
Cartografía digital

de clases de suelo con lógica difusa en áreas de montaña

Digital soil-class mapping by fuzzy logic
in mountain areas

Ángel R. Valera¹

María C. Pineda²

Jesús A. Viloria²

¹ Universidad Rómulo Gallegos (UNERG),
Centro de Investigación y Extensión en Suelos y Aguas (CIESA),
San Juan de Los Morros, Guárico, Venezuela

² Universidad Central de Venezuela, Facultad de Agronomía,
Instituto de Edafología, Maracay, Aragua, Venezuela
valeraangel2@gmail.com; maria.c.pineda@ucv.ve; jesus.viloria@ucv.ve

Resumen

Para el fortalecimiento del estudio de las relaciones suelo-paisaje en áreas de montaña, se aplicó un enfoque de cartografía digital de suelos basado en la teoría de los conjuntos difusos. Inicialmente se estimaron las propiedades del suelo con el método kriging de regresión (RK), combinando datos de suelo e información auxiliar derivada de un modelo digital de elevación (MDE) y de imágenes satelitales. Posteriormente, se realizó el agrupamiento de propiedades del suelo en formato *raster* con el algoritmo c-medias difuso (FCM, *Fuzzy c-Means*), cuyo producto final resultó en un modelo de variación de clases difusas de suelo a escala semidetallada. La validación del modelo presentó una confiabilidad global de 88% y un índice Kappa de 84%, lo cual muestra la utilidad del agrupamiento difuso en la evaluación de las relaciones suelo-paisaje y en la correlación con categorías taxonómicas del suelo.

PALABRAS CLAVE: lógica difusa; algoritmo FCM; kriging de regresión; cartografía digital de suelos; clases de suelo.

Abstract

To strengthen the study of soil-landscape relationship in mountain areas a digital soil mapping approach based on the theory of fuzzy sets was applied. Initially, soil properties were estimated with the regression kriging method (RK), combining soil data and ancillary information derived from a digital elevation model (DEM) and satellite images. Subsequently, the grouping of soil properties was performed on raster format by means of Fuzzy c-Mean algorithm (FCM), whose final product resulted in a variation model of fuzzy soil classes to semi-detailed level. The validation of the model presented an overall accuracy of 88% and Kappa index of 84%, which shows the usefulness of fuzzy clustering in the evaluation of soil-landscape relationships and correlation with soil taxonomic categories.

KEY WORDS: fuzzy logic; FCM algorithm; regression kriging; digital soil mapping; soil class.

1. Introducción

Las tecnologías emergentes han creado nuevas oportunidades para apoyar los métodos de levantamiento cuantitativo de suelos, que generen predicciones con mayor precisión y exactitud. Sin embargo, las necesidades de los usuarios de información de suelos son diversas. El conocimiento de la variación espacial de las propiedades del suelo debería satisfacer los requerimientos de los modelos agrícolas y ambientales, fortalecer la toma de decisiones relacionadas con la variación espacial de algunas propiedades particulares del suelo así como visualizar el comportamiento de varias propiedades relevantes del suelo de manera conjunta, en un modelo de variación espacial de clases de suelo. Al respecto, la cartografía digital de suelos (CDS) permite la representación de la variación espacial de propiedades específicas del suelo, y proporciona la posibilidad de integrar los diversos modelos de propiedades para obtener clases de suelo, a fin de apoyar la toma de decisiones sobre conservación de los suelos, manejo de cuencas y desarrollo de proyectos agro-ambientales, entre otras.

En la actualidad se han aplicado numerosos modelos estadísticos para la interpolación de propiedades del suelo, entre los que destacan los métodos geoestadísticos, los cuales son exigentes en cuanto al número de muestras y la reducida extensión geográfica que representan. Uno de los desarrollos metodológicos más significativos para la predicción de propiedades del suelo son los métodos predictivos que combinan la regresión lineal múltiple y la interpolación de los residuos (kriging de regresión, RK), (Zhu *et al.*, 2010; Sun *et al.*, 2012a). Este método de análisis, aunado al desarrollo de los sistemas de información geográfica (SIG), apoyados con información auxiliar de adecuada resolución espacial (MDE y sus derivadas, e imágenes de satélite), ofrece nuevas oportunidades para producir información edáfica de manera

eficiente, en el menor tiempo posible. De manera similar, la teoría de los conjuntos difusos (Zadeh, 1965) constituye uno de los avances científicos más importantes empleados en la clasificación de los suelos. Los algoritmos desarrollados bajo lógica difusa tienen la capacidad de aprender de los datos suministrados y de procesar una gran cantidad de información, compleja e imprecisa. Esta característica permite explorar y evaluar las relaciones suelo-paisaje en sectores de alta complejidad como las áreas montañosas.

Las técnicas mencionadas constituyen una amplia base científica para el fortalecimiento de la CDS. El modelo RK puede desempeñar un papel importante en la geoestadística, debido a que muchas covariables están disponibles con el avance en la teledetección y tecnologías de posicionamiento (Sun *et al.*, 2012a). Muchos estudios han demostrado que RK es fácil de usar y su precisión a menudo supera a la regresión lineal ordinaria, al *kriging* ordinario (Minasny y McBratney, 2007) y al *co-kriging*. Al respecto, Bishop y McBratney (2001) encontraron que RK es más preciso en la predicción de la CIC del suelo; ha sido de gran importancia en la predicción de la profundidad efectiva del suelo (Peñížek y Borůvka, 2006), y es más apropiado cuando la información auxiliar puede explicar parte de la variación de la variable estimada (Hengl *et al.*, 2007).

Las aplicaciones más relevantes de la lógica difusa en el campo edafológico se destacan en: *a)* clasificación de suelos (McBratney *et al.*, 1992; Odeh *et al.*, 1992; Mazaheri *et al.*, 1995; Bragato, 2004; Chen *et al.*, 2005; Lagacherie y McBratney, 2006; Borůvka *et al.*, 2008; Bhargavi y Tech, 2010); *b)* levantamiento de suelos y evaluación de tierras (Burrough, 1989; Kollias *et al.*, 1999); *c)* modelos de relaciones suelo-paisaje (Zhu *et al.*, 1997; De Bruin y Stein, 1998); *d)* cartografía digital de suelos (Zhu *et al.*, 2001; Balkovic *et al.*, 2007; Zhu *et al.*, 2008; Yang *et al.*, 2011; Sun *et al.*, 2012b); *e)* predicción

de propiedades del suelo (Zhu *et al.*, 2006; Zhu *et al.*, 2008; Yang *et al.*, 2007); f) zonas para el manejo de sitio específico (Li *et al.*, 2007); g) ecología del paisaje (Burrough *et al.*, 2000); h) evaluación de la calidad de los suelos (Oberthür *et al.*, 2000; Torbert *et al.*, 2008), e i) evaluación del cambio de cobertura del terreno (Zachwatowicz, 2011).

En la mayoría de los casos estudiados donde se aplica la lógica difusa, se realiza inicialmente el agrupamiento de un conjunto de datos de suelo obtenidos de un muestreo sistemático. Posteriormente, se aplica el método de interpolación kriging ordinario o cokriging para la estimación de propiedades del suelo, y finalmente se interpolan los valores de la función de membresía empleando los parámetros obtenidos de los variogramas ajustados para la predicción de propiedades del suelo. En otras investigaciones, se aplica el algoritmo con la finalidad de clasificar el conjunto de datos de suelo para generar importantes explicaciones acerca de las relaciones suelo-paisaje, pero sin alcanzar la representación cartográfica de las clases de suelo.

El objetivo de esta investigación consistió en producir un mapa de clases difusas de suelo aplicando el algoritmo FCM para el agrupamiento de modelos de predicción de propiedades del suelo en formato *raster*, obtenidos previamente con el método kriging de regresión. El algoritmo permite el establecimiento de límites graduales entre las clases, lo que a su vez puede facilitar el establecimiento de correlaciones con las características geomorfológicas y las categorías taxonómicas de los suelos en un sector de la cuenca alta del río Guárico, específicamente en la cuenca del río Caramacate, estado Aragua (Venezuela).

2. Materiales y métodos

2.1 Descripción del área de estudio

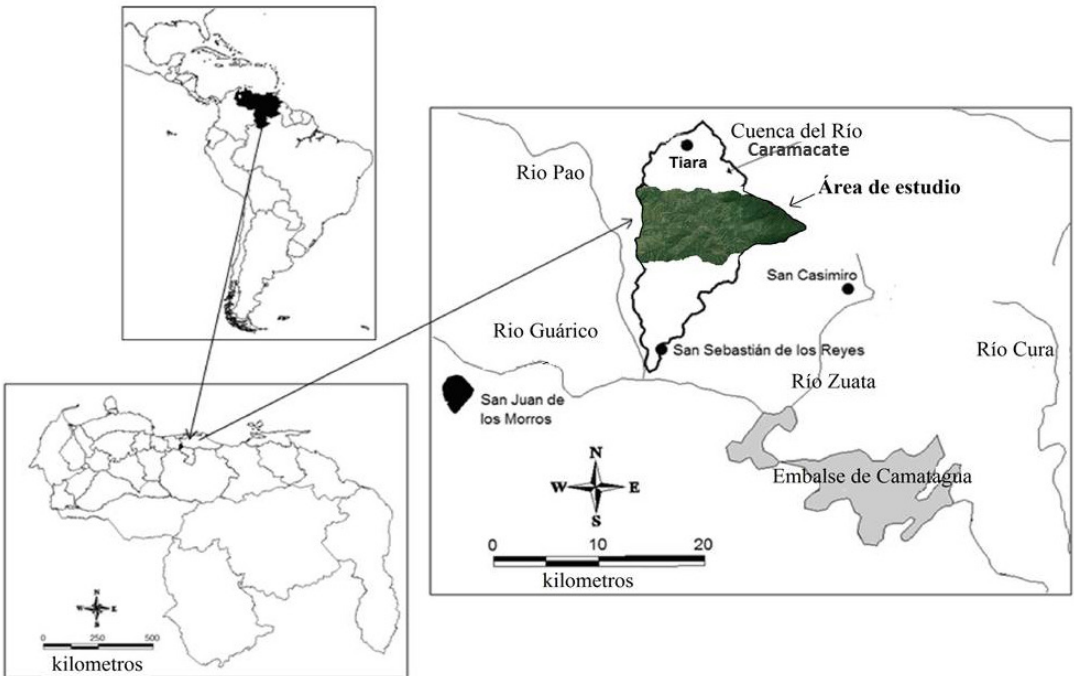
La investigación se realizó en un sector de la cuenca alta del río Guárico, específicamente en la cuenca del río Caramacate, la cual está ubicada entre los municipios Santos Michelena y San Sebastián de los Reyes del estado Aragua (Venezuela), entre las coordenadas geográficas 9,55 a 10,09° Norte y -67,12 a -67,03° Oeste, (FIGURA 1). La cuenca del río Caramacate representa el 8,5% de la cuenca alta del río Guárico, de la cual es tributaria. Esta cuenca, aunque abastece el 60% del agua que consume el área metropolitana de Caracas, está sometida a intensos procesos de degradación ambiental y carece de suficiente información para apoyar la implantación de planes de manejo.

Para el ensayo de agrupamiento de los suelos se seleccionó un área muestra de 6.760ha, donde el paisaje está dominado por laderas de montaña con pendientes del 40%. La geología está representada por rocas metavolcánicas y basaltos de la formación El Caño-El Chino, y por metalavas máficas de la formación El Carmen (Urbani y Rodríguez 2004). La zona presenta una altitud comprendida entre 334 a 1.405 msnm, con una precipitación media anual que oscila entre 1.100 y 1.400 mm y una temperatura media anual que varía entre 22 y 26°C. La vegetación herbácea ocupa más del 50% de la cobertura del sector, como producto del uso ganadero en condiciones extensivas, el sobrepastoreo y las quemadas anuales. Los suelos en su mayoría son Entisoles, Inceptisoles y Alfisoles, cuya variabilidad se ha incrementado por el uso de la tierra basado en ganadería extensiva y la incidencia de los movimientos en masa (Pineda *et al.* 2011a).

2.2 Predicción de propiedades del suelo

La estimación de las propiedades del suelo se realizó con la aplicación del modelo de predicción

FIGURA 1 Ubicación relativa del área de estudio dentro de la cuenca del río Guárico, estado Aragua, Venezuela



espacial denominado kriging de regresión (RK, *Regression Kriging*) o kriging de residuales, basado en la combinación de la técnica kriging ordinario y la regresión lineal múltiple. Este modelo estadístico permitió la integración de los valores de regresión de variables edáficas y atributos ambientales, con los valores de la interpolación de los residuales de dicha regresión. El algoritmo RK considera la correlación local entre variables ambientales y la bondad de ajuste no satisfactoria de los modelos de variación espacial para un determinado conjunto de datos (Sun *et al.*, 2012a). Las variables auxiliares se derivaron en estudios previos, partiendo de un modelo digital de elevación de 8 m de resolución (altitud (msnm), pendiente (rad), orientación de la pendiente (rad), índice topográfico de humedad, área de captación (m²), perfil de curvatura (m.m⁻²), plano de curvatura (m.m⁻²), posición relativa) y las bandas roja e infrarroja de una imagen de

satélite Spot (NDVI), a 15 m de resolución espacial (Valera, 2015). Adicionalmente se utilizó un mapa de precipitación estimado por *kriging* ordinario (Pineda *et al.*, 2011b).

Con RK se generaron los modelos de variación de nueve (9) propiedades del suelo, organizadas de acuerdo con su naturaleza en: a) morfológicas: espesor del horizonte A (Esp A), espesor del *solum* (Esp AB), profundidad efectiva (PEF); b) físicas: esqueleto grueso (%EG), arena (%a) y arcilla (%A), y c) químicas: contenido de carbono orgánico (%CO), porcentaje de saturación con bases (PSB) y pH del suelo en agua (1:1). En la predicción de las propiedades edáficas se emplearon 100 perfiles de suelo para generar los modelos (75%), y 33 perfiles para la validación (25%). La validación de las propiedades del suelo indicó que el índice de concordancia entre los valores estimados y los valores observados superó en promedio el 72%

de acuerdos, con un grado de concordancia de 61% para las variables morfológicas, 74% para las variables físicas, y 84% para las químicas. Estas variables fueron empleadas como parámetros de entrada a la red.

2.3 Predicción de clases de suelo

Para la generación del modelo digital de clases difusas de suelo se empleó el algoritmo *Fuzzy C-means* (FCM), implementado en el programa FuzME por Minasny y McBratney (2002).

2.3.1 Algoritmo C-Medias Difuso (FCM)

El algoritmo de clasificación difusa FCM también es denominado *Fuzzy k-Means*, y produce una clasificación no supervisada de individuos en clases difusas. El FCM divide de manera óptima un conjunto de datos en un número de clases y computariza las membresías de cada uno de los elementos a cada una de las categorías. El algoritmo requiere de un previo proceso de entrenamiento con un determinado número de clases y coeficientes de difusividad. Generalmente, finaliza cuando alcanza el número máximo de iteraciones o cuando el resultado de una iteración y la anterior es menor o igual al coeficiente de convergencia, los cuales son parámetros de aprendizaje definidos por el usuario.

El objetivo del algoritmo FCM (Bezdek, 1981; Bezdek *et al.*, 1984) es minimizar la suma media cuadrática ponderada de las distancias entre los puntos Z_k y el centro de la clase C_k , y las distancias d_{ik}^2 , son ponderadas con el valor de pertenencia i, k . Por consiguiente, la función objetivo es:

$$J(Z; U, C) = \sum_{j=1}^n \sum_{k=1}^c (\mu_{ik})^\phi d_{ik}^2 \quad (1)$$

donde $Z = \{z_1, z_2, \dots, z_n\}$ son los datos a ser clasificados, $U = [\mu_{ik}]$, es la matriz de partición difusa de Z , $C = [c_1, c_2, \dots, c_c]$ es el vector de centros (centroides) o patrones de las clases a determinar,

d_{ik}^2 es la distancia al cuadrado entre ik , y (1), es un exponente de ponderación que determina el grado de difusividad de los clases resultantes.

La función de membresía μ del i -ésimo objeto al k -ésimo clúster en el algoritmo *k-means* difuso ordinario emplea la distancia d utilizada para la similitud, y el exponente difuso para determinar la magnitud de difusividad:

$$\mu_{ik} = \left[(d_{ik})^2 \right]^{-1/(\phi-1)} / \sum_{k=1}^c \left[(d_{ik})^2 \right]^{-1/(\phi-1)} \quad (2)$$

Una vez determinadas las intensidades de pertenencia, se calculan los centroides de las clases (c_k) por medio de la siguiente ecuación:

$$c_k = \sum_{i=1}^n (\mu_{ik})^\phi x_i / \sum_{i=1}^n (\mu_{ik})^\phi \quad (3)$$

En cuanto al proceso de inicialización, el FCM trabaja por medio de un procedimiento iterativo que inicia con una distribución aleatoria de los objetos a ser clasificados en k clases. Dada la distribución de las clases, el centro de cada uno es calculado como el promedio de los valores atributivos de los objetos. En el siguiente paso, los objetos son redistribuidos entre las clases de acuerdo a su similitud relativa. El índice de similitud es usualmente una medida de distancia (d) como: la distancia Euclidiana, la Diagonal o la de Mahalanobis (De Gruijter y McBratney, 1988).

2.3.2 Número de clases difusas

Para la obtención del mejor modelo de clases difusas se utilizó un enfoque inductivo, basado en el procedimiento de Odeh *et al.* (1992), el cual relaciona el índice de difusividad alcanzada (FPI, *Fuzziness Performance Index*) y la entropía de partición modificada (MPE, *modified partition entropy*) con el número de clases. Estos parámetros se obtienen utilizando el algoritmo *Fuzzy c-Means* (FCM), (Bezdek 1981; Bezdek *et al.* 1984) del programa *Fuzme* 3.5 (Minasny y McBratney 2002).

La selección del número óptimo de clases en FCM se realizó por repetición de la clasificación

para un rango de número de clases. En cada agrupamiento obtenido se generan dos parámetros de clasificación, tales como el FPI y la entropía de partición modificada (MPE, *modified partition entropy*). El FPI estima el grado de difusividad generada por cada número específico de clases. Matemáticamente, se define como:

$$FPI = 1 - [(cF - 1)/(c - 1)] \quad (4)$$

dónde: **c** es el número de clases y **F** es el coeficiente de partición calculado como:

$$F = (1/n) \sum_{j=1}^n \sum_{k=1}^c (\mu_{jk})^2 \quad (5)$$

F es conceptualmente comparable a la relación del conjunto de varianzas dentro de las clases y la varianza entre clases y es cercana a 1 para los agrupamientos más significativos. En el presente estudio, el agrupamiento de mapas en formato *raster* se realizó estableciendo previamente los siguientes parámetros: *a*) número de clases ($c = 6$ a 12), *b*) exponente difuso = $1,1$ a $1,6$ con incrementos de $0,1$; *c*) un máximo de 50 iteraciones, y *d*) criterio de detención ($\epsilon = 0,0001$). La distancia métrica utilizada fue la de Mahalanobis, la cual toma en consideración la correlación encontrada entre algunas propiedades presentes entre suelos y paisajes de la zona estudiada.

2.3.3 Evaluación del modelo de clases de suelo

Para la evaluación de la confiabilidad de las clases de suelo se desarrollaron matrices de confusión y se realizaron los cálculos de la exactitud global (EG), (Chuvieco, 2008) y el índice Kappa (k) (Cohen, 1968). El índice de concordancia Kappa se utiliza como un método para evaluar clasificaciones multi-categorías, permitiendo determinar hasta qué punto la concordancia observada es superior a la que se espera obtener por puro azar, y se define de la siguiente manera:

$$k = \frac{\sum_{c=1}^n f_o - \sum_{c=1}^n f_e}{(n - \sum_{c=1}^n f_e)} \quad (6)$$

donde **f_o** es la suma de las frecuencias observadas en la diagonal principal de una tabulación cruzada, **f_e** es la suma de las frecuencias esperadas en esa diagonal, y **n** es el número total de casos (categorías).

La exactitud global del modelo (EG) se obtuvo del número de clases bien asignadas frente al total de categorías (*n*) empleadas en la calibración o en la validación de un modelo, con respecto a las frecuencias observadas en la diagonal principal de la matriz de confusión, con la siguiente fórmula:

$$EG = \sum_{c=1}^n (f_o / n) \quad (7)$$

Para el cálculo de los índices utilizados se empleó el módulo de validación de mapas de suelo del programa de cartografía digital de suelos *SoLIM Solutions* (Zhu y Burt, 2013). La validación se realizó con un conjunto de datos independientes de los perfiles de suelo empleados en la predicción de las clases de suelo. Se utilizaron 33 perfiles de suelo y se validaron las variables morfológicas, físicas, y químicas.

3. Resultados y discusión

3.1 Número de clases difusas de suelo

Para las clases difusas de suelo, el algoritmo FCM indicó que 10 categorías son óptimas para agrupar los mapas de propiedades del suelo. La combinación del número de clases y el parámetro FPI presentó un punto de inflexión que muestra el número de clases más adecuado, caracterizado por la mayor organización interna de las clases difusas. Los conceptos centrales de cada una de las clases difusas de suelo se indican en el **CUADRO 1**, donde se puede corroborar que todas las clases presentan diferencias entre sí, de acuerdo con el aporte de los centroides de los valores de las propiedades del suelo.

La clase A agrupa suelos superficiales o poco profundos y tienen un horizonte A muy delgado.

CUADRO 1 Centroides de las clases difusas de suelo representativas de la cuenca del río Caramacate, integradas con FCM

Clase	Esp A	Esp AB	PEF	%EG	%A	%a	PSB	pH	%CO
A	15	15	43	40	25,6	24,0	63	5,43	1,90
B	18	36	74	26	33,0	28,8	56	5,29	1,88
C	18	43	89	20	25,8	26,9	53	5,27	1,90
D	17	45	80	30	27,0	28,6	45	5,26	1,90
E	20	58	72	18	24,4	35,3	56	5,32	1,87
F	17	43	79	26	23,8	27,1	53	5,09	1,87
G	23	98	116	8	25,0	26,7	58	5,36	2,10
H	21	86	95	15	23,2	25,7	51	5,29	2,34
I	18	85	80	27	21,4	28,7	50	5,16	2,49
J	18	107	111	21	35,7	28,2	45	4,65	2,57

ESP A: ESPESOR A (CM), ESP AB: ESPESOR DEL SOLUM (CM), PEF: PROFUNDIDAD EFECTIVA (CM), EG: ESQUELETO GRUESO, A: ARENA, A: ARCILLA, PSB: PORCENTAJE DE SATURACIÓN CON BASES, CO: CARBONO ORGÁNICO, PH EN AGUA (1:1)

Son de textura superficial franco-limosa, con un pH moderadamente ácido, con un complejo de cambio de alta saturación con bases, y abundante cantidad de fragmentos gruesos en la superficie. Las clases B y C se caracterizan por agrupar suelos de moderada profundidad, con un horizonte superficial delgado de texturas francas a franco arcillosas. Ambas difieren en el espesor del *solum*, en la profundidad efectiva y en el contenido de esqueleto grueso de la capa superficial. Las propiedades químicas son similares, con un pH fuertemente ácido a un complejo de cambio con moderada a alta saturación de bases cambiables.

Los suelos de la clase D, E y F presentan un *solum* de espesor variable, con un horizonte A delgado. Presentan texturas que varían entre franco-arcillosas a francas con pocos a frecuentes fragmentos gruesos en la superficie; son de pH moderado a fuertemente ácido y una mediana saturación con bases. Las clases G y H incluyen suelos muy profundos a profundos, con un *solum* muy grueso, textura superficial franca y franco-limosa respectivamente, con pocos fragmentos gruesos superficiales, tienen un horizonte A grueso con

altos contenidos de CO. Los suelos son de pH moderadamente a fuertemente ácido, con moderados PSB en el complejo de cambio. Las clases I y J incluyen suelos profundos a muy profundos, con un *solum* bien desarrollado, textura superficial franca a franco arcillosa, con frecuentes fragmentos gruesos superficiales, tienen un horizonte A delgado con altos contenidos de CO. Los suelos de ambas clases son de pH fuertemente ácido, con un moderado PSB en el complejo de cambio.

3.2 Modelo de clases difusas de suelo

La integración de los datos de las propiedades del suelo en formato *raster* permitió la obtención de modelos de variación espacial de los valores de la función de pertenencia a cada clase de suelo. Estos mapas son un producto intermedio del algoritmo FCM, cuya salida se expresa en formato *raster* y refleja la variación espacial de los grados de pertenencia entre 0 y 1, donde los colores claros representan absoluta pertenencia y los colores oscuros indican no pertenencia a la clase. De los diez modelos obtenidos, en la FIGURA 2 se representan espacialmente las funciones de pertenencia de

cuatro clases de suelo representativas (A, D, G y J), las cuales muestran la similitud con el patrón geográfico discriminado en el modelo digital de clases difusas de suelo (FIGURA 3). Los valores de los grados de pertenencia a cada clase de suelo obtenidas con el método de agrupamiento difuso, permitió corroborar la influencia aportada por la información de las unidades espaciales mínimas (píxel), cuya expresión geográfica está dada por

los límites de las variables auxiliares derivadas del MDE y de la imagen de satélite. En tal sentido, la mayoría de las clases están representadas fisiográficamente por una diversidad de laderas de paisajes de montaña, con diferentes orientaciones y altura relativa (A, B, C, E, H, I, J).

Al respecto, la clase A representa al tipo de relieve de laderas que ocupan predominantemente el sector Este, con una gradualidad hacia la región

FIGURA 2 Mapas de valores de las funciones de pertenencia a algunas clases difusas de suelo. Los grados de pertenencia varían entre 0 (negro) y 1 (blanco)

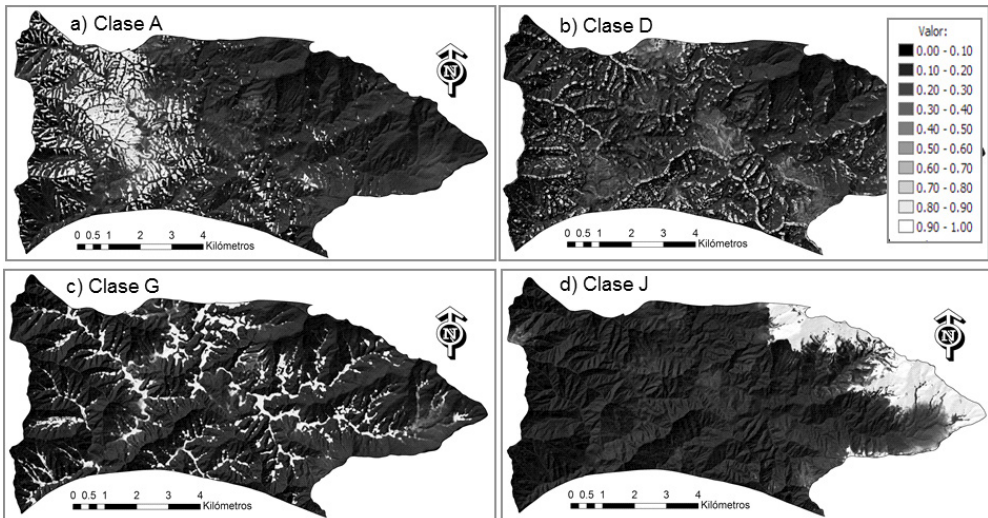



FIGURA 3 Modelo digital de clases difusas de suelo en un sector de Caramacate, cuenca alta del río Guárico



central y muy poca representación en la región Oeste del área estudiada, y la clase J está representada por laderas de montañas con la mayor altitud del sector, donde la cobertura del terreno está dominada por una vegetación boscosa. De manera contrastante, las clases D y E corresponden a tipos de relieve de crestas y vigas de las unidades de paisaje de montaña dominantes en todo el sector evaluado, y la clase G corresponde a las vegas de paisajes de valles intramontanos, cuyo curso drena en sentido Norte-Sur. Bajo el enfoque de los conjuntos difusos, la estructura de variación de las clases de suelo permitió la evaluación de las relaciones suelo-paisaje, y facilitó la correlación con las categorías taxonómicas a nivel de familia de clases de tamaño de partícula (Soil Survey Staff, 2014) en la zona de estudio (CUADRO 2).

A nivel de laderas, la poca estabilidad y la susceptibilidad a los movimientos de masa han promovido la ocurrencia de suelos de escaso a moderado desarrollo pedogenético (*Typic Haplustepts* entremezclados con *Lithic Ustorthents*). Estas clases ocupan una superficie equivalente al 59,6% del área evaluada en la zona. Esta situación

contrasta ligeramente con las laderas de paisajes de montañas dominantes en la región nor-oriental de la zona de estudio, donde los procesos pedogenéticos están altamente influenciados por la acción conjunta del relieve, la vegetación y el clima. En este sector, la distribución de las clases de suelo se caracteriza por la dominancia de los subgrupos taxonómicos *Typic Haplustalfs* y *Ultic Haplustalfs* (correspondientes al 15,3% del área estudiada).

En las crestas y en las vigas de laderas también existen suelos de incipiente desarrollo, los cuales presentan profundidades variables; con dominancia del subgrupo *Lithic Haplustepts*, mezclado con suelos del gran grupo *Ustorthents*. Este grupo ocupa alrededor del 19,8% de los suelos presentes en posiciones geomorfológicas. En las vegas de los valles intramontanos ocurren procesos de acumulación localizada, creando una superficie estable con suficiente tiempo para que existan procesos de desarrollo de un endopedón *cámbico*, encontrándose suelos del subgrupo *Typic Haplustepts*, ocupando el 5,3% de la superficie considerada.

CUADRO 2 Correlación entre las clases difusas y las categorías taxonómicas de los suelos

Clase	Familia correlacionada	Fisiografía	Superficie (%)
A	Lithic Ustorthents, <i>francosa gruesa</i>	Laderas	10,5
B	Typic Haplustepts, <i>francosa fina</i>	Laderas	12,2
C	Lithic Haplustepts, <i>francosa gruesa</i>	Laderas	10,7
D	Lithic Haplustepts, <i>francosa gruesa</i>	Crestas	12,6
E	Typic Haplustepts, <i>francosa fina</i>	Crestas, vigas	7,2
F	Lithic Haplustepts, <i>francosa fina</i>	Laderas	11,6
G	Typic Haplustepts, <i>francosa fina</i>	Vegas	5,3
H	Typic Dystrustepts, <i>francosa fina</i>	Laderas	14,6
I	Typic Haplustalfs, <i>francosa fina</i>	Laderas	4,1
J	Ultic Haplustalfs, <i>fina</i>	Laderas	11,2

FUENTE: SOIL SURVEY STAFF, 2014

3.3 Evaluación de la confiabilidad de las clases difusas de suelo

Los resultados de la evaluación de las clases de suelos indicaron que la mayoría presenta una confiabilidad equivalente al 88 %, donde las clases de referencia han sido bien clasificadas (CUADRO 3). La excepción la presentan las clases D, E y H (*Lithic Haplustepts* y *Typic Haplustepts* en vigas y crestas), en la que algunos suelos no resultaron clasificados en dicha categoría (falsos negativos), por lo que se confunden con otras clases (laderas), de acuerdo con la exactitud del productor. De igual manera, la exactitud del usuario referida al porcentaje de cada clase difusa que ha sido correctamente clasificada es indicativa de los suelos clasificados erróneamente (error de comisión). El caso más resaltante lo presentan las clases A, E y G (*Lithic Ustorthents* y *Typic Haplustepts* en laderas, crestas y vegas), donde algunos suelos resultaron clasificados en unas clases y en realidad pertenecen a otras (falsos positivos).

El otro estadístico derivado de la información integral de la matriz de error, y que corrobora el grado de acuerdos entre las clases del modelo con-

siderado, es el coeficiente kappa, cuyo resultado fue de 0,84. Este índice indica que el modelo de clases difusas presenta una fuerza de concordancia sustancial con respecto a la realidad de las clases de suelo presentes. Esto significa que la matriz empleada es 84 % mejor que el que podría resultar de aplicar otro clasificador que asigne las clases difusas al azar.

Los resultados de la validación del enfoque de conjuntos difusos utilizado demostraron que es una alternativa para la generación de clases de suelo, especialmente en áreas de alta complejidad geomorfológica y edafológica. Estos resultados son ligeramente superiores a los obtenidos por Yang *et al.* (2007), Zhu *et al.* (2008) y McKay *et al.* (2010), en la predicción de tipos de suelo a nivel de subgrupos y serie de suelos. Los autores mencionados aplicaron enfoques basados en el conocimiento de las relaciones suelo-ambiente, y obtuvieron modelos digitales con una exactitud de 72, 76, 73,7% respectivamente, y concluyeron que los resultados de la validación eran bastante aceptables para un mapa de suelos inicial con limitaciones de datos.

CUADRO 3 Matriz de evaluación de las clases difusas de suelo

Clase estimada	Clase observada						Total	EU
	A	D	E	F	G	H		
A	5	0	1	0	0	0	6	0,83
D	0	4	0	0	0	0	4	1,00
E	0	1	11	0	0	0	12	0,92
F	0	0	1	4	0	0	5	1,00
G	0	0	0	0	1	1	2	0,50
H	0	0	0	0	0	4	4	1,00
Total	5	5	13	4	1	5	29	
EP	1,00	0,80	0,92	1,00	1,00	0,80		

CONFIABILIDAD GLOBAL: 0,88; KAPPA: 0,84; EP: EXACTITUD DEL PRODUCTOR, EU: EXACTITUD DEL USUARIO

4. Conclusiones

El número de clases derivadas discriminó la variación espacial existente en los suelos, lo que destaca la importancia de la aplicación de la teoría de conjuntos difuso en áreas de alta complejidad, para la obtención de clases homogéneas internamente.

El enfoque basado en la integración de propiedades del suelo generado con la aplicación del algoritmo FCM, permitió el establecimiento de correlaciones entre clases locales de suelo con familias taxonómicas, logrando una confiabilidad de 88 %.

El agrupamiento de los suelos por medio de la aplicación de la teoría de conjuntos difusos generó un patrón de variación gradual en las áreas de

montaña, convirtiéndose en una alternativa para la evaluación de la estructura de variación de los suelos y una opción para el apoyo de la cartografía digital de suelos en áreas de montaña.

5. Agradecimiento

Los autores agradecen al Fondo Nacional de Ciencia, Tecnología e Innovación (FONACIT) por el financiamiento parcial de la investigación, a través del programa 'Misión Ciencia', al Laboratorio de Agrología del Instituto de Edafología de la Facultad de Agronomía de la Universidad Central de Venezuela y al Centro de Investigación y Extensión en Suelos y Aguas de la Universidad Rómulo Gallegos (CIESA-UNERG).

6. Referencias citadas

- BALKOVIČ, J.; ČEMANOVÁ, G.; KOLLÁR, J.; KROMKA, M. & K. HARNOVÁ. 2007. "Mapping soils using the Fuzzy Approach and Regression kriging-Case study from the Považský Inovec Mountains, Slovakia". *Soil & Water Res*, 2(4): 123-134.
- BEZDEK, J.C. 1981. *Pattern recognition with Fuzzy Objective Function Algorithms*. Plenum Press, New York. USA.
- BEZDEK, J. C.; EHRlich, R. & W. FULL. 1984. "FCM: the fuzzy c-means clustering algorithm". *Computers and Geosciences*, 10: 191-203.
- BHARGAVI, P. & M. TECH. 2010. "Fuzzy C-Means classifier for soil data". *International Journal of Computer Applications*, 6(4): 1-5.
- BISHOP, T. F. A. & A. B. McBRATNEY. 2001. "A comparison of prediction methods for the creation of field-extent soil property maps". *Geoderma*, 103(1-2): 149-160.
- BORŮVKA, L.; PAVLU, L.; VASAT, R.; PENIZEK, V. & O. DRABEK. 2008. "Delineating acidified soils in the Jizera Mountains Region using Fuzzy Classification". In: HARTEMINK, A. E.; MENDONÇA-SANTOS; McBRATNEY, A. B. (eds.). *Digital Soil Mapping with Limited Data*. pp. 233-245. Springer, Netherlands
- BRAGATO, G. 2004. "Fuzzy continuous classification and spatial interpolation in conventional soil survey for soil mapping of the lower Piave plain". *Geoderma*, 118: 1-16.
- BURROUGH, P. A. 1989. "Fuzzy mathematical methods for soil survey and land evaluation". *Journal of Soil Science*, 40: 477-492.
- BURROUGH, P. A.; VAN GAANS, P. F. M. & R. A. MACMILLAN. 2000. "High-resolution landform classification using fuzzy k-means". *Fuzzy Sets and Systems*, 113: 37-52.
- CHEN, J. W.; CHEN, C. H. & S. H. CHEN. 2005. Application of fuzzy k-mean cluster and fuzzy similarity in soil classification. In: *Proceedings of 15th international off shore and polar engineering conference*. pp. 459-465. Seoul, Korea.

- CHUVIECO, E. 2008. *Teledetección ambiental. La observación de la Tierra desde el Espacio*. 3ª. Edición actualizada. Editorial Ariel, S. A. España.
- COHEN, J. 1968. "Weighted kappa: nominal scales agreement with provision for scaled disagreement or partial credit". *Psychological Bulletin*, 70: 213-220.
- DE BRUIN, S. & A. STEIN. 1998. "Soil-landscape modelling using fuzzy c-means clustering of attribute data derived from a Digital Elevation Model (DEM)". *Geoderma*, 83: 17-33.
- DE GRUIJTER J. J. & A. B. McBRATNEY. 1988. "A modified fuzzy k-means method for predictive classification". In: BOCK H. H. (ed.). *Classification and related methods of data analysis*. Elsevier Science Publishers B.V. Amsterdam.
- HENGL, T.; HEUVELINK, G. B. M. & D. G. ROSSITER. 2007. "About regression-kriging: from theory to interpretation of results". *Computers & Geosciences*, 33(10): 1.301-1.315.
- KOLLIAS, V. J.; KALIVAS, D. P. & N. J. YASSOGLU. 1999. "Mapping the soil resources of a recent alluvial plain in Greece using fuzzy sets in a GIS environment". *European Journal of Soil Science*, 50: 261-273.
- LAGACHERIE, P. & A. M. McBRATNEY. 2006. "Spatial soil information systems. Perspective for digital soil mapping". In: LAGACHERIE P.; MCBRATNEY A. M.; VOLTZ M. (eds). *On digital soil mapping. An Introductory Perspective. Developments in Soil Science*, 31: 4-24.
- LI, A.; LIANG, S.; WANG, A. & J. QIN. 2007. "Estimating Crop Yield from Multi-temporal Satellite Data Using Multivariate Regression and Neural Network Techniques". *Photogrammetric Engineering & Remote Sensing*, 73(10): 1.149-1.157.
- MAZAHERI, A. S.; KOPPI, A. J. & A.B. McBRATNEY. 1995. "A fuzzy allocation scheme for the Australian great soil groups classification system". *European Journal of Soil Science*, 46: 601-612.
- McBRATNEY, A. B.; DE GRUIJTER, J. J. & D. J. BRUS. 1992. "Spatial prediction and mapping of continuous soil classes". *Geoderma*, 54: 39-64.
- McKAY, J.; GRUNWALD, S.; SHI, X. & R. F. LONG. 2010. "Evaluation of the transferability of a knowledge-based soil-landscape model". In: BOETTINGER J.; HOWELL D. W.; MOORE A. C.; HARTEMINK A. E. & S. KIENAST-BROWN (eds). *Digital Soil Mapping*. pp. 165-177. Bridging Research, Production and Environmental Applications. Springer, Heidelberg.
- MINASNY, B. & A. B. McBRATNEY. 2002. *FuzME version 3.0*. Australian Centre for Precision Agriculture. McMillan Building A05. The University of Sydney, NSW 2006. Disponible en: <http://www.usyd.edu.au/su/agric/acpa>.
- MINASNY, B. & A. B. McBRATNEY. 2007. "Spatial prediction of soil properties using EBLUP with the Matérn covariance function". *Geoderma*, 140(4): 324-336.
- OBERTHÜR, T.; DOBERMANN, A. & M. AYLWARD. 2000. "Using auxiliary information to adjust fuzzy membership functions for improved mapping of soil qualities". *International Journal of Geographical Information Science*, 14: 451-454.
- ODEH, I. O. A.; McBRATNEY, A. B. & D. J. CHITTLEBOROUGH. 1992. "Soil pattern recognition with fuzzy c-means: application to classification and soil landform interrelationships". *Soil Sci. Soc. Am. J.*, 56: 505- 516.
- PENÍŽEK, V. & L. BORŮVKA. 2006. "Soil depth prediction supported by primary terrain attributes: a comparison of methods". *Plant Soil Environ*, 52(9): 424-430.
- PINEDA, M. C.; ELIZALDE, G. y J. VILORIA. 2011a. "Determinación de áreas susceptibles a deslizamientos en un sector de la Cordillera de la Costa Central de Venezuela". *Interciencia*, 36(5): 370-377.

- PINEDA, M. C.; ELIZALDE, G. y J. VILORIA. 2011b. "Relación suelo-paisaje en un sector de la cuenca del río Caramacate, Aragua, Venezuela". *Revista de la Facultad de Agronomía*, 37(1): 27-37.
- SOIL SURVEY STAFF. 2014. *Keys to Soil Taxonomy*. Twelfth Edition. United States Department of Agriculture. Natural Resources Conservation Service. NRCS-USDA. Washington DC. USA.
- SUN, W.; MINASNY, B. & A. B. McBRATNEY. 2012a. "Analysis and prediction of soil properties using local regression-kriging". *Geoderma*, (171-172): 23-30.
- SUN, X. L.; ZHAO, Y. G.; WANG, H. L.; YANG, L.; QIN, C. Z.; ZHU, A. X.; ZHANG, G. L.; PEIT. & B. L. LI. 2012b. "Sensitivity of digital soil maps based on FCM to the fuzzy exponent and the number of clusters". *Geoderma*, (171-172): 24-34.
- TORBERT, H. A.; KRUEGER, E. & D. KURTENER. 2008. "Soil quality assessment using fuzzy modeling". *International Agrophysics*, 22: 365-370.
- URBANI, F. y J. A. RODRÍGUEZ. 2004. *Atlas geológico de la cordillera de la Costa, Venezuela*. Mapas a escala 1:25.000. Versión Digital. Edic. Fundación Geos, UCV. Caracas, Venezuela.
- VALERA, A. 2015. *Inventario de suelos y paisajes con apoyo de técnicas de cartografía digital en áreas montañosas. Caso cuenca del río Caramacate, Estado Aragua*. Postgrado en Ciencia del Suelo. Universidad Central de Venezuela. Maracay, Estado Aragua, Venezuela. Tesis de Doctorado en Ciencias del Suelo. DOI: 10.13140/RG.2.1.1714.3920
- YANG, L.; ZHU, A. X.; QIN, C.; LI, B. & T. PEI. 2007. Soil property mapping using Fuzzy Membership derived by Fuzzy c-Means (fcm) Clustering. *The 7th International Workshop of Geographical Information System (IWGIS07)*.
- YANG, L.; YOU, J.; SHERIF, F.; ZHU, A. X.; SHELDON, H.; BURT, J. E. & F. QI. 2011. "Updating conventional soil maps through digital soil mapping". *Soil Sci. Soc. Am. J.*, 75: 1.044-1.053.
- ZACHWATOWICZ, M. 2011. "The potential of fuzzy logic for quantitative land cover change analysis basing on historical topographic maps". *Miscellanea Geographica*, 15: 231-240.
- ZADEH, L. A. 1965. "Fuzzy sets". *Inform. Control*, 8: 338-353.
- ZHU, A.X.; BAND, L. E.; VERTESSY, R. & B. DUTTON. 1997. "Derivation of soil properties using a soil land inference model (SoLIM)". *Soil Sci. Soc. Am. J.* 61: 523-533.
- ZHU, A.X.; HUDSON, B.; BURT, J.; LUBICH, K. & D. SIMONSON. 2001. "Soil mapping using GIS, expert knowledge and fuzzy logic". *Soil Sci. Soc. Am. J.*, 65: 1.463-1.472.
- ZHU, A. X.; MOORE, A. & J. E. BURT, 2006. Prediction of Soil Properties Using Fuzzy Membership. *Proceedings of the 2nd Global Workshop on Digital Soil Mapping*. Río de Janeiro, Brazil. (July 4-7).
- ZHU, A.X.; YANG, L.; LI, B.; QIN, C.; ENGLISH, E.; BURT, J.E. & C. ZHOU. 2008. "Purposive Sampling for Digital Soil Mapping for Areas with Limited Data". In: HARTEMINK A. E.; MENDONÇA-SANTOS; MCBRATNEY A. B. (eds.). *Digital Soil Mapping with Limited Data*. pp. 233-245.
- ZHU, A. X.; MOORE, A. & J. E. BURT. 2010. "Prediction of soil properties using fuzzy membership values". *Geoderma*, 158: 199-06.
- ZHU, A. X. & J. E. BURT. 2013. *Digital soil mapping software: SoLIM Solutions 2013. Reference Manual*. Institute of Geographic Sciences, Natural Resources Research-Chinese Academy of Sciences-The University of Wisconsin-Madison.