



ESCUELA UNIVERSITARIA DE POSGRADO

USO DE IMÁGENES SATELITALES PARA PREVISIÓN IDENTIFICATIVA DE
FERTILIDAD DE SUELOS EN LONYA GRANDE, UTCUBAMBA, AMAZONAS
2024

Línea de investigación:
Procesamiento digital de imágenes y señales

Tesis para optar el Grado Académico de Maestro en Tecnologías de
Información Geográfica

Autor

Cubas Perez, Shelsen Joel

Asesor

Aroquipa Velasquez, Hector
ORCID: 0000-0002-6502-5618

Jurado

Alva Velasquez, Miguel
Mendoza Garcia, José Tomas
Sánchez Carrera, Dante Pedro

Lima - Perú

2025



USO DE IMÁGENES SATELITALES PARA PREVISIÓN IDENTIFICATIVA DE FERTILIDAD DE SUELOS EN LONYA GRANDE, UTCUBAMBA, AMAZONAS 2024

INFORME DE ORIGINALIDAD



FUENTES PRIMARIAS

1	hdl.handle.net Fuente de Internet	3%
2	repository.javeriana.edu.co Fuente de Internet	2%
3	repositorio.unas.edu.pe Fuente de Internet	1%
4	ridum.umanizales.edu.co Fuente de Internet	1%
5	terralatinoamericana.org.mx Fuente de Internet	1%
6	cibnor.repositorioinstitucional.mx Fuente de Internet	1%
7	www.coursehero.com Fuente de Internet	1%
8	Submitted to INACAP Trabajo del estudiante	1%
9	Submitted to Corporación Universitaria Minuto de Dios, UNIMINUTO Trabajo del estudiante	1%
10	repositorio.unapiquitos.edu.pe Fuente de Internet	<1%
11	repository.its.ac.id Fuente de Internet	<1%



Universidad Nacional
Federico Villarreal

VRIN | VICERRECTORADO
DE INVESTIGACIÓN

ESCUELA UNIVERSITARIA DE POSGRADO

USO DE IMÁGENES SATELITALES PARA PREVISIÓN
IDENTIFICATIVA DE FERTILIDAD DE SUELOS EN LONYA
GRANDE, UTCUBAMBA, AMAZONAS 2024

Línea de Investigación:
Procesamiento digital de imágenes y señales

Tesis para optar el Grado Académico de Maestro en Tecnologías de
Información Geográfica

Autor
Cubas Perez, Shelsen Joel

Asesor
Aroquipa Velasquez, Hector
ORCID: 0000-0002-6502-5618

Jurado
Alva Velasquez, Miguel
Mendoza Garcia, José Tomas
Sánchez Carrera, Dante Pedro

Lima – Perú
2025

DEDICATORIA

A Dios, por brindarme la fortaleza y la perseverancia necesarias para seguir adelante sin desanimarme en la búsqueda de mis objetivos, siendo siempre mi guía y mi apoyo en el camino correcto. A mis padres, Adelmo y Carmen, quienes me dieron la vida, una educación valiosa y su respaldo incondicional en todo momento.

A mi hermana Lorynm, por su constante interés en mi bienestar, por estar atenta a lo que necesito y por recordarme con firmeza la importancia de cumplir con mis responsabilidades.

Al señor Máximo Calderón, por sus constantes consejos y por motivarme a concluir este proyecto.

AGRADECIMIENTO

Expreso mi agradecimiento al Dr. Hector Aroquipa Velasquez por haber contribuido a una correcta redacción y definición de las partes de la tesis, además, de ayudarme durante la realización de este proyecto.

Agradezco a los docentes de la Escuela Universitaria de Posgrado (EUPG), en especial a la Dra. Vicenta Irene Tafur Anzualdo y al Mg. Eber Rostaing Risco Sence por haberme apoyado incondicionalmente haciendo posible la realización de este trabajo.

Agradezco a la Universidad Nacional Federico Villareal, por haberme albergado durante dos años y otorgado la oportunidad de vivir esta grata experiencia universitaria.

Al señor Javier Salazar Venegas, Project CEE de COINCA S.A.C., por las facilidades otorgadas que hicieron posible el desarrollo y cumplimiento de los objetivos de esta investigación.

ÍNDICE

RESUMEN	XII
ABSTRACT.....	XIII
I. INTRODUCCIÓN	14
1.1. Planteamiento del problema.....	15
1.2. Descripción del problema	16
1.3. Formulación del problema	17
1.3.1. Problema general.....	17
1.3.2. Problemas específicos	17
1.4. Antecedentes	17
1.4.1. Internacionales	17
1.4.2. Nacionales.....	20
1.5. Justificación de la investigación	23
1.6. Limitaciones de la investigación.....	24
1.7. Objetivos.....	25
1.7.1. Objetivo general	25
1.7.2. Objetivos específicos	25
1.8. Hipótesis	25
1.8.1. Hipótesis general.....	25
1.8.2. Hipótesis específicas	25
II. MARCO TEÓRICO.....	26
2.1. Bases teóricas.....	26
2.1.1. Imágenes satelitales.....	26

2.1.2.	Fertilidad de suelos	30
2.2.	Marco conceptual.....	31
2.2.1.	Satélite SENTINEL-2	31
2.2.2.	Modelo predictivo	32
2.2.3.	Macronutrientes.....	33
2.2.4.	Micronutrientes	34
III.	MÉTODO	35
3.1.	Tipo de investigación.....	35
3.2.	Población y muestra.....	35
3.3.	Operacionalización de variables	35
3.4.	Instrumentos.....	37
3.4.1.	Sistema de posicionamiento global (GPS).....	37
3.4.2.	Envases para muestras.....	37
3.4.3.	Softwares para procesamiento de datos geoespaciales.....	37
3.4.4.	Hojas de cálculo	37
3.5.	Procedimientos.....	38
3.5.1.	Delimitación del área con cultivos de café.....	38
3.5.2.	Ubicación de los puntos de muestreo.....	38
3.5.3.	Carga manual de las coordenadas al GPS	38
3.5.4.	Datos de fertilidad de suelos	38
3.5.5.	Procesamiento de imágenes satelitales.....	40
3.5.6.	Geoestadística	41
3.5.7.	Herramientas y softwares	42

3.6. Análisis de datos	42
3.6.1. Preparación de datos	42
3.6.2. Exploración de datos	42
3.6.3. Fertilidad del suelo	42
3.6.4. Imágenes satelitales.....	43
3.6.5. Análisis espacial.....	43
3.7. Consideraciones éticas	43
IV. RESULTADOS	44
4.1. Características de la zona óptimas para el cultivo de café	44
4.2. Ubicación de puntos de muestreo	50
4.3. Imágenes satelitales SENTINEL-2 – SWIR2	52
4.4. Datos de fertilidad de suelos	54
4.4.1. Relación entre la arcilla, arena y limo con la banda 12 SWIR2	57
4.4.2. Relación entre Saturación de agua (Sw) y la banda 12 SWIR2	60
4.4.3. Relación entre Conductividad eléctrica (CE) y la banda 12 SWIR2.....	62
4.4.4. Relación entre pH del suelo y la banda 12 SWIR2	63
4.4.5. Relación entre Materia Orgánica (MO) y la banda 12 SWIR2	65
4.4.6. Relación entre Capacidad de campo (CC), el punto de marchitez permanente (PMP) y la banda 12 SWIR2	67
4.4.7. Relación entre la Capacidad de Intercambio Catiónico Efectivo (CICE) y la banda 12 SWIR2	69
4.4.8. Relación entre los macronutrientes y la banda 12 SWIR2	70
4.4.9. Relación entre micronutrientes y la banda 12 SWIR2	75

4.5. Generación de mapas por parámetros del suelo	79
4.5.1. Datos muestreados vs SoilGrids.....	84
4.6. Modelo GWR.....	86
4.6.1. Obtención del modelo GWR	86
4.6.2. Modelos GWR	87
4.6.3. Modelo GWR óptimo.....	88
4.6.4. Visualización de los coeficientes locales	89
V. DISCUSIÓN DE RESULTADOS	91
VI. CONCLUSIONES	94
VII. RECOMENDACIONES.....	96
VIII. REFERENCIAS.....	97
IX. ANEXOS	108
- Matriz de consistencia.....	108
- Validación y confiabilidad de los instrumentos	109
A) GPS.....	109
B) Envases para muestras de suelos	111
C) Informes del Análisis de fertilidad de muestras de suelos.....	112
D) Softwares para procesamiento de datos.....	125
- Matriz de correlación	126
- Correlogramas.....	127
- Asignación de nomenclaturas a las variables analizadas	129
- Variables usadas en el modelo de distribución de especies	130
- Contribución de las variables a los modelos de distribución de especies	131

- Modelo de general de la distribución de C. Arábica.....	134
- Panel fotográfico.....	135

ÍNDICE DE TABLAS

Tabla 1. Bandas espectrales para los sensores SENTINEL-2 (S2A y S2B).....	27
Tabla 2. Operacionalización de variables de la investigación	36
Tabla 3. Profundidad del muestreo según el uso del suelo	39
Tabla 4. Principales parámetros y técnicas para el análisis de fertilidad del suelo	40
Tabla 5. Requerimientos agroclimáticos para Café arábica.....	44
Tabla 6. Datos de SWIR2 de acuerdo a las coordenadas de punto de muestreo	54
Tabla 7. Resultados del análisis en el laboratorio de características físicas y químicas del suelo (01).....	55
Tabla 8. Resultados del análisis en el laboratorio de características físicas y químicas del suelo (02).....	56
Tabla 9. Valores ráster asociados para resultado de arena, limo y arcilla	57
Tabla 10. Valores ráster asociados para resultado de Saturación de agua (Sw)	61
Tabla 11. Valores ráster asociados para resultado de Conductividad eléctrica (CE)	62
Tabla 12. Valores ráster asociados para resultado de pH	64
Tabla 13. Valores ráster asociados para resultado de Materia Orgánica (MO).....	66
Tabla 14. Valores ráster asociados para resultado de Capacidad de campo (CC) y Punto de marchitez permanente (PMP)	67
Tabla 15. Valores ráster asociados para resultado de Capacidad de Intercambio Catiónico Efectivo (CICE)	69
Tabla 16. Valores ráster asociados para resultado de los macronutrientes (N, P, K, S, Ca, Mg)	71
Tabla 17. Valores ráster asociados para cada muestra a los micronutrientes (Na, Cu, Zn, Mn, Fe, B).....	75
Tabla 18. Modelos GWR	87
Tabla 19. Matriz de consistencia	108
Tabla 20. Nomenclaturas asignadas para GWR	129
Tabla 21. Variables ambientales para el modelamiento MaxEn.....	130
Tabla 22. Variables espaciales para el modelamiento MaxEnt	131
Tabla 23. Contribución de las 22 variables al modelo de distribución del C. Arábica.....	131
Tabla 24. Contribución de las 16 variables al modelo de distribución del C. Arábica.....	132
Tabla 25. Contribución de las 13 variables al modelo de distribución del C. Arábica.....	133
Tabla 26. Variables y su porcentaje de contribución al modelo de distribución de especies	133

ÍNDICE DE FIGURAS

Figura 1. Espectro electromagnético.....	28
Figura 2. Imágenes multiespectrales (5 bandas).....	29
Figura 3. Flujo de trabajo para seleccionar el área óptima para el café Arábica	45
Figura 4. Modelo Digital de Elevación del distrito de Lonya Grande.....	46
Figura 5. Temperatura Media Anual del distrito de Lonya Grande.....	47
Figura 6. Precipitación Anual del distrito de Lonya Grande	48
Figura 7. Modelo de distribución del café arábica.....	49
Figura 8. Delimitación de la Zona óptima para el cultivo de café en Lonya Grande	50
Figura 9. Ubicación de los puntos de muestreo de suelo	51
Figura 10. Índice de Suelo Desnudo (BSI)	52
Figura 11. Imagen Satelital procedentes de SENTINEL-2 – Banda 12 SWIR2	53
Figura 12. Clases texturales de las 12 muestras de suelos	58
Figura 13. Correlación entre SWIR2 y el parámetro arena	59
Figura 14. Correlación entre SWIR2 y el parámetro limo.....	59
Figura 15. Correlación entre SWIR2 y el parámetro arcilla	60
Figura 16. Correlación entre SWIR2 y el parámetro saturación de agua (Sw).....	61
Figura 17. Correlación entre SWIR2 y el parámetro Conductividad eléctrica (CE)	63
Figura 18. Correlación entre SWIR2 y el parámetro pH en agua (pH_H2O).....	64
Figura 19. Correlación entre SWIR2 y el parámetro pH en cloruro de calcio (pH_CaCl2)....	65
Figura 20. Correlación entre SWIR2 y el parámetro MO.....	66
Figura 21. Correlación entre SWIR2 y el parámetro CC.....	68
Figura 22. Correlación entre SWIR2 y el parámetro PMP	68
Figura 23. Correlación entre SWIR2 y el parámetro CICE	70
Figura 24. Correlación entre SWIR2 y el parámetro N	72
Figura 25. Correlación entre SWIR2 y el parámetro P	72
Figura 26. Correlación entre SWIR2 y el parámetro K	73
Figura 27. Correlación entre SWIR2 y el parámetro S.....	73
Figura 28. Correlación entre SWIR2 y el parámetro Ca.....	74
Figura 29. Correlación entre SWIR2 y el parámetro Mg.....	74
Figura 30. Correlación entre SWIR2 y el parámetro Na	76
Figura 31. Correlación entre SWIR2 y el parámetro Cu	76
Figura 32. Correlación entre SWIR2 y el parámetro Zn.....	77
Figura 33. Correlación entre SWIR2 y el parámetro Mn.....	77

Figura 34. Correlación entre SWIR2 y el parámetro Fe	78
Figura 35. Correlación entre SWIR2 y el parámetro B	78
Figura 36. Interpolación con IDW para variables de textura: 1) Arcilla, 2) Arena y 3) Limo	79
Figura 37. Interpolación con IDW para variables de saturación de agua, conductividad eléctrica y pH: 1) Sw, 2) CE, 3) pH_H2O y 4) pH_CaCl2	80
Figura 38. Interpolación con IDW para variables de materia orgánica, capacidad de campo, punto de marchitez permanente y capacidad de intercambio catiónico efectivo: 1) MO, 2) CC, 3) PMP y 4) CICE.....	81
Figura 39. Interpolación con IDW para variables de macronutrientes: 1) N, 2) P, 3) K, 4) S, 5) Ca y 6) M	82
Figura 40. Interpolación con IDW para variables de micronutrientes: 1) Na, 2) Cu, 3) Zn, 4) Mn, 5) Fe y 6) B.....	83
Figura 41. Comparación entre los resultados muestreados y los datos obtenidos de SoilGrids	84
Figura 42. Comparación de texturas de suelo Muestreado vs SoilGrids	85
Figura 43. Comparación de texturas de suelo Datos de Interpolación VS SoilGrids	85
Figura 44. Flujo de trabajo para obtención del modelo predictivo GWR.....	86
Figura 45. Visualización de los coeficientes locales (N, P, K, S, Ca y Mg).....	90
Figura 46. Matriz de correlación entre parámetros analizados del suelo.....	126
Figura 47. Correlograma mostrando colores	127
Figura 48. Correlograma mostrando valores numéricos.....	128
Figura 49. Distribución del C. Arábica en Perú 	134

RESUMEN

Objetivo: Determinar la relación entre imágenes satelitales y la previsión de la fertilidad del suelo en Lonya Grande, Amazonas, para el cultivo de café. **Método:** Se utilizaron imágenes SENTINEL-2, específicamente la banda 12 SWIR2 y datos de análisis de suelos de 12 puntos de muestreo. Mediante la interpolación IDW se generaron mapas de distribución de nutrientes y propiedades del suelo, además se estableció un modelo de Regresión Geográficamente Ponderada (GWR), este modelo no solo sirve para predecir, sino también para evaluar con precisión la fertilidad de los suelos en la zona. **Resultados:** Se mostró la relación entre la banda SWIR2 y variables como macronutrientes y micronutrientes. El modelo predictivo GWR óptimo corresponde a macronutrientes presentando un R^2 de 0. 0.939, un CV de 572.118 y un AIC de 602.800, indicando su robustez para predecir la fertilidad del suelo. **Recomendaciones:** Aumentar la cantidad de puntos de análisis de suelo, validar los resultados de la predicción con datos de campo y explorar otras técnicas de análisis para comparar las técnicas de predicción. **Conclusiones:** El modelo GWR seleccionado está orientado al análisis de macronutrientes y ha sido diseñado específicamente para cultivos de café, considerando la naturaleza y características de las muestras utilizadas.

Palabras Clave: Fertilidad del suelo, imágenes satelitales, SWIR2, macronutrientes, micronutrientes, Regresión Geográficamente Ponderada (GWR), Ponderación de Distancia Inversa (IDW), Café Arábica.

ABSTRACT

Objective: To determine the relationship between satellite imagery and soil fertility prediction in Lonya Grande, Amazonas, for coffee cultivation. **Method:** SENTINEL-2 images were used, specifically band 12 SWIR2 and soil analysis data from 12 sampling points. Through IDW interpolation, nutrient distribution maps and soil properties were generated, and a Geographically Weighted Regression (GWR) model was established. This model not only serves for prediction, but also for accurately assessing soil fertility in the area. **Results:** A significant relationship was identified between the SWIR2 band and variables such as macronutrients and micronutrients. The optimal predictive GWR model for macronutrients achieved an R^2 of 0.939, a CV of 572.118, and an AIC of 602.800, demonstrating its robustness for soil fertility prediction. **Recommendations:** Increase the number of soil analysis points, validate predictive results with field data, and explore alternative analytical techniques to compare predictive methods. **Conclusions:** The selected GWR model focuses on macronutrient analysis and has been specifically tailored for coffee cultivation, taking into account the nature and characteristics of the collected samples.

Keywords: Soil fertility, Satellite imagery, SWIR2, macronutrients, micronutrients, Geographically Weighted Regression (GWR), Inverse Distance Weighting (IDW), Arabica Coffee.

I. INTRODUCCIÓN

A nivel mundial, la fertilidad de los suelos es un aspecto crucial para garantizar la seguridad alimentaria y el desarrollo sostenible de la agricultura (Cherlinka, 2024b). Según un estudio realizado por la Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO) en 2022, se estima que alrededor del 33% de los suelos cultivables del mundo sufren algún grado de degradación, lo que afecta directamente su fertilidad y capacidad productiva (Servimedia, 2022). Esta situación representa un reto, ya que la demanda de alimentos aumenta debido al crecimiento poblacional y los cambios en los patrones de consumo.

A nivel regional, América Latina y el Caribe, la degradación de los suelos también es una preocupación importante. De acuerdo con un informe de la Comisión Económica para América Latina y el Caribe [CEPAL] et al., (2021), cerca del 48 % de los suelos en el Caribe, 50 % en Mesoamérica y 18 % en Suramérica se encuentran en zonas con alta o muy alta severidad de degradación del suelo, impactando negativamente en la productividad agrícola y la sostenibilidad de los sistemas alimentarios.

A nivel local, en la región de Amazonas, Perú, la fertilidad de los suelos es un factor determinante para el desarrollo de la agricultura, siendo uno de los principales motores económicos de la zona representando en promedio un 25% de la Población Económicamente Activa (Polo et al., 2021). Los cultivos estacionarios, como el monocultivo, causan degradación del suelo debido a la reducción de su capacidad para regenerar nutrientes y a la erosión acelerada. En la provincia de Utcubamba, donde se encuentra el distrito de Lonya Grande, principal productor de café de la región Amazonas, se enfrenta a este desafío, sumado a la falta de datos sobre la fertilidad del suelo.

En este contexto, el uso de imágenes satelitales aparece como una herramienta valiosa para abordar esta problemática, ya que permite obtener información detallada y actualizada

sobre las características de los suelos a grandes escalas (Abdulraheem et al., 2023). Gracias a los avances tecnológicos en el campo de la teledetección y el procesamiento digital de imágenes, es posible analizar y mapear la fertilidad de los suelos con mayor precisión y eficiencia (Tunçay et al., 2021).

1.1. Planteamiento del problema

En la región de Amazonas, donde se ubica el distrito de Lonya Grande, la fertilidad de los suelos es un factor crítico para el desarrollo de la agricultura, el cual es uno de los principales motores económicos de la zona, representando el 25% de la PEA. El distrito de Lonya Grande es el principal productor de café de la región Amazonas. Sin embargo, el monocultivo estacionario que se practica en esta zona ocasiona degradación del suelo, ya que reduce su capacidad para regenerar nutrientes y acelera la erosión. Además, la falta de información accesible sobre la fertilidad de los suelos dificulta la implementación de medidas de mitigación para combatir la degradación del suelo.

En este contexto, la obtención de información detallada y actualizada sobre la fertilidad de los suelos en Lonya Grande es fundamental para la toma de decisiones y la implementación de estrategias que permitan mejorar la gestión de los recursos edáficos, aumentar la productividad agrícola y promover el desarrollo sostenible de la región. Sin embargo, los métodos tradicionales de evaluación de suelos, como los análisis de laboratorio, son costosos, lentos y difíciles de aplicar a grandes áreas.

Por lo tanto, el uso de imágenes satelitales emerge como una solución prometedora para abordar este problema, ya que permite obtener información detallada y actualizada sobre las características de los suelos a grandes escalas de manera eficiente y rentable. Los avances tecnológicos en el campo de la teledetección y el procesamiento digital de imágenes han abierto nuevas oportunidades para analizar y mapear la fertilidad de los suelos con mayor precisión y eficiencia (Abdulraheem et al., 2023).

1.2. Descripción del problema

La fertilidad de los suelos es un factor crítico para el desarrollo sostenible de la agricultura y la seguridad alimentaria. En el distrito de Lonya Grande, provincia de Utcubamba, región Amazonas, Perú, existe disponibilidad de información precisa y actualizada sobre el estado de fertilidad de los suelos, lo que representa un desafío significativo para la toma de decisiones y la implementación de estrategias efectivas para la gestión y conservación de estos recursos.

Uno de los principales problemas radica en la dificultad y los altos costos asociados con los métodos tradicionales de evaluación de la fertilidad de los suelos, como los análisis de laboratorio. Estos métodos requieren la recolección de muestras de suelo en campo, su transporte a laboratorios especializados y la realización de pruebas físicas y químicas para determinar las propiedades y características del suelo. Este proceso es laborioso y costoso para aplicar a grandes áreas, lo que limita la capacidad de obtener información detallada y actualizada sobre la fertilidad de los suelos a nivel local.

Además, la falta de información precisa sobre la fertilidad de los suelos dificulta la toma de decisiones informadas para la planificación y gestión de las actividades agrícolas en Lonya Grande. Los agricultores y productores locales carecen de datos confiables sobre las áreas con mayor o menor potencial de fertilidad, lo que puede conducir a una mala asignación de recursos y prácticas agrícolas inadecuadas, lo que a su vez puede resultar en una disminución de los rendimientos y la productividad, así, como en gastos innecesarios.

Otro aspecto importante es la necesidad de monitorear los cambios en la fertilidad de los suelos a lo largo del tiempo, ya que este es un recurso dinámico que puede verse afectado por factores como el uso intensivo de fertilizantes, la erosión, el cambio climático y las prácticas agrícolas tradicionales. Sin información actualizada, resulta difícil detectar y abordar adecuadamente los problemas de degradación del suelo antes de que se vuelvan críticos

Adicionalmente, la falta de información detallada sobre la fertilidad de los suelos puede obstaculizar los esfuerzos para promover prácticas agrícolas sostenibles y la conservación de los recursos edáficos en Lonya Grande. Sin acceso a datos precisos, resulta complicado identificar las áreas prioritarias para la implementación de medidas de protección y restauración del suelo, lo que puede llevar a una mayor degradación y a la pérdida de su capacidad productiva.

1.3. Formulación del problema

1.3.1. Problema general

¿De qué manera se relaciona las imágenes satelitales con la previsión identificativa de la fertilidad de suelos en el distrito de Lonya Grande, provincia Utcubamba, región Amazonas en el 2024?

1.3.2. Problemas específicos

¿De qué manera se relaciona el satélite SENTINEL-2 con la fertilidad de suelos en Lonya Grande, Amazonas en el 2024?

¿De qué manera se relaciona el modelo predictivo con la previsión identificativa la fertilidad de suelos en Lonya Grande, Amazonas en el 2024?

1.4. Antecedentes

1.4.1. Internacionales

Baquero (2023), en su investigación tuvo por objetivo, diseñar un modelo preliminar para identificar la fertilidad de suelos, para el cultivo de soja, a partir de imágenes satelitales e interpolación geoestadístico IDW. Respecto al tipo de investigación es cualitativo correlacional. El área de estudio son tres zonas en Paraguay, las cuales tienen las siguientes áreas: Zona 1 (179.1 Ha), Zona 2 (201.5 Ha) y Zona 3 (71.4 Ha). Los resultados esperados por el modelo fueron mapas de macronutrientes (P, K), nutrientes secundarios (Al, B, Ca, Cn, Fe, Mg, Mn, S, Zn), materia orgánica, pH, capacidad de intercambio catiónico y textura de suelo.

En conclusión, los mapas obtenidos permiten identificar concentración, distribución de nutrientes, textura de suelo y otras propiedades.

Collazos (2023), se planteó el objetivo de desarrollar un modelo de procesos Gaussianos que permita predecir la producción del cultivo de caña de azúcar a través del uso multitemporal de imágenes satelitales Sentinel 1 y el cruce de variables climáticas. Respecto al tipo de investigación el diseño de este trabajo es no experimental – transversal. El área de estudio se ubicó al suroccidente de Colombia en los municipios de Corinto, Miranda y Padilla, sobre seis Haciendas pertenecientes al Ingenio del Cauca S.A. Los resultados del modelo con mejor resultado lo arrojo los datos SAR, evaluando la polarización VH, utilizando la combinación de variables (Desviación estándar, Pendiente) en la fenología 1 obteniendo un error de 11.11 TCH. En conclusión, se desarrolló un modelo de estimación del rendimiento del cultivo en caña de azúcar usando el algoritmo de procesos gaussianos, necesitando como datos de entrada las características de tendencia (pendiente) y desviación estándar extraídas a partir de series temporales de los datos de la banda de polaridad VH del sensor Sentinel 1 en la etapa fenológica que comprende los primeros 120 días después de siembra.

Vega (2019), el objetivo de su investigación fue correlacionar las temperaturas calculadas a partir de banda térmica en imágenes satelitales con las aportadas por estudios geoquímicos, en la zona de Santa Rosa de Cabal y parte norte del Complejo Volcánico Nevado del Ruiz. Respecto al tipo de investigación el diseño de este trabajo es no experimental – transversal. El área de estudio se ubicó en el Volcán Nevado del Ruiz hasta Santa Rosa de Cabal al suroccidente de Colombia. Los resultados sugieren que las imágenes satelitales con banda térmica son un apoyo eficiente a los estudios superficiales de geología, geoquímica y geofísica para estimar el potencial geotérmico de una fuente. La conclusión de esta investigación indica que la determinación de las temperaturas se realizó con imágenes Landsat usando la banda termal, obteniéndose temperaturas entre -143.798°C y 70.3428°C , sin

embargo, la temperatura mínima es muy baja y fue considerada como fuera de rango, y las temperaturas mínimas aceptadas estuvieron alrededor de los -40°C , estas temperaturas bajas pueden deberse por las condiciones del sensor y a la alta nubosidad de algunas de las zonas del área de interés.

Matus (2019), el objetivo de su tesis fue proponer un sistema de monitoreo de proliferaciones algales en la Bahía de La Paz, a partir de las propiedades bio-ópticas del océano y los sistemas de detección remota (imágenes de satélite). El área de estudio se ubicó en la Bahía de La Paz, ubicada en la costa occidental de Baja California Sur, México. Los resultados sugieren que las imágenes Landsat 8 podrían aplicarse de manera efectiva para estimar la concentración de Chl-a (Clorofila-a) en ambientes costeros, mientras que los MDE (Modelo de Distribución de Especies) podrían ser una herramienta útil para describir las preferencias de hábitat de las comunidades de fitoplancton y permitiendo, en su conjunto, implementar programas de monitoreo para la detección de PA (proliferaciones algales). Se concluye que el estudio ha evaluado la capacidad predictiva de modelos de regresión (lineal simple - múltiples y modelos aditivos generalizados) para poder estimar la concentración de Chl-a, utilizando las primeras cinco bandas de imágenes de Landsat 8.

Rodríguez (2023), en el objetivo de su tesis fue implementar métodos de detección de macro plásticos y basura flotante, que haga uso del procesamiento de imágenes satelitales en la desembocadura del Río Magdalena con el Mar Caribe en la zona denominada Bocas de Ceniza. El área de estudio se ubicó en Bocas de Ceniza, Visegrad Dam, Solo River Mouth y Almería Greenhouses. Con los resultados se determinó que el algoritmo Random Forest ofrece excelentes resultados en términos de tiempo de ejecución, precisión y exactitud. Por esta razón, se implementó ampliamente para la clasificación detallada de la zona de interés durante dos periodos de tiempo: mayo y de junio del 2019, en la zona de Bocas de Ceniza para validación y de otras fechas y zonas para datos de entrenamiento. Se concluye que la precisión del método

Random Forest para detectar plástico y contaminación oceánica puede variar dependiendo de varios factores, como el tipo y calidad de las imágenes SENTINEL-2 utilizadas, la cantidad y calidad de los datos de entrenamiento utilizados en el algoritmo, la experiencia y habilidad del usuario en la configuración y ajuste del algoritmo, y la complejidad de la clasificación requerida.

1.4.2. Nacionales

Los antecedentes nacionales son en su mayoría tesis de pregrado y se incluyeron para complementar el marco teórico de esta investigación, debido a dos cosas, la primera, no hay tesis nacionales de posgrado sobre el tema, y la segunda, por la relevancia de sus aportes específicos al tema en estudio. A pesar de su nivel académico, estas investigaciones ofrecen datos empíricos y metodologías aplicables, reflejando el estado de la investigación nacional y sirven como referencia para identificar vacíos de conocimiento que esta investigación de posgrado busca profundizar.

Mora (2023) planteó como objetivo de su tesis, modelar y simular el espacio – temporal del proceso de cambio de la cobertura vegetal y temperatura ambiental en el distrito de Daniel Alomía Robles – Huánuco, 2021. El área de estudio es el distrito de Daniel Alomía Robles, provincia de Leoncio Prado, departamento Huánuco. Con los resultados de los modelos de temperatura ambiental y su respectiva clasificación de la cobertura vegetal, se determinó que la vegetación densa que presenta el menor rango de temperatura que va desde los 17, 51 °C a los 27,106 °C. En conclusión la temperatura ambiental con relación a la cobertura vegetal y el tiempo, se pudo determinar los modelos de temperatura con su respectivas ecuaciones y valores para las siguientes clasificaciones: la vegetación densa, vegetación dispersa y sin vegetación., donde el rango de la temperatura ambiental resulto ser la menor para clasificación de vegetación densa equivalente a 17,54 °C a 27,106 °C, por lo que se acopla con los microclimas que tienen las áreas de densas cuberturas vegetales.

Nina (2020), en su investigación tuvo por objetivo detectar embarcaciones dentro de las 100 millas del borde costero del Perú, técnicas de Deep Learning e imágenes satelitales. Respecto al tipo de investigación es investigación aplicada. El área de estudio considera las 100 millas del borde costero del Perú. Los resultados mostraron que YOLO (You Only Look Once) alcanzó 69,80 % en el conjunto de datos HRSC (High Resolution Ship Collection), mientras que YOLT (You Only Look Twice) es bueno solo para objetos pequeños con 76,06% de Average Precision (AP). Además, en el caso del conjunto de datos HRSC donde tienen objetos de diferentes tamaños, YOLT obtuvo un 40% de AP contra 75% de YOLO. En conclusión, se logró utilizar las técnicas de aprendizaje profundo que satisfactoriamente permite detectar embarcaciones dentro de las 100 millas del borde costero de Perú, utilizando procesamiento de imágenes mediante técnicas de deep learning e imágenes satelitales.

Becerra (2022) plantea como objetivo de su tesis, detectar las vías de acceso en la Amazonía Peruana con Análisis de características Texturales utilizando GLCM y SVM a partir de imágenes satelitales. El área de estudio es la Amazonia del departamento de Madre de Dios. La investigación tiene un diseño experimental. De los resultados, se indica que utilizando la extracción de características y la clasificación con SVM se alcanza una precisión mayor al 95%, es así que, las imágenes con vías de acceso fueron clasificadas en su mayoría correctamente, siendo muy pocas las imágenes de los conjuntos que fueron mal clasificadas., se ha obtuvo una precisión de 95.71 % de un total de 816 imágenes y en otras pruebas con un total de 2401 de imágenes se bordeo los 95%, dichos resultados son muy aceptables y demuestran la eficiencia de la propuesta. En conclusión, se desarrolló un modelo de análisis de características texturales de imágenes satelitales para la detección de vías de acceso, mediante la extracción de características Gray-Level Co-Occurrence Matrix (GLCM) y la clasificación con Support Vector Machine (SVM) en Python con OpenCV.

Barranzuela (2022) planteó como objetivo de su investigación, identificar los pasivos ambientales mineros en estado de abandono de tipo labor y/o residuo minero, mediante el procesamiento de imágenes satelitales, principalmente los que están ubicados en zonas donde existe un limitado acceso debido a la práctica de actividades mineras de tipo informal y artesanal. El área de estudio es el centro poblado de Secocha, distrito Mariano Nicolás Valcárcel provincia de Camaná, Región Arequipa. La investigación tiene un diseño no experimental tipo transeccional descriptivo. De los resultados obtenidos luego de realizar la Clasificación de Máxima Verosimilitud y el Mapeo de Ángulos Espectrales en las imágenes satelitales, se procedió a realizar el inventario de pasivos ambientales mineros abandonados dentro de los puntos de muestreo ubicados en zonas accesibles y seguras para el equipo de investigación lográndose identificar 21 puntos de desmontes de mina, siendo 17 de ellos unidades mineras “activas” y 04 puntos en estado de “abandono”; además 07 puntos correspondieron a bocaminas; 03 de ellos unidades mineras “activas” y 04 bocaminas en aparente estado de “abandono”. En conclusión, se logró identificar un total de 08 pasivos ambientales mineros en estado de abandono.

Silva (2022) planteó como objetivo de su tesis, evaluar la degradación de pastizales en las microcuencas de Pomacochas y Ventilla, Amazonas – Perú utilizando imágenes de un Remotely Piloted Aircraft (RPA) y satelital correspondientes a SENTINEL-2B / Planet e índices de vegetación. El área de estudio son los distritos La Florida y Molinopampa, donde se ubican las microcuencas Pomacochas y Ventanilla. En los resultados obtenidos, se desarrolló una metodología semiautomática para evaluar la degradación de pastizales basados en i) Imágenes RPAS, ii) composición florística, iii) análisis de suelos e iv) identificación visual. Los mapas de degradación reportaron precisiones superiores a 0.78 para los algoritmos de clasificación automática de Regresión lineal (LR) y Máquina de Soporte de Vectores (SVM) y Random Forest (RF), siendo mejor este último. Asimismo, el índice de degradación de

Cobertura de Vegetación de Pastizales (CVP) demostró que la degradación de pastizales indica que en el rango S4-Fuertemente (CVP, < 40%). En conclusión, para la microcuenca de Pomacochas se determinó un CVP de 2.6% (93.4 ha) y para Ventanilla, un 0.4%, (8.94 ha).

1.5. Justificación de la investigación

La fertilidad de los suelos es un componente fundamental para asegurar la productividad agrícola y, por ende, la seguridad alimentaria. Sin embargo, la degradación del suelo, por prácticas agrícolas como el monocultivo, y la falta de información actualizada sobre la fertilidad del suelo han puesto en riesgo el desarrollo sostenible de la agricultura en esta zona. La presente investigación se justifica en cinco ejes fundamentales, que son:

- **Importancia para la seguridad alimentaria:** La agricultura es uno de los principales motores económicos de la región de Amazonas, y la fertilidad de los suelos es un factor clave para garantizar una producción agrícola sostenible y suficiente para satisfacer las necesidades alimentarias de la población local y regional. Al contar con información precisa sobre la fertilidad de los suelos, se podrán implementar prácticas agrícolas adecuadas para optimizar los rendimientos y garantizar la seguridad alimentaria a largo plazo.
- **Conservación de los recursos naturales:** Los suelos son un recurso natural no renovable y su degradación puede tener consecuencias irreversibles. Al evaluar y monitorear la fertilidad de los suelos, se podrán identificar áreas prioritarias para la implementación de medidas de mitigación, contribuyendo así a la preservación de este recurso vital para el desarrollo sostenible de la región.
- **Toma de decisiones informadas:** La disponibilidad de información detallada y actualizada sobre la fertilidad de los suelos permitirá a las autoridades locales y agricultores, planificar y gestionar de manera más efectiva las actividades agrícolas. Esto puede conducir a una mejor asignación de recursos, la implementación de prácticas

agrícolas adecuadas y el desarrollo de políticas y programas enfocados en mejorar la productividad y sostenibilidad del sector agrícola.

- Eficiencia y reducción de costos: Los métodos tradicionales de evaluación de la fertilidad de los suelos, como los análisis de laboratorio, son costosos, lentos y difíciles de aplicar a grandes áreas. El uso de imágenes satelitales ofrece una alternativa más eficiente y rentable para obtener información detallada y actualizada sobre la fertilidad de los suelos, lo que puede resultar en un ahorro significativo de recursos económicos y tiempo.
- Contribución al desarrollo sostenible: La investigación contribuirá al desarrollo sostenible de la región al promover la conservación de los recursos naturales, la seguridad alimentaria y el crecimiento económico a través de una agricultura más productiva y sostenible. Además, los resultados del estudio podrán ser extrapolados y aplicados a otras regiones con características similares, ampliando así su impacto positivo.

1.6. Limitaciones de la investigación

Esta investigación enfrenta limitaciones como la disponibilidad y calidad de datos satelitales, que afectan la precisión del análisis. La variabilidad climática y la heterogeneidad de los suelos dificultan la generalización de los resultados. Además, la falta de información sobre prácticas agrícolas y los costos asociados con el análisis de muestras de suelo limitan la interpretación y el alcance del estudio. A pesar de estos desafíos, los hallazgos sobre la relación entre imágenes satelitales y fertilidad del suelo son valiosos, pero deben considerarse estas limitaciones para futuras investigaciones.

1.7. Objetivos

1.7.1. Objetivo general

Determinar la relación de las imágenes satelitales con la previsión identificativa de la fertilidad de suelos en distrito de Lonya Grande, provincia Utcubamba, región Amazonas en el 2024.

1.7.2. Objetivos específicos

- Determinar la relación del satélite SENTINEL-2 y la previsión identificativa de fertilidad de suelos en el distrito de Lonya Grande, provincia Utcubamba, región Amazonas en el 2024.
- Determinar la relación del modelo predictivo con la previsión identificativa de la fertilidad de suelos en el distrito de Lonya Grande, provincia Utcubamba, región Amazonas en el 2024.

1.8. Hipótesis

1.8.1. Hipótesis general

Las imágenes satelitales se relacionan significativamente con la previsión identificativa de la fertilidad de suelos en el distrito de Lonya Grande, provincia Utcubamba, región Amazonas en el 2024.

1.8.2. Hipótesis específicas

- El satélite SENTINEL-2 se relaciona significativamente con la previsión identificativa de la fertilidad de suelos en el distrito de Lonya Grande, provincia Utcubamba, región Amazonas en el 2024.
- El modelo predictivo se relaciona significativamente con la previsión identificativa de la fertilidad de suelos en el distrito de Lonya Grande, provincia Utcubamba, región Amazonas en el 2024.

II. MARCO TEÓRICO

2.1. Bases teóricas

2.1.1. Imágenes satelitales

Según Axess Networks (2021), las imágenes satelitales también conocidas como imágenes de observación de la Tierra, fotografías desde el espacio o simplemente fotografías de satélite son el producto obtenido por un sensor instalado a bordo de un satélite artificial, mediante la captación de la radiación electromagnética emitida o reflejada por un cuerpo, que posteriormente se transmite a estaciones terrenas para su visualización, procesamiento y análisis.

Las imágenes satelitales son fotografías tomadas de satélites que capturan la luz reflejada y emitida a través de varias longitudes de onda, proporcionando información sobre los recursos naturales de la Tierra y los cambios ambientales (Metternicht & Teece, 2023).

Las imágenes satelitales son cruciales para monitorear los cambios ambientales, pues al ser representaciones visuales de la superficie de la Tierra capturadas desde el espacio por medio de satélites, pueden ser utilizadas para analizar información ecológica, fuentes de contaminación y cambios ambientales en diversas zonas naturales (Martínez-Vega et al., 2015).

Los Sentinel son una nueva flota de satélites diseñada específicamente para proporcionar los abundantes datos e imágenes de que se nutre el programa Copernicus, de la Comisión Europea. SENTINEL-2 está equipado una innovadora cámara multispectral de alta resolución, con 13 bandas espectrales que aportan una nueva perspectiva de la superficie terrestre y la vegetación. La misión proporciona información útil para las prácticas agrícolas y forestales, y para gestionar la seguridad alimentaria. Las imágenes de los satélites son empleados para determinar varios índices vegetales, como el área con clorofila en la hoja y el contenido en agua (European Space Agency [ESA], 2015).

El satélite Sentinel-2 es utilizado para la teledetección de la Tierra y la observación de

los recursos naturales. Gracias a sus dos cámaras de alta resolución llamadas Multi-Spectral Instrument (MSI), pueden capturar diferentes longitudes de onda de luz, incluyendo el espectro visible y el infrarrojo cercano. El MSI mide la radiancia reflejada de la Tierra en 13 bandas espectrales desde VNIR hasta SWIR (ESA, 2015).

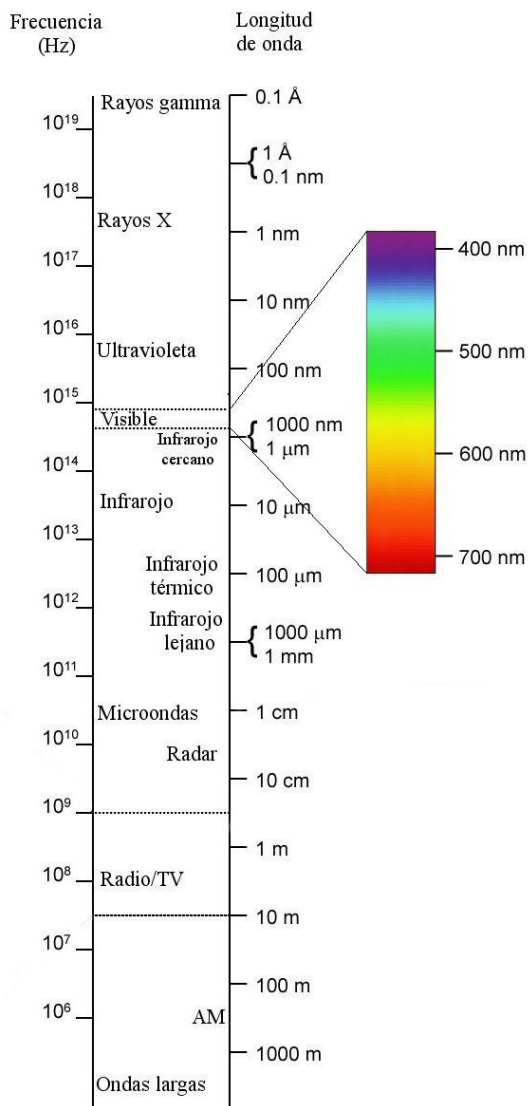
Tabla 1

Bandas espectrales para los sensores SENTINEL-2 (S2A y S2B)

Número de banda	S2A		S2B		Resolución espacial (m)
	Longitud de onda central (nm)	Ancho de banda (nm)	Longitud de onda central (nm)	Ancho de banda (nm)	
1 - Aerosol	442,7	20	442,3	20	60
2 - Blue	492,7	65	492,3	65	10
3 - Green	559,8	35	558,9	35	10
4 - Red	664,6	30	664,9	31	10
5 - Red Edge 1	704,1	14	703,8	15	20
6 - Red Edge 2	740,5	14	739,1	13	20
7 - Red Edge 3	782,8	19	779,7	19	20
8 - Near Infrared (NIR) 1	832,8	105	832,9	104	10
8a - Near Infrared (NIR) 2	864,7	21	864,0	21	20
9 - Water vapour	945,1	19	943,2	20	60
10 - Cirrus	1373,5	29	1376,9	29	60
11 - SWIR 1	1613,7	90	1610,4	94	20
12 - SWIR2	2202,4	174	2185,7	184	20

Nota. Características técnicas de las bandas espectrales del sensor SENTINEL-2 ESA, (2015).

La longitud de onda de luz es un rasgo fundamental de una onda y se refiere a la distancia entre los picos o valles sucesivos. En la teledetección, la longitud de onda se mide comúnmente en micrómetros. El espectro electromagnético es el conjunto de todas las longitudes de onda de las radiaciones electromagnéticas, que incluye desde rayos gamma, rayos X, radiación ultravioleta, luz visible, radiación infrarroja y ondas radioeléctricas (Mortenson, 2011).

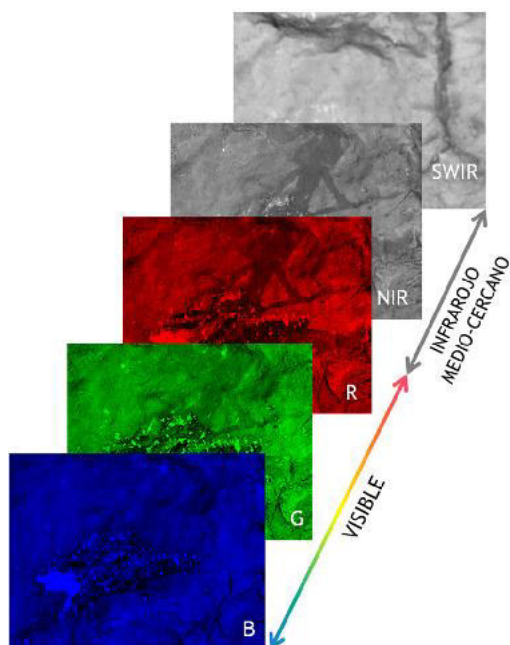
Figura 1*Espectro electromagnético*

Nota. Diagrama del espectro electromagnético realizado por Louis E. Kleiner, Coastal Carolina University citado por Scientific Committees, (s.f.).

Canalejo (2018), indica que las imágenes multispectrales se capturan dentro de rangos de longitudes de onda específicas a lo largo del espectro electromagnético. La luz se divide en bandas espectrales, generalmente de 3 a 15 bandas, por cada imagen. Las imágenes hiperespectrales son un caso especial que captura cientos de bandas espectrales de forma contigua. El procesamiento de imágenes multispectrales se utiliza para el análisis de índices de vegetación (He et al., 2020).

Figura 2

Imágenes multispectrales (5 bandas)



Nota. Métodos de documentación, análisis y conservación no invasivos para el arte rupestre postpaleolítico: radiometría de campo e imágenes multispectrales. Ensayos en la cueva del tío Garroso (Alacón, Teruel) (Sebastián et al., 2013).

La teledetección es el conjunto de instrumentos que permite obtener información de un objeto sin estar en contacto con él, simplemente escaneándolo a distancia. Los usos y aplicaciones de la teledetección espacial son cada vez más numerosos, abarcando desde agricultura hasta oceanografía, pasando por labores humanitarias o en las fuerzas armadas. Podemos distinguir entre teledetección activa (funciona con su propia fuente de emisión o luz) y pasiva (depende de la energía natural, rayos solares, que rebota en el objetivo) en función de cómo trabaja el sensor (Kogut, 2021).

Para realizar un procesamiento de imágenes, primero se hace un preprocesamiento a los datos brutos de una imagen antes de su uso en cualquier mejora posterior, interpretación o análisis. Algunas de estas operaciones están diseñadas para corregir fallos de los datos,

mientras que otras hacen que los datos sean más fáciles de procesar. Las operaciones de preprocesamiento son: ajustes del ruido y mejoramiento de la imagen usando técnicas como el filtrado y los métodos estadísticos (Puc & Wicynski, 1995), la normalización radiométrica relativa utilizando puntos invariantes en las imágenes superpuestas para adaptar el brillo y el contraste, lo que garantiza un mosaico impecable (Gehrke, 2010) y finalmente la ortorrectificación paramétrica, para garantizar una representación espacial precisa (Schläpfer et al., 2001).

2.1.2. Fertilidad de suelos

La fertilidad del suelo es la capacidad que tiene el terreno para sustentar el crecimiento de las plantas y optimizar el rendimiento de los cultivos. Ello puede potenciarse por medio de fertilizantes orgánicos e inorgánicos que nutran el suelo (Organismo Internacional de Energía Atómica[IAEA], 2023).

Cherlinka, (2024a), indica que la fertilidad del suelo hace referencia al potencial de un suelo para crear unas condiciones químicas, físicas y biológicas favorables para las plantas, proporcionándoles todos los nutrientes esenciales para su crecimiento. Es necesario entender que los nutrientes minerales no son alimento para las plantas (porque las plantas producen alimento por sí mismas mediante la fotosíntesis), sino un suplemento que proporciona más energía para su desarrollo. Así pues, se considera suelo fértil a aquel que cumple esta condición.

El manejo de la fertilidad del suelo gobierna la nutrición de la planta y esto a su vez tiene efecto directo sobre el crecimiento y rendimiento, así como en otros factores como en la susceptibilidad a las enfermedades. El manejo de nutrientes debe entonces encaminarse no solamente a lograr rendimientos altos sino también a mantener o elevar la fertilidad del suelo (Pérez, 2013).

La fertilidad intrínseca del suelo y la forma de riego podrían afectar la eficiencia de la fertilización con nitrógeno (N), modificar la meta de rendimiento, el crecimiento y el estado

nutrimental de los cultivos (Santillano et al., 2019).

Vega et al., (2022), realizó un análisis estadístico clásico para determinar la fertilidad del suelo, pero sus resultados no arrojaron información útil para el diagnóstico de las condiciones específicas de sitio, sin embargo, los mapas obtenidos del estudio, a partir, del modelo Kriging ordinario y los dos tipos de validación utilizados, sugieren que el proceso de interpolación a escala local, puede ser una herramienta útil como aproximación y referencia para determinar en buena medida la distribución espacial y variabilidad de las propiedades de fertilidad de los suelos. Los mapas de MO, N, K, P y pH definieron principalmente el estado actual de la fertilidad de los suelos y evidencian su degradación. Además, la incorporación de los mapas para las variables CIC, CE, Ca, Mg y Na, mostró el comportamiento general de los suelos, haciendo más evidente sus problemas de degradación.

2.2. Marco conceptual

2.2.1. *Satélite SENTINEL-2*

Un satélite artificial es cualquier objeto fabricado por el hombre que se ha puesto en órbita mediante cohetes. Estas naves espaciales están equipadas con instrumentos sensibles y cámaras para estudiar la Tierra y otros planetas, ayudar con las telecomunicaciones e incluso observar el universo lejano (Sergieieva, 2024).

Según ESA, (2024), indica que el Sentinel-2 lleva un instrumento óptico que muestrea 13 bandas espectrales: cuatro bandas a 10 m, seis bandas a 20 m y tres bandas a 60 m de resolución espacial. El ancho de la franja orbital es de 290 km. Esta misión facilita imágenes ópticas de alta resolución para servicios terrestres, como: la geofísica, el monitoreo de tierras, la vigilancia marítima, la gestión de emergencias y la seguridad. Los satélites gemelos Sentinel-2A y Sentinel-2B se lanzaron el 22 de junio de 2015 y el 7 de marzo de 2017, respectivamente.

2.2.2. *Modelo predictivo*

Un modelo predictivo es una herramienta estadística computacional diseñada para pronosticar resultados futuros con base en datos históricos, es así que, gracias a las Tecnologías de Información Geográfica, podemos realizar estimaciones futuras o análisis espaciales como: aumento de la temperatura en el planeta, deforestación, disminución en los nevados, distribución de especies, la disponibilidad del recurso hídrico, fertilidad de suelos, entre otros.

Los modelos predictivos usados en la geoestadística y el análisis espacial se basan en las siguientes técnicas:

- Regresión: Regresión Geográficamente Ponderada (GWR) (Hasiholan & Hidayat, 2024), Análisis de Regresión Lineal y No Lineal (Huang, 2024), entre otros.
- Modelos de clasificación: Máquinas de vectores de soporte (SVM) (Wang et al., 2024), Redes Neuronales Artificiales (ANN) (Black et al., 2023), K-Vecinos más Cercanos (KNN) (Amelia et al., 2024), Redes Bayesianas (Tansitpong, 2024), entre otros.
- Modelos basados en arboles de decisión: Random Forest (Huang, 2024), entre otros.
- Pronóstico de series de tiempo (Srivyshnavi & Aju, 2024).

2.2.2.1. *Regresión Geográficamente Ponderada (GWR)*

La regresión ponderada geográficamente (GWR) es una técnica de análisis espacial que potencia los modelos de regresión tradicionales al incorporar la ubicación geográfica en el análisis. Este método permite el examen de la heterogeneidad espacial, donde las relaciones entre variables pueden variar en diferentes ubicaciones.

GWR proporciona estimaciones localizadas de relaciones, lo que permite la identificación de variaciones espaciales en los efectos predictores, como por ejemplo: los estudios sobre retraso del crecimiento en niños pequeños en Java y precios inmobiliarios en Eindhoven (Airudelia et al., 2024) o el mapeo del crimen diferenciado por crímenes de odio y

por grupos de odio (Jendryke & McClure, 2019).

El modelo GWR se puede expresar de la siguiente manera:

$$y_i = \beta_0(u_i, v_i) + \sum_k \beta_k(u_i, v_i) x_{ik} + \varepsilon_i$$

Donde:

- y_i : es la variable dependiente en la ubicación i .
- (u_i, v_i) : son las coordenadas geográficas de la ubicación i .
- $\beta_0(u_i, v_i)$: es el término de intercepto local en la ubicación i .
- $\beta_k(u_i, v_i)$: son los coeficientes locales para cada variable independiente x_k en la ubicación i .
- x_{ik} : son las variables independientes en la ubicación i .
- ε_i : es el término de error aleatorio.

Una vez generado el GWR, se aplica los siguientes criterios para optimizar el modelo generado.

A. Validación Cruzada (CV)

Una manera de optimizar la GWR, es la validación cruzada (CV), la cual se usa para encontrar el valor óptimo del ancho de banda (bandwidth) que mejor se ajuste a los datos y minimice el error de predicción.

B. Criterio de Información Akaike (AIC)

La optimización del ancho de banda mediante el criterio de información de Akaike (AIC) en la regresión geográficamente ponderada (GWR) es un enfoque común para determinar el mejor valor de ancho de banda que se ajuste a los datos y proporcione un modelo GWR adecuado.

2.2.3. Macronutrientes

Los macronutrientes, están divididos en seis minerales y son esenciales para el crecimiento de las plantas, se clasifican en elementos primarios (N, P, K) y secundarios (Ca,

Mg, S).

- **Nitrógeno (N):** Crucial para aminoácidos y proteínas, el nitrógeno potencia el crecimiento vegetativo y la producción de clorofila (Wahid et al., 2023).
- **Fosforo (P):** Vital para la transferencia de energía (ATP) y el desarrollo radicular, el fósforo mejora la floración y fructificación (Varghese, 2022).
- **Potasio (K):** Regula el uso de agua y la activación enzimática, el potasio es esencial para la salud general de las plantas y la resistencia al estrés (Zewide & W, 2021).
- **Calcio (Ca):** Importante para la estructura y estabilidad de la pared celular, el calcio ayuda en la captación de nutrientes y el desarrollo radical (Varghese, 2022).
- **Magnesio (Mg):** Central para la producción de clorofila, el magnesio es crucial para la fotosíntesis y la función enzimática (Wahid et al., 2023).
- **Azufre (S):** Integral para aminoácidos y vitaminas, el azufre mejora la calidad del cultivo y la tolerancia al estrés (Zewide & W, 2021).

2.2.4. Micronutrientes

Según Sagwal et al., (2023), los micronutrientes del suelo forman parte de los nutrientes esenciales, los cuales son requeridos en cantidades muy pequeñas como parte de diversos sistemas enzimáticos de las plantas . Aquellos esenciales para las plantas son boro (B), cobre (Cu), hierro (Fe), manganeso (Mn) y zinc (Zn).

Las deficiencias en micronutrientes clave como Zn y B, particularmente regiones ácidas y semiáridas, puede conducir a una reducción de los rendimientos de los cultivos (Shafique et al., 2022).

III. MÉTODO

3.1. Tipo de investigación

Para el desarrollo de la presente tesis se seleccionó un diseño experimental transversal de enfoque cuantitativo, de tipo aplicada (Hernández & Mendoza, 2018), basándose que el propósito de la investigación será determinar la relación de las imágenes satelitales con la fertilidad de suelos en Lonya Grande, Utcubamba, Amazonas en el 2024.

3.2. Población y muestra

3.2.1. Población

La población de estudio abarca la totalidad del espacio geográfico del distrito de Lonya Grande, ubicado en la provincia de Utcubamba, departamento de Amazonas. Este distrito se destaca como el principal productor de café del departamento, según datos del portal SEIA (Ministerio de Desarrollo Agrario y Riego [MIDAGRI], 2024).

3.2.2. Muestra

La muestra seleccionada para el análisis de nutrientes en el área de estudio corresponde a 12 puntos de muestreo. La distribución de los puntos se realizó mediante un muestreo estratificado sistemático, dividiendo el área en cuatro zonas, según la localidad de la zona, esta última característica también se usó para codificar las muestras de la siguiente manera: Lonya Grande (LG-01, LG-02, LG-03 y LG-04), Roblepampa (RO-01, RO-02, RO-03 y RO-04), New York (NY-01, NY-02, NY-03 y NY-04) y Ortiz Arrieta (OA-01, OA-02, OA-03 y OA-04). Además, el área de estudio se complementó con imágenes satelitales procedentes del satélite SENTINEL-2.

3.3. Operacionalización de variables

Tabla 2

Operacionalización de variables de la investigación

VARIABLES	DEFINICIÓN CONCEPTUAL	DEFINICIÓN OPERACIONAL	DIMENSIONES	INDICADORES	TÉCNICA	INSTRUMENTO	EXPRESADO
Imágenes Satelitales (Variable Dependiente)	Las imágenes satelitales son fotografías tomadas de satélites que capturan la luz reflejada y emitida a través de varias longitudes de onda, proporcionando información sobre los recursos naturales de la Tierra y los cambios ambientales (Metternicht & Teece, 2023).	Esta variable se medirá por medio de 4 ítems divididos en dos dimensiones.	Satélite SENTINEL-2	- Banda 12 SWIR2.	Observación	Google Earth Engine ArcGIS 10.8 QGIS	Imágenes
			Modelo predictivo	- Regresión Geográficamente Ponderada (GWR). - Validación Cruzada (CV). - Criterio de Información Akaike (AIC).	Geoestadística	Software R	Hoja de análisis
Fertilidad de Suelos (Variable Independiente)	Cherlinka, (2024a), indica que la fertilidad del suelo hace referencia al potencial de un suelo para crear unas condiciones químicas, físicas y biológicas favorables para las plantas, proporcionándoles todos los nutrientes esenciales para su crecimiento. Es necesario entender que los nutrientes minerales no son alimento para las plantas (porque las plantas producen alimento por sí mismas mediante la fotosíntesis), sino un suplemento que proporciona más energía para su desarrollo. Así pues, se considera suelo fértil a aquel que cumple esta condición.	Esta variable se medirá por medio de 11 ítems divididos en 2 dimensiones.	Macronutrientes	- Valor de Nitrógeno (N). - Valor de Fosforo (P). - Valor de Potasio (K). - Valor de Calcio (Ca). - Valor de Magnesio (Mg). - Valor de Azufre (S).	Análisis de laboratorio	Recolección de muestra	Tablas
			Micronutrientes	- Valor de Boro (B). - Valor de Cobre (Cu). - Valor de Hierro (Fe). - Valor de Manganeso (Mn). - Valor de Zinc (Zn).	Análisis de laboratorio	Recolección de muestra	Tablas

3.4. Instrumentos

3.4.1. Sistema de posicionamiento global (GPS)

El GPS es un instrumento que sirve para encontrar las coordenadas de las muestras en el área de estudio. El GPS usado es de la marca Garmin, modelo OREGON 550, y las coordenadas ingresadas están en formato Universal Transversal Mercator (UTM) WGS 84, es decir en metros.

3.4.2. Envases para muestras

Son contenedores diseñados para recolectar, almacenar y transportar muestras de diferentes tipos, como líquidos, sólidos, gases o materiales biológicos, de manera segura y sin riesgos de contaminación. En esta investigación se usó bolsas con cierre hermético de la marca Ziploc con unas dimensiones de 17.7 cm x 19.5 cm y con capacidad de 1 kg.

3.4.3. Softwares para procesamiento de datos geoespaciales

Para realizar estas tareas, se emplearon programas especializados en Tecnologías de Información Geográfica (TIG) y en el procesamiento de datos geoespaciales, tales como Google Earth Engine, Google Earth Pro, RStudio, QGIS, ArcGIS 10.8 y TerrSet. Cada uno de estos programas ofrece herramientas avanzadas para la visualización, análisis y modelado espacial, facilitando un manejo preciso de la información geográfica y el análisis de datos.

3.4.4. Hojas de cálculo

Las hojas de cálculo son programas informáticos diseñados para organizar, calcular, analizar y visualizar datos de manera tabular. Esta investigación se apoyó directamente en los libros de Microsoft Excel, pues es aquí donde se organizaron mejor las tablas de los datos procesados.

3.5. Procedimientos

3.5.1. Delimitación del área con cultivos de café

Este paso es de vital importancia, pues gracias a este se modelan y se presentan de manera visual los lugares aptos para el desarrollo y cultivo de café, así como, discriminar los lugares que son de uso urbano, suelo desnudo o carreteras, para evitar errores al momento de la toma de muestras. Este proceso se basa principalmente en datos de precipitación y temperatura para delimitar el área óptima, la cual se compara posteriormente con el modelo de distribución de especies. Finalmente, se emplea el índice de suelo desnudo (BSI) para discriminar y caracterizar los lugares adecuados dentro del área de estudio.

3.5.2. Ubicación de los puntos de muestreo

Este proceso es consecuente al anterior, pues una vez delimitado el área con cultivos de café, se procede a cargar la capa creada a Google Earth Pro, para poder observar donde efectivamente existe cultivos de café y así ubicar los puntos de muestreo dentro de esa área.

3.5.3. Carga manual de las coordenadas al GPS

Obtenidos los 12 puntos de muestreo, se procede a ingresar de manera manual cada punto al GPS, teniendo en cuenta la nomenclatura asignada anteriormente. Luego de este proceso se realizó la recolección de muestras de suelo.

3.5.4. Datos de fertilidad de suelos

Dividido en dos actividades importantes:

a. Recolección de muestras de suelo

La recolección de las muestras es el hito principal de la investigación, pues sin esta no se puede avanzar. Cada muestra se recolectó según la ubicación marcada en el GPS, este emitió una vibración o sonido cuando se aproximó al lugar.

Según la Guía de Muestreo de Suelos del Ministerio del Ambiente [MINAM] (2014), indica que para la recolección de muestras se debe tomar en cuenta lo siguiente:

Tabla 3*Profundidad del muestreo según el uso del suelo*

USOS DEL SUELO	PROFUNDIDAD DEL MUESTREO (CAPAS)
Suelo Agrícola	0 – 30 cm (1) 30 – 60 cm
Suelo Residencial/Parques	0 – 10 cm (2) 10 – 30 cm (3)
Suelo Comercial/Industrial/Extractivo	0 – 10 cm (2)

1) Profundidad de aradura

2) Capa de contacto oral o dermal de contaminantes

3) Profundidad máxima alcanzable por niños

Nota. Tabla de profundidades para la toma de muestra de suelos según su uso (MINAM, 2014).

Para este estudio, se tomó una profundidad de 20 cm, adecuada para suelos agrícolas. El agujero tenía un ancho de aproximadamente 20 a 30 cm, para facilitar la recolección de la muestra de suelo. La muestra se obtuvo raspando las paredes del agujero, y posteriormente se mezcló de forma homogénea en un contenedor para su envase y almacenamiento.

b. Análisis de muestras de suelos

El proceso se inició con el envío de las muestras de suelo almacenadas al laboratorio de análisis en la ciudad de Lima y culminó con la recepción de informes detallados sobre los resultados de las 12 muestras. La elección de un laboratorio en la capital se debió a que los laboratorios locales no cuentan con todos los parámetros analíticos requeridos. El laboratorio elegido para el análisis de las muestras de suelos es del Instituto Valle Grande.

Las técnicas usadas para el análisis de las propiedades físicas y químicas de las muestras suelos, según el Laboratorio Químico Agrícola Valle Grande, son los siguientes:

Tabla 4

Principales parámetros y técnicas para el análisis de fertilidad del suelo

PARÁMETROS	TÉCNICA
Textura	
Arena	Bouyoucos
Limo	Bouyoucos
Arcilla	Bouyoucos
Macronutrientes	
Nitrógeno	Kjeldahl
Fósforo	Olsen
Potasio	Acetato de Amonio
Calcio	Espectrometría de Absorción Atómica por Llama
Magnesio	Espectrometría de Absorción Atómica por Llama
Azufre	CH ₃ COONH ₄ + CH ₃ COOH
Micronutrientes	
Boro	Colorimétrico
Cobre	Espectrometría de Absorción Atómica por Llama
Hierro	Espectrometría de Absorción Atómica por Llama
Manganeso	Espectrometría de Absorción Atómica por Llama
Zinc	Espectrometría de Absorción Atómica por Llama

Nota. Principales parámetros del suelo con sus respectivos métodos usados para su análisis (Laboratorio de Química Agrícola Valle Grande, 2024).

En la Tabla 4 se muestra los parámetros estudiados en esta investigación con sus respectivas técnicas empleadas por el Laboratorio de Química Agrícola Valle Grande para su análisis.

3.5.5. Procesamiento de imágenes satelitales

La descarga de imágenes satelitales en formato ráster se realizó mediante el uso de la plataforma Google Earth Engine, esta plataforma permite la descarga mediante scripts de productos Sentinel-2 y MODIS.

Para el procesamiento de imágenes con datos de temperatura, precipitaciones y altitud,

solo bastó en especificar el catálogo del producto, en este caso denominado WORLDCLIM/V1/BIO para los dos primeros y CGIAR/SRTM90_V4 para el último. Sin embargo, para el modelamiento de distribución de especies usando el algoritmo MaxEnt, se necesitó 22 variables provenientes de WORLDCLIM/V1/BIO (19 variables), CGIAR/SRTM90_V4 (01 variable), MODIS/061/MOD13A1 (01 variable) y MODIS/061/MCD12Q (01 variable), sumándole las ocurrencias descargadas de GBIF.

En el procesamiento del BSI, se necesitó bandas específicas del satélite Sentinel-2, como son: banda roja, banda azul, NIR y SWIR, con estas bandas se realizó un álgebra de mapas y se obtuvo dicho índice.

Finalmente, se extrajeron los valores ráster de la banda SWIR2 en cada uno de los puntos de muestreo, para elaborar una tabla detallada con estos datos. Esta tabla sirvió como base para llevar a cabo el análisis geostatístico mediante Regresión Geográficamente Ponderada (GWR).

3.5.6. Geoestadística

Este procedimiento se realizó netamente en la interfaz de RStudio. Pero antes de ejecutar el modelo GWR, se procedió a analizar las correlaciones entre los datos y para esto se instalaron las librerías: ggplot2, tidyverse, corrplot, PerformanceAnalytics y ggcorrplot. El siguiente proceso fue interpolar mediante IDW para ver la distribución de los datos de una manera gráfica y se instaló las librerías: ggplot2, readxl, rgdal, raster, sp, gdistance, gstat, ggspatial y automap, seguido se pasó a empaquetar los 23 resultados del IDW usando la librería raster en un solo archivo, este archivo sirve para extraer de manera rápida los datos contenidos en cada pixel y por ende por cada punto de muestreo, sin embargo, para realizar la extracción, primero se generaron cuadrículas en forma de hexágonos para cubrir toda el área óptima donde se distribuye Café Arábica, luego se generaron puntos aleatorios en cada uno de los hexágonos y así se extrajeron los datos ráster, además, al ser un número grande generado, se pasó a realizar

un resumen de datos usando el promedio para lo cual se instalaron librerías como: sf y dplyr. Finalmente, se realizó el modelamiento GWR y para esto se instaló previamente las librerías: rgdal, tmap, sf y spgwr.

3.5.7. Herramientas y softwares

- | | |
|--------------------------------|-----------------------------|
| – GPS. | – Celular para fotografías. |
| – Bolsas con cierre hermético. | – Google Earth Engine. |
| – Envase para mezclar. | – Google Earth Pro. |
| – Guantes. | – RStudio. |
| – Cinta métrica (Wincha). | – ArcGIS 10.8. |
| – Marcador indeleble. | – QGIS. |
| – Balanza gramera. | – TerrSet. |
| – Palana y pico pequeño. | – Excel |

3.6. Análisis de datos

3.6.1. Preparación de datos

Se organizó los datos relevantes del área geográfica. Esto incluye datos de precipitaciones, temperaturas, altitudes, datos de análisis de nutrientes y datos geospaciales (capas de ubicación, capas de áreas optimizadas).

3.6.2. Exploración de datos

Se realizó un análisis exploratorio de datos para comprender la distribución y correlación de los valores de nutrientes con los datos de la banda SWIR2, así como, con las características hidrogeológicas en el área geográfica. Esto implicó la creación de gráficos y tablas para identificar patrones iniciales.

3.6.3. Fertilidad del suelo

El análisis de fertilidad de las muestras de suelos lo realizó el Laboratorio de Química Agrícola Valle Grande. Estos informes sirvieron para poder realizar el modelamiento GWR y

la validación cruzada.

3.6.4. *Imágenes satelitales*

Se generó una presentación de las imágenes satelitales del satélite SENTINEL-2, específicamente la banda 12 SWIR2.

3.6.5. *Análisis espacial*

Se usaron técnicas de análisis espacial y geoestadístico empleando Tecnologías de Información Geográfica (TIG) para mapear la distribución de los valores de nutrientes y la construcción de mapas de parámetros del suelo.

3.7. Consideraciones éticas

En el proceso de investigación, se ponderará el impacto positivo en la sociedad o la comunidad estudiada, buscando maximizar los beneficios y minimizar cualquier posible perjuicio. La conducción del estudio se regirá por la honestidad y precisión, evitando la manipulación de datos o distorsión de resultados. Se mostrará respeto hacia todas las fuentes y trabajos previos incorporados en la investigación, reconociendo su contribución al conocimiento existente. Este enfoque ético busca asegurar que la investigación beneficie a la comunidad y contribuya de manera significativa al conocimiento colectivo.

IV. RESULTADOS

4.1. Características de la zona óptimas para el cultivo de café

De acuerdo a Ballesteros (2021), indica que la altitud en el que crece el Café arábica es entre los 800 y 2100 m.s.n.m. y en climas de 17°C hasta los 23°C.

A continuación, se muestra los requerimientos agroclimáticos para el café arábica:

Tabla 5

Requerimientos agroclimáticos para Café arábica

Variable	Unidad	Valor óptimo
Precipitación total anual	mm	1200 – 1800
Temperatura máxima	°C	21 – 30,6
Temperatura media	°C	17 - 23
Temperatura mínima	°C	10 – 19,9
Temperatura máxima extrema	°C	> 33
Temperatura mínima extrema	°C	07 – 10

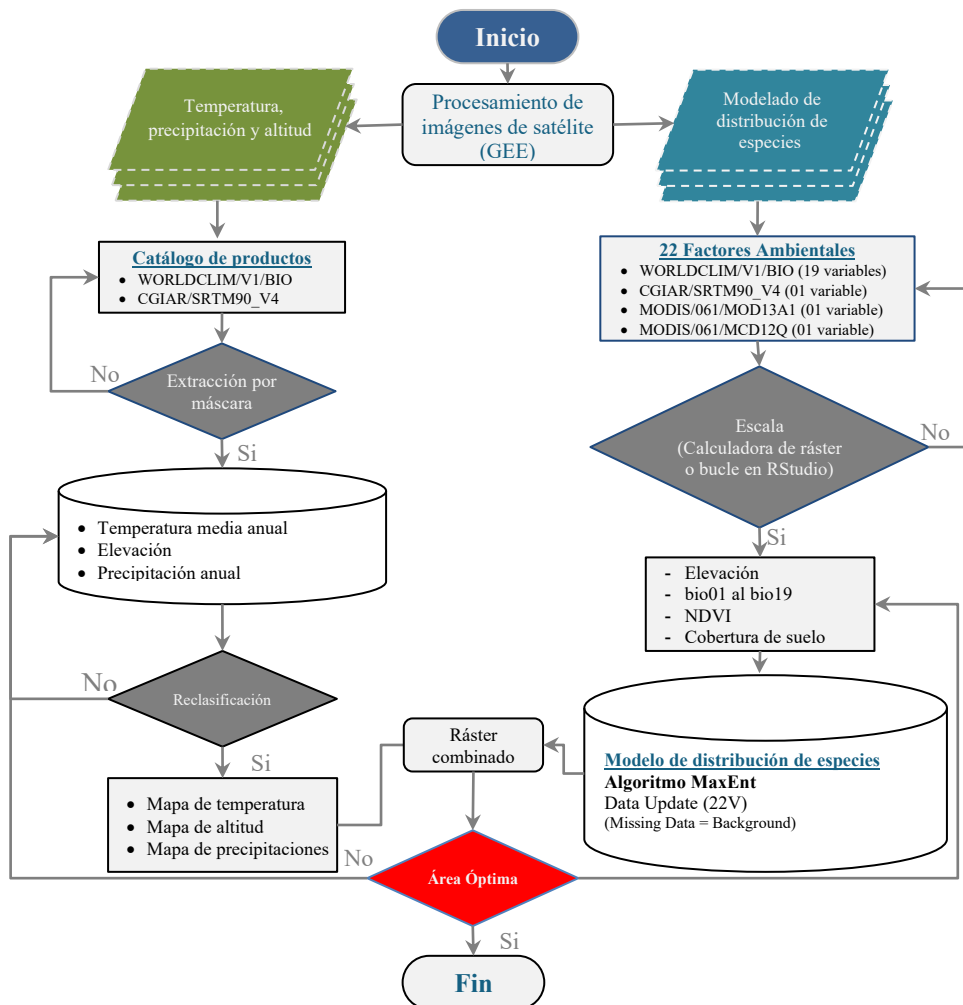
Nota. Parada et al., (2022)

Los datos presentados en la Tabla 5 ayudan a reforzar la información obtenida de Ballesteros, además de brindar un dato importante para poder determinar la zona de interés, este dato es la precipitación total anual.

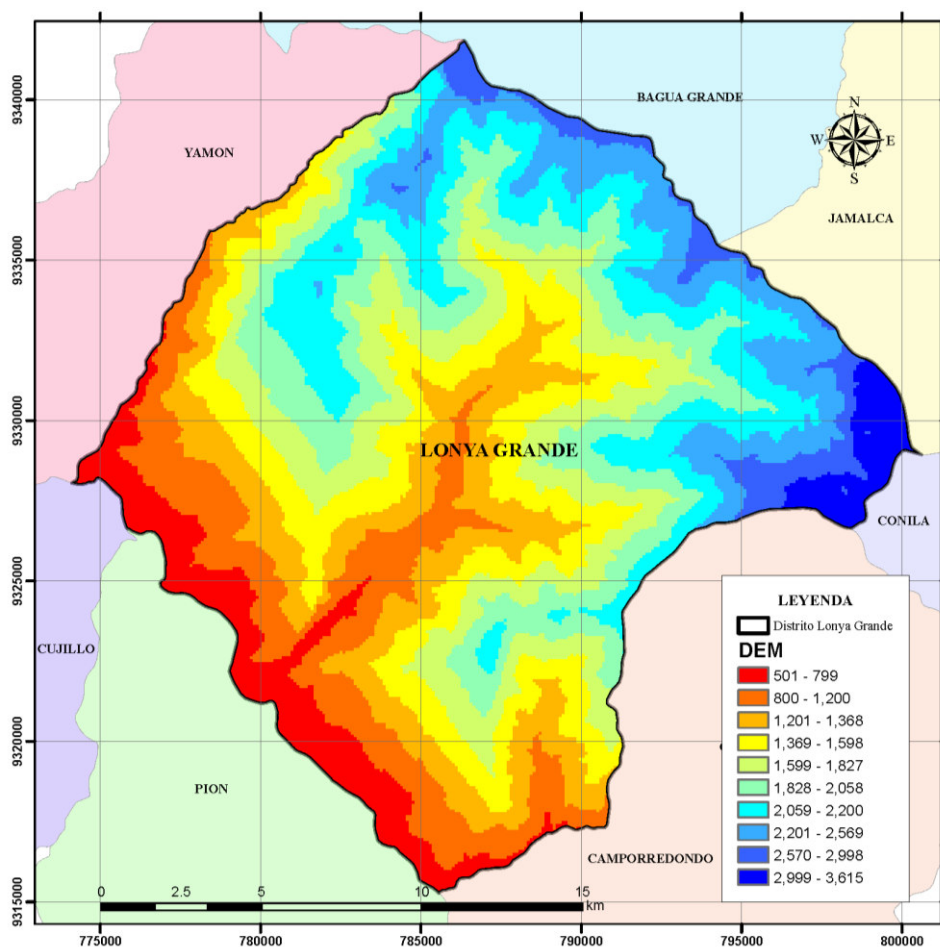
En la siguiente figura, se muestra el procedimiento seguido para la selección del área óptima, para luego presentar factores como altitudes, temperaturas, precipitaciones y el modelo de distribución de especies del distrito de Lonya Grande.

Figura 3

Flujo de trabajo para seleccionar el área óptima para el café Arábica



Nota. Flujo de trabajo seguido para la obtención del área óptima para cultivos de café arábica en la zona de estudio, es decir el distrito de Lonya Grande.

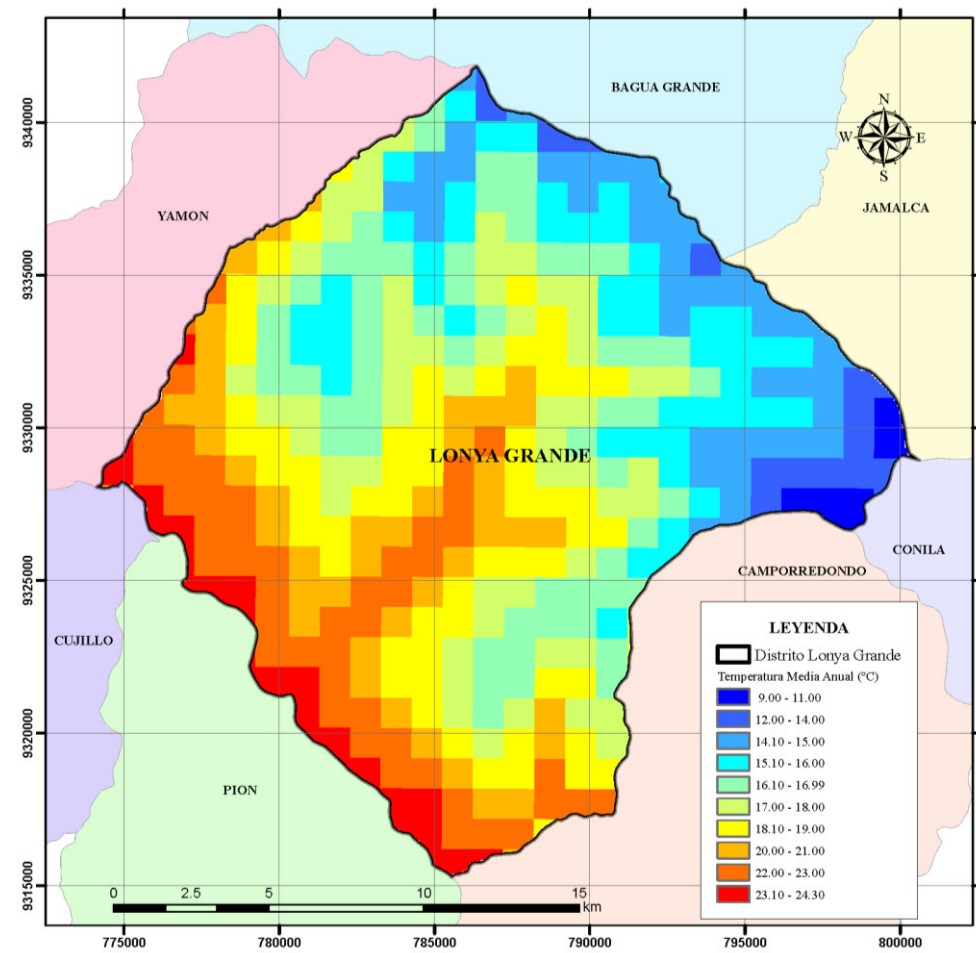
Figura 4*Modelo Digital de Elevación del distrito de Lonya Grande*

Nota. Data obtenida con una resolución de 90 metros de CGIAR/SRTM90_V4 (Jarvis & Guevara, 2018), a través de Google Earth Engine y procesada en ArcMap 10.8.

En Figura 4 se observa una vista gráfica del DEM (Modelo Digital de Elevación), el cual muestra las altitudes categorizado por colores, es así que desde el color naranja hasta el celeste son zonas aptas para el cultivo de café arábica.

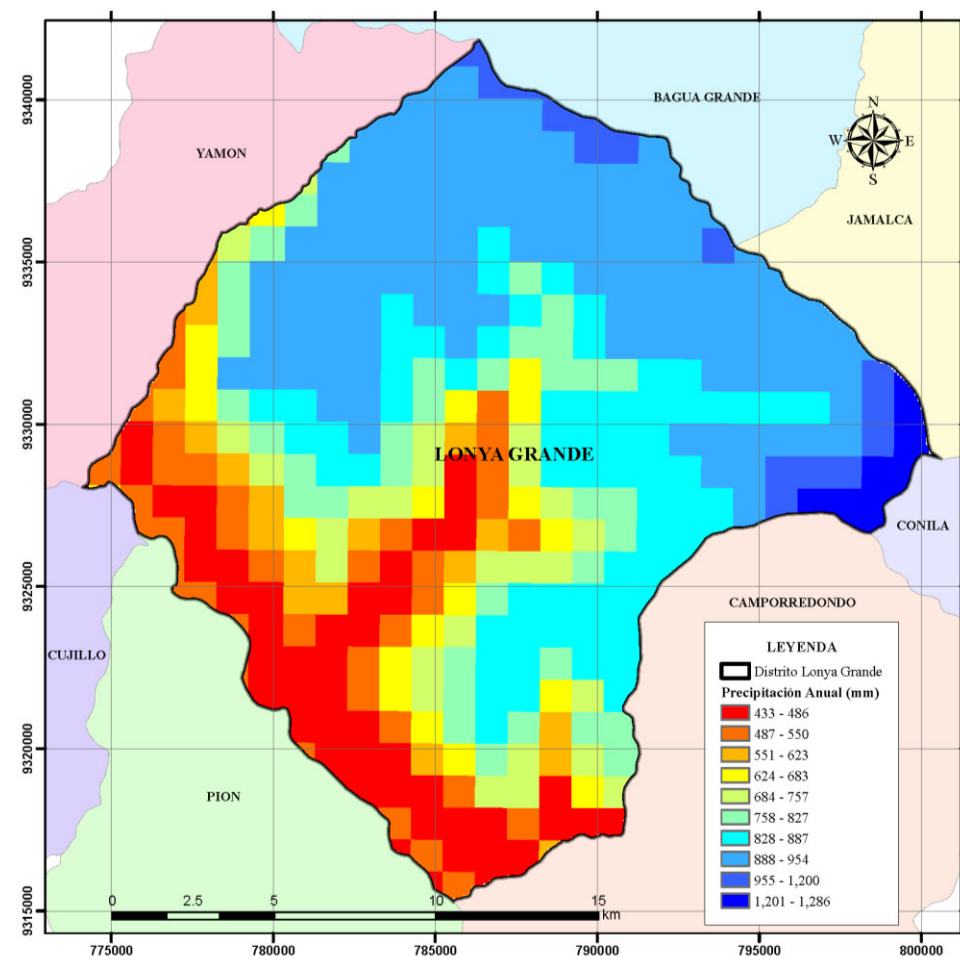
Figura 5

Temperatura Media Anual del distrito de Lonya Grande



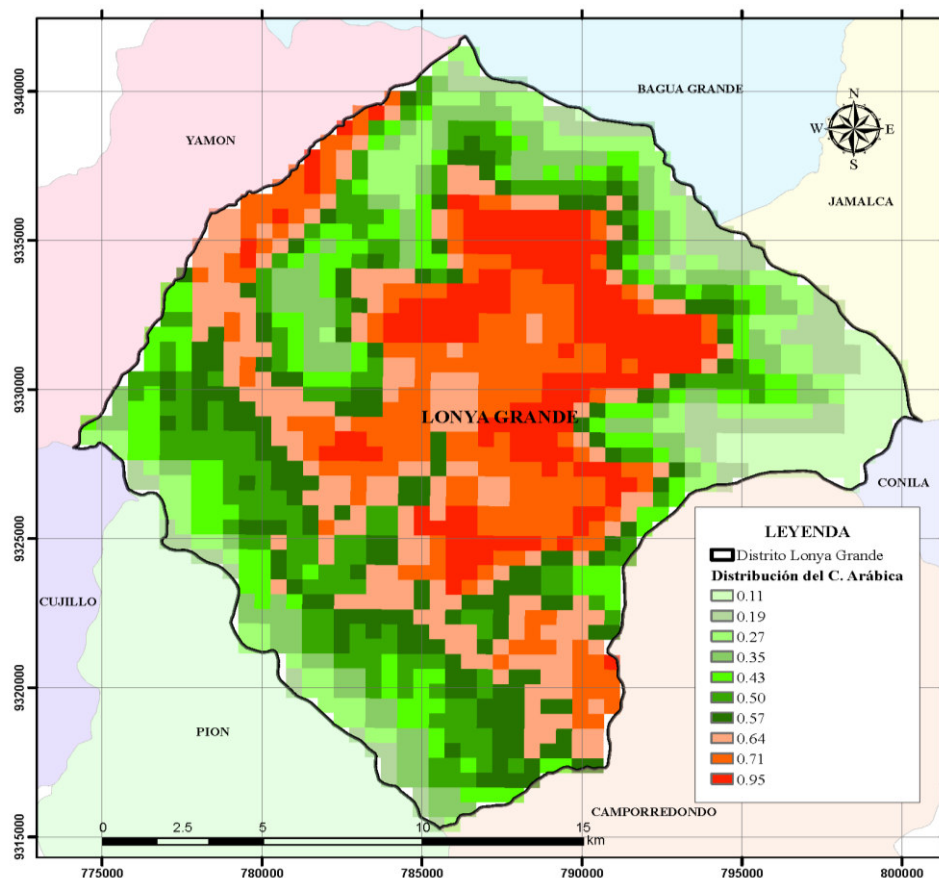
Nota. Data con una resolución de 927.67 metros obtenida de WORLDCLIM/V1/BIO (Hijmans et al., 2005) a través de Google Earth Engine y procesada en ArcMap 10.8.

La Figura 5 muestra las temperaturas presentes dentro del distrito de Lonya Grande, según esta clasificación, las zonas de color verde hasta naranja son las que presentan las condiciones climáticas necesarias para el crecimiento óptimo del café.

Figura 6*Precipitación Anual del distrito de Lonya Grande*

Nota. Data obtenida con una resolución de 927.67 metros de WORLDCLIM/V1/BIO (Hijmans et al., 2005) a través de Google Earth Engine y procesada en ArcMap 10.8.

Según la Figura 6, la cual muestra la precipitación anual, la categoría por color apta para el cultivo de café es la tercera tonalidad del color celeste, sin embargo, debe cumplir con el resto de las condiciones ambientales.

Figura 7*Modelo de distribución del café arábica*

Nota. Data obtenida con la aplicación del logaritmo MaxEnt usando un total 47 ocurrencias y 13 variables (Ver Anexo Tabla 25). El área bajo la curva (AUC) fue de 0.869, lo que sugiere un buen rendimiento del modelo.


La Figura 7 muestra el modelo de distribución para Café arábica, según el estudio de Orueta et al., (2014), indican que cuando el valor es igual o menor a 0.5 indica que el modelo no supera la predicción aleatoria, es decir, no tiene capacidad discriminativa. A medida que el valor de AUC se acerca a 1, la capacidad discriminativa del modelo mejora significativamente. En este sentido, los colores aptos del modelo están dados desde el color verde oscuro hasta el rojo, es decir de 0.57 a 0.95.

4.2. Ubicación de puntos de muestreo

Conocidas las características de la zona óptimas para el cultivo del café, procedemos a realizar un nuevo análisis que solo muestre las áreas que cumplen con esta definición.

Figura 8

Delimitación de la Zona óptima para el cultivo de café en Lonya Grande




Nota. Procesamiento realizado en ArcGIS 10.8 con los datos de entrada DEM, temperatura, precipitación y el modelo de distribución de especies.

La Figura 8 muestra la delimitación de la zona óptima para el cultivo de café, dicha zona tiene un área total de 19,079.06 ha., la delimitación se realizó usando las herramientas de: “Reclasificar” y “De Ráster a Polígono”. Además, se presenta en la vista la ubicación de los 04 centros poblados que sirvieron como referencia para realizar la división de la zona óptima.

Figura 9

Ubicación de los puntos de muestreo de suelo



Nota. Procesamiento realizado en ArcGIS 10.8. Esta figura representa visualmente los 12 puntos donde se realizó la toma de muestra de suelo.

Barren soil (BSI), es uno de los índices más usados para discriminar suelo desnudo, este se calcula según la siguiente fórmula:

$$BSI = ((SWIR2 + R) - (NIR + B)) / ((SWIR2 + R) + (NIR + B))$$

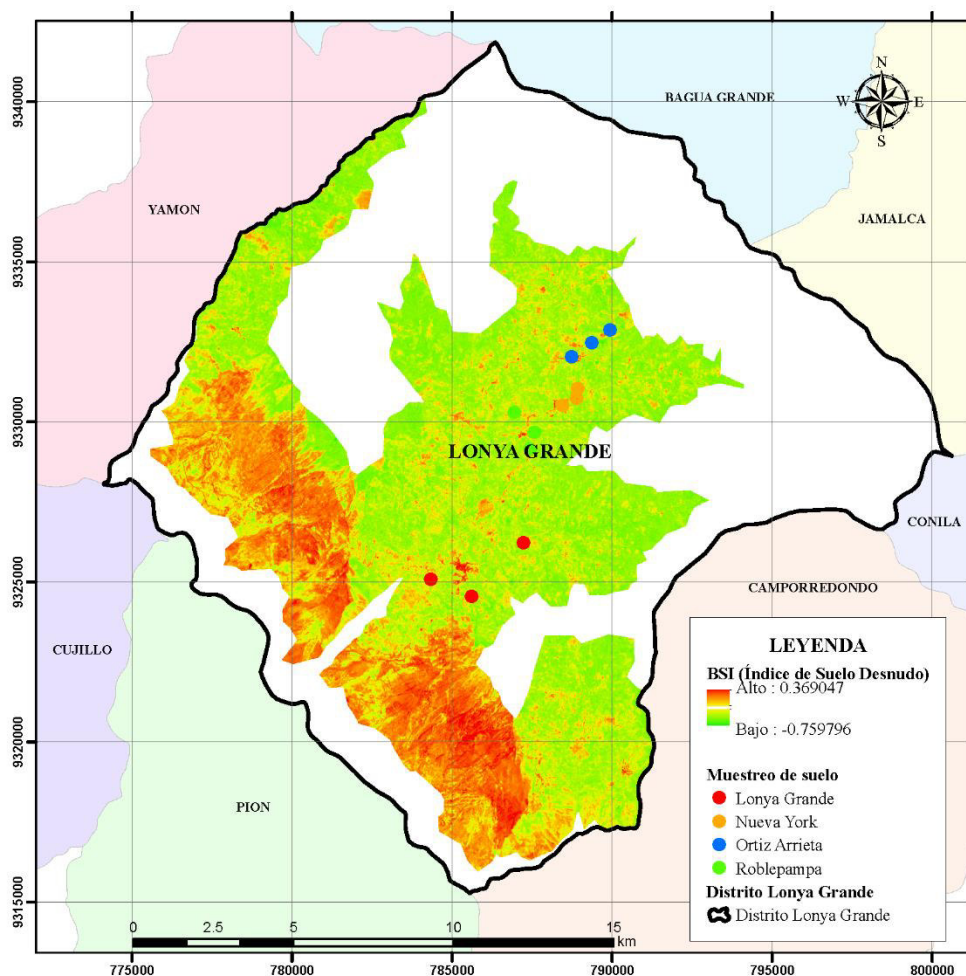
Donde:

Red (R) banda roja.

Blue (B) banda azul.

Near infrared (NIR), en SENTINEL-2 es la banda 8.

Short wave infrared (SWIR), en SENTINEL-2 es la banda 12.

Figura 10*Índice de Suelo Desnudo (BSI)*

Nota. Data obtenida con una resolución de 20 metros de COPERNICUS/S2_HARMONIZED y COPERNICUS/S2_SR_HARMONIZED a través de Google Earth Engine y procesada en ArcGIS 10.8.

La Figura 10 muestra las áreas con suelo desnudo, esta se diferencia por la coloración rojiza y por el rango que se presenta en la leyenda, este rango mientras más mayor, significa que hay suelo desnudo en la superficie.


4.3. Imágenes satelitales SENTINEL-2 – SWIR2

Con los puntos de muestreo ubicados y las áreas representativas escogidas, se procedió a buscar imágenes satelitales procedentes de SENTINEL-2 a través Google Earth Engine. Las

imágenes satelitales deben de cubrir toda la zona donde se localicen los puntos de muestreo.

Figura 11

Imagen Satelital procedentes de SENTINEL-2 – Banda 12 SWIR2



Nota. Data obtenida con una resolución de 20 metros de COPERNICUS/S2_HARMONIZED y COPERNICUS/S2_SR_HARMONIZED a través de Google Earth Engine y procesada en ArcGIS 10.8. Esta figura muestra los datos de la banda SWIR2 que tomarán cada punto de muestreo para poder realizar las correlaciones con los parámetros físicos y químicos del suelo.

Tabla 6

Datos de SWIR2 de acuerdo con las coordenadas de punto de muestreo

Nº	Código	Este	Norte	Altitud	SWIR2
1	LG-01	784344	9325092	1004	0.10115
2	LG-02	785619	9324550	1423	0.09340
3	LG-03	787226	9326229	1204	0.07615
4	RO-01	787438	9329176	1358	0.08570
5	RO-02	787569	9329689	1493	0.10155
6	RO-03	786943	9330318	1249	0.08495
7	NY-01	788444	9330524	1487	0.08075
8	NY-02	788882	9330741	1462	0.09650
9	NY-03	788931	9331049	1419	0.08450
10	OA-01	788731	9332040	1458	0.14160
11	OA-02	789366	9332489	1516	0.10030
12	OA-03	789947	9332890	1583	0.09790

Nota. Datos SWIR2 obtenidos luego de procesar las imágenes satelitales procedentes del catálogo COPERNICUS/S2_HARMONIZED a través de Google Earth Engine.

Los valores ráster extraídos por cada punto de muestreo se realizaron mediante el software QGIS, este proceso se puede realizar mediante la herramienta “Muestra de valores ráster” o usando la expresión “`raster_value ('SWIR_2', '1', $geometry)`”. Estos datos sirven para realizar las correlaciones y así poder elegir los parámetros que se utilizaron en el modelo predictivo GWR.

4.4. Datos de fertilidad de suelos

Estos datos provienen de hojas de análisis de muestras de suelos, es decir hay 12 muestras de diferentes ubicaciones, los cuales sirven para poder realizar la validación cruzada y así validar el modelo GWR.

Tabla 7

Resultados del análisis en el laboratorio de características físicas y químicas del suelo (01)

Código de Muestra	Arena	Limo	Arcilla	Sw	CE	pH_H2O	pH_CaCl2	MO	CC	PMP	N
LG-01	59.63	19.64	20.73	45.56	0.68	5.94	5.43	4.14	24.28	14.45	0.24
LG-02	49.59	31.65	18.76	64.31	0.67	5.68	5.26	6.48	34.47	20.51	0.38
LG-03	43.62	37.65	18.73	73.29	0.62	5.30	4.76	3.45	39.35	23.41	0.20
RO-01	33.58	35.64	30.78	74.24	1.38	5.07	4.77	5.79	39.87	23.72	0.34
RO-02	43.62	35.63	20.75	62.36	0.65	5.73	5.26	6.83	33.41	19.88	0.40
RO-03	33.63	39.64	26.73	74.78	0.61	5.46	4.96	7.45	40.16	23.90	0.43
NY-01	47.59	29.65	22.76	62.15	0.59	5.00	4.50	5.72	33.29	19.81	0.33
NY-02	45.62	31.65	22.73	65.22	0.66	5.05	4.62	4.41	34.97	20.80	0.26
NY-03	39.58	29.64	30.78	61.07	0.75	4.29	3.92	5.93	32.71	19.46	0.34
OA-01	53.62	29.63	16.75	70.83	0.37	4.47	3.98	6.28	38.01	22.62	0.36
OA-02	61.63	23.64	14.73	73.64	0.50	4.25	3.87	8.21	39.54	23.53	0.48
OA-03	61.59	25.65	12.76	73.53	0.35	4.36	3.93	5.93	39.48	23.49	0.34

Nomenclaturas:

Sw	: Saturación de agua
CE	: Conductividad eléctrica
pH_H2O	: pH en agua
pH_CaCl2	: pH en cloruro de calcio
MO	: Materia orgánica
CC	: Capacidad de campo
PMP	: Punto de marchitez permanente
N	: Nitrógeno total

Tabla 8

Resultados del análisis en el laboratorio de características físicas y químicas del suelo (02)

Código de Muestra	P	K	S	Ca	Mg	Na	CICE	Cu	Zn	Mn	Fe	B
LG-01	6.18	129.20	6.06	15.18	3.72	0.19	19.42	3.49	0.88	31.31	98.73	2.28
LG-02	10.02	84.40	7.50	29.19	6.74	0.22	33.36	7.89	1.83	56.01	181.32	2.20
LG-03	3.02	65.60	15.18	11.96	1.42	0.22	13.76	1.82	1.55	8.85	211.56	2.12
RO-01	1.10	147.60	11.88	9.59	3.21	0.18	13.36	17.76	5.53	112.35	121.74	2.32
RO-02	15.92	150.80	17.66	14.72	3.30	0.21	18.62	7.47	11.37	23.58	192.00	1.92
RO-03	7.96	151.20	18.90	16.28	3.72	0.23	20.61	6.95	6.81	98.67	183.24	2.04
NY-01	5.82	116.40	23.70	6.88	1.71	0.24	9.12	5.03	2.53	64.92	220.02	2.08
NY-02	7.68	59.80	25.02	6.78	1.01	0.23	8.16	4.58	1.53	31.54	155.85	2.44
NY-03	9.34	102.20	33.52	1.18	0.32	0.20	4.89	3.57	0.66	12.21	103.92	2.08
OA-01	7.42	44.40	26.38	0.74	0.27	0.20	4.25	3.40	0.54	4.35	143.97	1.88
OA-02	6.72	56.60	29.38	0.82	0.27	0.25	5.93	1.17	0.57	2.71	225.78	2.72
OA-03	6.04	43.60	6.06	0.59	0.20	0.20	3.99	1.84	1.06	3.68	209.70	2.40

Nomenclaturas:

P	: Fósforo disponible
K	: Potasio disponible
S	: Azufre disponible
Ca	: Calcio
Mg	: Magnesio
Na	: Sodio
CICE	: Capacidad de Intercambio Catiónico Efectivo
Cu	: Cobre
Zn	: Zinc
Mn	: Manganeso
Fe	: Hierro
B	: Boro

La Tabla 7 y 8 proporcionan datos de los 23 parámetros analizados en laboratorio correspondientes a 12 puntos de muestreo, dichos parámetros se subdividen en: 10 parámetros físicos (Arena, Arcilla, Limo, Sw, CE, pH_H2O, pH_CaCl2, MO, CC y PMP) y 13 parámetros químicos (N, P, K, S, Ca, Mg, Na, CICE, Cu, Zn, Mn, Fe y B).

4.4.1. Relación entre la arcilla, arena y limo con la banda 12 SWIR2

Benedet et al. (2019) indican que la espectroscopia SWIR ha mostrado una fuerte correlación con el contenido de arcilla y arena, logrando valores R^2 de 0.73 para arena y 0.83 para arcilla utilizando modelos multivariados como Cubist.

Tabla 9

Valores ráster asociados para resultado de arena, limo y arcilla

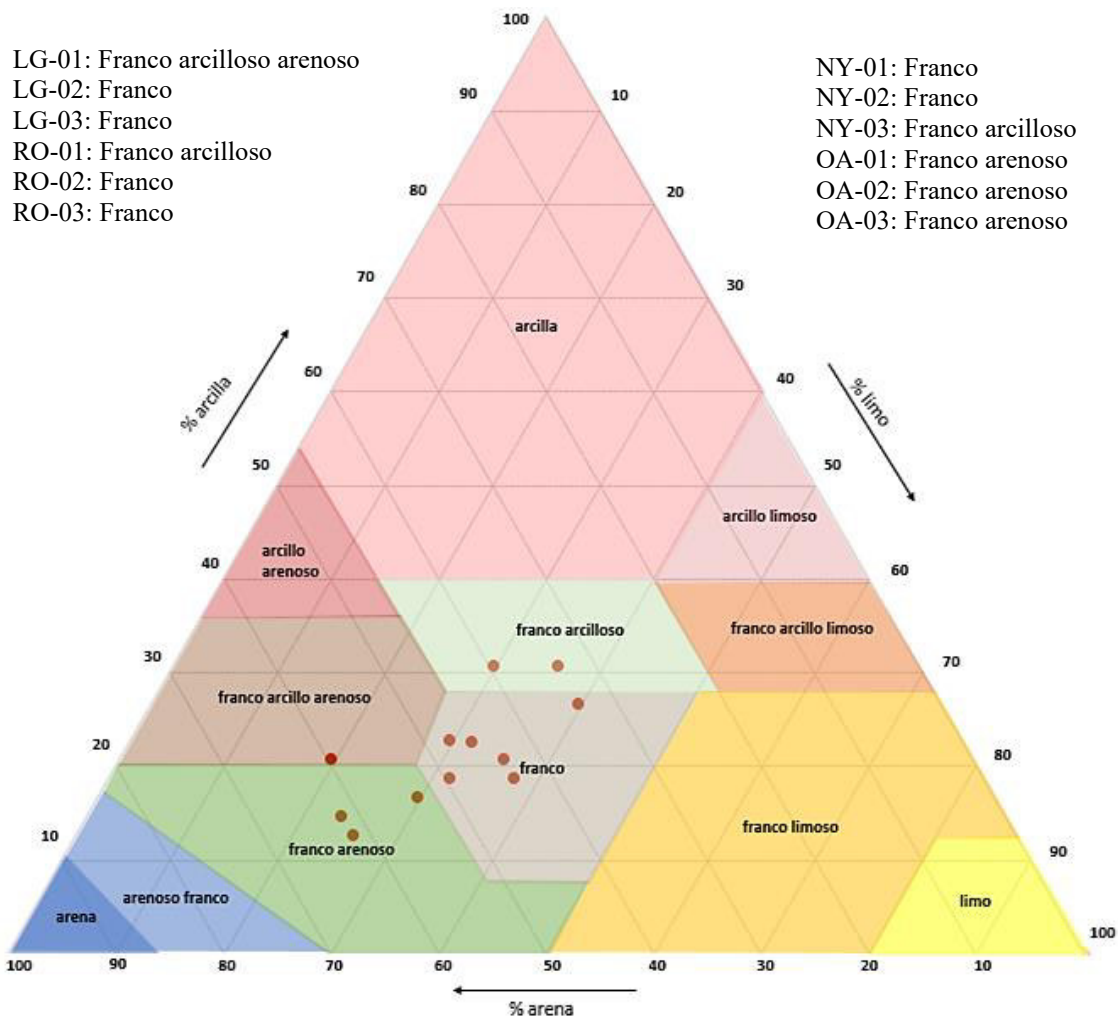
Nº	Código	Este	Norte	SWIR2	Arena	Limo	Arcilla
1	LG-01	784344	9325092	0.10115	59.63	19.64	20.73
2	LG-02	785619	9324550	0.09340	49.59	31.65	18.76
3	LG-03	787226	9326229	0.07615	43.62	37.65	18.73
4	RO-01	787438	9329176	0.08570	33.58	35.64	30.78
5	RO-02	787569	9329689	0.10155	43.62	35.63	20.75
6	RO-03	786943	9330318	0.08495	33.63	39.64	26.73
7	NY-01	788444	9330524	0.08075	47.59	29.65	22.76
8	NY-02	788882	9330741	0.09650	45.62	31.65	22.73
9	NY-03	788931	9331049	0.08450	39.58	29.64	30.78
10	OA-01	788731	9332040	0.14160	53.62	29.63	16.75
11	OA-02	789366	9332489	0.10030	61.63	23.64	14.73
12	OA-03	789947	9332890	0.09790	61.59	25.65	12.76

Nota. Los datos de esta tabla indican que los valores de SWIR2 tienen utilidad para estimar la textura del suelo, particularmente en relación con el contenido de arena.

Para generar la clase de textura del suelo se necesita de estos tres datos imprescindibles que son: arena, arcilla y limo. A continuación, se presenta el triángulo de texturas donde se ubican cada uno de los puntos muestreados.

Figura 12

Clases texturales de las 12 muestras de suelos




Nota. Triángulo de texturas creado en Microsoft Excel. Las muestras de suelo sugieren que los terrenos muestreados generalmente presentan suelos francos.

Las correlaciones de los puntos muestreados basándose en arena, limo y arcilla con la banda 12 SWIR2 de SENTINEL-2, quedan de la siguiente forma:

Figura 13


Correlación entre SWIR2 y el parámetro arena



Nota. La figura muestra una tendencia general al alza en los valores de Arena a medida que los valores del SWIR2 aumentan, lo que indica una correlación positiva entre estas dos variables. Sin embargo, también hay cierta variabilidad por algunos valores atípicos presentes.

Figura 14


Correlación entre SWIR2 y el parámetro limo



Nota. Esta figura de dispersión muestra una correlación negativa entre los valores de SWIR2 en el eje x y los valores de limo en el eje y. La línea de tendencia roja desciende de izquierda a derecha, lo que indica que a medida que aumentan los valores de SWIR2, disminuyen los valores de limo.

Figura 15

Correlación entre SWIR2 y el parámetro arcilla



Nota. Si bien hay una clara correlación negativa entre ambas variables, los datos presentan una dispersión considerable alrededor de la línea de tendencia roja. Esto indica que la relación entre SWIR2 y el contenido de arcilla es inversa.

4.4.2. Relación entre Saturación de agua (S_w) y la banda 12 SWIR2

El uso de imágenes SWIR (1400—1550 nm) mide eficazmente la saturación del suelo debido a la alta absorción del agua en este rango, proporcionando un método no invasivo para la evaluación de saturación (Parera et al., 2020). Este método aprovecha las características únicas de absorción del agua en el espectro infrarrojo de onda corta.

Tabla 10


Valores ráster asociados para resultado de Saturación de agua (Sw)

Nº	Código	Este	Norte	SWIR2	Sw
1	LG-01	784344	9325092	0.10115	45.56
2	LG-02	785619	9324550	0.09340	64.31
3	LG-03	787226	9326229	0.07615	73.29
4	RO-01	787438	9329176	0.08570	74.24
5	RO-02	787569	9329689	0.10155	62.36
6	RO-03	786943	9330318	0.08495	74.78
7	NY-01	788444	9330524	0.08075	62.15
8	NY-02	788882	9330741	0.09650	65.22
9	NY-03	788931	9331049	0.08450	61.07
10	OA-01	788731	9332040	0.14160	70.83
11	OA-02	789366	9332489	0.10030	73.64
12	OA-03	789947	9332890	0.09790	73.53

Nota. De esta tabla podemos observar que el grupo LG muestra la relación más clara, pero esta tendencia no se mantiene en los otros grupos, es decir, estos datos no están relacionados directamente o de forma lineal. La correlación entre la saturación de agua y la banda 12 SWIR2 de SENTINEL-2, queda de la siguiente forma:

Figura 16

Correlación entre SWIR2 y el parámetro saturación de agua (Sw)



Nota. Esta figura indica que existe una relación negativa leve entre estas dos variables, indicando así que cuando el SWIR2 aumenta, la saturación de agua tiene una ligera reducción.

4.4.3. *Relación entre Conductividad eléctrica (CE) y la banda 12 SWIR2*

Ferreira et al. (2023) indican que, si bien la frecuencia de la corriente eléctrica no afecta significativamente las mediciones de CE, puede correlacionarse con atributos del suelo como contenido de agua y pH. Por otra parte, Horváth et al., (2024), hallaron que los valores de CE aumentan con el aumento de la salinidad, con frecuencias específicas potenciando la detección de diferencias de concentración en las soluciones del suelo. También, Kumar et al., (2024) concluyen que existe una fuerte correlación entre la compactación del suelo y la conductividad eléctrica, lo que indica que la CE puede servir como un proxy para evaluar la compactación del suelo y otras propiedades relacionadas.

Tabla 11

Valores ráster asociados para resultado de Conductividad eléctrica (CE)


Nº	Código	Este	Norte	SWIR2	CE
1	LG-01	784344	9325092	0.10115	0.68
2	LG-02	785619	9324550	0.09340	0.67
3	LG-03	787226	9326229	0.07615	0.62
4	RO-01	787438	9329176	0.08570	1.38
5	RO-02	787569	9329689	0.10155	0.65
6	RO-03	786943	9330318	0.08495	0.61
7	NY-01	788444	9330524	0.08075	0.59
8	NY-02	788882	9330741	0.09650	0.66
9	NY-03	788931	9331049	0.08450	0.75
10	OA-01	788731	9332040	0.14160	0.37
11	OA-02	789366	9332489	0.10030	0.50
12	OA-03	789947	9332890	0.09790	0.35

Nota. Los resultados de esta tabla indican que existe una relación inversa entre SWIR2 y CE,

además, la relación es más consistente en valores bajos de CE. La correlación entre la conductividad eléctrica y la banda 12 SWIR2 de SENTINEL-2, queda de la siguiente forma:

Figura 17

Correlación entre SWIR2 y el parámetro Conductividad eléctrica (CE)



Nota. La tendencia negativa que se observa a medida que aumentan los valores de SWIR2, los valores de conductividad eléctrica tienden a disminuir. También se observa cierta dispersión de los puntos alrededor de la línea de tendencia, lo que indica que la relación no es perfectamente lineal.

4.4.4. Relación entre pH del suelo y la banda 12 SWIR2

La relación entre el pH en agua (pH_{H2O}) y el pH en cloruro de calcio (pH_{CaCl2}) es significativa en diversos contextos científicos, particularmente en química del suelo y estudios biológicos. Henderson & Bui (2002), en su estudio presentan una nueva curva de calibración para convertir el pH en agua (pH_{H2O}) a pH en CaCl₂ (pH_{CaCl2}), derivada de 70,465 observaciones, con un modelo aditivo estable que muestra una relación sigmoideal sobre el rango de pH de 2.5 a 10.5.

Tabla 12


Valores ráster asociados para resultado de pH

Nº	Código	Este	Norte	SWIR2	pH_H2O	pH_CaCl2
1	LG-01	784344	9325092	0.10115	5.94	5.43
2	LG-02	785619	9324550	0.09340	5.68	5.26
3	LG-03	787226	9326229	0.07615	5.30	4.76
4	RO-01	787438	9329176	0.08570	5.07	4.77
5	RO-02	787569	9329689	0.10155	5.73	5.26
6	RO-03	786943	9330318	0.08495	5.46	4.96
7	NY-01	788444	9330524	0.08075	5.00	4.50
8	NY-02	788882	9330741	0.09650	5.05	4.62
9	NY-03	788931	9331049	0.08450	4.29	3.92
10	OA-01	788731	9332040	0.14160	4.47	3.98
11	OA-02	789366	9332489	0.10030	4.25	3.87
12	OA-03	789947	9332890	0.09790	4.36	3.93

Nota. En esta tabla se puede definir que hay una ligera tendencia a que los valores más altos de SWIR2 se asocien con pH más bajos. La correlación entre el pH y la banda 12 SWIR2 de SENTINEL-2, quedan de la siguiente forma:

Figura 18

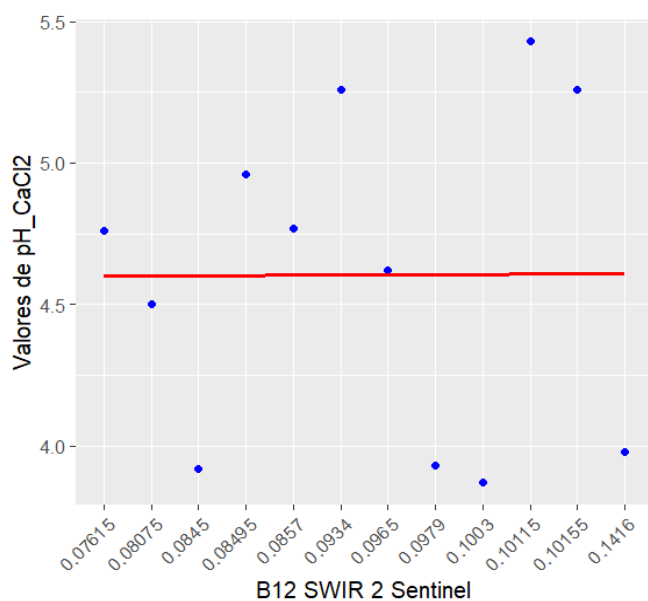
Correlación entre SWIR2 y el parámetro pH en agua (pH_H2O)



Nota. De esta figura se observa que no existe una relación significativa entre los valores de reflectancia de SWIR2 y el pH del agua en el suelo. Infiriendo que esta banda espectral específica no es un buen predictor para estimar los valores de pH en esta área de estudio.

Figura 19

Correlación entre SWIR2 y el parámetro pH en cloruro de calcio (pH_CaCl2)



Nota. Al igual que el anterior, se observa que no existe relación significativa entre los valores de reflectancia de SWIR2 y pH de cloruro de calcio en el suelo. También se infiere que esta banda no tiene buena capacidad predictiva para estimar los valores de pH.

4.4.5. Relación entre Materia Orgánica (MO) y la banda 12 SWIR2

La relación entre la materia orgánica (MO) y la banda 12 SWIR2 es significativa en el análisis del suelo, particularmente para estimar el contenido de materia orgánica del suelo (MOS). Nowkandeh et al. (2013) indican en su estudio que la banda SWIR2, parte del espectro Vis-SWIR, muestra una fuerte correlación con MOS, particularmente cuando se utilizan técnicas avanzadas de modelado. Por ejemplo, el modelo SWR logró un R^2 de 0.69 en la predicción del contenido SOM.

Tabla 13


Valores ráster asociados para resultado de Materia Orgánica (MO)

Nº	Código	Este	Norte	SWIR2	MO
1	LG-01	784344	9325092	0.10115	4.14
2	LG-02	785619	9324550	0.09340	6.48
3	LG-03	787226	9326229	0.07615	3.45
4	RO-01	787438	9329176	0.08570	5.79
5	RO-02	787569	9329689	0.10155	6.83
6	RO-03	786943	9330318	0.08495	7.45
7	NY-01	788444	9330524	0.08075	5.72
8	NY-02	788882	9330741	0.09650	4.41
9	NY-03	788931	9331049	0.08450	5.93
10	OA-01	788731	9332040	0.14160	6.28
11	OA-02	789366	9332489	0.10030	8.21
12	OA-03	789947	9332890	0.09790	5.93

Nota. Como se puede observar en los resultados obtenidos para MO los valores no son tan distantes, esto indica que la distribución de la materia orgánica en el área de estudio se comporta de manera homogénea. Sin embargo, la variación en los valores de MO establece diversas condiciones del suelo en las distintas zonas muestreadas. La correlación entre la Mo y la banda 12 SWIR2 de *SENTINEL-2*, queda de la siguiente forma:

Figura 20

Correlación entre SWIR2 y el parámetro MO



Nota. Esta figura indica que el SWIR2 puede ser un indicador útil del contenido de materia orgánica en el suelo, pero se debe tomar en cuenta otros factores. Además, se observa que hay una tendencia de aumento de MO cuando el SWIR2 aumenta.

4.4.6. Relación entre Capacidad de campo (CC), el punto de marchitez permanente (PMP) y la banda 12 SWIR2

La relación entre Capacidad de Campo (CC), Punto de marchitez permanente (PMP) y Banda 12 SWIR2 es significativa para comprender la dinámica de humedad del suelo y la disponibilidad de agua de las plantas. CC representa el contenido máximo de agua que el suelo puede retener después de drenar el exceso de agua, mientras que PMP indica el nivel de humedad al que las plantas ya no pueden extraer agua (Qiao et al., 2019).

Tabla 14

Valores ráster asociados para resultado de Capacidad de campo (CC) y Punto de marchitez permanente (PMP)


Nº	Código	Este	Norte	SWIR2	CC	PMP
1	LG-01	784344	9325092	0.10115	24.28	14.45
2	LG-02	785619	9324550	0.09340	34.47	20.51
3	LG-03	787226	9326229	0.07615	39.35	23.41
4	RO-01	787438	9329176	0.08570	39.87	23.72
5	RO-02	787569	9329689	0.10155	33.41	19.88
6	RO-03	786943	9330318	0.08495	40.16	23.90
7	NY-01	788444	9330524	0.08075	33.29	19.81
8	NY-02	788882	9330741	0.09650	34.97	20.80
9	NY-03	788931	9331049	0.08450	32.71	19.46
10	OA-01	788731	9332040	0.14160	38.01	22.62
11	OA-02	789366	9332489	0.10030	39.54	23.53
12	OA-03	789947	9332890	0.09790	39.48	23.49

Nota. Estos datos indican que hay relación proporcional entre CC y PMP, es decir cuando uno aumenta el otro también. Sin embargo, no se define una relación clara entre los datos de SWIR2

y estas dos variables. La correlación entre CC, PMP y la banda 12 SWIR2 de SENTINEL-2, quedan de la siguiente forma:

Figura 21


Correlación entre SWIR2 y el parámetro CC



Nota. En esta figura se observa una tendencia negativa, lo que se traduce en que a mayores valores de SWIR2, tiende a haber una ligera disminución en la CC. También, se puede ver un valor muy bajo en relación con los demás resultados y se le considera un dato atípico.

Figura 22

Correlación entre SWIR2 y el parámetro PMP



Nota. Al igual que la anterior figura, se observa tendencia negativa, donde a mayores valores de SWIR2, el PMP tiene una ligera disminución. También se tiene presente el dato atípico anterior.

4.4.7. Relación entre la Capacidad de Intercambio Catiónico Efectivo (CICE) y la banda 12 SWIR2

El CICE es un parámetro clave en estudios de fertilidad de suelos y calidad del sustrato para el crecimiento de cultivos. CIC es una medida de la capacidad de un suelo para retener e intercambiar cationes, la cual está influenciada por diversos factores incluyendo la composición del suelo y el pH. Seybold & Grossman (2006), en su estudio muestran que CIC puede predecirse utilizando propiedades del suelo como el carbono total y el pH, con ciertos tipos de suelo que exhiben predictibilidad variada.

Tabla 15


Valores ráster asociados para resultado de Capacidad de Intercambio Catiónico Efectivo (CICE)

Nº	Código	Este	Norte	SWIR2	CICE
1	LG-01	784344	9325092	0.10115	19.42
2	LG-02	785619	9324550	0.09340	33.36
3	LG-03	787226	9326229	0.07615	13.76
4	RO-01	787438	9329176	0.08570	13.36
5	RO-02	787569	9329689	0.10155	18.62
6	RO-03	786943	9330318	0.08495	20.61
7	NY-01	788444	9330524	0.08075	9.12
8	NY-02	788882	9330741	0.09650	8.16
9	NY-03	788931	9331049	0.08450	4.89
10	OA-01	788731	9332040	0.14160	4.25
11	OA-02	789366	9332489	0.10030	5.93
12	OA-03	789947	9332890	0.09790	3.99

Nota. Algunos valores de SWIR2 más altos (por ejemplo, el punto 10, OA-01, con SWIR2 = 0.1416) tienden a tener valores de CICE más bajos. Esto significa que los suelos con baja capacidad de intercambio catiónico tienden a reflejar más luz en el SWIR2. La correlación entre CICE y la banda 12 SWIR2 de SENTINEL-2, queda de la siguiente forma:

Figura 23

Correlación entre SWIR2 y el parámetro CICE



Nota. En esta figura podemos observar una relación levemente negativa, lo que indica que SWIR2 no es un predictor fuerte por sí solo, es decir necesita del apoyo de más variables.

4.4.8. Relación entre los macronutrientes y la banda 12 SWIR2

Los macronutrientes son elementos esenciales que se requieren para diversas funciones biológicas tanto en plantas como en humanos. Incluyen nitrógeno (N), fósforo (P), potasio (K), calcio (Ca), magnesio (Mg) y azufre (S).

La calidad del suelo influye en la disponibilidad de nutrientes; los estudios muestran que las mejores condiciones del suelo mejoran el contenido de macronutrientes en los cultivos (Faizullah et al., 2024). Debido a la alta volatilidad de los macronutrientes, es difícil que se establezcan en el suelo durante la rotación de cultivos o procesos de cosecha y siembra, siendo sus valores bastante dinámicos, por lo que el muestreo de suelo se usa para obtener tal información

(Neugschwandtner et al., 2022).

Tabla 16


Valores ráster asociados para resultado de los macronutrientes (N, P, K, S, Ca, Mg)

Nº	Código	Este	Norte	SWIR2	N	P	K	S	Ca	Mg
1	LG-01	784344	9325092	0.10115	0.24	6.18	129.20	6.06	15.18	3.72
2	LG-02	785619	9324550	0.09340	0.38	10.02	84.40	7.50	29.19	6.74
3	LG-03	787226	9326229	0.07615	0.20	3.02	65.60	15.18	11.96	1.42
4	RO-01	787438	9329176	0.08570	0.34	1.10	147.60	11.88	9.59	3.21
5	RO-02	787569	9329689	0.10155	0.40	15.92	150.80	17.66	14.72	3.30
6	RO-03	786943	9330318	0.08495	0.43	7.96	151.20	18.90	16.28	3.72
7	NY-01	788444	9330524	0.08075	0.33	5.82	116.40	23.70	6.88	1.71
8	NY-02	788882	9330741	0.09650	0.26	7.68	59.80	25.02	6.78	1.01
9	NY-03	788931	9331049	0.08450	0.34	9.34	102.20	33.52	1.18	0.32
10	OA-01	788731	9332040	0.14160	0.36	7.42	44.40	26.38	0.74	0.27
11	OA-02	789366	9332489	0.10030	0.48	6.72	56.60	29.38	0.82	0.27
12	OA-03	789947	9332890	0.09790	0.34	6.04	43.60	6.06	0.59	0.20

Nota. En esta tabla no se aprecia una relación evidente entre los valores de los nutrientes individuales y la banda SWIR2, es decir es necesario realizar una correlación para poder confirmar si hay alguna relación. La correlación entre N, P, K, S, Ca, Mg y la banda 12 SWIR2 de SENTINEL-2, quedan de la siguiente forma:

Figura 24


Correlación entre SWIR2 y el parámetro N



Nota. En esta figura podemos ver que hay una relación con una tendencia positiva leve, pero al tener los puntos bastante dispersos se infiere que hay una variabilidad considerable en los datos.

Figura 25


Correlación entre SWIR2 y el parámetro P



Nota. De esta figura se observa que existe una relación positiva entre las mediciones del satélite, pero también se debe tener en cuenta los demás parámetros, pues se tiene puntos bastante variables.

Figura 26*Correlación entre SWIR2 y el parámetro K*


Nota. A diferencia de los dos anteriores parámetros, tenemos una relación con tendencia negativa leve en esta figura, pero esta es débil debido a la dispersión de los puntos.

Figura 27*Correlación entre SWIR2 y el parámetro S*

Nota. En esta figura se puede ver una tendencia negativa muy leve, lo que indica una relación muy débil entre este parámetro y la banda SWIR2.

Figura 28


Correlación entre SWIR2 y el parámetro Ca



Nota. Este parámetro mostrado en esta figura también indica una relación negativa leve, es decir la relación con la banda SWIR2 es negativa débil.

Figura 29

Correlación entre SWIR2 y el parámetro Mg



Nota. En esta figura podemos ver una relación muy débil, este es el parámetro que presenta más debilidad en relación con la banda SWIR2.

4.4.9. Relación entre micronutrientes y la banda 12 SWIR2

La relación entre micronutrientes y banda 12 SWIR2 (infrarrojo de onda corta) es significativa en el contexto de la detección de deficiencias de micronutrientes en plantas. La banda SWIR2 es sensible a cambios en la estructura mineral, tal como lo dice Cloutier et al., (2021), los cambios en la composición de cationes entre capas de la mica blanca se correlacionan con los cambios en la característica de absorción de 2200 nm, lo que indica modificaciones estructurales.

Tabla 17


Valores ráster asociados para cada muestra a los micronutrientes (Na, Cu, Zn, Mn, Fe, B)

N°	Código	Este	Norte	SWIR2	Na	Cu	Zn	Mn	Fe	B
1	LG-01	784344	9325092	0.10115	0.19	3.49	0.88	31.31	98.73	2.28
2	LG-02	785619	9324550	0.09340	0.22	7.89	1.83	56.01	181.32	2.20
3	LG-03	787226	9326229	0.07615	0.22	1.82	1.55	8.85	211.56	2.12
4	RO-01	787438	9329176	0.08570	0.18	17.76	5.53	112.35	121.74	2.32
5	RO-02	787569	9329689	0.10155	0.21	7.47	11.37	23.58	192.00	1.92
6	RO-03	786943	9330318	0.08495	0.23	6.95	6.81	98.67	183.24	2.04
7	NY-01	788444	9330524	0.08075	0.24	5.03	2.53	64.92	220.02	2.08
8	NY-02	788882	9330741	0.09650	0.23	4.58	1.53	31.54	155.85	2.44
9	NY-03	788931	9331049	0.08450	0.20	3.57	0.66	12.21	103.92	2.08
10	OA-01	788731	9332040	0.14160	0.20	3.40	0.54	4.35	143.97	1.88
11	OA-02	789366	9332489	0.10030	0.25	1.17	0.57	2.71	225.78	2.72
12	OA-03	789947	9332890	0.09790	0.20	1.84	1.06	3.68	209.70	2.40

Nota. Los datos de esta tabla muestran que no hay relación entre los micronutrientes y la banda SWIR2, es decir este último no parece que sea un buen predictor. Además, cada micronutriente tiene variabilidades diferentes. La correlación entre Na, Cu, Zn, Mn, Fe, B y la banda 12 SWIR2 de SENTINEL-2, quedan de la siguiente forma:

Figura 30

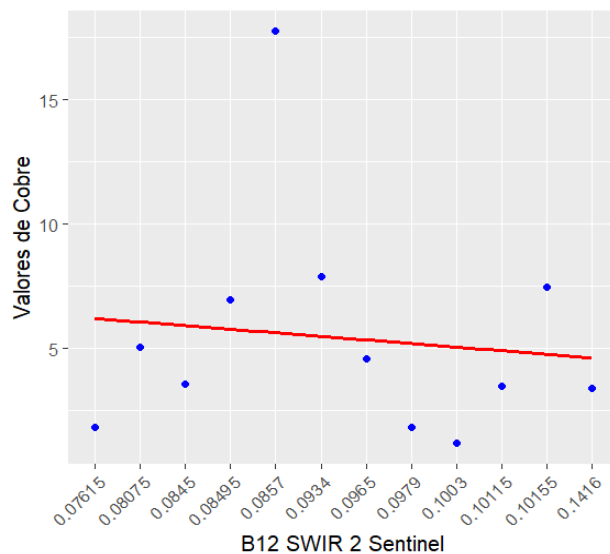
Correlación entre SWIR2 y el parámetro Na



Nota. Se aprecia en esta figura una relación de tendencia negativa leve, sin embargo, la relación es más consistente en comparación con los demás nutrientes analizados.

Figura 31

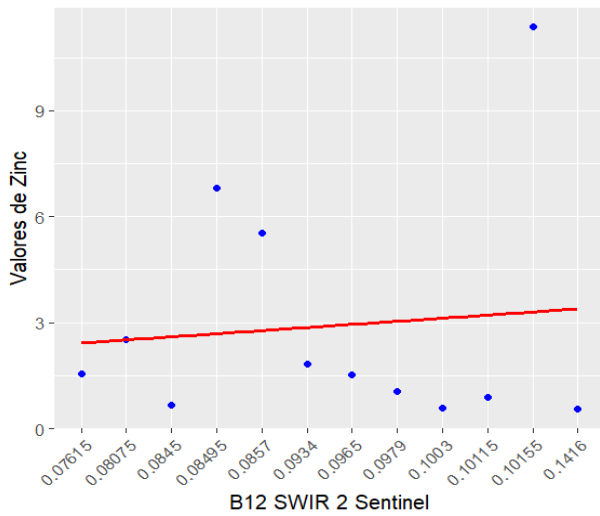
Correlación entre SWIR2 y el parámetro Cu



Nota. Esta gráfica indica que hay una tendencia negativa leve, es decir la relación no es fuerte entre las mediciones del sensor SWIR2 y los niveles de cobre.

Figura 32


Correlación entre SWIR2 y el parámetro Zn



Nota. La gráfica muestra una relación positiva leve, pero es una relación débil y por ende hay muy poca relación entre el parámetro y la banda SWIR2.

Figura 33


Correlación entre SWIR2 y el parámetro Mn



Nota. Esta vista de este grafico indica una tendencia negativa fuerte, es decir, existe una relación inversa entre el parámetro y la banda SWIR2.

Figura 34


Correlación entre SWIR2 y el parámetro Fe



Nota. Esta gráfica también indica que existe una relación inversa débil entre los dos elementos comparados, es decir hay una línea de tendencia negativa.

Figura 35

Correlación entre SWIR2 y el parámetro B



Nota. En este gráfico se puede observar una tendencia positiva muy débil, pues los datos están muy dispersos de la línea de tendencia, es decir, la relación entre este parámetro y la banda SWIR2 es bastante débil.

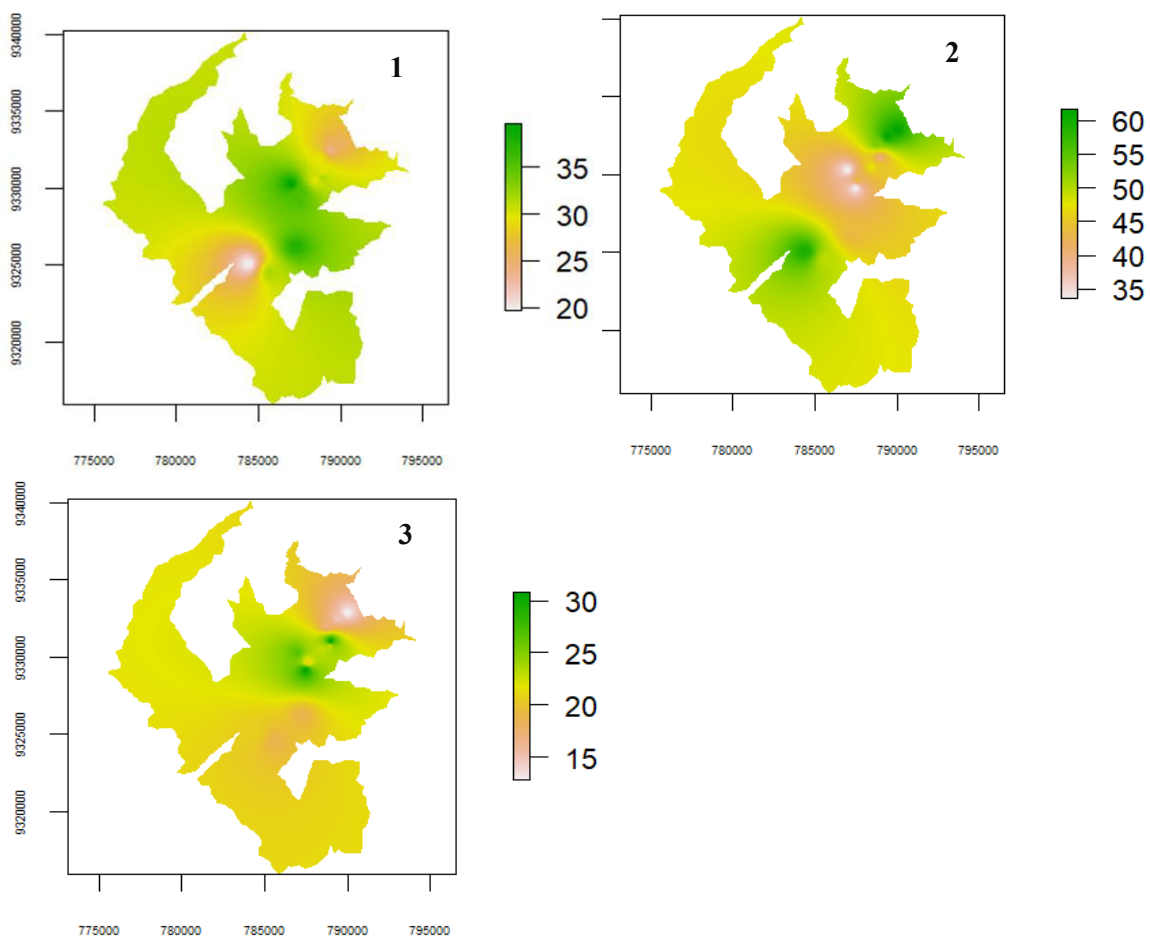
4.5. Generación de mapas por parámetros del suelo

El método de ponderación a distancia inversa (IDW) es una técnica de interpolación espacial ampliamente utilizada para generar mapas de parámetros de suelo, particularmente en estudios geotécnicos y ambientales. Si bien la IDW es efectiva, los estudios indican que los métodos geoestadísticos como el Kriging Ordinario pueden superar la IDW en precisión para aplicaciones específicas (Najmaddin et al., 2020). Sin embargo, IDW sigue siendo una opción preferida por su simplicidad y facilidad de implementación (AbdelRahman et al., 2021).

A continuación, se presentan los mapas generados usando la interpolación IDW de cada uno de los parámetros analizados:

Figura 36

Interpolación con IDW para variables de textura: 1) Arcilla, 2) Arena y 3) Limo

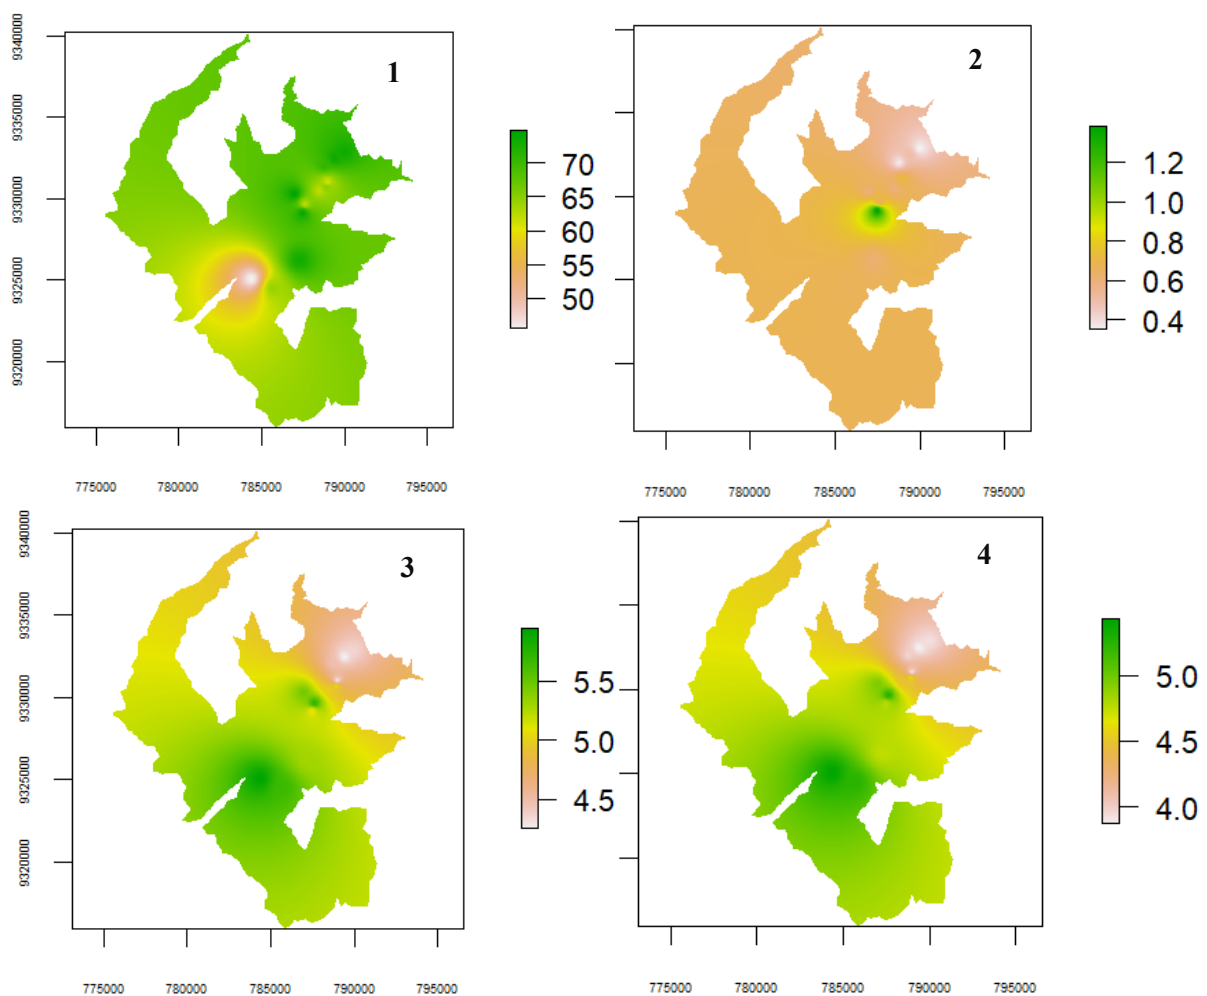


Nota. Mapeo de tres parámetros del informe de suelo (arcilla, arena y limo), fue realizado usando interpolación IDW. La interpolación se ejecutó solo dentro del área óptima para C. Arábica, además se definió que cada píxel tenga 2 x 2 metros. El objetivo de definir el tamaño del píxel es que sea de alta resolución pues será equivalente a un área real de 4 m².

Figura 37

Interpolación con IDW para variables de saturación de agua, conductividad eléctrica y pH:

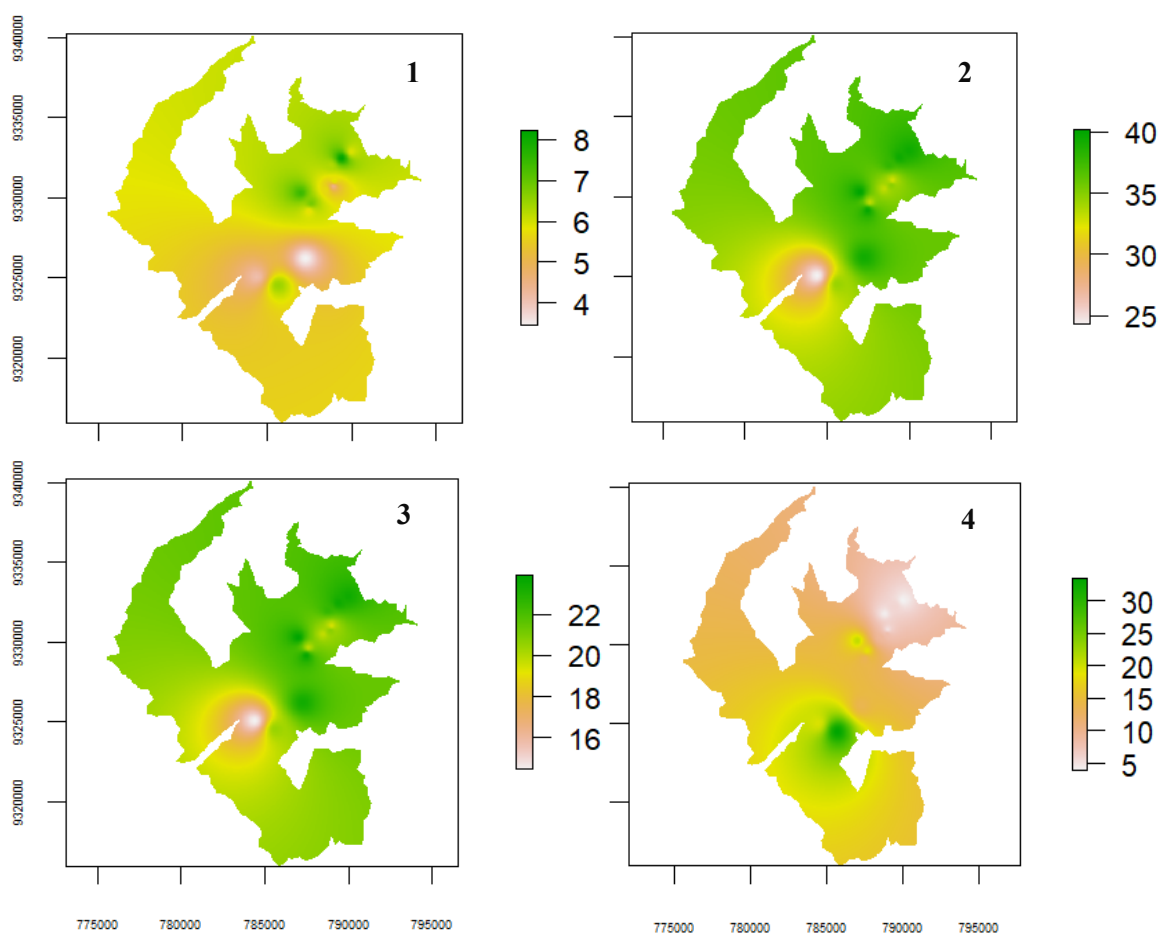
1) *Sw*, 2) *CE*, 3) *pH_H2O* y 4) *pH_CaCl2*



Nota. Mapeo de cuatro parámetros del informe de suelo (saturación de agua, conductividad eléctrica y pH). La generación de estos resultados fue realizada usando interpolación IDW, donde se tuvo especial consideración en la definición de las grillas (píxel), pues estos resultados sirven como base de datos para poder extraer los valores ráster a través de puntos aleatorios.

Figura 38

Interpolación con IDW para variables de materia orgánica, capacidad de campo, punto de marchitez permanente y capacidad de intercambio catiónico efectivo: 1) MO, 2) CC, 3) PMP y 4) CICE

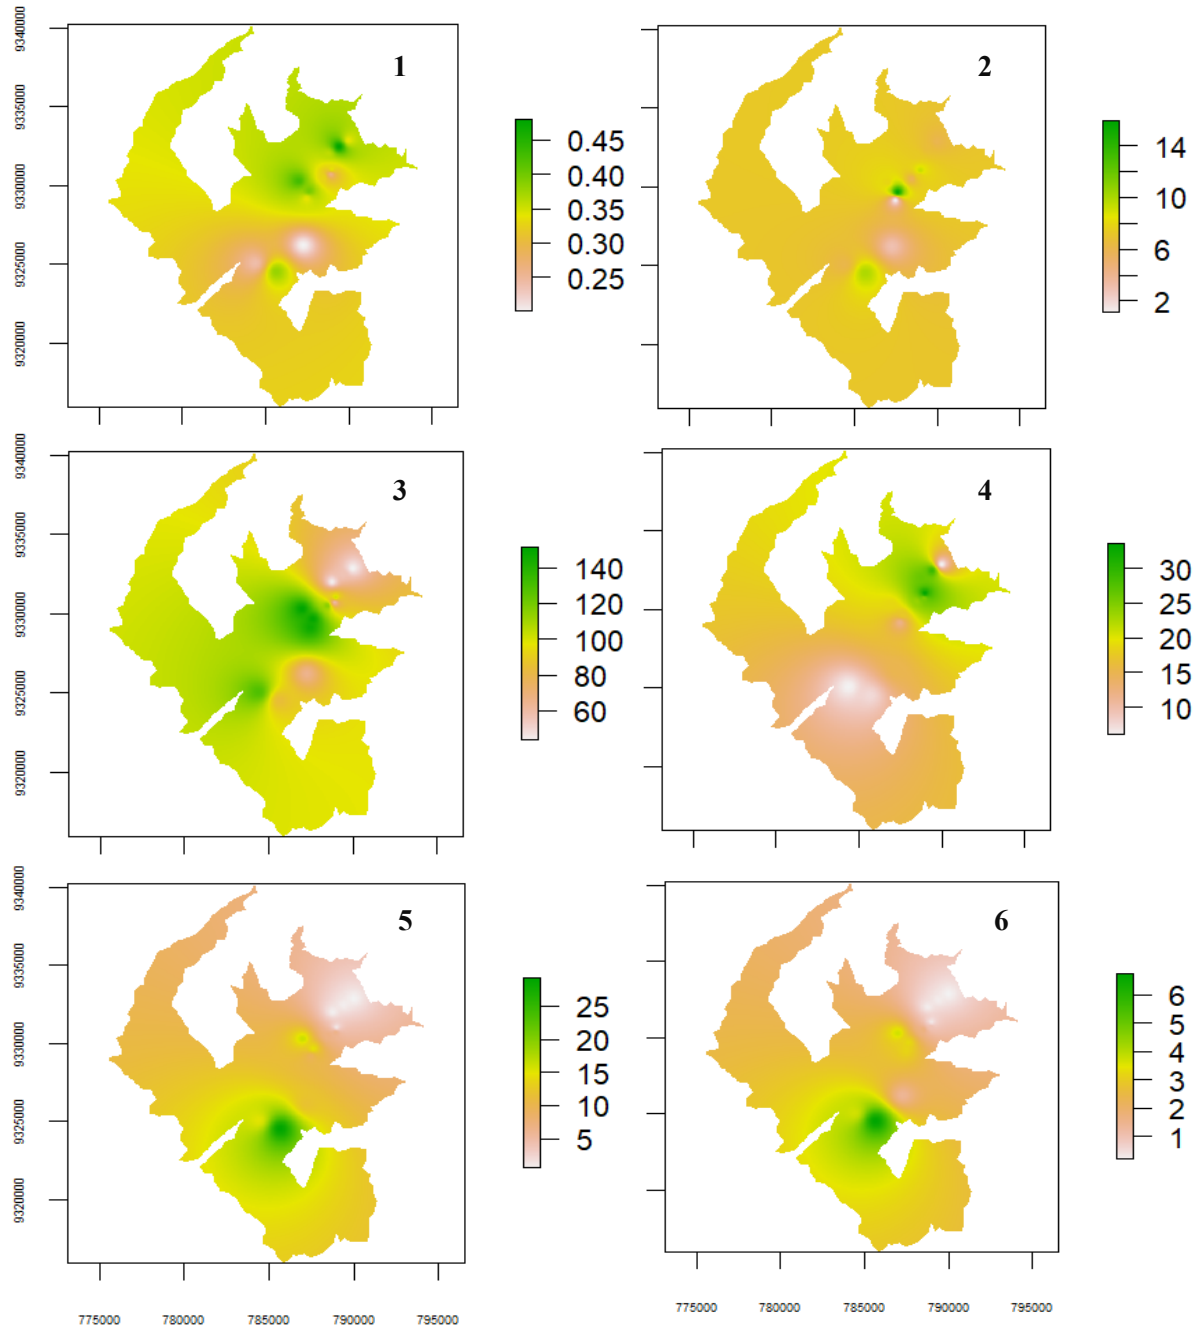


Nota. Mapeo de cuatro parámetros del informe de suelo (materia orgánica, capacidad de campo, punto de marchitez permanente y capacidad de intercambio catiónico efectivo). La técnica usada es interpolación mediante IDW, este método estima los valores en puntos no muestreados a partir de los puntos muestreados, asignando mayor peso a los valores más cercanos y reduciendo la influencia de los puntos más distantes. En las figuras presentadas se puede observar cómo se distribuyen los valores: las concentraciones más representativas se encuentran en el centro de la zona (muestreo realizado), mientras que en los extremos se observa una mayor uniformidad en la distribución de los datos.

Figura 39

Interpolación con IDW para variables de macronutrientes: 1) N, 2) P, 3) K, 4) S, 5) Ca y 6) Mg

Mg

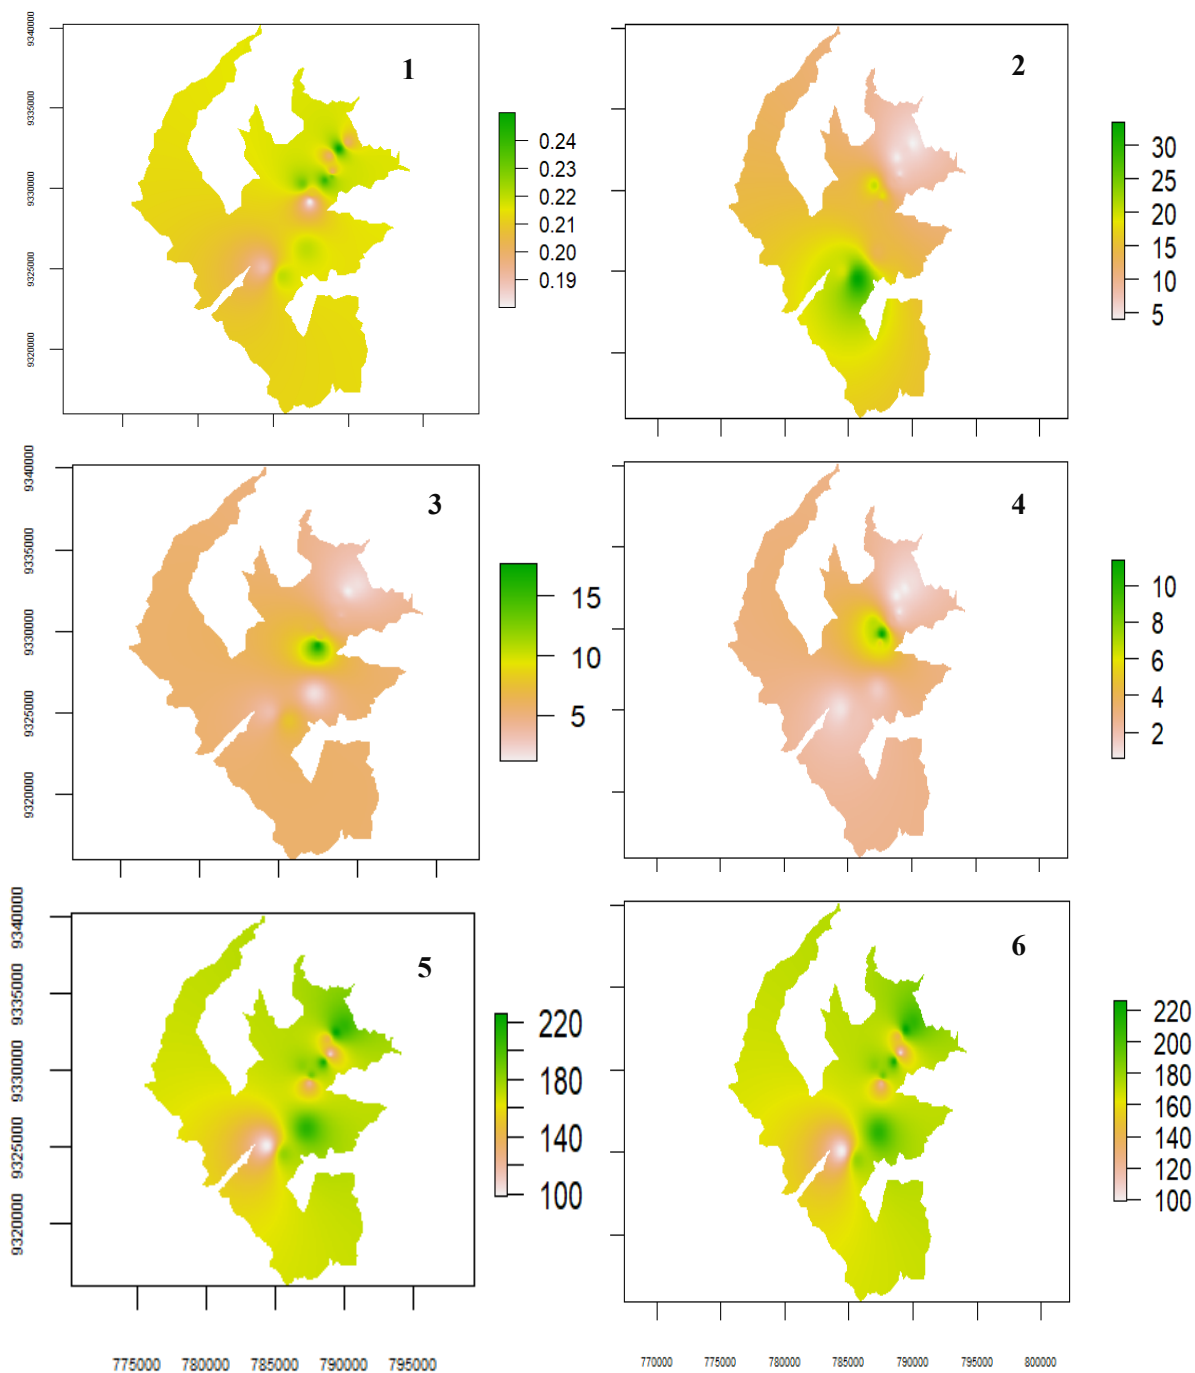


Nota. Mapeo de los macronutrientes del informe de suelo. Al igual que en los parámetros anteriores, se utilizó la técnica de interpolación IDW para su cálculo. Estos mapas sirven como base de datos para extraer valores ráster mediante la generación de puntos aleatorios.

Figura 40

Interpolación con IDW para variables de micronutrientes: 1) Na, 2) Cu, 3) Zn, 4) Mn, 5) Fe y

6) B



Nota. Mapeo de los micronutrientes del informe de suelo, utilizando el mismo método empleado en los parámetros anteriores, IDW. Los resultados obtenidos sirven como base para la extracción de valores ráster generados mediante puntos aleatorios.


4.5.1. Datos muestreados vs SoilGrids

Los datos muestreados se refieren a los obtenidos a través de la toma INSITU de las muestras de suelo y analizadas en el laboratorio, sin embargo, solo se usaron datos de arcilla, arena y limo, pues los demás parámetros no se encuentran disponibles.

SoilGrids es un sistema de mapeo digital de suelos basado en una compilación global de datos de perfiles de suelos (WoSIS) y capas ambientales. La información presentada a través de esa plataforma se basa en los mejores, y a veces únicos, datos de suelo disponibles, información sobre el medio ambiente y mapeo digital de suelos utilizando bosques aleatorios cuantiles (Centro Internacional de Información y Referencia del Suelo [ISRIC], 2024).

Figura 41

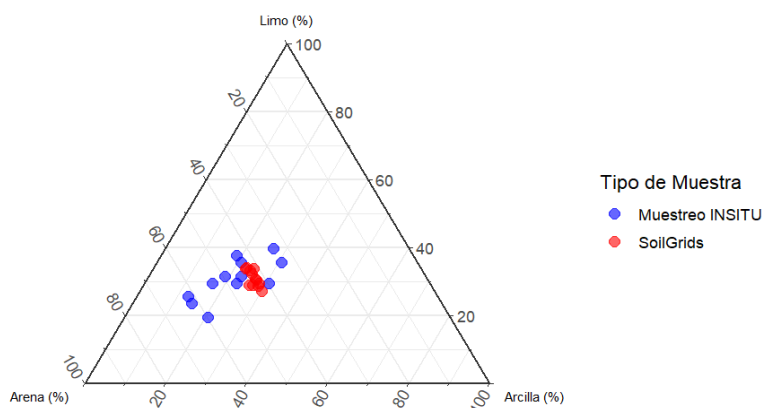
Comparación entre los resultados muestreados y los datos obtenidos de SoilGrids



Nota. De estos gráficos se puede observar que el parámetro Arcilla posee la mayor dispersión de entre las tres, mientras que el Limo posee la mejor correlación entre ambos conjuntos de datos. Los valores predichos por SoilGrid tienden a tener un rango más amplio que los valores muestreados. Los pixeles de los ráster de SoilGrids equivale a 250 x 250 metros.

Figura 42

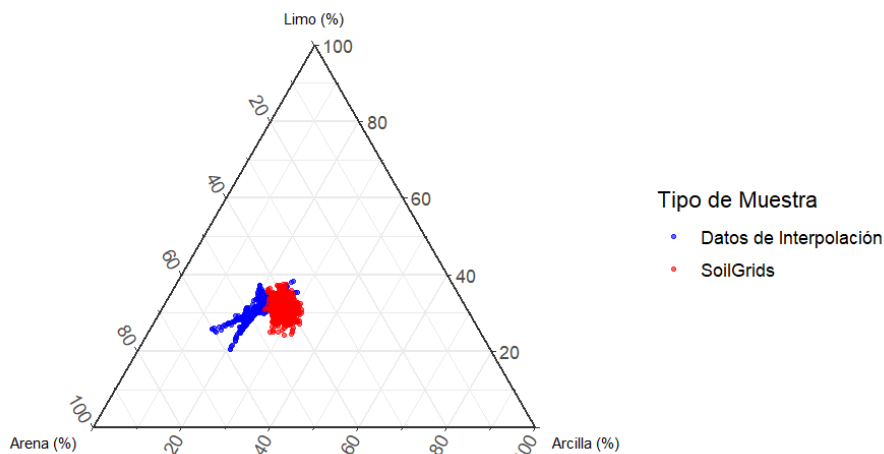
Comparación de texturas de suelo Muestreado vs SoilGrids



Nota. En este triángulo se muestra las texturas de suelo de los conjuntos de datos: muestreo INSITU vs las obtenidas de SoilGrids, de este último se puede observar que los datos se localizan dentro de una misma área y los del muestreo tienden a tener más diversidad, demostrando así la heterogeneidad espacial.

Figura 43

Comparación de texturas de suelo Datos de Interpolación VS SoilGrids



Nota. Este triángulo presenta los dos conjuntos de datos: Datos de interpolación y SoilGrids con un total de 716 puntos para cada uno. Hay una clara diferencia entre los datos de la interpolación con los de SoilGrids, siendo el primero tiende a ser más diverso y demostrando mayor heterogeneidad espacial. Se puede afirmar entonces que los datos obtenidos de la interpolación capturan con mayor calidad los datos de la realidad.

4.6. Modelo GWR

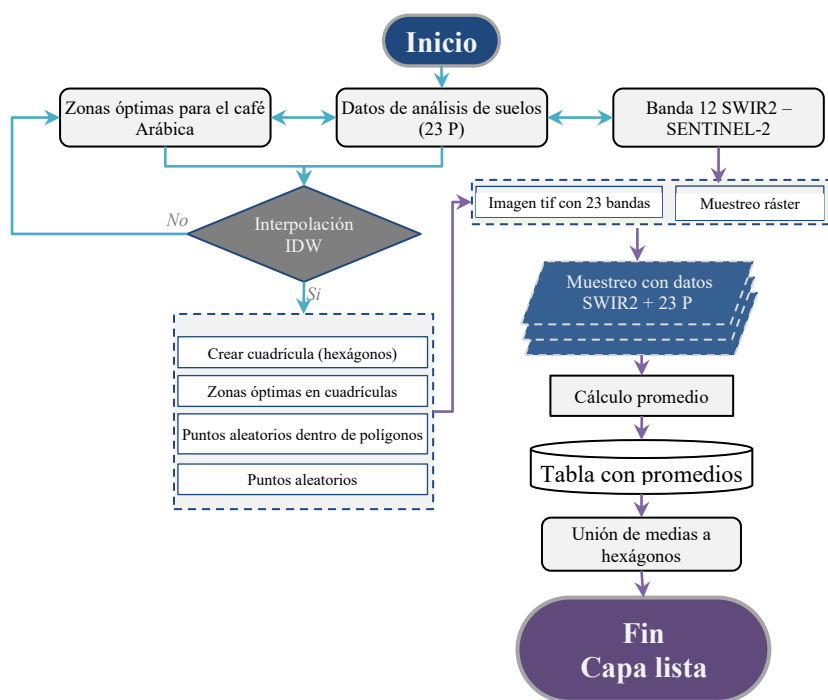
4.6.1. Obtención del modelo GWR

Airudelia et al., (2024), indican que GWR proporciona estimaciones de parámetros locales, permitiendo el análisis de la heterogeneidad espacial, a diferencia de los modelos globales que asumen uniformidad.

Debido a que solo se tenían 12 informes con los análisis de suelos, se realizó la extracción de datos del resultado generado a partir de la interpolación IDW. Para realizar la construcción del modelo GWR se siguió el siguiente flujo de trabajo:

Figura 44

Flujo de trabajo para obtención del modelo predictivo GWR



Nota. Esquema del flujo de trabajo seguido para la obtención de la capa usada para la generación del modelo predictivo GWR. Se generaron un total de 716 polígonos hexagonales de 500 x 500 metros, seguido de un total de 100 puntos aleatorios dentro de cada hexágono teniendo en cuenta la que tengan una separación de 35 metros. La cantidad de puntos aleatorios generados fueron de 716,000.00, los cuales fueron usados para extraer los datos contenidos

dentro de los ráster SWIR2 y datos de fertilidad. Finalmente se resumió los datos usando el promedio y agrupándoles según el ID del hexágono, para luego unirlos a cada hexágono.

4.6.2. Modelos GWR

Los siguientes modelos fueron construidos partiendo inicialmente de una validación cruzada (CV) entre los datos de SWIR2 con los 23 parámetros por cada punto de muestreo, y luego se realizó un ajuste mediante el criterio de Akaike (AIC).

Tabla 18

Modelos GWR

Tipo de variables	CV (Alto)	AIC (Mínimo)	R ²	Fórmula de la validación
Macronutrientes	572.1175	602.7998	0.9393331	V11+V12+V13+ V14+V15+V16
Macronutrientes 01	435.422	466.3309	0.9338081	V11+V12+V13
Macronutrientes 02	434.0447	480.8885	0.934158	V14+V15+V16
Micronutrientes	804.7157	958.6179	0.8990927	V17+V19+V20+V21+V22+V23
Físicos	318.4392	439.2748	0.9616367	V04+V05
Materia Orgánica	280.4751	403.3296	0.9719755	V08
Acidez	324.3908	438.0131	0.960785	V06+V07

Nota. De acuerdo con la Tabla 18, el modelo con mayor rendimiento es el de Materia Orgánica, pues posee el R² más alto, el AIC mínimo y solo utiliza una sola variable, haciéndolo fácil de aplicar. Sin embargo, se considera que el CV del modelo debe ser el más alto, considerando esto, los modelos que se adaptan mejor son los de Macronutrientes y Micronutrientes, además de ser los más complejos considerando la cantidad de variables que se usan para validarlo, pero de acuerdo al rendimiento solo el modelo de Macronutrientes alcanza un R² por encima de 90% y posee el AIC menor en comparación al de Micronutrientes. Por lo tanto, se elige el modelo predictivo GWR generado por la relación de Macronutrientes y SWIR2.

4.6.3. Modelo GWR óptimo

Geniaux (2023) indica que el modelo predictivo GWR está diseñado para maximizar la heterogeneidad espacial y capturar variabilidad local, siendo este el argumento principal de elegir el modelo que posea mayor CV, pues mientras este sea más alto en los coeficientes locales indica que el modelo captura adecuadamente estas variaciones espaciales.

El modelo predictivo GWR obtenido de la relación entre los Macronutrientes y SWIR2 presenta el siguiente resultado:

gwr (formula = SWIR2 ~ N + P + K + S + Ca + Mg, data = analisis_suelo,

bandwidth = bwg, gweight = gwr.Gauss, hatmatrix = TRUE)

Kernel function: gwr.Gauss

Fixed bandwidth: 572.4305

Summary of GWR coefficient estimates at data points:

	Min.	1st Qu.	Median	3rd Qu.	Max.	Global
X.Intercept.	-4.51E+03	-3.75E+00	1.87E-01	1.44E+02	1.07E+04	0.1822
N	-2.85E+04	-3.17E+02	-5.30E-01	7.38E+01	1.78E+04	-0.2598
P	-2.54E+03	-4.14E+01	-3.45E-02	1.59E-01	2.87E+03	0.0053
K	-6.50E+01	-1.23E+00	-1.12E-03	1.77E-02	2.93E+01	-0.0005
S	-3.22E+02	-1.16E-01	4.31E-02	1.58E+01	3.68E+02	-0.0002
Ca	-1.59E+03	-3.39E+01	-2.48E-02	9.93E-01	7.56E+02	-0.0091
Mg	-4.34E+03	-5.44E+00	2.05E-01	2.29E+02	8.98E+03	0.0524

Number of data points: 716

Effective number of parameters (residual: 2traceS - traceS'S): 256.5501

Effective degrees of freedom (residual: 2traceS - traceS'S): 459.4499

Sigma (residual: 2traceS - traceS'S): 0.0116088

Effective number of parameters (model: traceS): 195.6092

Effective degrees of freedom (model: traceS): 520.3908

Sigma (model: traceS): 0.01090791

Sigma (ML): 0.009299295

AICc (GWR p. 61, eq 2.33; p. 96, eq. 4.21): -4123.601

AIC (GWR p. 96, eq. 4.22): -4471.104

Residual sum of squares: 0.06191745

Quasi-global R2: 0.9392525

Del modelo se interpretó lo siguiente:

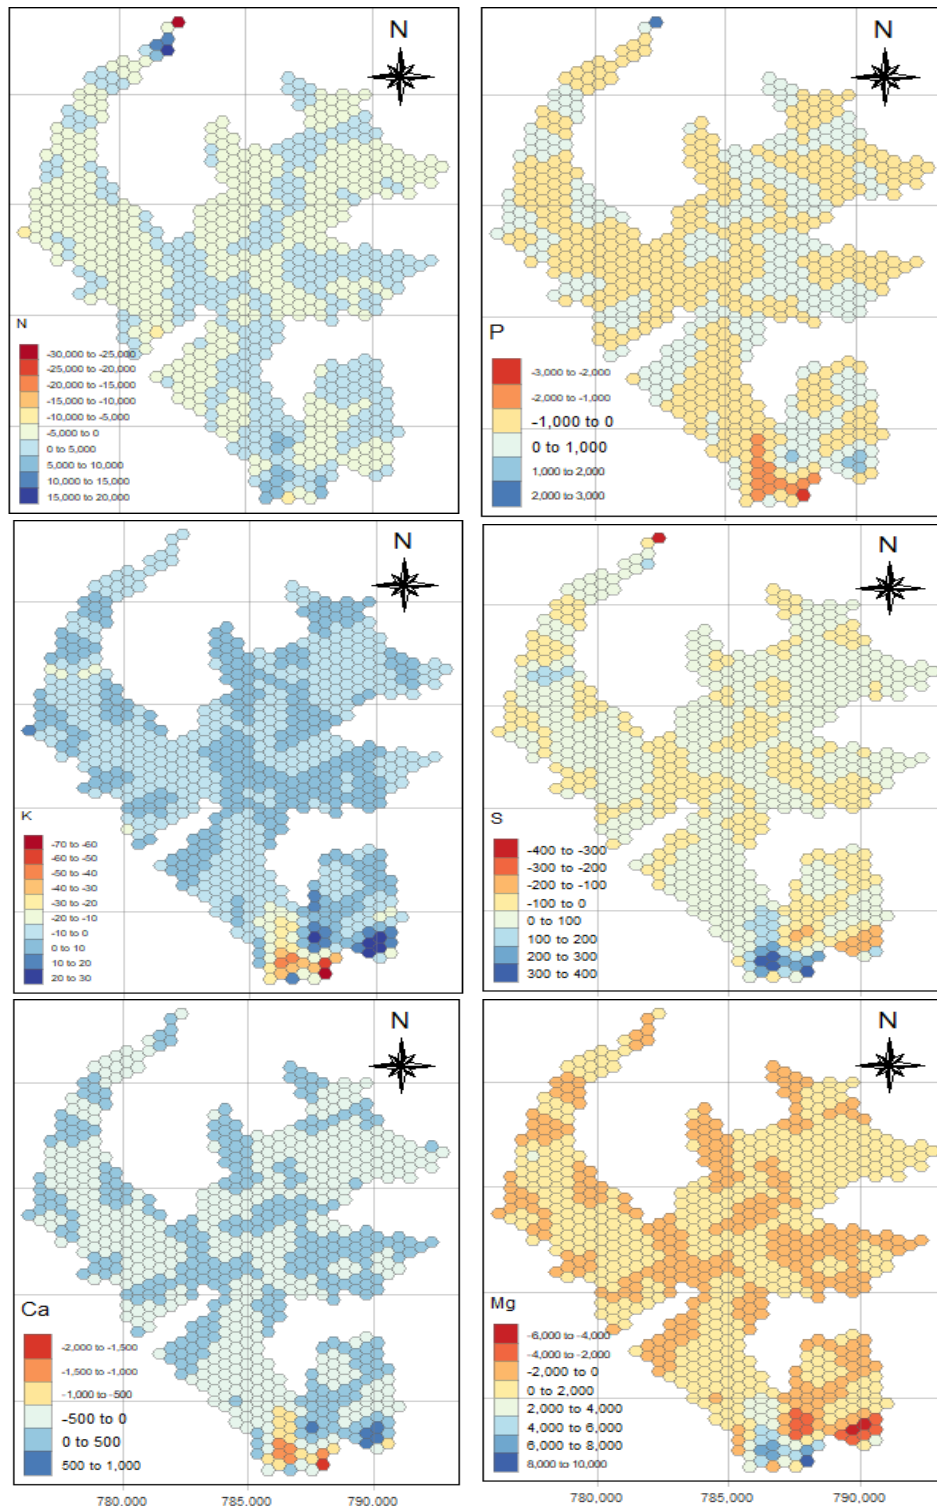
- Los coeficientes locales varían en cada punto geográfico, lo que refleja la heterogeneidad espacial de las relaciones entre las variables.
- El número de datos es de 716 puntos geográficos utilizados en el análisis, con residuales de 256.5501 y un modelo de 195.6092, estos indican el grado de ajuste del modelo y cuántos parámetros se han ajustado realmente debido al suavizamiento espacial respectivamente.
- El Sigma residual (modelo) es 0.01090791 y el Sigma ML (máxima verosimilitud) de 0.009299295, los cuales representan la desviación estándar de los residuales y al ser valores bajos indican que los errores del modelo son pequeños.
- El AICc (Criterio de Información de Akaike corregido) es de -4123.601 mientras que AIC es -4471.104, un AICc negativo y bajo indicando un modelo bien ajustado, además, AICc incluye una penalización por la cantidad de parámetros, lo que lo hace más robusto al comparar modelos.
- El Suma residual de cuadrados es de 0.06191745 lo cual representa la suma de los errores residuales al cuadrado y al ser un valor pequeño, indica que el modelo está bien ajustado.
- El R^2 tiene un valor de 0.9392525, lo que indica que el modelo explica aproximadamente el 93.93% de la variabilidad de la variable dependiente SWIR2.

4.6.4. Visualización de los coeficientes locales

Los coeficientes locales son los que se usaron en la fórmula de validación del modelo predictivo GWR óptimo, es decir corresponden a datos de los macronutrientes que son: N, P, K, S, Ca y Mg.

Figura 45

Visualización de los coeficientes locales (N, P, K, S, Ca y Mg)



Nota. La visualización de los coeficientes locales es importante para entender la variabilidad espacial de las relaciones entre variables (SWIR2 y macronutrientes) en diferentes ubicaciones geográficas.

V. DISCUSIÓN DE RESULTADOS

La interpolación IDW se presenta como una herramienta efectiva para la visualización y análisis espacial de datos de suelos debido a su facilidad de aplicación e interpretación. En este estudio, la técnica se empleó para mapear 23 parámetros derivados del análisis de suelos, utilizando un tamaño de píxel de 2 x 2 metros. Este enfoque permitió obtener una mayor resolución espacial, mejorando la precisión al extraer datos numéricos específicos, lo que resulta fundamental para diagnósticos más detallados.

La eficacia de IDW ha sido corroborada en estudios previos. Por ejemplo, Baquero (2023) diseñó un modelo preliminar para evaluar la fertilidad de suelos destinados al cultivo de soja, generando mapas detallados de macronutrientes (P, K), nutrientes secundarios (Al, B, Ca, Cu, Fe, Mg, Mn, S, Zn), materia orgánica, pH, capacidad de intercambio catiónico (CIC) y textura del suelo. Este modelo demostró la utilidad de IDW para representar parámetros críticos que afectan la productividad agrícola. Por otro lado, Vega et al., (2022) exploraron un enfoque complementario utilizando un análisis estadístico clásico y Kriging Ordinario para evaluar la fertilidad de suelos. Aunque el primer método no generó inicialmente información útil para diagnosticar condiciones específicas del sitio, los mapas obtenidos mediante Kriging Ordinario evidenciaron que la interpolación a escala local es una herramienta valiosa para capturar la distribución espacial y la variabilidad de las propiedades del suelo. Los mapas de parámetros clave como materia orgánica (MO), nitrógeno (N), potasio (K), fósforo (P) y pH reflejaron el estado actual de la fertilidad del suelo, destacando problemas de degradación. Además, los mapas de CIC, conductividad eléctrica (CE), calcio (Ca), magnesio (Mg) y sodio (Na) permitieron identificar patrones generales que evidencian la degradación del suelo.

Berton (2018) destaca que comparar dos técnicas de interpolación es una práctica útil para evaluar sus fortalezas y debilidades, analizar su capacidad para manejar incertidumbres y determinar cuál método produce mejores resultados bajo diferentes condiciones y supuestos de

datos. En este contexto, además de realizar una interpolación mediante la técnica de IDW, esta investigación incluyó la generación de un modelo predictivo basado en Regresión Geográficamente Ponderada (GWR). Esto permitió no solo comparar el desempeño de ambas metodologías, sino también explorar enfoques complementarios para mejorar la precisión y la interpretación de los resultados relacionados con la fertilidad del suelo.

El modelo predictivo de Regresión Geográficamente Ponderada (GWR) ha demostrado ser una herramienta eficaz para modelar fenómenos complejos, como la criminalidad en áreas urbanas, logrando resultados prometedores en la predicción y prevención de actos de violencia. Por ejemplo, Jendryke & McClure (2019) exploraron la relación espacial entre los delitos de odio y la presencia de grupos de odio, empleando metodologías avanzadas como la interpretación visual de ubicación, la Regresión Geográficamente Ponderada (GWR) y un Modelo de Retardo Espacial (SLM). Su investigación, basada en datos recopilados por el Centro Legal de la Pobreza del Sur, abordó la pregunta: ¿Los delitos de odio están relacionados con la presencia de grupos de odio y a qué escala?

A pesar de la considerable variabilidad y heterogeneidad de este tipo de datos, el modelo predictivo GWR logró capturar asociaciones espaciales significativas, destacando su capacidad para abordar problemas considerados casi imposibles de modelar con otras metodologías. Este ejemplo subraya la eficacia de GWR en la representación de datos espacialmente variables y su aplicabilidad a diversos contextos.

Siguiendo este enfoque, se seleccionó GWR como la técnica adecuada para el análisis de la fertilidad de suelos en esta investigación y fortalecer a la técnica de interpolación IDW. Los suelos presentan una alta heterogeneidad en sus propiedades físicas y químicas, lo que hace que la identificación y modelado de patrones espaciales sean un desafío. Sin embargo, la capacidad de GWR para incorporar relaciones espaciales locales y considerar variaciones específicas del entorno lo convierte en una herramienta ideal para analizar y predecir

características del suelo con mayor precisión.

Los resultados del modelo predictivo óptimo basado en GWR en esta investigación corresponden al modelo formulado con macronutrientes, que logró un coeficiente de determinación (R^2) de 0.939, un coeficiente de validación cruzada (CV) de 572.118 y un criterio de información de Akaike (AIC) de 602.800. Estos resultados reflejan un ajuste sólido y una capacidad predictiva robusta para describir la fertilidad de suelos en función de los macronutrientes.

Aunque no se han encontrado investigaciones previas que apliquen exactamente este modelo predictivo al mismo tema de análisis de fertilidad de suelos, estudios como el de Monteiro & Florindo (2022) demuestran la versatilidad del GWR en otros campos. Estos autores utilizaron GWR para analizar el crecimiento económico temporal en Paraná, Brasil, generando modelos independientes para cada año estudiado. En 2006, el mejor modelo obtuvo un R^2 de 0.7074 y un AIC de 87.9991; en 2010, el modelo más eficiente presentó un R^2 de 0.7787 y un AIC de 74.1423; mientras que, en 2016, el modelo óptimo alcanzó un R^2 de 0.7188 y un AIC de 67.2550.

La comparación de estos resultados con los obtenidos en esta investigación destaca la capacidad del GWR para ajustarse a diversos contextos y variables. Sin embargo, los valores significativamente superiores de R^2 y AIC en este estudio subrayan el desempeño del modelo en un análisis espacial altamente heterogéneo, como el de la fertilidad de suelos. Esto refuerza la pertinencia de utilizar GWR para abordar problemas complejos que requieren la incorporación de variaciones espaciales locales.

VI. CONCLUSIONES

Se determinó la relación entre las imágenes satelitales específicamente la banda 12 SWIR2 del satélite SENTINEL-2 con la previsión identificativa de la fertilidad de los suelos en el distrito de Lonya Grande en el año 2024. Esto se realizó usando datos del análisis de muestras de suelos y datos numéricos del ráster de la banda SWIR2, y aunque la correlación de estos conjuntos de datos no es significativa, los datos SWIR2 ayudan notablemente a poder comprender la heterogeneidad espacial presente en los suelos del distrito de Lonya Grande y así realizar una distribución óptima de los parámetros del suelo analizados.

Se determinó que existe una relación entre el satélite SENTINEL-2 con la previsión identificativa de los suelos en el distrito de Lonya Grande en el año 2024, esta relación se da debido a que la banda 12 SWIR2 proporciona datos que sirven para que los nutrientes se distribuyan de una forma más real al terreno al momento de realizar el modelado. El área estudiada en su mayoría presenta heterogeneidad espacial como es: la topografía, el uso de suelos, la temperatura, entre otros.

El modelo predictivo GWR se construyó a partir de los dos conjuntos de datos, tanto de los valores numéricos extraídos de la banda 12 SWIR2 y los datos del análisis de parámetros del suelo. El modelo seleccionado establece una relación significativa entre la variable SWIR2 y los macronutrientes (N, P, K, S, Ca y Mg), con un coeficiente de determinación (R^2) de 0.939, lo que indica un alto nivel de ajuste. Además, se obtuvo una validación cruzada (CV) de 572.118 y un AIC de 602.800, indicando una adecuada capacidad predictiva. Estos resultados cumplen con el objetivo de demostrar que el modelo predictivo está estrechamente relacionado con la evaluación de la fertilidad del suelo en el distrito de Lonya Grande para el año 2024.

Aunque el modelo predictivo óptimo seleccionado se basa en el conjunto de macronutrientes, es importante señalar que el modelo predictivo utilizando los micronutrientes presenta un valor de validación cruzada (CV) más alto, con 804.716. Sin embargo, este modelo

tiene un AIC de 958.618 y un R^2 de 0.899, lo que indica que, aunque su desempeño en términos de CV es superior, su capacidad predictiva es menos precisa en comparación con el modelo basado en los macronutrientes.

Según los datos obtenidos del análisis de suelos, los suelos muestreados presentan un contenido bajo de nitrógeno. Este hallazgo es consistente con las características de los terrenos utilizados para el cultivo de café, ya que los suelos en estas áreas, debido a factores como el tipo de cultivo y las prácticas agrícolas, tienden a agotar los nutrientes esenciales, particularmente el nitrógeno. El café es una planta que demanda grandes cantidades de nutrientes, y su cultivo constante puede ocasionar la baja concentración de este nutriente.

Dado que todas las muestras de suelo provienen de áreas con cultivos de café, los datos obtenidos en el análisis de suelos están directamente relacionados con este tipo de cultivo. Por lo tanto, el modelo predictivo desarrollado es aplicable exclusivamente a otras áreas no muestreadas dentro del mismo distrito de Lonya Grande que cuenten con cultivos de café. Este modelo beneficiaría a un total de 7,988.00 hectáreas dedicadas a la producción de café, impactando positivamente a 2,817 productores en la región, estos números fueron obtenidos de SIEA-MIDAGRI del año 2023.

Si bien los resultados obtenidos mediante este modelo no alcanzan el mismo grado de precisión que los derivados de un análisis de laboratorio, representan una mejora significativa frente a los datos proporcionados por plataformas como SoilGrids, que también están limitadas por la cantidad de parámetros disponibles. Además, el uso de este modelo ofrece ventajas en términos de tiempo y costos, ya que solo se requiere un punto con coordenadas geográficas para obtener información relevante sobre las características del suelo. Esto facilita la toma de decisiones para una fertilización eficiente, evitando gastos innecesarios y optimizando los recursos disponibles.

VII. RECOMENDACIONES

- Aumentar la densidad de puntos de muestreo para mejorar la precisión y representatividad de los resultados, teniendo en cuenta la variabilidad espacial de las propiedades del suelo.
- Validar los resultados obtenidos mediante el modelo GWR con datos de campo, realizando un seguimiento del crecimiento y rendimiento del cultivo de café en las zonas identificadas con diferentes niveles de fertilidad.
- Explorar el uso de otras técnicas de análisis espacial y machine learning, como Random Forest o Support Vector Machines, para comparar su desempeño con el modelo GWR y optimizar la predicción de la fertilidad del suelo.
- Desarrollar una plataforma o aplicación móvil que permita a los agricultores acceder fácilmente a los datos de fertilidad generados y recibir recomendaciones personalizadas de manejo nutricional para sus cultivos.
- Para aplicar a otros cultivos se tendría que realizar el mismo procedimiento más no tomando los mismos datos que se obtuvieron en los resultados de esta presente investigación.
- Promover la adopción de prácticas de manejo sitio-específico basadas en los mapas de fertilidad, en colaboración con instituciones locales y organizaciones de productores, para fomentar una agricultura más sostenible y eficiente en el uso de recursos.

VIII. REFERENCIAS

- AbdelRahman, M., Zakarya, Y., Metwaly, M., & Koubouris, G. (2021). Descifrando la variabilidad espacial del suelo mediante geoestadísticas y técnicas de interpolación. *MDPI*, *13*(1), 1–13. <https://doi.org/10.3390/su13010194>
- Abdulraheem, M. I., Zhang, W., Li, S., Moshayedi, A. J., Farooque, A. A., & Hu, J. (2023). Avances en la teledetección para mediciones y aplicaciones del suelo: una revisión exhaustiva. *Sustainability (Switzerland)*, *15*(21). <https://doi.org/10.3390/su152115444>
- Airudelia, F., Putu, N., & Eka, I. (2024). Modelo de regresión espacial ponderada geográficamente (GWR) sobre el retraso del crecimiento en niños pequeños en la isla de Java. *International Journal of Social Science and Human Research*, *7*(07), 5040–5046. <https://doi.org/10.47191/ijsshr/v7-i07-50>
- Amelia, A., Asfi, M., & Fahrudin, R. (2024). Implementación del método K-Vecino más cercano para la selección de nuevos candidatos a empleados (estudio de caso: CV. Syntax Corporation Indonesia). *Eduvest - Journal of Universal Studies*, *4*(7), 5742–5754. <https://doi.org/10.59188/eduvest.v4i7.1305>
- Axess Networks. (2021). *Las imágenes satelitales y sus aplicaciones en la vida cotidiana*. Axessnet.Com. <https://axessnet.com/las-imagenes-satelitales-y-sus-aplicaciones-en-la-vida-cotidiana/>
- Ballesteros, Y. (2021). *Altitud de la finca: ¿cómo influye en las decisiones de producción de café?* Perfect Daily Grind. <https://perfectdailygrind.com/es/2021/05/06/altitud-de-la-finca-como-influye-en-las-decisiones-de-produccion-de-cafe/>
- Baquero, D. (2023). *Modelo para identificación de fertilidad de suelos a partir de imágenes satelitales e interpolación geoestadística* [Universidad de Manizales]. <https://ridum.umanizales.edu.co/xmlui/handle/20.500.12746/6372>
- Barranzuela, N. (2022). *Identificación de pasivos ambientales mineros mediante imágenes*

- satelitales en el centro poblado de Secocha, distrito Mariano Nicolás Valcárcel, provincia de Camaná, región Arequipa* [Universidad Nacional de San Agustín de Arequipa]. <http://hdl.handle.net/20.500.12773/14949>
- Becerra, D. (2022). *Detección de Vías de Acceso con Imágenes Satelitales en la Amazonía Peruana utilizando GLCM y SVM* [Universidad Nacional de San Agustín de Arequipa]. <http://hdl.handle.net/20.500.12773/15309>
- Benedet, E., Giasson, É., Carnieletto, A., Ten, A., Melo, J., Zilli, I., & da Veiga, M. (2019). Un conjunto de datos de suelos heredado regional para la predicción del contenido de arena y arcilla con VIS-NIR-SWIR, en el sur de Brasil. *Revista Brasileira de Ciencia Do Solo*, 43, 1–20. <https://doi.org/10.1590/18069657rbc20180174>
- Berton, G. (2018). Comparación entre dos métodos de interpolación: Kriging y EPH. *Journal of Physics: Conference Series*, 1141(1). <https://doi.org/10.1088/1742-6596/1141/1/012130>
- Black, J., Kueper, J., & Williamson, T. (2023). Una introducción al aprendizaje automático para clasificación y predicción. *Family Practice*, 40(1), 200–204. <https://doi.org/10.1093/fampra/cmac104>
- Canalejo, S. (2018). Procesamiento de imágenes multiespectrales para el análisis del estado de la vegetación. In *Remote Sensing of Environment* (pp. 1–41). <https://openaccess.uoc.edu/bitstream/10609/81436/6/scanalejocTFM0618memoria.pdf>
- Centro Internacional de Información y Referencia del Suelo. (2024). *SoilGrids250m 2.0*. Soilgrids.Org. <https://soilgrids.org/>
- CEPAL, FAO, & IICA. (2021). Perspectivas de la agricultura y del desarrollo rural en las Américas. In *Una mirada hacia América Latina y el Caribe*. <https://repositorio.cepal.org/server/api/core/bitstreams/ec3e9a9f-593e-4c55-85a3-b5eefbeca839/content>

- Cherlinka, V. (2024a). *Fertilidad del Suelo: Cómo medirla y mejorarla*. EOS Data Analytics.
<https://eos.com/es/blog/fertilidad-del-suelo/>
- Cherlinka, V. (2024b). *Fertilidad del Suelo: Estrategias de Preservación y Mejora*. Eos.Com.
<https://eos.com/es/blog/fertilidad-del-suelo/>
- Cloutier, J., Piercey, S. J., & Huntington, J. (2021). Mineralogía, química mineral y reflectancia espectral de clorita y mica blanca. *MDPI*, *11*(5), 1–16.
<https://doi.org/10.3390/min11050471>
- Collazos, J. (2023). *Desarrollo de un Modelo Predictivo de Procesos Gaussianos para la Estimación de la Productividad de la Caña de Azúcar en Haciendas del Ingenio Incauca* [Universidad de Manizales Facultad].
<https://ridum.umanizales.edu.co/xmlui/handle/20.500.12746/6373>
- European Space Agency. (2015). *SENTINEL-2*. Esa.Int.
https://www.esa.int/Space_in_Member_States/Spain/SENTINEL_2
- European Space Agency. (2024). *Centinela-2*. Sentiwiki.Copernicus.Eu.
<https://sentiwiki.copernicus.eu/web/sentinel-2>
- Faizullah, M., Hassan, U., Ahmad, S., Ahmad, Z., Jeelani, F., Habib, R., Ayoub, M., Ahmad, J., & Mustafa, I. (2024). Distribución de macronutrientes en suelos superficiales y subterráneos en áreas de cultivo de azafrán del distrito de Pulwama de Jammu y Cachemira, India. *Journal of Scientific Research and Reports*, *30*(2), 39–46.
<https://doi.org/10.9734/jsrr/2024/v30i21841>
- Ferreira, F., Marçal, D., Magalhães, D., Khorsandi, F., & de Moura, G. (2023). Análisis de diferentes frecuencias de corriente eléctrica en la conductividad aparente del suelo. *Journal of Biosystems Engineering*, *48*(2), 269–282. <https://doi.org/10.1007/s42853-023-00187-9>
- Gehrke, S. (2010). Procesamiento radiométrico de imágenes ADS: mosaico de grandes bloques

- de imágenes. *American Society for Photogrammetry and Remote Sensing Annual Conference 2010: Opportunities for Emerging Geospatial Technologies, 1*, 1–13. <https://doi.org/10.1117/12.203228>
- Geniaux, G. (2023). Acelerar la estimación de modelos de coeficientes que varían espacialmente. *Journal of Geographical Systems*, 26(3), 293–327. <https://doi.org/10.1007/s10109-024-00442-3>
- Hasiholan, M., & Hidayat, N. (2024). Enfoque de regresión espacial para modelar la pobreza en la Isla de Java 2022. *BAREKENG: Jurnal Ilmu Matematika Dan Terapan*, 18(3), 1765–1778. <https://doi.org/10.30598/barekengvol18iss3pp1765-1778>
- He, X., Liu, Y., Ganesan, K., Ahnood, A., Beckett, P., Eftekhari, F., Smith, D., Uddin, M. H., Skafidas, E., Nirmalathas, A., & Unnithan, R. R. (2020). Una cámara de imágenes multiespectral basada en un solo sensor que utiliza mosaico de color de banda espectral estrecha integrado en el sensor de imagen monocromático CMOS. *APL Photonics*, 5(4), 1–10. <https://doi.org/10.1063/1.5140215>
- Henderson, B., & Bui, E. (2002). Una curva de calibración mejorada entre el pH del suelo medido en agua y CaCl₂. *Australian Journal of Soil Research*, 40(8), 1399–1405. <https://doi.org/10.1071/SR01098>
- Hernández, R., & Mendoza, C. (2018). Metodología de la Investigación: Las rutas cuantitativa cualitativa y mixta. In S. A. de C. V. McGRAW-HILL INTERAMERICANA EDITORES (Ed.), *Mc Graw Hill Education*. <http://repositorio.uasb.edu.bo/handle/20.500.14624/1292>
- Hijmans, R., Cameron, S., Parra, J., Jones, P., & Jarvis, A. (2005). Superficies climáticas interpoladas de muy alta resolución para áreas terrestres globales. *International Journal of Climatology*, 25(15), 1965–1978. <https://doi.org/10.1002/joc.1276>
- Horváth, J., Kátai, L., Szabó, I., & Korzenszky, P. (2024). Un sensor de conductividad eléctrica para la determinación selectiva de la salinidad del suelo. *MDPI*, 24(11).

<https://doi.org/10.3390/s24113296>

- Huang, X. (2024). Modelos predictivos: regresión, árboles de decisión y agrupación. *Applied and Computational Engineering*, 79(1), 124–133. <https://doi.org/10.54254/2755-2721/79/20241551>
- Jarvis, A., & Guevara, E. (2018). *Base de datos de elevación digital DEM de 90 m SRTM*. Srtm.Csi.Cgiar.Org. <https://srtm.csi.cgiar.org/>
- Jendryke, M., & McClure, S. (2019). Mapeo del crimen – Crímenes de odio y grupos de odio en los EE. UU.: Un análisis espacial con datos cuadrículados. *Applied Geography*, 111(August), 102072. <https://doi.org/10.1016/j.apgeog.2019.102072>
- Kogut, P. (2021). *Teledetección: Tipos y Aplicaciones de los Sensores Remotos*. Eos.Com. <https://eos.com/es/blog/teledeteccion/>
- Kumar, V., Bector, V., Singh, M., & Dixit, A. (2024). Exploración de los modelos de regresión para la relación entre la compactación del suelo, la conductividad eléctrica y diversas propiedades del suelo para la caracterización del suelo. *Environment and Ecology*, 42(1), 49–54. <https://doi.org/10.60151/envec/zjxo2607>
- Laboratorio de Química Agrícola Valle Grande. (2024). *Informe de Análisis de Suelo*.
- Martínez-Vega, J., Gallardo, M., & Echevarría, P. (2015). Imágenes de satélite y enseñanza de la Geografía. *Journal of Research and Didactics in Geography*, 1, 55–66. <https://doi.org/10.4458/5196-06>
- Matus, M. (2019). *Deteccion remota de proliferaciones algales en Baja California Sur, México* [Centro de Investigaciones Biológicas del Noroeste, S.C.]. <http://cibnor.repositorioinstitucional.mx/jspui/handle/1001/1575>
- Metternicht, G., & Teece, B. L. (2023). Imágenes de satélite: selfies para preservar el Medio ambiente terrestre. *Earth and Its Resources*, 1–7. <https://www.doi.org/10.3389/frym.2022.886767>

- Ministerio de Desarrollo Agrario y Riego. (2024). *Perfil productivo y competitivo de los principales cultivos del sector*. SIEA. <https://app.powerbi.com/view?r=eyJrIjoiYjYwYTk5MDgtM2M0MS00NDMyLTgzNDk5MjNhNjEzYWQyOTNliiwidCI6IjdmMDg0NjI3LTdmNDAtNDg3OS04OTE3LTk0Yjg2ZmQzNWYzZiJ9>
- Ministerio del Ambiente. (2014). Guía para el Muestreo de Suelos. In *Ministerio del Ambiente*. <http://www.minam.gob.pe/wp-content/uploads/2018/07/GUIA-PARA-EL-MUESTREO-DE-SUELO.pdf>
- Monteiro, R., & Florindo, A. (2022). Crecimiento Económico en Paraná: una aproximación con el modelo GWR. *Gestão & Regionalidade*, 38(114), 207–227. <https://doi.org/10.13037/gr.vol38n114.7027>
- Mora, P. (2023). *Modelo de simulación espacio-temporal del proceso de cambio de la cobertura vegetal y temperatura ambiental en el distrito de Daniel Alomía Robles - Huánuco, 2021* [Universidad Nacional Agraria de la Selva]. <https://hdl.handle.net/20.500.14292/2438>
- Mortenson, J. (2011). La física fundamental de las ondas electromagnéticas. In *Web of Science*. <https://www.doi.org/10.5772/16750>
- Najmaddin, P., Bahaaldeen, N., & Aram, T. (2020). Evaluación de la distribución espacial de algunas propiedades geotécnicas del suelo utilizando diversos métodos de interpolación (estudio de caso: provincia de Sulaimani, Irak). *Journal of Soil Sciences and Agricultural Engineering*, 11(7), 275–281. <https://doi.org/10.21608/jssae.2020.109461>
- Neuschwandtner, R., Száková, J., Pachtrog, V., Tlustoš, P., Kulhánek, M., Černý, J., Kaul, H., Wagentristsl, H., Moitzi, G., & Euteneuer, P. (2022). Macronutrientes intercambiables y disponibles para las plantas en un experimento de labranza y rotación de cultivos a largo plazo después de 15 años. *MDPI*, 11(4), 1–11. <https://doi.org/10.3390/plants11040565>

- Nina, W. (2020). *Detección de embarcaciones utilizando Deep Learning e imágenes satelitales ópticas* [Universidad Nacional San Agustín de Arequipa]. <http://hdl.handle.net/20.500.12773/12247>
- Nowkandeh, S., Homae, M., & Noroozi, A. (2013). Mapeo de la materia orgánica del suelo mediante imágenes de Hyperion. *International Journal of Agronomy and Plant Production*, 4(8), 1753–1759. <https://www.researchgate.net/publication/281298078%0AMapping>
- Organismo Internacional de Energía Atómica. (2023). *Mejora de la fertilidad del suelo*. <https://www.iaea.org/es/temas/mejora-de-la-fertilidad-del-suelo>
- Orueta, J., García, A., Alonso, E., & Nuño, R. (2014). Desarrollo de un modelo de Predicción de Riesgo de Hospitalizaciones no Programadas en el País Vasco. *Revista Española de Salud Pública*, 88(2), 251–260. <https://doi.org/10.4321/S1135-57272014000200007>
- Parada, P., Barradas, V., Ortiz, G., Cervantes, J., & Cerdán, C. (2022). Aptitud climática para *Coffea arabica* L. ante eventos climáticos extremos: Importancia de la cobertura arbórea. *Scientia Agropecuaria*, 13(1), 53–62. <https://doi.org/10.17268/sci.agropecu.2022.005>
- Parera, F., Pinyol, N., & Alonso, E. (2020). Mediciones basadas en imágenes del grado de saturación. *E3S Web of Conferences*, 195, 1–4. <https://doi.org/10.1051/e3sconf/202019503010>
- Pérez, E. (2013). Análisis de fertilidad de suelos en el laboratorio de Química del Recinto de Grecia, Sede de Occidente, Universidad de Costa Rica. *InterSedes*, XIV, 6–18.
- Polo, B., Chávez, R., Mori, P., & Ramirez, G. (2021). Potencialidades del sector agrario: Condición necesaria en la generación de empleo en la región Amazonas-Perú. *Revista de Ciencias Sociales*, 27, 326–339. <https://www.redalyc.org/journal/280/28068276026/html/>
- Puc, M., & Wicynski, K. (1995). *Preprocesamiento de imágenes bajo el control del Sistema de Procesamiento de Imágenes Visuales*. 2202, 588–589.

<https://doi.org/10.1117/12.203228>

Qiao, J., Zhu, Y., Jia, X., Huang, L., & Shao, M. (2019). Funciones de pedotransferencia para estimar la capacidad de campo y el punto de marchitez permanente en la zona crítica de la meseta de Loess, China. *Journal of Soils and Sediments*, 19(1), 140–147. <https://doi.org/10.1007/s11368-018-2036-x>

Rodríguez, D. (2023). *Detección de plásticos con procesamiento de imágenes empleando la banda del infrarrojo cercano, en la zona marítima de Bocas de Ceniza en Barranquilla Colombia* [Pontificia Universidad Javeriana]. http://scioteca.caf.com/bitstream/handle/123456789/1091/RED2017-Eng-8ene.pdf?sequence=12&isAllowed=y%0Ahttp://dx.doi.org/10.1016/j.regsciurbeco.2008.06.005%0Ahttps://www.researchgate.net/publication/305320484_SYSTEM_PEMBETU_NGAN_TERPUSAT_STRATEGI_MELESTARI

Sagwal, A., Wadhwa, P., Shubham, & Kaushal, S. (2023). Esencialidad de los micronutrientes en el suelo: una revisión. *International Journal of Plant & Soil Science*, 35(24), 56–65. <https://doi.org/10.9734/ijpss/2023/v35i244297>

Santillano, J., Roque, L. G., Núñez, F., Grijalva, R. L., Robles, F., Macías, R., Isabel, E., & Cárdenas, V. (2019). La fertilidad del suelo afecta el crecimiento, nutrición y rendimiento de algodón cultivado en dos sistemas de riego y diferentes dosis de nitrógeno. *Revista Terra Latinoamericana*, 37(1), 7. <https://doi.org/10.28940/terra.v37i1.304>

Schläpfer, D., Meier, P., & Schaepman, M. (2001). Efectos del preprocesamiento geoatmosférico en la calidad y los métodos de los datos de espectroscopía de imágenes. *Remote Sensing Laboratories (RSL)*, 1–8. https://aviris.jpl.nasa.gov/proceedings/workshops/02_docs/2002_Schlaepfer_web.pdf

Scientific Committees. (n.d.). *Glosario: Espectro electromagnético*. Ec.Europa.Eu. Retrieved October 21, 2024, from

https://ec.europa.eu/health/scientific_committees/opinions_layman/es/lamparas-bajo-consumo/glosario/def/espectro-electromagnetico.htm

Sebastián, M., Palomo, M., Rincón, J., Ormeño, S., & Vicent, J. (2013). *La Ciencia y el Arte IV Ciencias experimentales* (S.G. Instituto del Patrimonio Cultural de España (ed.)). https://libreria.cultura.gob.es/libro/la-ciencia-y-el-arte-iv-ciencias-experimentales-y-conservacion-del-patrimonio_4555/

Sergieieva, K. (2024). *Tipos De Satélites: Sus Órbita y Funciones*. Eos.Com. <https://eos.com/es/blog/tipos-de-satelites/>

Servimedia. (2022). *Un tercio del suelo del planeta está degradado, según la FAO*. Servimedia.Es. <https://www.servimedia.es/noticias/tercio-suelo-planeta-esta-degradado-fao/3507456>

Seybold, C., & Grossman, R. (2006). Predicción de la capacidad efectiva de intercambio catiónico en suelos de bajo pH. *Soil Science*, 171(1), 3–12. <https://doi.org/10.1097/01.ss.0000187360.92976.b2>

Shafique, M., Qazi, M., Farooq, A., Abbas, W., Gul, R., Khan, N., Umar, F., Khalid, M., Mughal, K., Nasir, M., Jamil, M., Rasool, G., Hamid, Z., Khan, S., David, M., & Ain, N. (2022). Estado de disponibilidad de micronutrientes (Zn, Cu, Fe, Mn, B) en los suelos del distrito Sargodha, Punjab, Pakistán. *Pakistan Journal of Science*, 73(1), 104–113. <https://doi.org/10.57041/pjs.v73i1.650>

Silva, J. (2022). *Análisis De La Degradación De Pastizales Basado En Imágenes Multiespectrales Uas- Microcuencas Pomacochas Y Ventilla , Amazonas Peru*. Universidad Nacional Toribio Rodríguez de Mendoza de Amazonas.

Srivyshnavi, P., & Aju, D. (2024). Un modelo de pronóstico de series de tiempo analítico predictivo. *Journal of Electrical Systems*, 20(7s), 3969–3974. <https://doi.org/10.52783/jes.4490>

- Tansitpong, P. (2024). Modelo probabilístico de clasificación de pacientes mediante el modelo bayesiano: un estudio de caso de los EMR de Tailandia. *International Journal of Reliable and Quality E-Healthcare*, 13(1), 1–19. <https://doi.org/10.4018/IJRQEH.348579>
- Tunçay, T., Kılıç, Ş., Dedeoğlu, M., Dengiz, O., Başkan, O., & Bayramin, İ. (2021). Evaluación del índice de fertilidad del suelo basado en técnicas de teledetección y SIG con validación de campo en un ecosistema agrícola semiárido. *Journal of Arid Environments*, 190(March). <https://doi.org/10.1016/j.jaridenv.2021.104525>
- Varghese, J. (2022). Aspectos fisiológicos y moleculares de la absorción de macronutrientes por las plantas superiores. *Sustainable Plant Nutrition: Molecular Interventions and Advancements for Crop Improvement*, April, 1–21. <https://doi.org/10.1016/B978-0-443-18675-2.00010-9>
- Vega, E. (2019). *Relación entre temperaturas de banda térmica en imágenes satelitales y estudios geoquímicos* [Universidad de Manizales]. https://ridum.umanizales.edu.co/bitstream/handle/20.500.12746/3707/Vega_Salazar_Elsa_j_2019.pdf?sequence=2&isAllowed=y
- Vega, V., Fernández, D., Macedo, A., Ríos, J., & Ruiz, A. (2022). Análisis de la fertilidad del suelo mediante la validación e interpolación Kriging de sus variables. *Terra Latinoamericana*, 40, 1–12. <https://doi.org/10.28940/TERRA.V40I0.1573>
- Wahid, A., Alimyar, O., Usman, M., Shafi, M., & Niazi, P. (2023). Macronutrientes para el crecimiento de las plantas y la salud humana. *Journal for Research in Applied Sciences and Biotechnology*, 2(2), 268–279. <https://doi.org/10.55544/jrasb.2.2.38>
- Wang, Y., Liao, W., Shen, H., Jiang, Z., & Zhou, J. (2024). Algunas notas sobre los conceptos básicos de las máquinas de vectores de soporte. *Journal of Computational Science*, 82(December 2023), 102390. <https://doi.org/10.1016/j.jocs.2024.102390>
- Zewide, I., & W, M. (2021). Revisión sobre macronutrientes en cultivos agronómicos.

Nutrition and Food Processing, 4(6), 01–07. <https://doi.org/10.31579/2637-8914/062>

IX. ANEXOS

- Matriz de consistencia

Tabla 19

Matriz de consistencia

Problema general	Objetivo general	Hipótesis General	Variables/Dimensiones	Método
¿De qué manera se relaciona las imágenes satelitales con la previsión identificativa de la fertilidad de suelos en el distrito de Lonya Grande, provincia Utcubamba, región Amazonas en el 2024?	Determinar la relación de las imágenes satelitales con la previsión identificativa de la fertilidad de suelos en distrito de Lonya Grande, provincia Utcubamba, región Amazonas en el 2024.	Las imágenes satelitales se relacionan significativamente con la previsión identificativa de la fertilidad de suelos en el distrito de Lonya Grande, provincia Utcubamba, región Amazonas en el 2024.		Tipo de investigación: - Aplicada. Diseño: - Experimental transversal de enfoque cuantitativo.
Problemas específicos	Objetivos específicos	Hipótesis Específicas		Población y Muestra: - Población: Lonya Grande, Utcubamba, Amazonas. - Muestra: 12 puntos para análisis de fertilidad e imágenes satelitales del área.
<ul style="list-style-type: none"> - ¿De qué manera se relaciona el satélite SENTINEL-2 con la fertilidad de suelos en Lonya Grande, Amazonas en el 2024? - ¿De qué manera se relaciona el modelo predictivo con la previsión identificativa la fertilidad de suelos en Lonya Grande, Amazonas en el 2024? 	<ul style="list-style-type: none"> - Determinar la relación del satélite SENTINEL-2 y la previsión identificativa de fertilidad de suelos en el distrito de Lonya Grande, provincia Utcubamba, región Amazonas en el 2024. - Determinar la relación del modelo predictivo con la previsión identificativa de la fertilidad de suelos en el distrito de Lonya Grande, provincia Utcubamba, región Amazonas en el 2024. 	<ul style="list-style-type: none"> - El satélite SENTINEL-2 se relaciona significativamente con la previsión identificativa de la fertilidad de suelos en el distrito de Lonya Grande, provincia Utcubamba, región Amazonas en el 2024. - El modelo predictivo se relaciona significativamente previsión identificativa de la fertilidad de suelos en el distrito de Lonya Grande, provincia Utcubamba, región Amazonas en el 2024. 	V1: VD: Imágenes Satelitales. Dimensiones: - Satélite SENTINEL-2. - Modelo predictivo. V2: VI: Fertilidad de Suelos. Dimensiones: - Macronutrientes. - Micronutrientes.	Técnica e instrumentos de recojo de datos: - Técnicas: Recojo de muestras de suelos y descarga de imágenes satelitales. - Instrumentos: GPS, envases para muestras, softwares y hojas de cálculo. Técnicas y procedimientos de análisis de datos: - Análisis de datos de fertilidad de suelos. - Procesamiento de imágenes satelitales. - Geoestadística.

- Validación y confiabilidad de los instrumentos

A) GPS

GPS OREGON 550



Imagen Referencial

El Garmin Oregon es una de las más modernas unidades desarrolladas por el líder mundial en la fabricación de receptores GPS.

- El Garmin Oregon 550, posee una memoria interna de 850 Mb, e incluye una cámara digital de 3,2 Megapixels.

GPS GARMIN OREGON 550

CARACTERÍSTICAS FÍSICAS Y RENDIMIENTO:

Dimensiones de la unidad (Ancho/Alto/Profundidad)	5,8 x 11,4 x 3,5 cm
Tamaño de la pantalla (Ancho/Alto)	3,8 x 6,3 cm, 3 "de diagonal (7,6 cm)
Resolución de pantalla (Ancho/Alto)	240 x 400 píxeles
Tipo de pantalla	Pantalla Táctil TFT transreflectiva de color
Peso	Con pilas 192,7 g
Batería	2 Pilas AA de NiMH incluidas
Duración de la batería	16 horas
Resistente al agua	Si (IPX7)
Flotante	No
Receptor de alta sensibilidad	Si
Interfaz del equipo	USB de alta velocidad y compatible con NMEA 0183

CARTOGRAFÍA Y MEMORIA:

Mapa base	Si
Posibilidad de agregar mapas	Si
Memoria interna	850 MB
Admite tarjetas de datos	Tarjeta microSD™ (no incluida)
Waypoints	2000
Rutas	200
Track log	10.000 puntos, 200 tracks guardados

PRESTACIONES:

Creación automática de rutas (giro a giro en carretera)	Si (con la cartografía opcional para carreteras detallada)
Brújula electrónica	Si (con inclinación compensada, 3 ejes)
Pantalla táctil	Si
Altimetro barométrico	Si
Cámara	Si (con 3,2 megapíxeles de enfoque automático, zoom de 4x)
Modo geocaching	Si (sin papel)
Custom maps compatible	Si
Navegación hacia fotos	Si
Juegos GPS para exteriores	Si (Whereigo solamente)
Calendario de caza y pesca	Si
Información astronómica	Si
Predicción de mareas	Si
Cálculo de áreas	Si
Puntos de interés personalizables	(posibilidad de agregar puntos de interés adicionales) Si
Transferencia de unidad a unidad	(comparte datos con unidades similares de forma inalámbrica) Si
Visor de imágenes	Si
Compatible con Garmin Connect™	(comunidad online en la que puedes analizar, clasificar y compartir datos) Si

B) Envases para muestras de suelos



Marca	: Ziploc.
Nº unidades	: 25 unidades.
Descripción de Color	: Transparente.
Dimensiones	: 17.7 x 19.5 cm.
Capacidad	: 1 kg.
Descripción de Material	: Polietileno de baja densidad (LDPE).
Material	: Plástico.
Color	: Transparente.
Cierre hermético	: Si.
Reutilizables	: Si.
BPA	: No.

C) Informes del Análisis de fertilidad de muestras de suelos

SOLICITANTE : SHELSEN JOEL CUBAS PEREZ
 PREDIO : LONYA GRANDE
 MATRIZ : SUELO AGRICOLA

 ANÁLISIS : 1014-01S-2024
 LUGAR : Jaén
 FECHA DE RECEP. : 04/10/2024

INFORME DE ANÁLISIS DE SUELO - CARACTERIZACIÓN CON MICRONUTRIENTES DISPONIBLES ESPECIAL
MUESTRA : CODIGO. LG- 01 - 20cm - CULT. CAFÉ - ALT. 1004 - 29-09-24

PARÁMETRO	RESULTADO	UNIDAD	MÉTODO	TÉCNICA
Textura				
Arena	59.63	%		
Limo	19.64	%		
Arcilla	20.73	%	MES - 001	Bouyoucos
Clase Textural	FRANCO ARCILLO ARENOSA			
Porcentaje de Saturación de Agua	45.56	%	MES - 002	Gravimétrico
Carbonato de Calcio Total	< 0.01	%	MES - 003	Gravimétrico
Conductividad Eléctrica (E.S) a 25 °C.	0.68	dS / m	MES - 004	Electrométrico
pH (1/1) - H ₂ O a Temp 25 °C	5.94		MES - 005	Electrométrico
pH (1/1) - CaCl ₂ a Temp 25 °C	5.43		MES - 027	Electrométrico
Fósforo Disponible	6.18	ppm	MES - 006	Olsen
Densidad Aparente	1.04	g / cm ³	MES - 030	Gravimétrico
Capacidad de Campo (1/3 atrn.)	24.28	%	MES - 026	Richards
Punto de Marchitez Permanente (15 atrn)	14.45	%	MES - 029	Richards
Materia Orgánica	4.14	%	MES - 007	Walkley y Black
Nitrógeno Total	0.24	%	MES - 008	Kjeldahl
Potasio Disponible	129.20	ppm	MES - 009	Acetato de Amonio
Azufre Disponible	6.06	ppm.	MES - 023	CH ₃ COONH ₄ + CH ₃ COOH
Cationes Cambiables				Extractante:Ac. Amonio
Calcio	15.18	mEq / 100 g	MES - 010	FAAS
Magnesio	3.72	mEq / 100 g	MES - 011	FAAS
Sodio	0.19	mEq / 100 g	MES - 012	FAAS
Potasio	0.33	mEq / 100 g	MES - 013	FAAS
Aluminio + Hidrógeno	< 0.01	mEq / 100 g	MES - 014	KCl / Volumétrico
P.A.I	< 0.05	%	MES - 015	Cálculo Matemático
C.I.C.E	19.42	mEq / 100 g	MES - 017	Cálculo Matemático
Micronutrientes Disponibles				Extractante: DTPA
Cobre	3.49	ppm.	MES - 018	FAAS
Zinc	0.88	ppm.	MES - 019	FAAS
Manganeso	31.31	ppm.	MES - 020	FAAS
Hierro	98.73	ppm.	MES - 021	FAAS
				Extractante: CaCl₂·2H₂O
Boro	2.28	ppm.	MES - 022	Colorimétrico

DONDE:
 E.S : Extracto de Saturación.
 (1/1) : Relación Masa del Suelo / Solución.
 P.A.I : Porcentaje de Acidez Intercambiable.
 C.I.C.E : Capacidad de Intercambio Catiónico Efectivo.
 % : Masa / Masa.
 ppm : mg / Kg.

 MES y MEA : Método Propio del Laboratorio.
 FAAS : Espectrometría de Absorción Atómica por Llama.
NOTA:
 1: Los resultados presentados corresponden sólo a la muestra indicada.
 2: Se prohíbe la reproducción parcial o total del presente informe sin la autorización del Laboratorio de Química Agrícola.


 MSc. Quím. Alexis Saucedo Chacón
 JEFE DEL LABORATORIO


 MSc. Agr. Julio Castro Lazo
 DIRECTOR DEL LABORATORIO
Promotora de Obras Sociales y de Instrucción Popular
 Panamericana Sur Km. 144, San Vicente de Cañete, Lima - Perú
 Teléfono: (511) 581 2261 | Celular: 991 692 563
 Email: laboratorio@vallegrande.edu.pe | Web: www.vallegrande.edu.pe

SOLICITANTE : SHELSEN JOEL CUBAS PEREZ

ANÁLISIS : 1014-02S-2024

PREDIO : LONYA GRANDE

LUGAR : Jaén

MATRIZ : SUELO AGRICOLA

FECHA DE RECEP. : 04/10/2024

INFORME DE ANÁLISIS DE SUELO - CARACTERIZACION CON MICRONUTRIENTES DISPONIBLES ESPECIAL
MUESTRA : CODIGO. LG-02 - 20cm - CULT. CAFÉ - ALT. 1423 - 29-09-24

PARÁMETRO	RESULTADO	UNIDAD	MÉTODO	TÉCNICA
Textura				
Arena	49.59	%		
Limo	31.65	%		
Arcilla	18.76	%	MES - 001	Bouyoucos
Clase Textural	FRANCO			
Porcentaje de Saturación de Agua	64.31	%	MES - 002	Gravimétrico
Carbonato de Calcio Total	< 0.01	%	MES - 003	Gravimétrico
Conductividad Eléctrica (E.S) a 25 °C.	0.67	dS / m	MES - 004	Electrométrico
pH (1/1) - H2O a Temp 25 °C	5.68		MES - 005	Electrométrico
pH (1/1) - CaCl2 a Temp 25 °C	5.26		MES - 027	Electrométrico
Fósforo Disponible	10.02	ppm	MES - 006	Olsen
Densidad Aparente	0.95	g / cm ³	MES - 030	Gravimétrico
Capacidad de Campo (1/3 atm.)	34.47	%	MES - 028	Richards
Punto de Marchitez Permanente (15 atm)	20.51	%	MES - 029	Richards
Materia Orgánica	6.48	%	MES - 007	Walkley y Black
Nitrógeno Total	0.38	%	MES - 008	Kjeldahl
Potasio Disponible	84.40	ppm	MES - 009	Acetato de Amonio
Azufre Disponible	7.50	ppm.	MES - 023	CH ₃ COONH ₄ + CH ₃ COOH
Cationes Cambiables				Extractante: Ac. Amonio
Calcio	26.19	mEq / 100 g	MES - 010	FAAS
Magnesio	6.74	mEq / 100 g	MES - 011	FAAS
Sodio	0.22	mEq / 100 g	MES - 012	FAAS
Potasio	0.22	mEq / 100 g	MES - 013	FAAS
Aluminio + Hidrógeno	< 0.01	mEq / 100 g	MES - 014	KCl / Volumétrico
P.A.I	< 0.03	%	MES - 015	Cálculo Matemático
C.I.C.E	33.36	mEq / 100 g	MES - 017	Cálculo Matemático
Micronutrientes Disponibles				Extractante: DTPA
Cobre	7.89	ppm.	MES - 018	FAAS
Zinc	1.83	ppm.	MES - 019	FAAS
Manganeso	56.01	ppm.	MES - 020	FAAS
Hierro	181.32	ppm.	MES - 021	FAAS
				Extractante: CaCl₂.2H₂O
Boro	2.20	ppm.	MES - 022	Colorimétrico

DONDE:

E.S : Extracto de Saturación.
 (1 / 1) : Relación Masa del Suelo / Solución.
 P.A.I : Porcentaje de Acidez Intercambiable.
 C.I.C.E. : Capacidad de Intercambio Cationico Efectivo.
 % : Masa / Masa.
 ppm : mg / Kg.

MES y MEA : Método Propio del Laboratorio.
 FAAS : Espectrometría de Absorción Atómica por Llama.

NOTA:

- 1: Los resultados presentados corresponden sólo a la muestra indicada.
 2: Se prohíbe la reproducción parcial o total del presente informe sin la autorización del Laboratorio de Química Agrícola.


MSc. Quím. Alexis Saucedo Chacón
JEFE DEL LABORATORIO


MSc. Agr. Julio Castro Lazo
DIRECTOR DEL LABORATORIO
Promotora de Obras Sociales y de Instrucción Popular

Panamericana Sur Km. 144, San Vicente de Cañete, Lima - Perú
 Teléfono: (511) 581 2261 | Celular: 991 692 563
 Email: laboratorio@vallegrande.edu.pe | Web: www.vallegrande.edu.pe



SOLICITANTE : SHELSEN JOEL CUBAS PEREZ

ANÁLISIS : 1014-03S-2024

PREDIO : LONYA GRANDE

LUGAR : Jaén

MATRIZ : SUELO AGRICOLA

FECHA DE RECEP. : 04/10/2024

INFORME DE ANÁLISIS DE SUELO - CARACTERIZACION CON MICRONUTRIENTES DISPONIBLES ESPECIAL
MUESTRA : CODIGO. LG- 03 - 20cm - CULT. CAFÉ - ALT. 1204 - 29-09-24

PARÁMETRO	RESULTADO	UNIDAD	MÉTODO	TÉCNICA
Textura				
Arena	43.62	%		
Limo	37.65	%		
Arcilla	18.73	%	MES - 001	Bouyoucos
Clase Textural	FRANCO			
Porcentaje de Saturación de Agua	73.29	%	MES - 002	Gravimétrico
Carbonato de Calcio Total	< 0.01	%	MES - 003	Gravimétrico
Conductividad Eléctrica (E.S) a 25 °C.	0.62	dS / m	MES - 004	Electrométrico
pH (1/1) - H ₂ O a Temp 25 °C	5.30		MES - 005	Electrométrico
pH (1/1) - CaCl ₂ a Temp 25 °C	4.76		MES - 027	Electrométrico
Fósforo Disponible	3.02	ppm	MES - 006	Bray I
Densidad Aparente	0.80	g / cm ³	MES - 030	Gravimétrico
Capacidad de Campo (1/3 atm.)	39.35	%	MES - 028	Richards
Punto de Marchitez Permanente (15 atm)	23.41	%	MES - 029	Richards
Materia Orgánica	3.45	%	MES - 007	Walkley y Black
Nitrógeno Total	0.20	%	MES - 008	Kjeldahl
Potasio Disponible	65.60	ppm	MES - 009	Acetato de Amonio
Azufre Disponible	15.18	ppm.	MES - 023	CH ₃ COONH ₄ + CH ₃ COOH
Cationes Cambiables				Extractante:Ac. Amonio
Calcio	11.96	mEq / 100 g	MES - 010	FAAS
Magnesio	1.42	mEq / 100 g	MES - 011	FAAS
Sodio	0.22	mEq / 100 g	MES - 012	FAAS
Potasio	0.17	mEq / 100 g	MES - 013	FAAS
Aluminio + Hidrógeno	< 0.01	mEq / 100 g	MES - 014	KCl / Volumétrico
P.A.I	< 0.07	%	MES - 015	Cálculo Matemático
C.I.C.E	13.76	mEq / 100 g	MES - 017	Cálculo Matemático
Micronutrientes Disponibles				Extractante: DTPA
Cobre	1.82	ppm.	MES - 018	FAAS
Zinc	1.55	ppm.	MES - 019	FAAS
Manganeso	8.85	ppm.	MES - 020	FAAS
Hierro	211.56	ppm.	MES - 021	FAAS
Boro	2.12	ppm.	MES - 022	Extractante: CaCl ₂ ·2H ₂ O Colorimétrico

DONDE:

E.S : Extracto de Saturación.
 (1/1) : Relación Masa del Suelo / Solución.
 P.A.I : Porcentaje de Acidez Intercambiable.
 C.I.C.E. : Capacidad de Intercambio Cationico Efectivo.
 % : Masa / Masa.
 ppm : mg / Kg.

MES y MEA : Método Propio del Laboratorio.
 FAAS : Espectrometría de Absorción Atómica por Llama.

NOTA:

1: Los resultados presentados corresponden sólo a la muestra indicada.
 2: Se prohíbe la reproducción parcial o total del presente informe sin la autorización del Laboratorio de Química Agrícola.


MSc. Quím. Alexis Saucedo Chacón
JEFE DEL LABORATORIO




MSc. Agr. Julio Castro Lazo
DIRECTOR DEL LABORATORIO

Promotora de Obras Sociales y de Instrucción Popular

Panamericana Sur Km. 144, San Vicente de Cañete, Lima - Perú
 Teléfono: (511) 581 2261 | Celular: 991 692 563
 Email: laboratorio@vallegrande.edu.pe | Web: www.vallegrande.edu.pe


 SOLICITANTE : SHELSEN JOEL CUBAS PEREZ
 PREDIO : ROBLEPAMPA
 MATRIZ : SUELO AGRICOLA

 ANÁLISIS : 1014-04S-2024
 LUGAR : Jaén
 FECHA DE RECEP. : 04/10/2024

INFORME DE ANÁLISIS DE SUELO - CARACTERIZACIÓN CON MICRONUTRIENTES DISPONIBLES ESPECIAL
MUESTRA : CODIGO. RO-01 - 20cm - CULT. CAFÉ - ALT. 1358 - 29-09-24

PARÁMETRO	RESULTADO	UNIDAD	MÉTODO	TÉCNICA
Textura				
Arena	33.58	%		
Limo	35.64	%		
Arcilla	30.78	%	MES - 001	Bouyoucos
Clase Textural	FRANCO ARCILLOSO			
Porcentaje de Saturación de Agua	74.24	%	MES - 002	Gravimétrico
Carbonato de Calcio Total	< 0.01	%	MES - 003	Gravimétrico
Conductividad Eléctrica (E.S) a 25 °C.	1.38	dS / m	MES - 004	Electrométrico
pH (1/1) - H ₂ O a Temp 25 °C	5.07		MES - 005	Electrométrico
pH (1/1) - CaCl ₂ a Temp 25 °C	4.77		MES - 027	Electrométrico
Fósforo Disponible	1.10	ppm	MES - 006	Bray I
Densidad Aparente	0.80	g / cm ³	MES - 030	Gravimétrico
Capacidad de Campo (1/3 atm.)	39.87	%	MES - 028	Richards
Punto de Marchitez Permanente (15 atm)	23.72	%	MES - 029	Richards
Materia Orgánica	5.79	%	MES - 007	Walkley y Black
Nitrógeno Total	0.34	%	MES - 008	Kjeldahl
Potasio Disponible	147.60	ppm	MES - 009	Acetato de Amonio
Azufre Disponible	11.88	ppm.	MES - 023	CH ₃ COONH ₄ + CH ₃ COOH
Cationes Cambiables				Extractante: Ac. Amonio
Calcio	9.59	mEq / 100 g	MES - 010	FAAS
Magnesio	3.21	mEq / 100 g	MES - 011	FAAS
Sodio	0.18	mEq / 100 g	MES - 012	FAAS
Potasio	0.38	mEq / 100 g	MES - 013	FAAS
Aluminio + Hidrógeno	< 0.01	mEq / 100 g	MES - 014	KCl / Volumétrico
P.A.I	< 0.07	%	MES - 015	Calculo Matemático
C.I.C.E	13.36	mEq / 100 g	MES - 017	Calculo Matemático
Micronutrientes Disponibles				Extractante: DTPA
Cobre	17.76	ppm.	MES - 018	FAAS
Zinc	5.53	ppm.	MES - 019	FAAS
Manganeso	112.35	ppm.	MES - 020	FAAS
Hierro	121.74	ppm.	MES - 021	FAAS
Boro	2.32	ppm.	MES - 022	Extractante: CaCl ₂ .2H ₂ O Colorimétrico

DONDE:
 E.S : Extracto de Saturación.
 (1/1) : Relación Masa del Suelo / Solución.
 P.A.I : Porcentaje de Acidez Intercambiable.
 C.I.C.E : Capacidad de Intercambio Cationico Efectivo.
 % : Masa / Masa.
 ppm : mg / Kg.

 MES y MEA : Método Propio del Laboratorio.
 FAAS : Espectrometría de Absorción Atómica por Llama.
NOTA:
 1: Los resultados presentados corresponden sólo a la muestra indicada.
 2: Se prohíbe la reproducción parcial o total del presente informe sin la autorización del Laboratorio de Química Agrícola.


 MSc. Quím. Alexis Saucedo Chacón
 JEFE DEL LABORATORIO


 MSc. Agr. Julio Castro Lazo
 DIRECTOR DEL LABORATORIO

Promotora de Obras Sociales y de Instrucción Popular

 Panamericana Sur Km. 144, San Vicente de Cañete, Lima - Perú
 Teléfono: (511) 581 2261 | Celular: 991 692 563
 Email: laboratorio@vallegrande.edu.pe | Web: www.vallegrande.edu.pe

SOLICITANTE : SHELSEN JOEL CUBAS PEREZ
 PREDIO : ROBLEPAMPA
 MATRIZ : SUELO AGRICOLA

 ANÁLISIS : 1014-05S-2024
 LUGAR : Jaén
 FECHA DE RECEP. : 04/10/2024

INFORME DE ANÁLISIS DE SUELO - CARACTERIZACION CON MICRONUTRIENTES DISPONIBLES ESPECIAL
MUESTRA : CODIGO. RO-02 - 20cm - CULT. CAFÉ - ALT. 1493 - 29-09-24


PARÁMETRO	RESULTADO	UNIDAD	MÉTODO	TÉCNICA
Textura				
Arena	43.62	%		
Limo	35.63	%		
Arcilla	20.75	%	MES - 001	Bouyoucos
Clase Textural	FRANCO			
Porcentaje de Saturación de Agua	62.36	%	MES - 002	Gravimétrico
Carbonato de Calcio Total	< 0.01	%	MES - 003	Gravimétrico
Conductividad Eléctrica (E.S) a 25 °C.	0.65	dS / m	MES - 004	Electrométrico
pH (1/1) - H ₂ O a Temp 25 °C	5.73		MES - 005	Electrométrico
pH (1/1) - CaCl ₂ a Temp 25 °C	5.26		MES - 027	Electrométrico
Fósforo Disponible	15.92	ppm	MES - 006	Olsen
Densidad Aparente	0.96	g / cm ³	MES - 030	Gravimétrico
Capacidad de Campo (1/3 atm.)	33.41	%	MES - 028	Richards
Punto de Marchitez Permanente (15 atm)	19.88	%	MES - 029	Richards
Materia Orgánica	6.83	%	MES - 007	Walkley y Black
Nitrógeno Total	0.40	%	MES - 008	Kjeldahl
Potasio Disponible	150.80	ppm	MES - 009	Acetato de Amonio
Azufre Disponible	17.66	ppm.	MES - 023	CH ₃ COONH ₄ + CH ₃ COOH
Cationes Cambiables				Extractante:Ac. Amonio
Calcio	14.72	mEq / 100 g	MES - 010	FAAS
Magnesio	3.30	mEq / 100 g	MES - 011	FAAS
Sodio	0.21	mEq / 100 g	MES - 012	FAAS
Potasio	0.39	mEq / 100 g	MES - 013	FAAS
Aluminio + Hidrógeno	< 0.01	mEq / 100 g	MES - 014	KCl / Volumétrico
P.A.I	< 0.05	%	MES - 015	Cálculo Matemático
C.I.C.E	18.62	mEq / 100 g	MES - 017	Cálculo Matemático
Micronutrientes Disponibles				Extractante: DTPA
Cobre	7.47	ppm.	MES - 018	FAAS
Zinc	11.37	ppm.	MES - 019	FAAS
Manganeso	23.58	ppm.	MES - 020	FAAS
Hierro	192.00	ppm.	MES - 021	FAAS
Boro	1.92	ppm.	MES - 022	Colorimétrico

DONDE:
 E.S : Extracto de Saturación.
 (1/1) : Relación Masa del Suelo / Solución.
 P.A.I : Porcentaje de Acidez Intercambiable.
 C.I.C.E. : Capacidad de Intercambio Catiónico Efectivo.
 % : Masa / Masa.
 ppm : mg / Kg.

 MES y MEA : Método Propio del Laboratorio.
 FAAS : Espectrometría de Absorción Atómica por Llama.
NOTA:

- 1: Los resultados presentados corresponden sólo a la muestra indicada.
 2: Se prohíbe la reproducción parcial o total del presente informe sin la autorización del Laboratorio de Química Agrícola.


 MSc. Quím. Alexis Saucedo Chacón
 JEFE DEL LABORATORIO


 MSc. Agr. Julio Castro Lazo
 DIRECTOR DEL LABORATORIO

Promotora de Obras Sociales y de Instrucción Popular

 Panamericana Sur Km. 144, San Vicente de Cañete, Lima - Perú
 Teléfono: (511) 581 2261 | Celular: 991 692 563
 Email: laboratorio@vallegrande.edu.pe | Web: www.vallegrande.edu.pe

SOLICITANTE : SHELSEN JOEL CUBAS PEREZ

ANÁLISIS : 1014-06S-2024

PREDIO : ROBLEPAMPA

LUGAR : Jaén

MATRIZ : SUELO AGRICOLA

FECHA DE RECEP. : 04/10/2024

INFORME DE ANÁLISIS DE SUELO - CARACTERIZACION CON MICRONUTRIENTES DISPONIBLES ESPECIAL
MUESTRA : CODIGO. RO-03 - 20cm - CULT. CAFÉ - ALT. 1249 - 29-09-24

PARÁMETRO	RESULTADO	UNIDAD	MÉTODO	TÉCNICA
Textura				
Arena	33.63	%		
Limo	39.64	%		
Arcilla	26.73	%	MES - 001	Bouyoucos
Clase Textural	FRANCO			
Porcentaje de Saturación de Agua	74.78	%	MES - 002	Gravimétrico
Carbonato de Calcio Total	< 0.01	%	MES - 003	Gravimétrico
Conductividad Eléctrica (E.S) a 25 °C.	0.61	dS / m	MES - 004	Electrométrico
pH (1/1) - H2O a Temp 25 °C	5.46		MES - 005	Electrométrico
pH (1/1) - CaCl2 a Temp 25 °C	4.96		MES - 027	Electrométrico
Fósforo Disponible	7.96	ppm	MES - 006	Bray I
Densidad Aparente	0.80	g / cm ³	MES - 030	Gravimétrico
Capacidad de Campo (1/3 atm.)	40.16	%	MES - 028	Richards
Punto de Marchitez Permanente (15 atm)	23.90	%	MES - 029	Richards
Materia Orgánica	7.45	%	MES - 007	Walkley y Black
Nitrógeno Total	0.43	%	MES - 008	Kjeldahl
Potasio Disponible	151.20	ppm	MES - 009	Acetato de Amonio
Azufre Disponible	18.90	ppm.	MES - 023	CH ₃ COONH ₄ + CH ₃ COOH
Cationes Cambiables				Extractante:Ac. Amonio
Calcio	16.28	mEq / 100 g	MES - 010	FAAS
Magnesio	3.72	mEq / 100 g	MES - 011	FAAS
Sodio	0.23	mEq / 100 g	MES - 012	FAAS
Potasio	0.39	mEq / 100 g	MES - 013	FAAS
Aluminio + Hidrógeno	< 0.01	mEq / 100 g	MES - 014	KCl / Volumétrico
P.A.I	< 0.05	%	MES - 015	Cálculo Matemático
C.I.C.E	20.61	mEq / 100 g	MES - 017	Cálculo Matemático
Micronutrientes Disponibles				Extractante: DTPA
Cobre	6.95	ppm.	MES - 018	FAAS
Zinc	6.81	ppm.	MES - 019	FAAS
Manganeso	98.67	ppm.	MES - 020	FAAS
Hierro	183.24	ppm.	MES - 021	FAAS
				Extractante: CaCl₂.2H₂O
Boro	2.04	ppm.	MES - 022	Colorimétrico

DONDE:

E.S : Extracto de Saturación.
 (1 / 1) : Relación Masa del Suelo / Solución.
 P.A.I : Porcentaje de Acidez Intercambiable.
 C.I.C.E. : Capacidad de Intercambio Cationico Efectivo.
 % : Masa / Masa.
 ppm : mg / Kg.

MES y MEA : Método Propio del Laboratorio.
 FAAS : Espectrometría de Absorción Atómica por Llama.

NOTA:

- 1: Los resultados presentados corresponden sólo a la muestra indicada.
 2: Se prohíbe la reproducción parcial o total del presente informe sin la autorización del Laboratorio de Química Agrícola.


MSc. Quím. Alexis Saucedo Chacón
JEFE DEL LABORATORIO


MSc. Agr. Julio Castro Lazo
DIRECTOR DEL LABORATORIO
Promotora de Obras Sociales y de Instrucción Popular

Panamericana Sur Km. 144, San Vicente de Cañete, Lima - Perú
 Teléfono: (511) 581 2261 | Celular: 991 692 563
 Email: laboratorio@vallegrande.edu.pe | Web: www.vallegrande.edu.pe

SOLICITANTE : SHELSEN JOEL CUBAS PEREZ

ANÁLISIS : 1014-07S-2024

PREDIO : NUEVA YORK

LUGAR : Jaén

MATRIZ : SUELO AGRICOLA

FECHA DE RECEP. : 04/10/2024

INFORME DE ANÁLISIS DE SUELO - CARACTERIZACION CON MICRONUTRIENTES DISPONIBLES ESPECIAL
MUESTRA : CODIGO. NY-01 - 20cm - CULT. CAFÉ - ALT. 1487 - 29-09-24

PARÁMETRO	RESULTADO	UNIDAD	MÉTODO	TÉCNICA
Textura				
Arena	47.59	%		
Limo	29.65	%		
Arcilla	22.76	%	MES - 001	Bouyoucos
Clase Textural	FRANCO			
Porcentaje de Saturación de Agua	62.15	%	MES - 002	Gravimétrico
Carbonato de Calcio Total	< 0.01	%	MES - 003	Gravimétrico
Conductividad Eléctrica (E.S) a 25 °C.	0.59	dS / m	MES - 004	Electrométrico
pH (1/1) - H ₂ O a Temp 25 °C	5.00		MES - 005	Electrométrico
pH (1/1) - CaCl ₂ a Temp 25 °C	4.50		MES - 027	Electrométrico
Fósforo Disponible	5.82	ppm	MES - 006	Bray I
Densidad Aparente	0.97	g / cm ³	MES - 030	Gravimétrico
Capacidad de Campo (1/3 atm.)	33.29	%	MES - 028	Richards
Punto de Marchitez Permanente (15 atm)	19.81	%	MES - 029	Richards
Materia Orgánica	5.72	%	MES - 007	Walkley y Black
Nitrógeno Total	0.33	%	MES - 008	Kjeldahl
Potasio Disponible	116.40	ppm	MES - 009	Acetato de Amonio
Azufre Disponible	23.70	ppm.	MES - 023	CH ₃ COONH ₄ + CH ₃ COOH
Cationes Cambiables				Extractante: Ac. Amonio
Calcio	6.88	mEq / 100 g	MES - 010	FAAS
Magnesio	1.71	mEq / 100 g	MES - 011	FAAS
Sodio	0.24	mEq / 100 g	MES - 012	FAAS
Potasio	0.30	mEq / 100 g	MES - 013	FAAS
Aluminio + Hidrógeno	< 0.01	mEq / 100 g	MES - 014	KCl / Volumétrico
P.A.I	< 0.11	%	MES - 015	Cálculo Matemático
C.I.C.E	9.12	mEq / 100 g	MES - 017	Cálculo Matemático
Micronutrientes Disponibles				Extractante: DTPA
Cobre	5.03	ppm.	MES - 018	FAAS
Zinc	2.53	ppm.	MES - 019	FAAS
Manganeso	64.92	ppm.	MES - 020	FAAS
Hierro	220.02	ppm.	MES - 021	FAAS
				Extractante: CaCl₂·2H₂O
Boro	2.08	ppm.	MES - 022	Colorimétrico

DONDE:

E.S : Extracto de Saturación.
 (1 / 1) : Relación Masa del Suelo / Solución.
 P.A.I : Porcentaje de Acidez Intercambiable.
 C.I.C.E. : Capacidad de Intercambio Catiónico Efectivo.
 % : Masa / Masa.
 ppm : mg / Kg.

MES y MEA : Método Propio del Laboratorio.
 FAAS : Espectrometría de Absorción Atómica por Llama.

NOTA:

1: Los resultados presentados corresponden sólo a la muestra indicada.
 2: Se prohíbe la reproducción parcial o total del presente informe sin la autorización del Laboratorio de Química Agrícola.


 MSc. Quím. Alexis Saucedo Chacón
 JEFE DEL LABORATORIO


 MSc. Agr. Julio Castro Lazo
 DIRECTOR DEL LABORATORIO
Promotora de Obras Sociales y de Instrucción Popular

Panamericana Sur Km. 144, San Vicente de Cañete, Lima - Perú
 Teléfono: (511) 581 2261 | Celular: 991 692 563
 Email: laboratorio@vallegrande.edu.pe | Web: www.vallegrande.edu.pe

SOLICITANTE : SHELSEN JOEL CUBAS PEREZ

ANÁLISIS : 1014-08S-2024

PREDIO : NUEVA YORK

LUGAR : Jaén

MATRIZ : SUELO AGRICOLA

FECHA DE RECEP. : 04/10/2024

INFORME DE ANÁLISIS DE SUELO - CARACTERIZACION CON MICRONUTRIENTES DISPONIBLES ESPECIAL
MUESTRA : CODIGO. NY-02- 20cm - CULT. CAFÉ - ALT. 1462 - 29-09-24

PARÁMETRO	RESULTADO	UNIDAD	MÉTODO	TÉCNICA
Textura				
Arena	45.62	%		
Limo	31.65	%		
Arcilla	22.73	%	MES - 001	Bouyoucos
Clase Textural	FRANCO			
Porcentaje de Saturación de Agua	65.22	%	MES - 002	Gravimétrico
Carbonato de Calcio Total	< 0.01	%	MES - 003	Gravimétrico
Conductividad Eléctrica (E.S) a 25 °C.	0.66	dS / m	MES - 004	Electrométrico
pH (1/1) - H ₂ O a Temp 25 °C	5.05		MES - 005	Electrométrico
pH (1/1) - CaCl ₂ a Temp 25 °C	4.62		MES - 027	Electrométrico
Fósforo Disponible	7.68	ppm	MES - 006	Bray I
Densidad Aparente	0.89	g / cm ³	MES - 030	Gravimétrico
Capacidad de Campo (1/3 atm.)	34.97	%	MES - 028	Richards
Punto de Marchitez Permanente (15 atm)	20.80	%	MES - 029	Richards
Materia Orgánica	4.41	%	MES - 007	Walkley y Black
Nitrógeno Total	0.26	%	MES - 008	Kjeldahl
Potasio Disponible	59.80	ppm	MES - 009	Acetato de Amonio
Azufre Disponible	25.02	ppm.	MES - 023	CH ₃ COONH ₄ + CH ₃ COOH
Cationes Cambiables				Extractante:Ac. Amonio
Calcio	6.78	mEq / 100 g	MES - 010	FAAS
Magnesio	1.01	mEq / 100 g	MES - 011	FAAS
Sodio	0.23	mEq / 100 g	MES - 012	FAAS
Potasio	0.15	mEq / 100 g	MES - 013	FAAS
Aluminio + Hidrógeno	< 0.01	mEq / 100 g	MES - 014	KCl / Volumétrico
P.A.I	< 0.12	%	MES - 015	Cálculo Matemático
C.I.C.E	8.16	mEq / 100 g	MES - 017	Cálculo Matemático
Micronutrientes Disponibles				Extractante: DTPA
Cobre	4.58	ppm.	MES - 018	FAAS
Zinc	1.53	ppm.	MES - 019	FAAS
Manganeso	31.54	ppm.	MES - 020	FAAS
Hierro	155.85	ppm.	MES - 021	FAAS
				Extractante: CaCl₂.2H₂O
Boro	2.44	ppm.	MES - 022	Colorimétrico

DONDE:


E.S : Extracto de Saturación.
 (1 / 1) : Relación Masa del Suelo / Solución.
 P.A.I : Porcentaje de Acidez Intercambiable.
 C.I.C.E. : Capacidad de Intercambio Catiónico Efectivo.
 % : Masa / Masa.
 ppm : mg / Kg.

MES y MEA : Método Propio del Laboratorio.
 FAAS : Espectrometría de Absorción Atómica por Llama.

NOTA:

1: Los resultados presentados corresponden sólo a la muestra indicada.
 2: Se prohíbe la reproducción parcial o total del presente informe sin la autorización del Laboratorio de Química Agrícola.


MSc. Quím. Alexis Saucedo Chacón
JEFE DEL LABORATORIO


MSc. Agr. Julio Castro Lazo
DIRECTOR DEL LABORATORIO
Promotora de Obras Sociales y de Instrucción Popular

Panamericana Sur Km. 144, San Vicente de Cañete, Lima - Perú
 Teléfono: (511) 581 2261 | Celular: 991 692 563
 Email: laboratorio@vallegrande.edu.pe | Web: www.vallegrande.edu.pe

SOLICITANTE : SHELSEN JOEL CUBAS PEREZ

ANÁLISIS : 1014-09S -2024

PREDIO : NUEVA YORK

LUGAR : Jaén

MATRIZ : SUELO AGRICOLA

FECHA DE RECEP. : 04/10/2024

INFORME DE ANÁLISIS DE SUELO - CARACTERIZACION CON MICRONUTRIENTES DISPONIBLES ESPECIAL
MUESTRA : CODIGO. NY-03- 20cm - CULT. CAFÉ - ALT. 1419 - 29-09-24

PARÁMETRO	RESULTADO	UNIDAD	MÉTODO	TÉCNICA
Textura				
Arena	39.58	%		
Limo	29.64	%		
Arcilla	30.78	%	MES - 001	Bouyoucos
Clase Textural	FRANCO ARCILLOSO			
Porcentaje de Saturación de Agua	61.07	%	MES - 002	Gravimétrico
Carbonato de Calcio Total	< 0.01	%	MES - 003	Gravimétrico
Conductividad Eléctrica (E.S) a 25 °C.	0.75	dS / m	MES - 004	Electrométrico
pH (1/1) - H2O a Temp 25 °C	4.29		MES - 005	Electrométrico
pH (1/1) - CaCl2 a Temp 25 °C	3.92		MES - 027	Electrométrico
Fósforo Disponible	9.34	ppm	MES - 006	Bray I
Densidad Aparente	0.79	g / cm ³	MES - 030	Gravimétrico
Capacidad de Campo (1/3 atm.)	32.71	%	MES - 028	Richards
Punto de Marchitez Permanente (15 atm)	19.46	%	MES - 029	Richards
Materia Orgánica	5.93	%	MES - 007	Walkley y Black
Nitrógeno Total	0.34	%	MES - 008	Kjeldahl
Potasio Disponible	102.20	ppm	MES - 009	Acetato de Amonio
Azufre Disponible	33.52	ppm.	MES - 023	CH ₃ COONH ₄ + CH ₃ COOH
Cationes Cambiables				Extractante: Ac. Amonio
Calcio	1.18	mEq / 100 g	MES - 010	FAAS
Magnesio	0.32	mEq / 100 g	MES - 011	FAAS
Sodio	0.20	mEq / 100 g	MES - 012	FAAS
Potasio	0.26	mEq / 100 g	MES - 013	FAAS
Aluminio + Hidrógeno	2.93	mEq / 100 g	MES - 014	KCl / Volumétrico
P.A.I	59.87	%	MES - 015	Cálculo Matemático
C.I.C.E	4.89	mEq / 100 g	MES - 017	Cálculo Matemático
Micronutrientes Disponibles				Extractante: DTPA
Cobre	3.57	ppm.	MES - 018	FAAS
Zinc	0.66	ppm.	MES - 019	FAAS
Manganeso	12.21	ppm.	MES - 020	FAAS
Hierro	103.92	ppm.	MES - 021	FAAS
Boro	2.08	ppm.	MES - 022	Extractante: CaCl₂.2H₂O Colorimétrico

DONDE:

E.S : Extracto de Saturación.

(1/1) : Relación Masa del Suelo / Solución.

P.A.I : Porcentaje de Acidez Intercambiable.

C.I.C.E. : Capacidad de Intercambio Cationico Efectivo.

% : Masa / Masa.


ppm : mg / Kg.

MES y MEA : Método Propio del Laboratorio.

FAAS : Espectrometría de Absorción Atómica por Llama.

NOTA:**1:** Los resultados presentados corresponden sólo a la muestra indicada.**2:** Se prohíbe la reproducción parcial o total del presente informe sin la autorización del Laboratorio de Química Agrícola.

MSc. Quím. Alexis Saucedo Chacón
JEFE DEL LABORATORIO


MSc. Agr. Julio Castro Lazo
DIRECTOR DEL LABORATORIO
Promotora de Obras Sociales y de Instrucción Popular

Panamericana Sur Km. 144, San Vicente de Cañete, Lima - Perú

Teléfono: (511) 581 2261 | Celular: 991 692 563

Email: laboratorio@vallegrande.edu.pe | Web: www.vallegrande.edu.pe

SOLICITANTE : **SHELSEN JOEL CUBAS PEREZ**ANÁLISIS : **1014-10S -2024**PREDIO : **ORTIZ ARRIETA**LUGAR : **Jaén**MATRIZ : **SUELO AGRICOLA**FECHA DE RECEP. : **04/10/2024**
INFORME DE ANÁLISIS DE SUELO - CARACTERIZACION CON MICRONUTRIENTES DISPONIBLES ESPECIAL
MUESTRA : CODIGO. OA-01- 20cm - CULT. CAFÉ - ALT. 1458 - 29-09-24

PARÁMETRO	RESULTADO	UNIDAD	MÉTODO	TÉCNICA
Textura				
Arena	53.62	%		
Limo	29.63	%		
Arcilla	16.75	%	MES - 001	Bouyoucos
Clase Textural	FRANCO ARENOSO			
Porcentaje de Saturación de Agua	70.83	%	MES - 002	Gravimétrico
Carbonato de Calcio Total	< 0.01	%	MES - 003	Gravimétrico
Conductividad Eléctrica (E.S) a 25 °C.	0.37	dS / m	MES - 004	Electrométrico
pH (1/1) - H ₂ O a Temp 25 °C	4.47		MES - 005	Electrométrico
pH (1/1) - CaCl ₂ a Temp 25 °C	3.98		MES - 027	Electrométrico
Fósforo Disponible	7.42	ppm	MES - 006	Bray I
Densidad Aparente	0.90	g / cm ³	MES - 030	Gravimétrico
Capacidad de Campo (1/3 atm.)	38.01	%	MES - 028	Richards
Punto de Marchitez Permanente (15 atm)	22.62	%	MES - 029	Richards
Materia Orgánica	6.28	%	MES - 007	Walkley y Black
Nitrógeno Total	0.36	%	MES - 008	Kjeldahl
Potasio Disponible	44.40	ppm	MES - 009	Acetato de Amonio
Azufre Disponible	26.38	ppm.	MES - 023	CH ₃ COONH ₄ + CH ₃ COOH
Cationes Cambiables				Extractante: Ac. Amonio
Calcio	0.74	mEq / 100 g	MES - 010	FAAS
Magnesio	0.27	mEq / 100 g	MES - 011	FAAS
Sodio	0.20	mEq / 100 g	MES - 012	FAAS
Potasio	0.11	mEq / 100 g	MES - 013	FAAS
Aluminio + Hidrógeno	2.93	mEq / 100 g	MES - 014	KCl / Volumétrico
P.A.I	68.81	%	MES - 015	Cálculo Matemático
C.I.C.E	4.25	mEq / 100 g	MES - 017	Cálculo Matemático
Micronutrientes Disponibles				Extractante: DTPA
Cobre	3.40	ppm.	MES - 018	FAAS
Zinc	0.54	ppm.	MES - 019	FAAS
Manganeso	4.35	ppm.	MES - 020	FAAS
Hierro	143.97	ppm.	MES - 021	FAAS
				Extractante: CaCl₂.2H₂O
Boro	1.88	ppm.	MES - 022	Colorimétrico

DONDE:

E.S : Extracto de Saturación.

(1 / 1) : Relación Masa del Suelo / Solución.

P.A.I : Porcentaje de Acidez Intercambiable.

C.I.C.E. : Capacidad de Intercambio Cationico Efectivo.

% : Masa / Masa.

ppm : mg / Kg.

MES y MEA : Método Propio del Laboratorio.

FAAS : Espectrometría de Absorción Atómica por Llama.

NOTA:

1: Los resultados presentados corresponden sólo a la muestra indicada.

2: Se prohíbe la reproducción parcial o total del presente informe sin la autorización del Laboratorio de Química Agrícola.


MSc. Quím. Alexis Saucedo Chacón
JEFE DEL LABORATORIO


MSc. Agr. Julio Castro Lazo
DIRECTOR DEL LABORATORIO
Promotora de Obras Sociales y de Instrucción Popular

Panamericana Sur Km. 144, San Vicente de Cañete, Lima - Perú

Teléfono: (511) 581 2261 | Celular: 991 692 563

Email: laboratorio@vallegrande.edu.pe | Web: www.vallegrande.edu.pe

SOLICITANTE : SHELSEN JOEL CUBAS PEREZ

ANÁLISIS : 1014-11S -2024

PREDIO : ORTIZ ARRIETA

LUGAR : Jaén

MATRIZ : SUELO AGRICOLA

FECHA DE RECEP. : 04/10/2024

INFORME DE ANÁLISIS DE SUELO - CARACTERIZACION CON MICRONUTRIENTES DISPONIBLES ESPECIAL
MUESTRA : CODIGO. OA-02- 20cm - CULT. CAFÉ - ALT. 1516 - 29-09-24

PARÁMETRO	RESULTADO	UNIDAD	MÉTODO	TÉCNICA
Textura				
Arena	61.63	%		
Limo	23.64	%		
Arcilla	14.73	%	MES - 001	Bouyoucos
Clase Textural	FRANCO ARENOSO			
Porcentaje de Saturación de Agua	73.64	%	MES - 002	Gravimétrico
Carbonato de Calcio Total	< 0.01	%	MES - 003	Gravimétrico
Conductividad Eléctrica (E.S) a 25 °C.	0.50	dS / m	MES - 004	Electrométrico
pH (1/1) - H ₂ O a Temp 25 °C	4.25		MES - 005	Electrométrico
pH (1/1) - CaCl ₂ a Temp 25 °C	3.87		MES - 027	Electrométrico
Fósforo Disponible	6.72	ppm	MES - 006	Bray I
Densidad Aparente	0.85	g / cm ³	MES - 030	Gravimétrico
Capacidad de Campo (1/3 atm.)	39.54	%	MES - 028	Richards
Punto de Marchitez Permanente (15 atm)	23.53	%	MES - 029	Richards
Materia Orgánica	8.21	%	MES - 007	Walkley y Black
Nitrógeno Total	0.48	%	MES - 008	Kjeldahl
Potasio Disponible	56.60	ppm	MES - 009	Acetato de Amonio
Azúfre Disponible	29.38	ppm.	MES - 023	CH ₃ COONH ₄ + CH ₃ COOH
Cationes Cambiables				Extractante: Ac. Amonio
Calcio	0.82	mEq / 100 g	MES - 010	FAAS
Magnesio	0.27	mEq / 100 g	MES - 011	FAAS
Sodio	0.25	mEq / 100 g	MES - 012	FAAS
Potasio	0.14	mEq / 100 g	MES - 013	FAAS
Aluminio + Hidrógeno	4.44	mEq / 100 g	MES - 014	KCl / Volumétrico
P.A.I	74.85	%	MES - 015	Cálculo Matemático
C.I.C.E	5.93	mEq / 100 g	MES - 017	Cálculo Matemático
Micronutrientes Disponibles				Extractante: DTPA
Cobre	1.17	ppm.	MES - 018	FAAS
Zinc	0.57	ppm.	MES - 019	FAAS
Manganeso	2.71	ppm.	MES - 020	FAAS
Hierro	225.78	ppm.	MES - 021	FAAS
				Extractante: CaCl₂·2H₂O
Boro	2.72	ppm.	MES - 022	Colorimétrico

DONDE:

E.S : Extracto de Saturación.
 (1 / 1) : Relación Masa del Suelo / Solución.
 P.A.I : Porcentaje de Acidez Intercambiable.
 C.I.C.E : Capacidad de Intercambio Catiónico Efectivo.
 % : Masa / Masa.
 ppm : mg / Kg.


MES y MEA : Método Propio del Laboratorio.
 FAAS : Espectrometría de Absorción Atómica por Llama.

NOTA:

- Los resultados presentados corresponden sólo a la muestra indicada.
- Se prohíbe la reproducción parcial o total del presente informe sin la autorización del Laboratorio de Química Agrícola.


 MSc. Quím. Alexis Saucedo Chacón
 JEFE DEL LABORATORIO




 MSc. Agr. Julio Castro Lazo
 DIRECTOR DEL LABORATORIO

Promotora de Obras Sociales y de Instrucción Popular

Panamericana Sur Km. 144, San Vicente de Cañete, Lima - Perú
 Teléfono: (511) 581 2261 | Celular: 991 692 563
 Email: laboratorio@vallegrande.edu.pe | Web: www.vallegrande.edu.pe

SOLICITANTE : SHELSÉN JOEL CUBAS PÉREZ

ANÁLISIS : 1014-12S -2024

PREDIO : ORTIZ ARRIETA

LUGAR : Jaén

MATRIZ : SUELO AGRICOLA

FECHA DE RECEP. : 04/10/2024

INFORME DE ANÁLISIS DE SUELO - CARACTERIZACIÓN CON MICRONUTRIENTES DISPONIBLES ESPECIAL
MUESTRA : CODIGO. OA-03- 20cm - CULT. CAFÉ - ALT. 1583 - 29-09-24

PARÁMETRO	RESULTADO	UNIDAD	MÉTODO	TÉCNICA
Textura				
Arena	61.59	%		
Limo	25.65	%		
Arcilla	12.76	%	MES - 001	Bouyoucos
Clase Textural	FRANCO ARENOSO			
Porcentaje de Saturación de Agua	73.53	%	MES - 002	Gravimétrico
Carbonato de Calcio Total	< 0.01	%	MES - 003	Gravimétrico
Conductividad Eléctrica (E.S) a 25 °C.	0.35	dS / m	MES - 004	Electrométrico
pH (1/1) - H ₂ O a Temp 25 °C	4.36		MES - 005	Electrométrico
pH (1/1) - CaCl ₂ a Temp 25 °C	3.93		MES - 027	Electrométrico
Fósforo Disponible	6.04	ppm	MES - 006	Bray I
Densidad Aparente	0.87	g / cm ³	MES - 030	Gravimétrico
Capacidad de Campo (1/3 atm.)	39.48	%	MES - 028	Richards
Punto de Marchitez Permanente (15 atm)	23.49	%	MES - 029	Richards
Materia Orgánica	5.93	%	MES - 007	Walkley y Black
Nitrógeno Total	0.34	%	MES - 008	Kjeldahl
Potasio Disponible	43.60	ppm	MES - 009	Acetato de Amonio
Azufre Disponible	6.06	ppm.	MES - 023	CH ₃ COONH ₄ + CH ₃ COOH
Cationes Cambiables				Extractante: Ac. Amonio
Calcio	0.59	mEq / 100 g	MES - 010	FAAS
Magnesio	0.20	mEq / 100 g	MES - 011	FAAS
Sodio	0.20	mEq / 100 g	MES - 012	FAAS
Potasio	0.11	mEq / 100 g	MES - 013	FAAS
Aluminio + Hidrógeno	2.90	mEq / 100 g	MES - 014	KCl / Volumétrico
P.A.I	72.51	%	MES - 015	Cálculo Matemático
C.I.C.E	3.99	mEq / 100 g	MES - 017	Cálculo Matemático
Micronutrientes Disponibles				Extractante: DTPA
Cobre	1.84	ppm.	MES - 018	FAAS
Zinc	1.06	ppm.	MES - 019	FAAS
Manganeso	3.68	ppm.	MES - 020	FAAS
Hierro	209.70	ppm.	MES - 021	FAAS
				Extractante: CaCl₂·2H₂O
Boro	2.40	ppm.	MES - 022	Colorimétrico

DONDE:

E.S : Extracto de Saturación.
 (1 / 1) : Relación Masa del Suelo / Solución.
 P.A.I : Porcentaje de Acidez Intercambiable.
 C.I.C.E. : Capacidad de Intercambio Catiónico Efectivo.
 % : Masa / Masa.
 ppm : mg / Kg.

MES y MEA : Método Propio del Laboratorio.
 FAAS : Espectrometría de Absorción Atómica por Llama.

NOTA:

- Los resultados presentados corresponden sólo a la muestra indicada.
- Se prohíbe la reproducción parcial o total del presente informe sin la autorización del Laboratorio de Química Agrícola.


 MSc. Quím. Alexis Saucedo Chacón
 JEFE DEL LABORATORIO


 MSc. Agr. Julio Castro Lazo
 DIRECTOR DEL LABORATORIO
Promotora de Obras Sociales y de Instrucción Popular

Panamericana Sur Km. 144, San Vicente de Cañete, Lima - Perú
 Teléfono: (511) 581 2261 | Celular: 991 692 563
 Email: laboratorio@vallegrande.edu.pe | Web: www.vallegrande.edu.pe

D) Softwares para procesamiento de datos

- Google Earth Engine (Libre).
- Google Earth Pro (Libre).
- RStudio (Libre).
- QGIS (Libre).
- Microsoft Excel (Licencia de Estudiante).
- ArcGIS 10.8 (Licenciado).
- TerrSet (Libre).

La confiabilidad de los instrumentos, se basan en que son softwares aceptados en el ámbito científico específico, además, hay evidencias (investigaciones previas publicadas en revistas científicas) donde podemos encontrar dos estrategias aplicadas:


- a. Repetibilidad: Se realizan los mismos análisis en diferentes ocasiones para ver si se obtienen resultados similares.
- b. Revisión por Pares: Las revistas someten los métodos y resultados a la revisión de expertos en el área.

- Correlogramas

a) Mapa de colores

Figura 47

Correlograma mostrando colores

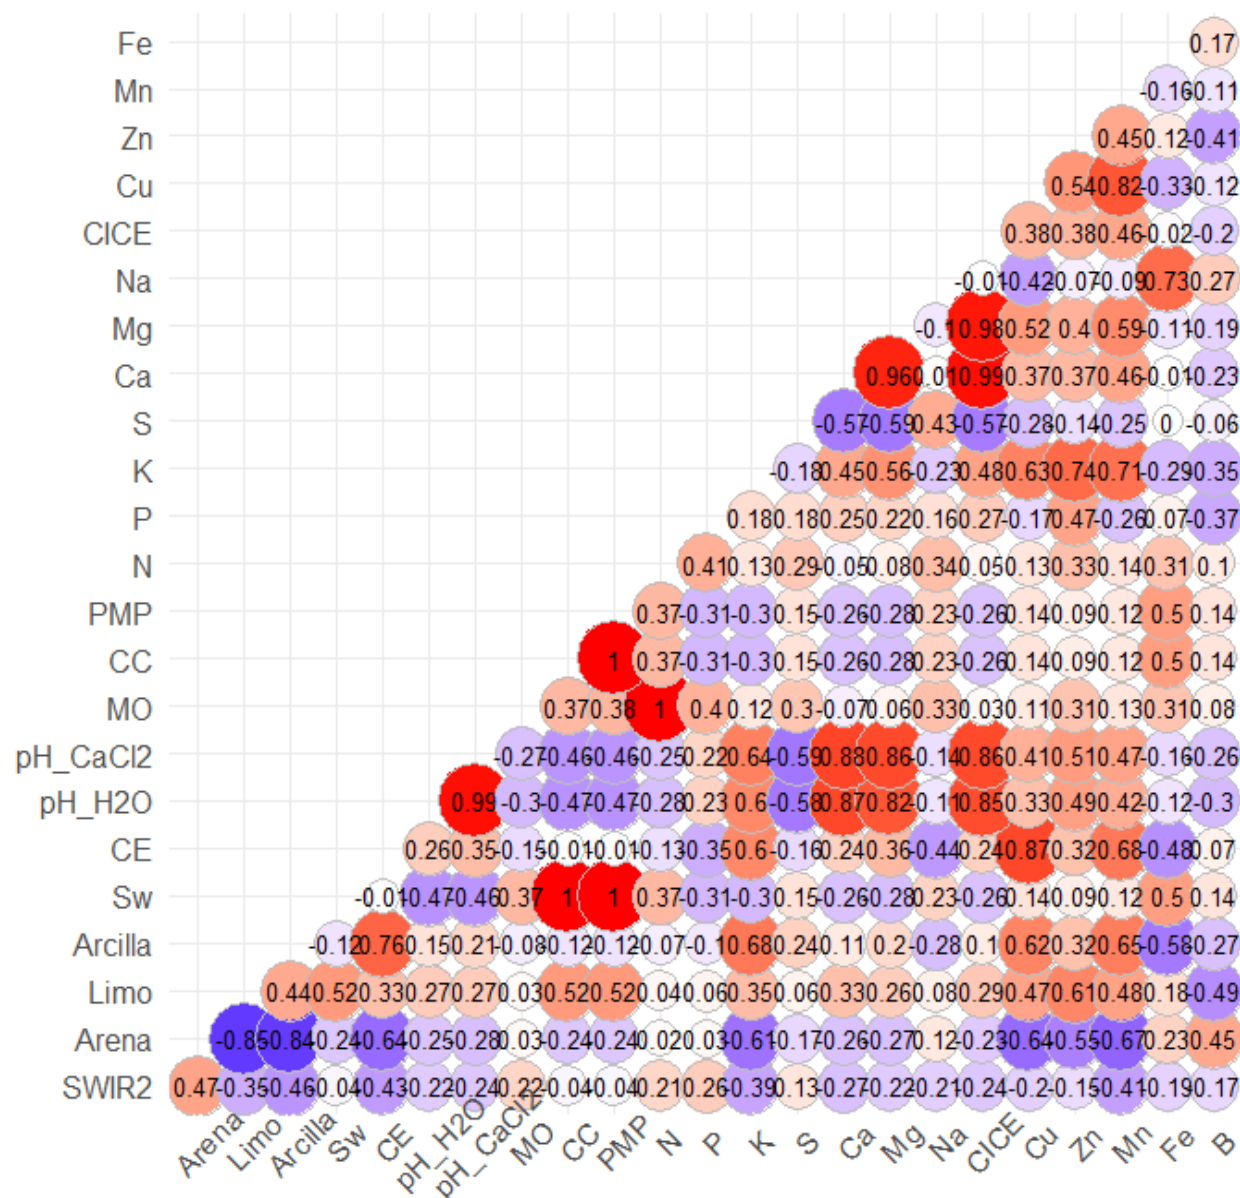


Nota. Este correlograma es un mapa de color para diferenciar a simple vista cuales de los parámetros se correlacionan entre sí. De acuerdo con la leyenda mientras los valores tiendan a rojo significan que poseen más correlación. También se debe tener en cuenta que la línea diagonal se desprecia.

b) Correlograma de círculos

Figura 48

Correlograma mostrando valores numéricos



Nota. Este correlograma sirve para tener una vista combinada tanto en colores y con valores numéricos, es decir facilita la interpretación al combinar ambas características.

- **Asignación de nomenclaturas a las variables analizadas**

Tabla 20

Nomenclaturas asignadas para GWR

Variable Analizada	Nomenclatura
Arena	V01
Limo	V02
Arcilla	V03
Sw	V04
CE	V05
pH_H2O	V06
pH_CaCl2	V07
MO	V08
CC	V09
PMP	V10
N	V11
P	V12
K	V13
S	V14
Ca	V15
Mg	V16
Na	V17
CICE	V18
Cu	V19
Zn	V20
Mn	V21
Fe	V22
B	V23

Nota. Nomenclaturas dadas a los 23 parámetros de análisis de suelo para abreviar al momento de generar la fórmula de validación de los modelos de predicción GWR.

- **VARIABLES USADAS EN EL MODELO DE DISTRIBUCIÓN DE ESPECIES****Tabla 21***Variables ambientales para el modelamiento MaxEnt*

Nombre	Unidades	mín.	máx.	Escala	Descripción
bio01	°C	-29*	32*	0.1	Temperatura media anual
bio02	°C	0.9*	21.4*	0.1	Rango medio diario (media mensual (temperatura máxima - temperatura mínima))
bio03	%	7*	96*	1	Isotermalidad (bio02/bio07 * 100)
bio04	°C	0.62*	227.21*	0.01	Estacionalidad de la temperatura (Desviación estándar * 100)
bio05	°C	-9.6	49*	0.1	Temperatura máxima del mes más cálido
bio06	°C	-57.3	25.8*	0.1	Temperatura mínima del mes más frío
bio07	°C	5.3*	72.5*	0.1	Rango anual de temperatura (bio05-bio06)
bio08	°C	-28.5	37.8*	0.1	Temperatura media del trimestre más húmedo
bio09	°C	-52.1	36.6*	0.1	Temperatura media del trimestre más seco
bio10	°C	-14.3	38.3*	0.1	Temperatura media del trimestre más cálido
bio11	°C	-52.1	28.9*	0.1	Temperatura media del trimestre más frío
bio12	milímetros	0*	11401*	1	Precipitación anual
bio13	milímetros	0*	2949*	1	Precipitaciones del mes más lluvioso
bio14	milímetros	0*	752*	1	Precipitación del mes más seco
bio15	Coefficiente de variación	0*	265*	1	Estacionalidad de las precipitaciones
bio16	milímetros	0*	8019*	1	Precipitaciones del trimestre más lluvioso
bio17	milímetros	0*	2495*	1	Precipitaciones del trimestre más seco
bio18	milímetros	0*	6090*	1	Precipitaciones del trimestre más cálido
bio19	milímetros	0*	5162*	1	Precipitaciones del trimestre más frío

Nota. Datos del catálogo WORLDCLIM/V1/BIO y obtenido a través de Google Earth Engine.

Tabla 22*Variables espaciales para el modelamiento MaxEnt*

Nombre	Unidades	mín.	máx.	Escala	Descripción
elevación	m	-444*	8806*	1	Elevación
NDVI	-	-2000	10000	0.0001	Índice de Vegetación de Diferencia Normalizada
LC_Type4	-	-	-	-	Tipo de cobertura terrestre 4: clasificación anual BIOMA-Ciclos biogeoquímicos (BGC)

Nota. Datos del catálogo CGIAR/SRTM90_V4, MODIS/061/MOD13A1 y MODIS/061/MCD12Q, obtenidos a través de Google Earth Engine.

- **Contribución de las variables a los modelos de distribución de especies**

Tabla 23*Contribución de las 22 variables al modelo de distribución del C. Arábica*

Variable	Porcentaje de contribución
maxent_bio01_b1_ASCII	21.1
maxent_LandCover_tratado_b1_ASCII	19.1
maxent_bio10_b1_ASCII	16.8
maxent_bio19_b1_ASCII	9
maxent_ndvi_tratado_b1_ASCII	7.5
maxent_bio14_b1_ASCII	5.5
maxent_bio09_b1_ASCII	4.8
maxent_bio03_b1_ASCII	4.5
maxent_bio05_b1_ASCII	3.2
maxent_bio15_b1_ASCII	2.7
maxent_bio08_b1_ASCII	2
maxent_dem_tratado_b1_ASCII	1.8
maxent_bio02_b1_ASCII	1.6
maxent_bio12_b1_ASCII	0.3
maxent_bio16_b1_ASCII	0.1
maxent_bio07_b1_ASCII	0.1
maxent_bio11_b1_ASCII	0
maxent_bio06_b1_ASCII	0
maxent_bio13_b1_ASCII	0
maxent_bio04_b1_ASCII	0
maxent_bio18_b1_ASCII	0
maxent_bio17_b1_ASCII	0

Nota. Este modelo tuvo un AUC de 0.873, sin embargo, se verifica que hay 06 variables que no aportan nada al modelo.

Tabla 24*Contribución de las 16 variables al modelo de distribución del C. Arábica*

Variable	Porcentaje de contribución
maxent_bio01_b1_ASCII	20.8
maxent_LandCover_tratado_b1_ASCII	19.2
maxent_bio10_b1_ASCII	16.9
maxent_bio19_b1_ASCII	9.8
maxent_ndvi_tratado_b1_ASCII	6.7
maxent_bio14_b1_ASCII	5.2
maxent_bio09_b1_ASCII	4.8
maxent_bio03_b1_ASCII	4.2
maxent_bio05_b1_ASCII	3.3
maxent_bio08_b1_ASCII	2.7
maxent_bio15_b1_ASCII	2.2
maxent_dem_tratado_b1_ASCII	2
maxent_bio02_b1_ASCII	1.5
maxent_bio12_b1_ASCII	0.3
maxent_bio16_b1_ASCII	0.3
maxent_bio07_b1_ASCII	0

Nota. Este modelo tuvo igual que el anterior un AUC de 0.873, sin embargo, se verifica que hay 01 variable que no aportan nada al modelo y 02 variables que aportan, pero no tienen significancia.

Tabla 25*Contribución de las 13 variables al modelo de distribución del C. Arábica*

Variable	Porcentaje de contribución
maxent_bio01_b1_ASCII	21.1
maxent_LandCover_tratado_b1_ASCII	19.4
maxent_bio10_b1_ASCII	16.9
maxent_bio19_b1_ASCII	9.4
maxent_ndvi_tratado_b1_ASCII	7.6
maxent_bio14_b1_ASCII	4.9
maxent_bio09_b1_ASCII	4.9
maxent_bio03_b1_ASCII	4.6
maxent_bio05_b1_ASCII	3.9
maxent_bio08_b1_ASCII	2.9
maxent_dem_tratado_b1_ASCII	1.8
maxent_bio15_b1_ASCII	1.5
maxent_bio02_b1_ASCII	1.1

Nota. Este modelo tuvo un AUC de 0.869, y aunque este valor disminuyó 0.004 en relación con los anteriores no afecta a la robustez del modelo MaxEnt. Este es el modelo elegido para C. Arábica.

Tabla 26*Variables y su porcentaje de contribución al modelo de distribución de especies*

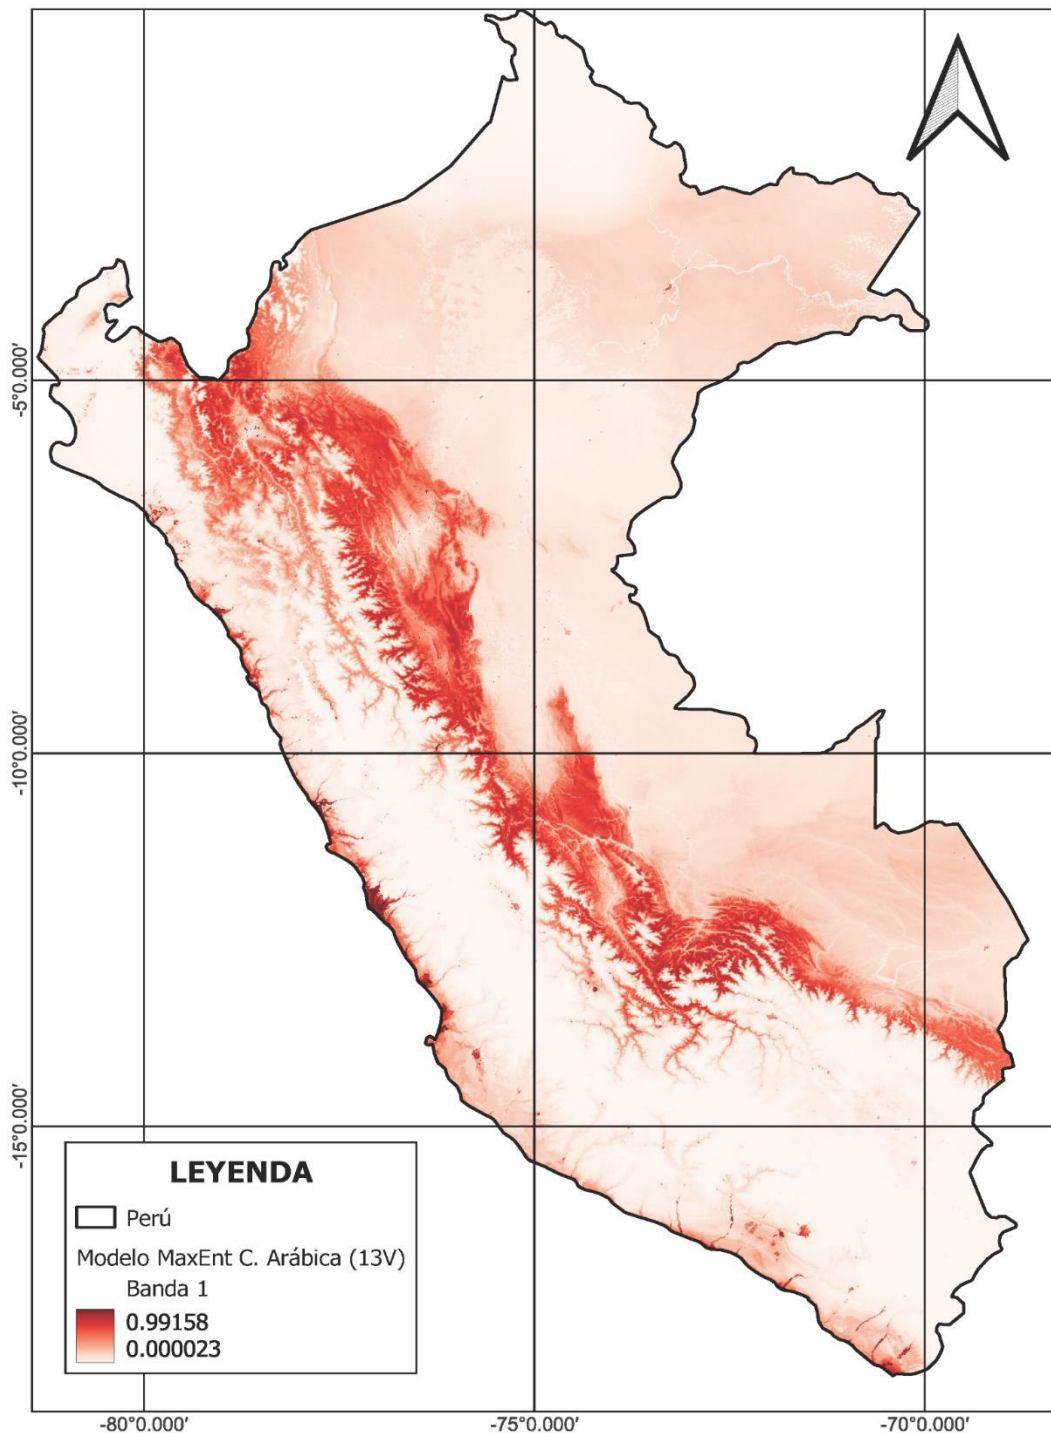
Variables	Contribución al modelo
Temperatura media anual	21.1
LandCover	19.4
Temperatura media del trimestre más cálido	16.9
Precipitaciones del trimestre más frío	9.4
NDVI	7.6
Precipitación del mes más seco	4.9
Temperatura media del trimestre más seco	4.9
Isotermalidad (bio02/bio07 * 100)	4.6
Temperatura máxima del mes más cálido	3.9
Temperatura media del trimestre más húmedo	2.9
DEM	1.8
Estacionalidad de las precipitaciones	1.5
Rango medio diario (media mensual (temperatura máxima - temperatura mínima))	1.1

Nota. Variables elegidas para el modelo de distribución de especies según el porcentaje de contribución al modelo.

- **Modelo de general de la distribución de C. Arábica**

Figura 49

Distribución del C. Arábica en Perú



Nota. Modelo de la distribución de *C. Arábica* en Perú, realizado en TerrSet usando un total de 13 variables y 47 ocurrencias.

- **Panel fotográfico**



Nota. Finca de café visitada para la toma de muestra de suelo (LG-01)



Nota. Excavación del agujero de donde se extrajo la muestra de suelo.



Nota. Medición de la profundidad del agujero (20cm).



Nota. Obtención de la muestra del suelo, esto se realizó raspando las paredes del agujero para luego ser depositado en un depósito de plástico, donde se realizó una mezcla uniforme.



Nota. Realizada la mezcla, se procedió a pesar un total de 1 kg de muestra, con su respectivo etiquetado.



Nota. Toma del punto GPS para hacer una rectificación final con los puntos iniciales calculados en gabinete.