



Universidad **Mariana**

Dispositivo inteligente para determinar porcentajes de macronutrientes presentes en el suelo para cultivos de papa a partir de pH, conductividad eléctrica y humedad.

Lida Yisely Cuastumal Tepud
Yerinson Ayendi Salazar Canacuan

Universidad Mariana
Facultad de Ingeniería
Programa Ingeniería Mecatrónica
San Juan de Pasto
2024

Dispositivo inteligente para determinar porcentajes de macronutrientes presentes en el suelo para cultivos de papa a partir de pH, conductividad eléctrica y humedad.

Lida Yisely Cuastumal Tepud
Yerinson Ayendi Salazar Canacuan

Informe de investigación para optar al título de: Proyecto De Grado

Ing. Carlos Patiño Teran Asesor
Ing. Fabio Camilo Gomez Co-asesor

Universidad Mariana
Facultad de Ingeniería
Programa Ingeniería Mecatrónica
San Juan de Pasto
2024

Artículo 71: los conceptos, afirmaciones y opiniones emitidos en el Trabajo de Grado son responsabilidad única y exclusiva del (los) Educando (s)

Reglamento de Investigaciones y Publicaciones, 2007
Universidad Mariana

Tabla de Contenido

Introducción	11
1. Resumen del proyecto	12
1.1. Descripción del problema	12
1.1.1. Formulación del problema	13
1.2. Justificación.....	14
1.3. Objetivos	15
1.3.1. Objetivo general.....	15
1.3.2. Objetivos específicos	15
1.4. Marco referencial o fundamentos teóricos	15
1.4.1. Antecedentes	15
1.4.1.1. Internacionales.. ..	18
1.4.2. Marco Teórico.....	20
1.4.2.1. Características del suelo	20
1.4.2.1.1. Propiedades del Suelo.	20
1.4.2.1.2. Macronutrientes (Nitrógeno, fósforo y potasio). . .	21
1.4.2.1.3. Desarrollo del producto de la papa.....	22
1.4.2.2. Tipos de sensores.	24
1.4.2.2.1. Sensor industrial CTW NPK.....	24
1.4.2.2.2. Sensor industrial temperatura, humedad, pH y conductividad eléctrica (CTW multiparámetros).	25
1.4.2.3. Modelos de Aprendizaje automático supervisado.....	28
1.4.2.3.1. Funciones de activación.	28
1.4.2.3.2. Técnicas por Clasificación... ..	29
1.4.2.3.3. Técnicas de prevención de sobreajuste.. ..	29
1.4.2.3.4. Arquitectura de Redes.. ..	30
1.4.2.3.5. Parámetros de evaluación.....	31
1.4.3. Marco conceptual.....	32
1.5. Metodología	33
1.5.1. Paradigma de investigación	33

1.5.2. Enfoque de investigación.....	33
1.5.3. Tipo de investigación.....	33
1.5.4. Población y muestra / Unidad de trabajo y unidad de análisis	33
1.5.5. Técnica e instrumentos de recolección de información.....	34
1.5.6. Descripción metodológica	34
2. Presentación de resultados	38
2.1. Análisis e interpretación de resultados.....	38
2.1.1. Análisis del primer objetivo.....	38
2.1.1.1. PH.....	39
2.1.1.2. Temperatura del suelo.. ..	39
2.1.1.3. Conductividad Eléctrica denominada (CE).....	40
2.1.1.4. Humedad.....	41
2.1.1.5. Nitrógeno.....	42
2.1.1.6. Fosforo.....	42
2.1.1.7. Potasio.....	43
2.1.2. Análisis del segundo objetivo	44
2.1.2.1. Entorno de hardware y software.....	44
2.1.2.2. Calibración del sensor (NPK).	45
2.1.2.3. Calibración sensor multiparámetros.....	50
2.1.2.4. Obtención de base de datos.. ..	53
2.1.2.5. Entrenamiento de algoritmo	55
2.1.2.5.1. Importar la base de datos.....	57
2.1.2.5.2. Preprocesamiento de datos.....	57
2.1.2.5.3. Normalizar los datos.....	58
2.1.2.5.4. Visualización de datos.....	58
2.1.2.5.5. Separar datos.	59
2.1.2.5.6. Diseñar configuración del modelo.	59
2.1.2.5.7. Evaluar modelo	62
2.1.2.6. Embeber en modelo.....	65
2.1.2.7. Diseño de placa electrónica.....	68

2.1.2.8. Diseñar y ensamblar dispositivo.	70
2.1.3. Análisis del tercer objetivo	70
2.1.3.1. Pruebas IN SITU..	70
2.2. Discusión.....	75
3. Conclusiones	76
4. Recomendaciones.....	79
Referencias bibliográficas	80
Anexos.....	83

Índice de Tablas

Tabla 1 Datasheet sensor NPK.....	25
Tabla 2 Datasheet sensor multiparámetros.....	26
Tabla 3 Valores ideales del suelo.	43
Tabla 4 Lecturas de prueba de sensor NPK.....	45
Tabla 5 Resultados de análisis de suelos.....	47
Tabla 6 Resultados de análisis de suelo.....	47
Tabla 8 Comparación de lectura de sensor NPK y análisis de suelos.....	49
Tabla 9 Pruebas de lectura en líquido y suelo.....	50
Tabla 10 Eliminar datos duplicados.....	57
Tabla 11 Evaluación de modelos.....	59
Tabla 12 Modelo que mejor se desempeña.....	63
Tabla 13 Resultados de matriz de confusión.....	64
Tabla 14 Métricas evaluadas a partir de matriz de confusión.....	64
Tabla 15 Datos de variables.....	66
Tabla 16 Datos de variables.....	67
Tabla 17 Resultados In- situ.....	72
Tabla 18 Métricas de respuesta.....	73

Índice de Figuras

Figura 1 Etapas de crecimiento del cultivo	23
Figura 2 Distribución de pines para sensor NPK	24
Figura 3 Distribución de pines para sensor multiparámetros	26
Figura 4 Metodología	34
Figura 5 Propiedades fisicoquímicas a estudiar	38
Figura 6 Escala de pH en cultivos de papa.....	39
Figura 7 Temperatura en terreno	40
Figura 8 Humedad en la planta.....	41
Figura 9 NPK en el cultivo de papa.....	42
Figura 10 Diagrama de lectura de sensores.....	44
Figura 11 Conexión sensor NPK y multiparámetros.....	45
Figura 12 Muestras realizadas	46
Figura 13 Desviación estándar	48
Figura 14 Porcentaje de error sensor NPK.....	49
Figura 15 Lectura de sensor multiparámetros	50
Figura 16 Lectura de pH en liquido.....	51
Figura 17 Lectura en suelo	52
Figura 18 Porcentaje de error de sensor multiparámetros.....	52
Figura 19 Lectura de variables	53
Figura 20 Características de las muestras.....	54
Figura 21 Arquitectura del modelo.....	55
Figura 22 Etapas para entrenar algoritmo.....	56
Figura 23 Importar base de datos	57
Figura 24 Graficas de variables respecto a macronutrientes	58
Figura 25 Separar datos para entrenamiento	59
Figura 26 Configuración de red neuronal.....	61
Figura 27 Grafica de Aprendizaje	62
Figura 28 Grafica de aprendizaje.....	63
Figura 29 Grafica de predicciones.....	65

Figura 30 Adquisición del modelo	65
Figura 31 Predicción del modelo.....	67
Figura 32 Diagrama electrónico	68
Figura 33 Montaje en 3D.....	69
Figura 34 Fabricación de circuito.....	69
Figura 35 Diseño de dispositivo 3D y real	70
Figura 36 Ubicación de terreno	71
Figura 37 Lectura de variables	71
Figura 38 Gráfico de dispersión de datos	73
Figura 39 Porcentaje de error en macronutrientes.....	74

Índice de Anexos

Anexo A. Pseudocódigo de entrenamiento	83
Anexo B. Análisis estadístico de calibración sensor NPK.....	84
Anexo C. Análisis estadístico de sensor multiparámetros	85
Anexo D. Correlación de Conductividad, humedad, temperatura, pH con respecto a nitrógeno, fosforo y potasio.....	86
Anexo E. Plano en SolidWorks de dispositivo para PCB	87
Anexo F. Plano Electrónico para circuito PCB.....	88
Anexo G. Base de datos.	89
Anexo H . Análisis 1 de laboratorio convencional.....	90
Anexo I. Análisis 2 de laboratorio convencional	91
Anexo J. Análisis 3 de laboratorio convencional.....	92
Anexo K. Análisis 4 de laboratorio convencional.....	93
Anexo L Análisis 5 de laboratorio convencional	94
Anexo M. Manual de Dispositivo	95

Introducción

El cultivo de papa es fundamental para la seguridad alimentaria y la economía de Colombia, destacándose el departamento de Nariño como una de las regiones productoras más importantes. Según Fedepapa, Nariño produce anualmente 585.202 toneladas de variedades como papa criolla, Diacol capira, ICA-unica, parda pastusa, pastusa suprema y superior, contando con 255.000 hectáreas aptas para su cultivo. Sin embargo, la falta de acceso a análisis avanzados de suelo lleva a muchos agricultores a fertilizar de manera empírica, aplicando un bulto de abono por bulto de papa sembrado sin considerar un previo análisis de suelo que brinda las condiciones fisicoquímicas y nutricionales del suelo. Este enfoque genera ineficiencias en el uso de fertilizantes, reduce la productividad y ocasiona impactos ambientales significativos, como la erosión del suelo y la contaminación del agua.

La agricultura de precisión, impulsada por la inteligencia artificial (IA), emerge como una solución sostenible y eficiente para optimizar la gestión de cultivos. Este estudio presenta el desarrollo de un dispositivo basado en IA, capaz de evaluar los niveles de nitrógeno, fósforo y potasio (NPK) en el suelo, utilizando variables como humedad, pH, conductividad eléctrica y temperatura. Este enfoque permite obtener tres variables cruciales a partir de cuatro variables del suelo. Para este propósito, se construyó una base de datos con 3,200 registros, utilizando sensores como el CTW NPK y el CTW multiparámetros, calibrados mediante cinco análisis realizados en el municipio de Valle del Guamuez, Putumayo.

El dispositivo fue entrenado en Google Colab utilizando cinco algoritmos de aprendizaje automático, y el modelo de redes neuronales mostró el mejor desempeño, alcanzando una precisión en campo del 78.5 %. Los datos de prueba se recolectaron en un terreno de cultivo ubicado en la vereda Bolívar, municipio de Iles, Nariño. Este dispositivo, diseñado para ser accesible y práctico, apoya la toma de decisiones informadas por parte de los agricultores, promoviendo un manejo más eficiente de los nutrientes del suelo y contribuyendo a un proceso de producción de papa más sostenible y respetuoso con el medio ambiente.

1. Resumen del proyecto

1.1. Descripción del problema

En Colombia, el sector de agricultura es uno de los principales ejes que mueve el país, tanto en el tema económico, como en el ámbito de la seguridad alimentaria, según la Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO, 2023), puede convertirse en una de las grandes despensas del mundo. El cultivo de la papa está entre los 5 productos de mayor consumo a nivel mundial (FAO 2023), caracterizándose Nariño como uno de los departamentos con mayor producción de papa, privilegiado por tener suelos andinos ricos en nutrientes. Datos aportados por la secretaría de Agricultura del Departamento de Nariño reportan áreas sembradas entre 25.000 y 34.000 hectáreas, con una producción que oscila entre 400.000 y 600.000 toneladas al año, generando alrededor de 264 mil empleos totales, de los cuales, 75 mil son directos y 189 mil indirectos.

Para la producción de dicho tubérculo es “fundamental preparar el suelo, por lo general muchos presentan problemas de acidez ya que es necesario hacer un proceso de regulación de PH, desintoxicación del suelo evitando plagas y hongos” (FAO, 2023), durante el proceso de crecimiento es de vital importancia fertilizar el cultivo con la cantidad adecuada de macronutrientes para no generar mayor demanda de insecticidas y fungicidas. El proceso de producción del tubérculo de papa, inicialmente algunos agricultores lo realizan haciendo un análisis de suelos o conocido comúnmente como métodos de laboratorio convencionales “Los cuales permiten caracterizar las propiedades físicas, químicas y biológicas del suelo para saber sus condiciones nutricionales” (Perret, Villalobos, Bolaños, & Fuentes, 2020, págs. 139-154), identificando el déficit de macronutrientes del suelo y así realizar un proceso de fertilización si lo requiere, sin embargo en su gran mayoría no lo realiza, lo que restringe a pequeños productores al acceso de estos servicios de alta precisión, dando como resultado cultivos de manera tradicional y uso desmedido de fertilizantes.

Según un estudio de Fedepapa, el costo promedio de producir una hectárea de papa asciende a \$19.728.760 COP, donde los insumos representan más del 45% del total, la mano de obra contribuye con un 20%, y el resto corresponde a costos indirectos. Esto destaca la importancia de cuantificar los costos de producción en relación con el rendimiento obtenido, considerando factores clave como la calidad del suelo, el uso de semillas certificadas y la aplicación adecuada de fertilizantes en el cultivo de papa. Alrededor del 80% de a causa de las actividades agropecuarias, bajo el uso de tecnologías inadecuadas e insostenibles sin considerar la aptitud del uso del suelo, generando pérdidas progresivas de este recurso y una reducción considerable de la capacidad productiva, debido a la alteración de las propiedades fisicoquímicas del suelo (FAO & MADS, 2018).

Por lo que es fundamental brindar información precisa y oportuna, efectuando la intervención correcta, en el momento adecuado lo que lleva a una agricultura de precisión permitiendo “la aplicación de tecnologías y principios para el manejo de la variabilidad espacial y temporal asociada a todos los aspectos de la producción agrícola con el propósito de mejorar la productividad de la zona andina está afectada por la erosión cultivo y la calidad ambiental”. (Castellanos & Morales, 2016, págs. 23-33).

De esta manera el desarrollo tecnológico y la inteligencia artificial han revolucionado el sector agrícola, permitiendo cultivar técnicamente y con alta precisión, brindando soluciones al sector agrícola al igual que el sector industrial ya que proporciona herramientas y métodos de monitoreo como modelos de aprendizaje automático los cuales puedan predecir anomalías en la etapa de crecimiento o producción del cultivo en este caso la implementación de manejo de datos que permita correlacionar el estudio de variación de las variables químicas las cuales generen un diagnóstico sobre la cantidad de macronutrientes presentes en el suelo. (Jhoan, 2023)

1.1.1. Formulación del problema

¿Cómo desarrollar un dispositivo inteligente que permita determinar el porcentaje de macronutrientes a partir de características fisicoquímicas evaluando métodos de inteligencia artificial?

1.2. Justificación

Los análisis realizados en laboratorios de suelos son esenciales en la agricultura, ya que permiten implementar técnicas y prácticas que mejoran la producción y protegen el medio ambiente. Estos análisis proporcionan informes detallados sobre las propiedades fisicoquímicas y la cantidad de nutrientes presentes en el suelo. Sin embargo, el acceso a estos métodos es limitado, especialmente para los pequeños productores de papa, quienes a menudo dosifican fertilizantes de manera intuitiva, sin un análisis previo. Por lo general, los análisis de laboratorio convencionales se realizan en ciudades centrales como Pasto e Ipiales, lo que presenta dificultades de acceso para los agricultores y demora en la entrega de resultados, generalmente entre 15 y 20 días, con un costo aproximado de \$200.000 COP. Esta situación puede llevar a un desequilibrio de minerales en el suelo y al uso excesivo de fertilizantes, impactando negativamente en el medio ambiente a través de la erosión del suelo y la contaminación del agua. Esto afecta la sostenibilidad económica de los agricultores (Ashina, Khaydukova, & Kirsanov, 2021), en relación con los objetivos propuestos por la FAO y los ODS mundiales, como aumentar la productividad y reducir el desperdicio, proteger los recursos naturales y fomentar la innovación agrícola.

Actualmente, existen dispositivos como el sensor Teralytic que proporcionan datos sobre la humedad, salinidad, nitrógeno, fósforo y potasio presentes en el suelo. Sin embargo, su alto costo restringe la accesibilidad para muchos productores. Por ello, es crucial desarrollar un dispositivo accesible que determine el porcentaje de macronutrientes (nitrógeno, fósforo y potasio) en el suelo a partir de variables como conductividad eléctrica, pH, temperatura y humedad de manera directa, evitando el desplazamiento a ciudades donde se encuentran los laboratorios certificados y, lo más importante, eliminando el tiempo de espera que conllevan los diferentes métodos de análisis. Esto permitirá cumplir con los objetivos de agricultura sostenible, permitiendo una fertilización precisa y reduciendo los costos de producción. Además, la implementación de tecnología en el sector agrícola no solo puede ser una fuente significativa de ingresos y mejorar la calidad de vida, sino que también ofrece beneficios como una mayor producción, protección del medio ambiente y precios más accesibles (Abdullahi & Madhieddine, 2015). Por tanto, en el departamento de Nariño,

es vital adoptar estas herramientas para impulsar la competitividad del agro colombiano a nivel global.

Teniendo en cuenta las especificaciones mencionadas, el desarrollo de este dispositivo inteligente permitirá adecuar el terreno de manera precisa antes de la siembra. Durante las etapas de fertilización, ayudará al agricultor a determinar la cantidad adecuada de fertilizante, con el apoyo de un experto que interprete los datos obtenidos mediante el dispositivo. El dispositivo determinará el porcentaje de macronutrientes en el suelo, utilizando propiedades fisicoquímicas mediante modelos de aprendizaje automático, beneficiando tanto a pequeños productores como a laboratorios e investigadores. Esto resultará en una fertilización precisa, reduciendo costos y promoviendo prácticas agrícolas sostenibles.

1.3. Objetivos

1.3.1. Objetivo general

Desarrollar un dispositivo que permita determinar los macronutrientes del suelo a partir de variables como el pH, conductividad eléctrica y humedad.

1.3.2. Objetivos específicos

- Identificar propiedades fisicoquímicas presentes en el suelo.
- Diseñar e implementar un sistema Software/hardware que permita predecir los macronutrientes del suelo.
- Validar el funcionamiento en un suelo con propiedades fisicoquímicas conocidas.

1.4. Marco referencial o fundamentos teóricos

1.4.1. Antecedentes

"La gestión mejorada de los nutrientes esenciales del suelo es una meta vital para lograr una agricultura sostenible y mantener los aumentos necesarios en la producción de alimentos, al tiempo que se minimizan las pérdidas económicas y los impactos ambientales (Balasundaram et al., 2012). Por lo que es importante mejorar las prácticas de gestión agrícola, dado esto se ve la necesidad de

implementar sistemas basados en computadora para entender las complejidades de la dinámica de los nutrientes y su variabilidad en espacio y tiempo. Se han utilizado técnicas como geoestadística, redes neuronales, árboles de regresión y sistemas de lógica difusa para analizar la distribución de nutrientes en el suelo.

Por otro lado, según He, Y., Huang, M., García, A. La espectroscopía visible-NIR es una técnica analítica rápida y no destructiva que correlaciona la radiación del infrarrojo cercano reflejada difusamente con las propiedades químicas y físicas de los materiales y se ha utilizado para evaluar las cualidades del grano y del suelo y ha demostrado ser rápido, conveniente, simple, preciso y capaz de analizar muchos componentes al mismo tiempo. Las características espectrales de los materiales del suelo en la región espectral NIR están asociadas con modos de vibración. La espectroscopia de infrarrojo cercano (NIR) mostró potencial para predecir el contenido de nitrógeno (N), materia orgánica (MO) y pH en suelos arcillosos con coeficientes de correlación de 0.93 y 0.91 con un error estándar de predicción de 3.28, 0.06, 0.07 sin embargo el NIR no es una buena herramienta para predecir fósforo(F) y potasio(K) en los suelos, con coeficientes de correlación(r) más bajos de 0.47 y 0.68 y valores de error estándar de más altos de 33.70 y 26.54 (Yong He et al., 2012).

Según Mahammad Mekala,P. & Viswanatha proponen evaluar el número de dispositivos necesarios para un modelo de selección de sensores basado en (t: número mínimo de sensores, n: sensores instalados en áreas específicas) y área, con el fin de crear un sistema de toma de decisiones preciso que aborde condiciones ambientales, funciones de rendimiento y regulación de fertilizantes. De modo que se puede predecir condiciones ambientales y evaluar situaciones anormales que afecten negativamente la producción agrícola, buscando simplificar el proceso de estipulación de sensores y planteando un modelo regulador de fertilizantes NPK para evaluar la disponibilidad de nutrientes en el suelo (Mekala & Viswanathan, 2020).

El sistema de monitoreo contiene nodos de sensores S heterogéneos, como sensores de humedad del suelo, pH, temperatura, contaminación del aire y una estación base. La cobertura de cada sensor es diferente; en este se requiere una alta conectividad de red en una parcela de una hectárea,

dividiendo en 4 subregiones el campo de cultivo en función de la proporción de conectividad de sensores la cual su cobertura es de 30-35 metros.

La salinidad del suelo comúnmente se estima a través de la medición de su resistividad o conductividad eléctrica. La utilización de sensores electromagnéticos móviles para evaluar estas propiedades en campos de cultivo (Sudduth et al., 2003). En su estudio, se compararon sensores de contacto con sensores de inducción electromagnética para cartografiar las características del suelo en campos agrícolas. Los resultados indicaron una correlación significativa entre la conductividad eléctrica del suelo y propiedades estables en el tiempo, como la cantidad de arcilla y la capacidad de intercambio catiónico, aunque la correlación fue baja con otras propiedades, como la humedad, limo, arena y carbono orgánico. Sin embargo, se observaron limitaciones en la utilidad de estos sensores debido a factores como la velocidad de operación, la altura de medición, las variaciones en la humedad y temperatura del suelo, la profundidad de la capa superficial del suelo y el posible desgaste de los instrumentos con el tiempo (Bollero, Bullock, & Sudduth, 2003).

Los sensores que se pueden portar de una manera fácil como los ópticos, electromagnéticos y electroquímicos han permitido una medición rápida de las diferentes variables. El manejo de sensores de Colza brinda resultados óptimos ya que, al implementar un sistema de lectura, se logra analizar y hacer el proceso de fertilización adecuado sin afectar el rendimiento de la producción (Balasundram et al., 2012). De esta manera el uso de los sensores portátiles, móviles y la aplicación de técnicas avanzadas como redes neuronales arboles decisiones entre otras permiten identificar una solución guía para los sensores a utilizar y la precisión que las técnicas llegan a tener en su aplicación tecnológica.

1.4.1.1. Internacionales. Actualmente existen métodos computacionales que han brindado beneficios en ciertos sectores siendo uno de ellos la agricultura, el cual favorece al sector campesino con un rendimiento y control del producto, sin embargo, un estudio aplicado en dos distritos (Pune y Ahmednagar) del estado de Maharashtra en la India, se identifica la cantidad de nutrientes disponibles en el suelo, (NPK) y el carbono orgánico (CO), aplicando nuevas técnicas para estimar las propiedades del suelo. En los que el gobierno implementó el esquema Soil Health Card. Ya que la escasez de tecnología de espectro medido desde el suelo y al costo de obtener imágenes hiperespectrales, se utilizan datos de teledetección multiespectral para explorar la estimación del contenido de nutrientes del suelo. sensores remotos ópticos (Landsat 8 y Sentinel2), datos de terreno/clima (precipitación, radiación, pendiente, etc.) y valor real del terreno para estimar cuatro nutrientes: N, K, P, y OC (Kaur, Das, & Hazra, 2020).

Dada esta limitación, se utilizan nuevas técnicas para estimar las propiedades del suelo, en las últimas décadas, los datos de sensores remotos (RS) se utilizan principalmente para la estimación de las propiedades del suelo. En general, la reflectancia multiespectral transporta información del suelo que potencialmente se usa en la literatura para estimar los nutrientes del suelo usando modelos ML supervisados. Una de las ventajas de los datos RS es su cobertura global y alta. Comparamos cuatro modelos de regresión lineal y no lineal: regresión lineal múltiple (MLR), regresión de bosque aleatorio (RFR), máquina de vectores de soporte para regresión (SVR) y aumento de gradiente (GB) para la estimación de NPK y OC. Los resultados comparativos sugieren que GB y RFR se desempeñaron mejor que otros modelos con sMAPE en un rango de 0.1250.377 para todos los nutrientes, lo que es mejor o comparable con la precisión reportada en la literatura. (Kaur, Das, & Hazra, 2020).

Del mismo modo se puede relacionar la respuesta del sistema multisensor con los resultados del análisis de laboratorio convencional utilizando regresión de mínimos cuadrados parciales (PLS). Este método de regresión multivariable se aplica ampliamente para la interpretación de datos de sensores múltiples. Durante el modelado, la matriz de variables independientes (respuestas del sensor) se relaciona con el conjunto de variables dependientes (valor del parámetro objetivo). El algoritmo está organizado de manera que solo busca la variación en los datos del sensor que está

correlacionada con el parámetro objetivo e ignora el resto de la variación. El resultado del modelado PLS es un conjunto de coeficientes de regresión. El parámetro de interés en la nueva muestra se puede calcular mediante la multiplicación de las lecturas del sensor potenciométrico en la nueva muestra por los coeficientes de regresión correspondientes. En este estudio se construyó un modelo individual para cada parámetro de calidad del suelo estimado por métodos agroquímicos tradicionales. (Khaydukova et al. 2021).

Continuando con la temática se complementa una investigación donde se realiza la predicción del tipo de cultivo en base al Macronutrientes tomando diferentes atributos químicos, como el valor de PH, la salinidad, se registraron valores como la humedad, la lluvia, la luz solar y la temperatura en diferentes intervalos dentro del suelo. Micronutrientes como Nitrógeno Fósforo y potasio fueron mapeados a partir de diferentes composiciones químicas y su interacción con los atributos químicos mencionados anteriormente. Se han llevado a cabo análisis de regresión y ajuste de curvas para encontrar la mejor ecuación matemática posible para los resultados del mapeo. El mapeo detallado utilizando la técnica de ajuste de curvas con respecto al nitrógeno, fósforo y potasio.

Para adquisición de datos se utilizan tipos de algoritmos de aprendizaje automático: como la máquina de vectores de soporte, la máquina de vectores de soporte con Kernel y el árbol de decisión. los resultados se compararon y se encontró que Support Vector Machine with Kernel proporciona el mayor grado de precisión en términos de puntaje f1 del 91% en comparación con SVM lineal y árbol de decisión donde el puntaje f1 es solo 43% (Chenzhen, Guaozhong, & Zhang, 2022).

La agricultura en la actualidad ha tenido avances tecnológicos donde se han aplicado soluciones viables como lo es LoRaWAN integrando sensores inteligentes NPK, humedad, temperatura, sensor de conductividad del suelo y pH, cabe recalcar que el sistema utilizado es un protocolo de comunicación a largo alcance que permite transmitir datos a través de aplicación Android. La implementación de un sistema de riego y monitoreo de parámetros químicos de los suelos ayuda a mejorar las tomas de decisiones al momento de fertilizar el cultivo mejorando la producción, generando prácticas agrícolas sostenibles (Islam, Kabir, & Oliullah, 2023). De acuerdo a lo

mencionado se comprende que los métodos computacionales mejoran y benefician el sector de la agricultura en las cuales se da a entender el costo de las tecnologías, por lo que el desarrollo de este dispositivo quiere llegar a prestar un servicio óptimo y de fácil acceso para el agricultor.

En el mercado existen diferentes sensores que permiten medir diversas variables en los cultivos. Uno de ellos es el sensor PRISMAB, que permite adaptar tres sensores de la misma referencia para medir variables como humedad, temperatura, conductividad eléctrica (CE) . Este sensor también permite el monitoreo a través de cualquier dispositivo sin costo adicional, y tiene un costo aproximado de \$1.950.000 COP.

Otro sensor disponible es el DG-HTEC-ST, que mide variables como conductividad eléctrica, humedad y temperatura, además permite el monitoreo mediante la tecnología LoRaWAN 1.0.3 a través de cualquier dispositivo. Este sensor tiene un costo aproximado de \$2.400.000 COP.

Una opción importante es el analizador portátil con múltiples sondas, el cual mide los niveles de NPK (nitrógeno, fósforo y potasio) del suelo, el pH y la humedad. Este analizador tiene un costo aproximado de \$1.200.000 COP, más los sensores adicionales que se quieran adaptar, con un costo aproximado de \$400.000 COP cada uno. Todos estos sensores vienen con sus hojas de datos y calibraciones respectivas, lo que los hace fiables al momento de adquirirlos.

1.4.2. Marco Teórico

1.4.2.1. Características del suelo

1.4.2.1.1. Propiedades del Suelo. Es importante resaltar propiedades químicas como el PH (potencial de hidrógeno) determina el grado de adsorción de iones (H⁺) por las partículas del suelo e indica si un suelo es ácido o alcalino. Es el indicador principal en la disponibilidad de nutrientes para las plantas, influyendo en la solubilidad, movilidad, disponibilidad y de otros constituyentes y contaminantes inorgánicos presentes en el suelo.

El valor del pH en el suelo oscila entre 3,5 (muy ácido) a 9,5 (muy alcalino). Los suelos muy ácidos (<5,5) tienden presentar cantidades elevadas y tóxicas de aluminio y manganeso. Los suelos

muy alcalinos ($>8,5$) tienden a dispersarse. La actividad de los organismos del suelo es inhibida en suelos muy ácidos y para los cultivos agrícolas el valor del pH ideal se encuentra en 6,5. (FAO, 2023).

La conductividad eléctrica (CE) es una medida esencial de la cantidad total de nutrientes disponibles para las plantas y se mide mediante métodos de análisis electrométricos, al igual que el pH. Un suelo con una conductividad eléctrica de 0-2 Ds/m se considera adecuado y óptimo para el desarrollo de cultivos. Por lo tanto, si el suelo tiene un nivel de CE incorrecto, las plantas pueden comenzar a mostrar signos de estrés. Si la CE es demasiado alta, las plantas presentarán signos de toxicidad (salinidad); si es demasiado baja, las plantas tendrán una deficiencia de nutrientes. Para que las plantas prosperen, es necesario que la CE se mantenga dentro de los rangos preferidos por ellas. Si las plantas permanecen fuera de estos límites durante un período considerable de tiempo, comenzarán a mostrar síntomas de mala salud.

1.4.2.1.2. Macronutrientes (Nitrógeno, fósforo y potasio). Los macronutrientes se definen como elementos necesarios en grandes cantidades para asegurar el crecimiento y la supervivencia de las plantas. Es importante afirmar que la presencia de una cantidad suficiente de elementos nutritivos en el suelo no asegura por sí misma la correcta nutrición de las plantas, ya que estos elementos se tienen que encontrar en una forma asimilable los cultivos y haya un correcto desarrollo de esta. Dentro de ellos, existen dos grupos: elementos primarios (N, P, y K) y secundarios (Ca, Mg y S) (Paul, Soil Microbiology, Ecology, and Biochemistry, 2014).

El nitrógeno es un elemento nutritivo que se encuentra presente en el suelo en diferentes formas, aunque las plantas y microorganismos lo absorben en forma de nitrato (NO_3^-) o amonio (NH_4^+). El mayor reservorio de nitrógeno en el suelo se encuentra en los microorganismos que lo habitan como pueden ser bacterias, hongos o nemátodos, aunque la cantidad de este es muy baja para la gran cantidad que consumen los cultivos.

Para el crecimiento vegetativo, es vital tener en cuenta al Potasio el cual produce succulencia y además es responsable del color verde que presentan las hojas. Si se produce un exceso de este nutriente en un cultivo puede afectar a la maduración, bajar la calidad del cultivo y, además,

debilitar la planta lo que conlleva que se sean más propensas a diferentes enfermedades y plagas, más vulnerables a la lluvia, etc. Mientras que un déficit de este provoca un color verde pálido en las hojas y afecta al crecimiento de la planta, aunque puede florecer. (Halvin, 2022).

Es nutriente esencial para todos los organismos vivos, ya que juega un papel importante en la activación enzimática, fotosíntesis y síntesis de proteínas y carbohidratos, balance de agua y en el crecimiento meristemático. Su presencia contribuye a un mejor crecimiento vegetativo y a la fructificación, maduración y calidad de los frutos. Por otro lado, también favorece la resistencia de la planta a diferentes plagas y enfermedades, a las sequías, al granizo, etc. Un déficit de este elemento en el suelo afecta a la floración, fructificación y desarrollo de toda la planta y además se observa en las hojas y brotes jóvenes cuando su carencia es aguda. Los suelos que presentan una mayor carencia de este nutriente son suelos arenosos y suelos con un alto contenido de calcio. (Halvin, 2022).


Seguido por el Nitrógeno el fósforo es un elemento nutritivo más limitante del rendimiento de los cultivos. Ayuda a las raíces y a que las plantas tengan un rápido desarrollo, mejorando de esta manera su resistencia a las bajas temperaturas y en el caso de algunas plantas, su resistencia a determinadas enfermedades. Además, interviene en numerosos procesos bioquímicos a nivel celular e incrementa la eficiencia del uso del agua. Su falta se observa en las hojas viejas ya que presentan un color verde pálido y los bordes secos y también afecta a la floración y al desarrollo de las raíces. (Halvin, 2022). Se estima que una tonelada de papa consume aproximadamente 6 kg de nitrógeno, 0.8 kg de fósforo y 9 kg de potasio (N-P-K), lo que implica un consumo total de 270 kg/ha de nitrógeno, 130 kg/ha de fósforo y 385 kg/ha de potasio para alcanzar un rendimiento promedio de 25 toneladas por hectárea.

1.4.2.1.3. Desarrollo del producto de la papa. “En el crecimiento de la planta de papa se pueden diferenciar tres etapas: emergencia, crecimiento vegetativo, reproductivo (desarrollo de tallos, hojas, inicio de tuberización, floración y fructificación) como se observa en la Figura 1 y madurez, las cuales a su vez determinan las diferentes prácticas de manejo del cultivo, como por ejemplo: la deshierba, controles fitosanitarios, requerimientos de nutrientes y agua, cuya oportuna

y apropiada realización depende la mayor o menor producción y calidad del cultivo” (Araujo, Cartajena, & Castillo, 2021).

Figura 1

Etapas de crecimiento del cultivo



Fuente: Proain tecnología agrícola, 2020.

Por otro lado, los elementos nutricionales que requiere el tubérculo de papa para su buen desarrollo y producción en su orden de importancia: nitrógeno (N), fósforo (P), potasio (K), calcio (Ca) y magnesio (Mg); y los elementos llamados menores porque la planta los demanda en menor cantidad: zinc (Zn), boro (B) y cobre (Cu). Por lo tanto, las cantidades a aplicar de estos elementos dependen de los rendimientos esperados en la producción (necesidades del cultivo) y del resultado del análisis de suelo (disponibilidad de nutrientes en el suelo); es decir, la diferencia entre las necesidades del cultivo y los nutrientes disponibles en el suelo determina el tipo y la cantidad de fertilizante que se debe aplicar.

Con el mismo propósito, los elementos nutricionales pueden suministrarse al cultivo mediante la aplicación de fertilizantes químicos como: 10-30-10; 13-26-6; 15-15-15; 14-14-14; fosfato di amónico (DAP) 18-46-0; cloruro de potasio; sulfato de potasio; urea 46 %; nitrato de amonio o sulfato de amonio (SAM), entre otros. Abonos orgánicos como gallinaza, estiércol fermentado, compost y abonos verdes. La adición de materia orgánica contribuye con el aporte de macro y

micronutrientes al suelo en menor proporción, mejora el intercambio y aprovechamiento de nutrientes por parte de la planta (relación suelo-planta), mejora la estructura del suelo, evita la compactación del suelo, protege el suelo de la erosión, aumenta la capacidad de aireación, mejora la retención de agua y regula la temperatura del suelo. Debido a esto, la aplicación de materia orgánica, especialmente como gallinaza seca y bien pulverizada (sola o en mezcla con fertilizantes de NPK), han dado buenos resultados en el oriente antioqueño. En el altiplano cundiboyacense, la aplicación de dos toneladas de gallinaza seca y pulverizada, combinada con 1.500 kg/ha de 10-30-10, ha dado incrementos hasta de 6 t/ha en los rendimientos” (Araujo, Cartajena, & Castillo, 2021).

1.4.2.2. Tipos de sensores.

1.4.2.2.1. Sensor industrial CTW NPK. El sensor NPK es una herramienta eficaz para detectar y medir el contenido de nitrógeno, fósforo y potasio en el suelo, determinando así su fertilidad. Funciona midiendo la conductividad eléctrica del suelo, lo que facilita una evaluación sistemática de su composición mediante un microprocesador, cuyos pines están conectados a un módulo RS-485 Figura 2, permitiendo obtener las variables. Este sensor puede ser enterrado en el suelo durante largos períodos, ya que es resistente a la electrólisis, la corrosión y a las condiciones de vacío, además de ser completamente impermeable. Es ampliamente utilizado en diversas aplicaciones, incluyendo la detección de nutrientes en el suelo, la agricultura de precisión, la silvicultura, la investigación del suelo, la exploración geológica y el cultivo de plantas.

Figura 2

Distribución de pines para sensor NPK



Fuente: Comwintop, 2022.

Por lo general los sensores industriales tipo CTW utilizan tramas de hexadecimales para su lectura, siendo este un sistema numérico posicional que utiliza 16 símbolos para representar valores el cual toma valores numéricos de 0 al 9 y las letras A a F representando valores del 10 al 15, esta es una forma eficiente de transmitir datos entre dispositivos electrónicos (Noguera, Ros, & Serna, 2010), este además cuenta con una hoja de datos los cuales brindan información como rango de medida, resolución y tiempo de respuesta como se observa en la Tabla 1 haciéndolo eficiente para medir macronutrientes de suelos.

Tabla 1

Datasheet sensor NPK

Variable	Rango
Nitrógeno	Rango de medida: 1 – 1999 (mg/kg) o ppm
Fosforo	Resolución: 1 (mg/kg) o ppm
Potasio	Tiempo de respuesta: <2 s

Fuente: Comwintop, 2022.

1.4.2.2.2. Sensor industrial temperatura, humedad, pH y conductividad eléctrica (CTW multiparámetros). Este sensor utiliza los mismos pines de distribución que el sensor CTW NPK, como se muestra en la Figura 3, y su funcionamiento es similar. La principal diferencia radica en la programación para obtener las variables a través del módulo RS-485. El principio de funcionamiento se basa en la conductividad eléctrica del suelo, lo que permite medir de manera eficiente las variables de humedad, temperatura, conductividad eléctrica y pH.

Figura 3

Distribución de pines para sensor multiparámetros



Fuente: Comwintop, 2022.

Este sensor cuenta con especificaciones técnicas en Datasheet, las cuales incluyen los rangos de medida, la precisión y el tiempo de respuesta. Estas características lo hacen especialmente adecuado para la medición de variables en suelos, asegurando resultados precisos y confiables. En la Tabla 2 se muestran los parámetros específicos, lo que facilita la interpretación y aplicación de los datos obtenidos.

Tabla 2

Datasheet sensor multiparámetros

Variable	Características
Temperatura	<ul style="list-style-type: none"> • Rango de medida -40 °C a 80 °C • Precisión: +- 5°C • Tiempo de respuesta < 16s
Humedad	<ul style="list-style-type: none"> • Rango de medida 0-100 % • Precisión: 2% • Tiempo de estabilidad: <5s
Conductividad eléctrica (CE)	<ul style="list-style-type: none"> • Rango de medida: 0-200000 us/cm • Precisión: 0-10000 +- 3%

	<ul style="list-style-type: none">• Tiempo de respuesta: < 2s
pH	<ul style="list-style-type: none">• Rango de medida: 3-9PH• Precisión: +- 0.3 PH• Tiempo de respuesta: <11 s

Fuente: Comwintop, 2022.

De acuerdo a las variables de lectura del sensor se tiene presente el significado de cada una de ellas como: La temperatura del suelo la cual está directamente asociada a la temperatura de la atmósfera porque el suelo es un aislante del flujo de calor entre la tierra sólida y la atmósfera. En un día soleado, por ejemplo, el suelo absorbe energía del sol y su temperatura aumenta. Por la noche, el suelo libera calor al aire, y esto afecta directamente a la temperatura del aire.

El único método directo que existe para la medición del contenido de agua en el suelo es el método gravimétrico. Se extrae una muestra de suelo de volumen conocido, se toma nota de su masa inicial, se seca en estufa a 105°C por 24 a 48 horas, hasta que la masa de suelo permanezca constante. El contenido gravimétrico de agua de la muestra corresponde a la pérdida de masa registrada después del secado, ya que se atribuye al agua presente inicialmente en la muestra (Topp, et al., 2002). Este método se utiliza normalmente para calibrar equipos que usan otros métodos de medición de humedad de suelo (métodos indirectos). Sin embargo, se puede utilizar sensores de tipo resistivos que permitan la identificación de dichas variables como el Sensor que ofrece una respuesta rápida y es resistente a la corrosión, rescatando que dicha unidad es de % marcando desde 1% como baja humedad y 100% completamente húmedo.

Los sensores de suelo miden conductividad eléctrica (CE) del medio como un todo, teniendo en cuenta que ese todo es una matriz de suelo/aire/agua, por lo que su valor depende de otras propiedades del suelo, a parte de la propia salinidad, como son la humedad y la textura de este. La CE de un suelo, en consecuencia, es distinta de la CE de una solución del suelo, y por supuesto distinta de la CEE (conductividad eléctrica en el extracto de saturación). Sin embargo, la utilización de sondas presenta la ventaja de la inmediatez de la medida y la desventaja de la compleja

correspondencia que existe entre la medida de la sonda y la medida de referencia en el extracto de saturación. Los sensores de resistividad eléctrica se fundamentan en la medida de la resistencia que el suelo opone al paso de la corriente eléctrica. Exigen un buen contacto entre el sensor y el suelo. Su unidad de medición es el Siemens/cm (S/cm); si lo aplicamos a una magnitud de 10 elevado a -6 obtenemos un valor en microSiemens ($\mu\text{S/cm}$); y si lo medimos en 10 elevado a -3, estamos hablando de miliSiemens (mS/cm).

1.4.2.3. Modelos de Aprendizaje automático supervisado. En clasificación la finalidad es predecir respuestas discretas y etiquetas de clase, un factor importante a considerar es que esto se puede utilizar si sus datos pueden ser etiquetados, categorizados o clasificados en general, dependiendo del modelo aplicado. Esta se caracteriza por conocer cuáles son las salidas esperadas para un determinado conjunto de datos proporcionados en la entrada, los cuales están pre etiquetados, de modo que el sistema pueda generalizar y asociar, para responder de manera adecuada cuando reciba una nueva entrada. Por otro lado, la clasificación se distribuye en clasificación binaria, que identifica precisamente entre dos clases, y en clasificación multiclase, donde clasifica más de dos clases (Guido & Müller, 2017).

1.4.2.3.1. Funciones de activación. La función ReLu se describe como una función que devuelve el valor de entrada si es positivo y cero si es negativo. Introduce no linealidad en la red, permitiendo que las redes neuronales profundas aprendan representaciones complejas de los datos. Su cálculo es eficiente y menos costoso computacionalmente, pero puede provocar el problema de "neuronas muertas", donde algunas neuronas dejan de aprender al producir solo ceros para entradas negativas. ReLU es especialmente efectiva en aplicaciones de visión por computadora. (Guido & Müller, 2017).

Función Lineal: Se describe como una función en la que la salida es proporcional a la entrada, expresada matemáticamente como la $E_c(1)$. En este contexto, la función de activación lineal permite que una neurona simplemente transmita el valor de entrada sin modificarlo, lo cual es útil en problemas de regresión donde se busca predecir valores continuos.

Sin embargo, la función lineal tiene una limitación importante: al no introducir no linealidad,

impide que la red aprenda relaciones complejas en los datos. Por esta razón, las funciones de activación lineales son menos comunes en las capas ocultas y se suelen reservar para la capa de salida en redes neuronales diseñadas para tareas de regresión (Aggarwal, 2018).

$$Ec(1). \quad f(x) = xf(x) = xf(x) = x.$$

1.4.2.3.2. Técnicas por Clasificación. Las técnicas de aprendizaje automático supervisado que se lleva a cabo son: Redes Neuronales son especialmente útiles para capturar patrones complejos y no lineales en los datos, y su efectividad se debe en gran parte a la capacidad de ajustar los pesos de cada conexión entre neuronas a través de un proceso de entrenamiento, generalmente usando un método llamado retro propagación. Este tipo de modelo es adecuado para tareas de clasificación, regresión y otros problemas complejos, como reconocimiento de imágenes y procesamiento de lenguaje natural. una red neuronal incluye la neurona artificial, que es cada nodo donde se procesan los datos de entrada mediante ponderación y aplicación de una función de activación antes de transmitir el resultado. Además, las redes neuronales pueden tener capas simples o profundas; las redes profundas (DNNs) poseen múltiples capas ocultas, lo cual aumenta su capacidad para aprender características complejas de los datos. Existen varios tipos de redes neuronales, cada una diseñada para tareas específicas: las Redes Neuronales Convolucionales (CNN), comunes en visión por computadora debido a su capacidad para procesar imágenes; las Redes Neuronales Recurrentes (RNN), ideales para datos secuenciales como texto o series de tiempo; y las redes Generativas antagónicas (GANs), utilizadas en la generación de datos sintéticos (Guido & Müller, 2017).

1.4.2.3.3. Técnicas de prevención de sobreajuste. La regularización L2: se describe como una técnica para evitar el sobreajuste en redes neuronales al agregar una penalización basada en el cuadrado de los pesos al término de pérdida del modelo. Este enfoque ayuda a mantener los valores de los pesos pequeños, lo que reduce la complejidad del modelo y lo hace menos propenso a ajustarse demasiado a los datos de entrenamiento. La regularización L2 mejora la capacidad de generalización al suavizar el modelo, y el parámetro de regularización λ permite controlar la intensidad de la penalización: valores más altos de λ incrementan la regularización, limitando el sobreajuste, aunque en exceso pueden llevar al modelo a su ajustarse (Aggarwal, 2018).

Doprou: Es un método de regularización que ayuda a prevenir el sobreajuste en redes neuronales. Durante el entrenamiento, dropout consiste en desactivar aleatoriamente un porcentaje de neuronas en cada iteración, lo que significa que esas neuronas no contribuyen a la activación y no se actualizan sus pesos en esa pasada. Esta técnica fuerza a la red a aprender representaciones más robustas y distribuidas, ya que cada neurona no puede depender de otras neuronas que pueden estar desactivadas. El uso de dropout promueve la generalización del modelo al reducir la co-adaptación de neuronas, lo que significa que cada neurona debe aprender características útiles por sí misma, en lugar de depender de la presencia de otras neuronas en la red. Esto resulta en un modelo más sólido y menos susceptible a los patrones específicos del conjunto de entrenamiento. Dropout se utiliza comúnmente en capas ocultas de redes neuronales y ha demostrado ser efectivo en mejorar el rendimiento en diversas tareas de aprendizaje automático (Aggarwal, 2018).

1.4.2.3.4. Arquitectura de Redes. Capas Ocultas. Se describen como las capas intermedias de una red neuronal que se encuentran entre la capa de entrada y la capa de salida. Estas capas no están directamente visibles para el usuario (de ahí el término "ocultas") y son fundamentales para el aprendizaje de representaciones complejas de los datos. En estas capas, cada neurona procesa los datos aplicando funciones de activación, permitiendo a la red aprender y capturar patrones o características que no serían posibles en una red simple sin estas capas adicionales. Las capas ocultas son esenciales para la capacidad de las redes neuronales profundas (DNN) de realizar tareas complejas y de reconocimiento de patrones en los datos. (Aggarwal, 2018).

Capas Densas: Las capas densas (o capas completamente conectadas, conocidas también como fully connected layers) se refieren a aquellas capas en las que cada neurona está conectada a todas las neuronas de la capa anterior. Esta estructura de conectividad completa permite a la red neuronal combinar todas las características de la capa anterior para aprender patrones complejos en los datos. Estas son especialmente comunes en las etapas finales de redes neuronales para realizar tareas de clasificación o regresión, ya que permiten procesar de manera exhaustiva toda la información extraída en las capas previas (Bengio, Courville, & Goodfellow, 2018).

1.4.2.3.5. Parámetros de evaluación. Val_loss (Pérdida de validación): Se discute el uso de la pérdida de validación como una métrica para monitorizar el rendimiento del modelo en un conjunto de datos que no se utiliza durante el entrenamiento. Esto es clave para evitar el sobreajuste (Bengio, Courville, & Goodfellow, 2018).

MAE: Similar al MSE, el MAE es una métrica utilizada para evaluar modelos de regresión. Este concepto se menciona en el contexto de las funciones de pérdida y la evaluación de modelos, pero no siempre con ese término específico (Bengio, Courville, & Goodfellow, 2018).

MSE: es una función de pérdida común en problemas de regresión que se utiliza para medir la precisión de un modelo. El MSE es sensible a los errores grandes, lo que significa que penaliza más fuertemente los grandes errores, lo cual es útil en situaciones donde estos son indeseables. Se emplea frecuentemente durante el entrenamiento de modelos de regresión porque su forma es diferenciable, lo que permite utilizar técnicas de optimización como el descenso de gradiente. Aunque es una métrica popular, también se compara con el Mean Absolute Error (MAE), que puede ser más adecuada en ciertos casos debido a su menor sensibilidad a los errores grandes (Bengio, Courville, & Goodfellow, 2018).

RSquared: Según "The Elements of Statistical Learning", es una medida que indica la proporción de variabilidad en la variable dependiente que puede ser explicada por las variables independientes en un modelo de regresión. Un R^2 de 0 significa que el modelo no explica ninguna variabilidad, mientras que un R^2 de 1 indica que explica toda la variabilidad. Se utiliza para comparar la bondad de ajuste entre diferentes modelos, pero su valor puede ser engañoso, ya que puede aumentar al añadir más variables, independientemente de su relevancia. Por lo tanto, R^2 debe interpretarse con cautela y complementarse con otras métricas de evaluación para una valoración más completa del modelo (Hastie, Tibshirani, & Friedman, 2009).

MAPE: Es una métrica que mide la precisión de un modelo de predicción calculando el promedio de los errores absolutos porcentuales entre las predicciones y los valores reales, expresado como un porcentaje. Un MAPE bajo indica que las predicciones son cercanas a los

valores reales, mientras que un MAPE alto sugiere un mayor error. Esta métrica es especialmente útil en pronósticos y regresiones, ya que permite la comparación entre diferentes modelos o conjuntos de datos. Sin embargo, debe usarse con precaución cuando los valores reales son cero o cercanos a cero, ya que puede llevar a resultados no definidos (Hastie, Tibshirani, & Friedman, 2009).

1.4.3. Marco conceptual

Para un mejor entendimiento se debe tener en cuenta conocimientos previos que llevan acabo el estudio de esta investigación tales como:

SOC: Integra componentes necesarios para el funcionamiento de un ordenador, combina varios componentes electrónicos en único integrado, este incluye uno o más CPU y añade otras cosas como memoria, almacenamiento, GPU controladores e/s, entre otros.

RS485: Este módulo conecta a un microcontrolador o Arduino y permite convertir las señales seriales TTL a RS-485. RS485 se utiliza para comunicaciones serie a distancias más largas que el RS232 directo o TTL, y admite múltiples unidades en el mismo bus (Multi-Drop).

Sistema embebido: Es un sistema de computación diseñado para realizar funciones específicas y cuyos componentes se encuentran integrados en una placa base, estos pueden ser programados directamente el lenguaje ensamblador

Ppm: Partes por millón (ppm), es una unidad de medida de concentración. Se refiere a la cantidad de unidades de la sustancia (agente, etc) que hay por cada millón de unidades del conjunto, se podría tomar la siguiente equivalencia: $10.000 \text{ ppm} = 1 \%$

IPC 2152: Tienen en cuenta especificaciones para asegurar la estabilidad térmica y el rendimiento de la placa. La regulación IPC ha generado huellas de componentes que deben ser estudiados para asegurar su capacidad de fabricación en placas de circuitos.

1.5. Metodología

1.5.1. Paradigma de investigación

Este proyecto se alinea con el paradigma positivista ya que utiliza métodos cuantitativos, mediciones, recolección de datos para obtención de resultados en este caso el valor de macronutrientes nitrógeno, fosforo y potasio, buscando obtener datos medibles lo que permite validar la tecnología en términos de precisión y confiabilidad.

1.5.2. Enfoque de investigación

Este proyecto adopta un enfoque cuantitativo ya que se recolectan datos medibles a partir de las variables de pH, conductividad eléctrica, humedad y temperatura mediante sensores lo cual a través del uso de herramientas estadísticas que relacionan la aplicación tecnología se predice resultados basados en algoritmos de aprendizaje.

1.5.3. Tipo de investigación

El desarrollo de la propuesta de investigación es de tipo aplicada empírica o práctica ya que inicialmente permite recolectar información y a través de esto aplicar conocimientos tecnológicos y de ingeniería el cual hace uso de herramientas que facilitan la solución a un determinado problema, por consecuente que permitadeterminar la información necesaria sobre el déficit de micronutrientes del suelo.

1.5.4. Población y muestra / Unidad de trabajo y unidad de análisis

La investigación se enfoca en los agricultores de papa por lo que la población se centra en los agricultores de papa. La unidad de trabajo son los terrenos de los diferentes municipios del Departamento de Nariño para dar inicio a su etapa productiva donde se realiza medición de variables para dar respuesta sobre el déficit de macronutrientes del suelo (nitrógeno, fosforo y potasio), que en este caso corresponde a la unidad de análisis.

1.5.5. Técnica e instrumentos de recolección de información

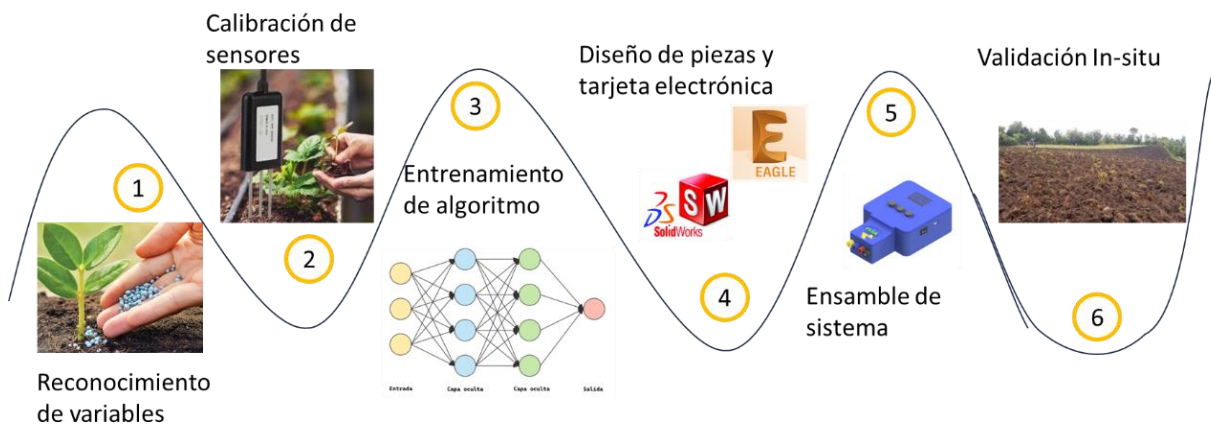
Para la recopilación de información se emplea varias técnicas y herramientas para obtener datos precisos sobre las variables físicas y químicas del suelo en cultivos de papa en la que se utilizan análisis de laboratorio convencional denominado laboratorio agroambiental de la Unión Valle, los cuales se utilizan como parámetro de referencia para calibración de sensores, posteriormente la medición directa en terrenos de cultivos de papa, haciendo uso de sensores para llevar a cabo el procesamiento de datos y la determinación del déficit de macronutrientes.

1.5.6. Descripción metodológica

Para llevar a cabo el desarrollo de este proyecto se tiene en cuenta fases que se encargan de llevar a cabo la ejecución de los objetivos planteados, enfatizando que va dirigido al análisis del suelo en cultivos de papa.

Figura 4

Metodología



1. Revisión bibliográfica acerca de estudios relacionados con el análisis de suelos.

Actividades:

- Identificar y acceder a plataformas académicas como IEEE, ScienceDirect y Springer para buscar estudios relevantes.
- Recopilar información sobre variables fisicoquímicas (pH, conductividad eléctrica, humedad y temperatura) y su relación con los macronutrientes (nitrógeno, fósforo y potasio).
- Clasificar y resumir los estudios encontrados según las variables estudiadas y los métodos utilizados.
- Identificar valores normales de NPK para el cultivo de papa en diferentes tipos de suelo.

Entregables:

- Informe de revisión bibliográfica con referencias y resúmenes de estudios relevantes.
- Tabla de valores normales de variables y macronutrientes ideales en un cultivo de papa.

2. Selección y calibración de sensores de acuerdo a las variables fisicoquímicas.

Actividades:

- Seleccionar sensores comerciales adecuados para medir las variables físicas y químicas identificadas.
- Evaluar la resistencia de los sensores a condiciones adversas, como corrosión y humedad.
- Realizar calibración aplicando las técnicas de calibración en múltiples puntos ya que este usa tres o más soluciones de referencia (p.ej., pH 4, 7 y 10). (Abdul & Kanjalochan, 2023).
- Analizar resultados de la calibración aplicando métodos estadísticos: media, mediana, desviación estándar y rango.
- Determinar errores y ajustar los sensores para garantizar lecturas precisas.

Entregables:

- Informe detallado de calibración con análisis estadístico.
- Tablas donde se visualice datos de sensores con desviación estándar y rango.

3. Creación de Base de datos propia.

Actividades:

- Diseñar una estructura de almacenamiento de datos que incluya pH, conductividad eléctrica, humedad, temperatura y NPK.
- Utilizar herramientas como Excel, plataformas IoT o memorias SDK para registrar datos.
- Monitorear las variables durante un período representativo, considerando la variabilidad del suelo.
- Identificar la correlación de los datos mediante gráficos de dispersión.

Entregables

- Base de datos inicial con registros organizados.
- Reporte que relacione variables fisicoquímicas y macronutrientes.
- Gráficos de tendencias y correlaciones.

4. Evaluación de algoritmos

- Seleccionar algoritmos de aprendizaje automático (regresión lineal, redes neuronales, árboles de decisión, etc.) para predecir valores de NPK.
- Preparar la base de datos dividiéndola en conjuntos de entrenamiento, validación y prueba.
- Evaluar modelos utilizando métricas como MSE, R^2 y RMSE para medir precisión.
- Implementar validación cruzada para evitar sobreajuste.
- Simular predicciones en un entorno controlado y comparar resultados con datos reales.

Entregables

- Informe técnico con resultados de comparación entre algoritmos.
- Código fuente del modelo elegido.
- Visualización gráfica de predicciones frente a valores reales.

5. Diseño de tarjeta electrónica (Eagle) y diseño de piezas (SolidWorks).

Actividades:

- Diseñar el esquema electrónico en Eagle, conectando sensores, microcontrolador y todos sus componentes.

- Crear modelos 3D en SolidWorks para albergar la tarjeta electrónica y proteger los sensores.
- Seleccionar materiales resistentes a la corrosión y a fluctuaciones de temperatura.

Entregables:

- Diseño definitivo del circuito electrónico en formato PCB.
- Modelos 3D de piezas mecánicas.
- Informe de materiales seleccionados.

6. Ensamble sistema

Actividades:

- Ensamblar la tarjeta PCB y conectar sus periféricos.
- Integrar las piezas mecánicas para proteger los componentes electrónicos.
- Realizar pruebas iniciales de conectividad y funcionamiento básico.

Entregables:

- Prototipo funcional ensamblado.
- Documentación de pruebas preliminares.
- Reporte visual (imágenes o video) del ensamblaje final.

7. Validación de la efectividad del prototipo realizando pruebas IN-SITU, con variables fisicoquímicas conocidas.

- Pruebas de dispositivo (precisión) en un cultivo de papa para pruebas en campo.
- Comparar mediciones del dispositivo con sensor NPK ya calibrado.
- Recopilar y analizar datos para ajustar parámetros y mejorar precisión.
- Evaluar la resistencia del sistema ante condiciones ambientales.

2. Presentación de resultados

2.1. Análisis e interpretación de resultados

2.1.1. Análisis del primer objetivo

El cultivo de papa en Nariño es uno de los más destacados de la región, particularmente se siembran tipos de papa como parda, pastusa suprema, capiro y suprema. Este cultivo, además de cubrir la necesidad nacional, se exporta a diferentes países, por lo tanto, para obtener un producto de calidad y mejorar las buenas prácticas agrícolas (BPA) del cultivo, es necesario realizar un análisis de suelos permitiendo conocer las condiciones nutricionales posteriores a su etapa productiva.

Figura 5

Propiedades fisicoquímicas a estudiar




Fuente: Orozco Lab, 2024.

Para ello se tiene en cuenta las variables que afectan al cultivo como pH, conductividad eléctrica, humedad y temperatura en relación con macronutrientes como nitrógeno fosforo y potasio al cual denominaremos (NPK).

2.1.1.1. PH. Esta variable mide el nivel de acides u alcalinidad en un determinado suelo, en este caso para el cultivo de papa es de vital importancia adecuar el terreno a un pH ligeramente acido entre valores de 5.5, 6.5, 7 como lo indica la Figura 6.

Figura 6

Escala de pH en cultivos de papa



Fuente: Info Agronomo, 2024.

Si el pH del suelo es acido (<5) afecta directamente al crecimiento y desarrollo de la planta ya que los nutrientes no son absorbidos de manera efectiva, en cambio si se tiene un suelo demasiado alcalino la planta no absorbe micronutrientes (zinc, hierro y magnesio).

2.1.1.2. Temperatura del suelo. Es una variable fundamental para el crecimiento y desarrollo del cultivo de papa, ya que influye directamente en la germinación, el crecimiento de las raíces, la absorción de nutrientes, y el desarrollo de los tubérculos, su unidad de medida es grados centígrados(°C). La temperatura del suelo también influye en la absorción de nutrientes y en la actividad de los microorganismos que facilitan la disponibilidad de nutrientes. A temperaturas bajas, la absorción de nitrógeno, fósforo y potasio se ralentiza, afectando el desarrollo de la planta. Temperaturas adecuadas (18-29 °C) durante el día y (13-18) durante la noche optimizan la disponibilidad de nutrientes y favorecen la actividad microbiana que beneficia la planta en la Figura 7 se aprecia una temperatura de 23°C.

Figura 7

Temperatura en terreno



Fuente: Dreamstime, 2020.

2.1.1.3. Conductividad Eléctrica denominada (CE). Al aplicar fertilizantes, la CE del suelo aumenta debido a la presencia de macronutrientes en forma de sales solubles, como nitrógeno, fósforo y potasio. Esta variable se convierte en un indicador de los niveles de nutrientes disponibles, permitiendo a los agricultores evaluar si han alcanzado la saturación adecuada o si han aplicado en exceso. Mantenerla en un rango óptimo es crucial, ya que una CE muy elevada por exceso de fertilización puede generar un ambiente salino que dificulta la absorción de agua y nutrientes, provocando estrés hídrico en la planta de papa y afectando su crecimiento y rendimiento. Medir la conductividad después de la fertilización ayuda a ajustar las dosis, asegurando que las plantas tengan acceso suficiente a los nutrientes sin riesgos de salinidad, lo cual beneficia tanto la salud del suelo como la calidad del cultivo. Esta variable utiliza la unidad de medida en decisiemens por metro (ds/m).

2.1.1.4. Humedad. Esta influye en el equilibrio de nutrientes y la disponibilidad de iones en el suelo, esta variable utiliza la unidad de medida de porcentaje (%). La humedad es esencial para que los nutrientes sean transportados hasta las raíces, facilitando la absorción. Sin embargo, niveles excesivos de agua pueden diluir nutrientes importantes, mientras que la sequía limita la movilidad de nutrientes y afecta la absorción Figura 8. En el caso de la papa, es crítico mantener un nivel de humedad adecuado para optimizar la absorción de nutrientes sin causar deficiencias o exceso de salinidad. (Tan, 2011).

Figura 8

Humedad en la planta

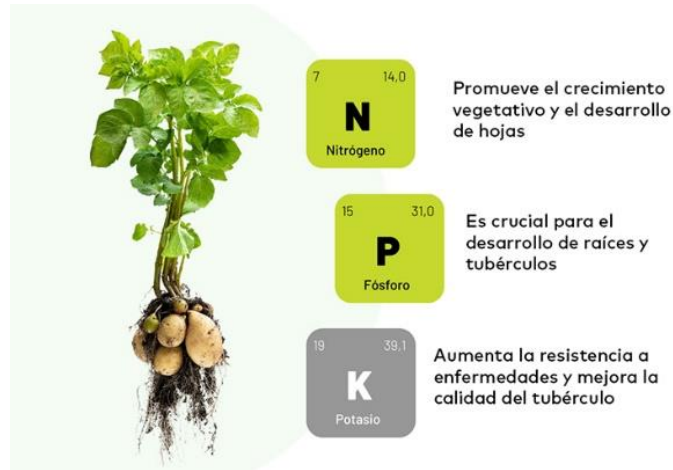


Fuente: Eos Data Analytics, 2024.

El cultivo de papa como cualquier otro cultivo necesita de macronutrientes que aportan su desarrollo, de modo que es de vital importancia tener en cuenta la cantidad de nutrientes que el suelo ya posee, posteriormente aplicar su debida fertilización aportando ventajas a la planta como se aprecia en la Figura 9.

Figura 9

NPK en el cultivo de papa



Fuente: Cambiagro, 2024.

2.1.1.5. Nitrógeno. Es un macronutriente importante en las etapas de germinación y crecimiento de la planta, el déficit de este elemento afecta el desarrollo foliar, afectando los procesos fotosintéticos adquiriendo un color verde amarillento, llegando a marchitarse la planta. Sin embargo, el exceso de este nutriente provoca una coloración verde intensa, retrasando la etapa de cosecha, en (Hidalgo, Mendez, & Salazar, 2022).

2.1.1.6. Fosforo. Para un desarrollo óptimo de la planta es fundamental tener presente este elemento ya que promueve el crecimiento de las raíces y favorece la formación de tubérculos, la falta de fosforo hace que la planta no desarrolle el tallo en un estado óptimo, afectando la formación de tubérculos por ende baja producción.

2.1.1.7. Potasio. Este elemento es el segundo más importante seguido por el nitrógeno, destacándose por generar rendimiento de producción, encargado de transportar agua y nutrientes desde las hojas a los tubérculos permitiéndoles buen crecimiento. Además, se encarga de proteger la planta de factores externos como enfermedades y es capaz de realizar fotosíntesis. Para el cultivo de la papa se recomienda un nivel de potasio entre 180 y 280kg/hectárea \cong **58 y 90**ppm.

De acuerdo a lo planteado se debe tener en cuenta las condiciones ideales para iniciar una tapa de producción como se identifica en la Tabla 3.

Tabla 3

Valores ideales del suelo.

Variable	Valor ideal del suelo	Unidad
Conductividad	500 - 2000 us/cm	Microsimens/centímetros
Temperatura	12 a 23°	Grados centígrados
Humedad	60-80%	Porcentaje
pH	5.5-6.5	Acides
Nitrógeno	20-50mg/kg(ppm)	Miligramo/kilogramo
Fosforo	15-30 mg/kg(ppm)	Miligramo/kilogramo
Potasio	58 -90 mg/kg(ppm)	Miligramo/kilogramo

Los macronutrientes como nitrógeno, fósforo y potasio son altamente sensibles a las variaciones en el pH, la CE, la humedad y la temperatura del suelo. Mantener estos factores dentro de los rangos óptimos para cada nutriente asegura una mayor disponibilidad de nutrientes para las plantas, promoviendo un mejor crecimiento y productividad en cultivos como la papa. La gestión adecuada de estos parámetros es esencial para lograr un equilibrio nutricional en el suelo, optimizando la absorción de NPK y mejorando el rendimiento de los cultivos

2.1.2. Análisis del segundo objetivo

2.1.2.1. Entorno de hardware y software. Con la información obtenida en el transcurso de la investigación y la identificación de las variables fisicoquímicas se tiene en cuenta que la humedad(H), temperatura(T), conductividad eléctrica (CE) y pH permiten correlacionarse con los macronutrientes como nitrógeno, fósforo y potasio (NPK). Con ello se determina sensores que cumplan la lectura de dichas variables por ende para variables de H, T, CE, PH se selecciona un sensor multiparámetros de igual manera para las variables de NPK se utiliza un sensor NPK con referencia CTW. Por lo tanto, se establece un diagrama de lectura igual ya que manejan igual protocolo de comunicación diferencial RS485 ya que utiliza dos cables (A y B) para enviar datos, lo que permite que la señal se transmita de manera más robusta y resistente al ruido eléctrico Figura 10. Así mismo para la conexión electrónica son iguales componentes, cambiando la programación Figura 11.

Figura 10

Diagrama de lectura de sensores

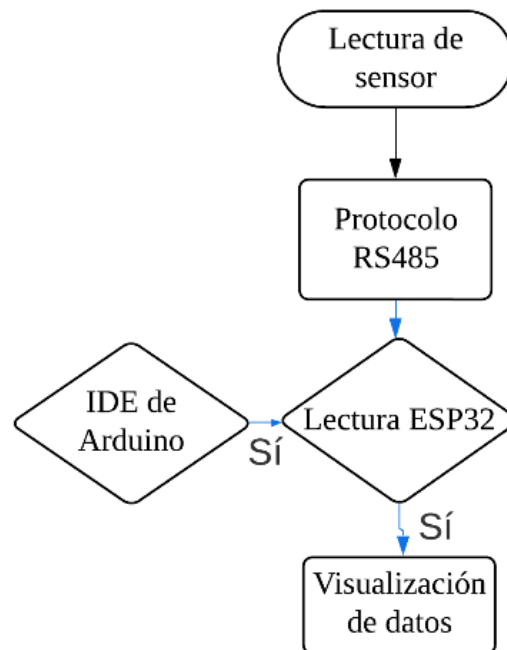



Figura 11

Conexión sensor NPK y multiparámetros.




2.1.2.2. Calibración del sensor (NPK). Para la calibración y análisis del sensor, se definieron tres etapas claves, con el fin de garantizar lecturas precisas o aproximadas para ello se ejecuta etapas para su previa calibración como es medición en agua destilada, suelos arcillosos identificando funcionamiento y respuesta de lectura en la cual se obtuvieron resultado como se identifica en la Tabla 4.

Tabla 4

Lecturas de prueba de sensor NPK


Macronutrientes (ppm)	Prueba en Agua destilada	Macronutrientes (ppm)	Prueba en suelos arcillosos
-----------------------	--------------------------	-----------------------	-----------------------------

Nitrógeno =0 Fósforo=0 Potasio=0		Nitrógeno =6 Fósforo=2 Potasio=3	
--	---	--	---

Como consecuente se lleva a cabo una recolección de muestras de suelo para ser analizadas por laboratorios convencionales y mediante ellas realizar una comparación de resultados respecto al sensor NPK. El muestreo realizado se lleva a cabo en Zigzag como se observa la Figura 12 recolectando dos kilogramos de muestra de suelo entre los 10 puntos dispersos con una profundidad de laboreo de 25 cm y una densidad aparente de 1.41 g/cm³.

Figura 12

Muestras realizadas



De acuerdo a los análisis realizados en San Miguel Putumayo donde se obtuvieron 5 muestras, el laboratorio certificado Agroambiental utiliza métodos diferentes para cada variable como es para fósforo (Bray II), potasio (Absorción atómica), nitrógeno (nitrógeno total Kjeldahl), donde ofrece información con los macronutrientes a estudiar como lo indica la Tabla 5 donde se indica los

valores correspondientes a cada macronutriente y sus unidades. Por lo tanto, sus unidades se representan:

Nitrógeno (%): Mide la cantidad de nitrógeno presente en el suelo como un porcentaje del peso total de la muestra, esencial para el crecimiento y desarrollo de las plantas.

Fósforo (ppm): Indica la concentración de fósforo en el suelo en partes por millón, esencial para la transferencia de energía y el desarrollo de raíces.

Potasio (meq/100g): Mide la cantidad de potasio disponible en el suelo en miliequivalentes por 100 gramos, crucial para la regulación hídrica y la función enzimática.

Tabla 5

Resultados de análisis de suelos

Análisis de suelo	Nitrógeno (%)	Fosforo (ppm)	Potasio (meq/100g)
Análisis 1	0.092	7.61	0.19
Análisis 2	0.090	5.08	0.16
Análisis 3	0.091	9.98	0.17
Análisis 4	0.098	6.48	0.15
Análisis 5	0.088	7.48	0.12

Cabe resaltar que el sensor NPK maneja unidad de lectura de ppm por lo que según a los análisis de suelos se debe convertir a dichas unidades para mejor interpretación, donde se utiliza la plataforma de BioTERRA (<https://bioterra.mx/conversion?v=1>), llegando a obtener los valores que se observa en la Tabla 6, resaltando que 1ppm (partes por millón) equivale a 1 miligramo/kilogramo (mg/kg).

Tabla 6


Resultados de análisis de suelo

Muestras	Nitrógeno (ppm)	Fosforo (ppm)	Potasio (ppm)
1	23.7	7.6	74.3
2	21.5	5.0	50.8
3	22.8	9.9	66.5
4	21.0	6.5	58.7
5	22	7.8	46.9

Resaltando que se tiene cinco análisis de suelos para conocer el rango de desfaz del sensor con respecto al análisis de suelos se lleva a cabo una toma de datos donde se identifica la media, mediana, desviación estándar que permiten una mejor corroboración de lecturas en cada uno de ellos **Anexo B** cada determinado tiempo, llegando a obtener una desviación estándar no muy alta ver Figura 13.

Figura 13

Desviación estándar



Aplicando la técnica de calibración en múltiples puntos, se lleva a cabo un registro de lectura del sensor NPK con respecto a los análisis como se aprecia en la Tabla 8.

Tabla 7

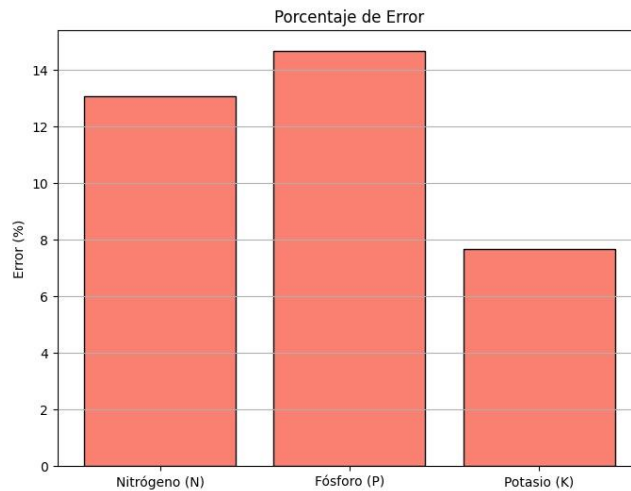
Comparación de lectura de sensor NPK y análisis de suelos

Muestras	Resultados Laboratoriomg/kg			Promedio Resultados Sensor NPKmg/kg		
	N	P	K	N	P	K
1	23,7	7,61	74,3	22,94	7,4	70,2
2	21,5	5,08	50,83	22	5,66	52,4
3	22,8	9,98	66,5	35,4	9,44	62,5
4	21,08	6,49	58,7	20,4	7,7	56,8
5	22	7,84	46,9	22,26	5,09	56,5

Usando los diferentes métodos estadísticos en l variedad de pruebas realizadas se llego a obtener un rango de error del sensor NPK en nitrógeno 13% fosforo 14,2% potasio 7,8%.

Figura 14

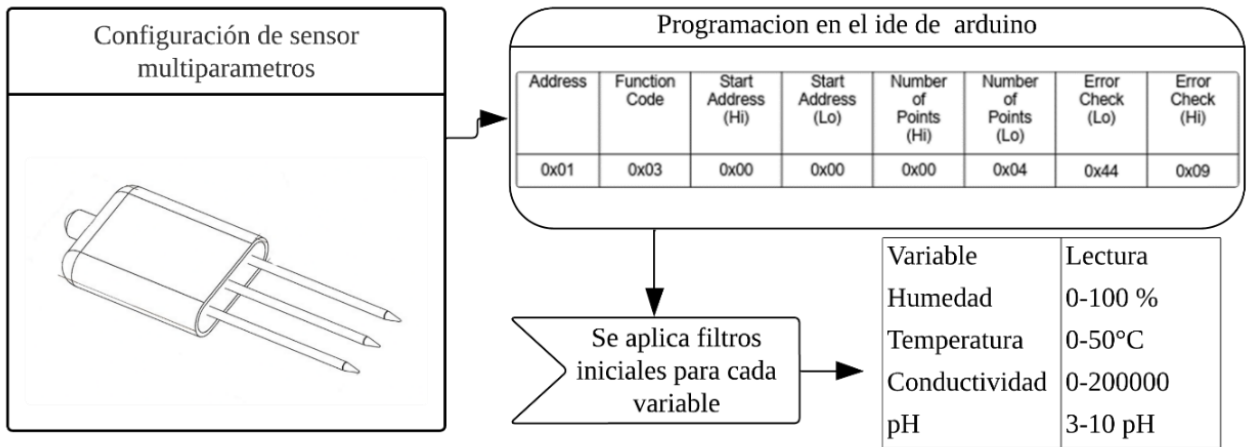
Porcentaje de error sensor NPK.



2.1.2.3. Calibración sensor multiparámetros. La calibración del sensor multiparámetros sigue las indicaciones del Datasheet, aplicando filtros de lectura para valores negativos y fuera de rango, facilitando datos precisos mediante la trama hexadecimal. Cada columna representa valores de lectura, una representación gráfica de dicho sensor se aprecia en la Figura 15.

Figura 15

Lectura de sensor multiparámetros




Por consiguiente, se realizan pruebas de calibración y precisión usando el sensor multiparámetros CWT y el sensor de laboratorio Martini ph55 (pH-Metro), registrando sus datos cada dos minutos en distintas condiciones de suelo y líquido como se aprecia en la Tabla 9, determinando el comportamiento de las variables y rango de desfaz mediante análisis estadísticos como media y rango ver Anexo C.

Tabla 8

Pruebas de lectura en líquido y suelo

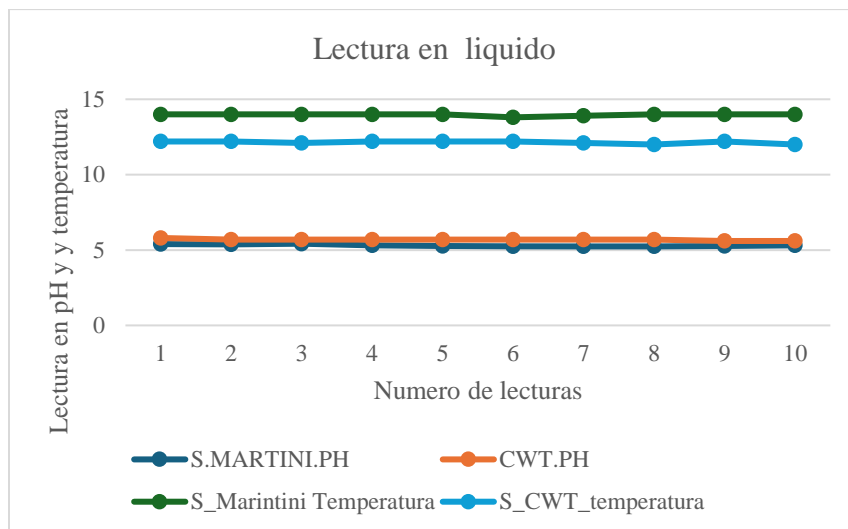
Prueba de pH y temperatura en Suelo	Prueba de pH y temperatura en Líquido
-------------------------------------	---------------------------------------



De acuerdo a ello se identifica en una de las pruebas que el sensor multiparámetros para lecturas de líquido en pH y temperatura su variación es pequeña como en la Figura 16.

Figura 16


Lectura de pH en líquido



De igual manera de las pruebas en suelo (planta 1) se obtiene un comportamiento simultaneo de lecturas de acuerdo a los dos sensores ver Figura 17.

Figura 17

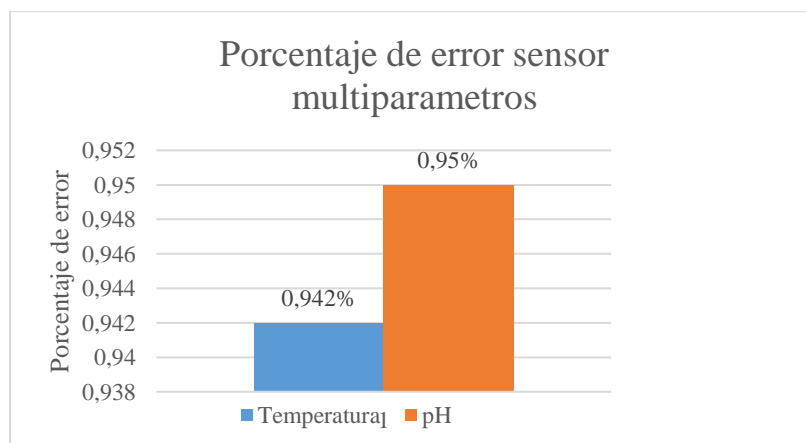
Lectura en suelo



Por ello en las diferentes pruebas se aplica métodos estadísticos donde se obtiene un determinado promedio mediante el número de veces de lectura por lo cual se obtiene un rango menor al 1% para pH y temperatura como se aprecia en la Figura 18.

Figura 18


Porcentaje de error de sensor multiparámetros.



2.1.2.4. Obtención de base de datos. Dado que no se dispone de una base de datos en plataforma para el desarrollo de investigación, se crea una base de datos propia. Esta se genera mediante la plataforma de IoT de ThingSpeak ya que se facilitaba el monitoreo para dichas variables. Esta permite enviar los datos a la nube desde ESP32 vía wifi y almacenarlos en un archivo CSV para su debido análisis y entrenamiento. En esta base de datos se registran variables de humedad, ce, pH, temperatura, humedad, nitrógeno, fosforo y potasio provenientes del sensor multiparámetros y NPK, las cuales son colocadas bajo condiciones preestablecidas Figura 19.

Figura 19

Lectura de variables

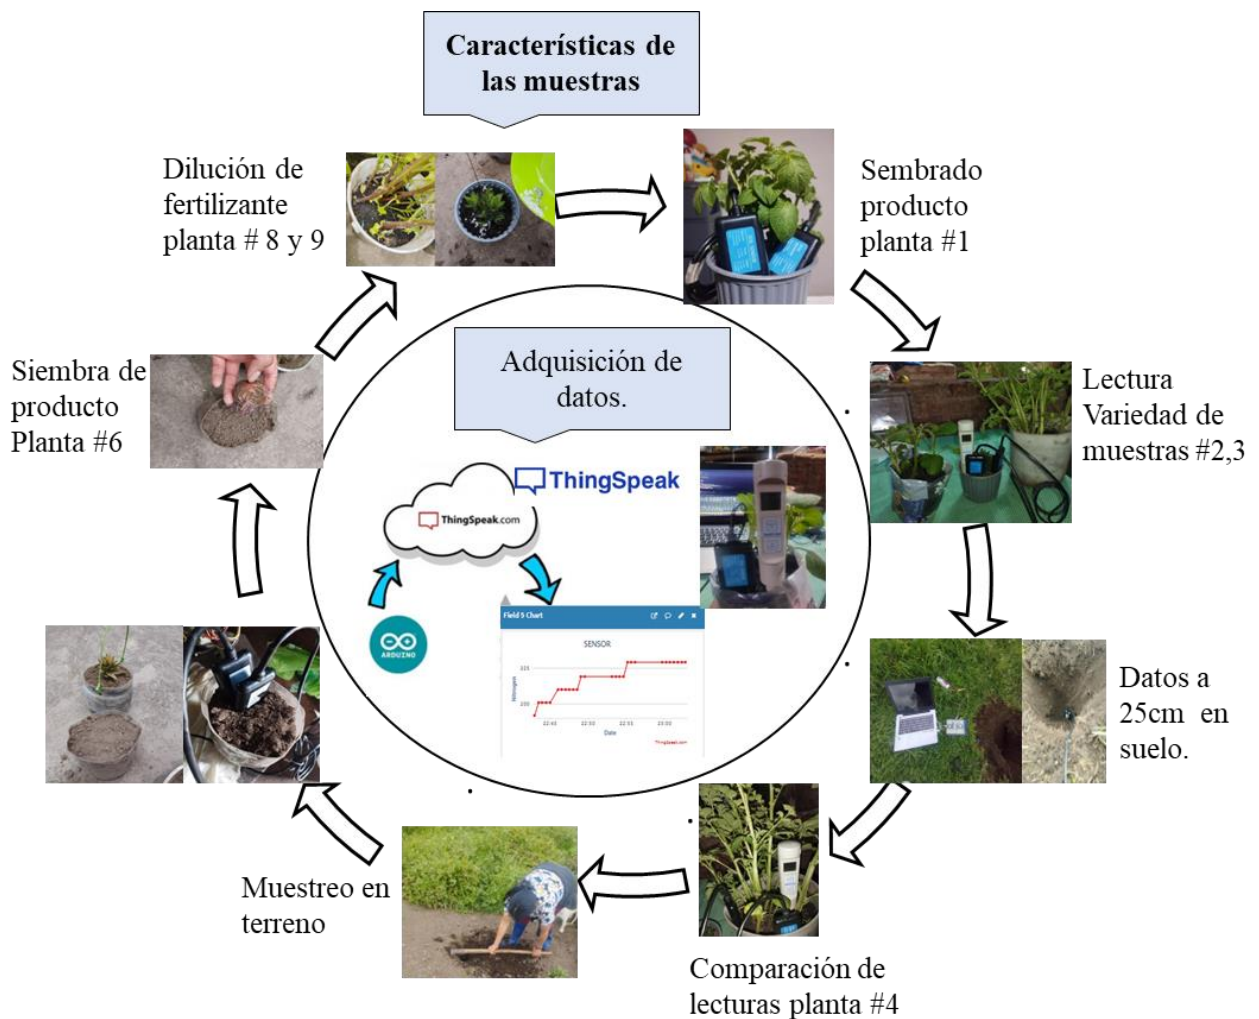


La base de datos se construyó de manera experimental recolectando muestras de diferentes tipos de suelo, seleccionados con base en el conocimiento empírico de agricultores locales. Se incluyeron suelos fértiles e infértiles, sometidos a diversas condiciones para analizar su comportamiento. Se recolectaron 10 muestras representativas, que se acondicionaron bajo distintos tratamientos, como exposición a variaciones de temperatura, aplicación de fertilizantes, riego controlado y simulación de cultivos. Estas condiciones simulan un cultivo real permitiendo evaluar las propiedades fisicoquímicas del suelo.

Parte de los datos se tomaron en terreno a una profundidad de 25 cm, considerando que este es el rango en el que se realizan las labores de preparación del suelo, dicha lectura se realizó en terrenos con características heterogéneas para ampliar la variabilidad y la aplicabilidad de los resultados. En la Figura 20 se evidencia las lecturas realizadas, reflejando la diversidad de condiciones experimentales y proporcionando una base sólida para el análisis mediante inteligencia artificial y la validación del modelo predictivo propuesto.

Figura 20

Características de las muestras

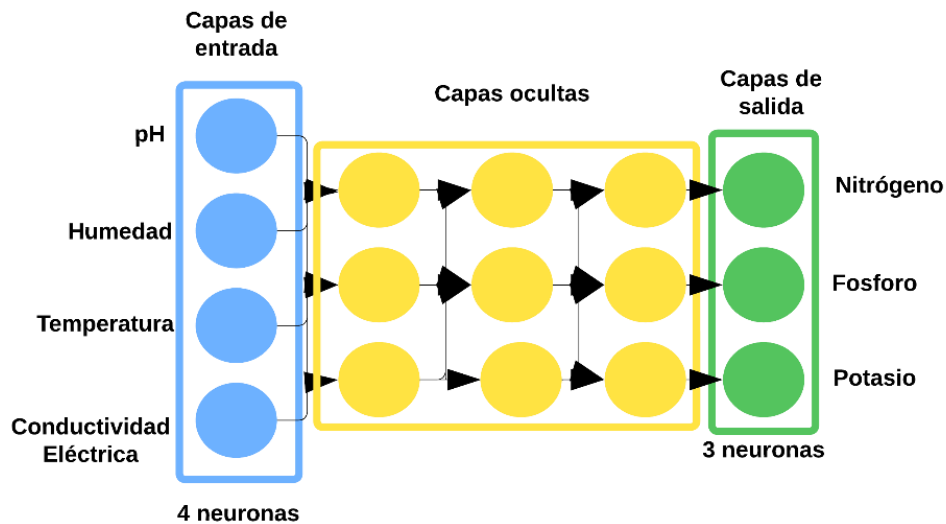


2.1.2.5. Entrenamiento de algoritmo. Teniendo en cuenta la base de datos generada esta permite la implementación de diferentes algoritmos de predicción. Para lo cual se identifica la correlación de los datos utilizando Google colab y sus gráficos correspondientes como se indica en el Anexo B, donde se indica que no tienen relación lineal por ende se decide que datos del algoritmo son los más óptimos para utilizar en el modelo.

En este caso por la naturaleza de los datos se identificó un problema de regresión, ya que el objetivo es predecir valores numéricos de salida correspondientes a los macronutrientes del suelo: nitrógeno, fósforo y potasio. Entre los modelos que se pueden aplicar, destaca el uso de redes neuronales, debido a su capacidad para resolver problemas complejos de manera eficiente, y también la regresión lineal. Las redes neuronales presentan una arquitectura flexible, como se muestra en la Figura 21, donde se define el número de capas de entrada y salida, las capas ocultas, las funciones de activación, la función de pérdida y, finalmente, se evalúa la optimización del algoritmo.

Figura 21

Arquitectura del modelo



De la misma manera identificado la correlación lineal en un modelo de redes neuronales aplicado a una regresión lineal múltiple, la ecuación representativa se basa en el concepto de una combinación ponderada de las entradas (variables independientes) para predecir una salida (variable dependiente). En términos generales, la ecuación tiene la siguiente forma para una sola neurona en la capa de salida:

$$\text{Ec(2)} \quad Y = w_1x_1 + w_2x_2 + \dots + w_nx_n + b$$

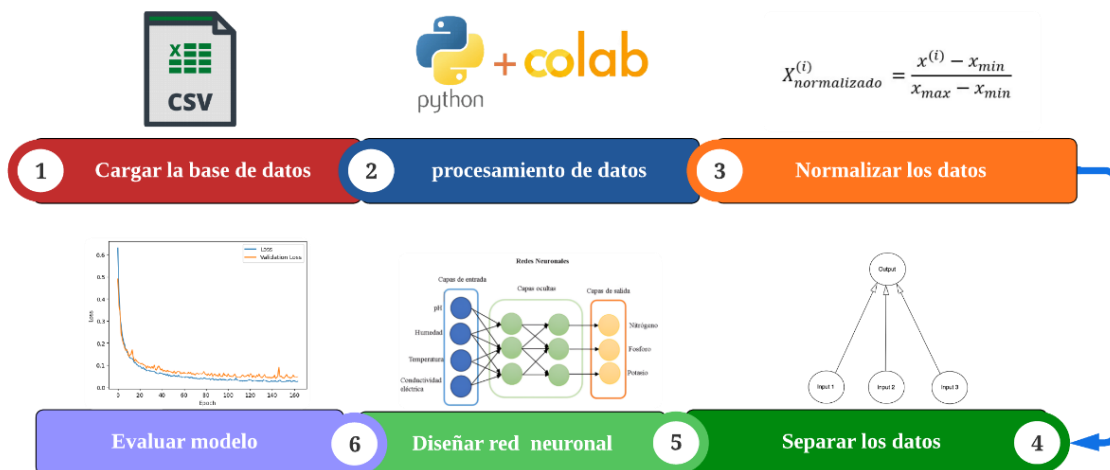
Donde y : es el valor predicho (output), x_1x_2 : son variables de entrada ejemplo pH, ce etc. w_1w_2 : son los pesos asignados a cada entrada, aprendidos durante el entrenamiento, b : es el sesgo, termino adicional que ajusta la predicción.

Para el entrenamiento del modelo, se utilizó Google Colab, aprovechando su entorno en Python y configurando el uso de una GPU T4 para acelerar el proceso de entrenamiento. Los datos fueron previamente cargados en Google Drive, permitiendo así un acceso eficiente y fluido desde el entorno de programación.

Las etapas para el entrenamiento del código se las puede observar en la Figura 22.

Figura 22


Etapas para entrenar algoritmo



2.1.2.5.1. Importar la base de datos. Esto se hace para tener acceso directamente de la plataforma de Google Colab. Para llamar la base de datos se utiliza la librería de pandas esta permite acceder a los archivos ver Figura 23.

Figura 23

Importar base de datos



2.1.2.5.2. Preprocesamiento de datos. Se utilizó la biblioteca panda para acceder a la base de datos y eliminar los datos duplicados, evitando así redundancias en el conjunto Tabla 10. Aunque existen técnicas adicionales de preprocesamiento, como la eliminación de valores anómalos, en este caso no fue necesario aplicarlas, ya que los datos fueron tomados correctamente. Es importante destacar que, según el tipo de problema, pueden requerirse diferentes técnicas de preprocesamiento

Tabla 9

Eliminar datos duplicados

Numero de filas antes preprocesamiento	3330
Numero de filas después del preprocesamiento	3090

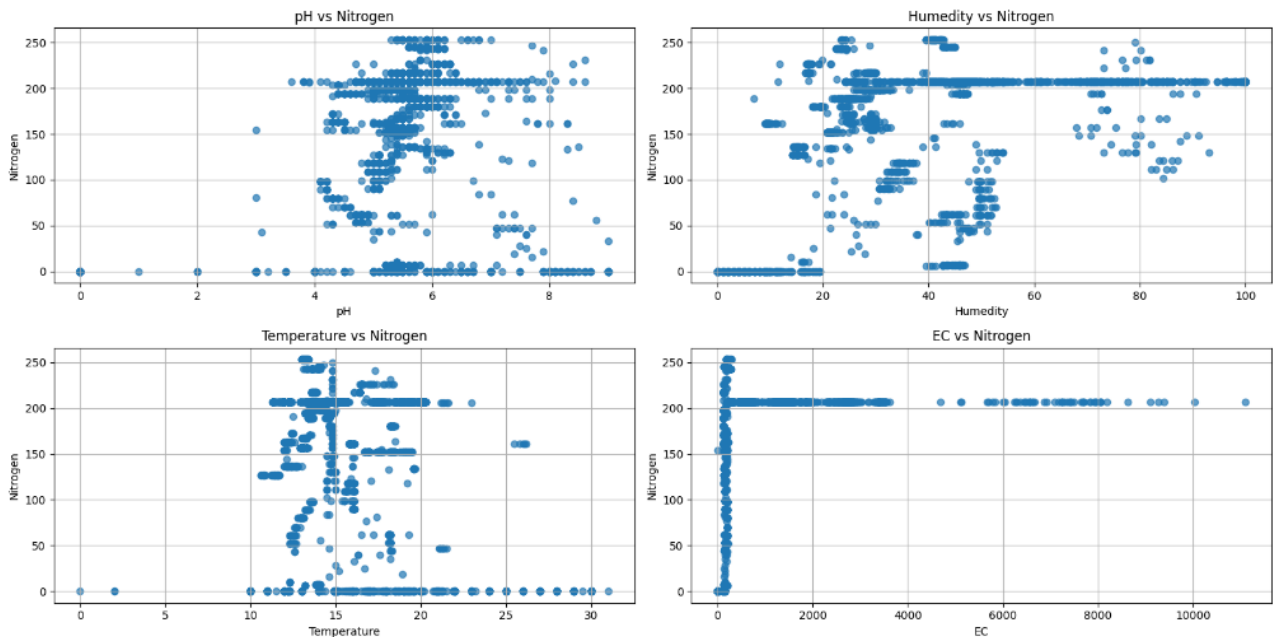
2.1.2.5.3. Normalizar los datos. El proceso de normalización se realizó para asegurar que todos los datos numéricos estuvieran en una escala común, entre 0 y 1, lo cual facilita un entrenamiento más eficiente del modelo. Para ello, se aplicó la ecuación 2 utilizando la media y la desviación estándar de los datos obtenidos mediante la biblioteca pandas.

$$\text{Ec (3)} \quad N_D = \frac{\text{datos} - \text{mediadatos}}{\text{desviaciondatos}}$$

2.1.2.5.4. Visualización de datos. Utilizando la biblioteca matplotlib, se representó gráficamente el comportamiento de las variables de pH, humedad, temperatura y conductividad eléctrica en relación con el contenido de macronutrientes, lo cual permitió identificar posibles patrones comunes. Como se muestra en la Figura 24, la relación entre estas variables no sigue un comportamiento lineal, permitiendo la selección de un modelo más adecuado para abordar el problema de predicción.

Figura 24


Graficas de variables respecto a macronutrientes



2.1.2.5.5. Separar datos. Dado que el modelo utiliza datos de entrada y de salida, se realizó una separación en el conjunto de datos. Las variables de entrada incluyen humedad, temperatura, conductividad eléctrica y pH, mientras que las variables de salida corresponden a los macronutrientes a predecir: nitrógeno, fósforo y potasio ver Figura 25.

Figura 25

Separar datos para entrenamiento



2.1.2.5.6. Diseñar configuración del modelo. En esta etapa, se evaluaron múltiples configuraciones de modelos utilizando redes neuronales usando la biblioteca TensorFlow y modelos de regresión lineal. Con el objetivo de identificar el modelo con mejor desempeño, se aplicó una optimización basada en hiperparámetros, lo cual facilitó la comparación de resultados y la selección del modelo más adecuado. En la red neuronal, se utilizó la función de activación "ReLU" y la activación "Linear" en la capa de salida. La evaluación del desempeño de cada modelo se realizó mediante las métricas de MAE, R^2 score y MSE ver Tabla 11.

Tabla 10

Evaluación de modelos

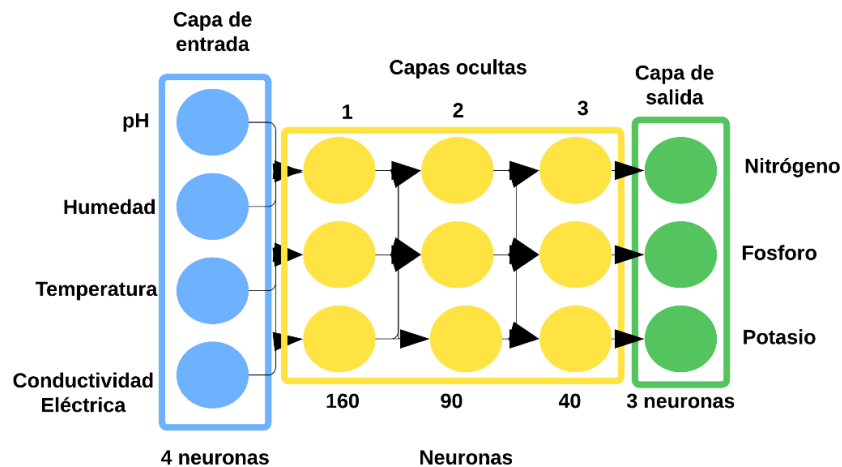
Algoritmo	Input	Tipo	Neuronas	Función de activación	MAE	R2	MSE	Técnicas de regularización	
Configuración 1	4	1:	130	Relu	0,21	0,88	0,117	L2 (0,002) Dropout (0,2)	
		Dense							
		2:		90					Relu
		Dense							
Configuración 2	4	1:	160	Relu	0,075	0,969	0,033	N/A	
		Dense							
		2:		90					Relu
		Dense							
Configuración 3	4	1:	130	Relu	0,115	0,96	0,075	N/A	
		Dense							
		2:		90					Relu
		Dense							
Configuración 4	4	1:	100	Relu	0,125	0,938	0,061	N/A	
		Dense							
		2:		50					Relu
		Dense							

3:					
Dense	20		Relu		
4:					
Dense	3		Linear		
Regresión					
Lineal			0,653	0,22	0,779
					N/A

El modelo con mejor desempeño fue el de redes neuronales en su configuración 3 de acuerdo a la Tabla 11, donde se obtuvo un MAE de 0.115, un resultado favorable que refleja la precisión del modelo en términos de error promedio absoluto. En la métrica R² score, se alcanzó un valor de 0.96, lo cual indica que las predicciones se ajustan adecuadamente a los valores reales. Finalmente, el valor de MSE fue de 0.075; un valor cercano a cero en esta métrica nos dice que el modelo presenta una alta precisión, ajustándose de manera efectiva a los datos reales.

Figura 26


Configuración de red neuronal



2.1.2.5.7. Evaluar modelo. En la Figura 27 se muestra el comportamiento de la función de pérdida ('loss') y la pérdida en validación, evidenciando que el modelo fue entrenado durante 160 épocas. Este gráfico, generado con la librería Matplotlib, permite visualizar la convergencia del modelo, donde a medida que aumentan las épocas, la pérdida disminuye hasta estabilizarse en un punto óptimo. Además, se implementó un monitoreo para evitar el sobreajuste del modelo, asegurando que mantuviera un buen desempeño en los datos de validación.

Figura 27

Grafica de Aprendizaje



A partir de las métricas anteriores, se elaboró una tabla que incluye nuevas métricas, como el val_loss, en el cual se obtuvo un valor óptimo de 0.0343, cercano a cero, lo que indica un buen ajuste del modelo en los datos de validación. Además, se evaluó el Error Porcentual Absoluto Medio (MAPE), que mide el porcentaje de error entre las predicciones y los valores reales. El MAPE resultó en un 21%, lo que da una confiabilidad del 79%, reflejando que el modelo tiene una precisión adecuada para las predicciones realizadas

Tabla 11

Modelo que mejor se desempeña

Característica	Val_loss	MAE	MSE	R_Squared	MAPE
290 neuronas en capas ocultas	0.0343	0.075	0.033	0.96	21 %
Épocas: 160					

Para evaluar el desempeño del modelo de redes neuronales, se construyó una matriz de confusión como complemento a las métricas previamente calculadas. Esta matriz permite un análisis detallado de las predicciones mediante la cual se obtuvo los valores de verdaderos positivos (TP), falsos negativos (FN), falsos positivos (FP) y verdaderos negativos (TN) ver Figura 28 y Tabla 13.

Figura 28

Grafica de aprendizaje




Tabla 12

Resultados de matriz de confusión

Verdaderos negativos (TN)	1188
Falsos positivos (FP)	10
Falsos negativos (FN)	36
Verdaderos positivos (TP)	620

Con estos datos, se pueden calcular métricas adicionales para evaluar el rendimiento del modelo, tales como la precisión, el recall (sensibilidad), el F1-score y la exactitud (accuracy) ver Tabla 14. Estas métricas se evalúan en un rango de 0 a 100%. Cuanto más alto sea su valor, más óptimo es el modelo.

Tabla 13


Métricas evaluadas a partir de matriz de confusión

Precisión	0.98
Recall	0.95
F1-score	0.96
Accuracy	0.97

Dado que el modelo desarrollado aborda un problema de regresión, su desempeño se evaluó gráficamente comparando las predicciones generadas con los valores reales. Como se observa en la Figura 29, la mayoría de las predicciones se ajustan de manera adecuada a los valores reales, lo que indica un buen rendimiento del modelo.

Figura 29

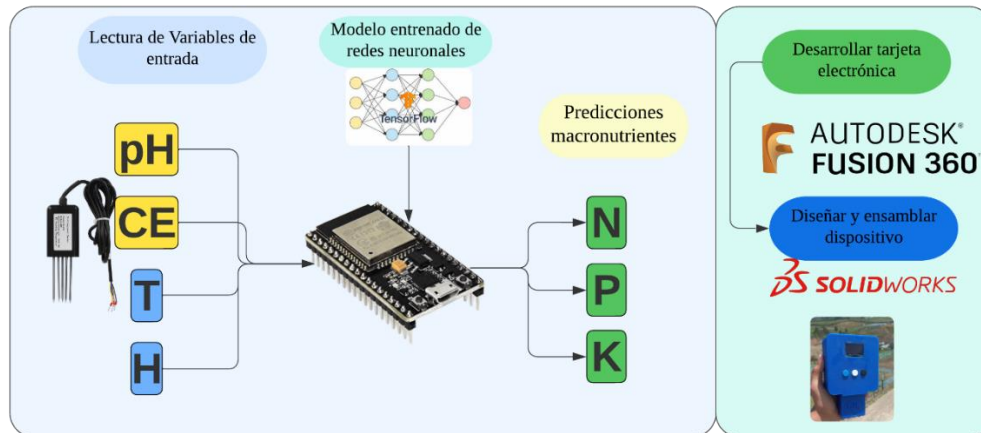
Grafica de predicciones



2.1.2.6. Embeber en modelo. Una vez entrenado el modelo, se procedió a exportarlo utilizando la biblioteca TensorFlow Lite. Esta herramienta permite desarrollar el dispositivo de manera autónoma, evitando la necesidad de una computadora o conexión a internet para realizar las predicciones de macronutrientes. En la Figura 30 se muestra el procedimiento detallado que se llevó a cabo.

Figura 30

Adquisición del modelo



- Obtener lectura de variables del sensor multiparámetros para normalizarlas:
A partir del sensor multiparámetro, se obtuvieron las variables de entrada: temperatura,

humedad, conductividad eléctrica, pH y CE. Estas variables fueron normalizadas utilizando la media y la desviación estándar de cada una, con el objetivo de proporcionar valores adecuados al modelo para su interpretación y permitir la predicción de datos reales. Los valores de media y desviación estándar utilizados para la normalización se detallan en la Tabla 15 y fueron obtenidos al procesar los datos en el entorno de Python.

Tabla 14

Datos de variables

Variable	Media	Desviación
Humedad	43.604	28.522
Temperatura	15.973	3.396
EC	724.526	1209.444
pH	5.304	1.419

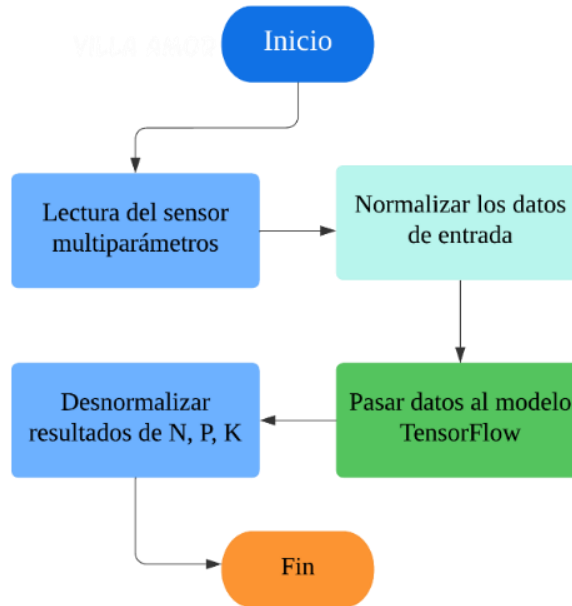
Por lo tanto, se aplicó la ecuación 3 para normalizar las variables, permitiendo así que los valores numéricos se adecuen al modelo previamente entrenado.

$$\text{Ec (4)} \quad N_D = \frac{\text{datos} - \text{mediadatos}}{\text{desviaciondatos}}$$

- Realizar predicción usando el modelo de redes neuronales: Para ello se tiene en cuenta actividades Figura 31, que se deben ejecutar.

Figura 31

Predicción del modelo



Al pasar las variables de entrada por el modelo, se obtienen predicciones de macronutrientes (nitrógeno, fósforo y potasio). Sin embargo, es necesario desnormalizar estos datos, ya que la respuesta está normalizada. Por lo tanto, se utilizan las variables de media y desviación estándar que se encuentran en la Tabla 16.

Tabla 15

Datos de variables

Variable	Media	Desviación
Nitrógeno	158.476	78.081
Fosforo	62.513	77.075
Potasio	94.689	67.800

Estas variables se reemplazaron en la ecuación 5, lo que permitió obtener el valor real de cada

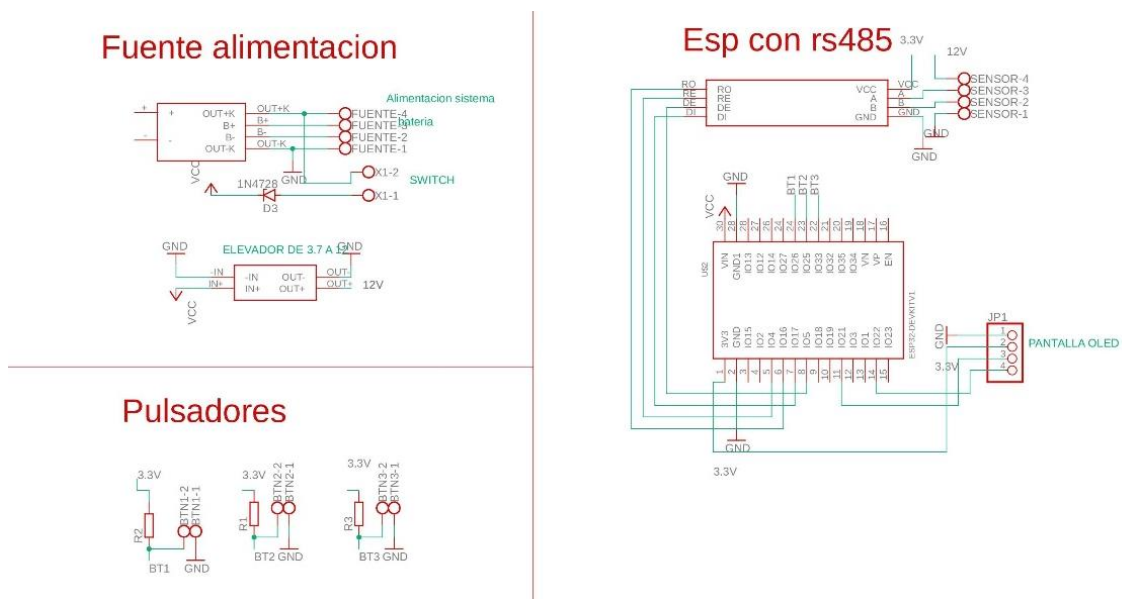
variable en ppm. Estos valores son útiles para ser interpretados por un ingeniero agrónomo.

$$\text{Ec (5)} \quad \text{variable_real} = ((\text{variable} * \text{Desviación_variable}) + \text{Media_variable})$$

2.1.2.7. Diseño de placa electrónica. Anteriormente, todas las pruebas se realizaron en una proto-board. Para el dispositivo final, fue necesario diseñar una tarjeta electrónica. Utilizamos el programa Fusión 360 para crear el diseño ver Figura 32 lo que permitió elaborar el plano eléctrico. Para garantizar el rendimiento y la fiabilidad del producto diseñado, se siguieron las normas IPC 2152 e IPC 6012E.

Figura 32


Diagrama electrónico



También se desarrolló la aplicación de normas para obtener la PCB como es ruteado y visualización de componentes en 3D de la tarjeta electrónica ver Figura 33, permitiendo obtener el diseño en formato Gerber. Este formato es esencial para la fabricación, ya que puede ser utilizado en máquinas CNC para la impresión precisa de los circuitos electrónicos.

Figura 33


Montaje en 3D



Para realizar el ruteado de la PCB, se utilizó una placa Pertinax de una sola capa, hecha de material FR4 reforzada en fibra de vidrio ideal para aplicaciones donde la resistencia y la durabilidad son cruciales. Además, el material FR4 es adecuado para ser utilizado con máquinas CNC ruteadores, seguridad en proceso de fabricación de la PCB ver Figura 34.

Figura 34

Fabricación de circuito



2.1.2.8. Diseñar y ensamblar dispositivo. Para diseñar el dispositivo, se utilizó el software SolidWorks, que permite crear dispositivos desde cero, realizar simulaciones y pruebas, e integrar los componentes electrónicos. Después de diseñar dispositivo en 3D, se exportó en formato STL para imprimir las piezas en una impresora 3D. Para la impresión, se utilizó material de PLA (ácido poliláctico), conocido por su resistencia y para asegurar la durabilidad en campo se le realizó un recubrimiento con laca multisuperficies para recubrir la porosidad del material como se viisualiza en la Figura 35.

Figura 35

Diseño de dispositivo 3D y real




2.1.3. Análisis del tercer objetivo

2.1.3.1. Pruebas IN SITU. Al tener ensamblado el dispositivo, se realizaron pruebas in situ en un terreno de aproximadamente 2 hectáreas ubicado en la vereda Bolívar, del municipio de Iles, con coordenadas geográficas latitud 0.976079° , longitud -77.541288° , y altitud de 2,939.8 metros sobre el nivel del mar Figura 36. El terreno seleccionado se encontraba sembrado papa la cual estaba en etapa de emergencia o brotación, fase crucial para la evaluación de los de macronutrientes (nitrogeno, fosforo y potasio) presentes en el suelo para establecer una etapa de fertilizacion adecuada.

Figura 36

Ubicación de terreno



Para la recolección de los datos en campo se consideró la profundidad de laboreo en el cultivo de papa, la cual es aproximadamente de 25 centímetros debajo de la capa arable. Se seleccionaron cuatro puntos representativos del terreno, en cada uno de los cuales se tomaron mediciones utilizando tanto el sensor multiparámetro integrado con el modelo de predicción de macronutrientes (nitrogeno, fosforo y potasio) y el sensor NPK ver Figura 37, que previamente fue calibrado mediante análisis de suelos Tabla 17. Los datos obtenidos permiten evaluar la precisión del sensor multiparámetro en las predicciones de macronutrientes, al comparar sus resultados con los del sensor NPK.

Figura 37

Lectura de variables



Convecciones para resultados de tabla 12 tabla humedad (H), temperatura(T), conductividad electrica (CE), nitrogeno(N), fósforo (P), potasio(K).

Tabla 16

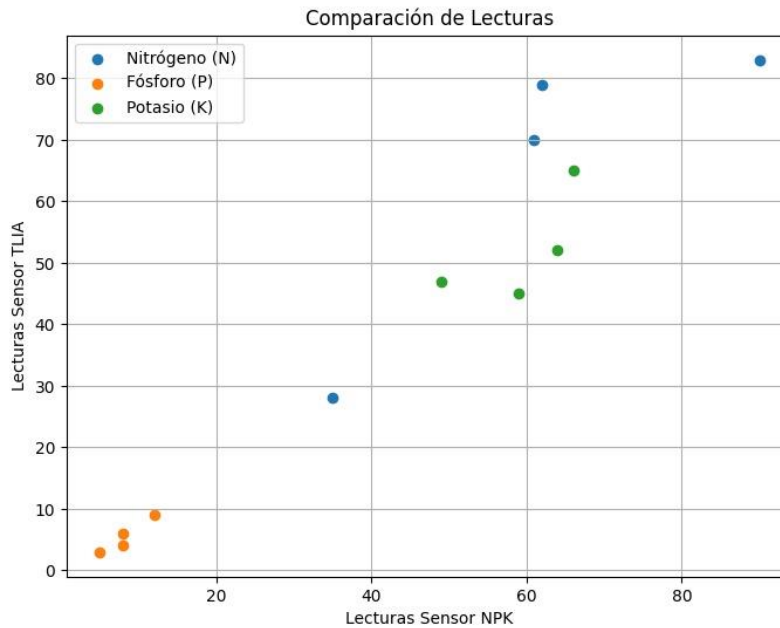
Resultados In- situ

Sensor multiparametros				Predicciones NPK (ppm)			Sensor NPK (ppm)		
H(%)	T(°C)	CE(ds/m)	pH	N	P	K	N	P	K
60	19	17	7	79	4	52	62	8	64
34	23	13	7	28	9	47	35	12	49
61	19	13	6	72	8	65	90	8	66
60	19	16	7	70	3	45	61	5	59

A partir de estos datos, se obtuvo un gráfico para visualizar las variables y sus dispersiones ver Figura 38.

Figura 38

Dispersión de datos



Para evaluar la precisión del dispositivo inteligente en comparación con el sensor NPK, se calcularon tres métricas clave. La Media del Error Absoluto (MAE) que identifica la desviación promedio entre las lecturas del dispositivo y las del sensor NPK.

La Desviación Estándar del Error evalúa la consistencia de las predicciones, y por ultimo el Porcentaje de Error mide el desfase relativo. Estos análisis ayudan analizar la precisión del dispositivo como se observa en la Tabla 18, estos valores no son tan altos lo que representa que se tiene buenas predicciones respecto al sensor NPK.

Tabla 17

Métricas de respuesta


Metricas	N (nitrógeno)	P (fósforo)	K (potasio)
Media del error Absoluto MAE	10 ppm	2.75 ppm	7.25 ppm

Desviación estandar del error	4.12 ppm	0.83 ppm	5.80 ppm
Porcentaje de error (%)	17.49	35	12.02

En la Figura 39 se observa el porcentaje de error para cada uno de los macronutrientes donde el fósforo tiene un valor de 35% siendo este el más alto respecto a los otros.

Figura 39

Porcentaje de error en macronutrientes



Para evaluar el dispositivo inteligente en general, se obtuvo un porcentaje de error del 21,50%, una Media del Error Absoluto (MAE) de 6,66 ppm y una Desviación Estándar del Error de 5,10 ppm. Estos resultados indican que el dispositivo tiene un porcentaje de confiabilidad del 78,5%, lo cual representa un buen desempeño.

2.2. Discusión

Durante la calibración del sensor NPK, se obtuvo una desviación estándar de 1.6 ppm para nitrógeno, 2.16 ppm para fósforo y 10.6 ppm para potasio. Estos resultados indican que no fue necesario ajustar el sensor, ya que las variaciones observadas se debían a las propiedades del suelo, las cuales cambian según el punto de muestreo. Además, el desfase del sensor se mantuvo dentro de los rangos aceptables, demostrando que su precisión es adecuada.

La calibración del sensor multiparámetro, se evaluaron las variables de pH y temperatura. Para el pH, se obtuvo un desfase de 2.38, mientras que para la temperatura el desfase fue de 2.3 °C. Estas mediciones se calibraron utilizando sensores comerciales. Para las variables de humedad y conductividad eléctrica, se siguieron las especificaciones del datasheet del sensor. En consecuencia, no fue necesario realizar ningún ajuste adicional, ya que los valores obtenidos eran confiables.

De acuerdo con el estudio realizado para determinar el nivel de macronutrientes en el suelo, se implementaron modelos de aprendizaje automático, destacándose el modelo de redes neuronales, el cual fue desarrollado utilizando la biblioteca TensorFlow. Los resultados obtenidos, con métricas de error absoluto medio (MAE=0.075), error cuadrático medio (MSE=0.033), coeficiente de determinación ($R^2=0.96$) y error absoluto porcentual medio (MAPE=21%), demuestran una respuesta óptima del modelo al entrenamiento aplicado. Estos indicadores sugieren una alta precisión en la predicción de macronutrientes

La validación in-situ del dispositivo se obtuvo un porcentaje de error del 21.50%, con una media del error absoluto (MAE) de 6.66 ppm y una desviación estándar del error de 5.10 ppm, lo que equivale a una confiabilidad del 78.5%. Estos resultados reflejan un buen desempeño del dispositivo, por lo que es una herramienta eficaz para apoyar a los agricultores en el monitoreo y manejo de la fertilidad del suelo, facilitando decisiones de fertilización basadas en datos y contribuyendo a mejorar la precisión y sostenibilidad en la producción agrícola.

3. Conclusiones

De las variables estudiadas en cultivos de papa, el pH y la conductividad eléctrica se destacan como las más importantes ya que tienen una correlación con la presencia de macronutrientes de lo cual están directamente relacionadas con el crecimiento de las plantas. Así mismo se tiene en cuenta los análisis de laboratorios convencionales permitiendo analizar las propiedades fisicoquímicas del suelo, implementando buenas prácticas agrícolas desde la preparación del suelo hasta la fertilización en cada etapa de desarrollo del cultivo.

Los sensores con referencia CTW se programaron de acuerdo al Datasheet dado por el fabricante, permitiendo obtener respuestas de lectura en los rangos establecidos, los cuales fueron calibrados a partir de análisis de suelos y sensores de laboratorio, obteniendo buenos resultados de modo que no fue necesario un previo ajuste de sensores, cabe resaltar que para obtener unos resultados precisos la humedad del suelo no se debe alterar ya que este tipo de sensores correlaciona las variables a partir de la conductividad eléctrica del suelo y la salinidad.

En el desarrollo de esta investigación, se creó una base de datos propia diseñada bajo condiciones predeterminadas presentes en diferentes tipos de suelo. Este proceso incluyó un monitoreo constante utilizando la plataforma IoT ThingSpeak, donde se registraron las siete variables clave necesarias para el análisis. Los datos recolectados fueron almacenados y procesados en formato CSV, lo que permitió su fácil manejo y análisis posterior. Como resultado de este esfuerzo, se logró publicar la base de datos en la plataforma IEEE DataPort, destacándose por su nivel de detalle y completitud. Esta publicación es particularmente relevante debido a la escasez de bases de datos similares que integren de manera exhaustiva las variables de suelos agrícolas con parámetros físico-químicos, ofreciendo un recurso valioso para la comunidad científica y agrícola. Este avance no solo facilita el acceso a datos estructurados, sino que también promueve investigaciones futuras que permitan mejorar la precisión de modelos predictivos y prácticas agrícolas sostenibles.

El desarrollo de este dispositivo, se implementó exitosamente el modelo previamente entrenado en un ESP32 utilizando la biblioteca TensorFlow Lite. Esto permitió que el dispositivo funcione

de manera autónoma, realizando predicciones de macronutrientes a partir de datos obtenidos por un sensor multiparámetros, sin requerir otros recursos externos.

Este dispositivo ha demostrado ser una herramienta integral y eficiente para el análisis de suelos, a partir de lecturas del sensor multiparámetros (pH, conductividad eléctrica, temperatura, humedad), se obtienen niveles de NPK con un determinado modelo de aprendizaje. Lo cual al obtener tres variables como nitrógeno, fósforo y potasio desde un solo sensor, no solo simplifica el proceso de análisis de suelos, sino que también representa una alternativa accesible frente a otros dispositivos de alto costo en el mercado.

El desarrollo de este dispositivo permitió la integración de sensores opcionales, haciéndolo una herramienta escalable y versátil. Además del sensor multiparámetros integra un modelo de predicciones de macronutrientes, en este se incorporó la opción de utilizar el sensor CTW NPK en caso de que el sensor multiparámetro no esté disponible durante el proceso. Esta flexibilidad garantiza que el dispositivo pueda adaptarse a diferentes necesidades en el análisis de suelos.

De tal manera que, para proporcionar autonomía en campo, el dispositivo incorpora una batería recargable de litio junto con su propio puerto de carga, lo que permite una operatividad continua de aproximadamente 2 horas en terreno siendo este dispositivo un apoyo a la lectura de macronutrientes y que el agrónomo pueda brindar un plan de fertilización útil.

Entre las principales limitaciones identificadas en el dispositivo, se encuentra la incapacidad de almacenar las variables medidas, lo que dificulta el seguimiento continuo del estado del suelo a lo largo del tiempo. Esto obliga al usuario a recurrir a herramientas externas para registrar los datos, lo que puede generar pérdidas de información. Por lo tanto, se recomienda desarrollar un servidor web que permita almacenar y organizar las variables del suelo de manera centralizada, facilitando la visualización histórica y el análisis comparativo.

Adicionalmente, durante la recolección de la base de datos en diferentes tipos de suelo, se observó que no existía una correlación lineal clara entre las variables pH, humedad, temperatura y

conductividad eléctrica con los macronutrientes (nitrógeno, fósforo y potasio). Esta falta de relación lineal llevó a que el modelo utilizado presentara un margen de error del 21.5%. Por lo tanto, se sugiere explorar otros modelos de aprendizaje automático más avanzados, como redes neuronales convolucionales o modelos de aprendizaje profundo optimizados, que puedan capturar mejor las relaciones no lineales entre las variables. Además, es esencial realizar una retroalimentación constante de la base de datos, incorporando nuevos registros provenientes de diferentes tipos de suelos y condiciones ambientales para mejorar la precisión del modelo. Estas mejoras contribuirán a fortalecer el rendimiento del dispositivo y a consolidarlo como una herramienta confiable para la agricultura de precisión.

Los sensores CTW NPK y CTW multiparámetros deben calibrarse exclusivamente mediante análisis en suelos, ya que presentan imprecisiones al medir variables en líquidos. Esto se debe a que estos sensores están diseñados para trabajar con la conductividad característica de los suelos, donde las propiedades físicas y químicas influyen en las mediciones. Por lo tanto, es fundamental realizar pruebas de calibración específicas en muestras representativas de suelo para garantizar lecturas precisas y confiables, adecuadas para las aplicaciones agrícolas.

El uso de este tipo de sensores permitió a los agricultores optimizar sus procesos productivos al proporcionar información precisa sobre las condiciones del suelo, facilitando una gestión más eficiente de los recursos y reduciendo el uso excesivo de fertilizantes. Esta tecnología respalda los principios de la agricultura sostenible promovidos por la FAO y contribuye a los Objetivos de Desarrollo Sostenible (ODS) globales, en especial los relacionados con la acción climática, la seguridad alimentaria y la gestión sostenible de los recursos naturales.

4. Recomendaciones

Para obtener lecturas precisas de los sensores CTW, tanto el sensor NPK como el multiparámetro deben usarse bajo condiciones donde la humedad del suelo no se vea alterada por lluvias u otros factores externos, ya que esto garantiza que los datos reflejen las condiciones reales del suelo. Además, se recomienda actualizar y retroalimentar la base de datos del dispositivo con nuevas variables que mejoren el modelo, permitiendo mediciones más precisas y confiables para el agricultor. A futuro, es recomendable implementar un sistema autónomo de fertilización para el cultivo de papa, de modo que el dispositivo pueda sugerir planes de fertilización óptimos sin necesidad de un ingeniero agrónomo. Esto facilitaría que los agricultores gestionen de forma autónoma la fertilización de sus cultivos, optimizando sus recursos y aumentando su eficiencia.

Para facilitar a los usuarios el acceso digital a los resultados del análisis de suelos, se recomienda desarrollar una plataforma en línea que, aprovechando la conectividad del módulo ESP32, permitiendo almacenar y visualizar las variables de manera remota. Esto brindaría a los agricultores acceso directo a los datos y la posibilidad de realizar un seguimiento más preciso de las condiciones del suelo, mejorando así la toma de decisiones para la gestión agrícola.

Para mejorar la precisión del dispositivo en futuros desarrollos, se recomienda explorar y evaluar otros algoritmos de aprendizaje automático como modelos de Gradient Boosting, Random Forest o redes neuronales profundas, que pueden ofrecer mejoras en la precisión en comparación con la regresión lineal y configuraciones básicas de redes neuronales. Además, sería beneficioso aplicar técnicas de optimización de hiperparámetros mediante Random Search, para encontrar configuraciones óptimas que maximicen la precisión.

Referencias bibliográficas

- Abdullahi, & Madhieddine, S. (2015). Technology Impact on Agricultural Productivity: A Review of Precision Agriculture Using Unmanned Aerial Vehicles. 388-400. doi:10.1007/978-3-319-25479-1_29
- Andrade, Mancini, Santos, & Silva. (2022). Proximal sensor data fusion for Brazilian soil properties prediction: Exchangeable/available macronutrients, aluminum, and potential acidity. Geoderma Regional. Obtenido de <https://doi.org/10.1016/j.geodrs.2022.e00573>
- Araujo, Cartajena, & Castillo, .. a. (2021). Manual de papa para pequeños productores. INIAP. Mejía-Ecuador. Obtenido de <https://hdl.handle.net/10568/111534>
- Ashina, Khaydukova, & Kirsanov. (2021). One shot evaluation of NPK in soils by “electronic tongue”,. ScienceDirect. Obtenido de <https://www.sciencedirect.com/science/article/pii/S0168169921002258>
- Bah, Balasundram, & Husni. (2012). Sensor technologies for precision soil nutrient management and monitoring. American Journal of Agricultural and Biological Sciences, 43-39. Obtenido de <http://thescipub.com/abstract/10.3844/ajabssp.2012.43.49>
- Bollero, Bullock, & Sudduth. (2003). Comparison of electromagnetic induction and direct sensing of soil electrical conductivity. Agronomy Journal, 472-482. Obtenido de <https://doi.org/10.2134/agronj2003.4720>
- Castellanos, & Morales. (2016). Análisis crítico sobre la conceptualización de la agricultura de precisión. Ciencia en su PC, 23-33. Obtenido de <https://www.redalyc.org/journal/1813/181349391004/html/>

Chenzhen, Guaozhong, & Zhang. (2022). Quantifying the relationships of soil properties and crop growth with yield in a NPK fertilizer application maize field. *Computers and Electronics in Agriculture*. Obtenido de <https://www.sciencedirect.com/science/article/pii/S0168169922003283>

Department of Soil Science, F. o. (2013). Evaluating long-term impact of land use on selected soil physical quality indicators. Obtenido de <https://doi.org/10.1071/SR12360>

FAO. (2023). Portal de Suelos de la FAO. Obtenido de <https://www.fao.org/soils-portal/soil-survey/clasificacion-de-suelos/sistemas-numericos/propiedades-quimicas/es/>

FAO, & MADS. (2018). Ministerio de Ambiente y Desarrollo. Obtenido de <https://archivo.minambiente.gov.co/images/AsuntosambientalesySectorialyUrbana/pdf/suelo/Guide buenas practicas para la gestion y uso sostenible de los suelos en areas rurales.pdf>

Garcia, Huang, M., He, Y., Hernández, & Song. (2007). Prediction of soil macronutrients content using near-infrared spectroscopy. *Computers and Electronics in Agriculture*, 144-153. Obtenido de <https://www.sciencedirect.com/science/article/pii/S0168169907001019>

Guido, & Müller. (2017). *Introduction to Machine Learning whit Python*. doi:9781449369897

Halvin, J. L. (2022). *Soil Fertility and Fertilizers*.

Islam, Kabir, & Oliullah. (2023). Sistema de IoT con aprendizaje automático habilitado para monitoreo de nutrientes del suelo y recomendación de cultivos. *Journal of Agriculture and Food Research*. Obtenido de <https://www.sciencedirect.com/science/article/pii/S2666154323003873>

Jhoan, Q. (2023). La inteligencia artificial en la agricultura y el cultivo de la caña de azúcar. *Revista General*. Obtenido de <https://procana.org/site/la-inteligencia-artificial-en-la-agricultura-y-el-cultivo-de-la-cana-de-azucar/>

Khaydukova, Kirsanov, Sarkar, & Mukherjee. (2021). One shot evaluation of NPK in soils by “electronic tongue”. *Computers and Electronics in Agriculture*. doi:10.1016/j.compag.2021.106208

Laboratorio GEydsa. (s.f.). *Propiedades Biológicas en el Suelo*.

Mekala, & Viswanathan. (2020). Sensor Stipulation with THAM Index for Smart Agriculture Decision-Making IoT System. 1909–1940. Obtenido de <https://doi.org/10.1007/s11277-019-06964-0>

Noguera, Ros, & Serna. (2010). *Guia Practica de Sensores*. Obtenido de <https://books.google.es/books?hl=es&lr=&id=CuoXCd6ZZqwC&oi=fnd&pg=PR9&dq=sensores++>

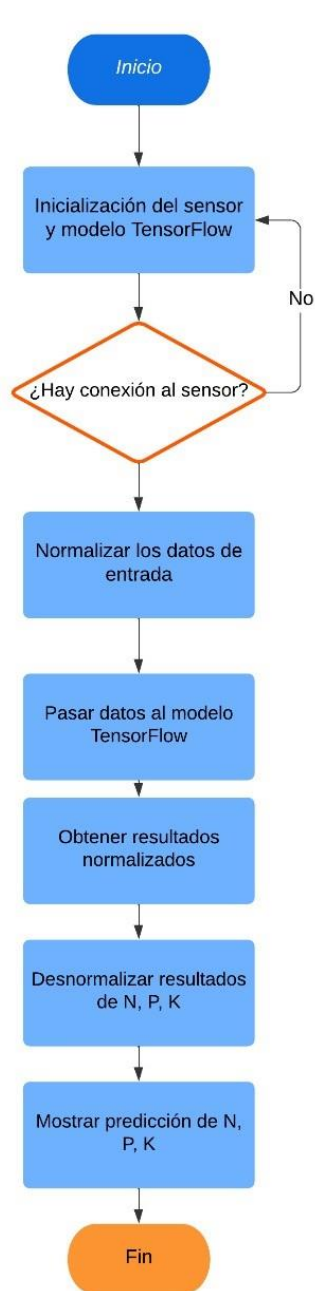
Paul, E. A. (2007). *Soil Microbiology, Ecology, and Biochemistry*. (E. A. Paul, Ed.)

Paul, E. A. (2014). *Soil Microbiology, Ecology, and Biochemistry*. Academic Press (parte de Elsevier).

Perret, Villalobos, Bolaños, & Fuentes. (2020). Desarrollo de métodos de análisis de espectroscopia y algoritmos de aprendizaje automático para la evaluación de algunas propiedades del suelo en Costa Rica. *Agronomía Costarricense*, págs. 139-154. Obtenido de <https://doi.org/10.15517/RAC.V44I2.43108>

Anexos

Anexo A. Pseudocódigo de entrenamiento



Anexo B Análisis estadístico de calibración sensor NPK

N(ppm): 23,7

Datos sensor Análisis 1				
Nitrógeno	1ra	2da	3ra	Rango
1	22	23	23	1
2	22	24	23	2
4	23	24	21	3
5	23	23	24	1
6	23	25	24	2
7	21	23	24	3
8	23	23	23	0
9	23	22	22	1
10	22	24	22	2
Promedio			22,93	
X_max			25	
X_min			21	
Desviación estandar			0,958	
Error Relativo %			0,042	4,2

K(ppm): 50,83

Datos sensor Analisis 1				
Potasio	1ra	2da	3ra	RANGO
1	49	53	55	6
2	49	55	56	7
4	50	55	70	20
5	50	55	55	5
6	51	48	51	3
7	51	57	51	6
8	49	49	50	1
9	49	51	52	3
10	53	51	51	2
Promedio			52,4	
X_max			70	
X_min			48	
Desviación estándar			4,3264	
Error Relativo %			0,0825	8,2

P(ppm): 7,61

Datos sensor Análisis 1				
Fósforo	1ra	2da	3ra	RANGO
1	7	7	7	0
2	7	7	8	1
4	8	8	7	1
5	8	7	7	1
6	7	8	8	1
7	8	6	8	2
8	7	7	8	1
9	7	7	9	2
10	7	8	7	1
Promedio			7,40740741	
X_max			9	
X_min			6	
Desviación estandar			0,63604906	
Error Relativo %			0,08586662	8,6

Anexo C. Análisis estadístico de sensor multiparámetros

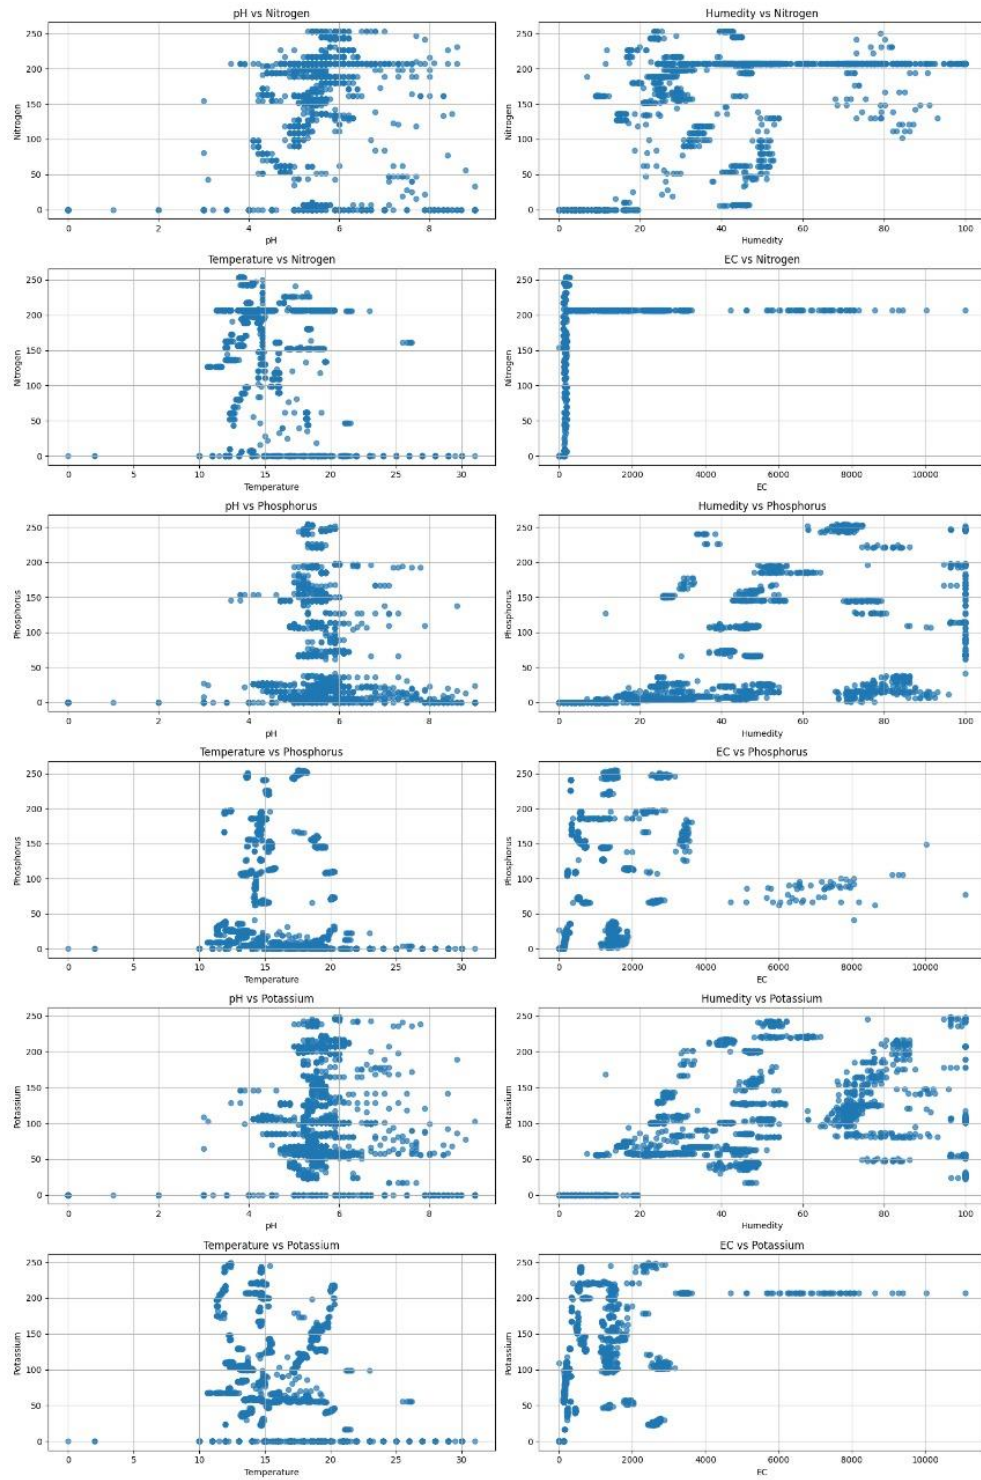
Planta 1		
Temperatura	S.MARTINI	CWT
1.	17,5	16,4
2.	17,8	16,3
3.	18	16,3
4.	18,1	16,2
5.	18,2	16,2
6.	18,2	16,2
7.	18,3	16,1
8.	18,3	16,1
9.	18,3	16,1
10.	18,3	16,1
Promedio	18,1	16,2
Rango		1,9
Desviación estándar		0,105
Error relativo %	0,006506744	0,651 %

Planta 1		
PH	S.MARTINI	CWT
1.	7,67	7,6
2.	7,67	7,5
3.	7,67	7,5
4.	7,67	7,5
5.	7,67	7,5
6.	7,69	7,4
7.	7,67	7,4
8.	7,69	7,3
9.	7,69	7,4
10.	7,69	7,3
PROMEDIO	7,678	7,44
RANGO		7,678
Desviación estándar		0,091
Error relativo %	0,0123	1,23 %


Planta 2		
Temperatura	S.MARTINI	CWT
1.	15,9	14,3
2.	16	14,5
3.	16,2	14,6
4.	16,2	14,8
5.	16,2	14,8
6.	16,2	14,9
7.	16,2	14,8
8.	16,2	14,9
9.	16,1	14,8
10.	16	14,7
PROMEDIO	16,12	14,71
RANGO	1,471	1,41
Desviación estándar		0,181383571
Error relativo %	0,01233063	1,23 %

Planta 2		
PH	S.MARTINI	CWT
1.	7,16	7,2
2.	7,14	7,2
3.	7,08	7,2
4.	7,07	7,2
5.	7,03	7,2
6.	7,01	7,2
7.	6,98	7,2
8.	6,97	7,1
9.	6,96	7,1
10.	6,93	7,1
PROMEDIO	7,033	7,17
RANGO		-0,137
Desviación estándar		0 0,048304589
Error relativo %	0,00673704	0,67 %

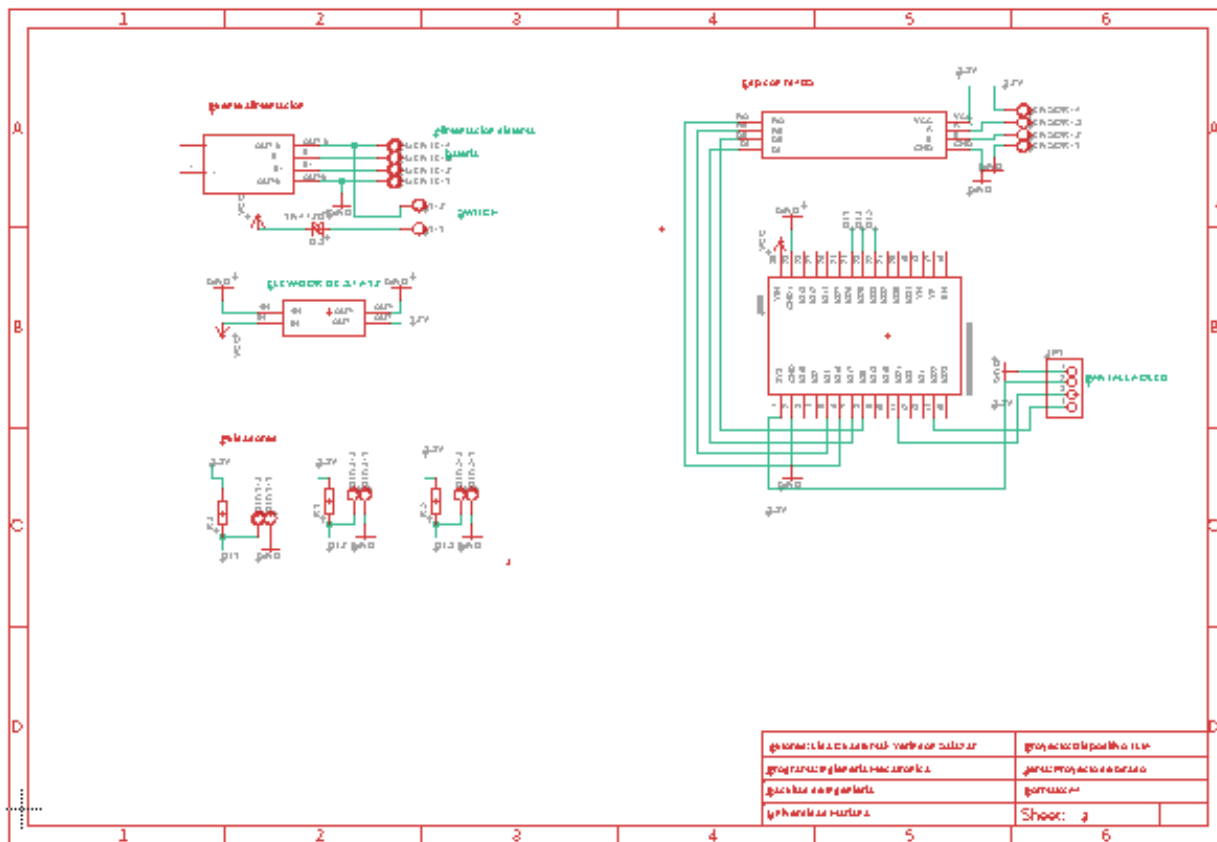
Anexo D. Correlación de Conductividad, humedad, temperatura, pH con respecto a nitrógeno, fosforo y potasio



Anexo E. Plano en SolidWorks de dispositivo para PCB



Anexo F. Plano Electrónico para circuito PCB



Anexo G. Base de datos.



The screenshot shows the IEEE DataPort website interface. At the top, there is a navigation bar with the IEEE DataPort logo, links for DATASETS, SUBMIT A DATASET, and COMPETITIONS, a search icon, and the IEEE logo. Below the navigation bar is a banner with the word "Datasets" in large white font on a blue background with a globe, and "Standard Dataset" in smaller white font on the right. The main content area features the title "DATASET DE PROPIEDADES FISICOQUÍMICAS DEL SUELO PARA DETERMINAR MACRONUTRIENTES EN CULTIVOS DE PAPA" in orange. To the left of the text is a small image of a data file. To the right, there is a metadata section with the following information:

Citation:	YERINSON AYENDI SALAZAR CANACUAN (<i>Universidad Mariana</i>)	Views:	132
Author(s):	LIDA YISELY CUASTUMAL TEPUD (<i>Universidad Mariana</i>)	Categories:	Agriculture Artificial Intelligence Machine Learning
Submitted by:	Yerinson Salazar	Keywords:	Humedad, temperatura, conductividad eléctrica, pH, nitrógeno, fosforo, potasio
Last updated:	Fri, 11/08/2024 - 10:15		


YERINSON AYENDI SALAZAR CANACUAN, LIDA YISELY CUASTUMAL TEPUD. (2024). Dataset de Propiedades Fisicoquímicas del Suelo para determinar Macronutrientes en cultivos de papa. IEEE Dataport. <https://dx.doi.org/10.21227/srfm-m316>

Anexo H. Análisis 1 de laboratorio convencional

LABORATORIO AGROAMBIENTAL		LABORATORIO DE ANÁLISIS DE SUELOS, TEJIDO VEGETAL Y FERTILIZANTES										F-LAB-013 Rev 02 30/01/2018				
Beneficiario		N° Identificación		Finca		Finca / Corregimiento		Municipio, Departamento		Informe de Laboratorio N°						
Roberto Ramiro Acosta		97.445.539		El Porvenir		El Guayabal		San Miguel, Putumayo		S-217						
Identificación de la muestra: LOTE 1		Cultivo - Edad		Fecha de toma		Fecha ingreso al Lab.		Fecha de resultados		Código Laboratorio						
a.s.n.m. (m)	295	Profundidad (cm)	25	Cacao - 11	No reporta	Marzo 07 de 2023	Marzo 16 de 2023			23-444						
RESULTADOS ANÁLISIS QUÍMICO DE SUELO																
Parámetro	pH	C.E	Materia Orgánica	Nitrógeno Total	P (Fósforo)	S (Azufre)	Ca (Calcio)	Mg (Magnesio)	K (Potasio)	Al (Aluminio)	Fe (Hierro)	Mn (Manganeso)	Cu (Cobre)	Zn (Zinc)	B (Boro)	Carbono Orgánico
Resultado	5,17	0,026	3,49	0,092	7,61	3,77	2,09	0,71	0,19	0,26	11,90	5,41	0,18	0,40	0,35	2,03
Unidades	N.A.	(dSm)	%	%	ppm	ppm	(meq/100g)	(meq/100g)	(meq/100g)	(meq/100g)	ppm	ppm	ppm	ppm	ppm	%
RELACIONES IONICAS Y SATURACION DE BASES								RESULTADOS OTROS ANALISIS Y GRANULOMETRIA								
Parámetro	% Ca	% Mg	% K	% Al	Ca / Mg	Mg / K	(Ca+Mg)/K	CIC	Parámetro	Densidad Aparente	Arena	Arcilla	Limo	Clasificación Textural		
Resultado	64,4	21,9	5,7	8,00	2,95	3,82	15,09	3,25	Resultado	1,31	40,17	31,84	27,99	FRANCO ARCILLOSO		
Interpretación	Medio	Alto	Alto	Óptimo	Adecuado	Adecuado	Adecuado	N.A.	Unidades	g/cm ³	%	%	%	NA		

INTERPRETACION GENERAL DE FERTILIDAD DEL SUELO

PARAMETRO	ESTADO
ACIDEZ/BASICIDAD	
pH	Acido Fuerte
Aluminio Intercambiable	Óptimo
ELEMENTOS MAYORES	
Materia Orgánica (Carbono Org.)	Medio
N (Nitrógeno Total)	Medio
P (Fósforo)	Bajo
K (Potasio)	Bajo
ELEMENTOS SECUNDARIOS	
Ca (Calcio)	Bajo
Mg (Magnesio)	Bajo
S (Azufre)	Bajo
ELEMENTOS MENORES	
Hierro	Bajo
Manganeso	Bajo
Cobre	Bajo
Zinc	Bajo
Boro	Bajo



Métodos de Análisis	
pH y CE	Electrométrico.
Textura	Boyucos
Mat. Org	Walkley-Black
P	Fósforo disponible (Blay II)
Fe, Mn, Zn, Cu	Extracción con DTPA, Absorción Atómica
S	Azufre (Turbidimetría)
B	Boro (Azometría)
Ca, Mg, K, CICE	Axialito de Anonio 1N pH 7, Absorción Atómica
N	Nitrógeno Total (Kjeldahl)

Observaciones

*Los resultados reportados en el presente informe corresponden exclusivamente a la muestra analizada y no a otras muestras de la misma procedencia
 *Las submuestras serán almacenadas por un periodo de tiempo de dos meses después, serán desechadas
 * Muestra tomada por: Agroambiental ____ Cliente
 *Si tiene alguna inquietud sobre los resultados, por favor comuníquese con la Dirección Técnica del Laboratorio

Alex Cuy Patiño
 Química - PQ 0192
 Dirección Técnica de Laboratorio

Anexo I. Análisis 2 de laboratorio convencional

LABORATORIO AGROAMBIENTAL		LABORATORIO DE ANÁLISIS DE SUELOS, TEJIDO VEGETAL Y FERTILIZANTES						F-LAB-013 Rev 02 30/01/2018								
Beneficiario		N° Identificación		Finca		Vereda / Corregimiento		Municipio, Departamento		Informe de Laboratorio N°						
Ever Nereo Belancourt Chavez		18.157.763		El Jardin		El Afilador		San Miguel, Putumayo		S-221						
Identificación de la muestra: LOTE 1		Cultivo - Edad		Fecha de toma		Fecha ingreso al Lab.		Fecha de resultados		Código Laboratorio						
a.s.n.m. (m)	292	Profundidad (cm)	25	Cacao - 10		No reporta		Marzo 07 de 2023		Marzo 16 de 2023						
RESULTADOS ANÁLISIS QUÍMICO DE SUELO																
Parámetro	pH	C.E	Materia Orgánica	Nitrógeno Total	P (Fósforo)	S (Azufre)	Ca (Calcio)	Mg (Magnesio)	K (Potasio)	Al (Aluminio)	Fe (Hierro)	Mn (Manganeso)	Cu (Cobre)	Zn (Zinc)	B (Boro)	Carbono Orgánico
Resultado	5,21	0,048	3,44	0,091	9,98	6,78	1,44	0,66	0,17	0,24	27,77	1,15	0,52	0,30	0,40	2,00
Unidades	N.A.	(dSm)	%	%	ppm	ppm	(meq/100g)	(meq/100g)	(meq/100g)	(meq/100g)	ppm	ppm	ppm	ppm	ppm	%
RELACIONES IONICAS Y SATURACION DE BASES								RESULTADOS OTROS ANALISIS Y GRANULOMETRÍA								
Parámetro	% Ca	% Mg	% K	% Al	Ca / Mg	Mg / K	(Ca+Mg)/K	CIC	Parámetro	Densidad Aparente	Arena	Arcilla	Limo	Clasificación Textural		
Resultado	57,4	26,1	6,9	9,55	2,20	3,76	12,03	2,51	Resultado	1,41	52,48	29,94	17,58	FRANCO ARCILLO ARENOSO		
Interpretación	Medio	Alto	Alto	Óptimo	Adecuado	Adecuado	Adecuado	N.A.	Unidades	g/cm ³	%	%	%	NA		

INTERPRETACION GENERAL DE FERTILIDAD DEL SUELO

PARÁMETRO	ESTADO
ACIDEZ/BASICIDAD	
pH	Ácido Fuerte
Aluminio Intercambiable	Óptimo
ELEMENTOS MAYORES	
Materia Orgánica (Carbono Org.)	Medio
N (Nitrógeno Total)	Medio
P (Fósforo)	Bajo
K (Potasio)	Bajo
ELEMENTOS SECUNDARIOS	
Ca (Calcio)	Bajo
Mg (Magnesio)	Bajo
S (Azufre)	Bajo
ELEMENTOS MENORES	
Hierro	Medio
Manganeso	Bajo
Cobre	Bajo
Zinc	Bajo
Boro	Bajo



Métodos de Análisis	
pH y CE	Electrométrico.
Textura	Bouyucos
Mat Org	Walkley-Black
P	Fósforo disponible (Bray II)
Fe, Mn, Zn, Cu	Extracción con DTPA. Absorción Atómica
S	Azufre (Turbidimetría)
B	Boro (Azometina)
Ca, Mg, K, CICE	Acetato de Amonio 1N pH 7. Absorción Atómica
N	Nitrógeno Total (Kjeldahl)

Observaciones

- * Los resultados reportados en el presente informe corresponden exclusivamente a la muestra analizada y no a otra(s) muestras de la misma procedencia
- * Las contramuestras serán almacenadas por un periodo de tiempo de dos meses, después, serán desechadas
- * Muestra tomada por: Agroambiental ___ Cliente X
- * Si tiene alguna inquietud sobre los resultados, por favor comuníquese con la Dirección Técnica del Laboratorio

Alix Cuy
Alix Cuy Patiño
Química - PQ 1792
Dirección Técnica de Laboratorio

Anexo J. Análisis 3 de laboratorio convencional

LABORATORIO AGROAMBIENTAL		LABORATORIO DE ANÁLISIS DE SUELOS, TEJIDO VEGETAL Y FERTILIZANTES										F-LAB-013 Rev 02 30/01/2018					
Km vía La Unión - La Victoria, Centro Administrativo ASORUT/ 316 8718691- 3504428290 - La Unión, Valle																	
Beneficiario		N° Identificación		Finca		Vereda / Corregimiento		Municipio, Departamento		Informe de Laboratorio N°							
Maria Lourdes Barragan		59.824.686		No reporta		Los Guaduales		San Miguel, Putumayo		S-216							
Identificación de la muestra: LOTE 1		Cultivo - Edad		Fecha de toma		Fecha ingreso al Lab.		Fecha de resultados		Código Laboratorio							
a.s.n.m. (m)	379	Profundidad (cm)	25	Cacao - 7	No reporta	Marzo 07 de 2023	Marzo 16 de 2023	23-443									
RESULTADOS ANÁLISIS QUÍMICO DE SUELO																	
Parámetro	pH	C.E	Materia Orgánica	Nitrógeno Total	P (Fósforo)	S (Azufre)	Ca (Calcio)	Mg (Magnesio)	K (Potasio)	Al (Aluminio)	Fe (Hierro)	Mn (Manganeso)	Cu (Cobre)	Zn (Zinc)	B (Boro)	Carbono Orgánico	
Resultado	5,17	0,111	3,72	0,098	12,05	9,36	2,14	0,77	0,19	0,26	15,66	3,59	2,25	0,91	0,48	2,16	
Unidades	N.A.	(dSm)	%	%	ppm	ppm	(meq/100g)	(meq/100g)	(meq/100g)	(meq/100g)	ppm	ppm	ppm	ppm	ppm	%	
RELACIONES IONICAS Y SATURACION DE BASES								RESULTADOS OTROS ANALISIS Y GRANULOMETRÍA									
Parámetro	% Ca	% Mg	% K	% Al	Ca / Mg	Mg / K	(Ca+Mg)/K	CIC	Parámetro	Densidad Aparente	Arena	Arcilla	Limo	Clasificación Textural			
Resultado	63,7	22,9	5,7	7,74	2,78	4,05	15,32	3,36	Resultado	1,40	53,18	28,45	18,37	FRANCO ARCILLO ARENOSO			
Interpretación	Medio	Alto	Alto	Optimo	Adecuado	Adecuado	Adecuado	N.A.	Unidades	g/cm3	%	%	%	NA			
INTERPRETACION GENERAL DE FERTILIDAD DEL SUELO																	

PARÁMETRO	ESTADO
ACIDEZ/BASICIDAD	
pH	Ácido Fuerte
Aluminio Intercambiable	Optimo
ELEMENTOS MAYORES	
Materia Orgánica (Carbono Org.)	Medio
N (Nitrógeno Total)	Medio
P (Fósforo)	Bajo
K (Potasio)	Bajo
ELEMENTOS SECUNDARIOS	
Ca (Calcio)	Bajo
Mg (Magnesio)	Bajo
S (Azufre)	Bajo
ELEMENTOS MENORES	
Hierro	Bajo
Manganeso	Bajo
Cobre	Medio
Zinc	Bajo
Boro	Bajo




Métodos de Análisis	
pH y CE	Electrométrico.
Textura	Boyucos
Mat. Org	Walkley-Black
P	Fósforo disponible (Bray II)
Fe, Mn, Zn, Cu	Extracción con DTPA. Absorción Atómica
S	Azufre (Turbidimetría)
B	Boro (Azometina)
Ca, Mg, K, CICE	Acetato de Amonio 1N pH 7. Absorción Atómica
N	Nitrógeno Total (Kjeldahl)

Observaciones

- * Los resultados reportados en el presente informe corresponden exclusivamente a la muestra analizada y no a otra(s) muestras de la misma procedencia
- * Las contramuestras serán almacenadas por un periodo de tiempo de dos meses, después, serán desechadas
- * Muestra tomada por: Agroambiental ____ Cliente X
- * Si tiene alguna inquietud sobre los resultados, por favor comuníquese con la Dirección Técnica del Laboratorio

Alix Cuy
Alix Cuy Patiño
Química - PQ 1792
Dirección Técnica de Laboratorio

Anexo K. Análisis 4 de laboratorio convencional

		LABORATORIO AGROAMBIENTAL LABORATORIO DE ANÁLISIS DE SUELOS, TEJIDO VEGETAL Y FERTILIZANTES Km vía La Unión - La Victoria, Centro Administrativo ASORUT/ 316 8718691- 3504428290 - La Unión, Valle						F-LAB-013 Rev 02 30/01/2018								
Beneficiario			N° Identificación		Finca	Vereda / Corregimiento	Municipio, Departamento		Informe de Laboratorio N°							
Erley Reinaldo Hernandez Benavidez			1.126.447.876		Selva Alegre	El Rosal	San Miguel, Putumayo		S-215							
Identificación de la muestra: LOTE 1			Cultivo - Edad		Fecha de toma	Fecha ingreso al Lab.	Fecha de resultados		Código Laboratorio							
a.s.n.m. (m)	372	Profundidad (cm)	25	Cacao	No reporta	Marzo 07 de 2023	Marzo 16 de 2023	23-442								
RESULTADOS ANÁLISIS QUÍMICO DE SUELO																
Parámetro	pH	C.E	Materia Orgánica	Nitrógeno Total	P (Fósforo)	S (Azufre)	Ca (Calcio)	Mg (Magnesio)	K (Potasio)	Al (Aluminio)	Fe (Hierro)	Mn (Manganeso)	Cu (Cobre)	Zn (Zinc)	B (Boro)	Carbono Orgánico
Resultado	5,03	0,026	3,71	0,098	6,17	4,36	1,13	0,61	0,15	0,32	8,73	0,24	0,02	0,19	0,35	2,16
Unidades	N.A.	(dSim)	%	%	ppm	ppm	(meq/100g)	(meq/100g)	(meq/100g)	(meq/100g)	ppm	ppm	ppm	ppm	ppm	%
RELACIONES IONICAS Y SATURACION DE BASES								RESULTADOS OTROS ANALISIS Y GRANULOMETRIA								
Parámetro	% Ca	% Mg	% K	% Al	Ca / Mg	Mg / K	(Ca+Mg)/K	CIC	Parámetro	Densidad Aparente	Arena	Arcilla	Limo	Clasificación Textural		
Resultado	51,1	27,6	6,8	14,48	1,85	4,07	11,60	2,21	Resultado	1,43	58,56	22,78	18,66	FRANCO ARCILLO ARENOSO		
Interpretación	Medio	Alto	Alto	Optimo	Bajo Ca	Adecuado	Adecuado	N.A.	Unidades	g/cm3	%	%	%	NA		
INTERPRETACION GENERAL DE FERTILIDAD DEL SUELO																

PARÁMETRO	ESTADO
ACIDEZ/BASICIDAD	
pH	Ácido muy Fuerte
Aluminio Intercambiable	Optimo
ELEMENTOS MAYORES	
Materia Orgánica (Carbono Org.)	Medio
N (Nitrógeno Total)	Medio
P (Fósforo)	Bajo
K (Potasio)	Bajo
ELEMENTOS SECUNDARIOS	
Ca (Calcio)	Bajo
Mg (Magnesio)	Bajo
S (Azufre)	Bajo
ELEMENTOS MENORES	
Hierro	Bajo
Manganeso	Bajo
Cobre	Bajo
Zinc	Bajo
Boro	Bajo



Métodos de Análisis	
pH y CE	Electrométrico.
Textura	Bouyucos
Mat Org	Walkley-Black
P	Fósforo disponible (Bray II)
Fe, Mn, Zn, Cu	Extracción con DTPA. Absorción Atómica
S	Azufre (Turbidimetría)
B	Boro (Azometina)
Ca, Mg, K, CICE	Acetato de Amonio 1N pH 7. Absorción Atómica
N	Nitrógeno Total (Kjeldahl)

Observaciones

- *Los resultados reportados en el presente informe corresponden exclusivamente a la muestra analizada y no a otra(s) muestras de la misma procedencia
- *Las contramuestras serán almacenadas por un periodo de tiempo de dos meses, después, serán desechadas
- * Muestra tomada por: Agroambiental ___ Cliente X
- * Si tiene alguna inquietud sobre los resultados, por favor comuníquese con la Dirección Técnica del Laboratorio


 Alix Cuy Patiño
 Química - PQ 1752
 Dirección Técnica de Laboratorio

Anexo L .Análisis 5 de laboratorio convencional

	LABORATORIO AGROAMBIENTAL		F-LAB-013 Rev 02 30/01/2018
	LABORATORIO DE ANÁLISIS DE SUELOS, TEJIDO VEGETAL Y FERTILIZANTES Km vía La Unión - La Victoria, Centro Administrativo ASORUT/ 316 8718691- 3504428290 - La Unión, Valle		

Beneficiario				N° Identificación	Finca	Vereda / Corregimiento	Municipio, Departamento	Informe de Laboratorio N°
Yeiny Manuela Muñoz				1.126.455.420	No reporta	El Rosario	San Miguel, Putumayo	S-214
Identificación de la muestra: LOTE 1				Cultivo - Edad	Fecha de toma	Fecha ingreso al Lab.	Fecha de resultados	Código Laboratorio
a.s.n.m. (m)	339	Profundidad (cm)	25	Cacao - 5 años	No reporta	Marzo 07 de 2023	Marzo 16 de 2023	23-441

RESULTADOS ANÁLISIS QUÍMICO DE SUELO																
Parámetro	pH	C.E	Materia Orgánica	Nitrógeno Total	P (Fósforo)	S (Azufre)	Ca (Calcio)	Mg (Magnesio)	K (Potasio)	Al (Aluminio)	Fe (Hierro)	Mn (Manganeso)	Cu (Cobre)	Zn (Zinc)	B (Boro)	Carbono Orgánico
Resultado	4,66	0,055	3,39	0,090	9,11	5,92	1,78	0,76	0,28	0,48	19,37	3,01	0,17	0,37	0,39	1,97
Unidades	NA	(dSm)	%	%	ppm	ppm	(meq/100g)	(meq/100g)	(meq/100g)	(meq/100g)	ppm	ppm	ppm	ppm	ppm	%

RELACIONES IONICAS Y SATURACION DE BASES								
Parámetro	% Ca	% Mg	% K	% Al	Ca / Mg	Mg / K	(Ca+Mg)/K	CIC
Resultado	53,9	23,0	8,5	14,55	2,34	2,71	9,07	3,30
Interpretación	Medio	Alto	Alto	Óptimo	Adecuado	Aceptable	Aceptable	N.A.

RESULTADOS OTROS ANALISIS Y GRANULOMETRÍA					
Parámetro	Densidad Aparente	Arena	Arcilla	Limo	Clasificación Textural
Resultado	1,40	38,91	34,74	26,35	FRANCO ARCILLOSO
Unidades	g/cm3	%	%	%	NA

INTERPRETACION GENERAL DE FERTILIDAD DEL SUELO

PARÁMETRO	ESTADO
ACIDEZ/BASICIDAD	
pH	Ácido muy Fuerte
Aluminio Intercambiable	Óptimo
ELEMENTOS MAYORES	
Materia Orgánica (Carbono Org.)	Medio
N (Nitrógeno Total)	Medio
P (Fósforo)	Bajo
K (Potasio)	Bajo
ELEMENTOS SECUNDARIOS	
Ca (Calcio)	Bajo
Mg (Magnesio)	Bajo
S (Azufre)	Bajo
ELEMENTOS MENORES	
Hierro	Bajo
Manganeso	Bajo
Cobre	Bajo
Zinc	Bajo
Boro	Bajo



Métodos de Análisis	
pH y CE	Electrométrico.
Textura	Bouyucos
Mat Org	Walkley-Black
P	Fósforo disponible (Bray II)
Fe, Mn, Zn, Cu	Extracción con DTPA. Absorción Atómica
S	Azufre (Turbidimetría)
B	Boro (Azometina)
Ca, Mg, K, CICE	Acetato de Amonio 1N pH 7. Absorción Atómica
N	Nitrógeno Total (Kjeldahl)

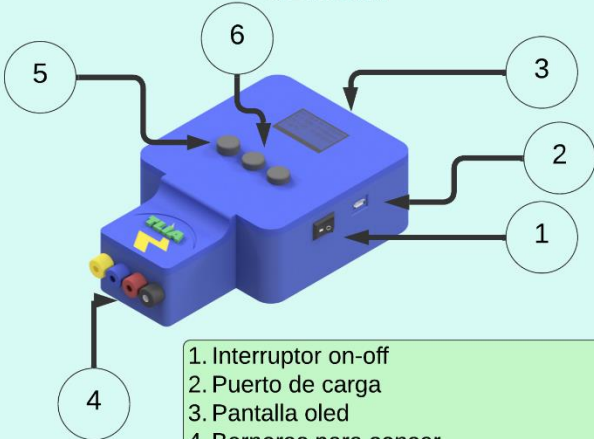
Observaciones

- * Los resultados reportados en el presente informe corresponden exclusivamente a la muestra analizada y no a otra(s) muestras de la misma procedencia
- * Las contramuestras serán almacenadas por un periodo de dos meses, después, serán desechadas
- * Muestra tomada por: Agroambiental ____ Cliente X
- * Si tiene alguna inquietud sobre los resultados, por favor comuníquese con la Dirección Técnica del Laboratorio


 Alix Cuy Patifio
 Química - PG 1732
 Dirección Técnica de Laboratorio



Anexo M. Manual de Dispositivo


MANUAL DEL SENSOR




- 1. Interruptor on-off
- 2. Puerto de carga
- 3. Pantalla oled
- 4. Borneras para sensor
- 5. Selección de sensor multiparametros
- 6. Selección de sensor NPK

Funcionamiento del sensor paso a paso

1. Encender el dispositivo

2. Adaptar el sensor ya sea mutiparamtros o NPK


3. Si adapto el sensor multiparametros presione primer pulsador


4. Si adapto el sensor NPK presione el segundo pulsador


5. Observar variables en la pantalla
