



SEP

SECRETARÍA DE
EDUCACIÓN PÚBLICA



TECNOLÓGICO NACIONAL DE MÉXICO

Instituto Tecnológico de Orizaba

“2019, Año del Caudillo del Sur, Emiliano Zapata”

DIVISIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN

OPCIÓN I.- TESIS

TRABAJO PROFESIONAL

“ELABORACIÓN DE UN SISTEMA INTELIGENTE PARA
LA ESTIMACIÓN DE PARÁMETROS FÍSICOQUÍMICOS EN
SUELOS CON PRODUCCIÓN DE CAÑA DE AZÚCAR”.

QUE PARA OBTENER EL GRADO DE:
DOCTORA EN CIENCIAS
DE LA INGENIERÍA

PRESENTA:


M.C. Ofelia Landeta Escamilla

DIRECTOR DE TESIS:

Dr. Albino Martínez Sibaja

CODIRECTOR DE TESIS:

Dr. Alejandro Alvarado Lassman



ORIZABA, VERACRUZ, MÉXICO.

ABRIL 2019

CONTENIDO

CONTENIDO	2
Agradecimientos	5
Resumen	6
Abstract	7
Introducción	8
Hipótesis	11
Objetivo General	11
Objetivos específicos	11
CAPITULO I. Antecedentes	13
1.1 Suelos	13
1.1.1. Caracterización	13
1.1.2. Relación entre variables físicas y químicas.....	14
1.1.3. Restauración	15
1.2 Metodologías para determinaciones en suelos.	18
1.3 Inteligencia artificial y determinaciones en suelos.	28
CAPÍTULO II. METODOLOGÍA	30
2.1 Delimitación de los sitios de muestreo	33
2.2 Caracterización de muestras de suelo	35
2.3 Sistema de extracción de núcleos	36
2.3.1. Diseño y fabricación del sistema de extracción de núcleos	37
2.3.1.1 Sistema de sujeción y Acoplamiento.....	37
2.3.1.2. Sección Tubo de Extracción	39
2.3.1.3. Sección de Expulsión de Muestra	40
2.3.1.4. Sección del sistema de cortadores	41
2.3.1.5. Experimentación	41
2.4 Desarrollo del sensor capacitivo.....	52
2.4.1 Desarrollo del sensor.....	52
2.4.2 Desarrollo del amplificador lock-in utilizando FPGA	57
2.4.3 Inteligencia Artificial utilizada para la determinación de variables fisicoquímicas	60
2.5 Sensor óptico de análisis de color y textura en suelos.	61

2.5.1	Introducción.....	61
2.5.2	Textura.....	62
2.5.2.1	Contraste.....	63
2.5.2.2	Correlación.....	63
2.5.2.3	Homogeneidad.....	63
2.5.2.4	Energía.....	63
2.5.2.5	Entropía.....	63
2.5.2.6	Característica de Segundo Momento Angular (ASM).....	63
2.5.3	Color del suelo.....	64
2.6	Sensor de conductividad térmica.....	65
CAPÍTULO III. ANÁLISIS Y EVALUACIÓN DE RESULTADOS FISICOQUÍMICOS DEL SUELO.....		66
CAPÍTULO IV. ANALISIS E INTERPRETACIÓN DE LOS RESULTADOS DE LA EXPERIMENTACIÓN CON EL SENSOR CAPACITIVO.....		77
4.1	Experimentación del sensor capacitivo.....	77
4.1.1	Experimentación y análisis sin muestra de suelo con variaciones en temperatura ambiental.....	77
4.1.2	Experimentación y análisis del sensor sin muestra de suelo con variaciones en temperatura ambiental.....	77
4.1.3	Análisis de varianza de magnitud.....	80
4.1.4	Análisis de Varianza de la fase.....	82
4.1.5	Histéresis.....	83
4.1.6	Repetibilidad.....	83
CAPITULO V: ANÁLISIS E INTERPRETACIÓN DE RESULTADOS DE LA EXPERIMENTACIÓN CON EL SENSOR ÓPTICO.....		85
5.1	Adquisición de datos por visión artificial de Color y Textura.....	85
5.2	Análisis de Resultados del Sistema de Visión.....	97
5.2.1	Análisis de Textura.....	97
5.2.2	Análisis de Color de Hue.....	102
5.2.3	Repetibilidad.....	107
5.3	Implementación del Sistema Inteligente.....	109
CAPITULO VI. ANALISIS E INTERPETACIÓN DE RESULTADOS CON EL SENSOR DE CONDUCTIVIDAD TÉRMICA.....		112
CAPITULO VII. SISTEMA INTELIGENTE PARA LA CARACTERIZACIÓN DE SUELOS. .		114
7.1	Correlación de variables.....	114
7.1.1	Introducción.....	114

7.1.2	Software Utilizado	115
7.1.3	Análisis de los datos.....	115
7.1.4	Correlación de datos	118
7.2	Correlación Variables Espectroscopía y variables Fisicoquímicas de Laboratorio.....	122
7.2.1	pH Magnitud y Fase	124
7.2.2	Fósforo Magnitud y Fase	125
7.2.3	Potasio Magnitud y Fase	126
7.2.4	Calcio Magnitud y Fase	127
7.2.5	Magnesio Magnitud y Fase	128
7.2.6	Sodio Magnitud y Fase	129
7.2.7	Conductividad Magnitud y Fase	130
7.2.8	Nitrógeno-Nitrato	131
7.3	Clasificación y validación.....	133
7.3.1	Clasificación y validación del Fósforo con parámetros de espectroscopía	134
7.3.2	Clasificación y validación del Potasio con parámetros de espectroscopía	135
7.3.3	Clasificación y validación del Magnesio con parámetros de espectroscopía	135
7.3.4	Clasificación y validación del Calcio con parámetros de espectroscopía	136
7.3.5	Clasificación y validación del Sodio con parámetros de espectroscopía	137
7.3.6	Clasificación y validación del Conductividad con parámetros de espectroscopía	137
7.3.7	Clasificación y validación del Nitrógeno-Nitrato con parámetros de espectroscopía	137
7.3.8	Redes Neuronales	138
7.3.8	Estadística final de validación del sistema de clasificación.....	141
CAPITULO VIII: SISTEMA INTELIGENTE PARA LA ESTIMACIÓN DE PROPUESTA DE RESTAURACIÓN.		143
CONCLUSIONES		149
Referencias.....		150
ANEXOS		157

Agradecimientos

A Dios, por ser esta experiencia viva en cada instante.

A mi familia, por estar siempre para mí y ser un pilar en cada experiencia de mi vida; en especial a este pequeño que llegó a hacerme más fuerte y enriquecer mi experiencia del amor y entrega.

Al programa del Doctorado en Ciencias de la Ingeniería del TecNM/ITO, por haberme dado la oportunidad de ampliar mis conocimientos al compartir con los investigadores que lo componen.

Al Consejo Nacional de Ciencia y Tecnología de México (CONACYT) por la beca nacional: 2015-2018.

Al financiamiento del Fondo Sectorial de Investigación Ambiental SEMARNAT-CONACYT 2015 con número de proyecto: 262829

A los miembros de mi comité tutelar Dr. Alejandro Alvarado Lassman, Dr. Rubén Posada Gómez y Dr. Juan Manuel Méndez Contreras y muy especialmente al Dr. Albino Martínez Sibaja, por sus enseñanzas, aportaciones, consejos y tiempo dedicado durante este trabajo de investigación. Así como al Dr. Oscar O. Sandoval Gonzalez y Dr. Agustín Flores Cautle por sus participaciones invaluable para enriquecer este documento.

A mis compañeros de posgrado por los comentarios para enriquecer este trabajo.

Resumen

El incremento de actividades como ganadería y agricultura genera cambios no medibles en las propiedades del suelo debido a la falta de recursos económicos y culturales. Por lo tanto, es necesario diseñar e implementar tecnologías de bajo costo y fácil uso que apoye a mejorar la química del suelo y facilite las determinaciones de variables fisicoquímicas en sitio.

Se han realizado estudios utilizando diversos modelos y sistemas para estimar la dosis de nutrientes necesarios, sin embargo; aún se sigue trabajando con la precisión de estos y el hacerlos más prácticos en cuanto a su manejo por gente no especializada. Por lo anterior, el reto principal fue por un lado emplear distintos algoritmos de Inteligencia Artificial para lograr la precisión necesaria y por el otro, elaborar un sistema electrónico embebido que facilite la lectura de diagnósticos y recomendaciones para mejorar la calidad del suelo y la caña de azúcar sembrada.

Para obtener lo anterior se experimentó con un sensor capacitivo, uno térmico, y uno óptico; siendo el primero el que se utilizó para obtener información de Magnitud y Fase de las muestras de suelo a una temperatura controlada. De igual forma, se realizaron análisis fisicoquímicos de más de 100 muestras de suelos en la zona de Las Montañas de Veracruz cuyo tipo de suelo es el Vertisol. Una vez obtenido toda la información se procedió a elaborar el sistema inteligente que estableció la relación entre los parámetros de laboratorio y la información de Magnitud y Fase de los suelos analizados.

Los resultados de los análisis fisicoquímicos mostraron que al menos 10 municipios tienen variaciones importantes de pH, y que las concentraciones de macro y micronutrientes pueden optimizarse para mejorar la producción de caña de azúcar. La propiedad dieléctrica del suelo a una temperatura controlada mostró tener variaciones en función de las concentraciones de nutrientes presentes en las muestras con una precisión del 95%.

El primer sistema IA requirió establecer las relaciones entre pH, Fósforo, Potasio, Calcio, Magnesio, Sodio, Conductividad y Nitrógeno-Nitrato con la finalidad de establecer si era viable emplear clasificadores y cuáles. Una vez obtenidos se procedió a relacionar estas con los datos de espectroscopía para finalmente validar con distintos algoritmos el sistema inteligente. Se encontró un error del 5% para las variables de Fósforo, Potasio, Calcio, Magnesio, Conductividad y Nitrógeno-Nitrato; mientras que para el pH y el Sodio fue cercano al 8.5%.

Finalmente, para el segundo sistema se muestra el resultado de los clasificadores utilizados para la estimación de Nitrógeno, Pentóxido de fósforo (P_2O_5), Magnesio, Boro, Cobre y Manganeseo. Los mejores resultados fueron obtenidos por la regresión logística, en donde solo el Magnesio no obtuvo el 100%, obtuvo 77% seguido del Gradient Boosting Classifier y el Random Forest.

Abstract

The raise in cattle and agriculture activities has created no measurable changes in soil properties due to the lack of economic and cultural resources. Therefore, it is necessary to design and implement low cost and easy to use technologies which could help improve the chemistry of soil and facilitate the determination of physicochemical variables on site.

Research has been done using different model and systems to estimate the dose of necessary nutrients, however; there is still a need to work with the accuracy of those and make them more practical when handling and implementing them by no specialized people. Hence, the main challenge of the present project was on one side to employ different algorithms of Artificial intelligence to achieve the needed accuracy and on the other side, create an electronic embedded system which facilitates the lecture of the diagnosis and recommendations to improve the quality of soil and the sugar cane sown.

To obtain the above, it was required to experiment with a capacitive sensor, a thermal one and an optical one; being the first one which was used to obtain information of magnitude and phase from the soil samples at a controlled temperature. Similarly, physicochemical analysis to more than 100 samples of soils in the area of the Montañas in Veracruz which soil type is the Vertisol were done. Once all the information was gathered, the intelligent system that established the relationship between the lab parameters and the magnitude and phase information of the analyzed soils was established.

The results of the physicochemical analysis showed that at least 10 municipalities have important variations in pH, and that the concentration of the macro and micronutrients can be optimized to improve the production of sugar cane. The dielectric property in soils at a controlled temperature showed to have variations as a function of the nutrients' concentrations present in the samples with an accuracy of 95%.

The first system of AI required to establish the relationships among pH, Phosphorus, Potassium, Calcium, Magnesium, Sodium, Conductivity and Nitrogen-Nitrate with the purpose of establishing if it was viable to use classifiers and which. Once those were obtained, they were related to the data of spectroscopy collected to finally validate the relationship among variables with different algorithms. An error of 5% was found for the variables of Phosphorus, Potassium, Calcium, Magnesium, conductivity and Nitrogen-Nitrate; while for pH and Sodium the best accuracy was for an error of 8.5%.

Finally, for the second system the result from the classifiers implemented for the estimation of Nitrogen, Phosphorus pentoxide (P_2O_5), Magnesium, Boron, Copper and Manganese was evaluated. The best results were obtained by logistics regression, where only the Magnesium didn't achieve the 100%, it obtained 77% though followed by the Gradient Boosting Classifier and the Random Forest.

Introducción

El suelo es un recurso natural que debido al tiempo que requiere para su restauración se puede considerar como no renovable adicionalmente, la forma en la que es utilizado y el incremento en la competencia por éste para actividades como ganadería, agricultura o asentamiento hacen prioritario el encontrar tecnologías y metodologías que permitan garantizar su uso adecuado.

En México destaca la degradación química (17.8%) correspondiente a 34.04 millones de hectáreas como el principal proceso de degradación de suelos, cuya causa es principalmente la pérdida de nutrientes debida a la intensificación en el uso agrícola, pecuario y forestal (SEMARNAT, 2014)

En ese sentido en México se destaca la producción de caña de azúcar (séptimo lugar mundial con 56,446,821 t, 2016) por debajo de la producción de Brasil, India, China, Tailandia y Pakistán (FAO, 2016). Durante lo que se lleva registrado de la zafra en México 2017 - 2018, la CONADESUCA (Comité Nacional para el Desarrollo Sustentable de la Caña de Azúcar) ha reportado que la mayor superficie cosechada de caña de azúcar en el país la tiene Veracruz con 327 234.00 ha, que representan el 41.7% de la superficie ocupada con este insumo (CONADESUCA/SAGARPA, 2018) (Figura 1).

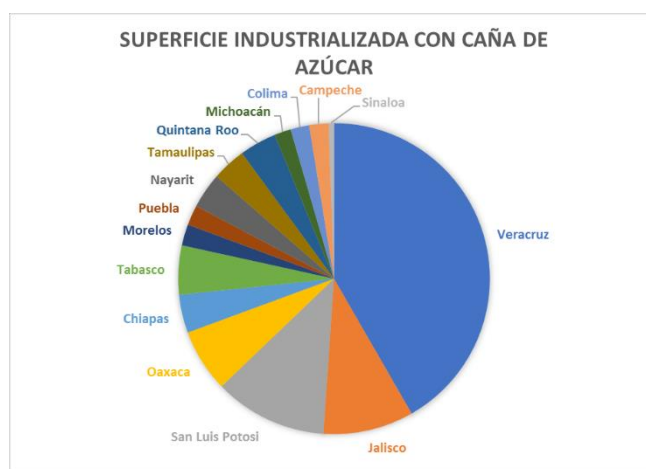


Figura 1. Superficie industrializada con caña de azúcar en la zafra 2017 – 2018.

Si bien el estado de Veracruz es un lugar óptimo para la producción de caña de azúcar porque su cultivo para ser adecuado, requiere una altitud superior a los 1000 msnm, una temperatura de germinación entre 32 y 38° C, una temperatura de desarrollo y absorción de nutrientes óptima entre los 21 y 27 °C, y una precipitación anual entre 1500 y 2500 mm (Moreno-Seceña, 2010); para lograr esa producción de caña de azúcar, se utilizan fertilizantes para incrementar el rendimiento en los cultivos. Si las proporciones aplicadas son las adecuadas, estos son aprovechados por las plantas, sin embargo; si son excesivos, estos permanecen en el suelo durante un tiempo y después son transportados por el

agua o el viento. A la fecha se han hecho estudios utilizando diversos modelos para estimar la dosis de Nitrógeno (N), Fósforo (P) y Potasio (K) necesarios, un ejemplo de esto es el estudio realizado por (Ruiz-Ramírez, 2009) en donde se evaluaron 12 experimentos de fertilización en el cultivo de caña de azúcar utilizando el coeficiente de variación para valorar la calidad de los mismos, como resultado, el 25% no tuvo la calidad adecuada. Otro estudio es el realizado por Palma-López en donde se obtuvieron resultados sobrestimados de la dosis de fertilización probablemente debido al exceso de humedad en el suelo, esto los llevo a determinar las proporciones basándose en la experiencia (Palma-lópez et al., 2002). El determinar de esta forma las concentraciones de nutrientes produce una mayor incertidumbre sobre la composición fisicoquímica de los suelos con producción de caña de azúcar.

Las causas de la degradación de los suelos agrícolas se encuentran relacionadas esencialmente con un manejo inadecuado de los mismos en los sistemas de producción convencionales (Hernández & Pastor, 2008), como consecuencia de la incorrecta aplicación de agro-tecnologías modernas (Altieri, 1999) que generan ecosistemas inestables por la dependencia externa de energía y materiales para su continuidad en el tiempo (Glissman, 2002). Se aumentan los factores limitantes de los sistemas de producción, como los nutrientes y el agua, con interferencia en los ciclos biogeoquímicos (Garrabou S. & González de Molina, 2010).

Sumado a lo ya mencionado, está la quema y requema de los residuos agrícolas o la cosecha mecanizada, que genera disminución en la materia orgánica y aumento en la compactación del suelo (Ascanio & Hernández, 2004). Al realizar esto sistémicamente se empobrece el suelo y se disminuye el rendimiento agrícola del cultivo con el tiempo (Rodríguez et al., 2007). Cabrera J. A. y Zuaznábar al evaluar el balance de carbono y su efecto en la atmósfera concluyeron, entre otras cosas, que la quema causa la degradación del suelo mediante la disminución de Carbono orgánico (C) y que la fertilización con N incrementa el secuestro de C por el incremento de rendimientos (Cabrera & Zuaznábar, 2010). Debido a esto, es necesario contar con información constante que nos permita conocer la composición fisicoquímica de los suelos para de esta forma; aplicar distintas herramientas que favorezcan la fertilidad y trabajabilidad del suelo y así, optimizar la producción del cultivo.

Consecuentemente, resulta primordial estudiar las características de los suelos ocupados para el cultivo de este insumo, ya que, al ser un recurso frágil; además de mantener y/o mejorar las producciones también se promueve la conservación de suelos, el control en el cambio de uso de suelo y reducción en las emisiones de Gases de Efecto Invernadero (GEI).

Por otro lado, restaurar las propiedades en el suelo después de haber sido modificadas es costoso y complejo y ha sido objeto de estudio en numerosos análisis en donde mediante el uso de fertilizantes químicos se pretende recuperar las propiedades del suelo temporalmente y a largo plazo incrementa la degradación de suelos. Adicionalmente, se han hecho estudios para evaluar el impacto de la aplicación del producto de las digestiones anaerobias obteniendo diferentes resultados en función del tipo de material alimentado al proceso de la

digestión, pueden ser utilizados en el suelo como mejoradores orgánicos o como fertilizantes. En su uso se han reportado que no existe diferencia en los resultados en suelos a corto plazo, es evidente que mejoran las propiedades como MO y N, así como la masa microbiana pero también existe el riesgo de incorporar metales pesados y otros compuestos que pudieran no enriquecer el suelo. En cuanto a los cultivos existen desde malos hasta buenos resultados en las distintas investigaciones realizadas hasta el momento. Sin embargo, hace falta una mayor investigación en esta línea para concluir su implementación como fertilizante o mejoradores orgánicos (Nkoa, 2014).

Por otro lado, la evaluación de aplicaciones de abonos orgánicos provenientes de compostas o lombricompostas han dado como resultado el incremento significativo en la concentración de K, P, Mg y Na y en los micronutrientes para Fe y Mn de acuerdo al estudio realizado por (Olivares, Hernández, Vences, Jáquez, & Ojeda, 2012), sin embargo no todos muestras cambios en las propiedades físicas del suelo (Dimas López-Mtz, J., Díaz Estrada, A., Rubin, E. M., & Valdez Cepeda, 2001). Estos fueron realizados en un corto periodo de tiempo. Dentro de los estudios a largo plazo (9 años) realizado por (García-Gil, Plaza, Soler-Rovira, & Polo, 2000) en donde reportan que encontraron las mayores concentraciones de biomasa microbiana en los suelos con tratamientos orgánicos de tratamientos acumulativos, concluyeron que el determinar la biomasa microbiana es un indicador mucho más sensible que el contenido de materia orgánica total, coincidiendo con lo comentado (Hernández-Rodríguez, Ojeda-Barrios, Lopez Díaz, & Arras Vota, 2010), en donde si bien los aportes de materia orgánica son críticos los nutrientes presentes se encuentran en forma orgánica y no necesariamente disponibles para las plantas, para esto es requerido de la biomasa microbiana. Finalmente, existe una necesidad de evaluar diferentes dosis de las distintas fuentes de materia orgánica para concluir su aporte a largo plazo en la fertilidad del suelo así como, la calidad de la materia orgánica que se utiliza para el humus, ya que de esto dependerá la diversidad de microorganismos el contenido de nutrientes (Alberto et al., 2008)

En la evaluación sobre la presencia de ciertos microorganismos adicionados a las compostas se han observado muy buenos resultados en la producción de piñón (Brenda Gabriela Díaz-Hernández, 2013) y en el crecimiento de plantas como *A. denticulata* y *E. polystachia* para su posterior siembra en suelos degradados (Hernandez-Cuervas, Guerra-De la Cruz, Santiago-Martínez, & Cuatlal-Cuahutencos, 2011).

Socialmente se promueven actividades como el Programa Integral de Agricultura Sostenible y Reconversión Productiva en Zonas de Siniestralidad Recurrente cuyo objetivo es aprovechar el suelo de acuerdo con su vocación natural y el Programa de Manejo de Tierras en la modalidad de proyectos ecológicos cuyo propósito es tener un programa de manejo adecuado de los recursos utilizados. Sin embargo; para el 2004 sólo se habían abarcado 1.4 millones de hectáreas mientras que la superficie sembrada en ese año ascendía a aproximadamente 20 millones de hectáreas. De igual forma, Lang-Ovalle y su equipo de trabajo han investigado la actitud de productores de caña de azúcar de la región del Golfo centro de Veracruz encontrando que el 100% de los ítems ensayados consideraron el enfoque de la

sustentabilidad y que la actitud puede ser un indicador social para la evaluación de la sustentabilidad de un proceso de producción agrícola (Lang-ovalle, 2007). Esto es relevante para el propósito de esta investigación ya que, se desea evaluar la forma más eficiente y económica para contribuir al desarrollo del campo mexicano que fomente un adecuado manejo de tierras y contribuya a mantener y/o incrementar la capacidad productiva pero de una forma sustentable y esto muestra que los productores se interesan por mejorar sus técnicas de producción.

Por lo anterior, se pretende elaborar un sistema que permita facilitar la realización de la caracterización y la restauración de suelos, enfocándose específicamente al sector cañero de las altas montañas de Veracruz. Para obtenerlo, este proyecto requiere utilizar un sistema inteligente que pueda analizar las condiciones actuales de los terrenos y automáticamente prediga mediante técnicas de inteligencia artificial las acciones a realizar para optimizar sus cosechas mediante el restablecimiento de la química del suelo.

Hipótesis

Mediante el desarrollo de nuevos sistemas electrónicos con inteligencia artificial se podría realizar una estimación de la condición del suelo para monocultivos de caña de azúcar, así como la determinación de una estrategia de restauración para un posible incremento en su utilidad.

Objetivo General

Crear un sistema electrónico inteligente capaz de analizar las condiciones de la situación actual de los Vertisoles en la región de Las Montañas en Veracruz, para predecir automáticamente mediante técnicas de inteligencia artificial las acciones a realizar para optimizar sus cosechas mediante la restauración de la química del suelo.

Objetivos específicos

- Establecer la metodología para la caracterización de Vertisoles con producción de caña de azúcar como monocultivo en la región de Las Montañas en el estado de Veracruz.
- Desarrollar un sensor de conductividad eléctrica del suelo que realice un análisis frecuencial de magnitud y fase.
- Desarrollar un sensor que logre medir la conductividad térmica del suelo mediante análisis frecuencial de magnitud y fase.
- Realizar la caracterización fisicoquímica de los Vertisoles con producción de caña de azúcar.
- Desarrollar un sistema basado en algoritmos de inteligencia artificial para estimar la concentración de materia orgánica, la capacidad de absorber cationes de Ca, Mg y K, la disposición de Ca, Mg y K, las sales solubles y textura.

- Desarrollar un sistema basado en algoritmos de inteligencia artificial en donde mediante las recomendaciones de los expertos se pueda definir las acciones necesarias para restaurar la química del suelo en estudio.
- Desarrollar un plan estratégico eficiente y económico para el campo con producción de caña de azúcar en la región de Las Montañas de Veracruz.

CAPITULO I. Antecedentes

Para el desarrollo del presente trabajo ha sido necesario evaluar lo investigado y estudiado en cuanto a caracterización de suelos, la correspondiente relación de las variables físicas y químicas presentes y la restauración de la composición del suelo; las metodologías utilizadas actualmente para determinar estas; y los algoritmos de inteligencia artificial empleados para evaluar el comportamiento de las variables tanto en caracterización como en restauración.

1.1 Suelos

1.1.1. Caracterización

En el marco mundial, ha sido investigada en el Norte de Costa Rica, en donde Chaves S. M. y Araya V. A. en el 2007 concluyeron que la caña presenta una alta necesidad de requerimientos nutricionales y por lo tanto, puede extraerlos del suelo o bien ser aportados por fertilización comercial (Chaves-Solera & Araya-Vindas, 2007). En el caso de que los nutrimentos no sean reforzados se termina con suelos infértiles e improductivos. Adicionalmente, consideraron necesario que, al tener variaciones químicas de manera natural en los suelos, estas se deben identificar y adoptar medidas para manejos diferenciales.

De acuerdo con información reportada por Hüskes solo del 1 al 3% de la aplicación del pesticida en los campos de caña de azúcar llega al sitio de acción (Hüskes & Levsen, 1997). Ya en el suelo, su destino depende de variables tanto fisicoquímicas como biológicas de la matriz y la pérdida de pesticida dependerá de las características del pesticida, las condiciones ambientales y prácticas de uso; entre otros (Lourencetti, Demarchi, & Ribeiro, 2008).

En el marco nacional, otros estudios revisados sobre la situación de suelos y sus necesidades en producción fueron los realizados por SAGARPA y el SIAP, en el suelo utilizado para la producción de caña de azúcar por ingenio para alcanzar agricultura de precisión en el 2009, estando en la región de estudio 6 ingenios, en cada estudio se presentan los suelos con problemas (de nutrimentos para la producción de caña de azúcar) y las necesidades de fertilización para cada ingenio (SEMARNAT, 2002a). Actualmente se desconoce cómo se encuentren estos suelos y si los productores han realizado las aportaciones necesarias por medio de fertilizantes o si han sido excesivas o deficientes afectando las propiedades de los suelos. Por otro lado, se desconoce si ha habido cambio de uso de suelo en esta región de los productores de café y otros cultivos hacia la producción de caña de azúcar.

Otro de los problemas reportados en los suelos con producción de caña de azúcar ha sido la compactación y baja retención de humedad (Zérega & Hernández, 2005). De acuerdo a los estudios encontrados para este problema se agregan cubiertas vegetales y materia orgánica, Guzmán O. I. propone el uso de una lombriz cuya especie es *Lumbricus Friendi* ya que es estructuradora de suelo y que ayuda a la descompactación de suelos de alto impacto productivo (Guzmán, 2006).

1.1.2. Relación entre variables físicas y químicas

De acuerdo a la norma NOM-021-RECNAT-2000 para determinar el grado de fertilidad del suelo las variables a monitorear indicadas son pH, densidad aparente y real, humedad, materia orgánica, nitrógeno inorgánico, textura, fósforo extraíble, capacidad de intercambio catiónico (CIC), cationes intercambiables (Calcio (Ca^{++}), Magnesio (Mg^+), Sodio (Na^+) y Potasio (K^+)), micronutrientes (hierro, manganeso, zinc y cobre) y boro (Diario Oficial de la Federación, 2002). Adicionalmente, la FAO y el INEGI incluyen las propiedades de estructura y color (FAO, 2015; Instituto Nacional de Estadística y Geografía, 2000). La siguiente tabla (Tabla 1) presenta las variables separadas en físicas y químicas.

Físicas	Químicas
Textura	Materia orgánica
Estructura	CIC
Densidad real (densidad específica relativa)	Nitrógeno inorgánico
Conductividad eléctrica	Cationes intercambiables (Na, Ca, K y Mg)
Humedad	Fósforo
Temperatura	Sales Solubles
Densidad relativa	pH
Color	Micronutrientes

Tabla 1. Variables fisicoquímicas que normalmente son determinadas para establecer el grado de fertilidad del suelo.

La suma de los compuestos (orgánicos e inorgánicos) y las condiciones químicas presentes o ausentes en los suelos determinan las propiedades físicas de los mismos (Coras Merino, 2003). Por lo tanto, este vínculo será utilizado para seleccionar las propiedades físicas a determinar mediante sensores y desarrollar el sistema para inferir otras variables. En el siguiente diagrama (Figura 2) se pueden observar las propiedades físicas y químicas y la relación entre ellas. Cada suelo está formado por diferentes porcentajes de arcilla (que proporciona mayor área superficial y retención de agua; es el almacén de nutrientes), limo (que proporciona los nutrientes solubles y mayor plasticidad que la arena) y arena; estos definen la propiedad de textura que resulta de apoyo en la determinación aproximada de la cantidad de materia orgánica y la retención de agua, por otro lado, la arcilla, el limo y la arena se unen formando agregados debido a la presencia óxidos coloidales de hierro (Fe) y manganeso (Mn), materia orgánica coloidal y minerales arcillosos (Coras Merino, 2003) y son evaluados y definidos como la variable de estructura del suelo. Estos agregados resultan de importancia para el movimiento de agua, la aireación, porosidad y la conducción térmica. En cuanto a la porosidad esta se encuentra relacionada con la densidad que es determinada de dos formas, la real en donde proporciona una idea de la proporción de los elementos presentes y la aparente que a mayor profundidad en el suelo debería ser mayor debido a que disminuye la concentración de materia orgánica, menor agregación y mayor compactación. La conducción térmica nos lleva a otra variable denominada temperatura que influye en la velocidad de disponibilidad de nutrientes (Nitrógeno, Fósforo, Azufre y Calcio) (Broome, n.d.; FAO, 2002; N.C., 1990).

Adicionalmente están las variables de conductividad eléctrica, color y humedad, La primera está directamente relacionada con la concentración de sales solubles,

ya que a mayor concentración de estas hay mayor conducción de la corriente eléctrica (Barbaro Lorena A., Karlanian Monica A., n.d.)(Diario Oficial de la Federación, 2002) y se puede complementar con la determinación de cationes intercambiables.

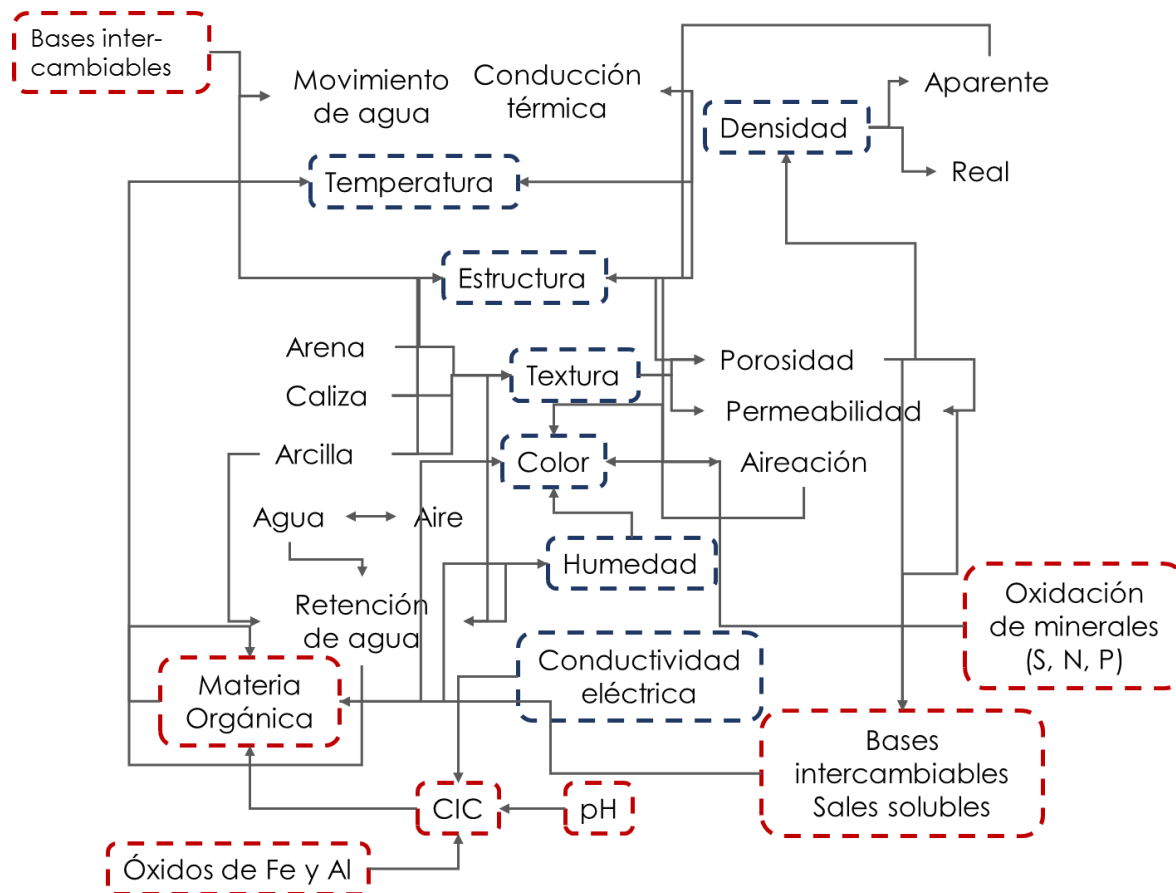


Figura 2. Diagrama que muestra la interrelación entre variables físicas y químicas del suelo.

El color se encuentra relacionado con el grado de oxidación de los minerales y es influenciado principalmente por la humedad ya que esta modifica al primero. Y finalmente, la humedad está ligada a la movilidad de nutrientes en el suelo y permite que la materia orgánica sea fácilmente biodegradable (Fernández Linares et al., 2006).

1.1.3. Restauración

Entre los métodos de remediación empleados actualmente se ha estudiado el uso de composta para tratar suelos con contaminación por metales pesados, en el estudio revisado de Ferrell M. en el 2009 utilizó una composta derivada de residuos municipales mezclados y separados. En este estudio se concluyó que el utilizar compostas de composición variada pueden servir para disminuir la toxicidad de elementos potencialmente tóxicos. En cuanto al crecimiento de plantas lo que se encontró es que no se alcanzaron los estándares en el establecimiento de plantas debido a que las compostas no cumplían con las especificaciones para ser utilizados en agricultura (Ferrell & Jones, 2009).

También se ha evaluado el uso de compostas, de residuos verdes y lodos residuales, mejoradas con minerales para sitios contaminados con metales, encontrando que la composta de residuos verdes redujo un 48% los lixiviados mientras que la otra composta los incrementó en uno se los componentes, esto debido a la formación de complejos entre la materia orgánica y los metales. Una desventaja de esta metodología es que la aplicación de lodos residuales en tierras con producción agrícola puede causar enriquecimiento gradual de metales como el Cd (Keller, Kayser, Keller, & Schulin, 2001). En este caso de estudio, se pretende estudiar tanto los residuos municipales como lodos residuales.

Entre las investigaciones que se han realizado relacionadas con la contaminación debida a la agricultura intensa se encuentra la contaminación de agua subterránea, en este sentido Dwivedi U.N. señala que se pueden utilizar barreras en el suelo que conjugue el uso de electrocinéticas con Fierro cero Valente (Fe) (Dwivedi, Mishra, Singh, & Tripathi, 2007). Por otro lado, se han caracterizado bacterias sulfato y nitrato reductoras en suelos con compuestos de petróleo (Gevertz, Telang, Voordouw, & Jenneman, 2000). De igual forma, se ha encontrado de gran apoyo la rotación de cultivos para reducir las concentraciones de nitratos en la zona raíz.

El manejo adecuado del nivel freático de agua se ha propuesto como una forma de remover el exceso de nitratos del suelo y proteger el agua del subsuelo, al estimular el a las bacterias desnitrificadoras y que remuevan el nitrato convirtiéndolo en N_2O y N_2 (Dwivedi et al., 2007). En algunos casos se ha utilizado la fitoremediación, tanto para los nitratos como para pesticidas, sin embargo; para este último se requiere modificar genéticamente las plantas para mejorar su habilidad de degradación (El-Sheikh & Ashour, 2010). Abundando un poco más en este tipo de remediación, nuevamente se reporta que para su uso las propiedades del suelo que controlan la disponibilidad de la no-sobreacumulación en plantas, son el pH, la mineralogía del suelo y la materia orgánica (Keller & Hammer, 2004).

Con el uso de microorganismos, se ha encontrado durante su uso que debe realizarse un seguimiento en largos periodos de tiempo ya que debido a las características del sitio (humedad, temperatura, lluvia, radiación ultravioleta) los resultados obtenidos en laboratorio varían en el sitio contaminado (El-Sheikh & Ashour, 2010).

Por otro lado, Cycon M. indica que la degradación microbiana se considera como el principal factor determinante en el destino de la diazonina y otros insecticidas organofosforados en el ambiente. Por lo tanto, en su investigación trabajó con *Serratia* y *Pseudomonas genera* concluyó que además de que este mecanismo microbiano es uno de los principales mecanismos de disipación de la diazonina en suelos es necesario tener conocimiento de los requerimientos de estas cadenas degradadoras (Cycoń, Wójcik, & Piotrowska-Seget, 2009).

Se ha observado que al disminuir la densidad del inóculo de microorganismos, solo una porción pequeña pudo sobrevivir a la competencia inicial y participar en la degradación del pesticida (Ramadan, El-Tayeb, & Alexander, 1990). El introducir un inóculo inicial mayor puede compensar el decremento inicial de la población,

y los sobrevivientes se pueden multiplicar y degradar contaminantes (Comeau, Greer, & Samson, 1993; Duquenne, Parekh, Gatrux, & Fournier, 1996).

Resulta difícil estimar de manera precisa la fracción de microorganismos específicos involucrados en la pérdida de pesticida debido a que hay muchos factores que impactan este proceso (Cycoñ et al., 2009). Sin embargo, se ha señalado que los parámetros más importantes involucrados en el efecto de la degradación de los microorganismos son el pH, la temperatura, concentración de pesticida y su biodisponibilidad, así como la cantidad de materia orgánica (Karpouzas & Walker, 2000; Singh, Walker, Denis, & Wright, 2006).

Por un lado, se ha señalado que un elevado contenido de materia orgánica conduce a una reducción en la biodisponibilidad de los pesticidas organofosforados y su velocidad de degradación (Karpouzas & Walker, 2000); mientras que por otro lado, hay estudios que indicaron que la materia orgánica no tiene efecto significativo en la disipación de fenamifós y clorpirifós (Singh et al., 2006).

En el trabajo realizado por Margesin R. se evaluó la actividad microbiana en suelos con bioestimulación y sin ella en el proceso de descontaminación de suelo contaminado con combustibles y minerales. Se utilizaron varias fuentes de N, P y grandes cantidades de carbón orgánico; y el tener este último resulta en el consumo más rápido de los nutrientes inorgánicos disponibles (N y P) mientras que las fuentes de N y P incrementan la biodegradación de petróleo. Sin embargo, varias fuentes de P pueden tener diferentes efectos en la biodegradación dependiendo en su solubilidad y toxicidad (Margesin, Zimmerbauer, & Schinner, 2000; Mills & Frankenberger, 1994).

Igualmente se ha estudiado ampliamente el uso de gusanos para remediar sitios contaminados por pesticidas generando distintos resultados en función del tipo de gusano, ya que este, responde diferente al tipo de suelo, tipo de contaminante, disponibilidad de comida, y otros parámetros ambientales (Curry & Schmidt, 2007; Edwards & Bohlen, 1996; Lavelle, 1998).

En este punto, se debe recordar que cada caso de estudio presenta características diferentes y, por lo tanto; la efectividad de la remediación radica en evaluar las tecnologías y los efectos en el suelo a restaurar.

Otro método disponible de remediación de suelos que se ha evaluado y se pretende estudiar en el presente proyecto es el de biolabranza, este método ha sido utilizado para tratar suelos contaminados con hidrocarburos, después de hacer las pruebas de tratabilidad correspondientes se elaboró una celda de tratamiento y se trataron los suelos en relación de 1:0.6 (suelos:lodos) para tener una humedad aproximada en suelo de 17 a 20%.

De igual forma, se ha utilizado la cachaza y bagazo de caña para tratar suelos con hidrocarburos logrando remociones de 60.1% para bagazo y 51.4% para la cachaza (García-Torres & Ríos-Leal, 2010). Debido a que estos materiales tienen una composición química con nitrógeno y fósforo estos ayudan en la activación de la flora microbiana autóctona (Eweis & Ergas, 1999); (Semple & Reid, 2001).

1.2 Metodologías para determinaciones en suelos.

En lo que concierne al tema de sensores y sistemas fabricados con estos se han realizado extensos trabajos utilizando distintos principios físicos para determinar una o más propiedades físicas y químicas, en la Tabla 2 a continuación se puede observar un resumen de los sensores utilizados en suelos. Entre estos, los sensores electromagnéticos y eléctricos destacan por su bajo costo y alta durabilidad; han sido utilizados para evaluar textura, materia orgánica, humedad, salinidad, profundidad, capacidad de intercambio catiónico y nitrato residual o total utilizando diversas propiedades físicas o químicas en el suelo. Por un lado; Sophocleous & Atkinson, (2015) han desarrollado un sensor que mide conductividades de hasta 0.5 mS/cm y se ha utilizado para correlacionarlo con el contenido de agua en suelo e inferir la porosidad del mismo, este se encuentra en la fase de prueba aún pero, se han obtenido resultados prometedores.

Authors	Year	Location	Methodology	Instrument	Determined variables	Conclusions
Sophocleous M., et. al.	2015	Laboratory	Electrical conductivity	Conductivity sensor	Electric conductivity (EC)	The determined voltage was directly proportional to the current with a correlation (R^2) above 0.99. Noise was found in values below 9mV. Temperature must be considered in the following studies due to the variations conductivity presents when temperature changes.
Strzałkowski K., et. al.	2015	Laboratory	Photopyroelectric calorimetry in back detection configuration (BPPE) and Infrared thermography	300mW power blue diode laser, a 0.4 mm thick LiTaO ₃ , provided with CrAu electrodes and a SR850 dual-phase lock in amplifier	Thermal properties	Results showed less uncertainty in the determinations obtained by photopyroelectric calorimetry ($0.005 - 0.021 \text{ m}^2/\text{s} \times 10^{-6}$); while the data obtained with thermography were among 0.085 and $0.169 \text{ m}^2/\text{s} \times 10^{-6}$
Paz-Kagan T., et. al.	2015	Israel and Germany	Optics	Airborne Imaging spectroscopy	Spectral soil quality index (SSQI) Soil quality index (SQI)	Soil properties were predicted well to moderately depending in the many factors. Properties were predicted using lineal models obtaining a correlation (R^2) of 0.84 and 0.78 for SQI for each analyzed soil and the correlations between SSQI and SQI were 0.7
Calamita, G., et al.	2014	Italy	Electromagnetics	EMI sensor with multy frequency (GEM 300)	Aparent electric conductivity (EC_a) Moisture	The correlation (R^2) between the conductivity and moisture was in the range of 0.46 to 0.69. A movil average was used to adjust variations, which were due to sensor position and not because of changes in soil.
Li Z., et al.	2014	Oklahoma	Selective ion	Wireless sensors network with flow injection analysis	Nitrates	Despite measurements were successfully determined in manually extracted soil, the system was not successful due to continuous calibrations.

Authors	Year	Location	Methodology	Instrument	Determined variables	Conclusions
Kodaira M., et al.	2013	Hokkaido, Japan	Optics	Visible and near infrared (vis-NIR 305 - 1700 nm) soil reflectance spectra	Moisture Organic Matter (OM) pH EC Cationic Exchange Capacity (CEC) Total Carbon Ammonium nitrogen Hot water extractable nitrogen Nitrates Total Nitrogen Available phosphorus Phosphorus absorptive Coefficient (PAC)	Twelve spectroscopic models were developed and correlations obtained were in the range of 0.45 to 0.93
Kuang B., et al.	2013	Czech Republic, Denmark, UK	Optics	On line spectroscopic system (vis-NIR)	Organic Carbon (OC) Total Nitrogen Moisture	Precision of the online determinations was classified as excellent with an Residual Prediction Deviation (RPD) from 1.88 to 2.01 for organic carbon, 1.96 to 2.22 for total nitrogen and 2.76 to 3.06 for moisture.
Kweon G., et al.	2013	Six states in US	Electric conductivity and optics	On-the-go sensor with 660 nm red and 940 nm near infrared wavelengths with an electrical conductivity sensing unit.	OM CEC	Good results are shown with a correlation R^2 higher than 0.8 r
Nocita M., et al.	2013	Luxembourg	Optics	Vis-NIR spectroscopy	Moisture OC	The determinations of moisture for many measurements ranges had a correlation R^2 of 0.78 to 0.87 whereas the calibration of dry samples had a very low correlation (0.25 -0.63). Finally, the moisture predicted by the index had a correlation of 0.8 to 0.86.
Sudduth K. A., et al.	2013	Down town Missouri	Electric conductivity and mechanics	DUALEM -2S EMI Sensor	EC Depth	The highest correlation R^2 found was 0.84 for EC_a . The two layers model presented an standard deviation (SD) in cm of 8, while the three layer model was of 3.2 cm.

Authors	Year	Location	Methodology	Instrument	Determined variables	Conclusions
Mahmood H. S., et al.	2012	Netherlands	Optics	Vis-NIR Spectroscopy and EM38 Sensor fusion	Texture pH Total OC Total Nitrogen Nitrogen - Carbon relationship	The results obtained by the fusion were better ($R^2 = 0.67$ to 0.87) than the results obtained by the single methods.
Serrano J. M., et al.	2010	Portugal	Electromagnetics	Electric Conductivity and GPS	EC _a Altitude pH Pasture dry matter	A positive and significant correlation was found between EC _a and pH ($R^2 = 0.57$) and a negative one between the first and the altitude ($R^2 = -0.49$). There was no significant relationship found with the variables of macronutrients, texture and OM. The methodology to evaluate soils with permanent pasture was simplified.
Viscarra-Rossel R. A., et al.	2005	Kelso NSW, Australia	Optics	VIS-NIR-MIR spectroscopy	pH _{Ca} pH _w Lime requirement OC Clay Lime Sand CEC Exchangeable Ca Exchangeable Al Nitrate - Nitrogen Available Phosphorus Exchangeable K EC	MIR methodology showed to be the most precise one for the 80% of the determinations. NIR was the most precise for Al determination. The fusion of all the methodologies didn't show more precision than the determinations made by MIR. The determinations with less precision were CEC, Ca, Al, NO ₃ , P, K and EC.
McBratney A. B., et al.	2006	Kelso NSW, Australia	Optics	DRS Diffuse Reflectance Spectroscopy (VIS-NIR-MIR)	pH Clay Lime Sand OC CEC	The determinations were precise with an $R^2 = 0.7$ to 0.9 for each of the evaluated characteristics.
Viscarra-Rossel R.A., et al.	2009	Australia and Laboratory	Optics	Portable visible-near infrared spectrophotometer (vis-NIR: 400 - 2500 nm)	Colour Mineral composition Clay content	There were differences between the in situ measurements and laboratory in the wavelength related to the content of water and another not related to minerals. The correlation found for clay content was $R^2 = 0.85$ and there was no difference between the predicted for in situ and laboratory samples.

Authors	Year	Location	Methodology	Instrument	Determined variables	Conclusions
Bou-Kheir R., et al.	2008	Lebanon	(Geographic Information System) GIS - decision tree model	maps, satellite images soils studies	Distribution of soil and bedrock	For the model there was a 95% of coincidence but the 87% of an independent data base. It is necessary to have satellite images of a higher quality and more detailed GIS layers as well.
Capolupo A., et al.	2015	Italy	Photogrammetry drones	Images obtained with a precision of 0.03m, (better than other devices in this area) DEM	Accumulation of water in soils yearly rainfall Evapotranspiration Topographic Index Wheather - Topographic Index Geostatistics	It is possible to determine the areas contaminated by Cupper robustly
Zhang J., et al.	2016	Subtropical forest	drones	Micro drones MD4 - 1000 Ortho-images DEM	Drone-derive canopy, Stand level attributes Topographic variables Edaphic variables (OC, TK, TP)	A relationship between the OC and the richness of species, the TK is negatively related with the richness and positively with the evenness of saplings. The most helpful variables were the related to canopy.
Poznyak T., et al.	2007	Laboratory	DNNO (Differential neural network observer)	Laboratory methods and ANN (DNN)	Anthracene	There was a prediction with an error of -0.02 ± 0.0795 . Therefore, It can be used to predict and control the degradation kinetics of anthracene.
Park J., et al.	2011	Korea	Decision tree algorithm, GIS-based spatial analysis	Forecasting model, Forward model (FWD) and Backguard model (BWD) Original DT	Gravel content of topsoil, Texture Erosion Slope Soil depth Drainage class Topography Soil ecology (microbial diversity)	FWD and BWD models were twice precise than the Original DT The most significant variables for FWD were: depth, texture and drainage; while for the BVD were drainage, depth and gravel. All of them to determine soil ecology. In both methods there was under and above estimation. Strict conservation areas and potential development were defined.
Lee M. H., et al.	2014	Laboratory	Electromagnetics	Capacitances with an ions trap	Moisture	There is high sensitivity (1.27 $\mu\text{F}/\%$) in a measurement range of 21 - 28% of gravimetric water content and a repeatability of $\pm 0.71\%$ and $\pm 0.55\%$ in low and high conditions of gravimetric water content and a constant concentration of NaCl 0.025M.
Feilberg A., et al.	2015	Laboratory	Optics	Proton-transfer-reaction mass spectrometry	Volatile Organic Compounds (VOC) Hydrogen sulfide Ammonia (NH ₃)	The comparison between the determinations of ammonia had a correlation (R ²) of 0.997

Authors	Year	Location	Methodology	Instrument	Determined variables	Conclusions
Nourouzi M. M., et al.	2012	Laboratory	ANN	Back Propagation Model (BPM)	Herbicide glyphosate (2-phosphonomethylamino) acetic acid)	The answer to both models was $R^2 = 0.8$. After doing more experiments, 0.2% of difference was observed among the model results with the experiments.
Naderi-Boldaji M., et al.	2014	Iran	Electric conductivity and dielectric properties	Veris 3100 sensor combined with a horizontal penetrometer equipped with a dielectric sensor	EC Resistance to penetrometer Volumetric water content (VWC) Bulk density (BD)	There was no correlation between EC and BD. A significant correlation was found between EC and VWC ($R^2 = 0.98$) Electric conductivity is affected by the variations of texture and VWC. Thus, fusionating the procedures can lead to correct results.
Naderi-Boldaji M., et al.	2011	Laboratory	dielectric properties	Dielectric sensor combined with a strain-gauge load cell and installed on a tine with thickness of 25 mm.	Mechanic resistance Water content (WC)	The relationship between the WC and the voltage measured presented a correlation (R^2) of 0.989 and for BD 0.918. Studies are missing to confirm its use in dynamic use.
Carvalhoes Dias P., et al.	2013	Laboratory	Thermal dissipation	Single probe heat pulse sensor comprised with an npn junction bipolar transistor	WC	When compared with other measuring instruments, this one presented six times more sensibility than the Dual/multi probe heat pulse sensor (DPHP) and twice more than the Single probe heat pulse sensor BPHP.
Mizuguchi J., et al.	2015	Laboratory	Electric conductivity	Frindging field capacitance	WC	The relationship between the determination with the sensor and the gravimetric method was lineal ($R^2 = 0.94$) The presence of moisture can lead to variations in temperature up to 5%. In dry samples the variation es of 1.5%.
Skierucha W., et al.	2010	Laboratory	Dielectric permittivity	Frequency domain reflectometry (FDR) and Time domain reflectometry (TDR)	Moisture Salinity	The proposed model (FDR) can measure dielectric permittivity in the proposed range. With a higher difference in the range of 10 - 50 MHz especially in salty soils. For the determination of moisture both methods determine similar results.
Sudarsan B., et al.	2016	Laboratory	Optics	Digital microscope AD 7013MT	Texture OM	A correlation for the prediction of sandy soils was found with an R^2 of 0.63 and for OM of 0.83.

Elaboración de un sistema inteligente para la estimación de propiedades fisicoquímicas de suelos con producción de caña de azúcar

Authors	Year	Location	Methodology	Instrument	Determined variables	Conclusions
Yin Z., et al.	2013	Laboratory	Optics	NIR spectroscopy	Moisture	There was a maximum correlation (R^2) of 0.86 and a minimum of 0.6 for four different soils. Hence, an individual calibration must be done.
Jackson T., et al.	2008	Laboratory	Electric conductivity	Nanotechnology-based Microelectro Mechanical Systems (MEMS) Sensor equipped with Water sensitive polimer.	Temperature Moisture	Obtained results for the proposed methodology and the destructive indicated they are determined with precision ($R^2 = 0.988$) for both moisture and temperature.
Murata H., et al.	2014	Laboratory	Electric conductivity	Sensors systems	EC	Three patterns were evaluated in which the error varied from 0.5% to 6.8% between the model and the measurement. As a conclusion, the system can be used to measure the change in the EC distribution.
Ji W., et al.	2016	Canada	Optics	MIR spectroscopy	OM WC BD CEC Calcium (Ca) Magnesium (Mg) pH Iron (Fe) Copper (Cu) Phosphorus (P) Nitrates- Nitrogen ($NO_3 - N$) Potassium (K) Sodium (Na)	A correlation (R^2) of 0.75 was found between OM and N, Fe, Ca, Mg, C EC, WC, and BD in a soil and a correlation of OM with Ca, Mg, CEC, WC, and BD.
Birrell S.J., et al.	2001	Laboratory	Optics	Selective ion electrode	Nitrates	The system handled manually has a precision (R^2) of 0.9
Gravalos I.G., et al.	2012	Laboratory	Electric conductivity	Modification of the sensor Diviner 2000 (Moisture sensor)	WC	The system showed having 99% of sensitivity in the first 10 cm and 92% was in a ratio of 3 cm outside the access of the tube.
Roberts D.F., et al.	2011	Nebraska	Optics and images	ACS-210 Circle and satellite images	OM	Amber and NIR sensors had a correlation (R^2) of 0.98. The red and green images and NIR had a correlation (R^2) of 0.94

Authors	Year	Location	Methodology	Instrument	Determined variables	Conclusions
Pelltier M.G., et al.	2012	Laboratory	Sensors structure and a second combination of high quality sensors	Sensors of WC, strength, EC, depth and current	WC EC Mechanical strength	Once the system was joint, the data correlation (R^2) for the WC was 0.99, for EC was 0.99 and the mechanical strength was of 0.993.
Brocca L., et al.	2011	Italy	Remote sensors	AMSR-E ASCAT MetOp	Moisture	The correlation coefficient (R^2) of the modelled data vs the real was of 0.74 for ASCAT and 0.62 for AMSR. When using the CDF (Cumulative Density Function) the correlation is incremented to 0.81 and 0.69 respectively.
Yurui S., et al.	2008	Laboratory	microwaves	SFI (swept frequency domain instrument)	WC	The system had a precision of 0.98% from the complete scale.
Dias P. C., et al.	2016	Laboratory	Thermal properties	Thermoelectric instrument	Moisture	The sensor presented a sensitivity of 2.83 °C and the repeatability tests were + 1 LSB
Mouazen A. M., et al.	2014	East Anglia, UK	Optics and ANN	vis-NIR spectroscopy, ANN and MLR	Moisture OM OC Clay content BD Plasticity Index	Moisture and OC were determined precisely ($R^2 = 0.97$ and 0.72 respectively). Clay content and plasticity index were determined with moderate precision. There were strong correlations between moisture, clay content and plasticity index.
Allen F. M., et al.	2007	California	Optics, dielectrics, electric	Infrared CO ₂ sensors, potentiometers, ion selective electrode, minirhizotron and automated microscope and RTD	Respiration process temperature moisture mycorrhizal fungi Nitrogen	Variations occurred in a distance of 50 cm and intervals of 15 min, 50% of the respiration was due to the roots and fungi during growing season. The main groups predicted to affect respiration resulted in having minor effects. Nitrogen pulses were tracked for 24 hrs and 10 cm depth

Authors	Year	Location	Methodology	Instrument	Determined variables	Conclusions
Amaro F., et al.	2011	-	Luminescence	T. Thermophila MTT1 or MTT5 genes	Cadmium Copper Zinc Lead Arsenic Mercurium	The MTT5Luc show lower concentrations detected than the MTT1Luc for all heavy metals except Zinc but all of the determinations by both biosensors were below the maximum allowed concentrations according to the European Directive.

Tabla 2. Trabajos realizados con distintos tipos de sensores para evaluar propiedades físicas, químicas y biológicas

De igual forma; el trabajo realizado por Serrano, Peça, Marques da Silva, & Shaidian, (2010) en donde se evalúa la variación en el rango de fertilización basándose en la medición de la conductividad eléctrica aparente en el suelo resulta interesante. Al medir esta última y evaluar las correlaciones, encontraron que existe correlación positiva con el pH y negativa con la altitud; y reportan no haber encontrado relación con macronutrientes, textura y materia orgánica.

Otro tipo de sensores utilizados son los ópticos y radiométricos, su ventaja es que permite diferenciar efectos de distintas fuentes con el uso de un solo sensor. Se han utilizado para determinar textura, materia orgánica, humedad, composición mineral, entre otros. El trabajo efectuado por Kodaira & Shibusawa, (2013) reporta que el sistema de sensores utilizado tuvo una precisión igual o mayor a los resultados obtenidos por metodologías convencionales. Entre las desventajas de estos sistemas se encuentra la humedad del suelo, ya que altera drásticamente el albedo del suelo, que de acuerdo con lo reportado Nocita M. et. al. para suelos húmedos, la diferencia entre el índice refractivo del suelo (aproximadamente 1.50) y el agua (aproximadamente 1.33) es más pequeño que para suelos secos, donde las partículas están rodeadas por aire (aproximadamente 1.00) (Nocita, Stevens, Noon, & Van Wesemael, 2013), y de acuerdo al estudio realizado por Kweon y Maxton (2013), 10% de la humedad incrementada en las muestras de suelo ocasionó más de 43 en la lectura de reflectancia roja y 100 en la NIR disminuida en las pruebas de laboratorio. Debido a que la humedad es el factor más significativo además de la materia orgánica para la medición de la reflectancia con sensores ópticos con longitud de onda dual, la variación de la humedad debería ser considerada cuando los datos de campo son combinados para la calibración, o cuando los datos de muchos sitios son calibrados por un modelo universal (Kweon et al., 2013). Finalmente, cabe destacar que estos sistemas tienen un costo elevado y la mayor parte del tiempo no es posible adquirirlos.

En cuanto a los estudios realizados en México se pueden considerar los realizados sobre los efectos del cambio climático en el régimen pluvial, ya que esto genera incertidumbre sobre qué hacer o cómo planificar los cultivos. Para esto, Sánchez Cohen presenta una herramienta basada en un modelo matemático que indica el nivel del rendimiento de un cultivo a falta de agua. El algoritmo integra información de más de 2000 estaciones climáticas distribuidas en el país, provenientes de la red de estaciones del Servicio Meteorológico Nacional (SMN) (Agencia Informativa Conacyt, 2015). De igual forma existen sensores de tipo mecánico, acústico y neumático que son utilizados para determinar algunas propiedades físicas y mecánicas como son compactación, profundidad y textura; debido a los principios en los que están basados los sensores. Finalmente, también se encuentran los sensores electroquímicos, donde se han utilizado para medir concentraciones de iones específicos como H^+ , K^+ y NO_3^- . Al utilizarlos en sitio, hay que considerar la muestra de suelo a utilizar, ya que puede no ser viable para realizarle determinaciones con este tipo de sistemas.

Debido a la compleja naturaleza de los suelos para agricultura, una técnica para medir información sobre un solo parámetro del suelo se considera limitante cuando ciertas incógnitas como la cantidad de lluvia, precipitaciones, temperatura del suelo, tamaño de partícula y muchas otras distorsionan el valor de salida de

los sistemas de sensores. Esta falta de habilidad se puede disminuir al utilizar distintos métodos de medición e integrar la información obtenida y proveer estimados de las propiedades del suelo más robustas (Mahmood, Hoogmoed, & van Henten, 2012)

1.3 Inteligencia artificial y determinaciones en suelos.

En cuanto a las redes de Inteligencia Artificial (IA) existen trabajos realizados en clasificación de la calidad de sedimento (Alvarez-Guerra, González-Piñuela, Andrés, Galán, & Viguri, 2008); en donde se evaluó un modelo que integra variables físicas y químicas para dicha clasificación, para llevar a cabo esta evaluación se comparó con otros modelos de IA y resultó ser más eficaz. De forma parecida, Nourouzi, Chuah, Choong, & Rabiei, (2012) trabajaron con un modelo para simular la biodegradación del herbicida glifosfato, las variables medidas fueron pH y concentración del herbicida; concluyeron que el modelo predice con precisión el proceso de biodegradación.

Aunque en una línea diferente, Katritzky et al., (2010) han utilizado las redes neuronales para correlacionar propiedades químicas y físicas en compuestos químicos pudiendo predecir propiedades de estructuras mecánicas que presentan dificultad para ser determinados experimentalmente, se puede observar que en la actualidad el uso de modelos de redes neuronales han permitido predecir y determinar variables que experimentalmente resultaría muy costoso, en un periodo largo de tiempo o bien imposible. En materia de suelos, Zhao et al., (2009) desarrollaron un modelo cuya capacidad sea de predecir la textura de suelo basada en atributos del suelo concluyendo que si bien el modelo predice de manera efectiva la textura cuando los rangos de esta última varían hay que recalibrar el equipo.

En el marco de sistemas expertos utilizados en la bioremediación se encuentra el artículo presentado por Kumar Rohit, en el cual, a través de una red neuronal hizo posible y efectivo generalizar y predecir el grado de reducción de la erosión de suelos mediante la utilización de una determinada bioremediación siendo esto un suplemento para los complicados modelos matemáticos utilizados en la predicción de los bioprocesos (Raj, Kardam, Arora, & Srivastava, 2009). La utilización de lógica difusa también ha sido estudiada en la remediación, Zhi Y. Hu utilizó un sistema basado en reglas difusas en un controlador jerárquico para la bioremediación de mantos acuíferos (Hu, Huang, & Chan, 2003).

Otra técnica de inteligencia artificial muy empleada en esta área son los mapas auto-organizados SOM, en el trabajo de Manuel Alvarez-Guerra se muestra cómo una SOM puede ser una herramienta efectiva para la integración de múltiples variables físicas, químicas y ecotoxicológicas para clasificar diferentes lugares bajo un estudio acorde a la calidad de sus sedimentos (Alvarez-Guerra et al., 2008). Una utilización más de la SOM es presentada por Tae-Soo Chon cuyo trabajo indica la capacidad de estas redes en proveer puntos de vista comprensivos cuando se maneja múltiples datos complejos en los niveles jerárquicos de la vida desde las moléculas hasta los ecosistemas (Chon, 2011).

Cuando se trabaja con múltiples datos, también se corre el riesgo de trabajar con datos que son poco representativos y que pueden afectar al entrenamiento de las redes neuronales con lo cual es importante conocer técnicas capaces de reducir la n-dimensionalidad del vector de entrada de la red neuronal, A. Astel muestra 3 técnicas de clasificación (Principal Component Analysis PCA, cluster analysis CA y self-organizaed maps SOM) que fueron aplicadas en una base de datos ambientales con indicadores químicos de la calidad de agua de los ríos, estas técnicas ayudaron a detectar diferentes patrones ocultos de los lugares de monitoreo, con lo cual se puede optimizar las redes de monitoreo de los ríos (Astel, Tsakovski, Barbieri, & Simeonov, 2007).

Por consecuencia, uno de los más grandes problemas es la determinación del algoritmo a utilizar. Aunque existen una gran gama de algoritmos a ser empleados, acorde a las necesidades de este proyecto se requiere trabajar en el área de aprendizaje supervisado ya que se requiere de un sistema que pueda aproximar sus datos al de un instrumento patrón a través de la experiencia obtenida durante su entrenamiento. Debido a esto, se optará por realizar pruebas con las Redes Neuronales Artificiales (feed-forward backpropagation learning y Redes Neuronales Probabilísticas) y Máquinas de Soporte Vectorial. Cada uno de estos algoritmos tiene sus características que pueden hacer o no viable la identificación. Por ejemplo las máquinas de soporte vectorial están más enfocadas a la parte de clasificación y regresión, al igual que otras técnicas de aprendizaje supervisado los datos de entrada son vistos como un vector p-dimensional, lo cual lo convierte en un problema debido a que en muchas ocasiones las dimensiones o entradas de la red no son tan representativas o proporcionan datos que confunden a la red por lo cual es necesario utilizar técnicas de análisis de componentes principales (PCA) para poder realizar una reducción p-dimensional y garantizar que lo que le entre a la red neuronal sea información útil. Como se puede observar para llevar a cabo esta sección de la tesis doctoral se debe de realizar experimentación variando diferentes factores de cada una de las redes a utilizar como lo puede ser las dimensiones del vector de entrada, el número de capas de neuronas ocultas, etc. De igual forma se evaluaron los estudios realizados a cerca las relaciones entre variables físicas y químicas estudiadas y determinadas hasta el momento; se reporta en el trabajo realizado por Paz González, Taboada Castro, & Gómez Suárez, (1997) que existe una relación entre el pH y la capacidad de intercambio catiónico, el Mg intercambiable y el Nitrógeno nítrico, también reportan relación con el porcentaje de saturación, sin embargo existe un amplio rango de datos comparado con los rangos de pH. Por otro lado, Onet, (2014) reporta que también existe relación entre el pH y el carbono orgánico. Mengel concluyó que debido a que la CIC del suelo está relacionada con el porcentaje de arcilla y materia orgánica, esta se puede estimar de la textura de suelo y el color (Mengel, 1993). Eldardiry, El-hady, & Zaghoul, (2013); y Onet, (2014) reportan que existe una relación entre la humedad y el contenido de la materia orgánica, el nitrógeno amoniacal, carbono orgánico, salinidad y la capacidad de intercambio catiónico. Igualmente, Eldardiry et al., (2013) indica que existe relación entre la conductividad eléctrica y el porcentaje de sodio intercambiable. (Regelink et al., 2015) señala que el contenido de materia orgánica está relacionado con la porosidad y en conjunto con el pH se relaciona con los agregados estables en agua.

CAPÍTULO II. METODOLOGÍA

La realización de este trabajo se estructuró en 7 etapas que permiten el diseño, implementación y validación de un conjunto de sistemas de inteligencia artificial y su aplicación en campo. A continuación, en la Figura 3 se muestra las fases generales en un diagrama de flujo; posteriormente, se describe cada fase en detalle.

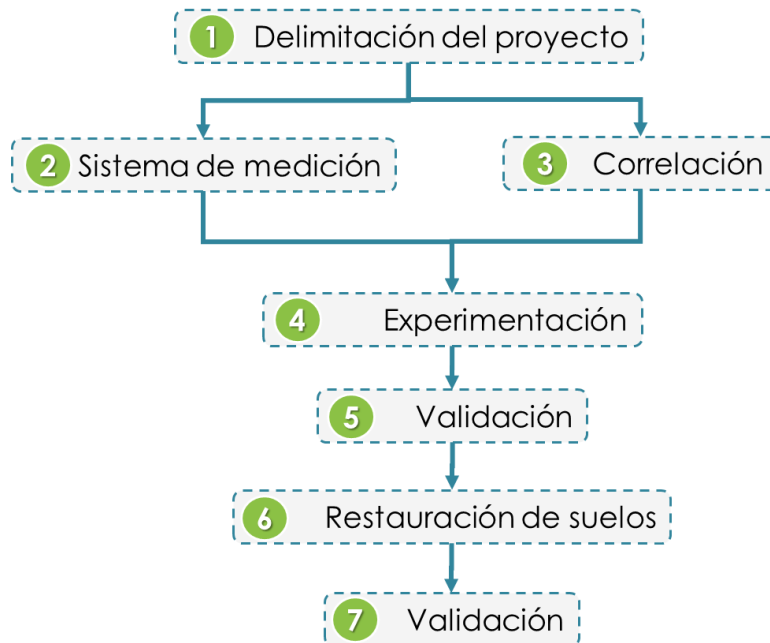


Figura 3. Diagrama general para el desarrollo del trabajo de investigación.

La primera etapa involucra la definición del tipo de suelo, los sitios y el tipo de muestreo, las variables fisicoquímicas críticas a monitorear y los sensores que se utilizarán para la determinación de estas variables. De igual forma, involucra la revisión de la investigación que se encuentra en la literatura en materia de determinación de variables mediante el uso de sensores y tecnología en sitio; esto es, metodologías experimentales validadas con las metodologías tradicionales. La segunda etapa contiene todo lo relacionado con el diseño y manufactura del sistema de medición y su soporte para la extracción de muestras, por lo tanto; involucra lo relacionado con la fusión de los sensores y la manufactura del sistema de soporte.

La tercera etapa involucra la determinación de las variables fisicoquímicas monitoreadas mediante métodos validados y el sistema de medición realizado en la etapa anterior, así como también, en la tercera etapa se desarrollará un sistema de inteligencia artificial, el cual será utilizado experimentalmente en la cuarta etapa, para inferir variables fisicoquímicas y concluir el grado de degradación del suelo en cuestión. El siguiente diagrama (Figura 4) muestra las actividades principales relacionadas con las primeras 4 etapas descritas hasta este punto y como se relacionan entre sí.

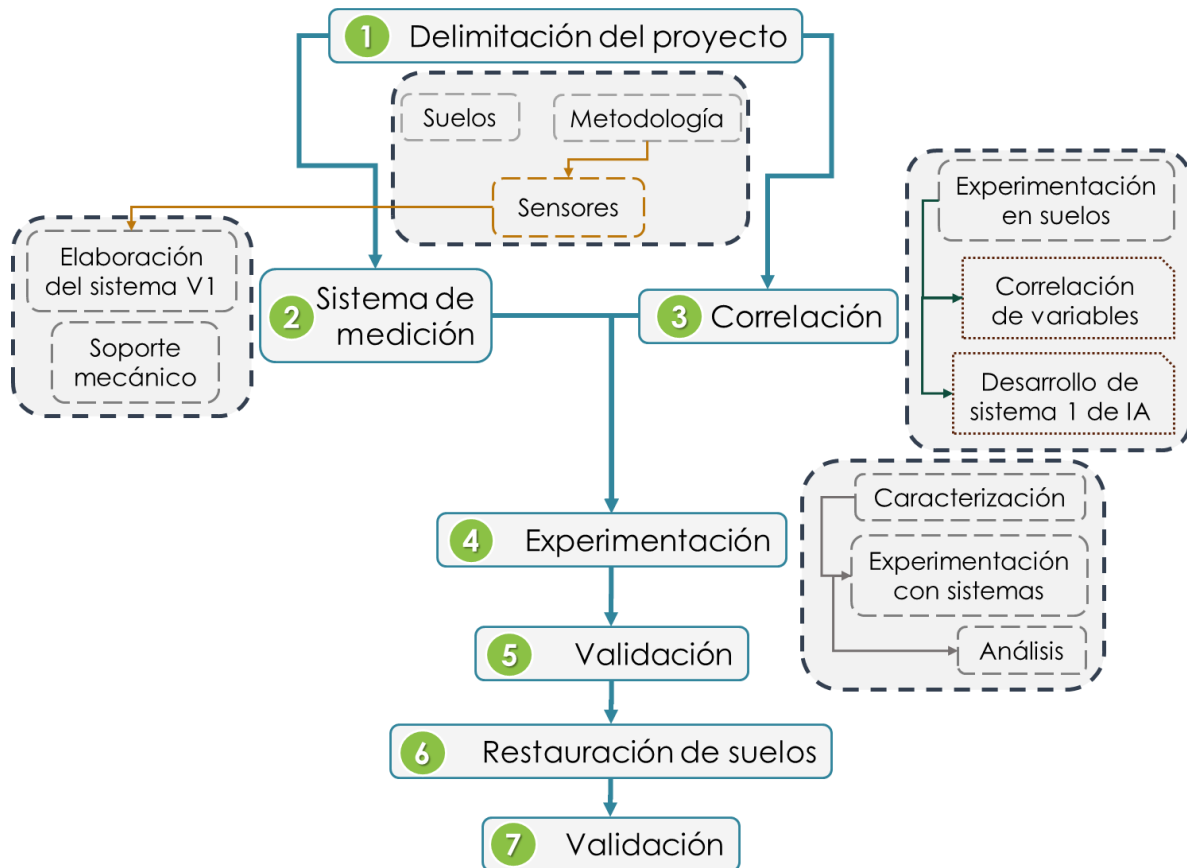


Figura 4. Diagrama detallado de actividades realizadas durante las primeras 4 etapas del proyecto.

En la siguiente fase, la etapa 5, se validará la información obtenida mediante el sistema inteligente que será desarrollado en este proyecto, con la información obtenida mediante metodologías validadas en el laboratorio.

La fase 6 engloba la recolección de la información que los expertos en materia de restauración de suelos proporcionarán para alimentar el siguiente sistema de inteligencia artificial que será evaluado y validado en la etapa 7 del proyecto. Esto se puede observar en el diagrama de flujo mostrado en la Figura 5.

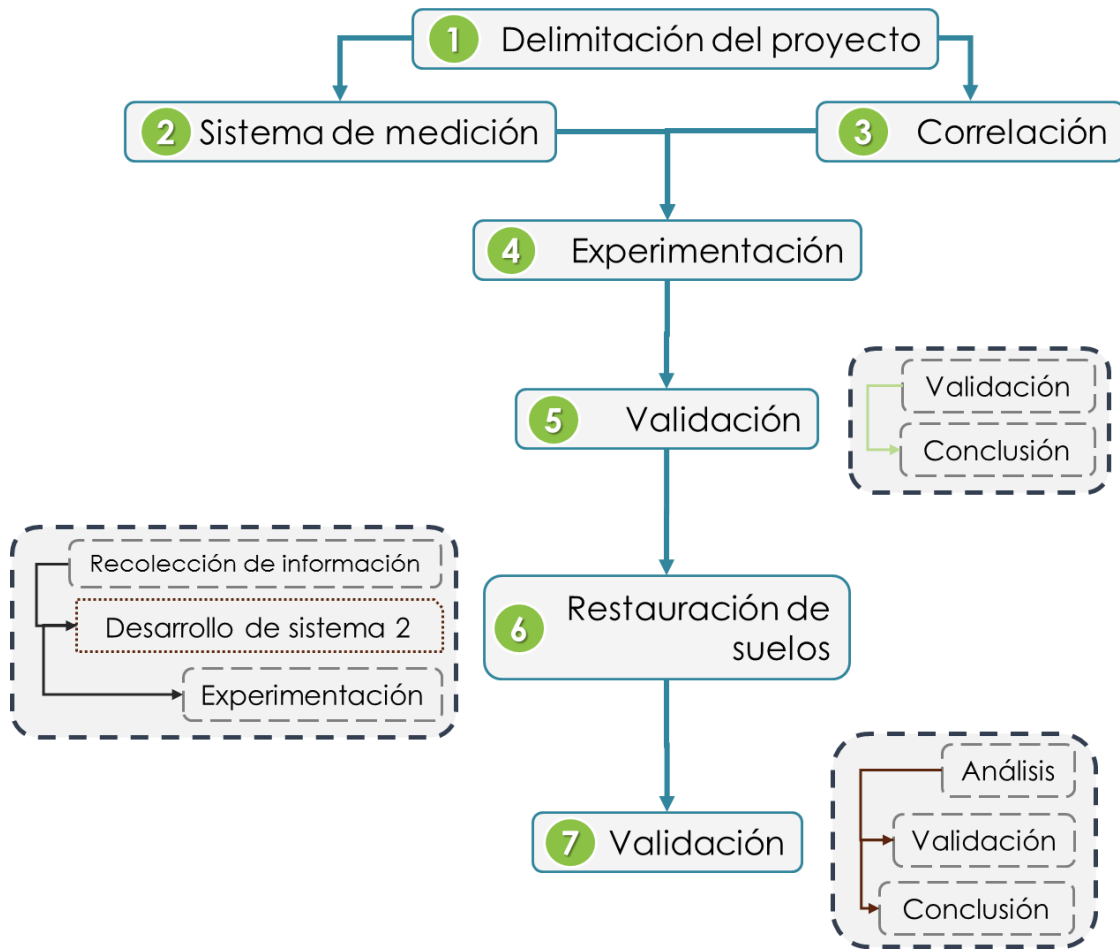


Figura 5. Segunda parte del diagrama de flujo del trabajo para las etapas 5 a la 7.

2.1 Delimitación de los sitios de muestreo

El estado de Veracruz consta de 10 regiones administrativas; I. Huasteca alta, II. Huasteca baja, III. Totonaca, IV. De Nautla, V. Capital, VI. Montañas, VIII. Papaloapan, IX. De los Tuxtlas y X. Olmeca. La que involucra este proyecto es la región VI. las Montañas, que contiene 57 municipios ([//siglo.inafed.gob.mx](http://siglo.inafed.gob.mx)) con un área aproximada de 6 053 km² (Figura 6) (Gobierno del Estado de Veracruz, 2013). De este territorio, para el 2015 el 0.5% tenía superficie sembrada con caña de azúcar y por otro lado, aproximadamente el 18.5% de suelos presenta el tipo Vertisol (Figura 7) (Mapa digital de México).



Figura 6. Identificación de la región de las Montañas en Veracruz (Mapa Digital de México)




Figura 7. Tipos de suelos presentes en la zona de estudio, en color rosa se identifica el tipo Vertisol (Mapa Digital de México).

Después de evaluar los municipios que cuentan con ambos requisitos, tener producción con caña de azúcar y suelos Vertisol se identificaron 18 municipios que representan el 1.54% del suelo en la región en estudio; a continuación, se muestra la lista correspondiente con las hectáreas de suelos con producción de caña de azúcar:

MUNICIPIO	HECTÁREAS	MUNICIPIO	HECTÁREAS	MUNICIPIO	HECTÁREAS
AMATLÁN DE LOS REYES	1	ATOYAC	2	CAMARÓN DE TEJEDA	780
CARRILLO PUERTO	141	CHOCAMAN	2	COETZALA	78
CUICHAPA	3	CUITLÁHUAC	592	CÓRDOBA	4
FORTÍN	1	IXTACZOQUITLAN	5	NARANJAL	60
OMEALCA	12	PASO DEL MACHO	8	RÍO BLANCO	20
TLALTETELA	2	TLILAPAN	8	YANGA	4

Tabla 3. Lista de municipios con siembra de caña de azúcar en suelos del tipo Vertisol y las hectáreas sembradas (<http://www.oeidrus-veracruz.gob.mx>)

De lo anterior, se pueden definir las muestras a tomar de cada municipio en función de lo que cada superficie de suelo representa en porcentaje del total de hectáreas involucradas en la región, lo mínimo que se colocó por municipio fue una muestra y se ajustaron los que tienen más muestras; de tal forma, la siguiente tabla presenta el número de muestras a tomar en cada municipio.

MUNICIPIO	HECTÁREAS	MUNICIPIO	HECTÁREAS	MUNICIPIO	HECTÁREAS
AMATLÁN DE LOS REYES	1	ATOYAC	1	CAMARÓN DE TEJEDA	18
CARRILLO PUERTO	4	CHOCAMAN	1	COETZALA	2
CUICHAPA	1	CUITLÁHUAC	13	CÓRDOBA	1
FORTÍN	1	IXTACZOQUITLAN	1	NARANJAL	2
OMEALCA	1	PASO DEL MACHO	1	RÍO BLANCO	1
TLALTETELA	1	TLILAPAN	1	YANGA	1

Tabla 4. Número de muestras de suelo a tomar en cada municipio de la región.

Las profundidades evaluadas para el cultivo de este estudio son de 0 – 20 cm y de 0 – 30 cm debido a que entre el 50 y 70% de las raíces se distribuyen entre los primeros 30 cm de profundidad y hay mayor absorción de nutrientes de acuerdo con el (Comité Nacional para el Desarrollo Sustentable de la Caña de Azúcar, 2015), adicionalmente al ser un cultivo de ciclo corto se recomienda ser muestreado de los 0 a los 20 cm (FHIA, 2007). Derivado de lo anterior se tomaron muestras separadas a tres profundidades: de 0 a 10 cm, de 10 a 20 cm y de 20 a 30 cm con el objetivo de evaluar si las diferencias entre los perfiles son significativas y estas muestras están compuestas por 40 submuestras que también son guardadas individualmente para evaluarse con el sistema propuesto en el proyecto, esto debido a que de acuerdo a la norma NOM-021-RECNAT-2000 el muestreo para evaluar un predio depende de las hectáreas a evaluar y se deben tomar entre 15 y 40 sub-muestras en zigzag para obtener información representativa de suelo en evaluación (Diario Oficial de la Federación, 2002; FENACH, 2000; FHIA, 2007; Salazar & Sanchez, 2000). La siguiente figura muestra la ubicación de las muestras realizadas y su correspondiente punto de localización geográfica (Figura 8).

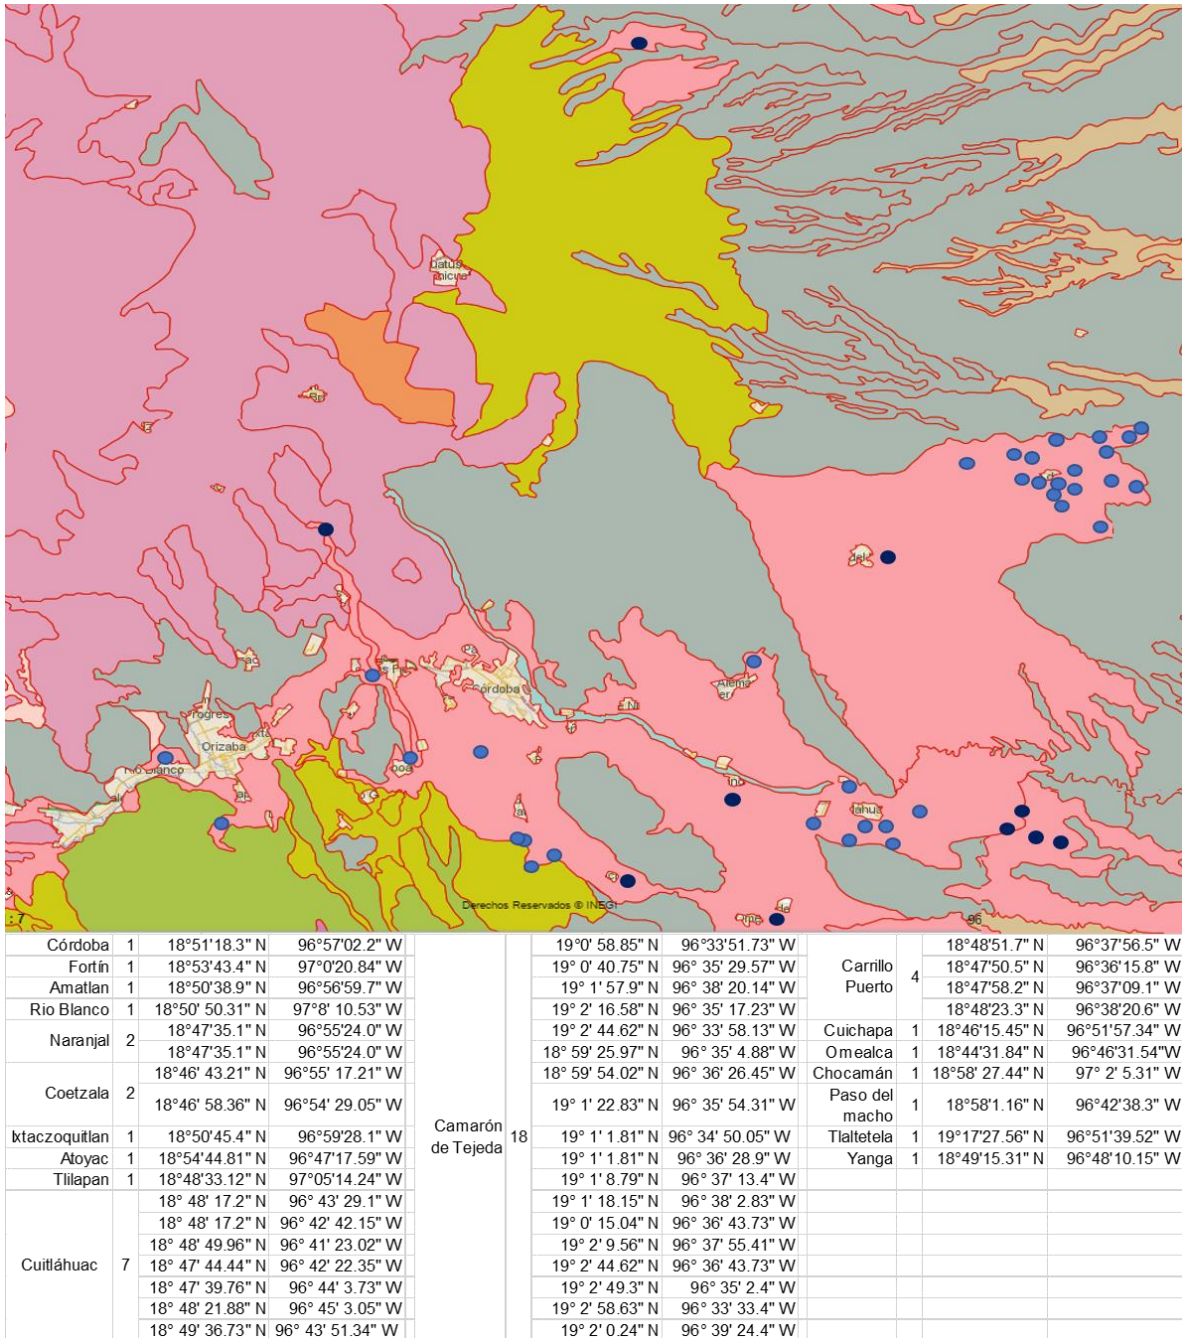


Figura 8. Ubicación de las muestras de suelos tomadas durante el proyecto.

2.2 Caracterización de muestras de suelo

Habiendo establecido las posibles correlaciones entre las variables físicas y químicas presentes en el suelo y las necesarias para concluir el estado de fertilidad del suelo en estudio, se determinó que los parámetros fisicoquímicos determinados mediante métodos normativos son: pH suelo, pH tampón, Materia orgánica (MO), Fósforo (P), Potasio (K), Calcio (Ca), Magnesio (Mg), Azufre (S),

Boro (B), Cobre (Cu), Hierro (Fe), Manganeseo (Mn), Zinc (Zn), Sodio (Na), Conductividad, Nitrógeno-Nitrato ($N_2 - NO_3^-$), Capacidad de intercambio catiónico (CIC), Saturación catiónica (SC) de K, SC de Ca, SC de Mg, SC de Hidrógeno (H), SC de Na, relación K/Mg, relación Ca/Mg, textura (arena, limo y arcilla), densidad aparente, Capacidad de campo 1/3 bar y Punto de marchitez permanente 15 Bar. Para los primeros 6 puntos de muestreo se realizaron muestras compuestas por las 3 profundidades para confirmar la hipótesis de tener diferencias significativas entre los perfiles del suelo; por lo tanto, se analizaron 4 muestras por municipio muestreado.

Los métodos analíticos utilizados para las determinaciones fisicoquímicas de las muestras de suelos fueron los siguientes:

PROPIEDAD	METODOLOGÍA
PH SUELO	MÉTODO ELECTROMÉTRICO
PH TAMPÓN	
TEXTURA	TÉCNICA DE HIDRÓMETRO DE BOUYOUCOS
CONDUCTIVIDAD ELÉCTRICA	TÉCNICA DE CONDUCTIMETRÍA
DENSIDAD RELATIVA	MÉTODO DEL TERRÓN PARAFINADO
MATERIA ORGÁNICA	TÉCNICA VOLUMÉTRICA DE WALKLEY Y BLACK
CIC	MÉTODO DEL ACETATO DE AMONIO
CATIONES INTERCAMBIABLES (SODIO, CALCIO, POTASIO, MAGNESIO)	ESPECTROFOTOMETRÍA DE ABSORCIÓN ATÓMICA.
FÓSFORO	PROCEDIMIENTO DE OLSEN Y COLABORADORES
BORO	MÉTODO CON EXTRACTANTE Y AZOMETINA-H.
AZUFRE	
MICRONUTRIENTES	ESPECTROFOTOMETRÍA DE ABSORCIÓN ATÓMICA.
NITRÓGENO - NITRATO	PROCEDIMIENTO MICRO-KJELDAHL
SALES SOLUBLES	SODIO Y POTASIO: ESPECTROFOTOMETRÍA DE ABSORCIÓN ATÓMICA Y/O DE FLAMA. SULFATOS: TÉCNICA TURBIDIMÉTRICA.
SATURACIÓN CATIÓNICA DE POTASIO, CALCIO, MAGNESIO, HIDRÓGENO, SODIO	ESPECTROFOTOMETRÍA DE ABSORCIÓN ATÓMICA Y/O DE FLAMA.
CAPACIDAD DE CAMPO 1/3	MÉTODO PARA DETERMINAR HUMEDAD
PUNTO DE MARCHITEZ PERMANENTE 15 BAR	MÉTODO BIOLÓGICO

Tabla 5. Técnicas utilizadas para la determinación de las características en las muestras de suelos colectadas (SEMARNAT, 2002b)

2.3 Sistema de extracción de núcleos

Estos sistemas son de suma importancia para poder realizar el análisis de suelo. Hoy en día existen varios dispositivos encargados de realizar esta tarea de una forma más eficiente y fácil, la Tabla 6, muestra un resumen de estas tecnologías y su uso más común. Para el presente proyecto fue necesario diseñar y fabricar una propuesta para la correcta extracción de los núcleos.

2.3.1. Diseño y fabricación del sistema de extracción de núcleos

Con la finalidad de mantener la integridad de las muestras y facilitar su extracción se diseñó y manufacturó un sistema mecánico que permita extraer la muestra de suelo sin modificar significativamente las propiedades físicas del mismo. Este está integrado por 4 secciones. 1) Sección de sujeción y acoplamiento, 2) Tubo de extracción, 3) Sistema de expulsión de material, y 4) Sistema de cortadores. En la Figura 9 se puede observar el sistema de extracción de suelos.



Figura 9. Mecanismo de extracción de suelo.

2.3.1.1 Sistema de sujeción y Acoplamiento

Esta sección es la base de todo el sistema ya que es el punto de unión con el taladro para la transmisión del torque necesario para la perforación. La Figura 10 muestra a detalle el esquema de los 5 elementos que componen esta sección: “Eje de transmisión” (1), “base” (2), “rodamiento” (3). Mientras que en la Figura 11 muestra adicionalmente la “tapa base” (4) y “Barras de sujeción” (5).




Figura 10. Sección de acoplamiento.

La primera pieza del sistema de sujeción y acoplamiento corresponde a la llamada “Eje de transmisión” señalada con el número (1), esta pieza fue torneada para tener 3 diferentes diámetros, uno de estos en la mitad del eje sirve de acoplamiento al rodamiento con lo cual queda directamente acoplado a la “Tapa base” (4) del dispositivo visto en la Figura 11.




Figura 11. Sección de Sujeción.

Uno de los extremos del “eje de transmisión” (1) fue manufacturado de forma hexagonal debido a que en esta sección se realiza la conexión mediante un acoplamiento al taladro (1A) que se muestra en la Figura 11.

Finalmente, en el extremo (1C) de la 0 el “eje de transmisión” (1) cuenta con una rosca con el objetivo de conectarse a la “base del tubo” (6) con lo cual transmitirá directamente el movimiento rotativo del taladro al tubo de extracción.

La segunda pieza del sistema de sujeción y acoplamiento es la “base” (2) de la 0, la cual conecta las piezas encargadas de generar la sujeción y acoplamiento como lo son: el “eje de transmisión” (1), “rodamiento” (3), “tapa base” (4) y las “barras de sujeción” (5).

Las “barras de sujeción” (5) son utilizadas para posicionar y manipular correctamente el dispositivo mientras se barrena el suelo, con lo cual se da al sistema estabilidad y además que sirve como punto de presión para acelerar el proceso de barrenado.

El “rodamiento” (3) es la tercera pieza del sistema de sujeción y acoplamiento (Figura 11), el cual está montado en su diámetro exterior en la “base2 (2) y en su interior acopado al “eje de transmisión” (1) con la finalidad de evitar y reducir los esfuerzos producidos por fricción y por fuerzas axiales y radiales.

2.3.1.2. Sección Tubo de Extracción

La sección del cilindro de extracción está conformada por 2 elementos que se pueden apreciar en la Figura 12. Dichos elementos son: la “base del tubo de extracción” (6) que sirve para acoplar el “eje de transmisión” (1) con el “tubo de extracción” (7) esto con el propósito de transmitir al “tubo de extracción” (7) la potencia mecánica del taladro. El “tubo de extracción” (7) está diseñado para girar con la potencia mecánica del taladro y penetrar a 30 cm de profundidad del suelo para obtener la muestra.




Figura 12, Sección de tubo de extracción

2.3.1.3. Sección de Expulsión de Muestra

Uno de los grandes retos de los sistemas de extracción de suelos es el sacar la muestra de suelo del cilindro contenedor. Por lo tanto, este sistema cuenta con un diseño especial para resolver esta situación; un mecanismo mediante el cual expulsar la muestra una vez contenida en el sistema. Esto se lleva a cabo introduciendo un tornillo de 30 cm de largo en la entrada de la figura hexagonal del acoplamiento del eje de transmisión, a su vez este tornillo cuenta con una figura hexagonal en uno de sus extremos que va acoplado al taladro. Al hacer funcionar el taladro este comienza a introducir el tornillo dentro del sistema atravesando el eje de acoplamiento, este tornillo comienza a empujar a la pieza de Nylamid que se encuentra dentro del cilindro de extracción, con lo cual hace que el núcleo empiece a ser desplazado del cilindro. Una vez desalojada la tierra, se invierte el giro del taladro para sacar el tornillo y regresar la pieza que funciona como empujador a su posición inicial dentro del cilindro.

Un problema que resuelve este sistema es la expulsión de muestra de suelo a través del contenedor cilíndrico. Esto a través de un mecanismo que se puede observar en la Figura 12 que funciona introduciendo un “tornillo esparrago” (10) de 30 cm de largo en la entrada de la figura hexagonal de acoplamiento (1A) del “eje de transmisión” (1). Dicho tornillo cuenta con una figura hexagonal (10A) en uno de sus extremos que funge como acople al taladro.

Al activar el giro del taladro el tornillo comienza a introducirse atravesando el “eje de transmisión” (1) y empujando al “cilindro de expulsión de suelo” (8) que se encuentra dentro del “tubo de extracción” (7) el cual expulsa la muestra.

Posterior a expulsar la muestra se activa el giro inverso del taladro para sacar el “tornillo esparrago” (10) y regresar el “cilindro de expulsión de suelo” (8) a su posición inicial dentro del “tubo de extracción” (7).




Figura 13. Sección de Expulsión de Muestra.

Finalmente, la Figura 14 muestra los 3 sistemas en el mecanismo real del extractor incluido el Nylamid.



Figura 14. Sistema de expulsión. (1) componentes de la pieza hexagonal del acoplamiento (2 y 3): sistema de acoplamiento con tapón de nylamid y sin el respectivamente.

2.3.1.4. Sección del sistema de cortadores

Por último, el sistema completo en el cual podemos apreciar el “sistema de cortadores” (9) que está constituido de una pieza de cortadores realizada con acero templado, la cual se encuentra soldada al “tubo de extracción” (7).

2.3.1.5. Experimentación

Todas las muestras de suelo en este proyecto han sido extraídas utilizando la barrenadora automática de extracción de suelos. Se puede apreciar en la Figura 15 el acoplamiento del taladro con el sistema y como penetra el suelo.



Figura 15. Sistema de extracción del suelo

La Figura 16 muestra el sistema de expulsión, en donde se desacopla el taladro y se coloca un tornillo el cual sirve como sistema de expulsión de la muestra, este tornillo ahora es acoplado al taladro el cual al ser accionado comienza a expulsar la muestra.



Figura 16. Integración del Sistema de expulsión con taladro

La Figura 17 muestra la expulsión de la muestra con el sistema. Se puede apreciar como el núcleo conserva sus propiedades físicas en su estructura lo que permite dividir las muestras en intervalos de 10 cm para su posterior análisis con los sensores.








Figura 17, Expulsión de muestra






Al comparar este sistema con los presentados en la Tabla 6 tenemos que el número 3 plantea el uso anillos pequeños, que si bien contienen muestras inalteradas y

se limpian fácilmente la cantidad de muestra es mínima y el mecanismo es mecánico. Los otros muestreadores (6 y 38) tienen un diámetro de 37 y 50 mm respectivamente y una longitud de muestra de 200 mm y 300 mm respectivamente; ambos reportan que la muestra contenida estará inalterada. Mientras que el sistema propuesto en este trabajo contempla 76 mm de diámetro y 300 mm de longitud garantizando que la muestra contenida este inalterada para las mediciones a realizar, adicionalmente, el peso del sistema propuesto es 7 veces menor que el del sistema 6 y 10 veces menor que el número 38.

Elaboración de un sistema inteligente para la estimación de propiedades fisicoquímicas de suelos con producción de caña de azúcar

No.	Nombre	Diseño	Usos		Ventajas / Notas
1	Equipo de Barrenas ergonómicas	<p>Diámetro de perforación 7 cm Profundidad máx. muestra 5 m material del producto hierro, otro material Longitud de la muestra 10 cm Especificación de muestra alterada Posición de la muestra vertical Package size (L*W*H) 120 x 65 x 30 cm Peso 29 kg</p>	<p>Descripción y clasificación del perfil del suelo Toma de muestras del suelo por encima del nivel freático Toma de muestras del suelo por debajo del nivel freático Estudio arqueológico del suelo Estudio medioambiental del suelo</p>		<p>Más complicado en comparación con la empuñadura simple El equipo no incluye el muestreador con pistón Dejar secar el equipo al aire después de su uso</p>
2	Barrena de media caña	<p>Profundidad máx. muestra 5 m material del producto hierro, otro material Diámetro de la muestra 16 / 25 / 56 mm Longitud de la muestra 50 / 100 cm Especificación de muestra semi alterada Volumen de la muestra 100 - 1770 ml Package size (L*W*H) 117 x 27 x 23 cm Peso 23 kg</p>	<p>Toma de muestras del suelo por encima del nivel freático Toma de muestras del suelo por debajo del nivel freático Estudio arqueológico del suelo Estudio medioambiental del suelo Mapas de suelo. Evaluaciones de aptitud del suelo. Fines educativos. Investigación de las raíces Muestreo de suelos para la investigación de la fertilización. Investigación de la distribución de la arcilla. Investigación Paleontológica.</p>		<p>Se puede usar cuando se quiere muestrear con poca alteración un muestra de suelo más o menos blandos, capas cohesionadas pueden alargarse añadiéndoles barras suplementarias. La selección del diámetro más adecuado depende de la composición y la estructura del suelo y del propósito de la investigación. Normalmente los diámetros más pequeños, se usan en suelos con una estructura densa o normal (en comparación con suelos con una estructura blanda, como turba pantanosa reciente).</p>
3	Equipos de anillos	<p>Anillos Tipo A: Soporte de tipo abierto para anillos Barrenas tipo Edelman y Riverside, Un mango, barras de extensión, Un maletín con anillos para toma de muestras, y Bolsa de transporte. El equipo estándar contiene anillos de 53 mm de diámetro (puede solicitarse con anillos de 60 mm) Anillos tipo C y E: Porta anillos cerrado, Mango que se puede golpear, Una barrena Edelman y una Riverside, Barras de extensión, Un porta anillos que se puede golpear un cilindro de guía, Una caja de aluminio con anillos y varios accesorios. El muestreador tipo SC está disponible con anillos de diámetro 53, 60 y 84 mm. Los anillos más comunes (estándar) son los de 50 mm El muestreador tipo SE sólo está disponible con anillos de 53 mm.</p>	<p>Estudios de perfiles Estudios de las propiedades físicas de suelos.</p>		<p>Para alcanzar las condiciones de muestra inalterada, las muestras se toman en anillos de diámetro y volumen conocidos y con dimensiones uniformes. Tres diámetros precisos disponibles Se puede golpear, para todo tipo de suelos Anillo de muestreo protegido por porta anillos cerrado El kit permite el muestreo en superficie y en profundidad El sistema de válvulas se puede limpiar fácilmente</p>
4	Muestreador de sedimentos Beeker	<p>El cabezal de corte se puede cerrar con aire a presión El pistón asegura una longitud perfecta de la muestra de perforación Para longitudes de muestreo de hasta 150 cm Transparente: La descripción de perfiles más sencilla Estructura de acero inoxidable libre de contaminantes El juego B permite 10 cm de transferencia de submuestra</p>	<p>Toma de muestras intactas de fondos subacuáticos. A partir de las muestras tomadas se pueden emitir descripciones claras del perfil del fondo.</p>		<p>No puede perderse la muestra en ningún caso Se puede golpear para muestrear todo tipo de sedimento No se puede utilizar en sedimentos insaturados</p>
5	Muestreador de turba hasta una profundidad de 10 m	<p>Conexión screwthread Profundidad máx. muestra 10 m material del producto acero inoxidable, hierro, otro material Diámetro de la muestra 52 mm Longitud de la muestra 50 cm Especificación de muestra semi alterada Volumen de la muestra 530 ml Posición de la muestra vertical Dimensiones(L*W*H) 117 x 27 x 23 cm Peso 32 kg</p>	<p>Descripción y clasificación del perfil del suelo Toma de muestras del suelo por encima del nivel freático Toma de muestras del suelo por debajo del nivel freático Estudio medioambiental del suelo Toma de muestras de sedimentos</p>		<p>La punta gruesa limita la penetración en material rígido Las raíces de las plantas acuáticas se echan a los lados Toma muestras de material saturado e insaturado Estructura del muestreador de acero inoxidable apta para todos los análisis Principio simple de gubia con aleta No se produce pérdida de sedimento gracias a la aleta de cierre grande Eficaz para tomar muestras de turba joven y sedimentos Toma muestras de puntas a cualquier profundidad (suelo blando) No requiere experiencia</p>

Elaboración de un sistema inteligente para la estimación de propiedades fisicoquímicas de suelos con producción de caña de azúcar





No.	Nombre	Diseño	Usos	Ventajas / Notas
6	Muestreador de suelos para entubación	<p>Conexión screwthread Profundidad máx. muestra 7 m material del producto acero inoxidable, hierro, otro material Diámetro de la muestra 37 mm Longitud de la muestra 20 cm Especificación de muestra inalterada Muestra almacenada en lámina Package size (L*W*H) 117 x 27 x 23 cm Peso 27.54 kg</p>	<p>Toma de muestras del suelo por encima del nivel freático Toma de muestras del suelo por debajo del nivel freático Estudio medioambiental del suelo Toma de muestras no alteradas Toma de muestras de raíces Las muestras pueden utilizarse para: • Determinaciones de fertilidad de suelo. • Ver la estructura del suelo. • Determinaciones de peso en volumen. • Determinación de composición granular. • Mediciones técnicas. • Educación agronómica</p>	 <p>El revestimiento permite la fácil extracción de la muestra y absorbe los volátiles Visualización de la muestra directamente en el terreno Visualización de la muestra sin tocar Juego B, más indicado para suelos duros Muestreador de acero inoxidable</p>
7	Barrena muestreadora de raíces bi-partida	<p>Conexión screwthread Grosor máximo de la raíz 20 mm Profundidad máx. muestra 200 cm material del producto hierro, otro material Diámetro de la muestra 80 mm Longitud de la muestra 150 mm Especificación de muestra inalterada Volumen de la muestra 750 ml Posición de la muestra vertical Tamaño (L*W*H) 117 x 27 x 23 cm Peso 27.5 kg</p>	<p>Toma de muestras del suelo por encima del nivel freático Estudio medioambiental del suelo Toma de muestras no alteradas Estudio de la textura del suelo Toma de muestras de raíces Investigación para determinar las posibilidades de desarrollo de un sistema de raíces y determinar la profundidad y densidad de un sistema de raíces La barrena de raíces puede utilizarse en cualquier tipo de suelo Muestreo de abono compuesto</p>	 <p>Toma muestras de raíces de todo tipo de capas de suelo no pedregosas Se puede golpear Anillo de corte afilado, resistente e intercambiable Incorpora extrusionadora de muestras</p>
8	Muestreador de raíces y turbas	<p>Grosor máximo de la raíz 10 mm Profundidad máx. muestra 100 cm material del producto acero inoxidable, hierro, otro material Diámetro de la muestra 100 x 100 mm Longitud de la muestra 100 cm Especificación de muestra inalterada Volumen de la muestra 10 litros Posición de la muestra vertical Tamaño (L*W*H) 147 x 62 x 82 cm Peso 34 kg</p>	<p>Descripción y clasificación del perfil del suelo Toma de muestras no alteradas Estudio de la textura del suelo Toma de muestras de raíces Este muestreador se puede utilizar para: • Estudios sobre crecimiento de raíces. • Análisis de polen. • Estudios sobre Macro-fósiles (paleo-ecología). • Obtención de monolitos de suelo.</p>	 <p>Mantener los bordes de corte afilados con la lima (incluida) Perforaciones grandes rectangulares en suelos blandos (turba) De acero inoxidable para años de uso El espacio de aire que queda por debajo de la muestra se llena desde la salida de aire Conector simple para recuperación de muestras</p>
9	Muestreador de perfiles	<p>Grosor máximo de la raíz 10 mm Profundidad máx. muestra 50 cm material del producto acero inoxidable, hierro, otro material Diámetro de la muestra 100 x 50 mm Longitud de la muestra 50 cm Especificación de muestra inalterada Volumen de la muestra 2500 ml Posición de la muestra vertical Dimensiones (L*W*H) 72 x 56 x 11 cm Peso 5.6 kg</p>	<p>Descripción y clasificación del perfil del suelo Toma de muestras del suelo por encima del nivel freático Toma de muestras no alteradas Estudio de la textura del suelo Toma de muestras de raíces Investigación en crecimiento de raíces. Investigación ecológica/biológica de horizontes en terreno forestal. Mapeado de suelo. Creación de monolitos sin necesidad de hacer una calicata. Válido para la mayoría de suelos.</p>	 <p>Un bonito perfil de la superficie en cuestión de segundos Corta raíces; indicado también para suelos forestales Vista detallada inmediata del perfil en grande Funciona en suelos de blandos a medios Galvanizado; muestras no aptas para el análisis de Zn</p>
10	Juego de barrenas para suelos heterogéneos	<p>Conexión bayoneta Diámetro de perforación 7 cm Profundidad máx. muestra 5 m material del producto hierro, otro material Longitud de la muestra 10 cm Especificación de muestra alterada Posición de la muestra vertical Dimensiones (L*W*H) 117 x 27 x 23 cm Peso 33 kg</p>	<p>Descripción y clasificación del perfil del suelo Toma de muestras del suelo por encima del nivel freático Toma de muestras del suelo por debajo del nivel freático Estudio arqueológico del suelo Estudio medioambiental del suelo</p>	 <p>Barrena forjada de alta resistencia a la tensión Conexión de bayoneta para accionamiento por un solo operario Formas de barrena perfectas para una perforación óptima Acero no tóxico para todo tipo de análisis Gama de barrenas para todo tipo de suelos Incluye muestreador de pistón para arenas saturadas Comprobación rápida del nivel de agua con sonda de nivel Calidad demostrada: El kit seguirá funcionando durante muchos años Dejar secar el equipo al aire después de su uso El kit se puede ampliar con más barras</p>

Elaboración de un sistema inteligente para la estimación de propiedades fisicoquímicas de suelos con producción de caña de azúcar

No.	Nombre	Diseño	Usos	Ventajas / Notas
11	Tubo perforador	<p>Conexión screwthread Profundidad máx. muestra 8 m material del producto hierro, otro material Diámetro de la muestra 46 mm Longitud de la muestra 100 cm Especificación de muestra inalterada Muestra almacenada en lámina, tubo Dimensiones (L*W*H) 135 x 8 x 8 cm Peso 11 kg</p>	<p>Descripción y clasificación del perfil del suelo Toma de muestras del suelo por encima del nivel freático Toma de muestras del suelo por debajo del nivel freático Estudio medioambiental del suelo Toma de muestras no alteradas</p>	<p>• Muestra encapsulada in situ Revestimiento de PVC transparente resistente para la inspección visual y la descripción del perfil Sin evaporación de agua o volátiles Sin contaminación de capas superiores El colector de perforación permite soltar la muestra, las arenas saturadas y las capas pedregosas Disponible solamente en un diámetro por lo que trabaja menos rápido en caso de muestreo de perfil completo El revestimiento de PVC puede adsorber y desorber volátiles El revestimiento de PVC generalmente no se puede volver a utilizar Para quitar el revestimiento, hay que cortar la muestra de manera longitudinal</p>
12	Kit de films insertables para muestreador			<p>Un material mucho más ligero, más fácil de retirar, resultados igualmente buenos sin olvidar un detalle: mucho más económico. El kit de films insertables sólo puede utilizarse en combinación con el muestreador de 63 mm, provisto de una rosca a la izquierda y racores RD32.</p>
13	Barrena de partida	<p>Barrenas de grandes diámetros. Clases: tipo Riverside y la barrena para arcillas blandas. La barrena tiene una "bocaza" de tal medida que hasta el material más grueso cabe en el muestreador. Un mango ergonómico, Una barrena de partida, Una barrena de media caña (tipo gubia) con diámetro de 60 mm, Una barrena para arcillas blandas, una barrena tipo Riverside de diámetro 100 mm y un tamiz de 16 mm.</p>	<p>Hace posible la toma de muestras de arena suelta, arena gruesa y grava fina</p>	<p>Satisface el protocolo BRL SIKB1000. Facilita la perforación en arena suelta, arena seca y gruesa y en grava fina. Disponible suelto o con un juego de herramientas.</p>
14	Muestreador de partido de perfiles	<p>Conexión screwthread Grosor máximo de la raíz 15 mm Profundidad máx. muestra 40 cm material del producto acero inoxidable, hierro, otro material Diámetro de la muestra 50 mm Longitud de la muestra 40 cm Especificación de muestra inalterada Muestra almacenada en lámina Volumen de la muestra 785 ml Posición de la muestra vertical Dimensiones (L*W*H) 126 x 65 x 50 cm Peso 35 kg</p>	<p>Descripción y clasificación del perfil del suelo Toma de muestras del suelo por encima del nivel freático Estudio medioambiental del suelo Toma de muestras no alteradas Estudio de la textura del suelo Toma de muestras de raíces Se usa por ejemplo en: • En la investigación del sistema de raíces • Estudios precisos (muestras para la descripción de perfiles) • La fertilización, la investigación química y la biología del suelo.</p>	<p>Perfecto para muestreo de superficie Se puede golpear Fácil apertura y sistema de tubo partido Estructura de acero inoxidable</p>
15	Muestreador de suelo con componentes volátiles	<p>Profundidad máx. muestra 0 m material del producto acero inoxidable, otro material Diámetro de la muestra 25 mm Longitud de la muestra 3.2 cm Especificación de muestra inalterada Muestra almacenada en anillo Volumen de la muestra 16 ml</p>	<p>Toma de muestras del suelo por encima del nivel freático Estudio medioambiental del suelo Toma de muestras no alteradas</p>	<p>Hay dos tipos: Equipo básico para el método del metanol sin determinación del peso seco. Con trepanador, émbolo, soporte con varilla para apretar lateralmente el anillo, martillo y 10 anillos de muestra con 20 tapas y 100 etiquetas. Equipo básico para refrigeración y método del metanol + determinación del peso seco. Con trepanador, émbolo, soporte con varilla para apretar lateralmente el anillo, martillo, 50 anillos de muestra, tapones (200 transparentes y 200 negros) y 200 etiquetas.</p>

Elaboración de un sistema inteligente para la estimación de propiedades fisicoquímicas de suelos con producción de caña de azúcar

No.	Nombre	Diseño	Usos	Ventajas / Notas
16	Equipo muestreador de perfil para investigación química del suelo	Una barrena Edelman para la perforación previa o para pulir el agujero. Un aparato perforador de acero con varios tubos muestreadores, recipientes para las muestras y placas aislantes. Tapas inferiores, un extractor de muestras, y material de mantenimiento. Conexión screwthread Profundidad máx. muestra 5 m material del producto acero inoxidable, hierro, otro material Diámetro de la muestra 38 mm Longitud de la muestra 20 cm Especificación de muestra inalterada Muestra almacenada en tubo Dimensiones (L*W*H) 7 x 30 x 24 cm Peso 41.5 kg Conexión screwthread	toma de muestras de suelo para determinar de la presencia de componentes muy volátiles como el benceno, tolueno, xileno e hidrocarburos clorados. Toma de muestras del suelo por encima del nivel freático Toma de muestras del suelo por debajo del nivel freático Estudio medioambiental del suelo Toma de muestras no alteradas	 Evita la pérdida de volátiles durante el muestreo Evita la pérdida de volátiles durante el transporte Cumple la norma EPA 5035A de EE.UU. Sin problemas en el terreno por el metanol Se puede combinar con el método de metanol Se puede golpear en suelos duros Todas las partes, excepto las tapas se pueden descontaminar repetidas veces No está indicado para suelos pedregosos
17	Barrena de aleta	Profundidad máx. muestra 2 m Punto of perfil de muestreo material del producto acero inoxidable, hierro, otro material Longitud de la muestra 25 cm Especificación de muestra semi-alterada Volumen de la muestra 47 ml Dimensiones (L*W*H) 50 x 25 x 13 cm Peso 4.3 kg Conexión bayoneta Diámetro de perforación 4 + 7 cm Profundidad máx. muestra 5 m Point or profile profile sampling material del producto acero inoxidable, hierro, otro material	Descripción y clasificación del perfil del suelo Toma de muestras del suelo por encima del nivel freático Toma de muestras del suelo por debajo del nivel freático Estudio de la textura del suelo Toma de muestras de granulados (plásticos, semillas, granos, minerales)	 Para muestreo de material seco o húmedo a profundidades de hasta 2 metros. Su forma delgada permite una fácil penetración en lodos, sedimentos, polvo, grano, granulados (< 3mm) y pastas. Ideal para tomar muestras en bidones, tanques y bolsas.
18	Juego de muestreador de pistón	Rod or cable operated rod Diámetro de la muestra 38 mm Longitud de la muestra 200 cm Especificación de muestra semi-alterada Volumen de la muestra 2.2 liter Posición de la muestra vertical Dimensiones (L*W*H) 221 x 17 x 20 cm Peso 16.5 kg Conexión screwthread Diámetro de perforación ≤ 10 cm Profundidad máx. muestra >8 m	Descripción y clasificación del perfil del suelo Toma de muestras del suelo por debajo del nivel freático Estudio medioambiental del suelo Toma de muestras no alteradas Toma de muestras de sedimentos	 Descripción perfecta de un perfil en un minuto Sin problemas de tuberías y tubos de perforación Visualización de hasta 2 m de suelo arenoso saturado También para fondos de agua Enjuagar después de usar para evitar el desgaste del pistón
19	Brocas de percusión hidráulicas con rodamiento de orugas	Fuente de alimentación gasolina material del producto hierro, otro material Longitud de la muestra 50 + 100 + 200 cm Especificación de muestra inalterada Muestra almacenada en lámina, tubo Posición de la muestra vertical Dimensiones (L*W*H) 197 x 87 x 200 cm Peso 1030 kg Ángulo o cono 0 ° Rango de superficie de cono 0.3165 cm ² Conexión screwthread, bayonet Diámetro de perforación 7 cm Fuerza máxima 500 @ 0.3165 cm ² kPa Profundidad máx. de medición 1 cm Profundidad máx. muestra 2 m Maximum shear stress 250 kPa	Descripción y clasificación del perfil del suelo Toma de muestras del suelo por encima del nivel freático Toma de muestras del suelo por debajo del nivel freático Estudio medioambiental del suelo Toma de muestras no alteradas	 Facilita enormemente la perforación a percusión Incluye dispositivo de tracción hidráulico Máquina estrecha que puede pasar por puertas
20	Muestreo y clasificación de suelos	Intervalo de medición 0 - 500 kPa, 0 - 2.5 kg/cm ² material del producto acero inoxidable, hierro, otro material Diámetro de la muestra 37 mm Longitud de la muestra 20 cm Especificación de muestra inalterada Muestra almacenada en lámina Posición de la muestra vertical Dimensiones (L*W*H) 117 x 27 x 23 cm Peso 21 kg	Descripción y clasificación del perfil del suelo Toma de muestras del suelo por encima del nivel freático	 Para determinar las cualidades físicas del suelo, se incluye un juego de tamices de bolsillo, un disco de arenas, una balanza electrónica portátil, un libro de identificación de colores para el suelo, un penetrómetro de bolsillo y un medidor de esfuerzo de corte de bolsillo, una lupa aplanática y una navaja de bolsillo. Para la determinación del nivel del agua subterránea hay un dispositivo de sondeo con cinta métrica.

No.	Nombre	Diseño	Usos	Ventajas / Notas
21	Muestreador de hierba	Grosor máximo de la raíz 5 mm Profundidad máx. muestra 5 cm material del producto acero inoxidable, hierro Diámetro de la muestra 23 mm Longitud de la muestra 50 mm Especificación de muestra inalterada Volumen de la muestra 25 ml Posición de la muestra vertical Dimensiones (L*W*H) 75 x 10 x 10 cm Peso 0.9 kg	Toma de muestras del suelo por encima del nivel freático Estudio medioambiental del suelo Toma de muestras no alteradas Toma de muestras de raíces	 Toma muestra mientras camina Perfecto para el muestreo de zonas radicales poco profundas Perfecto para el muestreo de suelos en depósitos al aire El muestreo nunca puede ser superior a 7 o 10 cm Acero inoxidable resistente no tóxico Es particularmente adecuado para la investigación en el cultivo de pastizales, así como en la horticultura y en los departamentos de Parques y Jardines
22	Barrenas de media caña de una pieza	Profundidad máx. muestra 1 m material del producto hierro, otro material Diámetro de la muestra 25 mm Longitud de la muestra 50 / 100 cm Especificación de muestra semi-alterada Dimensiones (L*W*H) 117 x 28 x 20 cm Peso 4.5 kg	Toma de muestras del suelo por encima del nivel freático Toma de muestras del suelo por debajo del nivel freático Estudio arqueológico del suelo Estudio medioambiental del suelo Colector de piedras Este complemento se utiliza para retirar las piedras sueltas dentro de un hoyo. En la investigación de perfiles: • Mapas de suelo. • Evaluaciones de aptitud del suelo. • Fines educativos. • Investigación de las raíces • Muestreo de suelos para la investigación de la fertilización. • Investigación de la distribución de la arcilla. • Investigación Paleontológica.	 Un más amplio perfil de estudio por cada muestra ya que la parte operacional es más larga en las barrenas de media caña. Se alcanza más profundidad en cada giro de la barrena lo que permite alcanzar grandes profundidades. Dado que la barrena de media caña corta una muestra del perfil del suelo las muestras obtenidas están prácticamente inalteradas.
23	Conexiones	Conexión tipo bayoneta: La principal ventaja de la conexión bayoneta es un acople muy rápido y su poco peso; resistente a fuerzas de torsión. Una ligera desventaja es que presenta un cierto juego y es inadecuado si hay que golpear las barrenas verticalmente. Conexión de rosca cónica: Esta conexión se basa en extremos cónicos roscados hembra y macho. Se ajusta firmemente con la ayuda de llaves, lo que constituye una construcción rígida que en su caso puede soportar golpes para introducir las barrenas.		 La conexión de bayoneta es el tipo de conexión es considerada como la estándar.
24	Perforador Akkerman	Profundidad máx. muestra 50 m Fuente de alimentación manual material del producto acero inoxidable, hierro, otro material Cuerda o cable cable operado Diámetro de la muestra 67 mm Longitud de la muestra 40 cm Especificación de muestra inalterada Muestra almacenada en tubo Posición de la muestra vertical Dimensiones (L*W*H) 130 x 42 x 24 cm Peso 120 kg	Toma de muestras del suelo por encima del nivel freático Toma de muestras del suelo por debajo del nivel freático Estudio geotécnico del suelo Toma de muestras no alteradas	 Tubos de perforación duraderos de acero inoxidable Martillo grande de alto impacto Sistema de válvula de bola para la mejor recuperación de la muestra Extrusora hidráulica resistente Revestimientos disponibles para tubos con colectores de perforación Requiere el uso de un trípode o mástil con cabrestante de caída libre
25	Barrena espiral	Esta barrena opera como un saca corchos, y no extrae el suelo.	Para perforar capas duras, por ejemplo en suelos calcáreos, y en combinación con otros tipos de barrena.	 Barrena forjada de alta resistencia a la tensión Formas de barrena perfectas para una perforación óptima Acero no tóxico para todo tipo de análisis Barras de extensión de conexión rápida Dejar secar la barrena al aire después de su uso Descontaminar con jabón Accionado por un solo operario hasta 10 m de profundidad

Elaboración de un sistema inteligente para la estimación de propiedades fisicoquímicas de suelos con producción de caña de azúcar

No.	Nombre	Diseño	Usos	Ventajas / Notas
26	Equipo de perforación manual para estudios geológicos	<p>Conexión bayoneta Profundidad máx. muestra 7 m material del producto hierro, otro material Diámetro de la muestra 7 cm Longitud de la muestra 10 cm Especificación de muestra alterada Posición de la muestra vertical Dimensiones (L*W*H) 117 x 27 x 23 cm Peso 18 kg</p>	<p>Descripción y clasificación del perfil del suelo Toma de muestras del suelo por encima del nivel freático Toma de muestras del suelo por debajo del nivel freático</p>	 <p>Juego de muestreo de suelos básico con la mayoría de las barrenas esenciales Para suelos blandos y duros Taladra hasta siete metros Accionado por un operario Peso ligero 17 kg</p>
27	Kit de perforación manual para suelos heterogéneos	<p>Conexión bayoneta Diámetro de perforación 7 + 10 cm Profundidad máx. muestra 7 m material del producto hierro, PVC, otro material Longitud de la muestra 10 cm Especificación de muestra alterada Posición de la muestra vertical Dimensiones (L*W*H) 120 x 80 x 50 cm Peso 150 kg</p>	<p>Descripción y clasificación del perfil del suelo Toma de muestras del suelo por encima del nivel freático Toma de muestras del suelo por debajo del nivel freático Estudio medioambiental del suelo Instalación de pozos de monitoreo Estudio geohidrológico Perforaciones de orientación. Toma de muestras de suelos. Colocación de tubos de sondeo.</p>	 <p>Kit muy completo; para tener siempre a mano el perforador adecuado. Funciona tanto por encima como por debajo del nivel freático. Apto tanto para la introducción de tubos de sondeo como para la toma de muestras de aguas subterráneas. Tubos durables, resistentes y ligeros. La plataforma de perforación facilita la introducción de los tubos. Sólo contiene elementos no contaminantes.</p>
28	Barrena Riverside	<p>consta de un tubo abierto con una abertura con dos picos en su base y un arco de soporte en su parte superior, que conecta a la barra de barrena. Las extremidades de la abertura están sesgadas para poder raspar el suelo presionando la muestra de manera uniforme hacia el interior del tubo. El diámetro de la boca de la barrena es ligeramente superior al del tubo a fin de reducir al mínimo la fricción entre el suelo y el tubo. La conexión con el mango puede ser a bayoneta o a rosca cónica</p>	<p>Uso para suelos duros y rígidos tales como barro seco, suelos de grava, para nivelar el fondo de un sondeo, antes de una toma de muestra inalterada Por encima y por debajo del nivel del agua subterránea. Las extremidades muy agudas de la barrena clavan con un cierto ángulo hacia abajo, lo que le permite atravesar el suelo fácilmente.</p>	 <p>Barrena forjada de alta resistencia a la tensión Formas de barrena perfectas para una perforación óptima Acero no tóxico para todo tipo de análisis Barras de extensión de conexión rápida Dejar secar la barrena al aire después de su uso Descontaminar con jabón Accionado por un solo operario hasta 10 m de profundidad</p>
29	Barrenas para suelos pedregosos	<p>esta construida en acero duro forjado en curva. Las puntas de corte son agudas y curvadas hacia fuera, lo que permite un diámetro de corte un poco mayor que el del cuerpo de la barrena.</p>	<p>Para suelos con gran contenido de grava.</p>	 <p>Barrena forjada de alta resistencia a la tensión Formas de barrena perfectas para una perforación óptima Acero no tóxico para todo tipo de análisis Barras de extensión de conexión rápida Notas Dejar secar la barrena al aire después de su uso Descontaminar con jabón Accionado por un solo operario hasta 10 m de profundidad</p>
30	Barreno para toma de cilindros de suelo	<p>Conexión screwthread Grosor máximo de la raíz 20 mm Profundidad máx. muestra 100 cm Fuente de alimentación gasolina material del producto hierro, PVC, otro material Cuerda o cable operado Diámetro de la muestra 84 mm Longitud de la muestra 100 cm Especificación de muestra inalterada Volumen de la muestra 6950 ml Posición de la muestra vertical Dimensiones (L*W*H) 145 x 62 x 72 cm Peso 101 kg</p>	<p>Descripción y clasificación del perfil del suelo Toma de muestras del suelo por encima del nivel freático Estudio medioambiental del suelo Toma de muestras no alteradas Estudio de la textura del suelo Toma de muestras de raíces Descripción de la estructura del suelo (incluso de las capas muy finas) Investigación de raíces para ganar en posibilidades de penetración del sistema radicular, considerando profundidad e intensidad Determinación de contenido y densidad del suelo mediante muestra inalterada Investigación del contenido de humedad y la concentración de sustancias disueltas en estudios de campo largos Estudios al posterior comportamiento del flujo de agua y sustancias disueltas en el suelo, p.e. en casos en que se produce un transporte de humedad preferencial Investigación arqueológica.</p>	 <p>Una muestra grande y lisa con un pequeño esfuerzo Baja fricción de extracción gracias al anillo de corte suelto Ventana grande para el muestreo secundario o descripción Móvil pero muy potente Perfecto para estudios exhaustivos del primer metro de superficie Limitado al primer metro de superficie No es adecuado para suelos muy duros (utilizar diámetro más pequeño)</p>

Elaboración de un sistema inteligente para la estimación de propiedades fisicoquímicas de suelos con producción de caña de azúcar

No.	Nombre	Diseño	Usos		Ventajas / Notas
31	Método de perforación de punta perdida	La punta perdida especialmente construida se clava en el suelo con un martillo eléctrico de golpe que se ha puesto encima de la cubierta. Entre los accesorios se encuentran: un martillo eléctrico de golpe, un motor-generador con protección térmica, percusores, un cabezal para la cubierta, cubiertas de acero, un aparatos de extracción, puntas perdidas y diversos accesorios. Está diseñado y equipado para hacer perforaciones hasta 10 metros de profundidad.	El método de perforación de punta perdida se aplica con mucho éxito en la colocación de tubos medidores de pequeño diámetro para estudios de higiene ambiental. La punta perdida se queda en el suelo después de perforar, pero esto no causa ningún tipo de problema ambiental, ya que los materiales usados existen en el suelo de forma natural.		Equipo completo de punta perdida. Método rápido y eficiente para perforar. No es necesario un gran medio de transporte, por lo que también se puede trabajar en áreas menos accesibles. La forma especial de la punta perdida genera una mínima fricción al insertar y extraer la cubierta.
32	De barrenas	Conexión screwthread, bayoneta, cuadrado material del producto hierro, otro material Diámetro de la muestra 7-20 cm Longitud de la muestra 10 cm Especificación de muestra semi-alterada Dimensiones (L*W*H) 69 x 6 x 6 cm Peso 0.9 kg	Descripción y clasificación del perfil del suelo Los hay para suelos arenosos, gravas, arcillas y combinado. Toma de muestras del suelo por encima del nivel freático		Barrena forjada de alta resistencia a la tensión Formas de barrena perfectas para una perforación óptima Acero no tóxico para todo tipo de análisis Barras de extensión de conexión rápida Dejar secar la barrena al aire después de su uso Descontaminar con jabón Accionado por un solo operario hasta 10 m de profundidad
33	Barrena Edelman				Barrena forjada de alta resistencia a la tensión Formas de barrena perfectas para una perforación óptima Acero no tóxico para todo tipo de análisis Barras de extensión de conexión rápida Dejar secar la barrena al aire después de su uso Descontaminar con jabón Accionado por un solo operario hasta 10 m de profundidad
34	Barrena Edelman para arena gruesa	Las hojas de esta barrena son extra anchas, formando así un sinfín casi cerrado.	Los suelos de arena gruesa y los suelos de arena extremadamente secos tienen poca o ninguna cohesión		Barrena forjada de alta resistencia a la tensión Formas de barrena perfectas para una perforación óptima Acero no tóxico para todo tipo de análisis Barras de extensión de conexión rápida Dejar secar la barrena al aire después de su uso Descontaminar con jabón Accionado por un solo operario hasta 10 m de profundidad
35	Edelman combinado		Es el modelo más habitual, ya que permite ser usado en diversos tipos de suelos.		Barrena forjada de alta resistencia a la tensión Formas de barrena perfectas para una perforación óptima Acero no tóxico para todo tipo de análisis Barras de extensión de conexión rápida Dejar secar la barrena al aire después de su uso Descontaminar con jabón Accionado por un solo operario hasta 10 m de profundidad
36	Muestreador de pistón	Se utiliza el pistón para vaciar la muestra en un canal. El muestreador y varios de sus accesorios se pueden llevar al campo en una bolsa de transporte.	Son muy adecuados para la toma de muestras de suelo poco cohesivo, debajo de las capas freáticas, de una profundidad de hasta 5m. Las muestras están poco alteradas, por lo que son adecuadas para la descripción de perfiles.		Descripción perfecta de un perfil en un minuto Sin problemas de tuberías y tubos de perforación Visualización de hasta 2 m de suelo arenoso saturado También para fondos de agua Enjuagar después de usar para evitar el desgaste del pistón

Elaboración de un sistema inteligente para la estimación de propiedades fisicoquímicas de suelos con producción de caña de azúcar






No.	Nombre	Diseño	Usos	Ventajas / Notas
37	Equipos de perforación a percusión para suelos heterogéneos	<p>Conexión screwthread</p> <p>Diámetro de perforación max 10 cm</p> <p>Profundidad máx. muestra 8 m</p> <p>Fuente de alimentación gasolina</p> <p>material del producto hierro, otro material</p> <p>Diámetro de la muestra 40 - 100 mm</p> <p>Longitud de la muestra 50 - 100 - 200 cm</p> <p>Especificación de muestra inalterada</p> <p>Muestra almacenada en lámina, tubo</p> <p>Posición de la muestra vertical</p> <p>Dimensiones (L*W*H) 223 x 80 x 80 cm</p> <p>Peso 375 kg</p>	<p>Descripción y clasificación del perfil del suelo</p> <p>Toma de muestras del suelo por encima del nivel freático</p> <p>Toma de muestras del suelo por debajo del nivel freático</p> <p>Estudio medioambiental del suelo</p> <p>Toma de muestras no alteradas</p>	 <p>Perfecto para suelos con ladrillos, con piedras grandes o muchas piedras</p> <p>La solución para centros de ciudad/terrenos industriales</p> <p>Muestras limpias buenas, sin uso de lubricantes</p> <p>Barras y gubias extremadamente resistentes</p> <p>Los diámetros permiten un trabajo eficiente, rápido y ligero</p> <p>Se puede combinar con la toma de muestras en film o revestimiento</p> <p>No reemplaza la perforación de diamante</p> <p>No está indicado para material fibroso como raíces (gruesas)</p> <p>Requiere porosidad, no está indicado para lodos glaciales</p> <p>Póngase en contacto con SonicSampDrill para profundidades mayores</p>
38	Muestreador de suelo para entubación SB	<p>Conexión screwthread</p> <p>Grosor máximo de la raíz 10 mm</p> <p>Profundidad máx. muestra 7 m</p> <p>material del producto acero inoxidable, hierro, otro material</p> <p>Diámetro de la muestra 50 mm</p> <p>Longitud de la muestra 300 mm</p> <p>Especificaciones de muestra inalterada</p> <p>Muestra almacenada en tubo</p> <p>Volumen de la muestra 590 ml</p> <p>Dimensiones (L*W*H) 130 x 50 x 72 cm</p> <p>Peso 38 kg</p>	<p>Toma de muestras del suelo por encima del nivel freático</p> <p>Toma de muestras del suelo por debajo del nivel freático</p> <p>Estudio medioambiental del suelo</p> <p>Toma de muestras no alteradas</p> <p>Estudio de la textura del suelo</p> <p>Toma de muestras de raíces</p> <p>Las muestras pueden utilizarse para:</p> <ul style="list-style-type: none"> • Determinaciones de fertilidad de suelo. • Ver la estructura del suelo. • Determinaciones de peso en volumen. • Determinación de composición granular. • Mediciones técnicas. • Educación agronómica. 	 <p>El revestimiento permite la fácil extracción de la muestra</p> <p>Visualización de la muestra directamente en el terreno</p> <p>Visualización de la muestra sin tocar</p> <p>Juego B, más indicado para suelos duros</p> <p>Muestreador de acero inoxidable</p> <p>El revestimiento adsorbe los volátiles</p>
39	Extractor modelo HC	<p>Largo: 52 cm.</p> <p>· Tubo recolector de muestras: 45 cm.</p> <p>· Mango: 20 cm de ancho</p>		
40	Muestreador Pürckhauer	<p>Longitudes: 81 y 117,5 cm</p> <p>Longitud de ranura: 600 y 1000 mm</p> <p>Diámetro superior: 20 y 28 mm</p> <p>Diámetro inferior: 22 y 25 mm</p> <p>Diámetro interior de ranura: 13 y 18 mm</p> <p>Peso: 2400 y 3800 g</p>	<p>Recogedor de muestras Pürckhauer de gran solidez para suelos pesados.</p>	
41	Muestreador geo-sampler	<p>Sin barra o con barra para ayudarse con el pie</p> <p>Longitud pequeña: 56 cm Longitud grande: 81 cm</p> <p>Longitud de la ranura: 300 mm</p> <p>Diámetro exterior: 17 y 20 mm respectivamente</p> <p>Diámetro interior: 11 y 14 mm respectivamente</p> <p>Peso: 550 g y 1500 g respectivamente</p>	<p>Muestreador para suelos ligeros, praderas, y céspedes</p>	
42	Equipo de perforación	<p>· Largo: 90 cm. totalmente montado</p> <p>· Longitud del taladro: 20 cm.</p> <p>· Mango: 30 cm de ancho</p>		

Tabla 6. Sistemas en el mercado para la extracción de muestras de suelos. (Burkle, n.d.; Eijkelkamp, n.d.; G.I.S. Ibérica, n.d.)

2.4 Desarrollo del sensor capacitivo.

Con el objetivo de obtener la respuesta en frecuencia del suelo, se realizó la fabricación de un sensor capacitivo y la programación de un amplificador lock-in que lograr realizar el análisis de la respuesta en frecuencia. Este amplificador es capaz de generar un barrido en frecuencia generando una señal analógica tipo senoidal y obtiene como resultado la respuesta en frecuencia en magnitud y fase de la señal resultante del sensor capacitivo.

El sistema fabricado está conformado por una cámara de temperatura controlada, un sensor capacitivo, y la programación de un sistema electrónico embebido que pueda realizar la función de un amplificador lock-in mediante el uso de una tarjeta FPGA (Field Programmable Gate Array).

2.4.1 Desarrollo del sensor

La Figura 18 muestra una vista isométrica de las 3 secciones del aparato; Cubierta lateral izquierda (1), cubierta frontal (2), cubierta lateral derecha (3), cubierta superior (4), cubierta posterior (7), el contenedor de tierra (9), tapa resistencia eléctrica (5), canaletas (6), conexiones de la cámara (8), el módulo de potencia (24), el módulo de control (25), una entrada de conexión de corriente alterna de 110Vac (29), un puerto RJ45 (30), un puerto de suministro de voltaje (28), un módulo de control (25) que es una tarjeta comercial MyRIO de la compañía National Instruments.




Figura 18. Imagen del sistema con identificación de partes e imagen real.

La Figura 19 muestra la cámara de temperatura controlada cuyo objetivo es mantener a 30°C el interior de la cámara durante la medición. Consta de 6 placas de Nylamid: placa frontal (10), placa inferior (11), placa lateral derecha (12), placa posterior (13), placa superior (17), placa lateral izquierda (16), las cuales ensambladas forman un contenedor que ayuda a conservar el calor. Cuenta con 2 orificios (10A) y (17A). El orificio de entrada de muestra (10A) sirve para poder introducir la muestra en el contenedor de tierra (9) que lleva el sensor capacitivo.




Figura 19. Núcleo de la cámara de temperatura controlada

En la Figura 20 se muestra el sensor capacitivo el cual contiene la muestra de suelo (20) que es utilizada como elemento dieléctrico del capacitor el cual está formado por dos placas de acero inoxidable: la placa superior del sensor capacitivo (18) y la placa inferior del sensor capacitivo (19). La placa inferior del sensor capacitivo (19) tiene 2 cables conectados en uno de sus extremos: terminal positivo placa inferior (19A) y terminal negativo placa inferior (19B) y la placa superior del sensor capacitivo (18) tiene 2 cables conectados en uno de sus extremos: el terminal positivo placa superior (18A) y el terminal negativo placa superior (18B). Estas 4 terminales (18A) (18B) (19A) (19B) van conectadas al módulo de control (25) a la entrada de audio analógica (31) y la salida de audio analógica (32). El capacitor está conectado en serie con una resistencia que tiene un valor de 10KOhms, haciendo con esto un filtro RC, la cual es requerida para conocer la respuesta en frecuencia del capacitor. La señal de excitación (31) consiste en una onda senoidal de 10 Volts Pico a Pico (10VPP) la cual es generada por el módulo de control (25) el cual en su interior contiene un FPGA. Dicho FPGA es programado para generar una señal senoidal que genere un barrido de frecuencias de 0-50KHz en pasos de 100Hz. Esta señal es enviada a través de la salida de audio (31) del módulo de control (25) hacia el circuito RC conformado por la resistencia (35) y las placas del sensor capacitivo (18) y (19). En cada paso de la frecuencia de la señal de excitación (31) se obtiene la respuesta en magnitud y fase del capacitor. Al final del estudio se logra obtener una gráfica completa del comportamiento del sensor en magnitud y fase a lo largo de la banda de frecuencias. Esta gráfica representa un patrón característico que le permite a la red neuronal estimar y cuantificar el contenido de K, Ca, Mg, Na y la conductividad eléctrica del suelo (CE).




Figura 20. Sensor Capacitivo.

La Figura 21 muestra una vista seccionada del interior de la cámara de temperatura controlada. Contiene un actuador que suministra el calor al interior de la cámara de temperatura controlada conformado por una resistencia eléctrica (23), un socket (22) y una base de aluminio metálica (21) la cual está ensamblada directamente la pieza (17A). La resistencia eléctrica (23) irradia calor a la cámara de temperatura controlada mediante la modulación del voltaje con un dimmer electrónico (24). Con fines estéticos se colocó una cubierta en 5 placas de plástico. Cubierta frontal (2), cubierta lateral derecha (3), cubierta lateral izquierda (1), cubierta superior (4), cubierta posterior (7). En esta figura también está indicado el contenedor de tierra (9), la placa superior del sensor capacitivo (18) y la placa inferior del sensor capacitivo (19).




Figura 21. Cámara de temperatura Controlada.

La Figura 22 muestra una vista seccionada el interior de la cámara de temperatura controlada. Un sensor de temperatura (34) es colocado sobre la placa lateral derecha (12) para realizar un monitoreo continuo de la temperatura al interior de la cámara. De igual forma, en esta figura se muestra el actuador que suministra el

calor al interior de la cámara de temperatura controlada conformado por una resistencia eléctrica (23), un socket (22) y una base de aluminio metálica (21) la cual está ensamblada directamente la pieza (17A).




Figura 22. Componentes armados de la cámara de temperatura controlada.

El módulo de control (25) es una tarjeta MyRIO de la compañía National Instruments, que consta de una Field Programmable Gate Array (FPGA) Xilinx, cuenta con una salida de audio analógica (31) que suministra una señal de excitación analógica con un barrido de frecuencia en el tiempo, también cuenta con una entrada de audio analógica (32) que corresponde a la señal de respuesta del capacitor a la señal de excitación.

El puerto C (33) contiene entradas analógicas para el sensor de temperatura y salidas analógicas para realizar el voltaje de control del dimmer (24). También consta una conexión USB (27) y una entrada de alimentación de voltaje del módulo de control (26).




Figura 23. Módulo de Potencia y Control.

La Figura 24 muestra el diagrama general de la cámara de temperatura controlada. Está conformada por un socket (22), una resistencia eléctrica (23), un dimmer (23) para controlar la energía suministrada a la resistencia eléctrica, el sensor de temperatura (34) que está conectado directamente a una entrada del convertidor Analógico a Digital del FPGA (38). El lazo cerrado de control está programado directamente dentro del FPGA, tomando en cuenta la temperatura de la cámara y a través de un control Proporcional-Integral-Derivativo (PID) (39) se logra realizar el control variando la energía entregada a la resistencia eléctrica (23) controlando el voltaje de control del dimmer (33).

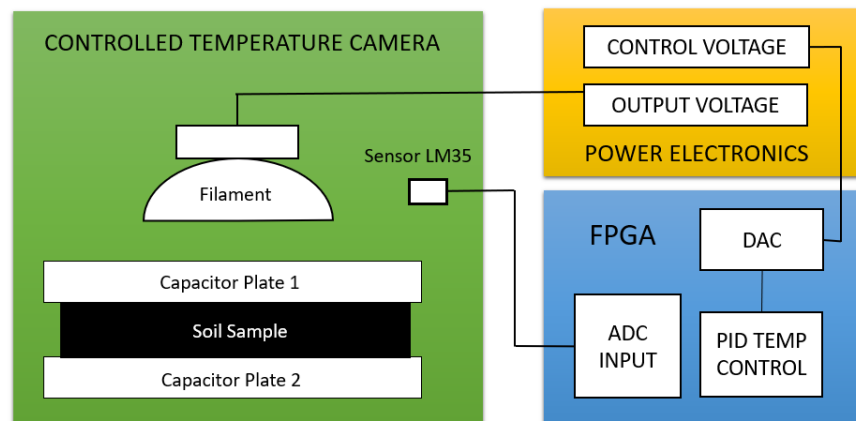


Figura 24. Diagrama general de la cámara de temperatura controlada.



Figura 25. Pruebas de control de temperatura.

El objetivo de la cámara de temperatura controlada es garantizar que las mediciones realizadas por el sensor capacitivo estén a una temperatura controlada debido a que cambios en la temperatura ocasionará variaciones en la magnitud de la señal del sensor capacitivo. Esta cámara (Figura 21) está compuesta por 6 placas de Nylamid (10) (11) (12) (13) (16) (17) las cuales se maquinan para garantizar la precisión en sus dimensiones. Con el objetivo de reducir la interferencia electromagnética se coloca papel aluminio en las paredes interiores de la cámara de temperatura controlada. Para realizar el control de temperatura se requiere de un sensor de temperatura (34) comercial LM35 que constantemente está monitoreando la temperatura al interior de la cámara. Esta señal de salida analógica del sensor va conectado al convertidor analógico-digital número 0 (ADC) del puerto C del módulo de control (25). Al interior del módulo de control contiene la programación para realizar un control PID, estableciendo 30°C como punto de referencia del controlador. La salida del control PID se encuentra en un rango de 0-4096, dicho valor es enviado a través del Convertidor Digital a Analógico número 0 del puerto C del módulo de control (25), el cual convierte la señal digital a un rango 0-10VDC. Este voltaje es suministrado a la entrada del voltaje de control (33) del dimmer (24). Al variar el voltaje de entrada de 0-10VDC, el dimmer variará la energía suministrada a la resistencia eléctrica (23) de 0-110VAC. Con lo cual se puede controlar la energía disipada en forma de calor por la resistencia eléctrica (23). En la Figura 25 se puede apreciar una de las pruebas iniciales en el proceso del control PID de temperatura dentro de la cámara.

2.4.2 Desarrollo del amplificador lock-in utilizando FPGA

La selección del dispositivo tuvo que cumplir con una serie de requisitos para poder realizar o imitar las funciones con las que normalmente opera un amplificador lock-in. Estos requisitos se enlistan a continuación:

1. Señal de Entrada Analógica de 12-bits a 250 kbps
2. Señal de Salida Analógica de 12-bits a 250 kbps
3. Capacidad para desarrollar algoritmos de FFT y AFFT (Transformada de Fourier y Anti-Transformada Inversa de Fourier) a 250 kbps.
4. Capacidad para crear interfaces gráficas y almacenar información

Para poder cumplir con los 4 requisitos establecidos se seleccionó un dispositivo Electrónico Embebido (MyRIO de National Instruments) que tiene un FPGA XILIX Zynq-7010 y un procesador de 667 MHz dual-cortex ARM Cortex-A9. Ambos trabajando conjuntamente en tiempo real. Se seleccionó este dispositivo por ser un sistema de bajo costo y que cumple con todos los requerimientos necesarios para realizar las tareas de un amplificador lock-in. Además de ser un sistema embebido que no requiere de una computadora para desempeñar su trabajo.

Dentro del FPGA se realiza la programación para generar una señal analógica de tipo senoidal con la capacidad de hacer un barrido de frecuencia de 0-50Khz en tiempo real. Esta señal analógica será la señal de entrada al sensor capacitivo y se utiliza el puerto de Audio Out de salida analógica del FPGA. La respuesta del sensor es obtenida e ingresada al puerto de Audio In de entrada analógica. Las 2 señales son filtradas utilizando filtros pasa-bajas Butterworth. La convolución de 2 señales es obtenida utilizando DFFT en cada señal (Generada y la obtenida del capacitor) y multiplicando los resultados obtenidos por la DFFT. Posteriormente se realiza la antitransformada para obtener el resultado en magnitud y fase de la respuesta en frecuencia del sensor capacitivo.

La Figura 26 muestra el diagrama general del funcionamiento del sensor capacitivo utilizando las técnicas de espectroscopia. Consta de la salida de audio analógica que realiza la generación de una onda senoidal con la capacidad de modular su frecuencia. La entrada de audio analógica recibe la señal de la respuesta en frecuencia del capacitor. La señal generada y la recibida del capacitor son analizadas dentro del FPGA para obtener su respuesta en frecuencia con finalidad de obtener su magnitud y fase. Esta respuesta en frecuencia es enviada al módulo de la red neuronal artificial que es el módulo responsable de realizar la determinación y cuantificación de la conductividad eléctrica, K, Ca, Mg y Na.

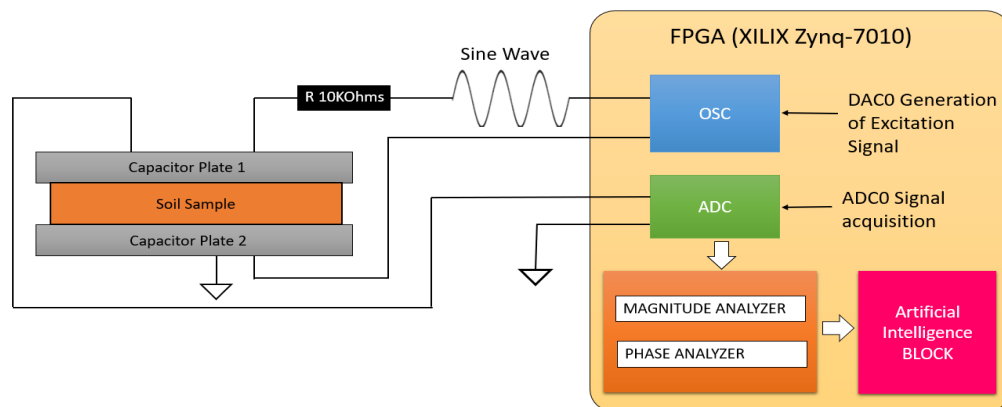


Figura 26. Diagrama general del funcionamiento del sensor capacitivo utilizando las técnicas de espectroscopia.

El FPGA genera una onda senoidal usando una tabla de 2048 valores. La variación de la frecuencia de la señal es obtenida a través del uso preciso de temporizadores, los cuales ejecutan cada uno de los valores de la tabla durante la generación de la onda senoidal. Esta onda senoidal es pasada a través de los convertidores digital-analógico (DAC) los cuales son conectados a una resistencia de 10KOhms. Esta resistencia es conectada en serie con la placa del capacitor 1, creando un circuito RC. El voltaje de salida del capacitor es adquirido usando un convertidor analógico/digital (AD), en el FPGA se calcula la respuesta en frecuencia del sensor en tiempo real. Las ecuaciones (1) y (2) muestran los cálculos de la ganancia y fase. El Tdelay es el retraso en segundo del voltaje del capacitor con respecto a la entrada de voltaje (onda senoidal) y la Tsignal es el tiempo de duración de un ciclo.

$$Gain\ dB = 20\log_{10}\frac{V_{out}}{V_{in}} \quad \text{Ecuación 1}$$

$$Phase = \Phi = \frac{360^{\circ} \cdot T_{delay}}{T_{signal}} \quad \text{Ecuación 2}$$

La interface gráfica (GUI) fue diseñada y programada en LabVIEW, el cual está conectado al FPGA y al bloque de inteligencia artificial. Como es mostrado en la Figura 28.

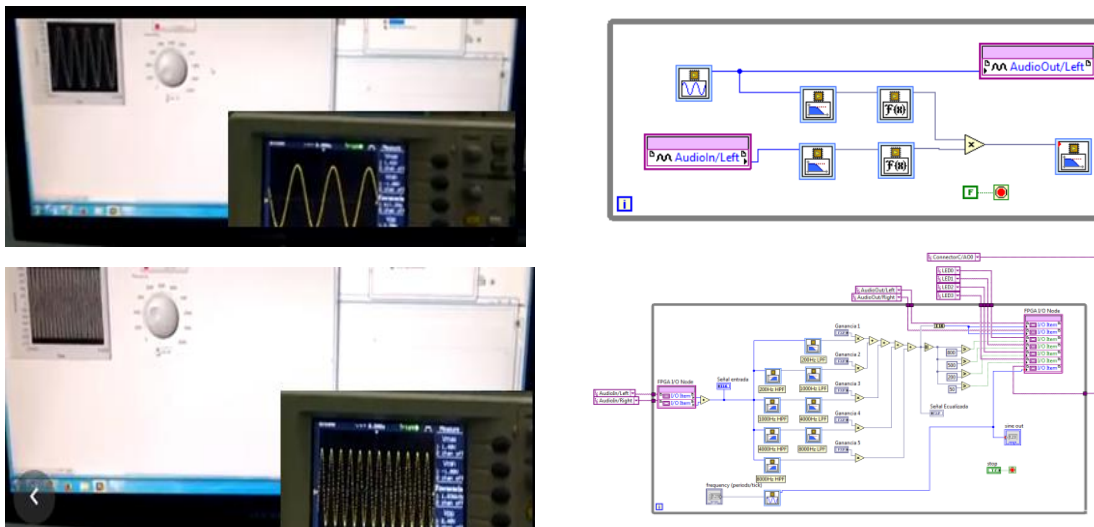


Figura 27. Generación de señal senoidal en el FPGA.

2.4.3 Inteligencia Artificial utilizada para la determinación de variables fisicoquímicas

La respuesta en frecuencia del suelo no puede por si misma ni determinar ni cuantificar las propiedades fisicoquímicas del suelo. Es por esto que algoritmos de inteligencia artificial fueron implementados utilizando los datos de la respuesta en frecuencia para la determinación de las propiedades físicoquímicas. Algoritmos de aprendizaje supervisado fueron utilizadas en particular las redes neuronales artificiales, regresión logística, máquinas de soporte vectorial, clasificadores Gradient boosting, arboles de decisión, Random Forest, Naive Bayes y Nearest neighbors fueron seleccionados. La razón por utilizar más de un algoritmo de IA es para comparar el desenvolvimiento y el grado de reconocimiento de cada algoritmo. Las librerías Scikit-learn fueron usadas en Python para entrenar, analizar y calcular toda la información adquirida por el sensor en tiempo real. En la figura 29 se muestran los bloques de la integración de la interface gráfica de la PC con el FPGA y el bloque de inteligencia artificial.

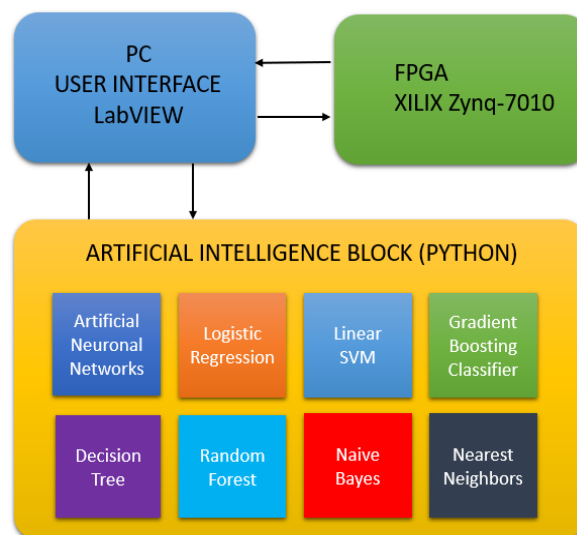


Figura 28. Integración de la interface grafica de la PC con el FPGA y el bloque de inteligencia artificial.

Un conjunto de muestras fue utilizado para entrenar los algoritmos de inteligencia artificial y el resto de las muestras fueron utilizadas para la validación. Un radio de 70/30 es usualmente implementado para dividir los datos entre el entrenamiento y los datos utilizados para la validación. La figura 30 indica el

procedimiento para determinar las propiedades fisicoquímicas del suelo utilizando algoritmos de inteligencia artificial. Los datos de entrada al sistema inteligente son proporcionados por el sensor vía TCP/IP a Python, en el cual están programados los bloques de inteligencia artificial.

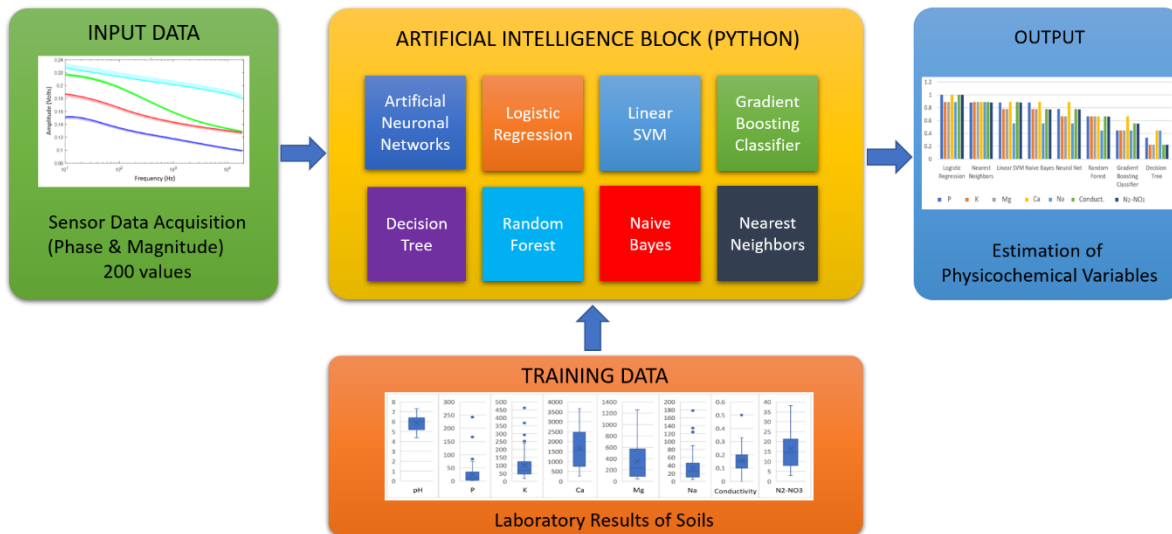


Figura 29. Determinación de las propiedades fisicoquímicas del suelo utilizando algoritmos de inteligencia artificial y el sensor.

2.5 Sensor óptico de análisis de color y textura en suelos.

2.5.1 Introducción

La relación existente entre las diferentes propiedades del suelo brinda la posibilidad de inferir algunas propiedades en base a la información obtenida de otras, incluso si pertenecen a otro tipo de propiedades, es decir, en base a la teoría por la relación existente se pueden inferir algunas propiedades químicas a partir de propiedades físicas. La textura, el color y la estructura del suelo son variables que pueden ayudar a determinar e inferir otras propiedades fisicoquímicas del suelo. Por esta razón, se decidió realizar un sistema de visión que logre obtener las características de textura, color y estructura del suelo de las muestras para posteriormente a través de algoritmos de inteligencia artificial nos permitan determinar y estimar variables químicas de las muestras de suelo.

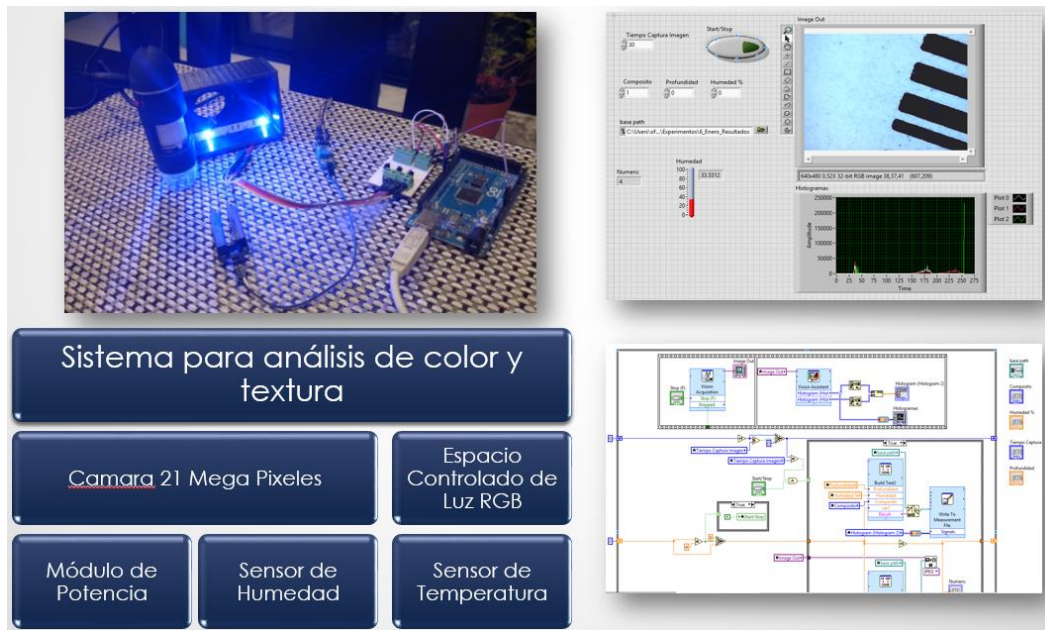


Figura 30. Sistema de adquisición de imágenes

El sistema de visión desarrollado consiste en una cámara digital de 12 Mega Pixeles y un sistema controlado de iluminación en donde las muestras son colocadas y analizadas. También se realizó un programa en labVIEW para la adquisición de la imagen y su procesamiento digital. Este último consistió en realizar el cálculo matemático del algoritmo de extracción de características de Haralick para el análisis de textura, la obtención del histograma HSL y RGB para la determinación. Al sistema se le ha añadido sensores comerciales de temperatura y humedad todos controlados por la tarjeta arduino. La Figura 30 muestra el sistema completo de adquisición de imágenes.

2.5.2 Textura

El término textura se refiere a la proporción de arena, limo y arcilla expresados en porcentaje. En la fracción mineral del suelo, son de interés edafológico solamente las partículas menores a 2mm de diámetro. A las partículas mayores a este diámetro se les denomina “modificadores textuales”, dentro de este concepto también se incluyen los carbonatos, la materia orgánica, las sales en exceso, etc.

Consecuentemente:

$$\% \text{ arena} + \% \text{ limo} + \% \text{ arcilla} = 100\% \quad \text{Ecuación 3}$$

Específicamente en el proyecto se utilizó una de las técnicas más sofisticadas y más utilizadas en visión artificial para el análisis de textura en imágenes la cual está basada en la extracción de características Haralick. A continuación, se describen cada una de estas características:

2.5.2.1 Contraste

El contraste mide la cantidad de los cambios localizados en una imagen. Refleja la sensibilidad de las texturas en relación con los cambios en la intensidad. Regresa la medida de la intensidad del contraste entre un píxel y sus alrededores. Si la cantidad de las variaciones locales son grandes, la característica de contraste también tiene valores más elevados consistentemente y al compararlos. Si una diferencia en la escala de grises ocurre continuamente, la textura se vuelve gruesa y el contraste se vuelve más grande. La textura se vuelve sutil si el contraste tiene un valor pequeño.

$$\text{Contraste} = \sum_{n=0}^{N_g-1} n^2 \sum_{|i-j|=n} P_d(i, j) \quad \text{Ecuación 4}$$

2.5.2.2 Correlación

Esta característica mide como correlacionar un píxel con sus alrededores. Es una medida de dependencias del tono gris lineal en una imagen. Los valores de esta característica están en el rango de -1 a 1, estos extremos indican una correlación perfecta entre negativo y positivo respectivamente. μ_i y μ_j son las medias y σ_i y σ_j son las desviaciones estándar de $P_d(i)$ y $P_d(j)$ respectivamente.

$$\text{Correlación} = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i-\mu) P_d(i, j)}{\sigma_i \sigma_j} \quad \text{Ecuación 5}$$

2.5.2.3 Homogeneidad

La homogeneidad mide la similitud de píxeles. Una matriz de co-ocurrencia con nivel gris diagonal proporciona la homogeneidad de 1. Se vuelve grande si las texturas locales solo tienen cambios mínimos.

$$\text{Homogeneidad} = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \frac{P_d(i, j)}{1+|i-j|} \quad \text{Ecuación 6}$$

2.5.2.4 Energía

La energía también significa uniformidad, o Segundo Momento Angular (ASM). Entre más homogénea sea la imagen, el valor será más grande. Cuando la energía equivale a 1, la imagen se considera como una imagen constante.

$$\text{Energía} = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} P_d^2(i, j) \quad \text{Ecuación 7}$$

2.5.2.5 Entropía

La entropía es una medición de la aleatoriedad de la intensidad de una imagen.

$$\text{Entropía} = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} P_d(i, j) \log(P_d(i, j)) \quad \text{Ecuación 8}$$

2.5.2.6 Característica de Segundo Momento Angular (ASM)

Esta característica es una medida de la uniformidad de la distribución de la escala gris local. Si $P(i, j, d, \theta)$ está centralizado cerca del área media diagonal, la distribución de la escala de grises local se vuelve uniforme. Es una medida de la

homogeneidad de la imagen. Una imagen homogénea presenta muy pocas transiciones dominantes en tono gris. La matriz para la imagen tendrá menos entradas de gran magnitud.

Se puede calcular usando la siguiente fórmula,

$$ASM = \sum_{i=0}^{L-1} \sum_{j=0}^{L-1} [\hat{p}(i, j, d, \theta)]^2 \quad \text{Ecuación 9}$$

Las características de energía, entropía, contraste, homogeneidad y correlación son usadas frecuentemente entre las 14 características de textura de Haralick para evidenciar ciertas propiedades sobre la distribución espacial de la textura en una imagen.

2.5.3 Color del suelo

El color del suelo es una de las características morfológicas que se observan con mayor facilidad y una de las más útiles ya que refleja la composición del suelo, además de sus condiciones pasadas y presentes de óxido-reducción del suelo. Está determinado generalmente por el revestimiento de partículas muy finas de materia orgánica humidificada (oscuro), óxidos de fierro (amarillo, pardo, anaranjado y rojo), óxidos de manganeso (negro) y otros, o puede ser debido al color de la roca parental.

En la parte de experimentación para el procesamiento digital de la imagen se utilizó el algoritmo de conversión de espacio de color de RGB a HSL.

$$Cmax = \max(R', G', B') \quad \text{Ecuación 10}$$

$$Cmin = \min(R', G', B') \quad \text{Ecuación 11}$$

$$\Delta = Cmax - Cmin \quad \text{Ecuación 12}$$

Cálculo de Hue

$$H = \begin{cases} 0^\circ, & \Delta = 0 \\ 60^\circ \left(\frac{G' - B'}{\Delta} \text{ mod } 6 \right), & Cmax = R' \\ 60^\circ \left(\frac{B' - R'}{\Delta} + 2 \right), & Cmax = G' \\ 60^\circ \left(\frac{R' - G'}{\Delta} + 4 \right), & Cmax = B' \end{cases} \quad \text{Ecuación 13}$$

Cálculo de Saturación

$$S = \begin{cases} 0, & \Delta = 0 \\ \frac{\Delta}{1 - |2L - 1|}, & \Delta <> 0 \end{cases} \quad \text{Ecuación 14}$$

Cálculo de iluminación

$$L = \frac{(Cmax + Cmin)}{2} \quad \text{Ecuación 15}$$

2.6 Sensor de conductividad térmica

El objetivo del sensor de conductividad térmica es obtener información relacionada al contenido de humedad en el suelo. Para realizar esto se utilizó un sensor basado en el método de Hot Ball (HB), el cual está formado por una esfera de metal sumergida en la muestra de interés y una etapa de calentamiento aplicado por un calentador. El fundamento teórico se describe como sigue:

$$T(t) = \frac{Q}{4\pi kR} \left[1 - \exp\left(-\frac{\alpha t}{R^2}\right) \operatorname{erfc}\left(\frac{\sqrt{\alpha t}}{R}\right) \right] \quad \text{Ecuación 16}$$

Siendo T la temperatura, t el tiempo, K y α la conductividad térmica y la difusividad térmica de la muestra respectivamente, Q el calor liberado, y $\operatorname{erfc}(x)$ la función del error complementario.

Las mediciones HB requieren garantizar un contacto térmico entre el sensor y la muestra. Por lo tanto, las muestras se prepararon por compactación mecánica del compósito alrededor del sensor HB. Todas las mediciones fueron realizadas a $23 \pm 1^\circ\text{C}$, y una vez la muestra estuvo a la temperatura deseada, se le aplicó 5mW al calentador de la bola. Las señales de medición de la temperatura se ajustaron con la ecuación 36, utilizando la conductividad térmica como el parámetro de ajuste. Previo a la medición se calibró el sistema con aceite de castor para asegurar las condiciones experimentales correctas.

Cada compósito de suelo evaluado con el sensor estuvo compuesto de 6 muestras. Para un total de 30 puntos de muestreo que se utilizaron para crear 5 compósitos; dos de estas estuvieron comprendidas entre los 0 y los 10cm, dos más entre los 10 y 30 cm.

Cada muestra fue subdividida en 3 sub-muestras y empaquetadas al vacío y se utilizaron para evaluar el sensor de conductividad térmica.



Figura 31. Sensor Hotball

CAPÍTULO III. ANÁLISIS Y EVALUACIÓN DE RESULTADOS FISICOQUÍMICOS DEL SUELO

Se detectaron variaciones importantes en algunos puntos, a continuación, se describe las medias obtenidas por municipio. Si bien el pH ideal se encuentra entre 6 y 7, se mantiene una buena disponibilidad de nutrientes por arriba de 5.5, por lo tanto, con la información obtenida hasta el momento hay 10 municipios, Córdoba, Fortín, Río Blanco, Coetzala, Amatlán de los Reyes, Ixtaczoquitlan, Tlilapan, Cuitlahuac, Camarón de Tejeda y Omealca que se consideran ácidos y no se pueden aprovechar los nutrientes además de tener probabilidades de toxicidad de algún micronutriente. Mientras que para los municipios de Paso del Macho y Yanga se obtuvieron resultados alcalinos dificultando el transporte de nutrientes (Figura 32).





Figura 32. Gráfica de pH de muestras en suelos en la región en estudio, en rojo se puede observar el rango de pH óptimo.

Aunque el pH en varios de estos municipios se encuentra dentro de rango la información correspondiente a la CIC confirma que el municipio de Omealca es el único que presenta valores que permiten el correcto transporte de nutrientes sin embargo la presencia de pH ácido podría estar permitiendo también la movilización de toxinas (Figura 33).

Por otro lado, se encuentra la MO que colabora con nutrientes disponibles para las plantas, y proporciona un indicador de la estructura del suelo debido a que le proporciona al suelo la capacidad de auto-recuperación; en los últimos municipios se ve un poco menor el contenido de MO; sin embargo, todo por encima de lo

deseable. De igual forma, cabe resaltar las variaciones dentro de los perfiles (0 – 30 cm) de suelo para el municipio de Tlaltetela.



a. Resultados de CIC

b. Resultados de MO

Figura 33. Gráficas de CIC (a) y MO (b) en suelos a 3 profundidades, en rojo se observa el límite para muy bajo CIC y en amarillo donde el suelo es bajo en CIC.

Los macronutrientes presentes en las muestras se resumen la siguiente tabla (Tabla 7), esta incluye una valoración, en donde se destaca que las concentraciones de Ca están por debajo de lo óptimo para los municipios de Córdoba, Fortín, Amatlan de los Reyes, Río Blanco, Coetzala, Ixtaczoquitlan, Tlilapan, Cuitlahuac y Camarón de Tejeda; esto muestra relación con los datos de pH reportados arriba. Para el P, la concentración óptima se encuentra solo en un segmento de profundidad y en los cuatro municipios en la capa superficial es encuentra muy alta su concentración, el K se encuentra en óptima concentración para el municipio del Naranjal y el Mg para el municipio de Tlilapan.

En cuanto a los municipios de Yanga y Cuichapa que presentan valores de P y K muy bajos o bajos y aunque el Ca este óptimo en el caso de Cuichapa tiene un pH que no permite la movilización de todos los nutrientes además de tener concentraciones muy bajas; esto se corrobora con los datos de pH reportados arriba.

Los municipios restantes; Paso del Macho, Omealca y Carrillo Puerto también presentan deficiencias principalmente en P y K y concentraciones altas de Mg y Ca para el caso de Paso del Macho.

	Profundidad cm	P		K		Ca		Mg	
		ppm	Valoración	ppm	Valoración	ppm	Valoración	ppm	Valoración
Córdoba	0 – 10	12	Bajo	64	Bajo	713	Bajo	102	Medio
	10 – 20	6	Bajo	54	Bajo	712	Bajo	89	Medio
	20 – 30	1	Muy bajo	27	Muy bajo	763	Medio	76	Medio
Fortín	0 – 10	9	Bajo	241	Muy alto	1663	Medio	280	Muy alto
	10 – 20	3	Muy bajo	109	Medio	1200	Medio	222	Óptimo
	20 – 30	2	Muy bajo	86	Bajo	963	Medio	185	Óptimo
Amatlán de los Reyes	0 – 10	83	Muy alto	83	Bajo	1024	Bajo	112	Medio
	10 – 20	39	Óptimo	64	Bajo	344	Bajo	49	Bajo
	20 – 30	7	Bajo	46	Muy bajo	512	Bajo	68	Medio

Elaboración de un sistema inteligente para la estimación de propiedades fisicoquímicas de suelos con producción de caña de azúcar

Río Blanco	0 – 10	75	Muy alto	79	Medio	388	Bajo	72	Medio
	10 – 20	35	Óptimo	53	Bajo	258	Bajo	48	Bajo
	20 – 30	11	Bajo	54	Bajo	323	Medio	54	Bajo
Naranja	0 – 10	68	Muy alto	213	Óptimo	3411	Óptimo	463	Muy alto
	10 – 20	69	Muy alto	183	Óptimo	3488	Óptimo	371	Muy alto
	20 – 30	42	Óptimo	192	Óptimo	3637	Óptimo	404	Muy alto
Coetzala	0 – 10	47	Óptimo	188	Muy alto	907	Bajo	105	Medio
	10 – 20	17	Medio	94	Medio	410	Bajo	47	Bajo
	20 – 30	3	Muy bajo	67	Bajo	301	Bajo	39	Bajo
Ixtaczoquitlan	0 – 10	242	Muy alto	145	Óptimo	691	Bajo	135	Medio
	10 – 20	167	Muy alto	114	Medio	383	Muy bajo	57	Bajo
	20 – 30	126	Muy alto	70	Muy bajo	315	Muy bajo	85	Medio
Atoyac	0 – 10	55	Muy alto	253	Muy alto	2253	Óptimo	311	Muy alto
	10 – 20	35	Óptimo	462	Muy alto	2721	Óptimo	224	Óptimo
	20 – 30	45	Óptimo	358	Muy alto	2487	Óptimo	268	Óptimo
Tlilapan	0 – 10	27	Medio	80	Bajo	1321	Medio	210	Óptimo
	10 – 20	20	Medio	119	Medio	1375	Medio	212	Óptimo
	20 – 30	24	Medio	100	Bajo	1348	Medio	211	Óptimo
Cuitláhuac	0 – 10	15	Medio	117	Medio	2165	Medio	287	Muy alto
	10 – 20	12	Bajo	256	Muy alto	1098	Bajo	68	Bajo
	20 – 30	10	Bajo	133	Medio	986	Bajo	71	Bajo
Camarón de Tejada	0 – 10	5	Bajo	59	Bajo	622	Bajo	84	Medio
	10 – 20	2	Muy bajo	134	Medio	817	Bajo	99	Medio
	20 – 30	2	Muy bajo	72	Bajo	783	Bajo	72	Medio
Chocamán	0 – 10	17	Medio	113	Medio	2712	Óptimo	352	Muy alto
	10 – 20	57	Muy alto	262	Muy alto	959	Medio	82	Medio
	20 – 30	60	Muy alto	257	Muy alto	970	Medio	95	Medio
Yanga	0 – 10	11	Bajo	54	Muy bajo	2182	Medio	895	Muy alto
	10 – 20	4	Bajo	28	Muy bajo	1519	Medio	501	Muy alto
	20 – 30	2	Muy bajo	46	Muy bajo	2941	Óptimo	1257	Muy alto
Cuichapa	0 – 10	2	Muy bajo	39	Muy bajo	2903	Óptimo	645	Muy alto
	10 – 20	3	Muy bajo	37	Muy bajo	3522	Óptimo	946	Muy alto
	20 – 30	1	Muy bajo	25	Muy bajo	3231	Óptimo	738	Muy alto
Tlaltetela	0 – 10	15	Medio	367	Muy alto	3081	Óptimo	172	Medio
	10 – 20	6	Bajo	209	Muy alto	1807	Óptimo	152	Medio
	20 – 30	6	Bajo	180	Muy alto	1539	Medio	145	Medio
Paso del Macho	0 – 10	14	Bajo	177	Óptimo	5703	Muy alto	285	Óptimo
	10 – 20	10	Bajo	133	Medio	6065	Muy alto	339	Muy alto
	20 – 30	6	Bajo	107	Bajo	8922	Muy alto	324	Muy alto
Omealca	0 – 10	39	Óptimo	122	Medio	696	Bajo	83	Medio
	10 – 20	16	Medio	80	Bajo	923	Medio	110	Medio
	20 – 30	8	Bajo	49	Muy bajo	1126	Medio	119	Medio
Carrillo Puerto	0 – 10	13	Bajo	47	Muy bajo	1735	Medio	556	Muy alto
	10 – 20	7	Bajo	35	Muy bajo	2378	Medio	709	Muy alto
	20 – 30	7	Bajo	37	Muy bajo	1667	Medio	567	Muy alto

Tabla 7. Contenido de macronutrientes en muestras de suelos y valoración.

En cuanto las concentraciones de micronutrientes se encontró una gran variabilidad en las concentraciones presentes. La

Tabla 8 resume la concentración reportada y la valoración para cada una de las profundidades, si bien los micronutrientes no requieren el uso de fertilizantes específicos podría haber toxicidad de Cu en el municipio de Amatlán de los Reyes y la presencia de Mn por arriba de 200 ppm en los suelos de Cuitláhuac, Camarón de Tejada y Amatlán de los Reyes con un pH de 5 y 4.7 respectivamente podría resultar en toxicidad de Mn.

Mientras que las concentraciones de azufre son bajas para los municipios de Paso del Macho y Carrillo Puerto y ese elemento es necesario para el mejor rendimiento de la caña de azúcar.

Municipio	Profundidad	S - SO4		B		Cu		Fe		Mn		Zn	
	cm	ppm	Valoración	ppm	Valoración	ppm	Valoración	ppm	Valoración	ppm	Valoración	ppm	Valoración
Córdoba	0 - 10	33	Óptimo	0.2	Bajo	1.8	Medio	103	Óptimo	174	Óptimo	1.9	Medio
	10 - 20	43	Muy alto	0.1	Muy bajo	1.4	Medio	91	Medio	202	Óptimo	1.3	Bajo
	20 - 30	58	Muy alto	0.1	Muy bajo	0.4	Bajo	61	Medio	214	Óptimo	0.5	Muy bajo
Fortín	0 - 10	15	Medio	0.4	Medio	2.9	Medio	98	Medio	186	Óptimo	4.1	Óptimo
	10 - 20	35	Óptimo	0.2	Bajo	2.3	Medio	82	Medio	144	Medio	2	Medio
	20 - 30	87	Muy alto	0.2	Bajo	1.1	Medio	71	Medio	130	Medio	0.9	Medio
Amatlán de los Reyes	0 - 10	44	Muy alto	0.1	Muy bajo	4.6	Muy alto	121	Óptimo	161	Óptimo	2.5	Medio
	10 - 20	92	Muy alto	0.1	Muy bajo	4.8	Muy alto	117	Óptimo	182	Óptimo	2.1	Medio
	20 - 30	63	Muy alto	0.1	Muy bajo	3.7	Óptimo	94	Medio	303	Muy alto	3.6	Óptimo
Riό Blanco	0 - 10	27	Óptimo	0.1	Muy bajo	1.4	Medio	180	Óptimo	25	Bajo	1.3	Bajo
	10 - 20	31	Óptimo	0.1	Muy bajo	1.4	Medio	129	Óptimo	24	Bajo	1.3	Bajo
	20 - 30	28	Óptimo	0.1	Muy bajo	1.5	Medio	95	Medio	25	Bajo	1.3	Bajo
Naranja	0 - 10	10	Bajo	0.5	Medio	1.3	Medio	135	Óptimo	32	Medio	6.1	Óptimo
	10 - 20	9	Bajo	0.4	Medio	1.3	Medio	134	Óptimo	25	Bajo	5.8	Óptimo
	20 - 30	7	Bajo	0.4	Medio	1.2	Medio	115	Óptimo	30	Medio	3.7	Óptimo
Coetzala	0 - 10	40	Óptimo	0.2	Bajo	2.3	Medio	108	Óptimo	100	Medio	3.1	Óptimo
	10 - 20	72	Medio	0.1	Muy bajo	2.3	Medio	96	Medio	101	Medio	2.1	Medio
	20 - 30	97	Muy alto	0.2	Bajo	2.2	Medio	121	Óptimo	144	Medio	1.8	Medio
Ixtaczoquitlan	0 - 10	15	Medio	0.2	Bajo	2.9	Medio	160	Óptimo	38	Medio	2.5	Medio
	10 - 20	28	Óptimo	0.2	Bajo	2.1	Medio	155	Óptimo	33	Medio	2.3	Medio
	20 - 30	25	Óptimo	0.1	Muy bajo	1.4	Medio	129	Óptimo	20	Bajo	1.2	Bajo
Atoyac	0 - 10	18	Medio	0.6	Óptimo	1.5	Medio	86	Medio	18	Bajo	4.6	Óptimo
	10 - 20	11	Medio	0.7	Óptimo	1.2	Medio	79	Medio	28	Medio	3.5	Óptimo


Elaboración de un sistema inteligente para la estimación de propiedades fisicoquímicas de suelos con producción de caña de azúcar

	20 - 30	14.5	Medio	0.65	Óptimo	1.35	Medio	82.5	Medio	23	Bajo	4.05	Óptimo
Tlilapan	0 - 10	16	Medio	0.3	Bajo	1.3	Medio	96	Medio	96	Medio	1.9	Medio
	10 - 20	17	Medio	0.2	Bajo	1.5	Medio	104	Óptimo	97	Medio	1.6	Medio
	20 - 30	16.5	Medio	0.25	Bajo	1.4	Medio	100	Óptimo	96.5	Medio	1.75	Medio
Cuitláhuac	0 - 10	14	Medio	0.6	Óptimo	3	Óptimo	92	Medio	112	Medio	10	Muy alto
	10 - 20	91	Muy alto	0.2	Bajo	4.7	Muy alto	175	Óptimo	386	Muy alto	5.6	Óptimo
	20 - 30	85	Muy alto	0.2	Bajo	2.3	Medio	102	Óptimo	126	Medio	2.4	Medio
Camarón de Tejeda	0 - 10	52	Muy alto	0.1	Muy bajo	1.2	Medio	74	Medio	179	Óptimo	1.2	Bajo
	10 - 20	52	Muy alto	0.3	Bajo	1.8	Medio	74	Medio	132	Medio	1.5	Bajo
	20 - 30	68	Muy alto	0.1	Muy bajo	4.1	Muy alto	107	Óptimo	252	Muy alto	2.8	Medio
Chocaman	0 - 10	13	Medio	0.7	Óptimo	3.4	Óptimo	102	Óptimo	125	Medio	11.5	Muy alto
	10 - 20	24	Óptimo	0.5	Medio	0.8	Bajo	40	Bajo	157	Óptimo	1.1	Bajo
	20 - 30	11	Medio	0.4	Medio	1.2	Medio	52	Bajo	187	Óptimo	5.4	Óptimo
Yanga	0 - 10	9	Bajo	0.3	Bajo	0.8	Bajo	131	Óptimo	66	Medio	1	Bajo
	10 - 20	4	Muy bajo	0.2	Bajo	0.7	Bajo	97	Medio	50	Medio	0.8	Bajo
	20 - 30	4	Muy bajo	0.4	Medio	0.7	Bajo	74	Medio	51	Medio	0.8	Bajo
Cuichapa	0 - 10	14	Medio	0.3	Bajo	0.8	Bajo	91	Medio	48	Medio	0.9	Bajo
	10 - 20	17	Medio	0.2	Bajo	1	Medio	97	Medio	49	Medio	1.1	Bajo
	20 - 30	14	Medio	0.2	Bajo	0.5	Bajo	73	Medio	79	Medio	2.1	Medio
Tlaltetela	0 - 10	14	Medio	1	Óptimo	2.1	Medio	100	Medio	72	Medio	9.9	Muy alto
	10 - 20	13	Medio	0.5	Medio	1.4	Medio	89	Medio	35	Medio	3.6	Óptimo
	20 - 30	9	Bajo	0.3	Bajo	1.5	Medio	90	Medio	35	Medio	2.5	Medio
Paso del Macho	0 - 10	8	Bajo	0.7	Óptimo	2.8	Medio	81	Medio	49	Medio	4.2	Óptimo
	10 - 20	10	Bajo	0.8	Óptimo	3.8	Óptimo	106	Óptimo	63	Medio	5.4	Óptimo
	20 - 30	16	Medio	0.8	Óptimo	3.4	Óptimo	99	Medio	67	Medio	3.7	Óptimo
Omealca	0 - 10	8	Bajo	0.2	Bajo	2.6	Medio	144	Óptimo	39	Medio	4.1	Óptimo


	10 - 20	12	Medio	0.2	Bajo	2.6	Medio	131	Óptimo	32	Medio	2.6	Medio
	20 - 30	14	Medio	0.2	Bajo	2.5	Medio	121	Óptimo	36	Medio	2	Medio
Carrillo Puerto	0 - 10	12	Medio	0.2	Bajo	0.9	Medio	138	Óptimo	71	Medio	1.2	Bajo
	10 - 20	6	Bajo	0.3	Bajo	0.6	Bajo	95	Medio	48	Medio	0.5	Muy bajo
	20 - 30	8	Bajo	0.2	Bajo	0.6	Bajo	110	Óptimo	73	Medio	0.5	Muy bajo

Tabla 8. Concentraciones de micronutrientes y valoraciones de las muestras de suelos a distintas profundidades

El porcentaje SC se presenta a continuación en la Figura 34 en donde podemos observar los porcentajes para K, Ca, Mg y Na que sumados deberían mostrar una saturación superior al 60% en sitios de intercambio en el suelo para los iones básicos mencionados. Por otro lado, en la Figura 35 se muestra el complemento en la SC con los sitios ocupados por cationes ácidos (H). Es importante mencionar que el pH superior a 6 se puede relacionar con saturaciones superiores a 70% como sucede con los municipios del Naranjal, Atoyac, Tlilapan y Chocamán.




a) Saturación catiónica de K



b) Saturación catiónica de Ca



c) Saturación catiónica de Mg



d) Saturación catiónica de Na

Figura 34. Porcentajes de SC para diversos iones catiónicos.




Figura 35. Saturación de iones ácidos. En rojo se observa el límite deseable de estos iones. La conductividad obtenida fue con efectos no significativos de salinidad para todos los suelos muestreados como se puede observar en la Figura 36 y concuerda para suelos no salinos.




Figura 36. Datos de conductividad recolectados.

El N – NO₃ también presentó resultados por debajo de lo deseable (20 ppm) para los municipios del Naranjal, Tlilapan, Tlaltetela, Omealca y Carrillo Puerto mientras que, para los municipios de Atoyac, Chocamán y Cuitlahuac se observa

contienen la concentración óptima de 0 – 10 cm, sin embargo, no se mantiene en el perfil (Figura 37)




Figura 37. Datos obtenidos para concentraciones de N – NO3 presentes en los suelos

Para confirmar si existe una diferencia significativa entre las profundidades para las variables fisicoquímicas determinadas por muestras se realizaron evaluaciones estadísticas utilizando la herramienta de ANOVA de dos vías, el cual utiliza la siguiente nomenclatura:

r : Número de niveles en el factor fila

c : Número de niveles en el factor columna

rc : Total de observaciones

x_{ij} : Observaciones en la celda (ij) de la tabla

Y las siguientes ecuaciones:

$$T_{Ri} = \sum_j x_{ij} : \text{Suma de las observaciones } c \text{ en la } i\text{th} \text{ fila} \quad \text{Ecuación 17}$$

$$T_{Cj} = \sum_i x_{ij} : \text{Suma de observaciones } r \text{ en la } j\text{th} \text{ columna} \quad \text{Ecuación 18}$$

$$T = \sum_i \sum_j x_{ij} = \sum_i T_{Ri} = \sum_j T_{Cj} : \text{Suma de todas las observaciones } rc \quad \text{Ecuación 19}$$

$$SS_T = \sum_i \sum_j x_{ij}^2 - \frac{T^2}{rc} : \text{Suma de cuadrados} \quad \text{Ecuación 20}$$

$$SS_R = \sum_i \frac{T_{Ri}^2}{c} - \frac{T^2}{rc} : \text{Suma de cuadrados entre filas} \quad \text{Ecuación 21}$$

$$SS_c = \sum_j \frac{T_{Cj}^2}{r} - \frac{T^2}{rc} : \text{Suma de cuadrados entre columnas} \quad \text{Ecuación 22}$$

$$SS_E = SS_T - SS_R - SS_C : \text{Suma de cuadrados para Error residual} \quad \text{Ecuación 23}$$

Para finalmente, determinar los grados de libertad y la relación F:

Fuente de variación	Suma de cuadrados	Grados de libertad	Cuadrados medios	Relación F
Entre filas	SS_R	$c - 1$	MS_R	$\frac{MS_R}{MS_E}$
Entre columnas	SS_C	$r - 1$	MS_C	$\frac{MS_C}{MS_E}$
Error (residual)	SS_E	$(r - 1)(c - 1)$	MS_E	
Total	SS_T	$rc - 1$	MS_T	

Se evaluaron las siguientes hipótesis:

$H_0: \mu_1 = \mu_2$ Las medias son iguales; por lo tanto, no hay diferencia significativa

$H_1: \mu_1 \neq \mu_2$ Las medias son diferentes; por lo tanto, hay diferencia significativa

Para un nivel de significancia de $\alpha = 0.05$

Una vez determinados los cálculos se obtuvieron las F calculadas que se muestran a continuación, en la Tabla 9:

VARIABLE	F	VARIABLE	F	VARIABLE	F
PH SUELO	0.57	pH tampón	3.05	MO	8.63
P	9.69	K	7.15	Ca	3.06
Mg	11.25	S	3.72	B	4.37
Cu	4.63	Fe	5.28	Mn	1.11
Zn	2.79	Na	1.14	Conductividad	5.82
N ₂ -NO ₃ ⁻	0.54	CIC	5.46	SC K	5.70
Sc Ca	3.10	SC Mg	11.33	SC H	3.05
Sc Na	2.50	relación K/Mg	0.29	relación Ca/Mg	0.17
Arena	0.53	Limo	0.58	Arcilla	0.78
Densidad aparente	0.58	Capacidad de campo 1/3 bar	0.53	Punto de marchitez permanente 15 Bar	0.51

Tabla 9. Estadísticos de t calculados para cada grupo de valores para cada variable analizada por profundidad y mezclada en una muestra compuesta.

Al compararlo con el dato de F de tablas (3.287) con el nivel de significancia mencionado arriba (0.05). Se concluyó que hay diferencia significativa para MO, P, K, Mg, S, B, Cu, la conductividad, la CIC, la SC K y la SC Mg; por lo tanto, se confirmó que las evaluaciones de los suelos a 3 profundidades son relevantes para encontrar las variaciones entre los sitios y en los mismos sitios a distintas profundidades.

CAPÍTULO IV. ANALISIS E INTERPRETACIÓN DE LOS RESULTADOS DE LA EXPERIMENTACIÓN CON EL SENSOR CAPACITIVO

4.1 Experimentación del sensor capacitivo

4.1.1 Experimentación y análisis sin muestra de suelo con variaciones en temperatura ambiental

Se realizaron experimentos con el sensor capacitivo sin el material dielectrico (muestra del suelo) a 4 diferentes temperaturas ambientales (20°, 25°, 30°, 35°) para visualizar la forma en que estas afectaban la medición. En las Figura 38 y Figura 39 se observa la respuesta en Magnitud del capacitor a un barrido en frecuencia de 1Hz hasta 100Khz.




Figura 38. Medición de Magnitud con aire como dieléctrico (temperatura de 20 a 35)




Figura 39. Medición de fase con aire como dieléctrico (temperatura de 20 a 35)

Las respuestas en magnitud y fase obtenidas en los 4 puntos de temperatura seleccionados tuvieron un error medio de 3.24% y 2.87% en magnitud y fase respectivamente. Estos errores obtenidos durante la variación de la temperatura indican que el sensor sin muestra de suelo no tiene una sensibilidad significativa con el cambio de temperatura. Sin embargo, estas variaciones en temperatura con la muestra de suelo como material dieléctrico pueden presentar cambios en la medición, por lo cual se procedió a realizar la experimentación correspondiente para conocer la variación en la medición de la respuesta en frecuencia que el sensor presenta en diferentes intervalos de temperatura como se presenta en la siguiente sección.

4.1.2 Experimentación y análisis del sensor sin muestra de suelo con variaciones en temperatura ambiental.

Se realizaron un total de 24 análisis con 8 muestras de suelo a 4 temperaturas controladas de 20°C, 25°C, 30°C y 35°C. A continuación, se muestran las gráficas

con los resultados obtenidos; estas muestran la respuesta en frecuencia en magnitud y fase del sensor capacitivo de 8 muestras de suelo diferentes con las 4 temperaturas controladas. Las Figura 40 a la Un grupo de 8 submuestras fueron utilizadas para validar la respuesta en frecuencia del sensor cuando hay una variación en la temperatura. Para cada muestra de suelo, la temperatura fue establecida en un rango de 25 a 35°C en pasos de 2.5°C. Como la Figura 40 lo muestra, la amplitud es reducida proporcionalmente a cada incremento de temperatura. Las 8 muestras de suelos fueron agrupadas con un color específico, y cada grupo contiene la información de la respuesta en frecuencia en diferentes temperaturas. En todos los casos, la máxima amplitud de la respuesta en frecuencia del sensor corresponde al mínimo de la temperatura., muestran las gráficas de la respuesta en frecuencia en magnitud y fase durante la ejecución del experimento.

Es importante resaltar que se observa que la respuesta en frecuencia en magnitud y fase permanece similar en cuanto a su forma en las 4 temperaturas y lo único que cambia con la temperatura es un desplazamiento proporcional en el eje de Magnitud y fase. Los resultados estadísticos son mostrados al final de esta sección.

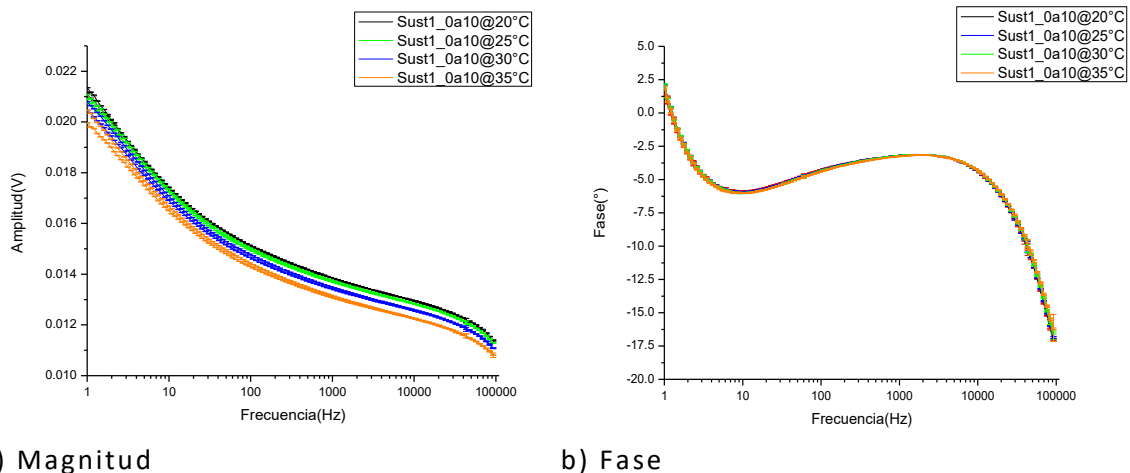


Figura 40. Medición de Magnitud y fase del sustrato 1 en una profundidad de 0 a 10 cm para las 4 temperaturas propuestas.

Un grupo de 8 submuestras fueron utilizadas para validar la respuesta en frecuencia del sensor cuando hay una variación en la temperatura. Para cada muestra de suelo, la temperatura fue establecida en un rango de 25 a 35°C en pasos de 2.5°C. Como la Figura 40 lo muestra, la amplitud es reducida proporcionalmente a cada incremento de temperatura. Las 8 muestras de suelos fueron agrupadas con un color específico, y cada grupo contiene la información de la respuesta en frecuencia en diferentes temperaturas. En todos los casos, la máxima amplitud de la respuesta en frecuencia del sensor corresponde al mínimo de la temperatura.




Figura 41. Respuesta en frecuencia del sensor (magnitud) en las 8 muestras de suelo.




Figura 42. Respuesta en frecuencia del sensor (fase) en las 8 muestras de suelo

Realizando un estudio estadístico de las muestras de suelo las 4 diferentes temperaturas, los resultados mostraron:

- 1) Existe una variación significativa en las gráficas de magnitud y fase en la respuesta en frecuencia del sensor por lo cual es importante realizar todos los experimentos en temperatura controlada.
- 2) La variación en la respuesta en frecuencia de magnitud y fase del sensor durante el experimento muestra que hay una variación lineal, por lo que dependiendo de la temperatura en la toma de la muestra de suelo puede ser compensado matemáticamente.

4.1.3 Análisis de varianza de magnitud

A continuación, se presenta el estudio del análisis de varianza de la respuesta en frecuencia en magnitud de las muestras suelo.

(# de filas) r =	6					
(# de columnas) c =	194					
r*c =	1164					
$T = \sum T_{r_i}$	174.14					
T_{c_j}	22.81	28.21	31.27	37.52	26.09	28.24
$\sum x_{ij}^2 =$	27.2636					

$$\sum T_{cj}^2 = 520.12 \quad 795.71 \quad 978.01 \quad 1407.39 \quad 680.95 \quad 797.67$$

$$\sum T_{cj}^2 = 5179.86$$

$$\sum T_{cj}^2/c = 26.70$$

$$\sum T_{ri}^2 = 159.31$$

$$\sum T_{ri}^2/r = 26.551$$

$$T^2/rc = 26.052$$

Fuente de variación	Suma de cuadrados	Grados de libertad	Cuadrados medios	Relación F	F tablas
SSR (entre suelos)	0.50	193	0.003	38.57	
SSC (entre características de imagen)	0.65	5	0.130	1934.41	2.115
SSr (residual)	0.06	965	0.00007		
total	1.21	1163			

Hipótesis:

$H_0: \mu_i = \mu$ No hay diferencia significativa entre medias

$H_1: \mu_i \neq \mu$ Hay diferencia significativa entre medias

Nivel de 0.95
significancia:

Ft:	2.115		
Por lo tanto:	2.11	<	1934.41

Se acepta hipótesis alternativa, hay diferencia significativa entre las respuestas a la frecuencia en magnitud de cada muestra de suelo estudiado.

Los resultados muestran que existe una varianza significativa entre los datos de las muestras por lo que nos indica que el sensor en su respuesta en frecuencia en magnitud tiene la capacidad de ver las variaciones de las propiedades fisicoquímicas de las muestras. Estos datos al tener esta varianza hacen posible

que se puedan ingresar a un algoritmo basado en inteligencia artificial para correlacionar o estimar los datos de esta magnitud con los datos los análisis de laboratorio.

4.1.4 Análisis de Varianza de la fase

A continuación, se presenta el estudio del análisis de varianza de la respuesta en frecuencia en magnitud de las muestras suelo.

(# de filas)	r =	6					
(# de columnas)	c =	194					
	r*c =	1164					
$T = \sum T_{ri}$	=	-9046.70					
T_{cj}	=	-1591.46	-1536.99	-1815.46	-1496.95	-1346.07	-1259.76
$\sum x_{ij}^2$	=	123200.36					
T_{cj}^2	=	2532774.85	2362356.704	3295895.74	2240856.31	1811899.59	1586989.21
$\sum T_{cj}^2$	=	13830772.4					
$\sum T_{cj}^2/c$	=	71292.6413					
$\sum T_{ri}^2$	=	716699.67					
$\sum T_{ri}^2/r$	=	119450					
T^2/rc	=	70312					

Fuente de variación	Suma de cuadrados	Grados de libertad	Cuadrados medios	Relación F	F tablas
SSR (entre suelos)	49138.27	193	254.602	88.72	
SSC (entre características de imagen)	980.97	5	196.194	68.36	2.115
SSr (residual)	2769.44	965	2.87		
total	52888.68	1163			

Hipótesis:

$H_0: \mu_i = \mu$ No hay diferencia significativa entre medias

$H_1: \mu_i \neq \mu$ Hay diferencia significativa entre medias

Nivel de significancia: 0.95

Ft:	2.115		
Por lo tanto:	2.11	<	1934.41

Se acepta hipótesis alternativa, hay diferencia significativa entre las respuestas a la frecuencia en fase de cada muestra de suelo estudiado.

Los resultados muestran que existe una varianza significativa entre los datos de las muestras por lo que nos indica que el sensor en su respuesta en frecuencia en magnitud tiene la capacidad de ver las variaciones de las propiedades fisicoquímicas de las muestras. Estos datos al tener esta varianza hacen posible que se puedan ingresar a un algoritmo basado en inteligencia artificial para correlacionar o estimar los datos de esta magnitud con los datos los análisis de laboratorio.

4.1.5 Histéresis

En cada muestra de suelo se realiza un barrido de frecuencia de 1Hz-50KHz y de 50KHz a 1Hz. Acorde a los análisis realizados se aprecia que la histéresis en la frecuencia 0 a 1KHz el offset del sensor presenta un 7.3% de diferencia y de 1KHz a 50KHz presenta una diferencia de 5.1%.

4.1.6 Repetibilidad

Una prueba requerida para poder conocer a detalle la confiabilidad del sensor es el parámetro de la repetibilidad. En el sensor anterior se documentó una serie de experimentos para determinar la repetibilidad. Sin embargo, solo se usaron 3 submuestras por cada muestra de suelo.

Para realizar esta prueba a cada muestra de suelo se separó en 8 submuestras; por lo tanto, se realizó el análisis para cada una de las submuestras de suelo, dando por resultado un error cuadrático medio del 4.96%. En la Figura 43 se muestra el análisis de la respuesta en frecuencia de magnitud y fase de solo 4 muestras con sus respectivas 8 submuestras.

Se puede apreciar que la respuesta del sensor ante suelos con condiciones fisicoquímicas iguales (las submuestras de cada muestra de suelo) presentan un comportamiento repetible. Al analizar el 100% de las submuestras de suelo

presentó un rango de error de aproximadamente 5%, es decir que la repetibilidad del sensor está por arriba del 95%.




Figura 43. Graficas de Repetibilidad en Magnitud y Fase para 4 muestras con sus respectivas 8 submuestras.

CAPITULO V: ANÁLISIS E INTERPRETACIÓN DE RESULTADOS DE LA EXPERIMENTACIÓN CON EL SENSOR ÓPTICO

La experimentación consistió en realizar el análisis de color y textura de 53 muestras de suelo de caña de azúcar extraídas para el proyecto, las 53 muestras seleccionadas fueron las que tuvieron una varianza significativa mayor entre sus datos de las propiedades fisicoquímicas obtenidas en laboratorio. A cada muestra se le hizo el análisis con 80% de humedad y 5% de humedad. Dando por resultado 106 imágenes analizadas. En los siguientes segmentos se explican los algoritmos utilizados para el análisis de estas imágenes.

5.1 Adquisición de datos por visión artificial de Color y Textura

De la Figura 44 a la Figura 68 se presenta la adquisición y el procesamiento digital de 106 imágenes seleccionadas. En todas las figuras se muestra la imagen original, el histograma HSL, el histograma RGB y los parámetros de contraste, correlación, homogeneidad, energía, entropía y disimilitud correspondientes a los parámetros de extracción de texturas de Haralick. En la sección 5.2 se presenta los análisis estadísticos de las 106 muestras utilizadas.

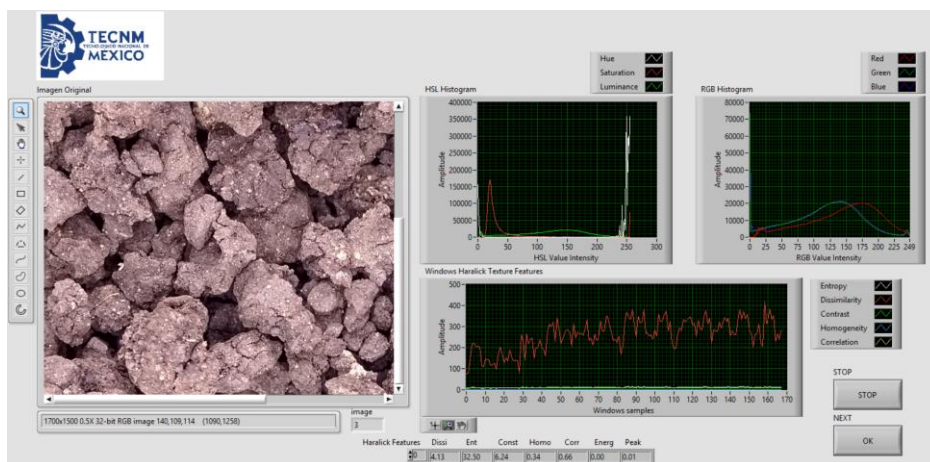


Figura 44. Compósito 1, Profundidad 0-10cm, Submuestra 1, Humedad 5%

Elaboración de un sistema inteligente para la estimación de propiedades fisicoquímicas de suelos con producción de caña de azúcar

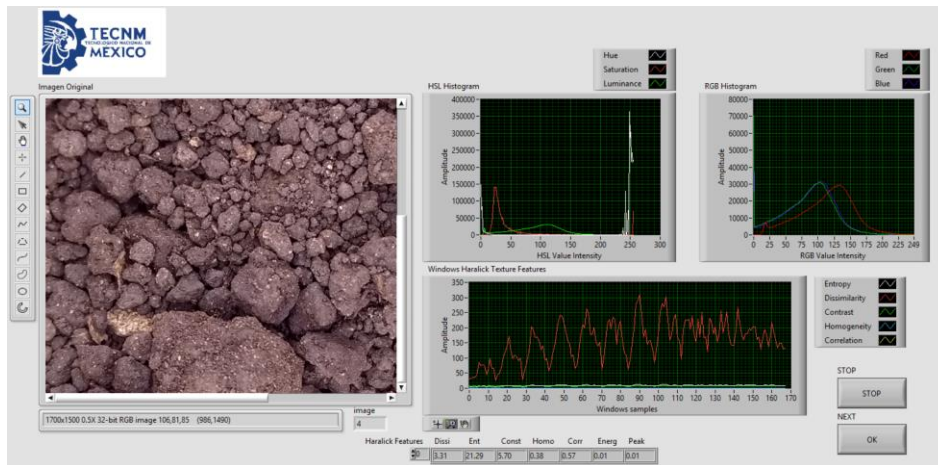


Figura 45. Compósito 1, Profundidad 0-10cm, Submuestra 2, Humedad 5%

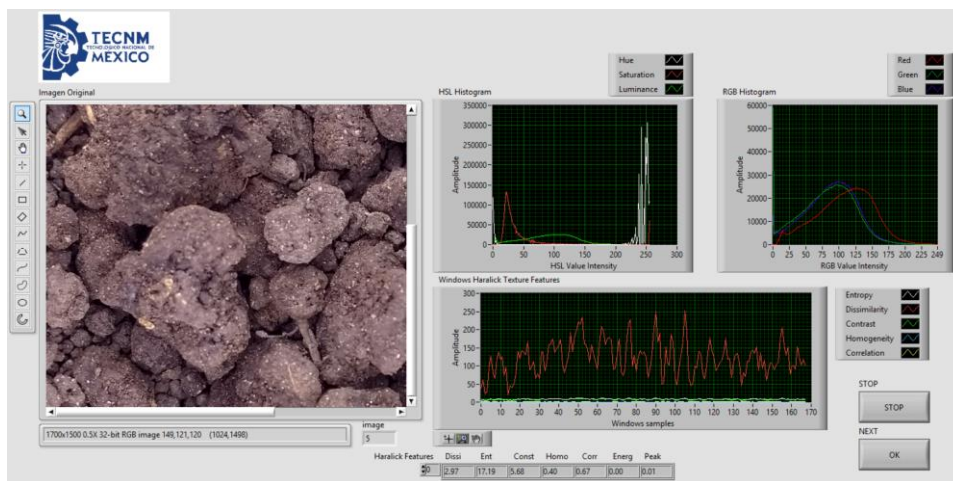


Figura 46. Compósito 2, Profundidad 0-10cm, Submuestra 1, Humedad 5%

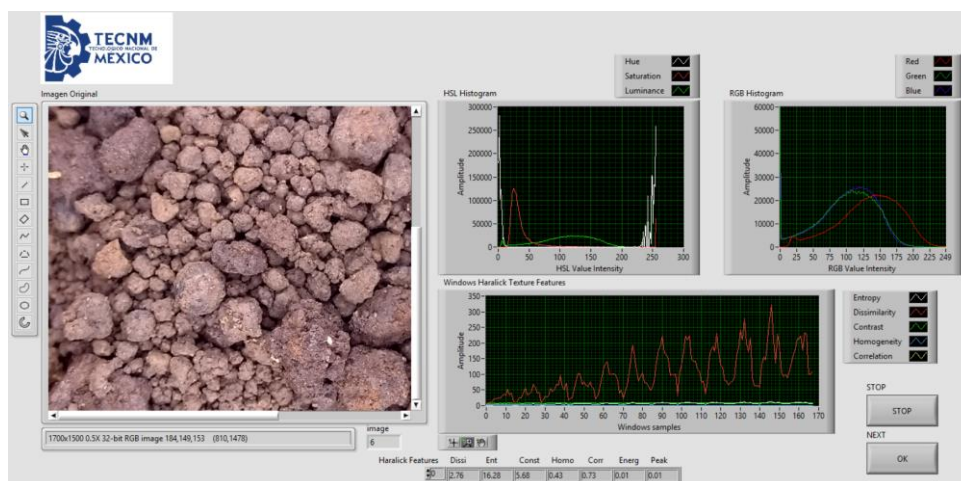


Figura 47. Compósito 2, Profundidad 0-20cm, Submuestra 2, Humedad 5%

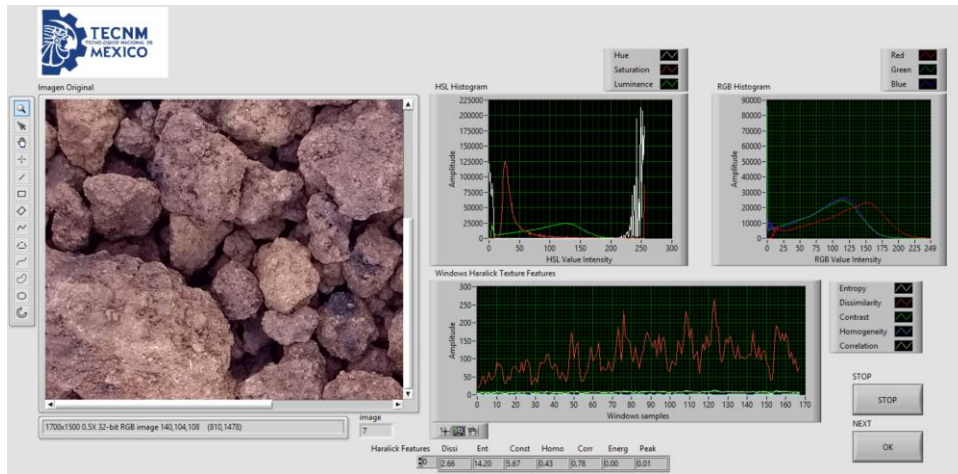


Figura 48. Compósito 2, Profundidad 0-30cm, Submuestra 2, Humedad 5%

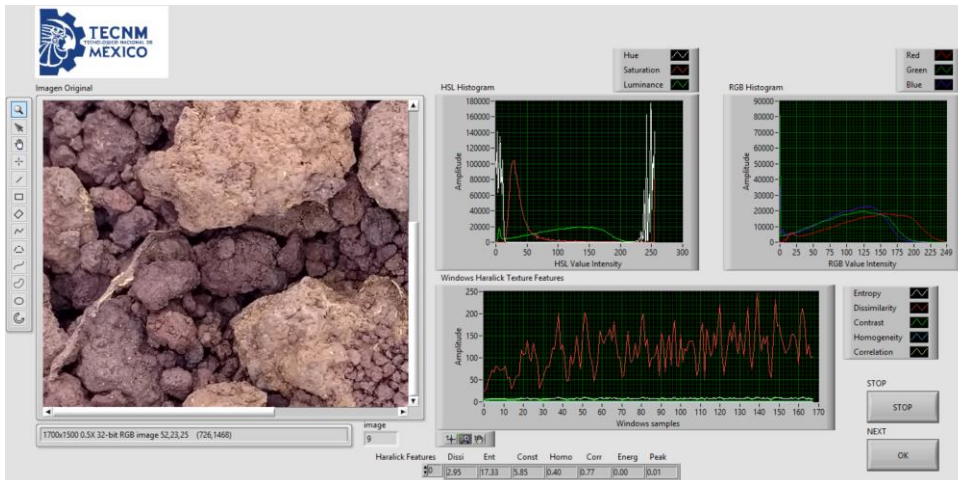


Figura 49. Compósito 2, Profundidad 0-30cm, Muestra general, Humedad 5 %

Elaboración de un sistema inteligente para la estimación de propiedades fisicoquímicas de suelos con producción de caña de azúcar

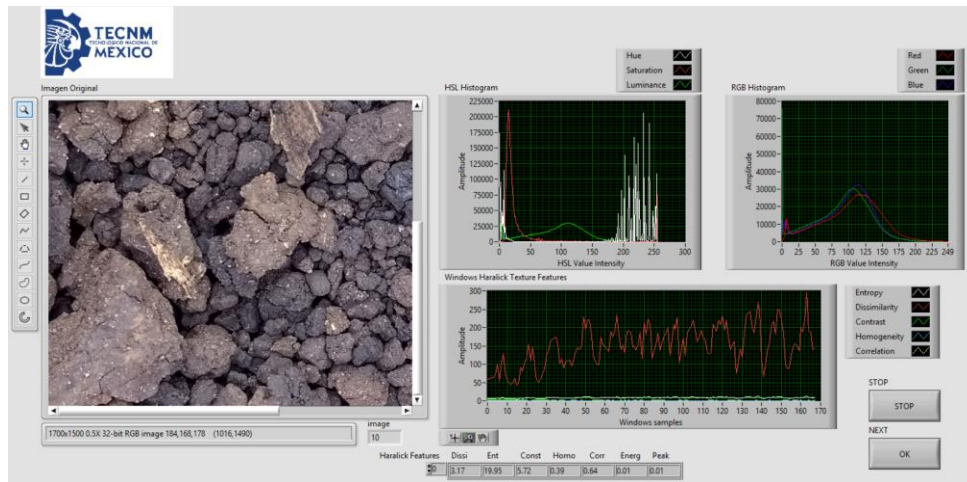


Figura 50. Compósito 3, Profundidad 0-10cm, Submuestra 1, Humedad 5 %

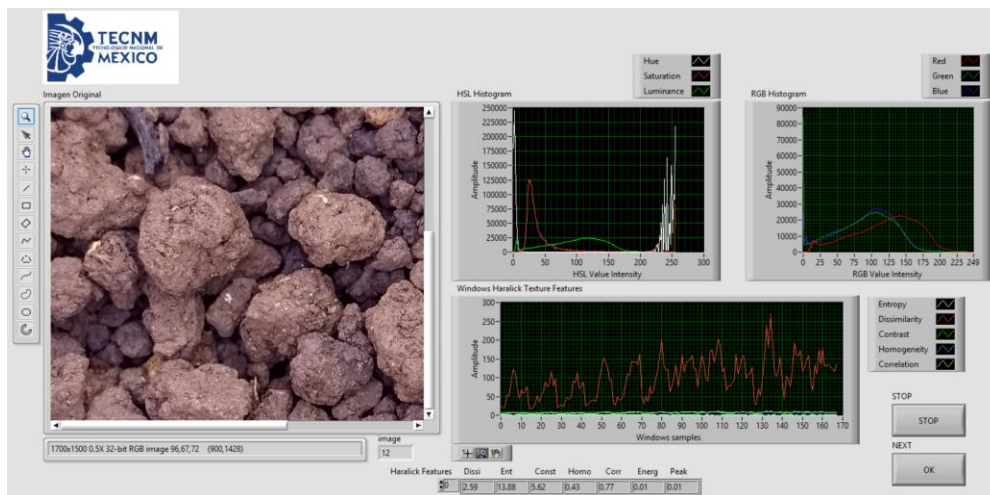


Figura 51. Compósito 3, Profundidad 10-20cm, Submuestra 1, Humedad 5 %

Elaboración de un sistema inteligente para la estimación de propiedades fisicoquímicas de suelos con producción de caña de azúcar

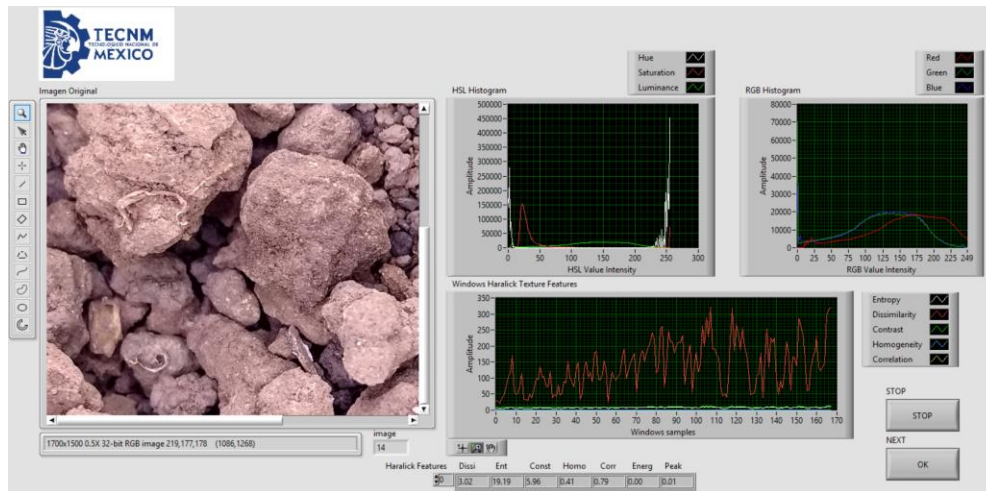


Figura 52. Compósito 4, Profundidad 0-10cm, Submuestra 1, Humedad 5%

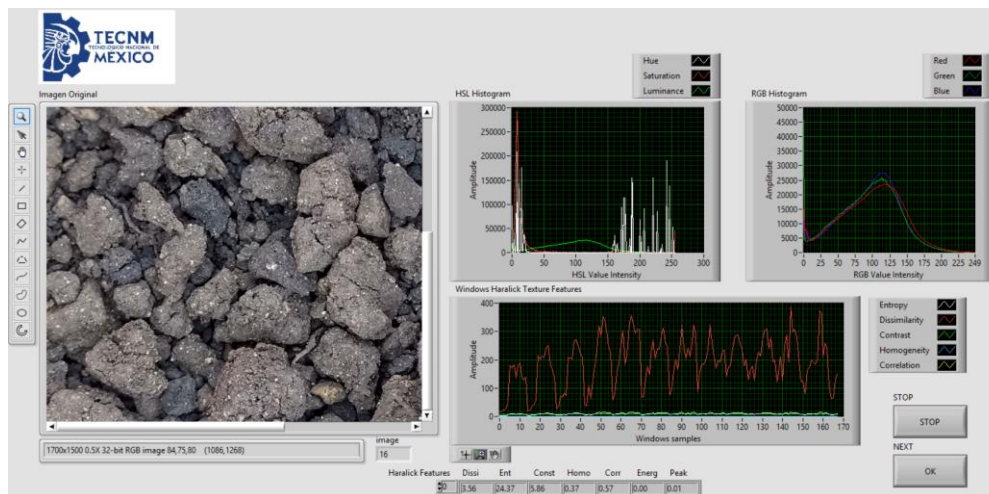


Figura 53. Compósito 3, Profundidad 10-20cm, Submuestra 1, Humedad 5%

Elaboración de un sistema inteligente para la estimación de propiedades fisicoquímicas de suelos con producción de caña de azúcar

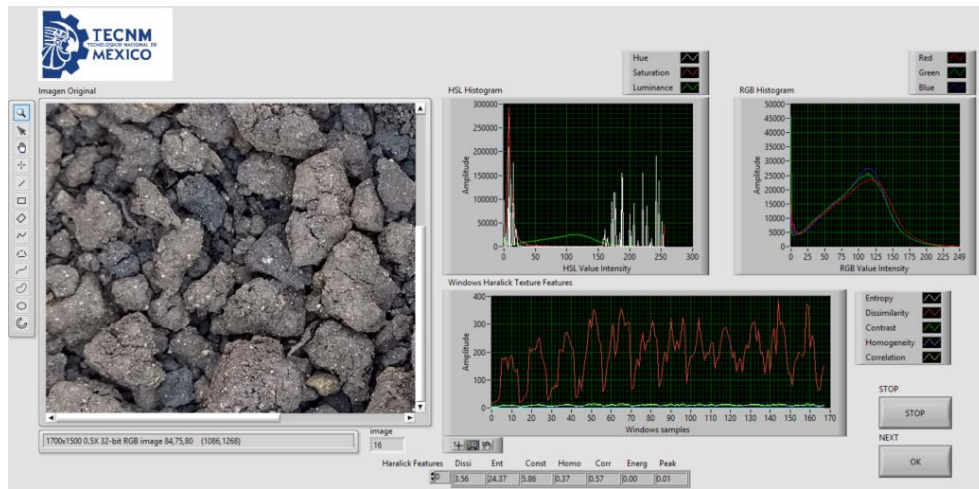


Figura 54. Compósito 3, Profundidad 20-30cm, Submuestra 2, Humedad 5%

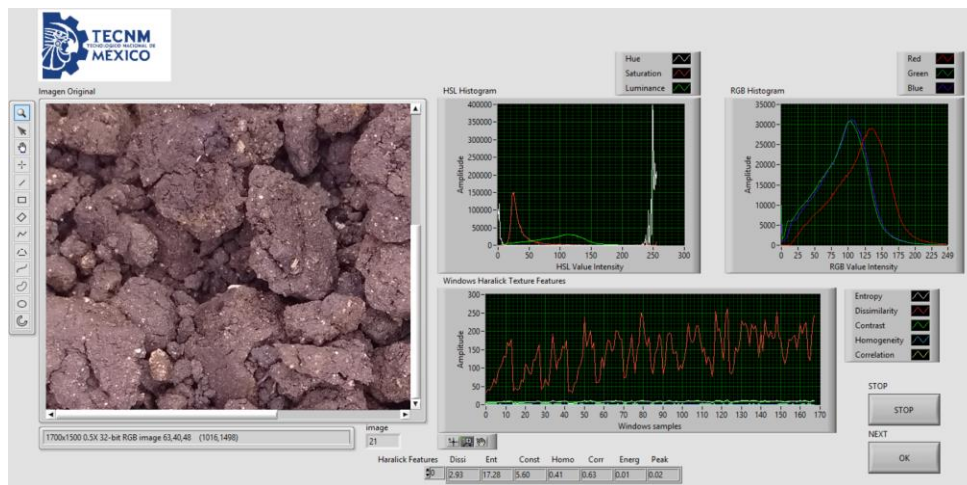
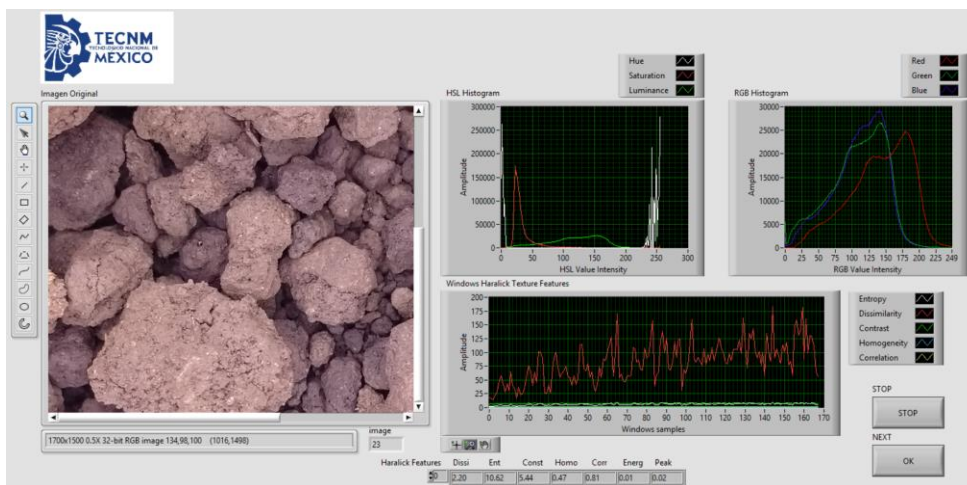


Figura 55. Compósito 4, Profundidad 10-20cm, Submuestra 1, Humedad 5%



Elaboración de un sistema inteligente para la estimación de propiedades fisicoquímicas de suelos con producción de caña de azúcar

Figura 56. Compósito 4, Profundidad 20-30cm, Submuestra 1, Humedad 5%

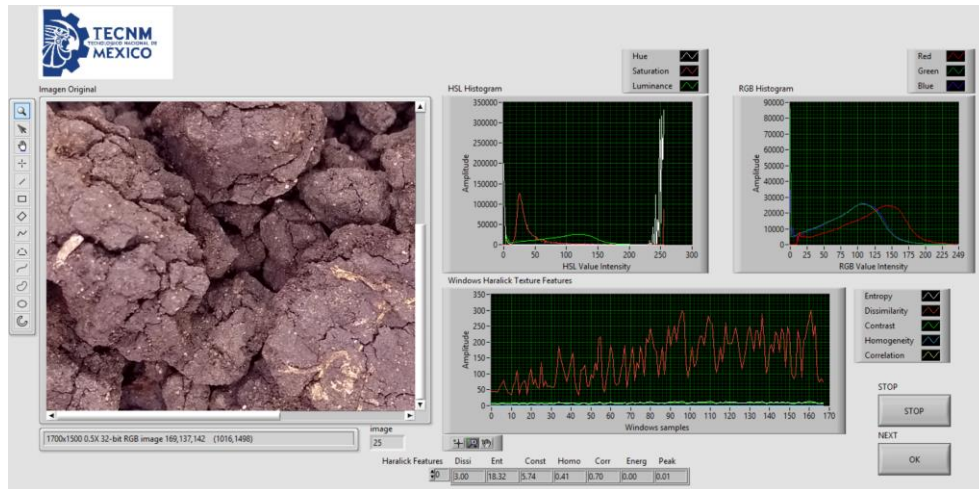


Figura 57. Compósito 4, Profundidad 10-20cm, Submuestra 2, Humedad 5%

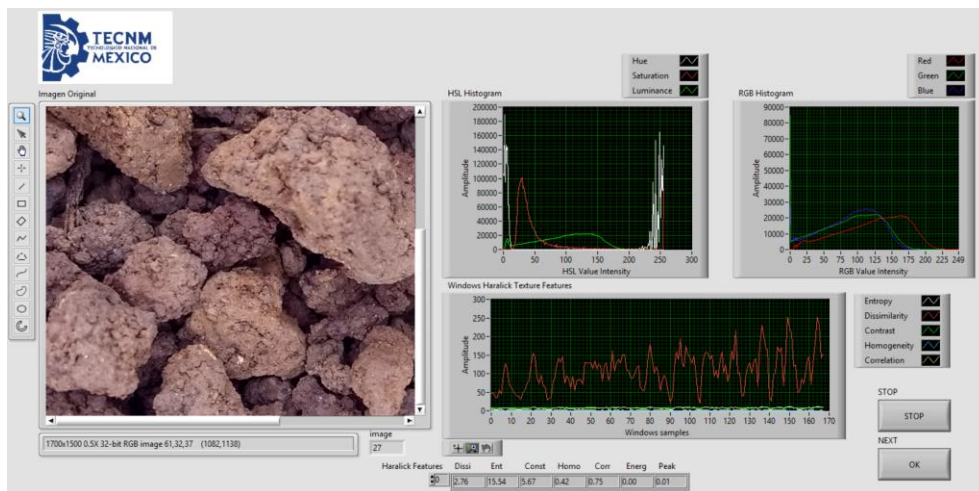


Figura 58. Compósito 5, Profundidad 0-10cm, Submuestra 1, Humedad 5%

Elaboración de un sistema inteligente para la estimación de propiedades fisicoquímicas de suelos con producción de caña de azúcar

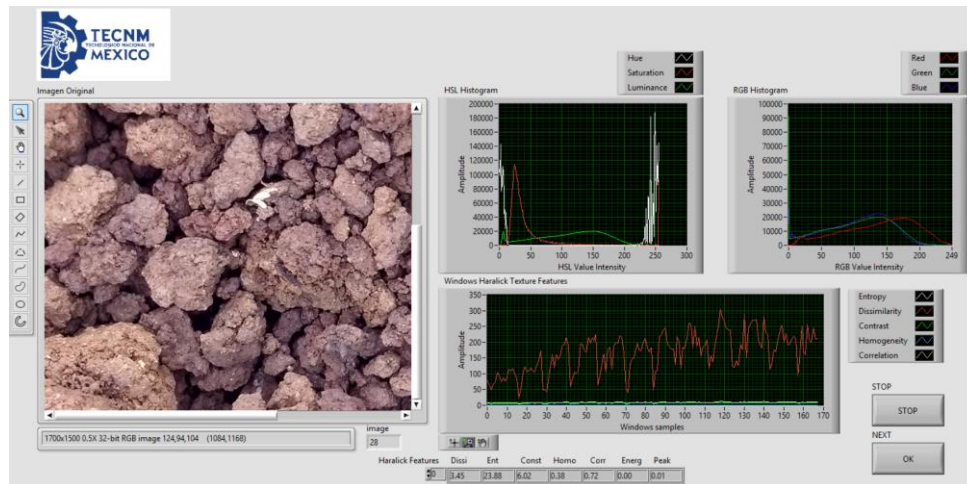


Figura 59. Compósito 5, Profundidad 10-20cm, Submuestra 1, Humedad 5%

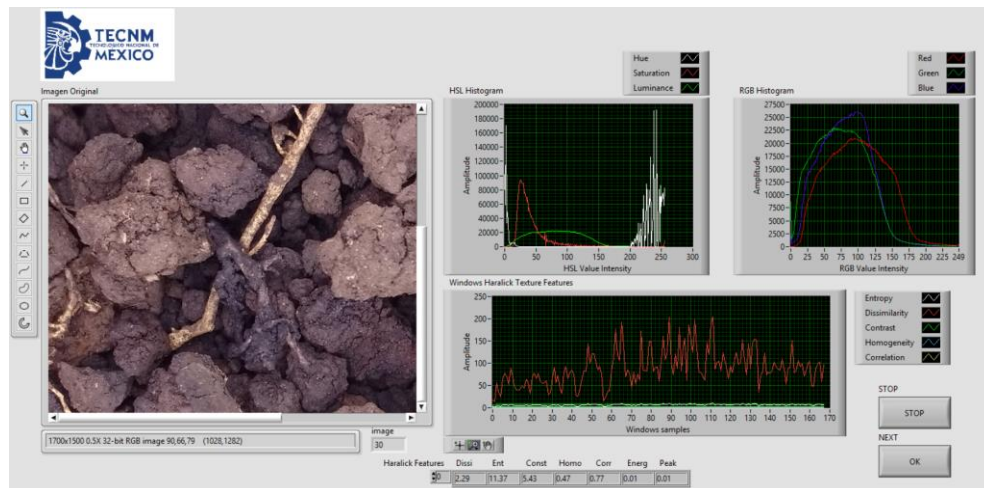


Figura 60. Compósito 5, Profundidad 20-30cm, Submuestra, Humedad 5%

Elaboración de un sistema inteligente para la estimación de propiedades fisicoquímicas de suelos con producción de caña de azúcar

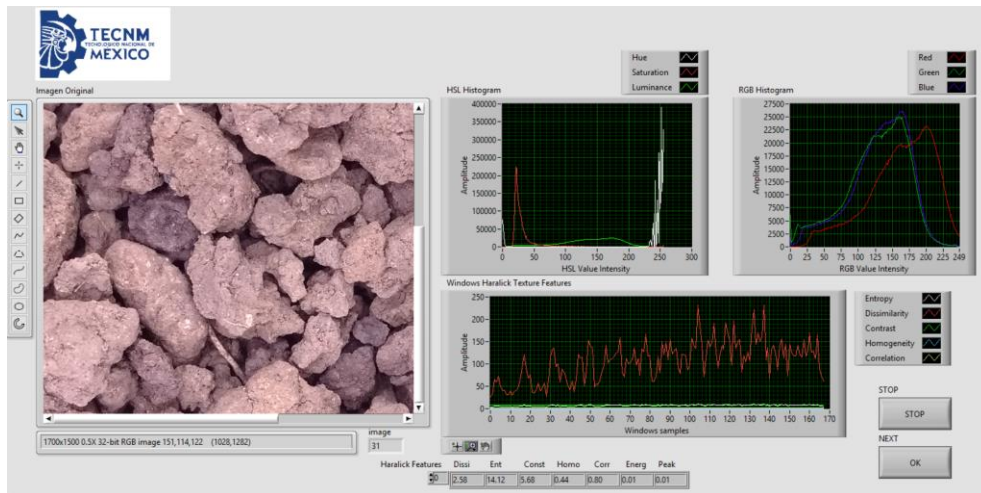


Figura 61. Compósito 6, Profundidad 0-10cm, Submuestra 1, Humedad 5%

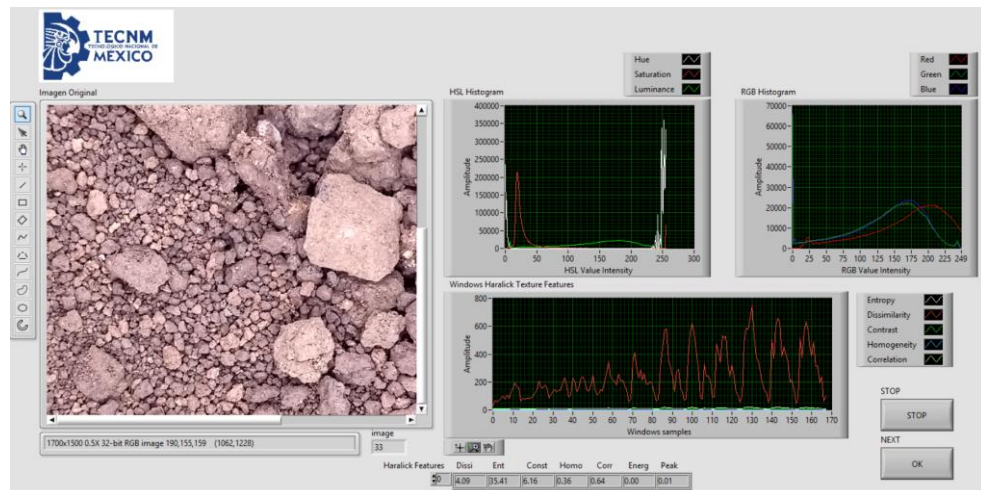


Figura 62. Compósito 6, Profundidad 10-20cm, Submuestra 1, Humedad 5%

Elaboración de un sistema inteligente para la estimación de propiedades fisicoquímicas de suelos con producción de caña de azúcar

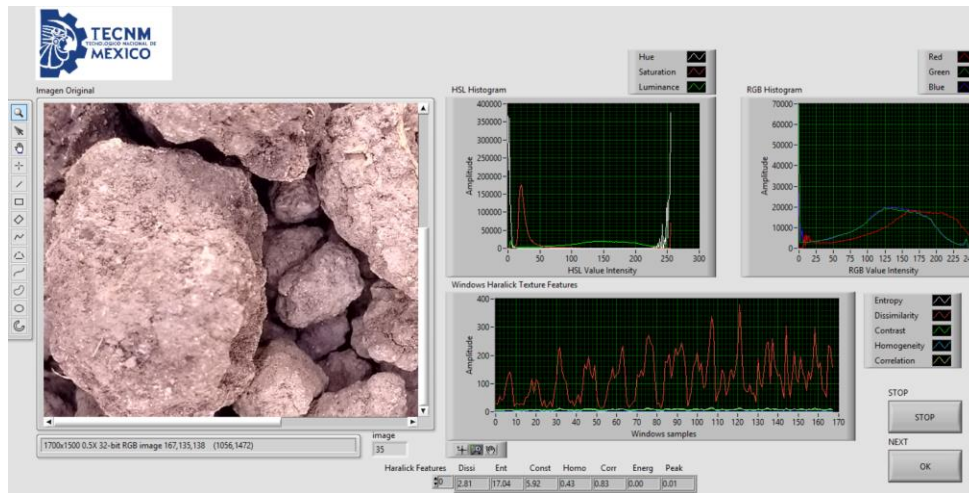


Figura 63. Compósito 7, Profundidad 20-30cm, Submuestra 1, Humedad 5%

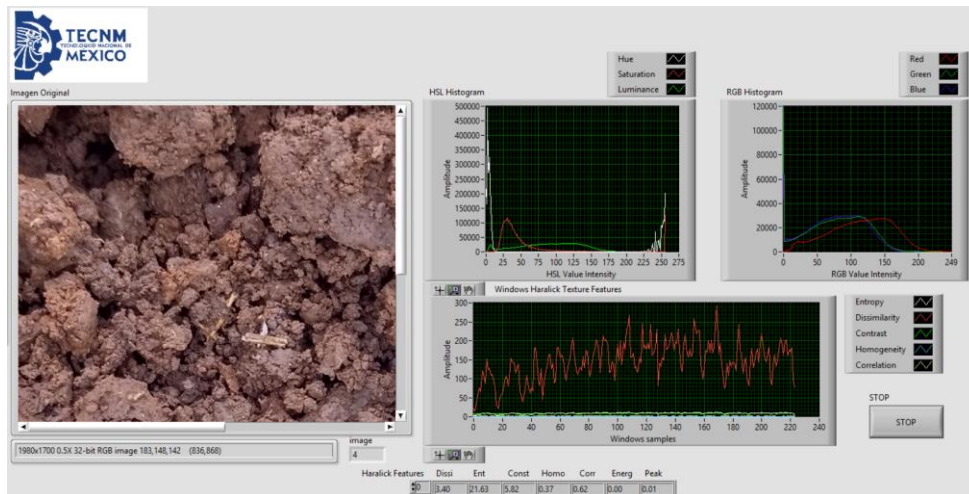


Figura 64. Compósito 1, Profundidad 0-10cm, Submuestra 1, Humedad 80%

Elaboración de un sistema inteligente para la estimación de propiedades fisicoquímicas de suelos con producción de caña de azúcar

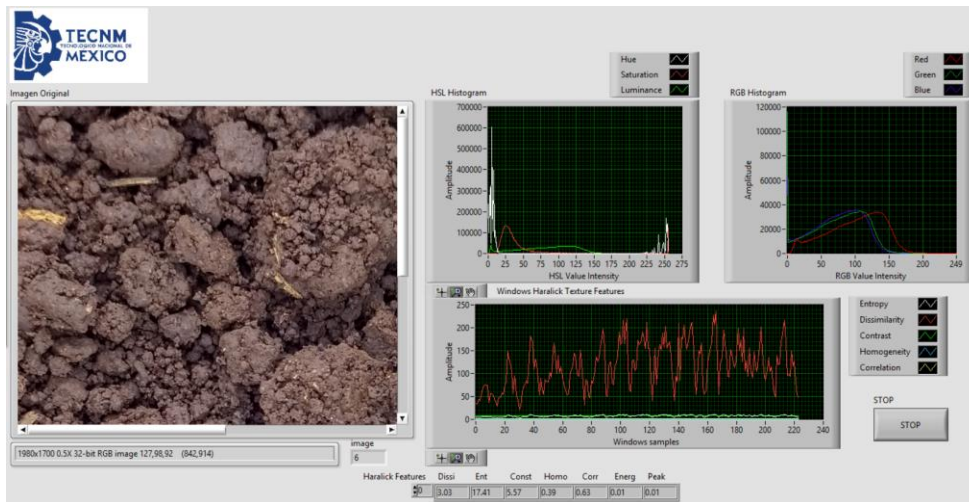


Figura 65. Compósito 2, Profundidad 0-10cm, Submuestra 1, Humedad 80%

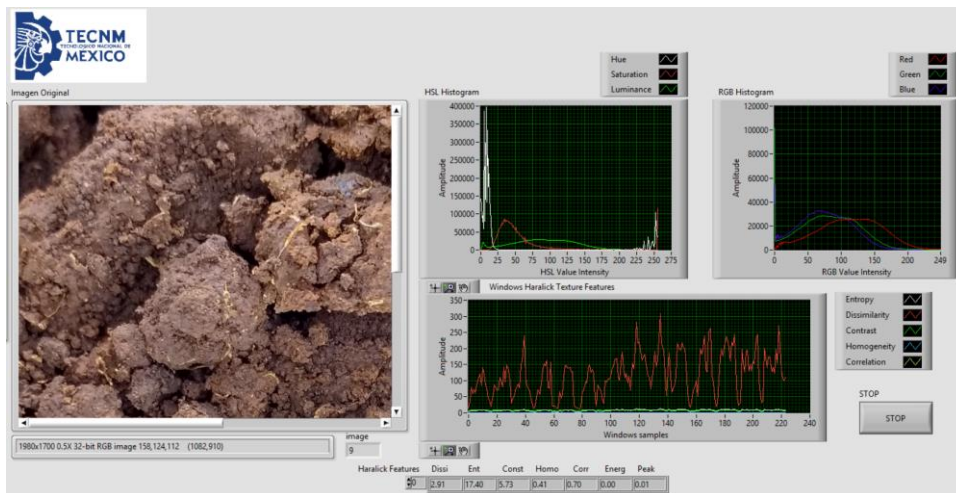


Figura 66. Compósito 3, Profundidad 0-10cm, Submuestra 1, Humedad 80%

Elaboración de un sistema inteligente para la estimación de propiedades fisicoquímicas de suelos con producción de caña de azúcar

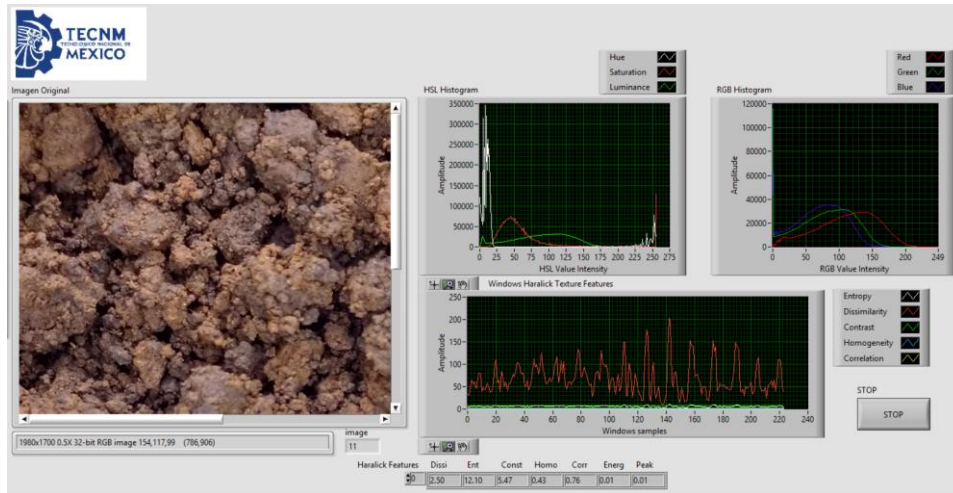


Figura 67. Compósito 4, Profundidad 0-10cm, Submuestra 1, Humedad 80%

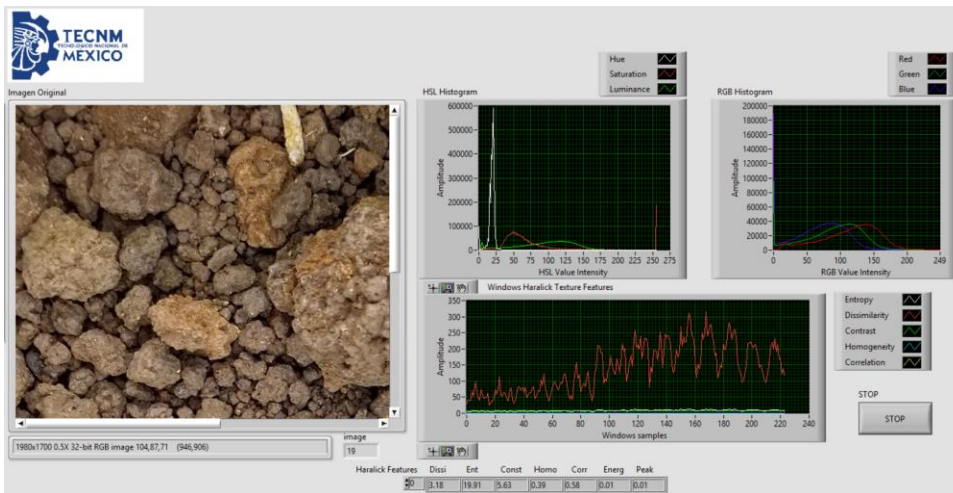


Figura 68. Compósito 5, Profundidad 0-10cm, Submuestra 1, Humedad 80%

5.2 Análisis de Resultados del Sistema de Visión

5.2.1 Análisis de Textura

Las gráficas de la Figura 69 a la Figura 74 muestran los resultados obtenidos del análisis de textura del suelo. Es importante remarcar que estos resultados de textura son completamente diferentes a los análisis de textura convencionales que se realizan en el laboratorio para el análisis del suelo. El objetivo de estos análisis de textura por visión artificial es el realizar un sistema que sea capaz de extraer automáticamente ciertas características matemáticas de la textura y color de la imagen.




Figura 69. Resultados de las características de disimilitud, entropía, contraste, homogeneidad, correlación, energía e intensidad de las 105 imágenes procesadas.




Figura 70. Resultados de las características de disimilitud de las 105 imágenes procesadas.




Figura 71. Resultados de la característica de correlación de las 105 imágenes procesadas




Figura 72. Resultados de la característica de Homogeneidad de las 105 imágenes procesadas




Figura 73. Resultado de la característica de Entropía de las 105 imágenes procesadas




Figura 74. Resultados de la característica de contraste de las 105 imágenes procesadas.

Se realizó un estudio de análisis de varianza de los 7 parámetros de la extracción de características del suelo de Haralick en todas las imágenes del estudio. Esto con el objetivo de conocer la varianza que existe debido a que una mayor varianza en los datos nos indica que tenemos imágenes cuyos datos serán relevantes para la etapa de entrenamiento de las redes neuronales. Una varianza poco significativa en los datos haría muy complicado entrenar la red neuronal. Para realizar este análisis se utilizaron los 7 parámetros de las 105 muestras existentes.

(# de filas) $r =$	7						
(# de columnas) $c =$	107						
$r * c =$	749						
$T = \sum T_{ri} =$	2795						
$T_{cj} =$	303.5	1777.57	594.47	45.03	72.05	0.61	1.97
$\sum x_{ij}^2 =$	36986						
$T_{cj}^2 =$	92112.70	3159779.69	353395.16	2028.10	5191.29	0.3774	3.8955
$\sum T_{cj}^2 =$	3612511						
$\sum T_{cj}^2 / c =$	33761.8						
$\sum T_{ri}^2 =$	7813262.21						
$\sum T_{ri}^2 / r =$	11007.8						
$T^2 / rc =$	10431.6						

Fuente de variación	Suma de cuadrados	Grados de libertad	Cuadrados medios	Relación F	F tablas
SSR (entre suelos)	576.16	106	5.435	1.31	1.2669
SSC (entre características de imagen)	23330.20	6	3888.366	933.86	2.115
SSr (residual)	2648.15	636	4.164		
total	26554.50	748			

Hipótesis:

$H_0: \mu_i = \mu$ No hay diferencia significativa entre medias

$H_1: \mu_i \neq \mu$ Hay diferencia significativa entre medias

Nivel de significancia: 0.95				Nivel de significancia: 0.9			
Ft:	2.114			Ft:	1.266		
Por lo tanto:	2.11	<	933.86	Por lo tanto:	1.27	<	1.31
Se acepta hipótesis alternativa, hay diferencia significativa entre las muestras y sus características de Haralick.				Se acepta hipótesis alternativa, hay diferencia significativa entre muestras de suelo.			

Los resultados de este análisis de varianza determinaron que hay una diferencia significativa en las imágenes de las muestras de suelo usadas.

5.2.2 Análisis de Color de Hue

De la Figura 75 a la Figura 78 se muestra el análisis de color de HUE de las muestras de suelo. Las gráficas muestran los porcentajes de color obtenidos en el histograma acorde al mapa de color de HUE. Los rangos de la tonalidad roja (que es en donde se concentran el color de las muestras de suelo) acorde al mapa de color de Hue se encuentran en valores de 210 a 240 y de 0 a 50. Se puede apreciar en las gráficas que estos son los tonos principales. La Figura 75 muestra el resultado obtenido de 20 imágenes (1-20) correspondientes a 20 diferentes 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.




Figura 75. Análisis de color de HUE muestras de suelo (1-20)

La Figura 76 se muestra el resultado obtenido de 20 imágenes (21-40) correspondientes a 20 diferentes muestras de suelos.




Figura 76. Análisis de color de HUE muestras de suelo (21-40)

La Figura 77 se muestra el resultado obtenido de 20 imágenes (41-40) correspondientes a 20 diferentes muestras de suelos.




Figura 77. Análisis de color de HUE muestras de suelo (41-60)




Figura 78. Análisis de color de HUE muestras de suelo (1-106)

Los datos obtenidos durante el análisis de HUE son de gran importancia debido a que se puede conocer a detalle los diversos rangos de colores que se encuentran concentrados en la imagen. Los rangos de color 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 de colores nos entrega parámetros importantes como podría ser el espacio entre rocas.

5.2.3 Repetibilidad

Debido a que es un factor importante por evaluar, se agruparon 3 submuestras de cada muestra de suelo y se realizó un análisis para poder calcular su repetibilidad. Las Figura 79, Figura 80, y Figura 81 muestran el análisis de repetibilidad para 3 submuestras de suelo. Se puede apreciar que las gráficas para cada submuestra son muy similares. Estadísticamente el error promedio obtenido fue de 6.83% entre submuestras.




Figura 79. Análisis de repetibilidad de suelo submuestras suelo 1




Figura 80. Análisis de repetibilidad de suelo submuestras suelo 1




Figura 81. Análisis de repetibilidad de suelo submuestras suelo 1

5.3 Implementación del Sistema Inteligente

Una parte fundamental en el diseño de los sistemas inteligentes es brindar al algoritmo de reconocimiento con datos de entrada que tengan una variabilidad e importancia. A continuación se describe el vector de entrada con los datos adquiridos por los sensores en este proyecto:

- 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
- Capacitivo: 100 datos pertenecientes a la magnitud en su respuesta en frecuencia
- Capacitivo: 100 datos pertenecientes a su fase en la respuesta en frecuencia.
- Temperatura: 1 dato en °C
- Humedad: 1 en % de humedad

Como variables de salida se seleccionaron los siguientes datos:

- Nitrógeno-nitrato
- Sodio
- Magnesio
- Calcio

- Zinc
- Manganeso
- Hierro
- Cobre
- Boro
- Azufre
- Potasio
- Fósforo
- % Arena
- % Limo
- % Arcilla

Análisis de Componentes Principales: En total son 107 datos de cada una de las 105 muestras de suelo. Estos datos pertenecen a la matriz que deben generar una correlación con los datos de los análisis fisicoquímicos 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 realizar un pre-procesamiento de estos datos para conocer la varianza y correlación de los datos 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 de entrada, en el cual en sus ejes coloca los datos de la mayor varianza a la menor varianza. Un PCA crea un nuevo sistema en el cual ordena los datos más relevantes a los menos relevantes, con esto se puede lograr reducir la dimensionalidad de los datos.

Se realizó la programación utilizando el software Matlab de un PCA utilizando los 11235 datos de la matriz de entrada, que corresponde a 107 dimensiones por 105 muestras. Acorde a los resultados del PCA, estadísticamente hablando viendo su porcentaje de relevancia se seleccionaron las 8 primeras columnas de los componentes principales ya que son los datos con mayor importancia. Con esta reducción dimensional ahora el vector de entrada de entrenamiento utilizado en la red neuronal es de 8 dimensiones.

Entrenamiento de la Red Neuronal Artificial (ANN): Se modeló una red neuronal con los 8 datos de entrada provenientes de la reducción dimensional de datos obtenida por el PCA y se experimentó con diferentes configuraciones relacionadas al número de capas ocultas y número de neuronas en la capa oculta. Esta red neuronal entregará 3 salidas como resultado las cuales son el MO, Fe y el CIC.

La Figura 82 se muestra el comportamiento de una red neuronal utilizando 5 neuronas en la capa oculta de la red neuronal obteniendo un error de reconocimiento del 4.28%. La Figura 83 muestra el comportamiento de la red neuronal utilizando 15 neuronas en la capa oculta con un error del 1.45%. Las gráficas muestran el target (la línea azul) que representa el valor de reconocimiento ideal y los círculos en la gráfica son los valores reales de reconocimiento obtenidos por cada valor del target. Se puede apreciar como la

red neuronal con 15 neuronas en la capa oculta presenta un menor error en el reconocimiento.




Figura 82. ANN usando 5 neuronas en la capa oculta




Figura 83. ANN usando 15 neuronas en la capa oculta

CAPITULO VI. ANALISIS E INTERPETACIÓN DE RESULTADOS CON EL SENSOR DE CONDUCTIVIDAD TÉRMICA

Debido a que el método de HB es práctico, de fácil manejo y la conductividad térmica puede ser utilizada para obtener información acerca del contenido de humedad se utilizó un sensor para determinarlo. En la Figura 84 se muestra el resultado obtenido para la muestra 1, y su respectivo ajuste, gráficos similares se obtuvieron para el resto de las muestras.




Figura 84. Gráfico representativo de la señal del comportamiento de HB y el resultado de ajuste; en esta gráfica, la barra de error representa el error obtenido de las diferentes mediciones tomadas en cada muestra.

Como se observa en la imagen, los cuadros representan los datos experimentales y la línea sólida es el mejor ajuste de la ecuación teórica para estos datos experimentales. La conductividad térmica (k) fue utilizada como parámetro de ajuste. Durante los cálculos, el radio de la bola (R) y el calor liberado (Q) se mantuvieron constante con valores de 3 mm y 5mW, respectivamente. Valores constantes se determinaron por adelantado utilizando las muestras con propiedades térmicas bien caracterizadas. Aunque la difusividad térmica puede

ser extraída de los mismos datos experimentales, el ajuste por incertidumbre es más significativo cuando la ecuación 36 es utilizada; por lo tanto, no se trabajó con la difusividad térmica.

La Figura 85 muestra la conductividad térmica para todos los compósitos medidos, así como la humedad obtenida mediante el método de prueba correspondiente. Las conductividades térmicas obtenidas corresponden a las reportadas por Li et al. (2017) para las muestras de suelo con el mismo rango de humedad. Del coeficiente de correlación de Pearson $r = -0.414$, se concluye que la conductividad térmica fue inversamente proporcional al contenido de humedad.

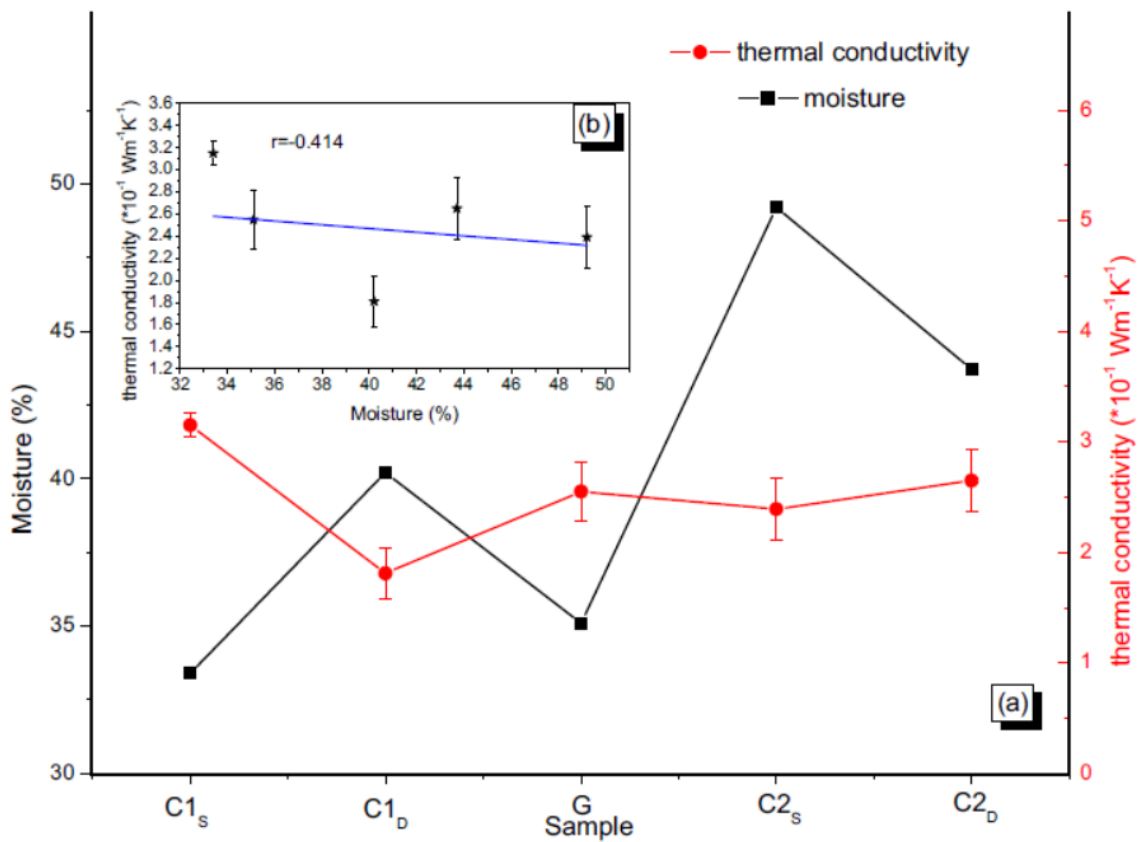


Figura 85. A) Conductividad térmica derivada del método HB y el contenido de humedad obtenido mediante el método estándar para todos los compósitos. B) El gráfico de dispersión de la conductividad térmica contra el contenido de humedad; las barras de error en la gráfica son debidas a las mediciones de la conductividad térmica.

CAPITULO VII. SISTEMA INTELIGENTE PARA LA CARACTERIZACIÓN DE SUELOS.

7.1 Correlación de variables

7.1.1 Introducción

En esta sección se presentan los modelos de Inteligencia Artificial utilizados para el reconocimiento de patrones y correlación de variables empleados en el sensor capacitivo con los datos de la respuesta en frecuencia del suelo. Se experimentó con varias técnicas de data mining para determinar la correlación de datos que existe entre los resultados obtenidos en el laboratorio de las variables fisicoquímicas del suelo (La Figura 86 muestra un esquema de los resultados de una muestra de suelo) y los resultados obtenidos por los sensores capacitivos y de imagen. El objetivo del capítulo es explicar la creación de un sistema inteligente que sea capaz de correlacionar los datos de entrada de nuestros sensores con los datos que los análisis de laboratorio. En otras palabras, lo que se pretende hacer es usar los datos de nuestros sensores y el sistema nos entregará como salida datos similares a los que nos hubiera entregado un análisis tradicional de laboratorio.

Determinaciones	Método	Resultados	CALIFICACION					Capacidad Intercambio
			Muy Bajo	Bajo	Medio	Optimo	Muy Alto	
pH Suelo	pH1:1	5.8						5.7 meq/100g
pH Tampón	SMP	6.82						Saturación Catiónica
Materia orgánica	Comb.	4.2 % FNI 150						%sat meq
Fósforo (P)	M3	1 ppm						K 1.2 0.1
Potasio (K)	M3	27 ppm						Ca 66.8 3.8
Calcio (Ca)	M3	763 ppm						Mg 11.1 0.6
Magnesio (Mg)	M3	76 ppm						H 19.3 1.1
Azufre (S-SO4)	M3	58 ppm						Na 1.1 0.1
Boro (B)	M3	0.1 ppm						K/Mg: 0.17
Cobre (Cu)	M3	0.4 ppm						Ca/Mg: 6.03
Hierro (Fe)	M3	61 ppm						%Arena %Limo %Arcilla
Manganeso (Mn)	M3	214 ppm						46 15 39
Zinc (Zn)	M3	0.5 ppm						Clasificación de la Textura
Sodio (Na)	M3	14 ppm						Arcillo arenoso
Conductividad	SS1.2	0.04 dS/m						Análisis de Densidad
Nitrógeno-Nitrato	NNO3	8 ppm						Aparente = 1.37 g/cm3

Figura 86. Esquemización de los resultados de análisis fisicoquímicos

Es importante remarcar que los métodos de aprendizaje en inteligencia artificial son divididos principalmente en:

- Aprendizaje Supervisado
- Aprendizaje No supervisado
- Aprendizaje Semi-supervisado

- Aprendizaje por Reforzamiento

Acorde a esto, los algoritmos son clasificados en:

- Clasificación
- Clustering
- Regresión
- Reducción de dimensionalidad

Específicamente para este proyecto fue requerido utilizar aprendizaje Supervisado, ya que las propiedades fisicoquímicas de los suelos que se desean estimar han sido previamente obtenidas a partir de análisis de laboratorio, por lo cual se conoce de antemano los resultados de estas variables del suelo.

Al abordar el tema de aprendizaje supervisado y basados en las características de los algoritmos y el tipo de datos con lo que se cuenta se optó por utilizar los siguientes algoritmos de clasificación:

1. Logistic Regression
2. Linear SVM
3. Gradient Boosting Classifier
4. Decision Tree
5. Random Forest
6. Naive Bayes
7. Nearest Neighbors
8. Artificial Neuronal Networks

Todos estos algoritmos son algoritmos utilizados en clasificación. En cada uno de los algoritmos mencionados se obtuvieron los datos de los resultados de entrenamiento, el resultado con los datos de prueba, y el tiempo de entrenamiento.

7.1.2 Software Utilizado

Para realizar estos análisis se utilizó la librería scikit-learn en Python. También se utilizaron las librerías del módulo Pandas que ofrece funcionalidades para cargar, inspeccionar y procesar datos. La Librería SeaBorn que está basada en Matplotlib y tiene funcionalidades avanzadas en gráficos.

7.1.3 Análisis de los datos

Antes de comenzar con la aplicación de las técnicas de inteligencia artificial es requerido realizar una identificación de qué clase de datos contiene nuestra base de datos,

- Si la base de datos contiene datos faltantes
- Si la base de datos tiene datos redundantes

- Estandarizar o normalizar la base de datos

Se revisó que estos tres requerimientos estuvieran correctos. A partir de esto se logró generar una base de datos libre de errores que pudieran afectar el proceso de clasificación. La

Tabla 10 muestra una fracción de la tabla de datos utilizada, se muestran los datos de pH, Fósforo, Potasio, Calcio, Magnesio, Sodio, Conductividad y Nitrógeno-Nitrato.

	pH suelo	Fósforo	Potasio	Calcio	Magnesio	Sodio	Conductividad	Nitrógeno-Nitrato
0	5.2	12	64	713	102	23	0.06	7
1	5.0	6	54	712	89	15	0.07	6
2	5.4	5	59	622	84	12	0.09	10
3	5.4	2	86	963	185	12	0.16	12
4	4.5	39	64	344	49	5	0.10	4

Tabla 10. Base de datos de las Propiedades fisicoquímicas de suelos obtenidos en Laboratorio de 8 elementos

La descripción de los datos es sumamente útil para poder saber de una forma rápida ciertas características estadísticas de la base de datos utilizados. Por este motivo se realizó este análisis con los datos obtenidos en el laboratorio. La Tabla 11 muestra el resultado de la descripción de la base de datos. Donde se muestra la media, desviación estándar, mínimo y percentiles.

	pH suelo	Fósforo	Potasio	Calcio	Magnesio	Sodio	Conductividad	Nitrógeno-Nitrato
count	90.00000	90.00000	90.00000	90.00000	90.00000	90.00000	90.00000	90.00000
mean	5.088889	22.000000	88.666667	926.111111	121.666667	12.222222	0.104444	11.000000
std	0.475511	24.919872	45.431267	1038.430600	113.877127	5.118051	0.038442	10.062306
min	4.500000	2.000000	54.000000	301.000000	39.000000	5.000000	0.060000	4.000000
25%	4.900000	5.000000	64.000000	388.000000	71.000000	9.000000	0.080000	6.000000
50%	5.000000	12.000000	67.000000	655.000000	84.000000	12.000000	0.090000	7.000000
75%	5.400000	39.000000	86.000000	713.000000	102.000000	15.000000	0.120000	10.000000
max	6.000000	75.000000	192.000000	3637.000000	404.000000	23.000000	0.170000	37.000000

Tabla 11. Descripción de base de datos

La Tabla 12 muestra una fracción de la tabla de datos utilizada, se muestran los datos obtenidos por laboratorio de los suelos de caña de azúcar extraídos en diversos puntos de la zona. Dichos elementos son el pH, Fósforo, pH Tampón, Materia Orgánica, Potasio, Calcio, Magnesio, Sodio, Conductividad y Nitrógeno-

Nitrato, Azufre, Boro, Cobre, Hierro, Manganeso, Zinc, Hidrogeno, Nitrógeno, Sodio, Arena, Limo, Arcilla, Densidad aparente, Capacidad de campo, punto de marchitez permanente.

	pH suelo	pH Tampón	Materia orgánica	Fósforo	Potasio	Calcio	Magnesio	Azufre (S-SO4)	Boro	Cobre	...	SC Hidrógeno	SC Sodio	K/Mg	Ca/Mg	Arena	Limo	Arcilla
0	5.2	6.68	4.3	12.0	64	713	102	33	0.2	1.8	...	34.7	1.4	0.22	4.19	17	41	42
1	5.0	6.62	4.3	6.0	54	712	89	43	0.1	1.4	...	40.8	0.9	0.14	4.78	13	45	42
2	5.8	6.82	4.2	1.0	27	763	76	58	0.1	0.4	...	19.3	1.1	0.17	6.03	46	15	39
3	5.4	6.77	4.5	5.0	59	622	84	52	0.1	1.2	...	28.6	0.9	0.29	4.44	49	13	38
4	5.5	6.53	5.3	9.0	241	1663	280	15	0.4	2.9	...	26.1	0.3	0.26	3.55	43	21	36

Tabla 12. Base de datos de las Propiedades fisicoquímicas de suelos obtenidos en Laboratorio de 32 elementos

La Tabla 13 muestra la descripción de la Tabla 12. Donde se muestran elementos estadísticos como la media, desviación estándar, valor mínimo, valor máximo y los percentiles.

	pH suelo	pH Tampón	Materia orgánica	Fósforo	Potasio	Calcio	Magnesio	Azufre (S-SO4)	Boro	Cobre	...	SC Hidrógeno
count	73.000000	49.000000	73.000000	73.000000	73.000000	73.000000	73.000000	73.000000	73.000000	73.000000	...	73.000000
mean	5.924658	6.655714	4.676712	24.504110	103.917808	1904.205479	351.465753	24.424658	0.298630	1.723288	...	20.489041
std	0.801003	0.127835	1.301444	37.271766	82.964811	1478.641982	298.548437	23.835034	0.198251	1.084809	...	17.361384
min	4.400000	6.100000	1.500000	1.000000	18.000000	258.000000	39.000000	2.000000	0.100000	0.400000	...	0.000000
25%	5.200000	6.600000	3.600000	4.000000	48.000000	783.000000	90.000000	10.000000	0.200000	0.800000	...	7.600000
50%	6.000000	6.670000	4.600000	11.800000	72.000000	1663.000000	258.000000	14.000000	0.200000	1.400000	...	14.900000
75%	6.500000	6.740000	5.300000	34.000000	133.000000	2712.000000	556.000000	31.000000	0.400000	2.300000	...	34.100000
max	7.700000	6.850000	7.500000	242.000000	462.000000	8922.000000	1257.000000	97.000000	1.000000	4.800000	...	62.200000

Tabla 13. Descripción de base de datos de las Propiedades fisicoquímicas de suelos obtenidos en Laboratorio de 32 elementos

La Tabla 14 muestra la base de datos del estudio de espectroscopia realizados con el sensor capacitivos con lo cual se obtuvieron los datos de magnitud y fase que corresponden a la respuesta en frecuencia del suelo. La información se encuentra dividida en 10 grupos, que corresponden a 10 puntos del análisis frecuencial de 0-50KHz. Estos puntos son la Magnitud de 0-10 Hz, Magnitud de 10-100Hz, Magnitud de 1k-10kHz, Magnitud de 10k-50KHz, Fase de 0-10Hz, Fase de 100-1Khz, Fase de 1k-10KHz, fase de 10Khz-50KHz.

Magnitud0-10	Magnitud10-100	Magnitud100-1k	Magnitud1k-10k	Magnitud10k-50k	FAse0-10	FAse10-100	FAse100-1k	FAse1k-10k	FAse10k-50k	pH suelo	Fósforo	Potasio	Calcio
0.149	0.116	0.0962	0.093	0.0997	-4.31000	-10.99200	-5.6328	-10.9992	-7.9374	5.2	12	64	713
0.184	0.141	0.1200	0.119	0.1270	-2.91000	-11.69580	-5.0148	-11.6958	-7.5654	5.0	6	54	712
0.213	0.157	0.1240	0.119	0.1300	-2.16000	-13.18526	-8.3352	-13.1860	-9.2220	5.4	5	59	622
0.225	0.199	0.1740	0.163	0.1800	-0.27300	-15.58020	-3.0456	-15.5802	-9.6012	5.4	2	86	963
0.164	0.134	0.1190	0.115	0.1230	-2.36124	-11.85360	-3.5358	-11.8536	-7.3782	4.5	39	64	344

Tabla 14. Base de datos del estudio de espectroscopia en Magnitud y fase de los suelos

La Tabla 15 muestra la descripción de la Tabla 14. Donde se muestran elementos estadísticos como la media, desviación estándar, valor mínimo, valor máximo y los percentiles.

	Magnitud0-10	Magnitud10-100	Magnitud100-1k	Magnitud1k-10k	Magnitud10k-50k	FAse0-10	FAse10-100	FAse100-1k	FAse1k-10k	FAse10k-50k	pH suelo	Fósforo
count	126.000000	126.000000	126.000000	126.000000	126.000000	126.000000	126.000000	126.000000	126.000000	126.000000	126.000000	126.000000
mean	0.167889	0.133844	0.109456	0.149200	0.113711	-3.912516	-11.654207	-5.596533	-11.656644	-8.049400	5.088889	22.000000
std	0.033761	0.038480	0.034462	0.105242	0.035672	3.405163	1.831184	2.139044	1.829897	0.984785	0.450106	23.5884
min	0.110000	0.060000	0.045700	0.074800	0.048300	-12.616200	-15.580200	-9.229800	-15.580200	-9.601200	4.500000	2.000000
25%	0.149000	0.116000	0.096200	0.093000	0.099700	-4.312800	-11.922600	-7.005000	-11.922600	-9.119400	4.900000	5.000000
50%	0.164000	0.141000	0.119000	0.119000	0.123000	-2.910000	-11.695800	-5.632800	-11.695800	-7.937400	5.000000	12.000000
75%	0.184000	0.157000	0.124000	0.128000	0.130000	-2.160000	-10.992000	-3.535800	-10.999200	-7.378200	5.400000	39.000000
max	0.225000	0.199000	0.174000	0.438000	0.180000	-0.273000	-8.876400	-2.937000	-8.876400	-6.613200	6.000000	75.000000

Tabla 15. Descripción de la Base de datos del estudio de espectroscopia en Magnitud y fase de los suelos

A través del uso de la descripción y análisis de la base de datos se puede apreciar diversas características de los suelos analizados. Es fácilmente apreciable que existe una variación significativa entre los datos de las diferentes muestras de suelo. Que es un factor importante para poder obtener clasificadores en Inteligencia Artificial que logren el cometido de realizar una correlación entre los datos de las variables y generar una clasificación de los datos.

7.1.4 Correlación de datos

La correlación de los datos es una técnica de análisis de información con base estadística en la cual se logra analizar la relación entre las variables de una base de datos. Por lo cual en esta sección se aborda el estudio de la correlación de datos para conocer la correlación que existe entre las variables fisicoquímicas de los suelos. La Figura 87 muestra una matriz de correlación de las variables pH Suelo, fósforo, Potasio, Calcio, Magnesio, Sodio, Conductividad y Nitrógeno-Nitrato.




Figura 87. Matriz de correlación entre los elementos pH, Fósforo, Potasio, Calcio, Magnesio, Sodio, Conductividad, Nitrógeno-Nitrato.

Para poder tener una mejor apreciación de los niveles de correlación de cada elemento, se realizaron por separado algunas gráficas en las que se establece los niveles de correlación que existen en todos los elementos con respecto a uno en particular.

En la Figura 88 se visualiza la correlación que existe entre el fósforo y las otras variables como el pH, Fósforo, Sodio, Conductividad, Nitrógeno, Calcio, Magnesio. Se puede observar que el Nitrógeno, Calcio, Magnesio tienen una estrecha correlación con el Potasio.

En la Figura 89 se visualiza la correlación que existe entre el Calcio y todas las demás variables. Se puede observar que el Nitrógeno, Calcio, Magnesio tienen una estrecha correlación con el Calcio.




Figura 88. Correlación Potasio con pH, Fósforo, Sodio, Conductividad, Nitrógeno, Calcio, Magnesio




Figura 89. Correlación Calcio con Potasio, pH, Fósforo, Sodio, Conductividad, Nitrógeno, Calcio, Magnesio.

En la Figura 90 se visualiza la correlación que existe entre el Magnesio y todas las demás variables. Se puede observar que el Calcio, Nitrógeno y pH tienen una estrecha correlación con el Magnesio.




Figura 90. Correlación Magnesio con pH, Fósforo, Sodio, Conductividad, Nitrógeno, Calcio, fosforo, Potasio




Figura 91. Correlación Fósforo con pH, Potasio, Magnesio, Sodio, Conductividad, Nitrógeno, Calcio, fosforo.

En la Figura 91 se visualiza la correlación que existe entre el Fósforo y todas las demás variables. Se puede observar que el Sodio y Potasio tienen una estrecha correlación con el Fósforo.





Figura 92. Correlación Fósforo con pH, Potasio, Magnesio, Sodio, Nitrógeno, Calcio, fosforo.

Figura 93. Correlación Nitrógeno-Nitrato con pH, Potasio, Magnesio, Sodio, Conductividad, Calcio, fosforo.

En la Figura 92 se visualiza la correlación que existe entre la Conductividad y todas las demás variables. Se puede observar que el Potasio, Magnesio, Nitrógeno y Calcio tienen una estrecha correlación con la Conductividad.

En la Figura 93 se visualiza la correlación que existe entre el Nitrógeno-Nitrato y el pH, Potasio, Sodio, Fósforo, Conductividad, Nitrógeno, Calcio, Fósforo. Se puede observar que el Calcio, Potasio, Magnesio, tienen una estrecha correlación con el Nitrógeno-Nitrato.

7.2 Correlación Variables Espectroscopía y variables Fisicoquímicas de Laboratorio

Una vez analizada y comprendida la correlación que existe entre diversas variables fisicoquímicas del suelo. Ahora se analiza la correlación que existe entre las variables (Magnitud y Fase) del estudio de espectroscopia realizado en el sensor capacitivo del suelo con respecto a las variables como Calcio, Magnesio, Sodio, pH, fósforo, Potasio, Sodio, Conductividad y Nitrógeno-Nitrato. Es importante remarcar que es de gran relevancia conocer la correlación que existe entre los diversos puntos de la respuesta en frecuencia en magnitud y fase de los suelos estudiados respecto a sus variables fisicoquímicas. En la Figura 94 se muestra la matriz de correlación entre las características de magnitud y fase del estudio espectroscopia y las variables fisicoquímicas de los suelos obtenidas en laboratorio.




Figura 94. Matriz de correlación entre los elementos pH, Fósforo, Potasio, Calcio, Magnesio, Sodio, Conductividad, Nitrógeno-Nitrato.

7.2.1 pH Magnitud y Fase

En las Figura 95 y 96 se muestra a detalle la correlación que existe entre el pH y las variables de Magnitud de 0-10 Hz, Magnitud de 10-100Hz, Magnitud de 1k-10kHz, Magnitud de 10k-50KHz, Fase de 0-10Hz, Fase de 100-1Khz, Fase de 1k-10KHz, fase de 10Khz-50HKhz. Se puede apreciar que la Magnitud de 1k-10kHz y la fase de 10Khz-50HKhz tienen una estrecha correlación con el pH del suelo.




Figura 95. Correlación del pH con Magnitud de 0-10 Hz, Magnitud de 10-100Hz, Magnitud de 1k-10kHz, Magnitud de 10k-50KHz, Fase de 0-10Hz, Fase de 100-1Khz, Fase de 1k-10KHz, fase de 10Khz-50HKhz.




Figura 96. Matriz de Correlación del pH con Magnitud de 0-10 Hz, Magnitud de 10-100Hz, Magnitud de 1k-10kHz, Magnitud de 10k-50KHz, Fase de 0-10Hz, Fase de 100-1Khz, Fase de 1k-10KHz, fase de 10Khz-50HKhz.

7.2.2 Fósforo Magnitud y Fase

En las figuras 97 se muestra a detalle la correlación que existe entre el Fósforo y las variables de Magnitud de 0-10 Hz, Magnitud de 10-100Hz, Magnitud de 1k-10kHz, Magnitud de 10k-50KHz, Fase de 0-10Hz, Fase de 100-1Khz, Fase de 1k-10KHz, fase de 10Khz-50HKhz. Se puede apreciar que la Magnitud de 0-10 Hz, la fase de 10Khz-50HKhz, Magnitud de 10-100Hz y la Magnitud de 1k-10kHz tienen una estrecha correlación con el Fósforo del suelo.




Figura 97. Correlación del Fósforo con Magnitud de 0-10 Hz, Magnitud de 10-100Hz, Magnitud de 1k-10kHz, Magnitud de 10k-50KHz, Fase de 0-10Hz, Fase de 100-1Khz, Fase de 1k-10KHz, fase de 10Khz-50HKhz.

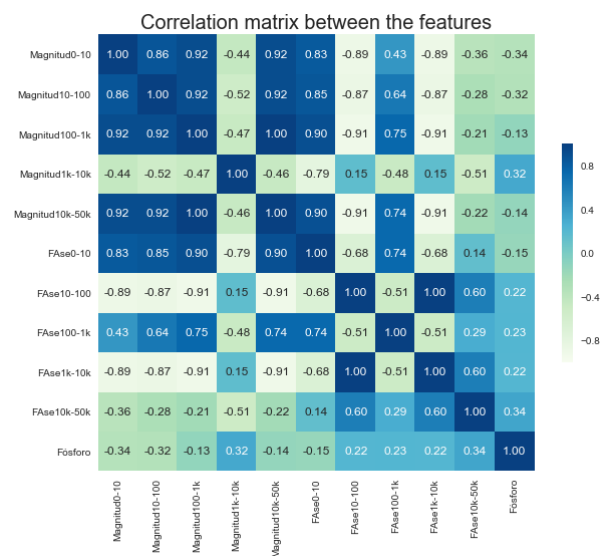


Figura 98. Matriz de Correlación del Fósforo con Magnitud de 0-10 Hz, Magnitud de 10-100Hz, Magnitud de 1k-10kHz, Magnitud de 10k-50KHz, Fase de 0-10Hz, Fase de 100-1Khz, Fase de 1k-10KHz, fase de 10Khz-50HKhz

7.2.3 Potasio Magnitud y Fase

En las figuras 99 se muestra a detalle la correlación que existe entre el Potasio y las variables de Magnitud de 0-10 Hz, Magnitud de 10-100Hz, Magnitud de 1k-10kHz, Magnitud de 10k-50KHz, Fase de 0-10Hz, Fase de 100-1Khz, Fase de 1k-10KHz, fase de 10Khz-50HKhz. Se puede apreciar que la Fase 0-10Hz, la Magnitud de 1k-10Khz, y la magnitud de 10-100Hz tienen una estrecha correlación con el Potasio del suelo.




Figura 99. Correlación del Potasio con Magnitud de 0-10 Hz, Magnitud de 10-100Hz, Magnitud de 1k-10kHz, Magnitud de 10k-50KHz, Fase de 0-10Hz, Fase de 100-1Khz, Fase de 1k-10KHz, fase de 10Khz-50HKhz.




Figura 100. Matriz de Correlación del Potasio con Magnitud de 0-10 Hz, Magnitud de 10-100Hz, Magnitud de 1k-10kHz, Magnitud de 10k-50KHz, Fase de 0-10Hz, Fase de 100-1Khz, Fase de 1k-10KHz, fase de 10Khz-50HKhz.

7.2.4 Calcio Magnitud y Fase

En las figuras 101 y 102 se muestra a detalle la correlación que existe entre el Calcio y las variables de Magnitud de 0-10 Hz, Magnitud de 10-100Hz, Magnitud de 1k-10kHz, Magnitud de 10k-50KHz, Fase de 0-10Hz, Fase de 100-1Khz, Fase de 1k-10KHz, fase de 10Khz-50HKhz. Se puede apreciar que la Magnitud de 1k-10Khz y la Fase 0-10Hz tienen una estrecha correlación con el Calcio del suelo.




Figura 101. Correlación del Calcio con Magnitud de 0-10 Hz, Magnitud de 10-100Hz, Magnitud de 1k-10kHz, Magnitud de 10k-50KHz, Fase de 0-10Hz, Fase de 100-1Khz, Fase de 1k-10KHz, fase de 10Khz-50HKhz.




Figura 102. Correlación del Calcio con Magnitud de 0-10 Hz, Magnitud de 10-100Hz, Magnitud de 1k-10kHz, Magnitud de 10k-50KHz, Fase de 0-10Hz, Fase de 100-1Khz, Fase de 1k-10KHz, fase de 10Khz-50HKhz.

7.2.5 Magnesio Magnitud y Fase

En las Figuras 103 y 104 se muestra a detalle la correlación que existe entre el Magnesio y las variables de Magnitud de 0-10 Hz, Magnitud de 10-100Hz, Magnitud de 1k-10kHz, Magnitud de 10k-50KHz, Fase de 0-10Hz, Fase de 100-1Khz, Fase de 1k-10KHz, fase de 10Khz-50HKhz. Se puede apreciar que la Magnitud de 1k-10Khz y la Fase 0-10Hz y la fase de 10K-50Khz tienen una estrecha correlación con el Magnesio del suelo.




Figura 103. Correlación del Magnesio con Magnitud de 0-10 Hz, Magnitud de 10-100Hz, Magnitud de 1k-10kHz, Magnitud de 10k-50KHz, Fase de 0-10Hz, Fase de 100-1Khz, Fase de 1k-10KHz, fase de 10Khz-50HKhz.




Figura 104. Matriz de Correlación del Magnesio con Magnitud de 0-10 Hz, Magnitud de 10-100Hz, Magnitud de 1k-10kHz, Magnitud de 10k-50KHz, Fase de 0-10Hz, Fase de 100-1Khz, Fase de 1k-10KHz, fase de 10Khz-50HKhz.

7.2.6 Sodio Magnitud y Fase

En las Figura 105 y 106 se muestra a detalle la correlación que existe entre el Sodio y las variables de Magnitud de 0-10 Hz, Magnitud de 10-100Hz, Magnitud de 1k-10kHz, Magnitud de 10k-50KHz, Fase de 0-10Hz, Fase de 100-1Khz, Fase de 1k-10KHz, fase de 10Khz-50HKhz. Se puede apreciar que la fase de 100-1KHz, la fase de 0-10Hz, la fase de 10K-50Khz y la Magnitud de 10-100Hz tienen una estrecha correlación con el Sodio del suelo.




Figura 105. Correlación del Sodio con Magnitud de 0-10 Hz, Magnitud de 10-100Hz, Magnitud de 1k-10kHz, Magnitud de 10k-50KHz, Fase de 0-10Hz, Fase de 100-1Khz, Fase de 1k-10KHz, fase de 10Khz-50HKhz.




Figura 106. Matriz de Correlación del Sodio con Magnitud de 0-10 Hz, Magnitud de 10-100Hz, Magnitud de 1k-10kHz, Magnitud de 10k-50KHz, Fase de 0-10Hz, Fase de 100-1Khz, Fase de 1k-10KHz, fase de 10Khz-50HKhz.

7.2.7 Conductividad Magnitud y Fase

En las Figuras 107 y 108 se muestra a detalle la correlación que existe entre el Magnesio y las variables de Magnitud de 0-10 Hz, Magnitud de 10-100Hz, Magnitud de 1k-10kHz, Magnitud de 10k-50KHz, Fase de 0-10Hz, Fase de 100-1Khz, Fase de 1k-10KHz, fase de 10Khz-50HKhz. Se puede apreciar que la Magnitud de 1k-10Khz, Magnitud de 10k-50KHz y la Fase 0-10Hz y la tienen una estrecha correlación con la Conductividad del suelo.




Figura 107. Correlación de la Conductividad con Magnitud de 0-10 Hz, Magnitud de 10-100Hz, Magnitud de 1k-10kHz, Magnitud de 10k-50KHz, Fase de 0-10Hz, Fase de 100-1Khz, Fase de 1k-10KHz, fase de 10Khz-50HKhz.

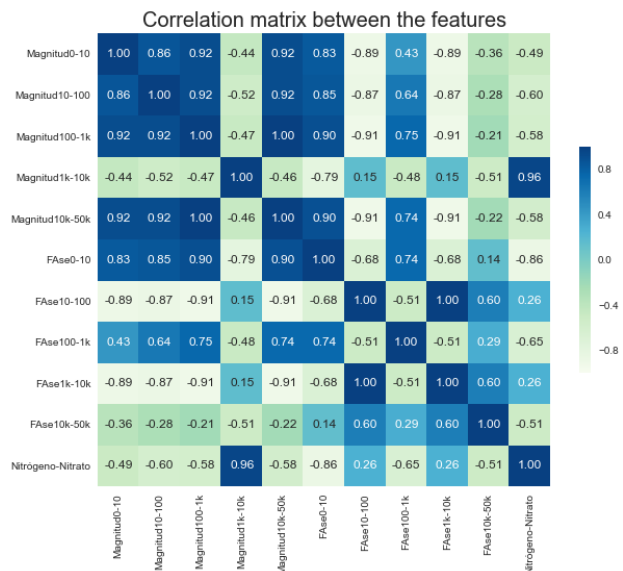


Figura 108. Matriz de Correlación de la Conductividad con Magnitud de 0-10 Hz, Magnitud de 10-100Hz, Magnitud de 1k-10kHz, Magnitud de 10k-50KHz, Fase de 0-10Hz, Fase de 100-1Khz, Fase de 1k-10KHz, fase de 10Khz-50HKhz.

7.2.8 Nitrógeno-Nitrato

En las Figura 109 y 110 se muestra a detalle la correlación que existe entre el Magnesio y las variables de Magnitud de 0-10 Hz, Magnitud de 10-100Hz, Magnitud de 1k-10kHz, Magnitud de 10k-50KHz, Fase de 0-10Hz, Fase de 100-1Khz, Fase de 1k-10KHz, fase de 10Khz-50HKhz. Se puede apreciar que la Magnitud de 1k-10Khz, la Fase 0-10Hz y la fase de 100-1Khz tienen una estrecha correlación con el Nitrógeno-Nitrato del suelo.




Figura 109. Correlación del Nitrógeno-Nitrato con Magnitud de 0-10 Hz, Magnitud de 10-100Hz, Magnitud de 1k-10kHz, Magnitud de 10k-50KHz, Fase de 0-10Hz, Fase de 100-1Khz, Fase de 1k-10KHz, fase de 10Khz-50HKhz.




Figura 110. Matriz de Correlación del Nitrógeno-Nitrato con Magnitud de 0-10 Hz, Magnitud de 10-100Hz, Magnitud de 1k-10kHz, Magnitud de 10k-50KHz, Fase de 0-10Hz, Fase de 100-1Khz, Fase de 1k-10KHz, fase de 10Khz-50HKhz.

Los resultados de los coeficientes de correlación indican que existe un patrón jerárquico entre la magnitud y la fase con respecto al análisis fisicoquímico del suelo. Puede ser observado que las variables (Na, Mn, K, Ca, P, pH, Conductividad y N-No3) tiene un patrón jerárquico que es diferente entre ellos mismos con respecto a la magnitud y fase de los componentes del sensor. Es por esto que cada variable tiene una respuesta característica en determinados puntos de la magnitud y fase del sensor. En las figuras 111 y 112 se muestra las gráficas totales de la correlación de cada uno de los elementos en su magnitud y fase.




Figura 111. Gráfica de correlación de los valores de la respuesta en frecuencia de magnitud del P, Ca, Mn, Na, CE y N-NO3




Figura 112. Gráfica de correlación de los valores de la respuesta en frecuencia de magnitud del P, Ca, Mn, Na, CE y N-NO3

7.3 Clasificación y validación

El siguiente paso estuvo enfocado a construir y entrenar un clasificador, el cual pueda clasificar los datos con precisión. Para esta sección es necesario dividir los datos en una porción de entrenamiento y otra de prueba. Con los datos de prueba se entrenará el clasificador y con los del test se validará la precisión del clasificador. Usualmente se realiza en un radio de 70%/30% cuando la base de datos contiene suficientes datos para realizar el análisis.

Otro factor importante es que la distribución de diferentes clases en los datos de entrenamiento y en los datos del test debe ser igual a la distribución en la actual base de datos. Normalmente se utiliza un algoritmo que aleatoriamente tome los datos para el set de entrenamiento y el de validación.

Se utilizaron en total 160 datos de muestras de suelos. Los datos utilizados corresponden a los datos de magnitud y fase del estudio de los suelos con espectrometría utilizando el sensor capacitivo. De esta forma se están utilizando los datos de Magnitud de 0-10 Hz, Magnitud de 10-100Hz, Magnitud de 1k-10kHz, Magnitud de 10k-50KHz, Fase de 0-10Hz, Fase de 100-1Khz, Fase de 1k-10KHz y fase de 10Khz-50Khz. Los datos utilizados en la salida con los cuales se quiere

entrenar el clasificador son los datos fisicoquímicos obtenidos en laboratorio de pH, Nitrógeno-Nitrato, Potasio, Magnesio, Sodio, Conductividad, Calcio, fósforo.

Se utilizaron en total 8 algoritmos de clasificación los cuales son descritos a continuación:

Logistic Regression: En estadística, la regresión logística es un tipo de análisis de regresión utilizado para predecir el resultado de una variable categórica (una variable que puede adoptar un número limitado de categorías) en función de las variables independientes o predictoras. Es útil para modelar la probabilidad de un evento ocurriendo como función de otros factores.

Nearest Neighbors: Este es un método de clasificación no paramétrico, que estima el valor de la función de densidad de probabilidad o directamente la probabilidad a posteriori de que un elemento x pertenezca a la clase a partir de la información proporcionada por el conjunto de prototipos.

Linear SVM: En el campo del aprendizaje automático, el objetivo del aprendizaje supervisado es usar las características de un objeto para identificar a qué clase (o grupo) pertenece. Un clasificador lineal logra esto tomando una decisión de clasificación basada en el valor de una combinación lineal de sus características. Las características de un objeto son típicamente presentadas en un vector llamado vector de características.

El clasificador de Bayes: es un clasificador probabilístico fundamentado en el teorema de Bayes y algunas hipótesis simplificadoras adicionales. Es a causa de estas simplificaciones, que se suelen resumir en la hipótesis de independencia entre las variables predictoras

Random Forest: Es una combinación de árboles predictores tal que cada árbol depende de los valores de un vector aleatorio probado independientemente y con la misma distribución para cada uno de estos. Es una modificación sustancial de bagging que construye una larga colección de árboles no correlacionados y luego los promedia.

Gradient Boosting Classifier: el cual produce un modelo predictivo en forma de un conjunto de modelos de predicción débiles, típicamente árboles de decisión. Construye el modelo de forma escalonada como lo hacen otros métodos de boosting, y los generaliza permitiendo la optimización arbitraria de una función de pérdida diferenciable.

7.3.1 Clasificación y validación del Fósforo con parámetros de espectroscopía

La Tabla 16 muestra los resultados obtenidos en la clasificación del fósforo utilizando los datos de magnitud y fase obtenidos por espectroscopia. Se puede apreciar que la regresión logística es la que obtuvo el mejor resultado tanto en el entrenamiento como en las pruebas con datos con los que no fue entrenado.

	classifier	train_score	test_score	train_time
0	Logistic Regression	1.000000	1.000000	0.003715
1	Nearest Neighbors	1.000000	0.888889	0.001133
2	Linear SVM	1.000000	0.888889	0.001816
7	Naive Bayes	1.000000	0.888889	0.001542
6	Neural Net	0.777778	0.777778	0.163604
5	Random Forest	1.000000	0.666667	1.427779
3	Gradient Boosting Classifier	1.000000	0.444444	2.943233
4	Decision Tree	1.000000	0.333333	0.000765

Tabla 16. Resultados de clasificación de Fósforo con los datos de entrenamiento, los datos de Prueba y el tiempo de entrenamiento

7.3.2 Clasificación y validación del Potasio con parámetros de espectroscopía

La Tabla 17 muestra los resultados obtenidos en la clasificación del Potasio utilizando los datos de magnitud y fase obtenidos por espectroscopia. Se puede apreciar los algoritmos de Nearest Neighbors y linear SVM son los que obtuvieron el mejor resultado tanto en el entrenamiento como en las pruebas con datos con los que no fue entrenado.

	classifier	train_score	test_score	train_time
1	Nearest Neighbors	1.000000	0.888889	0.000946
2	Linear SVM	0.888889	0.888889	0.001485
5	Random Forest	1.000000	0.777778	1.575811
6	Neural Net	0.777778	0.777778	0.158125
0	Logistic Regression	0.666667	0.666667	0.003880
3	Gradient Boosting Classifier	1.000000	0.666667	2.570700
4	Decision Tree	1.000000	0.444444	0.000522
7	Naive Bayes	1.000000	0.222222	0.001495

Tabla 17. Tabla de resultados de clasificación de Potasio con los datos de entrenamiento, los datos de Prueba y el tiempo de entrenamiento

7.3.3 Clasificación y validación del Magnesio con parámetros de espectroscopía

La Tabla 18 muestra los resultados obtenidos en la clasificación del Magnesio utilizando los datos de magnitud y fase obtenidos por espectroscopia. Se puede apreciar los algoritmos de Nearest Neighbors y linear SVM son los que obtuvieron

el mejor resultado tanto en el entrenamiento como en las pruebas con datos con los que no fue entrenado.

	classifier	train_score	test_score	train_time
1	Nearest Neighbors	1.000000	0.888889	0.000946
2	Linear SVM	0.888889	0.888889	0.001485
5	Random Forest	1.000000	0.777778	1.575811
6	Neural Net	0.777778	0.777778	0.158125
0	Logistic Regression	0.666667	0.666667	0.003880
3	Gradient Boosting Classifier	1.000000	0.666667	2.570700
4	Decision Tree	1.000000	0.444444	0.000522
7	Naive Bayes	1.000000	0.222222	0.001495

Tabla 18. Tabla de resultados de clasificación de Magnesio con los datos de entrenamiento, los datos de Prueba y el tiempo de entrenamiento

7.3.4 Clasificación y validación del Calcio con parámetros de espectroscopía

La Tabla 19 muestra los resultados obtenidos en la clasificación del Calcio utilizando los datos de magnitud y fase obtenidos por espectroscopia. Se puede apreciar los algoritmos de Logistic regression, Nearest Neighbors y linear SVM son los que obtuvieron el mejor resultado tanto en el entrenamiento como en las pruebas con datos con los que no fue entrenado.

	classifier	train_score	test_score	train_time
0	Logistic Regression	1.000000	1.000000	0.003650
1	Nearest Neighbors	1.000000	0.888889	0.000891
2	Linear SVM	1.000000	0.888889	0.001237
6	Neural Net	0.888889	0.888889	0.190346
7	Naive Bayes	1.000000	0.888889	0.001612
3	Gradient Boosting Classifier	1.000000	0.666667	2.819419
5	Random Forest	1.000000	0.666667	1.408348
4	Decision Tree	1.000000	0.444444	0.000538

Tabla 19. Tabla de resultados de clasificación de Calcio con los datos de entrenamiento, los datos de Prueba y el tiempo de entrenamiento

7.3.5 Clasificación y validación del Sodio con parámetros de espectroscopía

La Tabla 20 muestra los resultados obtenidos en la clasificación del Sodio utilizando los datos de magnitud y fase obtenidos por espectroscopia. Se puede apreciar los algoritmos de Nearest Neighbors y linear SVM son los que obtuvieron el mejor resultado tanto en el entrenamiento como en las pruebas con datos con los que no fue entrenado.

	classifier	train_score	test_score	train_time
1	Nearest Neighbors	1.000000	0.888889	0.001023
2	Linear SVM	0.888889	0.888889	0.001276
0	Logistic Regression	0.555556	0.555556	0.003065
3	Gradient Boosting Classifier	1.000000	0.555556	1.901970
5	Random Forest	1.000000	0.555556	1.413493
4	Decision Tree	1.000000	0.444444	0.000656
6	Neural Net	0.444444	0.444444	0.014769
7	Naive Bayes	0.888889	0.444444	0.001534

Tabla 20. Tabla de resultados de clasificación de Sodio con los datos de entrenamiento, los datos de Prueba y el tiempo de entrenamiento

7.3.6 Clasificación y validación del Conductividad con parámetros de espectroscopía

La Tabla 21 muestra los resultados obtenidos en la clasificación del Conductividad utilizando los datos de magnitud y fase obtenidos por espectroscopia. Se puede apreciar los algoritmos de Nearest Neighbors y linear SVM son los que obtuvieron el mejor resultado tanto en el entrenamiento como en las pruebas con datos con los que no fue entrenado.

Tabla 21. Tabla de resultados de clasificación de Conductividad con los datos de entrenamiento, los datos de Prueba y el tiempo de entrenamiento

7.3.7 Clasificación y validación del Nitrógeno-Nitrato con parámetros de espectroscopía

La Tabla 22 muestra los resultados obtenidos en la clasificación del Nitrógeno-Nitrato utilizando los datos de magnitud y fase obtenidos por espectroscopia. Se puede apreciar los algoritmos de Nearest Neighbors y linear SVM son los que obtuvieron el mejor resultado tanto en el entrenamiento como en las pruebas con datos con los que no fue entrenado.

	classifier	train_score	test_score	train_time
1	Nearest Neighbors	1.000000	1.000000	0.000889
2	Linear SVM	1.000000	0.888889	0.001180
6	Neural Net	0.888889	0.888889	0.181315
0	Logistic Regression	0.888889	0.777778	0.003390
3	Gradient Boosting Classifier	1.000000	0.777778	2.021747
4	Decision Tree	1.000000	0.666667	0.000463
5	Random Forest	1.000000	0.555556	1.610763
7	Naive Bayes	1.000000	0.222222	0.001355

Tabla 22. Tabla de resultados de clasificación de Nitrógeno-Nitrato con los datos de entrenamiento, los datos de Prueba y el tiempo de entrenamiento

7.3.8 Redes Neuronales

A diferencia de los demás algoritmos utilizados y reportados hasta el momento, las redes neuronales artificiales ANN, tienen la capacidad de crear clasificaciones de sistemas MIMO (Múltiple input multiple output). Por esta razón se abordó el uso de este algoritmo basado en diferentes configuraciones concernientes al número de neuronas en las capas de entrada, así como diferente número de capa de neuronas intermedia. Con la finalidad de crear un sistema que sea capaz de estimar paramétricamente los valores de N, CE, Na, Mg, Ca, K, F y pH a partir de los datos de entrada, lo cual son los valores correspondientes a la magnitud y fase del sensor capacitivo.

El vector de entrada de la red neuronal fue creado a partir de 100 valores correspondientes a la gráfica de respuesta en frecuencia de magnitud y 100 valores correspondientes a la gráfica de respuesta en frecuencia de la fase obtenidos de los experimentos de barrido de frecuencia de las muestras de suelo. Estos 200 valores de entrada contienen información detallada del comportamiento de magnitud y fase en la frecuencia de cada una de las muestras de suelo. Esta información es utilizada para poder realizar el aprendizaje supervisado de la red neuronal. Dicho aprendizaje se logra mediante el entrenamiento de la red neuronal la cual será capaz de estimar los valores de N, CE, Na, Mg, Ca, K, F, pH utilizando los valores de magnitud y fase de la respuesta en frecuencia del suelo.

En las Figura 113, Figura 114 y Figura 115 se muestran las gráficas que presentan los resultados de laboratorio de los niveles de Ca, CE, K y Mg de las muestras de suelo (azul) y los resultados obtenidos por de la Red Neuronal Artificial (amarillo).

Elaboración de un sistema inteligente para la estimación de propiedades fisicoquímicas de suelos con producción de caña de azúcar

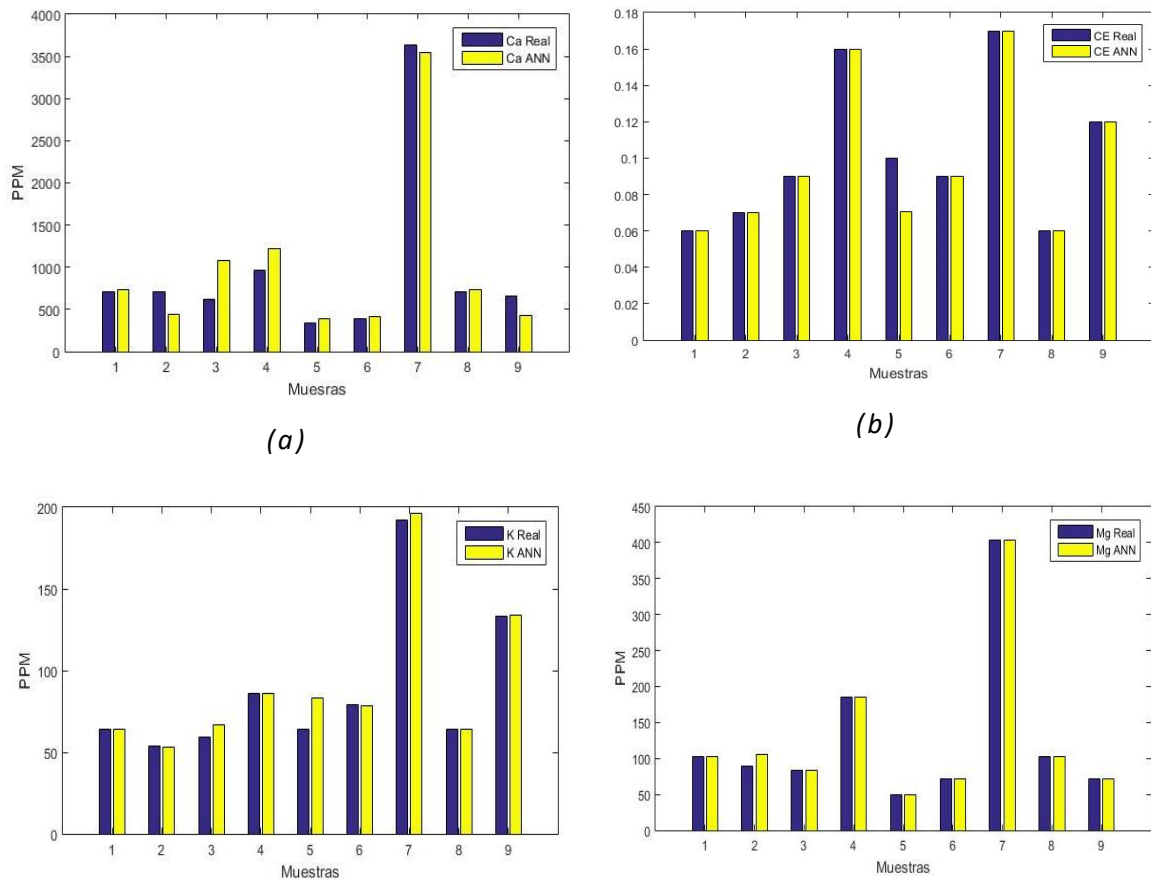


Figura 113. Gráficas que presentan los resultados de laboratorio de los niveles de a) Ca, b) CE, c) K y d) Mg de las muestras de suelo (azul) y los resultados obtenidos por de la Red Neuronal Artificial (amarillo)

Los errores cuadráticos medios obtenidos entre los valores reales y los estimado por la ANN son: P= 5.52 ppm, pH=.74, Na=2.91 ppm, N=2.35 ppm, Mg=5.68 ppm, K=7.03 ppm, CE=0.0097 dS/m y Ca=213 ppm. Estableciendo el máximo valor de cada elemento (P, pH, Na, N, Mg, K, CE y Ca) como el rango máximo, para cada gráfica se obtienen los errores: P=4.90%, pH= 8.52%, Na= 8.43%, N=4.24%, Mg= 0.93%, K= 2.44%, CE=3.81% y Ca=3.91%. Lo cual nos indica que la red neuronal para el pH y el Na son los elementos que presentan un mayor error en la estimación.

Elaboración de un sistema inteligente para la estimación de propiedades fisicoquímicas de suelos con producción de caña de azúcar




Figura 114. Gráficas que presentan los resultados de laboratorio de los niveles de a) Na, b) pH, c) P y d) N de las 8 muestras de suelo (azul) y los Resultados de la Red Neuronal Artificial (amarillo)




Figura 115. Validación ANNs (Porcentaje de error vs Número de neuronas de la capa intermedia)

En base a los resultados obtenidos, la técnica de espectroscopia de baja frecuencia utilizada en conjunto con algoritmos de inteligencia artificial basados en redes neuronales ha demostrado ser de gran utilidad para lograr la estimación de los valores de N, CE, Na, Mg, Ca, K, F y pH de las muestras de suelo. Los errores para la estimación de los diferentes parámetros estimados en este estudio son menores al 5% con excepción del pH y el Na, lo cual nos da una buena estimación del contenido de minerales en cada muestra. Se encontró un error cercano al 8.5% para el contenido de Na así como para el pH lo cual puede deberse al carácter iónico de estos parámetros, sin embargo para esta primer aproximación se considera que la información proporcionada por este sistema, puede ser de gran ayuda en la nutrientes y humedad de suelos.

7.3.8 Estadística final de validación del sistema de clasificación.

La Figura 116 muestra una gráfica con la puntuación de clasificación con los datos de entrenamiento utilizando las variables de magnitud y fase del estudio de espectroscopia y los datos fisicoquímicos de laboratorio del fósforo, potasio, magnesio, calcio, sodio, conductividad, nitrógeno-nitrato.




Figura 116. Train Score

La Figura 117 muestra una gráfica con la puntuación de clasificación con los datos de prueba utilizando las variables de magnitud y fase del estudio de espectroscopia y los datos fisicoquímicos de laboratorio del fósforo, potasio, magnesio, calcio, sodio, conductividad, nitrógeno-nitrato.




Figura 117. Test Score

La Figura 118 muestra una gráfica con la puntuación de clasificación con los datos de prueba utilizando las variables de magnitud y fase del estudio de espectroscopia y los datos fisicoquímicos de laboratorio del fósforo, potasio, magnesio, calcio, sodio, conductividad, nitrógeno-nitrato.




Figura 118. Tiempos de entrenamiento

CAPITULO VIII: SISTEMA INTELIGENTE PARA LA ESTIMACIÓN DE PROPUESTA DE RESTAURACIÓN.

En este capítulo se presenta la implementación de algoritmos de inteligencia artificial enfocados al proceso de restauración de suelos. Se experimentó con varias técnicas con el objetivo de tener un sistema inteligente que a través de aprendizaje supervisado sea capaz de realizar una estimación de la cantidad requerida de Yeso, N, P₂O₅, K₂O, Mg, S, B, Cu y Mn que deben de ser aplicados en el suelo para su proceso de restauración. En la Tabla 23 se muestra un análisis estadístico de 99 muestras con las cantidades requeridas para ser aplicadas en el suelo las cuales fueron estimadas por el laboratorio a partir de sus propiedades fisicoquímicas (Tablas 24) para poder realizar el proceso de remediación.

	Yeso	N	P2O5	K2O	Mg	S	B	Cu	Mn
count	99.0	99.000000	99.000000	99.0	99.000000	99.000000	99.000000	99.000000	99.000000
mean	144.0	73.333333	362.444444	0.0	58.333333	1.777778	3.333333	4.666667	4.666667
std	0.0	22.304022	540.593876	0.0	9.476071	0.320572	1.253566	1.571429	1.641304
min	144.0	30.000000	143.000000	0.0	45.000000	1.200000	2.000000	2.000000	2.000000
25%	144.0	62.000000	167.000000	0.0	45.000000	1.400000	2.000000	4.000000	4.000000
50%	144.0	78.000000	181.000000	0.0	65.000000	2.000000	4.000000	4.000000	6.000000
75%	144.0	94.000000	187.000000	0.0	65.000000	2.000000	4.000000	6.000000	6.000000
max	144.0	102.000000	1883.000000	0.0	65.000000	2.000000	5.000000	7.000000	6.000000

Tabla 23. Análisis estadísticos de los resultados con las cantidades requeridas para ser aplicadas en el suelo estimados por el laboratorio a partir de las propiedades fisicoquímicas del suelo para poder realizar el proceso de remediación.

	pH suelo	Fósforo	Potasio	Calcio	Magnesio	Sodio	CE	N-NO3
count	99.000000	99.000000	99.000000	99.000000	99.000000	99.000000	99.000000	99.000000
mean	6.444444	13.222222	52.555556	1983.111111	550.888889	56.822222	0.105556	15.555556
std	0.354914	8.999496	24.164497	449.720296	168.811384	31.501123	0.045964	7.249521
min	5.900000	2.000000	32.000000	1386.000000	258.000000	8.400000	0.000000	7.000000
25%	6.300000	7.000000	37.000000	1667.000000	514.000000	41.000000	0.090000	9.000000
50%	6.300000	13.000000	43.000000	1735.000000	567.000000	47.000000	0.100000	15.000000
75%	6.600000	19.000000	48.000000	2378.000000	709.000000	71.000000	0.140000	21.000000
max	7.000000	30.000000	104.000000	2848.000000	760.000000	124.000000	0.160000	29.000000

Tabla 24. Análisis estadístico de las propiedades fisicoquímicas de las muestras de suelo.

Específicamente para abordar el tema de restauración de suelo fue necesario utilizar aprendizaje Supervisado, ya que las cantidades requeridas como Yeso, N, P₂O₅, K₂O, Mg, S, B, Cu y Mn han sido recomendadas y estimadas por expertos. El laboratorio en donde se realizó el análisis de propiedades fisicoquímicas del suelo realizó estas recomendaciones de restauración de 99 muestras de suelo. Debido a que es un problema que envuelve la clasificación se optó por utilizar Logistic Regression, Linear SVM, Gradient Boosting Classifier, Decision Tree, Random Forest, Naive Bayes, Nearest Neighbors y Artificial Neuronal Networks. En cada uno de los algoritmos mencionados se obtuvieron los datos de los resultados de entrenamiento, el resultado con los datos de prueba, y el tiempo de entrenamiento. Los parámetros de entrada en los algoritmos de clasificación fueron pH, P, K, Ca, Mg, S, B, Cu y Mn. Los parámetros de salida de los clasificadores fueron Yeso, N, P₂O₅, K₂O, Mg, S, B, Cu y Mn.

En la Tabla 25 se muestran los resultados de los clasificadores para la estimación de la cantidad requerida de aplicación de N en el suelo para su restauración. Se logra apreciar que el que tuvo su máximo score fue la regresión logística al tener un 100% en reconocimiento. Los clasificadores de Gradient Boosting Classifier y el Random Forest también presentaron resultados aceptables teniendo un 77% de reconocimiento.

	classifier	train_score	test_score	train_time
0	Logistic Regression	1.000000	1.000000	0.003375
3	Gradient Boosting Classifier	1.000000	0.777778	2.084901
5	Random Forest	1.000000	0.777778	0.967582
1	Nearest Neighbors	1.000000	0.333333	0.000831
4	Decision Tree	1.000000	0.333333	0.000755
2	Linear SVM	1.000000	0.222222	0.001039
6	Neural Net	0.222222	0.222222	0.005899
7	Naive Bayes	1.000000	0.222222	0.001447

Tabla 25. Tabla de resultados de clasificación de N con los datos de entrenamiento, los datos de Prueba y el tiempo de entrenamiento

En la Tabla 26 se muestran los resultados de los clasificadores para la estimación de la cantidad requerida de aplicación de P₂O₅ en el suelo para su restauración. Se logra apreciar que el que tuvo el mejor resultado fue la regresión logística al tener un 100% en reconocimiento. Los clasificadores de Gradient Boosting Classifier y el Random Forest también presentaron resultados aceptables teniendo un 77% y 88% de reconocimiento respectivamente.

	classifier	train_score	test_score	train_time
0	Logistic Regression	1.000000	1.000000	0.003480
5	Random Forest	1.000000	0.888889	0.958055
3	Gradient Boosting Classifier	1.000000	0.777778	2.480871
1	Nearest Neighbors	1.000000	0.333333	0.000542
4	Decision Tree	1.000000	0.333333	0.000821
7	Naive Bayes	1.000000	0.333333	0.001656
2	Linear SVM	1.000000	0.111111	0.001147
6	Neural Net	0.111111	0.111111	0.019789

Tabla 26. Tabla de resultados de clasificación de P_2O_5 con los datos de entrenamiento, los datos de Prueba y el tiempo de entrenamiento

En la Tabla 27 se muestran los resultados de los clasificadores para la estimación de la cantidad requerida de aplicación de Mg en el suelo para su restauración. Se logra apreciar que el que tuvo el mejor resultado fue la regresión logística al tener un 77% en reconocimiento. Los clasificadores de Gradient Boosting Classifier y el Decision Tree también presentaron resultados aceptables teniendo un 77% de reconocimiento.

	classifier	train_score	test_score	train_time
0	Logistic Regression	0.777778	0.777778	0.001161
3	Gradient Boosting Classifier	1.000000	0.777778	0.234135
4	Decision Tree	1.000000	0.777778	0.000343
7	Naive Bayes	0.888889	0.777778	0.000919
1	Nearest Neighbors	1.000000	0.666667	0.000790
2	Linear SVM	1.000000	0.666667	0.000913
5	Random Forest	1.000000	0.666667	0.999255
6	Neural Net	0.666667	0.666667	0.052104

Tabla 27. Tabla de resultados de clasificación de Mg con los datos de entrenamiento, los datos de Prueba y el tiempo de entrenamiento

En la Tabla 28 se muestran los resultados de los clasificadores para la estimación de la cantidad requerida de aplicación de B en el suelo para su restauración. Se logra apreciar que el que tuvo el mejor resultado fue la regresión logística al tener un 100% en reconocimiento. Los clasificadores de Gradient Boosting Classifier y

el Decision Tree también presentaron resultados aceptables teniendo un 66% de reconocimiento.

	classifier	train_score	test_score	train_time
0	Logistic Regression	1.000000	1.000000	0.001543
3	Gradient Boosting Classifier	1.000000	0.666667	0.837909
4	Decision Tree	1.000000	0.666667	0.000832
5	Random Forest	1.000000	0.666667	0.888344
1	Nearest Neighbors	1.000000	0.555556	0.000730
7	Naive Bayes	1.000000	0.555556	0.000992
2	Linear SVM	1.000000	0.444444	0.000750
6	Neural Net	0.333333	0.333333	0.053325

Tabla 28. Tabla de resultados de clasificación de B con los datos de entrenamiento, los datos de Prueba y el tiempo de entrenamiento

En la Tabla 29 se muestran los resultados de los clasificadores para la estimación de la cantidad requerida de aplicación de Cu en el suelo para su restauración. Se logra apreciar que el que tuvo el mejor resultado fue la regresión logística al tener un 100% en reconocimiento. Los clasificadores de Random Forest tuvo un reconocimiento aceptable del 66%.

	classifier	train_score	test_score	train_time
0	Logistic Regression	1.000000	1.000000	0.002942
5	Random Forest	1.000000	0.666667	0.883674
1	Nearest Neighbors	1.000000	0.555556	0.000547
2	Linear SVM	1.000000	0.555556	0.000907
7	Naive Bayes	1.000000	0.555556	0.001287
3	Gradient Boosting Classifier	1.000000	0.444444	1.084125
4	Decision Tree	1.000000	0.333333	0.000664
6	Neural Net	0.222222	0.222222	0.015726

Tabla 29. Tabla de resultados de clasificación de Cu con los datos de entrenamiento, los datos de Prueba y el tiempo de entrenamiento

En la Tabla 30Tabla 29 se muestran los resultados de los clasificadores para la estimación de la cantidad requerida de aplicación de Mn en el suelo para su restauración. Se logra apreciar que el que tuvo el mejor resultado fue la regresión logística al tener un 100% en reconocimiento. Los clasificadores de Gradiente Boostin, Decision Tree, Random Forest y Naives Bayes tuvieron un reconocimiento del 77%.

	classifier	train_score	test_score	train_time
0	Logistic Regression	1.000000	1.000000	0.001474
3	Gradient Boosting Classifier	1.000000	0.777778	0.837917
4	Decision Tree	1.000000	0.777778	0.000617
5	Random Forest	1.000000	0.777778	0.921207
7	Naive Bayes	1.000000	0.777778	0.001089
1	Nearest Neighbors	1.000000	0.555556	0.000778
2	Linear SVM	1.000000	0.555556	0.000713
6	Neural Net	0.222222	0.222222	0.010220

Tabla 30. Tabla de resultados de clasificación de Mn con los datos de entrenamiento, los datos de Prueba y el tiempo de entrenamiento

Como se puede apreciar en la Figura 119 se muestra el resultado de los clasificadores utilizados para la estimación de N, P₂O₅, Mg, B, Cu y Mn. Los mejores resultados fueron obtenidos por la regresión logística, seguido del Gradient Boosting Classifier y el Random Forest.



Figura 119. Resultados de reconocimiento con los clasificadores

CONCLUSIONES

Una de las más importantes aportaciones científicas de esta tesis está basada en la estimación de los componentes fisicoquímicos del suelo utilizando la respuesta en frecuencia en su magnitud y fase del sensor capacitivo. En la literatura los sensores capacitivos son utilizados principalmente para la medición de humedad y de Conductividad Eléctricas de los suelos. Sin embargo, con la investigación realizada fue posible utilizar el sensor capacitivo para la estimación de parámetros fisicoquímicos a través del estudio de su respuesta en frecuencia y la utilización de algoritmos de inteligencia artificial que realizaron la estimación de dichos parámetros basada en la correlación de todas las variables involucradas y su respuesta en frecuencia. Se encontró que, para cada elemento fisicoquímico analizado, este mostraba un comportamiento característico en determinadas bandas de frecuencias tanto en su magnitud como en su fase.

Una de las aportaciones en el aspecto tecnológico fue la realización de un sistema de espectroscopía que puede inferir variables fisicoquímicas de los suelos, en específico los Vertisoles de la región de las Montañas de Veracruz. El sistema utilizado cuenta con una precisión del 95% en la estimación de los parámetros fisicoquímicos. Además, esta tecnología se logró implementar en un sistema embebido que puede ser utilizado en campo y sin necesidad de un experto para lograr las determinaciones necesarias.

En la investigación de la conductividad térmica se encontró en la investigación que los nitratos y fosfatos fue mayor que otros componentes químicos, sugiriendo que la presencia de fertilizantes incrementa la conductividad térmica del suelo estudiado. También se logró detectar que la información obtenida con el sensor de conductividad térmica coincidiera con los datos obtenidos por literatura; sin embargo, la correlación de la conductividad con la humedad fue inversa indicando que el contenido de sales, densidad, y otros parámetros fisicoquímicos interfieren en el comportamiento térmico del suelo. Se encontró que los valores de conductividad térmica tienden a tener un comportamiento de aislante térmico. El método probó ser confiable para explorar la conductividad térmica en suelos.

Se confirmó el estado de los suelos de la región, 10 municipios presentan acidez, lo cual se traduce en que no se pueden aprovechar los nutrientes además de tener probabilidades de toxicidad de algún micronutriente. 2 municipios presentaron alcalinidad dificultando el transporte de nutrientes. Solo un municipio presentó una CIC que permite que haya una buena disponibilidad de nutrientes a la planta, 9 municipios presentaron deficiencia de Ca, en cuanto a los otros nutrientes se observó un desbalance a lo largo del perfil del suelo, esto probablemente debido a la forma de aplicar los fertilizantes. Finalmente, se sospecha que para al menos un municipio pudiera haber toxicidad por Mn.

Referencias

- Agencia Informativa Conacyt. (2015). Software al servicio del sector agrícola. Retrieved from <http://www.conacytprensa.mx/index.php/tecnologia/tic/1804-nota-software-al-servicio-del-sector-agricola>
- Alberto, J., Herrán, F., Raudel, R., Torres, S., Enrique, G., Martínez, R., ... Ximhai, R. (2008). Ra Ximhai Universidad Autónoma Indígena de México IMPORTANCIA DE LOS ABONOS ORGÁNICOS, 4, 57–67. Retrieved from [http://www.uaim.edu.mx/webraximhai/Ej-10articulosPDF/Art\[1\]_4_Abonos.pdf](http://www.uaim.edu.mx/webraximhai/Ej-10articulosPDF/Art[1]_4_Abonos.pdf)
- Altieri, M. A. (1999). Agroecología. Bases científicas para una agricultura sustentable. *Editorial Nordan–Comunidad*.
- Alvarez-Guerra, M., González-Piñuela, C., Andrés, A., Galán, B., & Viguri, J. R. (2008). Assessment of Self-Organizing Map artificial neural networks for the classification of sediment quality. *Environment International*, 34(6), 782–790. <https://doi.org/10.1016/j.envint.2008.01.006>
- Ascanio, M. O., & Hernández, A. (2004). Cambios climáticos y degradación de los suelos en los agrosistemas cañeros representativos de México.
- Astel, a, Tsakovski, S., Barbieri, P., & Simeonov, V. (2007). Comparison of self-organizing maps classification approach with cluster and principal components analysis for large environmental data sets. *Water Research*, 41(19), 4566–4578. <https://doi.org/10.1016/j.watres.2007.06.030>
- Barbaro Lorena A., Karlanian Monica A., M. D. A. (n.d.). Importancia del pH y la Conductividad Eléctrica en los sustratos para plantas. *Ministerio de Agricultura, Ganadería y Pesca*. Retrieved from http://inta.gob.ar/sites/default/files/script-tmp-inta_-_importancia_del_ph_y_la_conductividad_elctrica.pdf
- Brenda Gabriela Díaz-Hernández, J. F. A.-M. y V. H. D.-F. (2013). Rendimiento de *Jatropha curcas* L. inoculada con micorriza y aplicación de composta de caña, 4, 599–610.
- Broome, S. W. (n.d.). Fertilizer & soils fertility. The agricultural Institute.
- Burkle. (n.d.). Muestreo de suelos. Retrieved from <https://www.buerkle.de/es/muestreo-de-suelos>
- Cabrera, R. A., & Zuaznabar, J. A. (2010). Impacto sobre el ambiente del monocultivo de la caña de azúcar con el uso de la quema para la cosecha y la fertilización nitrogenada. I. Balance del carbono. *Cultivos Tropicales*, 31(1), 5–13.
- Chaves-Solera, M., & Araya-Vindas, Á. (2007). Caracterización preliminar de suelos cultivados con caña de azúcar en la zona norte de Costa Rica: Cantones de

San Carlos y Los Chiles.

- Chon, T.-S. (2011). Self-Organizing Maps applied to ecological sciences. *Ecological Informatics*, 6(1), 50–61. <https://doi.org/10.1016/j.ecoinf.2010.11.002>
- Comeau, Y., Greer, C. V., & Samson, R. (1993). Role of inoculum preparation and density on the bioremediation of 2,4-D contaminated soil by bioaugmentation. *Appl Microbiol. Technol.*, 38, 681–687.
- Comité Nacional para el Desarrollo Sustentable de la Caña de Azúcar. (2015). *FICHA TÉCNICA DEL CULTIVO DE LA CAÑA DE AZÚCAR (Saccharum officinarum L.)*.
- CONADESUCA/SAGARPA. (2018). Reporte Final de producción de caña y azúcar zafra 2017/18, 661(53), 730. Retrieved from www.gob.mx/conadesuca,
- Coras Merino, P. M. (2003). *Propiedades físicas del suelo relacionadas con el riego*. Universidad Autónoma de Chapingo.
- Curry, J. P., & Schmidt, O. (2007). The feeding ecology of earthworms—A review. *Pedobiologia*, 50, 463–477.
- Cycoń, M., Wójcik, M., & Piotrowska-Seget, Z. (2009). Biodegradation of the organophosphorus insecticide diazinon by *Serratia* sp. and *Pseudomonas* sp. and their use in bioremediation of contaminated soil. *Chemosphere*, 76(4), 494–501. <https://doi.org/10.1016/j.chemosphere.2009.03.023>
- 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.
- Dimas López-Mtz, J., Díaz Estrada, A., Rubin, E. M., & Valdez Cepeda, R. D. (2001). (2001). Effect of Organic Fertilizers on Physical-Chemical Soil Properties and Corn Yield. *Terra Latinoamericana*, 19, 8. Retrieved from <http://www.redalyc.org/pdf/573/57319401.pdf>
- Duquenne, P., Parekh, N. R., Gatroux, G., & Fournier, J. C. (1996). Effect of inoculant density, formulation, dispersion and soil nutrient amendment on the removal of carbofuran residues from contaminated soils. *Soil Biol Biochem*, 28, 1805–1811.
- Dwivedi, U. N., Mishra, S., Singh, P., & Tripathi, R. (2007). Nitrate pollution and its remediation. In *Environmental Bioremediation Technologies* (pp. 354–380).
- Edwards, C. ., & Bohlen, C. . (1996). *Biology and Ecology of Earthworms*. (3rd editio). Chapman & Hall, London.
- Eijkelkamp. (n.d.). Eijkelkamp soil & water. Retrieved from [https://sp.eijkelkamp.com/productos/equipos-para-perforacion-y-muestreo-del-suelo/pagina\(1\)](https://sp.eijkelkamp.com/productos/equipos-para-perforacion-y-muestreo-del-suelo/pagina(1))
- El-Sheikh, E. A., & Ashour, M.-B. A. (2010). Biodegradation Technology for

- pesticide toxicity elimination. In M. H. FULEKAR (Ed.), *Bioremediation technology. Recent Advances* (pp. 167–205). Springer Berlin Heidelberg.
- Eldardiry, E. I., El-hady, M. A., & Zaghoul, a M. (2013). Relationship Between Soil Physical and Chemical Properties and Hydrophysical Soil Properties under Reuse of Agricultural Drainage Water, *13*(1), 1–6. <https://doi.org/10.5829/idosi.aejaes.2013.13.01.1913>
- Eweis, J. B., & Ergas, J. (1999). *Principios de biorecuperación*. Mc. Graw Hill.
- FAO. (2002). Conservación de los recursos naturales para una agricultura sostenible. *Fertilidad de Suelo*. Retrieved from http://www.fao.org/ag/ca/training_materials/cd27-spanish/sf/soil_fertility.pdf
- FAO. (2015). FAO soils portal. Retrieved from <http://www.fao.org/soils-portal/levantamiento-de-suelos/propiedades-del-suelo/propiedades-quimicas/es/>
- FAO. (2016). Estadísticas de caña de azúcar. Retrieved from <http://www.fao.org/faostat/es/#data>
- FENACH. (2000). *Como tomar muestras del suelo para Análisis Químico*.
- Fernández Linares, L. C., Rojas Avelizapa, N. G., Roldán Carrillo, T. G., Ramírez Islas, M. E., Zegarra Martínez, H. G., Uribe Hernández, R., ... Arce Ortega, J. M. (2006). *Manual de técnicas de análisis de suelos aplicadas a la remediación de sitios contaminados*. (SEMARNAT, INE, & IMP, Eds.).
- Ferrell, M., & Jones, D. (2009). Use of composts in the remediation of heavy metal contaminated soil.
- FHIA. (2007). *Analícemos el suelo para alimentar adecuadamente a los cultivos*.
- Flores, L., Alcalá, J. R., René, T. J., & Martínez, A. (2010). Manual de Procedimientos Analíticos. Laboratorio de física de suelos. Retrieved from [http://www.geologia.unam.mx/igl/deptos/edafo/lfs/MANUAL DEL LABORATORIO DE FISICA DE SUELOS1.pdf](http://www.geologia.unam.mx/igl/deptos/edafo/lfs/MANUAL_DEL_LABORATORIO_DE_FISICA_DE_SUELOS1.pdf)
- G.I.S. Ibérica. (n.d.). Barrenas, equipos para toma de muestras. Retrieved from http://www.gisiberica.com/barrenas_muestreo_de_suelos.pdf
- García-Gil, J. C., Plaza, C., Soler-Rovira, P., & Polo, A. (2000). Long term effects of municipal solid waste compost application on soil enzyme activities and microbial biomass. *Soil Biology & Biochemistry*, *32*, 1907–1913. <https://doi.org/10.1093/nq/s12-VII.128.250-e>
- García-Torres, R., & Ríos-Leal, E. (2010). Uso de cachaza y bagazo de caña de azúcar en la remoción de hidrocarburos en suelo contaminado.
- Garrabou S., R., & González de Molina, M. (2010). La reposición de la fertilidad en los sistemas agrarios tradicionales. *Barcelona, Icaria*, 319.
- Gevertz, D., Telang, A., Voordouw, G., & Jenneman, G. (2000). Isolation and

- characterization of strains CVO and FWKOB, two novel nitrate-reducing, sulfideoxidizing bacteria isolated from oil field brine. *Appl Environ Microbiol*, 66, 2491–2501.
- Glissman, S. R. (2002). Agroecología. Procesos ecológicos en Agricultura Sostenible. *CATIE, Turrialba, Costa, Rica*. Retrieved from <https://loomio-attachments.s3.amazonaws.com/uploads/6524915db1c9bdd88f2c7cd0f69924dc/agroecologia.pdf>
- Guzmán, I. (2006). Modelo de negocios para la comercialización de unidades, transferencia de lombrices (*lumbricus friendi*), para remediación de suelos compactados de naturaleza frutícola.
- Hernandez-Cuervas, L., Guerra-De la Cruz, V., Santiago-Martínez, G., & Cuatlal-Cuahutencos, P. (2011). Propagation and Mycorrhization of Native Plants With Soil Restoration Potential. *Revista Mexicana de Ciencias*, 2(7), 87–96.
- Hernández-Rodríguez, O. A., Ojeda-Barrios, D. L., Lopez Diaz, J. C., & Arras Vota, A. M. (2010). Abonos orgánicos y su efecto en las propiedades físicas, químicas y biológicas del suelo. *Tecnociencia Chihuahua*, IV(1), 1–6. Retrieved from http://www.ecosdeltajo.org/descargas/recursos/abonos_organicos_y_su_efecto_en_las_propiedades_fisicas_quimicas_biologicas_del_suelo.pdf
- Hernández, A. J., & Pastor, J. (2008). La restauración en sistemas con suelos degradados: estudio de casos en agroecosistemas mediterráneos y taludes de carretera. En: Contaminación de Suelos. Tecnologías para su Recuperación. *CIEMAT, Madrid.*, 545–564.
- Hu, Z. Y., Huang, G. H., & Chan, C. W. (2003). A fuzzy process controller for in situ groundwater bioremediation. *Engineering Applications of Artificial Intelligence*, 16(2), 131–147. [https://doi.org/10.1016/S0952-1976\(03\)00054-X](https://doi.org/10.1016/S0952-1976(03)00054-X)
- Hüskes, R., & Levsen, K. (1997). Pesticides in rain. *Chemosphere*, 35, 3013.
- Instituto Nacional de Estadística y Geografía, (Inegi). (2000). *Los análisis físicos y químicos en la cartografía edafológica del INEGI*.
- Karpouzas, D. G., & Walker, A. (2000). Factors influencing the ability of *Pseudomonas putida* epl to degrade ethoprophos in soil. *Soil Biol Biochem*, 32, 1753–1762.
- Katritzky, A. R., Kuanar, M., Slavov, S., Hall, C. D., Karelson, M., Kahn, I., & Dobchev, D. a. (2010). Quantitative correlation of physical and chemical properties with chemical structure: Utility for prediction. *Chemical Reviews*, 110(10), 5714–5789. <https://doi.org/10.1021/cr900238d>
- Keller, C., & Hammer, D. (2004). Metal availability and soil toxicity after repeated croppings of *Thlaspi Caerulescens* in metal contaminated soils. *Environmental Pollution (Barking, Essex : 1987)*, 131, 243–254.

- Keller, C., Kayser, A., Keller, A., & Schulin, R. (2001). *Heavy metal uptake by agricultural crops from sewage-sludge treated soils of the Upper Swiss Rhine Valley and the effects of time*. In: Iskander, I.K. (E. R. of M. Soils, Ed.). CRC Press.
- Kodaira, M., & Shibusawa, S. (2013). Using a mobile real-time soil visible-near infrared sensor for high resolution soil property mapping. *Geoderma*, 199, 64–79. <https://doi.org/10.1016/j.geoderma.2012.09.007>
- Kweon, G., Lund, E., & Maxton, C. (2013). Soil organic matter and cation-exchange capacity sensing with on-the-go electrical conductivity and optical sensors. *Geoderma*, 199, 80–89. <https://doi.org/10.1016/j.geoderma.2012.11.001>
- Lang-ovalle, F. P. (2007). CENTRO DE VERACRUZ , MÉXICO Attitude towards change in land use in the Gulf Center region of Veracruz , Mexico, 23(1), 47–56.
- Lavelle, P. (1998). Earthworms and the soil system. *Biol Fertil Soils*, 6, 237–251.
- Lourencetti, C., Demarchi, M., & Ribeiro, M. (2008). Determination of sugar cane herbicides in soil and soil treated with sugar cane vinasse by solid-phase extraction and HPLC-UV. *Talanta*, 77(2), 701–709. <https://doi.org/10.1016/j.talanta.2008.07.013>
- Mahmood, H. S., Hoogmoed, W. B., & van Henten, E. J. (2012). Sensor data fusion to predict multiple soil properties. *Precision Agriculture*, 13(6), 628–645. <https://doi.org/10.1007/s11119-012-9280-7>
- Margesin, R., Zimmerbauer, A., & Schinner, F. (2000). Monitoring of bioremediation by soil biological activities, 40(April 1999), 339–346.
- Mengel, D. B. (1993). Fundamentals of soil cation exchange capacity (CEC). *Agronomy Guide AY-238. Cooperative Extension Service, Purdue University*.
- Mills, S. A., & Frankenberger, W. T. (1994). Evaluation of phosphorus sources promoting bioremediation of diesel fuel in soil., 53, 280–284.
- Moreno-Seceña, J. C. (2010). *Evaluación del manejo del nitrógeno en el agroecosistema caña de azúcar*.
- N.C., B. (1990). The nature and properties fo soil. Macmillan Publishing Corpotation.
- Nkoa, R. (2014). Agricultural benefits and environmental risks of soil fertilization with anaerobic digestates: A review. *Agronomy for Sustainable Development*, 34(2), 473–492. <https://doi.org/10.1007/s13593-013-0196-z>
- Nocita, M., Stevens, A., Noon, C., & Van Wesemael, B. (2013). Prediction of soil organic carbon for different levels of soil moisture using Vis-NIR spectroscopy. *Geoderma*, 199, 37–42. <https://doi.org/10.1016/j.geoderma.2012.07.020>
- Nourouzi, M. M., Chuah, T. G., Choong, T. S. Y., & Rabiei, F. (2012). Modeling biodegradation and kinetics of glyphosate by artificial neural network.

Journal of Environmental Science and Health. Part. B, Pesticides, Food Contaminants, and Agricultural Wastes, 47(5), 455–465.
<https://doi.org/10.1080/03601234.2012.663603>



- Olivares, M., Hernández, A., Vences, C., Jáquez, J., & Ojeda, D. (2012). Lombricomposta y composta de estiércol de ganado vacuno lechero como fertilizantes y mejoradores de suelo. *Universidad y Ciencia*, 28(1), 27–37. Retrieved from http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S0186-29792012000100003&lng=es&nrm=iso&tlng=es
- Onet, A. (2014). Study of the correlations between soil physical, chemical properties and the number of microorganisms in oak forest soil, *XXIII(2004)*, 689–694.
- Palma-lópez, D. J., García, S. S., Olán, J. J. O., Narcía, A. T., Espinoza, C. L., Cruz, J. Z., ... Martel, M. A. C. (2002). SISTEMA INTEGRADO PARA RECOMENDAR DOSIS DE FERTILIZACION EN CAÑA DE AZUCAR (SIRDf). *Terra Latinoamericana*, 20, 347–358.
- Paz González, A., Taboada Castro, M. T., & Gómez Suárez, M. J. (1997). Relación entre textura, pH, materia orgánica y complejo de cambio en el horizonte superior de un suelo sobre serpentinas. *Caderno Lab. Xeolóxico de Laxe*, 22, 5–14.
- Raj, K. R., Kardam, A., Arora, J. K., & Srivastava, S. (2009). Artificial Neural Network (ANN) design for Hg–Se interactions and their effect on reduction of Hg uptake by radish plant. *Journal of Radioanalytical and Nuclear Chemistry*, 283(3), 797–801. <https://doi.org/10.1007/s10967-009-0415-x>
- Ramadan, M. A., El-Tayeb, O. M., & Alexander, M. (1990). Inoculum size as a factor limiting success of inoculation for biodegradation. *Appl. Environ. Microbiol.*, 56, 1392–1396.
- Ramos, E., & Zúñiga, D. (2008). Efecto de la humedad, temperatura y pH del suelo en la actividad microbiana a nivel del laboratorio. *Ecología Aplicada. Departamento Académico de Biología. Universidad Nacional Agraria La Molina.*, 7, 123–130.
- Regelink, I. C., Stoof, C. R., Rousseva, S., Weng, L., Lair, G. J., Kram, P., ... Comans, R. N. J. (2015). Linkages between aggregate formation, porosity and soil chemical properties. *Geoderma*, 247–248, 24–37. <https://doi.org/10.1016/j.geoderma.2015.01.022>
- Rodríguez, I., Pineda, E. ., Fernández, I. ., Marresa, M. ., Gil, Y. ., Rodríguez, L. ., ... Hernández, N. (2007). El cultivo de la caña de azúcar y su influencia sobre algunas propiedades químicas y el rendimiento agrícola de un suelo Pardo sialítico bajo diferentes regímenes de fertilización, (ISBN 1021-6527).
- Ruiz-Ramírez, J. (2009). Eficiencia relativa y calidad de los experimentos de fertilización en el cultivo de caña de azúcar. *Terra*, 28, 149–154.

- Salazar, M., & Sanchez, M. A. (2000). Guía para el muestreo de suelos en caña de azúcar.
- SEMARNAT. (2002a). Capítulo 3. Suelos.
- SEMARNAT. (2002b). Norma Oficial Mexicana NOM-021-SEMARNAT-2000 que establece las especificaciones fertilidad, salinidad y clasificación de suelos, estudio, muestreo y análisis.
- SEMARNAT. (2014). Degradación de suelos en México. Retrieved from https://apps1.semarnat.gob.mx:445/dgeia/informe_resumen14/03_suelos/3_2.html
- Semple, T., & Reid, J. (2001). Impact of composting strategies on the treatment of soils contaminated with organic pollutants.
- Serrano, J. M., Peça, J. O., Marques da Silva, J. R., & Shaidian, S. (2010). Mapping soil and pasture variability with an electromagnetic induction sensor. *Computers and Electronics in Agriculture*, 73(1), 7–16. <https://doi.org/10.1016/j.compag.2010.03.008>
- Singh, B. K., Walker, A., Denis, J., & Wright, D. J. (2006). Bioremedial potential of fenamiphos and chlorpyrifos degrading isolates: influence of different environmental conditions. *Soil Biol Biochem*, 38, 2682–2693.
- Sophocleous, M., & Atkinson, J. K. (2015). A novel thick-film electrical conductivity sensor suitable for liquid and soil conductivity measurements. *Sensors and Actuators B: Chemical*, 213, 417–422. <https://doi.org/10.1016/j.snb.2015.02.110>
- Zérega, & Hernández. (2005). Caracterización agroecológica de siete localidades con producción de caña de azúcar (*saccharum sp.*) en el estado de Yaracuy.
- Zhao, Z., Chow, T. L., Rees, H. W., Yang, Q., Xing, Z., & Meng, F. R. (2009). Predict soil texture distributions using an artificial neural network model. *Computers and Electronics in Agriculture*, 65(1), 36–48. <https://doi.org/10.1016/j.compag.2008.07.008>

ANEXOS

Article

Intelligent Spectroscopy System Used for Physicochemical Variables Estimation in Sugar Cane Soils

Ofelia Landeta-Escamilla ¹, Oscar Sandoval-Gonzalez ¹, Albino Martínez-Sibaja ^{1,*},
José de Jesús Agustín Flores-Cuautle ² , Rubén Posada-Gómez ¹ and
Alejandro Alvarado-Lassman ¹ 

¹ Tecnológico Nacional de Mexico/I.T.Orizaba, Orizaba, VZ 94320, Mexico; of_elia@hotmail.com (O.L.-E.); o.sandovalgonzalez@gmail.com (O.S.-G.); pgruben@yahoo.com (R.P.-G.); lassman@prodigy.net.mx (A.A.-L.)

² CONACYT-Tecnológico Nacional de Mexico/I.T.Orizaba, Orizaba, VZ 94320, Mexico; jflores_cuautle@hotmail.com

* Correspondence: cei.depi.ito@gmail.com; Tel.: +52-272-7033-425

Received: 27 October 2018; Accepted: 27 December 2018; Published: 10 January 2019



Abstract: The current condition of soils is a major area of interest due to the lack of certainty in their physicochemical properties, which can guarantee the quality and the production of a specific crop. Additionally, methodologies to improve land management must be implemented in order to address the consequences of many environmental issues. To date, many techniques have been implemented to improve the accuracy—and more recently the speed—of analysis, in order to obtain results while in the field. Among those, Near Infrared (NIR) spectroscopy has been widely used to achieve the objectives mentioned above. Nevertheless, it requires particular knowledge, and the cost might be high for farmers who own the fields and crops. Thus, the present work uses a system that implements capacitance spectroscopy plus artificial intelligence algorithms to estimate the physicochemical variables of soil used to grow sugar cane. The device uses the frequency response of the soil to determine its magnitude and phase values, which are used by artificial intelligence algorithms that are capable of estimating the soil properties. The obtained results show errors below 8% in the estimation of the variables compared to the analysis results of the soil in laboratories. Additionally, it is a portable system, with low cost, that is easy to use and could be implemented to test other types of soils after evaluating the necessary algorithms or proposing alternatives to restore soil properties.

Keywords: psychochemical prediction; frequency response of soil; FPGA-based

1. Introduction

A global issue to attend due to its relevancy is soil degradation: firstly, because it is a natural resource that is formed and regenerated slowly, is not renewable, and is very fragile in its degradation [1]. Therefore, it is one of the most vulnerable natural resources, because it is not possible to take actions to avoid or mitigate the adverse impacts that are produced by environmental detriment [2]. Soil plays a crucial role in the functioning of ecosystems [3] due to the impact on agronomics and food security [4], by decreasing its current and potential capability to produce goods and services. Land management is far from being sustainable; there has been an inadequate operation of soils in the conventional production systems [5]. For example, the excessive use of fertilizers has led to nitrogen depositions affecting not only surface and underground water, but also soils with acidification, because an incorrect application of modern agrotechnologies [6] generates unstable ecosystems, which in turn creates an external dependence on energy and materials for their continuity in time [7]. In turn, this increases the number of limiting factors in the production systems in relation

to the nutrients and water, interfering in the biogeochemical cycles [8]. In contrast, there are also places where the lack of fertilizers is degrading soils and decreasing yield, which is important because they also help with carbon fixation to mitigate climate change. Hence, it is necessary to monitor the health of soils [9] to determine their current status, and also to monitor nutrient levels in order to apply sustainable land management practices.

There are many approaches to determine the level of soil degradation. Some of them treat the problem as a single one instead of a complex process, integrating variables such as: vegetation growth, the flow of water, infiltration, land use, and land management. Furthermore, some variables could be partially hidden by management practices, the use of fertilizers [10], and land resilience [11]. Some others analyzed information from global datasets, which may mask local changes; it is important to remember that most relationships are based on local studies, and should not be used to infer global conclusions.

A more detailed physicochemical analysis by methodologies carried out at laboratories requires glassware, apparatus, chemicals, and trained personnel. Although these methodologies have been validated, in order to assure quality control, it is necessary to have controlled samples to evaluate method precision and uncertainty. That makes the access difficult for farmers, as not all of the samples that are taken are representative of the real condition of soils, and some locations are impossible to access.

Thus, investigations have been carried out in order to obtain correct results in the field with the use of different sensors and technology, reducing the time and cost of the regular analysis. Sensors operate by measuring physical or chemical properties via transducers, while another technology has focused on linking sensors with artificial intelligence or satellite images to infer the soils' situation in general.

Methods to determine chemical properties include: (1) electrical/electromagnetic sensors to obtain organic matter (OM) or total carbon content, salinity, cation exchange capacity (CEC), and residual nitrate or total nitrogen content; (2) optical and radiometric sensors to determine OM or organic carbon (OC), pH, CEC, residual nitrogen or total nitrogen content; and (3) electrochemical to determine salinity, pH, residual nitrate or total nitrogen content, and other macronutrients [12]. The property used in electrical and electromagnetic sensors is the electrical conductivity (ECa). Accordingly, ECa data electromagnetic interference sensors (EMI) can be linked to a global positioning system (GPS). The literature reports contain soil properties and pasture yield results collected over four years, finding significant variations in macronutrients (50–110%) with 20% to 26% of the variability in OM and clay content and stability (less than 10%) for pH and ECa throughout the area evaluated. Significant correlations have been found between ECa, altitude, and pH; correlations between ECa, grasses, yield, and other species were also found. Despite the correlations already reported in the literature, there is still a controversy. While Serrano et al. [13] concluded that no correlation was found, Kweon et al. determined an excellent correlation when a second chemical variable (CEC) is included; this highlights the importance of using a matrix of variables to achieve reliable results.

Another pathway that has been implemented to determine chemical properties is optics, where spectroscopy is used due to its sensitivity [14]. Methods relay the comparison of the incident and reflected light spectra on soils, using the amplitude and phase of signals [15]. This technique has been implemented in several studies to determine many variables; such as moisture, OM, pH, EC, CEC, TC, ammonium, nitrogen, nitrates, total nitrogen (TN), available phosphorus, and phosphorus absorptive coefficient (PAC), where 12 spectroscopic models were developed and the correlations that were obtained were in the range of 0.45 to 0.93 [16].

Spectroscopy has been used along with a wireless sensors network (WSN) for improving the measurements' precision, monitoring variables such as irrigation, fertilization, pesticide control, and animals in large areas [17]. All of those variables are being monitored using the normalized soil moisture index (NMSI) obtained from reflectance values and exploratory analysis of the raw spectra by using an artificial intelligence tool, the principal component analyses (PCA) [18]. On the other hand,

an impedance spectroscopic sensor is capable of measuring multiple frequencies to determine soil moisture and ionic content, and has a built-in self-calibration system. An advantage of these systems is the capability of calibrating the system response to different soil types. Furthermore, their main disadvantage is the presence of noise, which results in decreased accuracy. Results report having a 10% error range for real and imaginary impedance and 12% for soil saline water content measure, which enables mixed models to determine specific ions such as nitrates, sulfates, and phosphates.

From previous lines, it stands out that grouping technologies promises to be a suitable solution to determine the level of degradation in soils accurately, and thus propose local solutions based on the causes found at the specific locations. Additionally, the relationship between poverty and the percentage of land degradation is also a separate issue, because it highlights the need to propose new low-cost technology in order to determine the needs at these places and promote sustainable land management practices. Therefore, a sensor that is capable of determining physicochemical properties through artificial intelligence techniques could create a low-cost and easy to implement technology. If farmers could operate it, such a sensor would create technology that can know the current state of soils and enable the implementation of restoration strategies.

2. Materials and Methods

2.1. Soil Sampling

The region of so-called high mountains in Veracruz, Mexico is formed by 57 municipalities with an approximate area of 6053 km². The 0.5% of the total surface is planted by sugar cane; the studied soil can be classified as anthrosols (AT) according to World Soil Resources [19]. Therefore, an essential point to develop the presented system is the sampling of soils with sugar cane production made in high mountain regions. One hundred soil samples along this mentioned area were obtained, and the sampling procedure implemented to obtain the soil samples was the one described in the standard SESDPROC-300-R3 [20]. Specifically, the obtained soil samples were collected at the municipalities of Atoyac (18°55'00" N 96°46'00" O), Camaron de Tejada (19°01'00" N 96°37'00" O), Carrillo Puerto (18°47'00" N 96°34'00" O), Coetzala (18°47'00" N 96°55'00" O), Ixtaczoquitlan (18°51'46" N 97°03'44" O), Cordoba (18°51'18.3" N 96°57'02.2" W), and El Naranjal (18°47'38.1" N 96°55'30.5" W), which are areas that traditionally cultivate sugarcane. All of the samples were subject to laboratory analysis to obtain the following physicochemical properties: pH, tampon pH, organic matter (OM), phosphorus (P), Potassium (K), Calcium (Ca), Magnesium (Mg), Sulfur (S), Boro (B), Copper (Cu), iron (Fe), Manganese (Mn), Zinc (Zn), Sodium (Na), conductivity, Nitrogen–Nitrate (N₂–NO₃), cation exchange capacity (CEC), cationic saturation (SC) for K, Ca, Mg, and Na, Hydrogen (H), K/Mg ratio, Ca/Mg ratio, texture (sand, lime, and clay), apparent density, field capacity 1/3 bar, and permanent wilting point, 15 Bar.

2.2. Physicochemical Analysis

Sample moisture and the OM to soil moisture ratio was determined by gravimetry [21]. The humidity was obtained by weighing the sample and heating it to 105 °C for 24 h until all of the water was lost at a constant weight. The difference between the wet and dry sample gives the moisture content.

The Walkley and Black method [22] was conducted with the aim of determining the amount of organic matter (OM) expressed regarding total organic carbon.

2.3. Chemical Composition

Atomic absorption spectrometry was used to determine the global composition of Na, K, Mg, and Ca in soils. The composites were digested in hot HCl and deionized distilled water solution (2:1 ratio); afterward, the solution was filtered and submitted for analysis.

2.4. Exchangeable Cations, Nitrogen, Phosphorous, and Sulfur

Exchangeable cations (CEC) were measured using silver thiourea, following the method described by Pleyser and Juo [23]. Total nitrogen was measured by the Kjeldhal method [24], phosphorous was measured by colorimetry [25], and sulfur was measured by turbidimetry [26]. Apparent density was measured by the method proposed by the United States Department of Agriculture (USDA) [27], pH was measured by the 1:1 method ASTM D4972-13 (ASTM 2013), and electrical conductivity (EC) was measured by the conductimetry method. The textural analysis was performed by the Bouyoucos method.

2.5. Measurement Principle

When an electrical isolating and homogeneous material is under the influence of an electrical field (E), each molecule forming the material is affected by the field, as shown in Figure 1. As a result, all of the molecules are subject to an electrical force, and an electric dipole is formed. Forces acting on the dipoles are named electric momentum (μ_i), whose value is proportional to the electrical charge (z) and the distance between electrodes (l):

$$\mu_i = z \times l \quad (1)$$

The electrical momentum forces the molecules to rotate; then, the dielectric displacement is expressed as:

$$D = \varepsilon \times E + P_i \quad (2)$$

where ε is the dielectric constant, and P_i is the induced material polarization for the i st molecule, the Clausius–Mossotti equation establishes:

$$P_i = \left(\frac{\varepsilon - 1}{\varepsilon + 2} \right) \frac{M}{\rho} = \frac{4}{3} \pi N \alpha \quad (3)$$

with M and ρ being the molecular weight and density, respectively, N being the Avogadro number, and α being the molecule polarizability. Thus, each molecule makes a different contribution with the reacting field:




Figure 1. Molecule polarization under the electric field influence (a) original state, (b) polarized.

Therefore, when the soil sample is placed in the middle of two parallel plates in a capacitor configuration, the sample behaves as the dielectric, and its response is directly affected by the contribution of the physicochemical properties of the soil. By applying a voltage (V) with controlled magnitude and frequency between both terminals of the capacitor, an electric field is established (E) through the sample. The excitation signal is a sinusoidal wave with frequencies ranging from 10 Hz to 100 KHz. The electric field is directly affected by the charge separation according to their electrical charge. The frequency response allows knowing the salt and mineral content, which presents

a resonance to a specific frequency. The differences in magnitude and phase between the input signal and the obtained one in the capacitor are the variables that are used to correlate the data to make an estimation of the physicochemical properties in soils.

2.6. Development of the System

The spectroscopy system to estimate the physicochemical variables in sugar cane soils is integrated by four sections: (a) the data signal processing spectroscopy module, (b) the capacitive sensor, (c) the controlled temperature camera, and (d) the artificial intelligence module.

The module of the data signal processing spectroscopy module was developed to obtain the frequency response in terms of the magnitude and phase of a soil sample. Figure 2 shows the configuration of the electric circuit. The sensor is part of a voltage divisor and acts as an resistor-capacitance (RC) filter, which is required to know the frequency response of the sensor. The excitation signal is generated by the control module. This control module is formed by an MyRIO platform (National Instruments, Austin, TX, USA) from National Instruments that contains an FPGA XILIX Zynq-7010 and a 667 MHz dual-cortex ARM Cortex-A9 processor, which was programmed to generate the excitation signal and at the same time acquire the frequency response in magnitude and phase from the sensor. At the end of the study, it is possible to obtain the behavior of the sensor in magnitude and phase throughout the band of frequencies. The following diagram represents a distinctive pattern which allows the algorithms of artificial intelligence to estimate and quantify the content of the physicochemical variables.

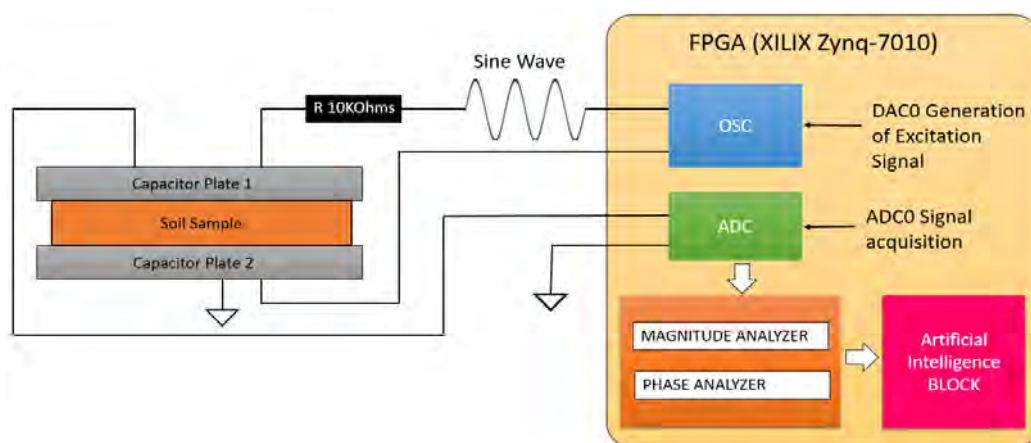


Figure 2. General diagram of the functioning of the capacitive sensor using the spectroscopy technique.

The Field-programmable gate array (FPGA) generates a sine wave using a table of 2048 values. The variation of the frequency of the signal is obtained through a precise delay timer, which is executed in each one of the values of the table during the generation of the sine wave. This sine wave signal is passed through the digital/analog converter (DAC), which is connected to a 10 KOhms resistor. This resistor is connected in series with a capacitor plate 1, creating an RC circuit. The voltage output of the capacitor is acquired using an analog/digital converter (ADC), and the FPGA computes the frequency response of the sensor in real time. Figure 2 shows the general diagram of the functioning of the capacitive sensor. Equations (4) and (5) show the gain and phase computing, where V_{out} is the Voltage of the capacitor, and V_{in} is the sine wave generated by the FPGA. The T_{delay} is the delay in seconds of the voltage of the capacitor with respect to the input voltage (sine wave), and T_{signal} is the elapsed time of one cycle.

$$Gain \text{ dB} = 20 \log_{10} \frac{V_{out}}{V_{in}} \quad (4)$$

$$Phase = \Phi = \frac{360^\circ \cdot T_{delay}}{T_{signal}} \quad (5)$$

A graphical user interface (GUI) was designed and programmed in LabVIEW, which is connected to the FPGA and the artificial intelligence block, as it is shown in Figure 3. The frequency response of the sensor is plotted, separating the magnitude and phase values. The results are submitted to the artificial intelligence block in Python via TCP/IP. The artificial intelligence block computes different algorithms, sending the result back to the PC to be visualized in the GUI.

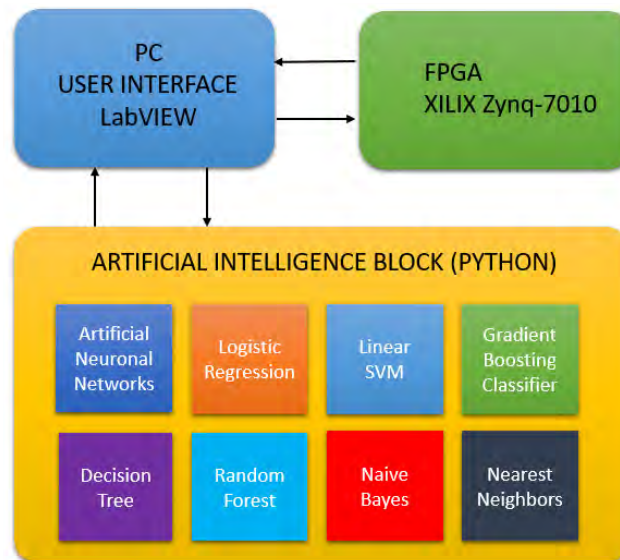


Figure 3. Integration of the personal computer (PC) graphical user interface (GUI) with the FPGA and the artificial intelligence block.

Figure 4 shows the user interface functioning. The excitation signal can be observed in white, and the response signal can be observed in red. The changes in the magnitude and phase of the signal can be appreciated when the frequency changes.

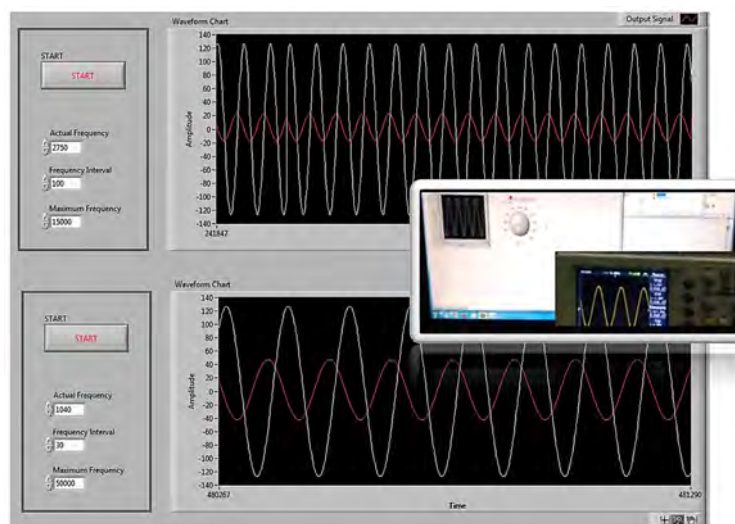


Figure 4. Tests of the functioning of the system in real time.

In the derived equation, a constant temperature is assumed, but physicochemical properties can be affected by the temperature. Therefore, a chamber of controlled temperature was necessary, due to the temperature generating deviations in the magnitude and phase graphics of the signal. To achieve the above, a temperature sensor (LM35) was used to monitor and control the temperature in the measuring chamber; this sensor with an incandescent filament generates thermic radiation inside the

camera. The voltage supplied to the filament was generated by an electronic dimmer. This dimmer requires a control voltage, which is supplied by the FPGA. The programmed Proportional Integrative Derivative (PID) temperature control, inside the FPGA, has an established set point at 30 °C as the reference point of the controller. The temperature was chosen because this is the average temperature at the locations with sugar cane crops. Figure 5 schematically shows the integration of the FPGA, the power electronics, and the controlled temperature chamber.

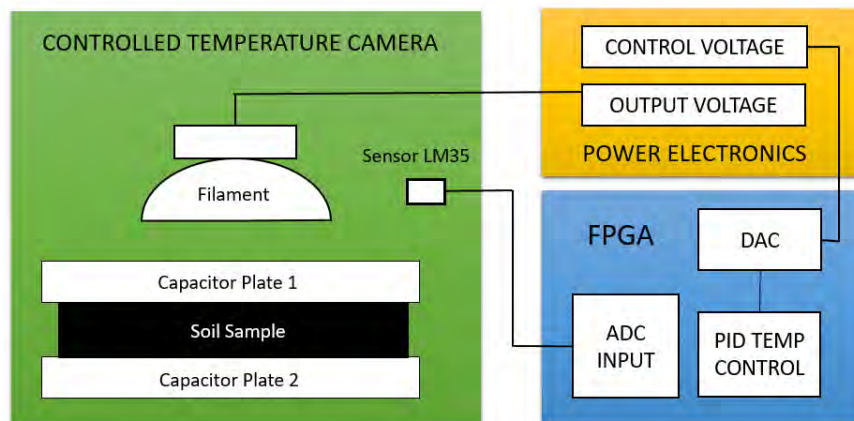


Figure 5. Integration of the controlled temperature camera.

Figure 6 shows a picture of the real experimental setup, with a sample placed inside the controlled temperature chamber, and the PID control running to reach the objective of 30 °C inside the chamber.




Figure 6. PID control of the controlled temperature camera.

2.7. Sample Measurement

The experimental measurement is performed as follows. The soil sample is placed in the measurement module, filling all of the empty space between sensor electrodes. A one V_{pp} sinusoidal wave was applied to the sample as an excitation signal. A frequency sweep was performed from 1 kHz to 100 kHz upward and downward. All of the frequencies were logarithmically spaced, and the amplitude and phase of the sensor signal were recorded. For testing the reliability of the sensor measurement, each sample was divided in eight sub-samples; all were submitted separately to the analysis, and the error measurement was calculated.

2.8. Artificial Intelligence for Determining Physicochemical Variables

The frequency response of the soil itself can neither determine nor quantify the physicochemical properties; thus, artificial intelligence (AI) analysis was implemented to the frequency response for determination of the physicochemical properties. Several artificial intelligence algorithms were applied

for determining the physicochemical properties of the soils from the results obtained by the capacitive sensor with spectroscopy.

Algorithms from the supervised learning class were used; in particular, Artificial Neural Networks, Logistic Regression, Linear Support Vector Machine (SVM), Gradient Boosting Classifier, Decision Tree, Random Forest, Naive Bayes, and Nearest Neighbors were selected. The reason for using more than one AI algorithm is for comparing the performance and the degree of recognition for each algorithm. The Scikit-learn library was used in Python to train, analyze, and compute all of the information acquired by the sensor in real time.

A subset of the samples was used for training the algorithms and the rest of the sub-samples for validation. For comparison purposes, the data of the training results, the results with the test data, and the time of training were obtained for each of the algorithms. A ratio of 70/30 is usually implemented to divide the training and validating data; this ratio is chosen due to it containing enough data to accomplish the analysis. Figure 7 indicates the procedure to determine the psychochemical properties of soil using artificial intelligence algorithms. The input data acquired by the sensor is sent via transfer control protocol/internet protocol (TCP/IP) to Python, in which the artificial intelligence block is programmed.

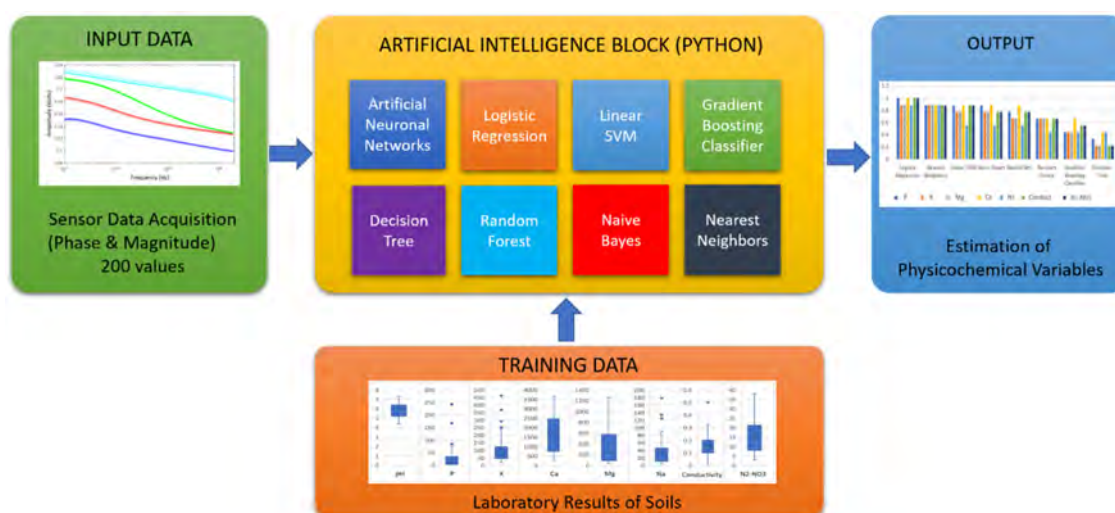


Figure 7. Determining psychochemical properties of soil using artificial intelligence (AI) algorithms and the sensor data.

The data from a total of 100 soil samples were used, which corresponded to the magnitude and phase data of the study of soils carried out by the capacitive sensor via spectroscopy. The input array used was an array of 200 elements (corresponding to the magnitude and frequency response of soil from 0 Hz to 100 kHz). The data used in the output, the ones with which the classifier was trained, were the physicochemical data obtained at the laboratory: pH, P, K, Ca, Mg, Na, Conductivity, and N₂-NO₃.

3. Results and Discussion

The results from the laboratory analysis served as a database used for training an AI block, as shown in Figure 8; in particular, this contained the pH, P, K, Ca, Mg, Na, conductivity, and N₂-NO₃ results from the analyzed soil samples.




Figure 8. Variables statistics of the 100 soil samples (pH, P, K, Ca, Mg, Na, conductivity, and N₂-NO₃).

3.1. Magnitude and Phase Results of the Frequency Response of the Sensor

The frequency response of four samples in amplitude (Figure 9) and phase (Figure 10) for the most different samples, according to the laboratory measurements, was obtained. Each sample was subdivided into eight sub-samples; the sub-samples are plotted using the same color as their corresponding soil sample. As can be seen from Figures 9 and 10, the frequency response behaves similarly with soils that have the same physicochemical conditions.




Figure 9. Magnitude results of the frequency response of the sensor of four soil samples and their sub-samples.




Figure 10. Phase results of the frequency response of the sensor of four soil samples and their sub-samples.

According to the analysis performed to the complete sample dataset, there is hysteresis when different sub-samples are measured; furthermore, the hysteresis takes different values. In the frequency range from 1 Hz to 1 KHz, the sensor presents an 8.3% difference, and from 1 KHz to 100 KHz, it presents a difference of 3.61%. The analysis of repeatability of the 100 soil samples computed a mean quadratic error of 4.96%, which means that the repeatability of the sensor is roughly 95%.

3.2. Sensor Response as a Function of Temperature

The evaluation of the behavior when there are temperature variations is also relevant. Therefore, to investigate the effects of temperature on the sample frequency scanning, the measurements were performed in the temperature range from 20 °C to 35 °C. Figures 11 and 12 show the results in these temperature variations of the frequency response of the sensor that contains a soil sample. The results indicate variations mainly in magnitude values, indicating that there is a proportional amplitude reduction of the signal when the temperature increases.




Figure 11. Magnitude results of the sensor response as a function of temperature.




Figure 12. Phase results of the sensor response as a function of temperature.

A group of eight soil samples was used to validate the frequency response of the sensor when there is a variation in temperature. For each soil sample, the temperature was set in the range from 25 °C to 35 °C in steps of 2.5 °C. As Figures 13 and 14 show, the amplitude is reduced proportionally to the increment of temperature. The eight soil samples were clustered by a specific color, and each cluster contained the information of the frequency response in different temperatures. In all of the cases, the maximum amplitude of the frequency response of the sensor corresponded to the minimum temperature.




Figure 13. Amplitude frequency response as a function of the temperature for eight samples.




Figure 14. Phase frequency response as a function of the temperature for eight samples.

3.3. Artificial Intelligence Analysis

As the first step in the signal analysis, the Pearson correlation coefficient was obtained for the different physiochemical properties with respect to five frequency intervals in amplitude and

phase. The frequencies ranges were selected by decades. Results from the calculated correlation coefficient show a direct relationship between the physicochemical properties of soils with respect to the magnitude and phase of the sensor. From Figures 15 and 16, the correlation of the pH, P, K, Ca, Mn, Na, conductivity, and N₂-NO₃ with respect to the magnitude and phase of the frequency response of the sensor is shown. The results of magnitude and phase for the frequency response of the sensor of the 100 soil samples were clustered in 10 groups: five groups for amplitude, and five for phase.




Figure 15. Pearson correlation coefficient of P, Ca, Mn, Na, conductivity, and N₂-NO₃ with respect to the amplitude in the range of frequencies of 10 Hz, 100 Hz, 1 kHz, 10 kHz, and 50 kHz.




Figure 16. Pearson correlation coefficient of P, Ca, Mn, Na, conductivity, and N₂-NO₃ with respect to the phase in the range of frequencies of 10 Hz, 100 Hz, 1 kHz, 10 kHz, and 50 kHz.

The correlation coefficient results indicate a hierarchy pattern between magnitude and phase with respect to the physicochemical analysis of soil. It can be observed that the physicochemical variables (Na, Mn, K, Ca, P, pH, conductivity, and N-NO₃) have a hierarchy pattern that is different between

themselves with respect to the magnitude and phase components of the sensor. Therefore, each variable has a characteristic response in the determined magnitude and phase points of the sensor.

By using the frequency response of the soil, a complex set of information is generated. Despite there being differences in the amplitude or phase spectra when the temperature, moisture, or chemical content varies, the differences cannot give useful information regarding the soil state. Amplitude and phase spectra were subject to different AI algorithms, which were written to predict the chemical composition of the soil. The implementation of the AI algorithms was carried out to obtain the estimation of the physicochemical variables of sugar cane soil. Figure 17 shows a graphic with the training times of classification of the P, K, Mg, Ca, Na, conductivity, and N_2-NO_3 using the AI algorithms of Decision Tree, Gradient Boosting Classifier, Random Forest, Neuronal Networks, Naive Bayes, Linear SVM, Nearest Neighbors, and Logistic Regression. The results indicate that Logistic Regression and Nearest Neighbors were trained faster than the rest of the algorithms.




Figure 17. Training times (seconds) comparison among classifiers.

The 70% of the data were used to train the AI algorithms. Figure 18 shows the punctuation of the training process using pH, P, K, Ca, Mg, Na, conductivity, and N_2-NO_3 values for all of the AI algorithms that were implemented. It should be noted that the correlation coefficient of one was reached with the Logistic Regression, Random Forest, Gradient Boosting Classifier, and Decision Tree algorithms.




Figure 18. Train score.

In order to validate the efficiency of the trained algorithms, 30% of the missing data was used to test the trained algorithms. Figure 19 shows the score obtained from the classification process using the magnitude and phase variables of the study of spectroscopy and the physicochemical data of the laboratory for: pH, P, K, Ca, Mg, Na, conductivity, and N_2-NO_3 . Despite the Decision Tree reaching a correlation coefficient of one during the training process, this algorithm had the worst punctuation in the classification, whereas Logistic Regression and Nearest Neighbors obtained the highest scores.

Only the P, Ca, conductivity, and N₂-NO₃ obtained a correlation coefficient of one; for the rest of the physicochemical variables, the highest correlation value was 0.9.




Figure 19. Test score comparison for all of the classifiers.

Through all of the experiments that were developed, it was possible to confirm that the use of classifiers such as Logistic Regression, Nearest Neighbors, and Linear SVM were reliable algorithms for the recognition and estimation of the desired variables. The correlation coefficient reached by using Logistic Regression and Nearest Neighbors was more than 0.9. The obtained results from the AI algorithms could give a rough estimation of the physicochemical state of the soil under study. Considering the technique used in this work, the accuracy obtained is good enough for serving as an indicator of the soil state.

4. Conclusions

The development of a new system that is capable of estimating the phosphorus, potassium, magnesium, calcium, sodium, conductivity, and nitrogen–nitrate in soils by the implementation of low-frequency spectroscopy techniques and artificial intelligence was achieved. The obtained results indicate that the instrument presents repeatability, and the artificial intelligence algorithms such as Logistic Regression and Nearest Neighbor can obtain results with an accuracy above 90% in its recognition. This makes the instrument appropriate for obtaining an adequate estimation of some of the most relevant physicochemical properties in soils through a prompt, simple, and low-cost means. In this study, these algorithms were successfully implemented in an FPGA-based system, which served at the same time as the signal acquisition system. The system that has been presented here is a useful alternative for people with little technical experience who require an analysis of the soil to produce more or better sugar cane; furthermore, it could also be helpful to improve the decisions made for its restoration.

For future improvement of the proposed system, a cross-validation using more than one classifier could be implemented. In order to determine universal soil properties, further studies are needed using different soil samples. Even so, the presented results show the suitability of the proposed system as a soil physicochemical indicator.

Author Contributions: Conceptualization, A.M.-S. and O.S.-G.; Methodology, O.L.-E. and J.d.J.A.F.-C.; Software, O.S.-G. and R.P.-G.; Validation, A.M.-S., O.L.-E. and A.A.-L.; Formal Analysis, J.d.J.A.F.-C.; Investigation, O.S.-G. and O.L.-E.; Resources, A.M.-S. and R.P.-G.; Data Curation, J.d.J.A.F.-C. and A.A.-L.; Writing-Original Draft Preparation, O.S.-G. and J.d.J.A.F.-C.; Writing-Review & Editing, A.M.-S., O.L.-E., O.S.-G. and J.d.J.A.F.-C.; Visualization, R.P.-G.; Supervision, A.A.-L.; Project Administration, A.M.-S.; Funding Acquisition, A.M.-S.


Funding: This research was funded by Consejo Nacional de Ciencia y Tecnología (CONACYT), Sectoral fund of environmental, grant number 26282.

Conflicts of Interest: The authors declare no conflict of interest. The funder had no role in the design of the study; in the collection, analyses, or interpretation of data; in the writing of the manuscript, or in the decision to publish the results.

References

1. Ortiz Bernad, I.; Sanz García, J.; Dorado Valiño, M.; Villar Fernández, S. *Técnicas de Recuperación de Suelos Contaminados*; Universidad de Alcalá Dirección General de Universidades e Investigación: Madrid, Spain, 2007.
2. Robert, M. *Captura de Carbono en Los Suelos Para un Mejor Manejo de la Tierra*; Informes Sobre Recursos mundiales de Suelos 96 de la Organización de las Naciones Unidas Para la Agricultura y la Alimentación; ONU: New York, NY, USA, 2002; p. 83.
3. European Commission. *Thematic Strategy for Soil Protection 2006*; COM(2006)231 Final; European Commission: Brussels, Belgium, 2006.
4. USDA Natural Resources Conservation Service. Available online: <http://www.nrcs.usda.gov/wps/portal/nrcs/detail/soils/use> (accessed on 5 January 2019).
5. Hernández, A.J.; Pastor, J. La restauración en sistemas con suelos degradados: Estudio de casos en agroecosistemas mediterráneos y taludes de carretera. In *Contaminación de Suelos. Tecnologías Para su Recuperación*; CIEMAT: Madrid, Spain, 2008; pp. 545–564.
6. Altieri, M.; Hecht, S.; Liebman, M.; Magdoff, F.; Norgaard, R.; Sikor, T.O. *Agroecología: Bases científicas para una agricultura sustentable*; Nordan-Comunidad: Montevideo, Uruguay, 1999.
7. Glissman, S.R. *Agroecología. Procesos ecológicos en Agricultura Sostenible*; CATIE: Turrialba, Costa Rica, 2002.
8. Garrabou, S.R.; González de Molina, M. *La Reposición de la Fertilidad en los Sistemas Agrarios Tradicionales*; Icaria: Barcelona, Spain, 2010; p. 319.
9. FAO Soils Portal. Available online: <http://www.fao.org/soils-portal/soil-survey/clasificacion-de-suelos/sistemas-numericos/propiedades-quimicas/es/> (accessed on 5 January 2019).
10. Oldeman, L.R. *Impact of Soil Degradation: A Global Scenario*; ISRIC (International Soil Reference and Information Centre): Wageningen, The Netherlands, 2000.
11. Eckert, S.; Hüsler, F.; Liniger, H.; Hodel, E. Trend analysis of MODIS NDVI time series for detecting land degradation and regeneration in Mongolia. *J. Arid Environ.* **2015**, *113*, 16–28. [[CrossRef](#)]
12. Adamchuk, V.I.; Hummel, J.W.; Morgan, M.T.; Upadhyaya, S.K. On-the-go soil sensors for precision agriculture. *Comput. Electron. Agric.* **2004**, *44*, 71–91. [[CrossRef](#)]
13. Serrano, J.M.; Peça, J.O.; Marques da Silva, J.R.; Shaidian, S. Mapping soil and pasture variability with an electromagnetic induction sensor. *Comput. Electron. Agric.* **2010**, *73*, 7–16. [[CrossRef](#)]
14. Lasia, A. Electrochemical Impedance Spectroscopy and its Applications. *Mod. Asp. Electrochem.* **1999**, *32*, 143–248.
15. Pandey, G.; Kumar, R.; Weber, R.J. A Low RF-Band Impedance Spectroscopy Based Sensor for In Situ, Wireless Soil Sensing. *IEEE Sens. J.* **2014**, *14*, 1997–2005. [[CrossRef](#)]
16. Kodaira, M.; Shibusawa, S. Using a mobile real-time soil visible-near infrared sensor for high resolution soil property mapping. *Geoderma* **2013**, *199*, 64–79. [[CrossRef](#)]
17. Aqeel, U.R.; Abbasi, A.Z.; Islam, N.; Shaikh, Z.A. A review of wireless sensors and networks' applications in agriculture. *Comput. Stand. Interfaces* **2014**, *36*, 263–270. [[CrossRef](#)]
18. Nocita, M.; Stevens, A.; Noon, C.; Van Wesemael, B. Prediction of soil organic carbon for different levels of soil moisture using Vis-NIR spectroscopy. *Geoderma* **2013**, *199*, 37–42. [[CrossRef](#)]
19. FAO. *World Reference Base for Soil Resources, in International Soil Classification System for Naming Soils and Creating Legends for Soil Maps*; World Soil Resources Reports: Rome, Italy, 2015; p. 150.
20. USEPA (U.S. Environmental Protection Agency). *SESDPROC-300-R3 Soil Sampling*; U.S. Environmental Protection Agency Science and Ecosystem Support Division: Athens, Georgia, 2014.
21. Willits, C.O. Methods for Determination of Moisture-Oven Drying. *Anal. Chem.* **1951**, *23*, 1058–1062. [[CrossRef](#)]
22. Walkley, A.; Black, I.A. An Examination of the Degtjareff Method for Determining Soil Organic Matter and a Proposed Modification of the Chromic Acid Titration Method. *Soil Sci.* **1934**, *37*, 29–38. [[CrossRef](#)]
23. Pleysier, J.L.; Juo, A.S.R. A single-extraction method using silver-thiourea for measuring exchangeable cations and effective cec in soils with variable charges. *Soil Sci.* **1980**, *129*. [[CrossRef](#)]
24. Bremner, J.M. Determination of nitrogen in soil by the Kjeldahl method. *J. Agric. Sci.* **1960**, *55*, 11–33. [[CrossRef](#)]

25. Menon, R.G.; Chien, S.H. Soil testing for available phosphorus in soils where phosphate rock-based fertilizers are used. *Fertil. Res.* **1995**, *41*, 179–187. [[CrossRef](#)]
26. Rodrigues, A.L.; Molina, R.; Bendassolli, J.A.; Ochueza Trivelin, P.C. Organic sulfur oxidation to sulfate in soil Samples for total sulfur determination by turbidimetry. *Rev. Bras. Cienc. Solo* **2008**, *32*, 2547–2553.
27. USDA. *2014 Soil Survey Staff. Kellogg Soil Survey Laboratory Methods Manual*; Soil Survey Investigations Report No. 42; Version 5; Burt, R., Soil Survey Staff, Eds.; U.S. Department of Agriculture, Natural Resources Conservation Service: Washington, DC, USA, 2014.



© 2019 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0/>).

Investigation of Thermal Conductivity by Hot Ball Method and its Correlation with Soil Quality Index of Veracruz Sugarcane Soil

J. J. A. Flores Cuautle¹  · N. P. Arias²  · O. O. Sandoval González³  ·
A. Martínez Sibaja³  · O. Landeta Escamilla³ · A. Rivera Vargas⁴

Received: 26 July 2018 / Accepted: 10 November 2018
© Society for Sugar Research and Promotion 2018

Abstract Different samples of soil were collected in two sugarcane crops in the Veracruz Region at two different depths. A transient method called hot ball was used to analyze the thermal conductivity of sugarcane soils for analyzing the influence of thermal conductivity on the soil quality index. Thermal conductivity results indicated a low thermal conductivity ranging from 1.81×10^{-1} to $3.15 \times 10^{-1} \text{ Wm}^{-1} \text{ K}^{-1}$. Global chemical composition and organic matter content of the studied soils were presented. Physicochemical parameters were used to perform the soil quality index study. pH results were within the 5–5.5 range, whereas the textural analysis tended to the clayed soil. The soil quality index results suggest a very-low-quality soil. The thermal conductivity was also correlated with the soil quality index. The Pearson correlation coefficient of thermal conductivity against the moisture content showed a coefficient of $r = -0.414$ which indicated a close and inverse relationship between both parameters. The sampled results pointed out that the Pearson coefficient for thermal conductivity against nitrate

and phosphate was higher than the other chemical components, suggesting that the presence of fertilizer increased the thermal conductivity of the studied soil.

Keywords Physicochemical properties · Organic matter content · Anthrosols · Mineral content

Introduction

The knowledge of thermal parameters is essential for many applications. In the soil science, thermal properties serve as a critical parameter for environmental engineering and geothermal energy extraction (Barry-Macaulay et al. 2013). In agriculture, thermal properties determine the energy exchange between ground and the surrounding environment, controlling the microclimatological behavior which is essential for the germination and crop growth (Abu-Hamdeh 2003; Chanzy et al. 2012; Li et al. 2017).

Among several factors that are involved in the harvest, soil thermal properties, environment properties, and soil nutrients are the main factors for a successful harvest. As mentioned previously, soil thermal properties control the microclimatological behavior due to the heat absorption capacity, but it is affected by chemical compositions, water saturation, and soil density, among other factors associated with the soil properties (Zhang and Wang 2017). In this sense, the heat transport phenomena in the soil also vary according to several factors such as the deepness from the soil surface. Then, it is necessary to study soil thermal properties not only on its surface but also in the A Horizon until a 0.30-m deepness (Farouki 1981).

Soil thermal conductivity can affect the productivity of the crops; therefore, it is an important issue to be controlled in countries based on the agricultural economy. In Mexico,

Electronic supplementary material The online version of this article (<https://doi.org/10.1007/s12355-018-0682-3>) contains supplementary material, which is available to authorized users.

✉ J. J. A. Flores Cuautle
jflores_cuautle@hotmail.com

¹ CONACYT-Tecnológico Nacional de México/I.T. Orizaba, Oriente 9, Emiliano Zapata, 94320 Orizaba, Ver., Mexico

² Facultad de Ciencias e Ingeniería, Universidad de Boyacá, Sogamoso, Colombia

³ Tecnológico Nacional de México/I.T. Orizaba, Orizaba, Ver., Mexico

⁴ Departamento de Ingeniería Bioquímica, Escuela Nacional de Ciencias Biológicas del IPN, Mexico City, Mexico

the agriculture products exportation represents a 3.5% of GDP (World Bank 2017) income, with sugarcane being among one of the country's main crops. Even more, in the Veracruz region, there is approximately 284,000 Ha planted with sugarcane (Servicio de Informacion Agroalimentaria y Pesquera 2017) making it one of the two main crops that are essential for its local economy. Therefore, it is essential to try to find the thermal and chemical information that will be useful in the improvement in such a harvest.

In the past, several methods have been used for measuring soil thermal properties such as computational methods such as least squares finite element method, statistical–physical models, and experimental methods such as frequency domain response (FDR), spectral analysis (Abbas et al. 2011; Serrano et al. 2014; Kojima et al. 2016; Nie et al. 2017; Lopo et al. 2018), and impedance analysis (Usovicz et al. 2017). It is not possible to monitor the soil thermal conductivity in real time since both computational and experimental methods have the drawback of being expensive, expending a lot of computational time, and requiring a complex infrastructure. Additionally, the hot wire method has traditionally been used to monitor the thermal conductivity of soils (ASTM 2014); however, the hot wire is ideal for liquids. In the hot wire method, it is necessary to ensure a good thermal contact for this type of materials that can reach an accuracy of up to 1.5% only by using a wire of 12.7 microns. For porous materials—as in the case of soils, this method does not ensure the accuracy of the measurement since the porosity of the materials prevents an excellent thermal contact (Roder 1981). Also, the ASTM D5334-14 standard indicated that errors in these measurements came from (1) redistribution of water due to hydraulic gradients (gravity drainage for high degrees of saturation or surface evaporation); (2) redistribution of water due to thermal gradients resulting from heating of the needle probe; and (3) phase changes in water in specimens with temperatures $< 0\text{ }^{\circ}\text{C}$ or $> 100\text{ }^{\circ}\text{C}$ (ASTM 2014). In the case of the needle method, the precision is about 10% and 15% for soil samples. In the case of hot ball, the accuracy achieved is 3–5% with a maximum of 7% under the worst conditions (Kubičár et al. 2010). As a reliable experimental method, the hot ball (HB) method has proved to be a useful and straightforward method to determine the thermal conductivity of sand and rocks (Kubičár et al. 2010; Fidiriková and Kubičár 2012). Therefore, HB was used in this work to measure the thermal conductivity of sugarcane (*Saccharum* spp.) soil. Chemical composition, moisture content, apparent density, and organic matter among other soil properties were also obtained serving as the parameters for the physical soil quality index (SQI) calculation.

Materials and Methods

Study Area and Sampling

Composites were obtained from the so-called high mountain region at Veracruz, Mexico (1350 m above sea level), at Cordoba ($18^{\circ}51'18.3''\text{N}$ $96^{\circ}57'02.2''\text{W}$) and El Naranjal ($18^{\circ}47'38.1''\text{N}$ $96^{\circ}55'30.5''\text{W}$) (Fig. 1), which is an area traditionally occupied to cultivate sugarcane.

Between May and October, 90% of the total rain of the year falls in the studied area, with around 700 mm of water. The minimum average temperature in these regions is $20\text{ }^{\circ}\text{C}$ from April to October, and the maximum is around $35\text{ }^{\circ}\text{C}$. The management system currently used in the process of sugarcane cultivation has been 60–100 metric tons/Ha manure, 100 kg of P_2O_5 , 250 kg of K_2O and N variable depending on the amount of manure. In the absence of manure, it would be replaced by 100 kg of N. This fertilizer was traditionally applied two times a year—usually during the summer and autumn.

Each soil composite was composed of a mixture of six samples. A total of 30 sample points were used to construct five composites; those samples were collected from the mentioned region over two zones, each consisting of 200 m^2 area, by using a method described in USDA (2014). The samples were obtained by using a 50-mm-diameter drill designed explicitly to get cylindrical samples[®]. This device can get up to a 0.30-m-deep sample without mixing the soil layers. Of 30 samples, two superficial composites obtained at deepness between 0.00 and 0.10 m ($\text{C}_{1\text{S}}$, $\text{C}_{2\text{S}}$), two in deep composites 0.10–0.30 m deepness ($\text{C}_{1\text{D}}$, $\text{C}_{2\text{D}}$), and a fifth composite consisting of a mixture of both deepness (G) (USDA 2014) were created. Afterward, each composite was subdivided into three subsets and packaged without air, and a subset of each composite was used for carrying out each different test. A classification, according to the physical texture, was performed using the USDA recommendations (USDA 1999).

Thermal Conductivity

Thermal conductivity measurements were taken using the hot ball method; the HB is a transient-temperature method (Kubičár et al. 2010; Kouyaté et al. 2015) that is based on a metal sphere submerged in the interest sample and a heating step applied to a heater. The theoretical basis is described elsewhere (Kubičár et al. 2010) and can be expressed by:

$$T(t) = \frac{Q}{4\pi\kappa R} \left[1 - \exp\left(\frac{\alpha t}{R^2}\right) \operatorname{erfc}\left(\frac{\sqrt{\alpha t}}{R}\right) \right] \quad (1)$$

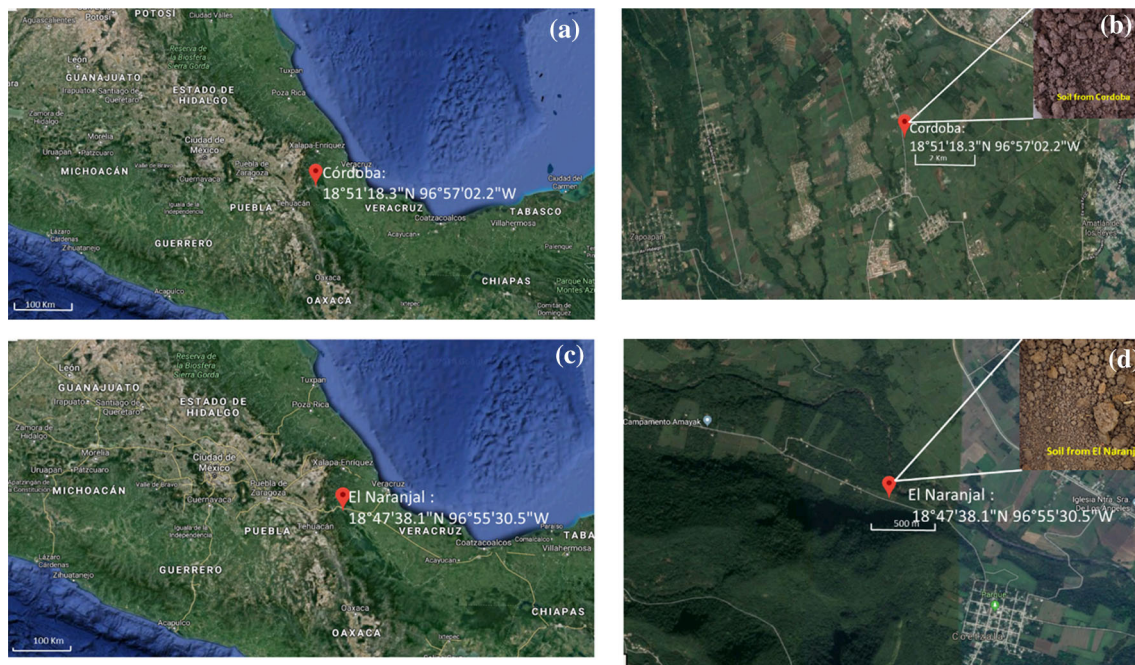


Fig. 1 Geographical localization of the study area. **a, b** Córdoba, scale 100 km and 2 km, respectively. Inset on **b** soil sample from Córdoba, **c, d** El Naranjal, scale 100 km, and 500 m, respectively. Inset on **d** soil sample of El Naranjal

with T being the temperature, t the time, κ and α the sample thermal conductivity and thermal diffusivity, respectively, Q the released heat, and $erfc(x)$ the complementary error function.

HB measurements require to warrant an excellent thermal contact between the sensor and the sample. Therefore, the samples were prepared by mechanical compaction of the composite around the HB sensor. All measurements were taken at $23 \text{ }^\circ\text{C} \pm 1 \text{ }^\circ\text{C}$, and once the sample was at the desired temperature, 5 mW of electric power was applied to the ball heater.

The measured ball temperature signals were fitted with Eq. 1, using thermal conductivity as a fitting parameter. Previously to the soil thermal conductivity measurement, the setup was calibrated with castor oil to ensure the right experimental conditions for the soil sample measurements.

Physicochemical Analysis

Sample Moisture and Organic Matter

Soil moisture was determined by gravimetric method (Willits 1951). The humidity was obtained by weighing the sample and heating it to $105 \text{ }^\circ\text{C}$ for 24 h until all water was lost at a constant weight. The difference between the wet and dry sample gave the moisture content.

The Walkley and Black method (WB method) (Walkley and Black 1934) was conducted with the aim of

determining the amount of organic matter (OM) expressed regarding total organic carbon.

Chemical Composition

Atomic absorption spectrometry was used to determine the global composition of Na, K, Mg, and Ca in soils. The composites were digested in hot HCl/deionized distilled water (DDW) solution (2:1 ratio) until the solution became clear. Afterward, the solution was filtered to remove silicon oxides that were present in the composites and were then submitted for analysis.

Exchangeable Cations, Nitrogen, Phosphorous, and Sulfur

Exchangeable cations (C.E.C) were measured by using silver thiourea, following the method described by Pleyser and Juo (1980). Total nitrogen of soils was measured by the Kjeldahl method (Bremner 1960), phosphorous by colorimetry (Menon and Chien 1995), and sulfur by turbidimetry (Rodrigues et al. 2008) standards.

Apparent Density, pH, Electrical Conductivity, and Textural Analysis

Apparent density was measured by the method proposed by USDA (2014), pH by 1:1 method ASTM D4972-13 (ASTM 2013), and electrical conductivity (E.C) by conductometric method (USDA 2014). The textural analysis

was performed using the Bouyoucos method (USDA 2014).

Soil Quality Index

The soil physical properties can help to calculate a spatial distribution of nutrients, and the so-called physical soil quality index (Rabbi et al. 2014), which is closely related to the soil water storage capacity and therefore to the amount of water necessary to maintain the nutrient diffusion and guarantee the crop production. The soil quality index was calculated based on Cantú et al.'s (2007) method.

The physicochemical parameters selected for this index calculation were pH, O.M, E.C, C.E.C, and apparent density. These parameters were selected because of their relationship with chemical, biological, and microbiological activity, stability, fertility, and crop potential of soils (Ewing and Singer 2012).

Each parameter was normalized by taking into account the following equation:

$$V_n = \frac{I_m - I_{\max}}{I_{\max} - I_{\min}} \quad (2)$$

where V_n : normalized physicochemical parameter, I_m : the value of the measured physicochemical parameter, and I_{\max} and I_{\min} : maxima and minima reference values, respectively, taken from the literature.

After that, the SQI using weighted additive method (Mukherjee and Lal 2014) was calculated based on the following equation Cantú et al. (2007):

$$SQI = \frac{\sum_{i=1}^n P_i * WF_i}{n} \quad (3)$$

where P_i : selected physicochemical soil parameter, WF_i : weigh factor associated with the selected physicochemical soil parameter and n : quantity of physicochemical parameters taken into account for SQI calculation, in this work $n = 5$.

Afterward, the soil was classified using the scale given in Table 1 Cantú et al. (2007).

Table 1 Classification of soil

SQI scale	Quality	Classification of soil
0.80–1.00	Very high	1
0.60–0.79	High	2
0.40–0.59	Moderate	3
0.20–0.39	Low	4
0.00–0.19	Very low	5

Results and Discussion

Thermal Conductivity

Thermal conductivity can be used to obtain information about moisture content as previously reported (Kubičár et al. 2010; Fidríková and Kubičár 2012). Figure 2 shows a representative plot of the HB signal for C1_s sample and the respective fitting result, and similar plots were obtained from the rest of the samples. As shown, the squares represent the experimental data and the solid line is the best fitting of the theoretical equation (Eq. 1) to the experimental data. Thermal conductivity (κ) was used as a fitting parameter. During the calculations, the ball radius (R) and released heat (Q) were maintained constant with values of 3 mm and 5 mW, respectively. Constant values were determined in advance by using samples with well-known thermal properties. Even though thermal diffusivity can be extracted from the same experimental data, the fitting uncertainty is more significant when Eq. 1 is used (Glorieux et al. 2011; Lara-Hernández et al. 2017); therefore, thermal diffusivity is not reported here.

Figure 3a shows the thermal conductivity for all measured composites as well as the moisture obtained from the standard method. Thermal conductivities obtained values agreed with those reports by Li et al. (2017) for soil samples at the same moisture range. From the Pearson correlation coefficient $r = -0.414$ (Fig. 3b), the thermal conductivity was inversely proportional to the moisture content. The previous fact was contrary as reported by the literature (Zhang and Wang 2017) even though the presence or lack of crop residue on the soil surface and the soil management affects their physical, hydraulic, and




Fig. 2 Representative plot of the HB signal behavior and the fitting result; the presented HB temperature signal is from C1_s sample; the solid line represents the best fit of Eq. 1 to the experimental data of this sample. In this plot, the error bar represents the error obtained from the different measurements taken on each sample

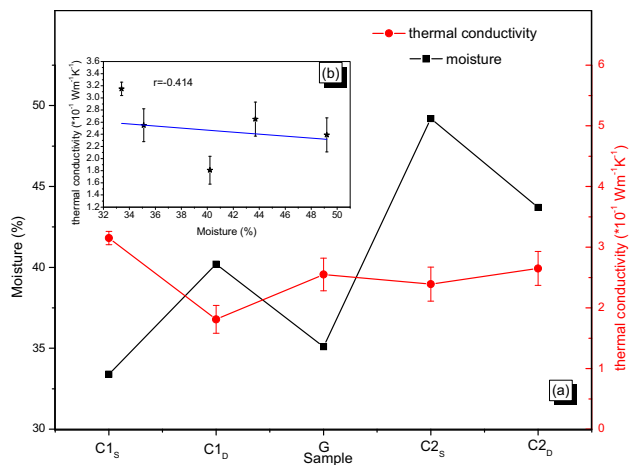


Fig. 3 **a** Thermal conductivity derived from HB and moisture content obtained by using the standard method for all composites. **b** The scattered plot of the thermal conductivity against moisture content; the error bars in the graph are due to the thermal conductivity measurements

consequently, thermal properties as it was reported for soils studied in Harste/Goettingen, Germany (Dec et al. 2009), and Trinidad and Tobago (Ekwue et al. 2015). Therefore, in the present study, other physicochemical parameters were also studied with the aim of understanding more in deep the tendency found for the thermal conductivity against moisture.

Physicochemical Analysis

Physicochemical parameters (see supplementary material) were obtained from the studied samples with the pH in the 5–5.5 range, indicating the existence of a moderate acid soil (Horneck et al. 2011). The apparent density was between 1.25 and 1.93 g/cm³, and the texture was mainly clayed soil (Table 2).

The results of apparent density indicate a possible reduction in soil aeration because this parameter was higher than the threshold range (Reynolds et al. 2003). The C.E.C was below 16 in all the composites studied indicating a restriction in soil mass transport, mainly cation diffusion type, affecting the nutrient uptake by the crops.

Figure 4 shows the organic matter content and the primary chemical components of the studied soils. This information, also with the physical properties, can be used as a global soil quality indicator of an agricultural field (Mukherjee and Lal 2014; Rabbi et al. 2014).

As shown in Fig. 4, C2s had the high P-PO₄³⁻, K, Mg, organic matter and N-NO₃⁻ content.

Table 3 shows the Pearson coefficient for moisture and thermal conductivity against the content of P-PO₄³⁻, K, Mg, organic matter and N-NO₃⁻ for the studied samples. As it is evident, there is a strong correlation between these chemical parameters with moisture (Table 3) indicating a direct ratio except for P-PO₄³⁻ with a negative Pearson coefficient.

The literature reports that the hydration energy evolved change serves as a function of the ion charge, the distance d between centers of the ion and the polar water molecule, and the dipole moment of water. Then, the difference in cationic radii between Mg²⁺ and K⁺ (79 pm and 133 pm, respectively) and also anionic radii between NO₃⁻ and PO₄³⁻ (165 pm, 238 pm, respectively) affects their hydration energy (– 1922 kJ/mol, – 321 kJ/mol, – 314 kJ/mol, and – 2765 kJ/mol, respectively) (Marcus 1991; Wulfsberg 2000). As a consequence, Mg²⁺ held together stronger water molecules than K⁺, then retained the moisture for the long term, so the Pearson coefficient for moisture against Mg was the higher. In the case of nitrate and phosphate, these anions tend to dissociate in water. As a result, they produce strong and weak acids that can alter the thermal conductivity behavior.

On the other hand, the thermal conductivity in the soil samples from the Veracruz Region can be studied as the thermal conductivity of an electrolyte solution that occupies the porous structure. In this sense, it can be expressed as the contribution of the thermal conductivity of the solvent (water), a contribution of thermal conductivity of individual species, and a contribution of interactions between pairs of species (Wang and Anderko 2012), and then, the contribution of all species can be taken into account. The results of the Pearson coefficient for thermal conductivity against nitrate and phosphate demonstrated that it was higher than the other ones, suggesting that the

Table 2 Textural properties of soils composites

	C1 _s	C1 _D	G	C2 _s	C2 _D
Sand	17	13	49	43	48
Silt	41	45	13	21	15
Clay	42	42	38	36	37
Texture	Silty clay	Silty clay	Clay Loam	Sandy Clay	Sandy Clay
Apparent density (g/cm ³)	1.27	1.25	1.93	1.37	1.39




Fig. 4 Mineral and organic matter content for the different samples

Table 3 Pearson’s correlation coefficient for mineral content versus moisture and thermal conductivity

Chemical parameter	<i>r</i>	
	Moisture	Thermal conductivity
P-PO ₄ ³⁻	- 0.23503	0.38838
K	0.82014	- 0.07405
Mg	0.90137	- 0.00833
O.M	0.64854	- 0.14495
N-NO ₃ ⁻	0.73785	0.10506

presence of fertilizer increases the thermal conductivity of the soil studied.

It was also found that the texture of the soil affected the thermal conductivity as it was reported by Abu-Hamdeh and Reeder (2000). The thermal conductivity values for the studied soil were in the range from 0.185 to 0.315 Wm⁻¹ K⁻¹, showing that these values are in close agreement with the reported results for clay loam soil (0.15–0.79

Wm⁻¹ K⁻¹) (Abu-Hamdeh and Reeder 2000). Thus, the reasons for the existence of the low thermal conductivity found in the Veracruz soil are supported by the presence of the high percentage of clay (Table 2) and the salt content (evidenced as the presence of Mg, K, phosphate, and nitrates) found in the samples.

Physicochemical Soil Quality Index

To obtain a better understanding of the thermal properties of soil from the Veracruz region, and its ratio with the physicochemical parameters described above, the soil quality index (SQI) was calculated (Table 4). The SQI with the physical properties can be used as a global soil quality indicator (Mukherjee and Lal 2014; Rabbi et al. 2014).

The results of SQI indicate the existence of soil with low quality according to the criteria indicated in Table 1. When analyzing the relationship between SQI and thermal conductivity (Fig. 5), it was found that a direct ratio between SQI index and thermal conductivity between 0.0 and 0.10 m deepness (samples C1_s and C1_D) and between 0.10 and 0.30 m deepness (samples C2_s and C2_D) existed. This finding can be useful to introduce the thermal conductivity parameter as an indicator of soil quality and can be used for monitoring a sugarcane soil quality.

Conclusions

The thermal conductivity of Veracruz sugarcane soil was obtained by using the so-called hot ball method. Such values agreed with the reported literature information found for this kind of soil and moisture content investigation. However, the correlation of thermal conductivity against moisture was inversely indicating that salt, density, and other physicochemical parameters affect the thermal behavior of soil. Through this work, it was found that

Table 4 Soil quality index (SQI) for Veracruz sugarcane soils

Parameter	Reference values		Weight factor (WF _i)	Soil sample				
	Maximum	Minimum		V _n × WF _i				
				C1 _s	C1 _D	G	C2 _s	C2 _D
pH	8.50	5.50	0.10	0.16	0.17	0.15	0.08	0.08
M.O (%)	5.00	0.50	0.30	0.25	0.25	0.27	0.32	0.25
E.C (dS/cm)	16.00	1.00	0.20	0.01	0.01	0.06	0.01	0.01
C.E.C (meq/100 g)	40.00	5.00	0.30	0.02	0.02	0.01	0.09	0.04
Apparent density (g/cm ³)	1.58	1.10	0.10	0.04	0.03	0.17	0.06	0.06
Soil quality index (SQI)	Average			0.10	0.10	0.13	0.11	0.09
	Type of soil			5	5	5	5	5

V_n calculated from Eq. 2 and SQI calculated from Eq. 3




Fig. 5 SQI–thermal conductivity ratio of Veracruz sugarcane soils

thermal conductivity values tend to have a thermally isolating behavior in the analyzed area. The HB method proved to be a reliable method to explore thermal conductivity in this type of samples.

Physical properties and mineral content were used in determining the soil quality index, indicating that this soil is classified as a very low quality which is a common problem for sugarcane soil. For future work, more parameters can be added to the SQI to serve as an effective method to predict a particular soil crop production.

Acknowledgements The authors thank SEMARNAT-CONACYT and Fondo de Ciencia, Tecnología e Innovación del Sistema General de Regalías, Fondo Nacional de Financiamiento para la Ciencia, la Tecnología y la Innovación “Francisco José de Caldas,” COL-CIENCIAS, Programa Colombia BIO, Gobernación de Boyacá thought FP44842-298-2018 contract and Vicerrectoría de Investigación, Ciencia y Tecnología-Universidad de Boyaca for the financial support and CENACAFE and F. Quevedo Garay for helping in the sample recollection.

Compliance with Ethical Standards

Conflict of interest The authors declare that they have no conflict of interest.

References

- Abbas, F., A. Fares, and S. Fares. 2011. Field calibrations of soil moisture sensors in a forested watershed. *Sensors* 11 (6): 6354–6369.
- Abu-Hamdeh, N.H. 2003. Thermal properties of soils as affected by density and water content. *Biosystem Engineering* 86 (1): 97–102.
- Abu-Hamdeh, N.H., and R.C. Reeder. 2000. Soil thermal conductivity effects of density, moisture, salt concentration, and organic matter. *Soil Science Society of America Journal* 64: 1285–1290.
- ASTM. 2014. D5334–14 Standard test method for determination of thermal conductivity of soil and soft rock by thermal needle probe procedure.

- Barry-Macaulay, D.A., A. Bouazza, R.M. Singh, B. Wang, and P.G. Ranjith. 2013. Thermal conductivity of soils and rocks from the Melbourne (Australia) region. *Engineering Geology* 164: 131–138.
- Bremner, J.M. 1960. Determination of nitrogen in soil by the Kjeldahl method. *Journal of Soil Science* 55: 11–33.
- Cantú, M.P., A. Becker, J.C. Bedano, and H.F. Schiavo. 2007. Evaluación de la calidad de suelos mediante el uso de indicadores e índices. *Ciencia Suelo (Argentina)* 25 (2): 173–178.
- Chanzy, A., J.C. Gaudu, and O. Marloi. 2012. Correcting the temperature influence on soil capacitance sensors using diurnal temperature and water content cycles. *Sensors* 12 (7): 9773–9790.
- Dec, D., J. Dörner, and R. Horn. 2009. Effect of soil management on their thermal properties. *Revista de la ciencia del suelo y nutrición vegetal* 9: 26–39.
- Ekwe, E., R.J. Stone, E.J. Peters, and S. Rampersad. 2015. Thermal conductivities of some agricultural soils in Trinidad as affected by density, water and peat content. *The West Indian Journal of Engineering* 38: 61–69.
- Ewing, S.A., and M.J. Singer. 2012. Soil quality. In *Handbook of soil sciences: resource management and environmental impacts*, 2nd ed, ed. P.M. Huang, Y. Li, and M.E. Sumner, 26. Boca Raton: CRC Press.
- Farouki, O.T. 1981. *Thermal properties of soils*. U.S. Army Corps of Engineers, Cold Regions Research and Engineering Laboratory.
- Fidričková, D., and E. Kubičár. 2012. The use of the Hot-Ball method for observing the transport of moisture in porous stones. *Slovak Journal of Civil Engineering* 20: 1–6.
- Glorieux, C., J. Hudec, J. Guarachi, K. Martinez, J.J.A. Flores Cuautle, L. Kubicar, V. Bohac, E. Marin, J.A. Calderon Arenas, S. Alvarado, H. Janssen, and W. Van De Walle. 2011. Round robin test between different heat transport techniques characterizing low thermal conductivity materials. In *33rd international thermal conductivity conference, Utah*.
- Horneck, D.A., D.M. Sullivan, J.S. Owen, and J.M. Hart. 2011. *Soil test interpretation guide*. EC1478 Technical report. Oregon Cooperative Extension.
- Kojima, Y., R. Shigeta, N. Miyamoto, Y. Shirahama, K. Nishioka, M. Mizoguchi, and Y. Kawahara. 2016. Low-cost soil moisture profile probe using thin-film capacitors and a capacitive touch sensor. *Sensors* 16 (8): 1292.
- Kouyaté, M., J.J.A. Flores-Cuautle, E. Slenders, J. Sermeus, B. Verstraeten, B.M.L. Garay Ramirez, E. San Martin Martinez, L. Kubicar, V. Vretenar, J. Hudec, and C. Glorieux. 2015. Study of Thermophysical properties of silver nanofluids by ISS-HD, Hot Ball and IPPE techniques. *International Journal of Thermophysics* 36 (10–11): 3211–3221.
- Kubičár, L.U., V. Vretenár, V. Štofánik, and V. Boháč. 2010. Hot-Ball method for measuring thermal conductivity. *International Journal of Thermophysics* 31 (10): 1904–1918.
- Lara-Hernández, G., J.J.A. Flores-Cuautle, C. Hernandez-Aguilar, E. Suaste-Gómez, and A. Cruz-Orea. 2017. Thermal properties of jojoba oil between 20°C and 45°C. *International Journal of Thermophysics* 38 (8): 1–9. <https://doi.org/10.1007/s10765-017-2252-4>.
- Li, B., W. Xu, and F. Tong. 2017. Measuring thermal conductivity of soils based on least squares finite element method. *International Journal of Heat and Mass Transfer* 115 (Part B): 833–841.
- Lopo, M., C.A. Teixeira dos Santos, R.N.M.J. Páscoa, A.R. Graça, and J.A. Lopes. 2018. Near-infrared spectroscopy as a tool for intensive mapping of vineyards soil. *Precision Agriculture* 19: 445–462.

- Marcus, Y. 1991. Thermodynamics of solvation of ions Part 5 Gibbs free energy of hydration at 298.15 K. *Journal of the Chemical Society Faraday Translation* 87: 2995–2999.
- Menon, R.G., and S.H. Chien. 1995. Soil testing for available phosphorus in soils where phosphate rock-based fertilizers are used. *Fertilizer Research* 41: 179–187.
- Mukherjee, A., and R. Lal. 2014. Comparison of soil quality index using three methods. *PLoS ONE* 9 (8): 1–15. <https://doi.org/10.1371/journal.pone.0105981>.
- Nie, P., T. Dong, Y. He, and F. Qu. 2017. Detection of soil nitrogen using near infrared sensors based on soil pretreatment and algorithms. *Sensors* 17 (5): 1–13. <https://doi.org/10.3390/s17051102>.
- Pleysier, J.L., and A.S.R. Juo. 1980. A single-extraction method using silver-thiourea for measuring exchangeable cations and effective CEC in soils with variable charges. *Soil Science* 129 (4): 205–211.
- Rabbi, S.M.F., B.R. Roy, M.M. Miah, M.S. Amin, and T. Khandakar. 2014. Spatial variability of physical soil quality Index of an agricultural field. *Applied and Environmental Soil Science* 2014: 1–10.
- Reynolds, W.D., X.M. Yang, C.F. Drury, T.Q. Zhang, and C.S. Tan. 2003. Effects of selected conditioners and tillage on the physical quality of a clay loam soil. *Canadian Journal of Soil Science* 83: 381–393.
- Roder, H.M. 1981. A transient hot wire thermal conductivity apparatus for fluids. *Journal of Research of the National Bureau of Standards* 86 (5): 457–493.
- Rodrigues, A.L., R. Molina, J.A. Bendassolli, and P.C. Ochueze Trivelin. 2008. Organic sulfur oxidation to sulfate in soil samples for total sulfur determination by turbidimetry. *Revista Brasileira do Ciencia do Solo* 32: 2547–2553.
- Serrano, J.S., S. Shahidian, and J.M. da Silva Shahidian. 2014. Spatial and temporal patterns of apparent electrical conductivity: DUALEM vs. Veris sensors for monitoring soil properties. *Sensors* 14 (6): 10024–10041.
- Servicio de Informacion Agroalimentaria y pesquera Mexico. 2017 <https://www.gob.mx/siap/articulos/cana-de-azucar-cierra-la-cosecha-2017-con-56-millones-de-toneladas?idiom=es>. Accessed 21 June 2018.
- USDA. 1999. *Soil quality kit guide*. Washington: U. S. A. Department.
- USDA. 2014. Soil Survey Staff. Kellogg soil survey laboratory methods manual. In *Soil Survey Investigations Report No. 42, Version 5.0.*, ed. R. Burt and Soil Survey Staff. U.S. Department of Agriculture, Natural Resources Conservation Service.
- Usovich, B., M.I. Lukowski, C. Rüdiger, J.P. Walker, and W. Marczewski. 2017. Thermal properties of soil in the Murrumbidgee River Catchment. *International Journal of Heat and Mass Transfer* 115: 604–614.
- Walkley A., Black, I. Armstrong. 1934. Examination of the degtjareff method for determining soil organic matter, and a proposed modification of the chromic acid titration method. *Soil Science* 37: 29–38.
- Wang, P., and A. Anderko. 2012. Modeling thermal conductivity of electrolyte mixtures in wide temperature and pressure ranges: seawater and its main components. *International Journal of Thermophysics* 33: 235–258.
- Willitis, C.O. 1951. Methods for determination of moisture-oven drying. *Analytical Chemistry* 23: 1058–1062.
- World Bank. 2017. Agricultura, valor agregado (%PIB). <https://datos.bancomundial.org/indicador/NV.AGR.TOTL.ZS>. Accessed 4 July 2018.
- Wulfsberg, G. 2000. *Inorganic chemistry*. USA: University Science Books.
- Zhang, N., and Z. Wang. 2017. Review of soil thermal conductivity and predictive model. *International Journal of Thermal Science* 117: 172–183.



ÍNDICE DE REVISTAS MEXICANAS

CONACYT DE DIVULGACIÓN CIENTÍFICA Y TECNOLÓGICA

Revista: AGROPRODUCTIVIDAD

Organismo responsable: Colegio de Postgraduados

Director Editorial: Jorge Cadena Iñiguez

Jefe Editorial: Jorge Cadena Iñiguez

Editor General: Said Infante Gil

Editor Adjunto: Fernando Carlos Gómez Merino

Consejo Editorial:

Ma. de Lourdes de la Isla
Dr. Ing. Agr. Catedrática Aereopolución

Ángel Lagunes Tejeda
Dr. Ing. Agr. Catedrático Entomología

Enrique Palacios Vélez
Dr. Ing. Agr. Catedrático Hidrociencias

Fernando Carlos Gómez Merino
Dr. Ing. Agr. Biotecnología

Fernando Clemente Sánchez
Dr. Ing. Agr. Fauna Silvestre

Luis Antonio Tarango Arámbula
Dr. Ing. Agr. Fauna Silvestre

Pedro Cadena Iñiguez
Dr. Ing. Agr. Transferencia de Tecnología

Victor Villalobos Arámbula
Dr. Ing. Agr. Biotecnología



ÍNDICE DE REVISTAS MEXICANAS

CONACYT DE DIVULGACIÓN CIENTÍFICA Y TECNOLÓGICA

Manuel David Sánchez Hermsillo
Dr. Ing. Agr. Nutrición Animal y manejo de
Pastizales

Manuel R. Villa Issa
Dr. Ing. Agr. Economía

Periodicidad: Mensual

Tiraje: 3,000

Circulación: Nacional

Distribución: Suscripciones

Vigencia: 2018


Portal: www.colpos.mx

Email: jocadena@colpos.mx, jocadena@gmail.com

Teléfonos: (595) 9284703

Dirección: Guerrero Núm. 9. Esquina Avenida Hidalgo, San Luis Huexotla, Texcoco, Estado de
México, México.

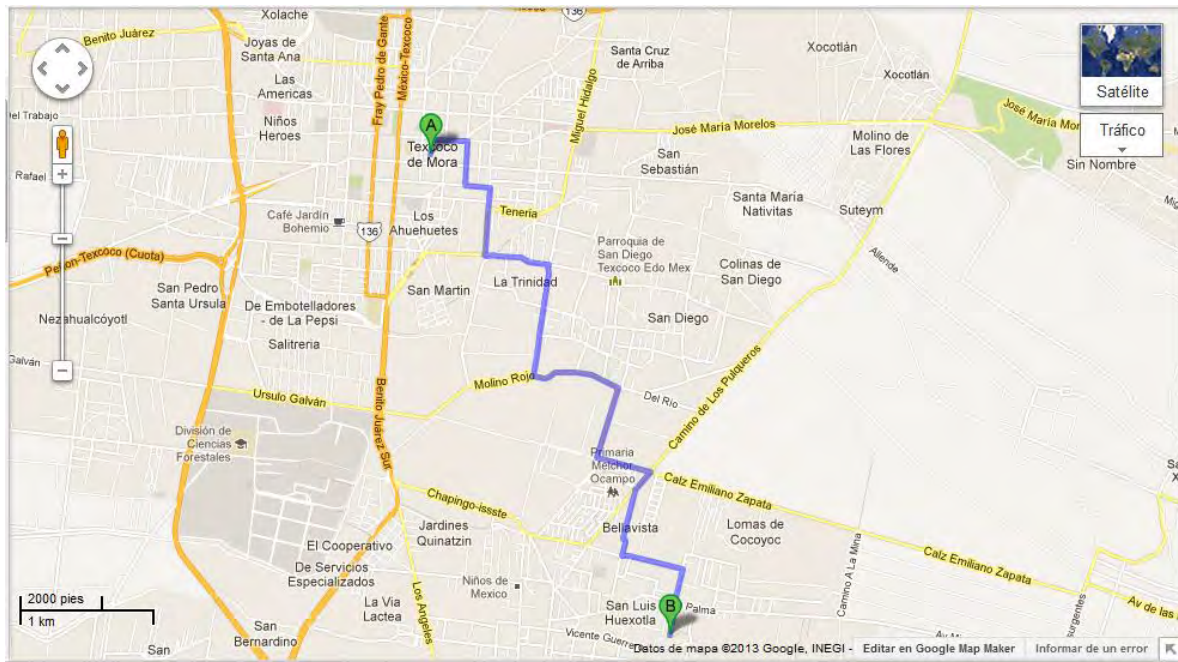
C.P: 56220



ÍNDICE DE REVISTAS MEXICANAS CONACYT DE DIVULGACIÓN CIENTÍFICA Y TECNOLÓGICA

Mapa de ubicación:

<http://goo.gl/maps/TnIU2>



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.¹; Sandoval-González, O.O.¹; Martínez-Sibaja A.^{1*}; Posada-Gómez R.¹; Alvarado-Lassman, A.¹; Quevedo-Garay, F.¹; Herrera-Aguilar, I.¹; 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, Lusnier *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



Figura 1. Sistema de adquisición de imágenes.

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 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.

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 3. Resultados de la Capacidad de Intercambio Catiónico (CIC).



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.

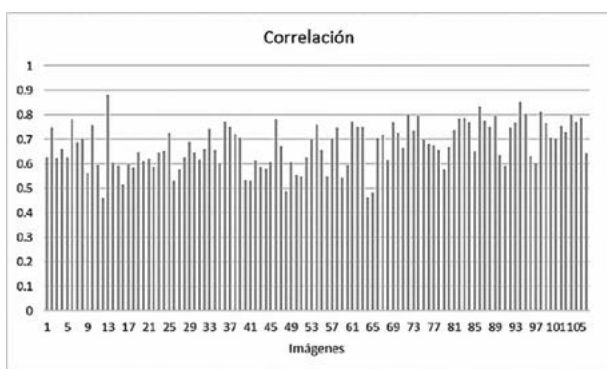


Figura 15. Resultado de la característica de correlación de las 105 imágenes procesadas




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

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.

Morisuka, 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>