

## Análisis Comparativo de las técnicas utilizadas en un Sistema de Reconocimiento de Hojas de Planta

Jair Cervantes<sup>a,\*</sup>, Jesús Taltempa<sup>a</sup>, Farid García-Lamont<sup>a</sup>, José S. Ruiz Castilla<sup>a</sup>, Arturo Yee Rendon<sup>b</sup>, Laura D. Jalili<sup>a</sup>

<sup>a</sup>Posgrado e Investigación, Universidad Autónoma del Estado de México, Prolongación de Av. Zumpango s/n, Fracc. El Tejocote, Texcoco, México, 52346.

<sup>b</sup>Facultad de Ciencias de la Computación, Universidad Autónoma de Sinaloa, Culiacán, Sinaloa, México, 80013

### Resumen

El desarrollo de sistemas de identificación de hojas de plantas es un reto actual que comprende numerosas aplicaciones que van desde alimentación, medicina, industria y medio ambiente. En la literatura actual, se han propuesto varias técnicas con el objetivo de identificar plantas en diversos campos de aplicación. Sin embargo, las técnicas actuales están restringidas al reconocimiento e identificación de tipos de plantas limitados, utilizando descriptores de características específicos. En este artículo, se realiza un análisis comparativo de diversos métodos de extracción de características (texturales, cromáticas y geométricas) y clasificación sobre conjuntos de plantas muy similares y disimiles entre sí. Doce conjuntos de hojas con características de forma similares son estudiados utilizando varios clasificadores. Se analiza el desempeño de diferentes combinaciones de características en cada conjunto. Los resultados obtenidos muestran que para incrementar el desempeño de los clasificadores estudiados, es necesaria una combinación de las diferentes técnicas de extracción de características, esta necesidad es mayor cuando se trabaja con conjuntos de hojas con características muy similares. Además, se muestra el mejor desempeño de un clasificador con otro.

### Palabras Clave:

Clasificación, Descriptores, SVM, Conjuntos de Datos, Características.

### 1. Introducción

En la actualidad la implementación de algoritmos de visión abarca casi cualquier campo de aplicación que uno pudiera imaginar. La agronomía parece no ser la excepción. El desarrollo de sistemas de visión que detecten automáticamente e identifiquen las plantas es un reto actual que tiene numerosas aplicaciones. Estas pueden ir desde simple identificación, detección de plagas, detección de enfermedades, identificación de plantas por personal de aduanas, identificación de la planta para cuidado y protección de pesticidas, etc.

La identificación de plantas no es un reto fácil debido a que existen muchas características foliares que los botánicos emplean para identificar las plantas, además de la enorme cantidad de diferentes plantas, muchas hojas poseen y/o comparten una o varias propiedades como: forma, tamaño, textura, color, aun cuando pertenecen a plantas diferentes. Aunado a ello existen otros factores que puede influir en algunas características de

la planta como: cromaticidad, color y textura, algunas de estas características se ven afectadas principalmente por nivel de madurez de la hoja, humedad, enfermedades, etc.

El desarrollo de algoritmos de identificación automática de hojas ha sido direccionado en años recientes por varios investigadores. Sin embargo, en reconocimiento de patrones los métodos de identificación pueden restringirse a descriptores geométricos, texturales, cromáticos y de venación.

En este artículo, estudiamos la influencia de los diferentes tipos de características (geométricas, texturales y cromáticas) en la precisión de clasificación. Además se analiza el desempeño de varios clasificadores sobre conjuntos de imágenes con características geométricas muy similares y disimiles entre sí.

En la metodología utilizada empleamos técnicas de extracción de características geométricas invariantes a escalado, traslación y rotación, técnicas de extracción de características texturales y cromáticas. En la fase de clasificación utilizamos un clasificador Bayesiano, el algoritmo de aprendizaje Backpropagation para redes neuronales y Máquinas de Vectores de Soporte (SVM). Los resultados obtenidos muestran la influencia de los tipos de características en la precisión de clasificación.

\* Autor en correspondencia.

Correos electrónicos: [jcervantesc@uaemex.mx](mailto:jcervantesc@uaemex.mx) (Jair Cervantes), [talte\\_203@hotmail.com](mailto:talte_203@hotmail.com) (Jesús Taltempa), [fglamont@yahoo.com.mx](mailto:fglamont@yahoo.com.mx) (Farid García-Lamont), [jsergioruizc@gmail.com](mailto:jsergioruizc@gmail.com) (José S. Ruiz Castilla), [yeerendon@gmail.com](mailto:yeerendon@gmail.com) (Arturo Yee Rendon), [jalili.anderi@yahoo.com.mx](mailto:jalili.anderi@yahoo.com.mx) (Laura D. Jalili)

## 2. Estado del Arte

Las plantas juegan un importante papel para la vida y el desarrollo humano, no solo son de interés en investigaciones de botánica, sino también en otras ramas, tales como la agricultura (Zhang and Lei, 2011), (Asraf et al., 2012), (Husin et al., 2012), (Xia et al., 2013), ecología vegetal (Zhang and Lei, 2011), (Zhang et al., 2013), (Du et al., 2013), medicamentos basados en plantas (Du et al., 2007), (Husin et al., 2012), (Zhang et al., 2013), (Gwo et al., 2013), conservación natural y también en muchas situaciones de interés público. En el mundo, existen aproximadamente una variedad de 310 000 a 420 000 especies de plantas (Du et al., 2007) sin tomar en cuenta que aún existen muchas que no han sido clasificadas. Por esta razón, identificar una planta a partir de imágenes de hojas no es una tarea trivial. Las técnicas de reconocimiento de patrones empleadas actualmente involucran técnicas de medición de características morfológicas y de textura de los objetos contenidos en la imagen y el desarrollo de sistemas capaces de reconocer el objeto a partir de aquellas características de medida. Es bien sabido que la mejor forma de extraer características válidas es basándose en la imagen de la hoja de la planta. En la literatura actual se ha mostrado que la forma externa de la hoja provee rica información para clasificar. Varios estudios, se han enfocado a la extracción de características y métodos de reconocimiento de patrones para la hoja, utilizando cuatro importantes características para clasificación, que son: La forma (Du et al., 2007) (Hu y Collomose, 2013) (Novotny, 2013) (Xia et al., 2013) (Gwo et al., 2013), textura (Sampallo, 2003) (Asraf et al., 2012) (Husin et al., 2012), el color (Zhang and Lei, 2011) (Cerruti et al., 2013), y la venación de la hoja (Du et al., 2013) (Larese et al., 2014) (Larese et al., 2014b).

La forma de la hoja es una de las características más importantes de la hoja de la planta y los dos enfoques básicos para este tipo de análisis son los basados en contorno y basados en la región. El enfoque basado en la región suele utilizar descriptores de momentos, que incluyen momentos geométricos, momentos de Zernike y momentos de Legendre. El enfoque basado en el contorno usualmente obtiene el contorno con métodos basados en la curvatura de la hoja (Zhang and Lei, 2011). Otros estudios han utilizado una combinación de características geométricas y texturales, permitiéndoles incluso utilizar hojas secas, mojadas o deformes (Husin et al., 2012). Los descriptores utilizados por los distintos autores van desde descriptores básicos como perímetro, área, circularidad y elipsidad (Sampallo, 2003), hasta descriptores invariantes como momentos de Hu y descriptores de Fourier para reconocimiento de contorno de la hoja (Novotny, 2013). Recientemente se han propuesto sistemas para extraer características que describen variaciones del borde de la hoja, utilizando descriptores invariantes a traslación, rotación y tamaño (Gwo et al., 2013).

La textura de la hoja puede ser definida como las características que la hoja posee en su superficie y que se manifiesta en imágenes digitales a través de variaciones de escala de grises en la imagen, a partir de donde se extraen las matrices de co-ocurrencia que servirán para obtener los descriptores texturales (Ma y Manjunath, 1996) (Manjunath y Ma, 1996).



Figura 1: Conjunto de hojas empleado

Otros estudios usan el color como característica de comparación de imágenes, ya que una simple similitud de color entre dos imágenes puede ser medida comparando sus histogramas de color (Zhang and Lei, 2011). En (Cerruti et al., 2013) utilizan como alternativa el espacio de color  $L^* a^* b^*$ , que muestra colores más consistentes y presenta más o menos el mismo eje para toda la hoja a diferencia del espacio RGB. Aunque los enfoques de clasificación como la forma, textura y color son válidos, no se ha documentado la influencia de cada tipo de características en el desempeño de los algoritmos de clasificación.

Los primeros estudios de reconocimiento de plantas utilizaron la cromaticidad de la planta como un descriptor importante para comparar imágenes. Descriptores muy simples de cromaticidad pueden obtener el color promedio en la región previamente segmentada de la hoja, gradiente promedio en el borde o la similitud de color entre dos imágenes que se puede medir mediante la comparación de sus histogramas de color. Descriptores de color más complejos utilizan momentos de invariancia comúnmente utilizados para obtener características geométricas pero incorporándoles la información de las variables de color de la hoja (Venters y Cooper, 2000), (Smeulders et al., 2000), (Tico et al., 2000). Sin embargo, un problema recurrente en las hojas de las plantas es que la cromaticidad en las hojas no es estática, esta es variable con respecto al tiempo y comúnmente con respecto a otros factores más. Uno de los enfoques más empleados en la actualidad consiste en analizar la forma de la hoja extrayendo características geométricas como tamaño, elongación, elipsidad, área, longitud, diámetro, rectangularidad, esfericidad, excentricidad, etc. (Chaki y Parekh,

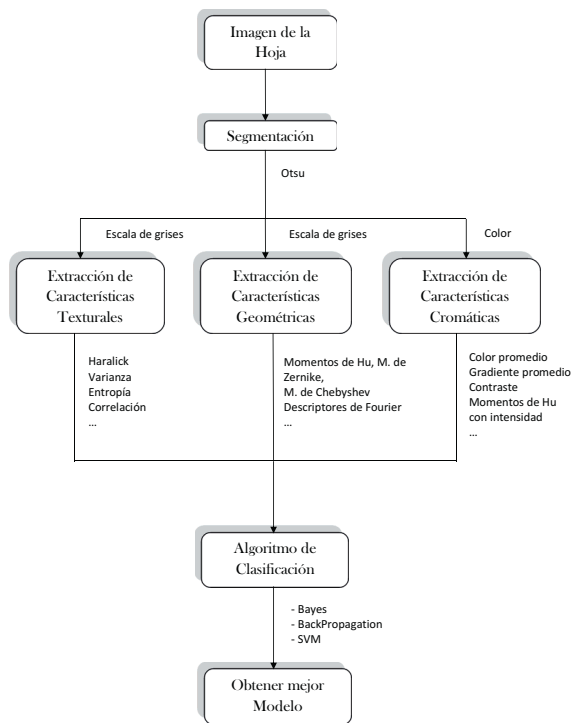


Figura 2: Diagrama de metodología

2012) (Park y Kim, 2004) (Xiang et al, 2007) (Kadir et al., 2012) (Kaur, 2012). Algunos autores han agregado a estos descriptores geométricos básicos, momentos de Hu y momentos de Fourier mejorando el desempeño de los clasificadores (Numar et al., 2012) (Hearn, 2009). Otros autores consideran además de cromaticidad y forma, la textura de la hoja (Novotny, 2013) (Cope et al., 2012) o utilizan combinaciones de descriptores para mejorar el desempeño de clasificación (Gwo et al., 2013) (Husin et al., 2012) (Zhang and Lei, 2011) (Brandstadt y Van Bang, 2006).

Existe gran cantidad de información en la literatura sobre identificación de plantas y/o arboles a partir de hojas. Sin embargo, en la mayoría de los sistemas actuales es fácil identificar dos problemas: 1) No existe un estudio completo sobre identificación complejo de plantas, es decir, un estudio que muestre la eficiencia de un algoritmo sobre conjuntos de imágenes muy similares entre sí. 2) Los trabajos actuales utilizan características texturales, cromáticas y geométricas. Sin embargo, no existen trabajos que realicen un análisis sobre la influencia de las características en el desempeño del clasificador. En este artículo se estudia la influencia de los tipos de descriptores en la precisión de clasificación en dos tipos generales de hojas; conjuntos de imágenes de hojas disímiles entre sí y conjuntos de hojas de imágenes con propiedades muy similares entre sí.

### 3. Metodología

La metodología utilizada es mostrada en la Figura 2. Los pasos son los habituales en cualquier sistema de reconocimiento

a partir de características. En los experimentos realizados se obtuvieron características geométricas, cromáticas y texturales, no se incluyeron características de venación debido a que el método tiene algunos fallos cuando las imágenes de hojas no contienen una venación prominente.

Primero, las imágenes son pre procesadas y segmentadas. Regularmente en pre procesamiento se emplea una máscara Gaussiana para obtener una buena segmentación (Gonzalez y Woods, 2010) (Sonka et al. , 1993) (Nixon y Aguado, 2002). En las simulaciones realizadas se aplicó este tipo de máscaras. Sin embargo, debido a que las imágenes fueron tomadas en un ambiente controlado, se notó que la fase de preprocesamiento no era necesaria para este conjunto de datos.

En general, la segmentación autónoma es una de las tareas más difíciles en el procesamiento de imágenes. En imágenes de hojas a menudo están rodeadas de zonas verdes en el fondo. Sin embargo, las imágenes utilizadas son hojas en ambientes totalmente controlados (imágenes con únicamente la hoja con fondo blanco). Se realizaron pruebas de segmentación con los algoritmos de segmentación frontera adaptativa, Otsu y segmentación utilizando una fase de análisis de componentes principales (PCA) y no se obtuvieron diferencias entre estos por la naturaleza del conjunto de datos, por ello finalmente se utilizó el algoritmo de Otsu para realizar la segmentación.

#### 3.1. Técnicas de segmentación

La región de la hoja en cada imagen fue segmentada empleando los siguientes pasos 1) Cálculo de alto contraste en escala de grises a partir de combinación lineal óptima de los componentes de color en RGB (Gonzalez y Woods, 2010) (Sonka et al. , 1993); 2) Estimar una frontera óptima empleando momentos acumulativos de orden cero y de primer orden (método de Otsu) (Gonzalez y Woods, 2010) (Sonka et al. , 1993). 3) Operaciones morfológicas para rellenar posibles espacios vacíos en la imagen segmentada (Gonzalez y Woods, 2010) (Sonka et al. , 1993) (Nixon y Aguado, 2002). Todo esto con el objetivo de obtener una buena segmentación aún cuando existan cambios en las condiciones globales de brillo. Al segmentar la imagen, el sistema utilizado puede utilizar únicamente la región de la hoja, determinar sus bordes y calcular las propiedades mediante la extracción de características.

#### 3.2. Extractores de Características

La extracción de características es un proceso crítico en cualquier sistema de reconocimiento de patrones. La precisión en la extracción de características tiene una gran influencia en los resultados de la identificación finales.

Una vez segmentada la región se extraen sus características. La extracción de características nos permite representar la imagen mediante un conjunto de valores numéricos con gran poder discriminativo, eliminando características redundantes y reduciendo la dimensionalidad de la imagen. Las características obtenidas son capaces de asociar rangos muy similares a imágenes similares, asociar rangos diferentes a imágenes diferentes, además de ser invariantes a escalado, rotación y traslación, permitiendo al clasificador reconocer objetos a pesar de tener diferente tamaño, posición y orientación. Todas estas características

juegan un rol importante en el desempeño del algoritmo y permiten al clasificador discriminar de una forma apropiada entre distintas clases (Nixon y Aguado, 2002).

*Características geométricas*

Las características geométricas son uno de los rasgos visuales más importantes y utilizados para clasificar un objeto. Las características geométricas proveen información del tamaño y forma de la región previamente segmentada.

Las características geométricas más elementales proveen información con significado intuitivo de las propiedades básicas de la región a reconocer, estas son; área de la región, redondez de la hoja, longitud del borde de la hoja, elongación definida por la longitud y ancho de la hoja, las coordenadas  $x$  e  $y$  del centro de gravedad, rectangularidad, proyección (sobre las componentes  $x$  e  $y$ ), excentricidad, centro de gravedad (componentes  $x$  e  $y$ ), factor Danielson, diámetro equivalente, longitud de ejes ( $x$  e  $y$ ), orientación, solidez, extensión, área convexa, área rellena, elipsidad (varianza, orientación, excentricidad, área, eje mayor, eje menor, centro de elipse  $x$  e  $y$ ).

Sin embargo, un sistema eficiente de clasificación de hojas debe permitir reconocer las hojas independientemente de su orientación, localización y tamaño, i.e. debe ser invariante a escalado, rotación y traslación.

Los momentos son comúnmente utilizados en reconocimiento de imágenes, estos permiten reconocer imágenes independientemente de su rotación, traslación o inversión. Aunque los momentos de Hu no proporcionan información intuitiva de las propiedades básicas de la hoja, pues estos se obtienen a partir de combinación de múltiples características de la región segmentada, estos proporcionan información discriminativa para comparar dos hojas. La Figura 3 muestra los momentos de Hu obtenidos con dos hojas muy parecidas, pero de diferente familia. Los momentos de Hu geométricos son casi idénticos para ambas hojas, sin embargo los momentos de Hu con intensidad varían significativamente. Los momentos de Hu geométricos podrían discriminar perfectamente bien para dos hojas con formas geométricas diferentes, pero fallan al comparar formas similares, estos deben ser ayudados por otras características.

Los momentos invariantes fueron inicialmente introducidos por Hu (Hu, 1962) y consisten de 7 momentos ( $\phi_1, \dots, \phi_7$ ), otras características invariantes comúnmente utilizadas son momentos de flusser ( $F_1, \dots, F_4$ ) (Flusser y Suk, 1993) (Mingqiang et al, 2008), Momentos R ( $R_1, \dots, R_{10}$ ) (Liu et al., 2008), descriptores de Fourier (primeros 8 descriptores) (Mingqiang et al, 2008) (Nixon y Aguado, 2002). Los momentos de Hu de orden  $(p + q)$  de una función de intensidad  $f(x, y)$  son obtenidos a partir de los momentos ordinarios.

Los momentos de orden  $(p + q)$  son definidos como:

$$m_{pq} = \sum_x \sum_y x^p y^q \rho(x, y). \tag{1}$$

donde  $\rho(x, y)$  es definida por la región segmentada. Los momentos de orden pequeño describen la forma de la región. Por ejemplo  $m_{00}$  describe el área de la región segmentada, mientras que  $m_{01}$  y  $m_{10}$  definen las coordenadas  $x$  e  $y$  del centro de

gravedad. Sin embargo, los momentos  $m_{02}, m_{03}, m_{11}, m_{12}, m_{20}, m_{21}$  y  $m_{30}$  son invariantes a traslación, rotación e inversión. Los momentos centrales son invariantes a desplazamiento y pueden ser calculados mediante

$$\mu_{pq} = \sum_{i,j \in R} (i - \bar{i})^p (j - \bar{j})^q \tag{2}$$

donde  $p, q$  pertenecen a la región segmentada y el centro de gravedad de la región es definido por:

$$\bar{i} = \frac{m_{10}}{m_{00}}, \bar{j} = \frac{m_{01}}{m_{00}} \tag{3}$$

Los momentos de Hu pueden ser obtenidos de la siguiente manera:

$$\begin{aligned} \phi_1 &= \eta_{20} + \eta_{02} \\ \phi_2 &= (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2 \\ \phi_3 &= (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2 \\ \phi_4 &= (\eta_{30} - 3\eta_{12})^2 + (\eta_{21} + \eta_{03})^2 \\ \phi_5 &= (\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] + \\ &\quad (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \\ \phi_6 &= (\eta_{20} - \eta_{02})(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2 + \\ &\quad 4(\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03})) \\ \phi_7 &= (3\eta_{21} - \eta_{03})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] - \\ &\quad (\eta_{30} - 3\eta_{12})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \end{aligned} \tag{4}$$

donde  $\eta_{pq} = \frac{\mu_{pq}}{\mu_{00}^t}, t = \frac{p+q}{2} + 1$ .

Algunas veces es necesario tener características invariantes a traslación, rotación, escala y transformaciones afines. Los momentos de Flusser obtienen características derivadas a partir de los momentos centrales de segundo y tercer orden que son invariantes a transformaciones afines (Flusser y Suk, 1993), estas pueden ser obtenidas a partir de las siguientes ecuaciones:

$$\begin{aligned} I_1 &= \frac{\mu_{20}\mu_{02} - \mu_{11}^2}{\mu_{00}^4} \\ I_2 &= \frac{\mu_{30}^2\mu_{03}^2 - 6\mu_{30}\mu_{21}\mu_{12}\mu_{03} + 4\mu_{30}\mu_{12}^3 + 4\mu_{21}^3\mu_{03} - 3\mu_{21}^2\mu_{12}^2}{\mu_{00}^{10}} \\ I_3 &= \frac{\mu_{20}(\mu_{21}\mu_{03} - \mu_{12}^2) - \mu_{11}(\mu_{30}\mu_{03} - \mu_{21}\mu_{12}) + \mu_{02}(\mu_{30}\mu_{12} - \mu_{21}^2)}{\mu_{00}^7} \\ I_4 &= \frac{(\mu_{20}^3\mu_{03}^2 - 6\mu_{20}^2\mu_{11}\mu_{12}\mu_{03} - 6\mu_{20}^2\mu_{02}\mu_{21}\mu_{03} + 9\mu_{20}^2\mu_{02}\mu_{12}^2 + \\ &\quad 12\mu_{20}\mu_{11}^2\mu_{21}\mu_{03} + 6\mu_{20}\mu_{11}\mu_{02}\mu_{30}\mu_{03} - 18\mu_{20}\mu_{11}\mu_{02}\mu_{21}\mu_{12} - \\ &\quad 8\mu_{11}^3\mu_{30}\mu_{03} - 6\mu_{20}\mu_{02}^2\mu_{30}\mu_{12} + 9\mu_{20}\mu_{02}^2\mu_{21} + 12\mu_{11}^2\mu_{02}\mu_{30}\mu_{12} - \\ &\quad 6\mu_{11}\mu_{02}^2\mu_{30}\mu_{21} + \mu_{02}^3\mu_{30}^2)/(\mu_{00}^{11})}{\mu_{00}^{11}} \end{aligned} \tag{5}$$

Obtener características que sean invariantes a cambios de luz es muy importante para identificar hojas de la misma clase

Escala de Grises		Escala de Grises	
1 Hu-Moment	0.1616	1 Hu-Moment	0.1665
2 Hu-Moment	0.0000	2 Hu-Moment	0.0001
3 Hu-Moment	0.0001	3 Hu-Moment	0.0001
4 Hu-Moment	0.0000	4 Hu-Moment	0.0000
5 Hu-Moment	0.0000	5 Hu-Moment	0.0000
6 Hu-Moment	0.0000	6 Hu-Moment	0.0000
7 Hu-Moment	0.0000	7 Hu-Moment	0.0000
Momento de HU-canal rojo		Momento de HU-canal rojo	
1 Hu-moment-int	0.6143	1 Hu-moment-int	1.039635
2 Hu-moment-int	0.0007	2 Hu-moment-int	0.004487
3 Hu-moment-int	0.0017	3 Hu-moment-int	0.010409
4 Hu-moment-int	0.0000	4 Hu-moment-int	0.001315
5 Hu-moment-int	0.0000	5 Hu-moment-int	-0.000002
6 Hu-moment-int	0.0000	6 Hu-moment-int	0.000052
7 Hu-moment-int	0.0000	7 Hu-moment-int	0.000005
Momento de HU-canal verde		Momento de HU-canal verde	
1 Hu-moment-int	0.5127	1 Hu-moment-int	0.717195
2 Hu-moment-int	0.0005	2 Hu-moment-int	0.002135
3 Hu-moment-int	0.0011	3 Hu-moment-int	0.004114
4 Hu-moment-int	0.0000	4 Hu-moment-int	0.00052
5 Hu-moment-int	0.0000	5 Hu-moment-int	0
6 Hu-moment-int	0.0000	6 Hu-moment-int	0.000014
7 Hu-moment-int	0.0000	7 Hu-moment-int	0.000001
Momento de HU-canal azul		Momento de HU-canal azul	
1 Hu-moment-int	0.1616	1 Hu-moment-int	0.166525
2 Hu-moment-int	0.0000	2 Hu-moment-int	0.000115
3 Hu-moment-int	0.0001	3 Hu-moment-int	0.000107
4 Hu-moment-int	0.0000	4 Hu-moment-int	0.000014
5 Hu-moment-int	0.0000	5 Hu-moment-int	0
6 Hu-moment-int	0.0000	6 Hu-moment-int	0
7 Hu-moment-int	0.0000	7 Hu-moment-int	0

Figura 3: Comparación de características (momentos de Hu geométricos y con intensidad) de dos hojas

con cambios en la iluminación, características invariantes a iluminación pueden ser obtenidos con los momentos R (Liu et al., 2008) descritos a continuación:

$$\begin{aligned}
 R_1 &= \frac{\sqrt{\phi_2}}{\phi_1}, R_2 = \frac{\phi_1 + \sqrt{\phi_2}}{\phi_1 - \sqrt{\phi_2}}, R_3 = \frac{\sqrt{\phi_3}}{\sqrt{\phi_4}}, \\
 R_4 &= \frac{\sqrt{\phi_3}}{|\sqrt{\phi_5}|}, R_5 = \frac{\sqrt{\phi_4}}{|\sqrt{\phi_5}|}, R_6 = \frac{|\phi_6|}{\phi_1 \cdot \phi_3}, R_7 = \frac{|\phi_6|}{\phi_1 \cdot \sqrt{|\phi_5|}} \\
 R_8 &= \frac{|\phi_6|}{\phi_1 \cdot \sqrt{|\phi_5|}}, R_9 = \frac{|\phi_6|}{\sqrt{\phi_2 \cdot \sqrt{|\phi_5|}}}, R_{10} = \frac{|\phi_5|}{\phi_3 \cdot \phi_4}
 \end{aligned} \quad (6)$$

En total 57 características geométricas fueron extraídas de cada imagen. El vector de características geométricas  $X_g$  obtenido puede ser representado como:

$$X_g = [x_1, x_2, \dots, x_{57}] \quad (7)$$

$$X_g = [x_{gb}, x_{Hu}, x_F, x_R, x_{DF}] \quad (8)$$

donde  $x_{gb}$  representa las características geométricas elementales descritas anteriormente ( $x_{gb} = [x_1, \dots, x_{28}]$ ),  $x_{Hu}$  representa las características invariantes de Hu ( $x_{Hu} = [x_{29}, \dots, x_{35}]$ ),  $x_F$  representa los 4 momentos invariantes de Flusser obtenidos ( $x_F = [x_{36}, \dots, x_{39}]$ ),  $x_R$  representa los momentos invariantes a cambios en iluminación en la región segmentada ( $x_R = [x_{40}, \dots, x_{49}]$ ), mientras que  $x_{DF}$  representa los primeros 8 descriptores de Fourier obtenidos de la región segmentada ( $x_{DF} = [x_{50}, \dots, x_{57}]$ ). Una descripción detallada sobre los descriptores de Fourier puede ser obtenida en (Mingqiang et al, 2008) (Nixon y Aguado, 2002).

### Características texturales

Las características texturales proveen información del arreglo espacial de colores o intensidades en la imagen. Los algo-

ritmos de extracción de características texturales buscan patrones repetitivos básicos con estructuras periódicas o aleatorias en imágenes. Estas estructuras dan lugar a una propiedad que puede ser rugosidad, aspereza, granulación, fineza, suavidad, etc. Debido a que una textura repite un patrón a lo largo de una superficie, las texturas son invariantes a desplazamientos, ello explica porqué la percepción visual de una textura es independiente de la posición. En este artículo, se utilizaron características texturales de Haralick. Estos extractores toman en cuenta la distribución de valores de intensidad en la región obteniendo la media y rango de las siguientes variables: media, mediana, varianza, suavidad, sesgo, curtosis, correlación, energía o entropía, contraste, homogeneidad, y correlación. Las características texturales más importantes son las características de Haralick y los Patrones Binarios Locales (LBP por sus siglas en inglés *-Local binary Patterns-*) (He y Wang, 1990) (Wang y He, 1990). Los descriptores de Haralick utilizados son descritos a continuación:

$$f_1 = \sum_i \sum_j [p(i, j)^2] \quad (9)$$

$$f_2 = \sum_{n=0}^{N_g-1} n^2 \left\{ \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j)}{|i-j|=n} \right\} \quad (10)$$

$$f_3 = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} [ijp(i, j) - \mu_x \mu_y]}{\sigma_x \sigma_y} \quad (11)$$

$$f_4 = \sum_i \sum_j (i - \mu_x)^2 p(i, j) \quad (12)$$

$$f_5 = \sum_i \sum_j \frac{1}{1 + (i-j)^2} p(i, j) \quad (13)$$

$$f_6 = \sum_{i=2}^{2N_g} iP_{x+y}(i) \quad (14)$$

$$f_7 = \sum_{i=2}^{2N_g} (i - f_8)^2 P_{x+y}(i) \quad (15)$$

$$f_8 = - \sum_{i=2}^{2N_g} P_{x+y}(i) \log\{P_{x+y}(i)\} \quad (16)$$

$$f_9 = - \sum_i \sum_j p(i, j) \log\{p(i, j)\} \quad (17)$$

$$f_{10} = \sum_{i=0}^{N_g-1} (i - f_8)^2 P_{x-y}(i) \quad (18)$$

$$f_{11} = - \sum_{i=0}^{N_g-1} P_{x-y}(i) \log\{P_{x-y}(i)\} \quad (19)$$

$$f_{12} = \frac{HXY - HXY1}{\max\{HX, HY\}} \quad (20)$$

$$f_{13} = (1 - e^{[-2(HXY2-HXY)]})^{\frac{1}{2}} \quad (21)$$

$$f_{14} = (\text{Segundo valor propio mas grande de } Q)^{\frac{1}{2}} \quad (22)$$

donde  $p(i, j)$  = define el valor de la matriz de coocurrencia en la posición  $(i, j)$ .  $N_g$  = Niveles de intensidad trabajados en la región segmentada de la imagen.  $p_x(i)$  =  $i$ -ésima entrada en una matriz de probabilidad original de coocurrencia que es obtenida mediante la suma de filas en  $p(i, j)$ .  $p_y(j)$  =  $j$ -ésima entrada en una matriz de probabilidad original de coocurrencia que es obtenida mediante la suma de columnas en  $p(i, j)$ .  $R$  = Número total de elementos en la matriz de coocurrencia.  $\mu_x, \mu_y$  = Media de  $P_x$  y  $P_y$ .  $\sigma_x, \sigma_y$  = Desviación estándar de  $P_x$  y  $P_y$ .  $H_x, H_y$  = Entropía de  $P_x$  y  $P_y$ . En total se obtuvieron 219 descriptores texturales de cada imagen. 73 por cada canal de color utilizado. El vector de características Texturales  $X_t$  obtenido puede ser representado como:

$$X_t = [x_1, x_2, \dots, x_{219}] \quad (23)$$

$$X_t = [x_{Rlbp}, x_{RH}, x_{Glp}, x_{GH}, x_{Blp}, x_{BH}] \quad (24)$$

donde  $x_{Rlbp}, x_{Glp}, x_{Blp}$  representan las características LBP obtenidas en el canal de color R, G y B respectivamente,  $x_{RH}, x_{GH}$  y  $x_{BH}$  representan las características texturales de Haralick obtenidas en los canales R, G y B respectivamente. Una descripción detallada sobre los descriptores de LBP puede ser obtenida en (He y Wang, 1990) (Wang y He, 1990).

#### Características cromáticas

Las características cromáticas proveen información de la intensidad del color de una región segmentada. éstas características pueden ser calculadas por cada canal de intensidad, por ejemplo, rojo, verde, azul, escala de grises, tono (Hue), saturación (Saturation) e intensidad (Value), etc.

Las características que se emplearon fueron características de intensidad elementales como: media, varianza, mediana, kurtosis, coeficiente de variación, moda, asimetría, media Laplaciana, gradiente en la frontera y momentos de Hu con intensidad  $(\phi_1, \dots, \phi_7)$ . Los momentos de Hu integran información de la variable de color en combinación con la forma geométrica de la región de la hoja segmentada. En total 39 características, sin embargo, al trabajar en el espacio RGB se extrajeron 39 características por cada componente, en total 117 características. El vector de características cromáticas  $X_c$  obtenido puede ser representado como:

$$X_c = [x_1, x_2, \dots, x_{117}] \quad (25)$$

$$X_c = [x_{Re}, x_{RHu}, x_{Ge}, x_{GHu}, x_{Be}, x_{BH_u}] \quad (26)$$

donde  $x_{Re}, x_{Ge}, x_{Be}$  representan las características de color elementales obtenidas en el canal de color R, G y B respectivamente,  $x_{RHu}, x_{GHu}$  y  $x_{BH_u}$  representan las características de color utilizando momentos de Hu, obtenidas en los canales R, G y B respectivamente. Una descripción detallada sobre los momentos de Hu con intensidad puede ser obtenida en (Hu, 1962) (Mingqiang et al, 2008).

### 3.3. Algoritmos de clasificación

En los experimentos realizados se compararon los resultados con tres técnicas utilizadas para clasificación, se utilizó un clasificador Bayesiano, regresión logística, el algoritmo de aprendizaje *Backpropagation* para redes neuronales y Máquinas de Vectores de Soporte (SVM). Los algoritmos se describen en esta subsección.

#### Máquinas de Vectores Soporte (SVM)

Las SVM son una de las técnicas de clasificación más utilizadas en los últimos años, Las características clave de las SVMs son el uso de *kernels* al trabajar en conjuntos no-lineales, la ausencia de los mínimos locales, la solución depende de un pequeño subconjunto de datos y el poder discriminativo del modelo obtenido al optimizar el margen de separabilidad entre clases, estas características permiten a las SVM obtener resultados muy competitivos en comparación con otros clasificadores. Formalmente las SVM pueden ser definidas de la siguiente manera:

Asumiendo que un conjunto de datos de entrenamiento  $X$  es dado como:

$$(\mathbf{x}_1, \mathbf{y}_1), (\mathbf{x}_2, \mathbf{y}_2), \dots, (\mathbf{x}_n, \mathbf{y}_n) \quad (27)$$

i.e.  $X = \{x_i, y_i\}_{i=1}^n$  donde  $x_i \in \mathbb{R}^d$  y  $y_i \in \{+1, -1\}$ . Entrenar una SVM permite resolver un problema de programación cuadrática como sigue:

$$\begin{aligned} \max_{\alpha_i} & -\frac{1}{2} \sum_{i,j=1}^l \alpha_i y_i \alpha_j y_j \mathbf{K}(x_i \cdot x_j) + \sum_{i=1}^l \alpha_i \\ \text{sujeto a: } & \sum_{i=1}^l \alpha_i y_i = 0, \quad C \geq \alpha_i \geq 0, i = 1, 2, \dots, l \end{aligned} \quad (28)$$

donde  $C > 0$ ,  $\alpha_i = [\alpha_1, \alpha_2, \dots, \alpha_l]^T$ ,  $\alpha_i \geq 0, i = 1, 2, \dots, l$ , son coeficientes que corresponden a  $x_i, x_j$  con  $\alpha_i$  diferentes a cero que son llamados Vectores Soporte (SV). La función  $\mathbf{K}$  es una función. Las SVM son clasificadores lineales, es decir, se clasifica entre dos conjuntos de datos mediante la construcción de una línea que separa dos clases. Cuando esto no es posible, se utiliza una función llamada *kernel* que transforma el espacio de entrada a un espacio altamente dimensional, en donde los conjuntos pueden ser separados linealmente después de la transformación. Sin embargo, la elección de una función está restringida a aquellas que satisfacen las condiciones de Mercer (Vapnik, 1998).

Sea  $S$  el conjunto de SV obtenidos después del entrenamiento, entonces el hiperplano óptimo es dado por:

$$\sum_{i \in S} (\alpha_i y_i) K(\mathbf{x}_i, \mathbf{x}_j) + b = 0 \quad (29)$$

y la función de decisión óptima es definida como

$$f(x) = \text{sign}(\sum_{i \in S} (\alpha_i y_i) K(\mathbf{x}_i, \mathbf{x}_j) + b) \quad (30)$$

donde  $\mathbf{x} = [x_1, x_2, \dots, x_l]$  son los datos de entrada,  $\alpha_i$  y  $y_i$  son los multiplicadores de Lagrange. Un nuevo objeto  $x$  puede ser clasificado empleando (30). El vector  $\mathbf{x}_i$  es dado en la forma








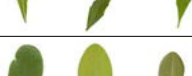
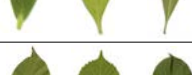
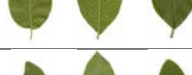

Subconjunto	Familias Asociadas	Ejemplos	Razon de Similitud
1	19		Orbicular
2	8		Lineal
3	14		Lanceolada
4	27		Elíptica
5	12		Aovada
6	3		Lacerada con forma de pentágono
7	7		Lineal dentada
8	9		Espatulada
9	13		aovada con cuspid
10	20		Elongada
11	37		Abovada

Figura 4: Conjuntos de hojas utilizados

de producto punto. Existe un multiplicador de Lagrange  $\alpha$  para cada punto de entrenamiento. Cuando el máximo margen del hiperplano es encontrado, solamente los puntos más cercanos al hiperplano satisfacen  $\alpha > 0$ . Estos puntos son los vectores soporte (SV).

### Redes neuronales

Una red neuronal es un conjunto de neuronas artificiales interconectadas que utilizan modelos matemáticos para procesar información. Las múltiples conexiones entre las neuronas forman un sistema adaptivo cuyos pesos se actualizan mediante un particular algoritmo de aprendizaje. Las redes neuronales han sido utilizadas en numerosos campos de aplicación con distintos algoritmos de aprendizaje (Portillo et al., 2009) (Jimenez et al., 2013) (Rossomando et al., 2010) (Valverde y Paez, 2007).

De los distintos algoritmos de aprendizaje, uno de los más

utilizados es el algoritmo de aprendizaje *backpropagation* (BP). Para llevar a cabo el proceso de aprendizaje, el algoritmo de aprendizaje BP cambia iterativamente los pesos entre las neuronas minimizando el error cuadrático entre la salida deseada y la obtenida con los pesos actuales. Cada uno de los ejemplos del conjunto de entrenamiento  $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$  son utilizados para ajustar los pesos en la red. Al ser presentado un ejemplo, la señal es propagada hacia adelante de la red hasta que la salida es obtenida. La salida de la  $j$ -ésima unidad oculta es calculada como:

$$o_{nj}^h = f_j^h(\text{net}_{nj}^h) = \frac{1}{1 + \exp(-\text{net}_{nj}^h)} \quad (31)$$

donde  $\text{net}_{nj}^h = \sum w_{ji}^h x_{ni} + \theta_j^h$ .  $w_{ji}^h$  es el peso de la conexión de la  $i$ -ésima neurona de entrada a la  $j$ -ésima neurona oculta.  $\theta_j^h$  y  $f_j^h$  representan el sesgo y la función de activación de la  $j$ -ésima neurona oculta. Por otro lado, la salida de la  $k$ -ésima neurona está dado por

$$o_{nk}^o = f_k^o(\text{net}_{nk}^o) = \frac{1}{1 + \exp(-\text{net}_{nk}^o)} \quad (32)$$

donde los superíndices  $h$  y  $o$  se refieren a las cantidades en las capas ocultas y de salida respectivamente. El error entre la salida actual y la salida deseada es calculado para ajustar los pesos mediante  $E_n = \frac{1}{2} \sum_{k=1}^C (t_{nk} - o_{nk}^o)$ . El procedimiento de ajuste es obtenido a partir del método de gradiente descendente para reducir la magnitud del error. El procedimiento es primeramente aplicado a los pesos en la capa de salida y retropropagado a través de la red hasta que los pesos en la primera capa han sido ajustados  $\Delta w_{kj}^o = -\eta \frac{\partial E_n}{\partial w_{kj}^o}$  y  $\Delta w_{ji}^h = -\eta \frac{\partial E_n}{\partial w_{ji}^h}$ . Este procedimiento es realizado para cada ejemplo en el conjunto de datos hasta que se cumple un criterio de paro. Para un estudio profundo del algoritmo puede referirse a (Rumelhart et al., 1986) (Werbos, 1994).

### Naive Bayes

Los clasificadores Bayesianos se basan en la teoría de decisión de Bayes, El principio de Bayes provee una metodología fundamental para resolver problemas de clasificación de patrones cuando la distribución de probabilidad de los patrones es conocida. Un clasificador Bayesiano utiliza un enfoque probabilístico para asignar la clase a un ejemplo. Sea  $C$  la clase de un objeto que pertenece a un conjunto de  $m$  clases  $(C_1, C_2, \dots, C_m)$  y  $X_k$  un objeto con  $k$  características  $X_k = [x_1, x_2, \dots, x_k]$ , en nuestro caso es el conjunto de características que definen a una hoja. el clasificador Bayesiano, calcula la probabilidad condicional posterior  $p(C_i | X_k)$  utilizando la regla de Bayes:

$$p(C_i | X_k) = \frac{p(X_k | C_i) p(C_i)}{p(X_k)}, i = 1, 2, \dots, m. \quad (33)$$

En la Ec. 33  $p(X_k | C_i)$ ,  $p(C_i)$  y  $p(X_k)$  son calculadas a partir de los datos de entrenamiento.

Tabla 2: Desempeño con características cromáticas, texturales y geométricas.

Subconjunto	Cromáticas						Texturales						Geométricas					
	Bayes	BP	RL	SVM <sub>RBF</sub>	SVM <sub>L</sub>	SVM <sub>P</sub>	Bayes	BP	RL	SVM <sub>RBF</sub>	SVM <sub>L</sub>	SVM <sub>P</sub>	Bayes	BP	RL	SVM <sub>RBF</sub>	SVM <sub>L</sub>	SVM <sub>P</sub>
CH.1	88.7	94.21	86.38	94.91	86.43	92.83	36.28	47.78	42.07	56.902	32.69	52.95	81.89	93.56	84.83	<b>95.408</b>	77.45	94.89
CH.2	81.57	84.50	82.17	88.28	82.81	87.94	38.87	68.24	70.94	73.053	30.71	71.82	85.58	90.19	87.64	<b>92.941</b>	82.48	92.45
CH.3	88.22	94.73	89.27	<b>95.03</b>	78.73	94.61	37.18	74.06	71.86	77.518	31.29	77.19	78.08	89.32	83.63	91.918	70.38	90.92
CH.4	86.25	94.56	89.61	<b>95.62</b>	83.29	95.16	36.72	67.32	65.91	75.881	37.68	72.24	74.70	90.74	85.73	93.409	69.63	91.26
CH.5	93.67	95.56	92.82	95.72	91.42	94.19	28.30	71.04	68.81	72.841	22.51	70.93	85.44	95.11	88.33	<b>97.289</b>	81.41	95.56
CH.6	99.37	<b>100</b>	98.62	<b>100</b>	96.16	<b>100</b>	75.53	91.71	76.53	93.308	70.19	90.81	93.08	99.37	98.11	99.742	84.67	97.28
CH.7	96.56	96.70	94.35	97.45	91.42	95.33	48.25	82.39	81.27	85.082	44.35	82.42	97.87	<b>98.75</b>	96.45	98.733	93.96	97.39
CH.8	95.85	97.83	96.18	98.56	93.92	97.84	56.40	84.23	83.85	87.875	49.58	87.09	95.26	98.31	96.84	<b>98.941</b>	81.31	96.91
CH.9	88.38	90.64	90.38	90.87	84.72	90.37	38.39	65.77	63.21	69.69	39.73	67.22	84.59	93.80	87.46	<b>94.410</b>	79.93	91.37
CH.10	86.31	95.85	92.48	<b>96.36</b>	81.38	95.54	39.54	78.89	75.59	82.871	35.14	81.53	80.21	93.10	86.84	94.182	78.24	92.72
CH.11	77.62	92.33	88.31	<b>93.91</b>	75.83	91.73	33.72	63.41	62.84	68.161	31.27	67.56	74.83	88.35	78.03	91.324	71.85	91.08
CH.12	79.37	95.72	87.26	<b>97.75</b>	72.21	96.31	58.23	61.55	58.52	65.585	61.38	65.14	79.98	86.93	83.81	89.095	73.37	87.38

De acuerdo a la teoría de Bayes (Ng y Jordan, 2002) (Russell y Norvig, 2003), para una observación dada ( $X_k$ , la clase a la que pertenece está dada por la probabilidad posterior máxima:

$$f(X_k) = \arg \max_i p(C_i | X_k) \tag{34}$$

Para un estudio más exhaustivo puede referirse a (Ng y Jordan, 2002) (Russell y Norvig, 2003).

#### Regresión logística

La regresión logística es utilizada para modelar las probabilidades de clase posterior sin tener que aprender las densidades de clase condicional, facilitando la clasificación en pequeños conjuntos de entrenamiento y una menor complejidad. Sea  $\pi_i = p(Y_i = 1 | X_i)$  donde  $X_i$  es un vector de tamaño  $1 \times (p + 1)$  con el primer elemento igual a 1 y los elementos restantes corresponden a las características extraídas de la hoja para el ejemplo  $i$ . El modelo de regresión logística relaciona  $\pi_i$  con las características mediante la función:

$$\text{logit}(\pi_i) = \log\left(\frac{\pi_i}{1 - \pi_i}\right) = X_i \beta \tag{35}$$

donde  $\beta = (\beta_0, \beta_1, \dots, \beta_p)$  es el vector de coeficientes de regresión. Un estudio detallado y diferentes algoritmos de regresión logística pueden ser encontrados en (Borges et al., 2011), (Bernardo y Smith, 1994), (Dempster et al., 1977).

Tabla 1. Subconjuntos de datos.

Subconjuntos	Subconjuntos	
	Tamaño	Clases
CH.1	1095	19
CH.2	348	8
CH.3	962	14
CH.4	2481	27
CH.5	782	12
CH.6	186	3
CH.7	428	7
CH.8	832	9
CH.9	1248	13
CH.10	1632	20
CH.11	4398	37
CH.12	9425	90

## 4. Resultados Experimentales

En esta sección se muestran la técnica de selección de parámetros, normalización de datos y los resultados experimentales obtenidos con el sistema utilizado.

### 4.1. Conjunto de datos

En los experimentos realizados se utilizó el conjunto de datos ICL, que es una colección de hojas de la Universidad de Hefei (Intelengine.cn, 2016). El conjunto de datos contiene 16849 imágenes de hojas de 220 especies.

Con el objetivo de realizar un análisis comparativo de los clasificadores y las características extraídas separamos los conjuntos en dos tipos, trivial (cuyas formas pueden ser fácilmente diferenciadas) y complejas (cuyas formas son muy similares entre sí). A partir del conjunto de datos original se obtuvo un conjunto trivial y 11 conjuntos complejos. Los 12 subconjuntos de datos son descritos en la Tabla 1.

El conjunto de hojas trivial contiene hojas muy distintas entre sí, se puede inferir que dada la gran diferencia en las características de forma, el clasificador distinguirá entre una y otra hoja muy fácilmente. Por otro lado, en el conjunto de hojas complejo podría ser un reto para un clasificador distinguir entre una hoja y otras, dado que sus características son muy similares. Sin embargo, es cierto que cada clasificador utiliza técnicas muy distintas que pueden tener variaciones en sus resultados.

El proceso de separación de conjuntos, se realizó de forma manual de acuerdo a las semejanzas y diferencias notables a simple vista. El total de especies asociadas al conjunto trivial fue de 90 de las 220 con las que se contaba. La Figura 1 muestra un ejemplo de hoja de las 90 familias asociadas al conjunto trivial.

Para el conjunto de hojas complejas, se formaron subconjuntos a partir de las hojas que tenían gran similitud pero con diferente clase. A partir de las 220 especies de hojas inicial se formaron 11 subconjuntos distintos con 169 especies. El subconjunto con menos especies contiene solo 3 y el subconjunto con más especies asociadas contiene 37.

La Figura 4 muestra cada subconjunto creado con algunos ejemplos de las familias de hojas que se tomaron para formar cada grupo, además se describe la razón de similitud que se tomó en cuenta para asignar cada hoja y se muestran 3 hojas como ejemplo aunque, el total de cada subconjunto se describe en Familias Asociadas.



#### 4.2. Normalización de datos

El vector final de características  $T$  fue almacenado en una matriz de tamaño  $m \times 393$  que contiene  $m$  imágenes con 393 características. 57 características geométricas, 219 texturales y 117 cromáticas.

Todas las características extraídas fueron normalizadas con la relación:

$$f_{ij} = \frac{T_{ij} - \mu_j}{\sigma_j}$$

donde  $i = 1, \dots, m$  y  $j = 1, \dots, n$ ,  $\mu_j$  y  $\sigma_j T_{ij} = \sigma_j$  representan la media y desviación estándar de la  $j$ -ésima característica,  $T_{ij}$  representa la  $j$ -ésima característica del  $i$ -ésimo vector,  $m$  es el número de imágenes y  $n$  el número de características. Las características normalizadas tienen media cero y desviación estándar igual a 1.

#### 4.3. Selección de parámetros

La selección de parámetros es un paso muy importante, ya que una buena selección de parámetros tiene un efecto considerable en el desempeño del clasificador.

En todos los clasificadores utilizados se obtuvieron los parámetros óptimos mediante validación cruzada y búsqueda de malla.

#### 4.4. Resultados

En los experimentos realizados, todos los conjuntos de datos fueron normalizados y se utilizó validación cruzada con  $k = 10$  para validar resultados, esto es, se realizaron 10 pruebas con 90 % y 10 % de los datos para entrenamiento y prueba respectivamente (los datos de prueba son excluyentes para cada una de las pruebas), el promedio de las 10 pruebas es el que se reporta en este artículo. La Tabla 2 muestra los resultados obtenidos con características geométricas, texturales y cromáticas, cada una como características individuales. En la Tabla 2, CH<sub>i</sub> define el subconjunto de datos de hojas utilizado, *Bayes* representa los resultados obtenidos utilizando el algoritmo Naive Bayes, *BP* representa a los desempeños utilizando el algoritmo de aprendizaje backpropagation, *RL* regresión logística, mientras que *SVM<sub>RBF</sub>*, *SVM<sub>L</sub>* y *SVM<sub>P</sub>* representan los resultados obtenidos con SVM utilizando los kernels RBF, lineal y Polinomial respectivamente. Para cada clasificador utilizado, se reportan las precisiones obtenidas con cada conjunto individual de características. La métrica utilizada para evaluar el desempeño del clasificador fue precisión y esta se obtiene de los aciertos del clasificador entre el total del conjunto de datos.

En los resultados obtenidos, no es posible inferir que la similitud entre hojas afecte significativamente a los clasificadores, pues los resultados mostrados en las Tablas 2, 3 y 4 nos permiten deducir que los desempeños de los clasificadores obtenidos con imágenes muy similares entre sí y disímiles, no son contrastantes. Sin embargo, es posible apreciar que las características texturales son poco discriminativas para la mayoría de los conjuntos de datos, excepto para el conjunto CH<sub>6</sub>. Dos posibles razones son que el tamaño del conjunto de datos es muy pequeño y que aun cuando las hojas son muy parecidas entre sí,

las características obtenidas logran discriminar entre las 3 clases de este conjunto.

La Tabla 3 muestra los resultados obtenidos con combinaciones de características. En los resultados es posible apreciar una mejora en la precisión de clasificación en comparación con los desempeños obtenidos con características no combinadas. Utilizar únicamente características texturales no produce resultados satisfactorios. Sin embargo, cuando son combinadas las características texturales con geométricas o cromáticas, estas obtienen muy buenos desempeños.

La Tabla 4 muestra los resultados obtenidos con todas las características (cromáticas, texturales y geométricas). Sin embargo, se puede notar que utilizar todas las características no precisamente infiere en una buena clasificación, ya que los resultados fueron mejores al utilizar solo características geométricas con cromáticas. Un estudio sobre más exhaustivo utilizando técnicas de selección de características podría ayudar a comprender mejor la influencia de cada característica en el desempeño de los clasificadores.

Tabla 4. Desempeño con características geométricas, texturales y cromáticas.

Subconjunto	Cromáticas-Texturales-Geométricas					
	Bayes	BP	RL	SVM <sub>G</sub>	SVM <sub>L</sub>	SVM <sub>P</sub>
CH.1	91.909	96.207	91.21	98.524	89.34	96.29
CH.2	87.739	90.038	88.41	94.941	86.23	94.67
CH.3	93.797	96.992	95.36	98.882	89.15	97.36
CH.4	90.940	96.253	94.71	97.183	88.22	94.53
CH.5	95.784	98.145	96.18	99.153	95.18	99.25
CH.6	98.742	100	99.48	100	92.70	100
CH.7	98.535	98.954	98.83	99.062	91.74	98.64
CH.8	96.354	98.177	97.74	99.828	91.82	98.03
CH.9	95.196	93.886	92.24	97.893	89.97	96.84
CH.10	90.027	98.292	93.54	98.531	88.95	97.79
CH.11	86.482	93.807	88.26	95.917	81.85	94.58
CH.12	88.488	96.19	91.82	98.526	83.92	97.35

## 5. Conclusiones

En este artículo presentamos un análisis comparativo de la influencia de las características en el desempeño de varios clasificadores. El sistema extrae un conjunto de características basadas en propiedades geométricas, texturales y cromáticas. En los resultados obtenidos se aprecia que una combinación de las diferentes características es necesaria para obtener una buena precisión de clasificación. Aunque no siempre es necesario incluir la combinación de todas las características, ya que algunas de estas afectan la precisión de clasificación. Por lo tanto se debe de hacer una buena combinación de estas. En este trabajo se demostró que para los conjuntos utilizados la mejor combinación son las características geométricas con las características cromáticas.

### English Summary

#### Comparative Analysis of the Techniques Used in a Recognition System of Plant Leaves.

Tabla 3: Desempeño con características cromáticas-texturales, cromáticas-geométricas y texturales-geométricas.

Subconjunto	Cromáticas-Texturales					Cromáticas-Geométricas					Texturales-Geométricas							
	Bayes	BP	RL	SVM <sub>G</sub>	SVM <sub>L</sub>	SVM <sub>P</sub>	Bayes	BP	RL	SVM <sub>G</sub>	SVM <sub>L</sub>	SVM <sub>P</sub>	Bayes	BP	RL	SVM <sub>G</sub>	SVM <sub>L</sub>	SVM <sub>P</sub>
CH_1	87.357	93.426	88.26	94.264	85.52	94.10	92.371	97.242	93.73	97.593	88.41	96.91	86.472	93.805	88.15	95.276	82.49	95.13
CH_2	82.061	84.732	81.82	86.253	80.92	85.08	87.058	90.588	88.69	92.476	81.32	91.78	88.122	91.869	89.04	91.421	84.07	90.53
CH_3	90.413	95.864	90.12	96.421	87.53	95.97	92.51	96.948	94.12	97.93	87.37	95.36	85.150	93.045	83.61	94.285	82.85	93.71
CH_4	87.261	94.005	87.58	95.218	84.31	93.74	91.423	97.262	91.83	95.825	90.82	95.72	84.332	92.370	85.45	94.720	80.45	92.89
CH_5	92.242	95.952	91.34	95.301	88.43	95.39	96.333	95.111	97.43	96.015	90.68	95.16	90.219	94.603	91.46	95.086	86.54	94.79
CH_6	98.742	100	97.75	100	94.25	99.82	98.742	100	98.76	100	91.45	99.83	96.226	99.371	97.90	99.371	89.71	98.58
CH_7	96.861	95.48	96.93	97.289	91.59	96.97	95.853	96.566	95.26	97.717	93.18	96.61	96.380	96.533	95.74	98.760	91.38	97.79
CH_8	95.052	96.135	95.58	96.211	90.18	95.35	96.844	96.211	95.71	97.823	93.55	97.30	96.614	96.697	94.52	96.958	92.89	96.19
CH_9	87.772	91.484	87.04	92.108	83.84	90.82	94.41	95.072	94.91	95.238	91.23	94.89	87.554	92.139	86.35	90.174	83.51	88.65
CH_10	87.748	95.926	88.19	95.332	82.34	95.71	89.77	95.296	91.29	96.163	87.26	95.83	90.505	92.628	90.72	91.939	86.16	90.91
CH_11	80.537	92.569	82.22	93.169	74.61	92.42	83.815	93.889	85.83	94.925	80.19	94.97	84.039	92.655	87.18	92.817	79.86	92.15
CH_12	81.0788	95.342	83.36	95.865	76.38	94.59	87.785	95.233	86.98	96.721	84.59	96.71	86.340	89.204	87.54	93.204	82.04	91.74

**Abstract**

The development of vision systems for identifying plants by leaves is an important challenge which has numerous applications ranging from food, medicine, industry and environment. Recently, several techniques have been proposed in the literature in order to identify plants in various fields of application. However, current techniques are restricted to the recognition and identification of plants using specific descriptors. In this paper, is accomplished a comparative analysis using different methods of feature extraction (textural, chromatic and geometric) and different methods of classification. The experiments are executed on very similar plants. Twelve sets of leaves with similar shape characteristics are studied using several classifiers. The performance of different combinations of classifiers-descriptors are analyzed in detail for each set. The results show that a combination of different feature extraction techniques is necessary in order to improve the performance. This combination of descriptors is more necessary when the leaves have similar characteristics.

*Keywords:*

Classification Descriptors SVM Data Sets

**Agradecimientos**

Agradecemos a los revisores anónimos que permitieron mejorar significativamente este trabajo de investigación. Este estudio fué financiado por la Secretaría de Investigación de la Universidad Autónoma del Estado de México con el proyecto de investigación 3771/2014/CIB.

**Referencias**

Asraf M.H., Nooritawati M.T., Shah Rizam M.S.B., 2012. A Comparative Study in Kernel-Based Support Vector Machine of Oil Palm Leaves Nutrient Disease, *Procedia Engineering*, 41, 1353–1359.  
 DOI: 10.1016/j.proeng.2012.07.321  
 Bernardo J. and Smith A., 1994. *Bayesian Theory*, Wiley.  
 Brandstät A., Van Bang L., 2006. Structure and linear time recognition of 3-leaf powers, *Information Processing Letters*, 98(4), 133–138.  
 DOI: 10.1016/j.ip1.2006.01.004  
 Borges J., Bioucas D.J. and Marçal A., 2011. Bayesian hyperspectral image segmentation with a discriminative class learning. *IEEE Transactions on Geoscience and Remote Sensing*; 49(6), 2151–2164.  
 DOI: 10.1109/TGRS.2010.2097268

Cerutti G., Tougne L., Mille J., Vacavant A., Coquin D., 2013. Understanding leaves in natural images, A model-based approach for tree species identification, *Computer Vision and Image Understanding*, 117(10), 1482–1501.  
 DOI: 10.1016/j.cviu.2013.07.003  
 Chaki, J., Parekh, R., 2012. Designing an automated system for plant leaf recognition, *International Journal of Advances in Engineering Technology*, 2(1), 149–158.  
 DOI: 10.1.1.667.5253  
 Cope J. S., Corney D., Clark J. Y., Remagnino P., Wilkin P., 2012. Plant species identification using digital morphometrics: A review, *Expert Systems with Applications*, 39(8), 7562–7573.  
 DOI: 10.1016/j.eswa.2012.01.073  
 Dempster A., Laird N. and Rubin D., 1977. Maximum likelihood from incomplete data via the EM algorithm. *Journal of the Royal Statistics Society*, 1(39),1–38.  
 DOI: 10.2307/2984875  
 Du J.X., Wang X.F., Zhang G.J., 2007. Leaf shape based plant species recognition, *Applied Mathematics and Computation*, 185 (2), 883–893.  
 DOI: 10.1016/j.amc.2006.07.072  
 Du J.X., Zhai Ch.M., Wang Q.P., 2013. Recognition of plant leaf image based on fractal dimension features, *Neurocomputing*, 116, 150–156.  
 DOI: 10.1016/j.neucom.2012.03.028  
 Flusser, J., Suk, T., 1993. Pattern recognition by affine moment invariants. *Pattern Recognition* 26(1), 167–174.  
 DOI: 10.1016/0031-3203(93)90098-H  
 Gonzalez R.C. and Woods R.E., 2010. *Digital Image Processing Using MATLAB*, Pearson.  
 Gwo Ch.Y., Wei Ch.H., Li Y., 2013. Rotary matching of edge features for leaf recognition, *Computers and Electronics in Agriculture*, 91, 124–134.  
 DOI: 10.1016/j.compag.2012.12.005  
 Haralick R.M., 1979. Statistical and Structural Approaches to Texture. *Proc. IEEE*, 67, 786–804.  
 DOI: 10.1109/PROC.1979.11328  
 Haralick R.M., Shanmugam K. and Dinstein I., 1973. Textural Features for Image Classification. *IEEE Transactions On System, Man Cybernetics*, 6, 610–621.  
 DOI: 10.1109/TSMC.1973.4309314  
 He D.C. and Wang L., 1990. Texture Unit, Texture Spectrum, And Texture Analysis, *Geoscience and Remote Sensing*, *IEEE Transactions on*, 28, 509–512.  
 DOI: 10.1109/IGARSS.1989.575836  
 Hearn D.J., 2009. Shape analysis for the automated identification of plants from images of leaves, *Taxon*, 58, 934–954.  
 Hu M.K., 1962. Visual pattern recognition by moment invariants, *IRE Trans. Inform. Theory*, 8, 179–187  
 DOI: 10.1109/TIT.1962.1057692  
 Hu R., Collomosse J., 2013. A performance evaluation of gradient field HOG descriptor for sketch based image retrieval, *Computer Vision and Image Understanding*, 117(7), 790–806.  
 DOI: 10.1016/j.cviu.2013.02.005  
 Husin Z., Shakaff A.Y.M., Aziz A.H.A., Farook R.S.M., Jaafar M.N., Hashim U., Harun A., 2012. Embedded portable device for herb leaves recognition using image processing techniques and neural network algorithm, *Computers and Electronics in Agriculture*, 89, 18–29.  
 DOI: 10.1016/j.compag.2012.07.009

- Intelligence.cn. (2016). intelengine.cn. [online], Intelligent Computing Laboratory, Chinese Academy of Sciences Homepage. Disponible en <http://www.intelengine.cn/English/dataset/>.
- Jiménez M.E., Sanchez A., Carvajal H., Blanco J., Sáenz J.C., 2013. Emisión Acústica y Redes Neuronales para Modelado y Caracterización del Proceso de Soldadura por Fricción Agitación, *Revista Iberoamericana de Automática e Informática Industrial RIAI*, 10(4), 434–440.  
DOI: 10.1016/j.riai.2013.09.003
- Kadir, A., Nugroho, L. E., Susanto, A., y Santosa, P.I., 2012. Experiments of distance measurements in a foliage plant retrieval system, *International Journal of Signal Processing, Image Processing and Pattern Recognition*, 5, 256–263.
- Kaur, G., y Kaur, G., 2012. Classification of biological species based on leaf architecture, *International Journal of Engineering Research and Development*, 1, 35–42.  
DOI: 10.1.1.642.4983
- Larese M., Namías R., Craviotto R., Arango M., Gallo C., Granitto P.M., 2014. Automatic classification of legumes using leaf vein image features, *Pattern Recognition*, 47(1), 158–168.  
DOI: 10.1016/j.patcog.2013.06.012
- Larese M., Bayá A., Craviotto R., Arango M., Gallo C., Granitto P.M., 2014. Multiscale recognition of legume varieties based on leaf venation images, *Expert Systems with Applications*, Volume 41(10), 4638–4647.  
DOI: 10.1016/j.eswa.2014.01.029
- Liu J., Liu Y., y Yan C., 2008. Feature extraction technique based on the perceptible invariability, *Proceedings of the Fifth International Conference on Fuzzy Systems and Knowledge Discovery*, Shandong, China, 551–554.  
DOI: 10.1109/FSKD.2008.232
- Ma W., Manjunath B., 1996. Texture features and learning similarity, in: *Proceedings of the Conference on Computer Vision and Pattern Recognition (CVPR)*, 425–430.  
DOI: 10.1109/cvpr.1996.517107
- Manjunath B. y Ma W., 1996. Texture features for browsing and retrieval of image data, *IEEE Trans. Pattern Anal. Mach. Intell.* 18, 837–842.  
DOI: 10.1109/34.531803
- Yang M., Kpalma K. and Ronsin J., 2008. A Survey of Shape Feature Extraction Techniques, *Pattern Recognition Techniques*, INTECH Open Access Publisher.
- Ng, A.Y.; Jordan, M.I., 2002. On discriminative vs. generative classifiers: A comparison of logistic regression and naive Bayes. *Advances in Neural Information Processing Systems 14*, MIT-Press, 841–848.
- Nixon M. y Aguado A., 2002. *Feature Extraction and Image Processing*, Academic Press.
- Novotný P., Suk T., 2013. Leaf recognition of woody species in Central Europe, *Biosystems Engineering*, 115(4), 444–452.  
DOI: 10.1016/j.biosystemseng.2013.04.007
- Kumar N., Belhumeur P.N., Biswas A., 2012. Leafsnap: a computer vision system for automatic plant species identification, in: *Proc. ECCV 2012*, 502–516.  
DOI: 10.1007/978-3-642-33709-3\_36
- Park J.S., Kim T.-Y., 2004. Shape-based image retrieval using invariant features, in: K. Aizawa, Y. Nakamura, S. Satoh, (Eds.), *Advances in Multimedia Information Processing-PCM 2004*, Berlin/Heidelberg Lecture Notes in Computer Science, pp. 146–153  
DOI: 10.1007/978-3-540-30542-2\_19
- Portillo E., Cabanes I., Marcos M., Zubizarreta A., 2009. Aplicación de Redes Neuronales en la Detección de Regímenes Degradados en el Proceso Wedm, *Revista Iberoamericana de Automática e Informática Industrial RIAI*, 6(1), 39–50.  
DOI: 10.1016/S1697-7912(09)70075-5
- Rossomando F.G., Soria C., Carelli R., 2010. Control de Robots Móviles con Incertidumbres Dinámicas usando Redes de Base Radial, *Revista Iberoamericana de Automática e Informática Industrial RIAI*, 7(4), 28–35.  
DOI: 10.1016/S1697-7912(10)70057-1
- Rumelhart, D.E.; Hinton, G.E.; Williams, R.J., 1986. Learning representations by back-propagating errors, *Nature*, 323(6088): 533–536.  
DOI: 10.1038/323533a0
- Russell S. y Norvig P., 2003. [1995]. *Artificial Intelligence: A Modern Approach* (2nd ed.). Prentice Hall.
- Sampallo G., 2003. Reconocimiento de tipos de hojas. *Inteligencia Artificial. Revista Iberoamericana de Inteligencia Artificial*, 7(21), 55–62. , Asociación Española para la Inteligencia Artificial España.
- Smeulders A.W.M., Worring M. , Santini S., Gupta A., Jain R., 2000. Content-based image retrieval at the end of the early years, *IEEE Trans. Pattern Anal. Mach. Intell.* 22, 1349–1380.  
DOI: 10.1109/34.895972
- Sonka M., Hlavac V., Boyle R., 1993. *Image Processing, Analysis and Machine Vision*, Springer.
- Tico M., Haverinen T., Kuosmanen P., 2000. A method of color histogram creation for image retrieval, in: *Proceedings of the Nordic Signal Processing Symposium (NORSIG-2000)*, Kolmarden, Sweden, 157–160.
- Valverde R., Gachet D., 2007. Identificación de sistemas dinámicos utilizando redes neuronales RBF, *Revista Iberoamericana de Automática e Informática Industrial RIAI*, 4(2), 32–42.  
DOI: 10.1016/S1697-7912(07)70207-8
- Vapnik V., 1995. *The Nature of Statistical Learning Theory*. Springer.
- Venters C., Cooper D., 2000. *A Review of Content-based Image Retrieval Systems*, Technical Report, Manchester Visualization Centre, Manchester Computing, University of Manchester, Manchester, UK.
- Wang L. y He D., 1990. Texture Classification Using Texture Spectrum, *Pattern Recognition*, 23(8), 905–910.  
DOI: 10.1016/0031-3203(90)90135-8
- Werbos P.J., 1994. *The Roots of Backpropagation. From Ordered Derivatives to Neural Networks and Political Forecasting*. New York, NY: John Wiley Sons, Inc.
- Xia Ch., Lee J, Li Y., Song Y., Chung B., Chon T.S., 2013. Plant leaf detection using modified active shape models, *Biosystems Engineering*, 116(1), 23–35.  
DOI: 10.1016/j.biosystemseng.2013.06.003
- Du J.X., Wang X.F., Zhang G., 2007. Leaf shape based plant species recognition, *Applied Mathematics and Computation*, 185(2), 883–893.  
DOI: 10.1016/j.amc.2006.07.072
- Zhang S., Lei Y.K., 2011. Modified locally linear discriminant embedding for plant leaf recognition, *Neurocomputing*, 74(14), 2284–2290.  
DOI: 10.1016/j.neucom.2011.03.007
- Zhang S., Lei Y., Dong T., Zhang X.P., 2013. Label propagation based supervised locality projection analysis for plant leaf classification, *Pattern Recognition*, 46(7), 1891–1897.  
DOI: 10.1016/j.patcog.2013.01.015