
ANÁLISIS ESPACIAL DE LA FERTILIDAD DEL SUELO CON APOYO DE TÉCNICAS GEOESTADÍSTICAS Y REDES NEURONALES ARTIFICIALES

Ángel Rafael Valera Valera^{1, 2*}, Eladio Ramon Arias Rodríguez^{1, 2}

¹ Universidad Rómulo Gallegos, Centro de Investigación y Extensión en Suelos y Aguas (CIESA-UNERG), San Juan de los Morros, Estado Guárico, Venezuela, e-mail: angelvalera@unerg.edu.ve. ORCID: <https://orcid.org/0000-0001-5500-1332>

² Universidad Rómulo Gallegos, Área de Ingeniería Agronómica, San Juan de los Morros, Estado Guárico, Venezuela, e-mail: eladioariasrod1956@gmail.com

* Autor correspondiente

Recibido: DD/MM/2025; **Aceptado:** DD/ MM/ 2025; **Publicado:** DD /MM/2025

RESUMEN

La información sobre la variación espacial de los atributos de fertilidad de un suelo es un insumo esencial en la agricultura de precisión y para la toma de decisiones sobre el manejo del suelo. En este estudio se realizó la evaluación de la fertilidad del suelo a través de la distribución espacial de mapas temáticos de propiedades individuales y la posterior integración en un modelo de cartografía digital de clases locales de fertilidad, como bases fundamentales para la implementación de planes de fertilización y enmiendas ajustadas al estatus del suelo y a los requerimientos del cultivo. Para la evaluación de la fertilidad se realizó un muestreo sistemático superficial en 70 sitios en terrenos del Campo de producción "Agronomía" de la Universidad Nacional de los Llanos Centrales "Rómulo Gallegos", sector El Castrero, municipio Juan German Roscio, estado Guárico, Venezuela. Se analizaron diez variables del suelo: pH (1:2,5), conductividad eléctrica (1:5), materia orgánica, fósforo disponible, potasio asimilable, calcio y magnesio disponible, y las cantidades relativas de arena, limo y arcilla. Los mapas de propiedades del suelo se produjeron mediante un análisis geoestadístico y la interpolación por kriging ordinario, y para la generación de las clases de fertilidad del suelo se aplicaron técnicas de inteligencia artificial basada en un sistema de clasificación por redes neuronales artificiales, con el algoritmo FKCN (red de agrupamiento difuso de Kohonen o Fuzzy Kohonen Clustering Network) mediante la interpolación de los valores de la función de pertenencia a cada una de las clases. La confiabilidad de los mapas individuales de cada variable del suelo se obtuvo mediante validación cruzada con un nivel de confiabilidad superior al 90%, a excepción de las variables % Arcilla y % Limo que presentaron una confiabilidad mayor al 85%. La integración de los mapas de atributos del suelo y la combinación de los valores de pertenencia a cada clase produjo un mapa integrado por cinco categorías de fertilidad de suelo. El modelo final de clases digitales de fertilidad de suelos presentó una confiabilidad equivalente al 86%, lo que indicó un alto grado de homogeneidad dentro de las clases de suelo obtenidas con fines de fertilidad.

Palabras clave: Fertilidad del Suelo, Geoestadística, Kriging, Red Neuronal Artificial, Algoritmo FKCN

SPATIAL ANALYSIS OF SOIL FERTILITY WITH THE SUPPORT OF GEOSTATISTICAL TECHNIQUES AND ARTIFICIAL NEURAL NETWORKS

ABSTRACT

Information on the spatial variation of soil fertility attributes is an essential input for precision agriculture and soil management decision making. In this study, soil fertility assessment was carried

out through the spatial distribution of thematic maps of individual properties and the subsequent integration into a digital mapping model of local fertility classes, as fundamental bases for the implementation of fertilization and amendment plans adjusted to soil status and crop requirements. For the evaluation of fertility, a systematic surface sampling was carried out in 70 sites in the "Agronomy" production field of the National University of the Central Plains "Romulo Gallegos", El Castreño sector, Juan German Roscio municipality, Guárico state, Venezuela. Ten soil variables were analyzed: pH (1:2.5), electrical conductivity (1:5), organic matter, available phosphorus, assimilable potassium, available calcium and magnesium, and the relative amounts of sand, silt and clay. Soil property maps were produced by geostatistical analysis and interpolation by ordinary kriging, and artificial intelligence techniques based on an artificial neural network classification system were applied to generate soil fertility classes using the Fuzzy Kohonen Clustering Network (FKCN) algorithm by interpolating the values of the membership function for each of the classes. The reliability of the individual maps of each soil variable was obtained by cross validation with a reliability level higher than 90%, with the exception of the variables % Clay and % Silt that presented a reliability higher than 85%. The integration of the soil attribute maps and the combination of the values of belonging to each class produced a map integrated by five soil fertility categories. The final model of digital soil fertility classes presented a reliability equivalent to 86%, which indicated a high degree of homogeneity within the soil classes obtained for fertility purposes.

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

INTRODUCCIÓN

La fertilidad del suelo es una importante cualidad que resulta de la interacción entre las características físicas, químicas, biológicas y bioquímicas del medio edáfico, la cual consiste en la capacidad de suministrar todas las condiciones necesarias para el crecimiento y desarrollo de las plantas. A su vez, el conocimiento de la variación espacial de la fertilidad del suelo en los campos agrícolas es un aspecto fundamental para la definición del establecimiento de parcelas productivas homogéneas, con fines de manejo de sitio específico (Srinivasan et al., 2022).

Una fuente de información relacionada con la fertilidad son los análisis de suelos que realizan los laboratorios, los cuales prestan dicho servicio en diversas localidades del país. Esta fuente de datos constituye un aporte sobre resultados analíticos de propiedades del suelo relacionadas con la reacción (pH), salinidad (conductividad eléctrica), granulometría (arcilla, arena, limo), materia orgánica, macroelementos (Fósforo, Potasio), elementos secundarios (Calcio, Magnesio), microelementos (Zinc, Cobre, Hierro y Manganeso) y acidez intercambiable (Aluminio, Hidrógeno). Cada informe de análisis de suelo con fines de fertilidad es una integración de resultados que tiene como propósito el desarrollo de un plan de fertilización orgánica e inorgánica y enmiendas ajustadas al estatus del suelo y a los requerimientos del cultivo, complementada con el manejo de los factores climáticos o riego y las actividades agro-culturales.

El análisis espacial de la fertilidad de suelo facilita la toma de decisiones al momento de la aplicación de prácticas agronómicas en los espacios productivos, permitiendo el suministro apropiado de nutrientes al suelo, y minimizando el impacto sobre el recurso suelo en beneficio de la biodiversidad. Sin embargo, la representación manual de las clases de fertilidad del suelo amerita la elaboración de mapas individuales de cada una de las variables, y la posterior superposición de éstos para la obtención de áreas homogéneas y patrones similares que faciliten el manejo, lo que implica sesgos y baja precisión en el resultado final. Por ello, la organización

sistemática de los datos de suelo en áreas geográficas o unidades de tierras es una oportunidad para evaluar la distribución espacial de la capa superficial del suelo, expresar la variación espacial de la fertilidad de los suelos a través de mapas temáticos y dar un mayor valor agregado a los análisis de suelo con fines de fertilidad, a través de los productos de cartografía digital de propiedades y clases de suelo con mayor grado de homogeneidad.

Dentro de las técnicas de análisis espacial, los métodos geoestadísticos juegan un papel importante para la predicción de propiedades del suelo, donde destaca el método de interpolación denominado kriging ordinario (Webster y Oliver, 1990). Sin embargo, la representación individual de las variables que definen la fertilidad de los suelos no cubre el interés y la necesidad de visualizar el comportamiento de manera conjunta de la fertilidad de suelo. El análisis espacial permite evaluar la variación de propiedades individuales del suelo y la conformación de clases de suelo, con la finalidad de apoyar la toma de decisiones sobre áreas homogéneas como base para el manejo de sitio específico y para el impulso de la agricultura de precisión. Esta información sirve como base a los usuarios, para tener una idea completa acerca del estado de los nutrientes del suelo de un sector en un solo mapa, y también contribuye a la toma de decisiones en cuanto al manejo más apropiado de los suelos (Padua et al., 2018; Shashikumar et al., 2022).

Para la generación de clases de suelo existen técnicas de análisis espacial basadas en inteligencia artificial, tales como la lógica difusa y las redes neuronales artificiales (RNA). Estas técnicas se adaptan adecuadamente al estudio de los atributos del suelo, los cuales varían gradualmente sobre el espacio, donde la representación de esa variación gradual puede resultar en la obtención de información útil y en la disminución de errores en la definición de límites apropiados de unidades edafológicas (Burrough et al. 2000). La combinación de la potencialidad de los conjuntos difusos y las RNA ha desarrollado una técnica integral de clasificación no supervisada denominada red de agrupamiento difuso de Kohonen o Fuzzy Kohonen Clustering Network (FKCN) (Lin y Lee, 1996; Bezdeck et al., 1992), que conjuga un algoritmo de mapas autoorganizados o self organizing map (SOM) (Kohonen, 1982) y el algoritmo Fuzzy C-means (FCM) (Bezdeck, 1981).

Son escasos los trabajos de investigación realizados en el ámbito de la Ciencia del Suelo que toman en cuenta la combinación de propiedades individuales para expresarlas como categorías de fertilidad de suelo. Al respecto, la aplicación de las redes neuronales-difusas ha dado un gran impulso a la cartografía digital de suelos tanto en la predicción de propiedades como en la obtención de clases de suelo. En Venezuela, las redes neuronales difusas 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), Viloria et al (2012), Valera (2012), Sevilla (2014) y Viloria et al (2016), en la predicción de propiedades y clases locales de suelo (Valera, 2015; Valera, 2018), en el estudio de las relaciones suelo y rendimiento del cultivo de banano (Rey et al., 2015) y en la delimitación de clases de fertilidad (Valera y Orta, 2018).

En este trabajo se presenta un estudio de análisis espacial de clases de fertilidad a través de la predicción de propiedades químicas y físicas del suelo obtenidas en los análisis de laboratorio por medio de técnicas geoestadísticas, y su posterior

agrupamiento mediante un algoritmo de redes neuronales artificiales difusas. Para evaluar el comportamiento espacial de las clases de fertilidad de los suelos, se consideró el Campo de Producción “Agronomía” de la Universidad Nacional Experimental de los Llanos Centrales “Rómulo Gallegos”, ubicado en el sector El Castrero, parroquia San Juan de los Morros, municipio Juan German Roscio, estado Guárico (Venezuela).

MATERIALES Y MÉTODOS

Área de Estudio

La zona de estudio donde se llevó a cabo el ensayo de cartografía digital del suelo se encuentra ubicada en terrenos del Campo de Producción “Agronomía” de la Universidad Nacional Experimental de los Llanos Centrales “Rómulo Gallegos”, ubicado en el sector El Castrero, parroquia San Juan de los Morros, municipio Juan German Roscio del estado Guárico (Figura 1). La unidad de estudio se encuentra enmarcada en una zona aluvial, con pendiente de 3 a 5%. Los suelos en esta área fueron formados de materiales geológicos del cuaternario, con un moderado desarrollo pedogenético, y son de moderada fertilidad.

Figura 1. Ubicación de la zona de estudio en el sector El Castrero, parroquia San Juan de los Morros, municipio Juan German Roscio, estado Guárico.

Muestreo

Para la evaluación de los suelos se realizó un muestreo sistemático en el horizonte superficial a 20 cm de profundidad, en cuadrículas espaciadas a 30 m, para un total de 70 muestras de suelo en una superficie de 6,15 ha (Figura 2). Cada punto de muestreo fue georreferenciado con apoyo de un sistema de posicionamiento global (GPS). A las muestras superficiales 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). Se analizaron diez variables de suelo: pH en agua (1:2,5), conductividad eléctrica en agua 1:5 (CE, dSm^{-1}), materia orgánica (MO, %), fósforo disponible (P, mgkg^{-1}), potasio asimilable (K, $\text{cmol}(+)\text{kg}^{-1}$), calcio (Ca, $\text{cmol}(+)\text{kg}^{-1}$) y magnesio disponible (Mg, $\text{cmol}(+)\text{kg}^{-1}$), y las cantidades relativas de arena, limo y arcilla (%).

Análisis estadístico

Los datos de las variables edáficas se sometieron a un análisis exploratorio (AED) con apoyo del paquete estadístico SPSS® (IBM® Statistics, versión 20), con el fin de determinar 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 Interpolación de los datos de las variables edáficas. **Interpolación de los datos de las variables edáficas.**

Para la interpolación de los datos de las variables edáficas se utilizó el método estadístico *kriging* ordinario, el cual utiliza un modelo de semivariograma para la estimación de los pesos que se asignan a cada punto de referencia empleado en la estimación del valor de las variables regionalizadas que 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, 1992). 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 o meseta (C_0+C_1) y el alcance o rango (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 de las propiedades del suelo se realizaron las transformaciones necesarias y se eliminaron las posibles tendencias presente en los datos. Luego se realizó el ajuste a modelos matemáticos con la extensión de análisis geoestadístico del programa ArcGIS® (ArcMap v. 10.8). Con los parámetros ajustados se obtuvieron los estimados óptimos de las variables edáficas

en los sitios no muestreados, a través de la interpolación con el método *kriging* ordinario (Webster y Oliver, 1990). Los modelos de las variables del suelo se generaron con el total de los datos y la exactitud de los mapas se obtuvo mediante validaciones cruzadas. En la evaluación se utilizaron seis índices: el error medio (EM), el error medio estandarizado (EME), el error cuadrático medio (ECM), el error cuadrático medio estandarizado (ECME), el error estándar promedio (EEP) y el nivel de confiabilidad (%NC). El EM evalúa el error sistemático e indica la presencia de subestimación o sobrestimación del modelo y el EME muestra la desviación del modelo obtenido. El ECM evalúa la precisión de la predicción y mide la cantidad de error que hay entre los conjuntos de datos medidos e inferidos, es decir, compara un valor predicho y un valor observado o conocido; mientras que el ECME es más preciso mientras más se aproxime al valor ideal de la unidad (1). El EEP indica la variabilidad de las predicciones, cuyas estimaciones serán más adecuadas si sus valores están más cerca del ECM.

Modelo digital de clases de fertilidad del suelo

Para la obtención de los modelos representativos de las clases de fertilidad del suelo se utilizó el algoritmo neuro-difuso FKCN implementado en ambiente Java (Windows) por Vilorio (2012). La arquitectura de la red neuronal FKCN utilizada en el análisis consta de tres capas (Figura 3). La capa de entrada contiene los valores normalizados de diez (10) variables del suelo procedentes de los modelos de predicción de dichos atributos. La capa de distancias incluye las neuronas equivalentes al número preestablecido de clases digitales de suelo, y la tercera capa calcula la función de pertenencia de cada celda a cada una de las clases de suelo, basada en las distancias computarizadas en la capa anterior y los valores preestablecidos del coeficiente difuso (ϕ). 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 del modelo 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 . En el 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 cada clase.

Las variables del suelo fueron agrupadas en una matriz de datos para la aplicación del algoritmo FKCN, lo que permitió evaluar el agrupamiento de píxeles con diversos números de clases (2 a 8) y diferentes coeficientes difusos ($\phi = 1,1$ a $1,6$). A las clases de fertilidad obtenidas se les asignó el significado edafológico a través de la interpretación de su distribución espacial, las descripciones de los centros de clase y las matrices de los valores de similitud (mapas del grado de pertenencia a cada clase) obtenidos mediante el algoritmo FKCN, conjuntamente con la información de los análisis de los suelos de la zona.



Figura 3. Estructura de la red neuronal difusa utilizada en la predicción de clases de suelo.**Número de clases de fertilidad del suelo**

Para la obtención del mejor modelo de clases difusas se empleó un enfoque inductivo, basado en el procedimiento de Odeh *et al.* (1992), el cual relaciona el índice de rendimiento difuso (FPI, *Fuzziness Performance Index*) con el número de clases. Estos parámetros se obtienen utilizando el algoritmo *Fuzzy Kohonen Clustering Networks* (FKCN) (Lin y Lee, 1996) del programa *FKCN* (Viloria *et al.*, 2012). La selección del número óptimo de clases en FKCN se realizó por repetición de la clasificación para un rango de número de clases. El FPI estima el grado de borrosidad generada por cada número específico de clases. Matemáticamente, se define como:

$$FPI = 1 - [(cF - 1) / (c - 1)] \quad (2)$$

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

$$F = (1 / n) \sum_{i=1}^n \sum_{k=1}^c (\mu_{ik})^2 \quad (3)$$

F es conceptualmente comparable a la relación del conjunto de varianzas dentro de las clases y la varianza entre clases y es cercana a la unidad (1) para los agrupamientos más significativos. En el presente estudio, el agrupamiento de mapas de propiedades del suelo en formato *raster* se realizó estableciendo previamente los siguientes parámetros: a) número de clases (**c**= 3 a 10), b) exponente difuso ϕ = 1,10 a 1,60 con incrementos de 0,10; c) un máximo de 300 iteraciones, y d) criterio de detención (ϵ = 0,0001). En los cálculos se utilizó la distancia métrica de *Mahalanobis*, la cual toma en consideración la correlación existente entre algunas variables del suelo de la zona evaluada.

Evaluación de la capacidad predictiva de las clases de fertilidad del suelo

Para evaluar la capacidad predictiva de las clases obtenidas mediante el agrupamiento difuso, se realizó la validación del modelo final mediante un proceso de validación cruzada, empleando las funciones discriminantes de cada clase como estadísticas multivariadas derivadas del análisis discriminante canónico. En el proceso de validación cruzada, cada caso se clasifica mediante las funciones discriminantes derivadas a partir del resto de los casos.

RESULTADOS Y DISCUSIÓN**Análisis estadístico**

Los estadísticos descriptivos indicaron que los valores promedios de los suelos

corresponden a grupos texturales franco-arcillosos y arcillosos, con reacciones que oscilan de ligeramente a fuertemente ácida, bajos a medianos contenidos de fósforo y moderados a altos contenidos de Potasio, alta disponibilidad de Calcio y Magnesio, bajos a medianos contenidos de materia orgánica, y no tienen problemas de salinidad (Cuadro 1).

Cuadro 1. Estadísticos descriptivos de las variables de fertilidad del suelo del Campo experimental.

Variable ¹	Mínimo	Máximo	Mediana	Mediana	Curtosis	Asimetría	DE	Varianza	CV (%)
pH (1:2,5)	4,97	6,40	5,70	5,66	-0,23	0,41	0,32	0,103	5,6
CE (dS m ⁻¹)	0,010	0,100	0,036	0,026	0,47	1,12	0,02	0,001	63,6
P (mg kg ⁻¹)	4,44	44,48	17,1	16,24	-0,20	0,57	9,83	96,55	57,6
K (cmol (+) kg ⁻¹)	0,31	1,44	0,71	0,67	0,68	0,91	0,26	0,069	37,3
Ca (cmol (+) kg ⁻¹)	0,90	2,40	1,59	1,55	0,63	0,53	0,29	0,082	18,0
Mg (cmol (+) kg ⁻¹)	0,17	1,41	0,88	0,90	0,43	-0,15	0,24	0,060	27,7
MO (%)	0,78	4,17	2,67	2,57	0,85	0,06	0,63	0,400	23,6
Arcilla (%)	14,00	70,00	41,1	40,48	0,14	0,13	11,23	126,0	27,3
Arena (%)	5,10	74,96	31,5	32,98	1,19	0,33	12,66	160,2	40,2
Limo (%)	5,04	52,40	27,3	29,00	-0,74	-0,17	11,45	131,1	41,9

¹Número de datos: 70, DE: Desviación estándar, CV: Coeficiente de variación, CE: Conductividad eléctrica, P: Fósforo disponible, K: Potasio asimilable, Ca: Calcio disponible, Mg: Magnesio disponible, MO: Materia orgánica.

La mayoría de las variables presentan cierta similitud entre la media y la mediana, a excepción de las variables CE y K. A su vez, la mayor dispersión de los datos la presentan las mismas variables aunadas a los valores de granulometría, debido a la expresión de la desviación estándar y la varianza; sin embargo, los coeficientes de variación de las variables en conjunto, no presentan problemas en cuanto a la existencia de valores extremos de los datos.

De acuerdo con el coeficiente de sesgo o asimetría las variables pH, %arena, % arcilla, Ca, Mg y %MO cumplen con la función de distribución de probabilidad normal, y se pueden aplicar métodos geoestadísticos a los datos. Sin embargo, para P, K y CE fue necesario evaluar los datos mediante transformaciones (normalización) para la posterior aplicación de algún método geoestadístico a los datos. En cuanto a la curtosis, solo los datos de las variables K están concentrados respecto a la media (desviación estándar pequeña) dando una gráfica alargada; mientras que los datos de pH, %limo y P están dispersos, presentando gráficas achatadas o aplastadas.

La aplicación de la prueba de cercas externas e internas indicó que las variables consideradas no presentan valores atípicos. Finalmente, en cuanto a la prueba de normalidad, se verificó que solamente las variables K y MO, proceden de poblaciones normales, ya que los valores de la prueba estadística son altamente significativos ($p > 0,05$). Para el resto de los datos fue necesario realizar la transformación de los mismos.

Interpolación de propiedades del suelo

La estimación de los semivariogramas empíricos de las variables del suelo, fueron ajustados a modelos matemáticos gaussianos, esféricos, exponenciales, estables y cilíndricos respectivamente (Figura 4), considerando el comportamiento isotrópico de las variables. Los parámetros geoestadísticos derivados del ajuste de los semivariogramas a diferentes modelos teóricos, se expresan en el Cuadro 2, y los modelos de cada variable se presentan en la Figura 5.

El análisis estructural de los modelos de semivariogramas indicaron que los modelos de las variables en su mayoría presentan una fuerte dependencia espacial ($< 25\%$ de efecto aleatorio o *nugget* relativo), aunque las variables K y Ca presentan una moderada dependencia espacial (varianza relativa entre 25 y 75%), y % arena presenta una débil dependencia espacial, con un *nugget* relativo $>75\%$. En general, todos los semivariogramas presentan estructura, con un incremento de la varianza total hasta alcanzar una distancia máxima promedio de 59 m. Es decir, destaca un rango de dependencia espacial de 59 m para todos los modelos, a excepción del semivariograma de la variable P disponible que presenta un alcance 1,5 veces del promedio.

Cuadro 2. Parámetros geoestadísticos de los semivariogramas compuestos de las propiedades del suelo.

Variables	Modelo	C_0	C_1	A_1	C_0+C_1	NR (%)
pH (1:2,5)	Gausiano	0,000	0,110	56	0,11	0,0
CE (dS m ⁻¹)	Gausiano	0,000	0,000	59	0,00	0,0
P (mg kg ⁻¹)	Esférico	0,100	82,49	93	82,6	0,1
K (cmol (+) kg ⁻¹)	Circular	0,080	0,05	59	0,13	60,4
Ca (cmol (+) kg ⁻¹)	J-Bessel	0,016	0,036	59	0,05	30,7
Mg (cmol (+) kg ⁻¹)	Estable	0,000	0,058	59	0,06	0,0
MO (%)	Gausiano	0,030	0,410	59	0,40	6,8
Arcilla (%)	Gausiano	0,000	125,64	59	125,6	0,0
Arena (%)	Esférico	78,28	22,06	59	100,3	78,0
Limo (%)	J-Bessel	0,000	137,02	59	137,0	0,0

C_0 : Varianza *nugget*, C_1 : Varianza estructural, $C_0 + C_1$: Umbral, A_1 : Alcance, NR: *Nugget* relativo ($(C_0/C_0+C_1)*100$), J-Bessel: función de simetría cilíndrica.

Figura 4. Ser

gronomía”.

Figura 5. Mapas de modelos de variables del suelo en el Campo de Producción “Agronomía”
Evaluación de la confiabilidad de los modelos de predicción

Los resultados de las validaciones de las variables del suelo se indican en el Cuadro 3, donde se observan los bajos valores de los errores de predicción, los cuales son muy cercanos a cero para los índices EM, ECM y EEP.

Cuadro 3. Error de predicción de las variables del suelo mediante validaciones cruzadas.

Variable	Función Regresión	Índice					
		EM	EME	ECM	ECME	EEP	NC (%)
pH (1:2,5)	$0,4631 * x + 3,03326$	0,00	0,00	0,25	1,08	0,23	99,6
CE (dS m ⁻¹)	$0,4466 * x + 0,01720$	0,00	0,01	0,02	1,30	0,02	100,0
P (mg kg ⁻¹)	$0,3914 * x + 10,3986$	-0,01	0,00	8,63	1,48	5,85	91,4
K ⁺ (cmol kg ⁻¹)	$0,1555 * x + 0,58614$	0,00	-0,01	0,25	0,96	0,26	99,7
Ca ⁺² (cmol kg ⁻¹)	$0,4550 * x + 0,84930$	0,00	0,00	0,23	0,98	0,23	99,7
Mg ⁺² (cmol kg ⁻¹)	$0,2305 * x + 0,67800$	0,00	0,01	0,21	0,96	0,22	99,7
MO (%)	$0,3167 * x + 1,81928$	0,01	0,02	0,55	0,98	0,56	99,2
Arcilla (%)	$0,5668 * x + 18,1189$	-0,02	0,00	9,08	1,31	7,19	86,1
Arena (%)	$0,3824 * x + 19,4403$	-0,41	-0,04	10,4	1,00	10,3	91,4
Limo (%)	$0,1880 * x + 21,5820$	0,20	0,02	10,8	0,93	11,6	85,1

EM: error medio, EME: Error medio estandarizado, ECM: error cuadrático medio; ECME: error cuadrático medio estandarizado; EEP: error estándar promedio, NC: Nivel de Confiabilidad. CE: Conductividad eléctrica, P: Fósforo disponible, K: Potasio asimilable, Ca: Calcio disponible, Mg: Magnesio disponible, MO: Materia orgánica

Se observa que los modelos que mejor se adaptan a los datos empleados cumplen con los requerimientos de ECM pequeño, EEP pequeño próximo a ECM, ECME cerca de 1 y un alto porcentaje de confiabilidad. De acuerdo con la confiabilidad de los modelos, la mayoría presentan valores superiores al 90%, a excepción de las variables % Arcilla y % Limo para los cuales es necesario mejorar la densidad de las medidas. La mayor subestimación la presentaron las variables físicas y la mayor incertidumbre está dada por la variable fósforo disponible (alejado de la unidad), las cuales presentaron una mayor varianza y coeficientes de variación algo elevados. Sin embargo, las variables granulométricas presentan valores de EEP muy cercanos a ECM. Para todos los casos evaluados los valores de ECM son inferiores a la *desviación estándar*, y por tanto son adecuados para la evaluación de los modelos de predicción (Marchetti *et al.*, 2010).

Generación del modelo digital de clases de fertilidad del suelo

Número de clases de fertilidad del suelo

La representación de la variación del índice de rendimiento difuso (FPI) en función del número de clases para diferentes coeficientes se señala en la Figura 6. En el esquema se visualiza que el número de clases de suelo más adecuado se obtuvo

con 5 clases, combinado con un ϕ de 1.2. El valor del FPI de 0,36 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 difusas y menos desorganizadas internamente para el conjunto de variables relacionadas con la fertilidad del suelo.



Figura 6. Var... es de suelo.

Los resultados de los valores de los centros de cada clase de fertilidad (centroides) se indican en el Cuadro 4. Esto permitió extraer los siguientes aspectos significativos: La clase 1 incluye suelos de clases texturales arcillosas y de pH ligeramente ácido y los valores más bajos de fósforo disponible.

Cuadro 4. Centros de clase de fertilidad del suelo obtenidas con el algoritmo FKN.

Variable del Suelo	Clase de Fertilidad de Suelo				
	1	2	3	4	5
pH agua (1:2,5)	5,99	5,52	5,52	5,88	5,70
CE agua (dS m ⁻¹)	0,02	0,03	0,06	0,03	0,05
P (mg kg ⁻¹)	11	17	18	25	22
K ⁺ (cmol kg ⁻¹)	0,59	0,71	0,75	0,93	0,57
Ca ⁺² (cmol kg ⁻¹)	1,35	1,58	1,80	1,54	1,77
Mg ⁺² (cmol kg ⁻¹)	0,73	0,99	1,07	0,90	0,68
MO (%)	2,41	2,87	2,73	3,04	2,09
Arcilla (%)	46,7	36,4	39,5	52,6	26,6
Arena (%)	26,0	31,3	37,5	24,5	47,3
Limo (%)	26,9	33,8	23,0	22,6	23,8

CE: Conductividad eléctrica, P: Fósforo disponible, K: Potasio asimilable, Ca: Calcio disponible Mg: Magnesio disponible, MO: Materia orgánica

La clase 2 incluye los suelos de textura franco-arcillosa, con reacciones moderadamente ácidas y con valores promedios en la mayoría de los elementos químicos disponibles que la caracterizan. La clase 3 también agrupa los suelos de textura franco-arcillosas y reacción moderadamente ácida, pero con contenidos de arcilla cercanos al 40%, además presentan los contenidos más elevados de calcio y de magnesio disponible. La clase 4 agrupa los suelos con los contenidos más elevados de arcilla (>50%), y los niveles más altos de fósforo disponible, potasio

asimilable, y contenidos de materia orgánica. La clase **5** involucra a los suelos franco-arcillosos con los niveles más bajos de potasio asimilable, magnesio disponible y contenidos de materia orgánica, pero con las mayores proporciones de materiales granulométricos gruesos (arena).

La aplicación del algoritmo FKCN también generó los valores de grados de pertenencia de cada celda (píxel) a cada una de las clases de fertilidad del suelo. La clasificación produjo vectores de valores de membresía para cada celda del modelo correspondiente a cada clase de fertilidad. 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 *raster* expresados en la Figura 7.



Figura 7. Mapas de fertilidad del suelo.

La combinación de los modelos de distribución espacial de los valores de membresía produjo el mapa integrado de cinco clases de fertilidad del suelo (Figura 8). Para producir este mapa el algoritmo FKCN convirtió las clases neuro-difusas en unidades discretas, por lo que cada celda del modelo fue asignada a la clase con el valor más alto de membresía. El modelo final corroboró la distribución de las clases de fertilidad de los suelos, donde los patrones de variación espacial permitieron discriminar la dominancia de clases texturales con variaciones de reacción del suelo y disponibilidad de elementos primarios y secundarios en los sectores Este-Oeste. El modelo final también permitió visualizar la expresión de los límites definidos por las clases de fertilidad dominantes en la capa superficial de los suelos. Estos límites facilitan la toma de decisiones para el manejo de suelos y para el desarrollo de parcelas productivas.



Figura 8. Modelo de distribución de clases de fertilidad del suelo del Campo de Producción “Agronomía”.

En cuanto a la superficie de las unidades de suelo: la clase 1 ocupa el 26,8% del sector evaluado, la clase 2 ocupa una superficie de 25,2%, la clase 3 representan el 23,4 de la zona estudiada, la clase 4 corresponde al 12,7% de la zona de estudio, y la clase 5 se corresponde con el 11,9% del campo de producción en consideración.

Evaluación de la capacidad predictiva del modelo digital de clases de fertilidad del suelo

Los resultados sobre la valoración de la capacidad predictiva de las clases de suelo con estadísticos multivariados se señalan en el Cuadro 5.

Cuadro 5. Resultados de la clasificación (%) basada en los tamaños de las clases de fertilidad de suelo neuro-difusas.

Clase	Grupo de pertenencia pronosticado ^a				
	1	2	3	4	5
1	100,0	0,0	0,0	0,0	0,0
2	5,6	83,3	11,1	0,0	0,0
3	0,0	6,7	93,3	0,0	0,0
4	12,5	12,5	0,0	75,0	0,0
5	0,0	44,4	0,0	0,0	55,6

^b Clasificados correctamente el 85,7% de los casos agrupados validados mediante validación cruzada.

El cálculo de la precisión del modelo, arrojó valores equivalentes al 86%, con una incertidumbre inferior al 15%. Es decir, el proceso de validación del modelo de clases de fertilidad del suelo indicó que el 86% de los casos fueron clasificados correctamente mediante validación cruzada, con base en la relación de puntos de referencia correctos (60) y el total de puntos verdaderos (70). El mayor grado de incertidumbre está dado por las clases 5 y 2, donde algunos sitios de la clase 5 fueron clasificados como parte de la clase 2, cuyas confusiones ocurren debido a que existen inclusiones vecinas, tal como se visualiza en el modelo final (Figura 8). Los resultados de la validación del enfoque FKCN demostraron que es una alternativa para la generación de clases de fertilidad del suelo. Estos resultados son ligeramente superiores a los obtenidos por Zhu *et al.* (2008), McKay *et al.* (2010) y, Valera y Orta (2018), cuyas investigaciones expresaron una confiabilidad de 76, 73,7 y 80,1% respectivamente para los mapas de suelo obtenidos.

CONCLUSIONES

Los mapas de las variables analizadas demostraron que existen cambios graduales del suelo con respecto a todos los atributos, los cuales presentaron dependencia espacial, que puede afectar la confiabilidad de las evaluaciones con fines de

investigación o producción.

El área evaluada no es internamente homogénea, debido posiblemente a la influencia del manejo de suelo y las prácticas agronómicas realizadas en la zona. Esta variabilidad hay que tenerla presente para evitar un efecto diferencial en los cultivos.

El establecimiento de parcelas productivas no debe ser superior al rango de dependencia espacial de los atributos de fertilidad, cuya moda es de 59 m, para incluir la variabilidad de los suelos evaluados. Por ello, la superficie el establecimiento de parcelas productivas que garanticen la homogeneidad de la estructura interna de los suelos no debe ser superior a 1,0 ha para así permitir la representatividad de la misma.

La evaluación del modelo digital neuro-difuso indicó que la predicción espacial de clases de fertilidad de suelo se corresponde con lo esperado en el sector estudiado, ya que la confiabilidad fue equivalente al 86%.

La información aportada mediante el análisis espacial de las propiedades individuales del suelo y el mapa de clases de fertilidad neuro-difusas es complementaria, y puede ser utilizada como base para el manejo del recurso suelo en la zona.

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).

REFERENCIAS

- Bezdek J.C., R. Ehrlich, Full. W. 1984. FCM: the fuzzy c-means clustering algorithm. *Computers and Geosciences*. 10: 191-203.
- Bezdek, J.C., E.C. Tsao, Pal, N.R. 1992. Fuzzy Kohonen Clustering Networks, in *Proc. IEEE Int. Conf. on Fuzzy Systems 1992* (San Diego), pp. 1035-1043.
- Burrough, P. 1986. *Principles of geographical information systems land resources assessment*. Clarendon Press Oxford. 193 p.
- Burrough, P.A., P.F.M. Van Gaans, MacMillan, R.A. 2000. High-resolution landform classification using fuzzy k-means. *Fuzzy Sets and Systems* 113: 37–52.
- Grunwald, S., R.L. Rivero, Ramesh, K. 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.
- Kohonen, T. 1982. Analysis of a simple self-organizing process. *Biological Cybernetics* 44: 135-140.
- Lin, C., Lee, C. 1996. *Neural fuzzy systems*. Prentice Hall, Inc. New Jersey, USA. 797 p.
- Marchetti, A.; C. Piccini, R. Francaviglia, S. Santucci, Chiuchiarelli, I. 2010. Estimating Soil Organic Matter Content by Regression Kriging. *In: Digital Soil Mapping. Bridging Research, Environmental Application, and Operation*. (Ed. A.B. McBratney and A.E. Hartemig). Chapter 20. New York. 241 p. ISBN 978-90-481-8862-8.

- McKay, J., Grunwald, S., Shi, X., Long, R.F. 2010. Evaluation of the transferability of a knowledge-based soil-landscape model. In: Boettinger J., D.W. Howell, A.C. Moore, A.E. Hartemink, & S. Kienast-Brown (eds.). Digital Soil Mapping: Bridging Research, Production and Environmental Applications. pp. 165-177. Springer, Heidelberg.
- 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. 56: 505- 516.
- Ovalles, F. 1992. Metodología para determinar la superficie representada por muestras tomadas con fines de fertilidad. FONAIAP-CENIAP-IIAG. Maracay. Serie B. 44 p.
- Padua, S., T. Chattopadhyay, S. Bandyopadhyay, S. Ramchandran, R.K. Jena, P. Ray, P. Deb Roy, U. Baruah, K D. Sah, S.K. Singh and S. K. Ray. 2018. A simplified soil nutrient information system: study from the North East Region of India. Current Science, 114 (6): 1241-1249.
- Rey, J.C., G. Martínez, E. Micale, N. Fernández, E. Namias, M.A. Polanco, Valera, A. 2015. Mapeo de suelos por medio de lógica difusa y su relación con el rendimiento de banano (musa AAA). XXII Congreso Venezolano de la Ciencia del Suelo. San Cristóbal, Táchira. Venezuela. 6 p.
- Sevilla, V. 2014. Comparación de dos métodos de cartografía digital con un estudio agrológico convencional en la Cuenca del Rio Canoabo, Estado Carabobo. Trabajo de Ascenso para optar a la Categoría de Asistente. Universidad Central de Venezuela. Caracas, Venezuela. 117 p.
- Shashikumar, B.N., Kumar, S., George, K.J. Kumar Singh, A. 2022. Soil variability mapping and delineation of site-specific management zones using fuzzy clustering analysis in a Mid-Himalayan Watershed, India. Environ Dev Sustain. <https://doi.org/10.1007/s10668-022-02411-6>
- Srinivasan, R., Shashikumar, B.N., Singh, S.K. 2022. Mapping of Soil Nutrient Variability and Delineating Site-Specific Management Zones Using Fuzzy Clustering Analysis in Eastern Coastal Region, India. Journal of the Indian Society of Remote Sensing. <https://doi.org/10.1007/s12524-021-01473-9>
- Tukey, J. 1977. Exploratory Data Analysis. Addison-Wesley Pub. Reading, EUA.
- Upchurch, D., Edmonds, W.J. 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.
- Valera A.R., M. Orta F. 2018. Aplicación de técnicas geoestadísticas y redes neuronales artificiales en la delimitación de clases de fertilidad de suelos. UNERG Agrocientífica 1 (1): 1-19
- Valera, A. 2012. Tecnologías de Inteligencia Artificial: Redes neuronales artificiales y teoría de conjuntos difusos 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. 2018. Geomorfometría y Edafometría. Cartografía Digital de Paisajes y Suelos con Técnicas de Inteligencia Artificial. Editorial Académica Española. Mauritius. ISBN:

978-620-2-12102-6. 317p.

- Valera, A., J.A. Vilorio; Vilorio, Á. 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.
- Valera, A., Vilorio, J.A. 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.
- Viloria J.A, A. Viloria-Botello, M.C. Pineda, Valera, A. 2016. Digital modelling of landscape and soil in a mountainous region: A neuro-fuzzy approach. *Geomorphology* Vol. 253:199-207.
- 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.
- Viloria, A., Núñez, H., J. Viloria (2012). Sistema Clasificador del Terreno por *Fuzzy Kohonen*. Versión 1.0. UCV. Facultad de Ciencias. Escuela de Computación. Centro de Ingeniería de Software y Sistemas. Laboratorio de Inteligencia Artificial. Caracas, Venezuela.
- Viloria, J.A., M.C. Pineda, A. Viloria-Botello, Y. Núñez, Valera, A. 2012. Predicción de pedregosidad superficial del suelo con redes neuro-difusas 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.
- Webster, R., Oliver, M.A. 1990. *Statistical Methods in Soil and Land Resource Survey*. Oxford University Press. Oxford, RU. 316p.
- Zhu, A. X., Yang, L., Li, B., Qin, C., English, E., Burt, J.E., Zhou, C. 2008. Purposive Sampling for Digital Soil Mapping for Areas with Limited Data. In: Hartemink, A.E.; Mendonça-Santos, M. L., A.B. McBratney, A. B., eds, *Digital Soil Mapping with Limited Data*, Springer-Verlag: New York, pp 233-245.