



Universidad de San Carlos de Guatemala
Facultad de Ingeniería
Escuela de Estudios de Postgrado
Maestría en Ciencias en Geomática

**USO DE IMÁGENES DE SATÉLITE DE ALTA RESOLUCIÓN ESPACIAL EN LA DETECCIÓN
DE CULTIVOS AGRÍCOLAS EN EL MUNICIPIO DE PATZICÍA, CHIMALTENANGO**

Ing. Mario Ottoniel Chávez Can

Asesorado por el Mtro. Juan Miguel Indekeu Rivas

Guatemala, septiembre de 2021

UNIVERSIDAD DE SAN CARLOS DE GUATEMALA



FACULTAD DE INGENIERÍA

**USO DE IMÁGENES DE SATÉLITE DE ALTA RESOLUCIÓN ESPACIAL EN LA DETECCIÓN
DE CULTIVOS AGRÍCOLAS EN EL MUNICIPIO DE PATZICÍA, CHIMALTENANGO**

TRABAJO DE GRADUACIÓN

PRESENTADO A LA JUNTA DIRECTIVA DE LA
FACULTAD DE INGENIERÍA
POR

ING. MARIO OTTONIEL CHÁVEZ CAN

ASESORADO POR EL MTRO. JUAN MIGUEL INDEKEU RIVAS

AL CONFERÍRSELE EL TÍTULO DE

MAESTRO EN INGENIERÍA EN GEOMÁTICA

GUATEMALA, SEPTIEMBRE DE 2021

UNIVERSIDAD DE SAN CARLOS DE GUATEMALA
FACULTAD DE INGENIERÍA



NÓMINA DE JUNTA DIRECTIVA

DECANA	Ing. Aurelia Anabela Cordova Estrada
VOCAL I	Ing. José Francisco Gómez Rivera
VOCAL II	Ing. Mario Renato Escobedo Martínez
VOCAL III	Ing. José Milton de León Bran
VOCAL IV	Br. Christian Moisés de la Cruz Leal
VOCAL V	Br. Kevin Vladimir Armando Cruz
SECRETARIO	Ing. Hugo Humberto Rivera Pérez

TRIBUNAL QUE PRACTICÓ EL EXAMEN GENERAL PRIVADO

DECANA	Ing. Aurelia Anabela Cordova Estrada
DIRECTOR	Ing. Edgar Darío Álvarez Cotí
EXAMINADOR	Ing. Marlon Antonio Pérez Türk
EXAMINADOR	Ing. Edson Toniño Hernández Mazariegos
SECRETARIO	Ing. Hugo Humberto Rivera Pérez

HONORABLE TRIBUNAL EXAMINADOR

En cumplimiento con los preceptos que establece la ley de la Universidad de San Carlos de Guatemala, presento a su consideración mi trabajo de graduación titulado:

USO DE IMÁGENES DE SATÉLITE DE ALTA RESOLUCIÓN ESPACIAL EN LA DETECCIÓN DE CULTIVOS AGRÍCOLAS EN EL MUNICIPIO DE PATZICÍA, CHIMALTENANGO

Tema que me fuera asignado por la Dirección de la Escuela de Estudios de Postgrado, con fecha 23 de mayo 2020.

Ing. Mario Ottoniel Chávez Can



DTG. 391.2021

La Decana de la Facultad de Ingeniería de la Universidad de San Carlos de Guatemala, luego de conocer la aprobación por parte del Director de la Escuela de Estudios de Postgrado, al Trabajo de Graduación titulado: **USO DE IMÁGENES DE SATÉLITE DE ALTA RESOLUCIÓN ESPACIAL EN LA DETECCIÓN DE CULTIVOS AGRÍCOLAS EN EL MUNICIPIO DE PATZICÍA, CHIMALTENANGO**, presentado por el **Ingeniero Mario Ottoniel Chávez Can**, estudiante del programa de **Maestría en Ciencias en Geomática**, y después de haber culminado las revisiones previas bajo la responsabilidad de las instancias correspondientes, autoriza la impresión del mismo.

IMPRÍMASE:


Inga. Anabela Cordova Estrada
Decana



Guatemala, septiembre de 2021

AACE/cc



Guatemala, Agosto 2021

EEPFI-1262-2021

En mi calidad de Director de la Escuela de Estudios de Postgrado de la Facultad de Ingeniería de la Universidad de San Carlos de Guatemala, luego de conocer el dictamen y verificar la aprobación del Revisor y la aprobación del Área de Lingüística al Trabajo de Graduación titulado: **"USO DE IMÁGENES DE SATÉLITE DE ALTA RESOLUCIÓN ESPACIAL EN LA DETECCIÓN DE CULTIVOS AGRÍCOLAS EN EL MUNICIPIO DE PATZICÍA, CHIMALTENANGO"** presentado por el Ingeniero **Mario Ottoniel Chávez Can** quien se identifica con carné **200810507** correspondiente al programa de **Maestría en Geomática**; apruebo y autorizo el mismo.

Atentamente,

"Id y Enseñad a Todos"



Mtro. Ing. Edgar Darío Álvarez Cofi
Director

Escuela de Estudios de Postgrado
Facultad de Ingeniería



Guatemala, Agosto 2021

EEPFI-1261-2021

Como coordinador de la **Maestría en Geomática** doy el aval correspondiente para la aprobación del Trabajo de Graduación titulado: **"USO DE IMÁGENES DE SATÉLITE DE ALTA RESOLUCIÓN ESPACIAL EN LA DETECCIÓN DE CULTIVOS AGRÍCOLAS EN EL MUNICIPIO DE PATZICÍA, CHIMALTENANGO"** presentado por el Ingeniero **Mario Ottoniel Chávez Can** quien se identifica con carné **200810507**.

Atentamente,

"Id y Enseñad a Todos"

Mtro. Ing. Marlon Antonio Pérez Turk
Coordinador de Maestría
Escuela de Estudios de Postgrado
Facultad de Ingeniería



Guatemala, Agosto de 2021

EEPFI-1263-2021

En mi calidad como asesor del profesional Mario Ottoniel Chávez Can quien se identifica con carné **200810507** procedo a dar el aval correspondiente para la aprobación del Trabajo de Graduación titulado: **"USO DE IMÁGENES DE SATÉLITE DE ALTA RESOLUCIÓN ESPACIAL EN LA DETECCIÓN DE CULTIVOS AGRÍCOLAS EN EL MUNICIPIO DE PATZICÍA, CHIMALTENANGO"** quien se encuentra en el programa de **Maestría en Geomática** en la Escuela de Estudios de Postgrado de la Facultad de Ingeniería de la Universidad de San Carlos de Guatemala.

Atentamente,

"Id y Enseñad a Todos"

Mtro. Juan Miguel Indekeu Rivas
Asesor

ACTO QUE DEDICO A:

- Dios** Por inspirarme y darme fuerza para continuar en este proceso de obtener otra meta más en mi vida.
- Mis padres** Mario Chávez y Micaela Can. Su amor y su ejemplo serán siempre fuente de motivación.
- Mi hermana** Fátima Chávez. Por animarme a perseverar en la consecución de esta meta.
- Mi esposa** Cesia Ovando. Por ser una importante influencia en mi carrera, a quien amo y con quien compartimos todos los anhelos de la vida.
- Mi hija** Ana Lucía Chávez, fue de gran alegría y motivación esperarte mientras realizaba esta tesis.

AGRADECIMIENTOS A:

**Universidad de San
Carlos de Guatemala**

Por ser una importante influencia en mi carrera y abrirme las puertas para formarme en esta prestigiosa casa de estudios.

Facultad de Ingeniería

Por permitirme ser parte del programa de maestría y formarme con excelencia académica.

Mi asesor

Juan Indekeu, por compartir sus conocimientos y apoyarme siempre en el proceso de elaboración de esta tesis.

**Mis amigos de la
maestría**

Claudia Saput, Rodolfo Fuentes y Erick Mejía, quienes ofrecieron siempre su apoyo y ánimos para la realización de este proyecto.

Apoyo de campo

A mis exalumnos de la EFA de Sololá Diego Xicay y Humberto Racanac, residentes en la zona de estudio, por su apoyo en el proceso de colecta de datos de campo.

Maxar y PlanetLab

Agradezco a estas dos empresas por atender mi solicitud y permitirme el acceso a las imágenes de satélite utilizadas en este estudio

ÍNDICE GENERAL

ÍNDICE DE ILUSTRACIONES	III
LISTA DE SÍMBOLOS	V
GLOSARIO	VII
RESUMEN	IX
PLANTEAMIENTO DEL PROBLEMA.....	XI
OBJETIVOS.....	XIII
Hipótesis	XV
RESUMEN DEL MARCO METODOLÓGICO	XVII
INTRODUCCIÓN	XXI
1. MARCO REFERENCIAL.....	1
1.1. Antecedentes.....	1
1.1.1. Imágenes de satélite utilizadas actualmente en agricultura de precisión.....	1
1.1.2. Teledetección en cultivos agrícolas	3
1.1.3. Técnicas actuales de clasificación de imágenes y criterios para su selección	4
1.1.4. Métodos y algoritmos de clasificación evaluados en agricultura	5
1.2. Justificación	9
1.3. Alcances	11
1.3.1. Perspectiva investigativa	11
1.3.2. Perspectiva técnica.....	12
1.3.3. Perspectiva de resultados.....	12

2.	MARCO TEÓRICO	15
2.1.	Fundamentos de teledetección	15
2.2.	Principio de la clasificación de imágenes	16
2.3.	Clasificador de Máxima Verosimilitud (MLC).....	19
2.4.	Clasificador Support Vector Machine (SVM)	21
2.5.	Clasificador de Árboles Aleatorios (RT)	22
2.6.	La calidad de la clasificación	24
2.7.	Matriz de confusión	24
2.8.	Exactitud global de la clasificación	25
2.9.	Fiabilidad de las clases individuales.....	26
2.10.	Índice Kappa	27
3.	PRESENTACIÓN DE RESULTADOS.....	29
4.	DISCUSIÓN DE RESULTADOS.....	43
	CONCLUSIONES.....	47
	RECOMENDACIONES	49
	REFERENCIAS	51
	APÉNDICES.....	55
	ANEXOS.....	63

ÍNDICE DE ILUSTRACIONES

FIGURAS

1.	Ploteo del vector de entidades en el espacio de entidades (feature space) de una imagen con dos y tres bandas para un píxel en específico	17
2.	Espacio de entidades mostrando los distintos clústeres para cinco clases, notar que cada clase ocupa un área limitada en el espacio de entidades.....	18
3.	Ejemplo simplificado de MLC con una banda espectral y dos clases	19
4.	Principio del algoritmo MLC. Los contornos equiprobables son mostrados sin límite de distancia (superior derecha) y con límite o threshold distance (inferior derecha)	20
5.	Representación simplificada del clasificador SVM	22
6.	Representación del clasificador Random Forest.....	23
7.	Asignación de píxeles de entrenamiento y validación para la PS (a) y WV2 (b).....	31
8.	Mapa de puntos de muestreo distribuidos dentro de los 20 km ² de la zona de estudio	32
9.	Mapa de cultivos obtenido con las bandas VIS/NIR de la imagen PS mediante el clasificador RT	34
10.	Mapa de cultivos obtenido con las bandas VIS/NIR de la imagen WV2 mediante el clasificador RT	35
11.	Mapa de cultivos obtenido con las bandas VIS/IR/NIR de la imagen WV2 mediante el clasificador RT	36

12.	Porcentaje de cobertura de cada clase sobre una superficie de 900 ha, obtenida con las imágenes PS y WV2 clasificadas mediante el algoritmo RT.....	41
-----	---	----

TABLAS

I.	Satélites recomendados para aplicaciones en agricultura de precisión.....	2
II.	Criterios de selección de técnicas de clasificación	5
III.	Comparación de distintos métodos de clasificación de imágenes realizadas en los últimos años pertenecientes a investigaciones publicadas en idioma inglés	8
IV.	Modelo de matriz de confusión	25
V.	Clases identificadas en el muestreo de campo con su respectivo número de parcelas y píxeles seleccionados para el entrenamiento y validación	30
VI.	Parámetros utilizados dentro de la clasificación supervisada para los distintos clasificadores	33
VII.	Intervalos de confianza de los índices Kappa para el 95 % de confianza para la clasificación de las imágenes PS y WV2 mediante tres clasificadores	36
VIII.	Integración de las matrices de confusión obtenidas de la clasificación con RT para las imágenes PS con las bandas VIS/NIR, WV2 con VIS/NIR y WV2 con VIS/RE/NIR para las clases 1 al 8.	37
IX.	Integración de las matrices de confusión obtenidas de la clasificación con RT para las imágenes PS con las bandas VIS/NIR, WV2 con VIS/NIR y WV2 con VIS/RE/NIR para las clases 9 al 16.	39
X.	Cuantificación de las clases identificadas con el algoritmo RT para una ROI de 900 ha.....	42

LISTA DE SÍMBOLOS

Símbolo	Significado
ha	Hectárea
km²	Kilómetro cuadrado
>	Mayor que
≤	Menor o igual que
<	Menor que
m²	Metro cuadrado
msnm	Metros sobre el nivel del mar
nm	Nanómetro

GLOSARIO

Algoritmo	Conjunto ordenado de operaciones sistemáticas que permite hacer un cálculo y hallar la solución de un tipo de problema.
ArcGIS Pro	Aplicación SIG de escritorio para crear y trabajar con datos espaciales.
Banda	Franja del espectro en la que opera el sensor del satélite para captar los niveles de energía emitidos por los objetos.
DN	Valor numérico que codifica cada píxel.
MCL	Siglas que hacen referencia al algoritmo de clasificación Maximum Likelihood Classifier.
NIR	Acrónimo con el que se designa a la parte del espectro electromagnético del infrarrojo cercano, entre 800 y 2,500 nm.
Parcela	Porción de terreno que puede ser utilizada de diferentes formas para sembrar un cultivo agrícola en específico.

Red Edge	Acrónimo con el que se designa a la parte del espectro electromagnético en la transición de la banda del rojo a la banda del infrarrojo cercano.
Resolución espacial	Tamaño de píxel de una imagen con el que se muestra la unidad mínima de representación.
RT	Sigla que hace referencia al algoritmo de clasificación Random Trees.
Survey123	Es parte de la nube geoespacial de Esri y es una solución completa y basada en formularios que permite crear, compartir y analizar encuestas.
SVM	Sigla que hace referencia al algoritmo de clasificación Support Vector Machine.
VIS	Acrónimo con el que se designa a la parte del espectro electromagnético del rango visible entre, 380 y 700 nm.

RESUMEN

La actividad agrícola en el altiplano central y occidental de Guatemala se caracteriza por la producción de diversidad de cultivos, en su mayoría hortalizas, que son cosechadas en unidades productivas de pequeña extensión, las cuales, ante la disponibilidad actual de imágenes de satélite de observación de la tierra de alta resolución espacial y temporal, pueden ser mapeadas aplicando técnicas de teledetección.

El presente estudio tiene como objetivo determinar qué algoritmo de clasificación es el mejor para la detección y discriminación de cultivos en el contexto antes mencionado, mediante el uso de imágenes de satélite de alta resolución espacial, de acuerdo con los criterios de bandas espectrales y resolución espacial, para darle seguimiento a la línea de investigación del mapeo a través de imágenes de satélite con percepción remota y un enfoque cuantitativo. Para esto se eligió una zona de estudio dentro del municipio de Patzicía, Chimaltenango, la cual cuenta con las características deseadas para el experimento.

Como procedimiento metodológico se realizó la captura de datos de campo, la creación de una capa de datos de entrenamiento y validación, la elección y obtención de imágenes de satélite, la clasificación en sí de dichas imágenes y, finalmente, la evaluación de la calidad de la clasificación.

El área de estudio posee una topografía plana en su mayoría, en la que se siembran hortalizas de diversas especies con rotación de cultivos, usualmente en parcelas de 30-90 m por lado. La fase de captura de datos de campo se realizó

entre el 27 y 29 de mayo de 2020, fechas en las que pasó el satélite WorldView-2 y PlanetScope sobre el área de interés. Basándose en los datos se creó la base de datos para el entrenamiento y la validación.

El proceso de clasificación se efectuó por medio del *software* ArcGIS Pro (<https://bit.ly/3tl8Xqc>) mediante los algoritmos Maximum Likelihood Classifier (MLC), Support Vector Machine (SVM) y Random Trees (RT).

En el proceso de evaluación de la calidad de la clasificación, con base en el índice Kappa, se obtuvieron resultados prometedores con el algoritmo RT definiéndose como el mejor clasificador, además, se observó que la incorporación de la banda Red Edge como complemento a las bandas VIS/NIR no se tradujo en una mejora en la precisión de la clasificación.

Finalmente, se realizó la cuantificación de la cobertura de cada clase detectada para el mejor clasificador, se encontró discrepancias importantes para algunos cultivos, observándose mejores aciertos cuando se emplean las imágenes WorldView-2 en comparación con PlanetScope.

PLANTEAMIENTO DEL PROBLEMA

Las zonas agrícolas del altiplano de Guatemala se caracterizan por contar con variedad de cultivos, principalmente hortalizas, cosechados en unidades productivas pequeñas, cuyas parcelas mínimas pueden ser de 420 - 1120 m², dependiendo de la localidad. Para la aplicación de teledetección mediante sensores remotos de observación de la tierra sobre estas zonas se dispone actualmente de una gama de imágenes de satélite de alta resolución espacial, de 5.0 - 0.3 m por píxel, con bandas del espectro electromagnético desde el visible (VIS) al infrarrojo cercano (NIR), y resoluciones temporales iguales o menores a cinco días, las cuales, gracias al desarrollo de distintos algoritmos de clasificación, son ideales para estudios y monitoreo de cobertura vegetal.

Tomando en cuenta los criterios de cobertura y disponibilidad actual de imágenes a la región de estudio, es decir, la zona agrícola del municipio de Patzicía, Chimaltenango, se definen las imágenes WorldView-2 y PlanetScope como fuente de información valiosa para estudios de clasificación de cultivos en las condiciones de zonas agrícolas con diversidad de cultivos y parcelas de poca extensión; sin embargo, se carece de información contextualizada que pueda servir de base para este propósito, así como de los algoritmos de clasificación más apropiados, disponibles actualmente en los softwares de teledetección.

De lo planteado anteriormente, surge la interrogante principal:

- ¿Qué algoritmo de clasificación es mejor para la detección y discriminación de cultivos en un contexto de parcelas de poca extensión y diversidad de cultivos agrícolas, utilizando imágenes de satélite de alta resolución

espacial si se toman en cuenta los criterios de bandas espectrales y resolución espacial?

De esta pregunta se desglosan varias preguntas secundarias:

- ¿Cuál de los clasificadores se debe elegir, dentro de una clasificación supervisada basada en píxeles, para lograr una adecuada identificación de especies de cultivos agrícolas utilizando imágenes de alta resolución espacial?
- ¿Qué nivel de mejora se obtiene en la precisión de la clasificación cuando se incluyen bandas adicionales a VIS/NIR en una clasificación supervisada basada en píxeles?
- Cuando se trabaja con imágenes de alta resolución espacial para la detección de cultivos agrícolas en el contexto antes mencionado, ¿es aún determinante la finura del píxel sobre la precisión en la clasificación?

OBJETIVOS

General

Determinar qué algoritmo de clasificación es mejor para la detección y discriminación de cultivos en un contexto de parcelas de poca extensión y diversidad de cultivos agrícolas, utilizando imágenes de satélite de alta resolución espacial, tomando en cuenta los criterios de bandas espectrales y resolución espacial.

Específicos

- Establecer cuál de los clasificadores: Maximum Likelihood Classifier (MLC), Support Vector Machine (SVM) y Random Trees (RT) es el más apropiado para una clasificación supervisada basada en píxeles en la identificación de especies de cultivos agrícolas utilizando imágenes de alta resolución espacial.
- Cuantificar el nivel de mejora en la precisión de la clasificación cuando se incluye la banda Red Edge (RE) como complemento a las bandas VIS/NIR en una clasificación supervisada basada en píxeles, utilizando las imágenes satelitales WorldView-2.
- Determinar en qué medida es aún determinante la finura del píxel sobre la precisión en la clasificación cuando se trabaja con imágenes de alta resolución espacial para la detección de cultivos agrícolas en la zona de

estudio, utilizando imágenes PlanetScope de 3 metros y WorldView-2 de 2 metros de resolución espacial.

Hipótesis

Dado el nivel de detalle que puede obtenerse de las imágenes de alta resolución espacial, cada parcela será cubierta por suficiente número de píxeles, por lo que ambas, WorldView-2 y PlanetScope serán ideales para la clasificación supervisada, esto se reflejará en un nivel de concordancia alto (índice Kappa > 0.8) en la clasificación, no obstante, es posible obtener una mejora al utilizar dentro de la clasificación la banda Red Edge, incluida en la imagen que la disponga, dada su sensibilidad a la vegetación, por lo que permitirá una mejor discriminación de cultivos agrícolas. Los tres algoritmos de clasificación brindarán resultados aceptables, con índices Kappa superiores a 0.8, sin embargo, los algoritmos no paramétricos SVM y RT, dado que son concebidos como algoritmos más evolucionados, prometen brindar mejores resultados ante MLC.

RESUMEN DEL MARCO METODOLÓGICO

- Tipo de investigación

La línea de investigación dentro de la cual se sitúa el presente trabajo de tesis es el mapeo a través de imágenes de satélite utilizando percepción remota, siendo de tipo cuantitativa, ya que se basó en la captura de datos de campo para su utilización en el entrenamiento y validación de distintos algoritmos de clasificación y su posterior análisis estadístico a través de matrices de confusión, a partir de las cuales se derivaron distintos índices de calidad de la clasificación.

- Diseño de investigación

La zona de estudio se encuentra dentro del municipio de Patzicía, Chimaltenango, una zona netamente agrícola, caracterizada por un sistema de producción intensivo, principalmente de hortalizas, los cuales se siembran en unidades productivas, cuyas parcelas mínimas tienen 30 metros por lado, pudiendo aumentar dos o tres veces este valor. Se definieron los cultivos ubicados en las cercanías de las orillas de las vías principales dentro de la zona de estudio como sitios de muestreo, de esta forma se obtuvieron parcelas representativas por cultivo y otros objetos de interés tales como suelo desnudo, agricultura con cobertura e infraestructura.

- Procedimiento metodológico

Se realizó la captura de datos de campo, donde se muestrearon parcelas, cuya información sobre cultivo, etapa fenológica, fotografía y su ubicación geográfica se ingresó por medio de un teléfono inteligente a un formulario previamente diseñado. A partir del centro de cada parcela muestreada se seleccionaron los píxeles representativos en radios de 5-20 m, quedando definida de esta forma una capa final de puntos de muestreo cuyo 50 % corresponde a los datos de entrenamiento y el otro 50 % a los datos de validación, esta asignación se efectuó de forma aleatoria.

Las imágenes de satélite se seleccionaron, gestionaron y descargaron por medio del panel de exploración web de los proveedores, en el cual se definieron parámetros como cobertura al área de interés, porcentaje de nubosidad y fechas requeridas.

Mediante la herramienta Image Classification del *software* ArcGIS Pro se efectuó el proceso de clasificación, con como entradas la imagen a clasificar y los datos de entrenamiento previamente preparados, además, se definieron parámetros propios de cada algoritmo de clasificación.

Se calculó el índice Kappa a partir de las matrices de confusión generadas para cada resultado de clasificación. Con este índice se definió la calidad final del algoritmo de clasificación, otorgando mayor confianza a aquel clasificador cuyo índice Kappa fuera más cercano a 1. La generación de la matriz de confusión para la evaluación de la calidad de cada clasificación se efectuó utilizando la herramienta Compute Confusion Matrix de ArcGIS pro, para ello se utilizó como entrada dentro de dicha herramienta la capa de puntos de validación, el cual contiene un campo que corresponde a la verdad del terreno (Ground Truth) y otro

con el resultado de clasificación (Classified), este último obtenido a partir del *raster* resultante de cada clasificación.

Finalmente, se analizó a detalle las matrices de confusión para las clasificaciones que presentaron mejores resultados, describiendo las exactitudes individuales, así como la generación de su mapa respectivo. En este punto también se realizó una exploración visual de los resultados, así como la generación de gráficas de cuantificación de cultivos.

- Instrumentos de recolección de información

Para la captura de datos de campo se utilizó la aplicación de formulario ArcGIS Survey123, el cual fue llenado desde un teléfono inteligente, de esta forma fue posible almacenar los datos en tiempo real como capa de puntos dentro de una plataforma basada en la nube para este propósito. En el apéndice 1 hay un resumen de datos colectados durante la fase de campo mediante el formulario de Survey123.

INTRODUCCIÓN

Actualmente, se dispone de imágenes de satélites de observación de la tierra de alta resolución espacial (<5m), con tiempos de revisita menores a 30 días y capturas en rangos del espectro electromagnético situadas entre las regiones del visible al infrarrojo cercano, las cuales las hacen ideales para su uso en agricultura. Durante las dos últimas décadas, se han desarrollado estudios de teledetección aplicada a la agricultura extensiva, en la que se evidencia su factibilidad en la identificación y discriminación de cultivos, principalmente con imágenes de mediana resolución espacial, entre ellas Sentinel y Landsat, a través de distintos algoritmos de clasificación, sin embargo, es notoria la carencia de este tipo de estudios en zonas agrícolas con características de unidades productivas de pequeña extensión y diversidad de cultivos, como el caso de la región del altiplano de Guatemala. Este estudio tiene como objetivo determinar qué algoritmo de clasificación es mejor para la detección y discriminación de cultivos agrícolas en el contexto antes mencionado, con el auxilio de imágenes de satélite de alta resolución espacial.

En el primer capítulo se presenta el marco referencial, en el que se hace una revisión bibliográfica de los antecedentes, se mencionan las características de las imágenes de satélite utilizadas actualmente en agricultura de precisión y algunos estudios recientes en los que se lograron identificar cultivos agrícolas mediante teledetección con imágenes de satélite. También contiene la justificación y los alcances de la investigación desde la perspectiva investigativa, técnica y de resultados.

En el segundo capítulo, se desarrolla el marco teórico, en el que se refieren los conceptos de fundamentos de teledetección y el principio de clasificación de imágenes. Para una mejor comprensión del tema de investigación se incluye una descripción de cada uno de los algoritmos de clasificación empleados en el experimento, así como la fundamentación teórica para la evaluación de la calidad de la clasificación como la interpretación de la matriz de confusión y el índice Kappa.

En el capítulo tres, se presenta los resultados; en el cuarto capítulo se discuten los resultados: la descripción de la zona de estudio, la definición de las clases identificadas en campo, su distribución geográfica en el área de estudio y la consolidación de los datos de entrenamiento y validación. También se describen las características de las imágenes PlanetScope (PS) y WorldView-2 (WV2) utilizadas y las modalidades en las cuales se emplearon dentro de la clasificación. Finalmente, se presentan y discuten los índices Kappa para todas las clasificaciones realizadas, los mapas de cultivos, la cuantificación de las coberturas obtenidas para las distintas clases y un consolidado de las matrices de confusión para las mejores clasificaciones.

En la parte final del documento, están las conclusiones y las recomendaciones en las que se indica el mejor clasificador, la cuantificación de la mejora en la clasificación con la banda RE y la definición de la resolución espacial ideal para mapeo de cultivos mediante teledetección en regiones con el contexto del área de estudio.

1. MARCO REFERENCIAL

Como marco referencial se presentan los antecedentes, justificación y alcances de la presente investigación.

1.1. Antecedentes

A continuación, se indica la tecnología actual utilizada en la teledetección aplicada a la agricultura.

1.1.1. Imágenes de satélite utilizadas actualmente en agricultura de precisión

En teledetección existen criterios que deben tomarse en cuenta para la elección de las imágenes de satélite adecuadas.

Para ello es necesario comprender el propósito del estudio; esto es: el tamaño del objeto a identificar, el tipo de objeto, la frecuencia de monitoreo, así como su disponibilidad para la zona de estudio (Tolpekin y Stein, 2012).

Actualmente existen imágenes de satélites de observación de la tierra, multiespectrales, con distintos tiempos de revisita y cobertura, disponibles en diferentes rangos de resolución espacial (Thenkabail, 2016):

- Alta resolución espacial (<5m)
- mediana resolución espacial (5-100 m)
- baja resolución espacial (>100m).

Para el caso de aplicaciones en agricultura, se recomienda la elección de satélites con las siguientes características (Sozzi, Marinello, Pezzuolo y Sortori, 2018):

- Tiempo de revisita (resolución temporal) que permita al menos una captura por mes (resolución temporal ≤ 30 días).
- Resolución espectral que cuyas bandas esté situadas en la región del espectro que permita el cálculo de índices de vegetación (450 - 900 nm).
- Poder computacional bajo para el proceso de los datos.

Tabla I. **Satélites recomendados para aplicaciones en agricultura de precisión**

Satélite	Resolución espacial (m)	Resolución espectral (nm)	Resolución radiométrica (bits/píxel)	Revisita (días)
Deimos-2	0.75	466-697/770-892	10	2
PlanetScope	3	420-700/770-900	16	1
GeoEye-1	0.5	450-690/780-920	11	3
Kompsat-2	1	450-690/760-900	14	6
Kompsat-3	0.7	450-690/760-900	14	3
Kompsat-3A	0.55	450-690/760-900	14	3
Landsat-7/8	15	450-690/770-900	8 - 12	8
Pleiades-1A/1B	0.5	430-720/750-950	12	1
RapidEye	5	440-685/690-850	12	5.5
Sentinel-2	10	458-680/785-900	16	5
Spot-6/7	1.5	455-695/760-890	12	1
WorldView-2/3/4	0.3-0.5	450-690/770-1040	11	1

Fuente: Sozzi, Marinello, Pezzuolo y Sortori. (2018). *Benchmark of satellites image services for precision agricultural use.*

1.1.2. Teledetección en cultivos agrícolas

A continuación, se mencionan algunos estudios recientes en los que se lograron identificar cultivos agrícolas mediante teledetección con imágenes de satélite.

En un estudio realizado en México se analizó la separabilidad espectral en una zona agrícola para identificar el cultivo de chile, nogal, cebolla, sandía y alfalfa (Manjarrez, Pinedo, Vélez y Pinedo, 2007) demostrando de que las bandas VIS/SWIR de Landsat TM son las adecuadas para su utilización dentro de una clasificación supervisada; en España se realizó un estudio similar utilizando las bandas VIS, NIR y SWIR de Landsat 7 a lo largo del ciclo de cultivo, encontrándose distintos períodos óptimos para su discriminación en los cultivos de forrajeras, maíz, cereales, guisantes, arroz, girasol y frutales (Sánchez y de la Riva, 2015).

En Argentina se estudiaron una variedad de usos del suelo en una región agrícola diversa y fragmentada, logrando identificar los momentos idóneos para discriminar cada una de las clases, obteniéndose buenos resultados al utilizar las bandas RED, NIR, IRM e IRL de Landsat 5 y Landsat ETM7 (Vásquez, Massuelli y Platzcek, 2006).

Un estudio simultáneo en Argentina y España definió el mejor método de clasificación con imágenes satelitales Sentinel-2, y cuantificó su mejora comparada a otros sensores, como los disponibles en SPOT, generando un mapa de uso del suelo donde se muestran distintos cultivos agrícolas (Borrás, Delgado, Pezzola, Pereira, Morassi y Camps-Valls, 2017).

En otro estudio publicado en Argentina se argumenta que en varias ocasiones no se dispone de estimaciones sobre el nivel de correspondencia entre los resultados generados utilizando técnicas de clasificación de imágenes satelitales y tipos sembrados observados a través técnicas de muestreo en el terreno, la evaluación de técnicas de clasificación realizada sobre distintas imágenes satelitales permitió estudiar el método de teledetección de especies agrícolas cultivadas a partir de firmas espectrales, logrando distinguir cultivos como maíz, soya y papa (Pantaleone y Tosini, 2012).

1.1.3. Técnicas actuales de clasificación de imágenes y criterios para su selección

Actualmente, se han definido distintas técnicas de clasificación de imágenes, las cuales tiene beneficios y limitaciones a considerar antes de elegir qué clasificación es la más adecuada para el análisis. Algunos aspectos que se deben considerar son el nivel de detalle requerido, la resolución espacial de las imágenes y el tiempo disponible para entrenar el clasificador.

Los métodos no supervisados y supervisados son los dos métodos principales de clasificación de imágenes, estos están disponibles en los softwares de uso común en teledetección (Environmental Systems Research Institute, s.f.). Cada método tiene requisitos de datos de entrada y diferentes salidas posibles. De acuerdo con la tabla II, existen dos opciones principales para los métodos de clasificación: basados en píxeles o basados en objetos.

En la tabla II se resume y sugiere la técnica de clasificación más apropiada para determinado estudio.

Tabla II. **Criterios de selección de técnicas de clasificación**

Técnica	Nivel de detalle requerido	Resolución espacial de la imagen	Tiempo de entrenamiento
No supervisada basada en píxeles	Área	Baja	Ninguno
Supervisada basada en píxeles	Área	Alta y baja	Razonable
Supervisada basada en objetos	Objeto	Alta	Largo
Aprendizaje profundo (Deep Learning) basado en objetos	Objeto y área	Alta	Excesivo

Fuente: Environmental Systems Research Institute. (s.f.). *Introduction to Image Classification, Web Course*. Consultado el 13 de marzo de 2020. Recuperado de <https://bit.ly/3g5qbE9>.

1.1.4. Métodos y algoritmos de clasificación evaluados en agricultura

Para la cartografía de los usos del suelo Manjarrez, Pinedo, Vélez y Pinedo (2007) utilizaron el método de clasificación supervisada, aplicando la técnica de máxima probabilidad gaussiana, demostrando la factibilidad de la utilización de las bandas de las imágenes Landsat TM en la diferenciación de cultivos agrícolas. Este clasificador también ha sido utilizado por Sánchez y de la Riva (2015) con imágenes Landsat 7, quienes, al computar los resultados mediante una matriz de confusión, obtuvieron una precisión global del 72 %, utilizando el 20 % de sus parcelas de muestreo en la clasificación y el resto como validación.

Vásquez, Massuelli y Platzeck (2006) determinaron que la clasificación no supervisada presenta grandes deficiencias para la determinación de patrones

espectrales de distintos usos de suelo en ambientes heterogéneos, y aunque la clasificación supervisada es la más utilizada, los resultados encontrados en la zona de estudio no son muy satisfactorios. Esta consideración se tomó en cuenta en la investigación desarrollada por Borrás *et al.* (2017) quienes mencionan que lo que hace la clasificación supervisada es forzar el resultado para que tenga correspondencia con coberturas de la tierra definidas por el interés del analista, sin embargo, no hay garantía de que las clases sean separables estadísticamente.

Skidmore (1989) y Chuvieco (2000) parafraseados por Vásquez, Massuelli y Platzeck (2006) mencionan un tercer tipo de clasificación, denominado método del árbol, en el cual se pueden ir discriminando clases entre sí en pasos sucesivos, tal como lo realizaría un sistema experto, utilizando para cada caso la banda o sus combinaciones específicas que permitan separar una clase del resto.

El algoritmo Random Forest (RF) constituye una colección de árboles descorrelacionados que posteriormente se promedian. RF se ha aplicado satisfactoriamente en muchos problemas de regresión y clasificación de datos de observación de la Tierra y han generado resultados satisfactorios (Gislason, Benediktsson y Sveinsson, 2006). Dentro de la clasificación del árbol y sus derivados, el NDVI es una fuente de información importante en la discriminación de usos del suelo (Vásquez, Massuelli y Platzeck, 2006).

Con atención a la lista de investigaciones relacionadas con la agricultura y mediante el empleo de la clasificación supervisada, Borrás *et al.* (2017) llevaron a cabo una clasificación de usos del suelo utilizando el algoritmo Linear Discriminant Analysis (LDA).

El principio de funcionamiento de LDA es estimar una proyección de los datos entrantes, con el propósito de que la separabilidad de clases sea la mayor posible; otro algoritmo para la clasificación supervisada es el de los vecinos más próximos (K-NN) el cual es un método de clasificación y regresión no paramétrico; realiza una estimación de la clase de un individuo (píxel, parcela, entre otros.) en función de los k vecinos más cercanos a través un sistema de selección (Hastie, Tibshirani y Friedman, 2009).

Finalmente, Borrás *et al.* (2017) proponen la combinación de clasificadores para obtener una mejora en los resultados, mediante la técnica del máximo voto, en el que cada píxel es clasificado con todos los métodos y al final se asigna a la clase a la que con más frecuencia se presenta, resaltando que es una aplicación robusta y sencilla de implementar.

Por último, otro algoritmo de clasificación evaluado en teledetección aplicada a la agricultura es el clasificador angular SAM, mostrando resultados satisfactorios sobre imágenes Landsat y ASTER en una investigación realizada por García y Martínez (2010). SAM compara la semejanza entre dos espectros a partir de su desviación angular, suponiendo que forman dos vectores en un espacio n -dimensional, correspondiendo n al número de bandas de la imagen (Chuvieco, 2002, parafraseado por García, 2010).

En las evaluaciones de métodos de clasificación utilizadas en las investigaciones mencionadas anteriormente, la matriz de confusión es la más utilizada, además del índice Kappa quien se emplea como medida de precisión.

Tabla III. **Comparación de distintos métodos de clasificación de imágenes realizadas en los últimos años pertenecientes a investigaciones publicadas en idioma inglés**

Referencia	Mayor exactitud	Exactitud Intermedia	Peor exactitud
Lu & Weng, 2007	NN, DT, ER, Kba		MLC
Akgun, Eronat, & Turk, 2004	MLC	MaD, LD	PaM
Madhura, 2015	MLC		MD, Mad
Escape, y otros, 2014	MLC		IS
Oliveira, Zanetti, Junior, & das Graças, 2016	NN	MLC, MD	PaM
Freitag, 2015	MLC		MiM, HyCl
Ayhan & Kansu, 2011	NN		MLC, FLM
Lin & Zhu, 2018	SVM		MaD, IS, MD
Hao, Wang, & Niu, 2015	HyMB, HyKF		RF, SVM, C5.0
Zhao, Zhang, Ma, & Pan, 2017	QUEST, SAM, MD	MaD	MaD, SVM, Kme

NN = Neural Network, DT = Decision Tree, ER = Evidential Reasoning, Kba = Knowledge-based approach, MLC = Maximum Likelihood Classifier, SVM = Support Vector Machine, HyMV = Hybrid M-Voting, HyKF O Hybrid K-Fusion, MD = Minimum Distance, MaD = Mahalanobis Distance, Kme = K-means, LD = Linear Discriminant, RF = Random Forest, PaM = Parallelepiped Method, MiM = Migration Means, HyCl = Hybrid Classification, FLM = Fuzzy Locig Method, IS = Isodata

Fuente: elaboración propia.

En la tabla III se contiene una recopilación de investigaciones relacionadas con la clasificación de uso de suelo en general con imágenes de satélite realizadas en los últimos años, pertenecientes a la literatura publicada en idioma inglés; puede observarse el desempeño de los clasificadores mencionados en los párrafos anteriores.

Dado que la mayor parte de investigación descrita anteriormente se centra en el uso de imágenes de satélite de mediana resolución espacial como las misiones Landsat y Sentinel para unidades agrícolas productivas de gran extensión, es importante determinar el desempeño de las imágenes obtenidas por sensores de mayor resolución espacial y temporal en condiciones locales. No debe descartarse también la selección adecuada del algoritmo de clasificación dentro de la gran gama que actualmente existe.

Es notoria la carencia de estudios relacionados a la aplicación de teledetección en la identificación de cultivos en zonas agrícolas con características de unidades productivas de pequeña extensión y diversidad de cultivos, como el caso de la región del altiplano de Guatemala, por lo que la presente investigación contribuirá a establecer consideraciones técnico científicas en la formulación de futuras metodologías de trabajo, que permitan el monitoreo e identificación oportuna, confiable y de bajo costo de la actividad agrícola en el sector.

1.2. Justificación

Las líneas de investigación dentro de las cuales se sitúa la presente idea de tesis son: mapeo a través de imágenes de satélite utilizando percepción remota, la cual posteriormente se podría aplicar a los SIG aplicados a ordenamiento territorial.

En los últimos años, ha incrementado la necesidad y el interés por parte de distintas entidades de contar con información actualizada y confiable acerca del uso y cobertura de la tierra, muestra de ello son los proyectos de cobertura nacional en los distintos países los cuales tienen el objetivo de actualizar las

bases de datos de uso de la tierra. Las imágenes provenientes de distintos satélites de observación de la tierra son una potente herramienta para la planificación, monitoreo, manejo y toma de decisiones en el sector agrícola ya que permiten contar con información confiable para el seguimiento y monitoreo de los cultivos.

Dentro de las aplicaciones, se pueden mencionar la estimación de rendimientos de cosecha, la densidad de siembra en un determinado lote, parcela o finca, la clasificación de cultivos; todo esto sirve de apoyo en el establecimiento de mecanismos de administración sostenible de los recursos agrícolas en una determinada localidad, así como en el establecimiento de estrategias de comercialización.

A pesar de que se han realizado varios estudios y existen investigaciones importantes realizadas en otros países con relación al uso de imágenes de satélite para la detección de cultivos agrícolas, no se recomienda realizar extrapolaciones, más bien es importante investigar la aplicabilidad de dichos avances al propio contexto. Es importante profundizar en el tema ya que en la actualidad aún se presentan inconvenientes en la determinación de algunos usos de la tierra, principalmente cuando se presentan condiciones heterogéneas en la composición del paisaje, como relieve, distintos tipos de suelo y diversidad de usos.

En los últimos años, ha aumentado el interés de los proveedores de imágenes de satélites en la agricultura de precisión, lo que ha llevado a un aumento en la resolución de los productos, tanto a nivel espacial, espectral y temporal. En la actualidad existen varios servicios de imágenes de satélites, que proporcionan distintos productos para diferentes demandas, y con tendencia a disminuir los costos de adquisición.

Un ejemplo de ello son las constelaciones de nanosatélites, que ahora puede producir a nivel global imágenes diarias, con una resolución espacial tan baja como 3 m como el caso de Planet Scope. Estas imágenes prometen derivar distintas aplicaciones para el monitoreo nutricional de los cultivos, manejo de agua, el estado fitosanitario y la predicción de las cosechas.

A lo largo de la historia de la teledetección, han surgido diversos algoritmos de clasificación, las cuales han evolucionado y se han ido adaptando a las necesidades y las mejoras de los sensores aerotransportados por satélite. Actualmente existe una variedad de clasificadores ya incluidos dentro de los paquetes de *software* cuya aplicabilidad a distintas áreas se ha estudiado, sin embargo en áreas nuevas como lo es la agricultura en pequeñas parcelas se hace necesario medir su desenvolvimiento antes de escoger aleatoriamente cualquiera de ellos para trabajos de mayor cobertura.

1.3. Alcances

Para la definición de los alcances se toma en cuenta la perspectiva investigativa, técnica y de resultados.

1.3.1. Perspectiva investigativa

El presente estudio es de carácter descriptivo-explicativo, en el que fueron calculados distintos indicadores de calidad a partir de los resultados obtenidos de la clasificación supervisada permitiendo:

- Definir qué clasificador y qué imagen es la más apropiada para el contexto de estudio.

- Explicar los resultados a partir del principio de funcionamiento de los algoritmos empleados y las condiciones propias de la zona de estudio.
- Analizar los resultados considerando de las características técnicas de las imágenes utilizadas y las condiciones propias de la zona de estudio.

1.3.2. Perspectiva técnica

Gracias a la facilidad actual de acceso y obtención de imágenes de satélite de alta resolución espacial y temporal, además del desarrollo de distintos algoritmos de clasificación de imágenes se definen los siguientes alcances:

- Emplear tecnología para la recolección de puntos de muestreo mediante formularios inteligentes.
- Explorar y gestionar imágenes de satélite de alta resolución espacial a través de una plataforma interactiva.
- Empleo de *software* especializado que incluye herramientas de clasificación supervisada el cual puede ser ejecutado desde un equipo de cómputo estándar.

1.3.3. Perspectiva de resultados

Los resultados obtenidos beneficiarán a la comunidad tanto técnica como científica de la siguiente manera:

- Establecer pautas que puedan ser empleadas en la definición de insumos y metodologías apropiadas para estudios de cobertura de la tierra en áreas agrícolas del altiplano de Guatemala, principalmente en temas relacionados a algoritmos e imágenes de satélite recomendadas.

- Ser una referencia científica para futuras investigaciones relacionadas con la detección de cultivos agrícolas en localidades de contexto similar al de la zona de estudio.
- Evidenciar la utilidad del uso de imágenes de satélite como apoyo en la gestión de proyectos e iniciativas de distintas organizaciones y entidades del sector.

2. MARCO TEÓRICO

En ese capítulo se abarcan aspectos de fundamentos de teledetección, principios de clasificación de imágenes de satélite, los algoritmos de clasificación y la evaluación de la calidad de estos.

2.1. Fundamentos de teledetección

El principio físico de la percepción remota se basa en la ley de la conservación de la energía, cuando esta llega a la superficie de la Tierra, una parte es absorbida, otra es transmitida y otra reflejada (Chuvieco, 1995).

Durante la transmisión de energía a través de un objeto, esta es absorbida selectivamente por sus componentes químicos y una parte es reflejada.

La clorofila de las plantas es el pigmento responsable de que la energía transmitida a una hoja sufra una absorción selectiva, reflejándose el resto, principalmente en las longitudes de onda correspondientes al rojo e infrarrojo desde las paredes celulares (McCloy, 1995).

Estas características son la base para identificar los objetos mediante sensores que pueden captar la energía reflejada por los cuerpos y convertirla en valores digitales (DN).

En particular, las imágenes de satélite almacenan las señales espectrales en diferentes longitudes de onda, y después de diversos análisis se efectúa la

interpretación (García y Martínez, 2010), de allí se obtiene la información sobre las características y los tipos de objetos presentes en el área de estudio.

2.2. Principio de la clasificación de imágenes

Una imagen digital se puede definir en términos de teledetección como un arreglo de píxeles en un plano bidimensional.

El valor de cada píxel, denominado DN, corresponde a la radiación electromagnética reflejada o emitida por una porción de la tierra o *Ground Resolution Cell* (GRC), cuyo detalle espacial depende del sensor (Tolpekin y Stein, 2012).

El rango del valor numérico del píxel depende de la profundidad en bits que captura el sensor, por ejemplo, una captura en 8-bit almacena los DN en un rango de 0-255 (2^8) niveles (Kumar, 2005).

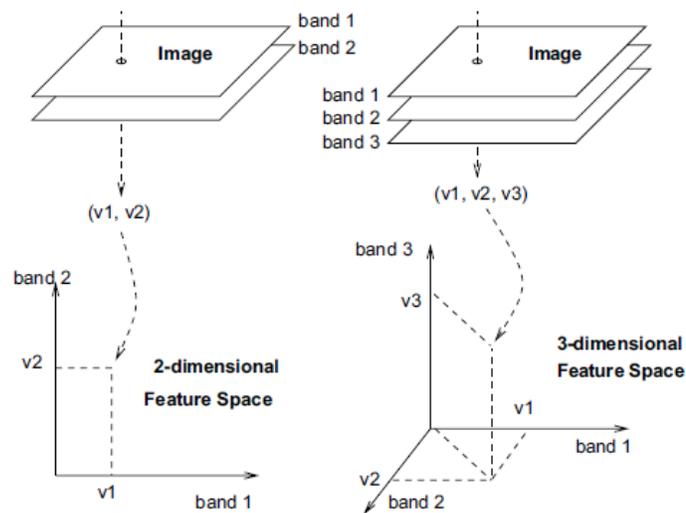
Un sensor multispectral captura la radiación de un GRC particular en diferentes canales, según su separación espectral de bandas:

Por ejemplo, un sensor que captura en tres bandas produce tres píxeles con la misma tupla (i, j) , ya que provienen del mismo GRC. La distribución espacial de los DN define el espacio de imagen (Tolpekin y Stein, 2012).

La colección de mediciones en un píxel es denominada vector de entidades. Con M bandas espectrales el vector de entidades tiene M componentes y corresponde a un punto en un M -dimensional espacio de entidades (Stein, van der Meer, y Gorte, 1999).

Este vector de entidades puede ser graficado en un plano bidimensional o tridimensional denominado espacio de entidades o *feature space*. Pese que el ploteo de los valores se dificulta para casos de cuatro o más dimensiones, concepto es el mismo (Tolpekin y Stein, 2012).

Figura 1. **Ploteo del vector de entidades en el espacio de entidades (feature space) de una imagen con dos y tres bandas para un píxel en específico**



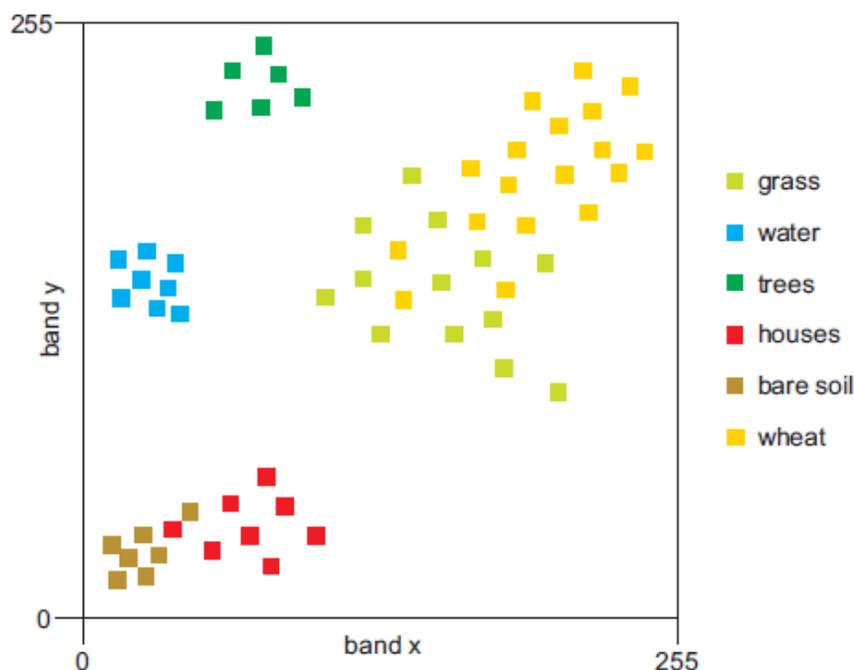
Fuente: Tolpekin y Stein. (2012). *The core of GIScience: a process-based approach*.

Es posible plotear un conjunto de vectores de entidades de una imagen en un espacio de entidades, tal como lo muestra la figura 2, en este ejemplo se ha representado una muestra (datos de entrenamiento) de cinco coberturas de suelo, mostrándose un agrupamiento (clúster) para las distintas clases (pastura, agua, bosque, entre otros.).

Una vez las clases han sido definidas en el espacio de entidades, cada vector de entidades de una imagen multibanda puede ser ploteado y comparado

con cada clúster para ser asignada a la que más se ajuste (Tolpekin y Stein, 2012).

Figura 2. **Espacio de entidades mostrando los distintos clústeres para cinco clases, notar que cada clase ocupa un área limitada en el espacio de entidades**



Fuente: Tolpekin y Stein. (2012). *The core of GIScience: a process-based approach*.

Lo anterior ilustra el concepto básico de clasificación; una parte específica del espacio de entidades corresponde a una clase específica (Tolpekin y Stein, 2012). La tarea de clasificación consiste en asignar una etiqueta de clase a cada vector de entidades, lo que significa subdividir el espacio de entidades en porciones que corresponden a las clases, esto se puede lograr mediante el reconocimiento de patrones (Stein, van der Meer, y Gorte, 1999).

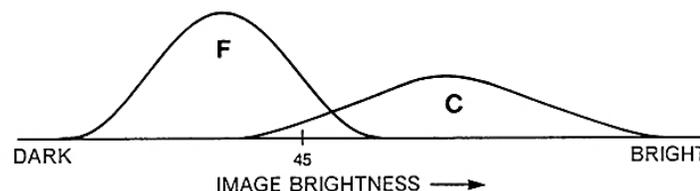
En resumen, una vez las clases han sido definidas en el espacio de entidades, cada vector de entidades de una imagen multibanda puede ser ploteado y comparado con cada clúster y ser asignado al que más se ajuste. Este proceso se realiza en distintas modalidades, dependiendo del algoritmo de clasificación que se emplea, a continuación, se describen algunos de ellos.

2.3. Clasificador de Máxima Verosimilitud (MLC)

El clasificador de máxima verosimilitud o *Maximun Likelihood Clasifier* (MLC), por sus siglas en inglés, es aplicado por el supuesto de que los píxeles en una imagen a clasificar siguen una distribución normal (Stein, van der Meer, y Gorte, 1999).

En la figura 3 se muestra un ejemplo simplificado con una banda espectral, sin embargo, el principio se extiende a valores observados en muchas bandas y más de las dos clases mostradas en la . En este ejemplo el valor 45 se sitúa en la región de traslape, donde no se puede hacer una clara asignación hacia bosque (F) o cultivo (C).

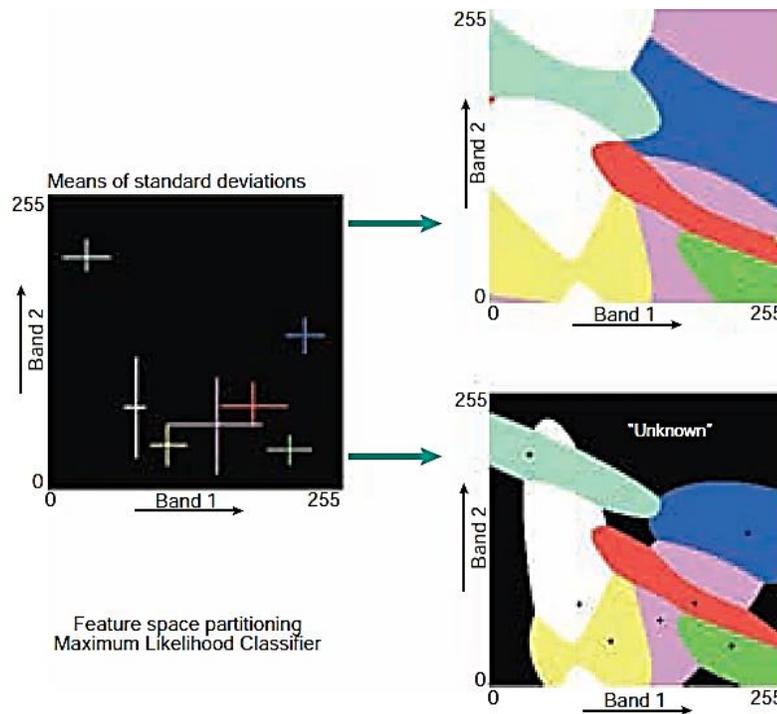
Figura 3. **Ejemplo simplificado de MLC con una banda espectral y dos clases**



Fuente: Campbell y Wynne. (2011). *Introduction to Remote Sensing*. Consultado el 13 de marzo de 2020. Recuperado de <https://books.google.es/books?isbn=1609181778>.

La relación de los píxeles dentro de la región de superposición con la distribución general de frecuencias para cada clase define la base para asignar píxeles a las clases (Campbell y Wynne, 2011). En la figura 3, la relación entre los dos histogramas indica que el píxel con el valor 45 pertenece más directamente a la clase bosque (F) que a la clase de cultivo (C).

Figura 4. **Principio del algoritmo MLC. Los contornos equiprobables son mostrados sin límite de distancia (superior derecha) y con límite o threshold distance (inferior derecha)**



Fuente: Tolpekin y Stein. (2012). *The core of GIScience: a process-based approach*.

En MLC se utilizan los datos de entrenamiento como medio de estimación de la media y la variancia de las clases (Tolpekin y Stein, 2012), los cuales posteriormente son usados para estimar distancias estadísticas, representando

estas la probabilidad de que una observación pertenezca a un clúster específico. MLC considera tanto la media como la variabilidad de los valores digitales en cada clase para la clasificación (Campbell y Wynne 2011).

Para cada clúster se puede delimitar un *contorno equiprobable* alrededor de su centro como lo muestra la figura 4. Este algoritmo también permite que el operador defina un límite de distancia mediante la asignación de un valor de máxima probabilidad (Tolpekin y Stein, 2012).

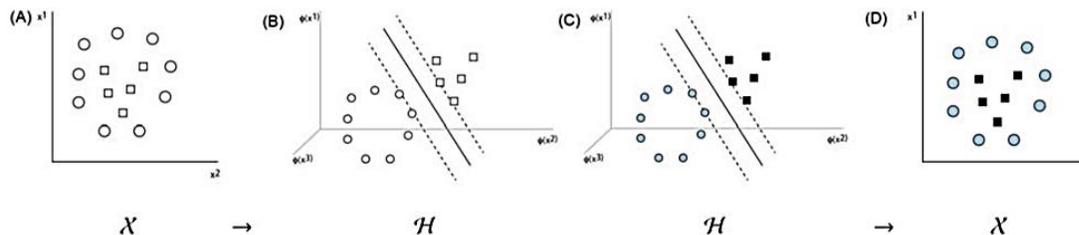
2.4. Clasificador Support Vector Machine (SVM)

SVM es un clasificador no paramétrico perteneciente a los clasificadores lineales, derivado de la teoría del aprendizaje estadístico.

El algoritmo induce hiperplanos o separadores lineales en el espacio de entidades, que maximiza el margen entre las clases (Cortes y Vapnik, 1995). Los puntos más cercanos al hiperplano se denominan Vectores de Soporte, siendo estos vectores elementos críticos del conjunto de entrenamiento, lo que significa que las muestras de entrenamiento no tienen que ser grandes, pero deben contener vectores de soporte (Liang, 2017).

Mediante una función de Kernel no lineal sobre los datos de entrada, estos hiperplanos también se pueden adaptar y actuar como clasificadores no lineales (Cortes y Vapnik, 1995). Este clasificador encuentra una función de decisión de tipo $f(x) = wx + b$ (Liang, 2017). Donde b es un término de sesgo, x son los datos por predecir, y w es un vector de pesos modelo, con valores $(d \times 1)$. Esta función encuentra el hiperplano que maximiza la distancia entre las muestras más cercanas de cada clase.

Figura 5. **Representación simplificada del clasificador SVM**



Fuente: Liang. (2017). *Comprehensive Remote Sensing*. Consultado el 13 de marzo de 2020.
Recuperado de <https://books.google.es/books?isbn=0128032219>.

En la figura 5 se puede observar una representación simplificada de SVM: en el espacio de entidades original, los datos (vectores de entidades) no pueden ser separados por un clasificador lineal (5A), pero cuando se utiliza una proyección adecuada (5B) los datos de entrenamiento pueden ser proyectados en el espacio, donde un modelo lineal puede ser ejecutado eficientemente y conducir a una simple solución lineal en el plano de mayor nivel (5C), el cual a la vez es una compleja función de decisión no lineal en el plano original (5D).

2.5. Clasificador de Árboles Aleatorios (RT)

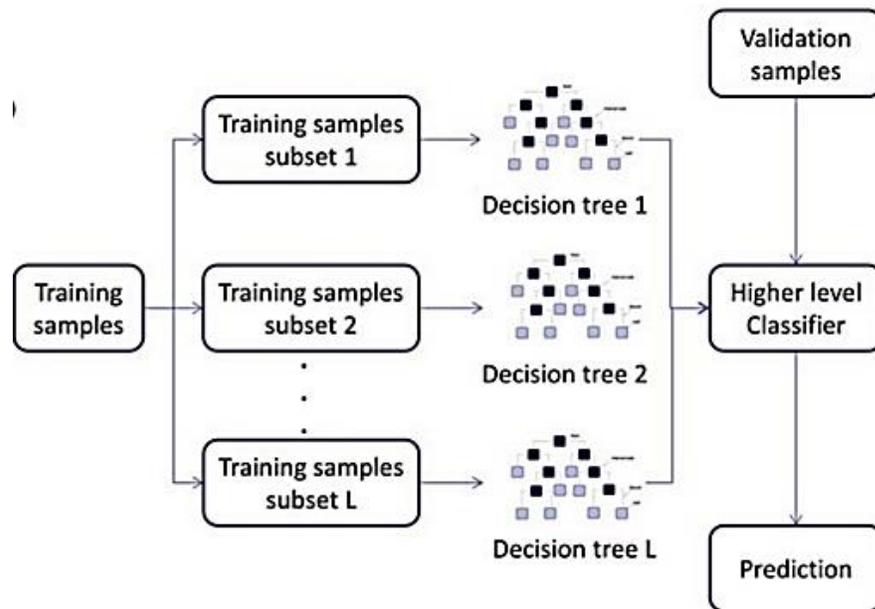
El clasificador de árboles aleatorios, Random Trees (RT) o Random Forest (RF) se trata de un algoritmo de aprendizaje automático, no paramétrico, propuesto por Breiman (2001). El algoritmo (RT) crea un conjunto de árboles individuales, cada uno de ellos generado con una parte de muestras en el proceso del entrenamiento (Liang, 2017).

El algoritmo tiene la capacidad de emplear las variables más apropiadas durante la formación de los nodos (Breiman, 2001).

Por cada píxel a clasificar, el algoritmo crea un número de decisiones ordenadas de acuerdo con su importancia. Cada uno de los árboles que conforma esta colección recibe un voto, determinante en la decisión final de la clasificación (Liang, 2017).

Como puede observarse en la figura 6, en este método de clasificación *crecen* una serie de árboles, analógicamente un bosque, cuya variación entre ellos se introduce al momento de proyectar los datos de formación en un espacio elegido al azar antes de colocar cada árbol.

Figura 6. **Representación del clasificador Random Forest**



Fuente: Liang (2017). *Comprehensive Remote Sensing*. Consultado el 13 de marzo de 2020.
Recuperado de <https://books.google.es/books?isbn=0128032219>.

2.6. La calidad de la clasificación

Al finalizar el proceso de clasificación, se obtiene un *raster* cuyas celdas almacenan un valor que representa una clase en específico, el siguiente paso es evaluar la calidad de la clasificación.

En esta evaluación se compara una muestra de los resultados con las clases reales, elaborando para ello una matriz de confusión, a partir de la cual se calculan distintos índices de exactitud (Tolpekin y Stein, 2012).

Según las técnicas aplicadas, se puede clasificarlas en descriptivas y analíticas; en la primera se describe la situación a través de índices que resumen la información mediante la matriz de confusión y distintos índices derivados de ella, mientras que en las técnicas analíticas se demuestran relaciones entre las características observadas. A continuación, se describen algunas técnicas descriptivas.

2.7. Matriz de confusión

La matriz de confusión consiste en una tabla de doble entrada (tabla 4), en la que se confrontan los valores o resultados reales -en el sentido horizontal- con los resultados de la clasificación -en el sentido vertical- (Chuvieco, 1995). Inicialmente la tabla contiene un conteo de valores, los cuales posteriormente son convertidos dentro de la misma en proporciones para su análisis (McCloy, 1995).

La tabla IV representa un formato para la elaboración de una matriz de confusión: en la diagonal de la matriz (celdas resaltadas) se coloca la cantidad de puntos coincidentes entre la clasificación y la realidad para cada clase,

mientras que los que se encuentren fuera de ella son aquellos puntos que presentan confusión con otras categorías.

Tabla IV. **Modelo de matriz de confusión**

Clase mapa → Clase Real ↓	Clase 1	Clase 2	Clase 3	Clase 4	Puntos en la fila (total)	Exactitud del usuario (porcentaje)
Clase 1						
Clase 2						
Clase 3						
Clase 4						
Puntos en la columna (total)						
Exactitud del productor (porcentaje)						
Exactitud global (porcentaje)						

Fuente: Environmental Systems Research Institute. (s.f.). *Introduction to Image Classification, Web Course*. Consultado el 13 de marzo de 2020. Recuperado de <https://bit.ly/3g5qbE9>.

2.8. Exactitud global de la clasificación

A partir de la matriz de confusión, se calcula el valor de la exactitud global, dividiendo el número de puntos correctamente clasificados, dentro del total de puntos de referencia, el resultado tomará valores entre cero (0) a uno (1), considerándose una mejor clasificación cuanto más cercano a 1 esté el valor.

Ya que este valor es una estimación basada en la muestra, es importante calcular los intervalos de confianza en los que se encontraría la exactitud real alcanzada en la clasificación (Chuvieco, 1995):

$$F = F_m \mp z E$$

$$E = \sqrt{\frac{pq}{n}}$$

Donde: F_m es valor de la exactitud global calculada en la matriz de confusión, z indica la abscisa del área bajo la curva normal para un nivel de confianza $(1-\alpha)$; E representa el error estándar de muestreo, el cual está en función del porcentaje de aciertos (p), fallos (q) y el tamaño de la muestra (n):

2.9. Fiabilidad de las clases individuales

Existen dos medidas individuales de exactitud en la clasificación: la exactitud del usuario y la exactitud del productor. Los cálculos se realizan de forma individual con la misma lógica que el cálculo de la exactitud global.

La fiabilidad de las clases individuales también se calcula a partir de la matriz de confusión y es cuantificada mediante dos medidas, la exactitud de usuario y la exactitud del productor, siguiendo el mismo principio de cálculo de la exactitud global, pero sobre cada una de las clases de forma individual.

De la exactitud de usuario y la exactitud de productor se puede estimar el error de comisión y omisión, los cuales indican las cubiertas del mapa que no se ajustan a la realidad y los tipos de cubierta real que no se incluyen en el mapa, respectivamente, ambas expresadas en porcentaje. (Chuvieco, 1995).

2.10. Índice Kappa

De los índices mencionados anteriormente se puede evaluar lo que ocurre en la diagonal y en los residuales de filas y columnas, sin embargo, la matriz de confusión permite el cálculo de otros índices.

En este sentido, es importante también analizar las relaciones múltiples que existe entre las distintas categorías, siendo el índice Kappa es el que más se ha empleado para este propósito (Chuvienco, 1995). Para conocer la precisión de una clasificación se descartando los efectos del azar se utiliza el índice Kappa (Rodríguez, Sánchez, Domínguez y Santa Marta, 2015). Es usado comúnmente para comparar métodos de clasificación (Borrás *et al.*, 2017). La ecuación para el cálculo del índice Kappa es la siguiente (Tolpekin y Stein, 2012):

$$\kappa = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r x_{i+} x_{+i}}{N^2 - \sum_{i=1}^r x_{i+} x_{+i}}$$

Donde:

- r = dimensión de la matriz (número de clases);
- x_{ij} = número de observaciones en la línea i , columna j ;
- x_{i+} y x_{+i} = total de la línea y columna i, j
- N = observaciones totales.

Dependiendo del valor del índice Kappa, el nivel de concordancia puede ser alto (>0.8), medio ($0.4-0.8$ %) o bajo (<0.4) (Jensen, 2005; Lillesand, Kiefer y Chipman, 2004).

3. PRESENTACIÓN DE RESULTADOS

El área de estudio se localiza dentro del municipio de Patzicía, Chimaltenango, el cual se encuentra a una altitud de 2,400 msnm, cuya topografía es plana en su mayoría, en el que se cosechan hortalizas de diversas especies con rotación de cultivos. En algunas unidades productivas se cuenta con sistema de riego por goteo por lo que pueden obtenerse de dos a tres cosechas al año.

Usualmente se encontraron parcelas entre 30-90 m de lado. Los datos se tomaron dentro de un área de 20 km² los días 27 y 29 de mayo de 2020, coincidiendo con una imagen PlanetScope y una imagen Wordview-2 libres de nubes para las parcelas muestreadas, ambas con la fecha 25 de mayo de 2020.

Durante la fase de campo se identificaron 16 clases, con un total de 192 parcelas, en su mayoría de hortalizas, además otros tipos de cobertura como infraestructura, parcelas sin cultivo y bosque, las cuales pueden verse a detalle en la tabla V. La figura 8 muestra la distribución de los puntos de muestreo visualizados sobre la imagen WV2 en una composición de infrarrojo.

Posterior a la fase de campo, por cada punto de muestreo (parcela) se seleccionó una región de interés de 12-60 píxeles centrales para la imagen PS y 53-270 píxeles para WV2, obteniendo, finalmente, 3,641 píxeles para PS y 16,423 píxeles para WV2 los cuales formaron parte de la base de datos para el entrenamiento y validación. En la tabla V puede verse a detalle el número de píxeles que fueron seleccionados para cada una de las 16 clases.

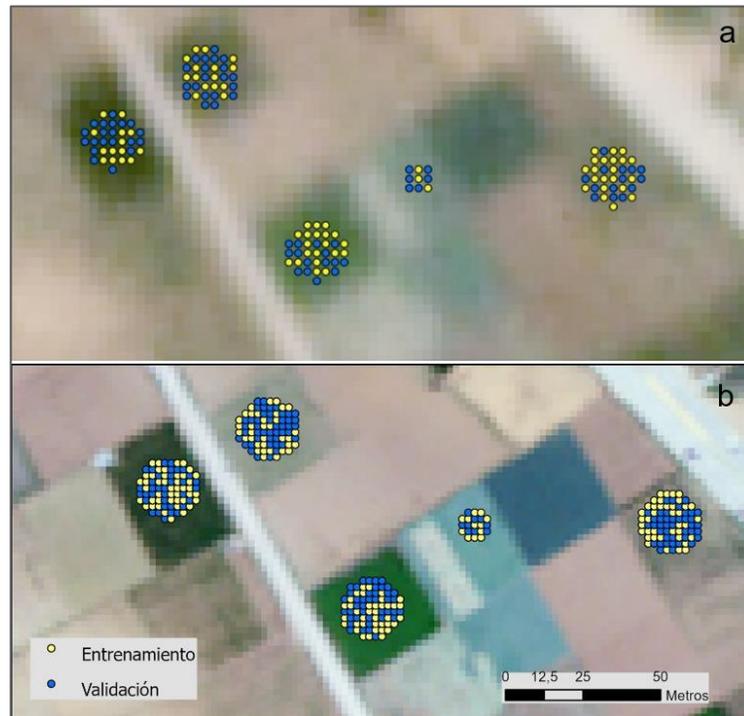
Tabla V. **Clases identificadas en el muestreo de campo con su respectivo número de parcelas y píxeles seleccionados para el entrenamiento y validación**

No. Clase	Clase	Parcelas	Píxeles en PS	Píxeles en WV2
1	Alfalfa	3	179	801
2	Apio	5	85	396
3	Arveja	6	104	473
4	Bosque	14	844	3784
5	Cebolla	9	130	589
6	Cebolla con <i>mulch</i>	5	73	330
7	Cobertura	22	415	1856
8	Coles	23	319	1446
9	Fresa	7	110	488
10	Frijol	7	124	547
11	Cucúrbitas	5	62	279
12	Infraestructura	17	199	898
13	Lechuga	11	149	687
14	Melocotón	4	56	250
15	Suelo	37	522	2373
16	Zanahoria	17	270	1226
	Total	192	3641	16423

Fuente: elaboración propia.

En la figura 7 puede observarse un ejemplo de cómo quedaron asignados los píxeles de entrenamiento y validación para cinco puntos de muestreo (parcelas). Para cada clase, los datos para el entrenamiento y validación se asignaron aleatoriamente en partes iguales, asegurando la distribución espacial de los píxeles que representan a las distintas clases por toda la zona de estudio.

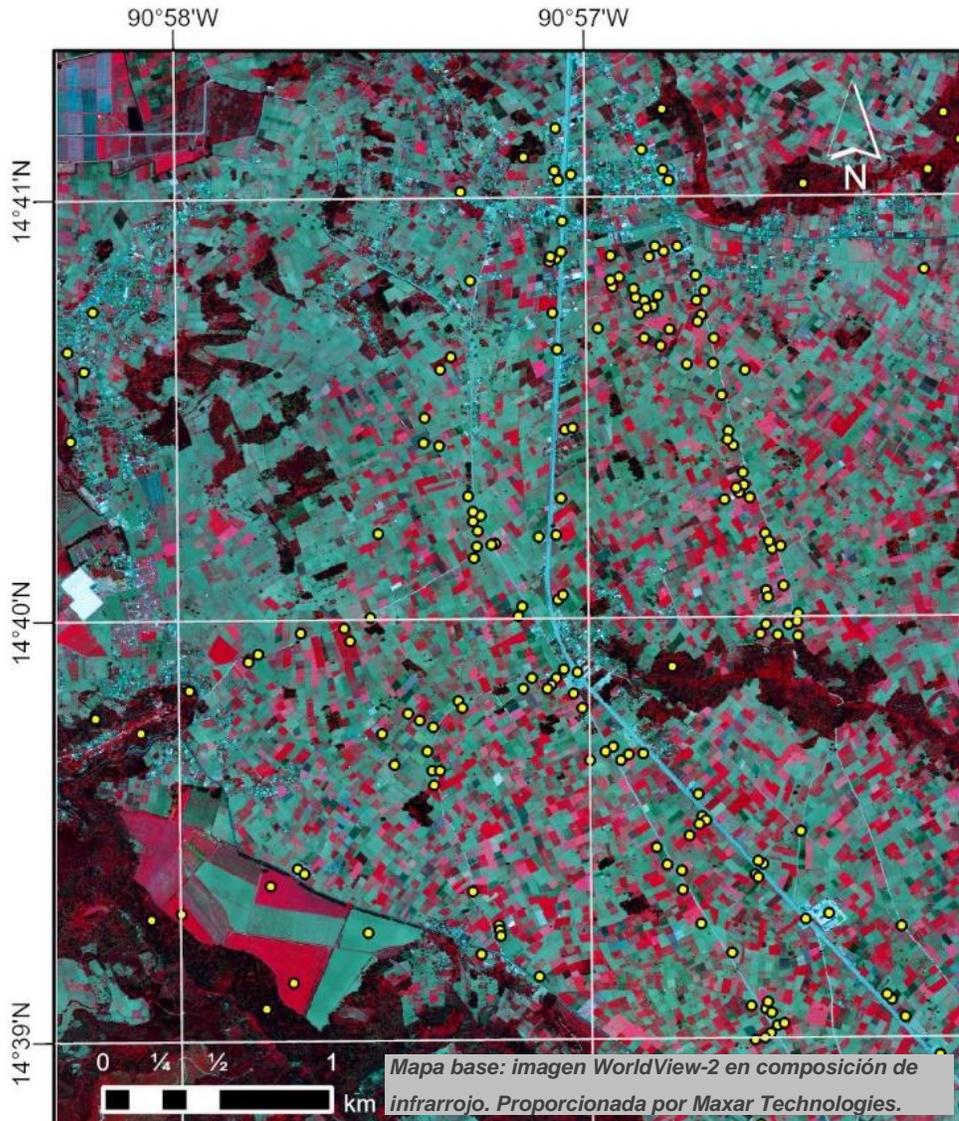
Figura 7. **Asignación de píxeles de entrenamiento y validación para la PS (a) y WV2 (b)**



Fuente: elaboración propia, realizada con software SIG.

Para el estudio se dispuso de dos imágenes multiespectrales con extensión de 20 km², la primera capturada por satélite PlanetScope, con 3 m de resolución espacial y la segunda proveniente del satélite WorldView-2, con 2 m de resolución espacial. Las dos imágenes cuentan con las tres bandas del espectro visible (VIS) y la banda que corresponde al infrarrojo cercano (NIR). Particularmente WV2 cuenta también con las bandas Coastal, Yellow, Red Edge (RE) e infrarrojo cercano 2 (NIR2).

Figura 8. **Mapa de puntos de muestreo distribuidos dentro de los 20 km² de la zona de estudio**



Fuente: elaboración propia, realizada con software SIG.

Ambas imágenes se adquirieron con corrección radiométrica y atmosférica mediante modelos propios de los distribuidores, por lo que corresponden a imágenes de reflectancia a nivel del suelo (BOA) cuyos valores vienen

almacenados en 16 bits de profundidad. Estas imágenes fueron sometidas al proceso de clasificación dentro la herramienta Image Classification del *software* ArcGIS Pro.

Tabla VI. **Parámetros utilizados dentro de la clasificación supervisada para los distintos clasificadores**

Parámetro	Algoritmo	Explicación
in_raster	MLC SVM RT	El <i>raster</i> de entrada a clasificar, ya sea: -Imagen PS con sus bandas VIS/NIR -Imagen WV2 con sus bandas VIS/NIR -Imagen WV2 con sus bandas VIS/RE/NIR
in_training_features	MLC SVM RT	Archivo de entrada de clase de entidad que contiene las muestras de entrenamiento con los nombres de campo obligatorios <i>classname</i> de tipo texto y <i>classvalue</i> de tipo entero largo, los cuales identifican cada una de las 16 clases definidas en campo.
out_classifier_definition	MLC SVM RT	El archivo JSON de salida que contiene información de atributos, estadísticas, vectores de hiperplano y otra información requerida por el clasificador. Se crea un archivo <i>.ecd</i> .
max_samples_per_class	SVM RT	El número máximo de muestras que se van a utilizar para definir cada clase. Se utilizó el valor predeterminado para <i>rasteres</i> no segmentados. 500 para SVM y 1000 para RT.
max_num_trees	RT	El número máximo de árboles en el bosque. Se estableció el valor predeterminado 50.
max_tree_depth	RT	a profundidad máxima de cada árbol del bosque. Se estableció el valor predeterminado 30.

Fuente: elaboración propia.

En la tabla VI pueden observarse los parámetros empleados para cada algoritmo de clasificación, así como la explicación de cada uno de ellos.

Como puede observarse en la tabla VI, para los parámetros específicos de cada clasificador se utilizaron las condiciones por defecto que sugiere la herramienta. Como resultado se obtuvo un archivo *raster* de clasificación, con la misma resolución de píxel que el *raster* de entrada (imagen) cuyos valores corresponden a una de las 16 clases definidas en el proceso de entrenamiento. En las figuras 9, 10 y 11 pueden observarse los mapas cultivos obtenidos de la clasificación de las imágenes PS y WV2 mediante el algoritmo RT.

Figura 9. **Mapa de cultivos obtenido con las bandas VIS/NIR de la imagen PS mediante el clasificador RT**



Fuente: elaboración propia, realizada con software SIG.

Posterior a la clasificación, se realizó el proceso de validación con los datos de muestreo reservados para este proceso, obteniéndose una matriz de

confusión para cada clasificación realizada, seguidamente se calculó el índice Kappa con base en los resultados de cada una de estas matrices.

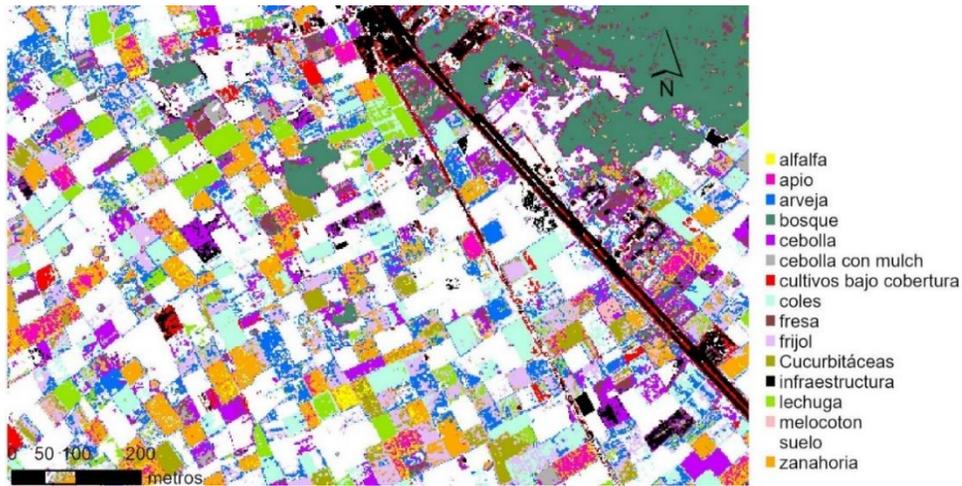
En el apéndice 2 se muestra el cálculo del índice Kappa a partir de la matriz de confusión de la clasificación con RT para la imagen WV2 con sus bandas VIS/NIR. Este mismo procedimiento se aplicó en todas las clasificaciones, resumiéndose los resultados en la tabla VII.

Figura 10. **Mapa de cultivos obtenido con las bandas VIS/NIR de la imagen WV2 mediante el clasificador RT**



Fuente: elaboración propia, realizada con software SIG.

Figura 11. **Mapa de cultivos obtenido con las bandas VIS/IR/NIR de la imagen WV2 mediante el clasificador RT**



Fuente: elaboración propia, realizada con software SIG.

Tabla VII. **Intervalos de confianza de los índices Kappa para el 95 % de confianza para la clasificación de las imágenes PS y WV2 mediante tres clasificadores**

Imagen	MLC	SVM	RT
WV2 con sus bandas VIS/RE/NIR	0.85-0.86	0.93-0.94	0.96-0.97
WV2 con sus bandas VIS/NIR	0.83-0.84	0.92-0.93	0.96-0.97
PS con sus VIS/NIR	0.73-0.76	0.88-0.91	0.96-0.97

Fuente: elaboración propia.

En la tabla VIII y IX se integran las matrices de confusión para la clasificación con RT, con el cual se obtuvo un mayor nivel de concordancia para el índice Kappa, según la tabla VII.

Tabla VIII. Integración de las matrices de confusión obtenidas de la clasificación con RT para las imágenes PS con las bandas VIS/NIR, WV2 con VIS/NIR y WV2 con VIS/RE/NIR para las clases 1 al 8

Clase	C01	C02	C03	C04	C05	C06	C07	C08
C01	99.4	0	0	0	0	0	0	0
	98.3	0	0	0.1	0	0	0	0
	99	0	0	0.1	0	0	0	0
C02	0	98.8	0	0	0	0	0	0.3
	0	94.9	0	0	0	0	0	0
	0	98.5	0	0	0	0	0	0
C03	0	0	93.3	0.1	0.8	0	0	0.3
	0	0	98.7	0.1	0	0	0	0.1
	0	0	100	0	0	0	0	0.4
C04	0	0	0	97.5	0	0	0	0
	0	0	0	96.1	0	0	0	0
	0	0	0	96.5	0	0	0	0.1
C05	0	0	1.9	0	97.7	0	0	0
	0	0	0	0.2	99.3	0	0	0
	0	0	0	0.2	99.7	0	0	0
C06	0	0	0	0	0	100	0.7	0
	0	0	0	0	0	99.4	1.7	0
	0	0	0	0	0	99.4	0.9	0
C07	0	0	0	0	0	0	98.8	0
	0	0	0	0	0	0.6	96.9	0
	0	0	0	0	0	0.6	97.4	0
C08	0	0	0	0.2	0.8	0	0	98.7
	0	0	0	0	0	0	0	95.7
	0	0	0	0	0	0	0	95.3
C09	0	0	1	1.7	0	0	0	0
	0	0	0	2.2	0.7	0	0	0
	0	0	0	2.2	0.3	0	0	0
C10	0	1.2	1	0	0	0	0	0
	0	0	0.8	0	0	0	0	0.3
	0	0	0	0	0	0	0	0.3

Continuación tabla VIII.

Clase	C01	C02	C03	C04	C05	C06	C07	C08
C11	0	0	0	0	0	0	0	0
	0	0	0	0	0	0	0	0
	0	0	0	0	0	0	0	0
C12	0	0	0	0	0	0	0.5	0
	0	0	0	0	0	0	0.6	0
	0	0	0	0	0	0	1.3	0
C13	0	0	1	0	0	0	0	0.3
	0	0	0	0	0	0	0	0
	0	0	0	0	0	0	0	0.3
C14	0	0	0	0.5	0	0	0	0
	0	0	0	0.5	0	0	0	0
	0	0	0	0.5	0	0	0	0
C15	0	0	1.9	0	0.8	0	0	0
	0	0	0.4	0	0	0	0.7	0.1
	0	0	0	0	0	0	0.4	0.1
C16	0.6	0	0	0	0	0	0	0.3
	1.8	5.1	0	0.8	0	0	0	3.7
	1	1.5	0	0.6	0	0	0	3.5

Fuente: elaboración propia.

Tabla IX. Integración de las matrices de confusión obtenidas de la clasificación con RT para las imágenes PS con las bandas VIS/NIR, WV2 con VIS/NIR y WV2 con VIS/RE/NIR para las clases 9 al 16

Clase	C09	C10	C11	C12	C13	C14	C15	C16
C01	0	0	1.6	0	0	0	0	3.3
	0	0	0	0	0	0	0	2.4
	0	0	0	0	0	0	0	2.4
C02	0	0	0	0	0	0	0	1.9
	0	0	0	0	0	0	0	1.3
	0	0	0	0	0	0	0	1
C03	1.8	0.8	0	0	0.7	0	0.8	0.4
	0	0.7	0	0	0	0	1.5	0
	0	1.1	0	0	0	0	1.1	0
C04	0.9	0	0	0	0	1.8	0	0
	0.8	0	0	0	0	1.6	0	0.3
	0.8	0	0	0	0	0.8	0	0.5
C05	3.6	0	0	0	0.7	0	0	0
	2	0	0	0	0	0.8	1.3	0
	2.5	0	0	0	0	1.6	1.7	0
C06	0	0	0	0	0	0	0	0
	0	0	0	0	0	0	0	0
	0	0	0	0	0	0	0	0
C07	0	0	0	0	0	0	0	0
	0	0	0	0.2	0	0	0.5	0
	0	0	0	0.2	0	0	0.3	0
C08	0	0.8	0	0	1.3	0	0.2	0.7
	0	0.4	0	0	0	0	0.7	0
	0	0.4	0	0	0	0	0.6	0
C09	92.8	0	0	0	0	1.8	0	0
	97.1	0	0	0	0	1.6	0	0
	96.3	0	0	0	0	1.6	0	0
C10	0	95.1	1.6	0	0.7	0	0.6	0
	0	98.5	2.9	0	0	0	1.2	0.3
	0	98.5	2.2	0	0	0	1.3	0

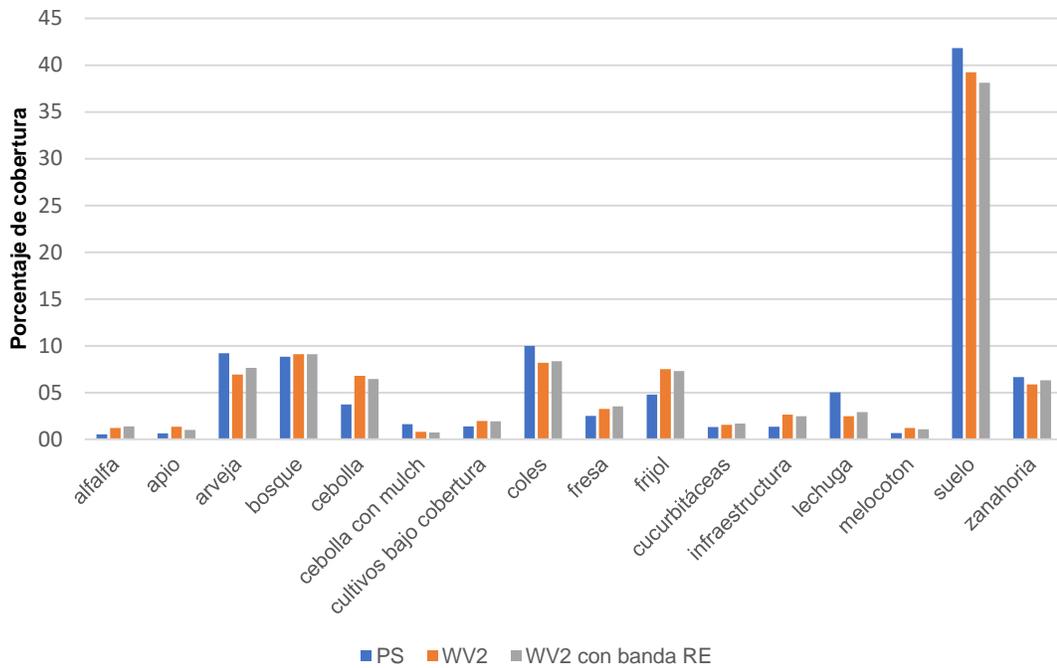
Continuación tabla IX.

Clase	C09	C10	C11	C12	C13	C14	C15	C16
C11	0	0	90.5	0	0	0	0	0.7
	0	0	96.4	0	0	0	0	0.5
	0	0	97.8	0	0	0	0	0
C12	0	0	0	99	0	0	0.8	0
	0	0	0	99.8	0	0	0.7	0
	0	0	0	99.8	0	0	0.9	0
C13	0	0.8	0	0	96.6	0	0	0
	0	0	0	0	100	0	0	0
	0	0	0	0	100	0	0	0
C14	0.9	0	0	0	0	96.4	0	0
	0	0	0	0	0	96	0	0
	0.4	0	0	0	0	96	0	0
C15	0	1.6	0	1	0	0	97.7	0
	0	0	0	0	0	0	94.2	0
	0	0	0	0	0	0	94.1	0
C16	0	0.8	6.3	0	0	0	0	92.9
	0	0.4	0.7	0	0	0	0	95.1
	0	0	0	0	0	0	0	96.1

Fuente: elaboración propia.

La diagonal resaltada en negrita de la tabla VIII y la tabla IX indica los porcentajes en los que los píxeles correspondientes a cada una de las clases fueron identificados correctamente por el algoritmo RT, quedando fuera de esta línea aquellos que no corresponde a la realidad. En cada casilla de la tabla VIII y IX, el primer valor corresponde a los porcentajes de acierto de PS, el segundo a los porcentajes de acierto de la clasificación obtenidos con la imagen WV2, ambas con sus bandas VIS/NIR y el tercer valor a la imagen WV2 con sus bandas VIS/RE/NIR.

Figura 12. **Porcentaje de cobertura de cada clase sobre una superficie de 900 ha, obtenida con las imágenes PS y WV2 clasificadas mediante el algoritmo RT**



Fuente: elaboración propia.

En la tabla X se cuantifican las clases identificadas con el algoritmo RT para las imágenes PS y WV2, el cálculo se efectuó para una región de interés de 900 ha del área de estudio, donde se visualiza una mayor actividad agrícola y permite la exclusión de una porción de nube sobre la imagen PS. En la figura 12 se presentan estos resultados de forma gráfica.

Tabla X. **Cuantificación de las clases identificadas con el algoritmo RT para una ROI de 900 ha**

Clase	PS		WV2		WV2	
	bandas VIS/NIR		bandas VIS/NIR		bandas VIS/IR/NIR	
	ha	porcentaje	ha	porcentaje	ha	porcentaje
C01	4.7	0.5	10.9	1.2	12.4	1.4
C02	5.6	0.6	12.1	1.3	9.1	1.0
C03	82.8	9.2	62.3	6.9	68.7	7.6
C04	79.4	8.8	81.9	9.1	82.0	9.1
C05	33.6	3.7	61.0	6.8	58.1	6.5
C06	14.5	1.6	7.1	0.8	6.7	0.7
C07	12.4	1.4	17.8	2.0	17.4	1.9
C08	89.7	10.0	73.6	8.2	75.1	8.3
C09	22.6	2.5	29.2	3.2	31.6	3.5
C10	43.0	4.8	67.5	7.5	65.8	7.3
C11	11.9	1.3	13.9	1.5	15.1	1.7
C12	12.2	1.4	23.9	2.7	22.3	2.5
C13	45.2	5.0	22.3	2.5	26.2	2.9
C14	6.0	0.7	10.8	1.2	9.6	1.1
C15	376.3	41.8	353.0	39.2	343.1	38.1
C16	60.0	6.7	52.7	5.9	56.7	6.3
Total	900.0	100.0	900.0	100.0	900.0	100.0

Nombres de las clases: C01-Alfalfa, C02-Apio, C03-Arveja, C04-Bosque, C05-Cebolla, C06-Cebolla con *mulch* plateado, C07-Cultivos con cobertura, C08-Coles, C09-Fresa, C10-Frijol, C11-Cucúrbitas, C12-Infraestructura, C13-Lechuga, C14-Melocotón, C15-Suelo, C16-Zanahoria.

Fuente: elaboración propia.

4. DISCUSIÓN DE RESULTADOS

Teniendo en cuenta los resultados de la tabla VII y con base en los rangos de interpretación del índice Kappa indicados en Anexo 1 se puede definir que el clasificador MLC proporcionó un nivel de concordancia moderado en la clasificación cuando se utilizó la imagen PlanetScope, por otra parte, con este mismo algoritmo el nivel de concordancia en la clasificación es alto cuando se emplean las imágenes WV2. El algoritmo SVM proporciona niveles de concordancia casi perfectos para las imágenes WV2, sin embargo, para las imágenes PS, en algunas ocasiones sólo se llega a niveles altos.

Para el caso de RT, en todos los casos arrojó niveles de concordancia casi perfectos ya que sus valores de índice Kappa son mayores a 0.90, además, siempre son superiores a los resultados obtenidos con el algoritmo SVM. A partir de esta interpretación se define al clasificador MLC como el peor clasificador y el RT como el mejor, a pesar de que aún con MLC se observaron niveles de concordancia altos. Al respecto se puede hacer mención de que SVM y RT son algoritmos de aprendizaje automático de más reciente introducción dentro del campo de la teledetección, los cuales se conciben como una evolución de los clasificadores tradicionales, entre ellos MLC.

Cabe destacar que, a pesar de que se esperaban mejoras en los resultados al utilizar la banda Red Edge (RE) como complemento a las bandas VIS/NIR, dada su sensibilidad a la vegetación, esta hipótesis se rechaza. A partir de los resultados de índices Kappa de tabla VII se pueden comparar las clasificaciones en las dos modalidades de la imagen WV2, con y sin la banda Red Edge (RE); al calcular la diferencia entre los resultados de sus índices Kappa se comprueba

que la incorporación de la banda RE dentro de la clasificación sólo mejoró en 0.02 el nivel de concordancia de la clasificación para el algoritmo MLC y 0.01 para SVM, mientras que para RT los resultados fueron similares con y sin la banda RE.

De esta forma se define para el presente estudio la potencialidad de las imágenes que sólo cuentan con las bandas VIS y NIR en la discriminación y cuantificación de cultivos agrícolas. Esta afirmación puede confirmarse en la figura 12 y en la tabla X, donde se observa similitud en la cuantificación de cada clase utilizando la imagen WV2 tanto con la banda RE como sin ella.

Los mapas de cultivo presentados en las figuras 9, 10 y 11 permiten realizar una exploración visual de los resultados para el mejor clasificador, RT, para las imágenes PS y WV2. De forma general se puede apreciar un desempeño satisfactorio del algoritmo RT en la discriminación de las distintas ocupaciones del suelo, tales como cultivos, suelo, bosque e infraestructura.

Un aspecto que resalta al comparar visualmente los mapas de cultivo de la figura 9 con los de la figura 10 y 11 es la cantidad de parcelas de cebolla y frijol identificadas con WV2 las cuales no están presentes en los mapas de cultivo con PS, reflejándose en la 12, donde las proporciones de estos cultivos obtenidos a partir de PS son menores a las proporciones obtenidas con WV2.

Si se examina la matriz de confusión de la tabla VIII y IX, y se comparan los porcentajes de acierto obtenidos en la clasificación para las dos fuentes de imágenes (PS y WV2 con sus bandas VIS/NIR), para el caso de frijol, con PS se tuvo un acierto del 95.1 % en comparación al 98.5 % para los resultados con WV2 y para el caso del cultivo de cebolla se logró un acierto del 97.7 % y 99.3 % para PS y WV2 respectivamente.

En la figura 12 también puede observarse una mayor estimación del cultivo de lechuga y un ligero incremento de coles y arveja para los resultados de la clasificación con la imagen PS. Si se examina la matriz de confusión de la tabla VIII y IX, y se observan los porcentajes en que el algoritmo acertó con la clase real para las dos fuentes de imágenes (WV2 y PS, ambas con sus bandas VIS/NIR), se observa que para el caso de lechuga, arveja y coles estos valores son 96.6 %, 93.3 % y 98.7 % respectivamente, cuando se utilizó la imagen PS, por otra parte, con WV2 los píxeles correctamente clasificados corresponden al 100 %, 98.7 % y 95.7 % para estos cultivos.

Para los cultivos antes mencionados, con excepción de las coles, los porcentajes en los que la clasificación acertó siempre son mejores cuando se utilizan las imágenes WorldView-2.

Un aspecto final que puede mencionarse de la exploración visual de los mapas de cultivos de las figuras 9, 10 y 11 es el detalle en la delimitación de las parcelas, si bien en ambas se pueden distinguir con claridad, en los resultados con WV2 se observa una mayor finura, pese a que en las imágenes de satélite utilizadas para la clasificación cada parcela es cubierta por suficiente número de píxeles según se observa en la figura 7.

CONCLUSIONES

1. Al realizar la evaluación de la calidad de la clasificación, mediante el uso de las muestras reservadas para este propósito y con base en los rangos de interpretación del índice Kappa, se obtuvieron aciertos altos para el algoritmo MLC y aciertos casi perfectos para los algoritmos SVM y RT, entre estos dos últimos, RT siempre superó a SVM para todas las imágenes empleadas por lo que se define el algoritmo RT como el mejor clasificador para la identificación y discriminación de cultivos agrícolas con las características de la zona de estudio, seguido por algoritmo SVM, quedando MLC como el peor clasificador.
2. Por la naturaleza del presente estudio, se planteó la utilización de la banda RE como complemento a las bandas VIS/NIR dentro de una clasificación supervisada basada en píxeles, dada su sensibilidad a la vegetación, esperándose resultados prometedores, sin embargo, se determinó que la incorporación de esta banda dentro de los distintos algoritmos de clasificación no influyó en los resultados, según lo indican los índices Kappa, mejorando a lo sumo en 0.02 el nivel de concordancia para uno de los clasificadores utilizados (MLC), por lo que se concluye que para la identificación de cultivos en el contexto del presente estudio la banda RE no es indispensable.
3. Pese a que se obtuvieron niveles de concordancia casi perfectos en la clasificación mediante el algoritmo RT empleando imágenes PS y WV2 de 3 m y 2 m de resolución espacial respectivamente, el análisis a detalle de la matriz de confusión y la exploración visual de los mapas de cultivo

evidencian que la elección de una imagen de mejor resolución de píxel dentro de las imágenes de alta resolución espacial, se traduce en un mejor detalle en la cuantificación y delimitación de los cultivos para la clasificación en el contexto del estudio.

RECOMENDACIONES

1. Elegir el algoritmo RT para la clasificación supervisada basada en píxeles, Si se utiliza *software* que incluye los clasificadores MLC, SVM y RT, para áreas agrícolas similares a las del altiplano de Guatemala.
2. Utilizar sólo las bandas VIS/NIR de la imagen por clasificar, pues se determinó que incorporar la banda Red Edge dentro de la clasificación supervisada basada en píxeles, utilizando imágenes de satélite multiespectrales, no se traduce en una mejora en la clasificación.
3. Emplear la elección de imágenes cuya resolución espacial sea mayor o igual a 2 m para un mejor detalle en la cuantificación, delimitación y visualización de las parcelas de cultivos, mediante teledetección con imágenes de satélite de alta resolución espacial, utilizando clasificación supervisada basada en píxeles.
4. Realizar estudios con otros métodos de clasificación, como la clasificación basada en objetos u algoritmos de *Deep Learning*, para cuantificar su nivel de mejora respecto de los algoritmos empleados en esta investigación, en el mismo contexto del área de estudio.
5. Prever que el empleo de los resultados de esta investigación en los sistemas nacionales de monitoreo de cultivos demanda un rubro importante dentro del análisis económico el costo de adquisición de las imágenes, pues estas son de carácter comercial, lo cual implica disponer de un presupuesto considerable para su viabilidad.

REFERENCIAS

1. Borrás, J., Delgado, J., Pezzola, A., Pereira, M., Morassi, G., y Camps-Valls, G. (2017). Clasificación de usos del suelo a partir de imágenes Sentinel-2. *Revista de Teledetección*, 0(48), 55-66. Recuperado de <https://doi.org/10.4995/raet.2017.7133>
2. Breiman, L. (2001). *Random forest*. Recuperado de <https://bit.ly/3ddQE0t>
3. Campbell, J., y Wynne, R. (2011). *Introduction to Remote Sensing* (5.^a ed.). Recuperado de <https://books.google.es/books?isbn=1609181778>
4. Chuvieco, E. (1995). *Fundamentos de teledetección espacial* (2.^a ed.). Madrid: Ediciones Rialp.
5. Cortes, C., y Vapnik, V. (2005). *Support-vector networks*. Machine Learning. Recuperado de <https://doi.org/10.1007/BF00994018>
6. Environmental Systems Research Institute. (s.f.). *Introduction to Image Classification, Web Course*. Recuperado de <https://bit.ly/3g5qbE9>
7. García, S., y Martínez, L. (2010). Método de identificación de cultivo de arroz (*Oryza sativa* L.) con base en imágenes de satélite. *Agronomía Colombiana*, 38(2), 281-290. Recuperado de <https://bit.ly/3sb4W6o>

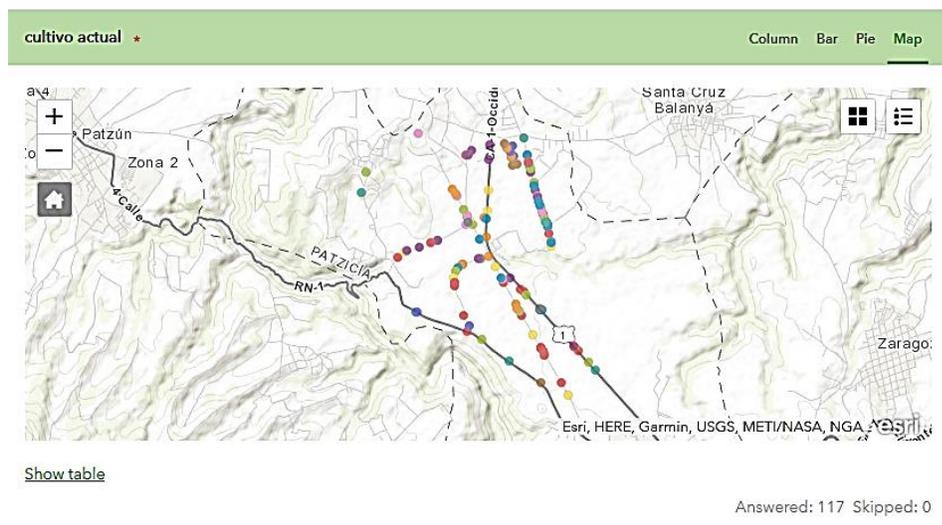
8. Gislason, P.O., Benediktsson, J.A., Sveinsson, J.R. 2006. Random Forests for land cover classification. *Pattern Recognition Letters*, 27(4), 294-300. Recuperado de <https://doi.org/10.1016/j.patrec.2005.08.011>
9. Hao, P., Wang, L., y Niu, Z. (2015). *Comparison of Hybrid Classifiers for Crop Classification Using Normalized Difference Vegetation Index Time Series: A Case Study for Major Crops in North Xinjiang, China*. Recuperado de <https://doi.org/10.1371/journal.pone.0137748>
10. Hastie, T., Tibshirani, R., y Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer Science & Business Media. Recuperado de <https://stanford.io/3uKNbML>
11. Jensen, J.R. (2005) *Introductory Digital Image Processing: A Remote Sensing Perspective*. (3.^a ed.). Prentice Hall, Upper Saddle River.
12. Kumar, S. (2008). *Basics of Remote Sensing and GIS*. Recuperado de <https://books.google.es/books?isbn=8170087961>
13. Liang, S. (2017). *Comprehensive Remote Sensing*. Recuperado de <https://books.google.es/books?isbn=0128032219>
14. Lillesand, T.M., Kiefer, R.W. and Chipman, J.W. (2004) *Remote Sensing and Image Interpretation*. (5.^a ed.). Hoboken, New Jersey: John Wiley and Sons, Inc.

15. Manjarrez, C., Pinedo, C., Vélez, C., y Pinedo, A. (2007). Separabilidad espectral de cultivos agrícolas con imágenes Landsat TM. *ecnociencia Chihuahua*, 1(2), 48-56. Recuperado de <https://bit.ly/3wR8n5O>
16. McCloy, K. (1995). *Resource Management Information Systems: Remote Sensing, GIS and Modelling* (2.^a ed.). Recuperado de <https://books.google.es/books?isbn=0748401202>
17. McHugh M. L. (2012). Interrater reliability: the Kappa statistic. *Biochemia medica*, 22(3), 276–282.
18. Pantaleone, L., y Tosini, M. (2012). *Clasificación de cultivos a partir de imágenes satelitales LANDSAT EM*. En XVIII Congreso Argentino de Ciencias de la Computación.
19. Sánchez, A. L., y de la Riva Fernández, J. Caracterización espectral e identificación temprana de cultivos de regadío en el valle del Ebro: Aplicación operativa para la gestión mediante teledetección y SIG. En *Análisis espacial y representación geográfica: innovación y aplicación* (pp. 671-680). Departamento de Geografía y Ordenación del Territorio.
20. Sozzi, M., Marinello, F., Pezzuolo, A., y Sartori, L. (2018, July). Benchmark of satellites image services for precision agricultural use. In *Proceedings of the AgEng Conference, Wageningen, The Netherlands* (pp. 8-11).

21. Stein, A., van der Meer, F., y Gorte, B. (1999). *Spatial Statistics for Remote Sensing*. Recuperado de <https://books.google.es/books?isbn=079235978X>
22. Thenkabail, P. (2015). *Remotely sensed data characterization, classification, and accuracies*. Florida: CRC Press. Recuperado de <https://books.google.es/books?isbn=1482217872>
23. Tolpekin, V., y Stein, A. (2012). *The core of GIScience: a process-based approach*. Enschede: ITC Educational Textbook Series.
24. Vásquez, P., Massuelli, S., y Platzeck, G. (2006). Determinación de patrones espectrales para distintos usos del suelo en ambientes heterogéneos. En *Simposio Internacional en Percepción Remota y Sistemas de Información Geográfica*. 12. 2006 09 24-29, septiembre 24 al 29 de 2006. Cartagena de Indias, Colombia. CO.

APÉNDICES

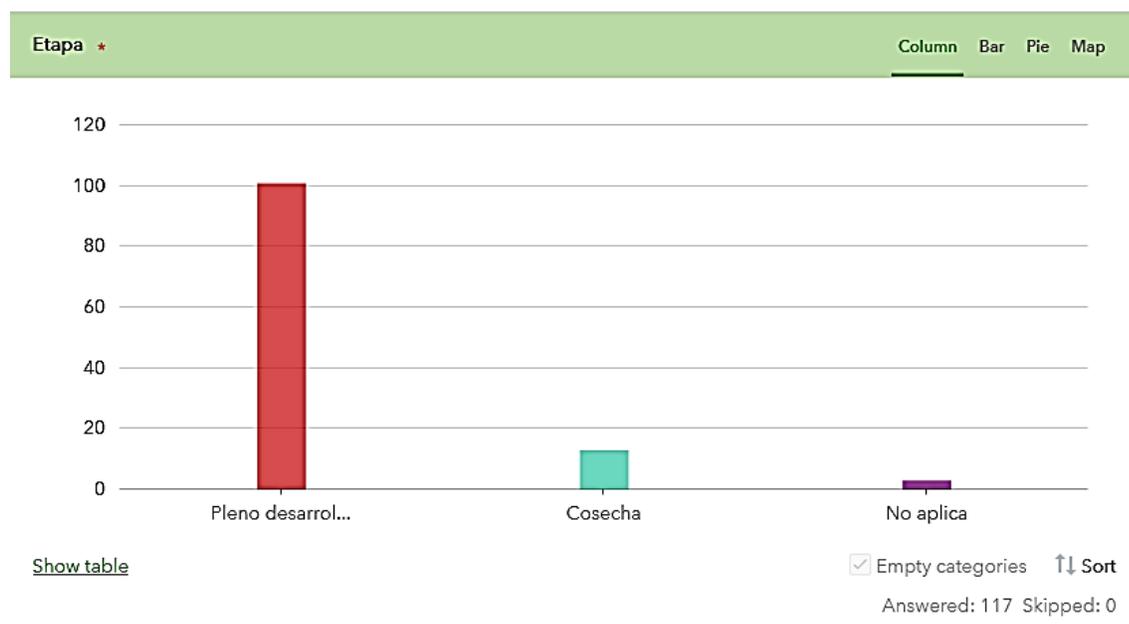
Apéndice 1. Resumen de datos colectados durante la fase de campo mediante el formulario de survey123



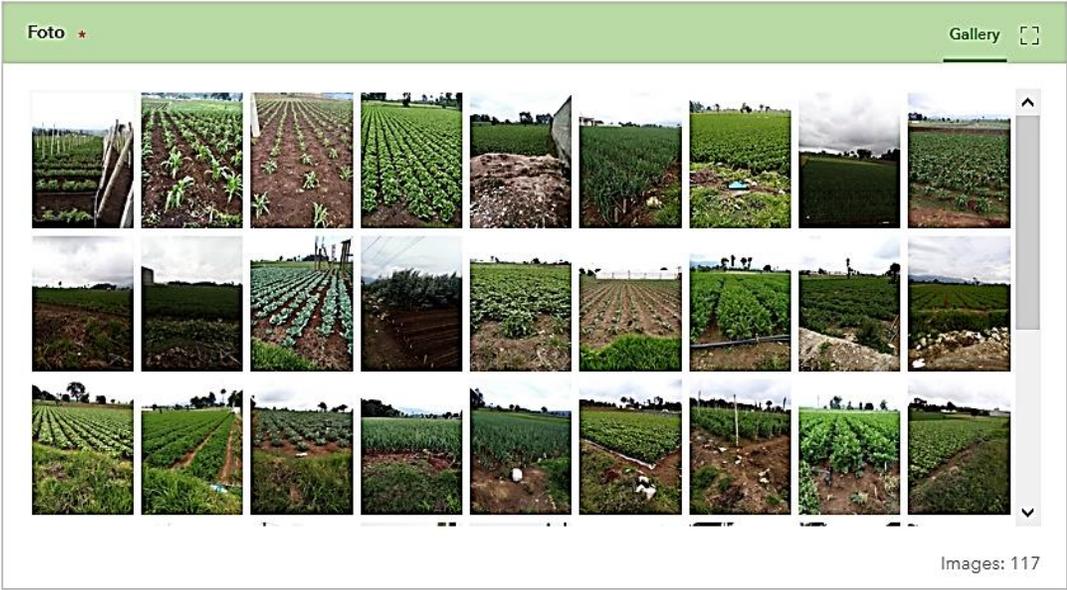
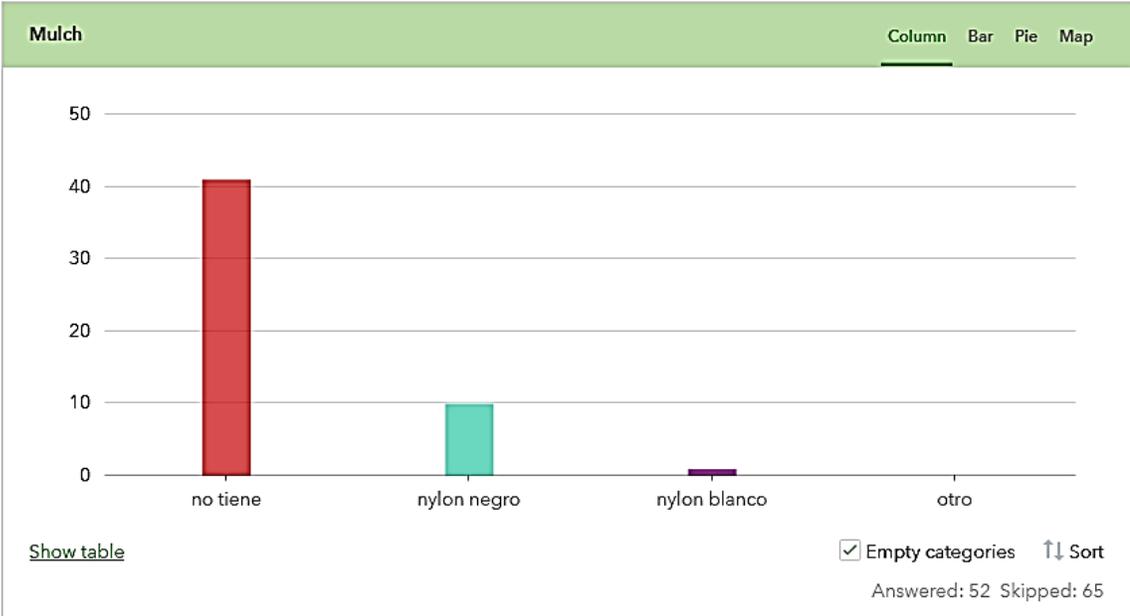
Respuestas	Conteo	Porcentaje
Zanahoria	17	15
Otro	15	13
Repollo	15	13
Maíz	14	12
Cebolla	10	9
Lechuga	10	9
Arveja china	8	7
Fresa	7	6
Brócoli	5	4

Continuación apéndice 1.

Respuestas	Conteo	Porcentaje
Invernadero	5	4
Frijol de suelo	4	3
Papa	3	3
Ejote francés	2	2
Remolacha	2	2
Total	117	



Continuación apéndice 1.



Fuente: elaboración propia.

Apéndice 2. **Matriz de confusión y cálculo del índice Kappa para la clasificación supervisada mediante el algoritmo RT de la imagen WV2 con sus bandas VIS/NIR. Valores de cada celda representados en número de píxeles**

CLASES	C01	C02	C03	C04	C05	C06	C07	C08
C01	393	0	0	2	0	0	0	0
C02	0	188	0	0	0	0	0	0
C03	0	0	234	2	0	0	0	1
C04	0	0	0	1818	0	0	0	0
C05	0	0	0	3	292	0	0	0
C06	0	0	0	0	0	164	16	0
C07	0	0	0	0	0	1	905	0
C08	0	0	0	0	0	0	0	692
C09	0	0	0	41	2	0	0	0
C10	0	0	2	0	0	0	0	2
C11	0	0	0	0	0	0	0	0
C12	0	0	0	0	0	0	6	0
C13	0	0	0	0	0	0	0	0
C14	0	0	0	10	0	0	0	0
C15	0	0	1	0	0	0	7	1
C16	7	10	0	16	0	0	0	27
CM	400	198	237	1892	294	165	934	723

Continuación apéndice 2.

CLASES	C09	C10	C11	C12	C13	C14	C15	C16	RM
C01	0	0	0	0	0	0	0	15	410
C02	0	0	0	0	0	0	0	8	196
C03	0	2	0	0	0	0	18	0	257
C04	2	0	0	0	0	2	0	2	1824
C05	5	0	0	0	0	1	15	0	316
C06	0	0	0	0	0	0	0	0	180
C07	0	0	0	1	0	0	6	0	913
C08	0	1	0	0	0	0	8	0	701
C09	237	0	0	0	0	2	0	0	282
C10	0	270	4	0	0	0	14	2	294
C11	0	0	134	0	0	0	0	3	137
C12	0	0	0	453	0	0	8	0	467
C13	0	0	0	0	344	0	0	0	344
C14	0	0	0	0	0	120	0	0	130
C15	0	0	0	0	0	0	1117	0	1126
C16	0	1	1	0	0	0	0	583	645
CM	244	274	139	454	344	125	1186	613	8222

Nombres de las clases: C01-Alfalfa, C02-Apio, C03-Arveja, C04-Bosque, C05-Cebolla, C06-Cebolla con mulc plateado, C07-Cultivos con cobertura, C08-Coles, C09-Fresa, C10-Frijos, C11-Cucúrbitas, C12-Cucúrbitas, C12-Infraestructura, C13-Lechuga, C14-Melocotón, C15-Suelo, C16-Zanahoria.

Fuente: elaboración propia.

Continuación apéndice 2.

Concordancia esperada

$$\text{Concordancia esperada } (pr_e) = \frac{\frac{CM_1 \times CM_1}{n} + \frac{CM_2 \times CM_2}{n} + \dots + \frac{CM_{16} \times CM_{16}}{n}}{n}$$

Donde:

CM₁ representa la columna marginal 1

CM₂ representa la columna marginal 2...

CM₁₆ representa la columna marginal 16

CR₁ representa la fila marginal 1

CR₂ representa la fila marginal 2...

CR₁₆ representa la fila marginal 16

n representa el número de observaciones

$$\text{Concordancia esperada } (pr_e) = \frac{\frac{400 \times 410}{8222} + \frac{198 \times 196}{8222} + \dots + \frac{613 \times 645}{8222}}{8222}$$

$$\text{Concordancia esperada } (pr_e) = \mathbf{0.11009741}$$

Concordancia real esperada (exactitud global)

$$\text{Concordancia real esperada } (Pr_a) = \frac{\sum \text{obs. correctamente clasificadas}}{\text{número de observaciones}}$$

$$\text{Concordancia real esperada } (Pr_a) = \frac{7944}{8222}$$

$$\text{Concordancia real esperada } (Pr_a) = \mathbf{0.966188275}$$

Continuación apéndice 2.

Índice Kappa

$$\text{Índice Kappa } (K) = \frac{Pr_a - Pr_e}{1 - Pr_e}$$

$$\text{Índice Kappa } (K) = \frac{0.966188275 - 0.11009741}{1 - 0.11009741}$$

$$\text{Índice Kappa } (K) = \mathbf{0.96200514}$$

Error estándar de Kappa

$$\text{Error estándar de Kappa } (SE_k) = \sqrt{\frac{pr_a(1 - pr_a)}{n(1 - pr_e)}}$$

$$\text{Error estándar de Kappa } (SE_k) = \sqrt{\frac{0.966188275(1 - 0.966188275)}{n(1 - 0.11009741)}}$$

$$\text{Error estándar de Kappa } (SE_k) = \mathbf{0.032668492}$$

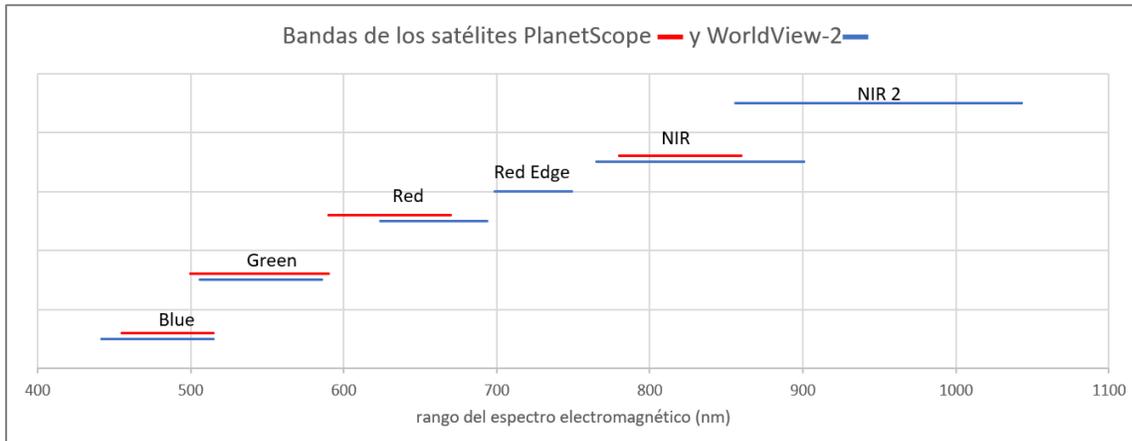
Intervalo de confianza para el índice Kappa para 95 % de confianza:

$$K \mp 1.96 \times SE_K$$

$$0.966188275 \mp 1.96 \times 0.032668492$$

El índice Kappa se encuentra entre **0.96-0.97**

Apéndice 3. **Rango del espectro electromagnético que cubre cada una de las bandas empleadas de los satélites PlanetScope y WorldView-2**



Fuente: elaboración propia.

ANEXOS

Anexo 1. Interpretación del índice de Kappa de Cohen

Valor de Kappa	Nivel de concordancia	Porcentaje de datos que son confiables
0-0.20	ninguno	0-4 %
0.21-0.39	mínimo	4-15 %
0.40-0.59	pobre	15-35 %
0.60-0.79	moderado	35-63 %
0.80-0.90	alto	64-81 %
Por encima de 0.90	casi perfecto	82-100 %

Fuente: McHugh. (2012). *Interrater reliability: the Kappa statistic*.