



**INSTITUTO POTOSINO DE INVESTIGACIÓN
CIENTÍFICA Y TECNOLÓGICA, A.C.**

POSGRADO EN GEOCIENCIAS APLICADAS

**IPICIM: Módulo Clasificador de Imágenes Ópticas
Multiespectrales Aplicado al Área de Geociencias**

Tesis que presenta

Jose Luis Castilla Carrillo

Para obtener el grado de

Maestro en Geociencias Aplicadas

Director (Codirectores) de la Tesis:

Dr. José Tuxpan Vargas

San Luis Potosí, S.L.P., Diciembre de 2016



Constancia de aprobación de la tesis

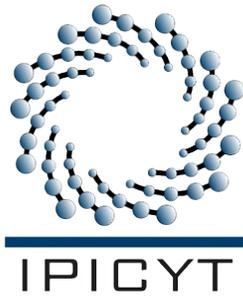
La tesis “**IPICIM: Módulo Clasificador de Imágenes Ópticas Multiespectrales Aplicado al Área de Geociencias**” presentada para obtener el Grado de Maestro en Geociencias Aplicadas fue elaborada por **Jose Luis Castilla Carrillo** y aprobada el **07 de Diciembre de 2016** por los suscritos, designados por el Colegio de Profesores de la División de Geociencias Aplicadas del Instituto Potosino de Investigación Científica y Tecnológica, A.C.

Dr. José Tuxpan Vargas
Codirector de la tesis

Dr. José Noel Carbajal Pérez
Codirector de la tesis

Dr. José Alfredo Ramos Leal
Miembro del Comité Tutorial

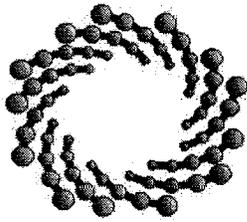
Dr. Sanjeet Kumar Verma
Miembro del Comité Tutorial



Créditos Institucionales

Esta tesis fue elaborada en la División de Geociencias Aplicadas del Instituto Potosino de Investigación Científica y Tecnológica, A.C., bajo la dirección del Doctor José Tuxpan Vargas.

Durante la realización del trabajo el autor recibió una beca académica del Consejo Nacional de Ciencia y Tecnología (337204) y del Instituto Potosino de Investigación Científica y Tecnológica, A. C.



IPICYT

Instituto Potosino de Investigación Científica y Tecnológica, A.C.

Acta de Examen de Grado

El Secretario Académico del Instituto Potosino de Investigación Científica y Tecnológica, A.C., certifica que en el Acta 020 del Libro Primero de Actas de Exámenes de Grado del Programa de Maestría en Geociencias Aplicadas está asentado lo siguiente:

En la ciudad de San Luis Potosí a los 6 días del mes de diciembre del año 2016, se reunió a las 16:00 horas en las instalaciones del Instituto Potosino de Investigación Científica y Tecnológica, A.C., el Jurado integrado por:

Dr. José Noel Carbajal Pérez	Presidente	IPICYT
Dr. José Alfredo Ramos Leal	Secretario	IPICYT
Dr. José Tuxpan Vargas	Sinodal	IPICYT

a fin de efectuar el examen, que para obtener el Grado de:

MAESTRO EN GEOCIENCIAS APLICADAS

sustentó el C.

José Luis Castilla Carrillo

sobre la Tesis intitulada:

IPICIM: Módulo Clasificador de Imágenes Ópticas Multiespectrales Aplicado al Área de Geociencias

que se desarrolló bajo la dirección de

Dr. José Tuxpan Vargas

El Jurado, después de deliberar, determinó

APROBARLO

Dándose por terminado el acto a las 17:00 horas, procediendo a la firma del Acta los integrantes del Jurado. Dando fe el Secretario Académico del Instituto.

A petición del interesado y para los fines que al mismo convengan, se extiende el presente documento en la ciudad de San Luis Potosí, S.L.P., México, a los 6 días del mes de diciembre de 2016.

Mtra. Ivonne Lizette Cuevas Vález
Jefa del Departamento del Posgrado

Dr. Marcial Bonilla María
Secretario Académico





Constancia de aprobación de la tesis

La tesis "**IPICIM: Módulo Clasificador de Imágenes Ópticas Multiespectrales Aplicado al Área de Geociencias**" presentada para obtener el Grado de Maestro en Geociencias Aplicadas fue elaborada por **José Luis Castilla Carrillo** y aprobada el **seis de diciembre del dos mil dieciséis** por los suscritos, designados por el Colegio de Profesores de la División de Geociencias Aplicadas del Instituto Potosino de Investigación Científica y Tecnológica, A.C.

Dr. José Tuxpan Vargas
Director de la tesis

Dr. José Alfredo Ramos Leal
Miembro del Comité Tutorial

Dr. Sanjeet Kumar Verma
Miembro del Comité Tutorial

Agradecimientos

Me gustaría agradecer a mis papas Jose Luis Castilla Cervera y Sara Edelmira Carrillo Aguirre y hermanito Juan Carlos Castilla Carrillo por su apoyo incondicional en mi trayectoria académica y proyectos que me he propuesto, aunque estos no hayan sido los más cuerdos. A los miembros de mi comité agradecerle todos sus consejos. Al Dr. José Tuxpan Vargas le agradezco toda la atención, ayuda, conocimientos y consejos, ya que fueron parte esencial para terminar este proyecto. Por último y no menos importante quisiera agradecer a todos los amigos que esta experiencia de la maestría me ha dado. Estaré siempre agradecido por haber compartido su tiempo conmigo en la escuela, jugando videojuegos, escalando y paseando, experiencias que jamás olvidare.

Contenido

Constancia de aprobación de la tesis	ii
Créditos institucionales	iii
Acta de examen	iv
Agradecimientos	v
Lista de tablas	viii
Lista de figuras	viii
Resumen	xi
Abstract	xii

1 Introducción.....	1
1.1 Antecedentes.....	5
1.2 Objetivos.....	8
1.3 Planteamiento del problema.....	8
1.4 Justificación.....	9
1.5 Alcance.....	10
2 Conceptos Básicos de Percepción Remota.....	11
2.1 Historia.....	11
2.2 Definición de Percepción Remota.....	13
2.3 Elementos de la PR.....	14
2.4 Sistema de Adquisición de Datos.....	15
2.4.1 Plataformas.....	15
2.4.1.1 Satélites Geoestacionarios.....	16
2.4.1.2 Satélites de Órbita Polar.....	17
2.4.2 Sensores Remotos.....	18
2.4.2.1 Sensores Pasivos.....	18
2.4.2.2 Sensores Activos.....	19
2.5 Características de los Datos.....	20
2.5.1 Resolución Espacial.....	21
2.5.2 Resolución Espectral.....	22
2.5.3 Resolución Temporal.....	22
2.5.4 Resolución Radiométrica.....	23
2.6 Aspectos Físicos.....	23
2.6.1 Radiación Electromagnética.....	24
2.6.1.1 Modelo de Onda.....	24
2.6.1.2 Modelo de Partícula.....	25
2.6.2 Espectro Electromagnético.....	26
2.6.3 Términos y Unidades de Medida.....	27
2.6.4 Interacciones.....	28
2.6.4.1 Interacciones Atmosféricas.....	29

3	Clasificación Digital y sus Estrategias de Solución.....	31
3.1	Clasificación.....	31
3.1.1	Fase de Entrenamiento.....	33
3.1.1.1	Métodos Supervisados.....	34
3.1.1.2	Métodos No Supervisados.....	36
3.1.2	Fase de Asignación.....	37
3.1.2.1	Clasificador por Mínima Distancia.....	38
3.1.2.2	Clasificador por Paralelepípedos.....	39
3.1.2.3	Clasificador de Máxima Verosimilitud.....	40
3.1.2.4	Clasificador Basado en Arboles de Decisión.....	41
3.1.2.5	Clasificador Basado en Redes Neuronales.....	42
3.2	Unidades Base Para la Clasificación.....	43
4	Desarrollo de la Propuesta IPICIM.....	47
4.1	Sistemas Ópticos Multiespectrales.....	50
4.2	Bases Digitales de Firmas Espectrales.....	53
4.2.1	Base de Datos ASTER.....	53
4.2.2	Base de Datos Nacional.....	54
4.3	Prototipo Computacional.....	56
4.3.1	Módulo Visualización y Edición.....	56
4.3.1.1	Visualización Escala de Grises.....	57
4.3.1.2	Visualización RGB.....	58
4.3.1.3	Recortar Imagen.....	60
4.3.2	Módulo de Pre-Procesamiento.....	62
4.3.2.1	Conversión de ND a Radiancia (Q_{cal} a L_{λ}).....	63
4.3.2.2	Conversión de Radiancia a Reflectancia (L_{λ} a ρ_{λ}).....	66
4.3.3	Módulo de Procesamiento.....	68
4.3.3.1	Cálculo de Temperatura de Brillo (L_{λ} a T).....	68
4.3.3.2	Cálculo de Índices.....	70
4.3.3.3	Calculadora de Bandas.....	72
4.3.3.4	Clasificador No Supervisado.....	73
4.3.3.5	Clasificador Supervisado.....	74
4.3.3.6	Clasificador Redes Neuronales.....	77
4.4	Implementación.....	80
4.4.1	Interface de Usuario.....	82
5	Resultados.....	87
5.1	Software IPICIM.....	88
5.2	Comparación de Tiempos.....	93
5.3	Resultados y Comparativa de los Tres Clasificadores.....	97
5.4	Capacidades y Aplicaciones en Geociencias.....	98
5.4.1	Mapeo de la Calidad del Agua en el Lago de Chapala Jalisco.....	99
5.4.2	Mapeo de Biomasa Arbórea en el Bosque de Chapultepec... ..	103
5.4.3	Flujo de Calor en el Volcán Popocatépetl.....	106
6	Conclusiones.....	109
7	Referencias.....	111
	Anexo 1: Tabla Elementos Base de Datos ASTER.....	115
	Anexo 2: Tablas Para Cálculo de Radianza y Reflectancia.....	125

Lista de tablas

Tabla 1.1.-SIG más usados en PR.....	7
Tabla 2.1.-Tonos de gris en la resolución radiométrica.....	23
Tabla 2.2.- Regiones del Espectro Electromagnético	27
Tabla 3.1.-Resumen de las técnicas de clasificación (Li, 2014).....	45
Tabla 4.1.- Resumen de características para los sistemas Landsat.....	52
Tabla 4.2.- Combinaciones de bandas en Color Verdadero y Falso Color.....	59
Tabla 4.3.- Constantes para el cálculo de temperatura de brillo (L_{λ} a T)..	69
Tabla 4.4.- Índices implementados en IPICIM (ρ_x =Reflectancia Banda x)	71
Tabla 5.1.-Especificaciones técnicas de la computadora.....	94
Tabla 5.2.- Comparativa de tiempos de procesamiento para varias operaciones.....	95
Tabla 5.3.- Algoritmos para el cálculo de parámetros de calidad del agua.....	100

Lista de figuras

Figura 1.1.- Crecimiento de la mancha urbana (Imagen obtenida del Atlas of Our Changing Environment, UNEP).....	1
Figura 1.2.- Espectro electromagnético.....	2
Figura 1.3.- Firmas espectrales de algunos elementos.....	3
Figura 1.4.- Procesamiento y clasificación de imágenes.....	5
Figura 2.1.- En esta figura se muestra una de las primeras técnicas utilizadas para la obtención de imágenes aéreas con fines principalmente militares.....	12
Figura 2.2.-Muestra algunos satélites meteorológicos y de observación de la tierra.....	13
Figura 2.3.- Elementos básicos en la Percepción Remota.....	14
Figura 2.4.- Comparativa entre las alturas de vuelo de distintas plataformas de PR.....	16
Figura 2.5.- Tipos de satélites usados en PR; a) Satélite Geoestacionario; b) Satélite de Órbita Polar.....	18
Figura 2.6.- Tipos de sensores en PR, a) Sensores Pasivos b) Sensores Activos.....	20
Figura 2.7.- Representación de una imagen digital, una muestra de la imagen de 5x5 píxeles y sus números digitales correspondientes.....	21
Figura 2.8.- Ejemplo de diferentes Resoluciones Espaciales para una misma imagen.....	21
Figura 2.9.- Sensores dependiendo de su número de bandas: Multiespectrales (parte superior) e Hiperespectrales (parte inferior).....	22
Figura 2.10.- Modelo de Onda de la energía electromagnética.....	24
Figura 2.11.- Espectro electromagnético.....	26
Figura 2.12.- Modificación de la REM al interactuar con los objetos.....	29

Figura 2.13.- Tipos de difusión dependiendo del tamaño de la partícula..	30
Figura 2.14.- Bandas de absorción y ventanas atmosféricas.....	30
Figura 3.1.- Ejemplo de una clasificación de usos de suelos realizada en Preveza Grecia (Kolios & Stylios, 2013).....	32
Figura 3.2.- Fases de la Clasificación de Imágenes.....	32
Figura 3.3.- Relación entre las clases o coberturas (lado izquierdo) y las clases espectrales (lado derecho): I) Una cobertura y varias clases espectrales, II) Varias coberturas y una clase espectral, III) Mezcla de ambas, IV) Caso ideal.....	34
Figura 3.4.- Pasos de los Métodos Supervisados.....	35
Figura 3.5.-Pasos de los Métodos No Supervisados.....	37
Figura 3.6.-Ejemplo de dos bandas del Algoritmo Mínima Distancia. Los subíndices “m” identifican el valor medio de la clase.....	39
Figura 3.7.- Ejemplo de dos bandas del Algoritmo de Paralelepípedos...	40
Figura 3.8.- Ejemplo de dos bandas del Algoritmo de Máxima Verosimilitud.....	41
Figura 3.9.- Árbol de decisiones.....	42
Figura 3.10.- Red Neuronal Back Propagation.....	42
Figura 3.11.- Ejemplo de una mezcla de diferentes coberturas de suelos en un mismo pixel.....	44
Figura 3.12.- Clasificación orientada a Píxeles y a Objetos.....	45
Figura 4.1.- GUIDE MATLAB.....	48
Figura 4.2.- Diagrama de bloques del software IPICIM.....	49
Figura 4.3.- Interface de usuario IPICIM.....	50
Figura 4.6.- Línea del tiempo de los satélites Landsat.....	51
Figura 4.7.- Cary 5000 UV-Vis-NIR Spectrophotometer.....	54
Figura 4.8.-Diagrama de flujo para la obtención de firmas espectrales en el equipo Cary 5000.....	56
Figura 4.9.- Visualización en escala de grises IPICIM.....	57
Figura 4.10.- Interface Visualización RGB IPICIM.....	60
Figura 4.11.- Interface de Recorte IPICIM.....	61
Figura 4.12.- Diagrama de flujo para recortar imagen por Coordenadas o Píxeles.....	61
Figura 4.13.- Diagrama de flujo para recortar imagen por Recuadro.....	62
Figura 4.14.- Diagrama de flujo para conversión de Q_{cal} a L_{λ}	65
Figura 4.15.- Diagrama de flujo para conversión de L_{λ} a ρ_{λ}	67
Figura 4.16.- Diagrama de flujo para conversión de L_{λ} a T	69
Figura 4.17.- Diagrama de flujo para el cálculo de Índices.....	70
Figura 4.18.-Diagrama de flujo para la resolución de funciones en la calculadora de bandas del IPICIM.....	72
Figura 4.19.- Interface IPICIM para la Clasificación No Supervisada.....	73
Figura 4.20.- Diagrama de flujo para la Clasificación No Supervisada.....	74
Figura 4.21.- Interface IPICIM para la Clasificación Supervisada.....	75
Figura 4.22.-Distribución Gaussiana y porcentaje de valores englobados para cada rango de la media y la desviación estándar.....	76
Figura 4.23.- Diagrama de flujo para la Clasificación Supervisada.....	77
Figura 4.24.- Conversión Matriz a Vector Fila.....	78

Figura 4.25.- Obtención de parámetros para el criterio de decisión.....	78
Figura 4.26.- Red Neuronal Implementada en el IPICIM.....	80
Figura 4.27.- Diagrama de flujo para la Clasificación propuesta con R.N...	80
Figura 4.28.- GUI MATLAB.....	81
Figura 4.29.- Interface Principal IPICIM.....	83
Figura 4.30.- Interface Calculadora de Bandas IPICIM.....	85
Figura 5.1.-Interface principal IPICIM.....	89
Figura 5.2.- Interface para recorte de imágenes.....	90
Figura 5.3.- Interface visualización escala de grises.....	90
Figura 5.4.- Interface Visualización en RGB.....	90
Figura 5.5.-Interface de la Calculadora de Bandas.....	91
Figura 5.6.- Interface clasificador no supervisado.....	91
Figura 5.7.- Interface Clasificador supervisado.....	91
Figura 5.8.- ENVI.....	93
Figura 5.9.-GRASS GIS.....	94
Figura 5.10.-Imagen RGB (3,2,1) Reflectancia.	97
Figura 5.11.- Comparativa de resultados obtenidos en la clasificación.....	98
Figura 5.12.- Diagrama de flujo para el cálculo de parámetros para la calidad del agua.....	100
Figura 5.13.-Proceso de obtención de la superficie de agua: a) RGB ND's; b) RGB Reflectancia; c) NDWI; d).RGB Mascara de Agua.....	101
Figura 5.14.- Valores de algunos parámetros para la calidad del agua para diferentes usos (Agust, Longoria, & Maldonado, 2012)	101
Figura 5.15.-Resultados de los algoritmos para los parámetros de calidad del agua.....	102
Figura 5.16.- Diagrama de flujo para el cálculo de Biomasa Arbórea.....	104
Figura 5.17.- Proceso de obtención de la Biomasa: a) RGB ND's; b) RGB Reflectancia; c) Falso color (5,4,3); d).NDVI.....	105
Figura 5.18.- Biomasa expresada en T/Ha.....	105
Figura 5.19.-Diagrama de flujo para el cálculo del Flujo de Calor en la zona del volcán Popocatépetl.....	106
Figura 5.20.- Zona de trabajo volcán Popocatépetl: a) RGB de Reflectancia b); T.....	107
Figura 5.21.- Flujo de Calor (Q_r en W/m^2) de la zona del volcán Popocatépetl.....	108

Resumen

“IPICIM: Módulo Clasificador de Imágenes Ópticas Multiespectrales Aplicado al Área de Geociencias”

En años recientes con la creación de la Agencia Espacial Mexicana (AEM) y su intención de incursionar en el sector aeroespacial, se han propiciado las condiciones adecuadas para la investigación y desarrollo de tecnología y capacidades nacionales en el ámbito aeroespacial. En este trabajo, se reporta el diseño e implementación de módulos computacionales para el procesamiento de datos adquiridos mediante sistemas satelitales ópticos multi-espectrales dedicados a la observación y monitoreo de la superficie terrestre.

El sistema IPICIM (formado por las siglas IPI de Instituto Potosino de Investigación y CIM de Clasificador de Imágenes Multi-espectrales) permite trabajar con todos los satélites de la familia Landsat (L1-L8), como primer requisito solicitado por la AEM-CONACYT con la posibilidad de expandir su rango de operación a otros sistemas ópticos multi-espectrales.

Se diseñaron e implementaron módulos especializados para el tratamiento de los datos en dos categorías principales: el pre-procesamiento consistente en la corrección de errores, adecuación y depuración de datos, y como segunda etapa la generación de contenidos digitales encargada de la elaboración de mapas temáticos y procesos dedicados de clasificación de la información. Los clasificadores con los que cuenta el IPICIM son del tipo supervisado, no supervisado y se presenta una propuesta de modelo basado en el uso de redes neuronales y autoaprendizaje a partir de dos librerías digitales de firmas espectrales, la primera formulada por los laboratorios de JHU (Johns Hopkins University), JPL (Jet Propulsion Laboratory) y USGS (United States Geological Survey) y de una base de firmas espectrales nacional, la cual fue iniciada en este trabajo, actualmente se tienen aproximadamente 40 firmas espectrales relacionadas con aguas contaminadas, vegetación invasiva y diferentes tipos de roca/suelo.

Los resultados obtenidos con el clasificador basado en redes neuronales y apoyado de las firmas espectrales sugieren que el desempeño del algoritmo aprovecha las ventajas de los clasificadores convencionales (supervisado y no supervisado) minimizando sus desventajas.

El IPICIM fue evaluado y comparado con otros SIG (Sistemas de información geográfica) de paga (ENVI) y gratuitos (GRASS-Qgis) obteniendo resultados muy semejantes.

Palabras Clave. Percepción remota, sensado pasivo, imágenes multi-espectrales, monitoreo de la superficie terrestre, clasificación neuronal.

Abstract

“IPICIM: Optical-Multispectral Imaging Module Applied to the Geosciences Area”

In recent years, with the creation of the Mexican Space Agency (AEM) and its intention to get into the aerospace sector, have favored the right conditions for research in that field. In this work, we report the design and implementation of computational modules for the processing of data acquired through multi-spectral optical satellite systems dedicated to the observation and monitoring of the Earth's surface.

The IPICIM system formed by the Spanish acronym IPI of Instituto Potosino de Investigacion (Investigation Institute of San Luis Potosi) and CIM of Clasificador de Imágenes Multiespectrales (Multi-Spectral Images Classifier), allows to work with every single satellite of the Landsat family (L1-L8), as the first requirement set by the AEM-CONACYT, with the possibility of expanding its operation range to other multi-spectral optical systems.

Specialized modules for data processing were designed and implemented in two main categories: consisting pre-processing on error correction, data adequacy and debugging, and as the second stage the generation of digital content in charge of thematic maps and dedicated classification processes. The IPICIM classifiers are: the supervised, unsupervised and a proposed model based on the use of neural networks and self-learning is presented. The last one using two digital databases of spectral signatures, the supervised formulated by the JHU laboratories (Johns Hopkins University, JPL (Jet Propulsion Laboratory) and USGS (United States Geological Survey) and the second one from a national spectral signature base, which was started in this work, currently it is conformed by approximately 40 spectral signatures related to contaminated water, invasive vegetation and different types of rock / soil.

The results obtained with the neural network based classifier and supported by the spectral signatures suggest that the algorithm performance takes advantage of the conventional classifiers (supervised and unsupervised) minimizing its disadvantages.

The IPICIM was evaluated and compared with other GIS (Geographical Information Systems) of payment (ENVI) and free (GRASS-Qgis) obtaining very similar results.

Keywords. Remote sensing, passive sensing, multi-spectral imaging, terrestrial surface monitoring, neuronal classification.

Capítulo 1: Introducción

En busca de satisfacer la creciente necesidad de alimentos, abastecimiento de agua, desarrollo urbano, entre muchas otras cosas, la humanidad ha cambiado ecosistemas como bosques por áreas para la agricultura y la ganadería, ha construido carreteras y caminos a través de desiertos y montañas, e incluso ha levantado ciudades sobre lagos. A medida que estos cambios ocurren por la falta de criterios basados en la sustentabilidad de los sistemas, el deterioro del suelo, del aire y del agua se convierten en grandes problemas para la sociedad.

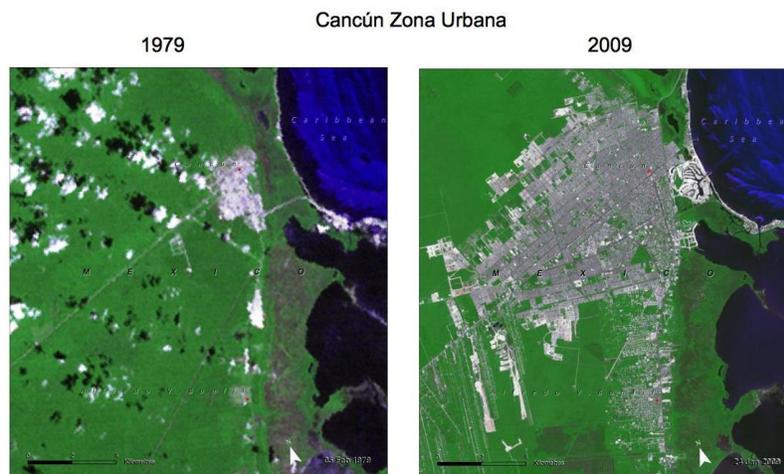


Figura 1.1.- Crecimiento de la mancha urbana (Imagen obtenida del Atlas of Our Changing Environment, UNEP).

La detección temprana de los cambios en el medio ambiente, y la magnitud de los mismos (Figura 1.1), son información valiosa que nos ayudan a planificar el uso de nuestro territorio a largo plazo. Para poder alcanzar este objetivo se han desarrollado muchas técnicas y metodologías entre las que destacan aquellas que usan como herramienta a la Percepción Remota (PR).

La PR es un conjunto de técnicas que permiten la adquisición de información de elementos de la superficie terrestre a distancia y sin estar en contacto con ellos. La adquisición de datos se da a través de sensores ubicados en lo alto de una escalera

o edificio, en aviones, vehículos no tripulados como drones, y en satélites que orbitan la tierra en altitudes que varían entre 400 y 900 kilómetros, estos últimos son tratados en el desarrollo de este trabajo de maestría.

A medida que los satélites orbitan la superficie de la tierra, los sensores acoplados captan la energía reflejada después de la interacción con los elementos en la superficie (árboles, agua, construcciones, rocas, etc.). Existen dos tipos principales de sensores, los activos y los pasivos y se diferencian de la fuente de energía que utilizan. Cuando es el mismo sensor el que produce la energía se trata de un sensor activo, tal es el caso de equipos radar que emiten energía electromagnética en el segmento de las microondas. En cambio, los sensores pasivos necesitan de una fuente externa, ejemplo de ellos son: los sensores ópticos cuya fuente electromagnética es el sol. En la Figura 1.2 se muestra la distribución del espectro electromagnético.

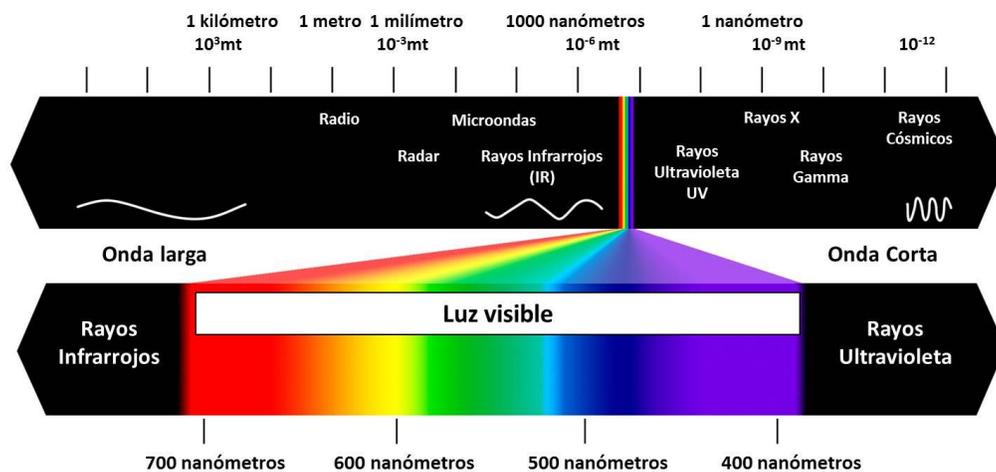


Figura 1.2.- Espectro electromagnético.

Dependiendo de las propiedades físicas, químicas, biológicas y de la longitud de onda de la energía electromagnética, la superficie terrestre y los elementos que en ella se encuentran, presentan un comportamiento diferente, el cual es captado por los sensores. A esta característica particular de cada elemento se le conoce como

firma espectral (Figura 1.3) y es la base para todos los procesos realizados posteriormente.

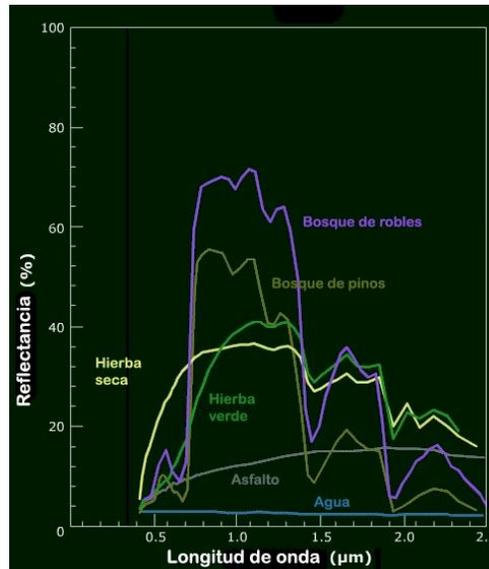


Figura 1.3.- Firmas espectrales de algunos elementos.

El resultado del proceso de adquisición de datos son las imágenes satelitales, representaciones visuales de la superficie de la tierra que muestran la energía reflejada por unidad de superficie. Cada imagen está compuesta de varias capas conocidas como bandas espectrales que representan mediciones a diferentes longitudes de onda, el elemento más pequeño de cada banda de las imágenes son los píxeles, que tienen valores que van comúnmente de 0 a 255.

El objetivo de este trabajo fue el desarrollo de un Sistema de Información Geográfica (SIG), en otras palabras, un software capaz de controlar, manipular y visualizar datos georreferenciados para su análisis e interpretación.

El software nombrado IPICIM de la combinación de IPI por el Instituto Potosino de Investigación Científica y Tecnológica y CIM por Clasificador de Imágenes Multiespectrales, se enfoca en los pasos posteriores a la adquisición de las imágenes:

- la etapa de **pre-procesamiento** realiza la corrección de distorsiones que alteran los valores del brillo de los píxeles debido principalmente a interferencias atmosféricas y a efectos asociados con la instrumentación;
- la etapa **procesamiento** está dedicada al desarrollo y reproducción de aplicaciones en las que se busca dar un significado físico o interpretación a los píxeles.

Existen gran cantidad de aplicaciones en diferentes ramas de las ciencias, algunos ejemplos son:

- Agricultura: mapeos para la clasificación de cultivos, exámenes de salud y viabilidad, supervisión de prácticas agrícolas.
- Forestal: mapas de coberturas forestales, monitoreo y medición de propiedades biofísicas de las masas forestales.
- Geología: mapeo de depósitos superficiales, cartografía litológica.
- Hidrología: Monitoreo y mapeo de humedales, dinámica de glaciares, contaminantes en el agua de ríos y lagos.
- Cobertura y uso de la tierra: Gestión de recursos naturales, protección de hábitat silvestre, expansión urbana.

Como se puede observar en los ejemplos una de las aplicaciones más importantes es la clasificación, que es la aplicación de procedimientos matemáticos y estadísticos a las imágenes originales para asignar a cada píxel una categoría de uso o cobertura de la tierra. En la literatura están reportadas gran cantidad de metodologías (Ayday & Minz, 2015; Goel, Gaur, & Jain, 2015; LI, ZHENG, WANG, CHANG, & Yufeng, 2016; Rahman & Verma, 2013) para su realización, métodos que requieren conocimientos previos del área de estudio, y otros donde no es necesario, al mismo tiempo se cuenta con métodos que emplean inteligencia

artificial. El resultado final es una imagen digital clasificada de la superficie terrestre que permite calcular las superficies y distribución de cada clase de identificada Figura 1.4.

En el software IPICIM contiene entre otras cosas, de un módulo para la clasificación mediante el uso de redes neuronales y de una combinación entre dos bases de datos, una internacional y otra nacional generada en el IPICYT. Este diseño es capaz de entregar un mapa detallado de las coberturas de suelo que se encuentren en la escena sin la necesidad de contar con información a priori sobre el área de estudio.



Figura 1.4.- Procesamiento y clasificación de imágenes.

1.1 Antecedentes

Desde la aparición del primer sistema de información geográfica (SIG) como una herramienta para el manejo de los datos del inventario geográfico canadiense a principios de los 60, estos han continuado apareciendo con el paso de los años, y aunque en un inicio solo se enfocaban a elementos de la cartografía cuantitativa, actualmente se ha incorporado un gran número de otras disciplinas.

La aparición de los satélites de observación terrestre marcó un gran avance en los métodos de adquisición de datos, dándole un nuevo giro al expandir las técnicas existentes de fotografía aérea a una escala global. Del mismo modo los incesantes avances tecnológicos y computacionales, acompañados de la creciente

disponibilidad de computadoras personales, han convertido a los SIG en herramientas poderosas disponibles para todos los investigadores de muchas áreas de las ciencias.

La Percepción Remota (PR) es un área de estudio que ha traído grandes beneficios por su aplicabilidad en diversos campos, su gran cobertura, reducción de costos y tiempos comparado con otros métodos, disponibilidad temporal y la accesibilidad de los datos en tiempo real, entre otras ventajas. Por todas las razones antes mencionadas, el desarrollo de SIG's enfocados en PR ha tomado mucho interés.

Comercialmente se cuenta con una gran variedad de softwares a elegir, dentro de los más comunes en el área de PR se enlistan en la Tabla 1.1. La información que se presenta fue extraída de sus páginas oficiales.

NOMBRE	BREVE DESCRIPCIÓN	DESARROLLADORES / PROCEDENCIA
INVI	Software completo de visualización y análisis de las imágenes obtenidas en la PR. Su interfaz lógico e intuitivo nos permite leer, visualizar y analizar diferentes formatos de imágenes, de todos los tamaños y en un gran número de plataformas.	Harris Geospatial Solutions Products / USA
TERRSET	TerrSet es un sistema de software geoespacial integrado para la vigilancia y la modelización del sistema de la tierra para el desarrollo sustentable. El sistema TerrSet incorpora las herramientas de procesamiento de imágenes junto con una constelación de aplicaciones verticales. TerrSet ofrece el más amplio conjunto de herramientas geoespaciales en la industria en un solo paquete, asequible. No hay necesidad de comprar costosos complementos para extender sus capacidades de investigación.	ClarkLabs / USA
GEOmatica	PCI Geomática ofrece una solución personalizada para automatizar la corrección de las imágenes	PCI Geomatics / Canada

	<p>históricas. Geomática soporta todos los sensores comerciales y muchos otros también. Trabajamos en estrecha colaboración con los proveedores de datos para que pueda contar con el apoyo puntual de las nuevas plataformas comerciales. Las recientes adiciones y mejoras incluyen anuncios, PALSAR, Deimos y TripleSat, con el apoyo de la corrección atmosférica para GF-2., TEOS y más de treinta.</p>	
GRASS	<p>GRASS GIS, comúnmente conocida como GRASS (Geographic Resources Analysis Support System), es un SIG gratuito que se utiliza para la gestión de datos geospaciales y análisis, procesamiento de imágenes, gráficos y mapas de la producción, el modelado espacial, y visualización. GRASS GIS se utiliza actualmente en ámbitos académicos y comerciales de todo el mundo, así como por muchos organismos gubernamentales y empresas de consultoría ambiental.</p>	GRASS Development Team / Alemania
ERDAS Imagine	<p>Proporciona herramientas para la teledetección, fotogrametría, análisis Lidar, análisis básico de vectores, y el procesamiento de radar en un solo producto.</p>	Hexagon Geospatial / USA

Tabla 1.1.-SIG más usados en PR.

De los softwares existentes se encontró que algunos son de paga, otros son gratuitos, pero todos son de arquitectura cerrada lo que significa que no se les pueden realizar modificaciones. Con base en esta problemática se decidió la creación de un SIG el cual sea el primero de origen mexicano y que servirá de base para el proyecto CONACYT-AEM.

1.2 Objetivos

Objetivo General:

Diseñar e implementar un sistema de información geográfica especializado en procesos correctivos y de valor agregado aplicables a sistemas ópticos multiespectrales

Requerimientos específicos:

- Capacidad de procesar imágenes satelitales multiespectrales provenientes de diversas plataformas;
- Desarrollo de procesos de corrección de errores, adecuación y depuración de los datos;
- Generación de contenidos digitales útiles para la creación de mapas temáticos;
- Los módulos se integrarán como parte de las funcionalidades ofrecidas por el sistema de almacenamiento y procesamiento de contenidos digitales.

Objetivos Específicos:

- Elaboración de un SIG mexicano
- Creación de una base digital nacional de firmas espectrales (primera fase)
- Desarrollo de procesos de clasificación
- Desarrollo de procesos orientados a aplicaciones *Near real Time*.

1.3 Planteamiento del problema

Con el fin de satisfacer una necesidad de la Agencia Espacial Mexicana (AEM) el CINESTAV-Tamaulipas, el Centro Nacional de Súper computo (CNS) y la División de Geociencias Aplicadas del Instituto Potosino de Investigación Científica y Tecnológica (DGA-IPICYT) en la “Convocatoria 2015-01 del Fondo Sectorial de

investigación, Desarrollo Tecnológico e innovación en Actividades Espaciales CONACYT-AEM 2015, se propuso el proyecto:

“Servicio Federado de Cómputo en la Nube para el Almacenamiento, Procesamiento y Distribución de Imágenes Satelitales”

Que tiene como objetivo el desarrollar servicios de pre-procesamiento en línea para aquellos productores y consumidores de imágenes digitales que requieren añadir valor agregado a las mismas y que no cuentan con recursos de cómputo suficientes en sus organizaciones.

Las actividades como redes de distribución y almacenamiento de datos serán realizadas por las dependencias CINVESTAV y CNS mientras que la DGA-IPICYT será la encargada del pre-procesamiento y procesamiento de las imágenes. Los productos finales de este proyecto serán:

- Mapas temáticos, en formato estándar, solicitado por el usuario (servicio bajo pedido), dentro de los resultados iniciales se podrá seleccionar estas opciones:
 - Mapas de análisis de vegetación
 - Mapas para ver zonas inundadas o con riesgo a inundarse
- Archivo con análisis básico de interpretación del mapa temático proporcionado.

1.4 Justificación

Existen en el mercado muchos softwares capaces de procesar y clasificar imágenes satelitales, algunos requieren de un pago en ocasiones elevado mientras que la minoría son gratuitos, pero ninguno es de origen mexicano; mediante la implementación de una colección de firmas espectrales de tres laboratorios diferentes, se buscará automatizar todo el proceso para eliminar los posibles errores inherentes al usuario y así aumentar la certidumbre de los resultados en la

clasificación así como la mejora considerable en los tiempos de procesamiento de los datos.

1.5 Alcance

En este trabajo se plantea el diseño e implementación de un módulo computacional especializado en procesos de tratamiento, análisis y clasificación de imágenes captadas por sistemas de percepción remota. Las imágenes admisibles (en esta primera versión) son aquellas adquiridas por sensores ópticos del tipo pasivo montados sobre plataformas satelitales (sistemas Landsat 1-8). Dentro de las actividades consideradas en este proyecto y como parte fundamental se pretende iniciar con la elaboración de una Base de Datos Nacional (BDN) que contenga las firmas espectrales de diversos materiales y/o recursos existentes en el territorio mexicano; dentro de los primeros registros ya almacenados se encuentran muestras provenientes de diversos cuerpos de agua, muestras de vegetación invasiva y de diversos tipos de suelo, las cuales resultan de especial interés debido a su impacto ambiental, social y económico, por ejemplo cuerpos de agua contaminados como el lago de Chapala o en la zona de Matehuala en San Luis Potosí. También se dispone de una base de datos proveniente de los laboratorios JPL, JHU, USGS consistente en 1343 firmas espectrales de suelos, vegetación, rocas, minerales, y elementos artificiales en el rango de 0.42 – 14 μm de longitud de onda. En lo que se refiere al módulo encargado del proceso de clasificación se pretende satisfacer dos criterios fundamentales, el primero es aumentar la precisión de nuestros resultados apoyándonos de la BDN y en segunda instancia emplear estrategias y técnicas computacionales eficientes en el procesamiento de los datos minimizando los tiempos de cálculo. Ante tales requerimientos, en este trabajo se propone y explora el uso de redes neuronales para la elaboración del sistema clasificador ad-hoc mexicano.

Capítulo 2: Conceptos Básicos de Percepción Remota

En este capítulo se resume la historia de la Percepción Remota (PR), su definición, cuales son los elementos que la componen, la obtención de datos y las características de los mismos, y por último, se darán las bases físicas que permiten la obtención de datos.

2.1 Historia

La exploración y conocimiento de lo que nos rodea, siempre ha sido una de las principales inquietudes del hombre. Aunque en un inicio solo se usaban los sentidos como la vista y el oído para explorar nuestro entorno, el avance en la tecnología como las cámaras fotográficas y aeronaves tuvieron un fuerte impacto en la consolidación de la PR, y fue hasta después de la Segunda Guerra Mundial que tomo mayor interés científico. El desarrollo de las primeras técnicas y equipo especializado tuvo fines militares y estratégicos; tiempo después se desarrollaron técnicas para usos civiles. En el libro “Una Introducción a la Percepción Remota Contemporánea” (Weng, 2012) mencionan ocho épocas en el desarrollo de la tecnología de los sensores remotos.

- Era aérea: La PR fue aplicada en usos militares como reconocimiento del terreno, mapeo y vigilancia militar.
- Era de los satélites rudimentarios: Primeros sensores a bordo de “satélites prueba” Sputnik 1 y Explorer 1 de la Unión Soviética y Estados Unidos respectivamente.
- Era de los satélites espías: Se desarrolló durante la guerra fría, usados con fines geo estratégicos exclusivamente militares, ayudaron a la mejora de procesos de mapeo y en menor medida al estudio de recursos y el medio ambiente.



Figura 2.1.- En esta figura se muestra una de las primeras técnicas utilizadas para la obtención de imágenes aéreas con fines principal mente militares.

- Era de los satélites meteorológicos: Primeros satélites exclusivamente meteorológicos como el GOES y NOAA/AVHRR, los datos comienzan a estar disponibles a escala global con aplicaciones sobre el medio ambiente.
- Era Landsat: Comienza con el lanzamiento del Landsat 1 en 1972 seguido de los satélites Landsat 1-8. *Landsat* ofrece una cobertura global, con una resolución temporal amplia (1970 a la actualidad), además de que sus datos son de acceso libre para la comunidad científica.
- Era de Observación de la Tierra (EOS): Comienza con el lanzamiento del satélite Terra en 1999 el cual provee de cobertura global, coberturas cíclicas de un mismo punto y libre acceso a la comunidad científica.
- Era del nuevo milenio: Se refiere a la era de lanzamiento de satélites prueba o experimentos, sus sensores se convertirán en la nueva generación de observación de la tierra, mejorando el aprovechamiento del espectro electromagnético. Entre estos satélites se encuentra el Earth-Observing-1, el primero en llevar un sensor hiperespectral.
- Era de los satélites comerciales: Esta era da inicio con el nuevo milenio y ofrece un gran número de innovaciones, los datos se colectan a muy alta

resolución, aumenta la cobertura de los datos, se introducen micro satélites y aparece Google Earth que provee un rápido acceso de datos, con tecnología disponible para cualquier persona no experta en PR.

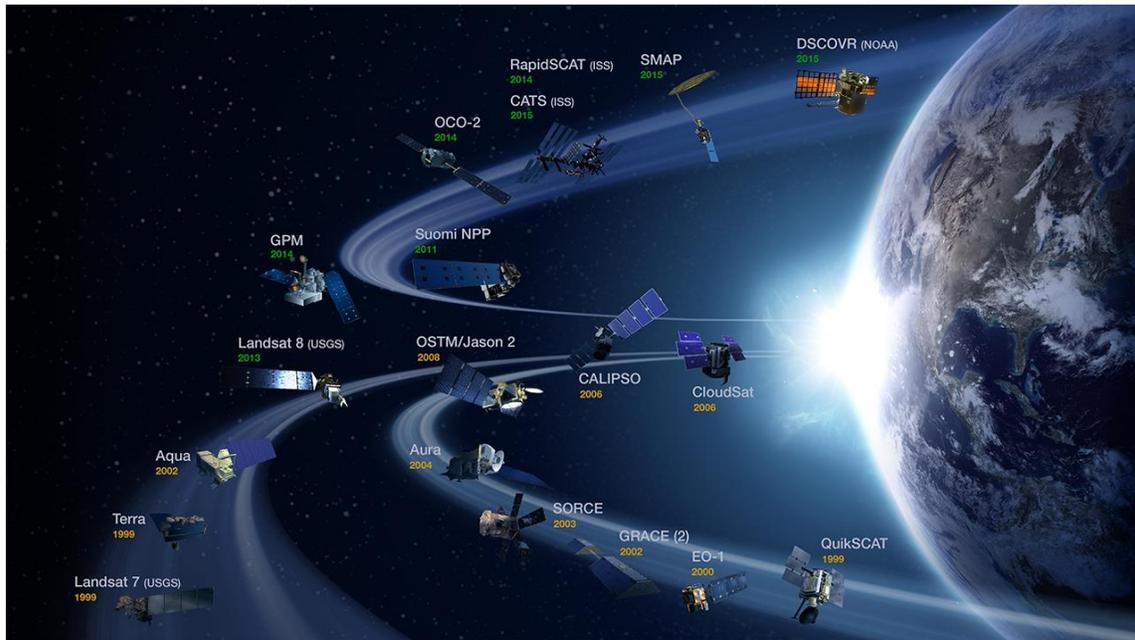


Figura 2.2.-Muestra algunos satélites meteorológicos y de observación de la tierra.

2.2 Definición de Percepción Remota

La percepción remota también conocida como teledetección tiene como objetivo obtener información de un área, objeto o fenómeno a través del análisis de datos adquiridos a una distancia conocida, es decir, sin estar en contacto físico (Gomasasca, 2009) ; también se define como un conjunto de técnicas de medición y procesamiento para la recopilación y análisis de geoinformación mediante el registro de energía electromagnética reflejada o emitida, captada con instrumentos montados en plataformas terrestres, aéreas o espaciales (Lemmens, 2011).

La PR no recoge información directa del medio ambiente por lo que la información electromagnética recopilada debe ser convertida en estimaciones de variables químicas, biológicas y físicas a través de la creación de modelos matemáticos

adecuados(Ahn et al., 2015; Buras, Thevs, Zerbe, & Wilmking, 2013; Cristóbal, Jiménez-Muñoz, Sobrino, Ninyerola, & Pons, 2009; Kolios & Stylios, 2013). El éxito o fracaso en la estimación de las variables ambientales, dependerá de los modelos y algoritmos desarrollados y utilizados para la extracción de datos ópticos-espectrales recogidos de los sensores, así como la comparación y evaluación con la superficie de referencia.

2.3 Elementos de la PR

Desde los inicios de la PR es posible distinguir varios elementos básicos para la obtención de datos e información de alguna escena o fenómeno (Lira, 1997), estos son representados en la Figura 2.3:

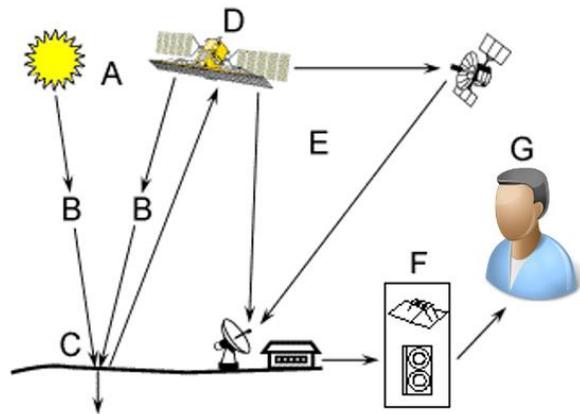


Figura 2.3.- Elementos básicos en la Percepción Remota.

- A. Fuente de energía electromagnética que será irradiada hacia los objetos.
- B. Medio, elemento (ej. Atmosfera) en donde la energía interactuara en su paso del sensor al objeto y viceversa.

- C. Objetos, son los elementos que reciben la energía electromagnética (ej. rocas, vegetación, ríos, etc.) y dependiendo de sus propiedades, tendrán diferentes respuestas a la energía recibida.
- D. Sistema de adquisición de datos, consta de dos partes el sensor remoto y la plataforma; el sensor remoto es el hardware que recibe la radiación electromagnética reflejada o emitida por los objetos y la atmosfera, mientras que la plataforma, es donde se encuentra montado el sensor remoto.
- E. Sistema de procesamiento, son los dispositivos para procesar cualitativa y cuantitativamente los datos recibidos y enviados por los sensores remotos.
- F. Interpretación y análisis, consiste en obtener información de los objetos captados.
- G. Usuario, es quien le da un uso o aplicación a la información obtenida de los objetos de interés.

2.4 Sistema de Adquisición de Datos

Los sistemas de adquisición de datos son muy variados, pero consisten principalmente de dos partes, la plataforma y el sensor remoto.

2.4.1 Plataformas

La plataforma es el lugar, objeto o medio de transporte donde se encuentra montado el sensor remoto, se pueden encontrar en la superficie, en el aire o en el espacio. Algunos ejemplos son escaleras, vehículos, edificios si hablamos de pocos metros de altura; globos aerostáticos, vehículos aéreos no tripulados o UAV's (Unmanned Aerial Vehicle) por sus siglas en inglés, aviones de altitud media y alta si ya hablamos de hasta 20 km; vehículos que se encuentran fuera de la atmosfera (200 km en adelante) como son los satélites y transbordadores espaciales, en los que se enfocara este trabajo Figura 2.4.

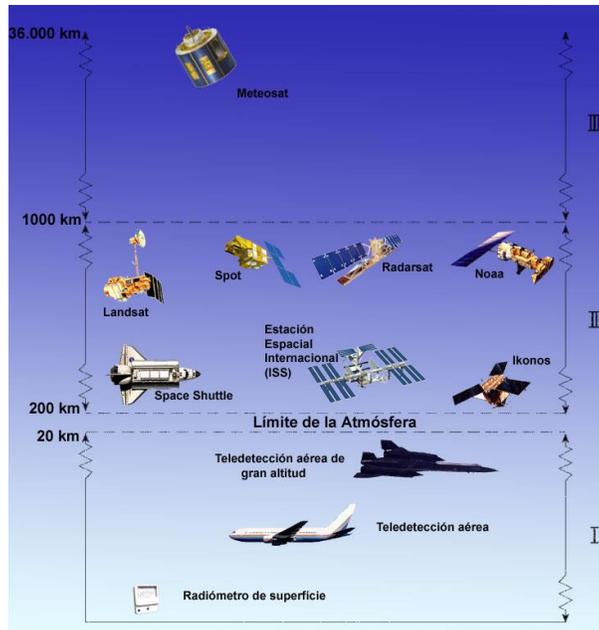


Figura 2.4.- Comparativa entre las alturas de vuelo de distintas plataformas de PR.

Usualmente los satélites usados en PR son de dos tipos, Geoestacionarios y de Orbita Polar (Butler, Mouchot, Barale, & LeBlanc, 1990).

2.4.1.1 Satélites Geoestacionarios

Se conoce como satélite geoestacionario (Figura 2.5) a aquellos que siguen una órbita geosincrónica (se mueven en la misma dirección de rotación de la tierra), se encuentran en alturas de hasta 36,000 km y sus velocidades son ajustadas para mantener una posición fija en el plano ecuatorial.

Las principales ventajas son:

- Tienen la más frecuente observación de región iluminada de la tierra desde un sistema orbital.
- Tienen la posibilidad de barrer el mismo punto de la tierra repetidamente.
- La más grande cobertura de área posible desde un sistema orbital.
- El uso efectivo de telecomunicaciones.

Las principales desventajas son:

- Las dificultades económicas y tecnológicas de poner el sistema en una órbita tan alto y que los sensores llevados a bordo tengan una adecuada resolución espacial.
- La pobre cobertura polar.

2.4.1.2 Satélites de Órbita Polar

Los satélites de órbita polar (Figura 2.5) pueden proveer observaciones de toda la superficie del planeta, se encuentra alrededor de los 900 km y pueden darle una vuelta al mundo aproximadamente cada 100 minutos.

Las principales ventajas son:

- Las facilidades económicas y tecnológicas de poner un sistema de órbita a baja altura y que los sensores a bordo puedan tener una alta resolución espacial.
- La posibilidad de darle servicio al sistema orbital con sistemas espaciales tripuladas.

Las principales desventajas son:

- La baja repetitividad de su cobertura en el orden de semanas.
- La pérdida de oportunidades de obtener imágenes debido a la cobertura de nubes, pequeña área de cobertura y baja repetitividad.

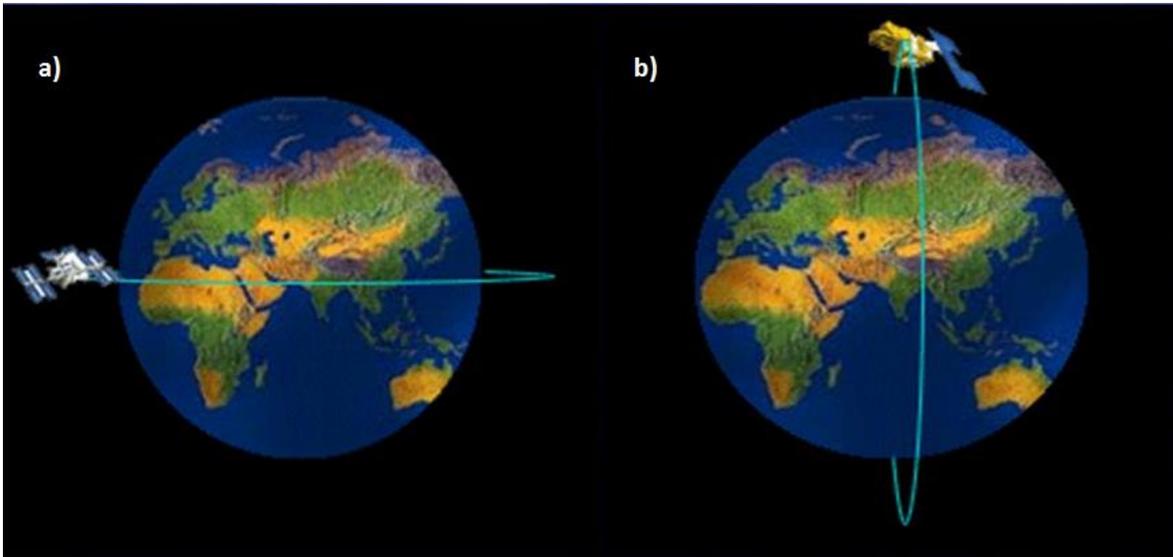


Figura 2.5.- Tipos de satélites usados en PR; a) Satélite Geoestacionario; b) Satélite de Órbita Polar.

2.4.2 Sensores Remotos

Un sensor remoto es el dispositivo capaz de detectar la Radiación Electromagnética (REM) emitida o reflejada por los objetos y convertirla en un valor físico que será almacenado y posteriormente procesado.

Dependiendo de la fuente de radiación utilizada por el sensor, es posible dividirlos en dos grupos: pasivos y activos.

2.4.2.1 Sensores Pasivos

Este tipo de sensores (Figura 2.6) detectan la REM emitida por los objetos y la reflejada proveniente de alguna fuente externa al instrumento, comúnmente la radiación solar.

Entre los sensores pasivos más representativos están:

- Radiómetros: Instrumento que mide la REM en alguna longitud de onda específica en las regiones espectrales visible, IR y de micro ondas.

- Escáneres: Son radiómetros que exploran la superficie mediante un barrido de la escena.
- Espectroradiómetro: Son radiómetros capaces de medir la REM en múltiples longitudes de onda.

2.4.2.2 Sensores Activos

Los sensores activos (Figura 2.6) no necesitan de una fuente externa, ellos proveen su propia REM para iluminar la escena que observan. Envían pulsos de energía desde el instrumento y reciben la radiación reflejada por los objetos.

Entre los sensores activos más representativos están:

- Radar: Instrumento con un emisor de REM y una antena direccional capaz de medir el tiempo de arribo de pulsos de radiación reflejados por los objetos con el objetivo de determinar su distancia.
- Radar de apertura sintética (SAR): Tipo de radar donde se procesa la información capturada de varios barridos para recrear un barrido virtual, como si el radar estuviera equipado con una antena mucho más grande.
- Radar interferométrico de apertura sintética (InSAR): Técnica que compara dos o más pasadas del SAR tomadas a diferentes tiempos sobre la misma región para generar cartas de deformación de superficie y elevaciones digitales.
- Lidar: Sensor óptico que utiliza un láser en las regiones UV, visible e IRC, para transmitir un pulso de luz y recibir la luz reflejada. La distancia con los objetos es determinada con el tiempo que le toma al sensor recibir la luz reflejada.

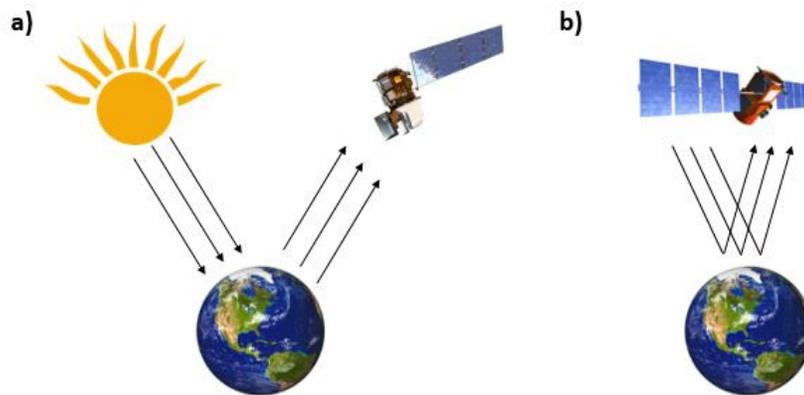


Figura 2.6.- Tipos de sensores en PR, a) Sensores Pasivos b) Sensores Activos.

2.5 Características de los Datos

En los apartados anteriores se habló que en la PR se mide la REM emanada de la tierra, estas mediciones son usadas para la construcción de imágenes digitales de la superficie que se encuentra debajo de nuestro sistema de adquisición de datos. Las imágenes digitales (Figura 2.7) son conjuntos de elementos ordenados en arreglos bidimensionales (matrices). Cada elemento de la matriz (pixel) está asociado a un número digital (ND) que expresa una medida discreta de la radiancia detectada por los sensores con unidades de Watt por metro cuadrado por estereorradián ($W \cdot m^{-2} \cdot sr^{-1}$).

Las imágenes obtenidas difieren en sus características dependiendo de la combinación de plataforma y sensor utilizados, a estas características se les conoce como resolución, y engloba a cuatro tipos: espacial, espectral, temporal y radiométrica, cada uno de ellas se explicará a continuación.

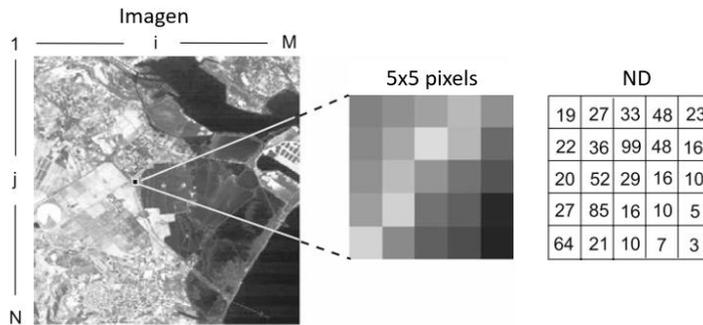


Figura 2.7.- Representación de una imagen digital, una muestra de la imagen de 5x5 pixeles y sus números digitales correspondientes.

2.5.1 Resolución Espacial

La resolución espacial representa la medida del objeto o superficie más pequeña que puede distinguir el sensor, en otras palabras, determina el tamaño del pixel en metros del terreno. A menores resoluciones espaciales, más objetos será posible distinguir (Figura 2.8).

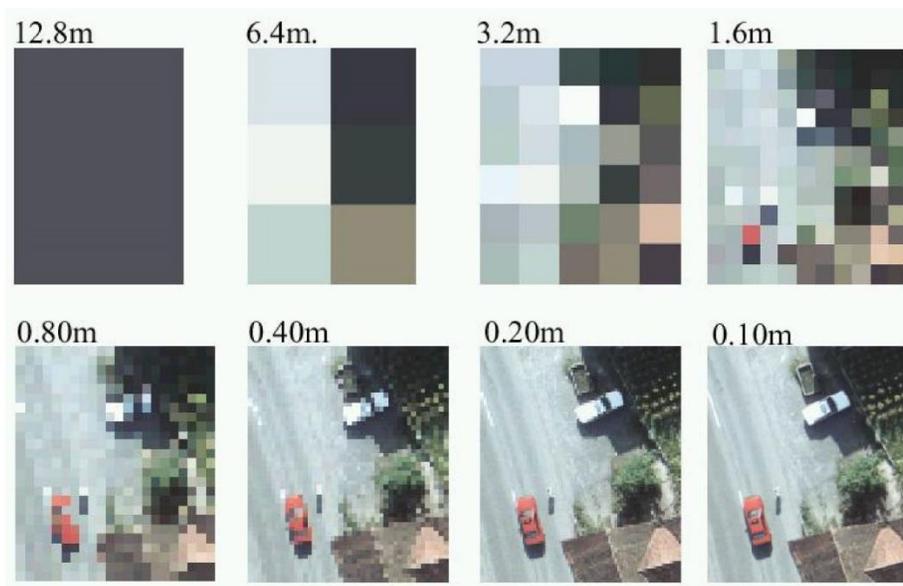


Figura 2.8.- Ejemplo de diferentes Resoluciones Espaciales para una misma imagen.

2.5.2 Resolución Espectral

Se refiere a la cantidad de bandas espectrales y al ancho de cada una de ellas que el sensor es capaz de captar. Cotidianamente nos referimos a sensores Multiespectrales a aquellos que tienen entre 3 y 10 bandas, e Hiperespectrales a los que tienen cientos. Algunos sensores cuentan con una banda pancromática que es simplemente una banda ancha que abarca varias longitudes de onda del espectro visible.

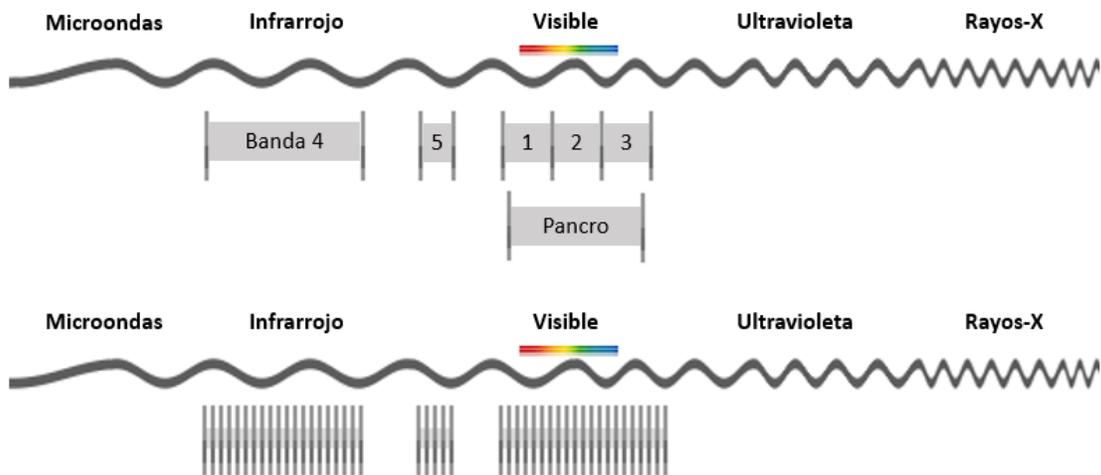


Figura 2.9.- Sensores dependiendo de su número de bandas: Multiespectrales (parte superior) e Hiperespectrales (parte inferior).

2.5.3 Resolución Temporal

La resolución temporal habla del tiempo necesario o frecuencia en la que el sensor pasa por un mismo punto de la superficie de la tierra. Su valor está determinado por la órbita y el diseño del satélite.

2.5.4 Resolución Radiométrica

También conocida como resolución dinámica, la resolución radiométrica se refiere al número de tonos de gris (entre el negro y el blanco) que puede tomar cada pixel de cada una de las bandas de la imagen, está determinado por el número de bits en los que la radiación registrada es dividida (Tabla 2.1).

Bits	Tonos	
1	2	
2	4	
3	8	
4	16	
5	32	
6	64	
7	128	
8	256	

Tabla 2.1.-Tonos de gris en la resolución radiométrica.

2.6 Aspectos Físicos

Como fundamento de la PR, la obtención de los datos se realiza sin estar en contacto con los objetos, en el caso de los sensores que se encuentran en el espacio, ni siquiera se cuenta con un medio en el cual se transporte la energía como es el caso del sonido en el aire, por dar un ejemplo. Existen en la naturaleza tres formas de transportar la energía: conducción, convección y radiación, de las tres la

radiación es la única que se transmite sin contacto material entre el emisor y el receptor, de ahí radica la importancia de la REM como transmisor de información en la PR.

2.6.1 Radiación Electromagnética

La radiación electromagnética es un fenómeno de transporte de energía que puede ser únicamente observada por su interacción con la materia. La REM está hecha de componentes eléctricos y magnéticos y es afectada por las propiedades eléctricas y magnéticas de la materia con la cual entra en contacto (Hugh D., Roger A., & A. Lewis, 2009). La naturaleza de la radiación electromagnética puede ser explicada a partir de dos modelos aparentemente contradictorios y en el fondo complementarios: el modelo de onda y el de partícula.

2.6.1.1 Modelo de Onda

Este modelo fue desarrollado principalmente por Huygens y Maxwell, y dice que la energía electromagnética se transmite de un lugar a otro siguiendo un modelo armónico y continuo, esta energía se produce como resultado de las oscilaciones entre dos campos de fuerzas ortogonales entre sí: el campo eléctrico y el magnético (Figura 2.10).

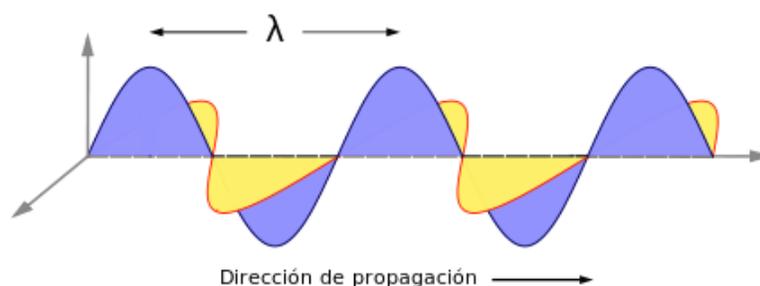


Figura 2.10.- Modelo de Onda de la energía electromagnética.

Al ser ondas las características de este flujo energético pueden describirse por dos elementos: longitud de onda y frecuencia.

- Longitud de onda (λ): es la distancia entre dos picos sucesivos de una onda.
- Frecuencia (f): se refiere al número de ciclos que pasan por un punto fijo en una unidad de tiempo, sus unidades son Hercios (Hz).

El producto de los términos anteriores es igual a la velocidad de la luz (c) como se muestra en la Ecuación 2.1, por lo tanto, si uno de los dos aumenta, el otro debe disminuir.

$$c = \lambda f = \frac{3 \times 10^8 \text{ m}}{\text{s}} \quad \text{Ec. 2.1}$$

2.6.1.2 Modelo de Partícula

En este modelo se asume que la energía viaja como un flujo de partículas llamadas fotones. Conociendo la frecuencia es posible calcular la cantidad de energía transportada por cada uno de los fotones Ecuación 2.2, donde "Q" es la energía radiante de un fotón en Joules (J), "f" es la frecuencia y "h" es la constante de Planck (6.626×10^{-34} J s).

$$Q = hf \quad \text{Ec. 2.2}$$

Los dos modelos anteriores se relacionan despejando la frecuencia de la ecuación de la onda y sustituyéndola en la ecuación de la partícula dando como resultado la Ecuación 2.3. Esta última implica que, a menores longitudes de onda, mayor será la energía transportada por la radiación, haciéndola más peligrosa.

$$Q = \frac{hc}{\lambda} \quad 2.3$$

2.6.2 Espectro Electromagnético

Al conjunto de longitudes de onda que puede adoptar la radiación se le conoce como espectro electromagnético Figura 2.11. Aunque se trata de una sucesión continua de valores de longitud de onda, se suelen agrupar en bandas donde la REM manifiesta comportamientos similares Tabla 2.2.

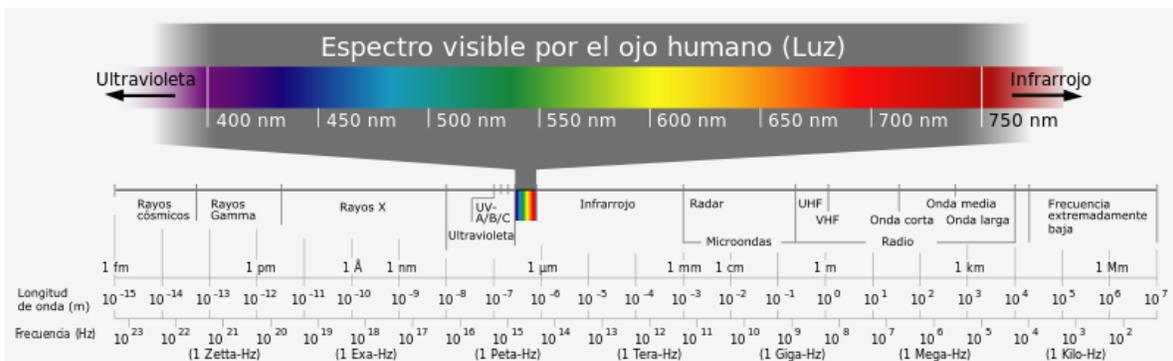


Figura 2.11.- Espectro electromagnético.

Cuando hablamos de radiación en una sola longitud de onda se le denomina radiación monocromática. Al intervalo que comprende las longitudes de onda de $0.4 \mu\text{m}$ a $10.0 \mu\text{m}$ se le conoce como la región óptica. Al intervalo de longitudes de onda de la radiación perceptible por el ojo humano se le llama región visible y aunque la sensibilidad del ojo humano a la REM varía de persona a persona, la región visible se define nominalmente como el intervalo de longitudes de onda entre $0.4 \mu\text{m}$ y $0.7 \mu\text{m}$. El sol genera radiación en un amplio intervalo, pero es de $0.32 \mu\text{m}$ a $3.5 \mu\text{m}$ a lo que se conoce como espectro solar.

Región	Rango de longitudes (λ)
Rayos X	[0.001-1.00] nm
Ultravioleta	[0.001-0.40] μm
Violeta	[0.40-0.45] μm
Azul	[0.45-0.51] μm
Verde	[0.51-0.56] μm
Amarillo	[0.56-0.59] μm
Anaranjado	[0.59-0.63] μm
Rojo	[0.63-0.70] μm
Visible	[0.40-0.70] μm
Infrarrojo Cercano	[0.70-1.1] μm
Infrarrojo medio	[1.1-15] μm
Infrarrojo lejano	[15-100.0] μm
Microondas	[0.10-100.0] cm

Tabla 2.2.- Regiones del Espectro Electromagnético

2.6.3 Términos y Unidades de Medida

En próximos apartados se emplearán términos comunes en la PR por lo que será conveniente explicarlos brevemente con el fin de tener un mejor entendimiento a la hora que estos se presenten.

- Energía Radiante (Q): Indica el total de la energía radiada en todas direcciones. Sus unidades son Joules (J).
- Emitancia (M): Total de energía radiada en todas direcciones desde una unidad de área por unidad de tiempo. Se mide en watts por metro cuadrado (W/m^2).
- Irradiancia (E): Total de la energía radiada (que incide) sobre una unidad de área y por unidad de tiempo (W/m^2).
- Radiancia (L): Total de la energía radiada por unidad de área y por ángulo solido de medida. Tiene gran importancia porque describe lo que mide el sensor. Sus unidades son watt por metro cuadrado y estéreo radian ($\text{W}/\text{m}^2\text{sr}$).

- Radiancia espectral (L_λ): Total de la energía radiada en una determinada longitud de onda por unidad de área y por ángulo sólido de medida.
- Emisividad (ϵ): Relación entre la Emitancia de una superficie (M), y la que ofrecería un emisor perfecto, denominado cuerpo negro, a la misma temperatura (M_n).
- Reflectancia (ρ): Parte de la irradiancia que refleja la superficie receptora, es un número adimensional comúnmente con valores entre 0 y 1.
- Absorbancia (α): Parte de la irradiancia que absorbe la superficie receptora, es un número adimensional comúnmente con valores entre 0 y 1.
- Transmitancia (τ): Parte de la irradiancia que transmite la superficie receptora, es un número adimensional comúnmente con valores entre 0 y 1.

2.6.4 Interacciones

Sabemos que la materia está constituida de sistemas atómicos-moleculares, los electrones de cada uno de estos se distribuyen, con base en restricciones de la mecánica cuántica, en niveles energéticos específicos para cada especie atómico-molecular. A temperatura ambiente los sistemas suelen encontrarse en sus niveles de energía más bajos, si a estos se les aporta energía suficiente (eléctrica, térmica, electromagnética etc.), pueden ser excitados a niveles energéticos superiores. Si consideramos un aporte de energía radiante (un haz de fotones cuyas energías cubren un amplio rango de valores), como la del sol, los objetos irradiados absorberán los fotones que posean la energía suficiente para producir la excitación de sus moléculas, es así que el haz transmitido o reflejado después de interactuar con los objetos, se verá disminuido en la cantidad de fotones de ciertas longitudes de onda Figura 2.12. A la forma de las curvas reflejadas se les conoce como firmas espectrales y son diferentes para todos los objetos.



Figura 2.12.- Modificación de la REM al interactuar con los objetos.

2.6.4.1 Interacciones Atmosféricas

Para que la REM llegue a los sensores ubicados en plataformas espaciales, esta sufre modificaciones al pasar a través de la atmosfera terrestre. La atmosfera se compone de gases y partículas que pueden afectar la intensidad y la distribución de la energía impidiendo en ocasiones la observación de características de la superficie.

Uno de los efectos atmosféricos que más se observa es la difusión (Figura 2.13). La difusión se define como la reflexión de la energía debido a partículas y dependiendo del tamaño de estas partículas se clasifican en:

- Difusión de Rayleigh: Este tipo de difusión es causado por moléculas y partículas considerablemente más pequeñas que las longitudes de onda de la radiación que afectan. Este tipo de difusión ocurre principalmente en las porciones ultravioleta y azul del espectro, y es una de las principales causas de la neblina en las imágenes.
- Difusión de Mie: Es causada por partículas que son aproximadamente del mismo tamaño que la longitud de onda que afectan. Ocurre desde el ultravioleta hasta el infrarrojo cercano.

- Difusión múltiple no selectiva: Ocurre cuando las partículas son varias veces más grandes que las longitudes de onda afectadas. Las gotas de agua en nubes o bancos de niebla, son ejemplos de esta difusión.



Figura 2.13.- Tipos de difusión dependiendo del tamaño de la partícula.

Otro de los efectos es la absorción atmosférica, que a diferencia de la difusión que redireccionan la REM, esta reduce el monto de energía en ciertas bandas de longitud de onda. A pesar de que en la región visible la atmosfera es transparente, existen regiones que son parcial o totalmente opacas y se conocen bandas de absorción Figura 2.14. Los sensores usados en la PR están diseñados para operar en las ventanas atmosféricas, regiones donde la REM no es absorbida.

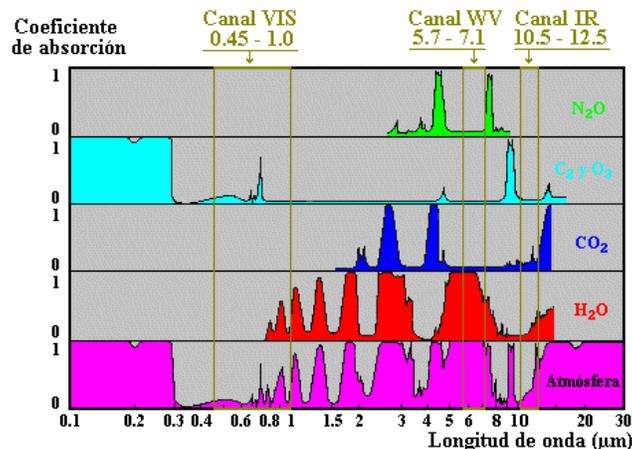


Figura 2.14.- Bandas de absorción y ventanas atmosféricas.

Capítulo 3: Clasificación Digital y sus Estrategias de Solución

En este capítulo se abordará el tema de la clasificación digital de imágenes en PR (en adelante únicamente clasificación), se mencionarán cuáles son las estrategias utilizadas y que modificaciones han tenido debido a las mejoras tecnológicas en los sistemas de adquisición de datos y en los equipos de cómputo utilizados para el procesamiento de la información.

3.1 Clasificación

La clasificación de imágenes representa la fase final en muchos procesos de la PR, en esta etapa los ND obtenidos con los sensores no tienen sentido en sí mismos, sino hasta que son interpretados y convertidos en categorías o clases que proporcionen un mejor conocimiento del territorio (Al-Awadhi & Hersi, 2006; Chen, Li, Liu, & Ai, 2013; Fraser, Olthof, Carrière, Deschamps, & Pouliot, 2012; S. Hu, Tong, Frazier, & Liu, 2015; Y. Hu & Jia, 2010).

La clasificación se define como el proceso de producir mapas temáticos a partir de imágenes (Richards, 2013). En otras palabras, tiene como objetivo la obtención de nuevas imágenes, en las que cada uno de los píxeles es definido con algún valor que sirva como identificador de la clase donde se haya incluido (Chuvieco, 1995) Figura 3.1.

Las clases pueden describir diferentes tipos de cubierta, o bien intervalos de una misma categoría de interés. Cuando la clasificación busca diferenciar entre cubiertas como podrían ser diferentes tipos de vegetación, suelos desnudos, construcciones, etc., hablamos de una clasificación de variables nominales o categóricas; por otro lado, si lo que diferencia son niveles de daño causado por un incendio hablamos de una clasificación de variables ordinales.

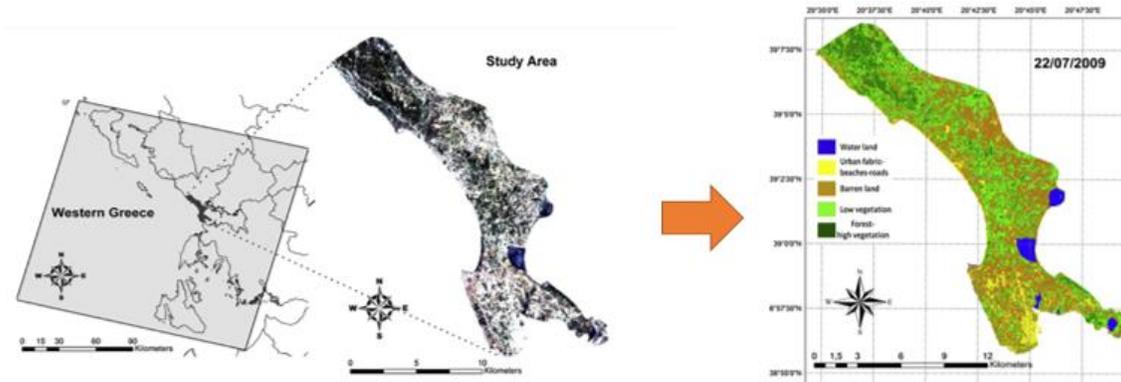


Figura 3.1.- Ejemplo de una clasificación de usos de suelos realizada en Preveza Grecia (Kolios & Stylios, 2013).

Los procesos realizados en la clasificación son muy similares a los que se emplean en la foto interpretación, en donde el usuario o interprete identifica cada una de las clases de acuerdo a patrones visuales como el tono, la forma, la disposición, textura, etc. Una vez determinas las clases, busca y delimita los mismos patrones sobre el resto de la fotografía, asignando de esta forma, superficies a cada una de ellas. Como último paso, se verifica sobre el terreno la interpretación realizada.

Con la ayuda de las computadoras, los procesos analógicos realizados en la fotointerpretación son digitalizados y se basan exclusivamente de los ND de la imagen. Del proceso de digitalización se reconocen tres fases, la primera es donde se definen las categorías y se conoce como fase de entrenamiento, en la segunda fase es la de asignación donde se distribuyen los pixeles de la imagen a cada una de las categorías, la última fase es la de comprobación y verificación de resultados.

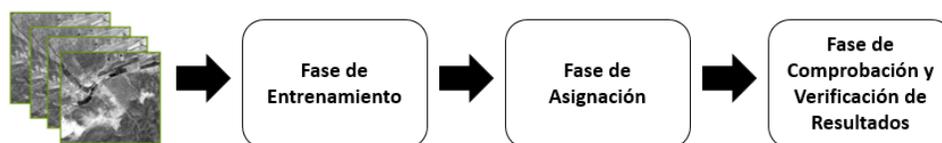


Figura 3.2.- Fases de la Clasificación de Imágenes.

3.1.1 Fase de Entrenamiento

Esta fase comienza con la definición de las categorías que se desean diferenciar en la imagen. Como está basada exclusivamente en los números digitales, se trata de obtener los rangos de valores numéricos que identifican a cada clase en todas las bandas que intervienen en la clasificación.

Esto se consigue con la correcta selección de muestras de píxeles que representen adecuadamente cada una de las clases. A partir de estas muestras, se obtiene el valor medio de ND de la clase y el rango en el que varía, para todas las bandas que intervienen en la clasificación. Como todos los procesos posteriores se basan de las muestras seleccionadas, es conveniente ser bastante cuidadosos y seleccionar adecuadamente, ya que los resultados de la clasificación están más influidos por la definición de las clases, que por el criterio por el cual estas son diferenciadas en la imagen.

Idealmente se debería encontrar una correspondencia entre una sola clase o cobertura y su correspondiente clase espectral obtenida con los ND, pero esto es poco común y se podría producir alguna de las siguientes situaciones (Figura 3.3):

- I. La cobertura puede expresarse en varias categorías espectrales.
- II. Dos o más coberturas comparten una misma clase espectral.
- III. Varias coberturas comparten varias clases espectrales.

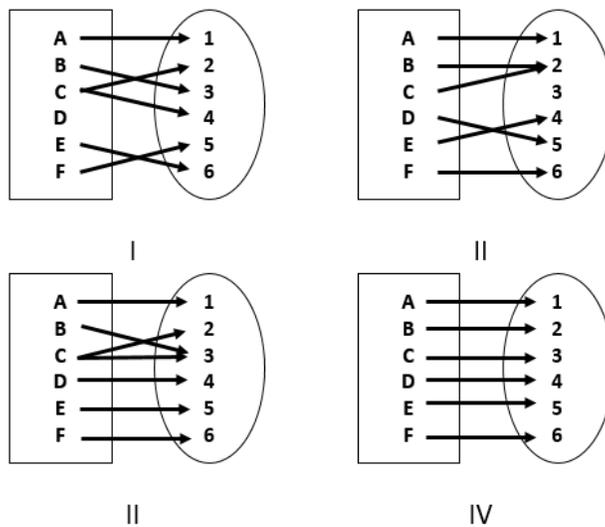


Figura 3.3.- Relación entre las clases o coberturas (lado izquierdo) y las clases espectrales (lado derecho): I) Una cobertura y varias clases espectrales, II) Varias coberturas y una clase espectral, III) Mezcla de ambas, IV) Caso ideal.

Los métodos de clasificación se pueden dividir en dos grupos principales, aquellos en los que es necesario tener un conocimiento previo del terreno, métodos supervisados (Basaeed, Bhaskar, & Al-Mualla, 2016; Fraser et al., 2012; Pope & Rees, 2014; R., 2010), y aquellos en los que se buscan automáticamente las clases agrupando los valores espectrales homogéneos de una imagen para que, en un paso posterior, el usuario relacione los grupos encontrados automáticamente con las categorías de interés, estos últimos conocidos como métodos no supervisados (Effat & Hassan, 2014; Mei, He, Wang, & Feng, 2014; Ottinger, Kuenzer, Liu, Wang, & Dech, 2013; Tahir, 2012).

3.1.1.1 Métodos Supervisados

Como se mencionó anteriormente, cuando se utilizan métodos supervisados es necesario tener un conocimiento previo del terreno del cual se seleccionarán las zonas o áreas representativas para cada una de las diferentes categorías.

Apoyándose de fotografías aéreas, mapas de la región de interés, herramientas de foto interpretación, y datos de campo, el analista obtiene grupos de píxeles de referencia, llamados de entrenamiento, a los que se les calculan diversos parámetros estadísticos que sirven para entrenar a la computadora para que pueda reconocer y clasificar el resto de los píxeles en las distintas categorías (Figura 3.4). Es necesario seleccionar varias áreas de entrenamiento para una misma clase para así poder reflejar la variabilidad de la zona de estudio.

Cuando el usuario ha seleccionado sus áreas de entrenamiento, es turno de la computadora de calcular para cada categoría la media, rango, desviación estándar, matrices de varianza y covariancia, etc., a partir de los ND de los píxeles incluidos en las áreas de entrenamiento de cada clase en todas las bandas espectrales.

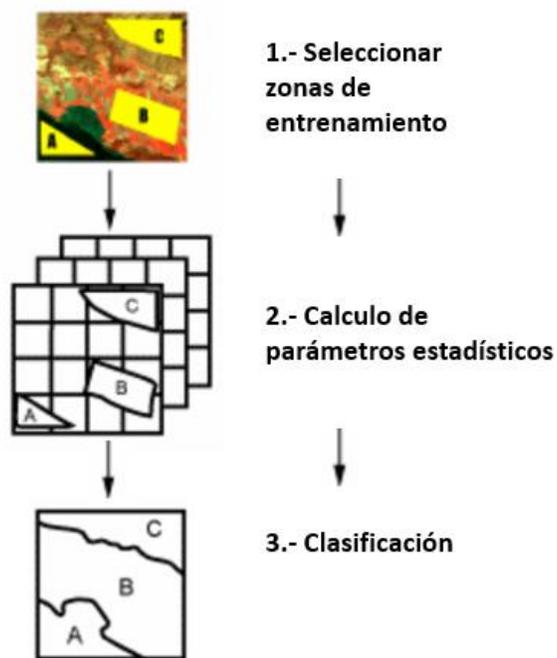


Figura 3.4.- Pasos de los Métodos Supervisados.

Entre los errores más comunes en la selección de las áreas de entrenamiento que conducen a resultados poco confiables, son la selección de áreas heterogéneas, es

decir, zonas donde se encuentren más de una categoría, ejemplo vegetación y suelo desnudo, ya que sus medidas estadísticas estarían en algún punto intermedio entre las distintas clases. Otro error en el que se incurre es la selección de zonas donde la cubierta sea muy homogénea ya que se perderían las variaciones reales de dicha clase.

3.1.1.2 Métodos No Supervisados

A diferencia de los métodos supervisados, en los métodos no supervisados no es necesario tener ningún conocimiento previo del área de estudio, se enfocan en definir las clases espectrales presentes en la imagen, y el usuario se ocupa de la interpretación de los resultados.

Estos métodos agrupan los píxeles que tienen comportamientos espectrales homogéneos, en conglomerados o clusters, todos los conglomerados deberían definir alguna clase de interés, pero no siempre es el caso, por lo que el usuario debe interpretar dichas categorías espectrales y asignarle alguna clase.

La forma de definir los conglomerados se base en la selección de tres parámetros:

- Variables que intervienen en el análisis: Bandas espectrales.
- Criterio para medir la similitud entre casos: Los casos son los píxeles y el criterio son las diferencias entre los valores de ND.
- Criterio para agrupar los casos similares: ND parecidos según distancias euclidianas, distancia media, distancia de Mahalanobis, etc.

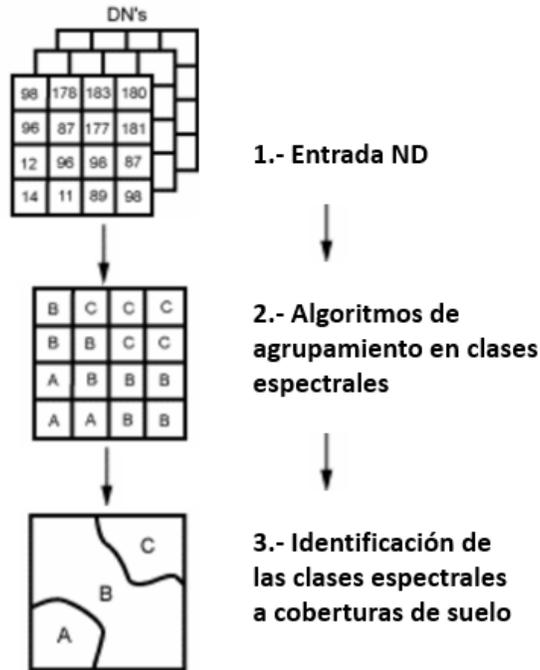


Figura 3.5.-Pasos de los Métodos No Supervisados.

3.1.2 Fase de Asignación

En esta fase se busca que cada pixel sea asignado estadísticamente a alguna clase, todos los algoritmos definen un área de dominio de cada clase entorno a su centro, si los ND del pixel se encuentran dentro de los límites establecidos para dicha clase, este será asignado a la misma.

Por ahora se dará una breve explicación de cinco de los métodos más usados para la clasificación, dos de ellos del tipo no estadístico: Clasificador por Mínima Distancia y Clasificador por Paralelepípedos; un método estadístico: Clasificación por Máxima Verosimilitud o Probabilidad; y por ultimo dos métodos que involucran inteligencia artificial: Clasificación con Árboles de Decisión y Clasificación con Redes Neuronales.

3.1.2.1 Clasificador por Mínima Distancia

Este algoritmo es el más sencillo para clasificar un pixel, los datos de entrenamiento se usan para determinar la media de las clases, y la clasificación se realiza adjudicando a cada pixel la clase con la media más cercana para todas las bandas que intervienen en el análisis.

La forma más empleada de medir las distancias es la distancia euclídea (Ec.3.1):

$$d_{ij}^{(k)} = \sqrt{\sum_{n=1}^{N_{bandas}} (X_{ij}^n - \bar{X}_{(k)}^n)^2} \quad \text{Ec. 3.1}$$

Donde $k=1,2,3,\dots,N_{clases}$; $n=1,2,3,\dots,N_{bandas}$; X_{ij}^n es el valor de cada pixel en la banda n ; $\bar{X}_{(k)}^n$ es el valor de la media aritmética de la clase k en la banda n . Los subíndices (i,j) corresponden al número de fila y número de columna de cada pixel de la imagen.

Cuando ya se conocen las distancias a cada clase, se toma la mínima de todas ellas y se asigna un valor representativo de la clase al pixel. El algoritmo es relativamente rápido y ofrece buenos resultados cuando no existe gran solapamiento entre las clases. Una ventaja es que no deja ningún pixel sin clasificar puesto que siempre habrá una clase más cercana (Figura 3.6).

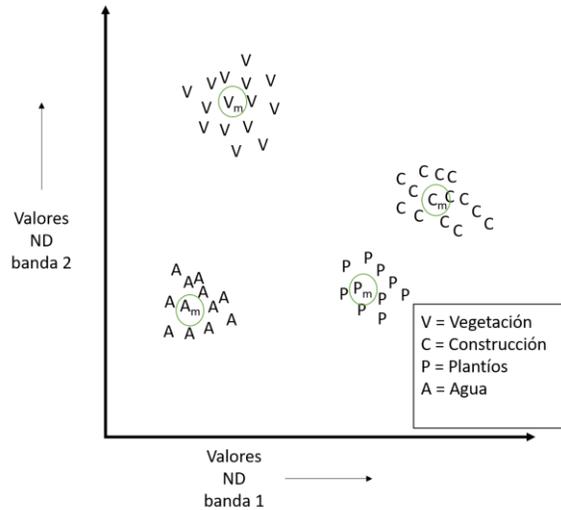


Figura 3.6.-Ejemplo de dos bandas del Algoritmo Mínima Distancia. Los subíndices “m” identifican el valor medio de la clase.

3.1.2.2 Clasificador por Paralelepípedos

La clasificación por paralelepípedos es también relativamente sencilla, en este algoritmo se definen cajas (paralelepípedos) con los valores máximos y mínimos de cada clase y de cada banda (Figura 3.7). Ahora la clasificación de los píxeles depende de si estos se ubican dentro de alguna de las cajas, si el píxel cae en una sola caja es asignado a la clase correspondiente. Sin embargo, si cae en más de una caja se clasifica como clase traslape, si no cae en ninguna clase se asigna a una clase nula.

En la Figura 3.7, se presentan los tres casos, con los puntos X, Y, Z que representan respectivamente a píxeles de la clase Traslape, Agua y Nula. El traslape de cajas se debe a altas correlaciones o covarianza entre bandas.

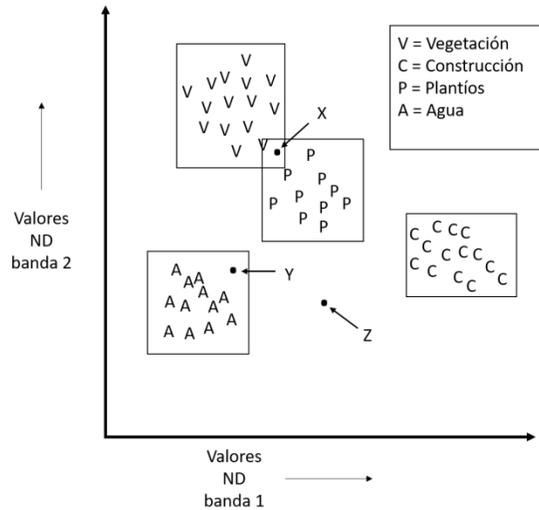


Figura 3.7.- Ejemplo de dos bandas del Algoritmo de Paralelepípedos.

Aunque el algoritmo de clasificación por paralelepípedos es bastante simple y rápido, existe muchos espacios donde no se encuentra ninguna clase y que conlleva a que los píxeles en esas regiones no sean clasificados, algo que no sucede en los algoritmos de mínima distancia o de máxima verosimilitud. El traslape de zonas y la falta de uso de probabilidades son también problemas a los que debe enfrentarse.

3.1.2.3 Clasificador de Máxima Verosimilitud

Este método considera que los ND de cada categoría se ajustan a distribuciones normales, los que permite describirlos por funciones de probabilidad a partir de su vector de medias y matriz de varianza y covarianza. Con lo anterior se puede calcular la probabilidad de que un determinado píxel pertenezca a una categoría, este cálculo se realiza para todas las categorías y el píxel se clasificará en la clase con el valor de probabilidad más alto.

Debido a las múltiples variables que hay que calcular este método representa el de mayor carga computacional, sin embargo, lo compensa un nivel mayor de fiabilidad de sus resultados ya que se ajusta fielmente a la distribución original de los datos.

La probabilidad de que un pixel pertenezca a cierta clase (en una banda) se calcula de la siguiente forma (Ec.3.2):

$$p(x/A) = \frac{1}{\sqrt{2\pi\sigma_A^2}} e^{-\frac{(ND_x - \overline{ND}_A)^2}{2\sigma_A^2}} \quad \text{Ec. 3.2}$$

Donde $p(x/A)$ es la probabilidad de que cierto pixel x pertenezca a la clase A ; ND_x es el valor del pixel; \overline{ND}_A es la media de la clase A ; σ_A^2 es la varianza de la clase A .

Para el caso de dos bandas, las categorías tienen forma elipsoidal, donde cada elipse representa líneas de isoprobabilidad (Figura 3.8). Con tres bandas se vuelve más complicada la representación gráfica y el trabajo con superficies; más de tres resulta imposible la representación y se debe extender la fórmula de probabilidad.

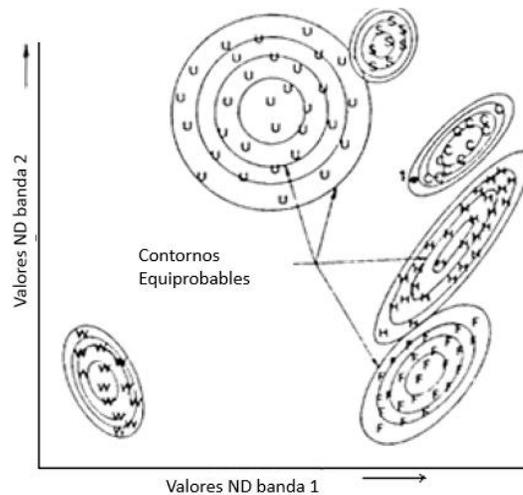


Figura 3.8.- Ejemplo de dos bandas del Algoritmo de Máxima Verosimilitud.

3.1.2.4 Clasificador Basado en Árboles de Decisión

Se realiza un análisis exhaustivo de las respuestas espectrales de las clases y del conjunto de datos disponibles. Consiste en hacerle preguntas a cada pixel cuya

respuesta positiva o negativa conducirá a otra pregunta y así sucesivamente hasta obtener la clase a la que pertenece (Figura 3.9).

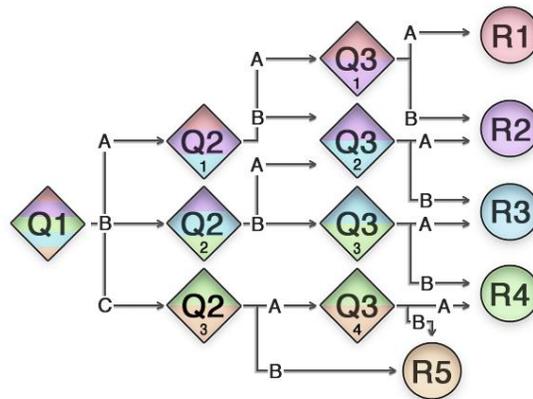


Figura 3.9.- Árbol de decisiones.

3.1.2.5 Clasificador Basado en Redes Neuronales

Este tipo de clasificación se basa en el uso de redes neuronales artificiales, una neurona artificial es un objeto lógico (software) que recibe diversas entradas, realiza una suma ponderada de las mismas y produce una salida a partir de la aplicación de una función umbral a la media ponderada. A la conexión de las salidas de unas neuronas, con la entrada de otras se le conoce como red neuronal.

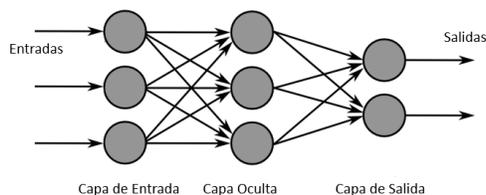


Figura 3.10.- Red Neuronal Back Propagation.

En las redes neuronales la información fluye en una única dirección, de la capa de entrada, pasando por la o las capas ocultas hacia la capa de salida. Cada neurona de cualquier capa está conectada (en la dirección de flujo) con todas las neuronas de la siguiente capa. Un ejemplo típico de red neuronal es la Back Propagation

Neural Network (BPNN), consta de una capa de entradas con tantas neuronas como variables de entrada se tengan, para el caso de la PR, se tiene una por cada banda; una o más capas ocultas que realizan la mayor parte del cálculo y por ultimo una capa de salida con tantas neuronas como posibles clases.

El proceso de clasificación con redes sigue tres fases:

- **Entrenamiento:** Se introducen pixeles cuya clase se conoce, y se compara la salida con la realidad. Con el resultado de la comparación se modifican los coeficientes de ponderación de todas las neuronas para obtener la respuesta adecuada, es decir valores de 1 en la clase correcta y ceros en las incorrectas.
- **Estabilización:** Al inicio del entrenamiento los factores de ponderación cambian rápidamente, pero conforme este se desarrolla los factores comienzan a estabilizarse, en el momento en que no se modifican más, finaliza la fase de entrenamiento.
- **Clasificación:** Se introducen pixeles cuya clase no se conoce y se adjudican a la clase con la respuesta más alta, no necesariamente 1.

3.2 Unidades Base Para la Clasificación

La clasificación ha ido evolucionando en conjunto con los sistemas de adquisición y de procesamiento de datos. En sus inicios, la mayoría de las técnicas de clasificación empleaban al pixel como unidad base, ejemplos de estas técnicas son las no supervisadas como k-medias e ISODATA, supervisadas como máxima verosimilitud, e híbridas como la semi-supervisada y fusión de aprendizaje supervisado y no supervisado (Ao et al., 2014; Im & Taylor, 2015), todas ellas con el objetivo de asignar una única clase de uso o cobertura de suelos a cada uno de los pixeles de la imagen.

Uno de los problemas a los que se enfrentan estas técnicas es cuando se aplica a regiones heterogéneas en donde un pixel puede no contener un único tipo de cobertura de suelo, en su lugar, una mezcla de varios tipos de usos de suelos está presente (Figura 3.11). La principal causa de este problema era la baja resolución espacial de los sensores de la época, lo que obligó al desarrollo de técnicas que usan como unidad base al sub-pixel. Como ejemplo de estas técnicas se encuentra la clasificación difusa y los análisis de mezclas espectrales.



Figura 3.11.- Ejemplo de una mezcla de diferentes coberturas de suelos en un mismo pixel.

Con el lanzamiento de sensores de alta resolución espacial, se desarrollaron métodos que emplean grupos de pixeles con características homogéneas llamados objetos y estos objetos son considerados como la unidad base (Liu, Li, Mao, Xu, & Huang, 2006; Zhang & Xie, 2012) (Figura 3.12).

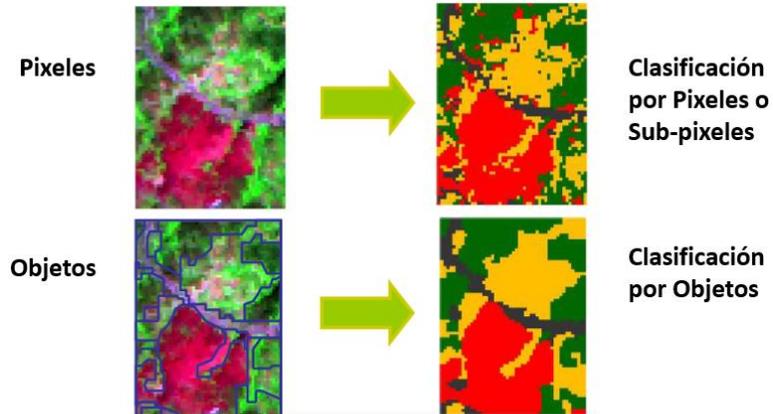


Figura 3.12.- Clasificación orientada a Píxeles y a Objetos.

En la siguiente tabla se presenta un resumen de las técnicas más comunes y utilizadas en clasificación digital de imágenes.

Técnicas de Clasificación	Características	Ejemplos
Basadas en Píxeles	Cada pixel se asume que es puro (una única firma espectral) y es clasificado como un único tipo de uso o cobertura de suelo.	-No Supervisados: k-means, ISODATA, SOM, hierarchical clustering. -Supervisados: Maximum likelihood, Minimum distance-to-means, Mahalanobis distance, Parallelepiped, k-nearest Neighbors.
Basada en Sub-Píxeles	Cada pixel es considerado como una mezcla de firmas espectrales.	Fuzzy classification, neural networks, regression modeling, regression tree analysis, spectral mixture analysis, fuzzy-spectral mixture analysis.
Basada en Objetos	Se basa en objetos (grupos de píxeles con características homogéneas) en lugar de píxeles individuales, estos son considerados como la unidad base.	Image segmentation and object-based image analysis techniques: E-cognition, ArcGIS Feature Analyst.

Tabla 3.1.-Resumen de las técnicas de clasificación (Li, 2014).

Capítulo 4: Desarrollo de la Propuesta IPICIM

En este capítulo se presenta el trabajo realizado consistente en la elaboración del módulo computacional IPICIM. Como se mencionó en el primer capítulo, el nombre IPICIM se forma de la unión de dos palabras “IPI” por el Instituto Potosino de Investigación Científica y Tecnológica, y “CIM” por Clasificador de Imágenes Multiespectrales.

El IPICIM se enfoca en ser una herramienta computacional simple y práctica para la limpieza, clasificación y procesamiento de imágenes ópticas multiespectrales, aunque no busca ser la primera en realizar estas acciones, si pretende ser la primera de origen mexicano y además satisfacer la necesidad del proyecto para la AEM-CONACYT. Algunos sistemas SIG que existen en el mercado de carácter comercial son: ArcGis, ENVI, EARDAS, PCI Geomatics entre otros, y del tipo gratuito se encuentran: BEAM, GRASS, EOLDAS, QGIS.

Para la elaboración del software se utilizó GUIDE (Figura 4.1) que es un entorno de programación visual disponible en MATLAB para realizar y ejecutar programas que necesiten un ingreso continuo de datos. MATLAB no es sólo un paquete de computación y graficación, sino una herramienta versátil y flexible, que permite a usuarios que cuentan con conocimientos básicos de programación producir gráficas e interfaces gráficas de usuario (GUIs) sofisticadas, y para programadores con más experiencia tiene la versatilidad de poder interactuar con otros lenguajes como C.

Matlab es uno de los lenguajes de programación más utilizados en el ámbito de la investigación debido a su gran capacidad para el procesamiento de cálculos matemáticos. Además de que cuenta con ToolBoxes (Cajas de herramientas) que contienen controles que facilitan aún más la programación de aplicaciones específicas en diferentes áreas del conocimiento como pueden ser: comunicaciones, control, procesamiento digital de señales, etc. Otra de las ventajas es que se pueden exportar el producto final como un archivo ejecutable “.exe” que funciona en cualquier computadora con sistema operativo Windows sin necesidad de tener el MATLAB instalado.

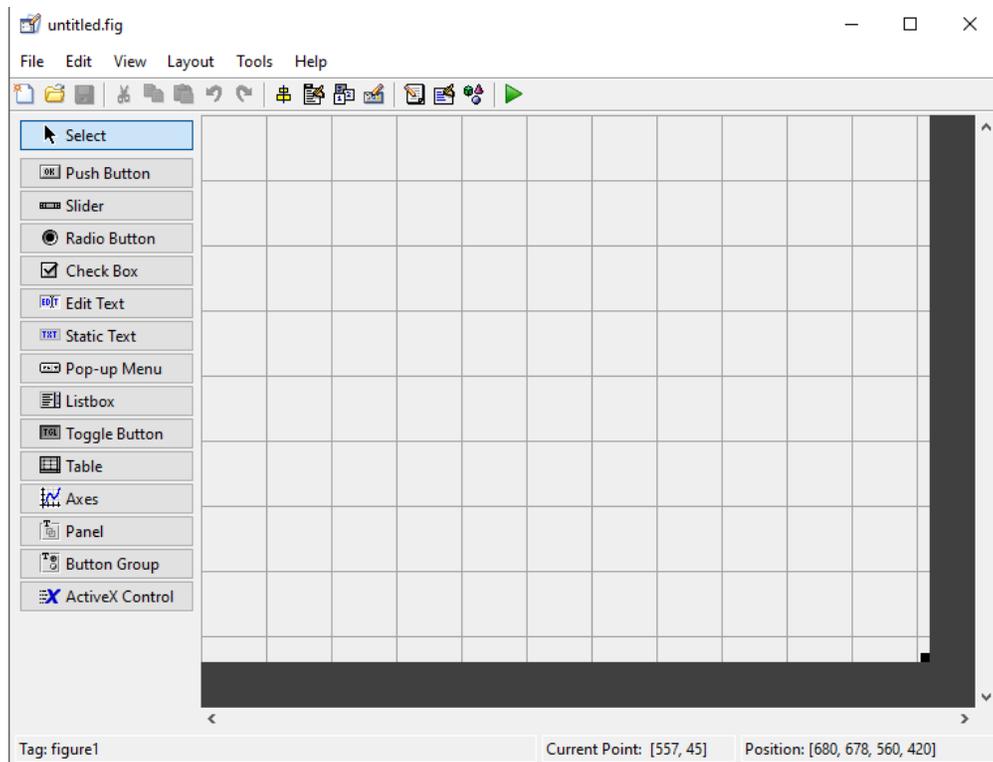


Figura 4.1.- GUIDE MATLAB.

En la aplicación el usuario podrá tomar una imagen óptica multispectral y con ayuda del IPICIM podrá obtener mapas temáticos de su interés, para que esto sea posible se agregaron algunas características divididas en tres categorías:

- Herramientas de visualización y edición: Visualización de las imágenes en escala de grises, combinación de tres bandas para la obtención de imágenes en color verdadero o falso color, recortes de la imagen original para analizar zonas determinadas.
- Herramientas de Pre-Procesamiento: Conversión de ND a Radiancia y Reflectancia para las bandas Reflectantes y Pancromática, así como conversión de ND a Radiancia y Temperatura de Brillo para la banda Térmica.

- Herramientas de Procesamiento: Cálculo de Índices, Calculadora de Bandas, Clasificación Supervisada, Clasificación No Supervisada y Clasificación con Redes Neuronales.

El IPICIM cuenta con dos entradas, una son las imágenes y la otra son las firmas espectrales de dos bases de datos, todo organizado como se muestra en la Figura 4.2. Cada una de las partes se explicará a detalle en los siguientes apartados de este mismo capítulo.

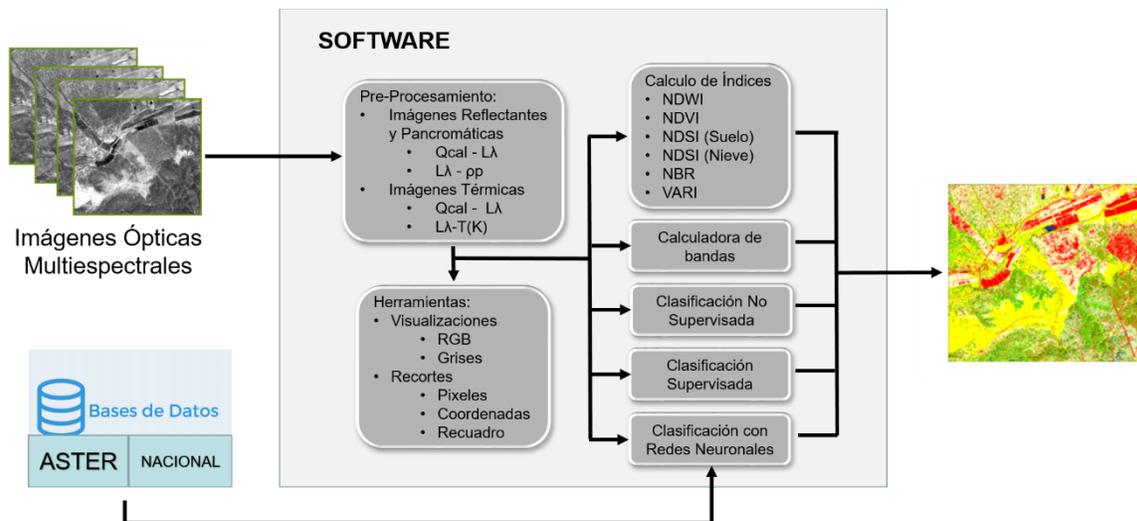


Figura 4.2.- Diagrama de bloques del software IPICIM.

La construcción del software se decidió que fuera del tipo modular, lo que significa que en cualquier momento se pueden agregar módulos para la realización de nuevas tareas o la actualización de los satélites compatibles, aunque el objetivo final es poder trabajar con cualquier sistema óptico multiespectrales, en esta primera etapa solo se encuentran habilitados los sistemas Landsat 1-8

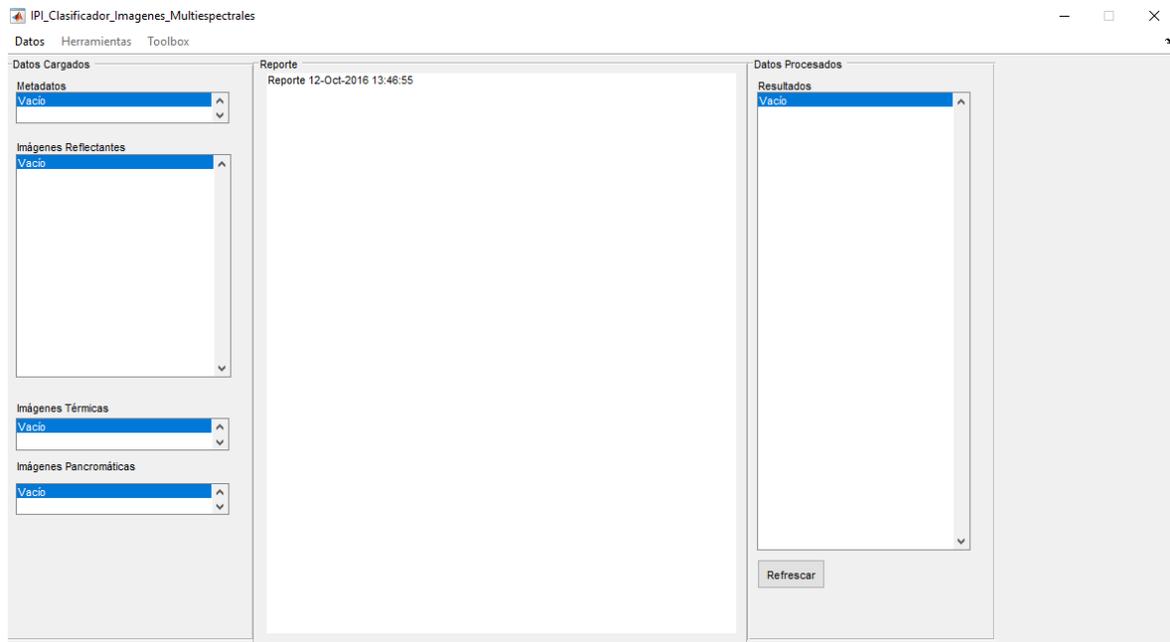


Figura 4.3.- Interface de usuario IPICIM.

4.1 Sistemas Ópticos Multiespectrales

El prototipo clasificador de imágenes IPICIM se enfoca en satisfacer las necesidades y requerimientos del proyecto titulado “*Servicio Federado de Cómputo en la Nube para el Almacenamiento, Procesamiento y Distribución de Imágenes Satelitales*” de la Agencia Espacial Mexicana (AEM). La AEM en su primera fase se encargará de proveer imágenes de “prueba” pertenecientes a los sistemas ópticos multiespectrales de la familia Landsat, por tal motivo el IPICIM como primer paso enfoca sus esfuerzos en la necesidad de obtener resultados a partir de las imágenes de la familia Landsat.

Landsat (Land= tierra y Sat= satélite) es el nombre del primer satélite de Estados Unidos enviado para el monitoreo de los recursos terrestres. En un inicio se llamó ETRS-1 (Earth Resources Technology Satellite) y posterior mente recibieron el nombre de Landsat.

Los sistemas Landsat proveen la mayor y más antigua base de datos de imágenes satelitales por lo que son una fuente invaluable para el monitoreo del cambio global

y la fuente principal de observaciones de la tierra a una resolución media (Chander, Markham, Helder, & Ali, 2009).

La familia Landsat está formada por 8 satélites cada uno de ellos dotado con diferentes sensores, siempre con la finalidad de captar mayor información de la superficie terrestre, implementando mejoras radiométricas, geométricas y espaciales. Basándose en las características de los sensores y plataformas se pueden clasificar en 4 grupos.

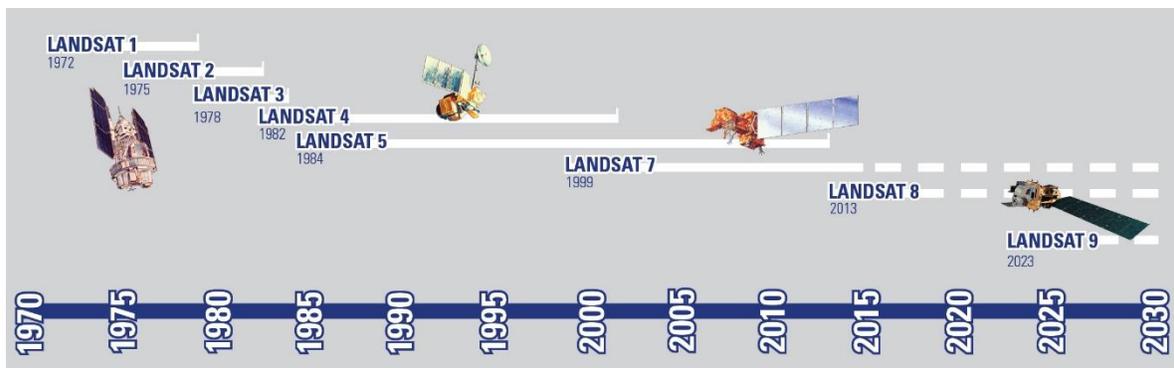


Figura 4.6.- Línea del tiempo de los satélites Landsat.

El primer grupo lo conforman los satélites Landsat del 1 al 3, todos ellos con el sensor Multispectral Scanner (MSS) y la cámara Return Beam Vidicon (RBV). El sensor MSS proveía de imágenes con una resolución espacial procesada de 60 m en cuatro bandas nombradas: MSS-4, MSS-5, MSS-6 y MSS-7 para el azul, verde, rojo e infrarrojo cercano respectivamente. Para que la nomenclatura de bandas sea consistente con las generaciones de sensores que prosiguieron, nos referiremos a las bandas MSS 4-7 como Bandas 1-4 respectivamente.

El segundo grupo lo conforman los satélites Landsat 4 y 5 que además de contar con el sensor MSS, cargaban con el sensor Thematic Mapper (TM) que mejoraban en resultados espaciales, espectrales, radiométricos y geométricos. El sensor TM ofrecía 6 bandas reflectantes con resolución espacial (RE) de 30 m y una banda térmica con una RE de 120 m.

El tercer grupo consiste en los satélites Landsat 6 y 7 que contaban con los sensores Enhanced Thematic Mapper (ETM) y Enhanced Thematic Mapper Plus (ETM+) respectivamente. El sensor ETM no estuvo en operación por un lanzamiento fallido mientras que el sensor ETM+ cuenta con 6 bandas reflectantes con RE de 30 m, 60 m para la banda térmica y una banda pancromática con RE de 15 m.

Por ultimo tenemos al Landsat 8, que carga dos sensores, el primero denominado Operational Land Imager (OLI) y el segundo el sensor térmico infrarrojo Thermal Infrared Sensor (TIRS). En conjunto proveen de 9 bandas reflectantes con RE de 30 m, 2 bandas térmicas con RE de 100 m y una banda pancromática con RE de 15m.

La administración de los recursos provenientes de los satélites Landsat corre a cuenta de la NASA en tanto que la producción y comercialización de las imágenes depende del Servicio Geológico de los estados Unidos (USGS). En la actualidad solo los satélites Landsat 7 y 8 se encuentran activos. La Tabla 4.1 presenta un resumen de algunas de las características de los Landsat.

SATÉLITE	SENSORES	PERIODO OPERACIONAL		ALTITUD (KM)	R. ESPACIAL (M)	R. TEMPORAL (DÍAS)
		INICIO	FIN			
LANDSAT 1	MSS y RBV	23/07/72	06/01/78	920	60	18
LANDSAT 2	MSS y RBV	22/01/75	25/02/82	920	60	18
LANDSAT 3	MSS y RBV	05/03/78	31/03/83	920	60	18
LANDSAT 4	MSS y TM	16/07/82	30/06/2001	705	60/30/120	16
LANDSAT 5	MSS y TM	16/07/82	30/06/2001	705	60/30/120	16
LANDSAT 6	ETM	05/10/93	05/10/93	N/A	N/A	N/A
LANDSAT 7	ETM+	15/04/99	En operación	705	30/15	16
LANDSAT 8	OLI y TIRS	11/02/13	En operación	705	30/15	16

Tabla 4.1.- Resumen de características para los sistemas Landsat.

El sistema clasificador que en esta tesis se propone tiene la capacidad de procesar las imágenes provenientes de cualquier sensor de las plataformas Landsat, efectuar procesos de corrección radiométrica y atmosférica; así como técnicas de filtración de ruidos y la obtención de mapas temáticos otorgando a las imágenes crudas un valor agregado. Para la obtención de los mapas temáticos es necesario realizar procesos de clasificación, recordando el capítulo 3 de este trabajo, el criterio de clasificación puede estar basado en el cálculo de mínima distancia, máxima verosimilitud, árboles de decisión, redes neuronales, entre otros. Para dar cumplimiento a uno de los requerimientos del proyecto AEM-CONACYT, que consta de procesamiento computacional en tiempo cercano al tiempo real, decidimos implementar un clasificador basado en redes neuronales con capacidad de “autoaprendizaje”, lo que nos llevó a pensar en la utilización de bases digitales de las firmas espectrales de diversos materiales como secuencias de entrenamiento.

4.2 Bases Digitales de Firmas Espectrales

Cuando hablamos de bases de datos, nos referimos a colecciones de firmas espectrales, el IPICIM está dotado de dos de ellas. la primera se trata de la Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER) de la NASA, y la segunda es una base de datos nacional (BDN) generada en el IPICYT.

4.2.1 Base de Datos ASTER

Esta base es una compilación de 2400 espectros de materiales naturales y creados por el hombre (Baldrige, Hook, Grove, & Rivera, 2009), incluye datos de tres laboratorios el Johns Hopkins University (JHU), Jet Propulsion Laboratory (JPL) y United States Geological Survey (USGS).

Puesto que los espectros provienen de diferentes laboratorios y al mismo tiempo se habían obtenido con diferentes equipos, se realizó una inspección a cada uno de ellos para saber si estos cumplían o no con los parámetros necesarios para incluirlos

en la base de datos del IPICIM. Después de filtrar los espectros se descartaron aquellos que no cubrían la región visible, solo se dejaron aquellos que cumplían con el rango de longitudes de onda que va de 0.42 μm a 14 μm , es decir, cubren el espectro visible, y los infrarrojos cercano y medio donde la mayoría de los sensores ópticos realizan sus mediciones. Al final, la base de datos ASTER aporta al IPICIM 1343 espectros divididos en 6 tipos: Suelos, Escarcha-Nieve-Hielo, Vegetación, Roca, Creado por el hombre y Minerales. En el Anexo 1 se presenta una tabla con el nombre, tipo, clase y subclase de todos los espectros que integran la base de datos del IPICIM.

4.2.2 Base de Datos Nacional

La BDN se realizó en colaboración con el Laboratorio de Nuevos Materiales Nano y Catálisis Heterogénea del IPICYT en el equipo Cary 5000 UV-Vis-NIR Spectrophotometer (Figura 4.7).



Figura 4.7.- Cary 5000 UV-Vis-NIR Spectrophotometer.

El Cary 5000 UV-Vis-NIR es un espectrofotómetro Ultravioleta-Visible-Infrarrojo Cercano de alto rendimiento con excelente rendimiento fotométrico en el rango de 175 a 3300 nm. Algunas de sus características son las siguientes:

- Medir la absorbancia más allá de 8,0 unidades con la atenuación del haz de referencia.
- Medir 175-3300 nm usando un detector de PbSmart NIR para la gama extendida fotométrica.
- El software WinUV - software modular con el análisis del poder y la transferencia mejorada e informar capacidad de exportación.
- Versátil conjunto de accesorios para la investigación de materiales incluyendo reflectancia espectral y difusa.
- Anchuras de hendidura variables (hasta 0,01 nm) para un control óptimo sobre la resolución de datos.
- Compartimento de muestra grande con mecanismo de bloqueo para los cambios rápidos y posicionamiento para obtener resultados reproducibles.
- El rendimiento máximo de la luz utilizando la óptica de acoplamiento Schwarzschild una mayor precisión en los niveles de baja transmisión.
- El mínimo ruido y la luz difusa utilizando una pieza de fundición de aluminio flotante y doble monocromador Littrow.
- Extendido rango dinámico mediante la atenuación del haz de referencia más en línea con la absorbancia de la muestra.
- Bombeo de nitrógeno - purga separado en los compartimentos de la muestra y monocromador.

En este equipo se midió la reflectancia de las muestras siguiendo la metodología presentada en la Figura 4.8. Se fijó el mismo rango de longitudes de onda al de la base de datos ASTER para tener la misma información comparable. En esta primera etapa de caracterización, la BDN cuenta con 40 muestras divididas en 3 tipos: vegetación invasiva, rocas y agua contaminada.

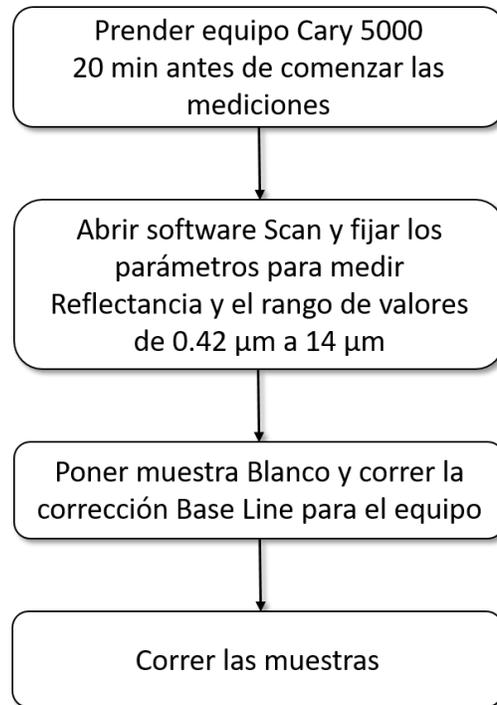


Figura 4.8.-Diagrama de flujo para la obtención de firmas espectrales en el equipo Cary 5000.

4.3 Prototipo Computacional

En este apartado se detalla cada una de los módulos de visualización, edición, pre-procesamiento y procesamiento que el software IPICIM es capaz de realizar, se identificarán cuáles son las entradas y procesos que se realizan en cada una de ellas y porque son de utilidad en este tipo de softwares.

4.3.1 Módulo Visualización y Edición

Las herramientas de visualización y edición son aquellas que permiten analizar de forma superficial las características y objetos que se encuentran en las imágenes con las que se esté trabajando. Permiten el realce de ciertos atributos mediante la combinación de bandas para generar escenas en color verdadero, en falso color y

también permiten trabajar sobre alguna sección específica de la imagen y no cargar de procesos innecesarios a los equipos de cómputo.

4.3.1.1 Visualización Escala de Grises

La escala de grises es la forma más común para la visualización de una sola de las bandas de la imagen. Independientemente del satélite, o proceso realizado sobre la imagen, la visualización en escala de grises muestra al valor más pequeño en color negro, al valor más grande color blanco al mismo tiempo asigna a todos los valores intermedios tonalidades de gris (Figura 4.9).

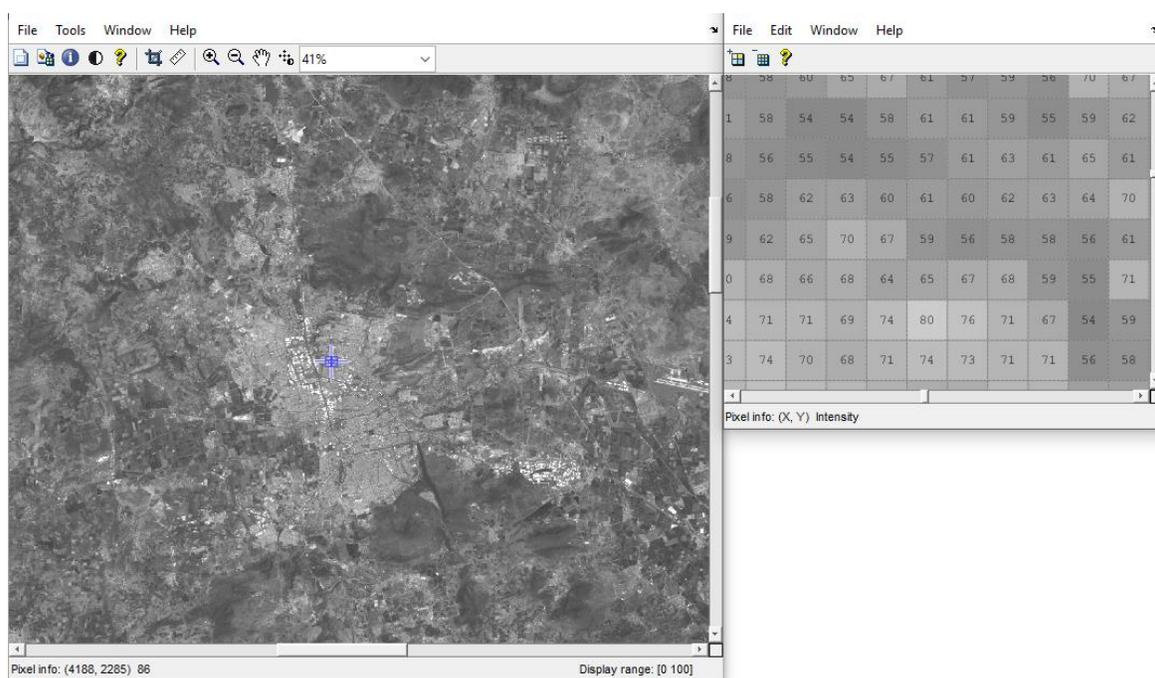


Figura 4.9.- Visualización en escala de grises IPICIM.

Como se puede observar en la Figura 4.9 esta herramienta cuenta entre otras cosas con botones para desplazarnos en la imagen, realizar acercamientos y alejamientos. En la parte inferior de la ventana izquierda se presenta información del pixel sobre el que se encuentra posicionado el puntero, (pixel x, pixel y) junto

con el valor del mismo, y también se muestra el rango de valores entre el negro y el blanco usados en esa visualización. La ventana derecha muestra un conjunto de píxeles junto con sus valores, estos píxeles son seleccionados con un recuadro en la imagen principal (indicador azul).

4.3.1.2 Visualización RGB

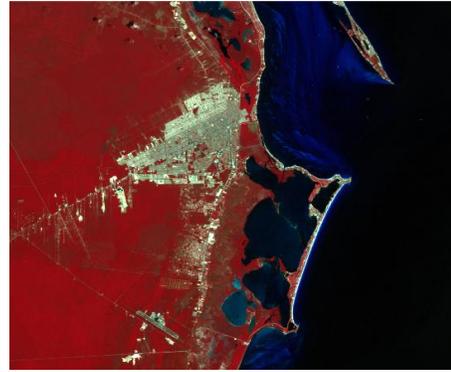
La visualización en RGB por las siglas en inglés Red, Green, Blue, es la composición del color en términos de la intensidad de los colores primarios de la luz. RGB es un modelo de color basado en la síntesis aditiva, con el que es posible representar un color mediante la mezcla por adición de los tres colores de luz primarios.

La visualización en RGB es de gran utilidad porque nos permite (sin la necesidad de realizar ningún proceso) mediante la combinación de bandas resaltar características que a simple vista no se puede observar, algunos ejemplos se presentan en la Tabla 4.2.

Bandas (R, G, B)	Aplicación	Ejemplo
(3,2,1)	<p>Esta combinación utiliza las bandas de la porción visible del espectro electromagnético, es la que más se aproxima a los colores reales. Es ideal para enfatizar información del agua: turbidez, corrientes y sedimentos en suspensión. En esta imagen las tonalidades de color azul claro representan aguas costeras y con sedimentos en suspensión, mientras que los tonos azul oscuro representan aguas más profundas y con pocos sedimentos en suspensión. Las áreas urbanas aparecen en tonalidades marrón claro y la vegetación en tonos verdes.</p>	

(4,3,2)

La banda 4 (infrarrojo cercano) es útil para identificar los límites entre el suelo y el agua. Los cuerpos de agua con sedimentos en suspensión aparecen en tonos azul claro y los que poseen pocos sedimentos en suspensión en azul oscuro. Las áreas urbanas y el suelo expuesto aparecen en tonos azul. También la banda 4 es sensible a la clorofila, permitiendo que se observen variaciones de la vegetación, que aparecen en tonos rojos.



(5,4,3)

Esta combinación con dos bandas en la región del infrarrojo muestra una mayor diferenciación entre el suelo y el agua. La vegetación se muestra en diversas tonalidades de verde y rosa, que varían en función del tipo y de las condiciones de ubicación. Las áreas urbanas y el suelo expuesto se presentan en tonos rosados. El agua, independiente de la cantidad de sedimentos en suspensión, aparece en negro.



(4,5,3)

Esta combinación, con una banda en la región visible y dos en la del infrarrojo, utiliza las mismas bandas de la combinación 3, 4 y 5; sin embargo, asociadas a colores diferentes, permitiendo una diferenciación de la vegetación en tonos marrones, verdes y amarillos. Las áreas urbanas y los suelos expuestos aparecen en tonos de azul claro, mientras que las áreas inundadas y el agua aparecen en tonos azul oscuros.

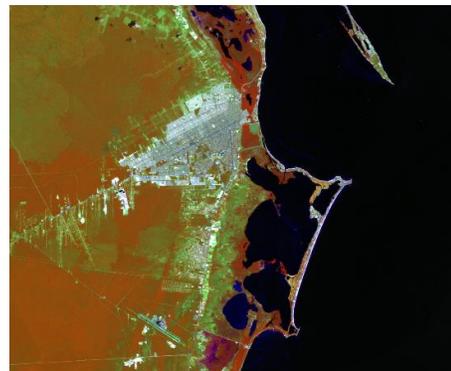


Tabla 4.2.- Combinaciones de bandas en Color Verdadero y Falso Color.

Al igual que en la visualización en escala de grises, la herramienta para la visualización RGB cuenta con botones para desplazarnos en la imagen, realizar acercamientos y alejamientos, permite seleccionar entre las bandas precargadas de la imagen, aquella que se desee colocar en la banda roja, verde y azul

respectivamente (Figura 4.10). En la parte inferior de la ventana central se presenta información del pixel sobre el que se encuentra posicionado el puntero, (pixel x, pixel y) junto con el valor del mismo [valor R, valor G, valor B].

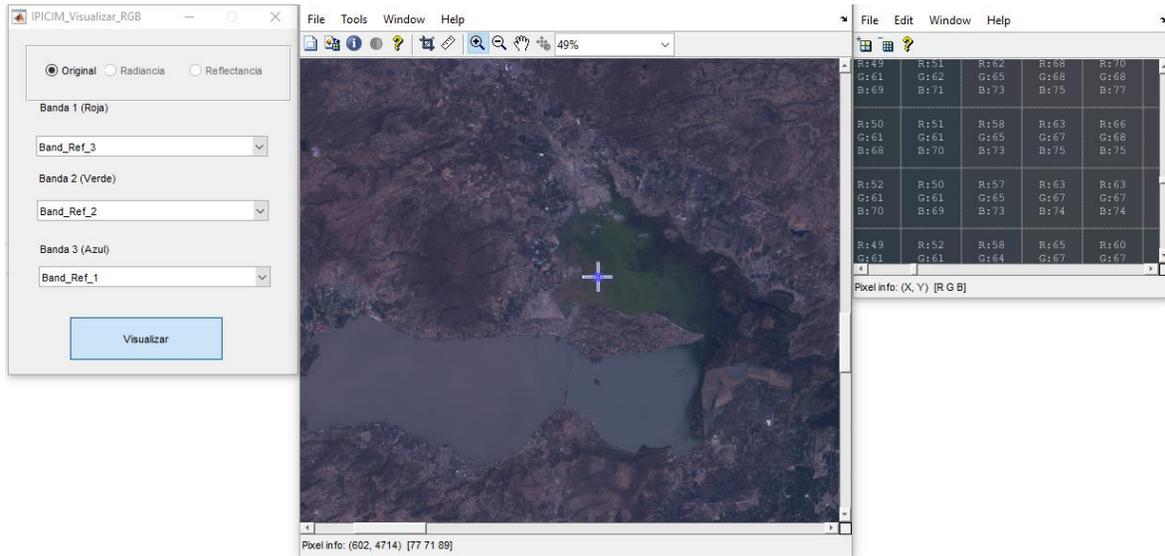


Figura 4.10.- Interface Visualización RGB IPICIM.

4.3.1.3 Recortar Imagen

Crear un recorte de una imagen ayuda a delimitar el área sobre la cual se desea trabajar porque se tiene algún interés sobre ella, esto a su vez libera carga de procesamiento computacional al disminuir la cantidad de píxeles con la que se trabajará. En el diseño se implementaron tres formas seleccionables de recorte: por píxeles, por coordenadas o por recuadro.



Figura 4.11.- Interface de Recorte IPICIM.

Las opciones por píxeles y por recuadro funcionan de forma similar, el usuario introduce dos valores de píxeles o coordenadas entre los cuales quiere su recorte, “x₁” y “x₂” inicial y final respectivamente para el eje horizontal, de forma similar introduce “y₁” y “y₂” para el eje vertical. Los valores del usuario son comparados con los valores iniciales “X₁”, “X₂”, “Y₁”, “Y₂” obtenidos del archivo con los metadatos. Si se cumple que los valores introducidos por el usuario se encuentran entre los valores del metadato, se realiza el recorte y se modifican los valores del metadato a los valores del usuario como se muestra en el diagrama de flujo de la Figura 4.12.

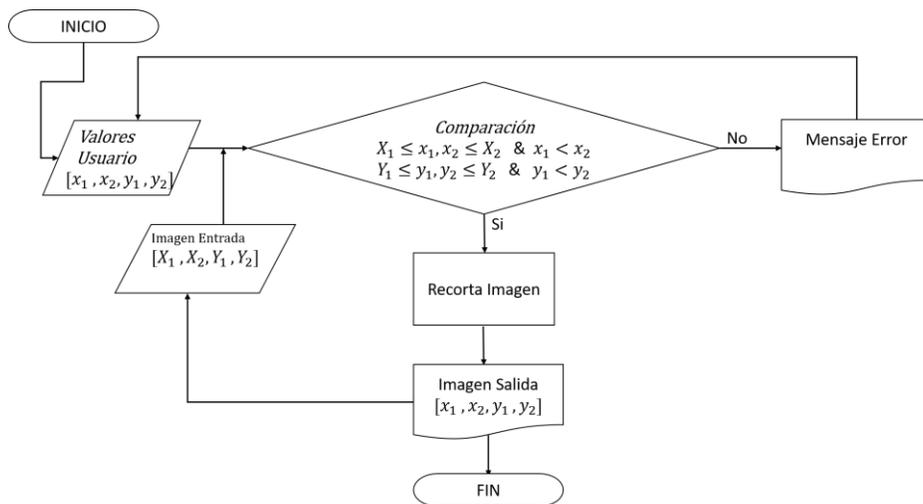


Figura 4.12.- Diagrama de flujo para recortar imagen por Coordenadas o Píxeles.

Para el recorte por recuadro es más sencillo, el usuario dibuja un recuadro en el interior de la imagen del cual se obtienen los píxeles iniciales y finales para los ejes horizontal y vertical, y se realiza el recorte (Figura 4.13).

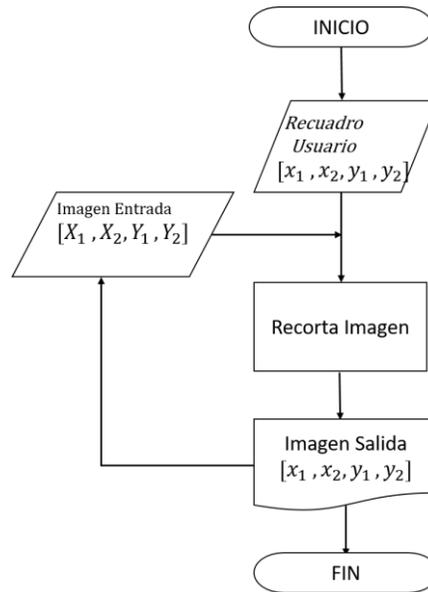


Figura 4.13.- Diagrama de flujo para recortar imagen por Recuadro.

4.3.2 Módulo de Pre-Procesamiento

Para interpretar y cuantificar correctamente los cambios que ocurren en la Tierra usando imágenes adquiridas por satélites, es necesario convertir los números digitales (ND) presentes en las imágenes ópticas, en unidades con un significado físico como la radiancia y la reflectancia.

La etapa del pre-procesamiento trata justamente de esto, corregir las alteraciones causadas por la interferencia de la atmosfera conocidas como correcciones radiométricas: cálculo de radiancia y cálculo de reflectancia.

Cuando se realiza una evaluación subjetiva sobre una sola imagen, las correcciones radiométricas se aplican, aunque no son tan relevantes como cuando el objetivo es extraer información cuantitativa (concentración de clorofila, profundidad batimétrica,

etc.) o cuando se comparan dos imágenes, para estos casos deben de ser removidos los efectos atmosféricos.

4.3.2.1 Conversión de ND a Radiancia (Q_{cal} a L_{λ})

El cálculo de la radiancia es un paso fundamental para recuperar la energía recibida por los sensores y una forma útil de unificar y comparar las mediciones realizadas por diferentes satélites y en diferentes tiempos. Para esta tarea el IPICIM utiliza dos procedimientos diferentes según el tipo de sensor presente en el satélite, para los sistemas Landsat 1-7 se usaron las ecuaciones y parámetros presentados por (Chander et al., 2009); en el caso del Landsat 8 se siguió el procedimiento presentado en (Ariza Alexander, 2013).

El primer procedimiento que se presenta es el realizado para los satélites Landsat 1-7 donde se utilizó la siguiente ecuación:

$$L_{\lambda} = \left(\frac{LMAX_{\lambda} - LMIN_{\lambda}}{Q_{calmax} - Q_{calmin}} \right) (Q_{cal} - Q_{calmin}) + LMIN_{\lambda} \quad \text{Ec. 4.1}$$

o

$$L_{\lambda} = G_{rescale} \times Q_{cal} + B_{rescale} \quad \text{Ec. 4.2}$$

Donde:

$$G_{rescale} = \frac{LMAX_{\lambda} - LMIN_{\lambda}}{Q_{calmax} - Q_{calmin}} \quad \text{Ec. 4.3}$$

$$B_{rescale} = LMIN_{\lambda} - \left(\frac{LMAX_{\lambda} - LMIN_{\lambda}}{Q_{calmax} - Q_{calmin}} \right) Q_{calmin} \quad \text{Ec. 4.4}$$

Donde:

L_{λ} = Radiancia Espectral en el techo de la atmosfera (TOA) [$W / (m^2 sr \mu m)$]

Q_{cal} = Valor estándar calibrado y cuantificado de pixel [ND]

Q_{calmin} =Mínimo valor estándar calibrado y cuantificado de pixel correspondiente a $L_{MIN_{\lambda}}$
[ND]

Q_{calmax} =Máximo valor estándar calibrado y cuantificado del pixel correspondiente a $L_{MAX_{\lambda}}$
[ND]

$L_{MIN_{\lambda}}$ =Radiancia espectral escalada a Q_{calmin} [$W / (m^2 sr \mu m)$]

$L_{MAX_{\lambda}}$ =Radiancia espectral escalada a Q_{calmax} [$W / (m^2 sr \mu m)$]

$G_{rescale}$ =Factor de ganancia re-escalado específico para cada banda [$(W / (m^2 sr \mu m)) /$
ND]

$B_{rescale}$ =Factor de sesgo re-escalado específico para cada banda [$W / (m^2 sr \mu m)$]

Los valores de $L_{MIN_{\lambda}}$, $L_{MAX_{\lambda}}$, $G_{rescale}$ y $B_{rescale}$ correspondientes para todos los sensores se encuentran en el Anexo 2: Tablas para Cálculo de Radiancia y Reflectancia.

Dos aspectos a considerar en el momento de seleccionar estos parámetros son: el software de procesamiento utilizado en la generación de las imágenes Landsat 4 y el estado de ganancia en el que fueron adquiridas las imágenes de Landsat 7.

A mediados del 2009 el procesamiento de las imágenes del Landsat 4 sufrió la transición del software National Land Archive Production System (NLAPS) hacia el Level 1 Product Generation System (LPGS) debido al cambio, algunos factores como $L_{MIN_{\lambda}}$, $L_{MAX_{\lambda}}$, $G_{rescale}$ y $B_{rescale}$ se modificaron. El sistema utilizado lo aparece como "PROCESSING_SOFTWARE_VERSION" en el archivo metadatos.

Para el sensor ETM+ de sistema Landsat 7 las imágenes se adquieren en dos estados, con ganancia alta (high gain) o baja (low gain), el objetivo para el uso de las dos ganancias es la de maximizar la resolución radiométrica sin saturar los detectores. La información sobre el estado de ganancia utilizado para cada banda se encuentra en el archivo metadatos como "GAIN_BAND_x". La x representa el número de la banda.

El segundo procedimiento es el requerido por los sistemas Landsat 8 donde la radiancia se calcula con la siguiente ecuación:

$$L_{\lambda} = M_L \times Q_{cal} + A_L \quad \text{Ec. 4.5}$$

Donde:

L_{λ} = Radiancia Espectral [$W / (m^2 \text{ sr } \mu\text{m})$]

Q_{cal} = Valor estándar calibrado y cuantificado de pixel [ND]

M_L = Factor multiplicativo de escalado específico obtenido del metadato "RADIANCE_MULT_BAND_X"

A_L = Factor aditivo de escalado específico obtenido del metadato "RADIANCE_ADD_BAND_X"

La Figura 4.14 presenta el diagrama de flujo para el cálculo de radiancia para cualquier sistema Landsat.

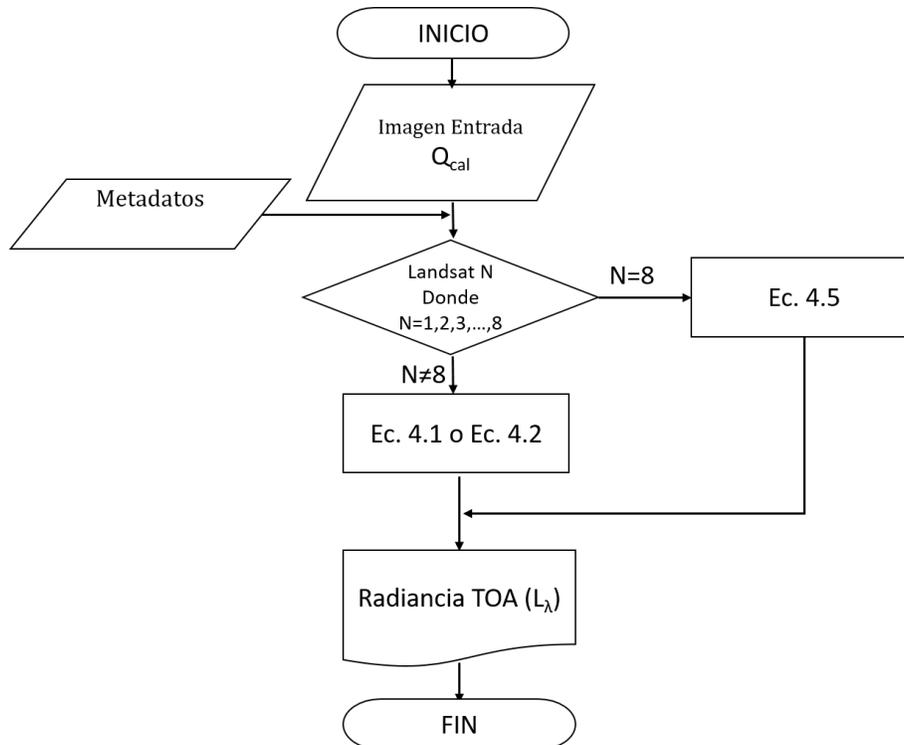


Figura 4.14.- Diagrama de flujo para conversión de Q_{cal} a L_{λ} .

4.3.2.2 Conversión de Radiancia a Reflectancia (L_λ a ρ_λ)

La conversión de la radiancia TOA a Reflectancia ayuda a reducir la variabilidad de una escena a otra. Chander et al. (2009) plantean tres ventajas de usar la reflectancia al comparar imágenes de diferentes sensores:

- Remueve el efecto coseno de diferentes ángulos cenitales solares debidos a la diferencia en tiempos entre la adquisición de las imágenes.
- Compensa los diferentes valores de la irradiación exoatmosférica solar derivados de las diferencias de banda espectral.
- Corrige la variación de la distancia entre el sol y la tierra entre el tiempo de adquisición de datos.

Del mismo modo que la radiancia se usaron los procedimientos de (Chander et al., 2009) y (Ariza Alexander, 2013) para el cálculo de reflectancia de los sistemas Landsat1-7 y Landsat 8 respectivamente.

La ecuación utilizada para los sistemas Landsat 1-7 es:

$$\rho_\lambda = \frac{\pi \times L_\lambda \times d^2}{ESUN_\lambda \times \cos \theta_s} \quad \text{Ec. 4.6}$$

Donde:

ρ_λ = Reflectancia Planetaria TOA [sin unidades]

L_λ = Radiancia Espectral [$W / (m^2 \text{ sr } \mu\text{m})$]

d = Distancia Tierra-Sol [Unidades Astronómicas] ($d=1-0.01674 \times \cos(0.9856 \times (\text{JD}-4))$), JD es el día juliano (Mapper et al., 1990).

$ESUN_\lambda$ =Irradiancia exoatmosférica solar media [$W / (m^2 \mu\text{m})$]

θ_s = Ángulo cenital solar [grados].

Los valores de $ESUN_\lambda$ correspondientes para todos los sensores se encuentran en el Anexo 2: Tablas para Cálculo de Radiancia y Reflectancia. El ángulo cenital solar se encuentra en el metadato como "SUN_ELEVATION" y el día juliano se obtiene calculándolo a partir de la fecha de adquisición de la imagen "DATE_ACQUIRED".

Mientras que para los sistemas Landsat 8 se emplea:

$$\rho_{\lambda} = M_{\rho} \times Q_{cal} + A_{\rho} \quad \text{Ec. 4.7}$$

Donde:

ρ_{λ} = Reflectancia Planetaria TOA [sin unidades]

Q_{cal} = Valor estándar calibrado y cuantificado de pixel [ND]

M_{ρ} = Factor multiplicativo de escalado específico obtenido del metadato "REFLECTANCE_MULT_BAND_x"

A_{ρ} = Factor aditivo de escalado específico obtenido del metadato "REFLECTANCE_ADD_BAND_x".

A continuación, se presenta el diagrama de flujo (Figura 4.15) para la obtención de la reflectancia de todos los sistemas Landsat.

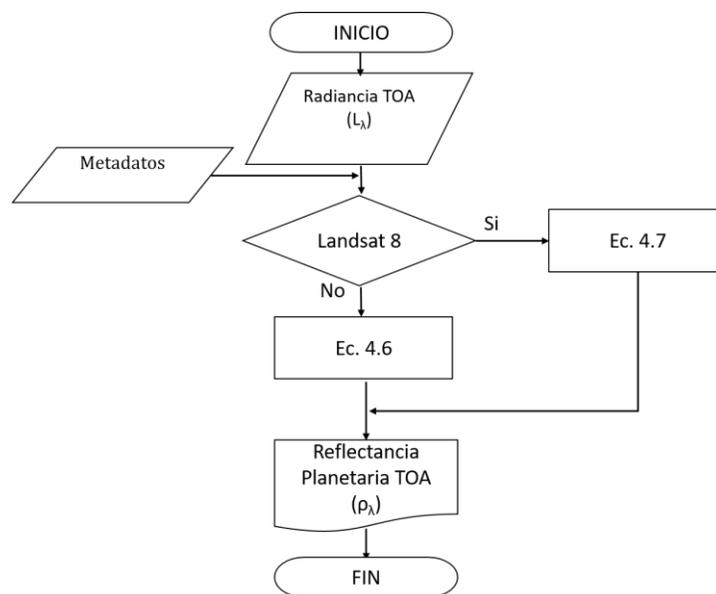


Figura 4.15.- Diagrama de flujo para conversión de L_{λ} a ρ_{λ} .

4.3.3 Módulo de Procesamiento

Una vez que se han removido efectos negativos como los atmosféricos, las imágenes de radiancia y reflectancia se convierten en el punto de partida para el procesamiento de las imágenes, esto proporcionara una mayor certeza y comparabilidad temporal de los resultados obtenidos en cualquier cálculo posterior, como lo son los cálculos de índices y clasificación de las imágenes entre muchos otros.

4.3.3.1 Cálculo de Temperatura de Brillo (L_λ a T)

La obtención de la temperatura de brillo es posible gracias a las bandas térmicas incorporadas en los sensores TM, ETM+ y TIRS. Estas bandas pueden ser convertidas de radiancia espectral a temperatura de brillo en grados Kelvin (K). La temperatura de brillo asume que la superficie de la tierra es un cuerpo negro (emisividad espectral es 1), e incluye efectos atmosféricos.

La ecuación para el cálculo de la temperatura usa dos constantes de calibración $K1$ y $K2$ de los cuales se tienen sus valores en la Tabla 4.3, la ecuación utilizada es la siguiente (Ariza Alexander, 2013; Chander et al., 2009):

$$T = \frac{K2}{\ln\left(\frac{K1}{L_\lambda} + 1\right)} \quad \text{Ec. 4.8}$$

Donde:

- T = Temperatura de brillo [K]
- $K1$ = Constante de calibración 1 [W / (m² sr μm)]
- $K2$ = Constante de calibración 2 [K]
- L_λ = Radiancia Espectral [W / (m² sr μm)]
- ln= Logaritmo natural

SATÉLITE, SENSOR Y BANDA	K1 [W / (M ² SR μM)]	K2 [K]
LANDSAT 4, TM, BANDA 6	671.62	1284.30
LANDSAT 5, TM, BANDA 6	607.76	1260.56
LANDSAT 7, ETM+, BANDAS 6L Y 6H	666.09	1282.71
LANDSAT 8, TIRS, BANDAS 10 Y 11	Metadatos "K1_CONSTANT_BAND_X"	Metadatos "K2_CONSTANT_BAND_X"

Tabla 4.3.- Constantes para el cálculo de temperatura de brillo (L_λ a T).

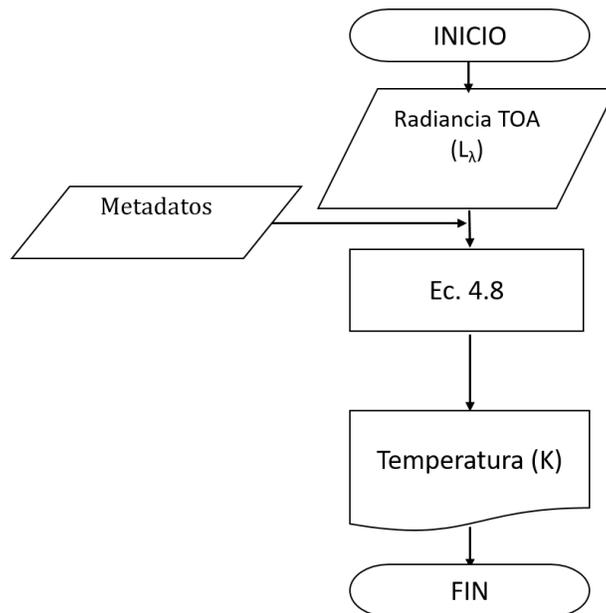


Figura 4.16.- Diagrama de flujo para conversión de L_λ a T .

4.3.3.2 Cálculo de Índices

Los índices son medidas cuantitativas producto de varias bandas espectrales sumadas, restadas multiplicadas o divididas de una forma diseñada para que indique la cantidad o vigor de la vegetación dentro de un pixel. Normalmente se usan como indicadores para monitoreo de crecimiento y productividad o como dispositivos de mapeo que ayudan en la clasificación de imágenes.

El software IPICIM cuenta con algunos índices pre-programados (Tabla 4.4), pero no se encuentra limitado a solo esos, con la herramienta **Calculadora de Bandas** es posible la obtención de cualquier otro índice que sea de nuestro interés. Puesto que no todos los sistemas Landsat cuentan con la misma cantidad de bandas, no es posible realizar el cálculo de todos los índices para todos los casos, es por esto que se sigue el siguiente diagrama de flujo (Figura 4.17).

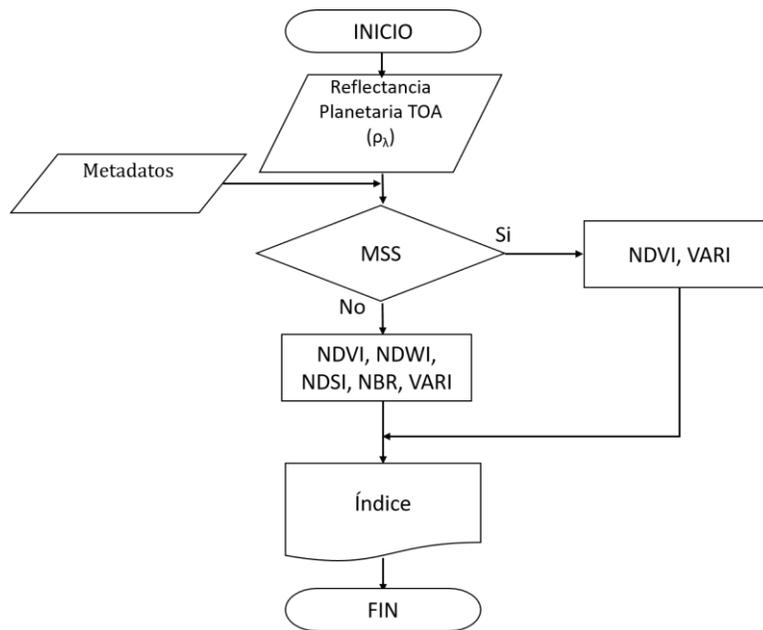


Figura 4.17.- Diagrama de flujo para el cálculo de Índices.

Nombre	Formula	Descripción y Características
NDVI (Normalized Difference Vegetation Index)	$NDVI_{L1-L7} = \frac{\rho_4 - \rho_3}{\rho_4 + \rho_3}$	Es un índice usado para estimar la cantidad, calidad y desarrollo de la vegetación. Su escala va de -1 a +1, valores menores de cero representan ausencia de vegetación (Alzate, 2012). Se sabe que está fuertemente relacionado con el contenido de agua de la planta. Por lo tanto, es un muy buen indicador de estrés hídrico de la planta, su rango va de -1 a +1 a valores más grandes, corresponden mayores contenidos de agua en la vegetación (JRC, 2011).
	$NDVI_{L8} = \frac{\rho_5 - \rho_4}{\rho_5 + \rho_4}$	
NDWI (Normalized Difference Water Index)	$NDWI_{L1-L7} = \frac{\rho_4 - \rho_5}{\rho_4 + \rho_5}$	Se usa para diferenciar nieve de nubes, debido a la alta absorción de ambas, valores menores de 0.4 se refieren a nieve (Hall & Riggs, 2011; Xiao, Shen, & Qin, 2001)
	$NDWI_{L8} = \frac{\rho_5 - \rho_6}{\rho_5 + \rho_6}$	
NDSI (Normalized Difference SnowIndex)	$NDSI_{L1-L7} = \frac{\rho_2 - \rho_5}{\rho_2 + \rho_5}$	Separa las áreas quemadas de aquellas que no están quemadas ,el rango que se obtiene va de -500 a +1300 (escalado por 10 ³), una escala de severidad de daños indica que: -100 a +99 son áreas no quemadas +100 a +269 Severidad baja +270 a +439 Severidad moderada (Escuin, Navarro, & Fernández, 2008; USGS, 2004)
	$NDSI_{L8} = \frac{\rho_2 - \rho_6}{\rho_2 + \rho_6}$	
NBR (Normalized Burn Ratio)	$NBR_{L1-L7} = \frac{\rho_4 - \rho_7}{\rho_4 + \rho_7}$	Estima la radiación fotosintéticamente activa absorbida en cubiertas vegetales en presencia de material de fondo no fotosintética como el suelo y la hojarasca (Gitelson et al., 2002).
	$NBR_{L8} = \frac{\rho_5 - \rho_8}{\rho_5 + \rho_8}$	
VARI (Visible Atmospherically Resistant Index)	$VARI_{L1-L7} = \frac{\rho_2 - \rho_3}{\rho_2 + \rho_3 - \rho_1}$	
	$VARI_{L8} = \frac{\rho_3 - \rho_4}{\rho_3 + \rho_4 - \rho_2}$	

Tabla 4.4.- Índices implementados en IPIICIM (ρ_x =Reflectancia Banda x).

4.3.3.3 Calculadora de Bandas

La calculadora de bandas es una de las herramientas más útiles implementadas al IPICIM, permite realizar operaciones básicas como sumas, restas, multiplicación y división de bandas, así como operaciones no tan básicas como exponentes, raíces y logaritmos entre otras.

La forma en la que funciona, es poniendo a disposición del usuario todas las bandas precargadas disponibles (reflectantes, térmicas o pancromáticas), también aquellas a las que se les haya realizado algún pre-procesamiento o procesamiento (Radiancia, Reflectancia, Índices, clasificaciones, etc.). Con todas las bandas a su disposición se le pide al usuario que genere una función con ellas la que será efectuada sobre cada pixel, el resultado se almacena en una nueva banda que también estará disponible para seguir realizando operaciones (Figura 4.18). La calculadora de bandas es una gran herramienta para la reproducción de resultados realizados por otros investigadores y también para el desarrollo de nuevas metodologías e índices.

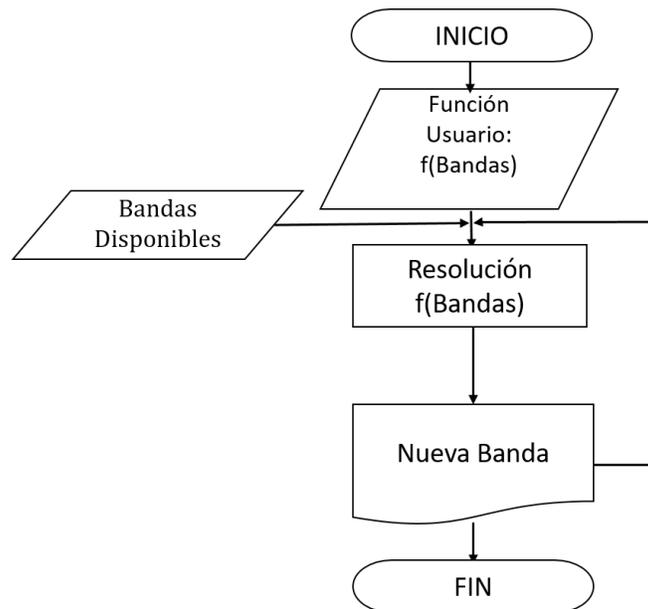


Figura 4.18.-Diagrama de flujo para la resolución de funciones en la calculadora de bandas del IPICIM.

4.3.3.4 Clasificador No Supervisado

Como se mencionó en el capítulo tres, los métodos de clasificación no supervisados, no requieren de ningún conocimiento previo de la zona a clasificar. El usuario indica el número de clases “z_T” que desea obtener de la escena y el clasificador le entrega un mapa en el que cada uno de los pixeles es clasificado hacia una única clase dependiendo de su firma espectral.

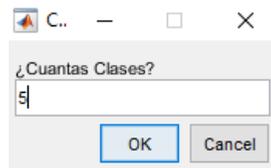


Figura 4.19.- Interface IPICIM para la Clasificación No Supervisada.

El procedimiento empleado para esta clasificación comienza convirtiendo la imagen de “B” bandas reflectantes (dependiendo del sistema de adquisición “B” podría variar de 4 hasta 8 bandas) a una única banda mediante la siguiente ecuación:

$$\bar{\rho}_{i,j} = \frac{1}{B} \sum_{b=1}^B \rho_{i,j}^b \quad \text{Ec. 4.9}$$

Donde $\bar{\rho}_{i,j}$ es la reflectancia promedio en el pixel “i,j”; los sub índices “i,j” representan el número de filas y columnas respectivamente, mientras que “b” indica la banda reflectante.

El segundo paso consiste en calcular el espesor espectral “Δx” para cada una de las clases y el rango de valores que la representará, cada una de las clases incorporará “1/ z_T” de la información espectral presente en la imagen:

$$\Delta x = \frac{\bar{\rho}_{MAX} - \bar{\rho}_{MIN}}{z_T} \quad \text{Ec. 4.10}$$

Las clases se obtienen de la siguiente forma:

$$\bar{\rho}_{MIN} + (1 - z) * \Delta x < Clase z \leq \bar{\rho}_{MIN} + z * \Delta x \quad \text{Ec. 4.11}$$

Donde “ $\bar{\rho}_{MAX}$ ” y “ $\bar{\rho}_{MIN}$ ” son los valores máximo mínimo de la imagen resultante de reflectancias promedio; “ z_T ” es el número de clases indicado por el usuario; “ z ” es el número de la clase.

$$\Delta z = \Delta x * z \quad \text{Ec. 4.12}$$

El último paso es comparar cada pixel contra el rango correspondiente a cada una de las clases, cuando se identifica a que clase pertenece, se le asigna un valor “ Δz ” entre cero y uno que representa a cada clase y se obtiene con la ecuación 4.12. El proceso general se aprecia en la Figura 4.20 que muestra el diagrama de flujo de la Clasificación No Supervisada.

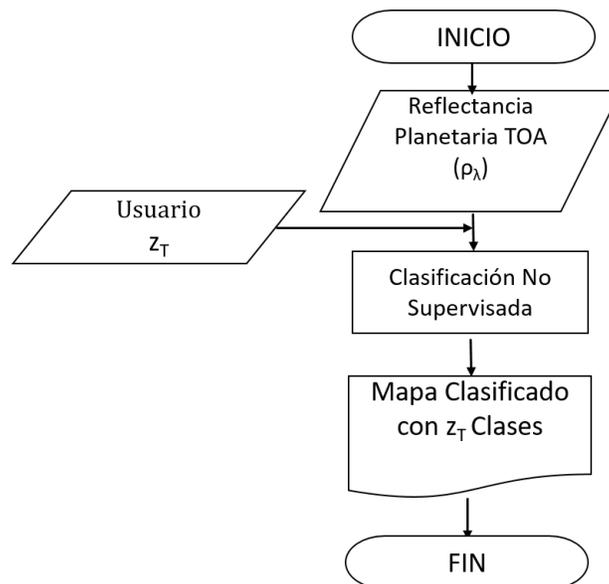


Figura 4.20.- Diagrama de flujo para la Clasificación No Supervisada.

4.3.3.5 Clasificador Supervisado

La metodología usada para clasificar de forma supervisada necesita que el usuario tenga conocimiento de la escena a procesar, se le solicita que indique el número de clases que desea encontrar “z_T” y también que indique mediante zonas de entrenamiento (Training Sets) los píxeles que representaran a cada una de las clases (Figura 4.21).

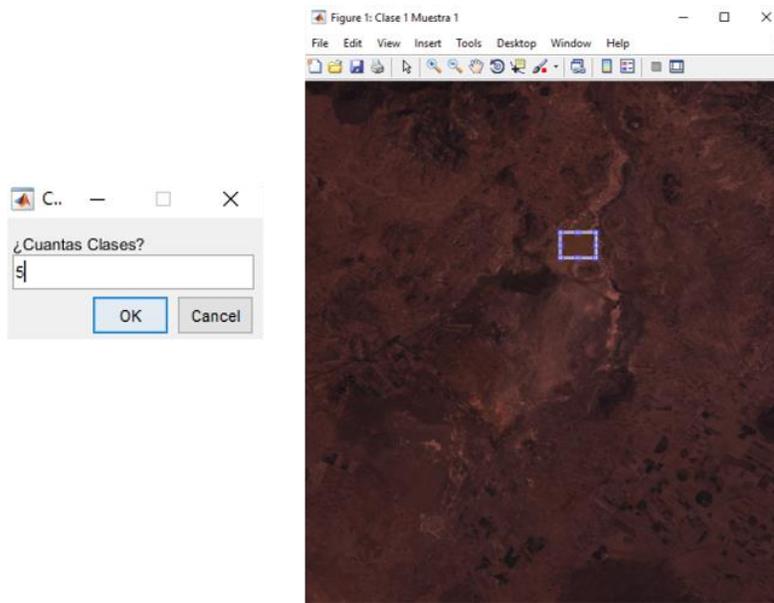


Figura 4.21.- Interface IPICIM para la Clasificación Supervisada.

Internamente se convierte la imagen de “B” bandas reflectantes a una única banda mediante la ecuación 4.9 mostrada en el apartado anterior, a diferencia de la metodología no supervisada donde se dividía el espectro de valores de la imagen en secciones de igual tamaño, en la metodología supervisada se utilizan parámetros estadísticos.

Los parámetros estadísticos necesarios son la media y desviación estándar calculados a partir de los píxeles contenidos en las zonas de entrenamiento para cada una de las clases:

$$\bar{x}_z = \frac{1}{p_z \times r_z} \sum_{i=1}^{p_z} \sum_{j=1}^{r_z} \bar{\rho}_{i,j} \quad \text{Ec. 4.13}$$

$$\sigma_z = \sqrt{\frac{\sum_{i=1}^{p_z} \sum_{j=1}^{r_z} (\bar{\rho}_{i,j} \times \bar{x}_z)^2}{p_z \times r_z}} \quad \text{Ec. 4.14}$$

Donde \bar{x}_z y σ_z son la media y la desviación estándar para la clase “z” obtenida de la zona de entrenamiento “TS” de tamaño “ $p_z \times r_z$ ”. El tamaño de cada clase se calcula con la ecuación 4.15 donde se asegura que cierto porcentaje (95.4%) de los datos se encuentren comprendidos en la clase (Figura 4.22).

$$\bar{x}_z - 2\sigma_z \leq \bar{\rho}_{i,j} \leq \bar{x}_z + 2\sigma_z \quad \text{Ec. 4.15}$$

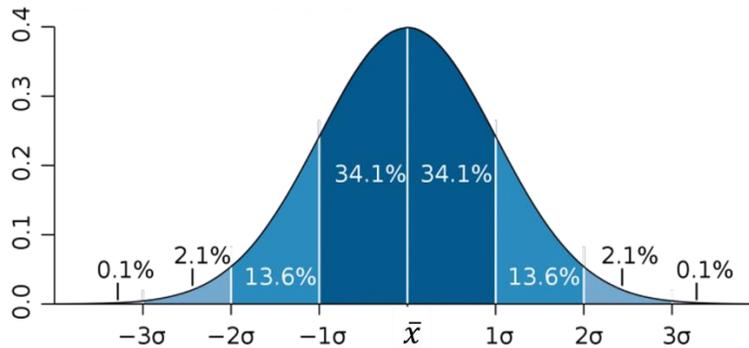


Figura 4.22.-Distribución Gaussiana y porcentaje de valores englobados para cada rango de la media y la desviación estándar.

El último paso es comparar cada pixel contra el rango correspondiente a cada una de las clases, cuando se identifica a que clase pertenece, se le asigna un valor “ Δz ” entre cero y uno que representa a cada clase y se obtiene con la ecuación 4.12. Otra diferencia que se puede encontrar con la Clasificación No Supervisada es que no todos los pixeles pertenecerán a alguna clase, por lo que el mapa final contiene

pixeles marcados con el valor cero que representa sin clase. La Figura 4.23 representa en términos generales el proceso para la Clasificación Supervisada.

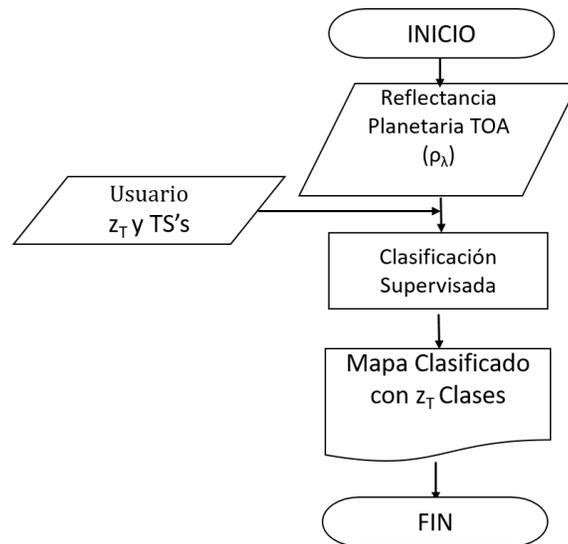


Figura 4.23.- Diagrama de flujo para la Clasificación Supervisada.

4.3.3.6 Clasificador Redes Neuronales

Este trabajo de tesis también propone una metodología nueva basada en la integración del uso de redes neuronales artificiales y las bases de datos digitales (firmas espectrales), la idea fundamental es encontrar un punto de equilibrio entre los procesos supervisado y no supervisado, en otras palabras, se busca desarrollar e implementar un proceso automático donde no se necesiten conocimientos previos de la escena, minimizando las desventajas inherentes del métodos no supervisado y supervisado, mediante la inclusión de las bases de datos para tener un criterio de decisión basado en las firmas espectrales de las clases más comunes.

El primer paso consiste en convertir cada una de las bandas de reflectancia de su formato original en forma matrices (N,M), donde N es el número de filas y M es el número total de columnas, a vectores fila (V_b), conocido como conversión lexicográfica. Este paso es necesario ya que la entrada de datos para las redes neuronales requiere que se encuentren ordenados de manera secuencial. La obtención de los V_b se consigue primero generando un vector columna en donde

las columnas son colocadas una debajo de la otra, una vez teniendo el vector columna se calcula la transpuesta y se obtiene el vector fila que tendrá dimensiones de “1” fila por “NxM” columnas (Figura 4.24).

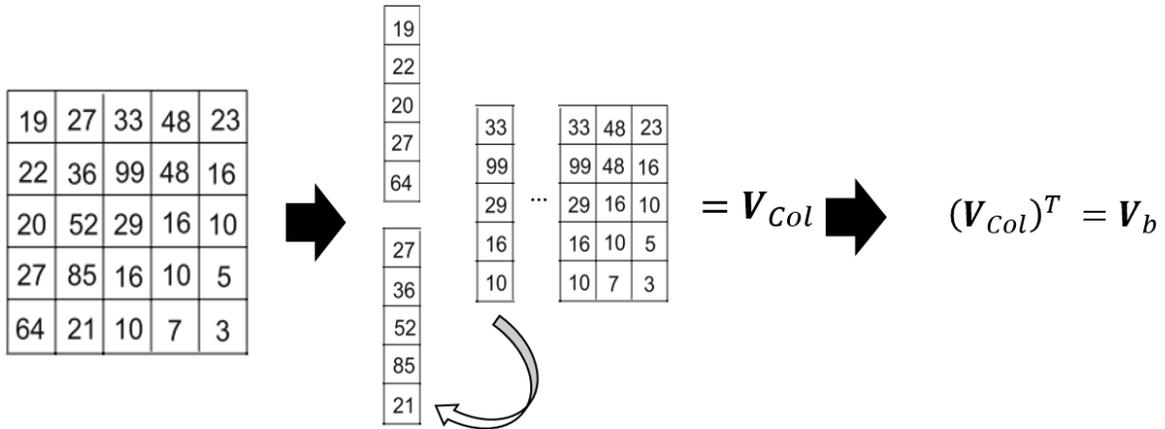


Figura 4.24.- Conversión Matriz a Vector Fila.

El segundo paso se enfoca en determinar los parámetros necesarios para los criterios de decisión de las redes neuronales. Para cada una de las clases más comunes (Roca, Vegetación, Agua, Creado por el hombre, etc.) se calcula una firma espectral promedio de todas las muestras pertenecientes a esa clase encontradas en las bases de datos ASTER y Nacional. De la firma espectral promedio de cada clase se obtienen las reflectancias mínima y máxima “ $\rho_{Min}^{b,z}$ ” y “ $\rho_{Max}^{b,z}$ ” respectivamente donde los superíndices “b” y “z” representan a la banda y a la clase en cuestión (Figura 4.25).

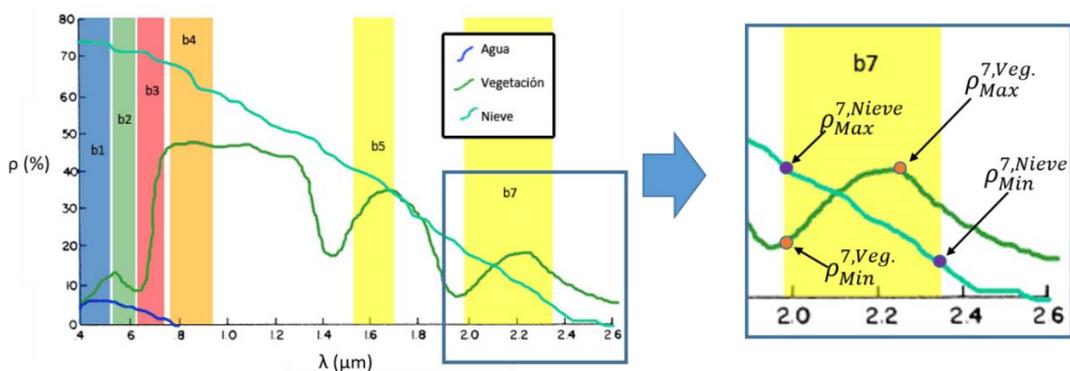


Figura 4.25.- Obtención de parámetros para el criterio de decisión.

Cuando se tienen los parámetros de entrada $(V_b, \rho_{Min}^{b,z}, \rho_{Max}^{b,z})$ se genera una red neuronal con la siguiente arquitectura:

- Capa de Entrada: Numero de neuronas igual al número de bandas “B” del satélite con el que se esté trabajando.
- Capa Salida: Numero de Neuronas igual al número de clases “z_T” que se estén buscando.
- Capa Oculta: El número de neuronas de la capa oculta “O” se obtiene con la siguiente ecuación $O = \sqrt{B * z_T}$

Cada neurona tendrá para su entrenamiento y también como regla de decisión un intervalo de valores para cada clase, si el valor de entrada del pixel en sus diferentes bandas, cae dentro del intervalo $\rho_{Min}^{b,z} \leq V_b(i) \leq \rho_{Max}^{b,z}$ la función de activación otorgará el valor de “1” y un valor de “0” en caso contrario (Figura 4.26). El diagrama de flujo general para la clasificación propuesta se presenta en la siguiente Figura 4.27.

La gran ventaja que obtenemos de la red neuronal radica en su capacidad de aprendizaje, ya que mientras se encuentra procesando comienza a predecir el resultado de su próximo pixel basándose en los pixeles que ya clasifico, si este pertenece a la clase predicha, se ahorrara la necesidad de inspeccionar la demás clases, resultando en un ahorro de tiempo y procesamiento computacional, en caso contrario inspeccionara las demás clases hasta encontrar a cual pertenece y en el proceso actualiza las ponderaciones para sus predicciones del próximo pixel.

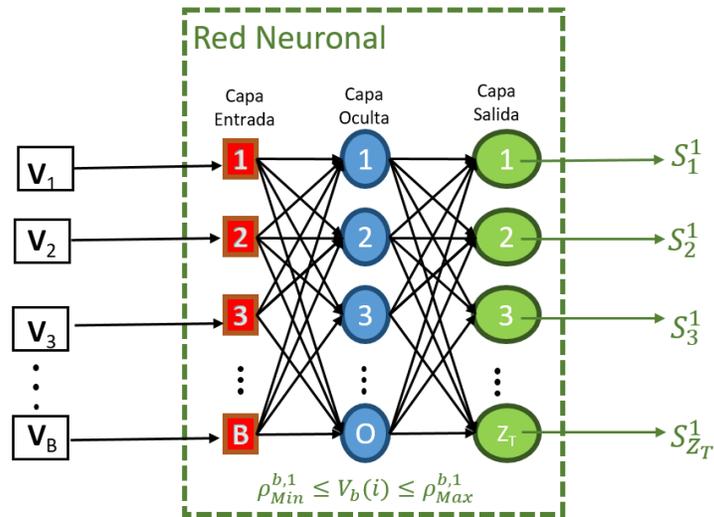


Figura 4.26.- Red Neuronal Implementada en el IPICIM.

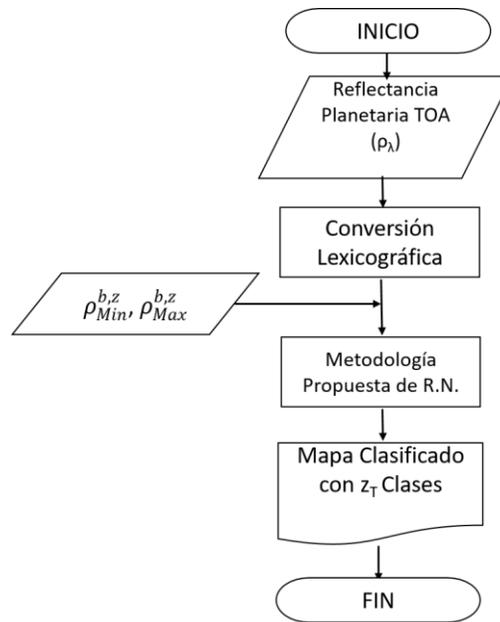


Figura 4.27.- Diagrama de flujo para la Clasificación propuesta con R.N.

4.4 Implementación

El software IPICIM fue elaborado con Interfaces Graficas de Usuario (GUI's) en MATLAB. Se optó por MATLAB porque es un sistema de programación y cálculo basado en la manipulación de matrices. El nombre mismo del sistema o paquete de

cómputo proviene de la abreviación MATriz LABoratory o Laboratorio de Matrices. Por lo tanto, la filosofía detrás de la computación por medio de este sistema es considerar a los objetos (tanto matemático como gráficos) como matrices de forma que podamos usar el álgebra matricial y otras propiedades para ahorrar tiempo de cómputo y como sabemos las imágenes ópticas multiespectrales no son más que matrices de dimensiones $M \times N \times B$ donde M es el número de filas, N el número de columnas y B el número de bandas.

En una GUI es posible generar la interface que el usuario tendrá, mediante la distribución de elementos como botones, tablas, cajas de texto, menús, etc. los cuales son programados individual mente para realizar acciones definidas al ser tocados e ir interactuando con otros elementos presentes en la interface (Figura 4.28).

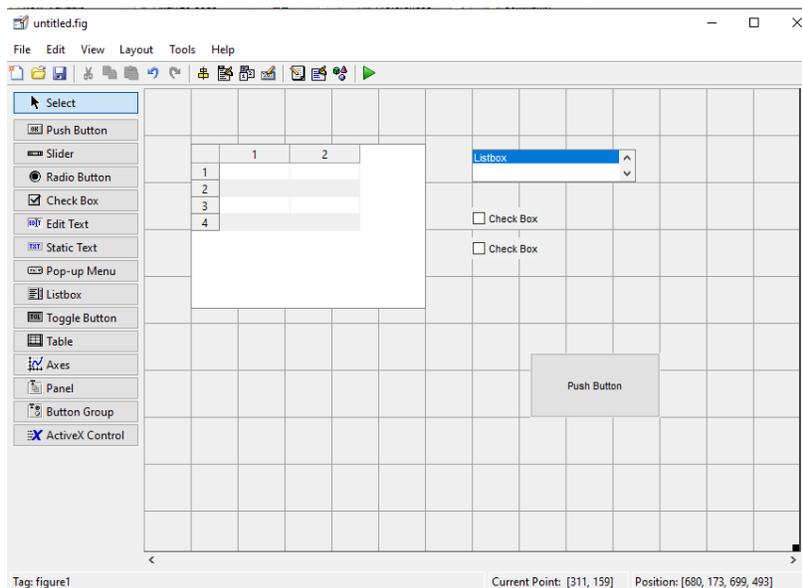


Figura 4.28.- GUI MATLAB.

Detrás de las GUI's se tiene un conjunto de funciones para la realización de todas las actividades, cada función se caracteriza por tener las siguientes partes:

```
function [ Parametros_Salida ] = Nombre_Funcion( Parametros_Entrada )

%Comentarios "Help"

Instrucciones y Comandos

end
```

La primera parte es la declaración de la función, cuáles serán los parámetros de entrada y salida que tendrá, así como el nombre que recibirá; la segunda parte está dedicada al archivo "Help" de la función, aquí se puede explicar el funcionamiento de la misma, unidades, el significado de cada parámetro etc.; la tercera parte es el cuerpo de la función, donde vienen expresadas todas las instrucciones y comandos que ejecutara; por último, se cierra la función con el comando "end".

4.4.1 Interface de Usuario

La interface de usuario IPICIM (Figura 4.29) está diseñada para guiar al usuario en el proceso de elaboración de mapas temáticos, sin importar el nivel de conocimientos con los que este cuente. En su ventana principal se observan 4 áreas: menús, datos, reporte y resultados.

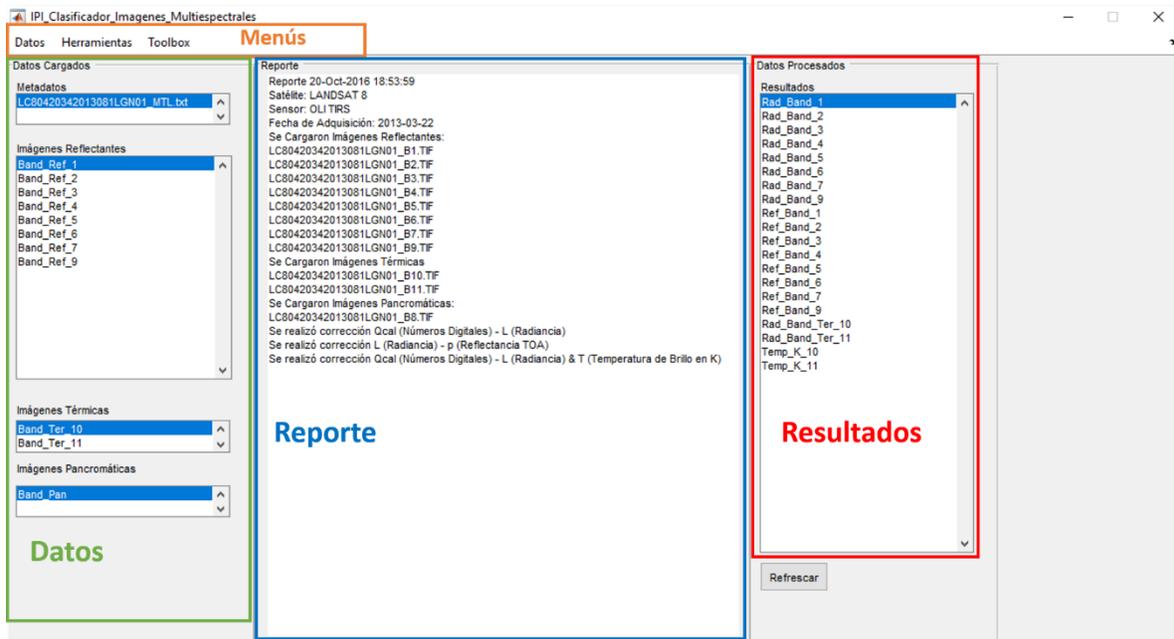


Figura 4.29.- Interface Principal IPI CIM.

En color naranja tenemos el área de menús, desde aquí se ejecutan todas las actividades desde la carga de datos como el metadatos e imágenes, hasta la obtención de imágenes corregidas radiométricamente y mapas temáticos como índices y clasificaciones. El área de menús cuenta con tres pestañas donde se encuentran las siguientes opciones:

- Datos:
 - Carga de Archivo Metadatos
 - Carga de Imágenes Reflectantes
 - Carga de Imágenes Térmicas
 - Carga de Imágenes Pancromáticas
 - Exportar

- Herramientas:
 - Interface para la visualización RGB
 - Interface para el recorte de imágenes

- Toolbox
 - Corrección de Imágenes Reflectantes
 - Nd a Radiancia (Qcal a $L\lambda$)
 - Radiancia a Reflectancia ($L\lambda$ a $\rho\lambda$)
 - Corrección de Imágenes Térmicas
 - Nd a Radiancia & Temperatura de Brillo (Qcal a $L\lambda$ & T)
 - Corrección de Imágenes Pancromáticas
 - Nd a Radiancia & Reflectancia (Qcal a $L\lambda$ & $\rho\lambda$)
 - Índices
 - NDVI
 - NDWI
 - NDSI Snow
 - NDSI Soil
 - NBR
 - VARI
 - Calculadora de Bandas y Áreas
 - Módulos de Clasificación
 - No Supervisada
 - Supervisada
 - Otros Clasificadores
 -

Las interfaces de recortes y visualización en RGB fueron introducidas en el apartado correspondiente a Visualización y Diseño. La única interface que hasta el momento no ha sido presentada es la de la calculadora de bandas (Figura 4.30). La Calculadora de Bandas como se observa en la imagen, cuenta con un menú desplegable para seleccionar entre las bandas pre-cargadas y las que ya recibieron algún tratamiento previo, aquellas que sean seleccionadas se despliegan para procesos posteriores y ser utilizadas en alguna función nueva o replicada de algún artículo, libro etc. Con los botones presentes se escribe la función la cual irá apareciendo en un recuadro para su visualización, si la función no cuenta con ningún error de sintaxis, se pide al usuario que coloque el nombre para almacenar

ese cálculo y se presiona el botón Calcular para finalizar el proceso. Como ejemplo se tiene precargada una función para el cálculo de Biomasa presentado por (Rodríguez, 2015).

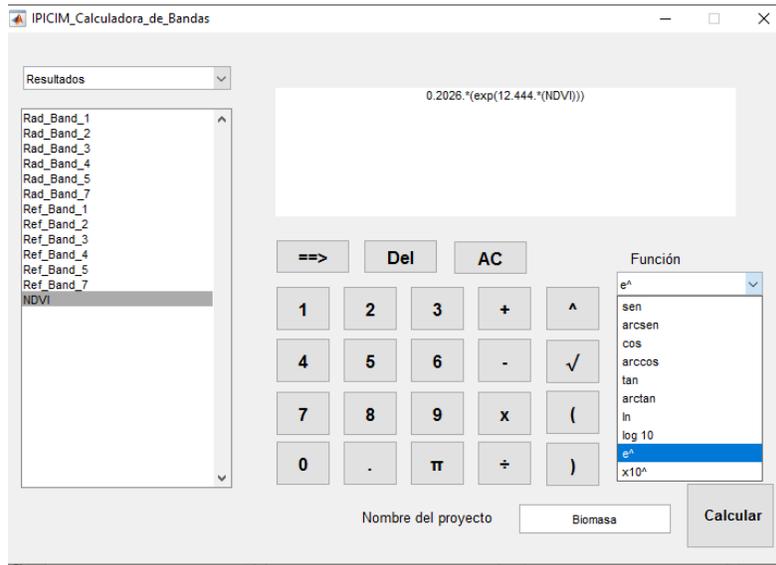


Figura 4.30.- Interface Calculadora de Bandas IPICIM.

Continuando con la interface principal se tienen las áreas en color verde y rojo donde se muestran las imágenes cargadas y los resultados o imágenes que han recibido algún proceso respectivamente. En la parte central se genera un reporte de todos los procesos que reciben las imágenes que es posible recuperarlo para su almacenaje o impresión desde el menú Exportar.

Capítulo 5: Resultados

Como se ha mencionado a lo largo de este documento, el objetivo fundamental es satisfacer las necesidades del proyecto conjunto donde colaboran el CINVESTAV-Tamaulipas, el CNS y la DGA-IPICYT para la Agencia Espacial Mexicana. Concentrándonos en la parte correspondiente a la DGA-IPICYT se tienen los siguientes requerimientos:

- Obtención de mapas temáticos, en formato estándar, solicitado por el usuario (servicio bajo pedido), dentro de los resultados iniciales se podrá seleccionar estas opciones:
 - Mapas de análisis de vegetación
 - Mapas para ver zonas inundadas o con riesgo a inundarse

- Archivo con análisis básico de interpretación del mapa temático proporcionado.

Basados en los requerimientos anteriores, se planteó la tarea de diseñar un software prototipo capaz de brindar estos servicios, por lo que el software IPICIM por sí mismo es uno de los resultados, él cual es descrito más adelante. Otro punto importante en los resultados del proyecto es que los procesos de cálculo de mapas y correcciones sean procedimientos cuyo tiempo de ejecución sea cercano al tiempo real, en otras palabras, que sean efectuados en el menor tiempo posible así que se realizó una comparativa de los tiempos de ejecución en tres softwares diferentes, dos de ellos SIG ampliamente utilizados y que se encuentran disponibles en la red y el tercero el IPICIM.

También se realizó una comparativa entre los métodos de clasificación, supervisado y no supervisado implementados en el IPICIM, la cual pone en evidencia buscar otras alternativas/ procesos para la clasificación. En este trabajo, se propone un método basado en redes neuronales que utiliza dos librerías de firmas espectrales: una Nacional desarrollada en el IPICYT y la librería de ASTER. Por último, se mostrará la utilidad del software IPICIM al ser utilizado en aplicaciones relacionadas con las Geociencias y otras disciplinas.

5.1 Software IPICIM

El software prototipo IPICIM se convierte en la primera herramienta para el procesamiento de imágenes multiespectrales de origen mexicano, viene a complementar la amplia gama de procesadores existentes. El IPICIM posee una interface amigable e intuitiva, con un mejor desempeño en tiempo de procesamiento y con una metodología de clasificación no supervisada basada en redes neuronales que emplea las bases de datos Nacional y la ASTER que ningún otro software ofrece.

Aunque en esta primera etapa cuenta con una limitada cantidad de herramientas, comparado con otros softwares, el IPICIM está dotado con aquellas indispensables para la obtención de mapas temáticos, recortes, visualizaciones, etc. necesarias en muchas de las aplicaciones en geociencias y algunas otras ramas.

La interface de usuario del IPICIM cuenta con una ventana principal sobre la cual se desarrollan la mayoría de las actividades (Figura 5.1). Para iniciar, el software requiere se seleccione el archivo metadatos, archivo donde se encuentra toda la información relacionada con la imagen como el nombre del satélite con el cual fue capturada, el número y nombre de las bandas que contiene, valores necesarios para ciertos cálculos como la radiancia y reflectancia, el tamaño de cada pixel, entre muchos otros.

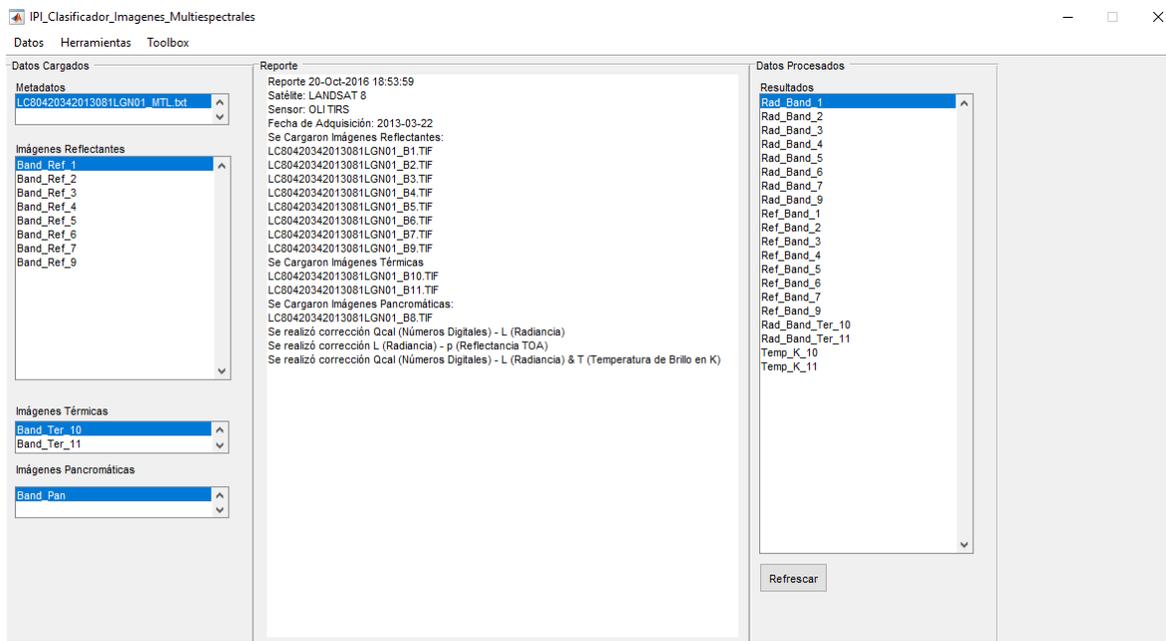


Figura 5.1.-Interface principal IPICIM.

Una vez que se ha cargado el archivo metadatos, el software detecta el satélite a procesar y de forma automática habilita únicamente las herramientas y aplicaciones que son posibles de realizar sobre el satélite seleccionado. Esto de una forma indirecta guía al usuario sobre los procesos necesarios y la secuencia en que estos se realizan para poder trabajar sobre las imágenes y obtener resultados correctos como los mapas temáticos y clasificaciones.

El IPICIM cuenta, además de la ventana principal, con otras ventanas o interfaces de usuario que se pueden abrir y cerrar en cualquier momento. Aquellos procesos que despliegan alguna ventana extra se presentan a continuación:

- Recorte de imágenes



Figura 5.2.- Interface para recorte de imágenes.

- Visualización en escala de grises

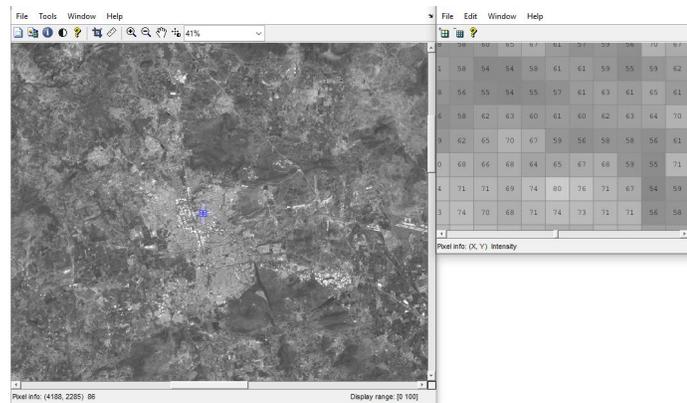


Figura 5.3.- Interface visualización escala de grises.

- Visualización en RGB

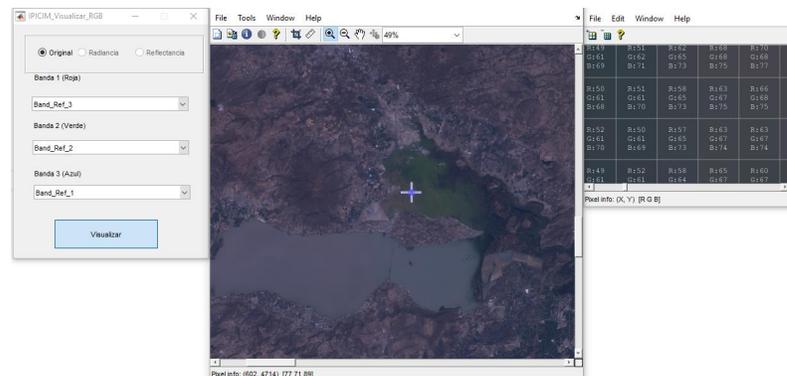


Figura 5.4.- Interface Visualización en RGB.

- Calculadora de bandas

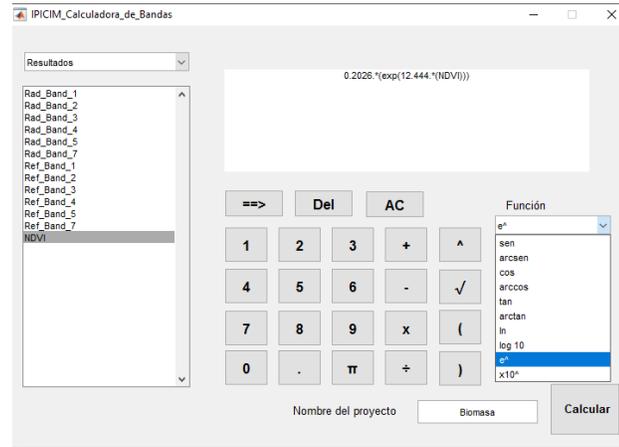


Figura 5.5.-Interface de la Calculadora de Bandas.

- Clasificación No Supervisada

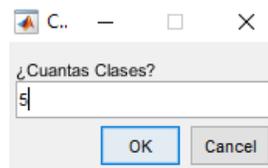


Figura 5.6.- Interface clasificador no supervisado.

- Clasificación Supervisada

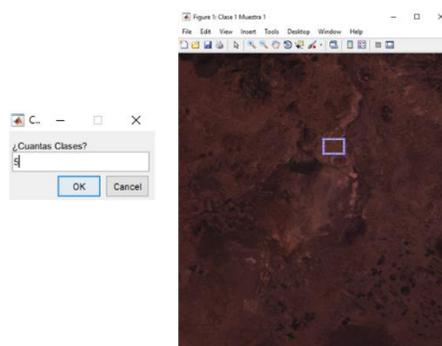


Figura 5.7.- Interface Clasificador supervisado.

Todas las interfaces presentadas antes fueron explicadas en sus respectivos apartados en el capítulo 4.

A continuación, se enlistan todas las actividades que son posibles de realizar en el software prototipo IPICIM:

- Datos:
 - Carga de Archivo Metadatos
 - Carga de Imágenes
 - Reflectantes
 - Térmicas
 - Pancromáticas
 - Exportar Resultados y Reporte

- Herramientas:
 - Visualizar en Escala de Grises
 - Visualizar en RGB
 - Recorte de Imágenes
 - Por Pixeles
 - Por Coordenadas
 - Por Recuadro

- Toolbox
 - Corrección de Imágenes Reflectantes
 - Nd a Radiancia (Qcal a $L\lambda$)
 - Radiancia a Reflectancia ($L\lambda$ a $\rho\lambda$)
 - Corrección de Imágenes Térmicas
 - Nd a Radiancia & Temperatura de Brillo (Qcal a $L\lambda$ & T)
 - Corrección de Imágenes Pancromáticas
 - Nd a Radiancia & Reflectancia (Qcal a $L\lambda$ & $\rho\lambda$)
 - Cálculo de Índices
 - NDVI
 - NDWI
 - NDSI Snow
 - NDSI Soil

- NBR
- VARI
- Calculadora de Bandas y Áreas
- Clasificación
 - No Supervisada
 - Supervisada
 - IPICIM (Redes Neuronales)

5.2 Comparación de Tiempos

Para realizar la comparativa de tiempos de procesamiento, se seleccionaron dos softwares ampliamente utilizados en la actualidad. El primero es el software de paga ENVI en su versión 5.1 desarrollado por Exelis Visual Information Solutions, se trata de un software completo para la visualización y análisis de las imágenes obtenidas en la PR. Posee un conjunto muy completo de funciones de análisis y de tratamiento de imágenes multiespectrales, hiperespectrales y de radar.



Figura 5.8.- ENVI.

El segundo es el software GRASS (Geographic Resources Analysis Support System) en su versión 7.0.5 desarrollado en sus inicios por ingenieros del ejército

de estados unidos, en la actualidad es un software gratuito parte de QGIS para crear, editar, visualizar, analizar y publicar información geoespacial.



Figura 5.9.-GRASS GIS.

Todas las pruebas se realizaron sobre la misma computadora cuyas especificaciones técnicas se presentan en la Tabla 5.1, el modo de energía se encontraba en alto rendimiento y ningún otro proceso se ejecutaba mientras se realizaban las pruebas.

Parámetro	Descripción
Nombre	Lenovo IdeaPad S410p Touch
Sistema Operativo	Windows 10 Home Single Language
Procesador	Intel® Core™ i5-4200U CPU @1.60 GHz 2.3GHz
Ram Instalado	8.00 GB
Tipo de Sistema	Sistema operativo de 64 bits, procesador x64
Tarjeta de Video Dedicada	NVIDIA GEFORCE GT 720M

Tabla 5.1.-Especificaciones técnicas de la computadora.

En el estudio se seleccionaron 8 pruebas fundamentales para el tratamiento de imágenes multiespectrales, y se realizaron sobre cuatro imágenes representativas para todos los sensores de la familia Landsat, se trata de imágenes completas (sin

recortes) de los satélites Landsat 5 MSS, 5 TM, 7 y 8. Los tiempos promedio obtenidos de las pruebas se encuentran registrados en la siguiente tabla:

Operación	Satélite	Tiempo			Tasa de Cambio en tiempo comparado con IPICIM	
		ENVI	GRASS QGIS	IPICIM	ENVI	GRASS QGIS
Carga Imágenes Reflectantes	L5 MSS	5s	10s	7s	40%	-30%
	L5 TM	12s	24s	16s	33.3%	-33.3%
	L7 ETM+	12s	44s	16s	33.3%	-63.3%
	L8 OLI TIRS	19s	48s	30s	57.8%	-37.5%
CONVERSIÓN DE ND A RADIANCIA (Q_{cal} a L_{λ})	L5 MSS	28s	6s	2s	-78.5%	-66.6%
	L5 TM	2min 23s	36s	8s	-94.4%	-77.7%
	L7 ETM+	2min 37s	36s	8s	-94.9%	-77.7%
	L8 OLI TIRS	2min 57s	2min	13s	-92.6%	-89.1%
CONVERSIÓN DE RADIANCIA A REFLECTANCIA (L_{λ} a ρ_{λ})	L5 MSS	22s	6s	2s	-90.9%	-66.6%
	L5 TM	2min 41s	36s	35s	-78.2%	-2.7%
	L7 ETM+	2min 37s	36s	35s	-98.7%	-2.7%
	L8 OLI TIRS	2min 8s	2min 11s	1min 25s	-33.5%	-35.1%
Conversión DE ND a Radiancia y TEMPERATURA DE BRILLO (Q_{cal} a L_{λ} & T)	L5 MSS	N/A	N/A	N/A	-	-
	L5 TM	39s	12s	6s	-84.6%	-50%
	L7 ETM+	1min 13s	24s	10s	-86.3%	-58.3%
	L8 OLI TIRS	1min 45s	1min 10s	10s	-90.4%	-85.7%
Conversión DE ND a Radiancia y Reflectancia de la banda pancromática (Q_{cal} a L_{λ} & ρ_{λ})	L5 MSS	N/A	N/A	N/A	-	-
	L5 TM	N/A	N/A	N/A	-	-
	L7 ETM+	1min 48s	-	13s	-87.9%	-
	L8 OLI TIRS	1min 55	-	14s	-87.8%	-
Cálculo NDVI	L5 MSS	2s	12s	1s	-50%	-91.6%
	L5 TM	5s	50s	5s	0%	-90%
	L7 ETM+	7s	50s	5s	-28.5%	-90%
	L8 OLI TIRS	6s	1min	8s	25%	-86.6%
División de dos bandas Calculadora de bandas	L5 MSS	2s	3s	2s	0%	-33.3%
	L5 TM	5s	14s	5s	0%	-64.2%
	L7 ETM+	6s	14s	10s	40%	-28.5%
	L8 OLI TIRS	7s	16s	10s	30%	-37.5%

Tabla 5.2.- Comparativa de tiempos de procesamiento para varias operaciones.

Como se puede apreciar de la tabla anterior, la mayoría de los resultados tienen una tasa de cambio negativa lo que indica una disminución en el tiempo de procesamiento, mientras que en caso contrario las tasas positivas nos indican incremento de tiempo.

Al observar las tasas de cambio de tiempo resulta evidente que en el proceso de carga de imágenes el IPICIM no es el más destacado, a pesar de promediar un tiempo bastante corto de 17.2 s, resulto ser un 41.1% más lento que el ENVI que obtuvo el mejor resultado con 12 s, por otro lado, es un 41% más rápido que GRASS que promedió 31.5 s haciéndolo el más lento. Prácticamente para el resto de los resultados, el IPICIM sobresale con disminuciones de tiempo, las reducciones son más notorias cuando se compara contra ENVI, con ahorros que van desde un 25% hasta 98.7%. Aunque con el software GRASS las disminuciones son menores, se obtuvieron mejoras considerables de entre un 2.7% y 90%.

Los mejores resultados se encontraron en la obtención de la Radiancia de las imágenes reflectantes con mejoras de 90.1% y 77.7% que representan ahorros de casi 2min y 40s para ENVI y GRASS respectivamente.

Cuando se trata de realizar operaciones con las calculadoras de bandas, el ENVI es quien menores tiempo necesita, mientras que el IPICIM se encuentra en un punto intermedio siendo 17.5% más lento que ENVI, pero 40.8% más rápido que GRASS.

En resumen, el IPICIM es un software que a pesar de contar con una librería de herramientas limitada comparada con otros SIG, permite realizar la mayoría de los procesos básicos útiles en el trabajo con imágenes multiespectrales, y gracias a su interface simple e intuitiva, usuarios con conocimientos básicos de PR podrán obtener de forma sencilla y rápida mapas temáticos de su elección.

5.3 Resultados y Comparativa de los Tres Clasificadores

A continuación, se muestran los resultados que se obtienen en la clasificación de imágenes al emplear el método supervisado de ENVI (Máximum Likelihood), y los métodos supervisado y basado en redes neuronales implementados en el IPICIM. Para la comparativa se utilizó una imagen del satélite Landsat 7, adquirida sobre la península de Yucatán, se efectuó un recorte de la ciudad de Cancún y alrededores, por último, se le aplicaron las correcciones radiométricas para la obtención de la reflectancia (Figura 5.10).



Figura 5.10.-Imagen RGB (3,2,1) Reflectancia.

Para que los resultados obtenidos fueran comparables, al aplicar los métodos supervisados en ENVI y en IPICIM se utilizaron las mismas zonas de entrenamiento para 5 clases diferentes (agua profunda, agua con sedimentos, vegetación densa, vegetación poco densa y construcción). Para la clasificación con redes neuronales solo basto con dar la instrucción de que realizara la clasificación y de forma automática se realizan todos los procesos necesarios. Los resultados obtenidos en los tres clasificadores se presentan a continuación (Figura 5.11).

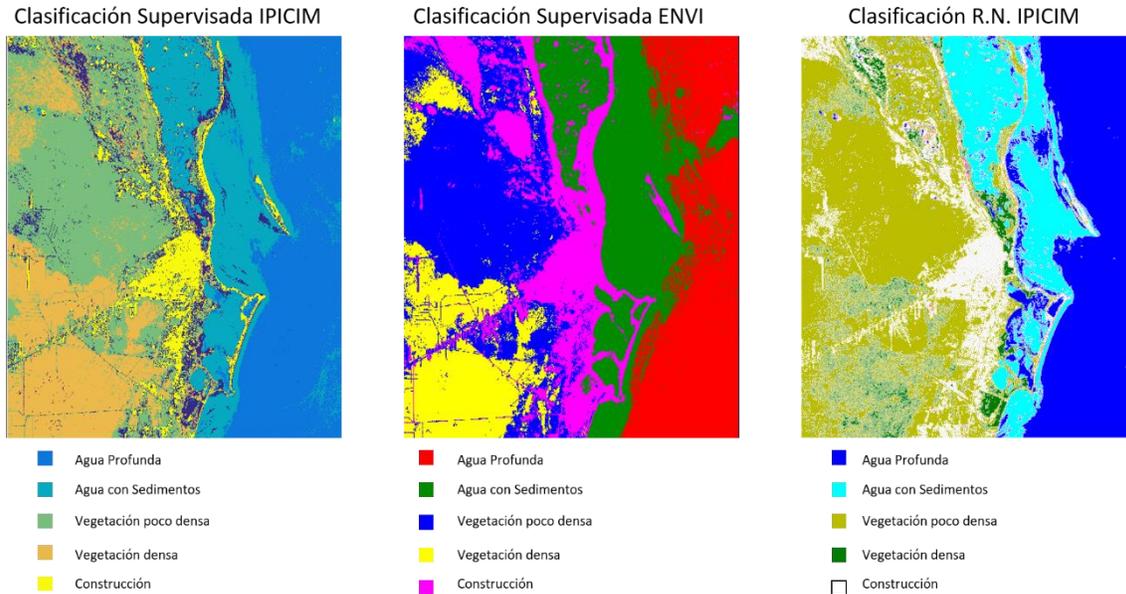


Figura 5.11.- Comparativa de resultados obtenidos en la clasificación.

Como se puede observar en la Figura 5.11 los tres métodos proporcionan resultados bastante acertados al etiquetar cada uno de los píxeles a una clase. Considerando los clasificadores supervisados, se aprecia una mejor discriminación entre el agua profunda y agua con sedimentos con la metodología IPICIM, pero ambos poseen un mismo comportamiento de confusión entre las clases de ciudad y parte de la vegetación. Ese problema se ve minimizado con la metodología basada en redes, donde la diferenciación entre clases fue bastante acertada sin la necesidad de que el usuario especifique algún parámetro.

5.4 Capacidades y Aplicaciones en Geociencias

En esta sección se replicarán las metodologías utilizadas y desarrolladas por otros autores en aplicaciones de PR enfocadas en el área de geociencias. El objetivo no es verificar si los procedimientos y/o resultados son correctos, simplemente se busca probar la utilidad del software IPICIM para este tipo de cálculos.

En cada caso que se presenta, se explica la aproximación y metodología empleada, así como la zona de estudio donde trabajaron, la misma metodología fue aplicada para una zona representativa con la misma problemática en territorio mexicano.

5.4.1 Mapeo de la Calidad del Agua en el Lago de Chapala Jalisco

El título original de la publicación es “Application of Landsat 5 and Landsat 7 images data for water quality mapping in Mosul Dam Lake, Northern Iraq”(Khattab & Merkel, 2014). El lago Mosul Dam en Irak es una fuente de agua para muchas ciudades alrededor del mismo, por lo que decidieron diseñar algoritmos simples y precisos de parámetros que les ayuden a monitorear la calidad del agua a partir de valores de reflectancia. Usando mediciones de campo y combinaciones de bandas de reflectancia generaron algunos algoritmos con correlaciones de hasta $R^2=0.9$ para el sensor ETM+ abordo del satélite Landsat 7.

Entre sus conclusiones indican que mediante el uso de imágenes satelitales es posible el monitoreo de la calidad del agua del lago Mosul Dam. Partiendo de sus resultados se asumió que los mismos algoritmos son aplicables para determinar la calidad del agua del lago de Chapala en estado de Jalisco. La metodología reportada se presenta en el siguiente diagrama de flujo (Figura 5.12).

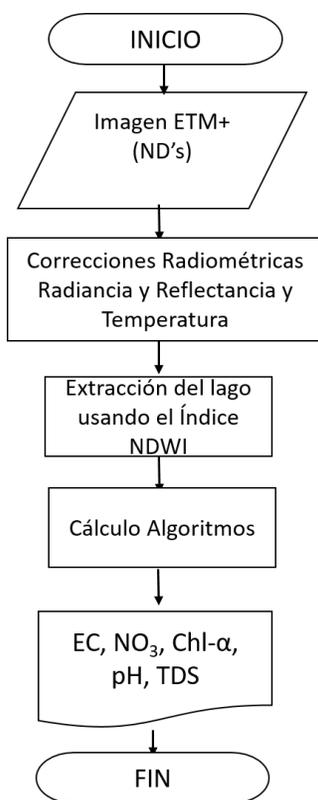


Figura 5.12.- Diagrama de flujo para el cálculo de parámetros para la calidad del agua.

Los algoritmos se encuentran en la siguiente tabla:

Parámetro	Algoritmo
Conductividad Eléctrica (EC) [mhos/cm]	$-0.585+0.002*\rho_4+0.008*T_{62}+0.322*(\rho_3/\rho_2)$
Nitrato (NO ₃) [mg/l]	$1.782+75.469*\ln(T_{62}/T_{61})$
Clorofila (Chl-α) [mg/l]	$-15.16+0.449*\rho_1-1.252*(\rho_3/\rho_1)$
Potencial De Hidrogeno (pH)	$-200.914+304.26*(T_{62}/T_{61})-95.202*(T_{62}/T_{61})^3$
Turbiedad	$35.121-14.489(\rho_2/\rho_3)-0.911\rho_4$

Tabla 5.3.- Algoritmos para el cálculo de parámetros de calidad del agua

De una imagen Landsat 7 se recortó la zona del lago de Chapala, se realizaron las correcciones radiométricas para hallar la reflectancia y temperatura posteriormente se calculó el NDWI para extraer la superficie correspondiente al agua del lago (Figura 5.13).

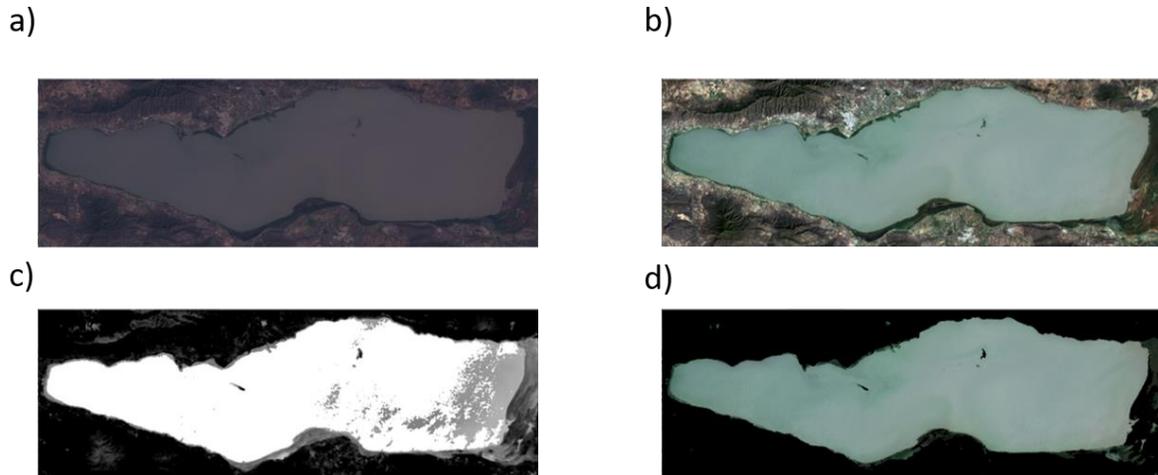


Figura 5.13.-Proceso de obtención de la superficie de agua: a) RGB ND's; b) RGB Reflectancia; c) NDWI; d).RGB Mascara de Agua.

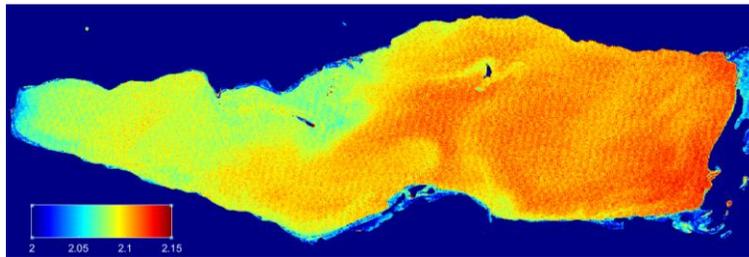
Usando la máscara que contiene únicamente la superficie que corresponde al agua, se efectuaron con la calculadora de bandas las ecuaciones presentes en la Tabla 5.3. Los resultados se presentan a continuación (Figura 5.15). Algunos valores para los parámetros de calidad del agua para diferentes usos están reportados en la Figura 5.14.

Parámetro	Usos		
	Suministro urbano	Riego agrícola +	Protección vida de acuática +
SST	n.s. +	2,996	n.r.
ST	1,770 +	n.r.	n.r.
pH	7,180 *	n.r.	n.r.
SDT	1,570 *	4,625	n.r.
G y A	c.n. *	n.r.	n.r.
TURBIEDAD [UTN]	c.n. *	n.r.	c.n.
SO ₄ ²⁻	n.s. *	2,078	c.n.
ALCALINIDAD TOTAL	2,123 +	n.r.	n.r.
N-NH ₃	1,383 *	n.s.	n.r.
C.E. [µmho/cm]	n.r.	2,675	n.r.
COLOR [Pt-Co]	c.n. *	n.r.	n.r.
COLIFORMES TOTALES [NMP/100 ml]	c.n. *	n.r.	n.r.
COLIFORMES FECALES [NMP/100 ml]	c.n. *	c.n.	c.n.

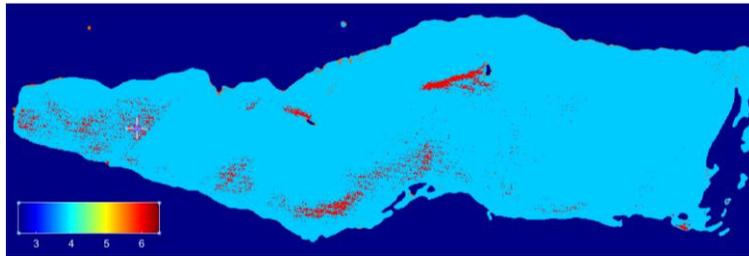
[n.r.] no regulado [n.s.] no sobrepasa [c.n.] cualquier volumen < 9,000 [Mm³]
 Unidades en mg/L si no se indican otras

Figura 5.14.- Valores de algunos parámetros para la calidad del agua para diferentes usos (Agust, Longoria, & Maldonado, 2012)

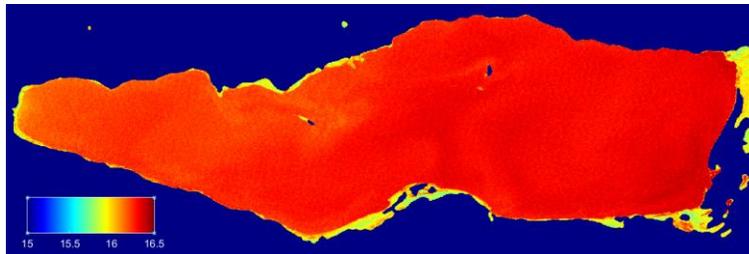
a) EC [mhos/cm]



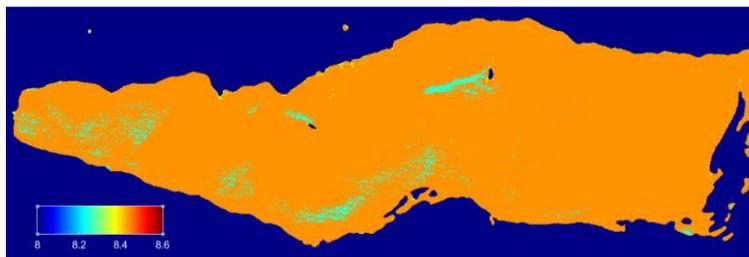
b) NO₃ [mg/l]



c) Chl- α [mg/l]



d) pH



e) Turbidez

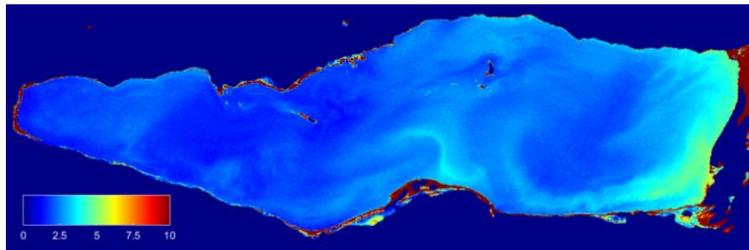


Figura 5.15.-Resultados de los algoritmos para los parámetros de calidad del agua.

A partir de los resultados obtenidos, se puede observar que la conductividad eléctrica oscila entre los 2.05 y 2.15 mhos/cm o 2,050 a 20150 μ hos/cm que se encuentran por debajo del máximo para el uso agrícola. Las cantidades de nitrato se encuentran en gran parte del lago con valor de 4 mg/l con algunas pequeñas zonas de valor 6 mg/l. La clorofila se encuentra en promedio con un valor de 16 mg/l que se asocia a lagos que tienen comúnmente aguas claras y mantienen lechos de plantas acuáticas sumergidas, y niveles medios de nutrientes. El pH entre 8.2 y 8.4 se encuentra un poco por encima del nivel para uso urbano. Por último, la turbidez nos muestra que en el centro del lago se tienen valores bajos que provocan aguas más claras, y que hacia las orillas los valores aumentan.

5.4.2 Mapeo de Biomasa Arbórea en el Bosque de Chapultepec

El título de la publicación original es “Estimación De Biomasa Arbórea Por Medio De Índices De Vegetación Para El Parque Nacional Natural La Paya” (Rodríguez, 2015) donde se estudia el potencial del índice de vegetación NDVI en el satélite Landsat 8 para estimar biomasa arbórea del Parque Nacional Natural “La Paya”, ubicado en el municipio de Leguízamo (Putumayo). El objetivo fue alcanzado aplicando una regresión que relacionaba la biomasa reportada en inventarios forestales de la zona, y los valores encontrados en el NDVI. Su conclusión fue que si era posible la estimación de la biomasa usando al NDVI y la ecuación de regresión encontrada con un $R^2=0.94$.

La metodología utilizada es la siguiente (Figura 5.16):

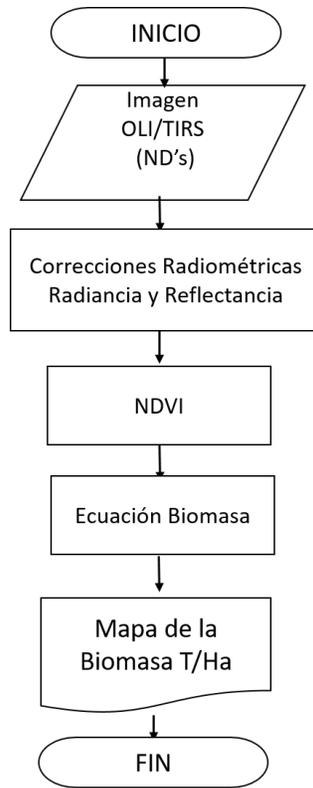


Figura 5.16.- Diagrama de flujo para el cálculo de Biomasa Arbórea.

La ecuación para el cálculo de la biomasa es:

$$y = 0.2026 * e^{12.444*x} \quad \text{Ec. 5.1}$$

Donde “y” representa la biomasa en T/Ha y “x” es el valor del NDVI.

La Imagen de la zona utilizada, así como la corrección radiométrica y el cálculo del NDVI se muestran en la Figura 5.17. La escena en Falso color (5,4,3) fue utilizada para resaltar la vegetación de los demás elementos, los tonos rojos indican la vegetación, mientras más fuerte el tono más sana o densa es la misma.

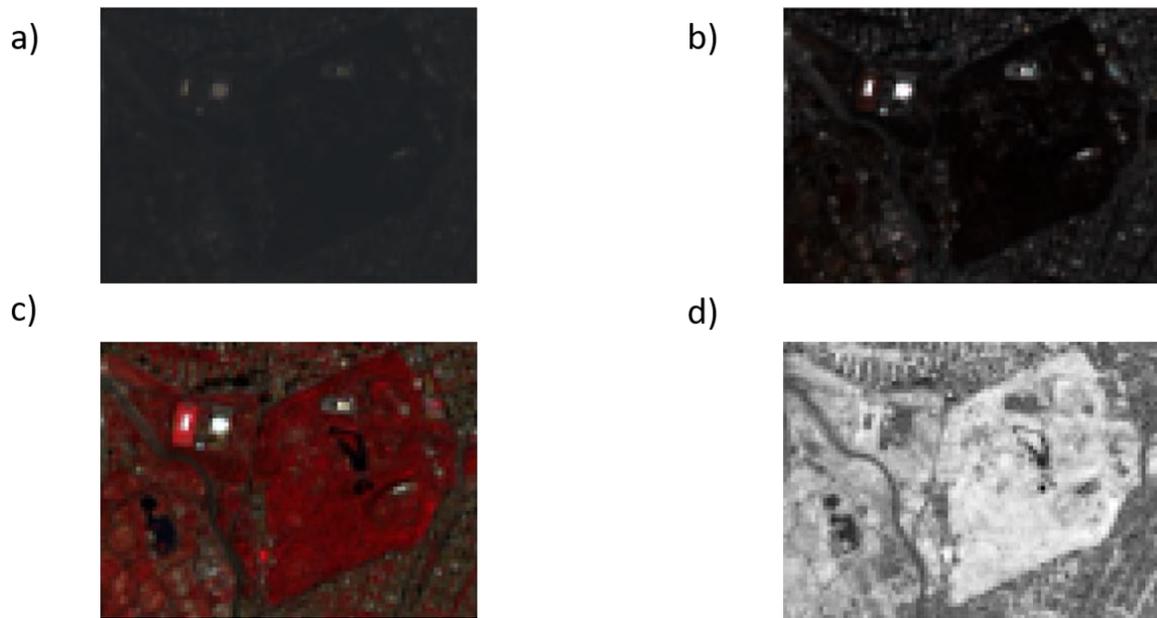


Figura 5.17.- Proceso de obtención de la Biomasa: a) RGB ND's; b) RGB Reflectancia; c) Falso color (5,4,3); d).NDVI.

Una vez que se obtuvo el índice NDVI, se extrajo la máscara que contenía únicamente la vegetación y a la misma se le aplicó la Ec.5.1 para la obtención de la biomasa, los resultados obtenidos se presentan en la Figura 5.18.

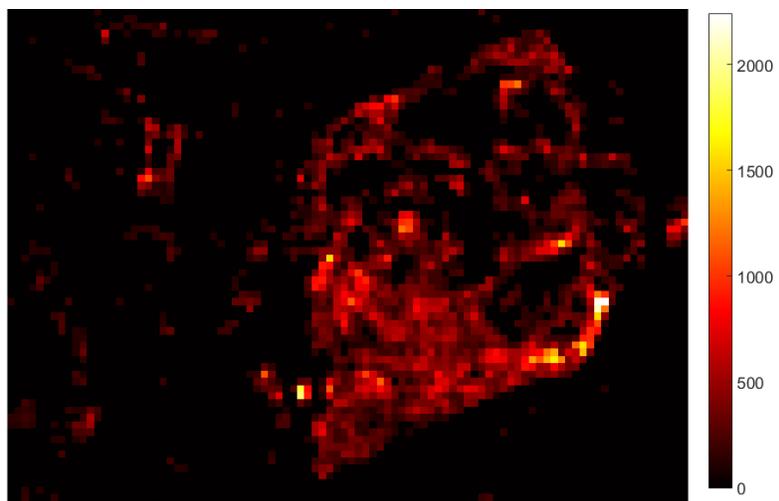


Figura 5.18.- Biomasa expresada en T/Ha.

Del resultado del cálculo se puede extraer de forma rápida la Biomasa Total de la escena multiplicando cada pixel por el área que representa expresada en hectáreas (0.09 Ha/pixel), lo que da como resultado un total de 50039.16 toneladas.

5.4.3 Flujo de Calor en el Volcán Popocatépetl

Del artículo titulado “Exploration and Monitoring Geothermal Activity Using Landsat ETM+ Images” (Mia, Nishijima, & Fujimitsu, 2014) que tenía como objetivo el monitoreo de la actividad geotérmica usando la PR, se utilizó la metodología para calcular el flujo de calor de la zona del volcán Popocatépetl.

La metodología usada se presenta en la Figura 5.19. Mientras que la zona de estudio se presenta en la Figura 5.20.

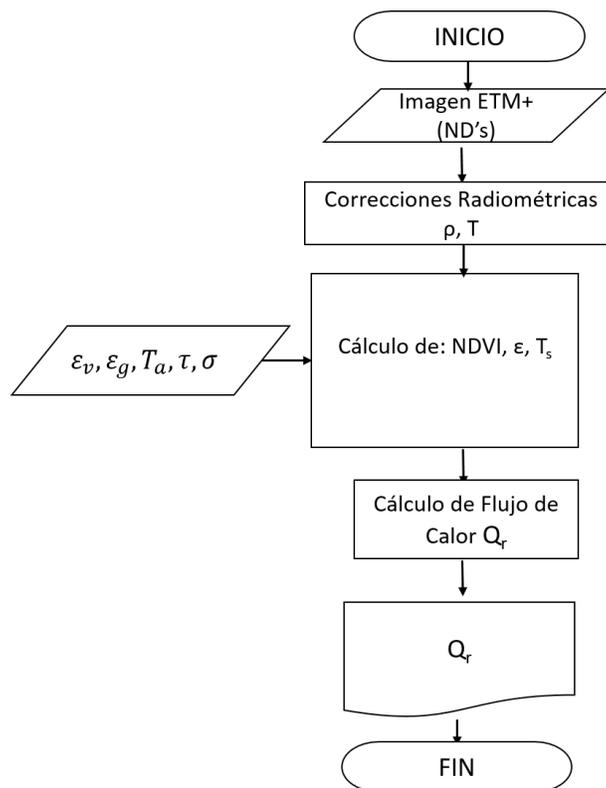


Figura 5.19.-Diagrama de flujo para el cálculo del Flujo de Calor en la zona del volcán Popocatépetl.

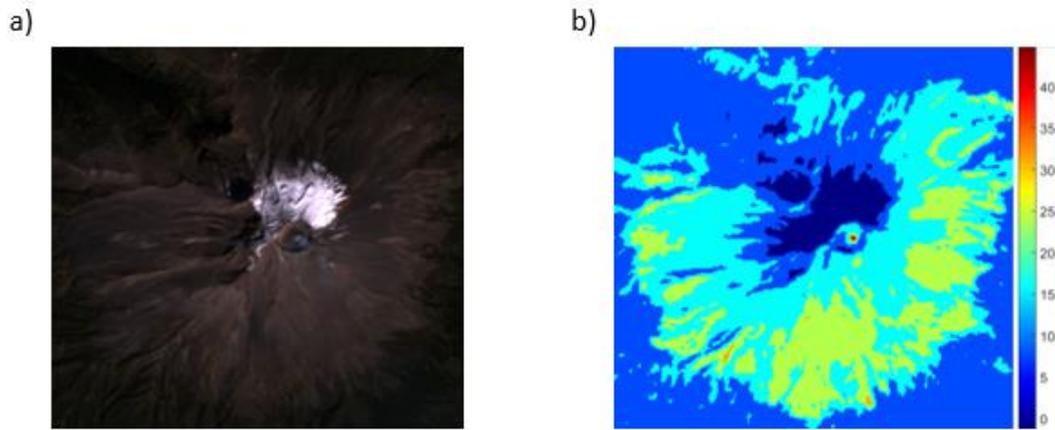


Figura 5.20.- Zona de trabajo volcán Popocatepetl: a) RGB de Reflectancia b); T.

Las ecuaciones empleadas son las siguientes:

$$Q_r = \tau * \sigma * \epsilon * (T_s^4 - T_a^4) \quad \text{Ec. 5.2}$$

Donde

$$\epsilon = \epsilon_v * P_v + \epsilon_g(1 - P_v)(1 - 1.74 * P_v) + 1.7372 * P_v * (1 - P_v) \quad \text{Ec. 5.3}$$

$$P_v = \left[\frac{NDVI - NDVI_{Min}}{NDVI_{Max} - NDVI_{Min}} \right]^2 \quad \text{Ec. 5.4}$$

$$T_s = \frac{T}{1 + 11.5 * \frac{T}{10^2} * \ln(\epsilon)} \quad \text{Ec. 5.5}$$

Donde:

Q_r = Flujo de Calor [W/m²]

τ = Transitividad Atmosférica

ϵ = Emisividad

T_s = Temperatura de Superficie [K]

T_a = Temperatura Ambiente [K]

ϵ_v = Emisividad promedio de la vegetación.

ϵ_g = Emisividad promedio del suelo.

P_v = Fracción de cobertura de suelo.

$NDVI_{Min}$ = Valor mínimo obtenido del NDVI.

$NDVI_{Max}$ = Valor máximo obtenido del NDVI.

El resultado final del cálculo de Flujo de calor se presenta en la Figura 5.21 donde se puede observar que pierde calor sobre gran parte de su superficie. Los valores más elevados de Q_r se encuentran, como era de esperarse, en el cráter del volcán con un valor máximo de 160 W/m^2 . También es posible visualizar tres peñas zonas (parte central inferior en color naranja) con flujos de calor anómalos de 84 W/m^2 contra los 47 y 10 W/m^2 del área que las rodea.

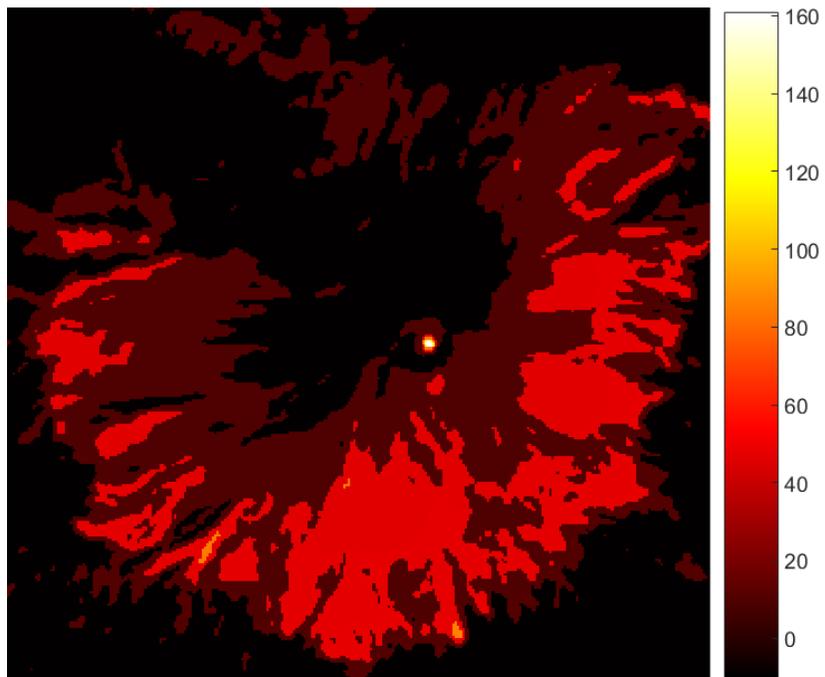


Figura 5.21.- Flujo de Calor (Q_r en W/m^2) de la zona del volcán Popocatépetl.

Capítulo 6: Conclusiones

- Se logró desarrollar un modelo computacional (IPICIM) integrado por diversos módulos para el tratamiento de imágenes ópticas multiespectrales con gran aplicabilidad en el área de las Geociencias.
- Con el IPICIM es posible realizar el Pre-procesamiento orientado a corrección de errores, adecuación y depuración de datos y como segunda fase la generación de contenidos digitales, la cual incluye elaboración de mapas temáticos (cálculo de índices) y el diseño de clasificadores.
- El sistema IPICIM es completamente funcional para todos los satélites de la familia Landsat, requerido por el proyecto AEM-CONACYT.
- Los resultados obtenidos son comparables con SIG de reconocimiento como lo es ENVI y GRASS para los procesos implementados.
- El desarrollo del trabajo representa una innovación tecnológica al desarrollar una plataforma multisensorial para el procesamiento y tratamiento de datos ópticos multiespectrales.
- Con el espectrofotómetro del Laboratorio de Nuevos Materiales Nano y Catálisis Heterogénea se estableció el primer paso para la creación de una base digital de firmas espectrales hecha en México.
- Se realizó un nuevo algoritmo clasificador basado en redes neuronales y acoplamiento de bases digitales.
- Los resultados preliminares sugieren que el desempeño del algoritmo basado en redes neuronales aprovecha las ventajas de los clasificadores convencionales (supervisados y no-supervisados) minimizando sus desventajas al ser un método completamente automático.
- Con el software IPICIM, es sencillo replicar las metodologías reportadas en la literatura para una amplia gama de aplicaciones en el área de geociencias y otras disciplinas.

Capítulo7: Referencias

- Agust, L., Longoria, L., & Maldonado, J. V. (2012). *TRATAMIENTO DE AGUA DEL LAGO DE CHAPALA: EVALUACIÓN TÉCNICA Y ECONÓMICA*.
- Ahn, S. R., Park, J. Y., Lee, J. W., Lee, M. S., Shin, H. J., & Kim, S. J. (2015). Comparison of SWAT streamflow and water quality in an agricultural watershed using KOMPSAT-2 and Landsat land use information. *KSCE Journal of Civil Engineering*, 0(0), 1–9. <http://doi.org/10.1007/s12205-015-1265-4>
- Al-Awadhi, J., & Hersi, A. (2006). Surface runoff hazard map distribution in Kuwait. *Management of Environmental Quality: An International Journal*, 17(1), 20–30. <http://doi.org/10.1108/14777830610639413>
- Alzate, B. E. (2012). Capitulo Ii Indices De Vegetación. *Office of Space Science & Applications*, 1, 29–44. Retrieved from http://www.biblioteca.udep.edu.pe/BibVirUDEP/tesis/pdf/1_59_185_24_508.pdf
- Ao, X., Luo, P., Ma, X., Zhuang, F., He, Q., Shi, Z., & Shen, Z. (2014). Combining supervised and unsupervised models via unconstrained probabilistic embedding. *Information Sciences*, 257, 101–114. <http://doi.org/10.1016/j.ins.2013.08.048>
- Ariza Alexander. (2013). Descripción y Corrección de Productos Landsat 8 LDCM (Landsat Data Continuity Mission). *Centro de Investigación Y Desarrollo En Información Geográfica Del IGAC -CIAF*, 46.
- Aydav, P. S. S., & Minz, S. (2015). Modified Self-Learning with Clustering for the Classification of Remote Sensing Images. *Procedia Computer Science*, 58, 97–104. <http://doi.org/10.1016/j.procs.2015.08.034>
- Baldrige, A. M., Hook, S. J., Grove, C. I., & Rivera, G. (2009). The ASTER spectral library version 2.0. *Remote Sensing of Environment*, 113(4), 711–715. <http://doi.org/10.1016/j.rse.2008.11.007>
- Basaeed, E., Bhaskar, H., & Al-Mualla, M. (2016). Supervised remote sensing image segmentation using boosted convolutional neural networks. *Knowledge-Based Systems*, 99, 19–27. <http://doi.org/10.1016/j.knosys.2016.01.028>
- Buras, A., Thevs, N., Zerbe, S., & Wilmking, M. (2013). Productivity and carbon sequestration of *Populus euphratica* at the Amu River, Turkmenistan. *Forestry*, 86(4), 429–439. <http://doi.org/10.1093/forestry/cpt014>
- Butler, M. J. A., Mouchot, M.-C., Barale, V., & LeBlanc, C. (1990). *Aplicación de la tecnología de percepción remota a las pesquerías marinas: manual introductorio*.
- Chander, G., Markham, B. L., Helder, D. L., & Ali, E.-. (2009). Summary of current radiometric calibration coefficients for Landsat MSS , TM , ETM +, and EO-1 ALI sensors. *Remote Sensing of Environment*, 113(5), 893–903. <http://doi.org/10.1016/j.rse.2009.01.007>
- Chen, Y., Li, X., Liu, X., & Ai, B. (2013). Analyzing land-cover change and corresponding impacts on carbon budget in a fast developing sub-tropical region by integrating MODIS and Landsat TM/ETM+ images. *Applied Geography*, 45, 10–21. <http://doi.org/10.1016/j.apgeog.2013.08.002>
- Chuvieco, E. (1995). *Fundamentos De Teledeteccion Espacial*.

- Cristóbal, J., Jiménez-Muñoz, J. C., Sobrino, J. A., Ninyerola, M., & Pons, X. (2009). Improvements in land surface temperature retrieval from the Landsat series thermal band using water vapor and air temperature. *Journal of Geophysical Research Atmospheres*, 114(8), 1–16. <http://doi.org/10.1029/2008JD010616>
- Effat, H. A., & Hassan, O. A. K. (2014). Change detection of urban heat islands and some related parameters using multi-temporal Landsat images; a case study for Cairo city, Egypt. *Urban Climate*, 10(P1), 171–188. <http://doi.org/10.1016/j.uclim.2014.10.011>
- Escuin, S., Navarro, R., & Fernández, P. (2008). Fire severity assessment by using NBR (Normalized Burn Ratio) and NDVI (Normalized Difference Vegetation Index) derived from LANDSAT TM/ETM images. *International Journal of Remote Sensing*, 29(4), 1053–1073. <http://doi.org/10.1080/01431160701281072>
- Fraser, R., Olthof, I., Carrière, M., Deschamps, A., & Pouliot, D. (2012). A method for trend-based change analysis in Arctic tundra using the 25-year Landsat archive. *Polar Record*, 48(244), 83–93. <http://doi.org/10.1017/S0032247411000477>
- Gitelson, a. a., Stark, R., Grits, U., Rundquist, D., Kaufman, Y., & Derry, D. (2002). Vegetation and soil lines in visible spectral space: A concept and technique for remote estimation of vegetation fraction. *International Journal of Remote Sensing*, 23(13), 2537–2562. <http://doi.org/10.1080/01431160110107806>
- Goel, S., Gaur, M., & Jain, E. (2015). Nature Inspired Algorithms in Remote Sensing Image Classification. *Procedia Computer Science*, 57, 377–384. <http://doi.org/10.1016/j.procs.2015.07.352>
- Gomasasca, M. A. (2009). *Basics of Geomatics*. *Basics of Geomatics*. Springer. <http://doi.org/10.1007/978-1-4020-9014-1>
- Hall, D. K., & Riggs, G. A. (2011). Normalized-Difference Snow Index (NDSI). *Encyclopedia of Snow, Ice and Glaciers*, 779–780. http://doi.org/10.1007/978-90-481-2642-2_376
- Hu, S., Tong, L., Frazier, A. E., & Liu, Y. (2015). Urban boundary extraction and sprawl analysis using Landsat images: A case study in Wuhan, China. *Habitat International*, 47, 183–195. <http://doi.org/10.1016/j.habitatint.2015.01.017>
- Hu, Y., & Jia, G. (2010). Influence of land use change on urban heat island derived from multi-sensor data. *International Journal of Climatology*, 30(9), 1382–1395. <http://doi.org/10.1002/joc.1984>
- Hugh D., Y., Roger A., F., & A. Lewis, F. (2009). *Física Universitaria con física moderna*, 2, 708.
- Im, D. J., & Taylor, G. W. (2015). Semisupervised Hyperspectral Image Classification via Neighborhood Graph Learning. *IEEE Geoscience and Remote Sensing Letters*, 12(9), 1913–1917. <http://doi.org/10.1109/LGRS.2015.2438227>
- JRC. (2011). NDWI (Normalized Difference Water Index). *Product Fact Sheet*, 5(July), 6–7.
- Khattab, M. F. O., & Merkel, B. J. (2014). Application of landsat 5 and landsat 7 images data for water quality mapping in Mosul Dam Lake, Northern Iraq. *Arabian Journal of Geosciences*, 7(9), 3557–3573. <http://doi.org/10.1007/s12517-013-1026-y>
- Kolios, S., & Stylios, C. D. (2013). Identification of land cover/land use changes in the greater area of the Preveza peninsula in Greece using Landsat satellite data. *Applied Geography*, 40, 150–160. <http://doi.org/10.1016/j.apgeog.2013.02.005>

- Lemmens, M. (2011). *Geo-information: Technologies, Applications and the Environment*. Springer Science & Business Media. Retrieved from https://books.google.com/books?id=n_tUAWYg4UQC&pgis=1
- Li, M. (2014). A Review of Remote Sensing Image Classification Techniques: the Role of Spatio-contextual Information. *European Journal of Remote Sensing*, 389–411. <http://doi.org/10.5721/EuJRS20144723>
- LI, S., ZHENG, Z., WANG, Y., CHANG, C., & Yufeng, Y. U. (2016). A new hyperspectral band selection and classification framework based on combining multiple classifiers. *Pattern Recognition Letters*. <http://doi.org/10.1016/j.patrec.2016.05.013>
- Lira, J. (1997). *La Percepción Remota. Nuestros ojos desde el espacio. La Ciencia para Todos* (Vol. 33).
- Liu, Y., Li, M., Mao, L., Xu, F., & Huang, S. (2006). Review of remotely sensed imagery classification patterns based on object-oriented image analysis. *Chinese Geographical Science*, 16(3), 282–288. <http://doi.org/10.1007/s11769-006-0282-0>
- Mapper, L. T., Tm, L., Handbook, R. S., Management, T. C., Bank, C., Dn, T., ... Turks, T. (1990). 3 : RADIOMETRIC CORRECTION OF SATELLITE IMAGES : WHEN AND WHY RADIOMETRIC CORRECTION IS NECESSARY Aim of Lesson The Bilko for Windows image processing software Image data. *Time*, 1(November), 79–102.
- Mei, S., He, M., Wang, Z., & Feng, D. D. (2014). Unsupervised Spectral Mixture Analysis of Highly Mixed Data With Hop fi eld Neural Network, 7(6), 1922–1935. <http://doi.org/10.1109/JSTARS.2013.2281414>
- Mia, M. B., Nishijima, J., & Fujimitsu, Y. (2014). Exploration and monitoring geothermal activity using Landsat ETM+images. *Journal of Volcanology and Geothermal Research*. <http://doi.org/10.1016/j.jvolgeores.2014.02.008>
- Ottinger, M., Kuenzer, C., Liu, G., Wang, S., & Dech, S. (2013). Monitoring land cover dynamics in the Yellow River Delta from 1995 to 2010 based on Landsat TM. *Applied Geography*, 44, 53–68. <http://doi.org/10.1016/j.apgeog.2013.07.003>.
- Pope, A., & Rees, G. (2014). Using in situ spectra to explore landsat classification of glacier surfaces. *International Journal of Applied Earth Observation and Geoinformation*, 27(PARTA), 42–52. <http://doi.org/10.1016/j.jag.2013.08.007>
- R., P. K. E. B. (2010). Supervised classification performance of multispectral images. *Journal of Computing*, 2(2), 126–129. Retrieved from <HTTPS://sites.google.com/SITE/JOURNALOFCOMPUTING/>
- Rahman, A., & Verma, B. (2013). Cluster-based ensemble of classifiers. *Expert Systems*, 30(3), 270–282. <http://doi.org/10.1111/j.1468-0394.2012.00637.x>
- Richards, J. a. (2013). Image Classification in Practice. In *Remote Sensing Digital Image Analysis* (pp. 381–435). <http://doi.org/10.1007/978-3-642-30062-2>
- Rodriguez, Á. N. (2015). *Estimación de biomasa arborea por medio de índices de vegetación para el Parque Nacional Natural La Paya. The effects of brief mindfulness intervention on acute pain experience: An examination of individual difference* (Vol. 1).
- Tahir, A. A. (2012). Integrating artificial neural network and classical methods for unsupervised classification of optical remote sensing data. *EURASIP Journal on Advances in Signal*

Processing, 2012(1), 165. <http://doi.org/10.1186/1687-6180-2012-165>

USGS. (2004). The Normalized Burn Ratio (NBR) - Brief Outline of Processing Steps. *FIREMON BR Cheat Sheet V4, 1300*(June), 2004. Retrieved from http://burnseverity.cr.usgs.gov/pdfs/LAv4_BR_CheatSheet.pdf

Weng, Q. (2012). *An Introduction to Contemporary Remote Sensing*. The McGraw-Hill Companies.

Xiao, X., Shen, Z., & Qin, X. (2001). Assessing the potential of VEGETATION sensor data for mapping snow and ice cover: A Normalized Difference Snow and Ice Index. *International Journal of Remote Sensing*, 22(13), 2479–2487. <http://doi.org/10.1080/01431160119766>

Zhang, C., & Xie, Z. (2012). Combining object-based texture measures with a neural network for vegetation mapping in the Everglades from hyperspectral imagery. *Remote Sensing of Environment*, 124, 310–320. <http://doi.org/10.1016/j.rse.2012.05.015>

Anexo 1: Tabla Elementos Base De Datos ASTER.

type	class	subclass	name	
Soils	Alfisol	Fragiboralf	Pale brown silty loam	
		Haploxeralf	Brown to dark brown gravelly loam	
		Haplustalf	Brown loamy fine sand	
			Brown fine sandy loam	
			Paleustalf	Dark reddish brown fine sandy loam
		Aridisol	Calciorthid	Reddish brown fine sandy loam
				Brown sandy loam
				Light yellowish brown interior dry gravelly loam
			Camborthid	Light yellowish brown loam
	Brown silty loam			
	Gypsiorthid		Light yellowish brown loamy sand	
			Very pale brown to brownish yellow interior dry gravelly silt loam	
	Haplargid		Brown gravelly sandy loam	
	Salorthid		Dark brown interior moist clay loam	
			Light yellowish brown clay	
		Dark yellowish brown silty clay		
	Entisol	Torripsamment	Very dark grayish brown loamy sand	
		Quartzipsamment	Brown to dark brown sand	
		Torripsamment	White gypsum dune sand	
Inceptisol	Ustifluent	Brown to dark brown silt loam		
	Cryumbrept	Gray/dark brown extremely stoney coarse sandy		
		Dystrochrept	Dark yellowish brown micaceous loam	
	Haplumbrept	Dark brown fine sandy loam		
		Brown sandy loam		
	Plaggept	Very dark grayish brown silty loam		
	Ustocrept	Pale brown dry silty clay loam		
	Xerumbrept	Brown to dark brown gravelly fine sandy loam		
	Mollisol	Agialboll	Dark grayish brown silty loam	
Agriudoll		Vary dark grayish brown loam		
Argiustoll		Very dark grayish brown silty loam		
Cryoboroll		Black loam		
		Very dark grayish brown loam		
Haplaquoll		Gray silty clay		
Hapludoll		Brown to dark brown sandy loam		
Haplustall	Grayish brown loam			

		Paleustoll	Very dark grayish brown loam
	Spodosol	Cryohumod	Dark reddish brown, organic-rich, silty loam
	Utisol	Hapludult	Brown to dark brown loamy sand
	Vertisol	Chromoxerert	Brown to dark brown clay
Frost, Snow and Ice	Frost	None	Frost
	Ice	None	Ice
	Snow	Fine snow	Fine Snow
		Medium Granular	Medium Granular Snow
		Coarse Granular	Coarse Granular Snow
Vegetation	Grasses	Dry grass	Dry grass
		Green grass	Grass
	Trees	Conifers	Conifer
		Deciduous	Deciduous
Rocks	Igneous	Felsic	Aplite
			Alkalic Granite
			Granite
			Rhyolite
			Obsidian
			Tuff
			Aporhyolite (felsite)
			Rhyolite Porphyry
			Quartz Felsite Porphyry
			Porphyritic Biotite Granite
			Biotite Granite
			Muscovite-Biotite Granite
			Hornblende Granite
			Pegmatite
			Alkali Granite
			Altered volcanic tuff
		Intermediate	Augite-hypersthene Andesite
			Basaltic Andesite
			Diorite
			Granodiorite
			Monzonite
			Rhyolitic obsidian
			Quartz Monzonite
			Alkalic Syenite
			Nepheline Syenite
			Tonalite (Bonsall Tonalite)
			Quartz Monzonite Porphyry
			Mica Dacite Porphyry
			Andesite Breccia

		Andesite Porphyry
		Diorite Porphyry
	Mafic	Anorthosite
		Unaltered volcanic tuff?
		Basalt
		Diabase
		Gabbro
		Lamprophyre
		Norite
		Anorthosite
		Basanite
		Alkali Basalt
	Ultramafic	Dunite
		Ijolite
		Picrite
		Pyroxenite
		Dunite (Olivine Peridotite)
		Mica Peridotite
		Augite-Mica Peridotite
	Alkalic	Trachyte
		Syenite
		Hornblende Syenite
		Nepheline-Sodalite Syenite
	Basic	Amygdaloidal Basalt
		Scoria
Metamorphic	Gneiss	Chloritic Gneiss
		Garnet Gneiss
		Felsitic Gneiss
		Syenite Gneiss
		Albite Gneiss
		Hornblende Gneiss
		Diorite Gneiss
		Augen Gneiss
		Biotite Gneiss
		Sillimanite-Garnet Gneiss
		Granitoid Gneiss
	Hornfels	Banded Hornfels
		Hornfels
		Spotted Hornfels
	Marble	Dolomitic Marble
		Serpentine Marble
		Marble
		Dolomite Marble
		White Marble
		Pink Marble
		Verde Antique

	Phyllite	Phyllite
	Quartzite	Red Quartzite
		Green Quartzite
		Pink Quartzite
		Purple Quartzite
		Gray Quartzite
		Quartzite
	Schist	Green Schist
		Hornblende Schist
		Mica Schist
		Tourmaline Schist
		Graphite Schist
		Tremolite Schist
		Chlorite Schist
		Anthophyllite Mica Schist
		Garnetiferous Mica Schist
		Tourmaline-Mica Schist
		Quartz-Sericite Schist
		Biotite Schist
	Slate	Gray Slate
		Green Slate
		Chiastolic Slate
		Red Slate
	None	Serpentine
Sedimentary	Limestone	Fossiliferous Limestone
		Dolomitic Limestone
		Limestone
		Oolitic Limestone
		Lithographic Limestone
		Argillaceous Limestone
		Ecrinal Limestone
		Chalk
		Chocolate "Marble" Limestone
		Gray Limestone (Birdseye Limestone)
		Cherty Limestone
		Travertine (Calcareous Tufa)
		Limestone CaCO ₃
	Sandstone	Greywacke Sandstone
		Arkosic Sandstone
		Glaucconitic Sandstone
		Sandstone (Micaceous Red)
		Ferruginous Sandstone
		Purple-banded Sandstone
		Sandstone (Red)
		Gray Sandstone
		Red Sandstone

			Micaceous Sandstone (Brownstone)
			Sandstone (Flagstone)
			Arkose
			Argillaceous Sandstone
	Shale		Shale (Arenaceous)
			Shale (Phosphatic)
			Shale (Calcareous)
			Black Shale
			Illite-bearing Shale
			Carbonaceous Shale
			Argillaceous Shale
			Calcareous Shale
			Arenaceous Shale
			Oil Shale (Kerogen Shale)
			Phosphorite
	Siltstone		Siltstone
			Limestone Siltstone
	Travertine		Travertine
	Breccia		Limestone Breccia
	Chemical precipitate		Gypsum
			Oolitic Iron Ore
	Conglomerate		Quartz Conglomerate
			Limestone Conglomerate-Breccia
	Siliceous		Diatomaceous Earth
			Siliceous Oolite
	dolomite		Dolomite CaMgCO ₃
	Intermediate	Felsic	Dacite
Manmade Materials	Road Asphalts and Tar	Paving Asphalts	Construction Asphalt
		Tar	Construction Tar
	Concretes	Construction Concrete	Construction Concrete
		Paving Concretes	Construction Concrete
			Asphaltic concrete
	General Construction Materials	Bricks	Red smooth-faced Brick
			Weathered Red Brick
			Bare Red Brick
		Cement Cinderblock	Construction Concrete
		Cinders	Cinders, ashen
		Glass	Plate Window Glass
		Marble	White Marble

		Paints	Olive green gloss paint
			Black gloss paint
			Black paint
			Olive green paint
		Woods	Pine Wood
Roofing Materials		Metal	Aluminum Metal
			Galvanized Steel Metal
			Oxidized Galvanized Steel Metal
			Copper Metal
		Roofing Paper	Black tar paper
		Rubber	White rubberized coating
			Black unspecified rubber
			White fiberglass unspecified rubber
		Roofing Shingle	Asphalt Shingle
		Shingle	Asphalt roofing shingle
			Reddish Asphalt roofing shingle
			Slate stone Shingle
			Reddish asphalt Shingle
		Tile	Terra cotta Tiles
Mineral	Carbonates	None	Strontianite SrCO_3
			Witherite BaCO_3
			Calcite CaCO_3
			Trona $\text{Na}_3(\text{CO}_3)(\text{HCO}_3) \cdot 2\text{H}_2\text{O}$
			Dolomite $\text{CaMg}(\text{CO}_3)_2$
			Magnesite MgCO_3
			Malachite $\text{Cu}_2(\text{CO}_3)(\text{OH})_2$
			Rhodochrosite MnCO_3
			Siderite $\text{Fe}^{2+}\text{CO}_3$
			Cerussite PbCO_3
			Smithsonite PbCO_3
			Azurite $\text{Cu}_3(\text{CO}_3)_2(\text{OH})_2$
			Natron $\text{Na}_2\text{CO}_3 \cdot 10\text{H}_2\text{O}$
			Burkeite $\text{Na}_6(\text{CO}_3)(\text{SO}_4)_2$
			Trona $\text{Na}_3(\text{CO}_3)(\text{HCO}_3) \cdot 2\text{H}_2\text{O}$
	Halides	None	Cryolite Na_3AlF_6
			Fluorite CaF_2
			Halite NaCl
			Atacamite $\text{Cu}_2\text{Cl}(\text{OH})_3$
	Hydroxides	None	Brucite $\text{Mg}(\text{OH})_2$
			Goethite $\alpha\text{Fe}^{3+}\text{O}(\text{OH})$
			Gibbsite $\text{Al}(\text{OH})_3$
	Oxides	None	Hematite $\alpha\text{Fe}_2\text{O}_3$
			Rutile TiO_2
			Cassiterite SnO_2
			Magnetite $\text{Fe}^{2+}\text{Fe}_2^{3+}\text{O}_4$

		Pyrolusite MnO ₂
		Columbite Fe ²⁺ Nb ₂ O ₆
		Magnesiochromite MgCr ₂ O ₄
		Gahnite ZnAl ₂ O ₄
		Anatase TiO ₂
		Zincite (Zn,Mn)O
		Periclase MgO
		Corundum Al ₂ O ₃
Silicates	Cyclosilicates	Tourmaline Na(Mg ₃ ,Fe ₃ ²⁺)Al ₆ (BO ₃) ₃ Si ₆ O ₁₈ (OH) ₄
		Beryl Be ₃ Al ₂ Si ₆ O ₁₈
		Cordierite Mg ₂ Al ₃ (Si ₅ Al)O ₁₈
		Ferroaxinite Ca ₂ Fe ²⁺ Al ₂ BSi ₄ O ₁₅ (OH)
	Inosilicates	Rhodonite (Mn,Ca)SiO ₃
		Wollastonite CaSiO ₃
		Glaucophane Na ₂ (Mg,Fe ²⁺) ₃ Al ₂ Si ₈ O ₂₂ (OH) ₂
		Actinolite Ca ₂ (Mg,Fe ²⁺) ₅ Si ₈ O ₂₂ (OH) ₂
		Tremolite Ca ₂ (Mg,Fe ²⁺) ₅ Si ₈ O ₂₂ (OH) ₂
		Cummingtonite (Mg,Fe ²⁺) ₇ Si ₈ O ₂₂ (OH) ₂
		Riebeckite Na ₂ (Fe ²⁺ ,Mg) ₃ Fe ₂ ³⁺ Si ₈ O ₂₂ (OH) ₂
		Anthophyllite (Mg,Fe ²⁺) ₇ Si ₈ O ₂₂ (OH) ₂
		Diopside CaMg(SiO ₃) ₂
		Enstatite Mg ₂ (SiO ₃) ₂
		Johannsenite Ca(Mn,Fe ²⁺)(SiO ₃) ₂
		Spodumene LiAlSi ₂ O ₆
		Hypersthene (Mg,Fe ²⁺) ₂ Si ₂ O ₆
		Augite (Ca,Na)(Mg,Fe,Al,Ti)(Si,Al) ₂ O ₆
	Nesosilicates	Fayalite Fe ₂ SiO ₄
		Forsterite Mg ₂ SiO ₄
		Grossular Garnet Ca ₃ Al ₂ (SiO ₄) ₃
		Almandine Garnet Fe ₃ Al ₂ (SiO ₄) ₃
		Topaz Al ₂ SiO ₄ (F,OH) ₂
		Titanite (Sphene) CaTiSiO ₅
		Sillimanite Al ₂ SiO ₅
		Zircon ZrSiO ₄
	Phyllosilicates	Sepiolite Mg ₄ Si ₆ O ₁₅ (OH) ₂ ·6H ₂ O

	Nontronite Na _{0.33} Fe ₂ ³⁺ (Si,Al) ₄ O ₁₀ (OH) ₂ ·H ₂ O
	Pyrophyllite Al ₂ Si ₄ O ₁₀ (OH) ₂
	Kaolinite Al ₂ Si ₂ O ₅ (OH) ₄
	Cookeite LiAl ₄ (Si ₃ Al)O ₁₀ (OH) ₈
	Montmorillonite (Na,Ca) _{0.33} (Al,Mg) ₂ Si ₄ O ₁₀ (OH) ₂ ·H ₂ O
	Dickite Al ₂ Si ₂ O ₅ (OH) ₄
	Palygorskite (Mg,Al) ₂ Si ₄ O ₁₀ (OH) ₄ ·4H ₂ O
	Corrensite (Mg,Fe) ₉ (Si,Al) ₈ O ₂₀ (OH) ₁₀ ·xH ₂ O
	Illite (K,H ₃ O)(Al,Mg,Fe) ₂ (Si,Al) ₄ O ₁₀ ((OH) ₂ ·H ₂ O)
	Lepidolite K(Li,Al) ₃ (Si,Al) ₄ O ₁₀ (F,OH) ₂
	Clinochlore (Chlorite) (Mg,Al) ₆ (Si,Al) ₄ O ₁₀ (OH) ₈
	Lepidolite K(Li,Al) ₃ (Si,Al) ₄ O ₁₀ (F,OH) ₂
	Chlorite
	Talc Mg ₃ Si ₄ O ₁₀ (OH) ₂
	Muscovite KAl ₂ (Si ₃ Al)O ₁₀ (OH,F) ₂
	Vermiculite (Mg,Fe ²⁺ ,Al) ₃ (Al,Si) ₄ O ₁₀ (OH) ₂ ·4H ₂ O
	Glaucanite (K,Na)(Fe ³⁺ ,Al,Mg) ₂ (Si,Al) ₄ O ₁₀ (OH) ₂
	Serpentine (Mg,Fe ²⁺ ,Ni)Si ₂ O ₅ (OH) ₄
	Prehnite Ca ₂ Al ₂ Si ₃ O ₁₀ (OH) ₂
	Hydroxyapophyllite KCa ₄ Si ₈ O ₂₀ (OH,F) ₈ ·8H ₂ O
	Biotite K(Mg,Fe ²⁺) ₃ (Al,Fe ³⁺)Si ₃ O ₁₀ (OH,F) ₂
	Saponite (Ca/2,Na) _{0.33} (Mg,Fe ²⁺) ₃ (Si,Al) ₄ O ₁₀ (OH) ₂ ·4H ₂ O
Sorosilicate	Epidote Ca ₂ (Al,Fe ³⁺) ₃ SiO ₄ Si ₂ O ₇ ·OH
	Hemimorphite Zn ₄ Si ₂ O ₇ (OH) ₂ ·H ₂ O
	Vesuvianite Ca ₁₀ (Mg,Fe ²⁺) ₂ Al ₄ (Si ₂ O ₇) ₂ (SiO ₄) ₅ (OH,F) ₄
	Clinozoisite Ca ₂ Al ₃ (SiO ₄) ₃ (OH)

	Tectosilicates	Quartz SiO ₂
		Labradorite (Feldspar) (NaSi,CaAl)AlSi ₂ O ₈
		Oligoclase (Feldspar) (NaSi,CaAl)AlSi ₂ O ₈
		Andesine (Feldspar) (NaSi,CaAl)AlSi ₂ O ₈
		Anorthite (Feldspar) (NaSi,CaAl)AlSi ₂ O ₈
		Albite (Feldspar) (K,Na)AlSi ₃ O ₈
		Cristobalite SiO ₂
		Natrolite Na ₂ Al ₂ Si ₃ O ₁₀ .2H ₂ O
		Stilbite NaCa ₂ Al ₅ Si ₃ O ₃₆ .14H ₂ O
		Sodalite Na ₈ Al ₆ Si ₆ O ₂₄ Cl ₂
		Buddingtonite (Feldspar) (NH ₄)AlSi ₃ O ₈ .0.5H ₂ O
		Orthoclase (Feldspar) (K,Na)AlSi ₃ O ₈
		Bytownite (Feldspar) (NaSi,CaAl)AlSi ₂ O ₈
		Sanidine (Feldspar) (K,Na)AlSi ₃ O ₈
		Chabazite CaAl ₂ Si ₄ O ₁₂ .6H ₂ O
		Nepheline (Na,K)AlSiO ₄
		Microcline (Feldspar) (K,Na)AlSi ₃ O ₈
		Analcime NaAlSi ₂ O ₆ .H ₂ O
Sulfates	None	Anhydrite CaSO ₄
		Gypsum CaSO ₄ .2H ₂ O
		Barite BaSO ₄
		Alunite KAl ₃ (SO ₄) ₂ (OH) ₆
		Celestite SrSO ₄
		Tschemmigite (NH ₄)Al(SO ₄) ₂ .12H ₂ O
		Jarosite KFe ₃ ³⁺ (SO ₄) ₂ (OH) ₆
		Glauberite Na ₂ Ca(SO ₄) ₂
		Plumbojarosite PbFe ₃ ³⁺ (SO ₄) ₂ (OH) ₆
		Natrojarosite NaFe ₃ ³⁺ (SO ₄) ₂ (OH) ₆
		Aphthitalite (K,Na) ₃ Na(SO ₄) ₂
		Anglesite PbSO ₄
		Antlerite Cu ₃ (SO ₄)(OH) ₄
Sulfides	None	Sphalerite (Zn,Fe)S
		Pyrite FeS ₂
		Realgar AsS
		Chalcopyrite CuFeS ₂
		Arsenopyrite FeAsS
		Stibnite Sb ₂ S ₃
		Galena PbS
		Chalcocite Cu ₂ S
		Bornite Cu ₅ FeS ₄

		Marcasite FeS ₂
		Molybdenite MoS ₂
		Pyrrhotite Fe _{1-x} S
Arsenates	None	Mimetite Pb ₅ (AsO ₄) ₃ Cl
		Scorodite Fe ³⁺ +AsO ₄ .2H ₂ O
Borates	None	Colemanite Ca ₂ B ₆ O ₁₁ .5H ₂ O
		Kernite Na ₂ B ₄ O ₆ (OH) ₂ .3H ₂ O
		Ulexite NaCaB ₅ O ₆ (OH) ₆ .5H ₂ O
		Tincalconite Na ₂ B ₄ O ₅ (OH) ₄ .3H ₂ O
		Howlite Ca ₂ B ₅ SiO ₉ (OH) ₅
		Borax Na ₂ B ₄ O ₅ (OH) ₄ .8H ₂ O
		Colemanite Ca ₂ B ₆ O ₁₁ * 5H ₂ O
		Gaylussite Na ₂ Ca(CO ₃) ₂ * 5H ₂ O
		Inderite MgB ₃ O ₃ (OH) ₅ * 5H ₂ O
		Kaliborite KHMg ₂ B ₁₂ O ₁₆ (OH) ₁₀ * 4H ₂ O
		Kernite Na ₂ B ₄ O ₆ (OH) ₂ * 3H ₂ O
		Meyerhofferite Ca ₂ B ₆ O ₆ (OH) ₁₀ * H ₂ O
		Pinnoite MgB ₂ O ₄ * 3H ₂ O
		Rivadavite Na ₆ MgB ₂₄ O ₄₀ * 22H ₂ O
		Ulexite NaCaB ₅ O ₆ (OH) ₆ * 5H ₂ O
Elements	None	Graphite C
		Sulphur S
Phosphates	None	Apatite Ca ₅ (PO ₄) ₃ F
		Montebrasite LiAlPO ₄ (OH)
		Amblygonite (Li,Na)Al(PO ₄)(F,OH)
		Triphylite Li(Mn,Fe)PO ₄
Tungstates	None	Scheelite CaWO ₄
Chloride	None	Carnallite KMgCl ₃ * 6H ₂ O
		Kainite MgSO ₄ * KCl * 3H ₂ O

Anexo 2: Tablas Para Cálculo De Radianza Y Reflectancia

Sensores MSS ($Q_{calmin}=0$ y $Q_{calmax}=127$)							
Banda	Rango espectral [μm]	Longitud de onda central [μm]	$L\text{MIN}_\lambda$ [$\text{W} / (\text{m}^2 \text{sr} \mu\text{m})$]	$L\text{MAX}_\lambda$ [$\text{W} / (\text{m}^2 \text{sr} \mu\text{m})$]	$G_{rescale}$ [$(\text{W} / (\text{m}^2 \text{sr} \mu\text{m})) / \text{ND}$]	$B_{rescale}$ [$\text{W} / (\text{m}^2 \text{sr} \mu\text{m})$]	ESUN_λ [$\text{W} / (\text{m}^2 \mu\text{m})$]
Landsat 1							
1	0.499-0.597	0.548	0	2487	1.952760	0	1823
2	0.603-0.701	0.652	0	200	1.574800	0	1559
3	0.694-0.800	0.747	0	176	1.385830	0	1276
4	0.810-0.989	0.900	0	153	1.204720	0	880.1
Landsat 2							
1	0.497-0.598	0.548	8	263	2.007870	8	1829
2	0.607-0.710	0.659	6	176	1.338580	6	1539
3	0.697-0.802	0.750	6	152	1.149610	6	1268
4	0.807-0.990	0.899	3.66667	130.333	0.997373	3.66667	886.6
Landsat 3							
1	0.497-0.593	0.545	4	259	2.007870	4	1839
2	0.606-0.705	0.656	3	179	1.385830	3	1555
3	0.693-0.793	0.743	3	149	1.149610	3	1291
4	0.812-0.979	0.896	1	0.997373	1.000000	1	887.9
Landsat 4							
1	0.495-0.605	0.550	4	238	1.842520	4	1827
2	0.603-0.696	0.650	4	164	1.259840	4	1569
3	0.701-0.813	0.757	5	142	1.078740	5	1260
4	0.808-1.023	0.916	4	116	0.881890	4	866.4
Landsat 5							
1	0.497-0.607	0.552	3	268	2.086610	3	1824
2	0.603-0.697	0.650	3	179	1.385830	3	1570
3	0.704-0.814	0.759	5	148	1.125980	5	1249
4	0.809-1.036	0.923	3	123	0.944882	3	853.4

Sensores TM ($Q_{calmin}=1$ y $Q_{calmax}=255$)							
Banda	Rango espectral [μm]	Longitud de onda central [μm]	$L\text{MIN}_\lambda$ [$\text{W} / (\text{m}^2 \text{sr} \mu\text{m})$]	$L\text{MAX}_\lambda$ [$\text{W} / (\text{m}^2 \text{sr} \mu\text{m})$]	$G_{rescale}$ [$(\text{W} / (\text{m}^2 \text{sr} \mu\text{m})) / \text{ND}$]	$B_{rescale}$ [$\text{W} / (\text{m}^2 \text{sr} \mu\text{m})$]	ESUN_λ [$\text{W} / (\text{m}^2 \mu\text{m})$]
Landsat 4 (NLAPS)							
1	0.452-0.518	0.485	-1.52	152.10	0.602431	-1.52	1983
2	0.529-0.609	0.569	-2.84	296.81	1.175098	-2.84	1795
3	0.624-0.693	0.659	-1.17	204.30	0.805765	-1.17	1539
4	0.776-0.905	0.841	-1.51	206.20	0.814549	-1.51	1028
5	1.568-1.784	1.676	-0.37	27.19	0.108078	-0.37	219.8
6	10.42-11.66	11.040	1.2378	15.3032	0.055158	1.2378	N/A
7	2.097-2.347	2.222	-0.15	14.38	0.056980	-1.15	83.49
Landsat 4 (LPGS)							
1	0.452-0.518	0.485	-1.52	163	0.647717	-2.17	1983
2	0.529-0.609	0.569	-2.84	336	1.334016	-4.17	1795
3	0.624-0.693	0.659	-1.17	254	1.004606	-2.17	1539
4	0.776-0.905	0.841	-1.51	221	0.876024	-2.39	1028
5	1.568-1.784	1.676	-0.37	31.4	0.125079	-0.50	219.8
6	10.42-11.66	11.040	1.2378	15.3032	0.055376	1.2378	N/A
7	2.097-2.347	2.222	-0.15	16.6	0.065945	-0.22	83.49
Landsat 5 (LPGS)							
1	0.452-0.518	0.485	-1.52	169	0.671339	-2.19	1983
2	0.528-0.609	0.569	-2.84	333	1.322205	-4.16	1796
3	0.626-0.693	0.660	-1.17	264	1.043976	-2.21	1536
4	0.776-0.904	0.840	-1.51	221	0.876024	-2.39	1031
5	1.567-1.784	1.676	-0.37	30.2	0.120354	-0.49	220.0
6	10.45-12.42	11.435	1.2378	15.3032	0.055376	1.18	N/A
7	2.097-2.349	2.223	-0.15	16.5	0.06551	-0.22	83.44

Sensores ETM+ ($Q_{calmin}=1$ y $Q_{calmax}=255$)							
Banda	Rango espectral [μm]	Longitud de onda central [μm]	LMIN$_{\lambda}$ [W / (m² sr μm)]	LMAX$_{\lambda}$ [W / (m² sr μm)]	G_{rescale} [(W / (m² sr μm)) / ND]	B_{rescale} [W / (m² sr μm)]	ESUN$_{\lambda}$ [W / (m² μm)]
Low Gain							
1	0.452-0.514	0.483	-6.2	293.7	1.180709	-7.38	1997
2	0.519-0.601	0.560	-6.4	300.9	1.209843	-7.61	1812
3	0.631-0.692	0.662	-5.0	234.4	0.942520	-5.94	1533
4	0.772-0.898	0.835	-5.1	241.1	0.969291	-6.07	1039
5	1.547-1.748	1.648	-1.0	47.57	0.191220	-1.19	230.8
6	10.31-12.36	11.335	0.0	17.04	0.067087	-0.07	N/A
7	2.065-2.346	2.206	-0.35	16.54	0.066496	-0.42	84.90
PAN	0.515-0.896	0.706	-4.7	243.1	0.975591	-5.68	1362
High Gain							
1	0.452-0.514	0.483	-6.2	191.6	0.778740	-6.98	1997
2	0.519-0.601	0.560	-6.4	196.5	0.798819	-7.20	1812
3	0.631-0.692	0.662	-5.0	152.9	0.621654	-5.62	1533
4	0.772-0.898	0.835	-5.1	157.4	0.639764	-5.74	1039
5	1.547-1.748	1.648	-1.0	31.06	0.126220	-1.13	230.8
6	10.31-12.36	11.335	0.0	12.65	0.037205	3.16	N/A
7	2.065-2.346	2.206	-0.35	10.80	0.043898	-0.39	84.90
PAN	0.515-0.896	0.706	-4.7	158.3	0.641732	-5.34	1362