

Modelo para identificación de fertilidad de suelos a partir de imágenes satelitales e interpolación geoestadística

Darwin Gonzalo Baquero Hernández

Universidad de Manizales
Facultad de Ciencias e Ingeniería
Maestría en Tecnologías de la Información Geográfica
Manizales, 2023

Modelo para identificación de fertilidad de suelos a partir de imágenes satelitales e interpolación geoestadística

Darwin Gonzalo Baquero Hernández

Trabajo de grado presentado como requisito parcial para optar al título de Magíster en
Tecnologías de la Información Geográfica

Director (a):

PhD. Mario Andrés Giraldo Fadul

Codirector (a):

PhD. Omar Antonio Vega

Grupo de Investigación y Desarrollo en Informática y Telecomunicaciones, Línea de
Investigación: Territorios inteligentes y sostenibles

Universidad de Manizales

Facultad de Ciencias e Ingeniería

Maestría en Tecnologías de la Información Geográfica

Manizales, 2023

Resumen

La metodología empleada, actualmente, en labores de toma de muestras de suelo geolocalizadas con enfoque agrícola carece de una alta correlación con información ráster suministrada por imágenes satelitales, las cuales ofrecen mayor cantidad de datos por unidad de píxel, sobre toda el área de interés, lo que permite estimar, con mayor detalle, las propiedades del suelo en el momento del paso del satélite sobre el área donde se iniciará el proceso de siembra de diferentes cultivos.

Debido a lo anterior, fue de vital importancia diseñar un modelo que permitió manipular, de manera asertiva, los datos obtenidos a partir de muestras de suelo e imágenes satelitales, al usar el nivel digital de las mismas con una banda específica apropiada, que logre identificar diferentes componentes del suelo descubierto o desnudo.

El modelo se fundamentó en estructurar un procedimiento lógico que incluye la recopilación, proceso y análisis de información de suelos de interés agrícola; esta metodología se validó con un trabajo de toma de muestras dirigidas en campo, teniendo en cuenta un previo proceso inicial con la imagen satelital de la cual se generó un mapa de ambientes de suelo, con este, se logró que las muestras geolocalizadas se enfoquen, de manera correcta, sobre unidades de suelo distribuidas en el área de interés.

Teniendo en cuenta lo anterior, se actualizan los métodos de recopilación de datos *in situ*. Al contar con los datos de concentración de cada nutriente (información obtenida en laboratorio), se correlacionaron con los datos obtenidos a partir de la imagen (banda 12 – Sentinel 2), finalmente se generaron los resultados esperados por el modelo como lo 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.

El diseño de este modelo permitió que la toma de decisiones en relación con la planificación de siembra y procesos agrícolas mejore significativamente y que el desarrollo tecnológico que, actualmente, se implementa en la agricultura extensiva pueda

emplear todos los recursos disponibles para la obtención, análisis y disposición de información agro-tecnológica.

Palabras clave: Fertilidad de suelos, Nutrientes, Soja.

Contenido

	Pág.
1. Planteamiento del problema de investigación y su justificación	4
1.1 Descripción del área problemática	4
1.2 Formulación del problema.....	5
1.3 Justificación.....	6
2. Antecedentes	8
3. Objetivos	16
3.1 Objetivo general.....	16
3.2 Objetivos específicos	16
4. Referente contextual	17
5. Referente normativo y legal.....	19
6. Referente teórico	20
6.1 Imágenes satelitales	20
6.1.1 Imágenes Sentinel 2 (S2)	21
6.1.2 Características banda 12 Sentinel 2.....	23
6.1.3 Uso de imágenes satelitales para clasificación de suelo	24
6.2 Muestreo de suelo	24
6.2.1 Propiedades físicas del suelo	25
6.2.2 Propiedades químicas del suelo	26
6.3 Interpolación de datos.....	27
7. Hipótesis de investigación.....	29
8. Metodología.....	30
8.1 Descripción etapa 1	31
8.1.1 Selección del área de estudio.....	32
8.1.2 Identificación de área de estudio con tradición de uso agrícola en soja	33
8.1.3 Selección de imágenes satelitales para consultas temporales.....	33

8.1.4 Corrección radiométrica de la imagen satelital y ajuste con modelo Kriging	38
8.1.5 Definición de puntos geolocalizados para toma de muestras en campo	42
8.1.6 Análisis de laboratorio del muestreo dirigido	44
8.2 Descripción etapa 2	45
8.3 Descripción etapa 3	50
8.3.1 Parámetros para determinar materia orgánica (MO)	50
8.3.2 Parámetros para determinar de pH de suelo	52
8.3.3 Parámetros para determinar CIC	54
8.3.4 Parámetros para determinar macronutrientes: P y K.....	56
8.3.5 Parámetros para determinar nutrientes secundarios: Ca, Mg, C, Fe, Mn, Zn, Cu, B y Al.....	60
8.3.6 Definición del área	65
8.4 Enfoque metodológico	66
8.5 Tipo de estudio	66
8.6 Diseño de la investigación	67
8.6.1 Estrategia de recolección de información primaria	67
8.6.2 Estrategia recolección de información secundaria.....	68
8.7 Población o unidad de trabajo.....	69
8.8 Muestra y muestreo	69
8.9 Operacionalización de variables	70
8.10 Técnicas e instrumentos de recolección de información.....	71
8.11 Plan de análisis	72
9. Resultados	73
9.1 Resultado 1. Modelo de fertilidad de suelo	73
9.2 Resultado 2. Mapa de textura de suelo.....	73
9.3 Resultado 3. Mapas de fertilidad de suelo, concentración y distribución de nutrientes	74
9.4 Resultado 4. Relación de elementos por sectores y la importancia para el cultivo de soja	76
10. Análisis de resultados.....	77

11. Discusión.....	81
12. Conclusiones	83
Anexos.....	84
Referencias bibliográficas	105

Lista de figuras

	Pág.
Figura 1. <i>Localización general área de estudio</i>	17
Figura 2. <i>Estructura referente teórico</i>	20
Figura 3. <i>Comparación de diferentes misiones satelitales en cuanto a resolución espacial y espectral</i>	23
Figura 4. <i>Estructura física del suelo</i>	26
Figura 5. <i>Modelo lógico metodología</i>	31
Figura 6. <i>Zonas área de estudio</i>	32
Figura 7. <i>Secuencia temporal de vigor vegetativo, con Sentinel 2, en el periodo 01/2018 a 07/2022</i>	34
Figura 8. <i>Resultado índice BSI para suelo desnudo</i>	37
Figura 9. <i>Comparación temporal imágenes de suelo desnudo</i>	37
Figura 10. <i>Comparación de imágenes Sentinel 2 L2A y L1C</i>	40
Figura 11. <i>Semivariograma imagen Sentinel-2</i>	40
Figura 12. <i>Resultado validación cruzada de modelo de Kriging</i>	41
Figura 13. <i>Comparación de imágenes con ajuste de modelo de Kriging</i>	42
Figura 14. <i>Distribución de puntos de muestreo dirigido</i>	43
Figura 15. <i>Representación de cobertura óptima por muestra</i>	44
Figura 16. <i>Correlación de datos de la banda 12 de suelo desnudo y resultados de muestras de laboratorio para arcilla, limo y arena</i>	46
Figura 17. <i>Resultado del algebra de mapas empleando la ecuación de la recta, distribución de arcilla y arena</i>	47
Figura 18. <i>Catalogación USDA para textura de suelo y mapa de ambientes</i>	48
Figura 19. <i>Comparación del histograma con calculadora de suelo</i>	49
Figura 20. <i>Correlación de datos de la banda 12 de suelo desnudo y resultados de muestras de laboratorio para MO</i>	51
Figura 21. <i>Semivariograma para MO</i>	52
Figura 22. <i>Correlación de datos de la banda 12 de suelo desnudo y resultados de muestras de laboratorio para pH</i>	53
Figura 23. <i>Semivariogramas para pH_{H₂O} y pH_{CaCl₂}</i>	54

Figura 24. <i>Correlación de datos de la banda 12 de suelo desnudo y resultados de muestras de laboratorio para CIC</i>	56
Figura 25. <i>Semivariograma para CIC</i>	56
Figura 26. <i>Correlación de datos de la banda 12 de suelo desnudo y resultados de muestras de laboratorio para CIC</i>	59
Figura 27. <i>Semivariogramas para P y K</i>	60
Figura 28. <i>Correlación de datos de la banda 12 de suelo desnudo y resultados de muestras de laboratorio para Ca, Mg, B, Al y C</i>	62
Figura 29. <i>Correlación de datos de la banda 12 de suelo desnudo y resultados de muestras de laboratorio para Fe, Mn, Cu y Zn</i>	62
Figura 30. <i>Semivariogramas para Ca, Mg, B, Al, C, Fe, Mn, Cu y Zn</i>	63
Figura 31. <i>Estrategia de recopilación de información primaria</i>	67
Figura 32. <i>Estrategia de recopilación de información secundaria</i>	69
Figura 33. <i>Técnicas e instrumentos de recolección de información</i>	71
Figura 34. <i>Plan de análisis</i>	72
Figura 35. <i>Estructura general modelo de fertilidad para suelo</i>	73
Figura 36. <i>Mapa de textura de suelo arcilloso</i>	74
Figura 37. <i>Mapa de Materia orgánica, aluminio, pH H₂O y pH CaCl₂, CIC, fósforo y potasio</i>	75
Figura 38. <i>Mapas de manganeso, azufre, magnesio y hierro, cobre, calcio, boro y zinc</i>	75

Lista de tablas

	Pág.
Tabla 1. <i>Marco normativo y legal</i>	19
Tabla 2. <i>Características generales Sentinel 2</i>	23
Tabla 3. <i>Parámetros de descarga de imágenes satelitales para la parcela 390 de soja</i>	35
Tabla 4. <i>Valores raster para cada punto de muestreo de suelo de arcilla, limo y arena</i>	45
Tabla 5. <i>Valores raster asociados para cada muestra de MO</i>	51
Tabla 6. <i>Valores raster asociados para cada muestra de pH</i>	52
Tabla 7. <i>Valores raster asociados para muestras de CIC</i>	55
Tabla 8. <i>Valores raster asociados a muestras de P y K</i>	58
Tabla 9. <i>Valores asociados a muestras Ca, Mg, B, Al y C</i>	60
Tabla 10. <i>Valores raster asociados a muestras Fe, Mn, Cu y Zn</i>	61
Tabla 11. <i>Clasificación de fertilidad para interpretación de resultados.</i>	64
Tabla 12. <i>Clasificación de bases de cambio para interpretación de resultados</i>	64
Tabla 13. <i>Clasificación de acidez para interpretación de resultados</i>	65
Tabla 14. <i>Parámetros para muestras de suelo</i>	70
Tabla 15. <i>Resultado de concentración por sectores y relación para el cultivo de soja</i> .	76

Lista de Símbolos y abreviaturas

Símbolos con letras latinas

Símbolo	Término	Unidad SI	Definición
<i>A</i>	Área	Ha	$\iint dx dy$
<i>Al</i>	Aluminio	g/ml	[Ne]3s ² 3p ¹
<i>B</i>	Boro	g/ml	1s ² 2s ² 2p ¹
<i>Ca</i>	Calcio	g/ml	[Ar]4s ²
<i>CIC</i>	Capacidad de intercambio catiónico	mEq/100g	
<i>Cu</i>	Cobre	g/ml	[Ar]3d ¹⁰ 4s ¹
<i>Fe</i>	Hierro	g/ml	[Ar]3d ⁶ 4s ²
<i>K</i>	Potasio	g/ml	[Ar]4s ¹
<i>Mg</i>	Magnesio	g/ml	[Ne]3s ²
<i>Mn</i>	Manganeso	g/ml	[Ar]3d ⁵ 4s ²
<i>Mo</i>	Molibdeno	g/ml	[Kr]4d ⁵ 5s ¹
<i>N</i>	Nitrógeno	g/ml	1s ² 2s ² 2p ³
<i>Na</i>	Sodio	g/ml	[Ne]3s ¹
<i>P</i>	Fósforo	g/ml	[Ne]3s ² 3p ³
<i>pH</i>	Cantidad de iones de hidrogeno	moles/l	1x10 ⁻²
<i>S</i>	Azufre	g/ml	[Ne]3s ² 3p ⁴
<i>Zn</i>	Zinc	g/ml	[Ar]3d ¹⁰ 4s ²
<i>a</i>	Coeficiente	1	Tabla 3-1

Símbolos con letras griegas

Símbolo	Término	Unidad SI	Definición
$\frac{A}{g}$	Factor de superficie	$\frac{m^2}{g}$	(W_F, waf) (A_{BET})
$\frac{m_j}{m_{bm} \rho}$	Grado de formación del componente i	1	$\frac{m_j}{m_{bm} \rho}$
α	Wandhaufreibwinkel (Stahlblech)	1	Sección 3.2
$\frac{1 - \rho_s}{\rho_w}$	Porosidad de la partícula	1	$1 - \frac{\rho_s}{\rho_w}$
β	mittlere Bettneigungswinkel (Stürzen)	1	Figura 3-1

Subíndices

Subíndice	Término
------------------	----------------

bm	Materia orgánica
----	------------------

B12	Cobalamina
-----	------------

E	Experimental
---	--------------

Superíndices

Superíndice	Término
--------------------	----------------

n	Exponente, potencia
---	---------------------

Abreviaturas

Abreviatura	Término
--------------------	----------------

1.LT	Primera ley de la termodinámica
------	---------------------------------

DF	dimensión fundamental
----	-----------------------

RFF	Racimos de fruta fresca
-----	-------------------------

Introducción

Desde una perspectiva socioeconómica, la agricultura y su evolución con la llegada de las nuevas tecnologías generan un impacto positivo para la optimización de procesos como cosecha y postcosecha. Con el paso del tiempo, la inmersión de tecnologías emergentes en el área agrícola también ha producido diferencias marcadas en la forma de producción de alimentos entre grandes explotadores agrícolas y pequeños productores, por lo que se hace necesario crear nuevos modelos y metodologías que, acompañadas de los desarrollos tecnológicos, permiten un ahorro en insumos, ya sean fertilizantes o pesticidas en áreas de cultivo que no lo requieren, lo que a su vez genera una reducción de contaminantes al medio ambiente que afecta a otras especies o pequeños ecosistemas que confluyen en estos espacios agrícolas.

Existe una estrecha relación entre el ser humano y el desarrollo agrícola, por lo cual se origina la idea de diseñar un modelo que permite a grandes y pequeños productores correlacionar los datos de análisis de muestreo de suelos (práctica común entre los agricultores), complementando con información de imágenes satelitales, para generar un panorama más amplio de la distribución de los macronutrientes (Nitrógeno, Fósforo y Potasio) y nutrientes secundarios en los cultivos.

De forma natural, el suelo aporta directamente a las necesidades de cada cultivo a través de macronutrientes o nutrientes secundarios los cuales son de gran importancia en relación con su distribución y concentración para la producción de cualquier tipo de cultivo. La toma de decisiones teniendo en cuenta las condiciones nombradas se hace bajo un análisis integral de la composición del suelo y no fundamentados bajo bases empíricas que, aunque presentan casos de éxito en ocasiones, carecen de soporte científico para una correcta toma de decisiones y no garantiza que procesos agrícolas sean más eficientes.

Al identificar la importancia del sector agrícola, en el ámbito mundial, surgen este tipo de modelos, en donde se busca a partir de unos objetivos alcanzables lograr el

desarrollo de la presente investigación. Cada uno de los componentes que aportan las tecnologías de la información geográfica, permiten definir un desarrollo lógico e integral que, sumados con la información agrícola, se convierten en herramientas de un alto potencial para lograr generar cada uno de los análisis sobre las salidas gráficas, al producir mapas de nutrientes de manera individual categorizados por sus concentraciones, producto que será determinante para el agricultor en su día a día.

La clara ejecución de estos objetivos remarcará la importancia del desarrollo tecnológico del sector agrícola que, en ocasiones, no es valorado dentro de la misma sociedad.

Desde una perspectiva lógica, también se pueden evidenciar los retos y limitaciones que presentan estos tipos de investigaciones, en lo particular las limitaciones climatológicas son un factor determinante, tanto para la captura de información como para el análisis de los datos. Como es bien sabido, los sensores ópticos, a diferencia de los de radar, tienen una limitación visual con respecto a nubes, por lo que las fechas escogidas para la captura de las imágenes debe ser programada para momentos donde las condiciones atmosféricas lo permitan y que coincidan temporalmente con las condiciones del suelo requeridas para la investigación, que para este caso es suelo sin ningún tipo de cobertura vegetal.

Otra limitación, es la posible variación de los datos de las muestras de suelo debido a las temperaturas del suelo, pues si los cambios de temperatura son muy elevados, las concentraciones pueden variar de forma considerable. Esta limitación abre una nueva posibilidad de investigación para determinar cuánto sería la variación de concentración de nutrientes por temperatura, para ello se necesitará de sensores que puedan captar información en el espectro electromagnético del térmico, aunque no compete para el desarrollo de este trabajo.

Junto con la importancia del proyecto, objetivos y limitaciones, se debe plantear una metodología de muestreo que permita la identificación de los nutrientes más importantes a mayor detalle de distribución y concentración. Esta metodología debe

enmarcarse en una secuencia lógica desarrollada por etapas, donde se estructura, de manera inicial, la parte de recolección de muestras y análisis para, posteriormente, enfocar los esfuerzos en las diferentes posibilidades de correlación los datos vectoriales con la información ráster, consideradas en la etapa dos y, por último, una tercera etapa que permitirá estructurar la secuencia final enfocada en el análisis de mapas por cada nutriente generados en la etapa anterior.

Finalmente, se brindará un panorama general del uso eficiente de las nuevas tecnologías con la intención de establecer la estrecha relación que presentan con el sector agrícola. En la actualidad, la situación de la relación del ser humano con el medio ambiente es crítica, y más cuando se cultiva de manera descontrolada y poco eficiente, por eso se debe trabajar en proyectos que ayuden en la reducción de contaminantes o agentes que alteren la composición y estructura natural del suelo, como los agroquímicos que, al paso del tiempo, pueden llegar hasta los recursos hídricos subterráneos, de vital importancia para vida de todas las especies de este planeta.

1. Planteamiento del problema de investigación y su justificación

En la presente investigación se desean explorar diferentes posibilidades de encontrar una relación en la información ráster y el manejo de muestras de laboratorio de suelo para generar información de mayor calidad al momento de identificar la distribución y nutrientes del suelo en áreas de uso agrícola. Porque, a partir de estos resultados, se podrá gestionar, de manera más eficiente, la aplicación de insumos agrícolas que, en muchas ocasiones, generan gastos innecesarios y así contribuir en la reducción de fertilizantes de síntesis química aplicados.

Para validar el desarrollo de la investigación se tiene que analizar cómo se debería diseñar una metodología que, teniendo en cuenta todas las posibles variables, permita correlacionar las muestras del suelo obtenidas en campo con la información que brinda la banda 12 de Sentinel 2 para suelo descubierto o sin cobertura vegetal. Encontrar esta relación tendría bastante relevancia, ya que potencializaría el alcance de las tecnologías para la gestión, análisis e interpretación de la conformación del suelo y, más en detalle, de la distribución de los nutrientes, eje fundamental para el desarrollo de los cultivos.

1.1 Descripción del área problemática

La agricultura desempeña un papel fundamental en el desarrollo socioeconómico, más en países menos desarrollados, donde los procesos eficientes mejoran los costos de producción. El manejo de insumos representa significativamente un impacto, negativo o positivo, dependiendo del uso adecuado de los recursos.

Actualmente, la metodología para definir las áreas de toma de muestra de suelo carece de interoperabilidad entre insumos y componentes tecnológicos, lo que conlleva a la mala toma de decisiones al momento de identificar la distribución de los nutrientes para las plantas, debido a que la cantidad de nutrientes disponibles en el suelo es determinante su potencia para alimentar los organismos vivos.

Los 16 nutrientes esenciales para el desarrollo y crecimiento de las plantas se suelen clasificar entre macro y micronutrientes dependiendo de su requerimiento para el desarrollo de las plantas. Los macronutrientes se requieren en grandes cantidades e incluyen Carbono (C), Hidrógeno (H), Nitrógeno(N), Fósforo (P), Potasio (K), Calcio (Ca), Magnesio (Mg), Azufre(S). Los micronutrientes por otro lado se requieren en pequeñas, su insuficiencia puede dar lugar a carencia y su exceso a toxicidad, se refieren a Hierro (Fe), Zinc (Zn), Manganeseo (Mn), Boro (B), Cobre (Cu), Molibdeno (Mo), Cloro (Cl). (FAO, 2022a).

Los nutrientes son de vital importancia para definir estrategias eficientes en el momento de planificar la siembra o distribución de fertilizantes para compensar el equilibrio entre los elementos faltantes.

Las herramientas empleadas para gestionar la toma de muestras no contemplan implementar el manejo de muestreo dirigido, de forma lógica, para obtener datos de suelo de todos los ambientes presentes en el área de estudio, sino que se realizan como procesos aislados, sin lineamientos metodológicos que permitan cruzar información entre las muestras dirigidas e información satelital, lo que conlleva a no disponer de una metodología clara que aporte a un flujo de trabajo eficiente y preciso en la interpretación del contenido de las muestras de laboratorio y los geoprocesos que potencializan los resultados, lo cual radica principalmente en el desconocimiento de los potenciales aportes de la implementación de tecnologías de información geográfica (TIG) en el análisis de datos.

1.2 Formulación del problema

¿Cómo desarrollar un modelo que permita generar muestreos dirigidos de suelo, que permita determinar, tipos de suelo, macronutrientes y nutrientes secundarios, para una óptima gestión de suelos, a través del empleo de mapas de ambientes y análisis de laboratorio?

1.3 Justificación

La implementación de un nuevo modelo estructurado con las TIG permitirá abordar temáticas que aún no han sido utilizadas y que aportarán de forma significativa en el desarrollo de actividades en la gestión agrícola.

Es importante para el agricultor, con menos capacidad de agenciamiento tecnológico, el desarrollo de un modelo que permita la inclusión de los procesos tecnológicos en la gestión de la información de toma de muestras de suelo, pues implica que los datos recolectados, procesados y analizados tengan la suficiente calidad y precisión en relación con los nutrientes y sus concentraciones, lo cual deriva en reducción de tiempos en la toma de decisiones y claridad en los procesos.

Esta propuesta parte de la premisa de que el dato geográfico debe ser digital y de fácil comprensión por parte del personal que no tiene los suficientes conocimientos en el área de los sistemas de información geográfica (SIG). Al desarrollar el modelo, muchos agricultores de bajos recursos se beneficiarán significativamente, ya que podrán identificar las zonas con mayor capacidad de desarrollo para sus cultivos dependiendo de la presencia de los nutrientes esenciales necesarios y el desarrollo potencial del área de interés.

La implementación y el uso de herramientas tecnológicas permite recolectar, procesar, modelar, analizar y publicar información de forma eficiente y, como consecuencia, actualizar sus métodos tradicionales. Pasando de manipular información no digital a datos geográficos digitales que reducen el error para la estimación de maniobras y planes de acción.

La propuesta de implementar este modelo desarrolla un interés particular, al reunir procesos que, por medio de herramientas calificadas, permiten la toma de decisiones eficiente, ya que el recurso tecnológico es la base fundamental para manejar las bases de datos geográficas actuales y lograr potencializar los alcances de las TIG en las

actividades desempeñadas cotidianamente por el agricultor; actividades que son de alto impacto social por las actividades realizadas en producción de alimentos.

2. Antecedentes

El uso de sensores remotos como apoyo en la adquisición de información contribuye de manera significativa al análisis de diferentes componentes de la superficie terrestre, desde hace ya varios años se han empleado gran variedad de imágenes para conocer características de conformación del suelo, según Bousbih et al. (2019), las técnicas como la espectroscopia visible (VIS) e infrarroja cercana (NIR) se han utilizado como técnicas de detección y medición de la textura del suelo, este aporte es significativo, ya que evidencia que el uso de imágenes satelitales es un recurso de alto impacto para la obtención de datos sobre los tipos de suelo sin cobertura vegetal, y sus resultados permiten estimar que el uso de la teledetección facilita generar información de manera eficiente para el proceso de construcción de mapas de textura de suelo.

El *sensoramiento remoto*, gracias a sus capacidades de captura de información, permite abarcar grandes extensiones, lo cual es importante para análisis de suelo y es factor determinante para la gestión agrícola, de acuerdo con Liao et al. (2013, p. 489), en la identificación de la distribución espacial y la variabilidad de la textura del suelo es esencial para la planificación y el uso del suelo. De forma general, con el uso y la implementación óptima de las tecnologías se puede contribuir a la generación de mapas de suelo; llegando a ese punto de eficiencia en la toma de decisiones sobre el manejo de tierras con enfoque agrícola.

El estado de la información es un factor determinante para obtener resultados satisfactorios, la calidad radiométrica de las imágenes y la resolución espacial permiten mayor nivel de detalle sobre el área de estudio. Pero se deben considerar diversos métodos de clasificación empleando sensores diferentes, la comparación de resultados permite identificar qué tipo de imagen se ajusta más a las necesidades del proyecto, de esta manera, y en coherencia con Borràs et al. (2017, p. 65), se puede definir que la calidad en la resolución espacial y radiométrica de S2 permite garantizar la mejora en los resultados de clasificación. Para los mapas de ambientes de suelo definir parámetros de calidad de la información entrante es determinante, dentro de estas características se contemplan variables significativas que pueden comprometer los resultados.

Un componente importante que es determinante para la generación de los mapas de macronutrientes y nutrientes secundarios es la textura del suelo y la degradación de este, los procesos de transporte de agua modifican la concentración de nutrientes. Curcio et al. (2013, p. 495) indican que se necesita mapear la textura del suelo a diferentes escalas para diferentes aplicaciones, pero, por lo general, una gran parte de las muestras deben analizarse, adecuadamente, para determinar la variabilidad espacial de la textura del suelo. El uso de imágenes satelitales en estos análisis permite la reducción de costos comparado con los métodos tradicionales, que son más complejos, unido a que el desarrollo científico actual impulsa a la creación de metodologías que impulsen las mediciones indirectas.

El suelo, como recurso, es un factor determinante para el desarrollo agrícola, por tal motivo es importante reconocer las posibilidades que actualmente brinda la teledetección a través de la clasificación de imágenes, este tipo de interpretaciones permite monitorear los cambios del suelo por diferentes factores. Según Nolasco, Willington y Bocco (2014, p. 64-65), en teledetección, el mapeo de la cobertura del suelo se constituye en sus aplicaciones principales, lo cual permite el desarrollo en investigación para mejorar los métodos de clasificación, logrando resultados más detallados y precisos, lo que conlleva a mejorar la eficiencia en la gestión de uso del suelo con enfoque agrícola.

Para obtener información precisa en diferentes comportamientos de tipos de suelo, se puede emplear la clasificación supervisada, y así categorizar las diferentes coberturas y generar un enfoque particular en suelos descubiertos, que son el componente de mayor interés para el desarrollo de esta investigación, por ende, tener una periodicidad en las imágenes permite soportar con mayor determinación los resultados esperados. El apoyo en la aplicación de procesos geoestadísticos también fortalece el proceso investigativo, lo que determina que, señalan Ramírez et al. (2020, p. 65), dependiendo el método estadístico se puede inferir cuál sería la forma más

adecuada para extrapolación de la información precisa de las imágenes de mayor resolución espacial a zonas de la imagen con menos resolución.

La optimización de procesos es otra de las características que se deben considerar dentro del manejo y análisis de la información a la hora de generar mapas de suelos, el aprendizaje automático o sistematización de procesos permite agilizar en gran medida rutinas manuales que al no ser controladas de forma correcta pueden aumentar el riesgo de incurrir en errores. De acuerdo con Trujillo et al. (2021, p. 180), se debe contar con una cantidad superior a tres métodos de aprendizaje automático, esto garantiza que el análisis de la información se pueda agilizar y se evalúe desde diferentes direcciones, este tipo de metodologías también permite generar mapas de suelo de manera más detallada teniendo como referencia la información pixel a pixel suministrada por las imágenes satelitales empleadas.

Dentro de los procesos de aprendizaje automático también se puede considerar el desarrollo de metodologías más especializadas, pero en ocasiones más complejas como lo son técnicas de aprendizaje profundo en el campo de la teledetección. Es bien sabido que el uso del suelo es uno de los recursos de mayor aprovechamiento para el ser humano dentro del desarrollo de sus actividades, desde hace varias décadas se ha venido implementando diferentes técnicas y métodos para la caracterización del suelo; para Campos et al. (2020, p. 45), el problema en la clasificación de suelos empleando imágenes satelitales se puede presentar al momento de elegir un algoritmo y otro, este tipo de elecciones deben contener un fundamento en el comportamiento habitual y su tipo de aplicación, lo que después deriva en la capacidad predictiva del mismo.

Así, los insumos fundamentales para extraer información de muestreo indirecto son las imágenes satelitales y los procesos donde se emplea la teledetección para generar los resultados finales, pero dentro del eje de la investigación también se debe considerar la información directa obtenida de las muestras de suelo recolectadas en campo; muestras analizadas posteriormente en laboratorio, resultados que facilitan identificar la composición detallada de nutrientes.

Asumadu-Sarkodie y Owusu (2017) mediante un modelo de regresión lineal, definieron el impacto del cambio de uso del suelo a través de los indicadores ambientales en una escala de análisis local, los cuales juegan un papel importante en la sustentabilidad del suelo. Sin embargo, los métodos y prácticas agrícolas que parecen insostenibles aún desempeñan un papel fundamental en las comunidades agrícolas. Por lo tanto, la introducción de prácticas agrícolas modernas en las comunidades locales y regionales a través de la creación de conciencia contribuiría en la lucha contra el cambio climático.

Nowak y Schneider (2017) por su parte, identificaron áreas amenazadas y degradadas por la actividad agrícola a través de indicadores ambientales en una escala de análisis regional, definida por la erosión del suelo, pérdida de nutrientes y contaminación del agua subterránea. (Jiménez et al., 2019, p. 1645-1646).

Estos datos de laboratorio son insumo fundamental, pues Garrido (1993, p. 2), afirma que uno de los aspectos más importantes al momento de crear mapas de suelo no solo es dar relevancia a los análisis, sino que, normalmente debe considerarse una serie de actividades que conllevan a resultados finales con consistencia lógica dentro del proceso ejecutado.

Dentro del componente tecnológico, cabe resaltar la importancia de los sistemas de información geográfica (SIG) como herramienta esencial para la administración del dato geográfico o, en gran medida, como motor de procesamiento de información. La generación e interpretación de los mapas de macronutrientes y nutrientes secundarios derivados de los mapas de ambientes y las muestras de suelo gestionados desde un SIG, permite percibir el resultado final al problema planteado. García et al. (2002, p. 94) se resalta la importancia de la vinculación de los sensores remotos y los SIG para la gestión de información en los cambios de los usos del suelo. Y no solo el manejo de la información empleando medios computacionales, sino también la geolocalización de las muestras, ya que se logra conocer con mayor precisión y nivel de detalle el componente del suelo en estructura y concentración de nutrientes presentes, datos que después de ser interpolados con la información de las imágenes permiten obtener mapas para cada

uno de los macronutrientes y nutrientes secundarios de forma más precisa y con datos más relevantes para el usuario final.

Como plantean González et al. (2019, p. 1004), el uso de las tecnologías de la información (TIC) en la agricultura de precisión contribuye al potencial rendimiento en la exploración de áreas de interés contemplando integración de sensores remotos, satélites, y sistemas de posicionamiento, pero se limita con la definición de macronutrientes, que es el desarrollo para implementar en la presente investigación.

Con el paso del tiempo y el uso habitual del suelo, las características y los componentes van cambiando, lo que enfatiza en la importancia de realizar muestreos de forma periódica, otro factor determinante para definir la temporalidad de las muestras se presenta en los suelos de ladera como lo son los suelos andinos. La pérdida de suelo puede alterar los resultados de una misma área en un periodo de tiempo muy corto; dentro de este tiempo se puede tener manejos agrícolas diferenciales con tipos de cultivos distinto, esto genera en el suelo el aporte de nutrientes se modifique de manera significativa, por este motivo Volverás y Amézquita (2009, p. 35) señalan que los usos de suelo con mayor intensidad de labranza disminuyen la proporción de macro agregados, la estabilidad estructural y el volumen del suelo, lo cual altera los resultados obtenidos de una misma área en periodos de tiempo diferentes.

La fertilidad del suelo, desde diferentes puntos de vistas, se considera como un componente determinante para el desarrollo óptimo de las plantas. Aunque el suelo es un elemento físico finito, con el paso del tiempo y la labranza ocurren pérdida y degradación de algunos elementos esenciales, cambios que se evidencian, en gran medida en el sector agrícola, con el uso elevado de fertilizantes buscando suplir las deficiencias de nutrientes, aportados de forma natural por los suelos. Según Rodríguez y Longa (2021, p. 10) las principales causas de la degradación del suelo radican principalmente en el mal manejo de la distribución de fertilizantes de fuente química desconociendo a su vez el alto impacto que se produce en los suelos con los niveles de contaminación en procesos productivos en áreas agrícolas. Debido a lo anterior es

importante encontrar métodos que permitan el uso responsable y eficiente de este tipo de elementos que se aplican de manera artificial al suelo.

Al paso del tiempo, las áreas que en su tradición han sido de destino agrícola permiten evidenciar cómo la degradación del suelo es bastante significativa, debido a manejos poco eficientes en la distribución de nutriente o aprovechamiento eficiente de los mismos. Martín et al. (2018, p. 24-25) señalan que, con el paso de los años y de acuerdo con los fertilizantes químicos empleados, se pueden encontrar aumentos de concentración de ciertos nutrientes y otros, por el contrario, se mantienen estables, lo que conlleva a que la agricultura intensiva puede modificar la fertilidad del suelo, y el conocimiento de los indicadores permite evaluar los sistemas productivos y su manejo.

La concentración de macronutrientes en el suelo es determinante para el desarrollo eficiente de los cultivos, conocer la distribución para cada uno de los elementos como N, P, K en un área de interés es un aporte muy valioso para el desarrollo agrícola. Conocer los usos del suelo que con el tiempo se le ha dado al área de estudio permite inferir la calidad de los nutrientes presentes en el mismo, como referencia se puede decir que aquellas tierras que anteriormente fueron empleadas para ganadería con el tiempo los macronutrientes presentes van a presentar variaciones y tendencia a la baja concentración de estos, por esto la importancia de realizar muestreos dirigidos en toda el área de estudio. La ganadería, en suelos amazónicos, “genera una baja concentración generalizada de elementos importantes como P, K, Ca, Mg y S, en comparación con los valores óptimos de concentración de macronutrientes para suelos tropicales” (Zambrano et al., 2020, p. 9).

La pérdida del componente estructural del suelo también se deriva por la modificación o sustitución del bosque nativo por uso agrícola, estos cambios aumentan la susceptibilidad y marca una tendencia a la erosión, lo que causa que la disponibilidad de ciertos nutrientes se altere de manera significativa, lo que enfatiza más en la importancia de definir las muestras dirigidas para conocer con mayor facilidad las tendencias de cambio. Un antecedente importante de la investigación realizada por Conti

(2004), quien define que la pérdida de las propiedades físicas, químicas, biológicas y microbiológicas se deben, principalmente, al uso intensivo de la tierra en actividades de ganadería, efecto que se puede revertir con la implementación de fertilizantes.

Uno de los factores más negativos con respecto a los fertilizantes es el uso no adecuado el cual puede contribuir de forma significativa en los altos contenidos de salinidad del suelo, aumentando también efectos negativos sobre el medio ambiente. De acuerdo con Beltrán et al., (2019, p. 377), los abonos orgánicos son buenas fuentes de nutrientes para los cultivos, además de tener valores de pH propicios para la asimilación de los macronutrientes.

Los insumos empleados para garantizar el equilibrio por pérdida natural o artificial de los macronutrientes y nutrientes secundarios del suelo son un mecanismo que no revierte el problema totalmente, pero garantiza que el cultivo cumpla con la demanda de consumo de nutrientes que le aporta el suelo. Todo tipo de suelo presenta, por diferentes razones, deficiencias de nutrientes, lo que conlleva a que si se desconoce la distribución de nutrientes se incurra en sobrecostos para mantener y garantizar la producción de una plantación específica. Para Meza (2021) es claro que “los fertilizantes son importantes, desde un punto vista agronómico, para el aumento de la productividad de los cultivos. El rendimiento depende principalmente de la cantidad de nutrientes, época y técnica de aplicación” (p. 9), posición ratificada cuando concluye:

Los resultados permiten evidenciar el efecto positivo de la aplicación del fertilizante con la técnica drench y fertirriego sobre la productividad (1560 y 1472 kg/ha de café pergamino respectivamente) con respecto al tratamiento control. Los resultados de la evaluación económica de costo nos indican que la técnica Fertirriego triplica los costos del método drench. (p. 11)

No se puede descartar el uso de información térmica para definir diferentes valores al momento de caracterizar el suelo, ya que diferentes componentes externos al comportamiento natural pueden afectar indirectamente los valores representativos de los macronutrientes, una característica relevante es que este tipo de información se puede

obtener usando imágenes satelitales, estos comportamientos atípicos presentan un punto diferencial en diferentes coberturas pero la que más interesa es el suelo descubierto y como varían su composición por diferencias de temperatura. Al respecto, Ferrelli et al. (2015, p. 32) enfatizan que la información obtenida de temperatura de suelo, empleando imágenes satelitales, permite obtener datos para realizar análisis más dinámicos. Este tipo de información no debe ser despreciable ya que puede contribuir a la precisión y calidad de los datos que se pueden generar la creación de los mapas de macronutrientes y nutrientes secundarios.

El comportamiento del suelo presenta una dinámica que debe ser considerada, y en ocasiones estipulada como un patrón, por lo que es de esperar cambios en las características espaciales en función del tiempo, así Alperín, Guerrero y Sarandón (2002, p. 41) señalan que con el análisis geoestadístico se logra cuantificar patrones espaciales que contribuyen a definir con mayor claridad a optimizar los cambio por efectos de temporalidad entre las imágenes, dando claridad a la concentración de nutrientes para cada tipo de suelo caracterizado.

3. Objetivos

3.1 Objetivo general

Diseñar un modelo preliminar para Identificar la fertilidad de suelos, para el cultivo de soja, a partir de imágenes satelitales e interpolación geoestadístico IDW.

3.2 Objetivos específicos

- Generar la información del componente físico del suelo empleando la banda 12 de Sentinel 2 y muestras de suelo.
- Identificar la distribución y concentración de macronutrientes y nutrientes secundarios en el suelo empleando procesos geoestadísticos.
- Analizar, en el área de estudio, cuáles son los sectores con mayor aporte de nutrientes para el cultivo de soja.

4. Referente contextual

La investigación se lleva a cabo en una zona de alto desarrollo agrícola, ubicada al oriente de Paraguay (Figura 1), específicamente en una zona agrícola de alto potencial del departamento de Itapúa, caracterizada por la producción de soja.

Figura 1.

Localización general área de estudio



Dentro de un contexto general, esta región presenta características particulares, por su localización cerca al río Paraná, cuenta con suelos predominantemente de origen residual lo que hace que la región oriental cuente con características especiales, esto permite que la gran mayoría de cultivos de soja se desarrollen en esa parte del país. Como referencia particular se pueden encontrar suelos de color amarillo y rojo lo que indica el bajo contenido de materia orgánica y conformación de suelos franco – arcillosos.

Por el gran potencial agrícola, actualmente en esta zona suceden eventos que afectan la composición del suelo, en particular son suelos con un alto porcentaje de erosión causada principalmente por la alta actividad agrícola que se presenta cada año, este fenómeno afecta directamente el horizonte superficial del suelo, lo que hace que los

grandes explotadores agrícolas cada año se enfoquen a integrar nuevos mecanismos que les permita mantener o mejorar su producción de forma eficiente.

Por ser la soja un cultivo extensivo que demanda una cantidad mayor de nutrientes aportados por el suelo, referente a otros cultivos, en la región oriental del Paraguay, cada cosecha o campaña evidencia que la reducción de los macronutrientes es considerablemente alta y sin nombrar los nutrientes secundarios que tienen una tendencia a ser de mayor baja concentración.

La soja o soya (*Glycine max*), es una leguminosa de gran importancia industrial, por lo que su producción ha tenido incrementos significativos, según Almerfors (2008), como es el caso de Paraguay, donde llega desde Brasil en la década de los 60:

Desde entonces la producción de soja ha crecido significativamente hasta llegar a la cosecha record de 6,2 millones de toneladas en 2007, específicamente durante un periodo de 11 años, desde 1995-2006, la producción de soja ha crecido 191 % (Palau et al 2007). Este aumento se debe, entre otras cosas a factores económicos en el ámbito global, una de las causas significantes de este ascenso ha sido la demanda mundial por la soja. Esta planta leguminosa se ha convertido en materia prima para el mercado del biocombustible, la creciente producción de soja ha implicado la instalación permanente del monocultivo en Paraguay. A consecuencias de la expansión del monocultivo en zonas forestales y áreas selváticas han surgido problemas ambientales. (p. 5)

Por el contexto anterior se resalta la importancia de conocer la dinámica del suelo referente a la concentración de sus nutrientes y de aquellos que son de mayor demanda para el cultivo de soja, estos suelos tienen otra particularidad no menos importante y es la capacidad de retención de agua, se manejan porcentajes muy bajos más las altas temperaturas llevan a que cada ciclo del cultivo tenga que tratarse de manera diferencial para alcanzar las estimaciones esperadas.

5. Referente normativo y legal

Los fundamentos normativos y legales del tema de estudio se fundamentan en documentos listados en la Tabla 1.

Tabla 1.
Marco normativo y legal

Normativa	Entidad	Año
Ley 6286 de defensa, restauración y promoción de la agricultura (Paraguay)	SIPROAF	2019
Norma técnica colombiana – Información Geográfica metadatos. NTC-4611 tercera actualización.	ICONTEC	2021
Metadatos geográficos - ISO 19115-1	ISO	2014
Calidad de los datos - ISO 19157	ISO	2013

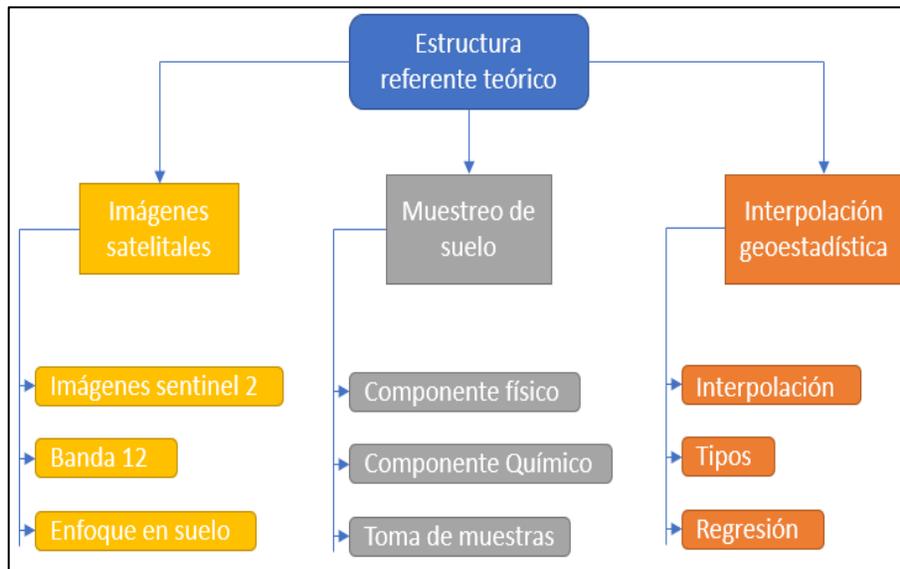
No solo es tener en cuenta el manejo de la información agronómica, también se debe contemplar un marco internacional para identificar como se deben manipular los datos geográficos que se emplean para la representación de diferentes escenarios, por lo que se considera lo propuesto en la norma ISO 19157:2013, que hace énfasis en los componentes determinadores de la calidad, estructura y validación de los datos geográficos. Los metadatos geográficos manejados en la interfaz gráfica de usuario deben ser ajustados, de acuerdo con la norma ISO 19115-1:2014, ya que deben proveer información acerca de su identificación, extensión, elementos espaciales, referencia espacial y todas las propiedades digitales del dato geográfico.

Es importante tener un referente normativo local para verificar qué tan importante es el aporte de la agricultura para el desarrollo local, por lo que la ley 6286:2019 dinamiza en gran medida lo siguiente: “Es fundamental que la república del Paraguay adopte las medidas normativa necesarias de una política nacional para la agricultura familiar campesina factor clave para la economía nacional”. En tanto, para el caso colombiano, el manejo la información geográfica es estandarizado por la NTC-4611:2021, que define “el esquema requerido para describir información geográfica y servicios por medio de metadatos. Proporciona información acerca de la distribución de información y la descripción completa de los conjuntos de datos y servicios”.

6. Referente teórico

El desarrollo del referente teórico se fundamenta en la estructura propuesta en la **¡Error! No se encuentra el origen de la referencia.**, donde se plantean tres líneas conductoras o principales temas de referencia que abordará la presente investigación. Por ello, se ejecutará en ese orden, con base en documentación local e internacional.

Figura 2.
Estructura referente teórico



6.1 Imágenes satelitales

Las imágenes satelitales son un producto que por sus características permite identificar diferentes coberturas del terreno, cada una de las bandas que compone la imagen satelital permite en gran medida categorizar de mejor manera ciertos elementos de interés, a mayor cantidad de bandas ofrecidas por la imagen, mayores serán las posibilidades de enfocar el análisis en características particulares del terreno, como por ejemplo cuerpos de agua, vegetación, suelos, entre otros.

Para ahondar más en la definición de una imagen satelital, se toma a Gonzaga (2014, p. 29), para quien “una imagen satelital es el producto obtenido por un sensor

instalado a bordo de un satélite artificial a través de la captación de la radiación electromagnética emitida o reflejada por un cuerpo” (p. 29), señalando además que:

Existen diferentes tipos de imágenes satelitales, dependiendo del tipo de sensor. Desde las primeras cámaras fotográficas montadas en satélites en la década de los 60 hasta los más sofisticados y sensibles sensores hiperespectrales. Existe una amplia gama de tipos de imágenes satelitales que hoy se utilizan en las más diversas áreas, dependiendo de su resolución espacial, así como de la información espectral que poseen; desde el espionaje militar, el monitoreo del cambio climático, monitoreo de incendios e inundaciones, seguimiento de huracanes y tifones, evaluaciones multiespectrales de vegetación etc. (Bense, 2007). (p. 30).

Actualmente, las implementaciones tecnológicas han permitido que diferentes fenómenos puedan ser monitorizados empleando técnicas de teledetección donde el insumo principal son las imágenes satelitales, de acuerdo con Molina, Trejo y Gutiérrez et al. (2018, p. 84), “la teledetección resulta ser una de las más utilizadas y con mayor posibilidad de aplicación en múltiples campos. Sin embargo, se requiere su fusión con herramientas informáticas que permitan un uso sistemático, ágil y eficiente de la información recopilada”.

6.1.1 Imágenes Sentinel 2 (S2)

Las imágenes satelitales abren nuevos campos de estudio en diferentes áreas del conocimiento, debido a la cantidad de información que se puede obtener de ellas, también se derivan una particularidad de estudios con diferentes enfoques para visualizar el comportamiento de fenómenos que afectan directa o indirectamente al ser humano.

Las secuencias multitemporales transformaron la manera de ver y analizar el comportamiento en función del tiempo, para lo cual las imágenes satelitales se convierten en recurso fundamental, como lo ratifican Pino y Huayna (2022, p. 149), al establecer estados de afectación de plagas en olivos mediante la variación temporal de los índices NDVI, DVI, SAVI, GNDVI, EVI2 y MSAVI.

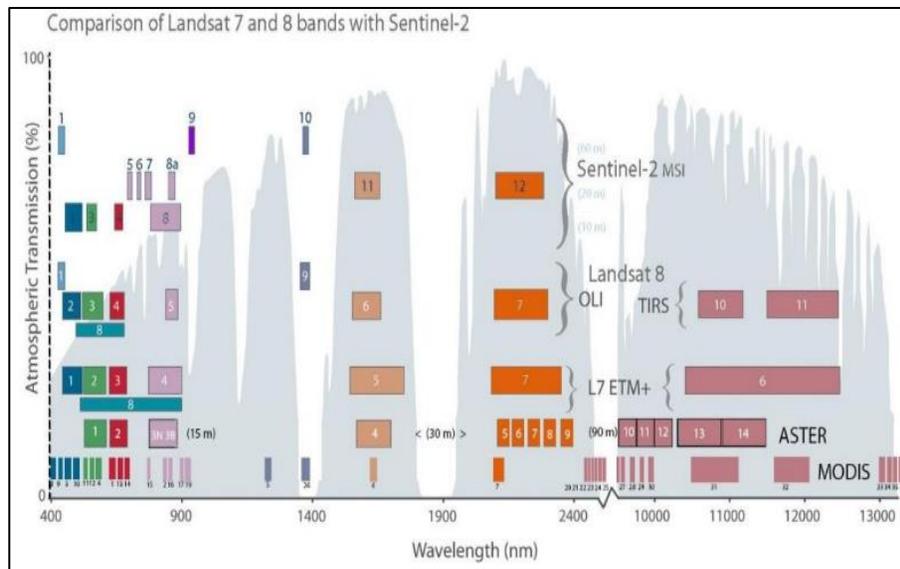
Las imágenes usadas en este trabajo fueron tomadas por S2, misión que forma parte del Programa Copérnico para la Observación de la Tierra de la ESA. Este programa fue diseñado para suministrar información actualizada y de fácil acceso para mejorar la gestión del medio ambiente, y comprender y mitigar los efectos del cambio climático. El programa tiene planificadas cinco misiones y cada una está conformada por varios satélites. (...)

S2 proporciona datos para la generación de productos tales como: mapas de usos del suelo, mapas de cambios a lo largo del tiempo, mapas de riesgo, e imágenes rápidas para prevención de desastres. También proporciona datos para la generación de variables biofísicas de la vegetación como la cobertura vegetal, el contenido de clorofila o el contenido de agua en las hojas. Este satélite cuenta con un instrumento de captura multiespectral mejorando los datos de otras misiones operativas (*Drusch et al., 2012*). (Borràs et al., 2017, p. 60)

El desarrollo e implementación de las misiones satelitales para captura de imágenes con diferentes sensores ha permitido, según Darius et al.,(2020, p.2), un salto revolucionario en la parte tecnológica aplicado a estudios que permiten al ser humano tener una mejor apreciación de los fenómenos naturales que suceden en la superficie de la tierra, por tal motivo es importante conocer las diferentes resoluciones que aportan diferentes misiones como se puede apreciar en la Figura 3.

Figura 3.

Comparación de diferentes misiones satelitales en cuanto a resolución espacial y espectral (USGS Landsat Program citado por El Atillah, El Morjani y Souhassou, 2019, p. 80)



6.1.2 Características banda 12 Sentinel 2

Las imágenes Sentinel 2 se caracterizan por estar compuestas por 13 bandas, las cuales están categorizadas por su longitud de onda y resolución espacial como se aprecia en la Tabla 2, cada una de las bandas permite realizar análisis independientes.

La banda 12 SWIR 2 tiene una particularidad que trabaja con infrarrojo de onda corta, este tipo de datos permite discriminar de mejor manera suelos secos y húmedos, estos suelos no deben contar con cobertura vegetal ya que alterara de forma significativa los resultados o análisis que se realicen con esta banda. Generalmente es muy utilizada para estudios geológicos y con un gran potencial en la clasificación física del suelo.

Tabla 2.

Características generales Sentinel 2 (Adaptado de (USGS, 2021).

Bandas	Nombre de la banda	Longitud de onda (μm)	Resolución (m)
BANDA1	Aerosol	0.43 - 0.45	60
BANDA2	Blue	0.45 - 0.52	10
BANDA3	Green	0.54 - 0.57	10
BANDA4	Red	0.65 - 0.68	10
BANDA5	Red edge 1	0.69 - 0.71	20
BANDA6	Red edge 2	0.73 - 0.74	20

Bandas	Nombre de la banda	Longitud de onda (μm)	Resolución (m)
BANDA7	Red edge 3	0.77 - 0.79	20
BANDA8	Near Infrared (NIR1)	0.78 - 0.90	10
BANDA8A	Near Infrared (NIR2)	0.85 - 0.87	20
BANDA9	Water vapour	0.93 - 0.95	60
BANDA10	Cirrus	1.36 - 1.39	60
BANDA11	SWIR 1	1.56 - 1.65	20
BANDA12	SWIR 2	2.10 - 2.28	20

6.1.3 Uso de imágenes satelitales para clasificación de suelo

El uso de imágenes satelitales para clasificación de coberturas se ha convertido en una herramienta de alto potencial; para el caso del suelo diferentes estudios han demostrado la eficiencia al emplear este tipo de datos para clasificar los tipos de suelos presentes en diferentes áreas. Cada actualización que realizan de las misiones satelitales de sus imágenes permite observar el grado de desarrollo que se produce para cada una de las bandas, lo que permite generar productos de mayor calidad y confiabilidad.

La clasificación de coberturas del suelo consiste en estimar los tipos de coberturas en un área determinada ya sea usando observación visual o métodos computacionales. La clasificación de coberturas es aplicada a cartografía (Eisavi et al., 2015, p. 1), al monitoreo de recursos naturales, estudios en cambios de biodiversidad e índices de vegetación (Bokusheva et al., 2016, p. 200) y un potencial de desarrollo en el monitoreo de cultivos en busca de fitopatógenos y otras afecciones.

6.2 Muestreo de suelo

El muestreo de suelo puede tener diferentes enfoques dependiendo el estudio para el cual sea aplicado, para el muestreo en suelos agrícolas se determinan diferentes protocolos y equipos que permiten obtener muestras *in situ*, que son llevadas a laboratorio y arrojan datos de relevantes para el plan de siembra y mejora de un cultivo. Estos análisis de laboratorio se realizan para cada una de las muestras recopiladas; las cuales son determinadas en puntos georreferenciados específicos de alto interés en las zonas cultivables. De acuerdo con Sainz et al. (2022), una distribución homogénea que

garantice la mayor cantidad de información, de acuerdo con la variabilidad del campo, implica diseñar una grilla que abarque el 100% del área de estudio, esto garantiza que las muestras queden bien distribuidas y se pueda lograr una obtención de datos más completa y uniforme, el inconveniente es el alto costo que representa, por lo que actualmente se maneja tomas de muestras aleatorias.

Por medio de los datos y los análisis se deriva una serie de sucesos que permiten conocer la realidad del campo en cuanto a la parte física y química del suelo, dependiendo de la orientación del análisis, se pueden lograr resultados completos o generales con enfoque en los nutrientes principales o alguno en particular, esto dependerá exclusivamente del manejo que le quiera dar el agrónomo.

La cobertura del suelo hace referencia a la información del material físico en la superficie de la tierra y el uso del suelo se asocia a las modificaciones hechas sobre esta cobertura por el hombre, Así, señalan Backoulou et al. (2015), la detección de cambios de cobertura o uso es el proceso de identificar los cambios en un área o fenómeno ambiental mediante la observación en diferentes momentos de tiempo.

6.2.1 Propiedades físicas del suelo

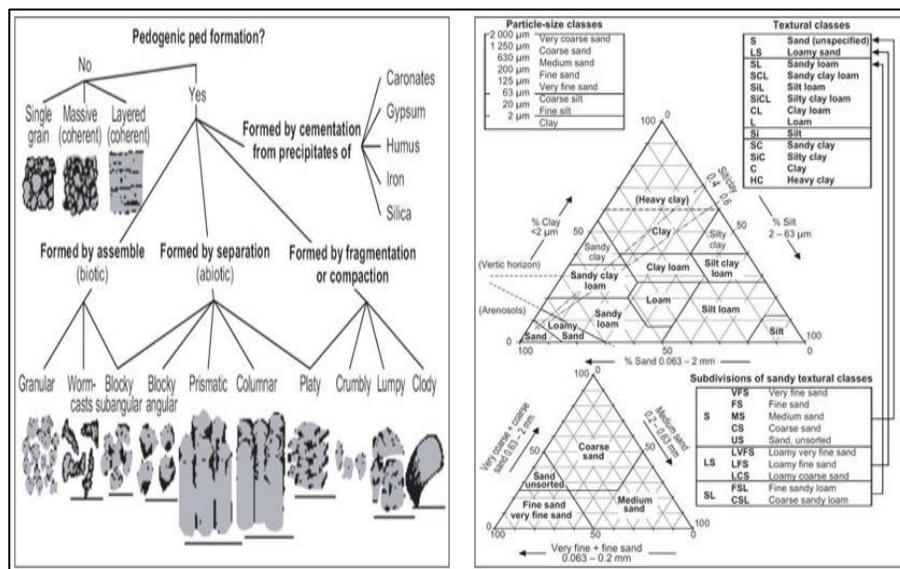
El suelo, en su conformación general, se considera un sistema abierto y dinámico, que por diferentes condiciones, ya sea temperatura o humedad, puede comportarse de manera diferente, algo que caracteriza a los suelos son sus tres fases: - la sólida, conformada principalmente por material orgánico e inorgánico, - la fase líquida y - la fase gaseosa, que se encuentran en los espacios que se deja la fase sólida, comportamiento dinámico que permite llenar estos espacio de aire con contenido de oxígeno y dióxido de carbono y líquidos que transportan iones y sustancias en solución. Sin embargo, las propiedades físicas del suelo están en función de su textura y su estructura (Figura 4).

Las partículas texturales del suelo como arena, limo y arcilla se asocian para formar agregados y a unidades de mayor tamaño nombrados por *peds*. La estructura del suelo

afecta directamente la aireación, el movimiento del agua en el suelo, la conducción térmica, el crecimiento radicular y la resistencia a la erosión. (...)

La textura del suelo se refiere a la proporción de componentes inorgánicos de diferentes formas y tamaños como arena, limo y arcilla. La textura es una propiedad importante ya que influye como factor de fertilidad y en la habilidad de retener agua, aireación, drenaje, contenido de materia orgánica y otras propiedades. (FAO, 2022b)

Figura 4
Estructura física del suelo (FAO, 2022b)



6.2.2 Propiedades químicas del suelo

Se refiere a la concentración de elementos químicos que hacen parte del suelo, el proceso más utilizado para obtener estos resultados se realiza por medio de muestras de suelo en campo, empleando calicatas las cuales pueden ser configuradas en ancho largo y profundidad dependiendo del interés de las muestras. Esto permite obtener muestras representativas del suelo las cuales posteriormente serán analizadas en laboratorio para conocer a detalle la composición química del mismo.

El componente químico del suelo resulta de alto valor para la industria agrícola debido a que, dependiendo de la concentración de los nutrientes se puede ver afectado

el desarrollo edafológico de las plantas, lo cual radica principalmente en la calidad esperada del fruto y la concentración de nutrientes. El desarrollo foliar también se ve directamente relacionado con la fertilidad del suelo, aunque cabe resaltar que existen diferentes elementos químicos que en altas concentraciones pueden ser perjudiciales para el cultivo. Diferentes estudios han demostrado que se debe mantener un balance en las propiedades químicas del suelo, para garantizar la disponibilidad de los nutrientes, siendo, según Vargas et al. (2022, p. 2), la rotación de cultivos una estrategia adecuada para “resolver problemas como el estancamiento del rendimiento, el agotamiento de los recursos y la reducción de la dependencia de insumos sintéticos”.

6.3 Interpolación de datos

La interpolación de datos, señalan Johnston et al. citados por Villatoro, Henríquez y Sancho (2008, p. 96), “ofrece la ventaja de proyectar mapas o superficies continuas a partir de datos discretos; sin embargo, la utilización de una buena cantidad de puntos del área en estudio limita su utilización”, aunque el tipo de datos, su costo y dificultad de obtención sean los determinantes de realizarla.

Para Vega et al. (2022, p. 2), al ser la fertilidad del suelo un factor limitante en el manejo adecuado de las explotaciones agrícolas, y dado que las propiedades del suelo varían espacialmente, tales variaciones “se pueden mapear a través de técnicas geoestadísticas que permiten delimitar áreas de manejo diferencial”, sin embargo, “la precisión en el mapa generado, a partir de las características de un suelo en particular, depende en gran medida de la estructura espacial de los datos, donde entre más fuerte la correlación espacial, mejor la calidad del mapeo” (Kravchenko, citado por Villatoro, Henríquez y Sancho, 2008, p. 96).

Los métodos de interpolación son empleados en múltiples estudios geoestadísticos, donde a partir de un dato central y su distribución espacial se logra obtener información que no fue obtenida de primera mano, *Inverse Distance Weighting* (IDW) es un modelo particular que permite, según Liu et al., (2021, p. 1), mejorar la

precisión al momento de realizar la estimación de los datos y calcular los pesos de acuerdo con las necesidades del análisis a realizar, siendo ampliamente utilizado en la interpolación de imágenes, de datos espaciales y la optimización de algoritmos.

El IDW asume que cada punto medido tiene una influencia local que disminuye con la distancia. Les asigna una ponderación mayor a los puntos más cercanos a la posición por predecir, que a aquellos que se encuentran más alejados, de ahí el nombre de distancia inversa ponderada. (Toro y Melo, 2009, p. 58)

Por su parte, Vega et al. (2022, p. 2) afirman que el método Kriging (llamado así en homenaje a su creador, el ingeniero surafricano Danie Gerhardus Krige) está “entre los métodos geoestadísticos más utilizados para interpolar variables y realizar predicciones, que consideren la estructura espacial de los datos y su autocorrelación mediante semivariogramas”.

El método Kriging proporciona una solución al problema de la estimación basada en un modelo de variación espacial estocástica. En su formulación original, una estimación, como tal, en un lugar era simplemente una suma lineal o promedio ponderado de los datos en su vecindario, aunque según Haining et al. (2010), el Kriging es una denominación general, ya que existen distintos tipos de modelos para describir el comportamiento de variables espaciales que se desee predecir. Kriging lineal es el método más robusto y conocido, aunque este puede tener funciones lineales y no lineales dependiendo de las variables en estudio. (García, Paniagua y Chicaiza, 2022, p. 69)

7. Hipótesis de investigación

La presente investigación dará como resultado una serie de datos que permitan mejorar la toma de decisiones, al ser un modelo preliminar se pretende acercarse lo más posible a la realidad del suelo, hablando de textura y distribución de macronutrientes y nutrientes secundarios en el área de estudio, es claro resaltar que por diferentes circunstancias y la adecuación del modelo geostatístico IDW los datos pueden variar y se requiera de datos adicionales que mejoren el modelo, pero esto evidentemente se podrá mejorar a medida que se trabajen en nuevas versiones del modelo en mejoras futuras.

La distribución de muestras geolocalizadas dentro de un mapa de ambientes permitirá obtener una serie de datos para cada uno de los elementos químicos del suelo que interpolados con los datos de nivel digital de la banda 12 de Sentinel 2, donde la información satelital sirve para establecer correlación con los nutrientes disponibles en el suelo bajo las condiciones del experimento que permitirán obtener un radiograma del campo más completo en distribución y concentración de estos elementos químicos.

La generación de mapas por nutriente es un insumo que permitirá diferenciar de forma independiente el comportamiento de cada elemento en el suelo, datos de alto valor que el agricultor puede emplear en la gestión de su campo al momento de planificar la siembra, ya que de antemano se conoce de forma general como es que están distribuidos los nutrientes en el campo y según el tipo de cultivo se conocerá cuales macronutriente y nutrientes secundarios son de mayor demanda, fortaleciendo zonas en déficit y ahorrando en zonas donde las concentraciones sean óptimas para su cultivo.

8. Metodología

La metodología que se empleó en la presente investigación parte del análisis de información primaria y secundaria, en donde se definieron términos como análisis de laboratorio, imágenes satelitales, nutrientes e interpolación geoestadística todo relacionado con este campo conceptual.

Basándose en los conceptos se realizó el diseño de un modelo preliminar que permitió emplear el método interpolación geoestadístico IDW para correlacionar muestras de laboratorio de suelo y la banda 12 de Sentinel 2 y obtener resultados de concentración de macronutrientes y nutrientes secundarios en el suelo.

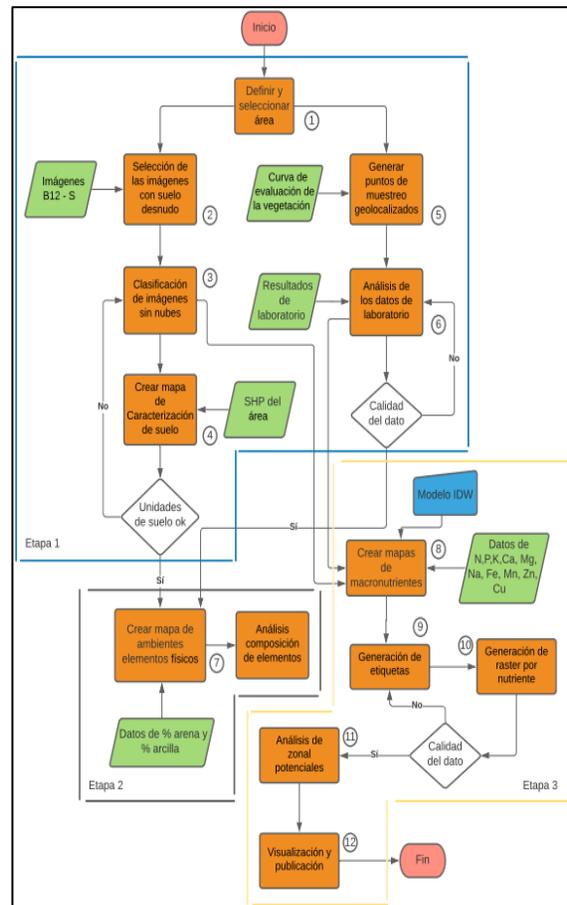
En el desarrollo de esta investigación la metodología se estructuró bajo parámetros lógicos organizados por etapas como se evidencia en la Figura 5, cada una de las estrategias, actividades y procedimientos se enmarcan en hilos conductores que garantizan la correcta correlación de la información e identificando los puntos críticos; que de no ser planteados pueden ser un problema dentro del desarrollo e implementación de la metodología que se presenta a continuación. En ella se identificó la estructura general de la metodología, seguidamente se realizó la explicación por etapas y las actividades que la conforman.

Para dar inicio con la conformación de las etapas planteadas, de manera exhaustiva se realizó la consulta de fuentes secundarias que ampliaron el panorama del área de estudio, permitiendo establecer las estrechas relaciones con otro tipo de investigaciones y sus metodologías, de igual forma, se obtuvo un panorama más amplio al comparar otros tipos de interpolaciones geoestadísticas que puedan aportar de manera significativa a las condiciones necesarias que deben ser tenidas en cuenta al momento de relacionar datos de diferentes fuentes de información.

8.1 Descripción etapa 1

La metodología propuesta para el desarrollo de la etapa 1 se caracterizó por definir los parámetros iniciales y el manejo de datos que permitieron el desarrollo de las siguientes etapas, el planteamiento correcto y la secuencia de las actividades planteadas serán determinantes para lograr que los resultados esperados; por tal motivo se convierte en la etapa clave para lograr una construcción basada en la temporalidad y calidad de la información obtenida de fuentes primarias y secundarias (Figura 5).

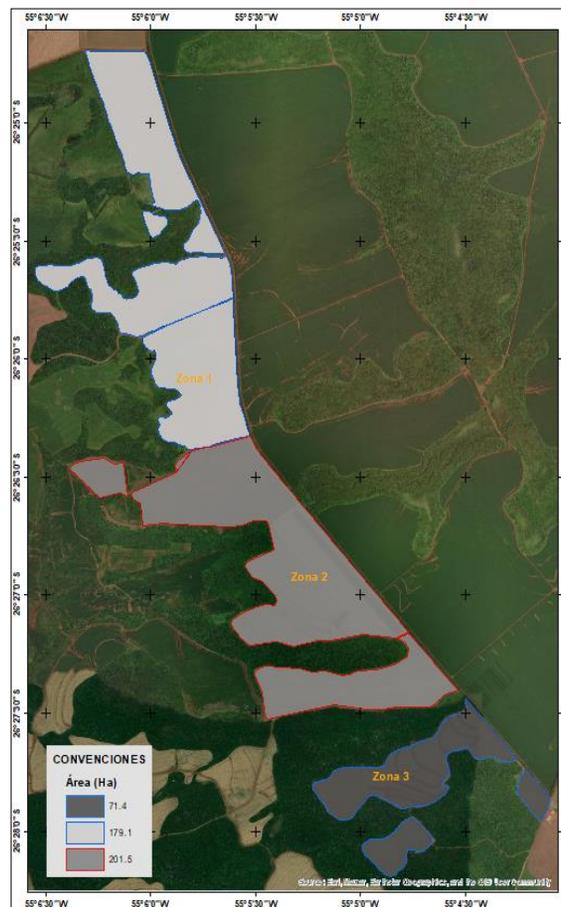
Figura 5.
Modelo lógico metodología



8.1.1 Selección del área de estudio

Para la investigación se seleccionó un área con potencial agrícola activo compuesta por tres sectores que presentan características similares, en la **¡Error! No se encuentra el origen de la referencia.** se puede apreciar el área de interés con sus tres zonas, las cuales tienen las siguientes áreas: Zona 1 (179.1 Ha), Zona 2 (201.5 Ha) y Zona 3 (71.4 Ha).

Figura 6.
Zonas área de estudio



Adicional, el interés en Paraguay por el manejo eficiente del cultivo de soja es altamente representativo, lo que permite que el área seleccionada tenga un alto valor.

A lo largo del tiempo diferentes estudios han calculado el impacto que genera la exportación del grano de soja y que aporta a la economía del país, es por ello por lo que todos aquellos estudios y mejoras que se puedan llegar a realizar para la optimizar la producción de soja tienen un alto apoyo de la industria local los cuales están abiertos a aportar información y captura de datos en campo de llegar a ser necesario.

Otro factor determinante para la selección fue el tipo de suelo, ya que al sur del Paraguay, Rasche et al. (2020, p. 14) consideran que al ser suelos de tendencia arcillosa el desarrollo radicular de las plantas de soja se puede ver afectado, de igual forma la concentración de nutrientes también puede variar llevando a cabo que las producciones bajen, es por lo anterior que definir un área con estas características aumenta el interés sobre los resultados de los mapas de concentración de nutrientes y como estos pueden llegar a potencializar la fertilización por aspersión variable.

8.1.2 Identificación de área de estudio con tradición de uso agrícola en soja

De acuerdo con los históricos manejados por el personal de campo y los registros tomados para cada zona, se concluye que, en un periodo de cinco años, el cultivo predominante es la soja y maíz el cultivo de rotación. El histórico de datos de análisis foliares y de suelo dejan evidenciar que esta parcela, dividida en tres zonas, fue explotada agrícolamente con los dos cultivos mencionados.

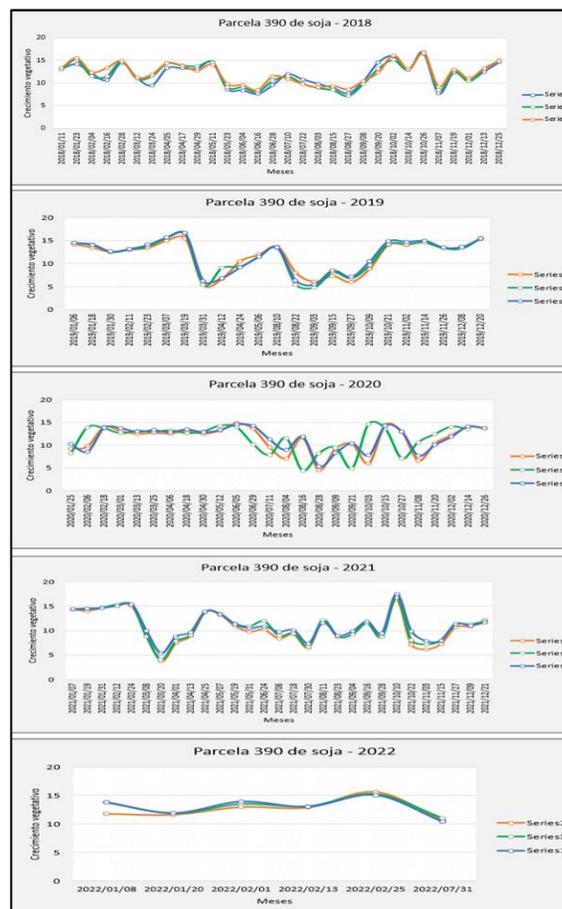
8.1.3 Selección de imágenes satelitales para consultas temporales

Para realizar la selección de las imágenes se validó la dinámica del crecimiento vegetativo en secuencias de tiempo, mediante un análisis multitemporal empleando imágenes satelitales de Sentinel 2 y la variable de crecimiento vegetativo se logra establecer una relación entre los datos, de cuyo cruce se evidencia la dinámica similar de los tres sectores de la parcela. Los ciclos vegetativos de la soja, donde las parcelas tuvieron valores muy bajos de desarrollo vegetativo, permitieron definir los momentos

óptimos para tomar las muestras de suelo desnudo y que coincidan la imagen de Sentinel 2.

Las imágenes seleccionadas deben cumplir con el porcentaje de nubosidad, si supera el 20% probablemente afecte el área de estudio, lo que alterará los resultados al momento de ejecutar el modelo. Para realizar el proceso de escoger las imágenes de Sentinel 2 en el tiempo indicado se emplean los gráficos diseñados, correspondientes a la parcela 390 de soja, durante el periodo 01/2018 a 07/2022 (Figura 7).

Figura 7.
Secuencia temporal de vigor vegetativo, con Sentinel 2, en el periodo 01/2018 a 07/2022



Con las secuencias de tiempo se logró identificar que durante los cinco años entre los meses de julio y octubre se produjeron valores muy bajos de crecimiento vegetativo lo que aumenta las probabilidades que para esos meses se puedan obtener imágenes de suelo desnudo, es muy importante lograr imágenes donde el suelo este sin cobertura

vegetal ya que los análisis se realizaran para identificar la fertilidad del suelo antes de cultivar, con presencia de vegetación estos valores se podrían ver afectados al extraer la información radiométrica de la imagen de Sentinel 2.

Los meses de presencia de no cultivo se muestran en la Tabla 3, que permite visualizar el procedimiento para la descarga de las imágenes, en la parcela 390, de referencia y que señalan el comportamiento del suelo. Lo ideal es observar patrones que se comporten similar durante diferentes periodos de tiempo: inicialmente se realizó una comparación visual del suelo desnudo y se identifican posibles zonas no homogéneas que puedan llegar a afectar el tratamiento de los datos. Los valores permiten apreciar con mayor detalle las fechas donde se tienen imágenes de suelo sin cobertura vegetal y cual banda representa mejor la información, siendo la banda 12 o SWIR, que se compone de un infrarrojo de onda corta, la que proporciona mejor calidad.

Tabla 3.

Parámetros de descarga de imágenes satelitales para la parcela 390 de soja, utilizando el sensor Sentinel-2 MSI

Fecha	Bandas	Cobertura	Nubes	TOA	BOA
24/07/2022				L1C	L2A
25/04/2022	12 -SWIR	Suelo desnudo	10%	L1C	L2A
20/04/2022				L1C	L2A
27/09/2021	Todas	Cultivo - Soja		L1C	L2A
09/07/2021				L1C	L2A
14/07/2021	12 -SWIR	Suelo desnudo	10%	L1C	L2A
24/07/2021				L1C	L2A
29/07/2021				L1C	L2A
21/12/2020	Todas	Cultivo - Soja		L1C	L2A
02/10/2020				L1C	L2A
07/10/2020	12 -SWIR	Suelo desnudo	10%	L1C	L2A
17/10/2020				L1C	L2A
27/09/2020				L1C	L2A
07/12/2019	Todas	Cultivo - Soja		L1C	L2A
28/09/2019				L1C	L2A
23/09/2019			10%	L1C	L2A
03/09/2019				L1C	L2A
29/08/2019				L1C	L2A
27/12/2018	Todas	Cultivo - Soja		L1C	L2A
22/11/2018				L1C	L2A
28/10/2018	12 -SWIR	Suelo desnudo	10%	L1C	L2A
26/05/2018				L1C	L2A
21/05/2018				L1C	L2A

El análisis temporal arrojó bastante información, que se validó bajo filtros espectrales, combinando diferentes bandas para discriminar el suelo de la vegetación y cuerpos de agua desde Sentinel hub (plataforma que permite la descarga de forma gratuita de las imágenes) aplicando filtros predeterminados, como *barren soil* (BSI), uno de los más usados para discriminar suelo desnudo, que emplea la combinación de bandas: $BSI = ((SWIR2 + R) - (NIR + B)) / ((SWIR2 + R) + (NIR + B))$, donde *red* (R) banda roja, *blue* (B) banda azul, *near infrared* (NIR) y *short wave infrared* (SWIR).

Al emplear la banda SWIR que hace parte del espectro electromagnético del infrarrojo permitió obtener información acerca de la humedad del suelo, índice que también permite realizar una aproximación estimada de cuál sería el tiempo óptimo en el cual la humedad del suelo no afecte los valores de fertilidad, esta banda también permite diferenciar el suelo desnudo en tonalidades pardas que combinadas con otras bandas permiten que esta tonalidad parda se visualice en tonos rojos y la vegetación en tonos verde. En la Figura 8 se pueden apreciar las zonas de suelo sin vegetación y las que contienen algún tipo de cultivo o bosque.

Al consolidar las posibles fechas de toma de las imágenes por el sensor satelital se procede a comparar las imágenes de los cinco años seleccionados, esto con el objetivo de apreciar un comportamiento homogéneo que durante este periodo de tiempo y evidenciar si por algún motivo hay cambios abruptos que afecten los resultados finales de la investigación.

En la recopilación de las imágenes que se encuentran en la Figura 8 se pueden evidenciar una serie de pequeñas zonas que se muestran de un color más oscuro, lo que permite ratificar que pueden ser causadas por erosión del suelo o causadas por caminos generados por la maquinaria que encargada de realizar la siembra, fertilización o riego, para verificar a que se deben esos cambios en el suelo se deberá tener una referencia de las alturas de la parcela o en su defecto un apoyo en una imagen de mayor resolución obtenida con un dron, lo que permitirá obtener mayor detalle para poder discriminar estas zonas con mayor precisión.

Figura 8.
Resultado índice BSI para suelo desnudo

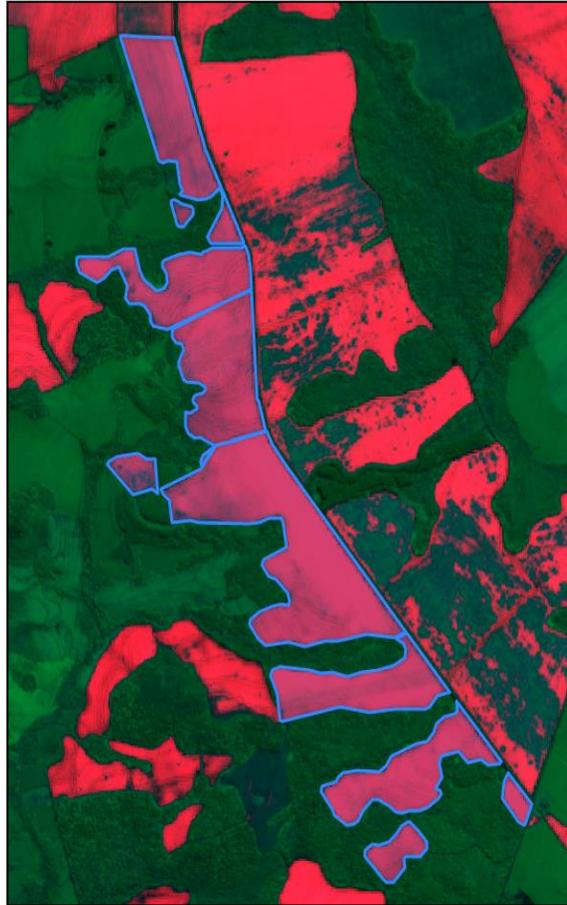
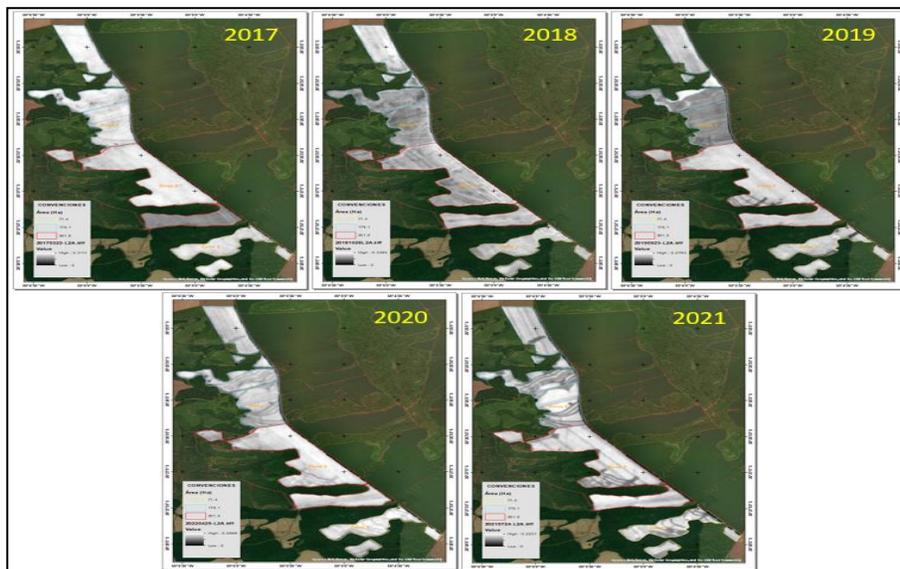


Figura 9.
Comparación temporal imágenes de suelo desnudo.



En la comparación, se logró apreciar que el comportamiento del suelo en los tres primeros años varía con respecto a los dos últimos, debido a que en la selección de las imágenes debe tenerse en cuenta el comportamiento de la humedad, ya que puede afectar, por ejemplo, que la zona 3 del año 2019 presente una tonalidad más oscura referente a los otros años, con valores ráster entre 0 y 0.27 con relación a 2017 y 2018 que se ubican en valores ráster próximos a 0 y 0.31.

Se puede observar que las imágenes de 2020 y 2021 presentan tonalidades similares, debido a que se tuvieron dos factores importantes en cuenta: primero, que coincidieron los meses, en este caso julio, por lo que temporalmente el comportamiento de suelo desnudo es homogéneo al paso de un año. La imagen seleccionada se emplea para programar la toma de muestras de suelo en campo, lo cual se convertirá en información orientadora para el personal de campo, pues al ser una imagen cruda que solo muestra el suelo desnudo, y sus concentraciones livianos y pesados con un proceso intermedio, se logra obtener el mapa de ambientes de elementos físicos.

El segundo factor es que los porcentajes de arcillas y arenas se acerquen lo más posible a la realidad del campo, haciendo los cálculos de la información ráster sobre una imagen de suelo desnudo de la banda 12 de Sentinel 2 en tempero (suelo oreado después de la lluvia), que lo cumplen las imágenes de 2020 y 2021, con similitud en los rangos de valor y tonalidades. Si se emplea una imagen donde el suelo desnudo se encuentre muy seco o estío se sobreestimarán el porcentaje de arenas y arcillas, y sucederá lo contrario si está excesivamente húmedo. La tendencia en la distribución de diferentes tipos de suelo en la parcela se podrá mantener, por tanto, si se requiere mucha precisión en la selección de la imagen, cumpliendo los parámetros anteriormente descritos, la capa generada permite localizar diferentes zonas de suelo presentes en el área de estudio, y redundar en un muestreo de suelo dirigido con mayor determinación.

8.1.4 Corrección radiométrica de la imagen satelital y ajuste con modelo Kriging

Seleccionada la imagen, en este caso corresponde a la del mes de julio de 2021, se realizó un ajuste radiométrico a la imagen, para garantizar la calidad de los datos y que

no se vean afectados por factores externos que distorsionan los datos, hay dos formas de obtener una imagen corregida:

- Un proceso manual en software, según Padró (2019), necesario para corregir radiométricamente las imágenes de satélite y tener datos más reales y aproximados a los del nivel de la tierra, sin interferencias por factores como la atmósfera y tropósfera.

- La segunda opción es la que ofrece directamente Sentinel en su portal de descarga, el cual permite que el usuario pueda descargar la imagen con corrección, existen dos tipos de imagen: - las L1C, que se encuentran ortorrectificadas con niveles de reflectancia por encima de la atmósfera, que se denomina TOA, por sus siglas en inglés *Top Of Atmosphere*, aunque tiene una corrección es aún muy básica, por lo que se recomienda trabajar con el siguiente nivel de ajuste, - las imágenes L2A, también se encuentra ortorrectificadas pero, a diferencia de las L1C, los niveles de reflectancia se encuentran por debajo de la atmósfera, que se denomina BOA, por sus siglas en inglés *Bottom Of Atmosphere*, más recomendada para descargar por sus datos más limpios, ocasionando menos ambigüedades en la información disponible por cada pixel.

En la Figura 10 se observa la diferencia entre una imagen LC1 y LC2, donde las tonalidades mejoran mucho con una imagen LA2, corrección óptima para garantizar buenos resultados. Una vez seleccionada la imagen se realizó un remuestreo de los pixeles para mejorar más los datos y obtener el mapa de orientativo para localizar el muestreo de suelo dirigido. Para ello se requiere realizar un proceso geoestadístico Kriging/cokriging para interpolar los datos de la imagen y ajustar los rangos de suelo desnudo. Este proceso, al ser un método que emplea modelos matemáticos y estadísticos, permite correlacionar los datos de manera precisa y confiable.

Para iniciar con el ajuste de del píxel se procede a generar el semivariograma de la imagen (Figura 11). Como se puede observar en el semivariograma generado por el modelo de Kriging, el comportamiento de los datos de la imagen se representa como un conjunto de puntos que se distribuyen muy cerca de la línea de tendencia central, lo que indica que se tiene una alta correlación de los datos, adicional se tienen datos predichos

en función de la distancia de estos, que son el grupo de puntos de color rojo. Para el modelo de Kriging el semivariograma es una herramienta muy valiosa ya que permite tener una visualización clara de las varianzas altas para grandes distancias entre los datos y varianzas para datos muy próximos entre sí, permitiendo de esta forma apreciar de una mejor manera el comportamiento y correlación de los datos.

Figura 10.
Comparación de imágenes Sentinel 2 L2A y L1C

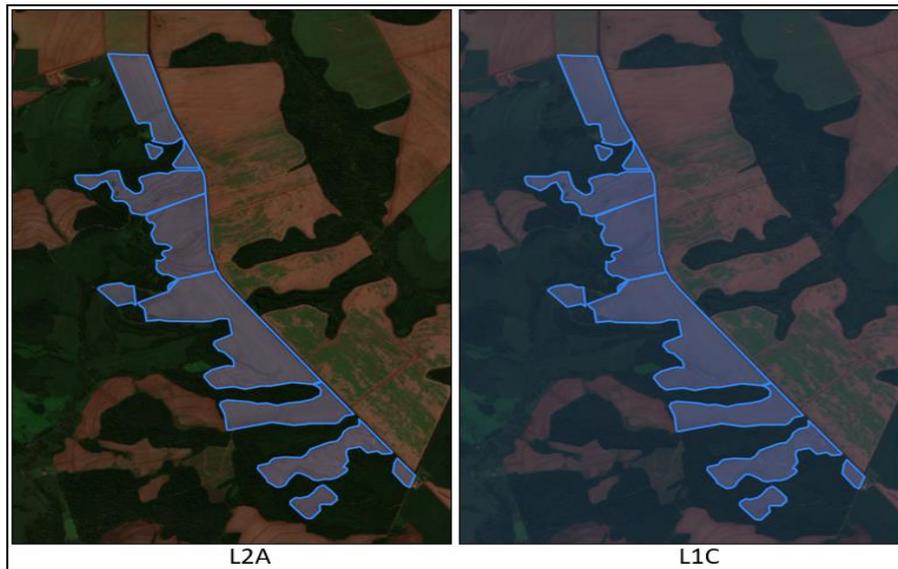
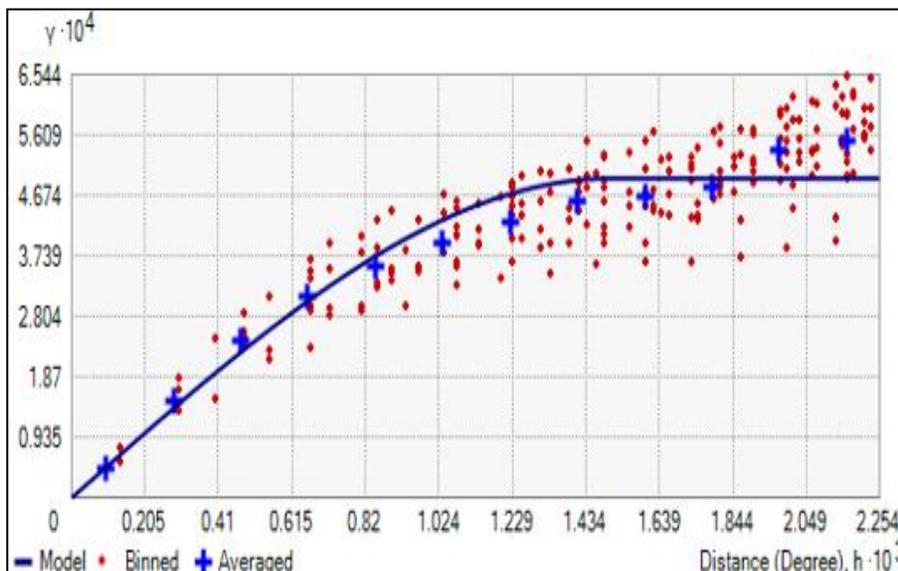
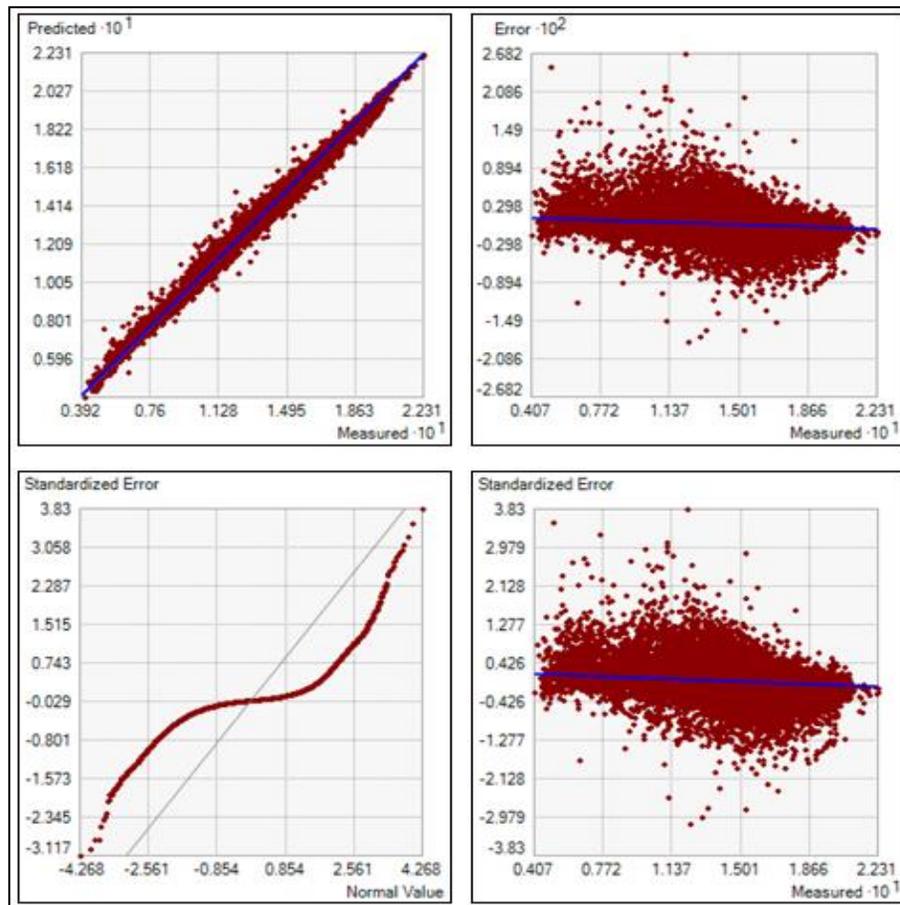


Figura 11.
Semivariograma imagen Sentinel-2



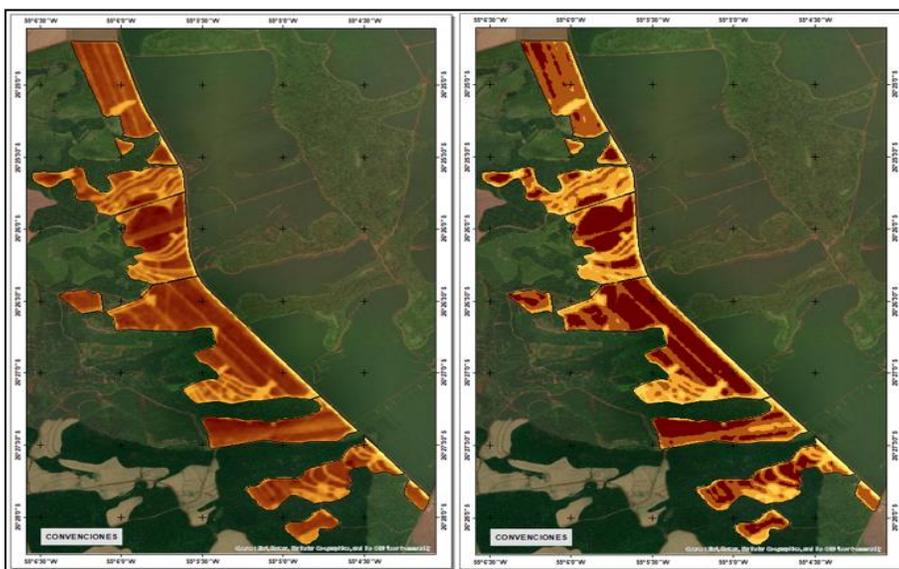
Una vez se tiene el modelo ejecutado se generó la validación cruzada, la cual permitió evaluar la precisión del modelo mediante errores de media y la raíz cuadrática media, con esta validación se puede apreciar el estimado y el comportamiento del conjunto de datos, como se puede apreciar en la **¡Error! No se encuentra el origen de la referencia..** La validación mostró que la mayoría de los datos de predicción tienen una buena respuesta, al estar muy cerca de la línea de tendencia central, un buen indicativo de que el modelo no presenta problemas en la interpolación. Por el lado de los errores se ven datos dispersos, pero no representativos para el conjunto de datos, ya que los valores que tienden a alejarse del grupo mayoritario corresponden a los bordes de la imagen o se alejan del área de interés, por lo que no afecta de forma determinante el resultado final.

Figura 12.
Resultado validación cruzada de modelo de Kriging



En la Figura 13 se puede apreciar el resultado final de la imagen ajustada y con los rangos definidos, en la comparación se evidencia la mejora después de aplicar el modelo de Kriging para mejorar la calidad del píxel. El resultado del primer proceso de la imagen cruda ya muestra que la imagen de la derecha permite un mayor detalle para la distribución del suelo en sus concentraciones, ahora, con este nuevo mapa, se puede diseñar la distribución de puntos para el muestreo de suelo en campo.

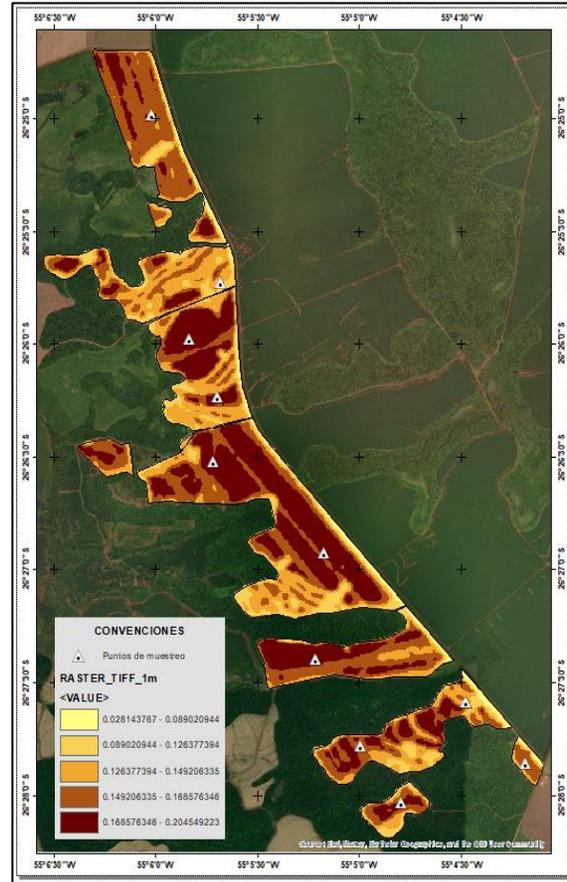
Figura 13.
Comparación de imágenes con ajuste de modelo de Kriging



8.1.5 Definición de puntos geolocalizados para toma de muestras en campo

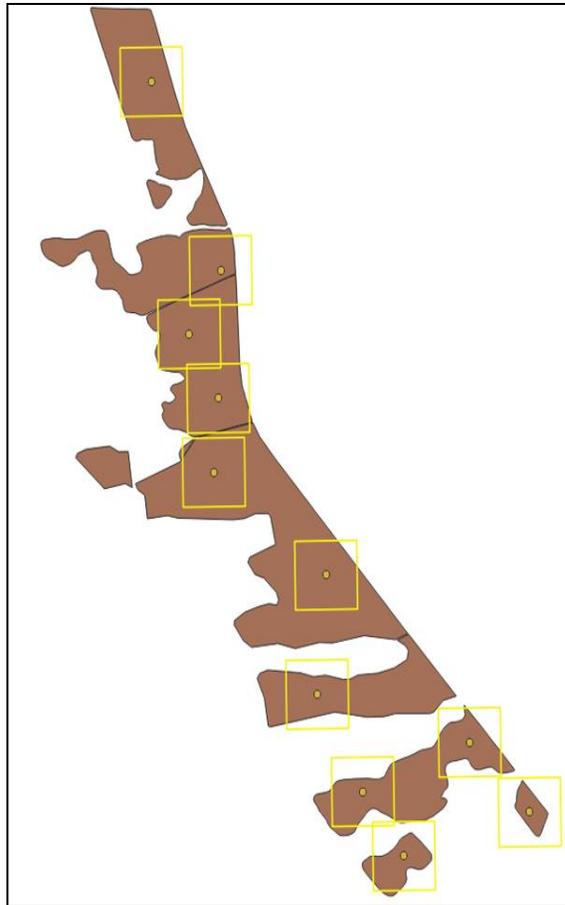
Para definir los puntos de muestreo, es recomendable definir una cantidad de puntos que represente la variedad de la parcela, entre más puntos se puedan tomar en campo los resultados serán mucho mejor, como se observa en la Figura 14, se estima que con mínimo cinco puntos, el modelo de interpolación podrá ajustar los valores de manera confiable y precisa.

Figura 14.
Distribución de puntos de muestreo dirigido



Las muestras se distribuyeron de manera que se cubra la mayor superficie posible dentro del área de interés, así la interpolación tendrá mejores resultados, para manejar unos estándares de calidad y basados en la información suministrada por el laboratorio que analiza las muestras la superficie óptima para el muestreo es representativa para 20 Ha por cada punto, como se puede observar en la Figura 15, sin embargo, lo que se encuentre fuera de ese rango aunque aporte datos de interés, no tendrán la misma precisión al generar los datos estimados por el modelo de interpolación.

Figura 15.
Representación de cobertura óptima por muestra



8.1.6 Análisis de laboratorio del muestreo dirigido

Ya definidas las acciones mencionadas, se puede sustentar que la parte inicial de la metodología es el hilo conductor que deriva en la secuencia lógica metodológica. En el Anexo B se evidencia el resultado de las muestras de laboratorio con las concentraciones para cada uno de los nutrientes, la captura en campo de la muestra se realizó a 20 cm de profundidad y manteniendo todos los protocolos por el personal de campo, donde se garantizó que las muestras no tuvieran cambios significativos por temperatura y humedad, no presenten alteraciones y sean lo más confiables posible.

8.2 Descripción etapa 2

En la etapa 2 se emplearon los datos recolectados en la etapa 1, para definir como está constituida la parte física del suelo y su distribución dentro del área de interés. Ya con los resultados obtenidos de las muestras de suelo recolectadas en campo y empleando el método regresión, obtener la distribución promedio del porcentaje de arenas y arcillas, dentro del área de estudio.

Lo primero que se debe realizar es encontrar la relación de cada una de las muestras de arena y arcilla con los valores de la imagen de suelo desnudo de Sentinel 2, con esos valores se puede establecer la relación entre la imagen y los datos de laboratorio (Tabla 4).

Tabla 4.

Valores raster para cada punto de muestreo de suelo de arcilla, limo y arena

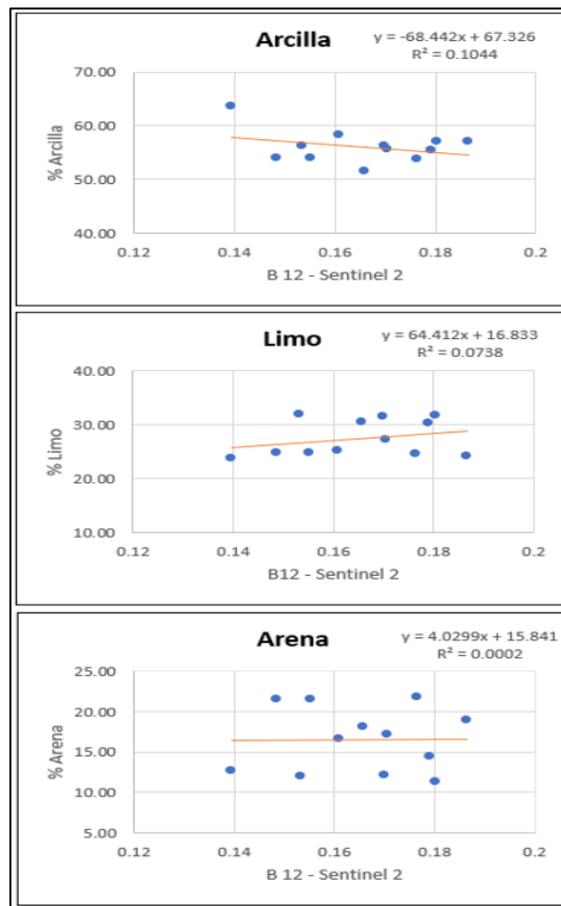
ID	Latitud	Longitud	Muestra	Arena	Arcilla	Banda 12
1	-26.4629851	-55.0831707	102609	18.10	51.40	0.165809169
2	-26.4672096	-55.0798450	102604	17.20	55.50	0.17059873
3	-26.4597493	-55.0745419	102611	21.45	53.90	0.148653612
4	-26.4643333	-55.0696882	102607	16.60	58.25	0.160912082
5	-26.4164253	-55.1002485	102627	11.95	56.10	0.153390735
6	-26.4288087	-55.0946584	102622	12.70	63.60	0.139560208
7	-26.4329641	-55.0971925	102619	18.95	56.95	0.186642185
8	-26.4371886	-55.0948555	102617	14.45	55.35	0.179172263
9	-26.4420423	-55.0952150	102616	12.15	56.25	0.170076847
10	-26.4487835	-55.0861368	102615	11.30	57.05	0.180393368
11	-26.4566033	-55.0868559	102612	21.80	53.65	0.1765908
12	-26.4597493	-55.0745419	102612	21.45	53.9	0.155399993

Encontrando la relación de los datos a emplear en la regresión, según Bousbih et al. (2019), las bandas SWIR tienen una alta capacidad para estimar contenidos de arcilla y arena, teniendo en cuenta la humedad del suelo, pero se encuentra una alta relación de los elementos físicos del suelo, en la Figura 16 se muestra cálculo de la regresión y su respectivo digrama de dispersión.

La correlación de las arcillas y el limo con la banda 12 es buena, ya que sus valores están muy cerca de la línea de tendencia central, lo que no sucede con la arena, aunque los datos se encuentran algo dispersos, no son descartables para generar el mapa de textura, el cual necesita de la combinación de la arcilla y la arena para definir la composición del tipo de textura, basado en los parámetros establecidos por la USDA.

Figura 16.

Correlación de datos de la banda 12 de suelo desnudo y resultados de muestras de laboratorio para arcilla, limo y arena



La ecuación de la recta empleada para observar la correlación entre los valores de B12 y cada parámetro de las muestras se realiza mediante $Y=n*x + n1$ (los valores que tomará X serán los de la imagen), lo cual permite tener la recta de regresión que después se emplea dentro de la calculadora *raster* para determinar los valores en el área de estudio.

Luego de encontrar la correlación de los datos y definir la ecuación de la recta para cada uno de los elementos físicos, empleando algebra de mapas se generaron las nuevas imágenes para cada elemento, como se puede apreciar en la Figura 17. De acuerdo con USDA, para generar el mapa de textura final se deben correlacionar las dos imágenes de arcilla y arena, para ello se emplea la herramienta *SoilTexture*, que se encarga de realizar el proceso automático y retornar un archivo .shp con la información del tipo de textura. Este proceso puede tardar bastante tiempo, por lo que se requiere de un buen equipo que soporte los datos.

Figura 17.

Resultado del algebra de mapas empleando la ecuación de la recta, distribución de arcilla y arena



El mapa de textura obtenido representa un tipo de parcela con suelo arcilloso código 1 para ambiente USDA, con un alto contenido de retención de fertilizante, alta compactación, alta probabilidad de encharcamiento y muy alto potencial productivo. El consolidado del resultado del *SoilTexture* se puede consultar en el Anexo C y la Figura 18 presenta la catalogación USDA para textura de suelo.

Figura 18.
Catalogación USDA para textura de suelo y mapa de ambientes (USDA, 2022)

Ambiente USDA	Ambiente	Textura	Capacidad de campo (%)	Punto marchitez permanente (%)	Retención de agua (mm agua)	Conductividad hidráulica (mm/h)	Retención de fertilizante	Compactación	Encharcamiento	Potencial productivo	Color
	ambiente	textura	cc	pmp	cra	infiltr	reten_fert	compact	encharc	pot_prod	color
10	1	sand	10	5	50	120	muy baja	muy baja	muy baja	muy baja	254,254,128
11	2	loamy_sand	15	10	70	90	muy baja	muy baja	muy baja	muy baja	254,241,115
12	3	sandy loam type a	20	15	90	40	baja	baja	baja	media	252,224,98
12 b	4	sandy loam type b	25	20	110	60	baja-media	baja	baja	media-alta	250,209,85
5	5	sandy clay loam	30	20	120	10	media	media	media	alta	247,195,72
9	6	loam	30	15	130	20	media-alta	media	media	alta	245,180,59
6	7	clay loam	35	20	140	5	alta	alta	alta	muy alta	242,167,46
1	8	clay	40	30	130	1	muy alta	alta	alta	muy alta	219,137,37
4	9	sandy clay	35	25	110	1	muy alta	muy alta	muy alta	variable	196,109,27
2	10	silty clay	40	30	140	5	muy alta	muy alta	muy alta	variable	173,83,19
3	11	silty clay loam	40	20	170	5	excesivo	excesivo	excesivo	variable	150,58,12
8	12	silty loam	30	10	200	15	excesivo	excesivo	excesivo	variable	128,35,6
7	13	silt	30	5	250	20	excesivo	excesivo	excesivo	variable	107,6,1

Determinar el tipo de ambiente de suelo es muy importante debido a que se pueden considerar los siguientes aspectos:

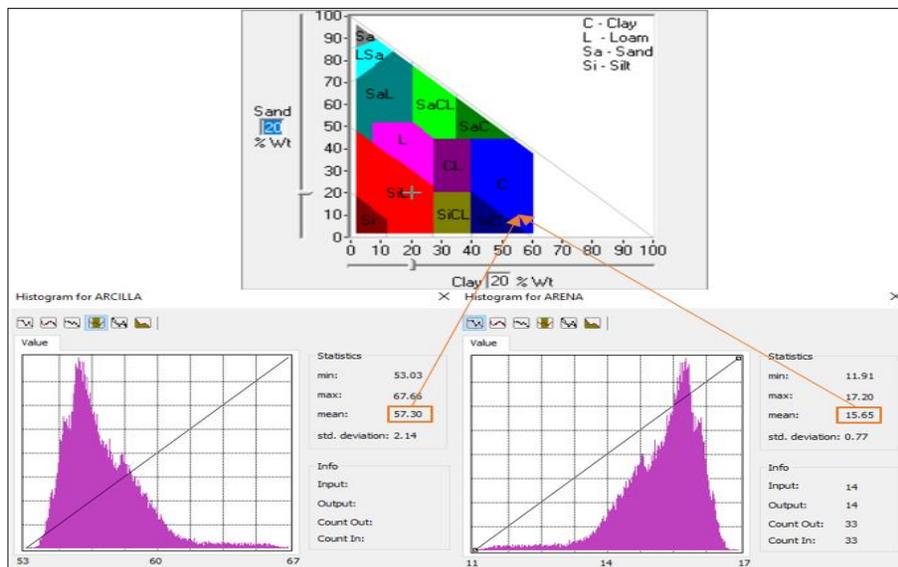
- Conocer de mejor manera el comportamiento del agua y los nutrientes en el suelo.
- Poder detectar posibles problemas de compactación, encharcamiento.
- Tener una visión más clara donde se pueden presentar deficiencias nutricionales.
- Comprender de mejor forma donde es más y menos productivo el suelo, lo que permite programar siembra y fertilización con tasas variables.
- Para saber dónde tomar muestras de suelo y que estas sean representativas en toda la superficie del cultivo, logrando obtener un mayor conocimiento de los nutrientes distribuidos en el suelo con menos cantidad de muestras, lo que se ve reflejado en la disminución de costos en los análisis de laboratorio.
- Generar una mejor planificación para fertilizaciones de fondo.
- Comprender mejor las variaciones de mediciones de NDVI.
- Ubicación de cultivos.
- Diseñar lo que son sistemas de riego de manera adecuada, agrupando los suelos más parecidos en sectores.

- Para detectar donde se pueden tener mayor concentración de enfermedades de suelo derivadas por exceso de humedad.

El mapa generado en función de la correlación entre los datos de la banda 12 SWIR2 de Sentinel 2 y las muestras de suelo, permitieron consolidar información más precisa para que los resultados que se esperan en la etapa 3 sean validados en un porcentaje de aceptación importante.

Todo lo anterior permite de alguna manera ambientar los distintos tipos de suelos en función de la textura, que influye en la dinámica de los parámetros químicos y contribuye en gran medida en que los resultados de distribución de nutrientes sean más efectivos. Para validar la información del resultado de USDA se generó el histograma para la imagen de arcilla y arena, y con los valores medios se ubicó sobre una calculadora de textura de suelo, lo cual arroja el mismo resultado, un ambiente arcilloso como se evidencia en la Figura 19.

Figura 19.
Comparación del histograma con calculadora de suelo



8.3 Descripción etapa 3

Acá confluyen los resultados obtenidos de las etapas anteriores, empleando el método de interpolación IDW, al cual se le realizó una validación cruzada (*Leave one out cross validation*) para medir el error de los valores interpolados y usar esta información para perfeccionar la tarea de interpolación. Se muestran algunos de los procesos para llegar al resultado final, los mapas de fertilidad por nutriente, ya con la información de textura y fertilidad se realizan recomendaciones agronómicas más acertadas y validadas con información confiable.

Como en la etapa 2, se relacionan los datos con la banda 12 Sentinel, solo para este caso en particular se correlacionan los datos de fertilidad, y así tratar de evidenciar el comportamiento del nutriente con los valores de la imagen, un buen desarrollo de esta etapa brinda información determinante para lograr los objetivos del proyecto. Para el desarrollo de la etapa 3, se consideran cinco aspectos, que se amplían a continuación.

8.3.1 Parámetros para determinar materia orgánica (MO)

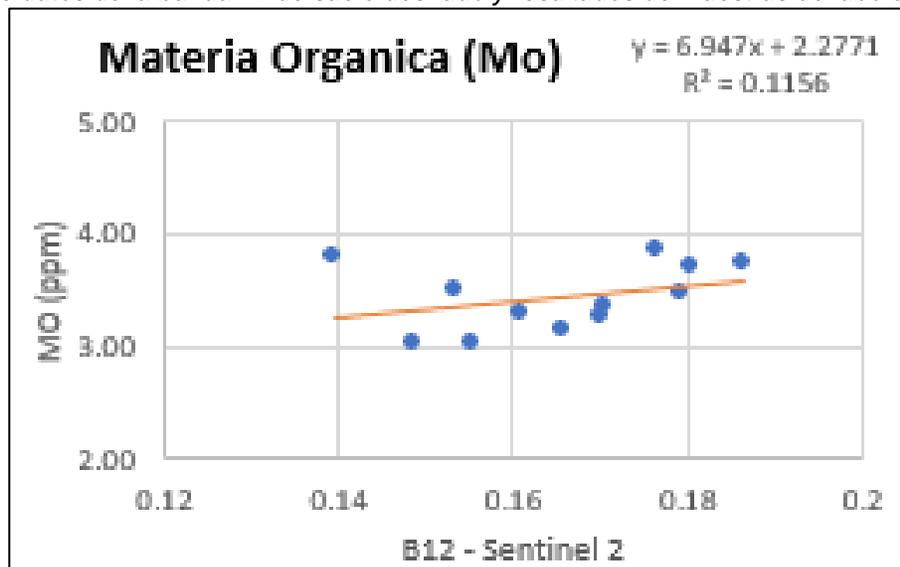
El componente biológico del suelo contribuye directamente sobre otros elementos potencializando sus propiedades, siendo, de acuerdo con Núñez et al. (2021, p. 372), la materia orgánica una de las propiedades bioquímicas con mayor importancia en el suelo, ya que, entre otros beneficios, “aumenta la capacidad de intercambio catiónico, contribuye con la neutralización del pH, favorece la retención de humedad, mejora la estabilidad de suelos arcillosos (...), fomenta la actividad microbológica, favorece la liberación de nutrientes”. Por ello, debe encontrarse su relación con la imagen de la banda 12, como se presentan en la Tabla 5 (relación de los datos de laboratorio con los valores *raster* extraídos en la imagen) y en la Figura 20 (correlación de los datos con su respectivo diagrama).

Tabla 5.
Valores raster asociados para cada muestra de MO

ID	Latitud	Longitud	Muestra	MO	Banda 12
1	-26.4629851	-55.08317072	102609	3.14	0.165809169
2	-26.46720961	-55.07984505	102604	3.36	0.17059873
3	-26.45974931	-55.07454194	102611	3.03	0.148653612
4	-26.46433335	-55.06968824	102607	3.28	0.160912082
5	-26.4164256	-55.10024853	102627	3.50	0.153390735
6	-26.42880879	-55.09465843	102622	3.79	0.139560208
7	-26.43296411	-55.0971925	102619	3.74	0.186642185
8	-26.43718862	-55.09485554	102617	3.47	0.179172263
9	-26.44204231	-55.09521507	102616	3.25	0.170076847
10	-26.44878356	-55.08613687	102615	3.69	0.180393368
11	-26.45660339	-55.08685594	102612	3.85	0.1765908
12	-26.45974931	-55.07454194	102612	3.03	0.155399993

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.

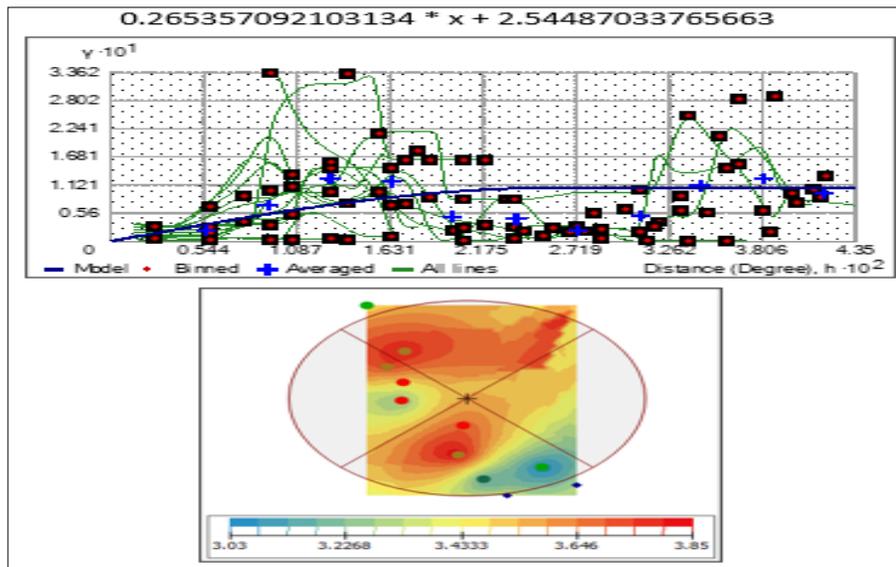
Figura 20.
Correlación de datos de la banda 12 de suelo desnudo y resultados de muestras de laboratorio para MO



La correlación de los datos es buena, lo que indica que el mapa resultante tiene un alto grado de confiabilidad. Para mejorar los datos, se ajusta el modelo de

interpolación empleando el semivariograma de Figura 21 y la validación cruzada, como aprecia en el Anexo D.

Figura 21.
Semivariograma para MO



8.3.2 Parámetros para determinar de pH de suelo

El pH influye en la composición ácida, neutra o alcalina del suelo. Existen varios métodos para determinarlo, como equipos especializados que dan valores de pH o por medio de muestreo de suelo, para Ferraz et al., (2019, 290), la calidad de la información para pH dependerá de la distribución espacial del muestreo, y el empleo de modelos esféricos en la mejora de los semivariogramas. En la Tabla 6 se observa la correspondencia de datos de pH con los datos *raster* de la banda 12 y en el Anexo E, los resultados obtenidos de la validación cruzada.

Tabla 6.
Valores *raster* asociados para cada muestra de pH

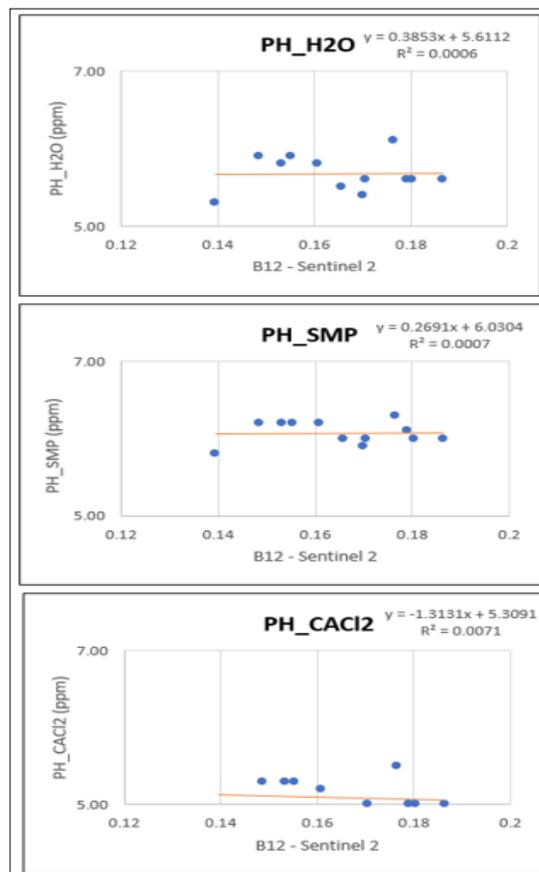
ID	Latitud	Longitud	Muestra	pH _{H₂O}	pH _{SMP}	pH _{CaCl₂}	Banda 12
1	-26.4629851	-55.08317072	102609	5.50	6.00	4.90	0.165809169
2	-26.46720961	-55.07984505	102604	5.60	6.00	5.00	0.17059873
3	-26.45974931	-55.07454194	102611	5.90	6.20	5.30	0.148653612
4	-26.46433335	-55.06968824	102607	5.80	6.20	5.20	0.160912082
5	-26.4164256	-55.10024853	102627	5.80	6.20	5.30	0.153390735
6	-26.42880879	-55.09465843	102622	5.30	5.80	4.80	0.139560208

ID	Latitud	Longitud	Muestra	pH_H ₂ O	pH_SMP	pH_CaCl ₂	Banda 12
7	-26.43296411	-55.0971925	102619	5.60	6.00	5.00	0.186642185
8	-26.43718862	-55.09485554	102617	5.60	6.10	5.00	0.179172263
9	-26.44204231	-55.09521507	102616	5.40	5.90	4.80	0.170076847
10	-26.44878356	-55.08613687	102615	5.60	6.00	5.00	0.180393368
11	-26.45660339	-55.08685594	102612	6.10	6.30	5.50	0.1765908
12	-26.45974931	-55.07454194	102612	5.90	6.20	5.30	0.155399993

Una primera aproximación permite observar que no se encuentran datos distantes, pero se tiene que corroborar con la generación del diagrama de dispersión y ajuste a la ecuación de la recta para validar su tendencia y correlación. En la Tabla 6 se pueden apreciar tres tipos de pH, el pH_H₂O que corresponde al pH en agua, el pH_SMP que tiene una alta relación con la acidez potencial de los suelos y el pH_CaCl₂ asociado con la concentración efectiva de iones. En la Figura 22 se presenta la correlación por el proceso de regresión lineal.

Figura 22.

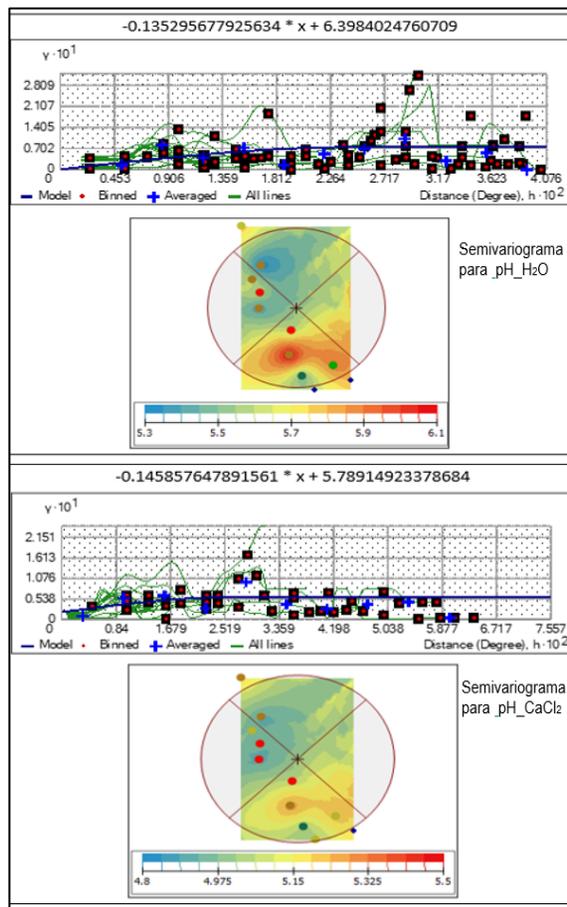
Correlación de datos de la banda 12 de suelo desnudo y resultados de muestras de laboratorio para pH



La correlación de pH con la imagen se comporta de manera lineal, o sea que es baja, por lo que se deben ajustar parámetros para que en la validación cruzada el modelo de interpolación logre mejorarla y conseguir un mapa óptimo. En la Figura 23 se presentan los resultados de los semivariogramas para pH_{H₂O} y pH_{CaCl₂}.

Figura 23.

Semivariogramas para pH_{H₂O} y pH_{CaCl₂}



8.3.3 Parámetros para determinar CIC

La capacidad de intercambio catiónico (CIC), por la retención e intercambio de nutrientes, favorece particularmente al comportamiento de la fertilidad del suelo, como los demás elementos, la manera más fácil de conocer las concentraciones de CIC en el suelo es a través de muestras y análisis de laboratorio, pero una manera de potencializar la información de esas muestras, y lograr un panorama más amplio en relación con la

parcela, es por medio de la interacción de imágenes satelitales. Según Perret et al. (2019, p. 141), citando a varios autores, “la espectroradioscopia visible e infrarroja (Vis-NIR-SWIR) ha surgido como opción para caracterizar eficazmente varias propiedades del suelo como carbono orgánico, pH, textura, capacidad de intercambio catiónico, contenido de CaCO_3 , entre otros”. Para apreciar la relación y el comportamiento de los datos de las muestras de campo con la banda 12, en la Tabla 7 se encuentran los resultados de la extracción de la información *raster* para cada una de las muestras que contienen datos de CIC.

Tabla 7.
Valores raster asociados para muestras de CIC

ID	Latitud	Longitud	Muestra	CIC	Banda 12
1	-26.4629851	-55.08317072	102609	13.45	0.165809169
2	-26.46720961	-55.07984505	102604	13.91	0.17059873
3	-26.45974931	-55.07454194	102611	13.03	0.148653612
4	-26.46433335	-55.06968824	102607	12.71	0.160912082
5	-26.4164256	-55.10024853	102627	12.91	0.153390735
6	-26.42880879	-55.09465843	102622	12.29	0.139560208
7	-26.43296411	-55.0971925	102619	13.84	0.186642185
8	-26.43718862	-55.09485554	102617	12.89	0.179172263
9	-26.44204231	-55.09521507	102616	11.93	0.170076847
10	-26.44878356	-55.08613687	102615	12.70	0.180393368
11	-26.45660339	-55.08685594	102612	13.88	0.1765908
12	-26.45974931	-55.07454194	102612	13.03	0.155399993

Ahora, con los datos disponibles, se realizó la regresión para identificar que tan correlacionados están los datos. En la Figura 24 se encuentra el resultado del modelo de regresión y en la Figura 25, el resultado de semivariograma, mientras en el Anexo F el resultado de la validación. Puede evidenciarse que la correlación del CIC con los datos *raster* tienen un comportamiento particular, ya que algunas muestras se mantienen cerca de la línea de tendencia y otros se alejan, por lo que la correlación no es muy alta.

Figura 24.

Correlación de datos de la banda 12 de suelo desnudo y resultados de muestras de laboratorio para CIC

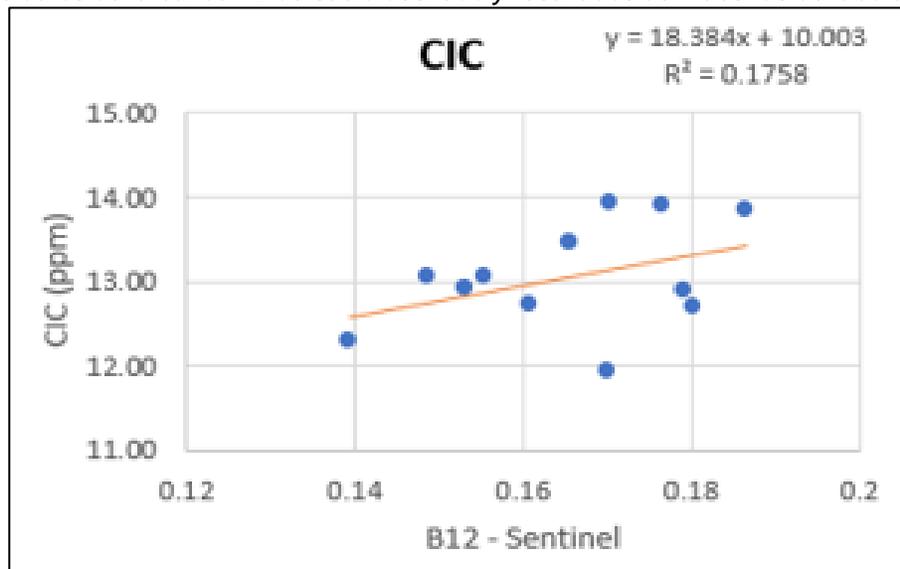
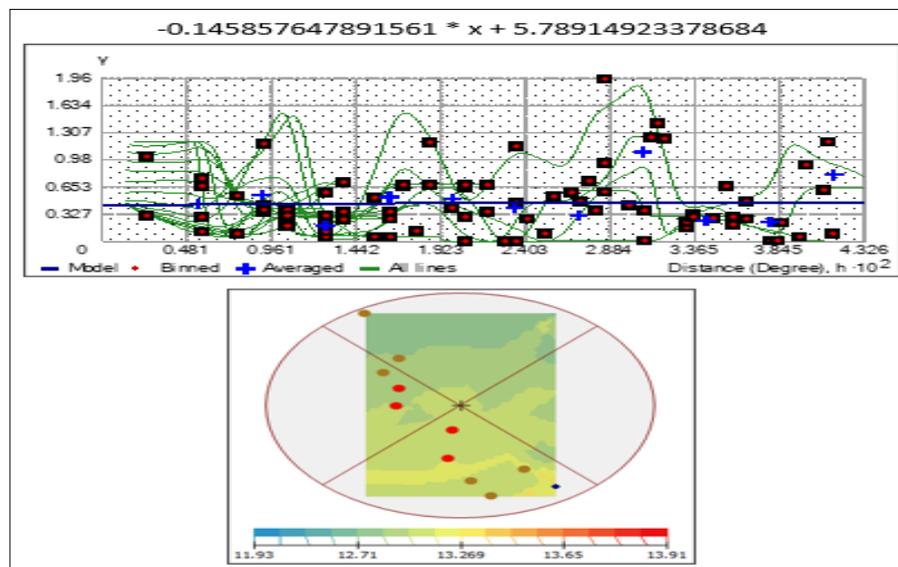


Figura 25.

Semivariograma para CIC



8.3.4 Parámetros para determinar macronutrientes: P y K

Los macronutrientes son elementos esenciales que se requieren en altas concentraciones, por lo que la mayor cantidad de recursos de los agricultores se dirigen a la fertilización con ellos. La importancia de los macronutrientes es resumida por Bautista et al. (2019, p. 229):

El nitrógeno (N) ha sido el elemento más estudiado en relación con la nutrición del huésped y la prevalencia de enfermedades, teniendo en cuenta su esencialidad en el crecimiento de las plantas, su limitada disponibilidad en el suelo y su efecto en el tamaño de las células y el espesor de la pared celular (Huber y Thompson, 2007, Walters y Bingham, 2007). Adicionalmente, juega un papel fundamental en la interacción planta - patógeno, debido a la movilidad del elemento durante el estrés biótico y abiótico como estrategia de defensa de la planta (Tavernier et al., 2007).

Por su parte, el fósforo (P) incrementa la resistencia de las plantas a diferentes enfermedades, cuando su concentración en los tejidos acelera la madurez y protege los órganos jóvenes; no obstante, los efectos sobre la severidad de enfermedades no son tan evidentes cuando se observa en cultivares susceptibles y/o moderadamente resistentes (Prabhu et al., 2007).

El potasio (K) es el soluto inorgánico más abundante en las células vegetales y está relacionado con la respuesta de la planta a estreses abióticos y bióticos (Zhou et al, 2014) y su deficiencia causa la reducción en la síntesis de proteínas, almidón y celulosa (compuestos de alto peso molecular) y por tanto, induce la acumulación de compuestos orgánicos de bajo peso molecular que pueden cubrir nutrientes requeridos por los microorganismos (Huber et al., 2012).

De acuerdo con el cultivo, los nutrientes principales o macronutrientes pueden ser controlados desde el aporte que hace al suelo o la concentración dispuesta en hoja, para el caso de la presente investigación no se tuvo en cuenta el nitrógeno (N), ya que para la soja, la evaluación de este macronutriente se realiza con análisis foliar, por lo que la disposición en suelo del mismo no es de alto interés.

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. Debe conocerse esos valores por muestra de suelo y relacionarse con la imagen de suelo desnudo representada en la banda 12, como se presenta en la Tabla 8.

Tabla 8.
Valores raster asociados a muestras de P y K

ID	Latitud	Longitud	Muestra	K	P	Banda 12
1	-26.4629851	-55.08317072	102609	0.49	21.05	0.165809169
2	-26.46720961	-55.07984505	102604	0.69	21.83	0.17059873
3	-26.45974931	-55.07454194	102611	0.57	20.84	0.148653612
4	-26.46433335	-55.06968824	102607	0.54	11.93	0.160912082
5	-26.4164256	-55.10024853	102627	0.67	10.73	0.153390735
6	-26.42880879	-55.09465843	102622	0.23	21.05	0.139560208
7	-26.43296411	-55.0971925	102619	0.24	10.66	0.186642185
8	-26.43718862	-55.09485554	102617	0.42	11.57	0.179172263
9	-26.44204231	-55.09521507	102616	0.40	13.55	0.170076847
10	-26.44878356	-55.08613687	102615	0.49	15.32	0.180393368
11	-26.45660339	-55.08685594	102612	0.66	21.97	0.1765908
12	-26.45974931	-55.07454194	102612	0.57	20.84	0.155399993

Los datos de la muestras tienen una variabilidad alta, debido a la distancia entre los mismos, se puede estimar que las concentraciones para estos dos nutrientes presentan zonas de déficit y excesos, aunque relación de las muestras con la banda 12 se encuentra visible en la Figura 26.

Determinar el comportamiento del potasio (K) y fósforo (P) permite proyectar la fertilización zonificada; por lo que la correlación geoestadística (Figura 27) facilitó el encuentro de patrones de optimización para la generación de mapas de fertilidad. En el Anexo G se encuentran los resultados de la convalidación del modelo geoestadístico de interpolación.

Figura 26.

Correlación de datos de la banda 12 de suelo desnudo y resultados de muestras de laboratorio para CIC

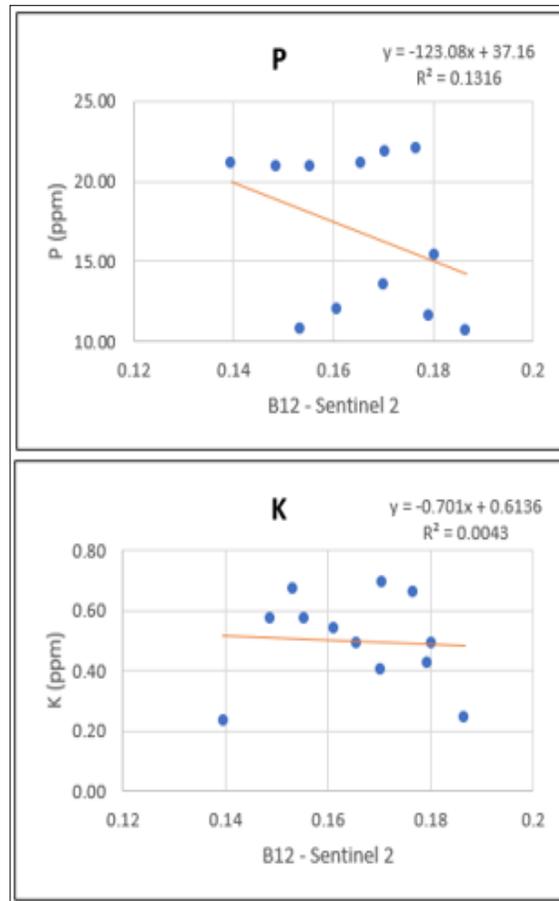
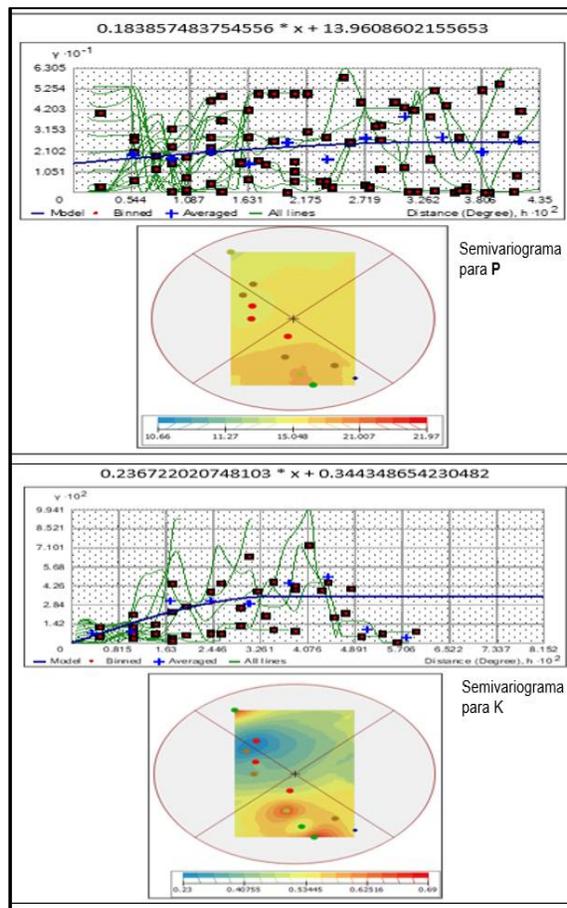


Figura 27.
Semivariogramas para P y K



8.3.5 Parámetros para determinar nutrientes secundarios: Ca, Mg, C, Fe, Mn, Zn, Cu, B y Al

Encontrar el valor *raster* para cada muestra es un proceso inicial, por lo que, para los elementos secundarios, su asociación se encuentra en las Tabla 9 y Tabla 10.

Tabla 9.
Valores asociados a muestras Ca, Mg, B, Al y C

ID	Latitud	Longitud	Muestra	Ca	Mg	B	Al	C	Banda 12
1	-26.4629851	-55.08317072	102609	6.83	1.17	0.56	0.03	18.27	0.165809169
2	-26.46720961	-55.07984505	102604	7.01	1.25	0.47	0.00	19.53	0.17059873
3	-26.45974931	-55.07454194	102611	7.06	1.12	0.53	0.00	17.63	0.148653612
4	-26.46433335	-55.06968824	102607	6.47	1.42	0.47	0.00	19.06	0.160912082
5	-26.4164256	-55.10024853	102627	7.02	0.94	0.53	0.00	20.32	0.153390735
6	-26.42880879	-55.09465843	102622	4.75	1.55	0.47	0.21	22.06	0.139560208
7	-26.43296411	-55.0971925	102619	7.34	1.30	0.59	0.00	21.74	0.186642185

8	-26.43718862	-55.09485554	102617	6.51	1.35	0.53	0.00	20.16	0.179172263
9	-26.44204231	-55.09521507	102616	5.01	1.17	0.47	0.09	18.90	0.170076847
10	-26.44878356	-55.08613687	102615	6.04	1.21	0.59	0.00	21.43	0.180393368
11	-26.45660339	-55.08685594	102612	7.73	1.52	0.64	0.00	22.38	0.1765908
12	-26.45974931	-55.07454194	102612	7.06	1.12	0.53	0	17.63	0.155399993

Tabla 10.

Valores raster asociados a muestras Fe, Mn, Cu y Zn

ID	Latitud	Longitud	Muestra	Fe	Mn	Cu	Zn	Banda 12
1	-26.4629851	-55.08317072	102609	14.57	136.07	11.31	10.29	0.165809169
2	-26.46720961	-55.07984505	102604	19.23	180.31	14.87	10.05	0.17059873
3	-26.45974931	-55.07454194	102611	17.85	157.11	10.06	8.08	0.148653612
4	-26.46433335	-55.06968824	102607	15.83	136.14	8.98	3.29	0.160912082
5	-26.4164256	-55.10024853	102627	13.54	162.92	8.03	4.17	0.153390735
6	-26.42880879	-55.09465843	102622	15.82	104.10	5.54	1.00	0.139560208
7	-26.43296411	-55.0971925	102619	16.34	127.34	7.97	1.71	0.186642185
8	-26.43718862	-55.09485554	102617	15.49	132.52	7.05	1.72	0.179172263
9	-26.44204231	-55.09521507	102616	22.33	145.61	7.21	1.99	0.170076847
10	-26.44878356	-55.08613687	102615	20.26	147.04	8.89	5.16	0.180393368
11	-26.45660339	-55.08685594	102612	18.70	151.44	13.61	10.01	0.1765908
12	-26.45974931	-55.07454194	102612	17.85	157.11	10.06	8.08	0.155399993

Los datos se correlacionan para determinar su comportamiento, mediante un diagrama de dispersión con su ecuación, viendo la variabilidad y la tendencia para cada uno de los elementos. Hay casos en que la relación es altamente positiva o negativa, dependiendo el comportamiento de los elementos frente a la información suministrada por la banda 12 de Sentinel 2 (Figura 28 y Figura 29).

Figura 28.

Correlación de datos de la banda 12 de suelo desnudo y resultados de muestras de laboratorio para Ca, Mg, B, Al y C

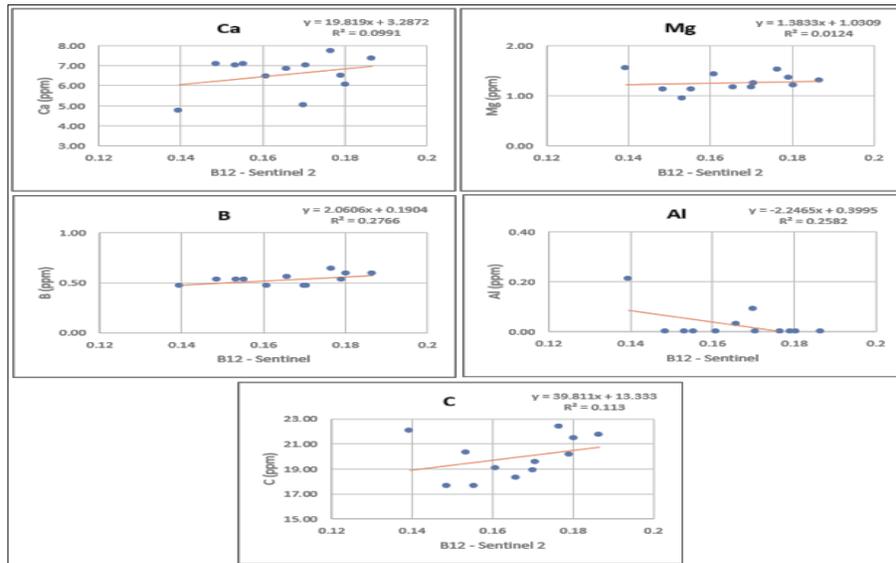
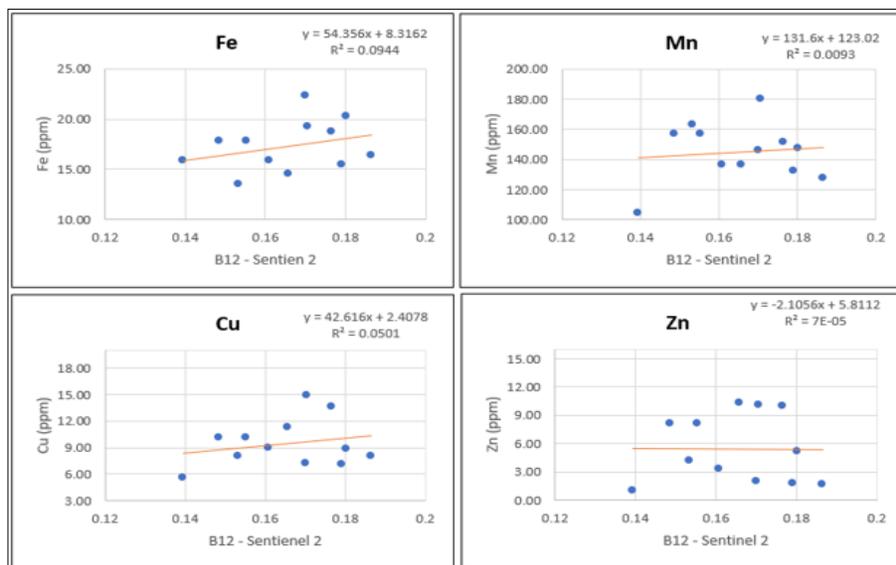


Figura 29.

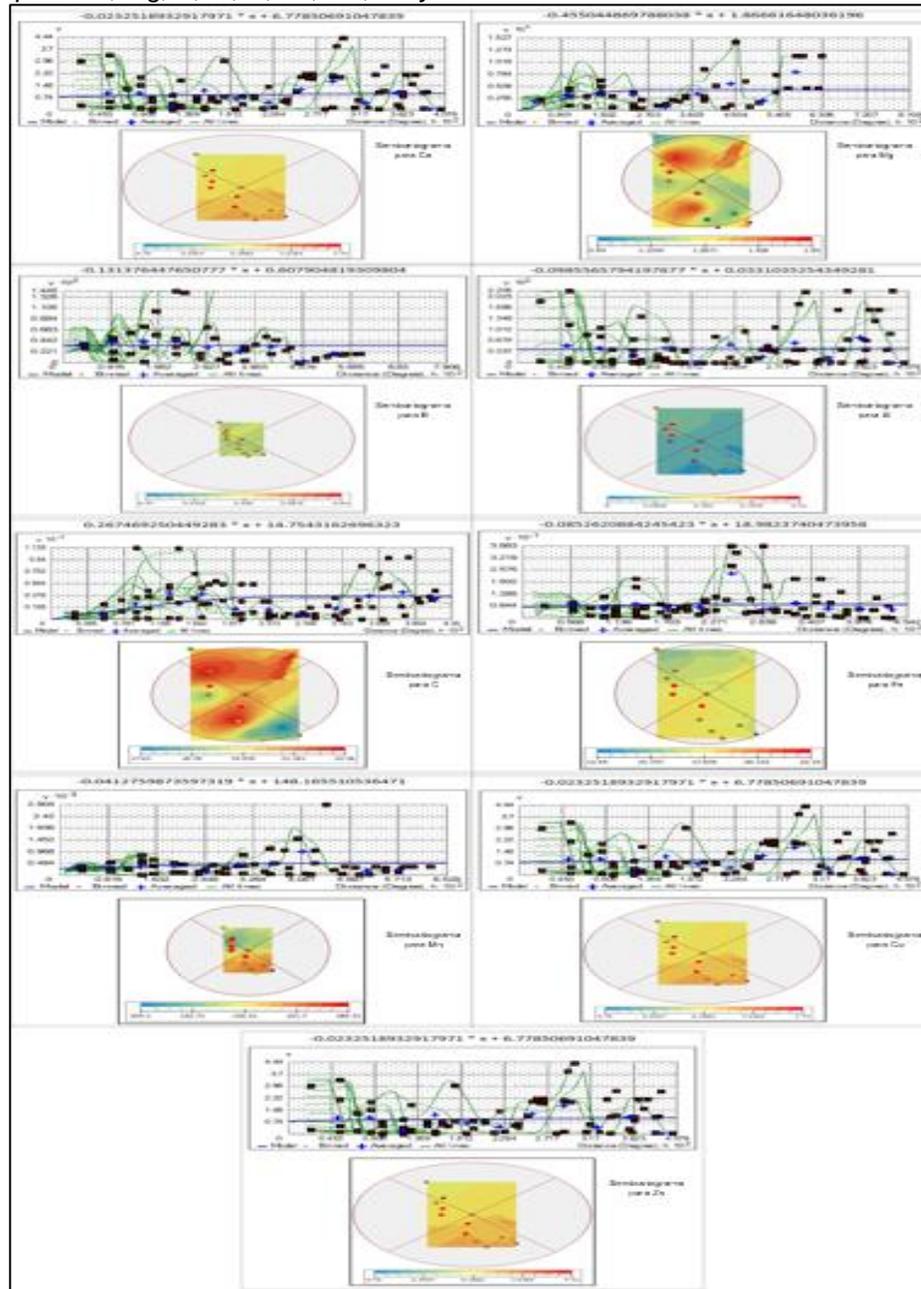
Correlación de datos de la banda 12 de suelo desnudo y resultados de muestras de laboratorio para Fe, Mn, Cu y Zn



Obteniendo el comportamiento de los datos, se logró realizar la validación cruzada, para identificar el mejor ajuste al modelo de interpolación y generar los mapas para cada uno de los elementos en función de la distribución. En la Figura 30, se pueden observar las validaciones efectuadas para cada uno de los elementos secundarios, arrojando información para efectos de análisis concisos y precisos. Cabe resaltar que

este tipo de verificaciones permite que la interpolación promedie mejor los datos, mejorando significativamente los errores producidos por la distancia entre las muestras, lo recomendable sería tener más puntos de muestreo, pero el alto costo de toma y análisis es un limitante para la gestión de campo.

Figura 30.
Semivariogramas para Ca, Mg, B, Al, C, Fe, Mn, Cu y Zn



Con la tercera etapa concluida se generaron los mapas de fertilidad, el desarrollo de cada etapa brinda opciones de tratar la información, permitiendo que la correlación de los datos se pueda realizar de manera efectiva y con coherencia.

Otro factor importante para lograr ejecutar un buen modelo de correlación es la temporalidad de todos los insumos empleados, para el muestreo dirigido se empleó la imagen de la banda 12 que representa el suelo desnudo que coincidieran con el mes y año en el cual se realizó el trabajo la toma de muestras. Si la imagen y las muestras no coinciden temporalmente, las variaciones en el suelo con respecto a sus nutrientes pueden cambiar debido a factores climatológicos o tratamientos agrícolas que se pueden realizar para potencializar las propiedades del suelo.

Para garantizar que la visualización de intensidad del nutriente sea correcta, se diseñó un estilo de etiquetas en formato .txt, con su respectivo código de color asociado con las concentraciones ya establecidas, y ajustan los rangos de las concentraciones bajo estándares internacionales dispuestos por la FAO. En la Tabla 11,

Tabla 12 y

Tabla 13 se observa la relación de concentración y su distribución en los diferentes estados.

Tabla 11.

Clasificación de fertilidad para interpretación de resultados. Adaptado de FAO (2022)

Elemento	Deficiente	Bajo	Óptimo	Alto	Muy alto
MO %	<0.35	0.35-1.05	1.05-2.30	2.30-3.50	>3.50
N-NO ₃ ppm	<5.00	6.00-10.00	10.00-20.00	20.00-35.00	>35.00
P ppm (Olsen)	<9.00	10.00-15.00	16.00-20.00	20.00-35.00	>36.00
P ppm (Bray)	<10.00	10.00-20.00	21.00-30.00	30.00-60.00	>61.00
K ppm	<100	101-200	200-400	400-1200	>1200
Na ppm	<50	51-100	101-200	201-300	>300
Ca ppm	<750	750-2000	2000-3000	3001-4500	>4500
Mg ppm	<50	50-200	200-800	800-1400	>1400
Fe ppm	<3.00	3.00-8.00	9.00-25.00	26.00-49.00	>50.00
Cu ppm	<0.2	0.2-0.9	0.9-1.3	1.3-2.5	>2.5
Mn ppm	<2.00	2.00-7.00	7.00-25.00	25.00-50.00	>50.00
Zn ppm	<0.3	0.4-1.2	1.3-5.0	5.1-8.0	>8.1
S ppm	<5.00	6.00-7.00	8.00-18.00	18.00-25.00	>25.00
B ppm	<0.3	0.4-0.8	0.9-1.4	1.5-3.0	>3.0

Tabla 12.

Clasificación de bases de cambio para interpretación de resultados. Adaptado de FAO (2022)

Elemento	Deficiente	Bajo	Óptimo	Alto	Muy alto
K % saturación	<3.1	3.1-4.0	4.1-6.0	6.1-10.0	>10.0
Na % saturación	<3.1	3.1-5.0	5.1-10.0	10.1-20.0	>20.0
Ca % saturación	<60	61-75	76-80	81-85	>86
Mg % saturación	<6.00	6.00-10.00	10.00-20.00	21.00-30.00	>30.00
Al % saturación	<2.00	2.00-5.00	5.00-15.00	15.00-60.00	>60.00
CIC	<5.00	5.00-15.00	15.00-25.00	25.00-40.00	>40.00

Tabla 13.

Clasificación de acidez para interpretación de resultados. Adaptado de FAO (2022)

Elemento	Fuertemente ácido	Moderadamente ácido	Neutro	Medianamente alcalino	Fuertemente alcalino
pH 1:2	<5.0	5.1-6.5	6.6-7.3	7.4-8.5	>8.5

La información generada propicia el análisis para cada concentración de nutrientes y evaluar, en particular, las zonas críticas que requieren un tratamiento diferenciado para equilibrar con las condiciones adecuadas de cada nutriente.

8.3.6 Definición del área

Para definir el área de interés para el desarrollo de la presente investigación, contemplaron diferentes factores determinantes que, de no ser tenidos en cuenta, pueden incurrir en errores futuros que produzca información errónea y poco relevante.

El área no debe ser de uso ganadero, ya que esta actividad genera un deterioro en el horizonte del suelo y pérdida de nutrientes por procesos de compactación, teniendo la particularidad de valores radiométricos, obtenidos de imágenes satelitales, significativamente alterados. Debido a lo anterior, se asumen áreas de uso netamente agrícolas, con identificación del cultivo sembrado durante el último año. Con el conocimiento adquirido del comportamiento del área agrícola se logra una apreciación respecto al ciclo de vida de las plantaciones, identificación de épocas del año en que el área se encuentra sin cobertura vegetal, y facilidad en la toma de decisiones sobre la selección de tiempo y paso del satélite para la toma oportuna de la imagen.

8.4 Enfoque metodológico

El enfoque de la investigación tendrá un componente mixto, en donde efectuarán en diferentes momentos enfoques cualitativos y cuantitativos: - de tipo cuantitativo, debido a que es un proceso de comportamiento secuencial y probatorio, el cual, según Garbanzo et al. (2017, p. 20), los modelos geoestadísticos por medio de datos numéricos permiten representar la variabilidad espacial de la fertilidad de los suelos a nivel local o de unidades de manejo integradas a mediana escala, dando como resultado un aporte sobre el área de estudio. Este enfoque se fundamenta en la medición basada en lo numérico, para este caso, cuyo objeto es diseñar un modelo basado en procesos geoestadísticos empleando información de muestras e imágenes satelitales, y - un enfoque cualitativo, ya que, durante el proceso correlacional, se pretenden analizar y tener en cuenta resultados basados en la interpretación de estos, debido a que a partir de los datos se pueden evidenciar cambios en el proceso, análisis de muestras, interpolaciones y procesos a realizar.

8.5 Tipo de estudio

El tipo de estudio se enmarcó en cualitativo correlacional, que, de acuerdo con Abreu (2012, p. 190), “especifican la relación entre dos o más variables y establecen la asociación entre dos variables del estudio”. En el caso del modelo geoestadístico se logrará interpolar los datos de las muestras obtenidas en campo con la B12 de la imagen, de esta manera se correlacionará la información que, a su vez, permitirá el resultado final de realizar predicciones basados en el comportamiento de los nutrientes en el suelo y su influencia sobre el cultivo de soja durante su desarrollo fenológico.

Es así como, en este tipo de estudio, también se logró identificar la relación entre variables y su cuantificación, lo que aportará a la elaboración del modelo preliminar. La correlación, a su vez, permitió que la información pueda ser tabulada en rango de valores numéricos, asignando rangos para cada uno de los nutrientes, este conjunto de datos obtenidos a través de la interpolación geoestadística generó un panorama muy amplio

que permite que se puedan describir acontecimientos para luego representarlos como recurso de consulta.

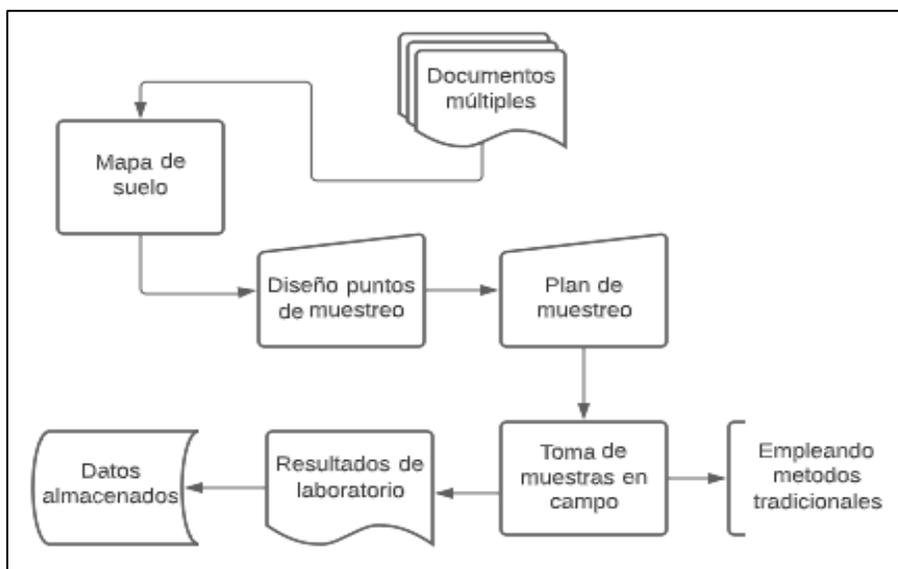
8.6 Diseño de la investigación

El plan o estrategia para obtener la información y dar cumplimiento a la pregunta de investigación y objetivos planteados está estructurado bajo dos segmentos recopilación de información primaria y secundaria.

8.6.1 Estrategia de recolección de información primaria

La recolección de este tipo de información es de mucha relevancia, debido a que con estos datos se podrá percibir el comportamiento de los nutrientes en el suelo del área de estudio, el enfoque es obtener muestras de suelo geolocalizadas y, empleando equipos de acción mecánica, extraer muestras de suelo que serán analizadas en laboratorio, permitiendo generar datos precisos acerca de las concentraciones de los macronutrientes y nutrientes secundarios. En la Figura 31 se describe el flujo dispuesto para la recolección de la información.

Figura 31.
Estrategia de recopilación de información primaria



Otro punto importante para la recolección de la información primaria es el formato del informe de laboratorio, una estructura sencilla para organizar los datos por muestra y que aporte la información necesaria que será empleada dentro del modelo, el formato se puede evidenciar en el Anexo A.

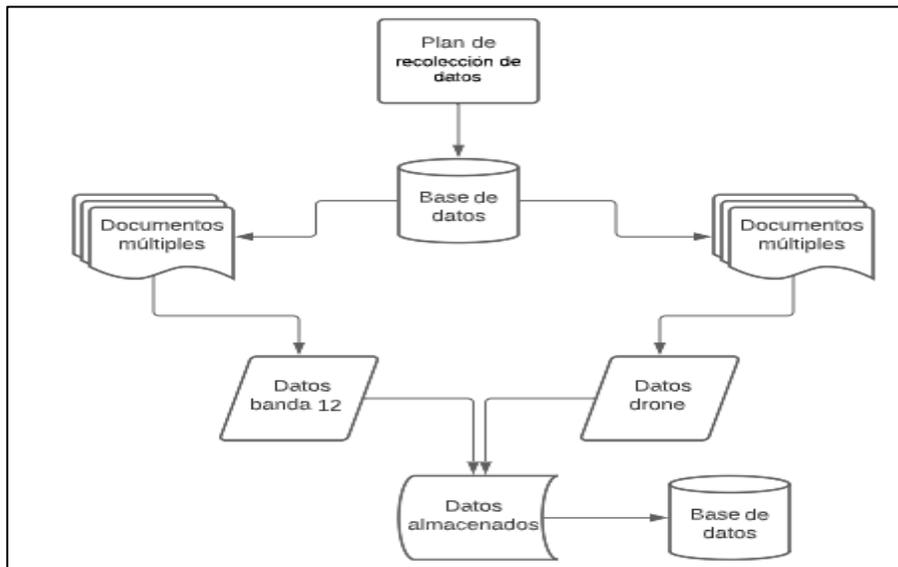
8.6.2 Estrategia recolección de información secundaria

Es representativa para todas las etapas expuestas en la metodología, las imágenes satelitales provenientes de sensores remotos aportan información de alto impacto para el análisis y el comportamiento de diferentes coberturas, para este caso en particular datos en el espectro electromagnético enfocado a suelo desnudo. La información de imágenes Sentinel 2 se encuentran de forma gratuita y disponibles en la red.

Para la adquisición de dicha información se realizó un plan de trabajo, el cual involucra la construcción de una base de datos que permita almacenar una serie de imágenes con diferente resolución temporal, lo que permitirá tener datos históricos para identificar el comportamiento del suelo desnudo y encontrar tendencias que clarifiquen, disminuyendo el riesgo de afectación por algún factor externo. Adicional a las imágenes satelitales, se tendrá acceso a una base de datos con información de vuelos de dron, con mayor resolución espacial y menos afectación de factores climatológicos presentes en las imágenes Sentinel 2.

La estrategia de recolección de información secundaria se representa en un diagrama (Figura 32), donde se puede apreciar la lógica, basada en estructura de base de datos, de la gestión de la información disponible, que integrará una nueva base de datos, con funcionamiento local y con datos exclusivamente seleccionados para la ejecución de los procesos establecidos.

Figura 32.
Estrategia de recopilación de información secundaria



8.7 Población o unidad de trabajo

Se pretende optimizar la forma de obtener información acerca de los macronutrientes y nutrientes secundarios empleando muestreos de suelo localizado e información *raster*, por lo tanto, estas mismas constituyen la población para este estudio. La unidad de trabajo está conformada por el suelo en sí mismo, ubicado en el área de estudio.

8.8 Muestra y muestreo

Las muestras se requieren para determinar la población, generalizar resultados y establecer parámetros, como el enfoque en su gran mayoría es cualitativo, las muestras se deben categorizar dentro de la clase probabilística ya que para la toma de muestras en campo se debe precisar claramente el tamaño de las muestras de suelo que por medio de un procedimiento claro se deben seleccionar los puntos geolocalizados que serán muestreados con una distribución lo más homogénea posible dentro del área de estudio.

Se tuvieron en cuenta muestras de suelo, tomadas anteriormente, para validar la consistencia del nuevo plan de muestreo estipulado para la presente investigación. Los

parámetros tenidos en cuenta dentro del análisis de laboratorio son: - Localización, dada en términos de Latitud y Longitud, - Propiedades físicas del suelo, considerando la composición, en %, de arena, arcilla y limo, - Propiedades químicas del suelo, dadas por las concentraciones de macronutrientes (P, K), micronutrientes (Mg, Na, Fe, Al, Zn, Mn, Cu, B, S), pH y CIC.

8.9 Operacionalización de variables

En la Tabla 14 se puede evidenciar el comportamiento de las variables para cada uno de los objetivos planteados.

Tabla 14.
Parámetros para muestras de suelo

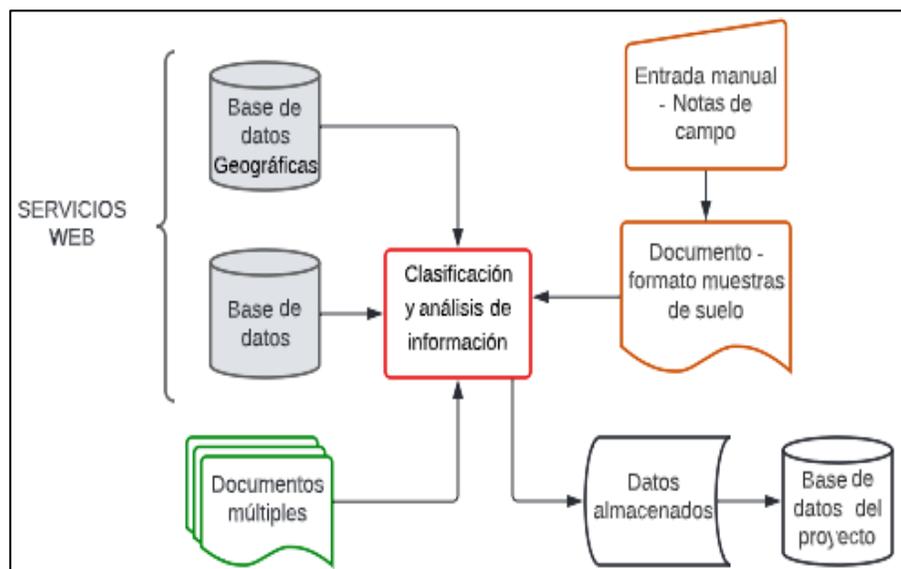
Objetivo General					
Diseñar un modelo preliminar para identificar la fertilidad de suelos, destinados al cultivo de soja, a partir de imágenes satelitales e interpolación geoestadístico IDW					
Objetivos específicos	Variable	Dimensión	Indicadores	Tipo de Variable	Definición
Generar información de componente físico del suelo empleando banda 12 de Sentinel 2.	Muestreo dirigido	Tipo de componente	Porcentaje	Cuantitativa	La confirmación de mapas de ambientes de suelo permite tener la primera aproximación con respecto a la distribución por porcentaje de los componentes físicos del suelo.
Identificar la distribución y concentración de macronutrientes y nutrientes secundarios en el suelo empleando procesos geoestadísticos.	Método geoestadístico	Componente distribución de nutrientes	Ppm/cmól	Cuantitativa	Los modelos de interpolación permiten correlacionar los datos de muestras de suelo con información <i>raster</i> .
Analizar en el área de estudio cuáles son las zonas de mayor aporte de nutrientes para el cultivo de soja	Macronutrientes y nutrientes en el suelo	Categorización de nutrientes por cultivo	Calidad del dato	Cualitativa	Dependiendo de la disposición de nutrientes en el suelo, el cultivo de soja puede disponer del aporte químico del suelo para su desarrollo, en zonas de déficit es necesario la fertilización por métodos mecanizados

8.10 Técnicas e instrumentos de recolección de información

Las técnicas para la recolección de información se fundamentan principalmente en análisis de contenido de bases de datos geográficas las cuales contienen datos *raster*, información vectorial y tablas de atributos. Adicionalmente, resultados de pruebas realizadas con diferentes modelos geoestadísticos para validar distintas alternativas y emplear la que mayor calidad de información pueda aportar.

Asimismo, un instrumento de recolección se focaliza en el muestreo de suelo, el cual cuenta con un formato debidamente estructurado para recopilar la información primordial de los análisis de laboratorio de las muestras tomadas directamente en campo. Para complementar la información capturada en el área de estudio, se emplean notas de campo donde se consignan eventos que puedan alterar las lecturas de los datos recopilados, como por ejemplo residuos de rastrojo, mallas y entre otros elementos que se deban tener en cuenta (Figura 33).

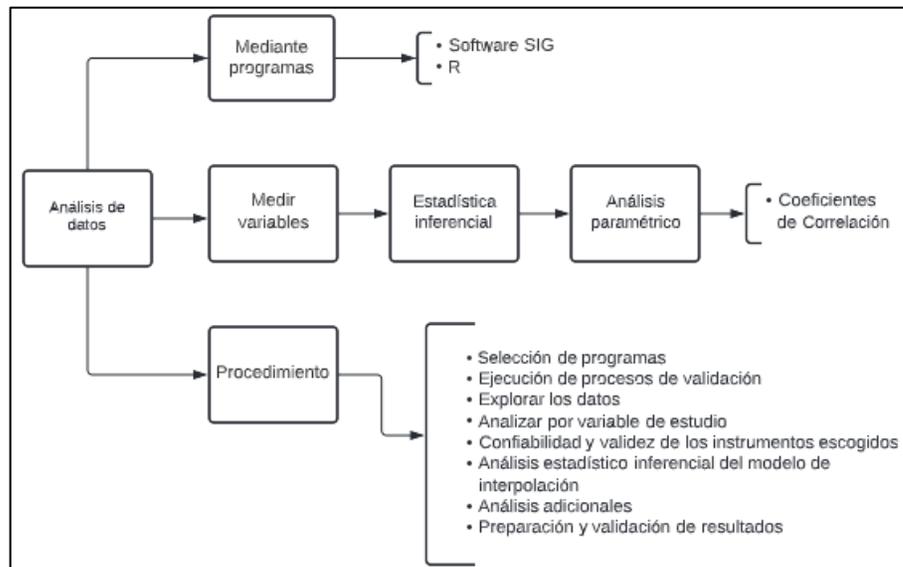
Figura 33.
Técnicas e instrumentos de recolección de información



8.11 Plan de análisis

Una etapa muy importante del proyecto es diseñar estrategias donde se analizaron los datos que se obtuvieron de cada proceso en las diferentes etapas. Estos planes ayudan, en gran medida, a dar respuesta a las preguntas formuladas. En la Figura 34 se puede evidenciar el plan de análisis.

Figura 34.
Plan de análisis

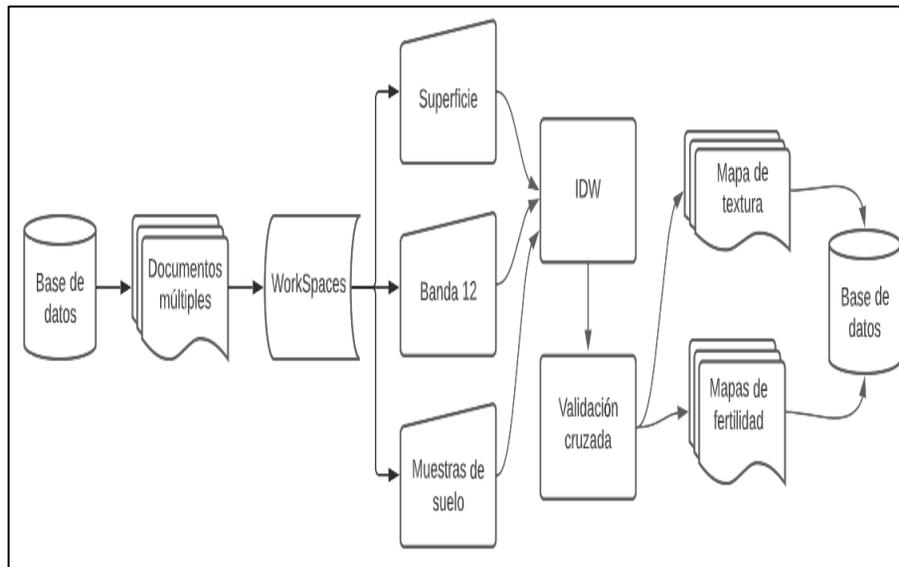


9. Resultados

9.1 Resultado 1. Modelo de fertilidad de suelo

El modelo que permite correlacionar la información de las muestras de campo, banda 12 de Sentinel, área de estudio y sus sectores para generar las respectivas salidas gráficas que representan el comportamiento de la textura de suelo, fertilidad, acidez y materia orgánica. Mientras en la Figura 35 se muestra una vista general, el Anexo I recoge la estructura del modelo.

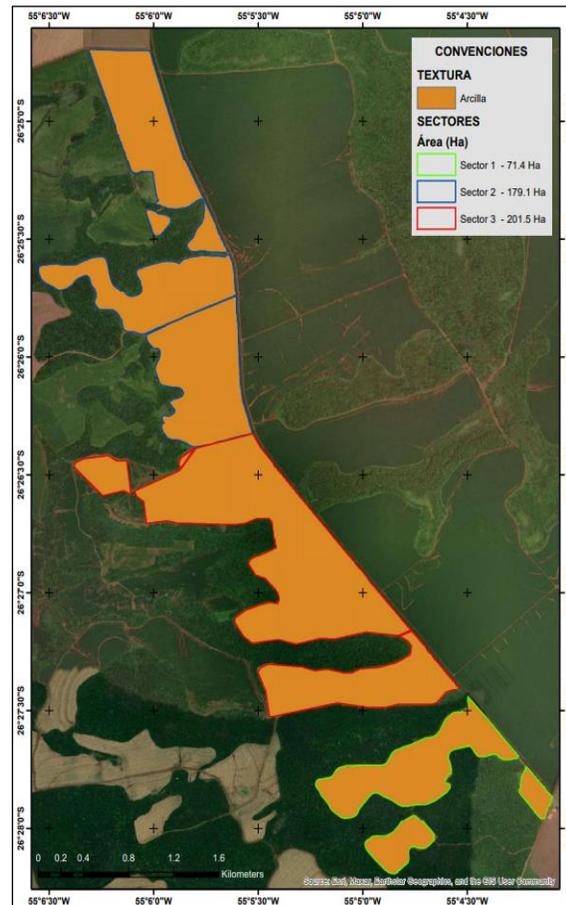
Figura 35.
Estructura general modelo de fertilidad para suelo



9.2 Resultado 2. Mapa de textura de suelo

El mapa de textura de suelo, basado en la composición de arena y arcilla extraída de la correlación de los porcentajes arrojados en el análisis de suelo y la imagen de suelo desnudo de la banda 12 de Sentinel 2 y acogiendo los parámetros de USDA, se observa en la Figura 36, en tanto los metadatos definidos se presentan en el Anexo C.

Figura 36.
Mapa de textura de suelo arcilloso



9.3 Resultado 3. Mapas de fertilidad de suelo, concentración y distribución de nutrientes

Los mapas (Figuras 37 y 38) evidencian el comportamiento de los diferentes nutrientes y otros elementos en el suelo, corresponden a información generada y representada en escala de colores por rangos de concentración para facilitar su interpretación.

Figura 37.

Mapa de Materia orgánica, aluminio, pH H₂O y pH CaCl₂, CIC, fósforo y potasio

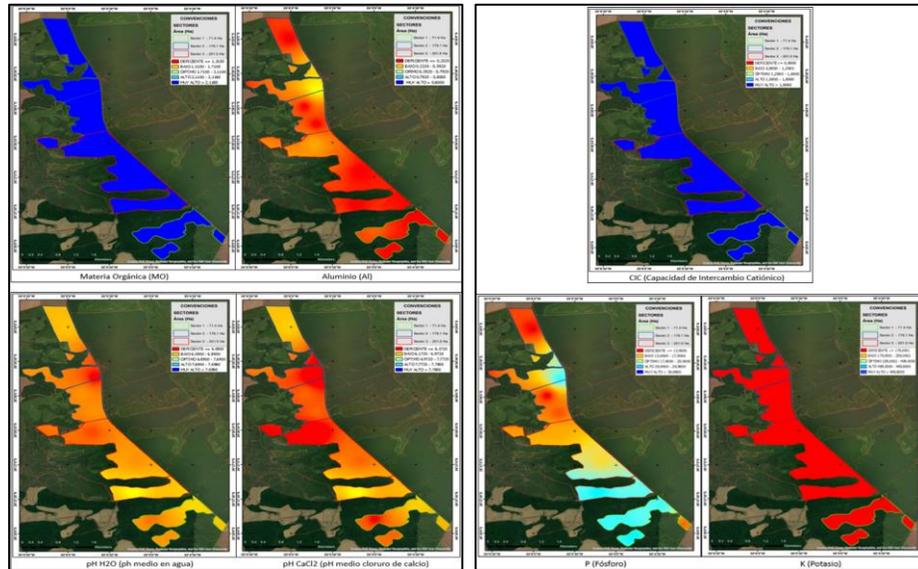
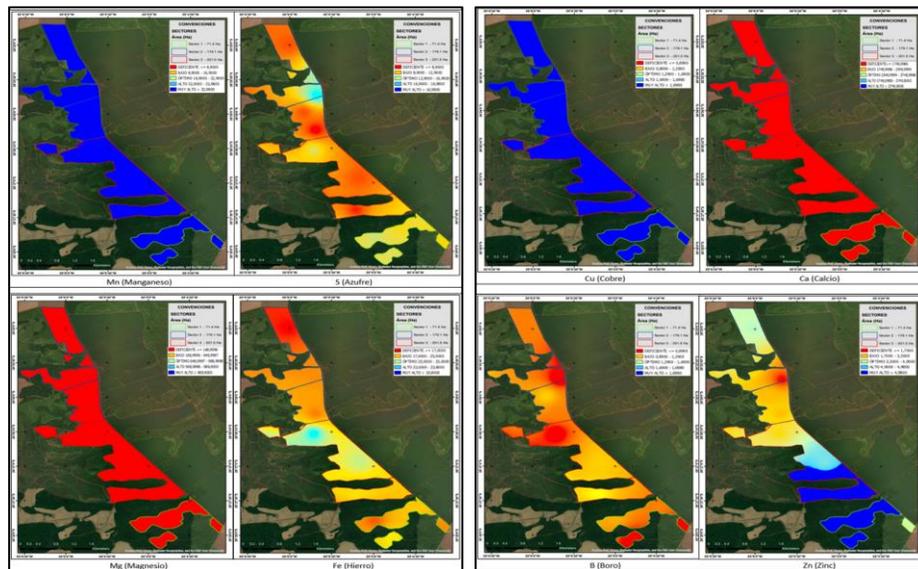


Figura 38.

Mapas de manganeso, azufre, magnesio y hierro, cobre, calcio, boro y zinc.



9.4 Resultado 4. Relación de elementos por sectores y la importancia para el cultivo de soja

En la Tabla 15 se puede evidenciar los resultados obtenidos para cada uno de los sectores con lo que respecta a su concentración y la importancia con respecto la relación por cada nutriente para el cultivo de soja.

Tabla 15.

Resultado de concentración por sectores y relación para el cultivo de soja.

Elemento	Concentración			Importancia y relación para soja
	Sector 1	Sector 2	Sector 3	
Al	Deficiente	Deficiente - Baja	Deficiente - Baja	Baja - Indirecta
B	Deficiente	Deficiente	Deficiente	Baja - Indirecta
Ca	Deficiente	Deficiente	Deficiente	Baja - Indirecta
Cu	Muy alta	Muy alta	Muy alta	Baja - Indirecta
Fe	Baja	Baja - Deficiente	Óptima - Baja	Baja - Indirecta
K	Deficiente	Deficiente	Deficiente	Alta - Directa
Mg	Deficiente	Deficiente	Deficiente	Baja - Indirecta
Mn	Muy alta	Muy alta	Muy alta	Baja - Indirecta
MO	Muy alta	Muy alta	Muy alta	Alta - Directa
P	Óptima	Baja – Óptima	Baja – Óptima	Alta - Directa
S	Baja	Óptima - Baja	Baja - Deficiente	Alta- Directa
Zn	Muy alta	Óptima - Baja	Óptima - Baja	Media - Indirecta

10. Análisis de resultados

El modelo diseñado para generar los mapas de fertilidad relaciona la información *raster* aportada por la banda 12, la información vectorial tipo punto que representa el resultado del muestreo geolocalizado y los tres sectores que componen el área de estudio. Los geoprocursos empleados por el modelo tienen un enfoque de tratamiento geoestadístico que permite tratar los datos con mayor veracidad, mediante validaciones y comprobaciones, al estimar la correlación de la información y su claridad para la generación de cada una de las salidas.

Se trata de un modelo con una estructura lógica y temporal definida que se ajusta a las necesidades básicas requeridas por el agricultor (Anexo I), enfocado en cuatro aspectos principales, dispuestos bajo parámetros, que permiten modelar la textura de suelo, ajustar la información proveniente de la banda 12 de Sentinel 2 con la conformación del área representada en archivo vectorial tipo polígono, correlación empleando métodos esféricos para regresión lineal y métodos geoestadísticos de interpolación para definir la relación entre el muestreo de suelo y la información *raster*, generando los mapas de concentración y distribución de fertilidad de suelo para cada elemento considerado.

Una de las salidas del modelo es el tipo de suelo, con la textura obtenida se pueden evidenciar algunas aproximaciones del comportamiento de los nutrientes disponibles en el suelo. La presencia de arcilla implica una alta retención, haciendo que los nutrientes permanezcan más tiempo en el suelo y, debido a la baja capacidad de drenaje, se tenga un menor lavado. Además, los suelos arcillosos, conocidos como cálidos, debido a la capacidad termorreguladora generada por el agua retenida, otorga una capacidad mayor de mineralizar los fertilizantes, por el hecho de que la biota presente es más activa.

Los suelos arcillosos también tienen una mayor tendencia a la compactación, derivado de esa capacidad de retener agua, por tanto, localizar las superficies de la parcela con estas tendencias, es muy importante para evitar labores con niveles de humedad muy altos que creen las llamadas suelas de compactación, impidiendo el correcto desarrollo del cultivo. Al igual que ocurre con la compactación, es un suelo con mayor capacidad de

retener el agua y menor drenaje, son más susceptibles a presentar problemas de encharcamiento, favoreciendo asfixia radicular y proliferación de enfermedades por hongos y bacterias.

Los mapas de fertilidad, materia orgánica, pH y capacidad de intercambio catiónico representan la distribución y concentración para cada elemento, con escalas de color que permiten comprender los datos de una mejor manera, por ejemplo, en el comportamiento de la materia orgánica se puede observar una alta concentración en toda el área de estudio con valores superiores a los 2.1 ppm, debido a la textura de suelo y su capacidad de retención, mejorando las propiedades físicas, químicas y biológicas del suelo.

Los resultados para pH muestran valores de pH_{H₂O} por debajo de 6 y para pH_{CaCl₂} de 6.1, lo que indica un suelo moderadamente ácido, comportamiento característico en suelos arcillosos, que influye sobre el calcio por su alta relación con el pH: en suelos con tendencias ácidas, su disponibilidad es baja, una concentración inferior a 1750 ppm se considera deficiente. Además, los suelos ácidos afectan la disponibilidad del magnesio, ratificado en el mapa con concentraciones deficientes, inferiores a 168 ppm.

Por otro lado, se detecta una alta capacidad de intercambio catiónico cuando el suelo es arcilloso y se tienen altos porcentajes de materia orgánica. Altos valores de CIC influyen directamente en la movilización de los nutrientes, acelerando su disponibilidad para la planta, algo muy parecido con los resultados de la MO, siendo los sectores de color azul donde hay mayor capacidad de mineralizar y disponibilidad de nutrientes.

Por su parte, se presenta una alta variabilidad en los valores del fósforo, entre los sectores, y concentraciones para potasio por debajo de las 180 ppm, con deficiencia del nutriente en el área de estudio, definen una baja correlación de los datos con respecto a la banda 12, debido a que son elementos inmóviles, es decir que tardan mucho en moverse por el suelo, lo que no permite que se reflejen claramente en un análisis de suelo. Otro factor que potencializa la deficiencia de alguno de los dos elementos es el tipo de pH, al ser una parcela con suelo moderadamente ácido, favorece su baja disponibilidad.

Los valores para aluminio por debajo de 0.2 ppm indican que sus concentraciones bajas son favorables, ya que los suelos con alto contenido de aluminio pueden ser tóxicos para las plantas, lo que afecta su desarrollo y potencial productivo. Por otro lado, la alta presencia de cobre, es un problema para el desarrollo de la biomasa, al ser un metal pesado que se puede depositar de forma natural, por lluvia o corrientes de agua. En la parcela de estudio, el agua de riego proviene de canales artificiales que pueden contener altos contenidos de cobre lo cual, sumado a altas concentraciones de MO, aumenta la capacidad del cobre de atarse a ella y perdurar más tiempo.

En cuanto a los demás micronutrientes, - el zinc, importante para el desarrollo de las plantas y su resistencia a las enfermedades, se encuentra presente de forma variable, - el boro presenta valores muy bajos, lo que puede afectar el desarrollo de raíces y su capacidad de absorción de agua, - el hierro muestra concentraciones deficientes en los tres sectores, que podrían afectar la producción de clorofila y, por ende, el amarillamiento foliar, - el manganeso refleja una concentración deficiente, generando un efecto similar a lo que produce la falta de hierro, y - el azufre, cuyos valores bajos y deficientes pueden afectar la síntesis de proteínas y reducirá la eficacia de la inoculación de nitrógeno.

El cultivo de soja demanda principalmente de los nutrientes esenciales, ya sea de forma directa o indirecta, tales como fósforo, potasio y azufre, también el nitrógeno, aportado normalmente por inoculación. Sin embargo, deben contemplarse otros factores que pueden interferir en la disponibilidad o retención de los nutrientes, como pH, CIC, textura y concentración de aluminio.

Además, se dispone de las relaciones entre grado de importancia y el cultivo de soja para cada uno de los sectores y los elementos evaluados. Para el caso del fósforo, presenta una distribución óptima para el sector 1, en tanto para los sectores 2 y 3 tiende a ser óptimo con tendencia a la baja, por lo que se debe realizar una recomendación de abonado diferencial para estos dos sectores. Con respecto al potasio, se deben ajustar los valores de concentración, mediante el plan de fertilización en toda el área y garantizar concentraciones entre 250 y 500 ppm. Se deben ajustar, de igual forma, los valores en los

sectores 1 y 3 para azufre, realizar un plan de mitigación destinado a bajar los contenidos de cobre y tratamientos diferenciales para regular la concentración de los demás nutrientes.

11. Discusión

La implementación de este tipo de modelos depende mucho de la interacción entre diferentes tipos de datos, lo que hace que la interoperabilidad de estos sea más compleja de lo normal, desde contemplar las características climáticas que afectan la variación en los contenidos de los nutrientes hasta comprender la relación que tienen cada uno de los elementos entre sí y su comportamiento principalmente con la textura de suelo. Validando los resultados del estudio realizado por Garbanzo et al.,(2017), quienes determinan que por medio de modelos geoestadísticos se puede establecer una relación con los nutrientes del suelo y variables interoperables externas, por lo que se asemeja a los resultados obtenidos en la presente investigación, discrepando en los procesos de validación empleados y la cantidad de elementos evaluados, pero llegando a la misma interpretación de la importancia que tiene la implementación de estos modelos, empleando información primaria y secundaria.

Otro factor importante es el control sobre el muestreo de suelo, el cual no se realiza de forma aleatoria, sino que se apoya en procesos tecnológicos de acceso libre, como las imágenes satelitales, las cuales permiten tener una mejor visión del campo, sin desestimar las variables medioambientales que pueden afectar la captura de datos y la temporalidad en un área específica. Un limitante para el muestreo dirigido son los altos costos de la toma de muestras *in situ*, lo que reduce significativamente mejorar la densidad de los puntos; por lo que correlacionar estos análisis de las muestras con información satelital ayuda a potencializar los resultados de una manera significativa. Los problemas de densidad, planteados en diferentes estudios, demuestran que son importantes para lograr una buena calidad en los procesos de interpolación, por ejemplo, la investigación de Villatoro, Henríquez y Sancho (2008), ratifica que los procesos de interpolación mejoran con el aumento en la densidad de puntos de muestreo, aunque el alto costo disminuye su sostenibilidad en el tiempo, lo cual coincide con el presente trabajo, donde la baja cantidad de muestras afectó la correlación de los datos y sus tendencias.

Los mapas, salida final del modelo, son un medio para comprender la predicción de la realidad, permitiendo al agricultor la implementación de planes para mejorar sus labores

de fertilización, en dosificación y oportunidad. El resultado de textura demuestra la alta relación entre las características físicas del suelo desnudo y la banda 12 de Sentinel 2, que empleando modelos esféricos para la regresión e interpolación permite obtener una alta correlación entre los datos, lo que no discrepa tanto de otros estudios, como el realizado por Bousbih et al., (2019) quienes lograron identificar que la banda 12 de Sentinel tiene una alta correlación con los porcentes de arcilla y arena, lo que permite categorizar la estructura del suelo de manera precisa.

Dentro de los resultados aportados por la presente investigación, el comportamiento de diversos elementos en el suelo dejan ver como la compactación del suelo y la acumulación de agua por falta de filtración aumentan las concentraciones de MO, debido a la acumulación de la biota, pero también potencializa la concentración de otros elementos que perjudican al cultivo de soja, como el cobre, que en altas concentraciones es tóxico para las plantas; al ser un metal pesado presente en agua de riego. Es notorio también el comportamiento de los elementos más demandados por la soja, N, K y S, los cuales presentan concentraciones bajas por su baja movilidad en el suelo. En estudios referentes en la generación de mapas de distribución de nutrientes, empleando procesos de interpolación, siempre se resaltan los elementos mayores como el N, P, K y propiedades del suelo, como pH y CIC, en coherencia con Zambrano et al. (2020), aunque en esta investigación se consideran más elementos, obteniendo mapas de B, Zn, Mg, Mn, Al, Cu, Ca, y materia orgánica.

12. Conclusiones

Se diseñó un modelo de fertilidad para suelo que, por medio de modelos geoestadísticos, correlacionan la información de imágenes de suelo desnudo con muestras geolocalizadas para obtener mapas que permiten identificar la concentración, distribución de nutrientes, textura de suelo y otras propiedades, como CIC y MO.

En problemas de validación cruzada por baja correlación entre los datos se suele elegir un método diferente de cálculo, empleando modelos de regresión esférica, con fundamento en la capacidad predictiva, para encontrar mejores ajustes estadísticos de los datos cuando se tienen correlaciones inversas o negativas.

La robustez de los resultados otorga al agricultor mecanismos interoperables que fortalecen las decisiones en el manejo del cultivo de soja, al mostrar el comportamiento de la fertilidad y propiciar planes de abonado con dosificación variable para aportar cantidades óptimas en zonas de déficit, disminución de producto en partes de concentraciones elevadas y manejo diferencial para lugares de óptimo aporte de nutrientes.

Estos resultados abren nuevas opciones en el ámbito de la gestión del suelo y su fertilidad, los que pueden mejorar con la densificación de muestras, mejor calidad de imágenes y validación de los resultados en campo donde se evalúe el desarrollo del cultivo de acuerdo con los mapas de fertilidad.

Por medio de los resultados se logra demostrar que se mejora con la toma de decisiones al momento de fertilizar, lo que permite evidenciar que con el modelo y los productos generados se tiene una realidad más asertiva de la realidad del suelo. El modelo con su integridad lógica en geo procesos y geoestadística permite generar salidas graficas aplicables a las labores de campo, que por medio de mapas permite al agricultor tener un panorama más detallado del comportamiento del suelo antes de la siembra, también se evidencia que las variables climatológicas son de alto valor para garantizar resultados más precisos.

Anexos

- Los valores de latitud y longitud deben ser ingresados en WGS-84 degree.
- La información física en porcentaje (%).
- La información química por elemento en las unidades expuestas en el encabezado del formato

Anexo B. Resultados de laboratorio muestras de suelo dirigido

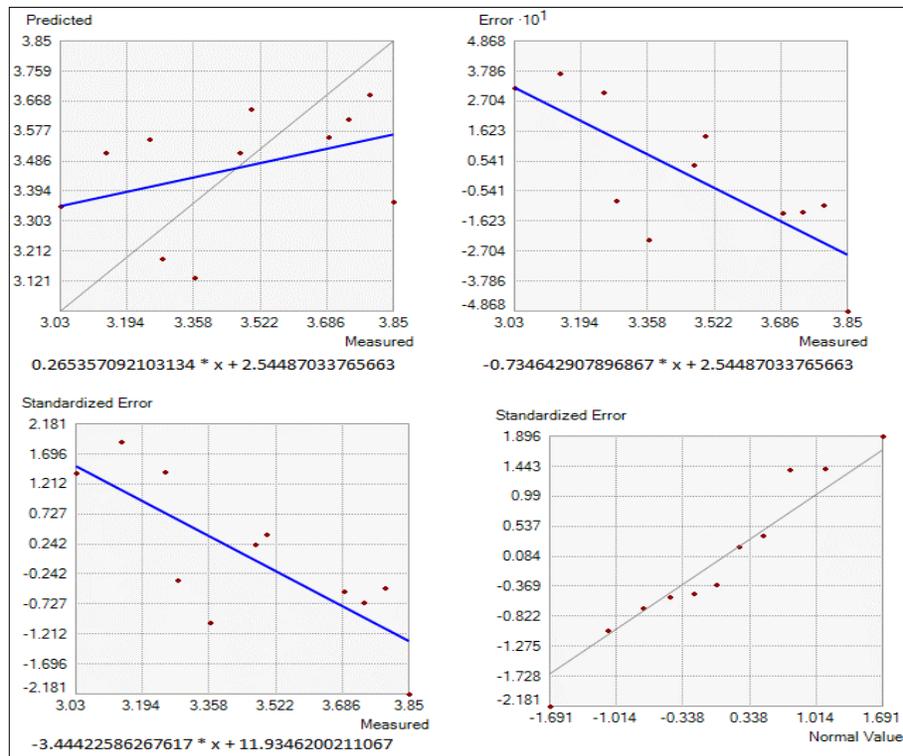
OBJECTID	Latitud	Longitud	Profundidad	Ca	Mg	K	Al	H	Al	S	Bases	CTC	C	MO	Sat	Al	P	Fe	Mn	Cu	Zn	pH_H2O	pH_SMP	pH_CaCl2	Arena	Limo	Arcilla	Boro	Azufre
1	-26.4629651	-55.08317072	0 - 20 CM	6.83	1.17	0.49	0.03	4.96	8.49	13.45	18.27	3.14	0.35	21.05	14.57	136.07	11.31	10.29	5.50	6.00	4.90	18.10	30.50	51.40	0.56	11.06			
2	-26.46720861	-55.07984505	0 - 20 CM	7.01	1.25	0.69	0.00	4.96	8.95	13.91	19.53	3.36	0.00	21.83	19.23	180.31	14.87	10.05	5.60	6.00	5.00	17.20	27.30	55.50	0.47	10.67			
3	-26.45874931	-55.07454194	0 - 20 CM	7.06	1.12	0.57	0.00	4.28	8.75	13.03	17.63	3.03	0.00	20.84	17.85	157.11	10.06	8.08	5.90	6.20	5.30	21.45	24.65	53.90	0.53	10.28			
4	-26.46433335	-55.06988824	0 - 20 CM	6.47	1.42	0.54	0.00	4.28	8.43	12.71	19.06	3.28	0.00	11.93	15.83	136.14	8.98	3.29	5.80	6.20	5.20	16.60	25.15	58.25	0.47	9.89			
5	-26.4164256	-55.10024653	0 - 20 CM	7.02	0.94	0.67	0.00	4.28	8.63	12.91	20.32	3.50	0.00	10.73	13.54	162.92	8.03	4.17	5.80	6.20	5.30	11.95	31.95	56.10	0.53	7.35			
6	-26.42881879	-55.09465843	0 - 20 CM	4.75	1.55	0.23	0.21	5.76	6.53	12.29	22.06	3.79	3.12	21.05	15.82	104.10	5.54	1.00	5.30	5.80	4.80	12.70	23.70	63.60	0.47	14.19			
7	-26.43298411	-55.0971925	0 - 20 CM	7.34	1.30	0.24	0.00	4.96	8.88	13.84	21.74	3.74	0.00	10.66	16.34	127.34	7.97	1.71	5.60	6.00	5.00	18.95	24.10	56.95	0.59	7.35			
8	-26.43718882	-55.09485554	0 - 20 CM	6.51	1.35	0.42	0.00	4.61	8.28	12.89	20.16	3.47	0.00	11.57	15.49	132.52	7.05	1.72	5.60	6.10	5.00	14.45	30.20	55.35	0.53	6.56			
9	-26.44204231	-55.09521507	0 - 20 CM	5.01	1.17	0.40	0.09	5.35	6.58	11.93	18.90	3.25	1.35	13.55	22.33	145.61	7.21	1.99	5.40	5.90	4.80	12.15	31.60	56.25	0.47	10.67			
10	-26.44878356	-55.08813687	0 - 20 CM	6.04	1.21	0.49	0.00	4.96	7.74	12.70	21.43	3.69	0.00	15.32	20.26	147.04	8.89	5.16	5.60	6.00	5.00	11.30	31.65	57.05	0.59	7.35			
11	-26.45661339	-55.08685594	0 - 20 CM	7.73	1.52	0.66	0.00	3.97	9.91	13.88	22.38	3.85	0.00	21.97	18.70	151.44	13.61	10.01	6.10	6.30	5.50	21.80	24.55	53.65	0.64	6.95			
12	-26.45874931	-55.07454194	1 - 20 CM	7.06	1.12	0.57	0	4.28	8.75	13.03	17.63	3.03	0.00	20.84	17.85	157.11	10.06	8.08	5.90	6.20	5.30	21.45	24.7	53.9	0.53	10.28			

Anexo C. Resultados de la creación del mapa de textura

Datos textura de suelo												
FID	code	label_txt	Shape_Ler	Shape_Are	Capacid pmp	Retencii	Cond_H	Reten_Fertilizai	Compactacion	Encharcamient	Potencial_prod	Color
1	1	clay	0.00679	0.000002	40	30	130	1 muy alta	alta	alta	muy alto	219-137-37
2	1	clay	0.050486	0.000054	40	30	130	1 muy alta	alta	alta	muy alto	219-137-37
33	1	clay	0.00027	0	40	30	130	1 muy alta	alta	alta	muy alto	219-137-37
34	1	clay	0.000348	0	40	30	130	1 muy alta	alta	alta	muy alto	219-137-37
43	1	clay	0.013689	0.000008	40	30	130	1 muy alta	alta	alta	muy alto	219-137-37
47	1	clay	0.213546	0.000277	40	30	130	1 muy alta	alta	alta	muy alto	219-137-37
48	1	clay	0.049115	0.000047	40	30	130	1 muy alta	alta	alta	muy alto	219-137-37
49	1	clay	0.010888	0.000005	40	30	130	1 muy alta	alta	alta	muy alto	219-137-37
50	1	clay	0.017468	0.000012	40	30	130	1 muy alta	alta	alta	muy alto	219-137-37

Anexo D. Resultados validación cruzada para materia orgánica (MO)

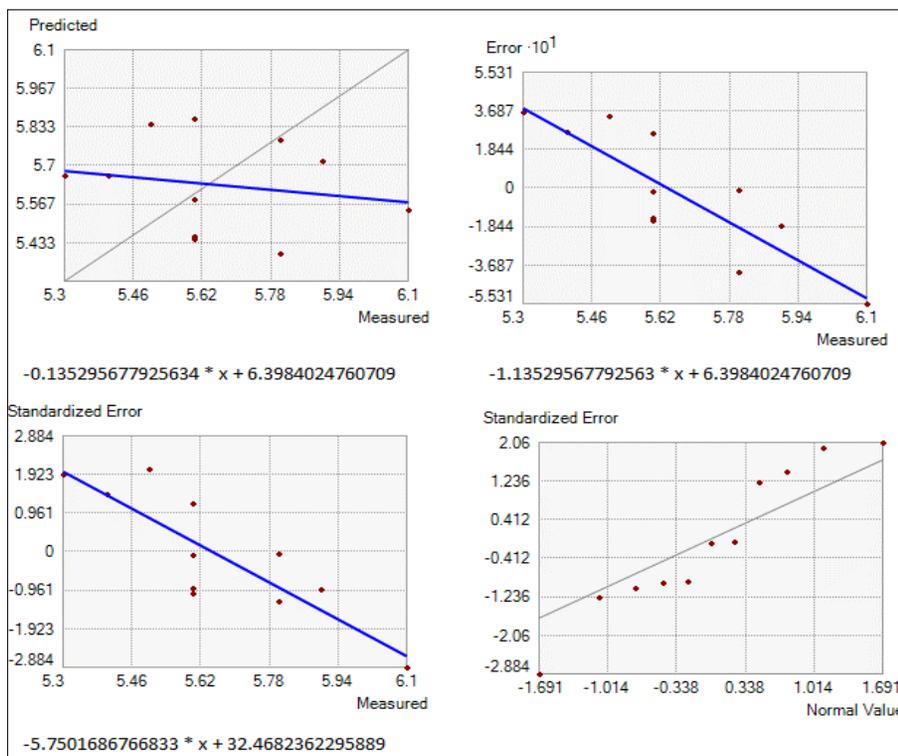
FID	Measured	Predicted	Error	StdError	Stdd_Error	NormValue	Source_ID	Included
0	3.14	3.51034	0.37034	0.195278	1.89647	1.690622	1	Yes
1	3.36	3.130879	-0.229121	0.223091	-1.027032	-1.096804	2	Yes
2	3.03	3.347091	0.317091	0.227921	1.391232	0.747859	3	Yes
3	3.28	3.1908	-0.0892	0.256922	-0.347187	0	4	Yes
4	3.5	3.644713	0.144713	0.371657	0.389372	0.472789	5	Yes
5	3.79	3.685878	-0.104122	0.218908	-0.475644	-0.229884	6	Yes
6	3.74	3.611164	-0.128836	0.183317	-0.702802	-0.747859	7	Yes
7	3.47	3.510541	0.040541	0.175231	0.231356	0.229884	8	Yes
8	3.25	3.551928	0.301928	0.214249	1.409239	1.096804	9	Yes
9	3.69	3.557113	-0.132887	0.251578	-0.528213	-0.472789	10	Yes
10	3.85	3.363232	-0.486768	0.223188	-2.180978	-1.690622	11	Yes



Anexo E. Resultados validación cruzada para pH

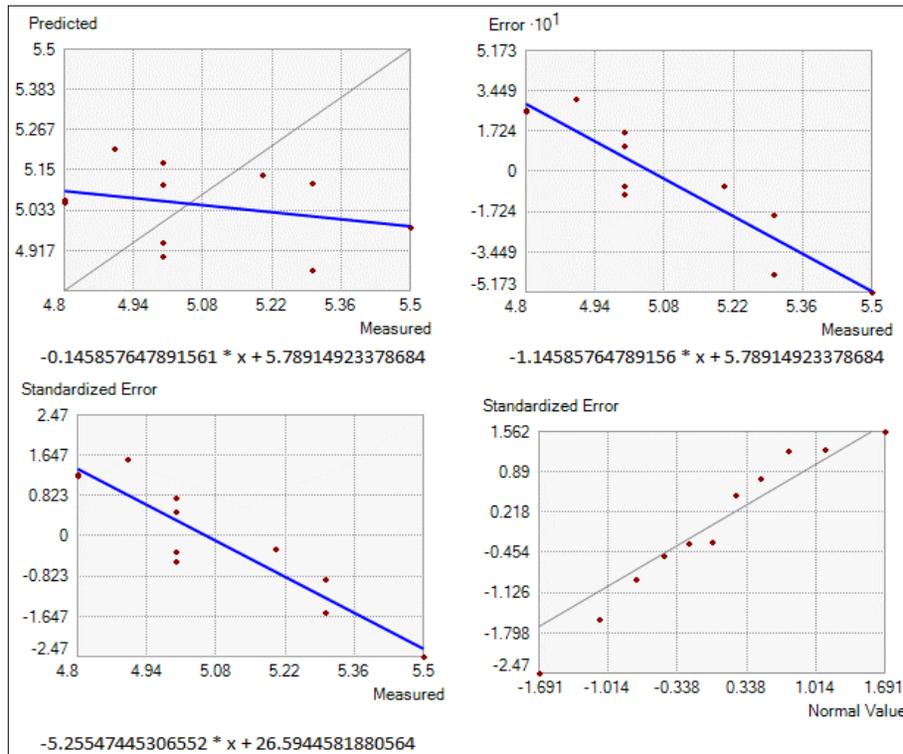
PH_H2O

FID	Measured	Predicted	Error	StdError	Stdd_Error	NormValue	Source_ID	Included
0	5.5	5.84501	0.34501	0.167474	2.060084	1.690622	1	Yes
1	5.6	5.583855	-0.016145	0.190948	-0.08455	0	2	Yes
2	5.9	5.717508	-0.182492	0.195569	-0.933133	-0.472789	3	Yes
3	5.8	5.788067	-0.011933	0.219308	-0.054411	0.229884	4	Yes
4	5.8	5.395845	-0.404155	0.323673	-1.248652	-1.096804	5	Yes
5	5.3	5.664027	0.364027	0.187511	1.941368	1.096804	6	Yes
6	5.6	5.456226	-0.143774	0.15715	-0.914882	-0.229884	7	Yes
7	5.6	5.444041	-0.155959	0.150165	-1.038583	-0.747859	8	Yes
8	5.4	5.665518	0.265518	0.184036	1.442751	0.747859	9	Yes
9	5.6	5.860018	0.260018	0.21587	1.20451	0.472789	10	Yes
10	6.1	5.546921	-0.553079	0.191749	-2.884396	-1.690622	11	Yes



PH_CaCl2

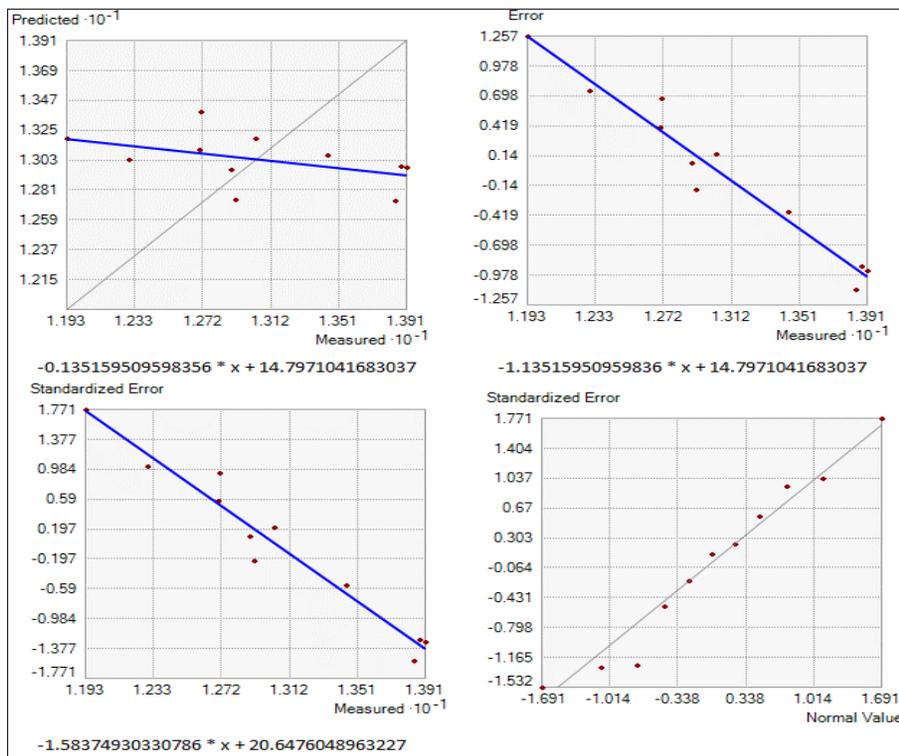
FID	Measured	Predicted	Error	StdError	Stdd_Error	NormValue	Source_ID	Included
0	4.9	5.210568	0.310568	0.198882	1.561574	1.690622	1	Yes
1	5	5.10685	0.10685	0.210396	0.507853	0.229884	2	Yes
2	5.3	5.113227	-0.186773	0.207688	-0.899297	-0.747859	3	Yes
3	5.2	5.136877	-0.063123	0.224336	-0.281376	0	4	Yes
4	5.3	4.861167	-0.438833	0.27801	-1.578481	-1.096804	5	Yes
5	4.8	5.063775	0.263775	0.209128	1.261307	1.096804	6	Yes
6	5	4.938787	-0.061213	0.194622	-0.314521	-0.229884	7	Yes
7	5	4.901457	-0.098543	0.191502	-0.514579	-0.472789	8	Yes
8	4.8	5.055012	0.255012	0.206963	1.232161	0.747859	9	Yes
9	5	5.171405	0.171405	0.220089	0.778798	0.472789	10	Yes
10	5.5	4.982658	-0.517342	0.209461	-2.469875	-1.690622	11	Yes



Anexo F. Resultados validación cruzada para CIC

CIC

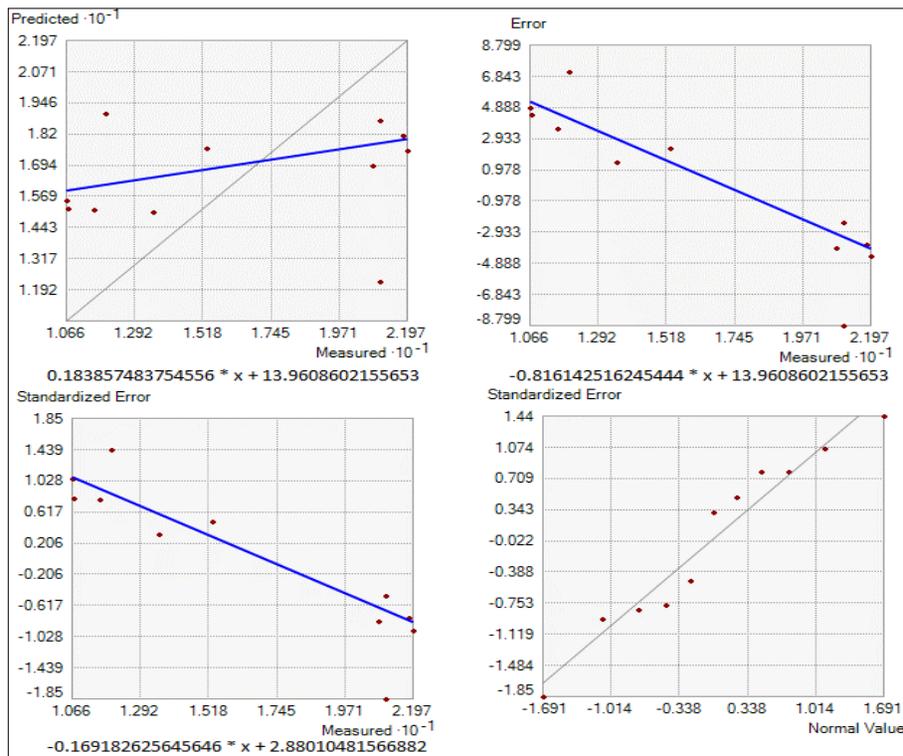
FID	Measured	Predicted	Error	StdError	Stdd_Error	NormValue	Source_ID	Included
0	13.45	13.06538	-0.38462	0.71643	-0.536857	-0.472789	1	Yes
1	13.91	12.975327	-0.934673	0.724785	-1.289587	-1.096804	2	Yes
2	13.03	13.189014	0.159014	0.713688	0.222806	0.229884	3	Yes
3	12.71	13.389692	0.679692	0.722406	0.940873	0.747859	4	Yes
4	12.91	12.737324	-0.172676	0.763781	-0.226081	-0.229884	5	Yes
5	12.29	13.036318	0.746318	0.725101	1.02926	1.096804	6	Yes
6	13.84	12.733066	-1.106934	0.722454	-1.532185	-1.690622	7	Yes
7	12.89	12.963625	0.073625	0.711533	0.103474	0	8	Yes
8	11.93	13.187054	1.257054	0.709827	1.77093	1.690622	9	Yes
9	12.7	13.104891	0.404891	0.710342	0.569995	0.472789	10	Yes
10	13.88	12.985658	-0.894342	0.709598	-1.260349	-0.747859	11	Yes



Anexo G. Resultados validación cruzada para P y K

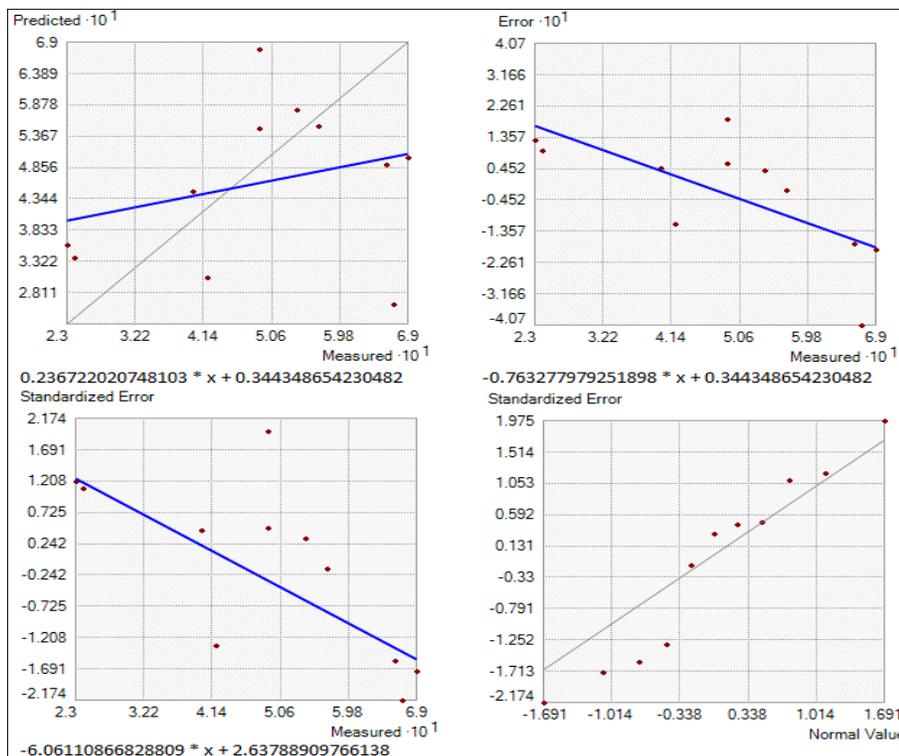
P

FID	Measured	Predicted	Error	StdError	Stdd_Error	NormValue	Source_ID	Included
0	21.05	18.753712	-2.296288	4.637634	-0.495142	-0.229884	1	Yes
1	21.83	18.139035	-3.690965	4.7696	-0.773852	-0.472789	2	Yes
2	20.84	16.931788	-3.908212	4.709347	-0.829884	-0.747859	3	Yes
3	11.93	19.045257	7.115257	4.942477	1.439613	1.690622	4	Yes
4	10.73	15.186997	4.456997	5.616078	0.793614	0.747859	5	Yes
5	21.05	12.251367	-8.798633	4.756667	-1.849747	-1.690622	6	Yes
6	10.66	15.5294	4.8694	4.620355	1.053902	1.096804	7	Yes
7	11.57	15.145399	3.575399	4.577976	0.781	0.472789	8	Yes
8	13.55	15.034022	1.484022	4.694233	0.316137	0	9	Yes
9	15.32	17.625471	2.305471	4.774674	0.482854	0.229884	10	Yes
10	21.97	17.533596	-4.436404	4.702751	-0.943364	-1.096804	11	Yes



K

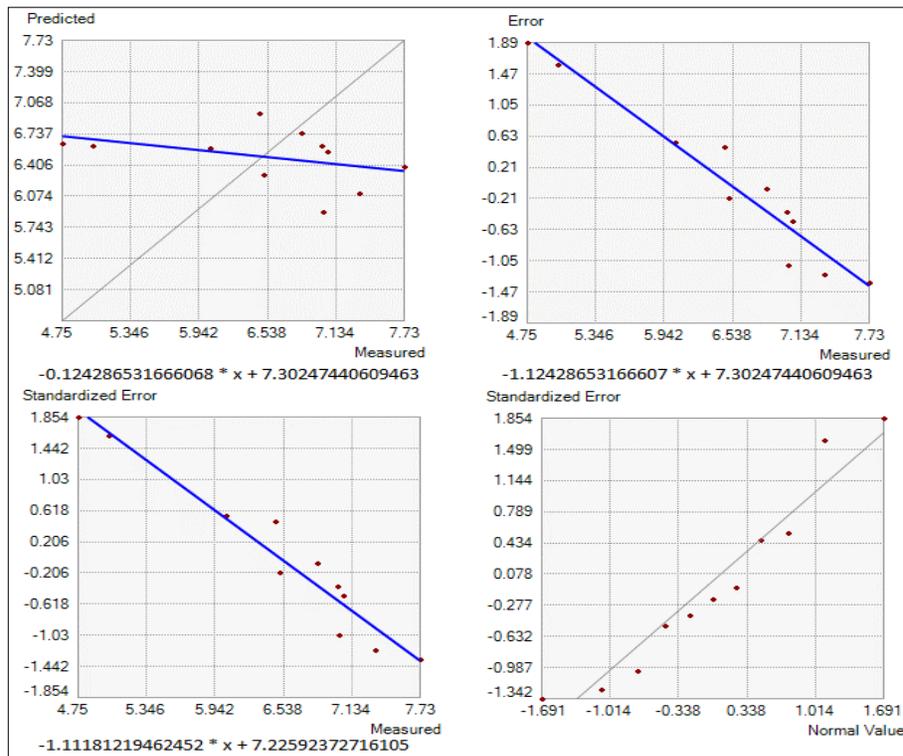
FID	Measured	Predicted	Error	StdError	Stdd_Error	NormValue	Source_ID	Included
0	0.49	0.677702	0.187702	0.095019	1.975408	1.690622	1	Yes
1	0.69	0.501427	-0.188573	0.108975	-1.73042	-1.096804	2	Yes
2	0.57	0.553607	-0.016393	0.109905	-0.149156	-0.229884	3	Yes
3	0.54	0.58041	0.04041	0.127049	0.318062	0	4	Yes
4	0.67	0.262991	-0.407009	0.187257	-2.17353	-1.690622	5	Yes
5	0.23	0.359048	0.129048	0.106488	1.211855	1.096804	6	Yes
6	0.24	0.338665	0.098665	0.089383	1.103849	0.747859	7	Yes
7	0.42	0.30697	-0.11303	0.085478	-1.322329	-0.472789	8	Yes
8	0.4	0.446088	0.046088	0.104355	0.441643	0.229884	9	Yes
9	0.49	0.549305	0.059305	0.121132	0.489587	0.472789	10	Yes
10	0.66	0.489923	-0.170077	0.10828	-1.570713	-0.747859	11	Yes



Anexo H. Validación cruzada para Ca, Mg, C, Fe, Mn, Zn, Cu, B y Al

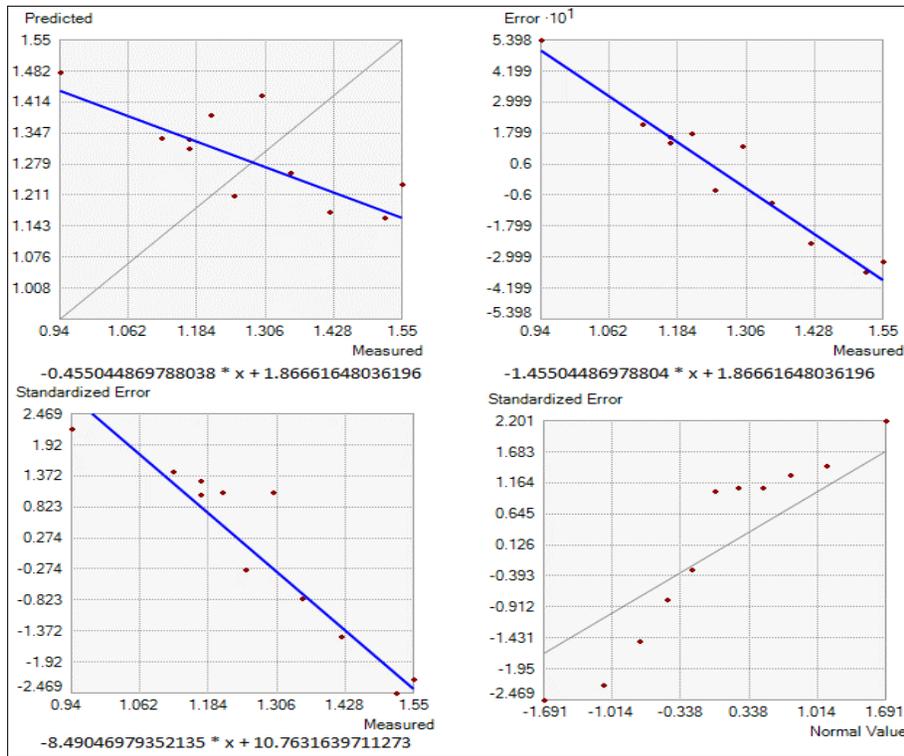
Ca

FID	Measured	Predicted	Error	StdError	StdErrorNormValue	Source_ID	Included
0	6.83	6.97579	0.14579	0.837589	0.174059	0.395725	1 Yes
1	7.01	7.016113	0.006113	0.851928	0.007175	0.194028	2 Yes
2	7.06	7.012652	-0.047348	0.805041	-0.058814	-0.395725	3 Yes
3	6.47	6.98781	0.51781	0.844089	0.613454	0.615141	4 Yes
4	7.02	6.040713	-0.979287	0.994614	-0.98459	-0.869424	5 Yes
5	4.75	6.573745	1.823745	0.875514	2.083058	1.768825	6 Yes
6	7.34	5.768913	-1.571087	0.856839	-1.833584	-1.768825	7 Yes
7	6.51	5.801939	-0.708061	0.854895	-0.828244	-0.615141	8 Yes
8	5.01	6.610489	1.600489	0.84207	1.900659	1.19838	9 Yes
9	6.04	6.815753	0.775753	0.854523	0.907819	0.869424	10 Yes
10	7.73	6.494264	-1.235736	0.849377	-1.454873	-1.19838	11 Yes
11	7.06	7.012652	-0.047348	0.805041	-0.058814	-0.194028	12 Yes
12	7.06	7.012652	-0.047348	0.805041	-0.058814	0	13 Yes



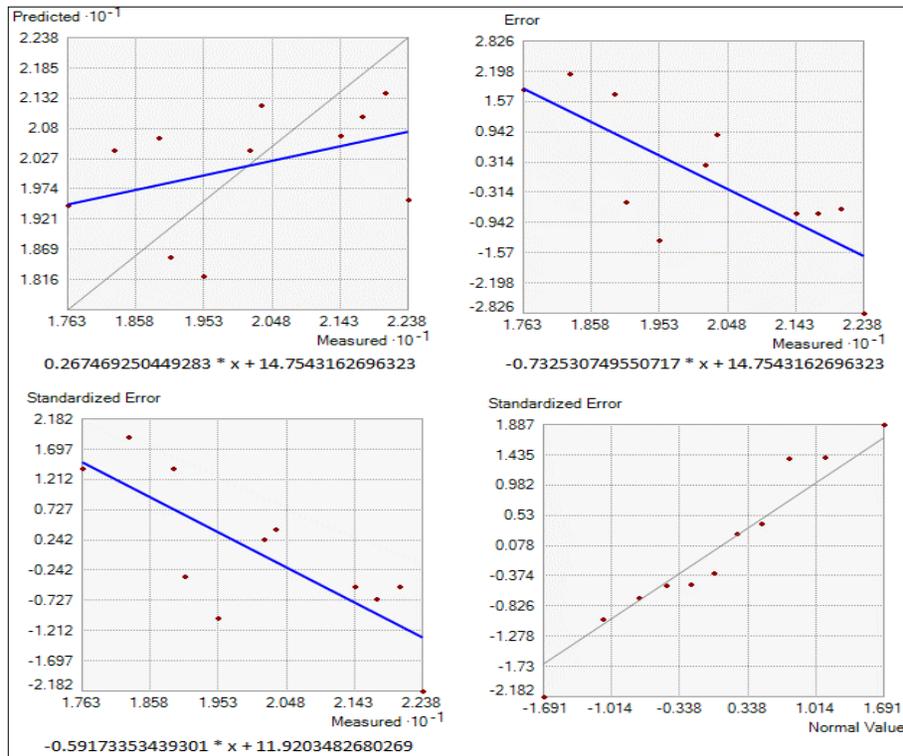
Mg

FID	Measured	Predicted	Error	StdError	Stdd_Error	NormValue	Source_ID	Included
0	1.17	1.333476	0.163476	0.126875	1.288482	0.747859	1	Yes
1	1.25	1.20878	-0.04122	0.144658	-0.284945	-0.229884	2	Yes
2	1.12	1.334878	0.214878	0.14816	1.450311	1.096804	3	Yes
3	1.42	1.174329	-0.245671	0.166144	-1.478666	-0.747859	4	Yes
4	0.94	1.479826	0.539826	0.245209	2.201492	1.690622	5	Yes
5	1.55	1.233778	-0.316222	0.142055	-2.226061	-1.096804	6	Yes
6	1.3	1.428756	0.128756	0.119054	1.081489	0.229884	7	Yes
7	1.35	1.259734	-0.090266	0.113762	-0.793461	-0.472789	8	Yes
8	1.17	1.313673	0.143673	0.139422	1.030487	0	9	Yes
9	1.21	1.387281	0.177281	0.163539	1.084027	0.472789	10	Yes
10	1.52	1.16134	-0.35866	0.145265	-2.468994	-1.690622	11	Yes



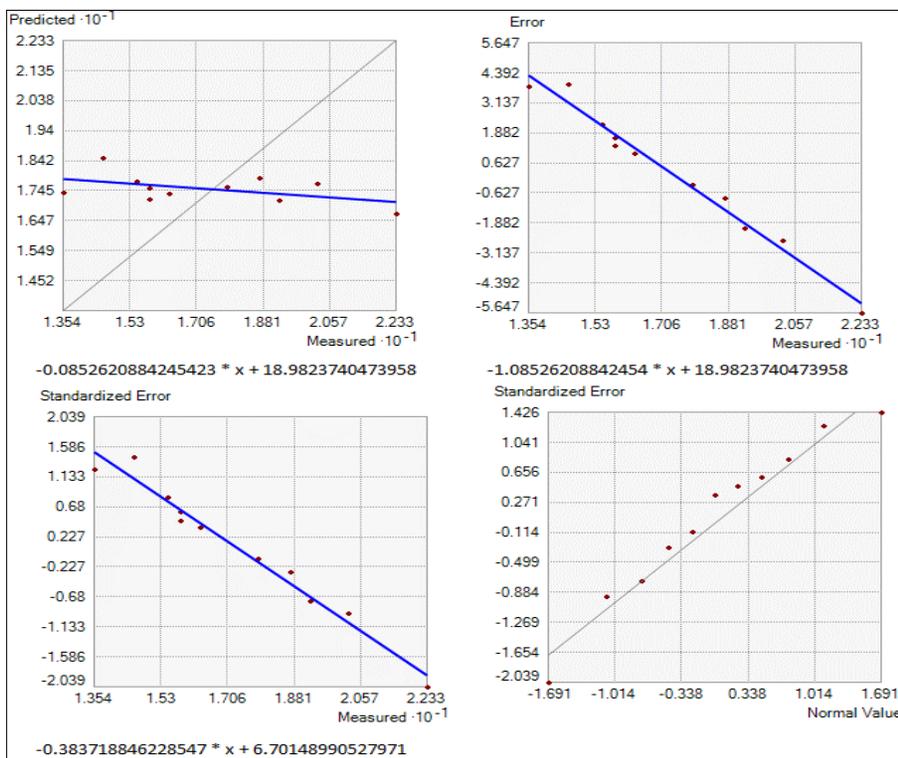
C

FID	Measured	Predicted	Error	StdError	Stdd_Error	NormValue	Source_ID	Included
0	18.27	20.407701	2.137701	1.133046	1.886684	1.690622	1	Yes
1	19.53	18.211463	-1.318537	1.29442	-1.018631	-1.096804	2	Yes
2	17.63	19.455072	1.825072	1.322447	1.380072	0.747859	3	Yes
3	19.06	18.555556	-0.504444	1.490715	-0.338391	0	4	Yes
4	20.32	21.210903	0.890903	2.156435	0.413137	0.472789	5	Yes
5	22.06	21.416786	-0.643214	1.270152	-0.506407	-0.229884	6	Yes
6	21.74	21.000288	-0.739712	1.063647	-0.695448	-0.747859	7	Yes
7	20.16	20.412766	0.252766	1.016729	0.248607	0.229884	8	Yes
8	18.9	20.630627	1.730627	1.243119	1.392165	1.096804	9	Yes
9	21.43	20.681352	-0.748648	1.459706	-0.512875	-0.472789	10	Yes
10	22.38	19.554054	-2.825946	1.294984	-2.182225	-1.690622	11	Yes



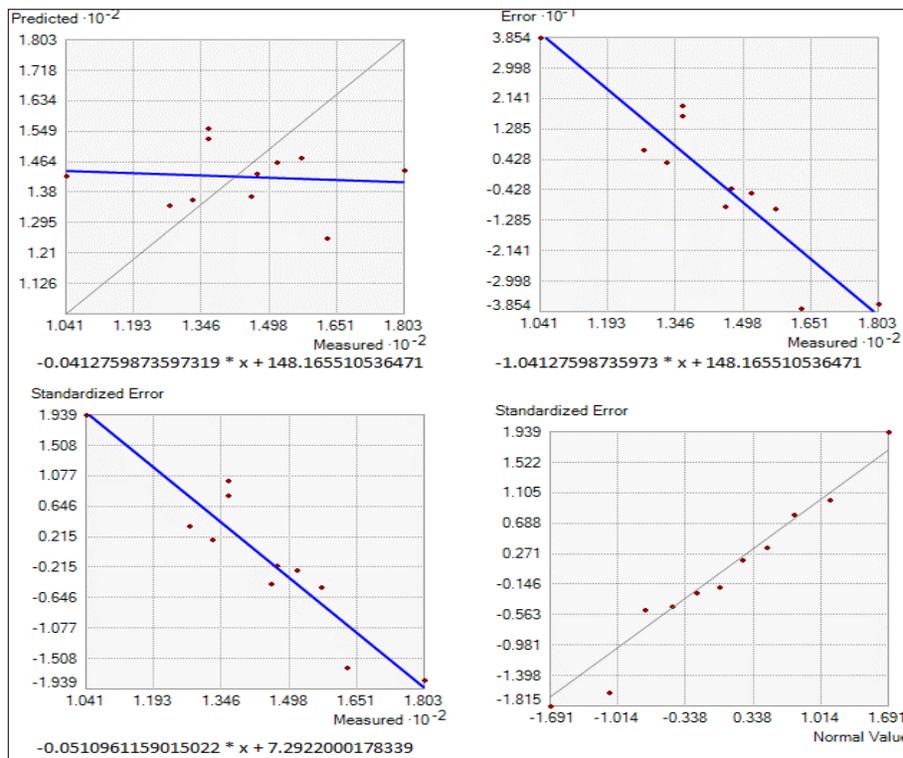
Fe

FID	Measured	Predicted	Error	StdError	Stdd_Error	NormValue	Source_ID	Included
0	14.57	18.51321	3.94321	2.765226	1.425999	1.690622	1	Yes
1	19.23	17.129634	-2.100366	2.832308	-0.741574	-0.747859	2	Yes
2	17.85	17.558325	-0.291675	2.770721	-0.105271	-0.229884	3	Yes
3	15.83	17.529316	1.699316	2.832752	0.599881	0.472789	4	Yes
4	13.54	17.388519	3.848519	3.066719	1.25493	1.096804	5	Yes
5	15.82	17.163035	1.343035	2.831796	0.47427	0.229884	6	Yes
6	16.34	17.363034	1.023034	2.778105	0.368249	0	7	Yes
7	15.49	17.747356	2.257356	2.753544	0.8198	0.747859	8	Yes
8	22.33	16.683001	-5.646999	2.769796	-2.038778	-1.690622	9	Yes
9	20.26	17.6697	-2.5903	2.782259	-0.931006	-1.096804	10	Yes
10	18.7	17.864599	-0.835401	2.772252	-0.301344	-0.472789	11	Yes



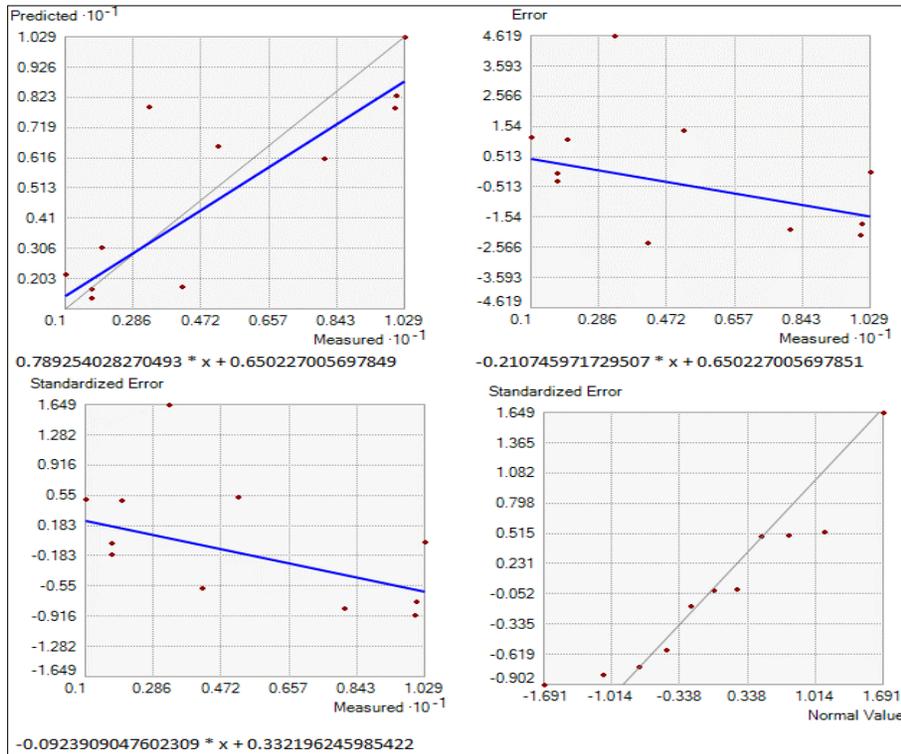
Mn

FID	Measured	Predicted	Error	StdError	Stdd_Error	NormValue	Source_ID	Included
0	136.07	155.62667	19.55667	19.442703	1.005862	1.096804	1	Yes
1	180.31	144.032351	36.277649	-19.990086	-1.814782	-1.690622	2	Yes
2	157.11	147.46116	-9.64884	19.682649	-0.490221	-0.747859	3	Yes
3	136.14	152.769902	16.629902	20.776764	0.800409	0.747859	4	Yes
4	162.92	125.237888	-37.682112	-23.086509	-1.632214	-1.096804	5	Yes
5	104.1	142.642501	38.542501	19.873643	1.939378	1.690622	6	Yes
6	127.34	134.389131	7.049131	19.397	0.363413	0.472789	7	Yes
7	132.52	136.048568	3.528568	19.203389	0.183747	0.229884	8	Yes
8	145.61	136.82699	-8.78301	19.56667	-0.448876	-0.472789	9	Yes
9	147.04	143.253863	-3.786137	19.736498	-0.191834	0	10	Yes
10	151.44	146.290768	-5.149232	19.56375	-0.263203	-0.229884	11	Yes



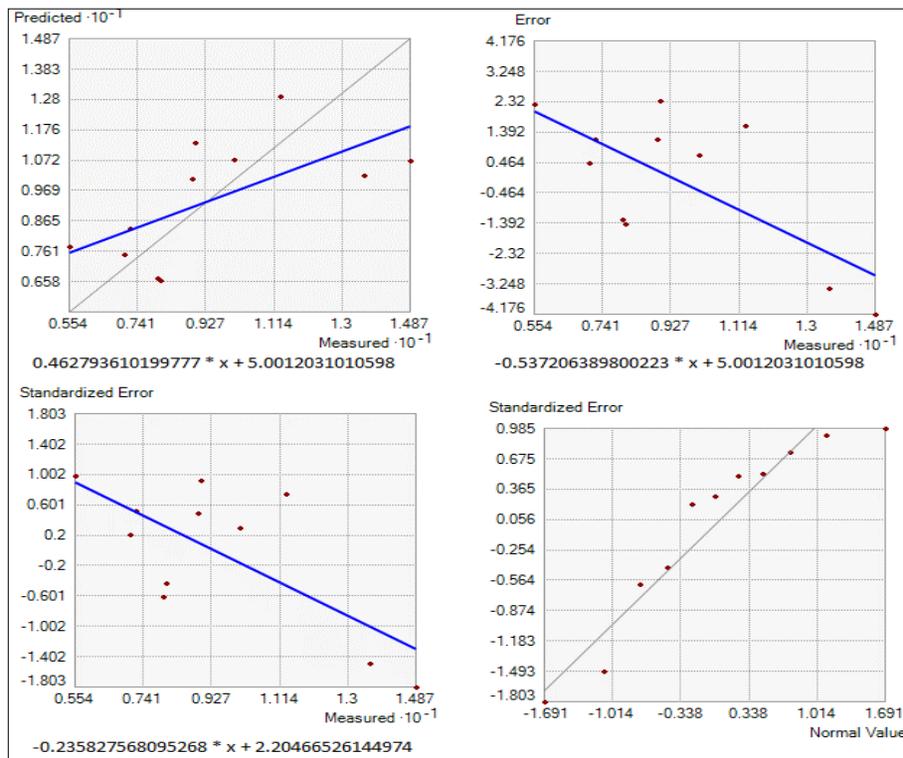
Zn

FID	Measured	Predicted	Error	StdError	Stdd_Error	NormValue	Source_ID	Included
0	10.29	10.305326	0.015326	2.163478	0.007084	0.229884	1	Yes
1	10.05	8.252815	-1.797185	2.480786	-0.724442	-0.747859	2	Yes
2	8.08	6.202499	-1.877501	2.502308	-0.750308	-1.096804	3	Yes
3	3.29	7.702521	4.412521	2.891175	1.526203	1.690622	4	Yes
4	4.17	2.027604	-2.142396	4.253883	-0.503633	-0.472789	5	Yes
5	1	2.221527	1.221527	2.424937	0.503735	0.747859	6	Yes
6	1.71	1.391051	-0.318949	2.034951	-0.156735	-0.229884	7	Yes
7	1.72	1.643989	-0.076011	1.946014	-0.03906	0	8	Yes
8	1.99	3.022687	1.032687	2.375939	0.434644	0.472789	9	Yes
9	5.16	6.704812	1.544812	2.75883	0.559952	1.096804	10	Yes
10	10.01	7.907875	-2.102125	2.465447	-0.852634	-1.690622	11	Yes



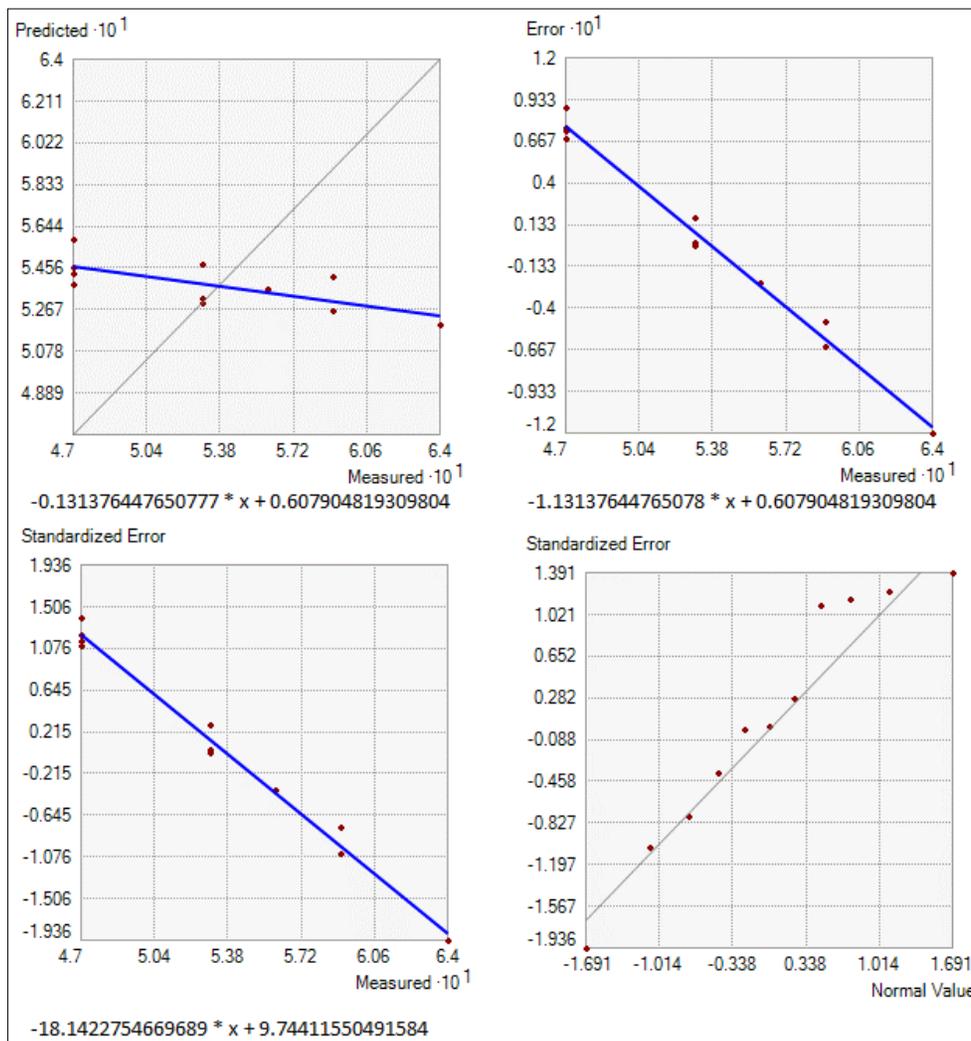
Cu

FID	Measured	Predicted	Error	StdError	Stdd_Error	NormValue	Source_ID	Included
0	11.31	12.909453	1.599453	2.164885	0.738817	0.747859	1	Yes
1	14.87	10.694201	-4.175799	2.316109	-1.802937	-1.690622	2	Yes
2	10.06	10.73572	0.67572	2.268701	0.297844	0	3	Yes
3	8.98	11.335487	2.355487	2.561266	0.919657	1.096804	4	Yes
4	8.03	6.620987	-1.409013	3.27491	-0.430245	-0.472789	5	Yes
5	5.54	7.775633	2.235633	2.269579	0.985043	1.690622	6	Yes
6	7.97	6.687576	-1.282424	2.112659	-0.607019	-0.747859	7	Yes
7	7.05	7.488582	0.438582	2.073774	0.21149	-0.229884	8	Yes
8	7.21	8.384634	1.174634	2.249194	0.522247	0.472789	9	Yes
9	8.89	10.071832	1.181832	2.369394	0.498791	0.229884	10	Yes
10	13.61	10.217525	-3.392475	2.268851	-1.495239	-1.096804	11	Yes



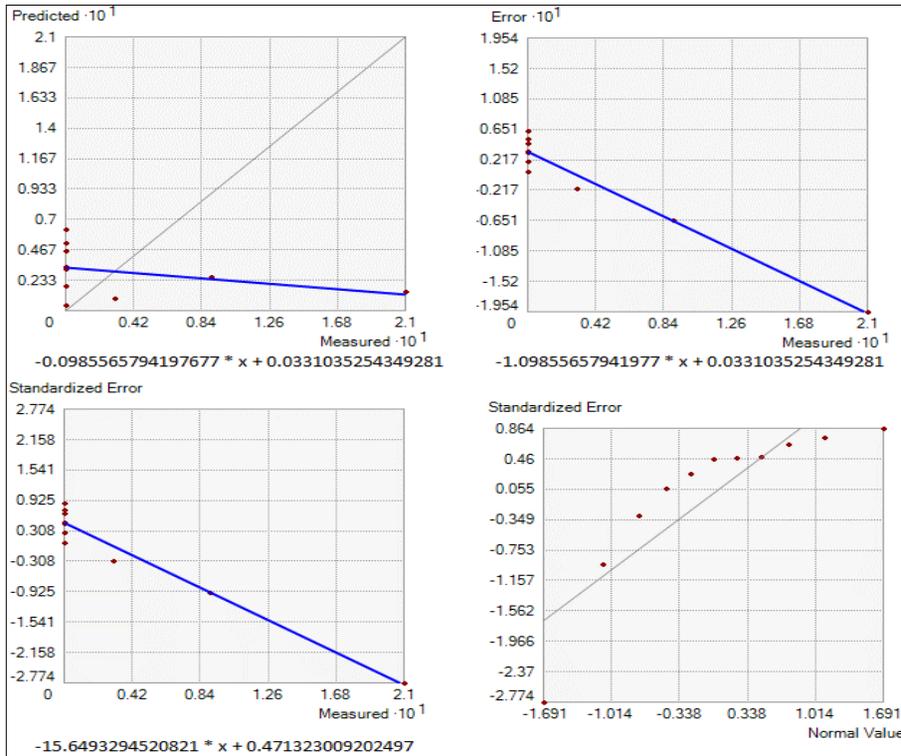
B

FID	Measured	Predicted	Error	StdError	Stdd_Error	NormValue	Source_ID	Included
0	0.56	0.53625	-0.02375	0.062357	-0.380871	-0.472789	1	Yes
1	0.47	0.543333	0.073333	0.063501	1.154831	0.747859	2	Yes
2	0.53	0.532	0.002	0.06166	0.032436	0	3	Yes
3	0.47	0.545556	0.075556	0.061971	1.219208	1.096804	4	Yes
4	0.53	0.53	0	0.064402	0	-0.229884	5	Yes
5	0.47	0.558333	0.088333	0.063501	1.391046	1.690622	6	Yes
6	0.59	0.541429	-0.048571	0.06285	-0.772814	-0.747859	7	Yes
7	0.53	0.5475	0.0175	0.062357	0.280642	0.229884	8	Yes
8	0.47	0.538	0.068	0.06166	1.102815	0.472789	9	Yes
9	0.59	0.526	-0.064	0.06166	-1.037944	-1.096804	10	Yes
10	0.64	0.52	-0.12	0.061971	-1.93639	-1.690622	11	Yes

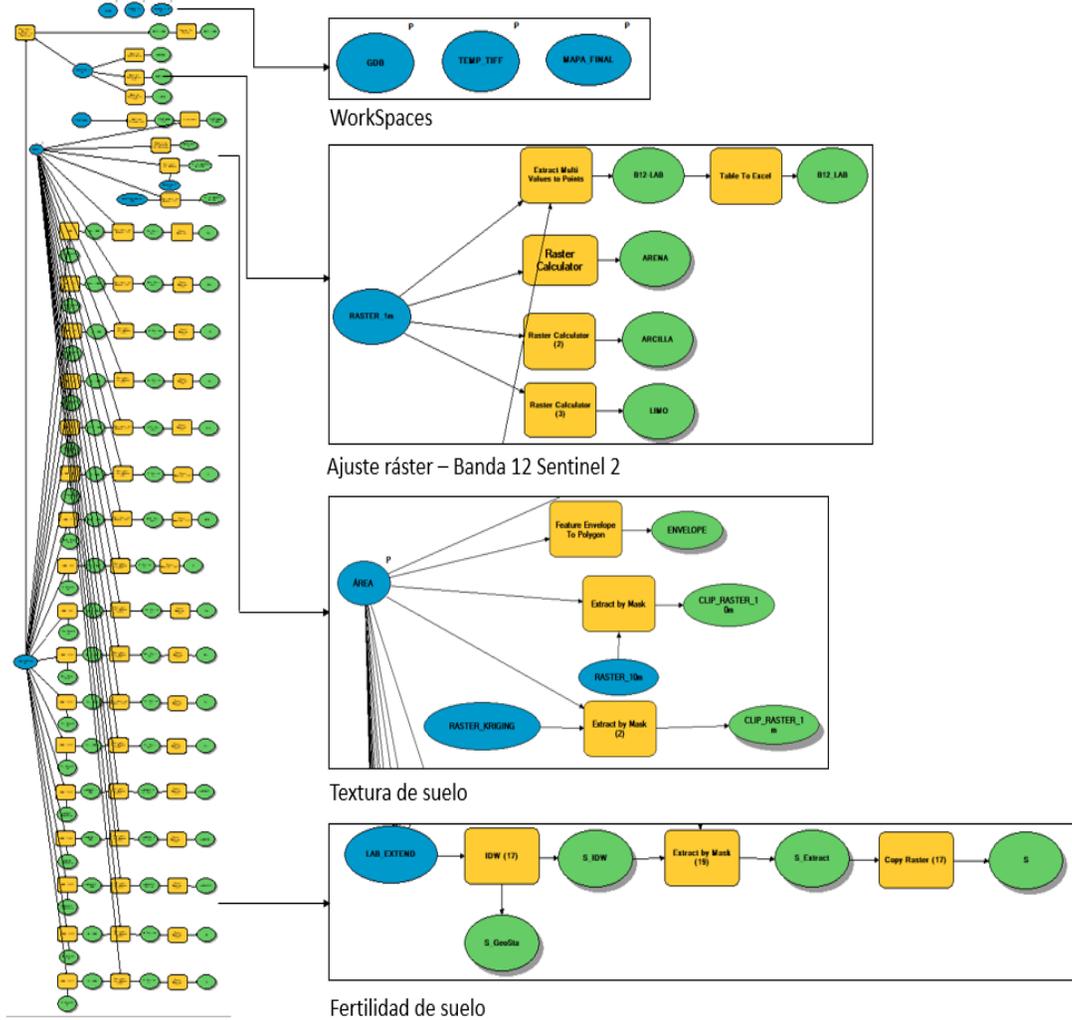


AI

FID	Measured	Predicted	Error	StdError	Stdd_Error	NormValue	Source_ID	Included
0	0.03	0.009816	-0.020184	0.069208	-0.291646	-0.747859	1	Yes
1	0	0.018949	0.018949	0.070426	0.269059	-0.229884	2	Yes
2	0	0.031751	0.031751	0.069049	0.459829	0	3	Yes
3	0	0.004444	0.004444	0.070217	0.063287	-0.472789	4	Yes
4	0	0.062749	0.062749	0.072626	0.863997	1.690622	5	Yes
5	0.21	0.014615	-0.195385	0.070427	-2.774286	-1.690622	6	Yes
6	0	0.051852	0.051852	0.069663	0.744322	1.096804	7	Yes
7	0	0.045577	0.045577	0.069119	0.659399	0.747859	8	Yes
8	0.09	0.025858	-0.064142	0.068647	-0.93437	-1.096804	9	Yes
9	0	0.032573	0.032573	0.068582	0.474954	0.229884	10	Yes
10	0	0.033433	0.033433	0.06883	0.485728	0.472789	11	Yes



Anexo I. Resultado 1, modelo de fertilidad y textura de suelo



Referencias bibliográficas

- Abreu, J. L. (2012). Hipótesis, Método & Diseño de Investigación. *Daena: International Journal of Good Conscience*, 7(2), 187-197.
- Almerfors, J. (2008). *El ascenso de la soja en Paraguay: Un estudio de la demanda mundial por la soja*. [Universidad de Estocolmo]. <http://www.diva-portal.org/smash/get/diva2:199556/FULLTEXT01.pdf>
- Alperín, M. I., Guerrero Borges, V., & Sarandon, R. (2002). Caracterización espacial de los tipos de cobertura de suelo usando técnicas geoestadísticas a partir de información satelital. *Revista de la Facultad de Agronomía*, 105(1), 40-51
- Backoulou, G. F., Elliot, N. C., Giles, K. L., & Mirik, M. (2015). Processed multispectral imagery differentiates wheat crop stress caused by greenbug from other causes. *Computers and Electronics in Agriculture*, 115, 34-39. <https://doi.org/10.1016/j.compag.2015.05.008>
- Bautista-Montealegre, L. G., Bolaños-Benavides, M. M., Fischer, G., & Argüelles-Cárdenas, J. H. (2019). Fertilización con nitrógeno, fósforo, potasio y calcio en mora (*Rubus glaucus* Benth.): Efecto sobre Antracnosis bajo condiciones controladas. *Acta Agronómica*, 68(3), 228-236. <https://doi.org/10.15446/acag.v68n3.68337>
- Beltrán-Morales, F. A., Nieto-Garibay, A., Murillo-Chollet, J. S. A., Ruiz-Espinoza, F. H., Troyo-Diequez, E., Alcalá-Jauregui, J. A., & Murillo-Amador, B. (2019). Contenido inorgánico de nitrógeno, fósforo y potasio de abonos de origen natural para su uso en agricultura orgánica. *Tierra Latinoamericana*, 37(4), 371-378. <https://doi.org/https://doi.org/10.28940/terra.v37i4.520>
- Bokusheva R., Kogan, F., Vitkovskaya, I., Conradt, S., & Batyrbayeva, M. (2016). Satellite-based vegetation health indices as a criteria for insuring against drought-related yield losses. *Agricultural and Forest Meteorology*, 220, 200-206. <https://doi.org/10.1016/j.agrformet.2015.12.066>
- Borràs, J., Delegido, J., Pezzola, A., Pereira, M., Morassi, G., & Camps-Valls, G. (2017). Clasificación de usos del suelo a partir de imágenes Sentinel-2. *Revista de Teledetección*, (48), 55-66. <https://doi.org/10.4995/raet.2017.7133>
- Bousbih, S., Zribi, M., Pelletier, C., Gorraeb, A., Lili-Chabaane, Z., Baghdadi, N., Ben Aissa, N., & Mougenot, B. (2019). Soil Texture Estimation Using Radar and Optical Data

- from Sentinel-1 and Sentinel-2. *Remote Sensing*, 11(13), 1520, 1-20. <https://doi.org/10.3390/rs11131520>
- Campos-Taberner, M., García-Haro, F.J., Martínez, B., & Gilabert, M. A. (2020). Deep learning para la clasificación de usos de suelo agrícola con Sentinel-2. *Revista de Teledetección*, (56), 35-48. <https://doi.org/10.4995/raet.2020.13337>
- Conti, M. E. (2004). Efectos del uso agrícola sobre suelos vertisólicos . *Revista Científica Agropecuaria*, 31 - 36.
- Curcio, D., Ciraolo, G., D'Asaro, F., & Minacapilli, M. (2013). Prediction of soil texture distributions using VNIR-SWIR reflectance spectroscopy. *Procedia Environmental Sciences*, 19, 494-503. <https://doi.org/10.1016/j.proenv.2013.06.056>
- Darius, P., Matamy, S., Salekin, S., Nyirenda, V. R., Murayama, Y., & Ranagalage, M. (2020). Sentinel-2 Data for Land Cover/Use Mapping: A Review. *Remote Sensing*, 12(14), 2291, 1-35. <https://doi.org/https://doi.org/10.3390/rs12142291>
- Eisavi, V., Homayouni, S., Yazdi, A. M., & Alimohammadi, A. (2015). Land cover mapping based on random forest classification of multitemporal spectral and thermal images. *Environmental Monitoring and Assessment*, 187(5), 291, 1-14. <https://doi.org/10.1007/s10661-015-4489-3>
- El Atillah, A., El Morjani, Z. E. A., & Souhassou, M. (2019). Use of the Sentinel-2a multispectral image for litho-structural and alteration mapping in Al Glo'a map sheet (1/50,000) (Bou Azzer–El Graara Inlier, Central Anti-Atlas, Morocco). *Artificial Satellites*, 54(3), 73-96. <https://doi.org/10.2478/arsa-2019-0007>
- Ferraz, G. A. S., Barbosa, B. D. S., Reynaldo, É. F., Santos, S. A., Gonçalves, J. R. M. R., Ferraz, P. F. P. (2019). Spatial variability of soil pH sampled by two methodologies used in precision agriculture in farms under crop rotation. *Dyna*, 86(209), 289-297. <https://doi.org/10.15446/dyna.v86n209.70897>
- Ferrelli, F., Bustos, M. I., Huamantínco-Cisneros, M. A., & Piccolo, M. C. (2015). Utilización de imágenes satelitales para el estudio de la distribución térmica en distintas coberturas del suelo de la ciudad de Bahía Blanca (Argentina). *Revista de Teledetección*, (44), 31-42. <http://dx.doi.org/10.4995/raet.2015.4018>
- Garbanzo-León, J. G., Alemán-Montes, B., Alvarado-Hernández, A., & Henríquez-Henríquez, C. (2017). Validación de modelos geoestadísticos y convencionales en

- la determinación de la variación espacial de la fertilidad de suelos del Pacífico Sur de Costa Rica. *Investigaciones Geográficas, Boletín del Instituto de Geografía*, (93), 20-41. <https://doi.org/10.14350/rig.54706>
- García Nieto, H., García Daguer, R. R., Moreno Sánchez, R., & González Ramos, A. (2002). Uso de sensores remotos y SIG para delimitar los cambios en el uso del suelo agrícola de 1970 a 1997 en el estado de Guanajuato. *Investigaciones Geográficas*, (47), 92-112
- García-Calabrese, M. V., Paniagua, M. T. & Chicaiza, E. (2022). Análisis de la distribución espacial de la precipitación anual (1979-2014) aplicando métodos de interpolación en la Región Occidental del Paraguay. *Revista Geográfica*, (164), 63-81. <https://doi.org/10.35424/regeo.164.2022.1067>
- Garrido Valero, S. (1993). Interpretación de análisis de suelo. *Hojas Divulgadoras*, (5), 1-40. https://www.mapa.gob.es/ministerio/pags/biblioteca/hojas/hd_1993_05.pdf
- Gonzaga Aguilar, C. (2014). *Aplicación de índices de vegetación derivados de imágenes satelitales Landsat 7 ETM+ y ASTER para la caracterización de la cobertura vegetal en la zona centro de la provincia de Loja, Ecuador*. [Tesis de maestría, Universidad Nacional de La Plata]. <http://sedici.unlp.edu.ar/handle/10915/34487>
- González-González, M. G., Gómez, J., Alegre, V., López, S., Blasco, J., Cubero, S., Soria, E., & Chueca, P. (3-6 de septiembre de 2019). *Herramienta para la generación de mapas de rendimiento en cítricos usando los datos de una plataforma de asistencia a la recolección con plataforma de asistencia a la recolección con sistema de clasificación*. [Ponencia]. X Congreso Ibérico de Agroingeniería, Huesca, España. <https://zaguan.unizar.es/record/84425/files/3369.pdf>
- ISO 19115-1:2014. *Geographic information - Metadata - Part 1: Fundamentals*. <https://www.iso.org/standard/53798.html>
- ISO 19157:2013. *Geographic information - Data quality*. <https://www.iso.org/standard/32575.html>
- Jiménez-Moreno, M. J., Rodríguez-Laguna, R., Escalona-Maurice, M. J., Razo-Zarate, R., & Acevedo-Sandoval, O. A. (2019). Análisis de indicadores ambientales

- espaciotemporales de agua, suelo y vegetación. *Revista Mexicana de Ciencias Agrícolas*, 10(7), 1641-1652. <https://doi.org/10.29312/remexca.v10i7.1806>
- Ley 6286 de defensa, restauración y promoción de la agricultura familiar campesina. 17 de mayo de 2019. LEX-FAOC186534. <https://faolex.fao.org/docs/pdf/par186534.pdf>
- Liao, K., Xu, S., Wu, J., & Zhu, Q. (2013). Spatial estimation of surface soil texture using remote sensing data. *Soil Science and Plant Nutrition*, 59(4), 488-500. <https://doi.org/10.1080/00380768.2013.802643>
- Liu, Z. N., Yu, X. Y., Jia, L. F., Wang, Y. S., Song, Y.C., & Meng, H. D. (2021). The influence of distance weight on the inverse distance weighted method for ore-grade estimation. *Scientific Reports*, (1), 2689, 1-8. <https://doi.org/10.1038/s41598-021-82227-y>
- Martín, G. M., Rivera Espinosa, R., Fundora, L. R., Cabrera, A., Martín, N., & Alonso, C. (2018). Evolución de algunas propiedades químicas de un suelo después de 20 años de explotación agrícola. *Cultivos Tropicales*, 39(4), 21-26
- Meza Pérez, G. (2021). Efecto del método de aplicación del fertilizante químico en la productividad del cultivo de café (*Coffea arabica*). *Revista de Investigación en Agroproducción Sostenible*, 5(3), 9-12. <http://dx.doi.org/10.25127/aps.20213.813>
- Molina Aguilar, J. P., Trejo Alonso, J. J., & Gutiérrez López, A. (2018). Aplicación web para referenciar fenómenos meteorológicos en imágenes satelitales infrarrojas. *Revista NTHE*, (24), 84-90
- Nolasco, M., Willington, E. A., & Bocco, M. (1-5 de septiembre de 2014). *Clasificación del uso de suelo en agricultura a partir de series temporales de imágenes* [Objeto de conferencia]. XLIII Jornadas Argentinas de Informática e Investigación Operativa (43JAIIO)-VI Congreso Argentino de AgroInformática (CAI), Buenos Aires, Argentina
- NTC 4611:2021. *Información geográfica. Metadatos. Parte 1: Fundamentos*. <https://tienda.icontec.org/gp-informacion-geografica-metadatos-parte-1-fundamentos-ntc4611-2021.html>
- Núñez-Ravelo, F., Ugas-Pérez, M., Calderón-Castellanos, R., & Rivas-Meriño, F. (2021). Cuantificación del carbono orgánico y materia orgánica en suelos no rizosféricos o cubiertos por *Avicennia germinans* (L.) y *Conocarpus erectus* (L.) emplazados en

- Boca de Uchire, laguna de Unare, Estado de Anzoátegui, Venezuela. *Revista Geográfica de América Central*, 66(1), 371-398. <https://doi.org/http://dx.doi.org/10.15359/rgac.66-1.13>
- Organización de las Naciones Unidas para la Alimentación y la Agricultura, FAO. (2022a). *Propiedades Químicas: Nutrientes para las Plantas*. <https://www.fao.org/soils-portal/soil-survey/clasificacion-de-suelos/sistemas-numericos/propiedades-quimicas/es/#:~:text=En%20el%20suelo%20se%20encuentran,porcentaje%20de%20saturaci%C3%B3n%20de%20bases>
- Organización de las Naciones Unidas para la Alimentación y la Agricultura, FAO. (2022b). *Propiedades Físicas del Suelo*. <https://www.fao.org/soils-portal/soil-survey/propiedades-del-suelo/propiedades-fisicas/es/>
- Padró Garcia, J. C. (2019). *Millora del tractament de les imatges captades pels satèl·lits Landsat-8 i Sentinel-2 mitjançant espectroradiometria de camp i sensors embarcats en Vehicles Aeris no Tripulats (UAV)*. [Tesi Doctoral, Universidad Autònoma de Barcelona]. <http://hdl.handle.net/10803/667180>
- Perret, J., Villalobos Leandro, J. E., Abdalla-Bolaños, K., Fuentes Fallas, C. L., Cuarezma Espinoza, K. M., Macas Amaya, E. N., López Maietta, M. T., & Drewry, D. (2019). Desarrollo de métodos de análisis de espectroscopia y algoritmos de aprendizaje automático para la evaluación de algunas propiedades del suelo en Costa Rica. *Agronomía Costarricense*, 44(2), 139-154. <https://doi.org/10.15517/rac.v44i2.43108>
- Pino Vargas, E., & Huayna, G. (2022). Evolución espacial y temporal de cultivo del olivo por efecto del ataque de plagas, utilizando sensoramiento remoto y procesamiento de imágenes satelitales. *Scientia Agropecuaria*, 13(2), 149-157. <https://doi.org/http://dx.doi.org/10.17268/sci.agropecu.2022.013>
- Ramírez, M., Martínez, L., Montilla, M., Sarmiento, O., Lasso, J., & Díaz, S. (2020). Obtención de coberturas del suelo agropecuarias en imágenes satelitales Sentinel-2 con la inyección de imágenes de dron usando Random Forest en Google Earth Engine. *Revista de Teledetección*, (56), 49-68. <https://doi.org/10.4995/raet.2020.14102>
- Rasche Alvarez, J. W., Gómez, E. J., Fatecha Fois, D. A., & Leguizamón Rojas, C. A. (2020). Compactación del suelo y su efecto en el crecimiento vegetativo de soja,

- maíz y guandú. *Investigación Agraria*, 22(1), 13-21.
<http://dx.doi.org/10.18004/investig.agrar.2020.junio.13-21>
- Rodríguez Briones, E., & Longa Narro, E. R. (2021). *Evaluación del efecto de los fertilizantes químicos y abonos orgánicos en suelos agrícolas con cultivo de papa-Distrito de Sorochuco 2020*. [Tesis, Universidad Privada del Norte].
<https://repositorio.upn.edu.pe/bitstream/handle/11537/28649/Tesis.pdf?sequence=2&isAllowed=y>
- Sainz Rozas, H. R., Angelini, H. P., Larrea, G. E., Avila Manotoa, O. O., Eyherabide, M., Pérez Marino, T., Reussi Calvo, N. I., Carciochi, W., Crespo, C., Barbieri, P., & Wyngaard, N. (30 de marzo-01 de abril de 2022). *Manejo variable de fósforo en trigo: ajuste de la dosis mediante el muestreo de suelo en grilla*. [Infografía]. 2º Congreso Latinoamericano de Agricultura de Precisión, Córdoba, Argentina.
<http://hdl.handle.net/20.500.12123/11708>.
- Toro, G. A., & Melo, C. E. (2009). Aplicación de métodos de interpolación geoestadísticos para la predicción de niveles digitales de una imagen satelital con líneas perdidas y efecto sal y pimienta. *Tecnura*, 12(24), 55-67.
- Trujillo-Jiménez, M. A., Liberoft, A. L., Pessacg, N., Pacheco, C., & Flaherty, S. (18-29 de octubre de 2021). *Metodología de clasificación automática de uso y cobertura de suelo: uso de métodos de aprendizaje automático y teledetección para clasificación de uso y cobertura del suelo en un valle semiárido de la Patagonia* [Objeto de Conferencia]. L Jornadas Argentinas de Informática e Investigación Operativa (50 JAIO)-XIII Congreso de AgroInformática (CAI 2021). Buenos Aires, Argentina
- USGS (17 de mayo de 2021). Sentinel-2 Data Dictionary. Science for a Changing World:
<https://www.usgs.gov/centers/eros/science/Sentinel-2-data-dictionary>
- Vargas Diaz, R. E., Wilches Ortiz, W. A., & Espitia Malagón, E. M. (2022). Efecto del establecimiento de sistemas de rotación para el cultivo de la papa sobre las características químicas y físicas del suelo. *Siembra*, 9(2), e4023, 2-9.
<https://doi.org/https://doi.org/10.29166/siembra.v9i2.4023>
- Vega-Blancas, V. J., Fernández-Reynoso, D. S., Macedo-Cruz, A., Ríos-Berber, J. D., & Ruiz-Bello, A. (2022). Análisis de la fertilidad del suelo mediante la validación e

- interpolación Kriging de sus variables. *Terra Latinoamericana*, 40, e1573. 1-12. <https://doi.org/10.28940/terra.v40i0.1573>
- Villatoro, M., Henríquez, C., & Sancho, F. (2008). Comparación de los interpoladores IDW y Kriging en la variación espacial de pH, Ca, CICE y P del suelo. *Agronomía Costarricense*, 32(1), 95-105.
- Volverás Mambuscay, B., & Amézquita Collazos, E. (2009). Estabilidad estructural del suelo bajo diferentes sistemas y tiempo de uso en laderas andinas de Nariño, Colombia. *Acta Agronómica*, 58(1), 35-39
- Zambrano-Yepes, J., Herrera-Valencia, W., & Motta-Delgado, P. A. (2020). Concentración de los macronutrientes del suelo en áreas de pastoreo del departamento de Caquetá, Amazonia colombiana. *Ciencia y Tecnología Agropecuaria*, 21(3), e1673, 1-12. https://doi.org/10.21930/rcta.vol21_num3_art:1673

