



Universidad Autónoma de Querétaro
Facultad de Ingeniería
Maestría en Ciencias

“Uso de imágenes multiespectrales para determinar textura en suelos
agrícolas”

Tesis

Que como parte de los requisitos para obtener el Grado de
Maestro en Ciencias (Hidrología Ambiental)

Presenta:

Ing. Ma. Clara Elena Mendoza González

Dirigida por:

Dr. Carlos Alberto Chávez García

Dr. Carlos Alberto Chávez García

Presidente

Dr. Enrique González Sosa

Secretario

Dr. Josué de Jesús Trejo Alonso

Vocal

Dr. José Antonio Quevedo Tiznado

Suplente

Dra. Mónica Cervantes Jiménez

Suplente

Centro Universitario, Querétaro, Qro.

Fecha de aprobación por el Consejo Universitario (11 de diciembre de 2019)

México

Agradecimientos

A Dios por la maravillosa oportunidad de vivir cada momento de la vida, sabiendo que todo es como debe ser.

Al Consejo Nacional de Ciencia y Tecnología (CONACYT) por ser el pilar de la investigación en México y el apoyo financiero para la culminación de este Posgrado.

A la Universidad Autónoma de Querétaro y en especial a la Facultad de Ingeniería por darme la oportunidad de realizar mis estudios de Posgrado.

A cada uno de mis profesores, por compartir sus conocimientos y contribuir con cada una de sus enseñanzas a mi crecimiento personal, profesional y emocional.

Al Dr. Carlos Alberto Chávez García por todas las facilidades y apoyo para llevar a cabo éste proyecto de tesis, así como todo el apoyo a lo largo de todo el posgrado. Gracias infinitas.

A Sistemas y Soluciones de Mapeo Aéreo Profesional (Sysmap SA de CV) por el soporte y ayuda en la toma de imágenes.

Al Laboratorio de Suelos de la Universidad Autónoma de Querétaro por el apoyo para el análisis de las muestras de suelo.

Al Dr. Enrique González Sosa por todas las observaciones y contribuciones realizadas para complementar y mejorar este proyecto de tesis.

Al Dr. Josué de Jesús Trejo Alonso por la revisión y atinadas observaciones en el desarrollo del trabajo y para la culminación de este proyecto de tesis.

A la Dra. Mónica Cervantes Jiménez y al Dr. José Antonio Quevedo Tizado por las observaciones y contribuciones realizadas en pro de la mejora y culminación de éste proyecto.

A todos mis compañeros y amigos de posgrado, por ser apoyo, ejemplo e inspiración a lo largo de esta etapa.

A mis papás José Ricardo Mendoza Hernández y Josefina González Álvarez, por quienes hasta hoy me encuentro aquí.

A todas las personas que me apoyaron a lo largo de este proceso, gracias por ser y estar.

GRACIAS, GRACIAS, GRACIAS

Dirección General de Bibliotecas UAQ

ÍNDICE

ÍNDICE	4
1 INTRODUCCIÓN	12
1.1 Planteamiento del problema y justificación del proyecto	13
2 ANTECEDENTES.....	15
3 MARCO TEÓRICO.....	19
3.1 Conceptos generales.....	19
3.1.1 Textura del suelo.....	19
3.1.2 Percepción remota.....	19
3.1.3 Radiación electromagnética	21
3.1.4 Espectro electromagnético	22
3.1.5 Espectroscopía.....	23
3.1.6 Espectrometría.....	25
3.1.7 Imagen multiespectral	25
3.1.1 Resolución.....	26
3.2 Construcción del marco teórico	26
3.2.1 Polígonos o zonas de entrenamiento (áreas de vuelo)	27
3.2.2 Muestreo de suelos.....	28
3.2.3 Vehículos aéreos no tripulados	29
3.2.4 Variables e índices empleados	30
3.2.5 Generación del modelo	32
3.2.6 Validación del modelo	35
4 Hipótesis y objetivos	36
Existe correlación entre la reflectancia espectral de los suelos y su contenido de arena, limo y arcilla.....	36
5 Objetivo general	36
5.1 Objetivos específicos	36
6 METODOLOGÍA	37

6.1	Descripción de la zona de estudio.....	37
6.2	Identificación de área de muestreo (zona de entrenamiento).....	37
6.3	Elaboración de plan de vuelos.....	40
6.4	Calibración de la reflectancia.....	42
6.5	Ubicación de áreas de muestreo.....	44
6.6	Vuelos en las zonas de interés.....	45
6.7	Obtención de muestras de suelo.....	46
6.8	Conversión de niveles digitales de las imágenes espectrales a reflectancia y elaboración de ortomosaico.....	46
6.9	Obtención de textura de las muestras de suelo en laboratorio.....	46
6.10	Extracción de valores de reflectancia por ancho de banda de los polígonos de entrenamiento y análisis estadístico.....	47
6.11	Selección de índices.....	47
6.12	Análisis de correlación:.....	49
6.13	Generación de modelo.....	49
6.14	Validación de resultados.....	49
7	RESULTADOS.....	49
7.1	Procesamiento de imágenes.....	50
7.2	Análisis estadístico básico.....	51
7.3	Análisis de correlación.....	62
7.4	Regresión lineal múltiple.....	65
7.5	Modelo exponencial.....	69
7.6	Regresión polinomial.....	71
7.7	Modelos por textura.....	72
8	VALIDACIÓN.....	77
8.1	Aplicación del modelo.....	81
9	CONCLUSIONES.....	86
9.1	Recomendaciones.....	88
10	REFERENCIAS.....	89

ÍNDICE DE TABLAS

Tabla 1. Diámetros de partículas del suelo (USDA).....	19
Tabla 2. Número de muestras colectadas y profundidad de muestreo de algunos autores que han estudiado suelos con percepción remota	28
Tabla 3. Importancia de los componentes del Análisis de componentes principales	54
Tabla 4. Componentes principales de las 4 bandas en estudio	55
Tabla 5. Coeficientes de correlación de Pearson de los diferentes índices y los contenidos de arena, limo y arcilla.	62
Tabla 6. Correlogramas de arcilla en las bandas extraídas de Sentinel-2 e índices espectrales calculados en diferentes ubicaciones (Gholizadeh <i>et al.</i> , 2018).	65
Tabla 7. Coeficientes de correlación de Pearson entre las fracciones del suelo y la reflectancia por banda de la clase textural Arcilla	73
Tabla 8. Coeficientes de correlación de Pearson entre las fracciones del suelo y la reflectancia por banda de la clase textural Franco arcilloso	74
Tabla 9. Coeficientes de correlación de Pearson entre las fracciones del suelo y la reflectancia por banda de la clase textural Franco	75
Tabla 10. Coeficientes de correlación de Pearson entre las fracciones del suelo y la reflectancia por banda de la clase textural Franco arenoso	76
Tabla 11. Coeficiente de determinación y Raíz del error cuadrático medio por modelo.....	80

ÍNDICE DE FIGURAS

Figura 1. Curvas característica de reflectancia espectral de suelos con altos contenidos de arena, limo y arcilla encontrada por Condit (1972)	16
Figura 2. Triángulo de textura de la USDA (Extraído de González-Naranjo, Leal, Lillo, de Bustamente y Palacios-Díaz, 2012)	20
Figura 3. Espectro electromagnético (Extraído de Jiménez, 2015)	23
Figura 4. Metodología de desarrollo del estudio.....	38
Figura 5. Plano de información textural disponible del distrito de riego 023 “San Juan del Río, Qro”. FUENTE: Módulos Uno y Dos, Distrito de riego 023 (2018).	39
Figura 6. Ubicación de los sitios de muestreo	40
Figura 7. Dron eBee con el que se tomaron los datos de reflectancia	41
Figura 8. Sensor multiespectral Parrot Sequoia	42
Figura 9. Ejemplo de un plan de vuelo generado en el software eMotion	43
Figura 10. Objetivo de campo para calibración de reflectancia.....	43
Figura 11. Calibración de los valores de reflectancia con la ayuda del objetivo de campo..	44
Figura 12. Marcas ubicadas en el suelo para la toma de imágenes multiespectrales.	45
Figura 13. Inicio de vuelo 1	45
Figura 14. Muestreo de suelos e identificación de muestras de las áreas de interés.....	46
Figura 15. Ortomosaico y modelo de superficie digital disperso (DSM) correspondiente (Vuelo 1)	50
Figura 16. Ortomosaico y modelo de superficie digital disperso (DSM) correspondiente (Vuelo 2).	51
Figura 17. Imagen tomada por el sensor en el ancho de banda 550 nm (verde).	52
Figura 18. Imagen tomada por el sensor en la banda 790 nm (Infrarojo cercano).	52
Figura 19. Imagen tomada por el sensor en el ancho de banda 660 nm (rojo).	53
Figura 20. Imagen tomada por el sensor en el ancho de banda 735 nm (Borde rojo).	53
Figura 21. Reflectancia en la banda verde por clase textural.....	56
Figura 22. Reflectancia en la banda roja por clase textural	56
Figura 23. Reflectancia en la banda infrarrojo cercano por clase textural.....	56

Figura 24. Reflectancia en la banda borde rojo por clase textural	56
Figura 25. Cociente B2/B4 por clase textural	57
Figura 26. Cociente B2/BR por clase textural	57
Figura 27. Cociente B2/B3 por clase textural	58
Figura 28. Cociente B4/B2 por clase textural	58
Figura 29. Cociente B4/BR por clase textural	58
Figura 30. Cociente B4/B3 por clase textural	58
Figura 31. Cociente BR/B2 por clase textural	59
Figura 32. Cociente BR/B4 por clase textural	59
Figura 33. Cociente BR/B3 por clase textural	59
Figura 34. Cociente B3/B2 por clase textural	59
Figura 35. Cociente B3/B4 por clase textural	60
Figura 36. Cociente B3/BR por clase textural	60
Figura 37. Índice GRVI por clase textural	60
Figura 38. Índice RI por clase textural	60
Figura 39. Índice BI por clase textural	61
Figura 40. Índice CI por clase textural	61
Figura 41. Índice de carbonato por clase textural	62
Figura 42. Coeficientes de correlación de Pearson entre las variables del estudio	64
Figura 43. Relación entre el contenido de arena y la reflectancia de las 4 bandas objeto de estudio	66
Figura 44. Relación entre el contenido de limo y la reflectancia de las 4 bandas objeto de estudio	67
Figura 45. Relación entre el contenido de arcilla y las ocho variables con las que más se correlaciona	68
Figura 46. Linealización de la relación entre la banda verde y el contenido de arena	70
Figura 47. Linealización de la relación entre la banda verde y el contenido de arcilla	71
Figura 48. Relación de las fracciones del suelo y la reflectancia por banda de a clase textural Arcilla	73

Figura 49. Relación de las fracciones del suelo y la reflectancia por banda de a clase textural Franco arcilloso.....	74
Figura 50. Relación de las fracciones del suelo y la reflectancia por banda de a clase textural Franco	75
Figura 51. Relación de las fracciones del suelo y la reflectancia por banda de a clase textural Franco arenoso.....	76
Figura 52. Datos de arena medidos contra los estimados modelo lineal ($R^2= 0.55$).....	77
Figura 53. Datos de arcilla medidos contra los estimados modelo lineal ($R^2= 0.53$)	78
Figura 54. Datos de arena medidos contra los estimados modelo exponencial ($R^2= 0.38$)..	79
Figura 55. Datos de arcilla medidos contra los estimados modelo exponencial ($R^2= 0.34$)..	79
Figura 56. Datos de arena medidos contra los estimados modelo polinomial ($R^2= 0.39$)	80
Figura 57. Datos de arena medidos contra los estimados modelo polinomial ($R^2= 0.41$)	81
Figura 58. Funciones de la calculadora raster disponible en QGIS.	82
Figura 59. Contenido de arena por pixel obtenido con el modelo ($R^2=0.56$)	83
Figura 60. Contenido de arcilla por pixel obtenido con el modelo ($R^2=0.54$).....	84
Figura 61. Contenido de limo obtenido por diferencia	85

Resumen

Es importante determinar aquellas propiedades de los suelos que influyen en su capacidad de infiltración y retención del agua, para mejorar su manejo en agricultura. Sin embargo, la medición directa de estas propiedades es lenta, costosa y, a veces, poco fiable debido a la heterogeneidad del suelo y los errores experimentales. Estas propiedades se pueden estimar a partir de datos indirectos como la textura del suelo por medio de funciones de pedotransferencia. La presente investigación se centra en el uso de las herramientas de las que dispone la percepción remota en la identificación del contenido de arena, limo y arcilla (textura) en los suelos agrícolas, haciendo uso de datos obtenidos de imágenes multiespectrales provenientes de vehículos aéreos no tripulados. Se volaron un total de 100 polígonos de entrenamiento con sus respectivas muestras de suelo para la generación del modelo. Se generaron 4 variables independientes (reflectancia en cuatro diferentes bandas: 550 nm –verde-, 660 nm –rojo-, 790 nm -infrarrojo cercano- y 735 nm -borde rojo-) y 3 variables dependientes (porcentaje de arena, limo y arcilla). Se obtuvieron índices espectrales provenientes de la literatura calculados a partir de las 4 bandas obtenidas con el dron. Se obtuvieron modelos: lineal multivariable, exponencial y polinomial con la reflectancia de las 4 bandas. La banda con el mayor coeficiente de correlación de Pearson al relacionarla con los contenidos de arena y arcilla fue la verde (0.62 y -0.63 respectivamente). Los mayores coeficientes de determinación se obtuvieron al modelar el contenido de arena y arcilla por medio de una regresión lineal múltiple, empleando las 4 bandas espectrales objeto de éste estudio. Se obtuvo un R^2 de 0.56 en el modelo generado para determinar arena y 0.54 para determinar arcilla. Los modelos obtenidos fueron empleados para generar tres mapas con la ayuda de QGIS en los ortomosaicos generados en los vuelos; uno para determinar contenido de arena, otro para limo y el último para contenido de arcilla.

PALABRAS CLAVE: Imágenes multiespectrales, Reflectancia, Textura del suelo, Arena, Limo y Arcilla

Abstract

The study of soils properties and their influence on water infiltration its very important if we are to improve water management in agriculture. However, the direct measurement of these properties is slow, expensive and sometimes unreliable due to soil heterogeneity and experimental errors. These properties can be estimated from indirect data such as soil texture through pedotransfer functions. The present research focuses on the use of the available tools in remote sensing to identify the content of sand, silt and clay in agricultural soils by using data obtained from multispectral images from unmanned aerial vehicles. A total of 100 training polygons were obtained with their respective soil samples for the generation of the model. Four independent variables were initially generated (reflectance in four different bands: 550 nm - green -, 660 nm - red -, 790 nm - near infrared - and 735 nm - red edge -) and 3 dependent variables (percentage of sand, silt and clay). Spectral indices from the literature were calculated from the 4 bands obtained with the drone. The following models were obtained: linear multivariable, exponential and polynomial with the reflectance of the 4 bands. The band with the highest Pearson correlation coefficient when related to sand and clay contents was the green band (0.62 nm and -0.63 nm respectively). The highest determination coefficients were obtained by modeling the sand and clay content with a multiple linear regression, using the 4 spectral bands object of this study. An R² of 0.56 was obtained in the model generated to determine sand and 0.54 to determine clay. The models were used to generate three maps with the help of QGIS in the orthomosaics obtained on the flights; one to determine sand content, another for silt and the last for clay content.

KEYWORDS: Multispectral imagery, reflectance, soil texture, sand, silt, clay.

1 INTRODUCCIÓN

Una de tantas desventajas en agricultura tradicional es que considera un manejo uniforme del suelo sin tomar en cuenta la heterogeneidad espacial de sus propiedades. Esta heterogeneidad influye en la distribución y almacenamiento del agua de riego, drenaje interno, fertilidad, movimiento de solutos a través de las capas del suelo y algunos otros requerimientos edáficos de los cultivos. La agricultura de precisión tiene como objetivo administrar láminas de riego e insumos de acuerdo con las necesidades de cada suelo. Por lo tanto, tiene el potencial de mejorar la productividad de los cultivos, evitar la aplicación excesiva de agua e insumos químicos y reducir impactos ambientales y gastos de producción. Para alcanzar este objetivo, las propiedades específicas del suelo como lo es su textura, deben medirse con el fin de proporcionar una base en su manejo. La medición de múltiples propiedades del suelo a una alta frecuencia temporal y/o espacial, requiere mucho tiempo y es costosa utilizando métodos convencionales. Por lo tanto, se necesitan enfoques alternativos para lograr información de alta resolución y en escala de campo útil para los productores (Pei, Sudduth, Veum y Li, 2019)

Se han desarrollado nuevas técnicas de monitoreo de suelos, basadas en la medición de reflectancia de la superficie terrestre mediante los sensores remotos. Estos sensores miden los distintos rasgos de absorbancia y reflectancia que corresponden a los rangos del espectro electromagnético (EM), dependiendo todos estos parámetros de las propiedades del suelo (Girón, *et al.*, 2009)

Durante las últimas dos décadas, tanto las imágenes de detección remota de suelo desnudo como la reflectancia espectral de las muestras de suelo se han utilizado con éxito para una estimación precisa y rápida de sus propiedades (Liao, Xu, Wu y Zhu, 2013). Diversos autores han encontrado correlación entre los datos de reflectancia obtenidos de las bandas de los diferentes satélites disponibles y los datos de arena, limo y arcilla provenientes de muestras en campo. Por mencionar algunas: (Liao, *et al.*, 2013) y (Alasta, 2011) encontraron una correlación significativa entre los datos de reflectancia de la banda 7 del satélite Landsat TM 7 y el contenido de arcilla del suelo. Gholizadeh, Žižala, Saberioon y

Borůvka (2018) encontraron una correlaci3n significativa entre la banda 7 del sensor Sentinel-2 y el contenido de arcilla de los suelos muestreados.

La presente investigaci3n se centra en el uso de las herramientas de las que dispone la percepci3n remota en la identificaci3n del contenido de arena, limo y arcilla en los suelos agrıcolas. Especıficamente el uso de datos obtenidos de im3genes multiespectrales provenientes de vehıculos a3reos no tripulados.

1.1 Planteamiento del problema y justificaci3n del proyecto

El suelo y el agua son dos de los m3s importantes recursos naturales del planeta, y su uso y manejo irracional est3n provocando p3rdidas en sus propiedades m3s ben3ficas para el ser humano. De seguir con su uso, no s3lo se ver3n disminuidos dr3sticamente los niveles de los mantos acuíferos, sino que se afectar3 la fertilidad de los suelos con el lixiviado de los elementos nutricionales que los componen, y que son a su vez sustituidos por sales minerales disueltas en el agua de riego; muchas veces no ben3ficas para las propiedades del suelo, pues incrementan la salinidad y disminuyen sus condiciones f3rtiles.

Estas condiciones se ven ampliamente reflejadas en la agricultura convencional, la explotaci3n irracional de estos recursos est3 provocando suelos est3riles y salinos, ası como mantos acuíferos sobreexplotados y contaminados, a cambio de producciones muchas veces ineficientes. Es fundamental establecer planes de manejo para mejorar la eficiencia en el uso del agua en agricultura y que contribuyan tambi3n con la conservaci3n de las propiedades ben3ficas de los suelos, evitando la sobreexplotaci3n y contaminaci3n de los mantos acuíferos.

Sin embargo, para poder lograr lo antes mencionado es necesario caracterizar las propiedades que determinan el procesos de infiltraci3n y escorrentıa. Las cuales juegan un papel central en la correcta compresi3n y modelado de balance hıdrico, procesos superficiales, evapotranspiraci3n, infiltraci3n de agua, erosi3n o transporte de solutos a trav3s del suelo (Gonz3lez- Sosa, *et al.*, 2010).

De acuerdo a Schaap, Leij, y Van Genuchten (1998), la medición directa de las propiedades hidráulicas es lenta, costosa y, a veces, poco fiable debido a la heterogeneidad del suelo y los errores experimentales. En cambio, las propiedades hidráulicas se pueden estimar a partir de datos indirectos como la textura del suelo por medio de funciones de pedotransferencia (PTF) lo que proporciona metodologías más accesibles.

Por ello nace la necesidad de explorar nuevas técnicas que permitan identificar tan importantes propiedades del suelo. Dichas técnicas deberán representar la realidad de la manera más precisa posible y haciendo uso de las herramientas tecnológicas de las que se dispone en la actualidad.

La información proveniente de sensores remotos proporciona una herramienta vital en los reconocimientos del recurso suelo a escalas que van desde lo local hasta lo regional. Sin embargo, es necesario demostrar que la utilización de tecnologías de Sistemas de Información Geográfica (SIG) y de teledetección, pueden contribuir con el análisis de las propiedades físicas de los suelos tanto a pequeña como a gran escala (Guillén *et al.*, 2015).

En su trabajo “*Soil clay content mapping using a time series of Landsat TM data in semi-arid lands*”, Shabou *et al.* (2015) consideran que el contenido de arcilla es la fracción más importante, pues controla propiedades hidráulicas del suelo como punto de marchitamiento, capacidad de campo y conductividad hidráulica saturada, que a su vez controlan los diversos flujos de agua en la zona no saturada, además de estar relacionada con la capacidad de intercambio catiónico, vital en la fertilidad de los suelos.

Sin embargo, a menudo no se pueden medir estas propiedades debido a limitaciones prácticas y / o financieras. Incluso si se tuvieran todas las condiciones favorables para llevar a cabo muestreos, es difícil saber si la muestra en verdad representa las propiedades físicas del área de interés; es por ello necesario explorar nuevas técnicas que contribuyan con la caracterización de los suelos de una manera eficiente, representativa y menos costosa.

Las imágenes multispectrales son una herramienta que se ha estado utilizando con éxito en el mapeo de algunas propiedades de la superficie terrestre, como son uso y erosión de los suelos, estrés hídrico y nutricional de los cultivos, entre otros. La información de la que disponen las imágenes satelitales cuenta con una resolución espacial de 15 a 30 m, lo que se vuelve una limitante en áreas con suelos muy heterogéneos (Navarro, 2011).

Otra de las opciones ampliamente estudiadas es la toma de datos con espectrofotómetro, pero aunque se generen buenos modelos que relacionen los datos obtenidos de éstos sensores y los contenidos de arena, limo y arcilla; será necesario siempre muestrear los suelos de los que se quiera conocer éstas fracciones de suelo, y la finalidad principal de éste trabajo es disminuir tiempo y costos de muestreo y análisis en laboratorio.

En el caso del uso de vehículos aéreos no tripulados, dadas las características de las cámaras utilizadas y la altura de vuelo, la resolución espacial de los datos proporcionados es centimétrica, por lo que se mejora la resolución espacial de las imágenes.

Por ello es que se plantea esta herramienta como una alternativa para la identificación de las propiedades físicas de los suelos importantes en agricultura, como lo son contenidos de arena, limo y arcilla, de tal manera que puedan hacerse análisis espaciales de las áreas de interés.

2 ANTECEDENTES

El empleo de técnicas de teledetección en estudios de suelos comenzó en la década de 1960 y se amplió a diversas aplicaciones, incluida la cuantificación rápida y no destructiva de los atributos del suelo; estudio y clasificación, mediciones mineralógicas, agricultura de precisión y cuantificación de metales (Bellinaso, Demattê, y Romeiro, 2010).

En 1972 Condit realizó estudios con mediciones que se extendieron de 320 a 800 nm por medio de un espectrofotómetro *Cary Recording Model 14*® equipado con un accesorio para la medición de la reflectancia difusa, y mediciones de 800 a 1,000 nm mediante el uso de un espectrofotómetro *Beckman DU*® operado manualmente (también equipado con un

accesorio para realizar mediciones de reflectancia difusa); obtuvo como característica distintiva de las curvas de reflectancia de los suelos con contenidos altos de arcilla (sobre cualquier rango de longitud de onda), que la pendiente, salvo algunas excepciones, se incrementó o se mantuvo casi constante. En la mayoría de las muestras de este tipo de suelos la pendiente se incrementó poco a lo largo de todos los instrumentos del rango espectral. Esta condición puede observarse en la Figura 1.

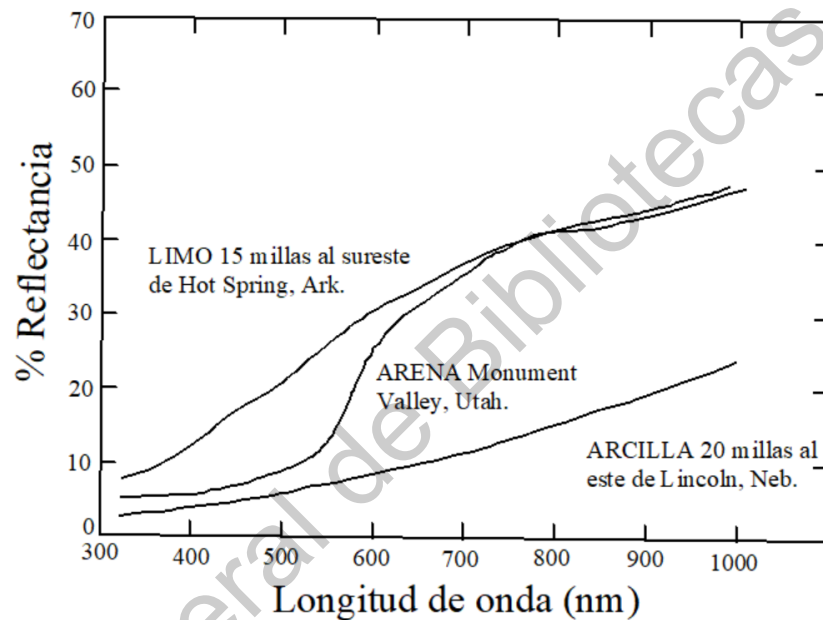


Figura 1. Curvas característica de reflectancia espectral de suelos con altos contenidos de arena, limo y arcilla encontrada por Condit (1972)

La mayoría de las muestras con altos contenidos de arcilla que presentaron una curva de reflectancia cuya forma se muestra en la Figura 1, presentaron una reflectancia bastante baja.

En el tipo de suelo 2 (mayor contenido de limo) proveniente de muestras colectadas a 24 km al sureste de *Hot Springs, Arkansas*, la reflectancia se incrementó bastante rápido; de 320 a alrededor de 450 nm, donde se presenta una leve o moderada depresión en la pendiente, seguido por un incremento de esta alrededor de los 480 nm. Alrededor de los 580 nm la pendiente decreció. De 600 a alrededor de 700 nm hubo una leve a moderada

depresión en la pendiente. Alrededor de los 750 nm la pendiente decreció otra vez. Más allá de 780 nm la pendiente cambia un poco con el incremento en la longitud de onda.

El tipo de suelo 3 (mayor contenido de arena), contiene arena de cuarzo rojo y calcita colectados de *Monument Valley, Utah*. En este tipo de suelo la pendiente de la curva se incrementa a una tasa moderada de la región de ultravioleta a alrededor de 530 nm, entonces se eleva bruscamente alrededor de los 580 nm, donde se presenta un definitivo decremento en la pendiente. De alrededor de los 620 a los 740 nm hay una leve a moderada depresión en la pendiente. A los 740 nm ocurre otro decremento. En aproximadamente la mitad de los 33 conjuntos obtenidos por el autor los cuales representan este tipo de forma de curva, se encontró que la pendiente se levantó de nuevo en las más grandes longitudes de onda.

Es importante analizar este tipo de estudios detallados en condiciones de laboratorio, ya que muestran un panorama general sobre las condiciones óptimas de medición. El estudio hecho por Condit, muestra las diferencias en la reflectancia de suelos con diferente contenido de arcilla en condiciones de laboratorio.

En 1993 Coleman, Agbu, y Montgomery estudiaron la diferenciación espectral de los suelos superficiales y las propiedades del suelo con los datos de Landsat TM y el radiómetro multibanda modular de Barnes (MMR). Encontraron correlaciones significativas entre los datos de reflectancia de teledetección en las siete bandas de Landsat y las variables de suelo estudiadas: textura del suelo, O.M. y contenido de Fe.

De acuerdo a los resultados obtenidos por Thomasson, Sui, Cox, y Al-Rajehy (2001) en sus pruebas realizadas en un amplio rango espectral (275 hasta 2500 nm) la región en la que existe la potencia discriminatoria máxima (90% a 100% del máximo para la relación de coeficiente de variación -CV-) está entre aproximadamente 500 y 800 nm. Las regiones de buena potencia discriminatoria (80% a 90% del máximo) existen entre 400 y 500 nm y entre 950 y 1500 nm. Estos autores encontraron también que las únicas propiedades del suelo que tenían valores de R^2 superiores a 0.50 con el empleo de modelos de regresión múltiple fueron Ca y Mg, arcilla y pH.

Estudios realizados por Rossel, Walvoort, McBratney, Janik, y Skjemstad, en el 2006 para las predicciones de contenido de arcilla, demostraron que el MIR (Infrarojo medio con longitudes de onda de 2500-25,000 nm) tiene un rendimiento con un R^2 promedio de 0.82 comparado con 0.71 para el VIS-NIR combinado, cuyas longitudes de onda van de 400 a 2500 nm, por medio de una regresión de mínimos cuadrados parciales, obteniendo datos de un espectrómetro *Varian Cary 500*®.

Bellinaso, Demattê y Romeiro (2010) demostraron que la intensidad de la reflectancia de las curvas estuvo principalmente influenciada por los niveles de Fe_2O_3 , arcilla, materia orgánica y la presencia de minerales opacos

De acuerdo a la investigación realizada por Rossel y Behrens (2010); las características de absorción en el NIR de onda corta visible (400–1000 nm) se deben principalmente a los óxidos de Fe: en el suelo, principalmente hematita y goetita, mientras que los del NIR entre 1000 nm y 2500 nm pueden deberse al agua, minerales de arcilla y materia orgánica.

De acuerdo con Jiménez (2015) la reflectividad de los suelos aumenta al aumentar el tamaño medio de las partículas, por lo tanto en suelos arenosos la reflectancia es mayor que los arcillosos. También menciona que el comportamiento espectral del suelo es mucho más uniforme respecto de otros objetos, mostrando una curva espectral casi plana de carácter ascendente.

Olivares (2015) menciona que las propiedades espectrales del suelo son relativamente simples, toda la energía se absorbe o refleja. En su trabajo “*Estudio de la erosión del suelo mediante imágenes de satélite. Aplicación al área de Los Yébenes (Toledo)*” concluye que aumenta la reflectividad al aumentar el tamaño medio de las partículas, es el caso de los suelos arenosos ya que estos se ven más claros que los arcillosos.

Los factores que afectan la reflectancia del suelo son complejos, variables y tienen frecuentemente una acción combinada. Un ejemplo de ello lo conforma la rugosidad superficial, el contenido de carbono orgánico, los agregados superficiales del suelo, el contenido de hierro, el contenido de agua, los contenidos de carbonatos y las texturas

superficiales. Estas propiedades son diferenciadas por las observaciones multiespectrales y ayudan a la correcta planificación de los sitios de observación o puntos de muestreo, a manera de validar los bordes de las unidades fisiográficas (Guillén, Murugan y Dávila, 2015).

3 MARCO TEÓRICO

3.1 Conceptos generales

3.1.1 Textura del suelo

La textura se refiere al tamaño de las partículas que componen el suelo. Los términos arena, limo y arcilla se refieren a los tamaños relativos de las partículas del suelo (Gisbert, Ibáñez y Moreno, 2017).

Las partículas del suelo se separan en grupos de tamaños de acuerdo al esquema utilizado por el Departamento de Agricultura de los Estados Unidos, el cual se muestra a continuación:

Tabla 1. Diámetros de partículas del suelo (USDA)

Nombre de la partícula	Rango de diámetro (mm)
Arena	2.0 – 0.05
Limo	0.05 – 0.002
Arcilla	Menor a 0.002

Los porcentajes de cada una de las fracciones de partículas de la fracción fina del suelo se representan como proporciones en un triángulo de texturas con el objetivo de determinar su clase textura, el cual se presenta en la Figura 2.

3.1.1 Percepción remota

La historia de la teledetección o percepción remota se remonta a las primeras plataformas de observación aérea: los globos aerostáticos y a la invención de la fotografía en el siglo XIX. La teledetección moderna, nace con la fotografía aérea en el siglo XX. El año que simboliza la entrada de la teledetección en la era moderna es 1957 con el lanzamiento del

satélite *Sputnik*, primer satélite artificial puesto en órbita alrededor de la Tierra por la Unión Soviética. Desde entonces a la fecha se han visto avances sustanciales en la modernización de satélites que le den cobertura al mundo entero. (Martínez-Vega, Martín, Díaz Montejo, López Vizoso y Muñoz Recio, 2010).

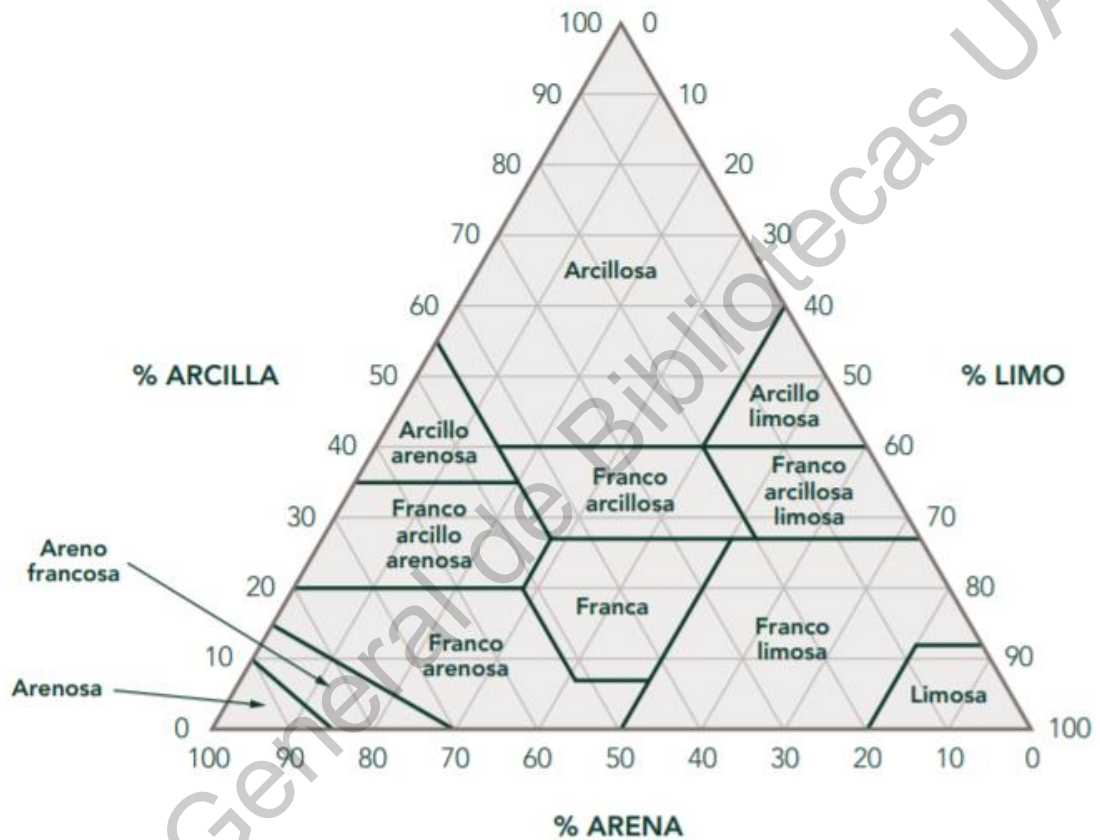


Figura 2. Triángulo de textura de la USDA (Extraído de González-Naranjo, Leal, Lillo, de Bustamente y Palacios-Díaz, 2012)

El sensado remoto (del inglés *remote sensing*) o teledetección, hace referencia a la técnica empleada para adquirir información sobre un objeto o fenómeno sin hacer contacto físico con él, a través de sensores ubicados en plataformas aerotransportadas (aviones tripulados o no tripulados – UAV) o aeroespaciales (satélites) (Camacho-Velasco, A. *et al.*, 2015).

La teledetección espacial, es el sistema integral de captura de información territorial (a partir de la radiación electromagnética captada por el sensor) que se emplea cada día con

mayor frecuencia para la captura tanto de información temática (medioambiental), como de información topográfica (planimetría). Esto ha sido posible gracias al desarrollo que han experimentado, por un lado, las técnicas de tratamiento digital de imágenes, y la obtención de datos significativos del territorio; y por otro, el acceso a la exhaustiva información digital proporcionada por sensores, en su aspecto espacial, radiométrico, espectral y temporal (Arozarena y Fernandez., 1989).

3.1.2 Radiación electromagnética

Las propiedades de la radiación electromagnética han sido explicadas por dos teorías aparentemente contrapuestas: aquella que la concibe como un haz ondulatorio (teorías de Huygens y Maxwell), y la cuántica que la considera como una sucesión de unidades discretas de energía, fotones y cuantos, con la masa igual a cero (teorías Planck y Einstein). Las dos teorías pueden coexistir, pues la ciencia ha demostrado que la luz presenta comportamientos que pueden explicarse de acuerdo a ambos planteamientos.

Según la teoría ondulatoria, la energía electromagnética se trasmite de un lugar a otro siguiendo un modelo armónico y continuo, a la velocidad de la luz y conteniendo dos campos de fuerzas ortogonales entre sí: eléctrico y magnético. Las características de este flujo energético pueden describirse por dos elementos: Longitud de onda (λ) y Frecuencia (ν). La primera hace referencia a la distancia entre los picos sucesivos de una onda, mientras que la Frecuencia designa el número de ciclos pasando por un punto fijo en una unidad de tiempo, ambos ejemplos están inversamente relacionados:

$$c = \lambda \nu \quad (1)$$

donde c indica la velocidad de la luz ($3 \times 10^8 \text{ m s}^{-1}$), λ expresa la longitud de onda (en unidades de longitud, habitualmente micrómetros, $1\mu = 10^{-6} \text{ m}$ o nanómetros ($1 \text{ nm}=10^{-9} \text{ m}$)) y ν es la Frecuencia (en *Hertz*, $1 \text{ Hz} = \text{un ciclo por segundo}$).

A mayor longitud de onda, menor frecuencia y viceversa, por lo que basta con indicar un solo término para caracterizar el flujo de energía mencionado.

Gracias a la teoría cuántica, es posible calcular la cantidad de energía transportada por un fotón, siempre que conozca su Frecuencia:

$$Q = hV \quad (2)$$

donde Q es la energía radiante de un fotón (en julios), V la Frecuencia y h la constante de *Planck* (6.6×10^{-34} Js).

Sustituyendo en la Ec. 2, se puede expresar:

$$Q = h \left(\frac{C}{\lambda} \right) \quad (3)$$

Por lo que a mayor longitud de onda (o menor frecuencia) el contenido energético será menor y viceversa.

Es decir, se puede definir cualquier tipo de energía radiante en función de su longitud de onda o frecuencia. Aunque la sucesión de valores de longitud de onda es continua, suelen establecerse una serie de bandas en donde la radiación electromagnética manifiesta un comportamiento similar. La organización de estas bandas de longitudes de onda o frecuencia se denomina espectro electromagnético (Gonzaga, 2014).

3.1.3 Espectro electromagnético

Es la distribución energética del conjunto de ondas electromagnéticas, aunque la sucesión de valores de longitud de onda es continua, suelen establecerse una serie de bandas en donde la radiación electromagnética manifiesta un comportamiento similar, las unidades de medida más comunes se relacionan con la longitud de onda, para las más cortas se utilizan micrómetros (μm) o nanómetros (nm), mientras las más largas se miden en centímetros (cm), metros (m) o kilómetros (km) (Chuvienco, 2008).

De acuerdo con Gonzaga, (2014) desde el punto de vista de la teledetección, conviene destacar, una serie de bandas espectrales, que son las más frecuentemente empleadas con la tecnología actual. Su denominación y amplitud varían según distintos autores, si bien la terminología más común es la siguiente:

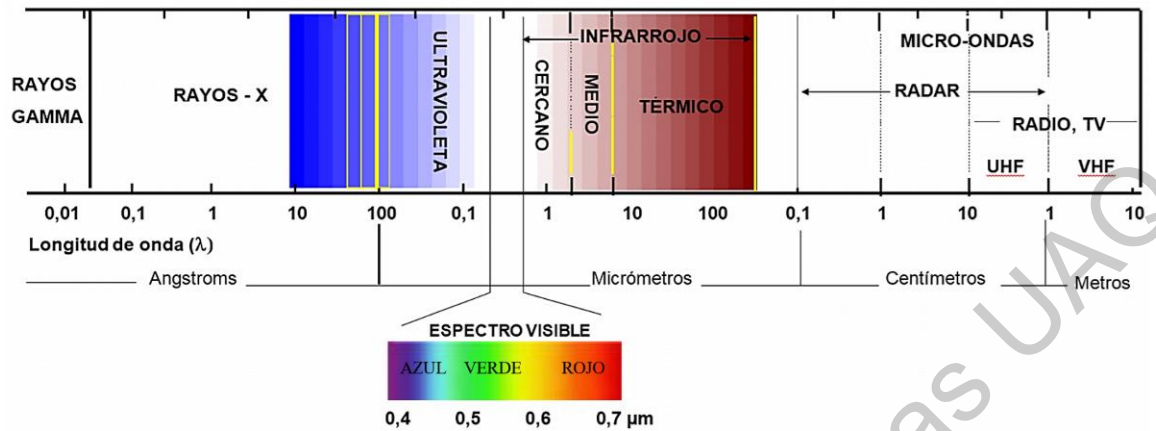


Figura 3. Espectro electromagnético (Extraído de Jiménez, 2015)

Espectro visible (0,4 a 0,7 μm): Se denomina así por tratarse de la única radiación electromagnética que pueden percibir el ojo humano, coincidiendo con las longitudes de onda en donde es máxima la radiación solar. Dentro de esta región, suelen distinguirse tres bandas elementales denominadas: azul (A: 0,4 – 0,5 μm), verde (V: 0,5 – 0,6 μm), y rojo (R: 0,6 – 0,7 μm), es la única porción del espectro que podemos asociar al concepto de color.

Infrarrojo: cubre la región entre 0,7 y 100 μm, esta porción puede subdividirse en dos categorías basadas en las propiedades de la radiación: IR Reflejado y el IR térmico o emitido. El primero es utilizado en teledetección de manera similar al visible, y el IR térmico es diferente al visible e IR reflejado, ya que esta energía es esencialmente la radiación emitida por la superficie de la tierra en forma de calor.

3.1.4 Espectroscopía

La espectroscopía, de acuerdo con Sánchez (2016), consiste en el estudio de la interacción entre la radiación electromagnética y la materia en función de la longitud de onda.

Radiancia

Camacho-Velasco, *et al.* (2015) mencionan que la radiancia o irradiancia se refiere a la energía de la luz por unidad de tiempo (potencia) que incide sobre una superficie ($W m^{-2}$).

Cuando la irradiancia incide sobre un material, este absorbe $L_{\alpha}(\lambda)$, transmite $L_{\tau}(\lambda)$ y refleja $L_{\gamma}(\lambda)$, la luz de manera particular. Todos los componentes están en función de la longitud de onda.

$$L_i(\lambda) = L_{\alpha}(\lambda) + L_{\tau}(\lambda) + L_{\gamma}(\lambda) \quad (4)$$

Las proporciones en $L_{\alpha}(\lambda)$, $L_{\tau}(\lambda)$ y $L_{\gamma}(\lambda)$ varían de acuerdo con el comportamiento espectral de los diferentes materiales encontrados dentro de la superficie de la tierra. La variación espectral permite detectar o clasificar un objeto o material en una imagen captada por el sensor remoto.

Reflectancia

La reflectancia (R) de una superficie se define físicamente como el cociente entre la potencia de la radiación reflejada y la potencia de la radiación total recibida por la misma. Dado que la cantidad de radiación reflejada por la superficie siempre será menor o igual que la potencia recibida, la reflectancia tendrá valores comprendidos entre 0 y 1. También suele expresarse en porcentaje.

La siguiente ecuación permite cuantificar la reflectancia ρ_{λ} , midiendo la cantidad de irradiancia incidente $L_i(\lambda)$ que es reflejada $L_{\gamma}(\lambda)$

$$\rho_{\lambda} = \frac{L_{\gamma}(\lambda)}{L_i(\lambda)} \quad (5)$$

Mencionan también que la reflectancia es una magnitud característica del medio y, por tanto, es esta magnitud la base para el reconocimiento de sustancias. Al igual que la radiancia, la reflectancia también depende de la longitud de onda (Alonso, *et al.*, 1999; Camacho-Velasco *et al.* 2015).

3.1.5 Espectrometría

Sánchez, B. E. (2016) define la espectrometría como una técnica espectroscópica que consiste estimar la concentración o cantidad de una determinada sustancia mediante la observación del espectro emitido o absorbido por las mismas. El instrumento de medición empleado es un espectrómetro.

El mismo autor definió el espectrómetro como un instrumento óptico que sirve para medir las propiedades de la luz sobre una porción específica del espectro electromagnético. Se utiliza para identificar los diferentes materiales que forman una escena, mediante la medida de la intensidad de luz en función de la longitud de onda.

Los datos obtenidos pueden ser utilizados para generar imágenes que muestran la ubicación y la cantidad de distintos componentes.

3.1.6 Imagen multiespectral

Las imágenes son matrices de celdas llamadas píxeles, formadas por un determinado número de filas y columnas, cada celda representa un área geográfica indivisible, determinando así el detalle mínimo de que se puede distinguir dentro de una imagen, el tamaño de superficie que puede ser representada (tamaño de pixel), varía dependiendo de los sensores que tomen la imagen. Cada pixel contiene un valor numérico, que representa en promedio la cantidad de energía electromagnética que un objeto terrestre puede reflejar (Chuvienco, 2008).

Las imágenes multiespectrales son imágenes que tienen varias bandas espectrales de información a través de todo el espectro electromagnético. Un pixel no se encuentra definido por un único valor de intensidad, sino que tiene tantos valores como bandas se hayan observado. Las técnicas de formación de estas imágenes dividen el espectro en bandas que se extienden más allá de lo visible (Bernabé, 2016).

3.1.1 Resolución

Ávalos (2012) se refiere a la resolución como la habilidad de registrar información a detalle, discriminándola. La precisión de la información obtenida no sólo se relaciona con el detalle espacial que proporciona el sensor, sino que también al número y anchura de las bandas que alberga, a su frecuencia temporal y a su capacidad de distinguir variaciones en la energía detectada.

Resolución espacial: Se refiere al objeto más pequeño que puede ser distinguido sobre una imagen, es decir, la mínima unidad de información incluida en la imagen y se denomina píxel. Se mide en unidades de longitud sobre el terreno y depende de la apertura focal del sensor y altura sobre la superficie.

Resolución espectral: Indica el número y amplitud de las bandas espectrales que puede detectar un sistema sensor. Este brindará información más detallada mientras más bandas proporcionen y más estrechas sean.

Resolución radiométrica: Es la capacidad que tiene el sistema de detectar variaciones en la radiancia espectral que recibe, es decir, el número máximo de niveles digitales que puede detectar un sensor óptico-electrónico.

3.2 Construcción del marco teórico

De acuerdo con Barahona y Vargas (2012) el marco teórico es un elemento que direcciona el camino a seguir, pues permite ubicar el tema objeto de estudio dentro del conjunto de las teorías existentes, con el propósito de precisar en qué corriente del pensamiento se inscribe y en qué medida significa algo nuevo o complementario.

Por su parte Sampieri, Collado, Lucio, Valencia y Torres (1998) afirman que la revisión de literatura puede revelar diferentes grados del desarrollo del conocimiento, pues se puede encontrar que:

- Hay una teoría completamente desarrollada, con abundante evidencia empírica y que se aplica a nuestro problema de investigación.

- Hay varias teorías con soporte empírico que se aplican a nuestro problema de investigación.
- Hay “piezas y trozos” de teoría con cierto respaldo empírico, que sugieren variables potencialmente importantes y que se aplican a nuestro problema de investigación (pueden ser generalizaciones empíricas e hipótesis con apoyo de algunos estudios).
- Hay descubrimientos interesantes, pero parciales, sin llegar a ajustarse a una teoría.
- Hay solo guías aún sin estudiar e ideas vagamente relacionadas con el problema de investigación.

En la revisión de literatura del presente estudio, el autor encontró que hay “piezas y trozos” de teoría con cierto respaldo empírico, que sugieren variables potencialmente importantes y que se aplican a nuestro problema de investigación, las cuales se presentan a continuación:

3.2.1 Polígonos o zonas de entrenamiento (áreas de vuelo)

Ariza (2018) define las zonas de entrenamiento como patrones o propiedades específicas que caracterizan una determinada cobertura o área; es decir, áreas de imágenes cuyas cualidades o propiedades de interés son conocidas.

Dado que en éste estudio el interés es en las propiedades del suelo, se revisaron artículos que hayan estudiado éste tipo de propiedades por medio de sensores remotos, encontrando lo siguiente:

Olivares (2015) menciona que la fuerte correlación que existe entre muchos de los factores que afectan a la respuesta espectral del suelo, imposibilita el que pueda sacarse conclusiones claras del análisis de una imagen de una zona cuyas características edáficas se desconocen. Aunque se puede comprobar que las áreas de suelo desnudo de una misma imagen siguen una serie de pautas reconocibles.

En su trabajo “*Soil clay content mapping using a time series of Landsat TM data in semi-arid lands*”, Shabou *et al.* (2015) mencionan que seleccionaron imágenes de épocas secas, con la menor vegetación verde y menor contenido de humedad del suelo posible debido a la lluvia, con ayuda de datos obtenidos de estaciones meteorológicas.

Gholizadeh *et al.*, (2018) recomiendan también para estudios de suelo, que al seleccionar la imagen de satélite que se empleará en el estudio, se trate de imágenes de fechas donde el suelo se encuentre descubierto y con al menos cinco días después de la última lluvia, lo que se puede verificar con alguna estación meteorológica cercana, esto debido a que las condiciones de humedad del suelo modifican los valores de radiación captada por el sensor. Así mismo, recomiendan zonas de áreas labradas (antes de la siembra), sin vegetación ni residuos de cosecha.

3.2.2 Muestreo de suelos

La metodología básica para el muestreo de suelos fue definida hace más de 50 años por Cline (1944) y hasta hoy no ha cambiado. Siempre se ha reconocido que la principal causa de errores en el análisis de suelos es el muestreo, antes que errores propios de los procedimientos analíticos. Cline estableció hace mucho tiempo que "la exactitud de análisis está determinada por el muestreo antes que por el procedimiento analítico". El objetivo principal del muestreo de un suelo es obtener una muestra que represente en forma precisa las condiciones de las propiedades del lote donde fue tomada (Roberts y Henry, 2019).

Para determinar el número de muestras de suelo a obtener en campo para poder llevar a cabo la metodología, se revisaron diversos estudios de suelo a partir de teledetección, encontrando los siguientes resultados:

Tabla 2. Número de muestras colectadas y profundidad de muestreo de algunos autores que han estudiado suelos con percepción remota

Fuente	Número de muestras	Prof. de muestreo (cm)
Kuang, Tekin y Mouazen (2015)	331	15-20 cm
Zhai, Thomasson, Boggess y Sui (2006)	717	0-15 cm
Zeraatpisheh, Ayoubi, Jafari,	334	0-30 cm

Fuente	Número de muestras	Prof. de muestreo (cm)
Tajik y Finke (2019)		
Aitkenhead <i>et al.</i> (2018)	255	0-20 cm
Pei, Sudduth, Veum y Li (2019)	148	0-50 cm
Aitkenhead, Coull, Towers, Hudson y Black (2013)	127	NE
Rossel, Walvoort, McBratney, Janik y Skjemstad (2006)	118	0-20 cm
Guillen, Murugan y Dávila (2015)	36	NE
Shabou <i>et al.</i> (2015)	100	0-30 cm

*NE (No especifica)

El número de muestras de suelo obtenidas en estudios a partir de teledetección, de acuerdo con los autores citados varía de 36 a 334 y la profundidad de muestreo de 0 a 50 cm, no encontrándose una profundidad en específico como la más recomendable.

Al realizar la planeación de su muestreo, Barnes y Baker (1999) obtuvieron una cuadrícula de sus área de estudio, con una distancia aproximada de la cuadrícula de 120 m.

3.2.3 Vehículos aéreos no tripulados

La mayor parte de los estudios revisados emplearon espectrofotómetros o espectrorradiómetros para analizar las muestras de suelo, y algunos otros hicieron uso de imágenes provenientes de los diferentes satélites disponibles; no se encontró ningún artículo que empleara datos obtenidos de cámaras montadas en vehículos aéreos no tripulados, debido quizá a que éste tecnología es relativamente nueva y los estudios recién comienzan, enfocados principalmente en investigaciones relacionadas con el estado de la vegetación.

Se trata de una plataforma versátil que permite la captura de información remota, con la cual se ha logrado generar un sin número de aplicaciones dentro de los campos de la cartografía, agricultura de precisión, teledetección, entre otras. Estas aeronaves se pueden clasificar según varios criterios, generalmente su clasificación tiende a estar relacionada con la manera en que se mantienen en el aire. Por lo cual se puede indicar que básicamente existen dos tipos de UAV, de ala rotatoria y de ala fija. Dependiendo de los resultados que se deseen se usará cualquiera de las clases de UAV mencionados. El área de estudio, la resolución espacial, las condiciones de despegue y aterrizaje será un condicionante para usar y seleccionar el UAV indicado (Segovia, 2016).

Para justificar su uso, y citando a Coleman *et al.* (1993) quienes estudiaron la diferenciación espectral de los suelos superficiales y las propiedades del suelo con los datos de Landsat TM y el radiómetro multibanda modular de Barnes (MMR). La ecuación de predicción para estimar las propiedades del suelo representó menos del 40% de la variabilidad en los datos. Los bajos porcentajes se atribuyeron a partículas atmosféricas como la humedad, el CO₂, el polvo, etc. que afectan la energía electromagnética detectada en las plataformas aéreas y espaciales. Se concluyó que a pesar de que el sensor TM es adecuado para diferenciar entre tipos de suelo similares del mismo orden de suelo, la resolución espacial de los datos (30 m) todavía es demasiado gruesa para ser utilizada efectivamente en la generación de ecuaciones para predecir propiedades del suelo como porcentajes de arcilla, óxido de hierro y contenido de materia orgánica.

3.2.4 Variables e índices empleados

Algunas de las variables independientes que han sido empleadas en estudios de percepción remota para determinar contenidos de arena, limo y arcilla se presentan a continuación:

Índices espectrales y de vegetación

El gran reto de la Teledetección consiste en estudiar la vegetación o la cobertura terrestre de una escena a partir de medidas de reflectividad con independencia de todos los factores que perturban a la señal radiométrica. Es decir, para establecer una relación biunívoca entre

la medida efectuada por Teledetección y los parámetros biofísicos que caracterizan una cubierta, es necesario derivar algún parámetro (magnitud secundaria) a partir de la reflectividad (magnitud primaria) que normalice la influencia de todos los factores perturbadores antes mencionados de forma que, idealmente, esta magnitud secundaria adopte el mismo valor para una cantidad de vegetación o cobertura dada aunque ésta se asiente sobre suelos con propiedades ópticas distintas, o la medida se realice bajo diferentes condiciones atmosféricas. La solución a este problema se ha abordado tradicionalmente en Teledetección a partir del diseño de los denominados índices espectrales. De forma genérica se podría definir un índice espectral como un parámetro calculado a partir de los valores de la reflectividad a distintas longitudes de onda y que pretende extraer de los mismos la información relacionada con la cobertura minimizando la influencia de perturbaciones como las debidas a las condiciones atmosféricas. En el caso del índice de vegetación ideal se puede describir como "aquél particularmente sensible a la cubierta vegetal, insensible al brillo y color del suelo y poco afectado por la perturbación atmosférica, los factores medioambientales y las geometrías de la iluminación y de la observación". Evidentemente, el IV ideal no existe y los IVs definidos hasta el momento tienen en común el uso de los valores de reflectividad en las zonas espectrales del rojo e infrarrojo cercano (Gilbert, González-Piqueras y García-Haro, 1997).

Kalambukattu, Kumar y Raj (2018) y Mahmoudabadi, Karimi, Haghnia y Sepehr (2017) emplearon un conjunto de índices espectrales para alimentar una red neuronal y predecir diferentes propiedades del suelo.

Análisis de componentes principales (ACP)

Es matemáticamente definido como una transformación lineal ortogonal de los datos a un nuevo sistema de coordenadas en donde la mayor varianza se acumula en un eje o proyección denominada 'primer componente principal'; la segunda varianza más grande queda representada en el segundo eje o proyección, y así sucesivamente. El ACP es teóricamente la transformación más óptima en términos de mínimos cuadrados, reduciendo la dimensionalidad de la información y reteniendo las características que mayor

contribuyen a la varianza (Guillen *et al.*, 2015). Los mismos autores, lo emplearon como una variable predictora más en su trabajo “Aplicación de teledetección y SIG para el levantamiento cartográfico de los suelos de la cuenca Solani, India”, así como Gholizadeh *et al.* en su trabajo “*Soil organic carbon and texture retrieving and mapping using proximal, airborne and Sentinel-2 spectral imaging*” en el 2018.

Gholizadeh *et al.* (2018) emplearon 10 bandas extraídas del Sentinel-2 y 18 índices espectrales, como variables independientes al predecir textura del suelo.

3.2.5 Generación del modelo

Análisis de correlación

El método más común de determinar si existe asociación lineal entre dos variables cuantitativas continuas es el Análisis de Correlación de Pearson. Con este método se obtiene el Coeficiente de Correlación de Pearson. Dos aspectos importantes del coeficiente de correlación son su magnitud y su signo. La magnitud refleja la intensidad de la asociación entre las dos variables; el valor absoluto de la magnitud puede variar entre cero y uno. Valores cercanos a cero indican que las variables no están asociadas, es decir, que el valor de una variable es independiente del valor de la otra. El signo, por su parte, refleja cómo están asociados los valores de ambas variables. Si el signo es positivo indica que a valores altos de una variable corresponden valores altos de la otra, o a valores bajos de una variable corresponden valores bajos de la otra. Si el signo es negativo, indica que a valores altos de una variable corresponden valores bajos de la otra (Camacho-Sandoval, 2008).

Los análisis de correlación, han sido ampliamente empleados en estudios de éste tipo; Barnes y Baker (1999) obtuvieron coeficientes de correlación entre las bandas espectrales de cada sensor (Landsat TM, SPOT y Sensor Airbone) y los porcentajes de arena, limo y arcilla.

Por su parte, Thomasson, Sui, Cox y Al-Rajehy (2001) realizaron un análisis de correlación entre 50 anchos de banda de un espectrofotómetro Cary 500UV/Vis/NIR y los contenidos de arena y arcilla de diferentes suelos en Mississippi, EUA.

Gholizadeh *et al.*, 2018 también realizaron un análisis de correlación entre reflectancia de 10 bandas extraídas del Sentinel-2 y 18 índices espectrales, como variables independientes al predecir contenidos de arena, limo y arcilla del suelo.

Regresión lineal múltiple

La correlación es una medida de la similitud de la variabilidad de dos magnitudes estocásticas (que, como varían, las denominamos variables). La ventaja de la correlación como medida de asociación es la sencillez de cálculo y su inconveniente es que, a veces, no es suficiente para comprender la relación entre ambas. La regresión es una técnica estadística que consiste en calcular dicha similitud en forma de función matemática. Esta función nos ofrece mucha más información sobre dicha relación (Granados, 2016).

El análisis de regresión lineal múltiple permite establecer la relación que se produce entre una variable dependiente Y y un conjunto de variables independientes (X_1, X_2, \dots, X_K). El análisis de regresión lineal múltiple, a diferencia del simple, se aproxima más a situaciones de análisis real puesto que los fenómenos, hechos y procesos sociales, por definición, son complejos y, en consecuencia, deben ser explicados en la medida de lo posible por la serie de variables que, directa e indirectamente, participan en su concreción (Rodríguez-Jaume y Mora, 2001).

Al igual que en regresión lineal simple, se considera que los valores de la variable dependiente Y han sido generados por una combinación lineal de los valores de una o más variables explicativas y un término aleatorio:

$$Y = b_0 + b_1 \cdot X_1 + b_2 \cdot X_2 + \dots + b_k \cdot X_k + u \quad (6)$$

Los coeficientes son elegidos de forma que la suma de cuadrados entre los valores observados y los pronosticados sea mínima, es decir, que se va a minimizar la varianza residual (Abuín, 2007).

En 1993 Coleman *et al.* estudiaron la diferenciación espectral de los suelos superficiales y las propiedades del suelo con los datos de Landsat TM y el radiómetro multibanda modular de Barnes (MMR). Utilizaron análisis de correlación, regresión y discriminantes para analizar los datos.

Thomasson *et al.* (2001) realizaron un análisis de regresión lineal múltiple entre 50 anchos de banda de un espectrofotómetro Cary 500UV/Vis/NIR y los contenidos de arena y arcilla de diferentes suelos en Mississippi, EUA.

Para predecir el contenido de arcilla sobre nuestra área de estudio, Shabou, *et al.* (2015), construyeron un modelo de regresión lineal para establecer la relación entre el índice infrarrojo medio y el contenido de arcilla.

Por su parte, Shabou *et al.*, (2015) Emplearon una regresión lineal simple al relacionar el Índice de infrarrojo medio con el contenido de arcilla.

Mientras que Müller, Bernhardt, Jackisch y Schulz (2016) emplearon una regresión lineal múltiple para relacionar Componentes principales (PC) derivados de datos de series de tiempo del infrarrojo con contenidos de arena, limo y arcilla por separado.

En su trabajo “*Spatial estimation of surface soil texture using remote sensing data*”, Liao, Xu, Wu y Zhu (2013) emplearon una regresión lineal múltiple para relacionar Números digitales (ND) de seis bandas de la imagen Landsat ETM y los contenidos de arena, limo y arcilla.

Bowers y Hanks (1971), al probar la reflectancia de los materiales del suelo de la textura desde la arcilla gruesa hasta la arena, descubrieron que el carácter de esta relación es exponencial.

De acuerdo a revisiones de Bakker (2012), algunos investigadores prefieren los algoritmos de clasificación no paramétrica, cuando se utilizan datos de fuentes múltiples; como los árboles de clasificación y regresión (CART) o las redes neuronales artificiales (RNN); debido al supuesto de que la relación entre los tipos de suelo y los datos extraídos de las bandas sea no lineal, y que tales métodos puedan tratar mejor la no linealidad. Sin embargo, los ANN no son adecuados para este estudio ya que son difíciles de interpretar. Todo dependerá de las necesidades del investigador.

3.2.6 Validación del modelo

La validación se define como la comparación de las predicciones del modelo con los valores observados del sistema real para determinar si el modelo es adecuado para el propósito establecido (Medina-Peralta, Vargas-Villamil, Navarro-Alberto, Canul-Pech y Peraza-Romero, 2010).

Con base en la revisión de literatura, se encontró que uno de los métodos de validación mayormente empleados es la validación cruzada. Este tipo de validación consiste en verificar el valor de una muestra dada y conocida, para lo cual esta muestra se descarta temporalmente y se estima su valor, por medio de las muestras del entorno, de forma que este proceso se va repitiendo para todas las muestras del conjunto de datos. Una vez obtenido el valor estimado se puede comparar con el dato verdadero eliminado durante el proceso de estimación. El método se basa simplemente en estimar un punto a partir de los restantes valores de la vecindad “tapando” dicho punto, si este valor estimado es similar a los que lo rodean, el punto se restituye bien y, por tanto, los errores serán pequeños, mientras que si el valor a restituir y los de la vecindad son muy diferentes los errores de estimación serán muy grandes, y dicho valor podrá ser considerado como alómallo respecto a sus vecinos (Olmo, 2003).

Shabou et al. (2015) validaron el mapa de contenido de arcilla que obtuvieron comparándolo con otras 50 muestras diferentes a las empleadas en la calibración.

Rossel *et al.* en su estudio “Visible, near infrared, mid infrared or combined diffuse reflectance spectroscopy for simultaneous assessment of various soil properties” del 2006, empleó el método de validación cruzada para las predicciones de contenido de arcilla a partir de datos de reflectancia en el MIR (Infrarojo medio con longitudes de onda de 2500-25,000 nm) obtenidos de un espectrómetro Varian Cary 500®.

Gholizadeh *et al.* (2018) evaluaron el rendimiento de su modelo mediante la validación cruzada de 5 veces del conjunto de entrenamiento (75% de las muestras), ellos dividieron el conjunto de entrenamiento que se utilizó para ajustar el modelo y obtuvieron un conjunto de validación mediante muestreo estratificado aleatorio.

Por su parte, Liao *et al.* (2013) realizaron validación cruzada de la siguiente forma: Se eliminó una muestra del conjunto de datos, se ajustó el modelo de predicción sobre las 57 muestras restantes, y se predijo el individuo "excluido". Se repitió el proceso hasta que todas las muestras fueron removidas individualmente.

Puede observarse que se encontró a la validación cruzada como el tipo de validación mayormente empleada en éste tipo de estudios.

4 Hipótesis y objetivos

Existe correlación entre la reflectancia espectral de los suelos y su contenido de arena, limo y arcilla.

5 Objetivo general

Determinar el contenido de arena, limo y arcilla a partir de imágenes multiespectrales.

5.1 Objetivos específicos

- Determinar la correlación que existe entre el contenido de arena, limo y arcilla del suelo con su reflectancia espectral.

- Determinar si las longitudes de banda green (550 nm), red (660 nm), near infrared (790 nm) y red edge (735 nm), pueden estimar el contenido de arena, limo y arcilla en los suelos.
- Obtener una ecuación que estime el contenido de arena, limo y arcilla de los suelos a partir de imágenes multiespectrales.

6 METODOLOGÍA

Con la finalidad de mostrar el cumplimiento de la hipótesis y gracias a la revisión y análisis que se ha estado llevando a cabo en la literatura, se planteó la siguiente metodología, la cual se encuentra brevemente resumida en la Figura 4:

6.1 Descripción de la zona de estudio

El área de estudio se encuentra en el distrito de riego 023 “San Juan del Río, Qro”, el cual está ubicado en una zona agrícola al sur de estado de Querétaro y comprende los municipios de Pedro Escobedo y San Juan del Río. Dicha zona se encuentra situada entre las coordenadas 20°30'11.46" y 20°27'46.86" latitud Norte y 100° 7'59.68" y 100° 3'28.65" longitud Oeste.

A continuación se describe detalladamente los pasos que se llevaron a cabo en la metodología:

6.2 Identificación del área de muestreo (zona de entrenamiento).

Con el apoyo de un plano proporcionado por dos de los módulos de riego que comprenden el distrito de riego 023, fue posible identificar las parcelas de los ejidos ubicados en el área de estudio; además, dicho plano contiene la clase textural del suelo de algunas de ellas, lo que permitió identificar parcelas con distintos tipo de textura de acuerdo con estudios hechos previamente. Este plano se convirtió en una herramienta valiosa para éste estudio pues permitió identificar parcelas con una adecuada variabilidad en el contenido de arena,

limo y arcilla de los suelos. Dicha área identificada se empleó como zona de entrenamiento para la obtención de datos y la generación del modelo. El plano con la información textural de los suelos del que dispone el distrito de riego se presenta en la Figura 5.

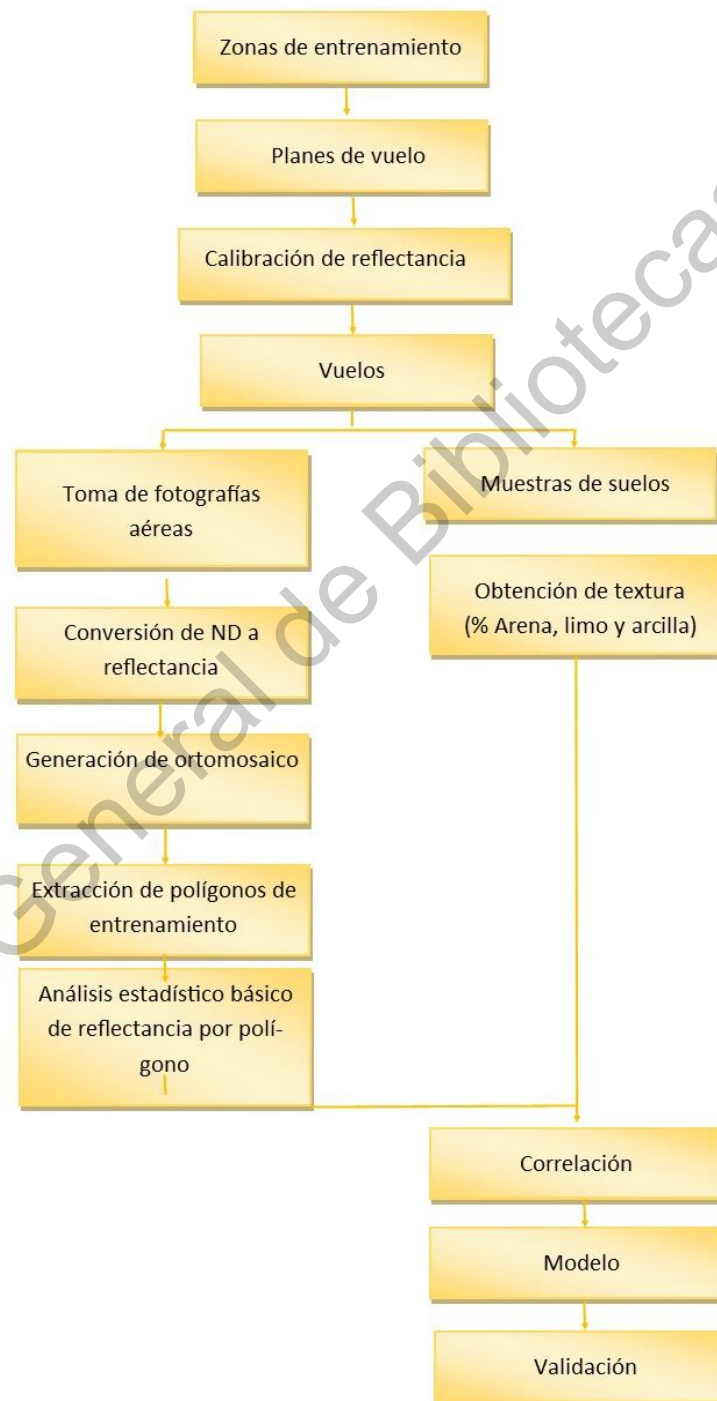


Figura 4. Metodología de desarrollo del estudio

PLANO DE TEXTURAS

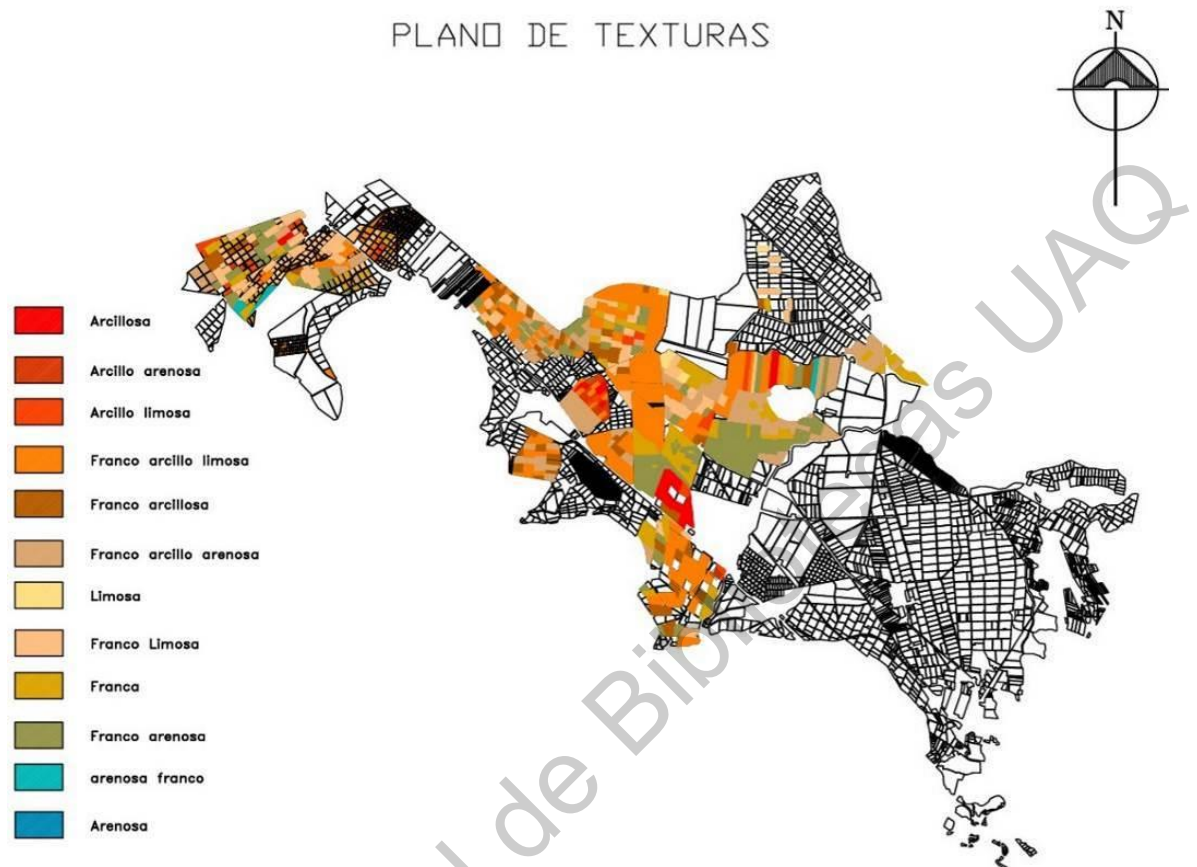


Figura 5. Plano de información textural disponible del distrito de riego 023 “San Juan del Río, Qro”.

FUENTE: Módulos Uno y Dos, Distrito de riego 023 (2018).

Con esta información se identificaron las parcelas y el número de muestras que se obtendría de cada parcela para incluirlas en el plan de vuelo. Posterior a ésta identificación se ubicaron las áreas de interés en el software Google Earth® con la finalidad de obtener los polígonos de vuelo (archivos .KML) e introducirlas al software eMotion® (ver Figura 6).

Fue necesario identificar zonas de entrenamiento para obtener un total de 100 polígonos de entrenamiento con sus respectivas muestras de suelo, pues se planeó emplear 75 para la generación del modelo y 25 para su validación.



Figura 6. Ubicación de los sitios de muestreo

Debe mencionarse que las parcelas seleccionadas se encontraban libres de residuos de cosecha, con un paso de arado y dos rastras, de tal manera que el factor rugosidad fuera homogeneizado en la medida de lo posible en todas las parcelas estudiadas. Esta fue una condición para seleccionar las zonas de entrenamiento. Si la parcela de interés no presentaba éstas condiciones de labrado del suelo, no se consideraba en el estudio.

6.3 Elaboración de plan de vuelos.

Las áreas seleccionadas fueron sobrevoladas con un dron eBee SQ (Figura 7). En este dron fue integrado un sensor multispectral Parrot Sequoia, el cual cuenta con 4 cámaras espectrales de 1.2 megapíxeles con una resolución radiométrica de 10 bits.



Figura 7. Dron eBee con el que se tomaron los datos de reflectancia

Para la elaboración del plan de vuelo se debe definir previamente la resolución espacial de las fotografías (centímetros cuadrados que deberá abarcar cada píxel), así como las áreas de interés de vuelo; lo cual determina la altura y distancias de vuelo. Esto se hizo con la ayuda del software eMotion®; el cual genera un plan de vuelo completo calculando la altitud requerida y mostrando la trayectoria proyectada que abarque en su totalidad el área de estudio (polígono), así como el traslape necesario según las necesidades del proyecto; todos estos datos ya procesados en el software se introdujeron en el dron, el cual quedó programado para su trayectoria.

Las longitudes de onda de las que el sensor Parrot Sequoia toma imágenes espectrales son: 550 nm (verde), 660 nm (rojo), 790 nm (infrarrojo cercano) y 735 nm (borde rojo), éste sensor se muestra en la Figura 8.



Figura 8. Sensor multispectral Parrot Sequoia

Para la programación de los vuelos, se generó un archivo con extensión .KML en Google Earth®, de tal manera que se abarcara toda el área a volar, éste archivo se introdujo en el software eMotion® para generar plan de vuelo correspondiente, tal como se muestra en la Figura 9.

6.4 Calibración de la reflectancia

Con la finalidad de que la hora o fecha de toma de información no sea una fuente de error en la toma de datos, se hizo una calibración de la reflectancia. Para calibrar cada píxel de las imágenes, se hace uso de valores de reflectancia conocidos con el uso de objetivos de campo como los que se muestran en la Figura 10.

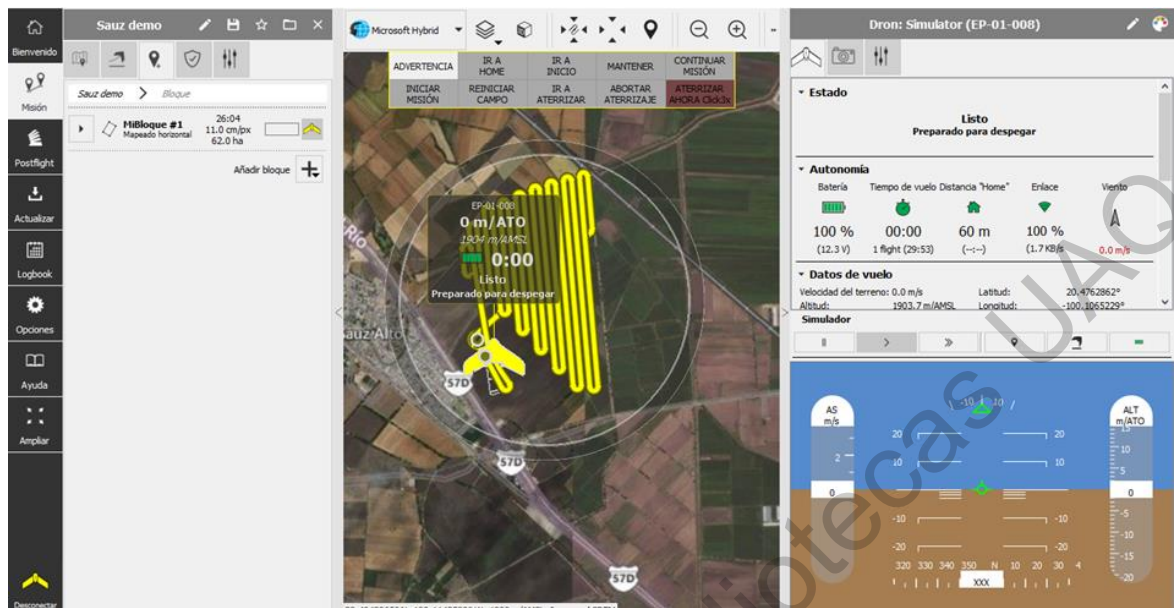


Figura 9. Ejemplo de un plan de vuelo generado en el software eMotion

Se capturaron imágenes del objetivo de campo de calibración de reflectancia, justo antes de iniciar cada vuelo. Los valores de píxeles de la imagen capturada se comparan con los valores de reflectancia conocidos de los objetivos. Usando esta información, se transforman los valores de los píxeles y con los datos obtenidos, se calculan los valores de reflectancia de las imágenes de los vuelos. El procedimiento en campo se muestra en la Figura 11.




Figura 10. Objetivo de campo para calibración de reflectancia



Figura 11. Calibración de los valores de reflectancia con la ayuda del objetivo de campo

6.5 Ubicación de áreas de muestreo

Para poder realizar un análisis que correlacione los datos tomados por el sensor multiespectral y los datos obtenidos de muestras de suelo analizadas en laboratorio, se delimitaron áreas pequeñas de donde se obtuvo la muestra de suelo a analizar. Previamente se definió que dichas áreas tuvieran dimensiones de 100 cm^2 , de las cuales se excluyen 50 cm^2 evitando contaminación de la reflectancia provocada por las marcas; es decir, para el análisis de la información, solo se tomaron en cuenta los 50 cm^2 del centro del polígono marcado, eliminando así las alteraciones a la reflectancia provocadas por las marcas colocadas en el suelo, éstas marcas son importantes para poder identificar en las imágenes tomadas, los píxeles que corresponden a las áreas de donde se extrajeron las muestras. Las marcas consistieron básicamente en círculos de cartón que por sus dimensiones pudieran ser claramente visibles en las imágenes tomadas. Un ejemplo de estas marcas se muestra en la Figura 12.



Figura 12. Marcas ubicadas en el suelo para la toma de imágenes multispectrales.

6.6 Vuelos en las zonas de interés

Una vez marcadas estas áreas de interés, se voló y se tomaron las imágenes aéreas. Es importante mencionar que para completar la meta de 100 puntos, fueron necesarios varios vuelos con la finalidad de volar suelos con amplia variabilidad textural.



Figura 13. Inicio de vuelo 1

6.7 Obtención de muestras de suelo

Una vez concluido el vuelo de la zona de interés, se procedió a tomar las muestras de suelo en las áreas delimitadas, a una profundidad de 20 cm; así como identificarlas en una base de datos para poder hacer los análisis de laboratorio.



Figura 14. Muestreo de suelos e identificación de muestras de las áreas de interés.

6.8 Conversión de niveles digitales de las imágenes espectrales a reflectancia y elaboración de ortomosaico

Ambas actividades se realizaron con el apoyo del software Pix4D®, en el caso de la conversión de los niveles digitales a reflectancia, se consideraron los valores generados en la calibración por medio de los objetivos de campo.

6.9 Obtención de textura de las muestras de suelo en laboratorio

Ya obtenidas y debidamente identificadas las muestras de suelo, se procedió a la obtención de los contenidos de arena, limo y arcilla de cada muestra en el laboratorio de suelos de la Universidad Autónoma de Querétaro, por medio del método de Boyoucos.

6.10 Extracción de valores de reflectancia por ancho de banda de los polígonos de entrenamiento y análisis estadístico

Una vez corregidas las imágenes (ortomosaico) y convertidos los valores digitales de las imágenes a reflectancia, se procedió a identificar los polígonos de entrenamiento en los ortomosaicos, con la finalidad de generar un archivo shape que los delimite. Este archivo .shp permite extraer el conjunto de píxeles de cada banda, que pertenecen a determinado polígono previamente muestreado, dicho procedimiento se realizó con las herramientas de las que dispone el software QGIS. De éste conjunto de píxeles se hizo un pequeño análisis estadístico con las librerías disponibles en el software R obteniendo media, mediana y moda. Cada uno de estos datos por ancho de banda se convirtieron en las variables independientes que se emplearon en un análisis correlacional con los contenidos de arena, limo y arcilla de las muestras. Es decir, se obtuvo la media, mediana y moda de cada una de las bandas, lo que generó un total de 12 variables iniciales. Estas covariables se correlacionaron con las variables dependientes para obtener aquellas con la mayor correlación y emplearlas en la generación del modelo.

6.11 Selección de índices

Se realizó una revisión de literatura para seleccionar algunas covariables potenciales; López, D. y Torres, A. (2018) recomendaron obtener los cocientes de todas las variables entre sí, pues mencionan que una de las principales ventajas de esta técnica es que la imagen resultante conserva las características espectrales de las imágenes originales, no así las variaciones en las condiciones de iluminación. El rango dinámico del cociente de imágenes es menor que el de las originales, debido a que los valores extremos de radiancia causados por la topografía se eliminan. Por lo tanto, el contraste de reflectancia entre los distintos objetos de la superficie puede mejorar utilizando composiciones a color de diferentes cocientes de la imagen.

Gholizadeh *et al.* (2018) emplearon algunos índices generados a partir de las bandas objeto de éste estudio, los cuales se presentan a continuación:

- Índice de vegetación verde-rojo (Tucker, 1979):

$$GRVI = \frac{B3 - B4}{B3 + B4} \quad (7)$$

- Índice relacionado con el brillo (Escadafal, 1989):

$$BI = \frac{\sqrt{(B4 \times B4) + (B3 \times B3)}}{2} \quad (8)$$

- Índice de enrojecimiento (Pouget et al., 1990):

$$RI = \frac{B4 \times B4}{B3 \times B3 \times B3} \quad (9)$$

- Índice de color (Pouget, et al., 1990):

$$CI = \frac{B4 - B3}{B4 + B3} \quad (10)$$

donde B3 corresponde a la banda del Rojo (660 nm) y B4 corresponde al Infrarrojo cercano (790 nm).

Y el citado por Maya, Lacaze, Monteforte y Passini en el 2004, en su trabajo “Análisis de imágenes SPOT: erosión en la región montañosa del sur de la Península de Baja California, México”:

$$IB = \sqrt{\left[\frac{(B2^2 + B3^2 + B4^2)}{3} \right]} \quad (11)$$

donde B2 es la banda verde (550 nm).

Mahmoudabadi et al., (2017) emplearon también el Índice de carbonatos que es el cociente entre la B3 y la B2.

Estas variables se emplearon en un análisis de correlación de Pearson para obtener aquellas con la mejor correlación con los contenidos de arena, limo y arcilla.

6.12 Análisis de correlación:

Se realizó un análisis de correlación de Pearson entre la reflectancia tomada por cada una de las bandas B2, B3, B4 y BR (media, mediana y moda), con los datos de contenido de arena, limo y arcilla resultantes, con la finalidad de identificar la variable estadística que mejor se correlacione con las fracciones de suelo. Una vez identificada la variable con mejor correlación, se procedió a calcular los cocientes e índices obtenidos de la literatura descritos en el apartado anterior. Este análisis también fue realizado con las herramientas que dispone el software R.

6.13 Generación de modelo

De acuerdo a la literatura revisada, se realizó una regresión lineal multivariable con el apoyo del software R. Para determinar el ajuste del modelo, se generó el coeficiente de determinación del modelo generado. Se obtuvieron también los modelos exponencial y polinomial.

6.14 Validación de resultados

Originalmente, se planeó obtener 75 datos para calibrar el modelo y 25 datos independientes para validarlo. Sin embargo, al analizar la información proveniente de laboratorio, se encontraron algunos datos de contenidos de arena, limo y arcilla que se alejaban de los datos obtenidos de muestras muy cercanas, y al hacer análisis de outliers por parcela, fueron considerados bajo éste término, por lo que fueron exiliados del análisis, quedando solamente un total de 60 datos. Por ello es que se decidió emplear los 60 datos para calibrar el modelo y realizar una validación cruzada.

7 RESULTADOS

Se realizó un total de 7 vuelos con el objetivo inicial de obtener un total de 100 muestras de suelo, con la misma cantidad de zonas de entrenamiento previamente marcadas. Sin embargo, como se mencionó previamente, al momento de revisar los resultados de laboratorio de muestras de la misma parcela (parcelas homogéneas), se encontró que algunas salían de los rangos obtenidos en diferentes muestras de la misma parcela. Por lo

que se hicieron pruebas de detección de outliers por parcela y éstas muestras detectadas como outliers, fueron eliminadas, eliminando un total de 40 muestras. Estos errores en los datos se atribuyen a errores en las pruebas de laboratorio.

7.1 Procesamiento de imágenes

Una vez obtenidas las imágenes en campo, se procedió a obtener los valores de reflectancia de cada uno de los píxeles de las imágenes por medio del software PIX4D®, así como a generar los ortomosaicos de cada uno de los vuelos, un par de ejemplos (vuelo 1 y 2) se presentan en las Figuras 15 y 16.




Figura 15. Ortomosaico y modelo de superficie digital disperso (DSM) correspondiente (Vuelo 1)

En estas imágenes puede apreciarse claramente la diferencia en la coloración debido a las diferencias en elevación a lo largo de toda el área; así como las imágenes correspondientes a la reflectancia en las cuatro bandas objeto de éste estudio.

De igual manera, en las Figuras 17 a 20 puede apreciarse la diferencia en las profundidades de color captadas por el sensor en los diferentes ancho de banda objeto de estudio. Incluso

pueden apreciarse las marcas que se pusieron para identificar los polígonos de entrenamiento. Puede apreciarse también la colocación de las marcas a modo de cuadrícula, lo que permitió una mejor identificación de las muestras por vuelo, al ser enviadas al laboratorio. Se empleó un círculo para mostrar las marcas puestas en las zonas de entrenamiento.




Figura 16. Ortomosaico y modelo de superficie digital disperso (DSM) correspondiente (Vuelo 2).

7.2 Análisis estadístico básico

De cada uno de los puntos de muestreo, se delimitaron los polígonos de entrenamiento en las imágenes por medio de las herramientas de las que dispone el software QGIS, estos polígonos tienen la información de la reflectancia de cada uno de los píxeles que en conjunto forman las áreas de entrenamiento.




Figura 17. Imagen tomada por el sensor en el ancho de banda 550 nm (verde).



Figura 18. Imagen tomada por el sensor en la banda 790 nm (Infrarojo cercano).




Figura 19. Imagen tomada por el sensor en el ancho de banda 660 nm (rojo).



Figura 20. Imagen tomada por el sensor en el ancho de banda 735 nm (Borde rojo).

Como primer paso, se realizó un test de normalidad a los conjuntos de datos de reflectancia que formaron las zonas de entrenamiento (test de Shapiro – Wilks con un nivel de significancia de 0.05%), el cual arrojó que el 47.5% de los conjuntos de datos tuvieron una distribución normal. En el Anexo 1 se presentan algunas de las distribuciones encontradas en la reflectancia de los polígonos de entrenamiento, para las 4 bandas en estudio.

Para analizar la información, se obtuvo la media, mediana y moda de cada conjunto de píxeles (zonas de entrenamiento), y se generó el coeficiente de correlación de Pearson de cada uno de éstos valores con sus correspondientes datos de textura (contenidos de arena, limo y arcilla), esto con la finalidad de identificar la variable estadística que mejor se correlacionara con las variables dependientes objeto de éste estudio, encontrándose las correlaciones más altas al relacionar los contenidos de arena, limo y arcilla con la moda de la reflectancia de los polígonos de entrenamiento (en el Anexo 2 se especifican los valores de la media, mediana y moda de algunos de los conjuntos de píxeles de reflectancia que conforman las zonas entrenamiento).

Con la finalidad de correlacionar algunos índices que han sido empleados en la literatura para identificar textura del suelo, se calcularon algunos que diversos autores han utilizado previamente; así como los cocientes entre bandas de las mismas zonas de entrenamiento.

Se realizó también un análisis de componentes principales empleando solo los valores de reflectancia de las 4 bandas objeto de éste estudio, para utilizarlo como una nueva variable, los resultados se presentan en las Tablas 4 y 5.

Tabla 3. Importancia de los componentes del Análisis de componentes principales

	Componente 1	Componente 2	Componente 3	Componente 4
Desviación estándar	0.05275028	0.009313341	0.003851825	0.002070844
Proporción de varianza	0.96334953	0.030029302	0.005136502	0.001484667
Proporción acumulativa	0.96334953	0.993378831	0.998515333	1.000000000

Tabla 4. Componentes principales de las 4 bandas en estudio

	CP1	CP2	CP3	CP4
Verde (B2)	-0.4833671	0.79777884	-0.1602822	-0.3228231
Rojo (B3)	-0.5105114	0.06663456	0.5546536	0.6536798
Borde rojo (BR)	-0.5008112	-0.48971176	0.3384260	-0.6283616
Infrarrojo cercano (B4)	-0.5048985	-0.34538550	-0.7430591	0.2713846

Dado que el 96.33% de la varianza se encontró en el Componente principal 1, éste componente se empleó como una ecuación más para obtener la correlación con los contenidos de arena, limo y arcilla, resultando la siguiente ecuación:

$$CP1 = -0.4833671 * B2 - 0.5105114 * B3 - 0.5008112 * BR - 0.5048985 * B4 \quad (12)$$

Los diagramas de cajas de los valores de cada variable empleada por clasificación textural se presentan en las Figuras 21 a 41. Estos gráficos son una presentación visual que describe varias características importantes, al mismo tiempo, tales como la dispersión y simetría.

Con fines de éste trabajo, y de acuerdo a las clases texturales propuestas por la USDA, la clasificación de los suelos en estudio es: Ar (Arcilla), F (Franco), FA (Franco arenoso), FAr (Franco arcilloso) y FAAr (Franco arcillo arenoso).

En el caso de la distribución de la reflectancia en la banda verde (ver Figura 21), puede observarse mayor dispersión de los datos en las clases Arcilla y Franco Arenoso. Mientras que en el caso de la reflectancia en la banda del rojo, infrarrojo cercano y borde rojo, la mayor dispersión de los datos se observa solo en los suelos clasificados como Franco Arenosos.

Los valores de reflectancia más altos para todos las clases texturales estudiadas se observan en la banda del infrarrojo cercano (ver Figura 23). Los valores más bajos de reflectancia para todas las clases texturales se observa en la banda verde (Figura 21).




Figura 21. Reflectancia en la banda verde por clase textural




Figura 22. Reflectancia en la banda roja por clase textural

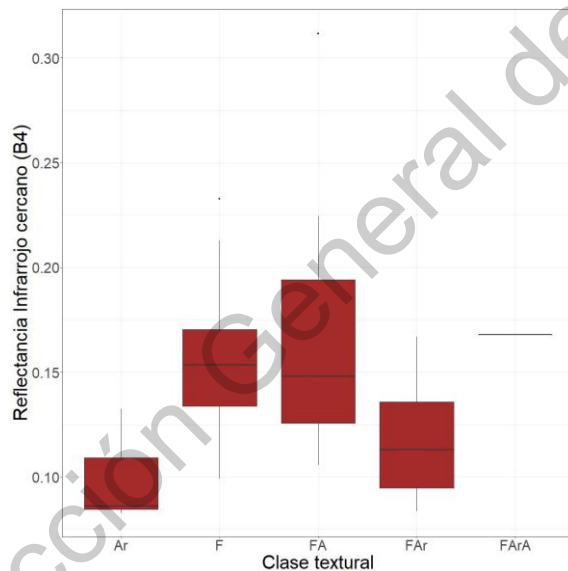


Figura 23. Reflectancia en la banda infrarrojo cercano por clase textural




Figura 24. Reflectancia en la banda borde rojo por clase textural

La clase textural con los valores más altos de reflectancia en todas las bandas es la Franco arenosa. Esta clase textural tiene los contenidos de arena más altos, en comparación con el resto de las clases, con un promedio de 58.46%; así como los contenidos de arcilla más

bajos (ver Figuras 21 a 24). La clase textural con los valores de reflectancia más bajos es la Arcilla; con altos contenidos de arcilla y bajos contenidos de arena, seguida de la Franco arcillosa, caso contrario a las características de los suelos Franco arenosos. Esto coincide totalmente con los resultados encontrados por Barnes y Baker (1999) que encontraron que en la banda del infrarrojo cercano la reflectancia fue mayor en el rango de los suelos con mayores contenidos de arena.

A partir de la Figura 25 se presentan las variaciones en cada uno de los cocientes y ecuaciones encontradas en la literatura que fueron aplicadas en éste estudio. Dado que gráficamente no es fácil interpretarlos, en el siguiente apartado se presentan un análisis de correlación que permite conocer la correlación de cada uno de éstos resultados con los contenidos de arena, limo y arcilla de las muestras estudiadas.

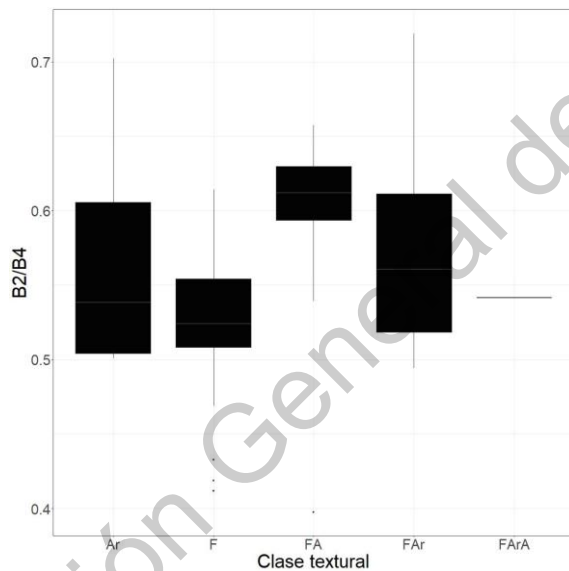


Figura 25. Cociente B2/B4 por clase textural




Figura 26. Cociente B2/BR por clase textural




Figura 27. Cociente B2/B3 por clase textural




Figura 28. Cociente B4/B2 por clase textural




Figura 29. Cociente B4/BR por clase textural




Figura 30. Cociente B4/B3 por clase textural




Figura 31. Cociente BR/B2 por clase textural

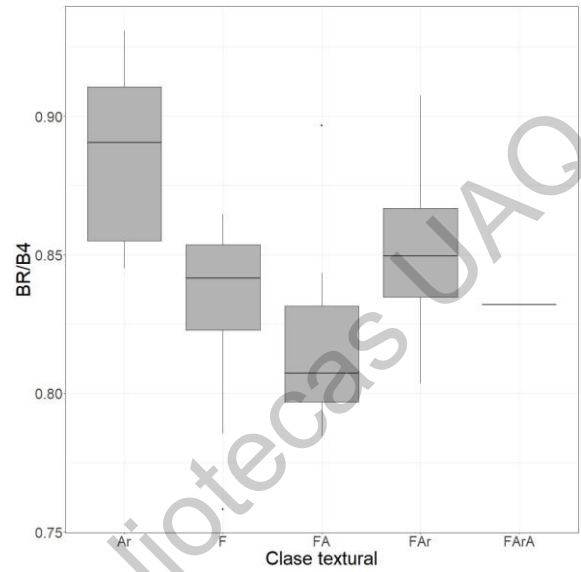


Figura 32. Cociente BR/B4 por clase textural




Figura 33. Cociente BR/B3 por clase textural

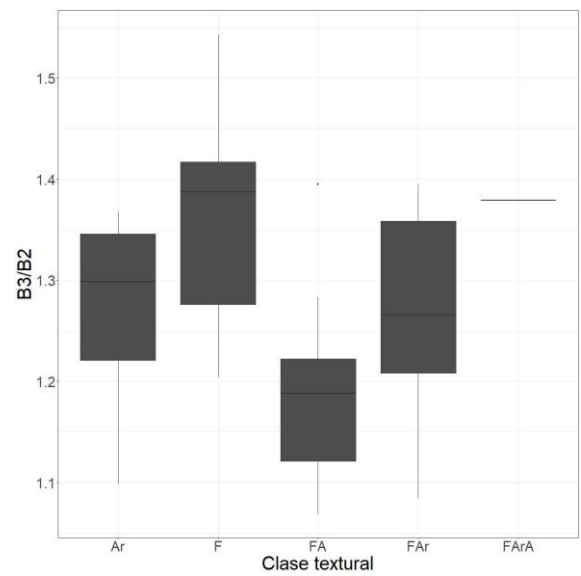


Figura 34. Cociente B3/B2 por clase textural




Figura 35. Cociente B3/B4 por clase textural




Figura 36. Cociente B3/BR por clase textural




Figura 37. Índice GRVI por clase textural




Figura 38. Índice RI por clase textural

De acuerdo con la Figura 37, el Índice de vegetación verde-rojo (GRVI), no muestra grandes variaciones entre las diferentes clases de suelos estudiadas, quizá porque éste índice fue creado para analizar vegetación. Mientras que el Índice de enrojecimiento (RI) muestra valores más altos en los suelos con mayores contenidos de arcilla, respecto al resto

de los suelos analizados (Arcilla y Franco arcilloso), y mayor dispersión de los datos en los suelos clasificados como Arcilla y Franco Arenosos.




Figura 39. Índice BI por clase textural

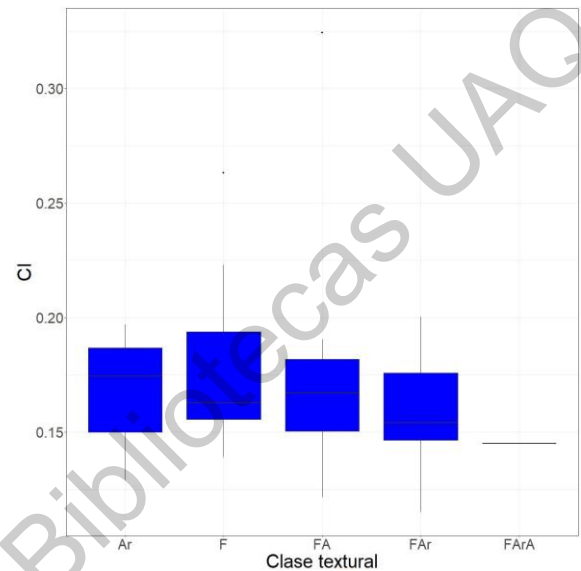


Figura 40. Índice CI por clase textural

El Índice relacionado con el brillo (BI) muestra sus valores más altos en las clases texturales con mayores contenidos de arena, texturas Franca (F) y Franco arenosa (FA), y sus valores más bajos en la clase textural con mayores contenidos de arcilla (Arcilla y Franco arcilloso), lo cual puede observarse en la Figura 39. La mayor dispersión de los datos se encuentra en la clase textural Franco arenosa.

El Índice de color (CI) no muestra variaciones significativas por clase textural, como se muestra en la Figura 40.

El índice de carbonato no muestra algún patrón que pueda relacionarse con los contenidos de arena, limo y arcilla de manera gráfica, tal como puede observarse en la Figura 41.




Figura 41. Índice de carbonato por clase textural

7.3 Análisis de correlación

Se realizó un análisis de correlación de Pearson, entre cada una de las variables independientes obtenidas directamente de las banda y las calculadas por medio de los cocientes e índices obtenidos de literatura; así como del componente principal obtenido a partir de la reflectancia de las 4 bandas. Los coeficientes de correlación de Pearson obtenidos con el apoyo del software R se presentan en la Tabla 5.

Tabla 5. Coeficientes de correlación de Pearson de los diferentes índices y los contenidos de arena, limo y arcilla.

Variable	ARENA	LIMO	ARCILLA
Verde (B2)	0.6200	0.1395	-0.6320
Infrarrojo cercano (B4)	0.5432	0.1063	-0.5475
Borde rojo (BR)	0.4853	0.0815	-0.4839
Rojo (B3)	0.5227	0.1272	-0.5366
GRVI	-0.0141	0.1242	-0.0350
BI	0.5397	0.1141	-0.5473
RI	-0.4031	-0.2300	0.4650
CI	0.0141	-0.1242	0.0350
IB	0.5612	0.1203	-0.5697
B2/B3	0.2614	0.0500	-0.2630

Variable	ARENA	LIMO	ARCILLA
B2/B4	0.1822	0.0896	-0.2046
B2/BR	0.3358	0.1609	-0.3754
B3/B2	-0.2581	-0.0367	0.2547
B3/B4	-0.0123	0.1223	-0.0360
B3/BR	0.3309	0.2554	-0.4075
B4/B2	-0.1789	-0.0917	0.2023
B4/B3	0.0175	-0.1271	0.0330
B4/BR	0.4858	0.2224	-0.5392
BR/B2	-0.3296	-0.1604	0.3694
BR/B3	-0.3266	-0.2679	0.4084
BR/B4	-0.4906	-0.2296	0.5464
Índice de carbonato	-0.2581	-0.0367	0.2547
CP1	-0.5493	-0.1135	0.5561

El mayor coeficiente de correlación de Pearson al analizar los contenidos de arena se encontró con la reflectancia en la banda del verde (0.62) seguido de la correlación con el índice de brillo estudiado por Maya *et al.* (2004), con un valor de (0.56). El menor coeficiente de correlación encontrado en el análisis de arena fue con el coeficiente B3/B4. De las bandas en estudio, la banda del borde rojo, es la que presenta el menor coeficiente de correlación de Pearson con el contenido de arena (0.49)

Respecto al análisis hecho al contenido de arcilla, el mayor coeficiente de correlación de Pearson se encontró también al relacionarlo con la banda verde, pero con valor negativo (-0.63); seguido del (-0.55) al relacionarlo con el mismo índice de brillo del caso anterior. El menor coeficiente de correlación se obtuvo al relacionarlo con el cociente B4/B3. El menor coeficiente de correlación de Pearson del contenido de arcilla con las bandas en estudio, se obtuvo también con la banda borde rojo (-0.48).

La matriz de correlación se muestra en la Figura 42.




Figura 42. Coeficientes de correlación de Pearson entre las variables del estudio

En el caso del contenido de limo, el mayor coeficiente de correlación de Pearson (-0.27) se obtuvo en la relación con el cociente BR/B3. Las bandas en estudio no muestran coeficientes de correlación significativos. Mientras que el menor coeficiente se obtuvo en la relación con el cociente B3/B2 y el índice de carbonato, con un valor de -0.04.

Gholizadeh *et al.* (2018) en su estudio “Soil organic carbon and texture retrieving and mapping using proximal, airborne and Sentinel-2 spectral imaging” realizaron un análisis de correlación con diferentes índices y el contenido de arcilla, para 4 diferentes lugares de

la República Checa, algunos de los cuales se incluyeron en éste estudio, encontrando los datos que se muestran en la Tabla 6. Puede observarse que se superaron todos los coeficiente de correlación al relacionar el contenido de arcilla con la reflectancia obtenida de las bandas B2 a B4, debe recordarse que la resolución espacial de las imágenes empleadas por estos autores es menor que la del presente estudio.

Tabla 6. Correlogramas de arcilla en las bandas extraídas de Sentinel-2 e índices espectrales calculados en diferentes ubicaciones (Gholizadeh *et al.*, 2018).

índice	Sitio			
	Prestavlky	Sardice	Nova Ves	Jicín
B2	0.43	-0.24	-0.03	0.00
B3	0.48	-0.26	-0.03	0.07
B4	0.46	-0.28	-0.09	-0.10
GRVI	0.42	-0.17	0.10	0.40
BI	0.47	-0.27	-0.07	-0.04
RI	-0.45	0.21	-0.06	-0.32
CI	-0.28	-0.01	-0.14	-0.44

7.4 Regresión lineal múltiple

Dado que es uno de los métodos más empleados por diversos autores mencionados previamente, se realizó una regresión lineal múltiple empleando como variables independientes, la reflectancia obtenida de las 4 bandas en estudio. Para realizar dicha regresión, se empleó también el software R.

Los modelos generados para cada una de las variables dependientes se muestran a continuación:

Contenido de arena (%):

Al modelar el contenido de arena con la reflectancia de las 4 bandas como variables independientes, se obtuvo el siguiente modelo:

$$ARENA = 1316.241 * B2 - 1645.69 * B3 + 189.104 * BR + 591.231 * B4 - 1.726 \quad (13)$$

con un coeficiente de determinación $R^2 = 0.5593$.

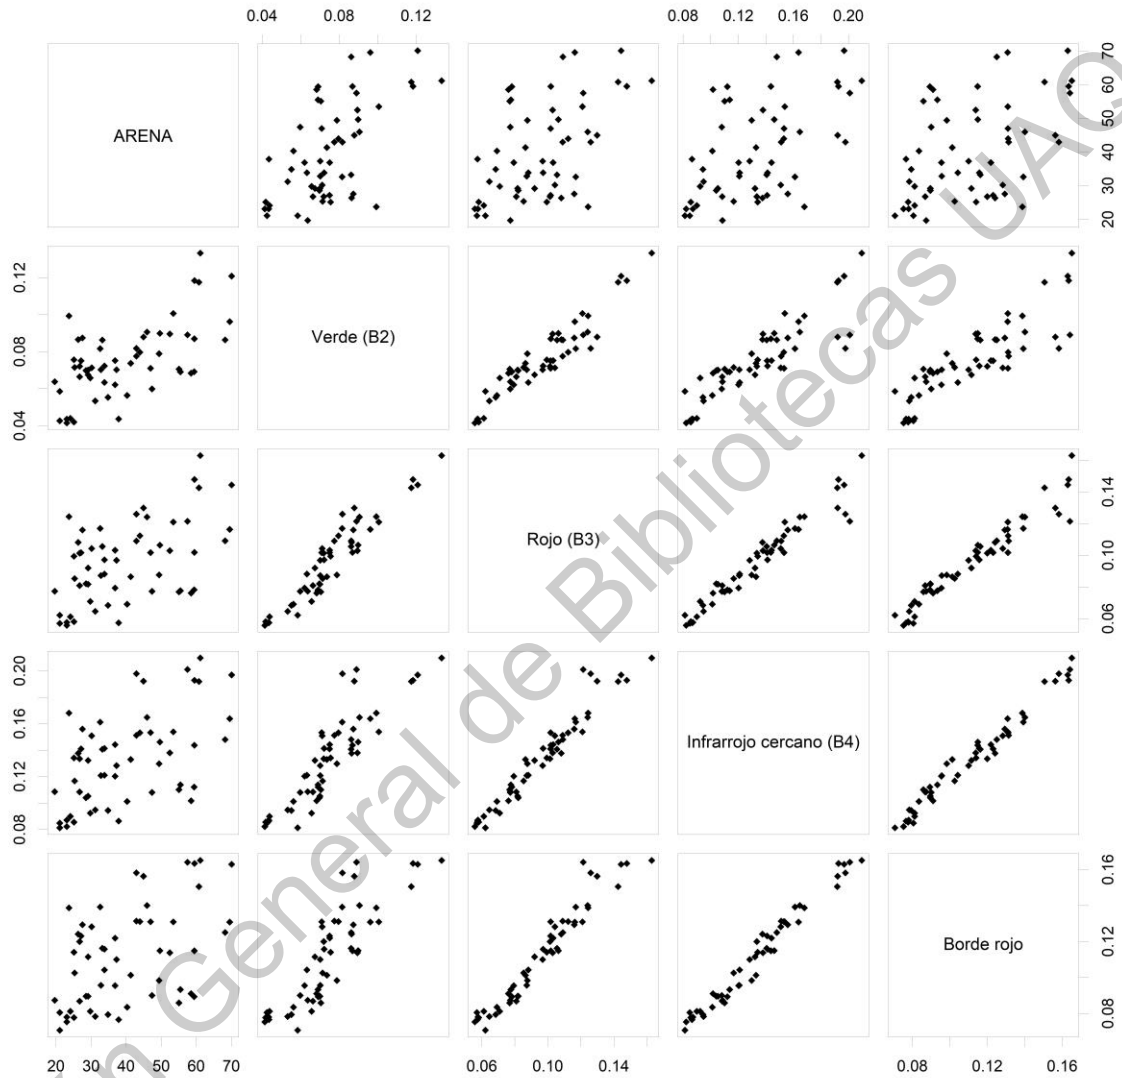


Figura 43. Relación entre el contenido de arena y la reflectancia de las 4 bandas objeto de estudio

Se trata del modelo, con el mejor coeficiente de determinación obtenido en todo el estudio, lo cual se puede deber a la buena relación positiva con la reflectancia en la banda 2, la cual presenta la menor dispersión de los datos como puede apreciarse en la Figura 43, respecto del resto de las variables independientes.

Contenido de limo (%):

El modelo que relaciona el contenido de limo con los valores de reflectancia de las bandas en estudio, se muestra en la Ecuación 15.

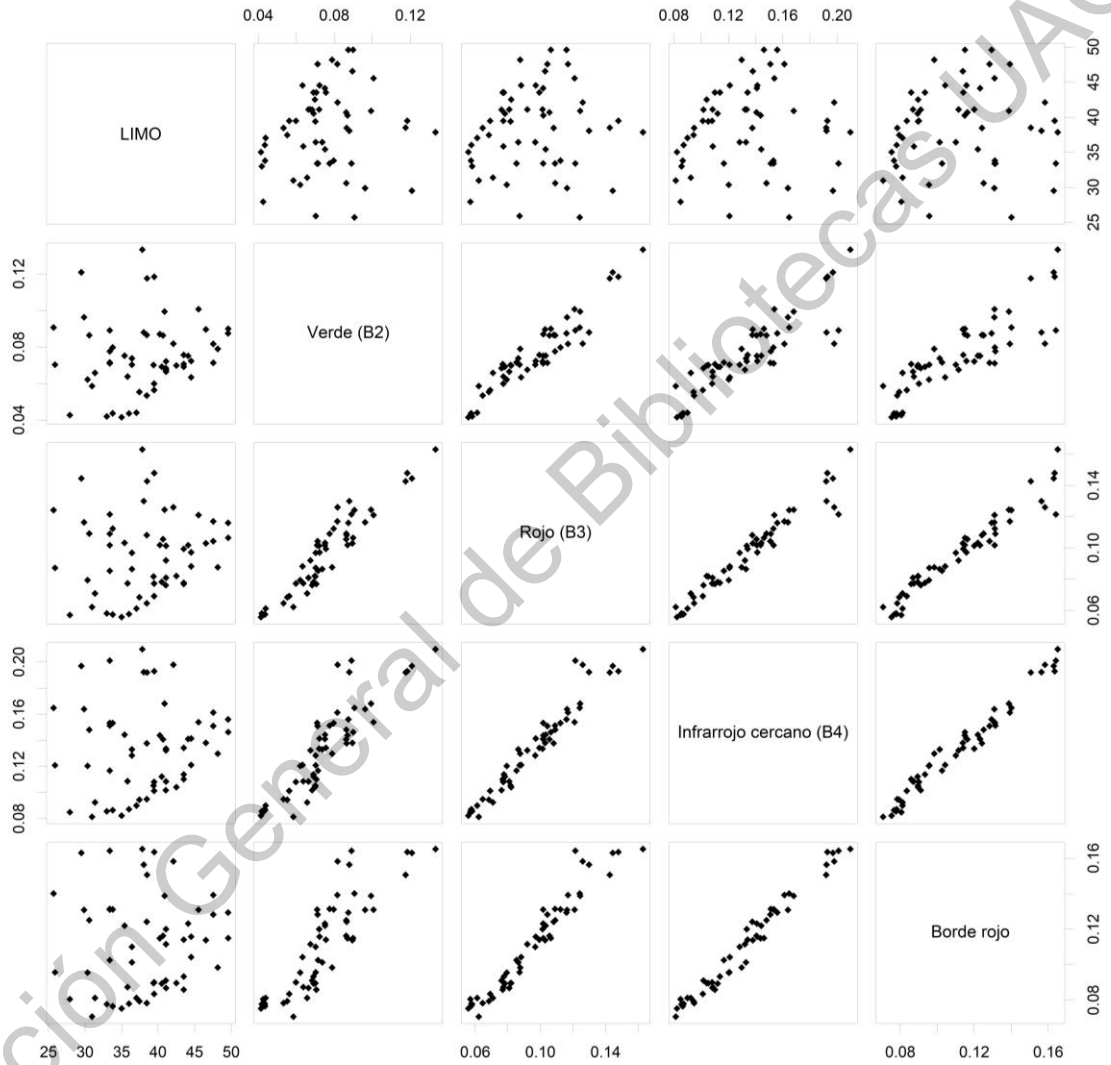


Figura 44. Relación entre el contenido de limo y la reflectancia de las 4 bandas objeto de estudio

$$LIMO = -147.272 * B2 + 340.449 * B3 - 355.437 * BR + 123.578 * B4 + 39.967 \quad (14)$$

Este modelo proporciona el menor coeficiente de determinación de todos los modelos generados en el presente estudio (0.0616). Lo cual refleja la poca relación que existe entre

el contenido de limo de los suelos y la reflectancia de las bandas en estudio. La dispersión de los datos, puede apreciarse en la Figura 44.

Contenido de arcilla (%):

La ecuación que representa la regresión lineal múltiple obtenida para determinar el contenido de arcilla a partir de las 4 bandas en estudio se muestra a continuación:

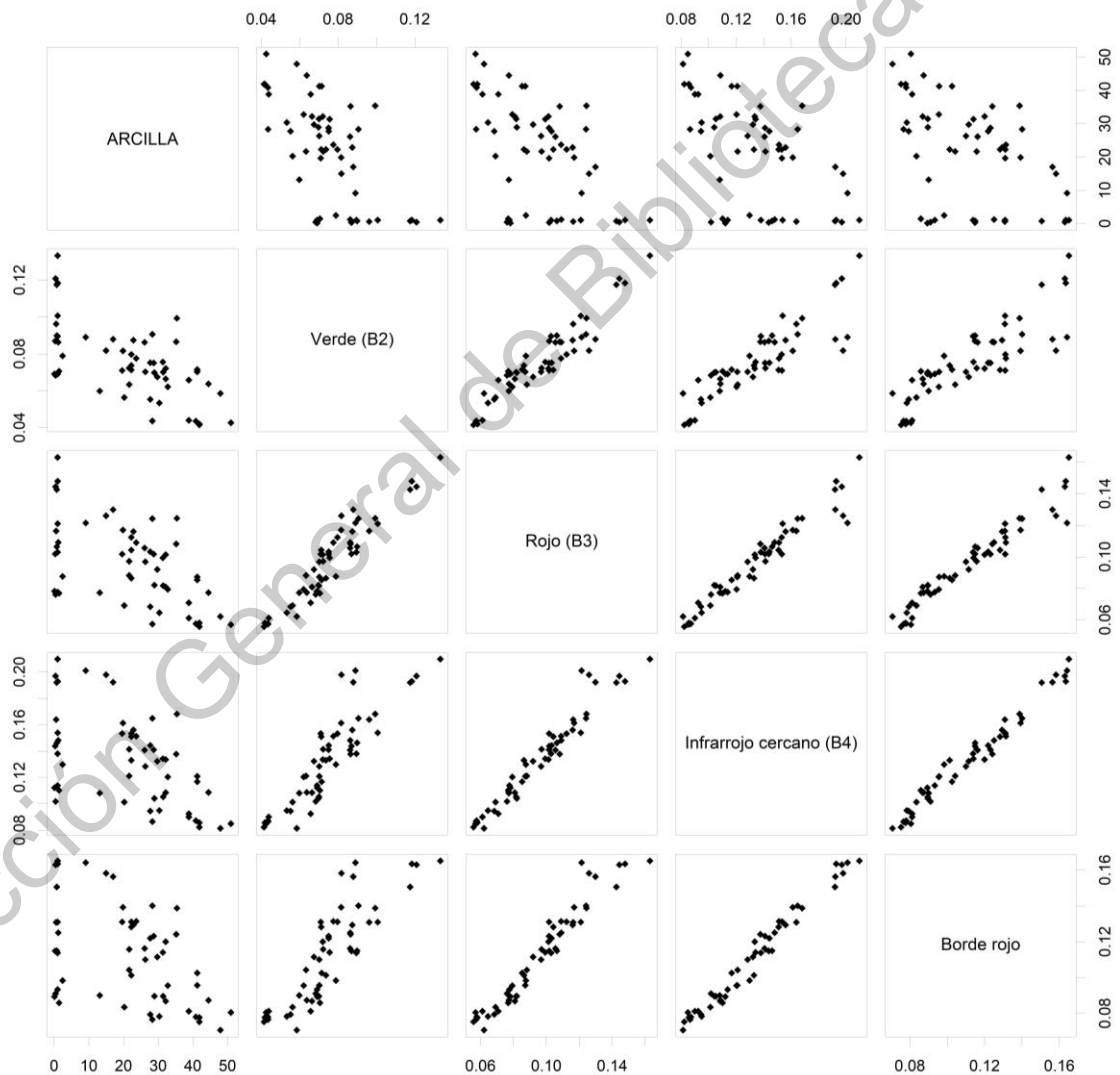


Figura 45. Relación entre el contenido de arcilla y las ocho variables con las que más se correlaciona

$$ARCILLA = -1168.85 * B2 + 1305.186 * B3 + 166.426 * BR - 714.917 * B4 + 61.759 \quad (15)$$

cuyo coeficiente de determinación es de 0.5418. La relación de ésta fracción del suelo con las variables independientes objeto de éste estudio se puede apreciar gráficamente en la Figura 45.

De éstas ecuaciones puede resumirse que el mayor coeficiente de determinación se obtuvo al modelar el contenido de arena, seguido del modelo del contenido de arcilla y por último el del contenido de limo, cuyo coeficiente de determinación es muy bajo.

En el estudio realizado por Thomasson *et al.* (2001) donde realizó una regresión lineal múltiple entre 50 anchos de banda de un espectrofotómetro Cary 500UV/Vis/NIR y los contenidos de arena y arcilla de diferentes suelos en Mississippi, EUA, se obtuvieron valores de R² para arcilla de 0.50 y 0.42, así como de arena de 0.30 y 0.18, por lo que puede decirse que se mejoraron los resultados obtenidos por éstos autores incluso aunque ellos hayan empleado espectrofotómetro.

7.5 Modelo exponencial

Otro de los modelos empleados en el análisis fue el exponencial, del cual se presentan resultados a continuación:

Contenido de arena (%):

La variable independiente para relacionarla exponencialmente con el contenido de arena, fue aquella con la que se obtuvo el coeficiente de correlación de Pearson más alto, la banda del verde, cuyo modelo exponencial es:

$$ARENA = 16.656 * e^{10.773 * B2} \quad (16)$$

donde se obtuvo un coeficiente de determinación de 0.36. La linealización de dicha relación, puede apreciarse en la Figura 46.




Figura 46. Linealización de la relación entre la banda verde y el contenido de arena

El contenido de limo no se modeló con esta metodología pues los coeficientes de correlación son muy bajos al relacionarlo con las variables independientes objeto de éste estudio.

Contenido de Arcilla (%):

El modelo exponencial obtenido al relacionar el contenido de arcilla con la banda verde es:

$$ARCILLA = 399.56 * e^{-48.46*B2} \quad (17)$$

obteniéndose un coeficiente de determinación de 0.32 en dicha relación. La linealización de esta relación, puede apreciarse en la Figura 47.




Figura 47. Linealización de la relación entre la banda verde y el contenido de arcilla

En ésta modelación de tipo exponencial, el contenido de arena se obtiene con un coeficiente de determinación ligeramente más alto que el obtenido con el modelo para determinar el contenido de arcilla.

7.6 Regresión polinomial

Con la idea de mejorar la relación exponencial obtenida en el apartado anterior de los contenidos de arena y arcilla y la banda verde, se obtuvieron otros modelos con una regresión polinomial, los cuales se muestran a continuación:

Contenido de arena (%):

Se usó nuevamente la banda verde como variable independiente y obtener el modelo de 4 polinomios el cual se presenta como ecuación 19:

$$ARENA = -3474381.2 * B2^4 + 1150453.1 * B2^3 - 135638.7 * B2^2 + 7163.5 * B2 - 110.8 \quad (18)$$

$$R^2 = 0.392$$

Contenido de Arcilla (%):

Mientras que el modelo polinomial para obtener el contenido de arcilla a partir de los datos de reflectancia en la banda verde se muestra a continuación:

$$ARCILLA = 2181804.5 * B2^4 - 738219.6 * B2^3 + 91671 * B2^2 - 5427.6 * B2 + 155.3 \quad (19)$$

$$R^2 = 0.4087$$

Con éste tipo de regresión, el coeficiente de determinación para obtener el contenido de arcilla es más alto que el generado para calcular el contenido de arena.

Puede apreciarse también que la regresión de tipo polinomial, mejora los coeficientes de determinación tanto para determinar contenido de arena como de arcilla, empleando sólo una variable predictora.

7.7 Modelos por clase textural

Con la finalidad de evaluar si la relación entre las variables independientes y los contenidos de arena, limo y arcilla se mejora al generar los modelos por clase textural, se presenta el siguiente análisis:

a) Clase textural: Arcilla

De acuerdo con la información de la Tabla 7, los mayores coeficientes de correlación de Pearson de los datos clasificados como Arcilla según la USDA; se obtienen con la banda de infrarrojo cercano tanto para contenidos de arena como de arcilla. A pesar de que no son tan bajos, si son más bajos que los obtenidos al analizar todos los datos juntos, donde fue más determinante la banda verde.

Lo que sí es importante resaltar es la mejora en la correlación del contenido de limo respecto de los valores de reflectancia por bandas; pues al analizar el conjunto de datos completo los coeficientes de correlación de Pearson con cada banda no fueron mayores a 0.14, casi la mitad de la obtenida en éste análisis.

Tabla 7. Coeficientes de correlación de Pearson entre las fracciones del suelo y la reflectancia por banda de la clase textural Arcilla

Banda	Arena	Limo	Arcilla
Verde (B2)	0.3980	-0.2555	-0.1830
Infrarrojo cercano (B4)	0.5788	-0.2340	-0.4029
Borde rojo	0.5358	-0.2116	-0.3780
Rojo (B3)	0.5437	-0.2691	-0.3294




Figura 48. Relación de las fracciones del suelo y la reflectancia por banda de a clase textural Arcilla

b) Clase textural: Franco arcilloso

En el caso del análisis de las muestras clasificadas como Franco arcilloso, no existe ningún tipo de correlación (o es muy baja), entre las tres fracciones del suelo y la reflectancia por banda.

Tabla 8. Coeficientes de correlación de Pearson entre las fracciones del suelo y la reflectancia por banda de la clase textural Franco arcilloso

Banda	Arena	Limo	Arcilla
Verde (B2)	-0.0719	0.0785	0.0099
Infrarrojo cercano (B4)	0.0653	0.0230	-0.1413
Borde rojo	0.0275	0.0436	-0.1070
Rojo (B3)	0.0048	0.0650	-0.0991




Figura 49. Relación de las fracciones del suelo y la reflectancia por banda de a clase textural Franco arcilloso

c) Clase textural: Franco

En el caso del conjunto de muestras clasificadas como suelo Franco, los coeficientes de correlación de Pearson fueron menores que los obtenidos al analizar todas las muestras de suelo, para las tres fracciones de suelo.

Tabla 9. Coeficientes de correlación de Pearson entre las fracciones del suelo y la reflectancia por banda de la clase textural Franco

Banda	Arena	Limo	Arcilla
Verde (B2)	-0.2125	0.1287	0.1805
Infrarrojo cercano (B4)	0.0616	0.0778	-0.2214
Borde rojo	0.0321	0.0748	-0.1657
Rojo (B3)	-0.0902	0.1328	-0.0381




Figura 50. Relación de las fracciones del suelo y la reflectancia por banda de a clase textural Franco

d) Clase textural: Franco arenoso

La Tabla 10 muestra que al analizar únicamente las muestras de suelo clasificadas como Franco arenoso, se obtuvo el mejor coeficiente de correlación de Pearson para contenido de limo. Los coeficientes para contenido de arena y arcilla no son mejores que cuando se emplea el conjunto de datos completo.

Tabla 10. Coeficientes de correlación de Pearson entre las fracciones del suelo y la reflectancia por banda de la clase textural Franco arenoso

Banda	Arena	Limo	Arcilla
Verde (B2)	0.3803	-0.3581	-0.0672
Infrarrojo cercano (B4)	0.4039	-0.5122	0.3246
Borde rojo	0.4388	-0.5451	0.3184
Rojo (B3)	0.4096	-0.4346	0.0746



Figura 51. Relación de las fracciones del suelo y la reflectancia por banda de a clase textural Franco arenoso

8 VALIDACIÓN

Dado que ya no se pudo destinar un porcentaje de los datos colectados en campo exclusivamente para la validación, se llevó a cabo la validación cruzada; es decir, se emplearon los modelos generados para estimar los contenidos de arena, limo y arcilla a partir de sus correspondientes valores de reflectancia por banda espectral.

Se graficaron los datos estimados contra los datos medidos, obteniendo los coeficientes de determinación que se muestran en la Figura 52 y Figura 53.

Modelos lineales

En el caso del modelo lineal para determinar contenido de arena, al graficar los datos medidos en campo contra los estimados en laboratorio, se obtiene un coeficiente de determinación de 0.55. La dispersión de los datos puede apreciarse en la Figura 52.




Figura 52. Datos de arena medidos contra los estimados modelo lineal ($R^2= 0.55$)

Mientras que para el caso de la gráfica de los datos medidos contra los estimados con el modelo lineal para determinar el contenido de arcilla, el coeficiente de determinación

obtenido es de 0.53. La dispersión de la relación de los datos medidos respecto de los datos estimados por el modelo se presenta en la Figura 53.




Figura 53. Datos de arcilla medidos contra los estimados modelo lineal ($R^2= 0.53$)

Modelos exponenciales

En lo que respecta al modelo exponencial para determinar el contenido de arena a partir de los datos de reflectancia obtenidos de la B2, la gráfica que relaciona los contenidos de arena medidos respecto de los obtenidos por medio del modelo generado se presentan en la Figura 54, cuyo coeficiente de determinación es de 0.38.

La relación entre los contenidos de arcilla medidos respecto de los estimados a partir del modelo exponencial generado se presentan en la Figura 55.




Figura 54. Datos de arena medidos contra los estimados modelo exponencial ($R^2= 0.38$)




Figura 55. Datos de arcilla medidos contra los estimados modelo exponencial ($R^2= 0.34$)

Modelos polinomiales

El coeficiente de determinación de la relación entre los datos del contenido de arena medido contra el estimado con el modelo polinomial es de 0.39 (ver Figura 56).




Figura 56. Datos de arena medidos contra los estimados modelo polinomial ($R^2= 0.39$)

Mientras que para la relación entre el contenido de arcilla medido contra el estimado con el modelo polinomial es de 0.41 (Figura 57).

De acuerdo con el coeficiente de determinación y la RECM, éste modelo estima mejor que el modelo exponencial.

Tabla 11. Coeficiente de determinación y Raíz del error cuadrático medio por modelo

Fracción textura	Modelo lineal		Modelo exponencial		Modelo polinomial	
	R^2	RECM	R^2	RECM	R^2	RECM
Arena	0.55	9.45	0.38	11.19	0.39	10.97
Arcilla	0.53	10.33	0.34	14.78	0.41	11.61




Figura 57. Datos de arena medidos contra los estimados modelo polinomial ($R^2= 0.41$)

8.1 Aplicación del modelo

Si bien es cierta la existencia de una diversidad amplia de modelos no lineales para el mejor ajuste de los datos, inclusive el uso de redes neuronales; se buscó tener ecuaciones sencillas que pudieran emplearse para operación entre bandas por medio de la **Calculadora raster**, disponible en los software para los Sistemas de Información Geográfica, en nuestro caso QGIS. Lo que de cierta forma limita el uso de redes neuronales o de minería de datos, puesto que aunque dicha modelación ajustaría mejor con la información obtenida, difícilmente podría reproducirse el modelo para estudiarlo en áreas diferentes.

Una vez generado el modelo, se procedió a calcular los contenidos de arena, limo y arcilla por pixel de las zonas voladas, con la ayuda de la herramienta Calculadora raster del software QGIS, tal como se presenta en la Figura 58. Para ello se considera a las bandas como las variables independientes tal como se obtuvo en los modelos previamente generados. Obteniendo una capa para cada fracción del suelo, tal como se muestra en las Figuras 59, 60 y 61.

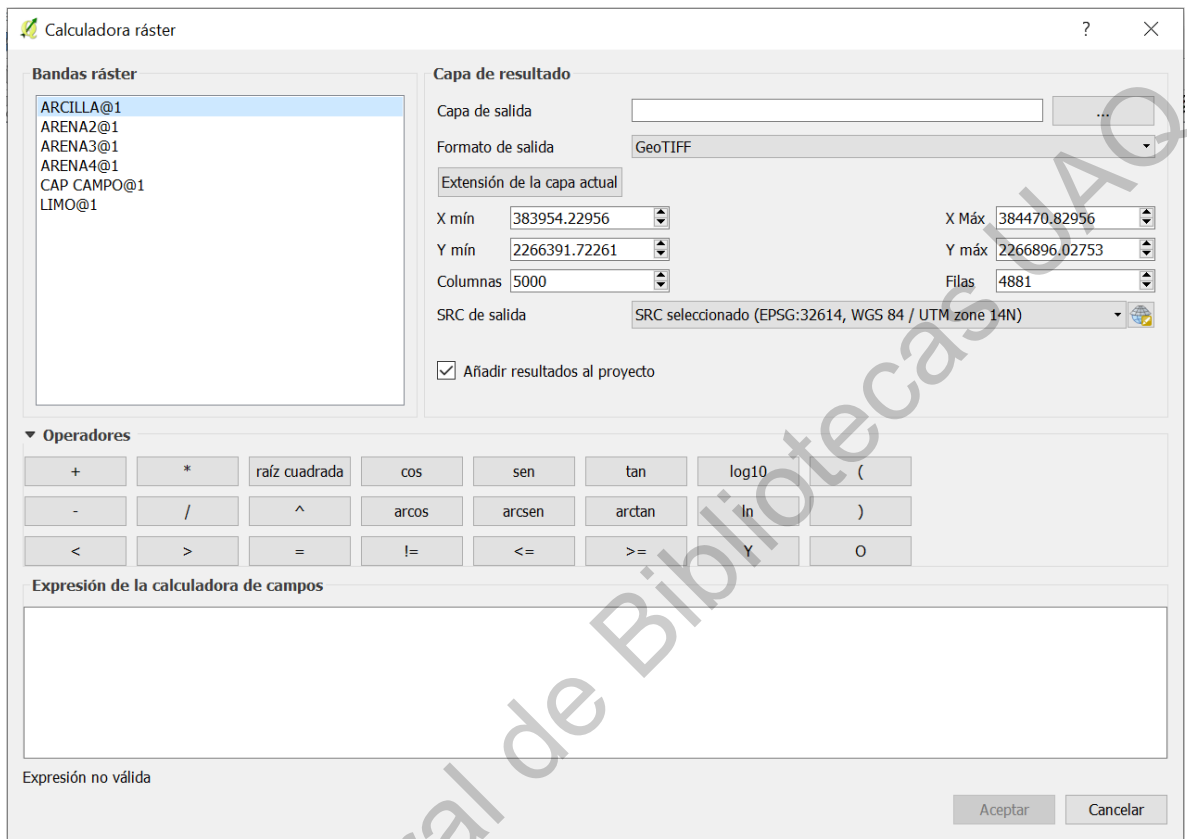


Figura 58. Funciones de la calculadora raster disponible en QGIS.

Para el caso del contenido de limo, dado que el coeficiente de determinación fue muy bajo, y ya que se puede obtener a partir de los modelos de arena y arcilla por diferencia, el cálculo se realizó por esta metodología.





Figura 59. Contenido de arena por pixel obtenido con el modelo ($R^2=0.56$)





Figura 60. Contenido de arcilla por pixel obtenido con el modelo ($R^2=0.54$)





Figura 61. Contenido de limo obtenido por diferencia

9 CONCLUSIONES

- El coeficiente de correlación de Pearson más alto que se obtuvo al correlacionar la media, mediana y moda de los valores de reflectancia de los conjuntos de píxeles (zonas entrenamiento), con los contenidos de arena, limo y arcilla fue con los datos de la moda, debido quizá a que solo 47.5 % de los datos tiene una función de distribución Normal, de acuerdo con el test de Shapiro – Wilks (con un nivel de significancia de 0.05%).
- Los valores de reflectancia más altos para todas las clases texturales estudiadas se observan en la banda del infrarrojo cercano. Los valores más bajos de reflectancia para todas las clases texturales se observa en la banda verde.
- La clase textural con los valores más altos de reflectancia en todas las bandas es la Franco arenosa. Esta clase textural tiene los contenidos de arena más altos, en comparación con el resto de las clases, con un promedio de 58.46%; así como los contenidos de arcilla más bajos. La clase textural con los valores de reflectancia más bajos es la Arcilla; con altos contenidos de arcilla y bajos contenidos de arena, seguida de la Franco arcillosa. Esto coincide totalmente con los resultados encontrados por Barnes y Baker (1999) que encontraron que en la banda del infrarrojo cercano la reflectancia fue mayor en el rango de los suelos con mayores contenidos de arena.
- El Índice de vegetación verde-rojo (GRVI), no muestra grandes variaciones entre las diferentes clases de suelos estudiadas, quizá porque éste tipo de índice que fue creado para analizar vegetación y no aporta información para los estudios relacionados con el suelo, salvo para diferenciar éste de la vegetación.
- El Índice relacionado con el brillo (BI) muestra sus valores más altos en las clases texturales con mayores contenidos de arena, texturas Franca (F) y Franco arenosa (FA), y sus valores más bajos en la clase textural con mayores contenidos de arcilla (Arcilla y Franco arcilloso).

- El mayor coeficiente de correlación de Pearson al analizar los contenidos de arena se encontró con la reflectancia en la banda del verde (0.62) seguido de la correlación con el índice de brillo estudiado por Maya, et al. (2004), con un valor de (0.56). El menor coeficiente de correlación encontrado en el análisis de arena fue con el coeficiente B3/B4 (-0.01).
- El mayor coeficiente de correlación de Pearson para el caso del análisis del contenido de arcilla se encontró también al relacionarlo con la banda verde, pero con valor negativo (-0.63); seguido del (-0.55) al relacionarlo con el mismo índice de brillo del caso del contenido de arena. El menor coeficiente de correlación se obtuvo al relacionarlo con el cociente B4/B3.
- El mayor coeficiente de correlación de Pearson al analizar el contenido de limo fue de -0.27 y se obtuvo en la relación con el cociente BR/B3. Mientras que el menor coeficiente se obtuvo en la relación con el cociente B3/B2 y el índice de carbonato, con un valor de -0.04. La reflectancia de las bandas en estudio no muestran coeficientes de correlación significativos con ésta fracción del suelo.
- Al realizar la modelación para determinar el contenido de arena a partir de las variables independientes se encontró el mejor coeficiente de determinación en la regresión lineal múltiple (0.55), seguido del modelo polinomial (0.39). El modelo exponencial tuvo el menor coeficiente de determinación (0.38).
- El modelo de regresión lineal para determinar el contenido de limo fue muy bajo (0.06).
- El modelo de regresión lineal múltiple para determinar el contenido de arcilla generó un coeficiente de determinación de 0.53, seguido del modelo polinomial (0.41), el menor coeficiente de determinación obtenido al modelar esta fracción del suelo se obtuvo con el modelo exponencial (0.34).

- No se mejoran los coeficientes de correlación de Pearson al analizar la información por conjunto de datos de acuerdo a la clasificación textural de la USDA, salvo cuando se analiza el conjunto de muestras clasificadas como Franco arenoso (mayor contenido de arena y menor contenido de arcilla), donde dicho coeficiente sube a -0.55 con la banda del borde rojo, el mejor coeficiente de correlación de Pearson para contenido de limo encontrado en todo el estudio.
- Los modelos podrían ser mejorados con la introducción de mayor cantidad de datos en la calibración de los modelos, ya que como se mencionó previamente, en la calibración de éste estudio sólo fueron empleados 60 datos.
- En el estudio realizado por Gholizadeh *et al.* (2018) encontraron que los datos de laboratorio y aerotransportados con mayor resolución espectral proporcionaron mejores resultados, por lo que sugiere el uso de mayor cantidad de bandas. Pues autores como Liao *et al.* (2013) encontraron que la banda 7 obtenida de información de satélites es buena predictora para el contenido de arcilla, incluso existe un índice de arcilla que considera ésta banda.

9.1 Recomendaciones

- Es importante analizar la información con mayor cantidad de datos y ver si se ajusta mejor el modelo.
- Dado que no se encontraron coeficientes de correlación y determinación adecuados para la determinación de los contenidos de arena, limo y arcilla, se recomienda también el empleo de otras variables relacionadas con los factores de formación del suelo como pueden ser pendiente, clima y geología; así como de más bandas espectrales.

10 REFERENCIAS

Abuín, J. R. (2007). Regresión lineal múltiple. IdEyGdM-Ld Estadística, Editor, 32.

Aitkenhead, M. J., Cameron, C., Gaskin, G., Choisy, B., Coull, M. & Black, H. I. J. (2018). Digital RGB photography and visible-range spectroscopy for soil composition analysis. *Geoderma*, 313, 265-275.

Aitkenhead, M. J., Coull, M., Towers, W., Hudson, G. & Black, H. I. J. (2013). Prediction of soil characteristics and color using data from the National Soils Inventory of Scotland. *Geoderma*, 200-201, 99-107.

Alasta, A. F. (2011). Using remote sensing data to identify iron deposits in central western Libya. In *International conference on Emerging trends in Computer and Image processing*, Bangkok (pp. 56-61).

Alonso, C., Moreno, V., & Rodríguez, E. (1999). Determinación experimental de la firma espectral de la Vegetación. una sencilla práctica de introducción a la teledetección. In *TELEDETECCIÓN. Avances y Aplicaciones. VIII Congreso Nacional de Teledetección*. Albacete, España (pp. 429-43).

Ariza, N. I. (2018). Elaboración de la Capa de Coberturas de la Tierra del municipio de Cajicá-Cundinamarca, con la finalidad de generar una herramienta de planificación, mediante el uso de Teledetección Espacial, imágenes de satélite y software Erdas Imagine y Qgis.. Recuperado de: <http://hdl.handle.net/10654/20448>.

Arozarena, V, I, & Fernandez, A. (1989). Teledetección y planificación integrada del territorio, MOPU. En *Aplicaciones de las imágenes espaciales a la cartografía de base*, (págs. 215-223). Madrid.

Avalos Piña, K. (2012). Percepción Remota y sus aplicaciones a la evaluación de la calidad del agua. Universidad Nacional Autónoma de México. UNAM Tesis de Maestría, 120.

Bakker, A. (2012). Soil texture mapping on a regional scale with remote sensing data. SI: sn. Thesis, Wageningen Univ., p. 71

Barnes, E. M., & Baker, M. G. (1999). Multispectral data for soil mapping: possibilities and limitations. In ASAE Annual International Meeting (Paper No. 991138). ASAE, St. Joseph, MI.

Bellinaso, H., Demattê, J. A. M., & Romeiro, S. A. (2010). Soil spectral library and its use in soil classification. *Revista Brasileira de Ciência do Solo*, 34(3), 861-870.

Bernabé, E. S. (2016). Procesado de imágenes hiperespectrales. Universidad Politécnica de Madrid. Madrid, Espana.

Bowers, S. A., & Hanks, R. J. (1971). Reflection of radiant energy from soils (Doctoral dissertation, Kansas State University).

Camacho-Sandoval, J. (2008). Asociación entre variables cuantitativas: análisis de correlación. *Acta Médica Costarricense*, 50(2), 94-96.

Camacho-Velasco, A., Vargas-García, C. A., Rojas-Morales, F. A., Castillo-Castelblanco, S. F., & Arguello-Fuentes, H. (2015). Aplicaciones y retos del sensado remoto hiperespectral en la geología colombiana. *Facultad de Ingeniería*, 24(40), 17-29.

Chuvieco, E. (2008). Teledetección Ambiental. La observación de la tierra desde el espacio. Tercera Edición. Ariel Ciencia. Barcelona, España. Pp. 450

Cierniewski, J., & Kuśnierek, K. (2010). Influence of several size properties on soil surface reflectance. *Quaestiones Geographicae*, 29(1), 13-25.

Coleman, T. L., Agbu, P. A., & Montgomery, O. L. (1993). Spectral differentiation of surface soils and soil properties: Is it possible from space platforms?. *Soil Science*, 155(4), 283-293.

Condit, H. R. (1970). The spectral reflectance of American soils. *Photogrammetric Engineering*.

Duarte, E., Emanuelli, P., Milla, F., Orellena, O., & López, S. (2015). Análisis de cambios de la cobertura forestal y uso de la tierra mediante imágenes satelitales de alta resolución espacial: sitio piloto cantón de Puriscal años 2009-2012-2015 República de Costa Rica. San José, Costa Rica: Deutsche Gesellschaft für Internationale Zusammenarbeit (GIZ) GmbH.

Escadafal, R. (1989). Remote sensing of arid soil surface color with Landsat thematic mapper. *Advances in space research*, 9(1), 159-163.

Fernández-Manso, Ó. (2015). Spectral mixture analysis and object-based image analysis for forestry applications. University of León. Upper school of agricultural engineering. Tesis de doctorado.

García-Cervigón, D., José, J., Rodríguez, G., & Del Pilar Gutierrez Puebla, M. (2014). Estudio de Índices de vegetación a partir de imágenes aéreas tomadas desde UAS/RPAS y aplicaciones de estos a la agricultura de precisión. Recuperado a partir de http://eprints.ucm.es/31423/1/TFM_Juan_Diaz_Cervignon.pdf.

Gholizadeh, A., Žižala, D., Saberioon, M., & Borůvka, L. (2018). Soil organic carbon and texture retrieving and mapping using proximal, airborne and Sentinel-2 spectral imaging. *Remote sensing of environment*, 218, 89-103.

Gilabert, M. A., González-Piqueras, J., & García-Haro, J. (1997). Acerca de los índices de vegetación. *Revista de teledetección*, 8(1), 1-10.

Giron-Rios, Y., Oleschko-Lutkova, K., Parrot, J., Hernández-Alcantara, J. M., Camarillo, G. E. & Velázquez-García, J. J. (2009). Análisis fractal de la reflectancia de los suelos salinos. *Agrociencia*, 43(4), 403-416.

Gisbert, J., Ibáñez, S. y Moreno, H.. (2017). La textura de un suelo. 24 de febrero de 2019, de Universidad Politécnica de Valencia Sitio web: <https://riunet.upv.es/bitstream/handle/10251/7775/Textura.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 (Doctoral dissertation, Facultad de Ciencias Astronómicas y Geofísicas).

González, A., Amarillo, G., Amarillo, M., & Sarmiento, F. (2016). Drones aplicados a la agricultura de precisión. *Publicaciones e Investigación*, 10, 23-37.

González-Naranjo, V., Leal, M., Lillo, J., De Bustamante, I., & Palacios, M. P. (2012). Guía de caracterización edáfica para actividades de regeneración de aguas residuales en usos ambientales.

González Rodríguez, M. (2007). Estación de seguimiento SKY-EYE para UAVs: mecanismos de georeferenciación y ortorectificación de imágenes aéreas. (Trabajo final de carrera. Escola Politècnica Superior de Castelldefels. Universitat Politècnica de Catalunya).

Gonzalez - Sosa, E., Braud, I., Dehotin, J., Lassabatère, L., Angulo - Jaramillo, R., Lagouy, M., Branger, F., Jacqueminet, C. & Michel, K. (2010). Impact of land use on the

hydraulic properties of the topsoil in a small French catchment. *Hydrological processes*, 24(17), 2382-2399.

Granados, R. M. (2016). *Modelos de regresión lineal múltiple*. Granada, España: Departamento de Economía Aplicada, Universidad de Granada. Recuperado el, 14.

Guillén, C., Murugan, V., & Dávila, M. (2015). Aplicación de teledetección y SIG para el levantamiento cartográfico de los suelos de la cuenca Solani, India. *Revista Geográfica Venezolana*, 56(2), 185-204.

Hernández, H. J., & Montaner, D. (2009). Patrones de respuesta espectral. *Tecnologías Geoespaciales: Experiencias Aplicadas al Estudio y Gestión del Territorio*. Carlos Mena (Ed.) ISBN, 978-956.

Juárequi, C. T. N., Caicedo, J. P. R., & Morales, J. C. A. C. (2016). Análisis de métodos de fusión de imágenes Landsat 8 sobre coberturas y uso del suelo en el municipio de Bahía de Banderas, Nayarit. *EDUCATECONCIENCIA*, 10(11).

Jiménez Merino, W. A. (2015). *Cartografía de suelos con cangahuas mediante teledetección en los cantones de Cayambe, Pedro Moncayo y Pimampiro, sierra norte de Ecuador* (Bachelor's thesis, Quito: UCE).

Kalambukattu, J. G., Kumar, S., & Raj, R. A. (2018). Digital soil mapping in a Himalayan watershed using remote sensing and terrain parameters employing artificial neural network model. *Environmental earth sciences*, 77(5), 203.

Karszenbaum, H., & Barraza, V. (2014). *Introducción a la teledetección cuantitativa*. <https://docplayer.es/46480497-Introduccion-a-la-teledeteccion-cuantitativa.html>, fecha de consulta: 20 de mayo de 2019.

Kuang, B., Tekin, Y. & Mouazen, A. M. (2015). Comparison between artificial neural network and partial least squares for on-line visible and near infrared spectroscopy measurement of soil organic carbón, pH and clay content. *Soil & Tillage Research*, 146, 243-252.

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.

Lillesand, T., Kiefer, R. W., & Chipman, J. (2015). *Remote sensing and image interpretation*. John Wiley & Sons.

López, D. y Torres, A. (2018). Análisis de datos tipo raster. 11 de abril de 2019, de CONACYT. Sitio web:

[https://centrogeo.repositorioinstitucional.mx/jspui/bitstream/1012/182/1/12-An%
a1lisis%20de%20Datos%20Tipo%20Raster%20-%20Diplomado%20en%20An%
a1lisis %20de%20Informaci%3bn%20Geoespacial.pdf](https://centrogeo.repositorioinstitucional.mx/jspui/bitstream/1012/182/1/12-An%c3%a1lisis%20de%20Datos%20Tipo%20Raster%20-%20Diplomado%20en%20An%c3%a1lisis%20de%20Informaci%3bn%20Geoespacial.pdf)

Lora López, J. C. (2016). Comparativa de sensores espaciales de diferente resolución espectral en la exploración minera (Master's thesis, Universitat Politècnica de Catalunya).

Mahmoudabadi, E., Karimi, A., Haghnia, G. H., & Sepehr, A. (2017). Digital soil mapping using remote sensing indices, terrain attributes, and vegetation features in the rangelands of northeastern Iran. *Environmental monitoring and assessment*, 189(10), 500.

Martínez-Vega, J., Martín, M. P., Díaz Montejó, J. M., López Vizoso, J. M., & Muñoz Recio, F. J. (2010). *Guía didáctica de teledetección y medio ambiente*.

Maya, Y., Lacaze, B., Monteforte, M., & Passini, M. F. (2004). Análisis de imágenes SPOT: erosión en la región montañosa del sur de la Península de Baja California, México. *Terra Latinoamericana*, 22(1), 23-34.

Medina-Peralta, S., Vargas-Villamil, L., Navarro-Alberto, J., Canul-Pech, C., & Peraza-Romero, S. (2010). Comparación de medidas de desviación para validar modelos sin sesgo, sesgo constante o proporcional. *Universidad y ciencia*, 26(3), 255-263.

Mejía-Melgarejo, Y. H., Villarreal-Dulcey, O. P., & Arguello-Fuentes, H. (2016). Adjustable spatial resolution of compressive spectral images sensed by multispectral filter array-based sensors. *Revista Facultad de Ingeniería Universidad de Antioquia*, (78), 89-98.

Montesinos, S. (2015). Los drones y sus aplicaciones a la ingeniería civil. Dirección General de Industria, Energía y Minas de la Comunidad de Madrid. España. 101-117. <http://www.madrid.org/bvirtual/BVCM015384.pdf>. Fecha de consulta 19 de abril de 2019.

Mulder, V. L., De Bruin, S., Schaepman, M. E., & Mayr, T. R. (2011). The use of remote sensing in soil and terrain mapping—A review. *Geoderma*, 162(1-2), 1-19.

Müller, B., Bernhardt, M., Jackisch, C., & Schulz, K. (2016). Estimating spatially distributed soil texture using time series of thermal remote sensing—a case study in central Europe. *Hydrology and Earth System Sciences*, (9), 3765-3775.

Navarro, A. P. (2011). Introducción a los sistemas de información geográfica y geotelemática (Vol. 173). Editorial UOC.

Olivares Lorenzo, L. (2015). Estudio de la erosión del suelo mediante imágenes de satélite. Aplicación al área de Orgaz-Los Yébenes (Toledo). Universidad Politécnica de Madrid. Escuela Técnica Superior de Ingenieros en Topografía, Geodesia y Cartografía.

Olmo, M. C. (2003). Geoestadística y modelos matemáticos en hidrogeología (Vol. 1). Publicacions de la Universitat Jaume I.

Padarian, J., Minasny, B., & McBratney, A. B. (2018). Using deep learning to predict soil properties from regional spectral data. *Geoderma Regional*, 16, e00198.

Pei, X., Sudduth, K. A., Veum, K. S., & Li, M. (2019). Improving In-Situ Estimation of Soil Profile Properties Using a Multi-Sensor Probe. *Sensors*, 19(5), 1011.

Pérez Gutiérrez, C., & Muñoz Nieto, A. L. (2002). *Teledetección: nociones y aplicaciones*. España: Universidad de Salamanca.

Pouget, M., Madeira, J., Le Floch, E., & Kamal, S. (1990). Caracteristiques spectrales des surfaces sableuses de la region cotiere nord-ouest de l'Egypte: application aux donnees satellitaires SPOT.

Roberts, T. L. & Henry, J. L., El muestreo de suelos: los beneficios de un buen trabajo. Fecha de consulta: julio de 2019. [http://www.ipni.net/publication/ia-lahp.nsf/0/97F3E059E43811A0852579A300790776/\\$FILE/EI%20muestreo%20de%20suelos.pdf](http://www.ipni.net/publication/ia-lahp.nsf/0/97F3E059E43811A0852579A300790776/$FILE/EI%20muestreo%20de%20suelos.pdf)

Rodríguez-Jaume, M. J., & Mora Catalá, R. (2001). *Análisis de regresión múltiple*. Técnicas de Investigación Social II.

Rodríguez Villamizar, J. (2015). *Sistemas multispectrales e hiperspectrales para la observación del territorio. Análisis y aplicación a la prospección de hidrocarburos*. Madrid: Trabajo fin de grado en geomática y topografía. Universidad Politécnica de Madrid.

Rossel, R. V., & Behrens, T. (2010). Using data mining to model and interpret soil diffuse reflectance spectra. *Geoderma*, 158(1-2), 46-54.

Rossel, R. V., Walvoort, D. J. J., McBratney, A. B., Janik, L. J., & Skjemstad, J. O. (2006). Visible, near infrared, mid infrared or combined diffuse reflectance spectroscopy for simultaneous assessment of various soil properties. *Geoderma*, 131(1-2), 59-75.

Sampieri, R. H., Collado, C. F., Lucio, P. B., Valencia, S. M., & Torres, C. P. M. (1998). *Metodología de la investigación* (Vol. 6). México, DF: Mcgraw-hill.

Sastre, L. F. S., Marcos-Robles, J. L., Llorente, E. H., Navarro, S. H., & Prieto, P. C. (2016). Aplicación de tecnologías de teledetección al estudio de biomasa forestal. *RISTI-Revista Ibérica de Sistemas e Tecnologias de Informação*, (19), 61-76.

Schaap, M. G., & Leij, F. J. (1998). Using neural networks to predict soil water retention and soil hydraulic conductivity. *Soil and Tillage Research*, 47(1-2), 37-42.

Schaap, M. G., Leij, F. J., & Van Genuchten, M. T. (2001). Rosetta: A computer program for estimating soil hydraulic parameters with hierarchical pedotransfer functions. *Journal of hydrology*, 251(3-4), 163-176.

Shabou, M., Mougenot, B., Chabaane, Z., Walter, C., Boulet, G., Aissa, N., & Zribi, M. (2015). Soil clay content mapping using a time series of Landsat TM data in semi-arid lands. *Remote sensing*, 7(5), 6059-6078.

Sharma, A. K. (2005). *Text book of correlations and regression*. Discovery Publishing House.

Thomasson, J. A., Sui, R., Cox, M. S., & Al-Rajehy, A. (2001). Soil reflectance sensing for determining soil properties in precision agriculture. *Transactions of the ASAE*, 44(6), 1445.

Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote sensing of Environment*, 8(2), 127-150.

Violini, S. N. (2016). Uso de suelo agrícola en la zona central de Córdoba: análisis de datos espaciales multisensor para su estudio y gestión (Master's thesis).

Waiser, T. H., Morgan, C. L., Brown, D. J., & Hallmark, C. T. (2007). In situ characterization of soil clay content with visible near-infrared diffuse reflectance spectroscopy. *Soil Science Society of America Journal*, 71(2), 389-396.

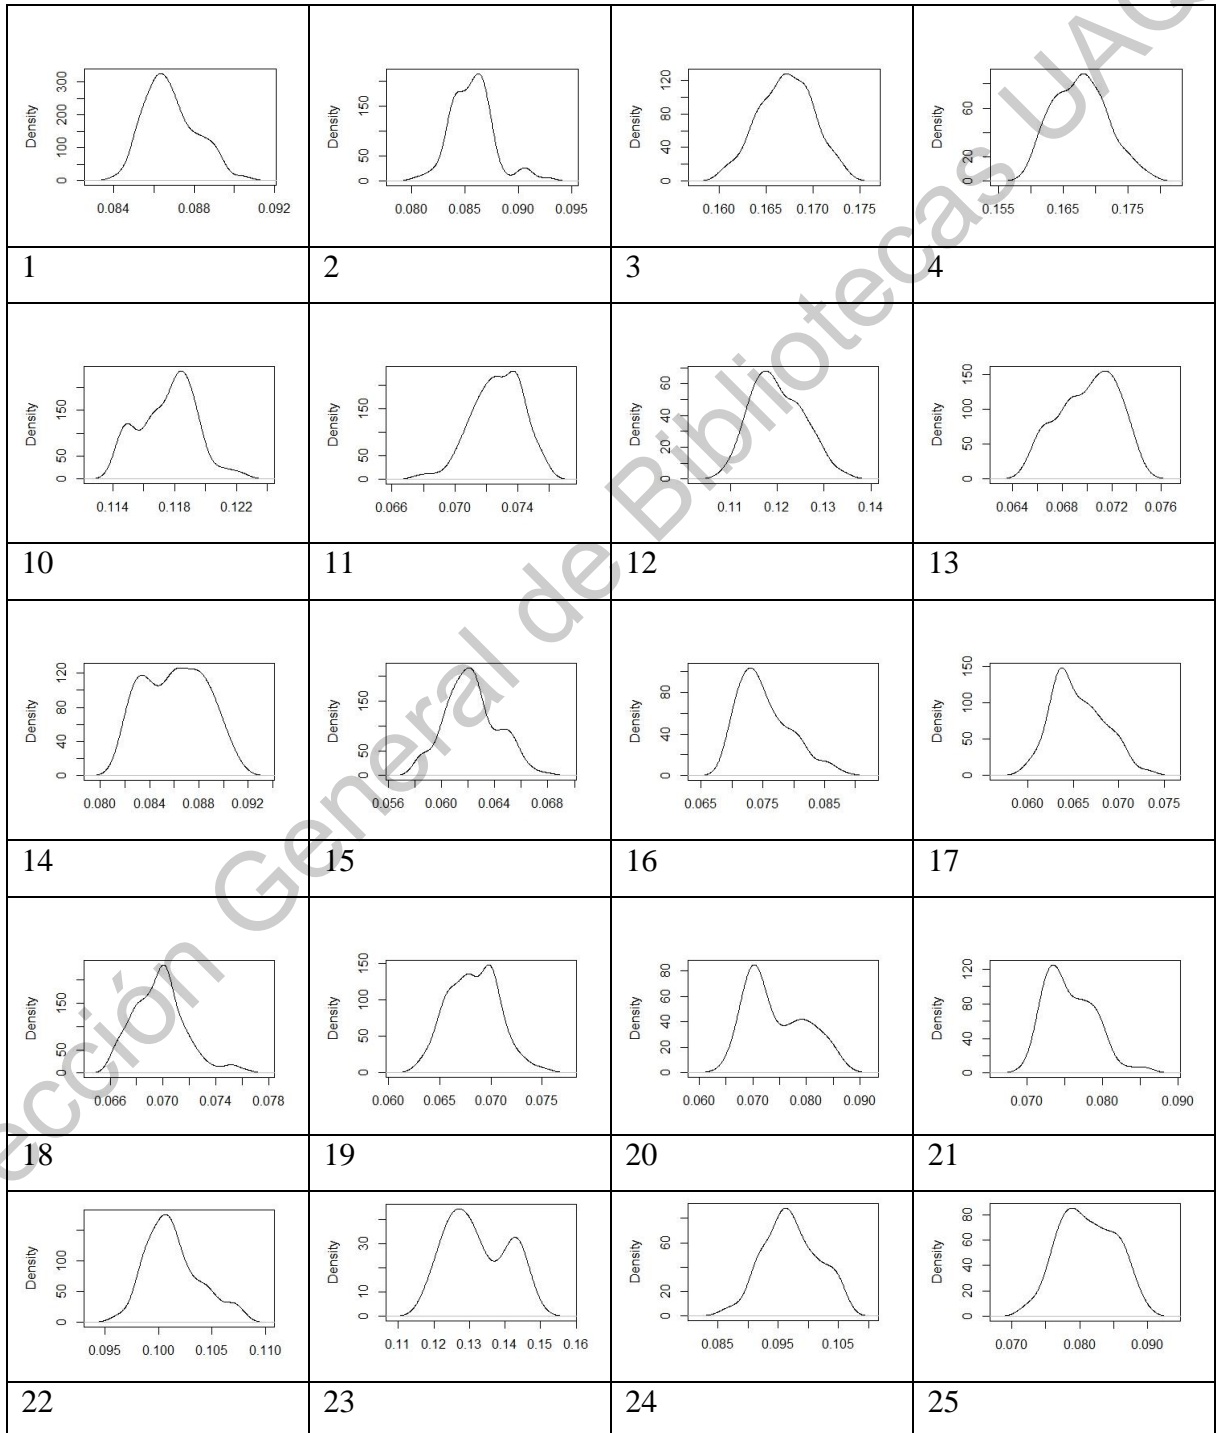
Yan, X., & Su, X. (2009). *Linear regression analysis: theory and computing*. World Scientific.

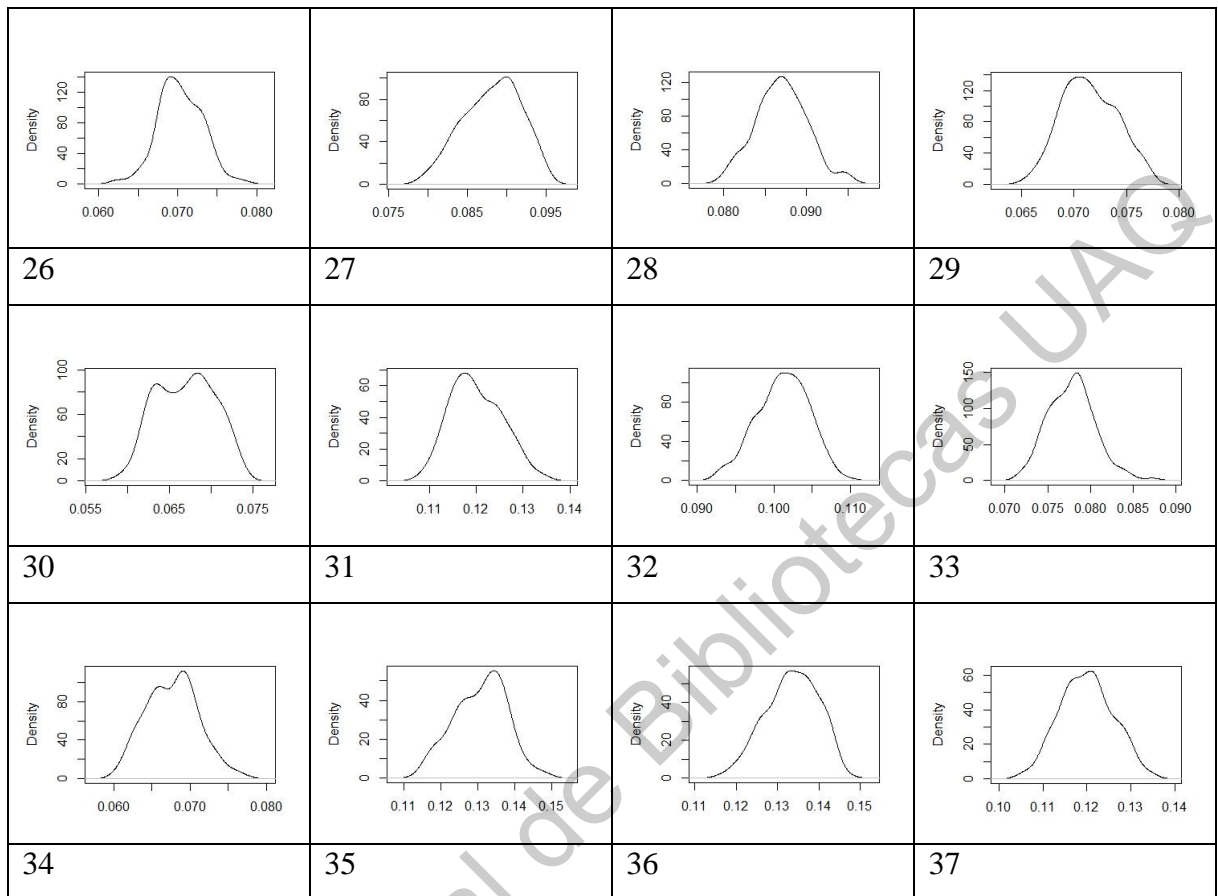
Zeraatpisheh, M., Ayoubi, S., Jafari, A., Tajik, S. & Finke, P. (2019). Digital mapping of soil properties using multiple machine learning in a semi-arid region, central Iran. *Geoderma* 338, 445-452.

Zhai, Y., Thomasson, J. A., Boggess III, J. E., & Sui, R. (2006). Soil texture classification with artificial neural networks operating on remote sensing data. *Computers and Electronics in Agriculture*, 54(2), 53-68.

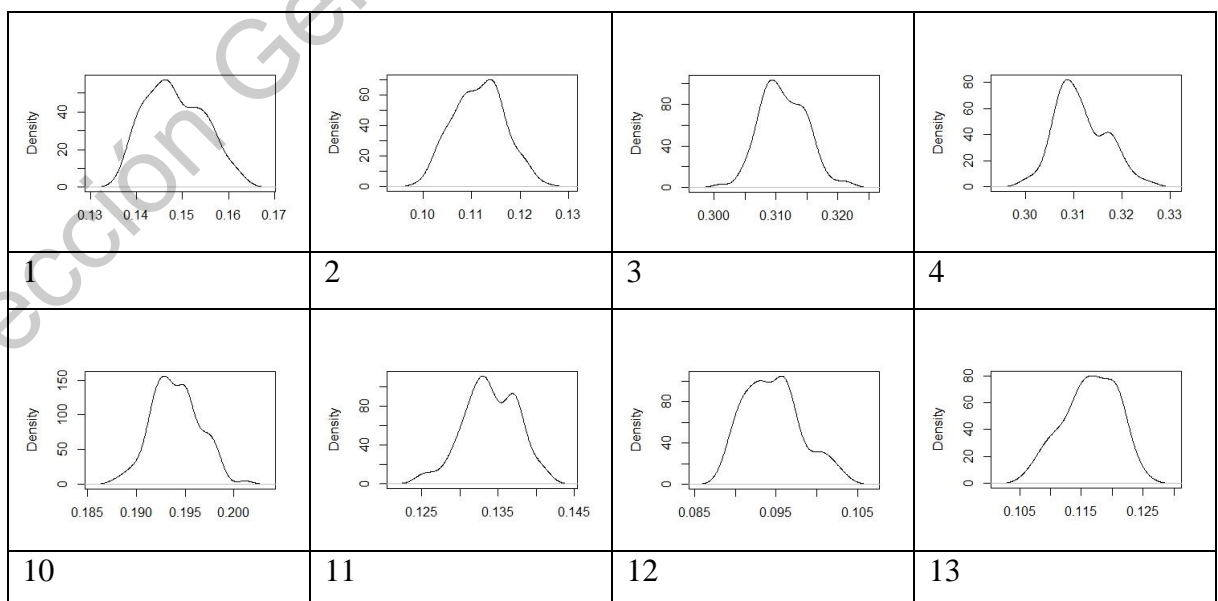
ANEXO 1. Funciones de densidad de los valores de reflectancia de los conjuntos de pixeles que conforman las zonas de entrenamiento (Banda verde)

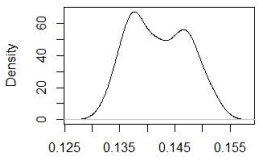
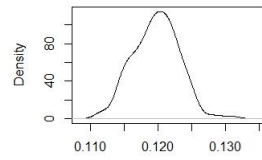
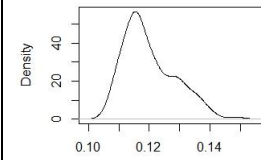
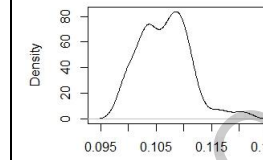
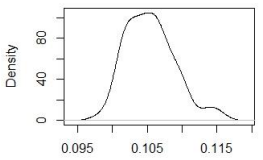
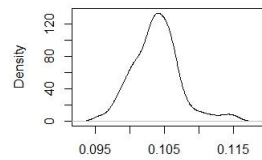
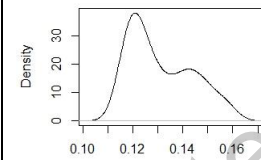
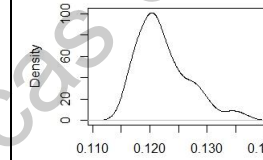
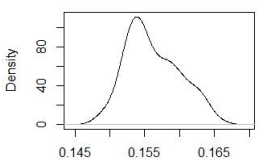
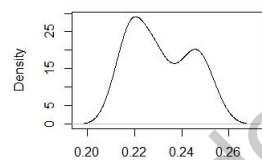
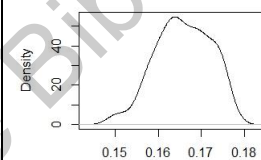
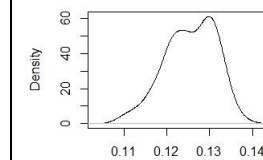
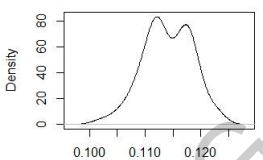
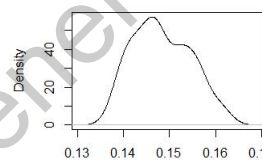
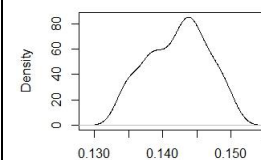
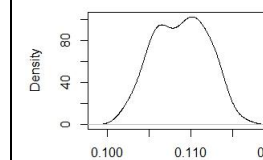
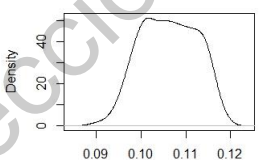
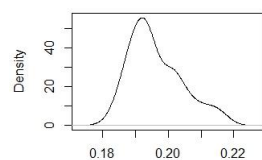
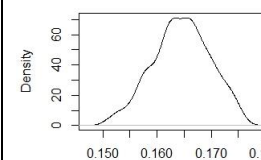
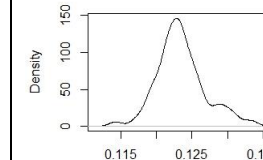
a) Funciones de densidad de la reflectancia en la banda del verde

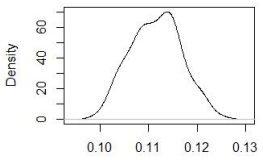
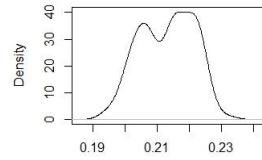
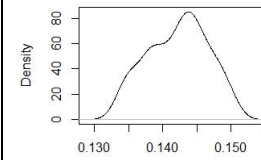
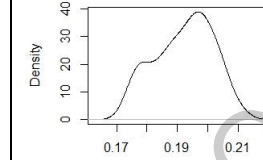




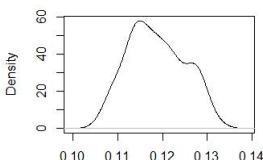
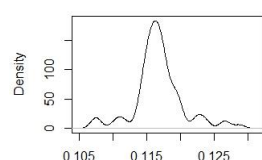
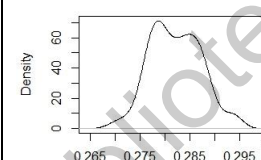
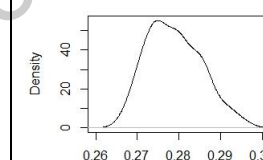
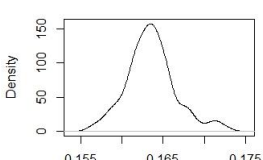
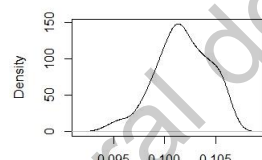
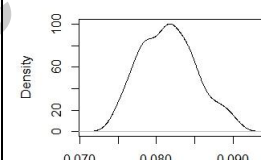
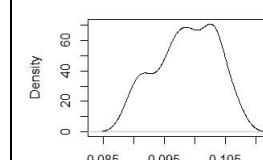
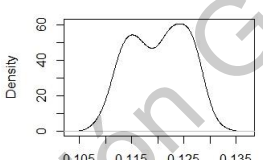
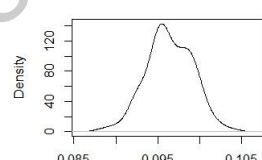
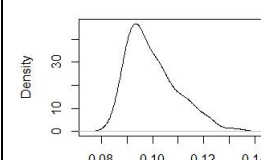
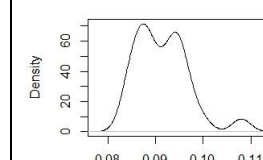
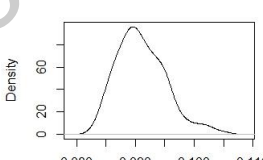
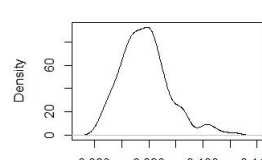
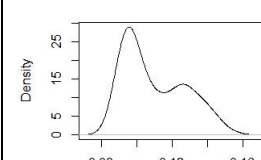
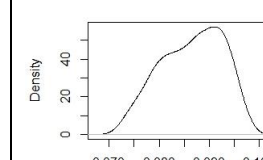
b) Funciones de densidad de la reflectancia en la banda del infrarrojo cercano

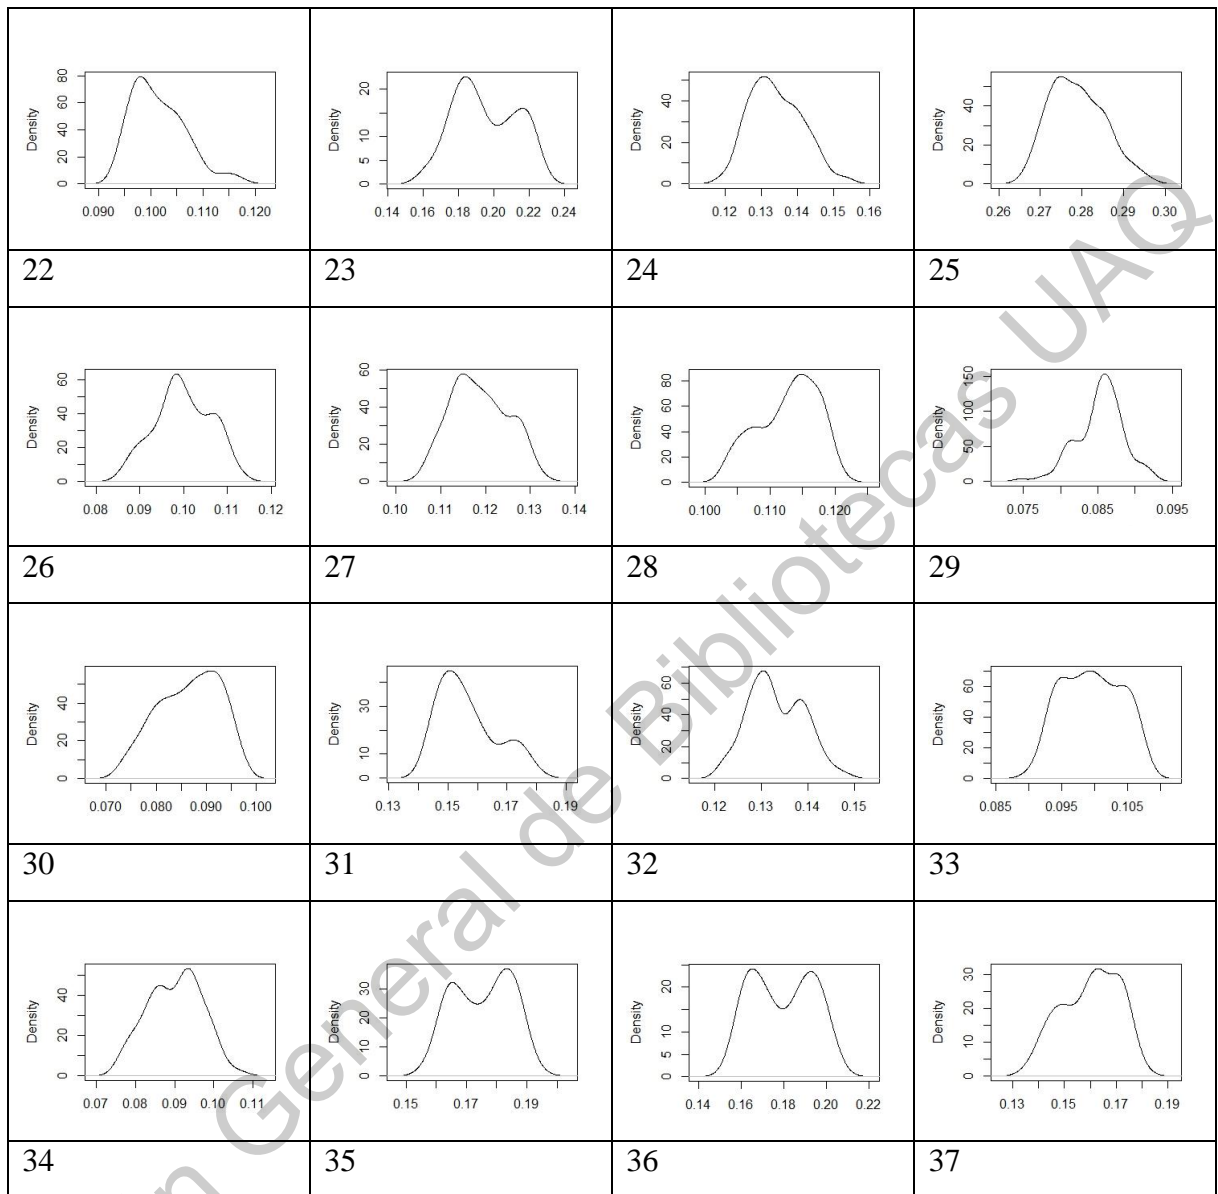


			
14	15	16	17
			
18	19	20	21
			
22	23	24	25
			
26	27	28	29
			
30	31	32	33


			
34	35	36	37

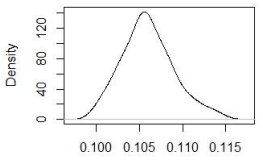
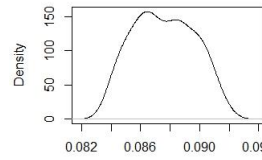
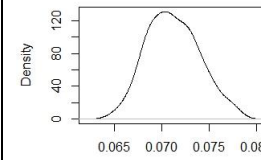
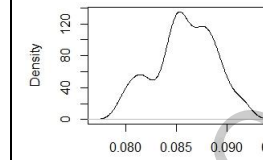
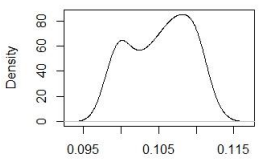
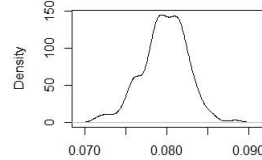
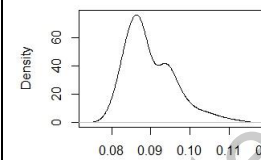
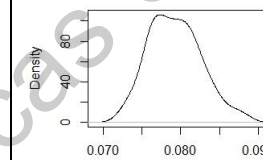
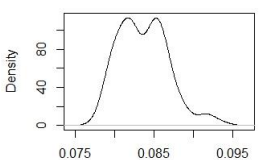
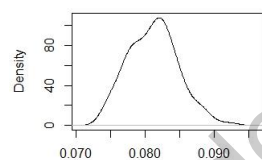
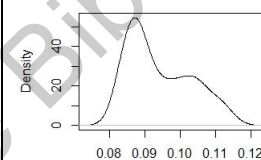
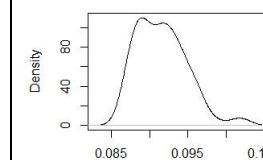
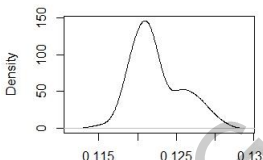
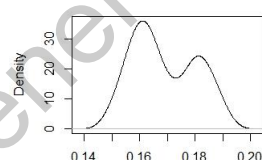
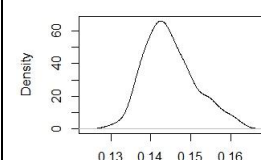
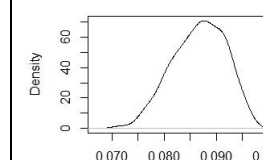
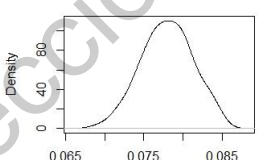
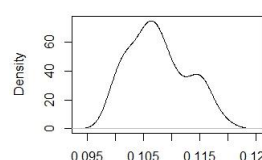
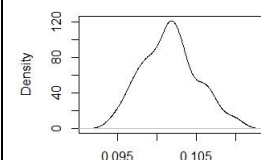
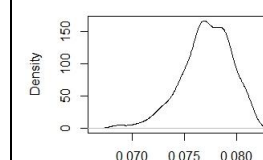
c) Funciones de densidad de la reflectancia en la banda del borde rojo

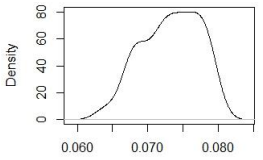
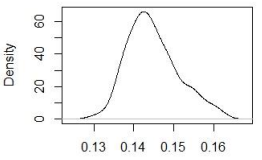
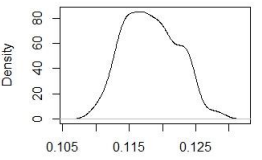
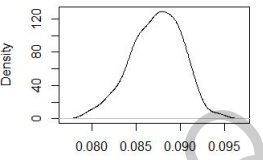
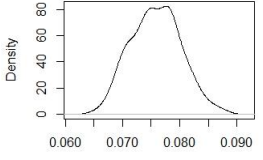
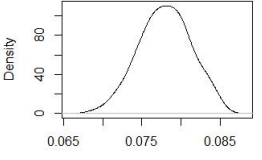
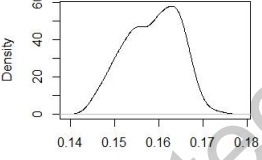
			
1	2	3	4
			
10	11	12	13
			
14	15	16	17
			
18	19	20	21



d) Funciones de densidad de la reflectancia en la banda del verde



			
10	11	12	13
			
14	15	16	17
			
18	19	20	21
			
22	23	24	25
			
26	27	28	29

 <p>Density plot for item 30. The x-axis ranges from 0.060 to 0.080 with ticks at 0.060, 0.070, and 0.080. The y-axis is labeled 'Density' and ranges from 0 to 80 with ticks at 0, 20, 40, 60, and 80. The curve is unimodal and slightly right-skewed, peaking at approximately 80 around x=0.075.</p>	 <p>Density plot for item 31. The x-axis ranges from 0.13 to 0.16 with ticks at 0.13, 0.14, 0.15, and 0.16. The y-axis is labeled 'Density' and ranges from 0 to 60 with ticks at 0, 20, 40, and 60. The curve is unimodal and slightly right-skewed, peaking at approximately 60 around x=0.145.</p>	 <p>Density plot for item 32. The x-axis ranges from 0.105 to 0.125 with ticks at 0.105, 0.115, and 0.125. The y-axis is labeled 'Density' and ranges from 0 to 80 with ticks at 0, 20, 40, 60, and 80. The curve is unimodal and slightly right-skewed, peaking at approximately 80 around x=0.115.</p>	 <p>Density plot for item 33. The x-axis ranges from 0.080 to 0.095 with ticks at 0.080, 0.085, 0.090, and 0.095. The y-axis is labeled 'Density' and ranges from 0 to 120 with ticks at 0, 40, 80, and 120. The curve is unimodal and slightly right-skewed, peaking at approximately 120 around x=0.088.</p>
30	31	32	33
 <p>Density plot for item 34. The x-axis ranges from 0.060 to 0.090 with ticks at 0.060, 0.070, 0.080, and 0.090. The y-axis is labeled 'Density' and ranges from 0 to 80 with ticks at 0, 20, 40, 60, and 80. The curve is unimodal and slightly right-skewed, peaking at approximately 80 around x=0.078.</p>	 <p>Density plot for item 35. The x-axis ranges from 0.065 to 0.085 with ticks at 0.065, 0.075, and 0.085. The y-axis is labeled 'Density' and ranges from 0 to 80 with ticks at 0, 40, and 80. The curve is unimodal and slightly right-skewed, peaking at approximately 80 around x=0.078.</p>	 <p>Density plot for item 36. The x-axis ranges from 0.14 to 0.18 with ticks at 0.14, 0.15, 0.16, 0.17, and 0.18. The y-axis is labeled 'Density' and ranges from 0 to 60 with ticks at 0, 20, 40, and 60. The curve is unimodal and slightly right-skewed, peaking at approximately 60 around x=0.165.</p>	
34	35	36	37

ANEXO 2. Media, mediana y moda de algunos de los conjuntos de pixeles considerados en éste estudio.

Puntos de muestreo	Verde			Infrarojo cercano			Borde rojo			Rojo		
	Media	Mediana	Moda	Media	Mediana	Moda	Media	Mediana	Moda	Media	Mediana	Moda
1	0.08679	0.08665	0.08634	0.14792	0.14797	0.14807	0.12475	0.12502	0.12506	0.10887	0.10885	0.10914
2	0.08547	0.08555	0.08627	0.14083	0.14093	0.14070	0.11643	0.11649	0.11628	0.10588	0.10563	0.10558
4	0.16809	0.16799	0.16808	0.31172	0.31123	0.30868	0.27951	0.27928	0.27489	0.23448	0.23406	0.23106
10	0.11756	0.11782	0.11842	0.19402	0.19352	0.19287	0.16344	0.16334	0.16347	0.14821	0.14781	0.14786
11	0.07264	0.07269	0.07369	0.13379	0.13355	0.13300	0.10144	0.10156	0.10131	0.08746	0.08735	0.08646
13	0.07018	0.07050	0.07147	0.11652	0.11710	0.11675	0.09882	0.09910	0.10257	0.08590	0.08602	0.08533
14	0.08634	0.08631	0.08652	0.14226	0.14185	0.13766	0.12048	0.12106	0.12415	0.10548	0.10603	0.10815
15	0.06210	0.06196	0.06209	0.11967	0.11985	0.12033	0.09616	0.09595	0.09551	0.07970	0.07968	0.07935
17	0.06567	0.06528	0.06372	0.10672	0.10721	0.10861	0.09149	0.09143	0.08735	0.07950	0.07958	0.07730
18	0.06984	0.06974	0.07006	0.10550	0.10507	0.10528	0.09112	0.09023	0.08959	0.08371	0.08304	0.08172
19	0.06837	0.06813	0.06979	0.10396	0.10353	0.10409	0.08974	0.08941	0.08962	0.08132	0.08119	0.08207
20	0.07492	0.07377	0.07025	0.13238	0.12966	0.12085	0.11187	0.10735	0.09568	0.09496	0.09315	0.08723
22	0.10122	0.10066	0.10066	0.15624	0.15555	0.15387	0.13170	0.13131	0.13096	0.12238	0.12168	0.12097
23	0.13319	0.13157	0.12710	0.23264	0.23002	0.22030	0.19703	0.19418	0.18399	0.16997	0.16916	0.16112
24	0.09700	0.09653	0.09623	0.16567	0.16506	0.16387	0.13385	0.13280	0.13086	0.11815	0.11761	0.11636
25	0.08109	0.08076	0.07888	0.12564	0.12622	0.12979	0.09991	0.09952	0.09836	0.08667	0.08722	0.08761
26	0.07013	0.07002	0.06912	0.11342	0.11322	0.11214	0.08930	0.08940	0.08935	0.07768	0.07782	0.07821
27	0.08775	0.08795	0.08992	0.14787	0.14704	0.14621	0.11804	0.11755	0.11495	0.10725	0.10690	0.10643
28	0.08681	0.08690	0.08697	0.14198	0.14217	0.14376	0.11267	0.11364	0.11485	0.10131	0.10132	0.10182
29	0.07142	0.07131	0.07054	0.10862	0.10883	0.11018	0.08523	0.08569	0.08590	0.07688	0.07699	0.07692
30	0.06676	0.06716	0.06836	0.10569	0.10577	0.10174	0.08583	0.08637	0.09104	0.07317	0.07329	0.07615
31	0.11995	0.11960	0.11752	0.19603	0.19395	0.19198	0.15641	0.15381	0.15059	0.14478	0.14441	0.14259
34	0.06771	0.06786	0.06906	0.11167	0.11210	0.11383	0.09016	0.09084	0.09333	0.07592	0.07587	0.07763
35	0.13071	0.13147	0.13433	0.21282	0.21426	0.21706	0.17509	0.17535	0.18334	0.15962	0.15991	0.16366
36	0.13311	0.13318	0.13330	0.21684	0.21453	0.20975	0.17858	0.17662	0.16514	0.15814	0.15859	0.16296
37	0.11998	0.11986	0.12085	0.19190	0.19277	0.19695	0.15955	0.16112	0.16299	0.14190	0.14193	0.14442
38	0.08833	0.08887	0.08956	0.14025	0.14024	0.13802	0.11210	0.11280	0.11380	0.09952	0.09990	0.10291

Dirección General de