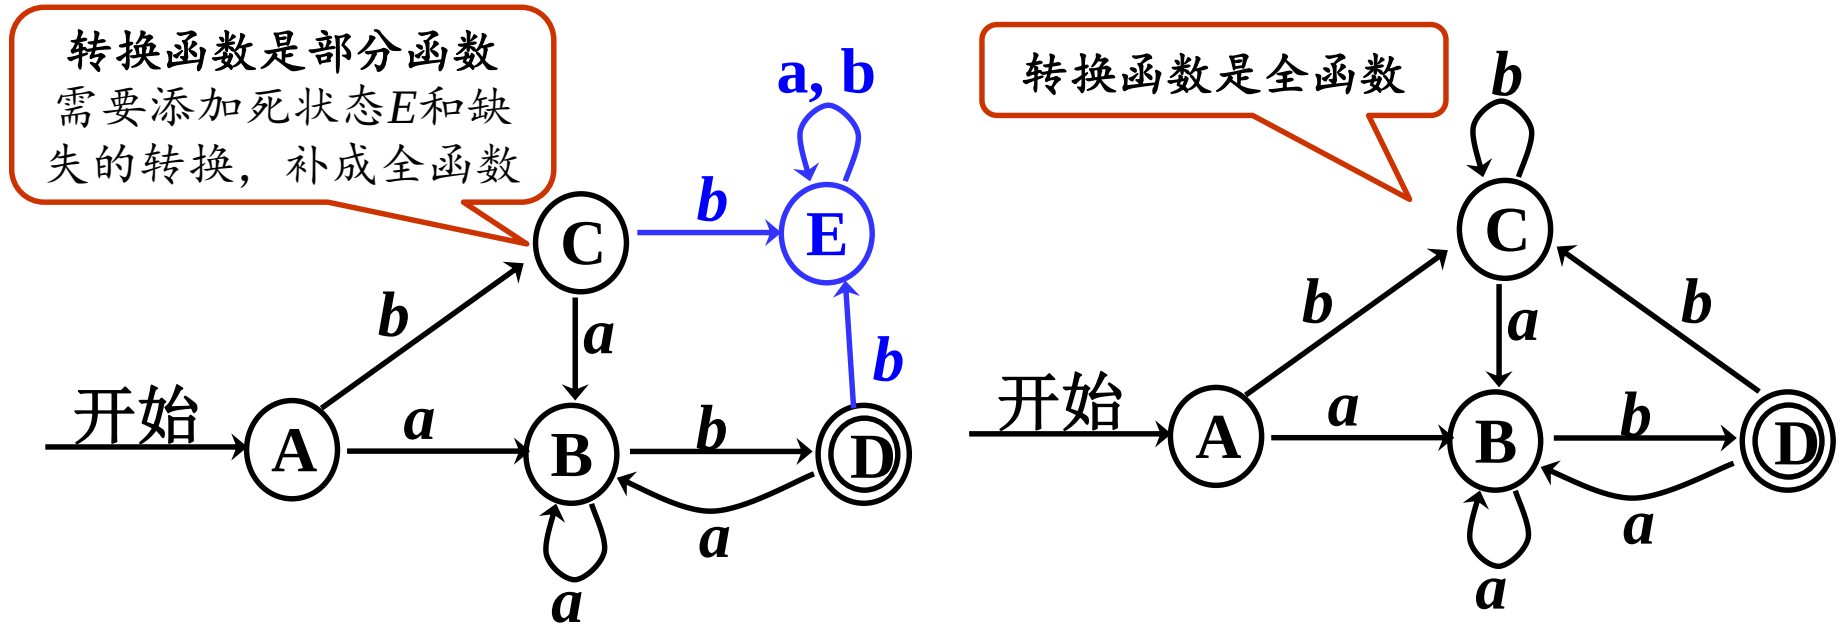

DFA的化简

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

将状态分成不相交的子集(**初始**按是否为接受状态来划分),

某子集中的状态*s*、*t* **可区别**是指，存在一个输入符号*w*，使得它们分别到达的状态落入当前划分中的不同子集。

- 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

可区别的状态
要分开对待

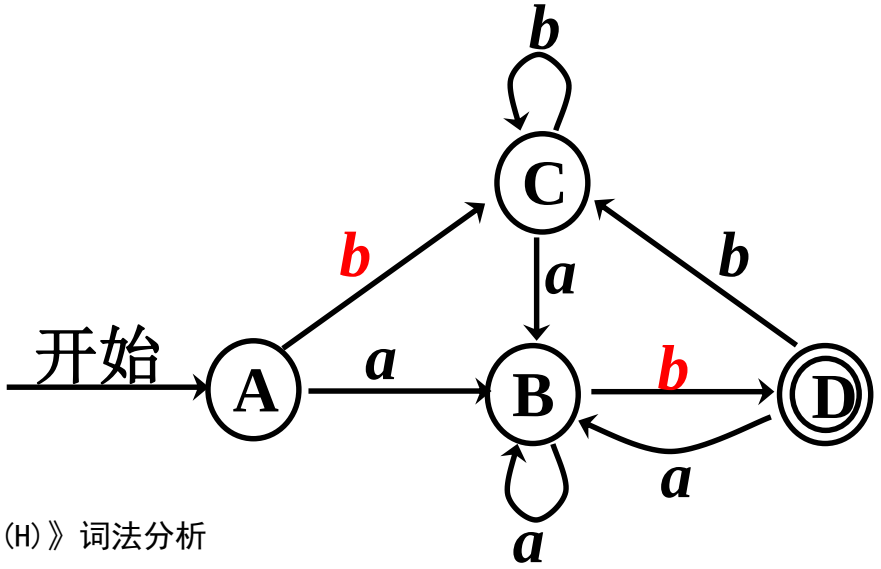

DFA的化简

方法

1. 按状态是否接受来划分状态集合

   {A, B, C}, {D}

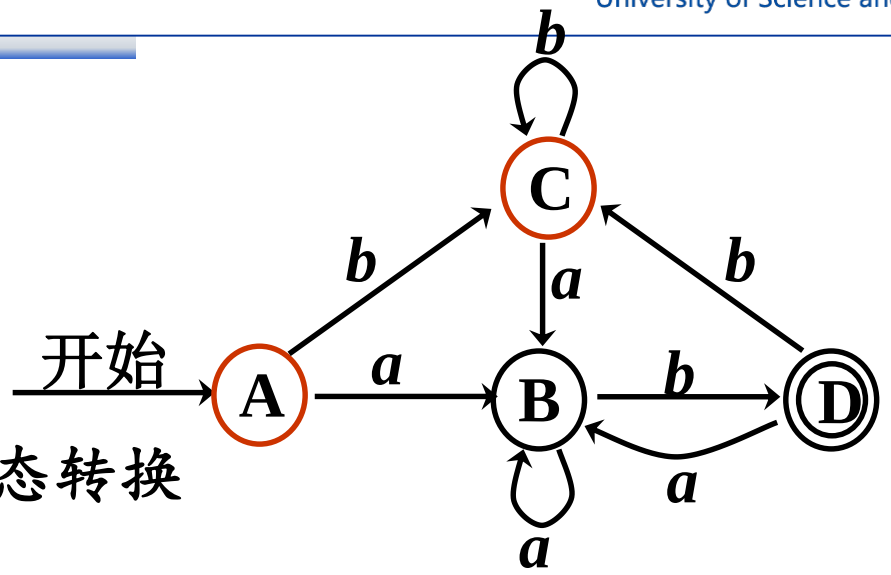

2. 考察每个子集(至少含2个状态)的状态转换

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

   move({A, B, C}, *b*) = {C, D} //面临*b*,转换到的状态落入不同子集

   说明{A, C}, {B}是可区别的

3. 继续分解，当前划分为{A, C}, {B }, {D}

4. 考察{A, C}, 不可区分，合并状态

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

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

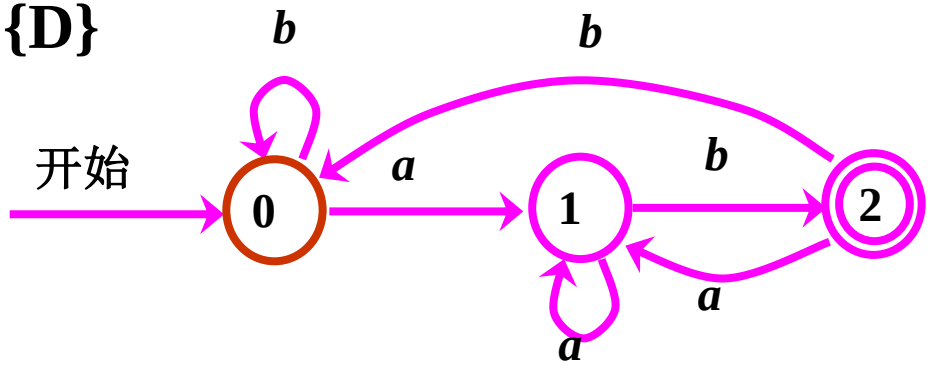

例题7

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

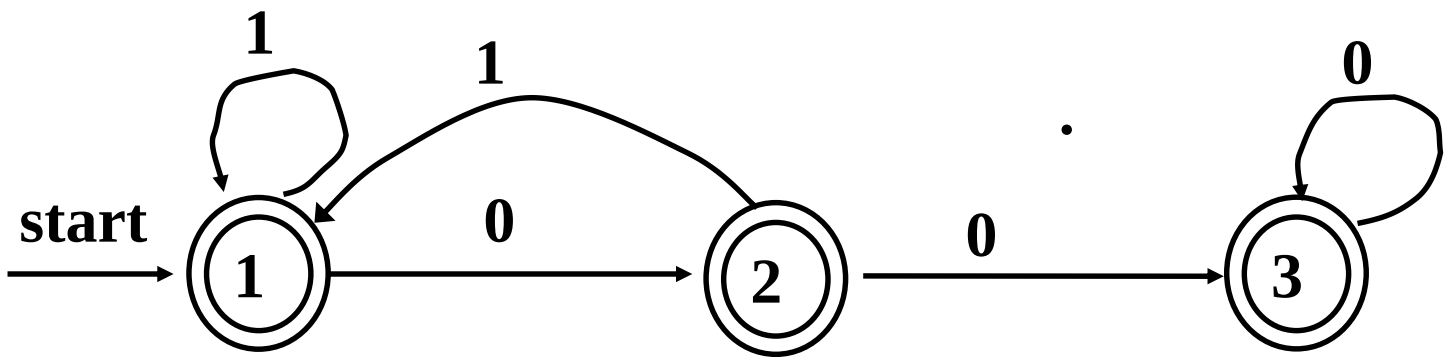

例题8

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

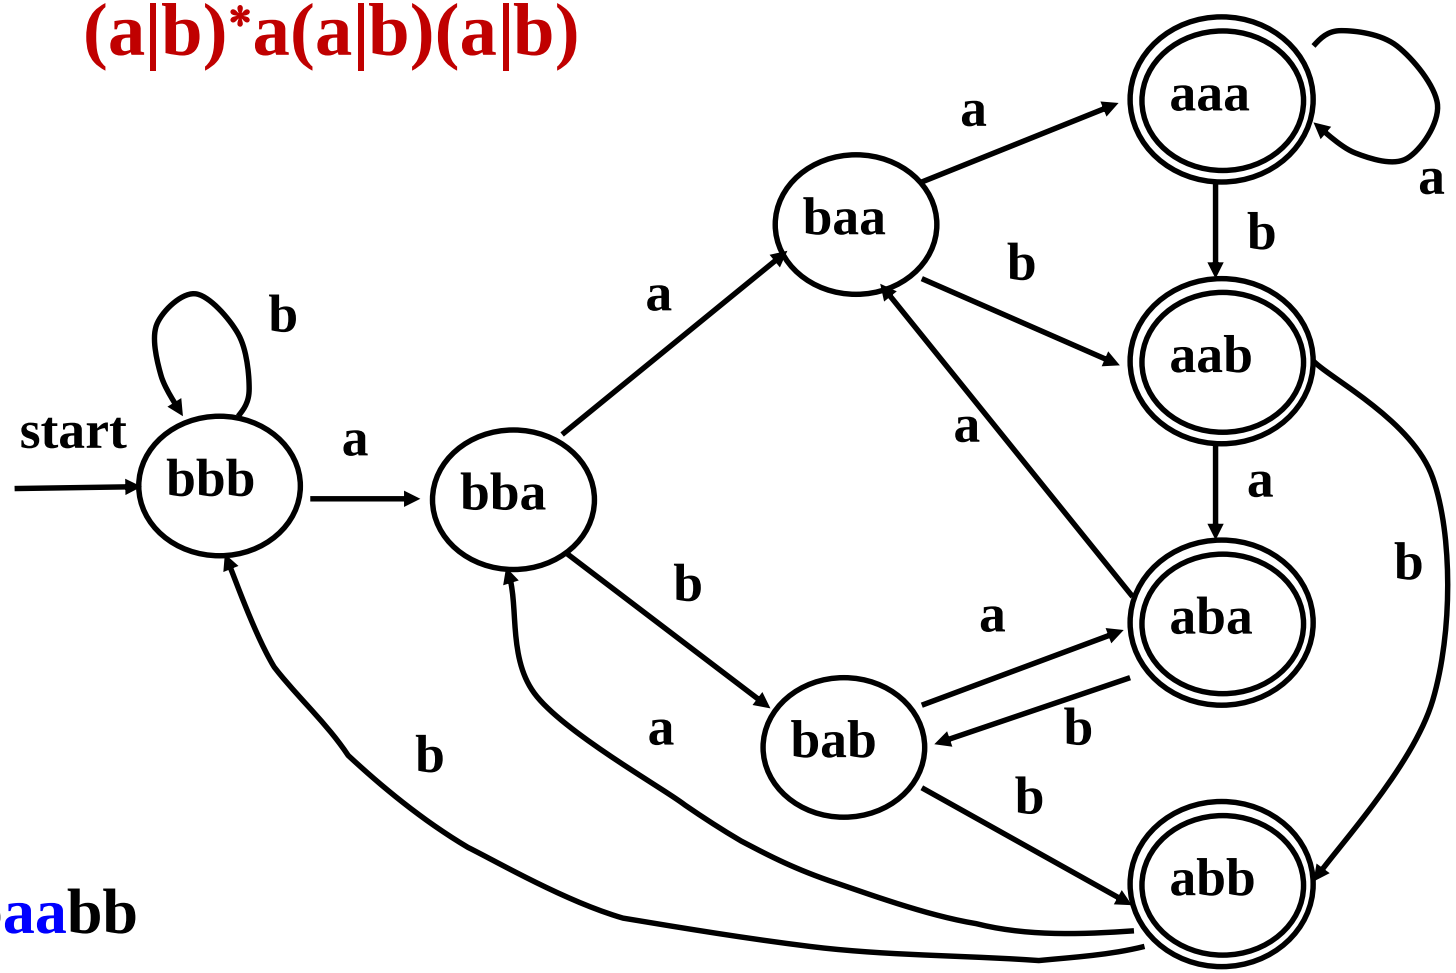

bbabaabb