



**UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO**

---

**FACULTAD DE INGENIERÍA**

**Procesamiento y clasificación de imágenes  
satelitales para la detección de crecimientos  
urbanos y rurales aplicando aprendizaje  
automático**

**INFORME DE ACTIVIDADES PROFESIONALES**

Que para obtener el título de

**Ingeniero Geofísico**

**P R E S E N T A**

Guillermo Isaac Nájera Rocha

**ASESOR DE INFORME**

M.C. Sergio Salinas Sánchez



**Ciudad Universitaria, Cd. Mx., 2022**

---

---

---

*Dedicatoria*

*Para mi madre y mi hermana:*

*Sin ustedes nada de esto hubiera sido posible.*

---

---

---

---

---

## *Agradecimientos*

A mi mamá Martha, por su amor incondicional y su incalculable comprensión. A pesar de todas esas decisiones que he tomado y pudieran haber parecido inciertas, nunca dudó de mí. Este logro es suyo.

A mi hermana Rosalinda, mi compañera de vida que siempre me ha demostrado su amor en todas las formas existentes. Sin su apoyo no habría llegado a este momento.

A la Universidad Nacional Autónoma de México, por brindarme la oportunidad de desarrollarme profesional y personalmente y por haber sido mi segunda casa desde los 15 años.

Al Dr. Ernesto Caetano, por su guía y consejos y por inspirarme a continuar en la incansable búsqueda del conocimiento.

Al M.C Sergio Salinas, por su muestra de solidaridad para conmigo cuando más lo necesitaba, además de sus consejos para terminar este trabajo.

A todos mis amigos que estuvieron en los mejores y en los peores momentos. En especial a Erasmo, que con su mente tan brillante nos sacó de apuros un sinnúmero de ocasiones; su humildad y compañerismo me hicieron comprender el completo significado de amistad. A Angélica, que desde el primer día en que nos dirigimos la palabra no hemos vuelto a separarnos; las noches en vela, las risas, las frustraciones y las palabras de aliento, todo se sintió mejor en su compañía.

---

---

---



## Índice.

1. Introducción
  - 1.1. Instituto Nacional de Estadística y Geografía
  - 1.2. Participación Profesional
  
2. Antecedentes
  - 2.1. Percepción Remota
  - 2.2. Imágenes Satelitales
  - 2.3. *Machine Learning*
  - 2.4. Clasificación Supervisada
  - 2.5. *Decision Tree*
  - 2.6. Definición del problema
  
3. Metodología
  - 3.1. Clasificación No Supervisada
  - 3.2. Clasificación Supervisada Aplicando *Machine Learning*
    - 3.2.1. Caso de Estudio 1: Tequila, Jalisco
    - 3.2.2. Caso de Estudio 2: Santa Lucía
  
4. Análisis de Resultados
  - 4.1. Caso de Estudio 1: Tequila, Jalisco
  - 4.2. Caso de Estudio 2. Santa Lucía
  
5. Conclusiones
  
6. Referencias
  
7. Anexo 1: Scrpit  
  
Anexo 2: Glosario

## 1. Introducción.

### 1.1. Instituto Nacional de Estadística y Geografía.

El Instituto Nacional de Estadística y Geografía (INEGI) es un organismo público autónomo responsable de normar y coordinar el Sistema Nacional de Información Estadística y Geográfica, así como de captar y difundir información de México en cuanto al territorio, los recursos, la población y economía, que permita dar a conocer las características de nuestro país y ayudar a tomar decisiones.

Se creó el 25 de enero de 1983 por decreto presidencial integrando en su estructura a la Dirección General de Estadística (dependencia de la Secretaría de Fomento, Colonización, Industria y Comercio), a la Dirección General de Geografía (adscrita a la Secretaría de la Presidencia), a la Dirección General de Política Informática y a la Dirección General de Integración y Análisis de la Información.

Con su creación, el INEGI modernizó los métodos en materia de captación, procesamiento y difusión de la información acerca del territorio, población y economía y se conjuntó en una sola institución.

Desde 1985, el Instituto se desconcentró para ubicar su sede en la ciudad de Aguascalientes, Aguascalientes (INEGI, 2022).

#### *Misión*

*“Suministrar a la sociedad y al Estado información estadística y geográfica de Interés Nacional de calidad, pertinente, veraz y oportuna, para coadyuvar al desarrollo nacional”*

#### *Visión*

*“La información de Interés Nacional sea la referencia para el Estado y la sociedad en la toma de decisiones para el desarrollo nacional”*

El INEGI es el encargado de difundir material de consulta y descarga de información estadística y geográfica de interés para la sociedad mexicana, con una gran diversidad temática y con distintos niveles de desagregación, y todo de forma gratuita.

Conforme a lo establecido en el artículo 17 de la Ley del Sistema Nacional de Estadística y Geografía (LSNIEG), actualmente se cuenta con cuatro Subsistemas Nacionales de Información: Demográfico y Social; Económico; Geográfico y del Medio Ambiente; Gobierno, Seguridad Pública e Impartición de Justicia.

En la componente geográfica, el Subsistema Nacional de Información Geográfica y del Medio Ambiente, genera a través de la Dirección de Modelado Topográfico, el procesamiento de imágenes de alta resolución para la actualización anualizada de la Base Cartográfica Única en su ámbito Urbano (BCUU) y en el Departamento de Altimetría del Relieve Continental, la clasificación de imágenes de percepción remota para la detección de crecimientos urbanos y viviendas rurales.

En el proyecto de BCU se han implementado diversas técnicas para la clasificación de imágenes, siendo el Aprendizaje Automático ("*Machine Learning*" por su término en inglés"), la última propuesta que busca aumentar la eficiencia y calidad de los procesos.

El *Machine Learning* es una rama de la Inteligencia Artificial (IA) que aplica técnicas bayesianas para el reconocimiento y aprendizaje de patrones (Amazon, 2022), por lo que su implementación en el proyecto de BCUU ha generado buenos resultados preliminares en cuestiones de tiempo y gasto computacional. Esto a partir de Sentinel-2 con resolución de 10 metros, así como con ortofotos con resolución de 0.5 metros. El algoritmo de *Machine Learning* utilizado en la clasificación supervisada es conocido como "árboles de decisión" (Somvanshi et. al., 2016) fue desarrollado en el lenguaje de programación Python.

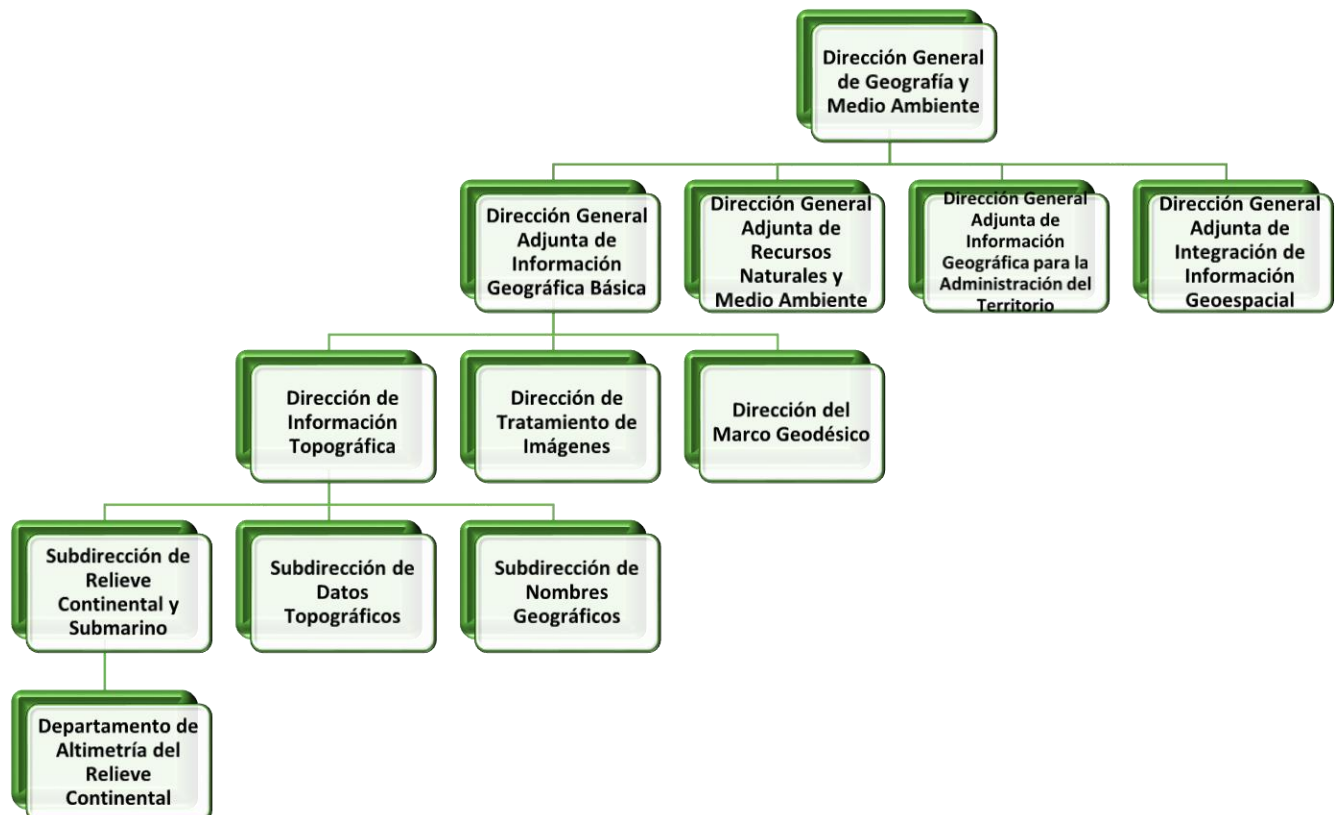
## 1.2. Participación Profesional.

Bajo el cargo de Enlace Supervisor en el Departamento de Altimetría del Relieve Continental, he colaborado en el proyecto de BCUU utilizando la metodología que se implementa actualmente basada en la percepción remota y la clasificación de imágenes de manera semiautomatizada con la finalidad de identificar crecimientos urbanos y que se divide en cuatro etapas generales:

- Adquisición de Imágenes Satelitales
- Procesamiento de Imágenes
- Integración Cartográfica
- Edición Cartográfica

Posteriormente se describirán estas etapas de forma más detallada.

En el Cuadro 1 se muestra el organigrama del Departamento de Altimetría.



Cuadro 1. Organigrama de ubicación del Departamento de Altimetría del Relieve Continental. Basado en el Manual de Organización Específico de la Dirección General de Geografía y Medio Ambiente. INEGI



A la par de esta labor, fui el encargado de la búsqueda para eficientizar los procesos mediante la automatización. De este modo, desarrollé e implementé una nueva técnica para la clasificación de las imágenes satelitales haciendo uso del *Machine Learning* a partir de algoritmos en el lenguaje de programación Python.

A su vez, participé en exposiciones sobre la mejora continua del proceso de BCUU y como parte del Programa de Cooperación Técnica y Científica entre Santa Lucía y México, he impartido capacitación a integrantes del Ministerio de Asuntos Exteriores, Comercio Internacional, Aviación Civil y Asuntos de la Diáspora de Santa Lucía en materia de actualización de procesos cartográficos para el monitoreo de crecimientos urbanos y rurales.

## **2. Antecedentes.**

### *2.1. Percepción Remota*

Disciplina con fundamento tecnológico que permite desarrollar, capturar, procesar y analizar imágenes obtenidas desde sensores aerotransportados en el espacio, con el objetivo de capturar datos y mediciones *in situ*, con el fin de identificar rasgos físicos de la Tierra (Centro de Investigaciones en Ciencias de Información Geoespacial, 2022),

La radiación electromagnética es la base para el desarrollo de la percepción remota, ya que es la energía emitida por los objetos en forma de onda con una temperatura mayor al cero absoluto (-273 °C) (Aguirre, 2002). El espectro electromagnético es el continuo de todos los tipos de radiación y está ordenado de acuerdo con su longitud de onda. Cada material con temperatura mayor al cero absoluto es capaz de emitir radiación electromagnética en diferentes rangos del espectro, esto debido a las propiedades físicas intrínsecas, de esta manera, se han desarrollado sensores capaces de captar el rango de la radiación emitida por los materiales de la superficie terrestre, obteniendo así imágenes espectrales.

A partir del procesamiento de imágenes espectrales, la percepción remota tiene amplias aplicaciones en diferentes disciplinas, desde la ciencia hasta de la vida

cotidiana, como en la agricultura, la astronomía y la medicina (CENAPRED, 2022). Permite estudiar la distribución espacial de los recursos naturales del planeta, los fenómenos meteorológicos y otros procesos que ocurren en la superficie terrestre tales como la contaminación, desertificación y los asentamientos humanos (Lira, 2003). En consecuencia, en México instituciones como el Instituto Nacional de Estadística y Geografía (INEGI), la Comisión Nacional para el Conocimiento y Uso de la Biodiversidad (CONABIO), el Centro Nacional de Prevención de Desastres (CENAPRED), entre otros; emplean técnicas de percepción remota y uso de sistemas de información geográfica (SIG) para adquirir diversos datos y estadísticas que les conciernen.

## *2.2. Imágenes Satelitales*

Los Sentinel son la flota de satélites diseñada específicamente para proporcionar abundantes datos e imágenes que nutre al programa Copernicus, de la Comisión Europea.

Es el resultado de la estrecha colaboración entre la Agencia Espacial Europea (ESA por acrónimo en inglés), la Comisión Europea, la industria, los proveedores de servicios y los usuarios de datos.

Las misiones Sentinel de Copernicus recogen imágenes del planeta, sea el océano o la tierra. La misión Sentinel-2 es una constelación cuya flota está formada por dos satélites separados por 180 grados de vigilancia terrestre que proporcionan imágenes ópticas de alta resolución. La misión proporciona una cobertura global de la superficie terrestre cada diez días con un satélite y de cinco días en conjunto. A bordo lleva consigo una cámara multiespectral de alta resolución con 13 bandas espectrales (ESA, 2022), las cuales van desde el espectro visible y el infrarrojo cercano (NIR), hasta el infrarrojo de onda corta (SWIR). Entre ellas hay cuatro bandas de 10 metros (tres del visible y una del NIR), seis bandas de 20 metros, y tres bandas de 60 metros de resolución para corrección atmosférica y detección de nubes. Tiene como objetivos, la generación de productos tales como mapas de uso del suelo, mapas de cambios a lo largo del tiempo, mapas de riesgo, e imágenes

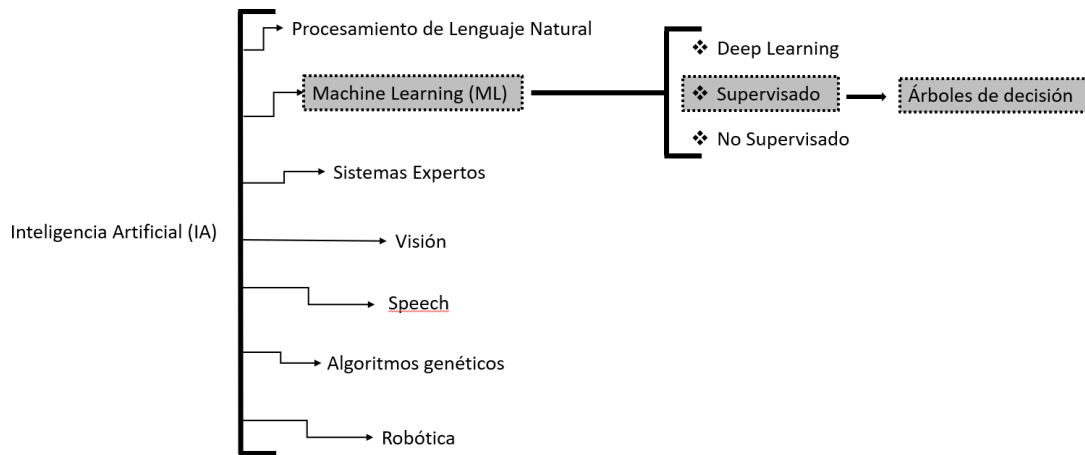
para la prevención de desastres, mediante datos que generan variables biofísicas como el contenido de clorofila.

Sentinel-2 incorporó tres nuevas bandas en la región del *red-edge* que mejora la configuración del sensor para estudios de aguas y vegetación (Delegido et al., 2011). También mejoró misiones operativas como Landsat o SPOT proporcionando bandas más estrechas y con canales adicionales con un instrumento de captura multiespectral (Drusch et al., 2012).

### 2.3. *Machine Learning.*

El *machine learning* o aprendizaje automatizado, es una forma o rama de la IA que permite aprender de los datos asignados en lugar de aprender mediante la programación explícita (International Business Machines, 2022). Se basa en la manera como las computadoras modifican o adaptan sus procesos, para de esta manera hacerlos más precisos en actividades que requieran medir la precisión (Marsland, 2015), es decir, un modelo de *machine learning* es una nueva forma de procesar y generar información por medio del entrenamiento de uno o varios algoritmos. Por tal razón el *machine learning* permite desarrollar modelos predictivos basados en los datos que son utilizados como entrenamiento.

De acuerdo con de la naturaleza del problema, existen diferentes enfoques para la aplicación del *machine learning*. Existen tres categorías: aprendizaje supervisado, aprendizaje no supervisado, aprendizaje de refuerzo o *deep learning*. En el Cuadro 2 se muestra de manera general algunas de las ramas de la inteligencia artificial y como se clasifica el *machine learning*.



Cuadro 2. Diagrama de clasificación de los métodos de Machine Learning. Basado en Neota Logic, 2015.

La categoría de aprendizaje o clasificación supervisada fue utilizada en este informe y tuvo la intención de encontrar patrones dentro de los datos que reconocen un proceso o cambio en las imágenes.

#### 2.4. Clasificación Supervisada.

La clasificación de una imagen se realiza con el propósito de convertir datos cuantitativos (generalmente niveles digitales de los píxeles en las bandas espectrales) en datos cualitativos (clases importantes en un dominio específico temático) (Richards y Jia, 1999).

Los algoritmos de clasificación de imágenes se pueden dividir en dos grupos, supervisados y no supervisados.

Las técnicas supervisadas parten de un grupo de elementos pertenecientes a la propia imagen, los cuales se denominan áreas de entrenamiento y de los que se conoce con un alto nivel de exactitud la clase a la que pertenecen (Borràs et al., 2017). El objetivo de la clasificación es desarrollar un modelo preliminar para cada clase usando las características disponibles de los datos. (García et al., 1998). La clasificación se realiza forzando el resultado para que corresponda con coberturas del suelo definidas por el usuario basándose en los atributos contenidos en las áreas de entrenamiento, y que, por lo tanto, son de interés, sin embargo, no se garantiza que las clases sean separables desde el punto de vista estadístico (Rees, 2005).

La clasificación supervisada aplicada a imágenes usa información etiquetada sobre las relaciones de los píxeles que son elegidos por usuarios expertos, para construir un modelo que permita generalizar una imagen completa (Camps-Valls, 2009).

## 2.5. *Decision Trees*

El método de árboles de decisión (“*decision trees*” por su término en inglés) son modelos predictivos creados por reglas binarias (Fig. 1) con las que se consigue repartir las observaciones en función de los atributos (o etiquetas), y así predecir el valor de una variable final (Lizarazo, 2008).




Figura 1. Esquema de un árbol de decisión. A partir de reglas binarias permite discriminar características no deseadas (Lizarazo, 2008).

La principal razón para elegir los árboles de decisión fue debido a la complejidad para clasificar imágenes con el objetivo de detectar crecimientos rurales y urbanos, es decir, la gran biodiversidad de México, aunado a su infraestructura, vuelve a las zonas de estudio muy heterogéneas, lo que reduce la posibilidad de establecer parámetros generales para clasificar las imágenes, es decir, las condiciones naturales en el norte del país son completamente distintas a las del sur.

Las ventajas principales de utilizar árboles de decisión es que son fáciles de interpretar. Al ser un método no paramétrico no requiere cumplir ningún tipo de distribución ni de geometría. Requiere menos limpieza en los datos y menos preprocesado, así como puede aplicarse a problemas de regresión y de clasificación (IBM, 2022).

## 2.6. *Definición del problema.*

El crecimiento acelerado de la mancha urbana es un fenómeno común de las sociedades actuales en todo el mundo, sus orígenes se ubican en la estructura misma de la sociedad y en su evolución histórica. La dinámica del crecimiento de las ciudades depende de la correlación de diversos factores como el económico, demográfico, cultural, político, social, geográfico y tecnológico. Este crecimiento acelerado tiene como consecuencia la necesidad de cubrir una demanda adicional de bienes y servicios, por lo que se debe fortalecer la dotación de infraestructura y equipamientos en las zonas pobladas a fin de satisfacer a la población.

Con el objetivo de obtener información geográfica para poder reforzar el tema de resiliencia de las poblaciones, el proyecto de BCUU es una pieza importante pues dentro de sus objetivos está el de permitir identificar las zonas con crecimientos urbanos y rurales donde se debe atender factores como prevención de riegos, marginación, infraestructura, servicios públicos, etc.

El proceso de urbanización en México puede definirse como una expansión desproporcionada de la mancha urbana. En las ciudades mexicanas, el crecimiento del territorio urbano no ha correspondido con la tendencia del crecimiento poblacional (INEGI, 2022). De acuerdo con la compilación de datos presentada en el Programa Nacional de Ordenamiento Territorial y Desarrollo Urbano 2021-2024, la población urbana se duplicó durante los últimos treinta años mientras que la superficie urbana se multiplicó por seis, por lo que resulta claro, tanto la transversalidad que conlleva el efecto de urbanización en las ciudades del país, así como la importancia de contar con información cartográfica actualizada que permita enfocar los esfuerzos hacia proyectos importantes para el INEGI, como los censos y las diversas encuestas.

Actualmente los avances tecnológicos han ayudado a establecer procedimientos, técnicas y herramientas que permiten identificar los crecimientos de las áreas metropolitanas con el fin de evaluar los impactos de estos cambios en los ecosistemas y recursos naturales. De tal forma, el análisis urbano a partir de señores remotos permite aproximarse a la distribución espacial de diferentes

aspectos, como infraestructura vial, crecimiento urbano y asentamientos humanos (Donay, Barney y Longley, 2001).

Las técnicas de clasificación aplicadas a imágenes ópticas son procesos que permiten identificar diferentes tipos de atributos por medio del análisis estadístico multivariado, en donde se obtienen valores radiométricos de cada píxel de una o varias bandas de una imagen satelital con el fin de crear y evaluar diferentes clases de acuerdo con su firma espectral. Este proceso es muy práctico al momento de clasificar rasgos como el suelo desnudo, cobertura vegetal, cuerpos de agua, crecimientos urbanos, entre otros (INEGI, 2018); sin embargo, la precisión de la clasificación depende por completo de las condiciones geográficas y del formato a escala 1:50,000 a trabajar, por lo que su generación puede variar en tiempo desde un par de horas hasta una semana. Por esta razón el trabajo tuvo el objetivo de encontrar nuevas metodologías, que, de manera eficiente, mejoren la calidad de los productos cartográficos y permitan de forma expedita reconocer patrones de crecimiento en las localidades del país.

### **3. Metodología (Proyecto BCUU)**

El proyecto de actualización de la Base Cartográfica Única (BCUU) surge frente a los modelos actuales de desarrollo urbano en los países industrializados en donde la existencia de crecimientos residenciales y comerciales descentralizados es muy importante, aunado con los crecimientos urbanos derivados de la necesidad natural debido al incremento de la población, ya sea de manera regular o itinerante. Estos patrones de crecimiento acelerado, principalmente en las localidades urbanas y zonas metropolitanas, se han convertido en incidencias con impactos negativos en las coberturas cartográficas censales, lo cual dificulta y obstaculiza los operativos de actualización en campo, esto al tener que realizar recorridos intensos in-situ, aunado con el gasto de tiempo y recursos que implica realizar estos trabajos.

De acuerdo con lo establecido en el artículo 30 de la LSNIEG, fracción IV y VI, el Instituto debe implementar metodologías para generar información que tomen en cuenta los estándares nacionales e internacionales, así como las mejores prácticas en la materia. De tal forma, actualmente el uso de tecnologías con aplicaciones de

percepción remota son las más vigentes y expeditas para detectar los crecimientos urbanos y así poder dirigir al personal de campo de manera ordenada y precisa con el fin de corroborar la información.

### 3.1. Clasificación no supervisada

El insumo principal para comenzar con el proceso de detección de crecimientos rurales fue la imagen Sentinel-2 de la zona de interés. Para ello fue necesario que cumpla con las especificaciones necesarias de temporalidad y porcentaje de nubosidad para el proceso Cabe mencionar que siempre se busca la imagen más reciente, sin embargo, la nubosidad en ocasiones provoca que se utilicen imágenes que no son las más actuales.

Se utilizó la plataforma *EOS LandViewer*, para lo cual fue necesario crear una cuenta para descargar las imágenes (Fig. 2).

La ventaja que ofrece esta plataforma es que se puede descargar la imagen con todas sus bandas, o elegir una composición de estas. Para el proyecto se decidió trabajar con la composición RGB (rojo-Red 4, verde-Green 3, azul-Blue 2) de color natural (Fig. 3).

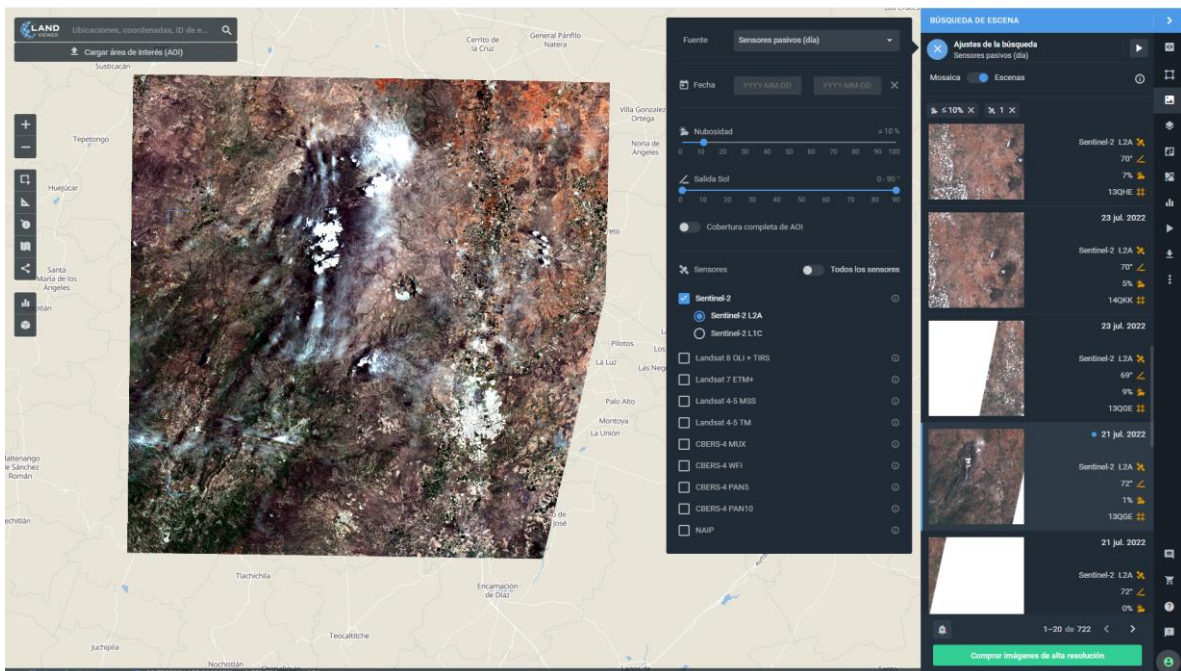




Figura 2. Muestra de la interfaz de la plataforma *LandViewer*. Se visualiza una imagen del estado de Aguascalientes del 21 de julio de 2022. En la columna central se aprecian los filtros aplicados para la búsqueda de la imagen, tales como temporalidad, nubosidad y ángulo con que tomó la imagen el sensor. En la columna derecha se pueden ver los resultados de la búsqueda con las características de cada imagen, siendo y la elegida con un ángulo de 72° y 1% de nubosidad.

De acuerdo con las necesidades del Departamento de Extracción Vectorial, se trabajaron con los 2,400 formatos cartográficos a escala 1:50,000 que cubren todo el territorio nacional (Fig. 4.). Este departamento generó un archivo vectorial llamado Área Efectiva, el cual es el resultado de la diferencia en superficie de los 2,400 formatos de interés contra la información vectorial existente y actual del Marco Geoestadístico (diciembre 2018), Registro Único de Vivienda (2015-2016) y Catastro (2017), es decir, el área donde no se tiene registro de asentamientos humanos ni crecimientos urbanos.

Con ayuda del sistema de información geográfica ArcMap, se desplegaron las imágenes descargadas y se seleccionaron las áreas de interés de acuerdo con el formato 1:50,000.

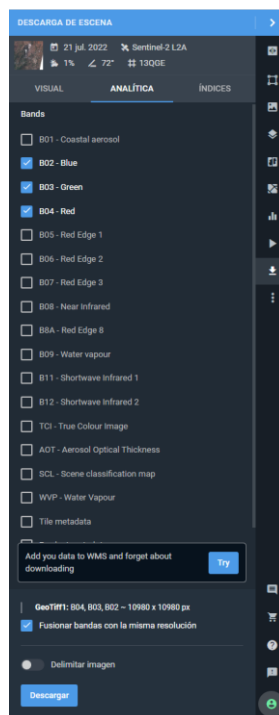


Figura 3. Se muestra la opción de fusionar bandas con la misma resolución. La imagen descargada corresponde a la combinación de las bandas 2, 3 y 4 de Sentinel-2.

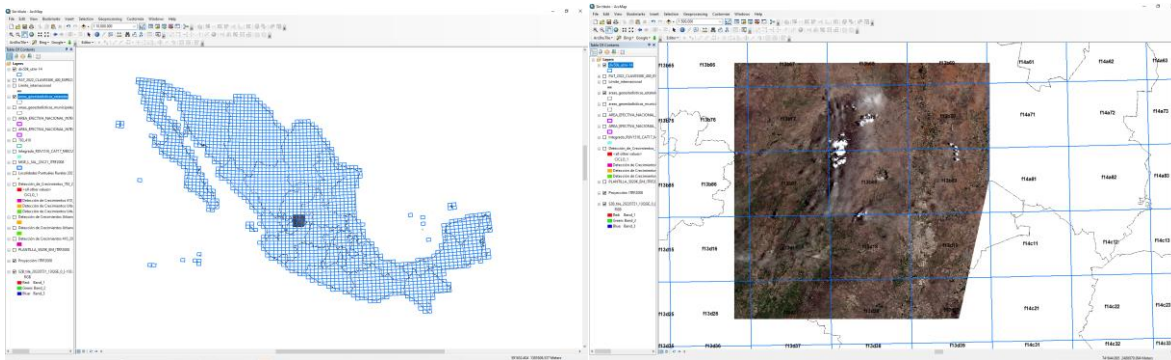


Figura 4. En la figura de la izquierda se pueden observar los 2,400 formatos 1:50,000. En la figura de la derecha se muestra la imagen descargada y los formatos que contiene.

Posteriormente se elige el área de interés y se recorta la imagen (Fig. 5).

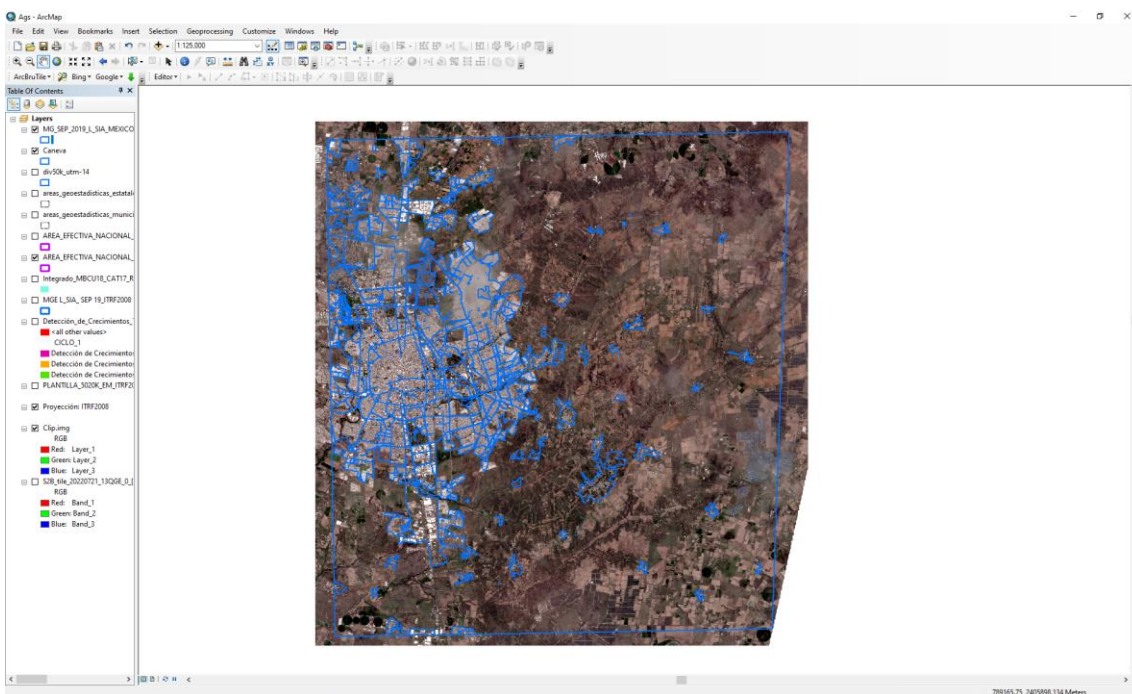
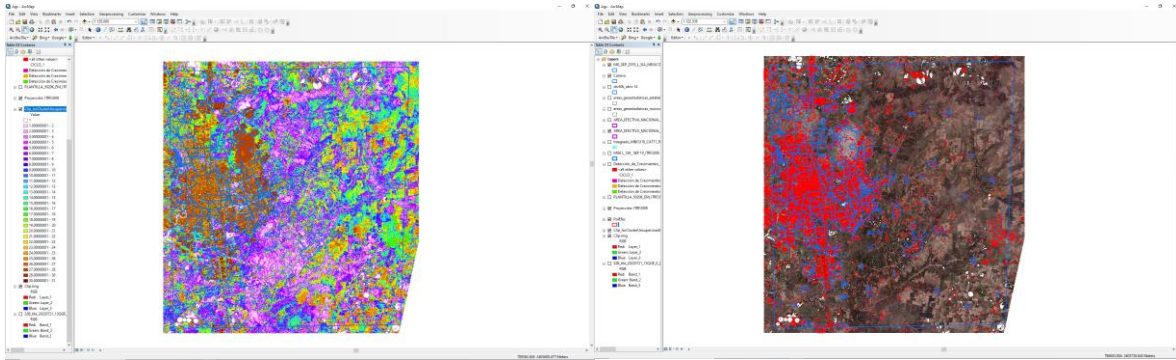


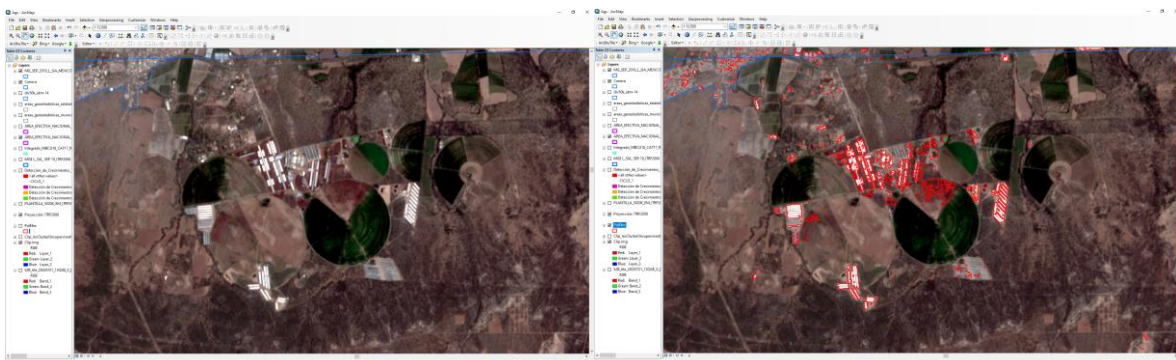
Figura 5. Área de interés correspondiente al formato cartográfico f13d19 donde se pueden apreciar las áreas ya identificadas como crecimientos urbanos.

De manera consecuente se realizó la clasificación no supervisada con el algoritmo *Iso Cluster* de ArcMap para identificar las diferentes clases que se encuentran en el área, de acuerdo con el valor de cada píxel y se realizó la separación de la clase correspondiente a los crecimientos urbanos (Fig. 6). El objetivo de esta clasificación es crear 32 clases diferentes de acuerdo con los valores radiométricos de los píxeles.



**Figura 6.** En la figura de la izquierda se muestra la clasificación realizada por ArcMap, de acuerdo con los valores de píxel de la imagen. En la figura de la derecha se muestra la clase que mejor representa a los crecimientos urbanos.

La clasificación realizada por el software identifica los crecimientos urbanos de manera general, sin embargo, para mantener los estándares de calidad y de precisión que estipula la LSNIEG, se debe verificar que tal clasificación haya sido realizada de manera correcta en toda la imagen. Por lo que se realiza una inspección visual para agregar o eliminar información, a este proceso se le conoce como depuración (Fig. 7). Sin embargo, de acuerdo con la zona en estudio, la calidad de la clasificación no supervisada, así como el tiempo requerido para la inspección visual, pueden significar un gasto muy alto en cuestión de tiempo y trabajo manual.



**Figura 7.** Inspección visual para la validación de la clasificación.

Después de considerar los aspectos mencionados y con el fin de asegurar la calidad del producto final, es factible terminar la depuración y proseguir con la edición de la tabla de atributos, que proporcionará todas las características que necesite consultar algún usuario respecto al proceso de clasificación. Estos atributos

corresponden a los polígonos generados por cada crecimiento urbano identificado, y estos fueron: número de polígonos identificados, la clave de la entidad a la que pertenece, nombre de la entidad, clave del municipio al que pertenece, nombre del municipio, clave del formato 1:50,000, clave del formato 1:20,000, año de realización, nombre del proyecto, clave tile de la imagen Sentinel-2, la fecha de realización del formato y fecha de la imagen (Fig. 8)

ID	Shape	CVE_ENT	NOM_ENT	CVE_MUN	NOM_MUN	CLAVE50K	CLAVE20K	CICLO	ORIGEN_CBE	CLAVE_TILE	MES	AÑO	DIA_IMG	MES_IMG	AÑO_IMG	FUENTE_IMG
1	Polygon	32	Zacatecas	007	Concepción	g1402c	g1402c	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
2	Polygon	32	Zacatecas	007	Concepción	g1402c	g1402c	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
3	Polygon	32	Zacatecas	007	Concepción	g1402c	g1402c	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
4	Polygon	32	Zacatecas	007	Concepción	g1402c	g1402c	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
5	Polygon	32	Zacatecas	007	Concepción	g1402c	g1402c	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
6	Polygon	32	Zacatecas	007	Concepción	g1402c	g1402c	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
7	Polygon	32	Zacatecas	007	Concepción	g1402c	g1402c	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
8	Polygon	32	Zacatecas	007	Concepción	g1402c	g1402c	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
9	Polygon	32	Zacatecas	007	Concepción	g1402c	g1402c	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
10	Polygon	32	Zacatecas	007	Concepción	g1402c	g1402c	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
11	Polygon	32	Zacatecas	007	Concepción	g1402c	g1402c	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
12	Polygon	32	Zacatecas	007	Concepción	g1402c	g1402c	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
13	Polygon	32	Zacatecas	026	Mazapán	g1402b	g1402b	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
14	Polygon	32	Zacatecas	026	Mazapán	g1402b	g1402b	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
15	Polygon	32	Zacatecas	026	Mazapán	g1402b	g1402b	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
16	Polygon	32	Zacatecas	027	Mechor Oc	g1402a	g1402a	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
17	Polygon	32	Zacatecas	027	Mechor Oc	g1402a	g1402a	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
18	Polygon	32	Zacatecas	027	Mechor Oc	g1402a	g1402a	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
19	Polygon	32	Zacatecas	027	Mechor Oc	g1402a	g1402a	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
20	Polygon	32	Zacatecas	027	Mechor Oc	g1402a	g1402a	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
21	Polygon	32	Zacatecas	027	Mechor Oc	g1402a	g1402a	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
22	Polygon	32	Zacatecas	027	Mechor Oc	g1402a	g1402a	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
23	Polygon	32	Zacatecas	027	Mechor Oc	g1402a	g1402a	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
24	Polygon	32	Zacatecas	027	Mechor Oc	g1402a	g1402a	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
25	Polygon	32	Zacatecas	027	Mechor Oc	g1402a	g1402a	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
26	Polygon	32	Zacatecas	027	Mechor Oc	g1402a	g1402a	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
27	Polygon	32	Zacatecas	027	Mechor Oc	g1402a	g1402a	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
28	Polygon	32	Zacatecas	027	Mechor Oc	g1402a	g1402a	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
29	Polygon	32	Zacatecas	027	Mechor Oc	g1402a	g1402a	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
30	Polygon	32	Zacatecas	027	Mechor Oc	g1402a	g1402a	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
31	Polygon	32	Zacatecas	027	Mechor Oc	g1402a	g1402a	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
32	Polygon	32	Zacatecas	027	Mechor Oc	g1402a	g1402a	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
33	Polygon	32	Zacatecas	027	Mechor Oc	g1402a	g1402a	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
34	Polygon	32	Zacatecas	027	Mechor Oc	g1402a	g1402a	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
35	Polygon	32	Zacatecas	027	Mechor Oc	g1402a	g1402a	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
36	Polygon	32	Zacatecas	027	Mechor Oc	g1402a	g1402a	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
37	Polygon	32	Zacatecas	027	Mechor Oc	g1402a	g1402a	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
38	Polygon	32	Zacatecas	027	Mechor Oc	g1402a	g1402a	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
39	Polygon	32	Zacatecas	027	Mechor Oc	g1402a	g1402a	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
40	Polygon	32	Zacatecas	027	Mechor Oc	g1402a	g1402a	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
41	Polygon	32	Zacatecas	027	Mechor Oc	g1402a	g1402a	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
42	Polygon	32	Zacatecas	027	Mechor Oc	g1402a	g1402a	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
43	Polygon	32	Zacatecas	026	Mazapán	g1402b	g1402b	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
44	Polygon	32	Zacatecas	026	Mazapán	g1402b	g1402b	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
45	Polygon	32	Zacatecas	026	Mazapán	g1402b	g1402b	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
46	Polygon	32	Zacatecas	026	Mazapán	g1402b	g1402b	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
47	Polygon	32	Zacatecas	026	Mazapán	g1402b	g1402b	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
48	Polygon	32	Zacatecas	026	Mazapán	g1402b	g1402b	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
49	Polygon	32	Zacatecas	026	Mazapán	g1402b	g1402b	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
50	Polygon	32	Zacatecas	026	Mazapán	g1402b	g1402b	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
51	Polygon	32	Zacatecas	007	Concepción	g1402c	g1402c	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
52	Polygon	32	Zacatecas	007	Concepción	g1402c	g1402c	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
53	Polygon	32	Zacatecas	007	Concepción	g1402c	g1402c	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
54	Polygon	32	Zacatecas	007	Concepción	g1402c	g1402c	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2
55	Polygon	32	Zacatecas	026	Mazapán	g1402b	g1402b	2022	Detección de Cr	1480N	AGOSTO	2022	07	AGOSTO	2022	SENTINEL2

Figura 8. Tabla de atributos del archivo de detección de crecimientos.

Por último, se integró la información completa de las bases de datos respecto del marco geoestadístico actual, los tipos de crecimientos y los nuevos que fueron identificados. Para de esta manera conformar el formato cartográfico final en formato PDF (Fig. 9).

Actualmente, respecto a la temática de la detección de crecimientos urbanos y rurales, solo se generan las cartas a escala 1:50,000.

Proyecto para la Base Cartográfica Única en Formatos Cartográficos Escala 1:50000  
E14B88, Tile 14QQF

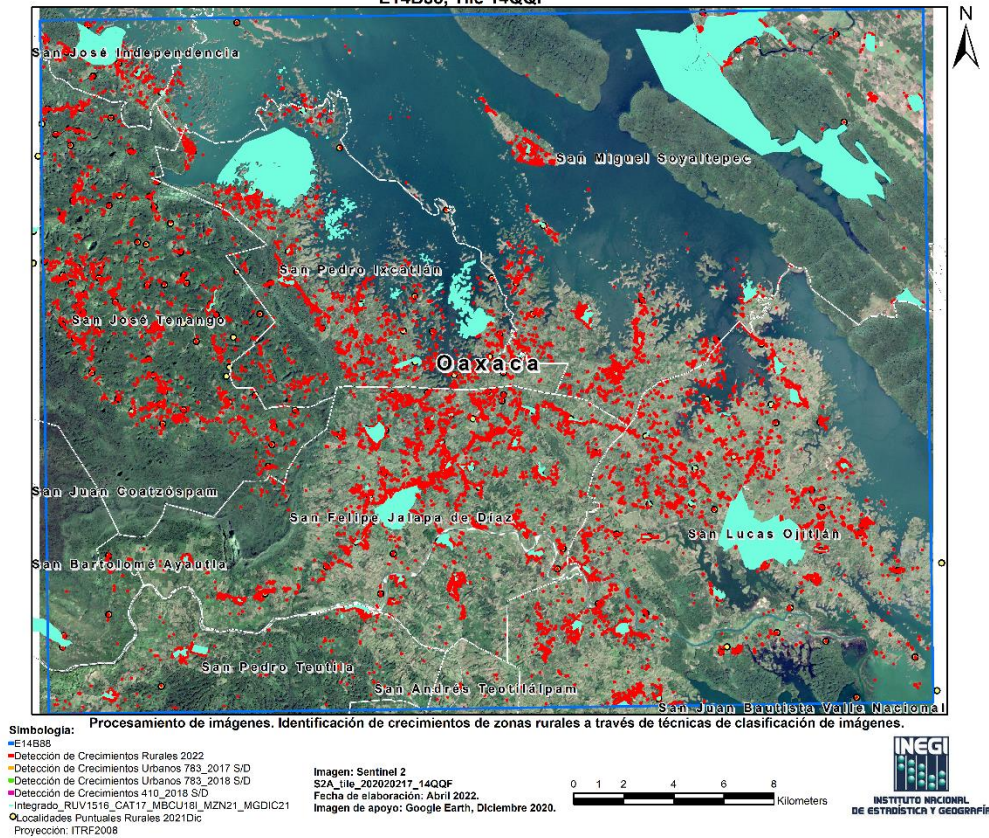


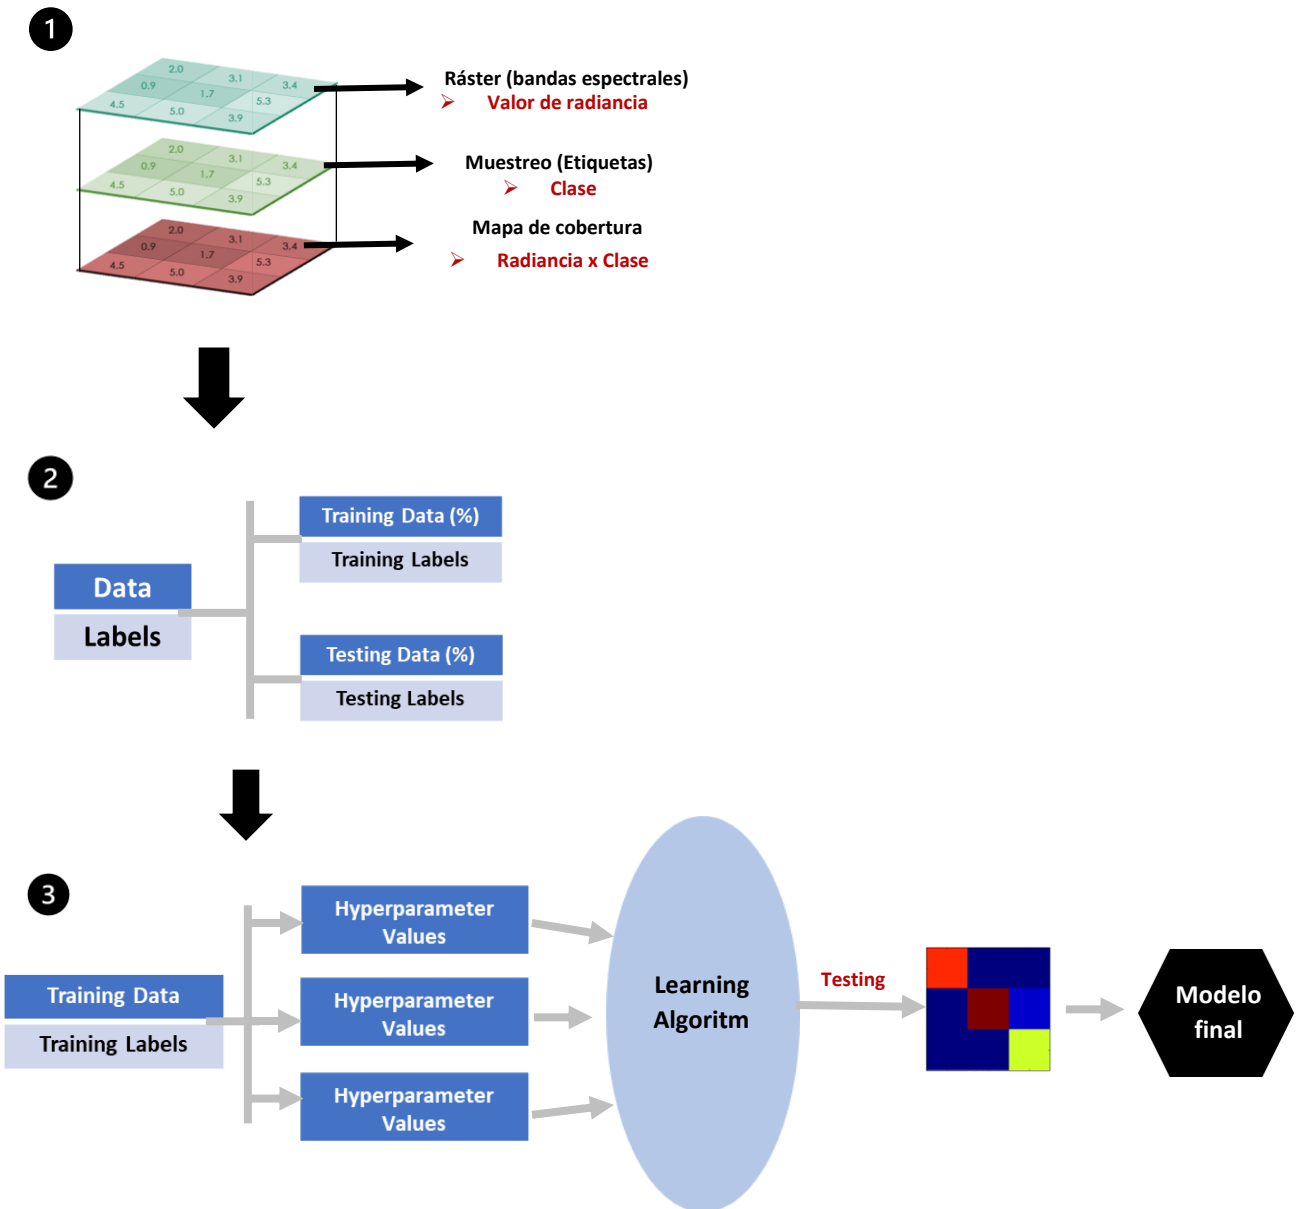
Figura 9. Mapa cartográfico escala 1:50,000, clave E14B88 correspondiente al estado de Oaxaca donde se identificaron nuevos crecimientos urbanos y rurales.

En la Figura 9 se muestra el producto final del proyecto BCUU, correspondiente a la carta con clave E14B88, localizada en Oaxaca.

### 3.2. Clasificación supervisada aplicando machine learning.

La decisión de implementar nuevas metodologías en el proyecto se debe a que el tiempo actual de generación de los formatos cartográficos es muy tardado. El proyecto de BCUU se inició en 2017 y para 2022 apenas se lleva aproximadamente el 40% de cobertura nacional, por lo que mantener actualizada la información parecería un objetivo poco probable de conseguir. De este modo desarrollé un algoritmo en lenguaje Python con ayuda del IDE (Entorno de Desarrollo Interactivo

por sus siglas en inglés) Spyder que permite automatizar los procesos de BCUU con el fin de proporcionarle a la institución información de calidad y actualizada. El algoritmo desarrollado utiliza el método de árboles de decisión, el cual funciona creando un modelo de predicciones a partir de datos que son seleccionados por el especialista en el proyecto (Cuadro 3). En el Anexo 2 se puede consultar el código.



Cuadro 3. Diagrama del algoritmo de árboles de decisión.

En el Cuadro 3 se muestra el procedimiento llevado a cabo para generar la clasificación mediante el algoritmo y se enumeran 3 fases. En la fase 1 se extraen los insumos necesarios; la imagen ráster que será clasificada y que contiene valores de radiancia por cada banda espectral; el archivo vectorial con un muestreo realizado de la zona de estudio y que en sus atributos contiene las etiquetas que definen las clases. Es importante mencionar que ambos insumos se deben extraer en forma de malla (grid). De esta forma, el tercer insumo hace referencia a la malla obtenida de la correlación entre el primer insumo y el segundo, que en el diagrama se identifica como “mapa de cobertura”, y contiene información de la correlación de valores de radiancia con una determinada clase.

Para la segunda fase del proceso, los datos de radiancia y sus etiquetas que son las clases se encuentran en el mapa de cobertura. De dicha información se define un porcentaje determinado de datos que servirán como datos de entrenamiento y el porcentaje restante se usará para datos de validación.

En la fase tres, los datos de entrenamientos se convierten en hiperparámetros. Un hiperparámetro es el conjunto de datos específicamente asignados para entrenar un modelo predictivo. Posteriormente se aplica el algoritmo con los datos de entrenamiento y se genera un modelo de predicción para clasificar; dicho modelo es evaluado con los datos de validación, es decir, las predicciones son evaluadas para obtener una matriz de confusión. Una vez conocida la precisión de las predicciones con ayuda de la matriz de confusión, se aplica el modelo al ráster completo.

Para desarrollar esta nueva metodología, se establecieron dos zonas de estudio, una utilizando una ortofoto de muy alta resolución y en otra con Sentinel-2. A continuación, se describen ambos proyectos.

### *3.2.1. Caso de estudio 1: Tequila, Jalisco.*

Para este proceso se utilizó una imagen tipo ortofoto con resolución espacial de 0.5 m con tres bandas espectrales. La composición RGB corresponde a la combinación para color natural (Cuadro 4).

**Sistema de referencia de coordenadas (SRC)**

Nombre	EPSG: 4326 – WGS 84
Unidades	Geográficas (latitud y longitud)

**Información del proveedor**

Extensión	-103.8543789551445542, 20.8453414707947715 : -103.7956325622826625, 20.8827812249041607
Anchura	14194
Altura	9046
Tipo de Datos	UInt16 – Entero natural de 16 bits
Metadatos del controlador de GDAL	GeoTIFF
Descripción del conjunto de datos	
Banda 1	STATISTICS_MAXINUM=2047 STATISTICS_MEAN=202.28169000438 STATISTICS_MINIMUM=0 STATISTICS_STDDEV=91.767950683207
Banda 2	STATISTICS_MAXINUM=2047 STATISTICS_MEAN=315.17699067739 STATISTICS_MINIMUM=0 STATISTICS_STDDEV=99.461020721241
Banda 3	STATISTICS_MAXINUM=1527 STATISTICS_MEAN=238.66655585817 STATISTICS_MINIMUM=0 STATISTICS_STDDEV=59.593916275934

**Cuadro 4. Características de la ortofoto. Se muestran las características de cada banda espectral, así como su sistema de referencia de coordenadas.**

La imagen de estudio ocupa un área de 4,136 x 6,114 m, es decir, 25,278  $km^2$ . El número de muestras fue de 250 y para el caso en estudio se determinaron cinco clases: crecimientos rurales, vegetación alta, vegetación baja, suelo desnudo y caminos, todas ellas con tamaño  $n = 50$  (Fig. 10).

Los parámetros del modelo de clasificación fueron:

- **Variables de training o de entrenamiento:** 80% (200 muestras)
- **Variables de testing de evaluación:** 20% (50 muestras)






Figura 10. Zona de estudio en Tequila, Jalisco. Se aprecian los puntos que sirvieron como muestras para aplicar el algoritmo.

### 3.2.2. Caso de estudio 2: Santa Lucía

Este caso de estudio corresponde al Programa de Cooperación Técnica y Científica entre Santa Lucía y México para el período 2021-2023 entre INEGI y el Ministerio de Asuntos Exteriores, Comercio Internacional, Aviación Civil y Asuntos de la Diáspora de Santa Lucía, donde se busca implementar la mejor metodología para apoyar en la generación de cartografía en dicho país del Caribe.

Se utilizó una imagen Sentinel-2 del 9 de noviembre de 2021 (Fig. 11).

La zona de estudio ocupa aproximadamente un área de  $86 \text{ km}^2$ . El tamaño del muestreo fue de 240, utilizando cuatro clases: crecimientos rurales, vegetación alta, vegetación baja y suelo desnudo, todas de tamaño  $n = 60$ .

Los parámetros del modelo de clasificación son:

- **Variables de training o de entrenamiento:** 80% (192 muestras)
- **Variables de testing de evaluación:** 20% (48 muestras)

La combinación RGB que se visualiza en la Figura 11 corresponde a la de color natural, sin embargo, para este proceso se consideró añadir al procesamiento la información de las bandas 11 y 12 correspondientes al rango del espectro térmico infrarrojo, considerando que dichos valores del espectro pueden aportar mejores elementos para clasificar los crecimientos urbanos. Las características de las bandas se muestran en el Cuadro 5.

Sistema de referencia de coordenadas (SRC)	
Nombre	EPSG: 32620 – WGS 84 / UTM zone 20N
Unidades	metros

Información del proveedor	
Extensión	699960, 1490220 : 809760, 1600020
Anchura	10980
Altura	10980
Tipo de Datos	UInt16 – Entero natural de 16 bits
Metadatos del controlador de GDAL	GeoTIFF
Descripción del conjunto de datos	
Banda 1	STATISTICS_MAXINUM=18032 STATISTICS_MEAN=781.48556552222 STATISTICS_MINIMUM=1
Banda 2	STATISTICS_STDDEV=1683.6378401921 STATISTICS_MAXINUM=216448 STATISTICS_MEAN=620.08074371928 STATISTICS_MINIMUM=1 STATISTICS_STDDEV=1604.06469224059
Banda 3	STATISTICS_MAXINUM=16448 STATISTICS_MEAN=536.74310324088 STATISTICS_MINIMUM=1 STATISTICS_STDDEV=1521.9221678866
Banda 4	STATISTICS_MAXINUM=10283 STATISTICS_MEAN=485.37600783586 STATISTICS_MINIMUM=1 STATISTICS_STDDEV=1004.3965746781
Banda 5	STATISTICS_MAXINUM=8110 STATISTICS_MEAN=377.68681135512 STATISTICS_MINIMUM=1 STATISTICS_STDDEV=750.94257424911

**Cuadro 5. Características de la imagen multiespectral. Se muestran las características de cada banda espectral, así como su sistema de referencia de coordenadas.**

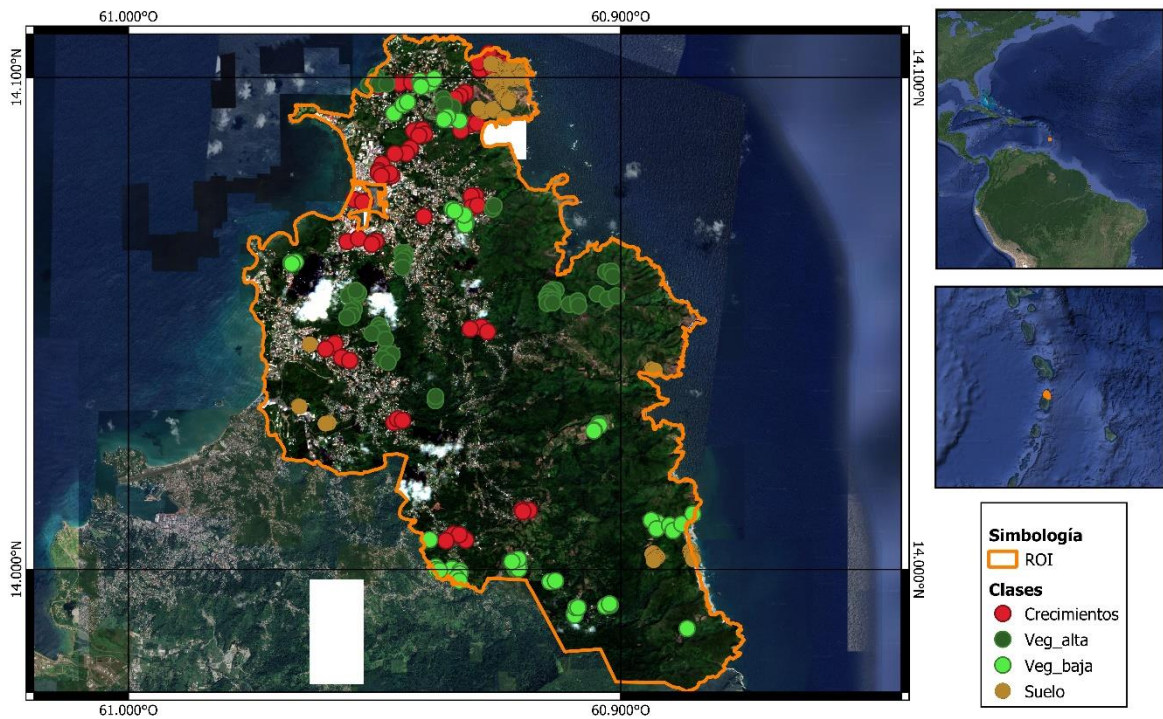


Figura 11. Zona de estudio en la parte norte de Santa Lucía en el caribe. Se aprecian los puntos que sirvieron como muestras para aplicar el algoritmo.

#### 4. Análisis de resultados.

##### 4.1. Caso de estudio 1: Tequila, Jalisco.

A continuación, se muestra la clasificación realizada por el algoritmo de *machine learning* a la imagen tipo ortofoto (Fig. 12).




Figura 12. Se muestra la comparación de la imagen de color real (imagen superior), junto con la clasificación realizada por el modelo predictivo (imagen inferior).

Se puede apreciar que la clasificación tiene coherencia respecto a la clase de crecimientos urbanos, que es la clase de interés, sin embargo, se debe realizar la inspección visual para ver si existen errores (Fig. 13).

13a)



13b)



13c)



Figura 13. Se puede apreciar un acercamiento a la ortofoto, a la clasificación y a la clasificación aplicando una transparencia en las figuras 13a, 13b y 13c respectivamente.

De la Figura 13c es posible notar que la identificación de la clase “crecimientos” se realizó de buena manera, sin embargo, como se señala con la flecha amarilla, se clasificaron rasgos asociados a suelo desnudo como si fueran crecimientos; por otra parte, en las flechas color cian se evidencia la confusión de la clase “caminos” con “crecimientos”.

Estos errores en la clasificación se pueden cuantificar con la matriz de confusión (Fig. 14).

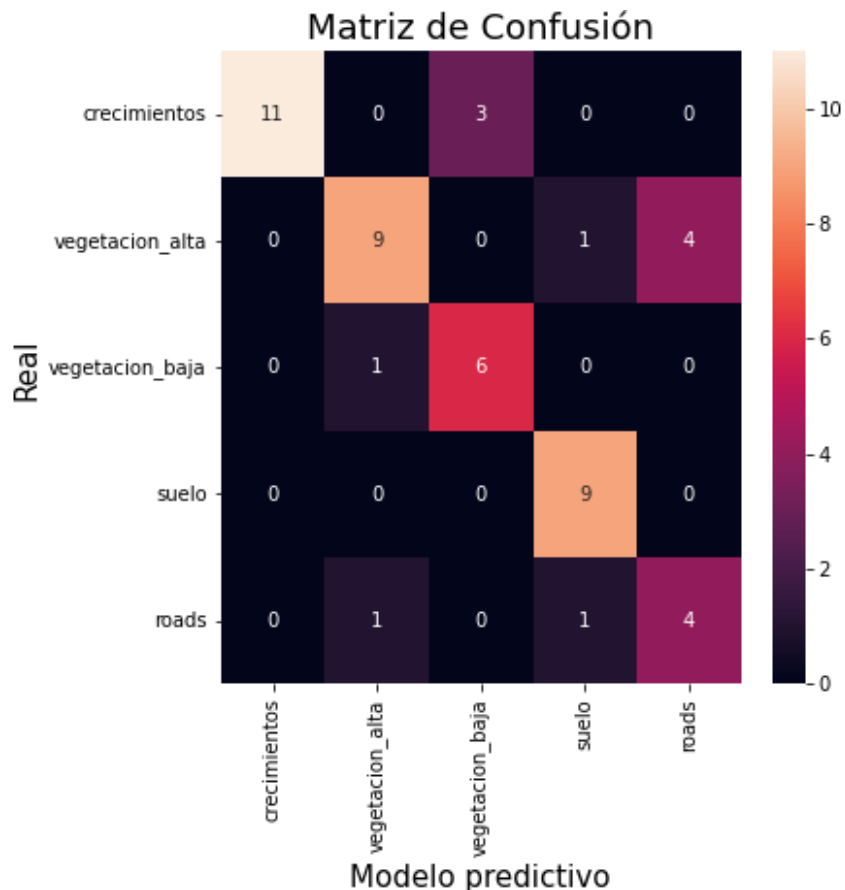


Figura 14. La matriz de confusión cuantifica en su diagonal, las predicciones que se realizaron de manera correcta, mientras que los demás números en cada renglón identifican a los errores de comisión, es decir, las predicciones mal realizadas.

Al analizar la matriz de confusión de la Figura 14, se observan los errores de comisión, es decir, las predicciones mal clasificadas de acuerdo con los datos de testing que son 50 muestras. En el primer renglón de crecimientos se observa que 11 muestras fueron bien clasificadas mientras que 3 fueron confundidas con

vegetación baja. En el segundo renglón de vegetación alta se aprecia que 9 muestras están bien clasificadas, mientras que 1 fue confundida con suelo desnudo y 4 fueron confundidas con caminos. En el tercer renglón de vegetación baja, 6 muestras fueron clasificadas de buena manera mientras que 1 fue confundida con vegetación alta. En la clase de suelo, las 9 muestras evaluadas estuvieron bien clasificadas. Por último, en el último renglón correspondiente a caminos, 4 muestras fueron bien clasificadas mientras que 1 fue confundida con vegetación alta y 1 con suelo.

Como se demostró, la generación de la matriz de confusión permite cuantificar la precisión de la clasificación e incluso notar en qué clases se está confundiendo más el algoritmo (Figura 15).




Figura 15. Se muestra la matriz de confusión en base 1 para obtener el porcentaje la evaluación de la precisión.

En la Figura 15 es posible visualizar en qué porcentaje de precisión se realizó la clasificación de cada clase. En consecuencia, la precisión final para la clasificación total fue de 78% en esta prueba.

#### 4.2. Caso de estudio 2: Santa Lucía.

A continuación, se muestra la clasificación realizada a la imagen Sentinel-2:

16a)



16b)




Figura 16. Se muestra la comparación de la imagen de color real (figura 16a) con la clasificación realizada por el modelo predictivo (figura 16b).

En la Figura 18 se muestra la clasificación realizada por el algoritmo a la imagen Sentinel-2, sin embargo, es importante mencionar, que como se muestra en círculos cian, hay una evidente presencia de nubes debido la ubicación geográfica del país.



Sin embargo, con la consideración de las zonas con nubosidad, se realiza la inspección visual.




Figura 17. Acercamiento a la imagen para inspección visual. La figura 17a es la composición RGB de Sentinel-2 y la figura 17b es una imagen del satélite de Google para tener una mejor visualización.






Figura 18. La figura 18a es un acercamiento de la clasificación para inspección visual y en la figura 18b se aplica una transparencia para mejor visualización.

Como se observa en la Figura 18b, la clasificación se realizó identificando los crecimientos urbanos de muy buena forma, aun los que son muy pequeños, sin embargo, se debe evaluar la precisión de la predicción para cuantificar los errores que se pudieron generar (Fig. 19).




Figura 19. La matriz de confusión cuantifica en su diagonal, las predicciones que se realizaron de manera correcta, mientras que los demás números en cada renglón identifican a los errores de comisión, es decir, las predicciones mal realizadas.

Analizando la matriz de confusión de la Figura 19, se pueden visualizar los errores de comisión de acuerdo con los datos de testing que fueron 60 muestras. En el primer renglón de crecimientos se observa que 12 muestras fueron bien clasificados mientras que otras 2 muestras se clasificaron como suelo desnudo. En el segundo renglón se observa que para vegetación alta 13 muestras clasificadas mientras que 1 muestra se clasificó erróneamente como crecimiento. En el tercer renglón correspondiente a vegetación baja, 14 muestras estuvieron bien clasificadas mientras que 1 muestra se clasificó como suelo. Por último, para la clase de suelo desnudo las 5 muestras evaluadas fueron bien clasificadas. En esta matriz de confusión se observó que el algoritmo realizó las clasificaciones de manera bastante eficiente, por lo que cuantificando la precisión se obtiene:




Figura 20. Se muestra la matriz de confusión en base 1 para obtener el porcentaje la evaluación de la precisión.

Si se evalúa la precisión con base en los resultados mostrados en la matriz de confusión de la Figura 20 se obtiene una precisión de 91.7%.

## 5. Conclusiones.

El proyecto de BCUU cumple con la misión y visión del Instituto, pues es generar este tipo de información para consulta de la sociedad, o bien, para la toma de decisiones en cuestiones políticas en niveles de gobierno desde municipal, estatal y federal, por lo que la calidad de los productos debería ser la mejor, sin embargo, como se explicó, la metodología actual presenta determinadas dificultades para la generación de los productos finales ocasionando que la continua actualización de la información aún no sea la adecuada. De esta manera, la propuesta de la implementación del lenguaje automatizado o machine learning, trae consigo grandes beneficios los cuales son: la gran disminución del tiempo de procesado

manual, pues el algoritmo permite automatizar los procesos y respecto de la metodología actual cuyo tiempo de análisis puede variar desde unas horas hasta un par de semanas, con esta metodología el tiempo se reduce a unos minutos invertidos en seleccionar los datos de entrenamiento del modelo predictivo; con ayuda de la matriz de confusión generada por el algoritmo, es posible identificar de manera eficiente las clases que generan mayor conflicto en la clasificación por lo que, basta con generar un buen muestreo para que el algoritmo logre identificar las diferencias que se quieren separar entre clases, de este modo, el tiempo de ejecución con el algoritmo permite generar diversos modelos de manera rápida hasta encontrar uno que satisfaga las necesidades de precisión del proyecto; el proceso es bastante sencillo de comprender, por lo que es relativamente sencillo identificar cualquier error que se presente al momento de ejecutar el programa; el algoritmo al ejecutarse en el lenguaje de Python permite manejar una gran cantidad de información en muy poco tiempo, por lo que la generación de los productos cartográficos tiene un potencial crecimiento muy considerable respecto a los actuales estándares de producción y el objetivo de poder mantener la actualización se podría cumplir de mejor manera.

Las zonas urbanas en México varían en sus materiales y forma constructiva dependiendo la región, es decir, la infraestructura urbana del norte de México no es igual a la infraestructura del sur, esto condicionado por factores desde los económicos, sociales, incluso geográficos y de condiciones naturales, por lo que, para cada caso en estudio del proyecto de BCUU se requiere un diferente trabajo de adiestramiento del sistema.

Es importante mencionar que en los ejemplos mostrados de Tequila, Jalisco y de Santa Lucía, las escalas digitales fueron aumentadas para tener una mejor visualización de los resultados, en este caso las escalas fueron de 1:5,000 y 1:4,000 respectivamente, pues en la práctica, con esas resoluciones es posible identificar de manera relativamente sencilla errores de clasificación.

El uso de la percepción remota conjuntado con los conocimientos en la computación científica se convierte en una poderosa herramienta para generar información con el fin de coadyuvar al desarrollo del país.

Es importante mencionar que el alcance de este proyecto no solo se queda dentro del propio proyecto de BCUU ni del Departamento de Altimetría, pues se puede implementar en las cuestiones de identificaciones de tipos de suelo, contaminantes, hidrogeología, etc.

Otro punto muy importante para destacar es que con esta metodología de clasificación se puede comenzar la migración de los procesos hacia el software libre, pues actualmente se debe pagar licencias para utilizar el sistema de información geográfico ArcMap, por lo que, en el contexto actual de austeridad gubernamental, tales gastos se pueden comenzar a disminuir justificando completamente que la calidad y eficiencia de la información generado será mejor.

Por último, hay que mencionar que los conocimientos adquiridos en la carrera de ingeniería geofísica fueron esenciales para lograr desarrollar este proyecto, desde las bases teóricas del espectro electromagnético para aplicar percepción remota, así como las bases para la programación científica, hasta las cuestiones prácticas como el uso de software libre y de licencia.

## 6. Referencias.

**Libro con autor (versión electrónica):** Aguirre, R. (2002). *Los Mares Mexicanos a través de la Percepción Remota*. Instituto de Geografía, Universidad Nacional Autónoma de México. Recuperado de <http://www.publicaciones.igg.unam.mx/index.php/ig/catalog/book/57>

**Página web:** Amazon. (2022). *¿Qué es la inteligencia artificial? Aprendizaje Automático y Aprendizaje Profundo*. Consultado en: [¿Qué es la inteligencia artificial \(IA\)?: Amazon Web Services](#)

**Artículo científico (versión electrónica):** Borràs, J., Delegido, J., Pezzola, A., Pereira-Sandoval, M., Morassi, G. y Camps-Valls, G. (2017). *Land Use Classification from Sentinel-2 Imagery*. Revista de Teledetección No. 48. Recuperado de: <https://doi.org/10.4995/raet.2017.7133>

**Contribución a un congreso publicado:** Camps-Valls, G. (2009). *Machine Learning in Remote Sensing Data Processing*. IEEE International Workshop on Machine Learning for Signal Processing. Recuperado de: [https://scholar.google.com/citations?view\\_op=view\\_citation&hl=es&user=6mgnau](https://scholar.google.com/citations?view_op=view_citation&hl=es&user=6mgnau)

[MAAAAJ&cstart=100&pagesize=100&citation for view=6mgnauMAAAAJ:Ec25XKZgu8sC](#)

**Página web:** Centro de Investigaciones en Ciencias de Información Geoespacial. (2022). *Percepción Remota*. Consultado en: <https://www.centrogeo.org.mx/investigacion/percepcion-remota#:~:text=La%20Percepci%C3%B3n%20Remota%20es%20una,datos%20de%20mediciones%20in%20situ>

**Página web:** Centro Nacional de Prevención de Desastres. *Tecnología Espacial y Percepción Remota en la Prevención de Desastres*. Consultado en: <https://www.gob.mx/cenapred/articulos/tecnologia-espacial-y-percepcion-remota-en-la-prevencion-de-desastres>

**Artículo científico (versión electrónica):** Delegido, J., Verrelst, J., Alonso, L. y Moreno, J. (2011). *Evaluation of Sentinel-2 Red-Edge Bands for Empirical Estimation of Green LAI and Chlorophyll Content*. *Sensors*. Recuperado de <https://doi.org/10.3390/s110707063>

**Artículo científico (versión electrónica):** Donnay, J., Barnsley M. y Longley P. (2001). *Remote Sensing and Urban Analysis*. Taylor & Francis Group. Recuperado de: <http://dx.doi.org/10.4324/9780203306062>

**Artículo científico (versión electrónica):** Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernández, V., Gascón, F., Hoersch, B., Isola, C., Laberinti, P., Martimort, P., Meygret, A., Spoto, F., Sy, O., Marchese, F. y Bargellini, P. (2012). *Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services*. *Remote Sensing Environment*. Recuperado de: <https://doi.org/10.1016/j.rse.2011.11.026>

**Página web:** European Space Agency. (2022). *SENTINEL 2*. Consultado en: [https://www.esa.int/Space\\_in\\_Member\\_States/Spain/SENTINEL\\_2](https://www.esa.int/Space_in_Member_States/Spain/SENTINEL_2)

**Artículo científico (versión electrónica):** García, A., Martínez, G., Núñez, G. y Guzmán, A. (1998). *Clasificación Supervisada. Inducción de Árboles de Decisión, Algoritmo k-d*. Centro de Investigación en Computación. Instituto Politécnico Nacional. Recuperado de: <https://www.cic.ipn.mx/aguzman/papers/109%20Algoritmo%20KD.%20Clasificacio n%20supervisada.pdf>

**Documento legal:** Instituto Nacional de Estadística y Geografía. (2022). *Manual de Organización Específico*. Dirección General de Geografía y Medio Ambiente. Recuperado de: [https://sc.inegi.org.mx/repositorioNormateca/MO\\_23Sep21.pdf](https://sc.inegi.org.mx/repositorioNormateca/MO_23Sep21.pdf)

**Documento electrónico:** Instituto Nacional de Estadística y Geografía. (2018). *Manual de Usuario: Procesamiento de Imágenes para la Detección de Crecimientos Urbanos y Viviendas para la Actualización de la Base Cartográfica Única en su Ámbito Urbano*. Dirección General de Geografía y Medio Ambiente. Departamento de Altimetría del Relieve Continental.

**Página web:** Instituto Nacional de Estadística y Geografía. (2022). *¿Quiénes somos?* Consultado en: [https://www.inegi.org.mx/inegi/quienes\\_somos.html](https://www.inegi.org.mx/inegi/quienes_somos.html)

**Página web:** International Business Machines. (2022). *¿Qué es Machine Learning?* Consultado en: <https://www.ibm.com/mx-es/analytics/machine-learning>

**Libro con autor:** Lira, J. (2003). *La Percepción Remota: Nuestros Ojos desde el Espacio*. Fondo de Cultura Económica.

**Artículo científico (versión electrónica):** Lizarazo, I. (2008). *Clasificación de la Cobertura y del Uso de Suelo Urbano Usando Imágenes de Satélite y Algoritmos Supervisados de Inteligencia Artificial*. UD y la Geomática No. 2. Recuperado de: <https://revistas.udistrital.edu.co/index.php/UDGeo/article/view/3669>

**Libro con autor:** Marsland, S. (2015). *Machine Learning. An Algorithmic Perspective*. Taylor & Francis Group.

**Documento electrónico:** Programa Nacional de Ordenamiento Territorial y Desarrollo Urbano 2021-2024. (2021). Secretaría de Desarrollo Agrario, Territorial y Urbano. Recuperado de: <https://www.gob.mx/sedatu/documentos/programa-nacional-de-ordenamiento-territorial-y-desarrollo-urbano-2021-2024>

**Libro con autor:** Rees, G. (2005). *The Remote Sensing Data Book*. Cambridge University Press, 262.

**Libro con autor:** Richards, J. y Jia, X. (1999). *Remote Sensing Digital Image Analysis*. Springer-Verlag, Berlin, Alemania.

**Documento legal:** Sistema Nacional de Información Estadística y Geográfica. (2002). *Ley del Sistema Nacional de Información Estadística y Geográfica*. Recuperado de: [https://sc.inegi.org.mx/repositorioNormateca/Lmj\\_SNIEG.pdf](https://sc.inegi.org.mx/repositorioNormateca/Lmj_SNIEG.pdf)



**Página web:** Sistema Nacional de Información Estadística y Geográfica. (2022). *Misión y Visión del SNIEG*. Consultado en: <https://www.snieg.mx/el-sistema-mision/>

**Contribución a un congreso publicado:** Somvanshi, M., Chavan, P., Tambade, S. y Shinde, S. (2016). *A Review of Machine Learning Techniques using decisión tree and support vector machine*. 2016 International Conference on Computing Communication Control and Automation. Recuperado de <https://doi.org/10.1109/ICCUBEA.2016.7860040>

## Anexo 1.

*Código para clasificación supervisada empleando árboles de decisión.*

```
@author: IsaacNajera
import os, glob
#Definimos la ruta del proyecto
ruta_archivos = r'Carpeta' ###Ingresar liga
os.chdir(ruta_archivos)
#os.getcwd()

#Guardamos la imagen como lista
lista = glob.glob("Imagen.tif") ###Ingresar nombre de imagen
#lista

import rasterio
import numpy as np

RS = rasterio.open(lista[0]) #####Renombrar variable

import geopandas as gpd
#Definimos la Region de Interés
roi = gpd.read_file('Muestreo.shp') #####Ingresar liga del shape
#roi.head()

#Comprobamos que las proyecciones sean iguales
print("Proyección ROI:",roi.crs)
print("Proyección imagen:",RS.crs)
print("Número de bandas imagen:",RS.count)

#Se crea una lista de cobertura
lista_cobertura = []
for point in roi['clases']:
    lista_cobertura.append(point[0:50])
```

```

#Se crea una lista (malla o grid) de coordendas
lista_este = []
lista_norte = []
for point in roi['geometry']:
    lista_este.append(round(point.xy[0][0],3))
    lista_norte.append(round(point.xy[1][0],3))

#Enlistamos las bandas
lista_banda2 = []
lista_banda3 = []
lista_banda4 = []
lista_banda11 = []
lista_banda12 = []
#Para cada punto de la geometría, se le asignará un valor de Radiancia Espacial
###proveniente del ráster
for point in roi['geometry']:
    x = point.xy[0][0]
    y = point.xy[1][0]
    row, col = RS.index(x,y)
    lista_banda2.append(RS.read(1)[row, col])
    lista_banda3.append(RS.read(2)[row, col])
    lista_banda4.append(RS.read(3)[row, col])
    lista_banda11.append(RS.read(4)[row, col])
    lista_banda12.append(RS.read(5)[row, col])

#creamos diccionario de datos
datos = {"cobertura": lista_cobertura,
        "Este": lista_este,
        "Norte": lista_norte,
        "B2": lista_banda2,
        "B3": lista_banda3,
        "B4": lista_banda4,
        "B11": lista_banda11,
        "B12": lista_banda12}

import pandas as pd
#Creamos un DataFrame
data_frame = pd.DataFrame(datos)
#data_frame.head()

#Para exportar el DataFrame
#data_frame.to_csv("Datos_StaLucia.csv")

```

```

#SEPARAMOS LAS VARIABLES PREDICTORIAS
X = data_frame.iloc[:,3:8]
#X.head()
Y = data_frame.iloc[:,0]
#Y.head()

#SEPARAMOS ENTRENAMIENTO Y VALIDACIÓN (TRAINING & TESTING)
#Se necesita instalar sklearn
from sklearn.model_selection import train_test_split #training y testing
from sklearn.metrics import confusion_matrix #matriz de confusión
Xtrain, Xtest, Ytrain, Ytest = train_test_split(X, Y, train_size=0.8, test_size=0.2,
random_state=1)
#Los datos a entrenar y testear son:
#Xtrain.head(), Xtest.head()

#INICIAMOS EL MODELO DE ÁRBOL DE DECISIONES
#Importamos el paquete
from sklearn.tree import DecisionTreeClassifier as DT
instancia_dt = DT()
#print(instancia_dt)

#ENTRENAMOS EL MODELO LLAMADO FIT
#Entrenamiento
instancia_dt.fit(Xtrain, Ytrain)
#print("Las predicciones en Xtest son:{}".format(instancia_dt.predict(Xtest)))

#MATRIZ DE CONFUSIÓN
prediccion = instancia_dt.predict(Xtest)
MC = confusion_matrix(Ytest, prediccion)
#print("Matriz de confusión:\n{}".format(MC))
#Le damos formato a la Matriz de Confusión
trainCM = pd.DataFrame(np.asarray(MC),
                        index=['crecimientos','veg_alta','veg_baja','suelo'],
                        columns=['crecimientos','veg_alta','veg_baja','suelo'])

#Instalar seaborn
import matplotlib.pyplot as plt
import seaborn as sns
fig, ax = plt.subplots(1,figsize=(4,4))
sns.heatmap(trainCM/trainCM.sum(axis=1),annot=True) #->Resultado unitario
#sns.heatmap(trainCM,annot=True) #-> Resultado no unitario
ax.set_xlabel('Modelo predictivo',fontsize=15)
ax.set_ylabel('Real', fontsize=15)
plt.title("Matriz de Confusión",fontsize=18)

```

```

#OBSERVAMOS LA PRECISIÓN GLOBAL O ACIERTO GLOBAL
print("Precisión de testing: {:.3f}".format(instancia_dt.score(Xtest, Ytest)) #3f=3
decimales

#SE EJECUTA EL MODELO A TODA LA IMAGEN RASTER
Mat= np.dstack((RS.read(1),RS.read(2),RS.read(3),RS.read(4),RS.read(5)))
mat.shape

rows, cols, nbands = mat.shape
#rows, cols, nbands

mat = mat.reshape((rows*cols, nbands)) #Obtenemos la cantidad de pixeles
#mat.shape

resultados = instancia_dt.predict(mat)
dt = resultados.reshape((rows,cols))
dt #El resultado se obtiene en tipo string
#Cambiamos de str a int, según el ID de la clase
dt[dt == 'crecimientos'] = 1
dt[dt == 'veg_alta'] = 2
dt[dt == 'veg_baja'] = 3
dt[dt == 'suelo'] = 4

dt
#Convertir tipo int
dt = dt.astype(int)
#dt

#VISUALIZACIÓN DE LA CLASIFICACIÓN
import matplotlib.pyplot as plt
plt.figure(figsize=(8,7))
plt.imshow(dt, cmap="Spectral") #jet,Spectral, viridis, RdYlGn, hsv
plt.colorbar()
plt.title("Sentinel 2 Clasificación Supervisada: Decision Tree")
plt.xlabel("Número de columna")
plt.ylabel("Número de Fila")
plt.show()

#EXPORTACIÓN DE BANDA CLASIFICADA
#dt.dtype
param = RS.meta
param.update(count = 1,
             dtype = 'int32',
             nodata = None)

```

```
#Guardar la exportación
name_clasificacion = os.getcwd() + "\\\" + lista[0][0:-4]+ "_Decision_Tree.tif"
name_clasificacion
#Exportamos la banda
with rasterio.open(name_clasificacion, "w", **param) as Class:
Class.write_band(1,dt)
```

## **Anexo 2.**

### *Glosario*

**Shape:** Es un formato vectorial de almacenamiento digital donde se guarda la localización de los elementos geográficos y los atributos asociados a ellos. No obstante, carece de capacidad para almacenar información topológica. Es un formato multiarchivo, es decir, está generado por varios ficheros informáticos. El número mínimo requerido de ficheros es de tres y tienen las extensiones siguientes:

- .shp – es el archivo que almacena las entidades geométricas de los objetos.
- .shx – es el archivo que almacena el índice de las entidades geométricas.
- .dbf – es la base de datos, donde se almacena la información de los atributos de los objetos.

**Ráster:** En su forma más simple, un ráster es una matriz de celdas o píxeles organizadas en filas y columnas (cuadrícula) en la que cada celda contiene un valor que representa información, como temperatura, elevación, etc. Los ráster pueden ser fotografías aéreas digitales, imágenes de satélite, imágenes digitales o incluso mapas escaneados.

**Ortofoto:** La imagen obtenida a partir de fotografías aéreas, imágenes de satélite o radar, en la cual han sido removidos los desplazamientos causados por la inclinación de la cámara o sensor, el relieve del terreno y la curvatura terrestres. Está referida a una proyección cartográfica, por lo que, posee las características geométricas de un mapa, además de la calidad pictórica de los insumos originales.

**Píxel (picture element):** La unidad más pequeña de información en una imagen o ráster, normalmente cuadrados o rectangulares. El término píxel a menudo se utiliza como sinónimo de celda.

**Clasificación de imagen:** El proceso de ordenar los píxeles de una imagen en clases o clústers. Dependiendo el enfoque del analista y de los procesos, existen dos tipos de clasificación: clasificación supervisada y clasificación no supervisada.

**Clasificación no supervisada:** Enfoque de clasificación de imágenes que ordena los píxeles de la imagen en grupos o clústers, sin la intervención del analista. El proceso se basa únicamente en la distribución de valores de píxeles en un espacio de atributos multidimensional.

**Clúster:** Grupo de píxeles que se puede distinguir en un espacio de atributos multidimensional. Un clúster es similar a una clase solo que el objeto de base que representa es desconocido cuando se realiza el análisis de clustering.

**Marco Geoestadístico:** Es un sistema único y de carácter nacional diseñado por el INEGI, para referenciar correctamente la información estadística de los censos y encuestas con los lugares geográficos correspondientes. Proporciona la ubicación de las localidades, municipios y entidades del país, utilizando coordenadas geográficas. Divide al territorio nacional en áreas con límites identificables en campo, denominadas Áreas geoestadísticas con tres niveles de desagregación: estatal, municipal y áreas básicas (urbano o rural).

**Matriz de confusión:** Es una herramienta estándar de evaluación de modelos estadísticos que ordena todos los casos de modelos en categorías, determinando si el valor de predicción coincide con el valor real. También permite la visualización del desempeño de un algoritmo que se emplea en aprendizaje supervisado y no supervisado.