

## **Leaf Type Recognition**

Guillermo Sampallo

Facultad Regional Resistencia - UTN  
French 414 - Resistencia – Chaco - Argentina  
sampallo@frre.utn.edu.ar

Keywords: Artificial vision. Pattern recognition. Measure of objects

An expert system was developed, based on rules, to recognize leaves of plants, for it, it was selected the following properties of the same ones: area, perimeter, circularity, signatures, superficial density and histogram that were evaluated, with these values and its variation range was built a database.

It was appealed the one enunciated of ten rules that combine the mentioned properties and their linkage to achieve the recognition. In the evaluation of the performance of the system it was verified that the recognition doesn't produce false results inside the group of selected objects.

# Reconocimiento de Tipos de Hojas

Guillermo Sampallo

Facultad Regional Resistencia - UTN  
French 414 - Rcia – Chaco - Argentina  
sampallo@frre.utn.edu.ar

## Resumen

Se desarrolló un sistema experto, basado en reglas, para reconocer hojas de plantas, para ello, se seleccionó las siguientes de las mismas: área, perímetro, circularidad, firma, densidad superficial e histograma, que fueron evaluadas, con estos valores y su rango de variación se construyó una base de datos. Se recurrió al enunciado de diez reglas que combinan las propiedades mencionadas y su encadenamiento para lograr el reconocimiento. En la evaluación de la performance del sistema se verificó que el reconocimiento no produce resultados falsos dentro del conjunto de objetos seleccionados.

**Palabras claves:** Visión artificial. Reconocimiento de patrones. Medida de objetos.

## 1. Introducción

El reconocimiento de patrones mediante técnicas de procesamiento de imágenes es un tema de permanente actualidad debido a que es posible aplicar a diferentes áreas de la ciencia y de la tecnología. El reconocimiento de objetos en una imagen está desarrollado ampliamente en la bibliografía [2, 3, 7, 8, 12 - 16], pero, los programas de procesamiento digital de imágenes (Corel, Paint Shop Pro, MGI PhotoSuite SE, etc) que generalmente acompaña a los equipos de adquisición no tienen la capacidad para hacer algún tipo de reconocimiento y tampoco admiten la posibilidad de agregar algoritmos para hacerlo. El reconocimiento de patrones involucra técnicas de medición de características morfológicas y de textura de los objetos contenidos en la imagen y el desarrollo de un sistema experto que sea capaz de reconocer el objeto a partir de aquellas características medidas.

En este trabajo se presenta el desarrollo de un sistema experto [1, 4, 5], basado en reglas para hacer el reconocimiento de hojas de plantas.

## 2. Los Objetos a Reconocer

Se seleccionaron las siguientes plantas

1. Peperomia seandens (pimentero),
2. Peschiera australis (palo víbora),
3. Eupatoriun canabina
4. Plectranthus australis,
5. Pileacadieri (madre perla o begonia francesa)
6. Brunfelsia australis (jazmín paraguayo),
7. Eugenia uniflora
8. Codiaeum variegatum

(las hojas están mostradas en la figura 1)

De cada una se extrajo 10 ejemplares. La adquisición de la imagen de niveles de grises de las hojas se realizó a través de un escáner de página completa con resolución 400 ppp, colocando en el campo del mismo todas las hojas de una clase, de

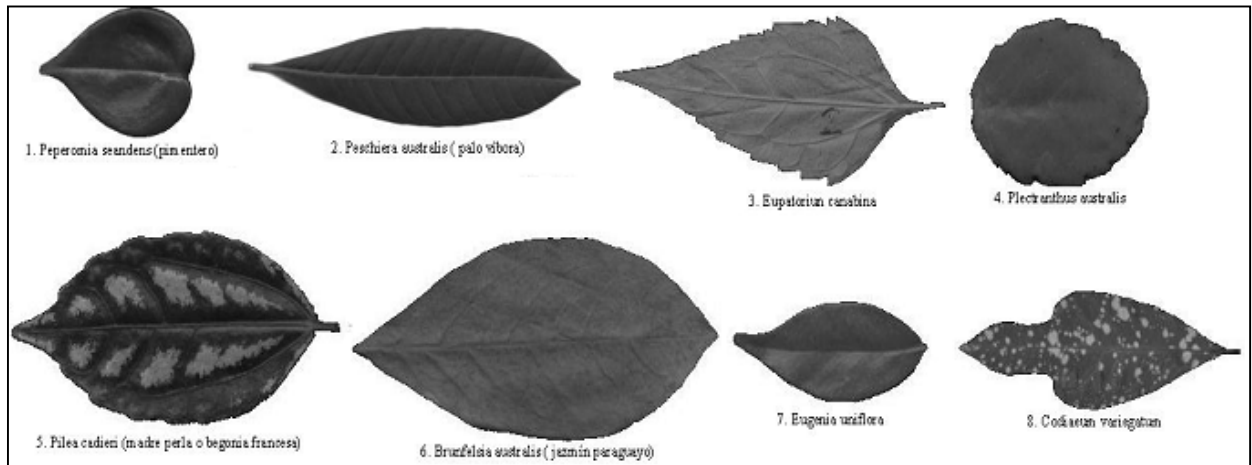


Figura 1. Tipos de hojas

modo que, la condición de iluminación en el registro fue idéntica, esta manera de adquirir la imagen permite la selección del color del fondo, que por razones de simplicidad, fue elegido negro (es decir, nivel de gris = 0).

Las hojas pueden considerarse como objetos planos, con contornos bien definidos y textura diferente en cada cara. Las hojas pueden considerarse como objetos planos, con contornos bien definidos y textura diferente en cada cara. Por razones de espacio y simplicidad acá solo fue tratada la cara del frente de la hoja.

### 3. Selección y evaluación de los descriptores

Las propiedades que deben tener los descriptores son: ser capaces de hacer una adecuada discriminación, ser suficientemente fiables y lo más independientes posible, además, es aconsejable que el número de descriptores que sea pequeño

Se seleccionaron descriptores de tipo morfológico y de textura. Dentro de los primeros están el área, el perímetro, la circularidad y la firma. Y como descriptor de textura se consideró al propio histograma de la hoja. Otro descriptor seleccionado fue la *densidad superficial* que combina la distribución del nivel de gris y el tamaño mediante el cociente entre la suma de las intensidades (niveles de gris) de todos los píxeles perteneciente al objeto y el área del mismo.

Por el tipo de objeto bajo estudio, se consideró conveniente realizar un estudio estadístico previo de los valores de los descriptores morfológicos para establecer un rango de variación de los mismos a fin de construir una base de datos de referencia. El mismo tipo de análisis debe realizarse con la textura y a la densidad superficial.

Tanto el área A y el perímetro P fueron determinados por medio de técnicas de procesamiento de imágenes semejantes a las presentadas en [7] y a partir de los cuales fue posible determinar la circularidad ( $c = P^2 / 4 \pi A$ ). Para estos descriptores se calculó el valor medio (fila superior) y el error porcentual (fila inferior) a partir de su correspondiente desviación standard para cada clase de hoja, almacenándose esta información en las siguientes tablas

$$Area = \begin{bmatrix} 16145 & 24579 & 25624 & 12175 & 28676 & 34542 & 7856 & 7659 \\ 26 & 17 & 46 & 35 & 13 & 20 & 15.1 & 215 \end{bmatrix}$$

$$Perimetro = \begin{bmatrix} 271 & 617 & 493 & 278 & 424 & 485 & 258 & 254 \\ 11 & 8 & 10 & 36 & 9 & 34 & 967 & 96 \end{bmatrix}$$

$$Circ = \begin{bmatrix} 0.38 & 1.26 & 0.86 & 0.57 & 0.51 & 0.56 & 0.68 & 0.68 \\ 17.9 & 16.3 & 25.7 & 68.3 & 12.5 & 59.7 & 8.2 & 57 \end{bmatrix}$$

Para determinar la firma de cada clase de hoja, se obtuvo primero la firma de cada ejemplar de la clase (ver secuencia de cálculo en el anexo 1) luego se calculó el promedio para cada orientación angular, por ejemplo, la figura 2 muestra las firmas de las hojas clase 1 y la figura 3 la firma promedio. En esta figura, se ve claramente como  $r(\theta)$  varía en forma análoga para hojas distintas de la misma clase, por lo tanto, cuando se hace el promedio para cada orientación angular se obtiene la firma promedio (figura 4), a la que se puede interpretar como la firma representativa de la clase. Cuando se tiene en cuenta la desviación de la firma de cada ejemplar respecto de esta firma promedio el resultado está por debajo de 9%.




Figura 2. Firmas de las hojas de la clase 1




Figura 3. Firma promedio de las hojas de la clase 1




Figura 4. Firmas promedios

En la figura 4 se muestran todas las firmas promedio de las clases de hojas estudiadas, para que el lector haga una comparación cualitativa de las mismas. En estas aparece el máximo alrededor de la orientación de  $180^\circ$ , esto se debe a que, en todos los casos, para obtener la firma se orientó la hoja de forma que su eje principal se alineó al eje horizontal. Además, se empleó la firma normalizada. La tabla 1 muestra los coeficientes de correlación entre las distintas clases de hojas, a partir de estos coeficientes se puede establecer un criterio para discriminar entre las

clases, eligiendo por ejemplo, 98% del valor del coeficiente de correlación mayor obtenido. En la tabla, con fondo gris, se muestran ocho casos que se hallan fuera de la diagonal donde este criterio falla. Aún así la firma promedio representativa de la clase de hoja es considerada un buen descriptor.

	Hoja 1	Hoja 2	Hoja 3	Hoja 4	Hoja 5	Hoja 6	Hoja 7	Hoja 8
Hoja 1	1.00	0.76	0.93	0.69	0.72	0.88	0.87	0.73
Hoja 2	0.76	1.00	0.93	0.92	0.99	0.97	0.97	0.97
Hoja 3	0.93	0.93	1.00	0.84	0.90	0.98	0.99	0.90
Hoja 4	0.69	0.92	0.84	1.00	0.96	0.91	0.88	0.83
Hoja 5	0.72	0.99	0.90	0.96	1.00	0.96	0.94	0.95
Hoja 6	0.88	0.97	0.98	0.91	0.96	1.00	0.99	0.93
Hoja 7	0.87	0.97	0.99	0.88	0.94	0.99	1.00	0.93
Hoja 8	0.73	0.97	0.90	0.83	0.95	0.93	0.93	1.00

Tabla 1 Coeficientes de correlación entre las firmas promedio de las distintas clases de hojas

El histograma de una imagen digital con niveles de gris en el rango  $[0, L-1]$  es una función discreta  $p(z_k) = n_k / n$  donde  $z_k$ , es el  $k$ -ésimo nivel de gris,  $n_k$  es el número de píxeles de la imagen con ese nivel de gris,  $n$  es el número total de píxeles de la imagen y  $k = 0, 1, \dots, L-1$ .  $p(z_k)$  da una idea del valor de probabilidad de que aparezca el nivel de gris  $z_k$ . La representación gráfica de esta función para todos los valores de  $k$  proporciona una descripción global de la apariencia de la hoja y en sí misma puede constituir un descriptor, debe tenerse presente que un histograma puede corresponder a más de una imagen.

La comparación entre histogramas de ejemplares de la misma clase se realizó empleando los coeficientes de diferencia significativa<sup>1</sup>, en todos los casos el resultado indicó que no hay diferencia entre los mismos. En la figura 5 se muestra los histogramas promedio de cada clase de hoja. Claramente se ve que solo una región del intervalo de niveles de gris es ocupado en forma significativa, mientras que es despreciable la presencia del nivel 160 y 255. Se debe destacar que en la representación se excluyeron los valores de niveles de gris entre 250 y 255 considerando que su contribución se debía al fondo, que en este caso, se usó blanco.

Una forma de analizar si estos histogramas pueden servir como descriptores es calcular la correlación entre ellos. La tabla 2, exhibe los coeficientes de correlación entre los mismos. Si se busca un criterio

1

Diferencia significativa

$$D = \frac{x_1 - x_2}{\sqrt{Ex_1 + Ex_2}}$$

Donde  $x_1$  y  $x_2$  son las medias aritméticas de la serie de observaciones a cada grupo y  $Ex_1$  y  $Ex_2$  son desviaciones standard respectivas. [17]

de clasificación, en la tabla 2 basta con seleccionar, por ejemplo, un coeficiente de correlación igual o superior a 0.98, para discriminar entre las clases de hojas.




Figura 5 Histogramas promedios

De esta forma el mismo histograma se convierte en un descriptor de la hoja. Es relevante porque es de tipo global, como se indicó antes. Además debe tenerse presente que el descriptor depende, primero, de la forma en que la imagen fue adquirida (depende de la iluminación y de la reflectancia) y segundo, del tiempo de deshidratación de la hoja, del cual este descriptor puede constituirse en un interesante diagnóstico. Se empleará como descriptor de cada clase de hoja su histograma promedio. Con estos se construye una matriz de histogramas promedio con los valores restringidos al intervalo entre 10 y 160 de niveles de gris, teniendo en cuenta la figura 3.

	Hoja 1	Hoja 2	Hoja 3	Hoja 4	Hoja 5	Hoja 6	Hoja 7	Hoja 8
Hoja 1	1.00	0.95	-0.07	0.44	0.95	0.04	0.47	0.91
Hoja 2	0.95	1.00	-0.10	0.29	0.96	-0.04	0.33	0.90
Hoja 3	-0.07	-0.10	1.00	0.06	0.09	0.95	0.12	0.11
Hoja 4	0.44	0.29	0.06	1.00	0.39	0.30	0.97	0.59
Hoja 5	0.95	0.96	0.09	0.39	1.00	0.18	0.46	0.96
Hoja 6	0.04	-0.04	0.95	0.30	0.18	1.00	0.37	0.25
Hoja 7	0.47	0.33	0.12	0.97	0.46	0.37	1.00	0.65
Hoja 8	0.91	0.90	0.11	0.59	0.96	0.25	0.65	1.00

Tabla 2. Coeficientes de correlación entre los histogramas promedios

La densidad superficial es el cociente entre la suma de las intensidades (niveles de gris) de todos los píxeles perteneciente al objeto dividida por el área del mismo.

$$D = \frac{\sum_{n=1}^N \sum_{m=1}^M I_{m,n}}{Area} \quad (1)$$

La densidad superficial promedio representativa de cada clase de hoja, con su error porcentual está indicada abajo. Como puede comprobarse puede ser empleada como un descriptor aún cuando en dos casos el rango de variación está superpuesto.

$$AREA = \begin{pmatrix} 54.8 & 181.8 & 96.7 & 70.5 & 61 & 84.4 & 68.3 & 68 \\ 8.4 & 4.8 & 33.3 & 2.1 & 2.9 & 5.1 & 4.7 & 33.7 \end{pmatrix}$$

## 4.- Construcción de la base de conocimiento de las hojas

### 4.1.- Base de datos

Con los valores y rangos de variación de los descriptores se construyó la base de datos. Por lo tanto de una clase de hoja, en particular, se tiene

- Área promedio ± error %
- Perímetro promedio ± error %
- Circularidad promedio ± error %
- Densidad promedio ± error %
- Firma promedio
- Histograma promedio

### 4.2. Enunciado de las Reglas

Las reglas que se proponen para la construcción de la base de conocimiento son:

#### Regla 1: Verificación de la firma

A partir del vector firma de un objeto desconocido y de la matriz construida con las firmas promedio de las clases de hojas, se efectúa la correlación. El resultado es un vector de coeficientes de correlación. De este vector se selecciona el valor máximo y se elige el 98% del mismo como valor límite. Aquellos coeficientes que se hallan por encima de este valor se los identifica por su posición en el vector. Esta/s posición/es en el vector indicará el o los candidatos al cuál corresponde la firma con la que la firma del objeto desconocido tuvo mayor coeficiente de correlación.

#### Regla 2: Verificación el área

*Si el candidato con área igual a a cumple con  $(A - \Delta A)_i \leq a \leq (A + \Delta A)_i$  entonces es elegido.*

El subíndice i recorre las áreas promedios A con su intervalo de error  $\Delta A$  de todas las clases de hojas.

#### Regla 3: Verificación el perímetro

*Si el candidato con perímetro igual a p cumple con  $(P - \Delta P)_i \leq p \leq (P + \Delta P)_i$  entonces es elegido*

El subíndice i recorre los perímetros promedios P con su intervalo de error  $\Delta P$  de todas las clases de hojas.

#### Regla 4: Verificación la circularidad

*Si el candidato con circularidad igual a c cumple con  $(C - \Delta C)_i \leq c \leq (C + \Delta C)_i$  entonces es elegido*

El subíndice i recorre las circularidades promedios C. con su intervalo de error  $\Delta C$  de todas las clases de hojas.

#### Regla 5: Combinación de las reglas 2, 3 y 4

*Si el candidato está presente en la conclusión de al menos dos de las reglas 2, 3 y 4 entonces es elegido*

#### Regla 6: Combinación de las reglas 1 y 5

Recordemos que la conclusión de la regla 1 - verificación de la firma, puede contener al menos un candidato para su identificación y lo mismo puede ocurrir con la regla 5, por lo tanto, en la combinación de las mismas se busca que:

1. Esté presente el mismo candidato en las combinaciones de ambas reglas para ser elegido.
2. Esté presente un único candidato en las conclusiones de la regla 1 y no en las de la regla 5 para ser elegido y además informar del coeficiente de correlación y la falta de cumplimiento de la regla 5.

**Regla 7:** Verificación de la densidad superficial  
 Si el candidato con densidad superficial igual a  $d$  cumple con  $(D - \Delta D)_i \leq d \leq (D + \Delta D)_i$  entonces es elegido

El subíndice  $i$  recorre las densidades promedios  $D$ , con su intervalo de error  $\Delta D$ , de todas las clases de hojas consideradas.

**Regla 8:** Verificación del histograma  
 Se efectúa la correlación a partir del histograma del objeto desconocido, y de la matriz construida con todos los histogramas con los niveles de gris reducidos a [10,160] representativos de todas las clases de hojas.

El resultado es un vector de coeficientes de correlación. De este vector se selecciona la posición en el vector de aquellos coeficientes cuyo valor está por encima del 98%. Esta/s posición/es en el vector indicarán el o los candidatos a los cuáles corresponden los histogramas con los que el histograma del objeto desconocido tuvo mayores coeficientes de correlación.

**Regla 9:** Combinación de las reglas 7 y 8  
 Recordemos que la conclusión de la regla 8 - verificación del histograma, puede contener al menos un candidato para su identificación y lo mismo puede ocurrir con la regla 7, por lo tanto, en la combinación de las mismas se busca que:

1. Esté presente el mismo candidato en ambas reglas para ser elegido.
2. Esté presente un único candidato en las conclusiones de la regla 8 y no en las de la regla 7 para ser elegido y además informar del coeficiente de correlación y la falta de cumplimiento de la regla 7.

**Regla 10:** Combinación de las reglas 6 y 9  
 En la combinación de las reglas 6 y 9 se busca que:

1. Esté presente el mismo candidato en las conclusiones de ambas reglas para ser elegido.
2. Se elige el candidato que en ambas reglas tenga mayor coeficiente de correlación. En

el caso de que los candidatos tengan igual coeficiente de correlación se elige a ambos.

### 4.3.- Encadenamiento de las Reglas

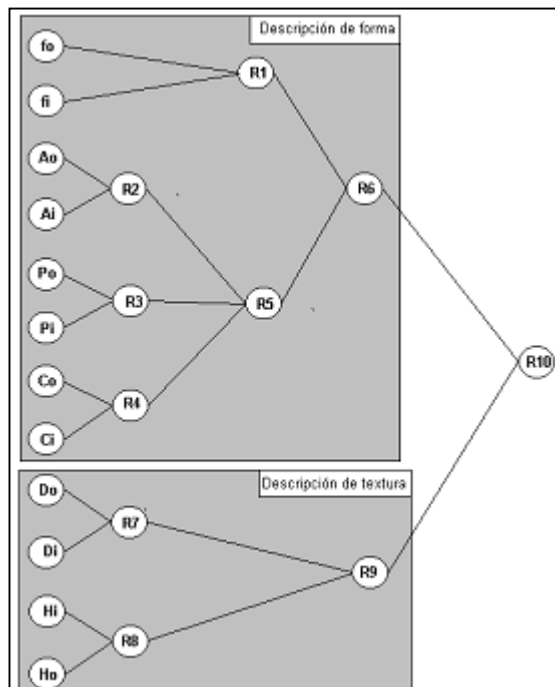


Figura 6. Encadenamiento de las reglas

En la figura 6 se muestra el encadenamiento de las reglas. Los nodos del primer nivel con letras en su interior tienen valores conocidos, los correspondientes al subíndice  $i$  se refieren al objeto bajo estudio y los que tienen subíndice  $i$  con  $i$  variando de 1 a 8 corresponden a los objetos tomados como referencia. Las reglas están presentadas en cuatro niveles de acuerdo a sus propios pesos. La regla 1 verifica la firma del objeto y hace una comparación entre vectores como conjunto, mientras que las reglas 2..4 analizan si un número pertenece o no a un intervalo. Las reglas 7 y 8 están referidas a la textura del objeto. La primera verifica si un número pertenece o no al intervalo y la otra compara vectores como conjunto se le da más peso a esta. Finalmente las reglas 6 (referida a la forma del objeto) y 9 (referida a la textura del objeto) se combinan en la 10 para alcanzar la conclusión final.

### 5. Resultado de la aplicación

A continuación se transcriben los resultados de aplicaciones concretas. En el programa se ingresa los datos del objeto bajo estudio

1. Imagen del objeto
2. Imagen del contorno del objeto

3. Firma del objeto en forma de archivo de texto con estructura ( un vector columna).
4. Histograma del objeto en forma de archivo de texto con estructura ( un vector columna)
5. La base de datos de los objetos de referencia que consiste en los siguientes archivos:
  - Área
  - Perímetro
  - Circularidad
  - Firma
  - Densidad superficial
  - Histograma
6. Se explicitan las reglas
7. Con los valores de los descriptores del objeto bajo estudio de determinan, los parámetros que faltan
8. Se aplican las reglas a casos concretos

**EJEMPLO 1: Ejemplar hoja clase 1**

**INGRESO DE DATOS**

Imagen del objeto I2 = READBMP("H11.BMP")  
 Imagen del contorno del objeto I1 = READBMP("h11-0.BMP")  
 Lectura de la firma f1 = READFRN("H11.FRN")  
 Lectura del histograma h1 = READFRN("hist-H11.FRN")

**Cálculo de los valores de los descriptores**

p1 = Perimetro(I1,255)    a1 = AREA(I2,0)    c1 =  $\frac{p1^2}{4 \cdot \pi \cdot a1}$     d1 = den(I2,0)

**APLICACIÓN DE LAS REGLAS**

R1(f1,0.98,0.6) = (1 0.987)  
 R2(A,a1)<sup>T</sup> = (0 0 0 4 0 0 0 8)  
 R3(P,p1)<sup>T</sup> = (0 0 0 4 0 0 0 8)    R4(C,c1)<sup>T</sup> = (1 0 0 4 0 6 0 8)  
 R5(p1,a1,c1) = 4    R6(f1,a1,c1)<sup>T</sup> = (1 0.987)  
 R7(D,d1)<sup>T</sup> = (1 0 0 0 0 0 0 8)    R8(h1,d1) =  $\begin{pmatrix} 1 & 0.963 \\ 2 & 0.966 \end{pmatrix}$   
 R9(h1,d1) =  $\begin{pmatrix} 0 & 2 \\ 0 & 0.966 \end{pmatrix}$   
 R10(f1,h1,p1,a1,c1,d1) =  $\begin{pmatrix} 1 \\ 0.987 \end{pmatrix}$

En el ejemplo 1, la regla 1 concluye que el candidato pertenece a la clase 1, con una correlación de 0.987. Las reglas 2, 3 y 4 no pueden discriminar correctamente, por lo tanto, la regla 5 dada como resultado una clase incorrecta. Con la regla 6 que combina la 1 y 5 se corrige el error. Hasta aquí, se analizaron los descriptores de forma. La regla 7 da dos posibles clases para el candidato, lo mismo que la regla 8, cuando se combinan a través de la regla 9 queda la clase seleccionada con la que el candidato tiene mayor correlación. Finalmente en la regla 10 se comparan, las conclusiones de las reglas 6 y 9 seleccionando la clase con la que el candidato tiene mayor correlación: Reconoce al candidato como perteneciente a la clase 1. Este resultado es correcto.

En el ejemplo 2, la Regla 1 concluye con tres clases para el candidato, mientras que las reglas 2, 3 y 4 tienen presente la clase 8, conclusión a la que llega la regla 5. En la comparación de los resultados de las reglas 1 y 5, la regla 6 concluye seleccionando la clase 7. Al mismo resultado llega la regla 9. La regla

10 concluye entonces que el candidato pertenece a la clase 7 lo cual es correcto.

**EJEMPLO 2: Ejemplar hoja clase 7**

**INGRESO DE DATOS**

Imagen del objeto I2 = READBMP("H77.BMP")  
 Imagen del contorno del objeto I1 = READBMP("h77-0.BMP")  
 Lectura de la firma f1 = READFRN("H77.FRN")  
 Lectura del histograma h1 = READFRN("hist-H77.FRN")

**Cálculo de los valores de los descriptores**

p1 = Perimetro(I1,255)    a1 = AREA(I2,0)    c1 =  $\frac{p1^2}{4 \cdot \pi \cdot a1}$     d1 = den(I2,0)

**APLICACIÓN DE LAS REGLAS**

R1(f1,0.98,0.6) =  $\begin{pmatrix} 3 & 0.979 \\ 6 & 0.992 \\ 7 & 0.993 \end{pmatrix}$   
 R2(A,a1)<sup>T</sup> = (0 0 0 0 0 0 0 8)  
 R3(P,p1)<sup>T</sup> = (0 0 0 4 0 0 0 8)    R4(C,c1)<sup>T</sup> = (0 0 0 4 0 6 0 8)  
 R5(p1,a1,c1) = 8    R6(f1,p1,a1,c1)<sup>T</sup> =  $\begin{pmatrix} 0 & 0 \\ 0 & 0 \\ 0 & 0 \\ 7 & 0.993 \end{pmatrix}$   
 R7(D,d1)<sup>T</sup> = (0 0 3 0 0 0 0 8)    R8(h1,d1) =  $\begin{pmatrix} 0 & 0 & 0 & 7 \\ 0 & 0 & 0 & 0.993 \\ 0 & 0 & 0 & 0.827 \end{pmatrix}$   
 R9(h1,d1) =  $\begin{pmatrix} 7 \\ 0.827 \end{pmatrix}$

## 6. Conclusiones

En este trabajo se desarrolló un sistema experto de reconocimiento de hojas de plantas, basado en reglas, a partir de su imagen en niveles de gris con fondo negro, obtenida bajo condiciones de iluminación de un escáner.

Los objetos considerados eran hojas de 8 (ocho) plantas distintas y los descriptores empleados fueron de dos tipos: de forma y de textura. En ambos tipos de descriptores se realizó un análisis de sus intervalos de variación para considerarlos fiables e independientes.

Todos mostraban intervalos de variación lo bastante amplios como para impedir la discriminación entre las clases constituyéndose de esta forma en pocos fiables individualmente.

Los descriptores que se consideraron fueron perímetro, área, circularidad y firma, que combinados daban información de la forma. El histograma en sí mismo lo hacía respecto de la textura, mientras que el descriptor densidad superficial combinaba forma y textura.

Del análisis de los rangos de variación surgió la información para construir la base de datos. Debido a las características de los objetos bajo estudio fue necesario para cada descriptor y cada clase de hoja encontrar un valor representativo y el error porcentual del mismo, con excepción de la firma y del histograma que, en estos casos, por tratarse de vectores, se debió recurrir al cálculo de coeficientes de correlación en vez de intervalo de variación.

Fue necesario enunciar diez reglas, que encadenadas en forma apropiada permitieron alcanzar el objetivo de establecer correctamente la clase de hoja a la que pertenecía un candidato. Esto quedó verificado a través de las aplicaciones a casos concretos.

Lo significativo de todo este proceso, es que se validó una metodología modular incorporando y desagregando descriptores y mejorando la

performance del conjunto. Además se dispone ahora de la implementación de los otros descriptores que, aunque para este caso no fueron apropiados, podrán serlo para otros.

El desarrollo modular presentado de esta forma, admite el crecimiento en dos aspectos: el intercambio de la base de datos de manera de poder aplicarse a otras áreas y la incorporación de nuevos descriptores y por supuesto, nuevas reglas haciendo que, en general, se incremente la base de conocimiento.

## Referencias

- [1] Castillo, Enrique Gutiérrez, J. y Hadi, A. Sistemas expertos y modelos de redes probabilísticas. Monografía de la Academia de Ingeniería. Madrid
- [2] Castleman Kennteh R. Digital image processing. Ed Prentice Hall (1996).
- [3] González Rafael C. y Woods E. Richard Tratamiento Digital de Imágenes. Addison-Wesley / Diaz de Santos (1996).
- [4] Haykin Simon. Neural Networks. Second Edition. Ed Prentice Hall (1999)
- [5] Kohonen T. Self- Organizing Maps. Springer, Berlin. (1997)
- [6] Parker, J.R Practical Computer Vision using C - Ed. John Willey & Sons (1994).
- [7] Schalkoff, Robert J. Digital image processing and computer vision - Ed. John Willey & Sons (1989).
- [8] Symon Keith R. *Mecánica* Ed. Aguilar 1977
- [9] Visauta Vinacua B Análisis estadístico con SPSS para Windows Volumen II Estadística multivariante McGraw Hill / Interamericana de España, S. A. (1998)
- [10] Ya-Lun Chou Análisis Estadístico Nueva Editorial Interamericana S.A. (1972)
- [11] Cortijo Bon Francisco J Visión artificial. <http://wwwetsi2.ugr.es/depar/ccia/robotica/indice.apuntes.html>.
- [12] Software and Hardware for Patten Recognition and Image Processing Research <http://www.ph.tn.tudelft.nl/PRInfo/software.html>
- [13] Bravo, V. Antonio J. Procesamiento Digital de Imágenes <http://www.ing.ula.ve/~abravo/document/tutorial/imágenes/indice.html#c110>
- [14] Molina, R. Introducción al Procesamiento y

## Análisis de Imágenes Digitales

[http://www.etsi2.ugr.es/depar/ccia/mia/complemento/Procesamiento Imágenes](http://www.etsi2.ugr.es/depar/ccia/mia/complemento/Procesamiento%20Imágenes)

[15] Serradilla García F., Castilla Angel Arroyo y Casado Javier Alcalá Curso de Visión artificial.

<http://www.sia.eui.upm.es/docent/vision.pdf>

[16] Muracciole, J Manual de Biofísica Loez Libreros Editores SRL Bs As (1965)

## Anexo 1: Secuencia de cálculo de la firma de un objeto

En este trabajo la firma de un objeto, es decir, la representación de su contorno fue obtenida empleando la siguiente secuencia:

1. Imagen en niveles de gris del objeto aislado con fondo negro.
2. Se hace la detección de bordes mediante el gradiente de Roberts, se debe reescalar y umbralizar
3. Se adelgaza el contorno ( thinning)
4. Se determinan los momentos de inercia del contorno y las coordenadas del centro
5. Se determinan los momentos normalizados centrales de inercia y el ángulo que forma el eje principal con el eje horizontal.

Momento central de inercia

$$\mu_{k,l} = \frac{\sum_i \sum_j I_{i,j} \cdot (i - x_c)^k (j - y_c)^l}{M_{0,0}}$$

Ángulo

$$\tan(2\alpha) = \frac{2\mu_{1,1}}{\mu_{2,0} - \mu_{0,2}}$$

6. La ambigüedad de 90° se puede resolver especificando que  $\mu_{20} \neq \mu_{02}$  y  $\mu_{30} > 0$
7. Si el ángulo  $|\alpha| \leq 0.5^\circ$  no se realiza ninguna modificación, de otra manera se rota el contorno hasta que su eje principal cumpla la condición citada.
8. A partir de las coordenadas i, j de cada pixel k del contorno se determinan las coordenadas polares  $R_k$  y  $\theta_k$  de los mismos.