



**I  
N  
A  
O  
E**

**Segmentación Semántica de la Cobertura  
Terrestre para Estimación de Humedad del  
Suelo en Base a Imágenes Satelitales  
Reporte Técnico No. CCC-23-002**

Por

**Beatriz Alejandra Flores Rojas**

Asesores:

**Dra. Hayde Peregrina Barreto**

**Dr. Sergio Camacho Lara**

**INAOE**

Instituto Nacional de Astrofísica, Óptica y Electrónica

©Coordinación de Ciencias Computacionales

Abril 2023

Santa María de Tonantzintla, Puebla, CP 72840



# Índice

<b>1. Introducción</b>	<b>6</b>
1.1. Justificación . . . . .	9
1.2. Planteamiento del Problema . . . . .	11
1.3. Preguntas de Investigación . . . . .	12
1.4. Hipótesis . . . . .	13
1.5. Objetivos . . . . .	13
1.6. Alcances y Limitaciones . . . . .	14
1.7. Contribuciones Esperadas . . . . .	14
<b>2. Antecedentes</b>	<b>16</b>
2.1. Imágenes Satelitales . . . . .	16
2.2. Análisis y Procesamiento de Imágenes . . . . .	18
2.2.1. Segmentación . . . . .	19
2.2.2. Análisis de Textura . . . . .	21
2.3. Estimación de Humedad del Suelo . . . . .	23
<b>3. Trabajos Relacionados</b>	<b>26</b>
3.1. Métodos de estimación de humedad . . . . .	27
3.2. Métodos de segmentación de cobertura terrestre . . . . .	33

3.2.1. Métodos estadísticos espectrales de segmentación de cobertura terrestre . . . . .	35
<b>4. Propuesta de Investigación</b>	<b>43</b>
4.1. Metodología . . . . .	43
4.2. Plan de Trabajo . . . . .	47
4.3. Plan de Publicaciones . . . . .	47
<b>5. Resultados Preliminares</b>	<b>48</b>
5.1. Recolección y selección de conjunto de datos . . . . .	48
5.2. Pre-procesamiento de imágenes . . . . .	49
5.3. Extracción y análisis de características de textura . . . . .	51
5.3.1. <b>Experimento 1:</b> Análisis de textura para diferenciar tipos de cobertura utilizando misma fecha de imágenes . . . . .	53
5.3.2. <b>Experimento 2:</b> Análisis de textura para inferir tipo de cober- tura utilizando imágenes con diferente contenido de humedad . . . . .	62
<b>6. Observaciones Finales</b>	<b>68</b>
<b>Referencias</b>	<b>70</b>

## Glosario

**Banda espectral** Banda dentro del intervalo de longitudes de onda disponibles del sensor con el cual se adquiere la imagen satelital

**Composición de color verdadero** Una imagen de composición de color verdadero también llamada color natural o real muestra una combinación de bandas rojas, verdes y azules visibles con los correspondientes canales rojos, verdes y azules. Corresponde a la forma en que el ojo humano ve el mundo: la vegetación aparece verde, el agua de azul a negro, y la tierra desnuda y las superficies impermeables gris claro y marrón.

**Imagen Multiespectral** Es la imagen que captura datos dentro de rangos de longitud de onda específicos a través del espectro electromagnético.

**Imagen raster** Imagen constituida por una serie de puntos arreglados en forma matricial. Cada punto (píxel) corresponde a un elemento de la imagen y representa una característica como el nivel de gris del tipo de cobertura, entre otros

**Píxel** Unidad básica de la imagen a base de puntos de color o en escala de grises

**Resolución espacial** Se refiere al área cubierta sobre la tierra por un solo píxel. La resolución espacial se basa en varios factores, tal como el campo de vista del sensor (Field of View, FOV), altitud a la que se encuentra el sensor, y el número de detectores del sensor

**Resolución espectral** Se refiere al número de bandas espectrales para un sensor dado y depende del número de bandas en los sensores

**Respuesta espectral** Es la cantidad de radiación que refleja cada tipo de cobertura de suelo y que es detectada por el sensor del satélite para obtener la imagen. La respuesta espectral permite la identificación de materiales y características

encontradas sobre la superficie de la tierra, tal como bosques, pastizales, aguas oceánicas, etc.

**Shapefile** Es un formato sencillo y no topológico que se utiliza para almacenar la ubicación geométrica y la información de atributos de las entidades geográficas.

# 1. Introducción

Las sequías son uno de los desastres naturales más costosos, cuyo impacto y frecuencia se han incrementado debido al cambio climático. Se estima que el número y duración de sequías se ha elevado en 29% desde el año 2000 y que hasta 700 millones de personas corren el riesgo de ser desplazadas como resultado de sequías pronosticadas hasta el año 2030 a nivel mundial [1]. En este sentido, la sequía es un tema de relevancia global, por ello, es importante contar con medidas de mitigación de riesgos mediante monitoreo, recolectando y analizando parámetros que proporcionen información para su detección [2]. Dentro de este orden de ideas, la humedad es un parámetro clave para identificar y evaluar el riesgo de sequía [3]. El costo de la medición precisa de la humedad del suelo *in situ* es costosa porque requiere un proceso de muestreo periódico y las mediciones reales son escasas debido a la falta de sensores *in situ*. Por tal motivo hay interés en desarrollar métodos enfocados a estimar la humedad del suelo en una región mediante imágenes satelitales.

Las técnicas de percepción remota mediante observaciones satelitales se han utilizadas para la obtención de indicadores o parámetros de humedad del suelo. Con estas observaciones se puede realizar análisis y recuperación de variables relacionadas con la sequía como la humedad del suelo mediante imágenes multiespectrales adquiridas en las bandas del visible, infrarrojo o de microondas. [4, 5, 6, 7, 8]. De esta manera se tiene una alternativa que proporciona un conjunto de datos para estudiar sequías, incluyendo observaciones globales, registros de datos consistentes, y acceso a lugares geográficos inaccesibles [9].

Se han realizado diversos esfuerzos para la estimación de humedad del suelo con imágenes satelitales aplicando diversos métodos. Entre estos métodos se encuentran los tradicionales, aprendizaje automático y procesamiento de imágenes. El enfoque tradicional calcula índices relacionados con la humedad derivados de imágenes satelitales como el *Normalized Difference Vegetation Index* (NDVI) o *Normalized*

*Difference Water Index* (NDWI), entre otros [10, 11]. Los métodos de aprendizaje automático aplican algoritmos como Redes Neuronales y modelos de regresión lineal, entre otros. Muchos de estos métodos estiman la humedad del suelo en función de su respuesta espectral [12, 13]. En el uso de los métodos de procesamiento de imágenes se procesa la imagen para obtener parámetros relacionados con la humedad como pH, textura u otros valores físicos del suelo [14, 15]. En el enfoque de procesamiento de imágenes se encuentran los métodos sinérgicos donde se combinan datos o parámetros como en el denominado método del “triángulo” o “trapezoide”. Este método constituye uno de los enfoques más populares y ampliamente utilizado para estimación de humedad superficial del suelo con imágenes satelitales [16, 17, 18]. Este método utiliza un modelo que se basa en la relación de reflectancia en el infrarrojo de onda corta (SWIR) y el índice de vegetación (IV) en una región de píxeles de superficie terrestre [19, 20, 21].

Aunque los métodos actuales para la estimación de humedad son prometedores y obtienen una tasa de reconocimiento de alrededor de  $90\% \pm 5$  están limitados en ciertos factores. Entre estos factores se encuentran, no tomar en cuenta la contribución de diferentes parámetros (tales como vegetación, temperatura, entre otros), la necesidad de intervención humana para el análisis y la interpretación o la necesidad de gran cantidad de datos de entrada para los algoritmos. En caso, del método “trapezoide” es necesaria la generación de datos en la parametrización del modelo en donde se requiere un proceso que lleva tiempo o recursos humanos. La estimación de la humedad del suelo con este modelo se realiza mediante una ecuación que exhibe una relación lineal entre el contenido de humedad superficial y la reflectancia transformada de SWIR [22]. En la ecuación se utilizan los parámetros de fracción de vegetación (IV), reflectancia transformada de SWIR (STR), el contenido de humedad mínima local de suelo seco, y el contenido máximo local de humedad del suelo húmedo para suelo desnudo y suelo con vegetación densa. Al superponer el modelo del trapezoide sobre el observado, los valores de los parámetros se obtienen a partir

de los valores de píxeles dentro del espacio trapezoidal STR-NDVI de una sucesión de imágenes para una ubicación de interés (escenas de satélite).

La selección de los parámetros de región seca (borde seco) y húmeda (borde húmedo) se puede trasladar al entorno computacional como un problema de segmentación semántica. En donde el objetivo es etiquetar a cada píxel en la imagen con base en un conjunto de características de tipos de cobertura terrestre como suelo desnudo, vegetación o cuerpos de agua. Una característica importante para la segmentación semántica de cobertura terrestre es la reflectancia. En ese sentido, las firmas espectrales hacen posible la identificación de distintos objetos de la tierra presentes en imágenes satelitales. Esta característica se genera a partir de la interacción de la radiación electromagnética en determinadas longitudes de onda del espectro electromagnético (reflectancia) con la materia. Esta característica particular de cada objeto, se le conoce como firma espectral, y es la base para procesos de segmentación semántica [23]. Los métodos con base en información espectral se basan en variaciones en la reflectancia espectral de clases similares. Entre los métodos tradicionales más utilizados para la segmentación semántica terrestre se encuentran los métodos estadísticos como distancia mínima, distancia Mahalanobis, máxima verosimilitud, entre otros. Entre estos métodos el algoritmo de máxima verosimilitud ha sido ampliamente utilizado en la segmentación semántica terrestre teniendo resultados aceptables dentro de los métodos estadísticos [24, 25].

En una imagen satelital se pueden distinguir distintos tipos de coberturas terrestres, tales como: vegetación, suelo desnudo, cuerpos de agua, entre otros. La información espectral es importante en la segmentación semántica para distinguir entre diferentes tipos de coberturas. Sin embargo, imágenes satelitales de una escena pueden tener cambios de iluminación debido a la hora, fecha y condiciones de nubosidad. Consecuentemente, puede llegar a presentar problemas en la segmentación semántica generando píxeles dispersos de tipos de coberturas erróneamente etiquetados. Para compensar este problema, se puede utilizar información contextual junto

con la información espectral del píxel. El análisis y segmentación de imágenes es un problema de investigación abierto para la comunidad de investigación que trabaja en aplicaciones de percepción remota y de visión artificial. Es por ello que es deseable incrementar el porcentaje de segmentación de coberturas terrestres sobre imágenes satelitales. Para atacar el problema de segmentación por cambios de iluminación se propone agregar información de textura a los criterios de máxima verosimilitud que permita mejorar la discriminación entre píxeles de tipo de cobertura como vegetación, suelo desnudo y cuerpos de agua.

El objetivo de este trabajo de investigación es atacar el problema de segmentación combinando información espectral e información de textura, permitiendo así tener información sobre similitud y proximidad en valores de reflectancia de respuesta espectral y propiedades similares entre píxeles vecinos mediante descriptores de textura. La solución que se propone va enfocada a optimizar y automatizar la estimación de humedad del suelo con el método trapezoide. Esto permitirá tener un buen desempeño de métodos sinérgicos, combinando parámetros para mejorar la estimación de la humedad sin necesidad de intervención humana y datos auxiliares. Esto proporcionaría una herramienta a los analistas y especialistas involucrados en el estudio de sequías que pueda ser utilizada como apoyo en beneficio de la sociedad.

## **1.1. Justificación**

Para obtener información de superficies sobre la tierra en las imágenes satelitales son necesarios métodos para extracción de datos. Esto provoca desafíos para las tareas de recuperación de información debido a la complejidad de los datos de imágenes satelitales. Esto se deriva por tener datos complejos y no estructurados, además de la variedad de resoluciones, como espacial, temporal y espectral. Por lo tanto, deben formularse técnicas que faciliten la recuperación eficiente y automatizada de contenido e información de las imágenes.

Para obtener información de las imágenes satelitales sobre humedad del suelo existen diversos métodos. Entre los más utilizados se encuentran los que son basados en modelos de relaciones físicas que suelen preferirse a los modelos empíricos relacionados con la humedad. Dentro de estos métodos se encuentra el método llamado trapezoide que es ampliamente utilizado para estimar la humedad del suelo [19, 20, 21]. Este método necesita una región o área de trabajo sobre la imagen, donde se requiere la identificación de cobertura terrestre como vegetación, suelo desnudo o cuerpos de agua. Una vez definida la región trapezoidal se obtienen los parámetros necesarios para estimar la humedad. El establecimiento de la región trapezoidal es complicado para grandes escalas debido a la heterogeneidad espacial de las propiedades de la superficie. Esto pueden afectar la forma de la región trapezoidal y por lo tanto interfiere con la determinación precisa de parámetros necesarios en el método y del resultado de estimación de humedad del suelo. Esto implica un desafío asociado con la identificación y categorización de superficie terrestre (suelo y superficie de vegetación) buscando una definición precisa y dinámica de la región trapezoidal del método [26].

En este sentido, mediante la segmentación semántica se puede determinar la región trapezoidal. Por medio de esto se podrá analizar y reconocer de manera automática la superficie terrestre y sus límites en las imágenes con el fin de producir información para que pueda ser utilizada en el método trapezoide. Hay investigaciones y técnicas que han logrado avances que permiten la identificación de coberturas terrestres, como técnicas de aprendizaje automático usando Redes Neuronales Artificiales [27, 28, 29, 30] y Árboles de Decisión [31, 32, 33], entre otros, sin embargo, existen las técnicas tradicionales como k-means, Mínima Distancia, Máxima Verosimilitud [34, 35, 36, 37] que se basan en comportamiento de firma espectral tomando una función de distancia. Estos métodos son ampliamente utilizadas y son implementados para operar en las plataformas de software de percepción remota (ERDAS, QGIS, GRASS, ENVI, ArcGIS) en imágenes satelitales [38, 39, 40, 41, 42].

Entre los métodos tradicionales el algoritmo de Máxima Verosimilitud es uno de los más utilizados en el área de percepción remota para categorización de coberturas terrestres en imágenes satélites. Además, se utiliza como método de validación en propuestas de segmentación semántica [35, 37, 43]. Este algoritmo ha dado buenos resultados, sin embargo, aún hay retos que resolver para delimitar los grupos de píxeles con valores homogéneos dentro de la imagen. Dado que este algoritmo es basado en píxeles y no toma en cuenta información contextual tiene limitaciones al enfrentarse a la complejidad de objetos y fondos heterogéneos de cobertura terrestre generando píxeles mal etiquetados para identificar de manera consistente las áreas de interés y sus límites. Es por ello que en este trabajo se propone un nuevo método para mejorar la segmentación semántica de cobertura terrestre del algoritmo de máxima verosimilitud agregando información contextual de textura.

## **1.2. Planteamiento del Problema**

La Observación de la Tierra por medio de imágenes satelitales ha jugado un papel imperativo en la ampliación de capacidades para obtener información sobre la distribución espacio-temporal de la humedad del suelo superficial. El proceso de extraer información de interés sobre la escena de la imagen satelital para la estimación de humedad del suelo en el método trapezoide consta de diversos procesos y cálculos que van desde la adquisición de datos hasta la integración y presentación de resultados. Entre los diferentes procesos para extraer información es necesario simplificar la selección de regiones para el modelo de trapezoide con la finalidad de estimar la humedad en una imagen satelital de manera automática. El proceso se puede automatizar mediante un proceso de segmentación, asignando una etiqueta de clase a cada píxel en la imagen de interés. En esta investigación se tiene interés del método de máxima verosimilitud por ser ampliamente utilizado en la segmentación de cobertura terrestre. Aunque el método de máxima verosimilitud obtiene buenos

resultados ( $87\% \pm 5$ ) aún hay huecos que atacar, por ejemplo, el método no utiliza información contextual que permita considerar la relación espacial entre píxeles vecinos.

Formalmente, el problema se define como la segmentación semántica de los píxeles en una imagen  $I$  para así poder determinar las regiones del método del trapecoide. Entonces, se debe asignar una etiqueta  $e$  a cada píxel en  $I$  entre  $k$  clases, las cuales pueden corresponder a vegetación, suelo desnudo o cuerpo de agua en función de las características  $C = \{S, T\}$  con base en el término  $I(x, y) = r(x, y) * B | r(x, y) = 2^n$ ,  $B = [b_1, b_n]$  donde  $r_p$  es el valor de reflectancia para un píxel  $p$  y  $B$  son las bandas espectrales de la imagen  $I$ . Se busca obtener un conjunto de características espectrales  $S = \{s_1, s_2 \dots s_n\}$  y de textura  $T = \{t_1, t_2 \dots t_n\}$  con la finalidad de segmentar  $I$  y convertirla en una imagen con etiquetas  $I'$  mediante un modelo computacional  $I' = M(I, C)$  tal que lo que deseamos encontrar es una función  $S$  que integre  $f^s(I)$  y  $f^t(I)$  en donde  $f^s$  es una función de distribución de probabilidad de máxima verosimilitud y  $f^t$  obtiene información de la textura para cada  $p$  en  $I$ .

### 1.3. Preguntas de Investigación

*¿Es posible mejorar un modelo de segmentación semántica de coberturas terrestres como vegetación y suelo desnudo en imágenes satelitales de un algoritmo estadístico espectral agregando información contextual de textura?*

*¿Cómo agregar información de textura a un algoritmo estadístico espectral?*

*¿Cómo se puede calcular de manera automática los parámetros del método trapecoide para estimar correctamente la humedad del suelo en imágenes satelitales?*

## 1.4. Hipótesis

Si se integra información de textura a un algoritmo estadístico espectral como el de máxima verosimilitud entonces es posible mejorar su desempeño en la segmentación semántica de cobertura terrestre. Dado que la textura podría proporcionar conocimiento adicional de información contextual con propiedades que podrían detectar la variabilidad intraclasses y separabilidad interclasses para discriminar clases heterogéneas, reduciendo la aparición de píxeles dispersos mal etiquetados y aumentando la descripción de las relaciones entre píxeles en textura.

## 1.5. Objetivos

Desarrollar una metodología computacional automática de segmentación de cobertura terrestre mediante combinación de información estadístico espectral y textural para obtener la región y los parámetros (NIR,IV) del modelo trapezoidal en la estimación de humedad del suelo a partir de imágenes satelitales multiespectrales.

### Objetivos Específicos

1. Generar paquetes de datos (*dataset*) que relacionen datos *in-situ* con imágenes satelitales de periodos con baja y alta humedad.
2. Analizar y seleccionar el descriptor de textura que mejor describa coberturas terrestres principalmente de vegetación, suelo desnudo y agua.
3. Diseñar e implementar un modelo de segmentación semántico que discrimine coberturas terrestres combinando información espectral y contextual de textura en imágenes satelitales multiespectrales.
4. Obtener región y parámetros del método trapezoide para estimación de humedad de manera automática a partir del modelo de segmentación semántica propuesto.

5. Validar y comparar resultados de estimación de humedad del suelo con segmentación propuesta con datos *in situ* y con otros datos de referencia.

## **1.6. Alcances y Limitaciones**

- El trabajo abarca el diseño, implementación y validación del segmentador semántico propuesto y la estimación de humedad del suelo principalmente en áreas de México.
- La metodología propuesta será evaluada bajo distintas condiciones de humedad del suelo como baja y alta humedad.
- En la toma de imágenes satelitales hay una interacción del sensor con la atmósfera lo que puede generar una oclusión en el área de interés, como nubes o aerosoles. Esto puede mermar la visibilidad de la imagen y por ende los datos. No tratará de resolver el problema de oclusión en las imágenes, no se tomarán en cuenta regiones con estas características y se descartarán imágenes con alto contenido de nubes.

## **1.7. Contribuciones Esperadas**

- La contribución de la investigación es la metodología computacional para mejorar el desempeño de segmentación semántica de cobertura terrestre de un método estadístico espectral combinando información espectral y textural.
- Una metodología automática para obtención de regiones para el modelo trapezoide de estimación de humedad del suelo en imágenes satelitales multiespectrales.
- Una metodología automática para estimación de humedad del suelo con el modelo trapezoide en imágenes satelitales multiespectrales.

- Recolección y procesamiento de una base de datos de imágenes satelitales para generar un subconjunto con datos de tipos de coberturas terrestres y de humedad del suelo.
- El estudio generado ofrecerá información y una herramienta útil para la comunidad científica, instituciones o interesados en el análisis de la dinámica de humedad del suelo y la sequía.
- Publicación de la investigación y de los resultados en congreso internacional y en revista indexada JCR

## 2. Antecedentes

El procesamiento y análisis digital de imágenes es un campo que se encarga del procesamiento de las imágenes digitales por medio de una computadora. El procesamiento digital de imágenes es el conjunto de técnicas que se aplican a las imágenes digitales con el objetivo de mejorar su calidad, mientras que el análisis de imágenes incluye aquellas técnicas cuyo principal objetivo es facilitar la búsqueda e interpretación de información contenida en ellas [44]. Dentro del procesamiento de imágenes se engloban una serie de técnicas que comprenden operaciones sobre una imagen y cuyo resultado final es la imagen procesada. El valor del píxel en la imagen de salida puede estar en función del valor que tenía en la imagen de entrada, de los valores de sus vecinos o del valor de todos los puntos de la imagen de entrada. Una imagen puede ser definida como una función de dos dimensiones  $f(x, y)$  donde  $x$  y  $y$  son las coordenadas espaciales (plano) y la amplitud de la función  $f$  en algún par de coordenadas  $(x, y)$  es llamada intensidad o nivel de gris de la imagen en ese punto. Cuando  $x$ ,  $y$ , los valores de la amplitud de la función  $f$  son cantidades discretas finitas, a dicha imagen se le llama imagen digital. Una imagen digital está compuesta de un número finito de elementos y cada uno tiene una localidad y valor particulares. A éstos elementos se les llama, elementos de la imagen o píxeles; siendo este último el término más usado para denotar los elementos de una imagen digital.

### 2.1. Imágenes Satelitales

Una imagen satelital representa una escena sobre el terreno captada desde el espacio por medio de un sensor montado en un satélite artificial. Estos sensores recopilan radiación electromagnética reflejada por la superficie de la Tierra y pueden proporcionar información valiosa sobre las características del área representada.

El sistema de captura de una imagen satelital consiste en un sensor que visualiza

la superficie terrestre, adquiriendo la radiación emitida y reflejada de los objetos situados sobre ella. Esta energía que capta el sensor está definida por el valor numérico o Nivel Digital - ND, que codifica digitalmente esta radiancia, para una área de terreno y en una banda espectral específica. La colección de todos los datos obtenidos en las bandas espectrales del sensor se constituye en un arreglo matricial (Figura 1) que tiene una unidad mínima de observación denominada píxel (Picture Element de su sigla en inglés) con un número entero (ND) que puede convertirse en nivel de gris y con una localización espacial.

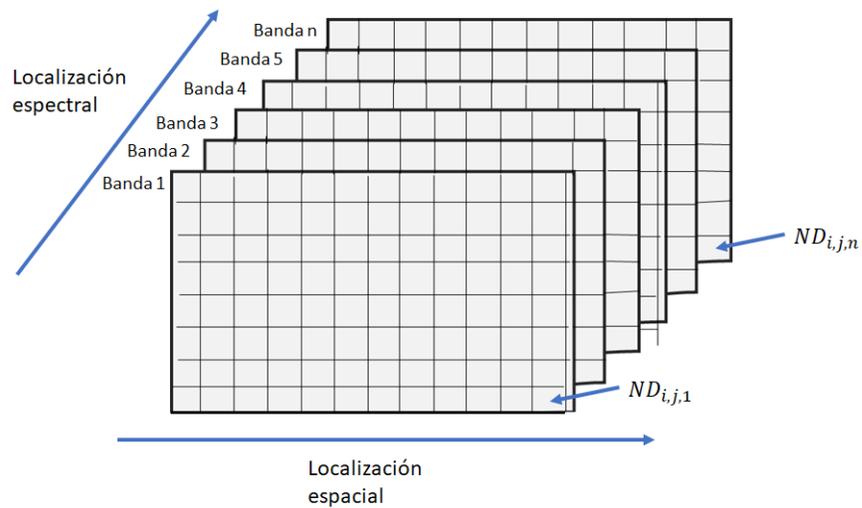


Figura 1: Representación de organización de datos en una imagen satelital espectral

Las características de los satélites utilizados en esta investigación se muestran en la Tabla 1.

Tabla 1: Características de Imágenes Satelitales

Satelite-Sensor	Resolución Espectral-Espacial
Landsat 4-5 Thematic Mapper (TM)	Band1 Visible (0.45 - 0.52 $\mu m$ )30m
	Band2 Visible (0.52 - 0.60 $\mu m$ )30m
	Band3 Visible (0.63 - 0.69 $\mu m$ )30m
	Band4 Near-Infrared (0.76 - 0.90 $\mu m$ )30m
	Band5 Near-Infrared (1.55 - 1.75 $\mu m$ )30m
	Band6 Thermal (10.40 - 12.50 $\mu m$ )120m
	Band 7 Mid-Infrared (2.08 - 2.35 $\mu m$ )30m

<p style="text-align: center;">Landsat 8 Operational Land Imager (OLI) Thermal Infrared Sensor (TIRS)</p>	<p>Band1 Coastal Aerosol(0.43 - 0.45 ) 30 m  Band2 Blue (0.450 - 0.51 <math>\mu m</math>) 30 m  Band3 Green (0.53 - 0.59 <math>\mu m</math>) 30 m  Band4 Red (0.64 - 0.67 <math>\mu m</math>)30m  Band5 Near-Infrared (0.85 - 0.88 <math>\mu m</math>)30m  Band6 SWIR 1 (1.57 - 1.65 <math>\mu m</math>)30m  Band7 SWIR 2 (2.11 - 2.29 <math>\mu m</math>)30m  Band8 Panchromatic (PAN) (0.50 - 0.68 <math>\mu m</math>)15m  Band9 Cirrus (1.36 - 1.38 <math>\mu m</math>)30m  Band10 TIRS 1 (10.6 - 11.19 <math>\mu m</math>)100m  Band11 TIRS 2 (11.5 - 12.51 <math>\mu m</math>)100m</p>
<p style="text-align: center;">Sentinel 2 MultiSpectral Instrument (MSI)</p>	<p>Band1 Coastal Aerosol(0.43 - 0.45 ) 60 m  Band2 Blue (0.450 - 0.52 <math>\mu m</math>)10m  Band3 Green (0.54 - 0.57 <math>\mu m</math>)10m  Band4 Red (0.65 - 0.68 <math>\mu m</math>)10m  Band5 Red Edge 1(0.69 - 0.71 <math>\mu m</math>)20m  Band6 Red Edge 2(0.73 - 0.74 <math>\mu m</math>)20m  Band7 Red Edge 3(0.77 - 0.79 <math>\mu m</math>)20m  Band8 NIR 1(0.78 - 0.90 <math>\mu m</math>)10m  Band8A NIR 2(0.85 - 0.87 <math>\mu m</math>)20m  Band9 Water Vapour(0.93 - 0.95 <math>\mu m</math>)60m  Band10 Cirrus(1.36 - 1.39 <math>\mu m</math>)60m  Band11 SWIR 1(1.56 - 1.65 <math>\mu m</math>)20m  Band12 SWIR 2(2.10 - 2.28 <math>\mu m</math>)20m</p>

## 2.2. Análisis y Procesamiento de Imágenes

El procesamiento digital de imágenes (PDI) puede definirse como el conjunto de técnicas que se aplican a las imágenes digitales con el objetivo de mejorar la calidad o facilitar la búsqueda de información [45]. El análisis digital de imágenes es un conjunto de técnicas destinadas a la extracción de información desde una imagen. En el análisis y procesamiento de imágenes se pueden usar una variedad de técnicas y características con el propósito de reconocimiento de objetivos en las imágenes digitales. Algunas de las operaciones más comunes en PDI se encuentran la segmentación, análisis de textura, reconocimiento de patrones, clasificación, entre otros. En esta investigación es de especial interés la segmentación y el análisis de textura.

### 2.2.1. Segmentación

La segmentación es uno de los problemas generales del campo de la visión artificial y consiste en dividir una imagen digital en varias regiones (grupos de píxeles) denominadas segmentos. La segmentación también se puede definir como un proceso de clasificación por píxel que asigna una categoría a cada píxel de la imagen analizada. La segmentación subdivide a una imagen en sus regiones u objetos constituyentes, de tal manera que los píxeles de esas regiones poseen propiedades o atributos idénticos, como niveles de gris, contraste o texturas. La mayoría de los algoritmos de segmentación se basan en dos propiedades básicas de intensidad de la imagen: la discontinuidad y la similitud. En la categoría de segmentación mediante discontinuidad, el proceso se realiza dividiendo a la imagen basándose en cambios abruptos en intensidad, como es el caso de la detección de bordes en una imagen. Con respecto a la segmentación con base en la similitud, ésta es lograda mediante la partición de una imagen en regiones que son similares de acuerdo con un conjunto de criterios predefinidos. Existen numerosas técnicas de segmentación entre las cuales se encuentra la segmentación semántica.

**Segmentación Semántica:** La segmentación semántica consiste en otorgar una etiqueta o categoría a cada píxel de una imagen y tiene como objetivo delimitar precisamente los objetos de las distintas categorías a nivel de píxel, dando como resultado cualquier forma arbitraria (Figura 2), donde se busca dar una etiqueta  $e$  a los píxeles de una imagen,  $I$ , entre  $k$  clases.

La segmentación semántica ha sido utilizada en el análisis de imágenes satelitales para identificar y delimitar los diferentes objetos o superficies de coberturas terrestres como vegetación o suelo. Los métodos espectrales estadísticos como distancia mínima, distancia Mahalanobis, paralelepípedos y máxima verosimilitud han sido aplicados para la segmentación de coberturas de la tierra. Estos métodos principalmente se basan en el valor de gris de los píxeles que corresponden a sus reflectancias

espectrales. Estos métodos utilizan las estadísticas de reflectancia para píxeles particulares y reunir píxeles para expresar las características de la cobertura terrestre [46]. Entre los métodos estadísticos espectrales más populares y ampliamente utilizados está el algoritmo de máxima verosimilitud.

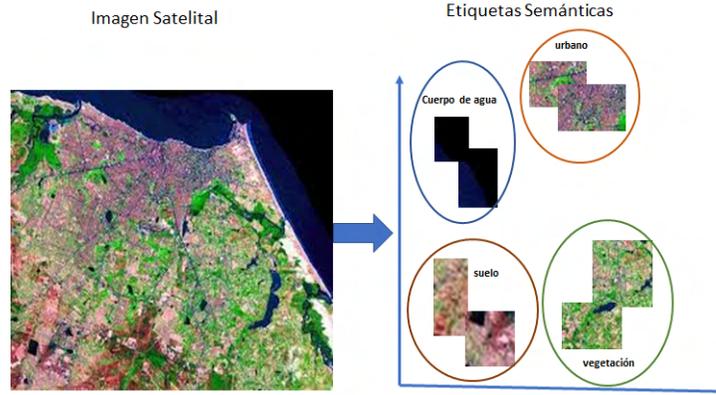


Figura 2: Esquema asignación de etiquetas en imagen satelital

El algoritmo de máxima verosimilitud utiliza la probabilidad posterior de que un píxel pertenezca a la clase  $k$  para asignar etiquetas de clase correspondiente.

$$L_k = \frac{p(k)p(X/k)}{p(i)p(X/i)} \quad (1)$$

donde  $P(k)$  es la probabilidad previa de clase  $k$ , es decir, sin información sobre los valores estadísticos de la clase  $k$ ,  $P(X/k)$  es la probabilidad condicional de observar  $X$  de la clase  $k$ , o función de densidad de probabilidad. Se aplica como la función de densidad de probabilidad. En el caso de distribuciones normales, la probabilidad se puede expresar en la siguiente ecuación.

$$L_k(X) = \frac{1}{\sqrt{(2\pi)^2 |\sum_k|}} e^{(\frac{-1}{2})(X-x_k)^T \sum^{-1}(X-x_k)} \quad (2)$$

Dónde:  $n$ : número de bandas,  $X$ : datos de imagen de  $n$  bandas,  $L_k(X)$ : probabilidad de que  $X$  pertenezca a la clase  $k$ ,  $x_k$ : vector medio de clase  $k$ ,  $\sum_k$ : matriz de

varianza-covarianza de la clase  $k$

### 2.2.2. Análisis de Textura

Las características de textura se consideran de las características más indicativas de la cobertura sobre el terreno. Son los más visibles y perceptibles patrones en cualquier imagen. A pesar de que su estudio es un campo de investigación importante en visión por computador, no hay una descripción formal de lo que es una textura dado que las características propias de una textura a menudo son opuestas en diferentes tipos de imágenes: regularidad frente a aleatoriedad, uniformidad frente a heterogeneidad. Los métodos de análisis de textura pueden ser divididos en dos enfoques: el enfoque estadístico o estocástico y el enfoque estructural. La primera categoría trata a la textura como fenómeno estadístico. La textura es descrita mediante las propiedades estadísticas de los valores digitales y posiciones de los píxeles. La formulación estocástica de una textura se basa en un modelo en el cual la textura es vista como un proceso estocástico bi-dimensional descrito por sus parámetros estadísticos.

Uno de los descriptores más famosos del enfoque estadístico es la matriz de co-ocurrencia. Este fue el resultado del primer enfoque para describir, y luego clasificar, la textura de imágenes [47]. Sigue siendo popular hoy en día en virtud de su buen rendimiento. La matriz de coocurrencia contiene elementos que son recuentos del número de pares de píxeles para niveles de brillo específicos, cuando están separados por cierta distancia y en alguna relativa inclinación. Para los niveles de brillo  $b_1$  y  $b_2$ , la matriz de coocurrencia  $C$  es

$$C_{b_1, b_2} = \sum_{x=4}^N \sum_{y=1}^N (P_{p,y} = b_1) \wedge (P_{x',y'} = b_2) \quad (3)$$

Donde  $\wedge$  denota la operación lógica *AND*,  $x$  la coordenada,  $x'$  es el desplaza-

miento dado por la distancia especificada  $d$  y la inclinación  $\theta$  por:

$$x' = x + d\cos(\theta)\forall(d \in 1, \max(d)) \wedge (\theta \in 0, 2\pi) \quad (4)$$

y la coordenada  $y'$  es:

$$y' = y + d\sin(\theta)\forall(d \in 1, \max(d)) \wedge (\theta \in 0, 2\pi) \quad (5)$$

Cuando la ecuación 4 se aplica a una imagen, obtenemos una matriz cuadrada, simétrica cuyas dimensiones son iguales al número de niveles de gris de la imagen. En la generación de la matriz de coocurrencia, la distancia máxima fue un píxel y las direcciones se establecieron para seleccionar los cuatro vecinos más cercanos de cada punto.

Otro de los descriptores de textura más utilizados en la actualidad es el llamado Local Binary Pattern (LBP) o patrón binario local, que tiene numerosas aplicaciones en el análisis de imágenes digitales y, en general, en la visión por computador. Local Binary Pattern (LBP) es un operador de textura simple y eficiente que etiqueta cada píxel de la imagen analizando su vecindario, estudiando si el nivel de gris de cada píxel supera un determinado umbral y codificando dicha comparación mediante un número binario. Para calcular LBP sobre una imagen en escala de grises se utiliza la ecuación 7 [48]

$$LBP(P, R) = \sum_{p=0}^{P-1} f(g_p - g_c)2^p \quad s(x) = \begin{cases} 1 & \text{si } x \geq 0 \\ 0 & \text{si } x < 0 \end{cases} \quad (6)$$

Donde  $P$  es el número de vecinos que se van a considerar,  $R$  es el tamaño del vecindario y,  $g_c$  y  $g_p$  son los valores de gris del píxel central y cada uno de los  $p$  píxeles del vecindario respectivamente.

La definición de Patrón de Invariancia Local es un método que no es invariante a la rotación. Para corregir esta falta de robustez, se propuso un método llamada invariancia a la rotación basado en asignar a cada píxel el menor valor resultante de LBP de entre todas las posibles rotaciones del patrón. En el método invariante a la rotación, se selecciona el valor mínimo para representar al píxel central. En la figura 3 se pueden ver todas las posibles combinaciones de un patrón concreto y el valor asignado, correspondiente a la rotación 3. Utilizando la ecuación (8) se puede obtener una descripción invariante a la rotación.

$$LBP_{P,R}^i = \min\{ROR(LBP_{P,R}, i) | i = 0, \dots, P - 1\} \quad (7)$$

donde  $ROR(x, i)$  es una desplazamiento hacia la derecha de  $i$  píxeles para el patrón  $x$ . En términos de píxeles de la imagen ecuación (8) corresponde a rotar el conjunto vecino en el sentido de las agujas del reloj tantos veces que un número máximo de los bits más significativos, a partir de  $g_{P-1}$ , son 0.

<table border="1"> <tr><td>1</td><td>1</td><td>0</td></tr> <tr><td>0</td><td>R1</td><td>0</td></tr> <tr><td>0</td><td>1</td><td>0</td></tr> </table> <p>LBP=78</p>	1	1	0	0	R1	0	0	1	0	<table border="1"> <tr><td>1</td><td>0</td><td>0</td></tr> <tr><td>1</td><td>R2</td><td>0</td></tr> <tr><td>0</td><td>0</td><td>1</td></tr> </table> <p>LBP=152</p>	1	0	0	1	R2	0	0	0	1	<table border="1"> <tr><td>0</td><td>0</td><td>0</td></tr> <tr><td>1</td><td>R3</td><td>1</td></tr> <tr><td>1</td><td>0</td><td>0</td></tr> </table> <p>LBP=49</p>	0	0	0	1	R3	1	1	0	0	<table border="1"> <tr><td>0</td><td>0</td><td>0</td></tr> <tr><td>1</td><td>R4</td><td>1</td></tr> <tr><td>1</td><td>0</td><td>0</td></tr> </table> <p>LBP=98</p>	0	0	0	1	R4	1	1	0	0
1	1	0																																					
0	R1	0																																					
0	1	0																																					
1	0	0																																					
1	R2	0																																					
0	0	1																																					
0	0	0																																					
1	R3	1																																					
1	0	0																																					
0	0	0																																					
1	R4	1																																					
1	0	0																																					
<table border="1"> <tr><td>0</td><td>1</td><td>0</td></tr> <tr><td>0</td><td>R5</td><td>0</td></tr> <tr><td>0</td><td>1</td><td>1</td></tr> </table> <p>LBP=196</p>	0	1	0	0	R5	0	0	1	1	<table border="1"> <tr><td>1</td><td>0</td><td>0</td></tr> <tr><td>0</td><td>R6</td><td>1</td></tr> <tr><td>0</td><td>0</td><td>1</td></tr> </table> <p>LBP=137</p>	1	0	0	0	R6	1	0	0	1	<table border="1"> <tr><td>0</td><td>0</td><td>1</td></tr> <tr><td>1</td><td>R7</td><td>1</td></tr> <tr><td>0</td><td>0</td><td>0</td></tr> </table> <p>LBP=19</p>	0	0	1	1	R7	1	0	0	0	<table border="1"> <tr><td>0</td><td>1</td><td>1</td></tr> <tr><td>0</td><td>R8</td><td>0</td></tr> <tr><td>1</td><td>0</td><td>0</td></tr> </table> <p>LBP=38</p>	0	1	1	0	R8	0	1	0	0
0	1	0																																					
0	R5	0																																					
0	1	1																																					
1	0	0																																					
0	R6	1																																					
0	0	1																																					
0	0	1																																					
1	R7	1																																					
0	0	0																																					
0	1	1																																					
0	R8	0																																					
1	0	0																																					

Figura 3: Ejemplo de posibles rotaciones de un vector y su valor de LBP.[49].

### 2.3. Estimación de Humedad del Suelo

El SM o contenido de agua del suelo, que puede expresarse en una base gravimétrica,  $\theta m$ , o volumétrica,  $\theta v$ , representa la cantidad de agua presente en el suelo a un potencial matricial dado [50]. la matriz potencial,  $\Psi m$  (o carga matricial, h), es sinónimo de las fuerzas superficiales de adsorción y capilar combinadas que retienen agua dentro de la matriz sólida del suelo y están únicamente relacionados con SM

en condiciones hidrostáticas. La relación altamente no lineal entre SM y  $\Psi_m$  se denomina la característica del agua del suelo y exhibe una forma distintiva para cada textura de suelo individual.

Entre los métodos más utilizados para estimación de humedad con imágenes satelitales se encuentran el método del “triángulo” o “trapezoide”-[19, 20, 21]. Este método exhibe una relación lineal entre el contenido de humedad superficial y la reflectancia transformada SWIR:

$$W = \frac{\theta - \theta_d}{\theta_w - \theta_d} = \frac{STR - STR_d}{STR_w - STR_d} \quad (8)$$

donde STR es la reflectancia transformada de Infrarrojo de Longitud de Onda Corta (SWIR), W es el contenido de humedad del suelo normalizado por el contenido mínimo local de humedad del suelo seco  $\theta_d$ , y el contenido máximo local de humedad del suelo húmedo,  $\theta_w$ . Los términos  $STR_d$  y  $STR_w$  son los valores STR del suelo seco y húmedo, respectivamente, donde  $STR_d$  y  $STR_w$  se obtienen del trapezoide STR-NDVI trapezoide (Fig. 2) para una ubicación específica (escena de satélite). El borde inferior (seco) y borde superior (húmedo) del trapezoide se utilizan para resolver  $STR_d$  y  $STR_w$  en cualquier NDVI dado (es decir, cobertura vegetal fraccionada):

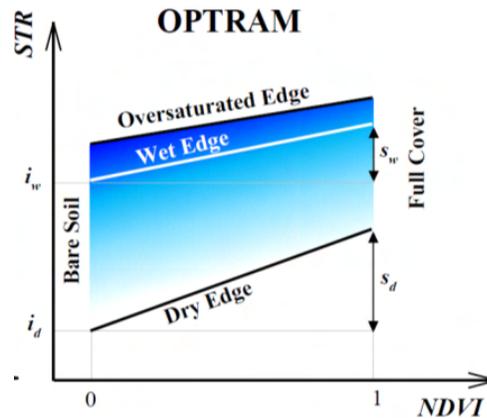


Figura 4: Boceto de los parámetros del modelo trapezoidal óptico (OPTRAM). Espacio (región) STR-NDVI [51].

El STR está relacionado con la reflectancia SWIR de la siguiente manera:

$$STR = \frac{(1 - R_{SWIR})^2}{2R_{SWIR}} \quad (9)$$

Este modelo, se basa en la interpretación de la distribución de píxeles de la superficie terrestre en un espacio de contenido de agua e índice de vegetación (STR-NDVI). Donde NDVI es el índice de vegetación de diferencia normalizada calculado como  $NDVI = (NIR-Red) / (NIR+Red)$  y STR es la reflectancia transformada de infrarrojo de onda corta (SWIR). La humedad del suelo para cada píxel se estima como una función de STR y NDVI [26]:

$$W = \frac{i_d + s_d NDVI - STR}{i_d - i_w + (s_d - s_w) NDVI} \quad (10)$$

Donde ( $i_d$  y  $s_d$ ) son los bordes secos y ( $i_w$  y  $s_w$ ) son los bordes húmedos .

### 3. Trabajos Relacionados

Con el avance en la resolución de las imágenes de satélite y aumento de la cantidad de datos, se han realizado esfuerzos recientes de estudio en análisis y extracción características de las imágenes de satélite. Las imágenes de satélite son consideradas la principal fuente de adquisición de información geográfica [5], y hay muchas aplicaciones de análisis de imágenes de satélite en el campo de la ingeniería civil, construcción, urbanismo y gestión de los recursos hídricos o desastres naturales. Una de las aplicaciones específicas es para la detección de sequía y las características o variables relacionadas a esta. Se han realizado diversos estudios y métodos para identificar y predecir diferentes categorías de sequía incluidas la sequía meteorológica (déficit de precipitaciones), agrícola (déficit de humedad del suelo), hidrológica (déficit de escurrimiento) y socioeconómica (suministro de agua, la demanda y la respuesta social) [52]. Estos métodos o estudios se pueden agrupar en análisis con datos *in situ*, modelos de predicción y técnicas de percepción remota.

El análisis *in situ* utiliza observaciones puntuales en tierra o datos interpolados, principalmente desde perspectivas meteorológicas y agrícolas en donde a partir de las observaciones se obtienen condiciones de sequía o análisis de series de tiempo [53, 54, 55, 56]. En los métodos de predicción usualmente se utilizan modelos o pronósticos de variables físicas como la lluvia donde aplican regresión lineal, series de tiempo, modelos probabilísticos o técnicas de aprendizaje automático [57, 58, 59]. Por otra parte, las observaciones satelitales de percepción remota ofrecen una alternativa al proporcionar un conjunto de datos para estudiar sequías y sus impactos en ecosistemas. Las observaciones obtenidas de imágenes satelitales dan pie para el análisis de la biofísica del fenómeno de la sequía y la obtención de indicadores de sequía para la investigación y aplicaciones prácticas. Los datos satelitales ópticos, infrarrojos térmicos o de microondas se han utilizado para recuperar variables relacionadas con la sequía incluyendo precipitación, humedad del suelo, o evapotrans-

piración [4, 5, 6, 7, 8]. Algunos estudios de análisis *in situ*, predicción y percepción remota (datos satelitales) realizan el cálculo de índices donde posteriormente hacen uso de algoritmos de aprendizaje automático como Random Forest, Redes Neuronales o predicción con filtros Kalman [57, 59, 60]. Otros estudios analizan los índices (como Porcentaje de Disponibilidad de Agua, Índice de Vegetación) por separado o las anomalías temporales de estos [61, 62, 63].

El análisis de datos *in situ* es ampliamente utilizado por organismos meteorológicos e instituciones hidrológicas para observar las condiciones de sequías. Sin embargo, existe escasez de datos por falta de mediciones o por difícil acceso al lugar de interés y no brindan información suficiente sobre los efectos de la sequía en vegetación. Por otro lado, aunque los modelos predictivos son prometedores requieren un gran número de observaciones de entrada, de lo contrario se ha observado que tienden a deficiencias en predecir condiciones muy húmedas o secas. Finalmente las ventajas de las imágenes satelitales obtenidas a partir de sensores remotos en relación con las observaciones terrestres tradicionales incluyen observaciones globales, registros de datos consistentes, y acceso a lugares geográficos inaccesibles [9]. En varios de estos estudios hacen estimaciones robustas, sin embargo, necesitan de datos auxiliares (*in situ*, mapas, entre otros), hacer reanálisis de datos o productos y necesitan una gran cantidad de datos de entrada de diferentes características (como precipitación, evapotranspiración y humedad del suelo) para generar indicadores de sequía. Además, son estudios por lo general de baja resolución espacial y de lugares geográficos específicos donde los resultados pudieran no ser aplicables a todas las zonas o áreas.

### **3.1. Métodos de estimación de humedad**

En la imagen satelital, el proceso de análisis y extracción de información juega un papel importante para lograr una buena interpretación del contenido de la ima-

gen. La información o características extraídas de las imágenes son aquellas cosas que definen distintivamente un fenómeno u objeto presente en la imagen, como el tamaño, la forma, la composición, la ubicación, entre otros. La extracción de información se puede definir como una técnica de procesamiento de imágenes que se utiliza para detectar y clasificar las relaciones o el significado en relación con las áreas de la imagen. Con esto se pretende adquirir una descripción, no redundante y significativa de las interpretaciones. La información o características que se obtienen en una imagen satelital comprenden principalmente estructuras e instalaciones (como edificios, aeropuertos), presencia de fenómenos (como inundaciones, sequías), uso del suelo, cobertura terrestre (como vegetación, cuerpos de agua), presencia de minerales, contenido de humedad del suelo, entre otros [64].

Para obtener información con respecto al contenido de humedad se han propuesto diversas técnicas de estimación de humedad del suelo. Enfoques convencionales se mide directamente utilizando instrumentación terrestre (*in situ*) por ejemplo, medidas puntuales con sensores electromagnéticos de humedad del suelo, métodos hidrogeofísicos y tomografía de resistividad eléctrica [65]. Por otro lado, se encuentran las técnicas para estimar la humedad del suelo con imágenes satelitales que incluyen las técnicas de aprendizaje automático y las técnicas tradicionales. Los métodos de aprendizaje automático utilizan algoritmos como Multicapa Perceptrón (MLP), Red Neuronal Convolutiva (CNN) o Modelos de Regresión Lineal para la estimación de la humedad del suelo en función de su respuesta espectral o con datos auxiliares de entrada [66, 12]. Dentro de los métodos tradicionales se encuentran el uso de índices relacionados con la humedad derivados de imágenes satelitales como el Índice de Diferencia Normalizada de Vegetación (NDVI, por sus siglas en inglés) o Índice de Agua de Diferencia Normalizada (NDWI, por sus siglas en inglés), entre otros [10, 19]. Además, los métodos que utilizan modelos para estimación en base a diferentes parámetros o variables físicas relacionados con la humedad. Algunos trabajos hacen estimaciones en base a una variable como la temperatura superficial

el suelo (LST, por sus siglas en inglés) utilizando un software especializado o un sistema de información geográfica [10]. Por otro lado, se utiliza también el método del triángulo (NDVI-LST) que se basa en las relaciones físicas que existen cuando una temperatura de la superficie terrestre derivada de un satélite se grafica contra un índice de vegetación espectral [19, 20, 21].

De las diversas técnicas utilizadas para estimación de humedad del suelo, los enfoques de medición puntual se puede considerar la forma más directa y precisa de medir, sin embargo, su uso en grandes áreas es limitado, principalmente debido al costo de mantener el equipo de campo por que requiere un proceso de muestreo periódico y porque las mediciones reales son escasas debido a la falta de sensores *in situ*. Por ello hay interés en desarrollar metodologías simplificadas que puedan aplicarse en regiones con escasez de datos. En los métodos utilizados con aprendizaje automático usualmente se toma en cuenta los cambios de reflectancia para la estimación de humedad o se utilizan datos auxiliares como mapas de tipos de suelo que pudieran no estar siempre disponibles. Además, se necesitan obtener gran cantidad de datos de entrada para los algoritmos. En los enfoques tradicionales los modelos basados en relaciones físicas suelen preferirse a los modelos empíricos. Dentro de estos se encuentra el método llamado Triángulo, que es ampliamente utilizado para estimar la humedad del suelo donde se combinan parámetros. Sadeghi en 2017 propuso un modelo modificado llamado Modelo Óptico TRapezoidal donde sustituye el LST por la reflectancia transformada del infrarrojo de onda corta (STR). Este método se ha utilizado para analizar la dinámica espaciotemporal y la distribución de estimación de humedad del suelo que será de interés en esta investigación. En la Tabla 2 se pueden ver algunos trabajos relacionados con el método Trapezoidal que contiene las propiedades de estudio de aplicación, método de obtener de la región trapezoidal y los resultados obtenidos.

Tabla 2: Trabajos de Estimación de Humedad con Método Trapezoide

Referencia	Estudio	Región Trapezoidal	Resultados
Sadeghi et. al. [67] (2018)	Evaluar la parametrización OPTRAM con datos MODIS en monitoreo de la sequía agrícola	Inspección visual y NDVI	RMSE <sup>1</sup> - entre 0.050 a 0.085 $cm^3 cm^{-32}$ , R <sup>3</sup> - entre 0.10 a 0.70.
Babaeian et. al [19] (2019)	Aplicación de agricultura de precisión a escala de campo	Ajuste manual	RMSE - entre 0.045 a 0.057 $cm^3 cm^{-3}$
Minnolo et. al. [68] (2019)	Mapear áreas irrigadas con Sentinel 2	Clasificación no supervisada con ISODATA sobre los datos de NDVI y ajuste manual	precisión global del 70%
Acharya et. al [69] (2022)	Predecir humedad del suelo con Landsat 8	Umbral de valores de NDVI	RMSE entre 0.013 y 0.031, R < 0.2

La principal motivación del estudio de Sadeghi et. al. [67] (2018) fue evaluar cómo la parametrización del método trapezoide funciona durante largos períodos de tiempo (por ejemplo, varias décadas). En este estudio, las observaciones del satélite MODIS fueron adquiridas y utilizadas para el análisis. Los resultados fueron comparados contra humedad del suelo medida *in situ* y con otros productos de humedad como humedad del suelo activa y pasiva de SMAP y SMOS (Soil Moisture Ocean Salinity). Además, los datos de humedad del suelo generados se analizaron para detectar posibles seguimientos de la sequía agrícola a través de la comparación con el Índice de Humedad de Cultivos (CMI). La región y los parámetros del trapezoide fueron

<sup>1</sup>Erro Cuadrático Medio

<sup>2</sup>Contenido volumétrico de agua

<sup>3</sup>Coefficiente de Correlación

optimizados visualmente y se realizaron pruebas de sensibilidad modificando las regiones de bordes secos y húmedos. Se observan correlaciones para diferentes niveles de incertidumbre. Los valores promedio de RMSE en diferentes cambios de regiones de bordes en el espacio trapezoidal fueron de 0.007, 0.010, 0.012 y 0.025  $\text{cm}^3 \text{cm}^{-3}$ . Los resultados generales de la evaluación fueron de 0.050 a 0.085  $\text{cm}^3 \text{cm}^{-3}$  en RMSE y entre 0.10 a 0.70 de coeficiente de correlación (R), respectivamente, para todos sitios los investigados.

El estudio de Babaeian [19] tiene como objetivo la evaluación de método trapezoide para aplicaciones de agricultura de precisión a escala de campo que utilizan tecnología óptica de resolución espacial ultra alta obtenidas con un escáner robótico de campo. Reemplazaron el NDVI por el índice de vegetación ajustado al suelo (SAVI) y las regiones o bordes húmedos y secos fueron ajustados manualmente. La exactitud de las estimaciones se evaluó en función de una comparación con mediciones de referencia terrestre. Los resultados obtenidos indican un error de estimación entre 0.045 y 0.057  $\text{cm}^3 \text{cm}^{-3}$  para la zona cercana a la superficie y la raíz, respectivamente. Demostraron que el marco presentado se puede aplicar con las observaciones del Sistema Aéreo No Tripulado (UAS) para ayudar al manejo preciso del riego.

Minnolo et. al. [68] presenta un enfoque para el mapeo de áreas irrigadas en alta resolución bajo diferentes condiciones climáticas, con base en el uso de la clasificación no supervisada en series temporales de NDVI. Este trabajo probó el método para obtener mapas de las áreas regadas con una precisión global del 70 %. En algunos resultados se compararon con los datos de riego encontrando una sobreestimación de áreas regadas del 21 % durante las temporadas de riego.

El objetivo del estudio de Acharya et. al [69] fue calcular y determinar la efectividad de los índices relacionados con la humedad, predecir humedad de superficie a partir de imágenes satelitales utilizando el modelo trapezoidal óptico, y evaluar las predicciones incorporando información meteorológica de datos de estaciones, suelos

y cultivos con un algoritmo de bosque aleatorio. Para el análisis, se utilizaron valores de NDVI para filtrar y omitir los píxeles sin vegetación o suelo (por ejemplo, superficies de agua, nieve, roca). Los resultados mostraron una relación muy débil entre los índices relacionados con la humedad y la superficie. La humedad obtenida por el método trapezoide en comparación con humedad superficial *in situ* mostró una relación débil con valores de regresión  $<0.2$ . La humedad del suelo luego se pronosticó usando Random Forest con valores de humedad estimados, precipitación medida, el Índice de Precipitación Estandarizado (SPI) y el porcentaje de arcilla mostraron una alta bondad de ajuste ( $r^2 = 0.69$ ) y error cuadrático medio (RMSE =  $0.053 \text{ m}^3 \text{ m}^{-2}$ ).

### **Discusión**

El método trapezoide tiene la capacidad de mostrar una diferencia entre húmedo o seco. Además, se puede aplicar solo teniendo como entrada imágenes satelitales y permite la transferibilidad en el tiempo y el espacio. Este método es utilizado tanto para estudios donde utilizan el método de manera individual o como dato de entrada para otros algoritmos de aprendizaje automático. Además teniendo la posibilidad de combinar diferentes parámetros como en donde reemplazan el NDVI por el SAVI [19]. Esto representa una herramienta poderosa que puede cubrir una gran área de estudio y procesar una gran cantidad de datos para la predicción de la humedad. En el estudio [68] se debe considerar algunas incertidumbres en la metodología o fuente de error podrían provenir de imprecisiones de la clasificación no supervisada que no permite una distinción clara del tipo de vegetación o cultivo, afectando los parámetros de OPTRAM ( $i_d, s_d, i_w, s_w$ ). En este sentido, el uso de métodos supervisados podría mejorar la precisión. Las pruebas de sensibilidad en [67] del método trapezoide muestran que hay cambios en las correlaciones entre las estimaciones de humedad del suelo, estas no son altamente significativos sin embargo estas pruebas se hicieron con ajustados visuales. La adaptación visual da como resultado estimaciones aceptables de la humedad del suelo, sin embargo, introduce sesgos del usuario

y conduce a cierto grado de incertidumbre de los resultados del modelo. Babaeian et. al [19] Mencionan que cuanto más homogéneos sean el suelo y la vegetación, obtener las condiciones en los campos agrícolas con las observaciones de ultra alta resolución espacial alivian los problemas con la parametrización OPTRAM que se presenta ocasionalmente para observaciones satelitales a gran escala y de baja resolución, como sobresaturación del borde húmedo o incertidumbre asociada con píxeles de la imagen que no pertenecen al suelo ni a la vegetación (por ejemplo, cuerpos de agua superficiales, carreteras o edificios). En general, la integración del modelo trapezoide con otros parámetros u otras metodologías como el aprendizaje automático parecen ser una herramienta confiable para estimar humedad del suelo. Sin embargo, se deben enfocar esfuerzos de investigación dirigidos en resolver los problemas de espacio STR-NDVI del modelo trapezoide.

### **3.2. Métodos de segmentación de cobertura terrestre**

La interpretación por computadora de las imágenes satelitales se conoce como análisis cuantitativo debido a su capacidad para identificar píxeles con base en sus propiedades digitales que representan la cobertura del suelo y debido a su capacidad para contar píxeles para estimaciones de área. También se le llama generalmente segmentación semántica o clasificación, que es un método por el cual las etiquetas se pueden unir a los píxeles en vista de su carácter espectral. La segmentación semántica es una de las técnicas utilizadas para la extracción de información importante en las imágenes satelitales y se puede clasificar en diferentes categorías sobre la base de diferentes criterios [70]. El Tabla 3 ofrece una descripción general de los métodos en función diferentes criterios y categorías.

Tabla 3: Métodos de segmentación semántica en función diferentes criterios y categorías

Categoría	Descripción	Algoritmos
<i>Uso de muestras de entrenamiento</i>		
Supervisado	Se proporcionan datos de referencia sobre clases de cobertura terrestre. El algoritmo separa los píxeles entre sí en función de las muestras de entrenamiento que denotan un tipo de cobertura del suelo.	MV <sup>4</sup> , AD <sup>5</sup> , MSV <sup>6</sup> , RNA <sup>7</sup> , RNCV <sup>8</sup> .
No Supervisado	Los píxeles se integran de acuerdo con las propiedades de reflectancia. Estos grupos se denominan individualmente como Clusters. Es responsabilidad del analista etiquetar y fusionar las clases espectrales en las clases deseadas.	ISODATA, k-media, ACP <sup>9</sup>
<i>Utilización de diferentes parámetros</i>		
Paramétricos	Generación de parámetros a partir de muestras de entrenamiento	MV, ADL <sup>10</sup>
No paramétricos	No necesita parámetros estadísticos para calcular la separación de clases	RNA, RP <sup>11</sup> , MSV, AD, Sistemas expertos
<i>Tipo de información de píxeles</i>		
Basada en píxeles	Esta técnica utiliza las estadísticas de reflectancia para píxeles particulares. La firma espectral cuenta con la aportación de cada tipo de cobertura o material dentro de los píxeles de los conjuntos de entrenamiento.	MV, Mínima distancia, RNA, MSV, K-media, ISODATA, Paralelepípedo
Clasificadores de subpíxeles	El valor espectral del píxel se toma como lineal/no lineal con la integración de los materiales puros mencionados con pertenencia proporcional.	CCD <sup>12</sup> , AME <sup>13</sup> , clasificadores de subpíxeles
Clasificación dura	<i>Salida es específica para la clase de cobertura terrestre</i> Cada píxel debe asignarse a la clase única. La estimación del área puede dar lugar a errores a partir de datos de baja resolución espacial debido al problema de la mezcla de píxeles.	ARN, MSV, AD, MP

<sup>4</sup>Máxima verosimilitud

<sup>5</sup>Árboles de decisión

<sup>6</sup>Máquina de vectores de soporte

<sup>7</sup>Redes Neuronales Artificiales

<sup>8</sup>Red neuronal convolucional

<sup>9</sup>análisis de componentes principales

<sup>10</sup>Análisis Discriminante Lineal

<sup>11</sup>Razonamiento probatorio

<sup>12</sup>Conjunto de clasificadores difusos

<sup>13</sup>Análisis de mezcla espectral

Clasificación suave	Se proporciona un grado de similitud para cada clase. Permiten descomponer a píxeles mezclados según las coberturas de suelo donde se utilizan funciones de pertenencia.	CCB, AME, clasificadores de subpíxeles
<i>Utilización de espacios de Información</i>		
Clasificadores espectrales	Uso de información espectral en la clasificación de imágenes.	MP, Mínima distancia, ARN
Clasificadores contextuales	Uso de información de espacialmente vecina.	CCDF <sup>14</sup>

La extracción de información en la imagen es un factor significativo para lograr el reconocimiento de objetivos o fenómenos en la imagen. La segmentación semántica es conocida como uno de los problemas principales en el procesamiento de imágenes. En las últimas décadas se han desarrollado varios métodos de segmentación, como algunos de los mencionados en la tabla anterior. En aplicaciones prácticas para imágenes satelitales, la segmentación es difícil de automatizar por las características propias de la imagen dado que su resolución espacial es mayor, pero su resolución espectral es menor, y las características de la textura de la superficie de los objetos pequeños no son diferenciables. Estas propiedades conducen a una variabilidad intracase maximizada y una separabilidad interclase minimizada. Esta investigación se centra en mejorar el desempeño de la segmentación del algoritmo de máxima verosimilitud dado que es uno de los algoritmos tradicionales más utilizados en la práctica en imágenes satelitales.

### 3.2.1. Métodos estadísticos espectrales de segmentación de cobertura terrestre

El enfoque espectral considera modelos que sólo utilizan las bandas de la imagen como espacio de representación para realizar la segmentación. Dentro de este enfoque se han empleado modelos estadísticos como distancia mínima, k-means, ISO-DATA, parelepípedos y máxima verosimilitud [71, 72]. Estos métodos son métodos tradicionales empleados para la obtención de mapas temáticos y para los modelos

---

<sup>14</sup>Clasificadores contextuales dependientes de la frecuencia

de segmentación programados dentro de aplicaciones especializadas para el procesamiento de imágenes de percepción remota como por ejemplo el software ERDAS IMAGINE [18] y GRASS (Geographic Resources Analysis Support System o Sistema de Apoyo para Análisis Geográfico de Recursos) [38, 39, 40]. En la Tabla 4 se presentan referencias sobre estos métodos indicando el método supervisado (S) o no supervisado (NS), la distancia que utilizan en su función de clasificación y la precisión en los resultados con el coeficiente kappa.

Tabla 4: Métodos Tradicionales Estadísticos Espectrales

	<b>K-means</b>	<b>ISODATA</b>	<b>Mínima Distancia</b>	<b>Paralelepípedos</b>	<b>Máxima Verosimilitud</b>
Referencia	[35, 37]	[35, 36, 37]	[35, 73, 74]	[35, 75]	[35, 37, 43, 75, 76, 74]
Método	NS	S	S	S	S
Distancia	Euclidiana	Euclidiana	Euclidiana	Desviación estándar	Desviación estándar
Kappa	0.5895 ±0.05	0.5987 ±0.05	0.70 ±0.05	0.71 ±0.05	0.7512 ±0.05

En las técnicas de agrupamiento (Clustering) como k-medias e ISODATA (Interactive Self-Organizing Data Analysis Technique) la imagen es segmentada en clases desconocidas que posteriormente serán etiquetadas [35, 36, 37]. El método ISODATA tiene la dificultad del gran volumen de cálculo que precisa, donde a partir de la quinta iteración los cálculos son mayores que para la clasificación de máxima verosimilitud. Estos métodos son adecuados para delimitar los grupos de valores homogéneos dentro de la imagen, sin embargo, el usuario no conoce inicialmente, el número de grupos espectrales presentes en la imagen, ni el valor idóneo de dispersión interna o distancia entre grupos. De esta forma, el análisis no supervisado se convierte en un proceso interactivo, en donde el usuario establece unos valores arbitrarios que se van modificando a la luz de los resultados.

Por otra parte están los métodos supervisados como el de mínima distancia que es uno de los más antiguos y hoy se considera en desuso salvo para propósitos docentes

y para comparar con el resto de los métodos [35, 35, 73, 74]. El método Paralelepípedos (a menudo denominado corte multinivel) divide cada eje del espacio de características multispectrales y la exactitud de clasificación depende de la selección del umbral más bajo y valores más altos en consideración de las estadísticas de población de cada clase. La principal desventaja de este método es que se pueden presentar empates entre probabilidades o quedar píxeles como no clasificados [35, 75]. El método de clasificación por Máxima Verosimilitud parte del supuesto de que los valores de reflectividad en cada una de las clases siguen una distribución de probabilidad normal multivariante [35, 37, 74, 76]. Utiliza el vector de medias y la matriz de varianzas-covarianzas para estimar la probabilidad de que un píxel dado pertenezca a cada una de las clases. Se pueden establecer umbrales de probabilidad para cada categoría, rechazando los píxeles con una probabilidad muy baja, evitando de esta manera que se clasifiquen píxeles en clases en las que realmente no pertenecen. La probabilidad máxima puede utilizarse como indicador de la certeza en la clasificación. El método de Máxima Verosimilitud es el más utilizado en percepción remota; sin embargo, el supuesto básico de distribución normal de los valores de píxeles no siempre se cumple.

En la comparación de los métodos de estadísticos para clasificación de cobertura, podemos observar que los métodos supervisados Máxima Verosimilitud y Paralelepípedos tienen mayor precisión que los no supervisados, en donde dentro de los no supervisados el que tiene peor desempeño es el de K-means seguido de ISODATA. Cabe señalar que en los métodos supervisados también influye que las muestras de entrenamiento sean apropiadas ya que se tiene que representar características espectrales muy variables entre los tipos de cobertura. Entre este grupo de métodos el que tiene mejores resultados es el de Máxima Verosimilitud. Este método se considera uno de los más utilizados en el área de percepción remota en la segmentación de coberturas entre los segmentadores que utilizaban sólo los valores espectrales. Sin embargo, uno de los problemas con estos algoritmos, es que sólo consideran la

información disponible de los datos observados con base en valores de píxel. Los métodos comúnmente empleados para la segmentación de coberturas de la tierra se ven limitados cuando en el problema de segmentación se trabaja con coberturas espectralmente similares y emplean únicamente la información de los datos observados. Es decir, los niveles de gris en las bandas espectrales pueden no ser suficiente para lograr una segmentación satisfactoria. Es necesario que las metodologías y algoritmos actualmente desarrollados busquen incrementar el porcentaje de segmentación correcta de coberturas espectralmente para obtener coberturas mejor segmentadas.

Tabla 5: Trabajos con Método Máxima Verosimilitud

Referencia	Cobertura	Imágenes	Resultados
Gijón [76] (2018)	Cobertura Forestal	SPOT 7	precisión global promedio 84.6 % y kappa promedio de 81.5 %,
Maestri et. al. [37] (2019)	Laguna Cuerpo de agua	Landsat (4TM, 5TM y 7ETM+)	ER <sup>15</sup> - 10.49, EG <sup>16</sup> - 3.15
Hussain et. al [43] (2022)	Vegetación, suelo desnudo y cuerpos de agua	Landsat 5,Landsat 7 (TM), and Landsat 8 (OLI)	Kappa - entre 80.7 % y 85.3 %
Del Toro Espín et. al [74] (2022)	Bosque, Matorral, Cultivo, Urbano, Agua, Suelo desnudo	Landsat TM	kappa 0.656, % de acierto 72.93

En [37] se presenta un análisis comparativo de cinco métodos computacionales para determinar la superficie de agua libre a partir de la aplicación de los índices NDWI (Índice de Diferencia Normalizada de Agua) y MNDWI (Índice de Diferencia Normalizada de Agua Modificado) con métodos supervisados (Máxima Verosimilitud) y no supervisados (ISODATA y K-means) en imágenes Landsat (4TM, 5TM y 7ETM+) a lo largo del período 1984-2004. Esto permitió evaluar la capacidad de cada uno de estos satélites para seguir la dinámica del área superficial e identificar el método que consume menos tiempo computacional y minimiza posibilidades de error en la implementación. Tomando en cuenta los errores máximos, tanto absolu-

---

<sup>15</sup>Error Relativo

<sup>16</sup>Error Global

to ( $EA(i)$ ) como relativo ( $ER(i)$ ), que indican puntualmente lo que ocurre en una fecha  $i$ , el clasificador Máxima Verosimilitud aparenta ser el más preciso. Sin embargo, esto no muestra la eficiencia real de este método dado que cuando se evalúa el rendimiento sobre la serie completa de imágenes los resultados de este método no se comportan de la misma manera. En sus resultados el NDWI, ISODATA y Máxima Verosimilitud presentan a su vez los mayores valores acumulados de error como sigue: ISODATA ER- 12.98 EG-3.20, Kmeans- ER- 14.55 EG- 2.70, MaximaVerosimilitus- ER-10.49 EG-3.15.

Hussain [43] presento un estudio donde utiliza herramientas de percepción remota y Sistema de Información Geográfica para aplicar la clasificación de Máxima Verosimilitud (MLC) para identificar los cambios de Uso del Suelo y de la Cobertura terrestre (LULC) . Se seleccionaron las bandas uno a cinco y siete para la evaluación y las banda dos a la banda nueve para los cambios de en usos de suelo. Todos los datos satelitales se estudiaron mediante la asignación de firmas por píxel. y selecciones de sitios de entrenamiento para los años 1981, 2001 y 2021. Para vegetación, suelo desnudo y cuerpos de agua cuerpos de agua las imágenes clasificadas se compararon con verificación del terreno (visita de campo) del área de estudio.

Gijón [76] utilizó imagenes SPOT 7 de dos fechas diferentes y realizo una clasificación no supervisada con modelo isodata, para determinar la superficie de cada clase y proceder al cálculo del tamaño de la muestra mediante la distribución multimodal. Además, utilizó métodos supervisados, los modelos de Maxima verosimilitud y Redes Neuronales Artificiales backpropagation (RNA). La precisión global promedio del primer modelo fue de 84.6 % y un coeficiente kappa promedio de 81.5 %, mientras que, para el modelo de Redes Neuronales se obtuvo una precisión global promedio de 86.5 % y un coeficiente kappa promedio de 83.8 %. Con base en el modelo RNA y el modelo digital de elevaciones, se determinaron las áreas con una pendiente mayor al 15 %, que se denominaron Zonas sin cubierta vegetal con vocación forestal.

En [74] Del Toro Espín realiza una clasificación de usos del suelo comparando los métodos Random Forest de aprendizaje automático y un método de clasificación contextual: SMAP, el método de máxima verosimilitud y K-means. Por otra parte, se estudia como la incorporación de información relativa a la textura pueden mejorar la clasificación de SMAP y Random Forest. Se obtuvieron dos capas de información textural utilizando la función semivariograma: Esta función se aplicó a dos bandas derivadas de las originales y que resumen gran parte de la información útil que contiene la imagen aplicando Análisis de Componentes Principales (ACP) sobre las capas de reflectividad. La validación tuvo algunas discrepancias ya que los mapas de referencia eran de fechas diferentes al estudio. Los métodos que, de forma global, obtienen mejores resultados son Random Forest (P=79.1) y SMAP (Porcentaje de acierto=80). Ambos métodos mejoran si se introducen variables de textura, sobre todo SMAP (P=83.4), si bien la mejora que se observa no es muy importante. El método de máxima verosimilitud da unos resultados algo inferiores (P=72.9). En el trabajo de porcentaje de ocupación se presentan problemas de sobreestimación en zonas de matorrales, arbóreo y zonas de bosque seco en donde se presentan discrepancias utilizando cualquiera de los métodos, el suelo desnudo resulta muy infraestimado en todos los casos.

### **Discusión**

La identificación de cobertura de superficie de una serie de clases relativas a tipos de cobertura terrestre es uno de los objetivos fundamentales en el análisis de imágenes satelitales para diferentes objetivos de investigación. La identificación de coberturas de tierra tiene como objetivo general categorizar píxeles en un conjunto de clases en función de una serie de variables cuantitativas. Para resolver este problema se necesita una medida de la semejanza o diferencia entre los diferentes píxeles y entre los píxeles y las clases. Cada algoritmo utiliza una medida o distancia para asignar los píxeles a las diferentes clases. En la práctica se puede complicar saber con certeza a que clase corresponde cada uno de los píxeles, entonces se tiene una

probabilidad de pertenencia a cada una de las clases de un conjunto, por tanto, se suelen usar métodos estadísticos.

Una de las ventajas de los algoritmos espectrales es que se basan en la firma espectral que forma parte del comportamiento característico de las coberturas terrestres en la imagen y esto es independiente de la resolución espacial. Además, en los métodos supervisados se pueden utilizar procesos estadísticos basados en un conocimiento a priori de las funciones de distribución de probabilidad para extraer descriptores de clase.

Los resultados reportados, aunque son buenos, no son tan satisfactorios para todos los casos, dado que aún hay errores de comisión por lo cual se puede buscar mejorar los métodos combinando información de diferentes contextos. Los métodos pueden confundir diferentes clases de cobertura como urbano con suelo desnudo o tener conflictos en identificar cultivos por falta de humedad. Además, resulta difícil distinguir entre tipos de cobertura vegetal con diferente contenido de humedad como los matorrales de los herbáceos tanto en seco como en regadío. Por otra parte, una de las desventajas de los algoritmos no supervisados es que hay que tener una mayor intervención del analista para asignar etiquetas finales de cobertura y eso no es práctico cuando se quiere automatizar un procedimiento o no hay mucho conocimiento del área de estudio.

Los métodos mencionados solo utilizan los valores de reflectividad recogidos en cada píxel. Este hecho es útil y da buenos resultados sin embargo puede causar problemas cuando el tamaño del píxel es menor que los diferentes elementos físicos que componen el área tomada en la imagen. Es entonces donde se podría utilizarse información de los píxeles de alrededor para estimar la pertenencia a una clase o confirmar la estimación. En este sentido, se ha demostrado que utilizar información de textura como en los algoritmos Random Forest y SMAP mejoran los resultados [74], por lo que se puede considerar tomar la textura como información adicional a otros

algoritmos en vías de mejorar su desempeño. La información contextual puede ayudar a homogeneizar las áreas cercanas y a generar regiones más grandes. Al tener en cuenta la información textural o contextual se puede hacer referencia a las características de la vecindad del píxel y tener el contexto espacial en el que se encuentra el píxel.

El algoritmo de Máxima Verosimilitud es un método actualmente muy utilizado en imágenes satelitales. En comparación con otros métodos de aprendizaje y con métodos basados en objetos tiene menor precisión, sin embargo, tiene los mejores resultados dentro de los métodos estadísticos espectrales. Aunque este método tiene resultados aceptables, hay oportunidad de mejorar su desempeño. En ese sentido, se puede considerar agregar información textural al método de Máxima Verosimilitud ya que esto permitiría incluir la información de los píxeles circundantes. Esto podría ayudar a tomar una decisión en caso de que las probabilidades para dos clases sean similares o no exista una clase con probabilidades de pertenencia suficientemente altas.

## **4. Propuesta de Investigación**

### **4.1. Metodología**

Cualquier estudio con imágenes satelitales requiere metodologías de extracción de datos y de disposición semántica eficiente para recuperar información sobre el área de estudio en la superficie terrestre. La disposición semántica de las imágenes se utiliza en varios dominios del procesamiento de imágenes digitales y de visión por computadora, como la detección remota, el reconocimiento de objetos o análisis de área de interés. El análisis de imágenes es un proceso multinivel que comienza desde preprocesamiento para mejorar la imagen, extraer características de las imágenes hasta clasificarlas en categorías (como tipos de cobertura, niveles de humedad o de riesgo, entre otros). Para este proceso es necesario seleccionar las áreas deseadas de esas imágenes y generar grupos iniciales. Después, se aplica un algoritmo a las imágenes para obtener la clasificación deseada y finalmente se evalúa la precisión de esta clasificación. A continuación, se describe la metodología propuesta vista en la Figura 5 que permitirá llegar a los objetivos de esta investigación.

#### **Paso 1 Análisis previo del problema:**

Se realiza un análisis de las características del problema para que sirva como base en la realización de la metodología propuesta. Se buscará determinar los puntos y recursos necesarios para resolver el problema como fuente y disponibilidad de datos y la identificación de datos que pertenecen al problema. Además, investigación sobre métodos para detección de sequía, estimación de humedad y algoritmos de segmentación semántica. En general comprender el dominio de la aplicación y adquirir el conocimiento previo necesario.

#### **Paso 2 Recolección y selección de imágenes:**

Selección y recopilación de imágenes digitales satelitales. En esta etapa se tendrán

que definir los periodos de tiempo adecuados para tener un conjunto de imágenes con diferentes condiciones de humedad. Además, coleccionar datos *in situ* y otros datos de referencia sobre tipos de cobertura o humedad del suelo para la validación de resultados.

### **Paso 3 Pre-procesamiento de imágenes:**

En la etapa de pre-procesamiento la idea fundamental es obtener datos limpios y reducción de datos. En el pre-procesamiento se deben tener los datos de referencia y las imágenes listas para ser utilizadas en procesamiento, análisis e interpretación. En esta se realizará corrección y mejoramiento de imágenes para reducción ruido y la extracción de regiones de interés.

### **Paso 4 Extracción y análisis de parámetros de Textura:**

Este es un proceso esencial, en donde se realizará extracción de descriptores de textura y análisis de estos para seleccionar los que mejor describan las coberturas terrestres. Algunos descriptores a evaluar son:

- Patrón Binario Local
- Matriz de Co-ocurrencia de Nivel de Gris
- Modelo teórico de semivariograma

A partir de parches obtenidos de las imágenes de las fechas seleccionadas donde se tiene diferentes contenidos de humedad y diferentes tipos de cobertura se extraerán los descriptores y se realizará un análisis para seleccionar la textura que represente de mejor manera los tipos de cobertura aun con cambios de contenido de humedad.

### **Paso 5 Segmentación Semántica:**

En esta etapa se realizará la implementación y entrenamiento del segmentador semántico estadístico espectral. Se implementará y aplicará el algoritmo de Máxima Verosimilitud en las imágenes satelitales seleccionadas para obtener regiones de

tipos de cobertura como vegetación, suelo desnudo y cuerpos de agua. Además, se realizará una evaluación del desempeño en la categorización de tipos de cobertura comparando con datos de referencia, obteniendo una matriz de confusión y porcentaje de precisión.

### **Paso 6 Integración de Información:**

Se diseñará e implementará una metodología para la combinación de información espectral obtenida con el algoritmo Máxima Verosimilitud y la información textural probando diferentes modelos como bolsas de palabras. Se realizará una evaluación de los resultados en la categorización de tipos de cobertura con matriz de confusión y porcentaje de precisión. Se buscará mejorar los resultados en la segmentación semántica de la etapa anterior.

Uno de los experimentos a realizar en esta etapa es crear un modelo de bolsa de palabras en donde se utilizará el descriptor de textura previamente seleccionado del conjunto de parches obtenidos de las imágenes satelitales. Se formará un diccionario o conjunto de palabras que representen los tipos de cobertura con los descriptores de textura extraídos. Se obtendrá el conjunto de palabras representativas a partir de agrupación o clasificación de los vectores de características obtenidos mediante alguna técnica de clustering y con la de máxima verosimilitud. Una vez que el diccionario está construido, es utilizado para medir la distancia de cada descriptor extraído de una imagen con todas las palabras visuales del diccionario. Cada descriptor quedará representado por la palabra visual cuya distancia sea menor. Para el reconocimiento para cada descriptor de la imagen es necesario buscar la palabra del diccionario más similar. Se evaluará la precisión con un conjunto de imágenes de prueba.

### **Paso 7 Modelo Trapezoidal:**

Se generará la región trapezoidal por medio del segmentador propuesto. Posteriormente se calcularán los parámetros del modelo trapezoidal para la estimación de humedad. Se realizarán experimentos con una serie de imágenes de periodos adecua-

dos que representen diferentes contenidos de humedad en la superficie para aplicar el método trapezoide. Se obtendrá la región llamada trapezoidal sobre las imágenes satelitales multiespectrales con ayuda del segmentador semántico mejorado en donde se buscará principalmente cobertura de vegetación con alta humedad y suelo desnudo con baja humedad. Posteriormente se obtendrán los parámetros requeridos por el modelo trapezoide para estimar la humedad en cada píxel del área de estudio.

### Paso 8 Evaluación de Resultados:

Se realizarán pruebas para evaluar el desempeño de la metodología propuesta y de sus resultados utilizando los datos de referencia recopilados. Se probarán diferentes técnicas de validación como atributos escalares del desempeño donde se obtiene exactitud (accuracy), sesgo (bias); tablas de contingencia 2X2 (Karl Pearson, 1904) donde se obtienen Bias (sesgo), probabilidad de detección (POD), tasa de falsa alarma (FAR), índice crítico de éxito (CSI), y la técnica Receiver Operating Characteristic Curve (ROC) que muestra el porcentaje de falsos positivos y falsos negativos en la detección.

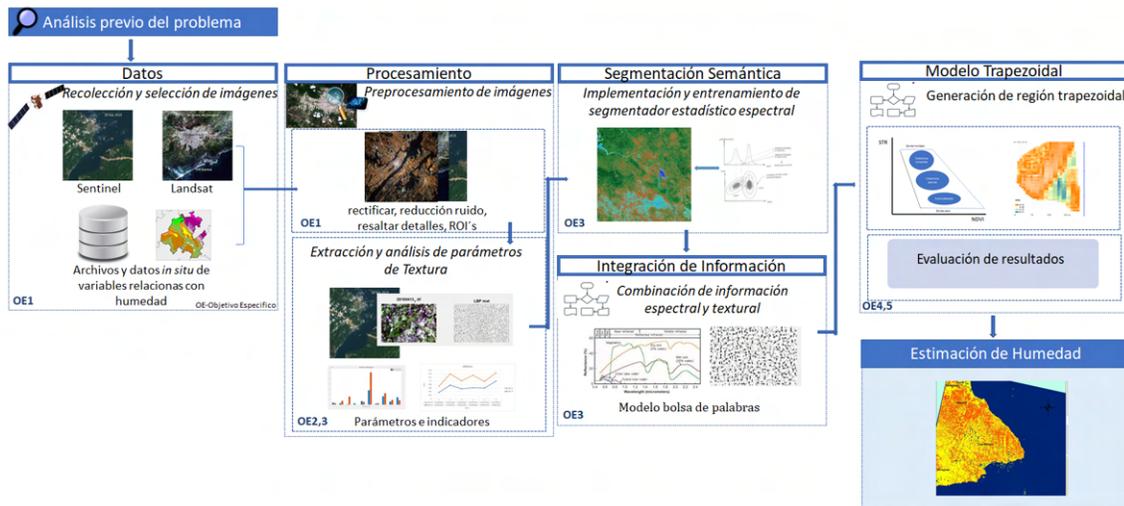


Figura 5: Diagrama de metodología propuesta

## 4.2. Plan de Trabajo

El plan de trabajo se organiza como se visualiza en la Figura 6.

	1		2		3		4	
	1Sem	2Sem	1Sem	2Sem	1Sem	2Sem	1Sem	2Sem
<b>Antecedentes</b>								
Estado del Arte								
Propuesta								
<b>Propuesta de Investigación</b>								
Preparación								
Defensa								
<b>Desarrollo de Tesis</b>								
Selección y recolección de datos e imágenes								
Pre-procesamiento de imágenes								
Extracción y análisis de parámetros de Textura								
Segmentación Semántica								
Integración de Información								
Modelo Trapezoidal								
Evaluación de Resultados								
<b>Preparación de Tesis</b>								
Escritura								
Publicación de Artículo								
Presentación y Defensa								
		Realizadas			En proceso			Por realizar

Figura 6: Cronograma de Actividades

## 4.3. Plan de Publicaciones

**Congreso Internacional** Otoño 2023 - Resultados preliminares de segmentación

**Revista** Otoño 2024 - Metodología propuesta y resultados

**Revista JCR** Otoño 2025 - Resultados finales aplicado al modelo trapezoide para estimación de humedad

## 5. Resultados Preliminares

### 5.1. Recolección y selección de conjunto de datos

Para realizar los experimentos y realizar la metodología computacional propuesta es necesario disponer de un conjunto de datos (datasets) o paquetes de datos. En esta etapa se coleccionaron datos *in situ* iniciales que servirán como referencia en el análisis de periodos de estudio y para la validación de resultados. Con los datos *in situ* recolectados de estaciones meteorológicas se definieron las fechas adecuadas para tener un conjunto de imágenes con diferentes condiciones de humedad. En la Figura 7 se muestra un esquema de los paquetes de datos. Se quiere obtener un conjunto de imágenes satelitales multiespectrales de uso libre en donde se tengan diferentes contenidos de humedad en regiones de coberturas terrestres. Estas imágenes deben estar respaldadas por datos *in situ* con información meteorológica. Para recolección y selección del conjunto de datos iniciales de la investigación se hace el siguiente proceso: a) búsqueda y descarga de datos de estaciones meteorológicas que contengan datos de temperatura, precipitación y humedad, se obtienen promedios de humedad, se realizan gráficas para hacer un análisis de periodos de mayor y menor humedad, se definen fechas para búsqueda y descarga de imágenes, b) búsqueda y descarga de imágenes multiespectrales de las fechas seleccionadas, las imágenes descargadas son las que tienen menor contenido de nubes y con la escena, o frame, centrado a las coordenadas de la estaciones meteorológicas. La disposición para descarga de algunas imágenes tarda de 2 a 20 días, c) Generar parches de diferentes tipos de cobertura sobre las imágenes. Los parches son generados de subimágenes de regiones de interés de tamaño 172x251.

El conjunto de datos recolectado está conformado de 3 paquetes de datos con imágenes satelitales multiespectrales que se obtuvieron de COPERNICUS de ESA [77] y del portal del Servicio Geológico de EE. UU [78], datos meteorológicos del Labora-

torio de Iluminación y Eficiencia Energética del INAOE y los parches de diferentes tipos de cobertura generados en esta investigación. Cada paquete representa una región geográfica y tiene de 12 a 16 imágenes satelitales adquiridas entre Febrero, Marzo, Julio y Agosto de 2021 y 2022 en donde cada imagen tiene 13 bandas espectrales. Los registros de datos meteorológicos contienen datos diarios de precipitación, temperatura y humedad de los años 2020, 2021 y 2022. Además, cada paquete tiene 60 parches generados con 3 bandas espectrales de coberturas de vegetación, vegetación agrícola, suelo desnudo, cuerpo de agua y urbano. Para los primeros experimentos se seleccionaron las bandas rojo, verde y azul ya que son las bandas que forman la composición de color verdadero de las imágenes satelitales.



Figura 7: Esquema de paquete de datos (*dataset*)

## 5.2. Pre-procesamiento de imágenes

Las imágenes satelitales usualmente necesitan de un pre-procesamiento para prepararlas para manipulación, procesamiento y análisis. La descarga de imágenes satelitales puede venir en bandas de forma separada o puede estar en un formato que no es compatible con cualquier aplicación dificultando su manipulación. Por ejemplo, el formato jp2 de las imágenes Sentinel. Por otra parte, la formación de una imagen

satelital está sometida a una serie de distorsiones geométricas y radiométricas que hacen que la información que quiere obtenerse aparezca perturbada por una serie de errores. Hay errores que pueden ser causados por fallos en los sensores, generar píxeles incorrectos o por interferencia de la atmósfera alterando de forma sistemática los valores de los píxeles. Para el pre-procesamiento se hacen pilas o stacks de las bandas de las imágenes para unirlos en un solo archivo. Se convirtió de formato jpg2 a geotiff. Posteriormente se realiza corrección atmosférica (Figura 8) en las imágenes que presentan afectaciones en los colores debido a valores de reflectancia alterados en los píxeles por variaciones estacionales o por la presencia de gases en la atmósfera. La corrección atmosférica se realizó con el método de Substracción de Píxeles Oscuros (o Método de Chávez). Finalmente se generan sub-imágenes para obtener áreas de interés (AOI) o parches para realizar las primeras pruebas de textura. Para esto se generaron *shapefiles* de polígonos para obtener áreas de interés de tamaño 172x251 que corresponden a diferentes áreas sobre el terreno de vegetación, vegetación agrícola, suelo desnudo, cuerpo de agua, zona urbana. Esto con el fin de tener parches de imágenes con diferentes coberturas terrestres y con cambios de humedad que servirán en la investigación. En la Figura 8 se representa el esquema de pre-procesamiento.



Figura 8: Esquema de Pre-procedamiento de imágenes

### 5.3. Extracción y análisis de características de textura

Para resolver el objetivo específico 2 es necesario analizar descriptores de textura para seleccionar el que mejor describa coberturas terrestres de interés mencionadas anteriormente. El objetivo en esta etapa es hacer una selección de características de textura. Por ello se experimenta con el algoritmo *Relieff* ya que es un algoritmo que puede manejar datos incompletos y ruidosos, además, ha dado buenos resultados tanto en conjuntos de datos artificiales como en problemas del mundo real [79, 80]. El método *Relieff* calcula una puntuación para cada característica que se puede aplicar para seleccionar las características de mayor puntuación o peso. La puntuación se basa en la identificación de diferencias de valores de características entre instancias vecinas más cercanas. Si se observa una diferencia en el valor de la característica de instancias vecinas con la misma clase (un 'acierto'), la puntuación de la característica disminuye. Si se observa una diferencia en el valor de la característica en instancias vecinas con diferentes valores de clase (un 'fallo'), la puntuación de la característica aumenta. La idea es favorecer atributos que tengan valores diferentes en ejemplos parecidos de diferente clase y valores iguales en ejemplos parecidos de la misma clase. A continuación se describe el algoritmo *Relieff* (ver Algoritmo 1).

El algoritmo primero establece todos los pesos de los predictores  $W[A]$  en 0. Luego, selecciona aleatoriamente una instancia  $R_i$  (línea 3), busca sus  $k$  vecinos más cercanos de la misma clase, llamados aciertos más cercanos  $H_j$  (línea 4), y también  $k$  vecinos más cercanos de cada una de las diferentes clases, llamadas fallas más cercanas  $M_j(C)$  (líneas 5 y 6). Se actualiza los pesos o estimación de la calidad  $W[A]$  para todos los atributos  $A$  dependiendo de sus valores para  $R_i$ , acierto  $H_j$  y falla  $M_j(C)$  (líneas 7, 8 y 9). Para la actualización se promedia la contribución de todos los aciertos y todas las fallas. La contribución para cada clase de fallos se pondera con la probabilidad previa de la clase  $P(C)$  (estimada a partir del conjunto de entrenamiento). Dado que se quieren las contribuciones de aciertos y fallas en

---

**Algorithm 1** *Algoritmo Relieff [81]*

---

**Entrada:** para cada instancia de entrenamiento, un vector de valores de atributo y el valor clase

**Salida:** el vector  $W$  de estimaciones de las cualidades de los atributos

---

```
1: Establecer todos los pesos  $W[A] := 0,0$ ;  
2: for  $i = 1 \dots m$  do  
3:   Seleccionar aleatoriamente una instancia  $R_i$ ;  
4:   Encontrar  $k$  aciertos más cercanos  $H_j$  ;  
5:   for para cada clase  $C \neq class(R_i)$  do  
6:     de la clase  $C$  encontrar los  $k$  errores más cercanos  $M_j(C)$ ;  
7:   end for  
8: end for  
9: for  $i = 1 \dots a$  do  
10:   $W[A] := W[A] - \frac{\sum_{j=1}^k \text{diff}(A, R_i, H_j)}{(m \cdot k)} +$   
     $\frac{P(C)}{1 - P(class(R_i))} \sum_{j=1}^k \text{diff}(A, R_i, M_j(C)) / (m \cdot k)$   
11: end for
```

---

cada paso estén en  $[0, 1]$ , se tiene que asegurar que los pesos de probabilidad de los errores sumen 1. Como falta la clase de aciertos en la suma se tiene que dividir cada peso de probabilidad con el factor  $1 - P(class(R_i))$  (que representa la suma de probabilidades para las clases de los fallos). El proceso se repite para  $m$  veces dando como salida el vector  $W$  de estimaciones de las cualidades de los atributos con sus respectivos pesos.

Para los experimentos se obtuvieron los descriptores de textura de Patrón Binario Local (LBP) y de Matriz de Co-ocurrencia de Nivel de Gris (GLCM) de los parches obtenidos de las imágenes satelitales. Se extraen 14 características de GLCM: autocorrelación, contraste, correlación, cluster promedio, cluster shade, disimilitud, energía, entropía, homogeneidad, máxima probabilidad, varianza, suma promedio, suma varianza y suma entropía. Además, vectores de 10 características de LBP. Para este descriptor se experimentó con 8 píxeles vecinos y la propiedad de invariancia de rotación (codifican la información de rotación o características rotacionalmente invariantes). Posteriormente, se obtuvieron coeficientes de variación y gráficas con los valores de las características de los descriptores de textura. Finalmente, se aplicó el

método *Relieff* donde se obtienen las cinco características más relevantes de acuerdo a su peso. Esto con la finalidad de seleccionar las características candidatas a ser utilizadas como información en la segmentación de coberturas terrestres.

Para el análisis de coeficientes de variación y gráficas se buscó que el comportamiento de valores de la textura fuera variante para poder diferenciar entre tipos de cobertura y por otro lado, que los valores entre mismo tipo de cobertura tuvieran poca variación ante cambios de humedad. Los experimentos realizados y resultados obtenidos se describen a continuación:

### 5.3.1. Experimento 1: Análisis de textura para diferenciar tipos de cobertura utilizando misma fecha de imágenes

**Objetivo:** Encontrar características de textura que mejor puedan diferenciar entre tipos de cobertura terrestre

**Descripción:**

En este experimento se realizó un análisis de los descriptores de textura utilizando parches de imágenes de una misma fecha de diferentes coberturas terrestres mencionadas anteriormente (ver Figura 9). Se utilizaron imágenes de julio de 2021 y 2022, por cada fecha se generaron 4 grupos de parches donde cada grupo tiene cobertura de vegetación, vegetación agrícola, suelo desnudo, cuerpo de agua y urbano.

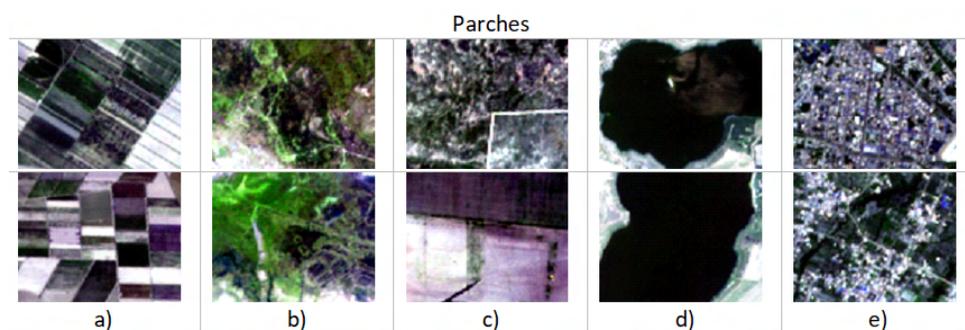


Figura 9: Ejemplos de parches: a) Vegetación agrícola, b) Vegetación, c) Suelo desnudo, d) Cuerpo de agua, e) Urbano

Se obtuvieron valores de coeficiente de variación de las características para tener información acerca de la dispersión relativa en el conjunto de muestras. Esta medida se seleccionó dado que nos da la variación que se obtiene al comparar conjuntos de datos de medidas diferentes. Las gráficas se generaron para ver el comportamiento de los valores de cada característica por cada tipo de cobertura.

Para el análisis se buscaron los siguientes comportamientos: a) que el coeficiente de variación fuera bajo, entre parches de la misma cobertura ya que esto representa que los valores de la característica tienen menor dispersión, b) que el coeficiente de variación fuera de los más altos entre parches de diferentes coberturas de tal manera que se pueda diferenciar entre los tipos de coberturas terrestres, c) que los valores de las características de la gráficas exista una variación mayor entre tipos de cobertura y menor variación entre misma cobertura. Los resultados obtenidos se presentan a continuación:

**Resultados:**

**1.- Parches de imágenes de Julio 2021**

A partir de los valores obtenidos de las características de GLCM, se calculó el coeficiente de variación por cada grupo tomando de los valores de cada característica en las diferentes coberturas. Los valores de coeficiente de variación se ordenaron de forma ascendente y se tomaron las seis primeras características con mayor valor (ver Tabla 6).

Tabla 6: Valores de coeficiente de variación (CV) de GLCM entre grupos de muestras

Grupo1	CV	Grupo2	CV	Grupo3	CV	Grupo4	CV
Maxprob	0.710564	Clustershade	0.822946	Energía	0.821471	Energía	1.296508
Energía	0.706901	Energía	0.550314	Maxprob	0.796396	Maxprob	1.022142
Clustershade	0.655887	Maxprob	0.493938	Contraste	0.700857	Clustershade	0.9606232
Clusterprom	0.520259	Contraste	0.464813	Disimilitud	0.594195	Contraste	0.784909
Contraste	0.484227	Sumvari	0.409376	Clusterprom	0.522831	Disimilitud	0.697614
Disimilitud	0.364532	Autocorr	0.366542	Sumvari	0.507184	Clusterprom	0.609231

Se destacan tres características, que son Máxima probabilidad, Energía y Contraste ya que estas coinciden dentro de este criterio de selección en los cuatro grupos de muestras. Para conocer la máxima variación de estas características sobre el mismo tipo de cobertura, se calcularon sus coeficientes de variación tomando los valores de todos los grupos por cada cobertura. De estos coeficientes, se tomaron los máximos valores de entre todas las coberturas, que se ven en la Tabla 7. En este sentido, Máxima probabilidad y Contraste tuvieron la máxima variación en Suelo y Energía en Agua.

Tabla 7: Valor máximo de coeficiente de variación de mismo tipo de cobertura (MAX-CV-Cob) de todas las muestras

Característica	MAX-CV-Cob
Maxprob	0.424018
Contraste	0.551756
Energía	0.671419

Por otro lado, las gráficas de la Figura 10 corresponden a gráficas de columnas agrupadas para comparar comportamiento de las muestras con los valores de características de textura *versus* tipos de coberturas. Se puede observar que el comportamiento es similar a los coeficientes de variación teniendo mayor variación de los valores entre tipos de coberturas dentro de una misma muestra y menor variación de los valores entre misma cobertura de diferentes muestras. Los valores mas bajos de la característica Contraste se tienen en Agua y los más altos en Urbano y Vegetación. Esto es de esperar ya que con el Contraste se pueden identificar las variaciones locales de la cobertura. La Máxima probabilidad corresponde a la respuesta más fuerte. Con esta característica pasa lo contrario que en Contraste ya que se tienen los valores más altos en Agua y más bajos en Vegetación y Urbano. Esto es, porque en el Agua se tienen valores dominantes sobre valores bajos de píxeles

(tonos oscuros). Finalmente, la Energía nos da una medida de patrones homogéneos y los valores mayores implican más pares de valores de intensidad que son vecinos entre sí en frecuencias más altas. Es por ello, que los valores más altos se tienen en los cuerpos de agua ya que hay más homogeneidad en la textura en comparación con Urbano y Vegetación.

Se generaron 20 vectores de características LBP y en la Figura 11 se puede ver una muestra del resultado donde se visualizan las imágenes utilizadas de cada cobertura, su respectivo Patrón Binario Local con su vector de características. En la

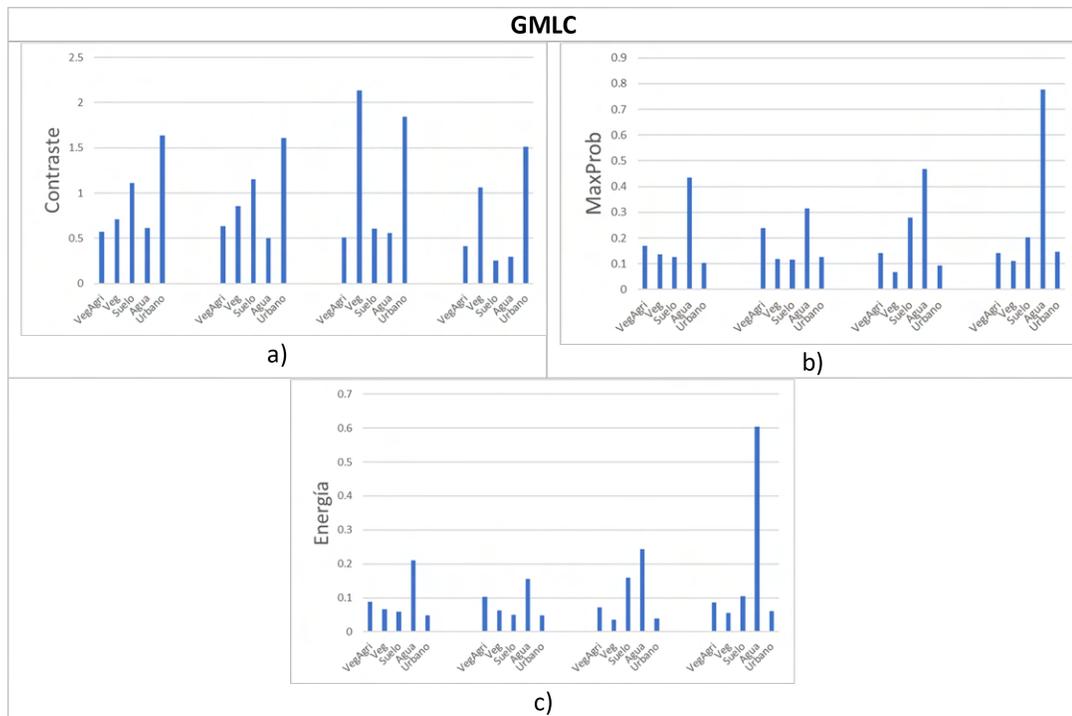


Figura 10: Gráficas de características relevantes de Co-ocurrencia de Nivel de Gris con diferentes tipos de coberturas. Eje  $x$  son tipos de cobertura, Eje  $y$  son valores de características GMLC: a) Contraste, b) Máxima probabilidad y c) Energía

Figura 12 se visualizan las gráficas de error cuadrático calculado a partir de valores de características LBP entre tipos de cobertura de diferentes grupos de muestras (G1,G2,G3,G4). Para estos valores se toma en cuenta que a menor error cuadrático las texturas son más similares. En la Tabla 8 se ven las características con mayor

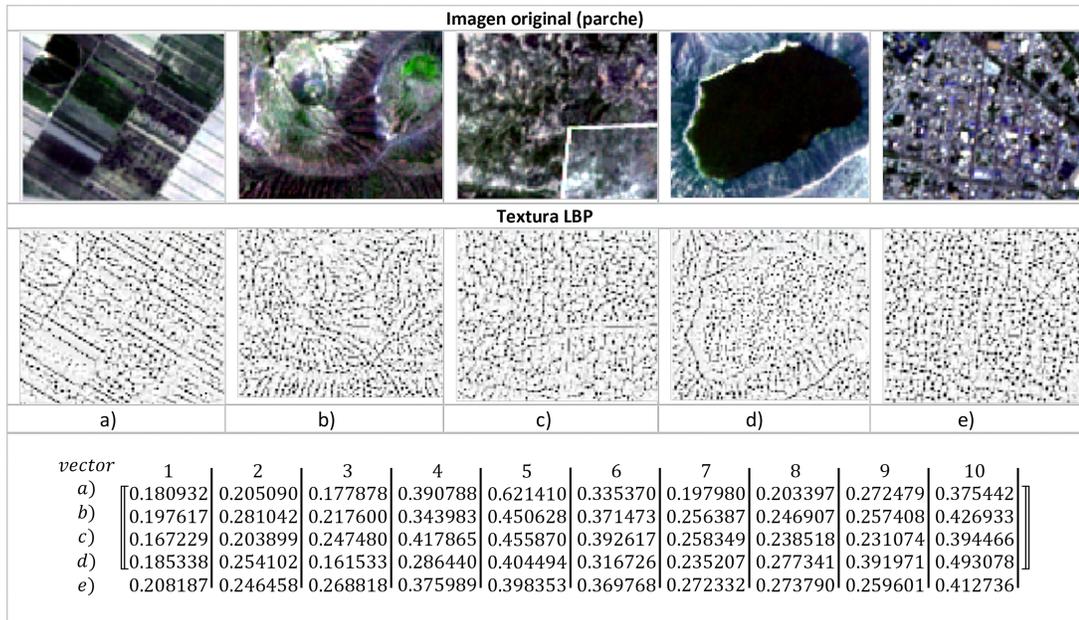


Figura 11: Patrones binarios locales y sus vectores de características LBP. a) Cobertura de vegetación agrícola, b) Vegetación, c) Suelo desnudo, d) Cuerpo de agua, e) Urbano.

rango de error cuadrático. En ese sentido, las características que mejor pudieran discriminar entre tipos de cobertura son 1,5 y 10 comparando vegetación con vegetación agrícola, 3,5 y 10 comparando suelo con urbano, 5,9 y 10 comparando agua con suelo. Estas características tienen el mayor rango entre las 10 características del vector de su respectiva comparación ver Tabla 8.

Tabla 8: Rangos de error cuadrático de LBP entre coberturas

VegAgri Vs Veg		Suelo Vs Urbano		Agua Vs Suelo	
Característica	Rango	Característica	Rango	Característica	Rango
5	0.074949	5	0.005053	9	0.198391
10	0.057977	3	0.003207	5	0.103133
1	0.023290	10	0.002781	10	0.055612

Finalmente, se obtuvieron las cinco características más relevantes con el algoritmo *Relieff* en donde para el descriptor de GMLC fueron Contraste, Disimilitud, Diferencia entropía, Homogeneidad y Correlación. Para el descriptor de LBP fueron las características 7, 5, 8, 2 y 4.

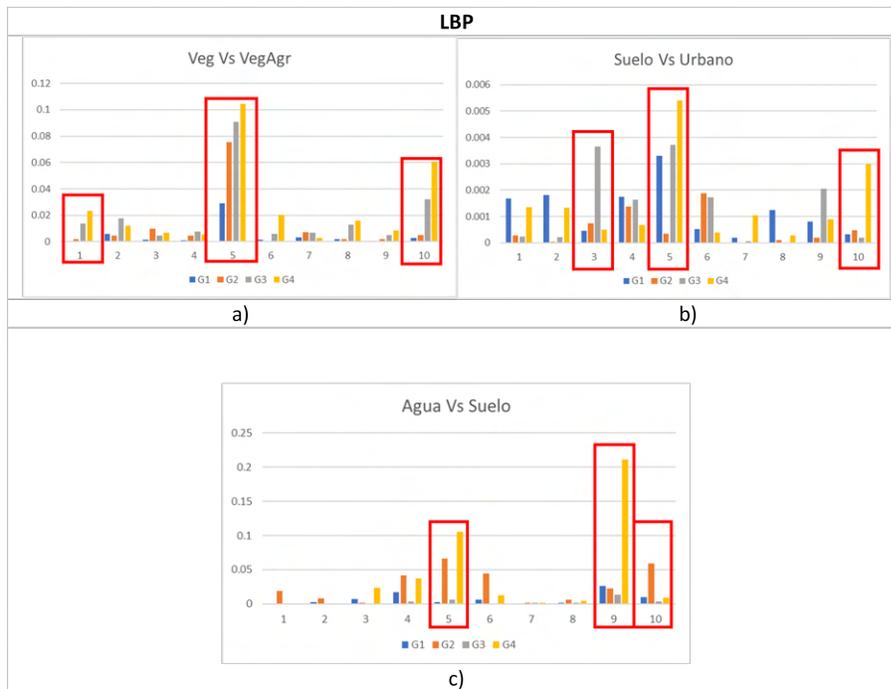


Figura 12: Gráficas de error cuadrático de comparativo entre coberturas de Patrón Binario Local (LBP): Eje x representa el vector de 10 características, Eje y representa los valores de error cuadrático a cada grupo de muestra G1,G2,G2,G3.

## 2.- Parches de imágenes de Julio 2022

En los parches de las imágenes de julio de 2022 se repitió el mismo proceso y análisis que en julio 2021. En la Tabla 9 y 10 se muestran los coeficientes de variación del descriptor GMLC. Las características que se encuentran presentes en todos los grupos de valores de coeficiente de variación de la Tabla 9 son Clustershade, Cluster promedio, Máxima probabilidad, Energía y Contraste. En la Tabla 10 se tienen los respectivos valores máximos de coeficiente de variación.

Tabla 9: Valores de coeficiente de variación (CV) de grupos de muestras de julio 2022

Grupo1	CV	Grupo2	CV	Grupo3	CV	Grupo4	CV
Clustershade	1.105456	Clustershade	1.420340	Clustershade	1.328637	Clustershade	3.041615
Clusterprom	0.559455	Contraste	0.540119	Energía	0.717429	Energía	1.079634

<b>Contraste</b>	0.510220	<b>Clusterprom</b>	0.530423	<b>Maxprob</b>	0.692851	<b>Contraste</b>	0.966471
<b>Maxprob</b>	0.498223	<b>Energía</b>	0.394536	Sumvari	0.556767	<b>Maxprob</b>	0.852189
<b>Energía</b>	0.464975	Disimilitud	0.381585	<b>Clusterprom</b>	0.516031	Disimilitud	0.775278
Sumvari	0.370646	<b>Maxprob</b>	0.377415	<b>Contraste</b>	0.506825	<b>Clusterprom</b>	0.557280

Tabla 10: Valor máximo de coeficiente de variación entre mismo tipo de cobertura (MAX-CV-Cob) de todas las muestras de julio 2022

Característica	MAX-CV-Cob
<b>Contraste</b>	0.669996
<b>Maxprob</b>	0.850512
<b>Energía</b>	0.914722
Clusterprom	0.914722
Clustershade	26.090600

En las gráficas de la Figura 13 se puede observar mayor variación de los valores entre tipos de coberturas dentro de una misma muestra y menor variación de los valores entre misma cobertura. En la característica Contraste hay menor valor en Agua y Suelo, excepto en el segundo bloque de la gráfica donde el contraste aumenta. Esto sucede cuando hay Agua es turbia. En la Máxima probabilidad se tienen los valores más altos en agua, seguido de Suelo y los valores más bajos en Vegetación y Urbano. En esta característica no hay cambio en comportamiento de Agua clara y turbia. En Energía hay valores más altos en agua ya que hay más homogeneidad en textura y menos en Urbano y Vegetación.

En la Figura 14 se pueden visualizar las gráficas de error cuadrático de LBP en donde, las características que tienen mayor error cuadrático son 2,5 y 10 comparando vegetación con vegetación agrícola, 3,5 y 10 comparando suelo con urbano, 5,9 y 10 comparando agua con suelo. En la Tabla 11 se pueden ver los rangos de estas características que se encuentran entre las de mayor rango y que mejor pudieran discriminar entre tipos de cobertura.

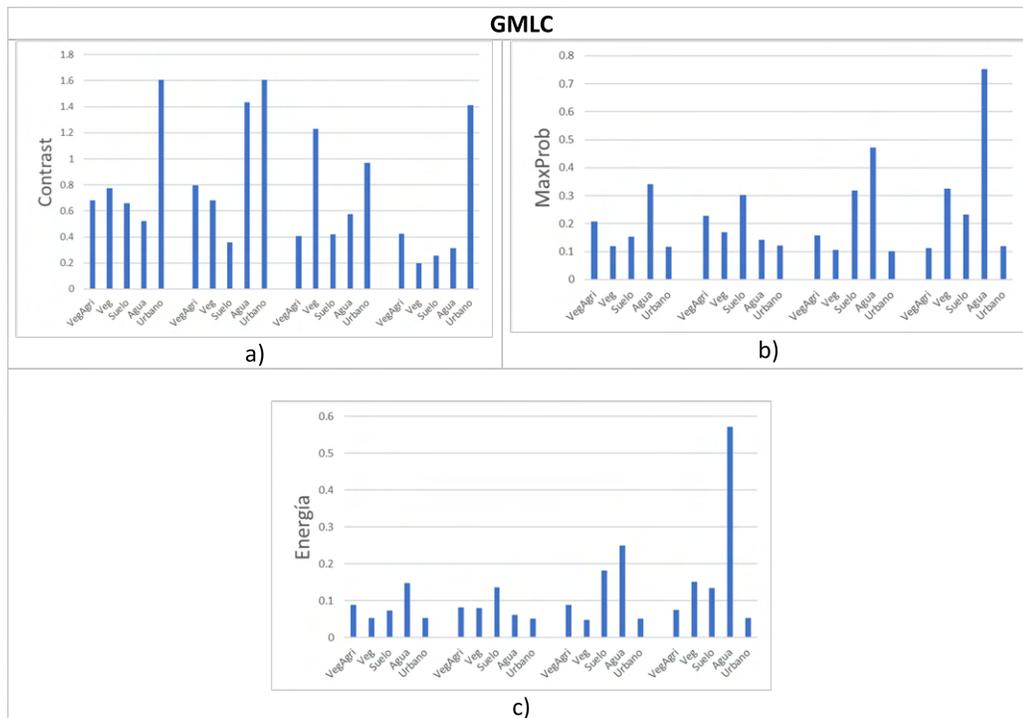


Figura 13: Gráficas de características relevantes de Co-ocurrencia de nivel de gris con diferentes tipos de coberturas de julio 2022. Eje  $x$  son tipos de cobertura, Eje  $y$  son valores de características: a) Contraste, b) Máxima probabilidad, c) Energía

Tabla 11: Rangos de error cuadrático de LBP entre coberturas de julio 2022

VegAgri Vs Veg		Suelo Vs Urbano		Agua Vs Suelo	
Característica	Rango	Característica	Rango	Característica	Rango
5	0.053708	5	0.009482	5	0.086277
10	0.03188920	10	0.003922	10	0.077225
2	0.01663073	3	0.003621	9	0.066895

Las características relevantes obtenidas con el algoritmo *Relieff* fueron Contraste, Disimilitud, Diferencia entropía, Homogeneidad y Correlación. La característica Contraste vuelve a coincidir como en julio de 2021 en los diferentes criterios de selección. Por otro lado, en Patrón Binario Local fueron obtenidas las características 3, 5, 9, 7 y 4.

### **Conclusión:**

En los resultados de este experimento se puede observar que las características de

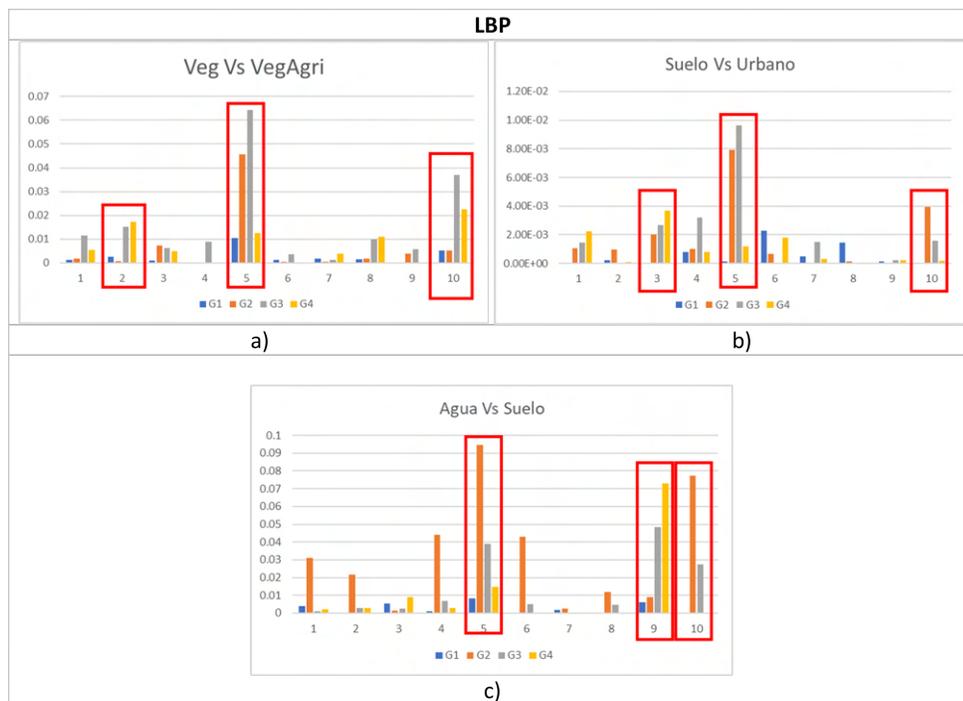


Figura 14: Gráficas de error cuadrático de comparativo entre coberturas de Patrón Binario Local (LBP) de experimento 2: Eje x representa el vector de 10 características, Eje y representa los valores de error cuadrático a cada grupo de muestra G1,G2,G2,G3.

GMLC Máxima probabilidad, Contraste y Energía salen como relevantes en las diferentes fechas y que Contraste coincide en los diferentes criterios de selección. Estas características tienen menor coeficiente de variación entre mismo tipo de cobertura que representa cierta estabilidad en los valores de esas características. En del descriptor de Patrón Binario Local las características 5 y 10 se presentan como características relevantes en las dos fechas. Con el algoritmo relief se presentan como relevantes la característica 4, 5 y 7 en las dos fechas de muestras. La característica 5 se encuentra dentro de los primeros rangos de error cuadrático en las tres comparaciones de cobertura terrestre y esta presenta en todos los criterios de análisis. Bajo la premisa de que a menor variación entre valores de características de mismo tipo de cobertura y mayor variación entre valores de diferentes tipos de cobertura hay mejor inferencia de coberturas. Las características candidatas en este experimento son Máxima probabilidad, Contraste y Energía para GMLC. En las característi-

cas LBP se complica más seleccionar de las candidatas de este experimento ya que en los resultados de *Relieff* y el análisis de coeficientes solamente coinciden en la característica 5. Sin embargo, se podrían considerar las características 4, 7 y 10.

### **5.3.2. Experimento 2: Análisis de textura para inferir tipo de cobertura utilizando imágenes con diferente contenido de humedad**

**Objetivo:** Encontrar características de textura que mejor puedan inferir el tipo de cobertura ante cambios de humedad de superficie terrestre.

**Descripción:**

En este experimento se formaron grupos de muestras de diferentes tipos de cobertura con imágenes de diferentes fechas. Esto con el fin de tener muestras con diferente contenido de humedad. Las imágenes utilizadas fueron de julio de 2021, julio de 2022 y febrero de 2021 teniendo un porcentaje promedio máximo de humedad de 70 %, 68 % y 48 % respectivamente. Se obtuvieron las mismas características del experimento 1 y se aplicó el algoritmo *Relieff* para selección de características. Para llegar al objetivo de este experimento se buscarán características de texturas que tengan un comportamiento similar entre mismo tipo de cobertura aun teniendo diferente contenido de humedad. En ese sentido, en el análisis se busca que exista poca variación de los valores de características entre misma cobertura en las diferentes muestras. Además, se aplicó el criterio para buscar características que mejor puedan discriminar entre diferentes coberturas para ver coincidencias con las que puedan inferir ante cambios de humedad.

**Resultados:**

Se obtuvieron los coeficientes de variación de cada característica GMLC en cada grupo por fecha. Se ordenaron de forma ascendente y se tomaron las características que coinciden dentro de las seis primeras con mayor valor en todos los grupos de fechas. Las características que se encuentran presentes en todos los grupos de fechas fueron Contraste, Energía y Máxima probabilidad. En la tabla 12 se pueden ver su

mínima y máxima variación.

Tabla 12: Valores mínimo y máximo de características GLMC con mayor coeficiente de variación

Característica	Mínimo	Máximo
Contraste	0.462343	0.966471
Energía	0.394536	1.296508
Maxprob	0.377415	1.022142

Por otro lado, se obtuvieron los coeficientes de variación entre mismo tipo de cobertura en todas las muestras y se ordenaron de forma descendente. Como se mencionó anteriormente se busca que exista menor variación de los valores de características entre mismo tipo de cobertura. En este experimento las características coincidentes en el primer criterio de selección no tuvieron los menores valores de coeficiente de variación ver Tabla 13. Esto puede ser normal ya que se tienen diferentes fechas en las muestras y la cobertura aun siendo la misma puede sufrir diversos cambios como por ejemplo, cambios en humedad o fenológicos. Aun cuando no se tienen los valores más bajos en variación entre misma cobertura en estas características no tienen coeficientes de variación altos ya que oscilan entre 0.2 y 0.5.

Tabla 13: Valores de coeficiente de variación tomando mismo tipo de cobertura de todas las muestras (posición ascendente-valor).

Característica	Veg	VegAgri	Suelo	Agua	Urbano
Contraste	14-0.517697	13-0.327766	14-0.590918	4-0.243868	10-0.154427
Maxprob	13-0.513113	11-0.324871	9-0.381520	10-0.530339	9-0.136471
Energía	11-473316	7-0.229320	10-0.405988	12-0.5698734	8-0.118368

Las gráficas con los valores de las características que destacan en este experimento según los criterios mencionados se pueden ver en la Figura 15. En estas gráficas se pueden ver agrupados los valores de cada característica por fecha y grupo de muestra.

Se puede observar que así como en los coeficientes de variación el comportamiento en las gráficas con estas características tiende a existir una mayor variación de valores entre diferentes coberturas que en valores de misma cobertura. Aunque en algunas ocasiones pudiera existir un mayor cambio de valores entre misma cobertura. Esto puede ser porque, al comparar diferentes fechas de imágenes se pueden presentar cambios de condiciones de superficie terrestre.

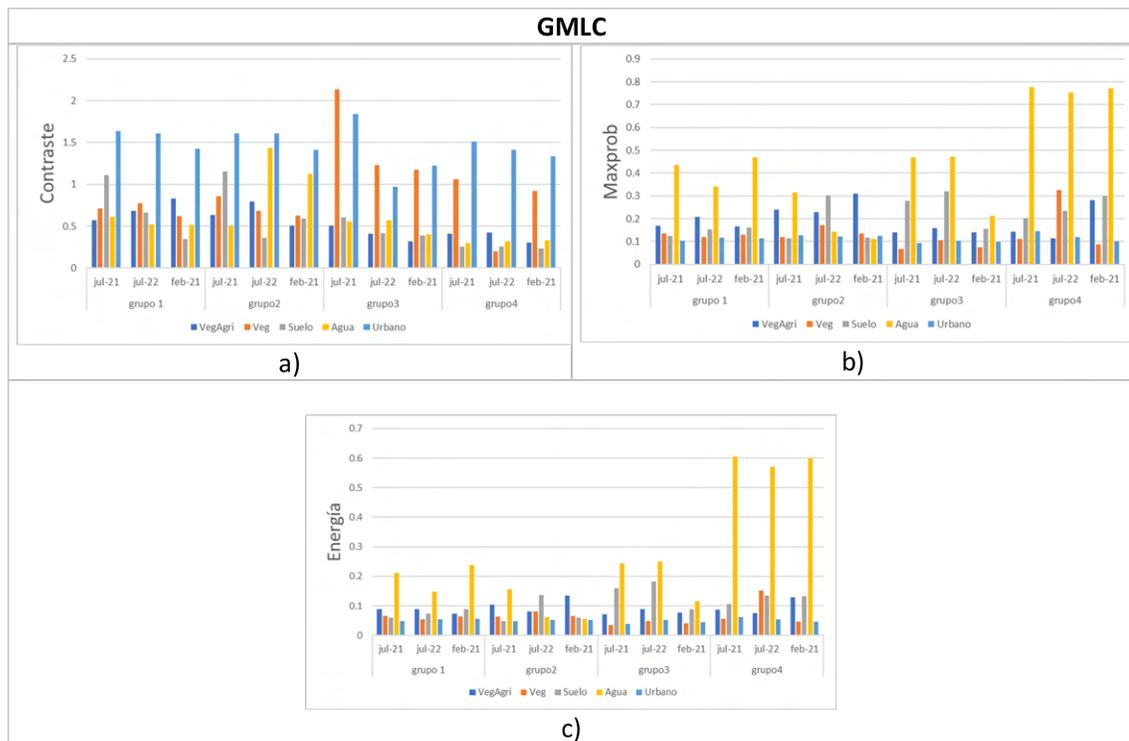


Figura 15: Gráficas de características relevantes de Co-ocurrencia de nivel de gris de experimento 2. Eje  $x$  son fechas de parches y grupos de muestras, Eje  $y$  son valores de características: a) Contraste, b) Máxima probabilidad, c) Energía

Para el descriptor de Patrón Binario Local se obtuvieron los valores de error cuadrático de las características entre diferentes fechas. Posteriormente se calcularon los rangos de error cuadrático de misma cobertura entre las fechas. Dado que en este experimento se busca identificar cuando una característica puede tener cierta estabilidad aun con cambios de humedad en la cobertura. Entonces, se tomaron en cuenta las características del vector que tuvieron los menores valores de rango - ver

Tabla 14. Esto porque mientras menor sea el error cuadrático más similar la textura.

En la Figura 16 se pueden visualizar las gráficas con los rangos de error cuadrático de cada cobertura. Se puede observar que en algunos casos hay mayor error en la comparación de julio 2021 y 2022 que en febrero y julio 2021. Esto se puede deber por cambios en la cobertura entre los diferentes años como por ejemplo en el contenido de vegetación. Entre otros motivos los cambios se pueden deber a que hay mayor humedad anual promedio en 2021 que en el 2022.

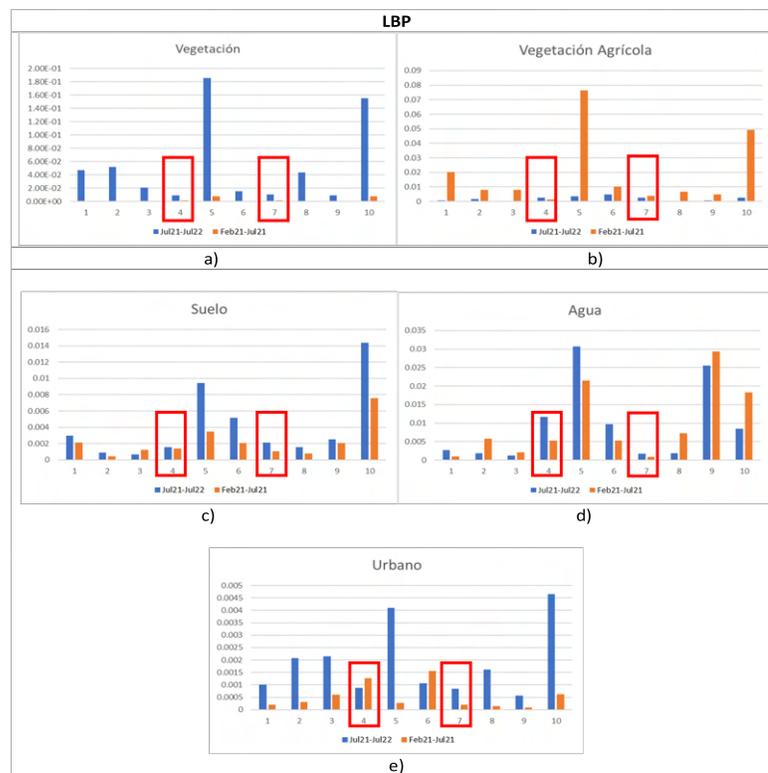


Figura 16: Gráficas de rango de error cuadrático de comparativo entre fechas con misma cobertura de Patrón Binario Local (LBP): Eje  $x$  es el vector de 10 características, Eje  $y$  son los rangos de error cuadrático de comparativo entre fechas

Tabla 14: Rangos de error cuadrático de LBP

Jul21-Jul22	Feb21-Jul21	Jul21-Jul22	Feb21-Jul21
-------------	-------------	-------------	-------------

Característica	Rango	Característica	Rango	Característica	Rango	Característica	Rango
<b>Vegetación</b>				<b>Vegetación Agrícola</b>			
9	0.009035	3	0.000112	3	0.000155	4	0.001190
4	0.009160	6	0.000915	8	0.000477	7	0.003852
7	0.010890	9	0.000967	9	0.000621	9	0.004728
6	0.015223	4	0.001276	2	0.001638	8	0.006638
3	0.021065	7	0.001283	4	0.002422	3	0.008080
				7	0.002685	2	0.008090
<b>Suelo</b>				<b>Agua</b>			
3	0.000637	2	0.000406	3	0.001248	7	0.000813
2	0.000872	8	0.000740	7	0.001678	1	0.000973
8	0.001540	7	0.001025	8	0.001814	3	0.002119
4	0.001560	3	0.001189	2	0.001881	6	0.005332
7	0.002113	4	0.001385	1	0.002697	2	0.005828
9	0.002486	9	0.002037	6	0.009663	8	0.007272
<b>Urbano</b>							
9	0.000568	9	0.000081				
7	0.000840	1	0.000200				
4	0.000874	7	0.000202				
1	0.001010	4	0.001255				

Finalmente, las características relevantes obtenidas con el algoritmo *Relieff* fueron nuevamente Contraste, Disimilitud, Diferencia entropía, Homogeneidad y Correlación. Para Patrón Binario Local el algoritmo obtuvo las características como relevantes 3, 4, 5, 9 y 7.

### **Conclusiones:**

En este experimento se pueden tomar como las mejores características para diferenciar tipos de coberturas las características Contraste, Energía y Máxima probabilidad. Sin embargo, la característica Contraste se presenta en todos los criterios analizados en este experimento. Para Patrón Binario Se pueden considerar las características como mejores la 5 y 7 ya que hay coincidencia en los criterios de análisis. La característica 5 presenta mayor variación en valores entre coberturas y la 7 presenta poca variación en sus valores en la misma cobertura ante cambios de humedad. En los dos experimentos realizados existen coincidencias en algunas características relevantes de Co-ocurrencia de nivel de gris y de Patrón Binario Local utilizando diferentes criterios de selección lo que hace posible seleccionar características candidatas para inferir coberturas terrestres. En la Figura 17 se pueden ver ejemplos de los valores de las características obtenidas como relevantes con su tipo de cobertura

terrestres.

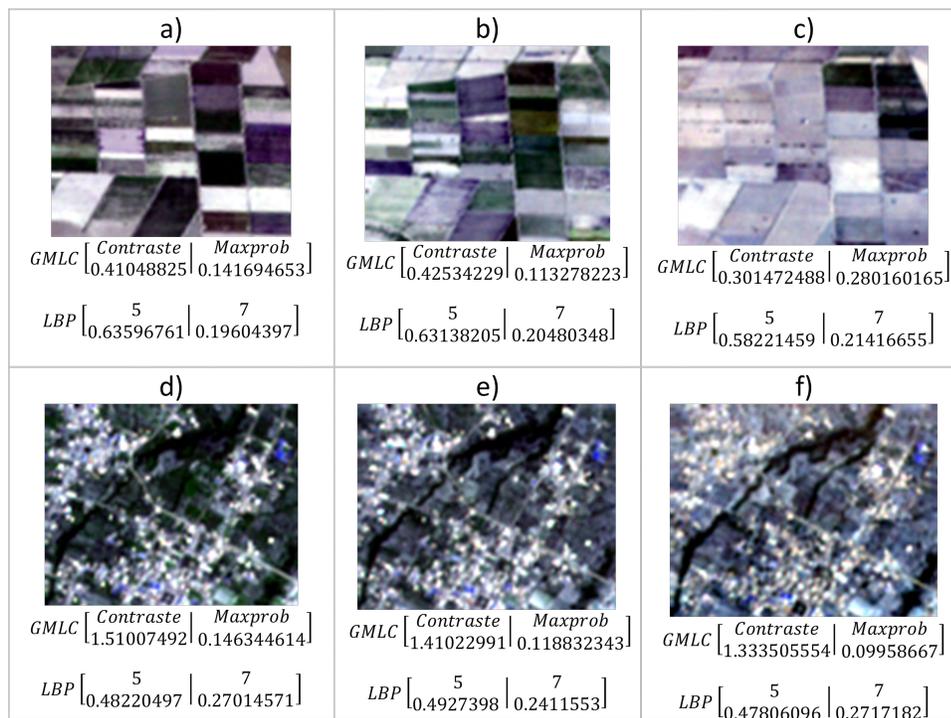


Figura 17: a)Vegetación Agrícola (VA) julio-21, b)VA julio-22,c)VA feb-21, d)Urbano (URB) julio-21, e)URB julio-22, f)URB feb-21

## 6. Observaciones Finales

Es un reto encontrar descriptores de textura que puedan inferir entre tipos de coberturas pero aun más que puedan identificarlas ante cambios de humedad. Sin embargo, de acuerdo con los experimentos realizados se pudo observar que las características seleccionadas como candidatas para utilizarlas en la segmentación semántica son Contraste, Máxima probabilidad y Energía pero principalmente Contraste dado que en los dos experimentos realizados se obtiene como relevante para inferir entre tipos de coberturas terrestres. Esto quiere decir que las variaciones locales pueden dar mejor información de las diferentes coberturas.

En el descriptor de Patrón Binario Local las características seleccionadas como candidatas son la 5 y 7 del vector. La característica 5 se ve como la que mejor puede diferenciar entre diferentes tipos de cobertura teniendo los mayores valores de error cuadrático y la 7 con menores valores de error cuadrático describiendo la textura como similar aun con cambios de humedad de la misma cobertura.

Los resultados obtenidos son útiles y prometedores ya que se tomó en consideración no solamente diferenciar entre tipos de cobertura si no también analizar comportamiento de textura ante cambios de humedad. Esto es importante ya que ante cambios de humedad se pueden generar cambios en la superficie terrestre y afectar la detección de tipo de cobertura. A pesar que se obtuvieron resultados útiles, es recomendable realizar otros experimentos similares con más periodos, además realizar experimentos de segmentación con las características de textura seleccionadas.

Los siguientes pasos a seguir son: realizar los experimentos recomendados, analizar la textura de modelo teórico de semivariograma ya que es muy utilizada en el área de análisis de imágenes satelitales. Implementar y aplicar la segmentación semántica del algoritmo Máxima Verosimilitud para obtener desempeño en la categorización de tipos de cobertura. Posteriormente comparar resultados agregando las

características de textura seleccionadas.

## Referencias

- [1] World Health Organization. Drought . <https://www.who.int/health-topics/droughttab=tab1>.
- [2] Wilhite D. Droughts. routledge, london. 2000. <https://doi.org/10.4324/9781315830896>.
- [3] J. Martínez et. al. Satellite soil moisture for agricultural drought monitoring: assessment of the smos derived soil water deficit index. *Remote Sens. Environ*, 177:277–286, 2016.
- [4] Sorooshian et. al. Hydrologic evaluation of satellite precipitation products over a mid-size basin. *Journal of Hydrology*, 397:225–237, February 2011.
- [5] Entekhabi et. al. The hydrosphere state (hydros) mission concept: An earth system pathfinder for global mapping of soil moisture and land freeze/thaw. *IEEE Trans. Geosci. Remote Sens*, (42):2184 – 2195, 2004.
- [6] Cashion et al. Microwave remote sensing of soil moisture: evaluation of the trmm microwave imager (tmi) satellite for the little river watershed tifton, georgia. *IEEE Trans. Geosci. Remote Sens*, 307:242–253, June 2005.
- [7] Anderson et al. Evaluation of drought indices based on thermal remote sensing of evapotranspiration over the continental united states. *Journal of Climate*, pages 2025–2044, April 2011.
- [8] Allen et al. Satellite-based energy balance for mapping evapotranspiration with internalized calibration „metric...—applications. *JOURNAL OF IRRIGATION AND DRAINAGE ENGINEERING*, 2007.
- [9] Heumann. Satellite remote sensing of mangrove forests: Recent advances and future opportunities. *JOURNAL OF IRRIGATION AND DRAINAGE ENGINEERING*, 35, February 1, 2011.

- [10] Tajudin et. al. Soil moisture index estimation from landsat 8 images for prediction and monitoring landslide occurrences in ulu kelang, selangor, malaysia. *wireless Communication Technology (WiCoT), Faculty of Electrical Engineering, Universiti Teknologi MARA, Selangor, Malaysia*, II:2101-2108, June 2021.
- [11] Yingxin Gu et. al. Evaluation of modis ndvi and ndwi for vegetation drought monitoring using oklahoma mesonet soil moisture data. *Geophysical Research Letters*, 35, 2008.
- [12] Rabiei et. al. A method to estimate surface soil moisture and map the irrigated cropland area using sentinel-1 and sentinel-2 data. 2021.
- [13] Sidney et. al. Estimation of the moisture content of tropical soils using colour images and artificial neural networks. *CATENA*, 135:100–106, 2015.
- [14] TManeesha G Nair<sup>1</sup> et. al. Determination of soil ph using digital image processing. *International Journal of Information Systems and Computer Sciences*, 8(2), 2019. <https://doi.org/10.30534/ijisecs/2019/20822019>.
- [15] Türkiye Emrullah Acar, Batman. The texture feature extraction of agricultural field images by hog algorithms and soil moisture estimation based on the texture features. 1(1), 2016.
- [16] Parinaz Rahimzadeh-Bajgirana et. al. Estimation of soil moisture using optical/thermal infrared remote sensing in the canadian prairies. *ISPRS Journal of Photogrammetry and Remote*, 83:94–103, September 2013. <https://doi.org/10.1016/j.isprsjprs.2013.06.004>.
- [17] Shafian y Maas. Index of soil moisture using raw landsat image digital count data in texas high plains. *Remote Sens.*, 7(3):2352–2372, 2015. <https://doi.org/10.3390/rs70302352>.

- [18] Yao F. Yang L. Hao C. Zhang J., Zhou Z. Validating the modified perpendicular drought index in the north china region using in situ soil moisture measurement. *Geosci. Remote Sens.*, 12:542–546, 2014.
- [19] Babaeian et. al. A new optical remote sensing technique for high-resolution mapping of soil moisture. *wireless Communication Technology (WiCoT), Faculty of Electrical Engineering, Universiti Teknologi MARA, Selangor, Malaysia*, 2019.
- [20] P. et. al. Rahimzadeh-Bajgiran. Estimation of sm using optical/thermal infrared remote sensing in the canadian prairies. 83:94–103, 2013.
- [21] S.J. Shafian, S.; Maas. Index of sm using raw landsat image digital count data in texas high plains. *Remote Sens.*, 7:2352–2372, 2015.
- [22] M. et. al. Effati. Application of satellite remote sensing for estimation of dust emission probability in the urmia lake basin in iran. *Soil Sci. Soc. Am. J.*, (83):993–1002, 2019.
- [23] Castilla Carrillo. Módulo clasificador de imágenes Ópticas multiespectrales aplicado al área de geociencias. *IPICIM*, 2016.
- [24] Pushpendra Singh Sisodia et. al. A comparative analysis of remote sensing image classification techniques. *IEEE International*, pages 1418–1421, 2014.
- [25] Manoj Pandya et. al. Comparison of various classification techniques for satellite data. *International Journal Of Scientific Engineering Research*, 4(2), 2013.
- [26] Ebrahim Babaeian et. al. Ground, proximal, and satellite remote sensing of soil moisture. *views of Geophysics*, 57:530–616, 2019.
- [27] Q. Zhu et. al. Adaptive deep sparse semantic modeling framework for high spatial resolution mathematical problems in engineering 21 image scene classification. *IEEE Transactions on Geoscience and Remote Sensing*, 56(10):1–16, 2018.

- [28] J. Xie et. al. Scale-free convolutional neural network for remote sensing scene classification. *IEEE Transactions on Geoscience and Remote Sensing*, 57(9):6916–6928, 2019.
- [29] J. Fang et. al. Robust space-frequency joint representation for remote sensing image scene classification. *IEEE Transactions on Geoscience and Remote Sensing*, 57(10):7492–7502, 2019.
- [30] Y. Liu et. al. Scene classification based on multiscale convolutional neural network. *IEEE Transactions on Geoscience and Remote Sensing*, 56(12):7109–7121, 2018.
- [31] N. B. Crews and K. A. Crews. Mapping vegetation morphology types in a dry savanna ecosystem: integrating hierarchical object-based image analysis with random forest. *International Journal of Remote Sensing*, 35(3):1175–1198, 2014.
- [32] Shafapour Tehrany et. al. A comparative assessment between object and pixel-based classification approaches for land use/land cover mapping using spot 5 imagery. *Journal Geocarto International*, 29(4):351–369, 2014.
- [33] B. Zafar et. al. Intelligent image classification- based on spatial weighted histograms of concentric circles. *Computer Science and Information Systems*, 3:615–633, 2018.
- [34] Lakshmi N. Kantakumar et. al. Multi-temporal land use classification using hybrid approach. *Computer Science and Information Systems*, 18:289–295, 2015.
- [35] Manoj Pandya et. al. Comparison of various classification techniques for satellite data. *International Journal Of Scientific Engineering Research*, 4(2):615–633, 2013.
- [36] Arango Gutiérrez et. al. Clasificación no supervisada de coberturas vegetales sobre imágenes digitales de sensores remotos: "landsat - etm+. *Revista Facultad Nacional de Agronomía - Medellín*, 58(1):2611–2634, 2015.

- [37] M. Maestri et. al. Análisis comparativo de cinco métodos de procesamiento para calcular el área de lagunas pampeanas a partir de imágenes satelitales landsat. *Biología Acuática*, 2019.
- [38] ERDAS-IMAGINE. Leica geosystems gis mapping llc; homepage. 2000. <http://www.ermapper.com/default.aspx>.
- [39] ARGIS Pro de ESRI. 3rd edition. <https://pro.arcgis.com/es/pro-app/latest/tool-reference/spatial-analyst/maximum-likelihood-classification.htm>.
- [40] GRASS. Geographic resources analysis support system. <http://grass.itc.it/>.
- [41] Documentación QGIS. Clasificación de imágenes. [https://docs.qgis.org/2.14/es/docs/user\\_manual/processing\\_algs/saga/imagery\\_classification](https://docs.qgis.org/2.14/es/docs/user_manual/processing_algs/saga/imagery_classification).
- [42] Using ENVI. Classification. <https://www.l3harrisgeospatial.com/docs/classification.html>: :tex
- [43] Hussain et. al. spatiotemporal variation in land use land cover in the response to local climate change using multispectral remote sensing data. 11, 2022. <https://doi.org/10.3390/land11050595>.
- [44] R. E.Woods. Gonzalez, R. C. Digital image processing using matlab. *Pearson Educational*, 2006.
- [45] John G. Proakis y Dimitris G. Manolakis. Tratamiento digital de señales. *PEARSON EDUCACIONES*, 2007.
- [46] Dharminder Kumar Sakshi Dhingra. A review of remotely sensed satellite image classification. *International Journal of Electrical and Computer Engineering (IJECE)*, 9(3):2088–8708, 2019.
- [47] Shanmugam K. Haralick, R.M. Textural features for image classification. *IEEE Trans. SMC*, 2(610-621), 1973.

- [48] Oscar GARCÍA-OLALLA et. al. Descripción de textura en imágenes utilizando local binary pattern (lbp). Cap.7:115–130, 2016.
- [49] OLALLA et.al. Descripción de textura en imágenes utilizando local binary pattern (lbp). *Universidad de León, Departamento de Ingeniería eléctrica y de Sistemas y Automática, Escuela de Ingenierías, León, España.*, CAPÍTULO 7, 2016. Grupo de Visión del Comité Español de Automática (CEA).
- [50] Dani Or Markus Tuller. Water films and scaling of soil characteristic curves at lowwater contents. *Soil and Land Resources Division, University of Idaho, Moscow, Idaho, USA*, 41, 2006. doi:10.1029/2005WR004142, 20051of6.
- [51] Morteza Sadeghi et. al. The optical trapezoid model: A novel approach to remote sensing of soil 2 moisture applied to sentinel-2 and landsat-8 observations. 2017.
- [52] Wilhite et. al. Drought preparedness planning: Building institutional capacity. - *National Drought Mitigation Center at DigitalCommons@University of Nebraska - Lincoln*, 2005.
- [53] AghaKouchak et. al. Global warming and changes in risk of concurrent-climate extremes: Insights from the 2014 california drought. *Geophys. Res. Lett.*, 41, 8847–8852, doi:10.1002/2014GL062308, 2014.
- [54] Sheffield et. al. Little change in global drought over the past 60 years. (Nature 491, 435–438 <https://doi.org/10.1038/nature11575>), 2012.
- [55] WC Palmer. Meteorological drought. (U.S. Research Paper No. 45. US Weather Bureau, Washington, DC), 1965.
- [56] GALLAGHER et. al. Effects of drought on grain growth. (Nature 264, 541–542 (1976). <https://doi.org/10.1038/264541a0>), 1965.

- [57] et al Chengguo Wua. Construction and application of comprehensive drought index based on uncertainty cloud reasoning algorithm. *ELSEVIER, Science of the Total Environment*, (779), 2021. [www.elsevier.com/locate/scitotenv](http://www.elsevier.com/locate/scitotenv).
- [58] et al Binbin He. A global grassland drought index (gdi) product: Algorithm and validation. *remotesensing*, (7), 2015. [www.mdpi.com/journal/remotesensing](http://www.mdpi.com/journal/remotesensing).
- [59] et al Pouya Aghelpour. A theoretical approach for forecasting different types of drought simultaneously, using entropy theory and machine-learning methods. *International Journal of Geo-Information*, 9(701), 2020. [www.mdpi.com/journal/ijgi](http://www.mdpi.com/journal/ijgi).
- [60] et al Mónica Castillo-Castillo. Pronóstico de sequías meteorológicas con filtro de kalman discreto en la cuenca del río fuerte, méxico. *Agrociencia*, 52(7):911–932, 2018.
- [61] et. al Cynthia S.A. Wallace. Fallow-land algorithm based on neighborhood and temporal anomalies (fanta) to map planted versus fallowed croplands using modis data to assist in drought studies leading to water and food security assessments. *GIScience Remote Sensing*, 2017. <https://www.tandfonline.com/loi/tgrs20>.
- [62] René Lobato-Sánchez. El monitor de la sequía en méxico. *Tecnología y Ciencias de Agua*, 7(5):197–211, 2016.
- [63] et al Carlos Rolando Rosero-Erazo. Evaluación de la sequía vegetativa mediante sensores remotos: Estudio de caso en la cuenca del río chimborazo-ecuador. *Pol. Con.*, 5(46):228–259, 2020.
- [64] Anand Upadhyay et. al. Comparative study of artificial neural network based classification of IRS LISS-III satellite images. *IEEE International Conference on Green Computing and Internet of Things (ICGCIoT)*, pages 961–965, 2015.

- [65] Peter van Oevelen Wouter Dorigo. A new international network for in situ soil moisture data. *EOS, TranSacTiOnS, amErican GEOPhySical*, 92(1726):141–148, 26 April 2011. <https://doi.org/10.1029/2011EO170001>.
- [66] Pere Quintana Seguí Yves Trambly. Estimation of soil water holding capacity with random forests for drought monitoring. *Natural Hazards and Earth System Sciences*, 23 December 2021.
- [67] Sadeghi et. al. Mapping soil moisture with the optical trapezoid model (optram) based on long-term modis observations. *Remote Sensing of Environment*, 211:425–440, 2018. <https://doi.org/10.1016/j.rse.2018.04.029>.
- [68] Sadeghi et. al. A stand-alone remote sensing approach based on the use of the optical trapezoid model for detecting the irrigated areas. *Agricultural Water Management*, 274, 2022. [www.elsevier.com/locate/agwat](http://www.elsevier.com/locate/agwat).
- [69] Acharya et. al. oil moisture mapping with moisture-related indices, optram, and an integrated random forest-optram algorithm from landsat 8 images. *Agricultural Water Management*, 14, 2022. <https://doi.org/10.3390/rs14153801>.
- [70] Dharminder Kumar Sakshi Dhingra. A review of remotely sensed satellite image classification. *International Journal of Electrical and Computer Engineering (IJECE)*, 9(3):1720–1731, 2019.
- [71] D. A. Landgrebe. Signal theory methods in multispectral remote sensing. wiley series in remote sensing and image processing. *Wiley-Interscience*, 2003.
- [72] F. F. Sabins. Remote sensing: Principles and interpretations. *Freeman and Company*, 3rd edition, 2000. <https://doi.org/10.3390/rs14153801>.
- [73] Abida et. al. Mapping: Comparing different supervised classifications in semi-arid areas. agriculture sentinel-2 data for land use. 12, 2022. <https://doi.org/10.3390/>.

- [74] del Toro Espín et. al. Comparación de métodos de clasificación de imágenes de satélite en la cuenca del río argos (región de murcia). *Boletín de la Asociación de Geógrafos Españoles*, 67:327–347, 2015. <http://grass.itc.it/>.
- [75] Quirós. Clasificación de imágenes multiespectrales aster mediante funciones adaptativas. *Tesis Doctoral, Universidad de Extremadura*, 2009.
- [76] Gijón. Comparación de dos modelos de clasificación de la cobertura superficial del municipio de texcoco de mora, estado de méxico. *Colegio de Postgraduados*, 2018.
- [77] Agencia Espacial Europea. Copernicus open access hub. <https://scihub.copernicus.eu/dhus//home>.
- [78] U.S. Geological Survey. Earthexplorer usgs. <https://earthexplorer.usgs.gov/>.
- [79] Martínez et. al. Evaluación de técnicas para el análisis de relevancia basadas en filtros sobre imágenes radiológicas. *Revista Ingeniería Biomédica*, 5(9):26–34, 2011. ISSN 1909-9762.
- [80] Robnik-Sikonja. An adaptation of relief for attribute estimation in regression. 2000. <https://www.researchgate.net/publication/2635627>.
- [81] ROBNIK et.al. Theoretical and empirical analysis of relief and rrelieff. *Machine Learning, Kluwer Academic Publishers. Manufactured in The Netherlands*, (53):23–69, 2003.