

Visión por Computador y Clasificación aplicado a la Micología

Ramón Moreno(ramon.moreno.jimenez@gmail.com)

September 26, 2007

Resumen

La evolución que vive la telefonía móvil, está abriendo un nuevo abanico de oportunidades para nuevas aplicaciones y herramientas. Los nuevos protocolos y nuevos canales de comunicación están rompiendo las limitaciones relacionadas con el ancho de banda. GPRS, UMTS, WiFi, 3G hacen que se pueda acceder a nuevos servicios y aplicaciones desde lugares remotos. El trabajo que se expone se enmarca dentro de los sistemas de información móviles y presenta un prototipo de sistema experto de acceso remoto aplicado a la micología. El objetivo es proporcionar una herramienta de ayuda micológica a los neófitos, con la que poder predecir a qué especie pertenece. Se presenta un esbozo del sistema de información y se profundiza en el sistema de extracción de características. Presentamos un nuevo contorno activo y discutimos los resultados obtenidos por distintos clasificadores

Keywords: Micología, Procesamiento de imágenes, Clasificación supervisada, Contornos activos.

1. Introducción

Las técnicas de visión por computador han experimentado una importante evolución en los últimos años. Un área de interés es el reconocimiento de figuras en una escena, es conocido como CBIR. El típico problema CBIR es dado un conjunto de imágenes poder hacer una clasificación y poder estimar cuales son las más próximas según algún criterio.

En nuestro caso, las imágenes con las que trabajamos, contienen setas cuyas especies ya conocemos, por lo que podemos experimentar con clasificación supervisada. La micología es la ciencia que estudia los hongos[1, 2, 3, 4, 5].

Las setas poseen diversos rasgos distintivos que pueden ayudar al consumidor a diferenciarlas entre sí: la forma del sombrero, la textura, detalles de la corteza, color y brillo, etc. Estos rasgos se combinan en ciertas reglas de análisis de la morfología de la seta que permiten identificarla y decidir sobre su

comestibilidad. Existen otro conjunto de características no susceptibles de ser detectadas visualmente como olor, habitat, sabor y dureza.

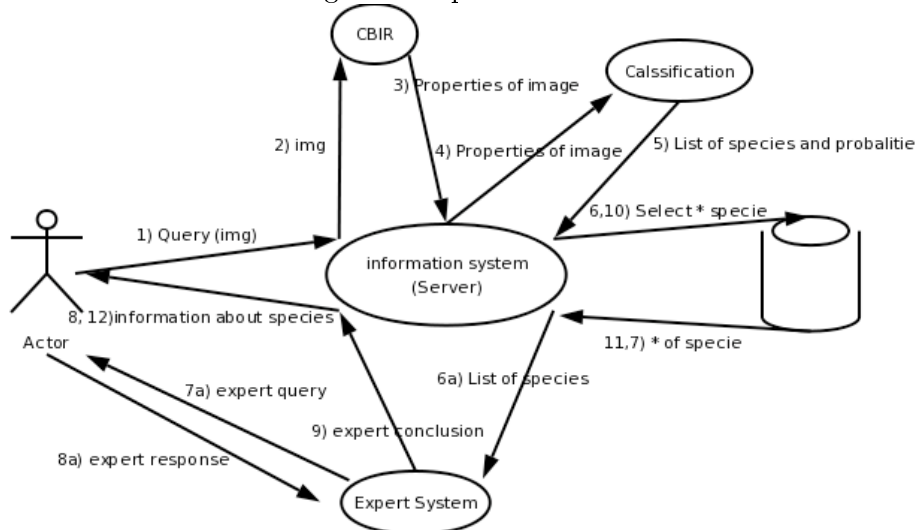
El conjunto de características son más de 70, pero necesitamos al menos conocer 30 para poder realizar una identificación correcta. Un problema añadido es que el usuario puede no ser capaz de responder con precisión a las preguntas que se hacen, por ejemplo determinar el color, definir su olor o sencillamente que su desconocimiento micológico le impida comprender la pregunta.

Aplicando técnicas de visión por computador (CBIR) hemos conseguido extraer 28 datos precisos. Con los datos extraídos, hemos experimentado con varios clasificadores (K*, RIPPER, C4.5 y Naive Bayes). Los resultados obtenidos por el clasificador en algunos casos no son suficientes para determinar a qué especie pertenece la figura de la imagen, en unos casos porque la probabilidad asociada a una especie predicha no supera un umbral de confianza y en otros casos porque existen varias especies con similar probabilidad de predicción.

2. Sistema de información

El siguiente esquema muestra los principales componentes del sistema de información

Figura 1: Esquema software




1. El usuario captura la imagen la transmite como pregunta
2. EL módulo CBIR extrae características de las figuras contenidas en la imagen

3. Estas características son enviadas al clasificador, el cual devuelve una lista con las n especies más parecidas junto a sus respectivas probabilidades
4. En el caso de que no existan ambigüedades, extraemos los datos de la DB y se los enviamos al usuario
5. En el caso de existir ambigüedades, el sistema experto interactúa con el usuario con preguntas discriminantes hasta que rompa la ambigüedad
6. Extraemos los datos de la DB y se los enviamos al usuario

3. Técnicas de visión por computador para la extracción de características

Para la extracción de características, recurrimos a los clásicos procesos binarios [6], en busca de componentes conectadas. De este modo localizamos las figuras de interés. Buscamos las mayores componentes conectadas. Una vez localizadas extraemos algunas de sus características: altura, anchura, área, de la seta en su conjunto y también del sombrero y del pie por separado. También analizamos la existencia de accidentes; anillo, volva o mamelón. Sin olvidarnos de extraer el color de la cutícula, carnes y pie. La siguiente figura muestra los datos de interés extraídos.

Figura 2: Datos de interés extraídos



El proceso general consta de los siguientes pasos:

1. Extracción del contorno de la seta. El número de puntos constituyentes del contorno puede ser variable. Para reducirlo a una dimensión fija se seleccionan los puntos más significativos del contorno. Estos puntos se

escogen como aquellos con la mayor magnitud de la segunda derivada, esto es, los puntos de mayor curvatura. De esta manera obtenemos una representación de tamaño constante que permite aplicar algoritmos analíticos. La representación del contorno se realiza mediante una función 1D dada por las distancias de cada punto al centro del componente conectado que representa la seta. Esta función es la signatura del contorno y puede interpretarse como un vector de alta dimensión en el contexto de reconocimiento estadístico de patrones.

2. Extracción de características: se trata de un proceso de reducción de la dimensión del vector que representa cada contorno. Se pueden utilizar diversas aproximaciones lineales, PCA, ICA, etc. Nosotros hemos utilizado una representación que consiste en las coordenadas convexas relativas a un conjunto de endmembers obtenidos mediante un algoritmo que usa redes morfológicas autoasociativas, lo denotamos AMM por brevedad.
3. Algoritmos de clasificación; dada la base de datos experimental se construye un clasificador y se valida su precisión. Los clasificadores probados son los proporcionados por WEKA, lo que evita su implementación, garantiza la calidad de la implementación y permite probar algoritmos que están en el estado del arte.

En primer lugar presentamos un algoritmo de contornos activos (snake) que mejora la calidad de los contornos extraídos de las imágenes, frente a algoritmos sencillos de binarización y extracción de la frontera de los componentes conectados. Como ya se ha mencionado, el algoritmo de extracción de la signatura del contorno se queda con los puntos de mayor segunda derivada. Los algoritmos basados en la binarización y cálculo de las fronteras de los objetos en la imagen binaria producían en general algunos contornos con detalles debidos a las peculiaridades de la intensidad de la seta. El algoritmo de contornos activos produce en general contorno suaves que disminuyen los problemas en la correcta representación del contorno. El algoritmo de contornos activos propuesto tiene algunas mejoras respecto a los encontrados en la literatura.

Por último realizamos una descripción somera del método de extracción de características que denominamos AMM, basado en las redes morfológicas autoasociativas.

Después se exponen dos maneras de atacar el problema, una basándonos únicamente en el proceso de reconocimiento basado en el contorno de la seta y otra utilizando diversas características micológicas no necesariamente obtenidas a partir de la imagen. A la primera la hemos llamado perspectiva morfológica y a la segunda perspectiva micológica.

En este apartado comentaremos los algoritmos que hemos usado, así como los que hemos creado para la extracción de las características.

3.1. Snake

En los experimentos se usó una adaptación de los contornos activos calculados usando algoritmos voraces clásicos. Los contornos activos producen contornos suavizados y que presentan menos dificultades en el proceso de extracción de características y clasificación, evitando que se seleccionen puntos no representativos de la forma real de la seta debido a un proceso defectuoso de cálculo del contorno.

3.1.1. Contornos activos, justificación

Entendemos como contorno activo, también llamado Snake, la sucesión de puntos que representan una curva cerrada, la cual tiene que acabar abrazando la figura de interés en un proceso dinámico en el que la snake se deforma siguiendo un proceso de minimización de una cierta función de energía que depende del gradiente de la imagen y de las tensiones internas de la snake, que actúan como factores de regularización o suavización.

La ventaja de usar contornos activos en nuestro caso, radica en que podemos controlar la suavidad del contorno calculado. Si por ejemplo quisiéramos encontrar el contorno de un tenedor, con el snake podemos camuflar los dientes. Ese es el efecto que buscamos.

La desventaja tradicional de las snakes es su sensibilidad a la configuración inicial y la necesidad de que ésta sea especificada manualmente. En el caso que nos ocupa, el snake inicial se sitúa entorno al objeto de interés en un fondo oscuro/negro bastante homogéneo. La inicialización es, por tanto, trivial y el condicionamiento al estado inicial no existe, sobre todo en nuestra versión en la que utilizamos la energía potencial. Esta energía potencial sirve para evitar que se estanquen los contornos especificados lejos del contorno real debido a la ausencia de gradiente en el fondo homogéneo.

3.1.2. Función de Energía

La idea clave del contorno deformable, consiste en asignar una función de energía a cada configuración de los puntos del contorno. Consideramos el contorno $c = c(s)$ parametrizado por su longitud de arco s .

En el caso particular de nuestro Snake, hemos usado la siguiente función de energía a minimizar:

$$E = \int (\alpha(s)E_{cont} + \beta(s)E_{curv} + \gamma(s)E_{img} + \delta(s)E_{pot})ds$$

En la cual las dos primeras componentes representan la energía interna del snake, y las dos últimas la energía externa del mismo. Donde alfa, beta, gamma y delta son los respectivos multiplicadores, con los que podemos controlar la influencia de cada término de la función.

3.1.3. Energía Interna

Continuidad

E_{cont} se refiere a la continuidad del contorno que está siendo estimado, con este término controlamos lo que se pueden separar los puntos del snake. En nuestro caso, (discreto de N puntos) lo calculamos de la siguiente manera:

$$E_{cont_i} = (\bar{d} - \|p_i - p_{i-1}\|)^2$$

Donde p_i y p_{i-1} representan un punto y su precedente y \bar{d} la distancia media.

Suavidad

E_{curv} se refiere a la curvatura del snake. Este se aproxima muy bien por la segunda derivada, que en nuestro caso discreto, la aproximamos de la siguiente manera:

$$E_{curv_i} = \|p_{i-1} - 2p_i + p_{i+1}\|^2$$

3.1.4. Energía Externa

Este término corresponde a la energía asociada a la fuerza de atracción del contorno deformable hacia el contorno deseado (en nuestro caso la frontera de la seta). Puesto que los contornos son lugares de alto gradiente en la imagen, esta energía externa está modelada mediante el gradiente de la imagen .

$$E_{img} = -\|\nabla I\|^2$$

Energía pseudo-potencial

Además del anterior término de atracción a los píxeles del borde, hacemos uso de una energía pseudo-potencial de la imagen. Esto evita que puntos muy alejados del objeto de interés en la configuración inicial se queden estancados en posiciones lejanas al autentico contorno del objeto dado que la función E (sin E_{pot}) no varía apenas en regiones con gradiente muy pequeño.

Esta función es como sigue:

$$E_{Pot_i} = K * \sum_{\substack{j \neq i \\ j \in \text{mxn}}} \frac{Q_j}{d_j}$$

Donde Q_j es la carga del punto j (que corresponde a su nivel de iluminación). Observemos que aplicamos la definición de potencial eléctrico, salvo que en nuestro caso la constante K es -1 .

3.1.5. Observaciones

Entendemos como Snake, la sucesión de n puntos que representan una curva cerrada, la cual tiene que acabar abrazando la figura que buscamos tras un proceso de adaptación que minimiza la función de energía. Por cada iteración del proceso de minimización, es conveniente calcular la distancia media entre los puntos \bar{d} y reconstruir el Snake situando todos los puntos a la misma distancia \bar{d} . De esta manera evitamos que unos puntos queden concentrados en una parte del contorno activo quedando en otra más separados. Este truco es clave para conseguir que el snake se adapta a concavidades.

3.1.6. Gradiente

El gradiente de una imagen bidimensional es:

$$G[f(x, y)] = \begin{bmatrix} Gx \\ Gy \end{bmatrix} = \begin{bmatrix} \frac{\partial}{\partial x} f(x, y) \\ \frac{\partial}{\partial y} f(x, y) \end{bmatrix}$$

En la práctica lo que nos interesa es la magnitud gradiente en valores absolutos, por lo que tenemos:

$$|G| = |Gx| + |Gy|$$

3.1.7. Gradiente utilizando las máscaras de Sobel

El cálculo del gradiente de la imagen se puede realizar de múltiples maneras, una de ellas, muy habitual en los sistemas de visión por computador, es mediante la convolución con los operadores de Sobel.

$$\begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix}$$

Lo que se traduce en el siguiente cálculo para cada pixel, considerando los Z_i como la codificación de los píxeles vecinos a cada pixel numerados siguiendo las agujas del reloj

$$Gx = (Z_3 + 2Z_6 + Z_9) - (Z_1 + 2Z_4 + Z_7)$$

$$Gy = (Z_7 + 2Z_8 + Z_9) - (Z_1 + 2Z_2 + Z_3)$$

3.1.8. Gradiente Morfológico

Existe otra manera de calcular el gradiente de la imagen de una manera muy distinta. Para ello haremos uso de los operadores morfológicos dilatación \oplus y erosión \otimes .

Se define como gradiente morfológico:

$$G = (I \oplus M) - (I \otimes M)$$

Donde I es la imagen a tratar y M una máscara, que en nuestro caso es una matriz de unos

$$M = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}$$

Comparación del Gradiente Morfológico y el de Sobel

Los experimentos realizados han dado mejores resultados con el gradiente calculando usando las máscaras de convolución de Sobel que con los operadores morfológicos. Encontramos que la aproximación lineal de Sobel potencia mucho más los bordes. Véanse los ejemplos en la figura 2.

Figure 3: Sobel Vs Morfológico



La primera figura es la imagen original (Amanita Muscaria) la segunda muestra el gradiente calculado usando las máscaras de Sobel y la tercera el gradiente morfológico. Como se puede apreciar el mejor resultado lo da la aproximación de Sobel. Además en setas de colores más pálidos (Suillus Luteus, Chantarellus Cibarius...) hemos encontrado que los resultados del gradiente morfológico empeoran bastante.

3.1.9. Suciedad en Imágenes

Dado que el experimento lo hemos realizado con imágenes en entornos naturales (en los que el control sobre el fondo de la escena en la que se sitúa el objeto se reduce a colocar un paño negro, pero donde no se puede controlar exhaustivamente la aparición de brillos o sombras espúreas), es conveniente hacer una limpieza, quitar todas las suciedades del fondo. Esto es necesario, para evitar que el snake se quede atrapado en una mota de brillo o en una sombra (donde el gradiente tendrá un gran valor). Esto lo hacemos sobre la imagen binaria y

posteriormente utilizamos la imagen binaria limpia como máscara en una imagen de grises para seleccionar el objeto de interés (la seta) y anular el resto de la imagen (el fondo).

Para realizar la limpieza recurrimos otra vez a operadores morfológicos, en este caso la apertura ($I \circ M$) sobre la imagen binaria, para posteriormente etiquetar los componentes conectados de la imagen y borrar los pequeños.

3.1.10. Algoritmo

Algorithm 1 GlotonB

1. Inicializar un snake con N puntos en el exterior del objeto de interés. Estos puntos se colocan en una posición entera correspondiente a un píxel. No pueden ocupar una posición con coordenadas reales (lo que corresponde a una fracción de píxel).
2. Inicializar los parámetros alfa, beta, gamma y delta
3. Calcular la matriz gradiente
4. Calcular la matriz de energía pseudo-potencial
5. Mientras el 99% del los puntos no estén en Mem^a
 - Para cada punto del snake
 - Buscar la posición de píxel vecino con menor valor de la función de energía E . La búsqueda es local y exhaustiva. Se calcula la función de energía para cada perturbación del punto del snake, recorriendo todas las posibilidades en un 8-vecindario.
 - Si se ha encontrado que la nueva posición proporciona un valor de la energía menor que el actual cambiar de posición el punto del snake.
 - fin para
 - Calcular la distancia media entre los puntos del snake (\bar{d})
 - Reconstruir el Snake situando todos los punto a distancia \bar{d} entre ellos.
 - Guardar posiciones actuales en Mem
- fin mientras

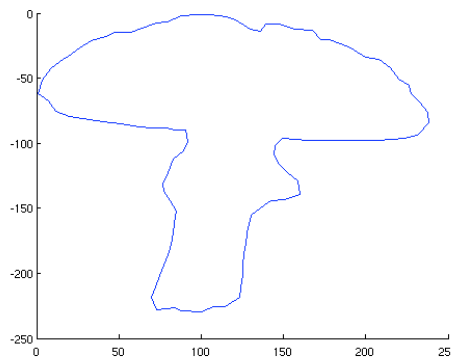
^a Memoria donde guardamos las p últimas iteraciones.

El algoritmo es fundamentalmente una implementación del “*greedy algorithm*” al que le hemos añadido la energía pseudo-potencial para evitar la inanición del proceso de adaptación en puntos muy alejados del contorno actual

del objeto, y el reajuste de Snake entre iteraciones situando los puntos a una distancia \bar{d} , dando así al algoritmo mayor adaptabilidad a las concavidades.

El algoritmo es local en el sentido de que no garantiza que se alcanzará el valor mínimo global de la función de energía. Es local también en el sentido de que cada punto del contorno se modifica sin tener en cuenta a los demás puntos del snake, y por último, en el sentido de que las posibles adaptaciones de los puntos en el snake son el conjunto de los 8-vecinos.

Figure 4: Resultado de GlotonB



3.1.11. Comportamiento

Hemos aplicado el algoritmo a todas las imágenes capturadas que conforman la base de datos experimental. No hemos realizado una evaluación cuantitativa de los resultados por que no tenemos un criterio ideal para la definición del contorno. Incluso la definición interactiva manual puede ser menos útil que otras técnicas desde el punto de vista de los resultados de clasificación que nos interesan finalmente. Por ello la evaluación ha sido cualitativa observando los resultados visualmente.

En la gran parte de las imágenes el resultado obtenido ha sido óptimo en el sentido de que no se aprecia visualmente desviaciones significativas respecto del contorno del objeto, sin embargo en algunos casos el Snake ha invadido el interior de la seta, dando como resultado un contorno incorrecto. Esto ha ocurrido en las setas de pie alargado y oscuro (*Pholliota Radicosa*, *Suillus Luteus*...).

Como contrapartida, el Snake tiene la virtud de producir contornos muy suavizados, dando resultados espectaculares en imágenes borrosas.

3.1.12. Discusión de las referencias

En el libro de visión por computador [6] se hace una descripción del “*greedy algorithm*” aunque no completa, además en el CD adjunto no viene el código,

por lo que deja varias incógnitas en el aire.

Un tipo de contornos activos que esta dando que hablar los últimos años es Gradient Vector Flow [7] y sus derivados [8]. Lo mejor es que Chenyang Xu y L.Price han publicado el código MathLab en la red. Por lo que utilizado este algoritmo con las imágenes y desgraciadamente el resultado ha sido pésimo. También lo hemos intentado usando mapas de gradiente morfológico en lugar de los obtenidos mediante la aproximación de Sobel pero la mejoría ha sido muy escasa. Sin embargo, nos ha sido muy clarificador ver un código de snake que funciona (aunque sea mal) para poder desarrollar las alternativas que finalmente han sido de utilidad, Por ejemplo, nos ha resultado interesante estudiar cómo hacen la interpolación lineal del snake.

Finalmente, Andrew Blake and Michael Isard tienen un libro colgado en Internet que habla sobre los contornos activos. La referencia es <http://www.robots.ox.ac.uk/~contours/>

3.2. AMM

De igual forma que el anterior algoritmo, no se pretende dar una descripción detallada de este. La descripción completa se encuentra en [?]. Para una mayor comprensión de las Associative Morphological Memories se recomienda la lectura de [9] que hace una descripción de las mismas comenzando desde cero. Las Autoassociative Morphological Memories son un caso particular de las anteriores.

La descripción matemática de este es compleja, la estructura algebraica con la que trabaja es $(\mathbb{R}, \vee, \wedge, +)$ en lugar de $(\mathbb{R}, +, \cdot)$. Donde \vee y \wedge son operadores de máximo y mínimo respectivamente.

En resumen, las AMM se utilizan para la detección de la condición de independencia morfológica. Un contorno (forma) n-dimensional puede ser visto como un punto en un espacio de alta dimensión. Un conjunto de formas nos da una nube de puntos en ese espacio de alta dimensión. La condición de independencia morfológica la cumplen los puntos extremos de esta nube y son los que utilizamos para definir una región convexa y para caracterizar los puntos en relación a estos puntos extremos, que denominamos endmembers, mediante las coordenadas convexas, que son las coordenadas de los puntos en la nube tomando como referencia a los endmembers. El proceso de extracción de características consiste simplemente en el cálculo de dichos endmembers a partir de la nube de datos y de las coordenadas convexas de los restantes puntos en relación a ellos.

Los puntos marcados en rojo en la figura 4 representan las formas extremas, el resto de los puntos pueden ser representados en función de estas. A la hora de pretender clasificar un nuevo contorno el proceso consiste en calcular las coordenadas convexas de este contorno y en realizar una clasificación usando el algoritmo 1-NN sobre la base de datos ya procesada y clasificada.

Figura 5: Coordenadas convexas



Una posible mejora es usar en lugar de un 1-NN usar un K-NN mayor, por ejemplo 5-NN. Esto es lo que en K* se llamaba “*esfera de influencia*”. Con este algoritmo, igual que con el anterior, lo más habitual es devolver la clase predicha más probable, no obstante podemos devolver m clases con sus probabilidades de acierto.

3.3. Perspectiva de visión por computador

Bajo la perspectiva de visión por computador, tratamos de abordar el problema basándonos únicamente en la forma de su contorno.

Para este caso, hallamos el contorno de la imagen con el snake, recuperando 100 puntos. Una vez que hemos hallado estos puntos, podemos atacar el reconocimiento de las formas de varias maneras.

1. Utilizando las coordenadas convexas obtenidas a partir de los endmembers obtenidos utilizando las AMM, y un clasificador 1-NN.
2. Hallando las firmas radiales desde el centroide y probar con varios clasificadores.
3. Hallando las firmas radiales desde el origen cartesiano y probar con distintos clasificadores.

Es curioso también el efecto que produce utilizar la firma radial desde el centroide en lugar del origen cartesiano. En principio supone una mejora.

3.4. Perspectiva micológica

Otra alternativa, más coherente micológicamente, consiste en realizar una extracción de características propias de las setas. Para nuestros experimentos se han realizado la extracción de las siguientes:

1. Altura total
2. Anchura total

Cuadro 1: Resultado de experimentos morfológicos

#Clases	#Extrema	AMM	ICA	CCA
32	16	0.3557	0.0772	0.2852
32	15	0.3356	0.0872	0.1913
32	14	0.2987	0.0369	0.2114
15	12	0.4772	0.1066	0.3706
15	11	0.4365	0.0761	0.4112
15	10	0.3957	0.1015	0.2386
10	8	0.5319	0.1489	0.4326
10	7	0.5177	0.1384	0.4894
10	6	0.4823	0.1844	0.4823
5	9	0.7512	0.1375	0.7125
5	8	0.7625	0.2250	0.7750
5	7	0.7375	0.1875	0.6625
3	5	0.9333	0.4889	0.8889
3	4	0.9556	0.5556	0.7111
3	3	0.9333	0.4889	0.8000

Cuadro 2: Signatura radial desde el origen cartesiano

Especies	K*	Naive Bayes	C4.5	RIPPER
32	0.4293	0.2147	0.2953	0.2013
15	0.5482	0.3248	0.4619	0.2842
10	0.6453	0.3971	0.5391	0.4397
5	0.8752	0.5527	0.6625	0.6625
3	0.9111	0.8001	0.8889	0.8844

3. Área total (dato que no figura en libros micológicos pero se intuye su valor para un clasificador entrópico¹)
4. Altura del sombrero
5. Anchura del sombrero
6. Área del sombrero
7. Existencia o no del mamelón²
8. Color de la cutícula
9. Color de la carne del sombrero
10. Altura del pie

¹Se entiende por entropía de una variable, la cantidad de información que esta aporta a un clasificador, digamos que es una medida de la importancia de la misma

²Bulto más o menos atenuado en el centro del sombrero

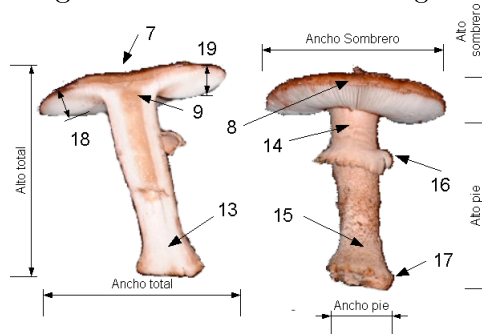
Cuadro 3: Signatura radial desde el centroide

Especies	K*	Naive Bayes	C4.5	RIPPER
32	0.5838	0.3523	0.3691	0.2852
15	0.6852	0.4619	0.4822	0.4365
10	0.7163	0.5106	0.5815	0.5319
5	0.90	0.625	0.7125	0.6125
3	0.9111	0.9333	0.9555	0.9333

11. Anchura del pie
12. Área del pie
13. Color del la carne del pie
14. Color de la parte superior del pie
15. Color de la parte inferior del pie
16. Existencia o no del anillo
17. Existencia o no de la volva
18. Margen Izquierdo
19. Margen Derecho

El área de las distintas regiones lo hallamos contabilizando píxeles y obteniendo el resultado en cm^2 . Obviamente, el conjunto de características que son susceptibles de ser detectadas visualmente son muchas más, pero ello excede los objetivos de este trabajo.

Figura 6: Características morfológicas



4. Clasificación

Para la clasificación existen multitud de algoritmos, en nuestro caso hemos experimentado con RIPPER³, C4.5[?], Naive Bayes[?] y K*[10]. También hemos experimentado con AMM [11] con contornos de las figuras obtenidos con snakes. Los mejores resultados los hemos obtenido con K* y con las características extraídas por los métodos antes citados. El espacio de colores que hemos utilizado es RGB, que es el que mejores resultados nos ha dado. La siguiente tabla muestra los resultados obtenidos por los distintos clasificadores donde el espacio de color utilizado es RGB

Cuadro 4: Experimento micológico RGB

Especies	K*	Naive Bayes	C4.5	RIPPER
32	0.7201	0.6238	0.4541	0.3440
15	0.8425	0.7007	0.5590	0.44888
10	0.8988	0.8202	0.7303	0.6404
5	0.9130	0.9130	0.8474	0.7173
3	0.92	0.84	0.84	0.88

5. Descripción del sistema experto

En nuestro caso, cuando tenemos ambigüedades recurrimos al sistema experto. Entendemos por ambigüedad cuando en la respuesta del clasificador existen varias especies con similar probabilidad de ocurrencia, o cuando las probabilidades asociadas a las especies de respuesta no superan un umbral de confianza. Caso en el que no podemos predecir con certeza la especie en cuestión.

Tradicionalmente los sistemas expertos se construyen con reglas de inferencia agrupadas en distintos módulos según su contexto. En nuestro caso creamos las reglas de inferencia “ad hoc” con la información contenida en la DB. Esto es; extraemos de la DB las características no susceptibles de ser detectadas visualmente de las especies predichas por el clasificador y preguntamos al usuario, por las propiedades más discriminantes entre ellas. Por ejemplo, la mayor parte tienen diferentes hábitat preguntaremos al usuario por esta característica. Le enviamos al usuario los hábitat de las especies seleccionadas. Si en la respuesta ha seleccionado un hábitat que solo pertenece a una especie, fin. En otro caso buscamos otra característica discriminante entre las especies con el hábitat seleccionado.

³This class implements a propositional rule learner, Repeated Incremental Pruning to Produce Error Reduction (RIPPER), which was proposed by William W. Cohen as an optimized version of IREP.

Algorithm 2 Regla de inferencia

- Tabla1= (SELECT características_no_detectables_visualmente FROM especies WHERE
 - especie.name = especie1 OR
 - especie.name = especie2 OR ...
 - especie.name = especieN);
- String rowQuery;
- int max = 0;
- for i = 1 .. #rows{
 - int aux = SELECT COUNT(*) FROM (SELECT DISCTINCT rows(i).name FROM Tabla1) AS suma;
 - if (aux >max) {
 - max = aux;
 - rowQuery = rows(i).name;}}

//rowQuery contiene el atributo por el que hemos de preguntar

6. Conclusiones

Con este artículo presentamos un sistema remoto información micológica, caracterizado por la extracción de información a partir de la imagen transmitida como pregunta, lo que nos permite extraer 33 datos precisos. Cuando esta información no es suficiente, aplicamos reglas de inferencia “ad hoc” con la información contenida en la DB.

La aplicación de las técnicas de visión por computador y la búsquedas de reglas de inferencia “ad hoc” permiten obtener información compleja de forma precisa. Por lo tanto estas técnicas se muestran poderosas en la optimización y adecuación de preguntas al usuario.

Referencias

- [1] R. L. Benguria, *Mil Setas Ibericas*. Diputacion Foral de Vizcaya, 1985.
- [2] A. T. A. . B. L. Frade, *Guia de Campo de los Hongos de la Peninsula Iberica*. Celarrayn Editorial, 2005.
- [3] E. Gernweidner, *Setas Venenosas*. Ed. Everest, 1994.
- [4] E. Gernweidner, *Setas*. Ed. Everest, 1994.
- [5] F. P. Lozano, *Setas para Todos, Guia practica de identificacion*. Editorial Pirineo, 2001.
- [6] G. P. . J. M. de la Cruz, *Vision Por computador Imagenes digitales y Aplicaciones*. Ra-Ma, 2001.
- [7] C. X. . L. Prince, "Snakes, shapes and gradient vector flow," *IEEE TRANSACTIONS ON IMAGE PROCESING*, vol. 7 NO.3, 1998.
- [8] R. L. Shuhuai Luo and S. Ourselines, "A new deformable model using gradient vector flow and adaptatives ballon forces," *CSIRO Telecominications & Industrial Physics, Medial Image Group. CNR Vimera & Pembroke RD, Marsfield NSW 2122, Australia*.
- [9] P. S. Gerhard X. Ritter and J. L. D. de Leon, "Morphological associatives memories," *IEEE TRANSACTIONS ON NEURAL NETWORKS*, vol. 9 NO.2, 1998.
- [10] J. G. C. . L. E. Trigg, "K*: An instance-based learner using an entropic distance measure," *Dept. of Computer Science, University of Waikato*, 1995.
- [11] F. M. R. Grana, M. Albizuri, "Convex coordenates based lattice independent sets as pattern freatures," *Fuzzy Systems, 2006 IEEE International Conference on*, pp. 225– 230, 2006.