PROCESADORES DE LENGUAJE

Ingeniería Informática
Especialidad de computación
Tercer curso, segundo cuatrimestre

Departamento de Informática y Análisis Numérico
Escuela Politécnica Superior de Córdoba
Universidad de Córdoba

Hoja de ejercicios nº **1.- ANÁLISIS LÉXICO**

Alfabetos, palabras y lenguajes formales

1. Obtén las palabras de longitudes 1, 2 y 3 de los siguientes alfabetos:
   Σ_1 = {a}, Σ_2 = {0,1}, Σ_3 = {if, then, else}, Σ_4 = {a, b, c, d}

2. Indica el lenguaje universal Σ^* que genera el alfabeto Σ = {a, b, 1, 2}

3. Dado el alfabeto Σ = {a, b, c}:
   - Se definen las siguientes palabras
     - x = ab, y = bba, z = cb
   - Realiza las siguientes operaciones
     - xy, yx, x(yz), x ε z, z y^0 x, x^2 y z^2, $(x\ y)^2$

4. Dado el alfabeto Σ = {a, b, c}:
   - Se definen los siguientes lenguajes formales
     - L_1 = {a, aa, aaa}, L_2 = {a, b, ba, bc} y L_3 = {ε, a, b, c}
   - Realiza las siguientes operaciones
     - $L_1 \cup L_2$, $L_1 \cap L_2$, $L_1 L_2$, $L_1 - L_2$, $L_2 - L_1$
     - $(L_1)^2$
     - L_1^*
     - L_3^+
     - $L_1 (L_2 \cup L_3)$
     - $(L_3 - L_1) \cap (L_1 L_3)$

5. Dado el alfabeto Σ = {a, b}
   - Indica dos lenguajes L_1, L_2 que verifiquen que
     - $(L_1 \cup L_2)^* \neq L_1^* \cup L_2^*$
   - Indica dos lenguajes L_1, L_2 que verifiquen que
     - $L_1 \not\subset L_2$, $L_2 \not\subset L_1$ y $(L_1 \cup L_2)^* = L_1^* \cup L_2^*$
   - Indica tres lenguajes L_1, L_2 y L_3 de forma que
     - $L_3 (L_2 - L_1) \neq L_3 L_2 - L_3 L_1$

6. Sea Σ = {a, b} y $L \subseteq \Sigma^*$ es un lenguaje definido recursivamente de la siguiente forma:
   a) $\varepsilon \in L$

b) Si $x \in L$, entonces a x b, b x a $\in L$
c) Si x, y $\in L$, entonces x y $\in L$
d) No hay nada más en L

- Demuestra que:
  - L = { w | w $\in \Sigma^* \wedge$ w contiene el mismo número de aes que de bes}
  - Si b, $\varepsilon \in L$ ¿Qué más palabras hay en L?
  - Da una definición recursiva para que L' $\subseteq \Sigma^*$ contenga todas las palabras que posean doble número de aes que de bes.

7. Si cardinal(L) nos indica cuantas palabras posee un lenguaje, comprueba si es cierta o falsa la siguiente afirmación:
   cardinal (L_1 L_2) = cardinal(L_1) cardinal(L_2).
   - Si se cree que es falsa, póngase un contraejemplo; si se cree que es verdadera, demuéstrese.

Expresiones regulares

8. Indica algunas expresiones regulares que se puedan definir sobre el siguiente alfabeto Σ = {a, b, 1, 2}

9. Indica cuál es el lenguaje denotado por las siguientes expresiones regulares definidas sobre Σ = {a, b}:
   a) a a* b b*
   b) a (a* + b*) b
   c) a (a + b)* b

10. Dado el alfabeto Σ = {-, ., _ ,a, b, c, …, z, A, B,…, Z, 0, 1, …, 9} y las siguientes definiciones regulares
    - dígito = 1 + 2 + … + 9
    - cero = 0
    - numero = cero + dígito
    - punto = .
    - guión = -
    - subrayado = _
    - letra = a + b + … + z + A + B + … + Z
    - Indica cuál es el lenguaje denotado por cada una de las siguientes expresiones regulares:
      a) número numero* punto número*
      b) número * (punto + ε)
      c) (cero + dígito número*) punto (cero + número* dígito)
      d) letra (letra + número)* número

11. Define expresiones regulares que denoten los siguientes lenguajes formales definidos sobre el alfabeto Σ = {0,1}:
    a) L_1 = { x | x $\in \Sigma^* \wedge$ x sólo contiene dos ceros y un número indefinido de unos}
    b) L_2 = { x | x $\in \Sigma^* \wedge$ x contiene al menos dos ceros consecutivos}
    c) L_3 = { x | x $\in \Sigma^* \wedge$ x contiene un número impar de ceros y un número indefinido de unos}

d) $L_4 = \{ x \mid x \in \Sigma^* \wedge$ cada cero de x es seguido inmediatamente por 11$\}$

12. Escribe expresiones regulares que denoten los siguientes lenguajes definidos sobre $\Sigma = \{a, b, c\}$
    a) Palabras que comienzan **y** finalizan con la letra **"a"**.
    b) Palabras que comienzan **o** finalizan con la letra "a" (o ambas posibilidades).
    c) Palabras en las que la **"a"**, si aparece, siempre precede a la **"b"**.
    d) Palabras que tengan un número **impar** de **aes**.

13. Define expresiones regulares que denoten los siguientes lenguajes definidos recursivamente:
    a) $\varepsilon \in$ L. Si **x** $\in$L, entonces **aax** y **xb** son palabras de L. Sólo están en L las palabras obtenidas mediante las premisas anteriores.
    b) $\varepsilon \in$ L. Si **x** $\in$L, entonces **abx**, **bax**, **aax** y **bbx** son palabras de L. Sólo están en L las palabras obtenidas mediante las premisas anteriores.

14. Escribe expresiones regulares que denoten los siguientes lenguajes:
    - Números naturales que no contengan dos o más ceros al principio: 0, 10, 121,…
    - Números pares.
    - Números impares.
    - Números reales con formato de punto fijo o con formato de punto flotante pero que no tengan ceros superfluos, es decir,
      - son permitidos los números del tipo 0.0, 132.0, 0.526, 1203.0494,
      - pero no son permitidos los números de la forma 00.12, 124.000, 001.727, 52.700.

15. Considera el siguiente código escrito en el lenguaje **C** que implementa el método de ordenación de Shell:

```
#include <stdio.h>
#include <malloc.h>
#include "macros.h"
/* Longitud maxima -1 de los nombres */
#define NUMERO_CARACTERES     20

void shell (struct ficha_persona *dato, int n)
{
 int d,i, bandera;
 struct ficha_persona auxiliar;
 d = n;
 do {
       d = d / 2;
       do{
           bandera = 0;
           i = 0;
          do {
               if (dato[i].edad > dato[i+d].edad)
                {
                 strcpy(auxiliar.nombre,(dato+i)->nombre);
                 auxiliar.edad = (dato+i)->edad;
                 strcpy((dato+i)->nombre,(dato+i+d)->nombre);
                 (dato+i)->edad = (dato+i+d)->edad;
```

```
                    strcpy((dato+i+d)->nombre, auxiliar.nombre);
                    (dato+i+d)->edad = auxiliar.edad;
                    bandera = 1;
                  }
                 i++;
               } while (i+d <= n-1);
            } while (bandera !=0);
         } while(d!=1);
      }
```

a) Indica **los diferentes tipos** de componentes léxicos o "tokens" que generaría el analizador léxico.
b) Define las expresiones regulares que denotan **los tipos** de componentes léxicos indicados en el apartado anterior.

16. Considera el siguiente código escrito en el lenguaje FORTRAN

```
      INTEGER I, J
        REAL Vector(10), Matriz(5,5)

        PRINT *,'INTRODUCE LAS COMPONENTES IMPARES DEL VECTOR'
        DO 10 I = 1, 9, 2
           PRINT *, 'COMPONENTE ',I,' -->'
           READ *, Vector (I)
   10   CONTINUE

        PRINT *,'INTRODUCE LAS COMPONENTES DE LA DIAGONAL PRINCIPAL'
        DO 20 I = 1, 5
             PRINT *, 'COMPONENTE (',I,',',I,') -->'
             READ *, Matriz (I,I)
   20   CONTINUE
```

a) Indica los diferentes tipos de componentes léxicos que reconocería el analizador léxico.
b) Escribe las expresiones regulares correspondientes a dichos tipos de componentes léxicos.

17. Indica las expresiones regulares que denoten los componentes léxicos de un lenguaje de programación en pseudocódigo:
    - **Identificadores**:
      - Podrán estar compuestos por letras, números y el símbolo "_".
      - Podrán comenzar por una letra o el símbolo "_"
      - El símbolo "_" no podrá aparecer al final.
    - **Números**:
      - Se podrán definir números enteros (19), reales de punto fijo (19.75) o con notación exponencial (0.19e+2).
    - **Cadenas de caracteres:**
      - Estarán compuestas por cualquier carácter excepto las comillas simples de apertura (‘) y cierre (’), que deberán aparecer al principio y al final, respectivamente.
      - Se utilizará la barra invertida \ para poder introducir las comillas simples dentro de las cadenas.
    - **Palabras reservadas:**
      - Se podrán escribir con letras mayúsculas o minúsculas o ambas
      - Deberán comenzar y terminar por el símbolo de subrayado "_".
      - Por ejemplo: _mientras_

- **Operadores**:
  - Asignación:
    - se utilizará el operador de Pascal (:=)
  - Lógicos:
    - Estarán delimitados por dos símbolos de subrayado
    - Por ejemplo: _no_
  - Aritméticos:
    - Se utilizarán como operadores las tres "primeras letras" de cada una de las operaciones aritméticas (suma, resta, multiplicación, división y potencia) pero delimitadas por el símbolo "_"
    - Por ejemplo: _pot_
  - Relacionales:
    - Se utilizarán los símbolos empleados por el lenguaje C, excepto los operadores "igual" y "distinto" que se utilizarán los empleados por Pascal (=, <>).

Autómatas finitos

18. Dados los siguientes autómatas finitos deterministas:
- Dibuja la representación gráfica de cada uno.
- Comprueba si reconocen o no las palabras que se indican en cada caso, mostrando las transiciones que se vayan produciendo "paso a paso".
- Indica de manera informal cómo es el lenguaje que reconoce cada autómata.
- Define una expresión regular que denote el lenguaje que reconocería cada autómata.

a) AFD1

δ	*a*	*b*	*c*
→ q_0	q_1	q_3	q_3
q_1	q_1	q_2	q_2
← q_2	q_3	q_2	q_2
q_3	q_3	q_3	q_3

- *x* = *aabcc*
- *y* = *abca*

b) AFD2

δ	*d*	*0*	*p*
→ q_0	q_1	q_2	-
← q_1	q_1	q_1	q_3
← q_2	-	-	q_3
q_3	q_4	q_5	-
← q_4	q_4	q_6	-
← q_5	q_4	q_6	-
q_6	q_4	q_6	-

donde $d \in \{1, 2, 3, 4, 5, 6, 7, 8, 9\}$ y *p* es el punto decimal "."
- $x_1 = 0.79$

- $x_2 = 012.0$
- $x_3 = 12.0$
- $x_4 = 10203$
- $x_5 = 45.600$
- $x_6 = 0.0$

19. Dados los siguientes autómatas finitos **no** deterministas:
    - **Dibuja** la representación gráfica de cada uno.
    - Comprueba si reconocen o no las cadenas que se indican en cada caso, mostrando las transiciones que se vayan produciendo "paso a paso".

    a) AFN **sin** transiciones épsilon no triviales

δ	a	b	c
$\rightarrow q_0$	$\{q_1,q_2\}$	ϕ	ϕ
q_1	ϕ	$\{q_1,q_2\}$	$\{q_3, q_4\}$
q_2	ϕ	$\{q_1,q_2\}$	$\{q_3, q_4\}$
$\leftarrow q_3$	ϕ	ϕ	$\{q_3, q_4\}$
$\leftarrow q_4$	ϕ	ϕ	$\{q_3, q_4\}$

    $x = abbcc$, $y = abcb$

    b) AFN **con** transiciones épsilon no triviales

δ	a	b	c	ε
$\rightarrow q_0$	$\{q_1\}$	$\{q_2,q_3\}$	ϕ	$\{q_0,q_2\}$
q_1	ϕ	$\{q_3,q_4\}$	$\{q_1,q_2,q_3\}$	$\{q_2\}$
$\leftarrow q_2$	$\{q_3\}$	$\{q_1,q_2\}$	ϕ	$\{q_3\}$
q_3	$\{q_0\}$	$\{q_2\}$	$\{q_4\}$	$\{q_4\}$
$\leftarrow q_4$	ϕ	$\{q_2,q_3\}$	$\{q_1,q_4\}$	$\{q_1,q_2,q_4\}$

    $x = aabc$, $y = bbacab$

20. Algoritmo de "**construcción de subconjuntos**"
    a) Aplica el algoritmo de "**construcción de subconjuntos**" a los autómatas finitos no deterministas del ejercicio anterior.
    b) Comprueba si los autómatas finitos deterministas construidos reconocen las cadenas propuestas en dicho ejercicio.

21. Dadas las siguientes expresiones regulares
    - *letra (letra + dígito) **
    - *(letra + subrayado) (letra + subrayado + dígito)**
    - *letra (letra + dígito + guion (letra + dígito))**
    - *comillas (letra + dígito + barra comillas)* comillas*

    donde letra∈{a, ..., z, A, ..., Z}, dígito ∈ {0,1,...,9}, subrayado es el símbolo '_', guion es el símbolo '-', comillas es el símbolo '"' y barra es símbolo '\'.

    a) Utiliza el algoritmo de "**construcción de Thompson**" para construir los autómatas finitos **no** deterministas equivalentes.
    b) Utiliza el algoritmo de **"construcción de subconjuntos"** para construir los autómatas finitos **deterministas** equivalentes a los obtenidos en el apartado anterior.
    c) **Minimiza** los autómatas finitos deterministas.
    d) Comprueba si los autómatas finitos construidos en los apartados anteriores reconocen, respectivamente, las siguientes cadenas:
        - *x = dato, y = dato1, z = 1dato*
        - *x = dato, y = dato_1, z = _dato__1*
        - *x = dato-1, y = dato--1, z = dato1-1*
        - *x = "ejemplo de \"cadena\" "*

22. Dado el siguiente autómata finito determinista

δ	*l*	*d*	*g*
→ ***q0***	*q1*	-	-
← ***q1***	*q2*	*q3*	*q4*
← ***q2***	*q2*	*q3*	*q4*
← ***q3***	*q2*	*q3*	*q4*
← ***q4***	*q2*	*q3*	-

    donde el significado de *l*, *d* y *g* es el siguiente: *l* = letra, *d* = dígito y *g* = guion
    a) Dibuja su representación gráfica.
    b) **Minimiza** el autómata mediante la obtención del autómata cociente.

23. Dado el siguiente autómata finito determinista:

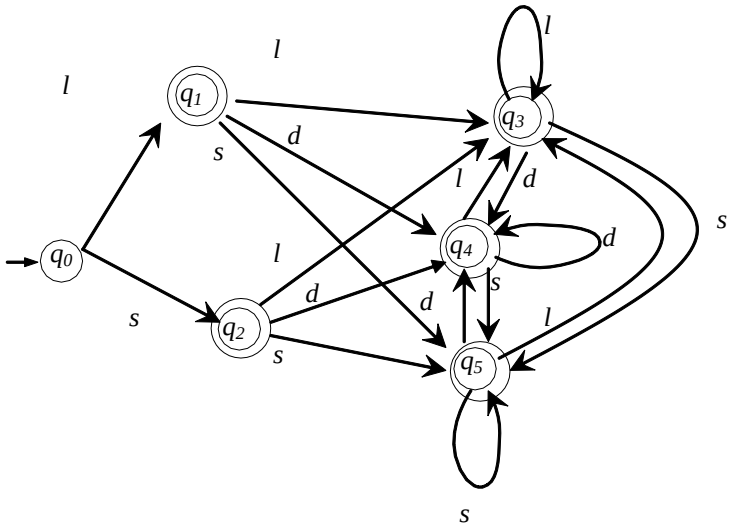

donde el significado de **l**: letra, **d**: dígito y **s**: subrayado.

a) Comprueba si reconoce o no la cadena x = ldsl
b) Minimiza el autómata finito determinista.
c) Comprueba si el autómata minimizado reconoce o no la cadena x = ldsl

Errores léxicos

24. El siguiente código escrito en lenguaje **C** calcula el factorial de un número, pero tiene **"diez errores léxicos"**.

```
[1] int factorial (int n
[2]
[3]  Int i;
[4]  int re$ultado;
[5]
[6]  nif ( (n==0) || (n==1) )
[7]        return (1.0.0);
[8]    else {
[9]          resultado := 1;
[10]          for (i===n ; i > 1 ; i--)
[11]                   resultado **= i;
[12]
[13]          return (resultado)
[14]        }
[15] }
```

a) Indica los errores léxicos que se **pueden detectar** durante el análisis léxico
b) Indica los errores léxicos que se **pueden detectar** durante el análisis sintáctico
- Observación: se indican los números de las líneas para facilitar la identificación de cada error

25. Considera el siguiente fragmento de código erróneo escrito en C

```
[1] fooor  (i = N ; > i  1.0.0 ; i--)
[2]   {
[3]         factorial = factorial * $n;
[4]   }
[5]   printf " Factorial = %d " /n, $factorial);
```

a) Indica los errores que **puede** detectar "el analizador léxico" y los que **no** puede detectar y **"por qué"**.
b) Indica los componentes léxicos que reconocería el "analizador léxico".
c) Escribe las expresiones regulares correspondientes a los diferentes tipos de componentes léxicos reconocidos en el fragmento anterior.
   - Observación: se indican los números de las líneas para facilitar la identificación de cada error