中山大學 SUN YAT-SEN UNIVERSITY

国家超级计算广州中心 NATIONAL SUPERCOMPUTER CENTER IN GUANGZHOU

DCS290

Compilation Principle

编 译 原 理

第三章 词法分析（1）

郑馥丹

zhengfd5@mail.sysu.edu.cn

CONTENTS

目 录

1. 什么是词法分析[Lexical Analysis]?

- 扫描源程序字符流，识别并分解出有词法意义的单词或符号（token）
  - 输入：源程序，输出：token序列
  - token表示：<类别，属性值>
    - ✓ 保留字、标识符、常量、运算符等
  - token是否符合词法规则?
    - ✓ 0var, $num

```
void main()
{
    int arr[10], i, x = 1;

    for (i = 0; i < 10; i++)
        arr[i] = x * 5;
}
```

keyword(for)
symbol(()
id(i)
symbol(=)
num(0)
symbol(;)
id(i)
symbol(<)
num(10)
symbol(;)
id(i)
symbol(++)
symbol())

id(arr)
symbol([)
id(i)
symbol(])
symbol(=)
id(x)
symbol(*)
num(5)
symbol(;)

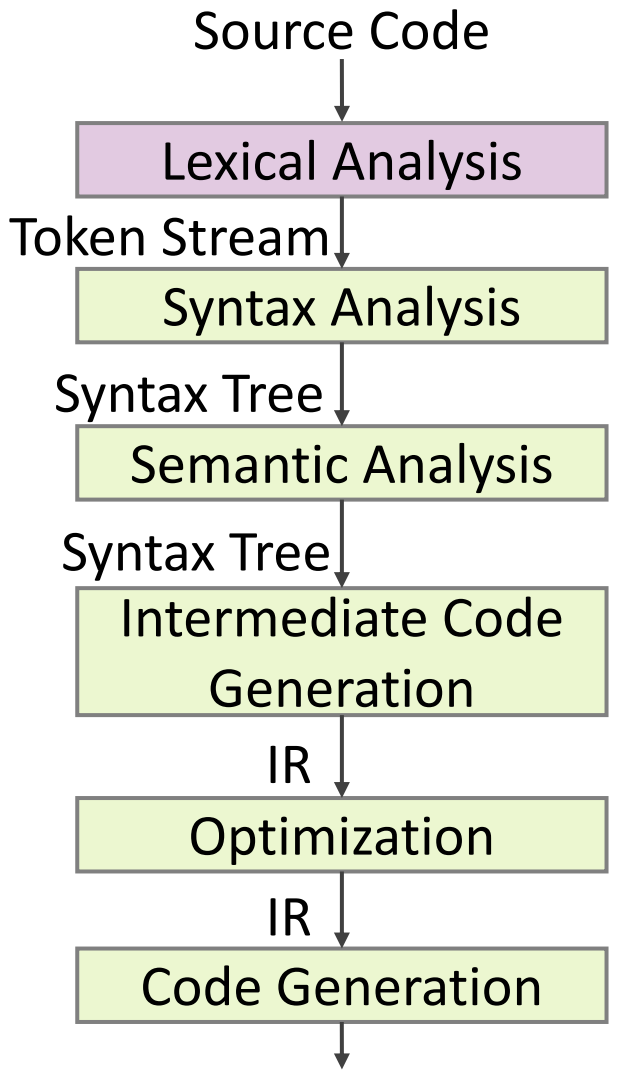

1. 什么是词法分析[Lexical Analysis]?

- 扫描源程序字符流，识别并分解出有词法意义的单词或符号（token）
- 例：
  - 输入：
    - ✓ 字符串“if (i == j)\n\tz = 0; \nelse\n\tz = 1; \n”
  - 目标：将字符串划分为一组**tokens**
  - 步骤：
    - ① 移除注释：/* simple example */
    - ② 识别tokens：‘**if**’ ‘**(**’ ‘**i**’ ‘**==**’ ‘**j**’ ……
    - ③ 识别tokens所属的类别：(**keyword**, ‘**if**’), (**LPAR**, ‘**(**‘), (**id**, ‘**i**’) ……
  - 输出：(**keyword**, ‘**if**’), (**LPAR**, ‘**(**‘), (**id**, ‘**i**’) ……

```
/* simple example */
if (i == j)
  z = 0;
else
  z = 1;
```

2. 什么是词[token]?

- Token：词，**最小意义单元**
  - 英语中的token类别：
    - ✓ 名词noun，动词verb，形容词adjective，...
  - 编程语言中的token类别：
    - ✓ 数字number, 关键词keyword, 空白whitespace, 标识符identifier, ...
- 每个token类别对应一个字符串集合[a set of strings]
  - number：非空的数字字符串
  - keyword：一组固定的**保留字**(“for”, “if”, “else”, ...)
  - whitespace：由空格blank、制表符tab、换行符newline组成的非空序列
  - identifier：用户自定义的要标识的实体名称

3. 词法分析：分词[Tokenization/Scanner]

- 词法分析器也称**标记化Tokenization**或**扫描器Scanner**
  - 将输入字符串划分为token序列
  - 对token进行分类——token类别
    - ✓ **词素[lexeme]**：token类的实例，例如：‘z’, ‘=’, ‘1’
    - ✓ 事先定义好token类别：例如keyword, identifier, whitespace, integer等
- 得到的token会被送入**语法分析器[Syntax Analyzer]**（也称**Parser**）
  - parser依赖token类来识别角色（例如，关键字与标识符的处理方式不同）。

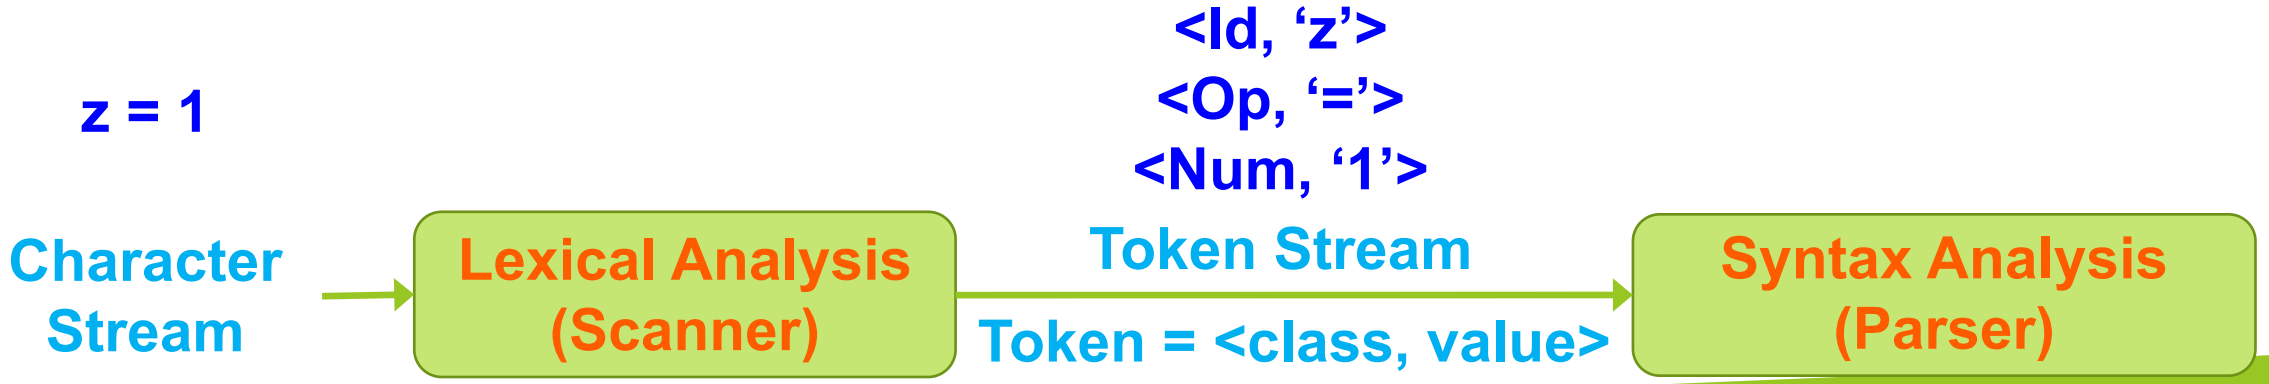

3. 词法分析：设计[Design]

- 定义token类别
  - 描述所有感兴趣的项
  - 依赖于语言、parser的设计
    - ✓ *“if (i == j)\n\tz = 0; \nelse\n\tz = 1; \n”*

      Keyword, identifier, whitespace, integer

5种最常见的编程语言token类别：

- **Identifiers: getBalance, weight,....**
- **Reserved words: if, else, while,...**
- **Constants: 10, 3.14, “abc”, ‘a’,...**
- **Operators: +, -, *, /, <<,...**
- **Punctuation: (,), ;, :,...**

- 识别哪些字符串属于哪个token类别

```
if (i == j)
  z = 0;
else
  z = 1;
```

‘==’ or ‘=’?

keyword or identifier?

3. 词法分析：实现[Implementation]

- **实现时需完成2件事情：**
  - **识别字符串的token分类**
  - **返回token的值或词素**
- 一个token是一个二元组**(class, lexeme)**
- 丢弃无意义词
  - 例如：whitespace，comments等
- 如果token类别是无二义性的，则可以在对输入字符串进行一次从左到右的扫描中识别标记
- 但token类别可能有歧义[ambiguous]

3. 词法分析：实现[Implementation]

- 歧义举例
  - C++ 模板语法
    - ✓ Foo<Bar>
  - C++ 流语法
    - ✓ cin >> var
  - 二义性
    - ✓ Foo<Bar<Bar>>
    - ✓ cin >> var
    - ✓ 疑问：‘>>’ 应当成是流操作符，还是两个连续的括号呢？

```
Template <typename T>
T getMax(T x, T y) {
    return (x > y) ? x : y;
}

int main (int argc, char* argv[]) {
    getMax<int>(3, 7);
    getMax<double>(3.0, 2.0);
    getMax<char>(‘g’, ‘e’);

    return 0;
}
```

3. 词法分析：实现[Implementation]

- “**向前看[look ahead]**”可以展望消除歧义
  - 要查看更大的上下文或结构　cin >> var
  - 有时词法分析需要parser的反馈
- 如果token没有重叠
  - tokenizing可以在没有parser反馈的情况下一次完成
  - 可明确区分词法和语法分析

3. 词法分析：总结

- 词法分析
  - 将输入符号串分解成token
  - 识别每个token的类别
- 从左到右扫描
  - 有时候需要“向前看[look ahead]”
  - 应该尽量减少“向前看[look ahead]”的数量

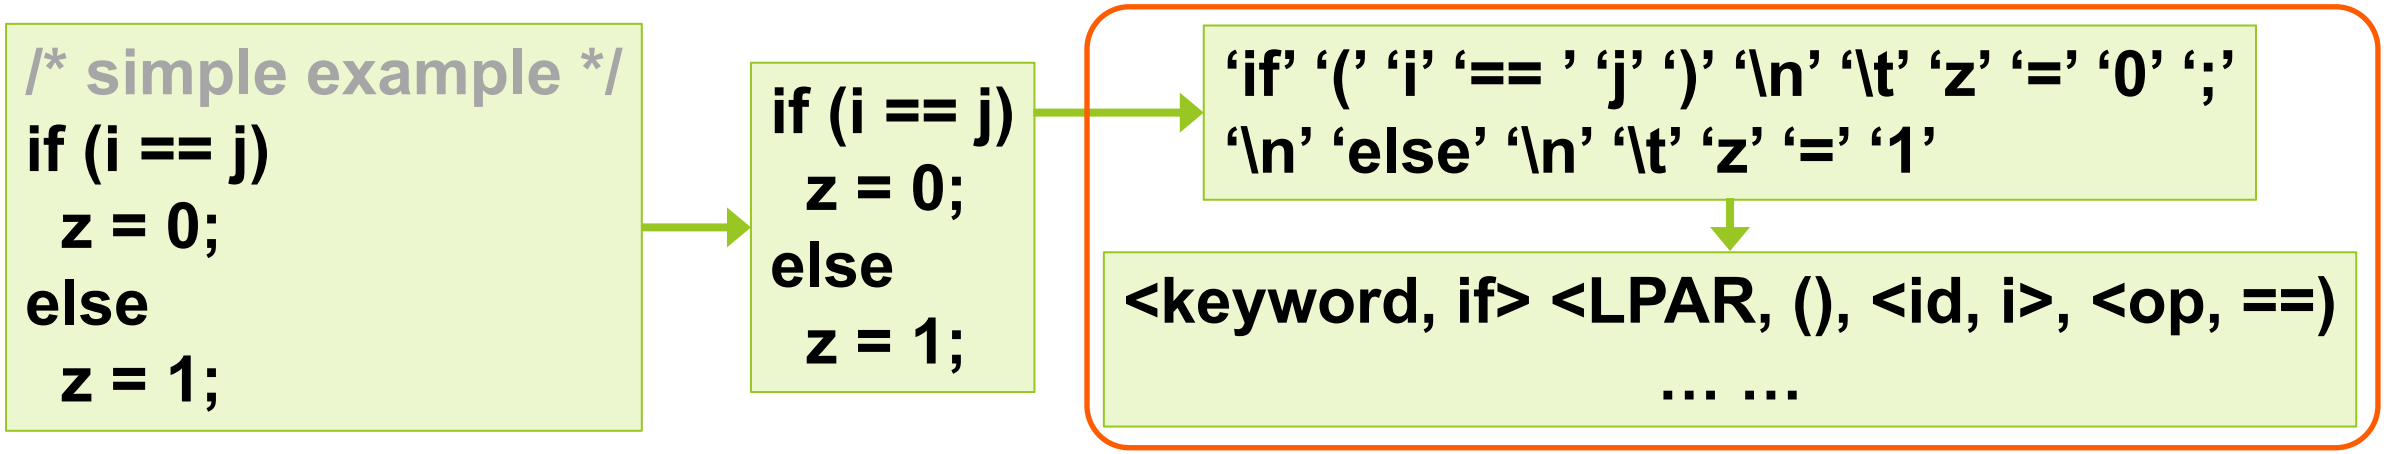

CONTENTS

目 录

1. 词法规范

- 三种词法规范
  - 表达式[Expressions]
    - ✓ 正则表达式[Regular expression]
    - ✓ 正则定义[Regular definition]
  - 语法
    - ✓ 正规文法[Regular grammar](3型文法)
  - 有穷自动机
    - ✓ 确定的有穷自动机[Deterministic Finite Automata (DFA)]
    - ✓ 不确定的有穷自动机[Nondeterministic Finite Automata (NFA)]

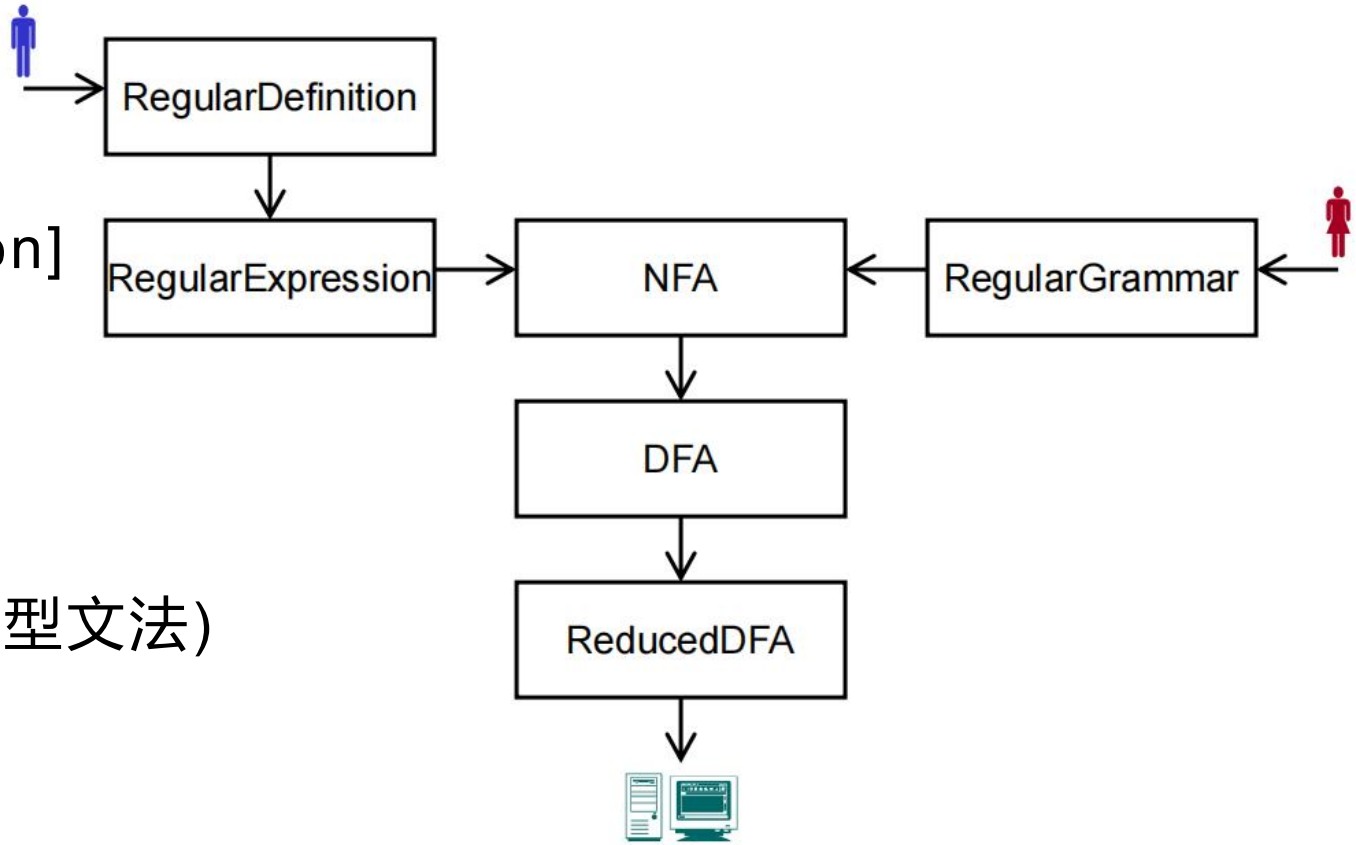

2. 正则表达式[Regular expressions, REs]

- 正则表达式可用于定义token class
  - **简单但功能强大**（能够表达模式）
  - 可以从规范**自动生成**Tokenizer实现（使用翻译工具）
  - 最终实现是**有效的**

2. 正则表达式[Regular expressions, REs]

- 定义

① ε和Φ是∑上的正规式，正规集L(ε)={ε}，L(Φ)=Φ;

② 对于任何a∈∑，a是∑上的正规式，它所表示的正规集为L(a)={a};

③ 假定r和s都是∑上的正规式，他们所表示的正规集分别为L(r)和L(s)，那么，以下也都是正规式和他们所表示的正规集;

正规式	正规集
(r)	L(r)= L ((r))= L (r)
r | s	L(r | s)= L (r)∪ L (s)
r•s	L(r•s)= L (r) L (s)
r *	L(r *)=(L (r)) *

算符的优先顺序: '( )' > ' * ' > '•' > ' | '

'•' 和 ' | ' 都是左结合

ab*c|d

a(b*)c|d

(a(b*))c|d

((a(b*))c)|d

④ 仅由有限次使用上述三步定义的表达式才是∑上的正规式，仅由这些正规式所表示的字集才是∑上的正规集。

2. 正则表达式[Regular expressions, REs]

- 例子
  - 令Σ={a，b}， Σ上的正规式和相应的正规集有：

正规式	正规集
a	{a}
a|b	{a,b}
ab	{ab}
(a|b)(a|b)	{aa,ab,ba,bb}
a *	{ε ,a,aa,…任意个a串}
(a|b)*	{ε ,a,b,aa,ab ……所有由a和b组成的串}

2. 正则表达式[Regular expressions, REs]

- 正则表达式的代数性质
  - r | s = s | r　　“|”满足交换律
  - r | (s | t) = (r | s) | t　　“|”的结合律
  - (r s) t = r (s t)　　“.(连接)”的结合律
  - r(s | t) = r s | r t
  - (r | s) t = r t | s t　　分配律
  - εr = rε= r　　ε是“.”的恒等元素
  - r|r=r　　“|”的抽取律　　r*=ε|r|rr|…

2. 正则表达式[Regular expressions, REs]

- 常用表达
  - At least one: **A+ ≡ AA***
  - Option: **A? ≡ A | ε**
  - Characters: **$[a_1a_2...a_n] \equiv a_1|a_2|...|a_n$**
  - Range: **'a' + 'b' + ... + 'z' ≡ [a-z]**
  - Excluded range: **complement of [a-z] ≡ [^a-z]**

2. 正则表达式[Regular expressions, REs]

- 例子

Regular Expression	Explanation
a*	0 or more a's (ε, a, aa, aaa, aaaa, …)
a+	1 or more a's (a, aa, aaa, aaaa, …)
(a|b)(a|b)	(aa, ab, ba, bb)
(a|b)*	all strings of a's and b's (including ε)
(aa|ab|ba|bb)*	all strings of a's and b's of **even偶数** length
[a-zA-Z]	**shorthand简写** for "a|b|…z|A|B|…|Z"
[0-9]	shorthand for "0|1|2|…|9"
0([0-9])*0	numbers that start and end with 0
1*(0|ε)1*	**binary strings that contain at most one zero**
(0|1)*00(0|1)*	all binary strings that contain '00' as substring

2. 正则表达式[Regular expressions, REs]

- 思考：$(a|b)^*$ 和 $(a^*b^*)^*$ 是否等价？ **等价**

$(a|b)^* = ?$

$(L(a|b))^* = (L(a) \cup L(b))^* = (\{a\} \cup \{b\})^* = \{a, b\}^*$

$= \{a, b\}^0 + \{a, b\}^1 + \{a, b\}^2 + \ldots$

$= \{\varepsilon, a, b, aa, ab, ba, bb, aaa, \ldots\}$

$(a^*b^*)^* = ?$

$(L(a^*b^*))^* = (L(a^*)L(b^*))^*$

$= (\{\varepsilon, a, aa, \ldots\}\{\varepsilon, b, bb, \ldots\})^*$

$= L(\{\varepsilon, a, b, aa, ab, bb, \ldots\})^*$

$= \varepsilon + \{\varepsilon, a, b, aa, ab, bb, \ldots\} + \{\varepsilon, a, b, aa, ab, bb, \ldots\}^2 + \{\varepsilon, a, b, aa, ab, bb, \ldots\}^3 + \ldots$

2. 正则表达式[Regular expressions, REs]

- 更多例子
  - Keywords: ‘if’ 或 ‘else’ 或 ‘then’ 或 ‘for’ …
    - ✓ RE = ‘i’‘f’ + ‘e’‘l’‘s’‘e’ + … = ‘if’ + ‘else’ + ‘then’ + …
  - Numbers: 非空数字字符串
    - ✓ digit = ‘0’ + ‘1’ + ‘2’ + ‘3’ + ‘4’ + ‘5’ + ‘6’ + ‘7’ + ‘8’ + ‘9’
    - ✓ 若定义integer = digit digit*，请问‘000’ 是否为integer?
  - Identifier: 以字母开头的字母或数字的字符串
    - ✓ letter = ‘a’ + ‘b’ + … ‘z’ + ‘A’ + ‘B’ + … + ‘Z’ = [a-zA-Z]
    - ✓ 若定义RE = letter(letter + digit)*，请问RE符合C语言中标识符的定义吗?
  - Whitespace: 由空格、换行符、制表符组成的非空序列
    - ✓ (‘ ’ + ‘\n’ + ‘\t’)+

2. 正则表达式[Regular expressions, REs]

- 编程语言中的REs https://docs.python.org/3/howto/regex.html

Symbol	Meaning		
\d	Any decimal digit, i.e. [0-9]		
\D	Any non-digit char, i.e., [^0-9]		
\s	Any whitespace char, i.e., [\t\n\r\f\v]		
\S	Any non-whitespace char, i.e., [^ \t\n\r\f\v]		
\w	Any alphanumeric char, i.e., [a-zA-Z0-9_]		
\W	Any non-alphanumeric char, i.e., [^a-zA-Z0-9_]		
.	Any char	\.	Matching “.”
[a-f]	Char range	[^a-f]	Exclude range
^	Matching string start	$	Matching string end
(…)	Capture matches		

2. 正则表达式[Regular expressions, REs]

- 正则表达式vs.正规文法[Regular grammar]

	正则表达式	正规文法
标识符集合	l (l | d) * 其中: l为a-z的字母，d为0-9的数字	• <标识符>→l | l <字母数字> • <字母数字>→l | d | l <字母数字> | d <字母数字>
无符号整数	dd *	<无符号整数>→d | d <无符号整数>

正规式比正规文法更容易让人理解单词是按怎样的规律构成的，且可以从某个正规式**自动地**构造识别程序。

随堂练习(1)

- 写出C语言中标识符的正则表达式

  (_|letter)(_|letter|digit)*

- 写出C语言中十进制数字的正则表达式

  0|([1-9][1-9]*)

- 写出2的倍数的二进制表示的正则表达式

  (0|1)*0