

Método para identificación de cultivos de arroz (*Oryza sativa* L.) con base en imágenes de satélite

Satellite image based method for rice (*Oryza sativa* L.) crop identification

Sergio Andrés García J.¹ y Luis Joel Martínez M.^{1,2}

RESUMEN

La presente investigación desarrolló un método de identificación de cultivos de arroz en algunas áreas de los departamentos de Cundinamarca y Tolima (Colombia), mediante imágenes de satélite Landsat 7 ETM+ y ASTER. El método integra diversos procesos, a saber: pre-procesamiento de imágenes; elaboración de máscaras basadas en valores de NDVI y de textura promedio, a través de procedimientos de lógica difusa; procesamiento digital mediante análisis de componentes principales; extracción de *endmembers* mediante visualizador n-dimensional; clasificación de coberturas por SAM, y evaluación de resultados. El método permitió identificar los cultivos de arroz con una exactitud global superior al 70% y valores kappa entre 0,45 y 0,74. Esto permite considerarlo como una buena estrategia de generación de información sobre áreas cultivadas cuando se busca apoyar la toma de decisiones en la agricultura.

Palabras clave: NDVI, endmember, SAM, textura promedio.

ABSTRACT

A method for identifying rice crops through Landsat 7 ETM+ and ASTER satellite images was developed in some areas of the departments of Cundinamarca and Tolima (Colombia). The method integrates image preprocessing, creation of NDVI and average texture data based masks by means of fuzzy logic; digital processing through principal component analysis; endmember extraction through n-dimensional display; SAM classification of coverage areas, and evaluation of results. The method allowed the identification of rice crops with a global accuracy of more than 70% and appropriate kappa values (*i.e.*, ranging from 0.45 to 0.74). Based on the results, the method can be said to constitute a good approach to the generation of cropping area information intended to support decision making in agriculture.

Key words: NDVI, endmember, SAM, average texture.

Introducción

Para lograr los objetivos de la competitividad y la sostenibilidad del sector agrícola es fundamental contar con información confiable, oportuna y pertinente sobre los cultivos, en aspectos como ubicación, extensión, distribución espacial, relaciones entre los tipos de uso, entre otros. El uso de imágenes de sensores remotos en la agricultura se ha planteado como una alternativa para obtener datos cuantitativos que permiten ubicar y caracterizar los cultivos con el fin de tomar decisiones para la planificación y el manejo. En los últimos años, debido al gran avance en el desarrollo de los sensores remotos en cuanto al número de sistemas disponibles, la resolución espacial, espectral y temporal y la tendencia a disminuir el costo, ha surgido un número mayor de aplicaciones que van desde la identificación y el monitoreo de cultivos, estado nutricional, manejo del agua, manejo sanitario, predicción de cosechas (Jensen, 2000, French *et al.*, 2008; García-Torres *et al.*, 2008)

recursos genéticos, zonificación de aptitud de tierras, hasta la agricultura de precisión, entre otras (Martínez, 2006; Breckling *et al.*, 2009; Muñoz *et al.*, 2009). En Colombia, el uso de los datos provenientes de sensores remotos ha sido aplicado principalmente en estudios de cobertura vegetal en los cuales los cultivos se agrupan como una clase general; en consecuencia, son pocos los trabajos enfocados a la diferenciación de cultivos y a la obtención de información aplicable específicamente a la agricultura.

Las imágenes de satélite se han utilizado como fuentes de datos en diversos proyectos agrícolas donde el arroz (*Oryza sativa* L.) es un componente importante. Xiao *et al.* (2006) utilizaron imágenes del sensor MODIS para detectar cambios y evaluar la expansión de los cultivos de arroz bajo riego en 13 países de Asia, y encontraron que a escala nacional hubo alta correlación con los datos de las estadísticas oficiales y menores correlaciones al nivel sub-nacional. También se emplearon para evaluar el aumento

Fecha de recepción: 7 de diciembre de 2009. Aceptado para publicación: 28 de julio de 2010

¹ Departamento de Agronomía, Facultad de Agronomía, Universidad Nacional de Colombia, Bogotá (Colombia).

² Autor de correspondencia. ljmartinezm@unal.edu.co

de áreas cultivadas en arroz mediante análisis de series de tiempo en Vietnam (Sakamoto, 2009). Las imágenes Landsat se utilizaron para identificar cultivos de arroz y estimar áreas en el Japón, donde se presentó confusión con algunos algoritmos en algunos sitios, mientras que los índices entre las bandas 4 y 5 permitieron una buena discriminación de los cultivos de arroz (Ishiguro *et al.*, 1993); igualmente en China se han utilizado imágenes Landsat con el apoyo de otros datos para estudiar el desarrollo agrícola (Welch y Pannell, 1982).

El principio físico de la percepción remota se basa en la ley de la conservación de la energía, mediante la cual una vez la energía llega a la superficie de la Tierra, una parte es absorbida, otra transmitida y otra reflejada. Durante la transmisión a través de un objeto la energía es absorbida selectivamente por los componentes químicos del objeto y luego es reflejada. En el caso de las plantas, la energía transmitida a una hoja sufrirá una absorción selectiva por los pigmentos de la hoja como la clorofila y luego será reflejada desde las paredes celulares (McCloy, 1995). Estas características son la base para identificar los objetos mediante sensores que pueden captar la energía reflejada por los cuerpos y convertirla en valores digitales. En particular, las imágenes de satélite almacenan las señales espectrales en diferentes longitudes de onda, y después de diversos análisis se efectúa la interpretación; de allí se obtiene la información sobre las características y los tipos de objeto presentes en el área de estudio

Aunque en otros países existen avances importantes en el uso de las imágenes de satélite para identificar cultivos, no es recomendable hacer extrapolaciones dadas las características particulares de nuestros sistemas productivos y, en consecuencia, es fundamental investigar la utilidad de dichas tecnologías en nuestro país. Características específicas como extensión y forma de los lotes cultivados, sistemas de manejo del suelo y siembra, condiciones atmosféricas, características fisiológicas de la planta (altura, tamaño, forma de las hojas y etapas de desarrollo del cultivo), variedades sembradas y patrón de distribución espacial de los cultivos influyen en la diferenciación e identificación de los cultivos.

Varios autores comparan los métodos tradicionales de obtención de datos agrícolas basados principalmente en encuestas o en estimaciones indirectas, al igual que en métodos basados en la percepción remota para la estimación del área agrícola y en la discriminación de cultivos; concluyen que los primeros son costosos, requieren mucho tiempo y poseen una variedad de errores en términos de

tipos y fuentes de los datos; las evaluaciones mediante percepción remota, en cambio, pueden ser más eficientes al generar información confiable y actualizada, de bajo costo, y son fáciles de llevar a cabo (Pradhan, 2001; Tsiligrides, 2008). Con base en lo anterior se realizó la presente investigación con el objetivo de desarrollar un método para identificación de cultivos de arroz con base en imágenes de satélite, como una contribución a la generación de información oportuna para mejorar la competitividad de la agricultura.

Materiales y métodos

Área de estudio

Se seleccionó una zona de 451.901 ha en los departamentos de Cundinamarca y Tolima, comprendida entre las coordenadas 3°49'12,35" y 4°30'39,20" Lat. N; 75°1'23,5" y 74°32'35,83" Long. W, la cual incluye parte de los municipios de El Espinal, El Guamo, Flandes, Girardot, Ricaurte, Saldaña y Tocaima (Fig. 1). El paisaje dominante es el valle del río Magdalena, con relieve de plano a ligeramente inclinado y pendientes de 1 a 3%, de forma plana y plano cóncava; el clima es cálido con temperatura superior a 26°C y precipitación anual entre 1.200 y 1.500 mm.

Imágenes empleadas

Se utilizaron tres imágenes Landsat 7 ETM+ (Landsat Enhanced Thematic Mapper Plus) con fechas del 14 de agosto de 2000, 16 de julio 2001 y 1 de agosto de 2001. Estas imágenes cuentan con una resolución espacial de 30 m x 30 m, una resolución temporal de 16 días, una resolución radiométrica de 8 bits, un cubrimiento de 185 km por 185 km y cobertura de nubes entre 5-10%. También se utilizó una imagen ASTER (Advanced Spaceborne Thermal Emission Reflection Radiometer) con fecha del 1 de febrero de 2008. El sistema ASTER consta de tres subsistemas separados: el visible-infrarrojo cercano (VNIR), el infrarrojo de onda corta (SWIR) y el infrarrojo termal (TIR). Las imágenes generadas por este sensor tienen la particularidad de manejar una amplia resolución espectral, lo que permite manejar un número mayor de bandas (9-14) superior a las del satélite Landsat 7 ETM+ (ERSDAC, 2007), tienen una resolución espacial de 15 m en su subsistema (VNIR) y de 30 m en su subsistema (SWIR). El área de cobertura de las imágenes se muestra en la Fig. 1.

Pre-procesamiento y análisis de los datos

Las imágenes se corrigieron geométricamente mediante el algoritmo del vecino más cercano (nearest neighbor resampling) (Richards y Jia, 2006) y se obtuvieron los valores de reflectancia de las imágenes Landsat 7 ETM+ mediante




FIGURA 1. Localización del área de estudio.

el software ENVI 4.6 (ITT, 2008). Se utilizaron imágenes ASTER con nivel 2 de pre-procesamiento, que registran los datos como porcentajes de reflectancia. Mediante estas correcciones se remueve el efecto de las condiciones atmosféricas mejorando la clasificación de las superficies, en especial las áreas agrícolas. Posteriormente se remuestrearon las bandas del subsistema SWIR a 15 m mediante la utilización del algoritmo de transformación espectral Gram-Schmidt.

Muestreo en campo para entrenamiento y validación

Mediante GPS se georreferenció el perímetro de algunos lotes cultivados en arroz, además de otras coberturas relevantes presentes en el área de estudio (Tab. 1) y se crearon polígonos con el software ArcGIS 9.3 (McCoy, 2004), los cuales posteriormente fueron exportados a ENVI 4.6 como regiones de interés (ROI) para extraer los píxeles de referencia en la fase de entrenamiento y de verificación de la clasificación de las imágenes. El tamaño de los ROI se expresó en número de hectáreas de acuerdo con las coberturas presentes en la escena (Tab. 1).

TABLA 1. Número de píxeles de entrenamiento promedio por cobertura.

Cobertura	Landsat 7 ETM+	
	Píxeles	Hectáreas
Cultivos arroz	2.427	218,43
Forestal-arbustivo	1.521	136,89
Pasturas	2.130	192,57
Urbano	1.288	115,98
Cuerpos de agua	1.005	90,48
Nubes	1.955	176,01
Cobertura	EOS-ASTER	
	Píxeles	Hectáreas
Cultivos arroz	14.796	332,91
Forestal-arbustivo	10.716	241,11
Pasturas	10.044	225,99
Urbano	10.085	226,91
Cuerpos de agua	673	15,14
Nubes	2.014	45,31

Cálculo del índice de vegetación de diferencia normalizado (NDVI)

Los valores del NDVI varían entre -1 y 1, donde el cero corresponde a un valor aproximado de no vegetación. Valores negativos representan superficies sin vegetación, mientras valores cercanos a 1 contienen vegetación densa. El NDVI se calcula mediante la ecuación (1).

$$NDVI = \frac{NIR - R}{NIR + R} \quad (1)$$

donde R y NIR se refieren a los valores de reflectancia medidos por las bandas del rojo (R) e infrarrojo cercano (NIR).

Creación de máscaras

El objetivo principal de la creación de máscaras fue mejorar la exactitud de la clasificación digital de los cultivos de arroz excluyendo las coberturas no vegetales y las de tipo forestal, preservando así únicamente las coberturas de tipo agrícola. Se efectuó con base en los valores del NDVI y de textura promedio utilizando la extracción por objetos.

Cálculo de la textura promedio

La textura se define como la variación existente en la tonalidad del contorno o patrón de los niveles de gris para una región de píxeles (Tso y Mather, 2001). La textura promedio es el valor promedio de los píxeles que comprenden una región dentro del kernel (Haralick *et al.*, 1973). Un kernel es un arreglo de píxeles usado para limitar una operación a un grupo de píxeles. La textura promedio se calculó con base en el infrarrojo cercano mediante un filtro de ocurrencia 3 x 3, el cual mide el número de veces que se presenta cada nivel de gris en la escena (Anys *et al.*, 1994; Shrivastava y Gebelein, 2007).

Segmentación y clasificación de las imágenes

Se efectuó la segmentación de la imagen mediante un método de clasificación basada en reglas de lógica difusa construidas con sustento en valores de NDVI y de textura que se procesaron mediante el módulo Feature Extraction de ENVI Zoom 4.5 (ITT, 2008) para generar una máscara que separara la cobertura agrícola presente en las imágenes.

Para modelar la distribución de los valores calculados del NDVI y de textura promedio, se utilizó lógica difusa mediante una función de pertenencia tipo sigmoidal. El grado de tolerancia difusa que maneja el Feature Extraction se da en porcentaje en un rango entre 0-20% de confianza; entre mayor sea el porcentaje de confianza, más objetos aparecerán en el área de transición de la característica. Esto permitió que las coberturas agrícolas no fueran aisladas usando condiciones binarias, sino se consideró la información a partir de todas las condiciones para realizar la clasificación. Los píxeles con mayor valor de confianza fueron tomados en cuenta para las siguientes etapas de transformación y clasificación de la imagen.

Análisis de los componentes principales (ACP)

La identificación de los endmember pertenecientes a los cultivos de arroz georreferenciados en la escena requirió un análisis de los componentes principales (ACP) con el fin de eliminar la redundancia propia de los datos utilizados. La naturaleza multiespectral o multidimensional de las imágenes puede ajustarse mediante la construcción de un espacio vectorial con un número de ejes o dimensiones igual al número de componentes asociados con cada píxel. Esta transformación genera un conjunto de bandas que corresponden a cada valor propio y son organizadas de acuerdo con la estimación de ruido (de menor a mayor ruido). Es común la presencia de ruido en las imágenes multiespectrales; por esta razón, para obtener un resultado confiable en la caracterización de los perfiles espectrales de los cultivos es necesario remover dicho ruido de la imagen; sin embargo, se debe evitar tanto como sea posible la pérdida de datos (Richards y Jia, 2006).

Visualizador n-dimensional y extracción de los endmember

Los endmember son materiales únicos espectralmente puros presentes en una escena (ITT, 2008). Cuando un píxel es representado en una gráfica de dispersión de puntos espectrales, aquellos espectralmente más puros siempre se encuentran en las esquinas de la nube de píxeles; los píxeles espectralmente mixtos siempre estarán dispuestos dentro de la nube de puntos. Se ingresaron en el visualizador n-dimensional las regiones de interés

(ROI) anteriormente construidas, permitiendo localizar, identificar y agrupar los píxeles puros con mayor respuesta espectral en sus respectivos endmember. Dependiendo de la distribución de la nube de píxeles en el espacio n-dimensional se estimó el número de endmember para cada imagen. De esta forma, se escogieron de la nube 10 píxeles puros por endmember de acuerdo con Bastidas (2006), tomando como espacio dimensional de referencia el número de componentes principales escogido para cada una de las imágenes. Los perfiles espectrales pertenecientes a los endmember identificados de los cultivos de arroz fueron sintetizados en un perfil espectral promedio con su varianza como espectro referencia para el clasificador angular SAM, siguiendo a South *et al.* (2004). Posteriormente se evaluaron los ángulos espectrales en el SAM que mejor discriminaran los cultivos de arroz con base en los datos tomados en campo.

Clasificador angular SAM (Spectral Angle Mapper)

El clasificador angular SAM compara la similitud entre dos espectros a partir de su desviación angular, asumiendo que forman dos vectores en un espacio n-dimensional (siendo n el número de bandas disponibles) (Chuvieco, 2002). El clasificador SAM viene dado por la ecuación (2).

$$\cos \alpha = \frac{\sum XY}{\sqrt{\sum(X)^2 \sum(Y)^2}} \quad (2)$$

donde α es el ángulo formado entre el espectro de referencia y el espectro de la imagen, X es el espectro de la imagen, y Y es el espectro de referencia. El valor del SAM se expresa en radianes donde el menor ángulo α representa la mayor similitud entre las curvas. El ángulo α presenta una variación entre 0 y $\Pi/2$ radianes. El clasificador angular requiere la asignación de un umbral mínimo que restrinja o amplíe el rango de variación entre los vectores espectrales de los endmember y los vectores espectrales de cada píxel sin clasificar.

Evaluación del método de clasificación

La evaluación de las imágenes clasificadas mediante el clasificador SAM se llevó a cabo usando matrices de confusión. Estas matrices mostraron el grado de precisión obtenido en la clasificación, haciendo una comparación entre los resultados clasificados y la información del terreno. La exactitud global se calculó mediante la suma de los píxeles clasificados correctamente y el número de píxeles totales. En este caso, los datos tomados en el trabajo de campo fueron utilizados como datos de entrenamiento para el clasificador y como datos de verdad del terreno. Adicionalmente se evaluaron los porcentajes de los errores por comisión y omisión. Los errores por comisión representaron el porcentaje de los

pixeles que, perteneciendo a otra cobertura de vegetación, se clasificaron como arroz. Los errores por omisión representaron el porcentaje de pixeles que, perteneciendo a la clase arroz, no fueron clasificados como esta. Finalmente se cuantificaron las áreas correspondientes a los cultivos de arroz en hectáreas.

Resultados y discusión

Valores del NDVI

En la Tab. 2 se indican los valores del NDVI para las diferentes coberturas analizadas. El arroz presentó los mayores valores del NDVI con un promedio de 0,57, aunque muy cercano a la cobertura forestal que tuvo un promedio de 0,5 mientras que los pastos mostraron valores bajos con promedio de 0,1. De acuerdo con Ren *et al.* (2008), la vegetación verde fotosintéticamente activa se encuentra entre 0,2 a 0,8 y los cultivos tienden a estar entre 0,4 y 0,9 dependiendo en gran parte del índice de área foliar y de la disposición en el terreno. Igualmente en el NDVI influye el porcentaje de cobertura del suelo, y se presenta la mejor correlación cuando la cobertura está entre el 25% y el 80%. Los valores bajos presentados por los pastos se deben posiblemente a poca cobertura, por debajo del 15%, en cuyo caso el NDVI no indica con precisión el grado de biomasa de la vegetación, ya que está afectado por la reflectancia del suelo desnudo (Boken, 2005).

TABLA 2. Valores del NDVI para las diferentes coberturas analizadas (promedio para todas las imágenes).

Cobertura	Máximo	Mínimo	Promedio
Arroz	0,71	0,36	0,57
Bosques	0,67	0,19	0,50
Pastos	0,49	-0,11	0,10
Nubes	0,20	0,13	0,05
Centros urbanos	0,30	0,18	-0,02

La similitud espectral entre los valores del NDVI para el arroz y los bosques limitó una discriminación basada únicamente en el cálculo del NDVI, lo cual indica la importancia de utilizar e involucrar otras variables para obtener una clasificación apropiada.

Las coberturas vegetales presentaron los valores más altos del NDVI en comparación con las coberturas restantes (Tab. 2). En otras investigaciones (Wardlow y Egbert, 2008) han encontrado rangos entre -0,2 a 0,2 para coberturas urbanas, suelo desnudo, nubes y cuerpos de agua. Riaño (2006) menciona como un rango crítico del NDVI para discriminar las coberturas vegetales los valores entre 0,1 y

0,5 para la vegetación bastante densa y entre -0,58 y -0,25 para las cubiertas con un NDVI bajo, típicos de áreas urbanas, cuerpos de agua o suelos erosionados, y de 0 a 0,07 para las coberturas con suelo desnudo o poca vegetación.

Valores de textura promedio

En la Tab. 3 aparecen los resultados del análisis de la textura promedio en las cuatro imágenes utilizadas. Las nubes presentaron los valores más altos, y los cuerpos de agua, los más bajos. Los cultivos de arroz mostraron valores mayores de textura promedio frente a las coberturas forestales y pasturas. La cobertura forestal presenta una textura muy gruesa que permite distinguirla de pastizales o de cultivos anuales, de acuerdo con Shrivastava y Gebelein (2007), quienes propusieron utilizar la textura promedio de la banda 4 (NIR) en imágenes del sensor Landsat 5 MSS para distinguir entre áreas forestales y los cultivos de cítricos en el estado de la Florida, debido a la semejanza espectral existente entre estas dos coberturas. Para ser definidas como regiones texturalmente distinguibles, los niveles de gris deben presentar un alto grado de homogeneidad (Anys *et al.*, 1994).

TABLA 3. Textura promedio (con base en el infrarrojo cercano).

Cobertura	Máximo	Mínimo	Promedio
Arroz	0,36	0,16	0,27
Bosques	0,29	0,16	0,20
Pastos	0,24	0,10	0,17
Nubes	0,63	0,30	0,55
Centros urbanos	0,20	0,10	0,14
Cuerpos de agua	0,40	0,12	0,05

Evaluación de la separabilidad entre coberturas

Se evaluó el grado de separabilidad existente entre las coberturas tomando en cuenta el valor promedio, el cual indica la tendencia espectral-textural, y la desviación estándar, que se refiere al grado de homogeneidad que aparece en torno al valor central. De esta forma se calcularon los valores mínimos y máximos de los rangos para cada una de las coberturas mediante la adición y sustracción de dos veces la desviación estándar al valor central del NDVI y la textura aparente. En general, la desviación estándar tuvo valores bajos alrededor de 0,0611 en promedio para el NDVI y alrededor de 0,028 para la textura promedio. Esto indicó que los polígonos de entrenamiento para todas las coberturas tuvieron un elevado grado de homogeneidad. Se utilizó el rango del NDVI entre 0,463 y 0,703, y entre 0,213 y 0,32 de textura promedio para aislar el área de tipo agrícola en las cuatro imágenes.

Con base en estos rangos se procedió a generar las cuatro máscaras correspondientes a las imágenes Landsat 7 ETM+ y ASTER mediante una segmentación basada en una función de lógica difusa sigmoidal S. Los porcentajes de tolerancia para los valores del NDVI y la textura promedio variaron entre 5 y 10% de confianza.

En la Tab. 4 se muestran las áreas agrícolas obtenidas mediante las máscaras, reduciendo el área total entre un 20% y un 37%. El uso de estas máscaras fue importante ya que permitió enfocar la clasificación en áreas con mayor probabilidad de encontrar cultivos de arroz excluyendo otras que tienen otras coberturas, lo cual evita mezclas de clases de cobertura que son indeseables al momento de clasificar.

TABLA 4. Extensión del área agrícola obtenida mediante las máscaras.

Imagen	Área (% del área total)	Área (ha)
Landsat 7 ETM+ 14/08/2000	80,1	362.379
Landsat 7 ETM+ 16/07/2001	81,0	366.491
Landsat 7 ETM+ 01/08/2001	93,5	422.663
ASTER 01/02/2008	63,0	123.730

En la Fig. 2 se pueden observar los traslapes entre las coberturas tomando los rangos promedio del NDVI para las cuatro imágenes. Se denota traslape (0,36 y 67,00) entre las coberturas forestales y los cultivos de arroz; las pasturas, cuerpos de agua, urbana y nubes no presentan rangos que puedan mezclarse con la cobertura arroz. En la Fig. 3 se pueden apreciar los rangos calculados para la textura promedio de cada cobertura. Las coberturas arroz y forestal reducen el nivel de traslape (0,16-0,29) en contraste con el NDVI.




FIGURA 2. Valores del NDVI promedio para las cuatro imágenes (tres de Landsat 7 ETM+ y una de ASTER).




FIGURA 3. Textura promedio para las cuatro imágenes (tres de Landsat 7 ETM+ y una de ASTER).

Componentes principales (ACP)

En la Tab. 5 se observan los resultados del análisis de los componentes principales calculados para las cuatro imágenes con su respectiva máscara construida. En todos los casos, el primer componente retiene la mayor parte de la información espectral disponible, mientras los últimos, sólo unas pequeñas o ruido. Con el fin de efectuar la identificación y clasificación de los *endmember*, se eligieron los dos primeros componentes de las tres imágenes Landsat 7 ETM+ para tener en promedio el 93,5% de la información. Este cálculo fue consistente con van der Meer (2002) donde, en el caso de Landsat, el 90% de la variabilidad espectral se ubicó en el componente principal 1 y el componente principal 2; y con Riaño (2006), cuyo análisis de componentes principales retuvo el 96,17% para una imagen Landsat 5 TM en los dos primeros componentes. Para la imagen ASTER se eligieron los tres primeros componentes por retener el 88,7% de la información (Tab. 5).

Identificación y clasificación de los *endmember* espectrales para los cultivos de arroz

Los dos primeros componentes principales fueron utilizados como ejes de referencia en el visualizador n-dimensional para el caso Landsat; para la imagen ASTER se utilizaron los tres primeros componentes generando un espacio tridimensional. De esta forma, se extrajeron los pixeles extremos de la nube para cada una de las imágenes evaluadas. Con la ayuda del visor de perfiles espectrales se identificaron las características radiométricas de los pixeles extremos dependiendo de su distribución en la nube de pixeles y sus porcentajes máximos de reflectancia en el NIR, de manera que aquellos pixeles con una cobertura uniforme de vegetación presentaron valores altos de reflectancia en esta banda. Se identificaron tres *endmember* pertenecientes al cultivo de arroz en las imágenes Landsat ETM+ del 14/08/2000 y 16/07/2001; para la imagen Landsat ETM+ 01/08/2001 se identificaron cuatro *endmember*, y para la imagen ASTER se

TABLA 5. Porcentajes de retención y de acumulación de la información de los componentes principales.

Imagen/Fecha	Componente	Valor propio	Retención (%)	Acumulación (%)
Landsat 7 ETM+ 14/08/2000	1	0,001783	63,3	63,3
	2	0,000877	31,1	94,5
	3	0,000120	4,3	98,8
	4	0,000024	0,9	99,6
	5	0,000008	0,3	99,7
	6	0,000003	0,1	1,0
Landsat 7 ETM+ 16/07/2001	1	0,001996	64,9	64,9
	2	0,000836	27,2	92,0
	3	0,000219	7,1	99,2
	4	0,000015	0,5	99,6
	5	0,000007	0,2	99,9
	6	0,000004	0,1	1,0
Landsat 7 ETM+ 01/08/2001	1	0,002000	63,6	63,6
	2	0,000955	30,4	94,0
	3	0,000144	4,6	98,5
	4	0,000034	1,1	99,6
	5	0,000008	0,3	99,9
	6	0,000004	0,1	1,0
ASTER 01/02/2008	1	2028,2426	54,9	54,9
	2	799,94	21,7	76,6
	3	445,67	12,1	88,7
	4	191,43	5,2	93,9
	5	150,03	4,1	97,9
	6	39,52	1,1	99,0
	7	29,70	0,8	99,8
	8	6,96	0,2	1,0
	9	0,43	0,01	1,0

identificaron cinco endmember. De acuerdo con Xie *et al.* (2007), la nube de píxeles y el número de endmember varían considerablemente entre las distintas fechas para un cultivo, incluso entre imágenes adquiridas en meses consecutivos. Debido a esta variación causada principalmente por la variación atmosférica y por las condiciones de iluminación, se presentan grandes limitaciones para la construcción de bibliotecas espectrales genéricas de los cultivos, aplicables para cualquier región del país.

En la clasificación de los endmember se utilizaron los perfiles espectrales promedio, mínima desviación estándar y máxima desviación estándar, eliminando los valores máximos y mínimos, para la clasificación de los cultivos de arroz en las imágenes con sus correspondientes máscaras. Los porcentajes mínimos de reflectancia para las imágenes Landsat 7 ETM+ del 14/08/2000, 16/07/2001,

01/08/2001 y ASTER tuvieron valores de 0,04; 0,05; 0,05 y 0,06, respectivamente; los porcentajes de reflectancia máximos tuvieron valores alrededor de 0,37; 0,35; 0,38 y 0,37 pertenecientes a las bandas del infrarrojo cercano (NIR); la varianza tuvo valores bajos de 0,07; 0,06; 0,08 y 0,08, lo que indicó un alto grado de homogeneidad entre los diferentes perfiles espectrales utilizados en la fase de clasificación.

Con base en el trabajo de campo se evaluaron distintos umbrales en radianes para cada perfil espectral (promedio, mín. desv. y máx. desv.), para catalogar los cultivos de arroz mediante el clasificador SAM. Estos umbrales SAM dados en radianes variaron entre un rango de 0,5 a 1,7 (Tab. 6). La Fig. 4 muestra una imagen Landsat 7 ETM+ catalogada mediante el clasificador SAM.

TABLA 6. Umbrales finales del SAM utilizados en la clasificación de los endmember para el cultivo de arroz.

Imagen	Perfil espectral	Umbral SAM
Landsat 7 ETM+ 14/08/2000	Mínima desviación	1,7
	Promedio	1,4
	Máxima desviación	1,7
Landsat 7 ETM+ 16/07/2001	Mínima desviación	1,0
	Promedio	0,5
	Máxima desviación	1,5
Landsat 7 ETM+ 01/08/2001	Mínima desviación	0,3
	Promedio	1,5
	Máxima desviación	1,0
ASTER 01/02/2008	Mínima desviación	3,0
	Promedio	1,5
	Máxima desviación	0,8

Evaluación de la clasificación y cuantificación de áreas sembradas

En la Tab. 7 se pueden ver los porcentajes de exactitud global obtenidos con el clasificador SAM según la matriz de confusión. Se obtuvieron porcentajes por encima del 70% de exactitud global, un desempeño relativamente bueno del clasificador SAM, y valores kappa entre 0,45 y 0,74. De acuerdo con Chuvieco (2002), el coeficiente kappa intenta delimitar el grado de ajuste debido sólo a la exactitud de la clasificación, prescindiendo del causado por factores aleatorios; sus valores varían entre -1 y 1; si el valor es 1 significa un acuerdo pleno entre la realidad y la imagen clasificada; cuando es cero indica que el acuerdo observado es puramente debido al azar. Como se observa en la Tab. 7, el valor de kappa fue relativamente alto (>0,70) para las imágenes ASTER y para la Landsat de julio del año 2001,




FIGURA 4. Clasificación de la imagen ASTER donde se aprecian las áreas que estaban cultivadas con arroz el 1 de febrero de 2008.

mientras que fue relativamente bajo para las imágenes Landsat de 2000 y de agosto de 2001. Los valores altos de omisión que se presentaron para la imagen Landsat de agosto de 2001 (40,25) indican que áreas cultivadas con arroz no quedaron bien clasificadas, y esto se debe, probablemente, al efecto de las fechas de toma de las imágenes en relación con el estado fenológico del cultivo y a diferencias en la ubicación de los cultivos de arroz en ese periodo con relación a los lotes tomados en campo como base para la evaluación del método.

La clasificación de la imagen ASTER (Fig. 4) arrojó un total de 27.962 ha sembradas con arroz en la zona de estudio para el 1 de febrero de 2008. Estos datos son similares a las estadísticas de Fedearroz, según las cuales en el semestre B de 2007 se sembraron 28.218 ha y para el semestre A de

TABLA 7. Matrices de confusión para el SAM para el cultivo de arroz.

Imagen/Fecha	Clase	Comisión (%)	Omisión (%)
Landsat 7 ETM+ 14/08/2000	Cultivos de arroz	18,26	9,82
	Otros cultivos	11,47	53,71
	Exactitud global (%)		76,85
	Kappa		0,444
Landsat 7 ETM+ 16/07/2001	Cultivos de arroz	10,08	17,85
	Otros cultivos	8,81	9,15
	Exactitud global (%)		87,47
	Kappa		0,744
Landsat 7 ETM+ 01/08/2001	Cultivos de arroz	0,81	40,25
	Otros cultivos	34,62	1,69
	Exactitud global (%)		72,72
	Kappa		0,516
ASTER 01/02/2008	Cultivos de arroz	2,35	22,81
	Otros cultivos	24,24	2,43
	Exactitud global (%)		85,50
	Kappa		0,710

2008, 27.169 ha. Para los otros años no se efectuó la comparación entre las áreas obtenidas a partir de las imágenes y los datos estadísticos por dificultad en la consecución de estos últimos.

Conclusiones

La creación de máscaras con base en la textura y el NDVI asignado en grados de pertenencia mediante una función de lógica difusa permitió mejorar la clasificación final de las imágenes y lograr una buena confiabilidad utilizando el clasificador SAM. Sin embargo, las diferencias entre los estados fenológicos del cultivo, las características atmosféricas y del sensor influyen en la confiabilidad de los resultados, ya que se tomaron imágenes de épocas diferentes.

La colección e identificación de los endmember mediante el uso del visualizador n-dimensional en ENVI fue interesante para extraer los píxeles más puros y evaluar la disposición de los endmember en la nube. Esta es una herramienta interactiva que depende en gran medida del conocimiento de expertos. Los umbrales (máximo ángulo) para el clasificador SAM son muy sensibles a los resultados de la clasificación. La selección del valor del umbral requiere una búsqueda exhaustiva utilizando los datos del terreno y de la experiencia del intérprete.

En el caso de Colombia, donde generalmente se cuenta con poca disponibilidad de imágenes, y para el caso de

los cultivos de ciclo corto, se debe tener especial cuidado con la variabilidad que presentan las áreas sembradas de un semestre a otro y a través de los años, puesto que esto influye en la confiabilidad de las estimaciones históricas que se efectúan. Una alternativa es conocer la historia de los lotes mediante registros que pueden llevarse en un Sistema de Información Geográfica.

El método propuesto es una alternativa confiable para la identificación y cuantificación de cultivos de arroz, y en consecuencia se deben realizar investigaciones para establecer su utilidad en otros cultivos y en otras condiciones ambientales. Si se tiene buena disponibilidad de imágenes se puede explorar el uso de aquellas tomadas en diferente estado fenológico para caracterizar mejor el comportamiento espectral del cultivo.

Agradecimientos

La presente investigación como parte del proyecto “Imágenes de satélite y modelos digitales de elevación como fuente de datos para la evaluación de la aptitud de tierras agrícolas” financiado por la División de Investigación de la Universidad Nacional de Colombia, sede Bogotá (DIB).

Literatura citada

- Anys, H., A. Bannari, D.C. Hee e Y.D. Morin. 1994. Texture analysis for the mapping of urban areas using airborne MEIS-II images. pp. 231-245. En: Proc. 1st International Airborne Remote Sensing Conference and Exhibition. Vol. 3. Estrasburgo, Francia.
- Bastidas, E. 2006. Crop area estimations from temporal unmixing: a case study using MERIS with artificial neural networks. Tesis de maestría. Wageningen University, Wageningen, The Netherlands.
- Boken, V.K. 2005. Monitoring and predicting agricultural drought: a global study. Oxford University Press, Cary, NC.
- Breckling, B., H. Laue y H. Pehlke. 2009. Remote sensing as a data source to analyse regional implications of genetically modified plants in agriculture—Oilseed rape (*Brassica napus*) in Northern Germany. Ecological Indicators. En: <http://dx.doi.org/10.1007/s12302-009-0080-210.1016/j.ecolind>; consulta: marzo de 2009.
- Chuvieco, E. 2002. Fundamentos de teledetección espacial. 2a ed. Editorial Rialp, Madrid.
- French, A.N., T.J. Schmugge, J.C. Ritchie, A. Hsu, F. Jacob y K. Ogawa. 2008. Detecting land cover change at the Jornada Experimental Range, New Mexico with ASTER emissivities. Remote Sens. Environ. 112, 1730-1748.
- García-Torres, L., J.M. Peña-Barragán, F. López-Granados, M. Jurado-Expósito y R. Fernández-Escobar. 2008. Automatic assessment of agro-environmental indicators from remotely sensed images of tree orchards and its evaluation using olive plantations. Comput. Electron. Agr. 61, 179-191.
- Haralick, R., M. Shanmugan e I. Dinstein. 1973. Textural features for image classification. IEEE Trans. Syst. Man Cyber. 3(6), 610-621.
- Ishiguro, E., M.K. Kumar, Y. Hidaka, S. Yoshida, M. Sato, M. Miyazato y J.Y. Chen. 1993. Use of rice response characteristics in area estimation by LANDSAT/TM and MOS-1 satellites. ISPRS J. Photogramm. Remote Sens. 48(1), 26-32.
- ITT. 2008. ENVI User's Guide. ITT Visual Information Solutions, Boulder, CO.
- Jensen, J. 2000. Remote sensing of the environment: an earth resource perspective. Prentice Hall Series, Saddle River, NJ.
- Martínez, L.J. 2006. Modelo para evaluar la calidad de las tierras agrícolas. Agron. Colomb. 24, 96-110.
- Mather, P.M. 2004. Computer processing of remotely-sensed images an introduction. 3a ed. John Wiley & Sons Inc., The Atrium, UK.
- McCloy, K.R. 1995. Resource management information systems process and practice. Taylor y Francis, London.
- McCoy, J. 2004. Geoprocessing in ArcGIS. ESRI, Redlands, CA.
- Muñoz, J.D., L.J. Martínez y G. Ligarreto. 2009. Caracterización de los ambientes agroecológicos del agraz o mortiño (*Vaccinium meridionale* Swartz), en la zona altoandina de Colombia. pp. 29-56. En: Ligarreto M., G.A. (ed.). Perspectivas del cultivo del agraz o mortiño (*Vaccinium meridionale* Swartz), en la zona altoandina de Colombia. Facultad de Agronomía, Universidad Nacional de Colombia, Bogotá.
- Pradhan, S. 2001. Crop area estimation using GIS, remote sensing and area frame sampling. Intl. J. Appl. Earth Observ. Geoinform. 3, 86-92.
- Ren, J., Z. Chen, Q. Zhou y H. Tang. 2008. Regional yield estimation for winter wheat with MODIS-NDVI data in Shandong, China. Intl. J. Appl. Earth Observ. Geoinform. 10, 403-413.
- Riaño, O. 2006. Desarrollo de un método basado en imágenes de satélite para detectar cambios y evaluar la erosión como indicador de la calidad de las tierras dedicadas al cultivo de la papa en provincias al nororiente de Cundinamarca. Tesis de maestría. Facultad de Agronomía, Universidad Nacional de Colombia, Bogotá.
- Richards, J.A. y X. Jia. 2006. Remote sensing digital image analysis: an introduction. 4th ed. Springer-Verlag, Berlín.
- Sakamoto, T., C. Van Phung, A. Kotera, K. Duy Nguyen y M. Yokozawa. 2009. Analysis of rapid expansion of inland aquaculture and triple rice-cropping areas in a coastal area of the Vietnamese Mekong Delta using MODIS time-series imagery. Landscape Urban Plan. 92(15), 34-46.
- Shrivastava, R.J. y J.L. Gebelein. 2007. Land cover classification and economic assessment of citrus groves using remote sensing. ISPRS J. Photogramm. Remote Sens. 61, 341-353.
- South, S., J. Qi y D.P. Lusch. 2004. Optimal classification methods for mapping agricultural tillage practices. Remote Sens. Environ. 91, 90-97.
- Tsiligirides, T.A. 2008. Remote sensing as a tool for agricultural statistics: a case study of area frame sampling methodology in Hellas. Comput. Electron. Agr. 20, 45-77.

- Tso, B. y P.M. Mather. 2001. Classification methods for remotely sensed data. Taylor & Francis, London.
- Van der Meer, F. 2002. Image classification through spectral unmixing. pp. 185-194. En: Stein, A., F. van der Meer y B. Gorte (eds.). Spatial statistics for remote sensing. Kluwer Academic Publ., Dordrecht, The Netherlands.
- Wardlow, B.D. y S.L. Egbert. 2008. Large-area crop mapping using time-series MODIS 250 m NDVI data: An assessment for the U.S. Central Great Plains. *Remote Sens. Environ.* 112, 1096-1116.
- Welch, R. y C.W. Pannell. 1982. Mapping recent agricultural developments in China from satellite data. *Adv. Space Res.* 2(8), 111-125.
- Xiao, X., S. Boles, S. Froking, C. Li, J.Y. Babu, W. Salas y B. Moore. 2006. Mapping paddy rice agriculture in South and Southeast Asia using multi-temporal MODIS images. *Remote Sens. Environ.* 100(15), 95-113.