

Inventario de cuerpos de agua de la Sierra Madre Occidental (México) usando SIG y percepción remota

Water Resource Inventory in the Sierra Madre Occidental (Mexico) based on Remote Sensing and GIS

Sarahi Sandoval,* Jonathan Gabriel Escobar-Flores** y Eduardo Sánchez-Ortíz**

Recibido: 02/09/2019. Aprobado: 21/04/2020. Publicado en línea: 13/07/2020.

Resumen. El agua dulce es un recurso fundamental para procesos ambientales y sociales, indispensable para el surgimiento y desarrollo de la vida, por lo que mapear y monitorear las aguas superficiales tiene gran importancia para comprender los procesos hidrológicos y gestionar los recursos hídricos. El presente estudio se realizó en la cadena montañosa más grande de México, la Sierra Madre Occidental (SMO), localizada entre los estados de Chihuahua, Sonora, Sinaloa, Durango, Nayarit, Zacatecas y Jalisco. La SMO tiene un área de 251 648 km² y cuenta con elevaciones desde 300 m hasta 3 347 m. Debido a su magnitud, orografía y posición geográfica, alberga una gran variedad de ecosistemas, lo que, a su vez, promueve una gran diversidad de especies y constituye la principal fuente de agua para el norte del país.

Los objetivos de esta investigación fueron: 1) la detección de cuerpos de agua en la SMO utilizando imágenes de satélite Sentinel-2 de alta resolución espacial, y 2) la realización de un inventario de los cuerpos de agua en los diferentes tipos de vegetación presentes en tal sierra. En esta investigación se utilizaron 120 imágenes del satélite Sentinel-2, que se caracteriza por tener un sensor multiespectral con una resolución espacial de 10 m. A cada una de las imágenes satelitales se le realizó una corrección atmosférica mediante el método de sustracción de cuerpos oscuros. Para la detección y delimitación de cuerpos de agua se aplicó el Índice Diferencial de Agua Normalizado (NDWI, por sus siglas en inglés). Previo al proceso de validación, se realizó una tabulación cruzada

entre los cuerpos de agua que se detectaron contra los polígonos de tipos de vegetación que se clasificaron de la siguiente manera: clase bosque, que incluye tipos de vegetación de pino, encino, pino-encino, encino-pino y bosque mesófilo; clase selva, que incluye selva baja y mediana caducifolia; clase bosque con vegetación secundaria herbácea y arbustiva; clase matorral; clase pastizal y clase chaparral. Estos polígonos se obtuvieron de la Serie VI del vectorial de uso de suelo y vegetación del Inegi, escala 1:250 000. Mediante un geoprocetamiento en el programa ArcGIS 10.7 se obtuvo el número de cuerpos de agua (y su superficie) detectados en cada clase de vegetación. La validación en la estimación de superficies de los cuerpos de agua se realizó con la estimación del índice de Kappa y matrices de confusión y errores, de las cuales se calcularon las superficies de cuerpos de agua y sus intervalos de confianza para cada clase de vegetación. Se detectaron 26 394 cuerpos de agua; el tipo de vegetación con más cuerpos de agua encontrados fue el correspondiente a bosques, con 46.86%, seguido por pastizales, con 21.47%. Los cuerpos de agua detectados tuvieron una superficie de entre 43 m² y 64 km². Los valores de los píxeles a partir del NDWI encontrados en los cuerpos de agua oscilaron entre 0.1 a 0.8, con una mediana cercana a 0.3, y los cuartiles, entre 0.2 y 0.4. En cuanto a la precisión de la detección de cuerpos de agua en los diferentes tipos de vegetación, los valores de Kappa indicaron acuerdos buenos y excelentes; los tipos de vegetación de bosque de pino-encino y mesófilo tuvieron el menor valor: $K = 0.62$, lo que se relacionó con

* CONACYT, Instituto Politécnico Nacional, CIIDIR Unidad Durango. Calle Sigma 119 Fraccionamiento 20 de Noviembre II, Durango, 34220, Durango, México. Email: sarahisandovale@gmail.com. <https://orcid.org/0000-0001-7221-5498>

** Instituto Politécnico Nacional, CIIDIR Unidad Durango. Calle Sigma 119 Fraccionamiento 20 de Noviembre II, Durango, 34220, Durango, México. Email: jescobarf@ipn.mx. <https://orcid.org/0000-0003-4265-9420>

sombras que se confundieron con cuerpos de agua (251 sombras). Los valores más altos de Kappa se obtuvieron en los pastizales, con $K = 0.91$, en donde se detectaron muy pocas sombras que se confundían con cuerpos de agua (13 sombras). La precisión global fue de 0.738, y en la matriz de error se encontró que la clase que presentó mayores errores de comisión fue el pastizal, con un valor de exactitud de usuario de 0.227. Otra clase que tuvo mayor omisión fue el matorral, con un valor de exactitud del productor de 0.351. La detección de los cuerpos de agua contribuye sustancialmente a los 800 cuerpos de agua reportados previamente para la SMO en la Serie VI del uso del suelo y vegetación en 2016.

Palabras clave: Índice Diferencial de Agua Normalizado, Sentinel-2, agua, percepción remota, tipos de vegetación.

Abstract. Fresh water is a fundamental resource for environmental and social processes, essential for the emergence and development of life. Mapping and monitoring surface water is therefore of great importance for understanding hydrological processes and managing water resources. This study was conducted in the largest mountain range in Mexico, the Sierra Madre Occidental (SMO), spanning the states of Chihuahua, Sonora, Sinaloa, Durango, Nayarit, Zacatecas and Jalisco. The SMO has an area of 251,648 km² and elevations ranging from 300 m to 3,347 m. Due to its size, orography and geographical location, this region which constitutes the main source of water for northern Mexico, contains a wide variety of ecosystems, which in turn promote high species diversity. The objectives of this study were: 1) to detect water bodies in the SMO using Sentinel-2 satellite images with high spatial resolution, and 2) to make an inventory of water bodies in the SMO by vegetation type. In this study, 120 Sentinel-2 satellite images were used. The satellite has a multispectral sensor with a spatial resolution of 10 m. An atmospheric correction was carried out for each image using the dark object subtraction method. The normalized difference water index (NDWI) was used to detect and delimit water bodies. Before the

validation process, the water bodies that had been detected were cross-tabulated against the polygons of the different vegetation types. These vegetation types were classified as follows: forest class, which includes pine, oak, pine-oak, oak-pine and cloud forest; tropical forest class, which includes low and medium deciduous tropical forest; forest with secondary herbaceous and shrubby vegetation class; scrub class; grassland class and chaparral class. The polygons were obtained from the INEGI 1:250,000 vectorial Series VI data on land use and vegetation. The number of water bodies (and their area) detected in each vegetation class were obtained through geoprocessing using the ArcGIS 10.7 program. Estimates of the areas of the water bodies were validated by estimating the kappa index, and by means of confusion and error matrices. These were used to calculate the areas of the water bodies and their confidence intervals for each vegetation class. A total of 26,394 water bodies were detected. The vegetation type with the most water bodies was forest, with 46.86%, followed by grasslands, with 21.47%. The water bodies detected had areas ranging from 43 m² to 64 km². Pixel values from the NDWI associated with water bodies ranged from 0.1 to 0.8. The median was close to 0.3, and the quartiles were 0.2 and 0.4. The kappa index values indicated good and excellent agreement for the precision of water body detection in the different vegetation types. The lowest value, $K = 0.62$, was associated with pine-oak and cloud forest vegetation types. This was due to shadows that were mistaken for water bodies (251 shadows). The highest kappa index values, $K = 0.91$, were obtained for grasslands, where very few shadows (13 shadows) were confused with water bodies. The overall precision was 0.738, and the error matrix showed that the class with the most errors of commission was grassland, with a user accuracy value of 0.227. The class that had the most errors of omission was scrub, with a producer accuracy value of 0.351. This study makes a substantial contribution to the 800 water bodies previously reported for the SMO in the Series VI data for land use and vegetation from 2016.

Key words: Normalized Difference Snow Index, Sentinel-2, water, remote sensing, vegetation type.

INTRODUCCIÓN

Aproximadamente 75% de la superficie terrestre está cubierta por el océano, sólo 0.26% es agua dulce (Rajagopal y Brands, 2017). Este recurso es fundamental para la salud humana, los medios de vida, la producción de alimentos, la industrialización y el desarrollo económico (UNESCO, 2006). La presencia de agua contribuye a preservar la biodiversidad en los ecosistemas ribereños o de humedales al proporcionar hábitats a una gran cantidad de flora y fauna (Vörösmarty *et al.*, 2010), por lo que mapear, monitorear y delinear la distribución

espacial de las aguas superficiales tiene gran importancia para comprender los procesos hidrológicos y gestionar los recursos hídricos (Papa *et al.*, 2008).

Los métodos tradicionales *in situ* usados para cuantificar y caracterizar los cuerpos de agua superficiales son demasiado costosos, por lo que actualmente se utilizan técnicas de percepción remota, ya que proporcionan mapas con cobertura sinóptica de forma rápida y con bajo costo (Yang *et al.*, 2017). Para la detección de cuerpos de agua se utilizaron imágenes satelitales de baja resolución espacial, por ejemplo, MODIS (Sharma *et al.*, 2015; Lu *et al.*, 2016) o imágenes de muy

alta resolución espacial, como Ikonos y QuickBird (Sarp, 2014; Huang *et al.*, 2015), imágenes Lidar (Canaz *et al.*, 2015), o bien imágenes de satélites de radar de apertura sintética (SAR) (Klemenjak *et al.*, 2012; Brisco *et al.*, 2009).

A la fecha se han desarrollado varios índices para el mapeo de cuerpos de agua derivados de las imágenes de satélite; entre los más utilizados se encuentran el NDWI, propuesto por McFeeters (1996), que utiliza la banda del verde (SWIR) y el infrarrojo cercano (NIR); el Índice de Agua de Diferencia Normalizada Modificada (MNDWI, por sus siglas en inglés) (Xu, 2006), y el Índice de Vegetación de Diferencia Normalizada (NDVI, por sus siglas en inglés), usado para detectar cuerpos de agua en zonas áridas (Aguilar *et al.*, 2012; Escobar-Flores *et al.*, 2019). Entre los satélites más mencionados para calcular este índice están SPOT y Landsat, como satélites de resolución moderada (20 y 30 m) y de alta resolución (1 y 10 m) se han utilizado IKONOS y Sentinel-2 para la detección de cuerpos de agua menores a 3 m² (Klemas y Pieterse, 2015).

Esta investigación se realizó en la SMO, cadena montañosa que representa una sexta parte del territorio nacional. Ésta fue el centro de la actividad minera y actualmente es la principal fuente de agua para el norte del país (Descroix, González y Estrada-Ávalos, 2004).

Los objetivos de esta investigación fueron: 1) la detección de cuerpos de agua en la Sierra Madre Occidental, y 2) realizar un inventario de los cuerpos de agua en diferentes tipos de vegetación.

METODOLOGÍA

Área de estudio

La Sierra Madre Occidental constituye el macizo de riolita más grande del mundo, se extiende por casi 1 200 km, se localiza en el noreste de México y abarca los estados de Chihuahua, Sonora, Sinaloa, Durango, Jalisco, Nayarit y Zacatecas, desde el noreste de Sonora (30° 35' N) hasta el norte de Jalisco (2° 00' N). Cubre una extensión de 289 000 km² y representa la sexta parte de México (Figura 1). La vegetación predominante en la vertiente oriental

son bosques bajos abiertos y chaparral hasta 2 300 metros; en las partes más altas dominan los bosques de pino y encino, y en las vertientes orientadas al Pacífico, desde 0 hasta 1500 m, predominan comunidades vegetales de selva baja caducifolia (González-Elizondo *et al.*, 2012).

Procesamiento de imágenes

Los insumos utilizados para este estudio fueron 120 imágenes del satélite Sentinel-2A, con una cobertura de nubes menor a 10%. Las imágenes fueron descargadas de la plataforma del Servicio Geológico de Estados Unidos (USGS, por sus siglas en inglés), disponible en la página www.glovis.usgs.gov, con fechas de adquisición de octubre de 2017, las cuales corresponden con el fin del periodo de lluvias de la zona de estudio; esto con la finalidad de detectar la mayoría de los cuerpos de agua presentes en la SMO. Las imágenes del satélite Sentinel-2 tienen una resolución especial de 10 m y la frecuencia de revisita es cada 10 días, son multispectrales y tienen un total de 13 bandas (Du *et al.*, 2016).

Para cada imagen satelital se seleccionaron las bandas espectrales en las que el agua presentaba un comportamiento de absorción de mayor contraste; éstas son de color verde (B3) del espectro visible (520-565 nm), e infrarrojo cercano B8 (NIR) (780-2500 nm). La B3 maximiza la reflectancia de la vegetación y la B8 minimiza la reflectancia de las masas de agua.

Debido a la compleja orografía de la SMO, fue necesario aplicar a cada imagen satelital una corrección radiométrica siguiendo el método de Chávez (1988); esto se debe a que las imágenes tienden a eliminar los ruidos causados a la señal que llega al satélite luego de haber atravesado la atmósfera (Chuvieco, 2010).

Detección de cuerpos de agua

Para la detección de cuerpos de agua se aplicó el NDWI propuesto por McFeeters (1996), método que se utiliza para delinear cuerpos de agua abiertos y aumentar su presencia en imágenes digitales de los sensores remotos (Kumar *et al.*, 2015; Memon *et al.*, 2015; Moradi, Sahebi y Shokri, 2017). Dicho índice hace uso de la radiación absorbida del infrarrojo cercano y reflejada de la banda

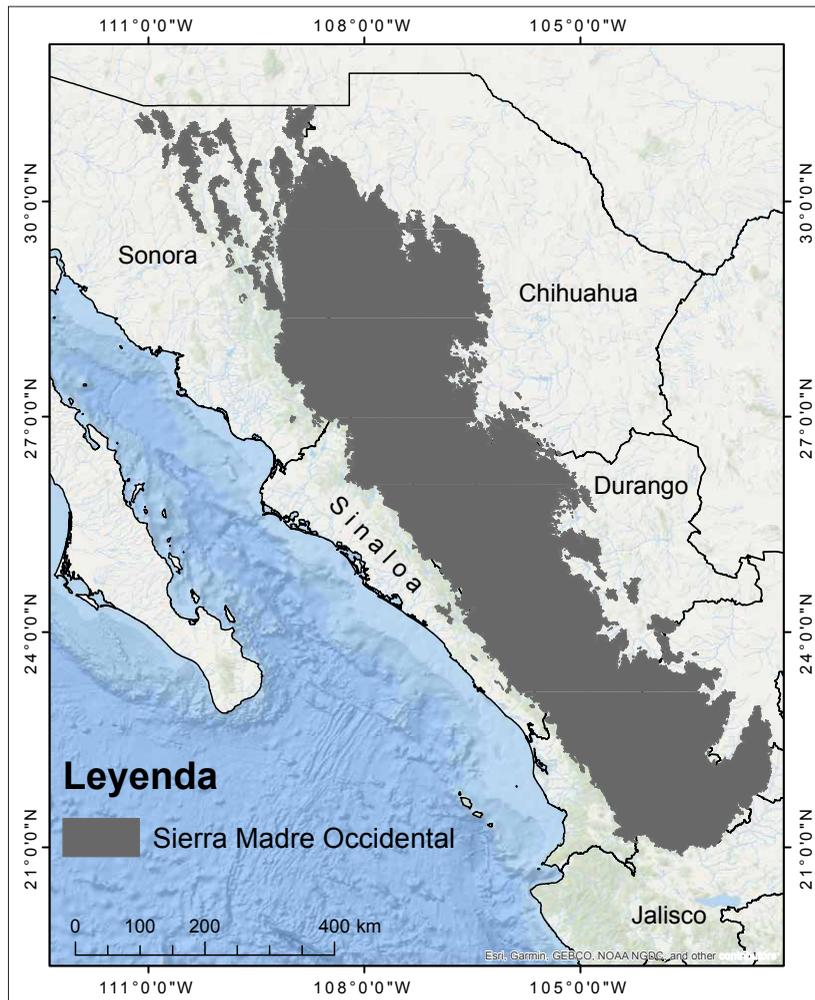


Figura 1. Sierra Madre Occidental México y sus límites. Fuente: González-Elizondo et al. (2012).

verde visible para aumentar la presencia de estos elementos mientras eliminan la presencia del suelo y los atributos de vegetación. Con éste se pueden reconocer desde cuerpos con grandes superficies hasta masas de agua pequeñas, tales como turberas y ecosistemas acuáticos de difícil percepción fotográfica (McFeeters, 1996).

Los valores del índice oscilan en un rango de -1 a 1, donde los menores a 0 están asociados a superficies sin presencia de vegetación o agua, y los mayores a 0 están asociados a presencia de agua y vegetación. Cuanto más se acerca a 1, mayor es el contenido de agua. El NDWI se calcula utilizando la ecuación propuesta por McFeeters (1996):

$$NDWI = \frac{\text{banda verde} - \text{banda NIR}}{\text{banda verde} + \text{banda NIR}} \quad (1)$$

Donde la banda verde es la banda visible del verde y la banda NIR es la longitud de onda infrarroja.

Una vez obtenidos los cuerpos de agua detectados en formato raster, se convirtieron a polígono con la herramienta Conversion Tools, de ArcGIS 10.7.1, posteriormente se calculó el área en m² y la superficie en km² de cada uno de los cuerpos detectados, con el cálculo de su geometría.

Validación

Previo al proceso de validación, se realizó una tabulación cruzada entre los cuerpos de agua que se detectaron contra los polígonos de tipos de vegetación, los cuales se clasificaron de la siguiente manera: clase bosque, que incluye los tipos de vegetación de pino, encino, pino-encino, encino-pino y bosque mesófilo; clase selva, que incluye selva baja y mediana caducifolia; clase bosque con vegetación secundaria herbácea y arbustiva; clase matorral; clase pastizal, y clase chaparral. Estos polígonos se obtuvieron de la Serie VI del vectorial de uso del suelo y vegetación del Inegi, escala 1:250 000. Mediante un geoprociamiento de CLIP en el programa ArcGIS 10.7.1 se obtuvo el número de cuerpos de agua detectados en cada clase de vegetación.

La precisión en la detección de los cuerpos de agua en cada clase de vegetación se evaluó utilizando el coeficiente Kappa (k) (Congalton, 1991; Abaira, 2001), con una tabla 2×2 , con las siguientes consideraciones: i) acuerdo positivo, entre el número de cuerpos de agua detectados por el algoritmo NDWI y confirmando que, si existen, ii) cuerpos de agua detectados que son sombras, iii) cuerpos de agua no detectados y que, si existen, iv) ambas ausencias correctas, donde los cuerpos de agua no estaban presentes y no se detectaron. También se calculó el error estándar de k (Ec. 2).

$$DE = \sqrt{\frac{Po(1-Po)}{n(1-Pe)^2}} \quad (2)$$

Donde:

Po = representa el acuerdo observado, Pe = representa el acuerdo esperado y n es el número total de observaciones.

Los intervalos de confianza (IC) de 95% de k se calcularon de la siguiente manera: $IC_{95\%} = k \pm 1.96$, desviación estándar (k). El parámetro k toma valores entre 0 y 1; k cerca de 1 indica un mayor grado de acuerdo entre clasificación y observación, y un valor de 0 sugiere que el acuerdo es aleatorio.

En ocasiones el índice de Kappa puede subestimar o sobreestimar la precisión en la clasificación temática (Olofsson *et al.*, 2013), por tal motivo,

en este estudio los cuerpos de agua encontrados en cada tipo de vegetación se evaluaron con una matriz de confusión, que se define como una tabla que compara registros de referencia, en este caso, los reportados por Conabio y registros de cuerpos de agua extraídos a partir del NDWI. También se estimó la incertidumbre de la clasificación siguiendo la propuesta de Olofsson *et al.* (2013) mediante la matriz de error en términos de la proporción del área y de la exactitud del mapa (\hat{O}), errores de comision (\hat{U}_i) y exactitud del productor o errores de omision (\hat{P}_j) (Congalton, 1991).

En la matriz de error, p_{ij} es definido como una entrada de celda de matriz de error de i clases de mapas (Ec. 3). Un estimador postratificado de p_{ij} es:

$$\hat{p}_{ij} = W_i \frac{n_{ij}}{n_i} \quad (3)$$

Donde:

W_i es la proporción del área asignada como clase; i , es el total de unidades de la muestra en la clase de mapa; i , n_{ij} es el recuento de muestra en la celda (i, j) en la matriz de error; \hat{p}_{ij} es un estimador posestratificado para muestreo aleatorio simple y sistemático (Ec. 4), donde q es el número de clases.

$$\hat{p}_{.j} = \sum_{i=1}^q W_i \frac{n_{ij}}{n_i} \quad (4)$$

Un estimador imparcial del área total de la clase j es entonces el reflejado en la ecuación 5, donde A es el área total del mapa. Para, el error estándar se estima con la ecuación 6.

$$\hat{A}_j = A \cdot \hat{p}_{.j} \quad (5)$$

$$S(\hat{p}_{.j}) = \sqrt{\sum_{i=1}^q W_i^2 \frac{n_{ij}(1 - \frac{n_{ij}}{n_i})}{n_i - 1}} \quad (6)$$

El error estándar del área estimada ajustada por error es el expresado en la ecuación 7 y, finalmente, los intervalos de confianza a 95% se calculan con la ecuación 8:

$$S(\hat{A}_j) = A \cdot S(\hat{p}_{.j}) \quad (7)$$

$$\hat{A}_j \pm 1.96 \cdot S(\hat{A}_j) \quad (8)$$

RESULTADOS

Un total de 120 imágenes satelitales Sentinel-2 fueron procesadas para obtener un cubrimiento sinóptico de la Sierra Madre Occidental. En el área de estudio se detectaron un total de 26 394 cuerpos de agua (Anexo 1), y 16% de éstos fueron sombras (Figura 2; Apéndice I). Los cuerpos de agua detectados tuvieron una superficie de entre 64 m² y 43 km². Los cuerpos de agua de mayor superficie fueron las presas. Los valores de los píxeles a partir del NDWI encontrados en los cuerpos de agua

oscilaron entre 0.1 a 0.8, con una mediana cercana a 0.3, y los cuartiles, entre 0.2 y 0.4.

Los tipos de vegetación con más cuerpos detectados fueron los bosques, con 12 369, seguidos del pastizal, con 5 667, y el bosque con vegetación secundaria, con 4 096. En cuanto a la precisión de la detección de cuerpos agua, en todos ellos los valores de Kappa indicaban acuerdos buenos y excelentes (Tabla 1); los tipos de vegetación de bosque de pino-encino y mesófilo presentaron el menor valor: $K = 0.62$, lo que también se relacionó con sombras que se confundieron con cuerpos de agua (251 sombras), mientras que el mayor valor de Kappa se obtuvo en los pastizales, con $K = 0.91$, donde se detectaron muy pocas sombras que se confundieron con cuerpos de agua (13 sombras).

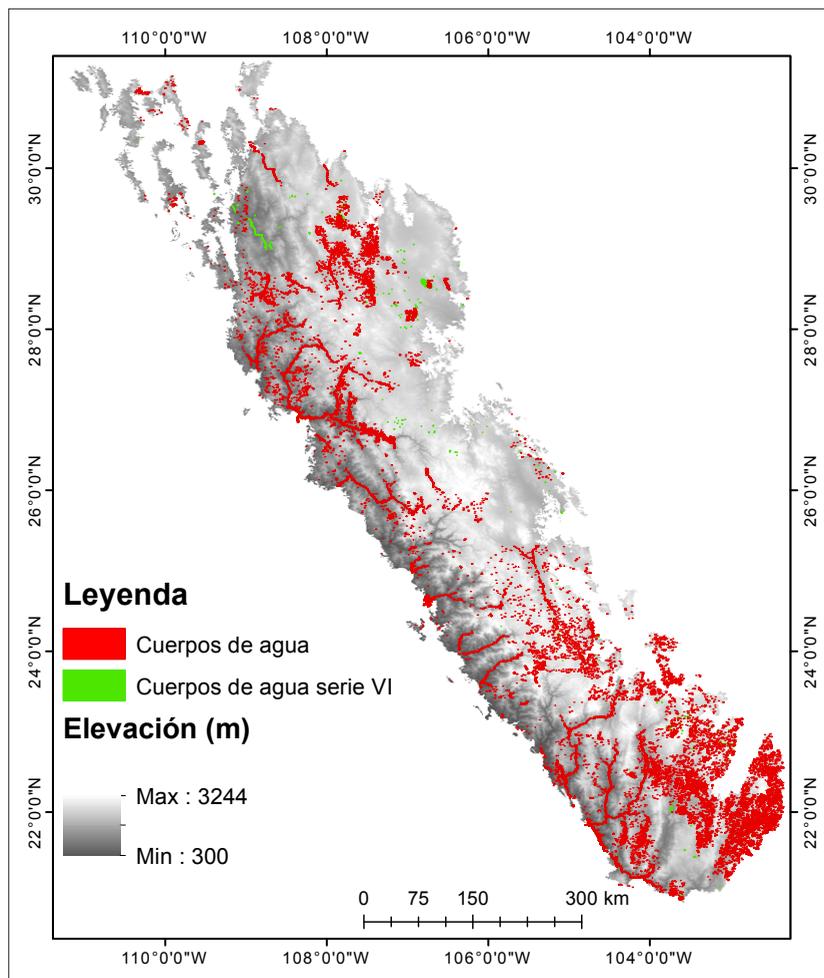


Figura 2. Cuerpos de agua detectados en la Sierra Madre Occidental. Fuente: Elaboración propia.

Tabla 1. Valores de Kappa con $p = 0.0001$, que indica que los acuerdos observados no fueron accidentales en la detección de cuerpos de agua en los tipos de vegetación en la SMO.

Tipo de vegetación	N	Kappa	Desv. estandar de Kappa	Área (ha)
B*	12 369	0.62	0.013	12393 ± 59.19
Bs**	4 096	0.86	0.012	4242 ± 75.38
S***	4 008	0.90	0.010	10292 ± 76.66
M****	250	0.71	0.023	345 ± 85.02
Pz*****	5 667	0.91	0.007	2311 ± 73.01
Chaparral	4	--	--	0.89

* Bosque

** Bosque con vegetación secundaria herbácea y arbustiva

*** Selva baja y mediana caducifolia

**** Matorral

***** Pastizal

Nota: la superficie estimada se obtuvo a partir de los errores de la matriz de confusión.

Fuente: Elaboración propia

Los tipos de vegetación con mayor superficie de cuerpos de agua fueron la clase bosques, con 12 393 ha ± 59.19, y con una proporción de área mapeada de $Wi = 0.3587$; seguido por la clase selvas, con 10 292 ha ± 76.6, y cuya proporción de área mapeada fue de $Wi = 0.2977$; la clase bosques con vegetación secundaria obtuvo 4 4242 ha ± 75.38 y un valor de $Wi = 0.1255$, mientras que las clases con menor

superficie de cuerpos de agua fueron el matorral y el chaparral (Tabla 2).

La precisión global fue de 0.738, y en la matriz de error se encontró que la clase que presentó mayores errores de comisión fue el pastizal, con un valor de exactitud de usuario de 0.227. Otra clase que tuvo una mayor omisión fue el matorral, con un valor de exactitud del productor de 0.351. Las

Tabla 2. Resultados obtenidos en la matriz de confusión.

Clases	Referencias					Total	Área (ha)	Wi*****
	B	Bs	S	M	Pz			
B*	12 369	532	0	32	268	13 201	13 109.0	0.3587
Bs**	106	4 096	1	106	891	5 200	4 588.4	0.1255
S***	3	36	4 008	22	174	4 243	10 882.0	0.2977
M****	15	12	19	250	1 239	1 535	1 007.7	0.0276
Pz*****	30	4	90	49	5 667	5 840	6 960.8	0.1905
Total	12 523	4 680	4 118	459	8 239	30 019	36 547.8	1.0000

* Bosque

** Bosque con vegetación secundaria herbácea y arbustiva

*** Selva baja y mediana caducifolia

**** Matorral

***** Pastizal

***** Proporción del área del mapa para la clase i

Fuente:Elaboración propia

otras clases tuvieron valores bajos en los errores de comisión y omisión (Tabla 3).

DISCUSIÓN

La detección de cuerpos de agua en la SMO fue viable por medio del NDWI derivado de imágenes satelitales Sentinel-2. La delimitación de ~26 000 cuerpos de agua contribuye sustancialmente a los 800 cuerpos de agua reportados previamente para la SMO en la Serie VI del uso del suelo y vegetación (INEGI, 2016). La metodología de esta investigación para la detección y delineación de cuerpos de agua es más sencilla que la descrita por Singh *et al.* (2019), quienes proponen la combinación de cuatro índices espectrales para la delimitación de cuerpos de agua, lo cual implica un mayor tiempo de procesamiento, además de que estos procesos son realizados en imágenes Landsat 8-OLI. Sin embargo, la aplicación del NDWI puede tener limitaciones, principalmente en cuerpos de agua poco profundos (menores de 0.5 m), lo cual provoca efectos de atenuación múltiple que producen superficies borrosas causados por el efecto del fondo y los componentes de la columna del agua (Singh *et al.*, 2019). Para el caso de la SMO, los tipos de vegetación que presentan estos cuerpos de agua

poco profundos fueron el matorral y el chaparral.

Los valores de NDWI en los cuerpos de agua detectados oscilaron entre 0.1 y 0.8; se ha reportado que esta variación tiene relación con la profundidad, la cantidad de sólidos disueltos y la presencia de materia orgánica en los cuerpos de agua (Rokni *et al.*, 2014; Yang *et al.*, 2017). En cuanto a la precisión en la detección de los cuerpos de agua, en general se encontró que 16% del total en realidad fueron sombras; esto se determinó porque al extraer los valores de los píxeles, en promedio fueron menores a 0, lo cual se asocia con superficies oscuras que no son agua (McFeeters, 1996). Para el caso de la SMO hay dos posibilidades de que el algoritmo de NDWI no encuentre agua, o bien se confunda por: 1) la presencia de superficies rocas de riolita y basaltos desprovistos de vegetación. Este tipo de rocas tiene un comportamiento espectral similar a los cuerpos de agua que oscila entre 1400 nm y 1500 nm de longitud de onda (Rivard *et al.*, 2009); estos afloramientos rocosos son comunes en vegetación de matorral en la SMO (Descroix, González y Estrada-Ávalos, 2004), y 2) el tamaño del cuerpo de agua, por ejemplo, en sitios con una cobertura vegetal mayor a 80%, como en el caso del bosque mesófilo, donde la vegetación cubre en su totalidad el cuerpo de agua y, por lo tanto, no es posible detectarlo. También existe la posibilidad

Tabla 3. Matriz de errores para las cinco clases consideradas expresadas en términos de proporción de área.

Clases	Referencias					Exactitud		
	B	Bs	S	M	Pz	Usuario	Productor	Global
B*	0.336	0.014	0.000	0.009	0.007	0.937	0.991	0.738
Bs**	0.002	0.098	0.000	0.002	0.021	0.787	0.851	
S***	0.003	0.002	0.281	0.001	0.012	0.944	0.998	
M****	0.003	0.002	0.003	0.004	0.022	0.807	0.351	
Pz*****	0.001	0.001	0.002	0.001	0.184	0.227	0.000	
Total	0.339	0.116	0.281	0.009	0.063			

* Bosque

** Bosque con vegetación secundaria herbácea y arbustiva

*** Selva baja y mediana caducifolia

**** Matorral

***** Pastizal

Fuente:Elaboración propia

de no detectar cuerpos de agua menores a 50 m², lo cual representa menos de la mitad del tamaño mínimo del píxel para imágenes Sentinel-2, que es de 100 m² (Tomíng *et al.*, 2016).

Lo anterior fue evidente porque el cuerpo de agua de menor superficie detectado y que se pudo delinear fue de 64 m², mejorando lo reportado por Bolanos *et al.* (2016), quienes utilizaron el sensor RadarSat-2 y detectaron cuerpos de agua con una superficie mínima de 100 m²; sin embargo, nuestros resultados contrastan con cuerpos de agua detectados, con superficies de 10 m², pero en vegetación desértica o de matorral (Xu, 2006; Escobar-Flores *et al.*, 2019).

La concordancia medida por el coeficiente de Kappa en la detección de cuerpos de agua en todos los tipos de vegetación fue de sustancial a buena, y coincidió con lo reportado por Du *et al.* (2016) y Escobar-Flores *et al.* (2019), al utilizar el mismo algoritmo de NDWI derivado de imágenes Sentinel-2. El valor de Kappa más bajo se obtuvo en vegetación de bosque (Tabla 1), lo que posiblemente se relaciona con el dosel de los bosques que cubre los cuerpos de agua y con el uso de imágenes de satélite provenientes de sensores pasivos la detección disminuye (Chuvieco, 2010).

Los tipos de vegetación que tuvieron valores de Kappa mayores fueron el pastizal y las selvas (Tabla 1), lo cual se esperaba. En el caso de los pastizales es vegetación abierta y de un tamaño que no obstruye la visibilidad de los cuerpos de agua, y en las selvas la mayoría de los cuerpos de agua se localizan en arroyos de primer y segundo orden, los cuales llegan a tener dimensiones mayores a 100 km de longitud, lo cual facilitó su detección (Descroix, González y Estrada-Ávalos, 2004).

Sin embargo, los valores de Kappa no fueron confiables para evaluar la precisión de la clasificación, por ejemplo, en la clase matorral se obtuvo $k = 0.71$, pero la exactitud del usuario y de productor fueron las más erróneas (Tabla 3), lo que contrasta con la clase bosque, en la cual se obtuvo $k = 0.61$, que fue la más baja para todas las clases, pero que en la matriz de errores obtuvo los mejores valores de precisión (usuario = 0.937, productor = 0.991), lo que ayudó a llevar a cabo una mejor estimación de la superficie que representan los cuerpos de agua para

ese tipo de vegetación. Estas inconsistencias ya han sido reportadas por Pontius y Millones (2011), motivo por el cual estos autores recomiendan la validez de la clasificación mediante una matriz de errores, como también sugieren Olofsson *et al.* (2013).

CONCLUSIONES

La detección y el monitoreo de cuerpos de agua es vital para estudiar los procesos ecológicos e hidrológicos. En los últimos años se dispone de imágenes de satélite con alta resolución espacial de adquisición libre, por lo que se pueden abarcar grandes áreas de estudio, como fue el caso de la SMO. El método llevado a cabo es de fácil aplicación y de bajo costo, pero se recomienda un monitoreo de estos cuerpos de agua durante época de secas para encontrar diferencias y hacer un inventario de cuerpos de agua permanentes o temporales, y así relacionar la variación y el tamaño de los cuerpos de agua con condiciones climáticas. Se recomienda que la técnica de detección de cuerpos de agua se considere en los inventarios realizados por el Inegi, los ejidos y la propiedad privada. Mediante esta metodología fue posible delinear cuerpos de agua con una superficie mayor a 64 m².

APÉNDICE I

El *shapefile* de los cuerpos de agua estará disponible gratuitamente en el siguiente enlace:

https://www.dropbox.com/sh/6rfxi47ii8q6jkk/AAB5MWqMBCFvisiboX_m86LTa?dl=0

REFERENCIAS

- Abraira, V. (2001). El índice Kappa. *Semergen*, 27(5), 247-249.
- Aguilar, C., Zinnert, J. C., Polo, M. J. y Young D. R. (2012). NDVI as an Indicator for Changes in Water Availability to Woody Vegetation. *Ecological Indicators*, 23, 290-300. Recuperado de <https://doi.org/10.1016/j.ecolind.2012.04.008>

- Bolanos, S., Stiff, D., Brisco, B. y Pietroniro, A. (2016). Operational Surface Water Detection and Monitoring Using Radarsat 2. *Remote Sensing*, 8(4), 285-302.
- Brisco, B., Short, N., van der Sanden, R. L., Landry, R. y Raymond, D. (2009). A Semi-Automated Tool for Surface Water Mapping with RADARSAT-1. *Canadian Journal of Remote Sensing*, 35(4), 336-344. Recuperado de <https://doi.org/10.5589/m09-025>
- Canaz, S., Karsli, F., Guneroglu, A. y Dihkan, M. (2015). Automatic Boundary Extraction of Inland Water Bodies Using LiDAR Data. *Ocean & Coastal Management*, 118, 158-166. Recuperado de <https://doi.org/10.1016/j.ocecoaman.2015.07.024>
- Chávez, P. S. (1988). An Improved Dark-Object Subtraction Technique for Atmospheric Scattering Correction of Multispectral Data. *Remote Sensing of Environment*, 24(3), 459-479. Recuperado de [https://doi.org/10.1016/0034-4257\(88\)90019-3](https://doi.org/10.1016/0034-4257(88)90019-3)
- Chuvieco, E. (2010). *Teledetección ambiental*. España: Ariel.
- Congalton, R. G. (1991). A Review of Assessing the Accuracy of Classifications of Remotely Sensed Data. *Remote Sensing of Environment*, 37(1), 35-46. Recuperado de [https://doi.org/10.1016/0034-4257\(91\)90048-B](https://doi.org/10.1016/0034-4257(91)90048-B)
- Descroix, L., González, J. L. y Estrada-Ávalos, J. (2004). *La Sierra Madre Occidental, una fuente de agua amenazada*. México: INIFAP.
- Du, Y., Zhang, Y., Ling, F., Wang, Q., Li, W. y Li, X. (2016). Water Bodies Mapping from Sentinel-2 Imagery with Modified Normalized Difference Water Index at 10-m Spatial Resolution Produced by Sharpening the SWIR Band. *Remote Sensing*, 8(4), 354-372. Recuperado de <https://doi.org/10.3390/rs8040354>
- Escobar-Flores, J. G., Sandoval, S., Valdez, R., Shahriary, E., Torres, J. y Alvarez-Cardenas, S. (2019). Water-hole Detection Using a Vegetation Index in Desert Bighornsheep (*Ovis canadensis cremnobates*) Habitat. *PLoS ONE*, 14(1): 211-202. Recuperado de <https://doi.org/10.1371/journal.pone.0211202>
- González-Elizondo, M. S., González-Elizondo, M., Tena-Flores, J. A., Ruacho-González, L. y López-Enríquez, I. L. (2012). Vegetación de la Sierra Madre Occidental, México: una síntesis. *Acta Botanica Mexicana*, 100, 351-403.
- Huang, C., Chen, Y., Wu, J., Li, L. y Liu, R. (2015). An Evaluation of Suomi NPP-VIIRS Data for Surface Water Detection. *Remote Sensing Letters*, 6, 155-164. Recuperado de <https://doi.org/10.1080/2150704X.2015.1017664>
- INEGI. 2016. Conjunto de Datos Vectoriales de Uso de Suelo y Vegetación. Escala 1:250 000. Serie VI (Capa Union), escala: 1:250 000. edición: 1. Instituto Nacional de Estadística y Geografía. Aguascalientes, México
- Klemas, V. y Pieterse, A. (2015). Using Remote Sensing to Map and Monitor Water Resources in Arid and Semiarid Regions. En T. Younos y T. Parece (Eds.), *Advances in Watershed Science and Assessment. The Handbook of Environmental Chemistry* (vol. 33). Cham: Springer.
- Klemenjak, S., Waske, B., Valero, S. y Chanussot, J. (2012). Automatic Detection of Rivers in High-Resolution SAR Data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5, 1364-1372. Recuperado de <https://doi.org/10.1109/JSTARS.2012.2189099>
- Kumar, S. V., Peters-Lidard, C. D., Santanello, J. A., Reichle, R. H., Draper, C. S., Koste, R. D., Nearing, G. y Jasinski, M. F. (2015). Evaluating the Utility of Satellite Soil Moisture Retrievals over Irrigated Areas and the Ability of Land Data Assimilation Methods to Correct for Unmodeled Processes. *Hydrology and Earth System Sciences*, 19, 4463-4478.
- Lu, S., Jia, L., Zhang, L., Wei, Y., Baig, M. H. A., Zhai, Z. y Zhang, G. (2016). Lake Water Surface Mapping in the Tibetan Plateau Using the MODIS MOD09Q1 Product. *Remote Sensing Letters*, 8(3), 224-233. Recuperado de <https://doi.org/10.1080/2150704X.2016.1260178>
- McFeeters, S. K. (1996). The Use of the Normalized Difference Water Index (NDWI) in the Delineation of Open Water Features. *International Journal of Remote Sensing*, 17(7), 1425-1432. Recuperado de <https://doi.org/10.1080/01431169608948714>
- Memon, A. A., Muhammad, S., Rahmana, S. y Haq, M. (2015). Flood Monitoring and Damage Assessment Using Water Indices: A Case Study of Pakistan Flood-2012. *The Egyptian Journal of Remote Sensing and Space Sciences*, 18, 99-106. Recuperado de <http://dx.doi.org/10.1016/j.ejrs.2015.03.003>
- Moradi, M., Sahebi, M. y Shokri, M. (2017). Modified Optimization Water Index (Mowi) for Landsat-8 Oli/Tirs, The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XLII-4/W4, 2017. Tehran's Joint ISPRS Conferences of GI Research, SMPR and EOEC 2017. Conferencia llevada a cabo en Teherán, Irán, del 7 al 10 de octubre de 2017.
- Olofsson O, Foody GM, Stehman SV, Woodcock CE. 2013. Making better use of accuracy data in land change studies: Estimating accuracy and area and quantifying uncertainty using stratified estimation. *Remote Sensing of Environment* 129:122-131. DOI: 10.1016/j.rse.2012.10.031
- Papa, F., Güntner, A., Frappart, F., Prigent, C., y Rossow, W. B. (2008). Variations of Surface Water Extent and

- Water Storage in Large River Basins: A Comparison of Different Global Data Sources. *Geophysical Research Letters*, 35. <http://doi.10.1029/2008GL033857>
- Pontius Jr, R. G., y Millones, M. (2011). Death to Kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment. *International Journal of Remote Sensing*, 32(15), 4407-4429.
- Rajagopal, R. M. W. y Brands, E. (2017). Water: Drinking. En *The International Encyclopedia of Geography* (pp. 7587-7599). Recuperado de <https://doi.org/10.1002/9781118786352.wbieg0338>
- Rivard, B., Zhang, J., Feng, J. y Sanchez-Azofeifa, G. A. (2009). Remote Predictive Lithologic Mapping in the Abitibi Greenstone Belt, Canada, Using Airborne Hyperspectral Imagery. *Canadian Journal of Remote Sensing*, 35, S95-S105. Recuperado de <https://doi.org/10.5589/m10-002>
- Rokni, K., Ahmad, A., Selamat, A. y Hazini S. (2014). Water Feature Extraction and Change Detection Using Multitemporal Landsat Imagery. *Remote Sensing*, 6, 4173-4189. Recuperado de <https://doi.org/10.3390/rs6054173>
- Sarp, G. (2014). Spectral and Spatial Quality Analysis of Pan-Sharpener Algorithms: A Case Study in Istanbul. *Journal European Journal of Remote Sensing*, 47(1), 19-28. Recuperado de <https://doi.org/10.5721/EuJRS20144702>
- Sharma, R. C., Tateishi, R., Hara, K. y Nguyen, L. V. (2015). Developing Superfine Water Index (SWI) for Global Water Cover Mapping Using MODIS Data. *Remote Sensing*, 7(10), 13807-13841. Recuperado de <https://doi.org/10.3390/rs71013807>
- Singh, K. K. K., Bharti, A. K., Pal, S. K., Prakash, A., Kumar, R., y Singh, P. K. (2019). Delineation of fracture zone for groundwater using combined inversion technique. *Environmental Earth Sciences*, 78(4), 110.
- Toming, K., Kutser, T. Laas, A. Sepp, M., Paavel, B., y Nõges, T. (2016). First experiences in mapping lake water quality parameters with Sentinel-2 MSI imagery. *Remote Sensing*, 8, 640. Recuperado de <https://doi:10.3390/rs8080640>.
- UNESCO (2006). *El agua, una responsabilidad compartida*. Recuperado de <http://unesdoc.unesco.org/images/0014/001495/149519S.pdf>
- Vörösmarty, C. J., McIntyre, P. B., Gessner, M. O., Dudgeon, D., Prusevich, A., Green, P., Glidden, S., Bunn, S. E., Sullivan, C. A., Reidy, L. C. y Davies, P. M. (2010). Global Threats To Human Water Security and River Biodiversity. *Nature*, 467, 555-561. Recuperado de <https://doi.org/10.1038/nature09440>
- Xu, H. (2006). Modification of Normalised Difference Water Index (NDWI) to Enhance Open Water Features in Remotely Sensed Imagery. *International Journal of Remote Sensing*, 27, 3025-3033. Recuperado de <https://doi.org/10.1080/01431160600589179>
- Yang, X., Zhao, S., Qin, X., Zhao, Na. y Liang, L. (2017). Mapping of Urban Surface Water Bodies from Sentinel-2 MSI Imagery at 10 m Resolution via NDWI-Based Image Sharpening. *Remote Sensing*, 9, 596. Recuperado de <https://doi.org/10.3390/rs9060596>

ANEXO 1

Tabla 1. Ejemplo del inventario de cada uno de los ~26000 cuerpos de agua detectados en la Sierra Madre Occidental México (véase Apéndice 1).

ID	X	Y	Área (m ²)	Área (km ²)	Entidad	Municipio
1	712 571	2 387 689	135.017	0.00013502	ZACATECAS	Jalpa
2	661 955	2 387 669	68.359	0.00006836	ZACATECAS	Tepechitlán
3	581 005	2 387 649	68.393	0.00006839	NAYARIT	La Yesca
4	661 905	2 387 649	68.359	0.00006836	ZACATECAS	Tepechitlán
5	661 925	2 387 649	68.359	0.00006836	ZACATECAS	Tepechitlán
6	741 755	2 387 649	68.359	0.00006836	JALISCO	Teocaltiche
7	661 887	2387638	206.319	0.00020632	ZACATECAS	Tepechitlán
8	592 005	2 387 629	68.393	0.00006839	NAYARIT	La Yesca
9	651 304	2 387 656	1148.511	0.00114851	ZACATECAS	Tepechitlán
10	713 425	2 387 600	2634.502	0.00263450	ZACATECAS	Jalpa
11	714 423	2 387 575	440.360	0.00044036	ZACATECAS	Jalpa
12	741 765	2 387 569	68.359	0.00006836	JALISCO	Teocaltiche