



Clasificación supervisada contextual de Markov, mediante el uso de imágenes multispectrales *LandSat 8 OLI* y *Sentinel 2A*

Supervised Markov contextual classification using *LandSat 8 OLI* and *Sentinel 2A* multispectral images

*Sergio Rojas*¹, *Javier Medina*²

Para citar este artículo: Rojas, S. y Medina, J. (2021). Clasificación supervisada contextual de Markov, mediante el uso de imágenes multispectrales *LandSat 8 OLI* y *Sentinel 2A*. *Revista UD y la Geomática* (16), 91-100.

DOI: <https://doi.org/10.14483/23448407.15269>

Fecha de envío: 24 de mayo de 2020

Fecha de aceptación: 10 de diciembre de 2020

RESUMEN

El presente artículo está orientado a mostrar el desarrollo y los resultados de la implementación de un método contextual de clasificación supervisada en imágenes multispectrales *LandSat 8, OLI* y *Sentinel 2A*, a partir de la teoría de los campos *aleatorios de Markov*. Este método se implementó y desarrolló en el software *MatLab*, empleando la herramienta *Mapping Toolbox*, lo que permitió conservar el sistema de referencia espacial. Se emplearon como insumo recortes de las cinco bandas (azul, verde, rojo, infrarrojo cercano e infrarrojo medio) de los dos sensores *LandSat 8* y *Sentinel 2A* de los días 22 y 23 de diciembre de 2018, respectivamente, sobre un área comprendida en municipios de Puerto López, San Carlos de Garagoa y Villavicencio. Como resultado se obtuvieron dos mapas de clasificación con las cinco coberturas predominantes de la zona y un índice Kappa mayor a 0,5, el cual es mayor que el obtenido con los métodos de clasificación supervisada de KNN y Malahanobis-ERDAS validados en el proyecto.

Palabras clave: campos aleatorios de Markov CAM, clasificación supervisada, imágenes multispectrales, coberturas terrestres.

ABSTRACT

This article aims to show the development and results of the implementation of a shortcut method of supervised classification

on multispectral *LandSAT 8 OLI* and *Sentinel 2A* from the theory of Markov random fields. This method was implemented and developed software *MatLab* using the tool *Mapping Toolbox* which allowed to preserve the spatial reference system. They were used as input cuts of 5 bands (blue, green, red, near infrared and infrared medium) of the two sensors *LandSAT 8* and *Sentinel 2A* of the 22nd and 23rd of December of 2018 respectively over an area included in the municipalities of Puerto López, San Carlos of Garagoa, and Villavicencio. As a result, two classification maps were obtained with the 5 predominant coverage of the area and a Kappa index greater than 0.5, which is higher than that obtained with the supervised classification methods of KNN and Malahanobis - ERDAS validated in the project.

Keywords: random fields from Markov CAM, supervised classification, image.

RESUMO

Este artigo tem como objetivo mostrar o desenvolvimento e os resultados da implementação de um método contextual de classificação supervisionada em imagens multispectrais *Land_S8 OLI* e *Sentinel 2A* baseadas na teoria Markov Random Fields. Este método foi implementado e desenvolvido no software *MatLab* usando a ferramenta *Mapping Toolbox*, que permitiu conservar o sistema de referência espacial. Estacas das 5 bandas (Azul, Verde,

1 Ideam, Bogotá D.C., Colombia. sarojas@ideam.gov.co

2 Universidad Distrital Francisco José de Caldas, Bogotá D.C. Colombia. rmedina@udistrital.edu.co

Vermelho, Infravermelho Próximo e Infravermelho Médio) dos dois sensores LandSat 8 e Sentinel 2A dos dias 22 e 23 de dezembro de 2018 respectivamente em uma área compreendida nos municípios de Puerto foram utilizadas como insumo. López, San Carlos de Garagoa e Villavicencio. Como resultado, dois mapas de classificação foram obtidos com as 5 coberturas predominantes

Introducción

En la actualidad, existen programas en el mercado diseñados para apoyar las tareas de procesamiento digital de imágenes de percepción remota, que en la mayoría de las aplicaciones se han concentrado principalmente en situaciones simples y con procesos no del todo automáticos (Mena, 2003). Uno de esos procesos es la clasificación supervisada de imágenes, que es el que se lleva a cabo para encontrar propiedades comunes entre un conjunto de datos y clasificarlos dentro de diferentes rangos, de acuerdo a un modelo de clasificación (García, Martínez, Nuñez y Guzmán, 1998). Por lo general, este tipo de clasificaciones presenta, en el mejor de los casos, 70 % de precisión global para el tipo supervisado, y esta puede ser aún menor cuando la clasificación es del tipo no supervisado (Lang, Shao, Pijanowski y Farnsworth, 2008). Por esto, en las últimas décadas, la comunidad científica ha promovido la investigación donde se intenta obtener una clasificación satisfactoria (Anderson *et al.*, 1976), y si bien la investigación y el desarrollo de métodos avanzados de clasificación han rendido frutos, aún no se ha identificado un método que sea aceptado por la comunidad científica y académica que compita directamente con los algoritmos tradicionales (Borras *et al.*, 2017; Perea, Meroño y Aguilera, 2009). En esta línea, nace la idea de incorporar la *propiedad markoviana*, del ruso Andrei Markov (1856-1922), propuesta por Besag (1974) en el análisis de imágenes. Esta propiedad es heredada por la teoría de las cadenas de Markov (CAM), pero con un enfoque espacial, donde se puede considerar que un pixel depende de otros pixeles vecinos. Al considerar la anterior la clasificación no solo tendría en cuenta la información espectral como los clasificadores clásicos sino también la información contextual o espacial. Este enfoque ha sido desarrollado por Derin, Elliott, Cristi y Geman (1984) que lo presentan mediante un marco bayesiano y donde se muestran resultados prometedores en la segmentación y restauración de imágenes. Lorette, Descombes y Zerubia (2004) realizan análisis de textura de áreas urbanas desde imágenes SPOT3 y SPOT5, con modelos markovianos y clasificación de lógica difusa, del cual se destaca el uso de técnicas bayesianas para el estudio de imágenes pancromáticas de fotografías aéreas. Guijarro Mata-García (2010) presenta diferentes métodos de clasificación de imágenes entre los que se encuentran las CAM sobre imágenes *LandSat 7 TM* y *Radar*. Gleich (2012) presenta el resultado de la extracción de información usando los modelos autobinomiales; el modelo Gibbs y Huber, de las CAM sobre imágenes *Radar*. Zhan, You y Fuqing (2013) proponen el uso

da área e um índice Kappa maior que 0,5, que é maior do que o obtido com os métodos de classificação supervisionada de KNN e Malahanobis - ERDAS validados no projeto.

Palavras-chave: Campos Aleatórios Markov CAM, Classificação Supervisionada, Imagens Multiespectrais, Tampus Terrestres.

de los *campos aleatorios adaptivos-discontinuos de Markov* (DACAM) para la detección de bordes en imágenes *Radar* y *LandSat*. Liao, Tang, Rosenhahn y Yang (2015) utilizan las CAM para optimizar la clasificación de imágenes hiperespectrales a partir de lo que ellos denominaron *aprendizaje de procesos gaussianos*, donde presentaron exitosamente resultados por encima de las demás clasificaciones. Cui *et al.* (2016) plantean una combinación entre los dos más grandes usos de las CAM en imágenes, que son la clasificación así como la detección de bordes, y obtener un producto clasificado y detallado con alta disimilitud entre clases.

Materiales y métodos

Área de estudio

Es un área comprendida en municipios de Puerto López, San Carlos de Garagoa, y Villavicencio (Meta, Colombia) (figura 1).




Figura 1. Captura de pantalla de la imagen multiespectral del sensor *LandSat 8 OLI*³

De acuerdo con la capa oficial de cobertura de la Tierra en el periodo 2007-2009 para Colombia, la zona de interés abarca un área de 39.788 hectáreas, en las que se identifican 9 tipos de coberturas en nivel 2; allí existen 5 categorías predominantes, entre las que *pastos* es la más preponderante (código 2.3) con cerca de 17.945 hectáreas (tabla 1).

3 Obtenida desde <https://earthexplorer.usgs.gov/>, en combinación (R: IRC, G: Verde, B: Rojo) de la del 23 de diciembre de 2018.

Tabla 1. Coberturas área de estudio

Nivel 2	Clase	Área (hectáreas)	Cobertura (%)
2.3	Pastos	17.945,5	45,10
3.1	Bosques	8.741,6	21,97
3.2	Vegetación secundaria	5558,5	13,97
2.4	Áreas agrícolas	3.980,4	10
5.1	Aguas continentales	1.711,3	4,30
2.2	Cultivos permanentes	1.169,8	2,94
Otros: 2.1, 3.3 y 4.1	Áreas Húmedas, Suelo desnudo y Cultivos transitorios	681	1,53

Fuente: elaboración propia.

Tabla 2. Características de las imágenes insumo

Imagen		Sentinel 2 ^a		LandSat 8 OLI	
Bandas	Resolución espacial	Banda 2 (Blue)	10 m	Banda 2 (Blue)	30
		Banda 3 (Green)	10 m	Banda 3 (Green)	30
		Banda 4 (Red)	10 m	Banda 4 (Red)	30
		Banda 8 (NIR)	10 m	Banda 5 (NIR)	30
		Banda 11 (MIR)	10 m	Banda 6 (MIR)	30
Tamaño		2010×2010 pixeles		670×670 pixeles	
Fecha captura		22 de diciembre de 2018		23 de diciembre de 2018	

Fuente: elaboración propia.

La elección de las bandas para realizar la composición es aquella que albergó un mayor contenido de información y a la vez mayor contraste (Chuvienco, 2008); es decir, las bandas de mayor resolución espacial, mayor variabilidad y menor correlación con las bandas compañeras. Las características de las bandas e imágenes seleccionadas se evidencian en la tabla 2.

radiancia. Para esto se requiere conocer la irradiancia solar y la fecha de adquisición de la imagen de la cual se estima el factor de corrección de la distancia Tierra-Sol y el ángulo cenital θ_1 (Ariza, García, Rojas y Ramírez, 2013). La reflectividad⁴ aparente se calcula por medio de la ecuación (1).

$$\rho_k = \frac{\text{DistanciaSol-Tierra}^2 * \pi * L_{sen,k}}{\text{IrradianciaSolar} * \cos \theta_i} \quad (1)$$

Corrección radiométrica y/o atmosférica

Las correcciones radiométricas no solo permiten normalizar los datos que son ofrecidos en valores de niveles digitales (ND), sino que también calibra la imagen de acuerdo con sus características propias, como día juliano, distancia del Sol a la Tierra y un ajuste propio de calibración para cada banda del dispositivo sensor, del que se obtienen sus correspondientes valores reales de reflectancia (Ariza, García, Rojas y Ramírez, 2013). Los valores resultantes del cálculo de reflectividad oscilan entre 0 y 1, en donde 0 sería de una superficie completamente absorbente y 1 para una superficie completamente reflectora de la energía incidente. Para el cálculo de la reflectividad aparente (modelo simplificado) se deben transformar los ND en valores de radiancia ($L_{sen,k}$), partiendo de los coeficientes de calibración del sensor, para posteriormente obtener la reflectividad a partir de dicha

Selección de muestras de entrenamiento

Para estimar el tamaño de muestra n se acude a la relación de la ecuación (2)⁵ (Plourde y Congalton, 2003).

$$n = \frac{B \Pi_i (1 - \Pi_i)}{b_i^2} \quad (2)$$

4 ρ_k – es la reflectividad aparente, k – es la banda correspondiente y $\theta_i = 90$ – ángulo de elevación.

5 Donde, b_i es la precisión requerida (expresada como una proporción, de modo que 0,05 es equivalente al 5 % de precisión), donde percentil superior es $(\alpha/k) \times 100\%$, y B es el valor de la distribución de *chi* cuadrado con un (1) grado de libertad, k es el número de clases, Π_i es la proporción del área cubierta por la clase i , y α es el nivel de confianza requerido.

Aunque, en la tabla 1 se muestran por separadas algunas coberturas que espectralmente son parecidas y el clasificador automático se tiende a confundir, como: las coberturas de cultivos permanentes, áreas agrícolas y cultivos transitorios, por esto se agrupan en la clase de cultivos (tabla 3).

Tabla 3. Coberturas agrupadas

Código	Clase	Área (hectáreas)	Cobertura (%)
1	Pastos	17.945,5	45,10
2	Bosques	8.741,6	21,97
3	Vegetación secundaria	5558,5	13,97
4	Cultivos	5177,5	13,01
5	Aguas continentales	1.711,3	4,30
6	Áreas Húmedas	455,8	1,14
7	Suelo desnudo	198,02	0,49

Fuente: elaboración propia.

Por practicidad, y debido a que las coberturas de áreas húmedas y suelos desnudos no superan ni el 2 % de porcentaje de cobertura, se decide no tomar muestras de su clase solo estimando 5 tipos de coberturas que corresponden a más del 98 % de cobertura. La selección de muestras (grupos de píxeles) representativas de una clase o categoría se basó en la ecuación (2). En la tabla 4 se refiere la cantidad mínima de muestras para las categorías de cobertura predominantes.

Tabla 4. Relación cantidad mínima de muestras por cobertura

Clases	Número de muestras	Cobertura
1	657	Pastos
2	454	Bosques
3	318	Vegetación secundaria
4	238	Cultivos
5	109	Aguas continentales

Fuente: elaboración propia.

Modelos de campos aleatorios de Márkov (CAM)

Los modelos estocásticos, en particular los modelos de CAM, establecen el proceso de segmentación como un problema a resolver de etiquetado (Lorette, Descombes y Zerubia, 2004; Acuña y Llano, 2010). De este modo, se considera el conjunto L de etiquetas que puede ser continuo o discreto, dependiendo de la aplicación definida por el usuario (por ejemplo: agua, bosque, pasto o áreas

residenciales), o en detección de bordes (bordes, o no bordes) (López, 2007). Por tanto, se requiere encontrar una función f que asigne la etiqueta L en una posición o sitio s , considerando la información contextual (ecuación (3)).

$$f: s \rightarrow L \quad (3)$$

En las imágenes, el conjunto de posiciones donde se define el campo se denota por el conjunto S y cada sitio como $s \in S$. Para cada sitio s se define un pixel o un vector de píxeles (o un vector de variables aleatorias o de características). Para que un campo sea aleatorio es necesario asignarle una probabilidad que cumpla con la condición de positividad. La positividad $P(f) > 0$ se presenta si la probabilidad conjunta de cualquier campo aleatorio es determinada unívocamente por su probabilidad condicional local. Para que el campo aleatorio sea CAM, debe considerar la propiedad markoviana, la cual pretende conectar las variables aleatorias asociadas con los sitios (nodos o vértices o píxeles). En la figura 2 se presentan las conexiones más comunes empleadas en los campos aleatorios de Markov.




Figura 2. Conexiones comunes para los modelos de campo aleatorios⁶

Fuente:

La propiedad markoviana de un campo aleatorio f es definida por la función de densidad de probabilidad que cumple la condición de la ecuación (4).

$$\text{Markovianidad: } P(fw_i | fw_{(s-r)}) = P(fw_i | fw_{Ni}) \quad (4)$$

Esta propiedad describe la característica local de f con respecto a un sistema de vecindades w . La etiqueta en un sitio depende únicamente de sus sitios vecinos. En otras palabras, solo los sitios vecinos, o píxeles, tienen interacción directa entre ellos mismos y es más probable que un pixel tenga la misma etiqueta que sus vecinos. Un CAM requiere dos tipos de modelos de campos diferentes para la toma de decisiones para un problema de etiquetado (Mather y Tso, 2009):

Un primer modelo espectral, para la observación en cada pixel para describir la relación entre los vectores de características y las clases de patrones, como distribuciones condicionales de clase.

6 (a) Conexión simple de 4 píxeles; (b) conexión de 8 píxeles y (c) conexiones irregulares en el que los nodos son grupos de píxeles adyacentes con características espectrales similares (Blake y Pushmeet, 2011) **NO SE RELACIONA EN LA LISTA DE REFERENCIAS.**

Un segundo modelo espacial CAM, que sirve como información contextual previa de la interacción espacial local, donde la etiqueta en un pixel dependa de las etiquetas en los pixeles vecinos.

El modelo espectral empleado fue el de clasificación mediante K vecinos más cercanos, mientras que el modelo CAM se implementó mediante un enfoque bayesiano, a partir de su función de energía *a priori* para determinar la función objetivo (*a posteriori*).

Función de energía *a priori*

Se puede definir mediante el teorema de Hammersley-Clifford (Ecuación (5)) que establece equivalencia entre los CAM y la distribución de Gibbs⁷ (Mather y Tso, 2009; Lorette, Descombes y Zerubia, 2004).

$$P(Wr) = \frac{1}{Z} \exp(-U(Wr)) \quad (5)$$

La función de energía *a priori* $U(Wr)$ se obtiene de sumar las funciones potenciales clique $V_c(Wr)$ y se puede asumir suavizado de la información *a priori*, si solo el clique de tipo C2 es incluido, entonces la energía suavizada *a priori*⁸ para cada píxel puede ser definido en la ecuación (6):

$$U(Wr) = \sum V_c(Wr) = \beta * \sum_{\{r,r'\}} \delta(w_r, w_{r'}), \quad (6)$$

Función de energía *a posteriori*

Una vez el contexto es incluido como información *a priori*, el siguiente paso es determinar la solución. Basados en la formulación bayesiana y en la energía de clase-condicional⁹ del dato observado (ecuación (7)).

$$U(dr|Wr) = (d_r - u_k) * \sum_k^{-1}(d_r - u_k) + \log|\Sigma_k| \quad (7)$$

Si se suman las dos funciones de energía se obtiene la función energía local potencial que representa la energía potencial que existe en una determinada vecindad (Dong, Forster y Milne, 1998). Una vez determinada la energía posteriori $U(Wr|dr)$ y asociados los parámetros β , se usa

7 Donde Z es la constante de normalización dada por la sumatoria de probabilidades conjunta de todas las posibles configuraciones (Ejemplo: para una imagen 256 x 256 con 8 clases, el total de todas las configuraciones sería $8^{256 \times 256}$).

8 Donde β es el parámetro potencial de dos cliques, donde se podría considerar el primer término especialmente para etiquetar k. El término $\delta(w_r, w_{r'})$ es la función de paso definida como $\delta(w_r, w_{r'}) = 1$ si $a \neq b$, y -1 en otro caso, y $\beta(>0)$ es un par parámetros potenciales clique $\beta * \delta(w_r, w_{r'})$. Entre más altos son los valores de β mas fuerte será el suavizado. En otras palabras, si w_r no acepta con sus vecinos, la energía priori más alta (ejemplo: probabilidad baja) será resultante.

9 Donde d_r es el dato observado u_k es el vector de medias de clase k.

la formulación bayesiana para construcción de una función objetivo también denominada energía *a posteriori*, que con la combinación de las ecuaciones (6) y (7), se obtiene la energía local posterior $U(W|d) = U(d|Wr) + U(Wr)$ (Li, 2001) (ecuación (8)).

$$U(Wr|dr) = (d_r - u_k) * \sum_k^{-1}(d_r - u_k) + \log|\Sigma_k| + \sum_{\{r,r'\}} \beta * \delta(w_r, w_{r'}) \quad (8)$$

Si se realiza la sumatoria de todas las funciones de energía local *a posteriori* (Paragios y Deriche, 2000) se obtiene la función de energía global (ecuación (9)).

$$E_{GP} = \sum_{i=1}^N U(Wr|dr) \quad (9)$$

Criterio MAP-CAM

El criterio de etiquetamiento para pixeles es encontrado en la estimación MAP. Este enfoque minimiza¹⁰ la solución de energía *a posteriori*, que es definida en la ecuación (10):

$$x_{MAP} = \operatorname{argmin} U(Wr|dr) \quad (10)$$

Si la función de energía es estrictamente convexa, una solución MAP-CAM puede ser obtenida mediante un básico enfoque de búsqueda, donde, cualquier mínimo local es también un mínimo absoluto.

Evaluación de la exactitud temática

La precisión de un proceso de clasificación se refiere al grado de concordancia entre las clases de la imagen o capa clasificada y una capa de referencia. Estas evaluaciones pueden ser dadas por matrices de confusión y el coeficiente Kappa (Cohen, 1960). Cuando se utilizan varios métodos de clasificación, las matrices de confusión resultantes se suelen comparar para analizar las diferencias en significancia (Plourde y Congalton, 2003). El coeficiente Kappa¹¹ se puede describir matemáticamente, como en la ecuación (11)¹² (Congalton *et al.*, 1988):

$$\hat{k} = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} \times x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} \times x_{+i})} \approx \frac{Pr(a) - Pr(e)}{1 - Pr(e)} \quad (11)$$

10 Recuerde que cuanto mayor es la energía U(evento), es menor la probabilidad P(evento).

11 Donde, r es el número de columnas (y filas) de la matriz de confusión, x_{ii} es la entrada (i, i) de la matriz de confusión, x_{i+} y x_{+i} son los totales marginales de la fila i y la columna j, respectivamente, y N es el número total de observaciones.

12 Donde Pr(a) es el acuerdo observado relativo, y Pr(e) es la probabilidad hipotética aleatoria.

El índice Kappa puede calcularse de forma individual para cada clase como Kappas condicionales, como lo indica la ecuación (12).

$$\hat{k}_{cond} = \frac{N_{x_{ii}} - x_i \cdot x_i}{N_{x_i} - x_i \cdot x_i} \quad (12)$$

De acuerdo con la escala de valoración del índice Kappa descrita por Landis y Koch (1977), los grados de acuerdo son: $K < 0,00$ es sin acuerdo, $0,00 \leq K < 0,20$ es insignificante, $0,20 \leq K < 0,40$ es mediano, $0,40 \leq K < 0,60$ es moderado, $0,60 \leq K < 0,80$ es sustancial y $0,80 \leq K < 1,00$ es casi perfecto.

La capa de referencia o validación fue generada desde un insumo *Sentinel 2A* de 10 metros de resolución a partir de un proceso cartográfico semiautomático y ajustada por métodos rigurosos de interpretación visual, edición y control visual por parte profesionales del Instituto Geográfico Agustín Codazzi, en los años 2017 y 2018.

Las imágenes seleccionadas corresponden a una *Landsat OLI* y una *Sentinel 2A*. Las muestras seleccionadas fueron las establecidas en la tabla 4. Los clasificadores usados –*KNN*, *Malahanobis*, *Erdas*– se emplean para comparar los resultados obtenidos de la implementación de *MatLab* de las cadenas de Markov lo que dan origen al clasificador CAM dentro de una interfaz gráfica. Este clasificador presenta las funcionalidades de *cargar* y *visualizar* imágenes en diferentes bandas espectrales, *selección* de muestreo de clases o coberturas, *algoritmos* clásicos de clasificación (*Kmedias* y *KNN* en modo supervisado). Además, permite la validación de la clasificación comparando con un *raster* de referencia, donde se genera la matriz de confusión y coeficiente Kappa como se observa en la figura 3. Las clasificaciones de las dos imágenes por los tres métodos se realizan con las mismas clases y las mismas muestras de entrenamiento. Finalmente, la validación utiliza el coeficiente Kappa con las mismas condiciones para las tres clasificaciones, el cual se realiza en el *software QGIS*.

Metodología

La metodología seguida en este estudio se desarrolla en cuatro etapas: a) selección de la imagen a clasificar; b) selección de las muestras de entrenamiento a partir de polígonos; c) aplicación del clasificador; d) validación de la

Resultados

En la figura 4 y 5 se presentan las salidas cartográficas con las capas *raster* clasificada, a partir del algoritmo de clasificación de los CAM.

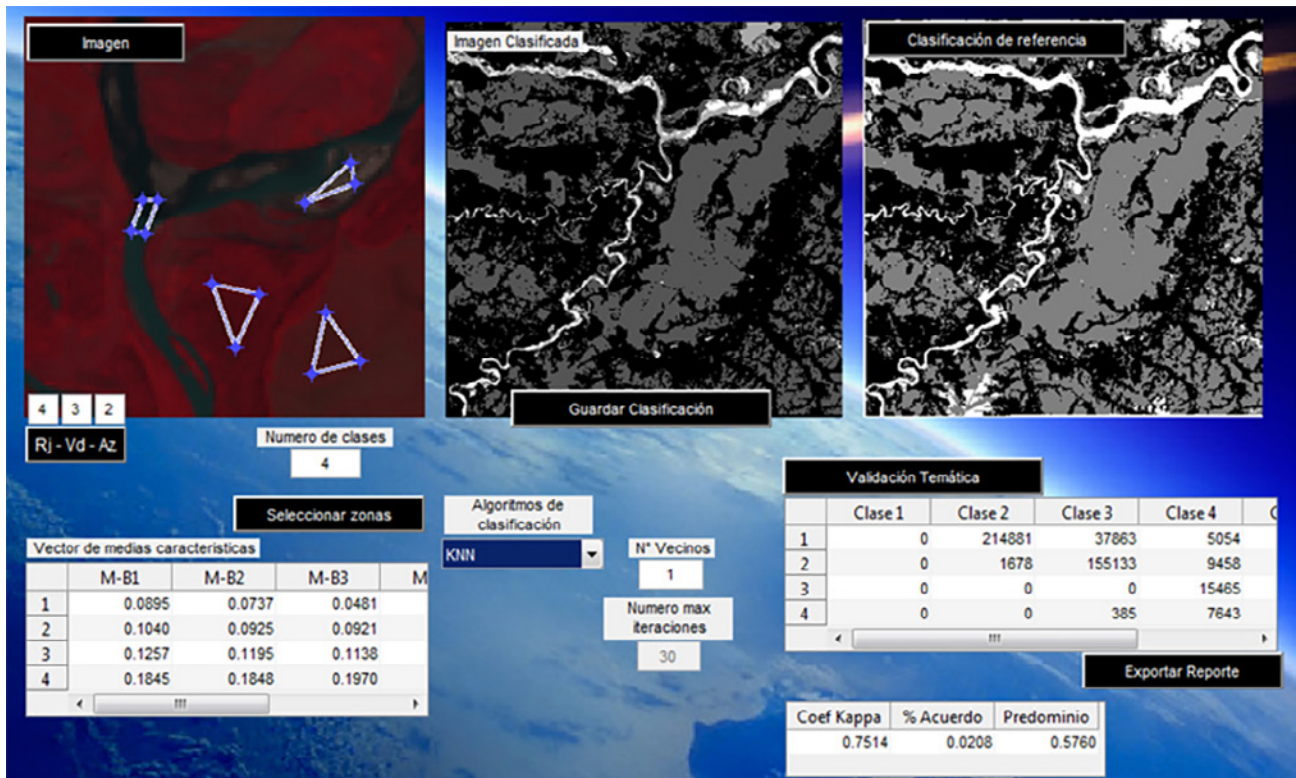


Figura 3. Interfaz gráfica desarrollada en *MatLab* para clasificación por CAM

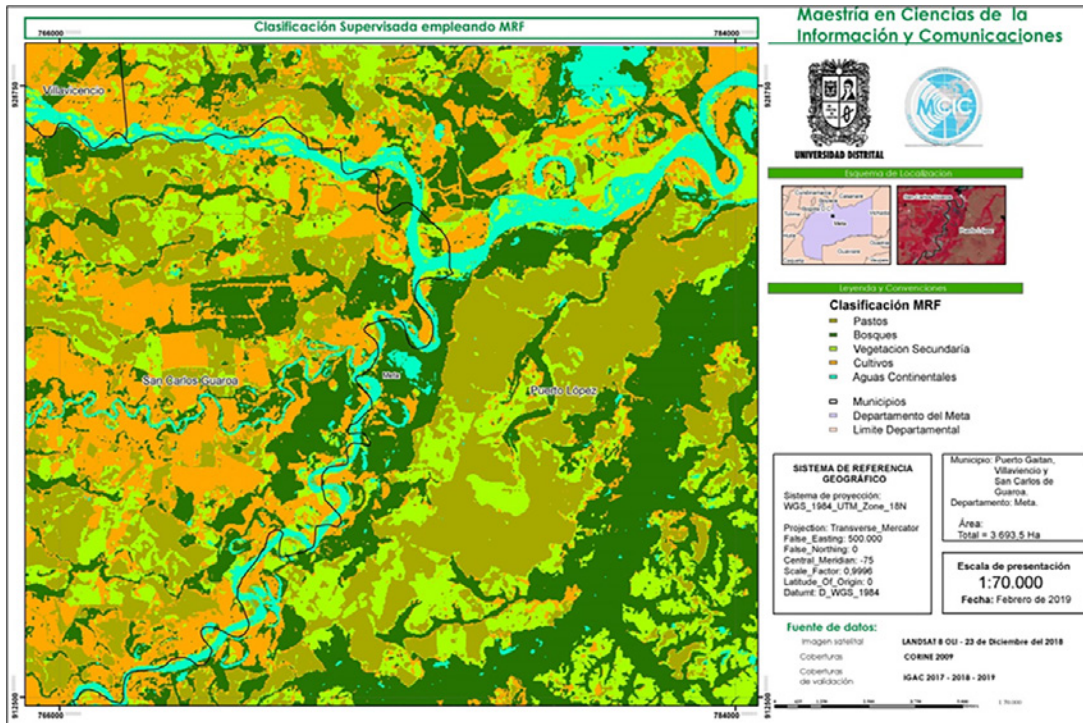


Figura 4. Mapa resultante de la clasificación CAM empleando la imagen *Landsat 8 OLI*

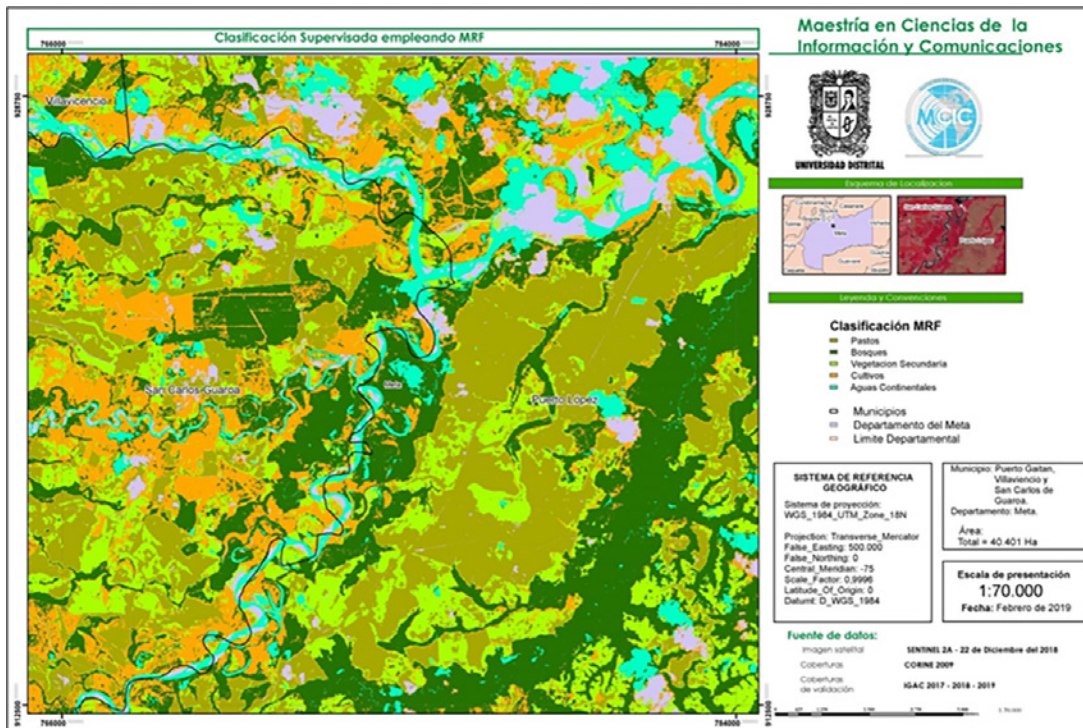


Figura 5. Mapa resultante de la clasificación CAM empleando la imagen *Sentinel 2A*

El resultado del análisis visual de la imagen *Landsat 8 OLI* clasificada es satisfactorio ya que cada una de las clases es bien definida y se logra ver con claridad la disociación entre ellas. Así mismo, el resultado del análisis visual de la imagen *Sentinel 2A* (figura 5) clasificada es

satisfactorio, pues cada una de las clases es bien definida, aunque es evidente que el algoritmo confundió las clases de las sombras de las nubes y el agua, debido a que son espectralmente parecidas en el rango espectral estudiado.

Validación de la imagen *LandSat 8 OLI*

Se relacionan los resultados (tablas 5 y 6) de la validación para la imagen *Landsat 8 OLI* de 30 metros de resoluciones espacial la capa clasificada por campos aleatorios de Markov obtuvo una precisión global del 65,09 % con un coeficiente Kappa 0,52.

Análisis de los resultados por clases o códigos

La cobertura que presenta mejor precisión son los pastos, la cual, la presenta un coeficiente Kappa de 0,80, lo que es representativo puesto que es la clase con mayor ocupación y área. Mientras que las clases 3, 4 y 5 son las coberturas con mayor confusión entre sí, lo que es de esperarse debido al alto grado de heterogeneidad de ciertas coberturas, como

los cultivos de arroz, espectralmente podrían confundirse con cuerpos de agua y vegetación secundaria, puesto que es bien sabido que este tipo de cultivo se inunda y, en consecuencia, disminuye la tasa de acierto de los algoritmos de clasificación supervisada aplicados a la imagen de satélite.

Validación de la imagen *Sentinel 2A*

Al igual que para la imagen *Landsat 8 OLI*, se presenta la validación de los resultados (tablas 7 y 8) de la clasificación para la imagen *Sentinel 2A* de 10 metros de resolución espacial; la capa clasificada por el método de los campos aleatorios de Markov obtuvo una precisión global de 66,29 %, con un coeficiente Kappa 0,53, lo que muestra que mejoró un poco la clasificación.

Tabla 5. Matriz de confusión resultado de la validación de la precisión de la clasificación

Código	1	2	3	4	5	Total
1	49948	121	5355	956	92	56472
2	2797	47286	12786	3796	150	66815
3	21164	1091	27188	4307	172	53922
4	5308	1403	7560	5576	21	19868
5	357	327	1839	895	1464	4882
Total	79574	50228	54728	15530	1899	201959

Fuente: elaboración propia.

Tabla 6. Resultado de la validación por cobertura de la precisión de la clasificación

Código	Coberturas	Precisión del productor (%)	Precisión del usuario (%)	Coefficiente Kappa
1	Pastos	62,76924	88,44737	0,80935
2	Bosques	94,14270	70,77153	0,61095
3	Vegetación secundaria	49,67840	50,42097	0,31991
4	Cultivos	35,90470	28,06523	0,22072
5	Aguas continentales	77,09320	29,98770	0,29323

Fuente: elaboración propia.

Tabla 7. Matriz de confusión o error resultado de la validación de la precisión de la clasificación de la imagen *Sentinel 2A* por el método de los campos aleatorios de Markov, mediante la herramienta implementada

Código	1.0	2.0	3.0	4.0	5.0	Total
1.0	50287	81	5780	952	30	57130
2.0	2200	42442	10862	2760	136	58400
3.0	18808	1065	25398	2384	126	47781
4.0	4537	2502	7140	4696	39	18914
5.0	563	665	1618	623	833	4302
Total	76395	46755	50798	11415	1164	186527

Fuente: elaboración propia.

Tabla 8. Resultado de la validación de la precisión de la clasificación de la imagen *Sentinel 2^a*, a través del método de los campos aleatorios de Markov, con *QGIS*

Código	Clase	Precisión del productor (%)	Precisión del usuario (%)	Coefficiente Kappa
1	Pastos	65,8249	88,0220	0,7971
2	Bosques	90,7753	72,6746	0,6353
3	Vegetación secundaria	49,9980	53,1550	0,3562
4	Cultivos	41,1388	24,8281	0,1992
5	Aguas continentales	71,5635	19,3630	0,1885

Fuente: elaboración propia.

Análisis de los resultados por clases o códigos

La cobertura que presenta la mejor precisión, al igual que en la imagen *Landsat* clasificada por este mismo método, es la cobertura de pastos, la cual presenta un coeficiente Kappa de 0,79, un poco menor que con la imagen *Landsat 8 OLI*, pero en parte es representativo puesto que es la primera clase con mayor ocupación y área. Se observa también que mejoró su desempeño en las coberturas de bosques y vegetación secundaria. Mientras que las coberturas de aguas continentales y cultivos para este método son las que presentan más confusión debido a la nubosidad. Sin embargo, la tasa de acierto global del algoritmo desarrollado en esta investigación es mayor que la de métodos de clasificación convencionales o clásicos empleando la misma imagen y muestras espectrales, las cuales se presentan a continuación.

Comparación de los resultados obtenidos

La comparación con otros métodos de clasificación se ha llevado a cabo sobre las mismas imágenes, los mismos polígonos de entrenamiento y el mismo raster de validación en los tres casos, para de esta manera establecer un parámetro de evaluación a partir del coeficiente Kappa, el cual permitió comparar los resultados. En la tabla 9 se muestra el resumen de los resultados con cada uno de los métodos implementados:

Como se observa en la tabla 9, el clasificador implementado fue el que mejor eficiencia presentó, ya que tuvo

el índice Kappa más alto entre las tres clasificaciones analizadas, esto se ve reflejado tanto en la imagen como en su matriz de confusión. De esta manera se cumple con el objetivo planteado de lograr una clasificación con un índice de exactitud temática competitivo.

Conclusiones

Como conclusión, el método de clasificación de los CAM, cuyo funcionamiento se basa en la identificación adecuada de las vecindades espaciales y espectrales, permitió eliminar posibles ambigüedades, y de este modo agrupar los píxeles de una imagen a sus correspondientes clases, mejorando la tasa de acierto de la clasificación.

Puesto, que el método de los CAM implementado ha conseguido alcanzar el objetivo de generar una clasificación con mejores niveles de exactitud temática, que los otros métodos clasificación convencionales validados de uso comercial con las dos imágenes de satélite con complejidad alta.

En el análisis comparativo por clases se concluye que el método propuesto de CAM representa de manera significativa las coberturas de los pastos y bosques, en comparación con los clasificadores clásicos.

Por otro lado, la aplicación desarrollada en *MatLab* permite emplear las funcionalidades de *mapping toolbox* que facilitan la conservación del sistema de referencia espacial, lo que genera beneficio para los investigadores que les gusta experimentar con nuevos algoritmos sobre imágenes de observación de la Tierra y personal especializado en teledetección.

Tabla 9. Comparación de los resultados obtenidos

Método de clasificación	<i>Landsat 8 OLI</i>		<i>Sentinel 2A</i>	
	% acuerdo	Coefficiente kappa	% acuerdo	Coefficiente Kappa
<i>KNN</i>	58,60	0,397	54,75	0,346
<i>Malahanobis - ERDAS</i>	59,89	0,44	49,67	0,3081
CAM	65,09	0,520	66,29	0,531

Fuente: elaboración propia.

Referencias bibliográficas

- Acuña, A.J. y Llano, E.G. (2010). Estado actual de los metodos automaticos de anotacion semantica de imagenes de teledeteccion espacial.
- Anderson, J.R., Hardy, E.E., Roach, J.T., Witmer, R.E. y Peck, D.L. (1976). *A Land Use and Land Cover Classification System for Use With Remote Sensor Data. A Revision of the Land Use Classification System as Presented in U.S. Geological Survey Circular*. Washington, D.C., EE. UU.: United States Government Printing Office.
- Ariza, A., García, S., Rojas, S. y Ramírez, M. (2013). Desarrollo de un modelo de corrección de imágenes de satélite para inundaciones: (CAIN - Corrección Atmosférica e Índices de Inundación).
- Besag, J. (1974). Spatial interaction and the statistical analysis of lattice systems. *Journal of the Royal Statistical Society. Series B*, 36(2), 192–236. DOI: <https://doi.org/10.2307/2984812>
- Borras, J., Delegido, J., Pezzola, A., Pereira, M., Morassi, G. y Camps-Valls, G. (2017). Clasificación de usos del suelo a partir de imágenes Sentinel-2. *Revista de Teledetección*, (48), 55–66. DOI: <https://doi.org/10.4995/raet.2017.7133>
- Chuvieco, E. (2008). Teledetección ambiental: La observación de la Tierra desde el Espacio. *Entorno Geografico*, 3, 575. Recuperado de http://www.slideshare.net/alinelabelen/savedfiles?s_title=teledeteccion-ambiental-listo&user_login=jaiflo7503
- Congalton, R. (1988). Comparison of sampling schemes used in generating error matrices for assessing the accuracy of maps generated from remotely sensed data. *Photogrammetric Engineering and Remote Sensing*, 54, 593–600.
- Cohen, J. (1960). A coefficient of agreement for nominal scales, *XX*(1), 37–46.
- Cui, Z., Wang, Y., Gao, X., Li, J. y Zheng, Y. (2016). Multispectral image classification based on improved weighted MRF Bayesian. *Neurocomputing*, 212, 75–87. DOI: <https://doi.org/10.1016/j.neucom.2016.03.097>
- Derin, H., Elliott, H., Cristi, R. y Geman, D. (1984). Bayes Smoothing Algorithms for Segmentation of Binary Images Modeled by Markov Random Fields. *IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI-6*(6), 707–720. DOI: <https://doi.org/10.1109/TPAMI.1984.4767595>
- Dong, Y.D.Y., Forster, B. y Milne, A. (1998). Evaluation of radar image segmentation by Markov random field model with Gaussian distribution and Gamma distribution. *IGARSS '98. Sensing and Managing the Environment. 1998 IEEE International Geoscience and Remote Sensing Symposium Proceedings. (Cat. No.98CH36174)*, 3(5), 1617–1619. DOI: <https://doi.org/10.1109/IGARSS.1998.691645>
- García, A., Martínez, G., Núñez, E. y Guzmán, A. (1998). Clasificación supervisada, inducción de arboles de decisión, algoritmo kd. *Proc. Simp. Int. de Comp. CIC*, 98, 602–614.
- Gleich, D. (2012). Markov random field models for non-quadratic regularization of complex SAR images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(3), 952–961. DOI: <https://doi.org/10.1109/JSTARS.2011.2179524>
- Guijarro Mata-García, M. (2010). Identificación de texturas en imágenes naturales: nuevas estrategias locales y globales.
- Landis, J.R. y Koch, G.G. (1977). The measurement of observer agreement for categorical data. *Biometrics*, 33(1), 159–174.
- Lang, R., Shao, G., Pijanowski, B.C. y Farnsworth, R.L. (2008). Optimizing unsupervised classifications of remotely sensed imagery with a data-assisted labeling approach. *Computers & Geosciences*, 34(12), 1877–1885. DOI: <https://doi.org/10.1016/j.cageo.2007.10.011>
- Li, S. (2001). *Markov Random Field Models in Computer Vision*. Springer Verlag, 2263(4).
- Liao, W., Tang, J., Rosenhahn, B. y Yang, M.Y. (2015). Integration of Gaussian Process and MRF for Hyperspectral Image Classification, 3–6.
- Lopez, E. (2007). Segmentacion de coberturas de la tierra espectralmente similares empleando CAM. Características y geometría estocástica.
- Lorette, A., Descombes, X. y Zerubia, J. (2004). Texture Analysis through a Markovian Modelling and Fuzzy Classification: Application to Urban Area Extraction from Satellite Images. *International Journal of Computer Vision*, 36(3), 221–236.
- Mather, P. y Tso, B. (2009). Classification methods for remotely sensed data.
- Mena, J. (2003). Extracción automática de entidades cartográficas lineales en zonas rurales o semiurbanas a partir de imágenes satélite en color de alta resolución.
- Paragios, N. y Deriche, R. (2000). Coupled Geodesic Active Regions for Image Segmentation: A Level Set Approach. *Computer Vision*, 224–240.
- Perea, A.J., Meroño, J.E. y Aguilera, M.J. (2009). Clasificación orientada a objetos en fotografías aéreas digitales para la discriminación de usos del suelo. *Interciencia*, 34(9)
- Plourde, L. y Congalton, R. (2003). Sampling method and sample placement: how do they affect the accuracy of remotely sensed maps. *Photogrammetric Engineering and Remote Sensing*, 69(3), 289–297. DOI: [https://doi.org/10.1109/0099-1112/03/6903-289\\$3.00/0](https://doi.org/10.1109/0099-1112/03/6903-289$3.00/0)
- Zhan, Y., You, H. y Fuqing, C. (2013). Bayesian edge detector for SAR imagery using discontinuity-adaptive Markov random field modeling. *Chinese Journal of Aeronautics*, 26(6), 1534–1543. DOI: <https://doi.org/10.1016/j.cja.2013.04.059>

