

Paradigmas de Aprendizaje Automático Aplicados a la Teledetección: Imágenes RGB e Imágenes Multiespectrales

Gabriela Calvario Sánchez

2019



UNIVERSIDAD DEL PAIS VASCO
Facultad de Informática

eman ta zabal zazu



Universidad
del País Vasco

Euskal Herriko
Unibertsitatea

**Paradigmas de Aprendizaje Automático
Aplicados a la Teledetección: Imágenes RGB
e Imágenes Multiespectrales**

Gabriela Calvario Sánchez

2019

Trabajo de graduación en modalidad de Tesis presentado
por:

Gabriela Calvario Sánchez

Para optar al grado académico de Doctorado en Ingeniería
Informática

País Vasco, España, Marzo del 2019

Agradecimientos

Rara vez se consigue llegar a los objetivos marcados en soledad, tanto en el ámbito profesional, como en el social. La realización de un trabajo de investigación de tesis es una amplia tarea que se desarrolla de forma ineludible en estos dos ámbitos, por lo que cuando se finaliza, quien la firma está obligado a agradecer la ayuda que se ha recibido a lo largo de todo este camino hacia la tesis.

En primer lugar, a mi familia por su apoyo incondicional y permanente en cada uno de los proyectos que he emprendido a lo largo de mi vida. A mi compañero de vida Juan Carlos que siempre ha estado en los momentos más difíciles a lo largo de este camino, gracias por tu amor y paciencia, a mi amada hija Alejandra que es el motor de mi vida.

Este proyecto tan importante en mi vida no hubiera sido posible sin la ayuda de las personas que estuvieron en este camino hacia la tesis. Me gustaría agradecer de una manera especial a mis directores de tesis Dr. Basilio Sierra y la Dra. Teresa Alarcón, su paciencia, tiempo y conocimiento, han sido extremadamente valiosos para mí desarrollo profesional y de manera personal, siempre estuvieron apoyándome, reconozco con gratitud el tiempo brindado y su valioso consejo siempre.

Gracias Dr. Oscar Dalmau, tu conocimiento y experiencia han sido base fundamental de esta investigación, mi respeto y admiración siempre para ti, de manera personal pienso que he aprendido de los mejores. Dra. Carmen Hernández al comenzar este camino me diste las bases de conocimiento, eres un gran ejemplo para mí y al estar en la recta final me alentaste y me diste animo cuando más me costaba continuar, recuerdo todas esas ocasiones que me ayudaste y me contestaste mis dudas a deshoras, mi eterna gratitud siempre a ti.

A mi Padre que me enseñó a amar el estudio, ya que nada de esto habría sido posible sin tu labor incansable, desde que muy pequeña me enseñaste a soñar y pensar que con trabajo nada es imposible, gracias papa por tu amor, paciencia y dedicación. A mi madre una mujer fuerte, superaste mil y una barreras, nos enseñaste el valor de la responsabilidad, del esfuerzo, de la honestidad y a no tener miedo a nada, gracias a ello lograste que cada uno de tus hijos adquiriera unos principios inquebrantables para poder caminar con orgullo y firmeza por la vida.

A mis dos hermanos y cómplices de travesuras en la infancia, en especial a ti José, eres mi confidente y mi amigo siempre.

Agradezco la beca académica que con el aporte de todos los mexicanos hacen posible los fondos económicos del CONACYT.

Por último y no menos importante a mis compañeros, quienes me han sabido brindar enseñanzas profesionales y personales en el lapso de tiempo que compartimos, en particular y muy especialmente a Jordán Martínez, Rosy Ulloa, Igor Rodríguez, Mikel Antoñana, Alejandro García, Iñigo Mendiadua.

Agradecimientos	IV
Lista de Figuras	XI
Lista de Cuadros	XII
Resumen	XIV
1. Introducción	1
1.1. Antecedentes	4
1.2. Identificación del Problema y Motivación	6
1.3. Hipótesis y Objetivos	6
1.4. Metodología de la Investigación	7
1.5. Contribuciones Esperadas de la Tesis	8
1.5.1. Publicaciones Durante este Proyecto de Tesis	8
1.5.2. Seminarios	9
1.5.3. Entrevistas	10
1.6. Estructura de Tesis	10
2. Conceptos Básicos de Teledetección	11
2.1. Conceptos Generales de Teledetección Usados en esta Tesis	13
2.1.1. Concepto de Longitud de Onda	13
2.1.2. Espectro Electromagnético	13
2.1.3. La Radiación Electromagnética.	14
2.1.4. Fuentes de Energía o Iluminación	15
2.1.5. Cuerpo Negro	15
2.1.6. Interacción Entre la Atmosfera y la Radiación	16
2.1.7. Ventana Atmosférica	17
2.1.8. Interacción con la Superficie	18
2.1.9. Curvas Espectrales	19

2.1.10.	Firmas Espectrales y su Aplicación Real	22
2.1.11.	Observación de la Tierra	24
2.1.12.	Sensores Remotos y Plataformas	25
2.1.13.	Resolución	25
2.1.14.	Tipos de Órbita en Satélites	29
2.1.15.	Principio de Funcionamiento de un Sensor	31
2.1.16.	Escala	32
2.2.	Conceptos de Imagen en Teledetección Usados en esta Tesis.	33
2.2.1.	Modo de la Imagen	33
2.2.2.	Niveles de Procesamiento de la Imagen por Satélites y Aeronaves	35
2.2.3.	Formatos de Imagen	36
3.	Estado del Arte y Revisión de Literatura	39
3.1.	Satélites	41
3.1.1.	Reseña Era Landsat	42
3.1.2.	Adquisición de Imágenes de Landsat (Fuentes):	44
3.1.3.	Satélites de Muy Alta Resolución	45
3.1.4.	Comparación Entre las Plataformas, Aérea y Satelital	48
3.2.	Detectores	51
3.2.1.	Dispositivo de Carga Acoplada, CCD	51
3.2.2.	Detector CCDs y Adquisición de la Imagen	52
3.2.3.	Semiconductor Complementario de Óxido Metálico	53
3.3.	Vehículos Aéreos No Tripulados	54
3.3.1.	Desarrollo de Aeronaves	55
3.3.2.	Integración de un UAV	56
3.3.3.	Campo de Aplicación General	58
3.3.4.	Ventajas y Desventajas	58
3.4.	Análisis de Datos Espectrales	59
3.4.1.	Métodos de Clasificación Supervisada	61
3.4.2.	Métodos de Clasificación No Supervisada	63
4.	Propuesta Elaborada Para Agave	65
4.1.	Teledetección de los Recursos Agrícolas	68
4.2.	UAVs en la Agricultura	69
4.3.	Structure-from-Motion	71
4.4.	Geometría y Radiometría	73
4.5.	Flujo de Trabajo para el Monitoreo del Agave	75
4.6.	Contribuciones	84
4.6.1.	A Multi-Disciplinary Approach to Remote Sensing through Low-Cost UAVs	85
4.6.2.	Un Enfoque Multidisciplinario de Sensado Remoto A Través de UAV de Bajo Costo	103
4.6.3.	Use of UAV for remote sensing; a methodology to agave plants counting	114
4.6.4.	Foro Geoespacial Latinoamericano	125

5. Propuesta Elaborada Para Cuerpos de Agua	134
5.1. Características Generales de la Imagen Óptica	136
5.2. Metodología General	138
5.2.1. Preprocesamiento	138
5.2.2. Metodologías de Extracción de la Información	143
5.2.3. Índices Espectrales	143
5.2.4. Clasificación	146
5.2.5. Evaluación de la Exactitud	150
5.3. Contribuciones	152
5.3.1. Selection and Fusion of Spectral Indices to Improve Water Body Discrimination	153
5.3.2. Machine Learning Approach to Fuse Multiple Band For Water Bodies Detection	164
6. Conclusiones Finales y Líneas de Investigación Futuras	175
Bibliografía	209
Glosario	210

Lista de Figuras

1.1. Observación Terrestre, Ejemplo de Sensores Remotos.	4
1.2. La naturaleza multifacética de la investigación y el desarrollo de tecnologías en teledetección. Fuente <i>La evolución del análisis de datos Landsat</i> por Landgrebe. Derechos de autor 1997, [119].	5
2.1. Longitud de Onda	13
2.2. Investigadores de la <i>L'École Polytechnique Fédérale de Lausanne</i> en Suiza han logrado captar, por primera vez, el comportamiento de la luz como onda y partícula [247].	15
2.3. Espectro electromagnético, clasificación según el rango de longitud de onda y ventana atmosférica. Propiedad de la atmósfera terrestre de ser permeable a algunas longitudes de onda.	18
2.4. (a) Reflexión Especular. (b) Reflexión Difusa o Lambertiana	19
2.5. Curvas espectrales que representan de manera general suelo, vegetación y agua	20
2.6. Curva Espectral de Vegetación, usando Hyperspectral Infrared Imager o HypSIRI, Fuente en https://speclib.jpl.nasa.gov/download	21
2.7. Curva Espectral del Agua de Grifo usando Aster Spectral Library, Rango IR - SWIR Datos Provistos de https://speclib.jpl.nasa.gov/download	22
2.8. Simulación de bandas en diferentes resoluciones espaciales	23
2.9. Simulación de pixel puro y pixel con mezcla de diferentes tipos de texturas	23
2.10. Ejemplo la imagen (a) pertenece a un dispositivo UAV su resolución espacial corresponde a 3 cm. La imagen (b) pertenece a una plataforma satelital con una resolución espacial de 50 cm.	26
2.11. (a) Relación FOV-IFOV. (b) Tamaño de pixel nadir, off-nadir, se puede observar el incremento.	27
2.12. Arquitectura de imagen multispectral.	28
2.13. Imágenes satelitales capturadas con diferente resolución radiométrica. Se muestra que mientras mayor es el número de bits por pixel, es posible observar mayor número de detalles.	29

2.14. Tipos de Órbitas	30
2.15. (a) Sensor de barrido o whiskbroom, realiza repetidas mediciones a través de una línea de barrido entre A y B. (b) Sensor de empuje o pushbroom, el espejo escanea por medio de una línea de barrido entre A y B. (c) Un arreglo de detectores de estado sólido (CCD). Fuente “Computer Processing of Remotely-Sensed Images: An Introduction” por Paul M. Mather, Magaly Koch, p. 3, John Wiley & Sons. Derechos de autor 2011, [133].	32
2.16. Imagen WorldView-2, 50cm GSD. Las características de los objetos en la imagen, se pueden observar con mayor facilidad, esto es debido a la resolución espacial que tiene la imagen pancromática.. . . .	34
2.17. Imagen WorldView-2, GSD 2m. Imagen de alta resolución de 8 bandas multispectrales.	34
2.18. Imagen WorldView-2, 50cm GSD. Imagen de alta resolución fusionada, a simple vista se pueden observar las mejoras en la imagen.	35
2.19. Grabación y Acceso de las Imágenes Digitales en Teledetección. Fuente “Georreferenciación de Cartografía: Datos Raster y Vectoriales” por Fernando J Sanchez Menendez, p. 53, EOSGIS SL. Derechos Reservados.2004-2009 [135].	38
3.1. El mapa de Abauntz ubicado en Navarra España es considerado como el mapa más antiguo conocido en Europa Occidental. En <i>A palaeolithic map from 13,660 calBP: engraved stone blocks from the Late Magdalenian in Abauntz Cave</i> , Navarra, España por P. Utrilla, 2009, Journal of Human Evolution, ELSEVIER, 57(2):99–111. Derechos de autor 2009, [216].	41
3.2. Desarrollos que dan comienzo al Inicio de la era en Teledetección. . .	42
3.3. Algunas plataformas gubernamentales y civiles actualmente en uso. . .	44
3.4. Detectores y modos de adquisición de la imagen	53
3.5. Arquitectura Básica de un UAV,[87].	57
3.6. (a) Coordenadas del dominio espacial del pixel sombreado, fila-columna. (b) Dimensiones de la imagen y números digitales. (c) Espacio de características de 2 y 3 dimensiones.	60
3.7. Cada caja está limitada por valores de puntos mínimos y máximos dentro de la clase, sin embargo, los pixeles en color negro no satisfacen ningún criterio de asignación para una clase.	62
3.8. Algoritmo de agrupamiento K-medias. Número de clúster K=3, cada clúster tiene asociado un centroide y los puntos se asignan al clúster cuyo centroide esté más cerca. Con cada iteración va actualizando los centroides en función de su distancia, hasta que los centroides dejan de cambiar.	64
4.1. Paisajes Agaveros, Ruta del Tequila en Jalisco, México.	67
4.2. Monitoreo de agave con un equipo UAV, Resolución Espacial a 3cm. .	71

4.3.	(a) y (b) Imágenes sobrepuestas obtenidas de un vuelo hecho por UAV sobre plantas de agave. (c) Configuración típica en bloques de imágenes UAV que cubren un área aproximada de 3 ha con un GSD de 3cm.	72
4.4.	Cuadrícula de zonas UTM que le corresponden a México (zonas 11 a 16 Norte). En el globo obtenido de la aplicación Google Earth, podemos observar la zona marcada con una chincheta amarilla que corresponde a Jalisco, esta área está gestionada sobre las coordenadas UTM zona 13 Norte datum WGS84, que son parte de las zonas con denominación de origen del agave. Derechos de autor Google Earth 2019 TM , [63].	76
4.5.	Equipo UAV DJI Phantom 4.	77
4.6.	Flujo de Trabajo del Proceso General Metodología para el Agave.	78
4.7.	Ejemplo de Plan de Vuelo generado por la aplicación Pix4D Capture.	79
4.8.	Los puntos de control en tierra o Ground Control Points (GCP), son objetivos marcados en el suelo, espaciados estratégicamente a lo largo de su área de interés.	80
4.9.	Áreas de estudio en el estado de Jalisco, seleccionadas para vuelos con plataforma DJI Phantom 4.	81
5.1.	(a) pertenece a la captura de imagen por el satélite Landsat 8 OLI, zona UTM 13 Norte utilizando la proyección WGS84 con fecha del 15 de febrero del 2014 en el área de Chapala, Jalisco, México; (b) Índice Diferencial de Agua Normalizado Modificado (MNDWI) y (c) Índice Diferencial de Agua Normalizado (NDWI) las imágenes pertenecen a la respuesta de una clasificación supervisada realizada por medio de un algoritmo de aprendizaje automático (Maquina de soporte Vectorial, SVM). Fuente: Servicio Geológico de Estados Unidos (USGS)[214].	137
5.2.	Corrección de Distorsión Geométrica.	139
5.3.	Imágenes del satélite Landsat 8 OLI, diferentes temporalidades del año 2014, sin embargo, se puede observar los problemas por efectos atmosféricos que se presentan y que pueden ser corregidos con ciertas limitaciones en varias regiones de la imagen. Area de la imagen Chapala, Jalisco, México. Fuente: Servicio Geológico de Estados Unidos(USGS) [214].	142
5.4.	La ilustración muestra una imagen del satélite Landsat 8 OLI y una serie de índices con los que se trabajó en esta tesis. (a) Área de estudio, presa de Nezahualcóyotl en Chiapas, México; (b) Índice espectral NDWI; (c) Índice espectral MNDWI; (d) Índice espectral AWEInSH y (e) Índice espectral AWESH.	145
5.5.	Búsqueda de KNN en un conjunto dado con $k = 3$ usando la distancia euclidiana.	148
5.6.	Ejemplos de árbol de decisión en cual una muestra es introducida, para la cual Wetness = low, Brightness =high y el valor de Greenness es el valor a clasificar. Fuente: Classification Methods for Remotely Sensed Data. Derechos de autor Paul M Mather 2009, [132].	149

5.7. Naive Bayes es la forma más simple de la red bayesiana, en los cuales todos los atributos son independientes dado el valor de la variable clase [243].	150
5.8. Ejemplo de Matriz de Confusión	151

Lista de Cuadros

2.1. División típica del espectro electromagnético [31].	14
2.2. En función de la emisividad, los cuerpos pueden dividirse en:	16
2.3. Principales procesos de dispersión de la radiación electromagnética por la atmósfera [40].	17
2.4. Clasificación de imágenes, según su resolución espacial [60]	26
2.5. Comparación de escalas en datos de imágenes digitales [176].	33
3.3. Comparación de escalas en datos de imágenes digitales [176]	45
3.1. Historia Landsat [213], [214].	46
3.2. Historia Landsat [213], [214].	47
3.4. Satélites de muy alta resolución (VHR) actualmente operando.	49
3.5. Satélites de muy alta resolución (VHR) actualmente operando.	50
3.6. Clasificación por categorías de UAVs.	56
3.7. Principales Clasificadores Utilizados en Teledetección [101], [191], [133].	61

La tendencia actual en el uso de sensores para recopilar datos georeferenciados con una alta redundancia, se basa en la aplicación de métodos robustos y automatizados para extraer información geoespacial.

Los resultados derivan en un cambio de paradigmas en tecnologías geoespaciales, que hasta este momento no han generado un límite en su aplicación. Sumado a ello, los avances en tecnologías sobre ordenadores, muestran una clara tendencia a la generación de estudios avanzados sobre imágenes, lo cual impulsa a la investigación de la información espacial con un progreso exponencial.

En general los sensores satelitales son una alternativa ampliamente usada en el campo de estudios científicos, existe una amplia variedad de estudios y con el avance sobre metodologías de procesamiento de imagen y aprendizaje automático ofrecen alternativas cada vez más avanzadas.

El rápido desarrollo de tecnologías ha generado un avance notable en la adquisición de datos por medio tecnologías geoespaciales en diversas plataformas. Un ejemplo claro de ello es el uso de vehículos aéreos no tripulados (UAV), los cuales pueden generar productos en teledetección como: mapas temáticos, clasificación de superficies, modelado del terreno, entre otros productos. La proliferación de sensores de alta resolución y el gran interés en detectar patrones sobre las imágenes, han contribuido a dar lugar a una era en la que la extracción de información sobre los datos, ha adquirido una mayor relevancia y ha ayudado en la evolución del procesamiento de imágenes.

El avance sobre metodologías de procesamiento de imagen y aprendizaje automático ofrecen alternativas cada vez más avanzadas, ya que se pueden obtener datos de una manera más precisa, automática y eficaz.

El presente trabajo presenta una revisión del estado del arte sobre sensores remotos multiespectrales, plataformas, tipos de sensores, métodos de extracción de la información, flujos de datos basado en procesamiento digital de imágenes y aprendizaje automático. La revisión realizada fue el inicio de la investigación que permitió la elaboración de propuestas para el análisis de imágenes usando métodos de procesamiento

de imagen, aprendizaje automático y datos de plataformas aéreas y satelitales. La primera propuesta que se presenta en esta investigación de tesis está encaminada al monitoreo de agave azul a través de una plataforma UAV de bajo costo. Como resultado principal de esta propuesta está la introducción de una nueva metodología para el monitoreo del agave en México. La segunda propuesta propone un método de análisis sobre imágenes con diferente temporalidad y la generación de un umbral automático apropiado para cada índice de detección de agua. La tercera propuesta presenta un método para la fusión de diferentes índices espectrales de agua y el uso de un clasificador supervisado y probabilístico para detectar cuerpos de agua. La estrategia de análisis y clasificación propuesta permite la creación adaptativa de índices espectrales y la clasificación de agua y no agua a partir del nuevo índice creado. Los resultados de estas propuestas están publicados y abonan a las contribuciones de la presente investigación.

CAPÍTULO 1

Introducción

El presente capítulo describe el panorama actual del análisis de imágenes a través de la teledetección o percepción remota, se detallan los antecedentes y la motivación de la investigación realizada y se enuncian los objetivos y las contribuciones esperadas. La sección final del capítulo describe la estructura del resto del manuscrito.

El capítulo está organizado de la siguiente forma: sección 1.1. Antecedentes, 1.2. Identificación del Problema y Motivación, 1.3. Hipótesis y Objetivos, 1.4. Metodología de la Investigación, 1.5. Contribuciones Esperadas de la Tesis, 1.6. Estructura de Tesis.

La teledetección o percepción remota (PR) se refiere a las actividades de registro, observación, percepción o detección de objetos en sitios alejados [228].

La teledetección se basa en el principio de conversión de los datos recolectados por sensores y la conversión de estos en productos de información, los cuales dan valor y contribuyen a alentar y generar aplicaciones en PR.

Hace más de 50 años, William T. Pecora tuvo un sueño. En una década, cuando la mayoría de la industria espacial y de la comunidad científica centraron su atención en llevar al hombre a la Luna y mirar hacia el universo, Pecora sintió que tal vez deberíamos mirarnos hacia nosotros mismos con nuestros avances tecnológicos y aprender más sobre la dinámica de nuestro propio planeta [230]. Haciendo un recuento hacia el pasado, en la toma de imágenes aéreas, se utilizaba una película fotográfica con filtros espectrales para la captura de datos en áreas de poca extensión. Posteriormente y en especial para áreas de mayor escala, se comenzaron a utilizar imágenes de satélite obtenidas comercialmente o de forma gratuita.

Durante la década de los 50, los sensores para PR continuaron evolucionando a partir de los métodos desarrollados para la guerra. La fotografía capturada en el rango del infrarrojo (IR), originalmente desarrollada como una herramienta de reconocimiento militar, demostró ser muy útil para los estudios en cultivos y vegetación. Estudios basados en interpretación visual y en el análisis de los datos de fotografías, demostraron ser una fuente de información muy valiosa para la inspección de daños causados por insectos y enfermedades en el área forestal y agrícola. Estos datos ayudan a minimizar y controlar los efectos de los daños causados, a través de técnicas que ayudan a reducir el impacto sobre las áreas afectadas [47], [46]. No obstante, cabe mencionar que la fotografía aérea tradicional está limitada por su coste y extensión de vuelo, ya que requieren equipos especializados y las condiciones ambientales y de vuelo deben ser óptimas para poder realizar esta tarea específica. Actualmente la oferta de productos provenientes de Vehículos Aéreos no Tripulados (UAV) y sensores espectrales, es creciente, su costo está relacionado con una mayor resolución espacial y espectral, tomando en cuenta que a mayor resolución espacial o detalle de observación, menor será el campo o extensión visual debido a una menor altura o mayor aproximación del sensor a la superficie terrestre.

Un sensor para teledetección está diseñado para capturar la energía reflejada de objetos sobre la tierra, en diversos rangos de longitud de onda del espectro electromagnético (EM) [149].

La observación de la tierra a través de dispositivos de teledetección es un tema fascinante dentro y fuera de la comunidad científica y una de las razones principales para el rápido desarrollo de dispositivos. La recolección de datos realizada por sensores aerotransportados o sobre un satélite permiten la medición de la radiación del espectro electromagnético que es reflejada, absorbida o emitida por los objetos que se encuentran en la superficie de la Tierra, ver Figura 1.1.

Hoy en día, los datos generados por sensores montados en las diversas plataformas son una importante fuente de información en muchos campos de la ciencia. En sus inicios tuvieron un uso limitado debido a la baja resolución de los mismos; sin embargo, esto ha ido cambiando de una manera muy rápida, debido a la disponibilidad de datos recolectados por los sensores. Actualmente existe una amplia gama de resoluciones

radiométricas, espectrales, espaciales y temporales, las cuales han logrado que la teledetección, sea quizás en este momento, la mejor fuente de datos para aplicaciones y estudios a cualquier escala, lo cual, está marcando una era de cambio, en la que aún no se ha encontrado un límite en la generación de nuevos enfoques.

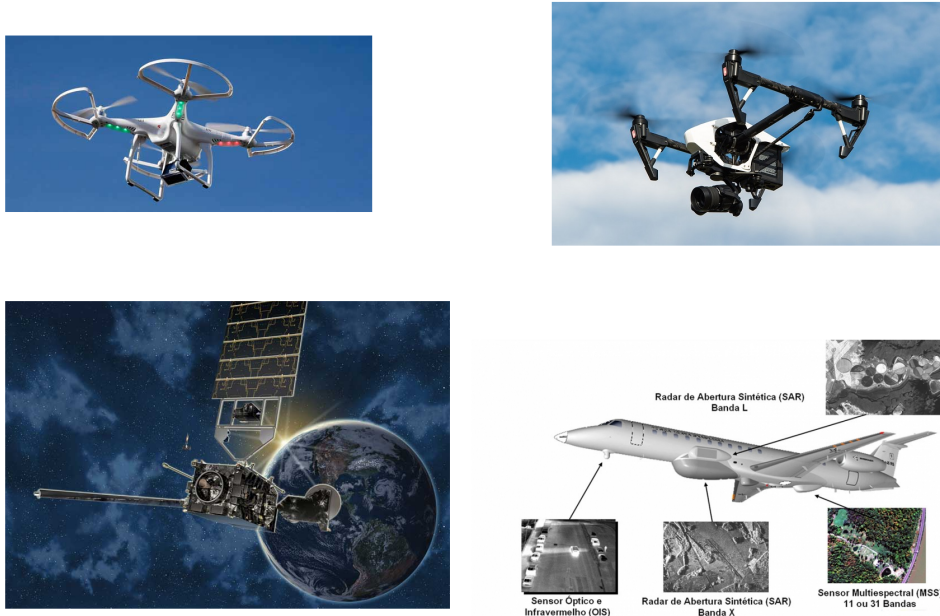


Figura 1.1: Observación Terrestre, Ejemplo de Sensores Remotos.

1.1. Antecedentes

De una manera temprana se reconoció que, para crear la disciplina de teledetección y para comenzar a utilizarla, se requería un enfoque interdisciplinario.

Citando a Landgrebe [119], *las relaciones ideales para caracterizar la ciencia acerca de la observación de la Tierra, serían la ingeniería, las ciencias de la tierra y el desarrollo de aplicaciones.*

El autor menciona un enfoque ideal, pero difícil de relacionar en aquellos momentos tempranos, sin embargo, hoy en día resulta fundamental esta relación, ver Figura 1.2.



Figura 1.2: La naturaleza multifacética de la investigación y el desarrollo de tecnologías en teledetección. Fuente *La evolución del análisis de datos Landsat* por Landgrebe. Derechos de autor 1997, [119].

El producto final de un sistema de teledetección es usualmente una imagen digital, la cual representa los datos obtenidos a través del sensor, de un objeto o evento de interés.

Dependiendo de los objetivos o alcances y citando al autor Quiao Weng [225], el sensado remoto puede ser dividido en :

1. Sensado remoto satelital: recolección de datos por medio de plataformas satelitales.
2. Fotografía y fotogrametría: captura fotográfica en el rango electromagnético del visible.
3. Detección remota térmica: la porción del espectro en el infrarrojo (IR) se utiliza como medio para la captura de información.
4. Sensado remoto a través de radar: cuando la fuente de información se captura por medio del rango de las microondas.
5. Detección de luz o LIDAR (Laser Imaging Detection and Ranging): utilizan pulsos láser enviados a la superficie de la Tierra para recolectar información. Es un sistema de medición y detección de objetos mediante pulsos de luz polarizada entre el ultravioleta y el infrarrojo.

La región del espectro visible (VIS) y el IR cercano dentro del espectro electromagnético es de $0.4 \mu\text{m}$ a aproximadamente $2 \mu\text{m}$. Esta región sigue siendo el rango más importante para la detección remota de la superficie de la Tierra [172]. Una razón importante de este hecho es que las imágenes adquiridas en el VIS y el IR suelen ser más fáciles de interpretar, incluso a simple vista, que las imágenes de otros sensores. La investigación, estudios y experimentos de este proyecto, se trabajaron sobre la región del VIS e IR y tomando en cuenta la división que hace Quiao Weng, se trabajó sobre los puntos 1 y 2 anteriormente citados en este apartado.

1.2. Identificación del Problema y Motivación

Este trabajo de investigación tiene especial motivación en proyectos reportados en la literatura, en gran parte apoyados por el Consejo Nacional de Ciencia y Tecnología (CONACYT) y el Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias (INIFAP) en México.

La búsqueda de opciones viables con enfoque de sustentabilidad de los recursos naturales de manera integral y transdisciplinaria, se dificulta por la enorme cantidad de información que se debe manejar para el diseño y ejecución de planes de manejo de recurso naturales.

“Esta dificultad se incrementa por la escasez de profesores formados en este enfoque y falta de libros en los que se incluyan tópicos prácticos y de generación de datos” [246], líneas citadas del libro de Zuñiga, del año 2004.

Cabe mencionar que México es reconocido a nivel mundial por sus recursos naturales. La diversidad biológica de México se expresa en la variedad de sus climas, geología y su topografía, son factores determinantes en su variedad de ambientes y riqueza de especies. Más del 50 % del territorio nacional se encuentra en altitudes mayores a 1000 metros sobre el nivel medio del mar. Estos elementos contribuyen a formar condiciones benéficas, ambientales y micro-ambientales que generan una gran variedad de hábitats y formas de vida [59].

Por otra parte, el agua constituye un recurso en peligro a nivel mundial, ya que de acuerdo con estudios de balance hídrico sobre la Tierra, el agua dulce solamente es del 0.007 % que se encuentra disponible para consumo humano. Recientes evaluaciones de especialistas y organizaciones internacionales sugieren que para el año 2025 más de dos terceras partes de la humanidad sufrirán algún tipo de estrés hídrico [208].

La falta de recursos hídricos afectaría directamente la agricultura puesto que el 70 % del agua consumida en el mundo se destina a la agricultura.

La producción de los alimentos y el agua son parte clave en el desafío de la gestión de los recursos, incluso con el fin de garantizar su seguridad alimentaria algunos países han adquirido tierras agrícolas en África y América Latina, debido a su riqueza de recursos [21], [86].

Resulta urgente la necesidad de gestionar la desmedida explotación de recursos naturales, ya que debido a esta cuestión cada vez existen más problemas en el planeta, ocasionando deterioro y agotamiento de recursos naturales en suelo, agua, aire y la biodiversidad. Estos elementos están siendo afectados al máximo y conllevan al incremento de problemas económicos y sociales de grandes consecuencias.

1.3. Hipótesis y Objetivos

Los estudios en el presente trabajo se han enfocado a la teledetección con sensores satelitales y aerotransportados; esto es, en el desarrollo de técnicas o metodologías de análisis de imágenes, recolectadas por sensores ópticos, eficientes en términos computacionales y orientadas a la aplicación paradigmas de aprendizaje automático en teledetección. Estos enfoques se orientan a la resolución de problemas en México, pero

pueden ser aplicables en cualquier lugar donde se presenten condiciones similares. Las hipótesis sobre las que se sustenta este proyecto de Tesis Doctoral se han desarrollado en dos principales tópicos:

1. Es posible llevar a cabo la supervisión y el monitoreo de cuerpos de agua de ecosistemas mexicanos a través imágenes satelitales procesadas por diferentes paradigmas de aprendizaje automático.
2. Es posible el monitoreo de agave con un sensor de bajo costo, montado en un Vehículo Aéreo No Tripulado (UAV).

Los objetivos de esta tesis son:

1. Generar un algoritmo para el estudio y monitoreo de cuerpos de agua en México, utilizando imágenes satelitales. El algoritmo está basado en técnicas de reconocimiento de patrones.
2. Elaborar una metodología para el uso de Vehículos Aéreos no Tripulados (UAV), basada en aprendizaje de máquina y procesamiento de imagen.

1.4. Metodología de la Investigación

En primer lugar, se busca obtener las herramientas necesarias para poder supervisar y llevar a cabo el monitoreo y dinámica de cambio en cuerpos de agua de ecosistemas mexicanos. Los pasos a seguir para cumplir este objetivo son:

- Procesamiento de imagen satelital óptica, para entrenamiento en fase de experimental.
- Búsqueda de índices espectrales en el estado del arte.
- Desarrollo de algoritmos para el monitoreo de cuerpos de agua por métodos de aprendizaje automático, a través de datos de imágenes satelitales gratuitas, utilizadas para el desarrollo de experimentos.
- Validación de resultados en localizaciones de interés y a través de diversas herramientas web y bases de datos de imágenes.
- Comparación de metodologías reportadas en la ciencia para el monitoreo de cuerpos de agua a través de sensores ópticos.
- Propuesta de soluciones y futuros trabajos en los métodos investigados.

En segundo lugar, se busca el monitoreo del agave con un sensor de bajo costo, montado en un Vehículo Aéreo No Tripulado (UAV). En este caso nos planteamos las siguientes preguntas: ¿Es posible separar cubiertas temáticas a través de un detector de bajo costo?, ¿Qué paradigmas se deben aplicar?, ¿dónde se puede aplicar y cuál es su objetivo final?. La metodología que se implemento fue:

- Estudio y análisis de técnicas de reconocimiento de elementos de interés basadas en técnicas de aprendizaje automático y visión por computador, cuya finalidad es la identificación de patrones y texturas de interés existentes en las imágenes procedentes de UAVs de bajo costo y los entornos sobre los que navegan.
- Implementar de forma eficiente una serie de algoritmos para identificar de forma automática los patrones buscados.
- Detección, monitoreo y control de texturas relativas a la capa vegetal (Agave y Maleza), identificación y separación de líneas de cultivo.
- Interacción, estudio y análisis de técnicas de localización espacial de los elementos de interés, con el fin de ubicar dichas áreas.
- Validación en campo de los resultados propuestos.
- Propuesta de soluciones y futuros trabajos en los métodos investigados.

1.5. Contribuciones Esperadas de la Tesis

El trabajo que se llevó a cabo para la realización de esta tesis ha sido un camino plagado de retos. Observando las ventajas de usar los datos generados por un sensor para aplicaciones de teledetección y en conjunto con metodologías de análisis de imagen, reconocimiento de patrones y aprendizaje máquina. Se partió de la hipótesis general acerca de evaluar el potencial de los paradigmas de aprendizaje automático en cuerpos de agua y agricultura en México. Las contribuciones de esta tesis se enuncian en las secciones 1.5.1, 1.5.2 y 1.5.3. Tales aportaciones han sido presentadas y publicadas para esta Tesis.

1.5.1. Publicaciones Durante este Proyecto de Tesis

La presente investigación se basa principalmente en las contribuciones publicadas en revistas y conferencias. La lista de publicaciones se presenta a continuación:

- [28], A Multi-Disciplinary Approach to Remote Sensing through Low-Cost UAVs. Gabriela Calvario, Basilio Sierra, Teresa E. Alarcón, Carmen Hernandez y Oscar Dalmau: *Sensors*, 17(6): 1411, 2017.

Este artículo describe las contribuciones llevadas a cabo a través del monitoreo en cultivos de agave a través de Vehículos Aéreos no Tripulados (UAV). Esta metodología fue desarrollada para cubrir la necesidad del monitoreo de cultivos con un esquema de bajo costo, de una manera sencilla y eficaz.

- [30], Selection and Fusion of Spectral Indices to Improve Water Body Discrimination. Gabriela Calvario, Basilio Sierra, Teresa E. Alarcón, Carmen Hernandez y Oscar Dalmau: *IEEE Access* 6, 72952-72961.

El presente artículo propone un enfoque para la selección y fusión de índices espectrales para mejorar la detección de cuerpos de agua a través de imágenes satelitales.

- (En Revision), Use of UAV for remote sensing; a methodology to agave plants counting.
Gabriela Calvario, Basilio Sierra, Teresa E. Alarcón, Carmen Hernandez y Oscar Dalmau.

El Vehículo Aéreo no Tripulado (UAV) ofrece nuevas oportunidades en el campo de la agricultura. El presente artículo muestra la metodología de generar un conteo automático a través de imágenes tomadas por un UAV, el cual permite una evaluación más precisa en los parámetros de proyección en la producción sobre el agave para producir tequila. El objetivo principal de este artículo es avanzar en el uso del UAV en el conteo automático de plantas de agave.

1.5.2. Seminarios

- [26], G Calvario, C Hernandez, E Lazkano, B Sierra, O Dalmau y T Alarcón: MACHINE LEARNING APPROACH TO FUSE MULTIPLE BAND FOR WATER BODIES DETECTION. In 3rd International Conference on Computer Science Networks and Information Technology (ICCSNIT 2017), ISBN: 9780998900032. (ver Capítulo 5)

En este documento se presenta un enfoque para detectar cambios de manera automática sobre cuerpos de agua, se basa en metodologías de aprendizaje maquina sobre imágenes del satélite Landsat 8.

- [29], Calvario Gabriela, Sierra Basilio, Martinez Jordan Monter Eder: UN ENFOQUE MULTIDISCIPLINARIO DE SENSADO REMOTO A TRAVÉS DE UAV DEBAJO COSTO. En I Simposio de Aplicaciones Científicas y Técnicas de los Vehículos no Tripulados, volumen 1, páginas 24–32. UNAM (Centro de Investigaciones en Geografía Ambiental) el Instituto Nacional de Estadística y Geografía y la Agencia Espacial Mexicana, 2017. (ver Capitulo 4)

Este trabajo, fue nuestro primer acercamiento que se presentó sobre el tema de monitoreo de cultivos con un sensor de bajo costo, trabajo que culmino en [28]. En este simposio se presentaron los primeros avances sobre el monitoreo de agave con equipos UAV.

- [27], Calvario Gabriela: Futura dirección de la Agricultura: Un Reto para Tecnologías Emergentes. LATIN AMERICA SPATIAL FORUM, Noviembre 2018. <https://lagf.org/ppt/Gabriela-Calvario.pdf>. (ver Capitulo 4)

En este Foro Geoespacial se presentó un panorama general del avance de tecnologías emergentes sobre agricultura, avances en México y Latinoamérica. Que tipos de tecnologías se utilizan en el campo, quienes las están generando y el futuro de dichas tecnologías en la agricultura.

1.5.3. Entrevistas

Ver anexo.

1.6. Estructura de Tesis

El presente trabajo de tesis está organizado en cinco capítulos principales considerando esta introducción. A continuación se procede a dar una breve descripción del contenido en cada capítulo.

Capítulo 1: este capítulo está enfocado a presentar un panorama actual acerca del análisis de imágenes a través de la teledetección. En este apartado se presenta un recorrido a través de los antecedentes, motivos, ideas y contribuciones de esta investigación de Tesis.

Capítulo 2: se presentan los conceptos y definiciones básicos en el tema de teledetección. Toda la información contenida en este capítulo es parte fundamental para la comprensión de los siguientes capítulos de esta memoria.

Capítulo 3: la revisión del estado del arte es prioritaria sobre la investigación de un tema. En el presente capítulo se presenta una revisión de literatura en el contexto del campo de la teledetección, en el cual expone una breve descripción de sensores y plataformas, información actual relevante del tema de teledetección y las técnicas que frecuentemente se han usado como alternativa de solución ante los desafíos habituales sobre este campo de estudio.

Capítulo 4 en este capítulo se presenta el trabajo realizado en este proyecto de investigación sobre la metodología de procesamiento de imágenes aéreas, utilizada para la detección de plantas de agave y otras capas de relaciones en campo; se muestra una metodología de procesamiento, identificación y conteo a través de la percepción remota realizada por medio de plataformas UAV de bajo costo.

Capítulo 5 en la sección 5 se aborda la metodología de extracción de características de cuerpos de agua sobre imágenes satelitales presentadas y aplicadas a este proyecto de tesis.

Capítulo 6 por último, se presentan conclusiones finales y líneas de investigación futuras tomando el trabajo en su conjunto y sintetizando sus aportes tanto en teledetección aérea como satelital.

CAPÍTULO 2

Conceptos Básicos de Teledetección

Este capítulo está dedicado a la introducción sobre conceptos básicos de teledetección y de procesamiento de la imagen usados en esta tesis. Este apartado presenta conceptos del campo de la percepción remota a el lector con previo o no antecedente en esta área y este puede ser omitido en caso de que el lector así lo desee.

2.1. Conceptos Generales de Teledetección Usados en esta Tesis

El término teledetección proviene de la traducción del francés *téledétection* en 1967 [138], que fue adoptado por países de habla hispana y debido a la traducción del inglés *remote sensing*. Este término fue implementado por Evelyn Pruitt de la Oficina de Investigación Naval de los Estados Unidos de América (EUA) en 1950.

De manera más restrictiva el término teledetección se reserva a las técnicas de adquisición de información sobre la superficie terrestre y la atmósfera, usando la radiación electromagnética como primer elemento [172].

Definido así, un sistema de teledetección desde el punto de vista de su aplicación se caracteriza por:

- Radiación electromagnética como fuente de información.
- Interacción de la radiación con los objetos de la superficie terrestre.
- Interacción de la radiación con la atmósfera.
- Recepción de las ondas electromagnéticas por los sensores a bordo de una plataforma [180].

2.1.1. Concepto de Longitud de Onda

La luz es una forma de energía electromagnética. La energía electromagnética se describe como una onda sinusoidal armónica que viaja a velocidad luz. La distancia entre 2 crestas consecutivas de esta onda sinusoidal se le llama longitud de onda y se representa con la letra (λ) lambda del alfabeto griego, ver Figura 2.1. Se puede medir en metros o en alguna otra unidad de longitud [152], [189].




Figura 2.1: Longitud de Onda

2.1.2. Espectro Electromagnético

El espectro electromagnético es el conjunto de todas las ondas electromagnéticas posibles [210], se extiende desde las bajas frecuencias usadas para la radio moderna, que son de onda larga, hasta los rayos gamma, los cuales pertenecen a onda corta,

estas longitudes de onda cubren una amplitud entre miles de kilómetros y la fracción del tamaño de un átomo. Ver Tabla 2.1.

A diferencia de otro tipo de onda, como el sonido que necesita un medio para propagarse, la radiación electromagnética se puede propagar en el vacío y su velocidad es de $c = 299,792,458 \text{ m/s}$.

Tabla 2.1: División típica del espectro electromagnético [31].

Rayos Gamma	< 0.03 nm. Radiación absorbida totalmente por la atmósfera superior.
Rayos X	0.03 - 300 nm. Radiación absorbida por los gases en la atmósfera.
Radiación Ultravioleta (UV)	0.30 - $0.38\mu\text{m}$. La región se utiliza en teledetección.
Visible (VIS)	0.38 - $0.72\mu\text{m}$. Es la región sensible para el ojo humano y es visible a película fotográfica y detectores.
Infrarrojo cercano, medio y lejano	$0.72\mu\text{m}$ - $1000\mu\text{m}$ o 1 mm. Región fundamental en los estudios de vegetación.
Microondas	1mm - 30cm. Radiaciones que pueden penetrar en la niebla y nubes y son usadas en sensores como el radar.
Radio	$\geq 30 \text{ cm}$. Se utilizan en transmisiones de radio y redes eléctricas de corriente alterna.

2.1.3. La Radiación Electromagnética.

Se define como la propagación de componentes eléctricos y magnéticos y es afectada por las propiedades de la materia con la cual entra en contacto. James Clerk Maxwell unificó las leyes de la electricidad y el magnetismo en 1860 y propuso que la luz era una forma de radiación electromagnética [172].

“La luz no es solo una onda, sino también una partícula”, Albert Einstein afirmó que la luz es una partícula que contiene energía correspondiente a su longitud de onda. El fotón es la forma física de un quantum, la partícula básica más estudiada en la mecánica cuántica. Con base en la hipótesis cuántica de luz de Einstein, se confirmó la dualidad del fotón en experimentos y exámenes de mecánica cuántica. La radiación electromagnética muestra una naturaleza dual, en la que, bajo las mismas circunstancias, el comportamiento de la radiación es una onda, pero en otro momento se comporta como partícula [177], [144]. Sin embargo, en el mayor de los casos, en

aplicaciones de teledetección, el modelo de onda es más utilizado [76].




Figura 2.2: Investigadores de la *L'École Polytechnique Fédérale de Lausanne* en Suiza han logrado captar, por primera vez, el comportamiento de la luz como onda y partícula [247].

2.1.4. Fuentes de Energía o Iluminación

Cualquier material por encima del cero absoluto, es decir aproximadamente -273°C o 0°K , emite radiación electromagnética y cuánto mayor sea su temperatura, menor será la longitud de la onda emitida [147] [133].

2.1.5. Cuerpo Negro

El sol es la fuente natural de radiación electromagnética y la principal para los sistemas de teledetección. La distribución de la cantidad de radiación no es uniforme en cada longitud de onda ya que la energía emitida en las diferentes regiones del espectro depende de la temperatura de la fuente. En el caso del sol, si ese fuera un emisor perfecto, sería un ejemplo teórico denominado cuerpo negro. Un cuerpo negro transforma la energía calorífica en energía radiante [201]. La Tabla 2.2 muestra los diferentes tipos de cuerpos en función de la emisividad.

Tabla 2.2: En función de la emisividad, los cuerpos pueden dividirse en:

Característica o Tipo	Emisividad (ϵ)	Descripción
Cuerpo negro o radiador perfecto	$\epsilon = 1$	Emisor perfecto
Cuerpo Gris	$0 < \epsilon < 1$	Absorben y emiten de manera constante en diferentes longitudes de onda.
Cuerpo Blanco o Reflector Perfecto	$\epsilon = 0$	No absorbe nada de energía incidente, sino que solo refleja.
Radiador selectivo	$\epsilon \lambda = f \lambda$	Son los más frecuentes en la naturaleza y su emisividad depende de la longitud de onda que se considere.

2.1.6. Interacción Entre la Atmosfera y la Radiación

La más importante fuente de energía es el sol y esta energía tiende a interactuar con la atmósfera terrestre. La atmósfera tiene diferentes efectos sobre la transferencia de ondas del espectro electromagnético. Antes de que la radiación alcance a la superficie de la Tierra, la atmósfera puede tener un profundo efecto sobre la intensidad y composición espectral de la radiación que alcanza un objeto en la superficie. Estos efectos son las principales interacciones que se generan por la atmósfera y son causados por la dispersión, refracción y absorción [107], [65], [187].

Dispersión: ocurre cuando las partículas o grandes moléculas de gas presentes en la atmósfera interactúan con la radiación, la cual tiende a ser refractada o reflejada de su camino original. La dispersión puede dividirse en 3 categorías, dependiendo de la relación entre la longitud de onda de la radiación (λ) y el tamaño de las partículas (ρ) presentes en la atmósfera. La Tabla 2.3 muestra un resumen de los procesos de dispersión de la radiación electromagnética.

- Dispersión de Rayleigh: ocurre cuando las partículas son más pequeñas comparadas a la longitud de onda. Estas podrían ser partículas tales como el polvo, nitrógeno u oxígeno.
- Dispersión de Mie: cuando las partículas tienen el mismo tamaño que la longitud de onda de la radiación ocurre ese tipo de dispersión. El polvo, polen, humo y el vapor de agua son las causas más comunes. La dispersión de Mie ocurre principalmente en las partes más bajas de la atmósfera donde las partículas más grandes son abundantes y además de ello existe afectación por las nubes.
- Dispersión No-Selectiva: este mecanismo de dispersión ocurre cuando las partículas son mucho más grandes que la longitud de onda. Este tipo de dispersión es causado principalmente por polvo, niebla y nubes y lo cual permite aparentar un color blanco a nuestros ojos, debido a que el azul, verde y rojo son dispersados de la misma manera [125].

Tabla 2.3: Principales procesos de dispersión de la radiación electromagnética por la atmósfera [40].

Proceso de dispersión	Dependencia con la longitud de onda	Diámetro (ρ) promedio de las partículas dispersoras	Tipo de partículas
Rayleigh	λ^{-4}	$\frac{\rho}{\lambda} \ll 1$	Moléculas de aire
Mie	λ^0 - λ^{-4}	$\frac{\rho}{\lambda} \approx 0.1$ -10	Humo, neblina y bruma
No-selectiva	λ^0	$\frac{\rho}{\lambda} \gg 10$	Polvo, nubes

Refracción: cuando la luz entra o escapa de un medio, esta es desviada o doblada. Este efecto es llamado refracción y juega un papel fundamental en el estudio de la óptica. La refracción atmosférica tiene lugar cuando la luz pasa a través de capas de diferente humedad, temperatura o luminosidad [187].

Absorción: a diferencia de la dispersión, este fenómeno causa que las moléculas en la atmósfera absorban la energía de diferentes longitudes de onda. El ozono, dióxido de carbono y el vapor de agua, son los principales componentes de la atmósfera y permiten este fenómeno de absorción de la radiación electromagnética [107], [176].

2.1.7. Ventana Atmosférica

Los gases en la atmósfera impiden selectivamente el paso de la radiación electromagnética. La teledetección puede recolectar datos en todas las regiones del EM donde la atmósfera lo permite; a estas zonas del espectro electromagnético donde la transmitancia atmosférica es permeable, se les llama comúnmente *Ventanas Atmosféricas*. Las longitudes de onda que hacen referencia a estas ventanas permiten a los sensores satelitales monitorear la superficie de la Tierra, ver Figura 2.3. Por citar un ejemplo, los sensores con sistemas que operan en el rango del visible VIS y el infrarrojo IR interactúan con los elementos del terreno, básicamente a nivel molecular, ya que la radiación incidente posee energía para excitar electrones. El resultado es la radiación reflejada que va en función de los componentes químicos de la superficie terrestre [172], [53].

Otro ejemplo refiere al rango del VIS, la porción del IR y una buena parte de las ondas de radio, las cuales atraviesan la atmósfera hasta llegar a la superficie terrestre, sin ser reflejadas o absorbidas por ésta. En cambio las radiaciones generadas en la longitud de onda en el rango del ultravioleta son absorbidas en la capa de ozono, mientras que los rayos gamma y los rayos X son absorbidos por las moléculas de nitrógeno y de oxígeno que constituyen la atmósfera del planeta. La Figura 2.3 muestra la clasificación general del rango del espectro electromagnético.




Figura 2.3: Espectro electromagnético, clasificación según el rango de longitud de onda y ventana atmosférica. Propiedad de la atmósfera terrestre de ser permeable a algunas longitudes de onda.

2.1.8. Interacción con la Superficie

Cuando la radiación electromagnética choca con la superficie de la Tierra, esta puede ser reflejada, absorbida o transmitida. La proporción de los efectos de los fenómenos que acabamos de mencionar son determinados por la naturaleza de la superficie, el ángulo de incidencia y su longitud de onda. El principio de conservación de energía es aplicable cuando la radiación electromagnética incide con la superficie de la Tierra.

La radiación que la superficie de la Tierra recibe puede descomponerse en (2.1):

$$E_I(\lambda) = E_R(\lambda) + E_A(\lambda) + E_T(\lambda) \quad (2.1)$$

donde E_I es la energía total incidente, E_R es la radiación reflejada, E_A la radiación absorbida y E_T la radiación transmitida [187], [45]. Cabe señalar que cada parámetro de la ecuación esta en función de la longitud de onda (λ).

La porción de la radiación que es absorbida o transmitida está determinada por aquellos rayos que nunca alcanzan un sensor remoto; sin embargo, el mayor interés de la teledetección se centra en la radiación reflejada desde los objetos que interactúan sobre la superficie de la Tierra.

La reflexión depende de las características de la superficie donde inciden las diferentes longitudes de onda. Si la superficie es lisa, esta actúa como un reflector especular, donde toda o casi toda la radiación electromagnética se dirige lejos de la superficie en una sola dirección. En el caso de una reflexión especular, el ángulo de incidencia es igual al ángulo de reflexión [187]. Ver Figura 2.4(a).




Figura 2.4: (a) Reflexión Especular. (b) Reflexión Difusa o Lambertiana

Cuando la superficie es rugosa en relación con la longitud de onda, esta actúa como un reflector difuso o lambertiano. En este caso, la radiación es dispersada, casi uniformemente, en todas las direcciones [133]. Ver Figura 2.4(b).

2.1.9. Curvas Espectrales

Un concepto fundamental en teledetección es la curva de reflectancia espectral o *firma espectral*. Este término involucra la recolección e identificación de un conjunto de características espectrales de un material u objeto sobre la superficie de la Tierra. El color de una superficie se puede definir por el porcentaje entrante de energía electromagnética que refleja en cada longitud de onda a través del espectro electromagnético. Por ejemplo, una hoja que forma parte de una cobertura vegetal, puede reflejar el 3% de la luz azul entrante, el 10% de la luz verde y el 3% de la luz roja [224]; razón por la cual, a simple vista, se puede observar el color verde en las hojas.

Los detectores de teledetección no registran la reflectancia directamente, sino más bien la radiancia, que es la cantidad de energía electromagnética recibida en las bandas de longitud de onda con rangos específicos [157]. Un cambio de iluminación, como la intensidad solar, por ejemplo, cambiará la radiancia [224]. Las firmas espectrales a menudo se representan como diagramas o gráficos, con longitud de onda en el eje horizontal y la reflectancia en el eje vertical, ver Figura 2.5.

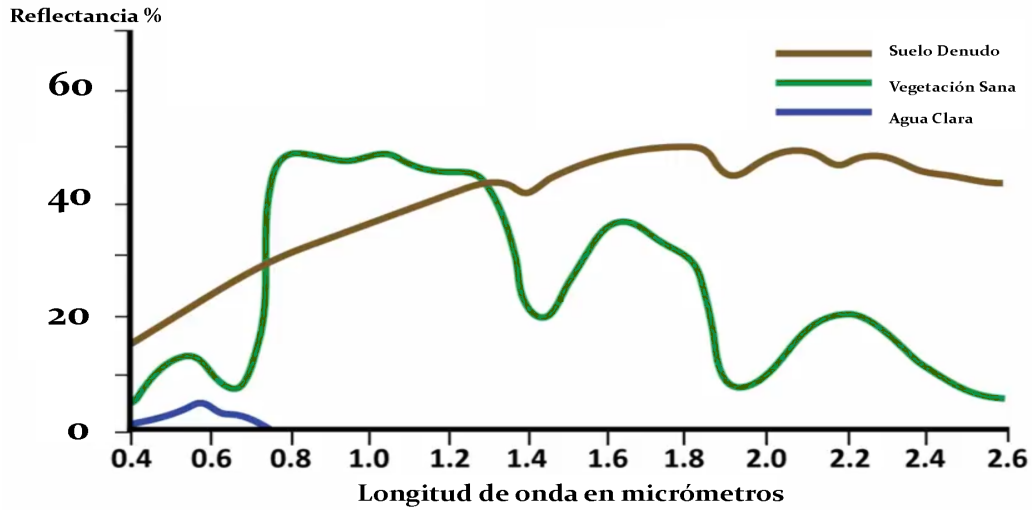


Figura 2.5: Curvas espectrales que representan de manera general suelo, vegetación y agua

Vegetación: la reflectancia espectral en el caso de la vegetación es baja en la porción VIS. Esto se debe a la absorción de clorofila, sin embargo, la reflectancia es alta en el IR cercano debido a la estructura celular de la planta. Dentro del rango del VIS en el espectro electromagnético, hay un pico de reflectancia local en el verde ($0,55 \mu\text{m}$), entre los valles de absorción de clorofila azul ($0,45 \mu\text{m}$) y rojo ($0,68 \mu\text{m}$), ver Figura 2.6(a), también podemos observar una alta reflectancia en el infrarrojo cercano, ver Figura 2.6(b); en este rango, la reflectividad crece notablemente debido a la escasa absorción de las plantas por su estructura fisiológica. También se observa otro cambio en el IR medio entre el $1,4 \mu\text{m}$ y $1,9 \mu\text{m}$, ver Figura 2.6(c); en esta región, el agua contenida en la hoja es la responsable de la baja reflectividad, debido a que en esta parte del espectro el agua presenta un máximo de absorción [224].

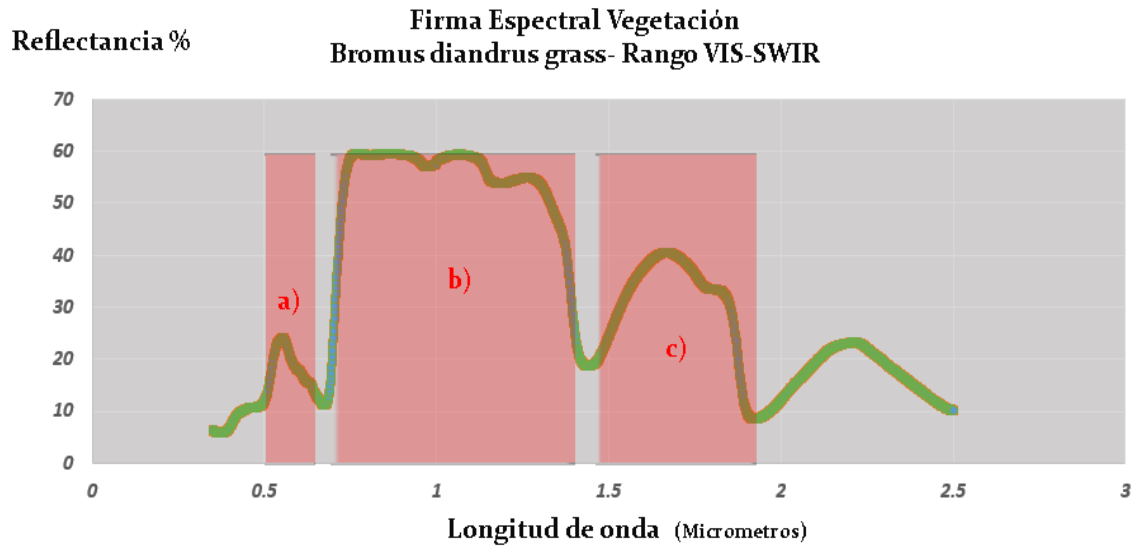


Figura 2.6: Curva Espectral de Vegetación, usando Hyperspectral Infrared Imager o HypsIRI, Fuente en <https://speclib.jpl.nasa.gov/download>

Agua: comparando el agua pura con otros elementos, la vegetación puede reflejar hasta un 50 %, los suelos de un 30 a 40 %, mientras el agua solo refleja hasta un 10 % de la energía incidente [107]. La curva espectral, en este caso del agua es baja en cualquier parte del espectro, aumentando su reflectancia en el rango del VIS, ver Figura 2.7.

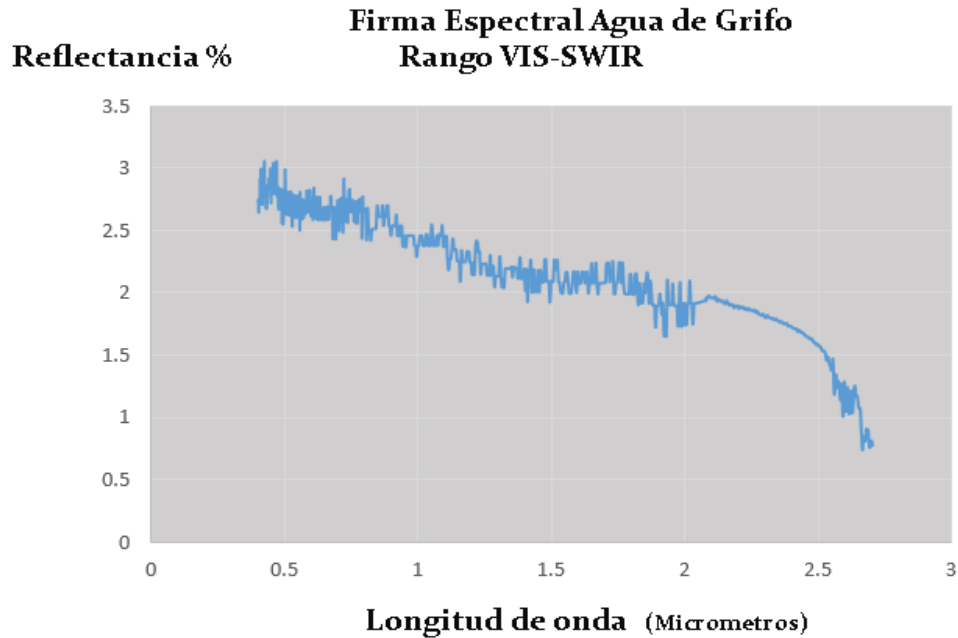


Figura 2.7: Curva Espectral del Agua de Grifo usando Aster Spectral Library, Rango IR - SWIR Datos Provistos de <https://speclib.jpl.nasa.gov/download>

2.1.10. Firmas Espectrales y su Aplicación Real

El conocimiento generado acerca de una curva o firma espectral, se debe tomar en consideración debido a que este conocimiento es muy útil si se está buscando sobre la imagen la relación de un material específico o si desea identificar qué material se representa sobre un píxel en particular. Sin embargo, antes de comparar los datos de la imagen con las firmas espectrales de una biblioteca espectral, se deben tomar en cuenta varios detalles como:

- Los datos obtenidos por sensores, que miden la radiancia por encima de la atmósfera, deberían ser corregidos de efectos atmosféricos y convertirse en reflectancia.
- Las curvas espectrales, que típicamente tienen cientos o miles de bandas espectrales, pueden tener que ser resampladas para que coincidan con los datos de todas las bandas espectrales, ver Figura 2.8.




Figura 2.8: Simulación de bandas en diferentes resoluciones espaciales

- Existe variación sobre una misma curva espectral dentro de un mismo tipo de superficie, es decir, no se presentarán la misma curva, en un tipo de suelo con contenido de materia orgánica o con contenido de hierro, suelos con texturas finas u otras características que pueden generarse en este tipo de superficies.
- Mientras que una librería tiene objetivos conocidos que contienen píxeles puros, un pixel sobre una imagen de teledetección muy a menudo incluye mezcla de píxeles, ver figura 2.9.




Figura 2.9: Simulación de pixel puro y pixel con mezcla de diferentes tipos de texturas

Las firmas espectrales de materiales conocidos son útiles para caracterizarlos. Las curvas de reflectancia espectral para muchos materiales, especialmente minerales, están disponibles en los archivos de referencia en internet llamados librerías espectrales. Los datos en las librerías espectrales se recopilan bajo condiciones controladas, con

un detallado control de calidad y documentados. Se toman estas medidas, debido a que estas son curvas de reflectancia y la reflectancia es teóricamente, una propiedad invariable de un material [224].

Las librerías espectrales más importantes, están disponibles en los siguientes sitios de internet:

- <https://speclab.cr.usgs.gov/spectral-lib.html>
- <https://speclib.jpl.nasa.gov>

2.1.11. Observación de la Tierra

El monitoreo de la superficie de la tierra tiene una larga historia, iniciando con el uso de cámaras en globos y aves en los siglos XVIII y XVIII, sin embargo, en la época actual el termino de percepción remota o teledetección puede remontarse a sistemas de aeronaves, que fueron desarrolladas en el siglo XX [133]. El sistema terrestre es observado de manera continua, sin embargo, la densidad de sistemas de observación satelital operativos en la última década es mayor que en años anteriores. Por esta razón, el volumen de datos es enorme, ya sea de manera gratuita (sistemas Landsat, SPOT, Sentinel) o con costo (sistemas WorldView, Geoeye y Pleiades) [36]. Sin embargo, la capacidad para utilizarlos es bastante limitada, llegando al punto que solo el 10 % de los datos adquiridos es requerido por algún usuario (5 % en el caso de las microondas) [186]. La radiación en el rango del visible y el infrarojo, al interactuar con los elementos del terreno, lo hace básicamente a nivel molecular, ya que posee la energía para excitar electrones de las moléculas del objetivo sobre la superficie terrestre. Por otro lado, cuando las microondas interactúan con el terreno, lo hacen con los componentes del objetivo del tamaño de la longitud de onda [186], [172].

Aunque existen numerosos sistemas de teledetección capaces de recolectar información, todos estos sistemas se pueden clasificar en 2 categorías:

Pasivos: estos sistemas miden la energía que esta naturalmente disponible. Los sistemas pasivos, utilizan al sol como fuente de energía, y miden la porción de la energía emitida por esta fuente, luego de interactuar con los elementos de la superficie terrestre y con la atmósfera [133].

Los valores registrados se almacenan como números enteros, conocidos numero digital (ND), su formato depende de la resolución radiométrica del sensor.

Activos: los sistemas activos, emplean una fuente de radiación artificial, estos sistemas emiten energía y miden la retrodispersión del terreno, en las longitudes de onda del visible y las microondas. Por ejemplo, LIDAR (Laser Imaging Detection and Ranging), RADAR (Radio Detection And Ranging), scatterómetros [133].

2.1.12. Sensores Remotos y Plataformas

Existe una amplia variedad de sensores remotos utilizados para la observación de la Tierra, en este campo se ha mostrado un importante desarrollo tecnológico en el campo de la teledetección, lo cual ha permitido al ser humano ampliar su capacidad de observación. Nuevos y modernos sensores han permitido capturar la luz no-visible, por mencionar la ultravioleta e infrarroja y detectar radiaciones como los rayos X y gamma [39].

Un sensor remoto en el campo de la teledetección, permite adquirir datos que pueden ser imágenes tipo raster u otro tipo de información analógica o digital; que contienen características de la superficie terrestre y sus elementos con los cuales interactúa, captados a través de la emisión y reflexión de energía electromagnética [153].

Al hablar acerca de una plataforma, estamos describiendo el lugar donde se coloca o monta el sensor remoto para obtener una visión o panorama de una escena. A medida que la plataforma de observación se coloca a mayor distancia del objetivo, la visión de conjunto crece, refiriéndonos a un panorama más amplio, pero el grado de detalle se hace menor [39].

Los sensores remotos han sido un generador valioso de información en los diversos campos de la teledetección. Las características que más se destacan en el análisis de un sensor remoto son las de resolución temporal, espacial, espectral y radiométrica.

2.1.13. Resolución

En general, el termino resolución en teledetección, se refiere a la capacidad de un instrumento de registrar, discriminar y localizar información a detalle. Se basa en las diferencias de radiación obtenidas y teniendo en cuenta el detalle de captura, la cantidad de bandas en las que trabaja y las variaciones existentes para diferentes períodos de tiempo.

La resolución no solo depende del tamaño de pixel, sino que puede estar influenciada por el contenido de la imagen y por factores como la geometría, contraste del objeto, resolución radiométrica, iluminación, claridad de la atmosfera o el efecto de pixeles vecinos [138]. En esta sección se presentan los conceptos de resolución espacial, espectral, temporal y radiométrica, conceptos fundamentales en el campo de la teledetección [157].

Resolución Espacial: una imagen digital consiste en un arreglo de pixeles, donde cada pixel contiene información acerca de un área determinada. La resolución espacial se expresa en unidades de longitud e indica cuanto mide el pixel, ver Figura 2.10 (a) y (b). Esto significa que cuanto menor es esta medida, el pixel contiene mayor detalle sobre el objeto correspondiente en la superficie terrestre. La resolución espacial varía en función de la distancia del sensor y el ángulo de observación.




Figura 2.10: Ejemplo la imagen (a) pertenece a un dispositivo UAV su resolución espacial corresponde a 3 cm. La imagen (b) pertenece a una plataforma satelital con una resolución espacial de 50 cm.

Los 3 principales parámetros de interés relativos a la geometría de la imagen son la resolución espacial, el campo de visión (FOV) y el campo de visión instantáneo (IFOV). La resolución espacial y el FOV dependen fuertemente de la altitud de vuelo, mientras que el IFOV es constante [155]. Los detalles discernibles en una imagen son dependientes de la resolución espacial del sensor, Chuvieco refiere al término de resolución espacial como la capacidad de identificar los objetos más pequeños que pueden ser detectados sobre una imagen [44]. En la Tabla 2.4 podemos observar cómo es clasificada la resolución espacial.

Tabla 2.4: Clasificación de imágenes, según su resolución espacial [60]

Resolución Espacial (m)	Tipo de resolución
< 1	muy alta
1-5	alta
5-20	media
20-50	baja
>50	muy baja

La resolución espacial es uno de los términos más importantes en teledetección y puede ser medida por su distancia de muestra en el terreno o ground sampling distance (GSD), este termino es expresado en la ecuación 2.2, [155].

$$GSD = p/f * H \quad (2.2)$$

Donde p es el tamaño de pixel, f es la longitud focal y H es la altitud del satélite[97].

El FOV, es normalmente expresado como el ángulo cónico por el cual la radiación incidente es enfocada a un dispositivo de carga acoplada (charge-coupled device, CCD)[148]. La resolución espacial en los sensores pasivos, depende principalmente de su IFOV, este se define como la sección angular, medida en radianes o el área sobre la superficie de la tierra en la cual, en un instante, son observados y recolectados datos en una celda de un detector. La resolución espacial de un sensor pasivo depende principalmente de su IFOV [23]. La resolución espacial en la superficie varía en función de la distancia del satélite y el ángulo de observación relativo a Nadir. De esta manera, cabe mencionar, que el tamaño de pixel en una escena es variable, incrementándose conforme nos alejamos del punto nadir del sensor satelital [88], ver Figura 2.11 (a) y (b).

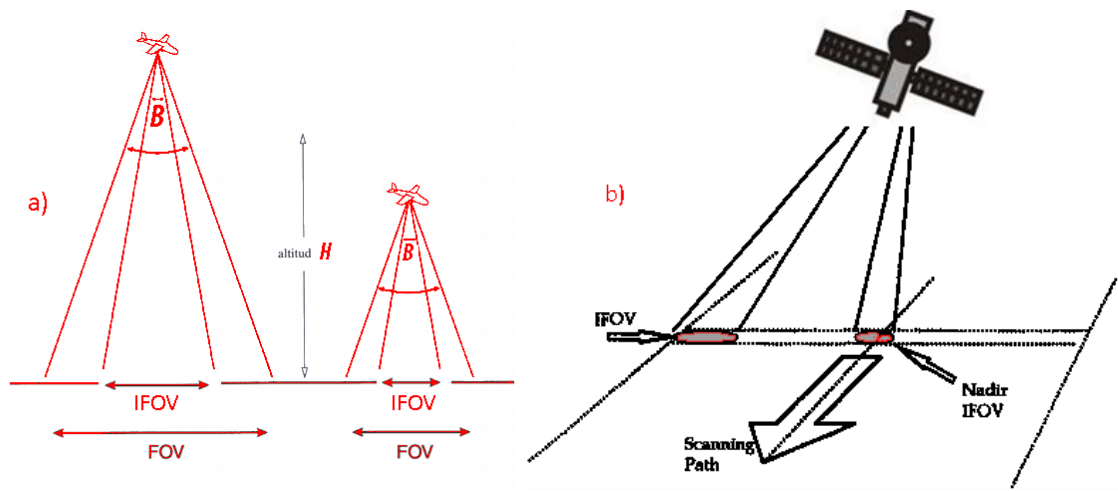


Figura 2.11: (a) Relación FOV-IFOV. (b) Tamaño de pixel nadir, off-nadir, se puede observar el incremento.

Resolución Espectral: la resolución espectral está relacionada con el número de bandas espectrales en los que el sensor recolecta datos, también hace referencia al rango espectral correspondiente a dichas bandas. Cuanto mayor sea el número de bandas disponibles, mejor será la caracterización de los objetivos presentes en el área de interés [45], [39].

La resolución espectral se puede definir como la capacidad de un sensor para resolver la energía recibida en un ancho de banda espectral para caracterizar diferentes componentes de la superficie de la Tierra. Cuanto más fina sea la resolución espectral, más estrecho será el rango de longitud de onda para una banda en particular. Cabe señalar que las características de la superficie se pueden distinguir mejor, de bandas con rangos estrechos a diferencia de una sola banda con un rango espectral ancho, ver Figura 2.12.

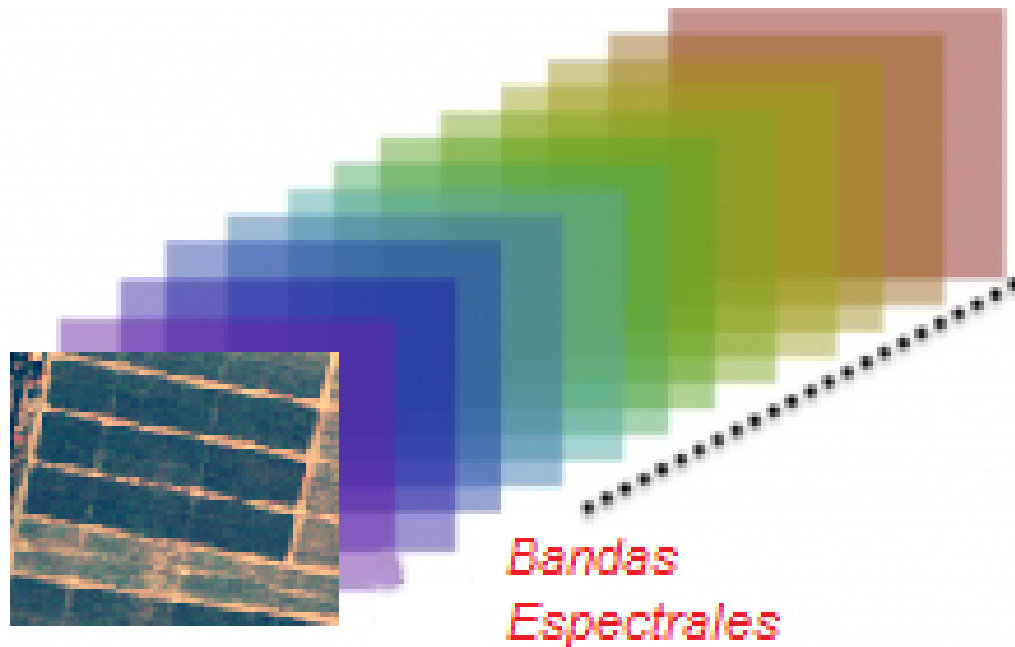


Figura 2.12: Arquitectura de imagen multispectral.

Resolución Radiométrica: se refiere a la sensibilidad a la que responde un sensor, entendiéndose ésta como la capacidad de detectar variaciones en los valores de la radiación espectral que recibe. La resolución radiométrica, viene habitualmente limitada por el número de bits utilizado para codificar los valores de radiancia. La resolución radiométrica de un sistema de imágenes describe su capacidad para discriminar diferencias muy pequeñas en energía. Cuanto más fina es la resolución radiométrica de un sensor, más sensible es para detectar pequeñas diferencias en la energía reflejada o emitida [45].

Las computadoras almacenan información usando ceros y unos, un bit a menudo hace referencia a la cantidad de variaciones tonales que se pueden mostrar o almacenar, en una celda raster, utilizando una serie de ceros y unos. Los valores que toma un pixel se nombran tonos y representan la medida de energía sensedada en correspondencia con la cantidad de bits que puede considerar el sensor (resolución radiométrica, profundidad) [133]. Por lo tanto, una imagen de 16 bits por banda contiene más profundidad que una de 8 bits, debido a que 8 bits permite 256 valores tonales diferentes, mientras que 16 bits permite 65.536 valores por banda, ver Figura 2.13.




Figura 2.13: Imágenes satelitales capturadas con diferente resolución radiométrica. Se muestra que mientras mayor es el número de bits por pixel, es posible observar mayor número de detalles.

Resolución Temporal: el concepto permite conocer la periodicidad de cobertura de una órbita entera en el caso de los satélites o una revisita en el caso de un dispositivo aéreo. El ciclo de cobertura está en función de las características de la plataforma, como son velocidad, inclinación y altura, así como del diseño del sensor, principalmente del ángulo de observación y abertura.

La resolución temporal es un factor importante para detectar cambios. Entre estas observaciones de cambio se encuentran ejemplos como el cambio climático, los peligros naturales, la urbanización, la deforestación y climas [45].

Por último, algunos autores destacan una relación inversa entre los aspectos relacionados con la resolución; Chuvieco [45] considera, que, a mayor resolución espacial, disminuye habitualmente la temporal y es previsible que se reduzca también la resolución espectral y radiométrica. El autor menciona que el problema se encuentra en la transmisión de las imágenes a la superficie terrestre, en este caso refiriéndose a satélites. También habla acerca del incremento considerable del volumen de datos que tanto el sensor como la unidad receptora tiene que procesar. Sin embargo, con el desarrollo actual de la tecnología en sensores, equipos informáticos y vehículos aéreos no tripulados, esto está cambiando.

2.1.14. Tipos de Órbita en Satélites

La órbita de un satélite determinar cuál es su recorrido. Para un instrumento o sensor a bordo de un satélite, el tiempo de visita depende de la órbita del satélite, así como también el barrido del sensor, a través del cual graba los datos observados que

capta a través de su recorrido.

Si bien existen órbitas especiales diseñadas para propósitos específicos, dos clases generales de órbitas se han utilizado ampliamente para la observación y monitoreo de la Tierra: órbitas geoestacionarias y órbitas polares [3], ver Figura 2.14.




Figura 2.14: Tipos de Órbitas

Órbita Polar: como su nombre indica, las órbitas polares pasan sobre las regiones polares de la Tierra de norte a sur. La órbita polar es una órbita con un ángulo de inclinación entre 80° y 100° . Esta órbita es capaz de observar toda la tierra y acercarse muy bien a los polos, este tipo de satélites orbitan a alturas que van desde 200 km a 1000 km. Los satélites de la NOAA son un ejemplo claro de este tipo de orbita [107]. Este tipo de órbita permite el estudio de la dinámica de procesos, fenómenos naturales y recopila información sobre el estado de los territorios en la superficie del planeta [32].

Órbita Sun-Sincrona: esta orbita Sun-Sincrona se mueve de tal manera que el satélite siempre pasa por encima de un punto sobre la tierra a la misma hora del día. Una órbita Sun-Sincrona esta típicamente inclinada aproximadamente 8° con respecto a los polos. Este tipo de orbitas se caracterizan por cruzar el ecuador a media mañana, un momento en el cual el ángulo solar es bajo y el resultado son pocas sombras sobre la imagen. Las órbitas Sun-Sincrona se utilizan principalmente para el sensado remoto, con el objetivo de monitorear, estudiar y vigilar los recursos de la Tierra. Los satélites Landsat y SPOT, Worldview, Geoeye, etc., tienen este tipo de órbitas. Las altitudes habitualmente utilizadas están entre 600 km y 800 km, produciendo un período orbital de aproximadamente 100 minutos [32], [3].

Órbita Geoestacionaria: este tipo de órbita hace referencia a satélites que se mueven sobre una órbita ecuatorial, con un ángulo de inclinación de 0° y una altitud de 36.000 km. Sobre esa distancia, el periodo orbital del satélite es igual al periodo de rotación de la tierra, el resultado de este movimiento genera que el satélite pueda mantenerse en un mismo punto sobre la tierra de manera continua. Por tomar un ejemplo, de este tipo de satélites, los sensores meteorológicos y de comunicaciones tienen órbitas geoestacionarias [3].

2.1.15. Principio de Funcionamiento de un Sensor

Se utilizan dos tipos de escáner para recolectar datos espectrales que son reflejados o emitidos por la superficie terrestre. Cada escáner cuenta con un número determinado de detectores los cuales, en un instante dado, cada detector a lo largo de su línea de escaneo, es capaz de capturar la energía reflejada o emitida de una pequeña área de la superficie de la tierra. A continuación, mencionan ambos tipos de escáner.

Sensor de barrido o whiskbroom: es un escáner de espejos giratorios u oscilantes que se utiliza para explorar el terreno en una serie de líneas llamadas líneas de exploración, que forman ángulos rectos con respecto a la línea de vuelo. A medida que la plataforma avanza, se escanean líneas sucesivas generando una serie de franjas contiguas. El escáner mide de forma continua la energía de un lado al otro de la plataforma y genera una imagen en 2 dimensiones, ver Figura 2.15(a).




Figura 2.15: (a) Sensor de barrido o whiskbroom, realiza repetidas mediciones a través de una línea de barrido entre A y B. (b) Sensor de empuje o pushbroom, el espejo escanea por medio de una línea de barrido entre A y B. (c) Un arreglo de detectores de estado sólido (CCD). Fuente “Computer Processing of Remotely-Sensed Images: An Introduction” por Paul M. Mather, Magaly Koch, p. 3, John Wiley & Sons. Derechos de autor 2011, [133].

Sensor de empuje o pushbroom: los escáneres de seguimiento también utilizan un movimiento frontal hacia la plataforma, para grabar sucesivas líneas de escaneo y construir una imagen en 2 dimensiones, perpendicular a la dirección de vuelo, ver Figura 2.15(b), [133]. Sin embargo, este escáner no utiliza espejos de escaneo, sino que una matriz lineal de detectores, registra simultáneamente la energía recibida de múltiples celdas a lo largo de la línea de escaneo. Esta matriz lineal está constituida típicamente por numerosos dispositivos de carga acoplada o charge-coupled device (CCD), ver Figura 2.15(c).

2.1.16. Escala

Escala y resolución han sido cuestiones claves en la teledetección. Debido al rápido desarrollo de la cartografía y la percepción remota se ha forzado a los temas de escala y resolución a ser tratadas de una manera más formal y ser mejor definidas [118]. Existe mucha confusión referente al término “Escala” por lo que es necesario identificar el significado de la palabra.

“La Escala representa una ventana a la percepción del mundo real, la capacidad de observación y de manera muy cuidadosa, debe ser elegida en temas de teledetección” [232].

Por otro lado, extensión y detalle son parte fundamental en una imagen digital y se

seleccionara según el objetivo de estudio y las características que se quieren observar [229]. Esta relación es fundamental para seleccionar una escala. La comunidad científica, investigadores, así como usuarios de la información espacial se enfrentan frecuentemente al interrogante de definir a qué escala sería y adecuada para presentar la información extraída con determinados sensores.

En este apartado se realizan algunas recomendaciones básicas que se deberían tener en cuenta para la interpretación de las representaciones gráficas resultante del procesamiento de la información espacial.

Tomando como referencia el IFOV [232], las imágenes digitales proporcionadas por varios sensores en teledetección, se manejan en diferentes escalas cartográficas. Como una guía, *JA Richards*, en su libro “*Remote sensing digital image analysis*” [176], sugiere una comparación de escalas sobre datos de imágenes digitales, en la cual se relaciona la escala cartográfica con el tamaño de pixel, ver Tabla 2.5.

Tabla 2.5: Comparación de escalas en datos de imágenes digitales [176].

Escala (metros)	Tamaño de pixel (metros)	Sensor
1: 10,000	1	Ikonos Banda pancromática
1: 50,000	5	Vuelo aéreo, MSS, Ikonos
1: 100,000	10	SPOT, HGR
1: 250,000	25	SPOT, HRVIR, Landsat TM
1: 500,000	50	Landsat TM, LISS
1: 5,000,000	500	OCTS, OCM
1: 10,000,000	1000	NOAA, AVHRR, MODIS
1: 50,000,000	5000	GMS Bandas infrarojas

2.2. Conceptos de Imagen en Teledetección Usados en esta Tesis.

En esta sección se incluyen conceptos de la imagen digital que utilizamos en esta investigación.

2.2.1. Modo de la Imagen

Normalmente los sensores a bordo de un satélite adquieren las imágenes en diferentes modos, estos son:

Imagen Pancromática: la imagen pancromática se capta mediante un sensor que a menudo adquiere luz visible con una longitud de onda en el rango típico de 0.50 y 0.80 μm . Un sensor que capta imágenes pancromáticas produce imágenes con mucha finura y permite recolectar la intensidad total de la radiación que cae en cada pixel generando datos pancromáticos que se representan por medio de una imagen en blanco y negro, ver Figura 2.16 [166].



Figura 2.16: Imagen WorldView-2, 50cm GSD. Las características de los objetos en la imagen, se pueden observar con mayor facilidad, esto es debido a la resolución espacial que tiene la imagen pancromática..

Imagen multispectral: un sensor multispectral adquiere simultáneamente múltiples imágenes de la escena en una banda espectral o rango de longitud de onda. El procedimiento de formación de la imagen digital se repite para cada una de las bandas generándose como resultado final una matriz multidimensional en la que cada valor del ND, de cada pixel está ubicado en una fila, una columna y una banda [89], ver Figura 2.17.




Figura 2.17: Imagen WorldView-2, GSD 2m. Imagen de alta resolución de 8 bandas multispectrales.

Imagen hiperespectral: un sensor hiperespectral, recolecta imágenes de una escena de manera simultánea en cientos de rangos espectrales contiguos, inherentemente el registro se basa sobre las longitudes de onda del rango de ultravioleta

cercano hasta el infrarrojo cercano. Lo más interesante de este tipo de imágenes es que es capaz de proveer una fina identificación de materiales que se encuentran en la superficie de la tierra y es usualmente utilizada en una variedad de aplicaciones de percepción remota incluyendo geología, suelos, océanos, vegetación, atmosfera, etc. [166].

Imagen fusionada o pan-sharpened: con disponibilidad de resoluciones, temporalidad, frecuencia y sensores disponibles de satélites y aeronaves que observan la tierra, la imagen, ha ganado ser una herramienta invaluable en la teledetección.

Fusión de imagen es definida, como el proceso de combinar múltiples imágenes de entrada en una sola imagen compuesta, esto ayuda a tener una mejor descripción de la escena que cualquier provista antes de ser fusionada [139].

La fusión de imágenes se puede utilizar como una herramienta para aumentar la resolución espacial. El procedimiento a seguir, se genera a través de imágenes pancromáticas de alta resolución, que se fusionan con datos de imágenes multi-espectrales de baja resolución. De esta manera, la resolución espectral se puede preservar mientras se incorpora una resolución espacial más alta que representa el contenido de información de las imágenes con mucho más detalle, ver Figura 2.18 [161].



Figura 2.18: Imagen WorldView-2, 50cm GSD. Imagen de alta resolución fusionada, a simple vista se pueden observar las mejoras en la imagen.

2.2.2. Niveles de Procesamiento de la Imagen por Satélites y Aeronaves

Satélites y aeronaves, provén imágenes en diferentes niveles de procesamiento. Entre estos se encuentra el procesamiento radiométrico y el procesamiento geométrico [15]. El procesamiento radiométrico consiste en convertir el ND en unidades físicas como la distancia del sensor, radiancia o reflectancia [38]. El procesamiento geométrico

consiste en realizar el registro temporal y espectral de todas las imágenes tomadas sobre cualquier objetivo. Para alcanzar este objetivo, el modelo geométrico físico asocia una dirección de visualización a cualquier píxel, el cual debe ser refinado de acuerdo con una referencia absoluta [15]. Tomando en cuenta, que cada sensor genera sus propios datos y estos a su vez, también generan sus propias notaciones y algoritmos de procesamiento a continuación, se muestra de manera general, como se puede clasificar el nivel de procesamiento de una imagen.

Level 0: datos crudos, sin un procesamiento radiométrico, ni geométrico. La mayoría de las agencias espaciales o empresas comerciales no distribuyen imágenes Level 0.

Level 1A: datos radiométricamente corregidos. Los operadores de satélites intentan igualar las respuestas en el detector a través de una serie de coeficientes de calibración radiométrica los cuales son esenciales para la corrección de imágenes. Usualmente los parámetros de calibración son calculados antes del lanzamiento, en un laboratorio.

Level 1B: datos radiométricamente y geométricamente corregidos. Otro error inherente que se genera sobre los datos recolectados por un detector son la geometría de la imagen. Considerando el momento de la capturan los datos, se debe tomar en cuenta que el sensor se encuentra en movimiento sobre la superficie de la Tierra y esta a su vez está girando debajo del satélite. Debido a este movimiento, la vista del sensor puede ser considerablemente más oblicua hacia las orillas de la toma, que directamente a nadir, todas estas variaciones crean distorsión sobre la geometría de la imagen. Todas estas distorsiones también son medibles y se pueden aplicar correcciones para mejorar sus cualidades geométricas.

Level 2: escenas orto-rectificadas. Posicionamiento espacial preciso sobre los datos recolectados, los datos requieren la interacción con el usuario a través de un proceso llamado corrección geométrica o rectificación de la imagen, este proceso es a través del registro de la imagen en un mapa base, seleccionando puntos par, mejor conocido como puntos de control. Los niveles de procesamiento pueden ser ordenados según el estudio a realizar o necesidades específicas, los niveles de procesamiento anteriormente mostrados, son aplicables a satélites tales como Landsat, Sentinel y SPOT [162], [165].

En los temas de esta investigación que se presentan en esta memoria, se ha utilizado el nivel 1A, escenas que han sido radiométricamente corregidas.

2.2.3. Formatos de Imagen

Casi todos los satélites captan imágenes utilizando sensores digitales que funcionan según los mismos principios que las cámaras digitales, es decir, con los mismos elementos constitutivos en conjunto con tecnología y avanzada óptica. Al igual que una cámara digital un sensor cuenta con miles detectores que mide la cantidad de

radiación electromagnética que es reflejada por la superficie terrestre, estos datos son capturados por los sensores y se registran con un ND. Los formatos de almacenamiento pueden ser:

Raster: corresponden a una matriz de miles de registros llamados píxeles. Cada pixel le corresponde a una cobertura del área estudiada, el pixel contiene una sola unidad de información que representa la firma espectral dominante para el área correspondiente en la superficie de la tierra. Una resolución de 8 bits, donde cada píxel contiene un valor entero y donde, 0 = negro y 255= blanco, es común. Sin embargo, en una imagen de color natural, hay un valor de 8 bits para rojo, un valor de brillo de 8 bits para verde y un valor de 8 bits para azul. Por lo tanto, cada píxel en una imagen en color requiere 3 valores separados para almacenarse en el archivo. Las estructuras típicas de grabación y consulta de las imágenes digitales en teledetección:

- BIP (secuencial por pixel o Band Interleaved by Pixel). El valor rojo para el primer píxel se escribe en el archivo, seguido del valor verde para ese píxel, seguido por el valor azul para ese píxel, y así sucesivamente para todos los píxeles de la imagen.
- BIL (secuencial por líneas o Band Interleaved by Line). Todos los valores rojos para la primera fila de píxeles se escriben en el archivo, seguidos de todos los valores en verde para esa fila seguidos de todos los valores azules para esa fila, y así sucesivamente para cada fila de píxeles en la imagen.
- BSQ (secuencial por bandas o Band Sequential). Todos los valores rojos para toda la imagen se escriben en el archivo, seguidos de todos los valores en verde para toda la imagen, seguidos de todos los valores azules para toda la imagen [135], ver Figura 2.19.

Ortoimagen: se refiere a una imagen de una zona de la superficie terrestre, en la que un alto porcentaje de los elementos, presentan una escala homogénea; en teoría está libre de errores y deformaciones. En ella se combinan las características de detalle de una fotografía aérea con propiedades geométricas similares a las de un plano cartográfico fotogramétrico. El resultado mantiene toda la información de la imagen aérea, permitiendo además medir a escala, tanto distancias como superficies [35].

La ortoimagen se entrega en una variedad de formatos, ya sean comprimidos o no comprimidos. Los más comunes son TIFF y JPG. En cualquier caso, también se debe proporcionar información de georreferenciación. Los formatos de imagen TIFF y JPG pueden acomodar información de georreferencia, ya sea insertada en el archivo de imagen en sí, como en el caso de GeoTIFF, o como un archivo separado para cada imagen, como en el caso de TIFF con un archivo TFW (TIFF world file). La información de georreferencia le dice al software de información geográfica (SIG), el tamaño de un píxel, dónde colocar una esquina de la imagen en el mundo real y si la imagen se rota con respecto al sistema de coordenadas de tierra.

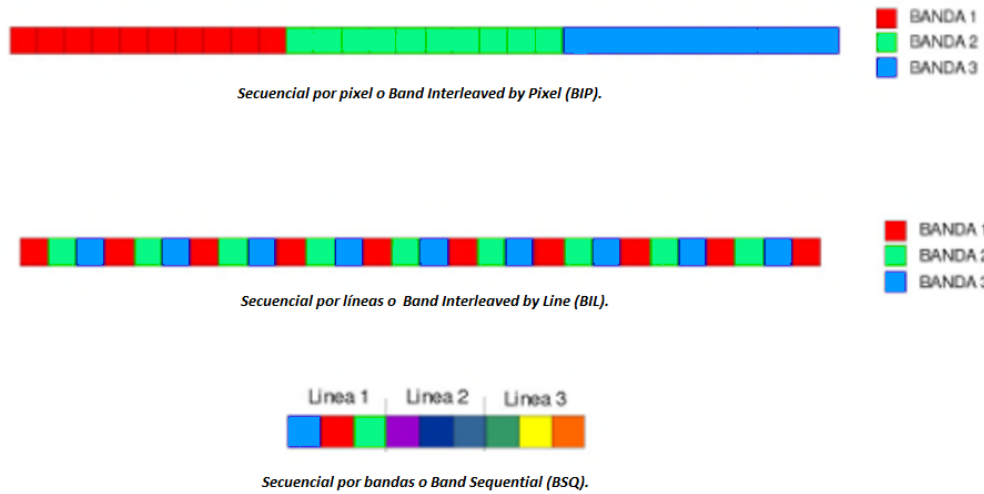


Figura 2.19: Grabación y Acceso de las Imágenes Digitales en Teledetección. Fuente “Georreferenciación de Cartografía: Datos Raster y Vectoriales” por Fernando J Sanchez Menendez, p. 53, EOSGIS SL. Derechos Reservados.2004-2009 [135].

Estado del Arte y Revisión de Literatura

El presente capítulo presenta la revisión del estado del arte de las tecnologías de teledetección de última generación. Está dedicada a abordar la historia de esta disciplina, además el tipo de información que se puede obtener de cada plataforma, metodología, adquisición de la misma, características de los datos obtenidos por medio de cada sensor, resoluciones, escalas, sus usos prácticos, requisitos especiales en la obtención y generación de datos sobre plataformas aéreas y satelitales.

3.1. Satélites

La humanidad ha visto la necesidad de documentar el espacio que lo rodea de una manera primordial. Un ejemplo se muestra en lo que podría llamarse el más antiguo mapa que ha sobrevivido hasta nuestros días. Este fue grabado en un bloque de piedras que ha permanecido por más de 13.000 años, ver Figura 3.1. El mapa mencionado, según investigadores, puede representar una plan para un próxima cacería o una historia que ya había sucedido; sin embargo, esta representación afirma la importancia de estar enterado sobre el lugar en el cual se habita y lo que sucede al alrededor [216], [108] .

La teledetección es la técnica que ha permitido en épocas modernas captar esa realidad que nos rodea, cuya función primordial es medir y adquirir información sin un contacto directo.




Figura 3.1: El mapa de Abauntz ubicado en Navarra España es considerado como el mapa más antiguo conocido en Europa Occidental. En *A palaeolithic map from 13,660 calBP: engraved stone blocks from the Late Magdalenian in Abauntz Cave, Navarra, España* por P. Utrilla, 2009, Journal of Human Evolution, ELSEVIER, 57(2):99–111. Derechos de autor 2009, [216].

3.1.1. Reseña Era Landsat

En Octubre de 1957, el satélite Sputnik es lanzado exitosamente por la URSS. Este hecho marca una pauta acerca del inicio de un serie de lanzamientos de misiones militares y civiles que tenían como objetivo la exploración del planeta. En la década de los 50, las computadoras emergen como una herramienta indispensable en la gestión y el procesamiento de datos, la cual se vuelve hasta nuestros días, un objeto fundamental en la manipulación de información a gran escala. Por último, siendo no menos importante, surge la tecnología de reconocimiento de patrones, la cual se vincula con la capacidad de extraer información que permita establecer propiedades de o entre conjuntos de objetos para discriminar diferentes características lo cual permite la entrada a la emulación de las habilidades humanas, entre ellas la visión [146]. Estos 3 desarrollos, equipos informáticos potentes, reconocimiento de patrones y el nacimiento de la era espacial permiten el surgimiento de una nueva época, la era de la teledetección, la cual tuvo que esperar a que se unieran esta serie de eventos para ganar su enorme relevancia [120], [230], ver Figura 3.2.

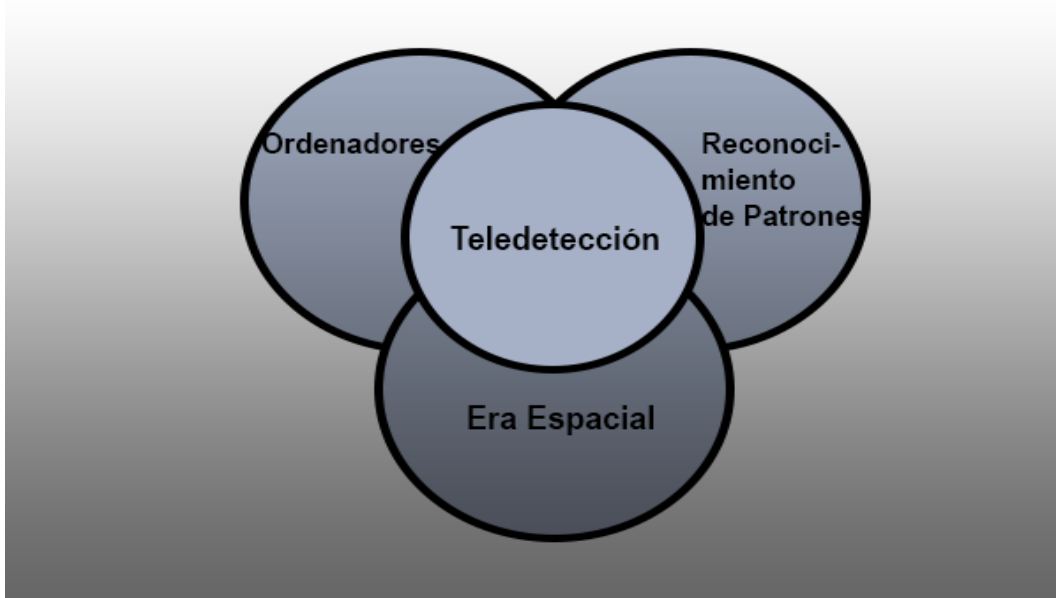


Figura 3.2: Desarrollos que dan comienzo al Inicio de la era en Teledetección.

Después del golpe que provocó la URSS sobre los EUA al haber lanzado el satélite Sputnik, el impacto de la noticia no hizo esperar una respuesta por parte de los Estados Unidos. Esta respuesta fue el surgimiento de el *National Aeronautics and Space Act* en 1958 (NASA).

El primer satélite de observación terrestre diseñado por la NASA fue TIROS I, pionero en observación meteorológica, que fue lanzado el 1 de abril de 1960 desde Cabo Cañaveral, Florida, Estados Unidos. TIROS I fue el primer satélite meteorológico,

lanzado con el objetivo principal de demostrar la viabilidad de utilizar cámaras de televisión para observar la cobertura de nubes de un satélite [115].

El primer satélite de la serie Landsat puesto en órbita, se lanzó en Julio de 1972 y posicionó a los Estados Unidos como líder mundial en teledetección. El nombre de este satélite fue *Earth Resources Technology Satellite* - ERTS (más tarde renombrado como Landsat 1). Esta misión fue pionera en la recolección de imágenes sobre la superficie de la Tierra [57] [214].

Es probable que nadie pueda determinar cuándo o dónde se originó la idea de Landsat, porque la idea seguramente evolucionó con el tiempo y provenía de muchas fuentes diferentes. Sin embargo, el interés de la comunidad científica ha crecido en magnitud tal, que los estudios desarrollados gracias a las imágenes de PR sobre satélites se pueden contar por miles.

El programa Landsat no se enfocó en un principio en áreas ecológicas o de biología, ya que la recolección de datos estuvo dirigida inicialmente a usos agrícolas y geológicos y en menor medida, a la silvicultura [120].

La constelación Landsat se puede dividir en dos grupos. En la primera parte podemos incluir a los satélites Landsat 1, 2 y 3 que llevan dos sistemas de sensores: el *Return Beam Vidicon* (RBV) y el *Multispectral Scanner System* (MSS). El sistema RBV sobre Landsat 1 y 2 era multiespectral con tres cámaras, mientras que el satélite Landsat 3 usaba solo dos cámaras en modo pancromático.

La segunda parte incluye los sistemas Landsat 4,5,6,7 y 8, debido a que estos sistemas omiten el sensor RBV, pero aún cuentan con escáners multiespectrales [207].

El 17 de Julio de 1984, la Ley Pública 98-365 del Gobierno de los Estados Unidos, hace responsable a la *National Oceanic and Atmospheric Administration* (NOAA), de la gestión para transferir el programa Landsat al sector de la industria privada. En 1985 la compañía EOSAT recibe los derechos para vender productos de Landsat 4 y 5 por un período de 10 años con el compromiso de desarrollar y participar en la construcción de 2 nuevos satélites. Sin embargo, durante esa década, se encuentran con diversos problemas al haber numerosos tropiezos en la gestión del programa y costos muy altos de los datos, pero un problema fundamental, fue la falla al no colocar exitosamente al Landsat-6 en la órbita de la Tierra [230].

El fracaso de Landsat 6 y el dudoso éxito de la gestión privada, sembró temor por el futuro de la constelación Landsat y, en el año de 1992, la Ley Pública 102-555 de EUA, devuelve la gestión del programa Landsat al gobierno y, con ello, se asegura la continuidad del programa. El 15 de abril de 1999, se lanza el satélite Landsat 7. Esta plataforma cuenta con un sensor *Enhanced Thematic Mapper Plus* (ETM+) que se diferencia con respecto a Landsat 5 por la inclusión de una banda pancromática. En este satélite se consolida la participación de las agencias federales: NASA que es responsable del desarrollo y lanzamiento del satélite, NOAA que se encarga de su operación y mantenimiento durante la vida del sensor y *United States Geological Survey* (USGS) que se encarga de recolectar, procesar y distribuir los datos del satélite [214]. La disponibilidad de datos acerca de la superficie terrestre obtenida de manera remota a partir de información satelital u otro tipo de plataformas aéreas ha generado una auténtica revolución en la generación de datos. Pero, de manera histórica, cabe señalar que los datos obtenidos de forma remota han seguido una serie de etapas

marcadas por la evolución de los sensores a bordo para la observación del planeta. En la historia de la observación de la Tierra, el programa Landsat debe considerarse el más importante, ya que ha proporcionado datos multispectrales con media resolución espacial y una alta resolución espectral durante casi 50 años, lo que representa el registro obtenido más largo de información sobre la superficie terrestre de forma global y multitemporal desde el espacio, ver Tablas 3.1 y 3.2.

3.1.2. Adquisición de Imágenes de Landsat (Fuentes):

El criterio para seleccionar una imagen satelital o el tipo de sensor que se va a utilizar en un proyecto varía de acuerdo a las necesidades de los usuarios. Se debe tomar en cuenta el tipo de proyecto, los requerimientos de monitoreo, el presupuesto de la investigación, tiempo estimados de revisita del sensor, la accesibilidad a las imágenes, la capacidad de procesamiento y la gestión de los datos [84]. Para la adquisición de



Figura 3.3: Algunas plataformas gubernamentales y civiles actualmente en uso.

imágenes existen diferentes opciones, desde las que son de acceso libre, hasta aquellas que se debe pagar por un licenciamiento para su uso, ver Figura 3.3.

Las imágenes de acceso libre tales como Landsat pueden ser descargadas directamente de páginas de distribución oficial y con diferentes niveles de procesamiento en prácticamente todos los países del mundo.

Para obtener más información sobre la constelación Landsat y sus productos podemos consultar en:

<https://landsat.usgs.gov/index.php>

<https://landsat.gsfc.nasa.gov/>

<https://earthexplorer.usgs.gov/>

<https://glovis.usgs.gov/>

3.1.3. Satélites de Muy Alta Resolución

Debido a la necesidad fundamental de alcanzar una mayor precisión y resolución sobre las imágenes obtenidas a partir de satélites, surgen en el mercado los satélites comerciales de muy alta resolución (*Very High Resolution*, VHR).

Recientes lanzamientos de satélites de observación de la Tierra, tienen la capacidad de capturar imágenes VHR; esto es, a nivel sub-métrico. Tomando en cuenta que las imágenes de satélite VHR se encuentran en el rango de gama media a baja sobre la resolución de imágenes aéreas digitales, siempre se ha buscado la opción de sustituir las clásicas imágenes aéreas que se utilizan para la obtención de cartografía a gran escala, por imágenes satelitales, lo cual abre una amplia posibilidad en la generación de dicha cartografía [77], [43]. Ver Tabla 3.3.

Escala (metros)	Tamaño de píxel (metros)	Sensor
1: 10,000	1	Ikonos Banda pancromática
1: 50,000	5	Vuelo aéreo, MSS, Ikonos
1: 100,000	10	SPOT, HGR
1: 250,000	25	SPOT, HRVIR, Landsat TM
1: 500,000	50	Landsat TM, LISS
1: 5,000,000	500	OCTS, OCM
1: 10,000,000	1000	NOAA, AVHRR, MODIS
1: 50,000,000	5000	GMS Bandas infrarrojas

Tabla 3.3: Comparación de escalas en datos de imágenes digitales [176]

Una resolución *alta* sobre un píxel, se encuentra en el rango de 1-5 m, como se mencionó en el Capítulo 2, en la Tabla 2.4. Mientras que una imagen VHR entra en la categoría de un píxel sub-métrico, donde cada píxel de la imagen representa un área inferior a un metro cuadrado en el suelo.

Existen numerosas aplicaciones que trabajan sobre datos satelitales, como mapeo de carreteras [236], detección de edificios [77], detección de invernaderos [6] y monitoreo de cambios en desastres naturales [8], [43]. En tales casos, las tasas de revisita cortas y de muy alta resolución espectral son clave para responder a muchas preguntas.

Las continuas mejoras en los sensores, así como la gran cantidad de datos de satélites

Satélite	Sensor	Banda	Resolución Espacial	Tiempo Operativo
Landsat 1	Return Beam Vidicon (RBV)	(Cam1) 475-575 nm, (Cam2) 580-680 nm (Cam3) 690-830 nm	Sistema RBV 1-3 80m	23-07-1972 al 05-08-1972
	Multispectral Scanner (MSS)	(B4) 0.5 to 0.6 μm , (B5) 0.6 to 0.7 μm (B6) 0.7 to 0.8 μm , (B7) 0.8 to 1.1 μm	Bandas MSS 4-7 80m	
Landsat 2	Return Beam Vidicon (RBV)	(Cam1) 475-575 nm, (Cam2) 580-680 nm (Cam3) 690-830 nm	Sistema RBV 1-3 80m	22-01-1975 al 27-07-1983
	Multispectral Scanner (MSS)	(B4) 0.5 to 0.6 μm , (B5) 0.6 to 0.7 μm (B6) 0.7 to 0.8 μm , (B7) 0.8 to 1.1 μm	Bandas MSS 4-7 80m	
Landsat 3	Return Beam Vidicon (RBV)	(Cam1), (Cam2) Pancromática (B4) 0.5 to 0.6 μm , (B5) 0.6 to 0.7 μm (B6) 0.7 to 0.8 μm , (B7) 0.8 to 1.1 μm (B8) 10.4 to 12.6 μm	Sistema RBV 1-2 40m	05-03-1978 al 07-09-1983
	Multispectral Scanner (MSS)	(B1) 0.5 to 0.6 μm , (B2) 0.6 to 0.7 μm (B3) 0.7 to 0.8 μm , (B4) 0.8 to 1.1 μm (B1) 0.45 - 0.52 μm , (B2) 0.52 - 0.60 μm (B3) 0.63 - 0.69 μm , (B4) 0.76 - 0.90 μm (B5) 1.55 - 1.75 μm , (B6) 10.40 - 12.50 μm (B7) 2.08 - 2.35 μm	Bandas MSS 1-4 80m Bandas TM 1-5 y 7 30 m Banda Thermal TM 6 120 m	16-07-1982 al 14-12-1993
Landsat 4	Multispectral Scanner (MSS)	(B1) 0.5 to 0.6 μm , (B2) 0.6 to 0.7 μm (B3) 0.7 to 0.8 μm , (B4) 0.8 to 1.1 μm (B1) 0.45 - 0.52 μm , (B2) 0.52 - 0.60 μm (B3) 0.63 - 0.69 μm , (B4) 0.76 - 0.90 μm (B5) 1.55 - 1.75 μm , (B6) 10.40 - 12.50 μm (B7) 2.08 - 2.35 μm	Bandas MSS 1-4 80m Bandas TM 1-5 y 7 30 m Banda Thermal TM 6 120 m	16-07-1982 al 14-12-1993
	Thematic Mapper (TM)	(B1) 0.5 to 0.6 μm , (B2) 0.6 to 0.7 μm (B3) 0.7 to 0.8 μm , (B4) 0.8 to 1.1 μm (B1) 0.45 - 0.52 μm , (B2) 0.52 - 0.60 μm (B3) 0.63 - 0.69 μm , (B4) 0.76 - 0.90 μm (B5) 1.55 - 1.75 μm , (B6) 10.40 - 12.50 μm (B7) 2.08 - 2.35 μm	Bandas MSS 1-4 80m Bandas TM 1-5 y 7 30 m Banda Thermal TM 6 120 m	01-03-1984 al Enero-2013
Landsat 5	Multispectral Scanner (MSS)	(B1) 0.5 to 0.6 μm , (B2) 0.6 to 0.7 μm (B3) 0.7 to 0.8 μm , (B4) 0.8 to 1.1 μm (B1) 0.45 - 0.52 μm , (B2) 0.52 - 0.60 μm (B3) 0.63 - 0.69 μm , (B4) 0.76 - 0.90 μm (B5) 1.55 - 1.75 μm , (B6) 10.40 - 12.50 μm (B7) 2.08 - 2.35 μm	Bandas MSS 1-4 80m Bandas TM 1-5 y 7 30 m Banda Thermal TM 6 120 m	01-03-1984 al Enero-2013
	Thematic Mapper (TM)	(B1) 0.5 to 0.6 μm , (B2) 0.6 to 0.7 μm (B3) 0.7 to 0.8 μm , (B4) 0.8 to 1.1 μm (B1) 0.45 - 0.52 μm , (B2) 0.52 - 0.60 μm (B3) 0.63 - 0.69 μm , (B4) 0.76 - 0.90 μm (B5) 1.55 - 1.75 μm , (B6) 10.40 - 12.50 μm (B7) 2.08 - 2.35 μm	Bandas MSS 1-4 80m Bandas TM 1-5 y 7 30 m Banda Thermal TM 6 120 m	01-03-1984 al Enero-2013

Tabla 3.1: Historia Landsat [213], [214].

Satélite	Sensor	Banda	Resolución Espacial	Tiempo Operativo
Landsat 6	Enhanced Thematic Mapper (ETM)	(B1) 0.45 - 0.52 μm , (B2) 0.52 - 0.60 μm (B3) 0.63 - 0.69 μm , (B4) 0.76 - 0.90 μm (B5) 1.55 - 1.75 μm , (B6) 10.40 - 12.50 μm (B7) 2.08 - 2.35 μm , (B8) 0.52 - 0.90 μm	Bandas ETM 1-5 y 7 30m Banda Thermal 6 120m Banda Pancromática TM 6 15m	05-10-1993 La misión no se colocó en órbita
Landsat 7	Enhanced Thematic Mapper Plus (ETM+)	(B1) 0.45 - 0.52 μm , (B2) 0.52 - 0.60 μm (B3) 0.63 - 0.69 μm , (B4) 0.77 - 0.90 μm (B5) 1.55 - 1.75 μm , (B6) 10.40 - 12.50 μm (B7) 2.08 - 2.35 μm , (B8) 0.52 - 0.90 μm	Bandas ETM+ 1-5 y 7 30m Banda Thermal 6 60m Banda Pancromática TM 6 15m	15-04-1999 al Presente
Landsat 8	Operational Land Imager (OLI) Thermal Infrared Sensor (TIRS)	(B1) 0.43 - 0.45 μm , (B2) 0.450 - 0.51 μm (B3) 0.53 - 0.59 μm , (B4) 0.64 - 0.67 μm (B5) 0.85 - 0.88 μm , (B6) 1.57 - 1.65 μm (B7) 2.11 - 2.29 μm , (B8) 0.50 - 0.68 μm (B9) 1.36 - 1.38 μm <hr/> (B10) 10.6 - 11.19 μm , (B11) 11.5 - 12.51 μm	Bandas OLI 1-7 y 9 30m Banda Pancromática TIRS 8 15m Bandas 10-11 100m	Febrero-2013 al Presente
Landsat 9	Operational Land Imager-2 (OLI-2) Thermal Infrared Sensor-2 (TIRS-2)	(B1) 0.43 - 0.45 μm , (B2) 0.450 - 0.51 μm (B3) 0.53 - 0.59 μm , (B4) 0.64 - 0.67 μm (B5) 0.85 - 0.88 μm , (B6) 1.57 - 1.65 μm (B7) 2.11 - 2.29 μm , (B8) 0.50 - 0.68 μm (B9) 1.36 - 1.38 μm <hr/> (B10) 10.6 - 11.19 μm , (B11) 11.5 - 12.51 μm	Bandas OLI-2 1-7 y 9 30m Banda Pancromática 8 15m Bandas TIRS 1-2 100m	Lanzamiento programado para Diciembre del 2020

Tabla 3.2: Historia Landsat [213], [214].

disponibles, han ayudado a expandir de manera ilimitada las aplicaciones de imágenes satelitales y las posibilidades en su aplicación cada vez aumentan más.

En junio del 2014, la empresa DigitalGlobe anunció que recibió una notificación del Departamento de Comercio de los EUA, sobre un requerimiento que se solicitó para permitirle a la compañía vender sus imágenes satelitales de la más alta calidad y colocarlos como líderes de la industria.

A DigitalGlobe se le permitió ofrecer a sus clientes las imágenes de mayor resolución disponible de su constelación actual. 31 centímetros de resolución espacial de los satélites comerciales WorldView-3 y 4, son las resoluciones más altas disponibles en este momento, ver Tabla 3.4 y 3.5. Sin embargo, se están haciendo esfuerzos para disminuir este límite en los próximos años. Negociaciones actualizadas permitirán a la compañía DigitalGlobe en un futuro próximo vender imágenes a todos sus clientes a una resolución espacial de hasta 25 cm en imagen pancromática y 1 metro multiespectral [64].

3.1.4. Comparación Entre las Plataformas, Aérea y Satelital

Históricamente, las técnicas de análisis de datos obtenidos por teledetección han seguido una serie de etapas marcadas por la evolución en los instrumentos de observación. En etapas tempranas, los medios de observación remota se caracterizaban por estar montados sobre plataformas exclusivamente espaciales, por lo que las técnicas de análisis derivadas se basaron en enfoques fundamentalmente diseñados para datos espaciales.

Existen aeronaves de varios tipos, las cuales proporcionan plataformas excepcionalmente convenientes y operacionalmente flexibles para su uso en teledetección. Estos dispositivos de vuelo pueden contar con cargas útiles (payload), que van desde algunos gramos en el caso de UAVs a toneladas, como es el caso de los satélites. Una adecuada elección de la plataforma en conjunto con el rango de altitudes, puede cubrir desde unas pocas decenas de metros, donde los efectos de propagación atmosférica son generalmente insignificantes, hasta miles de metros.

Las principales ventajas y desventajas de las plataformas de teledetección, cuando se realiza una comparación son:

- Una aeronave puede adquirir datos a muy baja altitud, pero su resolución espacial es muy alta, lo cual se traduce a una percepción total de las características de los objetos, sin embargo, en un estudio a gran escala, utilizar estas aeronaves es muy complicado por la extensión de áreas.
- La cobertura de datos espaciales desde un satélite, puede trabajar por mucho tiempo, lo que se traduce a la recolección de datos de manera continua por años.
- Una misión sobre una aeronave, únicamente puede durar horas, en comparación con una plataforma satelital que dura años.
- Económicamente hablando, coleccionar datos desde una aeronave es más barato

Satélite	Resolución Espacial (m)	Numero de bandas	Lanzamiento
WorldView 4	Pancromática: 0.31 m Multiespectral: 1.24 m	Pancromática: 450 - 800 nm 4 Multiespectral: Red:655 - 690 nm, Green:510 - 580 nm Blue:450 - 510 nm, Near-IR:780 - 920 nm	11/11/2016
WorldView 3	Pancromática: 0.31 m Multiespectral: 1.24 m SWIR: 3.70 m CAVIS: 30.00 m	Pancromática: 450-800 nm Multiespectral: Coastal 400 - 450 nm, Blue 450 - 510 nm, Green: 510 - 580 nm, Yellow 585 - 625 nm, Red 630 - 690 nm, Red Edge 705 - 745 nm, Near-IR1 770 - 895 nm, Near-IR2 860 - 1040 nm Short-wavelength infrared, (SWIR): SWIR-1 1195 - 1225 nm, SWIR-2 1550 - 1590 nm, SWIR-3 1640 - 1680 nm, SWIR-4 1710 - 1750 nm SWIR-5 145 - 2185 nm, SWIR-6 2185 - 2225 nm SWIR-7 2235 - 2285 nm, SWIR-8 2295 - 2365 nm Clouds, Aerosols, Vapors, Ice, and Snow, (CAVIS) Desert Clouds 405 - 420 nm, Aerosol-1 459 - 509 nm Green 525 - 585 nm, Aerosol-2 620 - 670 nm Water-1 845 - 885 nm, Water-2 897 - 927 nm Water-3 930 - 965 nm, NDVI-SWIR 1220 - 1252 nm Cirrus 1350 - 1410 nm, Snow 1620 - 1680 nm Aerosol-3 2105 - 2245 nm, Aerosol-3 2105 - 2245 nm	13/08/2014
WorldView 2	Pancromática: 0.46 m Multiespectral: 1.84 m	Pancromática: 450 - 800 nm Multiespectral: Coastal Blue 400-450 nm, Blue 450-510 nm Green 510-580 nm, Yellow 585-625 nm Red 630-690 nm, Red-Edge 705-745 nm NIR1 770-895 nm, NIR2 860-1040 nm	08/10/2009

Tabla 3.4: Satélites de muy alta resolución (VHR) actualmente operando.

Satélite	Resolución Espacial (m)	Numero de bandas	Lanzamiento
WorldView 1	Pancromática: 0.50 m	Pancromática: 400 - 900 nm	18/09/2007
GeoEye-1	Pancromática: 0.46 m Multiespectral: 1.84 m	Pancromática: 450 - 800 nm Multiespectral: Blue: 450 - 510 nm, Green: 510 - 580 nm Red: 655 - 690 nm, Near Infra 780 - 920 nm	06/09/2008
Pleiades-1A y 1B	Pancromática: 0.50 m Multiespectral: 2.0 m	Pancromática: 480-830 nm Multiespectral: Blue 430-550 nm, Green 490-610 nm Red 600-720 nm, Near Infrared 750-950 nm	1A 16/12/2011 1B 02/12/2012
QuickBird	Pancromática: 0.65 m Multiespectral: 2.62 m	Pancromática: 450-900 nm Multiespectral: Blue 450-520 nm, Green: 520-600 nm Red 630-690 nm, Near IR: 760-900 nm	18/10/2001

Tabla 3.5: Satélites de muy alta resolución (VHR) actualmente operando.

que desde una plataforma satelital, sin embargo, en términos de velocidad y cobertura un satélite es óptimo en la recolección de datos.

- Es una enorme ventaja el usar satélites para teledetección, pero también se plantean cuestiones muy fuertes e interesantes, tales como seguridad, ética, moral e implicaciones legales, cuestiones debido al hecho de que las leyes de la dinámica orbital no respetan las fronteras.

3.2. Detectores

3.2.1. Dispositivo de Carga Acoplada, CCD

George Smith and Willard Boyle fueron los creadores del dispositivo de carga acoplada CCD en los laboratorios Bell en el año de 1969. La intención inicial era crear un nuevo tipo de memoria para ordenadores y al mismo tiempo desarrollar cámaras de estado sólido para video teléfonos. Estos investigadores imaginaron la estructura básica del CCD, definieron sus principios de funcionamiento y describieron las aplicaciones, incluidas las imágenes y la memoria. Para el año 1970, Laboratorios Bell presenta la primera video cámara en estado sólido y en 1975 presentan al mundo la primera cámara CCD con una calidad lo suficientemente nítida para la televisión abierta. En el año 1983, los telescopios emplean por primera vez cámaras de estado sólido, el CCD revoluciona el mundo de los astrónomos permitiendo estudiar miles de objetos muy débiles, los cuales a través de placas fotográficas no podían captar. Hoy en día todos los observatorios ópticos, incluido el Telescopio Espacial Hubble, se basan en sistemas de información digital construidos a través de detectores CCD ultrasensibles a la luz, lo mismo ocurriendo en la observación satelital de la tierra [162].

Los primeros CCDs que se colocaron en órbita fueron los que se introdujeron en la carga útil de las 2 sondas Rusas Vega, lanzadas en 1984 con el fin de obtener imágenes del núcleo del cometa Halley en 1986. La Agencia Espacial Europea (ESA), continuó trabajando con sensores CCD en la nave espacial Giotto, también para el estudio del cometa Halley. El desarrollo de CCDs para aplicaciones espaciales se remonta al año 1974, cuando bajo el patrocinio de la NASA, el Jet Propulsión Laboratory (JPL), emprendió un programa para desarrollar matrices de CCD, para la misión Galileo a Júpiter, lanzada en 1989 y el telescopio espacial Hubble (HST), lanzado en 1990, hoy en día el detector CCD es el dispositivo usado por excelencia, sobre las longitudes del VIS y el ultravioleta, en los campos de teledetección planetaria y terrestre[95].

El CCD es un dispositivo semiconductor, que consiste en su forma más simple (en el orden de 1000) de elementos idénticos en una matriz lineal. Cada uno de estos elementos es sensible a la luz, lo cual permite almacenar cargas como resultado de la iluminación. Un CCD puede ser construidos en 1 y 2 dimensiones, en forma plana y lineal y usualmente este tipo de detectores han estado dominando el área de la teledetección por mucho tiempo[184].

Un CCD consiste en un arreglo de pequeñas celdas fotosensibles sobre las cuales incide radiación. Cada celda del CCD genera una carga eléctrica la cual varía dependiendo

de la intensidad de la radiación incidente. El arreglo entero forma un área de pixeles que agregan datos, los cuales pueden ser procesado por una computadora.

3.2.2. Detector CCDs y Adquisición de la Imagen

Un detector individual (cero dimensional), trabaja por medio de un espejo que escanea a través de la trayectoria del satélite, captando fotones en un solo detector que recolecta datos un pixel a la vez, ya que el movimiento hacia el frente de la plataforma puede proporcionar exploración en una sola dirección. La forma habitual de lograr este escaneo es a través de un espejo giratorio u oscilante, que escanea el campo de visión instantáneo (IFOV) de un lado a otro, en una dirección aproximadamente perpendicular al avance, ver Figura 3.4(a).

Un instrumento que opera según este principio se suele llamar *line scanner* y el modo de operación a menudo se denomina *whiskbroom imaging*. Es de uso generalizado para los instrumentos aerotransportados y espaciales, por ejemplo, los instrumentos del Landsat TM y ETM+.

En el caso de una matriz lineal de detectores, este escaneo se puede lograr usando el movimiento de la plataforma. Una tira de pixeles, orientada perpendicularmente a la dirección del movimiento, se visualiza instantáneamente, y la tira adyacente de pixeles se visualiza cuando la plataforma se ha movido una distancia igual al ancho de los pixeles. Este modo de obtención de imágenes a menudo se llama *pushbroom imaging*. Este tipo de sensor está incluido en la carga útil del satélite SPOT, y el nombre del sensor a bordo es HRV (high resolution visible), ver Figura 3.4(b).

Un detector duo-dimensional tal como un CCD de matriz plana, rectangular, típicamente llamado *step-stare*, es un dispositivo sensible a la detección de fotones que corresponden a un rango de longitudes de onda, lo cual genera una carga eléctrica en relación al número de fotones capturado en cada pixel. Debido a esta acción, la carga es medida y digitalizada para construir una imagen bidimensional. Todo lo que se necesita para garantizar que el detector visualice la escena, es tomar el tiempo suficiente para adquirir y procesar suficientes fotones. Este tipo de sensor es ideal para obtener imágenes de áreas locales más pequeñas o de puntos de distribución aleatoria que requieren alta resolución. La constelación Space-Based Infrared System (SBIRS) cuenta con un sensor *step-stare*, el principal objetivo de este satélite es detectar misiles balísticos lanzados desde submarinos, ver Figura 3.4(c), [114], [172].




Figura 3.4: Detectores y modos de adquisición de la imagen

3.2.3. Semiconductor Complementario de Óxido Metálico

El semiconductor complementario de óxido metálico (CMOS), en tecnologías de imagen es el más importante desarrollo desde la invención del CCD. Los sensores de imagen CMOS explotan la misma tecnología del chip de silicio, utilizadas en los sistemas de microprocesadores. Este hallazgo se debe a la naturaleza de la tecnología CMOS, ya que muchos millones de transistores se pueden integrar a un solo circuito de silicio, esto presenta la oportunidad de integrar una gran variedad de píxeles, cada uno con su propio fotodiodo y transistores de lectura.

Los sensores CMOS ya se utilizan en dispositivos espaciales y tienen aplicaciones en la instrumentación del satélite, tales como rastreadores de estrellas e inspección de cámaras. CMOS aún no tiene un impacto significativo en la carga útil de los dispositivos científicos, por lo cual el CCD mantiene su dominio.

Las principales ventajas de CMOS sobre CCD para la instrumentación en el espacio es su capacidad de compactación, baja masa y funcionamiento con bajo voltaje. El CCD permanece sin competencia en el rango dinámico y precisión fotométrica. Los efectos de la radiación espacial en los detectores CMOS y CCD son similares, debido a que ambos sufren efectos por la radiación ionizante.

Los sensores CMOS desempeñarán sin duda un papel cada vez más importante en la carga útil de una nave espacial, pero hoy en día es más probable que aparezcan

en aplicaciones que tienen limitaciones de tamaño, masa o potencia extremas, aplicaciones que requieren modos operativos complejos como el acceso aleatorio a píxeles, o en aquellas misiones para las cuales el daño por radiación a un CCD prueba ser insuperable [114].

Resumiendo, los detectores basados en la tecnología CMOS han ganado considerable interés. Los detectores CMOS funcionan a un voltaje más bajo que los CCD, lo que reduce el consumo de energía para aplicaciones portátiles. Cada celda de sensor de píxel activo CMOS tiene su propio amplificador de búfer y puede ser direccionado y leído individualmente.

La tecnología CMOS es ventajosa para la adquisición de imágenes de color y falso color. De hecho, una de las principales diferencias entre la tecnología CCD y CMOS es la generación de imágenes en color. Usando chips CCD se pueden usar diferentes técnicas para obtener imágenes en color. Uno de los más populares es el uso de un procedimiento de interpolación junto con un mosaico de pequeños filtros de color colocados sobre la matriz de detectores citepoli2005. Sin embargo, esto afecta la calidad de la imagen resultante.

El dinero y la atención concentrados en los detectores CMOS significan que su rendimiento continuará mejorando, borrando finalmente la línea entre la calidad de imagen CCD y CMOS. Pero en el futuro, los CCD y CMOS seguirán siendo complementarios, debido a que cada uno puede proporcionar beneficios que el otro no puede.

3.3. Vehículos Aéreos No Tripulados

Comparando la teledetección satelital y aérea, el vehículo aéreo no tripulado (VANT), UAV (del inglés unmanned aerial vehicle) o comúnmente dron, ha generado expectativas muy altas, expectativas que lo convierten en un campo muy activo en la actualidad. Específicamente, el UAV se puede desplegar de manera rápida, frecuente y eficaz para satisfacer los requisitos de un monitoreo rápido y de bajo costo, en un entorno funcional y definido por el usuario [205]. En esta sección se discute la evolución y el estado del arte del uso de UAVs en el campo de la fotogrametría y la teledetección (Photogrammetry and Remote Sensing, PaRS), [52].

Como plataforma de teledetección, los UAVs ofrecen a la comunidad científica un nivel de accesibilidad y flexibilidad sin precedentes en la generación de datos [106]. Un sensor a bordo de un UAV adquiere imágenes más finas que las de un satélite VHR lo que genera imágenes con una resolución centimétrica [73], las cuales pueden capturar detalles muy puntuales de objetos sobre la superficie de la tierra. En comparación con las aeronaves pilotadas, el UAV ofrece un sistema mucho más seguro y rentable para la adquisición de datos, esto debido a que las imágenes adquiridas por una aeronave pilotada dependen en gran medida de las condiciones atmosféricas, tiempos de vuelo y las gestiones de los sistemas aéreos, sin embargo en el caso de los UAVs aplicado en el área de PaRS, los cuales son abordados de una manera más amplia a lo largo del Capítulo 4 de esta tesis, pueden trabajar a menor altitud que los aviones pilotados, dando como resultado una resolución espacial incomparable [52], [150].

El comúnmente llamado Drone, se sujeta a varios nombres tales como, UAV (Unmanned Aircraft Vehicle), UAS (Unmanned Aircraft System), RPAS (Remotely-Piloted Aerial System), siendo los dos primeros, términos usados por la Federal Aviation Administration (FAA). El termino UAS fue adoptado por el Department of Defense de EUA (DOD) y la Civil Aviation Authority (CAA) en Inglaterra. *El término UAV se usa comúnmente en ciencias de la computación, robótica e Inteligencia artificial, así como en las comunidades de fotogrametría y teledetección* [68] y el termino RPAS (Remotely-Piloted Aerial System) fue presentado oficialmente por la International Civil Aviation Organization (ICAO), este último caracterizado por el hecho de que únicamente los RPAS pueden ser integrados en el sistema internacional de aeronáutica civil, además los RPAS solo pueden volar hasta los 400 ft o 120 mtrs, sobre el nivel del suelo (Above Ground Level). El termino AGL es uno de los parámetros más importantes en vuelo, el cual se refiere a la altitud que determina el tamaño del pixel sobre una imagen [55], [52], [137], [170].

3.3.1. Desarrollo de Aeronaves

El principal objetivo detrás del desarrollo de las aeronaves ha sido siempre la velocidad y la seguridad en la trasportación de las personas [73]. El área militar pronto se dio cuenta de los beneficios potenciales de las aeronaves no tripuladas, tales sistemas en un principio fueron direccionados como sistemas para transportar misiles o pequeñas bombas [55].

El primer UAV fue creado por el americano Lawrence and Sperry en 1916 y su uso fue direccionado principalmente al área militar, no se observó su potencial en mapeo hasta la década de los setentas, y se tomó en cuenta que no había mucho entusiasmo en la parte académica, esto debido a el limitado número de publicaciones y conferencias [87]. Sin embargo, las compañías de servicios y visionarios tecnológicos voltearon a observar las necesidades de los usuarios e iniciaron con una cruzada dirigida hacia las autoridades de aviación civil para abrir sus mentes hacia este potencial comercial y de investigación [200], [52].

A principios de la década de 1960, la Fuerza Aérea operaba vehículos aéreos no tripulados para la National Reconnaissance Office NRO, el más famoso UAV de uso militar es el Predator [87], [67].

El desarrollo de los vehículos aéreos no tripulados comenzó a fines de la década de 1950; aprovechando la guerra de Vietnam, la investigación y el desarrollo de estas aeronaves se continuo a gran escala en la década de 1970 [67]. Después de la Guerra de Vietnam, los Estados Unidos de América e Israel comenzaron a desarrollar UAVs más pequeños y más baratos. Estos eran pequeños aeronaves que adoptaban motores reducidos como los que se usan en motocicletas. Llevaban a bordo cámaras de video y transmitían imágenes a la ubicación del operador, el prototipo del presente UAV se puede encontrar durante este período. Durante la Guerra del golfo, los EUA adaptaron el uso de los UAV en la guerra en 1991, a partir de este evento, este tipo de aeronaves se desarrollaron para aplicaciones militares de manera exponencial [87].

Actualmente no existe una clasificación común de los UAVs que sea ampliamente

aceptada [68], [218], debido a la amplia variedad de capacidades, tamaño y características operativas de los diferentes sistemas. La mayoría de los UAVs se describen en términos de peso, resistencia y altitud, propósito de uso, etc. La clasificación o categorización que en esta tesis se adoptó acorde a la clasificación de UAVs, fue la realizada por Suraj G. Gupta, [87], [218] y la podemos observar en la Tabla 3.6.

Categoría	Peso Máximo (Kg)	Altitud Normal de Funcionamiento	Máximo Alcance de la Misión (Radio)
Micro	< 2 Kg	Hasta 400 ft AGL	5 Km
Mini	2 - 20 Kg	Hasta 3000 ft AGL	25 Km
Small	20 - 150 Kg	Hasta 5000 ft AGL	50 Km
Tactical	150 - 600 Kg	Hasta 10000 ft AGL	200 Km
Male	> 600 Kg	Hasta 45000 ft AGL	Depende de la capacidad de combustible. Sin Limite
Hale	> 600 Kg	Hasta 65000 ft AGL	Depende de la capacidad de combustible. Sin Limite
Strike	> 600 Kg	Hasta 65000 ft AGL	Depende de la capacidad de combustible. Sin Limite

Tabla 3.6: Clasificación por categorías de UAVs.

3.3.2. Integración de un UAV

Computadora de vuelo / Sistema de Control: la computadora de vuelo es el cerebro de la aeronave. Permite el enlace de datos de 2 vías a través de señales de radio para control remoto o con navegación GPS, conectado a un sistema de control de la aeronave. El control remoto de vuelo integra un sistema de radio, el operador recibe datos de vuelo del UAV y envía los comandos de vuelo de regreso [20].

Actuadores: los motores o multirrotores que propulsan la aeronave, los variadores, que son circuitos electrónicos que sirven para controlar la velocidad de giro de

los motores, así como su dirección, además de servir como freno dinámico para éstos; el Inertial Measurement Unit, IMU que es un dispositivo capaz de medir y reportar tanto la velocidad de la aeronave, así como su orientación y las fuerzas gravitacionales que actúan sobre ella, son actuadores y según la morfología del UAV los actuadores se adaptarán a la aeronave [238], [14].

Sensores: el sensor se usa para proporcionar una funcionalidad básica que es la capacidad de mantener un vuelo continuo, el radar, la cámara, los escáneres son los más comunes. Algunos UAV, más sofisticados, llevan una combinación de diferentes tipos de sensores, dentro de su módulo de carga útil (Payload) o dentro de una serie de módulos [14]. Los datos de estos sensores pueden procesarse e integrarse para proporcionar información a la computadora de vuelo, esta información se puede transmitir a través de un enlace a la estación de control u otro destino, según corresponda [87].

Los UAVs Self-thinking siguen siendo una opción futurista [20], sin embargo, con los adelantos en tecnologías tales como visión computacional e inteligencia artificial, cada vez este pensamiento es más cercano. Los sistemas “*sense and avoid*”, son muestra de ello. Estos permiten detectar y evitar automáticamente los obstáculos fijos, como las líneas eléctricas, torres eléctricas, árboles y obstáculos móviles, tales como aves u otras aeronaves. Esta tecnología es aún inmadura, pero se trabaja fuertemente en ella [240].

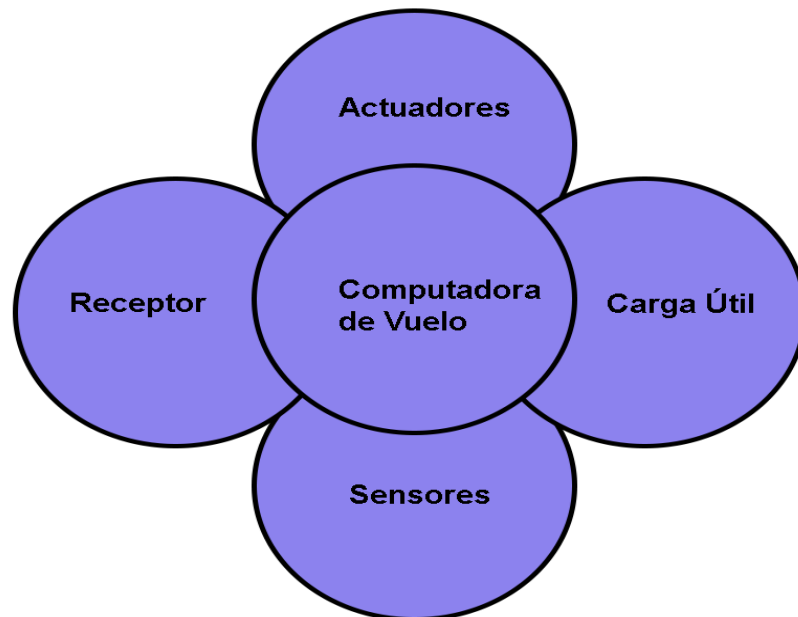


Figura 3.5: Arquitectura Básica de un UAV,[87].

3.3.3. Campo de Aplicación General

El uso de UAVs en Europa, Estados Unidos y el resto del mundo está creciendo de una manera muy rápida debido a su versatilidad, economía y facilidad de uso. En el caso de los Micro y Mini UAVs, que son los sistemas que se abordan en esta investigación de tesis, están equipados con una variedad de instrumentos tales como el IMU, receptor GNSS, control inalámbrico, estabilizadores de vuelo, etc. Los vehículos aéreos no tripulados permiten un registro, seguimiento de la posición y orientación de los sensores implementados en un sistema de coordenadas local o global, por lo que hace posible que la fotogrametría de UAV pueda integrarse como una herramienta de medición muy precisa. Este tipo de aeronaves no únicamente pueden proveer imágenes en el visible, sino también que cuenta con sensores para capturar datos LIDAR, multiespectrales, hiperespectrales y termales, solo por mencionar algunas fuentes de datos [52], [192].

Estos sistemas pueden ser utilizados en muchas áreas tales como:

- Agricultura de precisión [241]
- Protección pesquera
- Cambios de detección sobre cuerpos de agua [16]
- Monitoreo fronterizo
- Monitoreo de la biosfera [33]
- Cambios de detección [167]
- Volumetría [227].
- Mapeo en desastres naturales [183].

3.3.4. Ventajas y Desventajas

Ventajas :

- Puede ser utilizado en situaciones de alto riesgo, no exponiendo al peligro la vida humana.
- Alcance de áreas o regiones de poca accesibilidad y difíciles de recorrer por los humanos.
- La mayoría de los sistemas comerciales se enfocan sobre un bajo costo.
- En condiciones climáticas difíciles como lluvias, nubes y neblina la adquisición de datos es posible.
- Capacidad de toma de imágenes y video a tiempo real.

Desventajas :

- Los UAVs fácilmente pueden ser hackeados, perdiendo el control del equipo y la comunicación entre el usuario y su receptora.
- Capacidad muy limitada de vuelo debido a su fuente de energía.
- En general no existen suficientes regulaciones claras y confiables, ya que aún existen muchos huecos legales al día de hoy.
- Un equipo UAV no puede reaccionar de la misma manera que un humano a pesar de los adelantos tecnológicos sobre inteligencia y visión computacional.
- Pueden ser interferidos fácilmente por señales de radio o electromagnéticas.

3.4. Análisis de Datos Espectrales

La teledetección se basa en el hecho de que todos los materiales presentes en el mundo real reflejan, absorben y emiten energía electromagnética en diferentes longitudes de onda [48]. Existe una gran variedad de sensores que son capaces de adquirir datos espectrales de manera remota y trasladar estos datos a una imagen. La imagen contiene patrones o características que apuntan al conjunto de medidas o datos obtenidas por el sensor en cada una de sus bandas.

En el campo de reconocimiento de patrones, un patrón hace referencia a un vector de características que describen un objeto. Este patrón, está compuesto de mediciones sobre un grupo de rasgos o características, los cuales se pueden representar como un espacio k -dimensional llamado *espacio de características*, ver Figura 3.6.

Las características o patrones son capturados en cada pixel y estos datos son los utilizados para su clasificación. El objetivo principal del reconocimiento de patrones en el área de teledetección es establecer la relación entre un patrón y una clase [132].

En este apartado se presenta una revisión de las técnicas de análisis espectral más utilizadas en teledetección, facilitando una exploración previa a las metodologías que se proponen en los capítulos 4 y 5 de esta investigación de tesis.

La clasificación de imágenes es el proceso de categorizar todos los píxeles de una imagen o región de datos con el fin de obtener un conjunto de etiquetas o características de cobertura terrestre. El resultado del proceso de clasificación puede hacer referencia a un mapa temático, el cual ayuda al usuario a identificar objetivos específicos [133], [172]. Los enfoques de interés acerca de estos mapas temáticos pueden estar determinados por su aplicación. En geología, se puede mapear diferentes tipos de minerales [182]. En agricultura normalmente se incluirían los diferentes tipos de cultivos, características del área, humedad y tipo de suelo [28]. En Limnología se puede estudiar la distribución y límites de ecosistemas acuáticos [110], [26].

Existen dos enfoques fundamentales de clasificación y cada uno encuentra su aplicación en el procesamiento de imágenes de sensores remotos. Los enfoques de clasificación usualmente utilizados en el área de teledetección son los métodos *Supervisado y No Supervisado*. El desempeño de estas técnicas varía dependiendo de la calidad de los datos y la orientación del algoritmo [7], [133], [176].

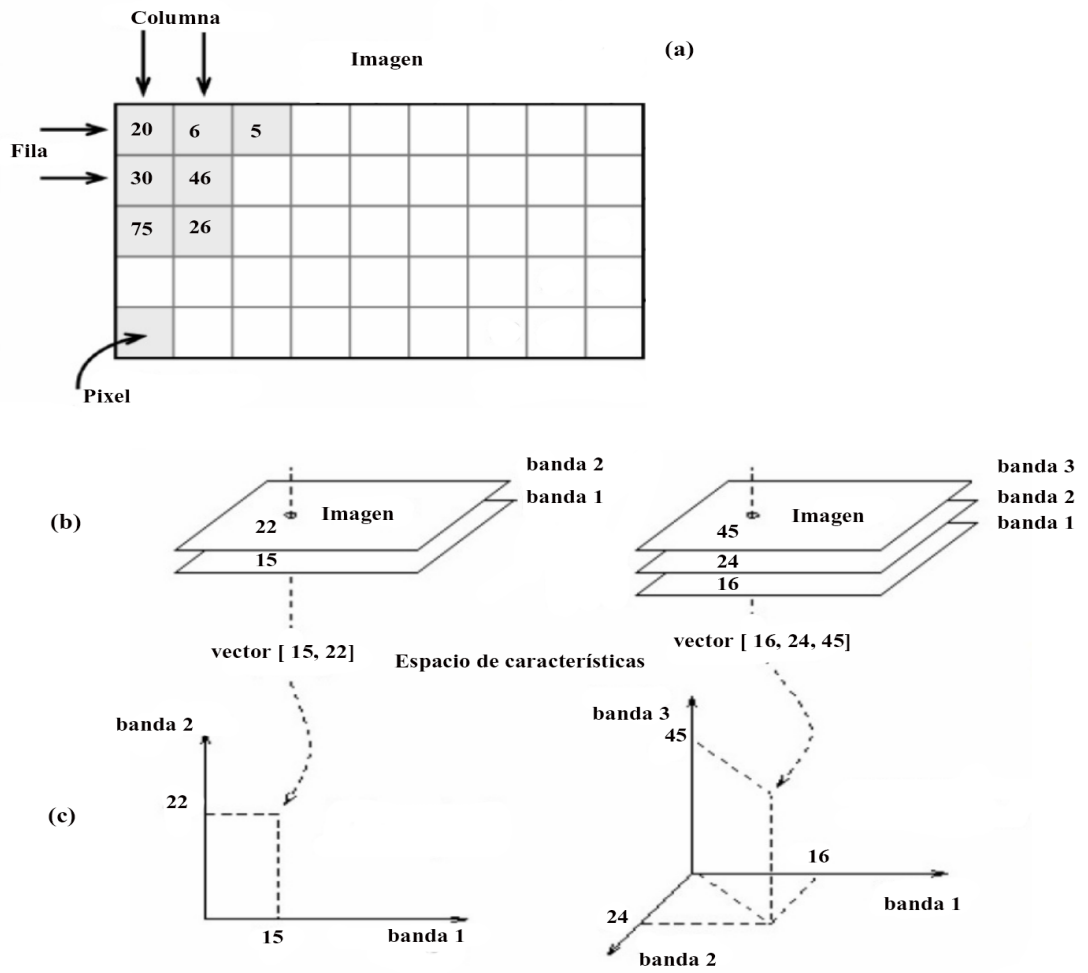


Figura 3.6: (a) Coordenadas del dominio espacial del pixel sombreado, fila-columna. (b) Dimensiones de la imagen y números digitales. (c) Espacio de características de 2 y 3 dimensiones.

Un enfoque *Supervisado* se basa en aquellos métodos donde el análisis se retroalimenta con datos para su entrenamiento con el fin de permitir que el algoritmo busque patrones similares.

Un enfoque *No Supervisado* trata generar clases que son distintas espectralmente a través de diferentes algoritmos, este tipo de enfoque no necesita datos etiquetados y no existe ningún tipo de conocimiento a priori sobre las clases existentes [30], [133], [7]. En la Tabla 3.7 se muestra una referencia acerca de algunos de los algoritmos comúnmente utilizados en el análisis de imágenes multiespectrales.

Método	Ejemplo de Algoritmo	Características
Supervisado	Paralelepípedo, Mínima Distancia, Máxima verosimilitud, Máquina de Soporte Vectorial	El analista alimenta el algoritmo con datos de entrenamiento para permitir que el algoritmo busque características similares
No-Supervisado	Clustering, ISODATA, K-Medias, etc	No existe ningún antecedente, se analiza la muestra o imagen completa sin hacer referencia a ningún entrenamiento previo. Permite la identificación grupos de datos.
Híbridos	Sistemas Redes Neuronales	Métodos emergentes y particularmente poderosos que han surgido recientemente. Combinación de los 2 enfoques anteriores.

Tabla 3.7: Principales Clasificadores Utilizados en Teledetección [101], [191], [133].

3.4.1. Métodos de Clasificación Supervisada

El hablar de un enfoque supervisado es hacer una referencia directa a la interacción del conocimiento del usuario sobre una imagen. El usuario especifica un conjunto de datos de la región de interés y las asocia a cada clase. Una vez que el usuario selecciona los datos de entrenamiento para cada una de las clases, se inicia con el proceso de clasificación, el cual es especialmente dependiente de que tan bien el usuario fue capaz de seleccionar las muestras para alimentar el algoritmo de entrenamiento. Las muestras a entrenar son normalmente localizadas directamente en campo, por medio de una imagen aérea o fointerpretación de un experto y a esta referencia se le conoce como *ground truth* [191]. Es muy importante enfatizar que todas las clases de interés deben ser cuidadosamente seleccionadas con el fin de obtener una buena respuesta del clasificador.

Aunque la selección de datos para entrenar suele ser tediosa, un enfoque supervisado

es el preferido por muchos investigadores, esto debido al resultado en la separación de clases y su precisión [132]. Existen 3 clasificadores estadísticos muy utilizados en teledetección. Estos clasificadores son el método paralelepípedo, mínima distancia y máxima verosimilitud [101], [133].

El método de paralelepípedo, genera cajas usando valores de reflectancia mínimos y máximos o unidades de desviación estándar dentro de los sitios de entrenamiento. La regla para este método es muy simple: si un pixel está dentro de una caja, este pixel es asignado a la clase correspondiente en dicha caja [172], ver Figura 3.7.

Este clasificador brinda una gran sencillez en su aplicación, sin embargo, algunas cajas se pueden superponer debido a que un pixel puede satisfacer el criterio para más de una clase. Otro factor a tomar en cuenta es cuando el pixel no satisface este criterio para ninguna de las clases, el pixel se asigna a una caja desconocida [199], [172].

La regla de decisión adoptada por el método de mínima distancia para determinar

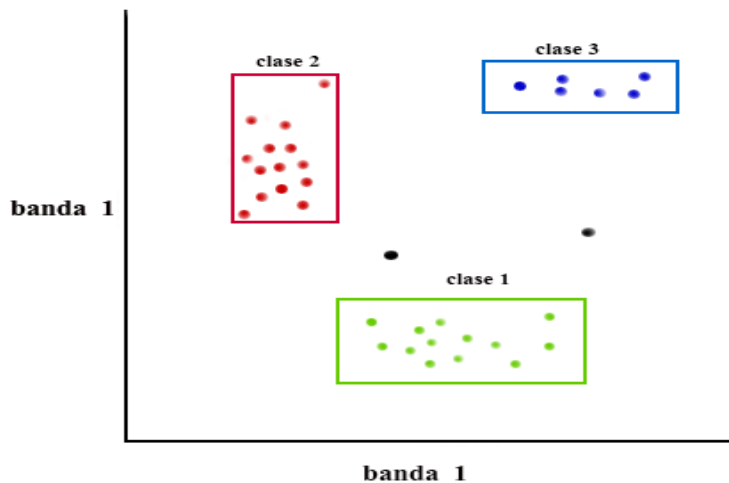


Figura 3.7: Cada caja está limitada por valores de puntos mínimos y máximos dentro de la clase, sin embargo, los píxeles en color negro no satisfacen ningún criterio de asignación para una clase.

la etiqueta de un pixel es la mínima distancia entre el pixel y el centro de la clase, medido por una distancia euclidiana o la distancia de Mahalanobis [133], [58].

Máxima verosimilitud o el análisis discriminante, es un método estadístico clásico que evalúa la probabilidad de que un pixel pertenezca a una categoría y asigna dicho pixel en la clase con la probabilidad más alta [133], [132].

Los 3 últimos métodos estadísticos de clasificación mencionados en este documento se utilizan en [199]. El autor utiliza los métodos de paralelepípedo, mínima distancia y máxima verosimilitud para la clasificación de suelos definidos como vertisol. La investigación fue realizada con imágenes de Landsat TM. El objetivo de la investigación fue identificar y clasificar los tipos de vertisol y su mineralogía, relacionar las propie-

dades de los tipos suelos por la reflectancia espectral y su delimitación cartográfica. Los métodos de clasificación estadísticos convencionales han sido utilizados con éxito por más de 50 años, sin embargo, estos métodos tienen sus limitaciones [176], [132]. Como resultado en los últimos años y debido a los avances en las tecnologías computacionales se han propuesto estrategias alternativas tales como redes neuronales, árboles de decisión y máquinas de soporte vectorial, métodos derivados de la teoría de conjuntos difusos [132]. También no se puede dejar de mencionar la necesidad de relacionar enfoques multidisciplinarios para extraer la información. Las ciencias como visión por computadora, geomática, fotogrametría, minería de datos y procesamiento de imagen, son enfoques que en conjunto están generando resultados muy interesantes en la extracción de la información [28], [58], [231].

La ventaja de una metodología supervisada sobre la no supervisada, refiere a que el enfoque supervisado primero determina categorías de información útil y luego examina su separabilidad espectral, mientras que, en un enfoque no supervisado, el ordenador determina las clases espectralmente separables [7].

3.4.2. Métodos de Clasificación No Supervisada

Un método no supervisado no requiere de la intervención del usuario, para la selección de conjuntos de datos de entrenamiento para caracterizar los objetivos o para entrenar un clasificador. En lugar de ello, el usuario puede especificar el número de agrupamientos o clúster y la clasificación de manera automática se genera. Algunas veces el número de clúster también puede ser generado de manera automática por el clasificador [42]. Sin embargo de manera general el usuario no necesita interactuar con el clasificador el cual opera de manera independiente y automática [42], [132].

Ejemplos clásicos sobre métodos no supervisados son los algoritmos de K-medias e ISODATA (Iterative Self-Organizing Data Analysis Technique). Ambos algoritmos son procedimientos iterativos y en la primera fase de trabajo ambos algoritmos asignan sus datos a un grupo arbitrario de manera inicial. A continuación, se clasifica cada pixel hacia el grupo más cercano y por último el nuevo clúster es recalculado en base a la media de todos los pixeles, este proceso sucede de manera recurrente hasta que el cambio en la iteración es mínimo. Este cambio se puede establecer de varias maneras, ya sea midiendo las distancias o por el porcentaje de pixeles que han cambiado entre las iteraciones. ISODATA tiene algunas mejoras adicionales al dividir y fusionar grupos durante su desempeño. K-medias es uno de los algoritmos más populares con enfoque no supervisado y es ampliamente utilizado para generación de segmentaciones automáticas en el campo de la teledetección [160], [128]. K-medias e ISODATA son algoritmos similares, la diferencia significativa es que ISODATA permite que el número de agrupaciones se ajuste automáticamente durante la iteración, mientras que K-medias asume que la cantidad de agrupaciones se conoce a priori [2].

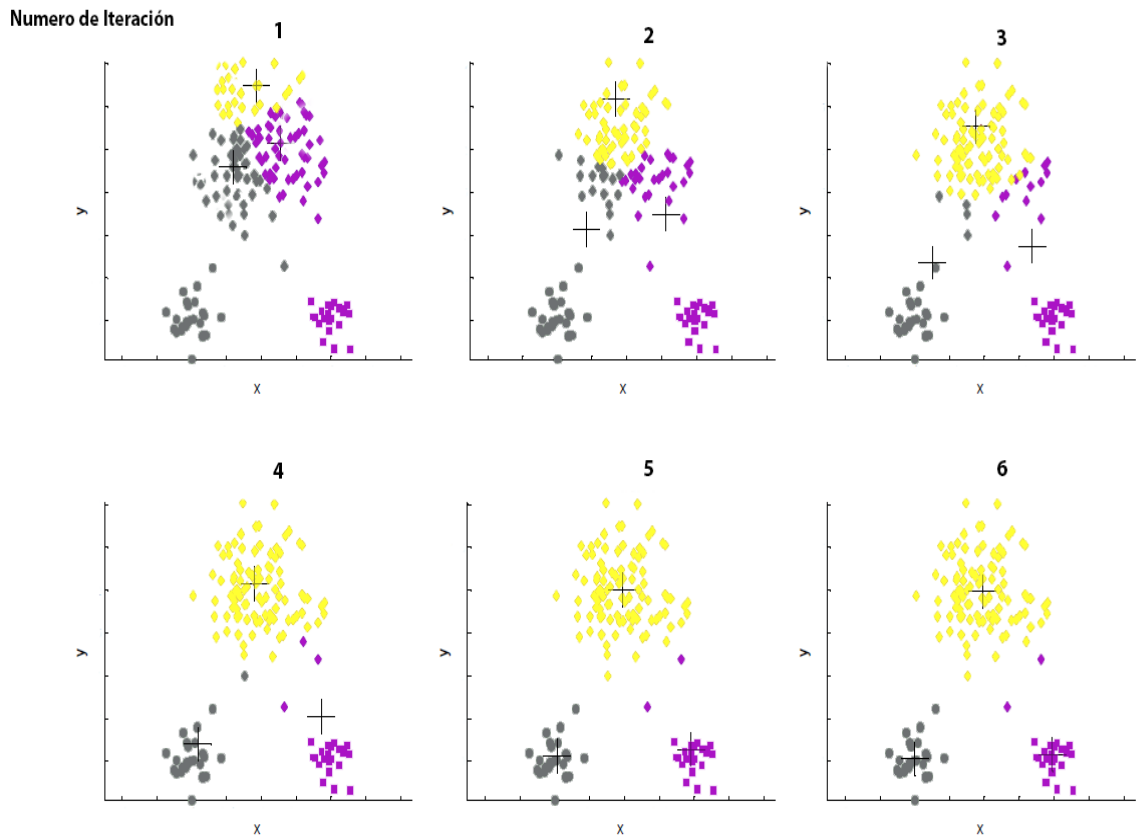


Figura 3.8: Algoritmo de agrupamiento K-medias. Número de clúster $K=3$, cada clúster tiene asociado un centroide y los puntos se asignan al clúster cuyo centroide esté más cerca. Con cada iteración va actualizando los centroides en función de su distancia, hasta que los centroides dejan de cambiar.

CAPÍTULO 4

Propuesta Elaborada Para Agave

El agave tequilana weber variedad azul, es la materia básica del tequila; bebida que a través de los siglos, ha sido símbolo de identificación del estado de Jalisco e imagen de México hacia el mundo.

En este capítulo se presenta el trabajo realizado en este proyecto de investigación sobre la metodología de procesamiento de imágenes aéreas, utilizada para la detección de plantas de agave y otras capas de relaciones en campo; se muestra una metodología de procesamiento, identificación y conteo a través de la percepción remota realizada por medio de plataformas UAV de bajo costo.

El agave, de la variedad denominada tequilana Weber variedad azul, es un cultivo que a lo largo de dos siglos ha sido sostén muy importante de la agroindustria tequilera de Jalisco y de la economía agrícola en México [174]. La producción y comercialización de tequila, bebida tradicional mexicana y cuya principal materia prima es el agave, ha logrado crecer en años recientes de una manera muy rápida. El volumen de exportación de tequila es visto como un indicador de la capacidad exportadora de México. Este se promueve como parte de la identidad nacional y como un producto de un paisaje mexicano único que aspira atraer turismo a nivel internacional [217]. Olmedo-Carranza, [154], refiere a esta bebida como el vínculo a las diversas manifestaciones culturales de la sociedad mexicana, desde los sentimientos, las pasiones, sus fiestas, canciones, películas, mariachis, etc. El tequila actualmente cuenta con una denominación de origen (DO) desde el año 1974. La mencionada DO se extiende a los estados de Guanajuato, Michoacán, Tamaulipas, Nayarit (solo en algunos municipios) y todo el estado de Jalisco, lugares donde únicamente es posible cultivar esta planta para que pueda ser procesada en un futuro para la bebida denominada tequila. En el año 2006, la UNESCO declaró como patrimonio cultural de la humanidad al denominado *Paisaje Agavero* que comprenden los extensos campos del cultivo de agave, las instalaciones industriales o haciendas, las destilerías y sus poblados, ver Figura 4.1, [154]. Por todo ello, este cultivo para el pueblo mexicano tiene un enorme valor cultural y forma parte de la identidad nacional.



Figura 4.1: Paisajes Agaveros, Ruta del Tequila en Jalisco, México.

4.1. Teledetección de los Recursos Agrícolas

La producción, el modelado, la detección del estrés o enfermedades en cultivos, en muchos países se realiza utilizando datos de teledetección. Los campos agrícolas son influenciados por muchos factores, tales como las características del suelo, genotipo, prácticas culturales, condiciones meteorológicas, enfermedades y plagas [56]. Muchos enfoques de teledetección son integrados para determinar y medir la producción del campo [127], los efectos en los cultivos y su desarrollo [169], [126]. Se han generado muchos estudios para determinar los efectos integrados de parámetros que afectan el crecimiento, tales como la maleza en los cultivos [121][103].

Sin embargo, una limitación importante para la teledetección por medio de imágenes de satélite ópticas, es un cielo nublado durante la temporada de cultivo [56]. Esta es la principal razón por la cual un sistema de teledetección de tipo óptico no puede proporcionar datos confiables bajo estas condiciones atmosféricas. Sin embargo, con la aparición de dispositivos UAV, esto se ha podido superar, ya que tales instrumentos pueden trabajar bajo este tipo de condiciones.

Los estudios de monitoreo de agave con UAV son escasos, pero existe un amplio crecimiento acerca de estudios con UAV en otras áreas. Por ejemplo, en la reconstrucción de escenas 3D con imágenes que provienen de cámaras digitales instaladas en plataformas aéreas y en tierra [24], [164], [145], [10]. Durante la última década se ha desarrollado un número creciente de ejemplos de aplicación de UAVs en monitoreo de agricultura y vegetación [188], [178]. Estudios de imágenes con plataformas UAV apoyados de métodos cartográficos y fotogramétricos están obteniendo excelentes resultados en costos, rapidez, resolución y escalas mucho más cómodas [204], [173]. La teledetección es básicamente una ciencia multidisciplinaria que incluye una combinación de varias disciplinas; por lo tanto, todas estas tecnologías están integradas para actuar en el campo de la percepción remota y son base fundamental en el estudio de monitoreo en aplicaciones agrícolas [4].

En el monitoreo de vegetación en aplicaciones agrícolas, tener información actualizada es crítico para la toma de decisiones a tiempo [222], [13]. En años anteriores la reducida investigación con equipos UAVs en el campo civil, se debía en parte a que los costos eran muy elevados para este tipo de plataformas; sin embargo, en estos momentos, el crecimiento en ventas, ha reducido los costos y la accesibilidad a estos equipos es más simple [52]. El avance tecnológico y civil ha generado la disponibilidad de UAVs en el mercado. Los UAVs en este momento pueden ser encontrados en tiendas especializadas con acceso a sensores espectrales, multiespectrales, LIDAR, o con sensores de posicionamiento cinemático en tiempo real (Real Time Kinematic, RTK) a precios accesibles o por otro lado, también se pueden encontrar en supermercados locales, siendo estos equipos más simples en su funcionamiento.

El autor David J. Mulla [142] en el año 2010 muestra un panorama futuro muy interesante acerca de la agricultura de precisión, donde menciona que se presentaran datos con una mayor resolución espacial y temporal, en los cultivos se podrá ajustar la medida de manera correcta e individualizada en fertilizantes, según la variabilidad en suelo. La gestión espacial y el tratamiento en cada planta será ajustable, los datos serán almacenados para su análisis y gestión masiva, el autor hace referencia a que

en el año 2010 esta escala de gestión de la información no era viable para este tipo de enfoques, sin embargo, en tan solo 9 años esto ha cambiado totalmente y hoy en día es posible ya realizar esta gestión de la información en agricultura de precisión a través de las diversas plataformas y tecnologías que están hoy en día en uso.

Tomando en cuenta los objetivos de esta tesis, la propuesta planteada es la de realizar un monitoreo de bajo costo con equipos UAV sobre áreas que contienen agave. El objetivo principal es monitorear las regiones cultivadas y distinguir entre distintas clases de elementos que rodean el agave y extraer mapas temáticos de los elementos de esta planta y su entorno. Esto es importante dado que permite estimar la cantidad de áreas sembradas con este tipo cultivo y se podría analizar la evolución de las mismas, verificar estados fenológicos, áreas de maleza, conteos e iniciar con el principio de prevención de enfermedades. Además, estas estadísticas son útiles a la hora de prever la producción que se obtendrá.

El presente proyecto está sustentado por la experiencia y trabajo realizado en regiones del estado de Jalisco, por el equipo de consejo regulador del tequila (CRT) y la empresa Cubo Geoespacial SA de CV.

4.2. UAVs en la Agricultura

Los dispositivos UAV, cada vez más compactos, inteligentes y optimizables han creado nuevas oportunidades para la aplicación de la teledetección en el área de la agricultura y vegetación. La Organización de Aviación Civil Internacional (OACI) ha definido las aeronaves no tripuladas como cualquier aeronave destinada a operar sin un piloto a bordo y ha establecido las reglas para dichas aeronaves puedan operarse con un nivel limitado de autonomía. La Organización de Aviación Civil Internacional (OACI), define la palabra obstáculo como: *todo objeto fijo (ya sea temporal o permanente o móvil), o partes del mismo, que esté situado en un área destinada al movimiento de las aeronaves en la superficie o que sobresalga de una superficie definida, destinada a proteger a las aeronaves en vuelo* [98], [163]. A pesar de las restricciones actuales a la regulaciones políticas y gubernamentales, acerca del uso de UAVs equipados con sensores; estos equipos han surgido como una alternativa prometedora para asistir en el modelado, mapeo y monitoreo sobre el área forestal, agrícola y ambiental [52], [158], [185].

El primer robot industrial estacionario fue desarrollado por George Devol y Joseph F. Engelberger a principios de la década de 1960 para la línea de producción de un fabricante de automóviles [239], [69]. Según Zecha [239], un importante criterio para las operaciones al aire libre es una es una geolocalización precisa de la posición de un vehículo o robot.

Los sistemas satelitales de navegación global se definen como GNSS y son aquellas constelaciones satelitales que transmiten señales para localizar un receptor en cualquier parte de la Tierra [117]. En el año 1973, se puso en marcha el del Sistema de Posicionamiento Global (GPS) desarrollado por el Departamento de Defensa de los Estados Unidos inicialmente para satisfacer las necesidades militares, sin embargo la

operación civil no fue concedida hasta el año 1994 [9], [117]. Los tres sistemas GNSS más conocidos hasta el momento GPS, GLONASS y el más reciente GALILEO, hablando operativamente.

Con los Sistema (GPS), GALILEO y (GLONASS), la precisión en la geolocalización de los receptores sobre la Tierra aumentó a menos de 3m. Esta precisión trajo con ello, el aumento en la inserción de sensores de consumo tales como los receptores GNSS diferencial que son sistemas de corrección que se basan en algoritmos que corrigen errores en tiempo real [159]. Esto ha permitido a diversas empresas fabricantes de equipos UAV, implementarlos en plataformas de bajo costo y con ello hacerlos más accesibles en el campo de la agricultura [61], [159]. El acceso a estos dispositivos de consumo y la precisión en el posicionamiento global que brindan los satélites de geoposicionamiento, también han permiti6 aumentar las aplicaciones y estudios en el campo.

La fusión y convergencia de varias tecnologías, incluidos los sistemas de posicionamiento global, los sistemas de información geográfica (GIS), los dispositivos electrónicos miniaturizados, el control automático, la teledetección, la computación, el procesamiento avanzado de la información y las telecomunicaciones están generando un enfoque muy interesante sobre estudios en la agricultura [83]. La industria agrícola ahora es capaz de recopilar datos más completos sobre la variabilidad de la producción tanto de manera temporal así como de manera geoespacial. El deseo de responder a tal variabilidad en una escala fina se ha convertido en el objetivo de la agricultura de precisión (PA) [244].

En el ámbito agrícola, las propiedades espectrales sobre la vegetación son muy importantes. Las imágenes proporcionadas por los satélites son una fuente de datos para analizar amplias regiones con el fin de detectar la salud de los cultivos, las áreas de maleza, el suministro de nutrientes y las condiciones de manera general de los cultivos [211]. Sin embargo, a menudo la resolución espacial es muy baja para detectar los detalles del cultivo o las imágenes se encuentran cubiertas de nubes para esas regiones de interés. Ensayos de campo en agricultura, muestran que se necesita reunir una mayor resolución en los datos para tener una mejor precisión de detección en el área estudiada [239].

Los UAVs han demostrado muchas ventajas en el uso en el monitoreo de la agricultura. Ventajas incluidas en el ahorro en costos, mayor facilidad de uso, resistencia, flexibilidad para la selección de la carga útil adecuada y una excelente resolución espacial y temporal ajustable en todo momento [62], ver Figura 4.2. C. W. Zang [241], menciona que la PA, es la aplicación de técnicas y sensores geoespaciales para identificar variaciones en el campo y tratarlas mediante estrategias alternativas [241]. Los equipos UAV, tienen sensores que son capaces de detectar la variabilidad del campo y generar mapas de aplicación de tasa variable (ATV). La tecnología ATV se enfoca en la aplicación automatizada de materiales en un área determinada. Los productos que se aplican incluyen materiales como fertilizantes, productos químicos, semillas, insecticidas y todos aquellos componentes que ayudan a optimizar la producción de los cultivos.

Naiqian Zhang [244], menciona que el enfoque principal acerca de estas tecnologías estuvo en el desarrollo de sensores capaces de guiar a los agricultores a través de la



Figura 4.2: Monitoreo de agave con un equipo UAV, Resolución Espacial a 3cm.

gestión de nutrientes especificando el lugar de interés.

Una gran parte de los sensores están basados en tecnología óptica y han generado estudios sobre enfoques de interpretación de firmas espectrales para identificar el estado de los nutrientes en las plantas y aplicar directamente la cantidad correcta de fertilizante [244], [169], [121]. La heterogeneidad reconocida en el campo debido a las diferencias en el color del cultivo, la cantidad de rendimiento o las manchas de maleza, pueden ser georreferenciadas con precisión y ser considerada para futuras decisiones de manejo.

4.3. Structure-from-Motion

La metodología Structure from Motion (SFM) es considerada una herramienta efectiva, es un método fotogramétrico automatizado de alta resolución y bajo coste en relación a otras técnicas. Este método se basa en la superposición de imágenes ópticas obtenidas desde distintos puntos de vista. Sin embargo, el SFM tiene sus orígenes en el campo de la visión artificial y el desarrollo de los algoritmos automáticos de correlación automática de imágenes (CAI) [209].

SFM es un algoritmo que necesita una gran cantidad de imágenes superpuestas tomadas por cámaras digitales o sensores sofisticados para generar productos de teledetección como un ortomosaico o un Modelo Digital de Superficie (DSM), [190], [206],




Figura 4.3: (a) y (b) Imágenes sobrepuestas obtenidas de un vuelo hecho por UAV sobre plantas de agave. (c) Configuración típica en bloques de imágenes UAV que cubren un área aproximada de 3 ha con un GSD de 3cm.

ver Figura 4.3.

Algunas limitaciones son propias a esta metodología de uso de SFM. Por ejemplo, las superficies de agua que no pueden medirse debido a la reflexión especular y la falta de coherencia entre imágenes consecutivas, este tipo de problemas se presenta sobre algunas áreas y el algoritmo SFM no puede correlacionar las imágenes y por lo tanto es muy difícil generar un ortomosaico. Además, en superficies homogéneas como la arena, la falta de textura hace que sea imposible identificar puntos homólogos y por lo tanto, no puede correlacionar imágenes [22].

Actualmente, existen varios programas capaces de utilizar el algoritmo de SFM. Algunas de las aplicaciones de código abierto que utilizan este tipo de algoritmos son Open Drone Map [223], Graphos [85], MVE [78], Python Photogrammetry Toolbox [140], VisualSFM [235] y OpenMVG [141]. Algunas de las opciones comerciales son

Agisoft Photoscan [22], [5], Pix4D [54], Inpho UAS Master[28] e Icaros OneButton [99].

4.4. Geometría y Radiometría

Para generar productos precisos para el mapeo en la agricultura, es necesario abordar las principales limitaciones de las imágenes de UAV: geometría y radiometría [94]. Como los UAV son relativamente pequeños, tienden a tener menos estabilidad en la captura de datos ópticos durante los vuelos. Por ello, la precisión geométrica tiende a ser menor en comparación con los datos provenientes de aviones pilotados. Sin embargo, este problema se ve compensado por la gran cantidad de imágenes sobrepuestas tomadas por el sensor montado en un UAV y utilizando algoritmos novedosos de visión por computadora como Structure-From-Motion (SFM) y Multi-View Stereo (MVS) [94].

Con el fin de reducir la diferencia entre la ubicación espacial de los objetos en las imágenes y su ubicación sobre el mundo real, se realiza la calibración geométrica. Una forma común de mejorar la precisión geométrica es georreferenciar el producto de teledetección con puntos de control de tierra (Ground Control Point, GCP). La distribución y el número de GCPs cambian y mejoran la precisión geométrica de los productos de teledetección.

Desafortunadamente, la radiometría no se ha estudiado tan a fondo como la geometría de la imagen [49]. Existen métodos de corrección radiométrica bien establecidos para la teledetección a través de imágenes satelitales; sin embargo, estos estándares no son directamente aplicables en el flujo de trabajo fotogramétrico [91]. La variabilidad en los sensores en cámaras digitales que se utilizan con diferentes características y muchas veces en ocasiones desconocidas, dificulta la determinación de la calidad de los datos obtenidos imagen [49], [91]. Un sensor de imágenes digitales, tal como un dispositivo de carga acoplada (CCD) o un semiconductor complementario de óxido metálico (CMOS), mide la radiación entrante y almacena la medición resultante como un ND. La radiación que entra al sensor de imagen es controlada por la apertura y el tiempo de exposición de cada dispositivo.

Los objetivos de referencia de reflectancia actuales y las mediciones in situ no se utilizan en la recopilación de datos fotogramétricos convencionales, tales como ortofotos, cartografía y estereoscopia [91].

Con la disponibilidad actual de equipos UAV, se ha abierto paso para una creciente adopción de sensores CCD y CMOS incluidos en las cámaras, que convierten la luz en un valor radiométrico. Por lo tanto, los sensores digitales modernos pueden adquirir bandas separadas en Rojo, Verde, Azul e IR (hablando de un sensor multiespectral) y con ello poder obtener imágenes en color verdadero y falso color al mismo tiempo. Según Honkavaara [91], los parámetros más importantes relacionados con las condiciones de la imagen son la altura de vuelo, el ángulo de elevación solar, el estado atmosférico, las nubes, neblina y la estación del año [50]. Por lo tanto, para obtener medidas de precisión y repetibilidad, los sensores requieren un procedimiento de calibración [158].

Según Martínez [131], en la hipótesis de sensores que utilizan una respuesta de un sensor lineal, la ecuación que permite la conversión del número digital ND a radiancia del sensor es (4.1):

$$L_r = CAL_g * ND_r + CAL_o \quad (4.1)$$

donde L_r es el valor de radiancia (en el sensor), CAL_g es el parámetro de ganancia en la calibración lineal para banda x , CAL_o es el parámetro de pérdida en la calibración lineal para banda x y ND_r promedio de ND sobre una imagen tomando un objetivo para la banda x [158], [131].

En la hipótesis de conocer todos los parámetros para el procedimiento de calibración, suponiendo que la superficie es de reflectancia Lambertiana uniforme y la atmósfera es uniforme, la reflectancia según Martínez [131] y Gao [80] se puede calcular por las ecuaciones mostradas en:

$$\rho = \frac{\pi * d^2 * L_r}{E * \cos\theta_s} \quad (4.2)$$

donde ρ es el valor de la reflectancia, L_r es el parámetro de radiancia, E es el parámetro de irradiancia solar extraterrestre, θ_s es el ángulo cenital solar y d es la distancia Sol-Tierra expresada en unidades astronómicas.

Sin embargo, cada imagen generada por el sensor de cámara tiene un valor específico de apertura de diafragma o número F. Este valor puede ser muy diferente a lo largo de la misma dirección de adquisición. Mientras que para los sistemas basados en satélites el coeficiente radiométrico es absoluto, es decir, es un número único. Para las cámaras digitales, el ajuste de apertura de diafragma o número F y el tiempo de exposición deben tomarse en cuenta [181]. Además, debido a que no es fácil obtener los parámetros de calibración y los valores de irradiancia solar extraterrestre, la transformación de ND a reflectancia con la precisión adecuada es bastante complicado en muchas ocasiones [158].

B. Basso [18] menciona que en la mayoría de los estudios sobre plataformas UAV hasta el año 2014, se han utilizado los datos brutos, es decir, valores de ND. Esto es, en parte, debido al hecho de que muchas de estas investigaciones utilizaron cámaras digitales comunes para capturar los datos y que pocos estudios han convertido sus ND a valores de reflectancia antes de calcular cualquier índice espectral.

Existen diferentes factores que pueden contribuir a los errores radiométricos durante los vuelos. A continuación se hace mención de algunos de estos percances que pueden surgir [205].

- El uso de equipos de imágenes con un amplio campo de visión (FOV) estos crean una variación radial inherente en el ángulo de visión.
- Incluso aunque las imágenes de UAV multiespectrales están libres de nubes, las nubes influyen en la radiación solar entrante en el área estudiada generando puntos más oscuros. Esto lleva a una variación en los valores del ND para el

mismo objeto y por lo tanto la costura de las imágenes superpuestas no se puede hacer correctamente.

- El movimiento solar que crea una fuente de iluminación no estática.

Dos de las principales tecnologías utilizadas por las imágenes aéreas en PaRS son las cámaras de marco y los escáner pushbroom. Las cámaras de marco se caracterizan por construir una perspectiva central en relación al tamaño del sensor y se distinguen por su tamaño, es decir puede ser pequeño, mediano y de gran formato. En el segundo caso, los escáneres pushbroom o de escoba producen imágenes de franjas continuas del terreno [158].

La corrección radiométrica en teledetección implica: la corrección del efecto de viñeteado o la caída de brillo en un cuadro de la imagen, esto depende de la óptica del sensor, corrección de la reflectancia dependiente del azimut del sol, reflexión de la superficie, topografía e iluminación y corrección atmosférica que depende de los efectos y dispersión de la atmosfera [124], [92].

Al hacer una comparación de la corrección radiométrica con los tradicionales métodos de percepción remota, se hace hincapié que la teledetección con imágenes ópticas comunes, ya tiene un proceso de corrección radiométrica bien establecido, mientras que las metodologías en percepción remota sobre la tecnología UAV todavía se están investigando [1], [49], [205].

La importancia de conocer como está conformada la cámara es fundamental, saber qué tipo de detector utiliza, es necesario conocer los parámetros ópticos y todos los aspectos técnicos que requiere un trabajo de fotogrametría y teledetección o por sus siglas en ingles PaRS.

4.5. Flujo de Trabajo para el Monitoreo del Agave

La fotogrametría es la ciencia y la tecnología para obtener mediciones espaciales y otros productos derivados geoméricamente confiables a partir de imágenes [124].

Un equipo UAV, es capaz de registrar en tiempo real su ubicación durante el vuelo a través de receptores GNSS. Estos datos son generados para un sistema de coordenadas.

Para poder generar una descripción matemática de un objeto en el mundo real, tenemos que definirlos dentro de un sistema de referencia. En la siguiente sección, se describen los sistemas de coordenadas necesarios para el procesamiento fotogramétrico de los datos de UAV en este estudio.

El sistema de coordenadas que nos interesan a efectos de esta Tesis es el denominado Sistema Geodésico Mundial 1984 (WGS84). El Sistema WGS84 permite localizar cualquier punto de la Tierra donde el cálculo de posición se apoya en un patrón matemático de tres dimensiones (x,y,z) [68]. WGS84 es de amplio uso debido al manejo de la tecnología GPS ya que es el Datum en el cual se calculan las posiciones GPS por defecto. El sistema WGS84 fue creado y también es controlado por el departamento de defensa de los Estados Unidos de Norteamérica. Actualmente se usa el elipsoide WGS84 como modelo de base para el sistema de coordenadas Universal Transverse

Mercator (UTM).

El sistema de coordenadas UTM es un sistema de proyección cartográfico basado en cuadrículas con el cual se pueden referenciar puntos sobre la superficie de la tierra. Este sistema refiere a las magnitudes en metros únicamente al nivel del mar. Cuando la superficie a representar es pequeña y por lo tanto la esfericidad terrestre no va a influir en la representación cartográfica, por ejemplo, en pequeños levantamientos con UAV, se recurre a su representación plana, de forma que todos los puntos representados estén vistos desde la perpendicular, ver Figura 4.4.



Figura 4.4: Cuadrícula de zonas UTM que le corresponden a México (zonas 11 a 16 Norte). En el globo obtenido de la aplicación Google Earth, podemos observar la zona marcada con una chincheta amarilla que corresponde a Jalisco, esta área está gestionada sobre las coordenadas UTM zona 13 Norte datum WGS84, que son parte de las zonas con denominación de origen del agave. Derechos de autor Google Earth 2019 TM, [63].

La plataforma UAV utilizada para trabajar los experimentos de esta memoria fue un equipo Phantom 4, adquirido del fabricante DJI, el cual en sus unidades UAV proporciona la conexión de mínimo 36 satélites disponibles para generar una mejor precisión en su geolocalización, ya que los datos continuos del GPS u otros sistemas de georreferencia, son fundamentales para la estabilidad y correcciones de dirección del vuelo de la aeronave, ver Figura 4.5.



Figura 4.5: Equipo UAV DJI Phantom 4.

También se debe tomar en cuenta, que los datos obtenidos por los sensores ópticos o cámaras deben cumplir calibraciones y orientaciones, para lograr la localización efectiva de los puntos en el espacio, por lo que es esencial comprender los fundamentos matemáticos utilizados en fotogrametría tradicional, para aplicarlos en plataformas UAV [37].

El siguiente flujo de trabajo fotogramétrico, del proceso general pertenece a la metodología llevada a cabo en esta memoria, ver Figura 4.6.

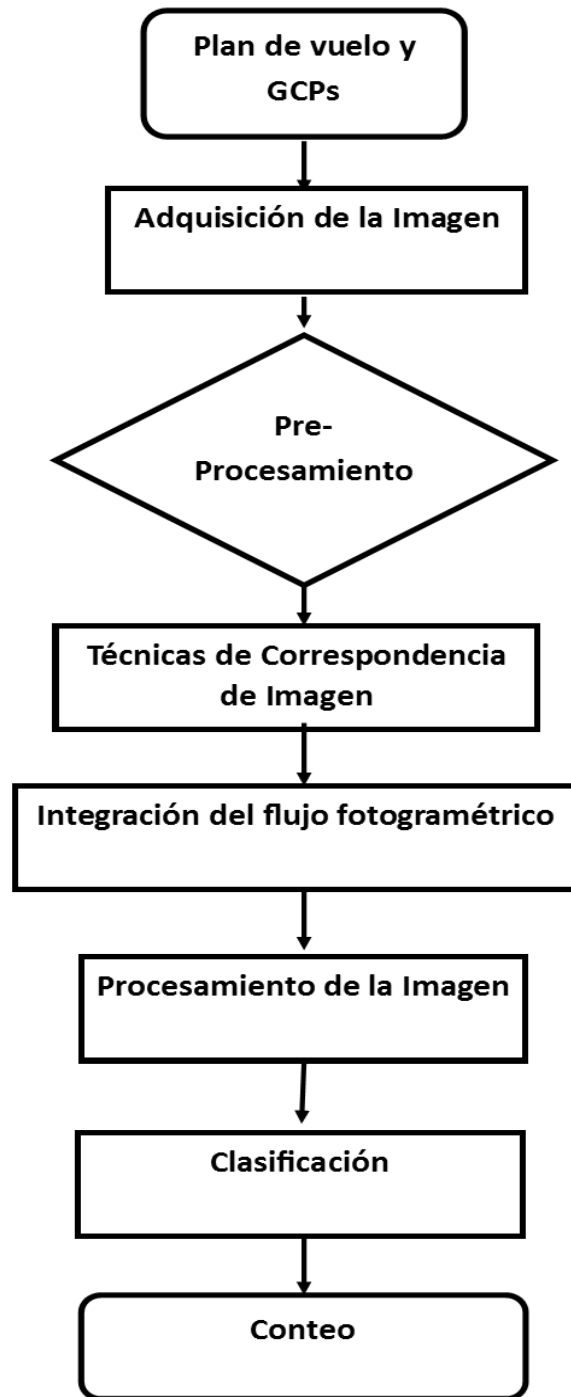


Figura 4.6: Flujo de Trabajo del Proceso General Metodología para el Agave.

Plan de Vuelo y GCPs :

para la planificación de la misión de vuelo de UAV sobre campos de agave,

utilizamos los software Qgis (Quantum Geographic Information System v2.162) y Google Earth™. Montamos varias capas en el SIG Qgis, tal como modelos digitales de elevación (MDE), archivos vectoriales de carreteras, construcción, montes, etc. y utilizamos el SIG Qgis para planificar las áreas de vuelo y determinar las altitudes mientras mantenemos la línea visual con el UAV. Para generar un plan de vuelo, se debe definir por lo general un punto de inicio y un punto de retorno a casa. En el punto de inicio la misión se configura en relación a una coordenada establecida por el usuario y el de retorno a casa, por lo regular es el área donde se encuentra la receptora del equipo UAV. Se requiere de las herramientas SIG para determinar la línea de visión de vuelo desde el UAV hasta la estación terrestre y así determinar los lugares para pilotos y observadores en terrenos despejados altos o montañosos. Utilizamos Google Earth™ como herramienta de visualización para planificar movimientos de pilotos y observadores en carreteras y familiarizar a la tripulación con el paisaje. Una vez que se determinaron las coordenadas para las áreas de vuelo en el SIG Qgis, la información se transfirió al software de la estación terrestre de UAV, Pix4Dcapture™, como un archivo KML (Keyhole Markup Language) con el fin de generar líneas de vuelo basadas en las alturas deseadas y la superposición de imágenes, ver Figura 4.7.



Figura 4.7: Ejemplo de Plan de Vuelo generado por la aplicación Pix4D Capture.

La mayoría de los métodos de operación fotogramétrica convencionales se basan puntos de control de tierra o Ground Control Points (GCP). Aunque la fotogrametría ha adoptado la tecnología digital, los GCPs generalmente se consideran la única fuente de información de georreferencia confiable [66], [133]. De una manera sencilla, podría ser útil pensar que los GCPs son una serie de chinche-

tas colocadas en un ortomosaico generado por UAVs y que debido a el software de mapeo de drones conoce la ubicación exacta de cada una de estas chinchetas, puede hacer referencia y posicionar con precisión un mapa en relación con el mundo real, ver Figura 4.8.



Figura 4.8: Los puntos de control en tierra o Ground Control Points (GCP), son objetivos marcados en el suelo, espaciados estratégicamente a lo largo de su área de interés.

Adquisición de la Imagen :

las plataformas UAVs son adecuados para aplicaciones de teledetección sobre campos de Agave. Debido a la lejanía y la baja densidad de población de los campos donde se siembra esta planta, es más fácil obtener permiso para volar sobre esas áreas en comparación con las áreas más pobladas.

Este estudio examinó áreas de agave administradas por el Consejo Regulador de Tequila (CRT). Estas áreas contienen información de plantas de agave de diferentes tamaños, concentración y edad.

Cada día de adquisición de imágenes, el equipo UAV fue instalado en campo y después de las comprobaciones del sistema, el UAV inició sus vuelos desde las áreas seleccionadas y previamente ya verificadas en Google EarthTM. Las imágenes adquiridas durante las operaciones de vuelo se descargaron después del aterrizaje y verificaron directamente en campo desde un dispositivo tablet. El equipo de trabajo estaba compuesto por tres personas: un piloto y dos observadores visuales. El UAV adquirió imágenes para este estudio en tres áreas

de interés. Vuelos que fueron ejecutados en diferentes días. Las áreas de vuelo variaron en tamaño de 3.2 a 5.8 ha. Las elevaciones en las tres áreas de adquisición de imágenes oscilaron entre 40 y hasta 120 m sobre el terreno. Sin embargo, cabe mencionar que el proyecto completo para inventariar plantas de agave se llevó a cabo en diferentes fechas del año 2017, ya que el proyecto completo recogió imágenes con una área aproximada de 13,000 ha.



Figura 4.9: Áreas de estudio en el estado de Jalisco, seleccionadas para vuelos con plataforma DJI Phantom 4.

Las alturas de vuelo del UAV deben programarse en relación con la ubicación de lanzamiento en metros sobre el nivel del terreno (Above Ground Level, AGL). Mantuvimos las alturas de vuelo consistentes dentro de cada área de vuelo, pero tuvimos que elegir diferentes alturas de vuelo para cada área debido a la variedad de terreno. El UAV adquirió imágenes entre altitudes de 40 y 120 m sobre el nivel del suelo (AGL) en cada área de interés.

Preprocesamiento :

una verificación de datos es llevada a cabo después de cada vuelo, con el fin de llevar un control de calidad en el procesamiento de las imágenes que se obtienen. De manera general un pre-procesamiento consiste en la manipulación inicial de los datos crudos para corregir las distorsiones de la imagen y eliminar el ruido. Las correcciones que se realizan habitualmente en teledetección son de dos tipos: radiométricas y geométricas.

El realce y mejora son técnicas aplicadas para mejorar la interpretación de la imagen. El ajuste del contraste, composiciones coloreadas y filtrado son algunas de las técnicas aplicadas antes de procesar una ortofoto, las metodologías de mejoramiento de imagen fueron aplicadas en Matlab v. 2012, MathWorks. Con el realce radiométrico se busca un mayor contraste visual. Todas estas técnicas

suavizan o refuerzan el contraste, haciendo que los ND de la imagen se asemejen o diferencien más de los ND de los píxeles que los rodean. Visualmente, esto se traduce en que se difumine la imagen o se resalten determinados hechos contenidos en ella [226], [133]. Cabe resaltar que en el caso que la imagen fuera de muy mala calidad, esta era desechada y se volvía a realizar el vuelo.

Correspondencia de Imagen :

las técnicas de correspondencia de Imagen generan la detección de características por medio del proceso de cálculo, la abstracción de la información de la imagen y toma decisión local en cada punto de la imagen. Este tipo de técnicas verifica si existe una característica de imagen de tipo correspondiente en ese punto. Las Técnicas de correspondencia de Imagen como SURF [60], SIFT [25] y BRIEF [105] son utilizadas en algoritmos como SFM [212]. Los software que se utilizaron en la generación de ortofotos como: Agisoft Photoscan [22], [5], Pix4D [54], Inpho UAS Master [28] utilizan estas técnicas de correspondencia para la generación de una ortofoto.

Integración del Flujo Fotogramétrico :

las fases mas importantes en la integración del flujo fotogramétrico [28], [70] son:

1. La orientación interior: se refiere a la geometría interna de la cámara y define las coordenadas del punto principal y la distancia focal.
2. La orientación exterior: se refiere a la proyección del sistema de coordenadas y la actitud (balanceo, inclinación y orientación), que permiten especificar, para cada imagen individual, la posición real en el espacio. Estos parámetros pueden incluirse en el formato de archivo de imagen intercambiable o Exchangeable Image File Format (EXIF).
3. La aerotriangulación: la cual ofrece posiciones 3D de puntos, medidos en imágenes, en un sistema de coordenadas de control de tierra. Este proceso consiste en generar la superposición correcta de cada imagen, la cual en nuestro caso estaba dada en la horizontal por el 70 % y en la vertical del 30 %.

Modelo Digital de Superficie y Ortomosaico :

en la fotogrametría UAV se identifican dos productos cartográficos tradicionales: los modelos digitales de superficie (MDS) y los ortomosaicos geoposicionados [70], [52]. En nuestro caso el producto que utilizamos para este estudio es el ortomosaico.

Un ortomosaico se refiere al conjunto de imágenes tomadas desde uno o varios sensores ópticos, tomado en las mismas o diferentes condiciones de disparo y presentan áreas de traslape superpuestas entre sí, para ser unidas y combinadas en una sola imagen para ampliar el rango de visión de la escena [41], [70].

Procesamiento de la Imagen :

un espacio de color son las características visuales más utilizadas en aplicaciones

como recuperación de imágenes y clasificación debido a su robustez e implementación [171], [195], [28]. Típicamente el color es percibido a través de un modelo que describe información. El objetivo de un espacio o modelo de color es facilitar la especificación de colores en forma estándar. En esencia un modelo de color es una especificación de un sistema de coordenadas 3-D y un subespacio dentro de ese sistema donde cada color es representado por un punto.

En el caso del espacio de color utilizada en la metodología de detección y separación de capas de plantas y maleza sobre los cultivos monitoreados, se observó que el espacio de color CIE $L^*a^*b^*$, sobre los ortomosaicos generados por este flujo de trabajo, funcionó de una manera correcta en la separación de capas temáticas.

En nuestro estudio, procesamos la información correspondiente a las regiones ubicadas entre 380 nm y 780 nm del espectro electromagnético, es decir de la longitud de onda que corresponde a las bandas roja (R), verde (G) y azul (B). Después, el ortomosaico RGB se transforma a un espacio de color CIE $L^*a^*b^*$. El espacio de color CIE $L^*a^*b^*$ fue desarrollado por la Comisión Internacional de Iluminación (CIE - Commission International de l'Éclairage). Los espacios de color CIE tienen la capacidad de representar las diferencias de color percibidas a través de la distancia euclidiana y se consideran una aproximación del sistema visual humano [28].

Clasificación :

después de la transformación al espacio de color CIE $L^*a^*b^*$, el algoritmo k-means se aplicó sobre el ortomosaico. Este enfoque es un algoritmo de aprendizaje no supervisado, que permite generar diferentes clases. K-means utiliza el criterio de distancia como una medida de similitud y se usa ampliamente en esquemas de clasificación científica y en el campo del reconocimiento de patrones [100], [28]. El criterio de distancia justifica el uso del CIE $L^*a^*b^*$. Según la investigación de Garnica [82], un enfoque no supervisado es una estrategia viable para el monitoreo de agave. Los algoritmos supervisados requieren buenas y suficientes muestras para su entrenamiento y en el caso del estudio de agave, es muy difícil tener muestras sin otras coberturas de la tierra.

Nuestra propuesta utilizó un algoritmo como K-means con un enfoque no supervisado para separar las plantaciones de agave en relación con otras coberturas.

Conteo :

de manera reciente, los métodos para medir y contar la población de plantaciones usando cámaras digitales de alta resolución y visión artificial ha sido introducido para muchos tipos de plantas [151], [197]. Una plataforma UAV puede proporcionarnos una resolución espacial de 3 cm. De ahí que al usar estos equipos podemos diferenciar entre plantas y diferentes tipos de capas mezcladas en un suelo agrícola.

Para automatizar el conteo de plantas debemos buscar técnicas de clasificación y procesamiento de imagen. De acuerdo con la literatura, las técnicas de clasificación supervisadas ofrecen las mejores precisiones, pero el entrenamiento del

clasificador requiere tiempo [111]. El principal inconveniente de este tipo de clasificadores es el tiempo que tarda en entrenar el clasificador. Además, como hay cientos de construcciones, parcelas, elementos diferentes en el terreno, existirán variaciones en las condiciones de iluminación, patrones de sombra y terreno. Sin embargo, en nuestro enfoque de conteo se utilizó un enfoque no supervisado. K-means, seguido del procesamiento de imagen, metodología que funcionó en un gran porcentaje de ortofotos de una excelente manera en la separación de capas de maleza y de agave y con una excelente precisión. Además de ello, también se eligió esta metodología, ya que es la primera vez que se realiza este tipo de auditoria en plantas con plataformas UAVs. No existía, ni existe aún mucha literatura referente a un conteo automático con imágenes en agave y además de ello, se tenía que generar una base de datos de imágenes, para iniciar este tipo de investigación. Al igual que este escenario industrial-agrícola, existen cientos de escenarios similares donde se requiere el recuento de plantas y este enfoque puede ser el principio para trabajar.

4.6. Contribuciones

Durante la última década se ha desarrollado un número creciente de ejemplos de aplicación de UAVs en monitoreo de agricultura. Las aplicaciones en teledetección con UAVs incluyen, la medición del contenido químico, el mapeo de rendimiento y vigor, el monitoreo del estrés, conteo y la evaluación de los impactos de la fertilización en el crecimiento de los cultivos. Sin embargo, aún queda un amplio camino por recorrer y diversos cultivos por monitorear con el fin de mejorar la confiabilidad de la plataforma, la capacidad del sensor y la falta de procedimientos estandarizados para procesar grandes volúmenes de datos. Durante años se ha intentado obtener una cuantificación real sobre cultivos de agave en la zona de denominación de origen en México, con fines de planeación de la cadena productiva en la agroindustria tequilera; muchos intentos han sido fallidos por muchos factores involucrados.

El monitoreo de plantaciones de agave con plataformas UAV, es una solución factible, alcanzable y de bajo costo, ya que toda la información que arroja este tipo de monitoreo está debidamente sustentada y verificada a partir de datos reales en campo y en un ordenador.

Esta información servirá de base para una planeación, lo cual llevara a romper con ciclos de abundancia y escaseo del agave, lo que ha provocado fluctuaciones en los límites permitidos de precios del agave para la elaboración del tequila y otros azúcares. Otras áreas que cuidar en el presente y futuro son las estrictas regulaciones de la aviación y la simple falta de interés de los agricultores que pueden obstaculizar la adopción de este tipo de plataformas en el monitoreo de los cultivos de agave. Afortunadamente, se espera que con el avance de la tecnología de las plataformas UAVs, todas estas áreas generen nuevos diseños de cámaras, menores costos, métodos y procedimientos mejorados de procesamiento de imágenes y un mayor número de estudios experimentales de sensores remotos basados en teledetección con plataformas UAV para aplicaciones sobre el agave y agrícolas en general. Todo este esfuerzo generado

habrá de sembrar fruto y una mayor valoración de los beneficios de estos sistemas en agricultura y monitoreo.

4.6.1. A Multi-Disciplinary Approach to Remote Sensing through Low-Cost UAVs

Gabriela Calvario, Basilio Sierra, Teresa E. Alarcón, Carmen Hernández y Oscar Dalmau

El uso de vehículos aéreos no tripulados (UAV) con base en el uso de sensores remotos han generado la oportunidad de adquirir y monitorear datos a un bajo costo. El documento que se presenta a continuación informa sobre la experiencia relacionada con el análisis de cultivos de agave con una plataforma UAV de bajo costo.

La publicación y los derechos de autor corresponden a la revista Multidisciplinary Digital Publishing Institute. La versión en línea de la revista es la siguiente URL: <https://www.mdpi.com/1424-8220/17/6/1411/htm>

Article

A Multi-Disciplinary Approach to Remote Sensing through Low-Cost UAVs

Gabriela Calvario ^{1,*}, Basilio Sierra ¹, Teresa E. Alarcón ², Carmen Hernandez ¹ and Oscar Dalmau ³

¹ Departamento de Ciencias de la Computación e Inteligencia Artificial, Universidad del País Vasco UPV/EHU, 20018 Donostia-San Sebastián, Spain; b.sierra@ehu.eus (B.S.); mamen.hernandez@ehu.es (C.H.)

² Centro Universitario de los Valles, Carretera Guadalajara - Ameca Km. 45.5, CP 46600 Ameca, Jalisco, México; teresa.alarcon@profesores.valles.udg.mx

³ Centro de Investigación en Matemáticas, Jalisco SN, Col. Valenciana, CP 36240, Guanajuato, México; dalmau@cimat.mx

* Correspondence: gcalvario001@ikasle.ehu.eus

Academic Editor: Felipe Gonzalez Toro

Received: 31 March 2017; Accepted: 9 June 2017; Published: 16 June 2017

Abstract: The use of Unmanned Aerial Vehicles (UAVs) based on remote sensing has generated low cost monitoring, since the data can be acquired quickly and easily. This paper reports the experience related to agave crop analysis with a low cost UAV. The data were processed by traditional photogrammetric flow and data extraction techniques were applied to extract new layers and separate the agave plants from weeds and other elements of the environment. Our proposal combines elements of photogrammetry, computer vision, data mining, geomatics and computer science. This fusion leads to very interesting results in agave control. This paper aims to demonstrate the potential of UAV monitoring in agave crops and the importance of information processing with reliable data flow.

Keywords: UAV; data mining; computer vision; geomatics; agave monitoring

1. Introduction

Remote sensing (RS) through Unmanned Aerial Vehicles (UAVs), is not only a new topic of research in the civil field, but also an alternative to conventional platforms, for the acquisition of data with infinite possibilities. Some examples of UAVs are: vegetation monitoring [1], forest inspection, mapping of territorial coverage [2], disaster response, construction monitoring [3], industrial and residential inspection, three-dimensional photogrammetric models, hydrocarbon pipeline monitoring and coastal surveillance [4]. Regarding the advantages of UAV, we also can highlight the importance to facilitate activities that have a detrimental effect on humans. Currently, we can remotely execute risk tasks, such as flying over contaminated areas, or places with high levels of radiation or in danger of collapse.

The support provided to agriculture through UAVs can be used to create alternatives with greater versatility and low cost. UAV technology in conjunction with other disciplines and fields of research are generating new applications in agriculture, such as crop identification, monitoring and mapping of cultivated areas, pest detection, crop yield estimation and prediction of anomalies. The check schedule in the field is more adjustable for the user. Therefore, monitoring crops through UAV can be a good tool for decision-making, management and planning of public policies in the agriculture. As the satellite sensors, UAV also allows for obtaining reliable data but in a more economical way.

Another important fact that has a direct impact on agriculture monitoring is climate change. This fact generates the need for low-cost and multitemporal monitoring. The increase of CO₂ leads to a remarkable change in the growth and maturation of vegetation [5], which causes problems in the crops. Through a UAV remote sensor, it is possible to detect the location of the weed within an agricultural

field, and, consequently, the right herbicide in the correct amount can be applied in a specific area. UAV sensors with high spatial resolution also generate data, which allows for discriminating different types of weeds, crops and textures.

Satellite imagery and aerial photography play an important role in agricultural monitoring; they are a robust research tool for monitoring and evaluating large scale crop inventory; however, there is a limitation: free sources of satellite imagery do not provide images with enough spatial resolution [6] as those given by the UAVs.

Precision farming requires frequent information on crop conditions. UAV is an adequate tool to systematically provide information with a high resolution and low-cost in real time. However, an important fact to be taken into account is that the farmer is often not very familiar with the use of images [6]. Another aspect to consider is that the flight session of the UAVs is limited by the battery charge, which leads to short periods of use and limited areas. In this respect, it is worth mentioning their vulnerability to cyber attacks and being knocked down, and their high risk of mismanagement by the users [7]. Nowadays, there is an increasing use of UAVs in the monitoring area, and the market for ultra-light cameras with spectral and hyperspectral ranges [8,9] has grown. The use of technologies such as special sensors [10,11], synthetic aperture radar and thermal sensors in UAVs is already remarkable. The growth of digital image processing tools is also observed (for example, Skycatch [12], dronedeploy [13], among others). A report about UAV sales estimated about 13.22 billion dollars in 2016 year and speculated an increase of up to 28.27 billion dollars by 2022 [14].

The relationship between computer vision, data mining [15], geomatics, computer science and photogrammetry are generating a very interesting multidisciplinary environment in the extraction of information and its treatment by the means of UAVs [16].

Remote sensing technology allows a feasible solution for crop monitoring. This technology together with computer science leads to monitoring, detecting and classifying different types of crops. In Ref. [17], six different supervised classifiers are implemented with the purpose of monitoring and classifying corn crops through RapidEye images. The studied supervised techniques were: Maximum Likelihood [18,19], Mahalanobis and Minimum distances [20], Spectral Angle Mapper [21,22], the Parallelepiped method [23] and SVM (support vector machine) [24–26]. Winner-takes-all (WTA) is the final classifier [27], which is an ensemble based classifier, and, for the research in [17], WTA considers the voting derived from the six mentioned techniques. In [28–30], an artificial neural network (ANN) is used to predict vegetation parameters and crop yields using data from satellite images. Vegetation indices are widely used to enhance the vegetation information in satellite images with the purpose of monitoring [31,32]. The mentioned works face the precision problem during the monitoring, detection and classification process of the crops. The problems are not only due to selected classifiers, but also due to the spatial resolution of the satellite sensor, and, even though this parameter is improving constantly because of the new technology, the access to high spatial resolution data also is high-cost. Therefore, achieving a high resolution is a problem for satellite images users in the agriculture. On the contrary, through UAVs, it is possible to achieve high spatial resolution at a low-cost in comparison with satellite sensors.

Agriculture is a very important item for the economy of any country. In Mexico, agriculture plays an important role, so the monitoring of the crops using the new technology is a useful tool nowadays for the farmer's job.

Agave is one of the important crops of Mexico. Agave is a plant with an American origin, with long leaves in a rosette shape (see Figure 1). Native to the hot and arid regions of Mexico and the Southwestern United States, the *Agave Tequilana Weber* plant is the one used to elaborate tequila, an original Mexican drink [33].

Ref. [34] reports the study of Agave plants through LANDSAT 7 imagery using supervised and unsupervised classification techniques. They used regression and classification tree methods and achieved 70% of Agave accuracy. The authors in Garnica et al. [34] faced the following problems: plant density in agave crops is not homogeneous, agave occurs in many soil types, humidity resulted

in a problem for satellite imagery classification, and the agave is camouflaged with other covers like low tropical forest and grasslands, mainly, [34]. To mitigate the influence of all of these problems in the classification process of agave, a possible solution is the use of UAVs, enabled with high resolution cameras.



Figure 1. Agave plants and crops.

In this work, we focus on developing a solution for the monitoring of agave crops, taking advantage of the opportunity to obtain a high spatial resolution, which is provided through low-cost UAVs. For the classification, we use an unsupervised approach: *k*-means. During the process, we obtain ortho-mosaics, which allow us to separate plants from other elements in the cultivation. The proposed approach let us perform an inspection of agave crops; in this way, detailed monitoring that helps agave farmers in their daily work can be done. It is worth mentioning that the proposed approach could be used as well for other kinds of plants.

The rest of the paper is organized as follows: Materials and Methods are introduced in Section 2; the proposed Method is presented in Section 3; Section 4 presents the evaluation of the proposed approach, and in the final section 5, conclusions are given and lines of future work are envisaged.

2. Materials and Methods

2.1. Work-Flow

In order to describe our research, the photogrammetric process is first presented in general terms, taking into account the state of the art. Then, a new methodology for classifying agave plants is explained. The methodology is based on photogrammetry and a *k*-means algorithm. Figure 2 illustrates all steps of our methodology.

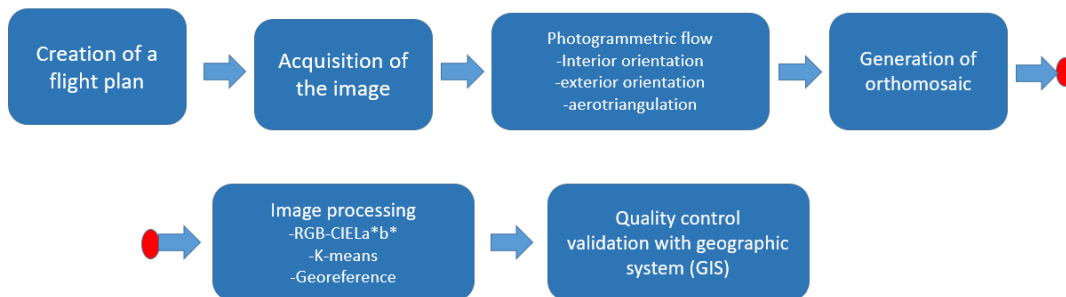


Figure 2. Work-flow system.

2.2. Study Areas and UAV Flight Plan

This study looked at four agave areas managed by the Tequila Regulatory Council (CRT). These areas contain information of agave plants of different sizes, concentration and years of age. The area **a**, represented in red in Figure 3, has 3.2 ha approximately and its over flight coordinates

are $20^{\circ}56'4.76''$ N, $104^{\circ}6'23.70''$ W. The area **b**, in purple, on the top right-hand side, has 5.8 ha and coordinates of $20^{\circ}51'28.24''$ N, $103^{\circ}46'48.92''$ W. The areas in blue and green are indicated with **c**, on the bottom right of the Figure 3, and they represent around 4.6 ha of land with over flight coordinates $20^{\circ}45'14.24''$ N, $103^{\circ}39'57.03''$ W. The immediate areas, of the previous areas, are included in this study.



Figure 3. Selected study areas. Regions in red and blue depict areas **a** and **b**, respectively, regions in blue and green correspond to area **c**.

The UAV flight plan was checked in advance via Google Earth (Google Inc-DigitalGlobe 2016, Mountain View, CA, USA), the take-off and landing area were specified. The flight time was about 15 min. We performed flight at different altitudes between 40 mts and 100 mts. The flight of the UAV allowed us to obtain the collection of images and their approximate coordinates. It is known that the conditions of the area, weather and the global positioning system generate errors in the image. For this reason, geodetic control points (GCPs) were distributed in the region of interest using the differential GPS.

The GCPs provide precision and at least three points are required. However, in our case, we used eight different control points for each studied area, with the aim of minimizing the error in georeferencing [35] (see Figure 4).



Figure 4. Ground Control Points, (GCPs), generation.

2.3. Description of the Sensor

For the image acquisition, we used a quad-copter Phantom 4 (DJI, Shenzhen, China), see Figure 5. It is low cost equipment, and it has an obstacle detection system of 0.7 to 15 m. Its operating environment must have good illumination to meet the objective. It has Global Positioning System-Global Navigation Satellite System, (GPS-GLONASS) mode, stabilization of 3 axes with a degree of inclination of -90° to $+30$ and axes of horizontal movement, vertical and rotation. The operating distance is about 3 km, and the quad-copter always flies within a clear line of sight for safety reasons. In addition to the automatic flight plan, all of the members of the team also have a manual control of the UAV and therefore the level of skills and knowledge about the manual control should be high, due to the setbacks that can arise directly in the acquisition area.

The quad-copter has a sensor sensitive to Red (R), Green (G), Blue (B) light, (RGB sensor), which allows the capture of image size of 4000×3000 , from a height predefined by the user. The use of stabilizers allows absorbing the vibration and stabilizes the position of the sensor. The stabilizer is mounted on a gimbal platform that allows for obtaining the searched-for nadir in the images. Table 1 summarizes the main characteristics of our UAV.




Figure 5. Low cost equipment and field work in selected study areas. (a) Agave crop area; (b) Unmanned Aerial Vehicle, (UAV); (c) Remote Controller.

Table 1. General characteristics of Unmanned Aerial Vehicle (UAV) [36].

Parameter	Value
Sensor RGB	6.25 mm \times 4.68 mm
Weight	25 grams
Sensor	12.4 Megapixels
Lens	FOV 94°
Focal length	20 mm (35 mm format equivalent) $f/2.8$ focus at ∞
Pixel size	1.5625 μm
Measurement of image	4000×3000
Image Type	JPEG, DNG (RAW)
Temperature	0° to 40°

2.4. Camera Calibration

We used a chessboard pattern approach for camera calibration and we obtained 16 calibration images in different orientations. For this purpose, we used the Camera Calibration Toolbox of Matlab (v. 2012, MathWorks, Inc., Natick, MA, USA) [37,38]. The results of camera calibration process are shown in Table 2.

Table 2. Camera calibration parameter values [39].

Parameter	Values
Focal length	$(2.2495 \times 10^3, 2.2498 \times 10^3)$
Principal point coordinates	$(2.0159 \times 10^3, 1.5088 \times 10^3)$
Skew	-7.2265
Lens distortion	
Tangential Distortion coefficients	$(0.0011, 5.6749 \times 10^{-4})$
Radial distortion coefficients	$(-0.0160, -0.0336)$
Num. Patterns	16

The calibration parameters allows us to extract the information of the image. The data generated by the calibration process provide a mapping from the image to the real-world dimensions [40].

The parameter that indicates the size of the pixel is called Ground Sample Distance (GSD), and it can be calculated through the Ground Sampling Distance Calculator tool by Pix4D in.

The computation of the size is done according to the following equation:

$$GSD = \frac{Sw \cdot H \cdot 100}{Fr \cdot imW} \quad (1)$$

where GSD is the Ground Sampling Distance (centimeters/pixel) and represents the distance between two consecutive pixel centers, Sw denotes the sensor width of the camera (millimeters), H is the flight height (meters), Fr is the real focal length of the camera (millimeters) and imW is the image width (pixels). In our case, $Sw = 6.25$ mm, the average of the flight height was $H = 60$ m, $Fr = 3.6$ mm and the $imW = 4000$ pixels, and, therefore, the distance between the centers of two pixels is 2.6 cm. For $H \in [40, 80]$, the $GSD \in [1.74, 3.47]$. The variation in altitude in the previous range did not affect the quality of the agave detection. Therefore, we suggest to use $H = 60$ m, in order to avoid obstacles during the flight and, in some sense, increase the time flight using the same battery.

2.5. Photogrammetric Flow

In order to obtain a good result in the image processing, a set of processing steps must be carried out [35]. Currently, in the market, there are a variety of photogrammetric software packages that can perform processes on the UAV images. These packages usually use an algorithm called *structure from motion* that is a set of techniques of photogrammetry and computer vision [41]. In our case, we use the software called Inpho UAS Master 6.0 (Trimble Inc, Sunnyvale, CA, USA) [42] and the application ExifTool that allows to read the metadata of a variety of photographic formats [43].

The starting point for a typical photogrammetric flow are the images set acquired during the flight. In general, all images are georeferenced [44].

In the integration process of photogrammetric flow, the most important phases are:

1. The interior orientation: it refers to the internal geometry of the camera and defines the coordinates of the principal point and focal length.
2. The exterior orientation: [45] It refers to coordinates system projection and attitude (roll, pitch and yaw), which allow for specifying, for each single image, the real position in space. These parameters may be included to Exchangeable Image File Format (EXIF-metadata) [43].
3. The aerial triangulation: it delivers 3D positions of points, measured on images, in a ground control coordinate system. This process consists in generating the correct overlap of each image [46], which, in our case, was in the horizontal of 70% and in the vertical of 30%.

We use the Root Mean Square Error (RMSE), to measure the quality of the aerial triangulation. This indicator is based on the residuals of the image coordinates and the ground coordinates. Taking into account conventional aerial photography, an RMSE of up to 1 pixel is desirable; however,

according to Laliberte et al. [47], and due to larger distortion of the imagery obtained with low-cost cameras, an acceptable RMSE error is considerable of 1.5 to 2 pixels from the aerial triangulation for UAV imagery (see Table 3). Once aerial triangulation process is finished, a digital terrain model (DTM) can be generated by a dense image matching. The ortho-mosaic can be generated from UAV-based images with known camera parameters and the obtained DTM (see Figure 6). The accuracy values for DTM were: 0.08 m for the area **a**, 0.11 m for the area **b** and 0.07 m for the area **c**. The described procedure is automated by Inpho UAS Master, (Trimble Inc, Sunnyvale, CA,USA) in order to improve the quality of the image.

As a result of this process, we obtain a georeferenced ortho-mosaic image in GeoTIFF file format.

Table 3. Root Mean Square Error (RMSE) aerial triangulation.

Study Areas	Images Low-Cost Camera	Number of Flight Lines	Image Resolution (cm)	RMSE (Pixels/cm)
a	146	10	2.60	1.4
b	140	8	1.63	1.7
c	266	18	2.10	1.6




Figure 6. Ortho-mosaics processed with Inpho UAS Master corresponding to: (a) area **a**; (b) area **b**. Images in panels (c,d) correspond to polygons in the study area **c**.

3. Image Processing

In our approach, we process the information corresponding to the regions located between 380 nm and 780 nm of the electromagnetic spectrum, i.e., the red (R), green (G) and blue (B) bands. The RGB ortho-mosaic is transformed into the International Commission on Illumination (Commission Internationale de l'éclairage), CIE $L^*a^*b^*$ color space. The CIE $L^*a^*b^*$ was developed by the International Commission on Illumination (CIE - Commission Internationale de l'Éclairage). CIE color spaces have the capacity to represent perceived color differences across Euclidean distance and are considered as an approximation of the human visual system [48]. For that reason, CIE color spaces are perceptually uniform. In order to convert from the RGB color space to the CIE space $L^*a^*b^*$, it is first necessary to obtain the so-called artificial primaries, denoted as X, Y, Z [48]. The CIE XYZ space is the result of direct measurements on the human eye made in the late 1920s by W. David Wright [49] and John Guild [50] and serves as the basis for other color representations. The values of XYZ are calculated by means of linear transformation of the RGB given by the Expression (2):

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0.4125 & 0.3576 & 0.1804 \\ 0.2125 & 0.7154 & 0.0721 \\ 0.0193 & 0.1192 & 0.9502 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix}. \quad (2)$$

In (2), the values of R, G and B are in the interval [0,1]. The elements of the transformation matrix depend on the type of selected reference white [48,51], and these values are tabulated in [48]. We considered D65 reference white [48], which is usually used for standard RGB monitors (sRGB) [52]. The values in the space $L^*a^*b^*$ are calculated from the XYZ, by a non-linear transformation, see Equations (3)–(5):

$$L^* = 116 \left(\sqrt[3]{\frac{Y}{Y_0}} \right) - 16, \quad (3)$$

$$a^* = 500 \left(\sqrt[3]{\frac{X}{X_0}} - \sqrt[3]{\frac{Y}{Y_0}} \right), \quad (4)$$

$$b^* = 200 \left(\sqrt[3]{\frac{Y}{Y_0}} - \sqrt[3]{\frac{Z}{Z_0}} \right). \quad (5)$$

In Equations (3)–(5) X_0 , Y_0 and Z_0 are the values corresponding to the RGB vector [1,1,1], i.e., the white color in RGB color space. For details of the implementation, see the information described in <http://www.brucelindbloom.com/>.

In Figure 7, the examples of the results are shown corresponding to the color space CIE $L^*a^*b^*$.




Figure 7. Ortho-mosaics represented in CIE $L^*a^*b^*$ color space: (a) Ortho-mosaic corresponding to area a; (b) Ortho-mosaic corresponding to area b. Images in panels (c,d) correspond to polygons in the study area c.

After the color space transformation, the k-means algorithm is applied on the CIE $L^*a^*b^*$ ortho-mosaic. This approach is a non-supervised learning algorithm, which allows for generating different class groups. k-means uses the distance criterion as a measure of similarity, and it is widely used in scientific classification schemes and in the field of pattern recognition [53]. The criterion distance justifies the use of the CIE $L^*a^*b^*$.

According to the research in [34], an unsupervised approach is a feasible strategy for agave monitoring. Supervised algorithms require good samples and enough samples for the training step, and, in the case of agave study, it is very difficult to have training samples without other land covers. This being the reason, in our proposal, we use an unsupervised algorithm in order to separate the plantations of agave in relation to other land covers.

The k-means algorithm [54] allows us to create two segmented layers: agave plant and weeds.

Some authors addressed the computational limitations of k-means [55]. In order to improve the performance of the k-means, we use a parallel approach [56].

In Figure 8, an example of the results of classification through k-means is depicted. The image represented in Figure 8 a,b corresponds to regions located in study areas b and c, indicated in Figure 3.




Figure 8. Example of classification results by *k*-means. (a) Image sample of the study area **b**; (b) Image sample of the study area **c**; (c) Detected agave plants in the sample represented in panel (a); (d) Detected agave plants in the image represented in panel (b); (e) Detected weeds in the sample represented in panel (a); (f) Detected weeds in the image represented in panel (b).

After the classification step through *k*-means, we create a copy of the geographic data of our ortho-mosaic. The geographic data are extracted from the GeoTIFF file [57,58]. The created copy is annexed to the file created by means of *k*-means. We used the Matlab (v.2012) implementation of *k*-means and GeoTIFF procedures. The programs that we elaborated in Matlab allows users to fix all necessary parameters. We carried out several experiments in order to find the best number of classes, *k*, for the *k*-means algorithm. According to our results, $k = 3$ was the best value of *k*, because, with this value, the agave plants and weeds were best discriminated. The third group detected regions not relevant for our application. In our study, we use the computer workstation with a high performance processors: Intel® Xeon® (Intel Corporation, Santa Clara, CA, USA) E3-1280 v5 3.7 GHz, up to 4 GHz with Intel Turbo Boost Technology, 8 MB cache, 4 cores, with Ram memory 32 GB DDR4 and with a Serial ATA, hard drive (SATA technology, Beaverton, OR, USA) with 2 TB storage [55].

4. Evaluation of Methodology

The accuracy of the processing in the described methodology depends mainly on three aspects: on the resolution of the UAV sensor, on the photogrammetric process and on the georeference. In order to evaluate our proposal, 25 samples were taken at different sites around the area of interest: 10 of them represent weeds and 15 agave plants. Each sample was obtained with relative accuracy planimetric [59] through the georeferenced ortho-mosaic, comparing this image with segmented images of agave plants

and weed on a geographic information system QGIS (Quantum Geographic Information System v2.162, Project of the Open Source Geospatial Foundation, Beaverton, OR, USA). With this procedure, we gather the information about the position of plants or weed areas into conformance with the Universal Transverse Mercator (UTM) map projection [60].

Figures 9 and 10 depict how we can validate the results obtained from the segmentation of agave plants and weed.

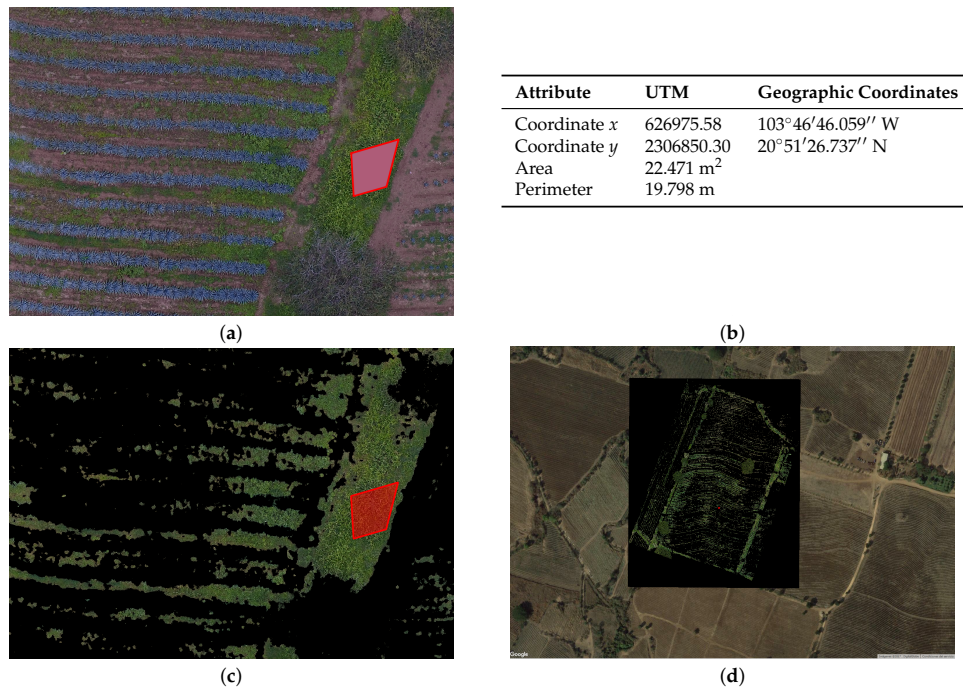


Figure 9. (a) example of sample weed, showed in the QGIS system (polygon in red), (b) table with the object attributes described by QGIS, (c) segmentation of the weed sample by *k*-means (polygon in red), (d) full study area [b](#).

First, we create random polygons of agave and weed. Then, we apply the identify tool in QGIS on every single polygon, and we verify the information output and the attributes for both agave and weed (see tables in Figures 9b and 10b).

After checking the spatial information, the segmentation results of the selected area are verified in the field by the Tequila Regulatory Council (CRT) in Mexico.

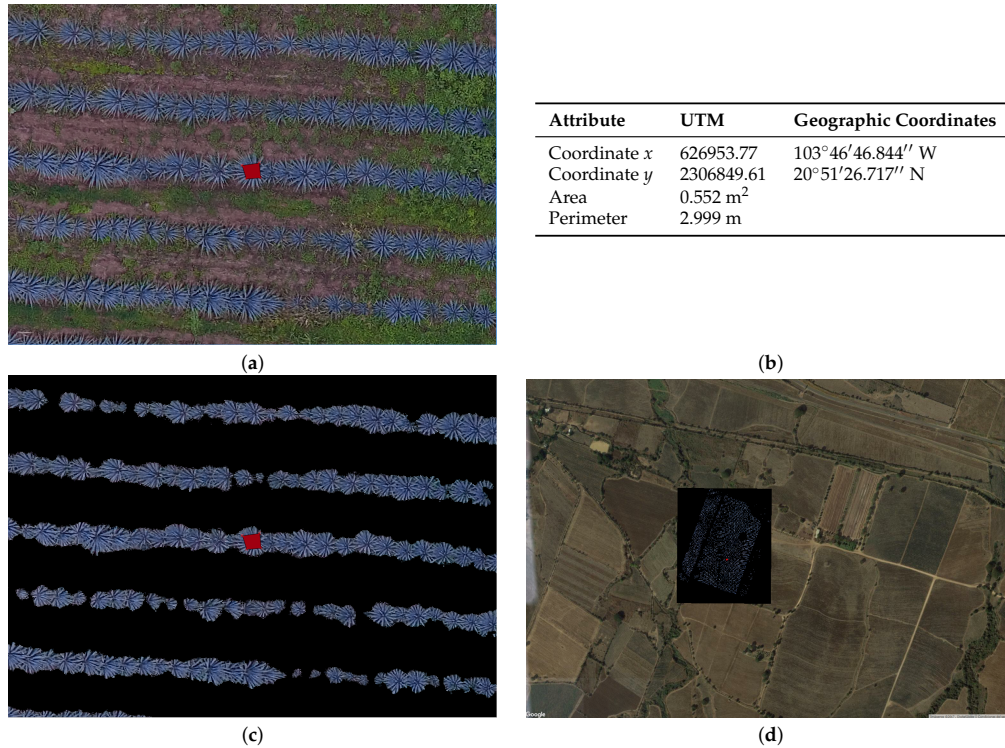


Figure 10. (a) position of agave plants in the QGIS system; (b) table with the object attributes described by QGIS; (c) sample of detected plants; and (d) full study area **b** described in Section 2.2, plants' segmentation, shown in Google earth.

It is worth mentioning that this process has been applied to all of the acquired images. In total, we processed four ortho-mosaics, and, for all of them, we obtained a valuable result. Table 4 contains the numerical evaluation of the segmentation of the agave plants by k-means. As it can be seen, obtained results are all over 99.999% in accuracy when compared to the human made process, which has been considered by the Agave Regulation Agency as a very good result. Study areas in column 1 correspond to the areas described in Section 2.2.

Figures 11 and 12 illustrate an example of the segmentation results. In both figures, (a) represents the studied land part, and (b), (c) and (d) represent the overlap between the original and segmented images.

Table 4. Plant detection accuracy.

Study Areas	Precision	Overall Accuracy
a	0.99995	0.99994
b	0.99998	0.99998
c	0.99961	0.99961
d	0.99991	0.99998




Figure 11. Detection of agave plants and weed corresponding to the study area **c** Described in Section 2.2: (a) Original ortho-mosaic; (b) Agave detection bottom-top; (c) Agave detection left-right; and (d) Detected weed.




Figure 12. Detection of agave plants and Weed corresponding to the study area **b** Described in Section 2.2: (a) Original ortho-mosaic; (b) Agave detection top-bottom; (c) Agave detection left-right; and (d) Detected weed.

5. Conclusions

In this work, we proposed a methodology for agave crop monitoring. The methodology combines remote sensing through low-cost UAV, photogrammetry, computer vision, data mining, geomatics and

computer science. This study has demonstrated the potential development of low-cost unmanned aerial vehicles in the area of agave monitoring. We achieved excellent detection results, which is demonstrated by the obtained precision value of 99%. The monitoring of the vegetation through UAV will allow, in the near future, the generation of very important data for the study of plants such as agave. The results of this study is the base for the geospatial database, which we are building to analyze the behavior of the agave plants. At the moment, we work together with the Tequila Regulatory Council in Mexico. To the best of our knowledge, this is the first application that integrates remote sensing based on low cost UAV, image processing and pattern recognition techniques for georeferenced images for agave crop monitoring.

As future work, an extension of the presented approach is envisaged, in order to apply it to wider areas of agave and help farmers in other places different to those used in the experimental phase. The presented approach could be applied as well to supervise other types of plants; an improvement of the model is needed to this end, in order to adapt to the characteristics of the plant of interest.

Acknowledgments: We wish to acknowledge the Consejo Nacional de Ciencia y Tecnologia (CONACYT) for its financial support to the PhD studies of Gabriela Calvario. We are grateful to Cubo Geoespacial S.A .de C.V. and special to Ing. Jordan Martinez for the stimulus to this work, more information about this Company is available at: <http://www.cubogeoespacial.com/>. In addition, we are grateful to the support of the Tequila Regulatory Council (CRT), which has allowed us to monitor several crops. This paper has been supported by the Spanish Ministerio de Economía y Competitividad, contract TIN2015-64395-R (MINECO/FEDER, UE), as well as by the Basque Government, contract IT900-16. This work was also supported in part by CONACYT (Mexico), Grant 258033.

Author Contributions: Gabriela Calvario conceived the idea of the paper; Basilio Sierra, Teresa E. Alarcón and Oscar Dalmau helped in the experimental design and writing process; Gabriela Calvario performed the experiments; Carmen Hernández analyzed the data and the results of the experiments. All the authors have taken part in the elaboration of this document.

Conflicts of Interest: The authors declare no conflict of interest.

References

1. Aasen, H.; Burkart, A.; Bolten, A.; Bareth, G. Generating 3D hyperspectral information with lightweight UAV snapshot cameras for vegetation monitoring: From camera calibration to quality assurance. *ISPRS J. Photogramm. Remote Sens.* **2015**, *108*, 245–259.
2. Horcher, A.; Visser, R.J. Unmanned aerial vehicles: Applications for natural resource management and monitoring. In Proceedings of the Council on Forest Engineering Conference, Hot Springs, AR, USA, 27–30 April 2004.
3. Tsach, S.; Penn, D.; Levy, A. Advanced technologies and approaches for next generation UAVs. In Proceedings of the International Council of the Aeronautical Sciences, Congress ICAS, Toronto, ON, Canada, 8–13 September 2002.
4. Gonçalves, J.; Henriques, R. UAV photogrammetry for topographic monitoring of coastal areas. *ISPRS J. Photogramm. Remote Sens.* **2015**, *104*, 101–111.
5. Kimball, B.; Idso, S. Increasing atmospheric CO₂: Effects on crop yield, water use and climate. *Agric. Water Manag.* **1983**, *7*, 55–72.
6. Seelan, S.K.; Laguette, S.; Casady, G.M.; Seielstad, G.A. Remote sensing applications for precision agriculture: A learning community approach. *Remote Sens. Environ.* **2003**, *88*, 157–169.
7. Weibel, R.; Hansman, R.J. Safety considerations for operation of different classes of uavs in the nas. In Proceedings of the AIAA 3rd “Unmanned Unlimited” Technical Conference, Workshop and Exhibit, Chicago, IL, USA, 20–22 September 2004; p. 6421.
8. Tetracam INC. Available online: <http://www.tetracam.com/Products1.htm> (accessed on 22 March 2017).
9. Resonon Systems. Available online: <http://www.resonon.com> (accessed on 25 March 2017).
10. Zhou, G.; Yang, J.; Li, X.; Yang, X. Advances of flash LiDAR development onboard UAV. *ISPRS-Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* **2012**, *39*, 193–198.
11. Geodetics Incorporated. Available online: <http://geodetics.com/wp-content/uploads/2016/10/Geo-MMS.pdf> (accessed on 22 March 2017).
12. Skycatch. Available online: <https://www.skycatch.com/> (accessed on 22 March 2017).

13. Dronedeploy. Available online: <https://www.dronedeploy.com/> (accessed on 22 March 2017).
14. Marketsandmarkets. Unmanned Aerial Vehicle (UAV) Market, by Application, Class (Mini, Micro, Nano, Tactical, MALE, HALE, UCAV), SubSystem (GCS, Data Link, Software), Energy Source, Material Type, Payload and Region—Global Forecast to 2022. Available online: <http://www.marketsandmarkets.com/Market-Reports/unmanned-aerial-vehicles-uav-market-662.html> (accessed on 22 December 2016).
15. Andersson, P.J. Hazard: A Framework Towards Connecting Artificial Intelligence And Robotics. Available online: <https://www.cs.auckland.ac.nz/courses/compsci777s2c/ijcai05.pdf#page=5> (accessed on 15 June 2017).
16. Colomina, I.; de la Tecnologia, P.M. Towards A New Paradigm for High-Resolution Low-Cost Photogrammetry and Remote Sensing. In Proceedings of the International Society for Photogrammetry and Remote Sensing, (ISPRS) XXI Congress, Beijing, China, 3–11 July 2008; pp. 1201–1206.
17. Ustuner, M.; Esetlili, M.T.; Sanli, F.B.; Abdikan, S.; Kurucu, Y. Comparison of crop classification methods for the sustainable agriculture management. *J. Environ. Prot. Ecol.* **2016**, *17*, 648–655.
18. Gould, W.; Pitblado, J.; Sribney, W. *Maximum Likelihood Estimation With Stata*; Stata Press: College Station, TX, USA, 2006.
19. Mather, P.; Tso, B. *Classification Methods for Remotely Sensed Data, Second Edition*; CRC Press: Boca Raton, FL, USA, 2009.
20. Richards, J.A. *Remote Sensing Digital Image Analysis*; Springer: Berlin, Germany, 2013.
21. Kruse, F.A.; Lefkoff, A.B.; Boardman, J.W.; Heidebrecht, K.B.; Shapiro, A.T.; Barloon, P.J.; Goetz, A.F.H. The Spectral Image Processing System (SIPS)—Interactive Visualization and Analysis of Imaging Spectrometer Data. *Remote Sens. Environ.* **1993**, *44*, 145–163.
22. Kruse, F.A.; Lefkoff, A.B.; Boardman, J.W.; Heidebrecht, K.B.; Shapiro, A.T.; Barloon, P.J.; Goetz, A.F.H. Comparison of Spectral Angle Mapper and Artificial Neural Network Classifiers Combined with Landsat TM Imagery Analysis for Obtaining Burnt Area Mapping. *Sensors* **2010**, *10*, 1967–1985.
23. Mather, P.M.; Koch, M. *Computer Processing of Remotely-sensed Images: An Introduction*, 4th ed.; Wiley-Blackwell: Chichester, UK, 2011.
24. Cortes, C.; Vapnik, V. Support-Vector Networks. *Mach. Learn.* **1995**, *20*, 273–297.
25. Huang, C.; Davis, L.S.; Townshend, J.R.G. An Assessment of Support Vector Machines for Land Cover Classification. *Int. J. Remote Sens.* **2002**, *23*, 725–749.
26. Melgani, F.; Bruzzone, L. Classification of Hyperspectral Remote Sensing Images with Support Vector Machines. *Geosci. Remote Sens. IEEE Trans.* **2004**, *42*, 1778–1790.
27. Zhang, C.; Xie, Z. Data fusion and classifier ensemble techniques for vegetation mapping in the coastal Everglades. *Geocarto Int.* **2014**, *29*, 228–243.
28. Pinter P.J., Jr.; Hatfield, J.L.; Schepers, J.S.; Barnes, E.M.; Moran, M.S.; Daughtry, C.S.; Upchurch, D.R. Remote sensing for crop management. *Photogramm. Eng. Remote Sens.* **2003**, *69*, 647–664.
29. Yu, K.; Li, F.; Gnyp, M.L.; Miao, Y.; Bareth, G.; Chen, X. Remotely detecting canopy nitrogen concentration and uptake of paddy rice in the Northeast China Plain. *ISPRS J. Photogramm. Remote Sens.* **2013**, *78*, 102–115.
30. Farifteh, J.; Van der Meer, F.; Atzberger, C.; Carranza, E. Quantitative analysis of salt-affected soil reflectance spectra: A comparison of two adaptive methods (PLSR and ANN). *Remote Sens. Environ.* **2007**, *110*, 59–78.
31. Motohka, T.; Nasahara, K.N.; Oguma, H.; Tsuchida, S. Applicability of green-red vegetation index for remote sensing of vegetation phenology. *Remote Sens.* **2010**, *2*, 2369–2387.
32. Tucker, C.J. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sens. Environ.* **1979**, *8*, 127–150.
33. Bautista-Justo, M.; García-Oropeza, L.; Barboza-Corona, J.; Parra-Negrete, L. *El Agave Tequilana Weber y la Producción de Tequila*; Red Acta Universitaria: Guanajuato, Mexico, 2000.
34. Garnica, J.F.; Reich, R.; Zuñiga, E.T.; Bravo, C.A. Using Remote Sensing to Support different Approaches to identify Agave (Agave tequilana Weber) CROPS. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* **2008**, *XXXVII*, 941–944.
35. Vallet, J.; Panissod, F.; Strecha, C.; Tracol, M. Photogrammetric performance of an ultra light weight swinglet UAV. In Proceedings of the AV-g (Unmanned Aerial Vehicle in Geomatics) Conference, Zurich, Switzerland, 14–16 September 2011.
36. DJI. Available online: <https://www.dji.com/phantom-4/info> (accessed on 23 February 2017).

37. Bouguet, J.Y. Camera Calibration Toolbox for Matlab. Available online: http://www.vision.caltech.edu/bouguetj/calib_doc/ (accessed on 25 April 2017).
38. MathWorks. Single Camera Calibration App. Available online: <https://es.mathworks.com/help/vision/ug/single-camera-calibrator-app.html> (accessed on 25 April 2017).
39. Gašparović, M.; Gajski, D. Two-step camera calibration method developed for micro UAV's. In Proceedings of the XXIII ISPRS Congress, Prague, Czech Republic, 12–19 July 2016.
40. Bath, W.; Paxman, J. UAV localisation & control through computer vision. In Proceedings of the Australasian Conference on Robotics and Automation, Sydney, Australia, 7 December 2005.
41. Snavely, N.; Seitz, S.M.; Szeliski, R. Modeling the world from internet photo collections. *Int. J. Comput. Vis.* **2008**, *80*, 189–210.
42. Sani, S.; Carlos, J. Vehículos aéreos no tripulados-UAV Para la Elaboración de Cartografía Escalas Grandes Referidas al Marco de Referencia Sirgas-Ecuador. Ph.D. Thesis, Universidad de las Fuerzas Armadas ESPE, Sangolquí, Ecuador, 2015.
43. Cohen, K. Digital still camera forensics. *Small Scale Digit. Device Forensics J.* **2007**, *1*, 1–8.
44. Laliberte, A.S.; Winters, C.; Rango, A. UAS remote sensing missions for rangeland applications. *Geocarto Int.* **2011**, *26*, 141–156.
45. Gašparović, M.; Jurjević, L. Gimbal Influence on the Stability of Exterior Orientation Parameters of UAV Acquired Images. *Sensors* **2017**, *17*, 401.
46. García, J.L.L. *Aerotriangulación: Cálculo y Compensación de un Bloque Fotogramétrico*; Universidad Politécnica de Valencia: Valencia, Spain, 1999.
47. Laliberte, A.S.; Herrick, J.E.; Rango, A.; Winters, C. Acquisition, orthorectification, and object-based classification of unmanned aerial vehicle (UAV) imagery for rangeland monitoring. *Photogramm. Eng. Remote Sens.* **2010**, *76*, 661–672.
48. Wyszecki, G.; Stiles, W. *Color Science: Concepts and Methods, Quantitative Data and Formulae*, 2nd ed.; Wiley: New York, NY, USA, 1982.
49. Wright, W.D. A re-determination of the trichromatic coefficients of spectral colours. *Trans. Opt. Soc.* **1929**, *30*, 141.
50. Guild, J. The colorimetric properties of the spectrum. *Philos. Trans. R. Soc. London* **1932**, *230*, 149–187.
51. Hutson, G.H. *Teoría de la Televisión en Color*, 2nd ed.; S.A. MARCOMBO: Barcelona, Spain, 1984.
52. Alarcón, T.E.; Marroquín, J.L. Linguistic color image segmentation using a hierarchical Bayesian approach. *Color Res. Appl.* **2009**, *34*, 299–309.
53. Jain, A.K. Data clustering: 50 years beyond K-means. *Pattern Recognit. Lett.* **2010**, *31*, 651–666.
54. Martins, O.; Braz Junior, G.; Corrêa Silva, A.; Cardoso de Paiva, A.; Gattass, M. Detection of masses in digital mammograms using K-means and support vector machine. *ELCVIA: Electron. Lett. Comput. Vis. Image Anal.* **2009**, *8*, 39–50.
55. Grama, A. *Introduction to Parallel Computing*; Pearson Education: Harlow, UK, 2003.
56. Zhao, W.; Ma, H.; He, Q. Parallel k-means clustering based on mapreduce. In *IEEE International Conference on Cloud Computing*; Springer: Berlin/Heidelberg, Germany, 2009; pp. 674–679.
57. Ritter, N.; Ruth, M.; Grissom, B.B.; Galang, G.; Haller, J.; Stephenson, G.; Covington, S.; Nagy, T.; Moyers, J.; Stickley, J.; et al. *GeoTIFF Format Specification GeoTIFF Revision 1.0*; SPOT Image Corp.: Reston, VA, USA, 28 December 2000.
58. Mahammad, S.S.; Ramakrishnan, R. GeoTIFF-A standard image file format for GIS applications. *Map India* **2003**, 28–31.
59. Bonilla Romero, J.H. Método Para Generar Modelos Digitales de Terreno con Base en Datos de Escáner láser Terrestre. Ph.D. Thesis, Universidad Nacional de Colombia-Sede Bogotá, Bogotá, Colombia, 2016.
60. Langley, R.B. The UTM grid system. *GPS World* **1998**, *9*, 46–50.



4.6.2. Un Enfoque Multidisciplinario de Sensado Remoto A Través de UAV de Bajo Costo

Gabriela Calvario, Basilio Sierra, Jordán Martínez y Eder Monter

Las plataformas no tripuladas UAV son equipos con una carga útil propulsados por varias hélices que pueden montar diversos tipos de cámaras. El tradicional recorrido a pie en campo por un área para evaluar el cultivo ahora se puede hacer virtualmente desde el aire. Esto ahora es posible con cámaras de una buena resolución y con información georreferenciada que provee al agricultor de información relevante en poco tiempo.

A continuación, se presenta un documento que presenta las bases de la investigación sobre plataformas UAV de esta tesis.

I Simposio de Aplicaciones Científicas y Técnicas de los Vehículos no Tripulados. La versión en línea del simposio es la siguiente URL: <http://www.igg.unam.mx/scitec/pdf/memoriasSCITEC17.pdf>

Sesiones 16/1-3

Agricultura

Sala 3

Horario: 12:10 – 13:10

SESIÓN 6/1, SALA 3. UN ENFOQUE MULTIDISCIPLINARIO DE SENSADO REMOTO A TRAVÉS DE UAV DE BAJO COSTO

G. Calvario-Sanchez¹

B.Sierra-Araujo ²

J.Martinez-Aguila ²

E.Monter-Ortiz²

¹ Terradata y Asociados SA de CV.

² Universidad del País Vasco UPV/EHU, España

info@terradata.com.mx

Resumen

El uso del vehículo aéreo no tripulado (UAV), basado en sensado remoto ha generado un monitoreo de bajo costo, debido a que se pueden adquirir datos de una manera rápida y sencilla. En este campo de aplicación se están generando una combinación de metodologías aplicadas en la fotogrametría, visión por computadora, minería de datos, geomática e informática, la cual en conjunto genera resultados muy interesantes en el monitoreo del agave. Este documento reporta la experiencia relacionada al análisis de un cultivo de agave con un UAV de bajo costo, los datos fueron procesados por medio del flujo fotogramétrico tradicional, pero se aplicaron técnicas de minería de datos para extraer nuevas capas y separar las plantas de agave de la maleza; además de otros elementos del entorno, a través de este documento se pretende demostrar el potencial del monitoreo de UAV en campos de agave y la importancia del tratamiento de la información con un flujo de datos confiable.

Introducción

El vehículo aéreo no tripulado (UAV), también conocido como drone, está inicialmente constituido por un dispositivo controlador de vuelo, radio receptor, baterías, sensores, actuadores, etc. En los últimos años el uso de UAV ha ido incrementado debido a su potencial en áreas diversas, ya que puede desplazarse de manera muy eficaz; según investigaciones de mercado, indican un amplio crecimiento en el área militar, civil y comercial. MarketsandMarkets proyectó una estimación en ventas para el año 2016 de 13.22 billones de dólares, y especulan un aumento para el año 2022 a la cifra de 28.27 billones (MarketsandMarkets, 2016).

El Sensado Remoto (RS), tradicional se ha llevado a cabo por medio de imágenes de satélite o fotografía aérea, lo cual tiene un costo considerable y no está al alcance de cualquier persona; sin embargo, el auge de nuevas tecnologías, tal como los vehículos no tripulados han dado lugar a un RS de bajo coste, el cual cuenta con una resolución espacial suficiente para observar el detalle de lo que se está estudiando. (Niethammer, 2009), también se debe mencionar la relación entre la visión computacional, aprendizaje automático, (Andersson, 2005), robótica y sistemas de información geográfica que están generando en este momento, un entorno multidisciplinario muy interesante en la extracción de información y su tratamiento (Colomina I. &, 2008).

En un enfoque de aplicación en campo podemos mencionar: monitoreo en agricultura, (Aasen, 2015) inspección forestal, mapeo de cobertura territorial, (Horcher, 2004), respuesta en desastres, (Tsach,

2002), monitoreo de construcción, inspección industrial y residencial, modelos fotogramétricos tridimensionales, monitoreo en conductos de hidrocarburos, vigilancia en costas, (Gonçalves, 2015), etc.

Acerca de las ventajas con la que se cuenta el UAV, se cuenta con la sustitución del hombre en campo, es decir, de manera remota se pueden ejecutar labores de riesgo, tales como volar áreas contaminadas, vulnerables a la radiación, en peligro de derrumbe, desplazamiento de materiales, monitoreo de riesgos y más.

La tecnología UAV ha sido ampliamente utilizada por la milicia debido a que tienen un costo menor que las tradicionales aeronaves de guerra y con el uso del mismo, se evitan bajas innecesarias, que es uno de los principales aspectos a considerar (Sparrow, 2009).

Las principales desventajas por mencionar es que estos no cuentan con la capacidad “Sense and avoid” (S&A), que es la incapacidad de reacción de un vehículo aéreo no tripulado ante la presencia de algún otro obstáculo; sin embargo, los métodos de aprendizaje automático y visión por computador han generado un desarrollo sin precedente en los actuales vehículo aéreos (Everaerts, 2008); otra de las desventajas más significativas es la batería, la cual no suele durar mucho tiempo y esto origina periodos de uso corto y áreas limitadas. También algo que se debe recordar es su vulnerabilidad para derribarlos, ataques cibernéticos y su alto riesgo acerca de un mal manejo (Weibel, 2004).

En este documento nos enfocamos a desarrollar una solución para el monitoreo de plantas de agave, generando un orto-mosaico que nos permitirá separar las plantas de otros elementos en campo y con ello poder realizar un monitoreo detallado, con el cual demostrar la utilidad de un entorno multidisciplinario, que genera en conjunto un buen tratamiento de la información.

Materiales y métodos.

Plan de trabajo



Área de estudio y plan de vuelo.

El área de estudio se encuentra ubicada cerca del municipio de San Diego de Alejandría, de la Región Altos Norte del estado de Jalisco, en México. Dicho municipio se encuentra dentro de la región nombrada como área de denominación de Origen para el Tequila, su altura es superior a 1800 m sobre el nivel del mar y sus coordenadas de sobrevuelo 20°54'33.82" latitud Norte y 102° 00' 04.00" longitud Oeste, el área es de aproximadamente 7 hectáreas ((Figura N° 1).



Figura No 1. Trabajo en campo en área de estudio seleccionada.

El plan de vuelo se verificó de manera anticipada por medio de Google Earth, se especificó el área de despegue y aterrizaje, en sitio se inició el lanzamiento y se llevó el dispositivo a una altitud 60 metros para proveer una resolución espacial $\leq 2\text{cm}$ por pixel, el tiempo de vuelo se llevó a cabo en alrededor de 15 minutos.

El parámetro que nos indica el tamaño aproximado de representación de un pixel en el terreno es llamado Ground Sample Distance (GSD), en nuestro caso el tamaño fue de $\leq 2\text{cm}$ por pixel, debido a que se realizó el vuelo a 60 metros de altura (Jacobsen, 2008).

$$GSD = (Sw * H * 100) / (Fr * lw)$$

Donde:

Sw la apertura del sensor(mm)

H la altura de vuelo(m)

Fr es la distancia focal (mm)

lw ancho de imagen(pixel) (Pix4D, 2016).

Cuadróptero-UAV

El cuadróptero utilizado para la adquisición de la imagen, es un equipo de bajo costo, cuenta con un sistema de detección de obstáculos de 0.7 a 15m, su entorno operativo debe tener buena iluminación para cumplir con dicho objetivo, modo GPS/GLONASS, sistema de estabilización de 3 ejes con un grado de inclinación de -90° a $+30^\circ$ y ejes de movimiento horizontal, vertical y rotación, distancia de operación es de 3 km. Sin embargo, siempre se vuela dentro de una línea de visión clara, por seguridad, tanto de los usuarios como del equipo, fue controlado de manera manual y se debe resaltar que para ello el nivel de habilidades y conocimientos del piloto debe ser alto, debido a los contratiempos que pueden surgir directamente en el área de adquisición (Figura N° 2).



Figura No 2. Equipo de bajo costo y trabajo en campo en área de estudio seleccionada.

Adquisición de la imagen

Se cuenta con un sensor RGB, que permite la captura de información raster, desde una altura predefinida por el usuario. El uso de estabilizadores permite absorber la vibración y estabiliza la posición del sensor, en el caso del UAV phantom 4, este se encuentra montado sobre una plataforma gimbal, que permite obtener el nadir buscado en las imágenes (Tabla N° 1).

Sensor RGB	6.25 mm x 4.68 mm, focal
Peso	25 grs
Sensor	12.4 M CMOS
Lente	FOV 94°
Medida de Imagen	4000x3000
Tipo Imagen	JPEG, DNG (RAW)
Temperatura	0° to 40° C

Tabla No 1, Características generales de UAV.

El vuelo del UAV nos permitió obtener la colección de fotografías y su coordenada aproximada, ya que se debe recordar que las condiciones del área, meteorológicas, la imprecisión del sistema de posicionamiento global, generan errores en la geoposición de la fotografía, por lo que también se asignaron puntos de control geodésicos (GCPs), en el sitio de interés.

Los puntos GCPs nos proveen de precisión, se requieren por lo menos tres (Gonçalves, 2015), sin embargo, en nuestro caso utilizamos 8 puntos de control en el área, con el fin de minimizar el error al georectificar (Figura N° 3).

Para obtener un buen resultado en el procesamiento de la imagen, se debe llevar a cabo un correcto procedimiento fotogramétrico, actualmente en el mercado existe una variedad de paquetes de software fotogramétrico que pueden realizar procesos sobre las fotografías de UAV, estos paquetes utilizan por lo regular un algoritmo llamado “structure from motion” que es un conjunto de técnicas de fotogrametría y visión computacional, (Snavely, 2007). En nuestro caso utilizamos el software llamado UAS Master, también se utilizó Exiftool, (ExifTool, 2016) que es una aplicación que permite leer los metadatos de una variedad de formatos fotográficos, esta aplicación también nos ayudó a obtener los parámetros para realizar la calibración radiométrica de nuestra imagen.



Figura No 3, Generación de puntos de control.

Flujo Fotogramétrico

El proceso de flujo fotogramétrico consistió en generar el correcto traslape de cada imagen que fue en la horizontal del 70% y en la vertical del 30%, una vez hecho esto, verificar de manera visual dicho traslape, para llevar a término con calidad nuestro producto (Linder, 2009). Después del proceso de aerotriangulación, se generó el Modelo Digital de Terreno (DTM), Modelo Digital de Superficie (DSM) y finalmente la creación del ortomosaico. Dicho flujo de trabajo está automatizado en UAS Master y debido a que es un software comercial no existe mucha bibliografía al respecto.

Metodología

La característica espectral y de textura son elementos fundamentales de los patrones utilizados por la interpretación humana de la fotografía. La textura representan una variación de tonos en el dominio espacial, determinan una visualización suave o burda de las características de una imagen (Haralick, 1973). Por lo que hemos observado, el análisis de texturas funciona como una clasificación de patrones relacionado directamente con la variabilidad que se presenta en una imagen, la metodología propuesta en este trabajo intenta realizar la separación de capas en cultivos de agave, la cual cuenta con elementos texturales tales como maleza, diferentes tipos de suelo, humedad, rocas, etc.

Se realizó una búsqueda significativa de procesos multidisciplinarios, en la literatura, se ha observado que se han publicado trabajos en su mayoría, donde se involucra la recolección de fotografías, calibración, la georectificación y ortomosaico de datos de UAV; existen artículos en los que se menciona la posibilidad del uso de algoritmos de aprendizaje automático (Clark, 2010), otros mencionan la aplicación de algunos métodos de clasificación (Hassan-Esfahani, 2014), lo que se propone en este documento es resaltar las ventajas de un método multidisciplinario entorno a la unión de todas estas técnicas mencionadas, sus ventajas en el presente y futuro.

El paso siguiente consiste en la creación de capas segmentadas usando un algoritmo de agrupación, el cual nos permitirá generar capas de maleza y plantas, dicha metodología está basada en tres pasos: creación de ortomosaico, segmentación de imagen usando un algoritmo de agrupación y, por último, creación de capas en formato de representación vectorial, (Shapefile) y su validación.

El primer paso es la construcción del ortomosaico, éste como se mencionó con anterioridad se realizó a través de UAS Master, después de esto, se realizó un análisis cualitativo del ortomosaico (Figura N° 4), en el cual se verificaron los siguientes parámetros:

Comparación geométrica mediante la digitalización de puntos en tierra ☐ Aspectos de Geometría en líneas rectas y artefactos. ☐ Balance de Color.



Figura No 4, Ortomosaico procesada con UAS masterTM.

A continuación, sometimos el ortomosaico a un algoritmo de agrupamiento desarrollado en Matlab, el algoritmo nos permitió generar nuevas capas temáticas de los objetos de interés y después construir bitmaps (Figura N° 5), que fueron validados en conjunto con los datos del orto mosaico en un sistema de información geográfica (GIS).




Figura No 5, vista Aérea sobre corte de ortomosaico (a), muestreo de capa de plantas (b), muestreo de capa de maleza(c).

Evaluación de la Metodología

La exactitud de los datos derivados de los UAV depende principalmente de dos aspectos: la restitución fotogramétrica basada en la triangulación y la exactitud del DTM y DSM. Para evaluar la metodología, se tomaron 35 muestras en diferentes sitios alrededor del área de interés, en los cuales 10 muestras fueron de maleza y 25 de plantas de agave, cada muestra fue obtenida con datos GPS y fotografía, se tomaron medidas de altura y diámetro, se hace notar que se tuvo un error de ≤ 5 cm en cuanto a las alturas y diámetros en cada muestra.

Conclusiones

El sensado remoto del agave a través de UAV de bajo costo, es generado por medio de la combinación de varias tecnologías como son: fotogrametría, visión por computador, minería de datos, geomática e informática.

Este estudio ha demostrado el potencial desarrollo de vehículos aéreos no tripulados de bajo costo en el área del monitoreo del agave. La detección remota de la estructura de la vegetación permitirá en un futuro cercano la generación de datos muy importantes, para el estudio de plantas como el agave. En el caso de este estudio se pretende que los resultados del sensado remoto se almacenen en una base de datos geoespacial, la cual nos permitirá observar el comportamiento de las plantas con respecto a su entorno ambiental e histórico.

En este momento se trabaja en conjunto con la gente del Consejo Regulador del Tequila, la cual nos ha permitido enfocarnos a sus necesidades y contar con el apoyo para monitorear algunos cultivos.

Agradecimientos

El desarrollo y metodología de este estudio fue llevado a cabo por el equipo técnico de Terradata y Asociados SA de CV, además del apoyo del Consejo Regulador del Tequila (CRT), el cual nos ha permitido monitorear varios cultivos. Para más información acerca de esta empresa se encuentra disponible en: <http://www.terradata.com.mx/>

Referencias

- Aasen, H. (2015). Generating 3D hyperspectral information with lightweight UAV snapshot cameras for vegetation monitoring: From camera calibration to quality assurance. *ISPRS Journal of Photogrammetry and Remote Sensing*, 245-249.
- Andersson, P. J. (2005). Hazard: A framework towards connecting artificial intelligence and robotics. *Reasoning, Representation, and Learning in Computer Games*, (págs. 1-6). Edinburgh, Scotland.
- Clark, A. F. (2010). A low-cost airborne platform for ecological monitoring. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 38.
- Colomina, I. &. (2008). Towards A New Paradigm for High-Resolution Low-Cost Photogrammetry and Remote Sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 1201-1206.
- Colomina, I. (2008). TOWARDS A NEW PARADIGM FOR HIGH-RESOLUTION LOW-COST. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*.
- DJI. (20 de 12 de 2016). DJI. Obtenido de <https://www.dji.com/phantom-4/info>
- Everaerts, J. (2008). The use of unmanned aerial vehicles (UAVS) for remote sensing and mapping. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*.
- ExifTool. (15 de 12 de 2016). ExifTool. Obtenido de <http://www.sno.phy.queensu.ca/~phil/exiftool/>
- Gonçalves, J. A. (2015). UAV photogrammetry for topographic monitoring of coastal areas. *ISPRS Journal of Photogrammetry and Remote Sensing*, 101-111.
- Haralick, R. M. (1973). Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics*.
- Hassan-Esfahani, L. T.-R. (2014). Topsoil moisture estimation for precision agriculture using unmanned aerial vehicle multispectral imagery. *IEEE Geoscience and Remote Sensing Symposium* (págs. 3263-3266). IEEE.

- Horcher, A. &. (2004). Unmanned Aerial Vehicles: Applications for Natural Resource Management and Monitoring. Conference Proceedings: "Machines and People, The Interface".
- Jacobsen, K. (2008). TELLS THE NUMBER OF PIXELS THE TRUTH? EFFECTIVE RESOLUTION OF LARGE SIZE DIGITAL FRAME CAMERAS. Hannover, Germany.
- Linder, W. (2009). Digital Photogrammetry, A Practical Course. Springer Science & Business Media.
- MarketsandMarkets. (2016). Unmanned Aerial Vehicle (UAV) Market by Application (Military, Civil & Commercial, Homeland Security), Class (Small, Tactical, Strategic, Special Purpose), Subsystem, Energy Source, Material Type, Payload and Region - Global Forecast to 2022. marketsandmarkets.com.
- Niethammer, U. R. (2009). UAV-based remote sensing of the slow-moving landslide super-sauze., (págs. In Proceedings of the International Conference on Landslide Processes: From Geomorphologic Mapping to Dynamic Modelling,). Strasbourg, France.
- Pix4D. (10 de 12 de 2016). Pix4D Tools-GSD Calculator. Obtenido de <https://support.pix4d.com/hc/enus/articles/202560249-TOOLS-GSD-Calculator#gsc.tab=0>
- Snavely, N. S. (2007). Modeling the world from internet photo collections. International Journal of Computer Vision, 189-210.
- Sparrow, R. (2009). Building a Better WarBot: Ethical Issues in the Design of Unmanned Systems for Military Applications. Science and Engineering Ethics, 169-187.
- Tsach, S. P. (2002). Advanced technologies and approaches for next generation UAVs. In Proceedings of ICAS 2002 Congress.
- Weibel, R. E. (2004). Safety Considerations for Operation of Different Classes of UAVs in the NAS. AIAA. Chicago, Illinois.

4.6.3. Use of UAV for remote sensing; a methodology to agave plants counting

Gabriela Calvario, Basilio Sierra, Teresa E. Alarcón, Carmen Hernández y Oscar Dalmau

El uso de imágenes aéreas adquiridas a través de las plataformas UAV permite a los investigadores obtener información sobre las propiedades de las plantas, su estado fenológico, anomalías y conteos. El vehículo aéreo no tripulado ofrece nuevas oportunidades en el campo de la agricultura tales como la posibilidad de generar un conteo automático a través de imágenes tomadas por un UAV permite una evaluación más precisa en los parámetros de proyección en la producción de la bebida nombrada tequila.

Por enviar.

Article

Use of UAV for remote sensing; a methodology to agave plants counting

Gabriela Calvario ^{1*}, Basilio Sierra ¹, Teresa E. Alarcón ², Carmen Hernandez ¹ and Oscar Dalmau ³

¹ Departamento de Ciencias de la Computación e Inteligencia Artificial, Universidad del País Vasco UPV/EHU, Donostia-San Sebastián 20018, Spain; b.sierra@ehu.eus

² Centro Universitario de los Valles, Carretera Guadalajara - Ameca Km. 45.5, C.P., 46600, Ameca, Jalisco, México; teresa.alarcon@profesores.valles.udg.mx

³ Centro de Investigación en Matemáticas, Jalisco SN, Col., Valenciana, C.P., 36240, Guanajuato, México; dalmau@cimat.mx

* Correspondence: gcalvario001@ikasle.ehu.eus

Academic Editor: name

Version June 4, 2019 submitted to Entropy; Typeset by L^AT_EX using class file mdpi.cls

Abstract: The blue agave of the variety known as Tequilana Weber, is a crop that has been a very important support for Jalisco's tequila agribusiness and the agricultural economy in Mexico. The Agave is an important commercial crop in Mexico and is the main raw material in the production of tequila, traditionally Mexican drink.

To maximize the productivity from tequila drink is need to know the number of agave plants in the plantation area, in order to prospect production.

The use of aerial images acquired through de Unmanned Aerial Vehicles platforms allows researchers to obtain information on the properties of plants, their phenological status, anomalies, and counting. The unmanned aerial vehicle (UAV) provides new opportunities in the field of agriculture. Being able to generate an automatic count through images taken by a UAV allows a more precise evaluation in the projection parameters in the production.

The main objective of this article is to advance the use of UAV in automatic counting of agave plantations. This study presents a focus on image processing which shows a wide potential in different areas of studies with different topographies, light and weather conditions in which it obtained promising results in the counting of agave plants.

16

Keywords: UAV; data mining; computer vision, geomatics, agave monitoring

18 ñsñ

19 1. Introduction

20 The present work makes reference to methodology in [1] as continuation of the monitoring of
21 agave crops.

22 2. Materials and Methods

23 2.1. Work-flow

24 First and in order to describe our research, the photogrammetric proc

25 2.2. Study areas

26 The experiments were conducted at 3 areas with different topography and dates. The agave
27 crops are used to create training were obtained the random way; however, we search areas with
28 diversity in soil and sizes of plants.

29

30 3. Image Processing

31 The sowing system the blue agave is linear, see Figure 1. The lines in each of these rows agave
32 crops can be made trough tractor, stakes or manually with a thread. With the tractor, a furrow is
33 made at the distance that it was decided to separate the rows and later a thread with marks to fix
34 the distance in which each son plant is inserted on the ground in order to establish straight lines and
35 equidistant in the plantations. Some producers carry out plantations according to the topography
36 of the land, using the trace of contour lines to avoid soil losses by erosion and to have a better
37 distribution of humidity, however, in most cases the plantation is done manually with farming tools.

38



Figure 1. Lines in agave crops

39 Agave crops can be varied in the management of your plantation however, you can find rows,
40 with a separation between each row of 2 to 3 meters on average and each plant is separated from .80
41 to 1.50 meters [2].

42 The main challenge we face with this type of crop is because the plant tends to overlap with adjacent
43 plants, see Figure 2(b) and (d). A counting algorithm was written in Matlab (R2016a) which is based
44 on taking the methodology presented in [1] using the plant layer obtained from an unsupervised
45 K-means approach, see Figure 2.

46

For image processing in Matlab, we mainly rely on CIELAB color space due to the texture
information to extract and analyze the plants. There is a particularly advantageous about the agave

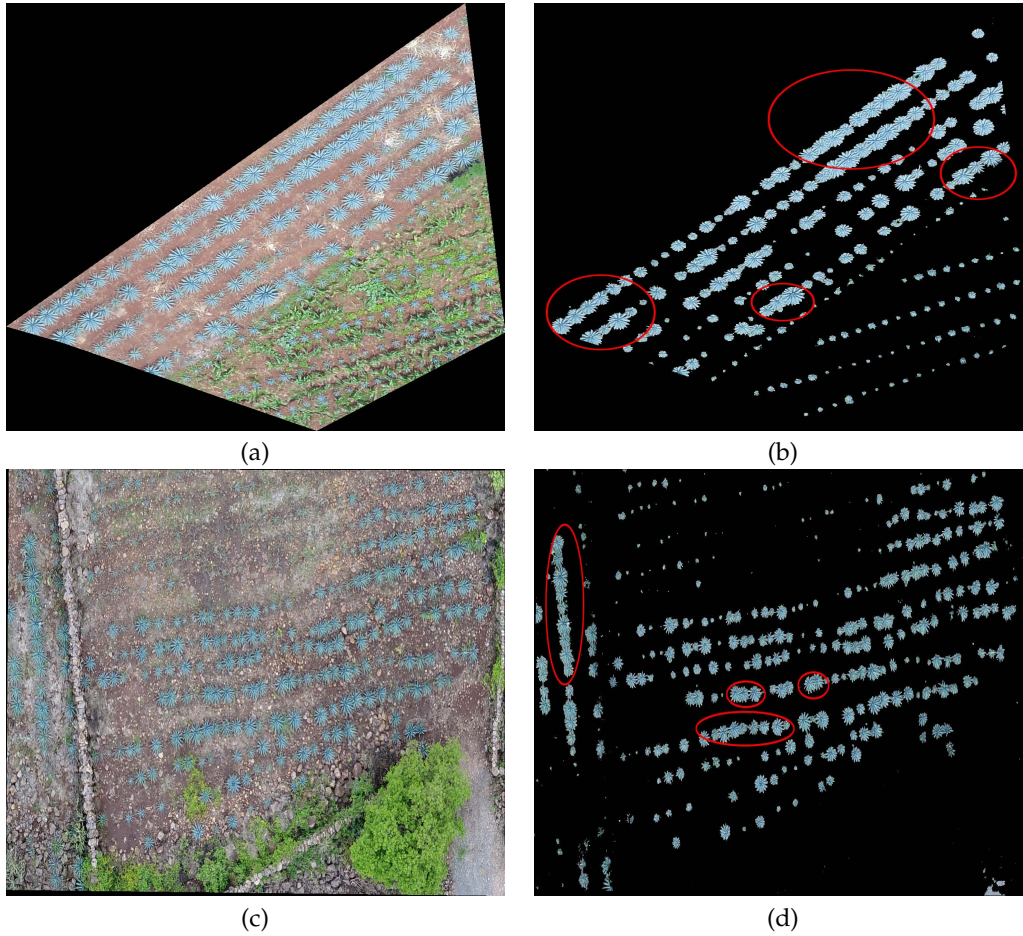


Figure 2. Extraction of agave layer. (a) and (c) to presents the agave crops without applying the plant extraction methodology in [1]. (b) and (d) shows agave detection layers after applying the methodology; in this image we can also observe with red circles the overlap between the plants

crops which is precisely its blue color and due to this characteristic it is easy to extract this layer and highlight the difference from weeds or different background. Main steps of the algorithm are discussed in the following.

(I) Convert the layer plants to a greyscale image in MATLAB; this function converts Red, Green, Blue (RGB) values to greyscale values by forming a weighted sum of the R, G, and B components. The coefficients used to calculate grayscale values are identical to those used to calculate luminance ($E'y$) in the recommendation ITU- BT.601-7 of International Telecommunication Union (ITU-R) [3], [4], see Figure 3(a).

$$0.299 * R + 0.587 * G + 0.114 * B \quad (1)$$

$$\begin{bmatrix} Y \\ I \\ Q \end{bmatrix} = \begin{bmatrix} 0.299 & 0.587 & 0.114 \\ 0.596 & -0.274 & -0.322 \\ 0.211 & -0.523 & 0.312 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (2)$$

47 **(II)** The second step is to remove isolated pixels. The target of this process is cleaning the input
48 image in order not to generate erroneous data around the canopy of agave plants or outside the

49 region of interest, see Figure 3(b).

50

51 **(III)**The rows are completed. In agave plants are fill the holes inside the plants and removing
52 groups of pixels or dots outside the rows that are falsely identified as plants, see Figure3(c).

53

54 **(IV)** Morphology operation. Performs morphological closing on an input image, returning an
55 image most thin. The morphological close operation is a dilation followed by an erosion with a
56 3-by-3 square structuring element pixels [5], see Figure 3(d).

57

58 **(V)** Create a predefined two-dimensional filter of 3-by-3 approximating the shape of the
59 two-dimensional Laplacian operator, $\alpha = 0$; applying this filter the input image and find
60 components to connected on the input image. pixels are connected if their edges or corners touch,
61 see Figure 3(e).

62

63 **(VI)** Compute measurements of the objects. Compute a vector of labels for the objects satisfying
64 the criteria where a binary image containing only the regions whose area is smaller than < 25 ; the
65 objective that it takes elements of the image smaller than an area of 25 which corresponds to a
66 footprint of an agave plant, see Figure 3(f).

67

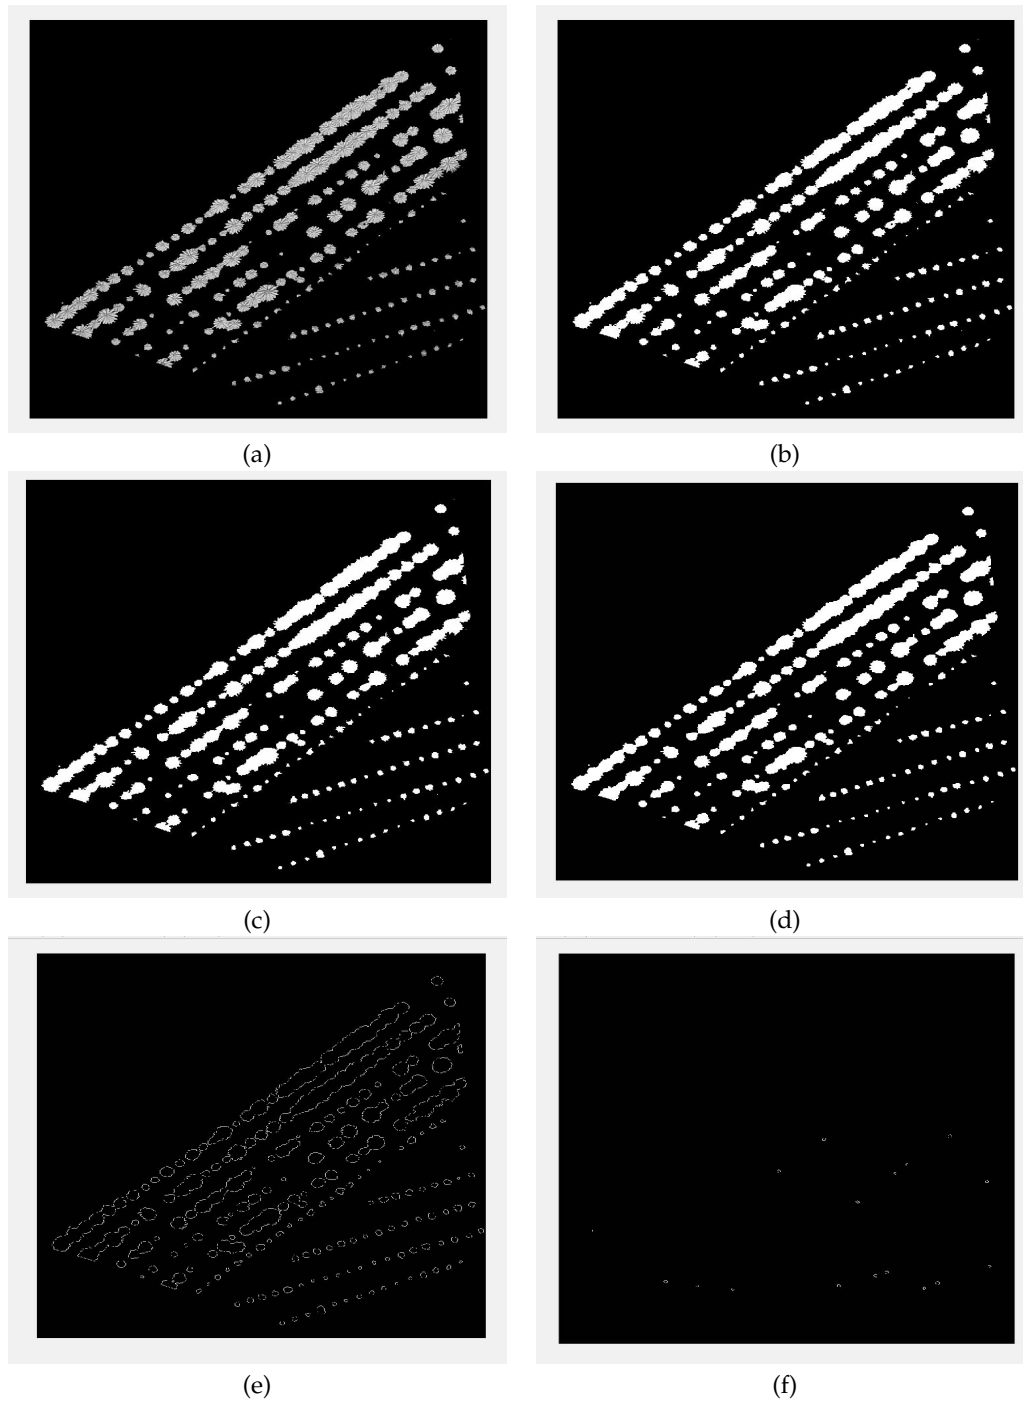


Figure 3. Matlab Algorithm methodology; (a) Convert the plants layer to a greyscale image. (b) Clean isolated pixels. (c) Rows completed. (d) Morphology operation. (e) Apply laplacian filter. (f) Compute measurements of the objects.

68 (VII) Convert the shapes of the input image to shapes fill hole boundaries to the image of
 69 objects, extracting the first agave plants.
 70 Once step VII has been applied in the methodology proposed by the algorithm, we can see in Figure
 71 4(a) that the rows representing the agave are kept clean of noise pixels and without holes inside the

72 rows. These rows will allow us to extract objects with an area <25 which represent the plants. the
73 pixels representing the agave plants will be stored in a temporary file which, through a loop, will
74 repeat the previous process until the image no longer has pixels to process and can represent in the
75 temporary file the count of plants on this image monitored.

76




Figure 4. Once step VII is applied in the methodology proposed by the algorithm we can observe in (a) the rows on the image with objects that represent the plants. Each object proposed to be classified as a plant must measure an area <25 (objects in red circles), if this is correct the plants of the image are extracted and stored in a temporary file. In (b) we can see the image to which the plants were extracted.

77 4. Results and Discussion

78 In this section, we discussed the results consistent with experiments described in previous
79 section.




Figure 5. Extraction of agave layer. (a) and (c) to presents the agave crops without applying the plant extraction methodology in [1]. (b) and (d) shows agave detection layers after applying the methodology




Figure 6. Extraction of agave layer. (a) and (c) to presents the agave crops without applying the plant extraction methodology in [1]. (b) and (d) shows agave detection layers after applying the methodology




Figure 7. Extraction of agave layer. (a) and (c) to presents the agave crops without applying the plant extraction methodology in [1]. (b) and (d) shows agave detection layers after applying the methodology

80 5. Conclusions and Future Work

81 In this work we proposed a methodology for agave crop monitoring. The methodology
 82 **Acknowledgments:** We wish to acknowledge the Consejo Nacional de Ciencia y Tecnología (CONACYT) for its
 83 financial support to the PhD studies of Gabriela Calvario. We are grateful to Cubo Geoespacial S.A .de C.V. and
 84 special to Ing. Jordan Martinez for the stimulus to this work, more information about this Company is available
 85 at: <http://www.cubogoespacial.com/>. In addition we are grateful to the support of the Tequila Regulatory
 86 Council (CRT), which has allowed us to monitor several crops. This paper has been supported by the Spanish
 87 Ministerio de Economía y Competitividad, contract TIN2015-64395-R (MINECO/FEDER, UE), as well as by the
 88 Basque Government, contract IT900-16. This work was also supported in part by CONACYT (Mexico), Grant
 89 258033.

90 **Author Contributions:** G. Calvario conceived the idea of the paper; B. Sierra, T. Alarcón and O. Dalmau helped
 91 in the experimental design and writing process; G. Calvario performed the experiments; M. Hernández analyzed
 92 the data and the results of the experiments. All the authors have taken part in the elaboration of this document.

93 **Conflicts of Interest:** The authors declare no conflict of interest.

94 Bibliography

- 95 1. Calvario, G.; Sierra, B.; Alarcón, T.; Hernandez, C.; Dalmau, O. A multi-disciplinary approach to remote
 96 sensing through low-cost uavs. *Sensors* **2017**, *17*, 1411.

- 97 2. Bueno, J.X.U.; Gutiérrez, C.V.; Figueroa, A.R. MUESTREO Y ANALISIS DE SUELO EN PLANTACIONES
98 DE AGAVE. *CONOCIMIENTO Y PRACTICAS AGRONOMICAS PARA LA PRODUCCION DE Agave*
99 *tequilana Weber EN LA ZONA DE DENOMINACION DE ORIGEN DEL TEQUILA*, p. 37.
- 100 3. Sugawara, M.; Choi, S.Y.; Wood, D. Ultra-high-definition television (Rec. ITU-R BT. 2020): A generational
101 leap in the evolution of television [standards in a nutshell]. *IEEE Signal Processing Magazine* **2014**,
102 *31*, 170–174.
- 103 4. Khandual, A.; Baciú, G.; Rout, N. Colorimetric Processing of Digital Colour Image! *International Journal*
104 **2013**, *3*.
- 105 5. Van Den Boomgaard, R.; Van Balen, R. Methods for fast morphological image transforms using
106 bitmapped binary images. *CVGIP: Graphical Models and Image Processing* **1992**, *54*, 252–258.

107 © 2019 by the authors. Submitted to *Entropy* for possible open access publication under the terms and
108 conditions of the Creative Commons Attribution license (<http://creativecommons.org/licenses/by/4.0/>)

4.6.4. Foro Geoespacial Latinoamericano

Gabriela Calvario

Futura dirección en la agricultura: Un reto para tecnologías emergentes.

La agricultura, basada en tecnologías emergentes, se está convirtiendo en una idea atractiva para la gestión de los recursos y la realización de un desarrollo agrícola sostenible.


Este enfoque requiere una recopilación masiva de datos y análisis a una escala posible en la actualidad, esta perspectiva involucra sensores que puedan medir características de plantas en tiempo real. La información generada por estos sensores, podría basarse en datos obtenidos por satélites, vehículos aéreos no tripulados, aviones, tractores, robots etc.

Registrar la densidad de la maleza, la altura, diámetros del cultivo, anomalías, el estado de humedad y otras propiedades importantes para la toma de decisiones sobre el manejo de fertilizantes y plagas. Este tipo de tecnologías deben ser robustas, de bajo costo y ser capaces de transmitir la información utilizando redes inalámbricas a bases de datos que pueden realizar procedimientos de datamining. El objetivo a alcanzar, debe ser, el poder efectuar recomendaciones que puedan transmitirse a computadoras y controladores en campo que sean capaces de variar las tasas de riego, fertilizantes, herbicidas, etc. y alertar sobre características específicas en los cultivos con una buena precisión.



Foro Geoespacial Latinoamericano. TEMA: Información Geoespacial: Haciendo una Diferencia Para Millones de Personas. La versión en línea del foro es la siguiente URL: <https://lagf.org/speakers.html>



RESUMEN



Dr. Gabriela Calvario, es Científico de Datos Geoespaciales en las compañías TERRAMAPPING® y CuboGeoespacial® en la ciudad de Guadalajara, Jalisco México. Profesional en ingeniería en computación por la Universidad de Guadalajara en el año 2003. Becaria CONACYT, realizo un master en ciencia y Tecnología Espacial, sobre el campo de procesamiento de imagen satelital, en el Observatorio Aula Espazio Gela en la facultad de Ingeniería de Bilbao, España. Después Gabriela se integró al departamento de ciencias computacionales e inteligencia artificial en la Universidad del País Vasco para continuar su Doctorado.



RESUMEN


La agricultura, basada en tecnologías emergentes, se está convirtiendo en una idea atractiva para la gestión de los recursos y la realización de un desarrollo agrícola sostenible.

Este enfoque requiere una recopilación masiva de datos y análisis a una escala actualmente posible. La información puede ser generada por diferentes sensores, tales como satélites, vehículos aéreos no tripulados, aviones, robots etc.

Registrar la densidad de la maleza, la altura, diámetros del cultivo, anomalías, el estado de humedad y otras propiedades, son parte fundamental en la toma de decisiones para la aplicación de fertilizantes y el control de plagas. Este tipo de tecnologías deben ser robustas, de bajo costo y ser capaces de transmitir la información utilizando redes inalámbricas a bases de datos que pueden realizar procedimientos de minería de datos.

El objetivo a alcanzar, debe ser, el poder efectuar recomendaciones que puedan transmitirse a computadoras y controladores en campo que sean capaces de variar las tasas de riego, fertilizantes, herbicidas, etc.








¿Quiénes somos?

¿COMO LO HACEMOS?

Empresa dedicada en proveer tecnologías de vanguardia a nuestros clientes, especializada en el procesamiento, análisis, desarrollo e ingeniería de datos geoespaciales



Antecedentes

ANTECEDENTES

Según la FAO y tomando en cuenta la opinión de expertos en el documento "Como alimentar al mundo en el 2050" generado en el año 2009, Se espera que en la primera mitad del presente siglo la demanda mundial de alimentos, aumente en un 70 %.



TERRAMAPPING

LETA AMÉRICA
LATINOAMERICANA
FORUM
2014
UNIVERSIDAD DE LOS ANDES
FACULTAD DE CIENCIAS
INFORMÁTICAS

ANTECEDENTES

Las perspectivas que se plantan para el año 2050, generan diversas preguntas importantes.

- ¿Son las inversiones públicas y privadas actuales suficientes para garantizar el potencial adecuado de la producción agrícola?
- ¿Estarán disponibles los recursos, las nuevas tecnologías y los servicios de apoyo disponibles para la población que más los necesita, "la población mas pobre y vulnerable"?
- ¿Qué se debe hacer para ayudar a la agricultura a hacer frente a los desafíos del cambio climático y la creciente escasez de agua?

TERRAMAPPING

Vías, J. M. S. (2012). Los retos de la agricultura para alimentar al mundo en 2050. *Tiempo de paz*, 106, 37-48.

LETA AMÉRICA
LATINOAMERICANA
FORUM
2014
UNIVERSIDAD DE LOS ANDES
FACULTAD DE CIENCIAS
INFORMÁTICAS

ANTECEDENTES

Cambios Clave:

- **En primer lugar:** Dietas mas saludables, basadas en plantas en todo el mundo. Esto podría reducir a la mitad las emisiones de gases de efecto invernadero del sistema alimentario y también reducir otros impactos ambientales como los derivados del uso de fertilizantes, tierra de cultivo y agua dulce.
- **Segundo:** mejores practicas y tecnologías agrícolas para limitar presiones sobre tierras.
- **Tercero:** El mundo necesita reducir a la mitad las enormes cantidades de perdida y desperdicio de alimentos.

TERRAMAPPING


Vías, J. M. S. (2012). Los retos de la agricultura para alimentar al mundo en 2050. *Tiempo de paz*, 106, 37-48.

LETA AMÉRICA
LATINOAMERICANA
FORUM
2014
UNIVERSIDAD DE LOS ANDES
FACULTAD DE CIENCIAS
INFORMÁTICAS

TERRAMAPPING
Geoprocessing & Development

Tecnologías emergentes Como Fuentes de datos

SATÉLITES ÓPTICOS



TERRAMAPPING

LETA AMÉRICA
LATINOAMERICANA
FORUM
2014
UNIVERSIDAD DE LOS ANDES
FACULTAD DE CIENCIAS
INFORMÁTICAS

SATÉLITES ÓPTICOS



TERRAMAPPING

LETA AMÉRICA
LATINOAMERICANA
FORUM
2014
UNIVERSIDAD DE LOS ANDES
FACULTAD DE CIENCIAS
INFORMÁTICAS

SATÉLITES ÓPTICOS

Landsat 8
 2013 - present

Landsat 7
 1999 - present

Landsat 4-5
 Landsat 4: 1982 - 1993
 Landsat 5: 1984 - 2013

Landsat 1-3
 Landsat 1: 1972 - 1978
 Landsat 2: 1975 - 1983
 Landsat 3: 1978 - 1983

TERRAMAPPING
 LATAM AMÉRICA LATINA
 GEOINFORMÁTICA Y SIG
 CONSULTORÍA Y DESARROLLO DE SOFTWARE
 # INNOVANDO EN SIGUINTE AL MUNDO

Last 3 Months

TERRAMAPPING
 LATAM AMÉRICA LATINA
 GEOINFORMÁTICA Y SIG
 CONSULTORÍA Y DESARROLLO DE SOFTWARE
 # INNOVANDO EN SIGUINTE AL MUNDO

TERRAMAPPING
 Geoprocessing & Development

Aplicación de Tecnologías

ALGUNAS APLICACIONES DE IMAGEN SATELITAL

- Delimitan los predios de las plantaciones con gran exactitud
- Inventarios rápidos, densidades de plantaciones con una buena precisión, no requieren de movilización
- Identificación de cultivos
- Gran cobertura (escalas locales y regionales)
- Generación de datos espectrales, múltiples bandas permiten generar análisis de utilidad para correlacionar condiciones fitosanitarias
- Monitoreo de plantaciones con múltiples temporalidades

TERRAMAPPING
 LATAM AMÉRICA LATINA
 GEOINFORMÁTICA Y SIG
 CONSULTORÍA Y DESARROLLO DE SOFTWARE
 # INNOVANDO EN SIGUINTE AL MUNDO

INVENTARIO A TRAVÉS DATOS ESPECTRALES


TERRAMAPPING
 LATAM AMÉRICA LATINA
 GEOINFORMÁTICA Y SIG
 CONSULTORÍA Y DESARROLLO DE SOFTWARE
 # INNOVANDO EN SIGUINTE AL MUNDO

DELIMITACIÓN DE PREDIOS

¿Dónde hay Agave?

TERRAMAPPING
 LATAM AMÉRICA LATINA
 GEOINFORMÁTICA Y SIG
 CONSULTORÍA Y DESARROLLO DE SOFTWARE
 # INNOVANDO EN SIGUINTE AL MUNDO


IDENTIFICACIÓN DE PATRONES



DENSIDAD DE PLANTACIONES



EXTRACCIÓN DE PATRONES



TRANSFORMACIÓN DIGITAL

En el mes de Septiembre del presente año se celebró el foro:

"Diálogo sobre el futuro de la agricultura"

Donde Bayer menciona:

"Las herramientas digitales han dado forma a muchos sectores y nosotros apenas estamos empezando a descubrir lo que significa para la agricultura. A través del potencial de las nuevas herramientas digitales y del análisis de datos podemos aumentar la productividad y la sustentabilidad de los agricultores".

<http://www.bayer.mx/es/prensa/noticias/noticias-globales/bayer-plantas-su-vision-para-el-futuro-de-la-agricultura.php>




VEHÍCULOS AÉREOS NO TRIPULADOS (UAV)

De una manera General, la forma de referirse a ellos es UAV que significa (Vehículo aéreo no tripulado), estos son la consecuencia de la mezcla de lo más moderno y avanzado de la robótica y la aeronáutica.

RPA, Remotely Piloted Aircraft, aviones controlados de forma remota. Se trata de un concepto que surgió con fuerza en EEUU para evitar que la gente se aterrorice por el uso de estos en medios urbanos, pensando que no hay ninguna persona que se haga cargo de evitar un desastre en caso de avería en vuelo.

RESOLUCIÓN ESPACIAL








TERRAMAPPING
Geoprocessing & Development

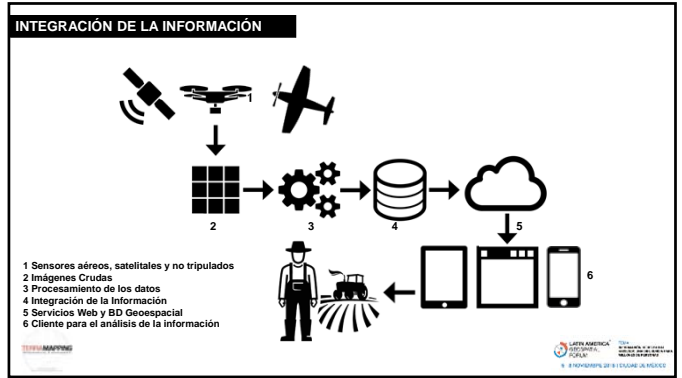
¿Qué no podemos observar?

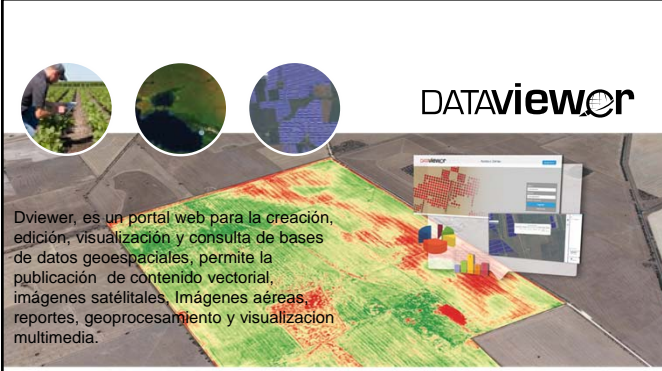
.... Más detalle



TERRAMAPPING
Geoprocessing & Development

Integración de tecnología

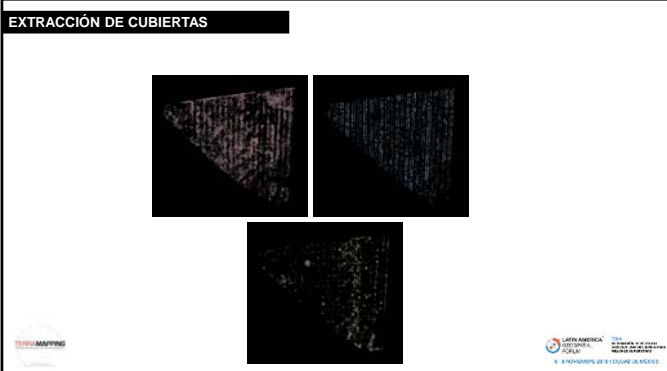




DATAviewer

Dviewer, es un portal web para la creación, edición, visualización y consulta de bases de datos geospaciales, permite la publicación de contenido vectorial, imágenes satelitales, Imágenes aéreas, reportes, geoprocesamiento y visualización multimedia.


EXTRACCIÓN DE CUBIERTAS



TERRAMAPPING

LETA AMÉRICA
SOLUCIONES
SIG/RS
INTEGRADAS PARA EL SECTOR
AGROPECUARIO

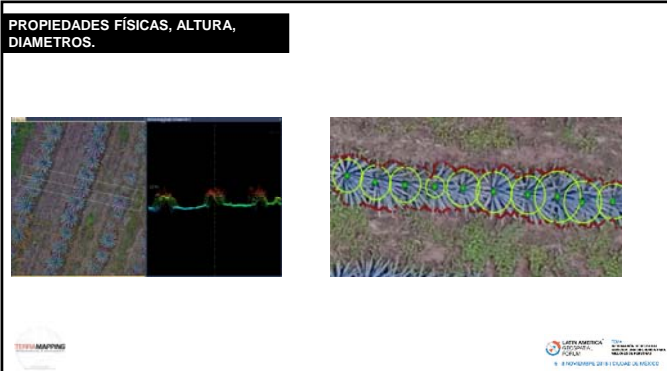
Cliente para el Análisis y Procesamiento de la información



TERRAMAPPING

LETA AMÉRICA
SOLUCIONES
SIG/RS
INTEGRADAS PARA EL SECTOR
AGROPECUARIO

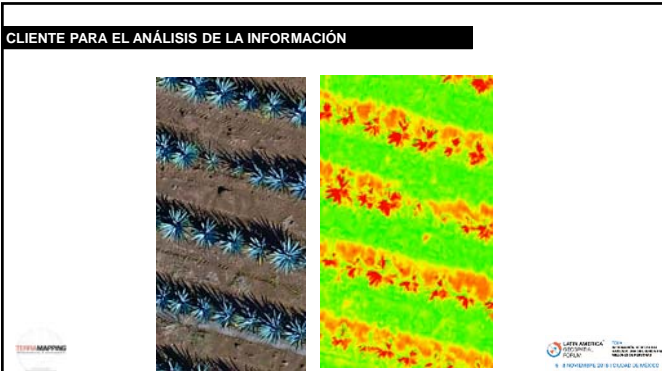
PROPIEDADES FÍSICAS, ALTURA, DIAMETROS.



TERRAMAPPING

LETA AMÉRICA
SOLUCIONES
SIG/RS
INTEGRADAS PARA EL SECTOR
AGROPECUARIO

CLIENTE PARA EL ANÁLISIS DE LA INFORMACIÓN



TERRAMAPPING

LETA AMÉRICA
SOLUCIONES
SIG/RS
INTEGRADAS PARA EL SECTOR
AGROPECUARIO

Mas tecnologías



TERRAMAPPING
Geoprocessing & Development

QUIEN VALIDA NUESTRO TRABAJO

Multidisciplinary Digital Publishing Institute (MDPI)

SPRINGER

Selection and Fusion of spectral indices to improve water body discrimination

Galvanes Cárdenas-Morales, Oscar Falduto, Susana E. Aguilar, Rosalva Torres, and Carmen Hernández

Machine Learning Approach to Fine Multiple Band for Water Bodies Detection

G. Cardenas-C., O. Falduto, S. Aguilar, R. Torres, C. Hernandez, S. Torres

Abstract: This paper presents a machine learning approach to detect water bodies in satellite imagery. The approach is based on the use of a Support Vector Machine (SVM) classifier. The results show that the proposed approach is able to detect water bodies with high accuracy. The approach is based on the use of a Support Vector Machine (SVM) classifier. The results show that the proposed approach is able to detect water bodies with high accuracy.


Contacto


“Gracias”

Por favor contacte nuestro departamento negocios e innovacion.

email address:
info@terradata.com.mx



Para más información visite nuestro portal:
www.terradata.com.mx



Referencias

- Pretty, J., Sutherland, W. J., Ashby, J., Auburn, J., Boucombe, D., Bell, M., ... & Cambell, H. (2010). The top 100 questions of importance to the future of global agriculture. *International journal of agricultural sustainability*, 8(4), 219-236.
- Ruffo V., F. O. et al., (ed.), 2007. *Conocimiento y prácticas agronómicas para la producción de Agave tequilano Weber en la zona de denominación de origen del tequila*. Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias. Centro de Investigación Regional del Pacífico Centro
- Zarco-Tejada, P. J., Hubbard, N., & Loudjani, P. (2014). Precision Agriculture: An Opportunity for EU Farmers—Potential Support with the CAP 2014-2020. *Joint Research Centre (JRC) of the European Commission*.
- Zarco-Tejada, P., Hubbard, N., & Loudjani, P. (2015). *Precision Agriculture: An Opportunity for EU Farmers—Potential Support with the CAP 2014-2020*. *Joint Research Centre (JRC) of the European Commission Monitoring Agriculture Resources (MARIS) Unit HD9*, Brussels, Belgium: 2014. Technical Report.
- McBratney, A., Whelan, B., Atkeson, T., & Bouma, J. (2005). Future directions of precision agriculture. *Precision agriculture*, 6(1), 7-23.
- Wang, N., Zhang, N., & Wang, M. (2006). Wireless sensors in agriculture and food industry—Recent development and future perspective. *Computers and electronics in agriculture*, 50(1), 1-14.

Propuesta Elaborada Para Cuerpos de Agua

Actualmente cualquier región del Planeta puede ser rápidamente reconocida por las plataformas de teledetección satelital, ofreciendo la más variada información de los elementos que la integran y de sus características específicas.

Las imágenes que son obtenidas de este tipo de plataformas sobre cuerpos de agua se convierten en todo un sistema de información y por lo tanto en un excelente recurso de apoyo en la gestión, manejo, análisis e identificación de agua.

En el presente capítulo se aborda la metodología de extracción de características de cuerpos de agua sobre imágenes satelitales presentadas y aplicadas a este proyecto de tesis.

El agua es un recurso necesario en cualquier parte del mundo, especialmente para su consumo y riego. El aumento de las actividades humanas, especialmente en la cercanía de los cuerpos de agua, tiene efectos directos en estos, lo que se considera uno de los problemas ambientales más importantes en muchas áreas del mundo. Se estima que existen más de 8 millones de lagos de más de 1ha, alrededor de 40,000 presas de más de 15 metros, alrededor de 800,000 lagos más pequeños y más de 10 millones de km² de humedales alrededor del mundo [122], [219]. El agua es un recurso natural muy importante y en algunos lugares empieza a ser escasa. Es por ello que se necesita cada vez más cuidar este recurso y hacer un buen uso del agua con el fin de hacer una buena gestión e impedir su deterioro.

El conocimiento actual de la abundancia global y la distribución de cuerpos de agua puede provenir de fuentes como: compilaciones de mapas, como la base de datos global de lagos y humedales (Global Lake and Wetland Database, GLWD) recopilada por los autores Lehner y Doll [219] y de las extrapolaciones estadísticas basadas en la relación de abundancia y tamaño para estimar el número de pequeños lagos no cubiertos por GLWD [219]. Sin embargo, varios estudios han encontrado que las extrapolaciones estadísticas son propensas a errores y que probablemente sobrestiman la abundancia de los pequeños cuerpos de agua [193], [194], [219]. Estos análisis mostraron una considerable incertidumbre en su estimación y en cuanto a la recopilación de mapas se detectó que existe una variedad completa de errores e incertidumbres [122]. Incertidumbres que requieren métodos que permitan mapeo directo de los cuerpos de agua con mayor precisión y la teledetección por medio de imágenes de satélite es la única forma práctica de determinar los patrones espaciales y temporales de cuerpos de agua a nivel global [220], [193].

La información sobre el agua desempeña un papel vital en el monitoreo de los recursos hídricos presentes y futuros. La información confiable sobre la detección y distribución espacial de cuerpos de agua sobre la superficie de la tierra es de importancia crítica en muchas áreas de la investigación. Algunos ejemplos de estas áreas de la ciencia son la gestión de desastres por inundaciones, monitoreo, respuesta a emergencias, planificación y protección de los recursos del agua, gestión de la agricultura y ecosistemas [196], [179], [19], [245].

La gestión de la información a través de imágenes de satélite se ha incrementado de una manera notable en los últimos años, tanto a nivel de agencias gubernamentales como público. Los grandes avances tecnológicos de las últimas décadas en la capacidad de procesamiento de las computadoras y en el campo de la teledetección permiten la realización de estudios sobre grandes superficies (local, regional y global) a partir del uso de imágenes satelitales. Hace apenas unos años la información geoespacial era utilizada solo por especialistas, mientras que actualmente está al alcance de cualquier persona interesada; además de resaltar la utilidad de poder alcanzar de manera práctica y sencilla la información de múltiples sensores, temporalidades, diversas resoluciones espectrales y espaciales.

La extracción de características de cuerpos de agua a través de imágenes de satélite ha sido conducida en muchas áreas de la investigación. En el año 1995 el primer índice para detección de características en cuerpos de agua fue el Índice Diferencial de Agua Normalizado (Normalized Difference Water Index, NDWI) [104], [134].


Al día de hoy existen una variedad de índices que han sido desarrollados con el fin de limitar el error en la información o su pérdida [72], [136], [233]. La razón de información engañosa proviene de la dificultad de distinguir el agua de otras superficies, por ejemplo, las sombras de objetos elevados como edificios, puentes, torres y árboles dispersos en la imagen. La presencia de sombras puede causar una clasificación errónea debido a la similitud en los patrones de reflectancia y esto puede disminuir la precisión del mapeo de aguas superficiales y en detección de cambios [74]. Aunque los índices han mejorado a lo largo de los años, aun es necesario aplicar otras metodologías en conjunto y un mayor esfuerzo en la extracción de cuerpos de agua para mantener y gestionar los recursos hídricos de una manera efectiva [123].

La clasificación basada en píxeles se puede utilizar para clasificar cuerpos de agua de otras superficies, ver Figura 5.1.


Los dos tipos más comunes de clasificaciones basadas en píxeles son las clasificaciones no supervisadas y supervisadas [132], [133], aunque algunos enfoques combinan ambas metodologías. En la clasificación no-supervisada, los píxeles se agrupan en función de las propiedades de reflectancia de los píxeles y los grupos creados se denominan *cluster*. El número de grupos debe ser identificado por el usuario. Los dos algoritmos principales de agrupamiento son K-means e ISODATA. La clasificación supervisada se realiza seleccionando muestras representativas de cada clase de cobertura terrestre en la imagen y la clasificación de la cobertura terrestre se basa en las firmas espectrales definidas por el usuario [104].

5.1. Características Generales de la Imagen Óptica


Los sensores ópticos, como ya se explicó en la sección 2.1.11, están ubicados en la categoría de sistemas *pasivos* de teledetección. Utilizan al sol como fuente de energía y miden la porción de la energía emitida por esta fuente que los alcanza luego de interactuar con los elementos de la superficie terrestre y con la atmósfera. Los detectores CCD o CMOS del sensor generan una corriente eléctrica cuya intensidad es directamente proporcional a la radiancia detectada en un determinado rango de longitudes de onda y en un instante. Las imágenes multiespectrales son producidas por sensores ópticos que poseen detectores que miden en rangos distintos de longitudes de onda y la radiancia es registrada independientemente en cada uno de ellos, correspondiendo cada uno a una banda de la imagen llamada ráster. Los valores registrados se almacenan como ND en un formato dependiente de la resolución radiométrica del sensor. Por ejemplo 0-255 para una imagen a 8 bits.



(a)



(b)



(c)

Figura 5.1: (a) pertenece a la captura de imagen por el satélite Landsat 8 OLI, zona UTM 13 Norte utilizando la proyección WGS84 con fecha del 15 de febrero del 2014 en el área de Chapala, Jalisco, México; (b) Índice Diferencial de Agua Normalizado Modificado (MNDWI) y (c) Índice Diferencial de Agua Normalizado (NDWI) las imágenes pertenecen a la respuesta de una clasificación supervisada realizada por medio de un algoritmo de aprendizaje automático (Maquina de soporte Vectorial, SVM). Fuente: Servicio Geológico de Estados Unidos (USGS)[214].

5.2. Metodología General

En esta sección se explicarán la metodología de preprocesamiento y extracción de información utilizados en esta Tesis.

5.2.1. Preprocesamiento

La corrección de deficiencias y la reducción de errores provocados por efectos atmosféricos presentes en los datos que provienen de sensores montados en plataformas satelitales, se denomina preprocesamiento [133]. Como ya se explicó, los sensores remotos detectan la energía electromagnética que les llega del sistema tierra-atmósfera y la registran como una señal eléctrica sobre un dispositivo CCD, que luego es convertida a un ND. La imagen adquirida en formato digital presenta una serie de anomalías con respecto a la imagen real detectada, bien en la geolocalización de sus puntos o quizá en los valores de los píxeles que la componen. El preprocesamiento pretende minimizar en la medida de lo posible estas alteraciones mediante correcciones geométricas, radiométricas y atmosféricas [180], [133].

Correcciones Geométricas :

las imágenes de sensores remotos no son mapas. Sin embargo, con frecuencia, la información extraída de las imágenes de teledetección se integra con los datos de un mapa en un SIG o se presenta a los usuarios finales en forma de mapa [133].

La transformación de una imagen obtenida de una plataforma de teledetección para que tenga las propiedades de escala y proyección dadas por la proyección de un plano o mapa es denominada corrección geométrica. Las correcciones geométricas tienen por objeto lograr que cada píxel esté en la ubicación planimétrica que corresponde.

Desde un punto de vista operacional es posible agrupar los tipos de errores geométricos en dos áreas; sistemáticos y no sistemáticos. (I) Los errores sistemáticos incluyen la esfericidad y rotación de la tierra y la inclinación de la órbita del satélite. Usualmente las agencias espaciales corrigen estos errores antes de entregar las imágenes a los usuarios. (II) Los errores no sistemáticos incluyen los efectos del relieve y los movimientos de la plataforma satelital. La información para corregir estos errores no siempre está disponible. Por lo tanto, es necesario tomar GCPs en el terreno para conseguir la precisión deseada [186].

Es necesario un registro preciso de imágenes si se utiliza una secuencia temporal de datos de teledetección para detectar cambios, por ejemplo, la cobertura terrestre de un área. El término corrección geométrica puede incluir geocorrección, georreferenciación, geocodificación y ortorectificación [132], [133].

La geocorrección es una forma abreviada de corrección geométrica y no tiene atributos especiales. La georreferenciación generalmente implica que los cuatro bordes de la imagen tienen coordenadas geográficas, pero el píxel individual no recibe latitud/longitud. Es decir, no se toman en cuenta datos específicos de sistema geodésico, proyección cartográfica, etc. Geocodificación significa que la

imagen tiene todas las propiedades de un mapa en todos los puntos de la imagen y ortorectificación que es el proceso aplicado a una imagen satelital donde cada pixel representa una posición verdadera sobre el terreno. Esto significa que la elevación del terreno se ha incluido en el proceso de corrección lo que implica que todos los píxeles se ven desde un punto superior y esta es la forma más precisa de corrección geométrica. La ortorectificación es la forma en la que un alto porcentaje de los elementos presentan una escala homogénea, en teoría libre de errores y deformaciones y aproximadamente con la misma validez de un plano cartográfico, en el aspecto de precisión [133], [175]. En el caso de los estudios presentados en esta tesis se utilizó la ortorectificación




Figura 5.2: Corrección de Distorsión Geométrica.

Correcciones Radiométricas :

las correcciones radiométricas tienen por objeto relacionar los ND con variables con significado físico. Los procedimientos necesarios son distintos según el sensor utilizado, pero pueden explicarse en términos generales de acuerdo a la región del espectro electromagnético que se está estudiando.

Por ejemplo, si se estudian las imágenes tomadas en las bandas óptica e infrarroja en diferentes momentos, una de las fuentes de variación que se deben tener en cuenta es la diferencia en el ángulo del sol. Una imagen tomada con un ángulo solar bajo proporciona sombras largas, a diferencia de un ángulo solar alto generará un efecto de sombra diferente. Si la superficie reflectante es

lambertiana, ver sección 2.1.8, la magnitud del flujo radiante que llega a los sensores dependerá del sol y de los ángulos de visión [133].

La obtención, descarga libre y gratuita de las imágenes satelitales utilizadas en esta Tesis se realizó en la página web del Servicio Geológico de los Estados Unidos, USGS [214].

Este sitio ofrece la posibilidad de obtener un producto de nivel L1, ver Sección 2.2.2, en formato geotiff de las imágenes Landsat 8 OLI.

Debido a que este producto es estándar de Landsat LDCM, se debe tomar en cuenta la escalada de los niveles digitales, los cuales representan los datos de una imagen multiespectral adquirida por ambos sensores OLI y TIRS, ver Tabla 3.2 que deben ser corregidos radiométricamente.

La radiancia espectral es la energía que capta el sensor y se define como *el total de energía radiada en una determinada longitud de onda por unidad de área y por ángulo sólido de medida* [45]. La medición de la radiancia por el sensor se hace mediante su codificación en ND de acuerdo con unos coeficientes de calibración específicos para cada sensor. La calibración radiométrica consistió en el caso de las imágenes Landsat 8 OLI a la obtención de radiancia techo de la atmosfera (TOA) como medida de la cantidad de energía que llega al satélite (L_λ) a partir de los números digitales ND siguiendo la ecuación:

$$L_\lambda = M_L * ND + A_L \quad (5.1)$$

donde L_λ [watts/m² * srad * μ m] es la radiancia medida por el sensor Landsat 8 OLI, ND es el número digital, M_L es el factor multiplicativo de escalado específico obtenido del metadato y A_L es el factor aditivo de escalado específico obtenido del metadato, para cada banda espectral λ [215].

Realizada la conversión a radiancia TOA, los datos pueden ser convertidos a valores de reflectancia TOA.

De manera similar a la conversión a radiancia, ND del producto L1 Landsat OLI también se pueden convertir a reflectancia TOA. La siguiente ecuación se usa para convertir los valores de ND a la reflectancia.

$$\rho\lambda' = M_\rho * ND + A_\rho \quad (5.2)$$

donde $\rho\lambda'$ es la reflectancia medida por el sensor Landsat 8 OLI, ND es el número digital, M_ρ es el factor multiplicativo de escalado específico obtenido del metadato y A_ρ es el factor aditivo de escalado específico obtenido del metadato, para cada banda espectral λ [215], [143].

Se debe de tomar en cuenta que $\rho\lambda'$ no es verdadera reflectancia TOA, porque no contiene una corrección para el ángulo de elevación solar. El cálculo de la reflectancia real $\rho\lambda$ de una cubierta captada por un sensor espacial está condicionado por el comportamiento de la atmósfera, así como del ángulo de

observación. La conversión a reflectancia TOA con corrección angular es dada por la siguiente ecuación:

$$\rho\lambda = \frac{\rho\lambda'}{\cos(\theta_{SZ})} = \frac{\rho\lambda'}{\text{sen}(\theta_{SE})} \quad (5.3)$$

donde $\rho\lambda'$ es el valor reflectancia espectral planetaria TOA, sin corrección para ángulo solar, θ_{SE} es el ángulo de elevación solar local; el ángulo de elevación solar del centro de la escena en grados y es provisto por metadato de la imagen y θ_{SZ} es el ángulo solar zenith local [215], [34], [143].

Correcciones Atmosféricas :

la radiación solar se ve afectada cuando interactúa con la atmósfera de la tierra, siendo dispersada y absorbida selectivamente. La suma de estas dos formas de pérdida de energía se denomina atenuación atmosférica. Los efectos atmosféricos sobre la radiación electromagnética (debidos principalmente a la dispersión y absorción) han sido descritos en la sección 2.1.8. Estos efectos agregan o reducen la radiancia que ejerce sobre el terreno y actúan de manera diferencial en todo el espectro. Si las estimaciones de los valores de radiancia o reflectancia se recuperan con éxito de los datos obtenidos por teledetección, entonces es necesario estimar el efecto atmosférico y corregirlo. Tales correcciones son particularmente importantes siempre que se requieran estimaciones de radiancias en el suelo o de reflectancia en lugar de valores relativos, por ejemplo, en estudios de detección de cambios se puede presentar problemas al complicar la comparación de firmas espectrales, presentando un impacto en la calidad de una clasificación en una escena donde la atenuación atmosférica puede variar de píxel a píxel [133], [175].




Figura 5.3: Imágenes del satélite Landsat 8 OLI, diferentes temporalidades del año 2014, sin embargo, se puede observar los problemas por efectos atmosféricos que se presentan y que pueden ser corregidos con ciertas limitaciones en varias regiones de la imagen. Area de la imagen Chapala, Jalisco, México. Fuente: Servicio Geológico de Estados Unidos(USGS) [214].

El usuario debe conocer las propiedades geométricas de los datos de la imagen y los efectos de factores externos (como el nivel y las variaciones de brillo, neblina, etc.) y ser capaz de seleccionar una técnica adecuada para corregir el defecto o estimar el efecto externo, en caso de que sea necesario. La corrección de deficiencias y la eliminación de fallas presentes en los datos que provienen de sensores montados en plataformas satelitales, se denomina preprocesamiento [133]. Como ya se explicó anteriormente la corrección de las deficiencias geométricas, radiométricas y atmosféricas son imprescindibles en el preprocesamiento de la imagen; sin embargo, es necesario

resaltar que no todas estas operaciones se aplicarán necesariamente en todos los casos de uso. En el caso del desarrollo de esta tesis se utilizaron los 3 tipos de correcciones mencionadas en esta sección.

5.2.2. Metodologías de Extracción de la Información

En esta sección se explicarán los fundamentos de los métodos de extracción de información usados en esta tesis.

5.2.3. Índices Espectrales

El campo de la teledetección el monitoreo de cuerpos de agua ha sido ampliamente usado desde hace más 30 años [81]. Este campo de investigación ha generado la facultad de acceso a la información de manera periódica y con un amplio rango de detección.

La teledetección por medio de imágenes ópticas ha generado la posibilidad de adquirir información de cuerpos de agua de manera rápida, periódica y precisa sobre el monitoreo de cuerpos en agua superficiales [237]. En el campo de la teledetección óptica existen 2 categorías en las cuales la extracción de cuerpos de agua se puede clasificar: (I) Los métodos de umbralización de banda única, que son aquellos que se usan para distinguir diferentes características de la superficie al establecer un cierto umbral en una sola banda de imagen de detección remota, los cuales determinan el umbral según las diferencias de reflectividad entre los cuerpos de agua y otras características de la superficie para extraer información [81], [71].

(II) Los métodos de umbral multibanda o índices que son ampliamente utilizados en la extracción de cuerpos de agua [81]. El objetivo de obtener la información que se permite adquirir desde un índice, es la reducción de las múltiples bandas de datos en un solo ráster o capa, concentrando así la información más importante según el tipo de estudio que se lleva a cabo [186], [102].

Todos los índices para detección de agua explotan su principal característica física en las imágenes satelitales: una disminución en la reflectancia de las longitudes de onda visible a infrarroja; es decir, una característica inherente de un índice para detección de cuerpos de agua es que se basa en el hecho de que el agua absorbe energía en longitudes de onda del infrarrojo cercano (NIR) y del infrarrojo de onda corta o medio (SWIR), mientras que la vegetación y el suelo tienen una fuerte reflexión [75]. La operación aritmética en el diseño de un índice de detección de cuerpos de agua no solo mejora las señales espectrales al contrastar la reflectancia entre diferentes longitudes de onda, sino que también cancela una gran parte de los componentes de ruido que son comunes en diferentes regiones de longitud de onda; por ejemplo, la calibración del sensor y condiciones cambiantes de radiación causadas por la iluminación, el suelo, topografía, y condiciones atmosféricas [242].

El Índice de Diferencia de Agua Normalizado (NDWI), ver Figura 5.4(b), es un método común para detectar cuerpos de agua; su fórmula es la siguiente:

$$NDWI = \frac{Verde - NIR}{Verde + NIR} \quad (5.4)$$


donde Verde e Infrarrojo cercano (NIR) son los datos de reflectancia del rango de longitud de onda del verde y NIR respectivamente. En este principio el agua tiene una alta reflectancia en la banda verde, mientras que es baja en la banda del infrarrojo cercano por lo que, a través del proceso de normalización, la diferencia se hace amplia, por lo que se resalta la información del agua. Con esta ecuación el valor NDWI varía de -1 a 1. Es decir es agua si el valor de NDWI es >0 y no es agua si el valor de NDWI ≤ 0 [134]. Existen varios inconvenientes del NDWI de McFeeters [134] y por lo que Xu [234] propuso el NDWI modificado (MNDWI), ver Figura 5.4(c), en el que se usó la banda SWIR de Landsat5 TM para reemplazar la banda NIR en la ecuación NDWI de McFeeters; al igual que el NDWI de McFeeters, el valor de umbral para MNDWI se estableció en cero. Sin embargo, Xu encontró que un ajuste manual del umbral podría lograr un resultado más preciso en la delimitación del agua [234]. NDWI de McFeeters inicio el estudio y desarrollo de varios índices para la detección de cuerpos de agua, índices que a día de hoy marcan la pauta en el estudio de las tecnologías de teledetección sobre cuerpos de agua.

También debemos tomar en cuenta el índice de Gao [79] que desarrolló un diferente NDWI para la estimación de cuerpos de agua y aunque los NDWI de McFeeters y Gao tienen la misma terminología, los conceptos de los dos NDWI son completamente diferentes. El NDWI de Gao desarrolla un NDWI diferente utilizado para estimación del contenido de agua del techo de vegetación y se calcula como la diferencia normalizada de NIR y el infrarrojo de onda corta (SWIR) [102].


Existen muchas variantes de NDWI, que pueden generar resultados bastante diferentes [102]. Sin embargo, siempre el objetivo de este índice es el realce de los datos de agua sobre las imágenes.

El Índice Automatizado de Extracción de Agua (AWEI), ver Figura 5.4(d) y (e), reportado por Feyisa en el año 2014 [74], refleja un método que mejora la precisión de la extracción de píxeles de agua sobre imágenes al aumentar la separabilidad espectral entre las superficies de agua y no de agua, particularmente en áreas con sombras y fondos urbanos que a menudo son causas importantes de baja precisión de clasificación. Esta metodología se divide en dos ecuaciones donde AWEInsh es un índice formulado para eliminar efectivamente los píxeles que no son agua, incluidas las superficies oscuras construidas en áreas urbanas y AWEIsh está formulado principalmente para una mejora adicional de precisión al eliminar los píxeles de la sombra que AWEInsh no puede eliminar efectivamente. El subíndice *nsh* se incluye para especificar que el índice es adecuado para situaciones donde las sombras no son un problema importante [74], [75].


Los Índices mencionados en esta sección son solo una parte de todos aquellos índices que funcionan para la detección de cuerpos de agua; sin embargo, cabe mencionar que todos los índices para detección de agua permiten clasificar los píxeles de agua aplicando un umbral, que puede ajustarse para diferentes imágenes o diferentes prioridades de clasificación.




(a)




(b)



(c)



(d)



(e)

Figura 5.4: La ilustraci6n muestra una imagen del sat6lite Landsat 8 OLI y una serie de 6ndices con los que se trabaj6 en esta tesis. (a) 6rea de estudio, presa de Nezahualc6yotl en Chiapas, M6xico; (b) 6ndice espectral NDWI; (c) 6ndice espectral MNDWI; (d) 6ndice espectral AWEInSH y (e) 6ndice espectral AWESH.

5.2.4. Clasificación

A pesar de las mejoras a través de diversos estudios, todos los índices requieren un umbral para discriminar el agua de no agua y los valores de umbral subjetivos y estáticos pueden llevar a una sobre o subestimación del área de píxeles de cuerpos de agua [75]. La extracción de información de cuerpos de agua a partir de datos satelitales sigue siendo un desafío; sin embargo, el uso de técnicas tales como clasificación supervisada y no supervisada, combinado con índices para la detección de cuerpos de agua mejora los resultados en la clasificación de datos multiespectrales en teledetección. Por ejemplo, Gao [81], logró extraer con una buena precisión pequeños cuerpos de agua en áreas montañosas y al mismo tiempo eliminar la sombras de montaña mediante la combinación de varios métodos extracción, entre los cuales se aplicó un método supervisado.

En el dominio del procesamiento de imágenes, la extracción de características es un campo prominente en uso [101]; por otra parte, la minería de datos o *data mining*, es un ciencia de explotación y análisis, que consiste en la búsqueda y extracción de información valiosa, patrones y reglas ocultos en grandes volúmenes de datos. Ambas ciencias son fundamento en muchos estudios y en la presente tesis [221], [28], [11].

Con el arribo continuo de potentes sensores satelitales, se ha vuelto más fácil adquirir imágenes de alta, media y baja resolución con mayor precisión. Esto ha facilitado que los usuarios experimenten en los datos de este tipo de sensores como nunca antes.

Una clasificación no supervisada es un proceso por el cual se realizan operaciones numéricas a fin de encontrar píxeles en una imagen y que puedan asignar a una categorías que se agrupan de manera natural por sus características las cuales incluyen aquellos píxeles de mayor semejanza en el espacio multiespectral. La mayoría de veces el proceso de agrupamiento resulta en un mapa temático que consiste en n clases espectrales. Un enfoque supervisado parte de un cierto conocimiento sobre las clases existentes, a partir del cual pueden derivarse criterios de clasificación. Esta aproximación suele venir dada por un paso previo en el que se seleccionan firmas espectrales con características de las clases existentes. Existen muchos métodos de clasificación sin embargo, en la presente investigación de tesis se abordarán los siguientes:

K-Nearest Neighbor (KNN) :

es un algoritmo de aprendizaje perezoso, lo que significa es que no utiliza los puntos de datos de entrenamiento para hacer ninguna generalización. En otras palabras, no hay una fase de entrenamiento explícita o es muy mínima. Esto también significa que la fase de entrenamiento es bastante rápida. La falta de generalización significa que KNN mantiene todos los datos de entrenamiento para tomarlos en cuenta en la fase de prueba.

El algoritmo KNN se basa en criterios de vecindad y se utiliza en muchas aplicaciones en el campo del reconocimiento de patrones estadísticos, la extracción de datos y el procesamiento de imágenes, entre otras [112], [129], [93].

El algoritmo de clasificación KNN es simple pero computacionalmente intensivo y es reconocido por su precisión, también es robusto, en el sentido de no exigir a las categorías ser linealmente separadas. Su único inconveniente es el costo

computacional relativamente alto de la clasificación, es decir, para cada pixel de prueba, debe ser calculada su semejanza con todos los píxeles de entrenamiento [116].

KNN funciona esencialmente para clasificar valores buscando los puntos de datos *más similares* (por cercanía) aprendidos en la etapa de entrenamiento y haciendo conjeturas de nuevos puntos basado en esa clasificación.

El principio del algoritmo es, si la mayoría de las K muestras más similares a la consulta de un punto q_i en la característica del espacio pertenece a una determinada categoría, entonces el veredicto puede caer en el punto de consulta q_i y pertenecer a esa categoría. La similitud se puede medir por la distancia en la característica espacio, es por eso que el algoritmo es llamado K Vecino más cercano (KNN). Un conjunto de datos de entrenamiento con un etiquetado preciso debe ser bien conocido al principio para entrenar el algoritmo. Luego para una consulta de datos q_i cuya etiqueta no se conoce y que es presentada por un vector en el espacio de características, calcula las distancias entre este y cada punto en el conjunto de datos. Después ordena los resultados por el cálculo de distancias y la decisión de la etiqueta de clase del punto de prueba q_i [116], [198].

Cada punto en el espacio d-dimensional se puede expresar como un d-vector de coordenadas, tales como:

$$p = (p_1, p_2, \dots, p_n) \quad (5.5)$$

La distancia entre dos puntos en el espacio de características multidimensional puede ser definido de múltiples maneras. Usando la distancia Euclidiana que es el método más común.

$$dist(p, q) = \sqrt{\sum_{i=1}^n (p_i - q_i)^2} \quad (5.6)$$

La calidad del conjunto de datos de entrenamiento afecta directamente a los resultados de la clasificación. Al mismo tiempo, la elección del parámetro K también es muy importante, ya que diferentes K podrían dar como resultado diferentes etiquetas de clasificación [116]; sin embargo, en la literatura se indica que de manera general los mejores resultados se obtienen con $K=3$ o $K=5$ [198].




Figura 5.5: Búsqueda de KNN en un conjunto dado con $k = 3$ usando la distancia euclidiana.

Árbol de Decisión J48 :

el algoritmo J48 es una versión del clásico algoritmo de árboles de decisión C4.5 propuesto por Quinlan [168], esta escrito en el lenguaje Java dentro de los paquetes de Weka [130]. Los árboles de decisión se encuentran dentro de la categoría de clasificación supervisada, es decir, se tiene una variable dependiente o clase y el objetivo del clasificador es determinar el valor de dicha clase para casos nuevos. Una definición cercana al paradigma de los árboles de decisión sería: un clasificador es una partición del espacio de clasificación X en M subconjuntos disjuntos $A_1, A_2, A_3, \dots, A_m$, siendo X la unión de todos ellos y para todo x perteneciente a A_m la clase predicha es C_m [198].

El proceso de construcción del árbol comienza por el nodo raíz, el que tiene asociados todos los ejemplos o casos de entrenamiento. Lo primero es seleccionar la variable o atributo a partir de la cual se va a dividir la muestra de entrenamiento original (nodo raíz), buscando que en los subconjuntos generados haya una mínima variabilidad respecto a la clase. Este proceso es recursivo, es decir, una vez que se haya determinado la variable con la que se obtiene la mayor homogeneidad respecto a la clase en los nodos hijos, se vuelve a realizar el análisis para cada uno de los nodos hijos, ver Figura 5.6. Aunque en el límite este proceso se detendría cuando todos los nodos hojas contuvieran casos de una misma clase, no siempre se desea llegar a este extremo, para lo cual se implementan métodos de pre-poda y post-poda de los árboles [168].

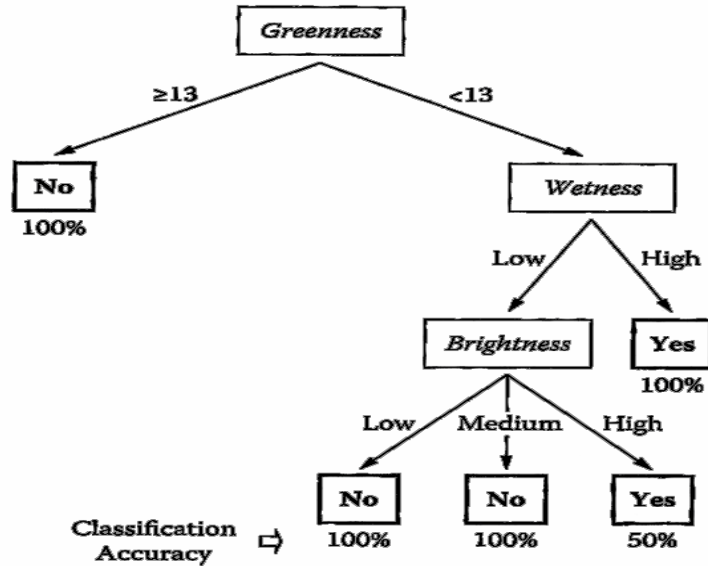


Figura 5.6: Ejemplos de árbol de decisión en cual una muestra es introducida, para la cual Wetness = low, Brightness = high y el valor de Greenness es el valor a clasificar. Fuente: Classification Methods for Remotely Sensed Data. Derechos de autor Paul M Mather 2009, [132].

El Algoritmo J48, es un algoritmo que permite generar un árbol de decisión a partir de los datos mediante particiones realizadas recursivamente este mantiene las amplias funcionalidades del C4.5, tales como que las divisiones sobre las variables discretas sean siempre binarias o cambiar un método de post-poda que utiliza el algoritmo C4.5 por un método basado en reducción de error (reduced-Error-Pruning) el cual se basa en dividir el conjunto de entrenamiento en el numero de subconjuntos que se deseen y reserva uno de ellos para realizar la estimación del error.

Los algoritmos de aprendizaje de árboles de decisión en su forma más sencilla obtienen un modelo que es completo y consistente con respecto a la evidencia; sin embargo, al ajustarse demasiado a la evidencia suele tener como consecuencia que el modelo se comporte mal para los nuevos datos, ya que, en la mayoría de los casos, el modelo es solamente una aproximación del concepto objetivo del aprendizaje. Por tanto, intentar aproximar demasiado hace que el modelo sea demasiado específico, poco general y por tanto, malo con otros datos no vistos [17], [198].

Naive Bayes :

es el algoritmo de clasificación fundamentado en el teorema de Naive Bayes (NB), es un clasificador simple probabilístico que calcula el conjunto de posibilidades contando la frecuencia y combinaciones de valores en un conjunto de datos dado, ver Ecuación 5.7.

$$P(A | B) = \frac{P(B | A) P(A)}{P(B)} \quad (5.7)$$

donde $P(A | B)$ es la probabilidad posterior, mientras que $P(A)$ es la probabilidad previa asociada con la hipótesis A [156].

NB predice las actividades futuras basadas en algunos datos históricos. Naive Bayes ofrece una alta precisión y velocidad cuando se aplica en grandes conjuntos de datos como las imágenes satelitales.

El clasificador Naive Bayes es seleccionado por su eficacia de clasificación y simplicidad de implementación [90], este clasificador ha sido ampliamente utilizado. NB se basa en la hipótesis de independencia condicional, es decir, el efecto de cada atributo en una clase dada es independiente de otros atributos, ver Figura 5.7. Cuando se establece el supuesto de independencia condicional, el algoritmo de clasificación de Naive Bayes tiene la menor posibilidad de error [113]. Basado en el supuesto de independencia condicional, el algoritmo de clasificación de Naive Bayes considera que cada atributo tiene el mismo efecto en el atributo de clase.




Figura 5.7: Naive Bayes es la forma más simple de la red bayesiana, en la cuales todos los atributos son independientes dado el valor de la variable clase [243].

5.2.5. Evaluación de la Exactitud

La selección de un diseño de precisión muestral debe ser tomado en cuenta ya que además de ser interés académico, dicho muestreo le da validez a un estudio [12]. Para decidir si un mapa es de una precisión aceptable, se comprueba una muestra de puntos del mapa o capa de interés con datos de terreno y se hace una declaración probabilística acerca de la verdadera precisión del mapa. Esta declaración generalmente reclama un nivel mínimo de precisión con un alto nivel de confianza.

Matriz de Confusión: una manera de expresar la precisión de las capas temáticas o mapas que se adquieren a partir de información satelital es estableciendo qué porcentaje del mapa ha sido correctamente clasificado cuando se lo compara con el *ground truth* (GT) o verdad del terreno. En general no sólo se procede a obtener la evaluación de la precisión de la capa en su conjunto, sino que se determina la exactitud de cada clase en particular. La clasificación generada al muestrear los datos ya clasificados se expresa en forma de una matriz de error también conocida como matriz de confusión [203].

En esta matriz, los datos de referencia generalmente están representados en columnas de la matriz y se comparan con los datos clasificados colocados en filas. La diagonal principal indica el grado de acuerdo entre los dos conjuntos de datos. La exactitud total del mapa se calcula dividiendo la suma de los valores de la diagonal principal de clasificaciones correctas, por el número total de la muestra, ver Figura 5.8.

La exactitud de la clasificación de cada conjunto de datos puede calcularse como el número de píxeles bien clasificados en relación al total de píxeles de las muestras tomadas para una clase. Este valor indica la probabilidad de que un punto geolocalizado y definido en el mapa como un ambiente particular se corresponda efectivamente con la realidad [12], [203].

		Datos de Referencia				
		X	Y	Z	Total	Suma de la Diagonal
Datos Clasificados	X	10	6	11	27	=48
	Y	4	18	3	25	Precisión
	Z	7	9	20	36	=48/88
		21	33	34	88	=54%

Figura 5.8: Ejemplo de Matriz de Confusión

Kappa: el coeficiente de Kappa fue derivado por Cohen en 1960 [51], es un índice flexible para usar cuando los acuerdos entre el conjunto de datos es una preocupación. Este coeficiente nos permite obtener una medida de la exactitud de

la clasificación (expresada como la concordancia entre el mapa obtenido y la verdad del terreno) extrayendo la contribución obtenida por azar [51], [96] y está definido por:

$$K = \frac{P(a) - P(e)}{1 - P(e)} \quad (5.8)$$

donde $P(a)$ es la proporción observada de píxeles bien clasificados y $P(e)$ es la probabilidad hipotética de clasificaciones correctas por azar.

$$K = \frac{NX_{ii} - \sum_{i=1}^r X_{i+} * X_{+i}}{N^2 - \sum_{i=1}^r X_{i+} * X_{+i}} \quad (5.9)$$

donde r es la cantidad de filas de la matriz, X_{ii} es la cantidad de observaciones que corresponden a la fila i y columna i , X_{i+} y X_{+i} son los totales de cada fila y columna respectivamente y N es el número total de observaciones.

Validación Cruzada: existe un problema recurrente en el ajuste de modelos que es el sobreajuste, lo que implica que el modelo se sobreajuste muy bien a nuestro conjunto de datos, pero puede no ser útil en el ajuste de otros datos. Una forma de validar el modelo es comprobar si el modelo predice correctamente un nuevo conjunto de datos. En caso de que se disponga suficientes observaciones la manera es dividir la muestra en dos submuestras, de forma que una se utilice para probar el modelo y la otra para evaluación del mismo. A esta metodología se le llama validación cruzada, que es considerando en dos variantes. En la primera, la llamada el método de validación cruzada *K-fold*, se divide la muestra en K submuestras, de forma que se utilizan $K-1$ para estimar el modelo y la restante como submuestra de evaluación, este proceso se repite K veces, de forma que cada submuestra es utilizada una vez para evaluar el modelo y $K-1$ veces para el ajuste. El segundo método de validación cruzada (leave-one-out cross-validation) y consiste en tomar K igual al número de observaciones, este método exige un mayor coste computacional, debido a que hay que ajustar tantos modelos como observaciones [202], [109].

5.3. Contribuciones

La extracción de cuerpos de agua mediante el uso de sensores remotos ha sido el método más utilizado e importante en la investigación de cuerpos de agua. Los índices espectrales de detección de agua se utilizan principalmente para la estimación de cuerpos de agua, debido a que permiten separar los píxeles de agua de no-agua. A través de esta investigación de tesis se analizaron varios métodos que incluyen la clasificación no supervisada, la clasificación supervisada, el umbral de banda única, fusión de índices espectrales para mejorar la discriminación del agua, método de relación entre espectro y el índice de agua, etc. Se seleccionaron diversas áreas de estudio para encontrar un método de extracción

de agua efectivo con diferentes usos en diferentes momentos. Los resultados que se obtuvieron muestran que, en comparación con los métodos tradicionales, estos aumentaron la precisión de manera general.

5.3.1. Selection and Fusion of Spectral Indices to Improve Water Body Discrimination

Gabriela Calvario Sánchez, Oscar Dalmau, Teresa E Alarcón, Basilio Sierra y Carmen Hernández

Los índices espectrales se usan ampliamente para enfatizar la información del cuerpo de agua en imágenes satelitales.

La selección del índice apropiado es una de las tareas que enfrenta la comunidad de sensores remotos cuando se estudian cuerpos de agua. En el artículo que se presenta a continuación se propone un enfoque para la selección y fusión de índices espectrales con el fin de lograr una mejor discriminación de agua y no-agua.

La publicación y los derechos de autor corresponden a la revista Institute of Electrical and Electronics Engineers (IEEE) Access. La versión en línea de la revista es la siguiente URL: <https://ieeexplore.ieee.org/abstract/document/8542672>

Received October 15, 2018, accepted October 31, 2018, date of publication November 21, 2018, date of current version December 19, 2018.

Digital Object Identifier 10.1109/ACCESS.2018.2881430

Selection and Fusion of Spectral Indices to Improve Water Body Discrimination

GABRIELA CALVARIO SÁNCHEZ¹, OSCAR DALMAU², TERESA E. ALARCÓN³,
BASILIO SIERRA¹, AND CARMEN HERNÁNDEZ^{1,4}

¹Departamento de Ciencias de la Computación e Inteligencia Artificial, Universidad del País Vasco UPV/EHU, 20018 Donostia-San Sebastián, Spain

²Centro de Investigación en Matemáticas, Guanajuato 36240, México

³Departamento de Ciencias Computacionales e Ingeniería, Centro Universitario de los Valles, Ameca 46600, México

⁴Centro de Investigação e Tecnologias Agro-ambientais e Biológicas, Universidade de Trás-os-Montes e Alto Douro, 5001-801 Vila Real, Portugal

Corresponding author: Teresa E. Alarcón (teresa.alarcon@profesores.valles.udg.mx)

This work was supported in part by the Consejo Nacional de Ciencia y Tecnología (CONACYT), Mexico, under Grant 258033, in part by the Basque Government under Grant IT900-16, and in part by the Spanish Ministry of Economy and Competitiveness (MINECO/FEDER) under Grant TIN2015-64395-R. The work of G. C. Sánchez was supported by CONACYT through a scholarship for her Ph.D. studies.

ABSTRACT Spectral indices are widely used to emphasize water body information in satellite images. The selection of the appropriate index is one of the tasks that the remote sensing community faces when water bodies are studied. In this paper, we propose an approach for the selecting and fusing of spectral indices, in order to improve water discrimination. First, we compute several spectral indices and analyze their discrimination power, taking into account the accuracy value. Through a hierarchical clustering applied only on indices with accuracy value greater than a certain threshold, we cluster the water indices into different groups. The result of the clustering depends on two factors: the discrimination capacity of the computed indices and the features of the studied water body. Indices in each group are fused by means of a linear combination. Therefore, we obtain an adaptive fusion of different spectral indices. The previous information is used to compute the likelihoods belonging to water and non-water. These values are the inputs for a probabilistic classification framework named Gaussian–Markov measure field. According to our experimental work, the proposed selection and fusion approach improves the discrimination power of the studied indices.

INDEX TERMS Water resources, spectral water index, remote sensing, spectral analysis, optimization.

I. INTRODUCTION

Water bodies are very important resources for maintaining equilibrium in the ecosystem, as well as social and economic development of a region or country. Therefore, the study of them is essential for establishing policies for the use and protection of water resources.

New technologies, particularly the employment of remote sensing and digital processing of satellite images, have provided synoptic and large scale observations, which has favored the investigation of water resources. Several techniques are used to study water bodies. Unsupervised and supervised methods, and the combination of both are general strategies used for water body extraction [1]. In the unsupervised algorithms, the grouping process is based on the feature space analysis of the image without information about classes. Examples of unsupervised algorithms are k-means [2], [3] and Iterative Self-Organizing Data Analysis Technique (ISODATA) [4]. Similar to k-means,

ISODATA is focused on the central tendencies and major structures of the data. Both methods are iterative algorithms, but unlike k-means, ISODATA includes a refinement step based on the splitting and merging of clusters. On the other hand, the supervised techniques require a training dataset with data consisting on a feature vector and the corresponding category or class. In the case of water segmentation, the algorithms need samples of pixels labelled as water/non-water (ground truth), that typically are given by an expert. Examples of supervised algorithms used for water classification are the random forest algorithm [5] and the J48 decision tree [6]. Moreover, the Support vector machine (SVM) [7] and artificial neural networks [8] are used in remote sensing for water recognition.

Spectral water indices, WI, are frequently used as descriptors for all aforementioned approaches. Among of them are: Normalized difference water index, NDWI [9], and modification of it such as NDWI1, NDWI5 in [10] and modified

normalized water index in [11]; water ratio index, WRI, in [12] and [13] and automatic water index for shadow, $AWEI_{sh}$, and no shadow conditions, $AWEI_{nsh}$ in [14]. The normalized difference moisture index, NDMI [15] and normalized difference vegetation index, NDVI [16] are indices frequently used to study vegetation, but due to their capacity to track the water stress in land coverage [17], both indices are useful to analyze water bodies. In [18], the perception model leads to accurate discrimination of water bodies. The considered descriptors were the MNDWI [11] and the reflectance in different spectral bands, obtained from Landsat TM imagery. The proposal in [19] allowed the analysis of the spatio-temporal changes in a water body using images from Landsat TM and ETM+ images. The experimental work took into account SVM [7] and three spectral indices: NDWI [9], MNDWI [11], $AWEI$ [14]. The SVM and NDWI were superior to other strategies. Research done in [20] combines a pixel-based approach such as NDWI and object oriented model [21], [22] on Sentinel-2 satellite images. This combination is justified by the fact that it is hard to discriminate objects with similar spectral response using only spectral indices, especially when this pixel-based approach tries to separate water bodies from another object with a low albedo, for instance: shadows, built-up areas, snow and ice [20]. Several indices have been proposed to avoid the mentioned problem [11], [14]. However there are still problems to finding the index or combination of appropriate indices that leads to an optimal descriptor that would facilitate the analysis of each water body. The results obtained by different spectral indices used for water detection, are not always reliable. Furthermore, the threshold values computed to discriminate water and non-water change with the contextual information and location of the water body [14]. Additionally, the spectral range of the bands varies from one sensor to another. Therefore the results obtained through spectral indices depend also on the sensor resolution.

In this work, we include several spectral indices and analyze the discrimination capacity of each of them. Firstly, indices with an accuracy value higher than a certain threshold are selected. Then, through a hierarchical clustering applied on selected indices, we obtain three groups. Indices in each group are mixed by means of a linear combination, leading to new three indices. Coefficients in the combination are calculated in three different ways: average and correlation sign, fisher discrimination analysis and best index in the group. The information given by the combination, together with the segmentation given by an expert are used to compute the likelihood values for a probabilistic segmentation framework, in particular, in this work a robust version of the Gaussian Markov Measure Field models is applied [23], [24].

The studied images correspond to Chapala lake, the Infiernillo and Nezahualcoyotl reservoirs in Mexico and they are Landsat 8 OLI images acquired through a USGS Global Visualization Viewer site <http://glovis.usgs.gov>.

The structure of this paper is the following: in Section 2 we briefly review the spectral indices included in the research,

in Section 3 we explain the proposal. Section 4 describes the studied areas. Section 5 and 6 are dedicated to the experimental setup and discussion of the results respectively. In Section 7 the conclusions are given.

II. STUDIED WATER INDICES

Table 1 contains all the indices considered in the proposal, including the formulae and the spectral range of the bands used to compute the index in the referenced papers (columns 2, 3 and 4).

In Table 1, ρ represents top-of-atmosphere-reflectances calculated according to [27].

The coefficients, for $AWEI_{nsh}$ and $AWEI_{sh}$ in the linear combinations were provided in [14]. Feyisa *et al.* [14] calculated these coefficients through an iterative procedure that maximizes the separability between water and non-water; they are used for the study of any water body and the facts related to the acquisition and the structure of the object are no longer considered when the index is applied.

The capability of detecting water bodies, for all included indices, depends on the resolution of the sensors and on the structure of water body being studied.

III. THE PROPOSAL

In general, the aforementioned spectral indices have proven to present a high discrimination power for water body detection. However, in some situations the discrimination power may decrease due to the particular conditions of the water body, cloudy weather, loss of information during the acquisition process and misleading data because of difficulty in discriminating water from other objects on the Earth's surface with low albedo. On the other hand, it has been observed that when applying the typical threshold for each water index these methods do not always yield good results [9], [11]. For the previous reason, some research has been carried out in order to find a good threshold, however these thresholds have been unstable, see [14] for details.

In this paper, we present a strategy based on the selection and fusion of spectral indices, taking into account the discriminant power of each studied index. The idea is to combine indices to form new adaptive indices (or layers) that can be used as the input of a classification method. In this work, for the classification step, we use a probabilistic segmentation method based on a robust version of the Gaussian Markov Measure Field models [23], [24].

Firstly, from indices presented in Table 1, we select the most relevant indices in order to reduce their number while maintaining, as much as possible, the discriminatory power. Secondly, we cluster the selected indices in K groups and finally, we compute new adaptive indices as follows:

$$L_i = \sum_{j=1}^{N_i} \alpha_i^j I_{ij}; \quad i = 1, 2, \dots, K; \quad (1)$$

where N_i is the number of spectral indices in the i -th cluster, I_{ij} represents an spectral index j in group i , α_i^j are the weights

TABLE 1. Included indices in the research. ρ represents the reflectances values. The spectral band ranges, in the third column, correspond to the resolution of the sensors in the references provided in the fourth column.

Name	Formulae	Satellite Band wavelength (μm)	Reference
NDWI	$\frac{\rho_2 - \rho_4}{\rho_2 + \rho_4}$ $\frac{\text{Green} - \text{NIR}}{\text{Green} + \text{NIR}}$	Landsat 5 TM Green band \rightarrow 0.52-0.60 NIR band \rightarrow 0.76-0.90	[9]
NDWI1	$\frac{\rho_7 - \rho_5}{\rho_7 + \rho_5}$ $\frac{\text{SWIR2} - \text{SWIR1}}{\text{SWIR2} + \text{SWIR1}}$	Landsat TM/ETM+ SWIR2 band \rightarrow 2.06-2.34 SWIR1 band \rightarrow 1.55-1.75	[10]
NDWI5	$\frac{\rho_7 - \rho_2}{\rho_7 + \rho_2}$ $\frac{\text{SWIR2} - \text{Green}}{\text{SWIR2} + \text{Green}}$	Landsat TM/ETM+ SWIR2 band \rightarrow 2.06-2.34 Green band \rightarrow 0.52-0.60	[10]
MNDWI	$\frac{\rho_2 - \rho_5}{\rho_2 + \rho_5}$ $\frac{\text{Green} - \text{SWIR}}{\text{Green} + \text{SWIR}}$	Landsat TM/ETM+ Green band \rightarrow 0.52-0.60 SWIR1 band \rightarrow 1.55-1.75	[11]
NDPI	$\frac{\rho_1 - \rho_4}{\rho_1 + \rho_4}$ $\frac{\text{Green} - \text{MIR}}{\text{Green} + \text{MIR}}$	SPOT5 Green band \rightarrow 0.50-0.59 MIR band \rightarrow 1.58-1.75	[25]
NDSI	$\frac{\rho_2 - \rho_5}{\rho_2 + \rho_5}$ $\frac{\text{Green} - \text{SWIR}}{\text{Green} + \text{SWIR}}$	Landsat 5 TM Green band \rightarrow 0.52-0.60 SWIR1 band \rightarrow 1.55-1.75	[26]
NDVI	$\frac{\rho_6 - \rho_5}{\rho_6 + \rho_5}$ $\frac{\text{NIR} - \text{Red}}{\text{NIR} + \text{Red}}$	Landsat 1 (ERTS 1) NIR band \rightarrow 0.7-0.8 Red band \rightarrow 0.6-0.7	[16]
WRI	$\frac{\rho_2 + \rho_3}{\rho_4 + \rho_5}$ $\frac{\text{Green} + \text{Red}}{\text{NIR} + \text{SWIR}}$	Landsat ETM+ Green band \rightarrow 0.52-0.60 Red band \rightarrow 0.63-0.69 NIR band \rightarrow 0.77-0.90 SWIR1 band \rightarrow 1.55-1.75	[12], [13]
AWEI _{sh}	$\rho_1 + 2.5\rho_2 - 1.5(\rho_4 + \rho_5) - 0.25\rho_7$ $\text{Blue} + 2.5\text{Green} - 1.5(\text{NIR} + \text{MIR1}) - 0.25\text{MIR2}$	Landsat 5 TM+ Blue band \rightarrow 0.45-0.52 Green band \rightarrow 0.52-0.60 Red band \rightarrow 0.63-0.69	[14]
AWEI _{nsh}	$4(\rho_2 - \rho_5) - (0.25\rho_4 + 2.75\rho_7)$ $4(\text{Green} - \text{MIR1}) - (0.25\text{MIR} + 2.75\text{MIR2})$	NIR band \rightarrow 0.76-0.90 MIR1 band \rightarrow 1.55-1.75 MIR2 band \rightarrow 2.08-2.35	

of the linear combination and K is the number of clusters. Therefore, the new adaptive index L_i is basically a linear combination of different spectral indices.

The general idea of the proposed method is to reduce the dimensionality while keeping the separability between classes. In order to select the most relevant indices, we

threshold the corresponding image, by means of Otsu [28]. This is a dynamic threshold method which is widely used in image processing. It consists of maximizing the variance between classes and minimizing the intraclass variance. This allows us to obtain an optimal threshold value for the separation between water and non water bodies. Then, we compute the discrimination capacity of each water index through the accuracy measure. Indices with an accuracy value higher than a certain threshold are selected. The training samples for computing accuracy values are randomly taken from the ground truth, i.e. water/non water regions manually labelled, provided by an expert.

The described step may reduce the feature space, but more importantly, it allows us to preserve the water indices with high discriminatory power. In the second step, after selecting the water indices with higher accuracy, we propose to cluster the selected indices in three different groups or clusters. In this work we use a hierarchical clustering algorithm [29]. Finally, for computing the new adaptive indices in (1) we propose three strategies. We can use the average with sign for each cluster, i.e., $\alpha_i^j = \frac{s_j}{N_i}$, for $j = 1, 2, \dots, N_i$, where s_j is the sign of the correlation between the index with best classification performance in the cluster i -th and the index I_j of the same cluster. Another proposed method is to highlight the contrast between the classes by maximizing the Fisher's criterion:

$$\text{FDR}(\alpha) = \frac{\alpha^T \mathbf{S}_b \alpha}{\alpha^T \mathbf{S}_w \alpha}, \quad (2)$$

where \mathbf{S}_b is the between-class scatter matrix and \mathbf{S}_w the within-class scatter matrix [30]. The solution is computed directly by:

$$\alpha = \mathbf{S}_w^{-1}(\mathbf{m}_1 - \mathbf{m}_2), \quad (3)$$

where \mathbf{m}_1 , \mathbf{m}_2 are the mean of the two classes, respectively [30]. The third proposed alternative simply assigns 1 to the coefficient corresponding to the spectral index with the best classification performance, and 0 to the remainder, i.e., selects the best spectral index for each cluster.

Here, we have proposed three different ways of obtaining the coefficients in (1). In practice, the selection of the weights of the linear combination depends on the analyzed image and the particular conditions of the water body. Regardless of the strategy used to calculate the coefficients of the linear combination, we obtain an adaptive fusion of different spectral indices. The new adaptive indices depend on the particular analyzed image, i.e., we cannot specify the spectral index to be selected nor the cluster to which it will belong.

In summary, we apply the previous fusion method to a sample of water pixels and non-water pixels. The sample is simply obtained from the ground truth provided by an expert. Then, we use the result of the linear combination to train a classification algorithm and finally we apply the classifier to the whole image.

Although, the fusion of the spectral indices can be used as a training set of any classification algorithm, for example:

a neural network or SVM; here we use a probabilistic segmentation method because this type of method takes into account the local information of the image, which allows producing less granular segmentations. Additionally, this method has recently been used successfully in satellite images for crop classification [23], [24]. For the sake of completeness we provide some details of a robust variant of the GMMF used in this work. The GMMF solves the problem of determining the probability $p_k(r)$ of each pixel or site r of the image to belong to class k . The GMMF is formulated as the following optimization problem:

$$\begin{aligned} \mathbf{p}^* = \arg \min_{\mathbf{p}} & \sum_{r \in \mathcal{L}} \sum_{k \in \mathcal{K}} (p_k(r) - v_k(r))^2 \\ & + \lambda \sum_{s \in \mathcal{N}_r} \omega_{rs} (p_k(r) - p_k(s))^2, \end{aligned} \quad (4)$$

where \mathcal{L} is the set of pixels in the region of interest, $\lambda > 0$ is a regularization parameter, \mathcal{N}_r is the set of neighboring pixels to site r , $\mathcal{K} = \{0, 1\}$ is the set of classes, $v_k(r)$ represents the likelihood of pixel r to belong to class k . The likelihoods $v_k(r)$ are computed from the layers L_i and histograms obtained from expert information, see details in [24]. The weight function $\omega_{rs} \in [0, 1]$ allows control of the edges between classes. Here we use:

$$\omega_{rs} = \frac{\mu}{\mu + \|v(r) - v(s)\|_2^2}, \quad (5)$$

such that $\omega_{rs} \approx 1$ if the sites r, s most likely belong to the same class and $\omega_{rs} \approx 0$ otherwise.

Finally, the solution of the optimization problem (4) yields the following Gauss-Seidel scheme:

$$p_k(r) = \frac{v_k(r) + \lambda \sum_{s \in \mathcal{N}_r} \omega_{rs} p_k(s)}{1 + \lambda \sum_{s \in \mathcal{N}_r} \omega_{rs}}, \quad (6)$$

This is an iterative algorithm in which the previous formula is repeated until convergence for each site r and each class k . Note however, that in our case, one just needs to apply the algorithm for one class, for example $k = 1$ and the other, $p_0(r)$ is simply computed as follows $p_0(r) = 1 - p_1(r)$. Figure 1 depicts the flowchart of the proposed algorithm.

IV. STUDY AREA

Three water bodies are included in this research: Chapala lake, the Infiernillo and Nezahualcoyotl reservoirs. The images were acquired from Landsat 8 satellite through a USGS Global Visualization Viewer site <http://glovis.usgs.gov>. The images have spatial resolution of 30 meters. The cloudiness level is very low, less than 10%, and does not affect the images corresponding to the analyzed water bodies. Table 2 summarizes some specifications of the study areas.

Chapala lake is located in Mexico and it is the largest natural lake in the country. Chapala is located in the eastern part of the state of Jalisco and in the northwestern part of Michoacan state in western Mexico, within latitude N20°15'00" and

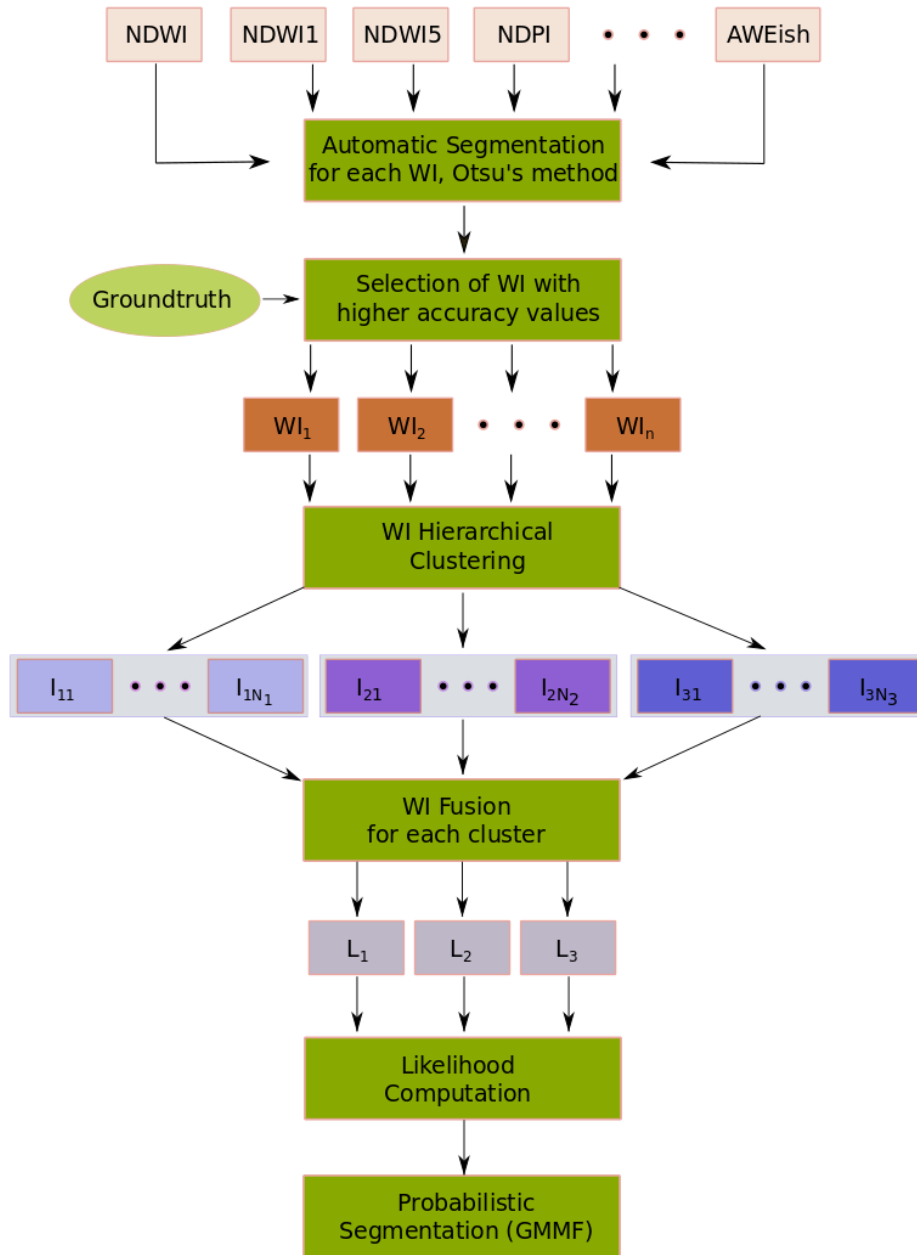


FIGURE 1. Flowchart of the proposed algorithm.

TABLE 2. Study areas.

Study Area	Path/Row	Acquisition Date	Water Body Type	Size
Chapala	29/46	2015-02-08	Lake	7731 x 7561
Infiernillo	28/47	2015-01-16	Reservoir	7711 x 7531
Nezahualcoyotl	22/48	2014-04-25	Reservoir	7781 x 7611

longitude W103°0'0". Its approximate dimensions are 80 km from east to west and about 12.5 km from north to south. The Chapala lake is highly polluted with heavy metals and other toxic substances derived from industrial and agricultural wastes [31].

Infiernillo reservoir, is an embankment dam located between the states of Michoacan and Guerrero in Mexico with coordinates: latitude N18°16'23" and longitude W101°53'34". The dam supports a hydroelectric power station and it has 149 m of depth and 344 m of length.




FIGURE 2. Study water bodies. From left to right: Chapala lake, Infiernillo and Nezahualcoyotl reservoirs.

The total capacity of the dam is $12\,500\,000\,000\text{ m}^3$, <http://www.conagua.gob.mx/atlas/>.

The Nezahualcoyotl dam is located in Chiapas, Mexico. The coordinates of the reservoir are $N17^{\circ}10'43''$ and $W93^{\circ}35'54''$. This reservoir supports an hydroelectric power station. The depth and the length of the dam are 37.5 m and 480 m, respectively. The total capacity of the reservoir is about $10\,596\,000\,000\text{ m}^3$, <http://www.conagua.gob.mx/atlas/>.

Figure 2 shows the images of Chapala lake, Infiernillo and Nezahualcoyotl reservoirs. Chapala lake has a regular shape with a border that resembles an ellipse, Infiernillo and Nezahualcoyotl reservoirs have irregular shapes. These images also contain narrow rivers and small lakes that could be a challenge for some segmentation algorithms.

A. PREPROCESSING

The images were radiometrically calibrated and geometrically corrected. This correction was applied according to documentation in [32] and it was performed using Matlab (v.2012) [33], [34].

V. EXPERIMENTAL SETUP

For the experiment, we use the images described in Section IV. The results of our proposal is compared with the linear and the radial basis function Support Vector Machines. Additionally, we provided a comparison with all the spectral indices included in Section II. Here we present the results of the MNDWI, AWEInsh and NDVI spectral indices due to they obtained the best and most stable results.

In the case of the supervised methods, SVM and our proposal, we conducted experiments with different sizes of randomly selected training sets, from 1% to 50% of the number of pixels in the analyzed water body. The training sets were selected from the ground truth. In all cases, the performance of the algorithms was good and very stable. In the experiments that follow, the size of the training set is equal to the 1% of the number of pixels that belong to the water body in the corresponding image. For the SVM methods we use as feature vector the set of indices described in Table 1.

To evaluate the performance of all reviewed indices, see Table 1, the studied images were manually segmented by an expert. The obtained images were considered as a ground truth.

An example of the segmentation process is depicted in Figure 3. First, we selected the water indices with an accuracy value greater than a threshold of 0.97. This parameter was tuned manually. If we select a too high value, the number of WI is too small, if we select a very low value the number of WI could be very high and the quality of some WI could be low. Therefore, there is trade-off. In practice, we would like to dispose a good number of WI (more than 3 because of the fusion step, see Figure 1) with high accuracy. We found experimentally that 0.97 met these requirements. Afterwards, these indices are clustered in three groups, see Fig. 3(a), and for each group we maximize the Fisher's criterion which gives the weights of the linear combination (1) obtaining the image in Fig. 3(b) from which we compute the likelihoods for each class, see Figures 3(a) y 3(d). Finally, the segmentation is depicted in Fig. 4.

A. COMPARISON MEASURES

For validation purposes we use several comparison measures which are based on the confusion matrix for binary class classification problems [35], [36]. These measures allow us to assess the performance of algorithms. The performance measure we used for comparing the algorithms are: overall accuracy, recall, precision and Cohen's kappa [37], i.e.,

$$\text{Overall accuracy} = \frac{TP + TN}{TP + FP + FN + TN}, \quad (7)$$

$$\text{Recall} = \frac{TP}{TP + FN}, \quad (8)$$

$$\text{Precision} = \frac{TP}{TP + FP}, \quad (9)$$

where TP is the true positive, TN is the true negative, FP is the false positive and FN is the false negative.

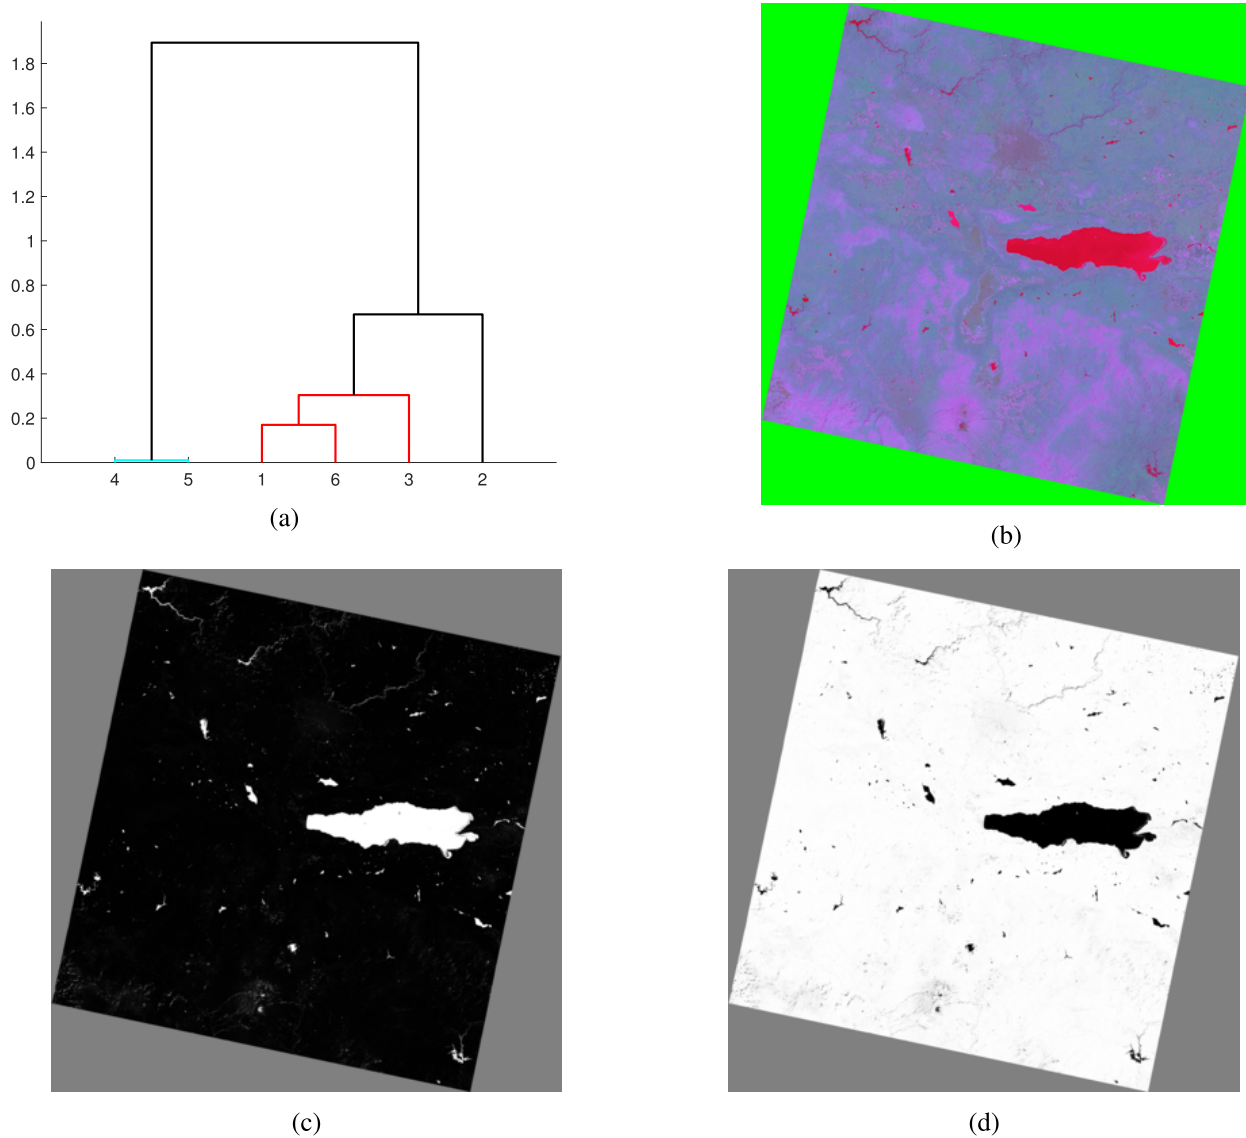


FIGURE 3. (a) Hierarchical clustering of water indices 1-NDWI, 2-MNDWI, 3-NDVI, 4-AWEInsh, 5-AWEIsh and 6-NDWI5. Dendrogram for clustering water indices applied to a sample taken from Chapala lake. (b) New image created with (1) and the following weights for the linear combination $\alpha_1 = [0.0237, 0.9997]$, $\alpha_2 = [-0.1674, -0.5467, -0.8204]$ and $\alpha_3 = [1]$ with corresponding water indices [AWEInsh, AWEIsh], [NDWI, NDVI, NDWI5] and [MNDWI] respectively. Weights were calculated through a maximization of the Fisher's criterion. Inputs of the GMMF Algorithm, (c) likelihood to belong to water body, (d) likelihood to belong to non-water.

The overall accuracy (7) is the number of correct classifications divided by the total number of classified data. The recall (8), in our case, corresponds to the proportion of pixels in the water body that are successfully classified, i.e., it is the ratio between true positives and the total number of positives (true positives and false negatives). The recall is also called *true positive rate* or *sensitivity*. The Precision (9) is a measure of the accuracy of the water class and it is the ratio between the number of correctly predicted data of the water class divided by the total number of classified data in the water class. Cohen's kappa [37] measures the agreement between two raters, in which each one classifies N items into K mutually exclusive categories.

VI. EXPERIMENTAL RESULTS AND DISCUSSION

In the case of the proposal, we consider three alternatives, see Section III, to combine the water indices: linear discriminant analysis (lda), the selection of the best index for each cluster (best), and the average of water indices for each cluster (average). Similarly, we compare two variants for SVM: the linear and Radial Basis Function (rbf) alternatives. The experiments are carried out to the three water bodies considered, some discussion is given for each of them, and a general analysis is also provided at the end of this section. The results are shown in Tables 3, 4 and 5. In bold we show the method with best results and in italic and bold the methods with the second best results.

TABLE 3. Chapala lake. numerical comparison. In bold the method with best results and in italics and bold the methods with the second best results.


Chapala lake	MNDWI	WRI	NDVI	SVM		Proposal		
				linear	rbf	lda	best	average
Accuracy	0.9943	0.9959	0.9955	0.9944	0.9940	0.9972	0.9971	0.9971
Kappa	0.9144	0.9319	0.9289	0.9159	0.9109	0.9557	0.9544	0.9549
Recall	0.9777	0.9052	0.9541	0.9798	0.9853	0.9799	0.9809	0.9797
Precision	0.8640	0.9648	0.9094	0.8648	0.8522	0.9354	0.9321	0.9341

TABLE 4. Infiernillo reservoir. numerical comparison.

Infiernillo reservoir	MNDWI	WRI	NDVI	SVM		Proposal		
				linear	rbf	lda	best	average
Accuracy	0.9927	0.9972	0.9955	0.9958	0.9970	0.9975	0.9978	0.9979
Kappa	0.9358	0.9744	0.9600	0.9632	0.9735	0.9777	0.9809	0.9813
Recall	0.9830	0.9696	0.9911	0.9913	0.9907	0.9843	0.9909	0.9911
Precision	0.8999	0.9823	0.9353	0.9409	0.9599	0.9737	0.9733	0.9739

TABLE 5. Nezahualcoyotl reservoir. numerical comparison.

Nezahualcoyotl reservoir	MNDWI	WRI	NDVI	SVM		Proposal		
				linear	rbf	lda	best	average
Accuracy	0.9858	0.9927	0.7694	0.9852	0.9850	0.9918	0.9942	0.9940
Kappa	0.7144	0.8295	0.1066	0.6979	0.6962	0.8129	0.8596	0.8560
Recall	0.9993	0.9950	0.9999	0.9769	0.9776	0.9917	0.9941	0.9939
Precision	0.5641	0.7166	0.0736	0.5514	0.5492	1.0000	1.0000	1.0000

**FIGURE 4.** Segmentation result of Chapala lake using GMMF with likelihoods, Fig. 3(c), computed from Fig. 3(b). Regions in white correspond to water bodies and in gray to non-water bodies. Regions of non-interest are areas in black.

A. CHAPALA LAKE

Obtained results for Chapala lake are shown in Table 3. As it can be seen, the results are very good for almost all the used indices. Nevertheless, it can be appreciated indeed that the proposed new approach outperforms the previous methods in accuracy, Kappa index and precision. With respect to recall, the SVM rbf obtains the best result, but it is important to notice that our method is ranked in second place. On the other hand, the overall accuracy is better for the proposed approach, which means that the proportion of well-classified pixels are better managed by the proposal.

B. INFIERNILLO RESERVOIR

Table 4 presents the results obtained for the Infiernillo water body; as it can be seen, the obtained results are very good for almost all the used indices. The proposed approach, using the average of water indices per cluster, obtains the best accuracy 0.9979 and Kappa 0.9813 results; obtained values for recall and precision are ranked in second position, with very low difference with the best ones SVM linear and WRI respectively.

C. NEZAHUALCOYOTL RESERVOIR

Obtained results for the Nezahualcoyotl reservoir can be seen in Table 5. As it can be seen, Kappa indices are in general not good for the state of the art methods, which obtain values in the range 0.1066 to 0.8295, value which is improved up to 0.8596 by the new proposed approach. The proposed approach also obtains the best accuracy among all of the used methods 0.9942 and 0.9940, slightly better than the third one 0.9927 obtained by WRI. As a matter of fact, the obtained precision is 1.0000 (actually the number of false positives in our proposals is very small compared to the true positives and the precision is practically 1), and that value combined with the good recall gives this accuracy result.

The new proposed approach obtained a 100% precision value, which is significantly better than the second best value (71.66%) obtained using the WRI index; the proposed approach is the one which obtains the best accuracy as well (99.42%). This indicates the appropriateness of the proposed approach for water detection in different places, morphologies and sizes.

The reviewed methods are competitive in their overall accuracy, however the proposed method not only presents the best overall accuracy, but is also more consistent with respect to the remaining comparison measures. The new method outperforms, in general, the kappa index and precision value for all the considered water bodies, see for example Table 5. Notwithstanding, our method requires more computational time due to the probabilistic segmentation (PS) step. The PS can easily be implemented in parallel with CUDA using a NVIDIA GPU and one can obtain binary segmentation in real time, see [38] for details.

VII. CONCLUSIONS

In this paper a new approach has been presented to deal with water bodies detection in satellite images; the main idea is to select and combine existing water indices which best fits with the characteristics of the studied water body. To this end, we select the water indices with best performance according to its accuracy, then the selected indices are clustered, and finally, the indices in each cluster are combined and used to perform a *water-non water* classification process.

Obtained results are very good, outperforming state-of-the-art approaches in almost all of the comparison measures considered in our study. Especially in accuracy and Kappa, the results are the best ones for all the considered water bodies.

It is worth mentioning that the new proposed approach is able to adapt to the characteristics of the water body in study, which helps to improve water indices accuracy. In fact, the method combines the best water indices found for a given water body, being dynamically adapted to the environment. It can be inferred as well that the formula used to classify water-non water pixels can vary for the same place in different periods of time, or in different weather conditions, which made it more feasible to deal with temporal evolution of the water presence.

As Future Works some lines remain open:

More combinations of water indices can be tested; as a matter of fact, the list of used indices can be updated and newer indices can be included in the combinations as they appear in the literature.

Other line which could improve the water detection capability is the use of Multi-classifiers instead of the one used in this paper. This is another research more related with Machine Learning, more precisely with the searching for the most adequate classifier to deal with a given classification task.

Another line that the authors of this paper have in mind is to use more image collections, and of different sensors, in order to extend the paradigm.

REFERENCES

- [1] S. D. Jawak, K. Kulkarni, and A. J. Luis, "A review on extraction of lakes from remotely sensed optical satellite data with a special focus on cryospheric lakes," *Adv. Remote Sens.*, vol. 4, pp. 196–213, 2015.
- [2] J. MacQueen, "Some methods for classification and analysis of multivariate observations," in *Proc. 5th Berkeley Symp. Math. Statist. Probab.*, vol. 1. 1967, pp. 281–297.
- [3] T. Z. Phyo, A. S. Khaing, and H. M. Tun, "Classification of cluster area for satellite image," *Int. J. Sci. Technol. Res.*, vol. 4, no. 6, pp. 393–397, 2015.
- [4] G. H. Ball and D. J. Hall, "ISODATA, a novel method of data analysis and pattern recognition," Stanford Res. Inst., Menlo Park, CA, USA, Tech. Rep., 1965. [Online]. Available: <http://www.dtic.mil/dtic/tr/fulltext/u2/699616.pdf>
- [5] B. C. Ko, H. H. Kim, and J. Nam, "Classification of potential water bodies using Landsat 8 oli and a combination of two boosted random forest classifiers," *Sensors*, vol. 15, no. 6, pp. 13763–13777, 2015.
- [6] T. D. Acharya, D. H. Lee, I. T. Yang, and J. K. Lee, "Identification of water bodies in a Landsat 8 oli image using a J48 decision tree," *Sensors*, vol. 16, no. 7, p. 1075, 2016.
- [7] C. Cortes and V. Vapnik, "Support-vector networks," *Mach. Learn.*, vol. 20, no. 3, pp. 273–297, 1995.
- [8] F. Rosenblatt, "The perceptron: A probabilistic model for information storage and organization in the brain," *Psychol. Rev.*, vol. 65, no. 6, pp. 386–408, 1958.
- [9] S. K. Mcfeeter, "The use of the normalized difference water index (NDWI) in the delineation of open water features," *Int. J. Remote Sens.*, vol. 17, no. 7, pp. 1425–1432, 1996.
- [10] Y. O. Ouma and R. Tateishi, "A water index for rapid mapping of shoreline changes of five East African Rift Valley lakes: An empirical analysis using Landsat TM and ETM+ data," *Int. J. Remote Sens.*, vol. 27, no. 15, pp. 3153–3181, 2006.
- [11] H. Xu, "Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery," *Int. J. Remote Sens.*, vol. 27, no. 14, pp. 3025–3033, 2006.
- [12] L. Shen and C. Li, "Water body extraction from Landsat ETM+ imagery using Adaboost algorithm," in *Proc. 18th Int. Conf. Geoinformatics*, Jun. 2010, pp. 1–4.
- [13] K. Rokni, A. Ahmad, A. Selamat, and S. Hazini, "Water feature extraction and change detection using multitemporal Landsat imagery," *Remote Sens.*, vol. 6, no. 5, pp. 4173–4189, 2014.
- [14] G. L. Feyisa, H. Meilby, R. Fensholt, and S. R. Proud, "Automated Water Extraction Index: A new technique for surface water mapping using Landsat imagery," *Remote Sens. Environ.*, vol. 140, pp. 23–35, Jan. 2014.
- [15] S. Jin and S. A. Sader, "Comparison of time series tasseled cap wetness and the normalized difference moisture index in detecting forest disturbances," *Remote Sens. Environ.*, vol. 94, no. 6, pp. 364–372, 2005.
- [16] J. W. Rouse, "Monitoring of natural vegetation," NASA/GSFC, Greenbelt, MD, USA, Tech. Rep., 1974. [Online]. Available: <https://ntrs.nasa.gov/archive/nasa/casi.ntrs.nasa.gov/19740004927.pdf>
- [17] M. A. Hardisky, V. Klemas, and R. M. Smart, "The influence of soil salinity, growth form, and leaf moisture on the spectral radiance of *Spartina alterniflora* canopies," *Photogramm. Eng. Remote Sens.*, vol. 49, no. 1, pp. 77–83, 2005.
- [18] K. Mishra and P. R. C. Prasad, "Automatic extraction of water bodies from Landsat imagery using perceptron model," *J. Comput. Environ. Sci.*, vol. 2015, Dec. 2015, Art. no. 903465. [Online]. Available: <http://downloads.hindawi.com/journals/jces/2015/903465.pdf>, doi: 10.1155/2015/903465.
- [19] G. Sarp and M. Ozelik, "Water body extraction and change detection using time series: A case study of Lake Burdur, Turkey," *J. Taibah Univ. Sci.*, vol. 11, no. 3, pp. 381–391, 2017.
- [20] G. Kaplan and U. Avdan, "Object-based water body extraction model using Sentinel-2 satellite imagery," *Eur. J. Remote Sens.*, vol. 50, no. 1, pp. 137–143, 2017.
- [21] G. Câmara, R. C. M. Souza, U. M. Freitas, and J. Garrido, "SPRING: Integrating remote sensing and GIS by object-oriented data modelling," *Comput. Graph.*, vol. 20, no. 3, pp. 395–403, 1996.
- [22] Y. He, X. Zhang, and L. Hua, "Object-based distinction between building shadow and water in high-resolution imagery using fuzzy-rule classification and artificial bee colony optimization," *J. Sensors*, vol. 2016, Jun. 2016, Art. no. 2385039. [Online]. Available: <https://www.tandfonline.com/doi/pdf/10.1080/22797254.2017.1297540?needAccess=true>
- [23] F. E. Oliva, O. S. Dalmau, and T. E. Alarcón, "Classification of different vegetation types combining two information sources through a probabilistic segmentation approach," in *Human-Inspired Computing and Its Applications* (Lecture Notes in Artificial Intelligence), vol. 8856. Springer, Nov. 2015, pp. 327–335. [Online]. Available: https://link.springer.com/chapter/10.1007/978-3-319-27101-9_29

- [24] O. S. Dalmau, T. E. Alarcón, and F. E. Oliva, "Crop classification in satellite images through probabilistic segmentation based on multiple sources," *Sensors*, vol. 17, no. 6, p. 1373, 2017.
- [25] J. Lacaux, Y. M. Tourre, C. Vignolles, J. A. Ndione, and M. Lafaye, "Classification of ponds from high-spatial resolution remote sensing: Application to Rift Valley fever epidemics in Senegal," *Remote Sens. Environ.*, vol. 106, no. 1, pp. 66–74, 1998.
- [26] D. K. Hall, J. L. Foster, D. L. Verbyla, A. G. Klein, and C. S. Benson, "Assessment of snow-cover mapping accuracy in a variety of vegetation-cover densities in Central Alaska," *Remote Sens. Environ.*, vol. 66, no. 2, pp. 129–137, 1998.
- [27] D. Chen, J. Huang, and T. J. Jackson, "Vegetation water content estimation for corn and soybeans using spectral indices derived from MODIS near- and short-wave infrared bands," *Remote Sens. Environ.*, vol. 98, nos. 2–3, pp. 225–236, 1998.
- [28] N. Otsu, "A threshold selection method from gray-level histograms," *IEEE Trans. Syst., Man, Cybern.*, vol. SMC-9, no. 1, pp. 62–66, Jan. 1979.
- [29] S. C. Johnson, "Hierarchical clustering schemes," *Psychometrika*, vol. 32, no. 3, pp. 241–254, 1967.
- [30] S. Theodoridis and K. Koutroumbas, *Pattern Recognition*, 4th ed. Amsterdam, The Netherlands: Elsevier, 2009.
- [31] J. Lira, "Segmentation and morphology of open water bodies from multispectral images," *Int. J. Remote Sens.*, vol. 27, no. 18, pp. 4015–4038, 2006.
- [32] U.S. Geological Survey. (2016). *Landsat 8 (L8) Data Users Handbook*. [Online]. Available: <http://landsat.usgs.gov/landsat-8-l8-data-users-handbook>
- [33] Y. Yang *et al.*, "Landsat 8 OLI image based terrestrial water extraction from heterogeneous backgrounds using a reflectance homogenization approach," *Remote Sens. Environ.*, vol. 171, pp. 14–32, Dec. 2015.
- [34] G. Chander, B. L. Markham, and D. L. Helder, "Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors," *Remote Sens. Environ.*, vol. 113, no. 5, pp. 893–903, 2009.
- [35] F. Provost and R. Kohavi, "On applied research in machine learning," *Mach. Learn.*, vol. 30, nos. 2–3, pp. 127–132, 1998.
- [36] M. Sokolova and G. Lapalme, "A systematic analysis of performance measures for classification tasks," *Inf. Process. Manag.*, vol. 45, no. 4, pp. 427–437, 2009.
- [37] J. Cohen, "A coefficient of agreement for nominal scales," *Edu. Psychol. Meas.*, vol. 20, no. 1, pp. 37–46, 1960.
- [38] F. J. Hernandez-Lopez and M. Rivera, "Binary segmentation of video sequences in real time," in *Proc. 9th Mexican Int. Conf. Artif. Intell.*, Nov. 2010, pp. 163–168.



GABRIELA CALVARIO SÁNCHEZ received the bachelor's degree in computer science engineering from the University of Guadalajara in 2003 and the master's degree in space science and technology in the field of satellite image processing from the Faculty of Engineering, Bilbao, Spain, in 2013. She is currently pursuing the Ph.D. degree with the Faculty of Informatics, University of the Basque Country. Her research interests are focused in the field of satellite and aerial image processing, machine learning paradigms, remote sensing, GIS, and computer vision.



OSCAR DALMAU received the B.Sc.Ed. degree in mathematics from ISP Manzanillo Cuba in 1989, and the M.Sc. degree in computer science and industrial mathematics and the Ph.D. degree in computer science from the Center of Research in Mathematics (CIMAT), Guanajuato, Mexico, in 2004 and 2010, respectively. He is currently with CIMAT. His research interests lie in the areas of machine learning, optimization, image processing, and computer vision.



TERESA E. ALARCÓN received the Title of Engineer degree in automated systems of management from the Moscow Institute of Direction "Sergo Orchonikidze," Russia, in 1989, the master's degree in digital image processing from the "José Antonio Echeverría" Polytechnic Institute, Cuba, in 1999, and the Ph.D. degree in computer science from the Center for Mathematics Research, Guanajuato, Mexico, in 2007. She is currently an Associate Professor with the Computational Sciences and Engineering Department, University of Guadalajara, Valley Campus, Ameca. Her field of research is digital image processing, including filtering, segmentation, and pattern recognition topics.



BASILIO SIERRA is currently a Full-Time Professor with the Computer Sciences and Artificial Department, University of the Basque Country. He is focused on supervised classification, one-class classification, machine learning, pattern recognition, and computer vision. He leads the University Robotics Team. He has published more than 40 journal papers, several international conference papers, and book chapters. His research interests are focused on improving robot autonomy by means of machine learning paradigms.



CARMEN HERNÁNDEZ is currently a Full-Time Professor with the Computer Sciences and Artificial Department, University of the Basque Country, and a PhD Collaborator with the Centro de Investigação e Tecnologias Agro-ambientais e Biológicas, Universidade de Trás-os-Montes e Alto Douro, Vila Real, Portugal. She is focused on GIS, spatial statistics, satellite image processing, machine learning, pattern recognition, and combinatorial optimization. Her research interests are focused on remote sensing and image processing.

...

5.3.2. Machine Learning Approach to Fuse Multiple Band For Water Bodies Detection

Gabriela Calvario, Carmen Hernández, Elena Lazkano, Basilio Sierra, Oscar Dalmau y Teresa E. Alarcón

La detección de cambios en los cuerpos de agua, es una aplicación común en teledetección. Este tipo de metodologías extrae las características de píxeles de agua utilizando datos de satélite.

En este artículo se presentan diferentes enfoques los cuales utilizan el aprendizaje automático aplicado a las características del agua, la automatización de un umbral adecuado aplicado a una banda espectral única y la detección de cambios sobre píxeles de cuerpos de agua.

El enfoque ha sido evaluado en comparación con métodos comunes de detección de cambios obteniendo resultados prometedores.

3^a Conferencia internacional sobre redes de informática y tecnología de la información, del 26 al 27 de agosto de 2017, en Montreal, Canada. La versión en línea de la conferencia es la siguiente URL: <http://www.innovativeresearchpublication.com/documents/canada%202017/single%20paper%2013.pdf>

MACHINE LEARNING APPROACH TO FUSE MULTIPLE BAND FOR WATER BODIES DETECTION

G. Calvario,

Dpmnt. of Comp. Sci. and A. I.

Faculty of Informatics

University of Basque Country

P. Manuel Lardizabal 1, 20018 Donostia

Spain

E. Lazkano,

Dpmnt. of Comp. Sci. and A. I.

Faculty of Informatics

University of Basque Country

P. Manuel Lardizabal 1, 20018 Donostia

Spain

O. Dalmau

CIMAT Mexico

C. Hernandez,

Dpmnt. of Comp. Sci. and A. I.

Faculty of Informatics

University of Basque Country

P. Manuel Lardizabal 1, 20018 Donostia

Spain

B. Sierra

Dpmnt. of Comp. Sci. and A. I.

Faculty of Informatics

University of Basque Country

P. Manuel Lardizabal 1, 20018 Donostia

Spain

T. Alarcón

CUValles Jalisco Mexico

Abstract—Classifying surfaces and analyzing changes are among the most common applications of remote sensing. To detect water bodies changes, water features are extracted using satellite data – taken in different days–, and after analyzed and compared to detect changes.

The novelties presented in this paper are threefold: firstly, a new approach for water change detection; it is based on

Machine Learning applied to a set of features, namely the Landsat 8 bands, and combinations of these bands, which are commonly used as Water Indexes.

Secondly, regarding the single band thresholding, it is necessary to identify an adequate threshold; this paper presents an approach to detect automatically an appropriate threshold value.

The third advance is related to the applicability of the proposed approach for surface water change detection during a time period.

The approach has been evaluated in comparison with common change detection methods, obtaining promising results.

1. Introduction

Water bodies detection is one of the most common applications of remote sensing. In its supervised form, field observations are used to train a classifier to detect water bodies in a determined area from its spectral radiance or reflectance, texture [18] and, in object-based classification, the shape, size and context of image segments [2]. These values can be derived from a single scene, or from a combination of scenes. For lakes nearby areas, the focus of this study, supervised classification has been used with

passive satellite images.

Surface waters such as lakes, rivers, artificial reservoirs, and seas are essential for climate equilibrium, hydrological cycle as well as ecosystem balance, providing fundamental resources to terrestrial life [27], [31]. Comprehensive and precise knowledge in terms of size-distributions and dynamics of surface water bodies is of crucial importance for the conservation of related aquatic biodiversity.

Among various satellite sensors, the Landsat satellite series has been most frequently used to detect long-term spatiotemporal variations in land covers thanks to its remarkable data availability, global coverage and continuity over 40 years [1], [29]. Research devoted to this satellite resource is, therefore, meaningful to extend the water monitoring mission of Landsat series.

In this paper we focus on the combination of different aspects which need to be taken into account when water body detection is to be done:

_ State-of-the-art water body detection paradigms are analyzed and tested, and a new approach on water detection from satellite images is presented, based on the combination of some of the existing ones.

_ Application of different Machine Learning classifiers which combine different Landsat-8 bands – Blue, Green, Red, Near Infrared (NIR), SWIR 1 and SWIR 2 bands – aiming at improve the water bodies detection existing approaches. As a matter of facts, some well known water detection filters have been used as features for the classification algorithms.

2. Related work

Water bodies detection and tracking systems have been studied extensively due to the increase of demand [10]. In this paper we focus on two main

aspects of water bodies detection from satellite images:

_ Water Body Detection Approaches.

_ Machine Learning to deal with Multi-Spectral Images

2.1. Water Detection Approaches

Several methods have been developed to detect water bodies by means of remotely sensed imagery. The most commonly used methods fall into the following categories:

1) Spectral bands: these methods identify water bodies by applying thresholds to one or more spectral bands; in general they are easy to implement, but often misclassify mountain shadows, urban areas or other background noise, classifying them as water bodies [23].

2) Classification: supervised or unsupervised machinelearning algorithms are used to extract water bodies from multispectral imagery. In the supervised classification approach, maximum-likelihood classifiers, decision trees, artificial neural networks and support vector machines are the most notable paradigms. For unsupervised classification, Kmeans and iterative self-organizing data analysis are used [12], [15]. These approaches may achieve higher accuracy than spectral band methods under some circumstances; nevertheless, expert experience or existing reference data are needed to select appropriate training samples, which avoids the use of these methods from being applied over large areas [6].

3) Water indices (WIs): combine two or more spectral bands using various mathematical operations to enhance the discrepancy between water bodies and the rest. The principle used in most WIs is based on that of the normalized-difference vegetation index (NDVI) [26].

Apart from those aspects, Temporal evolution analysis can also be performed, to this end all above mentioned points need to be considered.

2.2. Classification Techniques

[34] present a systematic surface water extraction method by taking advantage of the complementarity between a water index (WI) and a modified FCM (WIMFCM) using the Landsat-8 Operational Land Imager (OLI) images. Most of the above mentioned approaches have mostly used predefined water bodies; few works consider the application of learning techniques.

[11] proposes a new methodology to segment open water bodies based on a variant of principal component analysis (PCA). Close related to the presented approach, although using a different approach and methodology, [10] present a new model for extracting rivers and lakes.

[30] present an automated procedure that allows mapping of the actual number, size, and distribution of lakes using Landsat images. The same Research Team present, in a more recent work [31] GLOWABO, a system which allows for the global-scale evaluation of fundamental limnological problems, paving the line to an improved quantification of limnetic contributions to the biogeochemical processes at large scales.

The coastal zone of the Nile Delta witnessed several changes during the last century. [4] estimate the spatiotemporal changes occurred in the coastal zone between 1973 and 2007.

In the study of [21] a new approach for surface water change detection is introduced, integrating pixel-level image fusion and image classification techniques. Artificial neural network (ANN), support vector machine (SVM), and maximum likelihood (ML)

classification techniques were applied to extract and map the highlighted changes.

The approach most related to our work found in the literature is the one by [5], in which classifying surface cover types and analyzing changes are among the most common applications of remote sensing. They present a new Automated Water Extraction Index (AWEI) to improve classification accuracy in areas with shadow and dark surfaces.

Other authors present new water indexes to carry out shoreline detection in vast lakes. For instance, [16] present WI index, based on a logical combination of the Tasseled Cap Wetness (TCW) index and the Normalized Difference Water Index (NDWI).

3. Study areas and data sources: Lake Chapala and Landsat 8 Imagery

Chapala Lake (Jalisco, Mexico) within latitude parallels 20_070 and 20_210 North and longitude meridians

102_4004500 and 103_2503000 West [11]. Located east of the State of Jalisco and northwest of the State of Michoacán, is the largest lake in Mexico, has a maximum area of 114,659 ha, of which occupies 86 percent Jalisco and Michoacán 14 percent, and the main source of drinking water in Guadalajara, Jalisco because contributes 60 percent of the water coming into the city [3].

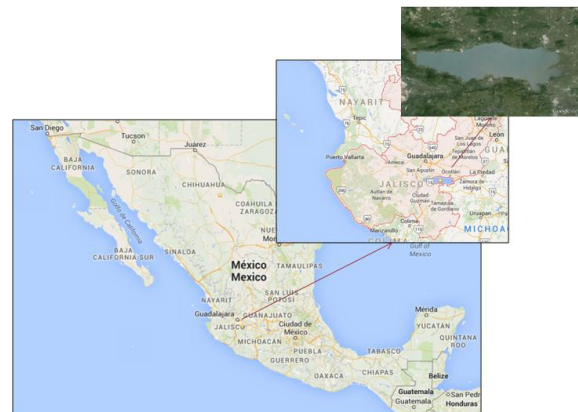


Figure 1. Lake Chapala, Jalisco, Mexico (Source: Google Maps and Google Earth)

We have used a time series of Landsat-8 OLI images acquired from June 2013 to May 2014 (one image per month) of Lake Chapala in Jalisco, Mexico. The images were acquired from [28], as Level 1 Terrain Corrected product (L1T), and pre-georeferenced to UTM zone 13 North projection using WGS84 datum. Table 1 presents the name, date, overall cloud cover and cloud cover around the Lake Chapala of time series of Landsat-8 OLI images.

TABLE 1. LANDSAT-8 IMAGERY USED FROM JUNE 2013 TO MAY 2014.

Name	Date	Cloud Cover	Cloud Cover %
LC80290462013161LGN01	2013-06-10	2.48	0.000
LC80290462013209LGN00	2013-07-28	9.57	0.440
LC80290462013241LGN00	2013-08-29	18.64	0.000
LC80290462013273LGN00	2013-09-30	26.75	0.257
LC80290462013289LGN00	2013-10-16	30.74	1.186
LC80290462013321LGN00	2013-11-17	20.41	0.000
LC80290462013337LGN00	2013-12-03	2.54	0.000
LC80290462014020LGN00	2014-01-20	0.17	0.013
LC80290462014036LGN00	2014-02-05	0.16	0.000
LC80290462014084LGN00	2014-03-25	0.18	0.000
LC80290462014100LGN00	2014-04-10	0.19	0.000
LC80290462014132LGN00	2014-05-12	7.67	0.012

To prepare the input satellite images for further processing, the usual pre-processing steps were performed: geometrically and orthometrically correction, radiometric calibration, co-registration of images, tessellation and mosaicking. We have omitted the clouds removal step because, on selected dates, there was no accumulation of clouds in the lake area (see Table 1).

4. Methods

Once acquired and pre-processed images in the time series, we have calculated several combinations of spectral bands and vegetation and water indices that have been used with the original bands in the classification process. This section presents three subsections, which are devoted, respectively, to the

Water Index combination, Training and Testing selection and thresholding, and time series analysis.

4.1. Combination of bands (bands ratio) and Vegetation and Water indices

In order to finally classify the targets as water or not water, we have used six bands of each Landsat image (RGB bands, Near infrared band and two Shortwave infrared bands), four combinations of bands (bands ratio), one vegetation index (NDVI index) and four indices related with water detection (NDWI indices). These combinations of bands and vegetation and water indices have been widely used in the literature of detection of water bodies. We have used the following bands ratios: Mid-Infrared Stress

Related Vegetation Index (MSVI2) [24], Ratio Vegetation Index (RVI) [17], Moisture Stress Index (MSI) [9], Midinfrared index (MidIR) [14]. We have also extracted, based on satellite imagery, the vegetation index known as Normalized Difference Vegetation Index (NDVI) [22] and four versions of Normalized Difference Water Index (NDWI): $NDWI1 = NIR-SWIR / NIR+SWIR$ known as Normalized Difference Moisture Index (NDMI) [7], $NDWI2 = G-NIR / G+NIR$ [13], $NDWI3 = R-SWIR / R+SWIR$ [20] and $NDWI4 = G-SWIR / G+SWIR$ known as Normalized Difference Snow Index (NDSI) [33]. Train and test set for classification and thresholding

First, we have selected the training data (train and test sets) into known zones of water bodies and areas which do not contain pixels of water from specific software and panchromatic first image of time series (reference image). We have used the Semi-Automatic Classification Plugin [Congedo(2013)] of [19] to create the ROIs that were used as training data set for supervised classification of pixels (water and non-water). We have selected 25 ROIs with 39349 pixels

which 16614 samples were of class "water" and 22735 samples were of class "no-water". The training data set was composed of 3674 pixels which 712 pixels of "water" class and 2962 pixels of "no-water" class and the test data set was composed of 33675 pixels which 15902 pixels of "water" class and 19773 pixels of "no-water" class.

Once the training set is selected, we have used three known classification algorithms: KNN, J48 and Naive Bayes [32]. To evaluate the accuracy of the classifiers, we have run 5-times repeated 2-fold cross-validation and we have collected statistics from this step of process. Finally, we have generated the final classifiers which have been applied to the test set with the aim of validate the performance of the classifiers over each image in the time series. Classification algorithms have been used from "RWeka" R-package [8].

A second contribution here presented is a proposal to determine the threshold of the vegetation and water indices; based on the training data set used in the classification, obtained from the reference image, we select a Machine Learning paradigm to decide the exact value of the threshold to be used for each water index. Afterwards, we have used these thresholds to binarize the vegetation and water indices throughout the year and to collect statistics of thresholding. For thresholding of vegetation and water indices, we have used a CART classification tree [25].

5. Experimental results

Performance of the water bodies detection system was evaluated in terms of detection rates and false positives or negatives. The same accuracy validation process has been applied to each image on each water detection standard approach. We have evaluated the classifiers (KNN, J48, Naïve Bayes) and obtained

rules of thresholdings for vegetation index (NDVI) and water indices (NDWI1, NDWI2, NDWI3, NDWI4) from test set of reference image. Figure 2 shows the evaluation of classifiers and thresholdings from test data all year long. With only two exceptions all of the algorithms have provided high-quality results. It is worth mentioning that the first thresholding of water index (NDWI1) has a kappa of 0.60 and J48 classification algorithm has a kappa value less than 0.9. Therefore, we can say that practically

all classifiers and thresholdings have given us a good rating for the first image in the time series (or reference image). We have decided not to show in the experimental results figures the results of NDWI1, as they distort the rest of the index and classifiers results. As we can see, for most of nthe algorithms the kappa value throughout the year is above 0.7 (except thresholding of water index NDWI1 and J48 algorithm). We can see small variations throughout the year probably due to seasonal variations but almost all algorithms follow the same trend.

As it can be seen, all approaches made good water discrimination with the exception of thresholded NDWI1, as has been already noticed in the previous subsection. Therefore, from now on the results obtained with the threshold of this index are omitted, as they disrupt the figures and tables.

The number of pixels identified as water is almost constant throughout the year (see Figure 3). It can be seen that most algorithms (except in this case the algorithm J48) maintain the same number of pixels of the year especially towards the end of the time series. For image differencing, we can see that changes (0 value) and no-changes (-1,+1 values) remain semi-constant throughout the year (Figure 3). In the experimental performed, the no-change is the most

stable feature, which can also be observed for image rationing (Figure 3) .

6. Conclusions and Future Works

Water body monitoring is essential for the effective management and conservation of water resources, which is enormously benefited from the use of remotely sensed images; an efficient as well as robust method to perform water detection from satellite images remains challenging due to noise sources and heterogeneous backgrounds. A robust methodology was designed in this study to deal with water bodies from multi-temporal and multi-spectral Landsat-8 images. The proposed approach took advantages of the complementarity between water detection Indexes and Machine Learning paradigms. Moreover, a temporal series analysis method as well as a thresholding strategy for known Water Indexes has been incorporated into the proposed method to reduce the requirement of manual actions.

It is worth mentioning that, with the use of a supervised classification approach to find the appropriate threshold for each water index, this work has been highly simplified. We do not need to find the threshold for each index and image, it is obtained automatically.

Although the current work makes progress on the improvements of water extraction accuracy in heterogeneous backgrounds, a full automation of the methodology in different sites remains lacking due to the parameter tuning issue in extreme situations.

Further experiments in different regions and with different classifiers are still necessary to enhance the adequateness of the method given the high diversity of aquatic environments globally. Nevertheless, the findings obtained in this study can provide a beneficial idea to enhance the accuracy and

generalizability of surface water detection using satellite images.

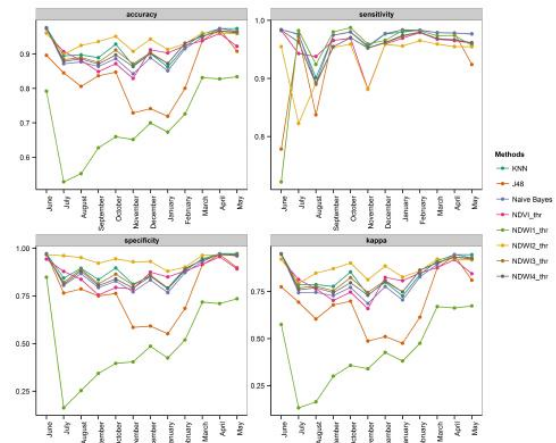


Figure 2. Accuracy, Sensitivity, Specificity, Kappa of all methods and for test set corresponding to each image throughout the year.

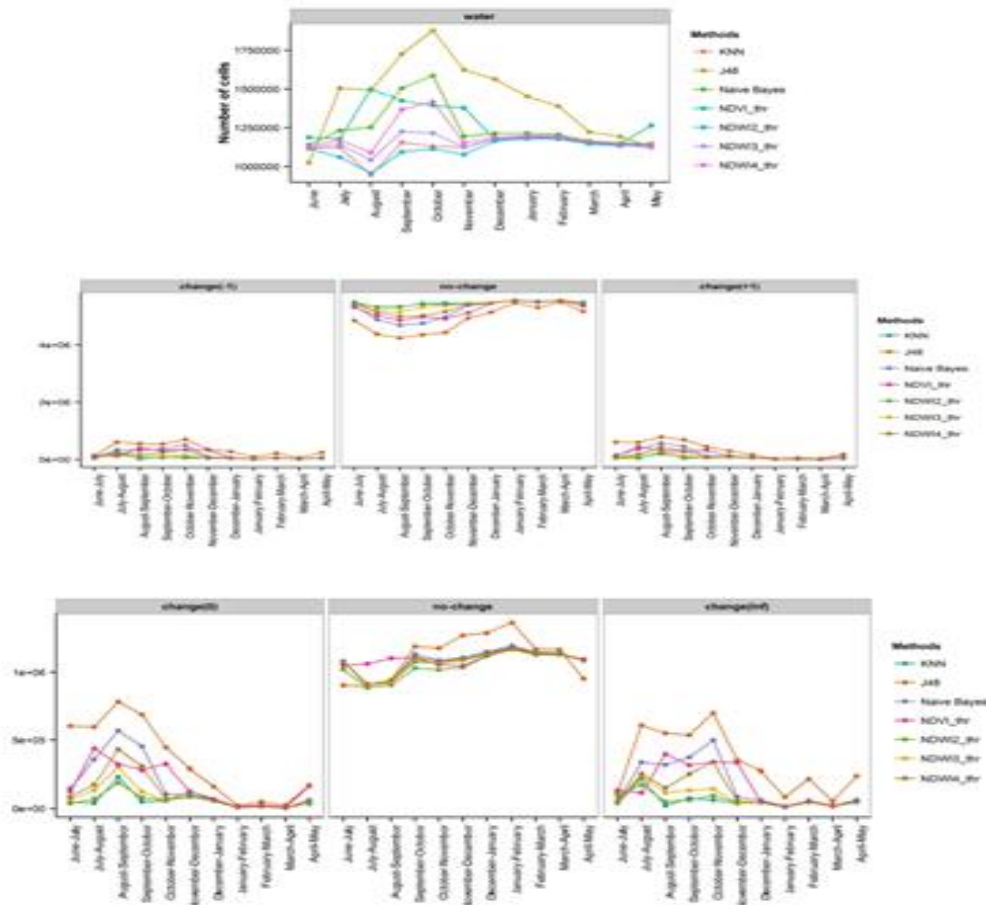


Figure 3. Number of water pixels, image differencing and image rationing of all methods throughout the year.

References

- [1] Anderson, M. C., R. G. Allen, A. Morse, and W. P. Kustas (2012), Use of Landsat thermal imagery in monitoring evapotranspiration and managing water resources, *Remote Sensing of Environment*, 122, 50–65, doi:10.1016/j.rse.2011.08.025.
- [2] Blaschke, T. (2010), Object based image analysis for remote sensing, *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1), 2–16, doi:10.1016/j.isprsjprs.2009.06.004.
- [3] CEA (2015), Comisión Estatal del Agua de Jalisco, Lago de Chapala, <http://www.ceajalisco.gob.mx/chapala.html>.
- [Congedo(2013)] Congedo, L. (2013), Semi-automatic classification plugin for QGIS, <http://www.planning4adaptation.eu/>.
- [4] El-Asmar, H., and M. Hereher (2011), Change detection of the coastal zone east of the Nile Delta using remote sensing, *Environmental Earth Sciences*, 62(4), 769–777, doi:10.1007/s12665-010-0564-9.
- [5] Feyisa, G. L., H. Meilby, R. Fensholt, and S. R. Proud (2014), Automated Water Extraction Index: A new technique for surface water mapping using Landsat imagery, *Remote Sensing of Environment*, 140(0), 23–35, doi:10.1016/j.rse.2013.08.029.

- [6] Frazier, P., and K. Page (2000), Water body detection and delineation with Landsat TM data, *Photogrammetric Engineering and Remote Sensing*, 66, 1461–1467.
- [7] Gao, B. (1996), NDWI a normalized difference water index for remote sensing of vegetation liquid water from space, *Remote Sensing of Environment*, 58(3), 257–266, doi:10.1016/S0034-4257(96)00067-3.
- [8] Hornik, K., C. Buchta, and A. Zeileis (2009), Open-Source Machine Learning: R meets Weka, *Computational Statistics*, 24(2), 225–232, doi:10.1007/s00180-008-0119-7.
- [9] Hunt, E., and B. Rock (1989), Detection of changes in leaf water content using Near- and Middle-Infrared reflectances, *Remote Sensing of Environment*, 30(1), 43–54, doi:10.1016/0034-4257(89)90046-1.
- [10] Jiang, H., M. Feng, Y. Zhu, N. Lu, J. Huang, and T. Xiao (2014), An automated method for extracting rivers and lakes from Landsat imagery, *Remote Sensing*, 6(6), 5067–5089, doi:doi:10.3390/rs6065067.
- [11] Lira, J. (2006), Segmentation and morphology of open water bodies from multispectral images, *International Journal of Remote Sensing*, 27(18), 4015–4038, doi:10.1080/01431160600702384.
- [12] Lu, D., and Q. Weng (2007), A survey of image classification methods and techniques for improving classification performance, *International Journal of Remote Sensing*, 28(5), 823–870, doi:10.1080/01431160600746456.
- [13] McFeeters, S. K. (1996), The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features, *International Journal of Remote Sensing*, 17(7), 1425–1432, doi:10.1080/01431169608948714.
- [14] Musick, H., and R. E. Pelletier (1988), Response to soil moisture of spectral indexes derived from bidirectional reflectance in Thematic Mapper wavebands, *Remote Sensing of Environment*, 25(2), 167–184, doi:10.1016/0034-4257(88)90099-5.
- [15] Otukey, J., and T. Blaschke (2010), Land cover change assessment using decision trees, support vector machines and maximum likelihood classification algorithms, *International Journal of Applied Earth Observation and Geoinformation*, 12, Supplement 1, S27–S31, doi:10.1016/j.jag.2009.11.002.
- [16] Ouma, Y. O., and R. Tateishi (2006), A water index for rapid mapping of shoreline changes of five East African Rift Valley lakes: an empirical analysis using Landsat TM and ETM+ data, *International Journal of Remote Sensing*, 27(15), 3153–3181, doi:10.1080/01431160500309934.
- [17] Pearson, R. L., and L. D. Miller (1972), Remote mapping of standing crop biomass for estimation of the productivity of the short-grass Prairie, Pawnee National Grasslands, Colorado, in *Proceedings of the Eighth International Symposium on Remote Sensing of Environment*, pp. 1357–1381, Willow Run Laboratories, Environmental Research Institute of Michigan, Ann Arbor, MI.
- [18] Purkis, S. J., S.W. Myint, and B. M. Riegl (2006), Enhanced detection of the coral *Acropora cervicornis* from satellite imagery using a textural operator, *Remote Sensing of Environment*, 101(1), 82–94, doi:10.1016/j.rse.2005.11.009.
- [19] QGIS (2009), QGIS Geographic Information System, <http://qgis.osgeo.org>.
- [20] Rogers, A. S., and M. S. Kearney (2004), Reducing signature variability in unmixing coastal marsh Thematic Mapper scenes using spectral indices, *International Journal of Remote Sensing*,

- 25(12), 2317–2335, doi:10.1080/01431160310001618103.
- [21] Rokni, K., A. Ahmad, A. Selamat, and S. Hazini (2014), Water feature extraction and change detection using multitemporal Landsat imagery, *Remote Sensing*, 6(5), 4173–4189, doi:10.3390/rs6054173.
- [22] Rouse, J., R. Haas, J. Schell, and D. Deering (1974), Monitoring vegetation systems in the Great Plains with ERTS, in *Proceedings of Third Earth Resources Technology Satellite Symposium*, vol. 1, pp. 309–317, Goddard Space Flight Center, Washington, D.C, NASA.
- [23] Rundquist, D. C., M. P. Lawson, L. P. Queen, and R. S. Cerveny (1987), The relationship between summer-season rainfall events and lake-surface area, *JAWRA Journal of the American Water Resources Association*, 23(3), 493–508, doi:10.1111/j.1752-1688.1987.tb00828.x.
- [24] Thenkabail, P., A. Ward, J. Lyon, and J. Merry (1994), Thematic Mapper vegetation indices for determining soybean and corn growth parameters, *Photogrammetric Engineering and Remote Sensing*, 60(4), 437–442, eng.
- [25] Therneau, T., B. Atkinson, and B. Ripley (2015), rpart: Recursive Partitioning and Regression Trees, <http://CRAN.R-project.org/package=rpart>, R package version 4.1-10.
- [26] Townshend, J., and C. Justice (1986), Analysis of the dynamics of African vegetation using the normalized difference vegetation index, *International Journal of Remote Sensing*, 7(11), 1435–1445, doi:10.1080/01431168608948946.
- [27] Tulbure, M. G., and M. Broich (2013), Spatiotemporal dynamic of surface water bodies using Landsat time-series data from 1999 to 2011, *ISPRS Journal of Photogrammetry and Remote Sensing*, 79(0), 44–52, doi:10.1016/j.isprsjprs.2013.01.010.
- [28] USGS GLOVIS (2015), US Geological Survey (USGS) Global Visualization Viewer (GLOVIS), <http://earthexplorer.usgs.gov>.
- [29] van Dijk, A. I. J. M., and L. J. Renzullo (2011), Water resource monitoring systems and the role of satellite observations, *Hydrology and Earth System Sciences*, 15(1), 39–55, doi:10.5194/hess-15-39-2011.
- [30] Verpoorter, C., T. Kutser, and L. Tranvik (2012), Automated mapping of water bodies using Landsat multispectral data, *Limnology and Oceanography: Methods*, 10(12), 1037–1050, doi:10.4319/lom.2012.10.1037.
- [31] Verpoorter, C., T. Kutser, D. A. Seekell, and L. J. Tranvik (2014), A global inventory of lakes based on high-resolution satellite imagery, *Geophysical Research Letters*, 41(18), 6396–6402, doi:10.1002/2014GL060641.
- [32] Witten, I. H., and E. Frank (2005), *Data Mining: Practical Machine Learning Tools and Techniques*, 2nd ed., Morgan Kaufmann, San Francisco.
- [33] Xu, H. (2006), Modification of Normalised Difference Water Index (NDWI) to enhance open water features in remotely sensed imagery, *International Journal of Remote Sensing*, 27(14), 3025–3033, doi:10.1080/01431160600589179.
- [34] Yang, Y., Y. Liu, M. Zhou, S. Zhang, W. Zhan, C. Sun, and Y. Duan (2015), Landsat 8 OLI image based terrestrial water extraction from heterogeneous backgrounds using a reflectance homogenization approach, *Remote Sensing of Environment*, 171, 14–32, doi:10.1016/j.rse.2015.10.005.

Conclusiones Finales y Líneas de Investigación Futuras

El presente trabajo está basado en el estudio de métodos de teledetección con sensores satelitales y aerotransportados; se trabajó en el desarrollo de técnicas y metodologías para el análisis de imágenes, recolectadas por sensores ópticos, que fueran eficientes en términos computacionales y orientadas a la aplicación paradigmas de aprendizaje automático en teledetección.

La investigación realizada abordó dos problemas:

- **Monitoreo de cultivos de agave tequilana weber variedad azul, con una plataforma UAV de bajo costo.**

Desarrollar un flujo de trabajo multidisciplinario para las imágenes ópticas adquiridas por medio de una plataforma UAV es cada vez más importante. Las imágenes basadas en UAV han estado ganando interés en los últimos años por diversos campos de la ciencia. En este estudio, se presentó un flujo de trabajo de procesamiento basado en un enfoque multidisciplinario y cuantitativo con una plataforma UAV de bajo costo.

La implementación de los UAV en monitoreo de agave puede generar escepticismo en su aplicación, debido a que es una metodología nunca antes usada y existe una resistencia al cambio por parte de los productores. Sin embargo, con la presente investigación se determinó que, manteniendo un proceso bien definido y controlado se puede desarrollar un monitoreo con una alta confiabilidad. La geometría de los levantamientos en el monitoreo fotogramétrico de agave mediante UAV presentó una resolución espacial centimétrica, parámetro que apoya en su verificación al profesional en campo.

Cabe resaltar que el procesamiento realizado con más de 500 imágenes adquiridas por el equipo UAV tuvo bajo rendimiento en el ordenador usado, debido

a la generación de ortoimagen, por lo cual cabe destacar que a pesar que se trabajó con un equipo de alto desempeño, el procesamiento de imágenes genera un alto coste computacional.

La presente investigación de tesis establece la primera metodología de estudio en el monitoreo de agave con un equipo phantom 4 de DJI, el cual se implementa con una resolución espacial de casi 3cm/pixel en relación directa a la altura de cada vuelo realizado. Con esta resolución espacial se puede establecer una escala estándar de 1:500; además el UAV demostró un radio de vuelo de 1.5 km con tiempo de vuelo de máximo 20 minutos, donde la cámara captó hasta 5.8 ha con imágenes a nadir a una altura de 60 m.

Es preciso señalar que a pesar de la utilización de tecnologías tan innovadoras con estas plataformas UAV, siempre es indispensable el seguimiento y verificación de la información por parte del experto en campo.

Como futuros trabajos en la investigación de monitoreo de cultivos de agave tequilana se consideran:

1. Desarrollo de un flujo de trabajo semiautomático completo donde solo haga falta integrar a la metodología generada las imágenes adquiridas por el equipo UAV y que este método dé como resultado el conteo automático georreferenciado de plantas de agave y maleza, disponibles para cualquier dispositivo (tablet, teléfono móvil, etc) con el fin de facilitarle al productor el conteo de sus cultivos.
 2. Elaboración de una base de datos de imágenes de agave que describa anomalías y enfermedades en el agave. Para desarrollar este tipo de investigación se cuenta ya con la primera base de datos de imágenes de muy alta resolución (ortoimágenes de plataforma UAV).
- **Monitoreo de cuerpos de agua sobre ecosistemas mexicanos por medio de imágenes multiespectrales, paradigmas de aprendizaje automático aplicables en cualquier lugar del Planeta.**

El sistema Landsat provee una resolución espacial, radiométrica y temporal adecuada para la evaluación de cuerpos de agua, ya que cubre grandes áreas y la recolección de datos está disponible de manera temporal y continua desde hace cinco décadas.

La idea principal fue seleccionar y combinar índices de agua existentes y que estos se adapten y expliquen las características del cuerpo de agua estudiado. Se eligieron los índices de agua con el mejor rendimiento de acuerdo con su precisión. La combinación de esos índices da lugar a una fusión adaptativa que origina un nuevo índice para cada cuerpo de agua estudiado. Posteriormente a través de un enfoque probabilístico se realiza la clasificación en agua y no agua. El clasificador utiliza como característica el nuevo índice creado.

Se hace notar que los resultados que se obtuvieron superaron a los enfoques de los índices más significativos en el estado de arte de detección de agua, se observó que en casi todas las medidas de comparación se superaron las expectativas. Esto se observó en los valores del coeficiente de precisión y en el del índice Kappa.

El nuevo enfoque propuesto fue capaz de adaptarse a las características del cuerpo de agua estudiado, lo que ayudó a mejorar la precisión de los índices de agua estudiados al aplicarlos por si solos. El método combina los mejores índices de agua encontrados para un cuerpo de agua y se adapta dinámicamente al ambiente.

La razón principal de esta investigación de tesis fue diseñar técnicas de tele-detección a través de paradigmas de aprendizaje automático que mejoren la precisión de extracción pixeles de agua y no agua, especialmente en regiones con sombras y fondos heterogéneos. En el trabajo de investigación realizado se describen diferentes formas para separar cuerpos de agua de otros fondos por medio de imágenes multispectrales, tomando en cuenta el sistema Landsat 8 OLI con imágenes geolocalizadas en México, pero con una metodología aplicable en cualquier lugar.

De la misma forma, se ha puesto de manifiesto la ventaja de utilizar los índices espectrales como una herramienta para el estudio de los pixeles de agua a partir de metodologías, análisis y discusiones robustas para el tratamiento de imágenes Landsat 8 OLI.

La investigación presentada utilizó técnicas de procesamiento digital de imágenes satelitales y metodologías de aprendizaje automático.

Lograr mayor automatización de la metodología propuesta para diferentes cuerpos de agua es un reto para el trabajo futuro de esta investigación. Factores como iluminación, sombras y topografía entre otras, obstaculizan una completa automatización.

Será necesario, además, investigar otros clasificadores y técnicas de aprendizaje profundo para mejorar la adecuación del método, dada la alta diversidad de ambientes acuáticos a nivel mundial. Sin embargo, los resultados obtenidos en este estudio pueden proporcionar una idea beneficiosa para mejorar la precisión y generalización de la detección de cuerpos de agua utilizando imágenes multispectrales de plataformas satelitales.

Como futuros trabajos, algunas líneas de investigación se presentan a continuación:

1. Probar con nuevas combinaciones de bandas de diferentes plataformas satelitales y generar nuevos índices para detección de cuerpos de agua.
2. Generar y mejorar la detección de pixeles de agua a través del uso de multclasificadores.

Anexos

La presente sección muestra un recorrido acerca de la opinión pública presentada en algunos periódicos y páginas web acerca de las metodologías planteadas en esta investigación de tesis.

Usan drones para contar plantaciones

2017-02-19 23:35:53



(Foto: Alfonso Hernández)

Jordán Martínez Águila, director de Desarrollo Geospacial de la empresa, informó que se podrá conocer de forma automatizada el área de cultivo, el número de plantas, hilos, altura de la planta, diámetro de ésta y gracias a que los drones tienen una cámara infraroja, se podrán determinar aspectos fitosanitarios dentro de los cultivos para saber cuáles plantas están enfermas.

Este tipo de tecnología apenas se está introduciendo en el área del agave con buen éxito y grandes beneficios aunque hay otras industrias que ya los utilizan, informó Gabriela Calvario, gerente de investigación de la misma empresa.

La industria del tequila se auxiliará de drones para hacer un censo que permita conocer a ciencia cierta el número de plantaciones de agave que existen en la zona de denominación de origen.

En el Campo Experimental del Consejo Regulador del Tequila (CRT), en el municipio de Acatic, se realizó un sobre vuelo para dar a conocer la importancia de utilizar tecnología de punta en los campos de cultivo.

La empresa Cubo Aeroespacial, fue contratada por el organismo regulador del tequila para auxiliar con la tecnología en el censo y será la que determine la escala de vuelos, dependiendo de los requerimientos.



De esta forma, el CRT le apuesta a la innovación para el registro de la cadena productiva.

Para este año hay 45 millones de plantas en posibilidad de ser jimadas, lo que garantiza el suministro de la materia prima para la elaboración de la bebida, dijo el director general del CRT, Ramón González.

“Como hay otros cultivos que han venido a competir por el agave como la inulina y los jarabes, a lo mejor el agave está registrado, lo venden y no lo dan de baja del inventario entonces eso nos puede ocasionar alguna información no precisa, en este caso lo que se le va a sumar es este esquema de drones que nos dará una certeza de 99.8 por ciento”.

Mencionó que hasta este mes de febrero, se cuenta con un inventario de 209 millones de litros de tequila, por lo que el abastecimiento de la bebida que da reconocimiento internacional no tendrá problema de abasto y está garantizado.

Recordó que en el 2016, se consumieron 43 millones de plantas de agave, equivalentes a 942 mil toneladas.



Piden inventario nacional

El director general del Consejo Regulador del Tequila enfatizó que se pretende que la Sagarpa realice un inventario nacional de agaves ya que el cultivo de agave está dando para varios productos entre los que destacan el mezcal, inulina, tequila, bacanora, sotol y jarabes. “Pero hay que ordenarlos porque hoy en día está ordenado el agave para el tequila pero los demás no, la idea es no estarnos compitiendo, por eso vienen las sobre demandas, no es que no haya agave, entonces la cadena agave-tequila tiene que estar preocupada por los demás para hacer más plantaciones y eso no conviene a nadie”.

Mencionó que mañana habrá una reunión con autoridades de la Sagarpa, quienes mostraron su interés por participar en el ordenamiento.

Dijo que igual que sucede en otros sectores, los precios del tequila y el agave se regulan por la ley de la oferta y la demanda, por lo que la especulación y desinformación alrededor del precio del agave son factores que han generado distorsiones en la industria.

Cabe señalar que del inventario que se tiene reportado, 78.5 por ciento corresponde a la categoría 100 por ciento agave y 21.5 por ciento a tequila.

El inventario actual del agave alcanza 120 mil hectáreas igual a 3.5 veces el Bosque de la primavera o toda la ciudad de México.



Enfermedades frecuentes

El Consejo Regulador del Tequila tiene desde el 2012 un Campo Experimental, ubicado en el municipio de Acatic, donde se generan respuestas en beneficio del sector primario, se identifican enfermedades y sintomatologías, además de la efectividad de productos que puedan controlar, curar o prevenir las enfermedades de la planta.

Adicionalmente trabajan para que la producción no sea mermada por marchitez, pudrición o mancha gris, principales enfermedades del agave.

El doctor Guillermo Briceño, director del programa de mejoramiento genético del agave en el Consejo Regulador del Tequila, dijo que la enfermedad más distribuida en los 5 estados que se ubican en la zona de denominación de origen llega a 3.9 por ciento. “Estamos bajos, pero necesitamos seguir monitoreando esta enfermedad que es marchitez del agave. Desde el 2012 se firmó un convenio con la Sagarpa a través de la Dirección de Sanidad Vegetal y se creó una campaña fitosanitaria del agave, se contratan técnicos para estar monitoreando Hay otras dos enfermedades que están en 0.6 por ciento y 0.5, que es pudrición del cogoyo y mancha gris, son las enfermedades que le ocasionan daños económicos al productor”.

Cabe señalar que la industria tequilera es el sustento de más de 70 mil familias y es representado por más de un millón de jornales al año.

45 millones de plantas en posibilidad de ser jimadas

942 mil toneladas de agave

209 millones de litros de tequila

120 mil hectáreas es el inventario actual del agave (equivalente a 3.5 veces el Bosque de la Primavera)

70 mil familias dependen de la industria tequilera

Aumentan ventas 8.5 por ciento

CIUDAD DE MÉXICO. El tequila ya es comercializado en 98 países, con ventas que alcanzaron un volumen superior a los 196 millones 736 mil litros en 2016 y un valor estimado en mil 203 millones de dólares.

La Secretaría de Agricultura, Ganadería, Desarrollo Rural, Pesca y Alimentación (Sagarpa) informó que las ventas de la bebida aumentaron 8.5 por ciento en volumen y 1.4 por ciento en valor, según estadísticas del Consejo Regulador del Tequila (CRT) y el Sistema de Información Arancelaria Vía Internet (SIAVI).

De 2014 a 2016, las exportaciones de este producto promediaron mil 187 millones de dólares y 188.9 millones de litros, refirió la dependencia federal en un comunicado.

Los principales destinos de exportación de tequila mexicano son Estados Unidos, Alemania, España, Francia, Japón, Reino Unido, Sudáfrica, Colombia, Canadá y Brasil.

Estos 10 países concentran alrededor de 92.4 por ciento de las exportaciones que realiza México de esta bebida a nivel mundial, el resto se divide en 88 naciones más a las que es enviado el tequila.

En Estados Unidos fueron comercializados 160 millones 985 mil litros; en Alemania, 5 millones 320 mil; en España, 3 millones 823 mil litros; en Francia, 3 millones 180 mil litros, y en Japón, 1 millón 757 mil litros. El valor total de las exportaciones de tequila a estos cinco destinos fue de mil 31 millones de dólares durante el año pasado.

Los crecimientos más importantes en adquisiciones de tequila se registraron en Alemania, nación que aumentó sus compras en 136 por ciento; Colombia, con 59.6 por ciento; Reino Unido, con 42 por ciento, y Canadá, con 20.6 por ciento de incremento. En el caso de China, uno de los mercados más recientes de tequila, las ventas a este destino se incrementaron en 8.5 por ciento entre 2015 y 2016, al pasar de 2.5 a 2.7 millones de dólares. Notimex

EH/I

Derechos reservados ® ntrguadalajara.com

Busca CRT crear inventario nacional de agave



Viridiana Saavedra Ponce

En la actualidad el territorio protegido para la producción de agave alcanza 120 mil hectáreas, equivalente a casi toda la extensión de la Ciudad de México y el Consejo Regulador del Tequila pretende crear un inventario nacional, informó Ramón González Figueroa, director del organismo.

Detalló que cuentan con 358 millones de agaves de diversas edades, de los que 73% están en Jalisco y el resto en Michoacán, Nayarit, Guanajuato y Tamaulipas.

“Algunas de las principales variables que se prevén en el inventario son la georreferenciación de los predios, datos generales del productor, prácticas agrícolas, edad de la planta, nombre de la plantación, colindancias, superficie, número de plantas y estado fitosanitario”.

Explicó que la idea del inventario es conocer cuánto agave hay, en dónde está, de quién es y si está vinculado o no con la industria tequilera, tomando en cuenta que el año pasado fueron 43 millones de agaves equivalentes a 942 mil toneladas y este año cuentan con 45 millones de agaves en edad de ser jimados, lo cual garantiza el suministro de la materia prima para la elaboración de la bebida nacional, cuyo precio se regirá por la oferta y demanda.

De acuerdo con González Figueroa, al cierre de 2016 se contaban con 209 millones de litros de tequila en inventario, de los que 78.5% son de categoría 100% de agave y 21.5% de la categoría tequila.

“Hoy estamos trabajando en alinear los factores de la producción, que permitan atenuar las crestas y valles que históricamente ha afrontado esta materia prima. Entre esas acciones está la planeación estratégica, la agricultura por contrato mediante diversos modelos como la parceria y suministro, el inventario nacional de agaves, que estamos solicitando a la Secretaría de Agricultura”.


Dijo que el inventario es importante, porque en la actualidad se demanda agave para inulina, jarabe, mezcal y bacanora y de inicio se apoyarán de la empresa Cubo Geoespacial, encargada del vuelo de los drones que apoyarán en la conformación del inventario.



≡ MENU

UAVs (Vehículo aéreo no tripulado) y Software Libre

Publicado por [qgismx](#) el 19 febrero, 2017



El pasado 16 y 17 de febrero de 2017, se celebró el primer **Simposio de Aplicaciones Científicas y Técnicas de los Vehículos no Tripulados** (UAV's) en el Centro de exposiciones y congresos de la

20/3/2019

UAVs (Vehículo aéreo no tripulado) y Software Libre – QGIS México

Universidad Nacional Autónoma de México (UNAM). Los qgistasMX asistimos, interesados en conocer lo que otros mexicanos hacen con los UAV's en materia de "open source geospatial".



Empezaremos con la reseña que hizo el Director de Centro Nacional de Prevención de Desastres (CENAPRED), el **Dr. Carlos Valdés**, de un personaje que apoya el software y hardware libre (ardupilot): **Jordi Muñoz**, de origen mexicano, uno de los creadores de drones de bajo costo, las dificultades académicas pero de su éxito como cofundador de 3D Robotics.

Gabriela Calvario Sánchez, doctorante de la Universidad Politécnica de Valencia (TERRADATA-UPV) presento la ponencia "Un enfoque multidisciplinario de sensado remoto a través de UAV de bajo costo", una propuesta relacionada con la Infraestructura de Datos Espaciales, UAVs y software libre.

Otro trabajo en materia, es el realizado por el **Ing. Natividad Hernández Romero y el Mtro. José Isidro Hernández Vega** del Instituto Tecnológico de Nuevo León, ellos tienen una propuesta de una sistema mecatrónico para el monitoreo de contaminantes mediante un UAV de arquitectura abierta, por supuesto utilizan Arduino y MySQL además de desarrollos propios; me impresiona este prototipo porque está basado en un ingenioso diseño de un repositorio donde coloca los sensores que analizan los contaminantes.

El trabajo de la Asociación Civil **Tlehticmati Geolab** con una iniciativa que utiliza software libre, esto es, Tower + QGIS + APM Planner + WebODM (Open Drone Map) en la caracterización de unidades geoecológicas relacionada con los ecosistemas de humedales.

20/3/2019

UAVs (Vehículo aéreo no tripulado) y Software Libre – QGIS México

El **SIGALT – UMAR**, a través de **Eduardo Ramírez y Alejandro Cruz**, en su ponencia “Caracterización del paisaje sumergido del Área Natural Protegida: Parque Huatulco”, mencionaron que durante el procesamiento de su información obtenida emplearon **QGIS**.

Por último, mencionaremos la participación del qgista **Hennessy Becerra** en la ponencia llamada “Sistema de restitución fotogramétrica digital 3D a partir de imágenes obtenidas por UAV”, esta información se ha utilizado en la elaboración de un Atlas de Riesgo Municipal en el Estado de Jalisco.

Quizás hubo más trabajos con el uso de hardware y software libre, pero con 79 ponencias, esto es lo que conocimos. En horabuena por las iniciativas.

<http://www.qgis.mx/2017/02/uavs-vehiculo-aereo-no-tripulado-y-software-libre/>

- [1] Helge Aasen, Andreas Burkart, Andreas Bolten, and Georg Bareth. Generating 3d hyperspectral information with lightweight uav snapshot cameras for vegetation monitoring: From camera calibration to quality assurance. *ISPRS Journal of Photogrammetry and Remote Sensing*, 108:245 – 259, 2015.
- [2] Arbab Waseem Abbas, N Minallah, Nasir Ahmad, Sahibzada Abdur Rehman Abid, and Muhammad Akbar Ali Khan. K-means and isodata clustering algorithms for landcover classification using remote sensing. *Sindh University Research Journal-SURJ (Science Series)*, 48(2), 2016.
- [3] Types of orbits Agencia espacial Europea (ESA). url <http://www.esa.int>, 2018. Accedido 06-09-2018.
- [4] Shefali Aggarwal. Principles of remote sensing. *Satellite remote sensing and GIS applications in agricultural meteorology*, pages 23–38, 2004.
- [5] Agisoft Photoscan, Manual de Uso. Agisoft photoscan user manual: Professional edition, version 1.3, Online; accessed 27 March 2019.
- [6] Francisco Agüera, Fernando J Aguilar, and Manuel A Aguilar. Using texture analysis to improve per-pixel classification of very high resolution images for mapping plastic greenhouses. *ISPRS Journal of Photogrammetry and Remote Sensing*, 63(6):635–646, 2008.
- [7] Jwan Al-doski, Shattri B Mansorl, and Helmi Zulhaidi Mohd Shafri. Image classification in remote sensing. *Department of Civil Engineering, Faculty of Engineering, University Putra, Malaysia*, 2013.
- [8] DHA Al-Khudhairy, I Caravaggi, and S Giada. Structural damage assessments from ikonos data using change detection, object-oriented segmentation, and classification techniques. *Photogrammetric Engineering & Remote Sensing*, 71(7):825–837, 2005.

- [9] R. M. Alkan, H. Karaman, and M. Sahin. Gps, galileo and glonass satellite navigation systems amp;gps modernization. In *Proceedings of 2nd International Conference on Recent Advances in Space Technologies, 2005. RAST 2005.*, pages 390–394, June 2005.
- [10] Mohamed Alzenad, Amr El-Keyi, Faraj Lagum, and Halim Yanikomeroglu. 3-d placement of an unmanned aerial vehicle base station (uav-bs) for energy-efficient maximal coverage. *IEEE Wireless Communications Letters*, 6(4):434–437, 2017.
- [11] K Angayarkkani and N Radhakrishnan. Efficient forest fire detection system: a spatial data mining and image processing based approach. *International Journal of Computer Science and Network Security*, 9(3):100–107, 2009.
- [12] Stan Aronoff. Classification accuracy: a user approach. *Photogrammetric Engineering and Remote Sensing*, 48(8):1299–1307, 1982.
- [13] Clement Atzberger. Advances in remote sensing of agriculture: Context description, existing operational monitoring systems and major information needs. *Remote sensing*, 5(2):949–981, 2013.
- [14] Reg Austin. *Unmanned aircraft systems: UAVS design, development and deployment*, volume 54. John Wiley & Sons, 2011.
- [15] SJ Baillarin, Aimé Meygret, Cécile Dechoz, Beatrice Petrucci, Sophie Lacherade, Thierry Trémas, Claudia Isola, Philippe Martimort, and François Spoto. Sentinel-2 level 1 products and image processing performances. In *2012 IEEE international geoscience and remote sensing symposium*, pages 7003–7006. IEEE, 2012.
- [16] Filippo Bandini, Jakob Jakobsen, Daniel Olesen, Jose Antonio Reyna-Gutierrez, and Peter Bauer-Gottwein. Measuring water level in rivers and lakes from lightweight unmanned aerial vehicles. *Journal of Hydrology*, 548:237–250, 2017.
- [17] Uzair Bashir and Manzoor Chachoo. Performance evaluation of j48 and bayes algorithms for intrusion detection system. *Int. J. Netw. Secur. Its Appl*, 2017.
- [18] Bruno Basso. Perspectivas y avances del uso de uav en ap en usa. *Curso Internacional de Agricultura de Precisión. 13. 2014 09 24-25, 24 y 25 de septiembre 2014. Manfredi, Córdoba. AR*, 2014.
- [19] Wim GM Bastiaanssen, David J Molden, and Ian W Makin. Remote sensing for irrigated agriculture: examples from research and possible applications. *Agricultural water management*, 46(2):137–155, 2000.
- [20] Javier Bilbao, Andoni Olozaga, Eugenio Bravo, Olatz García, Concepción Varela, and Miguel Rodríguez. How design an unmanned aerial vehicle with great efficiency in the use of existing resources. *International Journal of Computers*, 2(4), 2008.

- [21] Sergio Bitar. Las tendencias mundiales y el futuro de américa latina. *Santiago de Chile, Chile: CEPAL*, 2014.
- [22] Guillaume Brunier, Jules Fleury, Edward J Anthony, Virginie Pothin, Claude Vella, Philippe Dussouillez, Antoine Gardel, and Emma Michaud. Structure-from-motion photogrammetry for high-resolution coastal and fluvial geomorphic surveys. *Géomorphologie: relief, processus, environnement*, 22(2):147–161, 2016.
- [23] C Burguillos and H Deng. Emergency communications network for disasters management in venezuela. *International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences*, 42(3), 2018.
- [24] A Burkart, VL Hecht, T Kraska, and U Rascher. Phenological analysis of unmanned aerial vehicle based time series of barley imagery with high temporal resolution. *Precision Agriculture*, 19(1):134–146, 2018.
- [25] Guo-Rong Cai, Pierre-Marc Jodoin, Shao-Zi Li, Yun-Dong Wu, Song-Zhi Su, and Zhen-Kun Huang. Perspective-sift: An efficient tool for low-altitude remote sensing image registration. *Signal Processing*, 93(11):3088–3110, 2013.
- [26] G Calvario, C Hernandez, E Lazkano, B Sierra, O Dalmau, and T Alarcon. Machine learning approach to fuse multiple band for water bodies detection. In *International Conference on Computer Science Networks and Information Technology 2017*, 2017.
- [27] Gabriela Calvario. Futura dirección de la agricultura: Un reto para tecnologías emergentes. LATIN AMERICA SPATIAL FORUM, 11 2018. <https://lagf.org/ppt/Gabriela-Calvario.pdf>.
- [28] Gabriela Calvario, Basilio Sierra, Teresa E Alarcón, Carmen Hernandez, and Oscar Dalmau. A multi-disciplinary approach to remote sensing through low-cost uavs. *Sensors*, 17(6):1411, 2017.
- [29] Martinez Jordan Monter Eder Calvario Gabriela, Sierra Basilio. Un enfoque multidisciplinario de sensado remoto a través de uav de bajo costo., 2017.
- [30] Gabriela Calvario Sánchez, Oscar Dalmau, Teresa E Alarcón, Basilio Sierra, and Carmen Hernández. Selection and fusion of spectral indices to improve water body discrimination. *IEEE Access*, 6:72952–72961, 2018.
- [31] J.B. Campbell. *Introduction to Remote Sensing*. Taylor & Francis, 2002.
- [32] M. Capderou. *Handbook of Satellite Orbits: From Kepler to GPS*. SpringerLink : Bücher. Springer International Publishing, 2014.
- [33] Jesse Casana, John Kantner, Adam Wiewel, and Jackson Cothren. Archaeological aerial thermography: a case study at the chaco-era blue j community, new mexico. *Journal of Archaeological Science*, 45:207–219, 2014.

- [34] Facundo Ismael Casanola. Implementación de herramientas de teledetección e inteligencia artificial para la optimización de los recursos del ejército argentino en situaciones de emergencias volcánicas. Master's thesis, Universidad Nacional DE Cordoba, 2016.
- [35] E. Ceccon. *Restauración en bosques tropicales: Fundamentos ecológicos, prácticos y sociales*. Ediciones Díaz de Santos, 2014.
- [36] CEOS, Committee on Earth Observation Satellites. <http://eohandbook.com/past-editions.html>, Online; accessed 20 March 2018.
- [37] Roberto Alonso Cepeda Naula. Investigación y desarrollo metodológico del uso de vehículo aéreo no tripulado (uav) en las geociencias. B.S. thesis, Quito: UCE., 2017.
- [38] Gyanesh Chander, Brian L Markham, and Dennis L Helder. Summary of current radiometric calibration coefficients for landsat mss, tm, etm+, and eo-1 ali sensors. *Remote sensing of environment*, 113(5):893–903, 2009.
- [39] J.L. Chavez. *Percepcion remota*. Lulu Com, 2011.
- [40] J.L. Chávez. *Tratamiento Digital de Imágenes Multiespectrales*. Lulu Com, 2012.
- [41] Yuanhang Cheng, Dingyu Xue, and Yanping Li. A fast mosaic approach for remote sensing images. In *2007 International Conference on Mechatronics and Automation*, pages 2009–2013. IEEE, 2007.
- [42] Yiu-ming Cheung. On rival penalization controlled competitive learning for clustering with automatic cluster number selection. *IEEE Transactions on Knowledge and Data Engineering*, 17(11):1583–1588, 2005.
- [43] J Chmiel, S Kay, and P Spruyt. Orthorectification and geometric quality assessment of very high spatial resolution satellite imagery for common agricultural policy purposes. In *Proceedings of XXth ISPRS Congress*, pages 12–23, 2004.
- [44] E. Chuvieco and A. Huete. *Fundamentals of Satellite Remote Sensing*. CRC Press, 2009.
- [45] E. Chuvieco and E.C. Salinero. *Fundamentos de teledetección espacial*. Manuales universitarios Rialp. Rialp, 2000.
- [46] William M Ciesla, Ray A Allison, and Frederick P Weber. Panoramic aerial photography in forest pest management. *Photogrammetric Engineering and Remote Sensing (USA)*, 1982.
- [47] WM Ciesla, LE Drake, and DH Wilmore. Color photos, aerial sprays and the forest tent caterpillar. *Photogrammetric Engineering*, 1971.

- [48] RN Clark, GA Swayze, TVV King, KE Livo, JB Dalton, and RF Kokaly. Tetra-corder and expert system feature identification rules for reflectance (and emit-tance) spectroscopy analysis 1: Visible to near-infrared detection of minerals, organics, vegetation, water, amorphous and other materials. In *Proceedings, Ninth AVIRIS Airborne Geoscience Workshop. JPL Publication*, pages 99–17, 1999.
- [49] Shannon R Clemens. Procedures for correcting digital camera imagery acquired by the aggieair remote sensing platform, all graduate plan b and other reports. Technical report, Utah State University, 2012.
- [50] T Cocks, R Jenssen, A Stewart, I Wilson, and T Shields. The hymaptm airborne hyperspectral sensor: The system, calibration and performance. In *Proceedings of the 1st EARSeL workshop on Imaging Spectroscopy*, pages 37–42. EARSeL, 1998.
- [51] Jacob Cohen. A coefficient of agreement for nominal scales. *Educational and psychological measurement*, 20(1):37–46, 1960.
- [52] Ismael Colomina and Pere Molina. Unmanned aerial systems for photogram-metry and remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 92:79–97, 2014.
- [53] E.D. Conway and Maryland Space Grant Consortium. *An Introduction to Sa-tellite Image Interpretation*. Earth Sciences. Johns Hopkins University Press, 1997.
- [54] DANIEL CARNEIRO DA SILVA, GERARD WILLEM ANTHONY TOONS-TRA, HENRIQUE LACET SILVA SOUZA, and TÚLLIO ÁULLUS JÓ PE-REIRA. Qualidade de ortomosaicos de imagens de vant processados com os softwares aps, pix4d e photoscan. *V Simpósio Brasileiro de Ciências Geodési-cas e Tecnologias da Geoinformação, Recife-PE*, 2014.
- [55] K. Dalamagkidis, K.P. Valavanis, and L.A. Piegl. *On Integrating Unmanned Aircraft Systems into the National Airspace System: Issues, Challenges, Opera-tional Restrictions, Certification, and Recommendations*. Intelligent Systems, Control and Automation: Science and Engineering. Springer Netherlands, 2011.
- [56] HP Das. Satellite-based agro-advisory service. *Satellite Remote Sensing and GIS Applications in Agricultural Meteorology*, page 347, 2004.
- [57] Shirley M Davis, David A Landgrebe, Terry L Phillips, Philip H Swain, Roger M Hoffer, John C Lindenlaub, and Leroy F Silva. *Remote Sensing: The quantitative approach, the quantitative approach: concept and raionale*. McGraw-Hill, New York, 1978.

- [58] Nicolas del Toro Espín, Francisco Gomáriz-Castillo, Fulgencio Cánovas-García, and Francisco Alonso-Sarria. Comparación de métodos de clasificación de imágenes de satélite en la cuenca del río Argos (región de Murcia). *Boletín de la Asociación de Geógrafos Españoles*, Boletín de la Asociación de Geógrafos Españoles(67), 2015.
- [59] F. Di Castri, T. Younès, and International Union of Biological Sciences. *Biodiversity, Science and Development: Towards a New Partnership*, chapter Biological Conservations in a High Beta-diversity Country. A CAB International Publication. CAB International, 1996.
- [60] María del Mar Saldaña Díaz. *Generación de datos georreferenciados de muy alta resolución a partir de imágenes de los satélites GeoEye-1 y WorldView-2*. PhD thesis, Universidad de Almería, 2013.
- [61] DJI. Phantom 4 rtk, inteligencia visionaria. precisión elevada. <https://www.dji.com/es/phantom-4-rtk>, Online; accessed 02 April 2019.
- [62] Richard Dunford, Kristell Michel, Matthieu Gagnage, Hervé Piégay, and M-L Trémelo. Potential and constraints of unmanned aerial vehicle technology for the characterization of mediterranean riparian forest. *International Journal of Remote Sensing*, 30(19):4915–4935, 2009.
- [63] Google Earth. Mapa de zonas utm, 03 2019. <https://www.google.com/intl/es/earth/>.
- [64] Earth Observation Portal, eoportal. Worldview-4 (formerly geoeye-2). <https://directory.eoportal.org/web/eoportal/satellite-missions/v-w-x-y-z/worldview-4>, Online; accessed 15 March 2019.
- [65] Earthobservatory, NASA. <https://earthobservatory.nasa.gov/Features/RemoteSensingAtmosphere/>, Online; accessed 20 March 2018.
- [66] Heinrich Ebner and Timm Ohlhof. Utilization of ground control points for image orientation without point identification in image space. In *ISPRS Commission III Symposium: Spatial Information from Digital Photogrammetry and Computer Vision*, volume 2357, pages 206–212. International Society for Optics and Photonics, 1994.
- [67] Thomas P Ehrhard. Air force uavs: The secret history. Technical report, Mitchell Inst for Airpower Studies Arlington VA, 2010.
- [68] Henri Eisenbeiß. *UAV photogrammetry*. PhD thesis, ETH Zurich, 2009.
- [69] Joseph F Engelberger. Historical perspective and role in automation. *Handbook of industrial robotics*, pages 3–10, 1999.

- [70] Jesús Orlando Escalante Torrado, Hernán Porras Díaz, et al. Ortomosaicos y modelos digitales de elevación generados a partir de imágenes tomadas con sistemas uav. *Tecnura*, 20(50):119–140, 2016.
- [71] Zhang Fang-fang, Zhang Bing, Li Jun-sheng, Shen Qian, Wu Yuanfeng, and Song Yang. Comparative analysis of automatic water identification method based on multispectral remote sensing. *Procedia Environmental Sciences*, 11:1482–1487, 2011.
- [72] DING Feng. Study on information extraction of water body with a new water index (nwi)[j]. *Science of Surveying and Mapping*, 4, 2009.
- [73] Quanlong Feng, Jiantao Liu, and Jianhua Gong. Uav remote sensing for urban vegetation mapping using random forest and texture analysis. *Remote Sensing*, 7(1):1074–1094, 2015.
- [74] Gudina L. Feyisa, Henrik Meilby, Rasmus Fensholt, and Simon R. Proud. Automated water extraction index: A new technique for surface water mapping using landsat imagery. *Remote Sensing of Environment*, 140:23 – 35, 2014.
- [75] Adrian Fisher, Neil Flood, and Tim Danaher. Comparing landsat water index methods for automated water classification in eastern australia. *Remote Sensing of Environment*, 175:167–182, 2016.
- [76] Food and Agriculture Organization of the United Nations (FAO), Radiación Electromagnética y sus Propiedades. <http://www.fao.org/docrep/003/t0355s/T0355S02.htm>, Online; accessed 31 March 2018.
- [77] CS Fraser, E Baltsavias, and A Gruen. Processing of ikonos imagery for submetre 3d positioning and building extraction. *ISPRS Journal of Photogrammetry and Remote Sensing*, 56(3):177–194, 2002.
- [78] Simon Fuhrmann, Fabian Langguth, Nils Moehrle, Michael Waechter, and Michael Goesele. Mve—an image-based reconstruction environment. *Computers and Graphics*, 53:44 – 53, 2015. 40 years of Computer Graphics in Darmstadt.
- [79] Bo-Cai Gao. NdwI—a normalized difference water index for remote sensing of vegetation liquid water from space. *Remote sensing of environment*, 58(3):257–266, 1996.
- [80] Bo-Cai Gao, Marcos J Montes, Ziauddin Ahmad, and Curtiss O Davis. Atmospheric correction algorithm for hyperspectral remote sensing of ocean color from space. *Applied Optics*, 39(6):887–896, 2000.
- [81] H Gao, L Wang, L Jing, and J Xu. An effective modified water extraction method for landsat-8 oli imagery of mountainous plateau regions. In *IOP conference series: earth and environmental science*, page 012010. IOP Publishing, 2016.

- [82] JF Garnica, R Reich, E Talavera Zuñiga, and C Aguirre Bravo. Using remote sensing to support different approaches to identify agave (agave tequilana weber) crops. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.*, 37:941–944, 2008.
- [83] G Gibbons. Turning a farm art into science-an overview of precision farming. URL: <http://www.precisionfarming.com>, 2000.
- [84] A GOFC-GOLD. Sourcebook of methods and procedures for monitoring and reporting anthropogenic greenhouse gas emissions and removals associated with deforestation, gains and losses of carbon stocks in forests remaining forests, and forestation. *Gains and Losses of Carbon Stocks in Forests Remaining Forests, and Forestation*, page 126, 2013.
- [85] D. Gonzalez Aguilera, L. López-Fernández, P. Rodriguez-Gonzalvez, D. Hernandez-Lopez, D. Guerrero, F. Remondino, F. Menna, E. Nocerino, I. Toschi, A. Ballabeni, and M. Gaiani. Graphos – open-source software for photogrammetric applications. *The Photogrammetric Record*, 33(161):11–29, 2018.
- [86] Water Research Group et al. Charting our water future: Economic frameworks to inform decision-making. *Water Research Group*, 2009.
- [87] Suraj G Gupta, Mangesh M Ghonge, and PM Jawandhiya. Review of unmanned aircraft system (uas). *International Journal of Advanced Research in Computer Engineering & Technology (IJARCET)*, 2(4):pp-1646, 2013.
- [88] C.P. Gutiérrez and Á.L.M. Nieto. *Teledetección: nociones y aplicaciones*. Carlos Pérez Gutiérrez, Ángel Luis Muñoz Nieto, 2006.
- [89] C.P. Gutiérrez and Á.L.M. Nieto. *Teledetección: nociones y aplicaciones*. Carlos Pérez Gutiérrez, Ángel Luis Muñoz Nieto, 2006.
- [90] Mark A Hall and Geoffrey Holmes. Benchmarking attribute selection techniques for discrete class data mining, 2002.
- [91] E Honkavaara, R Arbiol, L Markelin, L Martinez, M Cramer, I Korpela, S Bovet, C Thom, L Chandelier, R Ilves, et al. Status report of the eurosdr project “radiometric aspects of digital photogrammetric airborne images”. In *Proceedings of the ISPRS Hannover Workshop*, pages 2–5, 2009.
- [92] Eija Honkavaara. State-of-the-art within radiometric correction of large-format aerial photogrammetric images finnish geodetic institute (fgi). Finnish Geodetic Institute, 7 2014.
- [93] Kunshan Huang, Shutao Li, Xudong Kang, and Leyuan Fang. Spectral–spatial hyperspectral image classification based on knn. *Sensing and Imaging*, 17(1):1, 2016.

- [94] Yanbo Huang, Steven J Thomson, W Clint Hoffmann, Yubin Lan, and Bradley K Fritz. Development and prospect of unmanned aerial vehicle technologies for agricultural production management. *International Journal of Agricultural and Biological Engineering*, 6(3):1–10, 2013.
- [95] M.C.E. Huber, A. Pauluhn, J.L. Culhane, J.G. Timothy, K. Wilhelm, and A. Zehnder. *Observing Photons in Space: A Guide to Experimental Space Astronomy*. ISSI Scientific Report Series. Springer New York, 2013.
- [96] William D Hudson. Correct formulation of the kappa coefficient of agreement. *Photogrammetric engineering and remote sensing*, 53(4):421–422, 1987.
- [97] Feng-Tai Hwang. Current Development Status and Future Trends for High Resolution Optical Earth Observation Satellites, 2013.
- [98] International Civil Aviation Organization (ICAO). Organismo especializado de las naciones unidas. <https://www.icao.int/about-icao/Pages/default.aspx>.
- [99] Icaros. Icaros, imaginary made simple. <https://www.icaros.us/>, Online; accessed 02 April 2019.
- [100] Anil K Jain. Data clustering: 50 years beyond k-means. *Pattern recognition letters*, 31(8):651–666, 2010.
- [101] John R Jensen and Kalmesh Lulla. Introductory digital image processing: a remote sensing perspective. *Geocarto International*, 1987.
- [102] Lei Ji, Li Zhang, and Bruce Wylie. Analysis of dynamic thresholds for the normalized difference water index. *Photogrammetric Engineering & Remote Sensing*, 75(11):1307–1317, 2009.
- [103] Sarah E Johnston, Mary C Henry, and David L Gorchov. Using advanced land imager (ali) and landsat thematic mapper (tm) for the detection of the invasive shrub *lonicera maackii* in southwestern ohio forests. *GIScience & remote sensing*, 49(3):450–462, 2012.
- [104] Gordana Kaplan and Ugur Avdan. Object-based water body extraction model using sentinel-2 satellite imagery. *European Journal of Remote Sensing*, 50(1):137–143, 2017.
- [105] Ebrahim Karami, Siva Prasad, and Mohamed Shehata. Image matching using sift, surf, brief and orb: performance comparison for distorted images. *arXiv preprint arXiv:1710.02726*, 2017.
- [106] Joshua Kelcey and Arko Lucieer. Sensor correction and radiometric calibration of a 6-band multispectral imaging sensor for uav remote sensing. In *The 12th Congress of the International Society for Photogrammetry and Remote Sensing*, volume 39, pages 393–398, 2012.

- [107] Norman Kerle, Lucas LF Janssen, and Gerrit C Huurneman. Principles of remote sensing. *ITC, Educational textbook series*, 2:63–65, 2004.
- [108] S. Khorram, F.H. Koch, C.F. van der Wiele, and S.A.C. Nelson. *Remote Sensing*. SpringerBriefs in Space Development. Springer New York, 2012.
- [109] Ron Kohavi et al. A study of cross-validation and bootstrap for accuracy estimation and model selection, 1995.
- [110] K.Y. Kondratyev and N. Filatov. *Limnology and Remote Sensing: A Contemporary Approach*. Springer Praxis Books. Springer London, 1999.
- [111] Sotiris B Kotsiantis, I Zaharakis, and P Pintelas. Supervised machine learning: A review of classification techniques. *Emerging artificial intelligence applications in computer engineering*, 160:3–24, 2007.
- [112] B R_ Kowalski and CF Bender. k-nearest neighbor classification rule (pattern recognition) applied to nuclear magnetic resonance spectral interpretation. *Analytical Chemistry*, 44(8):1405–1411, 1972.
- [113] Viktoriya Krakovna, Jiong Du, Haitong Securities, and Jun S Liu. Selective bayesian forest classifier: Simultaneous variable selection and classification. *stat*, 1050:8, 2015.
- [114] H.J. Kramer. *Observation of the Earth and its Environment: Survey of Missions and Sensors*. Springer Berlin Heidelberg, 2013.
- [115] Arthur F Krueger and Sigmund Fritz. Cellular cloud patterns revealed by tiros i. *Tellus*, 13(1):1–7, 1961.
- [116] Quansheng Kuang and Lei Zhao. A practical gpu based knn algorithm. In *Proceedings. The 2009 International Symposium on Computer Science and Computational Technology (ISCSCI 2009)*, page 151. Citeseer, 2009.
- [117] Ramon Lopez La Valle, Javier G Garcia, Pedro A Roncagliolo, and Carlos H Muravchik. An experimental l1/l2 gns receiver for high precision applications. *IEEE Latin America Transactions*, 11(1):48–53, 2013.
- [118] Nina Siu-Ngan Lam and Dale A Quattrochi. On the issues of scale, resolution, and fractal analysis in the mapping sciences. *The Professional Geographer*, 44(1):88–98, 1992.
- [119] David Landgrebe. The evolution of landsat data analysis. *Photogrammetric Engineering and Remote Sensing*, 63(7):859–867, 1997.
- [120] David Landgrebe. Hyperspectral image data analysis. *IEEE Signal Processing Magazine*, 19(1):17–28, 2002.

- [121] Lawrence W Lass, Timothy S Prather, Nancy F Glenn, Keith T Weber, Jacob T Mundt, and Jeffery Pettingill. A review of remote sensing of invasive weeds and example of the early detection of spotted knapweed (*centaurea maculosa*) and babysbreath (*gypsophila paniculata*) with a hyperspectral sensor. *Weed Science*, 53(2):242–251, 2005.
- [122] Bernhard Lehner and Petra Döll. Development and validation of a global database of lakes, reservoirs and wetlands. *Journal of Hydrology*, 296(1-4):1–22, 2004.
- [123] Bangyu Li, Hui Zhang, and Fanjiang Xu. Water extraction in high resolution remote sensing image based on hierarchical spectrum and shape features. In *IOP Conference Series: Earth and Environmental Science*, page 012123. IOP Publishing, 2014.
- [124] T. Lillesand, R.W. Kiefer, and J. Chipman. *Remote Sensing and Image Interpretation*. Wiley, 2014.
- [125] Kuo-Nan Liou. *An introduction to atmospheric radiation*, volume 84. Elsevier, 2002.
- [126] Jianguo Liu, Elizabeth Pattey, John R Miller, Heather McNairn, Anne Smith, and Baoxin Hu. Estimating crop stresses, aboveground dry biomass and yield of corn using multi-temporal optical data combined with a radiation use efficiency model. *Remote Sensing of Environment*, 114(6):1167–1177, 2010.
- [127] David B Lobell, Gregory P Asner, J Ivan Ortiz-Monasterio, and Tracy L Benning. Remote sensing of regional crop production in the yaqui valley, mexico: estimates and uncertainties. *Agriculture, Ecosystems & Environment*, 94(2):205–220, 2003.
- [128] James MacQueen et al. Some methods for classification and analysis of multivariate observations. In *Proceedings of the fifth Berkeley symposium on mathematical statistics and probability*, pages 281–297. Oakland, CA, USA, 1967.
- [129] Inderjeet Mani and I Zhang. knn approach to unbalanced data distributions: a case study involving information extraction. In *Proceedings of workshop on learning from imbalanced datasets*, volume 126, 2003.
- [130] Geoffrey Holmes Bernhard Pfahringer Peter Reutemann Mark Hall, Eibe Frank and Ian H. The weka data mining software: An update. sigkdd explorations, 2009.
- [131] Lucas Martínez, Roman Arbiol, Vicenç Palà, and Fernando Pérez. Digital metric camera radiometric and colorimetric calibration with simultaneous casi imagery to a cie standard observer based colour space. In *2007 IEEE International Geoscience and Remote Sensing Symposium*, pages 4140–4143. IEEE, 2007.

- [132] P. Mather and B. Tso. *Classification Methods for Remotely Sensed Data, Second Edition*. Environmental engineering. Taylor & Francis, 2009.
- [133] P.M. Mather and M. Koch. *Computer Processing of Remotely-Sensed Images: An Introduction*. Wiley, 2011.
- [134] Stuart K McFeeters. The use of the normalized difference water index (ndwi) in the delineation of open water features. *International journal of remote sensing*, 17(7):1425–1432, 1996.
- [135] F.J.S. Menendez and E. SL. *Georreferenciación de Cartografía: Datos Raster y Vectoriales*. Cartografía Magazine. Fernando J Sanchez Menendez, 2009.
- [136] Wei-can Meng, Shu-long Zhu, Wen Cao, Xiao-jun Su, and Bin-cai Cao. Establishment of synthetical water index. *Sci. Surv. Mapp.*, 38(4):130–133, 2013.
- [137] Francisco-Javier Mesas-Carrascosa, María Dolores Notario García, Jose Emilio Meroño de Larriva, and Alfonso García-Ferrer. An analysis of the influence of flight parameters in the generation of unmanned aerial vehicle (uav) orthomosaics to survey archaeological areas. *Sensors*, 16(11):1838, 2016.
- [138] J.M. Miralles. *La teledetección en el seguimiento de los fenómenos naturales. Recursos renovables: agricultura*. Universitat, Unidad de Teledetección, Departament de Termodinàmica, 1991.
- [139] H.B. Mitchell. *Image Fusion: Theories, Techniques and Applications*. Springer Berlin Heidelberg, 2010.
- [140] Pierre Moulon and Alessandro Bezzi. Python photogrammetry toolbox: A free solution for three-dimensional documentation. *Napoli, Italy*, pages 1–12, 2011.
- [141] Pierre Moulon, Pascal Monasse, Renaud Marlet, and Others. Openmvg. <https://github.com/openMVG/openMVG>.
- [142] David J Mulla. Twenty five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. *Biosystems engineering*, 114(4):358–371, 2013.
- [143] Hussain M. Hussain Modher H Mustafa T. Mustafa, Khalid I. Hassoon. Using water indices (ndwi, mndwi, ndmi, wri and awei) to detect physical and chemical parameters by apply remote sensing and gis techniques. In *International Journal of Research -GRANTHAALAYAH*, page 10. International Journal of Research -GRANTHAALAYAH, 2017.
- [144] P. Nag and M. Kudrat. *Digital Remote Sensing*. Concept Publishing Company, 1998.
- [145] Masahiko Nagai, Tianen Chen, Ryosuke Shibasaki, Hideo Kumagai, and Afzal Ahmed. Uav-borne 3-d mapping system by multisensor integration. *IEEE Transactions on Geoscience and Remote Sensing*, 47(3):701–708, 2009.

- [146] George Nagy. State of the art in pattern recognition. *Proceedings of the IEEE*, 56(5):836–863, 1968.
- [147] National Aeronautics and Space Administration, NASA. <https://www.mdsc.nasa.gov/index.php>, Online; accessed 14 March 2018.
- [148] Natural Resources Canada, Spatial Resolution, Pixel Size, and Scale. <http://www.nrcan.gc.ca/node/9407>, Online; accessed 31 March 2018.
- [149] Kumar Navulur. *Multispectral image analysis using the object-oriented paradigm*. CRC press, 2006.
- [150] F Nex and F Remondino. Uav for 3d mapping applications: a review.–applied geomatics 6 (1): 1–15, 2014.
- [151] Thuy Nguyen, David Slaughter, Bradley Hanson, Andrew Barber, Amy Freitas, Daniel Robles, and Erin Whelan. Automated mobile system for accurate outdoor tree crop enumeration using an uncalibrated camera. *Sensors*, 15(8):18427–18442, 2015.
- [152] M. Nunez. *Fisica/ Physics*. Editorial Limusa S.A. De C.V., 2002.
- [153] K. Okamoto. *Global Environment Remote Sensing*. Global Environment Remote Sensing. Ohmsha, Limited, 2001.
- [154] Bernardo Olmedo-Carranza. El tequila: de su origen a su desnaturalización. a quién le pertenece su conocimiento? una aproximación. *Revista CENIC. Ciencias Químicas*, 41, 2010.
- [155] Natascha Oppelt and Wolfram Mauser. The airborne visible/infrared imaging spectrometer avis: Design, characterization and calibration. *Sensors*, 7(9):1934–1953, 2007.
- [156] Tina R Patil, SS Sherekar, et al. Performance analysis of naive bayes and j48 classification algorithm for data classification. *International journal of computer science and applications*, 6(2):256–261, 2013.
- [157] Derek R Peddle, Philippe M Teillet, and Michael A Wulder. Radiometric image processing. In *Remote Sensing of Forest Environments*, pages 181–208. Springer, 2003.
- [158] Massimiliano Pepe. Use of digital aerial photogrammetry sensors for land cover classification. *International Journal of Applied Engineering Research*, 12(24):15610–15620, 2017.
- [159] M Pérez-Ruiz, J Carballido, J Agüera, and JA Gil. Assessing gnss correction signals for assisted guidance systems in agricultural vehicles. *Precision Agriculture*, 12(5):639–652, 2011.

- [160] Thwe Zin Phyo, Aung Soe Khaing, and Hla Myo Tun. Classification of cluster area forsatellite image. *International Journal of Scientific & Technology Research*, 4(6):393–397, 2015.
- [161] Cle Pohl and John L Van Genderen. Review article multisensor image fusion in remote sensing: concepts, methods and applications. *International journal of remote sensing*, 19(5):823–854, 1998.
- [162] Daniela Poli. *Modelling of spaceborne linear array sensors*. Number 85 in Mitteilungen / Institut für Geodäsie und Photogrammetrie an der Eidgenössischen Technischen Hochschule Zürich. ETH Zurich, 2005.
- [163] Jorge Prado Molina, José Antonio Quintero Pérez, Ana Rosa Rosales Tapia, Armando Peralta Higuera, Miguel Ángel Ramírez Beltrán, and Moisés Zamora Jiménez. Elaboración de cartas aeronáuticas oaci: planos de obstáculos de aeródromo, a partir de imágenes aéreas digitales de pequeño formato. *Investigaciones geográficas*, ISSN 2448-7279(79):75–96, 2012.
- [164] G Robleda Prieto and A Pérez Ramos. Modeling and accuracy assessment for 3d-virtual reconstruction in cultural heritage using low-cost photogrammetry: Surveying of the "santa maría azoguechurch's front. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 40(5):263, 2015.
- [165] S.J. Purkis and V.V. Klemas. *Remote Sensing and Global Environmental Change*. Wiley, 2011.
- [166] S.E. Qian. *Optical Payloads for Space Missions*. Wiley, 2016.
- [167] Rongjun Qin. An object-based hierarchical method for change detection using unmanned aerial vehicle images. *Remote Sensing*, 6(9):7911–7932, 2014.
- [168] J.R. Quinlan. *C4.5: Programs for Machine Learning*. Morgan Kaufmann series in machine learning. Elsevier Science, 1993.
- [169] William R Raun, John B Solie, Gordon V Johnson, Marvin L Stone, Robert W Mullen, Kyle W Freeman, Wade E Thomason, and Erna V Lukina. Improving nitrogen use efficiency in cereal grain production with optical sensing and variable rate application. *Agronomy Journal*, 94(4):815–820, 2002.
- [170] Timothy Ravich. A comparative global analysis of drone laws: Best practices and policies. In *The Future of Drone Use*, pages 301–322. Springer, 2016.
- [171] Michal Recky and Franz Leberl. Windows detection using k-means in cie-lab color space. In *2010 20th International Conference on Pattern Recognition*, pages 356–359. IEEE, 2010.
- [172] William Gareth Rees. *Physical principles of remote sensing*. Cambridge University Press, 2013.

- [173] JF Reinoso, JE Gonçalves, C Pereira, and T Bleninger. Cartography for civil engineering projects: Photogrammetry supported by unmanned aerial vehicles. *Iranian Journal of Science and Technology, Transactions of Civil Engineering*, 42(1):91–96, 2018.
- [174] Luis Reyes. Seguridad en la movilización del agave. url <http://www.casasauza.com/procesos-tequila-sauza/seguridad-movilizacion-agave>, 2017. Accedido 03-09-2018.
- [175] J.A. Richards. *Remote Sensing Digital Image Analysis: An Introduction*. Springer Berlin Heidelberg, 2013.
- [176] John A Richards and JA Richards. *Remote sensing digital image analysis*, volume 3. Springer, 1999.
- [177] C.S. Río. *Física cuántica*. Ciencia Y Técnica. Larousse - Ediciones Pirámide, 2016.
- [178] BP Roberts, N Snooke, MJ Neal, P Bunting, MD Fraser, et al. Multispectral imagery from uavs to classify and monitor vegetation change in semi-natural grasslands. In *Sustainable meat and milk production from grasslands. Proceedings of the 27th General Meeting of the European Grassland Federation, Cork, Ireland, 17-21 June 2018*, pages 904–906. Teagasc, Animal & Grassland Research and Innovation Centre, 2018.
- [179] Nell Roberts, Maurice Taieb, Philip Barker, Brahlam Damnati, Michel Icole, and David Williamson. Timing of the younger dryas event in east africa from lake-level changes. *Nature*, 366(6451):146, 1993.
- [180] C.P. Ruiz. *Elementos de teledetección*. Ra-Ma, 1995.
- [181] RE Ryan and Mary Pagnutti. Enhanced absolute and relative radiometric calibration for digital aerial cameras. In *Photogrammetric week*, volume 9, pages 81–90, 2009.
- [182] Floyd F Sabins. Remote sensing for mineral exploration. *Ore Geology Reviews*, 14(3-4):157–183, 1999.
- [183] G Saggiani, F Persiani, A Ceruti, P Tortora, E Troiani, F Giuletti, S Amici, M Buongiorno, G Distefano, G Bentini, et al. A uav system for observing volcanoes and natural hazards. In *AGU Fall Meeting Abstracts*, 2007.
- [184] Olivier Saint-Pe, Michel Tulet, Robert Davancens, Franck Larnaudie, Pierre Magnan, Philippe Martin-Gonthier, Franck Corbière, Pierre Belliot, and Magali Estriebeau. grade cmos image sensors for remote sensing applications. In *Sensors, Systems, and Next-Generation Satellites VIII*, volume 5570, pages 549–557. International Society for Optics and Photonics, 2004.

- [185] Esther Salamí, Cristina Barrado, and Enric Pastor. Uav flight experiments applied to the remote sensing of vegetated areas. *Remote Sensing*, 6(11):11051–11081, 2014.
- [186] María Mercedes Salvia. *Aporte de la teledetección al estudio del funcionamiento del macrosistema Delta del Paraná: análisis de series de tiempo y eventos extremos*. PhD thesis, Facultad de Ciencias Exactas y Naturales. Universidad de Buenos Aires, 2010.
- [187] J. Sanchez and M.P. Canton. *Space Image Processing*. Number v. 1 in Space Image Processing. Taylor & Francis, 1998.
- [188] Temuulen T Sankey, Jason McVay, Tyson L Swetnam, Mitchel P McClaran, Philip Heilman, and Mary Nichols. Uav hyperspectral and lidar data and their fusion for arid and semi-arid land vegetation monitoring. *Remote Sensing in Ecology and Conservation*, 4(1):20–33, 2018.
- [189] Cecilia Verónica Sanz. *Razonamiento evidencial dinámico*. PhD thesis, Facultad de Ciencias Exactas, 2002.
- [190] Korbinian Schmid, Heiko Hirschmüller, Andreas Dömel, Iris Grixia, Michael Suppa, and Gerd Hirzinger. View planning for multi-view stereo 3d reconstruction using an autonomous multicopter. *Journal of Intelligent & Robotic Systems*, 65(1):309–323, Jan 2012.
- [191] Robert A Schowengerdt. *Remote sensing: models and methods for image processing*. Elsevier, 2006.
- [192] J Šedina, K Pavelka, and E Housarová. Examples of using rpas. *Interdisciplinarity in Theory and Practice*, 2015(7):237–242, 2015.
- [193] David A Seekell and Michael L Pace. Does the pareto distribution adequately describe the size-distribution of lakes? *Limnology and Oceanography*, 56(1):350–356, 2011.
- [194] David A Seekell, Michael L Pace, Lars J Tranvik, and Charles Verpoorter. A fractal-based approach to lake size-distributions. *Geophysical Research Letters*, 40(3):517–521, 2013.
- [195] K Seetharaman and Bachala Shyam Kumar. Texture and color features based color image retrieval using canonical correlation. *Global Journal of Research In Engineering*, 2016.
- [196] Li Shen and Changchun Li. Water body extraction from landsat etm+ imagery using adaboost algorithm. In *2010 18th International Conference on Geoinformatics*, pages 1–4. IEEE, 2010.
- [197] Dev Sagar Shrestha and Brian L Steward. Automatic corn plant population measurement using machine vision. *Transactions of the ASAE*, 46(2):559, 2003.

- [198] Basilio Sierra Araujo. Aprendizaje automático: conceptos básicos y avanzados: aspectos prácticos utilizando el software weka, 2006.
- [199] E Sotelo, M del C Gutiérrez, CA Ortiz, G Cruz, and MA Segura. Delimitación de vertisoles a través de la identificación de sus firmas espectrales con el uso de imágenes landsat tm. *Terra Latinoamericana*, 25(3):223–230, 2007.
- [200] Lawrence B Sperry. Automatic pilot for airplanes, April 2 1929. US Patent 1,707,690.
- [201] S.M. Stewart and R.B. Johnson. *Blackbody Radiation: A History of Thermal Radiation Computational Aids and Numerical Methods*. Optical Sciences and Applications of Light. CRC Press, 2016.
- [202] Mervyn Stone. Cross-validators choice and assessment of statistical predictions. *Journal of the Royal Statistical Society: Series B (Methodological)*, 36(2):111–133, 1974.
- [203] Michael Story and Russell G Congalton. Accuracy assessment: a user’s perspective. *Photogrammetric Engineering and remote sensing*, 52(3):397–399, 1986.
- [204] Christoph Strecha, Olivier Küng, and Pascal Fua. Automatic mapping from ultra-light uav imagery. Technical report, L’Ecole Polytechnique Fédérale de Lausanne, 2012.
- [205] Maria Ximena Tagle Casapia. Study of radiometric variations in unmanned aerial vehicle remote sensing imagery for vegetation mapping. *Lund University GEM thesis series*, 2017.
- [206] Mohd Zubir Mat Jafri Lim Hwee San Khiruddin Abdullah Norhaslinda Mohammad Tahrin Tan Fuyi, Beh Boon Chun. Land cover use mapping using multi-band imageries captured by cropcam unmanned aerial vehicle autopilot (uav) over penang island, malaysia. In *SPIE 8540*, volume 8540, 2012.
- [207] K Thorne, B Markharn, P Slater Barker, and S Biggar. Radiometric calibration of landsat. *Photogrammetric Engineering & Remote Sensing*, 63(7):853–858, 1997.
- [208] Alejandro Toledo. El agua en México y el mundo. <http://www.redalyc.org/articulo.oa?id=53906402>, En línea; 25 de abril de 2019.
- [209] Roberto Tomás-Jover, Adrián J Riquelme Guill, Miguel Cano, Antonio A Abellán, and Luis Jordá. Structure from motion (sfm): una técnica fotogramétrica de bajo coste para la caracterización y monitoreo de macizos rocosos. In *Reconocimiento, tratamiento y mejora del terreno: 10^o Simposio Nacional de Ingeniería Geotécnica: A Coruña, 19, 20 y 21 de octubre de 2016*, pages 209–216. Sociedad Española de Mecánica del Suelo e Ingeniería Geotécnica, 2016.

- [210] W. Tomasi, G.M. Hernández, and V.G. Pozo. *Sistemas de comunicaciones electrónicas*. Pearson Educación, 2003.
- [211] C. J. TUCKER and P. J. SELLERS. Satellite remote sensing of primary production. *International Journal of Remote Sensing*, 7(11):1395–1416, 1986.
- [212] Darren Turner, Arko Lucieer, and Christopher Watson. An automated technique for generating georectified mosaics from ultra-high resolution unmanned aerial vehicle (uav) imagery, based on structure from motion (sfm) point clouds. *Remote sensing*, 4(5):1392–1410, 2012.
- [213] United States Geological Survey, (USGS). <https://landsat.usgs.gov/landsat-1-history>, Online; accessed 01 de Agosto de 2018.
- [214] United States Geological Survey, USGS. <https://www.usgs.gov/land-resources/nli/landsat>, Online; accessed 15 de Marzo del 2019.
- [215] United States Geological Survey (USGS), Landsat 8 Data Users Handbook. <https://www.usgs.gov/media/files/landsat-8-data-users-handbook>, 19 de Abril de 2019.
- [216] Pilar Utrilla, Carlos Mazo, María Cruz Sopena, Manuel Martínez-Bea, and Rafael Domingo. A palaeolithic map from 13,660 calbp: engraved stone blocks from the late magdalenian in abautz cave (navarra, spain). *Journal of Human Evolution*, 57(2):99–111, 2009.
- [217] María Basilia Valenzuela and Basilio Verduzco Chávez. Vendiendo tequila a china: una fiesta de coctel sin ganadores claros. *Estudios Gerenciales: Journal of Management and Economics for Iberoamerica*, 34(147):158–171, 2018.
- [218] Peter Van Blyenburgh. Uavs: an overview. *Air & Space Europe*, 1(5-6):43–47, 1999.
- [219] Charles Verpoorter, Tiit Kutser, David A Seekell, and Lars J Tranvik. A global inventory of lakes based on high-resolution satellite imagery. *Geophysical Research Letters*, 41(18):6396–6402, 2014.
- [220] Charles Verpoorter, Tiit Kutser, and Lars Tranvik. Automated mapping of water bodies using landsat multispectral data. *Limnology and Oceanography: Methods*, 10(12):1037–1050, 2012.
- [221] Matheus Alves Vieira, Antonio Roberto Formaggio, Camilo Daleles Rennó, Clement Atzberger, Daniel Alves Aguiar, and Marcio Pupin Mello. Object based image analysis and data mining applied to a remotely sensed landsat time-series to map sugarcane over large areas. *Remote Sensing of Environment*, 123:553–562, 2012.

- [222] F Vogel and G Carletto. Global strategy to improve agricultural and rural statistics. In *High Level Stakeholders Meeting on the Global Strategy-From Plan to Action*. World Bank, Rome, 2012.
- [223] Michael Waechter, Nils Moehrle, and Michael Goesele. Let there be color! large-scale texturing of 3d reconstructions. In David Fleet, Tomas Pajdla, Bernt Schiele, and Tinne Tuytelaars, editors, *Computer Vision – ECCV 2014*, pages 836–850, Cham, 2014. Springer International Publishing.
- [224] Michael Walsh. Remote sensing; us army corps of engineers, 2003.
- [225] Guangxing Wang and Qihao Weng. *Remote sensing of natural resources*. CRC Press, 2013.
- [226] Lung-Jen Wang and Wen-Shyong Hsieh. Toward an improvement of uav-aerial image using non-linear image enhancement. In *2018 32nd International Conference on Advanced Information Networking and Applications Workshops (WAINA)*, pages 623–626. IEEE, 2018.
- [227] Qiuling Wang, Lixin Wu, Shaojie Chen, Defu Shu, Zhihua Xu, Fashuai Li, and Ran Wang. Accuracy evaluation of 3d geometry from low-attitude uav collections a case at zijin mine. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 40(4):297, 2014.
- [228] Q. Weng. *Remote Sensing and GIS Integration: Theories, Methods, and Applications: Theory, Methods, and Applications*. McGraw-Hill Education, 2009.
- [229] John A Wiens. Spatial scaling in ecology. *Functional ecology*, 3(4):385–397, 1989.
- [230] Darrel L Williams, Samuel Goward, and Terry Arvidson. Landsat. *Photogrammetric Engineering & Remote Sensing*, 72(10):1171–1178, 2006.
- [231] I.H. Witten, E. Frank, F.E. coaut, C.D.D. ed, and J. Gray. *Data Mining: Practical Machine Learning Tools and Techniques with Java Implementations*. Database Management Systems Series. Elsevier Science, 2000.
- [232] Hua Wu and Zhao-Liang Li. Scale issues in remote sensing: A review on analysis, processing and modeling. *Sensors*, 9(3):1768–1793, 2009.
- [233] Yan-fang Xiao, W Zhao, and L Zhu. A study on information extraction of water body using band1 and band7 of tm imagery. *Science of Surveying and Mapping*, 5, 2010.
- [234] Hanqiu Xu. Modification of normalised difference water index (ndwi) to enhance open water features in remotely sensed imagery. *International journal of remote sensing*, 27(14):3025–3033, 2006.

- [235] Manel Llena y Damià Vericat y José Martínez Casasnovas. Aplicación de algoritmos structure from motion (sfm) para el análisis histórico de cambios en la geomorfología fluvial. *Cuaternario y Geomorfología*, 32(1-2):53–73, 2018.
- [236] Dongmei Yan and Zhongming Zhao. Road detection from quickbird fused image using ihs transform and morphology. In *Geoscience and Remote Sensing Symposium, 2003. IGARSS'03. Proceedings. 2003 IEEE International*, volume 6, pages 3967–3969. Ieee, 2003.
- [237] Du Yunyan and Zhou Chenghu. Automatically extracting remote sensing information for water bodies. *Journal of Remote Sensing*, 4(2):264–269, 1998.
- [238] Sarris Zak. Survey of uav applications in civil markets. In *Proc. 9th Mediterranean Conference on Control and Automation*, page 11, 2001.
- [239] CW Zecha, J Link, and W Claupein. Mobile sensor platforms: Categorisation and research applications in precision farming. *Journal of Sensors and Sensor Systems*, 2(1):51–72, 2013.
- [240] A Zhahir, A Razali, and MR Mohd Ajir. Current development of uav sense and avoid system. In *IOP Conference Series: Materials Science and Engineering*, volume 152, page 012035. IOP Publishing, 2016.
- [241] Chunhua Zhang and John M Kovacs. The application of small unmanned aerial systems for precision agriculture: a review. *Precision agriculture*, 13(6):693–712, 2012.
- [242] Fangfang Zhang, Junsheng Li, Qian Shen, Bing Zhang, Huping Ye, Shenglei Wang, and Zhaoyi Lu. Dynamic threshold selection for the classification of large water bodies within landsat-8 oli water index images. *Remote Sens*, 2016.
- [243] Harry Zhang. The optimality of naive bayes. *AA*, 1(2):3, 2004.
- [244] Naiqian Zhang, Maohua Wang, and Ning Wang. Precision agriculture—a world-wide overview. *Computers and electronics in agriculture*, 36(2-3):113–132, 2002.
- [245] Weifeng ZHOU and Bingfang WU. Assessment of soil erosion and sediment delivery ratio using remote sensing and gis: a case study of upstream chaobaihe river catchment, north china. *International Journal of Sediment Research*, 23(2):167 – 173, 2008.
- [246] Francisco Bautista Zúñiga, José Luis Palacio Prieto, HUGO DELFÍN GONZÁLEZ, ROSAURA PAÉZ BISTRAN, ESTELA CARMONA JIMÉNEZ, and MA DEL CARMEN DELGADO CARRANZA. *Técnicas de muestreo para manejadores de recursos naturales*. Number 333.715 T4 in Segunda edición. Universidad Nacional Autónoma de México, 2004.
- [247] École Polytechnique Fédérale de Lausanne, The first ever photograph of light as both a particle and wave. <https://actu.epfl.ch/news/the-first-ever-photograph-of-light-as-both-a-parti/>, Online; 31 de Marzo de 2018.

- AGL** Sobre el Nivel del Terreno, "Above Ground Level". 55, 56, 81
- Aster** Advanced Spaceborne Thermal Emission and Reflection. 22
- ATV** Aplicación de Tasa Variable.. 70
- AVHRR** Satélite, Advanced very-high-resolution radiometer (AVHRR). 33, 45
- BIL** Secuencial por pixel o Band Interleaved by Pixel. 37
- BIP** Secuencial por pixel o Band Interleaved by Pixel. 37
- BSQ** Secuencial por bandas o Band Sequential. 37
- c** Velocidad de la luz . 14
- CCD** Dispositivos de Carga Acoplada o charge-coupled device . 27, 32, 51, 73, 136
- CMOS** Semiconductor Complementario de Óxido Metálico o complementary metal-oxide-semiconductor. 53, 73, 136
- CRT** Consejo Regulador del Tequila. 69, 80
- Datum** El datum define el sistema de referencia que describe el tamaño y la forma de la Tierra.. 75
- DO** Denominación de Origen. 67
- EM** Espectro electromagnético. 3, 17
- EOSAT** Earth Observation Satellite Company. 43
- ERTS** Earth Resources Technology Satellite. 43

ESA Agencia Espacial Europea. 51

EUA Estados Unidos de América . 13, 55

FOV Campo de visión o field of view. 26, 74

GCP Los puntos de control en tierra o Ground control Points (GCP), son objetivos marcados en el suelo, espaciados estratégicamente a lo largo de su área de interés.. 73, 79, 138

GLONASS Sistema Mundial de Navegación por Satélites " GLObal'naya NAVi-gatsionnaya Sputnikovaya Sistema", GLONASS.. 70

GMS Satélite Himawari, sensor Geostationary Meteorological Satellites,(GMS). 33, 45

GNSS Sistema global de Navegación por Satélite, "Global Navigation Satellite System". 58, 69, 75

GPS Sistema de Posicionamiento Global " Global Positioning System", GPS.. 69, 70, 75

GSD Ground Sampling Distance . 26, 34

HRVIR Sensor del Satellite SPOT, High Resolution Visible IR . 33, 45

HST Telescopio Espacial Hubble. 51

HypIRI Hyperspectral Infrared Imager o Cámara infrarroja hiperespectral. 21

IFOV Campo de visión instantáneo o instantaneous field of view . 26, 52

IMU Unidad de Medición Inercial, "Inertial Measurement Unit". 57, 58

IR Infrarojo. 3, 5, 17, 20, 22, 73

JPG Joint Photographic Experts Group. 37

JPL Jet Propulsión Laboratory, NASA. 51

LDCM Misión de Continuidad de Datos Landsat o Landsat Data Continuity Mission. 140

LIDAR Light Detection And Ranging - detección por luz y distancia . 24, 58

LISS Sensor de alta resolución de la misión Resourcesat-1, Linear Imaging Self Scanner. 33, 45

MODIS Satélite MODIS, sensor Moderate Resolution Imaging Spectroradiometer). 33, 45

MSS Multispectral Scanner System. 33, 43, 45

Nadir Punto de la superficie más cercano al sensor y que suele coincidir con el centro de la imagen. 27

nadir Punto de la Superficie Terrestre más Cercano al Satélite y que Suele Coincidir con el Centro de la Imagen.. 36, 176

NASA National Aeronautics and Space Act. 42

ND Numero digital . 24, 34, 35, 37, 73, 74, 82, 136, 139, 140

NIR Infrarrojo Cercano (Near Infrared). 143, 144

NOAA National Oceanic and Atmospheric Administration. 43

NRO Oficina de Reconocimiento Nacional. 55

OACI Organización de Aviación Civil Internacional o "International Civil Aviation Organization", ICAO.. 69

OCM Sensor del satélite Oceansat-1, Ocean Colour Monitor (OCM). 33, 45

OCTS Sensor del satélite Advanced Earth Observing Satellite 1 (ADEOS 1), Ocean Color and Temperature Scanner (OCTS). 33, 45

PA Agricultura de Precisión.. 70

PaRS Photogrammetry and Remote Sensing. 54, 75

PR Percepción remota. 3, 43

Radar Radio Detection And Ranging . 24

RBV Return Beam Vidicon. 43

RPAS Aeronave Pilotada Remotamente, "Remotely-Piloted Aerial System". 55

RTK Técnica de posicionamiento global que se basa en la solución de la portadora de las señales transmitidas por los sistemas globales de navegación por satélites GPS, Glonass y Galileo.. 68

SFM Structure from motion.Técnica de origen en la comunidad de visión por computadora.. 71–73, 82

SIG Sistema de Información Geográfica. 37, 79, 138

SPOT Satellite Pour l'Observation de la Terre: Satélite Para la Observación de la Tierra . 33, 45

SWIR Infrarrojo de onda corta.. 22, 143, 144

TFW TIFF world file. 37

TIFF Tagged Image File Format, formato de archivo de imágenes con etiquetas. 37

TM Escáner multispectral de la misión Landsat, Thematic Mapper . 33, 45

TOA Techo de la Atmosfera o Top of Atmosphere. 140

UAS Sistemas Aéreos no Tripulados, "Unmanned Aerial Systems". 55

UAV Vehículo Aéreo No Tripulado . 3, 7, 8, 54–59, 68–70, 73, 75, 114

URSS Unión de Repúblicas Socialistas Soviéticas. 42

VHR Very High Resolution, Muy alta Resolución. 45, 54

VIS Rango del espectro aproximado, entre una longitud de onda de 400 nm hasta 700 nm . 5, 17, 20, 21