

Espectroscopía de infrarrojo cercano para la determinación de materia orgánica y nitrógeno total del suelo

Use of Near Infrared Spectroscopy for the Determination of Organic Matter and Total Nitrogen of Soils

Manuela Ortega Monsalve¹, Mario Fernando Cerón-Muñoz² y Marisol Medina-Sierra³

Resumen

Los análisis del suelo son fundamentales para la toma de decisiones en agricultura. Estos análisis pueden ser obtenidos por técnicas no destructivas, rápidas y precisas como lo es la espectroscopía de infrarrojo cercano NIRS. El objetivo fue generar ecuaciones de predicción de la Materia Orgánica (MO) y Nitrógeno total (*N* total), mediante el uso de espectros del NIRS. Se procesaron 459 muestras de suelo por química húmeda y por NIRS y se utilizaron diversas transformaciones de datos analizadas por mínimos cuadrados parciales. En la selección se tuvieron en cuenta los valores del coeficiente de determinación (R^2), de la raíz del error cuadrático medio de predicción (RMSEP) y la desviación residual predictiva (RPD). El mejor modelo para MO correspondió al modelo de absorbancia sin transformación ($R^2 = 0.90$, RMSEP = 0.29 y RPD = 1.3) y para el nitrógeno total el mejor modelo fue la transformación de la 1ª derivada de Savitzky-Golay ($R^2 = 0.84$, RMSEP = 0.09 y RPD = 2.5). Lo anterior indica que se pueden utilizar los valores de absorbancia de los espectros del NIRS para predecir los valores de MO y N del suelo, utilizando modelos de mínimos cuadrados parciales.

Palabras clave: Machine learning, Transformaciones, Métodos ópticos, Análisis químicos, Regresiones parciales

Abstract

Chemical analysis in soils are essential for decision making in agriculture. Currently, the aim is to use non-destructive, fast, and precise techniques that allow for results to be obtaining easily, such as NIRS near infrared spectroscopy. The objective was to generate prediction equations for Organic Matter (MO) and total Nitrogen (total *N*), by using NIRS spectra. 459 soil samples were processed by wet chemistry and by NIRS and various data transformations analyzed by partial least squares were used. In the selection, the values of the coefficient of determination (R^2), the root mean square error of prediction (RMSEP) and the predictive residual deviation (RPD). The best model for MO was without transformation with absorbance ($R^2 = 0.90$, RMSEP = 0.29 and RPD = 1.3) and for total Nitrogen with transformation of 1st derivative Savitzky-Golay ($R^2 = 0.84$, RMSEP = 0.09 and RPD = 2.5). This indicates that the absorbance values of the NIRS spectra can be used to predict the OM and N values of the soil, using partial least squares models.

Keywords: Chemical analysis, Machine learning, Optical methods, Partial regressions, Transformations

Recepción: 5-feb-2022

Aceptación: 1-jun-2022

¹Zoot. Grupo de investigación en agrociencias, biodiversidad y territorio (GAMMA), Facultad de Ciencias Agrarias, Universidad de Antioquia

²Zoot. MSc, DrSc, Grupo de investigación en agrociencias, biodiversidad y territorio (GAMMA), Facultad de Ciencias Agrarias, Universidad de Antioquia

³Ing. Agron., MSc, DrSc, Grupo de investigación en agrociencias, biodiversidad y territorio (GAMMA), Facultad de Ciencias Agrarias, Universidad de Antioquia. Correo Electrónico: manuela.ortegam@udea.edu.co

1 Introducción

La materia orgánica (MO) del suelo se forma gracias a los residuos de animales y plantas en descomposición [20] y está relacionada con la retención de nutrientes y la formación de agregados del suelo, almacena elementos importantes y en ella se genera gran actividad microbiana [19, 33]. El carbono orgánico es el principal componente de la MO, por lo que tienen una relación directa en su contenido [6]; por estas razones, la determinación del contenido de MO del suelo puede dar a conocer el estado de fertilidad [32]. Para saber el contenido de MO por química húmeda es necesario analizar primero el contenido de carbono orgánico CO, generalmente realizado por el método de Walkley y Black [9]. El Nitrógeno total se encuentra de forma orgánica e inorgánica y es uno de los elementos más importantes del suelo [11], además es uno de los nutrientes más limitantes para los cultivos y es un elemento muy dinámico en el suelo [1]. En la forma tradicional o química húmeda se determina por medio del método Kjeldahl.

Los análisis químicos son herramientas que permiten conocer el estado de fertilidad del suelo, sin embargo, son costosos, difíciles de realizar y toman mucho tiempo [5], además generan residuos químicos que pueden contaminar diferentes fuentes naturales. Por esto, se ha venido desarrollando e investigando en nuevas metodologías que permitan obtener resultados más fácilmente. La espectroscopía de infrarrojo cercano NIRS ha sido descrita por [17, 22, 10, 23] como una buena alternativa en la agricultura de precisión para analizar las propiedades del suelo, siendo un método fácil, útil y de bajo costo.

El NIRS funciona por medio de ondas en la región del infrarrojo cercano entre la longitud de onda de los 780 a 2500 nm, que en su mayoría no son percibidas por el ojo humano [13]. Estas longitudes de onda pueden reconocer los enlaces químicos como los N-H, S-H, C=O y O-H de los compuestos principalmente orgánicos presentes en el suelo [16]. Una de las mayores ventajas del método NIRS es que por medio del espectro obtenido de una sola muestra se pueden analizar simultáneamente propiedades químicas, físicas y biológicas del suelo [26]. Algunas de sus ventajas más importantes son la rapidez con

la que se realizan los análisis, no genera residuos químicos, requiere menos mano de obra, es muy fácil de manejar y sus análisis tienen un bajo costo [29, 27]. Esta es una metodología no destructiva que permite desarrollar modelos de predicción para diferentes parámetros presentes en el suelo [15].

Los modelos de predicción más utilizados en suelos mediante el método NIRS son la regresión lineal (LR), la regresión de mínimos cuadrados parciales (PLSR), regresión por componentes principales (PCR), la red neuronal de retropropagación y la máquina de vectores de soporte [33]. Algunos autores han realizado predicciones de estas variables con métodos como MPLS y Adaboost obteniendo buenos resultados (tabla 1). [12] concluye que los análisis PCR y PLSR son mucho más adecuados para examinar espectros debido a que convierten un conjunto de variables altamente correlacionadas en un conjunto de variables independientes y reducen la dimensionalidad de los datos extrayendo las variables más importantes.

El objetivo de este trabajo fue predecir la MO y el N total del suelo mediante espectros del infrarrojo cercano.

2 Materiales y métodos

2.1 Área de estudio y análisis químico de los suelos

La investigación se llevó a cabo en el departamento de Antioquia, Colombia con coordenadas desde la latitud: 6.55 hasta la longitud: -75.817; En esta región predominan los suelos andisoles, los cuales provienen de cenizas volcánicas. Se recolectaron 459 muestras de suelo de predios dedicados a la producción de forrajes, cacao y flores, localizadas en las diferentes subregiones del departamento, con una altura sobre el nivel del mar entre los 0 y 2,850. Estas propiedades edafoclimáticas hacen que las muestras de suelo tengan una alta variabilidad en sus características.

En cada predio se tomaron entre 1 y 3 muestras, esto dependió de que tan grande era el terreno. Cada muestra se obtuvo de una mezcla de diez submuestras tomadas a una distancia de 20 cm distribuidas en la zona de interés a muestrear, esto se realizó con la ayuda de un barreno.

Tabla 1. Reportes de uso de metodologías estadísticas para relacionar la materia orgánica y el nitrógeno del suelo con espectros de infrarrojo cercano (NIRS)

Parámetro	R^2	Rango espectral (nm)	modelo estadístico	N	Referencia
Materia orgánica	0.96	993, 1080, 1951 y 2277	PCR y PLSR	165	[17]
	0.99	450 y 600	LR	-	[34]
	0.90	379-780 y 780-1800	PLSR	72	[15]
	0.62	-	MPLS	281	[22]
	0.96	750 y 2400	PLSR	147	[10]
	0.91	479, 482, 487, 497, 503, 504, 1392, 1393 y 1888	AdaBoost	69	[32]
	0.90	-	PCR y PLSR	130	[21]
Nitrógeno	0.93	902 y 2364, 1826 y 2098	PCR y PLSR	165	[17]
	0.96	928,960,1638 y 1680	PLSR	-	[27]
Nitrógeno total	0.91	750 y 2400	PLSR	147	[10]
	0.88	-	PCR	156	[11]

R^2 : Coeficiente de determinación, N : número de muestras

Regresiones: PCR = componentes principales, PLSR = mínimos cuadrados parciales, LR = lineal,

MPLS = mínimos cuadrados modificados, y AdaBoost-Kernel (algoritmo boosting adaptado [30])

Cada muestra fue repartida homogéneamente en dos en bolsas ziploc previamente rotuladas con la información de la finca, una bolsa se envió al laboratorio de suelos de AGROSAVIA donde se analizó el contenido de la MO y el N total por los métodos tradicionales (Walkley-Black y Kjeldahl, respectivamente) y la otra bolsa se envió al Laboratorio Integrado de Nutrición Animal y de Pastos y Forrajes de la Facultad de Ciencias Agrarias de la Universidad de Antioquia para ser procesada y analizada por NIRS.



Figura 1. Muestra de suelo preparada para su lectura en el equipo NIRS.

2.2 Procesamiento del suelo y lectura en el equipo NIRS

Previamente a la realización del análisis por NIRS, el pretratamiento las muestras de suelo consistió en el secado en estufa de ventilación forzada (Memmert UF 750), a una temperatura de 40 °C por 48 horas, luego se tamizó a un diámetro de partícula de 2 mm y el suelo resultante se almacenó en recipientes de plástico hasta su lectura.

Para la lectura por medio de espectroscopía de infrarrojo cercano se utilizó el equipo NIRS modelo (FOSS DS 2500 F) en el rango de longitud de onda de 850 a 2500 nm. Se utilizó el recipiente de cuarzo que contenía el NIRS con una cantidad aproximada de 20 g de suelo para la lectura del espectro (figura 1). Luego de cada lectura la cubeta se limpió con un paño limpio y seco para eliminar los residuos de la muestra anterior.

2.3 Procesamiento de los datos

La base de datos de los espectros en unidades de absorbancia (A) se obtuvo por medio del software MOSAIC para su posterior importación al programa estadístico R-project (R Core Team, 2021). Se realizaron análisis visuales previos de las curvas espectrales y se utilizaron las metodologías de PCA y PLSR con diversas transformaciones de A , dejando únicamente la metodología PLSR porque presentó resultados previos adecuados. Se utilizaron las transformaciones de reflectancia ($1/100^A$), corrección de dispersión multiplicativa (MSC), variable normal estándar (SNV), Detrend, Savitzky-Golay (SG), SG+MSC, SG+SNV, 1ª derivada de SG y 2ª derivada de SG. La variable MO fue transformada a \sqrt{MO} . Los 459 espectros se dividieron en dos grupos: 344 para entrenamiento y 115 de prueba.

La selección de los mejores modelos se realizó por medio de los criterios: mayor coeficiente de determinación (R^2), menor raíz del error cuadrático medio de predicción (RMSEP) y una desviación residual predictiva (RPD) mayor a 2.6, con base a lo descrito por [32].

3 Resultados y discusión

En la figura 2 se visualizan los espectros de las muestras con la A y las transformaciones, su objetivo es mejorar la señal espectral y corregir la dispersión de los datos. Se observa que la A es mayor en los rangos de los 1800 a 1900 nm y luego de los 2300 nm. Para los gráficos de SG 1^a derivada y SG 2^a derivada se incrementaron los picos espectrales. con esta transformación se busca que los datos espectrales o las longitudes de onda sean más homogéneos.

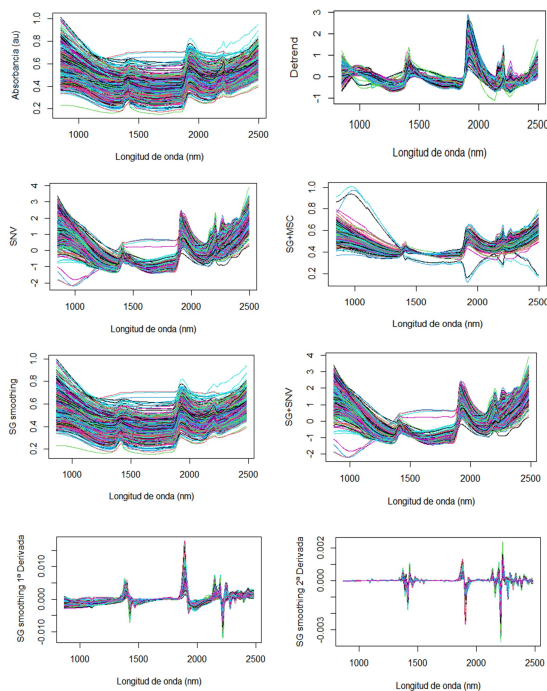


Figura 2. Gráficos de los espectros de las muestras de suelo con y sin transformaciones.

Según [18], se presenta una absorbancia mayor para la MO después de los 2300 nm, esto debido a la presencia de enlaces CH. Según [25] la MO presenta una longitud de onda más marcada en los 1900 nm cuando los datos han tenido diferentes transformaciones, esto concuerda con lo encontrado en esta investigación. [3] encontró absorbancias mayores para

la MO en las longitudes de onda cercanas a los 1400, 1900 y 2200 nm. Las longitudes de onda observadas en el rango espectral cercano (entre los 780 y 2500 nm) se producen debido a la combinación de vibraciones producidas por diferentes enlaces moleculares pertenecientes a los grupos OH, CH, NH, SO^4 y CO^3 . Por ende, los datos espectrales contienen información que dan a conocer la composición del suelo [18].

Los picos del espectro asociados a la determinación de N total pueden ser más difíciles de predecir, ya que sus enlaces con grupos OH pueden ser menores. [35] encontró algunos picos de absorbancia entre los 1940 y 1210 en la determinación de N total en suelos. Sin embargo, puede deberse a la presencia de compuestos orgánicos. [28] hallaron picos de absorbancia asociados al N total en los 1420, 1930 y 2200 nm.

Tabla 2. Contenido de materia orgánica y nitrógeno total en muestras del suelo

Variable	Media	Min	Máx	Mediana	Moda
Materia Orgánica (MO %)	5.37 ± 5.29	0.14	26.7	2.98	1.64
Materia Orgánica $MO = \sqrt{MO}$	2.07 ± 1.0	0.37	5.16	1.72	1.28
Nitrógeno total (N total %)	0.33 ± 0.25	0.06	1.24	0.22	0.14

Se observan las medias obtenidas para las variables de MO y N total (tabla 2), el promedio de la MO puede llegar a ser un valor bajo, sin embargo, las características de un gran porcentaje del suelo de las muestras recolectadas pertenece a zonas donde se presentan altas temperaturas o climas tropicales, lo que puede llegar a acelerar la descomposición de la MO, mientras que en zonas más frías o templadas la tasa de descomposición es más baja [2]. Con respecto al N total, se obtuvo una media la cual se encuentra dentro de los niveles adecuados en el suelo, cuando este valor es menor a 0.2 se recomienda fertilizar con dicho elemento [36].

La tabla 3 contiene los resultados obtenidos para el ajuste de la MO con las diferentes transformaciones aplicadas a los datos espectrales utilizando el análisis PLSR. Se obtuvo un mayor ajuste para esta variable cuando los datos no tuvieron ninguna transformación, obteniendo un R^2 de 0.92, un RMSEP de 0.29 y un RPD de 3 utilizando 10 componentes.

Tabla 3. Criterios de selección de modelos de regresión de mínimos cuadrados parciales (PLSR) para el análisis de la materia orgánica y nitrógeno total por espectroscopía de infrarrojo cercano

Transformación	Materia orgánica				Nitrógeno total			
	NC	R^2	RMSEP	RPD	NC	R^2	RMSEP	RPD
Absorbancia (A)	10	0.90	0.29	1.3	10	0.82	0.11	2.2
Reflectancia ($1/100^A$)	10	0.87	0.36	2.9	9	0.77	0.11	2.1
Corrección de dispersión multiplicativa (MSC)	9	0.88	0.38	3	5	0.76	0.13	2.1
Variable normal estándar (SNV)	9	0.84	0.4	2.8	8	0.74	0.12	2.1
Detrend	10	0.85	0.38	3	7	0.75	0.12	2.1
Savitzky-Golay (SG)	10	0.89	0.33	3.0	10	0.82	0.10	2.2
SG+MSC	9	0.86	0.37	3.1	10	0.76	0.11	2.1
SG+SNV	10	0.89	0.33	3.0	10	0.82	0.10	2.2
SG 1ª Derivada	10	0.88	0.32	3.5	9	0.83	0.09	2.5
SG 2ª Derivada	10	0.89	0.33	3.5	8	0.81	0.10	2.6

NC = número de componentes, R^2 = coeficiente de determinación, RMSEP = raíz del error cuadrático medio de predicción y RPD = desviación residual predictiva

Autores como [10] hallaron un ajuste de R^2 de 0.90 para la MO utilizando el análisis PLSR. [15] encontró un R^2 de 0.89 y 0.90 para la MO. [17] halló resultados cercanos a los encontrados en este estudio con R^2 de 0.93. [3] obtuvo un R^2 de 0.92, un RMSEP de 0.38 y un RPD de 5.2 utilizando diferentes transformaciones para los datos espectrales de la variable MO del suelo. [21] predijeron el contenido de materia orgánica por medio de transformaciones, encontrando un R^2 de 0.90, un RPD de 2.24 y un RMSEP de 0.21 con diferentes transformaciones, indicando que el modelo PLSR es adecuado. En el estudio de determinación de MO por medio del método NIR [31] concluye que la MO es un elemento del suelo que puede ser reconocido con gran facilidad.

En la tabla 3 se observan los resultados obtenidos para el ajuste del N total aplicando las diferentes transformaciones a los datos espectrales utilizando el análisis PLSR. Se obtuvo un mayor ajuste para esta variable cuando los datos se transformaron por medio de la 1ª Derivada de SG, utilizando 9 componentes se obtuvo un R^2 de 0.83, un RMSEP de 0.09 y un RPD de 2.5.

Con respecto a los resultados encontrados para la variable de N total en suelos, [11] encontró un R^2 de 0.88 y un RPD de 2.9 utilizando la transformación de SG y el análisis por PLSR. [24] obtuvieron un R^2 de 0.73, un RPD de 1.9 y un RMSEP de 0.007. [8] obtuvo un R^2 de 0.73 y un RMSEP de 0.33 para N total cuando los datos no fueron transformados y

halló un R^2 de 0.60 y un RMSEP de 0.40 cuando se aplicó la transformación de la derivada de SG a los espectros. [6] encontró un R^2 de 0.82 y un RMSEP de 0.06 utilizando 8 componentes por medio de PLSR. Este método es altamente utilizado en el NIRS para determinar diferentes componentes presentes en el suelo, ya que facilita la lectura de las líneas superpuestas del espectro [4].

En la figura 3 se observa las relaciones entre los valores observados de la \sqrt{MO} y N total con los valores predichos de los modelos seleccionados de las bases de datos utilizadas para el entrenamiento y la prueba, indicando que la MO tuvo un mejor ajuste que el N total con la metodología de PLSR, esto debido a que este modelo permite aumentar la predicción de las bandas del espectro que son sensibles a dichos elementos del suelo como la presencia de algunos enlaces de carbono.

Figura 3. Valores observados y predichos de la materia orgánica y el nitrógeno total del suelo de las bases de datos de entrenamiento (puntos negros) y prueba (puntos rojos), mediante análisis de regresión por mínimos cuadrados.

4 Conclusiones

El uso de la espectroscopía de infrarrojo cercano NIRS es una buena alternativa para predecir la composición fisicoquímica del suelo. Los resultados obtenidos para el ajuste o calibración de la MO presente

en los suelos son muy buenos (R^2 0.90) y para el N Total (R^2 0.83), utilizando transformaciones. Se podría obtener un ajuste más cercano a 1 para el N total experimentando más combinaciones entre las transformaciones utilizadas. El NIRS es una metodología fácil de usar, económica y permite analizar muchas muestras de suelo en poco tiempo.

Agradecimientos

Los autores expresan su agradecimiento al proyecto financiado por el Sistema General de Regalías “Desarrollo y Establecimiento del Centro de Desarrollo Agrobiotecnológico de innovación e integración territorial” (CEDAIT), código BPIN 2016000100060.

Referencias

- [1] D. Acevedo, M. Álvarez, E. Hernández, R. Améndola“, Concentración de nitrógeno en suelo por efecto de manejo orgánico y convencional”, *Terra Latino*, vol. 29, no. 3, 2011.
- [2] H. Arguello“, La descomposición de la materia orgánica y su relación con algunos factores climáticos y microclimáticos”, *Agronomía colombiana*, vol. 8, no. 2, pp. 384-388, 1991.
- [3] Y. Ba, J. Liu, J. Han, X. Zhang“, Aplicación de espectroscopía Vis-NIR para la determinación del contenido de materia orgánica en suelos salino-alcálinos”, *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, vol. 229, 2019. DOI: 10.1016/j.saa.2019.117863.
- [4] Pls: Partial Least Squares and Principal Component Regression. R package version 2.7-3, 2021.
- [5] A. Chacón, M. Rodríguez, E. Aguila, M. Carral, Y. Díaz, J. Baerdemaeker, W. Saeys“, Vis/NIR spectroscopic measurement of selected soil fertility parameters of Cuban agricultural Cambisols”, *Biosystems engineering*, vol. 125, pp. 105-121, 2014. DOI: 10.1016/j.biosystemseng.2012.06.018.
- [6] M. Conforti, G. Matteucci, G. Buttafuoco, “Uso de espectroscopía Vis-NIR de laboratorio para monitorear algunas propiedades del suelo forestal“, *Revista de suelo y sedimentos*. vol. 18, no. 3, pp. 1009-1019, 2017. DOI: 10.1007/s11368-017-1766-5.
- [7] G. Crespo“, Cómo incrementar la materia orgánica del suelo en la actividad ganadera del trópico“, *Avances en Investigación Agropecuaria*. vol. 22, no. 3, pp 37-44, 2018.
- [8] U. J. Dos Santos, E.V. de S Barretto Sampaio, J.A. de Melo Dematte, R.S. Menezes, A.C. Dotto, C.C. Guimaraes, D.C. Primo, “Rapid determination of carbon and nitrogen by low environmental impact spectroscopic techniques (Vis-NIR, MIR)“, *Geoderma Regional*. vol. 23, 2020. DOI: 10.1016/j.geodrs.2020.e00333.
- [9] C. Gámez“, Uso de modelos espectrales VIS-NIR para la determinación del contenido de carbono del suelo”, tesis de maestría. Departamento de ingeniería civil y agrícola, Universidad Nacional de Colombia, Bogotá, 2019.
- [10] M. Gandariasbeitia, G. Besga, I. Albizu, S. Larregla, S. Mendarte“, Prediction of chemical and biological variables of soil in grazing areas with visible- and near-infrared spectroscopy“, *Geoderma*. vol. 305, no. 2, pp. 228-235, 2017. DOI: 10.1016/j.geoderma.2017.05.045.
- [11] J. R.Gates“, A Comparison of VNIR and MIR Spectroscopy for Predicting Various Soil Properties”, dissertations and theses in natural resources. Universidad de Nebraska, Nebraska, 2018.
- [12] P. Geladi“, Chemometrics in spectroscopy. Part 1. Classical chemometrics. *Spectrochimica Acta Part B Atomic spectroscopy*. vol. 58, no. 5, pp. 767-782, 2003. DOI: 10.1016/S0584-8547(03)00037-5.
- [13] D. I. Givens, J. L. De Boever, E. R. Deaville“, The principles, practices and some future applications of near infrared reflectance spectroscopy for predicting the nutritive value of foods for animals and humans“, *Nutrition research reviews*. vol. 10, pp. 83-114, 1997.
- [14] Manual de prácticas de campo y del laboratorio de suelos. SENA, región Tolima, 2014.

- [15] D. González, A. Coáls, O. Rodríguez, D. Álvarez, S. Gattorno, A. Chacón“, Estimación de la materia orgánica en suelo Pardo mullido medianamente lavado mediante espectroscopia vis-NIR“, *Ciencia Agrícola* vol. 47, no. 3, pp.23-32, 2020.
- [16] C. Guerrero, R. Zornoza, A. Pérez, J. Solera, I. Gómez, F. García-Orenes“, Uso de la espectroscopía en el infrarrojo cercano (NIR) para la estimación rápida del carbono orgánico y la respiración basal en suelos forestales“, *Cuadernos de la Sociedad Española de Ciencias Forestales* vol. 47, vol. 25, pp.209-214, Enero. 2008.
- [17] Y. He, M. Huang, A. García, A. Hernández, H. Song“, Prediction of soil macronutrients content using near-infrared spectroscopy“, *Computers and Electronics in Agriculture* vol. 58, no. 2, pp. 144-153, Septiembre. 2007. DOI: 10.1016/j.compag.2007.03.011.
- [18] S. Katuwal, M. Knadel, P. Moldrup, T. Norgaard, M.H. Greve, L.W. de Jonge“, Visible-near-infrared Spectroscopy can predict mass transport of dissolved chemicals through intact soil“, *Scientific Reports* vol. 8, no. 1, 2018. DOI: 10.1038/s41598-018-29306-9.
- [19] B. Lazzaretti, L. Souza, G. Laerson, A. D. Carnieletto, D. Britzke, J. Laerte“, Prediction of soil organic matter and clay contents by near-infrared spectroscopy - NIRS“, *Ciencia Rural Santa Marias* vol. 50 no 1,2020. DOI: 10.1590/0103-84780190506.
- [20] M. Lezcano, C. Gamarra, S. Ruiz, M. Ortiz“, Contenido de materia orgánica en suelos de sistemas silvopastoriles establecidos en el Chaco Central paraguay“, *Revista Sociedad Científica del Paraguay* vol. 25 no 2, pp. 131-143, 2020.doi.org/10.32480/rscp.2020.25.2.131.
- [21] Z. Lin, R. Wang, Y. Wang, L. Wang, C. Lu, Y. Liu, L. Zhu“, Accurate and rapid detection of soil and fertilizer, properties based on visible near-infrared spectroscopy “*Applied Optics* vol. 57, no. 18, 2018. DOI: 10.1364/ao.57.000d69.
- [22] M. Macias, J. Cueto, J. Muñoz, O. Landeros“, Predicción de propiedades del suelo de importancia agronómica por espectroscopia de reflectancia de infrarrojo cercano“, *Revista Mexicana de Ciencias Agrícolas* vol. 6, no. 6, pp. 1317-1329, 2015.
- [23] E.S. Mohamed, A.M. Saleh, A.B. Belal, G. Abd Allah“, Application of near-infrared reflectance for quantitative assessment of soil properties“, *The Egyptian Journal of Remote Sensing and Space Science* vol. 21, no. 1, pp. 1-14, 2018. DOI: 10.1016/j.ejrs.2017.02.001.
- [24] A. Morellos, X.E. Pantazi, D. Moshou, T. Alexandridis, R. Whetton, G. Tziotzios, A.M. Mouazen“, Predicción basada en aprendizaje automático del contenido de nitrógeno total, carbono orgánico y humedad del suelo mediante el uso de espectroscopia VIS-NIR“, *Ingeniería de biosistemas* vol. 152, pp. 104-116, 2016. DOI: 10.1016/j.biosystemseng.2016.04.018.
- [25] S. Nawar, H. Buddenbaum, J. Hill, J. Kozak, A. Mouazen“, Estimación del contenido de arcilla y materia orgánica del suelo mediante diferentes métodos de calibración de espectroscopia de reflectancia difusa vis-NIR“, *Investigación del suelo y labranza* vol. 155, pp. 510-522, 2016. DOI: 10.1016/j.still.2015.07.021.
- [26] C. Nduwamungu, N. Ziadi, E. Parent, F. Tremblay, L. Thuries“, Opportunities for, and limitations of, near infrared reflectance spectroscopy applications in soil analysis: A review“, *Canadian Journal of soil science* vol. 89, no. 5, pp. 531-541, 2009. DOI: 10.4141/CJSS08076.
- [27] P. Nie, T. Dong, S. Oye Xiao, F. Qu, L. Lin“, The Effects of Drying Temperature on Nitrogen Concentration Detection in Calcium Soil Studied by NIR Spectroscopy“, *Applied Science* vol. 8, no. 2, pp. 269, 2018. DOI: 10.3390/app8020269.
- [28] A. Pudielko, M. Chodak“, Estimación del contenido total de nitrógeno y carbono orgánico en suelos mineros con espectroscopia de reflectancia NIR y

- varios métodos quimiométricos“, *Geoderma Regional* vol. 23, 2020. DOI: 10.1016/j.geodrs.2020.e00333.
- [29] Predicción de la composición química de alimentos de uso animal mediante NIRS Aplicaciones e interpretación práctica. Universidad de Antioquia, Facultad de Ciencias Agrarias. Fundación CIPAV, 2018.
- [30] R. Shapire“, The strength of weak learnability“, *Machine Learning* vol. 5, no. 2, pp. 197-227. 1990.
- [31] B. Stenberg, R.A.V. Rossel, A.M. Mouazen, J. Wetterlind“, Visible and near infrared spectroscopy in soil science“, *Advance in agronomy* vol.107, pp. 163-215, 2010. DOI: 10.1016/S0065-2113(10)07005-7.
- [32] L. Wei, Z. Yuan, Z. Wang, L. Zhao, Y. Zhan, X. Lu, L. Cao“, Hyperspectral Inversion of Soil Organic Matter Content Based on a Combined Spectral Index Model”*Sensors* vol. 20,no. 10, pp. 2777, 2020. DOI: 10.3390/s20102777.
- [33] Z. Xu, X. Zhao, X. Guo, J. Guo“, Aplicación de aprendizaje profundo para predecir el contenido de materia orgánica del suelo mediante espectroscopia VIS-NIR”, *Inteligencia computacional y neurociencias* vol. 2019, pp. 11, 2019. DOI: 10.1155/2019/3563761.
- [34] C. Yarce, J. Castillo“, Validación no exhaustiva del método analítico de Walkley-Black, para la determinación de materia orgánica en suelos por espectrofotometría de UV-VIS“, *Ingenium* vol. 8, no. 19, pp. 37-45, 2014.
- [35] Y. Zhang, M. Li, L. Zheng, Y. Zhao, X. Pei“, Soil nitrogen content forecasting based on real-time NIR spectroscopy”, *Computers and Electronics in Agriculture* vol. 124, pp. 29-36, 2016. DOI: 10.1016/j.compag.2016.03.016.
- [36] Manual de análisis de suelos y tejido vegetal. Una guía teórica y práctica de metodologías, documento de trabajo 129. CIAT. 1993.