

Publicamos a continuación tres trabajos realizados por alumnos de la especialidad de Cálculo Automático de la Facultad de Ciencias para la asignatura de Compilación y Sistemas Operativos. Dado su volumen no publicamos los listados de los programas que están a disposición de quien quiera consultarlos en el CCUM.

ANALIZADOR MORFOLOGICO PARA UN MINI-LENGUAJE

Por Pedro Roa Medina

Se ha realizado un procesador basado en las ideas expuestas por David Gries en su libro *Compiler Generator for Digital Computers*, pags. 66-71. Trabaja en la forma bottom-up.

Este precompilador no está orientado al tratamiento de ningún lenguaje usual en particular, si bien su metodología tiene la suficiente generalidad como para adaptarse a algunos de ellos si fuese necesario.

La gramática de las U.S. analizadas puede darse en la FNB como sigue:

$\langle \text{U.S.} \rangle ::= \langle \text{posible ident.} \rangle | \langle \text{entero} \rangle | \langle \text{signo simple} \rangle |$
 $\langle \text{signo doble} \rangle | \langle \text{comentario} \rangle \langle \text{U.S.} \rangle | \emptyset \langle \text{U.S.} \rangle$
 $\langle \text{pos. ident.} \rangle ::= \langle \text{letra} \rangle | \langle \text{pos. ident.} \rangle \langle \text{letra} \rangle |$
 $\langle \text{pos. ident.} \rangle \langle \text{digito} \rangle | \langle \text{pos. ident.} \rangle \emptyset$
 $\langle \text{entero} \rangle ::= \langle \text{digito} \rangle | \langle \text{entero} \rangle \langle \text{digito} \rangle | \langle \text{entero} \rangle \emptyset$
 $\langle \text{signo simple} \rangle ::= \langle \text{+} \rangle | \langle \text{-} \rangle | \langle \text{=} \rangle | \langle \text{<} \rangle | \langle \text{>} \rangle | \langle \text{=}$
 $\langle \text{signo doble} \rangle ::= \langle \text{//} \rangle$
 $\langle \text{comentario} \rangle ::= \langle \text{/} \rangle \langle \text{*} \rangle \langle \text{cadena} \rangle \langle \text{/} \rangle$
 $\langle \text{cadena} \rangle ::= \langle \text{caracter} \rangle | \langle \text{cadena} \rangle \langle \text{caracter} \rangle | \langle \text{ } \rangle$
 $\langle \text{caracter} \rangle ::= \langle \text{cualquier carácter permitido en la máquina} \rangle$
 $\langle \text{letra} \rangle ::= \langle \text{A} \rangle | \dots | \langle \text{Z} \rangle$
 $\langle \text{dígito} \rangle ::= \langle \text{0} \rangle | \dots | \langle \text{9} \rangle$

El programa se ha realizado en el lenguaje SNOBOL-3 que representa verdaderas ventajas de manejo de cadenas de caracteres, si bien es lento el proceso.

Las funciones que realiza son:

- a) Listado del programa objeto a reconocer.
- b) Reconocimiento de las U.S., dando mensajes de error si este existiera.
- c) Asociación a cada U.S. reconocida con un código propio de ella.
- d) Evaluación de número y almacenamiento en tabla de constantes
- e) Reconocimiento, dentro del tipo de U.S. posible ident., si se trata de palabras reservadas, en cuyo caso asociaría el código de dicha palabra; en otro caso asociaría em de identificador.

Los códigos asociados con las distintas U.S. son:

identificador1
/6
+7
-8
*9
(.....10
)11
=12
//13
ABS20
BEGIN21
DO22
DIMENSION23
END24
EQUIVALENCE25
GO TO26
IF27
INTERGER28
NAMelist.29
PRINT30
READ31
STOP32
WRITE33

A la U.S. <numero> se le asociará un código tal que el primer caracter será una C, el segundo será igual al primer dígito del número y el tercero y sucesivos dígitos indican

la colocación en la tabla de las constantes que empiezan por ese dígito. Así C94 indicaría que la U.S. analizada es una constante que comienza por 9 y es la cuarta de éstas encontrada hasta ahora. Dada la facilidad del lenguaje SNOBOL para concatenar cadenas para formar nombre y la facilidad del direccionamiento indirecto, el acceso a la tabla de constantes es fácilmente realizable; por ejemplo, para conseguir el valor de una de ellas, cuyo código fuese C47 y estuviese almacenado en CØDIGØ podría hacerse de la forma

```

I = "1"
CØDIGØ * A/"1"* *B/"1"* =
UP $(B "TC") D *NUM* ","
D = D NUM ","
I = .LT(I,CØDIGØ) I + "1" /S(UP)

```

El tratamiento de palabras reservadas se efectúa de la forma siguiente:

Las palabras irán almacenadas en distintas cadenas llamadas APR, BPR, ... , según empiecen por A, B, etc.; estos nombres pueden resumirse, si tenemos la primera letra del posible identificador en FIRL, en el nombre \$(FIRL "PR") y así todas las cadenas APR...ZPR pueden tratarse dentro de un mismo nombre; se almacenarán dentro de cada cadena por orden creciente de longitudes llevando a la izquierda de la palabra su longitud sin blancos intermedios (aunque en el programa

ma fuente puede llevarlos), y a su derecha el código que le queremos asociar; la consulta a la tabla se efectuará siempre que encontremos un posible identificador y solo tendrá que consultarse la cadena que nos indique la letra del posible identificador, y dentro de ella, solo mientras que las palabras consultadas de la tabla sean de longitud menor o igual a la del posible identificador. El tratamiento en el programa de la consulta a la tabla, se hace con la función J que tomará valor 0 si no está en la tabla y si estuviera en ella tomará el código asociado.

El analizador morfológico está confeccionado en forma de una función llamada SCANNER que a su vez llama a la función J antes descrita, si bien en el listado adjunto existe un programa principal que solo nos sirve para llamar sucesivas veces a la subrutina SCANNER con fines de prueba.

El trabajo se ha realizado según el diagrama de estados adjunto, donde las acciones semánticas indicadas significan:

GCH .- poner en CHAR el siguiente caracter del input
 GNB .- " " " " " " " " no blanco
 CLAS .- calcular CLAS de acuerdo con:
 CLAS=1 si CHAR es dígito.
 " 2 " " " letra
 " 3 " " " /
 " 4 " " " + ó - ó * ó (ó) ó =
 ADD .- concatenar el trozo de U.S. almacenado hasta ahora

con CHAR.

La programación de estas acciones se ha efectuado con un conjunto de instrucciones con etiquetas de salida que admiten ser definidas antes de que se efectue la transferencia, y por tanto nos permiten usarlas de forma parecida a una subrutina (tengase en cuenta que en el lenguaje de programación usado no existe la posibilidad de usar subrutinas).

El programa fué realizado en el C.C.U.M.; su puesta en marcha fué laboriosa dado que no existía práctica en el manejo del lenguaje usado ni en el de su compilador .

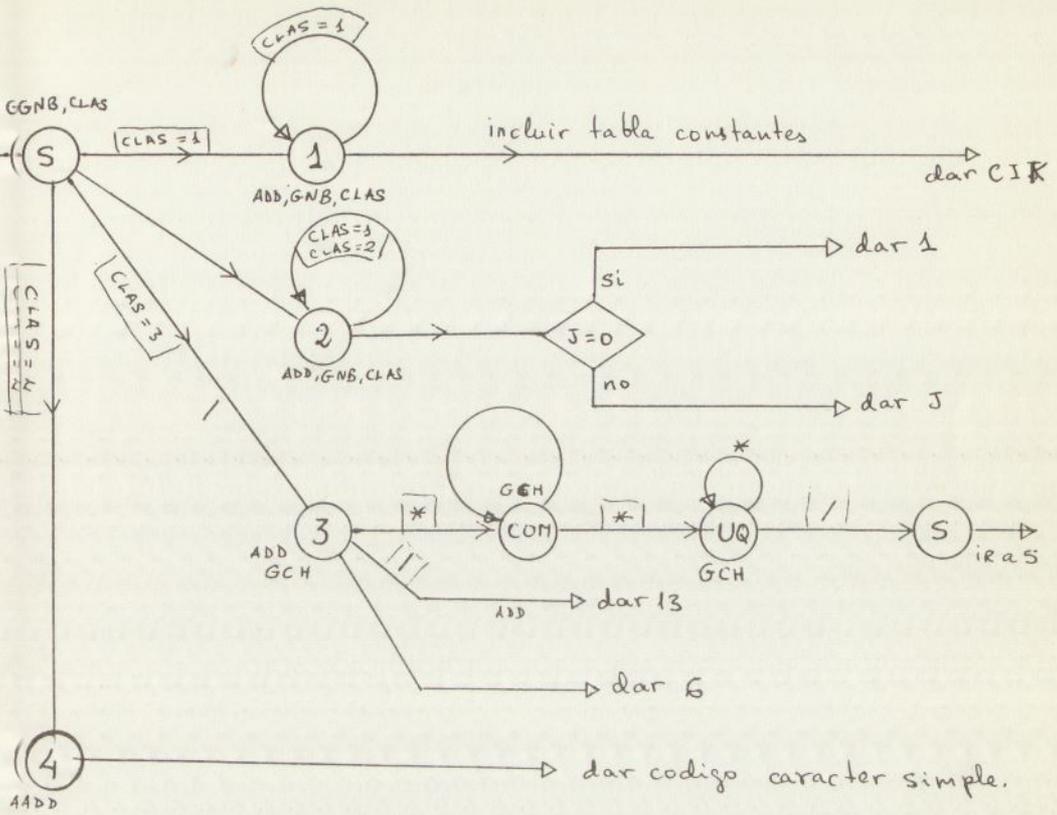


DIAGRAMA DE ESTADOS CON ACCIONES SEMANTICAS INDICADAS DE LA SUBROUTINA SCANNER