

# PROPIEDADES QUÍMICAS DE MO, FE Y CIC DEL SUELO MEDIANTE INTELIGENCIA ARTIFICIAL Y ANÁLISIS DE IMÁGENES

## CHEMICAL PROPERTIES OF MO, FE AND CIC OF THE SOIL THROUGH ARTIFICIAL INTELLIGENCE AND IMAGE ANALYSIS

Landeta-Escamilla, O.<sup>1</sup>; Sandoval-González, O.O.<sup>1</sup>; Martínez-Sibaja A.<sup>1\*</sup>; Posada-Gómez R.<sup>1</sup>; Alvarado-Lassman, A.<sup>1</sup>; Quevedo-Garay, F.<sup>1</sup>; Herrera-Aguilar, I.<sup>1</sup>; Flores-Cuautle, J.J.A.

Tecnológico Nacional de México - Instituto Tecnológico de Orizaba, Av. Oriente 9 No 852, Col. Emiliano Zapata, Orizaba, Veracruz, México. C.P. 94320.

\*Autor de correspondencia: amartinez@ito-depi.edu.mx

### RESUMEN

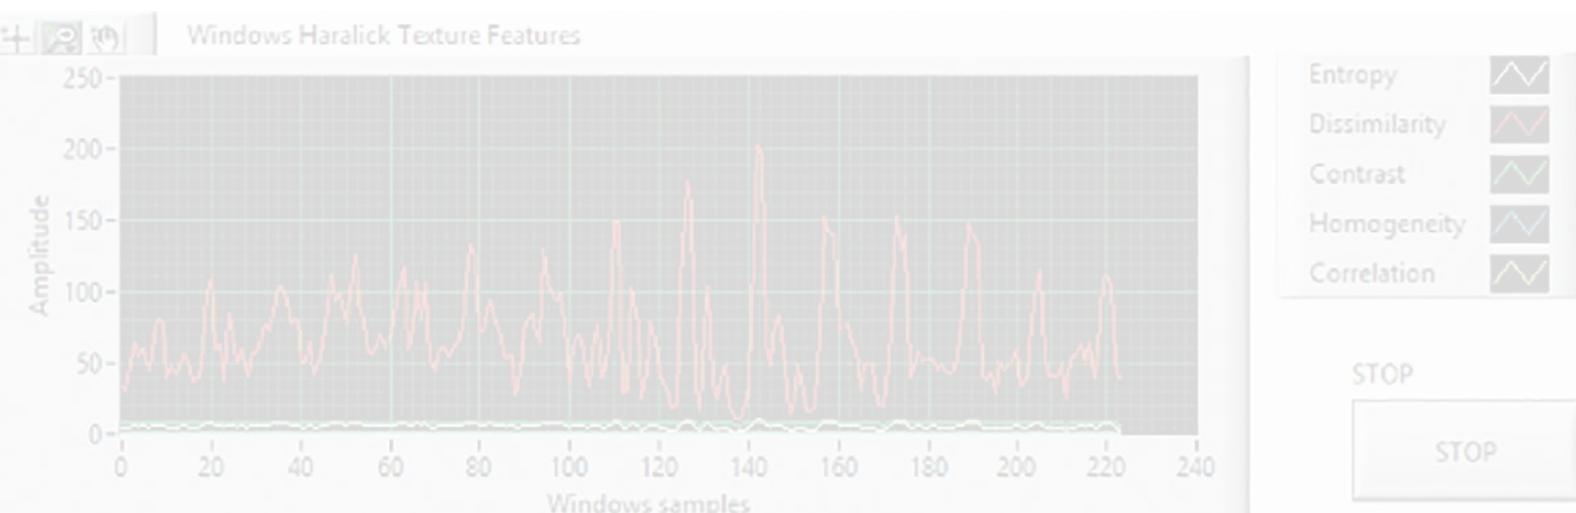
Se presenta el desarrollo de un sistema capaz de estimar la materia orgánica, hierro y capacidad de intercambio catiónico del suelo, a través del uso de Redes Neuronales Artificiales (RNA) y Análisis de Componentes Principales (ACP). Las variables empleadas para realizar análisis fueron: textura, histograma de color HSL y RGB de las imágenes, las cuales fueron correlacionadas con las propiedades obtenidas en los análisis de laboratorio convencionales.

**Palabras claves:** textura, color propiedades químicas, microelementos.

### ABSTRACT

The development of a system capable of estimating the organic matter, iron and capacity for cationic exchange of the soil, through the use of Artificial Neural Network (ANN) and principal component analysis (PCA), is presented. The variables used to perform the analysis were texture, HSL color histogram and RGB of the images, which were correlated with the properties obtained in conventional lab analyses.

**Keywords:** texture, chemical color properties, microelements.



**Agroproductividad:** Vol. 10, Núm. 10, octubre, 2017, pp: 54-61.

**Recibido:** julio, 2017. **Aceptado:** octubre, 2017.

## INTRODUCCIÓN

La evaluación de los suelos es de gran interés, debido a que es el medio para obtener alimentos y juega un papel importante en el desarrollo de los agroecosistemas. Existen numerosas metodologías para evaluar sus propiedades; sin embargo, el uso de imágenes para tal fin ha ido incrementándose debido a que es una metodología eficiente, reduce tiempo y costos, y ha resultado ser un alternativa en la clasificación de la superficie del suelo (Luscier *et al.*, 2006; Han *et al.*, 2016), estimación del índice de superficie de hojas en ecosistemas (McBratney *et al.*, 2003), identificar zonas erosionadas (Trueba-Espinosa *et al.*, 2004), propiedades mecánicas de productos de horticultura (Mollazade *et al.*, 2013), clasificación de alimentos (Golzarian y Frick, 2011), reconocimiento de hierba ajena a la producción (Li y Ji, 2008), determinación de la humedad (Zanetti *et al.*, 2015), determinación de microporos (Maragos *et al.*, 2004; Houston *et al.*, 2017) y concentraciones de otros nutrientes, tales como el fósforo (P) (Keshavarzi *et al.*, 2015). El color del suelo ha sido analizado convencionalmente con el uso de las tablas de color de Munsell (DOF, 2002) y está relacionado con las concentraciones de diversos compuestos presentes en él; entre ellos, la materia orgánica (MO), los componentes ferromagnesianos, componentes litológicos y el contenido de humedad (Moritsuka *et al.*, 2014; Porta-Casanellas *et al.*, 2003). Debido a esto se ha evaluado la correlación del color con otras variables fisicoquímicas, como es el caso de Moritsuka *et al.* (2014), quienes utilizando el Colorímetro tri-estimulante SPAD-503 y estadística descriptiva en Microsoft Excel 2010 para Windows correlacionaron matiz, brillo y saturación con carbono total (C), nitrógeno total (N) y hierro activo ( $Fe_0$ ), obteniendo correlaciones negativas entre el brillo (L) y el C ( $R^2=0.7$ ) y el N ( $R^2=0.59$ ) en el grupo de muestras de suelos nacionales y positivas entre el amarillo (b) y  $Fe_0$  de  $R^2=0.59$  para muestras de suelo de un solo sitio de muestreo (Moritsuka *et al.*, 2014). Adicionalmente, se ha buscado estimar el porcentaje de residuos de humus en suelos y poder determinar el grado de degradación de plástico biodegradable y polietileno. Moreno *et al.* (2014) buscaron evaluar los métodos de umbral Otsu, Ridler-Calvard, Entropía local y Umbral manual, utilizando una cámara digital (Canon Power Shot A80-35mm) y la herramienta de procesamiento de imágenes de Matlab R2009a, y obtuvieron resultados confiables al convertir imágenes RGB a HSV y utilizando el histograma del plano de saturación. Los métodos Otsu y Ridler Calvard obtuvieron resultados más precisos para este tipo de evaluación; sin embargo, las conclusiones de las imágenes pueden variar de un observador a otro. Autores como Thompson *et al.* (1992), Marcelino *et al.* (2007) y Baveye *et al.* (2010) han señalado que deben existir parámetros para reducir la variabilidad de las determinaciones. Entre las variables a controlar se encuentran la toma de muestras, el método de secado, la solidificación con resinas y el curado por un número de días previo a la toma de la foto y posterior a ésta: los arreglos de luz, la lente o lentes de la cámara, la configuración de la exposición y apertura de la lente, entre otros aspectos (Baveye *et al.*, 2010). Actualmente se han realizado varias comparaciones entre expertos, concluyendo que existe gran variabilidad en el software utilizado en el pre-tratamiento de la muestra; desde si se utiliza alguno o no, y en el método utilizado para el umbral y el pre-tratamiento de la muestra (Baveye *et al.*, 2010). Se ha buscado sumar a las imágenes otras metodologías para lograr los ob-

jetivos deseados; en este sentido, las redes neuronales (ANN, por sus siglas en inglés) han incrementado sus aplicaciones en los análisis de suelos ya que presentan mejor precisión que los modelos de regresión lineal. Zanetti *et al.* (2015) utilizaron imágenes y ANN para determinar la humedad del suelo con un procedimiento estándar para tomar las fotografías, utilizando una Cámara digital Canon® PowerShot A7 10 IS y resolución 7.1 megapíxeles en un sitio oscuro donde solo hubiera luz del flash de la cámara. Utilizó el modelo RGB y el software imageJ para cortar las imágenes de las muestras representativamente y las ANN fueron entrenadas 100 veces para cada caso evaluado. Los resultados fueron similares a los obtenidos por el método TDR (Third-order Polynomial Equation), donde el mismo modelo para varios tipos de suelos presentó un error de 0.0575 g/g; este mismo entrenado con datos de solo el primer suelo tuvo un error mayor, de 0.0781 g/g mientras que al entrenarlo con los suelos 2 y 3 individualmente, hubo un error de 0.0380g/g y 0.0422g/g, respectivamente, un método estandarizado (Zanetti *et al.*, 2015). Keshavarzi *et al.* (2015) utilizaron las ANN para determinar la concentración de Fósforo (P) con información sobre la correlación de distribución del suelo en los patrones de crecimiento de vegetación, topografía, características de la vegetación mediante imágenes satelitales e información pedológica, reportando una  $R^2$  de 0.68 (Keshavarzi *et al.*, 2015). En otro estudio realizado con el objetivo de hacer clasificación de suelos, utilizando la cámara de un celular Xiaomi2s, un lente D7000 SLR (Single Lens Reflex), un sensor CMOS (23.6 mm×15.6 mm) con 16.2 millones de píxeles efectivos y el rango focal

entre 18 y 105 mm), dio resultados positivos para diez suelos superiores a 90 % en identificación bajo condiciones específicas de intensidad de iluminación y humedad en las muestras; sin embargo, se concluyó que es difícil controlar la luz ambiental y los parámetros del equipo de visión. Por otro lado, se destacó que las diferencias en el hardware del celular podría afectar la precisión de los resultados y la estabilidad del software y la humedad en las muestras puede causar que el color se oscurezca generando resultados diferentes (Han *et al.*, 2016). Otra de las metodologías novedosas para el análisis de suelos es el uso de imágenes digitales aéreas; un ejemplo de este es el estudio realizado por Trueba-Espinosa *et al.* (2004), quienes evaluaron el grado de erosión hídrica mediante el modelo RGB de una imagen y ANN, obteniendo errores de 2.5 % y 7.1 % en el tepetate blanco y vegetación, respectivamente, y errores de sobreestimación para el tepetate amarillo, árboles, vegetación, cárcavas en dos profundidades y pedestales. Emplear esta herramienta en cuantificación de vegetación evita la subjetividad para determinar qué tipo de vegetación se presenta en ecosistemas; en este sentido, Luscier *et al.* (2006) buscó cuantificar zonas de suelos cubiertas con pasto, arbustos, desechos, sin vegetación,

empleando una Kodak DC4800 Zoom Digital Camera (Eastman Kodak Company, Rochester, NY) montada en un palo de golf a 1.5 m de altura, estableciendo la resolución en la cámara en 3.1 megapíxeles y empleando el software e-Cognition. Determinaron la combinación de escala, color y forma y utilizaron el Índice Kappa para estimar la correlación entre segmentos, concluyendo con cuantificaciones de pasto con una desviación hacia la sobre-estimación no mayor a 4 %, y para los arbustos no fue mayor a 3 %, mientras que para los residuos hubo un error no mayor a 4 % en sobre-estimación y 2 % en sub-estimación, de tal modo que el presente estudio tiene el objetivo de estimar concentraciones de compuestos químicos presentes en suelos Vertisoles de la región de las Montañas del estado de Veracruz, México, con producción de caña de azúcar con el uso de ANN e imágenes digitales.

## MATERIALES Y MÉTODOS

El sistema de visión desarrollado consistió en una cámara digital de 21 Mega Píxeles y un sistema controlado de iluminación en donde las muestras se colocan y analizan. Se realizó un programa en LabVIEW para la adquisición de la imagen y su procesamiento digital, el cual consistió en realizar el cálculo matemático del algoritmo de extracción de características de Haralick para el análisis de textura y la obtención del histograma HSL y RGB para el análisis de color de la muestra del suelo. Se utilizó un sensor de humedad controlado por un microcontrolador Arduino Due con un ADC de 12 bits de resolución (Figura 1).

Para el análisis de textura se utilizó una técnica llamada extracción de características de Haralick, la cual mide el contraste, correlación, homogeneidad, energía y entropía. Específicamente, el contraste mide la cantidad de

los cambios localizados en una imagen; la correlación, cómo relacionar un píxel con sus alrededores; la homogeneidad, la similitud entre píxeles. La energía también significa uniformidad y la entropía es una medición de aleatoriedad de la intensidad de una imagen. La Figura 2 muestra el programa que realiza

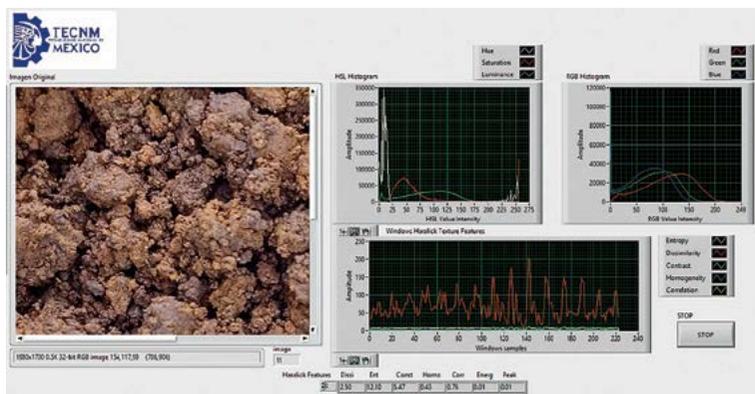
el procesamiento de imágenes de los suelos, el cual obtiene el histograma HSL y RGB y el análisis de textura de Haralick.

## RESULTADOS Y DISCUSIÓN

**Suelos:** Fueron extraídas 105 muestras de suelo de tipo vertisol con cultivo de caña de azúcar (*Saccharum spp.*) en la región de las altas montañas de Veracruz, México. Cada una fue enviada al laboratorio para obtener sus propiedades físico-químicas. Estos análisis son de gran relevancia para poder realizar la correlación de los parámetros obtenidos mediante las técnicas de visión artificial y los resultados de laboratorio. Las Figuras 3 y 4 muestran los resultados de laboratorio de la capacidad de intercambio catiónico y materia orgánica de una sección de las muestras de suelos.

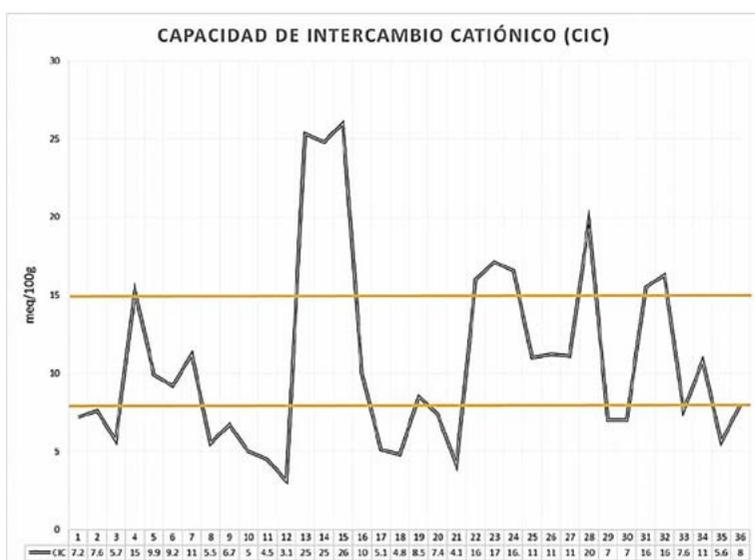


Figura 1. Sistema de adquisición de imágenes.



**Figura 2.** Interface gráfica que realiza el procesamiento de las imágenes de los suelos.

**Textura:** La experimentación consistió en realizar el análisis de color y textura de 105 muestras de suelo de tipo vertisol con cultivos de caña de azúcar. La humedad es un factor importante, por lo cual se controló en cada muestra para que estuvieran en un rango de 45 % a 55 %. Estas fueron depositadas al sistema de análisis para que su imagen fuera adquirida y obtuviera el procesamiento digital de las imágenes. De la Figura 5 a la 12 se muestran diferentes tipos de suelo que fueron analizados con el sistema de visión.



**Figura 3.** Resultados de la Capacidad de Intercambio Cationico (CIC).

En la Figura 13 se observan los resultados de textura obtenidos de las 105 muestras de suelo que fueron analizadas. Estos presentan la entropía, contraste, homogeneidad, correlación y energía de cada una de ellas.

De la Figura 14 a la 17 se muestran por separado las gráficas de las variables de Haralick obtenidas en el análisis de las muestras.

Los datos obtenidos en el laboratorio de las muestras presentaron varianza significativa, por lo cual fue importante realizar este análisis para verificar que los datos obtenidos con el sistema, también tuvieran el mismo tipo de significancia. Se realizó un estudio de análisis de varianza (ANOVA) de los siete parámetros de la extracción de características del suelo de Haralick en las imágenes del estudio de las 105 muestras existentes ( $P \geq 0.01$ ).



**Figura 4.** Resultados de laboratorio de materia orgánica (MO).

**Análisis de Color de Hue**

En las Figuras 18 y 19 se observa el análisis de color de HUE de las muestras de suelo, acorde al mapa de color de HUE. Los rangos de la tonalidad roja (que es en donde se concentran en mayor parte el color de las muestras de suelo) se encuentran en valores de 210 a 240 y de 0 a 50. En las gráficas se puede apreciar que estos son los tonos principales. La Figura 19 muestra el resultado obtenido de 20 imágenes (1-20), correspondientes a igual número de muestras de suelos. Cada color representa un rango en el histograma; por ejemplo, H (10), que es el color azul de gráfica, indica el porcentaje de pixeles en la imagen que se encuentran en un rango de tono de 0-10 del color de Hue.

La Figura 19 presenta el resultado obtenido de 20 imágenes (21-40) correspondientes a 20 diferentes muestras de suelos.

Los datos obtenidos durante el análisis de HUE son relevantes debido a que los diversos rangos de colores que se encuentran concentrados en la imagen pueden conocerse a detalle. Los dominantes son los que definen al suelo y con los cuales se va a realizar la estimación y correlación con los análisis de laboratorio del suelo. Sin embargo, el otro rango nos entrega parámetros importantes, como podría ser el espacio entre rocas.

### Sistema inteligente

Los datos obtenidos del histograma de color y de textura de las muestras de suelo fueron utilizados para realizar el sistema inteligente que sea capaz de correlacionar los datos de entrada del sistema de visión con los obtenidos en el análisis de laboratorio. Una parte fundamental en el diseño de los sistemas inteligentes es brindar al algoritmo de reconocimiento con datos de entrada que tengan variabilidad e importancia. A continuación se describe el vector de entrada con los datos adquiridos por el sistema de visión:

- Visión: 7 datos de las variables de Haralick
- Visión: 25 datos del histograma de color de Hue
- Visión: 75 datos de los histograma de color R,G,B

Como variables de salida se seleccionaron los siguientes datos:

- Mo, Fe, CIC

**Análisis de componentes principales:** En total fueron 107 datos de cada una de las 105 muestras de suelo. Estos datos pertenecen a la matriz que debe generar una correlación con los de los análisis físico-químicos del laboratorio. Utilizar los 107 datos de cada una de las 105 muestras como entrada para entrenar una Red Neuronal Artificial puede derivar en un entrenamiento incorrecto de la red, debido a que muchas de estas variables podrían no tener una relevancia significativa. Por esta razón fue necesario rea-

lizar un pre-procesamiento de estos datos para conocer la varianza y correlación de los mismos con el objetivo de reducir la dimensionalidad del vector de entrada a la red neuronal. Un PCA es una metodología estadística que realiza una transformación lineal a través de la creación de un nuevo sistema de coordenadas para los datos



Figura 5. Muestra 1, Humedad 50 %.



Figura 6. Muestra 10, Humedad 50 %.



Figura 7. Muestra 20, Humedad 50 %.



Figura 8. Muestra 30, Humedad 50 %.



Figura 9. Muestra 40, Humedad 50 %.



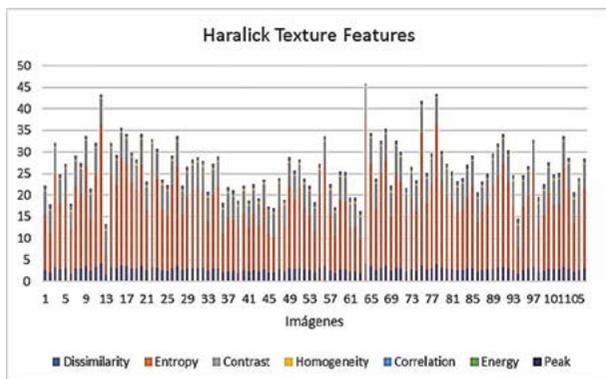
Figura 10. Muestra 50, Humedad 50 %.



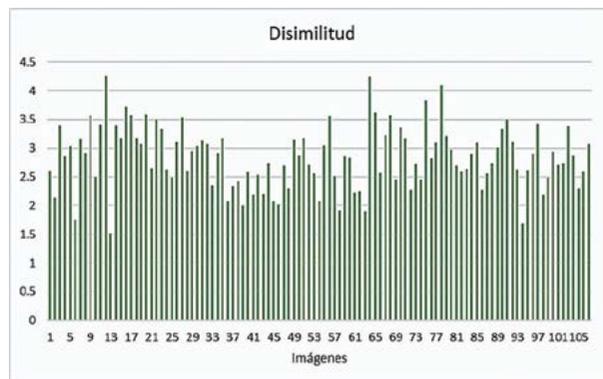
Figura 11. Muestra 80, Humedad 50 %.



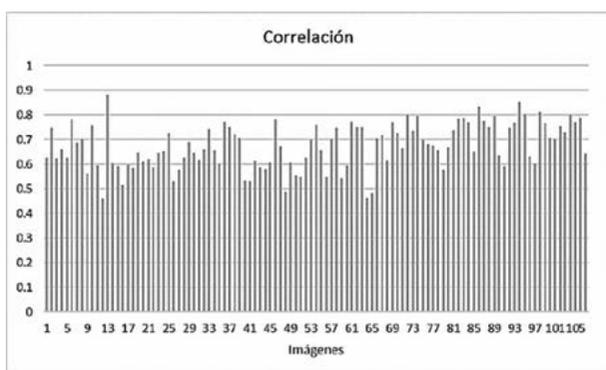
Figura 12. Muestra 100, Humedad 50 %.



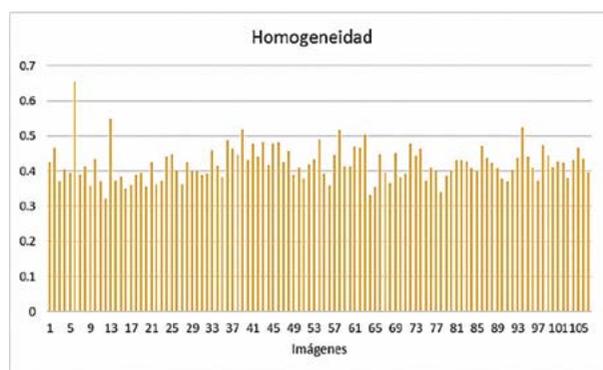
**Figura 13.** Resultados de las características de disimilitud, entropía, contraste, homogeneidad, correlación, energía e intensidad de las 105 imágenes procesadas.



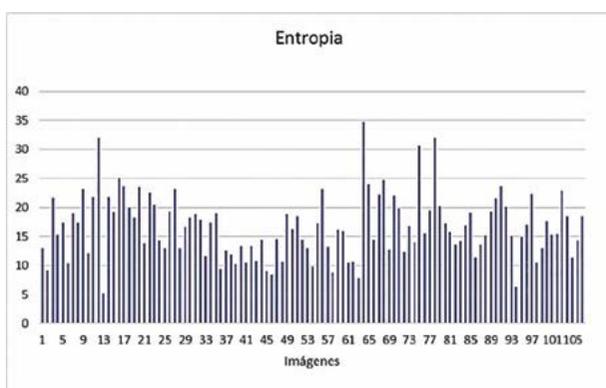
**Figura 14.** Resultados de las características de disimilitud, entropía, contraste, homogeneidad, correlación, energía e intensidad de las 105 imágenes procesadas.



**Figura 15.** Resultado de la característica de correlación de las 105 imágenes procesadas



**Figura 16.** Resultados de la característica de homogeneidad de las 105 imágenes procesadas.



**Figura 17.** Resultado de la característica de Entropía de las 105 imágenes procesadas.

de entrada, en el cual en sus ejes coloca los datos de mayor a menor varianza. Un PCA crea un nuevo sistema en el cual ordena lo datos de más a menos relevantes; con esto se puede lograr reducir la dimensionalidad de los datos. Se realizó la programación utilizando el software Matlab de un PCA mediante los 11235 datos de la matriz de entrada, que corresponde a 107 dimensiones por 105 muestras. Acorde con los resultados del PCA se

seleccionaron los ocho primeros componentes principales, reduciendo el vector de entrada de entrenamiento, utilizado en la red neuronal a ocho dimensiones.

**Entrenamiento de la Red Neuronal Artificial (ANN):** Se modeló una red neuronal con los ocho datos de entrada provenientes de la reducción dimensional obtenida por el PCA y se experimentó con diferentes configuraciones relacionadas al número de capas ocultas y de neuronas en la capa oculta. Esta red neuronal entrega tres salidas como resultado, las cuales son MO, Fe y CIC. Las Figuras 20 y 21 muestran la estructura de la red neuronal compuesta por una capa de entrada y una intermedia de neuronas.

La Figura 22a muestra el comportamiento de una red neuronal, utilizando cinco neuronas en la capa oculta de la red, obteniendo un error de reconocimiento de 4.28 %. La Figura 22b muestra el comportamiento de la red neuronal, utilizando 15 neuronas en la capa oculta, con un error de 1.45 %. Las gráficas muestran el target (la línea azul) que representa el valor de reconocimiento

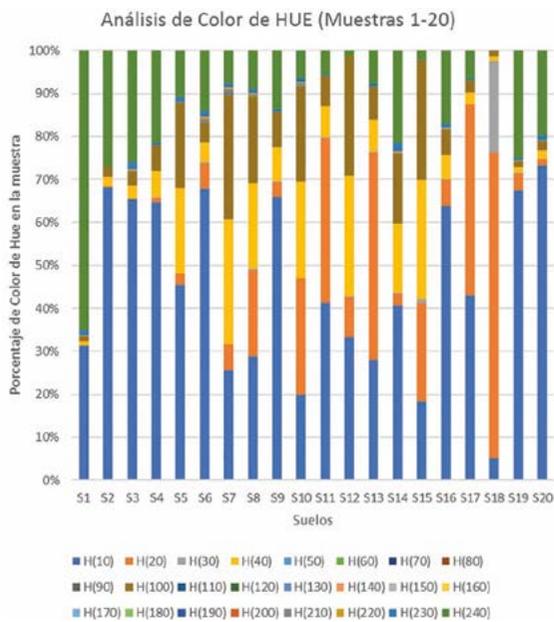


Figura 18. Análisis de color de HUE, muestras de suelo (1-20).

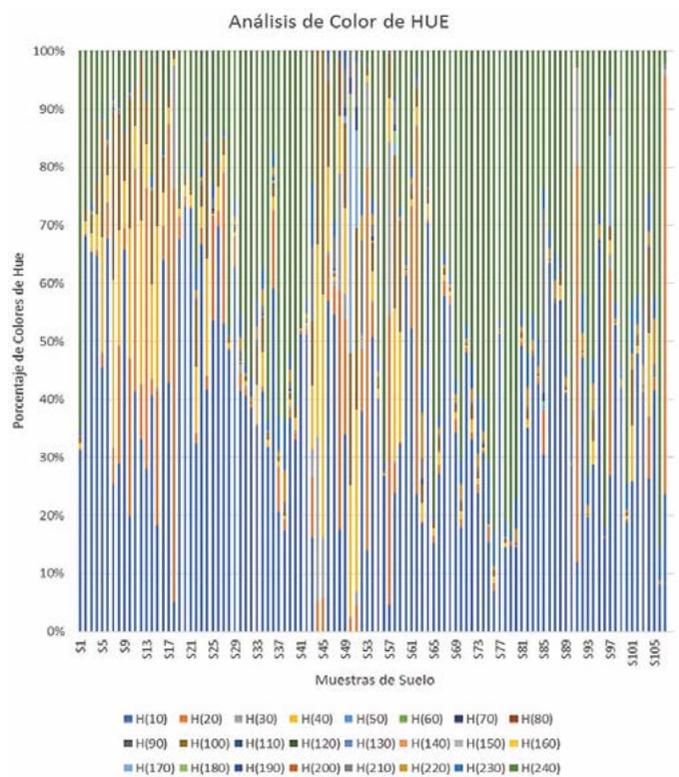


Figura 19. Análisis de color de HUE muestras de suelo (1-106).

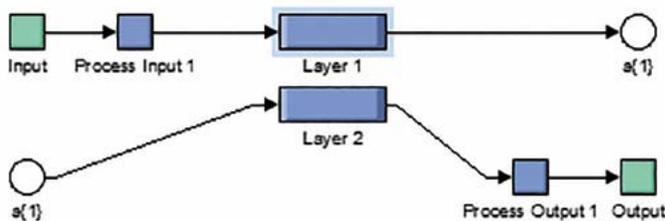


Figura 20. Estructura de la red neuronal, capa de entrada de neuronas y capa intermedia de neuronas.

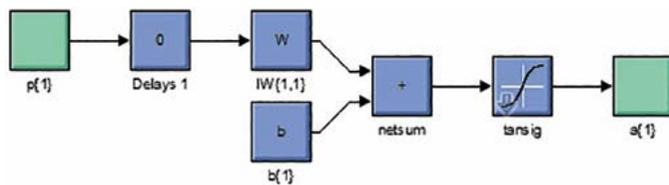


Figura 21. Capa de entrada, compuesta por el algoritmo de normalización, los pesos y la función.

ideal y los círculos en la gráfica son los valores reales de reconocimiento obtenidos por cada valor del target. Se puede apreciar cómo la red neuronal con 15 neuronas en la capa oculta presenta un menor error en el reconocimiento.

Una vez entrenada la red neuronal se procede a realizar una prueba de reconocimiento, utilizando valores de una muestra de suelo. Para realizar esto se ingresaron a la red neuronal los 107 datos provenientes de los parámetros del sistema de visión y se obtuvieron las estima-

ciones de los tres valores de salida correspondientes al MO, Fe, CIC.

## CONCLUSIONES

Los resultados obtenidos en el algoritmo de reconocimiento indican que existe una correlación entre las propiedades químicas como la materia orgánica, el hierro y la capacidad de intercambio catiónico de los suelos obtenidos por el sistema de visión y los análisis de laboratorio de estas variables químicas, lo cual hace factible tener una estimación de estos, utilizando únicamente técnicas de visión y de inteligencia artificial.

## AGRADECIMIENTOS

Al Fondo Sectorial de Investigación Ambiental por el financiamiento otorgado para la realización de este proyecto, en la convocatoria SEMARNAT CONACYT 2015\_1. Al CENACAFE por el apoyo brindado para la obtención de muestras de suelos en la región de las altas montañas en el estado de Veracruz.

## LITERATURA CITADA

Baveye, P. C., Laba, M., Otten, W., Bouckaert, L., Dello Sterpaio, P., Goswami, R. R., ... Sezgin, M. (2010). Observer-dependent variability of the thresholding step in the quantitative analysis of soil images and X-ray microtomography data. *Geoderma*, 157(1-2), 51-63. <http://doi.org/10.1016/j.geoderma.2010.03.015>

Diario Oficial de la Federación. (2002). Norma Oficial Mexicana NOM-021-RECNAT-2000, que establece las especificaciones de fertilidad, salinidad y clasificación de suelos, estudios, muestreo y análisis, 1-65.

Golzarian, M. R., & Frick, R. A. (2011). Classification of images of wheat, ryegrass and brome grass species at early growth stages using principal component analysis. *Plant Methods*, 7(1), 28. <http://doi.org/10.1186/1746-4811-7-28>

Han, P., Dong, D., Zhao, X., Jiao, L., & Lang, Y. (2016). A smartphone-based soil color sensor: For soil type classification. *Computers and Electronics in Agriculture*, 123, 232–241. <http://doi.org/10.1016/j.compag.2016.02.024>

Houston, A. N., Otten, W., Falconer, R., Monga, O., Baveye, P. C., & Hapca, S. M. (2017). Quantification of the pore size distribution of soils: Assessment of existing software using tomographic and synthetic 3D images. *Geoderma*, 299, 73–82. <http://doi.org/10.1016/j.geoderma.2017.03.025>

Keshavarzi, A., Sarmadian, F., Omran, E.-S. E., & Iqbal, M. (2015). A neural network model for estimating soil phosphorus using terrain analysis. *The Egyptian Journal of Remote Sensing and Space Science*, 18(2), 127–135. <http://doi.org/10.1016/j.ejrs.2015.06.004>

Li, Z., An, Q., & Ji, C. (2008). Classification of Weed Species Using Artificial Neural Networks Based On Color Leaf Texture Feature. *The Second IFIP International Conference on Computer and Computing Technologies in Agriculture (CCTA2008)*, 294, 1217–1225. [http://doi.org/10.1007/978-1-4419-0211-5\\_50](http://doi.org/10.1007/978-1-4419-0211-5_50)

Luscier, J. D., Thompson, W. L., Wilson, J. M., Gorham, B. E., & Dragut, L. D. (2006). Using digital photographs and object-based image analysis to estimate percent ground cover in vegetation plots. *Frontiers in Ecology and the Environment*, 4(8), 2006. [http://doi.org/10.1890/1540-9295\(2006\)4\[408:UDPAO\]2.0.CO;2](http://doi.org/10.1890/1540-9295(2006)4[408:UDPAO]2.0.CO;2)

Maragos, P., Sofou, A., Stamou, G. B., Tzouvaras, V., Papatheodorou, E., & Stamou, G. P. (2004). Image analysis of soil micromorphology: Feature extraction, segmentation, and quality inference. *Eurasip Journal on Applied Signal Processing*, 2004(6), 902–912. <http://doi.org/10.1155/S1110865704402054>

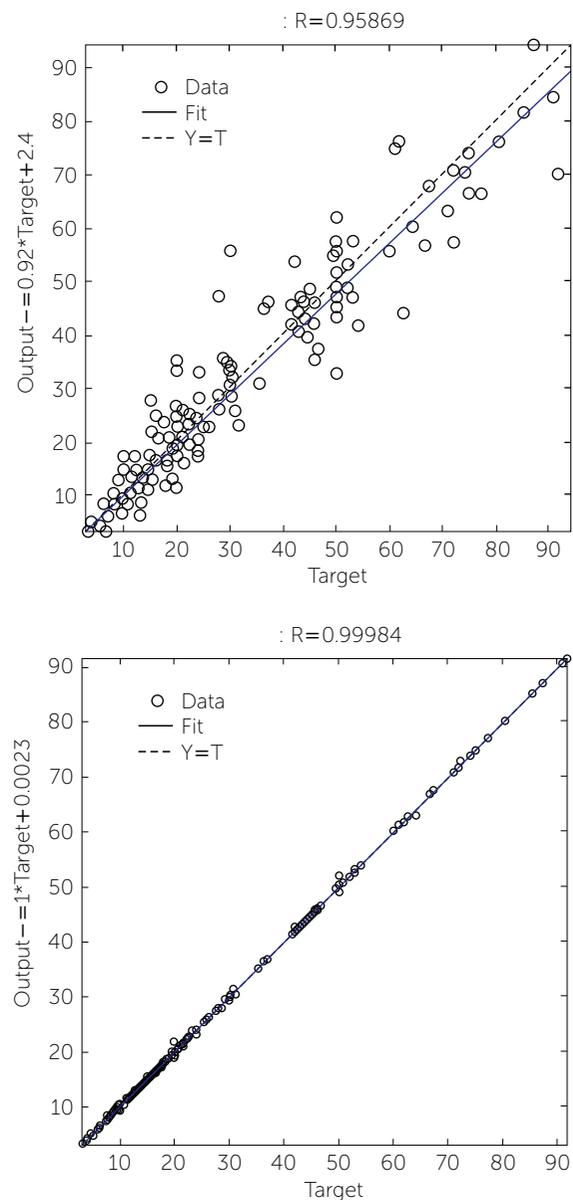
Marcelino, V., Cnudde, V., Vansteelandt, S., & Carò, F. (2007). An evaluation of 2D-image analysis techniques for measuring soil microporosity. *European Journal of Soil Science*, 58(1), 133–140. <http://doi.org/10.1111/j.1365-2389.2006.00819.x>

McBratney, a. B., Mendonça Santos, M. L., & Minasny, B. (2003). On digital soil mapping. *Geoderma* (Vol. 117). [http://doi.org/10.1016/S0016-7061\(03\)00223-4](http://doi.org/10.1016/S0016-7061(03)00223-4)

Mollazade, K., Omid, M., Akhlaghian Tab, F., Kalaj, Y. R., Mohtasebi, S. S., & Zude, M. (2013). Analysis of texture-based features for predicting mechanical properties of horticultural products by laser light backscattering imaging. *Computers and Electronics in Agriculture*, 98, 34–45. <http://doi.org/10.1016/j.compag.2013.07.011>

Moreno, C., Mancebo, I., Saa, A., & Moreno, M. M. (2014). Image Analysis to Estimate Mulch Residue in Soil. *The Scientific World Journal*, 2014.

Moritsuka, N., Matsuoka, K., Katsura, K., Sano, S., & Yanai, J. (2014). Soil color analysis for statistically estimating total carbon, total nitrogen and active iron contents in Japanese agricultural soils. *Soil Science and Plant Nutrition*, 60(4), 475–485. <http://doi.org/10.1080/00380768.2014.906295>



**Figura 22.** a: ANN usando 5 neuronas en la capa oculta. b: ANN usando 15 neuronas en la capa oculta.

Porta-Casanellas, J., López-Acevedo, M., & Roquero-deLaburu, C. (2003). *Edafología para la agricultura y el medio ambiente* (3a ed.). España: Mundi-Prensa.

Thompson, M. L., Singh, P., Corak, S., & Straszheim, W. E. (1992). Cautionary notes for the automated analysis of soil pore-space images. *Geoderma*, 53, 399–415. [http://doi.org/https://doi.org/10.1016/0016-7061\(92\)90067-H](http://doi.org/https://doi.org/10.1016/0016-7061(92)90067-H)

Trueba-Espinosa, A., Oropeza-Mota, J., Ortiz-Solorio, C., Martínez-Alcántara, A., & Ruelas-Ángeles, G. (2004). Identification of eroded zones with digital images using artificial neural networks. *Agrociencia*, 38(6), 573–581.

Zanetti, S. S., Cecilio, R. A., Alves, E. G., Silva, V. H., & Sousa, E. F. (2015). Estimation of the moisture content of tropical soils using colour images and artificial neural networks. *Catena*, 135, 100–106. <http://doi.org/10.1016/j.catena.2015.07.015>