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

词法分析 I

《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

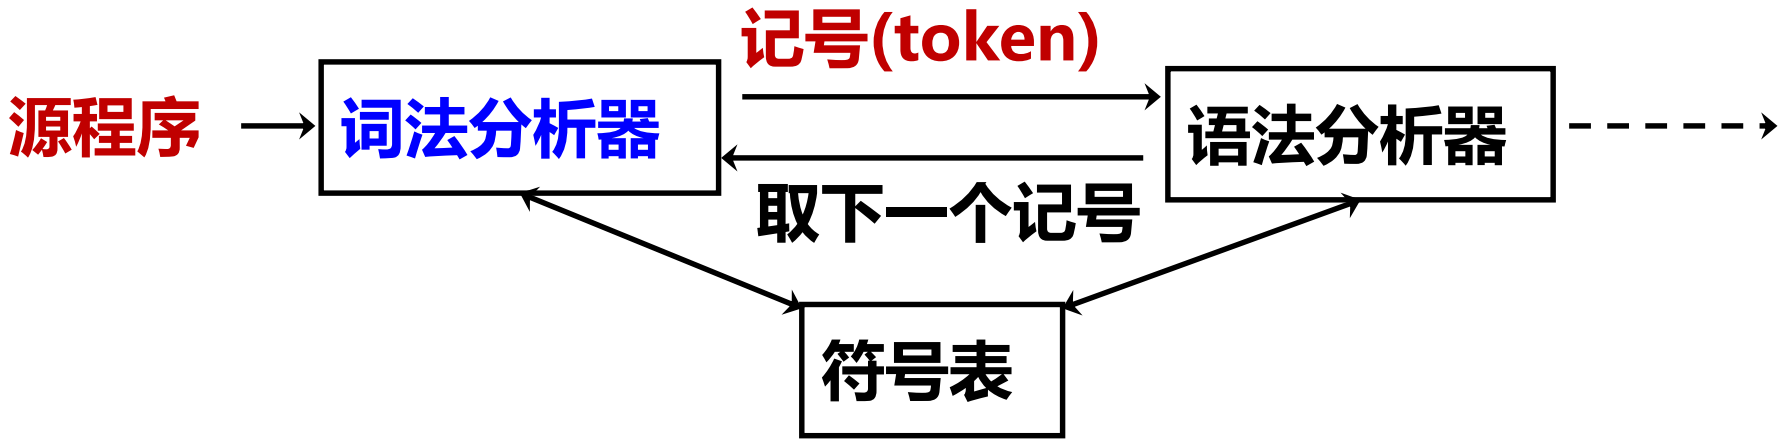

- 词法分析及要解决的问题
  - 向前看(Lookahead)、歧义(Ambiguities)
- 词法分析器的自动生成
  - 词法的描述：正规式；词法记号的识别：转换图
  - 有限自动机：NFA、DFA

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

2.1 词法记号及属性

- 词法单元(lexeme, 词素)
- 记号(token)
- 模式(pattern)

词法记号、词法单元、模式

记号名	词法单元实例	模式的非形式描述
if	if	字符i, f
for	for	字符f, o, r
relop	< , <= , = , …	< 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
ws	换行符	换行符\n

空白字：如空格、\t、换行
无意义，被丢弃，不提供给语法分析器

1. **词法单元(lexeme)**：
   又称 **单词** 或 **词素**
   源程序中具有某种词法含义的一个字符序列

2. **词法记号(token)**：
   简称**记号**
   由记号名和可选的属性值组成

3. **模式(pattern)**
   描述属于该记号的词法单元的形式

词法记号、词法单元、模式

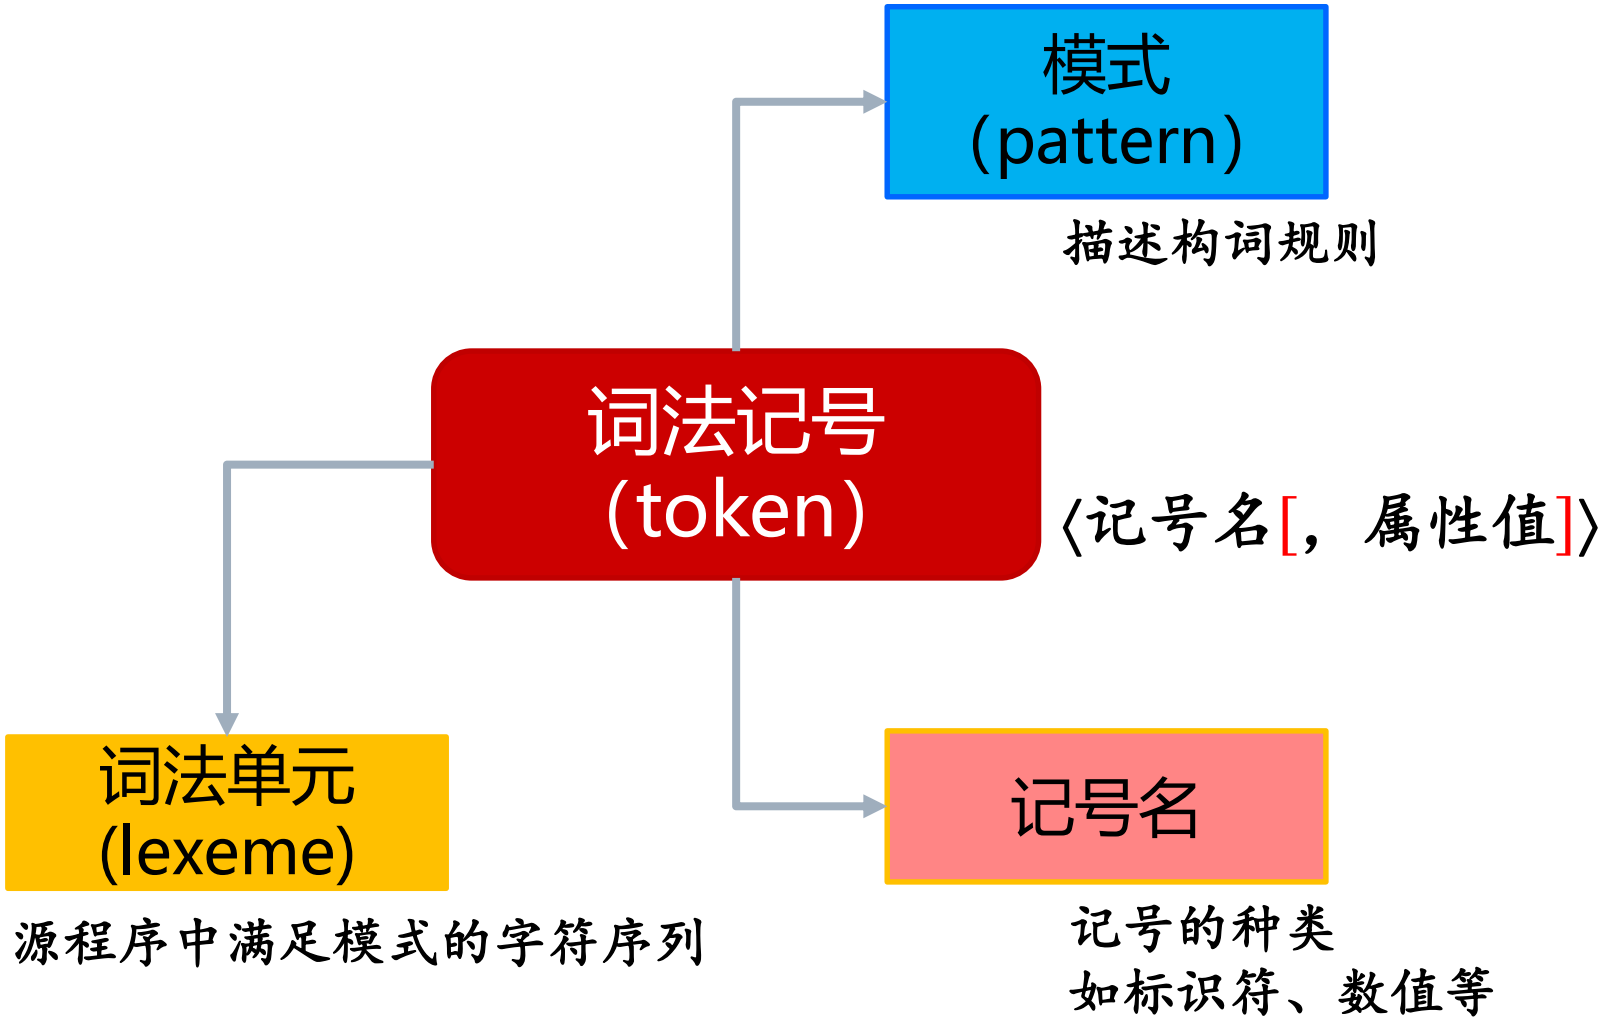
模式
(pattern)
描述构词规则
词法记号
(token)
〈记号名[，属性值]〉
词法单元
(lexeme)
源程序中满足模式的字符序列
记号名
记号的种类
如标识符、数值等

词法记号的属性

position = initial + rate * 60 的记号

⟨记号名[，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⟩

符 号 表

1	position	· · ·
2	initial	· · ·
3	rate	· · ·

Lexeme
词法单元/单词/词素

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

  空格不是分隔符

- 关键字不保留

  IF THEN THEN THEN=ELSE; ELSE …

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

词法单元是源程序中的字符序列（字符串）
字符串集合由称为模式的规则来描述

术语

- 字母表：符号的有限集合， 例：$\sum = \{0, 1\}$ 、ASCII、Unicode
- 串：符号的有穷序列，例：0110， ε

串s的长度是出现在s中符号的个数

- 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

注意区别：
ε， $\{\varepsilon\}$， $\varnothing$

空串　非空集合　空集

串的运算

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

优先级：
幂>连接

串和语言

语言表示字母表上的一个串集

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
均是自左向右结合

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（正则表达式）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	$\{a\}$	$a \in \sum$
(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|

正规式遵守的一些代数定律

定律	描述
r | s = s | r	| 是可交换的
r | (s | t) = (r | s) | t	| 是可结合的
(rs)t = r(st)	连接是可结合的
r(s | t) = rs | rt; (s | t)r = sr | tr	连接对 | 是可分配的
ε r = rε = r	ε 是连接的恒等元素
r* = (r | ε)*	ε 肯定出现在一个闭包中
r** = r*	*是幂等的

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

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

自底向上定义
Bottom-up

- 各个d_i 的名字都不同，是新符号，不在字母表∑中
- 每个r_i 都是 ∑∪{$d_1, d_2, \ldots, d_{i-1}$}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 → 0 | 1 | … | 9

digits → digit digit*

optional_fraction → .digits | ε

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

number → digits optional_fraction optional_exponent

正规定义举例

- 无符号数集合，例1946, 11.28, 63E8, 1.99E–6

digit → 0 | 1 | … | 9

简记为[0-9] --- 字符组

digits → digit digit*

optional_fraction → .digits | ε

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

number → digits optional_fraction optional_exponent

- 简化的表示

number → digit+ (.digit+)? (E(+|-) ? digit +)?

**注意区分？和 *
？表示0个或1个，*表示0个或多个，+表示1个或多个**

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

词法分析

- 从左到右读取输入串，每次识别出一个token实例
- 可能需要“lookahead”来判断当前是否是token的结尾或下一个token的开始（尤其是对Fortran语言）

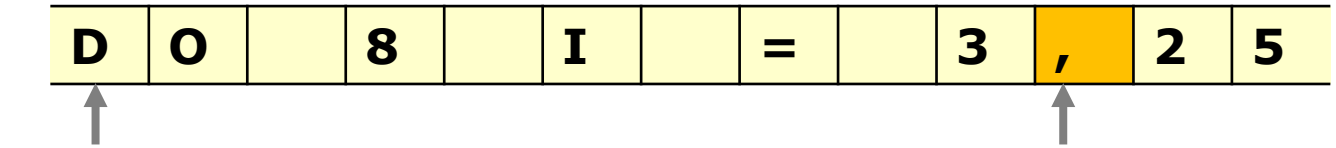


```
DO 8 I = 3
```

无法判断，需lookahead

```
DO 8 I = 3.25
```

点➔DO8I为id

```
DO 8 I = 3, 25
```

逗号➔DO为 关键字

词法分析

词法分析

- 从左到右读取输入串，每次识别出一个token实例
- 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）
- 可能需要结合上下文来识别是否是关键字（当关键字不是保留字时）

```
if (then > else) then
        then = else
else
        else = then
endif
```

需要结合上下文
识别是否是关键字

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，词素)
   - 词法单元是子串（token的实例）

词法记号的识别：状态转换图

转换图(transition diagram)

关系算符的转换图

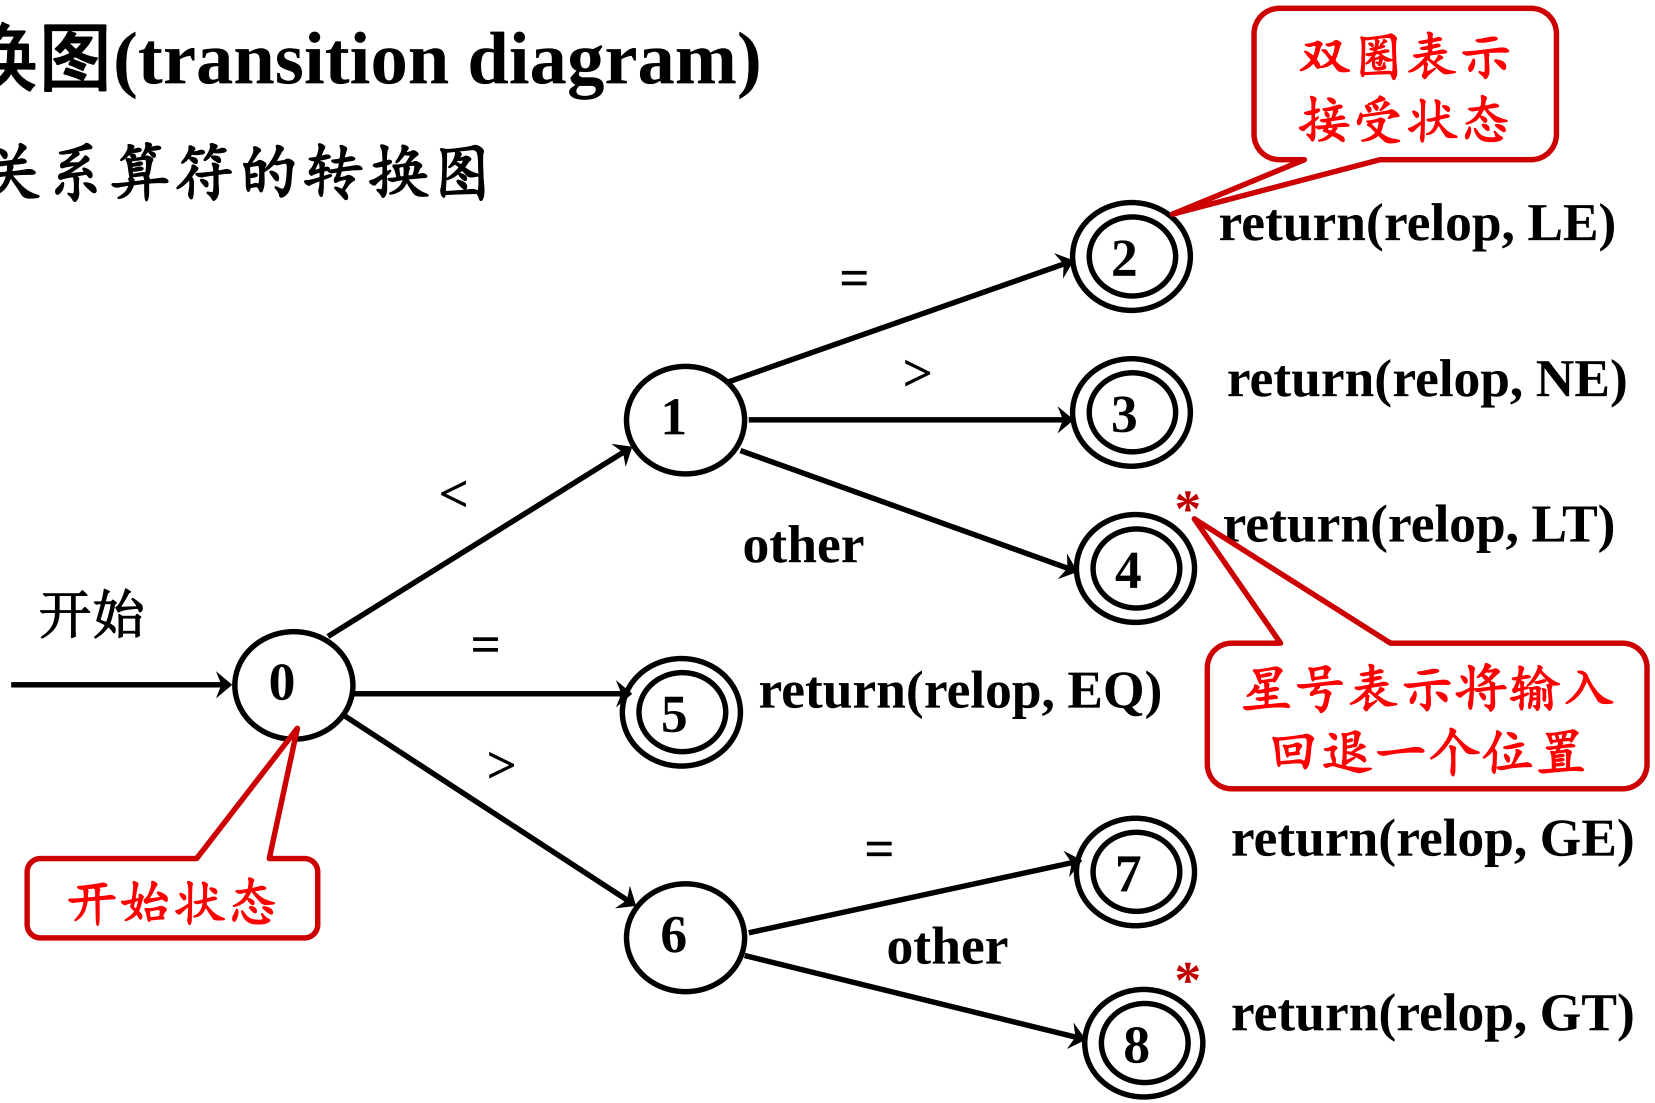

转换图

- 标识符和关键字的转换图

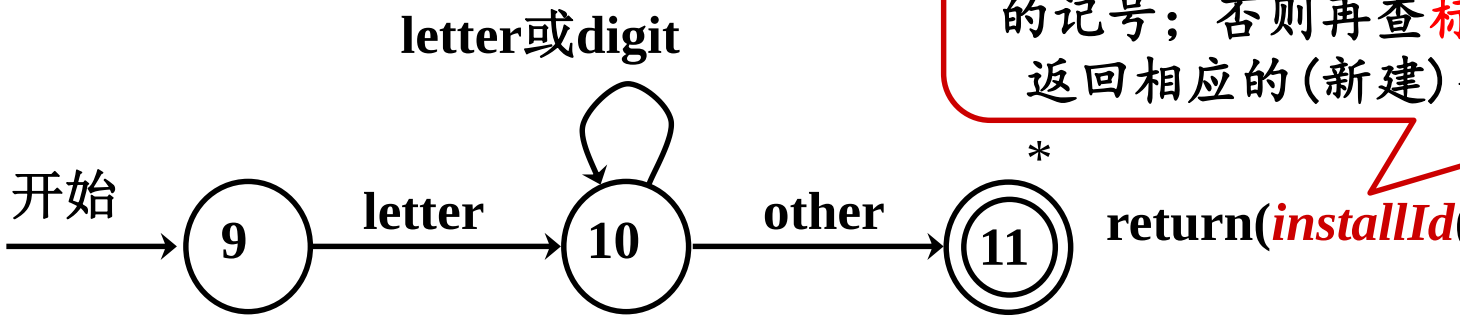

先查看关键字表，若当前词法单元构成关键字，则返回相应的记号；否则再查标识符表，返回相应的(新建)条目指针

- 无符号数的转换图

number → digit⁺ (.digit⁺)? (E(+|-) ? digit⁺)?

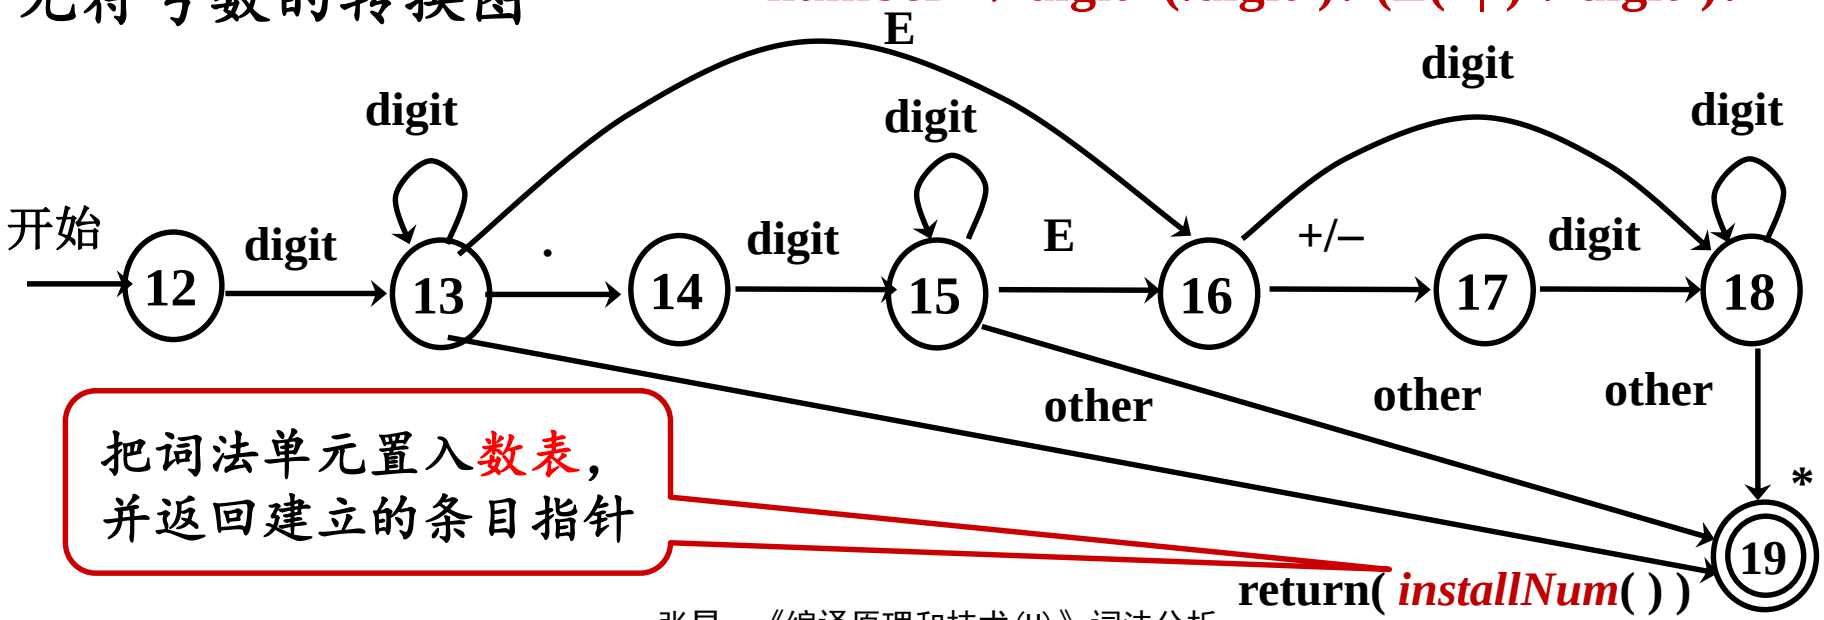

把词法单元置入数表，并返回建立的条目指针

转换图

空白的转换图

delim → blank | tab | newline

ws → delim+

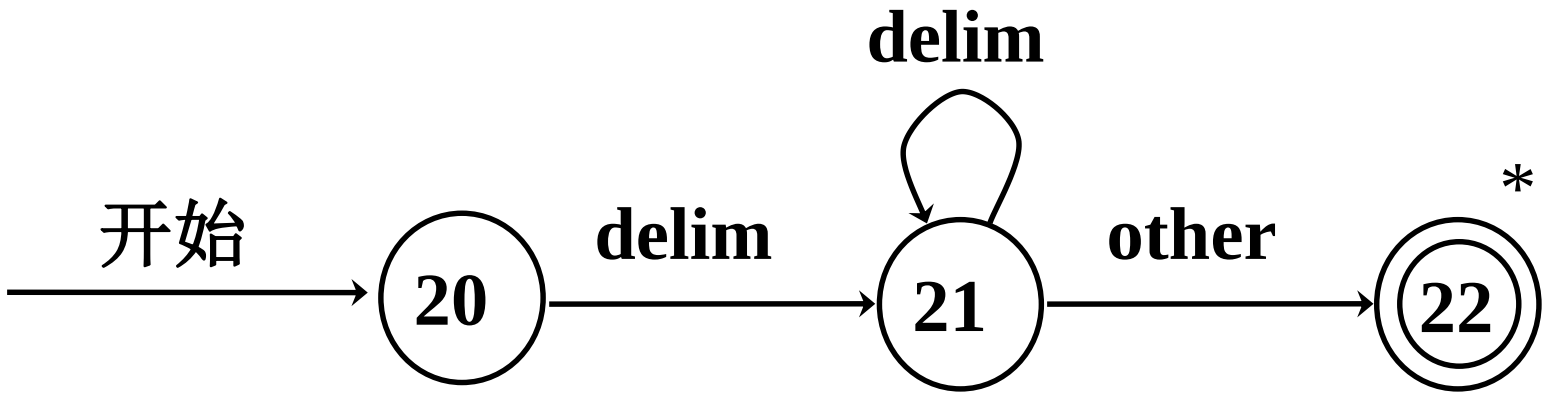

基于转换图的词法分析

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

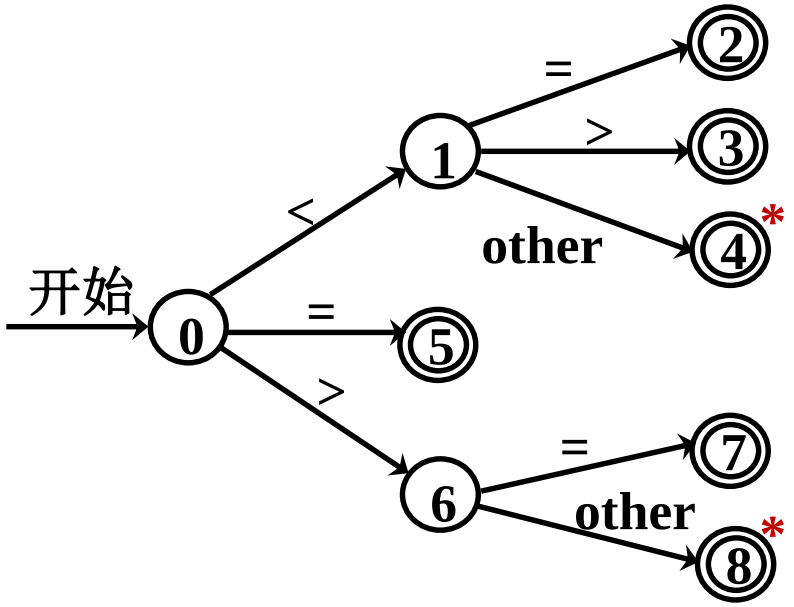

词法分析中的冲突及解决

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 $x_1 \ldots x_k \in L(R)$, 假设i<k

则可按"Maximal munch" 规则来选择:

→ 选择匹配 R 的最长前缀，即选择$x_1 \ldots x_k$

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 (R_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　　注：数字串长度不小于1

- 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);
}
```