
ANÁLISIS ESPACIAL DE CLASES DE TEXTURA DEL SUELO CON APOYO DE TÉCNICAS GEOESTADÍSTICAS Y REDES NEURONALES ARTIFICIALES

Ángel R. Valera Valera ^{1*}, Cándido B. Sumoza Agráz ¹, Williams Tovar Romero¹

¹ Universidad Rómulo Gallegos, Centro de Investigación y Extensión en Suelos y Aguas (CIESA-UNERG), San Juan de los Morros, Estado Guárico, Venezuela. Correo electrónico: angelvalera@unerg.edu.ve, sumagraz@hotmail.es, willtov@gmail.com

* Autor de correspondencia

Recibido: 14 - 08 - 2022; **Aceptado:** 23 - 09 - 2022; **Publicado:** 22 - 11 - 2022

RESUMEN

Con la finalidad de predecir la variación de las clases de textura del suelo se aplicó un procedimiento alternativo que combina dos métodos de análisis espacial. El primer método, corresponde a la utilización de técnicas geoestadísticas para la interpolación de las propiedades individuales relacionadas con la distribución de tamaño de partículas del suelo. El segundo método consistió en la aplicación de técnicas de inteligencia artificial a través de un sistema de clasificación no supervisado basado en una red neuronal de agrupamiento borroso (FKCN, Fuzzy Kohonen Clustering Network) para la generación de un modelo digital de clases de textura del suelo, a partir de los mapas interpolados de arcilla, limo y arena. Para tal fin, se realizó un muestreo de 205 muestras superficiales del suelo en terrenos del Campo Experimental del Instituto de Desarrollo de Sistemas Sostenibles Agroambientales de la Universidad Nacional Experimental de los Llanos Centrales "Rómulo Gallegos", ubicado en la cuenca del río San Juan del Municipio autónomo Juan Germán Roscio, estado Guárico, Venezuela. Para determinar la confiabilidad de los mapas individuales se realizó una validación cruzada y se empleó un grupo de datos independientes, y para la evaluación del producto final se realizó una evaluación cuantitativa mediante el uso de matrices de confusión y la exactitud global del modelo con un conjunto de datos independientes clasificados previamente. El mapa digital de clases de textura del suelo indicó que en el área de estudio predominan suelos de texturas arcillosas y franco-arcillosas. La validación del modelo de predicción de clases texturales del suelo arrojó una exactitud global de 81%, indicando un alto grado de correspondencia entre las clases evaluadas y la realidad presente en la capa superficial de los suelos.

Palabras clave: Arcilla; arena; textura del suelo; kriging; agrupamiento borroso; algoritmo FKCN.

SPATIAL PREDICTION OF SOIL TEXTURAL CLASSES BY ARTIFICIAL NEURAL NETWORKS AND GEOSTATISTICAL TECHNIQUES

ABSTRACT

In order to predict the change in soil texture classes an alternative process which combines two methods of spatial analysis was applied. The first method corresponds to the use of geostatistical interpolation for individual properties related to the particle size distribution of soil techniques. The second method consisted in applying artificial intelligence techniques through a classification system unsupervised based on a fuzzy clustering neural network (FKCN) for generating a digital model of classes of soil texture, from the interpolated maps clay, silt and sand. To this end, a sample of 205 surface soil samples in experimental areas of Development Institute of Sustainable Agro-environment

Systems at the National Experimental University “Romulo Gallegos” located in San Juan River basin autonomous municipality was held Juan German Roscio, Guárico state. To determine the reliability of the individual maps cross-validation was performed and a group of independent data was used, and for the evaluation of the final product a quantitative evaluation was performed using confusion matrices, through statistical Kappa and overall accuracy of the model with independent data set classified previously. The digital map of soil texture classes indicated that the study area predominantly clayey soils and loam-clayey textures. The validation of the prediction model soil textural classes showed an overall accuracy of 81%, indicating a high degree of correspondence between classes evaluated and reality in the surface layer of the soil.

Keywords: Soil Fertility; Geoestatics; Kriging; Artificial Neural Network; FKCN Algorithm

INTRODUCCIÓN

La textura del suelo es una de las propiedades físicas más importantes de un suelo, que afecta en gran medida su uso y manejo. Esta propiedad influye a la cantidad de agua y nutrientes que un suelo puede almacenar para el abastecimiento de los cultivos. Es decir, ejerce gran influencia en otras propiedades físicas del suelo como la estructura, y el movimiento de aire y agua a través del suelo. Además, es un atributo de gran utilidad y aplicaciones directas en la descripción y reconocimiento de suelos, en la taxonomía de suelos, en hidrología, y en el manejo de los suelos (Gabriels y Lobo, 2011).

El conocimiento de la variación espacial de la textura del suelo en los sitios experimentales es importante para el establecimiento de parcelas homogéneas, y evitar sesgos en la delimitación efectiva para la aplicación de los de tratamientos. La representación de las clases de textura del suelo amerita la elaboración de mapas individuales de los contenidos de arena, limo y arcilla, en forma manual y la posterior superposición de éstos para la definición de límites, lo que implica sesgos y baja precisión en el resultado final. La representación cartográfica de las clases de textura del suelo, facilita la toma de decisiones al momento del establecimiento de parcelas experimentales y ensayos con fines de investigación. Convencionalmente, la distribución espacial de las clases de textura del suelo se realiza a través de sus componentes individuales (arcilla, limo y arena), lo cual requiere una alta densidad de puntos de muestreo para evitar altos grados de incertidumbre. En la actualidad se utilizan diversas técnicas de interpolación, que permiten obtener información básica y confiable sobre importantes propiedades del suelo. Dentro de estas técnicas, los métodos geoestadísticos juegan un papel preponderante para la predicción espacial de las propiedades del suelo, donde destaca el método de interpolación denominado *kriging* ordinario. Sin embargo, la representación individual de las variables que constituyen la textura del suelo no cubre el interés y la necesidad de visualizar el comportamiento de manera conjunta, en un modelo de variación espacial de clases de suelo con fines de manejo específico.

La cartografía digital de suelos (CDS) permite integrar diversos modelos de variación espacial de propiedades individuales del suelo, para obtener clases de suelo, con la finalidad de apoyar la toma de decisiones sobre la definición de áreas específicas, como base para el impulso de la agricultura de precisión. La aplicación de la CDS a través de predicción de la textura del suelo intenta dividir el continuo suelo en clases, que exhiben una mayor homogeneidad de la combinación de la proporción relativa de arena, limo y arcilla (Pineda *et al.*, 2015).

Son escasos los trabajos de investigación realizados en el ámbito de la Ciencia del Suelo que toman en cuenta la combinación de la variación continua de propiedades individuales para expresarlas como categorías de suelo. Al respecto, la aplicación de las redes neuronales artificiales ha dado un gran impulso a la CDS tanto en la predicción de propiedades como en la obtención de clases de suelo. En Venezuela, las tecnologías de inteligencia artificial se han aplicado en el área de clasificación de paisajes y predicción de atributos del suelo (Viloria, 2007), en cartografía digital geomorfológica (Valera y Viloria, 2009), Valera *et al.* (2010), Núñez (2011), Viloria *et al.* (2012), Valera (2012) y Viloria *et al.* (2016); en la predicción de propiedades y clases locales de suelo (Valera, 2015) y en el estudio de las relaciones entre el suelo y el rendimiento del cultivo de banano (Rey *et al.*, 2015).

En este trabajo se presenta una alternativa de apoyo a la CDS, a través de la predicción de propiedades granulométricas del suelo y el posterior agrupamiento en clases de textura del suelo. Para realizar el ensayo de cartografía digital y evaluar el comportamiento espacial de las clases de textura de los suelos, se consideró una zona experimental ubicada en el Instituto de Desarrollo de Sistemas Sostenibles Agroambientales de la Universidad Rómulo Gallegos (IDESSA-UNERG), en el sector El Castrero de San Juan de los Morros, estado Guárico - Venezuela. El propósito fundamental de la investigación fue la predicción espacial de clases de textura del suelo a través de la combinación de redes neuronales artificiales y técnicas geoestadísticas, como base para la generación de información básica requerida para el desarrollo de ensayos y pruebas experimentales, que permitan una mejor interpretación de los resultados de los diferentes tratamientos y actividades productivas a desarrollar en el sector estudiado.

MATERIALES Y MÉTODOS

Área de Estudio

La zona de estudio donde se llevó a cabo el ensayo de cartografía digital de la textura del suelo se encuentra ubicada en terrenos del Instituto para el Desarrollo Sostenible de los Sistemas Agroambientales (IDESSA) de la Universidad Nacional Experimental Rómulo Gallegos, en el Sector El Castrero, en la cuenca del río San Juan (San Juan de los Morros, Estado Guárico, Venezuela) (Figura 1). La unidad de estudio se encuentra entre las coordenadas UTM Este: 676215-676353 y Norte: 1094983-1094678 (Zona 19 Norte, Datum: Sirgas-Regven) y abarca una superficie de

2,34 ha. Desde el punto de vista geomorfológico se encuentra enmarcada en una terraza aluvial de un valle intramontano dominado por colinas y montañas, con relieve plano a ligeramente inclinado y pendiente local de 2 a 5%. Los suelos en esta área fueron formados a partir de materiales geológicos de la formación Las Hermanas, acarreados por el río Cerro Pelón que baja de la vertiente occidental del Monumento natural “Juan Germán Roscio” o Pico Platillón, seccionando los materiales compuestos de rocas ígneas extrusivas máficas y conglomerados volcanoclásticos. Los suelos presentan un incipiente desarrollo pedogenético y son de moderada fertilidad.




Figura 1. Ubicación relativa del área de estudio dentro de la cuenca del río San Juan, estado Guárico, Venezuela.

Muestreo de suelos

Para la evaluación de los suelos se tomaron muestras superficiales individuales a 20 cm de profundidad, bajo un muestreo sistemático en cuadrículas espaciadas a 10 m, para un total de 205 muestras de suelos en una superficie de 2,34 ha que conforma el área experimental (Figura 2). Cada punto de muestreo fue georreferenciado con apoyo de un sistema de posicionamiento global (navegador GPS Garmin 76 GSX®). A las muestras obtenidas se les realizó un diagnóstico con fines de fertilidad, utilizando las metodologías del Laboratorio de análisis de suelos del Centro de Investigación en Suelos y Aguas de la Universidad Rómulo Gallegos (CIESA-UNERG). Para la determinación de los contenidos de arcilla (% A), limo (% L) y arena (% a) se utilizó el método del hidrómetro de Bouyoucos modificado (Gee y Or, 2002). El método del hidrómetro es una técnica sencilla que determina la densidad de la suspensión, cuya lectura está relacionada con la cantidad de partículas presentes en el medio disperso. Este método incluye una dispersión química con

hexametáfosfato de sodio y una dispersión física mediante agitación mecánica, y finalmente utiliza una corrección basada en la temperatura y en una lectura de un blanco. Para la definición de las clases texturales del suelo se utilizaron los criterios establecidos por el Departamento de Agricultura de los Estados Unidos (USDA, 1987).

Análisis estadístico

Los datos del contenido de arcilla y arena se sometieron a un análisis exploratorio (AED) con apoyo del programa InfoStat (Di Rienzo *et al.*, 2011), con el propósito de calcular los estadísticos descriptivos, tales como: media, mediana, varianza, coeficiente de variación, valores máximos y mínimos, y los índices de asimetría y curtosis. Se utilizó la metodología de cercas externas e internas de Tukey (1977), con el fin de detectar la presencia de valores atípicos. Adicionalmente se realizó la prueba de normalidad de Kolmogorov-Smirnov, para evaluar la distribución de los datos.




Figura 2. Distribución de los sitios de muestreo de suelos en campo el Campo Experimental IDESSA. (Los puntos rojos corresponden a los sitios de validación).

Interpolación de las propiedades granulométricas del suelo

Para la interpolación de los componentes de la textura del suelo se utilizó el método de interpolación conocido como *kriging*. Este método geoestadístico utiliza un modelo de semivariograma para la obtención de los pesos que se asignan a cada punto de referencia empleado en la estimación del valor de las variables regionalizadas (arcilla, arena, limo), las cuales presentan dependencia espacial. El semivariograma es

definido por la función de la semivarianza [$\gamma(h)$], la cual se estima con la siguiente expresión (Upchurch y Edmonds, 1991; Ovalles, 1992):

$$\gamma(h) = \frac{1}{2N(h)} \sum_{N(h)} [z(x_i) - z(x_{i+h})]^2 \quad (1)$$

donde N es el número de pares de puntos separados por una determinada distancia h ; $z(x_i)$ es el valor de la variable en una localidad x ; $z(x_{i+h})$ es el valor que toma la variable en otra localidad ubicada a una distancia h de x (Ovalles y Rey, 1994). El semivariograma contiene la información referente a la variable regionalizada, cuyos parámetros son: la varianza *nugget* (C_0), la varianza estructural (C_1), el umbral ($C_0 + C_1$) y el alcance (A_1), que indica la distancia dentro de la cual existe dependencia espacial [Burrough, 1986; Grunwald et al., 2007]. Para la estimación de los semivariogramas empíricos del contenido de arcilla, arena y limo, y su posterior ajuste a modelos matemáticos se empleó el programa *Vesper* 1.6 (Minasny et al., 2002). Con los parámetros ajustados se obtuvieron los estimados óptimos de las variables granulométricas en sitios no muestreados, a través de la interpolación con el método *kriging* ordinario (Webster y Oliver, 2007). Los modelos de cada una de las variables consideradas se generaron con el 70% del total de los datos muestreados ($n=164$), cuyos errores se obtuvieron mediante validaciones cruzadas. Los mapas de arena, limo y arcilla fueron empleados como parámetros de entrada a la red neuronal borrosa. El 30% de los datos ($n=41$) se utilizó para la validación del modelo de predicción espacial de clases de textura del suelo.

Validación de modelos de predicción de propiedades del suelo

Para la evaluación de la exactitud de los modelos de predicción de las propiedades de los suelos generados se utilizaron tres índices: el error medio (ME , *mean error*), la raíz del error cuadrático medio ($RMSE$, *root mean squared error*) y el coeficiente de concordancia (AC , *agreement coefficient*). Los índices ME y $RMSE$ contribuyen al análisis de los resultados indicando el error en los valores de la propiedad del suelo de interés (Hengl et al., 2004). El ME evalúa el error sistemático e indica la presencia de subestimación o sobrestimación del modelo, y el $RMSE$ evalúa la precisión de la predicción. Los valores de $RMSE$ y ME iguales a 0 indican un ajuste perfecto. Las ecuaciones que definen estos índices son las siguientes:

$$ME = \frac{1}{n} \sum_{i=1}^n (O_i - E_i) \quad (2)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - E_i)^2} \quad (3)$$

donde n es el número de observaciones, O_i es el valor observado o medido y E_i es el valor estimado o inferido.

El índice AC es una medida normalizada del grado de error de los modelos de predicción y varía entre 0 y 1. Un valor calculado de 1 indica un acuerdo perfecto entre los valores medidos y predichos, y un valor de 0 indica que no hay acuerdo o existe un desacuerdo total entre los valores estimados y los observados (Willmott, 1981). El índice representa la relación entre el error cuadrático medio y el error potencial (PE) (Willmott, 1984). El PE es definido como la suma de los cuadrados de los valores absolutos de las distancias de los valores predichos y el valor de la media observada, y la distancia entre los valores observados y el valor de la media observada; tal como se indica en las siguientes fórmulas:

$$AC = 1 - \frac{n \cdot (RMSE)^2}{PE} \quad (4)$$

$$PE = \sum_{i=1}^n (|E_i - \bar{O}| + |O_i - \bar{O}|)^2 \quad (5)$$

donde n es el número de observaciones y PE es el error potencial de la varianza. $\bar{O}$ es el valor medio observado y E_i y O_i son los valores estimados y observados, respectivamente. El índice AC tiene la ventaja de escalar la magnitud de las variables reteniendo el significado de la información, y no amplifica los valores extremos. No es una medida de correlación como tal, sino una medida del grado en el cual las predicciones del modelo están libres de errores (Willmott *et al.*, 1985). Además, es más apropiado para la investigación en casos de validación, donde se requiere comparar los valores observados y predichos por un determinado modelo (Ji y Gallo, 2006).

Obtención del modelo digital de clases de textura del suelo

Para la generación del mapa de clases de textura del suelo se utilizó el algoritmo FKCN (*Fuzzy Kohonen Clustering Networks*), el cual permite la organización y el agrupamiento de mapas en formato *ráster*. Es decir, se basa en el tratamiento y la representación de las entidades espaciales mediante la disposición de celdas o píxeles en forma de una matriz numérica. Este algoritmo fue programado en plataforma Java SE 6, Sun Microsystems, USA (Viloria, 2007).

Algoritmo FKCN

El FKCN es el resultado de la integración de la red neuronal de mapas autoorganizados (SOM, *Self Organizing Map*) y el algoritmo c-medias borroso (FCM, *Fuzzy c-Means*) (Bezdek *et al.*, 1992). El modelo SOM consiste en dos capas vectoriales: entrada y salida (Kohonen, 1982; Lin y Lee, 1996). Cada vector de entrada contiene los valores normalizados de las variables de entrada en una celda determinada del modelo. En la capa de salida un número de neuronas, iguales a la cantidad previamente establecida de clases se arregla sobre una rejilla, para que

cada nodo esté conectado a todos los demás por las relaciones topológicas específicas. Cada neurona se describe por un vector de pesos n -dimensional, donde n es igual al número de variables en los datos de entrada. Los vectores de peso se inicializan con valores aleatorios, y luego la red se ajusta de manera secuencial e iterativa. Cuando se presenta un nuevo vector de entrada a la red, la unidad de procesamiento de la capa de salida calcula la distancia entre el vector de entrada y cada uno de los pesos de los vectores (Viloria et al., 2016).

Red de agrupamiento neuronal de Kohonen

La arquitectura de la red neuronal FKCN consta de tres capas (Figura 3): i) la capa de entrada, la cual contiene los valores normalizados de las tres (3) variables edáficas generadas con las técnicas geoestadísticas, en formato *raster*; ii) la capa de distancias, que incluye las neuronas equivalentes al número preestablecido de clases de textura del suelo, y iii) la tercera capa, la cual calcula la función de pertenencia de cada celda a cada una de las clases de textura, basada en las distancias determinadas en la capa anterior y los valores preestablecidos del coeficiente de borrosidad (ϕ) (Valera, 2015; Viloria et al., 2016).

En la capa de distancia se calcula la separación d_{ij} existente entre un patrón de entrada X_j y el peso del nodo W_i , con $i = 1, 2, \dots, c$, donde c representa el número de clases a estimar. Posteriormente, la capa de membresía grafica las distancias d_{ij} en valores de membresía U_{ij} , donde U_{ij} representa el grado de pertenencia de un patrón de entrada X_j a una clase c (Lin y Lee, 1996). A lo largo del proceso de aprendizaje ocurre una retroalimentación de la capa de funciones de pertenencia a la capa de distancia, con la finalidad de ajustar los centros de clase.




Figura 3. Estructura de la red neuronal borrosa empleada en el proceso de agrupamiento.

Las variables granulométricas fueron agrupadas en una matriz de datos bajo formato ASCII con el sistema FKCN, para evaluar el agrupamiento de píxeles con diversos números de clases (2 a 6) y diferentes coeficientes de borrosidad ($\phi = 1,1$ a $1,7$), ya que la magnitud de este exponente determina el grado de borrosidad del modelo final.

A las clases obtenidas se les asignó el significado granulométrico a través de la interpretación de su distribución espacial, las descripciones de los centroides de clases texturales, y los mapas de los valores de membresía obtenidos mediante el algoritmo FKC.

Número de clases de textura del suelo

Para la selección del número más apropiado de clases de suelo se empleó un enfoque inductivo, basado en el procedimiento de Odeh *et al.* (1992), el cual relaciona el índice de borrosidad alcanzado (FPI, *Fuzziness Performance Index*) con el número de clases. La selección del número óptimo de clases se realizó por repetición de la clasificación para un rango de número de clases establecidos. En cada agrupamiento obtenido se generó el parámetro de clasificación FPI, el cual estima el grado de borrosidad generado por cada número específico de clases. Matemáticamente, se define como:

$$FPI = 1 - [(cF - 1)/(c - 1)] \quad (6)$$

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

$$F = (1/n) \sum_{i=1}^n \sum_{k=1}^c (\mu_{ik})^2 \quad (7)$$

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. La minimización de FPI indica un número óptimo de clases borrosas que reflejan adecuadamente el comportamiento del conjunto de datos.

Validación del mapa de clases de textura del suelo

Para la validación del modelo se realizó una evaluación cuantitativa basada en una matriz de confusión o error y a través de la medida de la exactitud global (**EG**). La matriz de error es una tabla de doble entrada en el cual se colocan en las filas y columnas las distintas clases a ser evaluadas, y la diagonal expresa el número de coincidencias que se produce entre las dos fuentes del mapa y la realidad. El resto supone errores de asignación (Chuvieco, 2008). La EG se obtiene de la sumatoria de las frecuencias observadas en la diagonal principal de la matriz de error ($\sum fo$), entre el número de clases bien asignadas frente al total de clases (n). La tabulación cruzada se obtuvo empleando el módulo de validación de mapas del programa *SoLIM* Solutions (*Soil Land Inference Model*) (Zhu y Burt, 2015). Para la validación del modelo de predicción espacial de clases de textura del suelo se utilizó el 30% de los datos ($n=41$).

RESULTADOS Y DISCUSIÓN

Análisis estadístico

Los estadísticos descriptivos indicaron que los valores promedios de las muestras superficiales corresponden a grupos de suelos con dominancia de arcillas, con moderados coeficientes de variación en la composición granulométrica de las tres propiedades del suelo y con rangos de variaciones muy similares (Cuadro 1). La distribución de los datos para todas las variables es leptocúrtica, ya que presentan un mayor grado de concentración alrededor de los valores centrales de las variables. Para las variables % arcilla y % arena, la distribución es asimétrica positiva, por lo que se concentran más valores a la derecha de la media, y para el % limo es asimétrica negativa. En todos los casos, las diferencias entre la media, la mediana y la moda presentan pocas desviaciones. Las clases de textura predominantes son franco arcillosas (68,3%) y arcillosas (31,7%), tal como lo indica la representación gráfica de la Figura 4. La aplicación de la prueba de cercas externas e internas indicó que las variables consideradas no presentan valores atípicos. En cuanto a la prueba de normalidad, tanto el % arena como el % limo, proceden de poblaciones normales, ya que los valores de la prueba Z de Kolmogorov-Smirnov son altamente significativos ($p > 0,05$) (Cuadro 2). Los datos del % arcilla no presentan una distribución normal; sin embargo, no se realizó ninguna transformación de datos.

Cuadro 1. Estadísticos descriptivos de la distribución de tamaño de partículas.

Parámetro	Arcilla (%)	Arena (%)	Limo (%)
n	205	205	205
Media	39,6	31,6	28,7
DE	3,02	3,3	3,7
Varianza	9,14	11,2	14,3
CV (%)	7,63	10,6	13,1
Mín	31,9	24,2	16,7
Máx	49,8	43,5	36,6
Mediana	39,8	31,5	29,3
Moda	39,9	30,6	30,2
Q ₁	37,8	29,4	26,0
Q ₃	41,8	33,5	31,8
Asimetría	0,53	0,38	-0,38
Kurtosis	0,37	0,27	-0,40

n: número de datos, DE; Desviación estándar, CV: Coeficiente de variación, Q₁: Primer cuartil, Q₃: Tercer cuartil.




Figura 4. Distribución de las clases de textura de los suelos del Campo Experimental IDESSA.

Cuadro 2. Prueba de normalidad del conjunto de datos de suelo.

Parámetro estadístico	Arcilla (%)	Arena (%)	Limo (%)
Media	39,63	31,58	28,79
Desviación típica	3,04	3,36	3,78
Z de Kolmogorov-Smirnov	2,12	1,20	1,21
Sig. asintót. (bilateral)	0,000	0,112	0,107

Nivel significación $\alpha = 0,05$. $n = 205$.

Interpolación de propiedades del suelo

La estimación de los semivariogramas empíricos del contenido de arcilla, arena y limo superficial, fueron ajustados a modelos matemáticos gaussianos, esféricos y exponenciales, respectivamente (Figura 5), considerando el comportamiento isotrópico de las variables.




Figura 5. Semivariogramas de los componentes de la distribución de tamaño de partículas de los suelos.

Los parámetros geoestadísticos derivados del ajuste de los semivariogramas a diferentes modelos teóricos, se expresan en el Cuadro 3.

Cuadro 3. Parámetros geoestadísticos de los semivariogramas compuestos de los componentes granulométricos.

Parámetro	Variable		
	%Arcilla	%Arena	%Limo
C ₀	5,16	6,68	3,89
C ₁	6,83	6,27	12,45
C ₀ + C ₁	12,00	12,95	16,34
A ₁	105,00	58,02	28,10
RMSE	5,56	0,92	1,85
AIC	70,14	30,63	45,86
NR (%)	43,03	51,56	23,81

C₀: Varianza nugget, C₁: Varianza estructural, C₀ + C₁: Umbral, A₁: Alcance, AIC: Criterio de información de Akaike, RMSE: Raíz del error cuadrático medio, NR: *Nugget* relativo $((C_0/C_0+C_1)*100)$

Los semivariogramas de los atributos presentan un carácter transitivo, donde la semivarianza aumentó con los incrementos de la distancia hasta llegar a un máximo en la cual se estabiliza indicando la presencia de dependencia espacial. Las tres variables presentaron una moderada dependencia (Cambardella *et al.*, 1994). El alcance o rango de dependencia espacial fluctuó entre 28 y 105 m, con un promedio de 64 m. Una vez ajustados los tres modelos, se estimaron las variables en los sitios no muestreados por medio de *kriging* ordinario, obteniéndose los modelos de variación espacial representados en la Figura 6.




Figura 6. Mapas de la distribución de tamaño de partículas del suelo: a) arcilla, b) arena y c) limo.

Evaluación de la confiabilidad de los modelos de predicción

Los resultados de las validaciones de las propiedades del suelo se indican en el Cuadro 4, donde se observan los bajos valores de los errores de predicción, los cuales son muy cercanos a cero para los índices ME y RSME. El coeficiente de concordancia presentó un mejor ajuste para la validación cruzada con un grado de acuerdos cercano al 100% entre los valores estimados y observados. Esto contrasta ligeramente con la validación con datos independientes cuyo valor promedio alcanza una concordancia del 67% entre los valores observados y los estimados por los modelos geoestadísticos.

Cuadro 4. Error de predicción de las propiedades granulométricas del suelo.

Índice	Validación cruzada			Datos independientes		
	Arcilla	Arena	Limo	Arcilla	Arena	Limo
ME	0,058	0,023	-0,001	0,184	-0,132	0,030
RMSE	2,467	3,015	2,910	1,996	2,696	2,906
AC	0,999	0,997	0,992	0,738	0,603	0,673

ME: error medio, RMSE: raíz del error cuadrático medio, AC: Coeficiente de concordancia.

Generación del modelo digital de clases de textura del suelo

Número de clases de textura del suelo

La representación de la variación del índice de rendimiento borroso (FPI) en función del número de clases para diferentes coeficientes de borrosidad, se señala en la Figura 7. En el esquema se visualiza que el número de clases de suelo más adecuado se obtuvo con 4 clases, combinado con un ϕ de 1.3. El valor del FPI de 0,17 señala el punto de intersección en la cual existe una minimización del grado de borrosidad, que determinó el número óptimo de clases, caracterizadas por ser menos borrosa y menos desorganizada internamente, para el conjunto de variables relacionadas con la distribución de tamaño de partículas.




Figura 7. Variación del índice de borrosidad alcanzado (FPI) en función del número de clases.

Clases de textura de los suelos

Los resultados de los valores de las propiedades del suelo al centro de cada clase de suelo neuro-borrosa se indican en el Cuadro 5. Las clases **A** y **B** agrupan suelos con contenidos de arcilla superiores al 40% en la capa superficial, por lo que ambas clasifican como arcillosas (A). Las clases difieren principalmente en la cantidad de fracciones medias en la distribución de tamaño de partículas, los cuales son inferiores en los suelos de la clase B. Las clases **C** y **D** se caracterizan por agrupar suelos con contenidos de arcilla inferiores al 40%, y clasifican en el grupo de textura franco arcillosa (FA). Ambas difieren en la cantidad de fracciones gruesas en la distribución de tamaño de partículas, cuya expresión es superior en los suelos de la clase D.

Cuadro 5. Centroides de las clases de textura del suelo obtenidas con FKCN.

Clase	Arcilla (%)	Arena (%)	Limo (%)
A	40,3	31,6	27,9
B	43,3	31,7	25,0
C	39,5	29,5	30,8
D	38,0	34,2	28,0

La aplicación del algoritmo FKCN también generó los grados de membresía de cada celda (píxel) a cada una de las clases de textura del suelo. La clasificación produjo vectores de valores de membresía para cada celda del modelo correspondiente a cada clase de textura. Estos valores fueron representados espacialmente produciendo mapas individuales de los miembros de las clases, las cuales reflejan la variación espacial de los grados de pertenencia entre 0 (colores oscuros) y 1 (colores claros), a través de mapas en formato *ráster* expresados en la Figura 8.

Tanto los valores de los centros de clase, como los mapas de las funciones de membresía, permitieron establecer dos grandes grupos de suelos con base en las clases de textura. De esta manera, las cuatro clases fueron reclasificadas y reagrupadas en dos categorías, cuya expresión cartográfica permitió una descripción más apropiada de la variación espacial de los suelos. Al respecto, los patrones de variación espacial permitieron discriminar la dominancia de suelos arcillosos en los sectores Nor-este, Sur-este y Sur, lo cual está relacionado con los procesos de distribución granulométrica, donde las partículas más finas se acumulan en las regiones más alejadas de los sitios de desborde de los cursos de agua. Las fracciones más gruesas recorren menos distancia, acumulándose en áreas cercanas al curso principal, específicamente en los sectores Nor-oeste y central del terreno.




Figura 8. Valores de la función de membresía a cada una de las clases de textura del suelo.

La combinación de los modelos de distribución espacial de los valores de membresía produjo el mapa unificado de variación de las clases de textura de los suelos (Figura 9). Para producir este mapa el algoritmo FKCN transformó las clases de textura borrosas a discretas, por lo que cada celda del modelo fue asignada a la clase con el valor más alto de membresía.




Figura 9. Modelo de distribución de clases de textura del suelo del Campo Experimental IDESSA.

El modelo final corroboró la distribución de las clases de textura de los suelos, y además permitió visualizar la expresión de los límites definidos por las clases de textura dominantes en la capa superficial de los suelos. Estos límites facilitan la toma de decisiones para el establecimiento de parcelas experimentales, y posibilitan las opciones para las posibles explicaciones relacionadas con el estudio de la fertilidad de los suelos y el establecimiento de cultivos con fines comerciales y de investigación en el área de estudio.

Evaluación del modelo digital de clases de textura del suelo

La matriz de error indicó que existe un importante grado de aciertos de 33 casos para el total de clases texturales evaluadas, con 8 errores de asignación entre el mapa digital y las clases de textura de suelos obtenidas en campo. Los resultados de la confiabilidad del modelo digital de clases de textura del suelo indicaron una exactitud global equivalente al 81%, donde las categorías del modelo generado con las redes neuroborrosas fueron bien clasificadas (Cuadro 6). De acuerdo con la exactitud del productor, el número de coincidencias más significativo los presenta la clase de textura arcillosa (A) en la que la mayoría de los suelos resultaron clasificados en dicha categoría sin confundirse con las clases de textura francoarcillosa (FA).

Cuadro 6. Matriz de error de la evaluación de las clases de textura del suelo con FKN.

Clase Estimada	Clase Observada		Total Filas	E. Usuario
	A	FA		
A	9	7	16	0,56
FA	1	24	25	0,96
Total Columnas	10	31	33	
E. Productor	0,90	0,77	n: 41	

Exactitud Global: 0,81

De igual manera, la exactitud del usuario referida al porcentaje de cada clase textural que ha sido correctamente clasificada, es también indicativa de la confiabilidad del modelo. El caso más resaltante lo presenta la clase FA, donde la mayoría de los suelos resultaron clasificados correctamente y solo pocos de ellos se corresponden con otra clase de textura.

CONCLUSIONES

El modelo digital obtenido permitió conocer la distribución de las clases de textura de los suelos y visualizar la expresión de los límites definidos por las clases de textura representativas en la capa superficial de los suelos.

La evaluación del modelo neuroborroso indicó que la predicción espacial de clases texturales se corresponde con las clases de textura del suelo presentes en el sector estudiado, ya que la confiabilidad del mapa digital fue superior al 80% de exactitud.

La combinación de las redes neuronales artificiales y las técnicas geoestadísticas proporcionaron una alternativa que puede contribuir a mejorar la toma de decisiones para la ubicación de parcelas experimentales y realizar investigaciones locales de gran importancia, al generar predicciones de clases de textura del suelo con adecuada exactitud, capaz de integrar la variabilidad de los componentes granulométricos de los suelos en el sector estudiado.

AGRADECIMIENTOS

Esta investigación fue apoyada por el Centro de Investigación y Extensión en Suelos y Aguas de la Universidad Nacional Experimental de los Llanos Centrales “Rómulo Gallegos” (CIESA-UNERG).

REFERENCIA BIBLIOGRAFICAS

- Bezdek, J.C., E.C. Tsao, N.R. Pal.** 1992. Fuzzy Kohonen Clustering Networks, *in*: Proc. IEEE Int. Conf. on Fuzzy Systems (San Diego), pp. 1035-1043.
- Burrough, P.** 1986. Principles of geographical information systems land resources assessment. Clarendon Press Oxford. 193 p.
- Cambardella, C., T. Moorman, J. Novak, T. Parkin, D. Karlen, R. Turco, E. Konopka.** 1994. Field scale variability of soil properties in Central Iowa Soils. Soil Sci. Soc. Am. J. Vol. 58:1501-1511.
- Chuvieco, E.** 2008. Teledetección Ambiental. La observación de la Tierra desde el Espacio. 3ª. Edición actualizada. Editorial Ariel, S. A. España. 595 p.
- Di Rienzo J.A., F. Casanoves, M.G. Balzarini, L. Gonzalez, M. Tablada, C.W. Robledo.** 2011. InfoStat versión 2011. Grupo InfoStat, FCA, Universidad Nacional de Córdoba, Argentina. URL <http://www.infostat.com.ar>.
- Gabriels, D., D. Lobo.** 2011. Métodos para determinar granulometría y densidad aparente del suelo. Venesuelos Vol.14: 37-48.
- Gee, G.W., D. Or.** 2002. Particle-size analysis. En: J.H. Dane and G.C. Topp (Ed.) Methods of soil analysis. Part 4. SSSA Book series N° 5, SSSA, Madison, WI. pp. 255-293.
- Grunwald, S., R.L. Rivero, K. Ramesh.** 2007. Understanding spatial variability and its application to biogeochemistry analysis. *In*: D. Sarkar, R. Datta and R. Hannigan (Ed.). Developments in Environmental Science, 5:443-463. Elsevier Ltd. ISSN: 1474-8177.
- Hengl, T., G.B.M. Heuvelink, A. Stein.** 2004. A generic framework for spatial prediction of soil variables based on regression-kriging. Geoderma Vol. 120: 75-93.
- Ji, L., K. Gallo.** 2006. An Agreement Coefficient for Imag Comparison. Photogrammetric Engineering & Remote Sensing, Vol. 72 (7): 823–833.

- Kohonen, T.** 1982. Analysis of a simple self-organizing process. *Biological Cybernetics*. Vol. 44: 135-140.
- Lin, C., C. Lee.** 1996. *Neural fuzzy systems*. Prentice Hall, Inc. New Jersey, USA. 797 p.
- Minasny, B., A.B. Mcbratney y M. Whelan.** 2002. VESPER. Version 1.6. Australian Centre for Precision Agriculture. McMilan Building. The University of Sidney, NSW 2006.
- Núñez, Y.** 2011. Modelo automatizado de unidades de paisaje a escala 1:50000 con un enfoque neuronal borroso. En la Cuenca del río Tucutunemo, Estado Aragua. Trabajo de Especialización de Geomática. Postgrado en Ciencia del Suelo. Facultad de Agronomía. UCV. 75 p.
- Odeh, I.O.A., A.B. McBratney, D.J. Chittleborough.** 1992. Soil pattern recognition with fuzzy c-means: application to classification and soil landform interrelationships. *Soil Sci. Soc. Am. J.* Vol. 56: 505- 516.
- Ovalles F., J. Rey.** 1994. Variabilidad interna de unidades de fertilidad en suelos de la depresión del lago de Valencia. *Agron. Trop.* Vol. 44(1): 41-65
- Ovalles, F.** 1992. Metodología para determinar la superficie representada por muestras tomadas con fines de fertilidad. FONAIAP-CENIAP-IIAG. Maracay. Serie B. 44 p.
- Pineda, M.C., A. Valera, J.A. Vilorio, R. Caballero, Z. Lozano, D. Lobo y L.C. Timm.** 2015. Mapa digital de clases texturales de suelo en un área bajo agricultura intensiva. 1er. Congreso Nacional de Geomática. Caracas, 26 al 31 de octubre de 2015. 5 p.
- Rey, J.C., G. Martínez, E. Micale, N. Fernández, E. Namias, M.A. Polanco, A. Valera.** 2015. Mapeo de suelos por medio de lógica borrosa y su relación con el rendimiento de banano (musa AAA). XXII Congreso Venezolano de la Ciencia del Suelo. San Cristóbal, Táchira. Venezuela. 6 p.
- Tukey, J.** 1977. *Exploratory Data Analysis*. Addison-Wesley Pub. Reading, EUA.
- Upchurch, D., W.J. Edmonds.** 1991. Statistical procedures for specific objectives. In: *Spatial variabilities of soils and landforms*. SSSA Special publication No. 28. 2ª Ed. SSSA. Madison. pp: 49-71.
- USDA.** 1987. *Soil Mechanics Level I. Module 3. USDA Textural Soil Classification*. Study Guide. Soil Conservation Service. 53 p.
- Valera, A.** 2012. *Tecnologías de Inteligencia Artificial: Redes neuronales artificiales y teoría de conjuntos borrosos para el análisis geomorfométrico de paisajes de montaña*. Editorial Académica Española. 108 p. ISBN: 978-3-8484-7612-1.
- 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*. Tesis de doctorado en Ciencias del Suelo. Universidad Central de Venezuela. Postgrado en Ciencias del Suelo. Maracay, Estado Aragua, Venezuela. 263 p. DOI: 10.13140/RG.2.1.1714.3920

- Valera, A. y J.A. Viloria.** 2009. Aplicación de técnicas de inteligencia artificial en el modelado de unidades de paisaje en la cuenca del río Güey, Maracay - estado Aragua. Memorias XVIII Congreso Venezolano de la Ciencia del Suelo. Santa Bárbara, Zulia. Venezuela. 7 p.
- Valera, A., J.A. Viloria; Á. Viloria.** 2010. Aplicación de redes neuro-difusas en la clasificación geomorfométrica de paisajes montañosos de Venezuela. *En: Resúmenes.* XV Congreso Colombiano de la Ciencia del Suelo. Morales, C., J. Cuervo y H. Franco (compiladores). SCCS. Risaralda, Pereira. Colombia. p.97.
- Viloria J.A, A. Viloria, M.C. Pineda, A. Valera.** 2016. Digital modelling of landscape and soil in a mountainous region: A neuro-fuzzy approach. *Geomorphology* Vol. 253:199-207.
- Viloria, J.A., M.C. Pineda, A. Viloria, Y. Núñez, A. Valera.** 2012. Predicción de pedregosidad superficial del suelo con redes neuro-borrosas en llanos venezolanos. XIX Congreso Latinoamericano de la Ciencia del Suelo. XXIII Congreso Argentino de la Ciencia del Suelo. Mar del Plata, Argentina - 16 al 20 de abril de 2012. 6 p.
- Viloria, A.** 2007. Estimación de Modelos de clasificación de paisaje y predicción de atributos de suelos a partir de imágenes satelitales y modelos digitales de elevación. Trabajo Especial de Grado. Universidad Central de Venezuela. Caracas, Venezuela. 88 p.
- Webster, R., M.A. Oliver.** 2007. *Geostatistics for Environmental Scientists.* Second Edition. Wiley, Chichester. 330 p.
- Willmott, C.J.** 1981. On the validation of models. *Physical Geography*, Vol. 2: 184-194.
- Willmott, C.J.** 1984. On the evaluation of model performance in physical geography. *In: Spatial Statistics and Models*, 443-460. Gaile, G.L. y C. J. Willmott, (eds). Norwell, Mass.: D. Reidel.
- Willmott, C.J., S.G. Ackleson, R.E. Davis, J.J. Feddema, K.M. Klink,, D.R. Legates, J. O'Donnell, C.M. Rowe.** 1985. Statistics for the evaluation and comparison of models. *Journal of Geophysical Research* Vol. 90(5): 8995-9005.
- Zhu, A.X., J.E. Burt.** (Noviembre, 2015). Digital Soil Mapping Software: SoLIM Solutions 2015. Reference Manual. Institute of Geographic Sciences, Natural Resources Research-Chinese Academy of Sciences-The University of Wisconsin-Madison. [On line]: <http://solim.geography.wisc.edu/software/index.htm>.