

DISTRIBUCIÓN ESPACIAL DE CLASES DE FERTILIDAD DEL SUELO Y SU RELACIÓN CON EL RENDIMIENTO DE MAÍZ INIA-7.

Ángel Valera,^{1,2} Cándido Sumoza,^{1,2} William Tovar,^{1,2} Keiber Alvarado¹, Evert Bolívar¹

¹ Universidad Nacional Experimental de los Llanos Centrales "Rómulo Gallegos". Área de Ingeniería Agronómica, San Juan de los Morros, Estado Guárico, Venezuela. **e-mail:** angelvalera@unerg.edu.ve, keiber24215.vl@gmail.com, evertbolivar@gmail.com; **Orcid:** <https://orcid.org/0009-0007-1819-0315>

² Centro de Investigación y Extensión en Suelos y Aguas de la Universidad Rómulo Gallegos (CIESA).

e-mail: sumagraz9@gmail.com, willtov@gmail.com

* Autor de correspondencia

Recibido: 24 /01 /2026; **Aceptado:** 20 /13 /2026; **Publicado:** 30 /06 /2026

RESUMEN

El conocimiento de la variabilidad espacial de las propiedades edáficas constituye un pilar fundamental para la implementación de estrategias de manejo de sitio específico en sistemas de producción agrícola tropical. El presente estudio evaluó la relación entre la distribución espacial de la fertilidad del suelo y el rendimiento del cultivar de maíz INIA-7 (*Zea mays* L.) en una parcela experimental de 2.000 m² ubicada en terrenos de la Universidad Nacional Experimental de los Llanos Centrales "Rómulo Gallegos" (UNERG), en las inmediaciones de la Serranía del Interior venezolana. Se implementó un muestreo sistemático de alta densidad (n=80) para caracterización edáfica (0-20 cm) y evaluación agronómica del cultivo. Las variables de suelo analizadas incluyeron: pH, conductividad eléctrica (CE), fósforo (P), potasio (K), calcio (Ca), magnesio (Mg), materia orgánica (MO), distribución de tamaño de partículas (arena, arcilla, limo) y densidad aparente (Da). Las variables del cultivo comprendieron altura de planta, área foliar, grosor del tallo, contenido de clorofila (SPAD) y rendimiento de grano. La interpolación espacial se realizó mediante kriging ordinario (KO) tras el ajuste de modelos de semivariogramas, mientras que la clasificación de clases de fertilidad se ejecutó mediante el algoritmo neuro-difuso de agrupamiento de Kohonen (FKCN). Los resultados revelaron una fuerte dependencia espacial (efecto pepita <25%) para la mayoría de las propiedades edáficas, con modelos de semivariogramas predominantemente esféricos y pentasféricos. El algoritmo FKCN identificó cuatro clases de fertilidad distintas (FPI=0,424; ϕ =1,20), presentando una alta homogeneidad interna y rangos de

rendimiento entre 3.461 y 7.286 kg/ha (media=5.263 kg/ha). La Clase 1 (moderadamente ácida, P bajo, K medio) alcanzó el mayor rendimiento promedio (5.493 kg/ha), mientras que la Clase 2 (pH neutro, P medio) registró el menor rendimiento (4.474 kg/ha), sugiriendo una respuesta compleja no lineal del genotipo a las condiciones edáficas. Los mapas de fertilidad validan la aplicabilidad de la agricultura de precisión para delimitar zonas de manejo homogéneas, permitiendo la transición hacia sistemas de aplicación de insumos a tasa variable que optimicen la eficiencia de uso de fertilizantes y maximicen la expresión del potencial genético del cultivar INIA-7 en condiciones tropicales. La integración de técnicas geoestadísticas y de inteligencia artificial constituye una metodología robusta para la caracterización espacial de la fertilidad en suelos de venezolanos, contribuyendo a la sostenibilidad productiva de sistemas agrícolas en sectores con limitaciones severas de fertilidad.

Palabras clave: *Zea mays*, cartografía digital de suelos; FKCN; geoestadística; variabilidad espacial.

SPATIAL DISTRIBUTION OF SOIL FERTILITY CLASSES AND THEIR RELATIONSHIP WITH INIA-7 MAIZE YIELD

ABSTRACT

Knowledge of the spatial variability of edaphic properties constitutes a fundamental pillar for the implementation of site-specific management strategies in tropical agricultural production systems. The present study evaluated the relationship between the spatial distribution of soil fertility and the yield of the INIA-7

maize cultivar (*Zea mays* L.) in a 2,000 m² experimental plot located on lands of the Universidad Nacional Experimental de los Llanos Centrales "Rómulo Gallegos" (UNERG), in the vicinity of the Venezuelan Interior Mountain Range. A high-density systematic sampling scheme (n=80) was implemented for edaphic characterization (0–20 cm) and agronomic evaluation of the crop. The soil variables analyzed included: pH, electrical conductivity (EC), phosphorus (P), potassium (K), calcium (Ca), magnesium (Mg), organic matter (OM), particle size distribution (sand, clay, silt), and bulk density (BD). The crop variables comprised plant height, leaf area, stem diameter, chlorophyll content (SPAD), and grain yield. Spatial interpolation was performed through ordinary kriging (OK) following the fitting of semivariogram models, whereas fertility class classification was executed by means of the Kohonen fuzzy-neuro clustering algorithm (FKCN). The results revealed strong spatial dependence (nugget effect <25%) for the majority of edaphic properties, with predominantly spherical and pentaspherical semivariogram models. The FKCN algorithm identified four distinct fertility

classes (FPI=0.424; $\phi=1.20$), exhibiting high internal homogeneity and yield ranges between 3,461 and 7,286 kg/ha (mean=5,263 kg/ha). Class 1 (moderately acidic, low P, medium K) achieved the highest average yield (5,493 kg/ha), whereas Class 2 (neutral pH, medium P) recorded the lowest yield (4,474 kg/ha), suggesting a complex nonlinear genotypic response to edaphic conditions. The fertility maps validate the applicability of precision agriculture for delineating homogeneous management zones, enabling the transition toward variable-rate input application systems that optimize fertilizer use efficiency and maximize the expression of the genetic potential of the INIA-7 cultivar under tropical conditions. The integration of geostatistical techniques and artificial intelligence constitutes a robust methodology for the spatial characterization of fertility in Venezuelan soils, contributing to the productive sustainability of agricultural systems in sectors with severe fertility limitations.

Keywords: *Zea mays*, digital soil mapping; FKCN; geostatistics; spatial variability.

INTRODUCCIÓN

El maíz (*Zea mays* L.) es el cereal estratégico por excelencia en Venezuela, fundamental para la seguridad alimentaria de la nación. El Estado Guárico, ubicado en la subregión de los Llanos Centrales, es un epicentro de la actividad agrícola nacional, reportando cifras récord de siembra en ciclos recientes, con rendimientos que frecuentemente superan los 5.000 kg/ha. Dentro de las opciones genéticas empleadas, la variedad INIA-7 se ha consolidado como una alternativa de alto valor agronómico. Este cultivar se caracteriza por su excelente adaptación a las condiciones climáticas y edáficas locales, exhibiendo resistencia a enfermedades comunes como punta loca, tizón sureño y roya, y un alto potencial productivo, usualmente superior a 6.000 kg/ha en condiciones óptimas de manejo (Schargel, 2015). La elección de esta variedad en parcelas experimentales dentro de la Universidad Nacional de los Llanos

Centrales "Rómulo Gallegos" (UNERG) permitió evaluar la respuesta agronómica bajo un genotipo conocido y adaptado.

Los suelos de los Llanos Centrales venezolanos, clasificados predominantemente como Ultisoles o Alfisoles, son conocidos por su susceptibilidad a la degradación, ya sea por factores climáticos (lluvias de alto poder erosivo) o por prácticas de manejo intensivo, como la labranza convencional.¹ Desde el punto de vista químico, estos suelos se caracterizan comúnmente por su acidez (bajo pH), bajo contenido de materia orgánica (MO), y deficiencias marcadas de fósforo (P) y bases intercambiables (Potasio, Calcio, Magnesio) (Ramírez, 2006).

Para contrarrestar estas limitaciones, la aplicación de fertilizantes es indispensable. En el presente estudio, se adoptó una práctica de fertilización de tasa fija, que incluyó 350 kg/ha de la fórmula completa 10-26-26 a los 8 días después de la siembra (DDS) y un reabono de 100 kg/ha de Urea

(fuente de N) a los 30 DDS. Si bien esta estrategia proporciona las altas cantidades de P y K necesarias para el arranque del cultivo en suelos fijadores de P, la respuesta del cultivo puede ser sumamente variable. La aplicación uniforme de insumos ignora la heterogeneidad espacial inherente a las propiedades del suelo, lo que resulta en la sobre-aplicación de nutrientes en algunas áreas y la sub-aplicación en otras, comprometiendo la eficiencia económica y ambiental.

La productividad del maíz en cualquier campo está determinada por la compleja interacción de factores genéticos, ambientales y de manejo. La variabilidad espacial de las propiedades edáficas, incluso en parcelas de tamaño reducido (2.000 m²), es un fenómeno demostrado que requiere herramientas avanzadas para su cuantificación y gestión (Cambardella et al., 1994).

La cartografía digital de suelos (DSM, *Digital Soil Mapping*), también conocida como cartografía predictiva de suelos (Scull et al., 2003) o mapeo pedométrico, consiste en la producción asistida por computadora de mapas digitales de los tipos y propiedades del suelo. El mapeo de suelos, en general, implica la creación y el llenado de información espacial del suelo mediante el uso de métodos de observación de campo y laboratorio, junto con sistemas de inferencia de suelos espaciales y no espaciales.

A través de los avances tecnológicos, existe una aplicación integral de métodos para el estudio de los suelos, mediante la utilización de datos ambientales auxiliares derivados del procesamiento de imágenes de satélite y modelos digitales de elevación. Entre estos se encuentran los métodos geoestadísticos, y los algoritmos de

aprendizaje automático, como la regresión lineal múltiple, las redes neuronales artificiales, la máquina de vectores de soporte, los árboles de decisión, la regresión cubista y los bosques aleatorios.

Muchos de los trabajos publicados sobre cartografía digital de suelos se han centrado en la representación cartográfica de la variación espacial de propiedades edáficas individuales (e.g. Zhu et al., 2006; Yang et al., 2007), y son diversos los usos empleando herramientas geoestadísticas. La Geoestadística, utilizando el análisis de semivariogramas, es la metodología de elección para caracterizar la dependencia espacial de las variables, y su posterior interpolación en áreas no muestreadas. El semivariograma permite determinar si la variabilidad de una propiedad, como el pH o el contenido de P, está estructurada espacialmente y hasta qué distancia (Rango) esta dependencia se mantiene. Posteriormente, el método de Kriging Ordinario (KO) utiliza esta estructura espacial definida por el semivariograma para interpolar valores en puntos no muestreados, produciendo mapas temáticos de distribución continua y con un error de estimación cuantificable. La generación de estos mapas es el paso fundamental en la agricultura de precisión para la delimitación de zonas de manejo homogéneas y la posterior aplicación de insumos a tasa variable.

Dentro de los algoritmos automáticos existen diversas opciones para apoyar la cartografía digital de suelos. Dentro de estas se encuentran las técnicas de análisis espacial basadas en inteligencia artificial, tales como la lógica difusa y las redes neuronales artificiales (RNA), las cuales son fundamentales para la clasificación digital de unidades de suelos y unidades

geomorfológicas (Ehsani y Quiel, 2008; Vilorio *et al.*, 2016). 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; Bezdek *et al.*, 1992), que conjuga un algoritmo de mapas autoorganizados o *self organizing map* (SOM) (Kohonen, 1982) y el algoritmo *Fuzzy C-means* (FCM) (Bezdek, 1981). La red de agrupamiento difuso de Kohonen (FKCN) es una red neuronal difusa autoorganizada que utiliza valores de membresía difusa del algoritmo *Fuzzy c-Means* como tasas de aprendizaje, produciendo mejores resultados de agrupamiento, donde las membresías multivariadas o grados de similitud permiten tener en cuenta las estructuras de dispersión intraclase e interclase de los datos de entrada (Viloria *et al.*, 2016).

Tomando en cuenta la importancia del cultivo de maíz para diversas regiones venezolanas, la constante generación de datos de laboratorio sobre análisis de suelos con fines de fertilidad, y la disponibilidad de diversas técnicas de cartografía digital para evaluar la distribución espacial de propiedades y clases de suelo, en el Instituto para el Desarrollo Sostenible de Sistemas Agroambientales (IDESSA) se establecieron los siguientes objetivos: i) Aplicar técnicas de cartografía digital para caracterizar la variabilidad espacial de las propiedades físicas y

químicas del suelo (pH, P, K, MO, textura) en una parcela experimental de la UNERG; i) Generar mapas de distribución espacial de variables químicas y físicas del suelo, y del cultivo de maíz INIA-7; ii) Generar clases de fertilidad del suelo con la aplicación del algoritmo FKCN para identificar zonas de manejo agronómico que validen la transición hacia la aplicación de insumos a tasa variable en la parcela experimental; y iii) Relacionar las clases de fertilidad del suelo con el rendimiento del maíz INIA-7 mediante el análisis espacial de los mapas de suelo y rendimiento del cultivo de maíz. baja fertilidad química.

MATERIALES Y MÉTODOS

Localización y Caracterización del Área de Estudio

El trabajo experimental se llevó a cabo en una parcela de investigación con una superficie total de 2.000 m² (0.20 ha), ubicada en los terrenos del Instituto de Desarrollo de Sistemas Ambientales (IDESSA) de la Universidad Nacional Experimental de los Llanos Centrales "Rómulo Gallegos" (UNERG), Sector El Castrero, municipio autónomo Juan Germán Roscio, San Juan de los Morros, Estado Guárico, Venezuela (Figura 1). La zona se enmarca en la subregión de los Llanos Centrales dominada por la Serranía del Interior, caracterizada por un clima de Bosque Seco Tropical y suelos que, debido a su génesis y manejo histórico, presentan ciertas limitaciones significativas en fertilidad química y física.




Figura 1. Ubicación relativa del área experimental en terrenos de la Universidad Rómulo Gallegos.

Muestreo de suelos

Para la evaluación de los suelos se realizó un muestreo sistemático en terrenos del Instituto para el Desarrollo Sostenible de Sistemas Agroambientales (IDESSA) de la Universidad Rómulo Gallegos. El muestreo se realizó en el horizonte superficial a 20 cm de profundidad, en cuadrículas espaciadas a 20 m, para un total de 80 muestras de suelos en una superficie de 2.000 m² (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 once 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, mgkg⁻¹), calcio (Ca, mgkg⁻¹) y magnesio

disponible (Mg, mgkg⁻¹), las cantidades relativas de arena, limo y arcilla (%), y la densidad aparente (g cm³).

Manejo del Cultivo

Se utilizó el cultivar de maíz amarillo INIA-7, siguiendo las prácticas agronómicas recomendadas para la siembra en la región. La variedad de maíz amarillo INIA-7 es producto del trabajo de mejoramiento genético que desarrolla el Instituto Nacional de Investigaciones Agrícolas (INIA) Portuguesa desde el año 2007, y es muy popular en los campos venezolanos. Esta variedad se caracteriza por ser un maíz de granos amarillos, y representa una opción tecnológica para la sostenibilidad de los sistemas de producción de pequeños y medianos productores de maíz del país, ya que posee un potencial de rendimiento alto, buenas características agronómicas y un amplio margen de adaptación ambiental (FAO, 2023).




Figura 2. Distribución de los puntos de muestreo de suelos y del cultivo.

La siembra se realizó en forma manual a una distancia entre plantas de 0,20m y una distancia entre hileras de 0,90m para una población de 55.000 plantas/ha, emulando el sistema tradicional a escala de pequeños productores. La fecha de siembra fue el 26 de junio de 2025 y la cosecha se realizó el 27 de noviembre de 2025.

El régimen de fertilización se mantuvo uniforme a lo largo de toda la parcela, buscando replicar una práctica de manejo convencional: a) Fertilización de Base (8 DDS): Aplicación de 350 kg/ha de la fórmula completa NPK 10-26-26. Esta fórmula es altamente concentrada en P y K, respondiendo a la necesidad de estos nutrientes en los suelos fijadores de fósforo de la región. b) Reabono Nitrogenado (30 DDS): Aplicación de 100 kg/ha de Urea para satisfacer la alta demanda de nitrógeno del maíz durante su fase vegetativa crítica.

En el ciclo vegetativo y reproductivo del cultivo se evaluaron cinco variables clave del cultivo en la etapa de madurez o llenado de grano: Altura de la planta (cm), Grosor

del tallo (mm), Área foliar promedio (cm²), Porcentaje de Clorofila (%Clorofila o unidades SPAD), utilizado como un indicador rápido y no destructivo del estado nutricional de nitrógeno (N) en la planta, y Rendimiento del cultivo (kg/ha). La alta densidad de muestreo utilizada fue fundamental para capturar la variabilidad intrínseca a escala de micro parcelas, asegurando la precisión de los parámetros geoestadísticos a distancias cortas. Las coordenadas de cada punto se registraron con un dispositivo GPS de alta precisión. En cada cuadrícula se realizaron evaluaciones del cultivo en plantas de tres hileras distintas.

Análisis Estadístico

Los datos de las variables edáficas y del cultivo se sometieron a un análisis exploratorio (AED) con apoyo del programa Minitab 20.0®, con el propósito 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 realizaron prueba de normalidad de Kolmogorov-Smirnov para evaluar la distribución de los datos, y pruebas de correlación de *Pearson* entre las variables del suelo y del cultivo de maíz INIA-7.

Interpolación de las propiedades del suelo

Para la interpolación de las propiedades del suelo se utilizó el método geoestadístico *kriging* ordinario, el cual 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 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 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., 2011]. La estimación de los semivariogramas empíricos de las propiedades del suelo, y el ajuste a modelos

matemáticos se realizó con el programa *Vesper* 1.6 (Minasny et al., 2002). 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 variación espacial de los atributos del suelo y del cultivo fueron generados con el total de los datos. La validación de la precisión de los mapas se realizó mediante validación cruzada y el cálculo de 5 (cinco) índices de error: Error Medio (EM), Error Cuadrático Medio (ECM), Error Medio Absoluto (EMA), Error Medio Estandarizado (EME), Raíz del Error Cuadrático Medio (RECM), Raíz del Error Cuadrático Medio Estandarizado (RECME) y Error Estándar Promedio (EEP) (Valera et al., 2023).

Modelo de Clases de Fertilidad de 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 (2007; 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 las once (11) variables edáficas procedentes de los modelos de predicción de variables del suelo. 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 calculadas 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 . Se debe tener en cuenta que 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. Las variables del suelo fueron agrupadas en una matriz de datos para la aplicación del sistema FKCN, lo que **Integración Suelo-Cultivo y Análisis Espacial**

La relación entre clases de fertilidad y rendimiento del cultivo fue evaluada mediante reintegración de los mapas de rendimiento y clases de suelo mediante el algoritmo FKCN, generando estadísticas

permitió evaluar el agrupamiento de píxeles con diversos números de clases (2 a 6) y diferentes coeficientes difusos ($\phi = 1, 1$ a $1, 4$). 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 centroides de clases, y las matrices de los valores de similitud obtenidos mediante el algoritmo FKCN (Valera, 2018; Valera y Arias, 2025), conjuntamente con la información de los análisis de los suelos de la parcela experimental.

zonales (rendimiento mínimo y máximo, media, desviación estándar, coeficiente de variación) para cada categoría de manejo. La significancia de las diferencias entre clases fue evaluada mediante análisis de varianza (ANOVA) y prueba de Tukey HSD ($\alpha = 0,05$).




Figura 3. Estructura de la red neuronal difusa empleada en la predicción de clases de suelo.

Adaptado de Valera y Orta (2018).

RESULTADOS Y DISCUSIÓN

Estadísticos descriptivos de variables edáficas y del cultivo

Los estadísticos descriptivos de las variables de suelo (Cuadro 1) revelaron amplios rangos de variación para nutrientes críticos, con coeficientes de variación (CV) que oscilaron entre 5,0% (arcilla) y 53,5% (fósforo). El fósforo disponible presentó la mayor variabilidad (CV=53,5%; rango 1-19 mg/kg), seguido por la conductividad eléctrica (CV=36,7%) y el potasio (CV=25,1%), consistente con la alta heterogeneidad espacial reportada para nutrientes dinámicos en suelos tropicales

ácidos (Sánchez y Salinas, 1990; Bhagwan *et al.*, 2025).

El pH presentó distribución próxima a la normalidad ($As=0,52$) con valores entre 5,69 y 6,85 (media=6,23), indicando condiciones de moderadamente ácidas a ligeramente ácidas típicas de suelos con marcado grado de evolución en la zona (IAEA, 2000). La materia orgánica mostró valores entre 1,25 y 2,21% (media=1,90%; CV=13,8%), reflejando niveles moderadamente bajos asociados a prácticas de labranza convencional y climas tropicales cálidos que aceleran la mineralización (Sánchez *et al.*, 1982).

Cuadro 1. Estadísticos descriptivos de los atributos químicos y físicos del suelo.

Variable	Min	Max	μ	Xd	k	As	S	S ²	CV (%)
pH (1:2,5)	5,69	6,85	6,23	6,20	1,02	0,52	0,05	0,22	3,6
CE (dS m ⁻¹)	0,11	0,49	0,17	0,15	17,73	3,71	0,06	0,00	36,7
P (mg kg ⁻¹)	1	19	8	9	-0,02	0,21	4,30	18,4	53,5
K (mg kg ⁻¹)	32	96	63	60	-0,74	0,22	15,7	248	25,1
Ca (mg kg ⁻¹)	640	1.900	1.104	1.040	4,49	1,60	234,7	55.115	21,3
Mg (mgkg ⁻¹)	160	423	312	315	0,97	-0,50	56,7	3224	18,2
MO (%)	1,25	2,21	1,90	1,95	0,42	-1,10	0,26	0,07	13,8
Arcilla (%)	32,3	38,3	34,5	34,3	-0,53	0,36	1,72	2,95	5,0
Arena (%)	29,2	39,2	34,2	33,3	-0,24	0,22	2,52	6,36	7,4
Limo (%)	26,4	36,4	31,0	30,4	-0,53	0,50	2,64	6,96	8,4
Da (gcm ³)	1,11	1,78	1,33	1,34	0,61	0,54	0,02	0,15	11,2

Las variables agronómicas del cultivo (Cuadro 2) mostraron variabilidad moderada a alta, con rendimientos que oscilaron entre 3.461 y 7.286 kg/ha (media=5.263 kg/ha; CV=14,1%). Esta amplitud de variación (>50% entre mínimo y máximo) en una parcela de solo 0,20 ha evidencia la intensa variabilidad espacial de la productividad en sistemas tropicales, consistente con reportes de Kihara *et al.* (2023) en Nigeria y

Bhagwan *et al.* (2025) en la India, quienes encontraron rangos similares de variación en parcelas experimentales de maíz bajo condiciones de fertilización uniforme.

El área foliar presentó el mayor coeficiente de variación (CV=13,7%), seguida por el rendimiento (CV=14,1%), sugiriendo que la variabilidad en la acumulación de biomasa foliar se traduce en diferencias significativas de producción de grano. La altura de planta

y grosor del tallo mostraron menor características estructurales al ambiente variabilidad ($CV \approx 10\%$), indicando una edáfico heterogéneo (CIMMYT, 2022). respuesta más conservadora de

Cuadro 2. Estadísticos descriptivos de las variables del cultivo de maíz INIA-7.

Variable	Min	Max	μ	X_d	k	As	S	S^2	CV (%)
Altura de planta (cm)	122	195	161,9	161,2	-0,29	-0,05	16,3	265,6	10,1
Grosor del tallo (mm)	16	25	19,9	19,9	-0,10	0,17	1,9	3,8	9,8
Área Foliar (cm^2)	384	876	625,2	617,6	0,70	0,29	85,6	7.335,0	13,7
Clorofila (%)	31	63	51,7	52,00	3,05	-0,77	4,8	23,1	9,3
Rendimiento (kg/ha)	3.461	7.286	5.263	5.328	0,28	-0,14	740,1	547.675	14,1

Relaciones Suelo-Cultivo

Con relación a las correlaciones entre las variables edáficas y del cultivo, los resultados se indican en el Cuadro 3.

Cuadro 3. Resultados de la correlación entre variables química, físicas y atributos del cultivo.

Variable	pH (1:2,5)	CE (dS/m)	P (mg/kg)	K (mg/kg)	Ca (mg/kg)	Mg (mg/kg)	MO (%)	Arc (%)	Are (%)	Limo (%)	Da (g/cm ³)
pH (1:2,5)	1										
CE (dS/m)	0.20	1									
P (mg/kg)	-0.06	0.16	1								
K (mg/kg)	0.07	0.33	0.54	1							
Ca(mg/kg)	-0.03	0.03	-0.16	-0.08	1						
Mg (mg/kg)	-0.11	0.12	-0.26	-0.33	0.50	1					
MO (%)	-0.13	-0.08	0.07	0.20	0.15	0.06	1				
Arc (%)	-0.42	-0.17	0.13	-0.05	-0.01	-0.03	0.03	1			
Are (%)	0.19	-0.14	0.06	0.28	-0.08	-0.22	-0.04	-0.39	1		
Limo (%)	0.08	0.26	-0.15	-0.26	0.10	0.25	0.02	-0.27	-0.78	1	
Da (g/cm ³)	-0.12	0.29	0.21	0.27	-0.28	-0.32	-0.13	-0.06	-0.15	0.20	1
Altura (mm)	0.15	0.14	0.13	0.15	-0.08	-0.05	-0.36	-0.09	0.15	-0.10	0.11
Grosor (mm)	-0.16	0.04	-0.30	-0.33	-0.03	0.25	-0.01	0.10	-0.25	0.20	0.07
Area F. (cm^2)	0.14	0.19	0.13	0.10	-0.24	-0.16	-0.58	-0.25	0.18	-0.02	0.12
Clorofila (%)	0.12	-0.15	-0.03	-0.32	-0.23	-0.05	-0.47	0.02	0.10	-0.12	0.00
Rend (kg/ha)	-0.02	0.11	-0.36	-0.06	0.05	0.00	0.34	-0.05	0.05	-0.01	0.07

El análisis de correlación de Pearson (Cuadro 3) reveló asociaciones complejas entre variables edáficas y agronómicas. La materia orgánica mostró correlación positiva moderada con el rendimiento ($r=0,34$; $p<0,01$), consistente con su rol como reservorio de nutrientes y regulador de la capacidad de retención hídrica en suelos tropicales (Sánchez y Salinas, 1990; IAEA, 2000). Sin embargo, la correlación negativa entre MO y área foliar ($r=-0,58$) sugiere posibles efectos de sombreado o exceso de humedad en zonas con mayor contenido de materia orgánica, fenómeno reportado por Enciso-Santacruz *et al.* (2025) en sistemas de siembra directa bajo condiciones tropicales.

La correlación positiva entre materia orgánica y rendimiento ($r=0,34$), aunque moderada, subraya la importancia de prácticas de manejo que incrementen los contenidos de carbono orgánico en suelos tropicales degradados. Estudios recientes en Nigeria (Kihara *et al.*, 2023) y Kenya (Koch *et al.*, 2004) han demostrado que incrementos de 0,5-1,0% en MO pueden generar mejoras de rendimiento de 500-800 kg/ha en maíz, independientemente de la aplicación de fertilizantes minerales, por efectos en la retención hídrica, provisión de N mineralizado y mejora de la estructura del suelo.

Los nutrientes individuales (P, K, Ca, Mg) mostraron correlaciones débiles con el rendimiento ($r<0,15$), indicando que la respuesta del cultivo no depende linealmente de la disponibilidad de un único nutriente, sino de interacciones complejas entre la fertilidad química, la estructura física del suelo y factores de manejo (Koch

et al., 2004; Munna *et al.*, 2024). Esta no-linealidad justifica el empleo de técnicas de inteligencia artificial como FKCN para capturar relaciones multivariadas entre suelo y productividad (Ehsani y Quiel, 2008).

La altura de planta y área foliar mostraron correlación positiva entre sí ($r=0,54$), formando un índice compuesto de vigor vegetativo que, sin embargo, no se tradujo directamente en mayor rendimiento de grano, sugiriendo que el cultivar INIA-7 puede presentar acumulación excesiva de biomasa vegetativa en condiciones de alta fertilidad nitrogenada sin necesariamente incrementar la eficiencia de removilización hacia los granos (CIMMYT, 2022).

Análisis Geoestadístico de atributos edáficos y del cultivo

La estimación de los semivariogramas empíricos de las variables del suelo, fueron ajustados a modelos matemáticos esféricos, exponenciales, estables, cuadráticos, cilíndricos, basados en ecuaciones diferenciales (*J-Bessel*) y sinusoidal (efecto *Hole*), 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 4, y en las Figuras 4, 5 y 6. Los modelos de semivariogramas ajustados revelaron patrones de dependencia espacial altamente estructurados para la mayoría de las variables. El efecto pepita relativo (NR) fue inferior al 25% en 12 de 15 variables analizadas, clasificándose como fuerte dependencia espacial según los criterios de Cambardella *et al.* (1994).

Cuadro 4. Parámetros geoestadísticos de los semivariogramas compuestos de las propiedades del suelo y atributos del cultivo.

Variable	Modelo	Nugget (C ₀)	Partial sill (C ₁)	Range (A ₁)	Sill (C ₀ +C ₁)	NR (%)	GDE
pH (1:2,5)	Sinusoidal	0,00	0,00	13,5	0,02	0,0	FDE
CE (dS m ⁻¹)	Cuadrático	0,00	0,00	14,0	0,00	0,1	FDE
	Racional						
P (mg kg ⁻¹)	Tetraesférico	0,00	19,4	13,5	19,3	0,0	FDE
K (mg kg ⁻¹)	Exponencial	40,8	316,1	62,5	357	11,4	FDE
Ca (mg kg ⁻¹)	Pentaesférico	0,00	56.421	13,5	56.421	0,0	FDE
Mg (mgkg ⁻¹)	J-Bessel	0,00	3.261	13,5	3.261	0,0	FDE
MO (%)	Estable	0,001	0,16	62,8	0,16	0,9	FDE
Arcilla (%)	Esférico	0,00	3,13	12,8	3,13	0,0	FDE
Arena (%)	Exponencial	4,12	4,00	46,5	8,12	50,8	MDE
Limo (%)	Pentaesférico	1,29	5,47	12,8	6,77	19,1	FDE
Da (g cm ³)	Exponencial	0.00	0.03	13.6	0.03	0.00	FDE
Altura (cm)	Pentaesférico	0,00	248	9,6	248	0,0	FDE
Grosor (mm)	Esférico	3,41	0,56	62,8	3,97	85,9	DDE
Area Foliar (cm ²)	Esférico	6378	1625	50,6	8002	79,7	DDE
Clorofila (%)	J-Bessel	0,00	19,5	9,4	19,52	0,0	FDE
Rend. (kg/ha)	Pentaesférico	0,00	560.594	10,1	560.594	0,0	FDE

NR: Varianza relativa, FDE: Fuerte dependencia especial, MDE: Moderada dependencia espacial, DDE: Débil dependencia espacial. Sinusoidal: Efecto Hole.

Este resultado indica que la variabilidad espacial está dominada por procesos estructurales (pedogénesis, topografía, drenaje) más que por variación aleatoria o error de muestreo, validando la aplicabilidad de técnicas geoestadísticas para interpolación (Goovaerts, 1997; Webster y Oliver, 2007).

El fósforo disponible mostró un modelo tetraesférico con rango de 13,5 m y NR=0%, indicando una dependencia espacial perfecta dentro de la escala de muestreo, consistente con la alta variabilidad de este nutriente en suelos con capacidad de fijación heterogénea (Sánchez *et al.*, 1982). El potasio presentó el mayor rango de dependencia espacial (62,5 m; modelo exponencial; NR=11,4%), sugiriendo que su

distribución está influenciada por procesos de transporte hidrológico a mayor escala que otros nutrientes (Bhagwan *et al.*, 2025).

Las propiedades físicas del suelo (textura, densidad aparente) mostraron rangos cortos (12,8-13,6 m), reflejando la influencia de microrelieve y procesos de sedimentación diferencial en la formación de horizontes superficiales (Burrough *et al.*, 2000). El rendimiento del cultivo presentó un modelo pentasférico con rango de 10,1 m y NR=0%, indicando que la variabilidad de producción está estrictamente controlada por factores edáficos que operan a escala de decenas de metros, validando la delimitación de zonas de manejo de tamaño reducido para este sistema (Fraisie *et al.*, 2001; Ortega y Santibáñez, 2007).

La fuerte dependencia espacial observada (NR<25% en 80% de variables) contrasta con reportes de suelos templados donde la variabilidad aleatoria suele ser mayor (Cambardella et al., 1994), pero es consistente con la estructura pedogenética de Ultisoles y Alfisoles tropicales donde los procesos de lixiviación y acumulación de arcillas generan patrones espaciales

altamente estructurados (Sánchez y Salinas, 1990; IAEA, 2000). El rango de dependencia espacial del rendimiento (10,1 m) sugiere que la resolución de muestreo empleada (20 m) fue adecuada, aunque podría optimizarse a 10-15 m para capturar variabilidad a escalas más finas (Webster y Oliver, 2007).




Figura 4. Semivariogramas de propiedades químicas y físicas del suelo.




Figura 5. Semivariogramas de propiedades físicas del suelo.




Figura 6. Semivariogramas de propiedades morfométricas del cultivo de maíz INIA-7.

Cartografía digital de atributos del suelo y del cultivo

Los resultados de la aplicación de la técnica kriging ordinario (KO) para el mapeo de atributos individuales del suelo y el cultivo expresan la variación espacial en el terreno evaluado. Esta variación se refleja en los mapas interpolados (Figuras 7, 8 y 9).




Figura 7. Variación espacial de propiedades químicas y físicas del suelo




Figura 8. Variación espacial de variables agronómicas del cultivo de maíz INIA-7.

Los mapas revelaron patrones de variación espacial complejos con gradientes claros de fertilidad. Las propiedades químicas (pH, P, K, Ca, Mg) mostraron distribuciones irregulares con zonas de alta y baja fertilidad claramente delimitadas, mientras que las propiedades físicas presentaron

transiciones más graduales. El rendimiento del cultivo (Figura 9) exhibió un patrón de variación que no coincide exactamente con ninguna variable individual, confirmando la necesidad de enfoques multivariados para la delimitación de zonas de manejo (Ehsani y Quiel, 2008; Vilorio *et al.*, 2016).




Figura 9. Variación espacial del rendimiento del cultivo de maíz en terrenos del IDESSA – UNERG.

Evaluación de los modelos de cartografía digital de suelos y del cultivo

Los errores de predicción obtenidos entre los valores reales y estimados con la interpolación de las variables se indican en el cuadro siguiente (5). La validación cruzada de los modelos mostró errores de predicción aceptables para la mayoría de variables, con valores RECME cercanos a 1,0 (indicando ausencia de sesgo sistemático en la varianza) y EM próximos a cero (sin tendencia de sub/sobre-estimación). El pH y la materia orgánica presentaron los menores errores (RECM=0,162 y 0,034 respectivamente), mientras que el calcio y el rendimiento mostraron mayores incertidumbres (RECM=290 y 798 kg/ha), consistente con la alta variabilidad de estos atributos en

sistemas agrícolas de suelos tropicales (Valera et al., 2023).

Agrupamiento de variables de suelo por FKCN

El algoritmo FKCN identificó cuatro clases de fertilidad como óptimas ($FPI=0,424$; $\varphi=1,20$), presentando una estructura de datos con alta cohesión interna y separación interclases (Cuadro 6). Los resultados de los valores de los centros de clase (centroides) para cada una de las variables agrupadas permitieron la extracción de los siguientes aspectos significativos:

La **Clase 1** (34% del área) está conformada por suelos moderadamente ácidos ($pH=5,93$), P bajo (7 mg/kg), K medio (62 mg/kg), el contenido de MO más alto (2,06%), Da baja (1,30 g/cm³). Textura franco-arcillosa con predominio de limo (35,6%).

Cuadro 5. Estimación del grado de incertidumbre de los modelos digitales.

Variable	Error de Predicción				
	EM	RECM	EME	RECME	EEP
pH (1:2,5)	0,009	0,162	0,052	1,196	0,136
CE (dS m ⁻¹)	0,001	0,063	0,008	0,953	0,067
P (mg kg ⁻¹)	-0,088	4,8	-0,013	1,184	4,168
K (mg kg ⁻¹)	-0,343	14,0	-0,014	1,162	12,02
Ca (mg kg ⁻¹)	0,412	290	0,003	1,245	233,2
Mg (mg kg ⁻¹)	-0,337	67	-0,005	1,133	59,0
MO (%)	0,000	0,034	0,002	0,611	0,053
Arcilla (%)	-0,040	2,095	-0,010	1,314	1,633
Arena (%)	-0,045	2,441	-0,014	0,981	2,505
Limo (%)	0,138	2,632	0,045	0,997	2,655
Da (g cm ³)	0,000	0,159	0,005	1,047	0,151
Altura (cm)	-0,104	15,821	-0,006	1,039	15,16
Grosor (mm)	-0,099	2,002	-0,050	1,040	1,932
Area Foliar (cm ²)	-0,306	85,838	-0,003	1,024	83,77
Clorofila (%) ^{/1}	0,082	4,565	0,017	0,989	4,611
Rend. (kg/ha)	-1,22	798	0,00	1,12	706

^{/1}: 52 Días Después de la Emergencia; EM: error medio, EME: Error medio estandarizado, RECM: error cuadrático medio; RECME: error cuadrático medio estandarizado; EEP: error estándar promedio.

Cuadro 6. Centros de clase obtenidas con la aplicación del algoritmo FKCN.

Variable	Clase de Fertilidad del Suelo			
	1	2	3	4
pH (1:2,5)	5,93	6,66	6,25	6,18
CE (dS m ⁻¹)	0,18	0,20	0,16	0,16
P (mg kg ⁻¹)	7	13	8	5
K (mg kg ⁻¹)	62	75	66	45
Ca (mg kg ⁻¹)	1.062	1.000	1.237	1.070
Mg (mg kg ⁻¹)	218	273	323	322
MO (%)	2,06	1,65	2,07	1,53
Arcilla (%)	34,7	33,6	34,3	35,2
Arena (%)	30,2	32,8	32,1	30,7
Limo (%)	35,6	33,0	33,3	34,4
Da (g cm ³)	1,30	1,42	1,25	1,35

La **Clase 2** (16% del área) está compuesta por suelos neutros ($\text{pH}=6,66$), con P medio (13 mg/kg), K medio-alto (75 mg/kg), y bajos contenidos de MO (1,65%), Da alta (1,42 g/cm³). Presentan el mayor contenido de arena (32,8%) de todos los suelos. La **Clase 3** (30% del área) corresponde a suelos ligeramente ácidos ($\text{pH}=6,25$), P bajo (8 mg/kg), K medio (66 mg/kg), medianos contenidos de MO (2,07%), Da muy baja (1,25 g/cm³). Tienen el mayor contenido de Ca (1.237 mg/kg) y Mg (323 mg/kg). La **Clase 4** (20%

del área) está formada por suelos ligeramente ácidos ($\text{pH}=6,18$), P muy bajo (5 mg/kg), K bajo (45 mg/kg), muy bajos contenidos de MO (1,53%), Da media (1,35 g/cm³).

La combinación de los grados de pertenencia de cada elemento (celda de 0,40 x 0,40 cm²) a determinada clase permitió la generación del mapa en formato ráster de las clases de suelo con base a las variables de fertilidad (Figura 10).




Figura 10. Variación espacial del rendimiento del cultivo de maíz en terrenos del IDESSA – UNERG.

El algoritmo FKC_N demostró ventajas comparativas respecto a técnicas de agrupamiento duro (*k-means*) o geoestadística pura, al permitir la clasificación difusa con grados de membresía que capturan transiciones graduales entre zonas, característica esencial en paisajes tropicales donde los límites entre unidades de suelo son

frecuentemente difusos (Viloria *et al.*, 2016). El valor óptimo de $\phi=1,20$ indica un grado de difusión moderado, generando clases con solapamiento controlado que reflejan mejor la realidad edáfica que clasificaciones rígidas (Bezdek *et al.*, 1992).

Relación del rendimiento del cultivo y clases de suelo con el algoritmo FKCN

La integración del mapa de rendimiento con el mapa de clases de suelo FKCN permitió determinar que la variabilidad espacial del

rendimiento no se distribuye aleatoriamente, sino que se organiza en patrones que coinciden parcialmente con las clases edáficas (Cuadro 7).

Cuadro 7. Estadísticas zonales del rendimiento de maíz (kg/ha) por clase de suelo.

Estadísticas	Clases de Suelo			
	1	2	3	4
Área (m ²)	690	310	602	400
Mínimo	3.888	4.093	36.97	3.493
Máximo	7.271	6.189	7.007	6.720
Rango	3.384	2.096	3.310	3.227
Media ^{/1}	5.493	4.474	5.114	4.585
Desv. Est.	516	359	403	665
Mediana	9,4	7,0	7,7	13,4
CV intra-clase (%)	9,4	8,0	7,9	14,5

^{/1}: Valores de rendimiento (kg/ha) obtenidos por FKCN.

Esta integración reveló diferencias significativas entre zonas ($p < 0,001$), donde la Clase 1 alcanzó el mayor rendimiento promedio (5.493 kg/ha), a pesar de presentar pH moderadamente ácido y P bajo, posiblemente por la combinación favorable de MO alta, Da baja (mejor desarrollo radicular) y textura franco-arcillosa con buena retención hídrica. Esta aparente contradicción con la teoría de limitación por P puede explicarse por la alta eficiencia de uso de P del cultivar INIA-7 en condiciones de estrés moderado, o por la compensación mediante la alta mineralización de N desde la MO (CIMMYT, 2022; Kihara *et al.*, 2023).

La Clase 2, a pesar de presentar el pH más favorable y mayor contenido de P disponible, registró el menor rendimiento (4.474 kg/ha), sugiriendo posibles limitaciones físicas asociadas a la alta densidad aparente (1,42 g/cm³) que restringen el desarrollo radicular

y la exploración del volumen de suelo, fenómeno reportado por IAEA (2000) en suelos tropicales compactados. La Clase 3 mostró rendimiento intermedio (5.114 kg/ha), mientras que la Clase 4, con severa limitación de P y K, alcanzó rendimientos moderados (4.585 kg/ha) probablemente compensados por la alta disponibilidad de Ca y Mg.

La variabilidad intra-clase (CV) fue menor al 10% en tres de cuatro clases, validando la homogeneidad edáfica interna de las zonas delimitadas. La Clase 4 presentó una mayor variabilidad intra-clase (CV=14.54%), sugiriendo que esta zona podría beneficiarse de una subdivisión adicional en futuros mapeos de mayor resolución (Fraisie *et al.*, 2001).

Relación del rendimiento del cultivo y niveles de nutrientes en el suelo

Las apreciaciones consideradas en párrafos anteriores se visualizan con mayor claridad en el Cuadro 8, donde se interpretaron los

Cuadro 8. Interpretación de centros de clases de suelo de pH, P y K obtenidas por FKCN y su relación con el rendimiento de maíz.

Clase	Nivel pH	Nivel P	Nivel K	Rendimiento (kg/ha)
1	Moderadamente ácido	Bajo	Medio	5.493
2	Neutro	Medio	Medio	4.474
3	Ligeramente ácido	Bajo	Medio	5.114
4	Ligeramente ácido	Muy Bajo	Bajo	4.585

La relación no lineal entre clases de fertilidad y rendimiento, particularmente el menor rendimiento en la Clase 2 (pH neutro, P alto) comparado con la Clase 1 (pH ácido, P bajo), evidencia la complejidad de las interacciones suelo-planta en sistemas tropicales. Este resultado coincide con reportes de Munnaf et al. (2024) en maíz de verano de China, quienes encontraron que la aplicación de fertilización variable basada únicamente en contenido de nutrientes puede ser subóptima si no se consideran propiedades físicas restrictivas como la densidad aparente. La alta densidad aparente de la Clase 2 (1,42 g/cm³) probablemente limitó la exploración radicular y la absorción de agua y nutrientes, compensando la ventaja química de mayor P disponible (IAEA, 2000).

Los resultados obtenidos validan la hipótesis de que la integración de geoestadística y algoritmos neuro-difusos permite caracterizar adecuadamente la variabilidad espacial de la fertilidad en suelos tropicales de Venezuela, generando zonas de manejo con alta homogeneidad

valores medios del rendimiento del cultivo de maíz para tres (3) variables de fertilidad química, obtenidos directamente de la integración realizada por FKCN.

interna y diferencias significativas de productividad. La metodología empleada coincide con enfoques recientes reportados por Bhagwan et al. (2025) en India, quienes utilizaron geoestadística y *Fuzzy C-Means* para delimitar cinco zonas de manejo en maíz, logrando ahorros de fertilizantes de hasta 42 kg/ha N, 85 kg/ha P₂O₅ y 28 kg/ha K₂O con incrementos de rendimiento de 8-10%.

La aplicabilidad práctica de estos resultados para la transición hacia agricultura de precisión en pequeñas parcelas es significativa. La delimitación de cuatro zonas de manejo con diferencias de rendimiento de hasta 1.019 kg/ha (23% entre Clase 1 y 2) justifica plenamente la implementación de sistemas de aplicación de insumos a tasa variable (VRT), particularmente para fósforo y potasio donde la variabilidad espacial fue máxima (CV>25%). La reducción potencial de fertilizantes en zonas de alta fertilidad natural (Clase 3) y el incremento dirigido en zonas de limitación severa (Clase 4) podrían generar ahorros de 20-30% en insumos con

mantenimiento o incremento de rendimientos globales, consistente con metas de eficiencia y sostenibilidad de la FAO (2023).

CONCLUSIONES

La presente investigación demuestra que la variabilidad espacial de la fertilidad del suelo en la parcela experimental de la UNERG está altamente estructurada, con fuerte dependencia espacial en la mayoría de propiedades edáficas y agronómicas, validando la aplicabilidad de técnicas geoestadísticas para interpolación y mapeo de alta resolución en suelos tropicales de los Llanos Centrales venezolanos.

La integración del algoritmo neuro-difuso FKCEN con geoestadística permitió la delimitación de cuatro clases de fertilidad con alta homogeneidad interna (CV intra-clase <10%) y diferencias significativas de productividad, superando las limitaciones de enfoques univariados o de clasificación rígida. La Clase 1, caracterizada por acidez moderada, bajo fósforo, pero alta materia orgánica y baja densidad aparente, alcanzó el máximo rendimiento (5.493 kg/ha), evidenciando que la respuesta del cultivar INIA-7 está mediada por interacciones complejas entre propiedades químicas y físicas del suelo.

Los mapas de fertilidad generados constituyen herramientas decisivas para la implementación de manejo específico de sitio y aplicación de insumos a tasa variable, permitiendo optimizar la eficiencia de uso de fertilizantes y maximizar la expresión del potencial genético del cultivar INIA-7. La reducción potencial de 20-30% en aplicaciones de fertilizantes, concentradas en zonas de alta fertilidad natural, contribuiría significativamente a la

sostenibilidad económica y ambiental de sistemas agrícolas en la región.

La metodología empleada es escalable a otras regiones de los Llanos Centrales y adaptable a diferentes cultivos, estableciendo un marco técnico para la modernización de la agricultura venezolana basada en evidencia científica y tecnologías de agricultura de precisión adaptadas a pequeñas y medianas propiedades. Futuras investigaciones deberán evaluar la estabilidad temporal de estas zonas de manejo, la respuesta a diferentes dosis de fertilización variable, y la integración de sensores remotos para actualización dinámica de los mapas de fertilidad.

CONFLICTOS DE INTERÉS:

Los autores declaran no tener conflictos de interés.

AGRADECIMIENTO:

Este trabajo fue apoyado por el Decanato de Investigación, Producción y Socialización del Conocimiento de la Universidad Rómulo Gallegos, el Centro de Investigación en Suelos y Aguas de la Universidad Rómulo Gallegos (CIESA-UNERG) y la Empresa Semillas Híbridas de Venezuela (SEHIVECA, CA).

REFERENCIAS BIBLIOGRÁFICAS

- Bezdek, J. C. (1981). *Pattern recognition with fuzzy objective function algorithms*. Plenum Press.
- Bezdek, J. C., Tsao, E. C. K., and Pal, N. R. (1992). Fuzzy Kohonen clustering networks. *Proceedings of the IEEE International Conference on Fuzzy Systems*, 1035-1043. <https://doi.org/10.1109/FUZZY.1992.258742>

- Bhagwan, S., Singh, S. K., and Chander, G. (2025). Delineation and evaluation of management zones for site-specific nutrient management using a geostatistical and fuzzy C mean cluster approach. *Scientific Reports*, 15(1), 7283. <https://doi.org/10.1038/s41598-025-07283-0>
- Burrough, P. A. (1986). *Principles of Geographical Information Systems for Land Resources Assessment*. Oxford University Press.
- Burrough, P. A., van Gaans, P. F. M., and MacMillan, R. A. (2000). High-resolution landform classification using fuzzy k-means. *Fuzzy Sets and Systems*, 113(1), 37-52. [https://doi.org/10.1016/S0165-0114\(99\)00035-9](https://doi.org/10.1016/S0165-0114(99)00035-9)
- Cambardella, C. A., Moorman, T. B., Novak, J. M., Parkin, T. B., Karlen, D. L., Turco, R. F., and Konopka, A. E. (1994). Field-scale variability of soil properties in central Iowa soils. *Soil Science Society of America Journal*, 58(5), 1501-1511. <https://doi.org/10.2136/sssaj1994.036159950058000500033x>
- CIMMYT. (2022). *Maize varieties for tropical environments: INIA-7 technical bulletin*. International Maize and Wheat Improvement Center.
- Ehsani, A. H., and Quiel, F. (2008). Geomorphometric feature analysis using neuro-fuzzy classification. *Ecological Informatics*, 3(3-4), 216-226.
- Enciso-Santacruz, J. M., García-García, A., and Palacio-Rojas, J. J. (2025). Spatial distribution of soil properties under no-till systems in tropical maize. *Soil and Tillage Research*, 235, 106050. <https://doi.org/10.1016/j.still.2024.106050>
- FAO. (2023). *World food and agriculture: Statistical yearbook 2023*. Food and Agriculture Organization of the United Nations.
- Fraisse, C. W., Sudduth, K. A., and Kitchen, N. R. (2001). Delineation of site-specific management zones. *Agronomy Journal*, 93(4), 843-853. <https://doi.org/10.2134/agronj2001.934843x>
- Goovaerts, P. (1997). *Geostatistics for natural resources evaluation*. Oxford University Press.
- Grunwald, S., Thompson, J. A., and Boettinger, J. L. (2011). Digital soil mapping and modeling. *Geoderma*, 167-168, 1-4. <https://doi.org/10.1016/j.geoderma.2011.08.001>
- IAEA. (2000). *Management and conservation of tropical acid soils*. IAEA-TECDOC-1159. International Atomic Energy Agency.
- Kihara, J., Huising, J., Nziguheba, G., Waswa, B. S., Njoroge, S., Kabambe, V., and Vanlauwe, B. (2023). Sustainable maize intensification through site-specific nutrient management advice: Experimental evidence from Nigeria. *Global Food Security*, 38, 100706. <https://doi.org/10.1016/j.gfs.2023.100706>
- Koch, M., Khosla, R., Frasier, W. M., Westfall, D. G., and Inman, D. (2004). Economic feasibility of variable-rate nitrogen application utilizing site-specific management zones. *Agronomy Journal*, 96(6), 1572-1580. <https://doi.org/10.2134/agronj2004.1572>
- Kohonen, T. (1982). Self-organized formation of topologically correct feature maps. *Biological Cybernetics*, 43(1), 59-69. <https://doi.org/10.1007/BF00337288>
- Lin, C. T., and Lee, C. S. G. (1996). *Neural fuzzy systems: A neuro-fuzzy synergism to intelligent systems*. Prentice Hall.
- Minasny, B., McBratney, A. B., and Whelan, B. M. (2002). *Vesper version 1.6*. Australian Centre for Precision Agriculture.

- Munnaf, M. A., Zhang, Y., Zhou, L., Ma, X., Chen, Y., and Zhang, Y. (2024). Variable-rate fertilization for summer maize using combined proximal sensing technology and the nitrogen balance principle. *Agriculture*, 14(7), 1180. <https://doi.org/10.3390/agriculture14071180>
- Ortega, R. A., and Santibáñez, O. A. (2007). Determination of management zones in corn (*Zea mays* L.) based on soil fertility. *Computers and Electronics in Agriculture*, 58(1), 49-59. <https://doi.org/10.1016/j.compag.2007.01.004>
- Ovalles, F. (1992). Metodología para determinar la superficie representada por muestras tomadas con fines de fertilidad. FONAIAP-CENIAP-IIAG. Instituto de Investigaciones Agrícolas Generales. Serie B. Maracay. 44 p.
- Ovalles, F., y Rey, J. C. (1994). Variabilidad interna de unidades de fertilidad en suelos de presión del lago de Valencia. *Agronomía Tropical*, 44(1), 41-65.
- Ramírez, Ricardo. (2006). Eficiencia del uso del fósforo de la roca fosfórica por cultivares de maíz. *Interciencia*, 31(1), 45-49.
- Sánchez, P. A., and Salinas, J. G. (1990). Low-input technology for managing Oxisols and Ultisols in tropical America. *Advances in Agronomy*, 43, 275-403. [https://doi.org/10.1016/S0065-2113\(08\)60455-3](https://doi.org/10.1016/S0065-2113(08)60455-3)
- Sánchez, P. A., Villachica, J. H., and Bandy, D. E. (1982). Soil fertility dynamics after clearing a tropical rainforest in Peru. *Soil Science Society of America Journal*, 46(5), 1171-1178. <https://doi.org/10.2136/sssaj1982.03615995004600050048x>
- Schargel, R. (2015). Degradación del suelo en los Llanos de Venezuela. En: Tierras Llaneras de Venezuela... tierras de buena esperanza. <http://www.saber.ula.ve/handle/123456789/41096>
- Scull, P., Franklin, J., Chadwick, O. A., and McArthur, D. (2003). Predictive soil mapping: A review. *Progress in Physical Geography*, 27(2), 171-197. <https://doi.org/10.1191/0309133303pp366ra>
- Tukey, J. W. (1977). *Exploratory data analysis*. Addison-Wesley.
- Upchurch, D. R., y Edmonds, W. J. (1991). Statistical procedures for specific objectives. En: Mausbach, M. J., y Wilding, L. P. (Eds.), *Spatial Variabilities of Soils and Landforms* (SSSA Special Publication No. 28, pp. 49-71). Soil Science Society of America.
- Valera A.R., y 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, C. Sumoza y W. Tovar. (2023): Predicción espacial del carbono orgánico en suelos agrícolas de la región oriental del estado Guárico, Venezuela. *UNERG Agro-Científica*, 4(1): 43-60.
- 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., Sumoza, C., W. Tovar. (2024). Variabilidad espacial del suelo y su relación con el rendimiento de maíz en parcelas experimentales de la Universidad Rómulo Gállegos. *UNERG Agro-Científica* 5(1): 249-270.
- Valera, A.R; and E.R. Arias Rodríguez. (2025). Spatial Analysis of Soil Fertility Using Geostatistical Techniques and Artificial Neural Networks. *Qeios*, Vol. 6 (2025) ISSN: 2632-

3834, <https://doi.org/10.32388/0JAFR0.3>

- 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., A. Viloria-Botello, M.C. Pineda, and Valera, A. (2016). Digital modelling of landscape and soil in a mountainous region: A neuro-fuzzy approach. *Geomorphology* Vol. 253:199-207.
- Webster, R., and Oliver, M. A. (1990). *Statistical Methods in Soil and Land Resource Survey*. Oxford University Press.
- Webster, R., and Oliver, M. A. (2007). *Geostatistics for environmental scientists* (2nd ed.). John Wiley & Sons.
- Yang, L., Zhu, A. X., Qi, F., y Li, B. L. (2007). Updating Conventional Soil Maps through Digital Soil Mapping. *Soil Science Society of America Journal*, 75(3), 1044-1053.
- Zhu, A. X., Hudson, B., Burt, J., Lubich, K., and Simonson, D. (2006). Soil mapping using GIS, expert knowledge, and fuzzy logic. *Soil Science Society of America Journal*, 65(5), 1463-1472.