

**“ANÁLISIS DE CONVENIENCIA DE IMÁGENES
SATELITALES DE ACCESO ABIERTO PARA LA
DETERMINACIÓN DE COEFICIENTES DE
ESCURRIMIENTO”**

Ing. Diana Italibi Uraga Tovar

Para obtener el grado de
**Maestro en Ciencias (Energía y Medio
Ambiente)**



Casa abierta al tiempo
UNIVERSIDAD AUTÓNOMA METROPOLITANA

UNIVERSIDAD AUTÓNOMA
METROPOLITANA
UNIDAD IZTAPALAPA

DIVISIÓN DE CIENCIAS BÁSICAS E
INGENIERÍA

POSGRADO DE ENERGÍA Y MEDIO AMBIENTE

**“ANÁLISIS DE CONVENIENCIA DE IMÁGENES SATELITALES DE
ACCESO ABIERTO PARA LA DETERMINACIÓN DE COEFICIENTES
DE ESCURRIMIENTO”**

TESIS

Que para obtener el grado de

**MAESTRO EN CIENCIAS (ENERGÍA Y MEDIO
AMBIENTE)**

PRESENTA:

Ing. Diana Italibi Uruga Tovar

Director:

Dr. Felipe Omar Tapia Silva

Asesor:

Dr. Eugenio Gómez Reyes

Asesor:

Dr. Alejandra Aurelia López Caloca

Ciudad de México, Mex. 08 de Junio del 2018

Agradecimientos

La Maestría en Ciencias (Energía y Medio Ambiente) de la Universidad Autónoma Metropolitana Unidad Iztapalapa, pertenece al Padrón Nacional de Posgrados de Calidad del CONACyT y cuenta con apoyo del mismo Consejo con el convenio 003893; por lo que agradece la beca recibida, a través del convenio No. 739125/596725 para el desarrollo de esta tesis.

Comité tutorial

Director:

Dr. Felipe Omar Tapia Silva. Departamento de hidrobiología. División de Ciencias Biológicas y de la Salud. Universidad Autónoma Metropolitana.

Co-asesor:

Dr. Eugenio Gómez Reyes. Departamento de Ingeniería de Procesos e Hidráulica. División de Ciencias Básicas e Ingeniería. Universidad Autónoma Metropolitana.

Co-asesor:

Dra. Alejandra Aurelia López Caloca. Percepción Remota. Centro de Investigación en Ciencias de Información Geoespacial.

El jurado designado por la
Comisión Académica del Posgrado en Energía y Medio Ambiente
de la Unidad Iztapalapa, aprobó la tesis que presento **DIANA ITALIBI URAGA TOVAR**
El día **08 de Junio** del año **2018**

Miembros del Jurado

Dr. Eugenio Gómez Reyes

Presidente

Dr. José Luis Silván Cárdenas

Secretario

Dra. Claudia Rojas Serna

Vocal



INDICE

RESUMEN	5
ABSTRACT	6
I. INTRODUCCIÓN.....	7
I.1. PLANTEAMIENTO DEL PROBLEMA.....	7
I.2. JUSTIFICACIÓN	8
II. MARCO TEÓRICO.....	9
II.1. CUENCAS CON CARACTERÍSTICAS CONTRASTANTES.....	9
II.2. COEFICIENTE DE ESCURRIMIENTO	12
II.3. LA GEOMÁTICA	15
II.4. EL MODELADO GEOESPACIAL CONCEPTUAL	16
II.5. PERCEPCIÓN REMOTA.....	16
II.5.1. PRINCIPIOS FISICOS EN LA PERCEPCIÓN REMOTA.....	17
II.5.2. IMÁGENES SATELITALES DE ACCESO ABIERTO.....	19
II.5.3. LANDSAT 8.....	20
II.5.4. MODIS	21
II.5.5. SENTINEL 1	21
II.5.6. SENTINEL 2	21
II.5.7. RESOLUCIÓN TEMPORAL	21
II.5.8. RESOLUCIÓN ESPACIAL	22
II.5.9. RESOLUCIÓN RADIOMÉTRICA	23
II.5.10. RANGO ESPECTRAL.....	23
II.5.11. SENSIBILIDAD AL CLIMA	24
II.5.12. METODOS DE PROCESAMIENTO DE IMÁGENES DIGITALES PARA LA DETERMINACIÓN DE LA COBERTURA TERRESTRE.....	25
III. OBJETIVO Y PREGUNTA DE INVESTIGACIÓN	29
IV. METODOLOGÍA	30
IV.1. ÁREA DE ESTUDIO	30
IV.2. MODELADO GEOESPACIAL CONCEPTUAL.....	31
IV.3. COMPARACIÓN GENERAL DE LOS SENSORES	32
IV.4. ANÁLISIS DE BANDAS ESPECTRALES.....	32
IV.5. PROCESAMIENTO Y EVALUACIÓN DEL ACUERDO EN LA DETERMINACIÓN DE LA COBERTURA TERRESTRE	32



IV.6.	SELECCIÓN DE LA IMAGEN	35
IV.7.	DETERMINACIÓN DEL COEFICIENTE DE ESCURRIMIENTO	35
V.	RESULTADOS Y DISCUSIONES.....	37
V.1.	MODELADO GEOESPACIAL CONCEPTUAL.....	37
V.2.	COMPARACIÓN GENERAL DE LOS SENSORES	39
V.3.	ANÁLISIS DE BANDAS ESPECTRALES.....	40
V.4.	EVALUACIÓN DEL ACUERDO DE LA DETERMINACIÓN DE LA COBERTURA TERRESTRE	42
V.4.1.	SUBREGIONES HIDROLÓGICAS.....	422
V.4.2.	SENSOR.....	43
V.4.3.	ALGORITMO DE CLASIFICACIÓN.....	433
V.4.4.	SUBREGIÓN DEL BAJO-BRAVO	44
V.4.5.	SUBREGIÓN DEL BAJO-GRIJALVA	477
V.4.6.	SUBREGIÓN DEL VALLE DE MÉXICO	522
V.4.7.	SELECCIÓN DE LA IMAGEN.....	555
V.5.	DETERMINACIÓN DEL COEFICIENTE DE ESCURRIMIENTO	588
V.5.1.	SUBREGIÓN DEL BAJO-BRAVO	588
V.5.2.	SUBREGIÓN DEL BAJO-GRIJALVA	600
V.5.3.	SUBREGIÓN DEL VALLE DE MÉXICO	644
VI.	CONCLUSIONES.....	677
VII.	BIBLIOGRAFÍA.....	69



INDICE DE TABLAS

Tabla 1 Características contrastantes de las regiones de estudio.....	11
Tabla 2. Valores de la constante Kv en función de tipo y uso de suelo del territorio mexicano.....	14
Tabla 3. Clasificación de los sensores remotos y sus productos.	20
Tabla 4. Claves de polarización.....	24
Tabla 5. Expresión matemática de algoritmos de clasificación evaluados en el estudio.	27
Tabla 6. Ejemplo de Matriz de confusión de la validación de una clasificación.	28
Tabla 7. Imágenes utilizadas en el estudio.	31
Tabla 8. Áreas seleccionadas para el estudio.	31
Tabla 9. Tipos de cobertura identificados por área de estudio.	33
Tabla 10. Porcentaje de área utilizada para el entrenamiento de los algoritmos.....	33
Tabla 11. Factor K de las subregión de estudio.	36
Tabla 12. Comparación general de las características de los sensores del estudio.	39
Tabla 13. Bandas utilizadas para la clasificación de la cobertura terrestre.....	41
Tabla 14. Acuerdo global promedio por cuenca.....	42
Tabla 15. Acuerdo global por sensor.	43
Tabla 16. Acuerdo global por algoritmo de clasificación.....	43
Tabla 17. Acuerdo global de las combinaciones Sensor-Algoritmo del área de estudio de la subregión hidrológica del Bajo Bravo.	44
Tabla 18. Resultados del dominio de cobertura terrestre del área de estudio de la subregión del Bajo Bravo.	46
Tabla 19. Acuerdo global de las combinaciones Algoritmo-Sensor de del área de estudio de la subregión BG.	48
Tabla 20. Resultados del dominio de cobertura terrestre del área de estudio de la subregión del Bajo Grijalva.	51
Tabla 21. Acuerdo global de las combinaciones Algoritmo-Sensor de la subregión del Valle de México	52
Tabla 22. Resultados del dominio de cobertura terrestre del área de estudio de la subregión Valle México.	54
Tabla 23. Factores que intervienen en la selección de una imagen para la determinación de la Cobertura terrestre.	57



INDICE DE FIGURAS

Figura 1. Ubicación de las cuencas de estudio Bajo Grijalva, Valle de México y Bajo Bravo.	10
Figura 2. Integración de las disciplinas de la Geomática con los sistemas de información geográfica.....	15
Figura 3. El sistema global de observación de la OMM.....	17
Figura 4. Firma espectral la avena Silvestre.	18
Figura 5. Polarización de onda en un sistema RADAR.	24
Figura 6. Modelado Geoespacial conceptual del estudio.....	37
Figura 7. Identificación de componentes del sistema que serán incluidos en el SIG.	38
Figura 8. Análisis Espectral de los sensores MODIS, L8, Sentinel 1 y Sentinel 2 para la determinación de la cobertura terrestre.	40
Figura 9. Dominio en el acuerdo global, error de omisión y comisión promedio de la Región de análisis de la cuenca de Bajo Bravo.....	45
Figura 10. Dominio en el acuerdo global, error de omisión y comisión promedio de la Región de análisis de la subregión de Bajo Grijalva.	50
Figura 11. Dominio en el acuerdo global, error de omisión y comisión promedio de la Región de análisis de la subregión de Valle de México.....	53
Figura 12. Clasificación de la cobertura terrestres de 3 de las combinaciones Sensor-Algoritmo con mayor acuerdo en el área de estudio de la Subregión Hidrológica del Bajo Bravo.....	58
Figura 13. Información de entrada para la determinación del CE en el área de estudio de la Subregión Hidrológica del Bajo Bravo.....	59
Figura 14. Coeficientes de escurrimiento determinados a partir de clasificaciones de cobertura terrestre de 3 de las combinaciones Sensor-Algoritmo con mayor acuerdo y comparación con la determinación de INEGI para el área de estudio de la Subregión del Bajo Bravo.....	60
Figura 15. Clasificación de la cobertura terrestres de 3 de las combinaciones Sensor-Algoritmo con mayor acuerdo en el área de estudio de la Subregión Hidrológica del Bajo Grijalva.....	61
Figura 16. Información de entrada para la determinación del CE en el área de estudio de la Subregión Hidrológica del Bajo Grijalva.....	62
Figura 17. Coeficientes de escurrimiento determinados a partir de clasificaciones de cobertura terrestre de 3 de las combinaciones Sensor-Algoritmo con mayor acuerdo y comparación con la determinación de INEGI para el área de estudio de la subregión del Bajo Grijalva.....	63
Figura 18. Clasificación de la cobertura terrestres de 3 de las combinaciones Sensor-Algoritmo con mayor acuerdo en el área de estudio de la Subregión Hidrológica del Valle de México.....	64
Figura 19. Información de entrada para la determinación del Coeficiente de escurrimiento en el área de estudio de la Subregión Hidrológica del Valle de México.....	65
Figura 20. Coeficientes de escurrimiento determinados a partir de clasificaciones de cobertura terrestre de 3 de las combinaciones Sensor-Algoritmo con mayor acuerdo y comparación con la determinación de INEGI para el área de estudio de la Subregión del Valle de México.....	66



RESUMEN

El coeficiente de escurrimiento (CE) es una variable clave en estudio del comportamiento hidrológico. La Geomática a través de la integración y análisis de diferentes capas de datos en los Sistemas de Información Geográfica (SIG) y el uso de los productos generados por la percepción remota (PR), nos permite modelar los cambios de cobertura terrestre y generar mapas temáticos de la distribución espacial de los CE. A pesar de a la existencia de un número elevado de productos provenientes de PR disponibles en la actualidad, aun no se ha desarrollado una base metodológica que permita seleccionar de forma sistemática el producto adecuado al proyecto en cuestión. En el presente estudio se propone un esquema de comparación de las imágenes generadas por los sensores Landsat 8, MODIS, Sentinel 1 y Sentinel 2 para realizar un análisis que arroje la imagen más conveniente en la determinación de la cobertura terrestre contemplado las características que definen el comportamiento hidrológico de la cuenca. El área de análisis se limitó a tres zonas que representan a las distintas características presentes en el territorio mexicano, estas áreas se encuentran dentro de la subregión Bajo Grijalva (BG), la cuenca del Valle de México (VM) y las cuencas del río San Juan y el río Bajo Bravo (BB). Se determinó la cobertura terrestre de dichas áreas aplicando los algoritmos de Distancia Mínima (DM), Mapeo del Ángulo espectral (MAE), Máxima Verosimilitud (MV) y Maquinas de Soporte Vectorial (MSV). Cada uno de estos algoritmos fueron empleados en los productos L8, MD, S1 y S2 obteniendo distinto resultados. Se determinó el acuerdo, error de comisión y omisión global para cada una de las clasificaciones. Se analizó el Acuerdo global promedio por Cuenca, Sensor y Algoritmo y se calculó el dominio, acuerdo, error de comisión y omisión promedio de la clase en los resultados de todas las clasificaciones de cada cuenca. Se analizó la resolución temporal, espacial, espectral y radiométrica y su influencia en la cobertura terrestre determinada por cada combinación sensor-clasificador. De manera general el sensor L8 y el algoritmo DM presentaron el mayor acuerdo en la determinación de la cobertura terrestre. Sin embargo, el análisis de cuencas arrojó resultados distintos para cada una de ellas. En área del BB obtuvo un mayor acuerdo con la combinación S2-DM. El sensor L8 obtuvo el mejor desempeño en el área del BG junto con el algoritmo MSV. La combinación L8-MAE logró el mayor acuerdo en el área del VM. La determinación del CE por este método presenta la ventaja de obtener valores puntales que permite realizar análisis de escurrimiento en escalas locales. Los resultados mostraron que la selección de la imagen debe incluir las resoluciones características de cada sensor, así como el periodo de estudio, el tipo de cobertura terrestre y su dinámica, el clima, el tamaño de la cuenca y el algoritmo de clasificación empleado.



ABSTRACT

The runoff coefficient (CE) is a key variable in the study of hydrological behavior. Geomatics allows us to model land coverage change and generate thematic maps of the runoff coefficients spatial distribution. Integration and analysis of different layers of data in Geographic Information Systems (SIG) and the use of products generated by remote sensing (PR) is important for this matter. Despite the existence of a high number of PR products, a methodological basis has not yet been developed to systematically select the appropriate product to each project. In this study, we propose a comparison scheme of images to perform an analysis that yields the most convenient image in the determination of land coverage used in CE's calculus. Sensors Landsat 8, MODIS, Sentinel-1 and Sentinel-2 were included. Characteristics of each sensor were related with the ones that define the Hydrological behavior of a basin. The analysis area was limited to three zones: Bajo Grijalva (BG) subregion, Valley of Mexico basin (VM) and San Juan river- Bajo Bravo river subregion (BB). These areas represent the different characteristic climates of Mexican territory. The terrestrial coverage of the areas was determined applying the algorithms of Minimum Distance, Spectral Angle Mapping, Maximum Likelihood and Vector Support Machines. Each of these algorithms were used in the L8, MD, S1 and S2 products obtaining different results. Total Agreement, commission and omission error was calculated for each of the classifications. Global average agreement by Basin, Sensor and Algorithm was analyzed. Average of Domain, agreement, commission and omission error by class was calculated for each basin. The temporal, spatial, spectral and radiometric resolution and its influence on the terrestrial coverage determined by each sensor-classifier combination were analyzed. In general terms, L8 and the DM algorithm presented the greatest agreement in the determination of land cover. However, watershed analysis yielded different results for each of them. In the BB area, it obtained a greater agreement with the S2-DM combination. The L8 sensor obtained the best performance in the BG area along with the MSV algorithm. The L8-MAE combination achieved the greatest agreement in the VM areas. The determination of the CE by this method has the advantage of obtaining baseline values that allow performing runoff analysis at local scales. The results showed that the selection of the image should include the characteristic resolutions of each sensor, as well as the study period, the type of land cover and its dynamics, the climate, the size of the basin and the classification algorithm used.



I. INTRODUCCIÓN

I.1. PLANTEAMIENTO DEL PROBLEMA

El acceso al agua es un derecho establecido en la constitución (CONT, 2016). Al ser un recurso finito, su manejo debe contar con estrategias que permitan dar soporte a las necesidades actuales. Sin embargo, dos tercios del territorio nacional mexicano han comprometido en su totalidad el agua que tienen disponible ejerciendo así una fuerte presión en el abastecimiento del vital líquido (CONAGUA, 2014).

En diversas regiones, entidades federativas y localidades del país, los volúmenes de agua concesionados superan el escurrimiento y la recarga de los acuíferos (DOF, 2015). Por otro lado, 1, 019 municipios del territorio nacional presentan algún grado de riesgo de inundación de los cuales 162 se encuentran en alto riesgo (CENAPRED, 2007). Las inundaciones causan no solo daños en las actividades humanas sino también problemas relacionados con el entorno como: deforestación de cuencas, invasión de lagunas de regulación, obstrucción o desvío de cauces, cambio en el régimen de escurrimiento, cambios en el microclima, cambios fisiológicos en la vegetación e incluso la muerte de ciertas especies vegetales no adaptadas (Mommer & Visser, 2005). Esto provoca modificaciones en la diversidad ecológica y alteraciones en el ciclo del carbono y de los nutrientes en el suelo.

Realizar un correcto balance hídrico es la base para una evaluación cuantitativa de los recursos de agua y las modificaciones que causa la actividad antropogénica, además facilita el control y redistribución del recurso (Sokolov, 1981). El coeficiente de escurrimiento (CE) es una variable clave en estudio del comportamiento hidrológico ya que es utilizada en cálculos de esorrentía, ecuaciones de balance hídrico y otros estudios hidrológicos (MERZ, 2006).

La Norma Oficial Mexicana número 11 (NOM-011-CONAGUA-2015) de la Comisión Nacional del Agua (CONAGUA) utiliza el CE como parámetro para determinar la disponibilidad media anual de las aguas nacionales. De acuerdo con esta norma el CE del área de estudio se puede obtener mediante tres métodos: (1) Usando el conjunto de datos vectoriales de las cartas hidrológicas de aguas superficiales escala 1:250000, (2) mediante transferencia de información hidrométrica y climatológica de una cuenca vecina o bien (3) obteniéndolo de tablas de correspondencia en función de tipo y uso de suelo (DOF, 2015).

Las cartas hidrológicas de aguas han sido generadas por el Instituto Nacional de Estadística, Geografía e Informática (INEGI) para la república mexicana con base a la información proporcionada por la CONAGUA. El resultado muestra la distribución espacial de los CE de las cuencas hidrológicas, donde los valores de CE se agrupan en rangos que representan las condiciones del escurrimiento: [0 a 5%], [5 a 10%], [10 a 20%], [20 a 30%] y [30 a 100%]. La elaboración de las cartas respectivas, su calibración y valoración requiere de gran inversión de tiempo, esfuerzo y recursos económicos, por lo que su disponibilidad al público siempre está desfasada en grandes periodos de tiempo. Por ejemplo, la última carta hidrológica de la cuenca del Valle de México data del año 1982 a pesar de contar con la mejor disponibilidad de información y solo incluye las condiciones de cobertura vegetal. El método de transferencia de información hidrométrica y climatológica adecua el valor de una cuenca vecina a la cuenca de estudio tiene la desventaja de introducir errores de cálculo y no tomar valores del sitio.



El tercer método, utiliza la información de precipitación, tipo y uso de suelo, sin embargo, este último parámetro no siempre se encuentra disponible o actualizado.

A nivel internacional, el método del Numero de Curva es el más utilizado para encontrar las relaciones escurrimiento-precipitación. Este método empírico fue propuesto por el servicio de conservación de recursos naturales de los Estados Unidos de América (NRCS por sus siglas en ingles) en la década de 1950 (Woodward et al., 2002). El método ha sido utilizado y recomendado en el cálculo de escurrimiento superficial en México (Kurczyn-Robledo et al., 2007). También se usa comúnmente como un término de abstracción o modelo de pérdida para simulaciones continuas y de eventos y se ha adaptado para estimar las tasas máximas de escorrentía utilizando el CN y los hidrogramas unitarios en diversos tipos de suelo (Fennessey & Hawkins, 2001). Sin embargo, los datos con los que se modelo el método no son claramente rastreables, por lo que usualmente se considera más fiable de lo que realmente es y se utiliza más allá de sus limitaciones (Fennessey & Hawkins, 2001).

1.2. JUSTIFICACIÓN

La Geomática a través de la integración y análisis de diferentes capas de datos en los Sistemas de Información Geográfica (SIG) y el uso de productos generados por la percepción remota (PR), nos permite modelar los cambios de cobertura terrestre y generar mapas temáticos de la distribución espacial de los CE. La implementación de un método de determinación del CE en una plataforma SIG a partir de la integración de relativamente poca y accesible información permite estimar y monitorear de manera eficiente los cambios en los patrones de escurrimiento en regiones con características ambientales contrastantes y diversos niveles de perturbación (Berlanga-Robles, 2011). Además, basar el cálculo en la cobertura terrestre del sitio permite obtener resultados actualizados pues este parámetro se actualiza con mayor velocidad que el escurrimiento total.

Gracias a el desarrollo tecnológico de los sensores remotos podemos disponer de productos con características diversas, que permiten conocer y registrar la intensidad de la radiación electromagnética dentro de la una zona específica del espectro en espacios y tiempos cada vez más cortos, como resultado se obtienen imágenes con un gran detalle u otras con un panorama general del objeto estudiado. Así también, se han desarrollado diversos programas a nivel internacional o nacional que permiten la observación de la tierra y producen datos de cobertura terrestre a distintos niveles de resolución y acuerdo.

Disponer de las imágenes procedentes de sistemas con alta tecnología en cualquier circunstancia pareciera ser en ideal lógico pues nos permite acceder a imágenes con gran detalle. Sin embargo, las características de los productos a utilizar deben seleccionarse en base al objetivo del proyecto, y a la escala de trabajo del análisis a realizar, entre otros factores que nos permitan identificar el sensor adecuado a los requerimientos del proyecto particular.



A pesar de a la existencia de un número elevado de productos provenientes de PR disponibles en la actualidad, aun no se ha desarrollado una base metodológica que permita seleccionar de forma sistemática el producto adecuado al proyecto en cuestión.

En el presente estudio se desarrolló una metodología útil para la determinación de los CE que contempla, además de la aplicación de un SIG, el uso de información de la cobertura terrestre obtenida desde PR y que se encuentra disponible en formato abierto. Para ello, se realizó un análisis de las características necesarias de una imagen satelital para determinar el CE de cuencas con diferentes características en México con la intención de disminuir el error que puede generarse al utilizar capas geográficas de uso de suelo desactualizado.

II. MARCO TEÓRICO

II.1. CUENCAS CON CARACTERÍSTICAS CONTRASTANTES

La delimitación oficial de las subregiones hidrológicas en nuestro país muestra una gran heterogeneidad espacial. Entre éstas, existen 79 que varían sus tamaños entre los 3,000 km² y los 90,000 km² (CONAGUA, 2007). Dichas subregiones están conformadas por 1,471 cuencas exorreicas, endorreicas y arreicas, de las cuales 807 son menores a 50 km² y 16 tienen una extensión mayor a 20,000 km². En el caso de estas últimas, su gran extensión geográfica y el hecho de comprender diferentes delimitaciones político-administrativas dificulta su gestión integral (Cotler, 2010). Por otra parte, la presencia de cuencas muy pequeñas dificulta su estudio por la ausencia de información a baja escala.

El comportamiento hidrológico de cada región del país está determinado por la variabilidad espacio temporal de factores geográficos como: cantidad y tipo de vegetación, configuración orográfica, estructura geológica, precipitación y otros factores climatológicos, (Carrillo-Rivera, J., 2005). Con el fin de incluir cuencas ejemplares de las distintas características presentes en el territorio mexicano, este trabajo de investigación analiza las subregiones hidrológicas o cuencas incluidas en la Figura 1. Estas son contrastantes en términos de tamaño, clima, tipo de cobertura terrestre, dinámica poblacional, disponibilidad y usos de agua. Estas son: a) la subregión Bajo Grijalva (BG) ubicada al sur del país en el trópico húmedo y por ello con alta disponibilidad de agua, b) la cuenca del Valle de México (VM) ubicada en el altiplano central de clima templado y con una presión de población intensa y c) al norte con clima semiárido y baja disponibilidad de agua las cuencas del río San Juan y el río Bajo Bravo (BB).

Las regiones seleccionadas siguen los lineamientos establecidos en el proyecto *“Hacia una Gestión Integral del Agua por Cuenca Hidrológica: un análisis de disponibilidad y usos”*, financiado por el Consejo Nacional de Ciencia y Tecnología (CONACyT), dentro de la convocatoria *“Proyectos de desarrollo científico para atender problemas nacionales 2014”*. El proyecto se realizó durante dos años y abarcó las mismas regiones hidrológicas de estudio. En el mismo se analizaron, los avances y obstáculos en la implementación del modelo de administración basado en el enfoque de Gestión Integral de Recursos Hídricos con base en indicadores clave aplicados para los tres casos de estudio. Como producto de este proyecto se publicará un libro donde se analizan los resultados. El capítulo V expondrá la factibilidad de aplicación de técnicas de PR para la determinación de diversas variables



del balance hidrológico como el CE. Este proyecto aporta una metodología para la selección de los datos que se utilizan en el territorio mexicano para la determinación del CE.



Fuente: Diseño propio con datos de CONAGUA, 2007

Figura 1. Ubicación de las cuencas de estudio Bajo Grijalva, Valle de México y Bajo Bravo.

La Tabla 1 muestra que las subregiones hidrológicas se encuentran en el norte, centro y sureste del país respectivamente e incluyen los climas semiáridos, templado y húmedo en extensiones que van entre los 9,738 km² a 71, 034 km². Estas tienen distintos usos de suelo y una densidad poblacional que va entre los 23 y los 6, 000 [hab/km²]. Además, se caracterizan por factores hidrológicos distintos entre los que destaca el CE tiene valores entre 0 y 30.

Al este de la Región Hidrológica número 24 Bravo Conchos se ubica la cuenca del BB. Esta región hidrológica se extiende por un total de 57 municipios de los estados de Nuevo León, Coahuila y Tamaulipas. En esta parte del territorio la densidad poblacional varía en un intervalo de 23 y 80 hab/km² de la cual entre un 15 y un 35% se encuentra empleada en actividades industriales y el porcentaje de empleados asalariados que va de entre un 60% a un 80% (INEGI, 2010). El núcleo de población más importante es la ciudad de Monterrey que contaba con 1, 109, 171 habitantes en el año 2015 (INEGI, 2015). La corriente principal es el Río Bravo que es el séptimo de mayor vertiente a nivel nacional (CONAGUA, 2015).

La cuenca del BG o Grijalva-Villa se localiza en las coordenadas extremas 18°26'31 N, 17°10'11 S, 93°37'39 E y 92°35'25 O, cubriendo un total de 57 Municipios. Esta cuenca forma parte de la zona noroeste de la Región Hidrológica No. 30 Grijalva-Usumacinta (CONAGUA, 2007). Su corriente principal, el río González desemboca en el Golfo de México siendo el punto de salida de la cuenca y se localiza en el municipio de Centla en las coordenadas 93°05'31" O y 18°26'38" N, a nivel del mar. La zona tiene porcentaje importante de empleados asalariados que va de entre 60% a 80% de los



cuales del 15 al 25% de la población se dedica a actividades industriales, pero alrededor de un 30% del total perciben menos de un salario mínimo (INEGI, 2009). Las tres regiones geoeconómicas son: Chontalpa, Centro y Sierra. El núcleo de población más importante es la ciudad de Villahermosa con más de 300,000 habitantes (INEGI, 2010).

La Cuenca del VM está integrada por 111 municipios. Forma parte de la Región hidrológica No. 26 (CONAGUA, 2015). Esta región se encuentra altamente urbanizada por lo que contiene la mayor densidad poblacional en el estudio. En esta área, un porcentaje aproximado al 70% de la población se encuentra empleada en actividades de comercios y servicios (INEGI, 2009). El núcleo de población más importante es la Ciudad de México y la zona metropolitana con más de 19 millones de habitantes (INEGI, 2007). El Lago de Tecocomulco es el cuerpo de agua principal, siendo el relicto de la cuenca del VM que contenía diferentes lagunas, las cuales han desaparecido debido a la evolución geológica y las actividades antropogénicas de la zona (Lanza & Gómez, 2012).

Tabla 1 Características contrastantes de las regiones de estudio.

CARACTERÍSTICA	NORTE	CENTRO	SUR
Subregión hidrológica	Bajo rio Bravo y Rio San Juan	Valle de México	Bajo Grijalva
Ubicación Nacional	Noreste	Centro	Sureste
Ubicación Estatal	Nuevo León y Tamaulipas	Ciudad de México, Estado de México, Hidalgo, Tlaxcala y Puebla	Tabasco y Chiapas,
Área de captación [km ²]	9, 499.28 y 32,941.6	9, 495	9, 822
Altitud Media [msnm]	150	2, 800	1, 016
Subcuencas hidrológicas	20	1	28
Precipitación media anual [mm]	500-800	400-1500	1500-4500
Climas	Semiáridos cálido, Áridos cálido y Semicálido subhúmedo	Semifrío subhúmedo, Templado subhúmedo y semiárido subhúmedo con lluvias en verano	Cálidos húmedos a templados húmedo con lluvias todo el año
Uso de Suelo	Mayormente agrícola, asentamientos humanos industriales, Matorrales, Mezquital Xerófilo, Pastizales, cuerpos de agua mayormente artificiales.	Mayormente Urbano, zonas agrícolas con asentamientos urbanos, Bosques, Matorrales y cuerpos de agua de tamaño medio	Mayormente vegetación (Manglar, Popal, tumbra), zona agrícola temporal, asentamientos humanos pocos desarrollados, cuerpos de agua de gran extensión.
Densidad Poblacional [hab/km ²]	23-80	315-6000	20-80
Escurrecimiento medio anual [mm]	10-50	10-500	1000-2000
Evapotranspiración [mm]	400-500	400-800	1401-1500
Coefficiente de escurrecimiento [%]	de 0 a 20	de 0 a 30	de 0 a 30
Tipo de cuenca	Exorreica	Endorreica	Exorreica

Fuentes: Elaboración propia con datos de Cuervo-Robayo et al. (2014), García (1998), Maderey Laura (1990), ¹INEGI (2010), Jiménez & Maderey (1992) e INEGI (2013).



II.2. COEFICIENTE DE ESCURRIMIENTO

El CE se define como la porción de la lluvia que se convierte en escorrentía superficial directa durante un evento de precipitación (Sherman, 1932). Entonces, el CE es igual al cociente del volumen de escurrimiento directo entre el volumen total de lluvia. Existen métodos empíricos para la determinación del CE que se aplican cuando se tienen registros simultáneos de lluvias y escurrimientos en una cuenca hidrológica. Cuando el área de drenaje está constituida por diferentes tipos de cubierta y superficies, se puede obtenerse el CE en función de las características de cada porción de área como un promedio ponderado (Breña & Jacobo, 2006). Sin embargo, los cálculos por métodos empíricos requieren de registros de largos periodos de tiempo (Merz et al., 2006). Además, el uso de instrumentos para la medición, su calibración y mantenimiento requiere de gran inversión de tiempo, esfuerzo y recursos económicos que no se encuentran siempre disponibles en la región de interés o para periodos prolongados. Por esto, se proponen técnicas de PR que implica resultados con menor costo y tiempo.

Los coeficientes de escurrimiento se utilizan ampliamente como una variable de diagnóstico de la generación de escorrentía en las cuencas y el estudio de procesos hidrológicos (Merz et al., 2006), También es un parámetro de entrada importante en el diseño hidrológico, se utilizan para la comprensión de la frecuencia de inundaciones (Sivapalan et al., 2005) y se han usado para evaluar la porción de lluvia de reciclamiento, especialmente en regiones áridas y semiáridas (Savenije, 1996).

El escurrimiento superficial depende fundamentalmente de dos tipos de factores: Meteorológicos y Fisiográficos (Villón-Bejar, 2002). Sin embargo, los mayores impactos sobre los sistemas hidrológicos son causados por cambios en los patrones de cobertura y uso del suelo (Bhaduri et al., 2000). Si este tipo de modificaciones en el balance hídrico sucede sobre áreas amplias o críticas de una cuenca o región, esta puede tener impactos inmediatos y a largo plazo. Los impactos incluyen el aumento en los volúmenes de escurrimiento y la reducción de los suministros de agua a los mantos freáticos (Bhaduri et al., 2000; Harbor, 1994; Ma, 2004). Por lo tanto, la evaluación de los impactos del cambio en la cobertura y el uso del suelo sobre el comportamiento hidrológico es un aspecto fundamental para el establecimiento de las estrategias de manejo ambiental y prevención de desastres (Berlanga-Robles, 2011).



De acuerdo con la establecido por la NOM-011-CONAGUA-2015, la expresión matemática para la determinación del CE es dependiente de la precipitación P y del parámetro K obtenido de tablas, de acuerdo con las siguientes expresiones:

$$Ce = \frac{K(P-250)}{2000} \quad \text{si } K \leq 0.15 \dots\dots\dots \text{Ecuación 1}$$

$$Ce = \frac{K(P-250)}{2000} + \frac{K-0.15}{1.5} \quad \text{si } K > 0.15 \dots\dots\dots \text{Ecuación 2}$$

La precipitación puede ser obtenida con diversas metodologías siendo oficialmente aceptada la que se genera con las mediciones realizadas por CONAGUA. Las tablas de correspondencia permiten obtener el valor del parámetro K en función de la textura (INIFAP, 1995) y el uso de suelo, una aproximación de estos valores se incluye en la Tabla 2, donde los suelos tipo A son aquellos permeables, los suelos tipo B son medianamente permeables y los suelos tipo C son casi impermeables (DOF, 2015; Solís et al., 2005). Por otro lado, los datos de uso de suelo se encuentran típicamente desactualizados, pero pueden ser sustituidos por datos de cobertura terrestre representativa en el territorio mexicano. De igual forma, esta última se encuentran comúnmente desactualizada o no se tiene información. Por ejemplo, a nivel nacional se cuenta con el programa de series de uso de suelo que se actualiza cada 3 años, pero esta este análisis se realiza con información de dos años anteriores a la fecha de su publicación y se presenta en escalas regionales de Escala 1:250 000 lo que dificulta el análisis local (INEGI, 2013)

Entonces, el CE es determinado como un parámetro espacialmente variable. Como resultado se obtiene un valor de CE por cada pixel de la región de estudio y es posible por ejemplo proceder a obtener los demás elementos del balance hidrológico. Realizar lo antes descrito permite también efectuar los cálculos necesarios para precisar la disponibilidad natural media anual de las aguas nacionales o el balance hidrológico necesario para la realización de un proyecto específico.



Tabla 2. Valores de la constante K_v en función de tipo y uso de suelo del territorio mexicano.

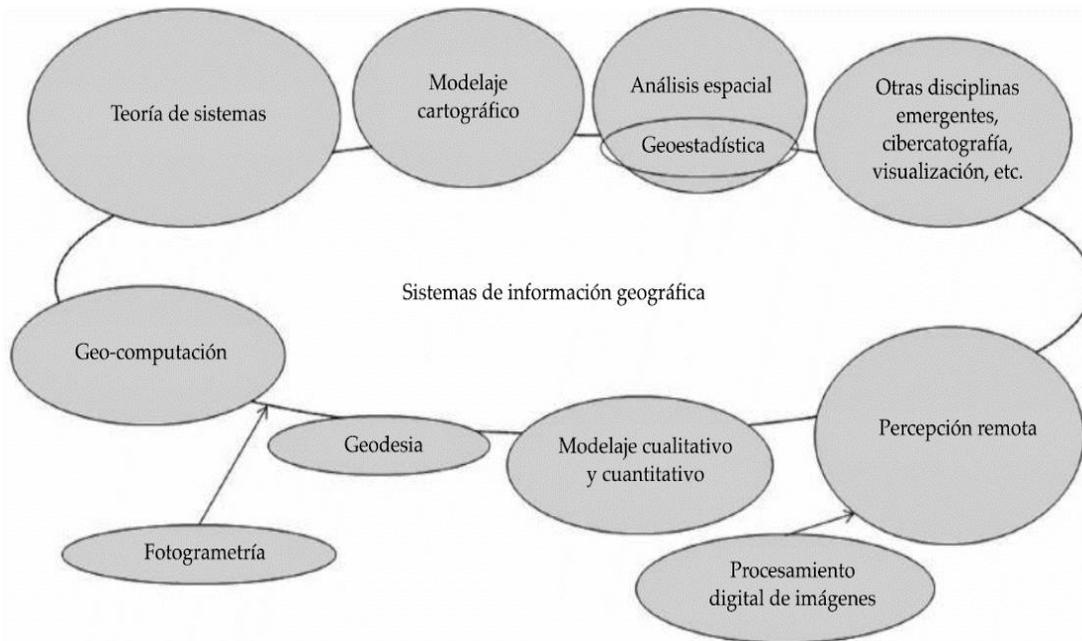
Uso de Suelo (cobertura Terrestre) Categoría de textura de suelo	Factor $K = f(\text{Suelo})$		
	Suelo A	Suelo B	Suelo C
Bosque de encino	0.07	0.16	0.24
Bosque de encino con vegetación secundaria arbustiva y herbácea	0.07	0.16	0.24
Bosque de Oyamel (incluye Cedro)	0.07	0.16	0.24
Bosque de Oyamel (incluye Cedro) con vegetación secundaria arbustiva y herbácea	0.07	0.16	0.24
Bosque de Pino	0.07	0.16	0.24
Bosque de pino con vegetación secundaria arbustiva y herbácea	0.07	0.16	0.24
Bosque de Pino-encino (incluyendo encino-pino)	0.07	0.16	0.24
Bosque de Pino-encino (incluyendo encino-pino) con vegetación secundaria	0.07	0.16	0.24
Bosque mesófilo de Montaña	0.07	0.16	0.24
Bosque mesófilo de Montaña con vegetación secundaria arbustiva y herbácea	0.07	0.16	0.24
Matorral crasicaule	0.22	0.28	0.30
Matorral subtropical	0.22	0.28	0.30
Matorral subtropical con vegetación secundaria arbustiva y herbácea	0.22	0.28	0.30
Mezquital (incluye huizache)	0.22	0.28	0.30
Pastizal cultivado	0.14	0.20	0.28
Pastizal cultivado	0.14	0.20	0.28
Pradera de alta montaña	0.14	0.20	0.28
Riego suspendido	0.24	0.28	0.30
Selva baja caducifolia y subcaducifolia	0.17	0.26	0.28
Selva baja caducifolia y subcaducifolia con vegetación secundaria arbustiva y herbácea	0.17	0.26	0.28
Selva media caducifolia y subcaducifolia	0.17	0.26	0.28
Selva media caducifolia y subcaducifolia con vegetación secundaria arbustiva y herbácea	0.17	0.26	0.28
Vegetación halófila y gipsófila	0.05	0.05	0.05

Fuente: Solís et al., 2005.



II.3. LA GEOMÁTICA

Geomática es una ciencia basada en un enfoque integrado, multidisciplinario y sistémico para seleccionar marcos teóricos y conceptuales que permitan derivar técnicas apropiadas para coleccionar, almacenar, integrar, modelar, analizar, recuperar, transformar, desplegar y distribuir datos espacialmente georreferenciados provenientes de diferentes fuentes con características bien definidas de precisión y continuidad en una forma digital (Gomarazca, 2010). El resultado es una ciencia tipo II que surge de la sociedad y busca cubrir sus necesidades (Tapia-Silva, 2011), a partir de la integración de componentes independientes de la teoría general de sistemas, el modelaje cartográfico, el análisis espacial, la cibercartografía, la geocomputación, la geodesia, del modelaje cuantitativo y cualitativo, la PR y otras disciplinas emergentes (Tapia-Silva, 2014), utilizando como herramienta de integración a los SIG (Figura 2).



Fuente: Tapia-Silva, 2014.

Figura 2. Integración de las disciplinas de la Geomática con los sistemas de información geográfica.

En materia Hidrológica, la Geomática ha sido aplicada para desarrollar modelos hidrológicos, estimar volúmenes de agua y escorrentía (Bhaduri et al., 2000; Treviño et al., 2002), estimar tasas de erosión (Symeonakis et al., 2007), evaluar la contaminación del agua por fuentes no puntuales (Bhaduri et al., 2000; Ma, 2004), modelar cambios de patrones espaciales y temporales de parámetros hidrológicos (Tapia-Silva, 2014; Harbor, 1994; Schmutge et al, 2002; Bernal–Brooks et al., 2002) además de simular el balance hidrológico en unidades espaciales, el flujo de agua, procesos de inundación (Ardila & Quintero, 2013) y los efectos de distintos eventos de perturbación (Mendoza et al, 2002).



II.4. EL MODELADO GEOESPACIAL CONCEPTUAL

El modelado geoespacial conceptual (MGC) es una metodología que dentro del marco de la Geomática busca definir un modelo conceptual del geoespacio, representando la realidad del territorio para permitir la identificación de las características relevantes del problema por resolver. Como resultado se obtiene un modelo conceptual correspondiente al problema que queremos solucionar en el entorno de los SIG y la Geomática (Tapia-Silva, 2015).

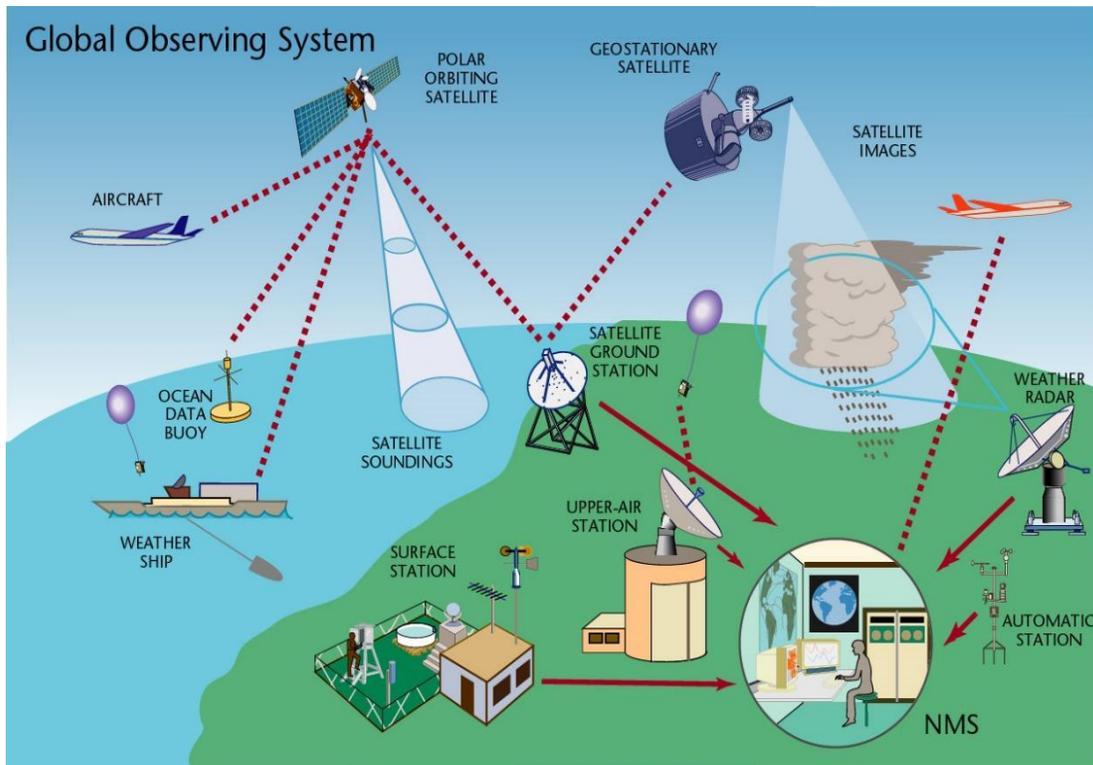
Este MGC permite tener un primer acercamiento del problema de interés desde el mundo conceptual para transformarlo a un modelo manejable en el mundo geográfico, esto significa delimitar geográficamente el problema, identificar elementos interactuantes y sus relaciones y después seleccionar el subsistema a implementar mediante modelos específicos del mundo geográfico.

II.5. PERCEPCIÓN REMOTA

La PR es el arte, ciencia y tecnología que permite observar a distancia objetos, escenas o fenómenos utilizando instrumentos montados sobre diversas plataformas, sin realizar un contacto físico directo. Para esto pueden utilizarse dispositivos que detecten en tiempo real la energía emitida o reflejada por el objeto de interés. Dicha energía puede ser luz o cualquier otra onda electromagnética, campos de fuerza u ondas acústicas (Tempfli et al, 2009).

Los sistemas de PR para la observación de la superficie terrestre han sido caracterizados por los autores citados al final de este párrafo en base a elementos esenciales. Estos elementos son: la fuente de energía, la interacción atmosférica, la cobertura terrestre u objeto de estudio, el sistema sensor que recopila los datos, el sistema de transmisión, recepción, procesamiento y comercialización y el intérprete o el usuario final que realiza en análisis de aplicación (Chuvienco, 1991; Natural-Resources, 2016, Martínez-Muñoz et al., 2005).

Existen sistemas de observación globales complejos que permiten la recopilación y análisis de información a nivel mundial. Entre ellos destaca el sistema coordinado de métodos e instalaciones (Figura 3) diseñado para hacer observaciones meteorológicas y otras observaciones ambientales a escala mundial en apoyo de todos los programas de la Organización Meteorológica Mundial. Las mediciones comprenden instalaciones de observación en tierra, en el mar, en el aire y en el espacio ultraterrestre (OMM, 2017).



Fuente: Organización meteorológica mundial.
Figura 3. El sistema global de observación de la OMM.

Las herramientas de la PR han sido integradas para elaborar análisis de cuencas hidrológicas y CE. Entre este tipo de estudios están: Cálculos del escurrimiento total (Zhou et al., 2013), evaluación de impactos en la cuenca hidrológica (Webster et al., 2014), efectos de la cobertura terrestre en el CE (Nutchant et al., 2011), efecto de las propiedades de captación del suelo en el CE (Zhang, Z. et al., 2014), desarrollo de aplicaciones en SIG para incluir la PR en el cálculo de CE (Zhan, X. et al., 2004) y uso de imágenes Landsat 5 y 7 para determinar el CE de una cuenca de la región de Al-Baha en Arabia Saudita (Mahmoud, et al., 2014).

II.5.1. PRINCIPIOS FISICOS EN LA PERCEPCIÓN REMOTA

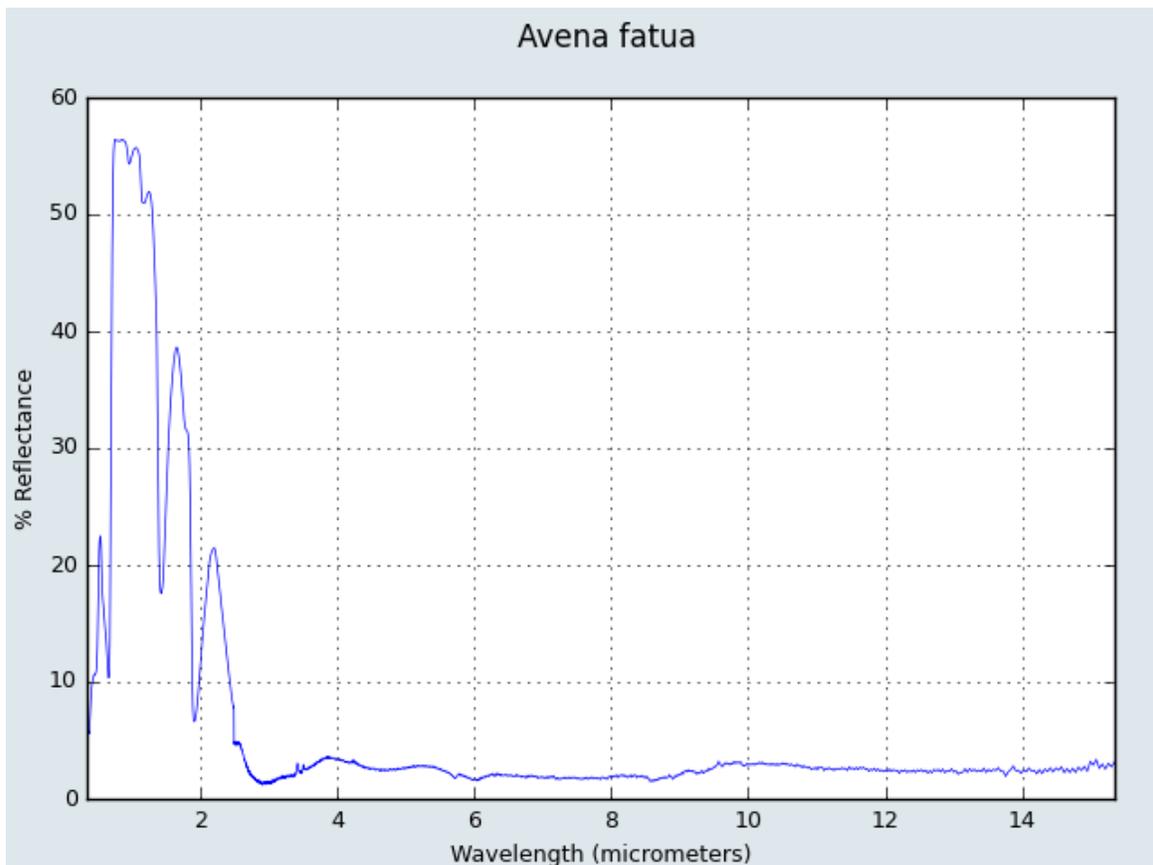
La radiación electromagnética es la energía medida en las técnicas de PR. La radiación electromagnética que existe en el universo, tanto la natural como la artificial, es una forma dinámica de energía causada por la oscilación de una carga eléctrica, que se manifiesta únicamente cuando interactúa con la materia (Fernández-García, 2000). Esta energía puede caracterizarse por las propiedades de longitud de onda, frecuencia, amplitud y fase, se mueve a la velocidad de la luz en un patrón de onda armónico en intervalos de tiempo iguales (Sabins, 2007). El comportamiento de estas ondas electromagnéticas en el espacio libre está regido por las ecuaciones Maxwell y la teoría del quantum de Plank (Gomarezca, 2010).

El espectro electromagnético completo podría ser utilizado en las técnicas de PR, ya que la radiación electromagnética es emitida por todos los cuerpos que tienen temperaturas por encima del cero



absoluto. Sin embargo, solo una parte del espectro electromagnético usado en PR tiene la característica de constituir "ventanas" atmosféricas relativamente transparentes. A través de ellas la tierra puede ser detectadas de manera efectiva por sensores disponibles en la actualidad (Schowengerdt, 2006). Entre estas ventanas de encuentran: Visible(V), Infrarrojo cercano (NIR), Infrarrojo de onda corta (SWIR), infrarrojo medio (MWIR), infrarrojo lejano (TIR o LWTR) y las microondas.

La radiación puede propagarse en fenómenos de dispersión, absorción, transmisión, reflexión y radiación. Este comportamiento está determinado por las características físicas de los cuerpos: agua, suelo, vegetación, nubes, etc. (Sabins, 2007). Cada objeto absorbe, transmite y refleja ondas muy particulares en los distintos rangos del espectro electromagnético. Este comportamiento diferencial que presenta la radiación reflejada o emitida desde algún tipo de superficie u objeto es conocido como la firma espectral del mismo. Su estudio está dispuesto en forma de grafica donde los datos de reflectancia se colocan en el eje de las abscisas y la longitud de onda se dispone el eje de las ordenadas. La Figura 4 muestra la firma espectral de la avena silvestre de acuerdo con los resultados de la librería espectral ASTER (Baldrige, et al., 2009).



Fuente: Baldrige, et Al. (2009).
Figura 4. Firma espectral la avena Silvestre.



II.5.2. IMÁGENES SATELITALES DE ACCESO ABIERTO

Los satélites sirven como plataformas de los sensores remotos. Estos son ubicados por encima de la atmósfera terrestre y permiten observar los objetos sobre la corteza de la tierra. Además, son frecuentemente utilizadas para el escaneo térmico, obtener una cobertura sistemática de la tierra y otras aplicaciones (Tempfli, K. et al., 2009).

Los instrumentos que son utilizados por la PR para recopilar la información pueden ser clasificados por: energía que utilizan, resolución espectral (RS), resolución espacial (RE), resolución temporal (RT) y resolución radiométrica (RR) o según los productos que generen. La Tabla 3 muestra que la división según la energía que utilizan se realiza en activos y pasivos, el primer registra la radiación emitida por objeto ajeno al instrumento. Son ejemplos de instrumentos pasivos: escáner, cámara térmica y cámara de video. Los instrumentos activos generan la radiación con la que realizan sus mediciones como por ejemplo el radar (Gomarazca, 2010). La división por la resolución espacial tiene la clase óptica y radar de acuerdo con el área del espectro electromagnético a la que son sensible. Cuando se clasifican los sensores según su producto pueden dividirse en imágenes y mediciones, las imágenes se obtienen por medio de radiómetros, mientras que las mediciones se consiguen al utilizar cámaras fotográficas, escáneres, cámaras térmicas y RADAR. Según a la resolución espacial, temporal y radiométrica los productos suelen dividirse en alto, moderado y bajo y están definida de acuerdo con la resolución con la que es tomada por el sensor que la genera.

Aunque en la actualidad existen numerosos satélites que transportan este tipo de sensores, esta tesis se limita a los de reciente lanzamiento que permiten el libre acceso a sus productos: LANDSAT 8 (L8), MODIS (MD), SENTINEL-2 (S2) y SENTINEL-1 (S1). Las primeras tres misiones analizadas son sensores ópticos y la última es sensible a las microondas (S1). Además, con el desarrollo de esta tesis se aplica Software de acceso abierto con el fin de impulsar su difusión (Zuhlke et al., 2015; Congedo, 2016; Grizonnet et al., 2017; CNES, 2018).

El procesar imágenes satelitales de acceso abierto que provienen de diferentes sensores remotos permite la observación, identificación, representación, evaluación y monitoreo de la cobertura terrestre. Los resultados presentan acuerdos con el terreno verdadero en función de la resolución espacial, temporal y radiométrica de cada sensor (Rogan & Chen, 2004). En esta tesis se evalúa el acuerdo que logran los sensores antes mencionados al identificar tipos de cobertura terrestre.



Tabla 3. Clasificación de los sensores remotos y sus productos.

Clasificado por	División	Descripción	Subdivisión
Energía que utilizan	Activo	Registran la radiación Reflejada o Emitida por la superficie terrestre	Cámaras fotográficas, escáneres, cámaras térmicas y cámaras de vídeo
	Pasivo	Generan por si mismos la radiación que miden tras ser reflejadas	Radares
Resolución espectral	Óptico	Utilizan la ventana espectral del óptico y sus cercanos en un intervalo de 0,3-15 μ	Multiespectral: 2-9 bandas espectrales
			Superespectral: 10-16 bandas espectrales.
	Radar	Utiliza microondas de 1 mm a 1 m	Hiperspectral: más de 16 bandas espectrales. Polarización única o multipolarizada y con uno o varios ángulos de incidencia, en frecuencia única o en multifrecuencia
Resolución espacial	-	El tamaño de la superficie del objeto que es percibido por el sensor	Alto Moderado Bajo
Resolución temporal	-	Periodo en el cual dos adquisiciones consecutivas son hechas la misma área	Alto Moderado Bajo
Resolución radiométrica	-	Número de niveles digitales en los que se expresa la variable	Alto Moderado Bajo
Producto	Mediciones	Se obtienen por medio de radiómetros, espectrofotómetros, etc.	-
	Imágenes	Se consiguen a utilizar cámaras fotográficas, escáneres, cámaras térmicas y RADAR.	-

Fuente: Elaboración propia con información de Gomarazca, 2010.

II.5.3. LANDSAT 8

El satélite L8 es el más reciente lanzamiento de la misión de continuidad Landsat como parte del Programa de Investigación del Cambio Global de los Estados Unidos (USGCRP) que comenzó en el año de 1972. L8 Fue lanzado en febrero del 2013 con la misión de proporcionar la adquisición repetida de datos multiespectrales de resolución moderada de la superficie de la Tierra para una serie de prioridades científicas, tales como cambio de la cobertura terrestre y la dinámica del uso de la tierra. L8 opera en una órbita circular polar sincronizada al sol y lleva a bordo dos sensores remotos, el reproductor de imágenes Operacional de la Tierra (OLI) y el Sensor de Infrarrojo Térmico (TIRS). Su gran disponibilidad de datos permite hacer estudios históricos de la cobertura terrestre (Vanjare, et al., 2014).



II.5.4. MODIS

MODIS (Moderate Resolution Imaging Spectroradiometer) es un instrumento clave a bordo de los satélites TERRA y de AQUA. Sus productos permiten estudiar las dinámicas y procesos globales que ocurren en la tierra, los océanos y la atmósfera inferior con un alta RT. MD ha permitido el desarrollo de modelos de sistemas terrestres globales e interactivos validados, que se encuentran disponibles para la consulta de los responsables de la formulación de políticas y así permitir la toma de decisiones acertadas en relación con la administración del territorio, los recursos naturales y su protección. Este satélite fue lanzado a órbita en el año de 1999 (Vermote et Al., 2011).

II.5.5. SENTINEL 1

S1 es la primera de las 5 misiones que la agencia espacial europea (ESA) está desarrollando para satisfacer las necesidades operacionales en el programa Copérnico. Fue lanzado en abril del 2014 con instrumento abordo C-SAR que trabaja en la banda C de las microondas (¹ESA, 2013). S1 busca beneficiar: el monitoreo del hielo marino y su mapeo, la vigilancia del medio marino, la vigilancia del derrame de petróleo, la detección de buques para seguridad marítima, el monitoreo de la superficie terrestre para mapeo durante el manejo de bosques, aguas y suelo y la cartografía para apoyar la ayuda humanitaria y las situaciones de crisis (Malenovský et al., 2012).

II.5.6. SENTINEL 2

La misión S2, también parte del programa Copérnico comprende dos satélites que orbitan en la misma órbita polar, escalonados 180° entre sí. El sensor remoto a bordo es el instrumento Multi-espectral (MSI) que permite el monitoreo terrestre en zonas del espectro visible e infrarrojo generando datos de entrada tanto para cartografía de la cubierta terrestre y la evaluación de parámetros biogeofísicos como: el índice de área foliar, el contenido de la clorofila de la hoja y la cubierta de la hoja (²ESA, 2013). S2 fue lanzado en junio del 2015 para proporcionar una continuidad mejorada de imágenes multiespectrales proporcionadas por la serie de satélites SPOT "Satellite Pour l'Observation de la Terre" (Drush et al., 2012).

II.5.7. RESOLUCIÓN TEMPORAL

Este concepto alude a la frecuencia de cobertura que proporciona el sensor, es decir, la periodicidad con la que el sensor adquiere imágenes de la misma porción de la superficie terrestre (Chuvienco, 1991). Además, se refiere a la circulación de datos y si esta es suficientemente frecuente para cubrir la necesidad por la que fue programado (Eastman, 2003). Por ejemplo, los satélites meteorológicos están obligados a tener una alta frecuencia temporal pues observan un fenómeno de gran dinamismo.

La transición de una corteza terrestre a otra y su tasa de cambio es variable en el tiempo y el espacio, sin embargo, el cambio puede ser capturado realizando repetidas observaciones del sitio en estudio. Existen regiones que permanecen relativamente estables en el tiempo, otras están sujetas a una transformación rápida y persistente. Ejemplo de las primeras son áreas de vegetación permanente y una zona urbana en expansión es ejemplo de las segundas (Gómez et al., 2016). Por otro lado, el aumento de la población humana y el desarrollo tecnológico ha sido asociado a la aceleración en el



cambio de la cubierta terrestre (Goldewijk, 2001; Liu, M., & Tian, H., 2010; Loperfido J. V. et al., 2014; Webster et al., 2014). Por eso es lógico pensar que una cuenca con una alta densidad poblacional cuente con un cambio de cobertura dinámico que afectará el comportamiento hidrológico (Yan et al., 2013).

Disponer de observaciones satelitales sistemáticas en diversos años nos permite realizar clasificaciones de cultivos, pastizales, hierbas, especies arbóreas y afloramientos rocosos con un acuerdo superior al obtenido por un solo muestreo (Peña & Brenning, 2015; Senf et al., 2015; Müller et al., 2014; Giannetti et al., 2018) y también permite evaluar el cambio o la estabilidad en la cobertura terrestre a través del tiempo (Yu, X. et al., 2012; Lehmann et al., 2013; Rußwurm & Körner, 2017).

Debido a que el CE depende de las coberturas terrestres, de acuerdo con la Tabla 2, es necesario que se analice la composición de cobertura terrestre de cada cuenca para poder determinar el CE. En cada cuenca existen distintas clases de cobertura como son: cuerpos de agua, asentamientos humanos, diversos tipos de vegetación, suelo desnudo y zonas de agricultura. La bibliografía muestra que los estudios hidrológicos se realizan en escalas tiempo variables, incluyendo desde determinaciones diarias hasta estudios que se prolongan por décadas (Chatziantoniou et al., 2017; Abdikan et al., 2016; Lei et al., 2016; Mahmoud, et al., 2014; Gómez et al., 2016; Chen et al., 2015; Webster et al., 2014; Jia et al., 2014; Ardila & Quintero, 2013; Lanza & Gomez, 2005; Berlanga–Robles et al., 2011; Yu, et al., 2012; Tchuente et al., 2011; Nutchant et al., 2011; Baldrige et al., 2009; Symeonakis et al., 2007; Frey y Smith, 2007; Bhaduri et al., 2000).

II.5.8. RESOLUCIÓN ESPACIAL

Este concepto designa la capacidad del sensor de distinguir en la superficie terrestre el objeto de menor tamaño posible. La resolución espacial se define en términos de dimensión lineal. Si el objeto que identifica el sensor disminuye en tamaño entonces su resolución espacial irá en aumento (Joseph, G. 2005). La resolución espacial tiene un papel protagonista en la interpretación de la imagen, pues solo los elementos que son superiores al tamaño del pixel serán discriminarles sobre la imagen (Chuvieco, 1991), cuando el pixel percibe una menor área de la superficie, más detalle cabe en una escena.

La determinación de la cobertura terrestre a nivel mundial ha sido realizada con una baja resolución espacial (Frey y Smith, 2007; Fritz et al, 2010), logrando escalas desde 1:250,000 a 1:5,000 en sensores ópticos y en escalas de 1:300,000 a 1:10,000 para los sensores de tecnología radar (Gomarazca, 2010). La RE gruesa generalmente deriva en acuerdo local reducido, especialmente en las regiones con cobertura de la tierra heterogénea (Herold et al., 2008; Tran, et al. 2014) sin embargo, se han introducido una serie de mejoras en el tratamiento de los datos logrado acuerdos de hasta un 75% correcto para el sensor MD de RE de 500 m (Friedl et al, 2010) y hasta un 69% en zonas de alta heterogeneidad (Tchuente et al, 2011). Es por ello que, en zonas de alta heterogeneidad debe optarse por el uso de datos con alta RE o la combinación de estos (Lei et al, 2016). Por ejemplo, se ha logrado obtener precisiones del 80% global con el uso de RE de 30 m (Chen et Al, 2015) y precisiones generales



de hasta el 94.8% en correcciones post clasificación al realizar una combinación de datos S1 y S2 (Abdikan et al, 2016; Chatziantoniou et al, 2017).

Otro factor importante involucrado con la RE es la precisión de la posición del centro del pixel ya que a medida que los sensores aumentan en la RE, la precisión posicional se hace más importante. Por ejemplo, si una imagen con tamaño de pixel de 10-30m está registrada en el suelo a una distancia de 5-15, simplemente no habría ninguna garantía de que el mapa y los datos de referencia se recolectaran de la misma área (Congalton, 2009) por lo tanto es importante revisar la calibración de cada uno de los satélites. Las escalas que proporcionan información útil para los estudios a nivel cuenca se encuentran entre 1:250,000 y 1:100,000 con resoluciones espacial entre 30 y 50 m y temporal entre 7 y 1 días (Chuvienco, 1991).

II.5.9. RESOLUCIÓN RADIOMÉTRICA

Hace mención a la sensibilidad del sensor, esto es, a su capacidad para detectar variaciones en la radiancia espectral que recibe. El número de valores que incluye la imagen suele identificarse con la resolución radiométrica del sensor. Este rango de codificación varía con los distintos sensores. Cuanto mayor sea la precisión radiométrica, tanto mejor podrá interpretarse la imagen (Khorram et al, 2015). El número de niveles más adecuados depende del método que se siga para la interpretación, así, el ojo humano solo percibirá 64 niveles de grises 200,000 tonalidades, pero en el análisis digital algunos autores han demostrado que el aumento de 64 a 256 niveles no implica una mejoría significativa en la clasificación de la cobertura terrestre (Chuvienco, 1991).

II.5.10. RANGO ESPECTRAL

El RS está determinada por el número y anchura de las bandas espectrales que puede discriminar el sensor. Un número de bandas alto permite distinguir en las diferentes ondas del espectro electromagnético, si además estas bandas son suficientemente estrechas es posible recoger la señal sobre regiones coherentes del espectro. Bandas muy amplias suponen registrar un valor promedio, que puede encubrir la diferenciación espectral entre las cubiertas de interés (Chuvienco, 1991). En este sentido, un sensor será más idóneo cuanto mayor número de bandas proporcione y lo estrecho que estas sean.

Entre los sensores espaciales, la menor RS corresponde al radar y los sistemas fotográficos. El primero trabaja normalmente en un solo canal, mientras la fotografía puede ofrecer películas pancromáticas, infrarrojo b/n, color natural o infrarrojo a color. Por el contrario, los sensores óptico-electrónicos ofrecen un amplio rango de bandas (Chuvienco, 1991), sin embargo, es necesario realizar un análisis de la información que nos proporciona cada banda a cada una de las coberturas terrestres.

En los sensores RADAR, como es S1, el rango espectral es sustituido por polarización, esta se refiere a la transmisión y recepción de onda, esta puede ser horizontal o vertical y cada combinación puede considerarse como una banda. Las combinaciones posibles se describen a continuación en la Tabla 4:

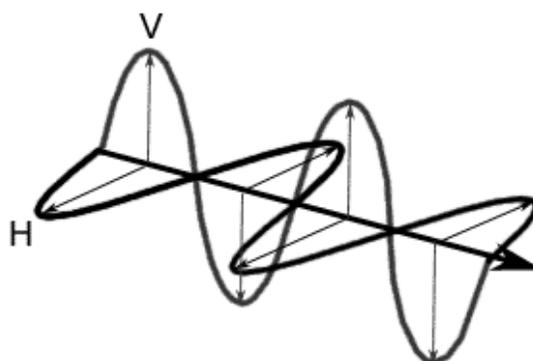


Tabla 4. Claves de polarización.

Tipo	Clave	Transmisión	Recepción
Similar	HH	Horizontal	Horizontal
Similar	VV	Vertical	Vertical
Cruzada	HV	Horizontal	Vertical
Cruzada	VH	Vertical	Horizontal

Fuente: Abdikan et al, 2016

Cuando un sensor permite obtener información en más de una combinación se conoce como Polarización Dual como se muestra en la Figura 5. El instrumento SAR de S1 cuenta con las polarizaciones: VV+VH,HH+HV,HH,VV. Se ha encontrado que la combinación [VV,VH, (VV-VH)] presenta un mayor acuerdo global en la clasificación de la cobertura terrestre (Abdikan et al, 2016).



Fuente: Abdikan et al, 2016

Figura 5. Polarización de onda en un sistema RADAR.

II.5.11. SENSIBILIDAD AL CLIMA

En áreas con nubosidad persistente, las observaciones disponibles podrían ser inadecuadas para el estudio debido a la presencia de nubes, sombras o neblina que se interpone en la medición. La repetición de la observación en la misma locación incrementa la probabilidad de encontrar datos libres de nubes incluso en áreas con nubosidad persistente (Gómez et al., 2016; Song et al., 2016). Por lo que el contexto espacio temporal de los datos proporcionados por cada sensor, las nubes y sombras proyectadas, así como la neblina, son una característica sumamente importante en las áreas con climas que presenten precipitación todo el año.

Algunas soluciones son: la aplicación de métodos que incorporen datos de series de tiempo (Jia et al., 2014) o el uso de tecnología que no sea afectada por estas inclemencias climatológicas como radar. Este último es un sensor que trabaja con una fuente energía activa por lo que puede usarse en cualquier condición luminosa y es insensible a la nubosidad pues trabaja en la ventana de las microondas (Gomarazca, 2010). S1 es un sensor de este tipo. Se trata de un radar de apertura sintética europeo (SAR, por sus siglas en inglés) que tiene la ventaja de operar en longitudes de onda no impedidas por la cobertura de nubes o una falta de iluminación y puede adquirir datos sobre un sitio durante el día o la noche bajo todas las condiciones climáticas.



II.5.12. METODOS DE PROCESAMIENTO DE IMÁGENES DIGITALES PARA LA DETERMINACIÓN DE LA COBERTURA TERRESTRE

Una imagen digital, está definida con una función de coordenadas planas y un valor de amplitud que define la escala de grises de forma finita y discreta (Ravi Shankar, 2017). Es una matriz de áreas con pequeñas celdas llamadas pixeles que representan una porción de la superficie terrestre. Las radiancias son percibidas por los sensores y transformadas a números digitales para optimizar su almacenamiento. Cada pixel representa las propiedades radiométricas del área muestreada dentro de el mismo. Para poder obtener el valor del pixel en el área se deben ejecutar un conjunto de algoritmos matemáticos, esto se conoce como el procesamiento digital de imagen.

De manera general el procesamiento digital comprende 4 áreas principales: (1) La restauración de imágenes o preprocesamiento que permite reducir el error producido por fuentes conocidas, (2) la mejora de la imagen que busca facilitar la interpretación visual, (3) la clasificación que consta de reglas de decisión cuantitativa para identificar objetos o patrones y (4) la evaluación del acuerdo que se realiza con el fin de aportar fiabilidad y repetibilidad de la clasificación (Ravi-Shankar, 2017; Richards & Jia, 2006). A esto pueden agregarse métodos de post-clasificación que buscan mejorar el resultado del proceso.

El preprocesamiento de imágenes producto de tecnología ópticas incluye la corrección geométrica, optométrica, radiométrica y atmosférica (Song et al, 2001); mientras que el preprocesamiento de imágenes provenientes de tecnología radar comprende la eliminación del ruido, la calibración, el multibarrido y la corrección del terreno (Richards & Jia, 2006; Richards, 2014; Veci, 2016). El mejoramiento de la imagen incluye procesos como el aumento del contraste, la ecualización del histograma, el filtrado digital, la fusión (con métodos como pansharpening) y el despliegue del falso color o color real en el RGB entre otros (Eastman, 2003).

La cobertura terrestre de la zona de estudio es determinada a partir de los datos de la imagen muestreada a través del proceso de clasificación de imagen digital. En dicho proceso se asigna una clase a cada pixel en base a los valores que tiene en las diferentes zonas del espectro. Cada uno es tratado de manera individual, pero contemplando todos los valores asignados al pixel por cada una de las bandas espectrales. De esta forma, es posible agrupar los pixeles con valores similares en clases asociadas a la información de categorización conocida y crear áreas que permiten entrenar al algoritmo de clasificación. Idealmente, los pixeles de cada clase tienen valores homogéneos, pero en la práctica cada clase tiene una variación en los valores de reflectancia de cada uno (Campbell & Wynne, 2011). Existen diversos algoritmos de clasificación (Tablas 5), sin embargo, el estudio se limita a los siguientes algoritmos de clasificación supervisada:



- a) **DISTANCIA MÍNIMA (DM):** Este algoritmo es probablemente el más simple y antiguo de los clasificadores utilizados en la PR (Wacker & Landgrebe, 1972). Perteneció a los conocidos como procesos de punto pues considera los valores propios del píxel para calcular la distancia Euclídea $d(x, y)$ entre las firmas espectrales de los píxeles de la imagen y las firmas espectrales de los píxeles de áreas conocidas (Congedo, 2016). La distancia es calculada para cada píxel en la imagen, asignando la clase de firma espectral más cercana de acuerdo con la expresión descrita en la Tabla 5 (Richards and Jia, 2006).
- b) **MÁXIMA VEROSIMILITUD (MV):** El enfoque consiste en calcular las distribuciones de probabilidad para las clases de acuerdo con el teorema de Bayes citado en la Tabla 5. Las probabilidades de distribución de las clases son asumidas en la forma de modelos normales multivariados (Richards & Jia, 2006). Para utilizarlo, es necesario un alto número de píxeles para cada área de entrenamiento que posibiliten el cálculo de la matriz de covarianza. MV es uno de los algoritmos de clasificación supervisada más comunes (Sudhakar et al., 1999; Bruzzone & Prieto, 2001; Jia et al., 2014; Xu et al., 2013) sin embargo, el proceso de clasificación puede ser más lento que el de otros clasificadores (Richards & Jia, 2006).
- c) **MAPEO DEL ANGULO ESPECTRAL (MAE):** El algoritmo de MAE calcula el ángulo espectral entre las firmas espectrales de los píxeles de la imagen y las firmas espectrales de entrenamiento. El ángulo espectral θ es definido según la ecuación de la Tabla 5 (Kruse et al., 1993).
- d) **MÁQUINAS DE SOPORTE VECTORIAL (MSV):** La categorización con MSV ha sido exitosamente aplicadas en la PR (Mountrakis et al., 2011). Su principio es definir un hiperplano óptimo para maximizar el ancho del margen mediante el uso de un subconjunto de entrenamiento hasta definir una superficie de separación entre dos clases mediante la definición de vectores de soporte, la expresión matemática de cálculo y el algoritmo de decisión se muestra en la Tabla 5 (Manning et al, 2008). Una limitante de este método es la carga computacional que requiere el cálculo de los algoritmos de expresión y decisión (Theodoridis & Koutroumbas, 2008).



Tabla 5. Expresión matemática de algoritmos de clasificación evaluados en el estudio.

EXPRESIÓN MATEMÁTICA DE ALGORITMOS DE CLASIFICACIÓN	
DISTANCIA MÍNIMA	MÁXIMA PROBABILIDAD
Expresión: $d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$	Expresión: $gk(x) = \ln p(Ck) - \ln \Sigma k (x - yk)^t \Sigma k (x - yk)$
Decisión: $x \in Ck \iff d(x, yk) < d(x, yj) \forall k \neq j$ $d(x, yk) < Ti$	Decisión: $x \in Ck \iff gk(x) > gj(x) \forall k \neq j$ $x \in Ck \iff gk(x) > gj(x) \forall k \neq j \text{ y } gk(x) > Ti$
Donde: x = vector de firma espectral de un pixel de la imagen y = vector de firma espectral del área de entrenamiento n = número de bandas de la imagen Ck = clase de cobertura k yk = firma espectral de la clase k yj = firma espectral de la clase j	Donde: Ck = clase de cobertura k x = vector de firma espectral de un pixel de la imagen p(Ck) = probabilidad de que la clase correcta sea Ck \Sigma k = determinante de la matriz de covarianzas de los datos en la clase Ck; \Sigma-1 k= inversa de la matriz de covarianzas yk = vector de firma espectral de la clase k
MAPEO DEL ANGULO ESPECTRAL	MÁQUINAS DE SOPORTE VECTORIAL
Expresión: $\theta(x, y) = \cos^{-1} \left(\frac{\sum_{i=1}^n x_i y_i}{\sqrt{(\sum_{i=1}^n x_i^2) (\sum_{i=1}^n y_i^2)}} \right)$	Expresión: $g(\vec{x}) = w^T \vec{x} + w_0$
Decisión: $x \in Ck \iff gk(x) > gj(x) \forall k \neq j$ $x \in Ck \iff gk(x) > gj(x) \forall k \neq j \text{ y } gk(x) > Ti$ $Ti: x \in Ck \iff \theta(x, yk) < \theta(x, yj) \forall k \neq j \text{ y } \theta(x, yk) < Ti$	Decisión: $y_1 [w^T x + w_0] \geq 1 - \xi_i$
Donde: x = vector de firma espectral de un pixel de la imagen; y = vector de firma espectral del área de entrenamiento; n = número de bandas de la imagen	Donde: \vec{x}: vector de firma espectral de un pixel de la imagen; w^T: vector normal M-dimensional del hiperplano yb \xi_i: variables estacionaria

Fuente: Elaboración propia con información de Congedo (2016), Richards & Jia (2006), Kruse et al. (1993), Manning et al (2008) y Theodoridis & Koutroumbas (2008).

La evaluación del acuerdo compara una serie de “áreas de verificación” que tienen cobertura terrestre conocida con las resultantes de la clasificación en el mismo sitio. Este proceso es comúnmente expresado en forma de una matriz de confusión (Congalton & Green, 2009; Eastman, 2003). La matriz es una tabulación cruzada que se puede construir colocando por un lado los datos de verificación que se saben cómo verdaderos y por el otro lado los resultados obtenidos de la clasificación de los datos del sensor remoto, el resultado es un esquema como el mostrado en la Tabla 6, un ejemplo de 6 clases de cobertura terrestre (Khorram et al, 2012).

La matriz de error organiza los datos de muestra adquiridos de una manera que resume los resultados clave y ayuda a la cuantificación del acuerdo y error. La diagonal principal de la matriz de error resalta las clasificaciones correctas mientras que los elementos fuera de diagonal muestran errores de omisión y comisión (Olofsson et al, 2014). La proporción de clasificaciones correctas es



conocida como acuerdo global. Se produce un error de comisión cuando se incluye un área en una categoría incorrecta. Se produce un error de omisión cuando un área se excluye de la categoría a la que pertenece. Cada error en el mapa es una omisión de la categoría correcta y una comisión a una categoría incorrecta (Congalton, 2008). Esta matriz ha sido utilizada como la base matemática para el cálculo de los índice Kappa (Cohen, 1960).

Tabla 6. Ejemplo de Matriz de confusión de la validación de una clasificación.

	Datos de Referencia							
	Clase 1	Clase 2	Clase 3	Clase 4	Clase 5	Clase 6	Omisión	
Resultado de la clasificación	Clase 1	37	7	5	3	9	0	24
	Clase 2	0	29	1	1	0	1	3
	Clase 3	2	3	31	1	3	0	9
	Clase 4	8	1	5	42	5	2	7
	Clase 5	1	4	3	2	33	1	11
	Clase 6	2	6	5	1	0	46	14
	Comisión	13	21	19	8	17	4	218

Fuente: Elaboración Propia en base a la descripción de Khorram et al, 2015

Sin embargo, en la actualidad se realiza un análisis de intensidad del muestreo pues no tiene sentido calcular estadísticas de resumen dentro de una columna al sumar los puntajes de diferentes filas porque la intensidad del muestreo puede ser diferente en cada fila al tratarse de un muestreo aleatorio dentro del estrato. Por ello, es necesario calcular una matriz imparcial de población a partir de la matriz de confusión que no solo incluya los resultados del muestreo, sino que represente toda el área de estudio y así poder calcular estadísticas sumarias sin sesgo (Pontius & Millones, 2011). La matriz imparcial de población es construida al multiplicar el número de muestras con el número total de celdas que representan la categoría muestreada (Pontius & Santacruz, 2014). Esta matriz permite realizar diferentes cálculos eliminando el sesgo de muestreo entre los que destacan: el acuerdo global, el acuerdo por tipo de cobertura, el error de omisión global y por tipo de cobertura, el error de comisión global y por tipo de cobertura, el dominio de cada clase en la imagen clasificada, el desacuerdo cuantitativo y el desacuerdo de asignación. Esta metodología ha sido aplicada en diversos estudios de clasificación de la cobertura terrestre (Pontius et al., 2013; Zhou et al., 2014; Estoque et al., 2018; Huang et al., 2018).

Las técnicas de post clasificación buscan mejorar el acuerdo. En la imagen clasificada, suelen existir manchas de color o píxeles asignados a otras clases en áreas donde se conoce la cobertura terrestre verdadera, estos efectos se denominan coloquialmente como sal y pimienta o manchas (Chuvieco, 1991). Para la eliminación de estos errores en la clasificación pueden aplicarse diversas técnicas entre las que se encuentran filtrados, suavizados, clasificaciones cruzadas, reclasificaciones o ediciones manuales del raster de salida y restauración de áreas con nubosidad (Congedo, 2016; Joseph, 2005; Chuvieco, 1991). Una forma posible de mejorar el resultado consiste en asignar regiones entrenamiento con mayor número de píxeles y mayor homogeneidad espectral (Richards & Jia, 2006). La selección de las áreas suele estar relacionada con el conocimiento de la misma y otros procesos que no dependen directamente de las características de a imagen que se analizan, por lo que en el presente estudio de han omitido estas técnicas ya que se busca evaluar a la imagen.



III. OBJETIVO Y PREGUNTA DE INVESTIGACIÓN

La presente investigación atendió el objetivo general de:

Evaluar las características necesarias en las imágenes satelitales de acceso abierto para su uso en la determinación de coeficientes de escurrimiento.

Dicho objetivo general corresponde a la pregunta de investigación general:

¿Qué características debe tener una imagen satelital de acceso abierto para la determinación de los coeficientes de escurrimiento considerando las diferentes características de la cuenca hidrológicas de estudio?



IV. METODOLOGÍA

El presente estudio comprendió 3 etapas principales: La evaluación de la precisión para en la determinación de la cobertura terrestre, la estructuración de recomendaciones que permite la selección de la imagen idónea para la determinación de CE y la determinación del CE.

IV.1. ÁREA DE ESTUDIO

El estudio incluye la subregión hidrológica BG, subregión hidrológica aguas del VM y la subregión hidrológica BB que presentan las características hidrológicas contrastantes del noreste, centro y sureste de la república mexicana. Las imágenes fueron obtenidas a través de las paginas <https://earthexplorer.usgs.gov/> y <https://scihub.copernicus.eu/>. Se utilizó una imagen de cada uno de los sensores: MD, L8, S1 y S2 para cada una de las subregiones de estudio. La Tabla 7 muestra la clave de cada una de las imágenes, así como la subregión que cubren, el sensor de procedencia y la fecha de adquisición. Las imágenes pertenecen a los meses de septiembre y octubre del año 2016, fechas en que se presenta el término de la época de lluvia de las tres subregiones de estudio. Las fechas fueron escogidas con el fin de incluir la cobertura terrestre que represente el máximo escurrimiento, además el periodo de separación entre ellas es menor a 40 días siendo el más corto posible de acuerdo con su disponibilidad.

El producto MD utilizado es el MOD09GA que muestra una estimación de la reflectancia espectral de la superficie que se mediría a nivel del suelo en ausencia de dispersión o absorción atmosférica. Los datos se adquieren diariamente con una resolución espacial de 500 m y están corregidos para los gases-aerosoles atmosféricos. Este producto proporciona 7 bandas en proyección Sinusoidal. Por otro lado, el producto L1TP fue tomado con los sensores OLI y TIRS a bordo del satélite L8, que tiene tiempo de revisita de 16 días y cubre un área de 30 m por pixel. El producto incluye 9 bandas en el espectro visible e infrarrojo que se encuentran radiométricamente calibradas y optométricamente rectificadas.

El producto de S1 utilizado fue adquirido en una órbita ascendente en el modo de banda ancha interferométrica por un sensor en la banda C (5.4GHz) de las microondas con polarización dual VV-VH. Es un producto de Nivel 1 en detección de rango a nivel tierra y tienen una resolución espacial alta de 10 m. La ESA pone a disposición el producto S2 nivel 2A, se trata de imágenes ortográficas de 100x100 km² en proyección UTM / WGS84 que presentan las reflectancias de la superficie terrestre por debajo de la atmosfera.



Tabla 7. Imágenes utilizadas en el estudio.

SUB-REGIÓN	SENSOR	FECHA	IMAGEN
BAJO BRAVO	LS8	08 SEPTIEMBRE	LC08_L1TP_027042_20160908_20170222_01_T1
	MD	4 OCTUBRE	MOD09GA.A2016278.H09V06.006.2016280065847
	S1	25 SEPTIEMBRE	S1A_IW_GRDH_1SDV_20160925T004143_20160925T004208_013202_01500A_8E60 S1B_IW_GRDH_1SDV_20160926T003306_20160926T003335_002233_003C11_A052
	S2	09 SEPTIEMBRE	S2A_OPER_MSI_L1C_TL_SGS_20160909T221922_A006358_T14RNP S2A_OPER_MSI_L1C_TL_SGS_20160909T221922_A006358_T14RMP
BAJO GRIJALVA	LS8	24 SEPTIEMBRE	LC80220472016249LGN00
	MD	7 SEPTIEMBRE	MOD09GA.A2016251.H09V07.006.2016253070124
	S1	27 SEPTIEMBRE	S1A_IW_GRDH_1SDV_20160927T002314_20160927T002340_013231_0150FO_905A
	S2	21 AGOSTO	S2A_OPER_MSI_L1C_TL_SGS_20160821T214512_A006086_T15QVA S2A_OPER_MSI_L1C_TL_SGS_20160821T214512_A006086_T15QWA
VALLE DE MÉXICO	L8	17 SEPTIEMBRE	LC80260472016261LGN00
	MD	13 SEPTIEMBRE	MOD09GA.A2016258.H08V07.005.2016260055311_01
	S1	25 SEPTIEMBRE	S1A_IW_GRDH_1SDV_20160930T004826_20160930T004851_013275_015252_C5B5
	S2	09 SEPTIEMBRE	S2A_OPER_PRD_MSIL1C_PDMC_20160912T231518_R069_V20160909_T170302_20160909T17110

Se dibujó un polígono de estudio para cada una de las cuencas y se guardó en formato vectorial en cada una de las proyecciones de las diferentes imágenes. El polígono incluyó el área de mayor magnitud posible que presenta coincidencia espacial entre imágenes y una baja nubosidad para el periodo de adquisición en cada una de las áreas de estudio. La Tabla 8 muestra el área geométrica de estudio y coordenadas UTM máximas y mínimas en el datum de referencia de WGS84 para cada una de las regiones de estudio. Las imágenes se cortaron al tamaño del polígono de estudio.

Tabla 8. Áreas seleccionadas para el estudio.

SUBREGIÓN	COORDENADAS		ÁREA [Km ²]
	MÍNIMAS	MÁXIMAS	
Bajo Bravo	99.0217 N, 25.4894 O	97.9482 N, 26.219 O	5, 915.04
Bajo Grijalva	93.2607 N, 18.2439 O	92.7732 N, 18.4422 O	688.64
Valle de México	99.3396 N, 19.3129 O	98.9069 N, 19.7256 O	1, 676.15

IV.2. MODELADO GEOESPACIAL CONCEPTUAL

Se realizó un análisis geoespacial conceptual que involucra los procesos del ciclo del agua, las interacciones que la actividad humana tiene con el mismo y sus relaciones con el CE, siguiendo la metodología de Tapia-Silva (2015).



IV.3. COMPARACIÓN GENERAL DE LOS SENSORES

Se realizó una búsqueda bibliográfica de las características generales de los cuatro sensores analizados en él estudio que incluyen: resolución espacial, resolución espectral, resolución temporal, y resolución radiométrica. Esta información fue analizada para efecto de establecer las diferencias primordiales de cada sensor y su aplicabilidad a las subregiones de estudio.

IV.4. ANÁLISIS DE BANDAS ESPECTRALES

Para realizar el análisis de las bandas que son necesarias en la determinación de la cobertura terrestre se realizó un análisis auxiliado de la construcción de una gráfica con los rangos del espectro electromagnético a la que cada sensor es sensible, utilizando la información oficial proporcionada por el USGCRP (Vermote et. al, 2011; USGS, 2016), y el programa Copérnico de la ESA (¹ESA, 2013; ²ESA, 2013). Las resoluciones espaciales incluidas son: 30 m para L8, 500 m para MD, 10 m para S1 y las firmas espectrales que se han determinado para: agua de llave, concreto, arena gruesa café-gris y vegetación caducifolia por la librería espectral ASTER (Baldrige et al. 2009). El sensor S1 fue exentado de este análisis ya que se utilizaron las polarizaciones HV, VV y su resta (VV-VH) según lo propuesto por Abdikan et al. (2016)

IV.5. PROCESAMIENTO Y EVALUACIÓN DEL ACUERDO EN LA DETERMINACIÓN DE LA COBERTURA TERRESTRE

Debido a que todas las imágenes se encuentran con corrección geométrica y optométrica desde su descarga, el preprocesamiento se limitó a:

- (1) corrección radiométrica y atmosférica por el método DOS1 (Song et al, 2001), para los productos ópticos de L8, MD y S2 utilizado el complemento "Semi-Automatic Classification Plugin" de QGIS 2.18 (SCP-QGIS) (Congedo, 2016) y disponible de forma libre en la dirección electrónica: <https://qgis.org/es/site/forusers/download.html> (Anexo 1);
- (2) eliminación del Ruido, calibración, Multibarrido y corrección del terreno para el producto S1 en la plataforma de aplicaciones de Sentinel "SNAP Tool" (¹ESA, 2013) desarrollado por la agencia espacial europea con acceso abierto electrónicamente en: <http://step.esa.int/main/download/> (Anexo 1).

Se identificaron visualmente los tipos de cobertura terrestre que fueron clasificados en cada una de las cuencas. La investigación está basada en: (1) las características de cada una de las regiones, (2) el conjunto de datos vectoriales de uso de suelo y vegetación escala 1:250 000 "serie V" (INEGI, 2013),



(3) la Tabla 2 de la relación de uso de suelo y el factor k del CE (Solis et al., 2005) y (4) la herramienta de creación de regiones de interés (ROI) del complemento SCP-QGIS. Los tipos de cobertura terrestre identificados se desglosan en la Tabla 9 y de forma general incluyen: cuerpos de agua, asentamientos humanos, vegetación y suelo desnudo. Es importante resaltar que las áreas de suelo desnudo de la subregión del BG no fueron identificables con MD pues su tamaño es menor que el posible reconocible por este sensor por lo que no se incluyeron en la clasificación de BG con MD. Además, se añadió la clase de nubes y sombra en las imágenes con presencia de estas.

Tabla 9. Tipos de cobertura identificados por área de estudio.

Bajo Bravo	Bajo Grijalva	Valle de México
Cuerpo de agua	Cuerpo de agua	Cuerpo de agua
Asentamientos humanos	Asentamientos humanos	Asentamientos humanos
Mezquital xerófilo	Manglar	Bosque
Suelo desnudo	Suelo desnudo	Suelo desnudo
Agricultura pastizal	Agricultura pastizal	Agricultura pastizal
Matorral espinoso	Vegetación sumergida	Matorral
	Zona inundada	

Se crearon composiciones de color real y falso color para identificar área de entrenamiento utilizando la herramienta ROI de SCP-QGIS para cada una de las imágenes del estudio. Se realizó un muestreo estratificado aleatorio para seleccionar de 25 a 30 áreas de entrenamiento en cada imagen por cada tipo de cobertura y se incluyeron las clases de nube y sombra cuando se presentaban en la imagen. Estas áreas son fácilmente identificables en: a) la imagen de prueba, b) la imagen de Google Earth Satellite de la herramienta de Open Layer de QGIS, c) la imagen Bing Maps aerial de la misma herramienta y d) coinciden con la cobertura terrestre de la Serie V de INEGI. Las áreas de entrenamiento fueron guardadas como un archivo vectorial en un porcentaje variable debido a que cada región de interés busca cubrir la mayor área identificable en la imagen de cada tipo de cobertura terrestre. En general el área de entrenamiento utilizada es de alrededor de un 3% del área total de la cuenca para los sensores de alta resolución espacial y más de un 7% para el sensor de baja resolución espacial (Tabla 10).

Tabla 10. Porcentaje de área utilizada para el entrenamiento de los algoritmos.

% Área de entrenamiento			
Sensor	Bajo Bravo	Bajo Grijalva	Valle de México
MODIS	7.6	14.6	19.4
LS8	3.2	3.4	2.9
SENT-1	1.8	5.1	2.8
SENT-2	3.0	3.9	3.6
PROMEDIO	3.9	6.75	7.17

Los archivos vectoriales se utilizaron como las áreas de entrenamiento para los algoritmos de clasificación y las imágenes fueron procesadas con las bandas seleccionadas con los resultados de la



sección VI.4. Los algoritmos de DM y MEA fueron aplicados con la herramienta SCP-QGIS (Congedo, 2016), el algoritmo de MP fue procesado con el programa GRASS-GIS y el algoritmo de MSV con la caja de Herramientas de Orfeo para QGIS. Como se ha mencionado los procesos posteriores a la clasificación no han sido aplicados pues suelen estar relacionados con el conocimiento del área y otros procesos que no dependen directamente de las características de a imagen que se analizan.

En este proyecto la validación se realizó mediante la matriz imparcial de población. Esta se compuso de la comparación por un lado de los resultados individuales de clasificación de cada combinación algoritmo-sensor-cuenca y por otro de información de referencia de cobertura terrestre elaborada para cada combinación siguiendo los lineamientos establecidos por Pontius & Santacruz (2014). Se empleo una la capa vectorial de información de referencia constituida con puntos de verificación de cobertura terrestre conocida. El procedimiento empleado para crear esta capa vectorial de áreas de entrenamiento fue igualmente utilizado para la realización de la capa de información de referencia, pero dibujando áreas del tamaño de un pixel de cada imagen. Se cálculo en cada resultado individual: acuerdo global, omisión global, y comisión global, dominio o presencia del tipo de cobertura en la clasificación global y error por tipo de cobertura. La matriz imparcial de población y las ecuaciones propuestas por Pontius & Santacruz fue utilizada en estos cálculos individuales. Con el fin de sintetizar resultados y obtener un panorama general se realizaron cálculos para a las 3 subregiones como se describe a continuación:

- (1) Acuerdo global promedio por subregión hidrológica: Se calculó un promedio con los resultados de acuerdo global individual de cada combinación algoritmo-sensor aplicados a la misma cuenca.
- (2) Acuerdo global promedio por Sensor: Se calculó un promedio con los resultados de acuerdo global individual obtenidos utilizando los datos de un mismo sensor combinado con los cuatro algoritmos de clasificación en cada una de las cuencas.
- (3) Acuerdo global promedio por Algoritmo de clasificación: Se calculó un promedio con los resultados de acuerdo global individual obtenidos utilizando los datos del mismo algoritmo de clasificación aplicado a los todos datos individuales de cada sensor-cuenca.
- (4) Dominio promedio de la clase en los resultados de todas las clasificaciones en una subregión hidrológica: Evaluado como el porcentaje de tipo de cobertura terrestre presente en la determinación con a las ecuaciones propuestas por Pontius & Santacruz para su cálculo (Pontius & Santacruz, 2014).
- (5) Error de omisión promedio por clase: Calculado como el promedio de la proporción de pixeles omitidos por tipo clase en todas las clasificaciones de una cuenca determinada. El error de omisión por individual clase fue evaluado de acuerdo con Pontius & Santacruz (2014) para cada clasificación resultante.



- (6) Error de comisión promedio por clase: Calculado como el promedio de la proporción de píxeles erróneamente asignados a una determinada clase en las clasificaciones resultantes de cuenca determinada. El error de comisión individual por clase fue evaluado de acuerdo con Pontius & Santacruz (2014) para cada clasificación resultante.
- (7) Acuerdo promedio por clase: Calculado como el promedio de la proporción de píxeles correctamente asignados a una determinada clase en las clasificaciones resultantes de cuenca determinada. El acuerdo individual por clase fue evaluado de acuerdo con Pontius & Santacruz (2014) para cada clasificación resultante.

IV.6. SELECCIÓN DE LA IMAGEN

Para seleccionar las imágenes más apropiadas para cada área de análisis se contemplaron: acuerdo global, resolución espacial, resolución espectral, resolución temporal, resolución radiométrica, periodo de estudio, tipo de cobertura terrestre y su dinámica, clima, tamaño de la cuenca y periodo de estudio. Se estableció un acuerdo global mínimo del 70% para la selección de una imagen.

En esta tesis se definió determinar el CE de las dos coberturas terrestres que resultaron en mayores los acuerdos globales y una tercera que sea de interés especial, debido a la nula presencia de nubes o de incluir en el análisis un sensor extra.

IV.7. DETERMINACIÓN DEL COEFICIENTE DE ESCURRIMIENTO

Para la determinación del CE se desarrollaron los siguientes pasos:

- (1) Se aplicó un algoritmo de decisión para generar un raster de valores K a partir de la información de la Tabla 11 utilizando como valor de entrada el raster de cobertura terrestre de cada clasificación. La Tabla 11 es una adaptación de la Tabla 2 (Solís et al., 2005) para los tipos de cobertura de las áreas de estudio del proyecto.
- (2) Se corrió un algoritmo de decisión con la ecuación 1 y 2 del CE y un análisis espacial del raster de factor K generado previamente, un raster de precipitación anual media elaborado con la interpolación de los datos de CONAGUA (Cuervo-Robayo et al, 2014) y un raster de textura del suelo (INIFAP, 1995). El resultado es un nuevo raster con valores de CE.



Las tablas y algoritmos utilizados para la determinación del CE se describen en el Anexo 2.

Tabla 11. Factor K de las subregión de estudio.

Factor K = f(Suelo)					
Clase	Categoría de Mapa	Categoría obtenida de tablas de K	Suelo A	Suelo B	Suelo C
Tipo de Cobertura terrestre en la subregión Bajo Bravo					
0	No clasificado	Definición propia	0	0	0
1	Cuerpo de Agua	Definición propia	0	0	0
2	Urbano	Asentamiento humano (Tabla 3.1.14)	0.26	0.29	0.32
3	Mezquital-Xerófilo	Mezquital, incluye huizache (Tabla 3.1.14)	0.22	0.28	0.30
4	Suelo Desnudo	Área sin vegetación aparente (Tabla 3.1.14)	0.26	0.28	0.3
5	Agricultura-Pastizal	Agricultura... (Tabla 3.1.14)	0.24	0.27	0.3
6	Matorral	Matorral ...(Tabla 3.1.14)	0.22	0.28	0.3
7	Nube	Definición propia	0	0	0
8	Sombra	Definición propia	0	0	0
Tipo de Cobertura terrestre en la subregión Bajo Grijalva					
0	No clasificado	Definición propia	0	0	0
1	Cuerpo de Agua	Definición propia	0	0	0
2	Urbano	Asentamiento humano (Tabla 3.1.14)	0.26	0.29	0.32
3	Manglar	Selva Baja ... (Tabla 3.1.14)	0.17	0.26	0.28
4	Suelo Desnudo	Área sin vegetación aparente (Tabla 3.1.14)	0.26	0.28	0.3
5	Agricultura-Pastizal	Agricultura... (Tabla 3.1.14)	0.24	0.27	0.3
6	Vegetación Sumergida	Vegetación halófila y gipsófila ... (Tabla 3.1.14)	0.05	0.05	0.05
7	Zona Inundada	Definición propia	0	0	0
8	Nube	Definición propia	0	0	0
9	Sombra	Definición propia	0	0	0
Tipo de Cobertura terrestre de subregión del Valle de México					
0	No clasificado	Definición propia	0	0	0
1	Cuerpo de Agua	Definición propia	0	0	0
2	Urbano	Asentamiento humano (Tabla 3.1.14)	0.26	0.29	0.32
3	Bosque	Bosque ... (Tabla 3.1.14)	0.07	0.16	0.24
4	Suelo Desnudo	Área sin vegetación aparente (Tabla 3.1.14)	0.26	0.28	0.3
5	Agricultura-Pastizal	Agricultura... (Tabla 3.1.14)	0.24	0.27	0.3
6	Matorral	Matorral ...(Tabla 3.1.14)	0.22	0.28	0.3
7	Nube	Definición propia	0	0	0
8	Sombra	Definición propia	0	0	0

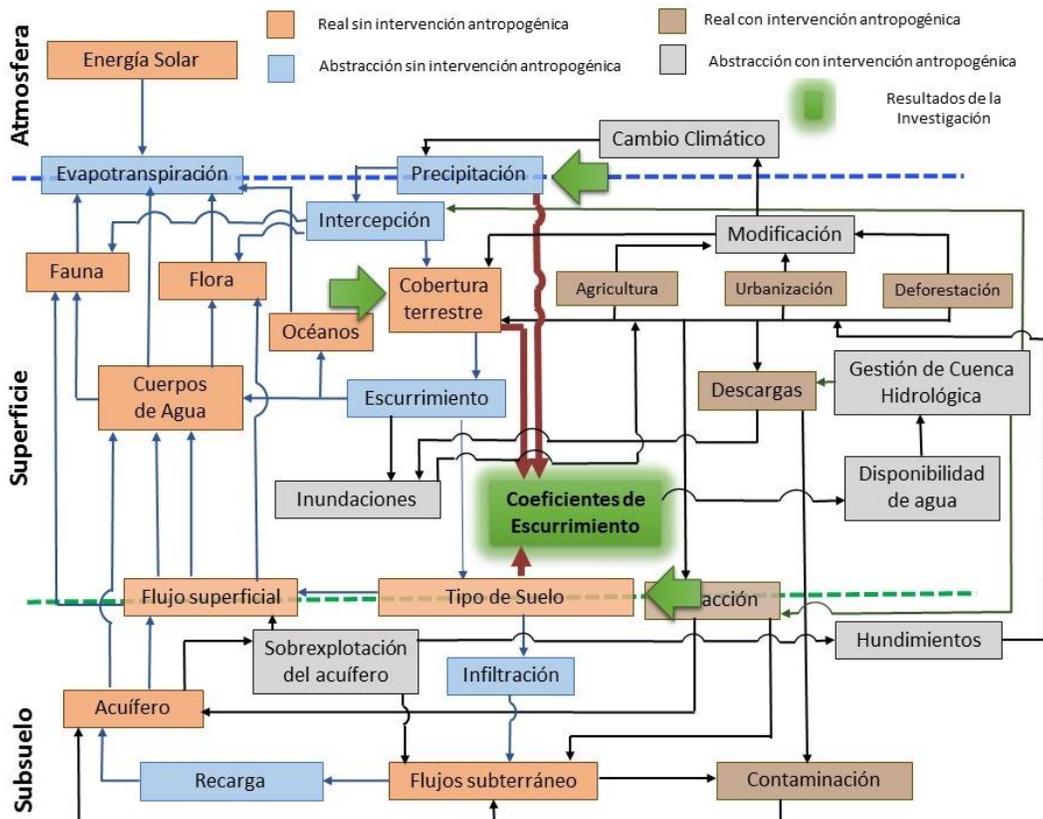
Fuente: Elaboración Propia con adaptación de los datos de Solís et al, 2005 al proyecto.



V. RESULTADOS Y DISCUSIONES

V.1. MODELADO GEOESPACIAL CONCEPTUAL

El desarrollo del proyecto se enfoca en el estudio de la cuenca hidrológica. Por ello el MGC comienza con un análisis conceptual de los procesos que el ser humano ha estudiado y abstraído a través de la observación del ciclo del agua y los objetos reales involucrados en el desarrollo del mismo en la atmósfera, la superficie y el subsuelo con apoyo en lo descrito por Breña & Jacobo (2006). La identificación holística de los componentes incluye los procesos hidrológicos: evapotranspiración, precipitación, intercepción, escurrimiento superficial y subterráneo, infiltración y recarga; así como otros componentes físicos como fauna, flora, energía solar, océanos, cobertura terrestre, cuerpos de agua, acuíferos y textura del suelo. El modelo resultante de la interacción observada entre dichos componentes se muestra en la Figura 6. Algunos componentes fueron agregados en el modelo geoespacial conceptual con la finalidad de incluir la intervención del hombre en el ciclo hidrológico. Estos factores interactúan con los previamente señalados. Los procesos abstraídos de la realidad que se realizan por acción antropogénica son: Modificación de la cobertura terrestre, impulso del cambio climático, explotación del acuífero, hundimientos e inundaciones involuntarias o voluntarias, cálculos de la disponibilidad del agua y actividades para la gestión del recurso hídrico. Otras actividades relacionadas con la interacción del hombre con el ciclo hidrológico son: descargas de aguas residuales, agricultura, urbanización, deforestación, extracción de agua, contaminación de acuíferos. Estos factores también son incluidos en el Modelo Geoespacial Conceptual del proyecto.

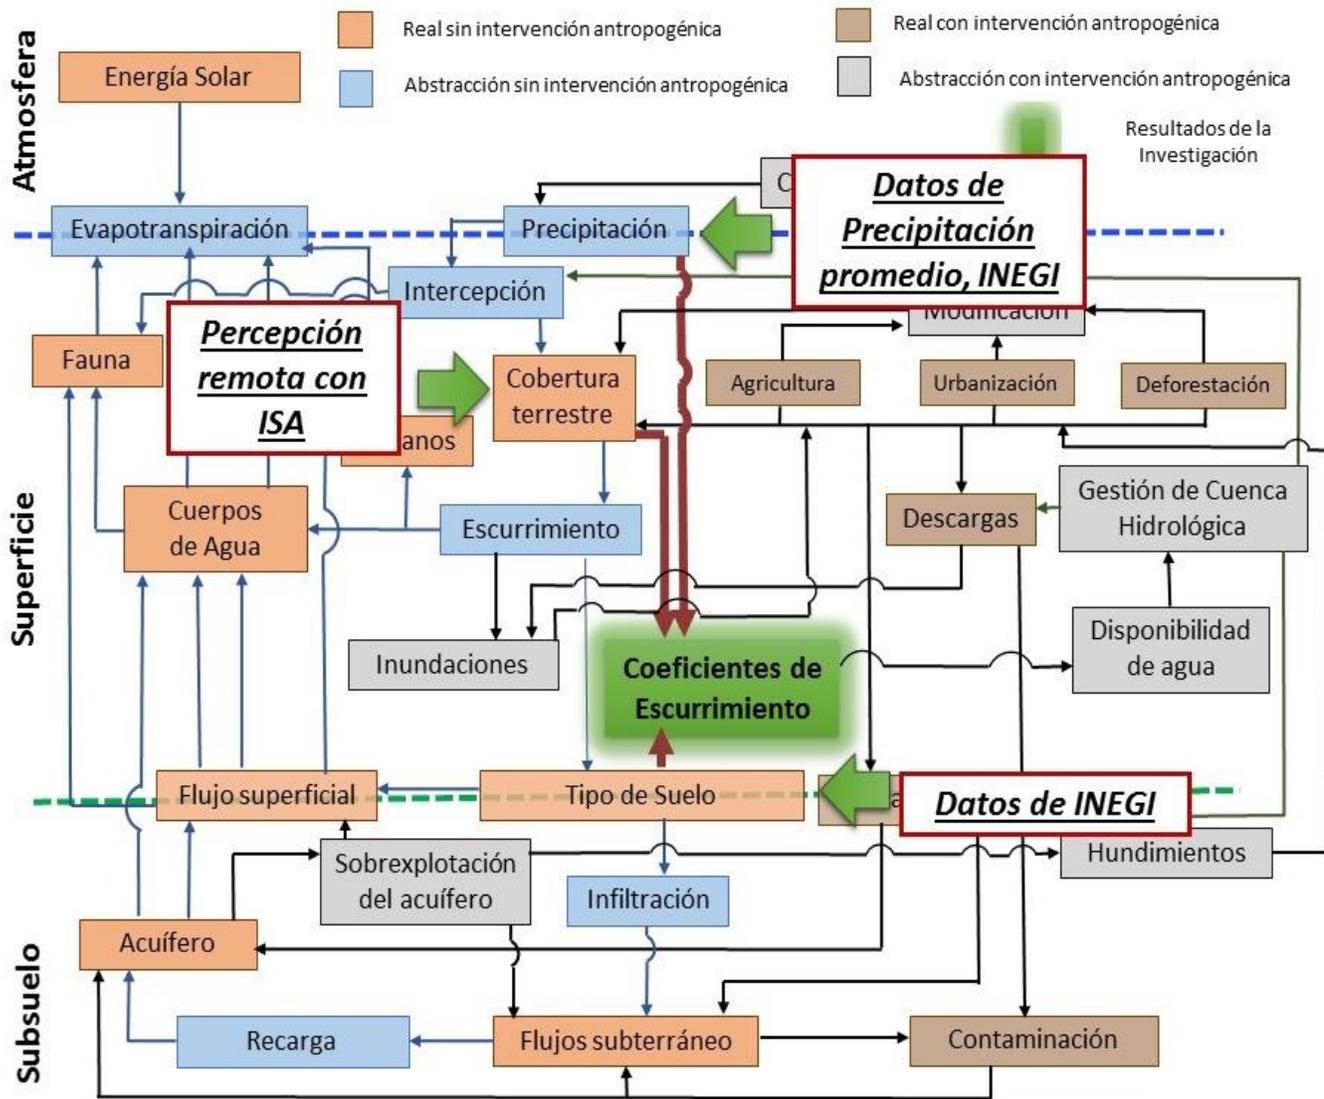


Fuente: Elaboración Propia para el proyecto siguiendo el Método de Tapia-Silva (2015).

Figura 6. Modelado Geoespacial conceptual del estudio.



El modelo permitió identificar los componentes del sistema que definen directamente el CE de la cuenca siendo estos: cobertura terrestre, precipitación y textura del suelo. Dichos componentes fueron los implementados en el SIG como capas de información geográfica. Ya que este cálculo del CE es un parámetro de entrada en el cálculo de la disponibilidad de agua, el proceso de gestión de la cuenca hidrológica se ve beneficiado por su conocimiento pues la estimación de disponibilidad del agua permite generar procesos equilibrados de gestión del recurso a nivel cuenca y así incidir positivamente en el ciclo hidrológico (Figura 7).



Fuente: Elaboración Propia para el proyecto siguiendo el Método de Tapia-Silva (2015).
Figura 7. Identificación de componentes del sistema que serán incluidos en el SIG.



V.2. COMPARACIÓN GENERAL DE LOS SENSORES

La información que los satélites MD, L8, S1 y S2 proporcionan depende mayormente de sus características propias. Por ello se ha generado una tabla como resultado de la revisión bibliográfica, en la que se pueden visualizar las diferencias principales que cada sensor incluyendo: resolución espacial, resolución espectral, resolución temporal, resolución radiométrica, número de bandas, sensibilidad al clima (Tabla 12).

La Tabla 12 muestra que la información con un menor periodo de disponibilidad es la proporcionada por S1 pues, aunque fue lanzado durante el año 2014, no generó imágenes del total del territorio nacional hasta el año 2016 al cambiar su línea base de escenarios de observación de la misión (¹ESA, 2013). Igualmente, la misión S2 del mismo programa comenzó a generar imágenes en el año 2015. Por otro lado, los datos del USGCRP se encuentran disponibles para un periodo más largo, desde el año 1999 para MD y desde 2013 para datos de la misión L8. Cabe recalcar que los datos de LS8 pueden ser complementados con los generados por los satélites de la serie LandSat que comenzaron a generarse en el año de 1972.

Aunque S1 y S2 se encuentran en desventaja debido a la disponibilidad de datos, su resolución espacial de 10 m, es superior que las presentadas por MD y L8 con 500 y 30 metros respectivamente. MD con la menor resolución espacial es la de mayor resolución temporal, generando datos diarios, seguido por S2 que tiene un tiempo de revisita de 5 días mientras L8 y S1 con resolución temporal de 16 días. Sin embargo, el último está diseñado para lograr tiempos de revisita de 5 días en un futuro cercano.

S1 presenta solo una banda espectral, pero tiene la ventaja de no ser sensible a la nubosidad. A primera vista, MD presenta un mayor número de bandas, seguido de S2 y L8, pero no todas ellas nos dan información importante sobre el tipo de cobertura terrestre por lo que la siguiente sección muestra el análisis para la selección de las bandas espectrales que se seleccionaron para la determinación de la cobertura terrestre.

Tabla 12. Comparación general de las características de los sensores del estudio.

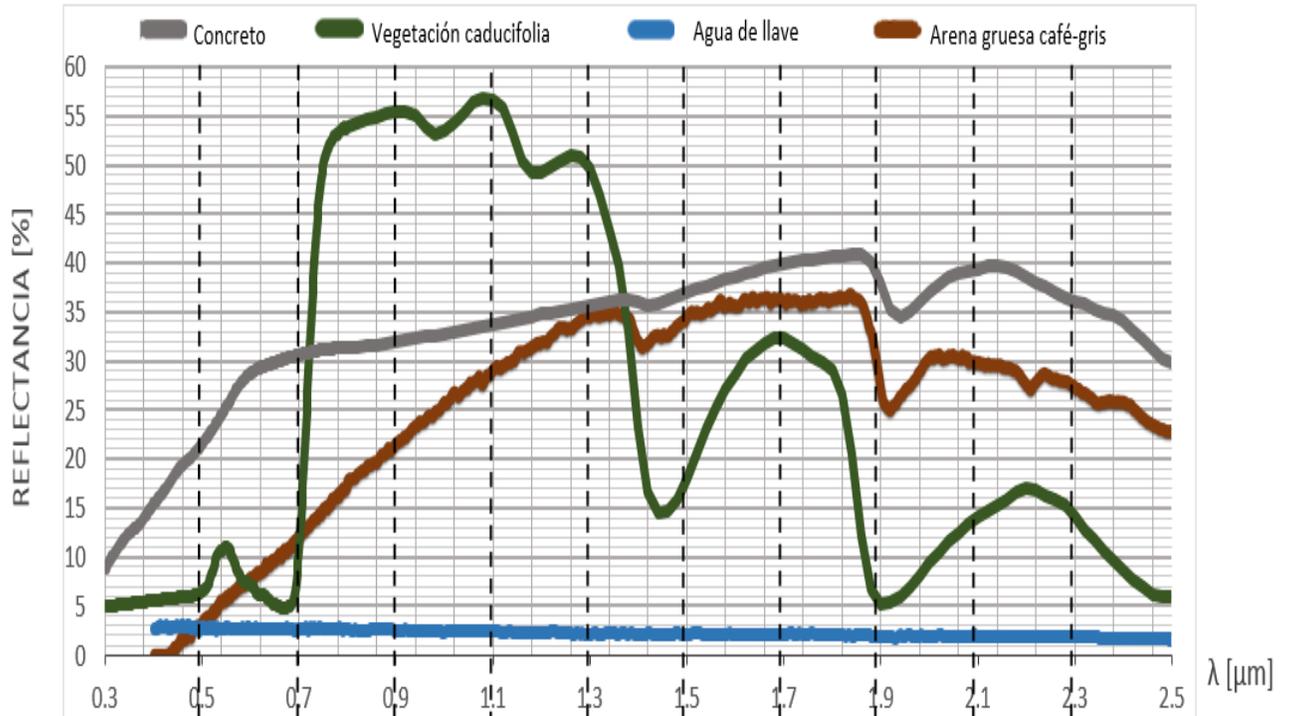
Sensor	MODIS MOD09	Landsat 8 OLI	SENTINEL 1 SAR	SENTINEL 2 MSI
Inicio del periodo de disponibilidad	1999	2013	2016	2015
Resolución temporal [días]	1	16	16	5
Resolución Radiométrica (bits)	12	12	1 dB	12
Resolución espacial [m]	500	30	10	10
No. bandas; Resolución espectral [µm]	36; 0.4-14.4	11; 0.435-12.51	Banda C Doble polarización	13; 0.449-2.19
Sensibilidad al clima	<i>Si</i>	<i>Si</i>	<i>No</i>	<i>Si</i>

Fuente: Elaboración propia para el proyecto con información de Vanjare et al. (2014), Vermote et al. (2011), Malenovsky et al. (2012), 1ESA (2013), 2ESA (2013) y Drush et al. (2012).



V.3. ANÁLISIS DE BANDAS ESPECTRALES

El gráfico comparativo creado para el análisis de bandas espectrales se muestra en la Figura 8. La sección superior de esta imagen muestra un gráfico que expresa la longitud de onda en micrómetros a lo largo del eje de las ordenadas y la reflectancia en el eje de las abscisas.



Sensor	Resolución espacial [m]	Bandas
MODIS TERRA	500	3, 4, 1, 2, 5, 6, 7
SENTINEL 2 MSI	10	1, 2, 3, 4, 5, 6, 7, 8, 11, 12
LANDSAT 8 OLI	30	1, 2, 3, 4, 5, 6, 7

Fuente: Elaboración propia para el proyecto con información de *Baldrige et al. (2009)*, *Vanjare et al. (2014)*, *Vermote et al. (2011)*, *Malenovský et al. (2012)*, ¹ESA (2013), ²ESA (2013) y *Drush et al. (2012)*.

Figura 8. Análisis Espectral de los sensores MODIS, L8, Sentinel 1 y Sentinel 2 para la determinación de la cobertura terrestre.



Para el gráfico de la Figura 8 se eligió representar el comportamiento de cuatro materiales: concreto, vegetación caducifolia, agua de llave y arena gruesa café-gris para incluir un ejemplo de los tipos de cobertura terrestre comunes en las aéreas de estudio. La línea gris corresponde a los datos del concreto y representa áreas urbanas, la línea verde muestra los datos de vegetación caducifolia como ejemplo de las áreas vegetadas, los cuerpos de agua son representados utilizando datos de agua de llave en una línea azul y la de arena gruesa café-gris en color café representa al suelo desnudo. Los datos utilizados para trazar la tendencia fueron tomados de la librería espectral ASTER (Baldrige, et.al 2009). Líneas punteadas atraviesan el gráfico hasta cruzar con una tabla de las longitudes de onda percibidas por cada sensor óptico analizado en esta tesis. Esta tabla incluye las bandas espectrales seleccionadas para el análisis de la cobertura terrestre en los sensores MD, LS, y S2. Cada una de las bandas fue seleccionada por que es sensible a una parte del espectro electromagnético en donde el valor de la reflectancia de los tipos de cobertura terrestre es distinto. Por ejemplo, las bandas: 2 de MD, 8 de S2 y 5 de L8, están ubicados en una zona del infrarrojo cercano en donde la reflectancia del agua, arena, cemento, y vegetación son muy distintos, con valores porcentuales alrededor del 3, 20 30 y 55. Los sensores ópticos MD, L8 y S2 presentan al menos una banda en las zonas de azul, verde, rojo, infrarrojo cercano, medio y lejano que como ya se expuso son áreas donde se presenta una diferencia en la firma espectral de los tipos de cobertura terrestre a analizar.

La Tabla 13 numera las bandas seleccionadas por subregión y sensor. Para el sensor L8 se seleccionaron: banda 2 sensible a color azul del espectro electromagnético, banda 3 sensible al verde, banda 4 sensible al rojo, 5 al infrarrojo cercano y bandas 6 y 7 al infrarrojo de onda corta. La banda 1 es útil para obtener imágenes de aguas poco profundas, por lo que fue incluida solo en la subregión del BG pues en esta existen cuerpos de agua someros y regiones inundadas. Fueron excluidas las bandas 8, 9, 10 y 11. El proceso de pansharpening no fue realizado por lo que se excluyó la banda 8. La banda 9 es utilizada para el análisis de nubes de tipo cirro, este análisis no fue necesario en el estudio debido a que las nubes se incluyeron como una clase. Las bandas 10 y 11 generan datos de temperatura de la superficie, estos no están siempre relacionados con el tipo de cobertura terrestre en el sitio por lo que se excluyeron del análisis.

Tabla 13. Bandas utilizadas para la clasificación de la cobertura terrestre.

Sensor	Bajo Bravo	Bajo Grijalva	Valle México
LandSat 8	2,3,4,5,6,7	1, 2,3,4,5,6,7	2,3,4,5,6,7
MODIS	1,2,3,4,5,6,7	1,2,3,4,5,6,7	1,2,3,4,5,6,7
Sentinel-1	HV, VV, VV-VH	V, VV, VV-VH	V, VV, VV-VH
Sentinel-2	2,3,4,5,6,7,8, 8 ^a ,11,12	1,2,3,4,5,6,7,8, 8 ^a ,11,12	2,3,4,5,6,7,8, 8 ^a ,11,12



El producto MOD09 de MD contiene 7 bandas que aportan información importante en la determinación de la cobertura terrestre (Tabla 13). La banda 1 corresponde al rojo visible, la banda 2 al infrarrojo de onda corta, la banda 3 a la sección azul del espectro visible, la 4 al verde. MD también cuenta con bandas del infrarrojo cercano y de onda corta siendo estas la 5, 6 y 7 respectivamente. Cada una de ellas es sensible a una región del espectro electromagnético donde el comportamiento de los tipos de cobertura analizados es distinto como se muestra en la Figura 8. Las siete bandas fueron incluidas en el análisis de las 3 regiones de interés del estudio.

Las bandas 2, 3, 4, 5, 6, 7, 8, 8ª, 11 y 12 fueron incluidas en la clasificación realizada con los productos de S2 como se presenta en la Tabla 7. El área de BG presenta zonas de aguas poco profundas por lo que también se incluyó la banda 1 de S2 en el análisis de dicha zona. Fueron excluidas las bandas 9 y 10. La banda 2, 3, 4 y 5 corresponden al azul, verde y rojo del espectro visible. Las Bandas 6 y 7 al rojo y ultrarrojo. Las bandas 8 y 8ª pertenecen a la sección del infrarrojo cercano y las bandas 11 y 12 al infrarrojo de onda corta. Las bandas 9 y 10 fueron excluidas pues no se realizó el análisis de vapor de agua ni de presencia de nubes tipo cirrus.

V.4. EVALUACIÓN DEL ACUERDO DE LA DETERMINACIÓN DE LA COBERTURA TERRESTRE

V.4.1. SUB-REGIONES HIDROLÓGICAS

Las áreas de las sub-regiones del BB y del VM presentaron un acuerdo global muy parecido, siendo sus valores de 59.53% y 59.87% respectivamente mientras que el área del BG superó su valor con un 65.30% (Tabla 14). Estos resultados pudieran estar influenciados por el tamaño del área de análisis ya que el mayor acuerdo pertenece a la cuenca del BG que es la de menor tamaño en el análisis. Cabe resaltar que en dicha subregión BG los cuerpos de agua cubren una alta superficie y estos presentan un grado de acuerdo elevado pues se ayudó de una banda extra en su identificación en esta cuenca. Por otro lado, la tasa alta de la dinámica de cambio del área del VM pudiera influir en el acuerdo global de la clasificación, mientras que el área de la subregión del BB pudo verse afectada por el alto contraste entre los diferentes tipos de cobertura terrestre.

Tabla 14. Acuerdo global promedio por cuenca.

CUENCA	Acuerdo Global [%]
Bajo Bravo	59.53
Valle México	59.87
Bajo Grijalva	65.30



V.4.2. SENSOR

El sensor L8 presentó un mayor acuerdo global con un 76.10%. Sin embargo, en la Tabla 15 puede notarse que L8 superó por muy poco al sensor S2 que logró un acuerdo global del 75.04% solo un 1.06% de diferencia. Lo que indica un desempeño semejante entre estos productos satélites. El sensor MD logró un acuerdo global del 56.38% mientras que S1 de 38.75%. Los sensores que lograron un mayor acuerdo global fueron los de mayor resolución espacial y espectral. Esto puede estar relacionado con el hecho de que pixeles de menor resolución espacial generalizan la información de la respuesta a la luz incidente de una mayor variedad de tipos de superficies en el espacio (Chuvienco, 1991). De acuerdo con lo anterior, el acuerdo de MD pudo verse afectado por su baja resolución espacial. Sin embargo, LS superó ligeramente a S2 a pesar de tener una resolución espacial menor. El bajo acuerdo mostrado por S1 pudo ser afectada por su baja resolución espectral.

Tabla 15. Acuerdo global por sensor.

SENSOR	Acuerdo Global [%]
LANDSAT-8	76.10
SENTINEL-2	75.04
MODIS	56.38
SENTINEL-1	38.75

V.4.3. ALGORITMO DE CLASIFICACIÓN

El algoritmo de clasificación de DM arrojó un acuerdo global del 68.60% siendo esta la mayor encontrada. DM es el algoritmo matemáticamente más sencillo de los analizados, mientras que MSV, el más complejo, obtuvo 65.97% quedando por debajo de DM. Este resultado permite afirmar que la sencillez de cálculo no siempre está asociada a resultados de menor acuerdo. El algoritmo MAE obtuvo un 60.14%. MV presentó la menor aceptación global con un 51.54% (Tabla 16). Este resultado es notable tomando pues MV se considera el clasificador de primera opción y que ha sido ampliamente utilizado en diversos estudios (Sudhakar, et al 1999; Bruzzone & Prieto, 2001; Jia et al, 2014; Xu et al 2013). Los tres primeros están alrededor del 65%, mientras el último se queda atrás hasta en un 17%. Asignar regiones de interés con mayor número de pixeles y homogeneidad podría mejorar el resultado de este algoritmo (Richards & Jia, 2006).

Tabla 16. Acuerdo global por algoritmo de clasificación.

ALGORITMO	Acuerdo Global [%]
Distancia Mínima	68.60
Máquinas de Soporte Vectorial	65.97
Mapeo del Angular Espectral	60.14
Máxima Verosimilitud	51.54



V.4.4. SUBREGIÓN DEL BAJO-BRAVO

El acuerdo global individual de las clasificaciones realizadas con cada combinación algoritmo-sensor en la subregión del BB se muestran en la Tabla 17. Como resultado de la evaluación del acuerdo global con la matriz imparcial de población se encontraron seis combinaciones que arrojaron un resultado superior al 70% en la cuenca del BB siendo estas: S2 con todos los algoritmos de clasificación y L8 con MSV y DM. La Tabla 17 incluye también el acuerdo global y el error de omisión/comisión global del resto de las combinaciones algoritmo sensor aplicado a BB. Los resultados más pobres los obtuvo MV con al ser aplicado a los sensores L8 y S1.

Tabla 17. Acuerdo global de las combinaciones Sensor-Algoritmo del área de estudio de la subregión hidrológica del Bajo Bravo.

Sensor	Algoritmo	Omisión/ Comisión	Acuerdo [%]	Escala [%]
S2	DM	16.48	83.52	
S2	MSV	18.47	81.53	
S2	MAE	19.24	80.76	
L8	MSV	21.78	78.22	
S2	MV	22.59	77.41	
L8	DM	23.14	76.86	
S1	MSV	31.37	68.63	
MD	DM	35.53	64.47	
S1	DM	37.65	62.35	
MD	MAE	39.10	60.90	
L8	MAE	42.14	57.86	
MD	MSV	52.87	47.13	
MD	MV	57.69	42.31	
S1	MAE	73.62	26.38	
L8	MV	74.35	25.65	
S1	MV	81.56	18.44	

La Tabla 17 muestra además que en esta subregión el sensor S2 presentó el mejor desempeño superando el promedio global de la cuenca hasta en un 24%. Cabe recalcar que este sensor muestra alta resolución espacial, característica que facilita la identificación de objetos de interés en la superficie terrestre. La región del BB se ve beneficiada por la resolución espacial de S2 ya que presenta diversos tipos de cobertura terrestre contenidos en áreas pequeñas, un alto contraste y dinámica de cambio.



Por otro lado, deberá evitarse el uso del algoritmo de MV con los sensores S1, L8 y MD pues arrojó un acuerdo pobre, así como MAE con S1. Dichos sensores presentaron resultados de aceptación alto en otras combinaciones, L8-MSV alcanzó un 78.22% y un 64.47% fue logrado por la clasificación de MD con DM. Las imágenes del sensor S1 al ser clasificadas con los algoritmos de DM y de MSV alcanzaron un acuerdo mayor del 60%. Este sensor podría utilizarse en presencia de alta nubosidad con dichos algoritmos ya que con técnicas post-procesamiento alcanzará acuerdos globales superiores (Congedo, 2016; Richards & Jia, 2006; Joseph, 2005; Chuvieco, 1991).

La Figura 9 muestra en una línea negra el dominio promedio de cada categoría en los resultados de todas las clasificaciones de la cuenca BB, el promedio de la proporción de pixeles que presentan acuerdo se muestra en forma de barras verdes, el error de comisión en barras azules y el error de omisión en rojas. En dicha figura se apunta que el tipo de cobertura dominante es la agricultura pastizal que además presenta la mayor proporción de acuerdo. Este resultado es de esperarse pues la gran presencia de la clase dominante permitió identificar áreas de entrenamiento con un alto número de pixeles y una firma espectral homogénea. Los asentamientos humanos, solo representan alrededor de un 5% de la superficie del área analizada para BB de estos el 3.14% presentan acuerdo, 1.68% de los pixeles fue erróneamente asignado a esta categoría y el número de pixeles de esta categoría que fueron erróneamente asignados a otra categoría supera los correctamente asignados, siendo estos el 3.95% por lo cual se concluye que los asentamientos humanos del área son subestimados.

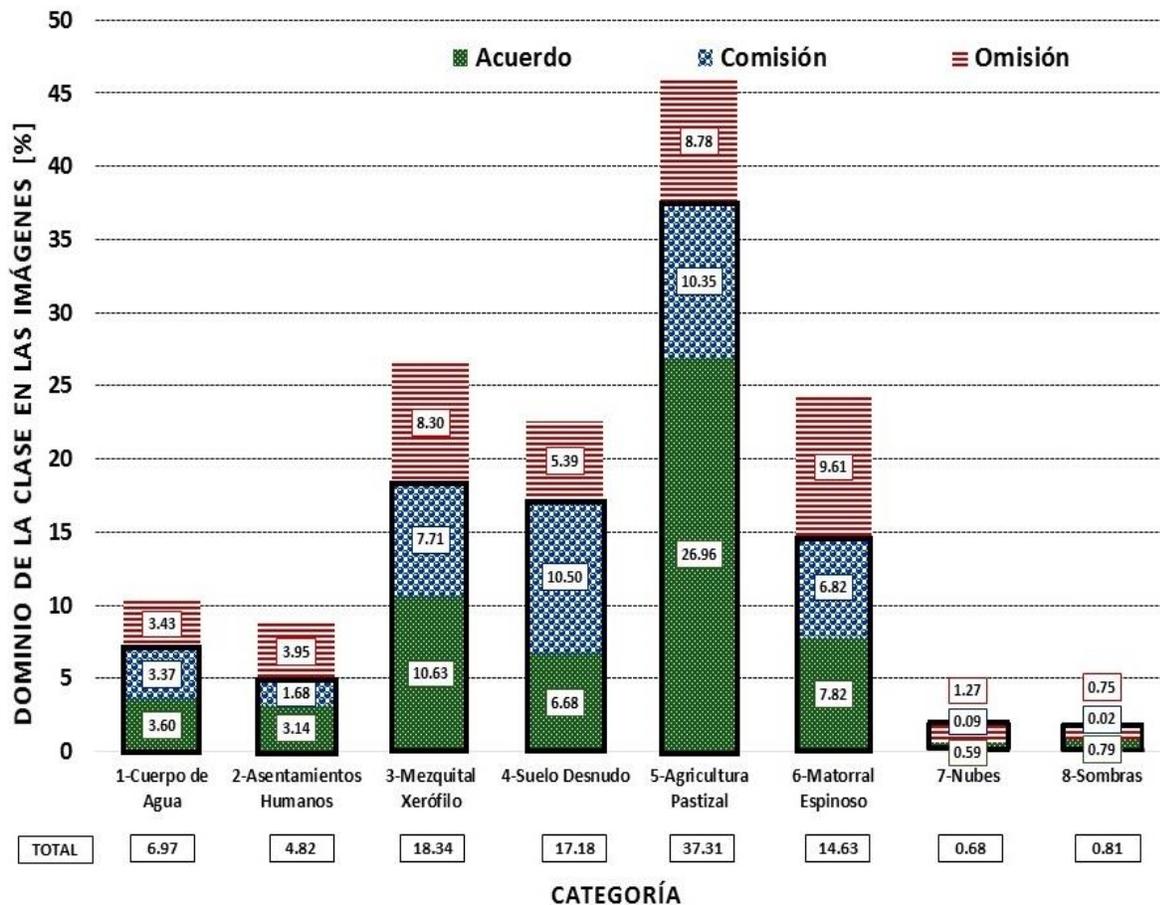


Figura 9. Dominio en el acuerdo global, error de omisión y comisión promedio de la Región de análisis de la cuenca de Bajo Bravo.



En esta región, la vegetación presenta firmas espectrales muy parecidas, lo que provoca altos errores de comisión entre ellas. El error de comisión en la que el mezquital xerófilo es del 7.71% y del 6.82% para el matorral espinoso. Ambos tipos de vegetación presentaron mayor error de omisión que de comisión con un 8.3% y un 9.61%.

El error de comisión de mayor porcentaje se presentó en el suelo desnudo con 10.5%, esto quiere decir que un alto número de píxeles fue asignado a esta categoría sin pertenecer a ella. Este error podría deberse a que el suelo desnudo suele ser confundido con superficies de agricultura pastizal recién sembradas o cosechadas. Los píxeles que no fueron incluidos en esta categoría, aunque debieron serlo representan el 5.39%. Si se lograra un acuerdo total en esta categoría, la presencia del suelo desnudo sería menor que la obtenida en los resultados de la Figura 9.

El dominio por clase resultante en cada una de las clasificaciones individuales se muestra en la Tabla 18 para todas las combinaciones algoritmo sensor aplicados a la cuenca del BB. Debido a que la clasificación de la imagen S2 de la región con el algoritmo de clasificación DM resultó con el mayor acuerdo, se asume que la proporción de los tipos de cobertura obtenidos con dicha combinación se ajustan considerablemente al terreno verdadero. La proporción SD-MD es: 0.4% de agua, 3.30% de asentamientos humanos, 16.23% de Mezquital xerófilo, 5.92% de Suelo desnudo, 55.64% de Agricultura-Pasizal, 17.93% de Matorral Espinoso, 0.36% de nubes y 0.21% de sombras.

Tabla 18. Resultados del dominio de cobertura terrestre del área de estudio de la subregión del Bajo Bravo.

AREA DE ESTUDIO DE LA SUBREGIÓN DEL BAJO BRAVO									
Sensor Algoritmo	DOMINIO								
	1 Cuerpo de Agua	2 Asenta- miento Humano	3 Mezquital Xerófilo	4 Suelo Desnudo	5 Agricultura Pastizal	6 Matorral Espinoso	7 Nubes	8 Sombras	
L8	DM	0.61	4.39	21.93	6.21	49.10	16.81	0.37	0.59
	MAE	0.45	4.04	24.29	6.96	41.56	20.37	0.50	1.84
	MV	0.42	4.92	19.64	55.70	17.71	0.00	1.09	0.53
	MSV	0.66	3.80	20.60	5.80	50.64	16.34	1.47	0.69
MD	DM	11.11	5.93	16.92	11.30	35.48	19.26	-	-
	MAE	10.15	6.58	18.80	14.25	32.51	17.70	-	-
	MV	17.92	3.30	6.15	4.74	41.11	26.79	-	-
	MSV	18.91	3.43	24.36	10.83	25.44	17.03	-	-
S1	DM	34.15	2.93	11.01	16.35	25.46	10.09	-	-
	MAE	15.19	17.29	14.90	17.43	23.58	11.62	-	-
	MV	0.00	0.00	0.00	100.00	0.00	0.00	-	-
	MSV	0.89	2.30	20.25	4.78	44.81	26.96	-	-
S2	DM	0.40	3.30	16.23	5.92	55.64	17.93	0.36	0.21
	MAE	0.42	2.78	19.65	6.22	46.40	21.74	0.58	2.22
	MV	0.00	8.54	30.96	4.09	55.87	0.00	0.38	0.15
	MSV	0.27	3.65	27.73	4.30	51.63	11.51	0.65	0.26



Las proporciones obtenidas de S2 con MSV y MAE son parecidas a la de DM sin embargo, el algoritmo de MV no fue capaz de identificar los cuerpos de agua presentes BB por lo que deberá evitarse su uso a pesar de su buen desempeño global. En L8 las proporciones obtenidas entre DM, MAE y SVM son también muy parecidas mientras que MV sobreestimo el área con Suelo desnudo, subestimo las áreas con agricultura pastizal y no fue capaz de identificar el matorral espinoso.

Los datos del sensor MD arrojaron una proporción parecida en las categorías de asentamientos humanos, mezquital xerófilo, agricultura pastizal y matorral espinoso, pero sobrestimaron las áreas de suelo desnudo y de cuerpo de agua. Los cuerpos de agua tienen baja presencia y tamaño pequeño en el área de BB por lo que solo son identificables en sensores con gran resolución espacial, puede ser que debido a esto MD presentara un menor acuerdo global.

El algoritmo que presentó el mayor acuerdo global con los datos de S1 en BB es MSV como ya se había discutido en la Tabla 18 la proporción que muestra esta clasificación es: 0.89% de cuerpos de agua, 2.30% de asentamientos humanos, 20.25% de mezquital xerófilo, 4.78% de Suelo Desnudo, 44.81% de Agricultura Pastizal y 26.96% de matorral espinoso. Estas proporciones son parecidas a las de la combinación de mayor acuerdo de la región y tienen la ventaja de no ser sensibles a la nubosidad. La combinación de S1 con DM y MAE sobrestimaron la presencia de cuerpos de agua y subestimaron la agricultura pastizal por lo que su uso no es recomendable. La combinación S1-MV deberá descartarse pues no logró distinguir entre clases si no que categorizó la totalidad de los píxeles como suelo desnudo.

V.4.5. SUBREGIÓN DEL BAJO-GRIJALVA

La Tabla 19 muestra los resultados de acuerdo global individual y el error de omisión /omisión global para todas las combinaciones de algoritmo-sensor de BG. En dicha Tabla 19 se muestran 8 combinaciones con un 80% de acuerdo global o más, correspondiendo estas a las imágenes de L8 y S2 con los 4 algoritmos de clasificación. En el análisis de la cobertura terrestre del BG con los sensores L8 y S2 incluye la banda 1 de ambos sensores que corresponde a la zona espectral del azul profundo y facilita en estudio de cuerpos de agua someros y zonas húmedas. El uso de una banda espectral extra parece influir positivamente en el resultado global de los sensores L8 y S2.

El algoritmo MSV obtuvo el mayor acuerdo con ambos sensores. El algoritmo de DM con la combinación de S2 en esta subregión de BG logró solo el cuarto lugar a pesar de ser el de mejor acuerdo global en el estudio. Esto podría indicar que las condiciones de alta humedad afectan sus capacidades de diferenciación de los diversos tipos de cobertura terrestre. Las combinaciones restantes no superaron el 60% de acuerdo como se muestran también en la Tabla 19. Las clasificaciones con acuerdos pobres son de las imágenes del sensor S1 con MV y MAE por lo que su uso no es recomendable.



Tabla 19. Acuerdo global de las combinaciones Algoritmo-Sensor de del área de estudio de la subregión BG.

Sensor	Algoritmo	Omisión/ Comisión	Acuerdo [%]	Escala
L8	MSV	9.48	90.52	
L8	MV	11.40	88.60	
S2	MSV	12.05	87.95	
S2	DM	13.84	86.16	
L8	MAE	13.95	86.05	
S2	MAE	15.82	84.18	
S2	MV	15.92	84.08	
L8	DM	18.50	81.50	
MD	MAE	45.22	54.78	
S1	DM	46.32	53.68	
MD	MSV	48.16	51.84	
MD	MV	50.90	49.10	
S1	MSV	51.27	48.73	
MD	DM	53.96	46.04	
S1	MAE	71.75	28.25	
S1	MV	76.63	23.37	

El sensor LS8 presentó la mayor aceptación en el área de estudio pues todas las combinaciones de este sensor con los clasificadores tienen una aceptación global alrededor del 80%. Incluso el algoritmo de MV logró la segunda mayor acuerdo con un 88.60% a pesar de su bajo desempeño en otras combinaciones y cuencas. El máximo acuerdo en esta área de estudio logró la combinación del algoritmo de clasificación de MSV y los datos de la imagen LS8 con un valor de 90.52%, este resultó ser también el mejor desempeño del estudio. Cabe recalcar que esta imagen presento nubosidad y no fue posible encontrar una imagen de esa fecha sin nubosidad, además las nubes y sus sombras presentan el mayor acuerdo en la cuenca lo que podría influir positivamente en el desempeño global.

En esta cuenca el sensor MD presentó resultados de aceptación alrededor del 50% los cuales pueden ser mejorados por la aplicación de técnicas post procesamiento hasta llegar a un mayor acuerdo. Esto es importante porque la alta resolución temporal de MD presenta la ventaja de proporcionar datos diarios de la cuenca y facilita encontrar una imagen sin nubosidad.



Por otro lado, las imágenes S1 presenta también una gran ventaja en regiones con alta precipitación, como lo es el área de estudio del BG, pues los sensores que trabajan en la región de las microondas no presentan sensibilidad a la nubosidad. Además, tiene una resolución espacial de 10 m, suficiente para la identificación del suelo desnudo o regiones de alto contraste. El uso de los algoritmos de DM y MSV en la clasificación de imágenes S1 resultó en acuerdos globales de alrededor del 50%. El aumento de cantidad y homogeneidad de las firmas espectrales de entrenamiento junto a la aplicación de técnicas post-procesamiento pueden aumentar el acuerdo global hasta lograr un acuerdo aceptable.

El mayor acuerdo presente en las clasificaciones con las imágenes S2 de la cuenca del BG fue lograda por el algoritmo de MSV con un valor 87.95%, solo un 2.57% menor que la clasificación con mayor acuerdo del presente trabajo. El sensor MSI a bordo de S2 presenta la ventaja de identificar objetos de un tamaño de hasta 10 m y adquirir imágenes semanales que aumentan la posibilidad de encontrar una imagen con baja presencia de nubosidad.

La Figura 10 muestra las barras verdes del acuerdo, azules de error de comisión y rojas de error de omisión proporcional promedio de cada categoría en los resultados de todas las clasificaciones de la subregión BG, así como una línea negra que muestra el dominio promedio de las categorías en la cuenca. El suelo desnudo resultó ser el tipo de cobertura con menor acuerdo encontrado y la menor presencia en la cuenca del BG como se muestra en esa figura tiene un 5.12% y presentó un error de comisión de 2014 y el 3.76 de omisión. Las sombras y nubes alcanzaron altos niveles de acuerdo, pero estas no solamente no aportan un valor al CE, sino que además impiden una determinación adecuada del mismo porque la presencia de nube no permite conocer la cobertura terrestre existente en la zona que cubren por lo que deberá realizarse una edición al ráster donde se sustituya el valor de la nube por el de la clase que está en la cobertura terrestre.

Las clases restantes presentan acuerdos que superan la mitad de su presencia (Figura 10). La categoría de vegetación sumergida resultó en la mayor presencia del sitio con un total de 22.17% del cual 8.97% no pertenecen a dicha categoría y 7.49% de los pertenecientes a esta clase fueron asignados a otras categorías. La zona inundada y la agricultura pastizal presentan comportamientos parecidos con un error de comisión alrededor del 6% y un error de omisión alrededor del 4%. El error de confusión de estas zonas puede deberse a que las firmas espectrales de dichas áreas son parecidas a las de las zonas inundadas donde comienza a crecer vegetación o las de la agricultura pastizal con alta presencia de humedad.

El manglar es la vegetación característica de la zona y se muestra claramente distinguible en el espectro de infrarrojo es por ello que presentó un acuerdo alto, 11.29% de 15.70%, sin embargo, el 5.99 % de los píxeles de manglar fueron asignados a otra categoría. Los cuerpos de agua son muy importantes en esta área de estudio debido a su alta presencia en el sitio y la frecuente precipitación. En esta área la presencia de cuerpos de agua resultó en 11.12% de los cuales el 7.76% presentaron acuerdo, el 3.36% no pertenecen a esta categoría, pero fueron asignados a ella y el 5.23% fueron omitidos.

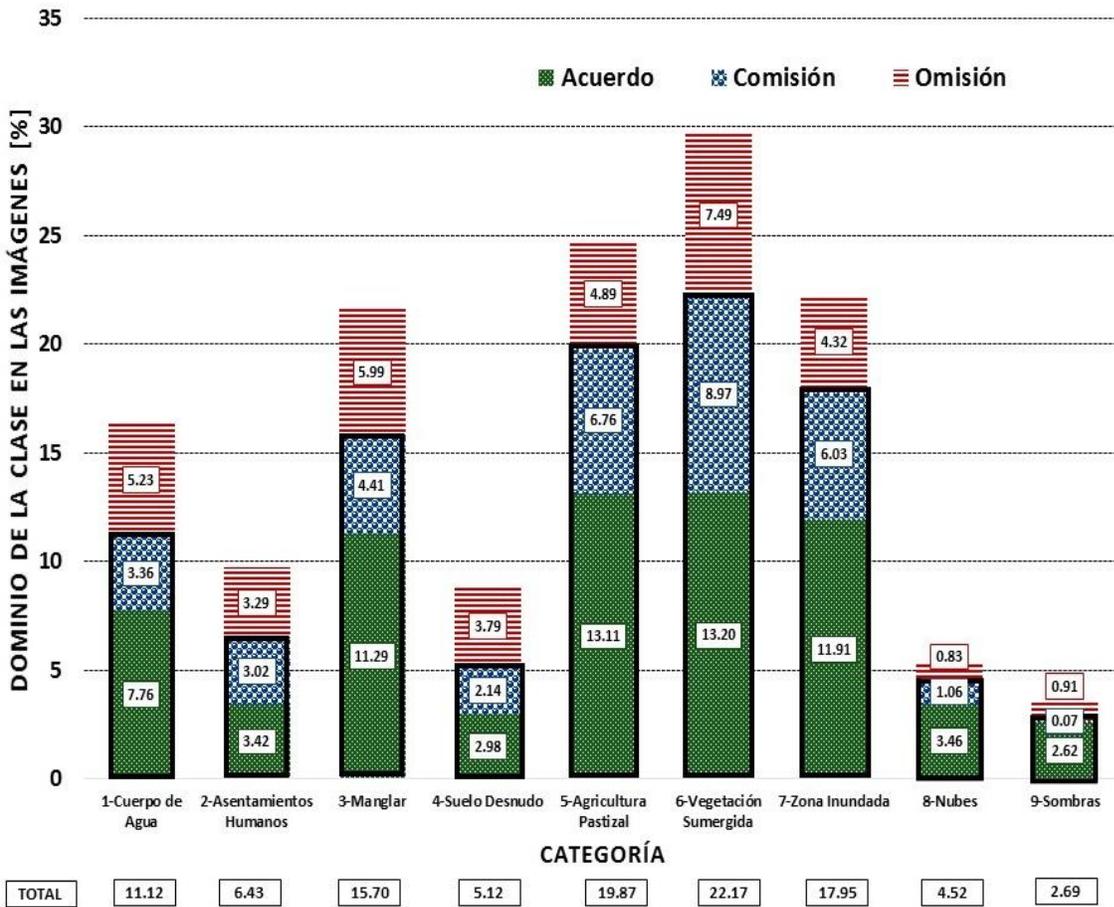


Figura 10. Dominio en el acuerdo global, error de omisión y comisión promedio de la Región de análisis de la subregión de Bajo Grijalva.

Los asentamientos humanos tienen una presencia del 6.43% en la zona y un acuerdo aproximadamente de la mitad de esto, el error de comisión y omisión son muy parecidos en esta categoría. En el área analizada, el suelo desnudo está especialmente cercano a las zonas de asentamientos humanos por lo que el error de comisión puede deberse a esta cercanía.

La Tabla 20 muestra para cada una de las combinaciones algoritmo-sensor el dominio por clase resultante de forma individual para la cuenca del BG. La proporción que se considera real en la zona de estudio es: 7.69% de Cuerpos de agua, 2.64% de asentamientos humanos, 15.52% de Manglar, 1.08% de suelo desnudo, 21.12% de Agricultura Pastizal, 27.54% de vegetación sumergida, 18.90% de zona inundada, 2.99% de nubes y 2.51% de sombras. La proporción elegida pertenece a los resultados de la clasificación de LS8 con MSV que se asume como verdaderos pues presentaron el mayor acuerdo global del estudio. Las proporciones obtenidas con L8-MV y S2-MSV, son muy parecidas a las tomadas como verdaderas no así para L8-MAE que subestimó las zonas de asentamientos humano y suelo desnudo mientras sobreestima la presencia de cuerpos de agua.



Tabla 20. Resultados del dominio de cobertura terrestre del área de estudio de la subregión del Bajo Grijalva.

AREA DE ESTUDIO DE LA SUBREGIÓN DEL BAJO GRIJALVA										
Sensor / Algoritmo	DOMINIO									
	1 Cuerpo de Agua	2 Asentamientos Humanos	3 Manglar	4 Suelo Desnudo	5 Agricultura Pastizal	6 Vegetación Sumergida	7 Zona Inundada	8 Nubes	9 Sombras	
L8	DM	7.58	2.31	18.16	2.74	17.77	29.91	18.50	1.30	1.73
	MAE	9.29	1.51	17.74	1.76	21.07	26.72	15.45	1.73	4.73
	MV	7.03	8.90	14.21	3.62	20.48	22.99	16.26	4.73	1.78
	MSV	7.69	2.64	15.52	1.08	21.12	27.54	18.90	2.99	2.51
MD	DM	26.99	11.59	11.31	-	10.39	15.82	19.68	4.23	-
	MAE	22.57	15.54	14.62	-	12.00	13.98	15.63	5.66	-
	MV	17.29	8.18	15.26	-	12.74	18.16	18.62	9.75	-
	MSV	21.01	6.30	10.76	-	9.06	14.99	32.14	5.75	-
S1	DM	6.99	14.69	15.20	10.24	14.32	19.69	18.88	-	-
	MAE	11.28	13.66	20.26	9.39	12.64	14.20	18.56	-	-
	MV	-	4.14	-	-	57.30	38.56	-	-	-
	MSV	8.23	1.56	28.01	20.48	24.97	-	16.74	-	-
S2	DM	7.83	1.14	18.64	1.55	22.25	27.59	20.99	-	-
	MAE	8.29	0.77	15.89	1.12	18.62	34.01	21.29	-	-
	MV	7.84	6.05	16.18	5.77	22.56	23.64	17.97	-	-
	MSV	7.97	3.95	19.38	3.64	20.61	26.94	17.51	-	-

Las clasificaciones logradas con S2 y el algoritmo de DM aunque fallan en la proporciones de áreas de asentamientos humanos mantuvieron las de cuerpos de agua, manglar, agricultura pastizal y zona inundada. El algoritmo de MV aunque obtuvo un buen acuerdo global sobrestimó las áreas de asentamientos humanos y suelo desnudo.

En el análisis del sensor MD no fue posible determinar áreas de entrenamiento de suelo desnudo pues en la cuenca del BG las áreas con dicho tipo de cobertura son más pequeñas que el área identificable por la resolución espacial de MD. Además, MD sobrestimo la presencia de masas de agua en el sitio y subestimó la presencia de vegetación sumergida. Es por esto que, a pesar de tener una resolución temporal de MD que facilita obtener imágenes sin nubosidad no se recomienda su uso para la determinación de la cobertura terrestre en BG.

Al utilizar S1 deberá evitarse el uso de los algoritmos de MSV y MV pues el primero no asignó píxeles a la categoría de vegetación sumergida a pesar de ser la de mayor presencia en la zona y el segundo solo logró distinguir las clases de asentamientos humanos, agricultura-pastizal y vegetación sumergida. MAE sobreestimo categorías de poca presencia y subestimó categorías de alto dominio. S1 presenta la ventaja de no ser sensible a la nubosidad, por lo que de ser necesario se recomienda la combinación de los datos S1 con el algoritmo de DM, teniendo especial cuidado en la determinación de áreas de entrenamiento de las clases de menor presencia y aumentando el número de áreas de entrenamiento con altos píxeles y alta homogeneidad.



V.4.6. SUBREGIÓN DEL VALLE DE MÉXICO

La matriz imparcial de población nos dio como resultado el acuerdo global individual, y error individual de omisión-comisión que se muestran en la Tabla 21 del área de análisis de la subregión del VM para cada una de las combinaciones algoritmo sensor. Se muestran 7 combinaciones con más de un 70% de acuerdo. La combinación de los cuatro algoritmos con el sensor L8 arrojó los 4 mejores resultados de aceptación para esta región a pesar de que en la clasificación de esta imagen se utiliza una banda espectral menos que en el sensor MD y 5 bandas menos que las utilizadas en S2. L8 presentó valores entre 79.40% y 84.62% de acuerdo global, una diferencia de solo el 5.22%. Los sensores que siguieron a L8 en el mayor acuerdo fueron MD con DM y S2 con MAE. El menor acuerdo se obtuvo con MV para las imágenes S1 y S2 y con MAE para S1.

Tabla 21. Acuerdo global de las combinaciones Algoritmo-Sensor de la subregión del Valle de México

Sensor	Algoritmo	Omisión/Comisión	Acuerdo [%]	Esca la [%]
L8	MAE	15.38	84.62	
L8	DM	16.21	83.79	
L8	MSV	19.92	80.08	
L8	MV	20.60	79.40	
MD	DM	28.07	71.93	
S2	MAE	28.53	71.47	
MD	MV	29.99	70.01	
S2	DM	33.03	66.97	
MD	MAE	40.20	59.80	
MD	MSV	41.78	58.22	
S2	MSV	42.74	57.26	
S1	DM	54.05	45.95	
S1	MSV	58.40	41.60	
S2	MV	60.85	39.15	
S1	MAE	73.31	26.69	
S1	MV	79.04	20.96	

La Figura 11 muestra en una línea negra el dominio promedio de cada categoría en los resultados de todas las clasificaciones de la subregión VM, el promedio de la proporción de pixeles que presentan acuerdo, error de comisión y omisión se muestra en forma de barras verdes, azules y rojas.



Esta subregión es altamente urbanizada por lo que es de esperarse que el dominio que predomina en el área de estudio son los asentamientos humanos como lo muestra la Figura 11, un 44.07% de presencia de esta categoría, el 31.63% de esto muestran acuerdo con las áreas de verificación, el 12.4% fue asignado erróneamente a esta categoría y el 5.29% de los asentamientos humanos se categorizó como otro tipo de cobertura terrestre.

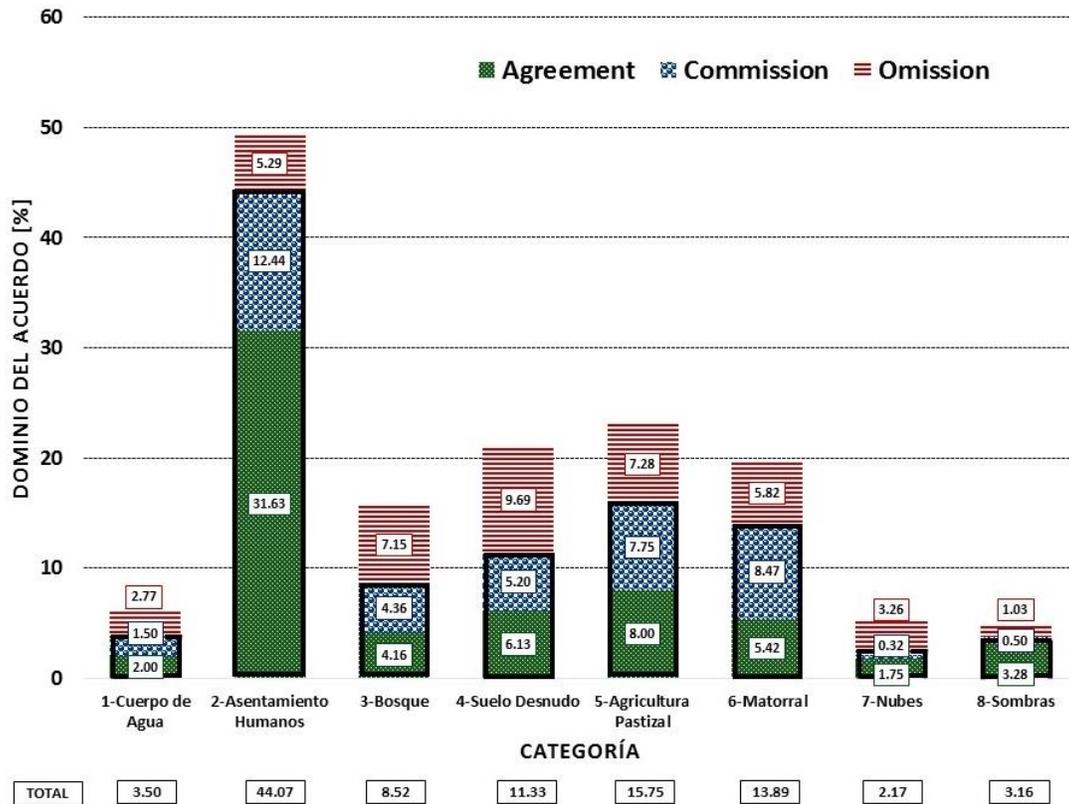


Figura 11. Dominio en el acuerdo global, error de omisión y comisión promedio de la Región de análisis de la subregión de Valle de México.

El suelo desnudo, bosque y los cuerpos de agua son las clases con bajo porcentaje de acuerdo y también son las que tiene la menor cantidad de pixeles de entrenamiento por su reducida presencia en la imagen. El suelo desnudo mostró un acuerdo del 6.13% y con el 5.2% de error de comisión sumo un 11.33% de presencia en la cuenca sin embargo el 9.69% de los pixeles del suelo desnudo fueron erróneamente asignados a otras categorías. La categoría de bosque mostro un comportamiento parecido, cantidades parecidas de acuerdo y comisión y una cantidad superior de omisiones, el 4.16%, 4.36% y 7.15% respectivamente. La presencia promedio de agua es de solo el 3.50% pero el 2.77% debió ser asignado a esta categoría, pero fue omitido y el 2.77% fue erróneamente asignado a esta categoría.

La agricultura pastizal alcanzó un 15.75% de dominio en la imagen siendo la segunda dominante en las imágenes evaluadas, el 8% presenta acuerdo y los valores de comisión y omisión son muy parecidos, con el 7.75 y 7.28 por ciento respectivamente. Como en otras imágenes, la comisión es alta entre el suelo desnudo y la agricultura pastizal, pero esta última también es confundida con el matorral. Esta región del país presenta un alto contraste y cambio en la cobertura terrestre por lo que



los sensores de alta resolución espacial resultaron ser apropiados. Sin embargo, debe buscarse una alta resolución temporal debido a la dinámica de cambio en el lugar.

Los resultados del dominio por clase resultante de forma individual para cada una de las combinaciones algoritmo-sensor de la cuenca del VM son mostrados en la Tabla 22. La combinación LS8-MAE presentó el mayor acuerdo global en VM por lo que las siguientes proporciones son las más adecuadas para describir el área: 1.1% de cuerpo de agua, 49.89% de asentamientos humanos, 7.29% de Bosque, 11.77% de suelo desnudo, 11.77% de agricultura pastizal, 12.26% de Matorral, 2.92% de nubes y 3.0% de sombras.

Tabla 22. Resultados del dominio de cobertura terrestre del área de estudio de la subregión Valle México.

AREA DE ESTUDIO DE LA SUBREGIÓN DEL VALLE DE MÉXICO									
Sensor / Algoritmo	DOMINIO								
	1 Cuerpo de Agua	2 Asentamiento Humano	3 Bosque	4 Suelo Desnudo	5 Agricultura Pastizal	6 Matorral	7 Nubes	8 Sombras	
L8	DM	1.21	50.47	5.68	13.04	17.00	9.04	2.67	0.91
	MAE	1.10	49.89	7.29	11.77	11.77	12.26	2.92	3.00
	MV	1.11	58.75	4.60	6.67	16.86	9.32	1.68	1.01
	SVM	2.00	59.29	5.16	6.49	14.57	7.97	3.30	1.22
MD	DM	8.71	38.61	9.95	17.34	18.27	7.12	-	-
	MAE	6.49	47.62	12.26	10.42	19.80	3.41	-	-
	MV	2.45	50.44	7.04	7.49	26.66	5.91	-	-
	SVM	1.08	51.13	8.12	11.58	22.11	5.98	-	-
S1	DM	2.27	35.83	24.29	10.49	13.96	13.15	-	-
	MAE	20.55	31.06	10.12	17.35	12.73	8.19	-	-
	MV	2.08	0.00	0.00	0.00	0.00	97.92	-	-
	SVM	2.10	51.44	8.85	9.86	12.10	15.65	-	-
S2	DM	2.09	45.25	6.64	12.29	23.92	7.83	1.07	0.91
	MAE	1.06	42.95	5.41	14.36	20.39	9.64	3.25	2.94
	MV	0.88	46.94	16.73	24.96	8.57	1.16	0.77	0.00
	SVM	0.88	45.47	4.26	7.15	13.37	7.69	0.97	20.21

En la Tabla 22 se muestran que los dominios de cada clase en las clasificaciones de L8 con los 4 algoritmos resultaron valores cercanos entre sí con excepción del suelo desnudo donde algunos valores están alrededor del 12% y otros del 6%.

La combinación MD-DM resultó en un 71.93% de acuerdo, sin embargo, las proporciones con las que clasifica los píxeles son bastante diferentes que las encontradas con LS8. MD tiene una baja resolución espacial es por ello que, los objetos de menor tamaño resultaron en sobreestimar la presencia de agua y subestimar los asentamientos humanos.



S2 a pesar de contar con la mayor resolución espacial y espectral solo mostró resultados ventajosos en la combinación con el algoritmo MAE que superó el 70% de acuerdo, pero obtuvo proporciones parecidas a las de la combinación algoritmo sensor de mayor acuerdo las combinaciones S2-DM y S2-MAE. El algoritmo de MV con este sensor sobreestimó la presencia del bosque y el suelo desnudo y subestimó la presencia del matorral

S1 resultó en los menores acuerdos. La clasificación de esta imagen con el algoritmo de DM proporcionó el mayor acuerdo de este clasificador con un 47.80% subestimando las áreas de urbanas a un 35.83% y sobrestimando un 17% de bosque sobre su valor. El algoritmo MAE con S1 clasificó como cuerpo de agua un número excesivo de píxeles, mientras que el clasificador de MV solo fue capaz de reconocer las clases de cuerpo de agua y matorral. La combinación S1-MSV aunque obtuvo un acuerdo global menor al 50% mantuvo proporciones parecidas a las de la combinación de mayor desempeño en esta cuenca, siendo: 2.10% de cuerpos de agua, 51.44% de asentamientos humanos, 8.85% de Bosque, 9.86% de suelo desnudo, 12.10% de agricultura pastizal y 15.65% matorral.

V.4.7. SELECCIÓN DE LA IMAGEN

Además de las características propias de cada sensor, para la selección de la imagen que es conveniente utilizar en alguna zona en particular deben considerarse los aspectos geográficos regionales del área de estudio y las necesidades de cada análisis. Como resultado de la revisión bibliográfica y los aspectos encontrados en el análisis de la clasificación de la cobertura terrestre en esta investigación se puede establecer que para la selección de la imagen más apropiada en la determinación de la cobertura terrestre de cada área de análisis deben considerarse las siguientes características prioritarias: resolución espacial, resolución espectral, resolución temporal, resolución radiométrica, periodo de estudio, tipo de cobertura terrestre y su contraste, dinámica de cambio y transiciones de la región, clima y tamaño de la cuenca. Los siguientes párrafos nos permiten elegir las características que deben utilizarse para la determinación del CE considerando las necesidades y características particulares de las cuencas:

Resolución espacial y Tamaño de la cuenca

La resolución espacial determinará que coberturas terrestres será posible distinguir con los datos del sensor en un menor espacio. Por ejemplo, en este estudio la resolución espacial fue protagonista en el área de estudio de BB donde S2 logro el mayor acuerdo pues al dividir los píxeles en 10 m² permitió identificar diversos tipos de cobertura en un espacio pequeño. Sin embargo, en este aspecto deben considerarse el tamaño de la cuenca ya que si se elige una resolución espacial alta deberán utilizarse un mayor número de imágenes para cubrir el área de estudio lo que implica un mayor tiempo de procesamiento y una mayor capacidad computacional.

Resolución espectral y tipo de cobertura

Una resolución espacial alta, que tenga un alto número de bandas con una anchura lo suficientemente estrecha como para discriminar diferentes regiones del espectro, nos permite discriminar diversos tipos de cobertura terrestre. En este estudio los cuatro sensores cuentan con una resolución espectral capaz de discriminar cuatro grandes categorías de cobertura terrestre que afectan los parámetros hidrológicos: Cuerpo de agua, vegetación, suelo desnudo y asentamientos



humanos. Sin embargo, el sensor de mayor número de bandas resultó no ser el de mayor acuerdo promedio global.

Resolución temporal y Periodo de estudio

1. La resolución temporal es un factor de decisión en la periodicidad del proyecto por lo que, si se trata de un análisis diario, los datos de entrada se verán limitados al sensor MD u otro sensor con alta resolución temporal que obtenga datos diariamente del área a analizar. Sin embargo, la dinámica de cambio de cobertura terrestre pocas veces es tan acelerada por lo que es posible realizar análisis semanales utilizando S2 o L8 y con S1 análisis quincenales, siempre que haya condiciones de poca nubosidad para los sensores ópticos.
2. Ya que se ha asociado el aumento de la población humana y el desarrollo tecnológico a la aceleración en el cambio de la cubierta terrestre es lógico pensar que las cuencas que presentan alta densidad humana deberán ser analizadas con una resolución espacial alta que permita la observación de los pequeños cambios de cobertura terrestre (Goldewijk, 2001; Liu & Tian, 2010; Loperfido et al., 2014). Así, el análisis en cuenca urbanizadas como la del VM deberá limitarse a los sensores L8, S2 o S1 u otros sensores con resoluciones espaciales equivalentes siempre que mantengan un acuerdo suficiente para el estudio realizado.

Dinámica de cambio y transiciones de cobertura terrestre en la región

La tasa de cambio y la naturaleza de las transiciones de la cubierta terrestre están definidas a diversas velocidades en el tiempo y el espacio (Broich et al., 2011; Gómez et al., 2016). Las regiones donde predomina la vegetación silvestre suelen aparecer con pequeños cambios en el tiempo. Estos cambios son perceptibles mediante imágenes de baja resolución temporal como L8, S1 y S2. Existen también áreas sujetas a una transformación rápida y/o persistente, generalmente debida a la expansión urbana o a principalmente grandes fenómenos naturales como una explosión volcánica o desastres climatológicos, estas zonas deberán ser clasificadas con imágenes de alta resolución temporal como MD.

Clima

El clima, específicamente la nubosidad de la zona impide que algunos sensores obtengan información de la cobertura terrestre, por lo que deben buscarse el uso de datos que no presenten este factor climático, así como buscar la utilización de sensores no sensibles a nubosidad o con una alta resolución temporal que faciliten la obtención de datos libres de nubes. En este estudio fue posible encontrar zonas de baja nubosidad para todos los sensores y áreas de análisis. El área de BG, al encontrarse en un clima tropical, presentó en este estudio la mayor nubosidad con 2.17% de nubes y 3.16% de sus sombras. El mayor acuerdo encontrado con S1 fue logrado con el algoritmo de DM en esta zona.

El resumen de las estas características para cada uno de los sensores analizados se describe en la Tabla 23, esta tabla además muestra el tipo de proyecto que se beneficia con cada una de las características. Si el proyecto a desarrollar implica el estudio de la cobertura terrestre actual entonces se podrán utilizar datos de S1,S2, MD y L8 pero si el estudio incluye el cambio histórico entonces los



datos se limitaran a MD para periodos posteriores del año 1999 y se deberá seleccionar datos de la serie LandSat para realizar estudios anteriores a esa fecha y hasta el año 1972. Por otro lado, si los datos deben analizarse diariamente deberá utilizarse datos MD, si se trata de un análisis semanal se favorecerán los datos de S2 y si se trata de periodos de tiempo mayores podrá usarse cualquiera de estos cuatro sensores.

La escala del proyecto es de gran importancia para seleccionar la resolución espacial de los datos a analizar, para proyectos regionales deberán utilizarse datos MD o con una resolución espacial parecida. Para estudio locales se recomienda el uso de L8, S1 y S2. El análisis de bandas permitió identificar que todos los sensores permiten la identificación de cuerpo de agua, vegetación, suelo desnudo y asentamientos humanos y así se expresa en la Tabla 23.

Para regiones de alta nubosidad se deberán utilizar sensores no sensibles al clima como S1 o bien sensores que debido a su alta resolución temporal aumenten la posibilidad de encontrar imágenes sin la presencia de nubes como es MD. L8 y S2 se recomiendan en zonas de baja nubosidad.

Para la selección del sensor deberá priorizar el sensor que ha mostrado un mayor acuerdo en su clasificación. En este estudio del territorio nacional se recomienda priorizar de la siguiente forma: (1) L8 que logro un 76.10% de acuerdo, S2 con un 75.04% de acuerdo, MD que logró un 56.10% y S1 con 38.75%.

Tabla 23. Factores que intervienen en la selección de una imagen para la determinación de la Cobertura terrestre.

Sensor	MODIS MOD09	LANDSAT 8 OLI	SENTINEL 1 SAR	SENTINEL 2 MSI
Inicio del periodo del estudio a realizar	1999	1972*	2016	2015
	<i>Históricos</i>	<i>Históricos</i>	<i>Actuales</i>	<i>Actuales</i>
Resolución temporal [d]	2	16	16	5
Apropiada para estudios	<i>Diario</i>	<i>Quincenales</i>	<i>Quincenales</i>	<i>Semanal</i>
Resolución espacial [m]	500	30	10	10
Apropiada para estudios	<i>Regionales</i>	<i>Locales</i>	<i>Locales</i>	<i>Locales</i>
Rango de resolución espectral [µm]	0.46-2.1	0.48-2.2	37500 -75000	0.44-2.19
Apropiada para Tipo de cobertura	Cuerpo de agua, vegetación, suelo desnudo y asentamientos humanos	Cuerpo de agua, vegetación, suelo desnudo y asentamientos humanos	Cuerpo de agua, vegetación, suelo desnudo y asentamientos humanos	Cuerpo de agua, vegetación, suelo desnudo y asentamientos humanos
Sensibilidad al clima	<i>Si</i>	<i>Si</i>	<i>No</i>	<i>Si</i>
Apropiada para estudios	<i>Zonas de Baja nubosidad</i>	<i>Zonas de Baja nubosidad</i>	<i>Zonas de Alta nubosidad</i>	<i>Zonas de Baja nubosidad</i>
[%]Acuerdo Global promedio en el estudio	56.10	76.10	38.75	75.04



V.5. DETERMINACIÓN DEL COEFICIENTE DE ESCURRIMIENTO

V.5.1. SUBREGIÓN DEL BAJO-BRAVO

Las combinaciones sensor-algoritmo seleccionadas para la determinación de CE son: S2 con DM y MSV y L8 con MSV. Las primeras dos son las de con mayor acuerdo y la última se seleccionó para fines de comparación. La Figura 12 muestra el resultado de la clasificación para las tres imágenes. La diferencia principal entre estas se encuentra en el centro del área donde se identifican áreas de vegetación de Mezquital Xerófilo en mayor o menor proporción. Las tres imágenes muestran confusión de nubes en las áreas de asentamientos humanos, esto podría deberse a la presencia de manufactureras con naves industriales blancas. Como se ha mencionado previamente, para reducir este error es recomendable agregar una clase especial o bien corregir con métodos post-clasificación. L8 con MSV clasificó como suelo desnudo áreas de la zona este de la región que en las imágenes S2 fueron identificadas como suelo desnudo.

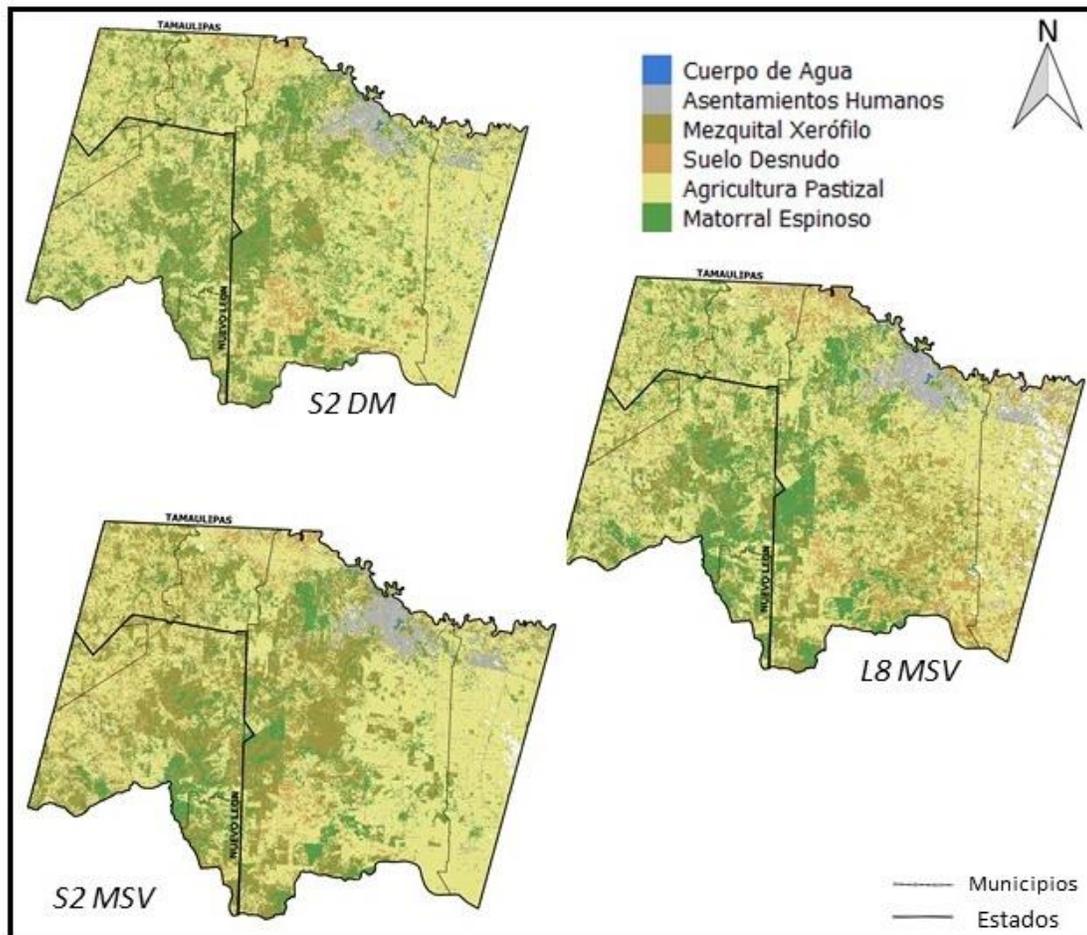


Figura 12. Clasificación de la cobertura terrestre de 3 de las combinaciones Sensor-Algoritmo con mayor acuerdo en el área de estudio de la Subregión Hidrológica del Bajo Bravo.



La información de la Precipitación y la textura de suelo que se utilizó para el cálculo del CE en la cuenca de BB se muestran en la Figura 13. La precipitación en el lugar tiene variaciones entre 470 y 620 mm que aumenta hacia el sur de la cuenca. La textura de suelo mediana es dominante en la imagen, donde también hay pequeñas áreas de textura fina y escasa áreas con textura gruesa en el norte de la imagen. La constante Kv mostrada en la Figura 13 es la resultante de la imagen del sensor S2 y el clasificador de DM encontrándose en un rango entre 0.22 y 0.3.

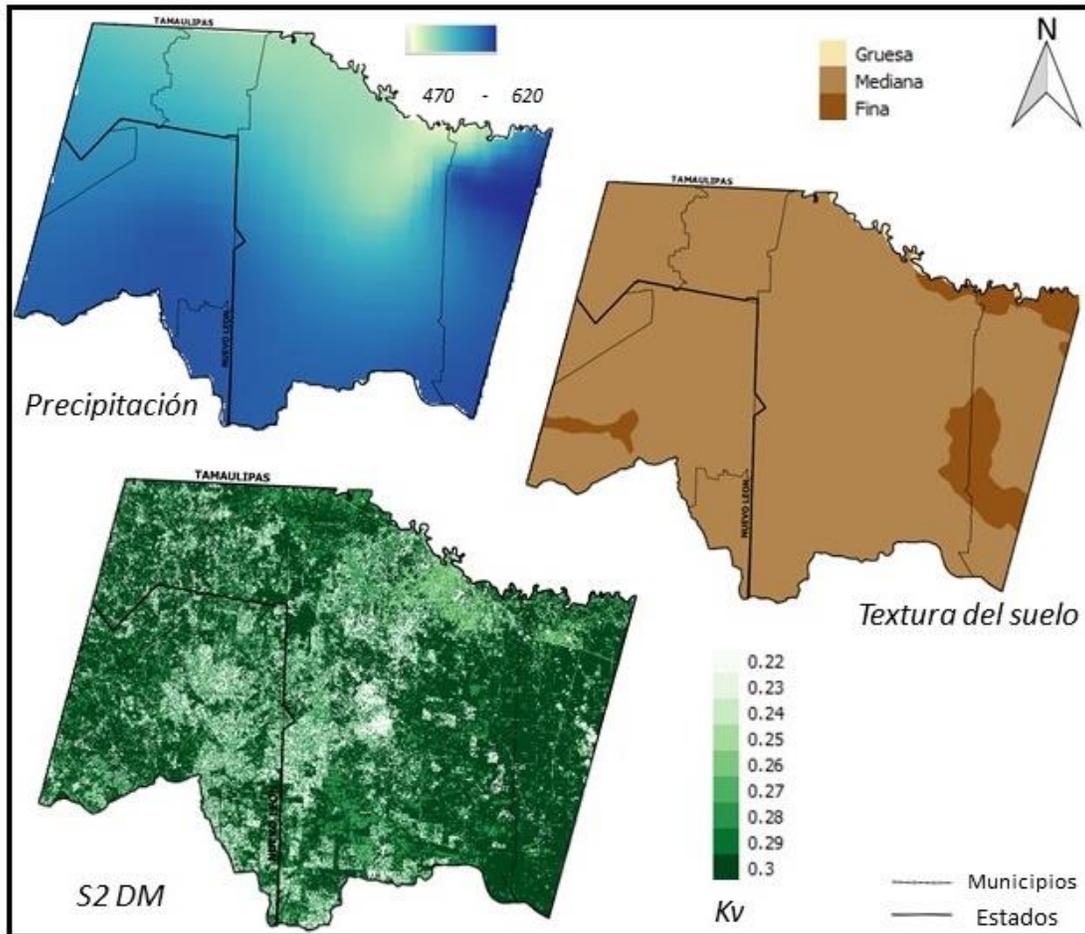


Figura 13. Información de entrada para la determinación del CE en el área de estudio de la Subregión Hidrológica del Bajo Bravo.

El resultado final del CE en la cuenca del BB se muestra en la Figura 14 para las clasificaciones seleccionadas. El CE comienza en un 0.17 hasta un 0.28 en las tres determinaciones, muy superior a los valores de INEGI que tienen un valor máximo del 20%. Por otro lado, la distribución espacial es bastante diferente. La carta hidrológica de INEGI muestra, por ejemplo, CE que van entre el 0 al 0.5% en el sureste y una pequeña cantidad en el norte mientras que las imágenes clasificadas resultaron en un menor CE en una mayor extensión del norte de la región. Además, el mayor escurrimiento se presentó en el sureste por el contrario en la carta de INEGI que se encuentra en el Noroeste. Cabe recalcar que las determinaciones de CE del presente estudio muestran valores puntales hasta cada 10 m del territorio, muy superiores a las proporcionadas por la carta hidrológica que agrupa regiones con valores de 0 a 5% y de 5 a 10%.

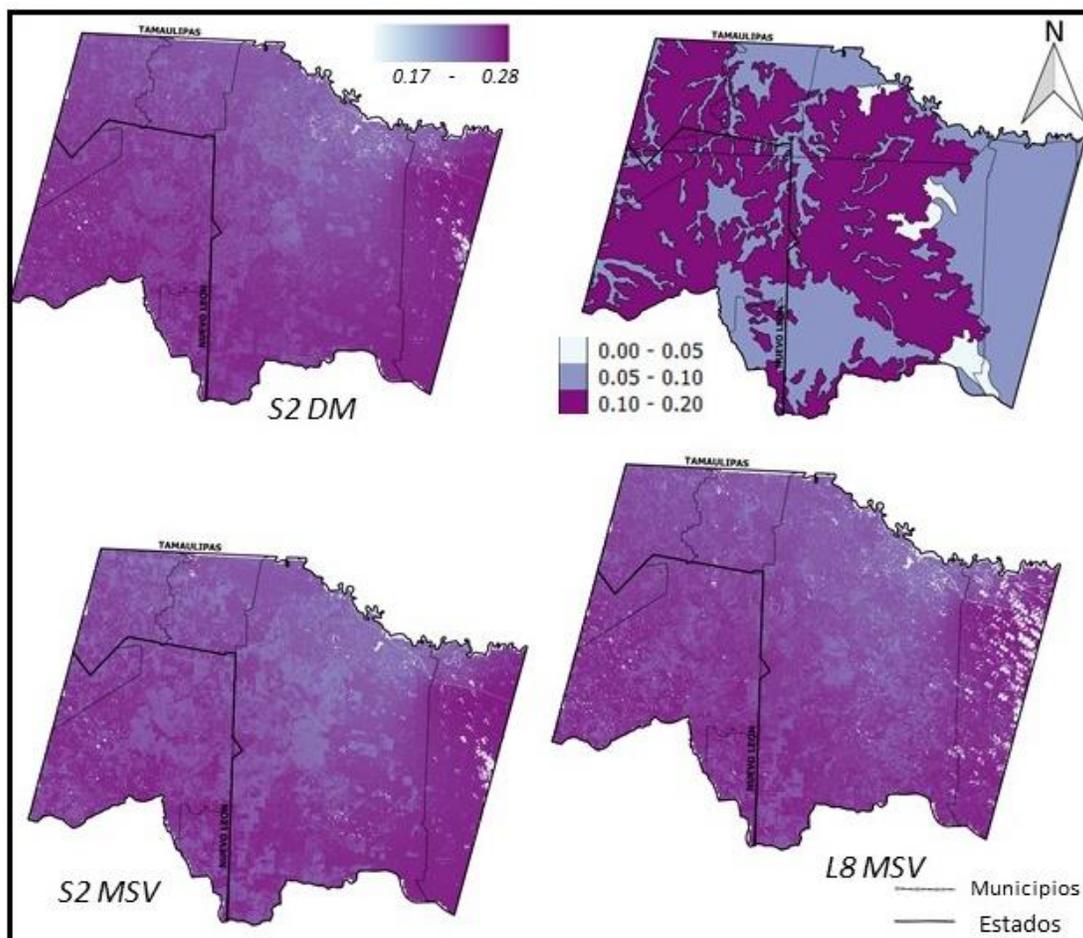


Figura 14. Coeficientes de escurrimiento determinados a partir de clasificaciones de cobertura terrestre de 3 de las combinaciones Sensor-Algorithmo con mayor acuerdo y comparación con la determinación de INEGI para el área de estudio de la Subregión del Bajo Bravo.

V.5.2. SUBREGIÓN DEL BAJO-GRIJALVA

La subregión hidrológica del BG presentó un mejor acuerdo con la imagen L8 y los clasificadores de MSV y MV, las coberturas terrestres de estos se muestran en la Figura 15 junto con la resultante de la aplicación del clasificador MSV en la imagen de S2 descargada para la región. La última imagen mencionada, aunque presentó un menor acuerdo global se incluye debido a la nula presencia de nubes. La principal diferencia entre las clasificaciones se encuentra en la cantidad y localización de las áreas de vegetación sumergida y las zonas inundadas. Otro problema visible en las clasificaciones es la confusión de áreas de agricultura con asentamientos humanos. Esto puede deberse a que probablemente se incluyó un área con una parte de tipo de cobertura de agricultura en las áreas que entrenan los asentamientos humanos, pues estas dos clases suelen estar adyacentes en estas áreas rurales del territorio y solo son claramente identificados en altas resoluciones espaciales.

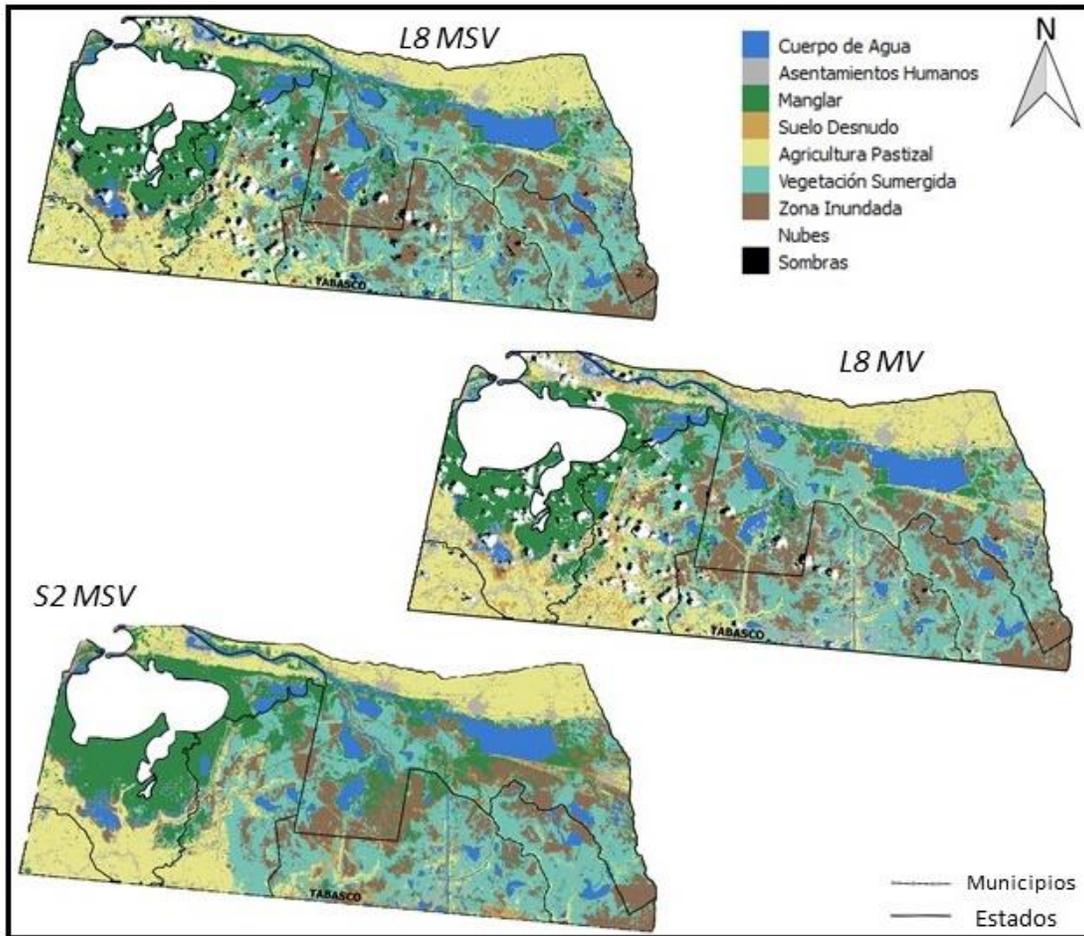


Figura 15. Clasificación de la cobertura terrestres de 3 de las combinaciones Sensor-Algorithmo con mayor acuerdo en el área de estudio de la Subregión Hidrológica del Bajo Grijalva.

La precipitación en esta cuenca es superior que la de otras regiones analizadas en el presente estudio, la menor es de alrededor de 1780 mm aumenta conforme aumentan las coordenadas al oeste de la región hasta llegar a casi 2000 mm de precipitación, de acuerdo con los datos proporcionados por INEGI. En esta región la textura de suelo dominante es fina, pero hay presencia de textura media en el sur y textura gruesa en el norte. La Figura 16 muestra la representación gráfica de la textura de suelo, precipitación y la constante K_v obtenida con la clasificación resultante de la combinación L8-SVM para BG que tiene valores desde 0 al 0.32 predominando valores bajos.

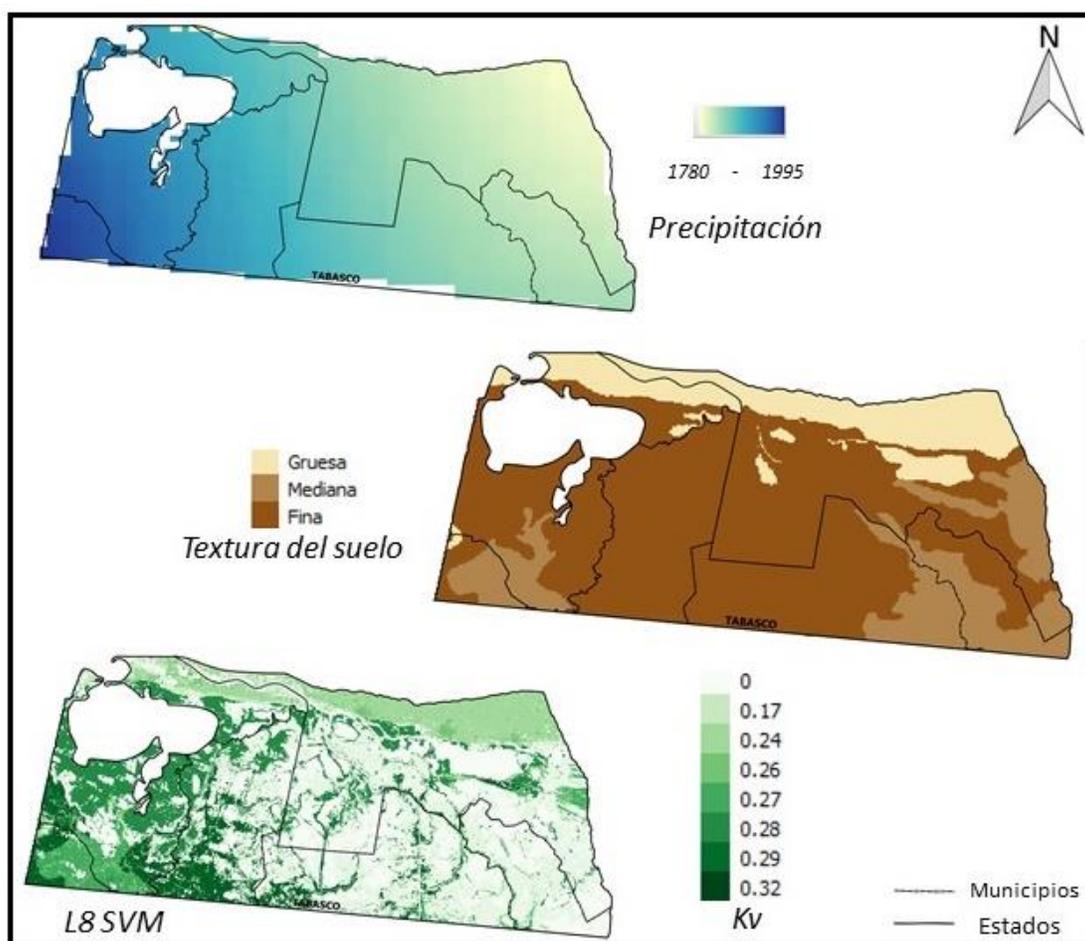


Figura 16. Información de entrada para la determinación del CE en el área de estudio de la Subregión Hidrológica del Bajo Grijalva.

El CE en esta zona de análisis resultó entre los valores de 0 a 1 con predominancia de valores superiores a 0.85. Estos valores son drásticamente diferentes a los proporcionados por la carta hidrológica de la zona que se limita a señalar valores superiores al 30% en un solo grupo. Espacialmente también se encuentra una diferencia visible pues los valores más altos para las tres clasificaciones se encuentran en el oeste de la cuenca mientras las proporcionadas por INEGI se encuentran en el centro del área. Las imágenes L8 nos permiten calcular un valor puntual de CE para un área de 30m² e incluso la RE puede aumentarse a 15m al aplicar procesos de fusión de imagen. Esta proporción supera enormemente la ofrecida por las cartas hidrológicas de INEGI. También puede aumentar a una determinación cada 10 m con la correcta combinación de un algoritmo de clasificación y las imágenes S2 que como se muestra en la Figura 17 no presentan una gran variación en el visual.

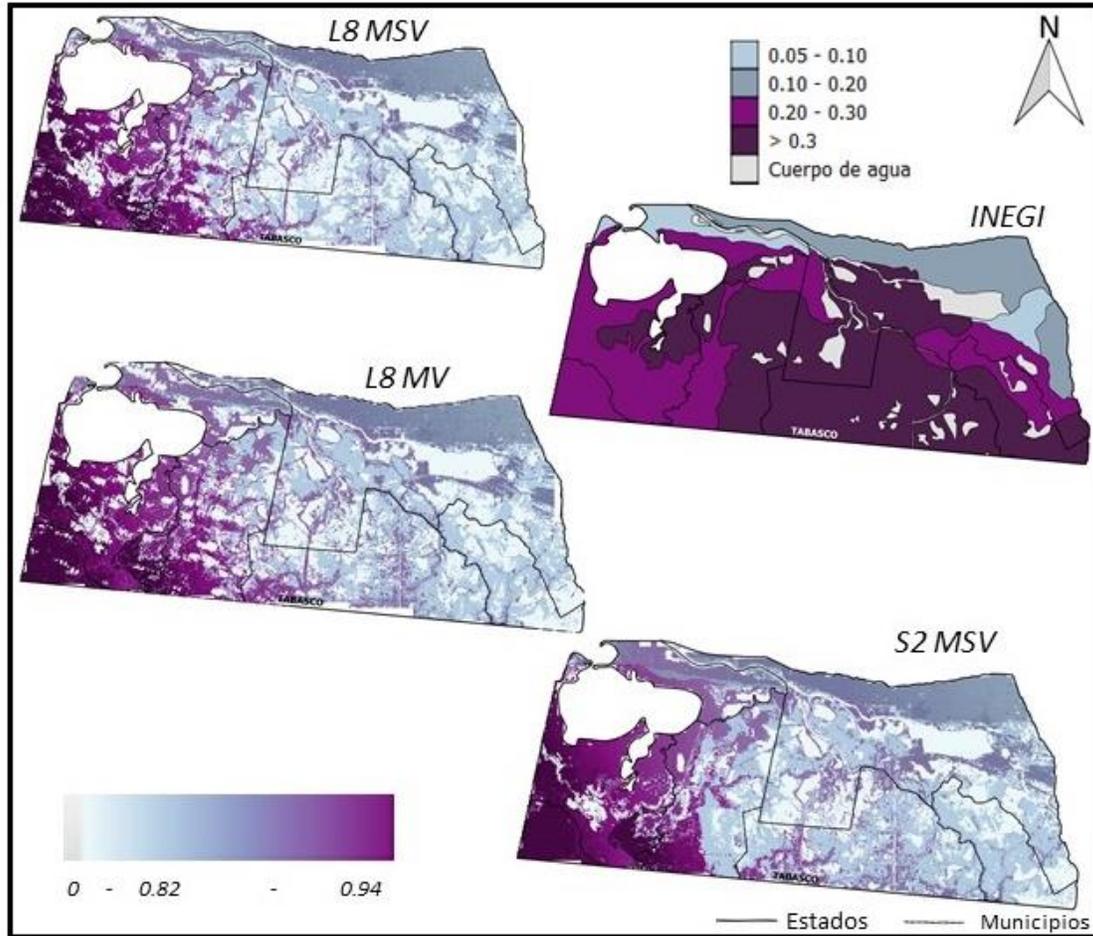


Figura 17. Coeficientes de escurrimiento determinados a partir de clasificaciones de cobertura terrestre de 3 de las combinaciones Sensor-Algoritmo con mayor acuerdo y comparación con la determinación de INEGI para el área de estudio de la subregión del Bajo Grijalva.



V.5.3. SUBREGIÓN DEL VALLE DE MÉXICO

Las combinaciones sensor-algoritmo que fueron seleccionadas son: L8 con MAE, DM y MSV. La Figura 18 muestra el resultado de la clasificación para las tres imágenes. La diferencia principal entre estas es la cantidad de vegetación que se logró percibir por cada una de las clasificaciones. Los resultados de la combinación L8- MAE lograron categorizar las áreas de vegetación con mayor acuerdo. Las tres imágenes clasificaron la nubosidad por igual. S2 con MSV tiende a confundir el suelo desnudo con áreas de asentamientos humanos.

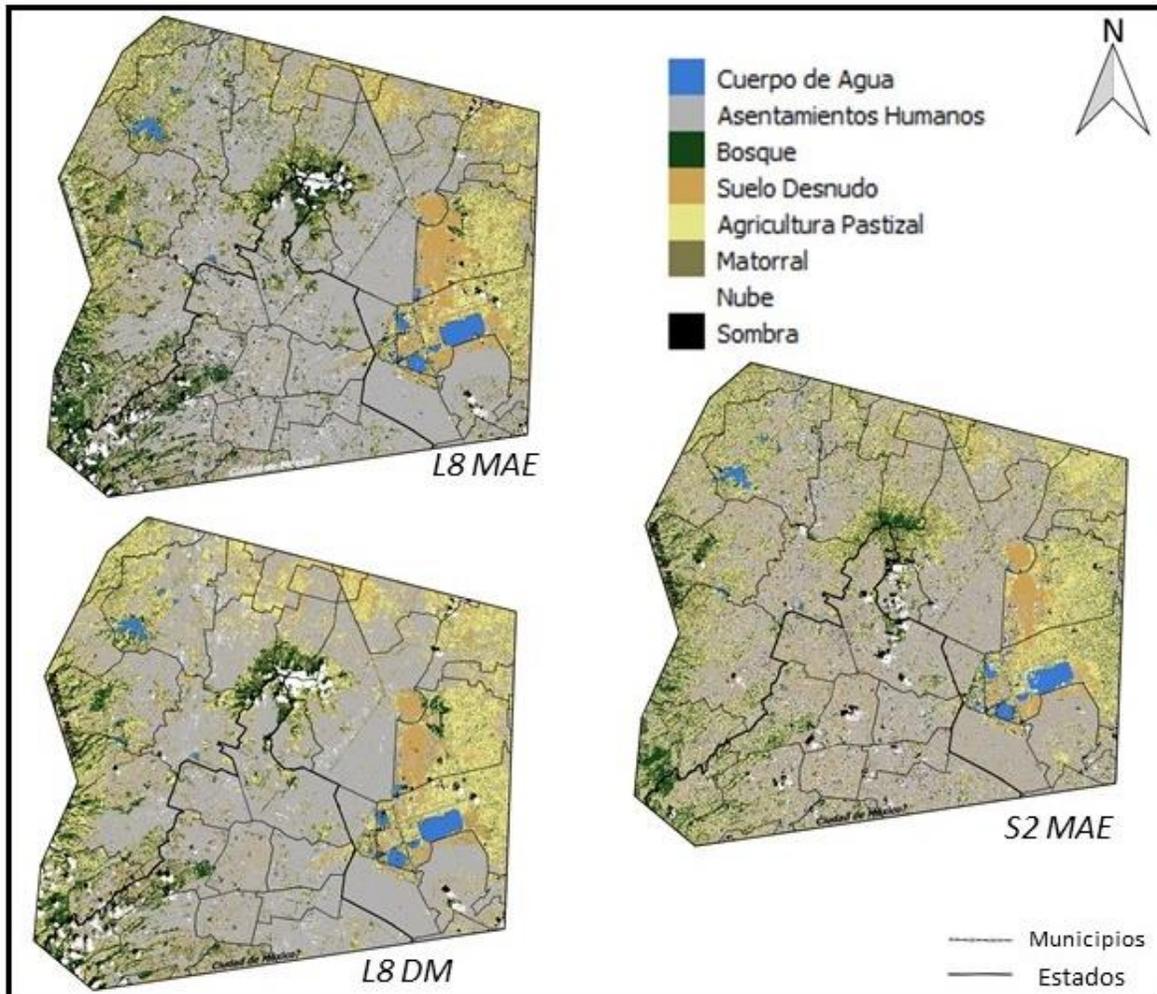


Figura 18. Clasificación de la cobertura terrestres de 3 de las combinaciones Sensor-Algoritmo con mayor acuerdo en el área de estudio de la Subregión Hidrológica del Valle de México.



De acuerdo con los datos de INEGI en esta región la textura de suelo dominante es la fina con presencia textura media en el centro y una menor parte de textura gruesa al noreste de la región. La precipitación en la cuenca del VM tiene un mínimo de alrededor de 570 mm y aumenta conforme aumentan las coordenadas hacia el oeste de la región hasta llegar a los 1190 mm de precipitación. Estos datos se utilizaron para los cálculos de CE de la cuenca VM. La Figura 19 muestra su representación gráfica. La constante K_v de la región va del 0 al 0.32 con valores predominantes superiores al 0.26, los resultados que se muestran en la Figura 19 son los provenientes de la clasificación de la imagen L8 con el algoritmo de MAE.

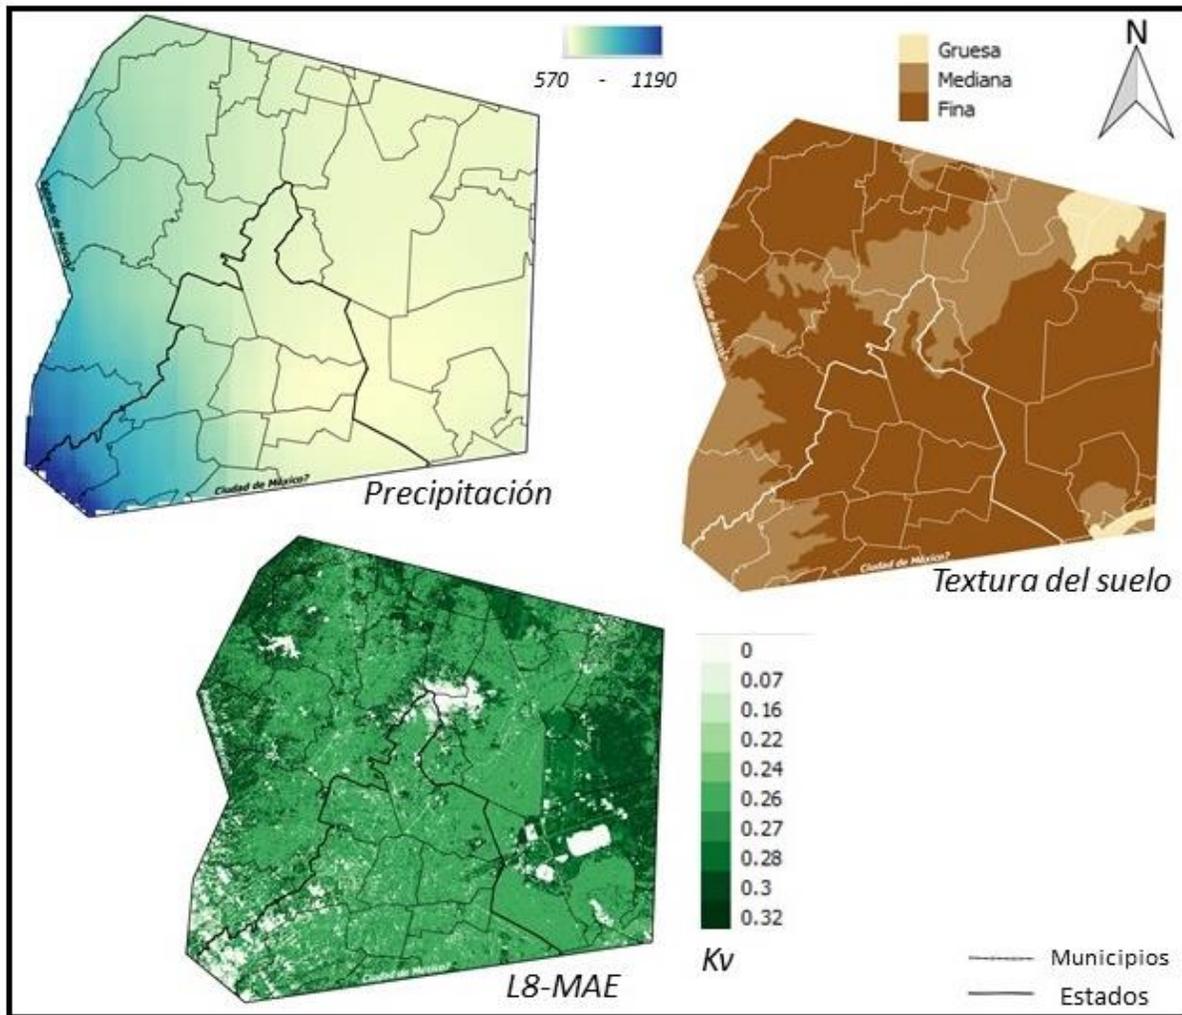


Figura 19. Información de entrada para la determinación del Coeficiente de escurrimiento en el área de estudio de la Subregión Hidrológica del Valle de México.



El CE en esta zona de análisis resultó entre 0.17 a 0.6 con predominancia entre los valores superiores de 0.24, estos valores son drásticamente diferentes a los proporcionados por la carta hidrológica de la zona. Espacialmente también se encuentra una diferencia visible pues los valores más altos para las tres clasificaciones se encuentran en el centro y sur de la cuenca mientras las proporcionadas por INEGI se encuentran en el centro del área (Figura 20). Esto puede ser debido a que en el cálculo propuesto en el presente trabajo se incluye la precipitación como una variable importante en el valor de CE pues al comparan visualmente los resultados de CE con el mapa de precipitación se puede ver una relación inmediata. Como se anotó anteriormente, las imágenes L8 nos permiten calcular un valor puntual de CE de hasta 15 m² del territorio, proporción que supera enormemente la ofrecida por las cartas hidrológicas de INEGI.

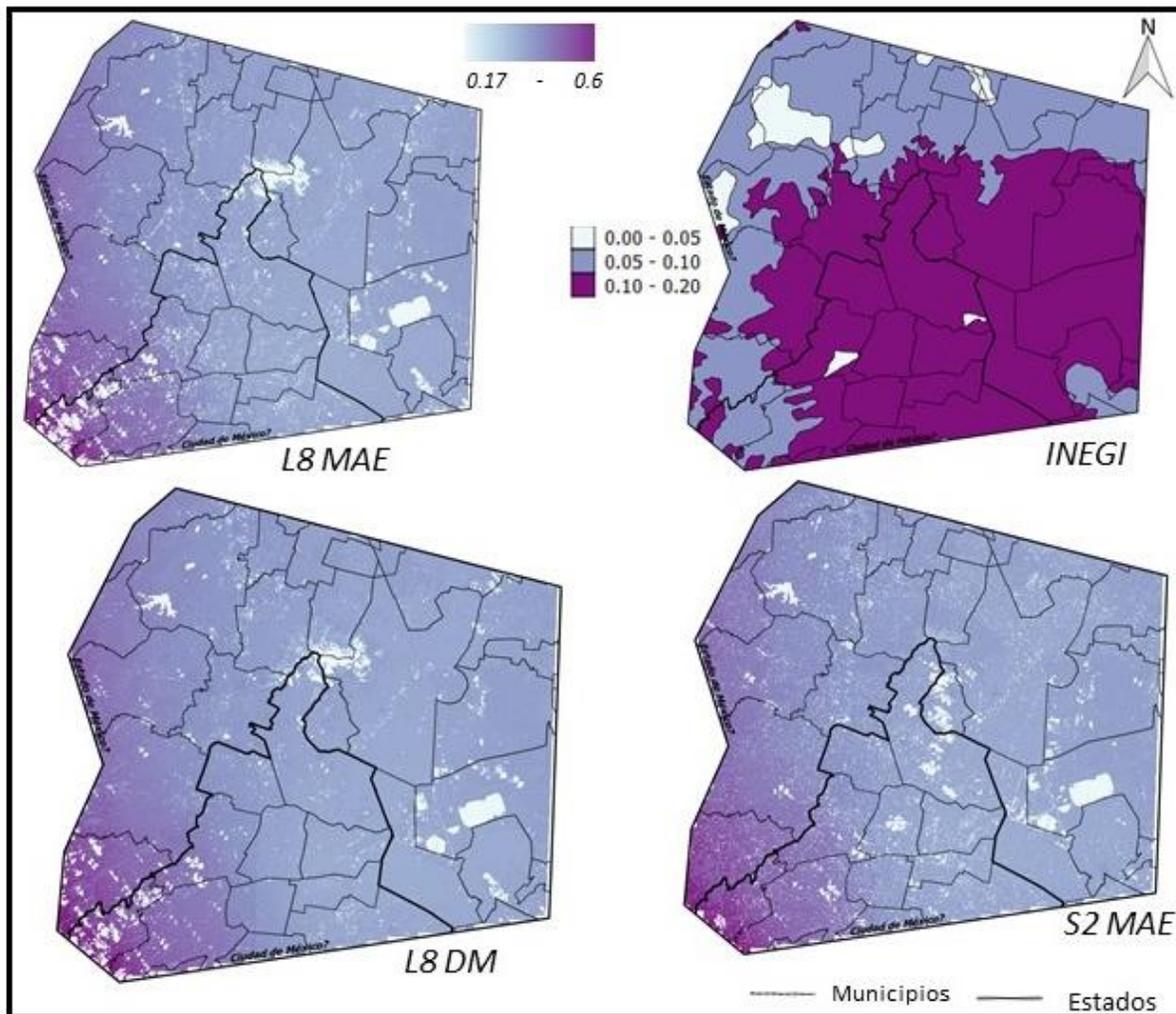


Figura 20. Coeficientes de escurrimiento determinados a partir de clasificaciones de cobertura terrestre de 3 de las combinaciones Sensor-Algoritmo con mayor acuerdo y comparación con la determinación de INEGI para el área de estudio de la Subregión del Valle de México.



VI. CONCLUSIONES

Como resultado del desarrollo de esta investigación se han evaluado las características necesarias en las imágenes satelitales de acceso abierto: L8, MD, S1 y S2 para su uso en la determinación de CE. Los sensores analizados presentan características que permiten obtener la cobertura terrestre necesaria para determinar el CE de áreas de estudio. Sin embargo, el uso de cada uno de ellos arroja resultados de acuerdo distintos y presenta características individuales que benefician o perjudican a las necesidades particulares de cada proyecto o región de estudio.

De manera general, el sensor L8 presentó el mayor acuerdo promedio global en la determinación de la cobertura terrestre seguido muy cercanamente por S2 dejando atrás a MD y por último a S1. En lo referente a los algoritmos probados, los resultados permiten recomendar que al determinar la cobertura terrestre con estos sensores se priorice el uso del algoritmo DM y MSV pero se evite el uso de MV pues este último resultó en acuerdos globales bajos, mientras MAE deberá de ser mejorado creando áreas de entrenamiento más mayor número de píxeles y mayor heterogeneidad en los valores de la reflectancia.

De forma individual los resultados dependen de las características de cada subregión. El área del BB presenta gran contraste de cobertura terrestre en áreas pequeñas por lo que se ve beneficiado por el uso de altas resoluciones espaciales. Es por esto que, los mejores acuerdos en esta cuenca se presentaron con los datos del S2 pues combina la mayor resolución espacial con un alto número de bandas espectrales. De acuerdo con los resultados en BB, S2 podrá combinarse con los algoritmos DM, MSV y MAE. Los algoritmos MSV y DM también presentaron resultados favorables en los sensores restantes, pero debe evitarse el algoritmo MV. Esta región presenta errores de comisión altos entre el mezquital xerófilo y el matorral espinoso, así como entre la agricultura y el suelo desnudo. Debido a la baja presencia de cuerpos de agua debe prestarse especial cuidado en la determinación de áreas de referencia que permitan entrenar correctamente al algoritmo que identificara dicha clase, favoreciendo la selección de áreas con mayor número de píxeles de comportamiento espectral homogéneo. En BB la cobertura terrestre dominante resultó ser la agricultura pastizal de la vegetación, los cuerpos de agua y los asentamientos humanos se encuentran en escasa presencia en la zona.

En la cuenca de BG, los sensores L8 y S2 obtuvieron acuerdos globales que superan al 80%. La combinación L8-MSV resultó en el mayor acuerdo. Los cuerpos de agua son muy importantes en esta región debido a su alta presencia en el sitio y la frecuente precipitación. El uso de la banda de azul profundo pareció indicar una mejoría en el acuerdo logrado en la determinación de cuerpos de agua, sin embargo, esto deberá ser estudiado a mayor detalle para eliminar la posibilidad de que dicha variación se deba a otros factores. Se recomienda el uso de S1 y MD en áreas con climas parecidos a esta cuenca para eliminar la nubosidad, deberá combinarse MD con MAE y S1 con DM además de aumentar el área de entrenamiento y aplicar técnicas post-procesamiento que permitan aumentar el acuerdo global. La vegetación sumergida, agricultura pastizal y la zona inundada resultaron ser los tipos de cobertura terrestre con mayor dominio mientras que el suelo desnudo y los asentamientos humanos tienen baja presencia.



La región de estudio del VM obtuvo acuerdos superiores al 70% con L8, S2 y MD, la mejor combinación resultó ser L8 con MAE y S2 mantiene las proporciones encontradas, pero no es así MD. Para mejorar la clasificación se recomienda aumentar las áreas de entrenamiento del suelo desnudo y matorral para disminuir el error de comisión entre ellas. Se debe evitar el uso del sensor S1 y el algoritmo MV.

Además del acuerdo logrado por cada combinación sensor-algoritmo, para la selección de la imagen deberán considerarse:

- La disponibilidad histórica de datos para la selección del sensor: MD y la serie Landsat para análisis históricos y S1 y S2 para análisis actuales.
- El periodo de tiempo del análisis para la selección de la resolución temporal: MD para análisis diarios, S2 para semanales y quincenales o superiores para los cuatro sensores.
- La escala del proyecto para elegir la resolución espacial: en proyectos regionales podrá utilizarse datos MD, en locales se recomienda el uso de L8, S1 y S2.
- El tipo de vegetación para seleccionar las bandas que se utilizaran. Aunque en el estudio los cuatro sensores mostraron capacidad para diferencia cuerpos de agua, vegetación, suelo desnudo y asentamientos humanos se recomienda realizar un el análisis de bandas para identificar las necesidades específicas del área de estudio.
- El clima para la selección de sensores tecnología óptica o radar. Las regiones con alta precipitación deberán seleccionar radares que al no ser sensibles a la nubosidad, permiten obtener más datos sin nubes que obstaculicen la medición.

Por otro lado, la determinación del CE por este método presenta la ventaja de obtener valores puntales hasta cada 10 m del territorio, esta escala es muy superior a la proporciona por la carta hidrológica de INEGI que agrupa regiones con valores de 0 a 5% y de 5 a 10%. Lo anterior permite realizar el análisis de escurrimiento en escalas locales. Además, los valores también muestran diferencias en magnitud y ubicación.

La pregunta "¿Qué características debe tener una ISA para la determinación de los coeficientes de escurrimiento considerando las diferentes características de la cuenca hidrológicas de estudio?" no arroja una respuesta directa en la selección de la imagen más conveniente, sino que se deben incluir una combinación de factores que influyen la selección como lo son: resolución espacial, la resolución espectral, resolución temporal, resolución radiométrica, periodo de estudio, el tipo de cobertura terrestre y su dinámica, el clima y el tamaño de la cuenca.



VII. BIBLIOGRAFÍA

1. Abdikan, S., Sanli, F. B., Ustuner, M., & Calò, F. (2016). LAND COVER MAPPING USING SENTINEL-1 SAR DATA. Paper presented at the, Xli-b7 757-761. <http://dx.doi.org/10.5194/isprs-archives-XLI-B7-757-2016>
2. Ardila León, J. F., & Quintero Delgado, O. Y. (2013). Aplicación de la teledetección y los sistemas de información geográfica en la interpretación de zonas inundables. Caso de estudio: río Soapaga, sector paz de río, Boyacá. *Ciencia e Ingeniería Neogranadina*, 23(2).
3. Baldridge, A. M., S.J. Hook, C.I. Grove and G. Rivera (2009). The ASTER Spectral Library Version 2.0. *Remote Sensing of Environment*, vol 113, pp. 711-715
4. Berlanga-Robles, César A., Arturo Ruiz-Luna, Hugo Orlando Covarrubias-Legaspi, Rafael Hernández-Guzmán (2011). Patrones de escurrimiento en la Cuenca Lechuguilla-Ohuira-Navachiste.
5. Bernal-Brooks, F. W., Rojas, A. G. T., & Alcocer, J. (2002). Lake Patzcuaro (Mexico): a controversy about the ecosystem water regime approached by field references, climatic variables, and GIS. In *Advances in Mexican Limnology: Basic and Applied Aspects* (pp. 187-197). Springer, Dordrecht.
6. Bhaduri, B., Harbor, J., Engel, B., Grove, M., (2000). Assessing watershed-scale, long-term hydrologic impacts of land use change using a GIS-NPS model: *Environmental Management* 26, 643-658.
7. Breña, A., & Jacobo, M. (2006). Principios y fundamentos de la hidrología superficial. Disponible en: [cortolima.gov.co/sites/default/files/images/stories/centro_documentos/estudios/cuenca_panel/as/DIAGNOSTICO/2.2 ASPECTOS_BIOFISICOS.pdf](http://cortolima.gov.co/sites/default/files/images/stories/centro_documentos/estudios/cuenca_panel/as/DIAGNOSTICO/2.2%20ASPECTOS_BIOFISICOS.pdf).
8. Broich, M., Hansen, M. C., Potapov, P., Adusei, B., Lindquist, E., & Stehman, S. V. (2011). International journal of applied earth observation and geoinformation: Time-series analysis of multi-resolution optical imagery for quantifying forest cover loss in sumatra and kalimantan, indonesia. *Borneo Research Bulletin*, 42, 361.
9. Bruzzone, L., & Prieto, D. F. (2001). Unsupervised retraining of a maximum likelihood classifier for the analysis of multitemporal remote sensing images. *IEEE Transactions on Geoscience and Remote Sensing*, 39(2), 456-460.
10. Carrillo-Rivera, J.; Maderey-Rascón, L. E.; (2005). El recurso agua en México: un análisis geográfico (Vol. 3). UNAM. 17-22.
11. Campbell, J. B., & Wynne, R. H. (2011). *Introduction to remote sensing*. Guilford Press.
12. CENAPRED Centro Nacional para la prevención del desastre, (2007). 'Grado de riesgo por inundaciones por municipio', escala: 1:1000000. edición: Primera. Centro Nacional de Prevención de Desastres. México.
13. Chatziantoniou, A., Psomiadis, E., & Petropoulos, G. P. (2017). Co-orbital sentinel 1 and 2 for LULC mapping with emphasis on wetlands in a mediterranean setting based on machine learning. *Remote Sensing*, 9(12), 1259. <http://dx.doi.org/10.3390/rs9121259>
14. Chen, J., Chen, J., Liao, A., Cao, X., Chen, L., Chen, X., ... & Zhang, W. (2015). Global land cover mapping at 30 m resolution: A POK-based operational approach. *ISPRS Journal of Photogrammetry and Remote Sensing*, 103, 7-27.



15. Chuvieco, E. (1991). Fundamentos de teledetección espacial. *Estudios Geográficos*, 52(203), 205-247, 371.
16. Cohen, J. (1960). A coefficient of agreement for nominal scales. *Educational and psychological measurement*, 20(1), 37-46.
17. CONAGUA Comisión Nacional del AGUA, (2015). Atlas de Agua en México. Secretaría de Medio Ambiente y Recursos Naturales, México. 2015 Pp. 45.
18. CONAGUA Comisión Nacional del AGUA, (2014). Programa Nacional Hídrico 2014-2018. Secretaría de Medio Ambiente y Recursos Naturales, México. 2014 Pp. 26,
19. CONAGUA Comisión Nacional del Agua (2007). 'Subregiones Hidrológicas, escala 1:250 000. República Mexicana' en formato vectorial. Subdirección General Técnica (2007). México, D.F.
20. CONSTITUCIÓN POLÍTICA MEXICANA [CONST], 2016. Constitución Política de los Estados Unidos Mexicanos. Artículo 4.
21. CNES Centro Nacional del Espacio, 2018. The ORFEO Tool Box Software Guide Updated for OTB-6.4.0. OTB Development Team. Francia.
22. Congalton, R. G., & Green, K. (2008). Assessing the accuracy of remotely sensed data: principles and practices. CRC press. Pp. 70
23. Congedo, L. (2016). Semi-automatic classification plugin documentation. Release, 4(0.1), 29.
24. Cotler, H., Garrido Arturo, Bunge Verónica, & Cuevas, M. L. (2010). Las cuencas hidrográficas de México: Priorización y toma de decisiones. *Las cuencas hidrográficas de México: diagnóstico y priorización*, 321.
25. Cuervo-Robayo, A. P., Téllez-Valdés, O., Gómez-Albores, M. A., Venegas-Barrera, C. S., Manjarrez, J., Martínez-Meyer, E., (2014). 'Precipitación anual en México (1910-2009)', datos vectoriales escala: 1:1000000. modificado por CONABIO (2015). México, D. F.
26. DOF. 2015. Diario Oficial de la Federación. Norma Oficial Mexicana NOM-011-CONAGUA-2015. Conservación del recurso agua - Que establece las especificaciones y el método para la determinar la disponibilidad media anual de las aguas nacionales. 27 de marzo del 2015.
27. Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., ... & Meygret, A. (2012). Sentinel-2: ESA's optical high-resolution mission for GMES operational services. *Remote sensing of Environment*, 120, 25-36.
28. Eastman, J. R. (2003). IDRISI Kilimanjaro: guide to GIS and image processing.
29. ¹ESA European Space Agency (2013). Sentinel-1 User Handbook. Sentinel User Handbook and Exploitation Tools. European Commission.
30. ²ESA European Space Agency (2013). Sentinel-2 User Handbook. Sentinel User Handbook and Exploitation Tools. European Commission.
31. Estoque, R. C., Pontius, R. G., Murayama, Y., Hou, H., Thapa, R. B., Lasco, R. D., & Villar, M. A. (2018). Simultaneous comparison and assessment of eight remotely sensed maps of Philippine forests. *International Journal of Applied Earth Observation and Geoinformation*, 67, 123-134.
32. Fernández García, F. (2000). Introducción a la fotointerpretación. Ariel. Madrid, España.
33. Fennessey, L. A. J., & Hawkins, R. H. (2001, October). The NRCS curve number, a new look at an old tool. In Proc. of Pennsylvania Stormwater Management Symp., Villanova Uni.



34. Frey, K.E., Smith, L.C., 2007. How well do we know northern land cover? Comparison of four global vegetation and wetland products with a new ground-truth database for West Siberia. *Global Biogeochem. Cycles* 21, GB1016.
35. Friedl, M. A., Sulla-Menashe, D., Tan, B., Schneider, A., Ramankutty, N., Sibley, A., & Huang, X. (2010). MD collection 5 global land cover: Algorithm refinements and characterization of new datasets. *Remote Sensing of Environment*, 114(1), 168-182. 10.1016/j.rse.2009.08.016.
36. Fritz, S., See, L., Rembold, F., 2010. Comparison of global and regional land cover maps with statistical information for the agricultural domain in Africa. *Int. J. Remote Sens.* 31, 2237–2256.
37. García, E. - Comisión Nacional para el Conocimiento y Uso de la Biodiversidad (CONABIO), (1998). 'Climas' (clasificación de Koppen, modificado por García). Escala 1:1000000. México. 11-05-2001. Climas Formato de representación geográfica Shapefile. Formato vectorial compuesto por 4 archivos (shp, shx, dbf, prj). Escala 1:1000000.
38. Giannetti, F., Barbati, A., Mancini, L. D., Travaglini, D., Bastrup-Birk, A., Canullo, R., . . . Chirici, G. (2018). European forest types: Toward an automated classification. *Annals of Forest Science*, 75(1), 1-14. 10.1007/s13595-017-0674-6
39. Gomarazca, (2010) M.A. Basis of Geomatics. *Applied Geomatics*. Vol. 2, pp. 137-146.
40. Gómez, C., White, J. C., & Wulder, M. A. (2016). Optical remotely sensed time series data for land cover classification: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 116, 55-72. [doi:10.1016/j.isprsjprs.2016.03.008](https://doi.org/10.1016/j.isprsjprs.2016.03.008)
41. Goldewijk, K.K., 2001. Estimating global land use change over the past 300 years: the HYDE database. *Global Biogeochem. Cycles* 15 (2), 417–433.
42. Grizonnet, M., Michel, J., Poughon, V., Inglada, J., Savinaud, M., & Cresson, R. (2017). Orfeo ToolBox: open source processing of remote sensing images. *Open Geospatial Data, Software and Standards*, 2(1), 15.
43. Harbor, J., (1994), A practical method for estimating the impact of land use change on surface runoff, groundwater recharge and wetland hydrology: *Journal of the American Planning Association*, 60, 95–108.
44. Herold, J. S. Latham, A. Di Gregorio & C. C. Schmullius (2006) Evolving standards in land cover characterization, *Journal of Land Use Science*, 1:2-4, 157-168, DOI: 10.1080/17474230601079316
45. Huang, B., Huang, J., Pontius, R. G., & Tu, Z. (2018). Comparison of Intensity Analysis and the land use dynamic degrees to measure land changes outside versus inside the coastal zone of Longhai, China. *Ecological Indicators*, 89, 336-347.
46. INEGI Instituto Nacional de Estadística, & Informática. (2007). Sistema para la Consulta del Cuaderno Estadístico de la Zona Metropolitana del Valle de México, Edición 2007.
47. INEGI Instituto Nacional de Estadística, & Informática. (2009). Censos económicos 2009. Censos Económicos 2009.
48. ¹INEGI Instituto Nacional de Estadística, & Informática (2010). Cartas hidrográficas de México, datos vectoriales escala: 1:250 000. 2ª edición. Instituto Nacional de Estadística y Geografía. México.
49. ²INEGI Instituto Nacional de Estadística, & Informática. (2010). Censo de población y vivienda 2010: Resultados definitivos.



50. INEGI Instituto Nacional de Estadística, & Informática. (2013). 'Conjunto de datos vectoriales de uso de suelo y vegetación escala 1:250 000, serie V (capa unión)', escala: 1:250000. edición: 2a. Instituto Nacional de Estadística y Geografía. Aguascalientes.
51. INEGI, 2015. Encuesta Intercensal (2015). edición: 2a. Instituto Nacional de Estadística y Geografía. Aguascalientes, Aguascalientes.
52. INIFAP Instituto Nacional de investigaciones Forestales y Agropecuarias (1995). Edafología, tipos, suelos, aspecto, físico escala 1:1000000 formato vectorial compuesto. CONABIO Comisión Nacional para el Conocimiento y Uso de la Biodiversidad. Mexico.
53. Jain, A. K., Duin, R. P. W., & Mao, J. (2000). Statistical pattern recognition: A review. *IEEE Transactions on pattern analysis and machine intelligence*, 22(1), 4-37.
54. Jia, K., Liang, S., Zhang, N., Wei, X., Gu, X., Zhao, X., ... & Xie, X. (2014). Land cover classification of finer resolution remote sensing data integrating temporal features from time series coarser resolution data. *ISPRS Journal of photogrammetry and remote sensing*, 93, 49-55.
55. Jiménez R., A. & Maderey R., L. E. (1992). 'Ecurrimiento medio anual'. En: Hidrogeografía IV.6.4. Atlas Nacional de México. Vol. II, Escala 1:4000000. Instituto de Geografía, UNAM. México.
56. Joseph, G. (2005). *Fundamentals of remote sensing*. Universities press. Pp.7, 344.
57. Khorram, S., Koch, F. H., Nelson, S. A. C., & Wiele, Cynthia F. van der. (2012). *Remote sensing* (1. Aufl.;2012; ed.). DE: Springer-Verlag. doi:10.1007/978-1-4614-3103-9
58. Kruse, F. A., Lefkoff, A. B., Boardman, J. W., Heidebrecht, K. B., Shapiro, A. T., Barloon, P. J., & Goetz, A. F. H. (1993). The spectral image processing system (SIPS)—interactive visualization and analysis of imaging spectrometer data. *Remote sensing of environment*, 44(2-3), 145-163.
59. Kurczyn-Robledo, J. A., Kretzschmar, T., & Hinojosa-Corona, A. (2007). Evaluación del escurrimiento superficial en el noreste del Valle de Guadalupe, BC, México, usando el método de curvas numeradas y datos de satélite. *Revista mexicana de ciencias geológicas*, 24(1), 1-14
60. Lanza Espino, Guadalupe de la, & Gómez Rodríguez, Gabriela. (2005). Analysis of the short term geo-environmental evolution of an endorreic basin using satellite images: the case of Tecocomulco Lagoon, Mexico. *Investigaciones geográficas*, (58), 66-79. Recuperado en 20 de marzo de 2018, de http://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S0188-46112005000300005&lng=es&tlng=en.
61. Lehmann, E.A., Wallace, J.F., Caccetta, P.A., Furby, S.L., Zdunic, K., 2013. Forest cover trends from time series Landsat data for the Australian continent. *Int. J. Appl. Earth Observation Geoinformation* 21, 453–462.
62. Loperfido, J. V., Noe, G. B., Jarnagin, S. T., & Hogan, D. M. (2014). Effects of distributed and centralized stormwater best management practices and land cover on urban stream hydrology at the catchment scale. *Journal of Hydrology*, 519, 2584-2595.
63. Lei, G., Li, A., Bian, J., Zhang, Z., Jin, H., Nan, X., Feng, W. (2016). Land cover mapping in southwestern china using the HC-MMK approach. *Remote Sensing*, 8(4), 305.
64. Liu, M., & Tian, H. (2010). China's land cover and land use change from 1700 to 2005: Estimations from high-resolution satellite data and historical archives. *Global Biogeochemical Cycles*, 24(3).
65. Ma, Y., (2004), L-THIA: A useful hydrologic impact assessment model: *Nature and Science*, 2, 68–73.



66. Maderey Laura E., (1990). 'Evapotranspiración real' en Hidrogeografía IV.6.6. Atlas Nacional de México. Vol. II Datos vectoriales Escala 1:400 0000. Instituto de Geografía UNAM. México.
67. Mahmoud, S. H., Mohammad, F. S., & Alazba, A. A. (2014). Determination of potential runoff coefficient for Al-Baha region, Saudi Arabia using GIS. *Arabian Journal of Geosciences*, 7(5), 2041-2057. doi:10.1007/s12517-014-1303-4
68. Manning, C. D., Raghavan, P., & Schütze, H. (2008). Introduction to information retrieval (Vol. 1, No. 1, p. 496). Cambridge: Cambridge university press.
69. Malenovský, Z., Rott, H., Cihlar, J., Schaepman, M. E., García-Santos, G., Fernandes, R., & Berger, M. (2012). Sentinels for science: Potential of Sentinel-1, -2, and -3 missions for scientific observations of ocean, cryosphere, and land. *Remote Sensing of Environment*, 120, 91-101.
70. Martínez-Muñoz, J.; Díaz-Ponce, A. (2005) PEREPCIÓN REMOTA: Fundamentos de Teledetección Espacial. Comisión Nacional del Agua Pp.8 DOI: <http://siga.cna.gob.mx/SIGA/Percepcion/Fundamentos%20de%20teledetecci%C3%B3n%20espacial.PDF>
71. Mendoza, M., Bocco, G., & Bravo, M. (2002). Spatial prediction in hydrology: status and implications in the estimation of hydrological processes for applied research. *Progress in Physical Geography*, 26(3), 319-338.
72. Merz, R., Blöschl, G., & Parajka, J. (2006). Spatio-temporal variability of event runoff coefficients. *Journal of Hydrology*, 331(3), 591-604. doi:10.1016/j.jhydrol.2006.06.008
73. Mommer, L., Visser, E.J.W. 2005. Underwater photosynthesis in flooded terrestrial plants: a matter of leaf plasticity. *Annals of Botany* 96:581-589.
74. Mountrakis, G., Im, J., & Ogole, C. (2011). Support vector machines in remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(3), 247-259.
75. Müller, H., Rufin, Ph., Griffiths, P., Barros Siqueira, A.J., Hostert, P., 2014. Mining dense Landsat time series for separating cropland and pasture in a heterogeneous Brazilian savanna landscape. *Remote Sens. Environ.* 156, 490–499.
76. Natural Resources (2016). Fundamental of remote sensing: A Canada Centre for Remote Sensing Remote Sensing Tutorial. Canada Centre for Remote Sensing.
77. Nutchant Sriwongsitanon, Wisuwat Taesombat, (2011). Effects of land cover on runoff coefficient. *Journal of Hydrology* 410 (2011) 226–238.
78. Olofsson, P., Foody, G. M., Herold, M., Stehman, S. V., Woodcock, C. E., & Wulder, M. A. (2014). Good practices for estimating area and assessing accuracy of land change. *Remote Sensing of Environment*, 148, 42-57. 10.1016/j.rse.2014.02.015
79. Organización Meteorológica Mundial (2007). Recuperado el 15 de Mayo del 2017. DOI: <http://www.wmo.int/pages/prog/www/OSY/GOS.html>
80. Peña, M. A., & Brenning, A. (2015). Assessing fruit-tree crop classification from landsat-8 times series for the maipo valley, Chile. *Remote Sensing of Environment*, 171, 234-244. 10.1016/j.rse.2015.10.029.
81. Pontius, R. G., Gao, Y., Giner, N. M., Kohyama, T., Osaki, M., & Hirose, K. (2013). Design and interpretation of intensity analysis illustrated by land change in Central Kalimantan, Indonesia. *Land*, 2(3), 351-369.
82. Pontius Jr, R. G., & Millones, M. (2011). Death to Kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment. *International Journal of Remote Sensing*, 32(15), 4407-4429.



83. Pontius Jr, R. G., & Santacruz, A. (2014). Quantity, exchange, and shift components of difference in a square contingency table. *International Journal of Remote Sensing*, 35(21), 7543-7554.
84. Ravi Shankar, D. (2017). *Remote sensing of soils*. Berlin, Heidelberg: Springer.
85. Richards, J. A. and Jia, X., (2006). *Remote Sensing Digital Image Analysis: An Introduction*. Berlin, Germany: Springer.
86. Richards, J. A. (2014). *Remote sensing with imaging radar (1. Aufl. ed.)*. Berlin, Heidelberg: Springer-Verlag.10.1007/978-3-642-02020-9.
87. Rogan, J., Chen, D.M., (2004). Remote Sensing technology for mapping and monitoring land cover and land-use change. *Prog. Plan.* 61, 301–325.
88. Rußwurm, M., & Körner, M. (2017). MULTI-TEMPORAL LAND COVER CLASSIFICATION WITH LONG SHORT-TERM MEMORY NEURAL NETWORKS. Paper presented at the , Xlii-1/w1 551-558. <http://dx.doi.org/10.5194/isprs-archives-XLII-1-W1-551-2017>
89. Sabins, F. F. (2007). *Remote sensing: principles and applications*. Waveland Press. Pp. 3.
90. Savenije, H.H.G. (1996). The runoff coefficient as the key to moisture recycling. *Hydrogeol. J.* 176 (1–4), 219–22.
91. Schmutge, T. J., Kustas, W. P., Ritchie, J. C., Jackson, T. J., & Rango, A. (2002). Remote sensing in hydrology. *Advances in water resources*, 25(8-12), 1367-1385.
92. Schowengerdt, R. A. (2006). *Remote sensing: models and methods for image processing*. Academic press. Pp- 8-10, 28-33.
93. Senf, C., Leitão, P.J., Pflugmacher, D., van der Linden, S., Hostert, P. (2015). Mapping land cover in complex Mediterranean landscapes using Landsat: improved classification accuracies from integrating multi-seasonal and synthetic imagery. *Remote Sens. Environ.* 156, 527–536. .
94. Sherman, L. K. (1932). Streamflow from rainfall by the unit-graph method. *Eng. News Record*, 108, 501-505.
95. Sivapalan, M., Bloßschl, G., Merz, R., Gutknecht, D., (2005). Linking flood frequency to long-term water balance: incorporating effects of seasonality. *Water Resources*. 41:1-17
96. Sokolov, A. A., & Chapman, T. (1981). *Métodos de cálculo del balance hídrico. Guía internacional de métodos de investigación (versión en español)*. Instituto de Hidrología de España-UNESCO.
97. Solís, A.Y., González, R.D., Lafragua, C.J., Gutiérrez-López, L.A., Bahena, H.A., Santos, S.J.F., Alfaro, M., Brindis P.J.G., (2005). Estudio de Actualización de la Disponibilidad y Balance Hidráulico de Aguas Superficiales de la Región Hidrológica No. 12, Cuencas Cerradas de Sayula y Región Hidrológica No. 15, Costa de Jalisco, Considerando las Concesiones del REPDA. Instituto Mexicano de Tecnología del Agua y Comisión Nacional del Agua (IMTA- CONAGUA), México.
98. Song, C., Woodcock, C. E., Seto, K. C., Lenney, M. P., & Macomber, S. A. (2001). Classification and change detection using Landsat TM data: when and how to correct atmospheric effects?. *Remote sensing of Environment*, 75(2), 230-244.
99. Song, S., Schmidt, K. S., Pilewskie, P., King, M. D., Heidinger, A. K., Walther, A., ... & Coddington, O. M. (2016). The spectral signature of cloud spatial structure in shortwave irradiance. *Atmospheric chemistry and physics*, 16(21), 13791.



100. Sudhakar, S., Sridevi, G., Ramana, I. V., Rao, V. V., & Raha, A. K. (1999). Techniques of classification for landuse/landcover with special reference to forest type mapping in jaldapara wildlife sanctuary, jalpaiguri district, west Bengal—a case study. *Journal of the Indian Society of Remote Sensing*, 27(4), 217-224. 10.1007/BF02990834
101. Symeonakis, E., Calvo-Cases, A, Arnau-Rosalen, E., (2007), Land use change and land degradation in Southeastern Mediterranean Spain: *Environmental Management*, 40, 80–94.
102. Tapia-Silva, F.O. (2011) Geomática y sociedad, ciencia emergente para generar conocimiento hacia la resolución de la problemática socioambiental. *Geopuce. Revista de la Escuela de Ciencias Geográficas Puce, Quito, Ecuador. Vol. 2, pp. 7-16.*
103. Tapia-Silva, F. O. (2014). Avances en geomática para la resolución de la problemática del agua en México. *Tecnología y Ciencias Del Agua*, 5(2), 131.
104. Tapia-Silva, F.O., Jaimes-Contreras,P., Freire-Cuesta Tamara. (2015). "Modelado Geoespacial Conceptual para definición del Potencial de Captación de Agua de Lluvia en una Megalopolis en crisis." *Latin America Geospatial Forum. Youth Geospatial Fórum. México DF. 10-12 Noviembre 2015.*
105. Tchuenté, A. T. K., Roujean, J. L., & De Jong, S. M. (2011). Comparison and relative quality assessment of the GLC2000, GLOBCOVER, MODIS and ECOCLIMAP land cover data sets at the African continental scale. *International Journal of Applied Earth Observation and Geoinformation*, 13(2), 207-219.
106. Tempfli, K., Kerle, N, Huurneman, G. Janssen, Lucas. (2009) *Principles of remote Sensing: An introductory textbook. International Institute for Geo-Information Science and Earth Observation. The Netherlands. Pp. 41.*
107. Theodoridis, S., & Koutroubas, K. (2008). Pattern recognition. *IEEE Transactions on Neural Networks*, 19(2), 376. Elsevier. USA. Pp. 77.
108. Tran, T. V., Julian, J. P., & Beurs, K. M. d. (2014). Land cover heterogeneity effects on sub-pixel and per-pixel classifications. *ISPRS International Journal of Geo-Information*, 3(2), 540-553. <http://dx.doi.org/10.3390/ijgi3020540>.
109. Treviño, G.E., Muñoz, R.C.A., Cavazos, C.C., Barajas, C.L., (2002). Evaluación del flujo hídrico superficial en la Sierra de San Carlos, Tamaulipas: *Ciencia UANL*, 5, 525–530.
110. USGS Department of the Interior U.S. Geological Survey (2016) *LANDSAT 8 (L8) DATA USERS HANDBOOK. Version 2.0 Earth Aeronautics and Science.*
111. Vanjare, A., Omkar, S. N., & Senthilnath, J. (2014). Satellite image processing for land use and land cover mapping. *International Journal of Image, Graphics and Signal Processing*, 6(10), 18-28. <http://dx.doi.org/10.5815/ijigsp.2014.10.03>
112. Veci, Luis (2016). Sentinel-1 Tool-box. SAR Basic Tutorial. Science toolbox exploitation platform. Array Systems Computing Inc. Europe special agency.
113. Vermote E., S. Y. iKotchenova and J. P. Ray. (2011). MODIS Land Surface Reflectance Science Computing Facility. Version 1.3. Land Surface Reflectance Science Computing Facility
114. Villón-Bejar, Máximo (2002). Hidrología. Instituto tecnológico de Costa Rica. Segunda Edición. Editorial Villón. Pp-135-143
115. Wacker, A. G., & Landgrebe, D. A. (1972). Minimum distance classification in remote sensing. *LARS Technical Reports*, 25, 365.



116. Webster Gumindoga, Tom Rientjes, Munyaradzi Davis Shekede, Donald Tendayi Rwasoka, Innocent Nhapi and Alemseged Tamiru Haile, (2014). Hydrological Impacts of Urbanization of Two Catchments in Harare, Zimbabwe. *Remote sensing*. Vol. 6, Pp. 12544-12574.
117. Woodward, D. E., Hawkins, R. H., Hjelmfelt, A. T., Van Mullem, J. A., & Quan, Q. D. (2002). Curve number method: Origins, applications and limitations. In US Geological Survey Advisory Committee on Water Information—Second Federal Interagency Hydrologic Modeling Conference. July.
118. Xu, J. B., Song, L. S., Zhao, Z. Z., & Zhao, K. (2013). Remote sensing image classification based on a modified self-organizing neural network with a priori knowledge. *Sensors & Transducers*, 153(6), 29.
119. Yan, M., Wang, Z., Kaplan, J. O., Liu, J., Min, S., & Wang, S. (2013). Comparison between reconstructions of global anthropogenic land cover change over past two millennia. *Chinese geographical science*, 23(2), 131-146.
120. Yu, X., Zhang, A., Hou, X., Li, M., & Xia, Y. (2012;2013;). Multi-temporal remote sensing of land cover change and urban sprawl in the coastal city of yantai, china. *International Journal of Digital Earth*, 6(sup2), 1-18. 10.1080/17538947.2011.653995
121. Zhan, X., & Huang, M. L. (2004). ArcCN-Runoff: an ArcGIS tool for generating curve number and runoff maps. *Environmental Modelling & Software*, 19(10), 875-879.
122. Zhang, Z., Chen, X., Huang, Y., & Zhang, Y. (2014). Effect of catchment properties on runoff coefficient in a karst area of southwest china: EFFECT OF CATCHMENT PROPERTIES ON RUNOFF COEFFICIENT. *Hydrological Processes*, 28(11), 3691-3702. doi:10.1002/hyp.9920
123. Zhou, P., Huang, J., Pontius, J., Robert Gilmore, & Hong, H. (2014). Land classification and change intensity analysis in a coastal watershed of southeast china. *Sensors (Basel, Switzerland)*, 14(7), 11640-11658. 10.3390/s140711640
124. Zhou, Y., Zhang, Y., Vaze, J., Lane, P., & Xu, S. (2013). Improving runoff estimates using remote sensing vegetation data for bushfire impacted catchments. *Agricultural and Forest Meteorology*, 182-183, 332-341. doi:10.1016/j.agrformet.2013.04.018.
125. Zuhlke, M., Fomferra, N., Brockmann, C., Peters, M., Veci, L., Malik, J., & Regner, P. (2015). SNAP (Sentinel Application Platform) and the ESA Sentinel 3 Toolbox. In *Sentinel-3 for Science Workshop (Vol. 734, p. 21)*.



ANEXO 1



CONTENIDO

<u>A. CORRECCIÓN DE IMÁGENES RADAR SENTINE-1 CON LA PLATAFORMA SNAP-ESA</u>	3
<u>B. PASOS PARA CLASIFICACION CON EL SEMIAUTOMATIC CLASIFICAION PLUG IN DE QGIS UTILIZANDO EL ALGORITMO DE DISTANCIA MÍNIMA O MAPEO DEL ANGULO ESPECTRAL</u>	16
<u>C. PROCEDIMIENTO PARA LA DETERMINACIÓN DE LA COBERTURA TERRESTRE UTILIZANDO LA HERRAMIENTA DE ORFEO PARA QGIS UTILIZANDO EL ALGORITMO DE MAQUINAS DE SOPORTE VECTORIAL</u>	26
<u>D. PROCEDIMIENTO PARA LA DETERMINACIÓN DE LA COBERTURA TERRESTRE UTILIZANDO EL ALGORITMO DE MAXIMA VEROSIMILITUD CON EL PRORMA GRASS GIS</u>	31
<u>E. PROCEDIMIENTO PARA OBTENER LAS ESTADÍSTICAS DE UN RASTER UTILIZANDO LA CAJA DE HERAMIENTAS DE PROCESOS DE GRAS GISS DENTRO DEL PROGRAMA QGIS</u>	431



A. CORRECCIÓN DE IMÁGENES RADAR SENTINE-1 CON LA PLATAFORMA SNAP-ESA

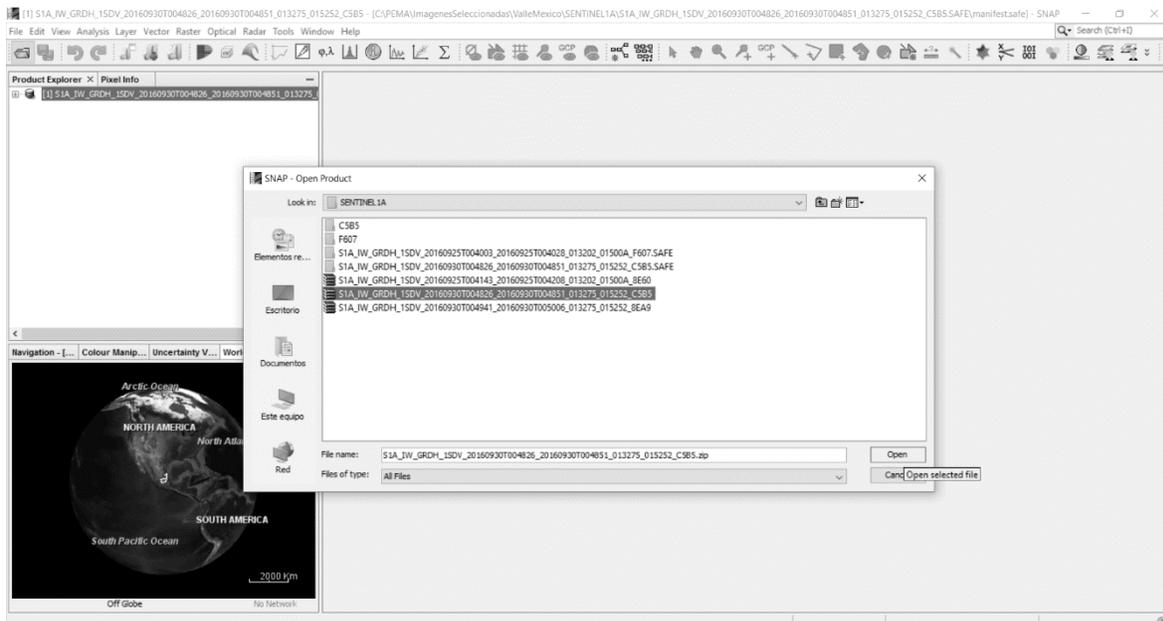
La plataforma de aplicación de Sentinel (SNAP) es un software desarrollado como herramienta para el procesamiento de los productos Sentinel por Brockmann Consult, Array Systems Computing y C-S para la agencia espacial europea.

La arquitectura SNAP es ideal para el procesamiento y análisis de la observación de la Tierra debido a las siguientes innovaciones tecnológicas: Extensibilidad, portabilidad, plataforma modular de cliente, abstracción de datos generales de observación de la tierra, gestión de memorias y un marco de procesamiento de gráficos. SNAP integra herramientas de procesamiento de los datos de satélite de Sentinel 1, Sentinel 2 y Sentinel 3 propios de la ESA pero también incluye sensores como Landsat, Rapid Eye, Radarsat ente otros.

A continuación, se describe el proceso que permite el procesamiento de imágenes Sentinel-1

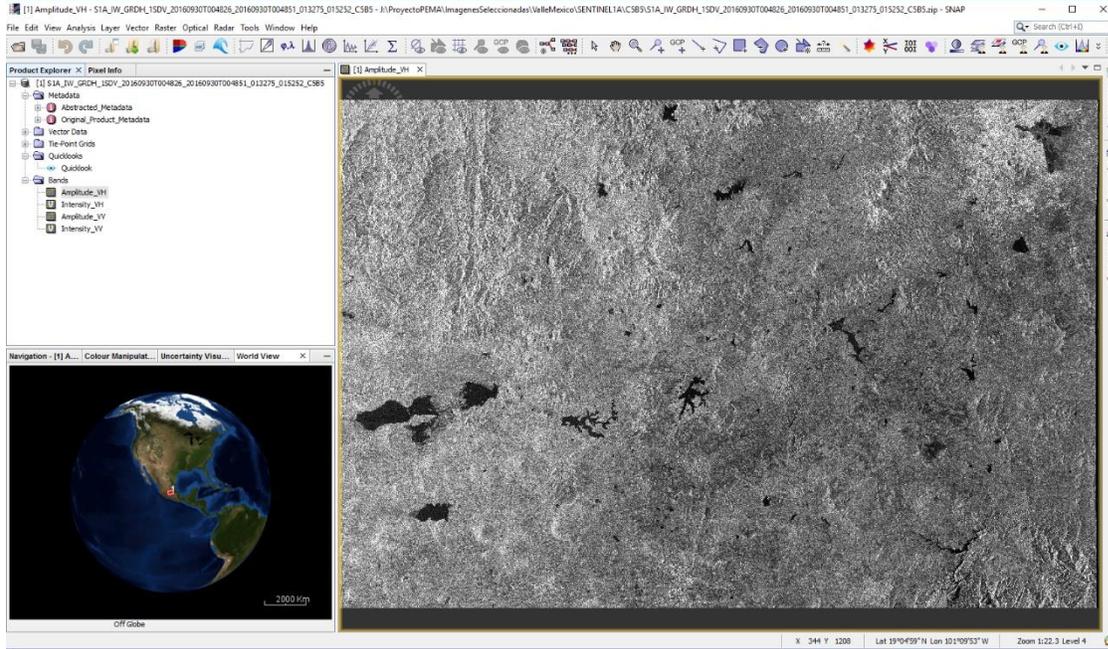
A.1. APERTURA, VISUALIZACIÓN DE LA IMAGEN SENTINEL-1

A.1.1. Dar clic en el icono de folder para desplegar la ventana de abrir producto ⇒ seleccionar el archivo comprimido que contenga la imagen a analizar (si la carpeta esta descomprimida seleccionar en archivo manifest.safe)⇒ Dar clic en abrir



⇒ Se cargarán los datos de la imagen como un fichero BEAM-DIMAP que nos permitirá manejarlos con facilidad.

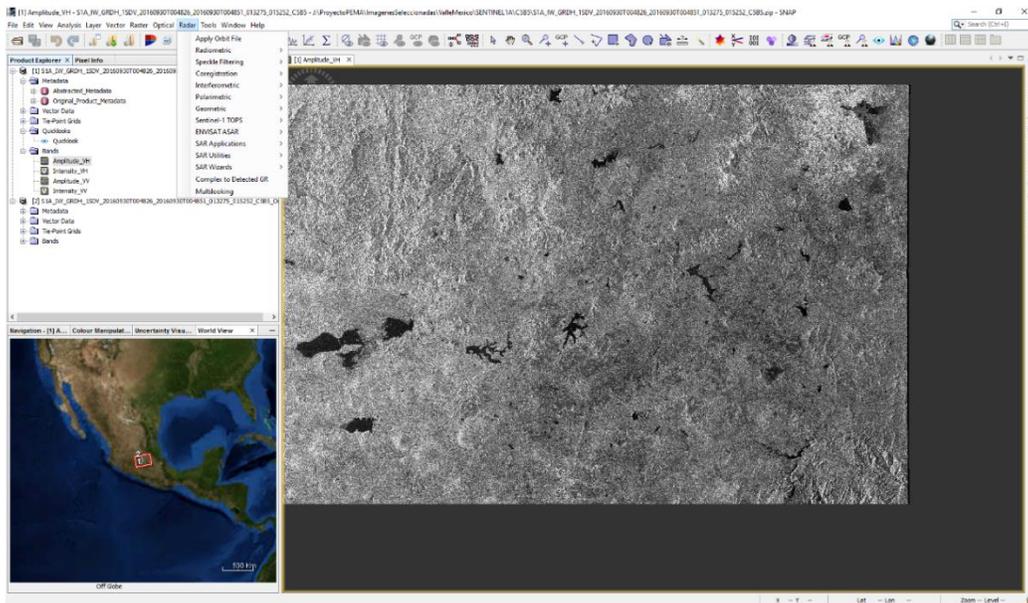
⇒ Puede revisar que se trate de la imagen deseada visualizando su ubicación en el visor global.



A.2. APLICANDO EL ARCHIVO DE ORBITA

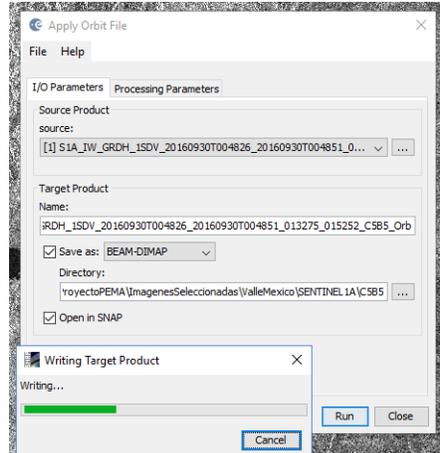
Aplicar el archivo de orbita permite al software relacionar los metadatos de la imagen en el lugar geográfico correcto para así permitir la descarga archivos de forma automática en las diferentes herramientas del SNAP.

A.2.1. Para aplicar el archivo de órbita vaya al menú Radar ⇒ selecciones la opción: "Aplicar el archivo de orbita" para desplegar la ventana de Aplicar archivo de orbita ⇒ es importante colocar el directorio donde se va a guardar el archivo.

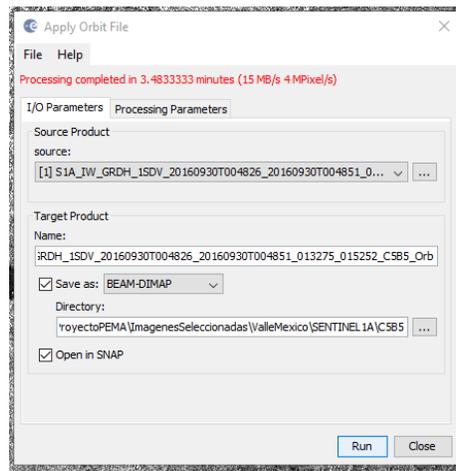




A.2.2. Seleccione el fichero de entrada como fuente en la pestaña de parámetros de entrada y salida ⇒ colocar en el directorio donde se va a guardar el archivo y el nombre con el que se identificará ⇒ Seleccione las opciones necesarias si desea guardar el archivo en la carpeta deseado ⇒ Seleccione desplegar si desea visualizar el nuevo BEAM-DIMAP en SNAP ⇒ Corra el proceso y espere a que sea terminado.



⇒ El programa SNAP avisará con letras rojas cuando el proceso se haya completado. Ahora puede cerrar la ventana.

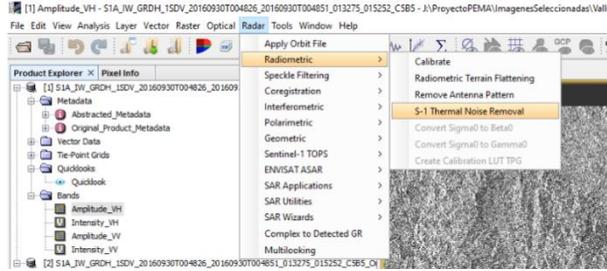


A.3. ELIMINACIÓN DEL RUIDO TÉRMICO

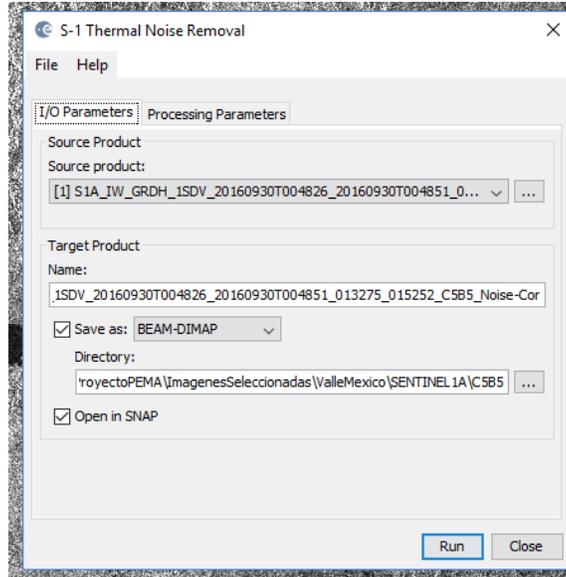
El ruido es cualquier señal indeseable captada por el sensor, estas señales son aleatorias e impredecibles y pueden ser generadas dentro y fuera del sistema. El ruido térmico está producido por la agitación térmica de los electrones, es por lo que se encuentra presente en todos los objetos que tengan una temperatura superior a 0 K. El procedimiento para eliminar el ruido térmico se conoce como TMR (Thermal noise Removal) y se debe aplicarse siempre antes de realizar la calibración pues es necesario eliminar aquellos puntos seriamente afectados por el ruido. Para lograrlo, siga los siguientes pasos:



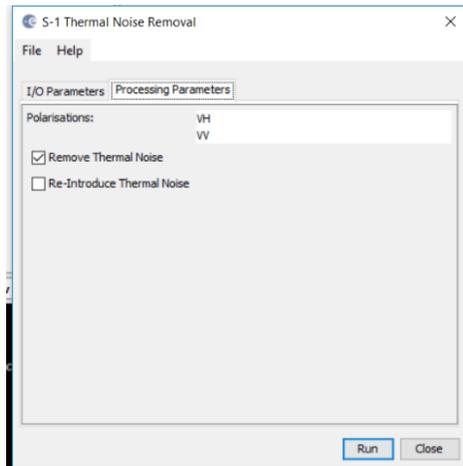
A.3.1. Vaya a el menú de Radar ⇒ Opción Radiometric ⇒ Remoción de ruido térmico S-1 (S-1 Thermal Noise Removal).



A.3.2. ⇒ Esto desplegará la ventana ⇒ En la pestaña de parámetros de entrada y salida (I/O Parámetros): Seleccionar el archivo al que se aplicó previamente el archivo de orbita ⇒ Colocar en el directorio donde se va a guardar y el nombre con el que se identificará el resultado⇒ Seleccione las opciones necesarias si desea guardar el archivo en la carpeta deseada ⇒ Seleccione desplegar si desea visualizar el nuevo BEAM-DIMAP en SNAP ⇒ Corra el proceso y espere a que sea terminado.

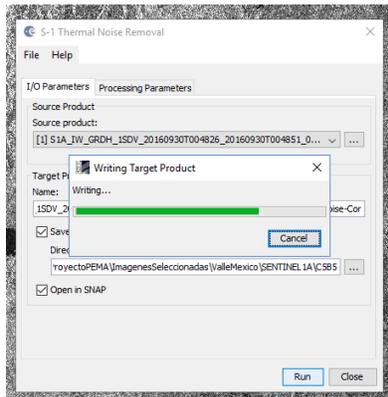


⇒ En la pestaña de parámetros de proceso (processing parameters), seleccionar la polarización en la que se encuentra la imagen y seleccionar la opción Remover el ruido térmico.

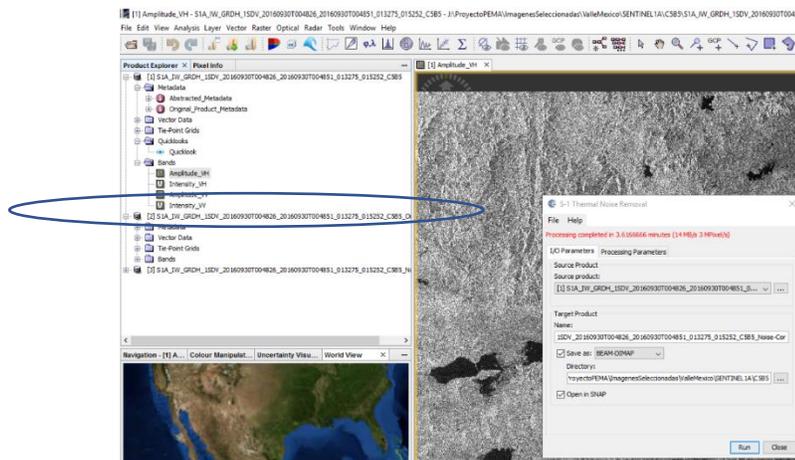




⇒ El programa trabajara en el proceso



⇒ El programa SNAP avisará con letras rojas cuando el proceso se haya completado y generara un tercer archivo con la corrección de ruido térmico. Ahora puedes cerrar la ventana.



A.4. CALIBRACIÓN

El proceso de calibración de una imagen RADAR permite obtener los datos de coeficientes de retrodispersión a partir de la amplitud registrada por el sensor, esto con el fin de crear un raster donde el valor de cada pixel esté relacionado directamente con el coeficiente de retrodispersión de cada escena y así poder realizar un análisis cuantitativo de la imagen.

El coeficiente de retrodispersión (backscatter) o también llamado sección equivalente de radar o corte transversal de radar o en sus siglas en inglés (Radar Cross Section), está definido como la razón entre la energía que recibiría el sensor si la misma hubiera sido totalmente dispersada en forma isotrópica y la energía real recibida por el sensor.

La calibración de imágenes de datos SAR, puede ser directamente relacionada con la retrodispersión de la señal de radar desde la escena, relacionando LUT (look-up table) y el número de pixeles en la



imagen con el valor de retrodispersión en radar (Freeman, 1992). Como el valor de cada pixel es proporcional a la radiación electromagnética retro dispersada de la superficie iluminada, para cada punto de la escena, la energía de retrodispersión se relaciona con la energía emitida.

En el caso de extender superficies compuestas de una infinidad de dispersores elementales, el término coeficiente de retrodispersión, es muy utilizado. Este coeficiente tiene una dinámica alta y usualmente se expresa en decibeles (dB).

Algunos los refieren como sigma naught o sigma cero. Los coeficientes de retrodispersión dan información acerca de la superficie observada. Es una función de la frecuencia, la polarización y el ángulo de incidencia de ondas emitidas, así como de las propiedades geométricas y físicas de la superficie iluminada. Los coeficientes de retrodispersión necesitan ser calibrados antes de interpretar sus medidas, tanto tiempo como espacio.

Los métodos de calibración SAR propuestos por Freeman, 1992 y Laur, 1996 permiten convertir las reflectancias del radar a unidades físicas: éstos dependen del sistema SAR característico ERS1 y RADARSAT. En el caso de datos ERS, el método de calibración se realiza por aur (1996). La ecuación de calibración de los productos S-1 sigue la expresión genérica de ENVI SAR. En el caso de la sección transversal de radar:

$$\sigma^0 = \frac{DN^2}{A_{dn}^2 K} * \frac{1}{G_{eap}^2} \left(\frac{R}{R_{ref}} \right)^3 \sin(\alpha)$$

Donde σ^0 es el coeficiente de retrodispersión, α es el ángulo incidente, $1/G_{eap}^2$ es la corrección del patrón de antena de elevación (EAP), $\left(\frac{R}{R_{ref}} \right)^3$ es la correlación de pérdida de dispersión de rango (RSL), K es la constante de calibración (específica para el tipo de producto y A_{dn} es: un factor de normalización de área.

En el caso de Sentinel-1, las correcciones del EAP y RSL se aplican por default al mismo, la formula anterior se simplifica a:

$$\sigma^0 = \frac{DN^2}{A_{dn}^2 K} \sin(\alpha)$$

Consecuentemente el cuadro 2, muestra la sección cruzada del radar LUT

Es posible transformar los valores a dB por ejemplo para σ^0 se aplica las siguientes formulas:

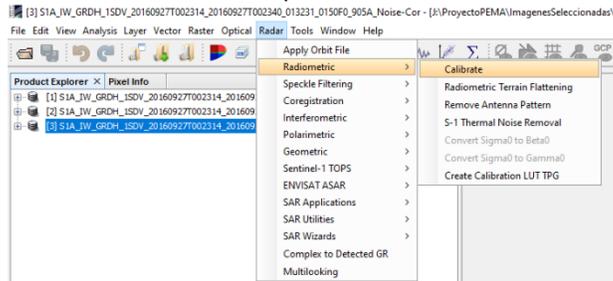
$$\sigma_{db}^0 = 10.0 \log_{10} \sigma^0$$

También pueden utilizarse el promedio del coeficiente de retrodispersión sobre el área de interés y usar la siguiente formula: $\sigma = \frac{\langle DN \rangle^2}{A_{\sigma}^2}$

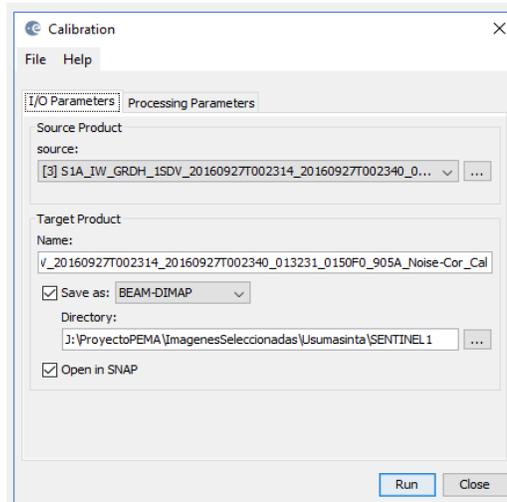
Para calibrar en SNAP siga el siguiente procedimiento:



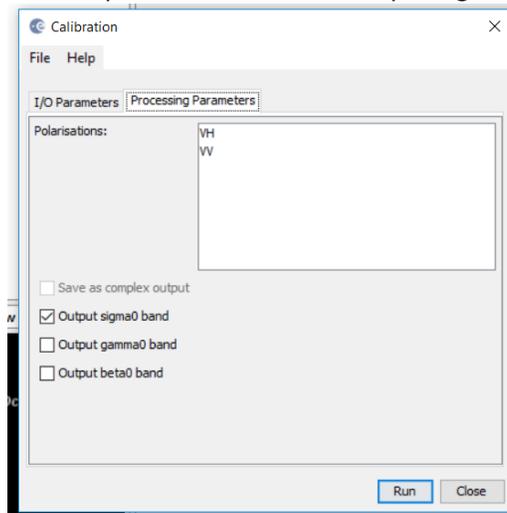
A.4.1. Vaya a el menú de Radar ⇒ selecciones la opción Radiometric ⇒ Seleccione Calibrate



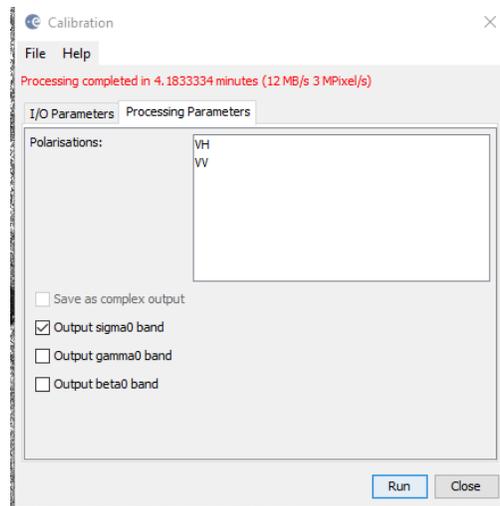
⇒ Esto desplegará la ventana similar a la de la imagen de bajo ⇒ Seleccionar en la pestaña de parámetros de entrada y salida (I/O Parámetros): el archivo al que se ha eliminado previamente el ruido térmico ⇒ Colocar en el directorio donde se va a guardar el archivo y el nombre con el que se identificará ⇒ Seleccione las opciones necesarias si desea guardar el archivo en la carpeta deseada ⇒ Seleccione open in SNAP si desea visualizar el nuevo BEAM-DIMAP en SNAP



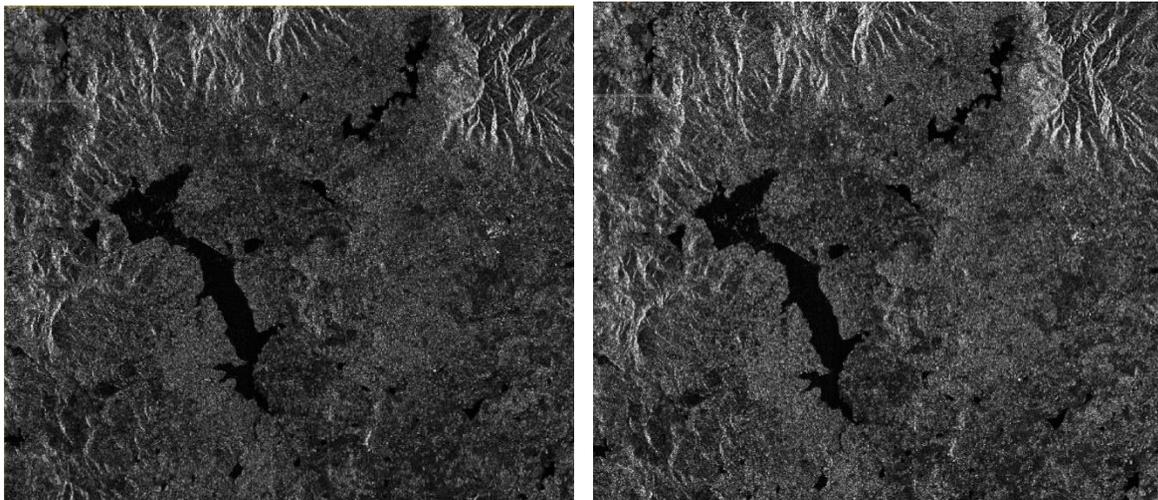
A.4.2. En la pestaña de parámetros de proceso seleccionar Output sigma 0 band.



⇒ Corra el proceso y espere a que sea terminado.



A continuación, se muestra un acercamiento antes y después de la calibración:

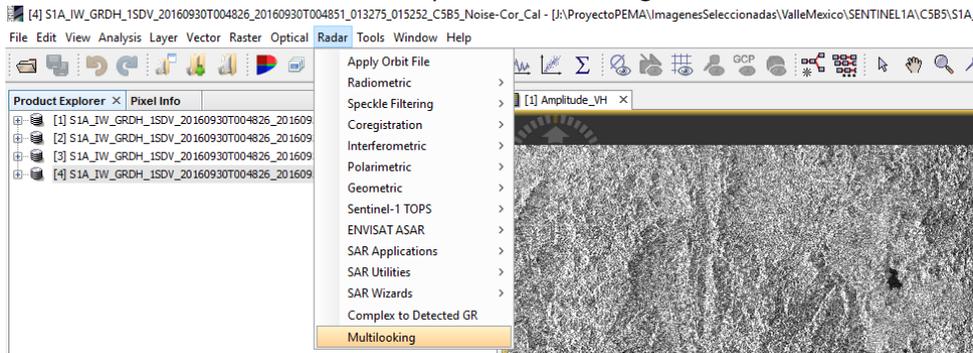


A.5. MULTILOOKING (MULTIBARRIDO).

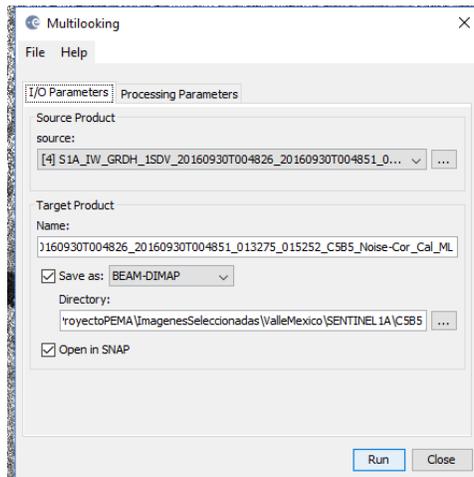
Durante el procesamiento de los pulsos captados por el radar pueden sintetizarse varias pasadas sobre la misma región con un solo juego de datos, con el objetivo de mejorar la resolución de la imagen. Las imágenes generadas por dichas pasadas corresponden a antenas sintéticas que observan la región desde ángulos ligeramente diferentes entre sí. A cada una de estas imágenes se la denomina un look (o barrido). Al promediarlas entre si se genera una sola imagen "multilook" o "multibarrido" la cual es de más fácil interpretación visual gracias al aumento de la resolución. Para realizar este procedimiento en los productos de Sentinel-1 siga el siguiente procedimiento en el programa SNAP:



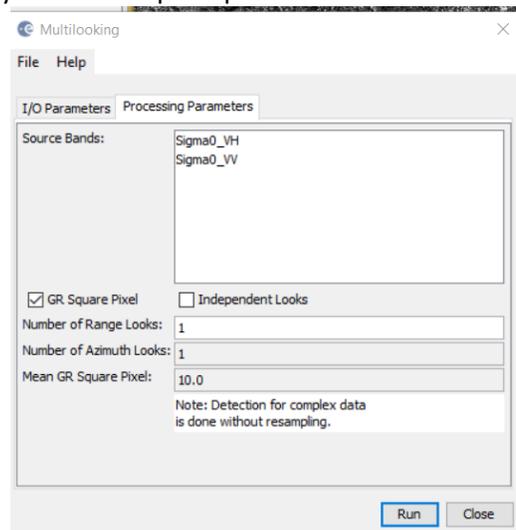
A.5.1. Vaya a el menú de Radar ⇒ Seleccione la opción Multilooking



A.5.2. Esto desplegará la ventana similar a la de la imagen de bajo⇒ Seleccionar en la pestaña de parámetros de entrada y salida (I/O Parámetros): el archivo al que se ha sido calibrado⇒ Colocar en el directorio donde se va a guardar el archivo y el nombre con el que se identificará ⇒ Seleccione las opciones necesarias si desea guardar el archivo en la carpeta deseada ⇒ Seleccione desplegar si desea visualizar el nuevo BEAM-DIMAP en SNAP

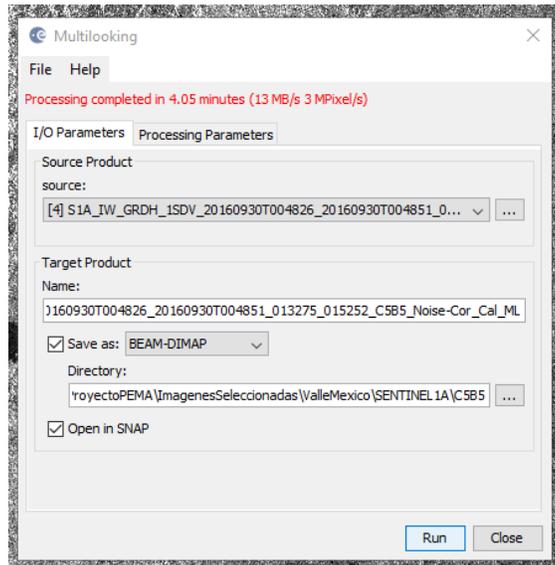


A.5.3. En los parámetros de proceso seleccione: GR square Pixel, numero barridos en rango:1, numero de barridos en azimuth: 1 y Mean GR square pixel: 10.0.





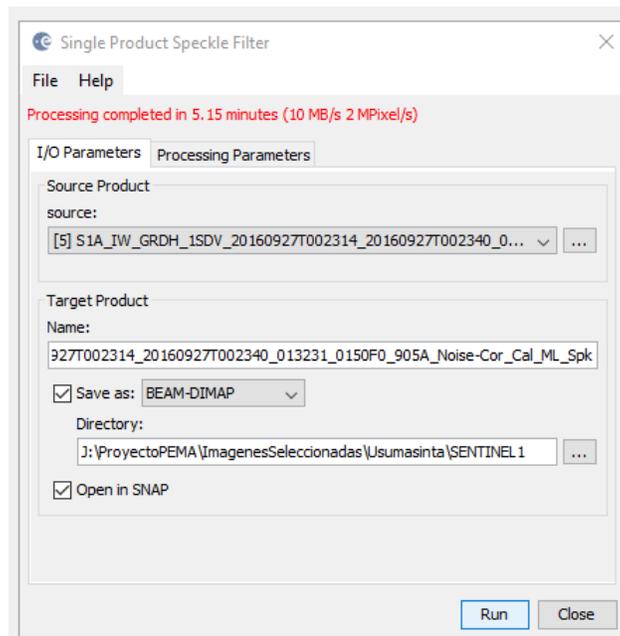
A.5.4. ⇒ Corra el proceso y espere a que sea terminado.



A.6. REDUCCION DE RUIDO "SPECKLE"

El ruido "speckle" es aquel inherente al sistema radar que afecta la calidad de la medición. Para corregirlo siga el siguiente procedimiento:

A.6.1. Vaya a el menú de Radar ⇒ Seleccione la opción Speckle Filtering ⇒ seleccione single product Speckle Filtering.

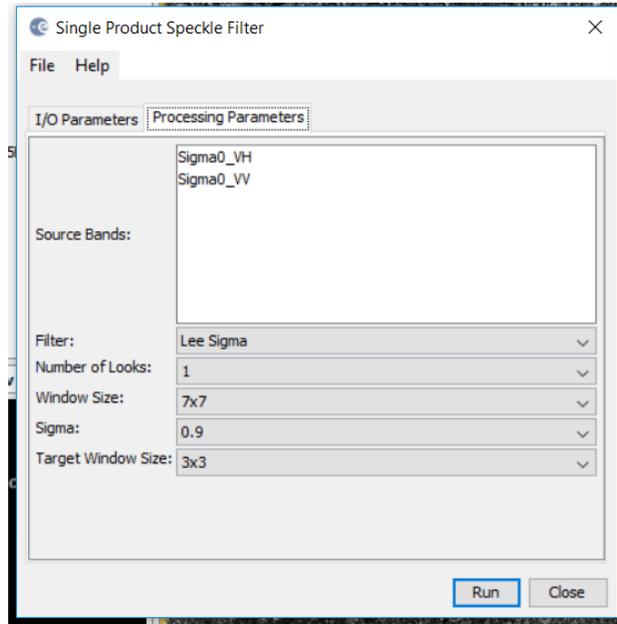




A.6.2. Esto desplegará la ventana similar a la de la imagen de bajo⇒ Seleccionar en la pestaña de parámetros de entrada y salida (I/O Parámetros): el archivo el fichero al que se ha sido aplicado el proceso de multilooking ⇒ Colocar en el directorio donde se va a guardar el archivo y el nombre con el que se identificará ⇒ Seleccione las opciones necesarias si desea guardar el archivo en la carpeta deseado ⇒ Seleccione desplegar si desea visualizar el nuevo BEAM-DIMAP en SNAP.

En los parámetros de proceso seleccione:

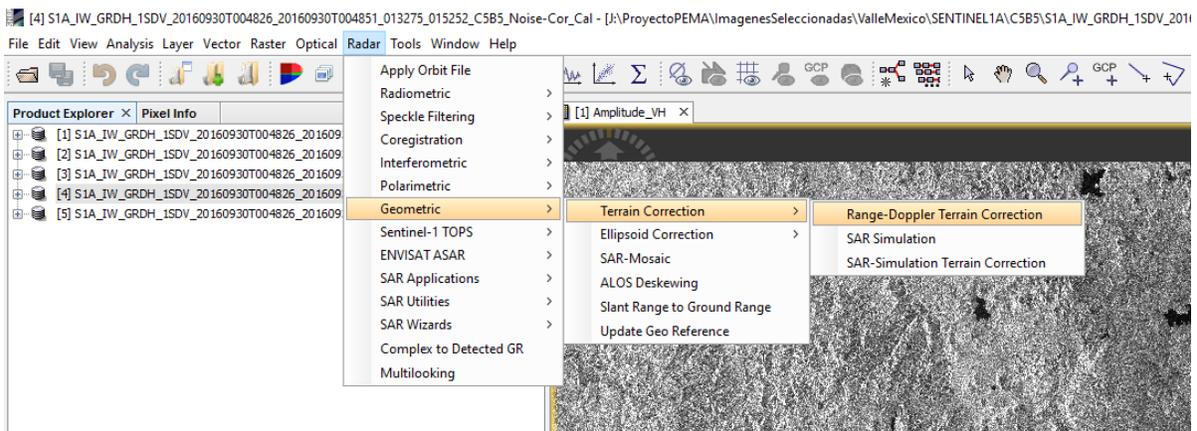
- source band: Sigma0_VV
- Filter: lee Sigma
- Number of looks: 1
- Sigma: 0.9
- Target window size: 3 * 3



A.6.3. Corra el proceso ⇒ el programa avisará una vez terminado.

A.7. CORRECCIÓN DEL TERRENO

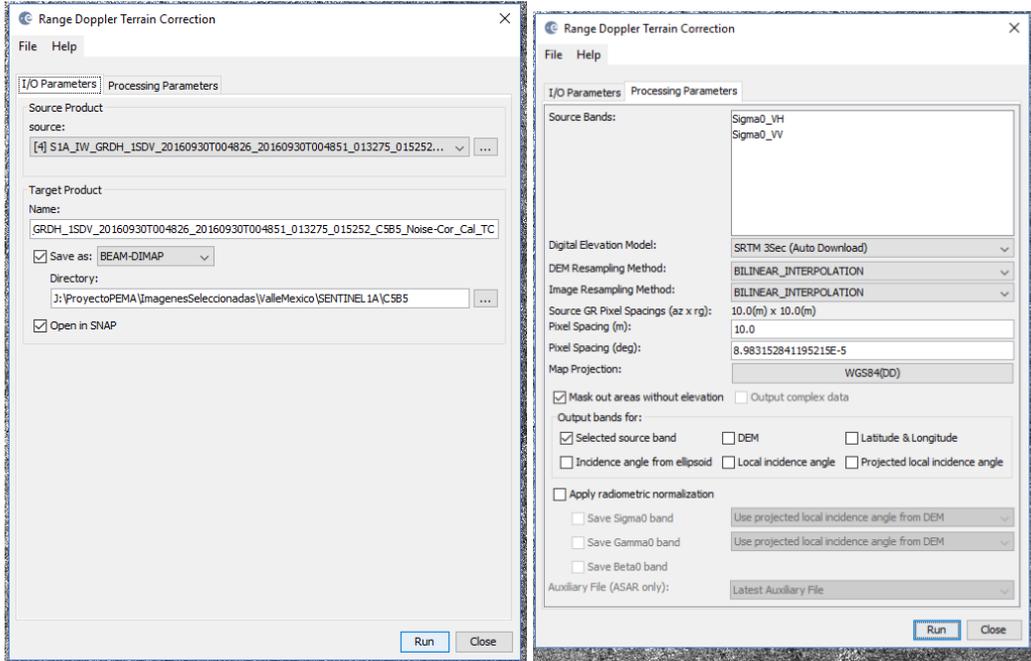
A.7.1. Vaya a el menú de Radar ⇒ Selecciona la opción Geometric ⇒ Range Doppler Terrain Correction.



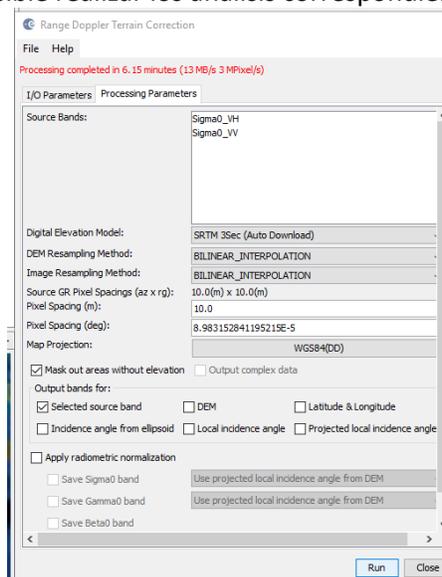


A.7.2. Esto desplegará la ventana similar a la de la imagen de bajo ⇒ Seleccionar en la pestaña de parámetros de entrada y salida (I/O Parámetros): el archivo el fichero al que se ha sido eliminado el ruido speckle" ⇒ Colocar en el directorio donde se va a guardar el archivo y el nombre con el que se identificará ⇒ Seleccione las opciones necesarias si desea guardar el archivo en la carpeta deseado ⇒ Seleccione desplegar si desea visualizar el nuevo BEAM-DIMAP en SNAP.

En los parámetros de proceso seleccione las opciones predeterminadas.



A.7.3. Corra el proceso ⇒ el programa avisará una vez terminado, con este procedimiento la imagen se encuentra corregida y es posible realizar los análisis correspondientes.

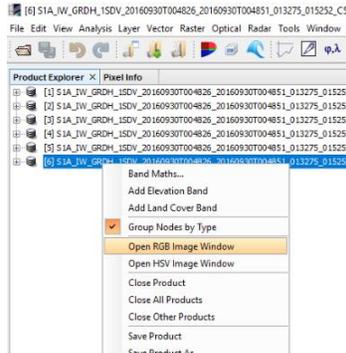




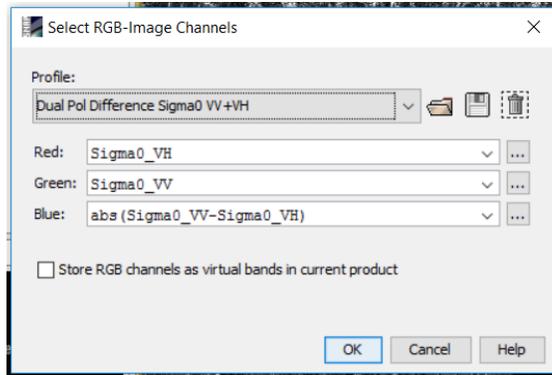
A.8. VISUALIZACIÓN RGB

Para visualizar los parámetros RGB se utiliza siga el siguiente procedimiento:

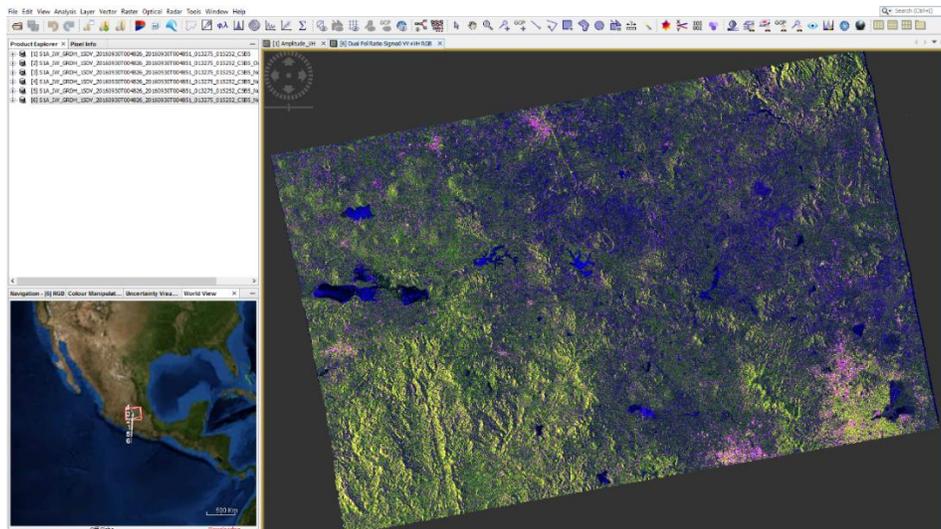
A.8.1. Despliegue el menú secundario de la imagen preprocesada ⇒ Seleccione la opción abrir una ventana RGB



A.8.2. Esto desplegará la ventana similar a la de la imagen de bajo⇒ Seleccionar profile Dual Pol Difference Sigma= VV+VH para seleccionar automáticamente los datos que se desplegarán los canales RGB.



⇒ Pulse Ok y espere a que se desplegué la imagen en la pantalla. A continuación, se muestra un ejemplo de una imagen RGB:





B. PASOS PARA CLASIFICACION CON EL SEMIAUTOMATIC CLASIFICAION PLUG IN DE QGIS UTILIZANDO EL ALGORITMO DE DISTANCIA MÍNIMA O MAPEO DEL ANGULO ESPECTRAL

El Semi-Automatic Classification Plugin (SCP siglas en inglés) es un complemento de código abierto y libre acceso para el programa QGIS que permite la clasificación semi-automática de imágenes de sensores remotos. Proporciona adicionalmente otras herramientas como descarga de imágenes satelitales disponibles sin costo, el pre-procesamiento de imágenes y calculadora ráster, entre otras.

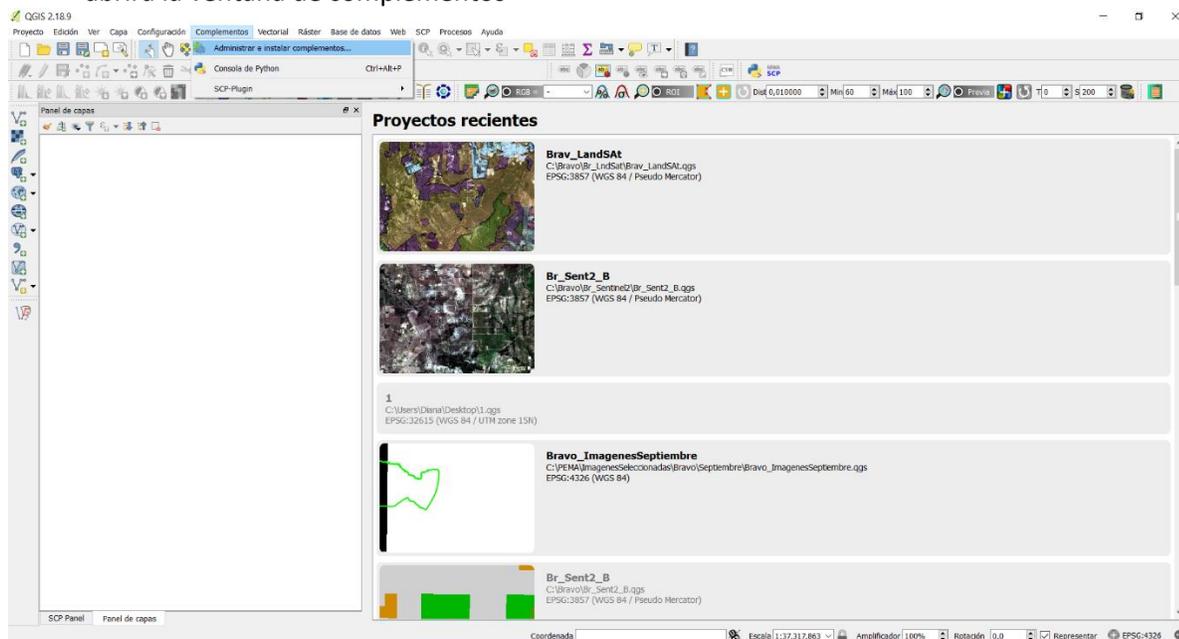
El objetivo principal de SCP es proporcionar un conjunto de herramientas interrelacionadas para el procesamiento ráster con el fin de hacer un flujo de trabajo automático y facilitar la clasificación de la cobertura del suelo, lo cual puede realizarse incluso por personas cuya área principal no es la teledetección.

La primer versión de SCP fue escrita por Luca Congedo en el 2012 para el ACC Dar Project con el fin de crear una herramienta para la clasificación de la cobertura del suelo de modo automático y económico (lea este documento de trabajo). Las siguientes versiones de SCP fueron desarrolladas como un compromiso personal con el campo de la teledetección y el software de código abierto. La versión 5 (codename: Kourou) de SCP es desarrollada en el marco del "PhD in Landscape and Environment" de Luca Congedo en "Sapienza University of Rome".

A continuación, se describe el procedimiento que permite la clasificación de una imagen satelital.

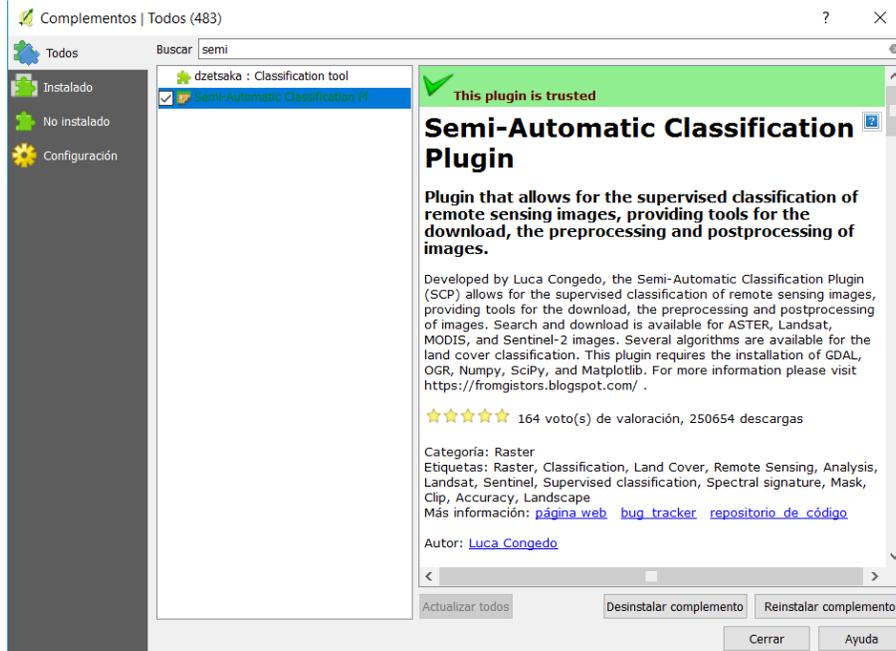
B.1. INSTALAR EL COMPLEMENTO

B.1.1. Dar clic en la pestaña Complementos ⇒ Seleccionar Administrar e instalar complementos⇒ Se abrirá la ventana de complementos



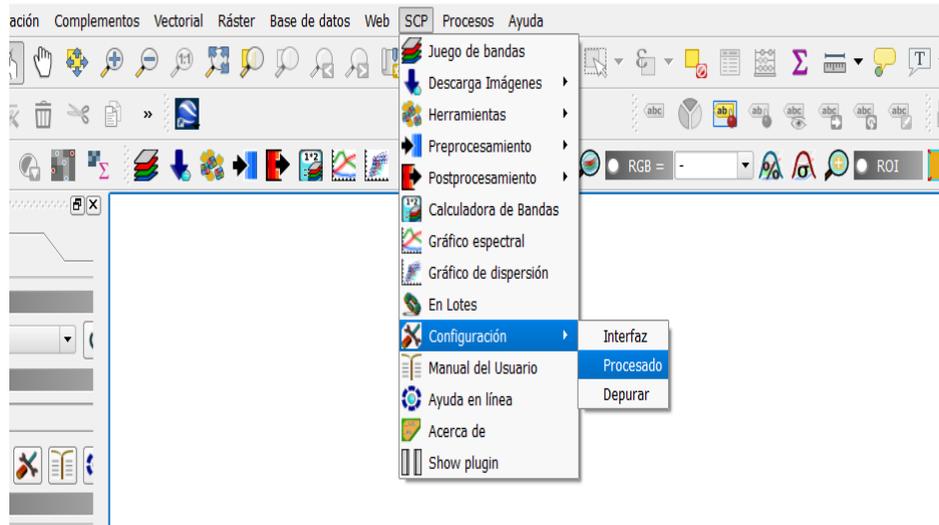


B.1.2. Buscar Semi-Automatic Classification Plugin ⇒ Dar clic en instala complementos ⇒ Esperar a que el complemento se instale Cerrar la ventana



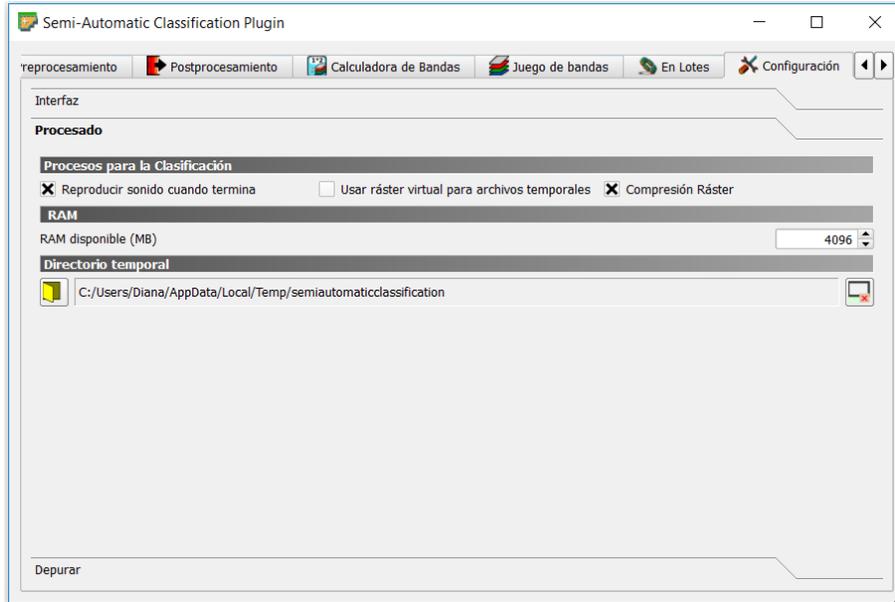
B.2. ASIGNAR LA MITAD DE LA MEMORIA RAM PARA EL PROGRAMA

B.2.1. Dar clic en la pestaña SCP ⇒ Seleccionar Configuración ⇒ Seleccionar complementos ⇒ Se abrirá la pestaña de Semi-Automatic Classification Plugin.



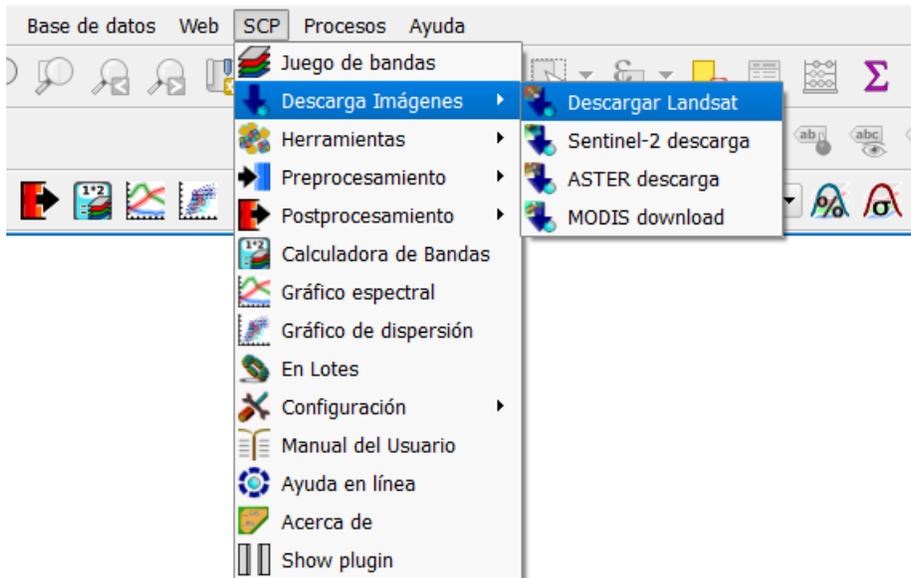


B.2.2. En Colocar en RAM la mitad de la capacidad de la computadora en MB, los siguientes son equivalentes: 32 GB \Rightarrow 16384 MB, 16 GB \Rightarrow 8192 MB, 8 GB \Rightarrow 4096 MB, 4 GB \Rightarrow 2048 MB, 2 GB \Rightarrow 1024 MB.



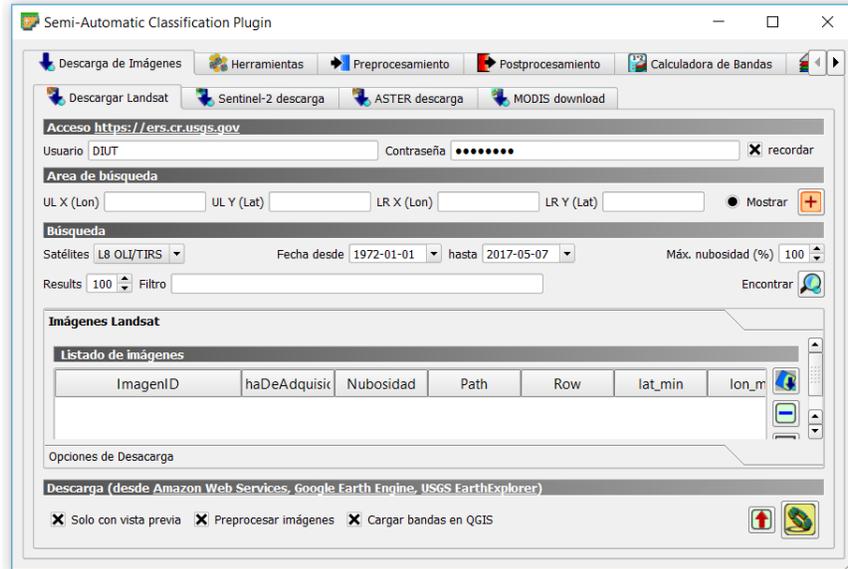
B.3. DESCARGA DE IMÁGENES

B.3.1. Dar clic en la pestaña SCP \Rightarrow Seleccionar Descarga de Imágenes \Rightarrow Seleccionar la imagen que desea descargar \Rightarrow Se abrirá la pestaña del Semi-Automatic Classification Plugin.



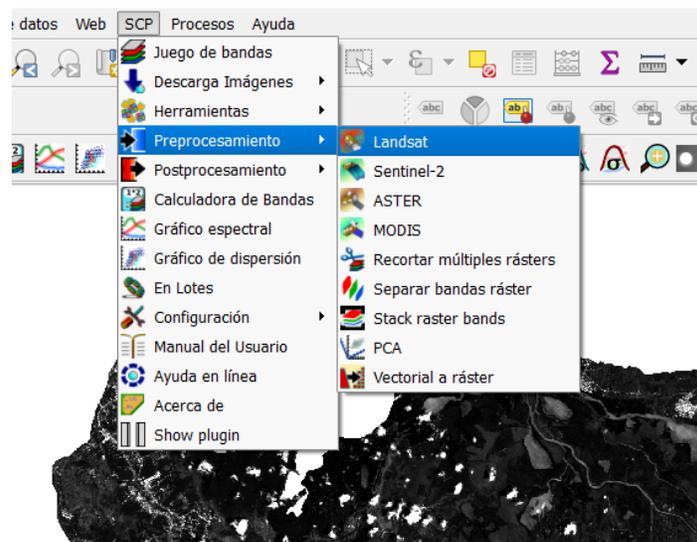


B.3.2. Ingrese su usuario y contraseña ⇒ De clic en el icono anaranjado  y selecciones el área o bien coloque las coordenadas ⇒ Selecciones los criterios de búsqueda (Fecha, sensor, etc.) ⇒ De clic en encontrar imágenes  ⇒ Visualice la vista previa de la imagen  ⇒ Selecciones la imagen que desea tomar ⇒ Selecciones las opciones necesarias si desea descargar solo las imágenes que es en vista previa, preprocesar y cargas bandas ⇒ de clic en procesar  y seleccione la carpeta donde desea guardar la descarga



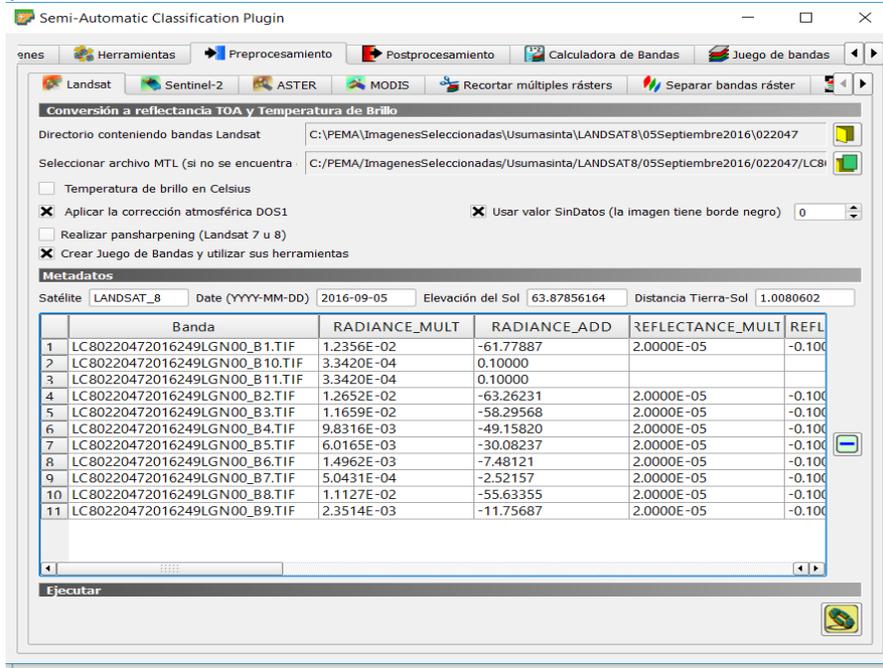
B.4. PREPROCESAMIENTO DE IMAGENES

B.4.1. Descomprima la carpeta de descarga ⇒ Seleccionar la pestaña SCP⇒ Seleccionar Preprocesamiento⇒ Seleccionar el satélite que desea preprocesar ⇒ Se abrirá la pestaña del Semi-Automatic Classification Plugin.





B.4.2. De clic en la capeta amarilla para seleccionar el directorio que contiene las bandas LandSat ⇒ Seleccione el archivo MTL ⇒ Seleccione el archivo MTL ⇒ Seleccione las opciones que son deseadas ⇒ de clic en procesar y seleccione la carpeta donde desea guardar las imágenes preprocesadas



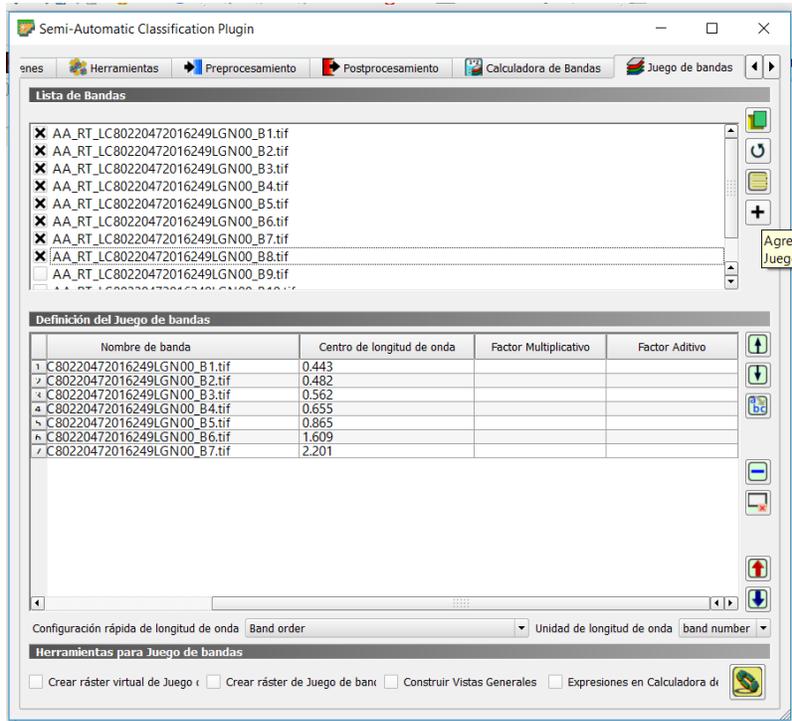
B.5. ESTABLECIMIENTO DEL CONJUNTO DE BANDAS

B.5.1. Dar clic en la pestaña SCP ⇒ Seleccionar Juego de Bandas ⇒ Se abrirá la pestaña del Semi-Automatic Classification Plugin.



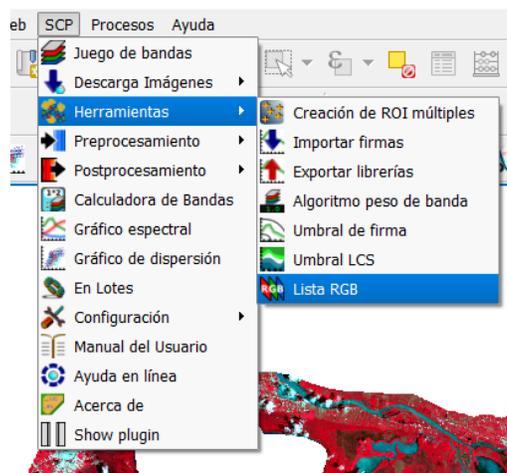


B.5.2. Actualice la ventana con el icono ⇒ Agregue las bandas al BandSet con el icono ⇒ Seleccione la configuración de longitud de onda y la unidad
 Configuración rápida de longitud de onda Band order Unidad de longitud de onda band number ⇒ Si la configuración no se encuentra previamente programada seleccione Orden de bandas e introduzca la Longitud de onda central manualmente.



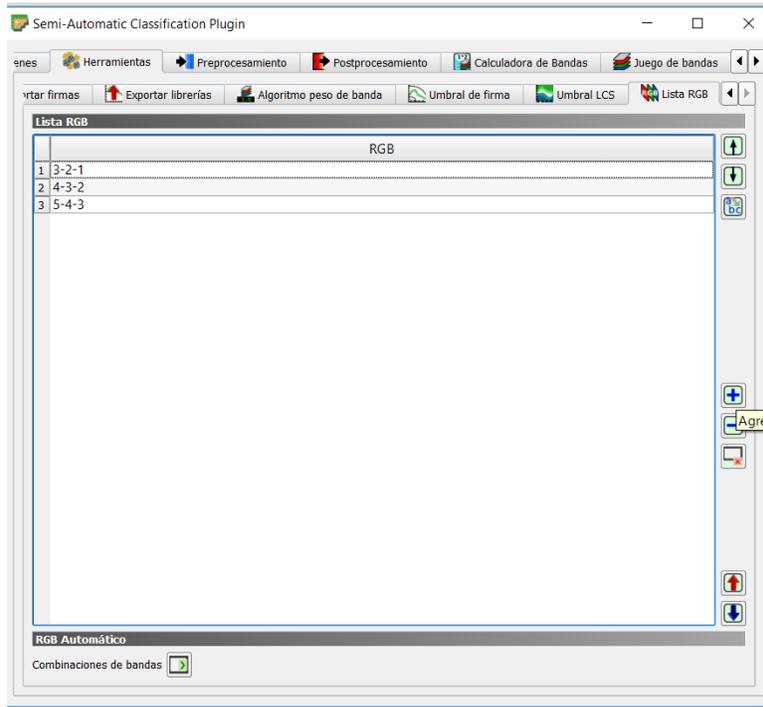
B.6. VISUALIZACIÓN RGB

B.6.1. Dar clic en la pestaña SCP ⇒ Seleccionar Juego de Bandas ⇒ Se abrirá la pestaña del Semi-Automatic Classification Plugin.

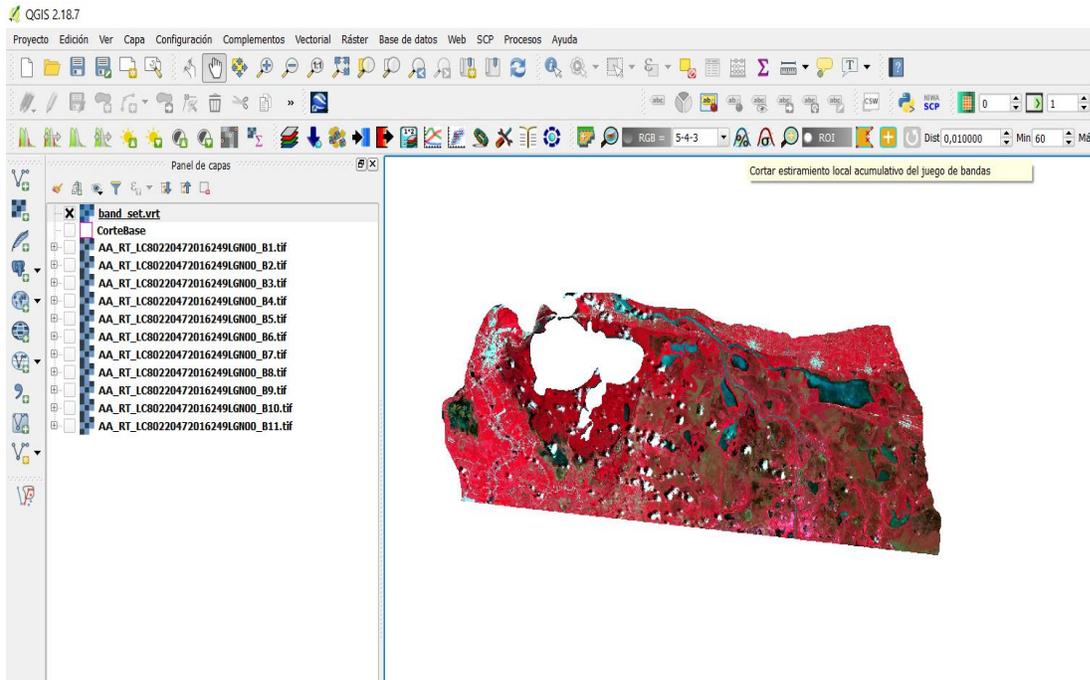




B.6.2. De clic en Agregar fila  ⇒ Escriba las bandas que desea seleccionar en el orden Rojo-Verde-Azul ⇒ La vista se actualizará automáticamente



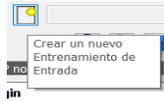
B.6.3. A continuación, se muestra la imagen de Sentinel-2 para un área de la cuanta del bajo Usumacinta en falso color.



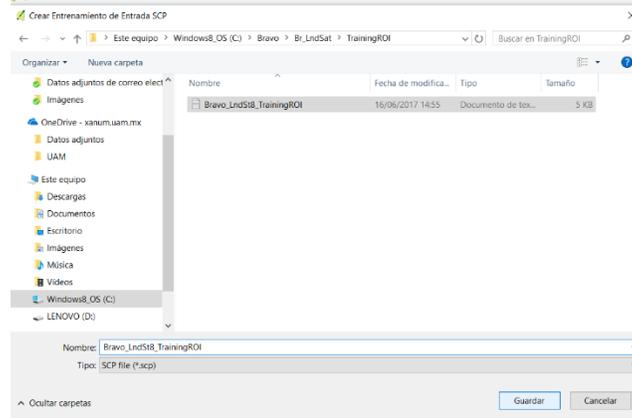


B.7. ESTABLECIMIENTO DE LAS ÁREAS DE ENTRENAMIENTO

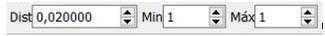
B.7.1. En el panel de SCP vaya a la pestaña de entrada de datos ⇒ Seleccionar Crear un training nuevo



⇒ Seleccione la carpeta donde desea guardar el archivo que contendrá los datos de entrenamiento, de click en Guardar.



B.7.2. Para crear un área de entrenamiento, vaya a la barra de SCP y seleccione:

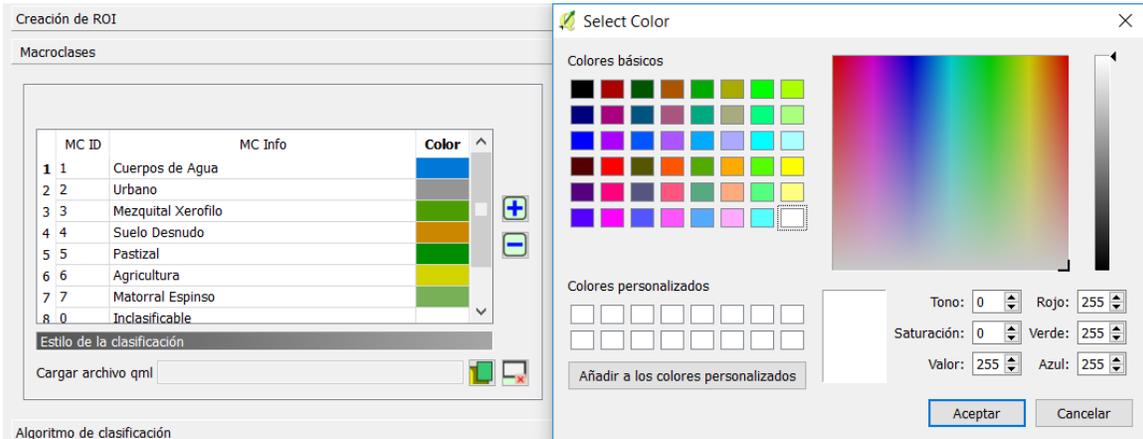
- El icono  para activar el puntero de ROI, esta herramienta permite realizar una selección automática de los iconos con firmas espectrales similares, para acortar o agrandar el área seleccionada y la diferencia de las firmas espectrales utilice la herramienta distancia de la barra de SCP  ,
- El icono  permite seleccionar el área de entrenamiento de la forma en la que se crea un objeto vectorial.

⇒ En el panel de clasificación asigne el número de Macroclase y el nombre de la macroclase para el objeto creado y de click en crear firma espectral Calcular firm.  , el objeto se añadirá en el listado de firmas de área de entrenamiento del panel para clasificación. Hacer esto repetidamente hasta lograr el número de áreas de entrenamiento deseadas

ROI listado de Firmas						
	S	Tipc	MC ID	C ID	C Info	Color
1	<input checked="" type="checkbox"/>	S	1	1	Cuerpos de Agua	
2	<input checked="" type="checkbox"/>	S	1	2	Cuerpos de Agua	
3	<input checked="" type="checkbox"/>	S	1	3	Cuerpos de Agua	
4	<input checked="" type="checkbox"/>	S	1	4	Cuerpos de Agua	
5	<input checked="" type="checkbox"/>	S	1	5	Cuerpos de Agua	
6	<input checked="" type="checkbox"/>	S	1	6	Cuerpos de Agua	
7	<input checked="" type="checkbox"/>	S	1	7	Cuerpos de Agua	
8	<input checked="" type="checkbox"/>	S	1	8	Cuerpos de Agua	
9	<input checked="" type="checkbox"/>	S	1	9	Cuerpos de Agua	
10	<input checked="" type="checkbox"/>	S	2	10	Urbano	
11	<input checked="" type="checkbox"/>	S	2	11	Urbano	

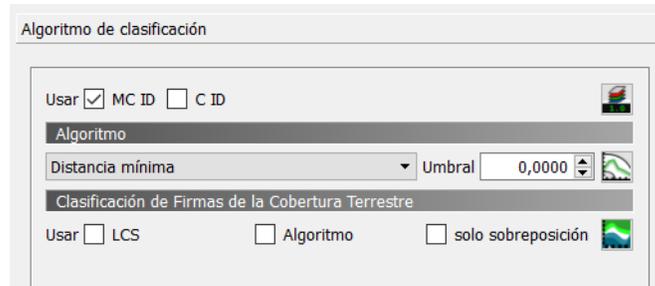


B.7.3. Verifique las macroclases y asigne un color representativo en el panel de macroclases:

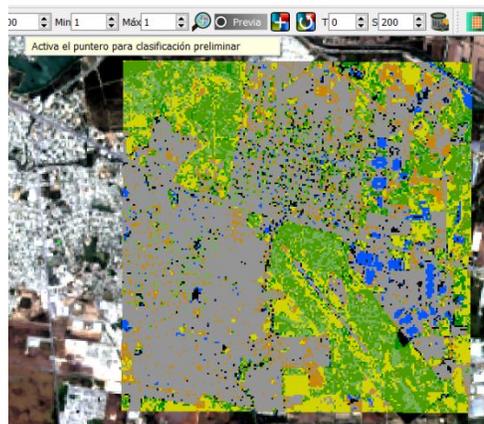


B.8. VISUALIZACION DE VISTA PREVIA

B.8.1. Vaya al panel de algoritmo de clasificación seleccione si va a utilizar macroclase o Clases y el algoritmo de clasificación deseado.



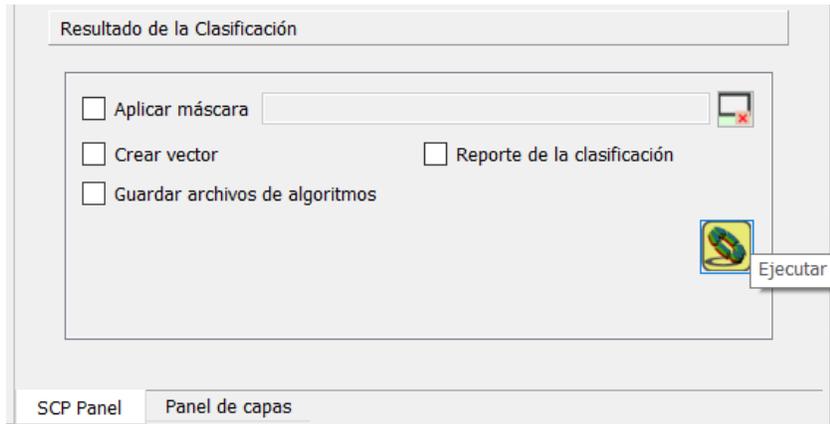
B.8.2. Active el puntero de clasificación preliminar y de clic en el área que desea preclasificar.



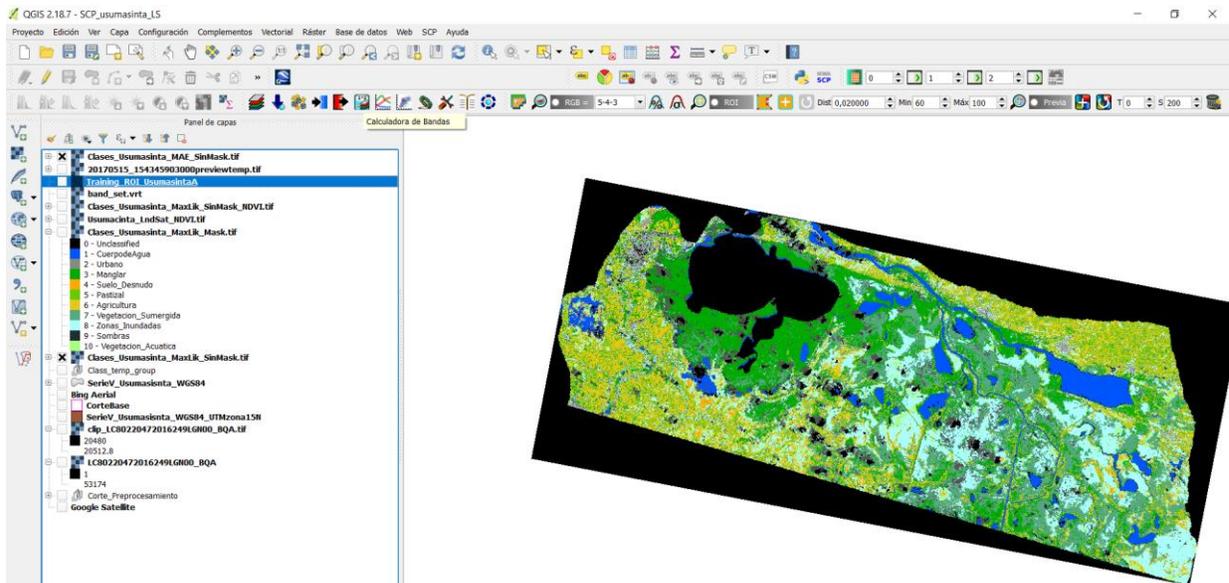


B.9. RESULTADO DE LA CLASIFICACIÓN

B.9.1. Una vez que se encuentre satisfecho con la preclasificación, Vaya al panel de Resultado de Clasificación de clic en ejecutar y seleccione la carpeta donde desea guardar el Raster de clasificación.



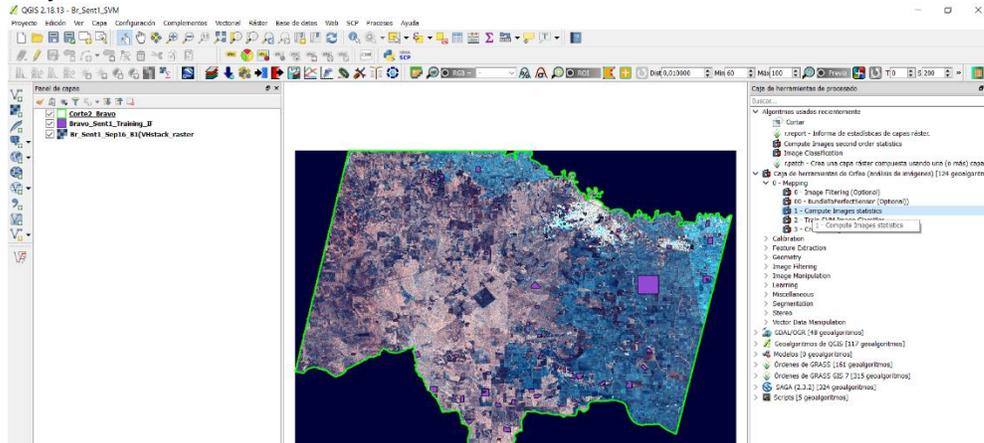
B.9.2. A continuación, se muestra el resultado de la clasificación de la imagen de Sentinel-2 para un área de la cuanta del bajo Usumacinta por el algoritmo de Mapeo del Angulo Espectral



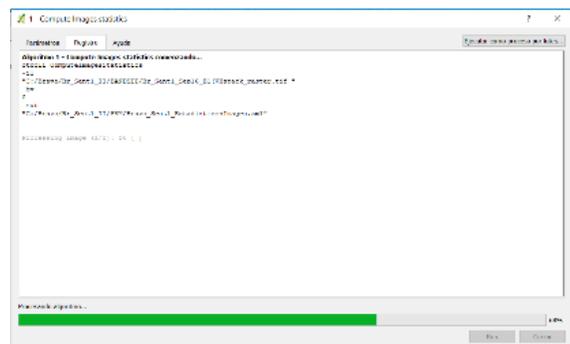
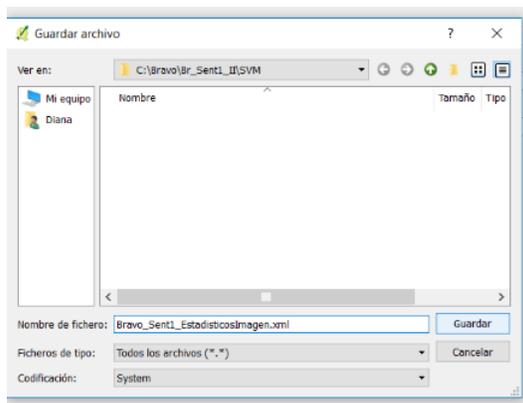
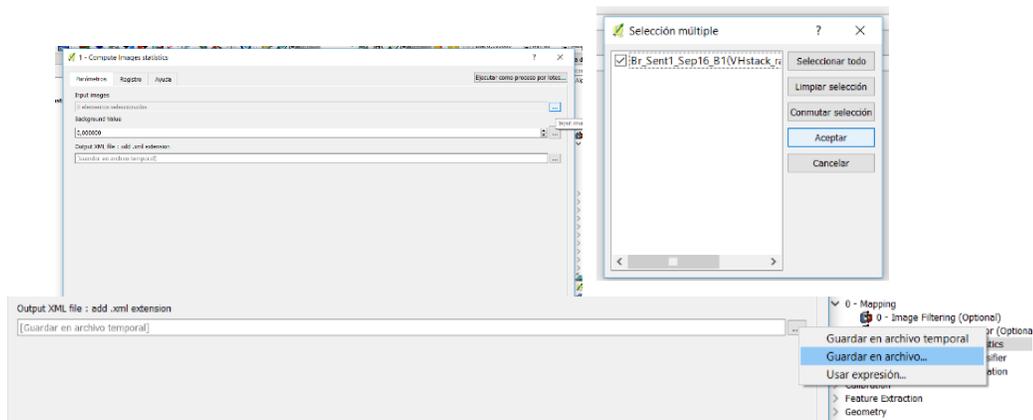


C. PROCEDIMIENTO PARA LA DETERMINACIÓN DE LA COBERTURA TERRESTRE UTILIZANDO LA HERRAMIENTA DE ORFEO PARA QGIS UTILIZANDO EL ALGORITMO DE MAQUINAS DE SOPORTE VECTORIAL

C.1. Cargue el archivo raster que contenga las bandas a analizar de forma apilada ⇒ cargue el archivo vectorial de entramiento ⇒ abrir la caja de herramientas de Orfeo dando clic en Menú procesos y vaya a la pestaña de caja de herramientas.

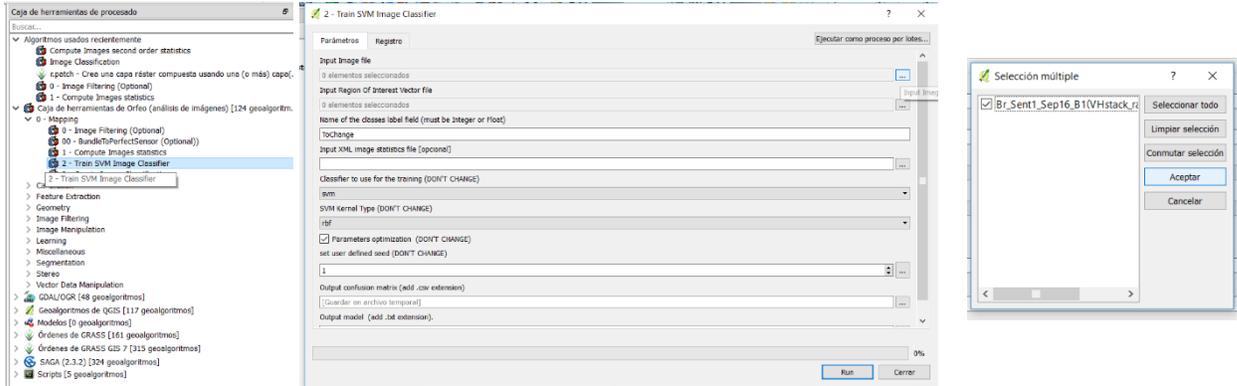


C.2. Para calcular las estadísticas de imagen: seleccione la opción 0-Mapping en la caja de herramientas y de doble click en la opción calcular estadísticas de Imagen ⇒ se desplegará una ventana donde se seleccionará en la pestaña parámetros la imagen a procesar ⇒ selecciones la carpeta en la que se guardará el archivo y coloque el nombre con la extensión .xml ⇒ corra el proceso dando click en run.

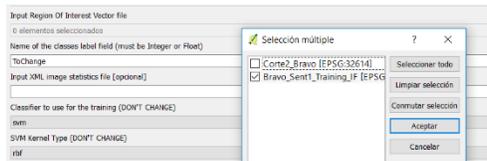




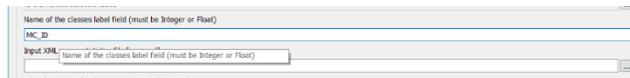
C.3. Para entrenar el clasificador de Maquinas de soporte Vectorial Seleccione: 0-Mapping ⇒ de doble click en 2-Train SVM Image Classifier⇒ Seleccionar el clasificador SVM ⇒ Se desplegará una pestaña, en ella seleccione la imagen a clasificar.



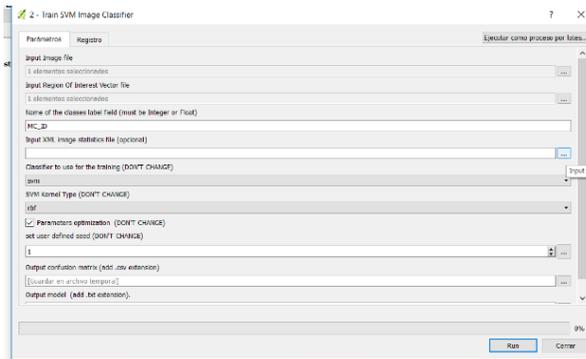
⇒ En la sección de región de interés “Input Region of Interest Vector file” seleccione el archivo vectorial de entrenamiento.



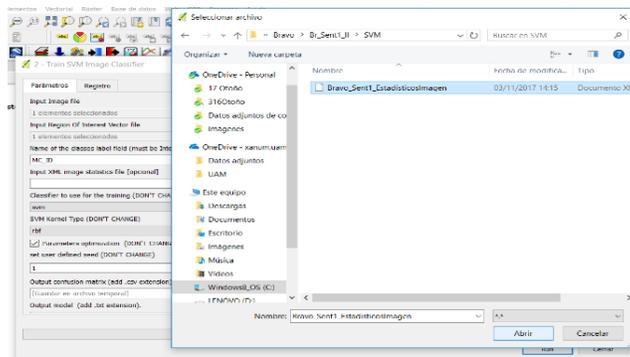
⇒ En la región de etiquetas del campo selecciones el atributo que describe la clase del objeto en el archivo vectorial.



⇒ Deje los parámetros restantes en los colocados por defecto por el programa.

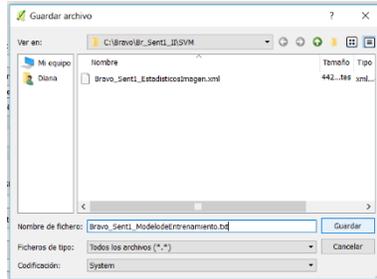
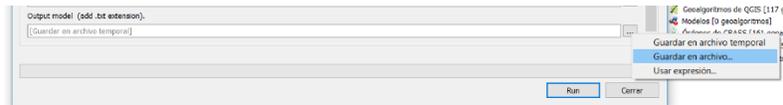


⇒ Seleccione el archivo de estadísticos de Imagen de la carpeta correspondiente.

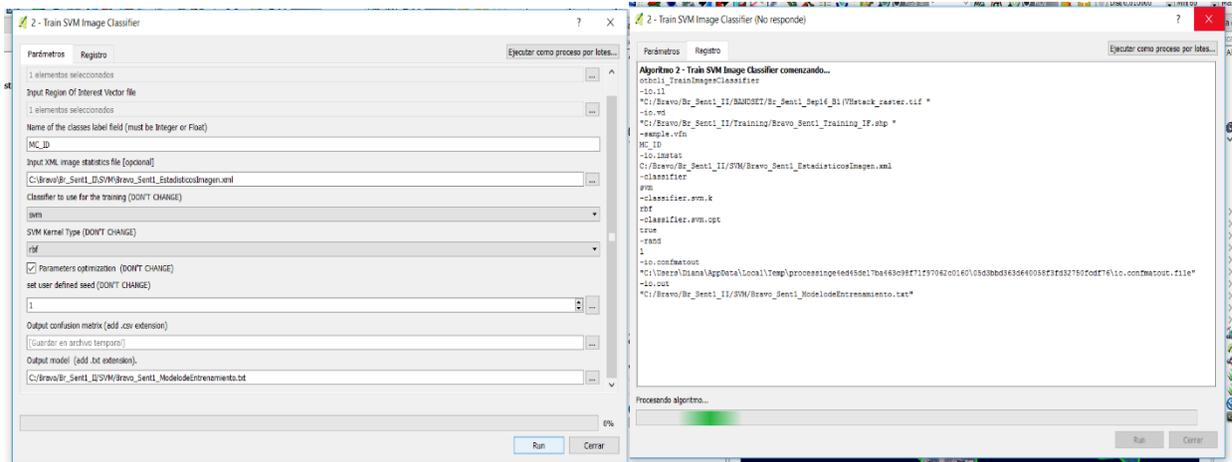




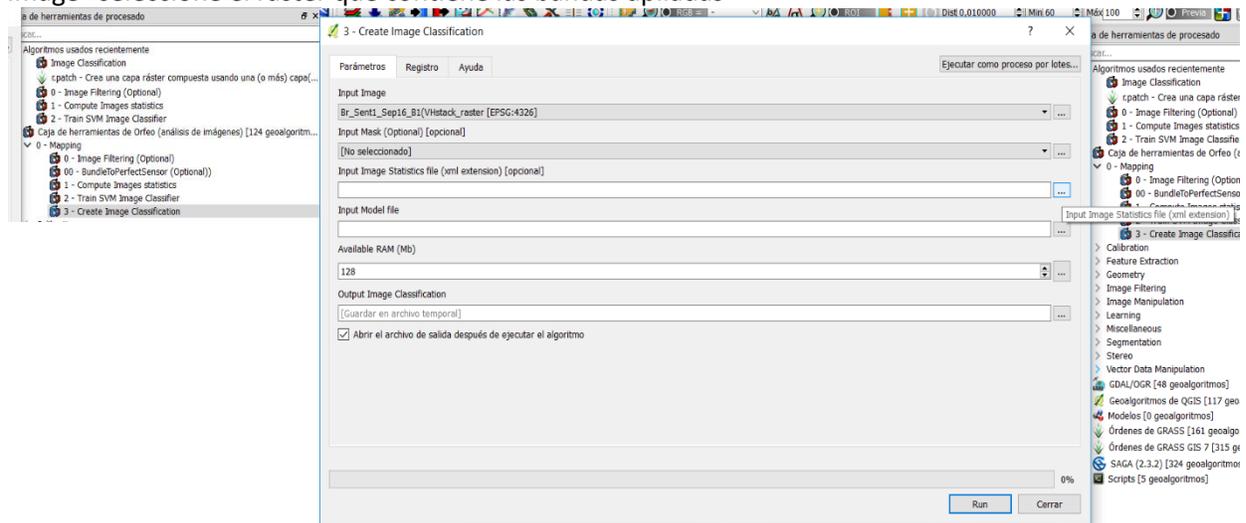
⇒ Guarde el archivo agregando la extensión .txt



⇒ Corra el proceso

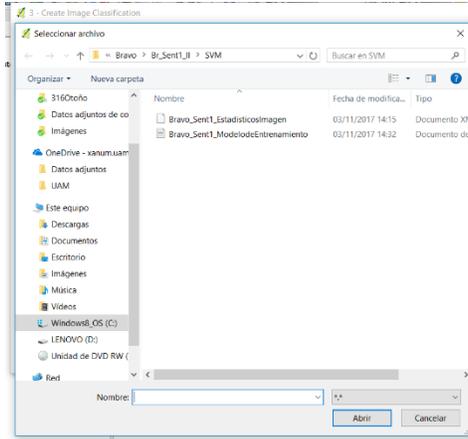
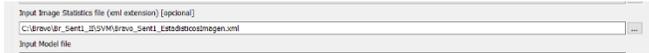


C.4. Para obtener la imagen clasificada: ⇒ Vaya a la caja de herramienta de orfeo ⇒ En la sección 0-Mapping seleccione la opción 3-Create Image Classification ⇒ Se desplegará una ventana ⇒ En la sección "Input Image" seleccione el raster que contiene las bandas apiladas

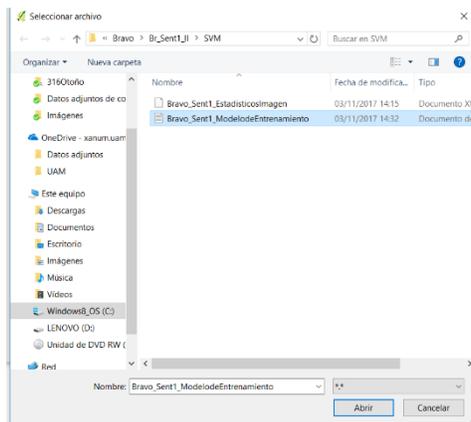




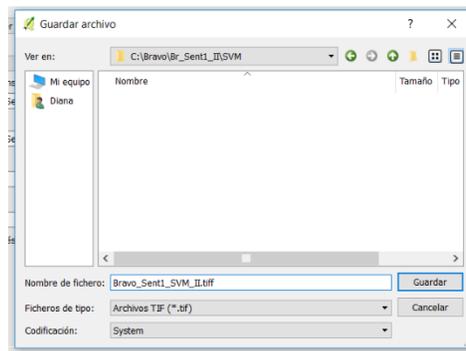
⇒ En la sección “Input Image stadistic file” seleccione el archivo .xml que guardo previamente en el paso II



⇒ En la sección “Input Model file” seleccione el archivo .xml que guardo previamente en el paso II

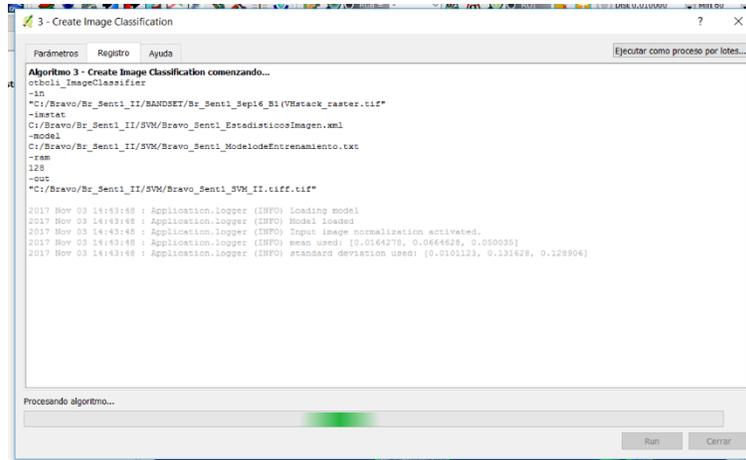
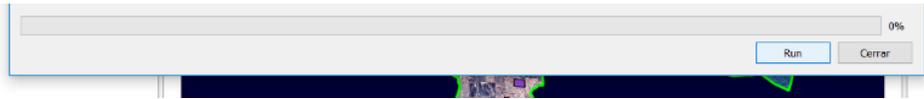


⇒ En la opción de imagen de salida seleccione la carpeta donde desea guardar el archivo y de un nombre con la extensión .tiff

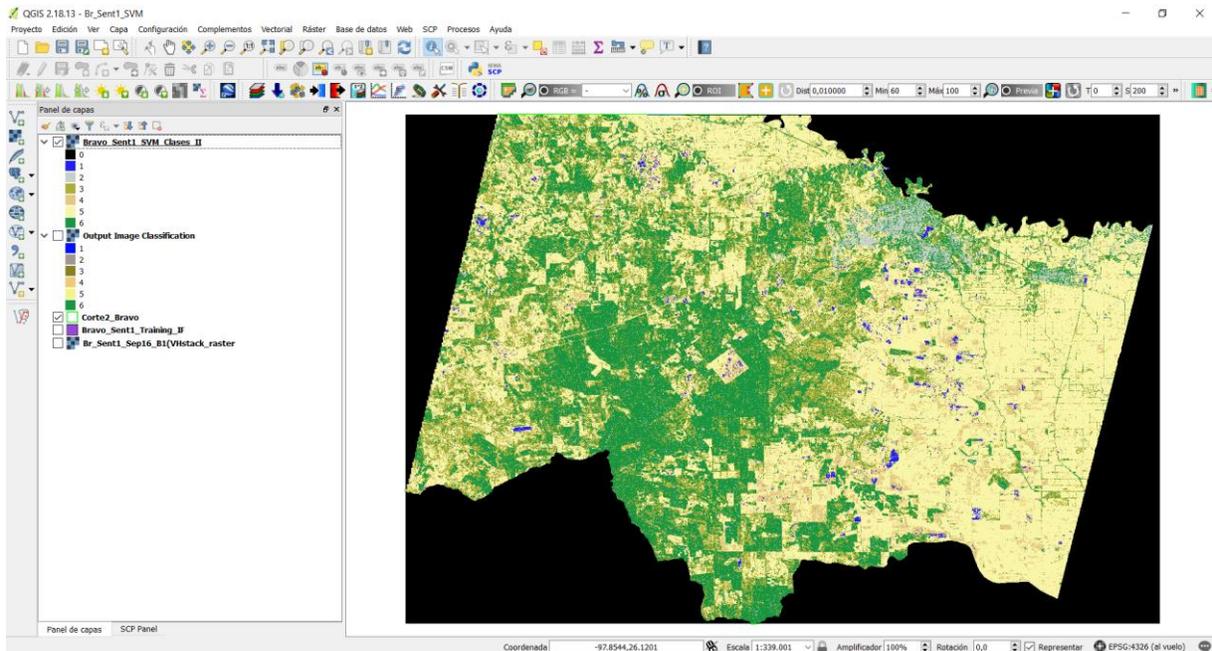




⇒ Corra el proceso



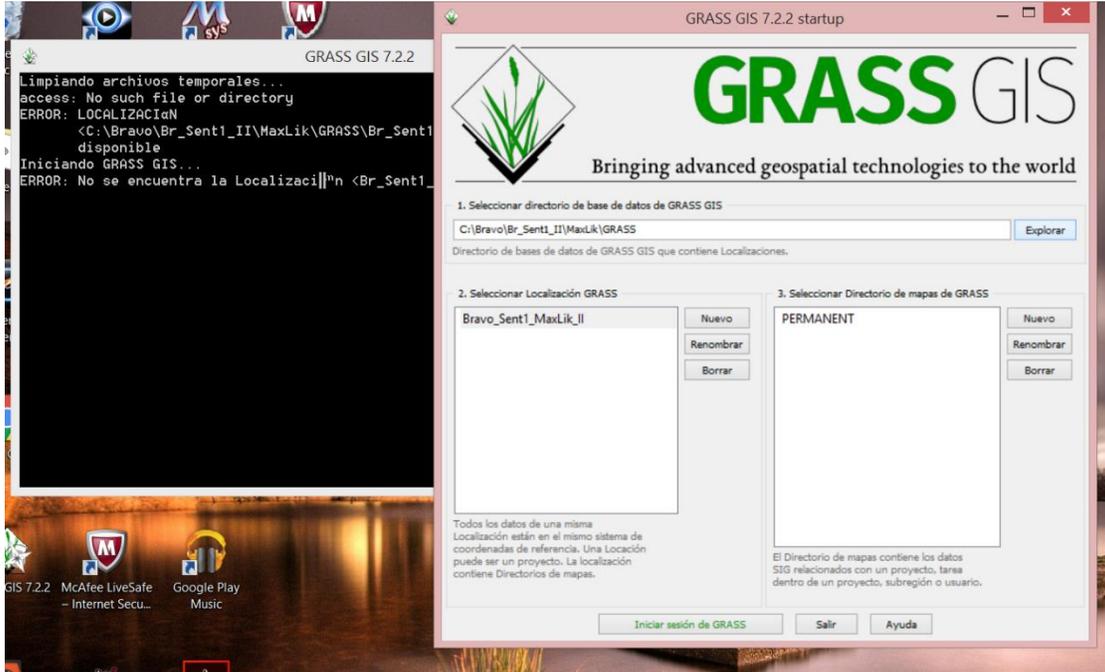
⇒ Se cargará la imagen clasificada



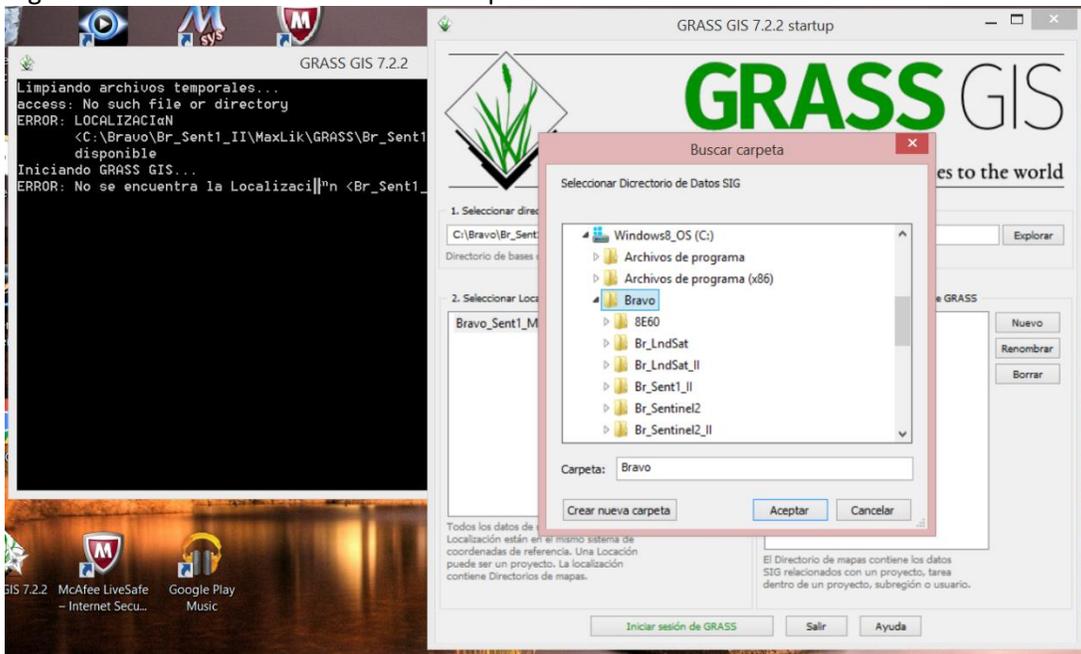


D. PROCEDIMIENTO PARA LA DETERMINACIÓN DE LA COBERTURA TERRESTRE UTILIZANDO EL ALGORITMO DE MÁXIMA VEROSIMILITUD CON EL PROGRAMA GRASS GIS

D.1. Abra el programa GRASS GIS ⇒ cargar el archivo vectorial de entrenamiento ⇒ abrir la caja de herramientas de Orfeo dando clic en Menú procesos ⇒ y la pestaña de caja de herramientas.

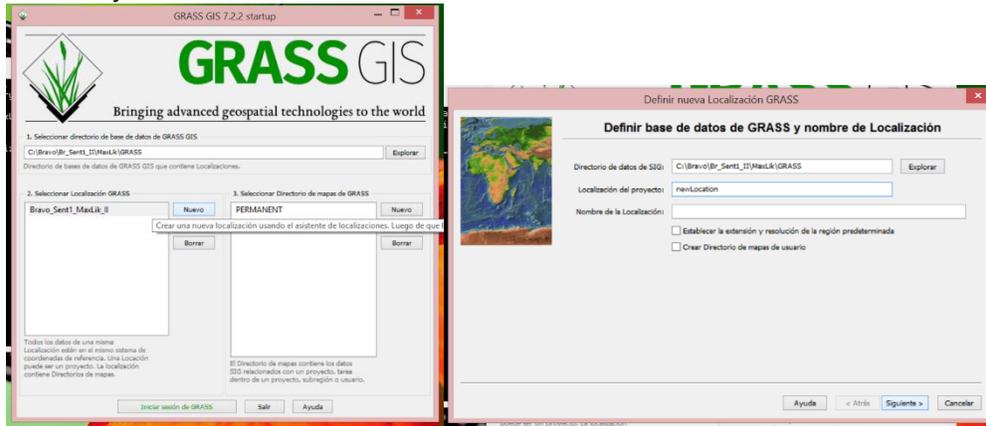


D.2. Seleccione la carpeta donde se archivara el para esto ⇒ De click en explorar y selecciones la careta donde desea guardad la locación ⇒ Selecciones aceptar.

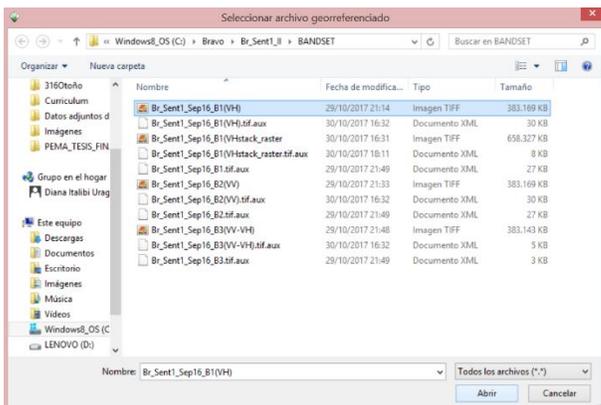
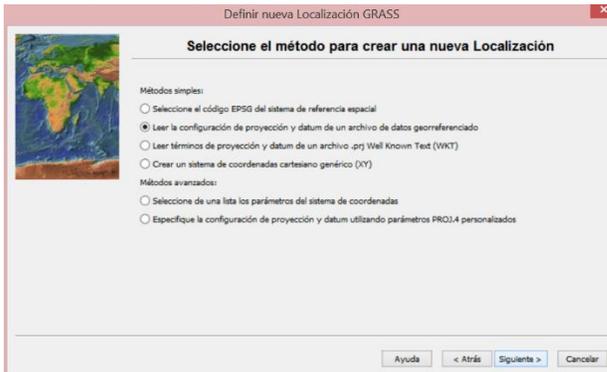




D.3. CREE UNA LOCALIÓN para esto ⇒ De click en Nuevo ⇒ Escriba el nombre de la nueva locación⇒ y la pestaña de caja de herramientas.

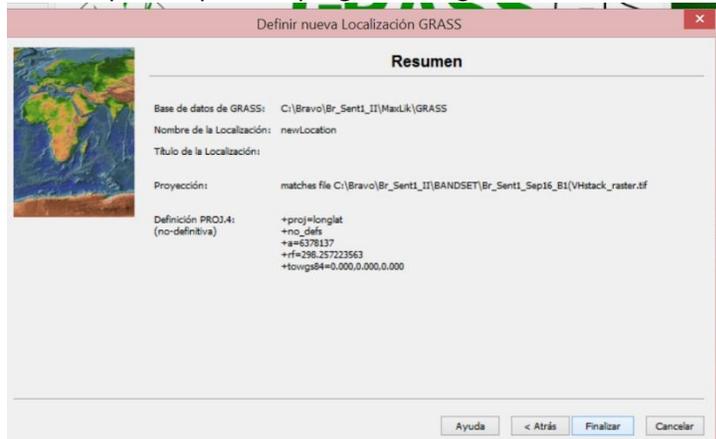


D.4. Para crearla a partir de un archivo georreferenciado ⇒ De click en explorar en la nueva ventana y seleccione en archivo de referencia ⇒ Escriba el nombre de la nueva locación⇒ y la pestaña de caja de herramientas.

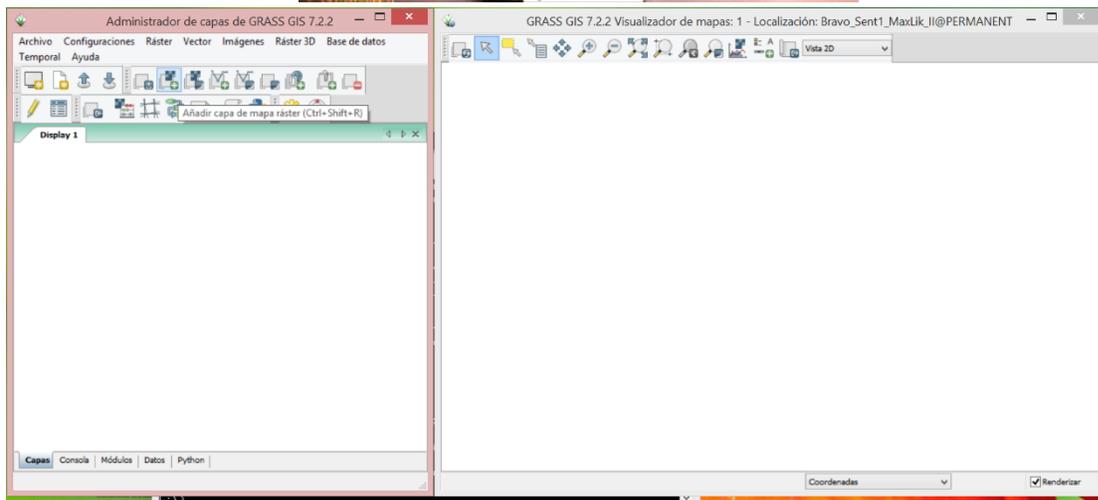
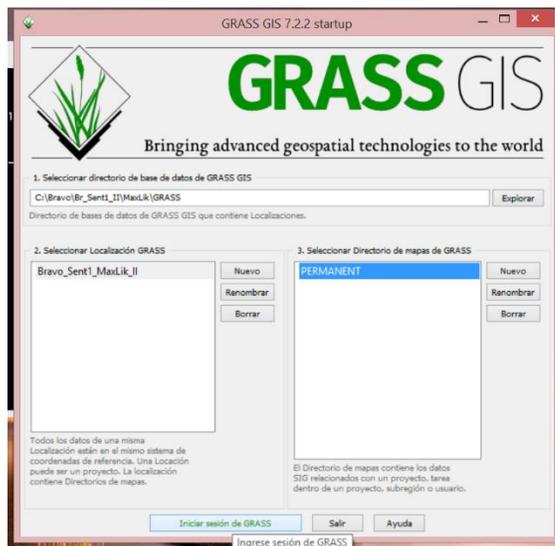




D.5. De click en aceptar ⇒ Espere a que el el programa cargue los datos ⇒ De click en aceptar

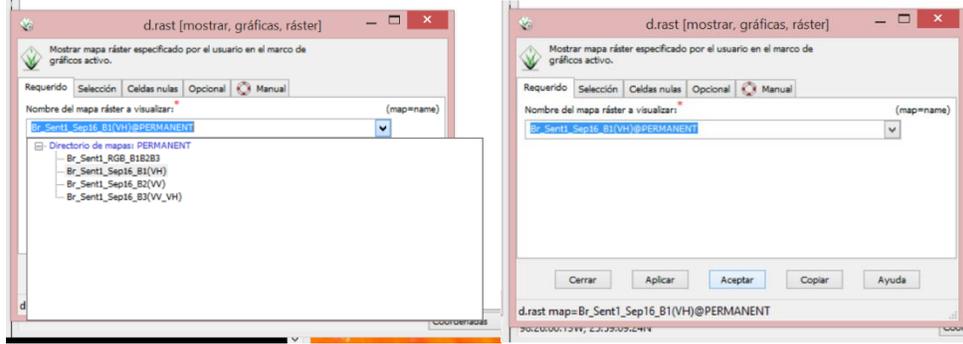


D.6. Seleccione Permanent o genere un nuevo Mapa y de Click en aceptar y espere a que se abra la pestaña

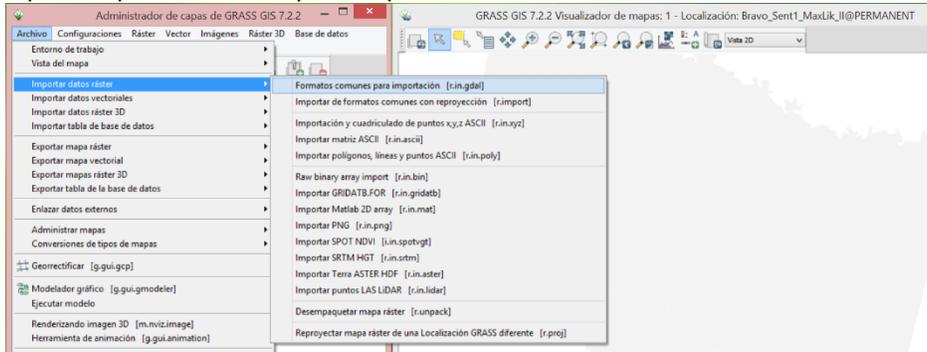




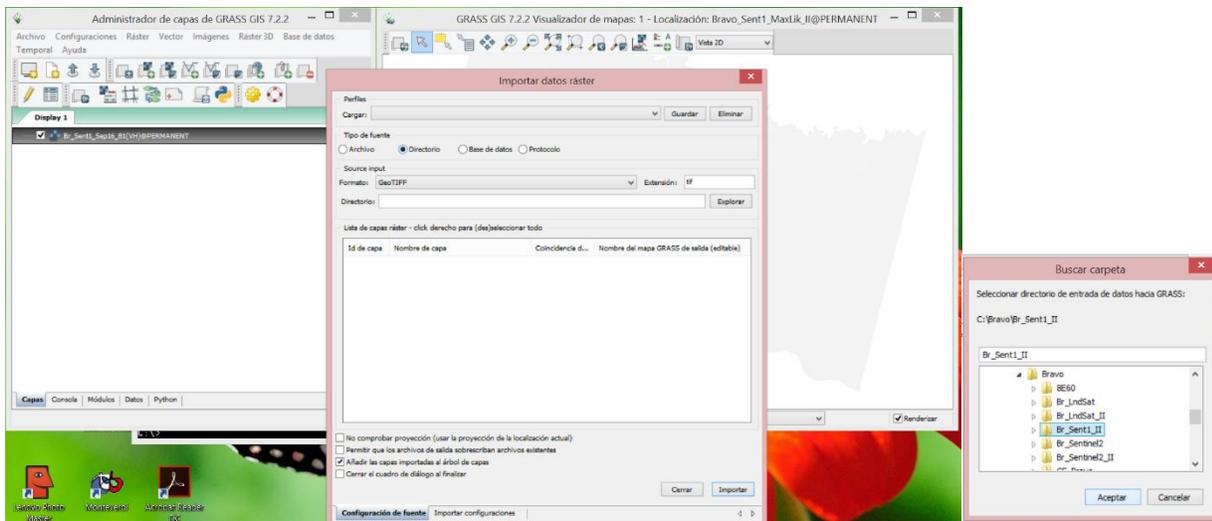
D.7. De click en el icono de añadir capa de mapa raster  ⇒ De click en aceptar y espere a que se abra la pestaña ⇒ Seleccione el raster que desea visualizar ⇒ De click en aceptar



D.8. Para agregar un nuevo raster valla a la pestaña Archivo⇒ De click en importar datos raster ⇒ Formatos comunes para importación ⇒ Espere a que abra la nueva ventana

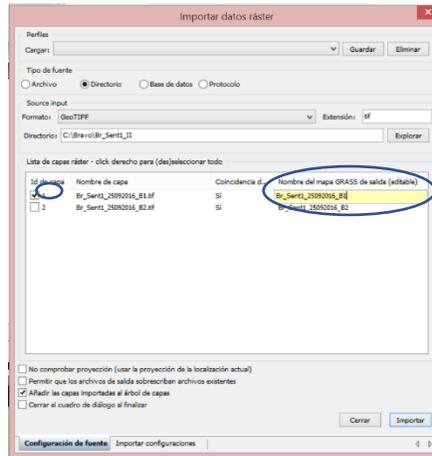


D.9. En la sección tipo de fuente de click en Directorio ⇒ En la sección de información fuente de click en explorar ⇒ Se abrirá una nueva ventana ⇒ Seleccione el directorio donde se encuentran los archivos a importar ⇒ En la sección de información fuente de click en explorar ⇒ Se abrirá una nueva ventana

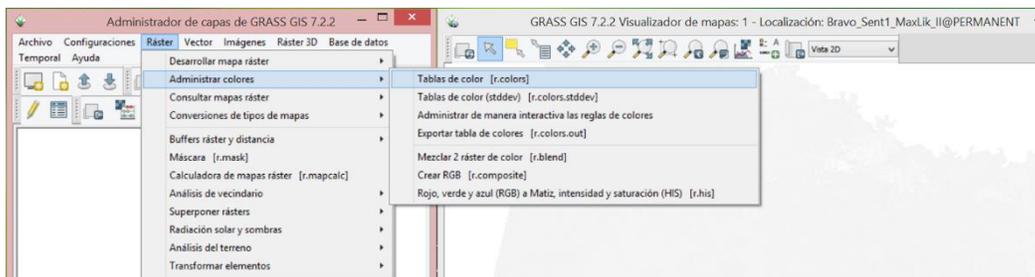




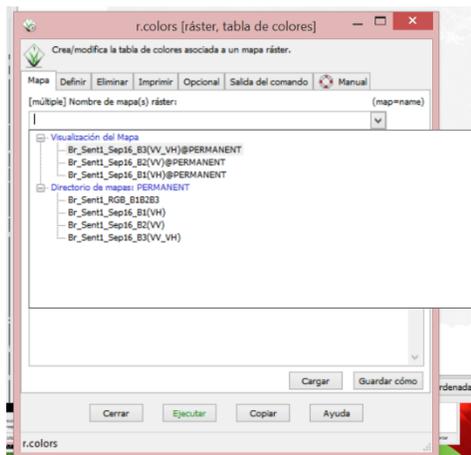
D.10. Seleccione las capas a importar y edite el nombre si es necesario ⇒ De click en importar y espere a que el proceso termine ⇒ Seleccione el directorio donde se encuentran los archivos a importar ⇒ Cierre la ventana



D.11. Para ecualizar el histograma valla a la pestaña Raster ⇒ Seleccione administrar colores ⇒ De click en tablas de color ⇒ espere hasta que se despliegue una nueva ventana

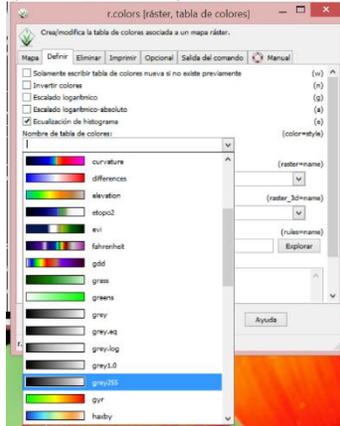


D.12. Vaya a la pestaña mapa ⇒ Seleccione los raster que desea ecualizar con el nombre del mapa ⇒ En esta sección puede escoger más de un mapa

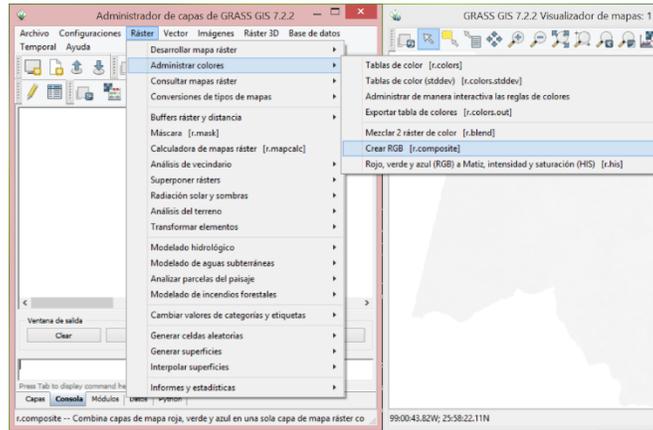




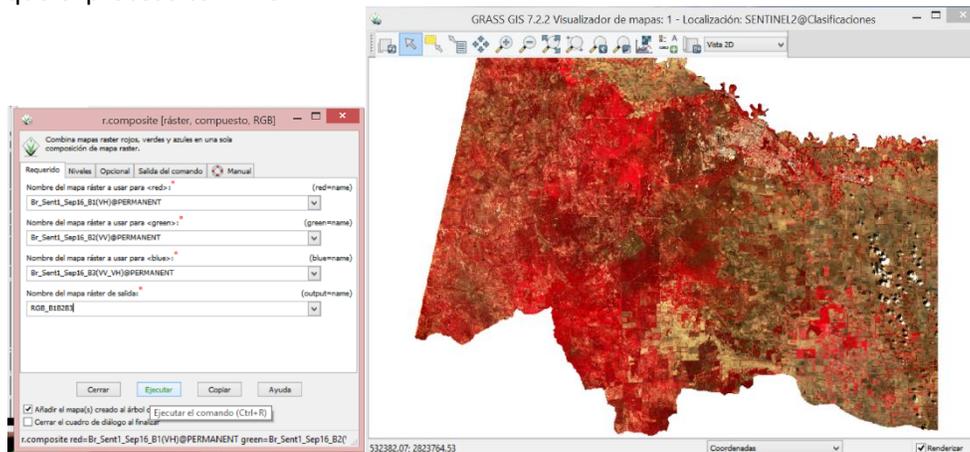
D.13. Vaya a la pestaña Definir ⇒ Seleccione la casilla de ecualización del histograma ⇒ Seleccione Grey 225 o cualquier otro color que dese aplicar y de click en ejecutar



D.14. Para ecualizar visualizar una combinación RGB ⇒ Vaya a la pestaña Raster ⇒ Seleccione Administrar colores ⇒ de click en Crear un archivo RGB

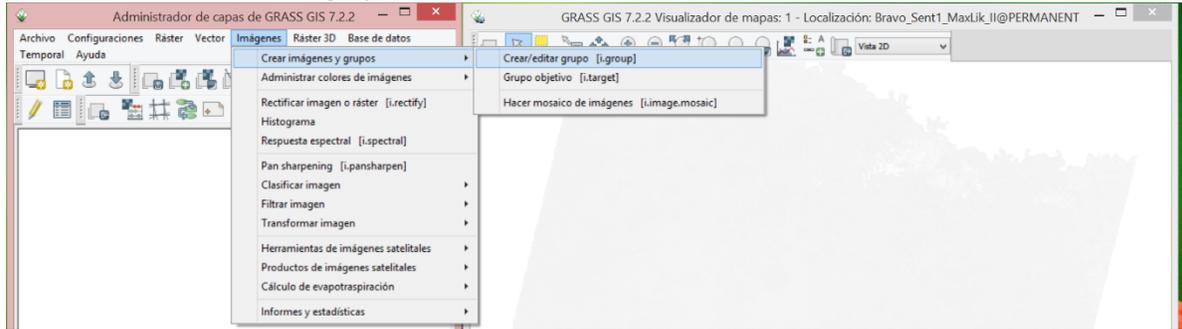


D.15. Para visualizar una combinación RGB ⇒ En la pestaña requerido ⇒ Seleccione el nombre del mapa raster a usar en para <red> <green> <blue> ⇒ Escriba el nombre del mapa raster de salida y de click en ejecutar ⇒ Espere hasta que el proceso termine

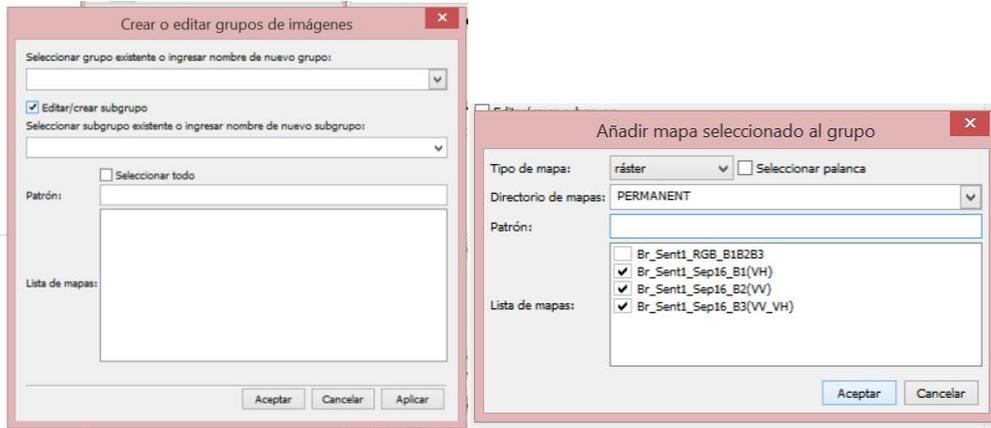




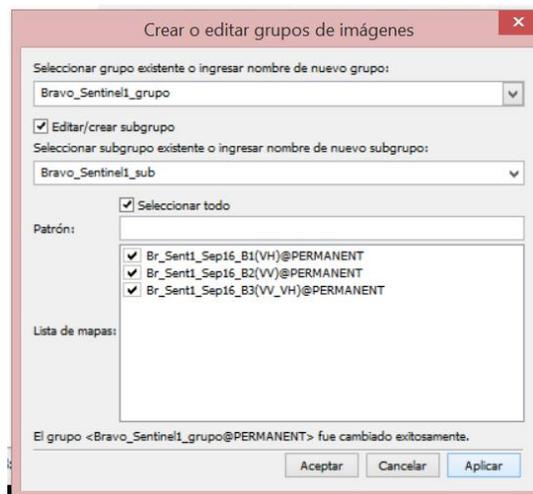
D.16. Para crear un grupo de imágenes ⇒ Vaya a la pestaña imágenes ⇒ Sitúese en crear imágenes y grupos ⇒ De click en Crear/editar grupo



D.17. Escriba el nombre del grupo el “Seleccionar grupo o ingresar nombre del nuevo grupo” ⇒ Vaya a la pestaña imágenes ⇒ Sitúese en crear imágenes y grupos ⇒ Seleccione la casilla Editar/Crear subgrupo

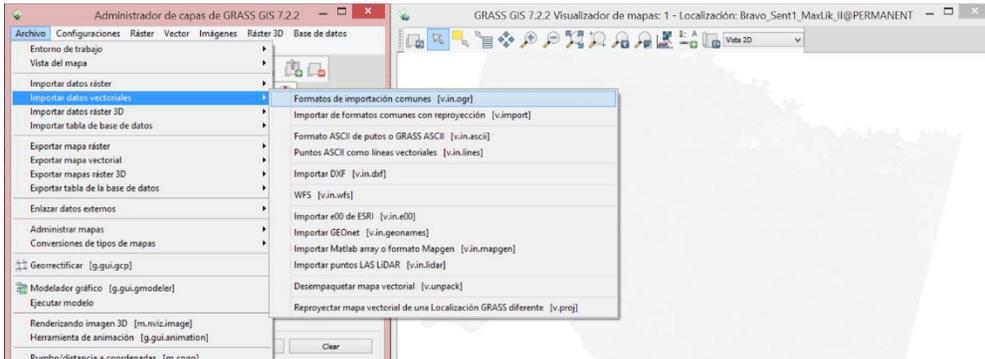


D.18. Para crear un subgrupo active la casilla Editar/crear subgrupo ⇒ escriba el nombre del subgrupo en la casilla “Seleccionar subgrupo existente o ingresar nombre del nuevo subgrupo” ⇒ Active la casilla seleccionar todo bien active las imágenes que desea integrar en el subgrupo ⇒ De click en aplicar ⇒ De click en aceptar.

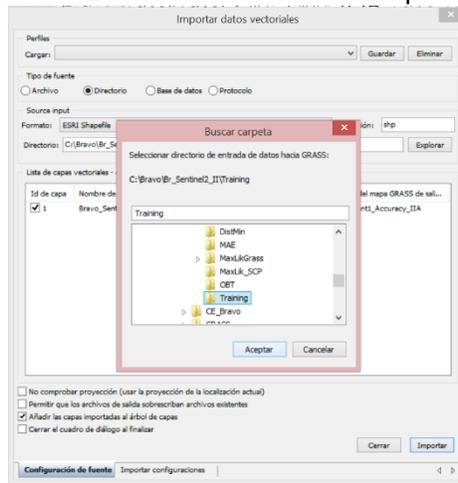




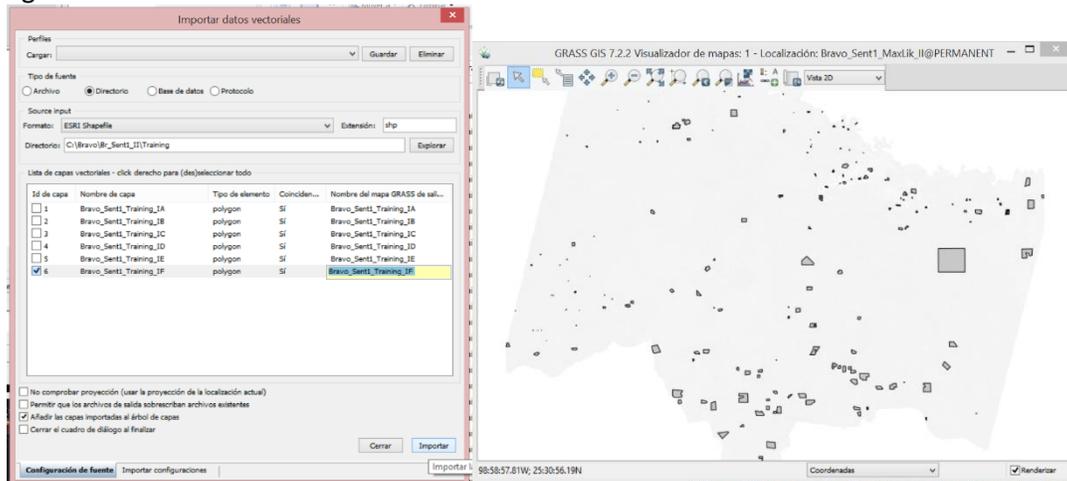
D.19. Para importar el archivo vectorial con las áreas de entrenamiento ⇒ Vaya a la pestaña Archivo ⇒ sitúese en importar datos vectoriales ⇒ de click en formatos de importación comunes ⇒ espere a que abra la nueva ventana



D.20. Seleccione directorio en tipo de fuente ⇒ de click en explorar y espere aparezca una nueva ventana ⇒ Seleccione la tarjeta donde se encuentra el archivo ⇒ de click en aceptar

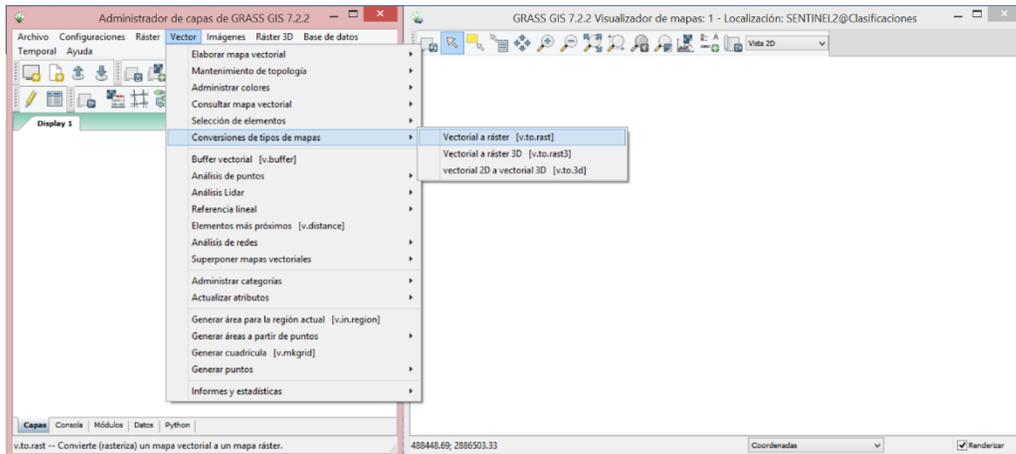


D.21. Seleccione el archivo que contiene las áreas de entrenamiento ⇒ de Click en Importar y espere a que la capa se cargue

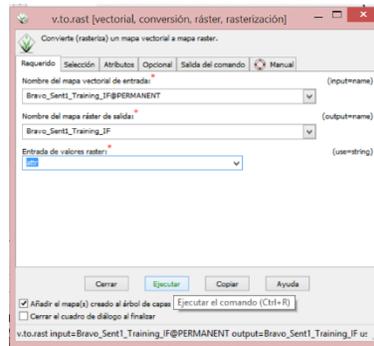




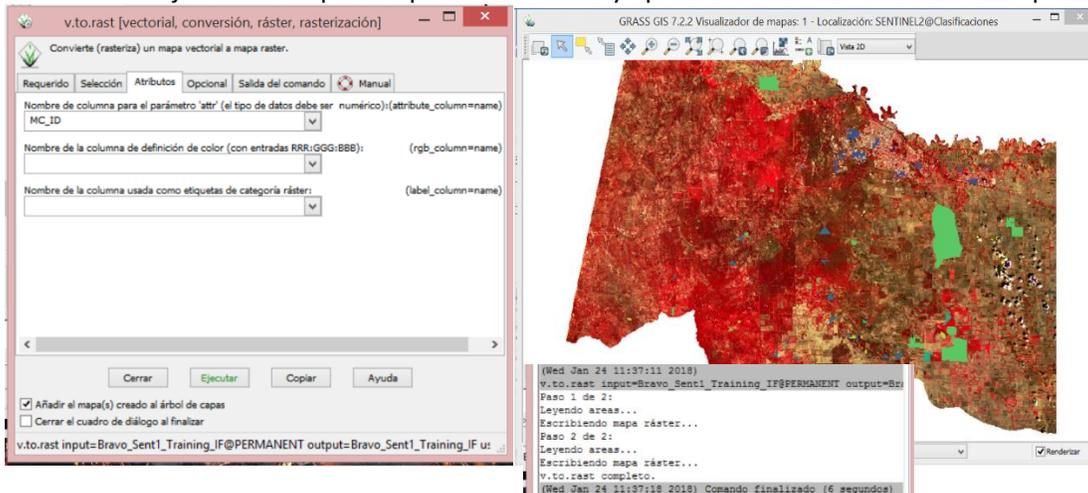
D.22. Para convertir el archivo vectorial a un archivo en formato raster ⇒ Vaya al Menú Vector ⇒ Colóquese en la sección Conversiones de tipos de mapas ⇒ De click en Vectorial a Raster ⇒ Espere a que se muestre la ventana



D.23. En la pestaña de Requerido de la nueva ventana seleccione el Nombre del mapa vectorial de entrada en la casilla correspondiente ⇒ Escriba el Nombre del mapa vectorial de entrada en la casilla correspondiente⇒ Seleccione attr en la casilla de entrada de valores raster ⇒ De click en Vectorial a Raster ⇒ Espere a que se muestre la ventana

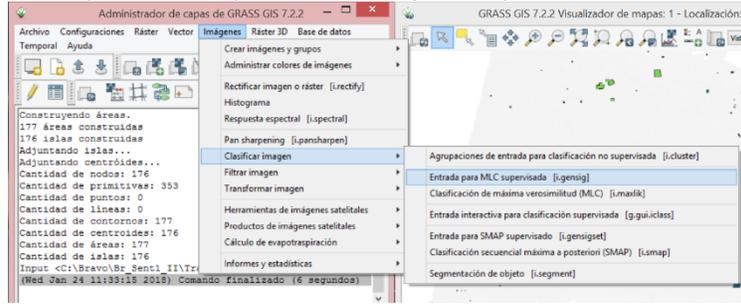


D.24. En la pestaña de Atributos seleccione el Nombre del atributo que desea se cargue en la información del raster ⇒ De click en ejecutar ⇒ Espere el proceso termine y aparezca en el Visualizador de mapas

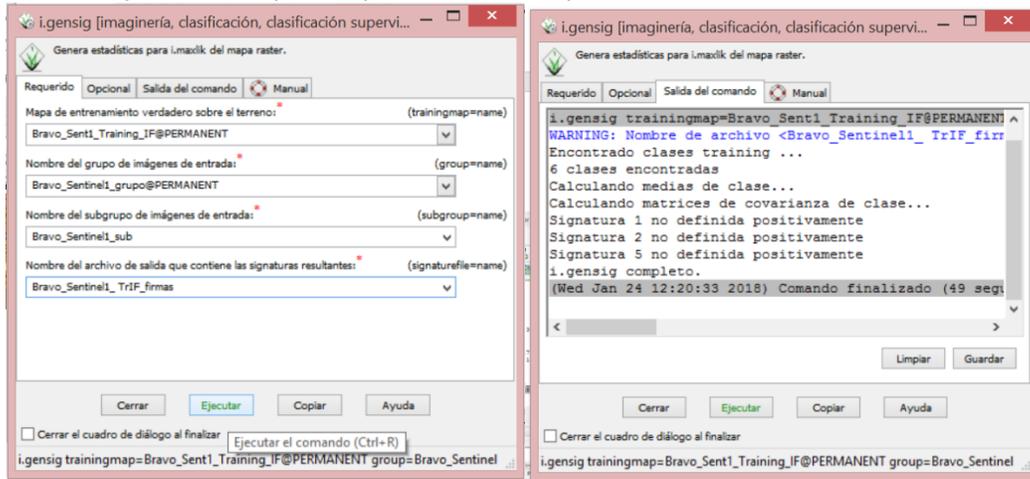




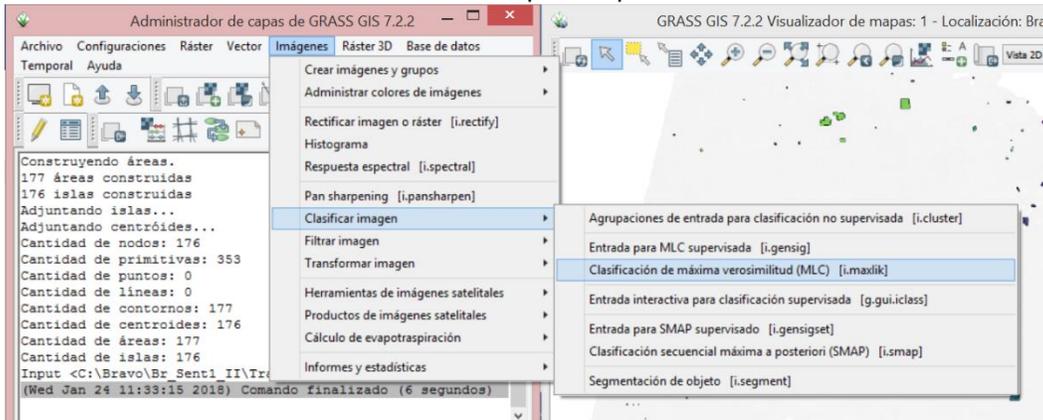
D.25. Para entrenar el algoritmo de clasificación vaya a la pestaña Imágenes ⇒ colóquese en Clasificar imágenes ⇒ De click en entrada para MLC supervisada ⇒ Espere a que se abra la ventana.



D.26. En la pestaña de Requerido de la nueva ventana ⇒ Seleccione el Mapa de entrenamiento verdadero sobre el terreno es decir el archivo que contiene las áreas de entrenamiento en formato raster ⇒ Seleccione nombre del grupo de imágenes de entrada ⇒ Seleccione nombre del subgrupo de imágenes de entrada ⇒ Escriba el nombre que desea darle al archivo de salida que contendrá las firmas espectrales al terminar el proceso ⇒ De click en Ejecutar ⇒ Espere el proceso termine y el archivo sea creado.

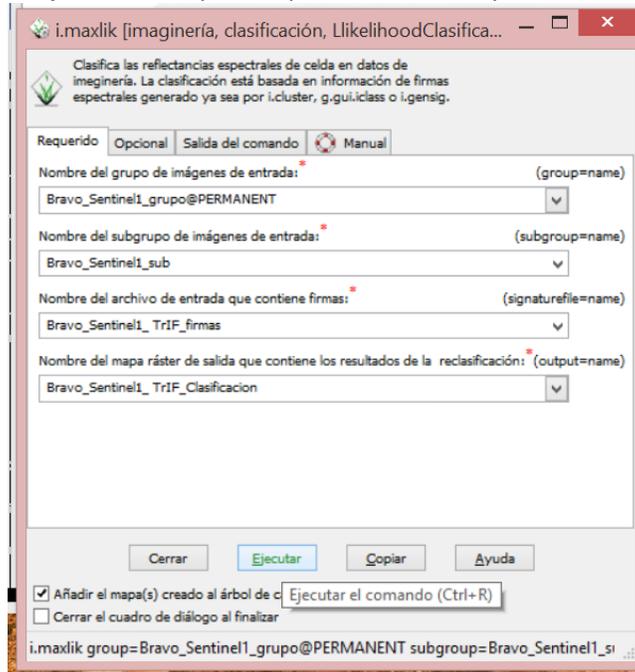


D.27. Para obtener la imagen clasificada vaya a la pestaña Imágenes ⇒ colóquese en Clasificar imágenes ⇒ De click en Clasificación de máxima verosimilitud ⇒ Espere a que se abra la ventana.

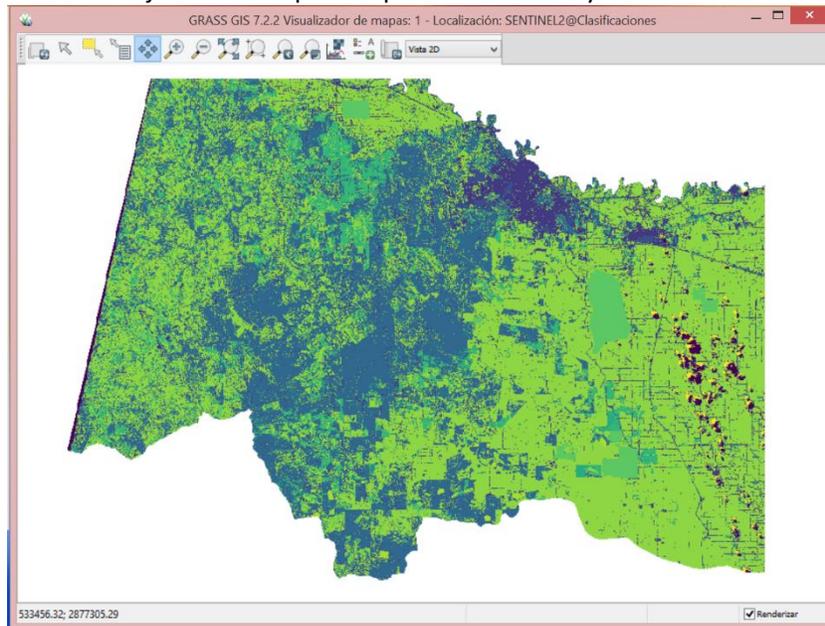




D.28. En la pestaña de Requerido de la nueva ventana ⇒ Seleccione nombre del grupo de imágenes de entrada ⇒ Seleccione nombre del subgrupo de imágenes de entrada ⇒ Seleccione del archivo de salida que contiene las firmas espectrales ⇒ Escriba el nombre que desea darle al archivo de salida que contendrá la imagen clasificada ⇒ De click en Ejecutar ⇒ Espere el proceso termine y el archivo sea creado.

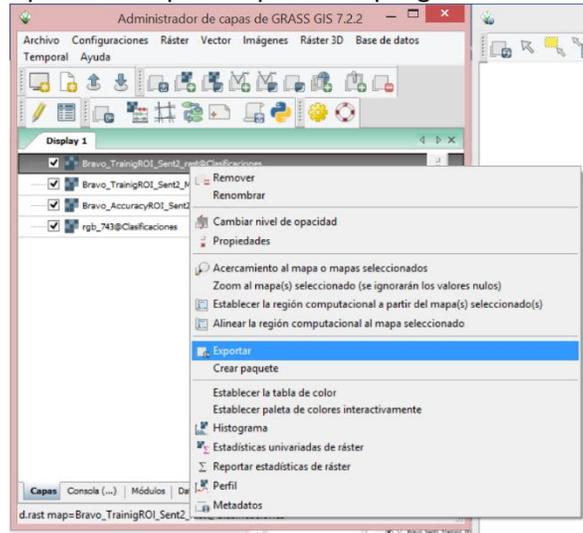


D.29. En la pestaña de Requerido de la nueva ventana ⇒ Seleccione nombre del grupo de imágenes de entrada ⇒ Seleccione nombre del subgrupo de imágenes de entrada ⇒ Seleccione del archivo de salida que contiene las firmas espectrales ⇒ Escriba el nombre que desea darle al archivo de salida que contendrá la imagen clasificada ⇒ De click en Ejecutar ⇒ Espere el proceso termine y el archivo sea creado.

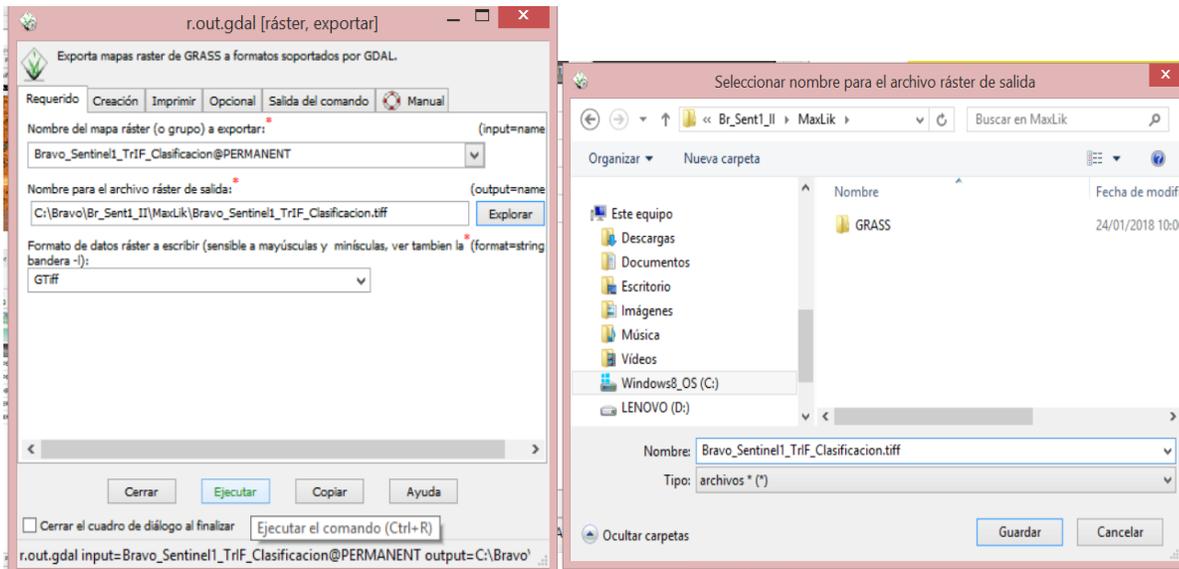




D.30. Para exportar el archivo de la clasificación de Click secundario en el archivo que se encuentra en la pestaña de capas ⇒ De click en Exportar ⇒ Espere a que se despliegue la ventana para exportar.



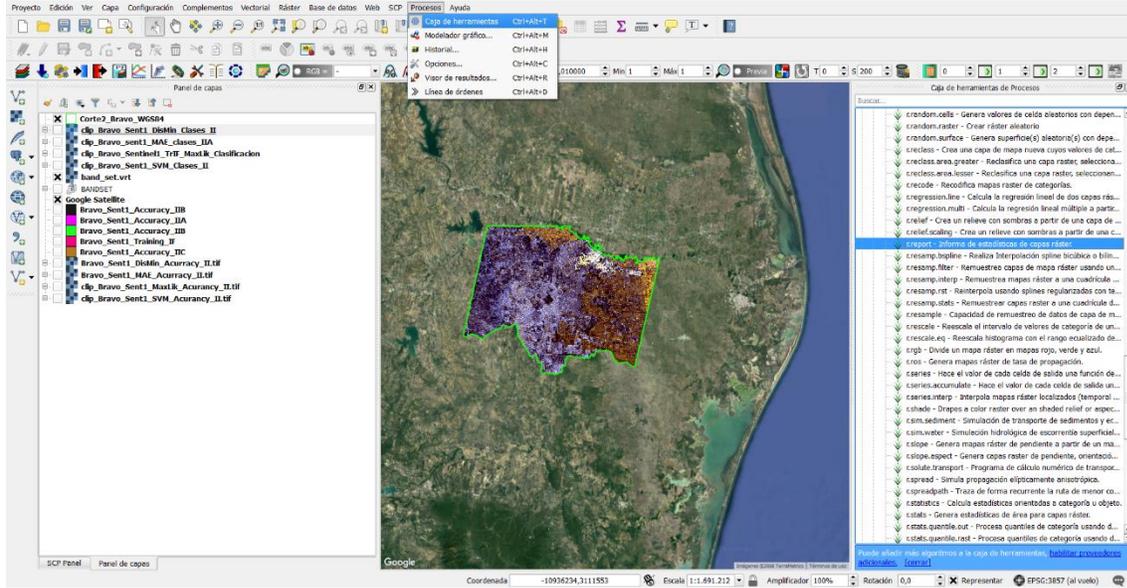
D.31. En la pestaña de Requerido de la nueva ventana ⇒ Seleccione nombre Mapa raster a exportar ⇒ Seleccione el formato de salida deseado ⇒ de click en explorar ⇒ Seleccione la carpeta donde desea guardar el archivo ⇒ Escriba el nombre del archivo con la extensión correspondiente⇒ De click en ejecutar ⇒ Espere el proceso termine y el archivo sea creado.



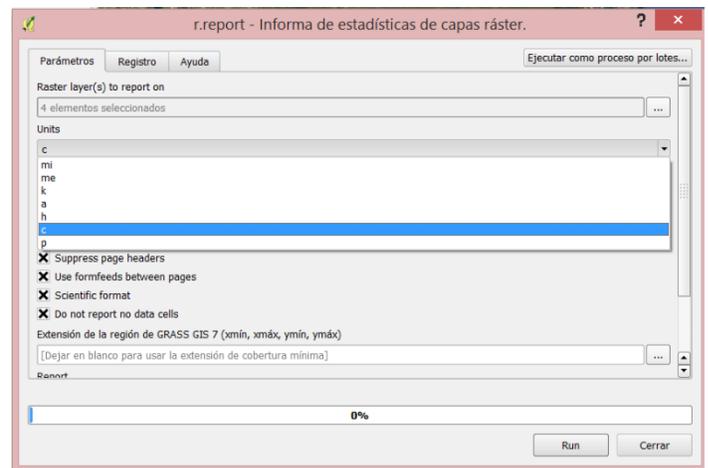
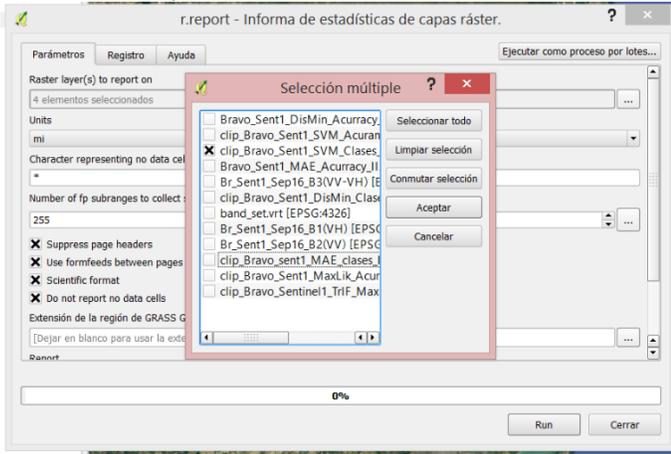


E. PROCEDIMIENTO PARA OBTENER LAS ESTADÍSTICAS DE UN RASTER UTILIZANDO LA CAJA DE HERAMIENTAS DE PROCESOS DE GRAS GISS DENTRO DEL PROGRAMA QGIS

E.1. Para obtener las estadísticas de un raster vaya a la pestaña procesos ⇒ Seleccione caja de herramientas ⇒ espere a que aparezca el panel caja de herramientas de proceso Busque el proceso r.report de GRASS GIS y de click en el ⇒ Espere a que se desplegué la nueva ventana



E.2. Seleccione las capas raster a reportar dando click en icono con tres puntos y seleccionándolo en la nueva pestaña ⇒ De click en aceptar ⇒ en unidades selecciones las deseadas ⇒ De click en correr y guarde el archivo temporal como se realiza usualmente en QGIS.





ANEXO 2



TABLAS Y ECUACIONES UTILIZADAS EN LA REGIÓN DEL BAJO BRAVO

Valor de k de tablas para Bravo

Tipo de Cobertura terrestre en la subcuenca Bajo Bravo			Factor K = f(Suelo)		
Clase	Categoría de Mapa	Categoría obtenida de tablas de K	Suelo A-1	Suelo B-2	Suelo C-3
0	No clasificado	Definición propia	0	0	0
1	Cuerpo de Agua	Definición propia	0	0	0
2	Urbano	Asentamiento humano (Tabla 3.1.14)	0.26	0.29	0.32
3	Mezquital-Xerófilo	Mezquital, incluye huizache (Tabla 3.1.14)	0.22	0.28	0.30
4	Suelo Desnudo	Área sin vegetación aparente (Tabla 3.1.14)	0.26	0.28	0.3
5	Agricultura-Pastizal	Agricultura... (Tabla 3.1.14)	0.24	0.27	0.3
6	Matorral	Matorral(Tabla 3.1.14)	0.22	0.28	0.3
7	Nube	Definición propia	0	0	0
8	Sombra	Definición propia	0	0	0

EQUIVALENCIA DE SUELO

Información de raster	Textura	Tipo de Suelo
1	GRUESA	A
2	MEDIANA	B
3	FINA	C



CODIGO del programa						
Clas e	Suelo		Ka	Instrucción	ID	
0	1	A	Null			
	2	B	Null			
	3	C	Null			
1	1	A	0	if(CT== 1, 0,	a	1
	2	B	0	a		
	3	C	0	a		
2	1	A	0.26	if(CT== 2 CT== 4 && Text== 1, 0.26,	b	2
	2	B	0.29	if(CT== 2 && Text== 2, 0.29,	c	3
	3	C	0.32	if(CT== 2 && Text== 3, 0.32,	d	4
3	1	A	0.22	if(CT== 3 CT== 6 && Text== 1, 0.22,	e	5
	2	B	0.28	if(CT== 3 CT== 4 CT== 6 && Text== 2, 0.28,	f	6
	3	C	0.30	if(CT== 3 CT== 4 CT== 5 CT== 6 && Text== 3, 0.3,	g	7
4	1	A	0.26	b		
	2	B	0.28	f		
	3	C	0.30	g		
5	1	A	0.24	if(CT== 5 && Text== 1, 0.24,	h	8
	2	B	0.27	if(CT== 5 && Text== 2, 0.27))))))	i	9
	3	C	0.3	g		
6	1	A	0.22	e		
	2	B	0.28	f		
	3	C	0.30	g		
7	1	A	Null			
	2	B	Null			
	3	C	Null			
8	1	A	Null			
	2	B	Null			
	3	C	Null			

ALGORITMO PARA GENERAR CONSTANTE Kv

if(CT== 1, 0, if(CT== 2 || CT== 4 && Text== 1, 0.26, if(CT== 2 && Text== 2, 0.29, if(CT== 2 && Text== 3, 0.32, if(CT== 3 || CT== 6 && Text== 1, 0.22, if(CT== 3 || CT== 4 || CT== 6 && Text== 2, 0.28, if(CT== 3 || CT== 4 || CT== 5 || CT== 6 && Text== 3, 0.3, if(CT== 5 && Text== 1, 0.24, if(CT== 5 && Text== 2, 0.27)))))))))

ALGORITMO PARA DETERMINAR EL COEFICIENTE DE ESCURRIMIENTO

if(K <= 0.15 , ((K* (P-250))/2000) ,(P-250)/2000)+((K-0.15)/1.5))



TABLAS Y ECUACIONES UTILIZADAS EN LA REGIÓN DEL BAJO GRIJALVA

Valor de k de tablas para Bajo Grijalva

Clase	Tipo de Cobertura terrestre en la subcuenca Bajo Grijalva		Factor K = f(Suelo)		
	Categoría de Mapa	Categoría obtenida de tablas de K	Suelo A-1	Suelo B-2	Suelo C-3
0	No clasificado	Definición propia	0	0	0
1	Cuerpo de Agua	Definición propia	0	0	0
2	Urbano	Asentamiento humano (Tabla 3.1.14)	0.26	0.29	0.32
3	Manglar	Selva Baja ... (Tabla 3.1.14)	0.17	0.26	0.28
4	Suelo Desnudo	Área sin vegetación aparente (Tabla 3.1.14)	0.26	0.28	0.3
5	Agricultura-Pastizal	Agricultura... (Tabla 3.1.14)	0.24	0.27	0.3
6	Vegetación Sumergida	Vegetación halófila y gipsófila... (Tabla 3.1.14)	0.05	0.05	0.05
7	Zona Inundada	Definición propia	0	0	0
8	Nube	Definición propia	0	0	0
9	Sombra	Definición propia	0	0	0

EQUIVALENCIA DE SUELO

Información de raster	Textura	Tipo de Suelo
1	GRUESA	A
2	MEDIANA	B
3	FINA	C



TABLAS Y ECUACIONES UTILIZADAS EN LA REGIÓN DEL BAJO VALLE MÉXICO

Valor de k de tablas para Valle México

Tipo de Cobertura terrestre de subcuenca del Valle de México			Factor K = f(Suelo)		
Clase	Categoría de Mapa	Categoría obtenida de tablas de K	Suelo A-1	Suelo B-2	Suelo C-3
0	No clasificado	Definición propia	0	0	0
1	Cuerpo de Agua	Definición propia	0	0	0
2	Urbano	Asentamiento humano (Tabla 3.1.14)	0.26	0.29	0.32
3	Bosque	Bosque (Tabla 3.1.14)	0.07	0.16	0.24
4	Suelo Desnudo	Área sin vegetación aparente (Tabla 3.1.14)	0.26	0.28	0.3
5	Agricultura-Pastizal	Agricultura... (Tabla 3.1.14)	0.24	0.27	0.3
6	Matorral	Matorral(Tabla 3.1.14)	0.22	0.28	0.3
7	Nube	Definición propia	¿?	¿?	¿?
8	Sombra	Definición propia	¿?	¿?	¿?

EQUIVALENCIA DE SUELO

Información de raster	Textura	Tipo de Suelo
1	GRUESA	A
2	MEDIANA	B
3	FINA	C



Casa abierta al tiempo

UNIVERSIDAD AUTÓNOMA METROPOLITANA

ACTA DE EXAMEN DE GRADO

No. 00037

Matrícula: 2161801601

ANÁLISIS DE CONVENIENCIA DE
IMÁGENES SATELITALES DE
ACCESO ABIERTO PARA LA
DETERMINACIÓN DE
COEFICIENTES DE ESCURRIMIENTO

En la Ciudad de México, se presentaron a las 16:00 horas del día 8 del mes de junio del año 2018 en la Unidad Iztapalapa de la Universidad Autónoma Metropolitana, los suscritos miembros del jurado:

DR. EUGENIO GOMEZ REYES
DRA. CLAUDIA ROJAS SERNA
DR. JOSE LUIS SILVAN CARDENAS



DIANA ITALIBI URAGA TOVAR
ALUMNA

Bajo la Presidencia del primero y con carácter de Secretario el último, se reunieron para proceder al Examen de Grado cuya denominación aparece al margen, para la obtención del grado de:

MAESTRA EN CIENCIAS (ENERGIA Y MEDIO AMBIENTE)

DE: DIANA ITALIBI URAGA TOVAR

y de acuerdo con el artículo 78 fracción III del Reglamento de Estudios Superiores de la Universidad Autónoma Metropolitana, los miembros del jurado resolvieron:

aprobar

Acto continuo, el presidente del jurado comunicó a la interesada el resultado de la evaluación y, en caso aprobatorio, le fue tomada la protesta.

REVISÓ

LIC. JULIO CESAR DE LARANSASSI
DIRECTOR DE SISTEMAS ESCOLARES

DIRECTOR DE LA DIVISIÓN DE CBI

DR. JESUS ALBERTO OCHOA TAPIA

PRESIDENTE

DR. EUGENIO GOMEZ REYES

VOCAL

DRA. CLAUDIA ROJAS SERNA

SECRETARIO

DR. JOSE LUIS SILVAN CARDENAS