Teoría de Autómatas y Compiladores [ICI-445]
Capítulo 3: Análisis Léxico

Dr. Ricardo Soto
[ricardo.soto@ucv.cl]
[http://www.inf.ucv.cl/~rsoto]

Escuela de Ingeniería Informática
Pontificia Universidad Católica de Valparaíso

Marzo, 2010

1. Introducción

El **analisis léxico** corresponde a la primera fase de un compilador. Es la encargada de recibir el programa fuente y reconocer los **tokens**.

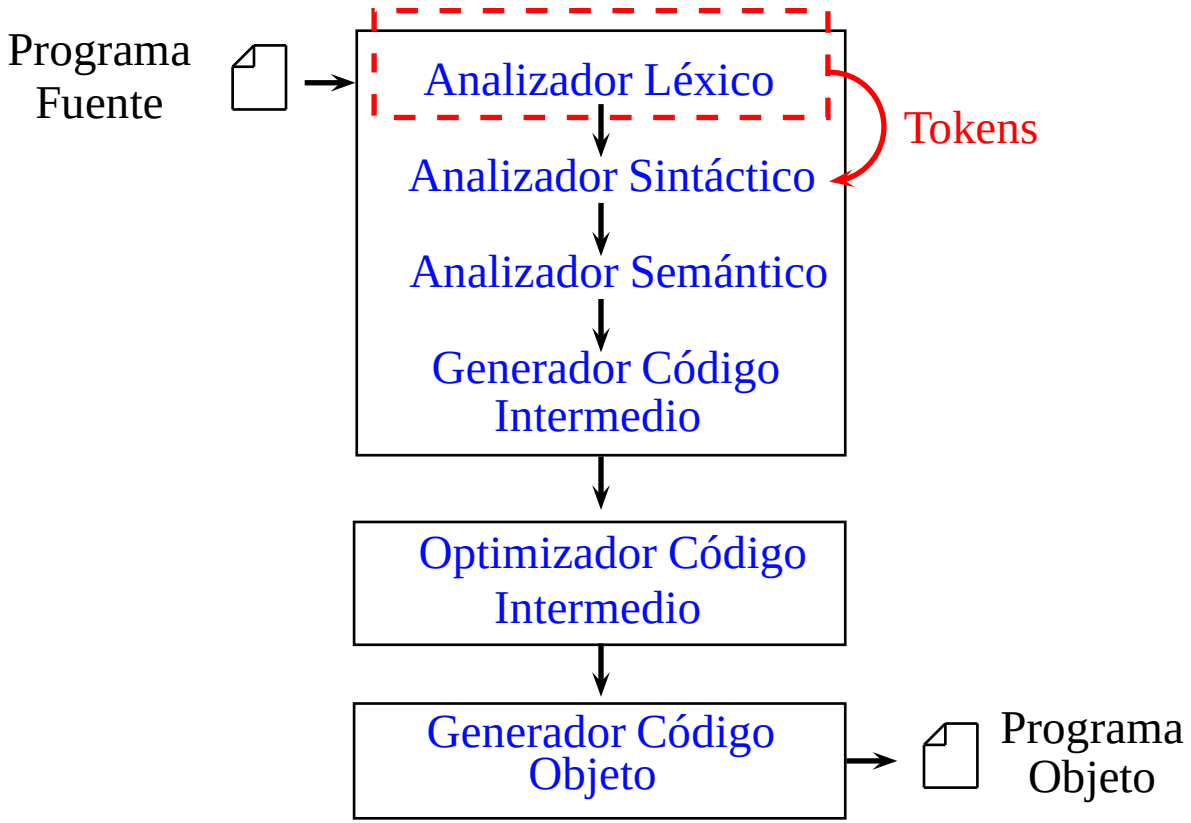

2. Funciones del Analizador Léxico

- **Generar** una lista ordenada de **tokens** a partir de los caracteres de entrada
- **Interactuar** con el analizador sintáctico, enviándole los **tokens** generados

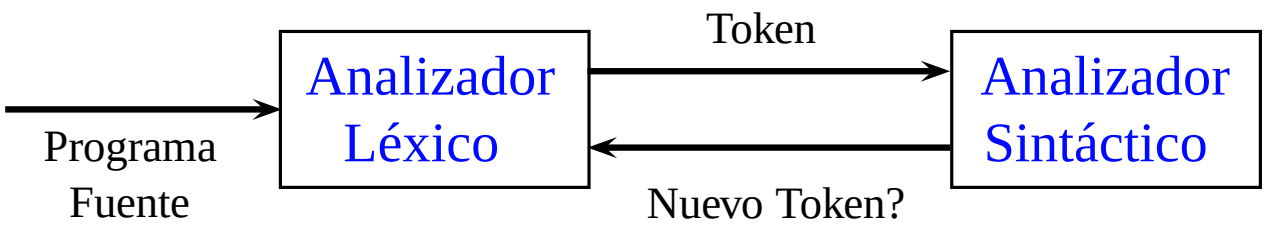

- Detección de **errores léxicos**
- **Guardar información** de los **tokens**, necesaria para el proceso de compilación.

Nota

El **analizador léxico** también se conoce como scanner, lexer o tokenizer.

3. Herramientas para implementar analizadores léxicos

- Autómatas finitos...

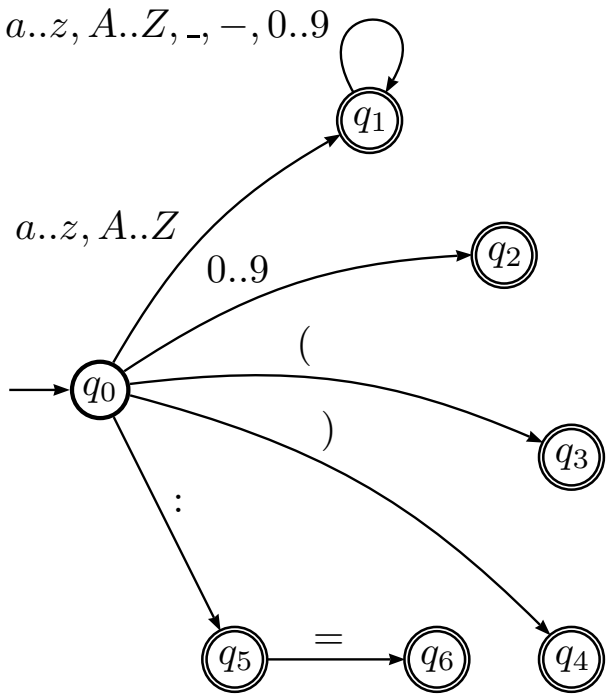

- Generadores de analizadores léxicos:
  - Lex, Flex (http://flex.sourceforge.net/)
  - JFlex (http://jflex.de/)
  - Ragel (http://www.complang.org/ragel/)
  - ANTLR (http://www.antlr.org/)
  - ...

4. Implementación de analizadores léxicos en ANTLR

Definición de Tokens

Palabras reservadas

```
tokens
{
   INT_TYPE       = "int"    ;
   REAL_TYPE      = "real"   ;
   BOOL_TYPE      = "bool"   ;
   STRING_TYPE    = "string" ;
   ...
   BEGIN_RW       = "begin"  ;
   END_RW         = "end"    ;
   IF_RW          = "if"     ;
   ELSE_RW        = "else"   ;
   WHILE_RW       = "while"  ;
   ...
   TRUE_LITERAL   = "true"   ;
   FALSE_LITERAL  = "false"  ;
   ...
}
```

4. Implementación de analizadores léxicos en ANTLR

Definición de Reglas

Letras

```
LETTER : 'a'..'z'
       | 'A'..'Z'
       ;
```

Dígitos

```
DIGIT : '0'..'9';
```

Identificadores

```
IDENT
options {testLiterals=true;} // Comprobar palabras reservadas
     : (LETTER|'_') (LETTER|DIGIT|'_')*
     ;
```

4. Implementación de analizadores léxicos en ANTLR

Definición de Reglas

Símbolos de puntuación

```
SEMICOLON : ';' ;
COMMA     : ',' ;
DOT       : '.' ;
COLON     : ':' ;
...
```

Paréntesis

```
LEFT_PAREN    : '(' ;
RIGHT_PAREN   : ')' ;
LEFT_BRACE    : '{' ;
RIGHT_BRACE   : '}' ;
LEFT_BRACKET  : '[' ;

RIGHT_BRACKET
//opción para mensajes de error
options { paraphrase="a right bracket (']')"; }
   : ']'
   ;
```

4. Implementación de analizadores léxicos en ANTLR

Definición de Reglas

Operadores Matemáticos

```
PLUS  :   '+' ;
SUB   :   '-' ;
STAR  :   '*' ;
SLASH :   '/' ;
...
```

Operadores Relacionales

```
EQUAL     : '=''=' ;
NOT_EQUAL : '!''=' ;
GR_EQUAL  : '>''=' ;
LE_EQUAL  : '<''=' ;
...
```

4. Implementación de analizadores léxicos en ANTLR

Definición de Reglas

Números

```
NUM_LITERAL : (( DIGIT )+ '.' ) =>
              ( DIGIT )+ '.' ( DIGIT )+ { $setType (REAL_LITERAL); }
            | ( DIGIT )+                 { $setType (INT_LITERAL); }
            ;
```

Blancos

```
WS :    ((' ' | '\t' | '\f')
        | ( '\n' | '\r' ) { newline(); }
        ) { _ttype = Token.SKIP;  }
        ;
```

5. Ejercicios

Implemente el analizador léxico del lenguaje MiLe (Micro Lenguaje)

Tokens

```
var      numeric   else   or
begin    string    for    and
end      if        in
```

Puntuación, paréntesis y operadores

```
. , ; { } [] () + - * / < > != == <= >= =
```

Números e identificadores

```
number ::= (digit)+ ("." (digit)+)?
ident  ::= (letter|'_') (letter|digit|'_')*
```