



U

P

T

# Diseño e implementación de índices multibanda para el monitoreo de recursos naturales

por

**Mario Martin Arreola Esquivel**

Tesis sometida como requisito parcial para obtener el  
grado de:

**Maestro en computación óptica**

en la

**Universidad Politécnica de Tulancingo**

2019

Tulancingo de Bravo, Hidalgo.

Supervisada por:

**Dra. Carina Toxqui Quitl**

**Dr. Alfonso Padilla Vivanco**

©UPT

El autor otorga a la UPT el permiso de reproducir y  
distribuir copias en su totalidad o en partes de esta  
tesis.



UNIVERSIDAD  
POLITÉCNICA  
TULANCINGO

# Dedicatoria

Ama, perdona y olvida. Dedicar es un privilegio que en este momento me permite Dios y la vida. Este trabajo está dedicado a mi esposa, hermanos y amigos que me apoyan todos los días en las buenas y en las malas, me brindan consejos y con los cuales comparto hermosos momentos.

*La vida pone obstáculos, pero tú  
pones los límites.*

*Anónimo.*



# Agradecimientos

A la Universidad Politécnica de Tulancingo, por el apoyo brindado durante el tiempo que desarrolle mi trabajo de investigación.

Al Consejo Nacional de Ciencia y Tecnología (CONACyT), por la beca otorgada con CVU: 858585, y la beca de movilidad para la realización de una estancia de investigación en el Politécnico de Turín.

A la Dra. Anna Carbone del Polito di Torino por el apoyo económico durante la estancia de investigación en el Departamento de tecnología y ciencia aplicada, durante los periodos de octubre-noviembre del 2018 y mayo-junio del 2019.

A mis asesores Dra. Carina Toxqui Quitl y Dr. Alfonso Padilla Vivanco por sus enseñanzas, comentarios, dedicación y sugerencias durante cada etapa de la Maestría en Computación Óptica.

A mis profesores por su enseñanza y conocimientos que nos brindan para poder ser mejores y que dejan una huella en cada uno de nosotros.



# Prefacio

Conocer y entender los cambios que sufre nuestro planeta a través del tiempo, ha sido y continúa siendo un reto para el ser humano. Las misiones Landsat proveen registros multiespectrales de la tierra por más de 30 años. El rápido desarrollo tecnológico, permite a los satélites y sus sensores multiespectrales abordar, proveer datos de mayor calidad y exactitud. Incluso, en nuestros tiempos es posible comparar escenas registradas por diferentes tecnologías satelitales (ejemplo, Landsat 5 *TM*, Landsat 8 *OLI* y Sentinel-2 *MSI*). La percepción remota, se enfrenta al cambio dinámico del entorno natural, que se hace cada vez más complejo, conforme aumenta la sobreexplotación de recursos naturales. Este cambio puede ser analizado y medido con exactitud utilizando datos satelitales multiespectrales. En conjunto, las bases de datos satelitales de Landsat y Sentinel-2, contienen datos repetitivos que ayudan a tener un monitoreo a largo plazo de una/múltiples escenas en todo el planeta.

Los datos Landsat y Sentinel-2, pueden ser analizados e interpretados mediante técnicas de interpretación visual y algoritmos computacionales. Esta tesis se divide en 5 capítulos. En el primer capítulo se hace una introducción a la percepción remota satelital, y su utilidad en el monitoreo de los recursos naturales. Se retoma el estado del arte de los métodos existentes en el área de la delimitación y extracción de recursos naturales y construcción. Se justifica la investigación realizada, así como el planteamiento, los objetivos y productos derivados de la tesis.

En el segundo capítulo, se revisa el diseño de algunos de los sistemas utilizados en la percepción remota satelital. Se explora el proceso físico de formación de imágenes satelitales. A partir de la descarga de los datos multiespectrales Landsat y Sentinel-2, se plantea el nivel de pasos de preprocesamiento en las imágenes multiespectrales utilizadas. Dentro de los pasos de preprocesamiento: se implementa un procedimiento para seleccionar la misma Región de Interés (RoI) registrada en diferente hora, fecha y sensor satelital mediante programación en Matlab y el software *ENVI*. Se revisa el proceso para convertir los *DN* a la radiancia en la apertura del sensor satelital. Así como la conversión de radiancia a reflectancia *TOA*. Se aplica la corrección atmosférica *IARR* a datos Landsat 5 *TM* y Sentinel-2.

En el tercer capítulo se hace una introducción al análisis de firmas espectrales de los diferentes materiales utilizando datos hiperespectrales *AVIRIS*. Posteriormente, se muestra la selección de un pixel multiespectral utilizando datos satelitales Landsat 5 *TM* y se muestra su respectiva firma espectral. Se revisa la metodología de los algoritmos computacionales *IDN* e *IMB*. Así como la expresión matemática de los métodos propuestos *AWI - MS* y *ASI - MS*.

En el cuarto capítulo se analizan las regiones para la extracción de cuerpos de agua, utilizando datos satelitales Landsat 5 *TM*, Landsat 8 *OLI* y Sentinel-2 *MSI*. Se aplica un valor de umbral óptimo obtenido por Acharya, para escenas de alta diversidad geográfica. Así como la selección de un *HTV* óptimo en datos *TM*, *OLI* y *MSI*. Utilizando los índices *IDN/IMB* definidos en el Capítulo 3, se segmenta la Región de Interés *RoI* de vegetación, cuerpos de agua, nieve y construcción según el caso, y se determina el porcentaje de cobertura en el área analizada. A partir de esto, se determina la variabilidad temporal y espacial de la *RoI*. Finalmente, en el quinto capítulo se presentan las conclusiones generales de la tesis y trabajos a futuro.

# Resumen

La detección de cambios en los cuerpos de agua, la superficie de la nieve y la vegetación son excelentes indicadores de la alteración ambiental natural. La percepción remota satelital, nos permite observar los cambios ambientales que sufre la superficie de la tierra a través del tiempo. Los datos satelitales Landsat y Sentinel-2, pueden ser utilizados para lograr este objetivo a largo plazo en cualquier región del mundo. En la presente investigación, se utilizan imágenes multiespectrales provenientes de los satélites Landsat y Sentinel-2, para monitorizar recursos naturales (agua, nieve y vegetación) y construcción a través del tiempo en distintas regiones del mundo. Para lograr este objetivo, se utilizan los algoritmos computacionales de segmentación  $NDVI$ ,  $MNDWI$ ,  $AWEI_{nsh}$ ,  $NDSI$  y  $NDBI$  basados en el valor de umbral óptimo. Mediante la supervisión visual, se observan las ventajas y desventajas de los  $IDN/IMB$  y se proponen los métodos  $AWI-MS$  y  $ASI-MS$ , fundamentados en la diferencia normalizada de bandas espectrales. Los resultados de la región de España muestran un rango de porcentaje de [12.680496 %, 23.624731 %], que tiene que ver con el aumento de vegetación a través del tiempo. El monitoreo del lago Metztitlán, arroja un porcentaje estadístico variable de [16.280024 %, 9.884537 %, 30.703616 %], correspondiente a la variabilidad de la cantidad de agua que el lago tiene a través del tiempo. El lago Poopó tiene un porcentaje de píxeles de agua decreciente de [30.501142 %, 19.835817 %], como resultado a la pérdida de agua que el lago tiene en el transcurso de los años. La región de Groenlandia tiene un rango de [31.899568 %, 24.343846 %], correspondiente al deshielo de esta región. Por último, la creciente ciudad de Moscú muestra un porcentaje de [21.2982 %, 36.1528 %], con respecto al progresivo incremento en la urbanización de esta ciudad.

# Abstract

Water body, snow surface and plant density change detection are an excellent indicators of the natural environmental alteration. Remote satellite perception, allows us to observe the environmental changes that the earth's surface undergoes over time. Landsat and Sentinel-2 satellite remote sensing data can be used to achieve this long-term goal worldwide. In the present investigation, Landsat and Sentinel-2 multispectral satellite images are used to monitor natural resources (water, snow and vegetation), and build-up over time in different regions of the world. To achieve this objective, the optimal threshold-based  $NDVI$ ,  $MNDWI$ ,  $AWEI_{nsh}$ ,  $NDSI$  and  $NDBI$  methods are used. Through visual inspection, the advantages and disadvantages of the  $IDN/IMB$  are observed, and the  $AWI - MS$  and  $ASI - MS$  methods are proposed, based on the normalized spectral band difference. The results of the Spain region show an increasing percentage range of [12,680496 %, 23,624731 %], due to the increasing vegetation cover over time. Lake Metztitlán monitoring, shows a statistical percentage of [16.280024 %, 9.884537 %, 30.703616 %] corresponding to the variability in the amount of water that the lake has over time. Lake Poopó has a decreasing percentage of water pixels of [30.501142 %, 19.835817 %], as a result of the loss of water that the lake has lost over the years. The Greenland region has a range of [31.899568 %, 24.343846 %], corresponding to the thaw of this region. Lastly, the growing city of Moscow shows a percentage of [21.2982 %, 36.1528 %], with respect to the progressive urban increase through the years.

# Índice general

Dedicatoria	I
Agradecimientos	III
Prefacio	V
Resumen	VII
Abstract	VIII
Índice de Figuras	XII
Índice de Tablas	XVII
<b>1. Antecedentes generales</b>	<b>1</b>
1.1. Introducción . . . . .	1
1.2. Percepción remota . . . . .	2
1.2.1. Misiones Landsat . . . . .	4
1.2.2. Misiones Sentinel-2 . . . . .	7
1.3. Planteamiento del problema . . . . .	8
1.4. Objetivos . . . . .	9
1.5. Justificación . . . . .	10
1.6. Aportaciones y productos derivados de la Tesis . . . . .	11
1.7. Antecedentes . . . . .	12
1.8. Estado del arte . . . . .	14
1.9. Conclusiones . . . . .	16
Referencias . . . . .	20
<b>2. Preprocesamiento de imágenes satelitales</b>	<b>21</b>
2.1. Introducción . . . . .	21
2.2. Sistemas de percepción remota . . . . .	22
2.3. Corrección geométrica . . . . .	27
2.4. Conversión de $ND$ a radiancia . . . . .	29
2.5. Conversión de $L_\lambda$ a reflectancia en la parte superior de la atmósfera ( $TOA$ )	30
2.6. Corrección atmosférica (reflectancia $IAR$ ) . . . . .	31

2.7. Conclusiones . . . . .	32
Referencias . . . . .	35
<b>3. Índices de diferencia normalizada (<i>IDN</i>) e Índices Multi-Banda (<i>IMB</i>)</b>	<b>37</b>
3.1. Introducción . . . . .	37
3.2. Índice de Vegetación de Diferencia Normalizada ( <i>NDVI</i> ) . . . . .	39
3.3. Métodos para la extracción de cuerpos de agua . . . . .	40
3.3.1. Índice de Agua de Diferencia Normalizada Modificado ( <i>MNDWI</i> )	40
3.3.2. Índice de Extracción de Agua Automatizado ( <i>AWEI<sub>nsh</sub></i> ) sin sombra	41
3.3.3. Índice de Agua Automático para Múltiples Superficies ( <i>AWI – MS</i> )	41
3.4. Métodos para la Extracción de Superficies de Nieve/Hielo . . . . .	42
3.4.1. Índice de Nieve de Diferencia Normalizada ( <i>NDSI</i> ) . . . . .	42
3.4.2. Índice de Nieve Automático para Múltiples Superficies ( <i>ASI – MS</i> )	42
3.5. Índice de Construcción de Diferencia Normalizada ( <i>NDBI</i> ) . . . . .	43
3.6. Conclusiones . . . . .	44
Referencias . . . . .	45
<b>4. Resultados del monitoreo de recursos naturales y construcción</b>	<b>47</b>
4.1. Introducción . . . . .	47
4.1.1. Post procesamiento de la imagen . . . . .	48
4.2. Análisis de la región de España utilizando el algoritmo <i>NDVI</i> . . . . .	49
4.3. Monitoreo del lago Metztitlán mediante los métodos <i>MNDWI</i> y <i>AWEI<sub>nsh</sub></i>	50
4.3.1. Imágenes satelitales del Landsat 5 <i>TM</i> . . . . .	51
4.3.2. Imágenes satelitales del Landsat 8 <i>OLI</i> . . . . .	51
4.3.3. Imágenes satelitales de Sentinel-2 <i>MSI</i> . . . . .	53
4.3.4. Monitoreo del lago Metztitlán a través del tiempo . . . . .	53
4.4. Monitoreo del lago Poopó mediante el método <i>AWEI<sub>nsh</sub></i> . . . . .	54
4.5. Comparación de resultados del método <i>AWEI<sub>nsh</sub></i> contra el método propuesto <i>AWI – MS</i> . . . . .	55
4.6. Extracción de cuerpos de agua mediante el método <i>AWI – MS</i> . . . . .	55
4.7. Monitoreo en la región de Groenlandia mediante el método <i>NDSI</i> . . . . .	57
4.8. Comparación de resultados del método <i>NDSI</i> contra el método propuesto <i>ASI – MS</i> . . . . .	58
4.9. Extracción de superficies de nieve mediante el método <i>ASI-MS</i> . . . . .	59
4.10. Monitoreo en el área urbana de Moscú mediante el método <i>NDBI</i> . . . . .	60
4.11. Conclusiones . . . . .	62
Referencias . . . . .	63

---

<b>5. Conclusiones generales y trabajo a futuro</b>	<b>65</b>
5.1. Conclusiones generales . . . . .	65
5.2. Trabajo a futuro . . . . .	66
<b>A. Evaluación de precisión y exactitud de <math>MNDWI</math>, <math>AWEI_{nsh}</math> y <math>AWI-MS</math></b>	<b>67</b>
<b>B. Apéndice: Trabajos derivados de la tesis</b>	<b>72</b>
B.1. Memorias en extenso . . . . .	72



# Índice de figuras

1.1.	Representación de 7 elementos involucrados en el proceso de la percepción remota con datos satelitales. . . . .	3
1.2.	Plataforma de descarga para las imágenes satelitales Landsat: URL: <a href="https://earthexplorer.usgs.gov">https://earthexplorer.usgs.gov</a> [1.12]. . . . .	4
1.3.	Lago Nasser de Egipto, ubicado a una Latitud: 23.104626° y Longitud: 32.806267°. . . . .	5
1.4.	Imagen multispectral TM en el rango visible e infrarrojo. . . . .	6
1.5.	Plataforma de descarga para las imágenes satelitales Sentinel-2: URL: [1.17]. . . . .	8
2.1.	Pasos de preprocesamiento para imágenes satelitales. . . . .	21
2.2.	Sistema básico de una cámara digital. . . . .	22
2.3.	Escaneador mecánico multispectral satelital. . . . .	23
2.4.	Escaneador de barrido satelital. . . . .	24
2.5.	El sensor a bordo del satélite, registra la radiancia espectral ( $L_\lambda$ ). . . . .	25
2.6.	Landsat 5 <i>TM</i> : (a) Selección geométrica de una imagen <i>RGB</i> de dimensión $7721 \times 6891$ píxeles (b) Extracción de la <i>RoI</i> con centro $p(d_{1p}, d_{2p})$ con tamaño de $1911 \times 2959$ píxeles citelandsat5. . . . .	27
2.7.	Selección de la misma <i>RoI</i> del rio Nasser mediante el software <i>ENVI</i> , en datos satelitales: (a) Landsat 5 <i>TM</i> y (b) Sentinel-2 <i>MSI</i> . . . . .	28
2.8.	<i>RoI</i> del Lago Nasser de Egipto, ubicado a una Latitud: 23.104626° y Longitud: 32.806267°, registrada por el satélite Landsat 5 <i>TM</i> : (a) Banda Verde sin corrección radiométrica y (b) resultado de la corrección de $L_\lambda$ y <i>TOA</i> de (a). . . . .	30
2.9.	Extracción del Lago Nasser mediante el método $AWEI_{nsh}$ utilizando imágenes <i>TM</i> : (a) resultado sin corrección radiométrica, (b) imagen con corrección $L_\lambda$ y <i>TOA</i> , y (c) resultado de la corrección $L_\lambda$ , <i>TOA</i> e <i>IARR</i> . . . . .	31
2.10.	Extracción del Lago Nasser mediante el método $AWEI_{nsh}$ utilizando imágenes <i>MSI</i> : (a) Resultado de imágenes <i>ESA</i> con corrección $L_\lambda$ y <i>TOA</i> y (b) Resultado de la corrección atmosférica <i>IARR</i> . . . . .	32
3.1.	Curvas de reflectancia espectral características (Datos originales tomados de <i>USGS</i> Laboratorio de espectroscopía): 224 bandas pertenecientes al espectrómetro <i>AVIRIS</i> , con muestreo espectral contiguo de $10nm$ y rango espectral de $400-2500 nm$ [3.5]. . . . .	38

3.2.	(a) Selección de un píxel que pertenece a la vegetación en seis bandas espectrales de Landsat 5 <i>TM</i> , y (b) firma espectral del píxel de vegetación.	39
3.3.	(a) Selección de un píxel que pertenece al agua en seis bandas espectrales de Landsat 5 <i>TM</i> , y (b) firma espectral del píxel del agua. . . . .	40
3.4.	(a) Selección de un píxel de nieve/hielo en seis bandas espectrales de Landsat 5 <i>TM</i> , y (b) firma espectral del píxel de nieve/hielo de (a). . .	42
3.5.	(a) Píxel perteneciente a un área de construcción, seleccionado en bandas <i>TM</i> , y (b) firma espectral de un píxel de construcción. . . . .	43
4.1.	Ubicación geográfica de la <i>RoI</i> del lago Metztlán, en imágenes RGB [4.1]: Resolución de 307x246 píxeles para (a) Landsat 5 <i>TM</i> y (b) Landsat 8 <i>OLI</i> , y 663 × 531 píxeles para (c) Sentinel 2A. . . . .	48
4.2.	Histograma de una imagen $AWEI_{nsh}$ , con intensidad de píxeles positiva (cuerpo de agua) e intensidad de píxeles negativa(fondo), utilizando imágenes Landsat 5 <i>TM</i> . Con un $HTV_{AWEI_{nsh}} = 2.02159$ . . . . .	49
4.3.	Región de España registrada en abril de los años 1984, 2005 y 2009: (a), (b) y (c) Imágenes RGB compuestas por la Banda Verde, Banda Rojo y Banda <i>NIR</i> . La vegetación se muestra en color rojo por la reflectancia del <i>NIR</i> . Las imágenes (d), (e) y (f) son los resultados de <i>NDVI</i> sin binarizar y (g), (h) e (i) son resultados <i>NDVI</i> binarizados con valor de umbral = 0.59693. . . . .	50
4.4.	Lago Metztlán: (a) <i>MNDWI</i> sin binarizar, (b) $OTN_{MNDWI}$ , (c) $HTV_{MNDWI} = 0.63888$ , (d) $AWEI_{nsh}$ sin binarizado, (e) $OTN_{AWEI_{nsh}}$ y (f) $HTV_{AWEI_{nsh}} = 2.02159$ . . . . .	51
4.5.	Lago Metztlán: (a) <i>MNDWI</i> sin binarizar, (b) $OTN_{MNDWI}$ , (c) $HTV_{MNDWI} = 0.58570$ , (d) $AWEI_{nsh}$ sin binarizar, (e) $OTN_{AWEI_{nsh}}$ , y (f) $HTV_{AWEI_{nsh}} = 2.37209$ . . . . .	52
4.6.	Lago Metztlán: (a) <i>MNDWI</i> sin binarizar, (b) $OTN_{MNDWI}$ , (c) $HTV_{MNDWI} = 0.50610$ , (d) $AWEI_{nsh}$ sin binarizar, (e) $OTN_{AWEI_{nsh}}$ , y (f) $HTV_{AWEI_{nsh}} = 1.75806$ . . . . .	52
4.7.	Lago Metztlán: (a) Landsat 5 <i>TM</i> , (b) Landsat 8 <i>OLI</i> y (c) Sentinel 2A.	53
4.8.	Lago Poopó registrado en agosto del 2003, 2005 y 2009. (a), (b) y (c) imágenes RGB de Landsat. Las imágenes (d), (e) y (f) son $AWEI_{nsh}$ sin binarizar y (g), (h), (i) son resultados de imágenes $AWEI_{nsh}$ binarizadas con valor de umbral = 1.20829. . . . .	54
4.9.	Comparación de extracciones de agua en el lago Poyang, China, registrada en noviembre de 1988 por Landsat 5 <i>TM</i> : a) Imagen RGB, b) Extracción de agua con $AWI - MS$ y c) Extracción de agua con $AWEI_{nsh}$ .	55
4.10.	Lagos naturales registrados por Landsat 5 <i>TM</i> : Extracciones de cuerpos de agua a través del tiempo, utilizando el método $AWI - MS$ , para valores iguales de $K$ . . . . .	56

4.11. Lagos creados por el hombre registrados por Landsat 5 <i>TM</i> : Extracciones de cuerpos de agua a través del tiempo utilizando el método <i>AWI – MS</i> , para valores iguales de <i>K</i> . . . . .	57
4.12. Región de Groenlandia registrada en septiembre de 1990, 1998 y 2009. La (a), (b) y (c) son imágenes <i>RGB</i> de la <i>RoI</i> . La (d), (e) y (f) son resultados <i>NDSI</i> sin binarizar y (g), (h), (i) son resultados <i>NDSI</i> con número de umbral = 0.24893. . . . .	58
4.13. Comparación de la extracción de nieve en la región de India, registrada en diciembre de 1995, por Landsat 5 <i>TM</i> : a) Imagen <i>RGB</i> , b) Extracción de nieve con <i>ASI – MS</i> y c) Extracción de nieve con <i>NDSI</i> . . . . .	59
4.14. Comparación de extracciones de nieve en la región de Alaska, registrada en mayo de 1992. a) Imagen <i>RGB</i> , b) Extracción de nieve con <i>ASI – MS</i> y c) Extracción de nieve con <i>NDSI</i> . . . . .	59
4.15. Áreas de estudio registradas por Landsat 5 <i>TM</i> : Extracciones de superficies de nieve a través del tiempo utilizando el método <i>ASI – MS</i> , para diferentes valores de <i>K</i> . . . . .	60
4.16. Imágenes de la ciudad de Moscú registradas en agosto de 1996, 2007 y 2011. (a). (b) y (c) imágenes <i>RGB</i> de la <i>RoI</i> . (d), (e) y (f) son extracciones de construcción sin binarizar y (g), (h), (i) son resultados <i>NDBI</i> con número de umbral = -0.13894. . . . .	61
A.1. Imágenes compuestas por <i>SWIR2</i> , <i>NIR</i> y Verde con 180 puntos verdaderos distribuidos aleatoriamente: (a) Landsat 5 <i>TM</i> , (b) Landsat 8 <i>OLI</i> y (c) Sentinel-2 <i>MSI</i> . . . . .	67
A.2. Puntos verdaderos distribuidos aleatoriamente en escenas registradas por los sensores <i>TM</i> , <i>OLI</i> y <i>MSI</i> . . . . .	68



# Índice de Tablas

1.1.	Características y aplicaciones de las bandas TM para el sensado remoto satelital [1.15].	7
1.2.	Especificación de bandas de los sensores satelitales <i>TM</i> , <i>OLI</i> y <i>MSI</i> [1.15], [1.18]. . . . .	8
4.1.	Región de España: porcentajes totales de píxeles de vegetación, obtenidos mediante el software <i>ENVI</i> . El cálculo de los porcentajes, es la relación de los píxeles de vegetación, entre todos los píxeles que integran la imagen. . . . .	50
4.2.	Porcentaje de píxeles de agua de la Figura 4.7 a-c. . . . .	53
4.3.	Porcentajes de píxeles de agua de imágenes binarizadas de Poopó calculados mediante el software <i>ENVI</i> . . . . .	55
4.4.	Áreas de estudio y sus características para la implementación de <i>AWI – MS</i> . . . . .	56
4.5.	Variación porcentual de píxeles de nieve de la región de Groenlandia, calculados mediante el software <i>ENVI</i> . . . . .	58
4.6.	Porcentajes de píxeles acumulados en imágenes binarizadas de Moscú, calculados en <i>ENVI</i> . . . . .	61
A.1.	Clasificación de datos de entrada. . . . .	69
A.2.	Resultado de la evaluación de exactitud y precisión de los algoritmos <i>MNDWI</i> , <i>AWEI<sub>nsh</sub></i> y <i>AWI – MS</i> en el Lago Bosques. . . . .	70



# 1

# Antecedentes generales

---

## 1.1. Introducción

La detección de cambios en los recursos naturales y el desarrollo urbano, son excelentes indicadores de la alteración ambiental. Para esto, la adquisición de imágenes digitales multiespectrales de manera remota, permiten realizar estudios sobre cuerpos de agua, superficies de nieve, áreas de vegetación, entre otros, a nivel regional y global. Incluso, se puede tener un registro de esta información a través del tiempo, mediante Bases de Datos (*BD*), almacenadas de manera digital.

Gracias al rápido desarrollo tecnológico, es posible observar y registrar información del planeta Tierra desde el espacio, mediante imágenes multiespectrales satelitales. A partir de la década de los 60's, las plataformas satelitales con sensores electrónicos multiespectrales, dieron origen a la percepción y sensado remoto de la Tierra [1.1]. Desde entonces, es posible monitorear, detectar y registrar cambios dinámicos de fenómenos naturales (ejemplo, huracanes, volcanes, inundaciones), a pequeña, mediana y gran escala. Aún más, es posible detectar la alteración ambiental, por intervención humana (ejemplo, deforestación, contaminación urbana, sobreexplotación del agua y suelo) a través del tiempo [1.2].

A diferencia de la pequeña porción del espectro electromagnético, que el ojo humano puede percibir ( $0.4 \mu m$  a  $0.7 \mu m$ ), los sensores multiespectrales, registran radiación electromagnética, que es invisible para el ojo humano. En la actualidad, existen sensores satelitales que detectan radiación en la región del ultravioleta, infrarrojo y microondas [1.1]. El poder analizar información fuera del rango visible, es una significativa ventaja, que permite distinguir/discriminar con mayor exactitud ciertos materiales de otros. Utilizando técnicas de interpretación visual y algoritmos computacionales que segmenten/extraigan información espectral, es posible realizar estudios temporales y espaciales del entorno terrestre de manera digital.

Entre los algoritmos computacionales propuestos en la literatura, para la extracción/segmentación de materiales/superficies, se encuentran, los Índices de Diferencia Normalizada (*IDN*) [1.3], [1.4], [1.5], [1.6]. Los *IDN* son utilizados, por la fácil implementación y el bajo costo computacional requerido para obtener buenos resultados. El objetivo de los *IDN*, es maximizar el contraste de intensidad entre los pixeles pertenecientes a la superficie de estudio, de otro tipo de pixeles registrados en la región de interés (*RoI*). Para lograr esto, un análisis de la respuesta espectral de dicha superficie, es necesaria. La firma espectral de una determinada superficie, muestra una reflectancia mínima para cierta longitud de onda y una máxima reflectancia en otra longitud de onda. Los *IDN* calculan la diferencia normalizada de dichas bandas, para maximizar el alta y minimizar la baja reflectancia. Una formulación básica de un *IDN* se puede expresar como [1.7],

$$IDN = \frac{B_i - B_j}{B_i + B_j}, \quad (1.1)$$

donde  $B_i$ , representa la reflectancia más baja y  $B_j$  la reflectancia más alta de la imagen multiespectral.

En este capítulo se hace una introducción a la percepción remota satelital, y su utilidad en el monitoreo de los recursos naturales. Se definen las características de los sensores satelitales multiespectrales utilizados para este estudio. De esta manera, se plantea el problema a resolver, el objetivo de la Tesis, justificación y aportaciones. Se revisa el estado del arte de los métodos existentes en el área de delimitación y extracción de recursos naturales y construcción. Finalmente se presentan las conclusiones del capítulo.

## 1.2. Percepción remota

La percepción remota puede ser definida, como la adquisición de información de un objeto descrito por datos obtenidos con algún sistema óptico digital, que se encuentra distante de esta *RoI* [1.8]. Este proceso consiste en detectar y registrar energía reflejada o emitida por objetos situados en la superficie terrestre, mediante un sensor satelital, que puede estar orbitando en la parte superior de la atmósfera de la tierra. Existen procesos involucrados en la percepción remota mostrados en la Figura 1.1, que implican la interacción de energía incidente (proveniente del sol) con los objetos de la *RoI* [1.9].

- A) Fuente de energía o iluminación: proporciona energía electromagnética que ilumina el objeto de interés.
- B) La radiación y la atmósfera: la radiación electromagnética proveniente del sol, entra en contacto con la atmósfera de la Tierra por primera vez, antes de incidir en el objeto de interés. Esta interacción tiene lugar una segunda vez, cuando la radiación reflejada o emitida por el objeto viaja hacia el sensor satelital.

- C) Interacción de la radiación con el objeto: de la radiación electromagnética total incidente en el objeto, cierta cantidad es absorbida, transmitida y reflejada en distintas magnitudes. Esta interacción va a depender de las propiedades tanto del objeto como de la radiación (longitud de onda).
- D) Registro de energía por el sensor: la radiación electromagnética reflejada o emitida por los objetos es muestreada y cuantificada por el sensor multispectral satelital.
- E) Transmisión, recepción y procesamiento: la energía electromagnética registrada por el sensor satelital, se transmite comúnmente de manera electrónica a una estación de recepción y procesamiento, donde los datos se procesan en una imagen digital.
- F) Interpretación y análisis: la imagen digital puede ser adquirida en distintos portales de Internet autorizados, para que el usuario/investigador analice e interprete los datos de manera visual y digital.
- G) Aplicación: la percepción remota se logra, cuando la información extraída de las imágenes multispectrales pertenecientes a la *RoI*, es comprendida y utilizada para resolver diferentes problemáticas.

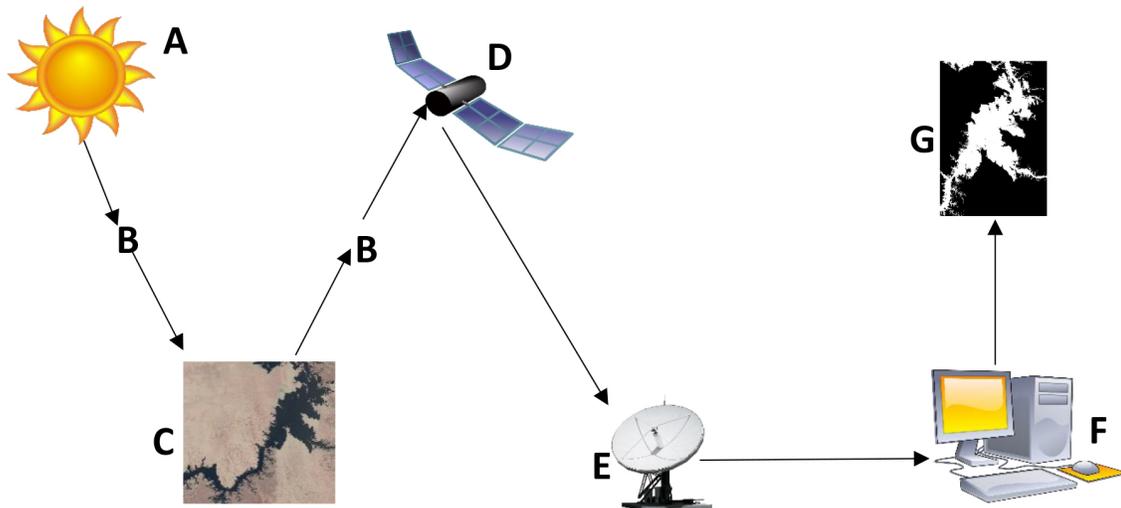


Figura 1.1: Representación de 7 elementos involucrados en el proceso de la percepción remota con datos satelitales.

### 1.2.1. Misiones Landsat

El proyecto Landsat comenzó en 1972, por la Administración del espacio y Aero-náutica Nacional (*NASA*). El satélite Landsat 5 *TM*, fue lanzado en Marzo de 1984 por la *NASA* y desmantelado en enero del 2013. El Servicio Geológico de los Estados Unidos (*USGS*) opera y maneja las misiones de Landsat desde 1990. Los datos Landsat desde el año 2009, son de descarga gratuita a través de portales en internet (ejemplo, Earth explorer; *USGS*). Anualmente, la *USGS* detecta un incremento en la descarga de imágenes satelitales de 50 veces [1.10] , [1.11]. La Figura 1.2, muestra la plataforma de descarga de datos satelitales de la *USGS*.

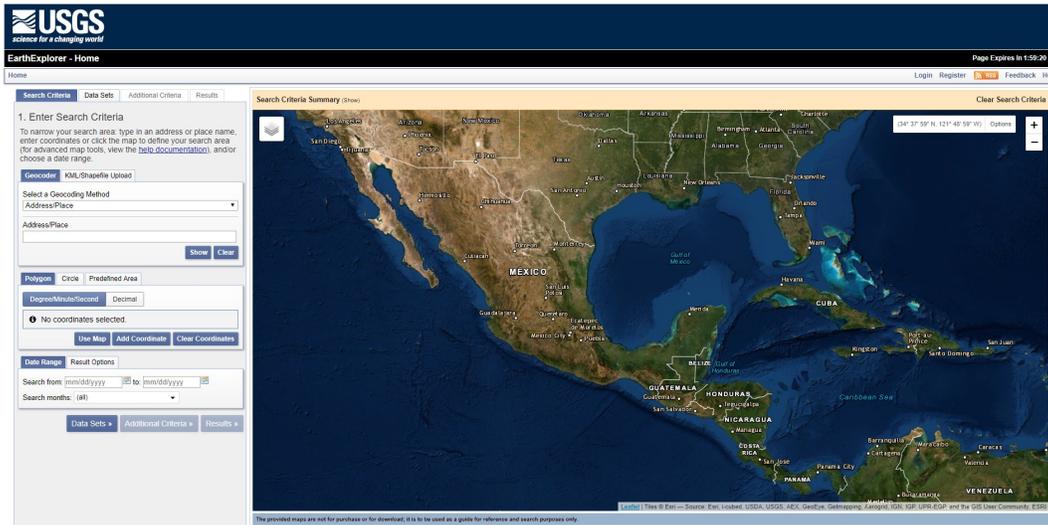
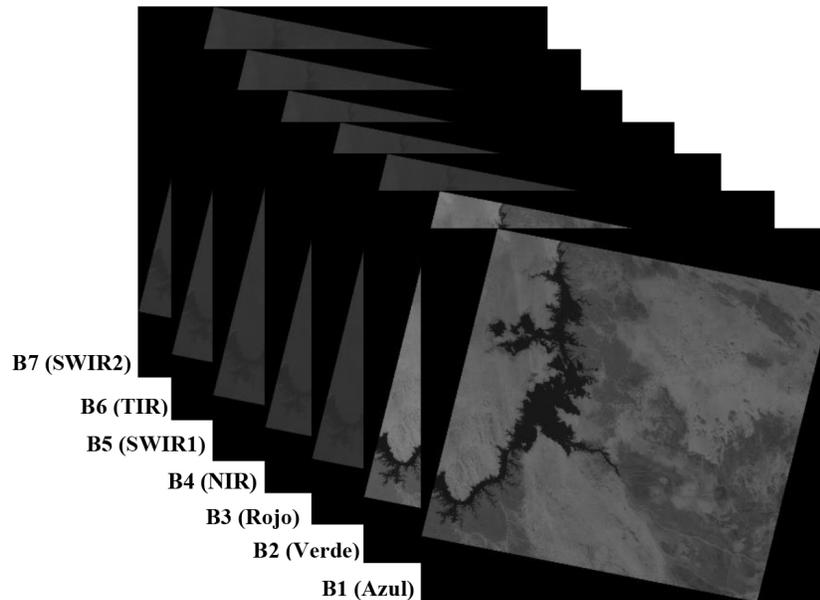


Figura 1.2: Plataforma de descarga para las imágenes satelitales Landsat: URL: <https://earthexplorer.usgs.gov> [1.12].

El sensor satelital de Mapeo Temático (*TM*), abordo del satélite Landsat 5 registra 7 Bandas espectrales. Tres bandas espectrales *TM* en el rango visible (rojo (*R*), verde (*G*) y azul (*B*)), tres en el infrarrojo (Infrarrojo Cercano (*NIR*) e Infrarrojos de onda corta (*SWIR1*) y (*SWIR2*)) y una banda Termal Infrarroja (*TIR*). Una sola escena cubre aproximadamente 170 *km* en alto y 185 *km* en ancho [1.13]. Todas las bandas del sensor *TM*, están registradas con una Resolución Radiométrica (*RR*) de  $2^8 = 256$  niveles de gris. En la Figura 1.3a, se observa una imagen multiespectral Landsat 5 *TM*, con tamaño para cada banda de  $7721 \times 6891$  píxeles y Figura 1.3b una combinación *RGB*.

Las imágenes multiespectrales del satélite Landsat 5 *TM*, permite el mapeo de sedimentos, delimitación de cuerpos de agua, análisis de biomasa vegetal, detección de minerales, entre otros. La resolución espectral (*RE*), se refiere al número de bandas que puede registrar el sensor [1.9]. Entre mayor sea la *RE*, el sensor podrá discriminar con

mayor exactitud ciertos materiales de otros.



(a) Imagen multiespectral registrada por el satélite Landsat 5 *TM*.

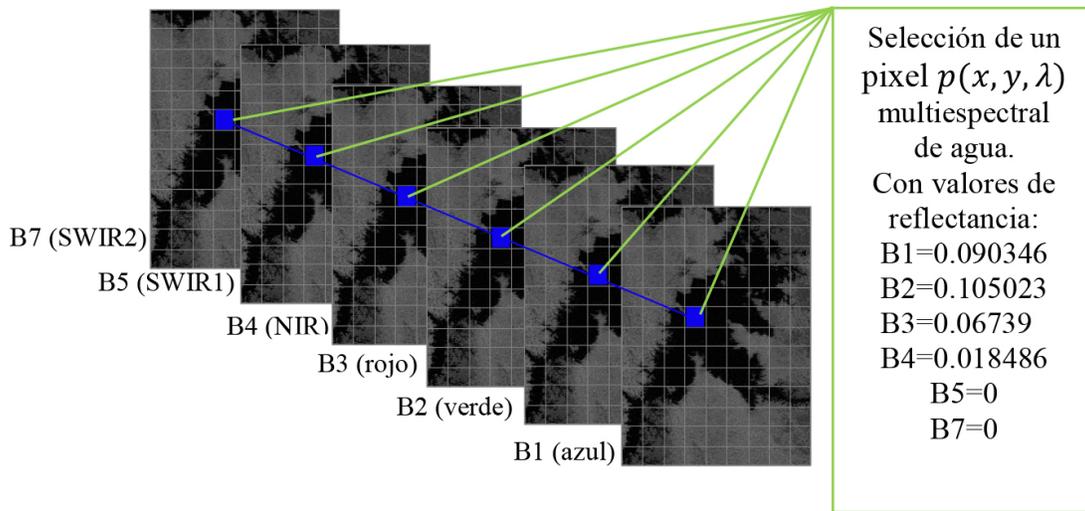


(b) Combinación de las bandas rojo, verde y azul (*RGB*) de la imagen multiespectral *TM*.

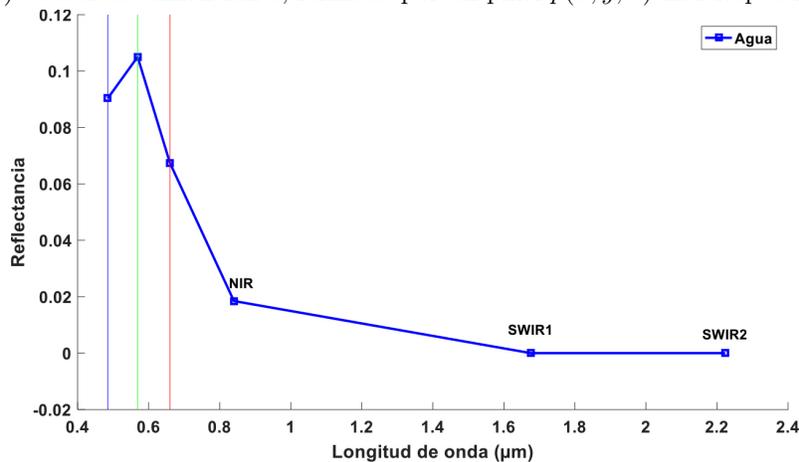
Figura 1.3: Lago Nasser de Egipto, ubicado a una Latitud:  $23.104626^\circ$  y Longitud:  $32.806267^\circ$ .

Midiendo la radiación emitida o reflejada de un determinado objeto, contra la *RE*, se puede obtener su firma espectral. Cada banda registrada por un sensor multiespectral, es muestreada y cuantificada. El muestreo tiene que ver con las características del sensor. Tamaño de píxel, tamaño del espacio entre píxeles y número de píxeles. La cuantificación se refiere, a la representación de intensidad de brillo (valor digital de cada píxel), correspondiente a la radiancia reflejada o emitida por el objeto, que fue registrada previamente por el sensor satelital [1.14].

En la Figura 1.4a, se observa la *ROI* del lago Nasser, que muestra un vector de dimensión seis, formado por un pixel  $p(x, y, \lambda)$  multispectral *TM* (rango visible e infrarrojo), perteneciente al agua. Cada pixel representa un valor de intensidad, correspondiente a la longitud de onda reflejada por el agua, en las diferentes bandas. En la Figura 1.4b, se gráfica la firma espectral del agua de 1.4a. Los valores de longitud de onda que se encuentran entre las bandas *TM*, no son registrados por el sensor *TM*, de ahí el nombre multispectral.



(a) Vector de dimensión 6, formado por un pixel  $p(x, y, \lambda)$  multispectral.



(b) Firma espectral del agua.

Figura 1.4: Imagen multispectral *TM* en el rango visible e infrarrojo.

En base al análisis de la respuesta espectral única para cada objeto/superficie, las bandas registradas por el sensor *TM*, pueden ser útiles en diferentes aplicaciones, como se muestra en la Tabla 1.1.

Tabla 1.1: Características y aplicaciones de las bandas TM para el sensado remoto satelital [1.15].

Nombre de la banda	Aplicaciones y características
B1 (azul)	Mapeo de sedimentos, distingue el suelo de la vegetación.
B2 (verde)	Alta reflectancia en la vegetación sana.
B3 (rojo)	Absorción de Clorofila.
B4 (NIR)	Absorción por el agua, para la delimitación de cuerpos de agua y análisis de la biomasa vegetal.
B5 (SWIR1)	Sensitiva al contenido de humedad, útil en la discriminación de rocas, nubes, hielo y nieve.
B6 (TIR)	Útil en el mapeo geológico, permite medir la temperatura de la superficie.
B7 (SWIR2)	Útil en la detección de depósitos minerales.

En febrero 11, del 2013, la *NASA* lanza el satélite Landsat 8, equipado con el sensor de Imagen de Terreno Operacional (*OLI*) y el sensor de Infrarrojo Termal (*TIRS*). Actualmente en operación, el sensor *OLI* tiene una *RR* de  $2^{12}=4096$  niveles de gris y *RE* similar al sensor *TM*, con tres bandas adicionales, la costera aerosoles, pancromática y cirrus [1.16].

### 1.2.2. Misiones Sentinel-2

La Agencia Espacial Europea (*ESA*) establecida en el año de 1975, desarrolló la misión Sentinel-2, para la observación del planeta tierra, como parte del programa Copernicus. El Sentinel-2, consta de dos satélites: (A) Sentinel 2A llevado a orbita el 23 de junio, del 2015 y (B) Sentinel 2B lanzado el 7 de marzo, del 2017.

El satélite Sentinel 2A y 2B, constan de un sensor Instrumental Multiespectral (*MSI*), con *RR* similar a Landsat 8 *OLI*. El sensor *MSI* registra 13 bandas espectrales, con resolución espacial en el rango de 10-60 metros, donde cada imagen cubre 290 *km* de ancho [1.17]. En la Figura 1.5, se muestra la plataforma de *ESA*, para poder descargar los datos satelitales Sentinel-2.

La resolución espacial tiene que ver con el objeto más pequeño que puede ser detectado en una imagen [1.8]. La resolución espacial y la *RE*, pueden diferir en imágenes satelitales registradas por diferentes sensores. Una comparación de longitudes de onda y resolución espacial de bandas espectrales adquiridas por diferentes sensores, es mostrada en la Tabla 1.2.



Figura 1.5: Plataforma de descarga para las imágenes satelitales Sentinel-2: URL: [1.17].

Tabla 1.2: Especificación de bandas de los sensores satelitales *TM*, *OLI* y *MSI* [1.15], [1.18].

Bandas	Landsat 5 TM		Landsat 8 OLI		Sentinel-2 MSI	
	Longitud de onda ( $\mu m$ )	Resolución espacial ( $m$ )	Longitud de onda ( $\mu m$ )	Resolución espacial ( $m$ )	Longitud de onda ( $\mu m$ )	Resolución espacial ( $m$ )
Azul	0.45 - 0.52	30	0.45-0.51	30	0.46-0.52	10
Verde	0.52 - 0.60	30	0.53-0.59	30	0.55-0.58	10
Rojo	0.63 - 0.69	30	0.64-0.67	30	0.64-0.67	10
NIR	0.76 - 0.90	30	0.85-0.88	30	0.78-0.90	10
SWIR-1	1.55 - 1.75	30	1.57-1.65	30	1.57-1.65	20
SWIR-2	2.08 - 2.35	30	2.11-2.29	30	2.10-2.28	20

### 1.3. Planteamiento del problema

Las áreas del mundo que son ricas en recursos naturales se enfrentan a los desafíos de su gestión. Las imágenes de los satélites Landsat y Sentinel-2, pueden ser útiles para monitorear los cambios en la superficie terrestre, que pueden afectar a la población y sus entornos regionales. Los datos satelitales Landsat y Sentinel-2, son utilizados para

monitoreo ecológico y el desarrollo urbano. Para esto, es necesario (A) reducir los efectos por degradación del sensor, absorción y dispersión atmosférica y (B) segmentar y/o extraer el cuerpo y/o superficie de estudio alojada en la escena.

En el primer caso, debido a la degradación del sensor y fallas en el equipo, los satélites son desmantelados y datos de baja, para posteriormente, ser reemplazados por nuevas tecnologías satelitales. Para poder realizar sensado remoto a largo plazo, es necesario comparar y tener condiciones atmosféricas similares, en imágenes satelitales registradas por diferentes sensores a través del tiempo. Los efectos solares, atmosféricos y topográficos, pueden ser causantes de distorsión en imágenes multiespectrales adquiridas en diferente hora, fecha y sensor. El preprocesamiento de las imágenes satelitales (*PIS*), reduce estos efectos mediante la calibración radiométrica y corrección atmosférica. En la literatura, se pueden encontrar diferentes recomendaciones y en algunos casos contradictorios, de los pasos a seguir del *PIS*. El no tener una visión general y un amplio conocimiento de este tema, el nivel del *PIS* puede alterar la información original, introduciendo distorsión a las imágenes y obtener resultados erróneos.

En el siguiente paso para segmentar la superficie de estudio alojada en la *RoI*, se encuentran los métodos basados en los Índices de Diferencia Normalizada (*IDN*) y Multi-Banda (*IMB*). En base al análisis de la respuesta espectral (firma espectral) única para cada material, los *IDN* e *IMB* utilizan combinaciones de bandas espectrales para segmentar las superficies de estudio. Los resultados muestran una alta variación de desempeño, que tiene que ver con el índice utilizado, el tipo de sensor y la *RoI* que se está analizando. Un bajo rendimiento (no logran separar un material de otro) es expuesto en los algoritmos *IDN* e *IMB*, en la percepción a largo plazo de una *RoI* con alta diversidad geográfica, registrada por uno o diferentes sensores satelitales.

## 1.4. Objetivos

### General

- Extracción y monitoreo de (1) recursos naturales y (2) zonas urbanas, a partir del análisis de imágenes multiespectrales provenientes de los satélites Landsat 5 *TM*, Landsat 8 *OLI* y Sentinel 2A.

### Particulares

- A partir de la base de datos (*BD*) del Servicio Geológico de los Estados Unidos (*USGS*), generar una BD de imágenes segmentadas con cuerpos de agua y superficies de nieve a través del tiempo en imágenes registradas por Landsat 5 *TM*, Landsat 8 *OLI* y Sentinel 2A.

- Preprocesamiento de las imágenes satelitales: (A) Corrección geométrica, (B) Conversión de valores digitales a radiancia espectral del sensor, (C) Calibración de radiancia espectral a reflectancia *TOA* y (D) corrección atmosférica *IARR*.
- Implementación de los índices de diferencia normalizada e índices multi-banda (*NDBI*, *NDVI*, *MNDWI*, *NDSI* y *AWEI<sub>nsh</sub>*), para el análisis urbano y recursos naturales.
- Monitoreo de cuerpos de agua en el tiempo, a partir de imágenes provenientes de los satélites Landsat 5 *TM*, Landsat 8 *OLI* y Sentinel 2A.
- Monitoreo de superficies de nieve en el tiempo, a partir de imágenes provenientes de los satélites Landsat 5 *TM*.
- Monitoreo de la vegetación en el tiempo, a partir de imágenes provenientes de los satélites Landsat 5 *TM*.
- Monitoreo de áreas urbanas en el tiempo, a partir de imágenes provenientes de los satélites Landsat 5 *TM*.

## 1.5. Justificación

Entender e interpretar los cambios que sufre nuestro planeta, puede ayudar a mejorar la toma de decisiones, que garanticen sustentabilidad de los recursos naturales y humanos a corto/largo plazo. En las últimas décadas, la percepción remota satelital ha ido en aumento, para el mapeo automático y semiautomático de recursos naturales y el desarrollo urbano.

La base de datos gratuita de Landsat, contiene los registros de percepción remota satelital de la Tierra más larga y continua en la historia. Estas imágenes multiespectrales, permiten observar, analizar y evaluar la evolución de zonas urbanas y la alteración ambiental a pequeña, mediana y gran escala. En base a este análisis, se pueden tomar mejores decisiones para el manejo de recursos naturales, que garanticen la disponibilidad de alimentos y agua potable, necesarios para el desarrollo rural y la salud pública.

Las fallas mecánicas y la degradación del sensor satelital, son razones por las que los satélites son desmantelados y dados de baja. Para poder realizar sensado remoto satelital a largo plazo, es necesario utilizar múltiples sensores. Landsat 5 *TM* tuvo un periodo limitado de funcionamiento entre los años 1984-2013. Para compensar la falta de registros multiespectrales *TM* en los años siguientes a su periodo, en este estudio se adquieren datos de los satélites Landsat 8 *OLI* y Sentinel-2 *MSI*.

El sensado remoto óptico de Landsat y Sentinel-2, se encuentra en un rango de longitudes de onda desde el espectro visible al espectro infrarrojo. Esto permite que los

sensores *TM*, *OLI* y *MSI*, tengan una *RE* suficiente para el mapeo de sedimentos, delimitación de cuerpos de agua, análisis de biomasa vegetal, detección de minerales, entre otros.

La calibración radiométrica y corrección atmosférica, permiten tener condiciones atmosféricas similares en imágenes multispectrales registradas por diferentes sensores. Para no alterar o agregar distorsión a los datos originales, en este estudio, el nivel apropiado de *PIS* es tomado en cuenta, para la obtención de resultados de alta calidad y tendencia.

Los métodos de Índices de Diferencia Normalizada y Multi-Banda propuestos en la literatura, son muy utilizados por la fácil implementación y el bajo costo computacional necesario para obtener buenos resultados. Sin embargo, los *IDN* e *IMB* tienden a confundir ciertos materiales con otros, en escenas con alta diversidad geográfica y en resultados sin binarizar. En esta Tesis, se proponen para segmentar cuerpos agua, el Índice de Agua Automático para Múltiples Superficies (*AWI-MS*) y para la extracción de áreas de nieve/hielo, el Índice de Nieve Automático para Múltiples Superficies (*ASI-MS*). Los resultados sin binarizar de *AWI-MS* y *ASI-MS*, pueden ser comparados en escenas con alta diversidad geográfica, registradas por los sensores *TM*, *OLI* y *MSI* en diferente tiempo y fecha.

## 1.6. Aportaciones y productos derivados de la Tesis

Las principales aportaciones de la presente tesis son:

- Diseño de un algoritmo de Índice de Agua Automático para Múltiples Superficies (*AWI-MS*).
- Diseño de un algoritmo de Índice de Nieve Automático para Múltiples Superficies (*ASI-MS*).

Derivadas del proyecto de Tesis, se publicaron 3 memorias en extenso,

- **M. Arreola-Esquivel**, M. Delgadillo-Herrera, C. Toxqui-Quitl, A. Padilla-Vivanco, "Index-based methods for water body extraction in satellite data," Proc. of SPIE 11137, 111372N 1-9 (2019). <https://doi.org/10.1117/12.2529756>
- M. Delgadillo-Herrera, **M. Arreola-Esquivel**, C. Toxqui-Quitl, A. Padilla-Vivanco, "Normalized difference indices in Landsat 5 TM satellite data," Proc. of SPIE 11104, 111040W 1-9 (2019). <https://doi.org/10.1117/12.2532322>
- L. Alvarado-Cruz, M. Delgadillo-Herrera, C. Toxqui-Quitl, A. Padilla-Vivanco, R. Castro-Ortega, **M. Arreola-Esquivel**, "Fractal analysis for classification of breast lesions," Proc. of SPIE 11104, 111040U 1-9 (2019). <https://doi.org/10.1117/12.2531201>

## 1.7. Antecedentes

Un monitoreo regional a largo plazo, ha sido realizado por Bhavani en los estados de Telangana y Andhra Pradesh en India. Donde se presenta un enfoque para evaluar la agricultura utilizando datos satelitales, meteorológicos y de riego en un periodo de 1982-2000. Como resultado, se encuentra un alto impacto en los cultivos tanto de verano como de invierno, en relación con la humedad del suelo y la fuente de riego [1.19].

Lin en el 2012, realiza la comparación de algoritmos para la extracción de nieve en áreas montañosas al norte de China. En el método *NDSI*, el índice de nieve por razón de bandas (*RSI*) y índice de nieve de diferencia de bandas (*DSI*), son utilizados para encontrar la estadística adecuada que relacione estos índices y la estimación de la cubierta de nieve. Los resultados muestran que el método *RSI* y el *DSI* pueden sustituir a *NDSI* para la extracción de superficies de nieve [1.20]

Utilizando imágenes multiespectrales Landsat 8 *OLI*, Yang en el 2015, realiza el estudio para extraer cuerpos de agua a gran escala (India, Brasil, Congo, Corea del Sur, China, y más). El Índice de Agua (*WI*) y el método de agrupamiento difuso modificado (*WIMFCM*), son utilizados en combinación para obtener una mayor exactitud en el mapeo de agua. El agrupamiento difuso *WIMFCM*, consiste en agrupar los elementos similares en clústeres con valores entre cero y uno. Cada pixel es asignado al pixel centroide mediante la comparación de sus intensidades. Una de las principales desventajas del método *WIMFCM*, es que cada clúster debe ser clasificado de manera manual [1.21].

Una clasificación en los cambios rurales de construcción utilizando datos Landsat 7 *ETM* y Landsat 8 *OLI/TIRS* es la realizada por Estoque en el 2015 [1.22]. En su estudio destaca la selección del valor óptimo de umbral mediante el método *Otsu*, aplicado a diferentes resultados de índices de extracción de agua y construcción. El método *Otsu* utiliza el criterio de la varianza máxima entre clases, para determinar el valor de umbral óptimo ( $t^*$ ) en una imagen segmentada. Asumiendo que el valor del pixel se encuentra en un rango  $[a, \dots, b]$ , donde  $-1 \leq a < b \leq 1$ . Los pixeles pueden ser divididos en dos clases:  $C_1$  con un rango de  $[a, \dots, t]$  y  $C_2$  con un rango de  $[t, \dots, b]$ , donde  $t$  es el valor de umbral. La varianza entre las clases  $C_1$  y  $C_2$  puede ser obtenida mediante la ecuación,

$$\sigma_2 = (M_{C_1} - M)^2 + P_{C_2}x(M_{C_2} - M)^2, \quad (1.2)$$

donde,

$$M = P_{C_1}xM_{C_1} + P_{C_2}xM_{C_2}, \quad (1.3)$$

para  $P_{C_1} + P_{C_2} = 1$ ,  $\sigma$  es la varianza entre la clase  $C_1$  (ejemplo, no es agua) y  $C_2$  (ejemplo, es agua),  $M$  es el valor de la media de la imagen índice (ejemplo, imagen segmentada por  $MNDWI$ ).  $P_{C_1}$  y  $P_{C_2}$  son las probabilidades de que un píxel este en la clase  $C_1$  y  $C_2$ .  $M_{C_1}$  y  $M_{C_2}$  son la media de los valores intensidad de los píxeles de  $C_1$  y  $C_2$  respectivamente, obtenidos de manera estadística. Debido a que los parámetros de la ecuación 1.3 son funciones de  $t$ . El valor de  $t^*$  puede ser determinado por la varianza entre clases de  $C_1$  y  $C_2$  mediante la expresión,

$$t^* = \text{ArgMax}_{a \leq t \leq b} \{P_{C_1}x(M_{C_1} - M)^2 + P_{C_2}x(M_{C_2} - M)^2\}. \quad (1.4)$$

El método de Otsu selecciona a  $t^*$  mediante la varianza máxima entre las clases  $C_1$  y  $C_2$  [1.23]. Si  $\sigma$  decrece, es porque se ha clasificado erróneamente cierta información de la *ROI*. Por otra parte entre mayor sea  $\sigma$ , minimiza la probabilidad de una clasificación errónea entre la superficie de estudio y otro tipo de objeto/fondo. Por lo tanto, maximizando la varianza entre  $C_1$  y  $C_2$ , minimiza la probabilidad de una clasificación errónea en la *ROI* segmentada [1.20]. El método Otsu puede ser calculado de forma automática mediante la función de umbralización, en el software ArcGis versión 10.2.2.

Una percepción remota del lago Poyang utilizando sensores satelitales *TM* y el Mapeador Temático Mejorado (*ETM*), es la realizada por Hui en el 2008. El objetivo es observar el bajo y alto nivel de agua, para predecir las temporadas de inundación y sequía del lago Poyang. El periodo de sensado se encuentra entre noviembre de 1999 y octubre del 2000. Utilizando los métodos de *IDN*, los resultados muestran que el lago Poyang se inunda en la temporada de verano y en invierno se seca considerablemente. Por la falta de registros multiespectrales de estos satélites, no se obtuvo una estimación temporal y espacial de la inundación de la región por interpolación lineal [1.24].

Mediante observaciones geomorfológicas y espectrales, un análisis espacial y temporal del suelo arenoso en una región al sur de Túnez, fue realizado por Afrasinei en el 2017. El periodo de observación de 1984 a 2015, fue suficiente para detectar el proceso de degradación del suelo a través del tiempo. Esta degradación, está relacionada con la sobreexplotación y exceso en el uso de la tierra para prácticas agrícolas en las décadas pasadas [1.25].

Utilizando técnicas de percepción remota, se puede analizar el uso del suelo y su cobertura en ciudades afectadas por terremotos. Un análisis del suelo de la ciudad de Dujiangyan que se encuentra en una zona sísmica, es realizado por Nath en el 2018. El periodo para este estudio se encuentra entre los años 2007-2018 (2007, 2008, 2010, 2015 y 2018). La técnica utilizada para este mapeo urbano, es la clasificación supervisada de máxima probabilidad. Debido a los cambios del suelo afectado por los sismos, se sugiere evitar planeaciones en el desarrollo de actividades naturales y antropogénicas a futuro [1.26].

## 1.8. Estado del arte

Se han desarrollado diferentes métodos para la extracción de información, utilizando imágenes multiespectrales satelitales. Entre estos encuentran, los métodos de umbralización, clasificación (redes artificiales neuronales), índices de diferencia normalizada y más [1.27]. Los métodos de umbralización son fácil de implementar, pero tienden a clasificar erróneamente las superficies/materiales registrados en la *RoI*. Los algoritmos de clasificación basados en redes neuronales son más robustos, pero tienen como desventaja el alto consumo de tiempo y de recursos computacionales usados durante el entrenamiento de la red neuronal para la correcta selección de materiales.

Los *IDN*, son muy utilizados, debido al ahorro de tiempo y el bajo requerimiento computacional para obtener buenos resultados binarizados. Uno de los primeros *IDN* propuestos es la literatura, es el Índice de Vegetación de Diferencia Normalizada (*NDVI*), implementado para el monitoreo de vegetación en grandes planicies, por Rouse en 1974 [1.3]. Entre los primeros estudios en que se utilizó *NDVI*, fue por Tucker en 1981, para detectar la acumulación de trigo seco en temporada de invierno [1.28]. Posteriormente, Emerson utiliza el método *NDVI* para un análisis fractal a múltiples escalas en terrenos de agricultura [1.29]. En el 2012, Bhandari realiza el estudio de vegetación en la ciudad de Jabalpur utilizando el algoritmo *NDVI* con bandas espectrales *TM* [1.30].

Derivado del *NDVI*, el Índice de Agua de Diferencia Normalizada (*NDWI*) propuesto por Feeters en 1996, es utilizado para delimitar cuerpos de agua en superficies abiertas [1.5]. El algoritmo *NDWI*, consiente en calcular la diferencia normalizada entre las bandas Verde y *NIR*. El objetivo es maximizar la reflectancia de la banda Verde y minimizar la baja reflectancia del *NIR*, por las características del agua. El resultado de *NDWI*, permite aumentar el contraste de intensidad del cuerpo de agua (valores de píxel positivos) y la vegetación (valores de píxel negativos).

Debido al bajo desempeño de *NDWI*, para delimitar cuerpos de agua en regiones construcción, en el 2006, Xu propone el el Índice de Agua de Diferencia Normalizada Modificado (*MNDWI*) [1.31]. En base a la misma expresión matemática de *NDWI*, el método *MNDWI* hace uso de las bandas Verde y *SWIR*. Como resultado, el suelo y la vegetación seguirán teniendo valores negativos, mientras que el agua tendrá valores positivos, porque absorbe más la longitud de onda *SWIR* que el *NIR*.

El Índice *NDWI* y el Modificado *MNDWI* fueron utilizados por Hui, para modelar el cambio espacial y temporal del lago Poyang con imágenes *TM* [1.24]. Un mapeo del lago Yangtze con imágenes Landsat 8 *OLI*, es el realizado por Du en el 2014. Du, realiza la combinación de bandas espectrales (Verde, *NIR*, *SWIR1* y *SWIR2*) en los tres modelos *NDWI*, obteniendo una exactitud mayor con las bandas Verde y *SWIR1* [1.32].

En la literatura están reportados, los *IMB* para delimitar superficies o cuerpos de agua. Los *IMB* hacen uso de una combinación algebraica de bandas espectrales, para incrementar el contraste de intensidad de la superficie analizada de otro tipo de materiales registrados en la *RoI*. Un ejemplo de *IMB*, es el Índice de Extracción de Agua Automatizado sin sombra ( $AWEI_{nsh}$ ), introducido por Feyisa en el año 2014 [1.33]. De acuerdo con el estudio de Feyisa, el método  $AWEI_{nsh}$ , mostró un mejor desempeño y precisión que *MNDWI*, para delimitar cuerpos de agua en datos Landsat 5 *TM*.

Existen diferentes estudios para la extracción de cuerpos de agua, utilizando los métodos *MNDWI* y  $AWEI_{nsh}$ . Entre ellos se encuentra, la detección de cambio del cuerpo de agua del lago Burdur a través del tiempo [1.34], la extracción de ríos y lagos utilizando imágenes espectrales Landsat [1.35], la evaluación de los índices de agua en la región de Nepal en Landsat 8 [1.36]. Un estudio reciente, es el realizado por Zhou, para el mapeo de agua en superficies abiertas con diferentes métodos, utilizando datos satelitales Landsat 7 *ETM*, Landsat 8 *OLI* y Sentinel-2 *MSI* [1.37].

Los métodos basados en un valor óptimo de umbral (*NDWI*, *MNDWI* y  $AWEI_{nsh}$ ), clasifican erróneamente las superficies/materiales registrados en la *RoI* en resultados sin binarizar. En base al análisis espectral del agua, en este estudio, se introduce y desarrolla el Índice de Agua Automático para Múltiples Superficies *AWI – MS*. El método *AWI – MS*, está diseñado para aumentar el contraste de intensidad de los píxeles pertenecientes al agua, de los píxeles del fondo (vegetación, construcción, suelo, entre otros). Los resultados de *AWI – MS*, son imágenes sin binarizar, con alta estabilidad para la extracción de cuerpos de agua en múltiples escenas y sensores.

El estudio de las superficies de nieve a nivel regional y global, es un tema importante para cuantificar los cambios climáticos que sufre el globo terráqueo a través del tiempo. El Índice de Nieve de Diferencia Normalizada (*NDSI*), puede ser utilizado para este propósito [1.4], [1.38]. Entre los estudios regionales para distinguir la nieve del suelo, se encuentra el realizado por Sibandze en la montaña Koue Bokkeveld [1.39]. Por otra parte, una investigación global, es la realizada por Burton en el 2016, con el propósito de diferenciar la nieve de las rocas en todo el continente Antártico. De acuerdo con el estudio de Burton, el método *NDSI* tiene dificultad para diferenciar rocas, sombras y cuerpos de agua de la nieve [1.40].

Debido al bajo rendimiento de *NDSI*, en este trabajo de Tesis, se introduce el nuevo Índice de Nieve Automático para Múltiples Superficies (*ASI – MS*). Sin utilizar un valor óptimo de umbral, el algoritmo *ASI – MS* extrae la superficie de nieve/hielo en una o múltiples escenas, con alta diversidad geográfica registradas a través del tiempo.

El monitoreo de las zonas de construcción, permite identificar las regiones con mayor temperatura que impactan el cambio climático [1.41]. Uno de los métodos para monitoreo urbano es el Índice de Construcción de Diferencia Normalizada (*NDBI*)

propuesto por Sha, en el 2003 [1.6]. Un estudio del crecimiento en las áreas urbanas a través del tiempo, es el realizado por Delgadillo y colaboradores, en la ciudad de Moscú [1.42]. Donde se determina el incremento en el porcentaje de píxeles pertenecientes a la construcción, utilizando datos Landsat 5 *TM*.

## 1.9. Conclusiones

La percepción remota a través de los satélites Landsat y Sentinel-2, permiten tener un registro de la superficie terrestre de forma continua a través del tiempo. En base a esta información multiespectral y al uso de algoritmos computacionales para la extracción de superficies, es posible estudiar cambios dinámicos en los recursos naturales y el desarrollo urbano. Entender e interpretar estos cambios puede ayudar a mejorar la toma de decisiones para reducir la alteración ambiental a pequeña, mediana y gran escala.

Para realizar percepción remota continua a largo plazo de una *RoI* en particular, se requiere de la utilización de múltiples sensores (ejemplo, *TM*, *OLI* y *MSI*). Sin embargo, las condiciones atmosféricas y radiométricas pueden variar por la diferencia de sensor, ángulo solar, condiciones climáticas, entre otras con la que fue registrada la *RoI*. El *PIS* tiende a reducir los efectos de distorsión causados por estas diferencias y condiciones. En la literatura se pueden encontrar diferentes secuencias de pasos a seguir para el *PIS*, es por eso que se debe considerar una amplia revisión de información sobre este tema.

Los resultados para la extracción de superficies utilizando los *IDN/IBM* han ido mejorando, gracias al desarrollo de las nuevas tecnologías satelitales, que ha logrado un incremento en la *RE* de los sensores. Entre mayor sea la *RE*, los *IDN/IBM* pueden ser mejorados, mediante la selección de bandas apropiadas que minimicen la probabilidad de una clasificación errónea de materiales/superficies. Aún más, mediante la comparación de bandas multiespectrales registradas por los sensores *TM*, *OLI* y *MSI*, se pueden desarrollar *IDN/IBM* automáticos que generen resultados comparables a través del tiempo.

## Bibliografía

- [1.1] S. Lavender and A. Lavender, *Practical handbook of remote sensing*. CRC Press, 2015.
- [1.2] G. M. Afrasinei, M. T. Melis, C. Arras, M. Pistis, C. Buttau, and G. Ghiglieri, “Spatiotemporal and spectral analysis of sand encroachment dynamics in southern tunisia,” *European Journal of Remote Sensing*, vol. 51, no. 1, pp. 352–374, 2018.
- [1.3] J. Rouse Jr, R. Haas, J. Schell, and D. Deering, “Monitoring vegetation systems in the great plains with erts,” 1974.
- [1.4] D. K. Hall, G. A. Riggs, and V. V. Salomonson, “Development of methods for mapping global snow cover using moderate resolution imaging spectroradiometer data,” *Remote sensing of Environment*, vol. 54, no. 2, pp. 127–140, 1995.
- [1.5] S. K. McFeeters, “The use of the normalized difference water index (ndwi) in the delineation of open water features,” *International journal of remote sensing*, vol. 17, no. 7, pp. 1425–1432, 1996.
- [1.6] Y. Zha, J. Gao, and S. Ni, “Use of normalized difference built-up index in automatically mapping urban areas from tm imagery,” *International journal of remote sensing*, vol. 24, no. 3, pp. 583–594, 2003.
- [1.7] J. C. Valdiviezo-N, A. Téllez-Quiñones, A. Salazar-Garibay, and A. A. López-Caloca, “Built-up index methods and their applications for urban extraction from sentinel 2a satellite data: discussion,” *JOSA A*, vol. 35, no. 1, pp. 35–44, 2018.
- [1.8] N. Levin, “Fundamentals of remote sensing,” *1st Hydrographic Data Management Course, IMO—International Maritime Academy, Trieste*, vol. 76, 1999.
- [1.9] E. Chuvieco, *Fundamentals of satellite remote sensing*. CRC press, 2009.
- [1.10] “Landsat science.” NASA, 2018 <https://landsat.gsfc.nasa.gov/landsat-5/>. (Accessed: 2 Octubre 2018).
- [1.11] N. E. Young, R. S. Anderson, S. M. Chignell, A. G. Vorster, R. Lawrence, and P. H. Evangelista, “A survival guide to landsat preprocessing,” *Ecology*, vol. 98, no. 4, pp. 920–932, 2017.
- [1.12] “Usgs science for a changing world.” USGS, 2018 <https://earthexplorer.usgs.gov>. (Accessed: 2 Octubre 2018).
- [1.13] A. Edwards, P. Mumby, and C. Clark, “Applications of satellite and airborne image data to coastal management seventh computer-based learning module (bilko for windows),” 1999.

- [1.14] R. C. Gonzalez, R. E. Woods, *et al.*, “Digital image processing,” 2002.
- [1.15] “What are the best landsat spectral bands for use in my research?” USGS, 2018 [https://www.usgs.gov/faqs/what-are-best-landsat-spectral-bands-use-my-research?qt-news\\_science\\_products=7#qt-news\\_science\\_products](https://www.usgs.gov/faqs/what-are-best-landsat-spectral-bands-use-my-research?qt-news_science_products=7#qt-news_science_products). (Accessed: 4 Octubre 2018).
- [1.16] “Landsat data continuity mission.” USGS, 2018 [https://landsat.gsfc.nasa.gov/wp-content/uploads/2012/12/20101119\\_LDCMbrochure.pdf](https://landsat.gsfc.nasa.gov/wp-content/uploads/2012/12/20101119_LDCMbrochure.pdf). (Accessed: 7 Octubre 2018).
- [1.17] “Sentinel-2.” ESA, 2018 <https://earth.esa.int/web/sentinel/missions/sentinel-2>. (Accessed: 8 Octubre 2018).
- [1.18] “Radiometric resolutions.” ESA, 2018 <https://earth.esa.int/web/sentinel/user-guides/sentinel-2-msi/resolutions/radiometric>. (Accessed: 8 Octubre 2018).
- [1.19] P. Bhavani, V. Chakravarthi, P. Roy, P. Joshi, and K. Chandrasekar, “Long-term agricultural performance and climate variability for drought assessment: a regional study from telangana and andhra pradesh states, india,” *Geomatics, Natural Hazards & Risk*, vol. 8, no. 2, 2017.
- [1.20] J. Lin, X. Feng, P. Xiao, H. Li, J. Wang, and Y. Li, “Comparison of snow indexes in estimating snow cover fraction in a mountainous area in northwestern china,” *IEEE Geoscience and Remote Sensing Letters*, vol. 9, no. 4, pp. 725–729, 2012.
- [1.21] Y. Yang, Y. Liu, M. Zhou, S. Zhang, W. Zhan, C. Sun, and Y. Duan, “Landsat 8 oli image based terrestrial water extraction from heterogeneous backgrounds using a reflectance homogenization approach,” *Remote Sensing of Environment*, vol. 171, pp. 14–32, 2015.
- [1.22] R. C. Estoque and Y. Murayama, “Classification and change detection of built-up lands from landsat-7 etm+ and landsat-8 oli/tirs imageries: A comparative assessment of various spectral indices,” *Ecological Indicators*, vol. 56, pp. 205–217, 2015.
- [1.23] N. Otsu, “A threshold selection method from gray-level histograms,” *IEEE transactions on systems, man, and cybernetics*, vol. 9, no. 1, pp. 62–66, 1979.
- [1.24] F. Hui, B. Xu, H. Huang, Q. Yu, and P. Gong, “Modelling spatial-temporal change of poyang lake using multitemporal landsat imagery,” *International Journal of Remote Sensing*, vol. 29, no. 20, pp. 5767–5784, 2008.

- [1.25] G. M. Afrasinei, M. T. Melis, C. Buttau, J. M. Bradd, C. Arras, and G. Ghiglieri, “Assessment of remote sensing-based classification methods for change detection of salt-affected areas (biskra area, algeria),” *Journal of Applied Remote Sensing*, vol. 11, no. 1, p. 016025, 2017.
- [1.26] B. Nath, Z. Niu, and R. Singh, “Land use and land cover changes, and environment and risk evaluation of dujiangyan city (sw china) using remote sensing and gis techniques,” *Sustainability*, vol. 10, no. 12, p. 4631, 2018.
- [1.27] S. S. Bhatti and N. K. Tripathi, “Built-up area extraction using landsat 8 oli imagery,” *GIScience & remote sensing*, vol. 51, no. 4, pp. 445–467, 2014.
- [1.28] C. J. Tucker, B. N. Holben, J. H. Elgin Jr, and J. E. McMurtrey III, “Remote sensing of total dry-matter accumulation in winter wheat,” *Remote Sensing of Environment*, vol. 11, pp. 171–189, 1981.
- [1.29] C. W. Emerson, “Multi-scale fractal analysis of image texture and pattern,” 1998.
- [1.30] A. Bhandari, A. Kumar, and G. Singh, “Feature extraction using normalized difference vegetation index (ndvi): A case study of jabalpur city,” *Procedia technology*, vol. 6, pp. 612–621, 2012.
- [1.31] H. Xu, “Modification of normalised difference water index (ndwi) to enhance open water features in remotely sensed imagery,” *International journal of remote sensing*, vol. 27, no. 14, pp. 3025–3033, 2006.
- [1.32] Z. Du, W. Li, D. Zhou, L. Tian, F. Ling, H. Wang, Y. Gui, and B. Sun, “Analysis of landsat-8 oli imagery for land surface water mapping,” *Remote sensing letters*, vol. 5, no. 7, pp. 672–681, 2014.
- [1.33] G. L. Feyisa, H. Meilby, R. Fensholt, and S. R. Proud, “Automated water extraction index: A new technique for surface water mapping using landsat imagery,” *Remote Sensing of Environment*, vol. 140, pp. 23–35, 2014.
- [1.34] G. Sarp and M. Ozcelik, “Water body extraction and change detection using time series: A case study of lake burdur, turkey,” *Journal of Taibah University for Science*, vol. 11, no. 3, pp. 381–391, 2017.
- [1.35] H. Jiang, M. Feng, Y. Zhu, N. Lu, J. Huang, and T. Xiao, “An automated method for extracting rivers and lakes from landsat imagery,” *Remote Sensing*, vol. 6, no. 6, pp. 5067–5089, 2014.
- [1.36] T. Acharya, A. Subedi, and D. Lee, “Evaluation of water indices for surface water extraction in a landsat 8 scene of nepal,” *Sensors*, vol. 18, no. 8, p. 2580, 2018.
- [1.37] Y. Zhou, J. Dong, X. Xiao, T. Xiao, Z. Yang, G. Zhao, Z. Zou, and Y. Qin, “Open surface water mapping algorithms: A comparison of water-related spectral indices and sensors,” *Water*, vol. 9, no. 4, p. 256, 2017.

- [1.38] J. Dozier, “Spectral signature of alpine snow cover from the landsat thematic mapper,” *Remote sensing of environment*, vol. 28, pp. 9–22, 1989.
- [1.39] P. Sibandze, P. Mhangara, J. Odindi, and M. Kganyago, “A comparison of normalised difference snow index (ndsi) and normalised difference principal component snow index (ndpsi) techniques in distinguishing snow from related land cover types,” *South African Journal of Geomatics*, vol. 3, no. 2, pp. 197–209, 2014.
- [1.40] A. Burton-Johnson, M. Black, P. Fretwell, and J. Kaluza-Gilbert, “An automated methodology for differentiating rock from snow, clouds and sea in antarctica from landsat 8 imagery: a new rock outcrop map and area estimation for the entire antarctic continent,” *The Cryosphere*, vol. 10, pp. 1665–1677, 2016.
- [1.41] Q. Weng, “A remote sensing? gis evaluation of urban expansion and its impact on surface temperature in the zhujiang delta, china,” *International journal of remote sensing*, vol. 22, no. 10, pp. 1999–2014, 2001.
- [1.42] M. Delgadillo-Herrera, M. Arreola-Esquivel, C. Toxqui-Quitl, and A. Padilla-Vivanco, “Normalized difference indices in landsat 5 tm satellite data,” in *Current Developments in Lens Design and Optical Engineering XX*, vol. 11104, p. 111040W, International Society for Optics and Photonics, 2019.

# 2

# Preprocesamiento de imágenes satelitales

## 2.1. Introducción

Antes de realizar cualquier análisis urbano o de recursos naturales, mediante datos obtenidos de la *USGS*, éstos deben ser preprocesados. Las imágenes satelitales Landsat y Sentinel-2 están sujetas a distorsión como resultado de los efectos solares, atmosféricos y topográficos [2.1]. La reducción de estos efectos en imágenes satelitales, es conocido en la literatura con el término de preprocesamiento. El preprocesamiento, ayuda a tener condiciones atmosféricas similares en escenas registradas por diferente sensor, hora, día, estación y latitud [2.1]. Los pasos de preprocesamiento para reducir la distorsión y selección de una misma *RoI* en imágenes Landsat y Sentinel-2 se muestran en la Figura 2.1a y Figura 2.1b.

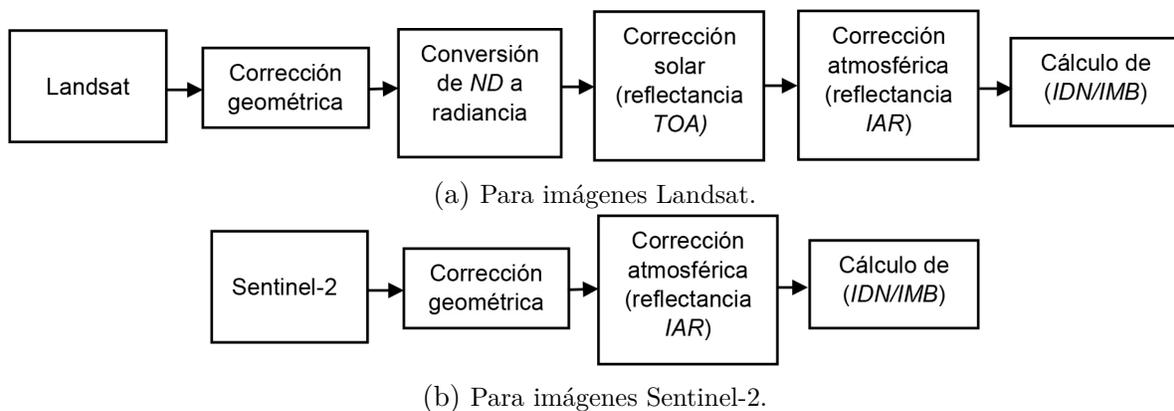


Figura 2.1: Pasos de preprocesamiento para imágenes satelitales.

En este capítulo, se revisa el diseño de algunos de los sistemas satelitales de percepción remota. Así como el proceso físico de formación de imágenes y su muestreo para la generación de imágenes digitales. A partir de la descarga de los datos multiespectrales Landsat y Sentinel-2, se plantean los pasos de preprocesamiento para reducir distorsión

a las imágenes multiespectrales. Dentro de los pasos de preprocesamiento: se muestra un procedimiento para seleccionar la misma *RoI* que puede ser registrada en diferente hora, fecha y sensor satelital. Se revisa el proceso para convertir los *DN* a la radiancia registrada por sensor satelital. Así como la conversión de radiancia a reflectancia *TOA*. Se aplica la corrección atmosférica *IARR* a datos Landsat 5 *TM* y se muestran resultados para diferentes pasos de preprocesamiento. Finalmente se presentan las conclusiones del capítulo.

## 2.2. Sistemas de percepción remota

Los sensores que tienen su propia fuente de iluminación, son conocidos como sensores activos y los que necesitan de una fuente de iluminación externa son sensores pasivos. Un ejemplo de sensor activo es el Radar de Apertura Sintética (*SAR*), que emite pulsos de radiación en la longitud de microondas para iluminar el objeto y registra la señal que regresa/proviene del objeto para generar una imagen. Un sensor pasivo, puede ser una cámara digital, con un sistema óptico como el que se muestra en la Figura 2.2. La energía electromagnética reflejada por la *RoI*, pasa a través del sistema óptico (ejemplo, lente óptica) y es enfocada en el plano focal, donde es registrada por un sensor (ejemplo, Dispositivo de Carga Acoplada (*CCD*)) [2.2]

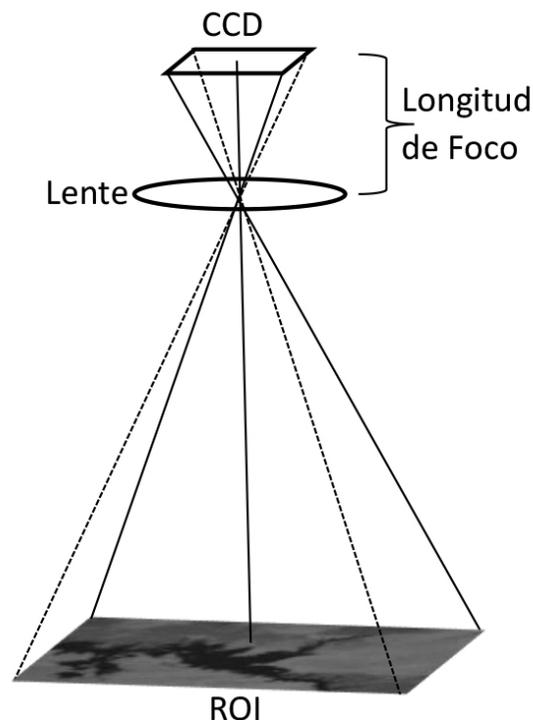


Figura 2.2: Sistema básico de una cámara digital.

Los primeros diseños de sistemas de sensores pasivos eran limitados por un solo sensor *CCD*. La nueva tecnología ha implementado el escaneo mecánico, que permite obtener imágenes multispectrales. En la Figura 2.3, se muestra la implementación de un escaneador multispectral mecánico. El sistema es esencialmente una cámara, pero consta de un espejo giratorio que escanea pixel por pixel y línea por línea a través de la pista (swath) y múltiples *CCDs*, para formar la imagen multispectral. La energía reflejada por la superficie terrestre, incide en el espejo oscilador de escaneo, que gira a una velocidad designada y constante para registrar la reflectancia de las distintas áreas a través del swath. El espejo giratorio dirige la luz blanca hacia un sistema de telescopio óptico (ejemplo, Newtoniano, Cassegrain), para evitar la aberración de color. Posteriormente, la energía incide en un sistema espectrográfico (ejemplo, prisma, espejo dicróico, rejilla o filtro), que descompone la energía incidente en sus diferentes longitudes de onda. Finalmente, el rayo multispectral incide en el arreglo de *CCDs*, que registran la longitud de onda correspondiente a la banda espectral del sensor [2.2] [2.3]. El sistema de fotodiodos, convierte la señal electromagnética en una señal eléctrica. Para las longitudes de onda del visible y *NIR* se utilizan sensores fabricados de Silicio (*Si*), para el *SWIR* Antimonio de Indio (*InSb*) y Teluro de Mercurio y Cadmio (*HgCdTe*) para la banda de Infrarrojo Térmico (*TIR*) [2.4]. Así, conforme el satélite avanza en su camino de órbita, el sistema escanea línea por línea delimitadas por el ancho de pista.

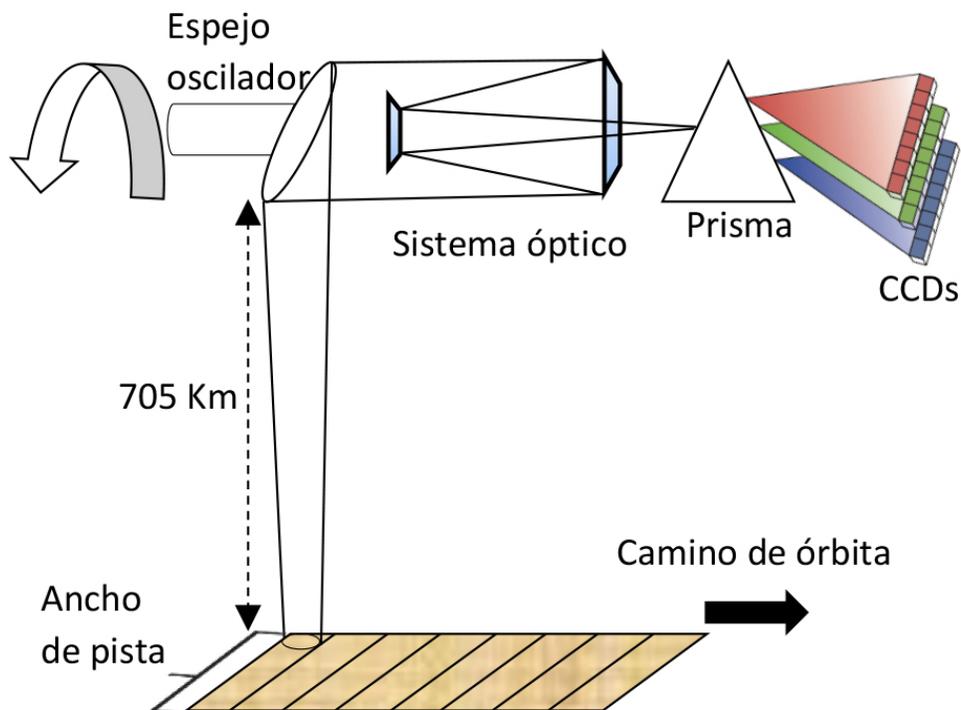


Figura 2.3: Escaneador mecánico multispectral satelital.

Con el rápido desarrollo tecnológico de los sistemas de *CCDs*, se han implementado sistemas de escaneo para adquirir imágenes hiperespectrales. El escaneador de barrido que se muestra en Figura 2.4, es un sistema que puede ser utilizado para adquirir imágenes hiperespectrales y tecnológicamente, es más avanzado que el escaneador mecánico multiespectral. A diferencia del escaneador mecánico que escanea pixel por pixel, el escaneador de barrido, escanea línea por línea simultáneamente a través de la pista y utiliza paneles con múltiples *CCDs* [2.2]. Para la adquisición de imágenes hiperespectrales, utiliza un sistema de espectrómetro, que puede utilizar filtros de interferencia, prisma o rejilla de dispersión para dividir el haz de luz blanca en cientos de longitudes de onda.

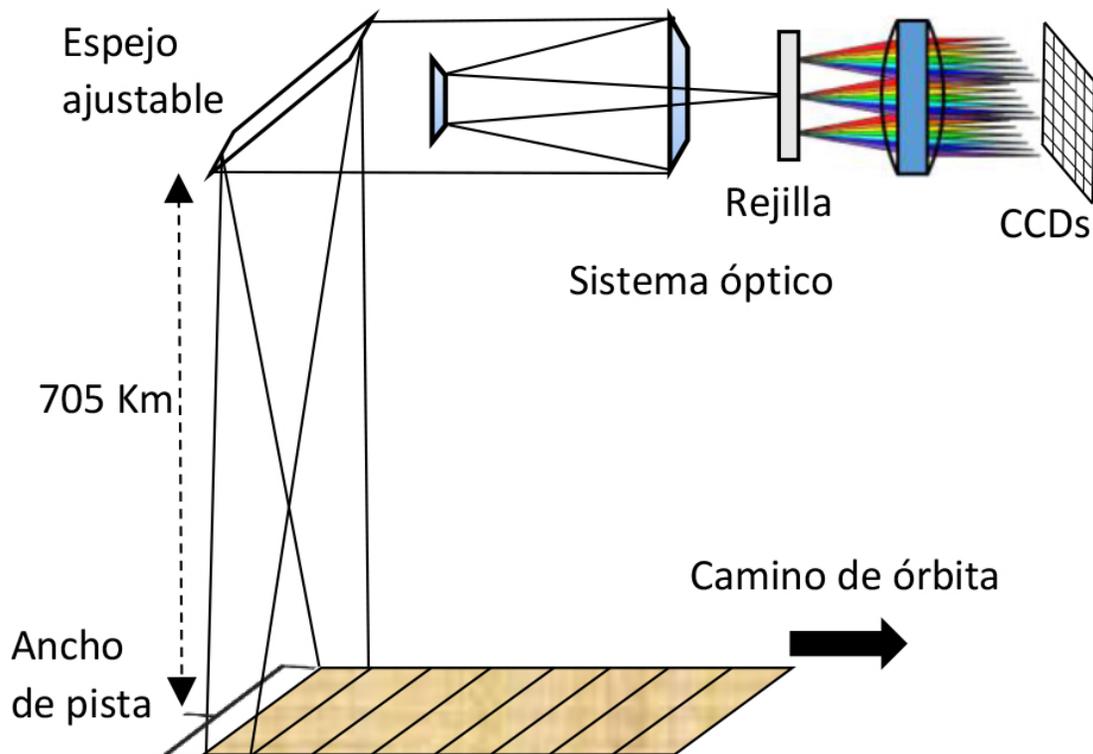


Figura 2.4: Escaneador de barrido satelital.

Los sensores satelitales pasivos, necesitan de una fuente de energía (Sol) que ilumine la *RoI*. La energía electromagnética proveniente del Sol, que no se absorbe o dispersa en la atmósfera e incide en la superficie terrestre es conocida como irradiancia solar ( $\frac{Watts}{m^2}$ ). Dependiendo de las características del objeto/superficie con la que interactúe (ejemplo, solido, líquido) y la longitud de onda incidente, la irradiancia de la Figura 2.5, puede ser:

- Transmitida (pasa a través de una sustancia),
- Absorbida (proporciona energía y calienta a la sustancia),

- Emitida (toda la materia por encima del cero absoluto  $0^{\circ}K$  emiten energía) o
- Reflejada: Especular (la energía es reflejada por la superficie con el mismo ángulo y opuesto al de incidencia). Difusa (la energía es reflejada uniformemente en todas las direcciones).

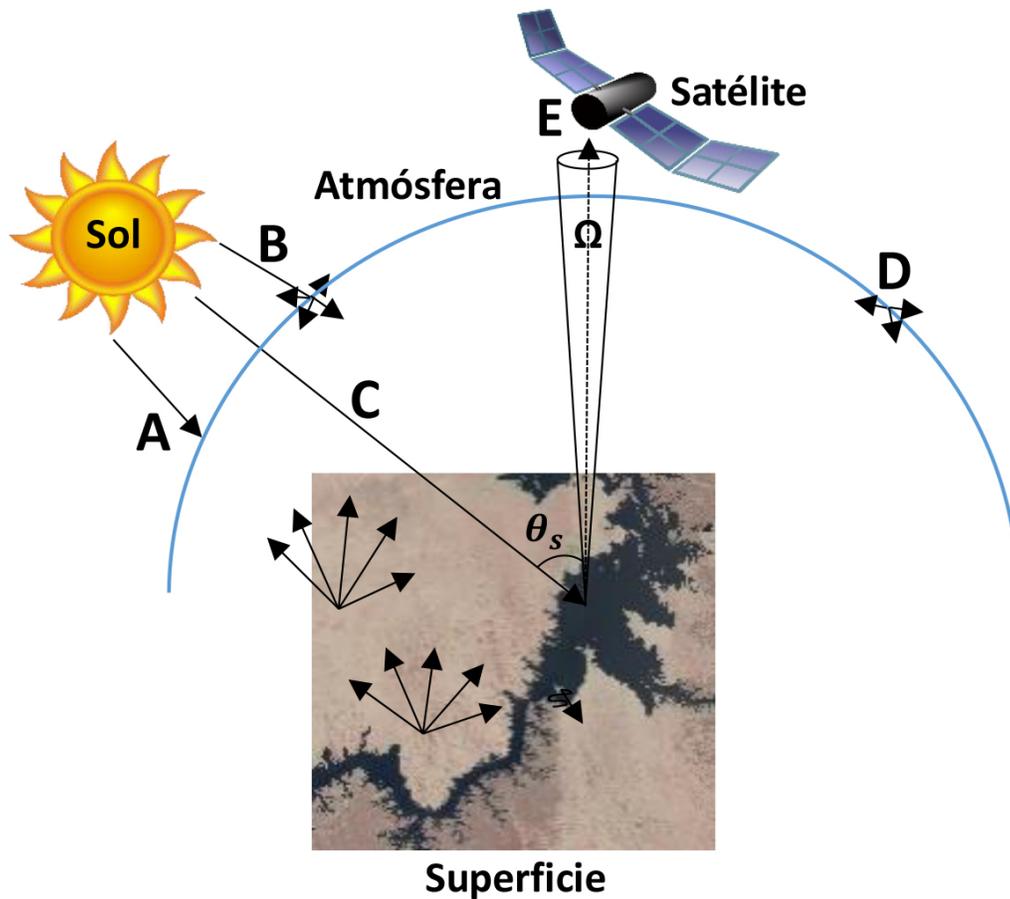


Figura 2.5: El sensor a bordo del satélite, registra la radiancia espectral ( $L_\lambda$ ).

Los sensores satelitales (digitales) pasivos, registran la intensidad de la radiación electromagnética (*RDET*) emitida/reflejada, vista desde la superficie terrestre, como valores digitales (*ND*) para cada banda espectral. El rango de los *ND* depende de las características del sensor (ejemplo, *TM* = 0 - 255 niveles de grises proporcionales a la radiancia registrada). El término de radiancia ( $\frac{Watts}{m^2} \cdot ester - radián^{-1}$ ), se refiere a cualquier radiación que salga de la tierra en cierta dirección (es decir, ascendente, hacia el sensor) [2.5].

La radiancia e irradiancia pueden ser expresadas en términos de unidad de longitud de onda, quedando denominadas como radiancia espectral ( $L_\lambda$ ) e irradiancia espectral ( $E_\lambda$ ). Como se observa en la Figura 2.5E, estrictamente lo que el sensor satelital mide, es la  $L_\lambda$ , con unidades ( $\frac{Watts}{m^2} \cdot ester - radián^{-1} \cdot \mu m^{-1}$ ). Donde,

- *Watts* es la proporción de flujo radiante transmitido, emitido o reflejado registrado por un sensor, por metro cuadrado ( $m^2$ ) de la superficie terrestre. Para un ester-radián ( $(\Omega)$  ángulo tridimensional desde un punto en la superficie de la Tierra hasta el sensor), por unidad de longitud de onda ( $\mu m^{-1}$ ) que se mide.

La  $L_\lambda$  depende del grado de iluminación del objeto (es decir, la irradiancia), que a su vez es dependiente de factores como el ángulo cenital solar ( $\theta_s$ ), que puede variar por la diferencia de hora, día, estación, latitud, etc.

Generalmente, para realizar percepción remota satelital a largo plazo, la  $L_\lambda$  registrada por el sensor se convierte a reflectancia. Desde que la reflectancia representa la relación de radiancia e irradiancia, esto proporciona una medida estandarizada, que es directamente comparable entre imágenes registradas en diferente hora y fecha. La reflectancia no tiene unidades y se mide en una escala de 0 a 1 (o de 0 a 100 %) [2.6].

Mientras que  $L_\lambda$  puede ser obtenida de la calibración del sensor, varios factores todavía complican la calidad de los datos satelitales. Antes de que la *RDET* sea registrada por el sensor satelital, primero pasa a través de la atmósfera, en su trayectoria del sol a la superficie terrestre y una segunda vez de la superficie al sensor. En su interacción con la atmósfera, dos mecanismos pueden afectar la *RDET*, conocidos como absorción y dispersión atmosférica mostrados en la Figura 2.5A, Figura 2.5B y Figura 2.5D.

La absorción vista en la Figura 2.5A, se produce cuando la *RDET* interactúa con gases como vapor de agua, dióxido de carbono y ozono, absorbiendo casi/toda su intensidad. Por otra parte, la dispersión o esparcimiento de Rayleigh mostrado en la Figura 2.5B y Figura 2.5D, ocurre cuando las partículas son muy pequeñas en comparación con la longitud de onda de radiación. Estas partículas pueden ser de polvo o moléculas nitrógeno y oxígeno [2.7].

La absorción y la dispersión atmosférica crean un efecto distorsión en las imágenes multispectrales. La dispersión también crea el *efecto de adyacencia* en el que la radiancia registrada para un píxel dado parcialmente incorpora la radiancia dispersa de los píxeles vecinos [2.7]. Para hacer una medida significativa de la  $L_\lambda$ , las interferencias atmosféricas deben eliminarse de los datos multispectrales. Este proceso es conocido como corrección atmosférica.

## 2.3. Corrección geométrica

La *USGS* y *ESA*, proporcionan datos de Nivel 1 (*L1T*) Landsat y Nivel 1C (*L1C*) de Sentinel-2, que se encuentran georreferenciados (alineación a su ubicación geográfica) y orto-rectificados (corrección de efectos de relieve) [2.1]. Las coordenadas de latitud y longitud de las cuatro esquinas de cada imagen multispectral, se encuentran almacenadas en el archivo de metadatos (ejemplo, Landsat (*MTL*), Sentinel-2 (*MTL\_MSI*)) adjunto a cada paquete. La corrección geométrica, permite obtener la misma *RoI* en imágenes satelitales registradas en diferente hora, fechas y sensor satelital. En la Figura 2.6a, se muestra una imagen *RGB*, para ejemplificar la selección de una misma *RoI*, en una escena Landsat con centro  $p(x_c, y_c)$  previamente seleccionado. Las coordenadas de las esquinas Noroeste (*NW*), Noreste (*NE*), Suroeste (*SW*) y Sureste (*SE*) pueden indicarse como  $NW = (x_B; y_B)$ ,  $NE = (x_A; y_A)$ ,  $SW = (x_D; y_D)$  y  $SE = (x_E; y_E)$  respectivamente. Las distancias  $d_1 = |y_C - y_B|$ ,  $d_2 = |x_C - x_B|$ ,  $d_3 = |y_C - y_E|$  y  $d_4 = |x_C - x_E|$  del centro de la *RoI*  $p(x_c, y_c)$  son expresadas en píxeles como [2.8],

$$d_{1p} = L \frac{d_1}{d_1 + d_2}; \quad d_{2p} = W \frac{d_2}{d_2 + d_4}, \quad (2.1)$$

$$d_{3p} = L \frac{d_3}{d_1 + d_3}; \quad d_{4p} = W \frac{d_4}{d_2 + d_4}, \quad (2.2)$$

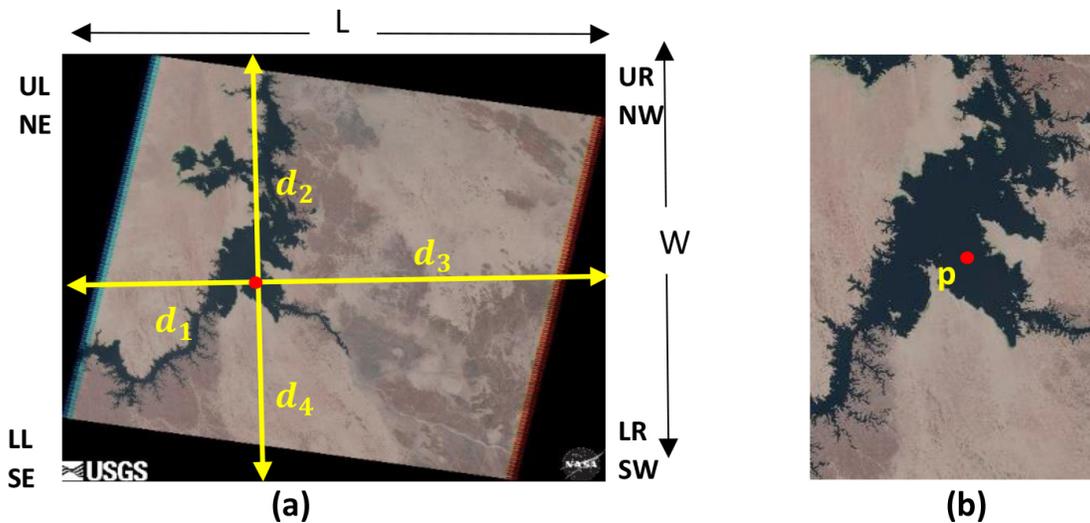


Figura 2.6: Landsat 5 *TM*: (a) Selección geométrica de una imagen *RGB* de dimensión  $7721 \times 6891$  píxeles y (b) Extracción de la *RoI* con centro  $p(d_{1p}, d_{2p})$  con tamaño de  $1911 \times 2959$  píxeles [2.9].

donde  $L$  y  $W$  delimitan el tamaño de la imagen en píxeles. Una vez determinadas las distancias de la imagen Landsat en términos de píxeles, la  $RoI$  puede ser extraída con centro  $p(d_{1p}, d_{2p})$ , como se muestra en la Figura 2.6b.

El proceso para seleccionar la misma  $RoI$  mostrado de la Figura 2.6 en imágenes Landsat, puede ser aplicado en imágenes Sentinel-2, mediante el software Matlab. Otra forma de seleccionar la misma  $RoI$ , de forma automática en imágenes Landsat y Sentinel-2, es utilizando el software *ENVI* versión 5.1 (Exelis Visual Information Solutions, Boulder, Colorado). En *ENVI*, se pueden traslapar una o más bandas registradas por uno o varios sensores satelitales a la vez. Esto permite seleccionar la misma  $RoI$ , utilizando un vector de la misma dimensión, para todas las imágenes multiespectrales de estudio. En la Figura 2.7a, se muestra una imagen compuesta por tres bandas ( $RGB$ ) Landsat y en la Figura 2.7b una banda espectral ( $NIR$ ) Sentinel-2. A la derecha de la Figura 2.7, se observa el resultado de la selección de misma  $RoI$ , registrada por los dos sensores satelitales.

En este ejemplo, la imagen  $NIR$  de Sentinel-2, se redimensiona, para obtener una resolución espacial consistente con los datos Landsat. La redimensión de las imágenes multiespectrales Sentinel-2, se realizó mediante el algoritmo del vecino más próximo, utilizando la plataforma de aplicación de Sentinel-2 (*SNAP*).

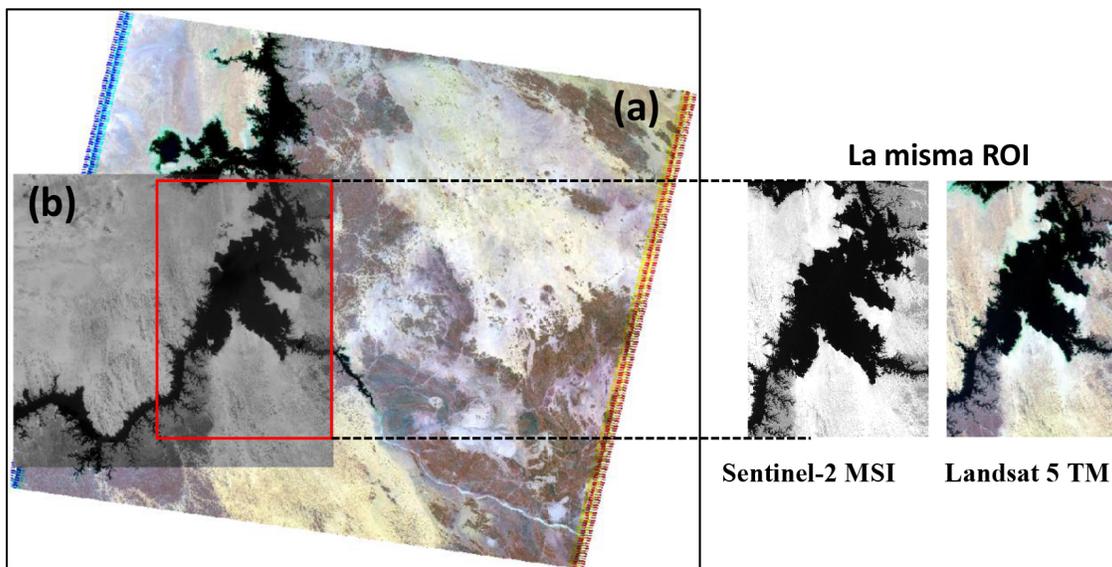


Figura 2.7: Selección de la misma  $RoI$  del río Nasser mediante el software *ENVI*, en datos satelitales: (a) Landsat 5  $TM$  y (b) Sentinel-2  $MSI$ .

## 2.4. Conversión de $ND$ a radiancia

La calibración del sensor satelital (relación entre la  $L_\lambda$  y el  $ND$ ) se lleva a cabo antes de ser lanzado a órbita. Sin embargo, esta calibración puede variar por la degradación que sufre el sensor a través del tiempo. Una forma de reducir este efecto, es mediante la conversión de  $ND$  a la  $L_\lambda$ . Durante la calibración radiométrica, los valores digitales crudos ( $Q$ ) de las imágenes multispectrales sin procesar, son convertidos a  $L_\lambda$  utilizando 32 bits. Posteriormente, estos valores de radiancia son reescalados a (ejemplo,  $TM = Q_{calmax} = 255$ ) valores de pixel calibrados ( $Q_{cal}$ ). Los  $ND$  que finalmente son distribuidos en los portales de internet son  $Q_{cal}$ . Para convertir los  $Q_{cal}$  nuevamente a  $L_\lambda$ , se necesita conocimiento de los límites superiores e inferiores de reescalado originales (ejemplo, radiancia máxima y mínima). Los datos satelitales  $L1T$  y  $L1C$  proporcionan un archivo adjunto (ejemplo,  $MTL$  de Landsat) a cada paquete, que contiene los valores de sus límites originales. Para convertir nuevamente  $Q_{cal}$  a  $L_\lambda$  se utiliza la expresión [2.10],

$$L_\lambda = G_{rescal} \times Q_{cal} + B_{rescal}, \quad (2.3)$$

para

$$G_{rescal} = \frac{LMAX_\lambda - LMIN_\lambda}{Q_{calmax} - Q_{calmin}}; \quad (2.4)$$

$$B_{rescal} = LMIN_\lambda - \frac{LMAX_\lambda - LMIN_\lambda}{Q_{calmax} - Q_{calmin}} Q_{calmin}, \quad (2.5)$$

donde

- $L_\lambda$  = radiancia espectral en la apertura del sensor [ $W/(m^2 sr \mu m)$ ]
- $Q_{cal}$  = valor del pixel calibrado cuantizado [( $DN$ )]
- $Q_{calmin}$  = valor del pixel calibrado cuantizado mínimo (1) correspondiente a  $LMIN_\lambda$  [( $DN$ )]
- $Q_{calmax}$  = valor del pixel calibrado cuantizado máximo (255) correspondiente a  $LMAX_\lambda$  [( $DN$ )]
- $LMIN_\lambda$  = radiancia espectral mínima en el sensor, escalada a  $Q_{calmin}$  [ $W/(m^2 sr \mu m)$ ]
- $LMAX_\lambda$  = radiancia espectral máxima en el sensor, escalada a  $Q_{calmax}$  [ $W/(m^2 sr \mu m)$ ]
- $G_{rescal}$  = factor de ganancia (gain) reescalado para una banda en específico [ $(\frac{W}{m^2 sr \mu m})/DN$ ]
- $B_{rescal}$  = factor de sesgo (bias) reescalado para una banda en específico [ $\frac{W}{m^2 sr \mu m}$ ]

## 2.5. Conversión de $L_\lambda$ a reflectancia en la parte superior de la atmósfera ( $TOA$ )

El ángulo cenital solar, la irradiancia solar exo-atmosférica y la distancia Tierra-Sol pueden variar en las imágenes satelitales registradas en diferente fecha y hora. Esta variabilidad entre escenas, puede reducirse calculando la reflectancia en la parte superior de la atmosfera ( $TOA$ ), mediante la expresión [2.10].

$$\rho_\lambda = \frac{\pi \cdot L_\lambda \cdot d^2}{ESUN_\lambda \cdot \cos \theta_s}, \quad (2.6)$$

donde

- $\rho_\lambda$  = reflectancia en la parte superior de la atmósfera  $TOA$  [sin unidades]
- $\pi$  = constante matemática (3.14159) [sin unidades]
- $L_\lambda$  = radiancia espectral en la apertura del sensor [ $W/(m^2 sr \mu m)$ ]
- $d$  = distancia del sol a la tierra [unidades astronómicas]
- $ESUN_\lambda$  = irradiancia media solar exo-atmosférica [ $W/(m^2 sr \mu m)$ ]
- $\theta_s$  = ángulo cenital solar [grados]

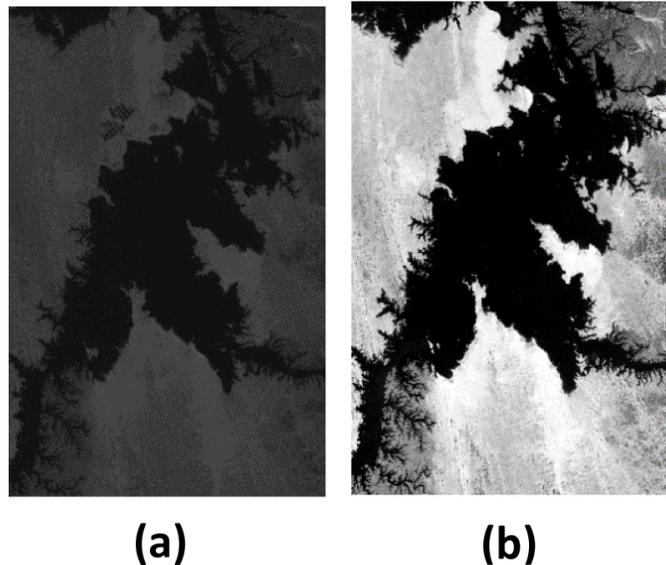


Figura 2.8:  $RoI$  del Lago Nasser de Egipto, ubicado a una Latitud:  $23.104626^\circ$  y Longitud:  $32.806267^\circ$ , registrada por el satélite Landsat 5  $TM$ : (a) Banda Verde sin corrección radiométrica y (b) resultado de la corrección de  $L_\lambda$  y  $TOA$  de (a).

Los valores (ejemplo,  $d$ ,  $ESUN_\lambda$ ,  $\theta_s$ ) para calcular  $\rho_\lambda$ , se encuentran almacenados en el archivo de metadatos adjunto a cada imagen espectral. Tanto la  $L_\lambda$  como  $\rho_\lambda$  pueden ser calculadas mediante el software *ENVI*, el cual extrae los valores almacenados en el archivo de metadatos de forma automática. En la Figura 2.8a, se muestra una *RoI* sin el preprocesamiento de  $L_\lambda$  y  $\rho_\lambda$  registrada por el sensor *TM* (banda, Verde). Por otra parte, en la Figura 2.8b, se observa la misma *RoI* de (a) con el preprocesamiento de  $L_\lambda$  y  $\rho_\lambda$ .

## 2.6. Corrección atmosférica (reflectancia *IAR*)

La reflectancia relativa media interna (*IARR*), es calculada obteniendo el espectro promedio de toda la *RoI* (espectro de referencia), dividido por el espectro de cada pixel que integran la *RoI*. La reflectancia *IAR* propuesta por Krusse en 1988, es utilizada para normalizar imágenes a un espectro de *RoI* promedio. De acuerdo con Krusse, *IARR* puede reducir efectos atmosféricos, al calcular la razón del espectro de referencia y el espectro de cada pixel de *RoI*, ya que tienen las mismas contribuciones atmosféricas [2.11], [2.12], [2.13]. En la Figura 2.9, se observa la extracción del cuerpo de agua del lago Nasser, utilizando el método  $AWEI_{nsh}$  para diferentes pasos de preprocesamiento, en imágenes Landsat 5 *TM* [2.14].

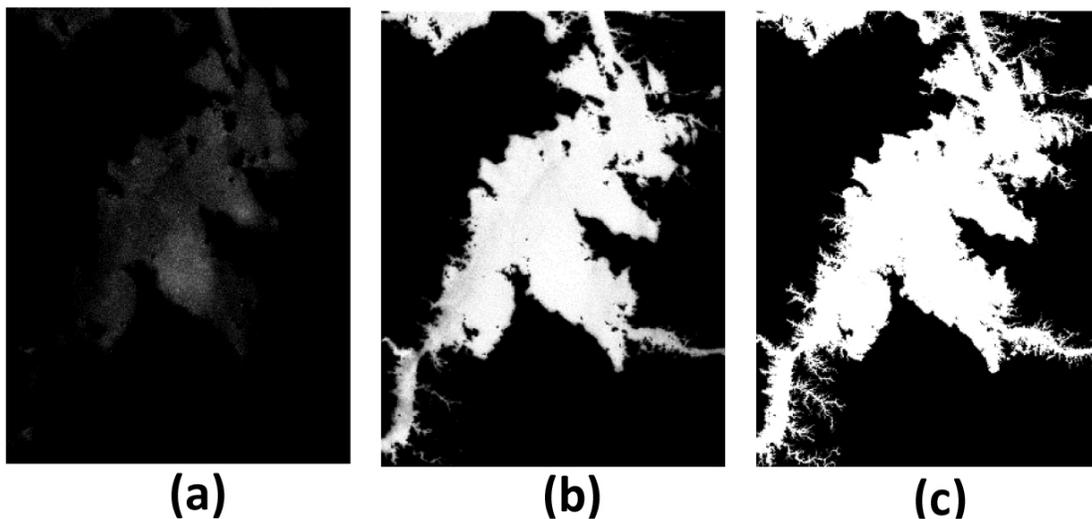


Figura 2.9: Extracción del Lago Nasser mediante el método  $AWEI_{nsh}$  utilizando imágenes *TM*: (a) resultado sin corrección radiométrica, (b) imagen con corrección  $L_\lambda$  y *TOA*, y (c) resultado de la corrección  $L_\lambda$ , *TOA* e *IARR*.

Las imágenes multiespectrales *L1C* de Sentinel-2, que se descargan del portal de *ESA*, se encuentran corregidas con el preprocesamiento de  $L_\lambda$  y *TOA*. En la Figura 2.10, se observa la extracción del cuerpo de agua del lago Nasser, utilizando el método  $AWEI_{nsh}$  para diferentes pasos de preprocesamiento, en imágenes Sentinel-2 *MSI* [2.14].

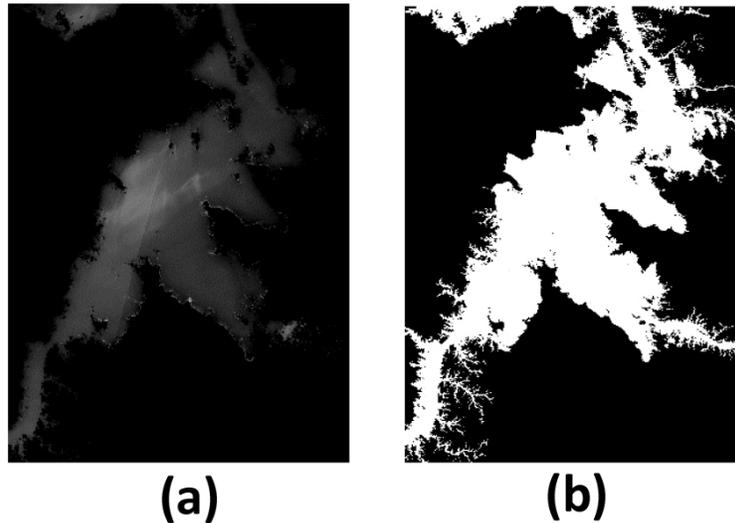


Figura 2.10: Extracción del Lago Nasser mediante el método  $AWEI_{nsh}$  utilizando imágenes *MSI*: (a) Resultado de imágenes *ESA* con corrección  $L_\lambda$  y *TOA* y (b) Resultado de la corrección atmosférica *IARR*.

## 2.7. Conclusiones

Los pasos de corrección para el preprocesamiento de imágenes satelitales, permiten obtener escenas en condiciones atmosféricas similares, registradas en diferente fecha, hora y espacio. En la literatura se pueden encontrar diversos pasos a seguir para la corrección radiométrica y atmosférica de imágenes satelitales. En este estudio, se toma en cuenta el número de pasos de preprocesamiento, para no alterar la información de las imágenes segmentadas resultantes.

La corrección geométrica, es una ventaja considerable en el ahorro tiempo y recurso computacional. El preprocesamiento es aplicado solo a la *RoI*, que es una imagen pequeña en comparación con la escena completa registrada por el sensor satelital. Además, permite el análisis de la misma *RoI* en diferentes momentos y registrada por diferentes sensores. Las correcciones  $L_\lambda$  y *TOA* aplicadas a la *RoI* del lago Nasser, generan resultados con mayor contraste, en comparación con la banda que no han tenido ningún tipo de preprocesamiento.

---

La calidad de los resultados de los *IDN/IMB*, puede variar de acuerdo al método utilizado y al grado de preprocesamiento por el que son sometidos los datos satelitales. Los datos *L1T* de Landsat y *L1C* de Sentinel-2, tienen un bajo efecto atmosférico. Por esta razón, la corrección atmosférica *IARR* reduce los efectos atmosféricos. Para el caso en que las contribuciones atmosféricas no fueran uniformes, *IARR* tendría un bajo desempeño, añadiendo artefactos en vez de eliminarlos.

## Bibliografía

- [2.1] N. E. Young, R. S. Anderson, S. M. Chignell, A. G. Vorster, R. Lawrence, and P. H. Evangelista, “A survival guide to landsat preprocessing,” *Ecology*, vol. 98, no. 4, pp. 920–932, 2017.
- [2.2] J. Liu, “Remote sensing | passive sensors,” *Encyclopedia of Geology*, pp. 431–439, 2005.
- [2.3] G. Chander and B. Markham, “Revised landsat-5 tm radiometric calibration procedures and postcalibration dynamic ranges,” *IEEE Transactions on geoscience and remote sensing*, vol. 41, no. 11, pp. 2674–2677, 2003.
- [2.4] N. Landsat, “Science data users handbook,” 2011.
- [2.5] E. Chuvieco, *Fundamentals of satellite remote sensing*. CRC press, 2009.
- [2.6] A. Edwards, P. Mumby, and C. Clark, “Applications of satellite and airborne image data to coastal management seventh computer-based learning module (bilko for windows),” 1999.
- [2.7] N. Levin, “Fundamentals of remote sensing,” *1st Hydrographic Data Management Course, IMO—International Maritime Academy, Trieste*, vol. 76, 1999.
- [2.8] J. C. Valdiviezo-N, R. Castro, G. Cristóbal, and A. Carbone, “Hurst exponent for fractal characterization of landsat images,” in *Remote sensing and modeling of ecosystems for sustainability Xi*, vol. 9221, p. 922103, International Society for Optics and Photonics, 2014.
- [2.9] N. Landsat, “Landsat 5.”
- [2.10] G. Chander, B. L. Markham, and D. L. Helder, “Summary of current radiometric calibration coefficients for landsat mss, tm, etm+, and eo-1 ali sensors,” *Remote sensing of environment*, vol. 113, no. 5, pp. 893–903, 2009.
- [2.11] F. A. Kruse, “Use of airborne imaging spectrometer data to map minerals associated with hydrothermally altered rocks in the northern grapevine mountains, nevada, and california,” *Remote Sensing of Environment*, vol. 24, no. 1, pp. 31–51, 1988.
- [2.12] E. Ben-Dor and F. Kruse, “The relationship between the size of spatial subsets of ger 63 channel scanner data and the quality of the internal average relative reflectance (iarr) atmospheric correction technique,” *REMOTE SENSING*, vol. 15, no. 3, pp. 683–690, 1994.
- [2.13] R. Pu, *Hyperspectral remote sensing: fundamentals and practices*. CRC Press, 2017.

- 
- [2.14] G. L. Feyisa, H. Meilby, R. Fensholt, and S. R. Proud, “Automated water extraction index: A new technique for surface water mapping using landsat imagery,” *Remote Sensing of Environment*, vol. 140, pp. 23–35, 2014.



# 3

# Índices de diferencia normalizada (*IDN*) e Índices Multi-Banda (*IMB*)

---

## 3.1. Introducción

El desempeño de los *IDN* e *IBM* para maximizar el contraste de intensidad entre la superficie de estudio de otro tipo de materiales, es variado entre los resultados de segmentación. Esta variación, tiene que ver con la diversidad geográfica de la *RoI*, las bandas espectrales involucradas y la expresión algebraica del algoritmo [3.1]. En la *RoI*, se puede encontrar una gran diversidad de objetos, cada uno con una composición compleja diferente. La firma espectral de cada objeto, mide la energía reflejada (o emitida), sobre un muestreo espectral (longitudes de onda) dependiente de la *RE* del sensor utilizado [3.2]. Cada patrón de respuesta es único para cada material. Al comparar estos patrones espectrales, se puede distinguir un objeto de otro. Sin embargo, es muy probable que los materiales no puedan ser distinguidos, si se está utilizando una sola longitud de onda o longitudes de onda con respuesta espectral similar [3.3].

El efecto de la dispersión atmosférica, puede alterar los valores de radiancia de las bandas registradas por un sensor satelital. Para realizar el análisis espectral de materiales, es conveniente obtener firmas espectrales con mayor consistencia. El utilizar imágenes multiespectrales/hiperespectrales, registradas por un sensor que se encuentre a una distancia cercana (ejemplo, 20 *km*) a la superficie terrestre, puede reducir el

efecto de dispersión [3.4].

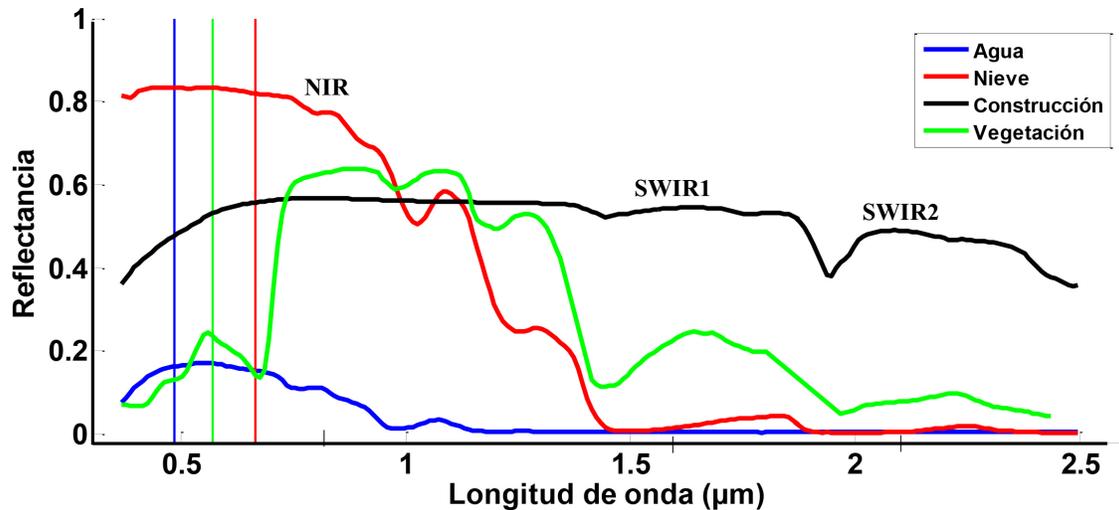


Figura 3.1: Curvas de reflectancia espectral características (Datos originales tomados de *USGS* Laboratorio de espectroscopía): 224 bandas pertenecientes al espectrómetro *AVIRIS*, con muestreo espectral contiguo de  $10\text{nm}$  y rango espectral de  $400\text{-}2500\text{ nm}$  [3.5].

Entre los patrones de respuesta espectral de la Figura 3.1, se observa una similitud de reflectancia en el rango del visible para el agua y la vegetación. Por otra parte, se percibe una diferencia de reflectancia significativa entre estos dos materiales en la longitud de onda *NIR*, que decrece en el *SWIR1* y *SWIR2*. La curva de respuesta de la vegetación saludable, generalmente presenta una absorción mayor en las longitudes de onda de  $0.45\text{ m}\mu$  y  $0.67\text{ m}\mu$  (bandas de absorción por la clorofila). La alta absorción del rojo y el azul de las hojas saludables, permite que el ojo humano perciba el color verde, que es mayormente reflejado [3.4]. La respuesta espectral de la vegetación, puede cambiar conforme los niveles de clorofila disminuyen, incrementando la reflectancia en el rojo. El rango entre  $0.68\text{ m}\mu$  y  $0.75\text{ m}\mu$  es conocido como borde rojo, que es donde la reflectancia de la vegetación sana incrementa considerablemente. En el rango entre  $0.75\text{ m}\mu$  y  $1.3\text{ m}\mu$ , las hojas sanas reflejan de 40 % a 50 % la energía incidente [3.4]. En las longitudes de onda del *SWIR1* y *SWIR2*, la reflectancia disminuye, por la concentración de agua en las hojas verdes.

El agua tiene una firma espectral característica, que muestra una alta absorción en las longitudes de onda del *NIR*, *SWIR1* y *SWIR2*. Por otra parte, el agua tiene su mayor reflectancia en la región del visible, en el que resalta un ligero pico en la longitud de onda del verde y decae hacia el azul y el rojo. La firma espectral de la nieve, muestra una fuerte reflectancia en el rango del visible y *NIR*, que decae en el *SWIR1* y *SWIR2*, a prácticamente cero. Entre los espectros analizados, el de construcción es

probablemente el más plano, con una brillantez alta y continua en la mayoría de longitudes de onda de su firma espectral.

En este capítulo se hace una introducción al análisis de firmas espectrales de los diferentes materiales utilizando datos hiperespectrales. Posteriormente, se muestra la selección de un píxel multispectral utilizando datos satelitales Landsat 5 *TM* y se muestra su respectiva firma espectral. Se revisa la metodología de los algoritmos computacionales *IDN* e *IBM*. Así como la expresión matemática de los métodos propuestos *AWI - MS* y *ASI - MS*. Finalmente se presentan las conclusiones del capítulo.

## 3.2. Índice de Vegetación de Diferencia Normalizada (*NDVI*)

En la Figura 3.2a, se puede observar un píxel multispectral de vegetación en las seis bandas del satélite Landsat 5 *TM*. En la Figura 3.2b, se observa la firma espectral del píxel de (a). Al igual que en la Figura 3.1, se distingue una baja reflectancia en el rango del visible (azul, verde y rojo) y en el *SWIR2*. Por otra parte, se obtiene una mayor reflectancia en el *NIR*.

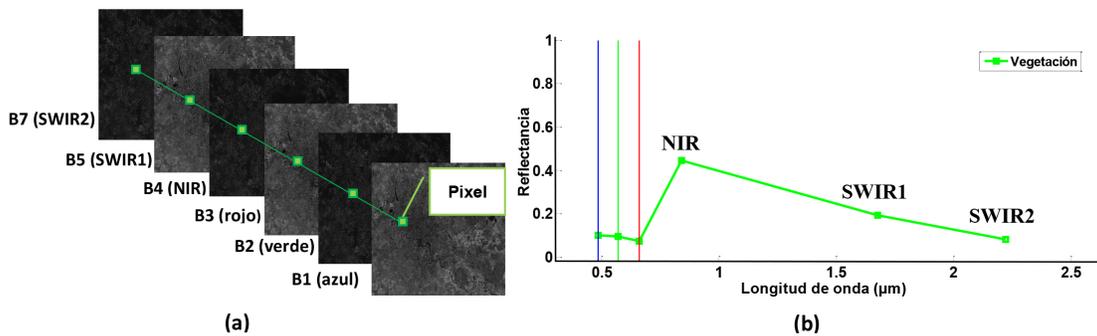


Figura 3.2: (a) Selección de un píxel que pertenece a la vegetación en seis bandas espectrales de Landsat 5 *TM*, y (b) firma espectral del píxel de vegetación.

Entre los primeros métodos de *IDN* propuestos en la literatura para el monitoreo de recursos naturales, destaca el Índice de Vegetación de Diferencia Normalizada (*NDVI*). El objetivo de *NDVI*, es maximizar la alta reflectancia del *NIR* y minimizar la baja reflectancia del Rojo, que produce la vegetación por sus características. El algoritmo *NDVI* se define como [3.6], [3.7],

$$NDVI = \frac{(NIR - Rojo)}{(NIR + Rojo)}, \quad (3.1)$$

donde Rojo y NIR son bandas espectrales definidas en la Tabla 1.2

### 3.3. Métodos para la extracción de cuerpos de agua

En base al análisis espectral del agua, se han desarrollado diferentes métodos para la extracción de cuerpos de agua. El propósito es, aumentar el contraste de intensidad de los píxeles pertenecientes a la superficie del agua, de los píxeles del fondo (vegetación, construcción, suelo, entre otros). La Figura 3.3a muestra la selección de un píxel perteneciente al agua en un cubo multi-espectral de 6 bandas *TM*. La Figura 3.3b indica la respuesta espectral del píxel de agua (a) seleccionado. Se observa un mayor reflectancia en la porción del visible (azul, verde y rojo) y una baja reflectancia en las longitudes de onda del *NIR* y *SWIR*.

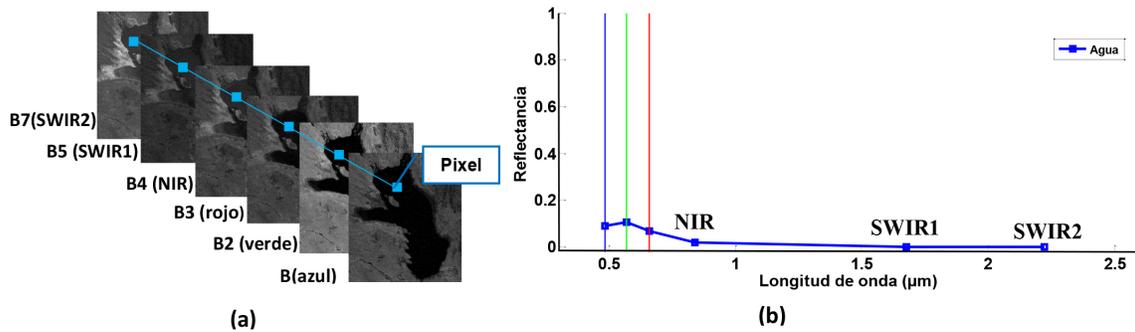


Figura 3.3: (a) Selección de un píxel que pertenece al agua en seis bandas espectrales de Landsat 5 *TM*, y (b) firma espectral del píxel del agua.

#### 3.3.1. Índice de Agua de Diferencia Normalizada Modificado (*MNDWI*)

Basado en la metodología de *NDVI*, el Índice de Agua de Diferencia Normalizada Modificado (*MNDWI*) propuesto por Xu en el 2006, es utilizado para la delimitación de cuerpos de agua. El cálculo del *MNDWI* producirá los siguientes resultados:

- El agua tendrá valores positivos, ya que absorbe el *SWIR1*
- Las zonas de construcción y suelo tendrán valores negativos, debido a que reflejan el *SWIR1*

El algoritmo *MNDWI* se define como [3.8],

$$MNDWI = \frac{(Verde - SWIR1)}{(Verde + SWIR1)}, \quad (3.2)$$

donde las bandas Verde y *SWIR1* se encuentran definidas en la Tabla 1.2.

### 3.3.2. Índice de Extracción de Agua Automatizado ( $AWEI_{nsh}$ ) sin sombra

En el año 2014, Feyisa propone el Índice de Extracción de Agua Automatizado ( $AWEI_{nsh}$ ) sin sombra, como una combinación algebraica de bandas espectrales. El Índice Multi-Banda ( $IMB$ )  $AWEI_{nsh}$ , muestra un mejor desempeño para diferenciar pixeles de agua y no agua que  $MNDWI$ . También, denota un incremento significativo en el aumento de contraste, entre el cuerpo de agua y otro tipo de superficies.  $AWEI_{nsh}$  está definido como [3.9],

$$AWEI_{nsh} = 4(R_{VerdeVerde} - R_{SWIR1SWIR1}) - (0.25R_{NIRNIR} + 2.75R_{SWIR2SWIR2}), \quad (3.3)$$

donde  $R_{banda}$  es el valor de reflectancia de la banda: Verde,  $NIR$ ,  $SWIR1$  y  $SWIR2$  definidas en la Tabla 1.2.

### 3.3.3. Índice de Agua Automático para Múltiples Superficies ( $AWI - MS$ )

Para remover artefactos (pixeles que no pertenecen al agua), los métodos  $NDWI$ ,  $MNDWI$  y  $AWEI_{nsh}$ , utilizan un valor fijo de umbral. Sin embargo, cierta información (pixeles de agua) puede ser removida de la  $RoI$ . El método propuesto en este estudio, es el Índice de Agua Automático para Múltiples Superficies ( $AWI - MS$ ). El algoritmo  $AWI - MS$ , está diseñado para separar con exactitud los pixeles de agua de los que no lo son, sin binarizar las imágenes resultantes.  $AWI - MS$  está definido como,

$$AWI - MS = K(R_{VerdeVerde} - 2.75R_{SWIR1SWIR1}) + (R_{VerdeVerde} + 2.75R_{SWIR1SWIR1}), \quad (3.4)$$

donde  $K$  es el coeficiente de aumento de contraste entre el cuerpo de agua y otro tipo de superficies,  $R_{banda}$  es el valor de reflectancia de la banda: Verde y  $SWIR1$  que se muestran en la Tabla 1.2. El algoritmo  $AWI - MS$  producirá los siguientes resultados:

- La diferencia de contraste entre el cuerpo de agua y otro tipo de materiales será más intenso, por el valor de  $K$  utilizado.
- Maximiza la reflectancia del agua, utilizando la longitud de onda del verde.
- Minimiza la baja reflectancia del  $SWIR1$  absorbida por el agua.
- Para aumentar los valores de intensidad positivos del agua, el  $SWIR1$  es multiplicado por el coeficiente de 2.75.
- Aprovecha la reflectancia de  $SWIR1$  por la vegetación y el suelo, y asigna valores negativos o nulos para suprimirlos de la  $RoI$ .

### 3.4. Métodos para la Extracción de Superficies de Nieve/Hielo

Basándose en la respuesta espectral de los materiales, se han desarrollado diferentes algoritmos para la extracción de superficies de nieve/hielo. En la Figura 3.4a, se observa la selección de un píxel perteneciente a la nieve/hielo, en una imagen multispectral *TM*. La firma espectral del píxel de nieve/hielo, puede verse en la Figura 3.4b. En el que se distingue una mayor reflectancia en la longitud de onda del Rojo y *NIR*, decayendo en el *SWIR*.

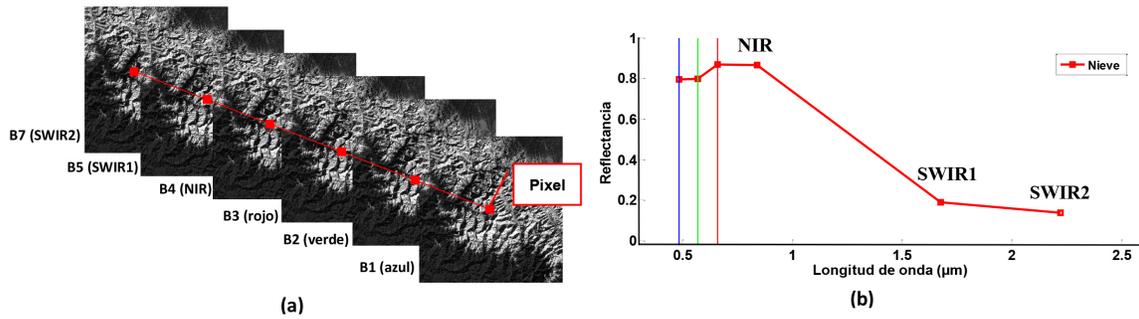


Figura 3.4: (a) Selección de un píxel de nieve/hielo en seis bandas espectrales de Landsat 5 *TM*, y (b) firma espectral del píxel de nieve/hielo de (a)

#### 3.4.1. Índice de Nieve de Diferencia Normalizada (*NDSI*)

Para identificar la nieve, Hall [3.10] introdujo el Índice de Nieve de Diferencia Normalizada (*NDSI*) en 1995. Basándose en el hecho de que la nieve refleja principalmente a la luz visible y absorbe la radiación en las longitudes de onda infrarroja. *NDSI* es definido como,

$$NDSI = \frac{(Verde - SWIR1)}{(Verde + SWIR1)}, \quad (3.5)$$

donde las bandas Verde y *SWIR1* se encuentran definidas en la tabla 1.2.

#### 3.4.2. Índice de Nieve Automático para Múltiples Superficies (*ASI - MS*)

Debido a la dificultad que *NDSI* tiene para diferenciar la superficie de nieve de los cuerpos de agua y zonas rocosas. En este estudio, se introduce el Índice de Nieve Automático para Múltiples Superficies (*ASI - MS*), que separa efectivamente los píxeles de nieve/hielo de los que no lo son, sin utilizar un valor óptimo de umbral. Como

resultado, se obtienen imágenes sin binarizar  $ASI - MS$  de manera automática y con información más completa de la superficie de nieve. El algoritmo  $ASI - MS$ , muestra alto rendimiento y exactitud en múltiples escenas, con alta diversidad geográfica registradas a través del tiempo.  $ASI - MS$  está definido como,

$$ASI - MS = \frac{K(R_{Verde}Verde + R_{Rojo}Rojo + R_{NIR}NIR + R_{SWIR1}SWIR1) - (R_{Azul}Azul + R_{SWIR1}SWIR1)}{R_{Azul}Azul + R_{SWIR1}SWIR1}, \quad (3.6)$$

donde  $K$  es el coeficiente de aumento de contraste entre la superficie de nieve/hielo y el fondo (ejemplo, cuerpos de agua, zonas rocosas, áreas de construcción, etc.).  $R_{banda}$  es el valor de reflectancia de la banda: Azul, Verde, Rojo,  $NIR$ ,  $SWIR1$  y  $SWIR2$  mostradas en la tabla 1.2.

### 3.5. Índice de Construcción de Diferencia Normalizada (*NDBI*)

Para obtener la firma espectral de construcción, se selecciona un píxel perteneciente a un área urbana. En la Figura 3.5a se observa esta selección, en una imagen multiespectral de Landsat 5 *TM*. La firma espectral de construcción de la Figura 3.5b, muestra una menor reflectancia en el rango visible, ascendiendo en las bandas  $NIR$  y  $SWIR$ . La firma espectral de construcción utilizando datos *TM* es aproximadamente plana, al igual que la proporcionada por los datos hiperespectrales *AVIRIS*.

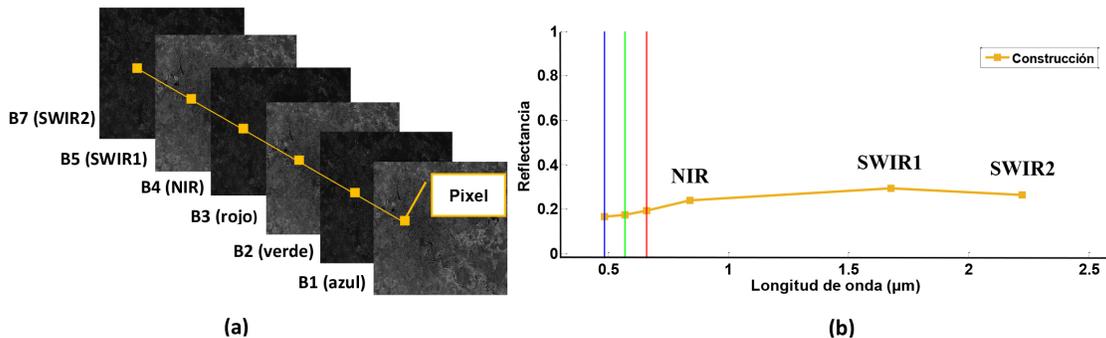


Figura 3.5: (a) Píxel perteneciente a un área de construcción, seleccionado en bandas *TM*, y (b) firma espectral de un píxel de construcción.

El Índice de Construcción de Diferencia Normalizada (*NDBI*) propuesto por Zha en 2003, para extraer superficies urbanas está definido como [3.11],

$$NDBI = \frac{(SWIR1 - NIR)}{(SWIR1 + NIR)}, \quad (3.7)$$

donde las características de las bandas  $NIR$  y  $SWIR1$ , se muestran en la Tabla 1.2.

### 3.6. Conclusiones

No toda la radiación electromagnética que proviene del Sol, incide en la superficie terrestre. La atmósfera es como un filtro que deja pasar ciertas longitudes de onda, algunas sin ser severamente afectadas por la absorción y dispersion. Las longitudes de onda que no son severamente afectadas por la atmósfera, son conocidas como ventanas atmosféricas. De cierta forma, la atmósfera determina qué longitudes de onda son apropiadas para la percepción remota satelital. Las ventanas atmosféricas, utilizadas por Landsat y Sentinel-2 se encuentran: en el rango visible e infrarrojo cercano, entre 0.3  $\mu m$  a 1.35  $\mu m$ , en el infrarrojo medio entre 1.5  $\mu m$  a 1.8  $\mu m$  y de 2.0  $\mu m$  a 2.4  $\mu m$ .

La firma espectral única de ciertos materiales, pueden tener patrones de respuesta similares en una determinada longitud de onda, pero difiere en otras. Basado en la diferencia normalizada de la baja y alta reflectancia espectral de los materiales, los métodos *IDN/IMB*, mejoran la segmentación entre la superficie de estudio del fondo, en una/varias escenas registradas por uno/varios sensores satelitales.

Los algoritmos *NDVI*, *MNDWI*, *AWEI<sub>nsh</sub>*, *NDSI* y *NDBI* utilizan un valor de umbral óptimo para eliminar artefactos (píxeles que no pertenecen a la superficie de estudio) de la *RoI*. Sin embargo, al analizar este método de binarización, cierta información (píxeles que representan la superficie de estudio), podría eliminarse de la *RoI*. Los algoritmos propuestos *AWI - MS* y *ASI - MS*, eliminan la información de ruido (ejemplo, sombra) en una o múltiples *RoIs* sin utilizar un valor de umbral óptimo. Los resultados de *AWI - MS* y *ASI - MS* muestran datos de alta calidad sin binarizar, útiles para un posible análisis fractal.

## Bibliografía

- [3.1] T. Acharya, A. Subedi, and D. Lee, “Evaluation of water indices for surface water extraction in a landsat 8 scene of nepal,” *Sensors*, vol. 18, no. 8, p. 2580, 2018.
- [3.2] E. Chuvieco, *Fundamentals of satellite remote sensing*. CRC press, 2009.
- [3.3] N. Levin, “Fundamentals of remote sensing,” *1st Hydrographic Data Management Course, IMO—International Maritime Academy, Trieste*, vol. 76, 1999.
- [3.4] T. Lillesand, R. W. Kiefer, and J. Chipman, *Remote sensing and image interpretation*. John Wiley & Sons, 2015.
- [3.5] NASA, “Avisar airborne visible/infrared imaging spectrometer,” 2011.
- [3.6] J. Rouse Jr, R. Haas, J. Schell, and D. Deering, “Monitoring vegetation systems in the great plains with erts,” 1974.
- [3.7] C. J. Tucker, B. N. Holben, J. H. Elgin Jr, and J. E. McMurtrey III, “Remote sensing of total dry-matter accumulation in winter wheat,” *Remote Sensing of Environment*, vol. 11, pp. 171–189, 1981.
- [3.8] H. Xu, “Modification of normalised difference water index (ndwi) to enhance open water features in remotely sensed imagery,” *International journal of remote sensing*, vol. 27, no. 14, pp. 3025–3033, 2006.
- [3.9] G. L. Feyisa, H. Meilby, R. Fensholt, and S. R. Proud, “Automated water extraction index: A new technique for surface water mapping using landsat imagery,” *Remote Sensing of Environment*, vol. 140, pp. 23–35, 2014.
- [3.10] D. K. Hall, G. A. Riggs, and V. V. Salomonson, “Development of methods for mapping global snow cover using moderate resolution imaging spectroradiometer data,” *Remote sensing of Environment*, vol. 54, no. 2, pp. 127–140, 1995.
- [3.11] Y. Zha, J. Gao, and S. Ni, “Use of normalized difference built-up index in automatically mapping urban areas from tm imagery,” *International journal of remote sensing*, vol. 24, no. 3, pp. 583–594, 2003.



# 4

# Resultados del monitoreo de recursos naturales y construcción

---

## 4.1. Introducción

En el monitoreo satelital, los *IDN/IMB*, son algoritmos que proveen información de cambios ambientales. La cobertura vegetal, áreas urbanas, cuerpos de agua y las superficies de nieve, pueden sufrir alteraciones significativas a través del tiempo. Estas variaciones ambientales, proporcionan información que puede ser analizada para una mejor toma de decisiones a futuro [4.1].

Para el monitoreo temporal de una región de interés, es necesario utilizar múltiples sensores. Como se mencionó, Landsat 5 *TM* tuvo un periodo limitado de funcionamiento entre los años 1984-2013. Para compensar la falta de registros multiespectrales *TM* en los años siguientes a su periodo, en este estudio se adquieren datos de los satélites Landsat 8 *OLI* y Sentinel-2 *MSI* de la siguiente manera.

Los datos de adquisición registrados por Landsat 5 *TM* (23 de enero, 2011), Landsat 8 *OLI* (18 de abril de 2013) y Sentinel 2A (11 de marzo de 2017) se muestran en la Figura 4.1a-c. La misma área georreferenciada del Landsat de Nivel 1 (*L1T*) y de Sentinel-2 de Nivel 1C (*L1C*), fue seleccionado en *ENVI* versión 5.1 Exelis Visual Information Solutions, Boulder, Colorado.

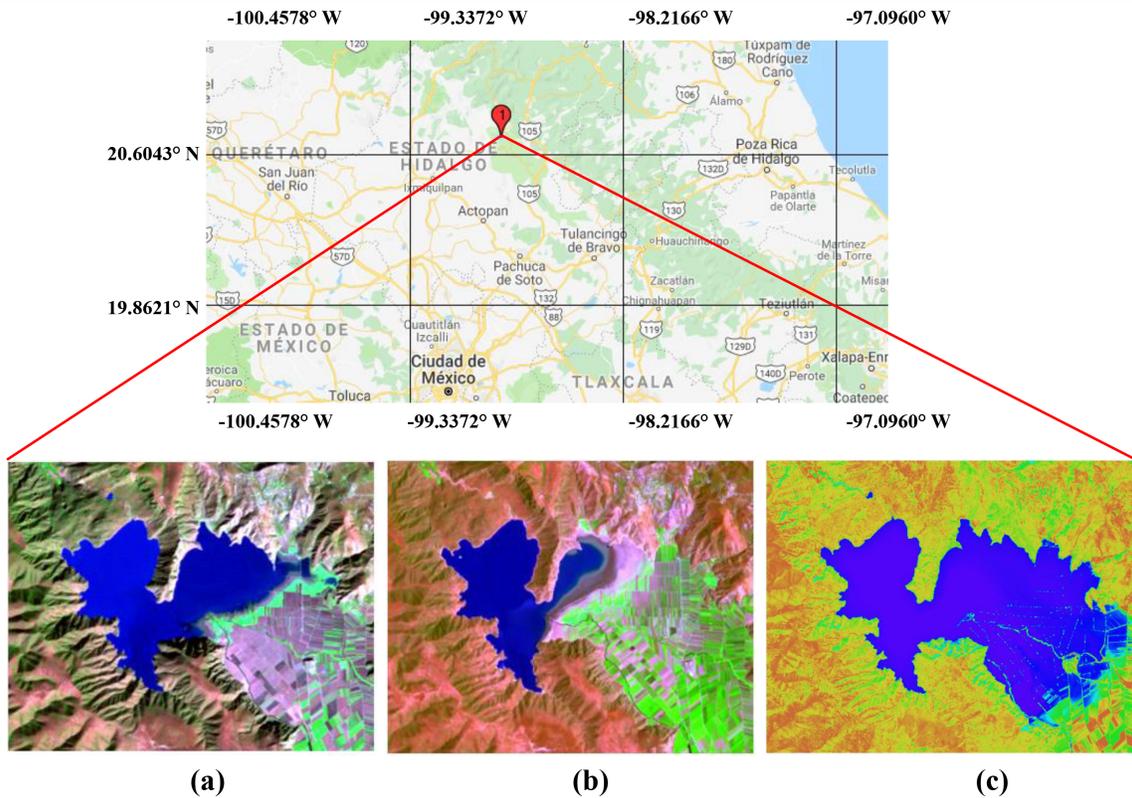


Figura 4.1: Ubicación geográfica de la *RoI* del lago Metztitlán, en imágenes RGB [4.1]: Resolución de 307x246 píxeles para (a) Landsat 5 *TM* y (b) Landsat 8 *OLI*, y 663 × 531 píxeles para (c) Sentinel 2A.

En este capítulo se analizan las regiones para la extracción de cuerpos de agua, utilizando en datos satelitales Landsat 5 *TM*, Landsat 8 *OLI* y Sentinel-2 *MSI*. Se aplica un valor de umbral óptimo obtenido por Acharya para escenas de alta diversidad geográfica. Así como, la selección de un *HTV* en datos *TM*, *OLI* y *MSI*. Utilizando los índices *IDN/IMB* definidos en el Capítulo 3, se segmenta la *RoI* de vegetación, cuerpos de agua, nieve y construcción según el caso, y se determina el porcentaje de cobertura en el área analizada. A partir de esto, se determina la variabilidad temporal y espacial de la *RoI*. Finalmente se presentan las conclusiones del capítulo.

#### 4.1.1. Post procesamiento de la imagen

Una vez que se determinó la zona a analizar a partir de los datos multispectrales (Landsat y/o Sentinel-2), se calculan alguno de los *IDM/IMB* para la extracción de la *RoI*. La imagen resultante es binarizada de la siguiente manera. Se utiliza un umbral para una escena de alta diversidad geográfica (*HGDST*), obtenido por Acharya [4.2]. De acuerdo con Acharya, el valor óptimo de umbral (*OTN*) para el método *MNDWI* es  $OTN_{MNDWI}=0.35$  y  $AWEI_{nsh}$  es  $OTN_{AWEI_{nsh}}=0.1897$ . Además, se obtiene el his-

tograma de cada resultado  $MNDWI$  y  $AWEI_{nsh}$ , para calcular su valor de umbral óptimo (Histogram Threshold Value  $HTV$ ). En la selección del  $HTV$  óptimo, se tiene en cuenta, el contraste de intensidad entre píxeles de agua (con valores positivos) y píxeles que no pertenecen al agua (con valores negativos) [4.3]. El valor entre los dos picos del histograma, es seleccionado como  $HTV$  óptimo, con alta estabilidad entre las imágenes  $MNDWI$  y  $AWEI_{nsh}$ . En la Figura 4.2, se muestra un ejemplo del histograma para encontrar el  $HTV$  óptimo.

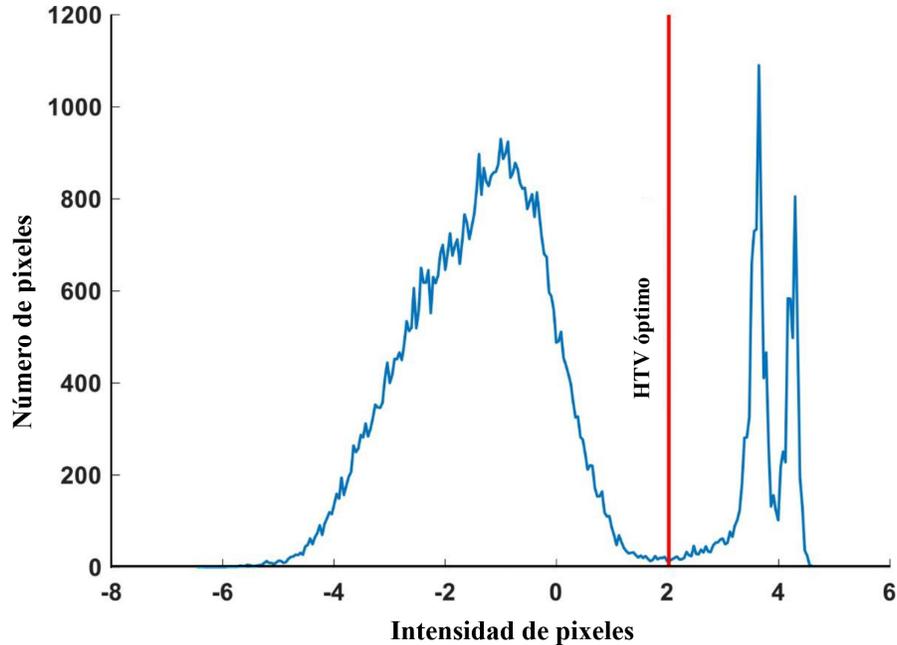


Figura 4.2: Histograma de una imagen  $AWEI_{nsh}$ , con intensidad de píxeles positiva (cuerpo de agua) e intensidad de píxeles negativa (fondo), utilizando imágenes Landsat 5 *TM*. Con un  $HTV_{AWEI_{nsh}} = 2.02159$ .

## 4.2. Análisis de la región de España utilizando el algoritmo *NDVI*

Para el estudio de la vegetación, se seleccionó una región de España, con latitud de  $43.100691^\circ N$  y longitud de  $7.650026^\circ O$  al centro de la *RoI*, mostrada en la Figura 4.3. La vegetación se muestra en color rojo por la reflectancia del *NIR*. El resultado  $NDVI$  con sub-imágenes de tamaño de  $320 \times 232$  píxeles, muestra una baja densidad de plantas en abril de 1984, aumentando para el año 2005 y una mayor cobertura en abril del 2009 [4.4] [4.5]. Este incremento puede confirmarse en la Tabla 4.1, que ilustra la cantidad en porcentaje de cobertura vegetal. El porcentaje total de vegetación, se calcula a partir de las sub-imágenes  $NDVI$  binarizadas de la Figura 4.3g-i.

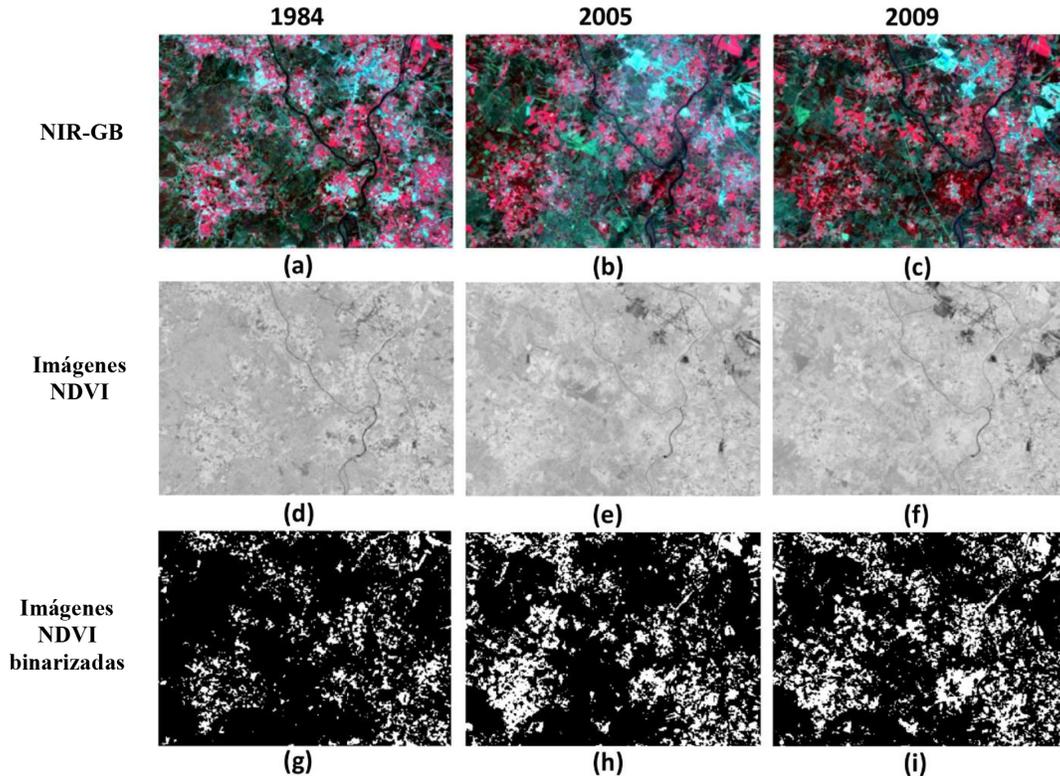


Figura 4.3: Región de España registrada en abril de los años 1984, 2005 y 2009: (a), (b) y (c) Imágenes RGB compuestas por la Banda Verde, Banda Rojo y Banda *NIR*. La vegetación se muestra en color rojo por la reflectancia del *NIR*. Las imágenes (d), (e) y (f) son los resultados de *NDVI* sin binarizar y (g), (h) e (i) son resultados *NDVI* binarizados con valor de umbral = 0.59693.

Tabla 4.1: Región de España: porcentajes totales de pixeles de vegetación, obtenidos mediante el software *ENVI*. El cálculo de los porcentajes, es la relación de los pixeles de vegetación, entre todos los pixeles que integran la imagen.

1984	2005	2009
12.680496 %	21.672953 %	23.624731 %

### 4.3. Monitoreo del lago Metztitlán mediante los métodos *MNDWI* y *AWEI<sub>nsh</sub>*

La *RoI* seleccionada para el análisis de cuerpo de agua, es el lago Metztitlán ubicado en: Lat: 20. 68226346° *N* y Lon: 98. 85789350° *O* en Hidalgo, México, como se observa en la Figura 4.1.

### 4.3.1. Imágenes satelitales del Landsat 5 $TM$

Los métodos  $MNDWI$  y  $AWEI_{nsh}$  para la extracción de cuerpos de agua, fueron aplicados a los datos satelitales de la Figura 4.1a [4.6] [4.7]. Comparando los resultados en la Figura 4.4, se presenta un rendimiento más bajo en (a), con el algoritmo  $MNDWI$  sin binarizado.  $MNDWI$  no logra discriminar entre diferentes tipos de materiales (ejemplo, áreas urbanas y sombra). Por otra parte, un mejor desempeño se muestra en (f) con  $HTV_{AWEI_{nsh}}$ .

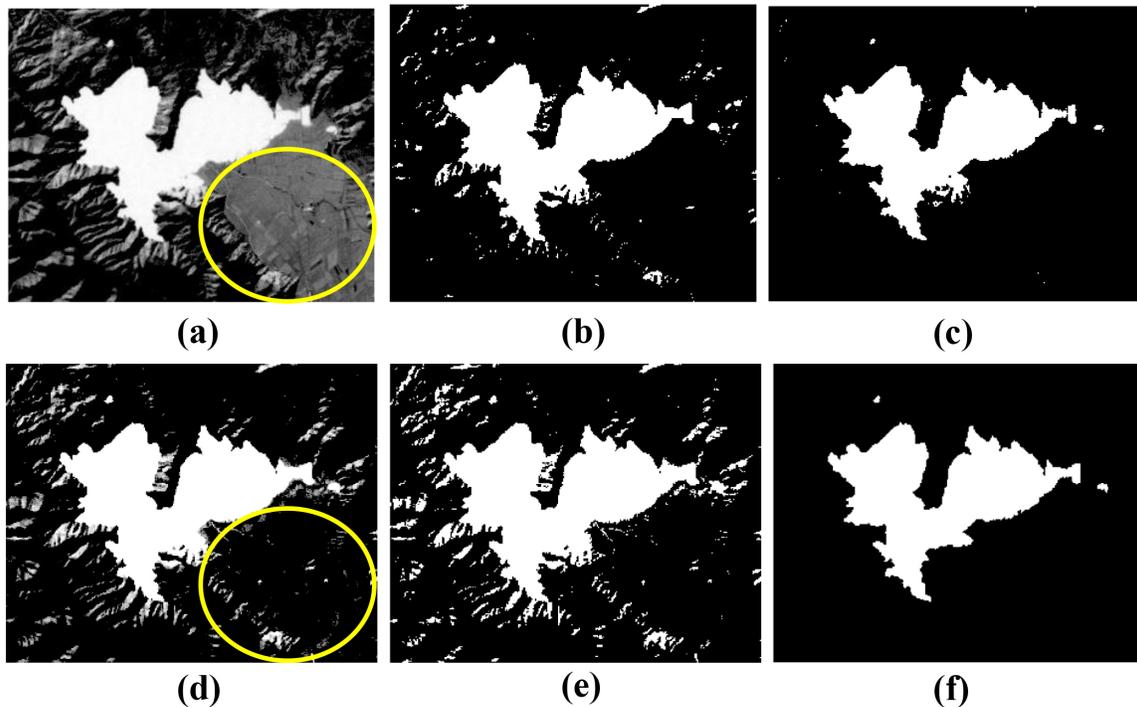


Figura 4.4: Lago Metztlán: (a)  $MNDWI$  sin binarizar, (b)  $OTN_{MNDWI}$ , (c)  $HTV_{MNDWI} = 0.63888$ , (d)  $AWEI_{nsh}$  sin binarizado, (e)  $OTN_{AWEI_{nsh}}$  y (f)  $HTV_{AWEI_{nsh}} = 2.02159$ .

### 4.3.2. Imágenes satelitales del Landsat 8 $OLI$

Los métodos  $MNDWI$  y  $AWEI_{nsh}$  para la extracción de cuerpos de agua, fueron aplicados a los datos satelitales de Figura 4.1b [4.6] [4.7]. De manera similar a la sección 4.3.1, en la Figura 4.5 el peor resultado se muestra en (a)  $MNDWI$  sin binarizar con datos  $OLI$ . Por otra parte, el resultado con procedimiento del histograma en la Figura 4.5c y f, presentan una delimitación de la superficie de agua con mayor precisión.

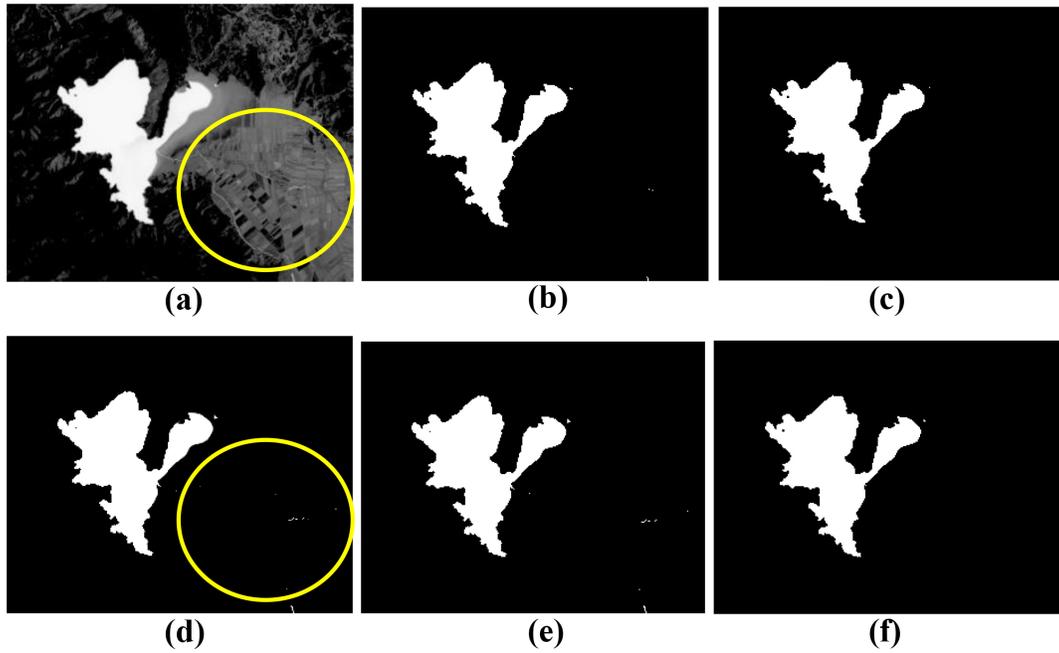


Figura 4.5: Lago Metztitlán: (a)  $MNDWI$  sin binarizar, (b)  $OTN_{MNDWI}$ , (c)  $HTV_{MNDWI} = 0.58570$ , (d)  $AWEI_{nsh}$  sin binarizar, (e)  $OTN_{AWEI_{nsh}}$ , y (f)  $HTV_{AWEI_{nsh}} = 2.37209$ .

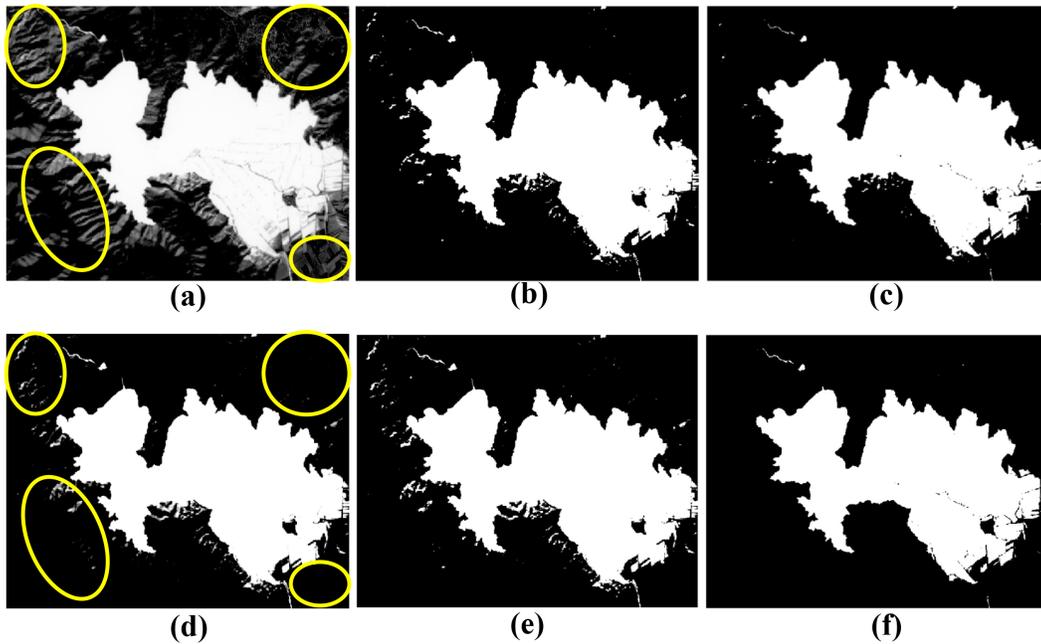


Figura 4.6: Lago Metztitlán: (a)  $MNDWI$  sin binarizar, (b)  $OTN_{MNDWI}$ , (c)  $HTV_{MNDWI} = 0.50610$ , (d)  $AWEI_{nsh}$  sin binarizar, (e)  $OTN_{AWEI_{nsh}}$ , y (f)  $HTV_{AWEI_{nsh}} = 1.75806$ .

### 4.3.3. Imágenes satelitales de Sentinel-2 *MSI*

Los algoritmos *MNDWI* y *AWEI<sub>nsh</sub>* para la extracción de cuerpos de agua, fueron aplicados a los datos satelitales de Figura 4.1c [4.6] [4.7]. Las imágenes sin binarizar (a) y (d) de la Figura 4.6, muestran los peores resultados como en las secciones 4.3.1 y 4.3.2. Por otra parte, los resultados del procedimiento del histograma con el sensor *MSI*, exhiben una separación más precisa, entre el cuerpo de agua (valores de píxel de agua positivos) del fondo (valores de píxel negativos).

### 4.3.4. Monitoreo del lago Metztitlán a través del tiempo

En esta sección, se realiza una comparación de los resultados con *HTV<sub>AWEI<sub>nsh</sub></sub>*, utilizando imágenes espectrales registradas por sensores *TM*, *OLI* y *MSI* [4.7]. En datos satelitales de alta calidad, la cantidad de agua (píxeles de agua), puede ser comparada a través del tiempo. La Figura 4.7a, muestra la *RoI* registrada el 23 de enero del 2011 por el sensor *TM*, en donde se observa una cantidad de agua considerable. Posteriormente en (b), registrada el 18 de abril del 2013, la reducción del nivel del agua es notable. Finalmente, en (c), registrada el 11 de marzo de 2017, se pueden observar zonas urbanas inundadas por el crecimiento desmesurado del nivel de agua del lago Metztitlán.



Figura 4.7: Lago Metztitlán: (a) Landsat 5 *TM*, (b) Landsat 8 *OLI* y (c) Sentinel 2A.

El incremento y decremento del nivel de agua a través del tiempo del lago Metztitlán, puede observarse cuantitativamente en la Tabla 4.2. El porcentaje total de píxeles de agua, es obtenido de la relación entre la suma de píxeles de agua y el total de píxeles que conforman la *RoI*.

Tabla 4.2: Porcentaje de píxeles de agua de la Figura 4.7 a-c.

2011	2013	2017
16.280024 %	9.884537 %	30.703616 %

#### 4.4. Monitoreo del lago Poopó mediante el método $AWEI_{nsh}$

El lago Poopó, se encuentra en Bolivia, con una latitud de  $18.806288^{\circ} S$  y una longitud de  $67.095296^{\circ} O$ . La Figura 4.8, muestra los resultados de  $AWEI_{nsh}$ , en subimágenes con dimensión de  $1911 \times 2959$  píxeles [4.7]. Se puede observar que el lago Poopó, se está secando conforme pasan los años.

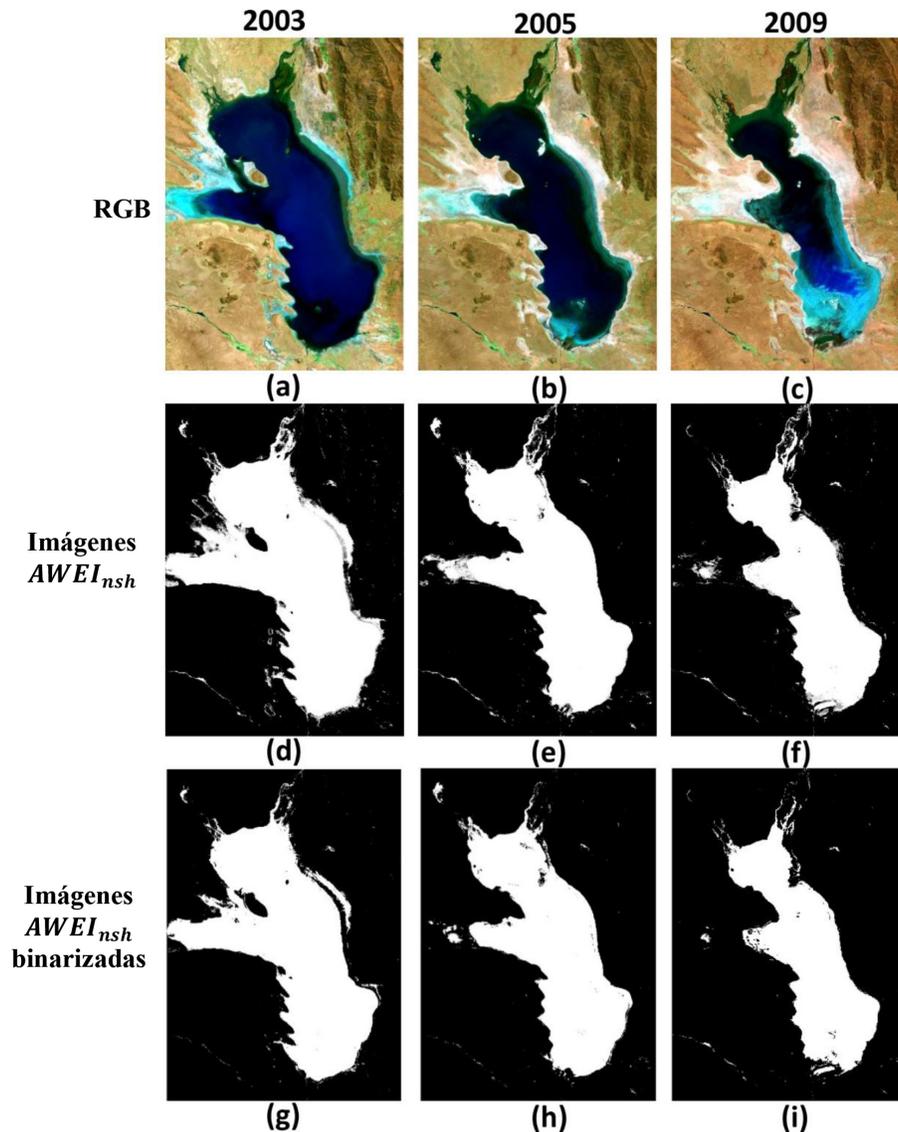


Figura 4.8: Lago Poopó registrado en agosto del 2003, 2005 y 2009. (a), (b) y (c) imágenes RGB de Landsat. Las imágenes (d), (e) y (f) son  $AWEI_{nsh}$  sin binarizar y (g), (h), (i) son resultados de imágenes  $AWEI_{nsh}$  binarizadas con valor de umbral = 1.20829.

Un porcentaje decreciente de los píxeles de agua es presentado en la Tabla 4.3. El porcentaje total de agua, se calcula a partir de las imágenes binarizadas  $AWEI_{nsh}$  de la Figura 4.8 g-i.

Tabla 4.3: Porcentajes de píxeles de agua de imágenes binarizadas de Poopó calculados mediante el software *ENVI*.

2003	2005	2009
30.501142 %	25.030619 %	19.835817 %

## 4.5. Comparación de resultados del método $AWEI_{nsh}$ contra el método propuesto $AWI - MS$

En la Figura 4.9b y 4.9c, se observan los resultados de los algoritmos  $AWI - MS$  y  $AWEI_{nsh}$  respectivamente en imágenes sin binarizar. Basado en la inspección visual,  $AWI - MS$  muestra un mayor rendimiento en la extracción del cuerpo de agua del lago Poyang, discriminando la vegetación que se encuentra en la *RoI*. Por otra parte,  $AWEI_{nsh}$  no logra diferenciar los píxeles de agua de los píxeles de vegetación [4.7].

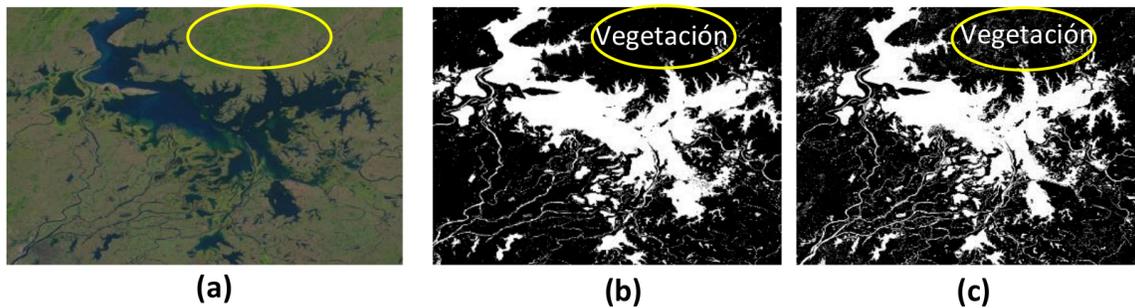


Figura 4.9: Comparación de extracciones de agua en el lago Poyang, China, registrada en noviembre de 1988 por Landsat 5 *TM*: a) Imagen RGB, b) Extracción de agua con  $AWI - MS$  y c) Extracción de agua con  $AWEI_{nsh}$ .

## 4.6. Extracción de cuerpos de agua mediante el método $AWI - MS$

De forma automática, el método propuesto  $AWI - MS$  permite separar efectivamente los píxeles de agua de los píxeles que no lo son, en resultados sin binarizar. Para verificar la precisión de  $AWI - MS$  en múltiples superficies, el algoritmo se aplicó en escenas registradas en diferente fecha y hora, con alta diversidad geográfica. La Tabla 4.4 muestra un resumen de las características de 5 *RoIs* elegidas para este estudio.

Tabla 4.4: Áreas de estudio y sus características para la implementación de *AWI – MS*.

Nombre	Registro	Coordenadas centrales	Características generales
Lago Poyang, China	Noviembre 1988 Octubre 2001 y 2009	Latitud 29.057375° Longitud 116.292321°	Lago natural, zona de clima húmedo. Rodeado por vegetación.
Lago Bosques, USA-Canadá	Septiembre 1987, 1998 y 2009	Latitud 49.047982 ° Longitud -94.821344°	Lago natural. Rodeado por vegetación.
Lago Nasser, Egipto	Junio 2002, 2008 y 2010	Latitud 23.1046° Longitud 32.8062°	Hecho por el hombre, zona desértica. Rodeado de arena.
Lago Kainji, Nigeria	Diciembre 1984, 1986 y 1990	Latitud 10.40682° Longitud 4.564763°	Hecho por el hombre, ubicado en una zona forestal.
Lago Manantali, Mali	Diciembre 1987, 1990 y Nov 2010	Latitud 13.09° Longitud -10.360°	Hecho por el hombre, ubicado en una zona forestal y cordilleras irregulares.
Lago Mead, USA	Mayo 1984 Agosto 2008 y 2009	Latitud 36.266017° Longitud -114.467111°	Hecho por el hombre. Rodeado de cordilleras irregulares.

Los resultados de las extracciones *AWI – MS* de los lagos naturales (Poyang y Bosques) y hechos por el hombre (Nasser, Kainji, Manantali y Mead), se pueden observar en la Figura 4.10 y la Figura 4.11.

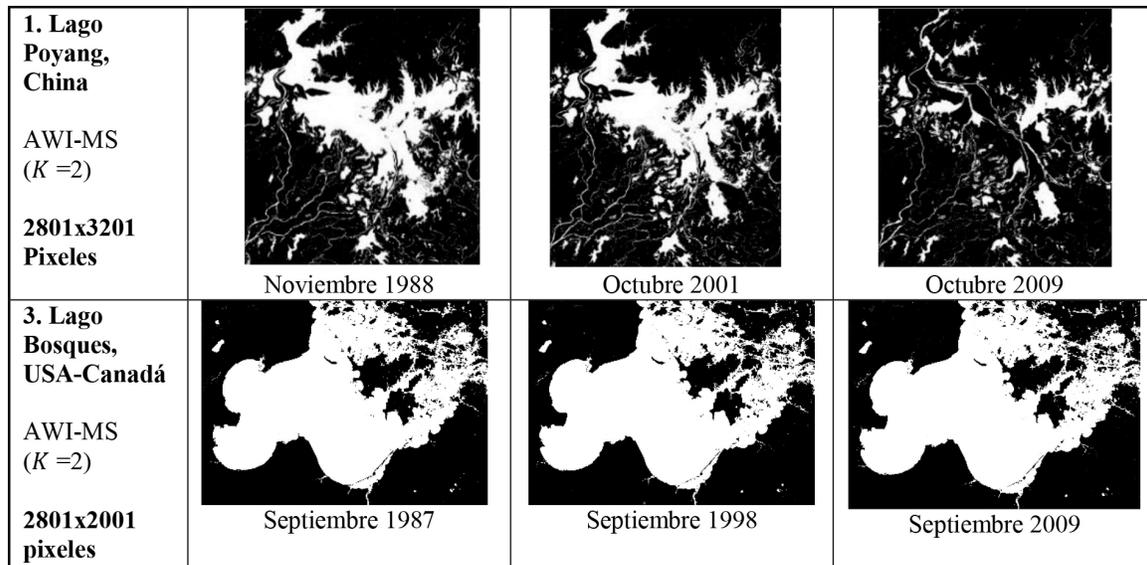


Figura 4.10: Lagos naturales registrados por Landsat 5 *TM*: Extracciones de cuerpos de agua a través del tiempo, utilizando el método *AWI – MS*, para valores iguales de  $K$ .

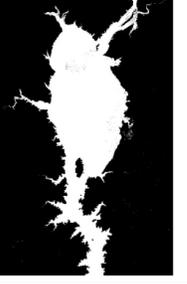
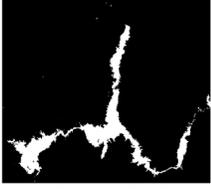
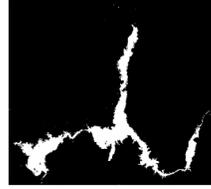
<p><b>1. Lago Nasser, Egipto</b></p> <p>AWI-MS (<math>K=4</math>)</p> <p>1911x2959 píxeles</p>		<p>Junio 2002</p>		<p>Junio 2008</p>		<p>Junio 2010</p>
<p><b>2. Lago Kainji, Nigeria</b></p> <p>AWI-MS (<math>K=4</math>)</p> <p>1435x3271 píxeles</p>		<p>Dic 1984</p>		<p>Dic 1986</p>		<p>Dic 1990</p>
<p><b>3. Lago Manantali, Mali</b></p> <p>AWI-MS (<math>K=4</math>)</p> <p>1001x1401 píxeles</p>		<p>Dic 1987</p>		<p>Dic 1990</p>		<p>Noviembre 2010</p>
<p><b>3. Lago Mead, USA</b></p> <p>AWI-MS (<math>\kappa=4</math>)</p> <p>2601x2001 píxeles</p>		<p>Mayo 1984</p>		<p>Agosto 2008</p>		<p>Agosto 2011</p>

Figura 4.11: Lagos creados por el hombre registrados por Landsat 5 *TM*: Extracciones de cuerpos de agua a través del tiempo utilizando el método *AWI – MS*, para valores iguales de  $K$ .

## 4.7. Monitoreo en la región de Groenlandia mediante el método *NDSI*

El centro del área de estudio de Groenlandia se encuentra en la latitud de  $73.8603^{\circ}$  *N* y longitud  $22.7857^{\circ}$  *O*. Las dimensiones de las sub-imágenes son de  $961 \times 629$  píxeles presentados en la Figura 4.12 [4.8] [4.9]. La delineación de la capa de nieve utilizando el método *NDSI*, muestra un incremento en el derretimiento en la corteza de nieve/hielo a través del tiempo.

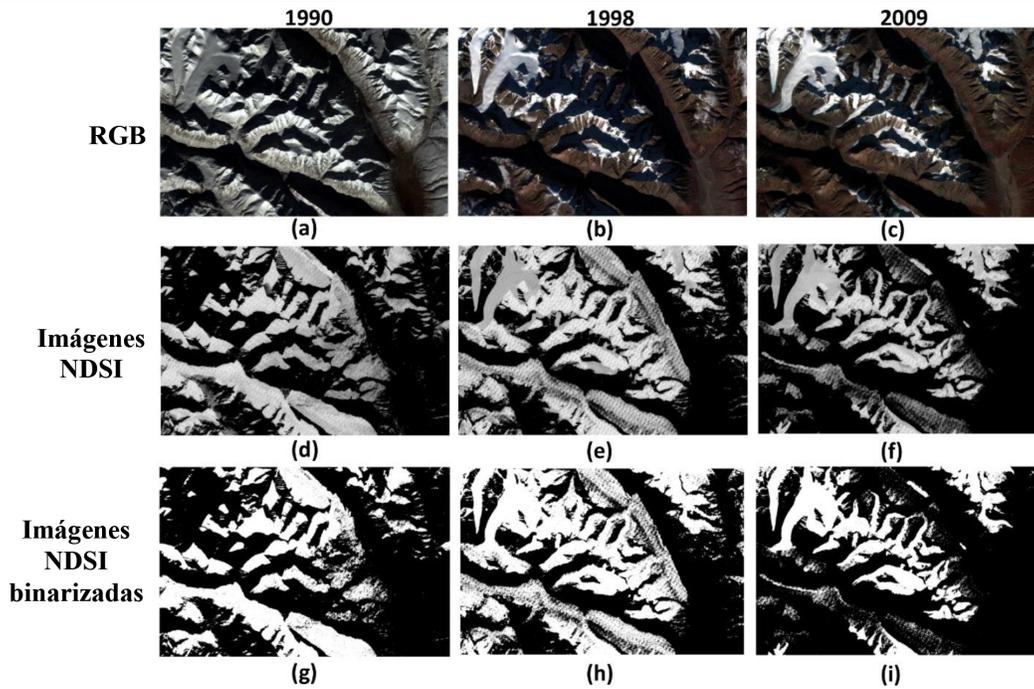


Figura 4.12: Región de Groenlandia registrada en septiembre de 1990, 1998 y 2009. La (a), (b) y (c) son imágenes *RGB* de la *RoI*. La (d), (e) y (f) son resultados *NDSI* sin binarizar y (g), (h), (i) son resultados *NDSI* con número de umbral = 0.24893.

En la Tabla 4.5, se puede observar la disminución en el total de la cantidad de píxeles de nieve de la región de Groenlandia a través del tiempo. El porcentaje total de nieve se calcula a partir de imágenes *NDSI* binarizadas de la Figura 4.12 g-i.

Tabla 4.5: Variación porcentual de píxeles de nieve de la región de Groenlandia, calculados mediante el software *ENVI*.

1990	1998	2009
31.899568 %	44.103006 %	24.343846 %

## 4.8. Comparación de resultados del método *NDSI* contra el método propuesto *ASI – MS*

En la Figura 4.13 b y c, se muestran los resultados de los algoritmos *ASI – MS* y *NDSI* respectivamente, en imágenes sin binarizar. Basado en la inspección visual, un bajo rendimiento en la extracción de nieve del algoritmo *NDSI* es observado [4.8]. Por otra parte, el método propuesto *AWI – MS* logra excluir la vegetación y sombras de las áreas de nieve/hielo.

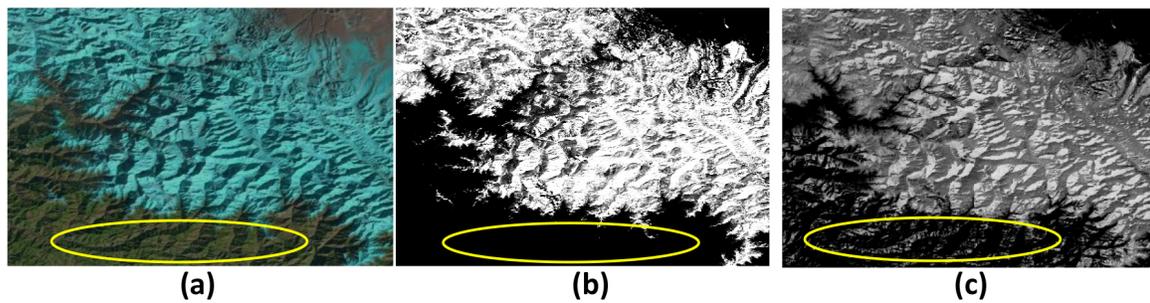


Figura 4.13: Comparación de la extracción de nieve en la región de India, registrada en diciembre de 1995, por Landsat 5 *TM*: a) Imagen *RGB*, b) Extracción de nieve con *ASI – MS* y c) Extracción de nieve con *NDSI*.

Para verificar la precisión de *ASI – MS* en múltiples superficies, el algoritmo se aplicó a una región en Alaska, donde la nieve/hielo, está interactuando con el agua. La Figura 4.14, muestra la extracción de nieve de *ASI – MS*, que logra separar la superficie de nieve/hielo del agua mejor que *NDSI* [4.8].

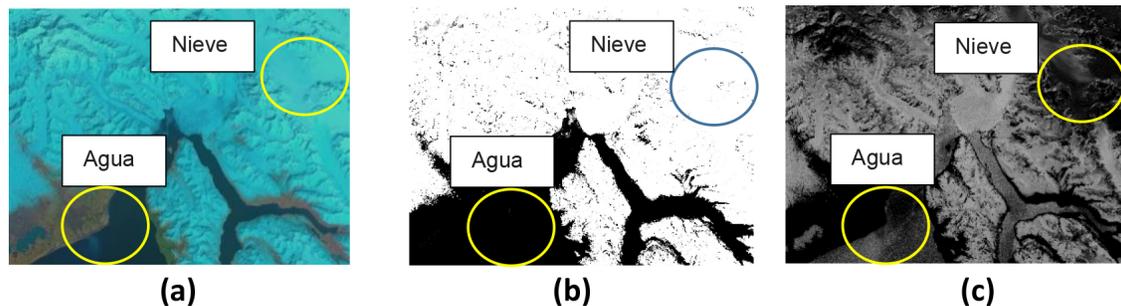


Figura 4.14: Comparación de extracciones de nieve en la región de Alaska, registrada en mayo de 1992. a) Imagen *RGB*, b) Extracción de nieve con *ASI – MS* y c) Extracción de nieve con *NDSI*.

## 4.9. Extracción de superficies de nieve mediante el método ASI-MS

De forma automática *ASI – MS*, separa efectivamente los píxeles de nieve de los píxeles que no lo son, en resultados sin binarizar. Para verificar la precisión de *AWI – MS* en múltiples superficies de nieve, el algoritmo se aplicó en escenas registradas en diferentes fecha y hora, con alta diversidad geográfica. La Figura 4.15 muestra un resumen de las características de 3 *RoIs* elegidas para este estudio.

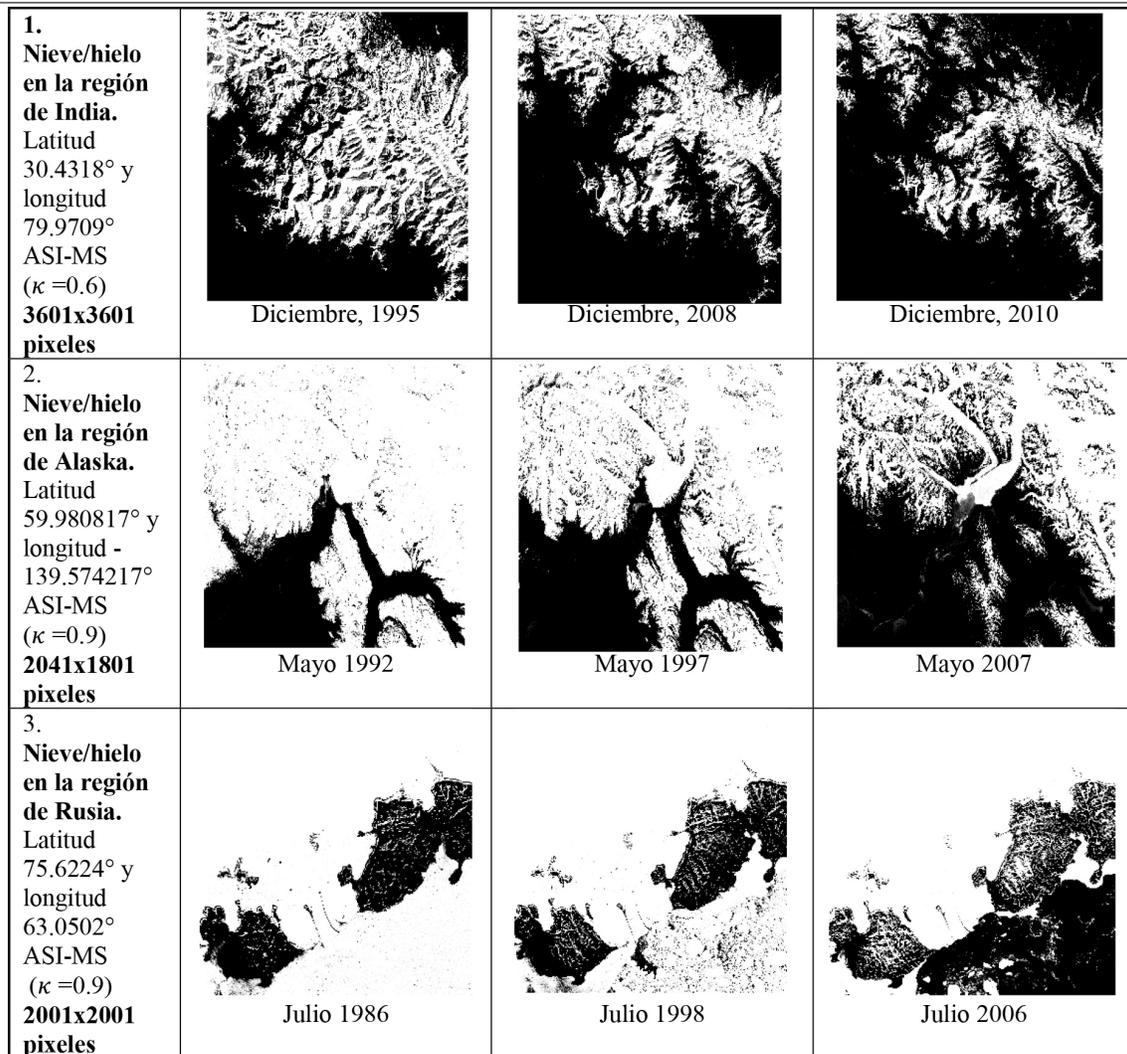


Figura 4.15: Áreas de estudio registradas por Landsat 5 *TM*: Extracciones de superficies de nieve a través del tiempo utilizando el método *ASI – MS*, para diferentes valores de  $K$ .

#### 4.10. Monitoreo en el área urbana de Moscú mediante el método NDBI

La delimitación de las áreas urbanizadas en la ciudad de Moscú con una latitud 55.731138° *N* y una longitud de 37.611004° *E* al centro de la *RoI*, se muestran en la Figura 4.16. El tamaño de las sub-imágenes es de 3601 × 3601 pixeles. Una inspección visual indica un crecimiento en la cobertura del suelo urbano en el periodo de 1996 a 2011. Además, cuantitativamente el incremento en la cantidad de píxeles de construcción se puede observar en la Tabla 4.6. La cantidad de porcentaje total de píxeles de

construcción, se calcula a partir de las imágenes *NDBI* binarizadas de la Figura 4.16 g-i [4.10].

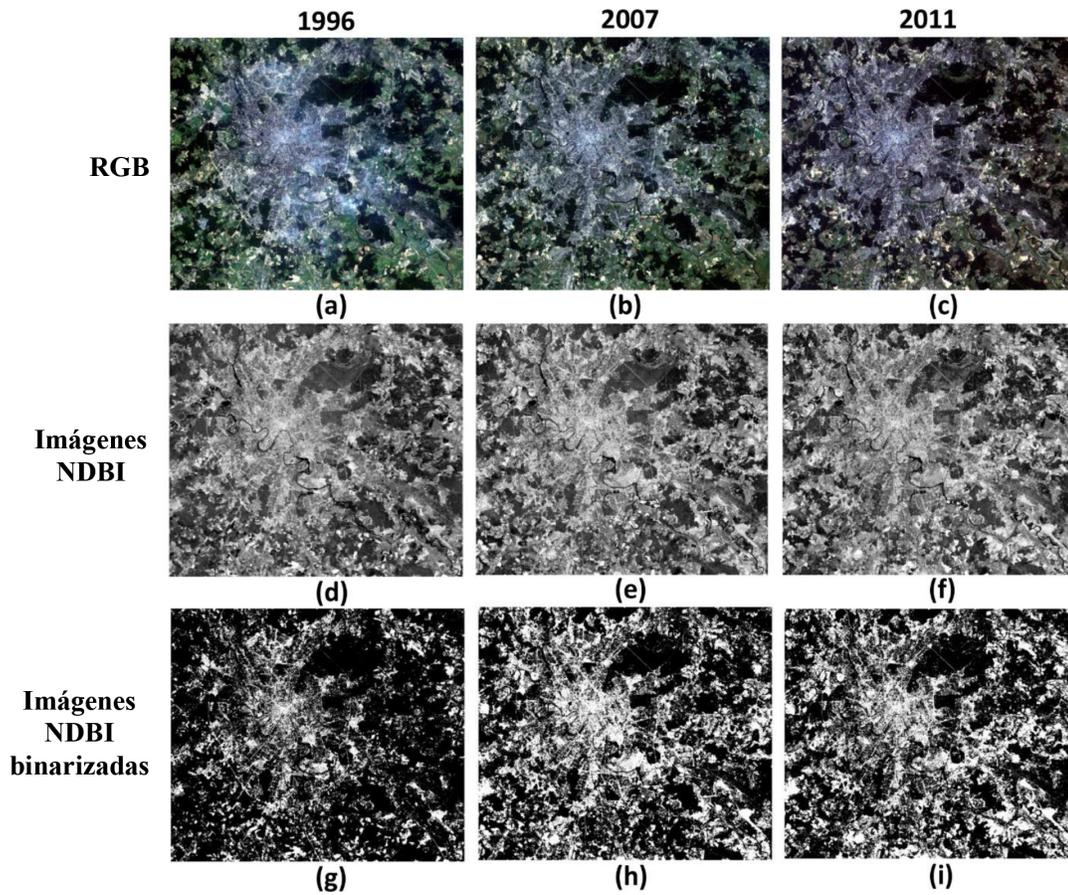


Figura 4.16: Imágenes de la ciudad de Moscú registradas en agosto de 1996, 2007 y 2011. (a). (b) y (c) imágenes *RGB* de la *RoI*. (d), (e) y (f) son extracciones de construcción sin binarizar y (g), (h), (i) son resultados *NDBI* con número de umbral = -0.13894.

Tabla 4.6: Porcentajes de píxeles acumulados en imágenes binarizadas de Moscú, calculados en *ENVI*.

1996	2007	2011
21.29826 %	35.392304 %	36.152817 %

## 4.11. Conclusiones

En la Figura 4.3 g-i, un rango de porcentaje de píxeles de vegetación creciente de [12.680496 %, 23.624731 %] es obtenido en el periodo de 1984 al 2009. Esta variación está relacionada, con la creciente cantidad de densidad de plantas en la región seleccionada.

Entre los resultados de  $AWEI_{nsh}$  y  $MNDWI$  que se muestran en las Figuras 4.4, 4.5 y 4.6, se obtiene un mejor rendimiento con Algoritmo  $AWEI_{nsh}$ .  $AWEI_{nsh}$  exhibe una alta estabilidad entre imágenes binarizadas y sin binarizar en el mapeo del cuerpo de agua del lago Metztitlán. Para discriminar diversos materiales (píxeles que no son agua) en la escena usando  $AWEI_{nsh}$ , se utiliza un valor umbral óptimo, pero podría eliminarse cierta información (píxeles de agua) del escena. En la Figura 4.7 a-c, se observa un análisis del lago Metztitlán en diferentes escenas registradas a través del tiempo y con distintos sensores satelitales en imágenes  $AWEI_{nsh}$ . El monitoreo del lago Metztitlán, arroja un porcentaje variable de [16.280024 %, 9.884537 %, 30.703616 %], correspondiente a la variabilidad de la cantidad de agua que el lago tiene a través del tiempo.

El monitoreo del lago Poopó mostrado en la Figura 4.8 g-i en imágenes  $AWEI_{nsh}$ , tiene un porcentaje de píxeles de agua decreciente de [30.501142 %, 19.835817 %]. Este resultado está asociado a la disminución de la cantidad de agua que el lago ha perdido a través del tiempo.

Debido a la dificultad que  $AWEI_{nsh}$  tiene para discriminar la vegetación que rodea al lago Poyang, en este estudio se introduce el nuevo algoritmo  $AWI - MS$ . Mediante la inspección visual, el algoritmo  $AWI - MS$  muestra una discriminación de los píxeles que no son de agua de los píxeles que sí lo son mayor que  $AWEI_{nsh}$ . Aún más, el método  $AWI - MS$  muestra estabilidad en escenas con alta diversidad geográfica, proporcionando resultados sin binarizar.

La inspección visual de los resultados del método  $NDSI$ , muestran que no logra discriminar las sombras y zonas rocosas de la nieve. Por otra parte, el algoritmo propuesto  $ASI - MS$ , si logra este cometido en múltiples superficies, como se observa en la región de la India, Rusia y Alaska, donde la nieve/hielo, está interactuando con diversos materiales.

Un rango de porcentaje estadístico de [31.899568 %, 24.343846 %] para la capa de nieve decreciente, se obtiene de Figura 4.12 g-i mediante análisis  $NDSI$ . Los resultados  $NDBI$  binarizados de las imágenes de la Figura 4.16 g-i, muestran un crecimiento del área urbana en la ciudad de Moscú en el período comprendido entre agosto de 1996 y agosto de 2011.

## Bibliografía

- [4.1] M. Delgadillo-Herrera, M. Arreola-Esquivel, C. Toxqui-Quitl, and A. Padilla-Vivanco, “Normalized difference indices in landsat 5 tm satellite data,” in *Current Developments in Lens Design and Optical Engineering XX*, vol. 11104, p. 111040W, International Society for Optics and Photonics, 2019.
- [4.2] T. Acharya, A. Subedi, and D. Lee, “Evaluation of water indices for surface water extraction in a landsat 8 scene of nepal,” *Sensors*, vol. 18, no. 8, p. 2580, 2018.
- [4.3] N. Otsu, “A threshold selection method from gray-level histograms,” *IEEE transactions on systems, man, and cybernetics*, vol. 9, no. 1, pp. 62–66, 1979.
- [4.4] J. Rouse Jr, R. Haas, J. Schell, and D. Deering, “Monitoring vegetation systems in the great plains with erts,” 1974.
- [4.5] C. J. Tucker, B. N. Holben, J. H. Elgin Jr, and J. E. McMurtrey III, “Remote sensing of total dry-matter accumulation in winter wheat,” *Remote Sensing of Environment*, vol. 11, pp. 171–189, 1981.
- [4.6] H. Xu, “Modification of normalised difference water index (ndwi) to enhance open water features in remotely sensed imagery,” *International journal of remote sensing*, vol. 27, no. 14, pp. 3025–3033, 2006.
- [4.7] G. L. Feyisa, H. Meilby, R. Fensholt, and S. R. Proud, “Automated water extraction index: A new technique for surface water mapping using landsat imagery,” *Remote Sensing of Environment*, vol. 140, pp. 23–35, 2014.
- [4.8] D. K. Hall, G. A. Riggs, and V. V. Salomonson, “Development of methods for mapping global snow cover using moderate resolution imaging spectroradiometer data,” *Remote sensing of Environment*, vol. 54, no. 2, pp. 127–140, 1995.
- [4.9] J. Dozier, “Spectral signature of alpine snow cover from the landsat thematic mapper,” *Remote sensing of environment*, vol. 28, pp. 9–22, 1989.
- [4.10] Y. Zha, J. Gao, and S. Ni, “Use of normalized difference built-up index in automatically mapping urban areas from tm imagery,” *International journal of remote sensing*, vol. 24, no. 3, pp. 583–594, 2003.



# 5

# Conclusiones generales y trabajo a futuro

---

## 5.1. Conclusiones generales

Las bases de datos gratuitas que contiene los datos satélites Landsat y Sentinel-2, permiten observar, analizar y evaluar la evolución de zonas urbanas y la alteración ambiental a pequeña, mediana y gran escala. La base de datos de un solo sensor, puede estar limitada por la falta de registros satelitales. Los sensores satelitales tienen un periodo de funcionamiento limitado, que tiene que ver con su degradación. El sensor *TM* a bordo del satélite Landsat 4, fue lanzado por la *NASA* el 16 de julio de 1982 y dejó de transmitir datos a finales de 1993. Posteriormente, una réplica exacta del sensor *TM* fue lanzado a bordo del satélite Landsat 5, el primero de marzo de 1984. Landsat 5 recopiló datos por 29 años continuos, obteniendo el record mundial Guinness. El 5 de junio del 2013 fue dado de baja y en ese mismo año fue lanzado Landsat 6, pero no alcanzó la órbita. Debido a la falla que Landsat 7 tiene en el sistema corrector de línea de escaneo, el satélite Landsat 8 fue lanzado el 11 de febrero del 2013. Por otra parte, *ESA* lanza el Sentinel-2A el 23 de junio del 2015 y el Sentinel-2B el 7 de marzo del 2017, con réplicas del sensor *MSI* a bordo de ambos satélites.

Para poder comparar imágenes multiespectrales registradas por diferente sensor, se deben encontrar en condiciones atmosféricas y radiométricas similares. Sin embargo, el nivel de preprocesamiento de los datos debe ser apropiado para no alterar o agregar distorsión a los datos originales. Con datos preprocesados de alta calidad, se pueden aplicar algoritmos computacionales (*IDN/IMB*) de segmentación de vegetación, cuerpos de agua, superficies de nieve y construcción. El resultado de la clasificación cierta/errónea de materiales/superficies va a depender de método *IDN/IMB* utilizado. Los algoritmos *NDVI*, *MNDWI*, *AWEI<sub>nsh</sub>*, *NDSI* y *NDBI* basados en el valor de umbral óptimo, tienden a clasificar erróneamente los materiales en resultados sin binarizar. Por otra parte, los métodos propuestos *AWI – MS* y *ASI – MS*, logran discriminar información (ejemplo, sombra), en una o múltiples escenas, en resultados sin binarizar de forma automática. Basados en la metodología de la diferencia normalizada, los méto-

dos  $AWI - MS$  y  $ASI - MS$ , aprovecha la alta y baja reflectancia de los materiales (ejemplo, vegetación y suelo), para asignar valores negativos o nulos y suprimirlos de la escena.

Los múltiples resultados de los algoritmos computacionales utilizados en esta Tesis, pueden ayudar a entender e interpretar los cambios que sufren las regiones y sus ecosistemas. Por ejemplo, la región de España de la Figura 3 del capítulo 4, muestra un crecimiento en la cantidad de densidad de plantas en el periodo de 1984 al 2009, con un porcentaje de píxeles de vegetación creciente de [12.680496 %, 23.624731 %]. El monitoreo del lago Metztitlán de la Figura 4.7 (a), (b) y (c), arroja un porcentaje estadístico variable de [16.280024 %, 9.884537 %, 30.703616 %], correspondiente a la variabilidad de la cantidad de agua que el lago tiene a través del tiempo. El lago Poopó mostrado en la Figura 4.8g-4.8i, tiene un porcentaje de píxeles de agua decreciente de [30.501142 %, 19.835817 %] en el periodo del 2003 al 2009, como resultado a la pérdida de agua que el lago tiene en el transcurso de los años. La región de Groenlandia en el periodo de 1990 a 2009 mostrado en la Figura 4.12, tiene un rango de [31.899568 %, 24.343846 %], correspondiente al deshielo de esta región. Por último, en la Figura 4.16 se observa la creciente ciudad de Moscú que muestra un porcentaje de [21.2982 %, 36.1528 %], con respecto a al progresivo incremento en la urbanización de esta ciudad.

## 5.2. Trabajo a futuro

Los algoritmos  $AWI - MS$  y  $ASI - MS$  propuestos en esta Tesis, tuvieron mejores resultados que los  $IDN/IMB$  mediante el método de la inspección visual. Como trabajo a futuro, se pretende evaluar y compara cuantitativamente los algoritmos propuestos y los  $IDN$  e  $IMB$ .

La firma espectral única para cada material, muestra información que puede ser utilizada para discriminar ciertos materiales de otros. Como trabajo a futuro, se realizarán nuevos índices de extracción para la construcción y vegetación en base a nuevas combinaciones de bandas espectrales, con el fin de obtener resultados de mayor calidad y consistencia en escenas de alta diversidad geográfica.

# Evaluación de precisión y exactitud de

$MNDWI$ ,

$AWEI_{nsh}$  y

$AWI - MS$

# A

La *RoI* utilizada para la evaluación de  $MNDWI$ ,  $AWEI_{nsh}$  y  $AWI - MS$ , en el lago Bosques que se encuentra en la frontera entre *USA* y Canadá. El Lago Bosques es seleccionado por la alta diversidad geográfica de materiales alojados en la escena (ejemplo, vegetación, construcción, suelo, arena). Para obtener los datos de referencia (puntos verdaderos de agua y no agua), se generaron 180 puntos aleatorios en el centro de 180 píxeles que componen la escena, como se muestra en la Figura A.1. Posteriormente, los puntos fueron etiquetados como agua (60 puntos) y no agua (120 puntos), utilizando imágenes de alta resolución en Google Earth Pro (Google Inc., Menlo Park, CA, USA).

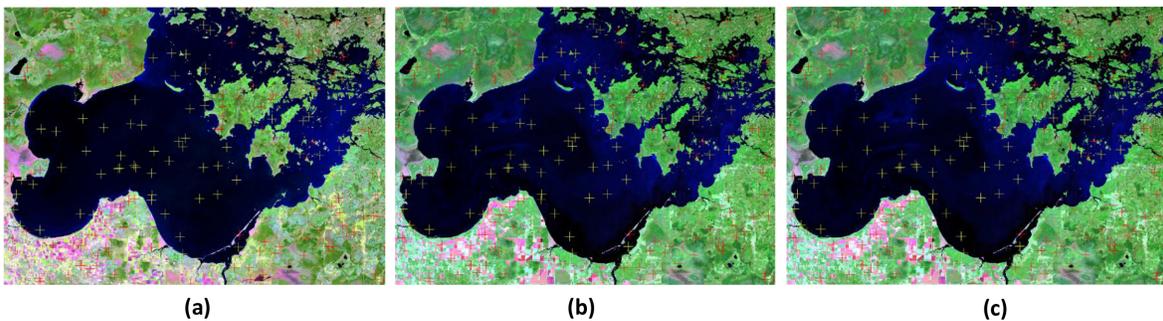


Figura A.1: Imágenes compuestas por  $SWIR2$ ,  $NIR$  y Verde con 180 puntos verdaderos distribuidos aleatoriamente: (a) Landsat 5  $TM$ , (b) Landsat 8  $OLI$  y (c) Sentinel-2  $MSI$ .

Los resultados de  $MNDWI$ ,  $AWEI_{nsh}$  y  $AWI - MS$  y la distribución de puntos en imágenes sin binarizar se muestran en la Figura A.2, para escenas registradas por los satélites Landsat y Sentinel-2.

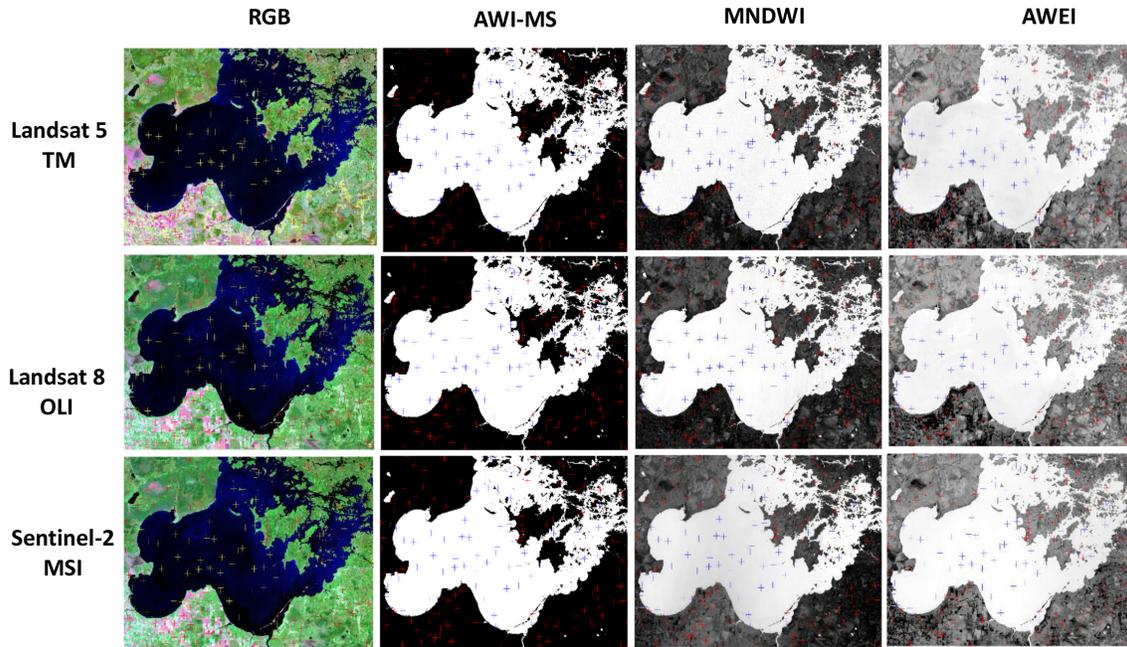


Figura A.2: Puntos verdaderos distribuidos aleatoriamente en escenas registradas por los sensores  $TM$ ,  $OLI$  y  $MSI$ .

Para la evaluación de  $MNDWI$ ,  $AWEI_{nsh}$  y  $AWI - MS$ , se utilizan cuatro tipos de datos (píxeles) de referencia:

- Verdadero positivo ( $TP$ ): el número de píxeles de agua extraídos correctamente.
- Falso negativo ( $FN$ ): el número de píxeles de agua no detectados.
- Falso positivo ( $FP$ ): el número de píxeles de agua extraídos incorrectamente.
- Verdadero negativo ( $TN$ ): el número de píxeles que no son agua rechazados correctamente [A.1, A.2].

Los datos de referencia se clasifican en la matriz de confusión como se muestra en la Tabla A.1 [A.2].

Tabla A.1: Clasificación de datos de entrada.

		Dato de referencia	
		Agua	No-agua
Datos de clasificación	Agua	TP	FP
	No-Agua	FN	TN

En base a los datos de clasificación, se calculó la exactitud del productor ( $PA$ ), que sirve para observar cuantitativamente el error de omisión entre las clases de píxeles. Para obtener los resultados de errores de omisión (píxeles que aparecen en cierta clase, pero no pertenecen a ella), se calcula la exactitud del usuario ( $UA$ ). Se obtiene la exactitud global ( $OA$ ), que indica la precisión entre las clases de píxeles de forma global y Kappa ( $k$ ) para verificar la clasificación correcta en datos aleatorios mediante las expresiones [A.1]:

$$PA = \frac{TP}{TP + FN}; \quad OA = \frac{TP + TN}{T}, \quad (A.1)$$

$$UA = \frac{TP}{TP + FP}; \quad k = \frac{T(TP + TN) - \Sigma}{T^2 - \Sigma}, \quad (A.2)$$

donde,

$$\Sigma = (TP + FP)(TP + FN) + (FN + TN)(FP + TN),$$

$T = total \text{ de píxeles}.$

$PA$ ,  $UA$  Y  $OA$  son predicciones correctas con rango entre  $[0,1]$ , donde el valor 1 corresponde a una perfecta predicción. Debido a que  $PA$ ,  $UA$  Y  $OA$  no consideran el acuerdo entre conjuntos de datos al azar, en este estudio se utiliza Kappa ( $k$ ).  $k$  es una herramienta para controlar el factor de acuerdo aleatorio, con un rango  $[-1, 1]$ , donde  $k = 0$  representa la cantidad de acuerdo que puede esperarse y  $k = 1$  significa un acuerdo perfecto entre los evaluadores. En la Tabla A.2 se muestran los resultados de precisión de  $PA$ ,  $UA$  Y  $OA$  y  $k$  para  $MNDWI$ ,  $AWEI_{nsh}$  y  $AWI - MS$  en datos sin binarizar adquiridos por diferentes satélites [A.1, A.2].

Los resultados de la tabla muestran que  $MNDWI$  extrae todos los píxeles que pertenecen al agua correctamente con un  $PA = 1$ , para las imágenes registradas por los sensores  $TM$ ,  $OLI$  y  $MSI$ . Sin embargo, extrae píxeles que no pertenecen al agua mostrando un bajo y variable  $UA$  para los datos registrados por los tres sensores satelitales. Los resultados del factor de acuerdo aleatorio  $k$  para el método  $MNDWI$  se encuentra en un rango entre  $[0.7067, 0.8235]$ , mostrando un acuerdo alto entre los evaluadores.

El método  $AWEI_{nsh}$  muestra un  $PA = 1$ , lo que significa que extrae correctamente los píxeles que pertenecen al agua. Sin embargo, muestra el peor resultado con un rango de  $UA$  entre  $[0.5084, 0.5660]$ , con una alta clasificación errónea de extracción de píxeles que no pertenecen al agua. El valor de  $k$  para  $AWEI_{nsh}$  es el más bajo entre los algoritmos analizados, con un valor de  $k$  con rango de  $[0.4285, 0.5174]$ , mostrando bajo factor de acuerdo aleatorio ente los conjuntos de datos.

Tabla A.2: Resultado de la evaluación de exactitud y precisión de los algoritmos  $MNDWI$ ,  $AWEI_{nsh}$  y  $AWI - MS$  en el Lago Bosques.

Satélite	Índice	PA	UA	OA	Kappa
Landsat 5 TM	AWI-MS	1	1	1	1
	MNDWI	1	0.6976	0.8555	0.7067
	$AWEI_{nsh}$	1	0.5660	0.7444	0.5174
Landsat 8 OLI	AWI-MS	1	1	1	1
	MNDWI	1	0.8	0.9166	0.8235
	$AWEI_{nsh}$	1	0.5084	0.6944	0.4285
Sentinel-2 MSI	AWI-MS	1	1	1	1
	MNDWI	1	0.7058	0.8611	0.7169
	$AWEI_{nsh}$	1	0.5309	0.7055	0.4573

El algoritmo propuesto  $AWI - MS$ , muestra una extracción correcta de píxeles que pertenecen al agua con un  $PA = 1$ .  $AWI - MS$  muestra un  $UA = 1$ , los que significa que logra discriminar los píxeles pertenecientes a diferentes materiales (ejemplo, vegetación, suelo, construcción, arena) alojados en la escena con alta precisión. Aún más, el valor de  $k = 1$  con un acuerdo exacto entre los evaluadores  $PA$ ,  $UA$  Y  $OA$  para datos registrados por los tres sensores satelitales mostrados en la Tabla A.2.

# Bibliografía

[A.1] McHugh, M. L. Interrater reliability: the kappa statistic. *Biochemia medica: Biochemia medica*, vol. 22, no 3, p. 276-282,(2012).

[A.2] Acharya, T., Subedi, A., & Lee, D. Evaluation of Water Indices for Surface Water Extraction in a Landsat 8 Scene of Nepal. *Sensors*, vol. 18, no 8, p. 2580, (2018).

# B

# Apéndice: Trabajos derivados de la tesis

---

## B.1. Memorias en extenso

- **M. Arreola-Esquivel**, M. Delgadillo-Herrera, C. Toxqui-Quitl, A. Padilla-Vivanco, "Index-based methods for water body extraction in satellite data,"Proc. of SPIE 11137, 111372N 1-9 (2019). <https://doi.org/10.1117/12.2529756>
- M. Delgadillo-Herrera, **M. Arreola-Esquivel**, C. Toxqui-Quitl, A. Padilla-Vivanco, "Normalized difference indices in Landsat 5 TM satellite data,"Proc. of SPIE 11104, 111040W 1-9 (2019). <https://doi: 10.1117/12.2532322>
- L. Alvarado-Cruz, M. Delgadillo-Herrera, C. Toxqui-Quitl, A. Padilla-Vivanco, R. Castro-Ortega, **M. Arreola-Esquivel**, "Fractal analysis for classification of breast lesions,"Proc. of SPIE 11104, 111040U 1-9 (2019). <https://doi.org/10.1117/12.2531201>

# PROCEEDINGS OF SPIE

[SPIDigitalLibrary.org/conference-proceedings-of-spie](https://SPIDigitalLibrary.org/conference-proceedings-of-spie)

## Index-based methods for water body extraction in satellite data

M. Arreola-Esquivel, M. Delgadillo-Herrera, C. Toxqui-Quitl, A. Padilla-Vivanco

M. Arreola-Esquivel, M. Delgadillo-Herrera, C. Toxqui-Quitl, A. Padilla-Vivanco, "Index-based methods for water body extraction in satellite data," Proc. SPIE 11137, Applications of Digital Image Processing XLII, 111372N (6 September 2019); doi: 10.1117/12.2529756

**SPIE.**

Event: SPIE Optical Engineering + Applications, 2019, San Diego, California, United States

# Index-based methods for water body extraction in satellite data

M. Arreola-Esquivel, M. Delgadillo-Herrera, C. Toxqui-Quitl, and A. Padilla-Vivanco

Computer Vision Laboratory, Universidad Politécnica de Tulancingo, Hgo. 43629, México.

## ABSTRACT

Several water index-based methods have been proposed in the literature, which, combine satellite multispectral bands in an algebraic expression. The objective of these water index-based methods is to increase the intensity contrast between water-pixels (surface water-body) and non-water pixels (built-up, soil, vegetation, etc.). The present investigation evaluates the Modified Normalized Difference Water Index (MNDWI) and the Automated Water Extraction Index (AWEI) using the Satellite data from Landsat 5 TM, Landsat 8 and Sentinel 2A at different time scenes. Based on visual inspection of the Lake Metztitlan water body mapping results, a high performance of AWEI approached via the OLI and the MSI sensors is observed. In the selected study area of  $[9210x9380]m$ , a statistical water pixel percentage of 30.703616% is observed in a flooding season and 9.884537% for a dry season of the year.

**Keywords:** Water index-based methods, Landsat data, Sentinel imagery.

## 1. INTRODUCTION

Water body change detection is an excellent indicator of environmental alteration [1, 2]. The shortage of natural resources due to climate change, urban growth, deforestation, among others has great impact on society. These environmental changes can be evaluated by spectral information registered with a satellite sensor[3]. The long-term Landsat and Sentinel satellite imagery has proved to be an invaluable data resource for environmental water change and ecological analysis. Landsat missions has been operated by the US Geological Survey (USGS) since 1990 [4] and Sentinel 2A was launched by ESA on 2015 [5]. Since, Landsat and Sentinel data became a free download through Internet portals (i.e. Earth Explorer, USGS), it has become an object of study in remote sensing of the Earth surface. The USGS registers 50-fold annually increase in downloads of satellite images [6]. The spatial and spectral resolution in satellite imagery may differ according to the satellite sensor. A comparison of the wavelength bands and spatial resolution among sensors are shown in Table 1.

Table 1. Band specifications of TM, OLI and MSI satellite sensors [7].

BANDS	Landsat 5 TM		Landsat 8 OLI		Sentinel-2 MSI	
	Wavelength ( $\mu m$ )	Spatial resolution ( $m$ )	Wavelength ( $\mu m$ )	Spatial resolution ( $m$ )	Wavelength ( $\mu m$ )	Spatial resolution ( $m$ )
Blue	0.45 - 0.52	30	0.45-0.51	30	0.46-0.52	10
Green	0.52 - 0.60	30	0.53-0.59	30	0.55-0.58	10
Red	0.63 - 0.69	30	0.64-0.67	30	0.64-0.67	10
NIR	0.76 - 0.90	30	0.85-0.88	30	0.78-0.90	10
SWIR-1	1.55 - 1.75	30	1.57-1.65	30	1.57-1.65	20
SWIR-2	2.08 - 2.35	30	2.11-2.29	30	2.10-2.28	20

Based on algebraic expression and bands combination [8, 9], several methods have been developed for surface water extraction [10]. Among the highly threshold-number methods proposed in the literature are the Modified Normalized Difference Water Index (MNDWI) [11], and the Automated Water Extraction Index  $AWEI_{nsh}$  no shadows [12].

In order to obtain a high MNDWI and AWEI surface water classification accuracy, an optimum threshold-number must be found. However, selecting a smaller interval number to find the optimum threshold value can be time-consuming due to different environmental scene (e.g. geographical area, date and time acquisition) conditions [13]. The histogram from a multispectral image can be used to identify the optimum histogram-threshold value in a single or multiple scenes with a high geographical diversity.

The purpose of this discussion paper is to provide a concise overview of the AWEI and the MNDWI performance, when combining multispectral bands registered by TM, OLI and MSI satellite sensors at different time scenes. The workflow of this document is as follows: In Section 2, the index-based methods definition for water extraction are given. In Section 3, is illustrated the Region Of Interest (ROI) of the study area and the optimum histogram-threshold value of the selected scene. Section 4, outlines MNDWI and AWEI examples of water body extractions using Landsat 5 TM, Landsat 8 OLI and Sentinel 2A imagery. Section 5, a statistical water pixel percentage change detection is analyzed using the AWEI method. Finally in Section 6, a main conclusion is discussed.

## 2. INDEX-BASED METHODS FOR WATER BODY EXTRACTION

Multi-band index-based methods lies in calculation of the normalized difference between the maximum and minimum reflectance values among multispectral imagery.

### 2.1 Modified Normalized Difference Water Index (MNDWI)

The aim of the Modified Normalized Difference Water Index (MNDWI) lies in increase the intensity contrast between the open water bodies and the background (non-water pixels). The MNDWI is express as [11],

$$MNDWI = \frac{(Green - (SWIR - 1))}{(Green + (SWIR - 1))}, \quad (1)$$

where *Green* and *SWIR - 1* are the spectral bands defined in table 1. As a result, the water-pixels will have greater positive values, due to it absorbs the SWIR. On the other hand, built-up, soil and vegetation land cover will have negative values as these ones reflect SWIR.

### 2.2 Automated Water Extraction Index $AWEI_{nsh}$ no shadows

In the development of the Automated Water Extraction Index ( $AWEI_{nsh}$ ), five spectral bands and different coefficients are used. The  $AWEI_{nsh}$  aim is to separate water-pixels with positive values from negative pixels that represent non-water (e.g. built-up surfaces).  $AWEI_{nsh}$  is defined as [12],

$$AWEI_{nsh} = 4(R_{Green} - R_{SWIR-1}) - (0.25R_{NIR} + 2.75R_{SWIR-2}), \quad (2)$$

where *R* is the reflectance value of the *Green*, *NIR*, *SWIR - 1* and *SWIR - 2* spectral bands defined in table 1.

## 3. DATA ANALISYS

The ROI of this study is Lake Metztitlan located at: Lat: 20.68226346° *N* and Lon: -98.85789350° *W* in Hidalgo state of México, which can be seen in Figure 1. The acquisition data registered by Landsat 5 TM (January 23, 2011), Landsat 8 OLI (April 18, 2013) and Sentinel 2A (March 11, 2017) are shown in Figure 1 (a), (b) and (c). The same georeferenced area of the Level 1 (L1T) Landsat and Level 1C (L1C) Sentinel 2 Terrain-Corrected was selected in ENVI version 5.1 (Exelis Visual Information Solutions, Boulder, Colorado).

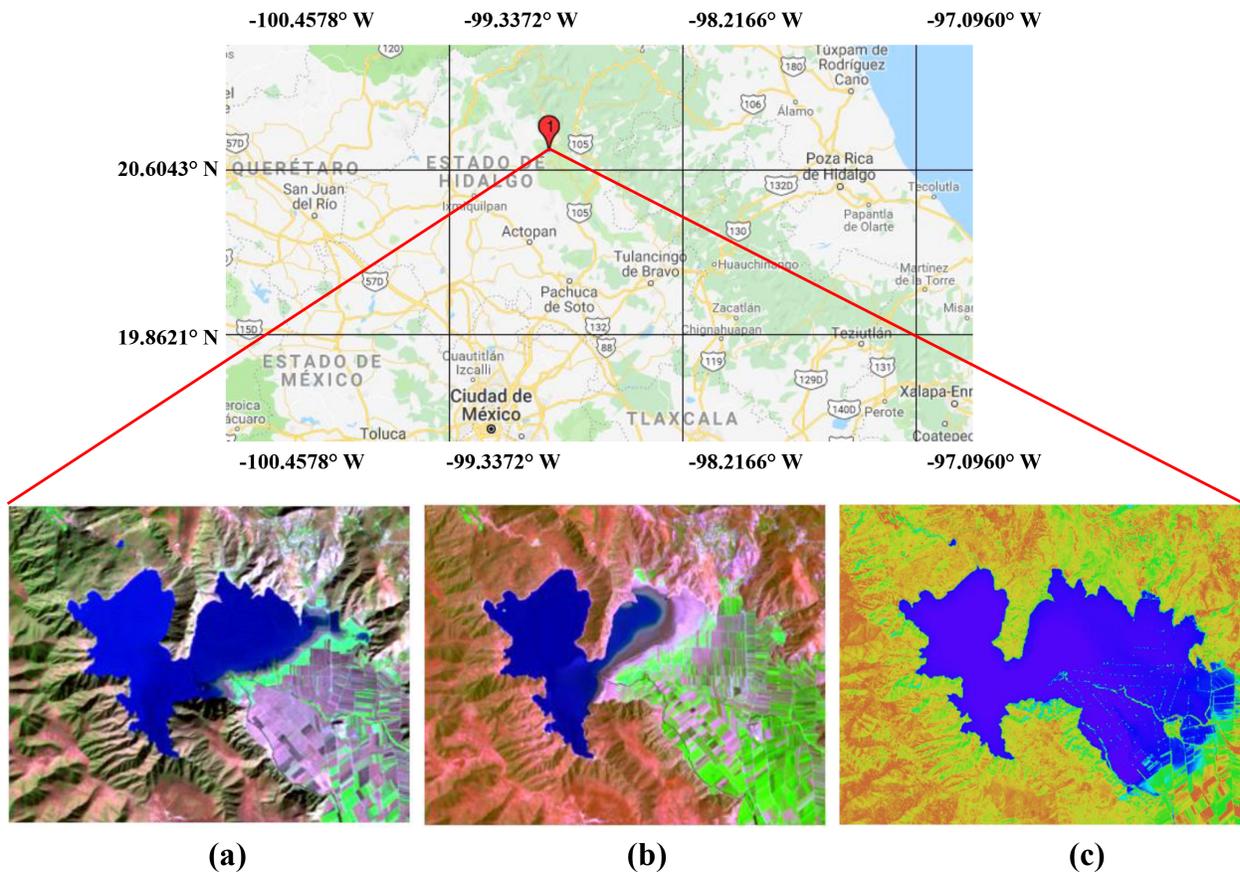


Figure 1. Geographical RGB scene location of Lake Metztiltan from [14]: Resolution of 307x246 pixels for (a) Landsat 5 TM and (b) Landsat 8 OLI, and 663x531 pixels for (c) Sentinel 2A.

The USGS satellite data used for certain water-land analyses, must be preprocessed to obtain high quality results in different time-sensor scenes [15]. Before computing the MNDWI and  $AWEI_{nsh}$  water extractions, the Landsat multispectral data was solar and atmospheric corrected using ENVI. The Sentinel 2A imagery were Bottom Of Atmosphere (BOA) corrected with the Sen2Cor algorithm on SNAP - ESA Sentinel Application Platform v2.0.2. In addition, Sentinel 2A visible and near infrared bands were resampled to 20 m by means of the nearest neighborhood approach in SNAP to make Sentinel and Landsat data resolution consistent.

#### 4. WATER EXTRACTION RESULTS

In this study, we analyzed the variation of a high geographical diversity scene threshold (HGDST) obtained by Acharya [3]. Where is propose an optimal threshold number (OTN) using the MNDWI method ( $OTN_{MNDWI} = 0.35$ ) and AWEI approach ( $OTN_{AWEI_{nsh}} = 0.1897$ ). Furthermore, we compute the histogram-threshold (HTV) derived from each scene. In order to select the optimum HTV, the intensity contrast between water-pixels (with positive values) and non-water pixels (with negative values) was taken into account. The positive number between the two height peaks in a histogram was chosen as the optimum threshold value with high stability among NDWI and  $AWEI_{nsh}$  images. An example of the histogram to find the optimum HTV is shown in Figure 2.

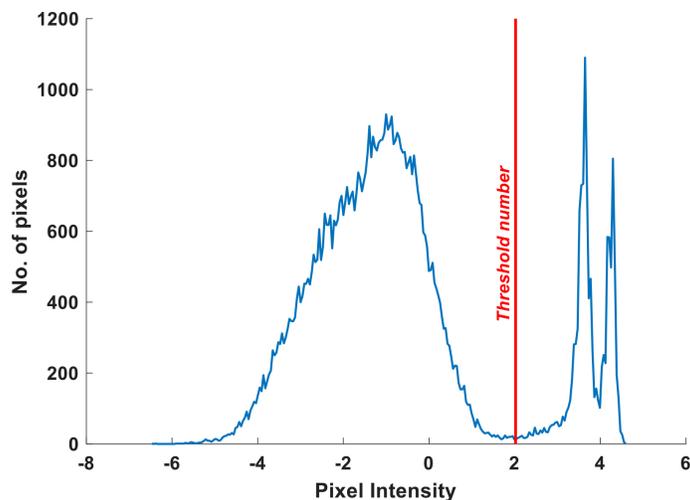


Figure 2. Histogram representing an AWEI image result with positive pixel intensity (water body) and negative pixel intensity (background), using Landsat 5 TM imagery. The selected  $HTV_{AWEI_{nsh}} = 2.02159$ .

#### 4.1 Water body extraction of Lake Metztitlan using Landsat 5 TM imagery

The MNDWI and  $AWEI_{nsh}$  index-based methods for water body extraction were applied to the satellite data of Figure 1a. Comparing the results in Figure 3 a lower performance is presented in (a) the non-binarized MNDWI algorithm, which does not suppress artifacts (e.g. urban and shadow areas).

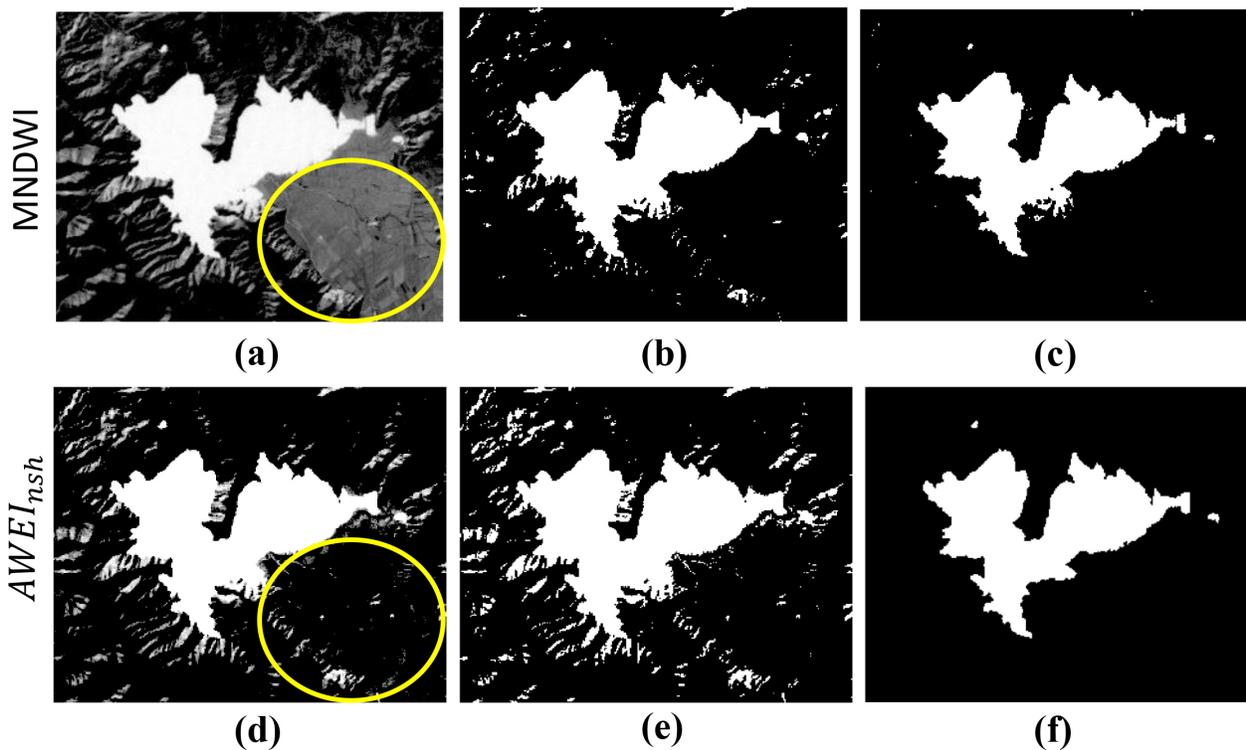


Figure 3. Lake Metztitlan: (a) Non-binarized MNDWI, (b)  $OTN_{MNDWI}$ , (c)  $HTV_{MNDWI} = 0.63888$ , (d) Non-binarized  $AWEI_{nsh}$ , (e)  $OTN_{AWEI_{nsh}}$ , and (f)  $HTV_{AWEI_{nsh}} = 2.02159$ .

Furthermore, the (d) non-binarized  $AWEI_{nsh}$  could not be able to discriminate mountain shadows and vegetation. On the other hand, (b) and (e),  $OTN_{MNDWI}$  shows a greater accuracy regarding  $OTN_{AWEI_{nsh}}$ . In Figures 3 (c) and (f) is shown that  $HTV_{MNDWI}$  is extracting shadows and water mix information that  $HTV_{AWEI_{nsh}}$  does not. Comparing OTN and HTV, the last present fairly stability to suppress non-water surfaces.

#### 4.2 Water body extraction of Lake Metztitlan using Lansat 8 OLI imagery

The MNDWI and  $AWEI_{nsh}$  index-based methods for water body extraction were apply to the satellite data of Figure 1b. Similar as in section 4.1, the worst result is shown by (a) non-binarized MNDWI. Meanwhile, the histogram procedure in Figure 4 (c) and (f) using multispectral OLI imagery, presents a high surface water mapping accuracy.

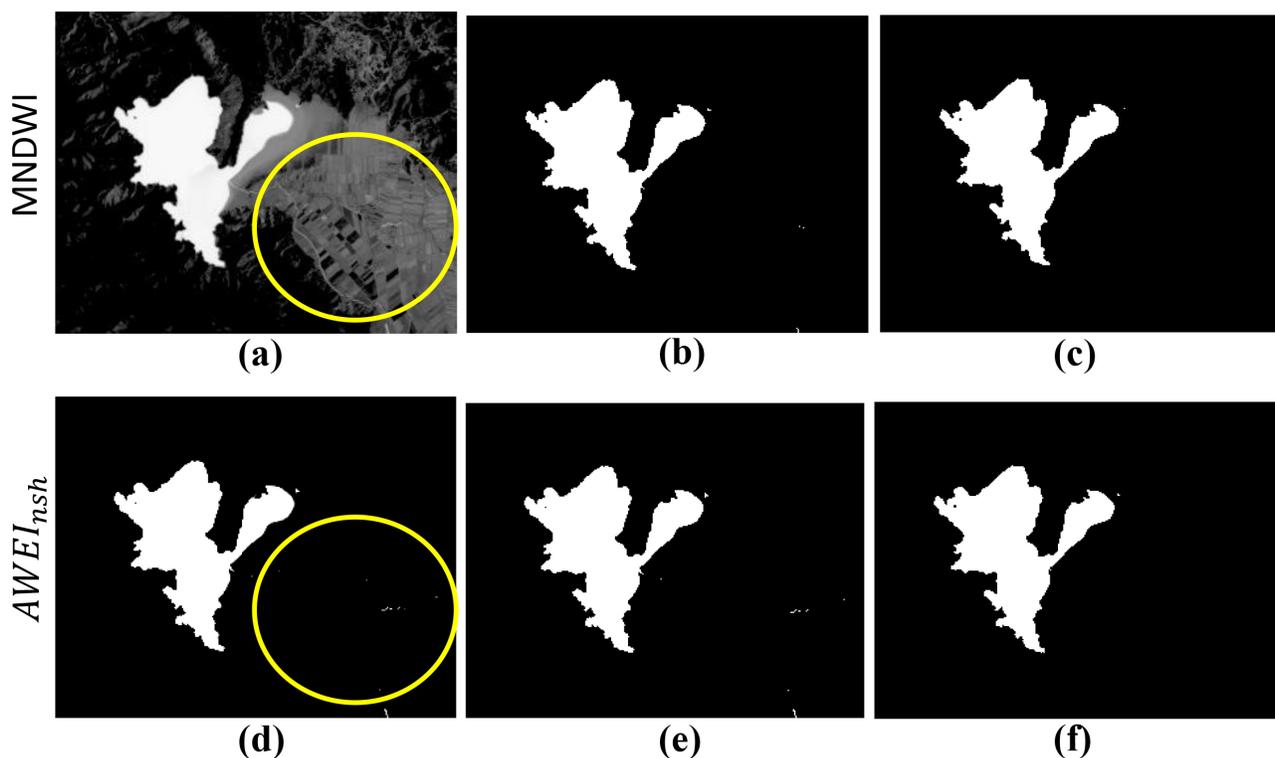


Figure 4. Lake Metztitlan: (a) Non-binarized MNDWI, (b)  $OTN_{MNDWI}$ , (c)  $HTV_{MNDWI} = 0.58570$ , (d) Non-binarized  $AWEI_{nsh}$ , (e)  $OTN_{AWEI_{nsh}}$ , and (f)  $HTV_{AWEI_{nsh}} = 2.37209$ .

#### 4.3 Water body extraction of Lake Metztitlan using Sentinel 2A imagery

The MNDWI and  $AWEI_{nsh}$  index-based methods for water body extraction were apply to the satellite data of Figure 1c. The non-binarized (a) and (d) images in Figure 5, show the worst results as in section 4.1 and 4.2. On the other hand, the results of the histogram procedure with the MSI sensor exhibit a precise water body separation (positive water pixel values) from the background (negative pixel values).

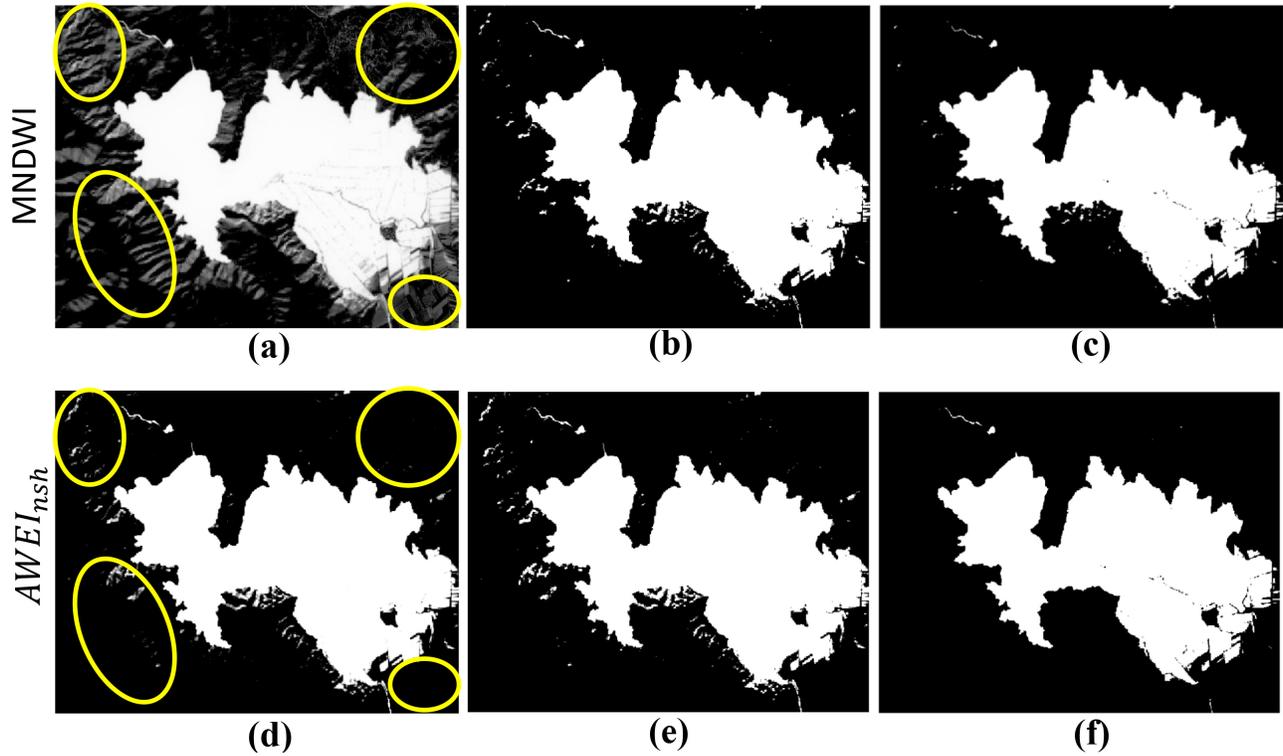


Figure 5. Lake Metztitlan: (a) Non-binarized MNDWI, (b)  $OTN_{MNDWI}$ , (c)  $HTV_{MNDWI} = 0.50610$ , (d) Non-binarized  $AWEI_{nsh}$ , (e)  $OTN_{AWEI_{nsh}}$ , and (f)  $HTV_{AWEI_{nsh}} = 1.75806$ .

## 5. SURFACE WATER MONITORING OF LAKE METZTITLAN

In this Section, a comparison of the  $HTV_{AWEI_{nsh}}$  results among sensor is done. In a high quality data results, the amount of water (pure water pixels) can be compared over time. In Figure 6 (b) the image registered on April 18, 2013 shows the least amount of water, while in (a) January 23, 2011 the water increases. In (c) image registered in March 11, 2017 can be observed flooded urban areas.

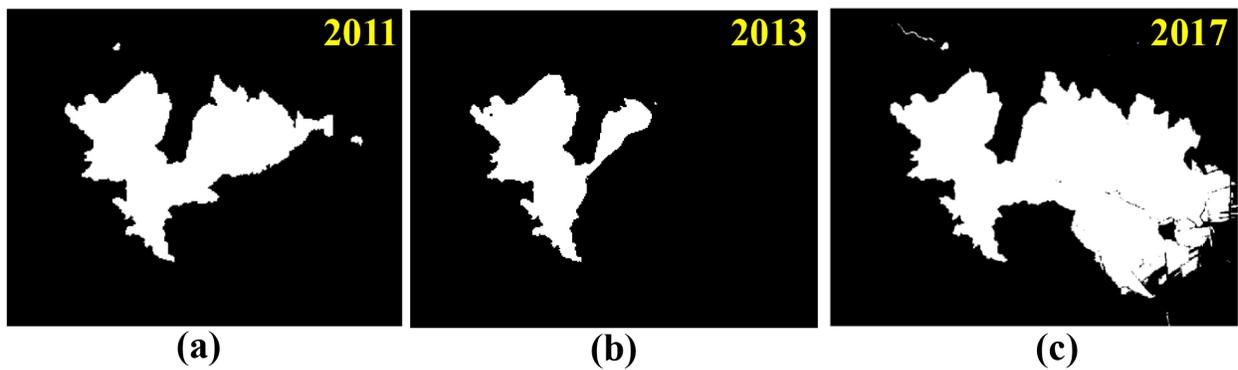


Figure 6. Lake Metztitlan: (a) Landsat 5 TM, (b) Landsat 8 OLI, (c) Sentinel 2A.

Table 2. Water pixel percentages from Figure 6 a-c.

2011	2013	2017
16.280024%	9.884537%	30.703616%

## 6. CONCLUSIONS

Among  $AWEI_{nsh}$  and MNDWI results shown in Figures 3, 4, and 5, a better performance is obtained with  $AWEI_{nsh}$  algorithm.  $AWEI_{nsh}$  exhibit a high stability among non-binarized and optimal threshold imagery of Lake Metztitlan water body mapping. In order to remove artifacts (non-water pixels) in the scene using  $AWEI_{nsh}$  method, an optimum threshold value is used, but some information (water pixels) could be remove from the scene. In the Figure 6 (a), (b) and (c), is observed a closer approach to the Lake Metztitlan analysis at different time scenes among sensors in  $AWEI_{nsh}$  imagery. The monitoring of the change detection in Lake Metztitlan shows a statistical percentage pixel of 30.703616% for flooding season and 9.884537% for dry season. Beyond this certain study, the radiometric characteristics and the atmospheric correction difference among sensors can affect the water mapping results. Those differences must be taken into account in upcoming analysis.

## ACKNOWLEDGMENTS

M. Arreola-Esquivel and M. Delgadillo-Herrera thank to Consejo Nacional de Ciencia y Tecnología (CONACyT); with CVU no. 858585 and 858588. We thank the support of PADES program; Award no. 2018-13-011-047. And we thank to Politecnico di Torino by the support during the research stay in October-November 2018 and May-June 2019.

## REFERENCES

- [1] Pekel, J.-F., Cottam, A., Gorelick, N., and Belward, A. S., "High-resolution mapping of global surface water and its long-term changes," *Nature* **540**(7633), 418 (2016).
- [2] Valdiviezo-N, J. C., Castro, R., Cristóbal, G., and Carbone, A., "Hurst exponent for fractal characterization of landsat images," in [*Remote sensing and modeling of ecosystems for sustainability Xi*], **9221**, 922103, International Society for Optics and Photonics (2014).
- [3] Acharya, T., Subedi, A., and Lee, D., "Evaluation of water indices for surface water extraction in a landsat 8 scene of nepal," *Sensors* **18**(8), 2580 (2018).
- [4] USGS, "What are the band designations for the Landsat satellites?." USGS, 2018 [https://www.usgs.gov/faqs/what-are-band-designations-landsat-satellites?qt-news\\_science\\_products=0#qt-news\\_science\\_products](https://www.usgs.gov/faqs/what-are-band-designations-landsat-satellites?qt-news_science_products=0#qt-news_science_products). (Accessed: 15 December 2018).
- [5] USGS, "USGS EROS Archive - Sentinel-2." USGS, 2019 [https://www.usgs.gov/centers/eros/science/usgs-eros-archive-sentinel-2?qt-science\\_center\\_objects=0#qt-science\\_center\\_objects](https://www.usgs.gov/centers/eros/science/usgs-eros-archive-sentinel-2?qt-science_center_objects=0#qt-science_center_objects). (Accessed: 20 January 2019).
- [6] Young, N. E., Anderson, R. S., Chignell, S. M., Vorster, A. G., Lawrence, R., and Evangelista, P. H., "A survival guide to landsat preprocessing," *Ecology* **98**(4), 920–932 (2017).
- [7] Zhou, Y., Dong, J., Xiao, X., Xiao, T., Yang, Z., Zhao, G., Zou, Z., and Qin, Y., "Open surface water mapping algorithms: A comparison of water-related spectral indices and sensors," *Water* **9**(4), 256 (2017).
- [8] Rouse Jr, J., Haas, R., Schell, J., and Deering, D., "Monitoring vegetation systems in the great plains with erts," (1974).
- [9] Tucker, C. J., Holben, B. N., Elgin Jr, J. H., and McMurtrey III, J. E., "Remote sensing of total dry-matter accumulation in winter wheat," *Remote Sensing of Environment* **11**, 171–189 (1981).
- [10] McFeeters, S. K., "The use of the normalized difference water index (ndwi) in the delineation of open water features," *International journal of remote sensing* **17**(7), 1425–1432 (1996).
- [11] Xu, H., "Modification of normalised difference water index (ndwi) to enhance open water features in remotely sensed imagery," *International journal of remote sensing* **27**(14), 3025–3033 (2006).
- [12] Feyisa, G. L., Meilby, H., Fensholt, R., and Proud, S. R., "Automated water extraction index: A new technique for surface water mapping using landsat imagery," *Remote Sensing of Environment* **140**, 23–35 (2014).

- [13] Jiang, H., Feng, M., Zhu, Y., Lu, N., Huang, J., and Xiao, T., “An automated method for extracting rivers and lakes from landsat imagery,” *Remote Sensing* **6**(6), 5067–5089 (2014).
- [14] USGS, “USGS science for a changing world.” USGS, 2019 <https://earthexplorer.usgs.gov/>. (Accessed: 10 July 2019).
- [15] Chander, G., Markham, B. L., and Helder, D. L., “Summary of current radiometric calibration coefficients for landsat mss, tm, etm+, and eo-1 ali sensors,” *Remote sensing of environment* **113**(5), 893–903 (2009).