

CLASIFICACIÓN NO SUPERVISADA CON IMÁGENES A COLOR DE COBERTURA TERRESTRE

UNSUPERVISED CLASSIFICATION WITH GROUND COVER COLOR IMAGES

Antonia Macedo-Cruz^{1*}, Gonzalo Pajares-Martinsanz², Matilde Santos-Peñas²

¹Hidrociencias. Campus Montecillo, Colegio de Postgraduados. 56230. Montecillo, Estado de México. (macedoan@colpos.mx). ²Universidad Complutense de Madrid. Ciudad Universitaria, 28040, Madrid, España.

RESUMEN

La cobertura terrestre es un elemento geográfico que constituye la base de referencia para diversas aplicaciones relacionadas con la planificación del uso de los recursos naturales, la biodiversidad y la deforestación, como indicador del cambio climático y la desertificación. Hay diversos métodos para clasificar imágenes, pero no todos son aplicables a la clasificación de la cubierta terrestre. Por tanto, el objetivo de esta investigación fue generar y evaluar un modelo de clasificación no supervisada aplicable a imágenes de cobertura terrestre en modelo de color RGB (Red, Green, Blue; o Rojo, Verde, Azul [RVA]), que clasifique automáticamente las diferentes cubiertas y usos del suelo. La metodología desarrollada corresponde al grupo de procedimientos de clasificación no supervisada y se derivó del criterio de umbralización sugerido por el método de Otsu, basado en la varianza entre clases y dentro de clases. Para aplicarla se usaron fotografías aéreas con resolución espacial de 1:19 500, resolución espectral de tres bandas visibles RVA, y resolución radiométrica de 0 a 255 niveles. Los resultados se compararon con los reportados por un experto conocedor de la zona de estudio. El aporte principal de esta investigación fue generar y evaluar un método de clasificación de imágenes no supervisado de alta precisión y bajo costo computacional; como es el uso alternativo del método de Otsu, utilizado en la segmentación y la clasificación de imágenes a color. Por tanto, el resultado fue un clasificador por agrupamiento no supervisado que reconoce y clasifica hasta 95 % de los elementos identificados en campo por el experto.

Palabras clave: clasificación, modelo de color RGB, método de Otsu, segmentación, umbralización, visión artificial.

ABSTRACT

Ground cover is a geographic element that constitutes the reference base for diverse applications related with planning the use of natural resources, biodiversity and deforestation, as an indicator of climatic change and desertification. There are diverse methods for image classification, but not all of them are applicable to the classification of ground cover. Therefore, the objective of this investigation was to generate and evaluate an unsupervised classification model applicable to ground cover images in color model RGB (Red, Green and Blue), which automatically classifies the different covers and soil uses. The developed methodology corresponds to the group of unsupervised classification procedures and was derived from the thresholding criterion suggested by the Otsu method, based on the variance among and within classes. For its application, aerial photographs were used with spatial resolution of 1:19 500, spectral resolution of three visible RGB bands, and radiometric resolution of 0 to 255 levels. The results were compared with those reported by an expert with knowledge of the zone of study. The principal contribution of this investigation was to generate and evaluate a method of unsupervised image classification of high precision and low computational cost, such as the alternative use of the Otsu method, utilized in the segmentation and classification of color images. Therefore, the result was a classifier by unsupervised clustering which recognizes and classifies up to 95 % of the elements identified in the field by the expert.

Key words: classification, RGB color model, Otsu method, segmentation, thresholding, artificial vision.

INTRODUCTION

The advances in computer systems and remote sensor technology change the form in which geospatial information is gathered, processed and used. Remote sensing and artificial vision are

* Autor responsable ♦ Author for correspondence.

Recibido: Julio, 2009. Aprobado: Julio, 2010.

Publicado como ARTÍCULO en *Agrociencia* 44: 711-722. 2010.

INTRODUCCIÓN

Los avances en informática y tecnología de sensores remotos cambian la forma de recoger, procesar y usar la información geoespacial. La teledetección y la visión artificial son herramientas eficientes para procesar este tipo de información y facilitar el análisis de los datos, permitiendo el seguimiento de los cambios en la superficie terrestre (Chen y Stow, 2003).

Se realizan esfuerzos para desarrollar métodos avanzados de clasificación y segmentación de imágenes y técnicas para mejorar la precisión, pero clasificar datos obtenidos por teledetección es un tema complejo (Chen *et al.*, 2004; Lu y Weng, 2007; Tseng *et al.*, 2008). Esto se debe a que en una imagen de cobertura terrestre se deben considerar objetos con propiedades heterogéneas (Chen *et al.*, 2003).

De acuerdo con el proceso de construcción, los métodos de clasificación de imágenes se dividen en dos grupos (Duda *et al.*, 2001; Bow, 2002; Chuvieco, 2008): 1) supervisado: método de reconocimiento de patrones basado en la existencia de un conjunto de prototipos predefinidos; 2) no supervisado: no requiere conocimiento previo de la zona de estudio y desarrolla la clasificación en forma automática, aprovechando las características espectrales de la imagen para definir las agrupaciones con valores similares.

Los algoritmos de clasificación no supervisada se subdividen en dos grupos: con número de clases conocido y desconocido. El primer grupo incluye el método de las K-medias, el algoritmo de agrupamiento secuencial y el algoritmo ISODATA. En los métodos con número de clases desconocidas se encuentran el adaptativo y el de Batchelor y Wilkins, conocido como de máxima distancia (Bow, 2002).

La clasificación no supervisada aplicada a imágenes de cobertura terrestre la realizaron Du (2007) utilizando el análisis discriminante lineal, y Shah *et al.* (2004) quienes usaron el análisis de componentes independientes, mezclado con modelos como el de las k-medias. La presente investigación está dentro de los métodos de clasificación no supervisada y dentro de los algoritmos de agrupamiento con número de clases desconocidas.

El método de Otsu (1979) en su origen no es un método de clasificación (Pajares y Cruz, 2001) sino de umbralización, aplicable a imágenes en escala de gris; un método no paramétrico que, con base a la

eficiente para procesar este tipo de información y facilitando el análisis de datos, permitiendo la observación de los cambios en la superficie terrestre (Chen y Stow, 2003).

Efforts are made to develop advanced methods of classification and segmentation of images and techniques for improving precision, but the classification of data obtained by remote sensing is a complex theme (Chen *et al.*, 2004; Lu and Weng, 2007; Tseng *et al.*, 2008). This is due to the fact that in a ground cover image, objects with heterogeneous properties should be considered (Chen *et al.*, 2003).

According to the construction process, the image classification methods are divided into two groups (Duda *et al.*, 2001; Bow, 2002; Chuvieco, 2008): 1) supervised: method of pattern recognition based on the existence of a set of predefined prototypes; 2) unsupervised: does not require previous knowledge of the zone of study and develops the classification automatically, using the spectral characteristics of the image to define the clusters with similar values.

The unsupervised classification algorithms are subdivided in two groups: with known and unknown number of classes. The first group includes the method of K-means, the sequential clustering algorithm and the ISODATA algorithm. Among the methods with unknown number of classes are the adaptive method and that of Batchelor and Wilkins, known as maximum distance (Bow, 2002).

Unsupervised classification applied to ground cover images was carried out by Du (2007) utilizing linear discriminating analysis, and Shah *et al.* (2004), who used the analysis of independent components, mixed with models such as that of the k-means. The present investigation is within the unsupervised classification methods and within the clustering algorithms with unknown number of classes.

The Otsu method (1979) in its origin is not a classification method (Pajares and Cruz, 2001), but rather of thresholding, applicable to gray scale images. It is a non-parametric method which based on the variance of the pixel intensity between two classes, calculates the optimum threshold. It has been improved and used with special objectives for the pre-processing of images by Liao *et al.* (2001) and Chen and Fang (2008), who improved the computation time; Du *et al.* (2004) applied it to color video images to extract text while Buxton *et al.* (2007) segmented medical images.

varianza de la intensidad del píxel entre dos clases, calcula el umbral óptimo. Ha sido mejorado y usado con objetivos especiales para el pre-procesamiento de imágenes por Liao *et al.* (2001) y Chen y Fang (2008), quienes mejoraron el tiempo de cómputo; Du *et al.* (2004) lo aplicaron a imágenes de video a color para extraer texto, mientras que Buxton *et al.* (2007) segmentaron imágenes médicas.

El objetivo de esta investigación fue desarrollar un clasificador no supervisado para imágenes de cobertura terrestre a color y clasificar agua, suelo y vegetación, lo cual se logró. Como aporte se obtuvo la expansión del principio de Otsu para la clasificación de imágenes útiles en el inventario de los recursos naturales.

MATERIALES Y MÉTODOS

La zona de estudio corresponde a la cuenca del río La Sabana, estado de Guerrero, México. Los materiales fueron 16 fotografías aéreas a color y en formato digital de octubre de 1997; escala 1:19 500 y resolución radiométrica de 0 a 255 niveles (Figura 1), las cuales se pre-procesaron, clasificaron y evaluaron.

Pre-procesamiento

Para el pre-procesamiento de las imágenes se utilizó el método Otsu (1979), buscando el umbral óptimo (simple o múltiple) para cada una de las bandas de la imagen a color, usando el algoritmo descrito en la Figura 2.

Clasificación no supervisada de imágenes en color

El objetivo del método de clasificación consiste en minimizar las desviaciones entre las observaciones que pertenecen al mismo grupo y maximizar las distancias entre los centros de los grupos, lo cual se representa por la función objetivo de la Ecuación 1.

$$\begin{aligned} t_{Otsu} &= \arg \left\{ \min_{1 \leq t \leq L} \left(Var_{dentro\ de\ clase}^t \right) \right\} \\ t_{Otsu} &= \arg \left\{ \max_{1 \leq t \leq L} \left(Var_{entre\ clases}^t \right) \right\} \end{aligned} \quad (1)$$

Los umbrales obtenidos por cada una de las bandas espectrales, rojo, verde y azul, son identificados por t_r , t_g y t_b .

Cada píxel de la imagen se representa por: $p_{i,j} = (r_{i,j}, g_{i,j}, b_{i,j})^T$ siendo (i, j) la coordenada espacial y usando t_r , t_g y t_b para representar el valor preliminar del umbral de cada dominio de color. Por tanto, un píxel $p_{i,j} = (r_{i,j}, g_{i,j}, b_{i,j})^T$ puede ser umbralizado como

$$\tilde{p}_{i,j} = (\tilde{r}_{i,j}, \tilde{g}_{i,j}, \tilde{b}_{i,j})^T.$$

The objective of this investigation was to develop an unsupervised classifier for ground cover color images and to classify water, soil and vegetation, which was achieved. As a contribution, the expansion of the Otsu principle for the classification of useful images in the inventory of natural resources was obtained.

MATERIALS AND METHODS

The zone of study corresponds to the basin of the La Sabana river, state of Guerrero, México. The material used consisted of 16 aerial color photographs and in digital form from October of 1997; scale 1:19 500 and radiometric resolution of 0 to 255 levels (Figure 1), which were pre-processed, classified and evaluated.

Pre-processing

For pre-processing of the images the Otsu method (1979) was utilized, aiming for the optimum threshold (simple or multiple) for each one of the bands of the color image, using the algorithm described in Figure 2.

Unsupervised classification of color images

The objective of the classification method consists of minimizing the deviations among the observations that pertain to the same cluster and maximizing the distances among the centers of the clusters, which is represented by the objective function of Equation 1.




Figura 1. Imágenes de cobertura terrestre en modelo de color RVA, con distinto tipo de información.

Figure 1. Images of ground cover in RGB color model, with different type of information.




Figura 2. Algoritmo de umbralización simple y múltiple para imágenes a color (A) y método de Otsu (B).
Figure 2. Simple and multiple thresholding algorithm for color images (A) and Otsu method (B).

$$\tilde{r}_{i,j} = \begin{cases} 0 & \text{si } r_{i,j} \leq t_{r1} \\ 1 & \text{si } r_{i,j} > t_{r1} \text{ y } y \leq t_{r2} \\ 2 & \text{si } r_{i,j} > t_{r2} \text{ y } y \leq t_{r3} \\ \vdots & \\ n & \text{si } r_{i,j} > t_{r1} \text{ y } y \leq t_{rM} \end{cases}$$

$$\tilde{g}_{i,j} = \begin{cases} 0 & \text{si } g_{i,j} \leq t_{g1} \\ 1 & \text{si } g_{i,j} > t_{g1} \text{ y } y \leq t_{g2} \\ 2 & \text{si } g_{i,j} > t_{g2} \text{ y } y \leq t_{g3} \\ \vdots & \\ n & \text{si } g_{i,j} > t_{gi} \text{ y } y \leq t_{gM} \end{cases}$$

$$t_{Otsu} = \arg \left\{ \min_{1 \leq i \leq L} \left(\text{Var}_{within\ class}^i \right) \right\}$$

$$t_{Otsu} = \arg \left\{ \max_{1 \leq i \leq L} \left(\text{Var}_{between\ classes}^i \right) \right\}$$

(1)

The thresholds obtained for each one of the spectral bands, red, green and blue, are identified by t_r , t_g and t_b .

Each pixel of the image is represented by: $p_{i,j} = (r_{i,j}, g_{i,j}, b_{i,j})^T$ being (i, j) the spatial coordinate and using t_r , t_g and t_b for representing the preliminary value of the threshold of each color dominion. Therefore, one pixel $p_{i,j} = (r_{i,j}, g_{i,j}, b_{i,j})^T$ can be thresholded as $\tilde{p}_{i,j} = (\tilde{r}_{i,j}, \tilde{g}_{i,j}, \tilde{b}_{i,j})^T$.

$$\tilde{b}_{i,j} = \begin{cases} 0 & \text{si } b_{i,j} \leq t_{b1} \\ 1 & \text{si } b_{i,j} > t_{b1} \text{ y } \leq t_{b2} \\ 2 & \text{si } b_{i,j} > t_{b2} \text{ y } \leq t_{b3} \\ \vdots & \\ n & \text{si } b_{i,j} > t_{bn} \text{ y } \leq t_{bM} \end{cases} \quad (2)$$

Como producto, cada píxel de la fotografía aérea en color puede codificarse por tres bits (c_1, c_2, c_3), donde los valores de c_i ($1 \leq i \leq 3$) pueden ser entre 0 y n , siendo n el número de umbrales obtenidos. El total de píxeles de la imagen se agrupa en $(n+1)^3$ clases, etiquetando cada grupo con un número consecutivo obtenido por la Ecuación 3, donde cada etiqueta representa un grupo de clases:

$$\tilde{p}_{i,j} = c_1(n+1)^2 + c_2(n+1) + c_3 \quad (3)$$

Considerando la k -ésima clase como c_k , para denotar el promedio de cada grupo de clase de una imagen RVA se usa la siguiente expresión: $\mu_k = (r_k, g_k, b_k)^T$, cuyos componentes se obtienen con la Ecuación 4:

$$\begin{aligned} r_k &= \frac{\sum_{r_{i,j} \in C_k} r_{i,j}}{\sum_{r_{i,j} \in C_k} 1} & g_k &= \frac{\sum_{g_{i,j} \in C_k} g_{i,j}}{\sum_{g_{i,j} \in C_k} 1} \\ b_k &= \frac{\sum_{b_{i,j} \in C_k} b_{i,j}}{\sum_{b_{i,j} \in C_k} 1} \end{aligned} \quad (4)$$

La varianza dentro de clases (σ_k) proporcionada por el método de Otsu (1979) se calcula para cada clase $\left(\{C_k\}_{k=1}^{(n+1)^3} \right)$ por la Ecuación 5:

$$\sigma_k = \frac{1}{N_k} \left\{ \sum_{i,j \in C_k} \left[(r_{i,j} - r_k)^2 + (g_{i,j} - g_k)^2 + (b_{i,j} - b_k)^2 \right] \right\}^{1/2} \quad (5)$$

donde, N_k es el número de píxeles de la clase C_k .

La varianza entre dos clases ($\sigma_{k,j}$), denotadas por C_k y C_j , con k diferente de j :

$$\tilde{r}_{i,j} = \begin{cases} 0 & \text{si } r_{i,j} \leq t_{r1} \\ 1 & \text{si } r_{i,j} > t_{r1} \text{ y } \leq t_{r2} \\ 2 & \text{si } r_{i,j} > t_{r2} \text{ y } \leq t_{r3} \\ \vdots & \\ n & \text{si } r_{i,j} > t_{rn} \text{ y } \leq t_{rM} \end{cases}$$

$$\tilde{g}_{i,j} = \begin{cases} 0 & \text{si } g_{i,j} \leq t_{g1} \\ 1 & \text{si } g_{i,j} > t_{g1} \text{ y } \leq t_{g2} \\ 2 & \text{si } g_{i,j} > t_{g2} \text{ y } \leq t_{g3} \\ \vdots & \\ n & \text{si } g_{i,j} > t_{gn} \text{ y } \leq t_{gM} \end{cases}$$

$$\tilde{b}_{i,j} = \begin{cases} 0 & \text{si } b_{i,j} \leq t_{b1} \\ 1 & \text{si } b_{i,j} > t_{b1} \text{ y } \leq t_{b2} \\ 2 & \text{si } b_{i,j} > t_{b2} \text{ y } \leq t_{b3} \\ \vdots & \\ n & \text{si } b_{i,j} > t_{bn} \text{ y } \leq t_{bM} \end{cases} \quad (2)$$

As product, each pixel of the aerial color photograph can be coded by three bits (c_1, c_2, c_3), where the values of c_i ($1 \leq i \leq 3$) can be between 0 and n , being n the number of thresholds obtained. The total of pixels of the image is grouped in $(n+1)^3$ classes, labeling each group with a consecutive number obtained through Equation 3, where each label represents a group of classes:

$$\tilde{p}_{i,j} = c_1(n+1)^2 + c_2(n+1) + c_3 \quad (3)$$

Considering the k -th class as c_k , to denote the average of each class group of a RGB image, the following expression is used: $\mu_k = (r_k, g_k, b_k)^T$, whose components are obtained with Equation 4:

$$\begin{aligned} r_k &= \frac{\sum_{r_{i,j} \in C_k} r_{i,j}}{\sum_{r_{i,j} \in C_k} 1} & g_k &= \frac{\sum_{g_{i,j} \in C_k} g_{i,j}}{\sum_{g_{i,j} \in C_k} 1} \\ b_k &= \frac{\sum_{b_{i,j} \in C_k} b_{i,j}}{\sum_{b_{i,j} \in C_k} 1} \end{aligned} \quad (4)$$

The variance within classes (σ_k) provided by the Otsu method (1979) is calculated for each class $\left(\{C_k\}_{k=1}^{(n+1)^3} \right)$ by Equation 5:

$$\sigma_{k,j} = \left((r_k - r_j)^2 + (g_k - g_j)^2 + (b_k - b_j)^2 \right)^{1/2} \quad (6)$$

donde, (r_k, g_k, b_k) , (r_j, g_j, b_j) son definidos por la Ecuación 4 y los promedios espectrales de la clase C_k y C_j corresponden al dominio de color RVA.

Con base en las varianzas obtenidas con las ecuaciones (5) y (6), se pueden fusionar algunas agrupaciones debido a sus similitudes espectrales. Considerando que las clases C_j y C_k , para $k \neq j$, se fusionan si $\sigma_k \geq \sigma_{kj}$ o $\sigma_j \geq \sigma_{kj}$. Esto se debe a que la varianza entre dos clases σ_{kj} debe ser superior a la varianza dentro de las clases individuales σ_k y σ_j .

Este proceso de reagrupamiento se repite hasta que todas las varianzas entre clases sean mayores que sus correspondientes varianzas dentro de clase, en cuyo caso el resultado podría ser no reclasificar.

Si no hubo reclasificación y el número de clases totales es igual a $(n+1)^3$, entonces el clasificador repite todo el proceso, y se incrementa en uno el número de umbrales a calcular; de lo contrario, se etiquetan las clases reagrupadas como clases definitivas.

Evaluación de la precisión

La precisión de un proceso de clasificación se refiere al grado de concordancia entre las clases de la imagen y un conjunto de datos de referencia (Congalton y Green, 1999). Para hacer una estimación cuantitativa se construyó una matriz de error difusa (Congalton y Green, 2009; Lunetta y Lyon, 2004), la cual es un arreglo cuadrado de números ordenados en columnas e hileras. Las columnas corresponden al conjunto de referencia, y las hileras a las clases generadas en el proceso de clasificación. Cada celda contiene dos valores: el primero representa las etiquetas aceptables; el segundo indica las etiquetas inaceptables y la diagonal principal sólo contiene las etiquetas consideradas absolutamente correctas.

Los valores de la diagonal principal de la matriz de error, donde coinciden las etiquetas de referencia y clasificación, corresponden a los aciertos del proceso. La precisión global de la clasificación se obtiene dividiendo la suma de los valores de la diagonal principal entre el tamaño de la muestra.

La precisión del usuario es un indicador de errores de omisión y se calcula dividiendo el número de aciertos por el total de muestras en la hilera correspondiente.

La precisión del productor del mapa es un indicador de errores de inclusión y se calcula dividiendo el número de aciertos entre el número total de muestras en la columna. La matriz de error difusa cuenta con dos valores por celda: el valor izquierdo significa aceptable (polígonos en los cuales más del 50 % de los píxeles corresponden a dicha clase); los de la derecha son los píxeles clasificados como una clase de cobertura a la que no pertenece.

$$\sigma_k = \frac{1}{N_k} \left\{ \sum_{i,j \in C_k} \left[(r_{i,j} - r_k)^2 + (g_{i,j} - g_k)^2 + (b_{i,j} - b_k)^2 \right] \right\}^{1/2} \quad (5)$$

where N_k is the number of pixels of class C_k .

The variance between two classes (), denoted by C_k and C_j , with k different from j :

$$\sigma_{k,j} = \left((r_k - r_j)^2 + (g_k - g_j)^2 + (b_k - b_j)^2 \right)^{1/2} \quad (6)$$

where (r_k, g_k, b_k) , (r_j, g_j, b_j) are defined by Equation 4 and the spectral averages of class C_k and C_j correspond to the RGB color dominion.

Based on the variances obtained with equations (5) and (6), some clusters can be fused due to their spectral similarities. Considering that the classes C_j and C_k for $k \neq j$, they are fused if $\sigma_k \geq \sigma_{kj}$ or $\sigma_j \geq \sigma_{kj}$. This is due to the fact that the variance between two σ_{kj} classes should be higher than the variance within the individual classes σ_k and σ_j .

This regrouping process is repeated until all of the variances among classes are higher than their corresponding variances within class, in which case the result could be to not reclassify.

If there were no reclassification and the total number of classes is equal to $(n + 1)^3$, then the classifier repeats the entire process, and increases in one the number of thresholds to calculate; otherwise the regrouped classes are labeled as definitive classes.

Evaluation of precision

The precision of a classification process refers to the degree of concordance among the classes of the image and a set of reference data (Congalton and Green, 1999). To make a quantitative estimation a diffuse error matrix was constructed (Congalton and Green, 1999; Lunetta and Lyon, 2004), which is a quadratic arrangement of numbers ordered in columns and rows. The columns correspond to the reference set, and the rows to the classes generated in the classification process. Each cell contains two values; the first value of the cell represents the acceptable labels, the second indicates the unacceptable labels, and the principal diagonal only contains the labels considered absolutely correct.

The values of the principal diagonal of the error matrix, where the reference and classification labels coincide, correspond to the correct results of the process. The global precision of the classification is obtained by dividing the sum of the values of the principal diagonal by the size of the sample.

La matriz de error se construyó a partir de los resultados de la clasificación y los datos tomados del muestreo de campo se consideraron como datos de referencias, con la participación de un experto conocedor de la zona de estudio (Villegas *et al.*, 2009) y la experiencia de los autores. También se consideró la clasificación de uso de suelos hecha por Villegas (2006), tomando polígonos como unidad de muestreo, seleccionados de manera aleatoria estratificada. El tamaño de la muestra se estimó de acuerdo con Congalton y Green (2009), mediante una distribución multinomial (95 % y 5 % de nivel de confianza y precisión), la cual tiene la siguiente expresión:

$$n = B\Pi_i(1 - \Pi_i) / b_i^2 \quad (7)$$

donde, la variable Π_i es la fracción de superficie correspondiente a la clase i ; B es el coeficiente determinado mediante una tabla de chi-cuadrada, con un grado de libertad y $1 - \alpha/k$, dado que k es el número de clases o categorías; y b es la precisión deseada ($b=0.05$).

RESULTADOS Y DISCUSIÓN

Los resultados se relacionan con el pre-procesamiento, clasificación y evaluación de la precisión del clasificador aplicado a las imágenes de la Figura 1. De acuerdo con la información mostrada en la Figura 1 (A) se desarrolló el pre-procesamiento de imágenes permitiendo segmentar la información de cada banda en dos grupos (Figura 3), cuyo contenido por grupo se reporta en el Cuadro 1. De la segmentación resultó una imagen RVA constituida por ocho grupos de información (Figura 4 A), permitiendo continuar con su clasificación.

La clasificación se logró mediante el análisis exhaustivo de las varianzas entre clases y dentro de clases, para reagrupar y clasificar los objetos presentes. Con este proceso se obtuvo seis clases de objetos identificados con distinto color (Figura 4 B), cuyo porcentaje de cobertura se muestra en el Cuadro 2.

La imagen de la Figura 1(B), con 375 452 píxeles y mayor diversidad de objetos fue procesada por el mismo método que la Figura 1 (A), pero en este caso al no presentarse reagrupación, el clasificador recurrió automáticamente a la multi-umbralización. Se obtuvieron dos umbrales por banda lo que genera un modelo de agrupación de 3^3 grupos, los cuales al ser clasificados se convierten en nueve clases de objetos (Figura 5 b), cuyo color y porcentaje de cobertura se muestra en el Cuadro 3.

The precision of the user is an indicator of errors of omission and is calculated by dividing the number of correct results by the total of samples in the corresponding row.

The precision of the map producer is an indicator of errors of inclusion and is calculated by dividing the number of correct results by the total number of samples in the column. The diffuse error matrix has two values per cell: the left value indicates acceptable (polygons in which more than 50 % of the pixels correspond to this class); those of the right are the pixels classified as cover class to which it does not belong.

The error matrix was constructed from the results of the classification and the data taken from the field sampling were considered as reference data, aided by the participation of an expert familiar with the zone of study (Villegas *et al.*, 2009) and the experience of the authors. The classification of soil use of Villegas (2006) was also considered, taking polygons as sampling unit, with a random and stratified selection. The size of the sample was estimated according to Congalton and Green (2009), through a multinomial distribution (95 % and 5 % of confidence level and precision), which has the following expression:

$$n = B\Pi_i(1 - \Pi_i) / b_i^2 \quad (7)$$

where the variable Π_i is the fraction of surface corresponding to class i ; B is the coefficient determined by means of a chi-squared table, with a degree of freedom and $1 - \alpha/k$, given that k is the number of classes or categories; and b is the desired precision ($b=0.05$).

RESULTS AND DISCUSSION

The results are related to the pre-processing, classification and evaluation of the precision of the classifier applied to the images of Figure 1. According to the information shown in Figure 1 (A) the pre-processing of images was developed, making it possible to segment the information of each band in two groups (Figure 3), whose content per group is reported in Table 1. The segmentation provided a RGB image constituted by eight groups of information (Figure 4 A), thus allowing the continuation of its classification.

The classification was achieved by means of the exhaustive analysis of the variances among classes and within classes, to regroup and classify the objects present. This process allowed to obtain six classes of objects identified with different color (Figure 4B), whose percentage of cover is shown in Table 2.




Figura 3. Imagen umbralizada por el método de Otsu (1979). Banda 1 (A), banda 2 (B), banda 3 (C).
Figure 3. Image thresholded by the Otsu method (1979). Band 1 (A), band 2 (B), band 3 (C).

Cuadro 1. Umbralización por el método de Otsu.
Table 1. Thresholding by the Otsu method.

Número de banda	Grupo 1 (color azul, Figura 3)	Grupo 2 (color negro, Figura 3)
Banda 1 (Rojo)	Suelos desnudo y con poca cubierta vegetal	Área con mayor cubierta vegetal
Banda 2 (Verde)	Pastos y suelos desnudos	Árboles y cuerpos de agua
Banda 3 (Azul)	Suelos desnudos	Pastos, árboles y cuerpos de agua

La precisión global obtenida en la clasificación de las imágenes de la Figura 1 (A) y (B) varió de 83 % a 84 % como exactitud determinista y de 93 % a 95 % como exactitud difusa. En el Cuadro 4 y 5 se presenta la precisión del productor y del usuario para cada una

The image of Figure 1(B), with 375 452 pixels and higher diversity of objects was processed by the same method as Figure 1 (A), but in this case in the absence of regrouping, the classifier automatically recurred to multi-thresholding. Two thresholds were




Figura 4. Imagen segmentada (A), e imagen clasificada (B).
Figure 4. Segmented image (A), and classified image (B).

Cuadro 2. Distribución de la clasificación de la Figura 4.
Table 2. Distribution of the classification of Figure 4.

C_k	Clases en la Figura 1 (a)	A-Px	Cobertura (%)	Color
1	Vegetación arbórea	752 664	50	Azul
2	Cuerpos de agua	34 346	2	Gris y verde-azul
3	Pasto cultivado de altura media	250 395	17	Rojo
4	Pasto corto poco denso	18 649	1	Amarillo
5	Pastos cortos	164 539	11	Rosa
6	Sin cobertura vegetal y sedimentos	285 797	19	Blanco

C_k : número de clase de cobertura terrestre. A-Px: área en píxeles.

de las clases, calculadas por el método determinista y difuso, mediante la matriz de error difuso, para los cuales el tamaño de la muestra fue de 354 y 274 polígonos. La ventaja del enfoque de la matriz de error difuso es que combina toda la potencia de la matriz de error, para calcular tanto la exactitud determinista como la exactitud difusa.

El clasificador usado confunde los cuerpos de agua poco profundos con los pastos, debido a que las firmas espectrales son muy parecidas. No es un problema exclusivo de este algoritmo de clasificación, ya que Zhu *et al.* (2000) señalan dificultades para clasificar cuerpos de agua y bosque usando imágenes aéreas. Polidório *et al.* (2003) y Rowe and Grewe (2001) reportan el mismo problema al separar los cuerpos de agua y las sombras, y Saeed (2006) lo indica al clasificar los cuerpos de agua poco profundos.

obtained per band which generates a clustering model of 3^3 groups, which when classified are converted to nine classes of objects (Figure 5 b), whose color and percentage of cover are shown in Table 3.

The global precision obtained in the classification of the images of Figure 1 (A) and (B) varied from 83 % to 84 % as deterministic exactness and from 93 % to 95 % as diffuse exactness. In Table 4 and 5 it is shown the precision of the producer and the user for each one of the classes, calculated by the deterministic and diffuse method, through the fuzzy error matrix, for which the size of the sample was 354 and 274 polygons. The advantage of the focus of the fuzzy error matrix is that it combines all of the power of the error matrix to calculate both the deterministic exactness and the fuzzy exactness.

The classifier that was used confuses the shallow bodies of water with the grasses, due to the fact that the spectral signatures are very similar. This is not




Figura 5. Imagen pre-procesada (A), y clasificada (B) por el método de Otsu.

Figure 5. Image pre-processed (A), and classified (B) by the Otsu method.

Cuadro 3. Distribución de la clasificación de la Figura 5.
Table 3. Distribution of the classification of Figure 5.

C_k	Clases en la Figura 1 (B)	A-Px	Cobertura (%)	Color
1	Árboles	102 528	27	Azul
2	Montículos de arena húmeda	22 404	6	Naranja
3	Pastos de altura media	26 564	7	Rosa
4	Cuerpos de agua	6 469	2	Verde-azul
5	Pasto alto	12 975	3	Rojo
6	Pastos cortos	137 392	37	Blanco
7	Pasto corto poco denso	23 238	6	Café
8	Pasto seco	14 227	4	Verde
9	Zonas sin cobertura vegetal	29 655	8	Azul marino

C_k : número de clase de cobertura terrestre. A-Px: área en píxeles.

Cuadro 4. Matriz de error difuso (Fuzzy) de la clasificación de la de cobertura terrestre, representada en la Figura 1(A).
Table 4. Fuzzy error matrix of the classification of the ground cover, represented in Figure 1 (A).

		Referencia					Precisión del usuario				
		Árboles	Cuerpos de agua	Pasto de altura media	Pasto natural	Pastos cortos	Zonas sin cobertura vegetal	Determinista		Fuzzy	
								Total	Por ciento	Total	Por ciento
Clasificación	Árboles	126	0.3	1.1	0.0	2.0	0.0	126/133	94 %	129/133	97 %
	Cuerpos de agua	0.0	8	0.0	0.0	0.0	0.0	8/8	100 %	8/8	100 %
	Pasto de altura media	0.0	3.3	61	1.1	15.14	0.0	61/98	62 %	80/98	82 %
	Pastos corto poco denso	0.0	0.0	0.0	4		0.0	4/4	100 %	4/4	100 %
	Pastos cortos	0.0	0.0	13.2	0.0	18	1.1	18/34	53 %	32/34	94 %
Zonas sin cobertura vegetal		0.0	0.0	0.0	0.0	0.0	77	77/77	100 %	77/77	100 %
Precisión del productor								Precisión general Determinista Fuzzy 294/354 83 % 330/354 93 %			
Total determinista		126/126	8/17	61/78	4/6	18/49	77/78				
Porcentual determinista		99 %	44 %	77 %	67 %	36 %	97 %				
Total Fuzzy		126/126	11/17	75/78	5/6	35/49	78/78				
Porcentual Fuzzy		99 %	65 %	96 %	83 %	71 %	100 %				

CONCLUSIONES

El método de Otsu mejorado y las modificaciones implementadas en esta investigación permiten obtener el valor de umbral óptimo como base para segmentar y clasificar imágenes en modelo a color, mediante el método de clasificación no supervisada.

a problem exclusive to this classification algorithm, given that Zhu *et al.* (2000) indicate difficulties for classifying bodies of water and forest using aerial images. Polidório *et al.* (2003) and Rowe and Grewe (2001) report the same problem when separating the bodies of water and the shadows, and Saeed (2006) mention this problem when classifying shallow bodies of water.

Cuadro 5. Matriz de error difuso (Fuzzy) de la clasificación de cobertura terrestre, representada en la Figura 1(B).
Table 5. Fuzzy error matrix of the classification of ground cover, represented in Figure 1 (B).

		Referencia								Precisión del usuario				
Clasificación		Árboles	Pasto seco	Pasto alto	Cuerpos de agua	Pasto de altura media	Pasto corto	Pasto corto poco denso	Mon-tículo de arena húmeda	Zonas sin cobertura vegetal	Determinista		Fuzzy	
		Total	Por ciento	Total	Por ciento									
	Árboles	70	0.3	1.1	0.0	2.0	0.0	0.0	0.0	0.0	70/73	96 %	72/73	99 %
	Pasto seco	0.0	11	0.0	0.0	0.0	0.0	0.0	0.0	0.0	11/17	65 %	15/17	88 %
	Pasto total	0.0	0.0	5	0.0	0.0	0.0	0.0	0.0	0.0	5/5	100 %	5/5	100 %
	Cuerpos de agua	0.0	0.0	0.0	7	0.0	0.0	0.0	0.0	0.0	7/9	78 %	9/9	100 %
	Pasto de altura media	0.0	0.0	0.0	0.0	14	0.0	0.0	0.0	0.0	14/23	61 %	20/23	87 %
	Pastos cortos	0.0	0.0	0.0	0.0	0.0	70	0.0	0.0	0.0	70/90	78 %	83/90	92 %
	Pastos corto poco denso	0.0	0.0	0.0	0.0	0.0	0.0	10	0.0	0.0	10/10	100 %	10/10	100 %
	Montículo de arena húmeda	0.0	0.0	0.0	0.0	0.0	0.0	0.0	18	0.0	18/20	90 %	19/20	95 %
Zonas sin cobertura vegetal	0.0	2.0	0.0	0.0	0.0	0.0	0.0	0.0	25	25/27	93 %	27/27	100 %	
Precisión del productor										Precisión general				
Total determinista	70/70	11/13	5/13	7/8	14/23	70/81	10/21	18/20	25/25	Determinista		Fuzzy		
Porcentual determinista	100 %	85 %	38 %	88 %	61 %	86 %	48 %	90 %	100 %	230/274	84 %	260/274	95 %	
Total Fuzzy	70/70	13/13	9/13	8/8	22/23	77/81	16/21	20/20	25/25					
Porcentual Fuzzy	100 %	100 %	69 %	100 %	96 %	95 %	76 %	100 %	100 %					

Bajo el principio de varianza ente clases y dentro de clases, es posible reagrupar y fusionar automáticamente diferentes valores de las agrupaciones obtenidas a partir de la imagen en dominio de color Rojo, Verde, Azul. El resultado del proceso de reagrupación permite al clasificador extender la técnica de umbralización simple a multi-umbralización de imágenes a color.

Las imágenes procesadas en esta investigación permiten identificar hasta nueve clases de cobertura terrestre, con una precisión global del 95 % calculada mediante la matriz de error difuso. Además, la metodología evaluada clasifica las imágenes a color con 5 % de incertidumbre, con respecto a los cuerpos de agua someros y los pastos.

AGRADECIMIENTOS

Los autores agradecen el apoyo de la Fundación Carolina (España) y la Secretaría de Relaciones Exteriores-(México), por el co-financiamiento de beca para estudios doctorales en la Universidad Complutense de Madrid, España, así como al Colegio

CONCLUSIONS

The improved Otsu method and the modifications implemented in this investigation make it possible to obtain the value of the optimum threshold as base for segmenting and classifying in color model, by means of the unsupervised classification method.

Under the principle of variance among classes and within classes, it is possible to regroup and automatically fuse different values of the clusterings obtained from the image in the color domain Red, Green, Blue. The result of the regrouping process permits the classifier to extend the simple thresholding technique to multi-thresholding of color images.

The images processed in this investigation make it possible to identify up to nine classes of ground cover, with a global precision of 95 % calculated through the fuzzy error matrix. On the other hand, the methodology evaluated classifies color images with 5 % uncertainty, with respect to the shallow bodies of water and the grasses.

de Postgraduados por el apoyo brindado a través del Subprograma de Formación de Profesores Investigadores; además al Instituto de Geografía de la Universidad Autónoma de México por permitir el uso de las fotografías aéreas. Al Dr. Isidro Villegas Romero por permitir utilizar sus resultados del muestreo de campo para la validación del clasificador.

LITERATURA CITADA

- Bow, S. T. 2002. Pattern Recognition and Image Preprocessing. 2nd ed. Marcel Dekker. New York, NY, USA. 698 p.
- Buxton, B. F., H. Abdallahi, D. Fernandez-Reyes, and W. Jarra. 2007. Development of an extension of the Otsu algorithm for multidimensional image segmentation of thin-film blood slides. *In: International Conference on Computing: Theory and Applications (ICCTA'07)*. Washington, DC, USA. IEEE computer society. pp:552-562.
- Chen, D., and D.A. Stow. 2003. Strategies for integrating information from multiple spatial resolutions into land-use/land-cover classification routines. *Photogrammetric Eng. and Remote Sensing* 69:1279-1287.
- Chen, D., D.A. Stow, and P. Gong, P., 2004, Examining the effect of spatial resolution and texture window size on classification accuracy: an urban environment case. *Int. J. Remote Sensing* 25:2177-2192.
- Chen, Q., J. Luo, and C. Zhou. 2003. A geostatistic based segmentation approach for remotely sensed images. *In: 24th Asian Conference on Remote Sensing*, Busan, South Korea. pp:3.
- Chen, W., and K. Fang. 2008. Multilevel thresholding algorithm based on particle swarm optimization for image segmentation. *In: Control Conference*, 27th Chinese. Kunming, Yunnan, China, pp:348-351.
- Congalton, R. G., and K. Green, 1999. Assessing the Accuracy of Remotely Sensed Data: Principles and Practices. Lewis Publishers, Boca Raton, FL. 160 p.
- Congalton, R. G., and K. Green, 2009. Assessing the Accuracy of Remotely Sensed Data: Principles and Practices. 2d ed. CRC/Taylor & Francis, Boca Raton, FL. 178 p.
- Chuvieco, E. 2008. Teledetección Ambiental. 3a ed. Ariel. Barcelona, España. 592 p.
- Du, Q. 2007. Unsupervised real-time constrained linear discriminant analysis to hyperspectral image classification. *Pattern Recognition* 40(5):1510-1519.
- Du, Y., C. I. Chang, and P.D. Thouin. 2004. Unsupervised approach to color video thresholding. *Optical Eng.* 43(2):282-289.
- Duda, R.O., P.E. Hard, and D.G. Stork. 2001. Pattern Classification. 2nd ed. John Wiley. New York, NY, USA. 654 p.
- Liao, P.S., T.S. Chen, and P.C. Chung. 2001. A fast algorithm for multilevel thresholding. *J. Comput. Information Sci. Eng.* 17:713-727.
- Lu, D., and Q. Weng. 2007. A survey of image classification methods and techniques for improving classification performance. *Int. J. Remote Sensing* 28(5):823-870.
- Lunetta, R. S., and J. G. Lyon. 2004. Remote Sensing and GIS Accuracy Assessment. Lewis Publishers, Boca Raton, FL. 292 p.
- Otsu, N. 1979. A threshold selection method from gray-level histogram. *IEEE Trans. on System Man Cybernetics* 9(1):62-66.
- Pajares, M, G., y M. de la Cruz. 2001. Visión por Computador, Imágenes Digitales y Aplicaciones. Rama, Madrid, España. 764 p.
- Polidório, A M., F. C. Flores, N. N. Imai, A. M. G. Tommaselli, and C. Franco. 2003. Automatic shadow segmentation in aerial color images. *Sibgrapi. XVI Brazilian Symposium on Computer Graphics and Image Processing (SIBGRAPI'03)*. pp: 270.
- Rowe, N. C, and L.L. Grewe. 2001. Change detection for linear features in aerial photographs using edge-finding. *IEEE Trans. Geosci. Remote Sensing* 39:1608-1612.
- Saeed, F. 2006. Digital image processing of high resolution aerial photograph of shallow marine sanctuary. Victoria, Australia. *Advances in Space Technologies, International Conference*. pp:179-184.
- Shah, C. A., M. K. Arora, and P. K. Varshney. 2004. Unsupervised classification of hyperspectral data: an ICA mixture model based approach. *Int. J. Remote Sensing* 25:481-487.
- Tseng, M. H., S. J. Chen, G. H. Hwang, and M. Y. Shen. 2008. A genetic algorithm rule-based approach for land-cover classification. *J. Photogrammetry and Remote Sensing* 63(2):202-212.
- Villegas R, I. 2006. Degradación del suelo por impacto del huracán Paulina, en la cuenca del río La Sabana, Guerrero. Tesis doctoral. Colegio de Postgraduados. México. pp:71-96.
- Villegas R, I., J. L. Oropeza, M. Martinez, y E. Mejía 2009. Trayectoria y relación lluvia-escurrimiento causados por el huracán Paulina en la cuenca del río La Sabana, Guerrero, México. *Agrociencia* 43: 345-356.
- Zhu, B., M. Ramsey, and H. Chen. 2000. Creating a large-scale content-based airphoto image digital library. *IEEE Trans Image Process* 9(1):163-167.