



UNIVERSIDAD AUTÓNOMA CHAPINGO

UNIDAD REGIONAL UNIVERSITARIA DE ZONAS ÁRIDAS

Maestría en Ciencias en Recursos Naturales y Medio Ambiente
En Zonas Áridas

CALIBRACIÓN DEL CONTENIDO DE HUMEDAD DEL SUELO UTILIZANDO IMÁGENES DE SATELITE LANDSAT-8 Y SENTINEL-2 MEDIANTE GOOGLE EARTH ENGINE

TESIS

Como requisito parcial para obtener el grado de:

**MAESTRO EN CIENCIAS EN RECURSOS NATURALES Y MEDIO
AMBIENTE EN ZONAS ÁRIDAS**

PRESENTA

JOSÉ RODOLFO QUINTANA MOLINA



APROBADA



Bajo la supervisión del Dr. Ignacio Sánchez Cohen

Bermejillo, Dgo. México, abril 2023



inifap

Instituto Nacional de Investigaciones
Forestales, Agrícolas y Pecuarias


Tesis realizada por **José Rodolfo Quintana Molina** bajo la supervisión del Comité Asesor asignado, aprobada por el mismo y aceptada como requisito parcial para obtener el grado de:

Maestro en Ciencias en Recursos Naturales y Medio Ambiente en Zonas Áridas.




DIRECTOR: _____

Dr. Ignacio Sánchez Cohen



CODIRECTOR: _____

M.C. Sergio Iván Jiménez Jiménez



ASESOR: _____

M.C. Mariana de Jesús Marcial Pablo



ASESOR: _____

Dr. Ricardo Trejo Calzada

CONTENIDO

LISTA DE CUADROS	vi
LISTA DE FIGURAS	vii
ABREVIATURAS USADAS.....	ix
DEDICATORIA	x
AGRADECIMIENTOS	xi
DATOS BIOGRÁFICOS.....	xii
RESUMEN GENERAL	xiii
ABSTRACT	xiii
CAPÍTULO I	xiv
1. INTRODUCCIÓN GENERAL	15
2. OBJETIVOS.....	17
2.1. Objetivo General.....	17
2.2. Objetivos Específicos	17
3. HIPOTESIS.....	17
CAPITULO II	18
4. REVISION DE LITERATURA.....	18
4.1. Percepción Remota	18
4.1.1. Sensores Remotos	19
4.2. Programa Landsat	22
4.3. Programa Copernicus Sentinel 2	26
4.4. Índices de vegetación para la estimación del contenido de humedad del suelo mediante sensores remotos.....	28
4.4.1. Índice de Vegetación de Diferencia Normalizada (NDVI)	28
4.4.2. Índice de Vegetación Ajustado al Suelo (SAVI) e Índice de Vegetación Modifica Ajustado al Suelo (MSAVI2).....	29
4.5. Contenido de humedad en el suelo	30
4.6. Modelo Trapezoidal Térmico-Óptico (TOTRAM) y Modelo Trapezoidal Óptico (OPTRAM) para la estimación del contenido de humedad del suelo mediante sensores remotos	32

4.7. Google Earth Engine.....	33
4.8. Ventajas de los estudios utilizando Google Earth Engine sobre el método tradicional	34
5. LITERATURA CITADA.....	37
CAPÍTULO III. ARTICULO CIENTÍFICO.....	45
RESUMEN	45
ABSTRACT	45
1. INTRODUCCIÓN	47
2. OBJETIVOS.....	48
2.1. Objetivo General.....	48
2.2. Objetivos Específicos	48
3. HIPÓTESIS.....	48
4. MATERIALES Y MÉTODOS.....	49
4.1. Área de Estudio	49
4.2. Método Gravimétrico para medición del contenido de humedad volumétrico del suelo <i>in situ</i>	52
4.3. Método Time Domain Reflectometry (TDR) para medición del contenido de humedad volumétrico del suelo <i>in situ</i>	54
4.4. Análisis de imágenes satelitales	55
4.4.1. Índice de Vegetación de Diferencia Normalizada (NDVI)	55
4.4.2. Índice de Vegetación Ajustado al Suelo (SAVI)	55
4.4.3. Índice de Vegetación Modificado Ajustado al Suelo (MSAVI2).....	56
4.4.4. Temperatura de la Superficie Terrestre (LST) mediante el algoritmo Mono-canal utilizando imágenes de satélite.....	56
4.4.4.1. Método para la Corrección de la Emisividad	56
4.4.4.2. Estimación la Temperatura de la Superficie Terrestre (LST).....	56
4.4.5. Algoritmo de la NASA para la Recuperación de la Temperatura de la Superficie Terrestre (LST _{NASA})	57
4.5. Modelos para la estimación de la humedad del suelo con imágenes satelitales	58

4.5.1. Modelo Trapezoidal Térmico-Óptico (TOTRAM)	58
4.5.2. Modelo Trapezoidal Óptico (OPTRAM)	59
4.6. Análisis Estadístico	61
4.6.1. Error Cuadrático Medio de la Raíz (RMSE)	61
4.6.2. Coeficiente de Correlación de Pearson (R) y R^2	61
5. RESULTADOS Y DISCUSIÓN	62
5.1. Distribución de la relación de los píxeles del modelo OPTRAM utilizando imágenes de satélite Landsat-8 y Sentinel-2	62
5.2. Distribución de la relación de los píxeles del modelo TOTRAM utilizando imágenes de satélite Landsat-8	63
5.3. Calibraciones de los datos medidos de humedad in situ (Θ) comparados con estimados de contenido normalizado de humedad (W) a diferentes profundidades	65
5.3.1. Resultados modelo OPTRAM-NDVI	65
5.3.2. Resultados modelo OPTRAM-SAVI	67
5.3.3. Resultados modelo OPTRAM-MSAVI2	69
5.3.4. Resultados modelo TOTRAM-NDVI	70
5.3.5. Resultados modelo TOTRAM-SAVI	72
5.3.6. Resultados modelo TOTRAM-MSAVI2	74
6. DISCUSIÓN	76
7. CONCLUSIONES	77
8. LITERATURA CITADA	78

LISTA DE CUADROS

Cuadro 1. Uso de las bandas Landsat.....	25
Cuadro 2. Características de las áreas agrícolas	50
Cuadro 3. Fechas de muestro de las parcelas privadas del Ejido “La Purísima”	55
Cuadro 4. Fechas de muestreo de las parcelas de la Universidad Autónoma Chapingo-Unidad Regional Universitaria de Zonas Áridas (URUZA)	53
Cuadro 5. Fechas de muestreo de las parcelas privadas agrícolas en las cercanías de la Universidad Autónoma Chapingo-Unidad Regional Universitaria de Zonas Áridas (URUZA)	54
Cuadro 6. Mejores ecuaciones obtenidas para los bordes húmedos (STRw) y secos (STRd) para el modelo OPTRAM	63
Cuadro 7. Mejores ecuaciones obtenidas para los bordes húmedos (LSTNASA/LSTw) y secos (LSTNASA/LSTd) para el modelo TOTRAM	64
Cuadro 8. Resultados modelo OPTRAM-NDVI a diferentes profundidades	67
Cuadro 9. Resultados modelo OPTRAM-SAVI a diferentes profundidades.....	69
Cuadro 10. Resultados modelo OPTRAM-MSAV2 a diferentes profundidades	69
Cuadro 11. Resultados modelo TOTRAM-NDVI a diferentes profundidades de la misión Landsat-8.....	72
Cuadro 12. Resultados modelo TOTRAM-SAVI a diferentes profundidades de la misión Landsat-8.....	74
Cuadro 13. Resultados modelo TOTRAM-MSAVI2 a diferentes profundidades de la misión Landsat-8.....	74

LISTA DE FIGURAS

Figura 1. Comparaciones de las longitudes de onda de las misiones Landsat.	25
Figura 2. Longitudes de onda de las bandas de la misión Sentinel 2	27
Figura 3. Mapa de ubicación del municipio de Mapimi, Durango.....	49
Figura 4. Parcelas Universidad Autónoma Chapingo-Unidad Regional Universitaria de Zonas Áridas (URUZA), imagen extraída de Google Earth Engine.....	50
Figura 5. Parcelas privadas cercanías URUZA, imagen extraída de Google Earth Engine.....	51
Figura 6. Parcelas privadas Ejido “La Purísima”, imagen extraída de Google Earth Engine.....	51
Figura 7. Parámetros del Modelo Trapezoidal Térmico-Óptico.....	58
Figura 8. Parámetros del Modelo Trapezoidal Óptico	59
Figura 9. Distribuciones de la relación de los pixeles de STR en conjunto con los índices de vegetación NDVI, SAVI y MSAVI2 del Modelo OPTRAM, y los bordes húmedos (líneas curvas azules) y bordes secos (lineales curvas rojas).....	62
Figura 10. Distribuciones de la relación de los pixeles de LST/LSTNASA en conjunto con los índices de vegetación NDVI, SAVI y MSAVI2 del Modelo TOTRAM, y los bordes húmedos (líneas rectas azules) y bordes secos (lineales rectas rojas).	64
Figura 11. Datos de humedad in situ (Θ) comparados con la ecuación de contenido normalizado de humedad (W) modelo OPTRAM-NDVI a 5, 10 y 20 cm de profundidad.....	70
Figura 12. Datos de humedad in situ (Θ) comparados con la ecuación de contenido normalizado de humedad (W) modelo OPTRAM-SAVI a 5, 10 y 20 cm de profundidad	68

Figura 13. Datos de humedad in situ (Θ) comparados con la ecuación de contenido normalizado de humedad (W) modelo OPTRAM-MSAVI2 a 5, 10 y 20 cm de profundidad	70
Figura 14. Datos de humedad in situ (Θ) comparados con la ecuación de contenido normalizado de humedad (W) modelo TOTRAM-NDVI a 5, 10 y 20 cm de profundidad	71
Figura 15. Datos de humedad in situ (Θ) comparados con la ecuación de contenido normalizado de humedad (W) modelo TOTRAM-SAVI a 5, 10 y 20 cm de profundidad	73
Figura 16. Datos de humedad in situ (Θ) comparados con la ecuación de contenido normalizado de humedad (W) modelo TOTRAM-MSAVI2 a 5, 10 y 20 cm de profundidad	75

ABREVIATURAS USADAS

LST	Temperatura de la superficie terrestre
STR	Banda del infrarrojo cercano transformada a reflectancia
NDVI	Índice de Vegetación de la Diferencia Normalizada
SAVI	Índice de Vegetación Ajustado al Suelo
MSAVI2	Índice de Vegetación Modificado Ajustado al Suelo
W	Contenido Normalizado de Humedad en el Suelo
θ	Contenido de Humedad Volumétrica en el Suelo
OPTRAM	Modelo Trapezoidal Óptico
TOTRAM	Modelo Trapezoidal Térmico-Óptico
GEE	Google Earth Engine
API	Interfaz de Programación de Aplicaciones
PR	Percepción Remota
EEM	Espectro Electromagnético
SR	Sensores Remotos
NASA	National Aeronautics and Space Administration
USGS	United States Geological Survey
ESA	European Space Agency
IV	Índices de Vegetación

DEDICATORIA

A mis padres **María Teresa** y **Edgar Gerardo**, que siempre me han apoyado y a mis hermanos para alcanzar cada una de las metas que nos hemos propuesto a lo largo de nuestras vidas.

AGRADECIMIENTOS

A la **Universidad Autónoma Chapingo** que desde mi bachillerato me ha otorgado una de las mejores educaciones que un estudiante puede recibir a lo largo de su vida académica y al posgrado en Recursos Naturales y Medio Ambiente en Zonas Áridas de la Unidad Regional Universitaria de Zonas Áridas.

Al **Consejo Nacional de Ciencia y Tecnología (CONACYT)** por otorgarme el apoyo económico para mis estudios de maestría a través del Programa de Becas Nacionales.

Al **Dr. Ignacio Sánchez Cohen** quien me acepto como asesorado en un nuevo tema de investigación a pesar de haber perdido un año del programa de maestría debido al cambio de tema de investigación y comité asesor.

A mi nuevo comité asesor el **M.C Sergio Iván Jiménez Jiménez**, la **M.C. Mariana de Jesús Marcial Pablo** y el **Dr. Ricardo Trejo Calzada** por aceptar ser parte de mi comité asesor a pesar de tener menos de un año para el término de la nueva investigación.

A los **M.C. Sergio Iván Jiménez Jiménez** y **M.C. Mariana de Jesús Marcial Pablo** por apoyarme en fechas de toma de muestra de suelo para la investigación.

Al **Dr. Gregorio Egea Cegarra** y **Dr. Salomón Montesinos Aranda** por aceptarme como becario de investigación en colaboración de SM Geodim y la Escuela Técnica Superior de Ingeniería Agronómica de la Universidad de Sevilla.

A mis **compañeros y amigos** que conocí en Bermejillo, Durango que ayudaron a que mi estadía fuera lo más placentera posible, se los agradezco mucho.

DATOS BIOGRÁFICOS

Datos personales

Nombre: José Rodolfo Quintana Molina

Fecha de Nacimiento: 31 de enero de 1997

Lugar de Nacimiento: Estado de México, México

CURP: QUMR970131HMCNLD08

Profesión: Ingeniero en Irrigación

Cedula profesional: 12392887

Desarrollo académico:

La presente investigación fue realizada por C. José Rodolfo Quintana Molina, quien es originario de Texcoco, Estado de México. Es Ingeniero en Irrigación de la Universidad Autónoma Chapingo. En su último semestre de ingeniería fue participante y seleccionado del Programa de Estancias Profesionales México-Estados Unidos, donde realizó una estancia en la Universidad de Arizona dentro del Departamento de Análisis y Tecnología en Biosistemas, bajo la tutoría del PhD. Kamel Didan y PhD. Armando Barreto Muñoz.

En la actualidad su línea de investigación se relaciona con el uso de los sensores remotos para la toma de decisiones en la agricultura de precisión. Participo en la estancia de investigación en colaboración de SM Geodim y la Escuela Técnica Superior de Ingeniería Agronómica de la Universidad de Sevilla en el último semestre de maestría en las investigaciones “Parametrización de la conductividad hidráulica frente al contenido de humedad dentro de los tipos de texturas en el suelo” y “Aplicación de índices de vegetación utilizando imágenes de satélite Sentinel-2 para la detección del estrés salino en los cultivos de arroz según el tipo de agua de riego en Sevilla, España mediante Google Earth Engine”. bajo la tutoría del Dr. Gregorio Egea Cegarra y Dr. Salomón Montesinos Aranda.

RESUMEN GENERAL

Calibración del contenido de humedad del suelo utilizando imágenes de satélite Landsat-8 y Sentinel-2 mediante Google Earth Engine

En la región norte de México la escasez de agua para la agricultura ha ido en aumento a causa de los bajos niveles de precipitación. En el año agrícola 2019-2020 la superficie irrigada por el Distrito de Riego 017-Comarca Lagunera fue de aproximadamente 55.2 mil hectáreas, pese a eso el abandono de las prácticas agrícolas por la falta de agua continua vigente. Por ende, es crucial generar modelos que ayuden a la mejora del manejo de los recursos hídricos para proporcionar soluciones a los problemas agronómicos en la parte norte de México. En este sentido, el objetivo de la presente investigación es calibrar modelos [(Óptico Trapezoidal (OPTRAM) y Térmico-Óptico Trapezoidal (TOTRAM)] para estimar el contenido de humedad volumétrico del suelo de diferentes profundidades (5, 10 y 20 cm) usando índices de vegetación derivado de imágenes de satelitales Sentinel-2 y Landsat-8 utilizando Google Earth Engine (GEE). Se realizaron mediciones in-situ en tres sitios diferentes (2 de riego y uno de temporal) en diferentes fechas. Los datos de contenido de humedad del suelo (Θ) in-situ fueron comparados con el contenido normalizado de humedad (W) derivado de los modelos. De acuerdo con los resultados, el modelo OPTRAM mediante la combinación de las distribuciones de dos modalidades de agricultura no presentó una relación lineal positiva, a diferencia del modelo TOTRAM. Las profundidades con mayor relación lineal ($W-\Theta$) se observaron a 20 cm en OPTRAM-SAVI y 10 cm en TOTRAM-MSAVI2, mostrando la mayor precisión para la estimación del contenido de humedad volumétrico en el suelo.

Palabras clave: Imágenes de satélite, agricultura, índices de vegetación, distribuciones.

Tesis de Maestría en Ciencias, Posgrado en Recursos Naturales y Medio Ambiente en Zonas Áridas, Unidad Regional Universitaria de Zonas Áridas, Universidad Autónoma Chapingo
Autor: José Rodolfo Quintana Molina
Director de Tesis: Ignacio Sánchez Cohen

ABSTRACT

Calibration of soil moisture content using Landsat-8 and Sentinel-2 satellite data through Google Earth Engine

In the northern region of Mexico, water scarcity for agriculture has increased due to low precipitation levels. In the 2019-2020 agricultural year, the area irrigated by the Irrigation District 017-Comarca Lagunera was approximately 55.2 thousand hectares. Despite this, the abandonment of agricultural practices due to the lack of water continues. Therefore, it is crucial to generate models that help improve the management of water resources to provide solutions to agronomic problems in the northern part of Mexico. In this sense, the objective of the present research is to calibrate models [(Optical Trapezoidal (OPTRAM) and Thermal-Optical Trapezoidal (TOTRAM)] to estimate the volumetric soil moisture content of different depths (5, 10, and 20 cm) using vegetation indices derived from Sentinel-2 and Landsat-8 satellite images using Google Earth Engine (GEE). In-situ measurements were performed at three sites (2 irrigated and one rainfed) on different dates. The in-situ soil moisture content (Θ) data were compared with the normalized moisture content (W) derived from the models. According to the results, the OPTRAM model, by combining the distributions of two modes of agriculture, did not show a positive linear relationship, unlike the TOTRAM model. The depths with the highest linear relationship ($W-\Theta$) were observed at 20 cm in OPTRAM-SAVI and 10 cm in TOTRAM-MSAVI2, showing the highest accuracy for estimating volumetric moisture content in the soil.

Key words: satellite images, agriculture, vegetation indices, distributions.

Master Science Thesis, Posgraduate in Natural Resources and Environment in Arid Zones, Regional University Unit of Arid Zones, Chapingo Autonomous University.

Author: José Rodolfo Quintana Molina

Advisor: Ignacio Sánchez Cohen

CAPÍTULO I

1. INTRODUCCIÓN GENERAL

En México la superficie cultivada con riego en el año 2021 fue del 30.13%, mientras que el 69.87% pertenece a la superficie de temporal (SIAP, 2022). Un adecuado sistema de riego aporta la cantidad necesaria de agua en el momento que el cultivo lo necesita, humedeciendo el suelo hasta la profundidad que requiere el cultivo. Existen diferentes variedades de riego recomendables para cada región y cultivo como; riego por goteo, aspersión, bombeo, gravedad, entre otros. La forma de regar puede generar mejores rendimientos y mayores ingresos mediante un mejor uso del agua debido a la escasez. La agricultura de riego proporciona un mejor manejo del riego de los cultivos (SIAP, 2018). Por otra parte, la agricultura de temporal depende del comportamiento de las lluvias, la capacidad del suelo para captar y retener el agua. Además, los gastos en la producción son menores al no tener que invertir en un sistema de riego. (SIAP, 2016a). El contenido de humedad del suelo en áreas de estudio como la hidrología es importante en la definición de la porción de la infiltración que se convierte en escurrimiento, en cuencas hidrológicas, así como en la definición del proceso de infiltración en el suelo. La proporción de lluvia no retenida por el suelo se convierte en escurrimientos superficiales, debido a que el suelo llega a su punto de saturación. En la meteorología, determinar la partición de la radiación neta en componentes de calor latente y sensible. Mientras que, en la agricultura el contenido de humedad tiene diversas aplicaciones tales como; el uso eficiente del recurso hídrico, incremento del rendimiento del cultivo, reducción de la dependencia de fertilizantes y mejoramiento de la calidad del cultivo (Grag, 2016).

Actualmente, la situación es crítica en la región, anteriormente se necesitaban perforar 30 m para la obtención de agua, hoy en día se perforan 300 m o más

para obtener aproximadamente 30 litros, los cuales comúnmente contienen arsénico y su uso principal dirigido a los agricultores que riegan sus cultivos con agua de pozos. Los pozos particulares son operados por los usuarios, pero administrados por la Comisión Nacional del Agua (CONAGUA), llevando a cabo la distribución del volumen de agua para los productores (CONAGUA, 2012). Esta cobra una cuota de 1600 Mx ha⁻¹ sin considerar el tipo de cultivo para cubrir parcialmente los costos de operación, pero no incluye los costos de mantenimiento de los canales, obras principales, pérdida de agua en el proceso de conducción y distribución (Ramírez , 2019). Su distribución se realiza conforme a la importancia del recurso en los diferentes sectores y su asignación es una cuestión social. El agua debe de tener un precio con el fin de lograr recuperar el costo de su distribución y dar una señal clara a los usuarios de que el agua escasea cada vez más y que debe de ser utilizada con racionalidad económica.

La presente investigación incluye un análisis de series de tiempo de la relación de la temperatura de la superficie terrestre (LST) y la banda del infrarrojo cercano transformada a reflectancia (STR) en conjunto con índices de vegetación (NDVI, SAVI y MSAVI2) para la calibración y validación del contenido normalizado de humedad (W) a través de los modelos ópticos OPTRAM y TOTRAM. Estos, fueron comparados con los datos medidos de contenido de humedad volumétrico del suelo (Θ) in situ a 5, 10 y 20 cm de profundidad de las áreas agrícolas seleccionadas para el estudio entre los periodos del 15 de febrero del 2022 al 01 de agosto del 2022. Los análisis y calibraciones realizadas permitieron validar a que profundidad se obtuvo la mayor relación lineal (W- Θ). Así mismo, la profundidad más precisa para la estimación de la humedad del suelo dependiendo el índice de vegetación y modelo óptico.

2. OBJETIVOS

2.1. Objetivo General

- Estimar el contenido de humedad volumétrico en el suelo ($\text{cm}^3 \text{ cm}^{-3}$) utilizando imágenes de satélite Landsat-8 y Sentinel-2 mediante la plataforma Google Earth Engine (GEE) como soporte a la toma de decisiones en la agricultura de riego y temporal en la parte baja de la región hidrológica No. 36, en el estado de Durango, México.

2.2. Objetivos Específicos

- Parametrizar los bordes húmedos y secos de los modelos TOTRAM y OPTRAM derivados de imágenes de satélite Landsat 8 y Sentinel 2, en conjunto con tres diferentes índices de vegetación (NDVI, SAVI y MSAVI2).
- Extrapolar las escenas satelitales utilizando la ecuación de contenido normalizado de humedad (W) a través de la combinación de las series de tiempo de las distribuciones de los píxeles bajo riego por gravedad y agricultura de temporal con escurrimientos de los modelos OPTRAM y TOTRAM, por separado.
- Calibrar y validar el contenido de humedad normalizado de humedad (W) con los datos medidos in-situ a 5, 10 y 20 cm de profundidad de las áreas de estudio.

3. HIPOTESIS

- El contenido de humedad medido in-situ (Θ) tiene una relación lineal positiva con el contenido normalizado de humedad (W) obtenido a 5, 10 y 20 cm de profundidad mediante los modelos OPTRAM y TOTRAM.

CAPITULO II

4. REVISION DE LITERATURA

4.1. Percepción Remota

El CentroGeo (2022) define a la Percepción Remota (PR) como una disciplina basada en la ciencia y tecnología que permite desarrollar, capturar, procesar y analizar imágenes, junto con otros datos físicos de la Tierra, obtenidos desde sensores en el espacio, y con sensores que capturan datos de mediciones in situ. Dicho así, la PR nos permite obtener datos de objetos o un medio físico (medio ambiente) sin la necesidad de tener contacto directo con él, utilizado para extensiones geográficas amplias, dimensionales, tridimensionales o modelos digitales de elevación.

La SEMAR (2009) asocia como elementos básicos que componen a la percepción remota moderna:

- La fuente de iluminación formada en este caso por el Sol que emite luz o radiación solar.
- La configuración del paisaje mediante los objetos explorados por el hombre (mar, ríos, vegetación, entre otras).
- La escena, aquella sección o superficie de interés.
- El sensor remoto, con el que se captura la luz proveniente de la escena, la cual permite obtener una representación visual del área de interés.
- La plataforma, sitio donde se sube la escena obtenida por el sensor remoto.
- El sistema de procesamiento, compuesto por el dispositivo a procesar cualitativa o cuantitativamente los datos procesados por el sensor remoto acerca de la escena obtenida.

- El apoyo de campo de la inspección directa de varios puntos seleccionados de la escena, de diferentes atributos de los objetos que se encuentran en el terreno, con el fin de evaluar los datos obtenidos.

La radiación electromagnética es la energía que la tierra recibe del sol. Esta radiación es absorbida, emitida o reflejada por la atmosfera terrestre. Los satélites cuentan con sensores calibrados para la detección de las longitudes de onda dentro del espectro electromagnético (EEM). La NASA (2015) comenta que los materiales reflejan o absorben diferentes tipos de longitudes de onda de la radiación electromagnética, dichos observan el comportamiento de las ondas electromagnéticas reflejadas, las cuales son detectadas por los sensores, y sirven para la determinación de la radiancia emitida de cada elemento de la superficie terrestre refleja, dicho proceso es conocido como firma espectral.

4.1.1. Sensores Remotos

Los Sensores Remotos (SR) o Teledetección es la ciencia y el arte de obtener información de un objeto, área o fenómeno, a través del análisis de datos adquiridos mediante un dispositivo, el cual no está en contacto directo con el objeto, área o fenómeno que se está investigando (Lillesand et al., 2015).

Dentro de los SR los rangos más utilizados para usos de recursos naturales y agrícolas son de 0.4 a 0.8 micrones (visible e infrarrojo). Pérez, (2007) caracteriza a los SR bajo los siguientes criterios:

Según el origen o fuente de radiación, siendo los sensores activos y pasivos.

- Sensores activos: la energía irradiada es propia, no dependen de la energía irradiada por la superficie de la tierra proveniente de los rayos solares. El sensor envía un flujo de radiación espectral que impacta con la superficie, siendo reflejada (albedo) y captada por el sensor. Dicho sensor es capaz de atravesar las nubes y doseles densos, por lo tanto, proporcionan más información. Sin embargo, suelen ser más costosas, más difíciles de analizar y pueden diferir drásticamente en

función de los parámetros utilizados. Ejemplos: Radar, Sentinel 1 y LiDAR.

- Sensores pasivos: registran la radiación electromagnética reflejada o emitida por la superficie terrestre. A diferencia de los sensores activos, los pasivos dependen principalmente de la energía irradiada por el sol. Siendo los datos más fáciles de interpretar, ya que producen imágenes similares a la de una cámara. El reflejo de distintas bandas del espectro se utiliza para clasificar tipos de cobertura del suelo y especies vegetales. Incluso, se puede inferir el estado de la vegetación a partir de los reflejos del infrarrojo y del infrarrojo cercano. Sin embargo, requieren de luz para generar imágenes, la nubosidad es una gran limitante para este tipo de sensores. Ejemplos: Landsat, Sentinel 2, MODIS (Terra/Aqua), SPOT, etc.

Según por el Principio de Funcionamiento. Los sensores activos y pasivos se agrupan en de barradura, y de no-barradura.

- Sensores de no barradura: registran la radiación reflejada de un área de superficie de la Tierra en su totalidad en un mismo instante. Se conocen como sensores de cuadro. Los datos pueden ser expresados en forma graficas (imagen) o numérica.
- Sensores de barradura: la imagen se forma por la adquisición secuencial de imágenes elementales del terreno o elementos de resolución; llamado “píxel”.

Según el Tipo de Producto. Clasificados en sistemas fotográficos y no fotográficos.

- Sistemas fotográficos: la energía está representada de manera continua (analógica), siendo dispositivos, que mediante un sistema óptico (conjunto de lentes) registran la energía reflexiva del albedo de la superficie, creando filmes fotográficos o detectores.

- Sistemas no fotográficos: son dispositivos utilizados para medir la intensidad de la radiación electromagnética de los albedos, provenientes de la superficie de la Tierra, en determinadas fajas espectrales del EEM. Ejemplo: radiómetros.

Radiómetros no generados y generados de imágenes.

- Radiómetros no generados de imágenes: miden la radiancia del albedo de la superficie terrestre, en forma de gráfico o numérica. En forma numérica registra la radiación en fajas (bandas) del EEM.
- Radiómetros generados de imágenes: generan como resultado final una imagen de un área del terreno, registrando la radiación electromagnética en diferentes bandas del EEM, desde ultravioleta hasta el infrarrojo térmico (0.2 a 14 μm). Estos sensores generadores de imágenes tienen cuatro dominios de resolución: espectral, espacial, temporal y radiométrica.

Los dominios de resolución de las imágenes radiométricas generadas dependen de la órbita del satélite y el diseño del sensor. En la actualidad, para estudios ambientales, de recursos naturales, hídricos y agrícolas, etc., el uso de satélites como Landsat, Sentinel y MODIS es muy común. Sin embargo, cada uno cuenta con diferentes dominios de resolución. MODIS cuenta con 36 bandas espectrales de entre 0.405 y 14.385 μm , resoluciones temporales de 1 a 2 días, resoluciones espaciales (píxel) de 250, 500 y 1000 m y una resolución radiométrica de 12 bits, discriminando 4096 niveles de brillo (NASA, 2022a).

Sentinel 2, está dividido en 2 sensores gemelos Sentinel 2A y Sentinel 2B, ambos con 13 bandas espectrales de entre 0.4921 a 13.769 μm , resoluciones temporales de intervalos de 2 a 5 días entre satélites, resoluciones espaciales de 10, 20 y 60 m, y una resolución radiométrica de 12 bits con 4095 niveles de brillo (ESA, 2022a). Y Landsat 7, 8 y 9, contienen 2 distintos sensores el Operational Land Imager (OLI) con 9 bandas espectrales y el Thermal Infrared Sensors (TIRS) con 2 bandas térmicas de entre 0.43 a 12.51 μm , resoluciones temporales de 16 días en solitario y en conjunto de 8 días, resoluciones espaciales de 30 y

100 m. Pero, a diferencia de los demás sensores Landsat 9 cuenta con una resolución radiométrica de 14 bits con 16,384 niveles de brillo. En cambio, Landsat 8 cuenta con la misma radiometría que los demás sensores anteriormente mencionados (NASA, 2022b).

Dicho esto, los SR son de gran importancia para estudios donde las extensiones geográficas cuentan con un área de gran tamaño, disponiendo de cualquier tipo de información proporcionada por los diferentes tipos de satélites y conjuntos de datos satelitales disponibles. Esto permite a distintas áreas realizar estudios o investigaciones referentes al medio ambiente, recursos naturales, agricultura, oceanografía, hidrología, geología, etc. De esta manera, ser capaces de desarrollar o implementar técnicas para evaluar y monitorear con más rapidez las tendencias a largo plazo y los cambios a corto plazo, en menor tiempo y a un menor costo.

4.2. Programa Landsat

El programa Landsat de la NASA/USGS proporciona el registro espacial más largo continuo de la cobertura de la Tierra en existencia. Los datos Landsat nos ofrecen información esencial para la toma de decisiones relacionadas a los recursos naturales y medio ambiente de la Tierra (NASA, 2022c).

Las misiones Landsat dieron comienzo el año 1972, donde Landsat 1 era conocido como Earth Resources Technology Satellite (ERTS). El cual fue el primer satélite en ser lanzado con la intención de estudiar y monitorear la masa de la Tierra. Para la realización del monitoreo, Landsat 1 cargaba con 2 sensores, uno construido por la Radio Corporation of America (RCA) llamado Return Beam Vidicon (RBV), y el Multispectral Scanner (MSS) construido por Hughes Aircraft Company (HAC). Sin embargo, los datos del MSS fueron hallados superiores a los del RBV, debido a un problema eléctrico que causó que el satélite disminuyera la altitud de su órbita. Siendo retirado en 1978, habiendo entregado más de 300,000 imágenes de la Tierra. A pesar de eso, los datos de Landsat MSS probaron ser útiles para el monitoreo agrícola, exploración petrolera, minería, y estudios ambientales (Draeger et al., 1997).

Años más tarde, en el 1975, 2 años y medio después del lanzamiento de Landsat 1. Landsat 2 fue lanzado, considerado por la NASA como un Proyecto Experimental. En el 1978, 3 años después Landsat 3 fue lanzado, como sus antecesores contaba con los mismos sensores (MSS y RCA) y las mismas 4 bandas (verde, azul e infrarrojas). A diferencia de sus predecesores, las bandas contaban con una mejora en la resolución espacial disminuyendo el tamaño de los píxeles y la incorporación de una quinta banda térmica al sensor MSS. Sin embargo, la banda térmica fallo en breve después de su lanzamiento.

Para Landsat 4 y Landsat 5, la incorporación del sensor Thematic Mapper (TM) proporcionaría una mayor sensibilidad radiométrica. Además de la adición de una nueva banda térmica, con un total de 7 bandas. Aunque, ambos satélites mostraban grandes avances, al año de su lanzamiento Landsat 4 sufrió la pérdida de 2 de sus paneles solares y sus transmisores de enlace directo. Por otro lado, Landsat 5, sufrió un fallo en el transmisor TDRSS primario, este último fue construido y diseñado al mismo tiempo que Landsat 4. Adicionalmente, Landsat 6, presentaría fallos durante su lanzamiento, al no alcanzar la velocidad necesaria para el trayecto de la órbita (NASA, 2022d).

En el 1999, la nueva misión Landsat 7 fue lanzada exitosamente, junto con la incorporación del sensor Enhanced Thematic Mapper Plus (ETM+). Incluyendo, características que lo convirtieron en el instrumento más versátil y eficiente para los estudios de cambio global, monitoreo y evaluación de la cobertura terrestre, y mapeo de áreas extensas que sus antecesores diseños. Además, del incremento de las colecciones de escenas satelitales, desarrollando e implementando una evaluación automatizada de la cobertura de nubes, un plan de adquisición a largo plazo para mejorar la probabilidad de alcanzar la meta de adquirir una base de datos global actualizada estacionalmente libre de nubes de un solo satélite (Irish et al., 2006; Arvidson et al., 2006). Landsat 7 en su tiempo fue considerado como el satélite de observación de la Tierra calibrado con mayor precisión. Siendo sus mediciones extremadamente precisas cuando se comparan con las mismas medidas en el suelo. No fue, si no hasta octubre del

2008, que la USGS dio acceso gratis a todo público a los datos Landsat 7, con un repertorio de 6 bandas visibles y 1 térmica.

Landsat 8 fue lanzado en el 2013 con 2 nuevos sensores para proveer un registro de datos continuo. La tecnología incluía las bandas de reflectancia y térmicas, las cuales fueron separadas en 2 instrumentos. The Operational Land Imager (OLI) es el sensor de banda reflectante y el Thermal Infrared Sensor (TIRS), el térmico. Adicionalmente, numerosos cambios fueron realizados como la incorporación de nuevas bandas, refinamiento en las bandas espectrales, y varias mejoras fueron implementadas. Constituido de 9 bandas espectrales y 2 térmicas. Al igual que, las anteriores misiones de Landsat, la National Aeronautics and Space Administration (NASA) y la United States Geological Survey (USGS) cooperaron en el desarrollo, lanzamiento y operación de Landsat 8 (Markham et al., 2015).

Por último, Landsat 9 fue lanzado en septiembre del 2021, constituido por el sensor Operational Land Imager 2 (OLI-2), con una órbita actual a la de Landsat-8, incluyendo 9 bandas espectrales, 8 con 30 m de resolución espacial, y 1 con 15 m. Mejorando la calidad radiométrica y geométrica para rastrear cambios a largo plazo en la cobertura del suelo, ecosistemas terrestres e hidrología (Masek et al., 2020). Además, del sensor Thermal Infrared (TIRS-2) aprovecha mucho más el diseño de Landsat 8, con cambios significativos para una absoluta precisión y su mejoramiento. Los principales cambios para la TIRS-2 fueron el incremento en la vida útil de la misión de 3 a 5 años, una mejora en el límite de temperatura de supervivencia, mejoras en la protección ante meteoritos, y un incremento en la disipación de carga superficial (Hair et al., 2018).

En la Figura 1, se muestran las bandas de todas las misiones Landsat, señalando el tipo de sensor de cada banda (MSS, TM, ETM+, OLI y TIRS) y comparando las longitudes de onda de cada misión en nanómetros.




Figura 1. Comparaciones de las longitudes de onda de las misiones Landsat (NASA, 2022e).

Adicionalmente, en el Cuadro 1, se enlista las bandas Landsat y los principales usos de cada banda para el desarrollo de investigaciones de distintas disciplinas.

Cuadro 1. Traducción de uso de las bandas Landsat (NASA, 2019).

Usos de las bandas de Landsat						Descripción del uso
Nombre de la banda	L-8-L9 OLI/TIRS	L-7 ETM+	L4-5 TM	L4-5 MSS	L1-3 MSS	
Costera/Aerosol	Banda 1	--	--	--	--	Observaciones de zonas costeras y aguas poco profundas; estudios de aerosoles, polvo, detección de humo.
Azul (B)	Banda 2	Banda 1	Banda 1	--	--	Cartografía batimétrica; discriminación de suelo/vegetación, mapeo de tipos de bosques, e identificación características artificiales
Verde (G)	Banda 3	Banda 2	Banda 2	Banda 1	Banda 4	Vegetación pico; evaluación del vigor de la planta
Rojo ®	Banda 4	Banda 3	Banda 3	Banda 2	Banda 5	Identificación de tipo de vegetación; características de suelos y características urbanas.
Infrarojo Cercano (NIR)	Banda 5	Banda 4	Banda 4	Banda 3	Banda 6	Detección de vegetación y análisis; mapeo costero y contenido de biomasa
	--	--	--	Banda 4	Banda 7	
Infrarojo de Onda Corta-1 (SWIR-1)	Banda 6	Banda 5	Banda 5	--	--	Contenido de humedad en la vegetación; análisis de sequía; áreas afectadas por incendios; detección de incendios activos
Infrarojo de Onda Corta-2 (SWIR-2)	Banda 7	Banda 7	Banda 7	--	--	Detección adicional de incendios activos (especialmente de noche); humedad de la planta/ análisis de sequías
Pancromática (PAN)	Banda 8	Banda 8	--	--	--	Afinación de imágenes multispectrales a una mayor resolución.
Cirrus	Banda 9	--	--	--	--	Detección de nubes de cirrus
Termica (T)	Banda 10	Banda 6	Banda 6	--	--	Mapeo de la temperatura del suelo y estimaciones de la humedad del suelo
	Banda 11			--	--	

Los datos Landsat recopilados de todas las misiones lanzadas proveen entradas técnicas y científicas a la USGS y NASA, ayudando a asegurar el éxito de los programas Landsat, mientras aportan ayuda científica en problemas incluidos en la adquisición de datos, el acceso a los productos, sus formatos, las oportunidades científicas y sus aplicaciones.

4.3. Programa Copernicus Sentinel 2

Como parte de del programa de Copernicus, la European Space Agency (ESA) desarrollo una nueva misión que observa la Tierra con un numero de bandas espectrales mayores, llamado Sentinel-2 (S2). Sus principales rangos de aplicaciones son; el monitoreo de vegetación, detección de componentes geológicos, manejo de riesgos y desastres (Transon et al., 2018). En el 2015, Sentinel-2A fue lanzado. Mientras que, en el 2017, Sentinel-2B fue lanzado, ambos con el fin de proporcionar series de tiempo de reflectancia multiespectral única sobre las costas y la tierra. El sensor que carga los satélites Sentinel-2, es conocido como Multi-Spectral Instrument (MSI), sensor tipo pasivo, recolecta la luz reflejada de la Tierra.

Además, datos nuevos son adquiridos en el instrumento conforme el satélite realiza su órbita. El haz de luz entrante es separado en un filtro y centrado en 2 ensamblajes de plano focal dentro del instrumento. Uno para las bandas visibles e infrarrojas (VNIR) y una para las bandas de infrarrojo de onda corta (SWIR). La separación espectral de cada banda y sus longitudes de onda individuales es lograda a través de los filtros montados en la parte superior de los detectores (ESA, 2022b).

En la Figura 2, nos muestras longitudes de onda de cada una de las bandas que incorporan la misión Sentinel-2. Donde, las resoluciones espaciales están divididas en tres partes:

- Cuatro bandas de 10 m: 490 nm (B2), 560 nm (B3), 665 nm (B4), 842 nm (B8).
- Seis bandas de 20 m: 705 nm (B5), 740 nm (B6), 783 nm (B7), 865 nm (B8a), 1 610 nm (B11), 2 190 nm (B12).
- Tres bandas de 60 m: 443 nm (B1), 945 nm (B9) and 1 375 nm (B10).

Siendo la resolución radiométrica la capacidad del instrumento para distinguir diferentes intensidades de luz y reflectancia.




Figura 2. Longitudes de onda de las bandas de la misión Sentinel 2 (ESA, 2012).

Además, ESA (2015) enlista 3 diferentes tipos de productos disponibles para los usuarios como:

- Level-1B: Radiancia al tope de atmosfera en la geometría sensor.
- Level-1C: Reflectancia al tope de atmosfera en la geometría de la cartografía.
- Level-2A: Reflectancia al fondo de la atmosfera en la geometría de la cartografía.

La misión Sentinel-2 constituida de satélites gemelos, alta frecuencia de revisión, e imágenes de alta resolución que apoyan a los programas Copernicus. Algunas aplicaciones del programa Copernicus provee un servicio del monitoreo terrestre en variables relacionadas al estado de la vegetación o el ciclo del agua. Apoya una variedad de aplicaciones incluyendo la planeación espacial, manejo forestal, manejo de agua, agricultura y seguridad alimentaria, desastres naturales (inundaciones, incendios, tormentas, terremotos, etc), crisis humanitarias (después de periodos de sequía severa). En casos de seguridad, apoyan en la

vigilancia de las fronteras del mar dentro y fuera de Europa, inmigración ilegal y vigilancia del tráfico ilegal en Europa, entre otras.

4.4. Índices de vegetación para la estimación del contenido de humedad del suelo mediante sensores remotos

Las imágenes multiespectrales de los conjuntos de datos satelitales en las distintas misiones presentes hoy en día son la principal fuente para la creación, desarrollo, interpretación, análisis y mapeo de la superficie terrestre (Jiménez et al., 2022). Las combinaciones de las distintas bandas y rangos del espectro electromagnético son conocidos como Índices de Vegetación (IV). La implementación de los IV en la agricultura ayuda a la parametrización numérica, cálculo y estimación indirecta de procesos como eficiencia del cultivo, monitoreo de las etapas fenológicas estimación del rendimiento, entre otras (Ibarra et al., 2020). Además, los IV son utilizados para el monitoreo de la humedad en cultivos de riego y temporal, control de sequías y estimación de la humedad del suelo (Mananze et al., 2019; Ambrosone et al., 2020) mediante su combinación con variables como la temperatura de la superficie terrestre y bandas dentro del dominio óptico.

4.4.1. Índice de Vegetación de Diferencia Normalizada (NDVI)

Uno de los índices de vegetación (IV) más utilizado en la agricultura es el NDVI. El número de artículos publicados relacionados al uso del NDVI incrementó rápidamente de 795 en los 90s, a 3361 en los 2000s. En los 2010s, ya habían sido publicados aproximadamente 12,618 artículos (Huang, et al., 2020). Rouse (1973) estudió el comportamiento de la relación de los valores de las firmas espectrales y la cobertura vegetal, derivado de la combinación de bandas espectrales del IV que conocemos el día de hoy, como NDVI.

El NDVI es calculado a partir de los valores de reflectancia de las bandas espectrales rojo (R) y el infrarrojo cercano (NIR) de diversos sensores satelitales, comprendiendo un intervalo de variación de entre -1 y +1. La vegetación saludable absorbe más de la luz visible que impacta sobre la planta, y refleja una porción grande de la luz del infrarrojo cercano, con valores alrededor de 0.8 y 0.9,

indicando una probabilidad alta en la densidad de las hojas. Por otro lado, la vegetación no saludable refleja más luz visible y menos luz del infrarrojo cercano, con valores de entre 0.2 y 0.3, indicando caída de follaje en la época de sequía. Valores cercanos a 0, no son considerados áreas con vegetación, pudiendo ser suelos desnudos (NASA, 2000).

En este contexto, relacionar el NDVI con la humedad del suelo ha dado paso a toda una línea de investigación. Farrar et al (1994), menciona la influencia del tipo del suelo, NDVI, precipitación y humedad del suelo en la zona semiárida de Botswana. Esta investigación demostró que los 5 tipos de suelos estudiados difieren significativamente con respecto a la tasa de generación de humedad del suelo por unidad de lluvia y la relación de NDVI a la humedad del suelo. El estudio demostró que los suelos más productivos son vertisoles ricos en arcilla, comparado con los suelos arenosoles que resultaron menos productivos, aunque el rango de humedad del suelo generado fue muy parecido entre los 2 tipos de suelo. Otros estudios se han enfocado en la relación entre el Índice de Área Foliar (LAI), y la cobertura vegetativa (Carlson y Ripley, 1997), la clasificación de la cobertura terrestre (DeFries y Townshend, 1994), el monitoreo de las sequías (Peters et al., 2002), entre muchos otros donde también es usado el NDVI y la relación que guarda con el contenido de humedad del suelo.

4.4.2. Índice de Vegetación Ajustado al Suelo (SAVI) e Índice de Vegetación Modifica Ajustado al Suelo (MSAVI2)

Los modelos espectrales y algunos IV son utilizados para mejorar la cuantificación de la sensibilidad de la vegetación a los cambios en variables atmosféricas y cambios de variables del suelo. El índice SAVI (Ecuación 2) fue desarrollado para minimizar el brillo del suelo de los IV espectrales a través de la incorporación de un factor de ajuste del suelo “L” en el denominador de la ecuación de NDVI (Huete, 1988). Por otra parte, el MSAVI2 (Ecuación 3) reemplaza la constante “L” de la ecuación de SAVI con una variable derivada mediante la utilización del NDVI y índice de vegetación de diferencia ponderada (WDVI), mostrando un incremento en el rango dinámico de la señal de la

vegetación, mientras se minimiza la influencia del fondo del suelo, resultando en una mayor sensibilidad de la vegetación (Qi et al., 1994).

El SAVI ha sido utilizado para la realización de comparaciones entre los distintos IV existentes. Vani y Mandla (2017) comparan el NDVI y SAVI en un área semiárida de la India, llegando a la conclusión de que la constante “L” varía dependiendo de la cubierta vegetal, si ésta aumenta, la “L” se acerca a 0, teniendo un comportamiento similar al NDVI. Por otro lado, si la cubierta vegetal es baja la “L” se acerca al valor 1, comportándose diferente al NDVI. Bajo una cubierta vegetal intermedia, la “L” se acerca a un valor de 0.5. Sin embargo, una baja cobertura vegetal en el NDVI es fuertemente afectada por el suelo con escasa vegetación o suelo desnudo. Por otra parte, el SAVI es mucho más apropiado para las áreas con escasas de vegetación y suelos desnudos.

No obstante, el MSAVI2 se ha utilizado para la evaluación de las sequías en regiones áridas. Tal es el caso de Narayanan et al (2013) que exponen la correlación entre el NDVI, MSAVI2 y la Misión de la Medición de la Precipitación Tropical (TRMM) para la evaluación de las sequías en la zona árida de Rajasthan, India, mostrando la superioridad del MSAVI2 ante el NDVI, debido a las mejores correlaciones obtenidas entre el MSAVI2 y el TRMM para la evaluación entre el porcentaje de precipitación y cobertura vegetal.

4.5. Contenido de humedad en el suelo

El contenido de humedad en el suelo en las capas de la superficie de la Tierra es de gran importancia en diferentes disciplinas de la agricultura, hidrología y meteorológica (Schmugge, 1980). El contenido de humedad del suelo puede ser definido como la cantidad de agua que el suelo puede retener, dependiendo del tipo de suelo y el contenido de materia orgánica (MO). Diferentes tipos de prácticas agrícolas modifican las propiedades inherentes de su fertilidad, lo cual repercute sobre el contenido de materia orgánica y la capacidad de almacenamiento de agua (Bowman et al., 1999). La textura del suelo influye en los procesos de retención de humedad y está relacionado con el contenido

porcentual de arcilla del suelo como lo demuestran Largaespada y Enríquez (2015).

Existen diferentes métodos o técnicas para medir el contenido de humedad en el suelo. Durante años el método más utilizado era el método gravimétrico, el cual consiste en pesar la muestra de suelo del lugar de estudio, colocarla dentro de una estufa a 105°C, durante 24 horas aproximadamente. Al término del tiempo, la muestra es pesada para conocer el peso perdido. La diferencia entre el peso húmedo y seco, relacionado al peso seco, arroja el contenido porcentual de humedad de ese suelo. A pesar de que este método se considera el método patrón, consume bastante tiempo y recursos. No obstante, existen técnicas más sofisticadas para su medición.

Walker et al., (2004) evaluó diferentes tipos de sensores de humedad del suelo que incluyeron sensores TDR (Time Dominant Reflectance). La técnica del TDR considera la relación de la velocidad de las ondas electromagnéticas que pasan entre las varillas de guía de onda midiendo el tiempo en el que viaja. Dentro del estudio, se consideraron sensores como el TDR Buriable, el cual consiste en 3 varillas con 20 cm de longitud y el TRASE, que es la unidad donde almacenada la información recopilada. El sensor TDR Connector, consiste en 2 varillas de acero inoxidable de la guía de las ondas con diámetro de 6 mm, así como el TRASE, correspondiente. Adicionalmente, el CS615 Campbell, consiste en 2 varillas de 30 cm de acero inoxidable conectadas a una placa de circuito impreso. El estudio mostro buenas relaciones entre el método gravímetro y las técnicas TDR a 10 y 15 cm de profundidad, a diferencia de la profundidad a 5 cm.

Sin embargo, las mediciones in situ no son las únicas maneras de lograr medir o estimar el contenido de humedad en el suelo a diferentes profundidades. Existen técnicas desarrolladas, calibradas y aplicadas para cuantificar el contenido de humedad del suelo mediante el uso de los sensores remotos (SR) y sus derivados.

4.6. Modelo Trapezoidal Térmico-Óptico (TOTRAM) y Modelo Trapezoidal Óptico (OPTRAM) para la estimación del contenido de humedad del suelo mediante sensores remotos

La humedad del suelo en la superficie de la tierra sufre variaciones con el paso del tiempo, afectando principalmente a los procesos hidrológicos como la infiltración, los escurrimientos y la evaporación. Los SR aportan una amplia y poderosa herramienta para el monitoreo de la humedad cercanas a la superficie del suelo, las cuales suelen variar entre los 0 a 10 cm de profundidad. Esta delgada capa de la superficie del suelo es fundamental para procesos hidrológicos, biológicos y biogeoquímicos (Wang y Qu, 2009).

La estimación de la humedad del suelo mediante SR dio comienzo en la mitad de 1970 con el inicio de la era satelital. Numerosos investigadores han mostrado que el contenido de humedad puede ser estimado a partir de métodos ópticos y térmicos, también como pasivos, y técnicas activas de teledetección mediante microondas. La principal diferencia entre estas técnicas son las regiones de longitud de onda dentro del espectro electromagnético (Walker, 1999).

El modelo trapezoidal es considerado como uno de los modelos más utilizados en la teledetección para la estimación de la humedad en el suelo basado en observaciones térmicas (temperatura de la superficie del suelo) y ópticas. Por su parte, el Modelo Trapezoidal Térmico-Óptico (TOTRAM), se basa de la interpretación de la distribución de los píxeles dentro de la temperatura de la superficie (LST) y el espacio del índice de vegetación. Sin embargo, el método cuenta con desventajas, debido al cálculo de la LST.

Dependiendo el método o algoritmo, será el número de variables que se deben desarrollar para su cálculo, existiendo distintos tipos como el método Single-Channel, el algoritmo Split-Window ó el algoritmo desarrollado por la NASA para sus últimas colecciones dentro de la USGS Earth Explorer para el cálculo de la LST mediante su banda térmica del sensor TIIRS-2. Además, dichos métodos y algoritmos únicamente pueden ser empleados con satélites que proporcionen datos térmicos. Asimismo, la LST no solo depende de la humedad del suelo, si

no, también de números factores como la temperatura del aire cercana al suelo, la humedad relativa y las variaciones que presentan las precipitaciones de cada zona (Pandey et al., 2020).

Por otra parte, el Método Trapezoidal Óptico (OPTRAM), está basado para remplazar la LST en TOTRAM con una medición para la humedad del suelo dentro del dominio óptico, basado del modelo de transferencia radiactiva de dos flujos de Kubelka y Munk (1931). Por otra parte, Sadeghi et al (2017) desarrollo un modelo físico mostrando una relación lineal entre el contenido de humedad de la superficie del suelo y la banda del infrarrojo cercano (SWIR) transformada en reflectancia. Las 2 bandas SWIR (e.j. 1650 nm correspondientes a la banda 6, y 2210 correspondiente a la banda 7 de Landsat 8) han sido probadas para suelos desnudos, y se ha demostrado que el modelo es muy preciso, especialmente en los 2210 nm. A diferencia del modelo TOTRAM, este modelo puede ser aplicado con cualquier satélite que cuente con sensores ópticos.

4.7. Google Earth Engine

Google Earth Engine (GEE) es una plataforma de geomática basada en la nube que permite a los usuarios visualizar y analizar imágenes de satélite del planeta, incluyendo un lapso de más de 40 años, el cual combina un catálogo con petabytes de imágenes de satélites y conjuntos de datos geoespaciales con capacidades de análisis a escala global, poniéndolo a disposición de estudiantes, investigadores, científicos con el objetivo de detectar cambios en la superficie terrestre de forma gratuita. (GEE, 2022).

La potencia de GEE descansa en la infraestructura de Google, la cual consiste en aproximadamente 10,000 CPUs trabajando en paralelo. De esta forma, los catálogos de datos son proporcionados a los usuarios, ayudando a estudios que podrían tomar años de recopilación de datos satelitales (Moore, 2017). GEE está conformado por varios elementos los cuales son: el catálogo de datos (datasets), el tipo de API (Application Program Interface) y el Editor del Código (Code Editor).

El catálogo de datos cuenta con una densidad amplia, incluyendo los conjuntos de datos satelitales completos de Landsat, MODIS y Sentinel. Además,

proporciona conjuntos de datos de pronósticos de clima, cobertura vegetal y muchos más medioambientales, geofísicos y socioeconómicos. Los catálogos son actualizados constantemente con un rango cercano a 6000 escenas por día de misiones activas, con un periodo de transferencia de datos a GEE cercanos a las 24 horas del tiempo de adquisición de la escena (Gorelick et al., 2017).

La Interfaz de Programación de Aplicaciones (API), se encarga de conectar los conjuntos de estructuras mediante comandos y funciones establecidas por GEE, permitiendo que los componentes de un código se comuniquen correctamente con otros. La API de GEE está desarrollado con el lenguaje de programación JAVA Script, pero de igual manera, existe un API para el lenguaje Python. Esta presenta la desventaja del consumo de memoria y limitación de los procesos de la computadora del usuario. A diferencia del API de JAVA Script, en la que los procesos son trabajados dentro de la nube y el Editor de Código de la plataforma. Por otro lado, el Editor de Código es la parte donde el catálogo de datos y el API se combinan para que el usuario pueda mediante códigos (scripts), llamar las colecciones de imágenes satelitales, procesarlas y visualizarlas de manera virtual con los servidores de Google, manteniendo su información y procesos dentro de la nube. Además, permite a los usuarios importar y exportar a la plataforma sus propios datos en formato vector o raster. Adicionalmente, GEE da acceso para la descarga de los procesos realizados en la nube, con la oportunidad de descargar la información generada, siendo almacenada en el Google Drive del usuario (Perilla y Mas, 2020).

4.8. Ventajas de los estudios utilizando Google Earth Engine sobre el método tradicional

Google Earth Engine (GEE) es accesible, amigable para los usuarios e interactivo para el desarrollo de datos y algoritmos. El uso de GEE es muy común, al igual que la utilización de softwares de Sistemas de Información Geográfica (SIG) tales como; ArcGIS (prepago), QGIS (gratuito) y SNAP (gratuito). En la actualidad, existen ventajas notables de GEE sobre los métodos tradicionales en el campo de los sensores remotos (SR). Como ejemplo, Hasen et al (2013) en su estudio,

tomaron en cuenta toda el área terrestre con excepción de la Antártida y un número de islas del Ártico, con una totalidad de 128.8 Mkm², equivalente a 143 billones de píxeles Landsat de 30 m, procesando 654,179 (cerca de 707 terabytes) imágenes de Landsat 7 en un lapso de 100 horas. Si el mismo estudio se hubiera realizado mediante el método tradicional hubiera tomado años completarlo. Esto debido, a la descarga, búsqueda de los conjuntos de datos satelitales, depuración de las fechas con porcentajes altos de nubosidad, combinación de escenas satelitales y sin mencionar el gran tamaño de memoria que se necesita para almacenar la enorme cantidad de información satelital.

Las aplicaciones de GEE son ampliamente reportadas en la literatura para uso en la agricultura como estimaciones de rendimiento de los cultivos, mapeo del área de los cultivos, vulnerabilidad ante enfermedades y plagas, evaluaciones de la idoneidad, entre otros. Otros estudios se enfocan a la estimación de la productividad primaria bruta y rendimiento de los cultivos (Mingzhu et al., 2018).

En relación con estudios hidrológicos a escala nacional, un ejemplo es el estudio de Sazib et al (2020) que relacionaron 601 cuencas de la base de datos de la Geospatial Attributes of Gages for Evaluating Streamflow (GAGE) con conjuntos de datos globales de humedad de suelo de la NASA-USDA y precipitación disponible en GEE. Este conjunto de datos fue relacionado con el flujo de corriente de las cuencas usando el Modelo Palmer, el cual estima la cantidad de agua ganada o perdida en los perfiles de suelo mediante la cantidad de agua perdida por la evapotranspiración y restaurada por la precipitación.

La integración de GEE a estudios de diferentes disciplinas otorgan un largo alcance, teniendo ventajas significativas sobre el método tradicional (Mutanga y Kumar, 2019) como:

- Ser gratuito para la realización de investigaciones, educación y actividades sin fines de lucro.
- Capacidad de procesamiento de escala de datos de peta-bytes.
- Los datos están disponibles en línea para todos los usuarios.
- Los códigos y scripts pueden ser compartidos a cualquier usuario de GEE.

- Utiliza pirámides de imágenes y mosaicos para mejorar los procesos.
- Rápida filtración y ordenamiento de información.
- Extenso catálogo de conjunto de datos archivados de más de 40 años.
- Datos en cercano tiempo real actualizada diariamente.
- Los usuarios son capaces de subir datos y descargar los resultados en cualquier momento.
- Proyecciones de datos manejables automáticamente.
- La mayoría de los datos ya han sido procesados y corregidos.
- Múltiples de productos derivados están ya disponibles.
- Contiene machine learning, procesamiento de imágenes, procesamiento de vectores, análisis geométrico, visualización de algoritmos, expansión de la librería de métodos y paquetes, entre otros.
- Disponibilidad de tutoriales y documentación para el desarrollo de algoritmos.

5. LITERATURA CITADA

- Ambrosone, M., Matese, A., Di Gennaro, S. F., Gioli, B., Tudoroiu, M., Genesio, L., & Toscano, P. (2020). Retrieving soil moisture in rainfed and irrigated fields using Sentinel-2 observations and a modified OPTRAM approach. *International Journal of Applied Earth Observation and Geoinformation*. 89, 102113. <https://doi.org/10.1016/j.jag.2020.102113>
- Arvidson, T., Goward, S.N., Williams, D.L., and Gasch, J. (2006). Landsat-7 long-term acquisition plan: Development and validation. *Photogrammetric Engineering & Remote Sensing*. 72(10), 1137-1146. <https://doi.org/10.14358/PERS.72.10.1137>
- Bowman, R. A., Vigil, M, F., Nielsen, R, L and Anderson, R, L. (1999). Soil Organic Matter Changes in Intensively Cropped Dryland Systems. *Soil Science Society of America Journal*. 63(1), 186-191. <https://doi.org/10.2136/sssaj1999.03615995006300010026x>
- Carlson, T. N., and Ripley, D. A. (1997). On the relation between NDVI, fractional vegetation cover, and leaf area index. *Remote sensing of Environment*, 62(3), 241-252. [https://doi.org/10.1016/S0034-4257\(97\)00104-1](https://doi.org/10.1016/S0034-4257(97)00104-1)
- Centro de Investigación en Ciencias de la Información Geoespacial. (2022). Percepción Remota. <http://www.centrogeo.org.mx/investigacion/percepcion-remota>.
- CONAGUA. 2012. Comisión Nacional del Agua (Atlas del agua en México. México. 139 p.
- DeFries, R. S., & Townshend, J. R. G. (1994). NDVI-derived land cover classifications at a global scale. *International journal of remote sensing*, 15(17), 3567-3586. <https://doi.org/10.1080/01431169408954345>

- Draeger, W.C., Holm, T.M., Lauer, D.T., and Thompson R.J. (1997). The availability of Landsat data: Past, present, and future. *Photogrammetric Engineering & Remote Sensing*. 63(7), 869-875.
- El Siglo de Torreón. 2010. Escasez de agua y arsénico afectan a la Comarca Lagunera. El Siglo de Torreón. 22 de marzo de 2010. <https://www.elsiglodetorreon.com.mx/noticia/509965.escasez-de-agua-y-arsenico-afectan-a-la-comarca-lagunera.html>
- ESA. (2012). ESA's Optical High-Resolution Mission for GMES Operational Services. European Space Agency.
- ESA. (2015). Sentinel-2 User Handbook. European Space Agency. https://sentinels.copernicus.eu/web/sentinel/user-guides/document-library/-/asset_publisher/xlslt4309D5h/content/sentinel-2-user-handbook
- ESA. (2022a). Sentinel 2, Resolution and Swath. <http://sentinels.copernicus.eu/web/sentinel/missions/sentinel-2/instrument-payload/resolution-and-swath>
- ESA. (2022b). Satellite Description. European Space Agency. <http://sentinels.copernicus.eu/web/sentinel/missions/sentinel-2/satellite-description>
- Farrar, T.J. & Lare, A. R. (1994). The influence of soil type on the relationships between NDVI, rainfall, and soil moisture in semiarid Botswana. II. NDVI response to soil moisture. *Remote Sensing of Environment*. 50(2), 121-133. [https://doi.org/10.1016/0034-4257\(94\)90039-6](https://doi.org/10.1016/0034-4257(94)90039-6)
- García, E. (2004). *Modificaciones al sistema de clasificación climática de Köppen*. Universidad Nacional Autónoma de México.
- Garg, A., Munoth, P., & Goyal, R. (2016). Application of soil moisture sensor in agricultura: A review. *Proceedings of International Conference on Hydraulic, Water Resources and Coastal Engineering*. 1662-1772.

- Google Earth Engine. (2022). Análisis a nivel planetario en la nube de Google. https://www.google.com/intl/es_ALL/earth/education/tools/google-earth-engine/
- Gorelick, Noel., Hancher, M., Dixon, Mike., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Enviroment*, 202, 18-27. <http://dx.doi.org/10.1016/j.rse.2017.06.031>
- Hair, J.H., Reuter, D.C., Tonn, S.L., McCorkel, J., Simon, A.A., Djam, M., Alexander, D., Ballou, K., Barclay, R., Coulter, P., & Edick, M. (2018). Landsat 9 thermal infrared sensor 2 architecture and design. *IEEE International Geoscience and Remote Sensing Symposium*. 8841- 8844. <https://10.1109/IGARSS.2018.8518269>
- Hansen, M. C., Potapov, P. V., Moore, R., Hancher, M., Turubanova, S. A., Tyukavina, A., Thau, D., Stehman, S. V., Goetz, S. J., Loveland, T. R., Kommareddy, A., Egorov, A., Chini, L., Justice, C. O., & Townshed, J. R. G. (2013). High-Resolution Global Maps of 21st-Century Forest Cover Change. *Science*, 342, 850. <https://doi: 10.1126/science.1244693>.
- Huang, S., Tang, L., Hupy., J. P., Wang, Y., & Shao, G. (2020). A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing. *Journal Forestry Research*. 32, 1-6. <https://doi.org/10.1007/s11676-020-01155-1>
- Huete, A.R (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing Enviroment*, 25(3), 295–309. [https://doi:10.1016/0034-4257\(88\)90106-x](https://doi:10.1016/0034-4257(88)90106-x)
- Ibarra, E. S., Bustamante, W. O., Capurata, R. E. O., & Cohen, I. S. (2020). Improving the monitoring of corn phenology in large agricultural areas using remote sensing data series. *Spanish journal of agricultural research*, 18(3), 23. <https://doi:10.5424/sjar/2020183-16269>.
- Irish, R. R., Barker J. L., Goward S. N., & Arvidson, T.J. (2006). Characterization of the Landsat-7 EMT+ automated cloud-cover assessment (ACCA)

- algorithm. *Photogrammetric Engineering & Remote Sensing*. 72(10), 1179-1188. <https://doi.org/10.14358/PERS.72.10.1179>
- Jiménez-Jiménez, S. I., Marcial-Pablo, M. D. J., Ojeda-Bustamante, W., Sifuentes-Ibarra, E., Inzunza-Ibarra, M. A., & Sánchez-Cohen, I. (2022). VICAL: Global Calculator to Estimate Vegetation Indices for Agricultural Areas with Landsat and Sentinel-2 Data. *Agronomy*, 12(7), 1518. <https://doi.org/10.3390/agronomy12071518>
- Kubelka, P., & Munk, F. (1931). Ein Beitrag zur Optik der Farbanstriche. *Zeitschrift für Technische Physik* 12, 593–601.
- Largaespada, K., & Henriquez, C. (2015). Distribución espacial de la humedad y su relación con la textura en un suelo. *Agronomía Costarricense*, 39(3). <https://doi.org/10.15517/rac.v39i3.21814>
- Lillesand, T.M., Kiefer, R.W., & Chipman, J.W. (2015). Remote Sensing and Image Interpretation. (7th ed.). John Wiley and Sons, Inc.
- Mananze, S., Pôças, I., & Cunha, M. (2019). Agricultural drought monitoring based on soil moisture derived from the optical trapezoid model in Mozambique. *Journal of Applied Remote Sensing*. 13(2), 024519. <https://doi.org/10.1117/1.JRS.13.024519>
- Markham, B., Storey, B., & Morfitt, R. Landsat-8 Sensor Characterization and Calibration. *Remote Sensing*. 7(3), 2279-2282. <https://doi.org/10.3390/rs70302279>
- Masek, J. G., Wulder M. A., Markha, B., MacCorkel, J., Crawford, C. J., Storey, J. & Jenstorm, D. T. (2020). Landsat 9: Empowering open science and applications through continuity. *Remote Sensing of Environment*. 248, 111958. <https://doi.org/10.1016/j.rse.2020.111958>
- Mingzhu, H., Kimball, J. S., Maneta, M. P., Maxwell, B. D., Moreno, A., Bequería, S., & Wu, X. (2018). Regional Crop Gross Primary Productivity and Yield

- Estimation Using Fused Landsat-MODIS Data. *Remote Sensing*. 10, 372.
<https://doi:10.3390/rs10030372>
- Moore, R. Google Earth (2017). Earth Engine User Summit 2017: Welcoming Remarks by Rebecca Moore.
<http://www.youtube.com/watch?v=5yy1EwtZmhE>
- Mutanga, O., & Kumar, L. (2019). Google Earth Engine Applications. *Remote Sensing*. 11, 591. <https://doi:10.3390/rs11050591>
- Narayanan, J., Kothari, M., Pathak, S., & Jeyseelan, A. T. (2013). Assessing Drought for Arid Regions using Satellite Derived Vegetation Index (MSAVI2) and TRMM data. *Indian Cartographer*, 32, 421-427.
- NASA. (2000). Normalized Diferrence Vegetation Index. Earth Observation.
http://earthobservatory.nasa.gov/features/MeasuringVegetation/measuring_vegetation_2.php
- NASA. (2015). Fundamentals of remote sensing.
<https://arset.gsfc.nasa.gov/webinars/fundamentals-remote-sensing>
- NASA. (2019). Landsat Overview. National Aeronautics and Space Administration. USA. Consultado en
https://www.nasa.gov/mission_pages/landsat/overview/index.html
- NASA. (2022a). MODERATE RESOLUTION IMAGING SPECTRORADIOMETER. <http://modis.gsfc.nasa.gov/data>
- NASA. (2022b). Landsat 9 Instruments. <http://www.usgs.gov/landsat-missions/landsat-9#multimedia>
- NASA. (2022c). Landsat Science. <http://landsat.gsfc.nasa.gov>
- NASA. (2022d). Landsat Science. Landsat-1.
<http://landsat.gsfc.nasa.gov/satellites/landsat-1>
- NASA. (2022e). Landsat Science. Landsat-3.
<http://landsat.gsfc.nasa.gov/satellites/landsat-4>

- Pandey, R., Goswami, S., Sarup, J., & Matin, S. (2020). The thermal-optical trapezoid model based soil moisture estimation using Landsat-8 data. *Modeling Earth Systems and Environment*. 7, 1029-1037. <https://doi.org/10.1007/s40808-020-00975-8>
- Pérez, D. J. (2007). Introducción a los Sensores Remotos – *Aplicaciones en Geología*. Universidad de Buenos Aires.
- Perilla, A. P., & Mas, J. F. (2020). Google Earth Engine (GEE): una poderosa herramienta que vincula el potencial de los datos masivos y la eficiencia del procesamiento de la nube. *Investigaciones Geográficas*. 101. <https://doi: dx.doi.org/10.14350/rig.59929>.
- Peters, A. J., Walter-Shea, E. A., Ji, L., Vina, A., Hayes, M., & Svoboda, M. D. (2002). Drought monitoring with NDVI-based standardized vegetation index. *Photogrammetric engineering and remote sensing*, 68(1), 71-75.
- Qi, J., Chehbouni, A., Huete, A. R., Kerr Y. H., & Sorooshian, S. (1994). A modified soil adjusted vegetation index. *Remote Sensing Enviroment*. 48(2), 119–126. [https://doi:10.1016/0034-4257\(94\)90134-1](https://doi:10.1016/0034-4257(94)90134-1).
- Rábago, I. (9 de septiembre del 2021). *Distrito de Riego 017, uno de los más importantes a nivel nacional*. Milenio. <http://www.milenio.com/estados/distrito-riego-017-importantes-nivel-nacional>
- Rábago, I. (7 de septiembre del 2021). *Distrito de Riego 017, de los más importantes en México: Conagua*. Milenio. [http:// www.pressreader.com](http://www.pressreader.com)
- Ramírez Barraza, B. A., González Estrada, A., Valdivia Alcalá, R., Salas González, J. M., & García Salazar, J. A. (2019). Tarifas eficientes para el agua de uso agrícola en la Comarca Lagunera. *Revista mexicana de ciencias agrícolas*. 10(3), 539-550. <https://doi.org/10.29312/remexca.v10i3.1295>

- Rouse, J. W. (1973). Monitoring the vernal advancement and retrogradation of natural vegetation [NASA/GSFCT Type II Report]. Greenbelt, MD: NASA/Goddard Space Flight Center.
- Sadeghi, M., Babaeian, E., Tuller, M., & Jones, S. B. (2017). The optical trapezoid model: A novel approach to remote sensing of soil moisture applied to Sentinel-2 and Landsat-8 observations. *Remote sensing of environment*, 198, 52-68. <https://doi.org/10.1016/j.rse.2017.05.041>
- Sazib, N., Bolten, J., & Mladenova, I. (2020). Exploring Spatiotemporal Relations between Soil Moisture, Precipitation, and Streamflow for Large Set of Watersheds Using Google Earth Engine. *Water*. 12, 1371. <https://doi:10.3390/w12051371>.
- Schmugge, T. J., Jackson, T. J., & McKim, H. L. (1980). Survey of methods for soil moisture determination. *Water Resources Research*. 16(6), 961–979. <https://doi:10.1029/wr016i006p00961>.
- Secretaría de Marina. (2009). Percepción Remota. <http://2006-2012.semarn.gob.mx/informacion-sector/ciencia/ermexs/temas-de-interes/384-percepcion-remota.html>
- Servicio de Información Agroalimentaria y Pesquera (21 de marzo de 2018). Anuario Estadístico de la Producción Agrícola <http://www.nube.siap.gob.mx/cierreagricola/>
- Servicio de Información Agroalimentaria y Pesquera (21 de septiembre de 2022). En la agricultura, los sistemas de riego son utilizados para un aprovechamiento óptimo del agua. <http://www.gob.mx/siap/articulos/en-la-agricultura-los-sistemas-de-riego-son-utilizados-para-un-aprovechamiento-optimo-del-agua?idiom=es>
- Servicio de Información Agroalimentaria y Pesquera (24 de octubre de 2016). Tipos de cultivo, estacionalidad y ciclos. <http://www.gob.mx/agricultura/es/articulos/tipos-de-cultivo-estacionalidad-y-ciclos>

- Transon, J., d'Andrimont, R., Maignard, A., & Defourny, P. (2018). Survey of Hyperspectral Earth Observation Applications From Space in the Sentinel-2 Context. *Remote Sensing*. 10(2), 57. <https://doi.org/10.3390/rs10020157>
- Vani, V., & Mandla, V. R. (2017). Comparative study of NDVI and SAVI vegetation indices in Anantapur district semi-arid areas. *International Journal of Civil Engineering and Technology*. 8(4), 559-566.
- Walker, J. P. (1999). Estimating soil moisture profile dynamics from near-surface soil moisture measurements and standard meteorological data (Doctoral dissertation, University of Newcastle).
- Walker, J. P., Willgoose, G. R., & Kalma D. J. (2004). In situ measurement of soil moisture: a comparison of techniques. *Journal of Hydrology*. 293(4), 85–99. [https://doi:10.1016/S0022-1694\(04\)00039-3](https://doi:10.1016/S0022-1694(04)00039-3)
- Wang, L., & Qu, J. J. (2009). Satellite remote sensing applications for surface soil moisture monitoring: A review. *Frontiers of Earth Science in China*, 3(2), 237-247. <https://doi:10.1007/s11707-009-0023-7>

CAPÍTULO III. ARTICULO CIENTÍFICO

RESUMEN

Estudio de caso: parte baja de la Región Hidrológica No. 36 cuenca de los ríos Nazas y Aguanaval.

En la región norte de México la escasez de agua para la agricultura ha ido en aumento a causa del cambio climático y los bajos niveles de precipitación. En el año agrícola 2019-2020 la superficie irrigada por el Distrito de Riego 017-Comarca Lagunera fue de aproximadamente 55.2 mil hectáreas, pese a eso el abandono de las prácticas agrícolas por la falta de agua continua vigente. Por ende, es crucial generar modelos que ayuden a la mejora del manejo de los recursos hídricos para proporcionar soluciones a los problemas agronómicos en la parte norte de México. En este sentido, el objetivo de la presente investigación es calibrar los modelos Óptico Trapezoidal (OPTRAM) y Térmico-Óptico Trapezoidal (TOTRAM) para estimar el contenido de humedad volumétrico del suelo a diferentes profundidades (5, 10 y 20 cm) usando índices de vegetación derivado de imágenes de satelitales Sentinel-2 y Landsat-8 utilizando Google Earth Engine (GEE). Se realizaron mediciones de áreas agrícolas seleccionadas bajo riego por gravedad y temporal por escorrentías. Los datos de contenido de humedad del suelo (Θ) in-situ fueron comparados con el contenido normalizado de humedad (W) derivado de los modelos. Los resultados obtenidos de los errores para OPTRAM utilizando imágenes Sentinel-2 fueron RMSE entre 0.033 a 0.043 $\text{cm}^3 \text{cm}^{-3}$ y R^2 entre 0.66 a 0.75, mientras que para Landsat-8 fueron RSME de 0.036 a 0.057 $\text{cm}^3 \text{cm}^{-3}$ y R^2 entre 0.70 a 0.81. Por otra parte, para TOTRAM los resultados de los errores obtenidos fueron RMSE entre 0.045 a 0.053 $\text{cm}^3 \text{cm}^{-3}$ y R^2 entre 0.62 a 0.85 con la calibración para cada modelo de las áreas de estudio.

Palabras clave: imágenes de satélite, agricultura, modelos, índices de vegetación.

Tesis de Maestría en Ciencias, Posgrado en Recursos Naturales y Medio Ambiente en Zonas Áridas, Unidad Regional Universitaria de Zonas Áridas, Universidad Autónoma Chapingo
Autor: José Rodolfo Quintana Molina
Director de Tesis: Ignacio Sánchez Cohen

ABSTRACT

Study case lower part of Hydrologic Region No. 36 of Nazas and Aguanaval rivers

In the northern region of Mexico, water scarcity for agriculture has increased due to climate change and low precipitation levels. In the 2019-2020 agricultural year, the area irrigated by the Irrigation District 017-Comarca Lagunera was approximately 55.2 thousand hectares. Despite this, the abandonment of agricultural practices due to the lack of water continues. Therefore, it is crucial to generate models that help improve the management of water resources to provide solutions to agronomic problems in the northern part of Mexico. In this sense, the objective of the present research is to calibrate the Optical Trapezoidal (OPTRAM) and Thermal-Optical Trapezoidal (TOTRAM) models to estimate the volumetric soil moisture content at different depths (5, 10, and 20 cm) using vegetation indices derived from Sentinel-2 and Landsat-8 satellite images using Google Earth Engine (GEE). Measurements were performed of selected agricultural areas under gravity irrigation and rainfed runoff. The in-situ soil moisture content (Θ) data were compared with the normalized moisture content (W) derived from the models. The results obtained from the errors for OPTRAM using Sentinel-2 images were RMSE between 0.033 to 0.043 $\text{cm}^3 \text{cm}^{-3}$ and R^2 between 0.66 to 0.75, while for Landsat-8, they were RSME from 0.036 to 0.057 $\text{cm}^3 \text{cm}^{-3}$ and R^2 between 0.70 to 0.81. On the other hand, for TOTRAM, the results of the errors obtained were RMSE between 0.045 to 0.053 $\text{cm}^3 \text{cm}^{-3}$ and R^2 between 0.62 to 0.85 with the calibration for each model of the studied areas.

Key words: satellite images, agriculture, models, vegetation indices.

Master Science Thesis, Posgraduate in Natural Resources and Environment in Arid Zones, Regional University Unit of Arid Zones, Chapingo Autonomous University.

Author: José Rodolfo Quintana Molina

Advisor: Ignacio Sánchez Cohen

1. INTRODUCCIÓN

El contenido de humedad del suelo es una variable relacionada a la salud presente en los ecosistemas e importante para los cultivos en la agricultura. El contenido de humedad del suelo se define como el almacenamiento temporal de agua en la capa superficial del suelo. Esta capa es crucial para la agricultura, ya que, controla la cantidad de agua disponible para las raíces de la planta, por lo tanto, influye en los procesos fisiológicos que afectan al crecimiento. (Lakshmi, 2012). El incremento en temperaturas y alteraciones en el medio ambiente a causa del cambio climático provoca cambios en la evapotranspiración y tendencias de la precipitación, resultando en precipitaciones impredecibles, sequías y escasez de agua (Vanino et al., 2018). Es fundamental el desarrollo de modelos que ayuden a mejorar el manejo de los recursos hídricos para la agricultura. Un buen manejo del cultivo y un preciso uso del agua para el riego es esencial para apoyar la sustentabilidad y las prácticas eficientes, con el fin de garantizar un alto rendimiento en los cultivos (Lankhankar et al., 2009).

La humedad del suelo es altamente fluctuante debido a la variabilidad espacial de sus propiedades físicas, tipo de textura, cobertura vegetal, topografía, condiciones climáticas y evapotranspiración (Santos et al., 2014). El contenido de humedad volumétrico del suelo es calculado utilizando el método gravimétrico y el método del TDR (Time Domain Reflectometry, por siglas en inglés), proporcionando una precisión cuantitativa de las mediciones en campo. La implementación de tecnologías satelitales permite evaluar la variabilidad temporal y espacial a través de los sensores remotos, estimando cuantitativamente la humedad en el suelo mediante modelos basados en observaciones de sensores ópticos y radar, logrando pasar de un alcance local, a otro regional o incluso global. Los productos de las observaciones terrestres han mostrado ser una herramienta viable para la estimación del contenido de humedad en el suelo (Zhang, 2016). Estos otorgan una alta resolución temporal y espacial de los conjuntos de datos satelitales disponibles, ayudando a la toma de decisiones y monitoreo de los cultivos a escala regional y global de las actividades agrícolas.

2. OBJETIVOS

2.1. Objetivo General

- Estimar el contenido de humedad volumétrico en el suelo ($\text{cm}^3 \text{ cm}^{-3}$) utilizando imágenes de satélite Landsat-8 y Sentinel-2 en la plataforma Google Earth Engine (GEE) como apoyo a la toma de decisiones en la agricultura de riego y temporal en la parte baja de la región hidrológica No. 36, en el estado de Durango, México.

2.2. Objetivos Específicos

- Parametrizar los bordes húmedos y secos de los modelos TOTRAM y OPTRAM derivados de imágenes de satélite Landsat 8 y Sentinel 2, en conjunto con tres diferentes índices de vegetación (NDVI, SAVI, MSAVI2).
- Extrapolar las escenas satelitales utilizando la ecuación de contenido normalizado de humedad (W) a través de la combinación de las series de tiempo de las distribuciones de los píxeles bajo riego por gravedad y agricultura de temporal con escurrimientos de los modelos OPTRAM y TOTRAM, por separado.
- Calibrar y validar el contenido de humedad normalizado de humedad (W) con los datos medidos (Θ) in-situ a 5, 10 y 20 cm de profundidad de suelo de las áreas de estudio.

3. HIPÓTESIS

- El contenido de humedad medido in-situ (Θ) tiene una relación lineal positiva con el contenido normalizado de humedad (W) obtenido a 5, 10 y 20 cm de profundidad mediante los modelos OPTRAM y TOTRAM.

4. MATERIALES Y MÉTODOS

4.1. Área de Estudio

El estudio se llevó a cabo en tres áreas agrícolas de la parte baja de la región hidrológica No. 36 del estado de Durango, áreas agrícolas dentro del Distrito de Riego-017, Comarca Lagunera ubicadas al sureste del municipio de Mapimí, Durango, México (Figura 3).




Figura 3. Mapa de ubicación del municipio de Mapimí, Durango (elaboración propia)

Las áreas de estudio cuentan con diferentes características físicas de suelo, tipo cultivo, tipo de agricultura, fecha de siembra y cosecha. El tipo de textura de suelo fue caracterizado por el método del Triángulo de Texturas de Suelo (U.S.D.A, 1977) y el método de Bouyoucos mediante muestras de suelo compuesta de cada área de estudio (Cuadro 2).

Cuadro 2. Características de las áreas agrícolas

Universidad Autónoma Chapingo (URUZA) (Figura 4)	Parcelas privadas cercanas a la URUZA (Figura 5)	Parcelas privadas agrícolas del Ejido “La Purísima” (Figura 6)
Coordenadas 103° 35' 5" longitud O, 25° 53' 4" latitud N	Coordenadas 103° 36' 12" longitud O, 25° 53' 8" latitud N	Coordenadas 103° 46' 9" longitud O, 25° 49' 57" latitud N
Cultivo sorgo forrajero de autoconsumo (URUZA)	Cultivo sorgo forrajero para venta a empresas lecheras	Monocultivo de maíz para autoconsumo.
Tipo de textura Franco-Arenoso a 0-30 cm y 30-60 cm de profundidad.	Tipo de textura Franco-Arenoso a 0-30 cm y 30-60 cm de profundidad.	Tipo de textura Franca a 0-30 cm y 30-60 cm de profundidad.
Agricultura de riego por gravedad con 7.21 ha de extensión con riegos de un aniego y cuatro auxilios entre las fechas de octubre a febrero	Agricultura de riego por gravedad con 9.05 ha de extensión con riegos de un aniego y cuatro auxilios entre las fechas de marzo a agosto	Agricultura de temporal por escurrimientos con 1.62 ha de extensión con riegos a partir de los escurrimientos de la cuenca entre las fechas de julio a noviembre



Figura 4. Parcelas Universidad Autónoma Chapingo-Unidad Regional Universitaria de Zonas Áridas (UACH-URUZA), imagen extraída de Google Earth Engine.



Figura 5. Parcelas privadas cercanías UACH-URUZA, imagen extraída de Google Earth Engine.



Figura 6. Parcelas privadas Ejido "La Purísima", imagen extraída de Google Earth Engine.

De acuerdo con la clasificación de Köppen el área Mapimí presenta un clima muy seco y extremoso semicálido con lluvias de verano. Las precipitaciones se presentan en forma de violentos aguaceros de corta duración. La precipitación tiene un promedio anual de 264.2 mm con una máxima de 513 y una mínima de 81 mm. La temperatura anual es de 20.8°C con una mínima promedio en el invierno de 3.9°C y una máxima promedio en el verano de 36.1°C (Montaña, 1988) y los suelos se caracterizan por la carencia de materia orgánica, fósforo y calcio y por tener altas concentraciones salinas y sódicas, especialmente en las áreas bajas.

El municipio de Mapimi ubicado en el Bolsón de Mapimi es área protegida que cuenta con una flora de aproximadamente 350 especies de plantas vasculares en el área, siendo las familias de las gramíneas, de forma compuestas y cactáceas las más abundantes (Instituto de Ecología, 1991). La vegetación ha sido clasificada como matorral desértico micrófilo y matorral xerófilo. En términos más específicos, se caracteriza por matorrales, pequeñas áreas de chaparral (mogotes) y pastizales, mientras que la fauna se reconoce alrededor de 270 especies de vertebrados, los cuales están conformados por anfibios, 36 reptiles, 28 mamíferos y aproximadamente 200 aves (Aguirre y Maury, 1989).

4.2. Método Gravimétrico para medición del contenido de humedad volumétrico (θ) del suelo *in situ*

El método gravimétrico es el más preciso para medir el contenido de humedad del suelo y resulta necesario para calibrar el equipo utilizado en los demás métodos. (AOAC y Horwitz, 1975). Para la extracción del suelo fue necesario el uso de una barrena de tipo Vehinmeyer de humedad del suelo modificada con un volumen total de la muestra (V_t) de 30.78768 cm³ y botes herméticos para el resguardo de la muestra extraída, junto con las Balanzas Analíticas OHAUS® y estufas para el secado de las muestras.

Para el cálculo del contenido de humedad volumétrico del suelo (θ) o el contenido de humedad gravimétrico del suelo (w) en g cm⁻³, se utilizó la Ecuación 1. (Patton, 2014):

$$w = \left(\frac{M_w}{M_s} \right) \quad (1)$$

Donde, M_w (g) es la diferencia entre el P_{sh} (g) es el peso húmedo de la muestra en gramos y P_{ss} (g) el peso seco de la muestra después de ser secada en la estufa (g), respectivamente. Y M_s (g) es el peso seco de la muestra después de ser secada en la estufa (P_{ss}) (g).

A continuación, el contenido de humedad volumétrico del suelo (θ) fue calculado mediante la Ecuación (2):

$$\theta = \frac{w\rho_b}{\rho_w} \quad (2)$$

Donde ρ_w es la densidad del agua (g cm^{-3}) y ρ_b es la densidad aparente (g cm^{-3}), y fue calculada mediante la Ecuación 3:

$$\rho_b = \frac{M_s}{V_t} \quad (3)$$

Donde, V_t es el volumen total de la muestra de suelo (cm^3).

En las parcelas de la Universidad Autónoma Chapingo-Unidad Regional Universitaria de Zonas Áridas (UACH-URUZA), se realizaron 118 mediciones aleatorias de 5, 10 y 20 cm de profundidad de 13 fechas distintas en las que la orbita de los satelites Landsat 8 y Sentinel 2, sobrevolaron el area de estudio (Cuadro 3).

Cuadro 3. Fechas de muestreo de las parcelas de la Universidad Autónoma Chapingo-Unidad Regional Universitaria de Zonas Áridas (URUZA)

Satélites	Fecha
Landsat 8	22 de marzo del 2022
Sentinel 2B	23 de marzo del 2022
Sentinel 2A	31 de marzo del 2022
Sentinel 2B	2 de abril del 2022
Sentinel 2B	5 de abril del 2022
Landsat 8 y Sentinel 2A	7 de abril del 2022
Sentinel 2B	15 de abril del 2022
Sentinel 2A	17 de abril del 2022
Landsat 8	10 de junio del 2022
Sentinel 2B	14 de junio del 2022
Sentinel 2B	21 de junio del 2022
Landsat 8 y Sentinel 2A	26 de junio del 2022
Sentinel 2B	01 de junio del 2022

Adicionalmente, en las parcelas privadas agrícolas en las cercanías de la Universidad Autónoma Chapingo-Unidad Regional Universitaria de Zonas Áridas (UACH-URUZA) se realizaron 92 mediciones aleatorias de 5, 10 y 20 cm de profundidad de 6 fechas distintas en las que la órbita de los satélites Landsat 8 y Sentinel 2, sobrevolaron el área de estudio (Cuadro 4).

Cuadro 4. Fechas de muestreo de las parcelas privadas agrícolas en las cercanías de la Universidad Autónoma Chapingo-Unidad Regional Universitaria de Zonas Áridas (URUZA)

Satélites	Fechas
Landsat 8	12 de julio del 2022
Sentinel 2B	14 de julio del 2022
Sentinel 2A	16 de julio del 2022
Sentinel 2B	24 de julio 2022
Landsat 8	28 de julio del 2022
Sentinel 2B	31 de julio del 2022

4.3. Método Time Domain Reflectometry (TDR) para medición del contenido de humedad volumétrico del suelo *in situ*

Para las mediciones de contenido de humedad volumétrico del suelo ($\text{cm}^3 \text{cm}^{-3}$) se utilizó el Método del TDR, con ayuda del sensor 5TE para contenido de humedad y el ProCheck Versión 4 de la marca Decagon Devices® para el almacenamiento de los datos de contenido de humedad del suelo para las parcelas privadas del Ejido “La Purísima”.

Se realizaron 58 mediciones aleatorias a 5, 10 y 20 cm de profundidad de 6 fechas distintas en el momento que la órbita de los satélites Landsat 8 y Sentinel 2, sobrevolaron el área de estudio (Cuadro 5).

Cuadro 5. Fechas de muestro de las parcelas privadas del Ejido “La Purísima”

Satélite	Fecha
Sentinel 2B	16 de febrero del 2022
Sentinel 2B	21 de febrero del 2022
Sentinel 2A	26 de febrero del 2022
Landsat 8 y Sentinel 2B	06 de marzo del 2022
Sentinel 2A	08 de marzo del 2022
Sentinel 2B	11 de marzo del 2022

4.4. Análisis de imágenes satelitales

4.4.1. Índice de Vegetación de Diferencia Normalizada (NDVI)

El NDVI fue calculado mediante el uso de las bandas espectrales del infrarrojo cercano y las bandas espectrales rojas (Rouse, 1973), con la Ecuación 4:

$$NDVI = \frac{\text{Banda NIR} - \text{Banda Roja}}{\text{Banda NIR} + \text{Banda Roja}} \quad (4)$$

4.4.2. Índice de Vegetación Ajustado al Suelo (SAVI)

El SAVI fue calculado mediante el uso de las bandas espectrales del infrarrojo cercano (NIR) y las bandas espectrales rojas. Adicionalmente, se incorpora un factor de ajuste del suelo “L” con valor de 0.5 en el denominador de la ecuación de NDVI (Huete, 1988), resultando la Ecuación 5:

$$SAVI = \left(\frac{\text{Banda NIR} - \text{Banda Roja}}{\text{Banda NIR} + \text{Banda Roja} + L} \right) (1 + L) \quad (5)$$

4.4.3. Índice de Vegetación Modificado Ajustado al Suelo (MSAVI2)

El MSAVI2 fue calculado mediante el uso de las bandas espectrales del infrarrojo cercano y las bandas espectrales rojas (Qi, 1994), con la Ecuación 6:

$$MSAVI2 = \frac{(2 * \text{Banda NIR} + 1) - \sqrt{(2 * \text{Banda NIR} + 1)^2 - 8(\text{Banda NIR} - \text{Banda Roja})}}{2} \quad (6)$$

4.4.4. Temperatura de la Superficie Terrestre (LST) mediante el algoritmo Mono-canal utilizando imágenes de satélite

Para el cálculo de la LST se ha utilizado el brillo de la temperatura en el sensor (BT) en grados Kelvin (°K), el cual está disponible en el catálogo de datos satelitales de GEE con el nombre de “Top of Atmosphere (TOA)- Reflectance” (Chander et al., 2009).

4.4.4.1. Método para la Corrección de la Emisividad

La emisividad, ha sido desarrollada e incluida en los catálogos de Landsat disponibles dentro GEE. En los productos de las Colecciones 2/ Tier1 (GEE, 2022) de los productos ST (ST_EMIS) desarrollada a partir del algoritmo single-channel y desarrollado por The Rochester Institute of Technology (RIT) and National Aeronautics and Space Administration (NASA) Jet Propulsion Laboratory (JPL) .

4.4.4.2. Estimación la Temperatura de la Superficie Terrestre (LST)

La LST fue calculada mediante la combinación del brillo en el sensor (BT) convertida a grados Celsius (°C) y la emisividad de la superficie terrestre (Stathopoulou y Cartalis, 2007), acorde a la Ecuación (7):

$$T_s = \frac{BT}{\left\{1 + \left[\left(\frac{\lambda BT}{\rho}\right) \ln \epsilon_\lambda\right]\right\}} \quad (7)$$

En donde T_s es la LST en grados Celsius ($^{\circ}\text{C}$), BT es la Temperatura de Brillo en el sensor, λ es la longitud de onda de la radiación emitida (nm que deben ser convertidos a m) (Markhan y Baker, 1985), ε_λ es la emisividad, ρ (Constante de Rydberg) mediante la Ecuación (8):

$$\rho = h \frac{c}{\sigma} = 1.438 \times 10^{-2} \text{m}^{\circ}\text{K} \quad (8)$$

En donde σ es la constante de Boltzmann ($1.38 \times 10^{-23} \text{ J}/^{\circ}\text{K}$), h es la constante de Planck ($6.626 \times 10^{-34} \text{ J s}$), y “ c ” es la velocidad de la luz ($2.998 \times 10^8 \text{ m.s}^{-1}$).

4.4.5. Algoritmo de la NASA para la Recuperación de la Temperatura de la Superficie Terrestre (LST_{NASA})

Para la estimación de la LST_{NASA} se implementó el algoritmo desarrollado para la banda Térmica (ST_{B10}) mediante la multiplicación y suma de aditivos (Ecuación 9) de los productos de las Colecciones 2/ Tier1 (GEE, 2022) creados a partir del algoritmo single-channel y desarrollado por The Rochester Institute of Technology (RIT) and National Aeronautics and Space Administration (NASA) Jet Propulsion Laboratory (JPL) .

$$LST_{\text{NASA}} = (ST_{\text{B10}}) * (0.00341802) + (149) \quad (9)$$

Esta última fórmula para la retribución de la LST fue considerada para comparar las diferencias y mejoras entre ambos algoritmos, el Mono-canal y la banda 10 de los productos de Colecciones 2/ Tier1 creados a partir del algoritmo single-channel. Diferencias significativas entre ambos se observa en el número de variables necesarias para el cálculo de la LST para el algoritmo del Mono-canal. A diferencia de la desarrollada por los productos para el cálculo de la LST_{NASA} , en la que para su retribución únicamente son necesarios la multiplicación de un aditivo y la resta de otro, sin la dependencia de variables para su cálculo.

4.5. Modelos para la estimación de la humedad del suelo con imágenes satelitales

4.5.1. Modelo Trapezoidal Térmico-Óptico (TOTRAM)

El Modelo Trapezoidal Térmico-Óptico (TOTRAM), está basado en la relación de la distribución dentro del espacio entre la temperatura de la superficie terrestre (LST) y los índices de vegetación (IV) (Nemani, 1993), mostrado en la Figura 7.




Figura 7. Parámetros del Modelo Trapezoidal Térmico-Óptico (elaboración propia)

Donde la relación lineal entre la humedad del suelo superficial (θ) y la LST es obtenida mediante la Ecuación 10:

$$W = \frac{\theta - \theta_d}{\theta_w - \theta_d} = \frac{LST_d - LST}{LST_d - LST_w} \quad (10)$$

Donde, W ($\text{cm}^3 \text{ cm}^{-3}$) es el contenido normalizado de humedad en el suelo mediante el mínimo local de contenido de humedad del suelo seco (θ_d) y el mínimo local de contenido de humedad de suelo húmedo (θ_w). Mientras que, los términos LST_d y la LST_w son las temperaturas de la superficie terrestre en los suelos secos y húmedos, respectivamente.

LST_d y la LST_w son obtenidos mediante la relación de la LST-IV para un área específica. La parte alta considerada como el borde seco Ecuación 11 y la parte baja considerada como el borde húmedo Ecuación 12 del trapecoide. Son utilizados para resolver la LST_d y la LST_w dentro del IV.

$$LST_d = i_d + s_d \text{ Índice de Vegetación} \quad (11)$$

$$LST_w = i_w + s_w \text{ Índice de Vegetación} \quad (12)$$

Mediante la combinación de las Ecuaciones 10,11 y 12, la humedad del suelo para cada píxel fue estimada como una función de la relación de la LST y el IV con la Ecuación 13:

$$W = \frac{i_d + i_d \text{ Índice de Vegetación} - LST}{i_d - i_w + (s_d - s_w) \text{ Índice de Vegetación}} \quad (13)$$

4.5.2. Modelo Trapezoidal Óptico (OPTRAM)

El Modelo Trapezoidal OPTRAM, está basado en el concepto de remplazar la variable de la LST en el modelo TOTRAM con una medida para la humedad del suelo en el dominio óptico. Mediante la relación lineal de la STR-IV, como se muestra en la Figura 8 (Sadeghi et al., 2017).




Figura 8. Parámetros del Modelo Trapezoidal Óptico (elaboración propia)

Desarrollado por Sadeghi et al., (2017) como un modelo físico para la relación lineal entre el contenido de humedad superficial y la banda del infrarrojo de onda corta (SWIR) transformada en reflectancia (STR), mediante la Ecuación 14:

$$W = \frac{\theta - \theta_d}{\theta_w - \theta_d} = \frac{STR - STR_d}{STR_w - STR_d} \quad (14)$$

Donde, STR es la SWIR transformada a reflectancia y, STR_d y STR_w son las STR mínimo y máximo local del contenido de humedad en el suelo seco (θ_d) y húmedo (θ_w). La STR está relacionada a la reflectancia de la SWIR (R_{SWIR}), mediante la Ecuación 15:

$$STR = \frac{(1 - R_{SWIR})^2}{2R_{SWIR}} \quad (15)$$

Donde, STR_d y la STR_w fueron obtenidos mediante la relación de la STR-IV para una específica área. La parte alta considerada como el borde húmedo (Ecuación 16) y la parte baja considerada como el borde seco (Ecuación 17) del trapezoide. Y fueron utilizados para resolver la STR_d y la STR_w dentro del IV.

$$STR_w = i_w + s_w \text{ Índice de Vegetación} \quad (16)$$

$$STR_d = i_d + s_d \text{ Índice de Vegetación} \quad (17)$$

Mediante la combinación de las Ecuaciones 14, 16 y 17, fue estimada la humedad en el suelo para cada píxel como una función de la STR y el IV, con la Ecuación (18):

$$W = \frac{i_d + i_d \text{ Índice de Vegetación} - STR}{i_d - i_w + (s_d - s_w) \text{ Índice de Vegetación}} \quad (18)$$

4.6. Análisis Estadístico

4.6.1. Error Cuadrático Medio de la Raíz (RMSE)

La capacidad predictiva de los modelos obtenidos fue estimada mediante los parámetros estadísticos ordinarios. Así, el error cuadrático medio de la raíz fue calculado mediante la Ecuación 19:

$$RMSE = \left(\frac{1}{n} \sum_{i=1}^n (i, \text{estimados} - i, \text{medidos}) \right)^{1/2} \quad (19)$$

Donde, n es el número de datos pares y la diferencia entre los valores i -estimados y los valores i -medidos (Gil y Zarate de Lara, 1984).

Esta prueba provee información sobre el rendimiento a corto plazo de las correlaciones al permitir una comparación término por término de la desviación real entre la calculada y el valor medido. Cuanto menor sea el valor, mejor será el rendimiento del modelo. Sin embargo, algunos errores grandes en la suma pueden producir un incremento significativo en el RMSE.

4.6.2. Coeficiente de Correlación de Pearson (R) y R^2

Es un índice que mide el grado de covariación entre distintas variables relacionadas linealmente. Sus valores absolutos se encuentran entre 0 y 1. Esto si se tienen dos variables X e Y, mediante la Ecuación 20:

$$0 \leq R = \frac{\sigma_{XY}^2}{\sigma_X^2 \sigma_Y^2} \leq 1 \quad (20)$$

Donde, σ_{XY}^2 es la covarianza de los valores i -medidos (X) y i -estimados (Y), σ_X^2 como la varianza de los valores i -medidos (X) y σ_Y^2 como la varianza de los valores i -estimados (Benesty et al., 2009).

El coeficiente de relación lineal R^2 se calculó a partir del coeficiente de correlación de Pearson, mediante la Ecuación 21:

$$R^2 = (\text{Coeficiente de Pearson})^2 \quad (21)$$

Donde R es el coeficiente de correlación de Pearson.

5. RESULTADOS Y DISCUSIÓN

5.1. Distribución de la relación de los pixeles del modelo OPTRAM utilizando imágenes de satélite Landsat-8 y Sentinel-2

Se observó que las distribuciones de la relación de la STR y los índices de vegetación NDVI, SAVI y MSAVI2 mostraron tener la misma distribución para ambas misiones. Además, los bordes húmedos y secos presentaron el mismo patrón curvo desde el comienzo hasta el final de cada borde (Figura 9). Adicionalmente, se muestran las ecuaciones obtenidas de cada borde húmedo y seco de las distribuciones de los pixeles (Cuadro 6).




Figura 9. Distribuciones de la relación de los pixeles de STR en conjunto con los índices de vegetación NDVI, SAVI y MSAVI2 del Modelo OPTRAM, y los bordes húmedos (líneas curvas azules) y bordes secos (lineales curvas rojas).

Cuadro 6. Mejores ecuaciones obtenidas para los bordes húmedos (STR_w) y secos (STR_d) para el modelo OPTRAM

Landsat-8		
	Bordes Húmedos	Bordes Secos
NDVI	$STR_w = -318.38NDVI^6 + 924.35NDVI^5 - 1012.4NDVI^4 + 541.32NDVI^3 - 141.59NDVI^2 + 18.16NDVI + 0.4325$	$STR_d = 11.792NDVI^3 - 10.195NDVI^2 + 4.2675NDVI - 0.1949$
SAVI	$STR_w = -2906.5SAVI^6 + 5874.1SAVI^5 - 4575.3SAVI^4 + 1760.9SAVI^3 - 342.25SAVI^2 + 33.231SAVI + 0.0648$	$STR_d = 35.754SAVI^3 - 31.486SAVI^2 + 10.381SAVI - 0.7013$
MSAVI2	$STR_w = -650.87MSAVI2^6 + 1365.1MSAVI2^5 - 1136.4MSAVI2^4 + 495.61MSAVI2^3 - 108.31MSAVI2^2 + 12.473MSAVI2 + 0.8403$	$STR_d = 11.978x^3 - 7.0858x^2 + 3.2215x - 0.1144$
Sentinel-2		
	Bordes Húmedos	Bordes Secos
NDVI	$STR_w = 274.49NDVI^6 - 686.76NDVI^5 + 675.38NDVI^4 - 323.06NDVI^3 + 80.002NDVI^2 - 8.5951NDVI + 2.0712$	$STR_d = 26.568NDVI^5 - 44.046NDVI^4 + 25.083NDVI^3 - 3.3776NDVI^2 + 0.3093NDVI + 0.1686$
SAVI	$STR_w = 154.98SAVI^5 - 201.9SAVI^4 + 101.78SAVI^3 - 18.166SAVI^2 + 2.0873x + 1.61$	$STR_d = 85.568SAVI^5 - 128.83SAVI^4 + 70.095SAVI^3 - 14.705SAVI^2 + 2.0199SAVIx + 0.0293$
MSAVI2	$STR_w = 952.8MSAVI2^6 - 2026.9MSAVI2^5 + 1698.8MSAVI2^4 - 704.93MSAVI2^3 + 156.02MSAVI2^2 - 15.735MSAVI2 + 2.2834$	$STR_d = 31.199MSAVI2^5 - 52.147MSAVI2^4 + 33.236MSAVI2^3 - 7.6363MSAVI2^2 + 1.6994MSAVI2 + 0.0281$

5.2. Distribución de la relación de los pixeles del modelo TOTRAM utilizando imágenes de satélite Landsat-8

Se observó que las distribuciones de las relaciones LST y LST_{NASA}, junto con los índices de vegetación NDVI, SAVI y MSAVI2 mostraron tener la misma distribución para la misión Landsat-8 (Figura 10). Sin embargo, los bordes secos mostraron diferencias entre la LST y la LST_{NASA}. A diferencia del borde húmedo el patrón fue el mismo para ambas LST. Adicionalmente, se muestran las ecuaciones obtenidas de cada borde húmedo y seco de las distribuciones de los pixeles (Cuadro. 7)




Figura 10. Distribuciones de la relación de los pixeles de LST/LST_{NASA} en conjunto con los índices de vegetación NDVI, SAVI y MSAVI2 del Modelo TOTRAM, y los bordes húmedos (líneas rectas azules) y bordes secos (lineales rectas rojas).

Cuadro 7. Mejores ecuaciones obtenidas para los bordes húmedos (LST_{NASA}/LST_w) y secos (LST_{NASA}/LST_d) para el modelo TOTRAM

Landsat-8		
LST	Bordes Húmedos	Bordes Secos
NDVI	$LST_w = 2.7322NDVI + 13.672$	$LST_d = -5.4645NDVI + 50.656$
SAVI	$LST_w = 3.1746SAVI + 13.683$	$LST_d = -6.3492SAVI + 50.635$
MSAVI2	$LST_w = 2.9412MSAVI2 + 13.706$	$LST_d = -5.8824MSAVI2 + 50.588$

LST_{NASA}	Bordes Húmedos	Bordes Secos
NDVI	$LST_{NASA_w} = 0.6849NDVI + 15.918$	$LST_{NASA_d} = 5.4795NDVI + 55.342$
SAVI	$LST_{NASA_w} = 0.7937SAVI + 15.921$	$LST_{NASA_d} = 6.3492SAVI + 55.365$
MSAVI2	$LST_{NASA_w} = 0.7353MSAVI2 + 15.926$	$LST_{NASA_d} = 5.8824MSAVI2 + 55.412$

5.3. Calibraciones de los datos medidos de humedad in situ (Θ) comparados con estimados de contenido normalizado de humedad (W) a diferentes profundidades.

Las gráficas generadas sin calibraciones (no mostradas aquí) mostraron como OPTRAM (Sentinel-2 y Landsat-8) y la relación $LTS_{NASA-IV}$ (Landsat-8) sobrestiman más del doble los datos in-situ a 20 cm para la agricultura de temporal. Por ende, las calibraciones excluyen los datos medidos de la agricultura de temporal en esos dos casos, pero no para la relación $LST-IV$ en TOTRAM. Las validaciones entre la Θ y W , permite conocer la relación lineal más precisa entre cada modelo e índice de vegetación a diferentes profundidades. De igual manera, la comparación, permite observar que relación modelo e IV es más apropiado para diferentes rangos entre los IV, temperaturas de la superficie terrestre (LST) y reflectancia de la banda del infrarrojo de onda corta (STR), características climatológicas, manejo de suelo, fecha de siembra de los cultivos, tipo de agricultura y riego.

5.3.1. Resultados modelo OPTRAM-NDVI

El modelo OPTRAM a través de la relación del índice de vegetación NDVI a diferentes profundidades mostro tener una precisión buena entre los rangos de contenido de humedad volumétrico en el suelo de 0.1 a $0.3 \text{ cm}^3 \text{ cm}^{-3}$ para ambas misiones. A diferencia de contener diferente tamaño de muestra donde el promedio de la misión Landsat fue de 41 unidades, mientras que el tamaño de muestra de la misión Sentinel fue de 102 unidades (Figura 11).

Los resultados obtenidos (Cuadro 8) para la misión Landsat-8 fueron R^2 entre 0.7964 a 0.8112; RMSE entre 0.0444 a 0.0571 $\text{cm}^3 \text{cm}^{-3}$ y Sentinel-2 fueron R^2 entre 0.658 a 0.7366; RMSE de entre 0.0334 a 0.0378 $\text{cm}^3 \text{cm}^{-3}$.




Figura 11. Datos de humedad in situ (Θ) comparados con la ecuación de contenido normalizado de humedad (W) modelo OPTRAM-NDVI a 5, 10 y 20 cm de profundidad

Para ambas misiones, los resultados más precisos se obtuvieron a 10 cm de profundidad. Por otra parte, Sentinel-2 presento subestimación de 0.1 a 0.15 $\text{cm}^3 \text{cm}^{-3}$, homogeneidad de 0.15 a 0.21 $\text{cm}^3 \text{cm}^{-3}$ entre sí y, sobrestimación de 0.21 a 0.25 $\text{cm}^3 \text{cm}^{-3}$. Así mismo, Landsat-8 presento homogeneidad de 0.13 a 0.25 $\text{cm}^3 \text{cm}^{-3}$ y sobrestimación de 0.25 a 0.3 $\text{cm}^3 \text{cm}^{-3}$. Por lo que, Sentinel-2 a 10 cm de profundidad mostro los valores más precisos para la estimación de la humedad del suelo entre las 2 misiones. Posiblemente asociada al tamaño de píxel observado (10 m), resolución temporal y el tamaño de muestra.

Cuadro 8. Resultados modelo OPTRAM-NDVI a diferentes profundidades

	Sentinel-2			Landsat-8		
	R^2	RMSE	n	R^2	RMSE	n
5 cm	0.658	0.0334	104	0.7964	0.0571	39
10 cm	0.7107	0.035	103	0.7696	0.0444	43
20 cm	0.7366	0.0378	100	0.8112	0.0465	43

5.3.2. Resultados modelo OPTRAM-SAVI

El modelo OPTRAM-SAVI mostró tener una precisión buena entre los rangos de contenido de humedad del suelo de 0.1 a 0.25 $\text{cm}^3 \text{cm}^{-3}$ para ambas misiones. A diferencia de contener diferente tamaño de muestra, donde el promedio de la misión Landsat fue de 39 unidades, mientras que el tamaño de muestra de la misión Sentinel fue de 102 unidades (Figura. 12).

Los resultados obtenidos (Cuadro 9) para la misión Sentinel-2 de R^2 fueron entre 0.6652 a 0.7469; RMSE entre 0.0362 a 0.0369 $\text{cm}^3 \text{cm}^{-3}$. Para la misión Landsat-8 fueron R^2 entre 0.7358 a 0.8062; RMSE entre 0.0359 a 0.0549 $\text{cm}^3 \text{cm}^{-3}$. La misión Sentinel-2 presento los valores más precisos a 20 cm de profundidad; así también, observó una subestimación entre el rango de 0.1 a 0.14 $\text{cm}^3 \text{cm}^{-3}$, homogeneidad de 0.14 a 0.22 $\text{cm}^3 \text{cm}^{-3}$ y sobrestimación de 0.22 a 0.25 $\text{cm}^3 \text{cm}^{-3}$. Así mismo, Landsat-8 presento a 5 cm de profundidad la mejor precisión

mostrando homogeneidad en el rango de entre 0.1 a 0.25 $\text{cm}^3 \text{cm}^{-3}$ en el contenido de humedad del suelo.




Figura 12. Datos de humedad in situ (Θ) comparados con la ecuación de contenido normalizado de humedad (W) modelo OPTRAM-SAVI a 5, 10 y 20 cm de profundidad

Cuadro 9. Resultados modelo OPTRAM-SAVI a diferentes profundidades

	Sentinel-2			Landsat-8		
	R ²	RMSE	n	R ²	RMSE	n
5 cm	0.6685	0.0369	107	0.8045	0.0359	39
10 cm	0.6652	0.0368	102	0.8062	0.0423	37
20 cm	0.7469	0.0362	96	0.7358	0.0549	40

5.3.3. Resultados modelo OPTRAM-MSAVI2

El modelo OPTRAM a través de la relación del índice de vegetación MSAVI2 a diferentes profundidades mostro tener una precisión buena entre los rangos de contenido de humedad del suelo de 0.1 a 0.25 cm³ cm⁻³ para ambas misiones, Landsat-8 con 40 unidades y Sentinel-2 con 104 unidades (Figura 13).

Los resultados obtenidos (Cuadro 10) para la misión Sentinel-2 fueron R² entre 0.6163 a 0.6973; RMSE entre 0.0339 a 0.0434 cm³ cm⁻³. Landsat-8 obtuvo R² entre 0.7004 a 0.7647; RMSE entre 0.0424 a 0.0533 cm³ cm⁻³. La misión Sentinel-2 obtuvo los valores más precisos a 20 cm de profundidad, se observó subestimación entre el rango de 0.1 a 0.14 cm³ cm⁻³, y homogeneidad de 0.14 a 0.22 cm³ cm⁻³ entre sí. Así mismo, Landsat-8 mostró a 20 cm de profundidad la mejor precisión mostrando subestimación entre 0.1 a 0.3 cm³ cm⁻³ en el contenido de humedad en el suelo.

Cuadro 10. Resultados modelo OPTRAM-MSAV2 a diferentes profundidades

	Sentinel-2			Landsat-8		
	R ²	RMSE	n	R ²	RMSE	n
5 cm	0.6617	0.0434	105	0.7067	0.0533	40
10 cm	0.6163	0.0365	107	0.7004	0.0424	40
20 cm	0.6973	0.0339	102	0.7647	0.0428	41




Figura 13. Datos de humedad in situ (Θ) comparados con la ecuación de contenido normalizado de humedad (W) modelo OPTRAM-MSAVI2 a 5, 10 y 20 cm de profundidad.

5.3.4. Resultados modelo TOTRAM-NDVI

El modelo TOTRAM a través de la relación del índice de vegetación NDVI a diferentes profundidades presento una precisión buena entre los rangos de

contenido de humedad del suelo de 0.1 a 0.45 $\text{cm}^3 \text{cm}^{-3}$ para la misión Landsat-8, con tamaños de muestra promedio de 39 (LST-NDVI) y 35 unidades (LST_{NASA}-NDVI) (Figura. 14).




Figura 14. Datos de humedad in situ (Θ) comparados con la ecuación de contenido normalizado de humedad (W) modelo TOTRAM-NDVI a 5, 10 y 20 cm de profundidad

Los resultados obtenidos (Cuadro 11) para la relación LST-NDVI mostraron una R^2 entre 0.7794 a 0.8404; RMSE de 0.0485 a 0.0514 $\text{cm}^3 \text{cm}^{-3}$. Para la relación

LST_{NASA}-NDVI, se obtuvieron R^2 entre 0.6513 a 0.7658; RMSE entre 0.0484 a 0.0503 $\text{cm}^3 \text{cm}^{-3}$. La primera relación obtuvo los valores más precisos a 20 cm de profundidad, se observó subestimación entre el rango de 0.1 a 0.23 $\text{cm}^3 \text{cm}^{-3}$, subestimación de 0.3 a 0.38 $\text{cm}^3 \text{cm}^{-3}$ y homogeneidad de 0.38 a 0.45 $\text{cm}^3 \text{cm}^{-3}$ entre sí. Así mismo, la segunda relación mostró a 10 cm de profundidad la mejor precisión mostrando sobrestimación de 0.14 a 0.21 $\text{cm}^3 \text{cm}^{-3}$, subestimación de 0.25 a 0.37 $\text{cm}^3 \text{cm}^{-3}$, y homogeneidad de 0.37 a 0.45 $\text{cm}^3 \text{cm}^{-3}$ en el contenido de humedad del suelo.

Cuadro 11. Resultados modelo TOTRAM-NDVI a diferentes profundidades de la misión Landsat-8

	LST-NDVI			LST _{NASA} -NDVI		
	R^2	RMSE	n	R^2	RMSE	n
5 cm	0.8183	0.0514	32	0.7658	0.0502	29
10 cm	0.7794	0.0505	43	0.7203	0.0484	39
20 cm	0.8404	0.0485	42	0.6513	0.0503	38

5.3.5. Resultados modelo TOTRAM-SAVI

El modelo TOTRAM a través de la relación del índice de vegetación SAVI a diferentes profundidades mostro tener una precisión buena entre los rangos de contenido de humedad volumétrico en el suelo de 0.1 a 0.45 $\text{cm}^3 \text{cm}^{-3}$ para la misión Landsat-8, con tamaños de muestra promedio de 38 unidades para la relación LST-SAVI y 36 unidades para la relación LST_{NASA}-SAVI (Figura 15).

Los resultados obtenidos (Cuadro 12) para la relación LST-SAVI fueron R^2 0.8279 a 0.8488; RMSE entre 0.0461 a 0.0507 $\text{cm}^3 \text{cm}^{-3}$. Para la relación LST_{NASA}-SAVI, se obtuvieron R^2 de 0.6227 a 0.7581; RMSE de entre 0.0495 a 0.0528 $\text{cm}^3 \text{cm}^{-3}$. La primera relación obtuvo los valores más precisos a 10 cm de profundidad, observando sobrestimación de 0.1 a 0.21 $\text{cm}^3 \text{cm}^{-3}$, subestimación de 0.25 a 0.3 $\text{cm}^3 \text{cm}^{-3}$ y homogeneidad de 0.31 a 0.45 $\text{cm}^3 \text{cm}^{-3}$ entre sí.




Figura 15. Datos de humedad in situ (Θ) comparados con la ecuación de contenido normalizado de humedad (W) modelo TOTRAM-SAVI a 5, 10 y 20 cm de profundidad

Así mismo, la segunda relación mostró a 10 cm de profundidad la mejor precisión mostrando sobrestimación de 0.15 a 0.20 $\text{cm}^3 \text{cm}^{-3}$, subestimación de 0.26 a 0.37

$\text{cm}^3 \text{ cm}^{-3}$, y homogeneidad de 0.37 a $0.45 \text{ cm}^3 \text{ cm}^{-3}$ en el contenido de humedad en el suelo.

Cuadro 12. Resultados modelo TOTRAM-SAVI a diferentes profundidades de la misión Landsat-8

	LST-SAVI			LST _{NASA} -SAVI		
	R ²	RMSE	n	R ²	RMSE	n
5 cm	0.8279	0.0507	32	0.7581	0.0513	29
10 cm	0.8488	0.0461	40	0.7139	0.0495	39
20 cm	0.8469	0.0485	42	0.6227	0.0528	39

5.3.6. Resultados modelo TOTRAM-MSAVI2

El modelo TOTRAM con MSAVI2 presento una precisión buena entre los rangos de contenido de humedad del suelo de 0.1 a $0.45 \text{ cm}^3 \text{ cm}^{-3}$ para la misión Landsat-8, con tamaños de muestra con promedio de 38 unidades para la relación LST-MSAVI2 y 37 unidades para LST_{NASA}-MSAVI2 (Figura 16).

Los resultados obtenidos (Cuadro 13) para LST-MSAVI2 fueron R² entre 0.8255 a 0.8511; RMSE entre 0.0467 a $0.0495 \text{ cm}^3 \text{ cm}^{-3}$. Para la relación LST_{NASA}-MSAVI2, se obtuvieron R² entre 0.7217 a 0.7694; RMSE entre 0.045 a 0.0487 $\text{cm}^3 \text{ cm}^{-3}$.

Cuadro 13. Resultados modelo TOTRAM-MSAVI2 a diferentes profundidades de la misión Landsat-8

	LST-MSAVI2			LST _{NASA} -MSAVI2		
	R ²	RMSE	n	R ²	RMSE	n
5 cm	0.8255	0.0484	31	0.7694	0.0487	30
10 cm	0.8511	0.0467	40	0.7457	0.045	41
20 cm	0.8475	0.0495	42	0.7217	0.0468	41

La primera relación obtuvo los valores más precisos a 10 cm de profundidad, observando sobrestimación de 0.1 a 0.2 $\text{cm}^3 \text{cm}^{-3}$, subestimación de 0.26 a 0.3 $\text{cm}^3 \text{cm}^{-3}$ y homogeneidad de 0.32 a 0.45 $\text{cm}^3 \text{cm}^{-3}$ entre sí. Así mismo, la segunda relación mostró a 10 cm de profundidad la mejor precisión mostrando sobrestimación de 0.1 a 0.21 $\text{cm}^3 \text{cm}^{-3}$, subestimación de 0.26 a 0.3 $\text{cm}^3 \text{cm}^{-3}$, y homogeneidad de 0.31 a 0.45 $\text{cm}^3 \text{cm}^{-3}$ de humedad del suelo.




Figura 16. Datos de humedad in situ (Θ) comparados con la ecuación de contenido normalizado de humedad (W) modelo TOTRAM-MSAVI2 a 5, 10 y 20 cm de profundidad

6. DISCUSIÓN

Estudios para la estimación de la humedad del suelo a diferentes profundidades con suelo desnudo, semidesnudo y cubierto por vegetación, en general han sido desarrollados. Hassanpour et al., (2020) compara OPTRAM a dos profundidades (humedad superficial y en la raíz) a través de la parametrización de bordes lineales y no lineales utilizando tres distribuciones de píxeles diferentes (suelo desnudo, suelo con cobertura vegetal y combinando). En este caso, el mayor R^2 fue 0.803 y menor RMSE fue $0.030 \text{ cm}^3 \text{ cm}^{-3}$, obtenido en la humedad superficial del suelo utilizando bordes no lineales a partir de las distribuciones de píxeles de los suelos desnudos. Sin embargo, la combinación de la distribución de suelos con cobertura vegetal y desnudos obtuvo un resultado ligeramente menor en R^2 de 0.75 y mayor en RMSE de $0.036 \text{ cm}^3 \text{ cm}^{-3}$, los bordes parametrizados y las fechas escogidas para el desarrollo de las distribuciones de los píxeles mostraron tener una precisión buena para la estimación de la humedad superficial del suelo entre los 0 y 5 cm de profundidad. En estudios hidrológicos, Sadeghi (2017) compara el funcionamiento entre OPTRAM y TOTRAM para dos cuencas en Arizona y Oklahoma, Estados Unidos de Norteamérica, revela que para las comparaciones diarias las RMSE de TOTRAM son ligeramente mejores que las de OPTRAM en la mayoría de los casos. Debido a que TOTRAM fue capaz de capturar la variación temporal de la humedad media del suelo en las cuencas, pero fallo en capturar la variabilidad espacial detallada de la humedad del suelo. Indicando la fuerte relación entre el contenido de humedad volumétrico del suelo (θ) y la LST, destacando la dependencia temporal debido a los cambios en los parámetros atmosféricos ambientales. Concluyendo la viabilidad de una calibración universal para OPTRAM, pero no para TOTRAM.

En este estudio, las series de tiempo de las distribuciones de los píxeles para OPTRAM y TOTRAM a diferentes profundidades presentaron estimaciones de humedad del suelo precisas para rangos bajos en suelos desnudos secos, húmedos y con cobertura vegetal. La diferencia entre los modelos se centra en los rangos de los IV, STR y LST. El modelo OPTRAM es susceptible a diferentes

rangos entre la STR y IV a partir de los parámetros establecidos para cada modelo, mostrando sobrestimaciones debido al incremento de la STR por encima de 0.8 en IV bajos y 1.6 en IV relativamente altos. Por otra parte, TOTRAM es susceptible a los niveles bajos de la LST, menores a 38 °C para LST y 46 °C para LST_{NASA} para niveles bajos de IV, sobrestimando la humedad del suelo en la presencia de temperaturas por debajo de los niveles observados. Existen diferencias significativas entre OPTRAM y TOTRAM para la estimación de la humedad del suelo, donde OPTRAM fue más preciso para suelos con rangos de IV menores a 0.5 y TOTRAM más preciso para rangos de IV mayores de 0.5. Las posibles razones para este estudio podrían recaer en las distribuciones de las series de tiempo, las parametrizaciones de los bordes, la exposición de la humedad del suelo a la radiación solar, la separación entre surcos y las fechas de los cultivos.

7. CONCLUSIONES

Primeramente, se rechazó la hipótesis de la relación lineal positiva de la ecuación de contenido normalizado de humedad (W) comparado con los datos medidos in-situ (Θ) proveniente de la combinación de los datos extraídos de las series de tiempo de dos años de agricultura de riego por gravedad y temporal con escurrimientos para OPTRAM (S2 y L8) y TOTRAM (LST_{NASA}-IV). Se observó que el W sobrestimaba más del doble la Θ , incluso a 20 cm de profundidad dentro de la agricultura de temporal con escurrimientos. Los valores obtenidos de W en la agricultura de temporal fueron excluidos a través de las calibraciones realizadas para los modelos y validadas mediante las comparaciones entre W - Θ .

Por otro lado, OPTRAM presentó mayor precisión dentro de los contenidos de humedad menores a 0.3 cm³ cm⁻³ y valores bajos de IV entre 0.15 y 0.45. Mientras que, TOTRAM presentó mayor precisión entre los contenidos de humedad de 0.25 a 0.5 cm³ cm⁻³ y valores más altos de IV entre los 0.45 y 0.8. Así mismo, OPTRAM-IV mediante Sentinel-2 mostró la relación lineal más precisa a 20 cm de profundidad utilizando SAVI y mejor correlación W -IV a 10 cm, utilizando NDVI. Por otro lado, TOTRAM-IV mediante Landsat-8 presentó la

relación lineal más precisa a través de MSAVI2 a 10 cm de profundidad y mejor correlación W-IV a 20 cm utilizando MSAVI2. Los resultados obtenidos presentaron una inclinación mayor hacia los índices de vegetación que toman en cuenta la presencia del brillo del suelo (SAVI y MSAVI2) mostrando mejores resultados en sus validaciones. En este contexto, la implementación de los anteriores índices para cultivos con mayor presencia de suelo a causan de la separación entre surcos proporcionan mejores resultados que los índices que no consideran el brillo del suelo para la estimación de la humedad del suelo para los dos tipos de agricultura utilizados en la investigación.

En conclusión, los resultados obtenidos aportarán un mejor entendimiento de los modelos ópticos para la estimación de la humedad del suelo en las actividades agrícolas. Acorde a los resultados del estudio, la viabilidad de los modelos depende del tipo de agricultura, valor de IV, LST y STR. Dichos modelos pueden ser calibrados de distintas maneras, como por etapa vegetativa, tipo de cultivo, tipo de suelo, tipo de agricultura, información espacial y temporal de un área para futuros trabajos de investigación.

8. LITERATURA CITADA

- Association of Official Agricultural Chemists, & Horwitz, W. (1975). *Official methods of analysis* (Vol. 222). Washington, DC: Association of Official Analytical Chemists.
- Aguirre, G., Adest, G, A., (1989). *The Conservation Biology of Tortoises*. Switzerland. (5), 10-13.
- Benesty, J., Chen, J., Huang, Y., & Cohen, I. (2009). *Noise reduction in speech processing* (Vol. 2). Springer Science & Business Media.
- Chander, G., & Helder, D. L. (2009). Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors. *Remote Sensing and Environment*. 113(5), 893-903. <https://doi.org/10.1016/j.rse.2009.01.007>

- Montaña, C. (1988). Estudio integrado de los recursos vegetación, suelo y agua en la Reserva de la Biosfera de Mapimí. *Instituto de Ecología, AC, México, DF*.
- Department of the Interior U.S. Geological Survey. Landsat 8-9 Operational Land Imager (OLI) - Thermal Infrared Sensor (TIRS) Collection 2 Level 2 (L2) Data Format Control Book (DFCB). Version 6.0, 2020.
- Gil, I., & Zárate de Lara, G. P. (1984). Métodos estadísticos: un enfoque interdisciplinario. *Editorial Trillas S.A. de C.V.*
- Google Earth Engine. (2022). Landsat Algorithms, Landsat collection structure. <https://developers.google.com/earth-engine/guides/landsat>
- Hassanpour, R., Zarehaghi, D., Neyshabouri, M. R., Feizizadeh, B., & Rahmati M. (2020). Modification on optical trapezoid model for accurate estimation of soil moisture content in a maize growing field. *Journal of Applied Remote Sensing*. <https://doi:10.1117/1.JRS.14.034519>
- Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). 25(3), 295–309. [https://doi:10.1016/0034-4257\(88\)90106-x](https://doi:10.1016/0034-4257(88)90106-x)
- Instituto de Ecología. (1991). El concepto de la reserva de la biosfera. Mexico. <https://www.files.cenapred.unam.mx/es/BibliotecaVirtual/1991C21/1991-9-19-C21-N27.PDF>.
- Lakhankar, T., Krakauer, N., & Khanbilvardi, R. (2009). Applications of microwave remote sensing of soil moisture for agricultural applications. *International Journal of Terraspace Science and Engineering*. 2(1), 81–91 <https://doi:10.1.1.701.7873>
- Lakshmi, V. (2013). Remote sensing of soil moisture. *International Scholarly Research Notices*, 2013, 1-33. <https://doi.org/10.1155/2013/424178>.
- Markham, B. L., & Barker, J. L. (1985). Spectral characterization of the LANDSAT Thematic Mapper sensors. *International Journal of Remote Sensing*. 6(5), 697-716. <https://doi.org/10.1080/01431168508948492>
- Nemani, R., Pierce, L., Running, S., & Goward, S. (1993). Developing satellite-derived estimates of surface moisture status. *Journal of Applied Meteorology and Climatology*. 32(3), 548-557. [https://doi.org/10.1175/1520-0450\(1993\)032<0548:DSDEOS>2.0.CO;2](https://doi.org/10.1175/1520-0450(1993)032<0548:DSDEOS>2.0.CO;2)
- Qi, J., Chehbouni, A., Huete, A. R., Kerr, Y.H., & Sorooshian, S. (1994). A modified soil adjusted vegetation index. *Remote Sensing of Environment*. 48(2), 119-126. [https://doi.org/10.1016/0034-4257\(94\)90134-1](https://doi.org/10.1016/0034-4257(94)90134-1)

- Rouse, J. W. (1973). Monitoring the vernal advancement and retrogradation of natural vegetation [NASA/GSFCT Type II Report]. Greenbelt, MD: NASA/Goddard Space Flight Center.
- Sadeghi, M. & William, D. P. (2015). A linear physically-based model for remote sensing of soil moisture using short wave infrared bands. *Remote Sensing of Environment*. 164, 66-76. <https://doi.org/10.1016/j.rse.2015.04.007>
- Sadeghi, M., Babaeian, E., Tuller, M., & Jones, S. B. (2017). The optical trapezoid model: A novel approach to remote sensing of soil moisture applied to Sentinel-2 and Landsat-8 observations. *Remote sensing of environment*, 198, 52-68. <https://doi.org/10.1016/j.rse.2017.05.041>
- Santos, W.J.R., Silva, B.M., Oliveira, G.C., Volpato, M.M.L., Lima, J.M., Curi, N., & Marques, J.J. (2014). Soil moisture in the root zone and its relation to plant vigor assessed by remote sensing at management scale. *Geoderma* (221-222), 91–95. <https://doi.org/10.1016/j.geoderma.2014.01.006>
- Stathopoulou, M., & Cartalis, C. (2007). Daytime urban heat islands From Landsat ETM+ and Corine land cover data: An application to major cities in Greece. *Solar Energy*. 81(3), 358-368. <https://doi.org/10.1016/j.solener.2006.06.014>.
- Patton, J. Tyson Oschsner (2014). Relating Volumetric and Gravimetric Soil Water Contents. Youtube. http://www.youtube.com/watch?app=desktop&v=-5hH_knnhgzg
- Vanino, S., Nino, P., De Michele, C., Falanga Bolognesi, S., D'Urso, G., Di Bene, C., Pennelli, B., Vuolo, F., Farina, R., Pulighe, G., & Napoli, R. (2018). Capability of Sentinel-2 data for estimating maximum evapotranspiration and irrigation requirements for tomato crop in Central Italy. *Remote Sensing of Environment*. 215, 452–470. <https://doi.org/10.1016/j.rse.2018.06.035>
- United State Department of Agriculture. (1977). Texture Triangle USDA. 36(1).
- Zhang, D., & Zhou, G. (2016). Estimation of soil moisture from optical and thermal remote sensing. *Sensors*. 16(8), 1308. <https://doi.org/10.3390/s16081308>