

Memorias



Sociedad Latinoamericana en
Percepción Remota y Sistemas
de Información Espacial
Capítulo Colombia

30
AÑOS

Medellín, Colombia
29 de Septiembre al 3 de Octubre de 2014



Determinación de la fracción urbana a partir de imágenes satelitales para la modelación del clima en ciudades

Determination of urban fraction from satellite imagery for climate modeling in cities

Flórez, L.Z.¹; Botero, V.², Jiménez, J.F.²; Ochoa, A.²

¹Estudiante de Maestría en Ingeniería – Recursos Hidráulicos. ²Profesor asociado.

^{1,2}Universidad Nacional de Colombia Sede Medellín. Facultad de minas. Departamento de Geociencias y Medio Ambiente. Carrera 80 No 65-223 - Núcleo Robledo Oficina M2-301.

[¹lzflorezb@unal.edu.co](mailto:lzflorezb@unal.edu.co)

Resumen

Los modelos climáticos requieren una representación adecuada de la superficie terrestre, dado que sus propiedades regulan algunos procesos bioquímicos y el intercambio de materia y energía con la atmósfera; en los últimos años, imágenes derivadas de sensores remotos han sido ampliamente utilizadas para este fin. En el presente artículo se evalúa el desempeño de diferentes métodos de clasificación supervisada para determinar el porcentaje de cobertura urbana (fracción urbana) sobre el área metropolitana del Valle de Aburrá (Colombia), a partir de un mosaico de imágenes multiespectrales. Los algoritmos evaluados fueron Máxima Verosimilitud (MLC), Mínima Distancia (MND), Paralelepípedos (PL), SAM (del inglés, *Spectral Angle Mapper*) y Distancia de Mahalanobis (MHD). Para elegir el mejor, se digitalizó una celda de 1km² cerca del centro de la ciudad y, mediante matrices de confusión, se comparó la categoría observada con la predicha por cada algoritmo. Los resultados sugieren que la clasificación de imágenes multiespectrales por los métodos SAM y de Máxima Verosimilitud representan apropiadamente las características del terreno, convirtiéndose estos métodos en

herramientas adecuadas para “urbanizar” modelos climáticos de mesoescala como, por ejemplo, el sistema WRF-urbano (*Weather Research and Forecasting*).

Abstract

Climate models require proper representation of the earth's surface, since their properties regulate some biochemical processes and the exchange of matter and energy with the atmosphere; in recent years, images derived from remote sensing have been widely used for this purpose. In this paper the performance of different methods of supervised classification is evaluated to determine the percentage of urban coverage (urban fraction) on the metropolitan area of the Aburrá Valley (Colombia) from a mosaic of multispectral images. The algorithms evaluated were Maximum Likelihood (MLC), Minimum Distance (MND), Parallelepipeds (PL), SAM (English, *Spectral Angle Mapper*) and Mahalanobis distance (MHD). To choose the best one among them, it was digitized a cell of 1km² near downtown and, using confusion matrix, we compared the category observed with that predicted by each algorithm. The results suggest that the evaluations of urban fraction by the methods SAM and Maximum likelihood represent appropriately the characteristics of the land, becoming these methods in convenient tools to “urbanize” mesoscale climate models as, for example, the urban-WRF system.

Palabras claves: Clasificación supervisada, Modelación del clima urbano, Fracción urbana impermeable, Máxima verosimilitud, SAM.

Keywords: Supervised classification, Climate modeling, Maximum likelihood, SAM, Urban fraction.

1. Introducción

Los primeros modelos atmosféricos para áreas urbanas atribuían a la ciudad una categoría de cuerpo homogéneo, plenamente diferenciado del terreno natural o rural circundante en cuanto a sus características térmicas y de rugosidad. Sólo con el desarrollo de las tecnologías de cómputo, la vasta heterogeneidad del paisaje urbano comenzó a tomar forma en términos de sus características de cobertura del suelo (impermeable o no), la morfometría de las construcciones (altura de los edificios, ancho de los corredores viales, entre otros), materiales de construcción (de techos, paredes y vías) y actividad de la población urbana (WMO, 2008). A diferencia de los estudios gruesos de mesoscala que se discutían hace apenas unos años, donde las ciudades aparecían como elementos singulares en el dominio de interés, los actuales permiten hacer un análisis más fino en la escala local y la microscala de fenómenos como la dispersión de contaminantes, islas de calor, riesgos ambientales urbanos, entre otros.

Desde este punto de vista, y aún si no se buscara una aproximación muy detallada de los procesos meteorológicos que tienen lugar en la capa límite urbana, los patrones de uso y cobertura del suelo aportan información fundamental para el entendimiento de los procesos de interacción suelo-atmósfera en las ciudades. De ahí que, se concluye en numerosas investigaciones, éstas tienden a ser más secas y calientes que sus alrededores debido al modo como se afectan los flujos y la disponibilidad del agua sobre el territorio urbano, y a como se alteran las diferentes componentes de los balances de energía en superficie. Esto explica porqué proyectos como, por ejemplo, el National Urban Database and Access Portal

Tool, conocido como NUDAPT (Ching et al, 2009), cuyo propósito principal es el de aportar información más confiable y específica sobre variables físicas urbanas para mejorar el desempeño de los modelos de clima y meteorología en ciudades de los Estados Unidos, incluye en sus bases de datos campos específicos para la cobertura del suelo.

Un modelo de última generación como el WRF (Skamarock et al, 2008) en su versión urbanizada permite, entre otras opciones, utilizar el esquema de dosel urbano de una sola capa (en inglés Single Layer Urban Canopy Model, SLUCM), basado en la propuesta de Kusaka y Kimura (Chen et al, 2011). El amplio uso que se le está dando a este esquema responde, en parte, a la relativa sencillez del código y a los modestos requerimientos de información del mismo. Pero no menos significativo es que investigadores como Loridan y Grimmond (2012), después de hacer un minucioso análisis de sensibilidad de las variables del esquema, concluyen que el SLUCM se desempeña tan bien como cualquier otro modelo actual en el estado del arte, lo cual sugiere que se debería esperar un desempeño similar para el WRF-SLUCM.

Este esquema requiere información de entrada de la variable fracción urbana (F_{urb}), definida en primera instancia como:

Ecuación 1

$$F_{urb} = \frac{\text{Área construida}}{\text{Área de la celda}}$$

La cual es luego reclasificada en tres categorías de uso del suelo: residencial de baja densidad, residencial de alta densidad y comercial/industrial. A diferencia de las demás variables de entrada, la información de fracción urbana debe ser específica para cada

ciudad, mientras que las demás variables, a falta de información sobre las condiciones locales, pueden ser sustituidas por un conjunto de parámetros por defecto que tiene el WRF, el cual se ha venido ajustando a partir de estudios relacionados principalmente con ciudades de Europa y los Estados Unidos. En otras palabras, el primer paso hacia una modelación urbana con WRF-SLUCM es determinar F_{urb} en una escala conveniente para la zona urbana de interés, que por lo general corresponde a celdas del orden de 1 km^2 o menos.

Los sensores remotos permiten obtener valores de F_{urb} a este nivel de detalle a partir de la clasificación de imágenes captadas por ellos. Existen dos formas de realizar procedimientos de clasificación: supervisada y no supervisada. La clasificación supervisada requiere un conocimiento previo del área de estudio por parte del analista, el cual define grupos de píxeles con una respuesta espectral similar para generar las clases de interés, estos grupos se conocen como polígonos de entrenamiento. Luego del entrenamiento, se define un método de clasificación que asignará a cada píxel no clasificado la clase más cercana a su valor espectral. De otro lado, la clasificación no supervisada no requiere que el analista defina de forma previa las clases de interés, dado que se emplean algoritmos de agrupamiento o *clustering* con un número definido de clases (Richards, 2013).

En lo que sigue mostraremos una metodología para obtener F_{urb} a partir de la clasificación supervisada de imágenes de satélite y ortofotos. Aunque el caso de estudio corresponde a las condiciones urbanas del Valle de Aburrá (Colombia), se verá cómo la aplicación de la metodología es posible en otras ciudades o áreas metropolitanas muy disímiles, incluso a partir de imágenes gratuitas como LANDSAT.

2. Metodología

2.1. Área de estudio

El valle de Aburrá está ubicado al norte de la cordillera central de los Andes de Colombia, en la latitud N $6^{\circ}15'$ y longitud O $75^{\circ}35'$, aproximadamente. Los picos opuestos de las montañas que lo rodean distan entre sí de 10 a 20 km, siendo mayor esta distancia en la ciudad de Medellín, donde la profundidad es del orden de unos 1000 metros. En la base de este valle y en sus laderas se asienta una población que supera los 3.5 millones de habitantes, en un área metropolitana relativamente estrecha compuesta por 10 municipios ubicados en el centro del departamento de Antioquia, entre los cuales el municipio de Medellín es el más urbanizado.

El río Medellín, que recorre de sur a norte este valle, tiene un alineamiento algo quebrado, de modo que esta característica, junto con relativa estrechez del cañón montañoso, dificulta la circulación de material atmosférico contaminante, el cual proviene en mayor proporción, como en muchas otras ciudades del mundo, del tránsito vehicular. En tales circunstancias, es comprensible el interés que suscitan los procesos vinculados con las condiciones atmosféricas y de calidad del aire, con el agravante de que la topografía compleja obliga a probar recursos de simulación relativamente más complejos quizás más aptos para capturar rasgos significativos de este ambiente urbano. Justo por esto se viene buscando una buena configuración del WRF-urbano con el esquema SLUCM, para estudiar la atmósfera de ésta área metropolitana. El dominio de

aplicación elegido para el modelo contiene 67 celdas en sentido este-oeste (entre los 75.27° y 75.87° de longitud oeste) y 87 celdas en sentido norte -sur (entre los 5.84° y 6.63° de latitud norte), cada celda con dimensiones de 1km x 1km (Figura 1).

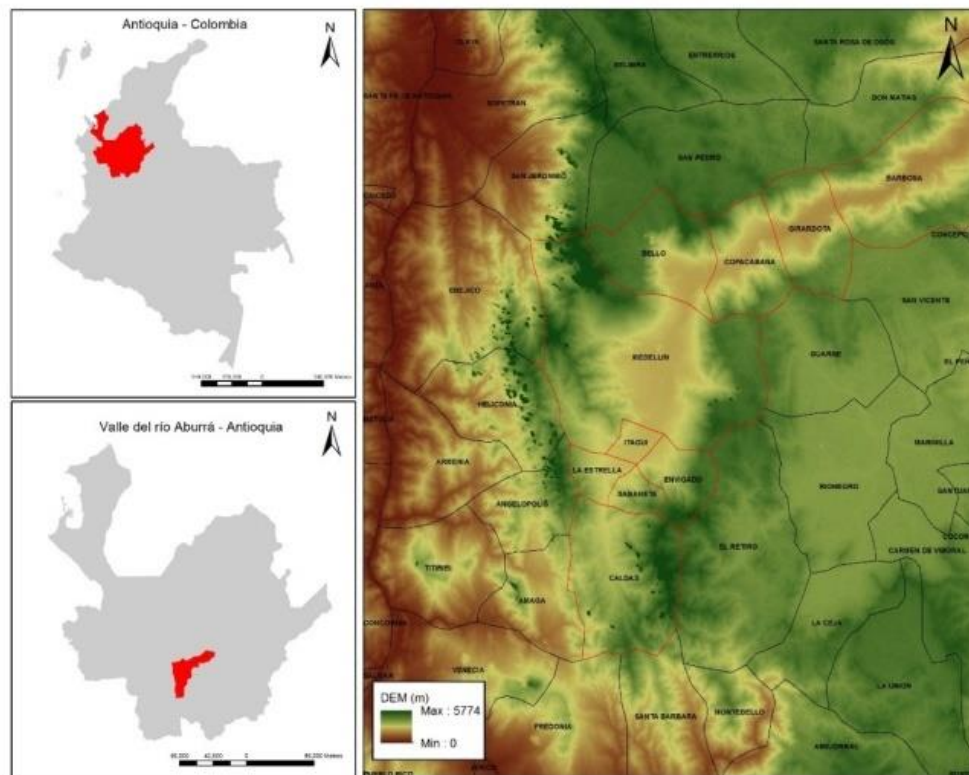


Figura 1. Zona de estudio

2.2. Obtención de la información

En el dominio de aplicación del modelo se conformó un mosaico de imágenes que incluye información de diferentes fuentes. El área correspondiente a la zona más urbanizada del dominio está representada por una ortofoto tomada en el año 2012 por el Área Metropolitana del Valle de Aburrá (AMVA) y en menor proporción por una imagen del sensor Quick Bird del año 2006, propiedad del AMVA. El área restante se

analizó a partir de una imagen Landsat 7 ETM del 2006 obtenida desde la plataforma virtual del Servicio Geológico de los Estados Unidos (USGS) (earthexplorer.usgs.gov).

La Figura 2 presenta las fuentes de información empleadas en el mosaico de imágenes de la zona de estudio y las características de las imágenes que lo conforman.

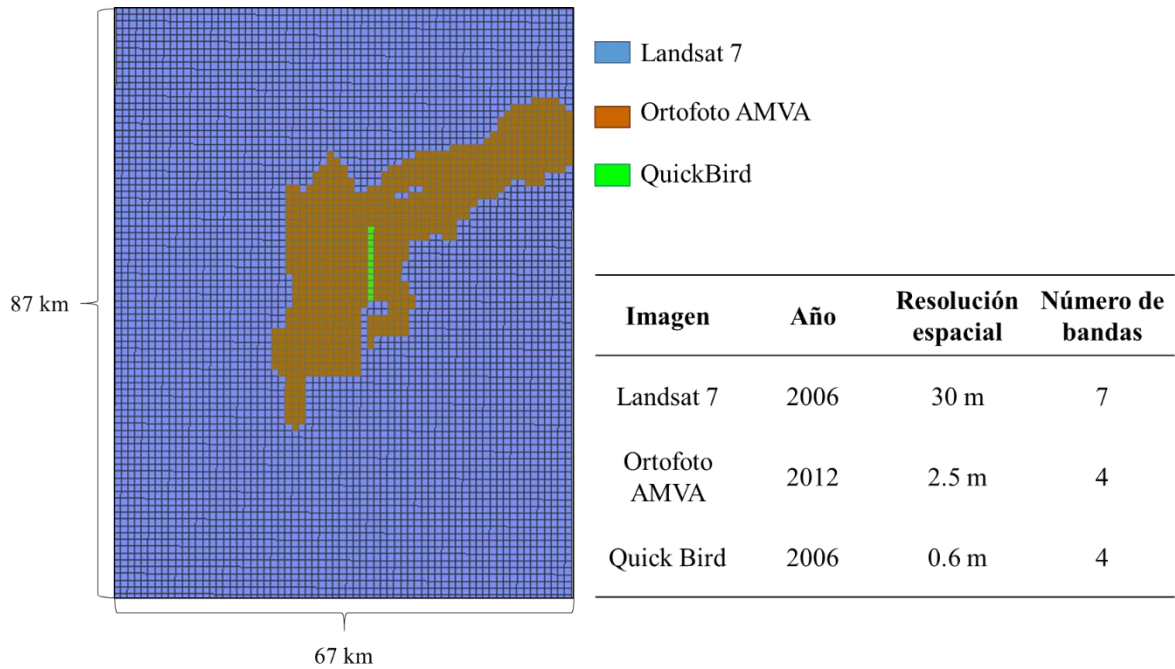


Figura 2. Fuentes de información y características de las imágenes

2.3. Procesamiento de la imagen y clasificación supervisada

El mosaico de imágenes multiespectrales fue construido y procesado en el software ENVI 5.0. Luego de la corrección atmosférica y geométrica de las imágenes se definieron cinco clases de cobertura en el área de estudio agrupadas en dos categorías: i) urbano (vías, techos blancos, techos naranja) y ii) no urbano (pastos y vegetación

arbórea). Para definir los polígonos de entrenamiento de cada clase se utilizó la combinación en falso color RGB-432, como se muestra en la Figura 3.

a. Clase árboles

b. Clase techos blancos




Figura 3. Ejemplo de polígonos de entrenamiento en la combinación en falso color RGB-432.

Luego del entrenamiento, se realizó la clasificación supervisada por diferentes métodos agrupados según el criterio de decisión que utilizan: distancia, probabilidad o ángulo espectral. Los algoritmos basados en la distancia, paralelepípedos (PL), mínima distancia (MND) y distancia de Mahalanobis (MHD), emplean principalmente valores espectrales medios para diferentes clases, omitiendo su varianza. El método de probabilidad de máxima verosimilitud (MLC), incorpora la media y la varianza del conjunto de datos. Por último, el método SAM utiliza los ángulos espectrales formados entre un valor de referencia o polígono de entrenamiento y el píxel a clasificar (South et al., 2004). Todos los algoritmos fueron implementados en el software ENVI 5.0.

2.4. Análisis y selección del método de clasificación

Para evaluar la precisión de los métodos de clasificación, se empleó un método ampliamente usado para este fin conocido como matriz de confusión (Jenness & Wynne, 2005). La matriz de confusión determina la precisión de los resultados de clasificación comparando las clases asignadas con puntos de control tomados en campo a partir de tablas cruzadas de valores observados y predichos. Esta matriz fue calculada en el lenguaje de programación R statistics versión 3.1 y el programa R-Studio versión 0.98.953.

Tabla 1. Matriz de confusión con y No urbano		Observado	
		Urbano	No urbano
Clasificado	Urbano	A	B
	No urbano	C	D

Donde A y D corresponden a píxeles correctamente clasificados y C y B a píxeles incorrectos. A partir de la matriz de confusión se derivan algunas métricas útiles para la selección del mejor algoritmo de clasificación. Entre ellas el índice de sensibilidad (S) indica la probabilidad de que un píxel clasificado en una clase i pertenezca efectivamente a dicha clase (Ecuación 2). El índice de especificidad (E) indica la probabilidad de que un píxel que no pertenece a una clase determinada sea clasificada como no perteneciente a dicha clase (Ecuación 3) (Altman & Bland, 1994).

Ecuación 2

$$S = \frac{A}{A + C}$$

Ecuación 3

$$E = \frac{D}{B + D}$$

Para construir la matriz de datos observados, se digitalizó una celda de 1 km² en el centro de la zona de estudio validada con conocimiento previo de los autores, como lo muestra la Figura 4. Estas clases fueron reclasificadas en una matriz binaria de categorías urbano (1) y no urbano (0) para construir la matriz de confusión con los resultados de cada algoritmo.

a. Composición en color verdadero RGB

b. Digitalización manual de clases.



Figura 4. Construcción de matriz de datos observados.

3. Resultados y discusión

La Figura 5 presenta los resultados de los métodos de clasificación en cuatro clases de cobertura terrestre y dos clases sin información: nube y sin clasificar (*Unclassified*).

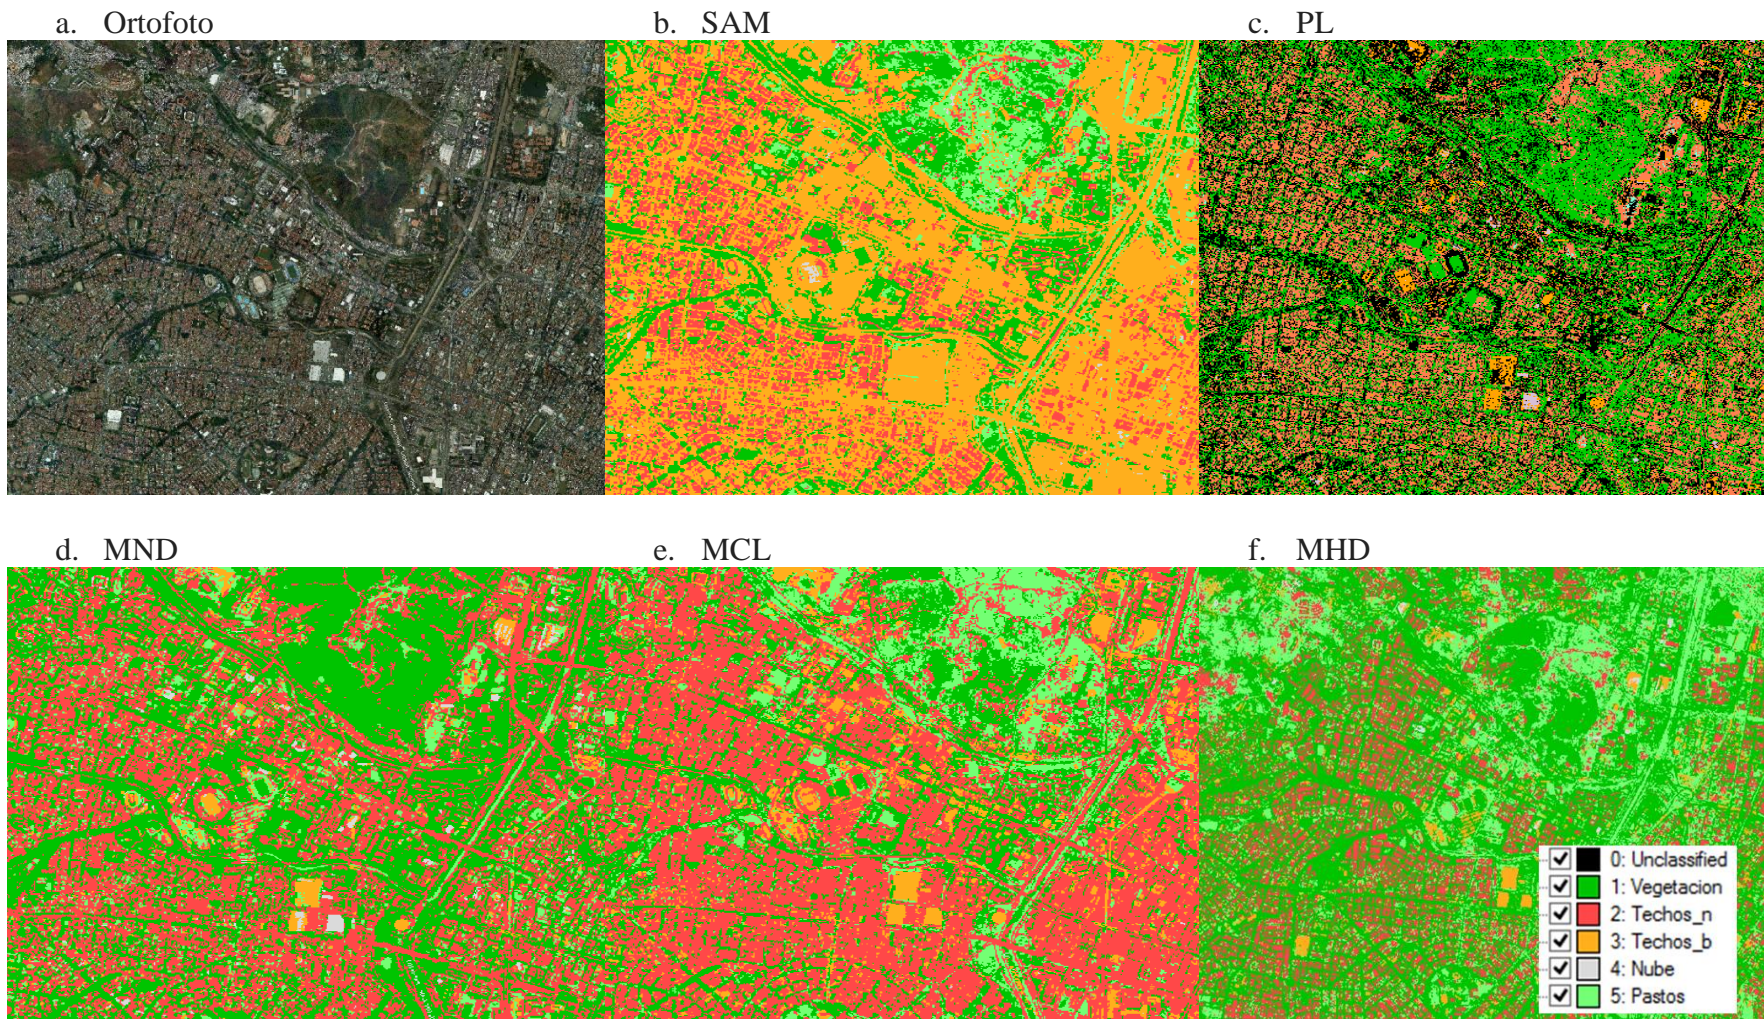


Figura 5. Resultados de los diferentes algoritmos de clasificación supervisada para el cálculo de la fracción urbana.

La Tabla 2 presenta las métricas empleadas para evaluar el desempeño de los algoritmos calculadas a partir de la matriz de confusión entre las clases observadas y las asignadas por cada algoritmo.

Tabla 2. Métricas de evaluación de los algoritmos de clasificación.

Algoritmo	Precisión – Matriz de confusión	Sensibilidad (S)	Especificidad (E)
SAM	0.90**	0.80**	0.94*
PL	0.42	0.26	0.86
MND	0.66	0.40	0.94
MCL	0.82*	0.57*	0.95**
MHD	0.39	0.27	0.99

SAM: *Spectral Angle Mapper*, PL: Paralelepípedos, MND: Mínima distancia, MCL: Máxima verosimilitud, MHD: Distancia de Mahalanobis.

De los métodos evaluados, dos presentaron desempeños aceptables en la clasificación de la cobertura urbana. El método *Spectral Angle Mapper* (SAM) presentó la mayor precisión (90%) y sensibilidad (80%), seguido del algoritmo de Máxima Verosimilitud (MCL) (S=82% y E=57%). Por su parte, el algoritmo MHD presenta la menor precisión (0.39%) y como se observó en la Figura 5, sobreestima las áreas de pasto y vegetación arbórea. MND aunque comete el mismo error que MHD en cuanto a las coberturas no urbanas, presenta una precisión más aceptable (66%). Por último, el método PL además de presentar una precisión del 42% deja una cantidad considerable de píxeles sin clasificar. El índice de especificidad no aporta un criterio de selección claro entre los métodos, dado que los 5 algoritmos presentan valores superiores al 85%.

Entre los dos métodos más precisos, se observan diferencias claras en los resultados de la clasificación (Figura 5). El algoritmo SAM diferencia bien las zonas urbanas de las no urbanas, sin embargo no distingue de forma adecuada entre las clases Techos naranja y Techos blanco de la categoría Urbano, sobreestimando la ocurrencia de este último. Por el contrario, aunque MCL presenta una precisión inferior a SAM, distingue adecuadamente entre estas clases. La discriminación entre clases de una misma categoría es necesario para definir las propiedades térmicas de los materiales, las cuales influyen en las interacciones suelo-atmósfera simuladas por los modelos climáticos. Así, la elección del método de clasificación dependerá sustancialmente del objetivo del estudio, de manera que para el cálculo de la fracción urbana SAM presentará el mejor desempeño, mientras que para la clasificación de las propiedades térmicas de los materiales será más conveniente emplear MCL. A esta ambigüedad en la elección del método de clasificación se refirió Castillejo-González *et al.* (2009), quien explicaba que no existe un método de clasificación ideal, sino que el método más preciso para cada estudio está determinado por sus requerimientos.

Los resultados de este estudio coinciden con los encontrados por South *et al.* (2004) y Souza & Mercante (2013), quienes luego de comparar cinco métodos de clasificación concluyeron que el algoritmo SAM obtuvo los mejores resultados. La precisión de SAM se debe a su capacidad de evadir los errores inducidos por efectos del brillo y la luz solar en las imágenes, dado que este método extiende los vectores de los píxeles no clasificados y los polígonos de referencia a través de todos los niveles de brillo posibles.

De acuerdo a los resultados encontrados, el algoritmo *Spectral Angle Mapper* fue empleado para el cálculo de la fracción urbana en el dominio de aplicación del modelo WRF.

La Figura 6 presenta los resultados del cálculo de Furb en el área de estudio. En general se observan gradientes en la densidad de celdas urbanizadas, de forma que las áreas periféricas presentan los menores valores, los cuales se incrementan hacia el centro del dominio. En ella se observa de forma clara la concentración de celdas de alta densidad urbana sobre el eje del río Medellín y la aparición de centros poblados hacia el sureste del dominio del dominio.

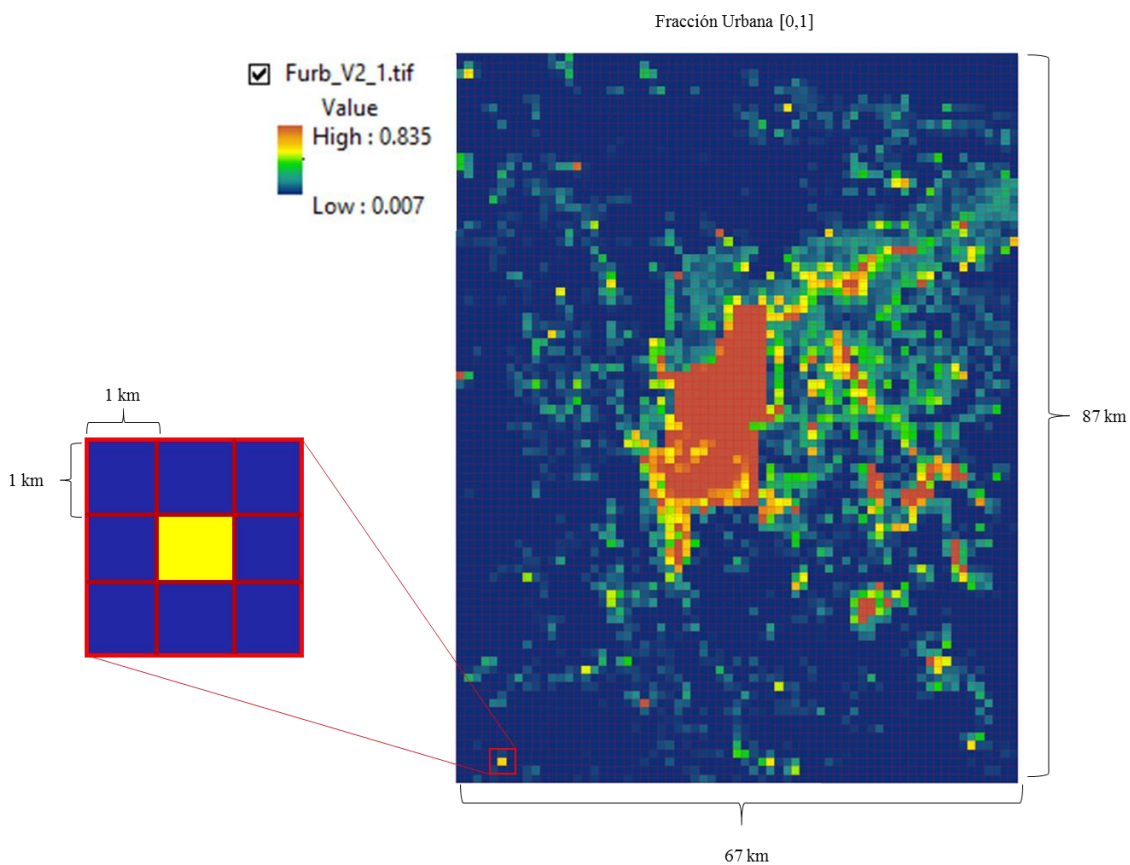


Figura 6. Fracción urbana obtenida de la clasificación por el método SAM de un mosaico de imágenes multiespectrales.

Los valores del parámetro F_{urb} , comprendidos en un rango entre 0 y 0.83, fueron reclasificados en tres categorías de uso del suelo: residencial de baja densidad, residencial de alta densidad y comercial/industrial para ser incluidos en el modelo de pronóstico.

4. Conclusiones

Los alcances de este estudio demuestran que la clasificación de imágenes multiespectrales de alta resolución por el método *Spectral Angle Mapper* es una herramienta adecuada para determinar el porcentaje de cobertura urbana con la precisión necesaria para garantizar la confiabilidad de los resultados de los modelos climáticos en zonas urbanas. De otro lado, el método de Máxima verosimilitud distingue mejor entre las clases de las categorías Urbana y no Urbana. La discriminación entre clases de una misma categoría es necesario para definir las propiedades térmicas de los materiales, las cuales influyen en las interacciones suelo-atmósfera simuladas por los modelos climáticos, sin embargo esta discriminación no se precisa para el cálculo de la fracción urbana. De esta manera, para seleccionar el algoritmo es preciso esclarecer el objetivo de la clasificación, sin embargo en general se encontró que los métodos basados en criterios de distancia presentaron la menor precisión respecto a los de ángulo espectral (SAM) y probabilidad (MCL).

La obtención del parámetro F_{urb} es posible a partir de la integración de información de diferentes niveles de detalle e incluso sólo mediante información satelital disponible de forma gratuita como las imágenes del satélite Landsat 7 y posteriores.

Una cuantificación equívoca de la fracción urbana podría causar alteraciones en los flujos de calor que conducen a errores en los pronósticos meteorológicos. Los trabajos que se desarrollen alrededor de esta investigación, confirmarán los niveles de incertidumbre de los modelos de pronóstico en función de la fracción urbana.

Agradecimientos

Los autores agradecen al Área Metropolitana del Valle de Aburrá por la información suministrada para el presente estudio, a Colciencias y la Universidad Nacional de Colombia por el apoyo económico al proyecto y a los profesores del Departamento de Geociencias y Medio Ambiente de la Universidad Nacional de Colombia por el apoyo.

Referencias

- Altman, D.G., Bland, J.M. (1994) "Diagnostic tests 1: sensitivity and specificity," *British Medical Journal*, vol 308, 1552.
- Castillejo-González, I.L., F. López-Granados, A. García-Ferrer, J.M. Peña-Barragán, M. Jurado-Ex-pósito, M.S. Orden, and M. González-Audicana. 2009. Object - and pixel-based analysis for map- ping crops and their agro-environmental associat- ed measures using QuickBird imagery. *Computers and Electronics in Agriculture* 68: 207-215.
- Chen, F., Kusaka, H., Bornstein, R., Ching, J., Grimmond, C.S.B., Grossman-Clarke, S., Loridan, T., Manning, K., MChen, F., Kusaka, H., Bornstein, R., Ching, J., Grimmond, C.S.B., Grossman-Clarke, S., Loridan, T., Manning, K., Martilli, A., Miao, S., Sailor, D., Salamanca, F., Taha, H., Tewari, M., Wang, X., Wyszogrodzki, A., Zhang, S., 2011: The integrated WRF/urban modeling system: development, evaluation, and applications to urban environmental problems. *International Journal of Climatology*. 31: 273-288.
- Jenness, J., and J.J. Wynne. 2005. Cohen's Kappa and classification table metrics 2.0: an ArcView 3x extension for accuracy assessment of spatially explicit models: U.S. Geological Survey Open-File Report OF 2005-1363. U.S. Geological Survey, Southwest Biological Science Center, Flagstaff, AZ.

Loridan, Thomas, and C. S. B. Grimmond. "Multi-site evaluation of an urban land-surface model: intra-urban heterogeneity, seasonality and parameter complexity requirements." *Quarterly Journal of the Royal Meteorological Society* 138.665 (2012): 1094-1113. Referencias

Richards, J. A. (2013). *Remote Sensing Digital Image Analysis* (Fifth editi.). Berlin, Heidelberg: Springer Berlin Heidelberg. doi:10.1007/978-3-642-30062-2

South, S., J. Qi, and D.P. Lusch. 2004. Optimal classification methods for mapping agricultural tillage practices. *Remote Sensing of Environment* 91:90-97

Souza, C. de, & Mercante, E. (2013). Methods of performance evaluation for the supervised classification of satellite imagery in determining land cover classes. *Ciencia E Investigación Agraria*, 40(2), 419–428. Retrieved from <http://www.scielo.cl/pdf/ciagr/v40n2/art16.pdf>

Skamarock, W. C., Klempt J.B., Dudhia J., Gill D., Barker D., Duda M., Huang X., Wang W. y Powers J G. (2008). A description of the Advanced research WRF version 3. No. NCAR/TN-475+STR. National Center for Atmospheric Research. Boulder, CO. Mesoscale & Microscale Meteorology Division, 2008.

WMO, 2008: Guide to Meteorological Instruments and Methods of Observation. Ginebra, Suiza, World Meteorological Organization. Capítulo 11, Parte II: Observing Systems. <http://www.wmo.ch>.